

## Thèse

présentée devant

l'Université Claude Bernard Lyon-I

École Doctorale de Physique et d'Astrophysique

pour l'obtention du

DIPLÔME de DOCTORAT  
Spécialité : Physique des Particules

(arrêté du 7 août 2006)

par

*Nicolas CHANON*

### **Observation des photons directs dans les premières données et préparation à la recherche du boson de Higgs dans l'expérience CMS au LHC (CERN)**

Soutenue le 6 octobre 2010  
devant la Commission d'Examen

Jury :	Mme	S.	Gascon-Shotkin	Directrice de thèse
	M.	A.	Deandrea	co-directeur de thèse
	M.	G.	Dissertori	Rapporteur
	M.	G.	Unal	Rapporteur
	M.	B.	Ille	Président du jury
	M.	J.-P.	Guillet	
	M.	R.	Granier de Cassagnac	

Thèse de l'Université de Lyon

École Doctorale de Physique et Astrophysique de Lyon (PHAST)

Thèse de Doctorat en Physique des Particules

Institut de Physique Nucléaire de Lyon (IPNL)

Observation des photons directs dans les premières données  
et préparation à la recherche du boson de Higgs dans l'expérience  
CMS au LHC (CERN)

Nicolas CHANON

Sous la direction de :  
Suzanne Gascon-Shotkin  
Aldo Deandrea

JURY :	Mme S. GASCON-SHOTKIN	(directeur de thèse)
	M. A. DEANDREA	(co-directeur de thèse)
	M. G. DISSERTORI	(rapporteur)
	M. G. UNAL	(rapporteur)
	M. B. ILLE	(examineur)
	M. J.-P. GUILLET	(examineur)
	M. R. GRANIER DE CASSAGNAC	(examineur)

## Remerciements :

J'aimerais tout d'abord remercier Suzanne Gascon-Shotkin, qui a été mon encadrante durant ces trois années de thèse, pour sa bonne humeur, son souci pour l'avenir de ses étudiants et son enthousiasme. Suzanne, tu as su me faire confiance, m'encourager et me guider et pour cela je te remercie. Je te remercie aussi de m'avoir poussé à explorer toute la chaîne d'analyse, de la reconstruction aux résultats finaux. Enfin, je crois que je me rappellerai longtemps les trajets en voiture Lyon-CERN avec toi !

Je tiens aussi à remercier Aldo Deandrea, pour avoir accepté d'être mon co-directeur de thèse et m'avoir permis de réaliser un projet qui me tenait à coeur : effectuer des travaux d'ordre plus phénoménologiques, sur la physique au-delà du modèle standard. Je voudrais remercier Guillaume Unal et Günther Dissertori pour avoir accepté d'être rapporteurs, ainsi que Jean-Philippe Guillet, Raphaël Granier de Cassagnac et Bernard Ille d'être examinateurs. Désolé de vous avoir infligé la lecture de ce long document, j'espère que vous y aurez trouvé quelque plaisir...

Je voudrais aussi remercier chaudement Morgan Lethuillier, qui a été particulièrement présent lors du moment difficile de la fin de rédaction de thèse (jusqu'à s'absenter de ses vacances pour me rendre le manuscrit corrigé !). Merci Morgan pour tes conseils, ton jugement scientifique toujours avisé et ta disponibilité, c'était vraiment un plaisir de travailler avec toi ! Merci aussi à Jean Fay pour toutes ces discussions au CERN, tes conseils et ton recul. Merci à Houmani El Mamouni et Pierre Depasse pour m'avoir permis d'enseigner en licence ainsi qu'à l'IUT, deux univers très différents, c'était une expérience très enrichissante. J'ai aussi une pensée pour Jean-Paul Martin, Hugues Chabot et Hubert Hansen pour ces intéressantes discussions sur la science. Cet atelier d'histoire de la physique est définitivement une expérience à réitérer ! Enfin merci à Sylvie Florès pour ta patience et ton efficacité...

Je voudrais aussi remercier Clément Bâty, Hugues Brun et Olivier Bondu, les thésards avec qui j'ai partagé le bureau à l'IPNL... et eu le plaisir d'engager maintes batailles de gobelets en plastiques :) Un grand merci à Dominique Fortin pour avoir initié le mouvement (tu vois nous l'avons perpétué par-delà les générations). Clément, tes inénarrables histoires de logiciel libre, de science-fiction et de sirop d'orgeat me manquent déjà ; j'espère que tu réaliseras tes projets concernant l'enseignement. Hugues, courage pour la fin de la thèse - je suis sûr que tu vas finir par devenir color convenir ;) . Olivier, je te souhaite de garder la motivation nécessaire pour continuer de faire du théâtre ! ("faut pas se biler")

J'en profite pour remercier Timothée, Claire-Emilie, Yohann, Robert, Fabrice, Marcus et les autres doctorants de l'IPNL que j'oublie... Pour toutes les délires débités aux repas de midi et les bières enfilées au Berthom. Timothée, je promets que je ne t'embarquerai plus dans des trajets en voitures de plus de 500 km. Ou alors seulement pour écouter du gros son ;).

Un grand merci à mes amis qui m'ont tour à tour soutenu, supporté, permis de décompresser : les fidèles Pierre et Alexandre à l'amitié irréprochable, Antoine le fan inavoué d'Eddy Mitchell, Arnaud pour sa bouffée d'air artistique, Nicolas pour son franc-parler, Anthony pour ses délires scientifiques, je ne compte plus vos qualités. Je suis sûr que la dispersion géographique ne nous empêchera pas de nous voir.

Enfin, j'aimerais terminer en remerciant le Laboratoire France-Chine de Physique des Particules (FCPPL) pour m'avoir donné la chance de travailler deux mois à l'IHEP à Pékin. C'était vraiment une expérience fantastique, tant scientifiquement que culturellement. Je voudrais remercier Guoming Chen, Zhen Zhang, Xiao Hong, Junquan Tao ainsi que Zhang Zhenxia pour leur accueil chaleureux. Après l'aperçu que j'ai eu de la Chine, je suis persuadé que je reviendrai bientôt !



# Table des matières

<b>Résumé</b>	<b>6</b>
<b>Introduction</b>	<b>7</b>
<b>1 L'expérience CMS au LHC</b>	<b>9</b>
1.1 Présentation du LHC . . . . .	9
1.1.1 La machine . . . . .	10
1.1.2 Du démarrage à aujourd'hui . . . . .	12
1.2 L'expérience CMS . . . . .	12
1.2.1 Le détecteur CMS et ses sous-détecteurs . . . . .	13
1.2.2 Acquisition, reconstruction des données et simulation . . . . .	17
1.3 Le calorimètre électromagnétique de CMS . . . . .	19
1.3.1 Description du calorimètre électromagnétique . . . . .	20
1.3.2 Reconstruction des électrons et des photons . . . . .	24
<b>2 Physique du boson de Higgs</b>	<b>30</b>
2.1 Le boson de Higgs dans le modèle standard . . . . .	31
2.1.1 Naissance de la théorie de l'interaction électro-faible . . . . .	31
2.1.2 Mécanisme de Higgs dans le modèle standard . . . . .	33
2.1.3 Le boson de Higgs au-delà du modèle standard . . . . .	36
2.2 Le boson de Higgs au LHC . . . . .	38
2.2.1 L'interaction proton-proton . . . . .	38
2.2.2 Modes de production du boson de Higgs . . . . .	40
2.2.3 Désintégration du boson de Higgs . . . . .	43
2.3 La recherche du boson de Higgs : état de l'art et perspectives . . . . .	48
2.3.1 Limites d'exclusion du boson de Higgs : LEP et Tevatron . . . . .	49
2.3.2 Perspectives pour la recherche du boson de Higgs standard au LHC . . . . .	52
<b>3 Effets cinématiques dus aux ordres supérieurs</b>	<b>56</b>
3.1 Les générateurs à éléments de matrice . . . . .	57
3.1.1 Génération du processus $\gamma\gamma + X$ avec DIPHOX au NLO . . . . .	58
3.1.2 Génération du processus "boîte" $gg \rightarrow \gamma\gamma + X$ Gamma2MC au NLO . . . . .	61
3.1.3 Génération du processus $\gamma\gamma + X$ avec RESBOS . . . . .	62
3.1.4 Génération du processus $gg \rightarrow H \rightarrow \gamma\gamma$ avec HNNLO au NNLO . . . . .	64
3.2 Les générateurs à gerbes partoniques . . . . .	64
3.2.1 Le processus dur . . . . .	65
3.2.2 La radiation dans l'état initial et final . . . . .	66
3.2.3 La fragmentation ou hadronisation . . . . .	68
3.2.4 L'évènement sous-jacent et l'empilement . . . . .	68
3.3 Prendre en compte les effets dus aux ordres supérieurs dans la génération des évènements . . . . .	68
3.3.1 L'interfaçage entre les générateurs ME et PS . . . . .	69
3.3.2 La repondération des évènements PS avec les distributions ME aux ordres supérieurs . . . . .	70
3.4 Comparaison des prédictions théoriques aux données du Tevatron pour le processus $\gamma\gamma + X$ . . . . .	72
3.4.1 Section efficace $\gamma\gamma + X$ dans les données de CDF . . . . .	72

3.4.2	Section efficace $\gamma\gamma+X$ dans les données de D0 . . . . .	73
<b>4</b>	<b>Récupération des photons de bremsstrahlung interne dans le canal <math>H \rightarrow ZZ^* \rightarrow 4l</math></b>	<b>77</b>
4.1	Motivation . . . . .	78
4.2	Présentation de l'analyse $H \rightarrow ZZ^* \rightarrow 4l$ . . . . .	79
4.2.1	Signal et bruits de fond . . . . .	80
4.2.2	Déclenchement . . . . .	81
4.2.3	Reconstruction et identification des leptons . . . . .	81
4.2.4	Ecrémage et préselection . . . . .	81
4.2.5	Variables discriminantes et sélection des événements . . . . .	82
4.2.6	Incertitudes systématiques . . . . .	83
4.2.7	Résultats de l'analyse . . . . .	84
4.3	Description de la méthode de récupération "multi-brem" . . . . .	85
4.3.1	Méthode de récupération "PTDR" et "multi-brem" . . . . .	85
4.3.2	Optimisation des critères de sélection . . . . .	86
4.4	Résultats obtenus avec la récupération des photons FSR . . . . .	87
4.4.1	Sélection d'un lot de photons candidats . . . . .	88
4.4.2	Reconstruction des pics de masse invariante des bosons $Z^0$ et du boson de Higgs . . . . .	89
4.4.3	Impact de la récupération sur la signification . . . . .	91
4.5	Incertitudes statistiques et systématiques . . . . .	93
4.5.1	Incertitudes statistiques et gedanken experiment . . . . .	93
4.5.2	Source des incertitudes systématiques . . . . .	95
4.5.3	Incertitudes systématiques : contrôle de la méthode à partir des données . . . . .	97
4.6	Conclusions et perspectives pour la récupération des photons de bremsstrahlung interne . . . . .	103
4.6.1	Améliorations possibles . . . . .	104
4.6.2	Plans pour les premières données . . . . .	106
<b>5</b>	<b>Discrimination <math>\gamma/\pi^0</math> à l'aide d'un réseau de neurones</b>	<b>107</b>
5.1	Position du problème . . . . .	107
5.1.1	Propriétés des photons et des pions neutres . . . . .	107
5.1.2	Utilisation d'un réseau de neurones . . . . .	109
5.1.3	Discrimination $\gamma/\pi^0$ dans CMS . . . . .	110
5.2	Variables d'entrée du réseau de neurones . . . . .	113
5.2.1	Sélection des photons . . . . .	114
5.2.2	Variables de forme du cluster . . . . .	115
5.2.3	Variables d'environnement . . . . .	116
5.2.4	Corrélation des variables d'entrée . . . . .	118
5.3	Performances du réseau de neurones . . . . .	118
5.3.1	Choix du classifieur : le MLP . . . . .	120
5.3.2	Performances . . . . .	121
5.3.3	Comparaison avec une approche optimisée d'isolation . . . . .	128
5.4	Incertitudes systématiques . . . . .	129
5.4.1	Source des incertitudes systématiques . . . . .	129
5.4.2	Entraînement du réseau de neurones à partir des données . . . . .	130
5.5	Validation à partir des données . . . . .	134
5.5.1	Sélection . . . . .	134
5.5.2	Variables d'entrée . . . . .	136
5.5.3	Entraînement et test des réseaux de neurones . . . . .	136
5.5.4	Sortie des réseaux de neurones dans les données . . . . .	139
5.6	Conclusions et perspectives . . . . .	141

<b>6</b>	<b>Analyses du processus <math>\gamma</math>+X dans les données</b>	<b>143</b>
6.1	Signal $\gamma$ +jet attendu . . . . .	143
6.2	Mesure du spectre inclusif des photons par la méthode des templates dans les données . .	144
6.2.1	Préselection des photons . . . . .	145
6.2.2	Discrimination $\gamma/\pi^0$ pour le canal $\gamma$ +X . . . . .	146
6.2.3	Méthode “2 bins” . . . . .	146
6.2.4	Méthode d’ajustement par maximum de vraisemblance . . . . .	148
6.2.5	Mesure de la pureté et du nombre de photons de signal inclusifs . . . . .	149
6.2.6	Construction d’une distribution template à partir des données pour le bruit de fond	152
6.2.7	Incertitudes systématiques . . . . .	153
6.3	Entraînement du réseau de neurones avec les jets de $\gamma$ +jet . . . . .	155
6.3.1	Sélection d’un lot de photons mal identifiés dans les données : principe . . . . .	155
6.3.2	La sélection . . . . .	156
6.3.3	Entraînement et test du réseau de neurones . . . . .	156
6.3.4	Construction de la distribution template du bruit de fond . . . . .	157
6.4	Conclusion et perspectives . . . . .	157
<b>7</b>	<b>Repondération pour les analyses <math>\gamma\gamma</math>+X et <math>H \rightarrow \gamma\gamma</math></b>	<b>160</b>
7.1	Génération des processus $\gamma\gamma$ +X et $gg \rightarrow H \rightarrow \gamma\gamma$ . . . . .	161
7.1.1	Genérateurs pour les processus $\gamma\gamma$ +X et $H \rightarrow \gamma\gamma$ . . . . .	161
7.1.2	Configurations pour la repondération . . . . .	163
7.2	Etudes d’isolation au niveau partonique, générateur et reconstruit . . . . .	163
7.2.1	Proximité des critères de sélection niveau générateur et reconstruit . . . . .	164
7.2.2	Corrections au critère d’isolation dues à l’évènement sous-jacent et à l’hadronisation	165
7.2.3	Efficacités d’isolation au niveau partonique NLO . . . . .	167
7.2.4	Conclusion sur les études d’isolation . . . . .	168
7.3	Etude des variables cinématiques aux ordres supérieurs . . . . .	169
7.3.1	Variables cinématiques jusqu’au NLO pour le processus $\gamma\gamma$ +X . . . . .	169
7.3.2	Variables cinématiques jusqu’au NNLO pour le processus $gg \rightarrow H \rightarrow \gamma\gamma$ . . . . .	172
7.4	Repondération des processus $\gamma\gamma$ +X . . . . .	176
7.4.1	Repondération du processus $\gamma\gamma$ +X avec les échantillons officiels . . . . .	178
7.4.2	Echantillons $\gamma\gamma$ +X repondérés pour la recherche du boson de Higgs . . . . .	183
7.5	Repondération du processus $gg \rightarrow H \rightarrow \gamma\gamma$ . . . . .	185
7.5.1	Détermination des K-facteurs . . . . .	186
7.5.2	Application des K-facteurs . . . . .	188
7.5.3	Repondération appliquée aux autres observables . . . . .	189
7.6	Conclusion et perspectives sur la repondération . . . . .	189
<b>8</b>	<b>Préparation pour la mesure de la section efficace du processus <math>\gamma\gamma</math>+X</b>	<b>192</b>
8.1	Signal $\gamma\gamma$ +X attendu . . . . .	193
8.2	Mesure de la section efficace $\gamma\gamma$ +X par la méthode des “templates” dans la simulation . .	194
8.2.1	Méthode des “templates” pour $\gamma\gamma$ +X . . . . .	194
8.2.2	Discrimination $\gamma/\pi^0$ pour le canal $\gamma\gamma$ +X . . . . .	196
8.2.3	Mesure de la section efficace $\gamma\gamma$ +X dans la simulation . . . . .	197
8.2.4	Comparaison avec les prédictions théoriques par la méthode de repondération . . .	203
8.2.5	Incertitudes statistiques et systématiques . . . . .	203
8.3	Etudes des évènements diphotons dans les données . . . . .	204
8.3.1	Préselection des diphotons . . . . .	204
8.3.2	Masse invariante $\gamma\gamma$ pour différents critères d’identification des photons . . . . .	205
8.3.3	Autres distributions diphotons dans les données . . . . .	207
8.3.4	Mesure du nombre d’évènements de signal dans les données . . . . .	207
8.4	Conclusions et perspectives . . . . .	210

<b>9</b>	<b>Recherche du boson de Higgs dans le canal <math>H \rightarrow \gamma\gamma</math></b>	<b>212</b>
9.1	Sensibilité au canal $H \rightarrow \gamma\gamma$ : projections à 7 TeV et $1 fb^{-1}$	213
9.2	Préparation à la recherche du boson de Higgs dans le canal $H \rightarrow \gamma\gamma$ pour $\sqrt{s} = 7$ TeV et $1 fb^{-1}$	215
9.2.1	Echantillons et sélection de base des photons	215
9.2.2	Discrimination $\gamma/\pi^0$ pour le canal $H \rightarrow \gamma\gamma$	216
9.2.3	Construction des catégories	217
9.2.4	Optimisation en fonction de la signficance	218
9.2.5	Effet du réseau de neurone de discrimination $\gamma/\pi^0$ sur la signficance	220
9.2.6	Utilisation des variables cinématiques pour la réduction du bruit de fond $\gamma\gamma+X$	222
9.2.7	Incertitudes systématiques	226
9.2.8	Résultats : signficance et limites d'exclusion	230
9.2.9	Impact de la repondération sur les résultats obtenus	232
9.3	Conclusions et perspectives	234
<b>10</b>	<b>Recherche du boson de Higgs dans le canal <math>H \rightarrow \gamma\gamma</math> au-delà du modèle standard</b>	<b>237</b>
10.1	Paramétrisation de la théorie effective dans Madgraph	237
10.1.1	Théorie effective du boson de Higgs (HEFT) dans Madgraph	238
10.1.2	Implémentation de la paramétrisation $\kappa_{\gamma\gamma}-\kappa_{gg}$	238
10.2	Sections efficaces du boson de Higgs dans le plan $\kappa_{\gamma\gamma}-\kappa_{gg}$	239
10.2.1	Rapport des sections efficaces $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM} / \sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$ dans le plan $\kappa_{\gamma\gamma}-\kappa_{gg}$	239
10.2.2	Prise en compte des autres mécanismes de production	240
10.3	Interprétations pour la recherche du boson de Higgs avec 7 TeV et $1 fb^{-1}$	241
10.3.1	Projection de l'analyse du PTDR à 7 TeV	242
10.3.2	Rapport de vraisemblance multi-variables	242
10.4	Conclusions et perspectives	242
	<b>Conclusion</b>	<b>245</b>
<b>A</b>	<b>Reconstruction et identification des photons à <math>\sqrt{s} = 7</math> TeV</b>	<b>248</b>
A.1	Reconstruction des super-clusters et des photons	248
A.2	Identification des photons	250



# Résumé

Le LHC (Large Hadron Collider) fournit aux expériences du CERN (Organisation Européenne pour la Recherche Nucléaire) des collisions proton-proton avec une énergie de 7 TeV dans le centre de masse depuis fin Mars 2010. Le LHC a en particulier été conçu pour permettre la recherche du boson de Higgs, particule prédite par le modèle standard encore jamais observée à ce jour, dans toute la gamme de masse où il est attendu. Ce travail de thèse est une contribution à la recherche du boson de Higgs dans CMS (Compact Muon Solenoid), l'un des quatre grands détecteurs placés auprès du LHC, et développe plusieurs outils qui permettent la mesure des bruits de fonds et l'amélioration du potentiel de découverte, en particulier grâce à la prise en compte d'effets cinématiques dus aux ordres supérieurs dans le calcul perturbatif des sections efficaces différentielles.

Un premier effet dû aux ordres supérieurs est la radiation réelle de photons dans l'état final, pris en compte de façon approximée par les générateurs à gerbes partoniques. Un nouvel outil de récupération des photons émis par les leptons dans l'état final de la désintégration  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  ( $l = e, \mu$ ) a été développé dans cette thèse. Cette méthode permet la récupération d'un nombre variable de photons par événements, donne une meilleure performance que la méthode précédemment utilisée dans CMS et permet l'amélioration de la résolution sur la masse des bosons  $Z^0$  et du boson de Higgs, ainsi qu'un gain de 5% sur la signification d'une observation du boson de Higgs dans ce canal.

La deuxième partie de cette thèse traite de l'étude des bruits de fond et de la recherche d'un boson de Higgs léger ( $110 < m_H < 140$  GeV) dans le canal  $H \rightarrow \gamma\gamma$ . Un nouvel outil de discrimination  $\gamma/\pi^0$  à l'aide d'un réseau de neurone a été mis au point pour le rejet des photons provenant de la désintégration des  $\pi^0$  produits copieusement dans les jets de QCD. Les performances du réseau de neurone sont examinées dans le détail. Le réseau de neurone est alors utilisé comme variable "template" permettant la mesure du processus  $\gamma+X$  à partir des données avec  $10 \text{ nb}^{-1}$  de luminosité intégrée dans CMS. La mesure du processus  $\gamma\gamma+X$  est aussi préparée à partir de la simulation dans l'hypothèse d'une luminosité intégrée de  $10 \text{ pb}^{-1}$ .

La prise en compte des effets cinématiques aux ordres supérieurs, nécessaire pour la prédiction la plus précise possible du signal  $H \rightarrow \gamma\gamma$  et du bruit de fond, est effectuée dans cette thèse par la méthode de repondération, pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  au NNLO et pour la première fois pour le processus  $\gamma\gamma+X$  au NLO, dans les deux cas à l'aide de distributions doublement différentielles. Les outils de repondération et de discrimination  $\gamma/\pi^0$  sont ensuite intégrés dans l'analyse pour améliorer la sensibilité de CMS à la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  dans le modèle standard et au-delà, grâce à une paramétrisation effective développée par des phénoménologues avec lesquels nous avons travaillé.



# INTRODUCTION

Le LHC (Large Hadron Collider) fournit aux expériences du CERN (Organisation Européenne pour la Recherche Nucléaire) des collisions proton-proton avec une énergie de 7 TeV dans le centre de masse depuis fin Mars 2010. Le LHC a en particulier été conçu pour permettre la recherche du boson de Higgs, particule prédite par le modèle standard encore jamais observée à ce jour, dans toute la gamme de masse où il est attendu. Ce travail de thèse est une contribution à la recherche du boson de Higgs dans CMS (Compact Muon Solenoid), l'un des quatre grands détecteurs placés auprès du LHC.

Initialement, cette thèse avait pour but l'amélioration du potentiel de découverte du boson de Higgs. Les données du LHC avec une énergie de 7 TeV dans le centre de masse ayant été disponibles à partir du mois d'Avril 2010, en plus de la préparation à la recherche du boson de Higgs qui nécessite plutôt une luminosité intégrée de  $1 fb^{-1}$  (attendus au bout d'un an et demi de fonctionnement du LHC), nous avons pu analyser les premières données avec une luminosité intégrée d'environ  $10 nb^{-1}$ .

Dans cette thèse, nous nous sommes principalement intéressés aux photons, particules détectées à l'aide du calorimètre électromagnétique de CMS, qui constituent une signature claire pour de nombreux processus du modèle standard. Nous avons aussi porté une attention particulière aux effets cinématiques dûs aux ordres supérieurs de la théorie perturbative de QED et QCD sur les analyses. Trois principaux outils ont été développés. Le premier outil que nous proposons dans cette thèse consiste en une méthode de récupération des photons FSR émis par les leptons dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$ . Ceci constitue un premier effet dû aux ordres supérieurs, la radiation réelle de photons dans l'état final étant prise en compte de façon approximée par les générateurs à gerbes partoniques. Nous proposons aussi un nouvel outil de discrimination  $\gamma/\pi^0$  à l'aide d'un réseau de neurone, qui a été mis au point pour rejeter les photons provenant de la désintégration des  $\pi^0$  produits copieusement dans les jets de QCD. Enfin, la prise en compte des effets cinématiques aux ordres supérieurs, nécessaire pour la prédiction la plus précise possible du signal  $H \rightarrow \gamma\gamma$  et du bruit de fond, est effectuée par la méthode de repondération, pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  au NNLO et pour la première fois pour le processus  $\gamma\gamma+X$  au NLO, dans les deux cas à l'aide de distributions doublement différentielles.

Ce manuscrit se compose de dix chapitres. Le premier chapitre décrit le fonctionnement du LHC, présente le détecteur CMS, ses sous-détecteurs ainsi que la chaîne d'acquisition des données et insiste sur le calorimètre électromagnétique de CMS, qui permet la reconstruction des photons et des électrons. Le deuxième chapitre est dédié à l'état de l'art de la physique du boson de Higgs, généré par la brisure de symétrie électrofaible dans le modèle standard de la physique des particules. Les mécanismes de production et de désintégration du boson de Higgs au LHC seront examinés, et les limites actuelles sur la masse du boson de Higgs présentées. Nous décrirons aussi dans ce chapitre la paramétrisation effective du processus  $H \rightarrow \gamma\gamma$  au-delà du modèle standard développée par des phénoménologues avec lesquels nous avons travaillé. Pour clore cette partie théorique, nous décrirons chapitre 3 quelles sont les possibilités offertes pour prendre en compte dans les analyses les effets cinématiques dûs aux ordres supérieurs de la théorie perturbative de QCD et QED. Nous décrirons les générateurs à éléments de matrices des processus  $gg \rightarrow H \rightarrow \gamma\gamma$  et  $\gamma\gamma+X$  que nous avons utilisé, ainsi que le fonctionnement des générateurs à gerbe partonique, avant de présenter les résultats actuels de la comparaison entre théorie et expérience pour la mesure des sections efficaces différentielles du processus  $\gamma\gamma+X$ .

Les sept chapitres suivant traitent du travail que j'ai effectué dans l'expérience CMS. Le chapitre 4

présente une nouvelle méthode de récupération d'un nombre variable de photons FSR émis par les leptons dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ), qui s'insère dans le cadre de l'analyse  $H \rightarrow ZZ^* \rightarrow 4l$  de CMS, dans le but d'améliorer la résolution sur la masse des bosons  $Z$  et du bosons de Higgs ainsi que d'améliorer la signification d'une observation du signal. Les données de muons cosmiques sont utilisées pour une première validation de la forme des distributions cinématiques pour les photons émis par les muons. A partir du chapitre 5, nous nous consacrons aux analyses portant directement sur les signatures avec un ou deux photons dans l'état final. Le chapitre 5 présente une nouvelle approche pour la discrimination  $\gamma/\pi^0$  dans CMS à l'aide d'un réseau de neurones, qui utilise deux types de variables d'entrée : les variables de forme du cluster et les variables d'environnement. Les performances du réseau de neurone sont examinées dans le détail, et son utilisation est validée dans les premières données avec une luminosité intégrée de  $6,7 \text{ nb}^{-1}$ . Au chapitre 6, la sortie du réseau de neurone est ensuite utilisée comme variable "template" pour la mesure du processus  $\gamma+X$  observé dans les données avec  $10,24 \text{ nb}^{-1}$ . Nous proposons aussi dans ce chapitre un moyen d'entraîner le réseau de neurones à partir des données, qui tire parti de la cinématique du processus  $\gamma+\text{jet}$ .

Le but du chapitre 7 est la prise en compte des effets cinématiques dus aux ordres supérieurs de la théorie perturbative de QCD (NLO pour  $\gamma\gamma+X$  et NNLO pour  $gg \rightarrow H \rightarrow \gamma\gamma$ ) dans l'analyse. Une étude des critères d'isolation niveau générateur est effectuée et les différentes distributions cinématiques examinées, avant d'effectuer une repondération en deux dimensions pour les processus  $\gamma\gamma+X$  et  $gg \rightarrow H \rightarrow \gamma\gamma$ . Nous présentons ensuite au chapitre 8 une préparation à la mesure de la section efficace du processus  $\gamma\gamma+X$  utilisant la sortie du réseau de neurone comme "template" dans l'hypothèse d'une luminosité intégrée de  $10 \text{ pb}^{-1}$ , et examinons les distributions diphotons dans les premières données avec  $10,24 \text{ nb}^{-1}$ . Chapitre 9, nous présentons une analyse pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$ , à l'aide d'un rapport de vraisemblance multi-variables comme test statistique. Le réseau de neurones de discrimination  $\gamma/\pi^0$  ainsi que la méthode de repondération sont inclus dans l'analyse. Les incertitudes systématiques sont évaluées et le bruit de fond est mesuré à partir des bandes de côté de la distribution de masse invariante. Les résultats sont donnés en terme de section efficace exclue à 95% de niveau de confiance pour une luminosité de  $1 \text{ fb}^{-1}$ . Enfin, le chapitre 10 présente la mise en oeuvre de la paramétrisation du processus  $H \rightarrow \gamma\gamma$  au-delà du modèle standard avec le générateur Madgraph. Les sections efficaces sont comparées avec les prédictions théoriques approchées et les limites obtenues au chapitre 9 sont interprétées en terme d'exclusion de modèles théoriques.

# Chapitre 1

## L'expérience CMS au LHC

Le CERN (Organisation Européenne pour la Recherche Nucléaire), est le centre de recherche de physique des hautes énergies qui héberge actuellement le plus grand accélérateur de particules au monde, le LHC [1] (Large Hadron Collider ou Grand Collisionneur de Hadrons). Le CERN est situé sur la frontière franco-suisse, à côté de Genève. Il s'agit d'une coopération internationale qui a vu le jour en 1952.

Le projet du collisionneur de hadrons LHC a été approuvé par le CERN en 1994. Le LHC a été conçu pour permettre l'accélération et la collision de faisceaux de protons ainsi que de faisceaux d'ions lourds à une énergie encore jamais égalée : 14 TeV dans le centre de masse pour les protons et 2,8 TeV par nucléon pour les ions lourds. La machine est aujourd'hui en fonctionnement, et les premières collisions ont eu lieu en décembre 2009. Quatre grandes expériences de physique des particules utilisent le LHC : CMS [2], ATLAS [3], ALICE [4] et LHCb [5]. Les expériences CMS et ATLAS sont des expériences généralistes de physique des particules, aussi bien construites pour des mesures de précision que pour la recherche de nouvelle physique. ALICE est une expérience dédiée à l'exploration des propriétés du plasma quark-gluon dans les collisions d'ions lourds, tandis que LHCb est dédiée à la physique du quark  $b$  pour l'étude de la violation de CP. Un des principaux enjeux du LHC est la recherche du boson de Higgs, particule prédite par la théorie depuis la fin des années 1960 mais qui n'a encore jamais été observée à ce jour (voir chapitre 2). C'est dans l'expérience CMS que s'insère ce travail de thèse.

Dans ce chapitre, nous nous intéresserons d'abord au LHC. Nous décrirons le fonctionnement de la machine que nous caractériserons par quelques chiffres significatifs, de la chaîne d'injection des protons à l'accélération et aux collisions. L'histoire récente des premières collisions sera retracée, et les plans officiels pour la prise de données dans les prochaines années seront présentés. Dans un deuxième temps, l'expérience CMS et ses sous-détecteurs seront présentés, ainsi que son système d'acquisition et de reconstruction des données et de simulation. Dans ce contexte, une attention particulière sera donnée au calorimètre électromagnétique de CMS (ECAL) présenté dans ce chapitre à la dernière section. Le calorimètre électromagnétique est chargé de la détection, de l'identification et la mesure des propriétés des photons et des électrons. Il est donc d'une importance cruciale pour la recherche des désintégrations du boson de Higgs en 4 leptons ou en paire de photons, analyses qui seront décrites dans les chapitres suivants.

### 1.1 Présentation du LHC

Le LHC (Large Hadron Collider ou Grand Collisionneur de Hadrons) est le plus grand collisionneur de particules au monde. Doté d'une circonférence de 27 km et situé à la frontière franco-suisse, il occupe l'ancien tunnel du LEP (Large Electron Positron) dont l'arrêt de fonctionnement date de 2000. Le LEP était un collisionneur d'électrons et de positons, tandis que le LHC a été construit pour des collisions proton-proton et d'ions lourds. Le LHC est enfoui à une profondeur moyenne de 100 m (jusqu'à 175 m sous les montagnes du Juras et 50 m sous le lac Léman) avec une inclinaison de 1.4% [6]. L'énergie nominale à laquelle seront accélérés les faisceaux de protons est de 7 TeV, portant à 14 TeV l'énergie dans le centre de masse lors d'une collision. Pour comparaison le collisionneur proton/anti-proton Tevatron à

Chicago, encore en activité aujourd'hui et dont l'arrêt est prévu pour 2011, dispose d'une énergie dans le centre de masse de  $1.96 \text{ TeV}$ .

Le LHC a été construit pour affiner notre compréhension des phénomènes de physique des hautes énergies qui sont depuis la fin des années 1960 et aujourd'hui encore décrits par le modèle standard de la physique des particules. Il va permettre des mesures de précision à une énergie encore jamais atteinte et la découverte éventuelle de phénomènes encore jamais observés. Il a en particulier été conçu pour la recherche du boson de Higgs (les propriétés du boson de Higgs seront décrites en détail au chapitre 2) qui devrait être observé au LHC s'il existe tel que le prédit le modèle standard. La mise en évidence de déviations par rapport aux prédictions du modèle standard est aussi attendue et serait le signe d'une physique nouvelle, comme la supersymétrie ou la présence de dimensions supplémentaires, qui seront aussi recherchés directement dans les expériences généralistes CMS et ATLAS.

### 1.1.1 La machine

Installé dans le tunnel du LEP, l'élément principal du LHC consiste en deux tubes circulaires "jumeaux" d'aimants supra-conducteurs accolés l'un à l'autre, pour permettre l'accélération des deux faisceaux de protons en sens inverse [6]. Le tunnel est refroidi à une température de  $4 \text{ K}$  et les aimants faits de NbTi opèrent à  $2 \text{ K}$ , pour délivrer un champ magnétique nominal de  $8 \text{ T}$  sous une pression de  $10^{-13} \text{ atm}$  (ultra-vide). Les aimants, au nombre total de 9300, ont pour rôle de garder les protons sur une orbite circulaire (1232 dipôles), de focaliser le faisceau (858 quadrupôles focalisant alternativement le faisceau horizontalement et verticalement) et d'accélérer les hadrons. 8 cavités à radio-fréquence par faisceau accélèrent les protons de  $0.5 \text{ MeV}$  par tour et permettent d'accroître l'énergie des protons de  $450 \text{ GeV}$  à  $7 \text{ TeV}$  en  $20 \text{ min}$ .

Avant d'être injectés dans le LHC, les protons sont accélérés en plusieurs étapes par la chaîne d'injection [7] (voir schéma 1.1). Au départ, l'hydrogène est fourni par des bouteilles d'hydrogène puis ionisé. Les protons sont accélérés par paquets dans l'accélérateur linéaire Linac 2 à une énergie de  $50 \text{ MeV}$ , puis injectés dans le "booster" du Synchrotron à Protons (PSB) qui les porte à une énergie de  $1.4 \text{ GeV}$ . Le PSB est constitué de quatre anneaux parallèles qui peuvent accélérer simultanément les protons, avant de reconstituer un seul faisceau fourni au PS (Synchrotron à Protons) proprement dit. Dans le PS, les protons vont atteindre une énergie de  $25 \text{ GeV}$  et les paquets vont être divisés en paquets plus petits et plus rapprochés en temps. Les protons sont ensuite envoyés au Super Synchrotron à Protons (SPS) qui les accélère jusqu'à une énergie de  $450 \text{ GeV}$  avant de les fournir au LHC, où ils seront accélérés jusqu'à  $7 \text{ TeV}$  lorsque l'énergie nominale sera atteinte ( $3,5 \text{ TeV}$  aujourd'hui).




FIG. 1.1 – Chaîne d'injection du LHC (source : LHC FAQ [7])

Les faisceaux de proton accélérés à  $7 \text{ TeV}$  sont ensuite collimés au maximum pour réduire l'extension

Energie des protons	7 TeV
Nombre de paquets par faisceau	2808
Nombre de protons par paquet	$1.15 \times 10^{11}$
Extension horizontale des paquets	15 $\mu m$
Extension verticale des paquets	15 $\mu m$
Extension longitudinale des paquets	5 cm
Espacement des paquets	7.7 m
Fréquence de révolution des paquets	11.25 kHz
Temps entre deux croisements de faisceau	25 ns
Nombre de collision p-p par croisement de faisceau	20
Angle de croisement	200 $\mu rad$
Luminosité	$10^{34} cm^{-2} s^{-1}$

FIG. 1.2 – Quelques grandeurs caractéristiques nominales du LHC.

spatiale des paquets au point d'interaction de chaque expérience (plus l'extension est faible, plus les protons des deux faisceaux ont de chance de se rencontrer). L'ajustement de leur taille est un facteur aussi important que le nombre de protons par paquets pour augmenter le nombre de collisions détectées par les expériences, c'est-à-dire augmenter la luminosité instantanée. Le LHC a été conçu pour fonctionner à une luminosité instantanée nominale de  $10^{34} cm^{-2} s^{-1}$ . On définit la luminosité instantanée par la relation suivante [8] :

$$L = \frac{N^2 n_b f_{rev} F}{4\pi \sigma_X \sigma_Y}$$

Où  $N$  est le nombre de protons par paquets,  $n_b$  est le nombre de paquets circulant dans le LHC,  $f_{rev}$  est la fréquence de révolution des protons,  $\sigma_X$  et  $\sigma_Y$  l'extension horizontale et verticale des paquets au moment du croisement des faisceaux, et  $F$  un facteur de correction géométrique qui tient compte de l'angle entre les faisceaux. Les valeurs de quelques unes des grandeurs caractéristiques importantes au LHC sont résumées sur le tableau 1.2.

La structure des paquets choisis pour le LHC permet la présence de 2808 paquets par faisceau au maximum [9]. Il y aurait la place nécessaire pour en contenir jusqu'à 3564, mais des temps morts sont laissés dans le schéma de remplissage pour permettre la synchronisation en temps des différentes parties de la machine, l'acquisition de données de calibration par les détecteurs et le redémarrage de certains composants électroniques [10].

Les faisceaux de protons se rencontrent au point d'interaction de chaque expérience, près du centre des détecteurs et peuvent donner lieu à une collision. La section efficace totale d'une collision proton-proton à 14 TeV est estimée à environ 100-110 mb [11] (il est intéressant de noter que cette section efficace augmente avec l'énergie des protons), et trois types de processus y contribuent. La plupart des collisions sont dites élastiques : les protons échangent de l'impulsion mais ne se désintègrent pas en d'autres particules ; ils possèdent alors une grande impulsion longitudinale ainsi qu'une faible impulsion transverse. Les collisions diffractives sont des collisions inélastiques, où l'un et/ou l'autre des deux protons peuvent se désintégrer en particules secondaires. Les collisions élastiques et diffractives [12] sont des processus décrits par les outils de la QCD non perturbative et se caractérisent par une absence de particules détectées dans une large région centrale de rapidité <sup>1</sup>. Enfin, les interactions dures ont lieu lorsque les protons qui collisionnent échangent une impulsion plus élevée, et se désintègrent en gerbes de particules avec une grande impulsion transverse. Lors de l'interaction dure, seul un parton (quark ou gluon) de chaque proton interagit (voir section 2.2.1). Les autres partons des protons sont spectateurs de l'interaction dure, et vont s'hadroniser en empruntant des quarks à la mer de particules virtuelles (voir section 3.2.4). De plus, la haute luminosité

<sup>1</sup>La rapidité dans la théorie de la relativité restreinte est définie comme  $y = \frac{1}{2} \ln \left( \frac{E+p_L}{E-p_L} \right)$ , où  $E$  est l'énergie de la particule émise et  $p_L$  son impulsion longitudinale.

atteinte par le LHC devrait conduire à 20 collisions par croisement de faisceau (phénomène d'empilement). Parmi elles il n'y aura en général qu'une seule collision inélastique en raison de leur rareté, tandis que les autres collisions seront élastiques ou diffractives.

### 1.1.2 Du démarrage à aujourd'hui

Le LHC a démarré en septembre 2008, et les faisceaux de protons ont fait le tour complet du LHC pour la première fois le 10 septembre, dans un sens puis dans l'autre. Le 19 septembre, un incident s'est produit dans le tunnel du secteur 3-4 [13] (entre les sites de l'expérience CMS et ALICE), causé par une connexion électrique défectueuse entre deux aimants. L'incident a provoqué l'arrêt du LHC pour plus d'un an, temps mis à profit pour opérer le remplacement des aimants endommagés dans le tunnel, et procéder aux vérifications de mise pour qu'un tel incident ne se reproduise plus.

Le LHC a redémarré le 20 novembre 2009, avec une énergie dans le centre de masse de 900 GeV (soit 450 GeV par protons). Trois jours plus tard, les deux faisceaux ont circulé simultanément, avec le premier croisement de faisceau et les premières collisions détectées au sein des expériences le 23 novembre. Le 30 novembre, l'énergie dans le centre de masse a été portée à 2,36 TeV (soit plus que le Tevatron, 1,98 TeV), suivi de près par des collisions. Les données accumulées jusqu'au 16 décembre 2009 ont permis d'effectuer une première phase de calibration et de compréhension des détecteurs. Après un arrêt technique les mois d'hiver, les premières collisions avec une énergie de 7 TeV dans le centre de masse ont été détectées par les quatre expériences au LHC le 30 mars 2010 (un exemple de vues d'une collision est donné pour illustration figure 1.3). Le LHC devrait fonctionner avec une énergie de 7 TeV dans le centre de masse (soit la moitié de l'énergie nominale) jusqu'à avoir accumulé une luminosité intégrée de  $1 \text{ fb}^{-1}$  fin 2011. Devrait suivre en 2013 un arrêt technique d'un peu plus d'un an ayant pour but de d'améliorer la protection des aimants pour accélérer les faisceaux de protons jusqu'à 13-14 TeV. La luminosité acquise par année devrait alors avoisiner les  $3 \text{ fb}^{-1}$  par an. Les plans à long terme (qui évoluent beaucoup) prévoient un arrêt technique aux alentours de 2015 pour procéder à l'amélioration des détecteurs, et un autre en 2020 pour améliorer les aimants du LHC et atteindre la luminosité de  $200 \text{ fb}^{-1}$  par an.




FIG. 1.3 – Reconstitution d'un des premiers événements de collision à 7 TeV détecté par l'expérience CMS.

## 1.2 L'expérience CMS

L'expérience CMS [2] (Compact Muon Solenoid ou Solénoïde Compact à Muons) est, avec ATLAS, l'une des deux expériences généralistes de physique des particules au LHC, conçue pour effectuer des mesures de précision du modèle standard et la recherche de physique nouvelle, en particulier la recherche



du boson de Higgs. Le détecteur CMS est situé au point 5, diamétralement opposé à ATLAS sur le tunnel du LHC, dans la “caverne” CMS enfouie à environ 100 m de profondeur. Le détecteur pèse au total 12500 tonnes, mesure 21,5 m de long pour un diamètre de 15 m. 36 pays ont contribué à sa conception et environ 2500 personnes travaillent dans l'expérience. Le dernier élément de construction a été descendu dans la caverne en janvier 2008. Le détecteur est opérationnel et est en période de prise de données, avec des faisceaux de protons à 7 TeV dans le centre de masse fournis par le LHC. Les deux faisceaux de protons accélérés par le LHC se croisent approximativement au centre du détecteur, qui récolte ensuite les produits de désintégration issus des collisions.

La conception du détecteur CMS (dont les détails techniques du projet ont été proposés en 1994) a été guidée par la configuration d'un champ magnétique permettant la mesure précise de l'impulsion des muons. Plus le champ magnétique est fort, plus le rayon de courbure de la trajectoire des particules chargées est petit, et donc plus précis est la mesure de l'impulsion des particules. Le champ magnétique du détecteur CMS a été choisi pour être de 3,8 T. Il est généré par un solénoïde supraconducteur de 13 m de long et de 5,9 m de diamètre interne. Une des particularités de CMS est aussi d'avoir placé son calorimètre hadronique à l'intérieur de l'aimant.

Le détecteur CMS est constitué d'un ensemble de sous-détecteurs dont nous allons passer brièvement en revue l'un après l'autre les propriétés, les objectifs et les performances principales. Le principe de l'acquisition des données et de leur reconstruction sera ensuite analysé à partir du déclenchement jusqu'aux objets physiques. Enfin, nous détaillerons la chaîne de simulation qui permet de faire des prédictions qui seront comparées avec l'expérience.

### 1.2.1 Le détecteur CMS et ses sous-détecteurs

Comme de nombreuses expériences de physique des hautes énergies, le détecteur CMS est constitué d'une partie centrale cylindrique appelée *tonneau* et de deux extrémités appelées *bouchons* pour une couverture angulaire maximale. Il est constitué d'une série concentrique de sous-détecteurs autour du tube à vide du faisceau, chaque couche étant optimisée pour la mesure des propriétés d'un certain type de particules.

En physique des particules expérimentales, on définit généralement la pseudo-rapacité  $\eta$  des particules :

$$\eta = -\ln\left(\tan\left(\frac{\theta}{2}\right)\right)$$

Où  $\theta$  est l'angle polaire entre la direction de la particule et le faisceau. Pour les particules de masse nulle ou ultra-relativistes, la pseudo-rapacité est exactement égale à la rapidité. Le détecteur CMS est conçu pour une grande couverture en pseudo-rapacité ( $|\eta| < 3$ ). De plus, l'herméticité due à la présence d'un faible nombre de séparation entre les modules lui permet de collecter la majeure partie des particules émises lors de l'interaction dure. Un calorimètre hadronique (HF, “Forward Hadron”) est placé derrière les bouchons, qui permet la détection jusqu'à  $|\eta| < 5$ .

Les différents sous-détecteurs de CMS sont schématisés sur la vue d'ensemble en 3D schéma 1.4, et dans le plan transverse par rapport à la direction du faisceau schéma 1.5. Par ordre décroissant de proximité avec le centre du détecteur, on trouve le trajectographe, le calorimètre électromagnétique, le calorimètre hadronique, l'aimant supraconducteur et les chambres à muons.

#### Le trajectographe

Le trajectographe est constitué d'un détecteur à pixel et d'un détecteur à pistes de silicium [14]. Il est le premier sous-détecteur rencontré par les particules issues de la collision, et mesure 2,6 m de circonférence pour 5,8 m de longueur. Le trajectographe permet la détection de la trajectoire des particules




FIG. 1.4 – Vue schématique 3D du détecteur CMS présentant les différents sous-détecteurs qui le composent.




FIG. 1.5 – Schéma d'une coupe transverse du détecteur CMS, présentant les différents sous-détecteurs et les particules qu'ils sont capables de détecter.

chargées à partir des traces qu'elles laissent dans le silicium sous forme de paires électrons-trous, et la mesure de leur impulsion est obtenue à partir du sagitta des trajectoires (qui sont déviées par le champ magnétique généré par l'aimant de CMS). Le trajectographe permet de plus la mesure du vertex primaire (vers lequel pointent les traces issues de l'interaction dure), et du vertex secondaire lorsque un lot de particules est émis après désintégration d'une particule dont le temps de vol est long (comme le quark  $b$ ). Les vertex surnuméraires dus à l'empilement peuvent aussi être reconstruits. Le trajectographe (et plus particulièrement le détecteur à pixel) est le sous-détecteur de CMS le plus soumis au vieillissement dû au radiations : sa proximité par rapport au point d'interaction l'expose à une dose de radiation plus grande que les autres sous-détecteurs et sa durée de vie est estimée à 10 ans.




FIG. 1.6 – Schéma [15] d'une coupe transverse du trajectographe. Chaque ligne représente un module du sous-détecteur.

Dans le tonneau, les trois premières couches du trajectographe rencontrées par les particules issues de la collision sont celles du détecteur à pixel, à un rayon compris entre seulement 4.4 cm et 10.2 cm par rapport au faisceau. Le détecteur à pixel dispose d'une fine granularité pour permettre la reconstruction des particules à proximité du point d'interaction (la surface d'un pixel est de  $100 \times 150 \mu\text{m}^2$ ). Les couches plus lointaines sont constituées de pistes croisées de plus de  $10 \text{ cm} \times 80 \mu\text{m}$ . Dans le tonneau au-delà du détecteur à pixel, le trajectographe à piste de silicium est divisé en deux parties (voir schéma 1.6) : le TIB (Tracker Inner Barrel) et le TOB (Tracker Outer Barrel), constitués de 10 couches à micro-pistes de silicium, jusqu'à un rayon de 1,1 m. Dans le bouchon, on trouve d'abord les deux couches du détecteur à pixel, puis deux sous-parties du trajectographe à piste en silicium : le TEC (Tracker End Cap) composé de 9 disques entre 1,2 m et 2,8 m du point d'interaction, et le TID (Tracker Inner Disks) composé de 3 disques, qui remplit l'espace entre le TIB et le TEC.

### Le calorimètre électromagnétique

Le calorimètre électromagnétique [16] (ECAL) est constitué de cristaux de tungstate de plomb ( $PbWO_4$ ). Il est chargé de mesurer l'énergie des électrons et des photons, qui déposent toute leur énergie dans le calorimètre. Le ECAL est formé de deux parties : dans le tonneau, la gamme de pseudo-rapidity des particules détectées est  $|\eta| < 1.479$  et dans le bouchon  $1.48 < |\eta| < 3$ . De plus, un détecteur pied de gerbe est placé devant les bouchons dans la région  $1.65 < |\eta| < 2.6$ , pour permettre une meilleure discrimination entre les photons et les  $\pi^0$ . Le ECAL sera présenté de manière plus détaillée dans la section 1.3.

### Le calorimètre hadronique

Le calorimètre hadronique [17] (HCAL) à échantillonnage est constitué de couches de laiton (de longueur d'interaction 16,5 cm) alternées avec des scintillateurs pour une couverture en pseudo-rapidity allant jusqu'à  $|\eta| < 3$ . Au-delà, un calorimètre hadronique à grand angle ("Hadron Forward" ou HF) en fer et fibres de quartz basé sur une technologie Cherenkov, permet une couverture jusqu'à  $|\eta| < 5.2$  (voir schéma 1.7). Le HF est utilisé pour accroître la couverture en  $\eta$ , mesurer la luminosité récoltée par CMS et permettre les études des collisions inélastiques et diffractives.

Le HCAL mesure l'énergie, l'impulsion et la position des hadrons neutres et chargés, qui y déposent la plus grande part de leur énergie. L'énergie est reconstruite à partir des tours du HCAL sous la forme de *jets* (gerbes de particules issues de l'hadronisation/fragmentation des quarks ou gluons émis lors des collisions). Lorsqu'un hadron rencontre le HCAL, une gerbe hadronique se forme et se développe à travers le sous-détecteur (la gerbe a parfois pu commencer dans le ECAL avant d'atteindre le HCAL). Contenir



FIG. 1.7 – Schéma [15] d'une coupe transverse du calorimètre hadronique.

toute la gerbe hadronique issue des jets serait l'idéal, mais l'extension du HCAL dans le tonneau est contrainte par son emplacement entre le ECAL (à un rayon de 1,77 m) et l'aimant (2,95 m). Dans le tonneau, la partie du HCAL placée à l'intérieur de l'aimant (Hadron Barrel ou HB dans la région  $|\eta| < 1.6$ ) possède 2304 tours de  $\Delta\eta \times \Delta\phi = 0.087 \times 0.087$ . Une partie supplémentaire du HCAL est située au-delà de l'aimant (Hadron Outer ou HO dans la région  $|\eta| < 1.26$ ) pour détecter la queue de distribution de la gerbe hadronique, accordés à la couverture des chambres à dérives (DT, voir chambres à muons). Dans les bouchons, le HE (Hadron Endcap) couvre la région  $1.3 < |\eta| < 3$  avec 14 tours en  $\eta$  ayant une granularité de  $5^\circ$  en  $\phi$ .

### L'aimant supraconducteur

L'aimant supraconducteur [18] constitué de cinq bobines jointives en Niobium-Titane génère un champ uniforme de 3,8 T, grâce un solénoïde supraconducteur de 13 m de long et de 5,9 m de diamètre interne (pesant près de 220 tonnes) refroidi à l'hélium liquide (4,2 K). Il est placé entre le calorimètre hadronique et les chambres à muons. Lors de la mise sous tension, l'aimant génère une déformation mécanique de 0.15% qui doit être prise en compte lors de l'alignement des différents sous-détecteurs. L'aimant chargé stocke une énergie totale de 2.6 GJ.

Le champ magnétique a pour rôle de courber la trajectoire des particules chargées ; la mesure du rayon de courbure (dans le trajectographe ou les chambres à muons) permet à la reconstruction de calculer l'impulsion de la particule ainsi que sa charge. L'aimant de CMS a été conçu pour permettre une incertitude inférieure à 10% sur la mesure de l'impulsion d'un muon de 1 TeV (peu dévié par le champ magnétique).

### Les chambres à muons

Parmi toutes les particules finales issues de la collision, les muons ont le plus grand pouvoir pénétrant dans la matière (si on omet les neutrinos qui ne peuvent pas être détectés du fait de leur interaction très faible avec la matière) et traversent toutes les couches précédentes du détecteur. Le système de détection des muons [19] est constitué de trois sous-parties (voir schéma 1.8). Dans le tonneau, les 250 chambres à dérive (Drift Tube, DT) organisées en quatre couches mesurent l'impulsion des muons dans la gamme de pseudo-rapacité  $|\eta| < 1.3$ . Dans les deux bouchons, le système de détection des muons est composé de 468 chambres à pistes cathodiques (Cathod Strip Chamber, CSC) couvrant la région  $0.9 < |\eta| < 2.4$ , et de 4 stations à plaques résistives (Resistive Plate Chamber, RPC) dans la région  $1.6 < |\eta| < 2.1$ . Il s'agit de trois technologies différentes de détecteurs gazeux, choisies en fonction de leur résistance aux doses radio-actives, leur rejet du bruit de fond induit par les neutrons, leur capacité à fonctionner sous grand

champ magnétique et pour la rapidité du déclenchement.

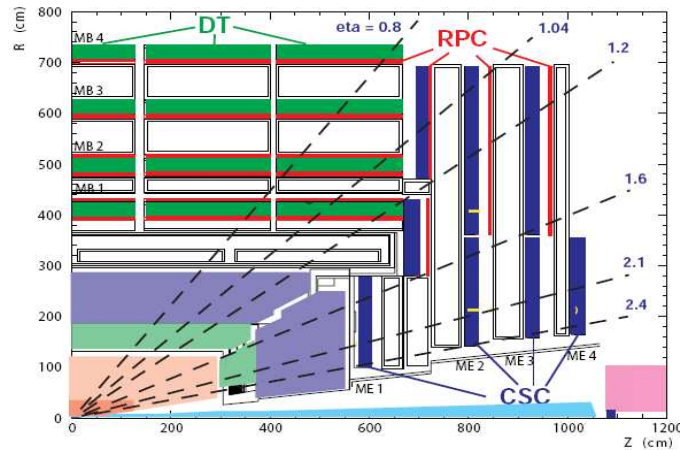


FIG. 1.8 – Schéma [10] d'une coupe transverse du système de détection des muons.

La résolution spatiale sur la mesure de la position des muons est d'environ  $200 \mu\text{m}$ , et la résolution angulaire est de l'ordre de  $10 \text{ mrad}$  dans les bouchons. La mesure de l'impulsion des muons dans les chambres à muons peut être complétée par l'usage du trajectographe. A basse impulsion transverse (pour  $p_T < 100 \text{ GeV}$ ), l'incertitude sur l'impulsion est plus faible dans le trajectographe (inférieure à 1% dans les régions centrales du tonneau), tandis qu'à grande impulsion transverse (de l'ordre du TeV) l'incertitude est plus faible dans les chambres à muons (de l'ordre de 10%). Une telle résolution sur les grandes impulsions transverses est nécessaire pour la détection des paires  $\mu^+\mu^-$  issues des désintégrations d'un boson lourd  $Z'$  dont l'existence est prédite dans certaines théories au-delà du modèle standard.

### 1.2.2 Acquisition, reconstruction des données et simulation

Le LHC a été conçu pour fournir aux expériences un croisement de paquets toutes les 25 ns, soit une fréquence de 40 MHz. Durant l'acquisition des données, une première analyse rapide des données de chaque événement doit être effectuée afin de décider quelles données archiver pour une analyse ultérieure. Pour des raisons d'espace de stockage disponible, le taux d'acquisition doit être ramené à un maximum d'environ 100 Hz et seuls les événements les plus intéressants (les plus rares) peuvent être gardés : c'est le rôle du système de déclenchement. Lorsque l'évènement a passé plusieurs seuils de déclenchement, il est ensuite reconstruit dans son intégralité par des algorithmes de reconstruction qui peuvent utiliser tout ou partie du détecteur. Le déclenchement est aussi simulé par le framework de CMS, CMSSW [20], à la suite d'une simulation détaillée du détecteur dans son entier.

### Système de déclenchement et d'acquisition de CMS

Le système de déclenchement de CMS [21, 22] est constitué de deux niveaux : le déclenchement de niveau 1 (Level 1 Trigger, L1), dont le but est de réduire le taux d'évènement à un maximum de 100 kHz, et le déclenchement de haut niveau (High Level Trigger, HLT) qui le réduit à moins de 100 Hz.

#### Déclenchement de niveau 1

Les sous-détecteurs qui sont capables d'une lecture rapide des données (calorimètres électromagnétiques et hadroniques, chambres à muons) mettent en oeuvre un déclenchement de niveau 1 [21]. Pour chaque événement détecté par le sous-détecteur (toutes les 25 ns), le L1 exécuté par les processeurs de la salle informatique dédiée de la caverne CMS est chargé de décider si il doit être conservé ou non. Pendant tout le temps mis par le signal pour atteindre les processeurs et revenir à l'électronique ( $3,2 \mu\text{s}$ , temps de

calcul inclus), l'évènement entier est gardé dans une mémoire tampon. Le calcul en lui-même prend environ  $1 \mu s$  et est effectué sur des primitives de déclenchement ("trigger primitives" ou TP), représentations simplifiées des dépôts d'énergie ou des coups détectés plutôt que reconstruits comme objets physiques (électrons ou muons par exemple). L'évènement passe (ou échoue) le déclenchement de niveau 1 si typiquement l'amas contient une énergie transverse supérieure (inférieure) à un certain seuil.

Dans les périodes de démarrage ou de premières prises de données, lorsque le taux d'acquisition est faible parce qu'il y a peu de paquets par faisceau (et donc moins d'un croisement toutes les 25 ns), le déclenchement de niveau 1 n'est plus seulement basé sur les sous-détecteurs et inclut un déclenchement "technique". Il s'agit d'informations provenant de capteurs situés en amont et en aval du détecteur CMS [15], le BPTX (Beam Pick-up Timing Experiment, à 175 m du point d'interaction) et le BSC (Beam Scintillator Counter, à 10,5 m du point d'interaction) qui détectent les croisements de faisceaux, ainsi que les évènements issus de collisions entre le faisceau et les molécules de gaz résiduelles qui peuvent subsister malgré l'ultra-vide. Le déclenchement "technique" est peu restrictif et sélectionne des évènements dits de "biais minimum", principalement des collisions élastiques ou diffractives.

### *Déclenchement de haut niveau*

Une ferme de calcul applique ensuite sur les données les algorithmes logiciels de déclenchement de haut niveau [22] (HLT). Il s'agit d'une sélection complémentaire chargée de réduire encore le taux de données par rapport au L1 et de sélectionner les évènements potentiellement intéressants pour les analyses de physique (réduction des bruits de fond). Le HLT est conçu pour être flexible et propose une large gamme de "voies" de déclenchement (paths) adaptables aux analyses ultérieures. Contrairement au L1, il s'intéresse aussi aux traces détectées dans le trajectographe.

### *Monitoring des données*

Si l'évènement a passé le déclenchement de niveau 1 et le HLT les données gardées en mémoire sont transférées dans un autre tampon de lecture où un traitement supplémentaire est appliqué, qui peut consister suivant le sous-détecteur en une suppression (non-lecture) des données provenant des canaux bruités, à une sélection supplémentaire, etc. Les données sont ensuite placées dans une autre zone de mémoire de l'électronique frontale d'acquisition pour l'évaluation en ligne de la qualité des données (DAQ, Data Quality Monitoring). Chaque séquence (ou run) d'acquisition des données est examinée en ligne et hors-ligne pour chaque sous-détecteur et si la synchronisation en temps, les spectres en énergies, etc. (toutes les informations bas niveau) sont de bonne qualité, alors le run est validé et reconstruit dans une ligne expresse.

## **Reconstruction des objets physiques**

Les évènements qui passent le HLT sont ensuite reconstruits pour chaque sous-détecteur par des algorithmes dédiés. Par exemple, les photons sont reconstruits à l'aide des dépôts d'énergie dans le calorimètre électromagnétique, les muons sont reconstruits à l'aide des traces laissées dans les chambres à muons. Comme beaucoup d'objets sont complexes et ne peuvent pas être mesurés avec suffisamment de précision par un seul sous-détecteur, une deuxième étape de la reconstruction consiste à utiliser les informations qui concernent plusieurs sous-détecteurs pour reconstruire un objet physique. Par exemple, les muons combinent les mesures des traces dans le trajectographe et des traces dans le système à muons, les électrons combinent les dépôts d'énergie dans le ECAL avec les traces dans le trajectographe. Il y a plusieurs variantes de la reconstruction des jets : la première combine les dépôts d'énergie dans le ECAL et le HCAL (jets calorimétriques), la deuxième utilise en plus les traces, et la dernière combine tous les sous-détecteurs pour une estimation plus précise (mesure du flot de particules). On définit aussi l'énergie transverse manquante comme l'énergie non-détectée en raison d'inefficacités de reconstruction ou parce que des particules interagissant très faiblement avec la matière ont été émises lors de la collision (dans le modèle standard, les neutrinos). Elle peut être estimée en utilisant l'information de tous les sous-détecteurs comme la somme vectorielle de l'énergie transverse de chaque particule détectée.

## La chaîne de simulation

La simulation des collisions proton-proton et de leur détection est un travail complexe qui doit être séparé en plusieurs étapes distinctes. La simulation est utile pour préparer les algorithmes de reconstruction et d'analyse, comprendre le fonctionnement du détecteur et comparer prédictions et données de l'expérience. CMS dispose d'une chaîne de simulation en plusieurs étapes [10], qui peuvent être effectuées ensemble ou l'une après l'autre (voir schéma 1.9) :

- En premier lieu, des événements de collision pour le processus désiré sont générés à l'aide de programmes Monte-Carlo appelés *générateurs à élément de matrice* (leur fonctionnement sera décrit plus loin, voir section 3.1), comme Madgraph [23] ou Alpgen [24]. La sortie de ces programmes fournit les quadri-impulsions des partons (voir section 2.2.1) issus de l'interaction dure, en général au format Les Houches [25].

- La sortie du générateur à élément de matrice est fournie à un générateur à gerbe partonique (voir section 3.2), comme Pythia [26] ou Herwig [27], qui calcule les impulsions des partons spectateurs, effectue leur hadronisation/fragmentation ainsi que celle des partons de l'interaction dure et peut aussi générer les émissions réelles de photons et de gluons dans l'état initial et final. La désintégration des particules instables (par exemple les  $\pi^0$  ou les leptons  $\tau$ ) est ensuite effectuée jusqu'à l'obtention de particules finales stables qui sont les produits de la réaction (protons, neutrons, photons, électrons, muons, neutrinos, pions chargés, kaons, etc). A l'issue de cette étape, un fichier au format ROOT [28] est créé qui contient l'impulsion de toutes les particules initiales, intermédiaires et finales de l'évènement. Cette étape nommée "GEN" (génération) est entièrement interfacée avec le logiciel (software) de CMS, CMSSW [20].

- Par la suite, le fichier GEN est fourni à un programme chargé de simuler le passage des particules dans la matière (particules finales ou intermédiaires si leur temps de vol leur a permis d'arriver au détecteur avant de se désintégrer). Pour cette étape dite "SIM" (simulation), CMS a fait le choix d'utiliser GEANT4 [29]. Une fois la géométrie et les caractéristiques du détecteur implémentées, GEANT4 est capable de simuler une vaste gamme de processus d'interaction particules-matière. En sortie, l'étape SIM produit un fichier ROOT où sont stockés des "simhits" (dépôts d'énergie simulés des particules dans la matière du détecteur).

- L'étape suivante est prise en charge par CMSSW et consiste à numériser les dépôts d'énergie dans les différents sous-détecteurs pour produire des données brutes ("RAW"), ce qui revient à simuler l'électronique de lecture utilisée pour l'acquisition des données. Il s'agit de phénomènes complexes qui doivent être reproduits au plus près de la réalité et ont été calibrés avec les données des faisceaux-test. Le bruit électronique est simulé par une fonction de dispersion appliquée à l'énergie récupérée. Les fluctuations de la réponse de l'électronique au signal sont aussi prises en compte. Cette étape est appelée "DIG".

- Enfin la dernière étape est celle de la simulation du déclenchement et la reconstruction des objets physiques par les algorithmes de CMSSW à partir des données digitalisées. Pour le déclenchement de haut niveau cette étape est la même pour la simulation que pour les données (voir plus haut, section 1.2.2). Les fichiers "RECO" qui sont produits peuvent alors être utilisés pour les analyses.

## 1.3 Le calorimètre électromagnétique de CMS

Le calorimètre électromagnétique [16] (ECAL) de CMS a été conçu pour permettre la résolution la plus précise possible sur la masse du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$ , mais aussi dans le canal  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  (voir section 2.2.3),  $l = e, \mu$  avec au moins une des deux paires de leptons qui sont des électrons. La résolution sur le pic de masse invariante  $H \rightarrow \gamma\gamma$  pour un boson de Higgs de 120 GeV est entièrement dominée par les effets instrumentaux et l'objectif est d'atteindre une résolution inférieure à 1 GeV. Le calorimètre a donc pour rôle de récolter toute l'énergie déposée par les photons et les électrons

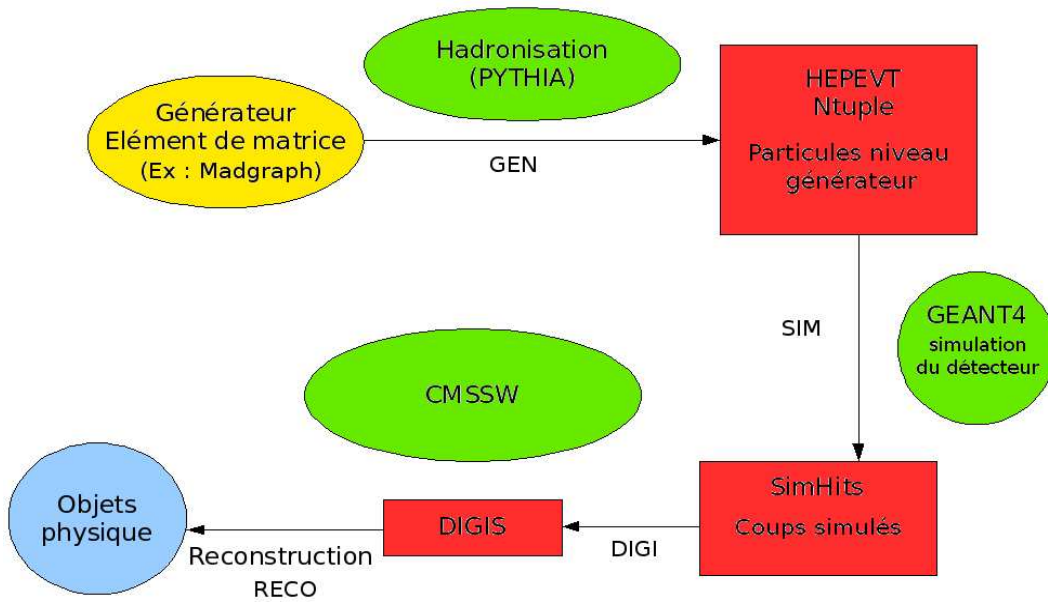


FIG. 1.9 – Schéma de la chaîne de simulation de CMS.

et de mesurer leur énergie avec la plus grande précision possible.

Nous décrirons dans un premier temps les caractéristiques principales du ECAL, sa disposition géométrique dans le détecteur CMS et ses matériaux de constitution, et expliquerons le principe de la détection des photons et des électrons avec le ECAL. Nous essayerons ensuite de donner un aperçu complet de la chaîne d'acquisition des données, des photo-détecteurs jusqu'au déclenchement. Les problèmes liés à la calibration sera abordé et les performances attendues seront présentées. Enfin, nous détaillerons les algorithmes standards de reconstruction des photons et des électrons, qui ont été confrontés aux premières données.

### 1.3.1 Description du calorimètre électromagnétique




FIG. 1.10 – Vue schématique 3D du calorimètre électromagnétique de CMS.



## Géométrie

Le calorimètre électromagnétique de CMS est composé de trois parties (voir schéma 1.11) : le tonneau qui couvre la région  $|\eta| < 1.479$ , deux bouchons pour la détection de particules aux grands angles  $1.48 < |\eta| < 3$ , et un détecteur pied de gerbe placé devant chacun des bouchons ( $1.65 < |\eta| < 2.6$ ). Le tonneau et les bouchons sont constitués de cristaux scintillant de tungstate de plomb ( $PbWO_4$ ), tandis que le détecteur pied de gerbe est un calorimètre à échantillonnage constitué de deux couches : une plaque de plomb pour initier la gerbe et des capteurs à pistes de silicium pour mesurer l'énergie déposée.

Le tonneau compte 61200 cristaux, répartis en rangées de 360 cristaux en  $\phi$  et  $2 \times 85$  en  $\eta$ . Les cristaux sont montés de telle sorte qu'ils présentent un angle de  $3^\circ$  avec le point d'interaction. Ils mesurent  $22 \times 22 \text{ mm}^2$  sur la face avant et  $25 \times 25 \text{ mm}^2$  sur la face arrière, pour une couverture en angle individuelle de  $0,0174 \times 0,0174^\circ$  en  $\eta - \phi$ . Les cristaux sont regroupés en 18 super-modules pour chaque moitié du tonneau, comprenant chacun 4 modules de 400 ou 500 cristaux.

Il y a 7324 cristaux dans chacun des deux bouchons. Chaque bouchon est fait de deux "D" de 3662 cristaux, répartis en 138 unités de  $5 \times 5$  cristaux et de 18 supercristaux spéciaux partiels. A l'avant leur surface est de  $28,62 \times 28,62 \text{ mm}^2$  et à l'arrière  $30 \times 30 \text{ mm}^2$ . La couverture des cristaux en  $\eta$  dans les bouchons augmente à mesure qu'on se rapproche du tube à vide.

## Principe de la détection

Lorsqu'un photon ou un électron avec une énergie de l'ordre du GeV ou supérieure rencontre un cristal, il donne lieu à une gerbe électromagnétique : les électrons émettent des photons par mécanisme de bremsstrahlung externe (rayonnement de freinage) et les photons peuvent se convertir en paire électron-positon, les deux mécanismes s'alimentant l'un l'autre sur toute l'extension en profondeur de la gerbe. La grandeur caractéristique du phénomène est la *longueur de radiation*  $X_0$  [8], qui est la longueur au bout de laquelle un électron de haute énergie a rayonné par bremsstrahlung de sorte à avoir  $1/e$  de son énergie initiale. La longueur de radiation correspond aussi à  $7/9$  du libre parcours moyen de conversion pour un photon. Les cristaux de  $PbWO_4$  ont une longueur de radiation de 0,89 cm et mesurent 23 cm de longueur dans le tonneau (soit  $25,8 X_0$ ) et 22 cm dans les bouchons (soit  $24,7 X_0$ ).

L'extension latérale de la gerbe est de l'ordre du rayon de Molière du matériau, 2,2 cm pour le  $PbWO_4$ . Lorsqu'un photon ou un électron pénètre dans le calorimètre, il peut déposer la plus grande part de son énergie dans un petit nombre de cristaux (94% dans  $3 \times 3$  cristaux, et 97% dans  $5 \times 5$  cristaux, mesuré pour des électrons en faisceau test sans champ magnétique). Toutefois, s'il s'agit d'un électron qui rayonne des photons de bremsstrahlung ou que le photon s'est converti en paire  $e^+/e^-$  en amont du calorimètre (dans le trajectographe), l'étalement latéral peut être plus important.

En fin de gerbe électromagnétique, l'énergie des paires  $e^+/e^-$  et les photons de bremsstrahlung passent en-dessous d'une énergie critique. Le mécanisme de cascade électromagnétique cède alors la place aux mécanismes de perte d'énergie par ionisation et effet photo-électrique. Les particules en fin de gerbe excitent les électrons du matériau à des niveaux d'énergie plus élevés. Lors de la désexcitation, il y a émission de photons (phénomène de scintillation des cristaux de  $PbWO_4$ ) dans les longueurs d'onde du visible (avec un pic vers 420 nm, scintillation dans le bleu-vert) qui seront récoltés par des photo-détecteurs. Le  $PbWO_4$  a un temps de scintillation rapide : il y a émission d'environ 80% de la lumière en 25 ns (temps entre deux croisements de faisceaux).

Le rôle du détecteur pied de gerbe n'est pas de contenir la gerbe électromagnétique, mais plutôt de la déclencher grâce aux plaques de plomb et de mesurer ses propriétés dès son initiation. La fine granularité des pistes doit en particulier aider à discriminer les photons des  $\pi^0$  et améliorer l'identification des électrons. Les  $\pi^0$  se désintégrant en effet majoritairement en paire de photons, il est possible de mesurer l'énergie des deux gerbes électromagnétiques auxquelles il donne lieu, et ce même si elles sont très proches

l'une de l'autre (cas d'un  $\pi^0$  très boosté), tandis qu'un photon ne donne lieu qu'à une seule gerbe.

### Acquisition des données

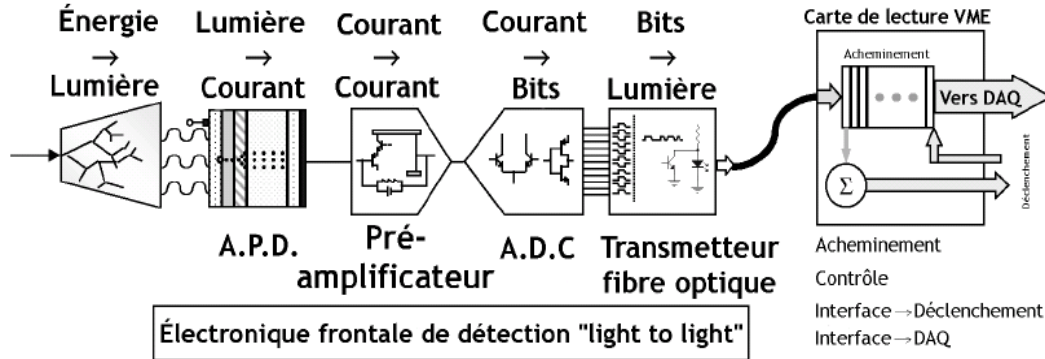


FIG. 1.11 – Electronique frontale de lecture du ECAL.

Le  $PbWO_4$  émet environ 4,5 photo-électrons par MeV qui sont récoltés par des **photo-détecteurs**, photo-diodes à avalanche (APD) dans le tonneau et photo-triodes à vide (VPT) dans les bouchons. Les APD et VPT sont chargées de convertir les photo-électrons en courant électrique. A l'arrière de chaque cristal du tonneau sont collés deux APD, qui ont une surface active de  $5 \times 5 \text{ mm}^2$  chacun. Les APD amplifient le signal photo-électrique avec un gain de 50 (ils peuvent aussi être configurés pour fonctionner à un gain de 200, comme lors de la prise de données de muons cosmiques en 2008 [30]). A l'arrière des cristaux du bouchon, il y a une VPT par cristal, qui sont des photo-multiplicateurs dont la photo-cathode a un diamètre de 25 mm de diamètre avec un gain moyen de 10 à 0 T.

Les **cartes électroniques VFE** ("Very Front End") sont ensuite chargées de récolter le courant électrique émis par les photo-détecteurs, d'amplifier le signal grâce au MGPA ("Multi Gain Pre-Amplifier") et de convertir le signal analogique en signal numérique avec les ADC ("Analogic Digital Converter"). Il y a une carte VFE pour 5 cristaux. En fonction de l'énergie déposée dans les cristaux, les ADC choisissent automatiquement l'un des trois gains possibles d'amplification (12, 6 ou 1) de sorte que la réponse de l'ADC ne soit pas saturée. L'ADC effectue un échantillonnage du signal toutes les 25 ns. 10 échantillons sont récoltés pour un événement. Le maximum d'énergie autorisé par cristal dans le tonneau est 1,7 TeV, et 3 TeV dans le bouchon (au-delà, il y a saturation de l'ADC).

Le signal de 5 cartes VFE est ensuite collecté sur une **carte FE** ("Front End" ou électronique frontale), utilisée pour plusieurs tâches : sommer le signal de 5 canaux en  $\phi$  (1 piste) à une fréquence de 40 MHz et sommer les signaux de  $5 \times 5$  canaux en  $\eta$ - $\phi$  (tours de déclenchement, 5 pistes) pour la transmission d'une primitive de déclenchement (Trigger Primitive, TP) au déclenchement de niveau 1, garder en mémoire les données jusqu'à ce que le déclenchement de niveau 1 envoyé par le déclenchement global soit reçu (3,2  $\mu\text{s}$ ). Il y a génération d'une TP pour chaque TT, constituée d'une information codée sur 9 bits contenant l'énergie transverse de la tour de déclenchement ainsi qu'un bit de grain fin, activé si la piste adjacente en  $\eta$  de plus haute énergie contient moins de 90% de l'énergie de la tour.

Le **déclenchement de niveau 1** (L1) pour les électrons et les photons [21] utilise une fenêtre glissante de  $3 \times 3$  TT qui parcourt tout le plan  $\eta$ - $\phi$ . L'énergie transverse du photon ou électron candidat est défini par la somme de la tour centrale ajoutée à celle de la tour voisine ayant la plus haute énergie. Le candidat est gardé seulement si le bit de veto fin est activé (selon l'hypothèse que la gerbe est concentrée en  $\eta$ ). De plus, l'énergie associée à la tour dans le HCAL doit être inférieure à 5% de l'énergie mesurée par le ECAL. Plusieurs voies de déclenchement sont alors définies : simple photon ou électron, double photon ou électron pouvant être isolés ou non, avec divers seuils requis en énergie transverse (typiquement 10 ou

20 GeV). Le déclenchement sur des photons ou électrons isolés demande qu'au moins 5 des 8 tours adjacente à la tour centrale aient une énergie transverse en-dessous d'un certain seuil (typiquement 1,5 GeV).

Une première réduction des données est effectuée par le **SRP** ("Selective Readout Processor" ou processeur de lecture sélectif) si le système de déclenchement décide de garder l'évènement. Elle est uniquement basée sur les tours de déclenchement (constituées de  $5 \times 5$  cristaux dans le tonneau, ou d'un super-cristal dans les bouchons) et les pistes dont l'énergie est sommée par la carte FE. Le SRP classe 3 types de signaux (les valeurs suivantes ont été mises en place pour les premières collisions [31]) :

- grand intérêt : lecture complète de  $3 \times 3$  TT si la TT centrale a une énergie transverse  $E_T > 2$  GeV.
  - intérêt moyen : lecture complète de la tour centrale seulement si son énergie transverse est  $E_T > 1$  GeV.
  - faible intérêt : lecture de la TT en mode "Zero Suppression" (ZS) si elle a une énergie inférieure à 1 GeV.
- En mode ZS, l'électronique ne lit pas les canaux qui ont une énergie en-dessous de  $2\sigma_{\text{bruit}}$  (i.e.  $\simeq 80$  MeV dans le tonneau) pour supprimer la composante due au bruit électronique.

Si l'évènement passe le déclenchement de niveau 1, le **déclenchement de haut-niveau** (HLT) va ensuite analyser les évènements fournis par le SRP en procédant en plusieurs étapes. Le déclenchement de niveau 2 reconstruit les photons et les électrons par les algorithmes de clusterisation (voir ci-après section 1.3.2). Le déclenchement de niveau dit "2,5" demande alors spécifiquement pour les électrons un coup dans le détecteur à pixels, et le déclenchement de niveau 3 utilise toute la reconstruction des traces dans le trajectographe. Finalement, une énergie transverse minimale est demandée pour que l'évènement passe le HLT et soit lu et enregistré en utilisant les informations de tous les sous-détecteurs.

### Performance : résolution en énergie

La résolution en énergie du ECAL a été mesurée lors des test faisceaux en 2004 et peut être paramétrisée par la formule suivante :

$$\left(\frac{\sigma}{E}\right)^2 = \left(\frac{S}{\sqrt{E}}\right)^2 + \left(\frac{N}{E}\right)^2 + C^2$$

$S$  est un terme stochastique tenant compte des fluctuations sur le développement latéral de la gerbe et sur l'énergie déposée dans le détecteur pied de gerbe, ainsi que sur le traitement des photo-électrons.  $N$  est un terme de bruit qui prend en compte le bruit du MGPA, de la numérisation et le bruit physique dû à l'empilement (significatif à haute luminosité).  $C$  un terme constant qui dépend des non-uniformités lors de la récupération de la lumière, de l'intercalibration, de la perte d'énergie à l'arrière du cristal et des effets de géométrie non pris en compte dans la modélisation.

La mesure de la résolution dans le tonneau sur des blocs  $3 \times 3$  de cristaux donne typiquement (pour des énergies en GeV) [32] :

$$\left(\frac{\sigma}{E}\right)^2 = \left(\frac{2.8\%}{\sqrt{E}}\right)^2 + \left(\frac{0.124}{E}\right)^2 + (0.3\%)^2$$

### Calibration du ECAL

La calibration du calorimètre électromagnétique peut être décomposée en deux parties : l'échelle absolue d'énergie (composante globale), et l'intercalibration entre les différents canaux (composante relative ou locale). On peut schématiquement décomposer l'énergie d'un électron ou d'un photon selon 3 facteurs :

$$E_{e,\gamma} = G \times F \times \sum_i c_i \times A_i$$

Où  $G$  est l'échelle d'énergie absolue ;  $F$  est une fonction de correction dépendant du type de la particule, de sa position, de son impulsion et du type d'algorithme utilisé pour la reconstruction (voir section 1.3.2) ; les  $c_i$  sont les constantes d'intercalibration et  $A_i$  les amplitudes du signal en coups ADC sommés sur les  $i$  cristaux de l'amas.

L'échelle d'énergie absolue  $G$  est un facteur correctif qui sera appliqué à tous les photons et électrons. Dès une luminosité de  $10 \text{ pb}^{-1}$ , l'échelle absolue peut être dérivée à partir du processus  $Z \rightarrow ee$  en se servant de la propriété selon laquelle la masse invariante  $ee$  doit piquer à la masse nominale du  $Z^0$ . A partir d'une luminosité intégrée de  $100 \text{ pb}^{-1}$  il devient possible d'utiliser aussi le canal  $Z \rightarrow \mu\mu\gamma$  pour calculer  $G$  [33, 34] à partir d'un lot de photons certifiés. En effet, la distribution en masse invariante  $\mu\mu\gamma$  est censée piquer exactement à la masse du  $Z^0$ , mais devrait être légèrement en-dessous du fait des effets instrumentaux : le facteur  $G$  devrait ramener le pic à sa place attendue.

Il est nécessaire de déterminer les constantes  $c_i$  d'intercalibration pour obtenir une réponse uniforme du détecteur. Ces corrections sont rendues nécessaires par les inévitables différences entre les canaux pour l'intensité de lumière émise et le gain des photo-détecteurs (par exemple). Les  $c_i$  peuvent être déterminées de nombreuses manières. Des mesures en tests faisceaux (pour seulement 9 des 36 des super-modules) ont permis de les mesurer une première fois (pré-calibration) avec une précision de 0,3 % dans le tonneau. Une précision de 1,5-2,5% a été atteinte à l'aide des muons cosmiques pour les 27 autres modules. Une partie des cristaux du bouchon a été calibré à 1% près et les constantes ont été interpolées aux autres cristaux. Ces mesures ont été validées lors des prises de données de muons cosmiques en 2008 [32]. Enfin, un lot d'évènement de  $1000 \pi^0$  par cristal devrait permettre d'améliorer encore la précision jusqu'aux 0,5% attendus.

### 1.3.2 Reconstruction des électrons et des photons

Lorsqu'un électron ou un photon dépose son énergie dans le calorimètre, l'énergie est d'abord reconstruite en "clusters" (amas de cristaux), avant que le cluster ne soit identifié comme étant un électron ou un photon. La présence du champ magnétique de CMS courbe la trajectoire des électrons selon  $\phi$ . Dans la matière placée devant le calorimètre (le trajectographe, voir schéma 1.12), les électrons peuvent émettre des photons par bremsstrahlung, qui tendent à s'étaler en  $\phi$ . Pour cette raison, les cristaux d'abord sont regroupés en "basic-cluster", eux-mêmes regroupés en "super-clusters" pour récupérer les photons de bremsstrahlung. Différentes corrections sont appliquées pour palier aux inévitables pertes d'énergie induites par le procédé de clusterisation. C'est seulement ensuite que l'identification des électrons et des photons peut avoir lieu.

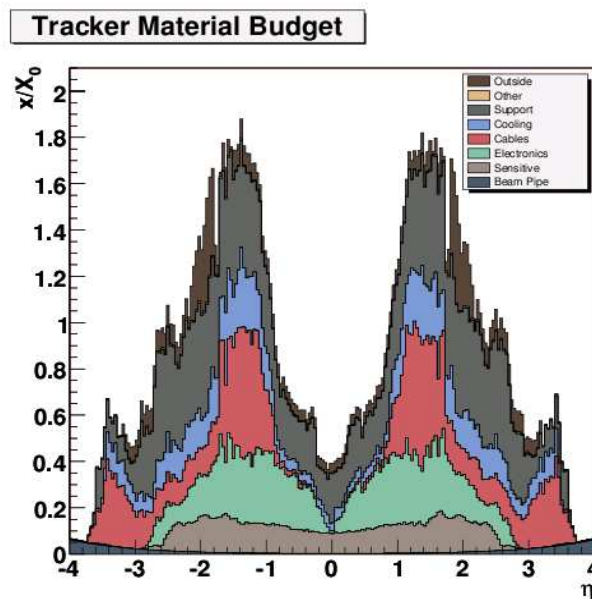


FIG. 1.12 – Quantité de matière dans le trajectographe, exprimée en longueurs de radiation, en fonction de  $\eta$  [15].

## La clusterisation

Le tonneau et les bouchons nécessitent des algorithmes de clusterisation adaptés, du fait du taux d'occupation différent dans les bouchons et dans le tonneau ; le champ magnétique n'y est pas le même, et la quantité de matière présente devant les bouchons est plus importante. L'algorithme "hybrid" est utilisé dans le tonneau, tandis que l'algorithme "multi5x5" est utilisé dans les bouchons [35].

### Clusterisation dans le tonneau : algorithme "hybrid"

L'algorithme "hybrid" a été conçu pour permettre une recollection efficace des photons de bremsstrahlung émis par les électrons (issus ou non d'une conversion) étalés selon  $\phi$ . L'idée est de collecter l'énergie par rectangles de cristaux étendus en  $\phi$  et constant en  $\eta$ . L'algorithme opère comme suit :

- L'algorithme sélectionne les cristaux classés par énergie transverse décroissante. Pour chacun d'eux (non encore inclus dans un cluster), il teste si l'énergie transverse est supérieure à un seuil  $E_T > E_T^{hybseed}$  ( $E_T^{hybseed} = 1$  GeV). Si tel est le cas, le cristal est un germe qui initie le processus de clusterisation.
- Un "domino" de  $5 \times 1$  cristaux est construit autour du cristal germe en  $\eta \times \phi$ .
- Tant que l'énergie du domino est supérieure à un certain seuil  $E_{domino} > E_{thresh}$  ( $E_{thresh} = 0.1$  GeV), un nouveau domino avec  $\phi$  incrémenté d'un cristal est construit pour les mêmes valeurs de  $\eta$ . Le processus est répété au maximum sur 17 cristaux en  $\phi$ .
- Le processus est répété pour tous les cristaux germes (et qui peuvent être très séparés en  $\phi$  du cristal de plus haute énergie) : voir schéma 1.13. Le regroupement de tous ces amas en un super-cluster assure la récupération des photons de bremsstrahlung.

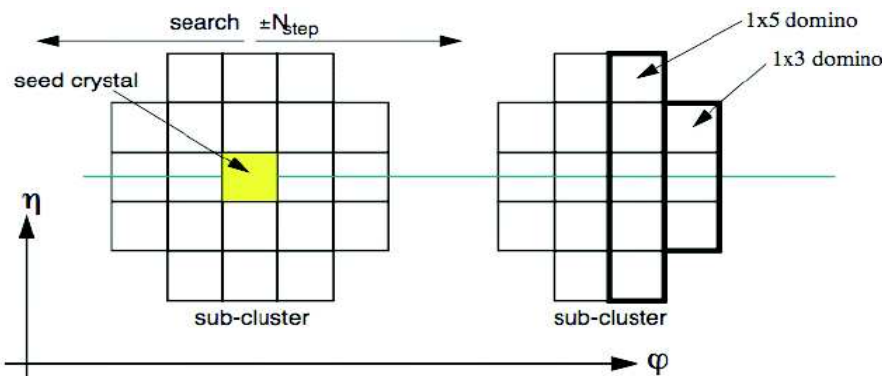


FIG. 1.13 – Schéma du procédé "hybrid" de clusterisation dans le tonneau.

### Clusterisation dans les bouchons : algorithme "multi5x5"

L'algorithme "multi5x5" a été conçu pour être adapté à la géométrie des bouchons, qui n'ont pas une symétrie de révolution en  $\phi$  comme le tonneau. La récupération des photons de bremsstrahlung est ici effectuée en permettant au super-cluster d'avoir une extension variable en  $\eta$ - $\phi$  :

- L'algorithme sélectionne les cristaux classés par énergie transverse décroissante. Si  $E_T > E_T^{seed}$  ( $E_T^{seed} = 0.18$  GeV) le cristal initie le processus.
- Si l'énergie du cristal est supérieure à ses voisins de gauche, droite, haut et bas (maximum local d'énergie) il est sélectionné comme germe et on passe au cristal suivant de l'étape 1.
- Une fois tous les cristaux germes trouvés, un basic-cluster de  $5 \times 5$  cristaux est construit autour de chacun d'eux. Si plusieurs basic-clusters se chevauchent, seuls ceux qui n'appartiennent pas déjà à un basic-cluster dont le germe est plus énergétique sont inclus (voir schéma 1.14). Tous les basic-clusters contigus sont rassemblés dans un seul super-cluster. L'énergie dans le détecteur pied de gerbe associée à chaque cristal du super-cluster est ajoutée à l'énergie de celui-ci.

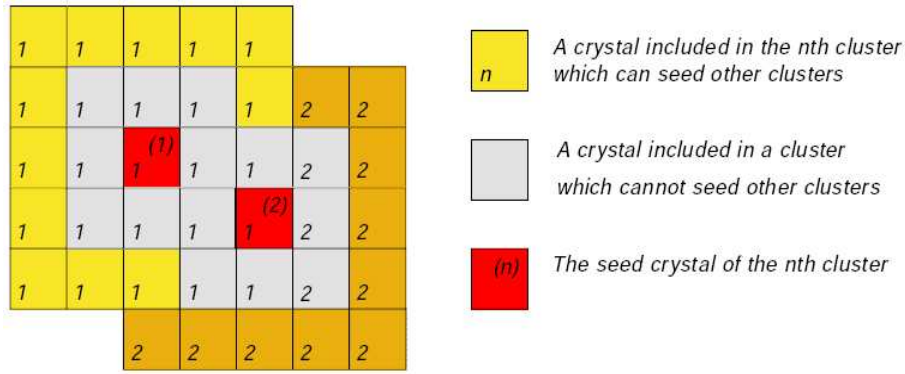


FIG. 1.14 – Schéma du procédé “multi5x5” de clusterisation dans les bouchons.

### Corrections en énergie

Trois types de corrections sont appliqués aux super-clusters [35]. Pour le moment les mêmes corrections sont appliquées aux photons et aux électrons, mais ceci est appelé à changer (dans l'idéal il serait nécessaire de prendre en compte la différence de comportement des gerbes créées par les électrons et les photons) :

- En premier lieu, un facteur  $C_{EB}(\eta)$  est appliqué aux super-clusters du tonneau pour compenser la perte d'énergie latérale due au fait que les cristaux du tonneau sont légèrement inclinés en  $\eta$  par rapport au centre du détecteur. Cette correction a été calculée dans les simulations et vérifiée en faisceau test.

- Une correction appelée  $f(brem)$  est ensuite appliquée pour corriger la perte d'énergie induite par l'inefficacité de récupération des photons de bremsstrahlung dans le processus de clusterisation. La variable  $brem$  est définie par la formule suivante :

$$brem = \frac{\sigma_\phi}{\sigma_\eta} = \frac{\sum_{Xtal} \sqrt{\frac{E_{Xtal}}{E_{SC}} (\phi_{Xtal} - \phi_{SC})^2}}{\sum_{Xtal} \sqrt{\frac{E_{Xtal}}{E_{SC}} (\eta_{Xtal} - \eta_{SC})^2}}$$

$\sigma_\phi$  et  $\sigma_\eta$  représentent la largeur de la gerbe dans la direction  $\phi$  et  $\eta$ . La somme est effectuée sur chacun des cristaux  $Xtal$  du super-cluster,  $E_{Xtal}$  est l'énergie des cristaux et  $E_{SC}$  est l'énergie du super-cluster.  $\sigma_\phi$  est la variable pertinente pour décrire l'étalement des bremsstrahlung selon  $\phi$ , et est normalisée en  $\eta$  pour supprimer la dépendance en énergie ( $\sigma_\phi$  et  $\sigma_\eta$  varient logarithmiquement avec l'énergie).

$f(brem)$  est calculé de telle sorte que le rapport de l'énergie de la particule incidente sur l'énergie du super-cluster reconstruit  $E_{reco}/E_{MC}$  soit égal à 1 sur tout le spectre en  $\sigma_\phi/\sigma_\eta$ .

- La dernière correction appliquée à l'énergie des super-clusters est une correction résiduelle  $f(E_T, \eta)$  nécessaire pour compenser les pertes d'énergie dans le trajectographe, calculée de la même façon que  $f(brem)$  mais par divisions de 2 GeV en  $E_T$  et de 0.1 en  $\eta$ . Pour le moment  $f(E_T, \eta)$  est déterminée par la simulation, mais devrait être mesurée dans les données à l'aide du canal  $Z \rightarrow e^+e^-$  (la masse du  $Z^0$  étant connue), dès  $10 \text{ pb}^{-1}$  de luminosité intégrée.

### Reconstruction des photons

A partir des super-clusters, les photons sont reconstruits différemment si l'énergie déposée est très concentrée autour du cristal de plus haute énergie (germe) ou non. On définit habituellement la variable topologique  $R9 = \frac{E_{3 \times 3}}{E_{SC}}$ , où  $E_{3 \times 3}$  est l'énergie de  $3 \times 3$  cristaux centrés autour du cristal germe, et  $E_{SC}$  l'énergie corrigée du super-cluster.

- Si  $R9 > R9_{seuil}$ , il a été montré que la meilleure résolution en énergie pour les photons est obtenue avec

l'énergie des cristaux  $5 \times 5$  centrés autour du cristal germe plutôt qu'avec l'énergie du super-cluster. La position du super-cluster est alors par le barycentre des positions des cristaux pondérées par un facteur tenant compte de la profondeur estimée de la gerbe. Les grandes valeurs de  $R9$  sont surtout peuplées par les photons non-convertis ou ayant converti très tard dans le trajectographe, qui ne sont pas sujet au problèmes liés au bremsstrahlung. La valeur choisie de  $R9_{seuil}$  est  $R9_{seuil} = 0.94$  dans le tonneau et  $R9_{seuil} = 0.95$  dans le bouchon pour éviter la contamination des conversions.

- Si  $R9 < R9_{seuil}$ , la meilleure résolution est obtenue avec l'énergie du super-cluster et la position du cristal germe. De tels photons sont en général convertis et les électrons résultant de la conversion perdent de l'énergie par bremsstrahlung.

Additionnellement, un traitement spécial est appliqué pour la reconstruction des photons convertis, qui n'utilise pas la variable  $R9$  mais recherche les traces associées à la conversion en paire  $e^+/e^-$ . Si le photon s'est converti dans le trajectographe, il est possible de retrouver les traces associées à l'électron et au positon. La recherche des traces associées aux photons est initiée à partir du super-cluster et effectuée de l'ECAL vers le trajectographe [36]. Zero, une ou deux traces peuvent être reconstruites et associées au super-cluster. Cette information est rendue disponible dans CMSSW mais ne modifie pas l'énergie reconstruite des photons.

En général une énergie transverse minimum est aussi demandée pour la promotion des superclusters en photons, car les corrections en énergie ont été optimisées pour  $E_T > 10$  GeV. Il est à noter que par défaut, les photons reconstruits par les algorithmes incluent aussi les super-clusters qui ont été identifiés comme appartenant à un électron et il convient de nettoyer la collection en les supprimant.

A ce stade le taux de photons reconstruits provenant de la désintégration de  $\pi^0$  et de  $\eta$  (ou même de dépôts d'énergie provenant du bruit ou de gerbes hadroniques initiée dans le ECAL par exemple) reste très élevé, spécialement dans des processus de QCD multi-jets. Les photons reconstruits de signal (photons prompts ISR/FSR ou partoniques) peuvent être identifiés avec plus de probabilité (et une plus grande pureté) par application de critères de sélection supplémentaires sur les variables d'isolation, telles que l'énergie transverse des cristaux dans le ECAL, des traces dans le trajectographe ou des tours dans le HCAL environnant le photon dans un cône de 0,3 en  $\Delta R$ .

## Reconstruction des électrons

A la différence des photons non-convertis les électrons laissent une trace dans le trajectographe, et ce dès les premières couches du détecteur à pixel. L'algorithme de reconstruction des électrons [37] part du super-cluster reconstruit et cherche le coup dans le détecteur à pixel le plus proche de la trajectoire extrapolée de l'électron compatible avec le point d'interaction. A partir de ce germe, les traces possibles de l'électron sont reconstruites en utilisant un algorithme (appelé "Gaussian Sum Filter") qui effectue un ajustement entre trajectoire des traces attendues et effectivement reconstruites et qui tient compte des pertes d'énergie par bremsstrahlung à chaque itération. La trajectoire donnant le meilleur ajustement est sélectionnée si elle a laissé 5 coups au minimum dans le trajectographe.

En principe, l'impulsion estimée  $p$  de l'électron en utilisant l'information sur les traces devrait être égale à l'énergie estimée  $E$  par la reconstruction du super-cluster. Dans la pratique la distribution  $E/p$  pique effectivement en 1, mais une large dispersion est due aux incertitudes de la mesure (principalement dues à prise en compte incomplète des bremsstrahlung par les deux algorithmes). L'énergie de l'électron est donc calculée en pondérant  $p$  et  $E$  de sorte que la résolution sur l'énergie de l'électron soit optimale. A basse (haute) énergie, la résolution sur l'énergie est principalement obtenue par le trajectographe (le calorimètre) et entre les deux régimes (autour de 10-25 GeV) l'incertitude est issue d'une combinaison entre les deux informations.

Une fois les électrons reconstruits et leur énergie fixée, ils sont classés en quatre catégories : électron d'or ("golden electron") peu affecté par le bremsstrahlung et dont l'énergie est contenue dans un seul

basic-cluster, électron de grand bremsstrahlung (“big Brem electron”) qui a émis plus de la moitié de son énergie par bremsstrahlung, électron étroit (“narrow electron”) ayant émis une partie importante de son énergie par bremsstrahlung mais dont l’énergie est contenue dans un seul basic-cluster, et électron de gerbe (“showering electron”) qui émet des photons de bremsstrahlung qui se convertissent, et pour lesquels une plus faible résolution en énergie et position est obtenue. Cette classification est utilisée pour appliquer des coupures d’identification supplémentaires sur diverses variables (énergie dans un cône d’isolation, forme du cluster,  $E/p$ , etc) et permet d’abaisser le taux de faux électrons reconstruits (photons, hadrons chargés ou bruit).

### Résultats dans les premières données

Le ECAL est en fonctionnement : après la prise de données de muons cosmiques en 2008, le bon fonctionnement du ECAL a pu être testé dans les premières données des collisions à 900 GeV, 2,36 TeV et 7 TeV d’énergie dans le centre de masse. Les résultats publics obtenus avec les collisions à 7 TeV peuvent être trouvés référence [38] pour le commissionnage du ECAL, référence [39] pour la calibration du ECAL et référence [40] pour le commissionnage des algorithmes de reconstruction des super-clusters et des photons. Notons qu’avec une luminosité de  $123 \text{ nb}^{-1}$ , la précision atteinte sur les constantes d’intercalibration est déjà de 1,2% dans la partie centrale du tonneau (l’analyse est seulement limitée par la statistique).

Des algorithmes ont aussi été développés pour éliminer les dépôts d’énergie anormaux [38] de haute énergie observés dans le tonneau du ECAL, découverts lors des premières collisions. Les données montrent un excès de super-clusters avec une grande énergie transverse, dont le dépôt d’énergie est concentré sur un seul cristal (“spikes”). La source de ces “spikes” a été identifiée : il s’agit en fait de dépôts d’énergie non dans les cristaux mais directement dans le volume sensible de l’APD, dûs à des particules hautement ionisantes (principalement des protons et des ions lourds produits durant les collisions). Le taux de ces événements est d’environ 1 pour 1000 événements de biais minimum. La prise en compte de ce processus dans la simulation est en cours d’investigation.

Il est possible d’éliminer ces “spikes” en utilisant des critères portant sur la forme du dépôt d’énergie. Notons  $E1$  l’énergie du cristal de plus haute énergie dans le super-cluster et  $E4$  la somme des énergies des quatre cristaux voisins en  $\eta$ - $\phi$ . Le critère recommandé actuellement dans CMS demande  $(1 - E4/E1) < 0.95$ . Un critère plus ancien demandait  $|E1/E9 - 1| < 0.95$ , où  $E9$  est la somme des énergies des cristaux  $3 \times 3$  autour du cristal de plus haute énergie. Il est aussi possible de se servir du fait que les “spikes” ont une synchronisation en temps déplacée par rapport au croisement de faisceau (ils piquent à -10 ns), car la réponse de l’APD est légèrement différente pour les “spikes” et pour les dépôts d’énergie normaux. Les distributions de  $(1 - E4/E1)$  et de la synchronisation des cristaux de plus haute énergie par événement sont montrés figure 1.15.



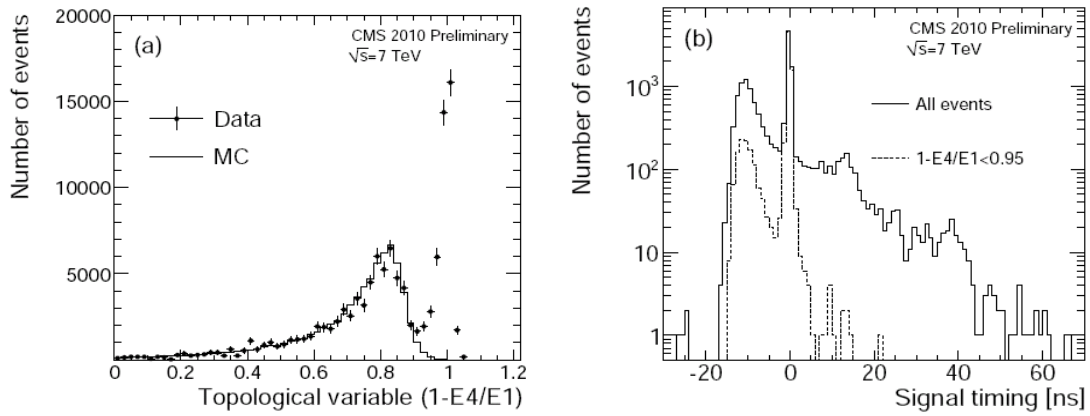


FIG. 1.15 – À gauche, distribution  $(1 - E_4/E_1)$ . À droite, synchronisation en temps du cristal de plus haute énergie, par évènement, pour des évènements ayant des dépôts d'énergie ayant une énergie transverse supérieure à 3 GeV, dans les données de collision à 7 TeV.



## Chapitre 2

# Physique du boson de Higgs

Depuis sa création dans la fin des années 1960, le modèle standard de la physique des particules s'est montré capable de décrire une large variété des phénomènes physiques aux hautes énergies. Dans le modèle standard, on sépare généralement la *matière*, constituée de fermions (quarks et leptons) des *interactions* véhiculées par les bosons. Le modèle standard rend compte de l'interaction électromagnétique, faible (rassemblés en une seule interaction générique dite électrofaible) et forte. Les quarks sont au nombre de 6 ( $u, d, s, c, t, b$ ) plus leurs anti-quarks associés, et interagissent principalement par interaction forte. Il y a de même 6 leptons ( $e, \mu, \tau$ , et les neutrinos  $\nu_e, \nu_\mu, \nu_\tau$ ) plus leurs anti-leptons associés, qui interagissent principalement par interaction électromagnétique ou faible. Le photon est le boson vecteur de l'interaction électromagnétique, les bosons  $W^\pm, Z^0$  sont vecteurs de l'interaction faible (le  $Z^0$  peut aussi véhiculer l'interaction électromagnétique) et les gluons sont les vecteurs de l'interaction forte. Enfin, le modèle standard inclut un mécanisme pour briser la symétrie de l'interaction faible et doter les bosons  $W^\pm, Z^0$  d'une masse. Ce mécanisme, dit mécanisme de Higgs, prédit aussi l'existence du boson de Higgs, particule associée à un champ scalaire qui n'a pas encore été découverte à ce jour.

Le LHC a été construit pour tenter de répondre aux questions actuellement ouvertes en physique des hautes énergie. La principale interrogation concerne l'existence du boson de Higgs, qui est la particule-clé du modèle standard en ce qu'elle est révélatrice de la physique du secteur électrofaible. Si le boson de Higgs n'existe pas, il faudra trouver une autre explication théorique à la masse des bosons  $W^\pm$  et  $Z^0$ . Si le boson de Higgs tel qu'il est décrit par le modèle standard existe (ou s'il possède des propriétés semblables à celles prédites par le modèle standard), il devrait être observé au LHC car tout le domaine de masse permis par la théorie y est accessible.

Ce chapitre débutera avec un bref rappel historique des problèmes théoriques qui ont conduit à la formulation du modèle standard, avant d'exposer plus en détail le mécanisme de Higgs (section 2.1.2). Malgré ses succès, le modèle standard n'est pas exempt de problèmes théoriques et pratiques, qui ont conduit les théoriciens à proposer des alternatives brièvement passées en revue section 2.1.3. La recherche du boson de Higgs au LHC sera ensuite abordée section 2.2. Le boson de Higgs est produit au LHC lors de collisions proton-proton principalement par fusion de gluons, et les canaux de désintégration privilégiés dans lequel il est recherché dans CMS seront ensuite examinés, avec une attention particulière portée à  $H \rightarrow ZZ^*$  et  $H \rightarrow \gamma\gamma$ . Une nouvelle paramétrisation du canal  $H \rightarrow \gamma\gamma$  au-delà du modèle standard sera aussi décrite. Si l'existence du boson de Higgs n'a toujours pas été prouvée, la recherche du boson de Higgs au LEP a permis de poser une limite d'exclusion sur sa masse par recherche directe :  $m_H > 114.4$  GeV, domaine que couvre les recherches au LHC. Les recherches du boson de Higgs au Tevatron commencent aussi à porter leur fruit et à aboutir à des limites d'exclusion. Un état de l'art de la recherche du boson de Higgs, directe et indirecte, sera dressé section 2.3, et les perspectives pour la recherche du boson de Higgs au LHC seront finalement présentées.

## 2.1 Le boson de Higgs dans le modèle standard

### 2.1.1 Naissance de la théorie de l'interaction électro-faible

#### Invariance de jauge et théorie de Yang-Mills

A la base des théories actuelles en physique des particules, il y a l'idée que les nombres quantiques liés aux interactions sont conservés quelle que soit le processus considéré. On appelle cette propriété l'invariance de jauge du lagrangien. L'idée de "jauge" était connue dès le XIX<sup>e</sup> siècle, avec les travaux de Lorentz et de Maxwell sur les lois de l'électromagnétisme. Les champs électriques et magnétiques dérivent d'un potentiel électromagnétique, qui peut être défini de manière non ambiguë par le choix d'une jauge [41]. La notion d'invariance de jauge apparut pour la première fois dans la théorie des champs au XX<sup>e</sup> siècle en 1918 sous la plume de Hermann Weyl, qui avait le projet d'unifier la théorie de relativité générale avec l'électromagnétisme [42]. C'était la première formulation d'une symétrie externe (symétrie de l'espace-temps).

La notion d'invariance de jauge a dès lors pris une importance croissante au sein de la physique théorique. Vers la fin des années 1920, Fock et Weyl remarquaient une symétrie de l'électromagnétisme d'un nouveau type, symétrie interne, qui ne porte pas sur l'espace-temps mais sur le champ électromagnétique. Ainsi, alors que Pauli, Dirac et d'autres travaillaient sur la formulation de la théorie quantique des champs, Pauli insistait sur cette invariance du lagrangien sous les transformations de jauge de l'électromagnétisme [43]. La jauge de l'électromagnétisme se définit comme une symétrie locale et interne du lagrangien : il reste invariant sous une transformation de jauge dont le paramètre dépend des coordonnées spatio-temporelles. Mathématiquement, le groupe des transformations est le groupe de Lie  $U(1)$ , qui est un groupe à paramètre continu avec un seul générateur (il est donc commutatif).

En 1954, afin de rendre compte des propriétés du spin isotopique observées dans les expériences de désintégration  $\beta$ , Yang et Mills ont été conduit à proposer une théorie de jauge non abélienne [44]. Elle était présentée comme une généralisation de la jauge de l'électromagnétisme et était destinée à expliquer la désintégration du proton en neutron, dont l'isospin diffère d'une unité.

#### Le modèle V-A de l'interaction faible

Au début des années 1950, on venait alors de découvrir que dans certaines réactions (comme la diffusion proton-proton), le spin isotopique était conservé, ce qui motiva Yang et Mills à formuler leur théorie. On découvrit de plus une nouvelle symétrie interne, la conservation de l'étrangeté [45]. De nouvelles symétries globales apparaissaient sans qu'on ne trouve un principe simple qui pouvait en rendre compte simultanément [46].

En 1957, on découvrit que l'interaction faible violait la parité. Aussitôt, Sudarshan et Marshak, Feynman et Gell-Mann [47], Sakurai, ainsi que Bludman [48] proposèrent séparément en 1958 la première théorie de l'interaction faible. Bludman proposa une théorie aujourd'hui appelée "V-A" (la violation de la parité était effectuée par des interactions qui concernent les vecteurs ainsi que les vecteurs axiaux), qui prédit l'existence d'une particule intermédiaire dans l'interaction entre 4 fermions ( $W^\pm$ , le boson faible chargé de spin 1), tandis que les autres proposèrent une théorie dite de Fermi avec un vertex à 4 fermions. Il est à noter que seul Bludman faisait référence dans son travail à la théorie de Yang-Mills.

Il y avait toutefois un problème majeur pour ces deux théories : leur non-renormalisabilité. La théorie à 4 fermions donnait de bons résultats à l'ordre le plus bas, mais dès l'ordre suivant conduisait à des infinis impossibles à éliminer. La théorie V-A de Bludman, elle aussi n'était pas renormalisable.

#### Théorème de Goldstone et mécanisme de Higgs

L'idée d'une brisure de symétrie spontanée n'a pas tout d'abord été introduite en physique des particules, mais en matière condensée, dans le cadre de la théorie BCS de la superconductivité (Bardeen, Cooper

et Schriber, [49]). C'est Anderson [50] qui réalisa le premier qu'un superconducteur était un matériau où il y a brisure de la symétrie de jauge de l'électromagnétisme. Nambu et Jona-Lasinio [51] en montrèrent un premier exemple en physique des particules avec la symétrie chirale de l'interaction forte. Ce modèle conduisait à l'apparition d'un pion non massif comme nouveau degré de liberté du système résultant de la brisure de symétrie.

Le théorème de Goldstone, qui a été formulé dans un article fondateur de 1961 [52], modélisait la brisure de symétrie interne du lagrangien à partir du cas général des groupes à paramètres continus. Sa démonstration était basée sur l'usage d'un champ scalaire ajouté de manière ad-hoc, pour lequel la symétrie était brisée de manière dynamique, comme brisure de la symétrie du vide (la possibilité d'un vide ne respectant pas la symétrie du lagrangien avait été évoquée par Heisenberg [53]). On peut l'énoncer ainsi : toute brisure de symétrie spontanée d'une symétrie interne continue conduit à l'apparition de particules scalaires non massives au même nombre que la dimension du groupe de départ. Mais le problème consistait en ce qu'à part le photon, on ne connaissait aucune autre particule de masse nulle. Il a fallu attendre les travaux de Peter Higgs et d'autres physiciens comme Kibble, Guralnik, Englert et Brout pour surmonter ce problème.

Le mécanisme de Higgs [54] peut être vu comme une généralisation du théorème de Goldstone dans le cas où le système est invariant sous un groupe d'une symétrie interne locale, qui dépend des coordonnées d'espace-temps (groupe de jauge). En brisant la symétrie de jauge par une valeur non nulle dans le vide d'un champ scalaire ajouté de manière ad-hoc, les bosons de Goldstone sont absorbés dans le tenseur de champ associé au groupe de jauge. Après changement de base, il apparaît que les particules associées à ce tenseur acquièrent une masse. Il est intéressant de noter que Higgs, à la suite de Freund et Nambu dans leur article de 1964 [55], parlait en 1966 de "vacuum" pour la valeur dans le vide du champ scalaire, et de "zeron" pour ses oscillations à partir de cette valeur [56], terminologie qui n'a pas été retenue dans la suite de l'élaboration du modèle standard.

### Formulation du modèle standard

Au début des années 1960, on ne disposait pas d'une théorie satisfaisante de l'interaction faible. Du point de vue théorique, il manquait alors deux composants fondamentaux : le choix du bon groupe de symétrie et le mécanisme de brisure de symétrie qui doterait les bosons vecteurs de l'interaction faible de masses non nulles. Le groupe de symétrie consistant avec l'interaction faible telle qu'elle était observée expérimentalement fut introduit par Georgi Glashow en 1961 [57]. Il s'agissait du groupe  $SU(2) \times U(1)$ , qui permettait de mettre en oeuvre l'interaction faible avec  $SU(2)$  tout en conservant la théorie de l'électromagnétisme dont la jauge est  $U(1)$ . Le modèle prédisait l'existence de courants neutres (dont le boson vecteur est aujourd'hui connu comme étant le  $Z^0$ , de spin 1 et de charge nulle). Mais son principal problème était d'ajouter manuellement les masses des particules dans le lagrangien, ce qui correspond à une brisure statique de la symétrie de l'interaction faible et de l'électromagnétisme.

Il fallut attendre 6 ans de plus pour trouver comment donner une masse aux bosons vecteurs de l'interaction faible sans briser l'invariance du lagrangien, lorsque Steven Weinberg [58] et Abdus Salam [59] eurent l'idée d'appliquer le mécanisme de Higgs au modèle de Glashow. En brisant la symétrie de jauge  $SU(2)$  dans le vide et en conservant  $U(1)$ , les bosons vecteurs de l'interaction faible acquièrent une masse non nulle. Le modèle prédit l'existence d'une nouvelle particule, le boson de Higgs, champ scalaire qui brise la symétrie de jauge de l'interaction faible dans le vide. Par l'intermédiaire des couplages de Yukawa, il donne aussi leur masse à toutes les particules de matière. Ce modèle est aujourd'hui connu comme le modèle standard de l'interaction électrofaible.

Les succès du modèle standard ont été très nombreux. Tout d'abord, la théorie était renormalisable (ainsi que l'ont montré 't Hooft [60] et Veltman en 1971). Les courants neutres ont été découverts en 1971 par l'expérience Gargamelle. Suivirent la découverte du méson  $J/\psi$  et de son spectre ainsi que du quark charme (1974), du lepton tau en 1975 par Perl et al., la découverte des bosons W et Z en 1983 au SPS, celle des quarks bottom (1977, Fermilab) et top (1994, Tevatron)...

### 2.1.2 Mécanisme de Higgs dans le modèle standard

Le boson de Higgs dans le modèle standard est décrit par le modèle Glashow-Weinberg-Salam (GWS) de l'interaction électrofaible (Glashow, 1961 [57] ; Weinberg, 1967 [58] ; Salam, 1968). Il s'agit d'une théorie de jauge non abélienne, dont le groupe de symétrie est  $SU(2)_L \times U(1)_Y$  et qui est accompagnée par le mécanisme de Higgs. Le mécanisme de Higgs consiste en une brisure spontanée de cette symétrie continue. Comme toutes les brisures de symétries continues, la conséquence en est l'apparition formelle d'un boson massif, ici le boson de Higgs. L'amplitude d'interaction des champs des particules avec le champs de Higgs est alors proportionnelle à la masse du boson de Higgs. L'ajout d'un terme de masse au lagrangien n'aurait pas conservé l'invariance du lagrangien, alors que le mécanisme de Higgs la conserve.

#### Le lagrangien

Le lagrangien du modèle standard peut être divisé en 4 secteurs [61] :

$$L_{SM} = L_D + L_{YM} + L_{Higgs} + L_{Yukawa}$$

Dans la suite, on ne tiendra pas compte de la QCD, puisque la génération du boson de Higgs demande seulement les termes d'interaction électrofaibles. Il faudrait notamment en tenir compte pour le terme cinétique dans le potentiel de Yang-Mills.

#### Secteur de Dirac

Le lagrangien de Dirac s'écrit de la manière suivante :

$$L_D = \bar{L}i\gamma^\mu D_\mu L + \bar{R}i\gamma^\mu D_\mu R$$

Pour plus de simplicité, on se limitera aux leptons de la première famille, l'électron  $e$  et le neutrino  $\nu_e$ . Dans le modèle GWS, ces composants de la matière sont décrits par un doublet de chiralité gauche L et par un singlet de chiralité droite R du groupe  $SU(2)$  :

$$L = \begin{pmatrix} \nu_e \\ e \end{pmatrix}_L, \quad R = e_R$$

$$e_L = \frac{1}{2}(1 + \gamma_5)e, \quad e_R = \frac{1}{2}(1 - \gamma_5)e, \quad \gamma_5 \nu_{eL} = \nu_{eL}$$

Le lagrangien est invariant sous les transformations de jauge locales des groupes  $SU(2)_L$  et  $U(1)_Y$  :

$$SU(2)_L : L \rightarrow L' = e^{-i\alpha^i(x)\frac{\tau^i}{2}}, \quad R' \rightarrow R$$

$$U(1)_Y : L \rightarrow L' = e^{-\frac{i}{2}\beta(x)}, \quad R' \rightarrow e^{i\beta(x)}R$$

La dérivée covariante s'écrit explicitement :

$$D_\mu = \partial_\mu - ig\frac{\vec{\tau}}{2} \cdot \vec{A}_\mu - ig' \frac{Y}{2} B_\mu$$

Où  $A_\mu^i (i = 1, 2, 3)$  et  $B_\mu$  sont les champs des bosons de jauge associés à  $SU(2)_L$  et  $U(1)_Y$  respectivement. On désigne par  $\tau^i$  les 3 matrices de Pauli usuelles.

L'hypercharge vaut  $Y = -1$  pour L et  $Y = -2$  pour R. R étant un singlet de  $SU(2)_L$ , il n'a pas de couplage avec  $A_\mu^i$ .

### Secteur de Yang-Mills

Le terme de Yang-Mills du lagrangien est composé des termes cinétiques des champs de jauge :

$$L_{YM} = -\frac{1}{4}F_{\mu\nu}^i F^{i\mu\nu} - \frac{1}{4}B_{\mu\nu}B^{\mu\nu}$$

$$F_{\mu\nu}^i = \partial_\mu A_\nu^i - \partial_\nu A_\mu^i + g\epsilon_{ijk}A_\mu^j A_\nu^k$$

$$B_{\mu\nu} = \partial_\mu B_\nu - \partial_\nu B_\mu$$

Où  $F_{\mu\nu}^i (i = 1, 2, 3)$  est le tenseur de l'interaction faible, associé au champ de jauge correspondant à  $SU(2)_L$ ; et  $B_{\mu\nu}$  est le tenseur de Yang-Mills, associé au champ de jauge correspondants à  $U(1)_Y$ .

### Secteur de Higgs

Le lagrangien de Higgs a la forme suivante :

$$L_{Higgs} = (D_\mu\phi)^\dagger(D_\mu\phi) - V(\phi^\dagger\phi)$$

$$V(\phi^\dagger\phi) = -\mu^2\phi^\dagger\phi + \lambda(\phi^\dagger\phi)^2$$

Où  $\phi = \begin{pmatrix} \varphi_0^+ \\ \varphi_0^0 \end{pmatrix}$  est un doublet de  $SU(2)$  de 2 champs scalaires complexes et dont l'hypercharge faible est  $Y=1$ . Le potentiel de Higgs  $V(\phi^\dagger\phi)$  est invariant de jauge ;  $\mu^2$  et  $\lambda$  sont des paramètres réels constants et positifs. Le potentiel présente une symétrie de rotation (voir schéma 2.1) dans l'espace des générateurs de  $SU(2)$ .




FIG. 2.1 – Représentation du potentiel de Higgs.

### Secteur de Yukawa

$$L_{Yukawa} = -G_e(\bar{L}\phi R + \bar{R}\phi^\dagger L) + h.c.$$

Où  $G_e$  est appelé la constante de couplage de Yukawa, qui ne peut pas être déterminée par le modèle GWS lui-même et est déterminée par l'expérience à partir des masses mesurées des particules (voir plus loin : masse des fermions).

### Le boson de Higgs

Dans le modèle standard, le boson de Higgs adopte une valeur non nulle dans le vide, ce qui brise spontanément la symétrie électrofaible. Dans la mesure où il y a brisure spontanée d'une symétrie de jauge continue (ou locale), la masse de la particule créée est non nulle (contrairement aux cas où la symétrie n'est pas celle d'un groupe de jauge et pour lesquels il y a génération d'un boson de Goldstone sans masse).

On brise la symétrie de la manière suivante :

$$SU(2)_L \times U(1)_Y \rightarrow U(1)_{em}$$

### Le champ de Higgs

On cherche le minimum du potentiel  $V(\phi^\dagger\phi)$ . Il est atteint pour une valeur  $\phi^\dagger\phi = |\phi|^2 = \frac{v^2}{2}$ , avec  $v = \sqrt{\frac{\mu^2}{\lambda}}$ . La valeur du champ  $\phi$  dans le vide est alors :  $\phi_0 = \langle 0|\phi|0 \rangle = \begin{pmatrix} 0 \\ v/\sqrt{2} \end{pmatrix}$ . La symétrie du vide est brisée.

On paramétrise différemment  $\phi$ , en tenant compte de la rotation à partir de l'état de vide  $\phi_0$  :

$$\phi = e^{i\vec{\tau}\cdot\vec{\xi}/2v} \begin{pmatrix} 0 \\ (v+H)/\sqrt{2} \end{pmatrix}$$

On applique alors la transformation unitaire  $U(\xi) = e^{-i\vec{\tau}\cdot\vec{\xi}/2v}$  à tous les champs. On a :

$$\phi' = U(\xi)\phi = \frac{1}{\sqrt{2}}(v+H)\chi, \quad \chi = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$L' = U(\xi)L$$

$$\vec{A}'_{\mu'} \cdot \frac{\vec{\tau}}{2} = U(\xi)\vec{A}_{\mu} \cdot \frac{\vec{\tau}}{2}U(\xi)^{-1} - \frac{i}{g}(\partial_{\mu}U(\xi))U^{\dagger}(\xi)$$

$$R' = R, \quad B'_{\mu} = B_{\mu}$$

Le lagrangien est invariant sous cette transformation et peut être réécrit ainsi :

$$L_D = \bar{L}'i\gamma^{\mu}(\partial_{\mu} - ig\frac{\vec{\tau}}{2} \cdot \vec{A}'_{\mu} + g'\frac{i}{2}B'_{\mu})L' + \bar{R}'i\gamma^{\mu}(\partial_{\mu} + ig'B'_{\mu})R'$$

$$L_{YM} = -\frac{1}{4}F_{\mu\nu}^i F^{i\mu\nu} - \frac{1}{4}B_{\mu\nu}^i B^{i\mu\nu}$$

$$L_{Higgs} = (D_{\mu}\phi)^{\dagger}(D_{\mu}\phi)' - V(\phi^{\dagger}\phi')$$

$$L_{Yukawa} = -G_e(\bar{L}'\phi'R' + \bar{R}'\phi^{\dagger}L') + h.c.$$

### Les bosons de jauge de l'interaction électrofaible

Dans le terme de Higgs, on a :

$$(D_{\mu}\phi) = (\partial_{\mu} - ig\frac{\vec{\tau}}{2} \cdot \vec{A}'_{\mu} - g'\frac{i}{2}B'_{\mu})\frac{1}{\sqrt{2}}(v+H)\chi$$

Le terme de masse pour les bosons de jauge de l'interaction électrofaible vaut alors :

$$L_{masse} = \frac{v^2}{2}\chi^{\dagger}(g\frac{\vec{\tau}}{2} \cdot \vec{A}'_{\mu} + \frac{g'}{2}B'_{\mu})(g\frac{\vec{\tau}}{2} \cdot \vec{A}'^{\mu} + \frac{g'}{2}B'^{\mu})\chi$$

$$L_{masse} = \frac{v^2}{8}(g^2\vec{A}'_{\mu}\vec{A}'^{\mu} + g'^2B'_{\mu}B'^{\mu} - 2gg'B'_{\mu}A'^{3\mu})$$

$$L_{masse} = \frac{v^2}{8}(g^2A'_{\mu}{}^1A'^{1\mu} + g^2A'_{\mu}{}^2A'^{2\mu} - (gA'_{\mu}{}^3 - g'B'_{\mu})^2)$$

On introduit les champs des bosons chargés  $W^+$  et  $W^-$  par le changement de variable :

$$W_{\mu}^{\pm} = \frac{A'_{\mu}{}^1 \mp iA'_{\mu}{}^2}{\sqrt{2}}$$

Les deux premiers termes de  $L_{masse}$  peuvent être réécrit sous la forme  $\frac{1}{4}g^2v^2W_{\mu}^+W_{\mu}^-$ . Les bosons  $W$  ont donc une masse de  $M_W = \frac{1}{2}gv$ . Le dernier terme s'écrit :

$$\frac{v^2}{8} \begin{pmatrix} A'_{\mu}{}^3 & B'_{\mu} \end{pmatrix} \begin{pmatrix} g^2 & -gg' \\ -gg' & g'^2 \end{pmatrix} \begin{pmatrix} A'^{3\mu} \\ B'^{\mu} \end{pmatrix}$$



Ce qui se diagonalise en :

$$\frac{v^2}{8}(Z_\mu \quad A_\mu) \begin{pmatrix} g^2 + g'^2 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} Z^\mu \\ A^\mu \end{pmatrix} = \frac{v^2}{8}(g^2 + g'^2)Z_\mu Z^\mu + 0 \cdot A_\mu A^\mu$$

Par la transformation orthogonale :

$$\begin{pmatrix} Z_\mu \\ A_\mu \end{pmatrix} = \begin{pmatrix} \cos(\theta_W) & -\sin(\theta_W) \\ \sin(\theta_W) & \cos(\theta_W) \end{pmatrix} \begin{pmatrix} A_\mu^3 \\ B_\mu \end{pmatrix}$$

Où  $\theta_W$  est appelé angle de mélange faible ou *angle de Weinberg*. La diagonalisation conduit à  $\tan(\theta_W) = \frac{g'}{g}$ , ainsi que  $\sin(\theta_W) = \frac{g'}{\sqrt{g^2+g'^2}}$  et  $\cos(\theta_W) = \frac{g}{\sqrt{g^2+g'^2}}$ . La masse du boson  $Z$  vaut alors :

$$M_Z = \frac{1}{2}v\sqrt{g^2 + g'^2} = \frac{M_W}{\cos(\theta_W)}$$

### La masse du boson de Higgs

Après brisure de symmétrie, le potentiel de Higgs peut être réécrit de la manière suivante :

$$V(\phi^\dagger \phi) = -\frac{\mu^2}{2}(v + H)^2 \chi^\dagger \chi + \frac{\lambda}{4}(v + H)^4 (\chi^\dagger \chi)^2$$

$$V(\phi^\dagger \phi) = -\frac{\mu^2 v^2}{4} + \frac{1}{2}(2\mu^2)H^2 + \lambda v H^3 + \frac{\lambda}{4}H^4$$

La masse du boson de Higgs peut donc être identifiée à  $M_H = \sqrt{2\mu^2}$ . La valeur de la masse n'est pas prédite par le modèle GWS, mais peut être restreinte à un certain domaine par des considérations théoriques (qui seront brièvement abordées section 2.3).

### La masse des fermions

Il nous reste à montrer que la masse des particules du modèle standard sont couplées avec la valeur dans le vide du boson de Higgs. C'est ce que nous allons faire en considérant le potentiel de Yukawa sur l'exemple de l'électron :

$$L_{Yukawa} = -G_e(\bar{L}' \phi' R' + \bar{R}' \phi'^{\dagger} L') + h.c.$$

$$L_{Yukawa} = -G_e(\bar{e}_L' \frac{1}{\sqrt{2}}(v + H)e_R' + \bar{e}_R' \frac{1}{\sqrt{2}}(v + H)e_L') + h.c.$$

$$L_{Yukawa} = -\frac{G_e v}{\sqrt{2}}\bar{e}' e' - \frac{G_e}{\sqrt{2}}H\bar{e}' e'$$

La masse de l'électron est alors  $m_e = \frac{G_e v}{\sqrt{2}}$ .

### 2.1.3 Le boson de Higgs au-delà du modèle standard

Depuis les années 1970 où les prédictions du modèle standard ont commencé à être comparées avec l'expérience, d'innombrables mesures ont prouvé sa pertinence pour une large gamme de prédictions. Toutefois, un certain nombre de problèmes sont apparus au fil du temps :

- Contrairement à ce que prévoit le modèle standard, les neutrinos ont une masse non nulle, comme l'a prouvé l'expérience SuperKamiokande en mettant en évidence l'oscillation des neutrinos.
- Bien que le modèle standard suggère la violation de la symétrie CP en chromodynamique quantique, aucune mesure ne l'a montré à ce jour (problème dit "CP fort").
- Le modèle standard ne nous dit rien à propos de la masse manquante de l'univers (problème de la matière noire), non plus que sur l'accélération de l'univers (problème de l'énergie noire).

- En tant que théorie quantique des champs, le formalisme du modèle standard inclut la relativité restreinte mais pas la relativité générale : il ne décrit pas l'interaction gravitationnelle.
- Alors que les contraintes expérimentales demandent au boson de Higgs d'avoir une masse à l'arbre de l'ordre de 100 GeV (échelle d'énergie du secteur électrofaible), les corrections à plusieurs boucles peuvent la porter jusqu'à la masse de Planck. La coexistence d'échelles d'énergie si différentes n'est pas naturelle (problème de hiérarchie).
- Le signe négatif devant l'interaction quadratique dans le potentiel du boson de Higgs est ajouté de manière ad-hoc : il n'y a pas de mécanisme dynamique permettant de le générer dans le modèle standard.

Nous allons brièvement passer en revue un certain nombre de modèles qui ont été proposés pour résoudre une partie de ces problèmes. Nous nous focaliserons sur les propriétés du boson de Higgs dans ces modèles.

### Modèle à deux doublets de Higgs

L'extension minimale du modèle standard consiste à introduire un doublet scalaire de Higgs supplémentaire [62] avec une valeur dans le vide différente du premier doublet. Le modèle était initialement conçu pour trouver une source à la violation de la symétrie CP. Selon les modèles, le premier doublet couple seulement aux quarks de type  $u$  et le second aux quarks de type  $d$  (type II [63]), le premier couple aux quarks de type  $u$  et  $d$  et le second non (type I [64]), ou bien les deux doublets peuvent coupler avec tous les types de fermions (type III [65]). Ce modèle prédit l'existence de 5 bosons de Higgs : 2 chargés ( $H^\pm$ ) et 3 neutres ( $A$  viole la symétrie CP,  $h$  et  $H$  non).

### La supersymétrie

L'idée de la supersymétrie consiste à adjoindre à chaque particule du modèle standard un partenaire supersymétrique avec un spin décalé de 1/2 (chaque fermion a pour superpartenaire un boson et vice-versa) [66]. La supersymétrie résout (partiellement) le problème de hiérarchie, propose un candidat pour la matière noire (le neutralino) et son formalisme permet d'incorporer la gravitation. La brisure de symétrie est effectuée de manière dynamique. Le modèle supersymétrique minimal [67] (MSSM) inclut deux doublets de Higgs et prédit l'existence de 5 bosons de Higgs. C'est un modèle à deux doublets de Higgs de Type II, où le boson  $h$  a les mêmes couplages que le boson de Higgs dans le modèle standard. A l'arbre,  $m_h \leq M_Z$  mais une fois les corrections radiatives prises en compte à une ou deux boucles, la limite théorique devient  $m_h \leq 135$  GeV [68], ce qui rend l'existence du boson de Higgs supersymétrique compatible avec les mesures expérimentales du LEP (voir paragraphe 2.3.1).

### Les modèles de "little Higgs"

Les modèles dits de "little Higgs" [69] postulent que la symétrie de jauge la plus fondamentale n'est pas  $SU(2) \times U(1)$  mais une symétrie d'ordre plus élevée qui contient  $SU(2) \times U(1)$  en tant que sous-groupe. A l'échelle d'énergie du secteur électrofaible, la symétrie fondamentale est brisée et on retrouve la symétrie du modèle standard. Dans ces modèles le boson de Higgs est un pseudo-boson de Goldstone qui possède une masse nulle à l'arbre. C'est seulement la prise en compte des corrections radiatives qui lui confère une masse. Ces modèles postulent parfois la présence de bosons de jauge supplémentaires  $Z'$  et  $W'$  d'une masse plus élevée que le  $Z$  et le  $W$ , par exemple dans les modèles "littlest Higgs" [70] et "simplest little Higgs" [71]. L'avantage de ces modèles est de permettre la protection de la masse du Higgs jusqu'à une échelle d'énergie de 10 TeV par annulation des divergences à une boucle (résolution partielle du problème de hiérarchie).

### Les dimensions supplémentaires

L'idée des modèles de dimensions supplémentaires consiste à ajouter à nos 4 dimensions usuelles d'espace-temps un certain nombre de dimensions d'espace, qui peuvent être compactifiées ou non. Dans le cas de dimensions compactifiées, des modes de Kaluza-Klein apparaissent, qui correspondent à de

nouvelles particules. Il existe trois types de modèles prédisant l'existence de bosons de Higgs avec des dimensions supplémentaires : les modèles dits “bulk Higgs”, “brane Higgs” et “jauge-Higgs”. Parmi les modèles “bulk Higgs”, on trouve les modèles Dimensions Supplémentaires Universelles (UED, voir par exemple [72]). D'une manière générale, le boson de Higgs est ici un champ scalaire en 5 dimensions. Dans les modèles de “brane Higgs”, le boson de Higgs est un champ en 4 dimensions localisé sur une brane ou à la limite d'un espace compact (voir par exemple [73]). Enfin, dans les modèles “jauge-Higgs” le boson de Higgs est médiateur d'une interaction de jauge [74], cinquième composante d'un champ en cinq dimensions. Il existe aussi un certain nombre de modèles sans boson de Higgs. L'idée est ici de déclencher la brisure spontanée de symétrie sans champ scalaire, et la solution consiste généralement à imposer des conditions aux limites bien choisies dans le cadre d'un modèle avec des dimensions supplémentaires. Toutefois, ces modèles ont beaucoup de difficulté à être rendus compatibles avec les mesures de précision électrofaibles (voir par exemple [75]).

## 2.2 Le boson de Higgs au LHC

### 2.2.1 L'interaction proton-proton

Au LHC, la collision de deux protons à une vitesse proche de celle de la lumière est principalement régie par les lois de la Chromodynamique Quantique (QCD). Or le proton est un objet complexe : on sait qu'il est constitué de particules massives (2 quarks up et 1 quark down), ainsi que de gluons, médiateurs de l'interaction forte qui maintiennent la cohésion du noyau. Les calculs de QCD sur réseau sont capables de rendre compte des propriétés de la matière hadronique au repos, mais l'énergie atteinte dans la collision proton-proton rend la tâche plus difficile en raison du plus grand nombre d'interactions possibles. Un formalisme a été développé pour rendre compte de l'interaction de ces objets complexes qui relèvent de la QCD non perturbative sans utiliser les outils de QCD sur réseau : il s'agit du modèle des partons.

#### Le modèle des partons

On doit l'idée d'un modèle des partons à Richard Feynman [76]. Le problème consiste à modéliser l'interaction entre hadrons de la façon la plus indépendante possible des constituants spécifiques des hadrons. Un même formalisme rendra compte des interactions entre quarks, gluons, etc. L'idée du modèle des partons est d'envisager le hadron comme étant de masse nulle et constitué de particules libres non interagissantes de masses nulles, qui portent chacune une fraction  $x\vec{p}$  de l'impulsion du hadron et une fraction  $xE$  de son énergie. Il s'agit d'une approximation qui peut être justifiée, puisque pour un collisionneur proton-proton, l'impulsion du proton est grande devant les masses mises en jeu dans le repère du laboratoire. Dans ce repère, la dilatation relativiste du temps rend les interactions fortes entre les quarks constituants du proton très lentes devant l'interaction entre les protons.

Si l'on note  $d\sigma$  la section efficace différentielle d'un mécanisme de production de particule (par exemple, un boson de Higgs) par interaction proton-proton,  $d\hat{\sigma}$  la section efficace différentielle de production du boson de Higgs par interaction entre les partons (calculée dans le cadre de la QCD perturbative),  $f_{a/A}$  (resp.  $f_{b/B}$ ) la probabilité de trouver le parton  $a$  (qui peut être un quark ou un gluon) dans le proton  $A$  (resp.  $b$  dans le proton  $B$ ), alors dans l'approximation des partons on peut écrire [77] :

$$d\sigma = \sum_{a,b} \int dx_A f_{a/A}(x_A, \mu) \int dx_B f_{b/B}(x_B, \mu) d\hat{\sigma}$$

Où  $\mu$  a la dimension d'une masse et est appelé échelle de factorisation (qui dépend du processus considéré et de l'ordre auquel il est calculé). Le *principe de factorisation* stipule que  $d\hat{\sigma}$  peut être calculé séparément de  $f(x, \mu)$ , et que la formule précédente est valable tant que la masse des protons reste petite devant l'impulsion transverse des partons, et est valable à n'importe quel ordre de la théorie perturbative de QCD.

## Les densités partoniques (pdf)

L'intérêt d'une telle formulation est de séparer le problème de l'interaction hadronique en deux : d'une part,  $d\hat{\sigma}$  ne dépend que du processus considéré, et il est possible de le calculer avec les outils de la QCD perturbative ; et d'autre part les densités partoniques  $f_{a/A}$  et  $f_{b/B}$  qui ne sont pas calculables a priori, mais qui peuvent être mesurées à partir des données pour un certain nombre de processus et réutilisées pour calculer d'autres processus. Les densités partoniques auront des valeurs différentes si elles sont relatives aux différentes saveurs de quarks ou aux gluons.

Pour évaluer les densités partoniques, on sélectionne un ensemble de processus dont les sections efficaces sont mesurées avec une grande précision, et dont les propriétés dépendent hautement des valeurs prises par les densités partoniques. Un ajustement numérique global du modèle aux données est ensuite effectué, et il donne la valeur des densités partoniques à une certaine échelle d'énergie initiale (arbitraire). Par la suite, les équations d'évolution de la QCD donnent la valeur des densités partoniques à n'importe quelle échelle d'énergie  $\mu$  :

$$\mu^2 \frac{\partial}{\partial \mu^2} f(\mu) = \frac{\alpha_S(\mu)}{2\pi} \int_x^1 f(\mu) P_{qq}^0(y) f(x/y, \mu) dy$$

Il s'agit de l'équation dite Dokshitzer-Gribov-Lipatov-Altarelli-Parisi [78], ou DGLAP, dans laquelle le noyau d'Altarelli-Parisi  $P_{qq}^0$  est la probabilité pour qu'un quark émette un gluon et voit son impulsion réduite d'un facteur  $y$ . En réalité, la formule précédente n'est valable qu'à l'arbre et il faut prendre en compte toutes les contributions du même ordre en  $\alpha_S$  (interaction quark/quark, anti-quark/anti-quark, quark/gluon, anti-quark/gluon et gluon/gluon).

Il existe plusieurs groupes de travail dont le but est de fournir un ensemble de valeurs numériques pour les densités partoniques, par exemple CTEQ [79] et MRS [80], pour ne citer que les plus connus. Dans ce qui suit, nous allons décrire brièvement la procédure suivie par le groupe CTEQ pour l'ajustement global.

La méthode suivie par le groupe CTEQ pour calculer leur dernière version des densités partoniques CTEQ6M [79] est la suivante. Certaines constantes fondamentales sont fixées dès le début de la procédure : la constante de couplage de QCD est prise à l'échelle d'énergie du boson  $Z^0$   $\alpha_S(M_Z) = 0.118$ , les quarks  $u, d, s$  sont considérés sans masse tandis que les quarks  $c$  et  $b$  ont pour masse  $m_c = 1.3$  GeV et  $m_b = 4.5$  GeV. Les éléments de matrice correspondant aux processus des données sont tous calculés au NLO. L'échelle d'énergie initiale a été choisie à  $Q_0 = 1.3$  GeV. La formule générique choisie pour modéliser les densités partoniques a l'expression suivante :

$$xf(x, Q_0) = A_0 x^{A_1} (1-x)^{A_2} e^{A_3 x} (1 + e^{A_4 x})^{A_5}$$

Où  $A_1, A_2, A_3, A_4, A_5$  sont des paramètres qui vont être déterminés par le résultat de l'ajustement. La flexibilité d'une telle paramétrisation est plus grande que pour les versions précédentes de CTEQ (et MRST), qui disposait d'un plus petit nombre de paramètres. Les densités partoniques disposent de paramètres indépendants pour les combinaisons  $u_v = u - \bar{u}$ ,  $d_v = d - \bar{d}$ ,  $g$  et  $\bar{u} + \bar{d}$ . De plus à  $Q_0$ , la condition initiale  $s = \bar{s} = 0.2(\bar{u} + \bar{d})$  est imposée. Enfin, le rapport  $\bar{d}/\bar{u}$  prend une expression particulière  $\bar{d}/\bar{u} = A_0 x^{A_1} (1-x)^{A_2} + (1 + A_3 x)(1-x)^{A_4}$ . Au total, il y a 20 paramètres libres utilisés pour l'ajustement à  $Q_0$ .

La particularité de CTEQ6M est d'inclure, pour la première fois, la corrélation des erreurs systématiques dans l'ajustement. L'ajustement global de CTEQ6M utilise pour une part les mêmes données que pour les versions précédentes (notamment les données issues d'expériences sur cibles fixes et diverses mesures de CDF), avec en plus des données des expériences H1, ZEUS, et surtout la mesure de la section efficace inclusive de production de jets par D0 dans plusieurs plages de rapidité. Les données inclusives sur les jets issues de D0 jouent un grand rôle pour  $0.01 < x < 0.5$  et  $50 < Q < 500$  GeV. La nouveauté par rapport aux précédents résultats (de CTEQ aussi bien que de MRS), est un spectre plus dur en ce qui concerne la densité partonique des gluons (voir fig. 2.2). Ce résultat est d'une grande importance pour le LHC : par rapport aux anciens pdf, CTEQ6M inclut dans son ajustement des données avec une plus

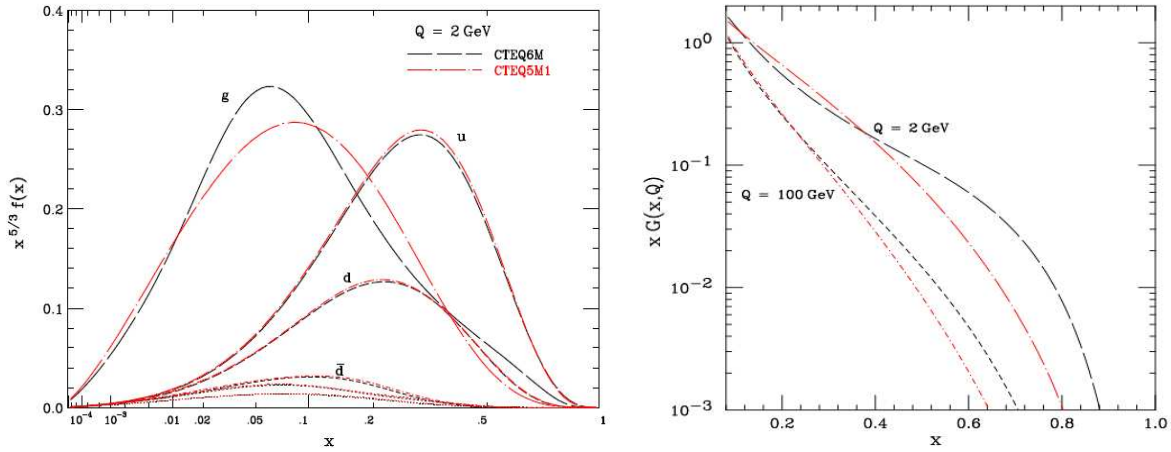


FIG. 2.2 – A gauche, comparaison des densités partoniques de CTEQ6M avec CTEQ5M1 pour  $Q = 2 \text{ GeV}$  (les distributions non labellisées en bas du graphique correspondent aux pdf de  $\bar{u}$  et  $s = \bar{s}$ ); l'abscisse est multipliée par un facteur  $x^{1/3}$  et l'ordonnée par  $x^{5/3}$ , de sorte que l'aire sous la courbe soit proportionnelle à la fraction de l'impulsion portée par le quark ou le gluon. A droite, comparaison des densités partoniques des gluons de CTEQ6M avec CTEQ5M1 pour  $Q = 2 \text{ GeV}$  et  $Q = 100 \text{ GeV}$ .

grande énergie que précédemment, et prévoit une hausse de la densité des gluons dans le proton (ce qui signifie, entre autre, une section efficace pour la fusion de gluons plus importante que pour les expériences précédentes). L'incertitude reste toutefois grande pour les  $x$  proches de 1 et les bas  $Q$ , car il n'y a pas de données pour de telles régions de l'espace de phase. Le groupe CTEQ estime l'incertitude due aux pdf sur la section efficace de production du boson de Higgs au LHC (produit majoritairement par fusion de gluon, voir section 2.2.2) comme étant de l'ordre de  $\pm 5\%$ .

### 2.2.2 Modes de production du boson de Higgs

Au régime d'énergie atteint par le LHC, les quatre modes dominants pour la production du boson de Higgs [81] (et qui contribuent à sa section efficace totale) sont la fusion de gluons, la fusion de bosons vecteurs, la production associée avec une paire de quarks et la production associée avec un boson vecteur (voir schéma 2.3). Les sections efficaces pour ces mécanismes de production sont représentées figure 2.4. Nous allons détailler tour-à-tour chacun de ces quatre mécanismes.

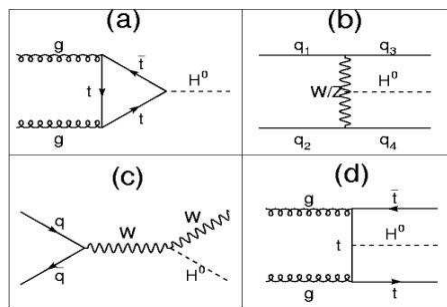


FIG. 2.3 – Diagrammes de production du boson de Higgs : fusion de gluons (a), fusion de bosons vecteurs (b), production associée avec un boson vecteur (c), et production associée avec une paire de quarks (d).

#### La fusion de gluons

En 1978, Georgi, Glashow et al. ont montré que la fusion de gluons est le mode de production prépondérant du boson de Higgs pour une collision proton-proton [82]. Les auteurs éliminent tout d'abord




FIG. 2.4 – Sections efficaces de production du boson de Higgs pour les principaux mécanismes de production au LHC, prédites avec les densités partoniques de CTEQ6M au NLO [79].

la production de boson de Higgs par l’annihilation d’une paire de quark/anti-quark avec un argument qualitatif. Le couplage des quarks légers au boson de Higgs est négligeable, et la probabilité de trouver un quark lourd dans le proton étant faible, il sera d’autant plus rare de trouver un quark lourd dans un proton et un anti-quark lourd dans l’autre. La contribution due à ce mécanisme sera donc négligeable devant d’autres mécanismes, comme la fusion de gluon. Les auteurs éliminent aussi le Higgs-strahlung et d’autres mécanismes pour le même genre de raison.

Tout d’abord, pour des raisons de conservation de l’hypercharge faible, la création d’un boson de Higgs par annihilation directe de 2 gluons est interdite dans le modèle standard. Le couplage du boson de Higgs à deux gluons fait intervenir une boucle de quarks virtuels [83] (aussi appelé diagramme triangulaire, ou encore paire virtuelle quark/anti-quark). Toutes les saveurs de quarks participent à la boucle, des quarks légers aux quarks les plus lourds. Dans la pratique, la contribution due au quark  $t$  (et dans une moindre mesure  $b$ ) est très grande devant les contributions des autres quarks. Elle fait aussi intervenir toutes les particules chargées et colorées couplées fortement au Higgs qui peuvent apparaître dans des théories au-delà du modèle standard.

Au LHC, la fusion de gluons a lieu lors d’une collision proton-proton. La section efficace de production de boson de Higgs peut être évaluée avec le modèle des partons [84]. A l’arbre, on peut montrer que dans l’approximation d’une largeur étroite, modélisée par une distribution Breit-Wigner (“narrow-width”) elle vaut [81] :

$$\sigma_{LO}(pp \rightarrow H) = \sigma_0^H \tau_H \int_{\tau}^1 \frac{dx}{x} g(x, \mu_F^2) g(\tau/x, \mu_F^2)$$

Avec  $\tau_H = M_H^2/s$ , où  $s$  est le carré de l’énergie invariante portée par le proton (moitié de l’énergie dans le centre de masse),  $M_H$  la masse du boson de Higgs,  $\mu_F$  l’échelle de factorisation de la densité de partons, et  $g$  la fonction de distribution des partons et  $x$  la fraction de l’impulsion du proton. La section efficace  $\sigma_0^H$  de production de boson de Higgs par fusion de gluon au premier ordre :

$$\sigma_0^H = \frac{G_\mu \alpha_s^2(\mu_R^2)}{288\sqrt{2}\pi} \left| \frac{3}{4} \sum_q A_{1/2}^H(\tau_Q) \right|$$

Où le facteur de forme  $A_{1/2}^H$  vaut :

$$A_{1/2}^H(\tau) = 2[\tau + (\tau - 1)f(\tau)]\tau^{-2}$$

Avec  $f(\tau) = \arcsin^2(\sqrt{\tau})$  si  $\tau \leq 1$ , et  $f(\tau) = -\frac{1}{4} \left[ \log \frac{1+\sqrt{1-\tau^{-1}}}{1-\sqrt{1-\tau^{-1}}} - i\pi \right]^2$  si  $\tau > 1$ . Dans les expressions

ci-dessus,  $\tau$  est défini par la relation  $\tau = \frac{M_H^2}{4m_q}$ . Le facteur de forme est défini de telle sorte que pour  $m_q \gg M_H$ , il tend vers  $4/3$ , et vers 0 quand  $m_q \rightarrow 0$ .

En choisissant pour masse du quark top  $m_t = 178$  GeV et pour masse du quark bottom  $m_b = 4.88$  GeV, ce résultat conduit à une section efficace de production qui diminue lorsque la masse du boson de Higgs augmente, avec une bosse autour du seuil  $m_H = 2m_t$  (voir fig. 2.4).

Les contributions dues aux ordres supérieurs peuvent être prises en compte pour une plus grande précision sur la prédiction de la section efficace. Les calculs actuels prennent généralement en compte tous les diagrammes jusqu'au 2<sup>e</sup> ordre (NNLO) [85, 86]. La section efficace de production via fusion de gluons au NLO augmente de 100% la section efficace LO, et de 20% supplémentaires au NNLO. Une approximation faite couramment, spécialement dans les calculs aux ordres supérieurs, consiste à prendre  $m_t \rightarrow \infty$  : elle simplifie les calculs (car alors on a  $\frac{4}{3}A_{1/2}^H \rightarrow 1$ ) et reste une bonne approximation de la section efficace à 10% près.

### La fusion de bosons vecteurs

Après la fusion de gluon, le second mécanisme le plus important au LHC est la production du boson de Higgs par fusion de bosons vecteurs [87]  $W^+$  et  $W^-$ , ou  $Z^0$ . Les bosons vecteurs de l'interaction électrofaible sont émis hors de leur couche de masse par les quarks initiaux, et fusionnent pour produire un boson de Higgs. Au LHC, la contribution due aux bosons  $W$  est 3 fois plus importante que celle due aux bosons  $Z^0$ . Pour des masses du boson de Higgs valant  $m_H \lesssim 500$  GeV, la section efficace de ce processus est supprimée d'un ordre de grandeur par rapport à la fusion de gluons, tandis que si  $m_H$  tend vers 1 TeV, elles sont du même ordre de grandeur. La contribution des diagrammes NLO pour ce processus est pratiquement constante (5 à 10%) sur toute la gamme de masse du boson de Higgs au LHC [81].

Ce canal a l'intérêt d'avoir une cinématique très particulière qui permet une rejection importante des bruits de fonds, notamment grâce aux deux notions de veto anti-jet central [88], et de marquage des jets émis vers l'avant ou l'arrière du détecteur. En effet les bosons vecteurs intermédiaires tendent à porter une petite fraction de l'énergie initiale des partons, c'est pourquoi le boson de Higgs est produit de manière centrale. La probabilité de trouver un jet dans la région centrale est donc faible. De plus, après émission des bosons vecteurs, les quarks finaux disposent d'une très grande énergie (de l'ordre du TeV) mais une impulsion transverse très faible, d'où une grande probabilité d'être dirigés selon l'axe  $z$ , conduisant lors de leur fragmentation/hadronisation à la production de jets vers l'avant et l'arrière du détecteur.

### La production associée avec un boson vecteur (Higgs-strahlung)

La production associée d'un boson de Higgs avec un boson vecteur [89]  $W^\pm$  ou  $Z^0$  (prépondérant au LEP) peut être vue comme la production d'un boson virtuel par le mécanisme Drell-Yan, qui se désintègre alors en un boson de Higgs et en un boson vecteur sur sa couche de masse. A l'arbre, le boson de Higgs et le boson vecteur final portent alors une impulsion transverse opposée (par simple conservation de l'impulsion). La probabilité d'obtenir un boson  $W^\pm$  en état final est environ 2 fois plus grande que celle d'obtenir un boson  $Z^0$ . De plus le rapport de branchement pour la désintégration  $BR(W^\pm \rightarrow l^\pm \nu) \simeq 20\%$  tandis que  $BR(Z^0 \rightarrow l^+ l^-) \simeq 6\%$  ( $l = e, \mu$ ), ce qui rend le canal  $W^\pm$  beaucoup plus intéressant. Les corrections NLO augmentent la section efficace LO d'environ 30%. Pour des basses masse du boson de Higgs, ce canal est supprimé d'environ un ordre de grandeur par rapport à la fusion de bosons vecteurs, et d'environ 2 ordres de grandeur pour les masses approchant du TeV.

### La production associée avec une paire quarks lourds

La production associée du boson de Higgs avec une paire de quarks lourds est le processus pour lequel le boson de Higgs est émis par un quark par Higgs-strahlung, avec pour partons initiaux une paire de quark/anti-quark. Lorsque l'énergie dans le centre de masse augmente la fusion de gluon devient

prépondérante, et au LHC le boson de Higgs est émis tant par une ligne externe de quark que par une ligne interne. Au Tevatron comme au LHC, la contribution  $pp \rightarrow b\bar{b}H$  est plus grande que la contribution  $pp \rightarrow t\bar{t}H$  pour des masses  $m_H < 300$  GeV ; toutefois ce canal souffre d'un bruit de fond QCD à 4 bottom en état final et la production associée avec une paire  $\bar{t}$  reste plus intéressante. Ce canal a une section efficace à peu près égale à celle de la production associée avec un boson vecteur.

### 2.2.3 Désintégration du boson de Higgs

On distingue généralement trois canaux principaux de désintégration du boson de Higgs au LHC : le canal  $H \rightarrow W^+W^-$ , le canal  $H \rightarrow ZZ^*$  et le canal  $H \rightarrow \gamma\gamma$ . Après une brève description du canal  $H \rightarrow WW$ , nous détaillerons les canaux  $H \rightarrow ZZ$  et  $H \rightarrow \gamma\gamma$ , qui ont plus particulièrement été étudiés pendant ce travail de thèse.




FIG. 2.5 – Rapports de branchement pour la désintégration du boson de Higgs au LHC, donnés par le programme HDECAY [90].

D'autres canaux possèdent un rapport de branchement plus élevé mais conduisent à de réels défis expérimentaux pour une découverte à cause de bruits de fond extrêmement importants. Ainsi  $H \rightarrow b\bar{b}$ , qui est le mode de désintégration dominant pour des masses du boson de Higgs  $m_H < 150$  GeV (avec un rapport de branchement d'environ 80-90% pour  $115 < m_H < 130$  GeV), mais qui risque d'être "noyé" dans le bruit de fond QCD et nécessite une grande efficacité pour le marquage des quarks bottom ainsi qu'une grande précision sur l'échelle d'énergie des jets (difficile au démarrage du LHC).

Le canal  $H \rightarrow \tau\tau$  est prépondérant après  $H \rightarrow b\bar{b}$  pour cette même plage de masse, est aussi étudié au LHC, avec un rapport de branchement d'environ 8% pour  $m_H < 135$  GeV. La difficulté réside ici dans le marquage des leptons  $\tau$ , qui peuvent se désintégrer de manière leptonique ( $\tau \rightarrow l^\pm\nu$ ) ou hadronique ( $\tau \rightarrow hadrons + \nu$ ), les neutrinos conduisant à de l'énergie manquante.

#### Le canal $H \rightarrow WW$

A partir d'une masse du boson de Higgs  $m_H > 130$  GeV, le rapport de branchement  $BR(H \rightarrow WW)$  devient supérieur à 30%, et à partir de  $m_H > 160$  GeV, il devient le mode de désintégration dominant du boson de Higgs. Pour  $m_H < 2M_W$ , un des deux bosons  $W$  est émis hors de sa couche de masse (ce qui diminue la section efficace dans cette plage de masse). Pour des masses du boson de Higgs supérieures, les bosons  $W$  ont de plus en plus tendance à être polarisés longitudinalement.

La largeur partielle de désintégration pour le canal  $H \rightarrow WW$  s'écrit [91] :

$$\Gamma(H \rightarrow WW) = \frac{G_\mu m_H^3}{16\sqrt{2}\pi} 2\sqrt{1-4x}(1-4x+12x^2)$$



Avec  $x = \frac{M_W}{m_H}$ . De ce fait, pour des larges masses du boson de Higgs, la largeur de désintégration  $H \rightarrow WW$  devient de plus en plus grande (elle croît en raison de  $m_H^3$ ) jusqu'à atteindre environ 300 GeV pour  $m_H = 1$  TeV, ce qui rend la résonance difficile à détecter.




FIG. 2.6 – Diagramme de Feynman pour la désintégration  $H \rightarrow WW \rightarrow 2l2\nu$ , ici représenté pour le mode de production via fusion de gluons.

Ce canal est en général recherché expérimentalement avec la signature  $2l + mET$  (2 leptons de signe opposés avec de l'énergie manquante), qui proviennent de la désintégration leptonique  $H \rightarrow W^+W^- \rightarrow l^+l^-\nu\bar{\nu}$  (voir schéma 2.6). Comme dit plus haut, la désintégration  $W \rightarrow l\nu$  ( $l = e, \mu$ ) possède un rapport de branchement de 20% environ et a l'avantage d'avoir des leptons dans l'état final (dont l'efficacité de reconstruction est généralement plus grande que pour les hadrons, ce qui est particulièrement vrai pour les muons grâce aux bonnes performances du système de détection des muons de CMS). Toutefois les neutrinos conduisent à une énergie manquante importante. Le bruit de fond principal irréductible est le processus  $WW$ , suivi des bruits de fonds réductibles  $t\bar{t} \rightarrow 2l2\nu$  et  $Z \rightarrow ll$ . Le canal  $H \rightarrow WW \rightarrow 2l2\nu$  est le canal "doré" pour la recherche du boson de Higgs d'une masse  $m_H \simeq 160 - 165$  GeV.

### Le canal $H \rightarrow ZZ$

Pour des masses du boson de Higgs  $m_H < 180$  GeV, un des deux  $Z$  est produit hors de sa couche de masse, ce qui diminue la section efficace, mais pour  $m_H > 180$  GeV (soit environ  $2M_Z$ ) où les deux  $Z$  sont sur leur couche de masse, le rapport de branchement  $BR(H \rightarrow WW)$  tend vers 2/3 lorsque  $m_H$  augmente, et  $BR(H \rightarrow ZZ)$  tend vers 1/3. Le même problème de largeur du pic de masse intervient pour le canal  $H \rightarrow ZZ$  :

$$\Gamma(H \rightarrow ZZ) = \frac{G_\mu m_H^3}{16\sqrt{2}\pi} \sqrt{1-4x}(1-4x+12x^2)$$

Avec  $x = \frac{M_Z}{m_H}$ . La largeur vaut environ 150 GeV quand la masse du boson de Higgs tend vers 1 TeV.

Le processus  $H \rightarrow ZZ$  est un canal très intéressant pour la recherche du boson de Higgs, en particulier lorsque les bosons  $Z$  se désintègrent de manière leptonique. Même si le rapport de branchement  $BR(Z \rightarrow l^+l^-)$  ( $l = e, \mu$ ) vaut seulement 6% environ, la désintégration  $H \rightarrow ZZ \rightarrow 4l$  avec  $l = e, \mu$  (voir schéma 2.7) offre l'avantage d'un état final purement leptonique, ce qui constitue une signature claire, les électrons étant détectés avec une bonne résolution par la combinaison des sous-détecteurs trajectographe/calorimètre électromagnétique et les muons dans le système de détection des muons.

Les bruits de fond principaux de cette analyse sont avant tout les processus  $ZZ^*$  (le plus important en fin d'analyse, produit par annihilation quark/anti-quark et par fusion de gluon),  $Zb\bar{b}$  et  $t\bar{t}$ . D'autres processus, notamment  $Z+jets$ ,  $W+jets$ ,  $b\bar{b}$  et QCD jets constituent aussi des bruits de fond pour ce canal.

L'analyse du canal  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ) offre l'avantage de présenter une résonance du boson de Higgs visible en fin d'analyse sur la distribution de masse invariante des quatre leptons (ce qui est plus délicat pour  $H \rightarrow WW$  en raison de l'énergie transverse manquante). Un des enjeux de l'analyse sera donc de reconstruire une largeur du boson de Higgs la plus fine possible. En particulier, les leptons dans l'état final peuvent émettre des photons par mécanisme de bremsstrahlung interne. La récupération des




FIG. 2.7 – Diagramme de Feynman pour la désintégration  $H \rightarrow ZZ \rightarrow 4l$ , ici représenté pour le mode de production via fusion de gluons.

photons de bremsstrahlung interne sera étudiée en détail plus loin (voir Chapitre 4) d'un point de vue expérimental, et conduit à une amélioration de la précision de la mesure de la masse du boson de Higgs ainsi qu'à une augmentation de la signification.

### Le canal $H \rightarrow \gamma\gamma$

Pour les basses masses du boson de Higgs ( $m_H < 150$  GeV), la désintégration  $H \rightarrow \gamma\gamma$  (voir schéma 2.8) a un très faible rapport de branchement :  $BR(H \rightarrow \gamma\gamma) < 0.3\%$ , maximum pour environ 130 GeV. Ce canal très fortement supprimé est pourtant un des canaux privilégiés pour la recherche du boson de Higgs dans l'expérience CMS. Le calorimètre électromagnétique de CMS a en effet été conçu pour la recherche du boson de Higgs dans ce canal. Dans cette plage de masse, la largeur du boson de Higgs est négligeable devant la résolution du calorimètre, qui doit donc être le plus précis possible pour ne pas manquer la résonance.




FIG. 2.8 – Diagramme de Feynman pour la désintégration  $H \rightarrow \gamma\gamma$ , ici représenté pour le mode de production via fusion de gluons.

Comme pour la production du boson de Higgs par fusion de gluons, la désintégration du boson de Higgs en deux photons ne peut pas être directe et est médiée par une boucle de particules chargées. En plus des quarks lourds qui apparaissent pour la fusion de gluons, la médiation par une boucle de bosons  $W^\pm$  est permise. Dans des modèles au-delà du modèle standard qui prédisent l'existence de particules très massives (chargées et/ou colorées) fortement couplées au boson de Higgs, l'étude du rapport de branchement du canal  $H \rightarrow \gamma\gamma$  pourrait permettre de prouver leur existence de manière indirecte puisqu'ils contribueraient de façon significative à la boucle (voir section suivante).

La largeur partielle de la désintégration  $H \rightarrow \gamma\gamma$  s'écrit à l'arbre [92] :

$$\Gamma(H \rightarrow \gamma\gamma) = \frac{G_\mu \alpha^2 m_H^3}{128\sqrt{2}\pi^3} \left| \sum_q N_C Q_q^2 A_{1/2}^H(\tau_q) + A_1^H(\tau_W) \right|^2$$

Où  $\alpha$  est la constante de couplage de l'électromagnétisme,  $N_C$  est le nombre de couleurs (3),  $Q_q$  la charge des quarks contribuant au processus. Avec les facteurs de forme  $A_{1/2}^H$  suivant pour les quarks (il s'agit de la même expression que pour la production du boson de Higgs par fusion de gluons) :

$$A_{1/2}^H(\tau) = 2[\tau + (\tau - 1)f(\tau)]\tau^{-2}$$

Et le facteur de forme  $A_1^H$  pour le boson  $W$  :

$$A_1^H(\tau) = -[2\tau^2 + 3\tau + 3(2\tau - 1)]f(\tau)\tau^{-2}$$

La fonction  $f(\tau)$  est aussi la même que pour la fusion de gluons :  $f(\tau) = \arcsin^2(\sqrt{\tau})$  si  $\tau \leq 1$ , et  $f(\tau) = -\frac{1}{4} \left[ \log \frac{1+\sqrt{1-\tau^{-1}}}{1-\sqrt{1-\tau^{-1}}} - i\pi \right]^2$  si  $\tau > 1$ . Les paramètres  $\tau_i = m_H^2/4M_i^2$  avec  $i = q, W$  dépendent des masses intervenant dans la boucle. Il est intéressant de noter que les contributions dues aux quarks et au boson  $W$  sont de signes opposés.

Aller plus loin que le calcul à l'arbre pour cette désintégration implique de prendre en compte des diagrammes qui seront seulement virtuels (si on omet le processus de production). En effet la conservation de la couleur interdit une désintégration du type  $H \rightarrow \gamma\gamma + g$  avec un gluon supplémentaire dans l'état final. Les diagrammes à prendre en compte au NLO seront donc les diagrammes d'échanges de gluons virtuels entre les lignes internes de la boucle de quarks, ainsi que les diagrammes avec deux boucles de quark/ $W$ . Toutefois la prise en compte de ces diagrammes ne change pas significativement le rapport de branchement (moins de 5% de différence).

Les principaux bruits de fond pour le canal  $H \rightarrow \gamma\gamma$  sont par ordre décroissant d'importance les processus de QCD multi-jet,  $\gamma$ +jets, et les processus  $\gamma\gamma+X$ . Le bruit de fond  $\gamma\gamma+X$  comporte une variété de processus différents qui seront détaillés plus loin (voir section 3.1). Il s'agit d'un bruit de fond dit irréductible puisqu'il y a production d'une paire de photons dans l'état final, avec une cinématique proche de celle des photons issus du boson de Higgs. Le fait que le signal soit résonnant aide toutefois à la discrimination car le bruit de fond irréductible se distribue sur une large plage de masse invariante (voir fig. 2.9). Une analyse utilisant un réseau de neurones permet aussi d'améliorer la discrimination (la cinématique des photons de  $\gamma\gamma+X$  est légèrement différente de celle des photons issus du bosons du Higgs).

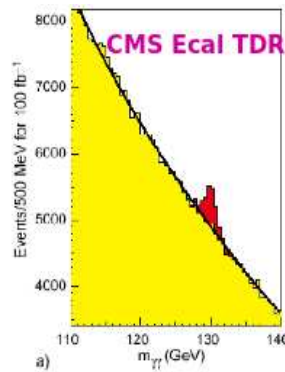


FIG. 2.9 – Masse invariante diphoton incluant bruit de fond (en jaune) et signal (en rouge), pour une masse du boson de Higgs de 130 GeV [16].

Les processus QCD multi-jets et  $\gamma$ +jets constituent aussi un bruit de fond important pour la recherche du boson de Higgs dans ce canal. D'une part lorsque les partons issus de l'interaction dure possèdent une grande impulsion transverse, ils vont avoir tendance à émettre des photons par radiation dans l'état initial ou final, pouvant conduire à une signature diphoton qui est celle recherchée. D'autre part à mesure que leur impulsion diminue, les jets formés par fragmentation/hadronisation vont avoir tendance à produire de nombreux  $\pi^0$ , qui se désintègrent très majoritairement en une paire de photons (avec une probabilité d'environ 98.8% [8] - voir figure 2.10 pour le diagramme de désintégration). Dans la plage d'impulsion transverse où on trouve les photons issus du boson de Higgs (i.e.  $p_T > 35$  GeV), il subsiste un grand nombre de ces photons provenant des  $\pi^0$ , dotés d'une large impulsion transverse et qui de fait ont été émis en une paire de photons très collimée. S'ils sont suffisamment proches l'un de l'autre, l'énergie déposée par ces photons dans le calorimètre électromagnétique sera reconstruite dans un seul super-cluster, ce qui les rend très similaires à des photons uniques. Il est possible de s'affranchir d'une partie des événements

QCD multi-jets et  $\gamma$ -jets par un critère d'isolation appliqué aux deux photons candidats, car les photons FSR ou issus de  $\pi^0$  sont généralement accompagnés d'une activité hadronique dans leur voisinage due aux jets desquels ils sont issus, tandis que les photons du bruit de fond irréductible et du signal ont plutôt tendance à être isolés.




FIG. 2.10 – Diagramme de Feynman pour la désintégration d'un  $\pi^0$  en une paire de photons.

### Le canal $H \rightarrow \gamma\gamma$ au-delà du modèle standard

Le processus de désintégration  $H \rightarrow \gamma\gamma$  fait intervenir une boucle de particules, qui dans le modèle standard peuvent être des quarks lourds (principalement le top) ou des  $W^\pm$ . Au-delà du modèle standard, toute particule qui se couple fortement au boson de Higgs peut intervenir dans la boucle : les stops et les gauginos (superpartenaires du top et des bosons de jauge) dans les modèles supersymétriques, bosons  $W$  lourds dans les modèles de “little Higgs” ou avec des dimensions supplémentaires par exemple. De plus, la fusion de gluon est le mécanisme majoritaire de production de boson de Higgs au LHC, et c'est aussi un mécanisme qui fait intervenir une boucle (de particules colorées seulement, cette fois-ci), et il sera lui aussi sensible aux particules de physique au-delà du modèle standard. En mesurant les sections efficaces de production du boson de Higgs par fusion de gluon ainsi que la largeur de désintégration du boson de Higgs en paire de photons, et en quantifiant la déviation par rapport à leur valeur attendue dans le modèle standard, une mise en évidence indirecte d'un mécanisme au-delà du modèle standard est possible [93]. Si le boson de Higgs est découvert, une telle étude sera complémentaire avec la recherche directe de ces particules.

On peut paramétriser les contributions aux largeurs de désintégration dues aux particules au-delà du modèle standard de la manière suivante :

$$\Gamma(H \rightarrow \gamma\gamma) = \frac{G_\mu \alpha^2 m_H^3}{128\sqrt{2}\pi^3} \left| A_W(\tau_W) + 3\left(\frac{2}{3}\right)^2 A_t(\tau_t)[1 + \kappa_{\gamma\gamma}] + \dots \right|^2$$

$$\Gamma(H \rightarrow gg) = \frac{G_\mu \alpha_s^2 m_H^3}{16\sqrt{2}\pi^3} \left| \frac{1}{2} A_t^H(\tau_t)[1 + \kappa_{gg}] + \dots \right|^2$$

Où  $A_W$  ( $A_t$ ) est la même fonction que  $A_1^H$  ( $A_{1/2}^H$ ) explicitée plus haut, mais appliquée seulement aux particules  $W$  (top). Les paramètres  $\kappa_{\gamma\gamma}$  et  $\kappa_{gg}$  dépendent des particules de nouvelle physique (NP) impliquées dans les boucles, qui dans l'approximation d'un boson de Higgs léger prennent les expressions suivantes :

$$\kappa_{\gamma\gamma} = \sum_{NP} \frac{3}{4} N_{c,NP} Q_{NP}^2 \frac{\partial m_{NP}}{\partial v} \frac{v}{m_{NP}} \frac{A_{NP}}{A_t}$$

$$\kappa_{gg} = \sum_{NP} 2C(r_{NP}) \frac{v}{m_{NP}} \frac{\partial m_{NP}}{\partial v} \frac{A_{NP}}{A_t}$$

Où le rapport  $\frac{A_{NP}}{A_t}$  vaut simplement 1 pour les fermions,  $-\frac{21}{4}$  pour les vecteurs et  $\frac{1}{4}$  pour les scalaires.  $v$  est la valeur du champ de Higgs dans le vide,  $Q_{NP}^2$  est la charge de la particule NP,  $N_{c,NP}$  est son nombre d'états de couleur et  $C(r_{NP})$  le facteur de couleur de  $SU(3)$ .

Dans le modèle standard,  $\kappa_{\gamma\gamma} = \kappa_{gg} = 0$ . Toute déviation des mesures des largeurs de désintégration par rapport au modèle standard peut être évaluée en terme de  $\kappa_{\gamma\gamma}$  et  $\kappa_{gg}$ . Il est dès lors intéressant de

tracer le graphe en deux dimensions  $\kappa_{\gamma\gamma}$  en fonction de  $\kappa_{gg}$ , et de répertorier toutes les valeurs que peuvent prendre ces deux paramètres pour une large gamme de modèles (voir fig.2.11). Les modèles représentés sur le graphe sont les suivants (tous les détails peuvent être trouvés dans la ref.[93]) :

- ◆ : quatrième génération de fermions.
- ♣ : supersymétrie dans la “golden” région.
- ▲ : “simplest little Higgs”.
- \* : “littlest Higgs”.
- : modèle d’octet de couleur.
- ▶ : modèle standard de Lee-Wick.
- ⊗ : dimensions supplémentaires universelles (UED).
- ★ : unification jauge-Higgs dans un espace plat.
- : Higgs composite minimal (unification jauge-Higgs dans un espace courbé).
- ▼ : modèle “brane-Higgs” dans un espace plat.
- ♠ : modèle “brane-Higgs” dans un espace courbé.

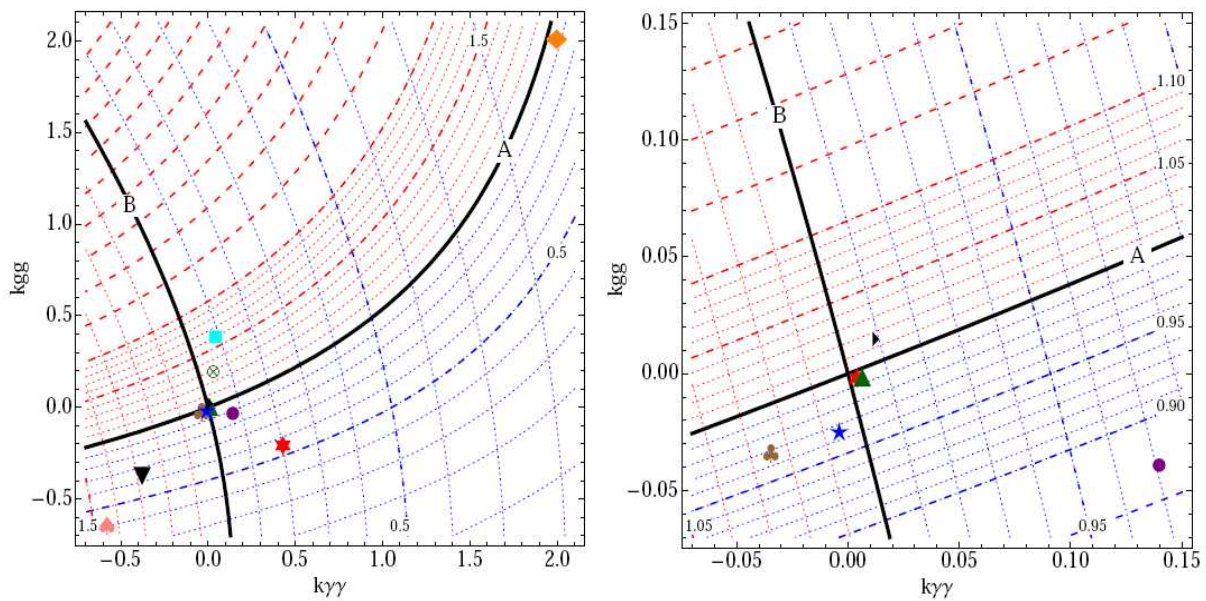


FIG. 2.11 –  $\kappa_{\gamma\gamma}$  et  $\kappa_{gg}$  au LHC pour un boson de Higgs de masse  $m_H = 120$  GeV. Les deux lignes continues correspondent aux valeurs dans le modèle standard pour le canal inclusif  $H \rightarrow \gamma\gamma$  (A) et pour le canal de production par fusion de bosons vecteurs (B). La figure de droite est un agrandissement mettant en évidence les valeurs proches du modèle standard.

De nombreux modèles présentent des déviations très petites par rapport au modèle standard (moins de 5% en terme de  $\kappa_{\gamma\gamma}$  ou  $\kappa_{gg}$ ) qui risquent d’être très difficiles à mettre en évidence au LHC, où la sensibilité sur la mesure du rapport de branchement  $H \rightarrow \gamma\gamma$  est de 10% avec une luminosité intégrée de  $10 \text{ fb}^{-1}$  [88]. Le graphe montre aussi des déviations plus importantes, en particulier pour les modèles de quatrième génération (◆), “brane-Higgs” dans un espace plat (▼) et courbé (♠), littlest Higgs (\*) et modèle d’octet de couleur (■). La plupart des modèles peuplent plutôt la région  $\kappa_{\gamma\gamma} < \kappa_{gg}$  et tendent à prédire une réduction du signal inclusif : à l’inverse, un excès inattendu pourrait être le signe d’une nouvelle physique qui n’est prévue par aucun modèle à ce jour. Dans tous les cas, si le boson de Higgs est découvert au LHC, il faudra attendre la construction d’un collisionneur linéaire pour atteindre la précision nécessaire à la discrimination entre les différents modèles.

## 2.3 La recherche du boson de Higgs : état de l'art et perspectives

Bien que les recherches du boson de Higgs aient commencé dans les années 1970, aucun signal n'a été observé à ce jour et la masse du boson de Higgs, s'il existe, reste encore inconnue. Il existe des limites théoriques à la masse du boson de Higgs, dites d'unitarité, de trivialité et de stabilité du vide. Les contraintes d'unitarité pour les diagrammes de diffusion des bosons  $Z$  et  $W$  imposent une limite supérieure à la masse du boson de Higgs de l'ordre de  $m_H \lesssim 710$  GeV [94, 95]. Les contraintes de trivialité proviennent des diagrammes d'auto-couplage du boson de Higgs pris dans la limite d'une théorie non-interagissante (triviale) et permettent de poser la limite  $m_H \lesssim 200$  GeV, jusqu'à  $m_H \lesssim 700$  GeV suivant l'échelle d'énergie choisie pour l'évaluer [96]. Enfin les contraintes de stabilité du vide [97] utilisent l'argument suivant lequel le potentiel de Higgs doit posséder un minimum absolu et préfèrent la plage de masse  $m_H \gtrsim 70$  GeV (ici encore la limite dépend de l'échelle d'énergie choisie). Ces prédictions varient beaucoup en fonction des diagrammes de corrections pris en compte et de l'échelle d'énergie à laquelle le modèle standard est considéré comme valide.

Expérimentalement, il est possible de délimiter des zones où le boson de Higgs pourrait être observé, par des tests statistiques mettant en perspective les propriétés cinématiques du signal attendu et du bruit de fond mesuré. Ces tests conduisent à l'exclusion de certains domaines de masse, dont les mesures actuelles proviennent du LEP et du Tevatron. Ces limites d'exclusion peuvent être issues de recherche directe, sans autre contrainte que les spectres cinématiques du boson de Higgs dans le modèle standard, ou bien être issues de recherches indirectes, qui sont contraintes par les mesures d'autres processus reliés au boson de Higgs par le modèle choisi. Après une description des limites d'exclusion du boson de Higgs, nous nous attacherons à expliciter les plans concernant la recherche du boson de Higgs dans CMS.

### 2.3.1 Limites d'exclusion du boson de Higgs : LEP et Tevatron

Le LEP était le collisionneur électron/positon précédemment situé sur le site où est aujourd'hui LHC. L'exploitation du LEP a été arrêtée en 2000. Les quatre collaborations du LEP (ALEPH, DELPHI, L3 et OPAL) ont collecté une luminosité intégrée de  $2465 \text{ pb}^{-1}$  pour une énergie dans le centre de masse de 189 GeV à 209 GeV. Le Tevatron est un collisionneur proton/anti-proton encore en activité aujourd'hui, et dont les collaborations CDF et D0 ont collecté respectivement une luminosité intégrée de  $5.9 \text{ fb}^{-1}$  et  $6.7 \text{ fb}^{-1}$  pour une énergie dans le centre de masse de 1.96 TeV depuis le début du Run II. Les données du LEP ont posé une limite inférieure sur la masse du boson de Higgs de  $m_H > 114.4$  GeV à 95% de niveau de confiance [98] par recherche directe, tandis que la sensibilité des expériences du Tevatron conduit à exclure par recherche directe le boson de Higgs dans une plage  $158 < m_H < 175$  GeV à 95% de niveau de confiance [99]. De plus, si on ajoute aux mesures de la recherche directe au LEP la recherche indirecte du boson de Higgs combinant les mesures du LEP et du Tevatron, une limite maximale sur la masse du boson de Higgs est obtenue de  $m_H < 185$  GeV à 95% de niveau de confiance [100].

#### Limites d'exclusion directe au LEP

Au LEP, le canal principal de production du boson de Higgs est la production associée avec un boson  $Z$  ( $e^+e^- \rightarrow HZ$ ), et le principal canal de désintégration est  $H \rightarrow b\bar{b}$ . Comme les signatures multi-jets sont plus aisées à détecter pour les collisionneurs leptoniques que hadroniques (où le bruit de fond QCD est important), les recherches du boson de Higgs au LEP ont été effectuées dans les canaux de désintégration ( $H \rightarrow b\bar{b}q\bar{q}$ , ( $H \rightarrow b\bar{b})\ell^+\ell^-$  ( $\ell = e, \mu, \tau$ ), ( $H \rightarrow b\bar{b})\nu\bar{\nu}$  et ( $H \rightarrow \tau^+\tau^-)q\bar{q}$ ). Alors que l'arrêt d'exploitation du LEP était prévu pour septembre 2000, la collaboration ALEPH a montré un excès d'évènement (principalement dans le canal 4-jets) suggérant la production d'un boson de Higgs ayant une masse proche de 115 GeV. L'arrêt a été repoussé d'un mois, temps mis à profit pour l'accumulation de données à des énergies dans le centre de masse allant jusqu'à 209 GeV.

Le graphique 2.12a montre les valeurs du test statistique  $-2\ln(Q)$  en fonction de la masse du boson

de Higgs dans les données, pour des événements simulés dans l'hypothèse où il n'y a pas de signal, et dans l'hypothèse où il y a bruit de fond et signal. Il s'agit d'un test statistique relevant d'une approche fréquentiste modifiée.  $Q$  est le rapport de la vraisemblance pour lequel l'hypothèse d'un bruit de fond plus signal est vérifiée, divisé par la vraisemblance pour l'hypothèse d'un bruit de fond seul. Plus  $-2\ln(Q)$  est négatif dans les données, plus un signal a de probabilité d'avoir été observé. Les données du LEP tendent à préférer un boson de Higgs ayant une masse autour de 115 GeV. Il est possible de calculer un niveau de confiance  $CL_s = \frac{CL_{s+b}}{CL_b}$  pour l'hypothèse où il y a signal dans les données.  $1 - CL_b$  est la probabilité, dans l'hypothèse bruit de fond seul, d'observer un taux d'évènement qui serait celui qu'il y aurait en présence de signal et bruit de fond.  $CL_s$  est à l'inverse la probabilité pour observer dans l'hypothèse signal plus bruit de fond, un taux d'évènement qui serait celui d'un bruit de fond seul. Une figure de mérite usuelle pour exclure une plage de masse est alors  $CL_s < 0.05$  (on parle alors d'exclusion à 95% de niveau de confiance). Comme on peut le voir sur la figure 2.12b, la limite inférieure sur la masse du boson de Higgs est de  $m_H > 114.4$  GeV à 95% de niveau de confiance [98].




FIG. 2.12 – Résultats finals du LEP [98] pour la recherche directe du boson de Higgs : (a) Test statistique  $-2\ln(Q)$  en fonction de la masse du boson de Higgs dans les données, pour des événements simulés dans l'hypothèse où il n'y a pas de signal, et dans l'hypothèse où il y a bruit de fonds et signal ; (b) Niveau de confiance  $CL_s$  pour l'hypothèse bruit de fond et signal.

### Limites d'exclusion directe au Tevatron

Les expériences CDF et D0 ont accumulé suffisamment de données depuis Mars 2009 [101] pour commencer à poser des limites d'exclusion sur la masse du boson de Higgs. Ces limites sont appelées à évoluer puisque le Tevatron continue de prendre des données, et les dernières limites datent de Juillet 2010 [99] (résultats présentés à la conférence ICHEP). Au Tevatron, le principal mode de production du boson de Higgs est la production associée avec un boson vecteur, mais les recherches ont aussi été étendues à la production par fusion de gluons et par fusion de bosons vecteurs. Les canaux de désintégration étudiés sont  $H \rightarrow b\bar{b}$ ,  $H \rightarrow W^+W^-$ ,  $H \rightarrow \tau^+\tau^-$  et  $H \rightarrow \gamma\gamma$ . Au total, les recherches ont été séparées en 129 canaux de désintégration exclusifs (56 pour CDF et 73 pour D0). Les sections efficaces de production du boson de Higgs par fusion de gluons ont été calculées à la précision NNLL et à l'ordre NNLO pour la QCD, et incluent les corrections électro-faibles à deux boucles.

Les données analysées montrent un excès d'évènements par rapport au taux attendu pour les hauts

rapports  $s/b$  (nombre d'évènement de signal divisé par le nombre d'évènements de bruit de fond) dans les analyses recherchant un boson de Higgs de masse  $m_H = 115$  GeV, et un déficit pour les hauts  $s/b$  dans les analyses recherchant un boson de Higgs de  $m_H = 165$  GeV. Deux approches statistiques ont été utilisées pour la combinaison des résultats : la méthode bayésienne (qui demande d'injecter une hypothèse subjective dans le calcul) et la méthode fréquentiste modifiée (considéré comme plus objective). Le graphique 2.13a montre les sections efficaces attendues et observées d'exclusion du boson de Higgs à 95% de niveau de confiance (calculé dans l'approche bayésienne), divisé par la section efficace dans le modèle standard, en fonction de la masse du boson de Higgs. Le boson de Higgs dans le modèle standard est exclu à 95% de niveau de confiance dans la plage de masse  $158 < m_H < 175$  GeV [99], le rapport observé des sections efficaces passant en-dessous de 1 dans cette zone. Ceci peut aussi être compris par la lecture du graphique 2.13b qui représente le niveau de confiance  $1 - CL_s$  calculé dans l'approche fréquentiste, avec une plage d'exclusion similaire à celle de l'approche bayésienne (qui a été choisie pour les limites officielles). La sensibilité de l'exclusion dans cette plage de masse est principalement due aux résultats obtenus pour le canal de désintégration  $H \rightarrow W^+W^-$ , pour lequel une analyse séparée donne une limite d'exclusion à 95% de niveau de confiance dans la plage de masse  $162 < m_H < 166$  GeV [102].

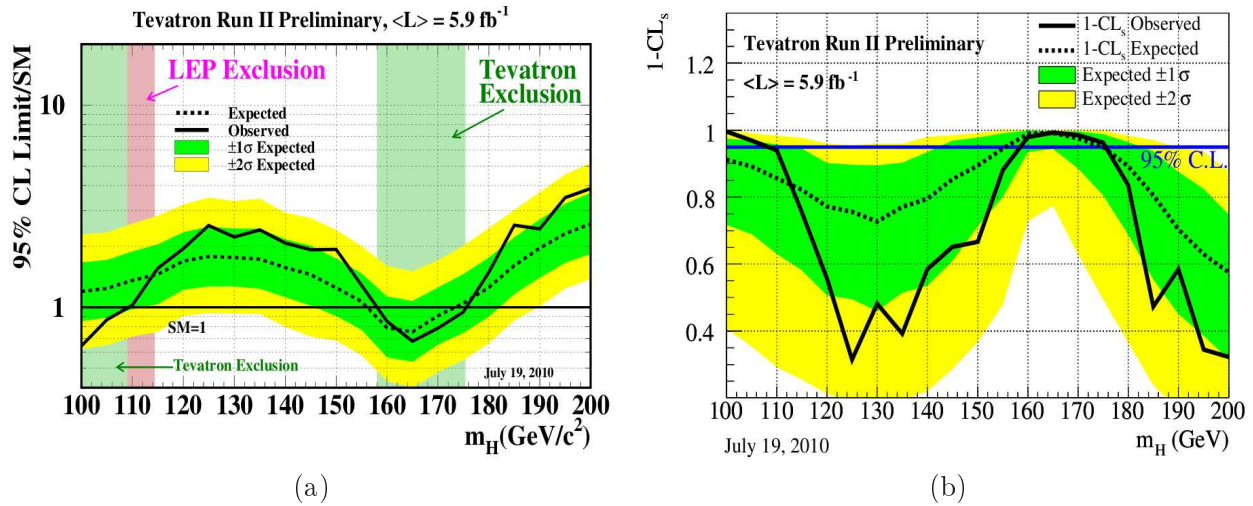


FIG. 2.13 – Résultats de Juillet 2010 du Tevatron [99] pour la recherche directe du boson de Higgs : (a) Sections efficaces attendues et observées d'exclusion du boson de Higgs à 95% de niveau de confiance (calculé dans l'approche bayésienne), divisé par la section efficace dans le modèle standard, en fonction de la masse du boson de Higgs ; (b) Niveau de confiance  $1 - CL_s$  calculé dans l'approche fréquentiste en fonction de la masse du boson de Higgs.

### Limites d'exclusion indirecte au LEP et au Tevatron

Les mesures de précision sur la masse des bosons  $W^\pm$  et  $Z^0$  et sur la masse du quark top peuvent permettre de contraindre la masse du boson de Higgs dans le modèle standard. En effet, les corrections aux ordres supérieurs pour les processus impliquant la production de bosons vecteurs font intervenir des boucles de quark top et de boson de Higgs. En ajustant les prédictions théoriques avec les données, il est possible d'obtenir une contrainte sur la masse du boson de Higgs. Les meilleures contraintes obtenues utilisent toutes les données concernant le pôle du boson  $Z^0$  provenant du LEP (masse, largeur de désintégration, section efficace de désintégration hadronique et leptonique), la masse du  $W$  et sa largeur de désintégration combinant les mesures du LEP et du Tevatron, ainsi que la masse du quark top mesurée au Tevatron.

La figure 2.14 montre le  $\chi^2$  de l'ajustement en fonction de la masse du boson de Higgs par recherche indirecte, qui est contrainte à  $m_H = 89^{+35}_{-26}$  GeV (les mesures dépendent logarithmiquement de la masse du boson de Higgs, ce qui explique que les incertitudes soient si asymétriques). La limite haute d'exclusion






FIG. 2.14 –  $\Delta\chi^2 = \chi^2 - \chi_{min}^2$  de l’ajustement en fonction de la masse du boson de Higgs, pour la recherche indirecte utilisant les mesures du LEP [100].

à 95% de niveau de confiance est de  $m_H < 158$  GeV. Si de plus la limite basse du LEP est incluse dans l’ajustement, le résultat obtenu est  $m_H < 185$  GeV à 95% de niveau de confiance.

### 2.3.2 Prospectives pour la recherche du boson de Higgs standard au LHC

Les recherches du boson de Higgs au LHC tel que le prédit le modèle standard sont effectuées dans la plage de masse permise par le LEP :  $m_H > 114.4$  GeV. Dans un premier temps, les perspectives pour la recherche exclusive du boson de Higgs dans les canaux  $H \rightarrow ZZ^* \rightarrow 4l$  et  $H \rightarrow \gamma\gamma$  seront présentées, pour les expériences CMS et ATLAS, avec une énergie dans le centre de masse de 14 TeV. Les potentiels de découvertes des autres canaux seront ensuite évoqués. Enfin, les perspectives pour  $1 fb^{-1}$  de luminosité accumulée dans CMS avec une énergie de 7 TeV dans le centre de masse seront présentés.

#### Recherche du boson de Higgs dans le canal $H \rightarrow ZZ^* \rightarrow 4l$ à $\sqrt{s} = 14$ TeV

L’analyse du canal  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ) dans ATLAS [103] et CMS [88] est effectuée de manière inclusive (elle ne dépend pas du mode de production du boson de Higgs), pour une plage de masse comprise entre 115 GeV et 600 GeV (au-delà il devient difficile d’observer une résonance puisque la largeur de désintégration augmente très vite). L’analyse est divisée en trois canaux  $4e, 4\mu, 2e2\mu$  dans l’idée d’utiliser les spécificités des saveurs des leptons pour optimiser l’analyse. Les ingrédients de l’analyse sont les mêmes quel que soit le canal : coupure sur l’impulsion transverse des leptons, identification et isolation des leptons, choix du candidat Higgs formé de 4 leptons, coupure sur le paramètre d’impact, coupure sur la masse invariante du  $Z$  et du  $Z^*$  reconstruits. L’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  de CMS sera décrite plus en détail section 4.2.

La signification attendue pour une luminosité intégrée de  $30 fb^{-1}$  avec une énergie dans le centre de masse de 14 TeV est représentée figure 2.15. ATLAS et CMS ont approximativement la même sensibilité sur la recherche du boson de Higgs dans le canal  $H \rightarrow ZZ^* \rightarrow 2e2\mu$ , avec une signification maximale autour de  $m_H = 190$  GeV, et une signification minimale pour les basses masses  $m_H < 120$  GeV (la sensibilité suit approximativement l’évolution de la section efficace de production du signal pour des masses allant jusqu’à 300 GeV ; au-delà le pic de masse du signal devient trop large, la fenêtre de masse choisie pour

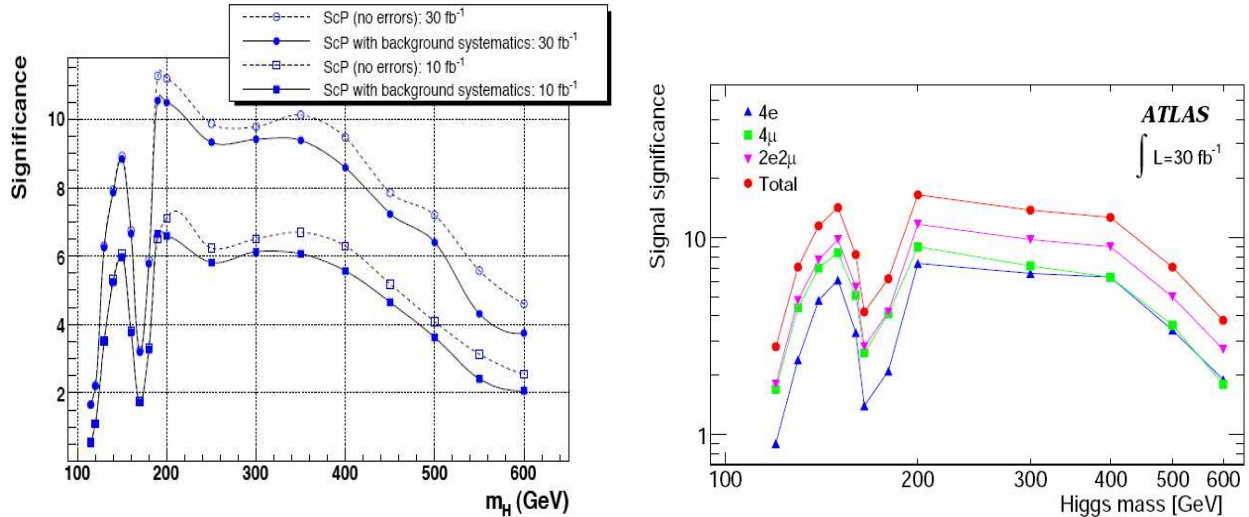


FIG. 2.15 – Significance attendue avec une énergie dans le centre de masse de 14 TeV pour une luminosité intégrée de 30  $fb^{-1}$  pour ATLAS (à droite) dans les canaux  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ), et de 10 et 30  $fb^{-1}$  pour CMS (à gauche), dans le canal  $H \rightarrow ZZ^* \rightarrow 2e2\mu$ .

calculer la signification s'élargit, et donc le rapport signal sur bruit diminue). A 30  $fb^{-1}$ , les expériences ATLAS et CMS auront découvert séparément le boson de Higgs dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$  s'il existe dans les plages  $140 < m_H < 160$  GeV et  $180 < m_H < 450$  GeV.

### Recherche du boson de Higgs dans le canal $H \rightarrow \gamma\gamma$ à $\sqrt{s} = 14$ TeV

Pour le TDR, deux analyses inclusives  $H \rightarrow \gamma\gamma$  ont été effectuées dans CMS avec une énergie dans le centre de masse de 14 TeV. La première est basée sur des coupures séquentielles (acceptance du détecteur, impulsion transverse des deux photons candidats, isolation des photons). La seconde, dite optimisée, utilise plusieurs réseaux de neurones pour réduire les bruits de fonds QCD jets et  $\gamma$ +jets (réseau de neurone basé sur l'isolation) et  $\gamma\gamma$ +X (utilisant la cinématique des événements de signal). La sensibilité des expériences CMS et ATLAS est présentée sur la figure 2.16. Les analyses d'ATLAS sont basées sur une évaluation de la signification dans l'approche d'un rapport de vraisemblance multi-variables, dans le cas de production inclusive du boson de Higgs, ou dans les canaux exclusifs qui sont ensuite combinés (canaux  $H$ ,  $H$  + jet,  $H$  + 2 jets, et production associée séparés). CMS dispose d'une analyse inclusive [104] et d'analyses exclusives pour les canaux de production associée [105, 106].

Bien que la luminosité intégrée soit différente pour ATLAS et CMS sur la figure 2.16, les résultats sont compatibles. Une signification de  $4\sigma$  peut être atteinte dès 10  $fb^{-1}$  et une découverte est possible pour un boson de Higgs de masse inférieure à 145 GeV avec 30  $fb^{-1}$ .

### Potentiels de découverte dans les autres canaux à $\sqrt{s} = 14$ TeV

La figure 2.17 compare la luminosité nécessaire à une découverte du boson de Higgs pour différentes masses dans l'expérience CMS pour les canaux  $H \rightarrow \gamma\gamma$ ,  $H \rightarrow ZZ^* \rightarrow 4l$  et  $H \rightarrow WW \rightarrow 2l2\nu$  ( $l = e, \mu$ ). Une luminosité de 6-8  $fb^{-1}$  est nécessaire pour une découverte d'un boson de Higgs de masse 120 GeV dans le canal  $H \rightarrow \gamma\gamma$ . Le canal  $H \rightarrow WW \rightarrow 2l2\nu$  a le plus grand potentiel pour une découverte précoce d'un boson de Higgs de 165 GeV : moins de 1  $fb^{-1}$  est nécessaire dans ce canal à 14 TeV. Pour des masses entre 130 et 160 GeV, ainsi qu'au-delà de 200 GeV c'est dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$  qu'on est le plus susceptible de découvrir en premier le boson de Higgs.




FIG. 2.16 – Significane pour l’observation du boson de Higgs avec une énergie dans le centre de masse de 14 TeV pour une luminosité intégrée de 10  $fb^{-1}$  pour ATLAS (à droite), et 30  $fb^{-1}$  pour CMS (à gauche), dans le canal  $H \rightarrow \gamma\gamma$ .




FIG. 2.17 – Luminosité intégrée nécessaire pour une découverte du boson de Higgs dans différents canaux en fonction de la masse du boson de Higgs dans l’expérience CMS, pour une énergie dans le centre de masse de 14 TeV.

### Limites d’exclusion à $\sqrt{s} = 7$ TeV et 1 $fb^{-1}$ dans CMS

Au bout d’environ un an de fonctionnement du LHC avec une énergie de 7 TeV dans le centre de masse, une luminosité intégrée d’1  $fb^{-1}$  est attendue. Les perspectives présentées ci-dessous ont été obtenues par une projection à 7 TeV [107] des résultats attendus à 14 TeV décrits dans les paragraphes précédent. Le nombre d’évènements de signal et bruit de fond attendus à 7 TeV sont obtenus en multipliant le nombre attendu à 14 TeV par le rapport des sections efficaces  $\frac{\sigma_{7TeV}}{\sigma_{14TeV}}$ . Les améliorations des algorithmes de reconstruction n’ont pas été pris en compte. Les erreurs systématiques ont été évaluées de manière conservatrice et les erreurs statistiques ré-évalués à partir du nouveau nombre d’évènements attendus. Avec 1  $fb^{-1}$  de luminosité avec une énergie de 7 TeV dans le centre de masse, la découverte d’un boson de Higgs de masse 160 GeV dans le canal  $H \rightarrow WW \rightarrow 2l2\nu$  est possible. La zone d’exclusion à 95% de niveau de confiance attendue dans ce canal est  $150 < m_H < 185$  GeV.

La sensibilité attendue dans les canaux  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ) et  $H \rightarrow \gamma\gamma$  est montrée figure 2.18. La sensibilité est moins grande pour ces canaux que pour le canal  $H \rightarrow WW$  et aucune limite d'exclusion à 95% de niveau de confiance ne peut être posée avec une luminosité de  $1 \text{ fb}^{-1}$ . Il serait possible de commencer à exclure des plages de masse si le boson de Higgs avait une section efficace 4 fois plus grande que celle prédite par le modèle standard (pour un boson de Higgs de 120-130 GeV dans le canal  $H \rightarrow \gamma\gamma$ ) et  $\sim 2$  fois la section efficace du modèle standard (pour un boson de Higgs de 190 GeV dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$ ). La combinaison statistique des canaux  $H \rightarrow \gamma\gamma$ ,  $H \rightarrow ZZ^* \rightarrow 4l$  et  $H \rightarrow WW \rightarrow 2l2\nu$  donne une zone d'exclusion à 95% de niveau de confiance dans la plage  $145 < m_H < 190$  GeV (voir figure 2.19).




FIG. 2.18 – Rapport de la section efficace nécessaire pour exclure le boson de Higgs à 95% de niveau de confiance sur la section efficace dans le modèle standard, en fonction de la masse du boson de Higgs pour le canal  $H \rightarrow ZZ^* \rightarrow 4l$  (à gauche) et  $H \rightarrow \gamma\gamma$  (à droite), pour une luminosité intégrée de  $1 \text{ fb}^{-1}$  et une énergie dans le centre de masse de 7 TeV dans CMS [107].

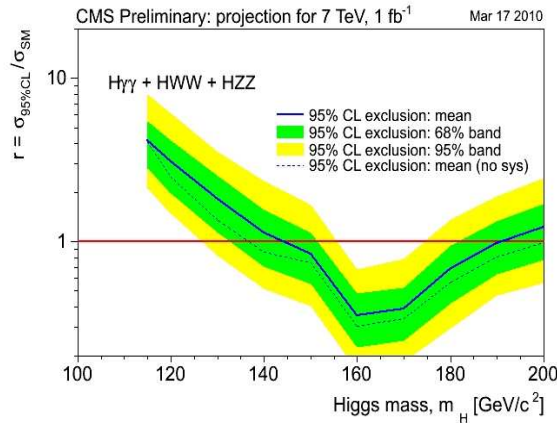


FIG. 2.19 – Rapport de la section efficace nécessaire pour exclure le boson de Higgs à 95% de niveau de confiance sur la section efficace dans le modèle standard, en fonction de la masse du boson de Higgs pour les canaux  $H \rightarrow ZZ^* \rightarrow 4l$ ,  $H \rightarrow \gamma\gamma$  et  $H \rightarrow WW \rightarrow 2l2\nu$  combinés, pour une luminosité intégrée de  $1 \text{ fb}^{-1}$  et une énergie dans le centre de masse de 7 TeV dans CMS [107].

## Chapitre 3

# Effets cinématiques dus aux ordres supérieurs

La plupart des sections efficaces, largeurs partielles et rapports de branchement présentés à la section 2.2 résultent de calculs à l'arbre. Toutefois, les diagrammes à l'arbre ne représentent que le premier terme de la série perturbative de QCD ou de QED. D'une manière générale, on peut écrire la section différentielle d'une interaction dure à courte distance comme une série de puissances en  $\alpha_S$  [77] (nous tenons seulement compte des corrections de QCD) :

$$\frac{d\sigma}{dw} = \sum_N \left( \frac{\alpha_S(\mu_R)}{\pi} \right)^N H_N(x_A, x_B, w; \mu_R)$$

Où  $\alpha_S$  est la constante de couplage de la QCD,  $H$  est une fonction de l'échelle de renormalisation  $\mu_R$  utilisée pour le calcul de la section efficace (pour une série infinie, le résultat ne devrait plus en dépendre), de  $w$  qui est une observable quelconque, de  $x_A$  et  $x_B$  qui sont les fractions de l'impulsion des protons portée par les partons. Cette formule met en évidence la dépendance de la section efficace du processus en fonction de l'ordre  $N$  auquel elle est évaluée.

Au LHC, l'échelle d'énergie typique à laquelle est évalué un processus est  $\alpha_S(M_Z) = 0.118 \ll 1$ , ce qui devrait assurer la convergence de la série précédente si la fonction  $H$  se comporte comme  $O(1)$ . Toutefois on ne connaît pas l'amplitude des termes de corrections avant de les avoir calculés, et il arrive souvent qu'ils soient du même ordre de grandeur que le terme à l'arbre. Une estimation la plus précise possible se doit de les prendre en compte. Pour l'instant, la plupart des processus d'intérêt au LHC ont été calculés jusqu'au NLO (terme en  $\alpha_S$ ) voire NNLO (terme en  $\alpha_S^2$ ). Les mesures issues du Tevatron ne semblent pas indiquer le besoin d'un calcul prenant en compte des puissances en  $\alpha_S$  plus élevées.

Les corrections de QCD à un certain ordre fixé peuvent être de deux types : *réelles*, pour les diagrammes de Feynman correspondant à l'émission d'un quark ou d'un gluon supplémentaire, ou *virtuelles*, pour les diagrammes de Feynman correspondant à l'insertion d'une boucle de quarks ou de gluons, ou à l'émission-absorption de gluons sur une ligne de quarks. Les corrections virtuelles comportent des singularités *ultra-violettes* (qui rendent infini le calcul des intégrales lorsque l'impulsion des particules mises en jeu tend vers l'infini), et doivent donc recevoir un traitement spécial (en l'occurrence le procédé de renormalisation : régularisation dimensionnelle et soustraction des dépendances en  $\ln(Q^2/\mu_R^2)$  qui sont absorbées dans la constante de couplage  $\alpha_S$ , où  $Q$  est l'échelle d'énergie du processus dur, l'impulsion échangée entre les protons lors de l'interaction dure). Les corrections réelles et virtuelles, prises séparément, souffrent aussi de divergence *infra-rouges* (elles sont divergentes quand l'impulsion des particules mises en jeu tend vers 0), et ce n'est que leur somme qui pourra rendre le résultat convergent.

Toutefois, avec une telle approche à ordre fixe, il subsiste des divergences *molles*, dues à la non prise en compte à tout les ordres de l'émission de gluons mous dans l'état initial ou final à petit angle par rapport aux quarks. Ici seule une resommation des processus d'émission de gluons à tous les ordres conduira à une annulation des divergences. En effet, la formule citée plus haut pour le développement de

la section efficace en série perturbative pourrait s'écrire de façon plus détaillée de la manière suivante [108] :

$$\hat{\sigma} = \hat{\sigma}^{LO} \left[ 1 + \sum_{n=1}^{\infty} \alpha_S^n \left( C_{2n}^{(n)} L^{2n} + C_{2n-1}^{(n)} L^{2n-1} + C_{2n-2}^{(n)} L^{2n-2} + \dots \right) \right]$$

Chaque ordre  $n$  de la série perturbative donne lieu à une somme de  $2n$  logarithmes divergents de la forme  $L = \ln(Q^2/p_T^2)$ . Tenir compte du premier terme logarithmique (dominant) à tous les ordres de la théorie perturbative et négliger les autres, c'est effectuer le calcul de section efficace dans l'approximation Leading-Log (LL). Si on tient de plus compte du deuxième terme on fait l'approximation Next-to-Leading-Log (NLL), etc. Il existe plusieurs façon de traiter le problème : la première en passant dans l'espace de phase conjugué des paramètres d'impacts  $b$  (transformée de Fourier de l'impulsion transverse, comme le fait Resbos [109], voir section 3.1.3), où alors en restant dans l'espace de phase des  $p_T$ .

La simulation des processus physiques procède généralement en deux étapes. Dans un premier temps, un générateur à élément de matrice (ME, décrits à la section 3.1) va générer les événements au niveau partonique correspondant au processus à l'ordre désiré. Nous nous intéresserons plus particulièrement aux générateurs ME permettant un calcul NLO du processus  $\gamma\gamma+X$  (avec Diphox [110], Gamma2MC [111] et Resbos [109]) et NNLO du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  (avec HNNLO [86]). Les effets de la resommation des gluons peuvent aussi être inclus à cette étape, comme le fait Resbos. Pour l'instant, seul le processus dur a été pris en compte. Dans un deuxième temps, un générateur à gerbe partonique (PS, décrit section 3.2) va fragmenter puis hadroniser les partons de l'interaction dure, et produire toutes les particules dans l'état final. Un générateur à gerbe partonique peut aussi simuler les émission de gluons dans l'état initial ou final, et fragmenter/hadroniser les partons spectateurs relevant de l'évènement sous-jacent. Pour cette classe de générateurs, le plus populaire est probablement PYTHIA [26], et c'est celui dont nous décrirons plus loin le fonctionnement. Enfin, la prise en compte des effets aux ordres supérieurs calculés par un générateur ME dans un générateur d'évènements PS peut être délicate. Ce point sera détaillé à la section 3.3. Finalement, nous présenterons section 3.4 une comparaison des prédictions théoriques et des données du Tevatron pour le processus  $\gamma\gamma+X$ .

La formalisation développée plus haut (séries de termes en puissances de  $\alpha_S$ ) est adaptée à la QCD, mais convient aussi aux corrections électrofaibles (série en puissances de  $\alpha$ ), qui peuvent s'avérer importantes pour certains processus, et dont il est parfois nécessaire de tenir compte. Les corrections électrofaibles peuvent être évaluées aux ordres supérieurs par un générateur à élément de matrice, au niveau de l'interaction dure (comme Alpgen [24] qui prend en compte les émissions d'un photon en état initial ou final - et leurs interférences - pour le processus  $Z + \gamma$ ). La radiation de photons est aussi implémentée de manière générale par les générateurs à gerbe partonique tels PYTHIA (voir section 3.2).

### 3.1 Les générateurs à éléments de matrice

Le but des générateurs à éléments de matrice (ME) est la simulation de l'interaction dure à l'aide des outils de la théorie perturbative de QCD. Les générateurs ME se basent sur un calcul précis des éléments de matrice associés aux diagrammes de Feynman correspondant aux processus considérés (LO, NLO ou NNLO), et combinent souvent la méthode analytique (avec la solution exacte d'une partie des équations mathématiques) et une méthode numérique d'intégration Monte-Carlo. A la fin du calcul, les générateurs ME fournissent des fichiers résultats comportant la section efficace du processus, les distributions cinématiques des sections efficaces différentielles, ou bien des événements comportant les quadri-impulsions des particules initiales et finales.

Dans cette section, nous nous intéresserons plus particulièrement aux générateurs à élément de matrice NLO et NNLO, pour l'évaluation des processus  $\gamma\gamma + X$  avec Diphox et Gamma2MC, et  $gg \rightarrow H \rightarrow \gamma\gamma$  avec HNNLO. Pour chacun d'entre eux, nous décrirons les différents processus pris en compte ainsi que la méthode de calcul. Quand les informations sont disponibles, les dépendances des sections efficaces calculées en fonction des échelles d'énergie sera examinée ainsi que les limitations inhérentes aux approches

effectuées.

### 3.1.1 Génération du processus $\gamma\gamma + X$ avec DIPHOX au NLO

#### Processus $\gamma\gamma + X$ considérés

DIPHOX [110] est un générateur à élément de matrice capable d'évaluer les sections efficaces (et les sections efficaces différentielles pour diverses observables) de processus impliquant la production de deux photons dans l'état final jusqu'au NLO. A l'arbre, la production d'une paire de photons est donnée par le processus  $q\bar{q} \rightarrow \gamma\gamma$ , appelé en anglais contribution *Born*, dont le diagramme de Feynman est représenté sur la figure 3.1a. DIPHOX inclut toutes les corrections NLO au diagramme Born : d'une part les corrections dues aux processus virtuels (fig. 3.1c), et d'autre part les corrections dues aux émissions réelles (fig. 3.1b), avec 3 particules dans l'état final. Ces émissions réelles correspondent aux processus  $q\bar{q} \rightarrow \gamma\gamma g$ ,  $gq \rightarrow \gamma\gamma q$  et  $g\bar{q} \rightarrow \gamma\gamma\bar{q}$ .

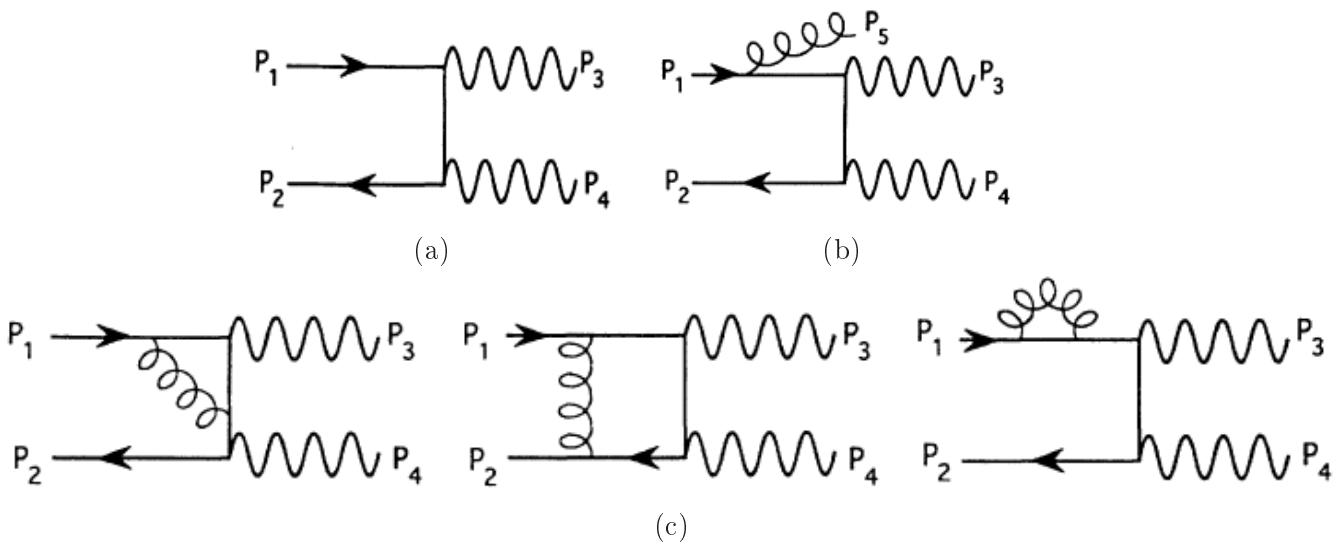


FIG. 3.1 – Diagramme de Feynman associés : (a) au processus Born à l'arbre, (b) aux corrections réelles NLO typiques du diagramme Born, (c) aux corrections virtuelles NLO typiques du diagramme Born.

En plus du processus Born et de ses corrections NLO, DIPHOX tient aussi compte des contributions de fragmentation simple et double jusqu'au NLO. Il y a fragmentation simple (aussé appelée contribution de "bremsstrahlung") lorsqu'un des photons provient de la fragmentation collinéaire d'un parton de l'interaction dure (voir fig.3.2a), et double lorsque les deux photons résultent de la fragmentation colinéaire de deux partons différents (fig.3.2b). L'émission de deux photons de fragmentation par le même quark n'est encore calculée complètement par aucun code à élément de matrice existant (c'est un problème théorique ouvert). La fragmentation est un processus d'interaction à longue distance (qui apparaît "après" l'interaction dure), qui ne peut pas être traité par les outils de la QCD perturbative. Les photons issus de la fragmentation sont la plupart du temps accompagnés de hadrons, ce qui du point de vue mathématique, fait apparaître une singularité colinéaire dans le calcul de l'élément de matrice pour le processus de fragmentation. De plus, chaque fois qu'un gluon est émis par le quark ou le gluon qui finit par fragmenter, une nouvelle singularité colinéaire apparaît. Toutes ces singularités sont factorisées (à tous les ordres de la théorie des perturbations) dans la fonction de fragmentation  $D_{\gamma/q}(z, M_f^2)$  du quark ou  $D_{\gamma/g}(z, M_f^2)$  du gluon, où  $z$  est la fraction de l'impulsion du quark ou gluon initial portée par le photon et  $M_f$  est une échelle d'énergie du processus de fragmentation (arbitraire, elle doit toutefois être du même ordre de grandeur que l'échelle de factorisation  $\mu_F$  et l'échelle de renormalisation  $\mu_R$ ). Les fonctions de fragmentation, comme les densités partoniques, sont déterminées à une échelle d'énergie initiale, et c'est l'équation d'évolution de la QCD qui donnera leur expression à n'importe quelle échelle d'énergie. Des arguments de comptage des puissances montrent que les contributions de fragmentation au LO se comportent en  $O(\alpha_S)$

et qu'il faut donc les prendre en compte pour un calcul complet au NLO ; de plus, les corrections NLO pour ces contributions de fragmentation sont calculées par DIPHOX par souci de complétude. Pour résumer, si les diagrammes qui conduisent à la fragmentation sont inclus dans DIPHOX jusqu'au NLO, le calcul des éléments de matrice fait intervenir une fonction non perturbative pour l'émission en cascade de gluons réels par le quark qui fragmente. Le calcul de la fonction de fragmentation est effectué au-delà du LL [112].




FIG. 3.2 – Diagrammes de Feynman LO associés aux (a) processus de production d'un diphoton lorsqu'un des photons est issu de la fragmentation d'un des partons, (b) processus de production d'un diphoton par fragmentation de deux partons. Les protons incidents et les quarks spectateurs sont aussi représentés.

Il faut ajouter que la séparation du processus  $\gamma\gamma+X$  en 3 parties (Born, 1-fragmentation, 2-fragmentation) relève d'une procédure arbitraire : c'est une convention choisie pour faciliter les calculs. Prises séparément, chacune des trois contributions dépend de l'échelle de fragmentation, et ce n'est que leur somme qui annule cette dépendance. Il est donc important de noter que seule la somme des trois contributions revêt un sens physique.

Avec les corrections au diagramme Born et les contributions de fragmentation, DIPHOX effectue un calcul NLO complet du canal  $q\bar{q} \rightarrow \gamma\gamma+X$ . De plus, DIPHOX est aussi capable de calculer la section efficace du processus NNLO  $gg \rightarrow \gamma\gamma$  (dit "boîte", en anglais *Box*), où la paire de photon est produite par fusion de gluon médiée par une boucle de quarks. Ce processus correspond en fait à un nouveau canal, car au LHC la luminosité des gluons est très grande comparée à celle des quarks et des anti-quarks, donnant une section efficace de la contribution Box du même ordre de grandeur que la contribution Born. Pour une prise en compte des corrections aux ordres supérieurs pour le diagramme Box déjà NNLO, il faudra utiliser le programme Gamma2MC [111] (voir section 3.1.2). DIPHOX est en effet conçu pour faciliter l'interfaçage avec Gamma2MC (on peut "éteindre" la contribution Box dans le calcul de DIPHOX).

### Méthode de calcul

DIPHOX combine des techniques d'intégration analytiques et Monte-Carlo, ce qui permet une grande flexibilité : contrairement à l'approche purement analytique où chaque observable doit être calculée en fonction des paramètres, l'approche Monte-Carlo permet de générer des événements qui peuvent être réutilisés pour le calcul de chaque observable. Schématiquement, la méthode de calcul des sections efficaces est abordée en plusieurs étapes :

- L'espace de phase est d'abord découpé en quatre parties (méthode de "phase space slicing") par la définition des valeurs seuils non-physiques  $R_{th}$  et  $p_{Tm}$ , choisis petits.  $R_{th}$  est le rayon du cône à l'intérieur duquel on considère avoir affaire à une collinéarité entre deux particules, et  $p_{Tm}$  est l'énergie transverse en-dessous de laquelle on considérera que les particules sont "molles".

- Les éléments de matrices sont ensuite intégrés sur les différents espaces de phase, ce qui conduit à



l'annulation des divergences une fois que les diagrammes réels et virtuels des processus ont été combinés. Il est à noter que les termes d'ordre  $p_T$  sont alors négligés devant ceux d'ordre  $\ln(p_T)$  pour les particules molles et colinéaires (l'annulation des divergences est partielle pour cet partie de l'espace de phase tandis qu'elle est complète ailleurs).  $p_{Tm}$  doit donc être choisi suffisamment petit pour pouvoir négliger ces termes sans que cela ne biaise le résultat. Il suffit en général de prendre une valeur de  $p_{Tm}$  d'environ 5% de l'impulsion transverse minimale des photons (typiquement  $0.05 \times 20$  GeV).

- La contribution de chaque mécanisme à la section efficace finale est calculée après des coupures minimales sur la rapidité des photons, leur impulsion transverse et masse invariante. Les coupures d'isolation sont alors appliquées. Des événements sont ensuite générés au niveau partonique et stockés. Les distributions de section efficace différentielles sont données comme résultat.

### Limitations

DIPHOX est un générateur à ordre fixe, NLO, et souffre donc des mêmes limitations que tous les générateurs à ordre fixe. En particulier, le comportement de la distribution de section efficace différentielle  $d\sigma/dq_T$  devient pathologique dans la limite  $q_T \rightarrow 0$  (où  $q_T$  est l'impulsion transverse du système diphoton). Dans cette limite, la distribution est en effet sensible aux divergences infra-rouges, contrôlées par l'émission multiple de gluons mous et colinéaires. A une échelle d'énergie  $Q$  donnée (souvent prise égale à la masse invariante du système diphoton  $m_{\gamma\gamma}$ ), la section efficace différentielle a la forme suivante [109] dans la limite  $q_T \ll Q$  :

$$\frac{d\sigma}{dq_T^2} = \sigma_0 \frac{\alpha_S}{\pi} \frac{1}{q_T} \left[ a_1 \ln(Q^2/q_T^2) + a_0 \right]$$

Où  $a_0$  et  $a_1$  sont des constantes sans dimension et  $\sigma_0(Q)$  est la section efficace LO du processus Born évaluée à l'échelle de renormalisation  $Q$ .  $Q$  est l'échelle d'énergie du processus et est souvent prise à la valeur  $Q = m_{\gamma\gamma}$  (masse invariante du système diphoton). On voit donc que selon le signe de  $a_1$ , la section efficace diverge négativement ou positivement dans la limite  $q_T \rightarrow 0$ . Les logarithmes en  $\ln(m_{\gamma\gamma}^2/q_T^2)$  (avec  $m_{\gamma\gamma}$  masse invariante de la paire diphoton, et  $q_T$  son impulsion transverse) doivent être resommés à tous les ordres de la théorie des perturbations pour conduire à un résultat non divergent. Un tel resommation est effectuée par le générateur RESBOS [109] pour le canal  $\gamma\gamma+X$  (mais RESBOS ne dispose pas d'un traitement complet NLO des contributions de fragmentation). Il existe donc un seuil en  $q_T$  à déterminer expérimentalement au-delà duquel on ne peut plus faire confiance aux prédictions de DIPHOX concernant cette observable. Pour la même raison, la section efficace différentielle  $d\sigma/d\Delta\phi$  (où  $\Delta\phi$  est l'angle azimuthal entre les deux photons) diverge quand  $\Delta\phi \rightarrow \pi$ .

Les incertitudes sur les grandeurs calculées avec DIPHOX peuvent être de plusieurs types :

- Il y a d'abord une incertitude statistique qui provient du nombre d'évènements générés au niveau partonique. Par défaut, DIPHOX génère 40 millions d'évènements, ce qui pour les ensembles de coupures usuels (en impulsion, pseudo-rapidité, isolation) rend l'incertitude statistique négligeable.
- La première source d'erreur systématique est due à la méthode d'intégration. De telles incertitudes sont très difficiles à estimer. Lorsque les coupures sur l'impulsion transverse des deux photons sont symétriques, DIPHOX fournit une évaluation précise et globale de l'incertitude sur la section efficace. Lorsque les coupures sont asymétriques, DIPHOX fournit seulement une incertitude sur chacune des divisions des distributions de section efficace différentielle. Une estimation de l'erreur sur la section efficace est alors possible par sommation quadratique des erreurs. L'erreur évaluée avec cette méthode est systématiquement au-dessus de l'erreur donnée par DIPHOX dans le cas d'une coupure symétrique.
- Enfin, une autre source d'incertitude systématique vient du choix des échelles d'énergie, qui sont des paramètres pour le calcul des sections efficaces. Lorsque des choix symétriques sont effectués, du type  $\mu_F = \mu_R = M_f = km_{\gamma\gamma}$  (où  $\mu_F$  est l'échelle de factorisation,  $\mu_R$  l'échelle de renormalisation,  $M_f$  l'échelle de fragmentation) avec  $k = 0.5, 1$  ou  $2$ , ce qui est habituellement la convention utilisée pour calculer cette incertitude, la section efficace différentielle NLO incluant toutes les contributions apparaît de façon surprenante comme étant très stable avec 5% de variation seulement. En revanche dans le cas d'un choix asymétrique des échelles d'énergie, la variation peut monter jusqu'à 20%. L'amplitude de la variation est

une indication concernant l'importance des termes aux ordres supérieurs qui n'ont pas été pris en compte dans le calcul.

- Une autre source d'incertitude provient du choix de l'ensemble de densités partoniques utilisées. L'incertitude doit être calculée expérimentalement pour chaque lot de coupures en essayant différents lots de densités partoniques.
- Une dernière incertitude théorique concerne l'incertitude sur les fonctions de fragmentation utilisées. Elle peut être évaluée en répétant les calculs de sections efficaces avec différentes fonctions de fragmentation.

### 3.1.2 Génération du processus "boîte" $gg \rightarrow \gamma\gamma + X$ Gamma2MC au NLO

Le générateur à éléments de matrice Gamma2MC [111] est dédié au calcul de la section efficace (et des sections efficaces différentielles) du processus Box par fusion de gluon via une boucle de quarks et de ses corrections NLO. Ainsi qu'il a déjà été expliqué plus haut, la densité partonique des gluons dans le proton devient très grande dans les plages d'énergie atteintes par le LHC (et plus spécialement à bas  $x$  de Bjorken), ce qui rend le calcul des corrections au processus Box très important pour une estimation correcte de ce canal. Alors que DIPHOX calcule le processus Box au LO seulement, la combinaison de DIPHOX pour les processus Born et fragmentations avec le processus Box Gamma2MC donne une prédiction à la précision NLO des processus  $\gamma\gamma + X$ .

#### Le processus Box et ses corrections NLO

Le processus Box (voir fig. 3.3a) est formellement un processus NNLO, contenant une boucle de quark. Les corrections à l'ordre suivant au processus Box incluent des corrections virtuelles (fig. 3.3b), qui font donc intervenir des diagrammes à deux boucles, ainsi que des corrections réelles à une seule boucle  $gg \rightarrow \gamma\gamma g$  avec émission d'un gluon supplémentaire (ce qui donne lieu à des diagrammes en pentagone, voir fig. 3.3c). Les corrections virtuelles et réelles prises séparément souffrent d'une divergence infra-rouge et ce n'est que leur somme qui annule la divergence. Toutes les corrections ont été évaluées dans la limite des quarks de masse nulle, ce qui est une excellente approximation dans la plage de masse  $90 < m_{\gamma\gamma} < 150$  GeV où on recherche un boson de Higgs léger.




FIG. 3.3 – Diagrammes de Feynman correspondant (a) au processus Box, (b) à ses corrections typiques virtuelles, et (c) réelles à l'ordre suivant.

Parmi tous les processus NNLO de production de diphoton, le processus Box est estimé comme étant le plus important. Les autres processus NNLO ne sont ni pris en compte par DIPHOX (si on omet les corrections aux contributions de fragmentation, qui en terme de puissance de  $\alpha_S$  sont formellement au-delà de NLO), ni par Gamma2MC. La contribution estimée comme la plus importante à ne pas avoir été prise en compte vient probablement du processus  $gg \rightarrow \gamma\gamma q\bar{q}$ , initié lui aussi par deux gluons (voir fig. 3.4), mais dont le calcul n'a pas encore été mené à bien à ce jour. Toutefois un processus similaire,  $gg \rightarrow WVq\bar{q}$  ( $V = \gamma$  ou  $Z$ ), a été évalué à une importance de 5% ou moins par rapport au processus Born LO. Tous les autres processus NNLO non considérés ne sont initiés que par un unique gluon (avec un quark ou anti-quark), ou par des quarks seulement, ce qui devrait réduire leur section efficace étant donné qu'ils ne bénéficient pas autant que le diagramme Box d'une haute luminosité en gluons.

Les corrections au processus Box sont du même ordre de grandeur que le processus Box en lui-même, et leur importance varie selon les coupures utilisées. Bien que distribuées sur toute la plage de masse




FIG. 3.4 – Diagrammes de Feynman correspondant aux processus NNLO autres que Box, non pris en compte par Gamma2MC.

invariante, elles deviennent plus importantes à mesure que la masse invariante diphoton diminue. Elles restent toutefois modestes par rapport au taux total d'évènements diphotons incluant Born et Box.

### Erreurs systématiques

Dans l'espace de phase  $0.01 < x < 0.1$  et  $Q$  de l'ordre de 100 GeV, les densités partoniques des gluons changent peu selon les pdf utilisés (CTEQ6M ou divers MRST). La principale incertitude sur les distributions différentielles proviendra plutôt des valeurs choisies pour les échelles de factorisation et de renormalisation.

Si l'échelle de factorisation  $\mu_F$  et l'échelle de renormalisation  $\mu_R$  sont affectées à des valeurs différentes (par exemple,  $\mu_R = 0.5m_{\gamma\gamma}$  et  $\mu_F = 2m_{\gamma\gamma}$ , ou bien  $\mu_R = 2m_{\gamma\gamma}$  et  $\mu_F = 0.5m_{\gamma\gamma}$ ), alors la section efficace Box au LO et au NLO varie dans la même proportion d'environ 25%. En revanche, si un choix plus orthodoxe est effectué,  $\mu_R = \mu_F = 0.5m_{\gamma\gamma}$ , ou  $\mu_R = \mu_F = 2m_{\gamma\gamma}$ , l'amplitude de la variation de la section efficace NLO (environ 5%) est beaucoup plus faible que pour la section efficace LO (environ 10%). On peut donc affirmer que les erreurs systématiques liées à la génération du processus Box par Gamma2MC sont sous contrôle théorique.

### 3.1.3 Génération du processus $\gamma\gamma + X$ avec RESBOS

RESBOS [109] est un générateur à élément de matrice capable de simuler les processus  $\gamma\gamma + X$  Born (NLO), fragmentation simple (LO), et Box (NLO). De plus, RESBOS effectue une resommation des partons mous et collinéaires émis dans l'état initial, résolvant par-là le problème de la nature non physique du spectre en énergie transverse lorsque  $q_T \rightarrow 0$  liés aux générateurs à ordre fixe comme DIPHOX.

#### Processus $\gamma\gamma + X$ considérés

Dans la terminologie utilisée par RESBOS, il y a d'abord les processus  $q\bar{q} + gg$ , qui incluent le processus Born et ses corrections réelles et virtuelles NLO, ainsi que la composante de fragmentation simple calculée au LO. A la différence de DIPHOX, le processus de fragmentation n'est pas calculé à l'aide d'une fonction de fragmentation  $D_{\gamma/q}(M_f)$  mais seulement approximée [113]. Les photons issus de la fragmentation sont émis principalement collinéairement aux partons à l'état final, et peuvent donc être supprimés par un critère d'isolation (on demande l'énergie transverse  $E_T < E_{T,iso}$  dans un cône  $\Delta R < \Delta R_{iso}$  autour du photon). RESBOS supprime la composante de fragmentation pour  $q_T > E_{T,iso}$  en appliquant directement ce critère d'isolation au processus  $gg$  (processus pour lequel l'annulation des divergences intervient dans DIPHOX par ajout de la composante de fragmentation incluant la forme explicite de la fonction de fragmentation). Pour  $q_T < E_{T,iso}$ , la divergence du processus  $gg$  est régularisée par l'ajout d'un terme effectif.

Les autres processus pris en compte par RESBOS sont nommés  $gg + gq_S$ . Il s'agit de la même contribution  $gg$  Box NLO que celle calculée avec Gamma2MC, avec en plus un nouveau processus  $gq_S \rightarrow \gamma\gamma q_S$  [114] (voir fig.3.5) que n'inclut pas Gamma2MC. Le symbole  $q_S$  indique la combinaison de toutes les saveurs de quarks et anti-quarks intervenant dans le processus.




FIG. 3.5 – Contribution  $gq_S$  prise en compte dans RESBOS, mais négligée dans GAMMA2MC.

RESBOS prend aussi en compte à la précision NNLL les radiations QCD dans l'état initial, en effectuant une resommation des logarithmes  $\ln^n(q_T/M_{\gamma\gamma})$  qui interviennent dans la section efficace différentielle des processus  $q\bar{q} + qg$  et  $gg + gq_S$  et qui deviennent divergents dans la limite  $q_T \rightarrow 0$ . Le formalisme utilisé est celui de Collins-Soper-Sterman (CSS, [115]), dans lequel l'intégration est faite dans l'espace des  $b$  (paramètre d'impact) égal à la transformée de Fourier de la distribution en  $p_T$ . Le calcul de la section efficace fait aussi intervenir une fonction non-perturbative dont les coefficients sont déterminés à partir de l'expérience. Elle fait aussi intervenir un facteur de Sudakov qui contient toutes les puissances des logarithmes (dominants, sous-dominants, etc.). RESBOS combine les sections efficaces NLO et resommées de la façon suivante :

- La section efficace NLO est approximée par sa composante asymptotique  $A$  à bas  $q_T$ . C'est à partir de cette approximation que sont calculées les contributions dues à la resommation. La section efficace resommée à bas  $q_T$  est appelée  $W$ .
- La section efficace totale NLO  $P$  (pour Perturbative) est aussi calculée. On nomme  $Y = P - A$  la composante  $P$  à laquelle on a soustrait son approximation asymptotique  $A$ .
- La section efficace totale à bas  $q_T$  vaut alors  $W + Y$ , c'est à dire que le double-comptage entre les contributions prises en compte à la fois dans la partie resommée  $W$  et la partie perturbative  $P$  est évité. Lorsque  $q_T$  augmente, il existe un point pour lequel  $W + Y$  passe en-dessous de  $P$ . A partir de ce point, la méthode de resommation n'est plus valide et la section efficace que fournit RESBOS est remplacée par  $P$ , la section efficace NLO sans resommation. Ce point de croisement apparaît de manière naturelle aux alentours de  $q_T \approx M_{\gamma\gamma}$  (pour lesquels la contribution des logarithmes est proche de 0).

### Limitations

La première limitation concernant RESBOS est l'approximation faite au niveau du processus  $q\bar{q} + qg$  pour le calcul de la contribution de fragmentation simple LO, qui n'inclut pas explicitement la fonction de fragmentation, à la différence de DIPHOX qui calcule les contributions de fragmentations simples et doubles jusqu'au NLO. En contre-partie, Resbos effectue la resommation des partons mous et collinéaires émis dans l'état initial, ce qui régularise la divergence rencontrée par DIPHOX aux bas  $q_T$ . Toutefois cette resommation n'est appliquée que dans la région de l'espace de phase  $q_T \lesssim M_{\gamma\gamma}$ . Pour la région  $q_T \gtrsim M_{\gamma\gamma}$ , le taux d'évènements prédit par RESBOS sera donc moindre que celui prédit par DIPHOX, tandis qu'en-dessous de  $M_{\gamma\gamma}$  ce taux devrait probablement être supérieur en raison des termes de resommation.

Les incertitudes systématiques liées au calcul de section efficace avec RESBOS sont les suivantes :

- Les incertitudes liées aux paramètres de resommation indiquent la variation de la section efficace attendue si le calcul était effectué au-delà de NNLL : elles sont inférieures à 10% pour la section efficace totale (elles sont plutôt de l'ordre de 20% pour les contributions  $gg + gq_S$ ).
- Les incertitudes liées au schéma de resommation (CSS [115] ou CFG [116]) sont de l'ordre de 2% au LHC.
- Les incertitudes liées à la variation des échelles d'énergie est de 10% au LHC à bas  $q_T$  et 7% pour  $q_T > 50$  GeV.
- Seul l'ensemble de densités partoniques CTEQ6M [79] a été utilisé par les auteurs, l'incertitude liée aux pdfs doit donc être évaluée par l'utilisateur.

### 3.1.4 Génération du processus $gg \rightarrow H \rightarrow \gamma\gamma$ avec HNNLO au NNLO

Au LHC, la fusion de gluon est le processus dominant pour la production du boson de Higgs standard. Les corrections NLO à la section efficace de production LO sont du même ordre de grandeur (80-100%) que la section efficace au LO [117]. Il est donc important de prédire les sections efficaces et les spectres cinématiques du boson de Higgs à l'ordre le plus haut possible de la théorie des perturbations. HNNLO [86] est un générateur à éléments de matrice capable de calculer au LO, NLO et NNLO la section efficace, ainsi que les sections efficaces différentielles de production du boson de Higgs par fusion de gluon, et sa désintégration dans divers canaux, dont  $H \rightarrow \gamma\gamma$ .

Au NNLO, il y a trois types de corrections qui souffrent séparément de divergences infra-rouges :

- Les corrections *doublement réelles*, où 2 partons émis par le processus dur reculent par rapport à la paire diphoton.
- Les corrections *réelles-virtuelles*, où un seul parton émis recule par rapport à la paire diphoton, et une boucle virtuelle a été prise en compte dans l'interaction.
- Les corrections *doublement virtuelles*, où deux boucles ont été prises en compte dans l'interaction.

La somme des trois contributions doit annuler explicitement les divergences infra-rouges.

La méthode de calcul utilisée par HNNLO est indépendante du processus et des observables. L'idée de base est la suivante : au LO, l'impulsion transverse  $q_T$  du système de particules dans l'état final  $F$  est exactement nulle. Par conséquent si pour un certain processus NLO ou NNLO on a  $q_T \neq 0$ , les contributions (N)NLO sont en fait données par les contributions (N)LO au processus  $F+\text{jet}(s)$ . Cette idée est résumée par la formule suivante :

$$d\sigma_{(N)NLO}^F \Big|_{q_T \neq 0} = d\sigma_{(N)LO}^{F+\text{jet}(s)}$$

Ce qui signifie que toutes les divergences infra-rouges du calcul NNLO sont celles du calcul NLO de  $F+\text{jets}$ , qui peuvent être traitées par les méthodes habituelles de soustraction. Les seules singularités non traitées pour le calcul NNLO sont associées à la limite  $q_T \rightarrow 0$ . HNNLO n'inclut pas de traitement spécial de resommation des logarithmes et est donc un générateur à ordre fixe. Les auteurs de HNNLO ont toutefois mis en place un code de calcul séparé pour la prédiction du spectre en  $q_T$  du boson de Higgs au NLO, qui inclut la resommation des logarithmes [118].

HNNLO choisit les valeurs suivantes par défaut pour les échelles d'énergie :  $\mu_F = \mu_R = M_H$  (la masse du boson de Higgs). Les corrections NNLO apportent une contribution globale d'environ 20% sans aucune coupure par rapport au NLO, et de 5% après les coupures  $|\eta| < 2.5$ ,  $p_{Tmin} > 35$  GeV,  $p_{Tmax} > 40$  GeV et une isolation hadronique maximum permise de 6 GeV dans un cône de  $\Delta R < 0.3$  autour de chaque photon (qui sont des critères de sélection usuels pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  au LHC).

## 3.2 Les générateurs à gerbes partoniques

L'éventail des phénomènes physiques couverts par les générateurs à gerbe partonique (PS) est beaucoup plus vaste que celui des générateurs à éléments de matrice (ME). Le but des générateurs ME est de simuler le processus dur avec la plus grande précision possible (ce qui inclut de prendre en compte les corrections dues aux ordres supérieurs). Les générateurs PS se contentent souvent d'une modélisation de l'évènement dur avec un "noyau" à élément de matrice au LO, mais compensent cette faiblesse par la prise en compte d'effets indispensables à la simulation globale d'un processus : la radiation QCD et QED dans l'état initial et final, la fragmentation et l'hadronisation des partons issus de l'interaction dure comme ceux provenant de l'évènement sous-jacent, ainsi que la désintégration des particules issues de l'hadronisation en particules stables.

De plus, à la différence de la plupart des générateurs ME, l'intérêt des générateurs PS est de fournir

non pas seulement des distributions pour les observables, mais directement des événements qui contiennent toutes les informations sur les impulsions de chacune des particules qui ont participé au processus. Ceci est particulièrement utile pour l'analyse des processus physiques, d'autant plus que les effets dus au passage des particules finales dans la matière et leur dépôt d'énergie dans le détecteur peuvent être simulés par une sur-couche comme GEANT4 [29]. Il ne reste plus alors qu'à reconstruire les événements à partir des dépôts d'énergie simulés pour disposer d'une simulation complète du processus physique, de l'interaction dure jusqu'à la détection.

Dans la suite, nous nous référerons au générateur à gerbe partonique PYTHIA [26], probablement l'un des plus populaires, bien qu'il en existe d'autres (notamment SHERPA [119] et HERWIG [27]).

### 3.2.1 Le processus dur

Lorsque les deux faisceaux de protons se rencontrent au point d'interaction, ils peuvent donner lieu à une collision élastique ou relevant de la physique diffractive, ou donner lieu à une interaction dure, plus rare, et dont la section efficace peut être évaluée à l'aide de la théorie perturbative de QCD. Les générateurs PS utilisent un ensemble de densités partoniques, comme CTEQ, et calculent la section efficace de l'interaction proton-proton dans le modèle des partons. PYTHIA possède un générateur à élément de matrice LO intégré, qui fournit la section efficace différentielle de l'interaction dure désirée et qui sera convoluée avec les densités partoniques.

#### Largeur des résonances

Dans le cas où le processus dur implique une résonance, les sections efficaces sont souvent données dans la littérature avec l'approximation d'une largeur nulle. PYTHIA approxime alors la largeur de désintégration par une fonction de type Breit-Wigner qui entre dans la section efficace (approximation de largeur de désintégration étroite ou "narrow-width"), ayant pour expression :

$$f_{BV} = \frac{s}{\pi} \frac{H_R(s\tau)}{(s\tau - m_R^2) + m_R^2 \Gamma_R^2}$$

Où  $s$  est l'énergie dans le centre de masse des partons mis en jeu,  $\tau$  est la fraction de l'énergie dans le centre de masse des partons par rapport à l'énergie totale de la collision,  $m_R$  est la masse nominale de la résonance,  $H_R$  est une fonction qui dépend du processus,  $\Gamma_R$  une largeur constante. Une telle modélisation peut devenir problématique une fois la section efficace convoluée avec les densités partoniques, dont les formules analytiques divergent lorsque  $\tau \rightarrow 0$  : la queue de distribution à basse masse est augmentée et à haute masse supprimée ; à basse masse, il peut même apparaître une résonance qui doit être traitée expérimentalement par un critère de sélection supplémentaire. Le problème est apparu en particulier dans la génération des échantillons PYTHIA  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ) pour des masses du boson de Higgs  $m_H > 250$  GeV, et a été réglé par l'ajout d'un filtre demandant  $m_H > 100$  GeV.

#### Calcul de la section efficace et génération des événements

Avant de générer les événements, PYTHIA effectue un balayage de l'espace de phase disponible pour le processus considéré. La section efficace différentielle calculée avec les points obtenus ainsi est ensuite interpolée pour rendre l'intégration plus aisée sur tout l'espace de phase par la suite.

Les événements sont générés par méthode Monte-Carlo : les valeurs des quadri-impulsions des particules initiales sont déterminées par un processus aléatoire, et les quadri-impulsions des particules finales sont données par les distributions de probabilités associées à l'élément de matrice. La procédure globale est effectuée en plusieurs étapes que nous ne décrivons pas ici. Nous mentionnerons simplement le fait que des poids sont associés aux différentes régions de l'espace de phase pour éviter de générer trop d'événement dans les régions peu probables. En fin de calcul, PYTHIA fournit la section efficace (10000 événements sont nécessaires pour obtenir une précision de l'ordre de 1%) ainsi que les quadri-impulsions des particules initiales et finales intervenant dans l'interaction dure (et que toutes les particules de l'événement

sous-jacent et des radiations ISR/FSR, comme il sera décrit plus loin).

### Quelques canaux d'intérêts

PYTHIA 6 est capable de simuler environ 240 processus durs différents. Parmi ceux-ci, nous décrirons simplement quelques limitations liées au calcul de plusieurs processus qui auront l'occasion d'être utilisés par la suite pour les analyses :

- Le processus Box  $gg \rightarrow \gamma\gamma$  simulé avec PYTHIA est calculé au LO. Toutefois, il n'inclut pas la dépendance complète en masse des quarks sous peine d'instabilités de la section efficace. Le quark top est donc considéré comme étant de masse nulle : PYTHIA ne rend donc pas compte du creux caractéristique dans la distribution de masse autour de la masse du top.
- Le processus  $H \rightarrow \gamma\gamma$  peut être calculé de manière inclusive ou exclusive. En particulier, les quatre mécanismes de production pertinent au LHC (fusion de gluon, fusion de bosons vecteurs, production associée avec un boson vecteur et production associée avec une paire de quarks) sont disponibles séparément et calculés au LO. Dans le cas de la production associée avec une paire de quark, seuls des quarks top finals sont considérés. Quelques processus formellement NLO sont aussi disponibles (notamment  $H+\text{jet}$ ), mais ils ne disposent pas de corrections virtuelles.
- PYTHIA produit toujours les bosons de Higgs dans l'approximation d'une largeur de désintégration étroite, ce qui pose les problèmes déjà mentionnés plus haut pour le pic non-physique dans la région des basses masses pour  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ). D'autre part, les corrélations angulaires dues à la production d'une paire de bosons  $Z^0$  sont incluses dans la simulation de ce canal.

### 3.2.2 La radiation dans l'état initial et final

L'un des intérêts principaux des générateurs à gerbe partonique est de proposer une simulation des radiations QCD (émission de quarks et de gluons) et QED (émission de photons par les quarks et les leptons) dans l'état initial (ISR) et final (FSR). Dans PYTHIA, les radiations initiales et finales sont traitées par un mécanisme différent, et les interférences entre les deux états ne sont pas prises en compte.

#### Le mécanisme de radiation

Que la radiation soit émise dans l'état initial ou final, le mécanisme est globalement le même. L'idée des générateurs PS consiste à doter les partons d'une échelle d'énergie  $Q^2$ , dite échelle de virtualité en général égale à leur masse effective (suivant la terminologie de PYTHIA, on considérera ici comme parton aussi bien un lepton qu'un quark ou un gluon), et à faire évoluer  $Q$ , ce qui donne une idée de l'ordonancement en temps des radiations. A chaque itération, le parton  $a$  possède une certaine probabilité différentielle de branchement en partons  $b$  et  $c$ , conformément à la formule suivante :

$$dP_a = \sum_{b,c} \frac{\alpha}{2\pi} P_{a \rightarrow bc}(z) d\ln(Q^2) dz$$

Dans cette formule,  $a$  est le parton initial,  $b$  et  $c$  le parton final et la particule émise, le facteur  $\alpha$  vaut  $\alpha_{em}$  pour l'émission d'un photon et  $\alpha_S$  pour l'émission d'un quark ou d'un gluon,  $z$  est la portion d'énergie du parton  $a$  portée par la particule émise,  $P_{a \rightarrow bc}$  est le noyau de fragmentation.

Dans le cas d'une radiation d'un gluon par un quark :

$$P_{q \rightarrow qg}(z) = \frac{4}{3} \frac{1+z^2}{1-z}$$

Les formules pour  $P_{g \rightarrow gg}(z)$  et  $P_{g \rightarrow q\bar{q}}(z)$  sont omises ici. Dans le cas d'une émission de photon par un lepton (bremsstrahlung interne) :

$$P_{l \rightarrow l\gamma}(z) = \frac{1+z^2}{1-z}$$

Dans le cas de la fragmentation d'un quark en quark et photon :

$$P_{q \rightarrow q\gamma}(z) = e_q^2 \frac{1+z^2}{1-z}$$

Avec  $e_q^2 = 4/9$  pour les quarks de type  $u$ ,  $e_q^2 = 1/9$  pour les quarks de type  $d$ .

Dans les formules précédentes, l'approximation d'une émission colinéaire a été faite : les noyaux de fragmentation ne dépendent pas de l'angle d'émission mais seulement de la fraction  $z$ . L'angle est choisi aléatoirement, de manière isotrope. Une condition supplémentaire d'ordonnement en angle est effectué pour les radiations successives de gluons mous. C'est une manière de prendre en compte le phénomène de cohérence de couleur, où les interférences entre diagrammes tendent à supprimer l'émission de gluons à grand angle. Les formules indiquent que le traitement des radiations ISR et FSR par PYTHIA est globalement effectué dans l'approximation LL. Pourtant, nombre d'effets au-delà de LL sont pris en compte : notamment, il y a conservation de l'énergie-impulsion pour chaque branchement (alors que l'approche LL classique considère la limite nulle de l'énergie-impulsion de la particule émise), et un traitement approximatif du phénomène de cohérence est inclus.

### Radiation dans l'état final

Les gerbes dans l'état final sont dites de genre "temps" : pour un branchement  $a \rightarrow bc$ ,  $a$  et  $b$  ont une masse obéissant à  $m^2 = E^2 - \vec{p}^2 > 0$ . Les partons évoluent par échelle de virtualité décroissante jusqu'à atteindre le seuil  $Q_0 = 2$  GeV. Lors du premier branchement, un appariement entre la particule émise et l'élément de matrice du premier ordre est automatiquement effectué, si le processus dur fait intervenir la désintégration d'un singlet de couleur en une paire de quarks et de leptons, ou si l'appariement est explicitement demandé parce que le processus dur calculé par un générateur ME qui n'est pas celui de PYTHIA (par exemple Madgraph [23]). Cet appariement sera décrit plus en détail section 3.3.1. Pour tous les branchements suivants, PYTHIA n'effectue aucun appariement (à moins que cela ne soit explicitement demandé par exemple pour un processus avec deux jets supplémentaires en état final). Pour les radiations QCD, toutes les émissions après le premier branchement seront ordonnées par angle d'émission décroissant. Un tel ordonnancement n'est pas effectué pour les émissions de photons.

### Radiation dans l'état initial

Les gerbes dans l'état initial sont dites de genre "espace" : pour un branchement  $a \rightarrow bc$ ,  $a$  et  $b$  ont une masse obéissant à  $m^2 = E^2 - \vec{p}^2 < 0$ . Pour une cascade de radiation dans l'état initial,  $Q$  est augmenté à mesure que l'on se rapproche du processus dur. En fait, l'évolution est effectuée en allant vers l'arrière dans le temps : au commencement du calcul de la gerbe, les partons considérés ont un  $Q$  maximal et sont ceux de l'interaction dur. Puis  $Q$  est décrémenté, et les partons possèdent à chaque pas la possibilité d'émettre une particule par branchement, jusqu'à atteindre un seuil en  $Q_0 = 1$  GeV qui signale que les partons initiaux ont été trouvés. Ils peuvent être de saveur ou de couleur différentes des partons de l'interaction dure. Dans le cas des ISR, la probabilité différentielle de branchement dépend donc aussi des densités partoniques dans le proton.

Pour l'émission de gluons mous (très fréquente dans l'état initial), la fraction de l'impulsion portée par le parton une fois le gluon émis vaut  $z \rightarrow 1$  : la probabilité de branchement diverge. Un seuil de 2 GeV est donc imposé à l'énergie des gluons mous, contrairement à l'approche ME pour laquelle les divergences liées aux gluons mous non-colinéaires sont annulées par les différentes contributions aux ordres supérieurs. Comme dans le cas des radiations FSR, les angles d'émission sont par défaut ordonnés pour les radiations QCD seulement. Pour la radiation de photons mous, le seuil est fixé à une fraction de l'impulsion véhiculée par le photon de  $x_\gamma > 10^{-10}$ . Il est aussi à noter que pour une interaction proton-proton où la gerbe partonique est simulée avec PYTHIA, les gerbes QCD et QED dans l'état initial ne peuvent pas être mélangées : si le premier branchement est de type QCD (QED), toute la gerbe sera de type QCD (QED). Un traitement "démocratique" des émissions croisées de QCD et QED [120] est en revanche implémenté dans le générateur SHERPA [119] pour l'état initial et final.



### 3.2.3 La fragmentation ou hadronisation

A longue distance, la théorie perturbative de QCD ne s'applique plus car l'interaction entre les partons s'accroît en raison du confinement. Elle cède la place à un régime de confinement, dans lequel les partons colorés vont se rassembler en hadrons non-colorés, par mécanisme de fragmentation ou hadronisation. Le modèle de fragmentation/hadronisation choisi par PYTHIA est celui des *cordes* [121]. Il consiste à considérer les partons éloignés comme étant liés par une corde ou ressort qui modélisent un confinement linéaire. On peut ainsi assigner une raideur  $k = 1 \text{ GeV/fm}$  au ressort (mesurée dans des expériences de spectroscopie). Lorsque les deux partons s'éloignent l'un de l'autre, l'énergie potentielle portée par la corde s'accroît jusqu'à un certain seuil où elle casse. La fragmentation de la corde donne lieu à la création de deux nouveaux quarks (par exemple une paire  $q\bar{q}$ , où  $q$  peut être  $u, d, s$ , les quarks plus lourds ne pouvant être créés dans PYTHIA que lors de l'interaction dure) ou d'un quark et d'un diquark. S'ils possèdent une masse invariante suffisante, ils peuvent à leur tour donner lieu à autre une fragmentation.

Si les quarks ainsi créés ne font pas casser la corde, les quarks et anti-quarks issus de la fragmentation s'assemblent ensuite par paire avec les quarks de la corde initiale, selon le schéma  $q\bar{q} \rightarrow q\bar{q}'q'\bar{q} \rightarrow q\bar{q}' + q'\bar{q}$  (création de mésons). Un mécanisme similaire conduit à la production de baryons avec les diquarks issus de la fragmentation. Par la suite, les mésons et les baryons se désintègrent en particules stables dans l'état final. Typiquement, les  $\pi^0$  dans des évènements de QCD sont tous issus de ce type de fragmentation.

### 3.2.4 L'évènement sous-jacent et l'empilement

Le mécanisme de radiation dans l'état initial évoqué plus haut permet de remonter aux deux partons qui participent à l'interaction dure. Dans les deux protons subsistent les partons spectateurs qui n'ont pas participé à l'interaction dure. Par exemple, dans le cas d'un quark  $u$ , il subsiste un quark  $u$  et un quark  $d$  spectateurs qui ne participent pas à l'interaction. En tant que système confiné, ils vont obéir au même système de fragmentation que les partons issus de l'interaction dure et que les partons émis lors de radiations QCD dans l'état initial ou final. La fragmentation/hadronisation des partons spectateurs est appelée *évènement sous-jacent*, et ce mécanisme est pris en compte par défaut dans PYTHIA.

L'*empilement* apparaît lorsqu'une ou plusieurs collisions supplémentaires ont lieu lors d'un croisement de faisceaux, en raison d'une haute luminosité instantanée. PYTHIA dispose alors d'une option qui permet la superposition de plusieurs évènements de biais minimum avec une interaction plus rare. Cette approximation est valide tant que les sections efficaces de biais minimum sont beaucoup plus grandes que celle de l'évènement rare. De plus, PYTHIA est limité par la taille maximale des fichiers, qui augmente avec le nombre d'évènements empilés, c'est pourquoi cette option ne sera pas utilisée dans les analyses décrites plus tard.

## 3.3 Prendre en compte les effets dus aux ordre supérieurs dans la génération des évènements

Les générateurs PS comme PYTHIA incluent un calcul au LO du processus dur, ainsi qu'une modélisation au-delà du LL pour l'émission des radiations dans l'état initial et final (sans pour autant être véritablement NLL). Il y a toutefois des processus durs LO que PYTHIA n'est pas capable de modéliser pour l'instant, en particulier les processus avec une haute multiplicité de jets durs dans l'état final. Si un processus  $pp \rightarrow X$  est inclu dans PYTHIA au LO, tous les jets supplémentaires issus de la gerbe partonique seront calculés avec la précision LL, dans l'approximation de jets mous et collinéaires. Pour l'étude des processus  $pp \rightarrow X + n$  jets où l'on souhaite une meilleure description des jets durs et non-collinéaires, on utilisera plutôt un générateur ME qui calculera chacun des processus durs  $pp \rightarrow X + i$  jets ( $i = 0..n$ ) au LO, avant d'*interfacier* ce générateur ME avec un générateur PS comme PYTHIA, qui fragmentera/hadronisera les partons issus du processus dur et effectuera les radiations molles supplémentaires. Il est alors important de veiller à ce que les jets déjà pris en compte au niveau ME ne soient pas

double-comptés au niveau PS.

Si l'on souhaite de plus une description NLO du processus dur quand elle est disponible (et non plus seulement les émissions réelles, même calculées avec des générateurs ME dédiés), tout en conservant la fragmentation/hadronisation, deux options s'offrent à nous. La première consiste à appairier les partons issus du processus dur NLO calculé avec un générateur ME avec la fragmentation/hadronisation effectuée au niveau PS. Ceci demande un formalisme dédié mis en oeuvre dans le générateur MC@NLO [122] (ainsi que POWHEG [123]), où le générateur PS utilisé pour l'interfaçage est HERWIG [27]. Lorsqu'un tel appariement n'est pas possible (MC@NLO compte encore peu de processus durs) il existe une autre solution, qui consiste à *repondérer* les événements générés au LO et hadronisés avec un générateur PS à l'aide des distributions des observables cinématiquement importantes calculées au NLO par un générateur ME. Cette approche permet de prédire au NLO les spectres des observables.

### 3.3.1 L'interfaçage entre les générateurs ME et PS

Il existe plusieurs générateur ME LO proposant des processus dont les états finals comportent une haute multiplicité de jets et pouvant être interfaçés avec des générateurs PS. Entre autres, ALPGEN [24] et MADGRAPH [23] peuvent être interfacé avec PYTHIA [26] ou HERWIG [27]. Comme les études effectuées aux chapitres suivants feront usage d'échantillons MADGRAPH interfaçés avec PYTHIA, la description de l'appariement propre à ces générateurs sera explicitée dans ce qui suit.

L'appariement de générateurs NLO avec des générateurs PS demande une procédure dédiée, plus compliquée, et seuls MC@NLO [122] et POWHEG [123] l'utilisent aujourd'hui. Nous en examinerons brièvement le principe dans la suite.

#### Interfaçage MADGRAPH-PYTHIA : appariement par la méthode MLM

Il existe deux grandes procédures d'appariement ME-PS : CKKW [124] (implémentée dans SHERPA [119]) et MLM [125] (implémentée pour l'interfaçage de MADGRAPH ou ALPGEN avec PYTHIA). Soit un processus  $pp \rightarrow X + N$  jets dont chacune des amplitudes des processus  $pp \rightarrow X + n$  jets ( $0 \leq n \leq N$ ) est calculé au niveau élément de matrice avec les critères minimaux sur les jets  $p_T > p_{T,min}$ ,  $|\eta| < \eta_{max}$ ,  $\Delta R_{jj} > R_{min}$  (distance minimale entre deux jets). L'interfaçage MLM avec la gerbe partonique s'effectue de la manière suivante [126] :

- 1) Pour chacune des  $N + 1$  contributions, le générateur PS génère des événements et effectue la fragmentation des partons dans l'état final. Pour chaque événement, un certain nombre de partons supplémentaires sont émis au cours de l'évolution de la gerbe par branchements successifs (radiations dans l'état initial et final).
- 2) Les partons sont hadronisés. Un algorithme de type  $k_T$  rassemble les produits d'hadronisation en jets, eux-mêmes regroupés en amas de jets si ils vérifient  $\Delta R_{jj} < R_{min}$  et  $p_{T,jj} > p_{T,min}$ .
- 3) Le jet le plus proche du parton le plus dur est considéré comme apparié si la distance  $\Delta R$  est inférieure à  $1.5 * R_{min}$ . On passe au second jet plus dur, etc., jusqu'à ce que tous les partons soient appariés. Si un parton non apparié est rencontré, l'événement est rejeté. Sinon, l'événement est considéré comme pleinement apparié.
- 4) Si une fois que tous les partons donnés par le calcul ME sont appariés il subsiste encore des jets non-appariés venant de la gerbe partonique, il y a deux possibilités. Si le nombre  $n$  de partons du processus dur considéré est inférieur à  $N$ , alors l'événement est rejeté, car s'il était gardé il y aurait double-comptage avec le processus comportant  $n + 1$  jets de l'événement dur. A l'inverse si  $n = N$ , tous les jets supplémentaires de la gerbe partonique sont gardés, et l'événement est conservé.
- 5) Dans le cas de MADGRAPH, les événements appariés correspondant aux  $N + 1$  processus durs sont rassemblés dans un seul échantillon (au contraire d'ALPGEN qui les garde séparés).

Trois processus en particulier utilisés dans les analyses des chapitres suivants ont été générés avec

MADGRAPH interfaçé avec PYTHIA : le processus QCD dijet (comportant jusqu'à 2 jets supplémentaires),  $\gamma$ +jet (jusqu'à 3 jets supplémentaires) et  $\gamma\gamma$ +jet en particulier (jusqu'à 1 jet supplémentaire). La procédure d'appariement assure que les jets supplémentaires sont décrits comme des émissions réelles au niveau ME et non dans l'approximation des jets mous et collinéaires comme ils l'auraient été sans interfaçage. Toutefois, les corrections virtuelles ne sont pas prises en compte, ni au niveau ME, ni au niveau PS. A ce jour, il n'existe pas de générateur ME NLO interfaçable avec un générateur PS pour ces processus. Prendre en compte les corrections NLO nécessitera donc un travail de repondération (voir 3.3.2).

### La méthode du générateur MC@NLO

MC@NLO [122] est le premier générateur à avoir proposé un appariement entre une description NLO des partons du processus dur et les partons supplémentaires dues à la gerbe partonique. Il n'existe pas à ce jour de générateur à gerbe partonique utilisant un formalisme NLL satisfaisant. L'appariement a donc lieu avec un générateur PS classique (HERWIG [27]) dans une description LL améliorée. MC@NLO possède les propriétés suivantes :

- Les sections efficaces sont calculées à la précision NLO (ainsi que les sections efficaces différentielles obtenues à partir des événements).
- Les émissions réelles dures sont traitées comme dans le calcul NLO.
- Les émissions réelles molles/collinéaires sont traitées comme dans le générateur PS (LL amélioré).
- L'appariement entre les régions dures et molles est effectué de manière lisse.
- L'hadronisation est effectuée au niveau PS.
- A l'inverse de l'appariement MLM, le noyau ME fournit à HERWIG des événements pour lesquels le veto anti-double comptage a déjà été effectué.

Dans les analyses, nous utiliserons un échantillon  $gg \rightarrow H \rightarrow \gamma\gamma$  généré avec MC@NLO. Toutefois, une description NNLO de ce processus est disponible et ici aussi, une repondération s'avère nécessaire pour prendre en compte les effets de QCD perturbative les plus précis.

### 3.3.2 La repondération des événements PS avec les distributions ME aux ordres supérieurs

Les générateurs à gerbe partonique sont capables de décrire la plupart des processus dont les signatures sont recherchées au LHC. A part pour MC@NLO ou POWHEG, la section efficace est évaluée au LO. Or il est courant que les calculs ME aux ordres supérieurs donnent une section efficace beaucoup plus importante (pour un calcul NLO il n'est pas rare que la section efficace s'avère deux fois supérieure au résultat LO). Pour prendre en compte ces effets dus aux ordres supérieurs, l'approche habituelle consiste à affecter les événements d'un poids appelé "K-facteur" :

$$K = \frac{\sigma_{h.o.}}{\sigma_{PS}}$$

Où  $\sigma_{h.o.}$  est la section efficace calculée aux ordres supérieurs (en général NLO ou NNLO) et  $\sigma_{PS}$  est la section efficace généralement au LO donnée par le générateur PS. Il va de soi que la repondération des événements PS par un tel K-facteur change seulement la section efficace totale du processus, tandis que la forme des variables cinématiques reste la même que dans la description PS. Pour les canaux qui dépendent peu de la cinématique des événements, tel le canal  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ), où la réduction du bruit de fond passe surtout par l'identification et l'isolation des leptons, l'approche d'un K-facteur constant comme défini ci-dessus est en général suffisante [127].

### Repondération à l'aide d'une ou plusieurs variables

Si en revanche l'analyse d'un canal demande la prise en compte d'effets fins de cinématique (tel  $H \rightarrow WW$  ou  $H \rightarrow \gamma\gamma$ ), il est préférable de définir et d'utiliser un K-facteur qui dépendra des variables cinématiques discriminantes. On peut en effet définir un K-facteur qui dépend des sections efficaces

différentielles PS et aux ordres supérieurs [128] :

$$K(\xi) = \left( \frac{d\sigma_{h.o.}(\xi)}{d\xi} \right) / \left( \frac{d\sigma_{PS}(\xi)}{d\xi} \right)$$

Dans cette formule, le K-facteur dépend explicitement de l'observable  $\xi$ . Plus les effets aux ordres supérieurs se font ressentir pour une valeur de  $\xi$  donnée, plus  $K(\xi)$  sera différent de 1. Le choix de la variable  $\xi$  utilisée pour la repondération est donc crucial : il s'agit de choisir la variable cinématique la plus affectée par les effets aux ordres supérieurs. Lorsque  $\xi$  est bien choisie, les distributions repondérées des autres observables seront proches des sections efficaces différentielles calculées aux ordres supérieurs. Généralement l'impulsion transverse du système de particules dans l'état final est choisie comme variable  $\xi$ , parce qu'elle est supposée être la variable qui contient le plus d'informations des ordres supérieurs sur l'évènement (au LO, l'impulsion transverse du système est nulle).

Dans certains cas, une repondération plus adéquate devrait en fait dépendre de deux variables cinématiques  $\xi$  et  $\psi$  [129], par exemple l'impulsion transverse et la rapidité de la particule  $F$ . Le K-facteur s'écrit alors :

$$K(\xi, \psi) = \left( \frac{d^2\sigma_{h.o.}(\xi, \psi)}{d\xi d\psi} \right) / \left( \frac{d^2\sigma_{PS}(\xi, \psi)}{d\xi d\psi} \right)$$

Il s'avère que pour le processus de production du boson de Higgs par fusion de gluon  $gg \rightarrow H$ , une repondération utilisant l'impulsion transverse du boson de Higgs contient déjà une grande partie de l'information sur les corrections aux ordres supérieurs, mais que l'information apportée par la rapidité n'est pas négligeable et aide à reproduire les distributions NNLO.

### Limites de la technique de repondération

La limitation la plus évidente d'une telle approche relève du choix des coupures appliquées dans la sélection des évènements au niveau partonique pour le générateur ME aux ordres supérieurs et au niveau particule pour le générateur PS. Seules des coupures affectant la cinématique du processus ainsi que sur l'isolation des particules sont permises dans la mesure où elles trouvent un équivalent entre le niveau partonique et le niveau particule. Une double difficulté provient aussi des coupures d'isolation : d'une part la description partonique du générateur ME n'inclut pas les effets de la gerbe partonique (radiations QCD et évènement sous-jacent), donc l'énergie dans un cône autour des particules calculée avec un générateur PS sera plus grande que celle calculée avec le générateur ME aux ordres supérieurs. D'autre part la définition de l'isolation est différente dans les deux cas : au niveau partonique toute l'énergie du parton est prise en compte s'il est dans le cône, tandis qu'au niveau particule seulement une partie de l'énergie rentre dans le cône puisque l'hadronisation disperse les particules finales.

La technique de repondération ne prend pas en compte la cinématique des radiations QCD accompagnant le processus d'intérêt. Tant que les coupures choisies pour le calcul du K-facteur ne dépendent pas de la cinématique des radiations ou de leur multiplicité, cela ne pose pas de problème particulier. En revanche si l'analyse d'un processus demande de différencier le cas  $F + 0\text{jet}$ ,  $F + 1\text{jet}$ , etc., ou bien si un veto sur les jets centraux (comme dans l'analyse  $H \rightarrow WW$ ) est appliqué, il y a un risque pour que le taux d'évènements après coupure soit mal évalué avec le générateur PS repondéré. Ceci peut s'expliquer par le fait que les distributions aux ordres supérieurs utilisées pour la repondération sont calculées à un ordre fixe : les émissions réelles supplémentaires non prises en compte peuvent dès lors biaiser le résultat.

Un autre problème lié au précédent est celui de la prédiction des spectres cinématiques dans les régions proches des bords (par exemple dans la limite  $q_T \rightarrow 0$ ). Les générateurs ME aux ordres supérieurs utilisés pour la repondération effectuent les calculs à ordre fixe, tandis que les effets de resommation des gluons à tous les ordres sont présents avec la précision LL dans les générateurs à gerbe partonique. On peut donc considérer que pour des petites valeurs de l'impulsion transverse, le générateur PS est plus adéquat que le générateur ME à ordre fixe : il prédit un spectre physique, non divergent dans la limite

$q_T \rightarrow 0$ . La repondération des régions à bas  $q_T$  est délicate et il existe alors deux options. Un K-facteur constant, positif obtenu par moyenne sur les premières valeurs de  $q_T$  peut convenir, mais une approche probablement plus appropriée consisterait à utiliser un générateur ME aux ordres supérieurs qui inclut aussi les effets de la resommation.

### 3.4 Comparaison des prédictions théoriques aux données du Tevatron pour le processus $\gamma\gamma+X$

Les expériences CDF et D0 ont comparé les prédictions des programmes PYTHIA, DIPHOX, GAMMA2MC et RESBOS avec leurs mesures pour le processus  $\gamma\gamma+X$ . Récemment, les auteurs du générateur PS SHERPA [119] ont proposé une nouvelle modélisation des photons prompts [120] faisant intervenir un traitement démocratique des radiations QED et QCD au niveau de la gerbe partonique incluant un appariement avec les éléments de matrice associés. Ces prédictions ont aussi été comparées avec les données de CDF et D0.

#### 3.4.1 Section efficace $\gamma\gamma+X$ dans les données de CDF

Au mois de Mai 2010, les nouveaux résultats de CDF concernant l'analyse  $\gamma\gamma+X$  au Run II du Tevatron [130], pour une énergie dans le centre de masse de 1.96 TeV et une luminosité intégrée de  $5.4 fb^{-1}$  ont été publiés. Les critères de sélection appliqués aux photons sont  $E_T^{\gamma 1} > 17$  GeV et  $E_T^{\gamma 2} > 15$  GeV, dans la région de pseudo-rapidité  $\eta < 1.0$ .

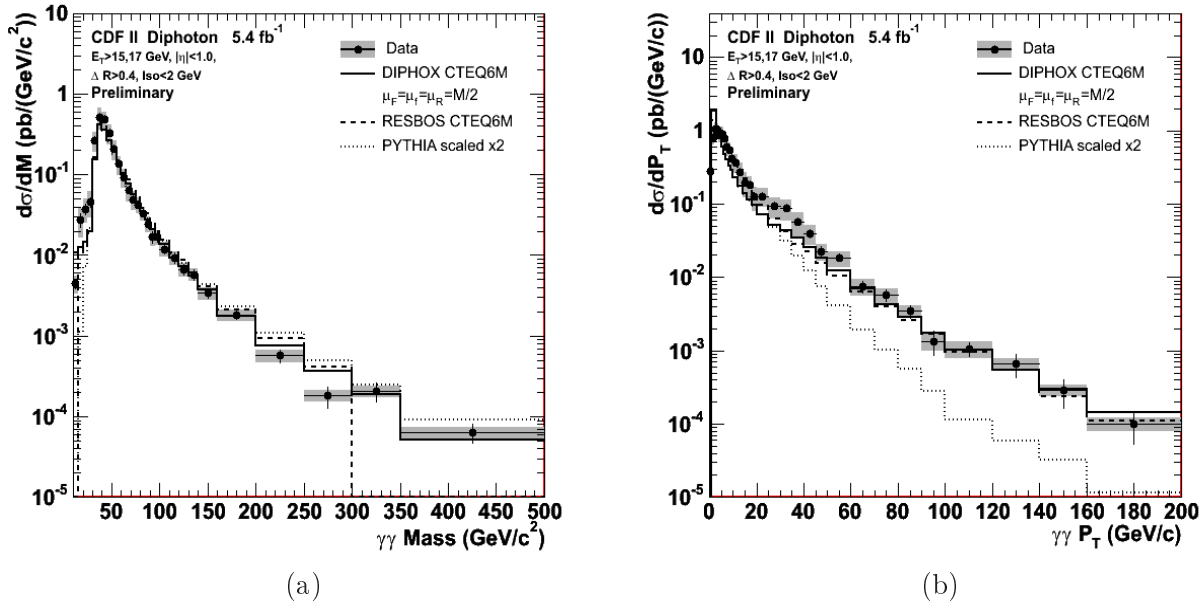


FIG. 3.6 – Comparaison des données de CDF [130] et des prédictions de DIPHOX (trait plein), RESBOS (traits rouges espacés) et PYTHIA (traits-points). Les prédictions de PYTHIA ont été repondérées par un facteur 2. (a) Masse invariante du diphoton. (b) Impulsion transverse du système diphoton.

Les données sur la figure 3.6 montrent le besoin d'une prédiction comme celle de RESBOS incluant les effets de resommation (la courbe de DIPHOX diverge pour  $q_T < 5$  GeV). L'accord est globalement bon pour la plage d'impulsion transverse  $q_T > 40$  GeV et la plage de masse invariante  $M_{\gamma\gamma} > 50$  GeV pour DIPHOX et RESBOS. Il faut toutefois noter que la contribution GAMMA2MC Box NLO n'a pas été ajoutée aux contributions Born et de fragmentations de DIPHOX. Pour ces deux spectres, les plus gros désaccords ont lieu pour  $q_T < 40$  GeV et  $M_{\gamma\gamma} < 50$  GeV, ce qui pourrait provenir de contributions




FIG. 3.7 – Angle  $\Delta\phi$  entre les deux photons pour les données de CDF [130] et les prédictions de DIPHOX (trait plein), RESBOS (traits rouges espacés) et PYTHIA (traits-points). Les prédictions de PYTHIA ont été repondérées par un facteur 2.

manquantes comme les diagrammes NNLO pour les processus Born et Box, un traitement complet de la composante de fragmentation double du même quark ou des tours de logarithmes manquantes dans les calcul au-delà du LL. Remarquons que ni DIPHOX ni RESBOS ne prédisent de bosse vers  $q_T \simeq 30$  GeV contrairement à ce qui est observé dans les données : il pourrait s'agir d'un artefact du au calcul de l'énergie d'isolation. Le traitement des composantes de fragmentation n'est pas complet dans RESBOS et conduit à une sous-estimation du taux d'évènements à bas  $\Delta\phi$  (voir fig. 3.7), où sont attendus la plupart des évènements de fragmentation [113] (et qui correspondent aussi à  $q_T > M_{\gamma\gamma}$ ). À l'inverse, la resommation incluse dans RESBOS reproduit mieux les données que DIPHOX pour  $\Delta\phi > \pi/2$  (DIPHOX tend à sous-estimer le taux d'évènements). Les générateurs DIPHOX et RESBOS semblent donc complémentaires en ce qu'ils décrivent adéquatement chacun une région de l'espace de phase différente, avec un accord pour les valeurs moyennes des sections efficaces différentielles en fonction de  $q_T$  et  $M_{\gamma\gamma}$ .

Les prédictions de SHERPA (voir figure 3.8) ont aussi été comparées aux données de CDF [131] (pour  $207 \text{ pb}^{-1}$ ) ainsi qu'aux prédictions de DIPHOX (incluant la contribution de fusion de gluons calculée avec GAMMA2MC) et de RESBOS pour le spectre  $q_T$ , avec les mêmes critères de sélection. SHERPA montre un bon accord global avec les données.

### 3.4.2 Section efficace $\gamma\gamma+X$ dans les données de D0

Fin Février 2010 est parue une analyse du processus  $\gamma\gamma+X$  par la collaboration D0 [132] avec une luminosité intégrée de  $4,2 \text{ fb}^{-1}$  et une énergie dans le centre de masse de 1,96 TeV. Les mesures des sections efficaces doublement différentielles ont été présentées pour la première fois. Les distributions des sections efficaces différentielles mesurées sont montrées figure 3.9 pour les observables  $q_T$ ,  $M_{\gamma\gamma}$ ,  $\Delta\phi$  et  $\cos(\theta^*)$  ( $\cos(\theta^*)$  est le cosinus de l'angle entre la direction du diphoton et l'un des photons, dans le référentiel du diphoton). Les critères de sélection suivants ont été appliqués : sur les variables cinématiques,  $E_T^{\gamma 1} > 21$  GeV et  $E_T^{\gamma 2} > 20$ ,  $|\eta| < 0,9$ ,  $30 < M_{\gamma\gamma} < 350$  GeV,  $q_T < M_{\gamma\gamma}$ ,  $\Delta R(\gamma_1, \gamma_2) > 0,4$ ,  $\Delta\phi > \pi/2$ , et un critère d'isolation  $E_{T,iso} < 2,5$  GeV dans un cône  $\Delta R < 0,4$  autour des photons.

Comme attendu, PYTHIA prédit systématiquement une section efficace plus petite que celle mesurée dans les données. La distribution de la masse invariante  $M_{\gamma\gamma}$  montre un bon accord entre les données et les prédictions de DIPHOX et RESBOS sur toute la plage mesurée. Le spectre  $q_T$  montre un excès d'évène-




FIG. 3.8 – Section efficaces différentielle  $\gamma\gamma+X$  pour l’observable  $q_T$ , pour les données de CDF et les prédictions de SHERPA, DIPHOX et PYTHIA 3.8.

ments dans les données pour  $q_T > 30$  GeV par rapport aux prédictions. Les prédictions de DIPHOX divergent quand  $q_T \rightarrow 0$  et sont en désaccord avec les données pour  $10 < q_T < 75$  GeV. Il est à noter qu’au contraire des mesures de CDF, Gamma2MC n’a pas été utilisé pour le diagramme Box qui est donc seulement inclu au LO. Les distributions angulaires montrent un excès d’évènements dans les données qui augmente à mesure que  $\Delta\phi$  et  $\cos(\theta^*)$  décroissent. Il faut aussi noter que les coupures  $q_T < M_{\gamma\gamma}$ ,  $\Delta R(\gamma_1, \gamma_2) > 0.4$ ,  $\Delta\phi > \pi/2$  correspondent à la région de l’espace de phase où les prédictions de Resbos sont les plus cohérentes (régions où les contributions dues à la resommation sont valides).

Les sections efficaces doublement différentielles pour les observables  $q_T$ ,  $\Delta\phi$  et  $\cos(\theta^*)$  ont été mesurées dans trois régions de masse invariante :  $30 < M_{\gamma\gamma} < 50$  GeV,  $50 < M_{\gamma\gamma} < 80$  GeV et  $80 < M_{\gamma\gamma} < 350$  GeV. L’accord est globalement bon pour les hautes valeurs de  $M_{\gamma\gamma}$  mais se dégrade lorsque  $M_{\gamma\gamma}$  diminue. On montrera simplement ici les distributions de  $q_T$  pour les trois régions de masse invariante (voire figure 3.10). La prédiction d’un nombre trop faible d’évènements à basse masse invariante peut aussi être comprise comme étant dûe à la non prise en compte de la composante de fragmentation double par le même quark (pour lesquels les deux photons sont émis colinéairement).

La figure 3.11 montre la comparaison des prédictions de SHERPA avec les données de D0 pour le canal  $\gamma\gamma+X$ , avec les mêmes critères de sélection que précédemment. L’accord entre données et prédictions semble meilleur avec SHERPA qu’avec les RESBOS ou DIPHOX (toutefois l’écart est exprimé en déviation  $\sigma$  plutôt qu’en pourcentage, ce qui rend la comparaison difficile). L’accord est très bon pour la distribution  $\Delta\phi$ , ce qui implique que les composantes de fragmentation ont été prises adéquatement en compte par SHERPA. Cela tend aussi à signifier que les corrections virtuelles NLO ne semblent pas primordiales pour l’estimation du taux d’évènements  $\gamma\gamma+X$  dans les collisions  $p\bar{p}$ , et qu’une approche utilisant l’appariement ME-PS pour les radiations réelles suffit dans la limite des incertitudes statistiques et systématiques de la mesure.

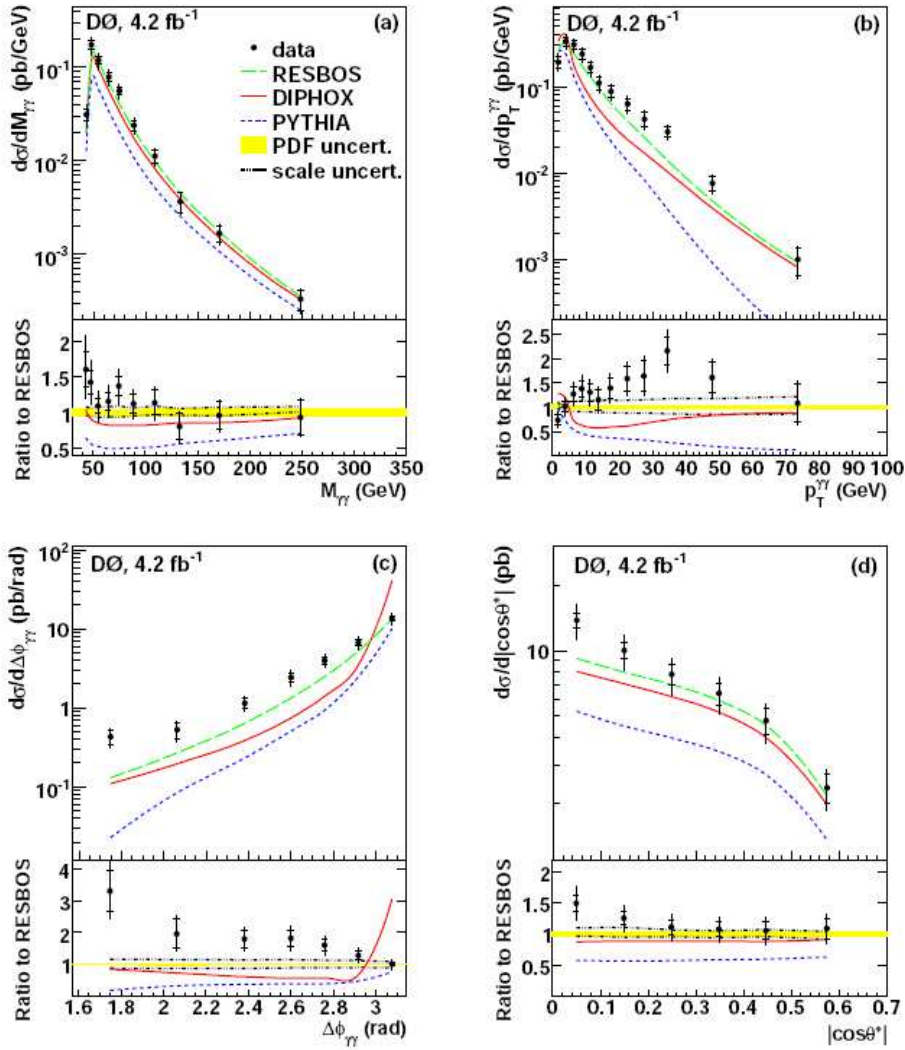


FIG. 3.9 – Sections efficaces différentielles  $\gamma\gamma+X$  pour les observables  $M_{\gamma\gamma}$  (a),  $q_T$  (b),  $\Delta\phi$  (c) et  $\cos(\theta^*)$  (d), pour les données et les prédictions de DIPHOX, RESBOS et PYTHIA. Le rapport des sections efficaces divisées par celles obtenues avec RESBOS est présenté en-dessous de chaque distribution.




FIG. 3.10 – Sections efficaces différentielles  $\gamma\gamma+X$  pour l'observable  $q_T$  dans la plage de masse invariante  $30 < M_{\gamma\gamma} < 50$  GeV (à gauche),  $50 < M_{\gamma\gamma} < 80$  GeV (au milieu) et  $80 < M_{\gamma\gamma} < 350$  GeV (à droite), pour les données et les prédictions de DIPHOX, RESBOS et PYTHIA. Le rapport des sections efficaces divisées par celles obtenues avec RESBOS est présenté en-dessous de chaque distribution.



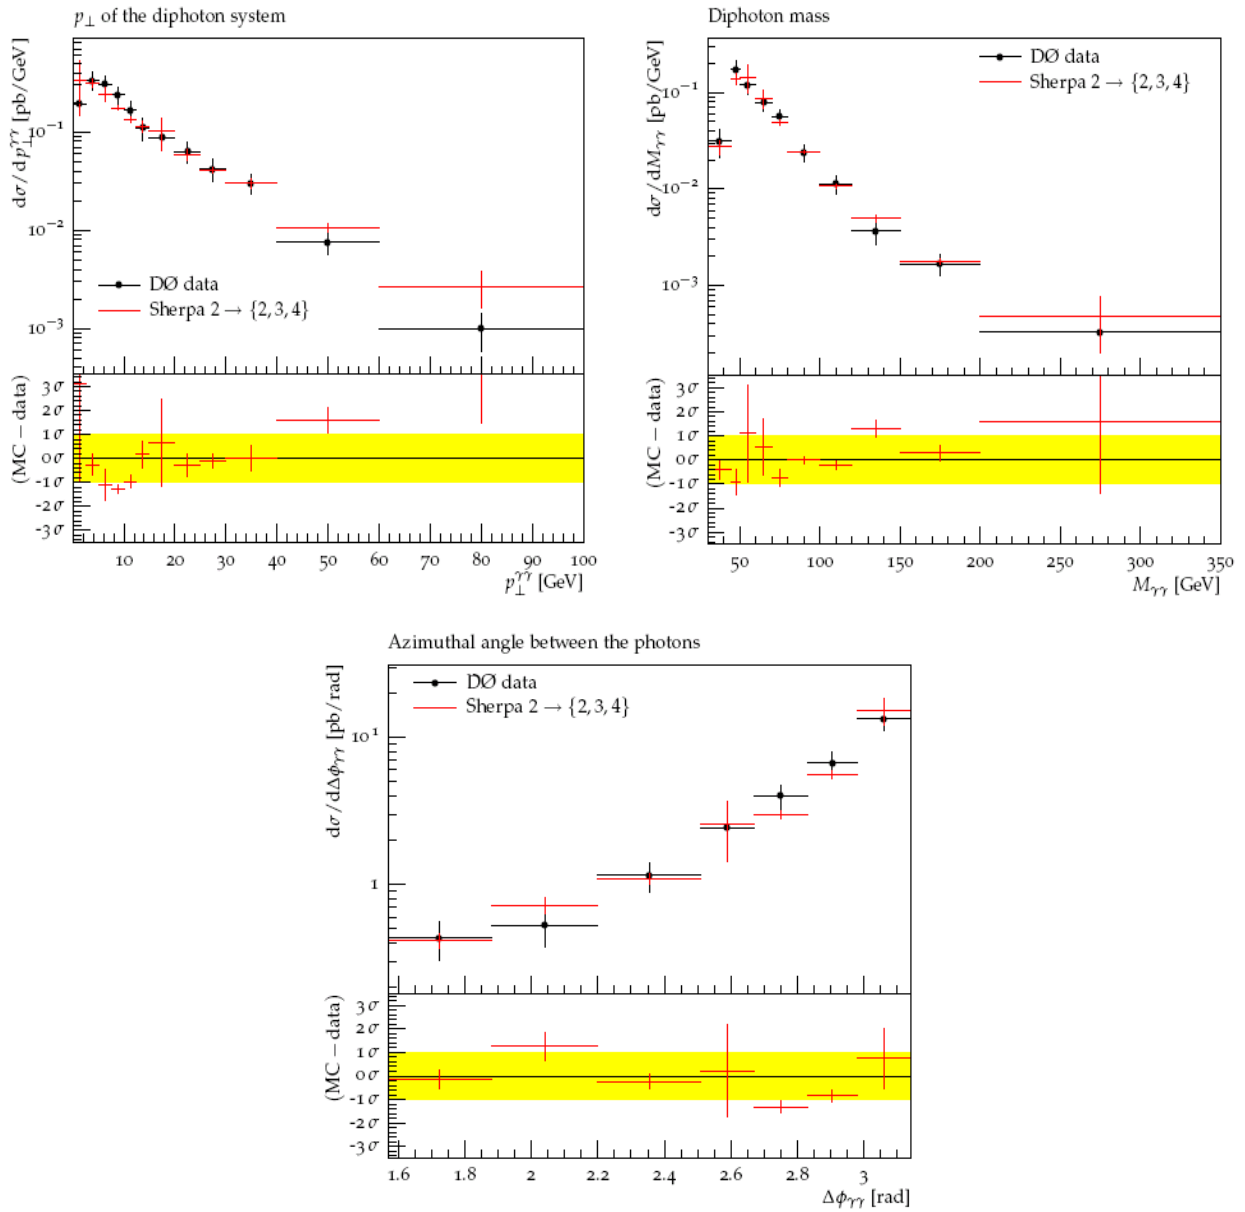


FIG. 3.11 – Section efficaces différentielle  $\gamma\gamma+X$  des observables  $q_T$  (en haut à gauche),  $M_{\gamma\gamma}$  (en haut à droite) et  $\Delta\phi$  (en bas), pour les données de D0 et les prédictions de SHERPA.



## Chapitre 4

# Récupération des photons de bremsstrahlung interne dans le canal $H \rightarrow ZZ^* \rightarrow 4l$

Le phénomène de bremsstrahlung (émission d'un photon par une particule chargée) peut apparaître dès qu'une particule chargée accélère ou décélère. L'accélération/décélération des particules chargées dans la matière est due aux déviations par rapport à la trajectoire initiale en fonction du champ fluctuant généré par les noyaux et électrons. L'émission de photons par une particule chargée dans la matière est appelée *bremsstrahlung externe*. C'est un phénomène dominant devant l'ionisation pour les électrons ayant une énergie de l'ordre du GeV comme c'est le cas au LHC, et qui est pris en compte lors de la reconstruction des super-clusters. Le phénomène de bremsstrahlung peut aussi apparaître dans le vide. Lorsqu'un électron ou un muon est produit lors d'une interaction dure, il peut émettre un photon à l'état final ("Final State Radiation", FSR) avant d'atteindre le détecteur : c'est le phénomène de *bremsstrahlung interne*.

Le processus  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ) est un canal de recherche du boson de Higgs privilégié au LHC, dans la mesure où il peut permettre une découverte précoce dès les premières années d'exploitation du LHC à 10 ou 14 TeV (environ  $5 fb^{-1}$  pour un boson de Higgs de masse 180 GeV [88]). La recherche dans ce canal est complémentaire à la recherche dans le canal  $H \rightarrow WW \rightarrow 2l2\nu$  puisqu'il est le plus sensible des canaux pour la plage de masse  $130 < m_H < 150$  GeV et  $m_H > 180$  GeV (voir figure 2.17). Une telle sensibilité est due au fait que les leptons chargés<sup>1</sup> constituent une signature claire, en raison d'une bonne résolution mesurée dans les chambres à muons et dans le ECAL et le trajectographe pour les électrons. Le calcul de la signification pour le canal  $H \rightarrow ZZ^* \rightarrow 4l$ , dans sa version la plus simple (et la plus robuste) demande de compter le nombre d'événements de signal et de bruit de fond dans une certaine fenêtre de masse autour de la masse attendue du boson de Higgs. Au-delà de la rejection du bruit de fond, l'enjeu de l'analyse va être de rassembler le plus d'événements de signal possible dans une plage de masse invariante étroite autour du pic de résonance du boson de Higgs afin d'augmenter la signification d'une observation. La récupération des photons de bremsstrahlung internes émis par les électrons ou les muons issus du boson de Higgs (voir schéma 4.1) peut aider à atteindre cet objectif en améliorant la résolution sur la masse invariante du boson de Higgs.

Dans un premier temps, nous estimerons par des études au niveau générateur le taux de photons FSR qui peuvent potentiellement être récupérés, et nous verrons l'impact de cette récupération sur le pic de masse. L'analyse qui va être développée dans la suite de ce chapitre se fonde sur un travail antérieur [133], qui proposait une méthode de récupération d'un photon FSR au maximum par événement dans le canal  $H \rightarrow ZZ^* \rightarrow 2e2\mu$ . Une nouvelle méthode "multi-brem" de récupération d'un nombre variable de photons a été mise en oeuvre pour les trois canaux  $H \rightarrow ZZ^* \rightarrow 4e$ ,  $H \rightarrow ZZ^* \rightarrow 2e2\mu$  et  $H \rightarrow ZZ^* \rightarrow 4\mu$ , qui permet d'obtenir une meilleure résolution sur la masse des bosons  $Z$  et du boson de Higgs. Ce travail a également été présenté dans les notes internes CMS AN 2008/050 [134] et CMS AN 2010/237 [135]. La

<sup>1</sup>Dans toute la suite de ce chapitre, les leptons désigneront les électrons et les muons (le canal de désintégration du boson de Higgs en leptons taus fait l'objet d'une analyse dédiée qui ne sera pas couverte dans cette présente étude).




FIG. 4.1 – Diagramme de Feynman pour la désintégration  $H \rightarrow ZZ \rightarrow 4l$ , ici représenté pour le mode de production via fusion de gluons et avec deux photons FSR émis par les leptons dans l’état final.

méthode sera d’abord décrite dans le détail, puis les performances seront comparées dans chacun des trois canaux et la signifi­cance pour les trois canaux combinés sera estimée. Nous montrerons que la méthode “multi-brem” permet d’augmenter la signifi­cance moyenne d’environ 5% pour les masses du boson de Higgs  $m_H > 180$  GeV. Deux analyses ont été faites pour contrôler la méthode à partir des données : les distributions des variables pertinentes pour la récupération des FSR ont été comparées dans la simulation et les données de muons cosmiques, et une méthode d’estimation du taux de faux FSR à partir des données par une variante de la technique des “cônes aléatoires” a été mise au point.

## 4.1 Motivation

La masse invariante du boson de Higgs se désintégrant en 4 leptons (de quadri-impulsions  $p_{1\dots 4}$ ) s’écrit  $M_H^2 = |p_1 + p_2 + p_3 + p_4|^2$ . Si un ou plusieurs leptons émettent des photons, la non-récupération des photons de bremsstrahlung occasionne une sous-estimation de la masse invariante du boson de Higgs. L’idée de la récupération des photons de bremsstrahlung interne est de ramener ces événements dans le pic de masse - idéalement, il serait nécessaire de récupérer tous les photons émis par les leptons.

Les trois graphiques 4.2 montrent l’impact au niveau particule de la récupération des photons FSR ayant une énergie transverse  $E_T > 5$  GeV, dans le canal  $H \rightarrow ZZ^* \rightarrow 2e2\mu$  pour un boson de Higgs de masse nominale  $m_H = 195$  GeV dont l’échantillon a été généré avec Pythia [26]. L’émission des photons FSR par Pythia a été décrite section 3.2.2. La résolution  $\sigma$ , la hauteur  $h$  et la valeur moyenne  $m$  du pic de masse invariante sont obtenus par un ajustement itératif avec une distribution gaussienne utilisant toute la statistique disponible (environ 4700 événements). Une figure de mérite utilisée pour quantifier l’effet de la récupération qui sera utilisée par la suite est la hauteur obtenue par l’ajustement divisée par la résolution ( $h/\sigma$ ). Le tableau 4.3 résume l’amélioration sur  $\sigma$  et  $h/\sigma$  pour le pic de masse invariante du boson de Higgs, du  $Z \rightarrow \mu^+\mu^-$  et du  $Z \rightarrow e^+e^-$ . L’amélioration sur la résolution en masse est supérieure à 5% pour les deux  $Z^0$  et a pour résultat d’améliorer de 7,7% la résolution sur la masse du boson de Higgs. L’amélioration est la plus visible dans le canal  $Z \rightarrow e^+e^-$ , car après sélection les électrons émettent deux fois plus de photons que les muons du fait de leur masse bien inférieure à celle des muons. De plus, les graphiques 4.2 montrent aussi une amélioration de la valeur moyenne ajustée du pic de masse invariante, légèrement plus proche de la masse nominale des bosons  $Z$  et du boson de Higgs.

Les chiffres précédents montrent qu’il est important de récupérer les photons FSR émis par les leptons pour l’obtention d’un pic de masse invariante plus ramassé autour de la masse nominale du boson de Higgs et des bosons  $Z$ . Toutefois ces chiffres sont obtenus par une analyse au niveau particule où l’information sur la provenance des photons est disponible. Au niveau reconstruit, l’enjeu est de proposer une méthode qui récupérera le plus de photons FSR possibles sans être contaminé par les photons ayant une autre origine. Une telle méthode est décrite au paragraphe suivant.

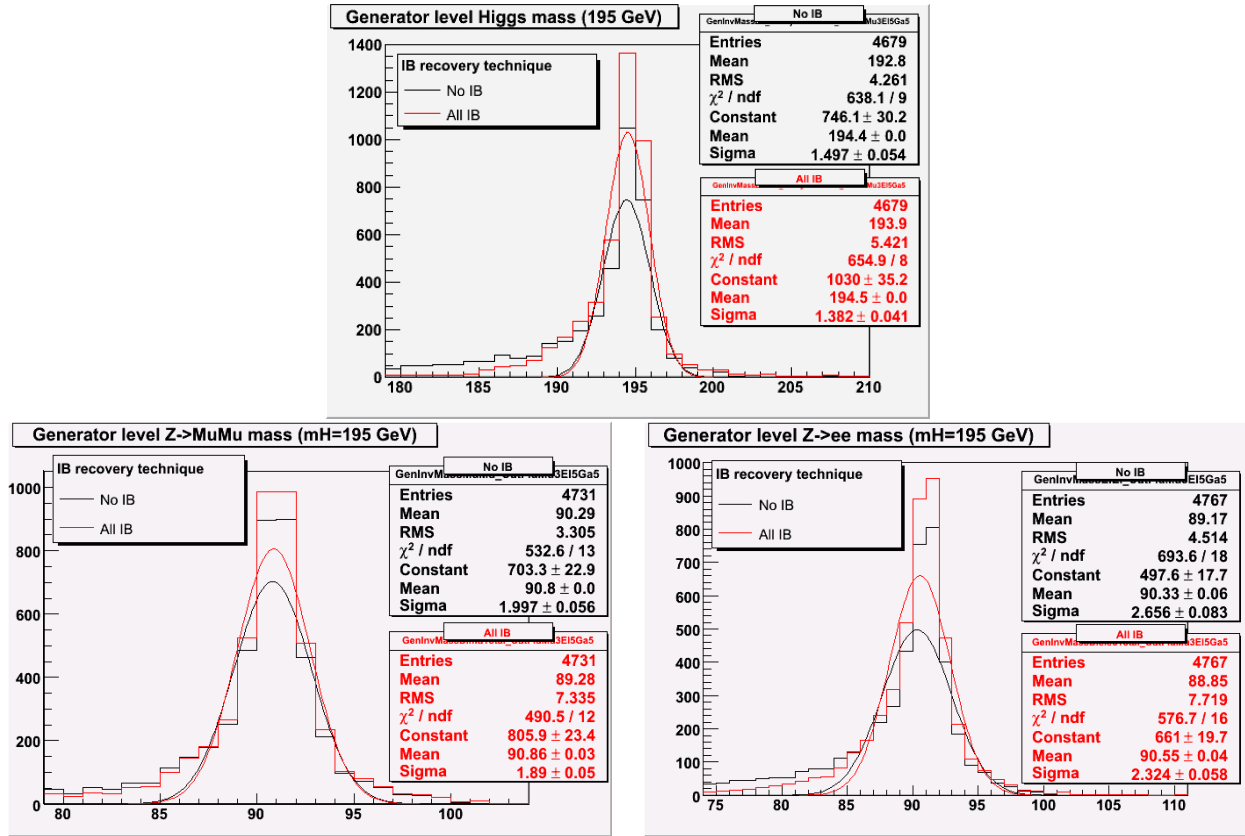


FIG. 4.2 – Masse invariante niveau particule : du boson de Higgs (en haut), de  $Z \rightarrow \mu^+\mu^-$  (à gauche) et de  $Z \rightarrow e^+e^-$  (à droite), sans récupération des photons FSR (en noir) et avec récupération de tous les photons FSR ayant une énergie transverse  $E_T > 5$  GeV, dans un échantillon  $H \rightarrow ZZ^* \rightarrow 2e2\mu$  avec une masse du boson de Higgs de 195 GeV.

## 4.2 Présentation de l'analyse $H \rightarrow ZZ^* \rightarrow 4l$

Les trois processus  $H \rightarrow ZZ^* \rightarrow 4\mu$ ,  $H \rightarrow ZZ^* \rightarrow 2e2\mu$  et  $H \rightarrow ZZ^* \rightarrow 4e$  sont réunis dans un même cadre d'analyse depuis la note interne [134], avec une énergie dans le centre de masse de 14 TeV. De nombreuses améliorations ont depuis été apportées à l'analyse, qui ont donné lieu à une autre note interne [135] avec une énergie dans le centre de masse de 10 TeV. La méthode de récupération des photons de bremsstrahlung interne est décrite dans les deux notes, et constitue un raffinement de l'analyse qui est gardé comme option et n'est pas pour le moment utilisé pour les résultats finals. La récupération des photons FSR est aussi implémentée dans le code d'analyse  $H \rightarrow ZZ^* \rightarrow 4l$  ( $l = e, \mu$ ) [136], avec une option qui permet de l'activer ou non et de choisir les valeurs seuils pour les différents paramètres de la méthode "multi-brem" et son amélioration "KeepCloseToZ".

Dans cette section, nous décrivons la chaîne d'analyse du canal  $H \rightarrow ZZ^* \rightarrow 4l$ , telle qu'elle est appliquée dans sa version la plus simple dans la note [135]. Nous présenterons d'abord les échantillons

Canal	Résolution $\sigma$	Figure de mérite $h/\sigma$
$H \rightarrow ZZ^* \rightarrow 2e2\mu$	7,7% meilleur	+49,5%
$Z \rightarrow \mu^+\mu^-$	5,4% meilleur	+21,1%
$Z \rightarrow e^+e^-$	12,5% meilleur	+32,5%

FIG. 4.3 – Performances niveau particule de la récupération des photons FSR sur les pics de masse du boson de Higgs et des bosons  $Z$  issus de sa désintégration, pour un boson de Higgs de masse de 195 GeV.

Processus	Section efficace
$H \rightarrow ZZ^* \rightarrow 4l$ ( $m_H = 115 - 250$ GeV)	4-50 fb
$q\bar{q} \rightarrow ZZ^* \rightarrow 4l$	255,15 fb
$gg \rightarrow ZZ^* \rightarrow 4l$	19,9 fb
$Zbb \rightarrow llbb$	93,3 fb
$t\bar{t} \rightarrow WWbb$	410,1 pb
$W$ +jets	40000 pb
$Z$ +jets	7096 pb
QCD dijet	1457159248 pb

FIG. 4.4 – Sections efficaces aux ordres supérieurs à 10 TeV dans le centre de masse, pour le signal et les bruits de fond de l’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  (dans le tableau,  $l$  se réfère à  $e, \mu, \tau$ ).

Masse nominale du boson de Higgs	Section efficace
115 GeV	2.978 fb
130 GeV	11.129 fb
145 GeV	18.375 fb
160 GeV	8.187 fb
175 GeV	5.097 fb
185 GeV	20.865 fb
195 GeV	29.728 fb
205 GeV	30.166 fb
250 GeV	23.571 fb

FIG. 4.5 – Valeur des sections efficaces du signal  $H \rightarrow ZZ^* \rightarrow 4l$  pour quelques masses nominales du boson de Higgs, aux ordres supérieurs à 10 TeV dans le centre de masse, pour le signal et les bruits de fond de l’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  (dans le tableau,  $l$  se réfère à  $e, \mu, \tau$ ).

utilisés pour le signal et les bruits de fond. Les voies de déclenchement choisies pour une première sélection des évènements seront ensuite décrites, ainsi que la reconstruction, l’identification et l’isolation des électrons et des muons. L’analyse est effectuée en plusieurs étapes chargées de réduire progressivement les différents bruits de fond : tout d’abord l’écrémage (“skimming”), puis la préselection, avant la sélection finale proprement dite. Enfin, les sensibilités obtenues pour une luminosité de  $1 \text{ fb}^{-1}$  avec une énergie dans le centre de masse de 10 TeV seront présentées.

#### 4.2.1 Signal et bruits de fond

Le signal  $H \rightarrow ZZ^* \rightarrow 4l$  (inclusif :  $l = e, \mu, \tau$ ) a été généré avec Pythia [26], pour différentes masses du boson de Higgs comprises dans la plage  $115 < m_H < 250$  GeV. Les principaux bruits de fond en fin d’analyse sont les processus  $q\bar{q} \rightarrow ZZ^* \rightarrow 4l$ ,  $Zbb \rightarrow llbb$  et  $t\bar{t} \rightarrow WWbb$  (généré avec Madgraph [23]). Les autres bruits de fond important à différentes étapes de l’analyse sont  $W$ +jets (Madgraph),  $Z$ +jets (Pythia), et le processus de QCD di-jets (Pythia). Tous les échantillons ont été générés à l’arbre (Madgraph inclut aussi les contributions réelles aux ordres supérieurs en tenant compte des jets supplémentaires). Toutes les section efficaces inclusives LO des bruits de fond sont repondérées avec les sections efficaces inclusives NLO, sauf pour le signal, pour lequel la section efficace totale est calculée avec la contribution de fusion de gluons au NNLO, de fusion de bosons vecteurs et production associée avec un boson vecteur au NLO, production associée avec une paire  $t\bar{t}$  au LO [137]. Dans le cas particulier du processus  $ZZ$ , la section efficace NLO tient aussi compte du mécanisme de fusion de gluon (au LO) qui contribue à environ 20% de la section efficace  $q\bar{q} \rightarrow ZZ$  LO. Les sections efficaces pour les différents processus sont résumées sur le tableau 4.4 et détaillées pour différentes masses nominales du boson de Higgs dans le tableau 4.5.

Voie de déclenchement	Objet de déclenchement	Seuil L1 (GeV)	Seuil HLT (GeV)
HLT_IsoEle15_L1I	$e$ isolé	12	15
HLT_IsoEle18_L1R	$e$ relâché	15	18
HLT_DoubleIsoEle10_L1I	Double $e$ isolé	8,8	10,10
HLT_DoubleIsoEle12_L1R	Double $e$ relâché	10,10	12,12
HLT_IsoMu11	$\mu$ isolé	7	11
HLT_Mu15	$\mu$ relâché	10	15
HLT_DoubleMu3	Double $\mu$ relâché	0,0	3,3

FIG. 4.6 – Voies de déclenchement pour l’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  et une luminosité de  $L = 2 \times 10^{30} \text{ cm}^2 \text{ s}^{-1}$ .

### 4.2.2 Déclenchement

L’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  a été menée dans l’hypothèse d’une luminosité au démarrage de  $L = 2 \times 10^{30} \text{ cm}^2 \text{ s}^{-1}$ . La bande passante permet de déclencher sur des leptons de moins de 20 GeV, ce qui est important car si les leptons sont issus du  $Z$  et portent souvent une impulsion transverse de l’ordre de  $M_Z/2 \simeq 45$  GeV, le lepton ayant la plus petite impulsion transverse peut être de l’ordre de  $p_T \simeq 5$  GeV. Les seuils en impulsion transverse des différentes voies de déclenchement sont résumées sur le tableau 4.6. Les objets de déclenchement qui sont dit isolés demandent une énergie maximum dans un cône d’isolation autour de l’électron ou du muon, et ceux qui sont dit relâchés demandent une isolation plus lâche pour les électrons et aucune isolation sur les muons. Les événements sont gardés si ils passent l’une des 8 voies de déclenchement. L’efficacité simulée de sélection du signal (définie comme le rapport du nombre d’événements déclenchés sur le nombre d’événements générés) est supérieure à 99% sur toute la gamme de masse  $m_H$  recherchée du boson de Higgs, et augmente avec  $m_H$  (l’efficacité est supérieure à 99,9% pour  $m_H = 200$  GeV).

### 4.2.3 Reconstruction et identification des leptons

La **reconstruction des électrons** est effectuée par l’algorithme standard de reconstruction dont le schéma général a été décrit section 1.3.2. La procédure de reconstruction a ici été optimisée pour récupérer les électrons ayant une basse impulsion transverse,  $p_T > 5$  GeV. L’efficacité de reconstruction des électrons provenant du boson de Higgs (définie comme le nombre d’électrons issus du boson de Higgs reconstruits divisé par le nombre d’électrons issus du boson de Higgs générés) est d’environ 94% pour  $|\eta| < 1.1$  et décroît jusqu’à 60% en  $|\eta| \simeq 2.5$  du fait du volume d’acceptance du trajectographe. L’efficacité vaut 65% pour des électrons ayant  $p_T \simeq 5$  GeV et augmente jusqu’à atteindre un plateau de 94% d’efficacité pour des électrons ayant  $p_T > 25$  GeV. L’**identification des électrons** repose sur la classification des électrons en quatre catégories décrite section 1.3.2. Des coupures différentes en fonction des catégories sont appliquées sur les variables  $R9$ ,  $H/E$  (rapport de l’énergie transverse mesurée dans le HCAL divisée par l’énergie transverse mesurée dans le ECAL dans un cône  $\Delta R$  autour de l’électron) et les différences en  $\eta$  et  $\phi$  entre la position du super-cluster et de la trace extrapolée au niveau du ECAL. L’identification est optimisée pour préserver une haute efficacité tout en réduisant le nombre d’électrons ne provenant pas de la désintégration du boson de Higgs.

La **reconstruction des muons** s’effectue en deux temps : d’abord, seule l’information provenant des chambres à dérives (DT) et des chambres à pistes cathodiques (CSC) est utilisée. La trajectoire de ces candidats muons est ensuite extrapolée dans le trajectographe et éventuellement combinée à des coups pour former une trace. Le résultat de l’opération est appelé *muon global*, et son intérêt est d’améliorer la résolution par un facteur 10. L’efficacité de reconstruction des muons globaux du signal est supérieure à 97% sur toute la région  $|\eta| < 2.5$  et  $p_T > 5$  GeV.

### 4.2.4 Ecrémage et préselection

Le but de l’**écrémage** est de réduire le taux d’événements pour garder la quantité de données à un niveau raisonnable. L’efficacité du signal doit rester proche de 100%. Les bruits de fond réduits par

l'écrémage sont principalement les processus de QCD,  $W$ +jets et  $Z$ +jets (où des jets reculent contre des dileptons du  $Z$  ou les  $\nu$  issu du  $W$ ). L'étape d'écrémage demande la présence d'au moins deux leptons ( $e$  ou  $\mu$ ) ayant  $p_T > 10$  GeV, et d'un lepton supplémentaire ayant  $p_T > 5$  GeV. Dans le cas des électrons, il est aussi demandé qu'au moins trois électrons de  $p_T > 5$  GeV satisfassent une isolation lâche  $\sum_i p_{T,i}/p_T^e < 0.7$ , où  $p_{T,i}$  est l'impulsion de la trace  $i$  dans un cône  $0.015 < \Delta R < 0.25$  (seules les traces provenant du même point d'interaction que l'électron et de  $p_T > 1$  GeV sont prises en compte). C'est aussi à ce niveau de l'analyse que sont appliquées les coupures d'identification sur les électrons.

La **préselection** a pour but d'éliminer les événements inutiles qui ne passeraient pas les coupures suivantes de l'analyse tout en préservant l'efficacité du signal et l'espace de phase nécessaire aux études des bruits de fond. En terme de réduction du bruit de fond, la préselection ramène le taux d'évènements de QCD,  $W$ +jets et  $Z$ +jets à celui des bruits de fond  $t\bar{t}$ ,  $Zbb$  et  $ZZ$ , et améliore la combinatoire en réduisant aussi le nombre d'évènements ayant plus de 4 leptons candidats. La préselection contient quatre étapes qui demandent :

- Au moins deux paires  $l^+l^-$  de leptons identifiés de même saveur et de charges opposées. Les électrons doivent satisfaire  $p_T > 5$  GeV et  $|\eta| < 2.5$ , tandis que les muons doivent satisfaire  $p_T > 5$  GeV si  $|\eta| < 1.2$ , et  $p_T > 3$  GeV ainsi que  $p > 9$  GeV si  $1.2 < |\eta| < 2.4$ .
- Parmi ces paires, au moins une doit satisfaire le critère sur la masse invariante  $m_{l^+l^-} > 12$  GeV.
- Au moins une combinaison de deux paires doit avoir une masse invariante  $m_{ll} > 100$  GeV.
- Une isolation de même type que celle demandée lors de l'écrémage est cette fois appliquée sur les quatre leptons candidats.

#### 4.2.5 Variables discriminantes et sélection des événements

Les variables qui ont été trouvées comme les plus discriminantes sont les variables d'isolation, le paramètre d'impact des leptons, la masse invariante des dileptons et la masse invariante du candidat boson de Higgs. Ces variables seront d'abord décrites, puis les valeurs seuils des critères de sélection seront données tableau 4.7.

Les **variables d'isolation** utilisées sont différentes dans le cas de diélectrons ou de dimuons, mais utilisent dans les deux cas l'idée d'une combinaison de variables d'isolation dans plusieurs sous-détecteurs. Le rôle de l'isolation est de réduire le nombre de "faux" leptons provenant de jets (spécialement de jets de  $b$  des processus  $t\bar{t}$  et  $Zbb$ ). On définit  $\mu Iso$  pour les muons et  $e Iso$  pour les électrons :

$$\begin{aligned}\mu Iso &= 2\mu Iso_{track} + 1.5\mu Iso_{ECAL} + \mu Iso_{HCAL} \\ e Iso &= e Iso_{track} + e Iso_{HCAL}\end{aligned}$$

Où  $\mu Iso_{track}$  est la somme de l'énergie des traces,  $\mu Iso_{ECAL}$  la somme en énergie transverse des cristaux dans le ECAL et  $\mu Iso_{HCAL}$  la somme en énergie transverse des tours du HCAL autour de la trace du muon dans un cône  $0.015 < \Delta R < 0.3$ .  $e Iso_{track}$  a été définie précédemment à la section écrémage et  $e Iso_{HCAL}$  est la somme en énergie transverse des tours du HCAL dans un cône  $\Delta R < 0.25$ . Selon les canaux (voir tableau 4.7), les critères de sélection sur les variables combinées  $\mu Iso$  et  $e Iso$  sont pris pour le lepton le moins isolé (i.e. le "pire") ou sommés sur les deux leptons les moins isolés (i.e. les "2 pires"). Une critère supplémentaire consiste à couper sur  $\mu Iso$  et  $e Iso$  en fonction du  $p_T$  du 3<sup>me</sup> et du 4<sup>me</sup> lepton (ordonnés par impulsion transverse décroissante).

La méthode choisie pour évaluer le **paramètre d'impact** est le paramètre d'impact des leptons en 3 dimensions. On utilise la signficance du paramètre d'impact  $S_{IP3D} = \frac{IP3D}{\sigma_{IP3D}}$ .  $IP3D$  est le paramètre d'impact 3D calculé par rapport au vertex primaire (distance minimale entre le point d'impact et la trajectoire extrapolée du muon ou de l'électron) et  $\sigma_{IP3D}$  est son incertitude associée. Les  $S_{IP3D}$  des deux leptons les plus éloignés du vertex primaire reconstruit sont utilisés dans le critère de sélection.

Enfin, les **propriétés cinématiques** du processus  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  sont utilisées. Les quatre leptons candidats sont d'abord sélectionnés parmi tous les candidats de l'évènements de la manière suivante : le



	$4e$	$2e2\mu$	$4\mu$
Isolation	$eIso_{2pires} < 0.35$ $eIso_{2pires} < 0.06p_T^3 - 0.9$ $eIso_{2pires} < 0.035p_T^4 - 0.2$	$eIso_{2pires}$ et $e(\mu)Iso_{2pires}$ vs $p_T$ comme $4e/4\mu$ si $e(\mu)$ le moins bien isolé	$\mu Iso_{2pires} < 30$ $\mu Iso_{2pires} < 1.5p_T^3 - 15$ $\mu Iso_{pires} < 2p_T^4 - 10$
IP3D	$S_{IP3D}(pire\ e) < 5$ $S_{IP3D}(2^{nd}pire\ e) < 4$	$S_{IP3D}(pire\ l) < 5$ $S_{IP3D}(2^{nd}pire\ l) < 4$	$S_{IP3D}(pire\ \mu) < 12$ $S_{IP3D}(2^{nd}pire\ \mu) < 4$
$M_Z$	$50 < M_Z < 100$ GeV	$50 < M_Z < 100$ GeV	$50 < M_Z < 100$ GeV
$M_{Z^*}$	$20 < M_{Z^*} < 100$ GeV	$20 < M_{Z^*} < 100$ GeV	$20 < M_{Z^*} < 100$ GeV

FIG. 4.7 – Résumé des critères de sélection appliqués aux évènements passant la préselection.

dilepton de masse invariante la plus proche de la masse nominale  $m_Z$  est sélectionné comme candidat  $Z$ , et le dilepton d'impulsion transverse scalaire la plus grande parmi les candidats leptons restant est sélectionné comme candidat  $Z^*$ . Le processus présente au moins un  $Z^0$  sur sa couche de masse, contrairement au processus  $t\bar{t}$ . Le pic de masse du boson de Higgs est très étroit dans la plage de masse nominale considérée ( $115 < m_H < 250$  GeV), ce qui fait de cette observable une variable très discriminante et qui va être utilisée pour le calcul de la signficance (voir résultats).

Après les coupures de sélection, le principal bruit de fond est  $ZZ^*$ , suivi de  $Zbb$  surtout à basse masse invariante. Le bruit de fond  $t\bar{t}$  est complètement éliminé sauf dans le canal  $2e2\mu$  où quelques évènements subsistent. Les contributions des autres bruits de fond sont négligeables. L'avantage de cette sélection est d'être robuste car basée sur des coupures séquentielles non corrélées à la masse attendue du boson de Higgs. Elle fait apparaître le signal quelle que soit la masse nominale considérée (voir figure 4.8).




FIG. 4.8 – Masse invariante 4-leptons en fin d'analyse [135], dans le canal  $2e2\mu$ , pour une luminosité intégrée de  $1\text{ fb}^{-1}$  et une énergie dans le centre de masse de 10 TeV. Différentes masses nominales du boson de Higgs sont représentées ( $m_H = 130, 150, 200, 250$  GeV).

#### 4.2.6 Incertitudes systématiques

Les sources d'incertitudes systématiques intervenant dans l'analyse  $H \rightarrow ZZ^* \rightarrow 4l$  influent sur l'estimation de la signficance et doivent être maîtrisées, si possible à partir des données. Elles se divisent en plusieurs catégories :

- *Incertitude sur la luminosité* : inférieure ou de l'ordre de 10% durant la première année d'exploitation du LHC.
- *Incertitudes théoriques sur les sections efficaces* NLO du signal (10%) et des bruits de fond, évaluées en

variant les échelles d'énergie de renormalisation  $\mu_R$  et de factorisation  $\mu_F$  ainsi qu'en variant l'ensemble de densités partoniques utilisé. Dans le cas particulier du bruit de fond  $qq \rightarrow ZZ^*$ , le nombre d'évènements va être évalué dans les données à partir de la mesure de la section efficace  $Z$ +jets (incertitude inférieure à 4%), et vérifiée par la méthode des "sidebands" (extrapolation du nombre d'évènements de bruit de fond  $ZZ^*$  à partir de leur mesure hors de la fenêtre de masse du signal ("bandes de côté"), incertitude inférieure à 6%). L'incertitude sur le processus  $gg \rightarrow ZZ^*$  est de l'ordre de 30%, de 20% sur  $t\bar{t}$ , et de 100% sur  $Zbb$  (chiffre soumis à investigation).

- L'efficacité de déclenchement approche les 100% pour les leptons. L'incertitude associée est négligée dans l'analyse.

- *Incertitudes sur la reconstruction et l'identification des leptons.* De nombreuses méthodes ont été mises en place pour mesurer ces incertitudes à partir des données. L'efficacité sur la reconstruction des leptons est mesurée par la méthode "tag and probe" (des critères agressifs sont appliqués pour sélectionner avec une grande pureté un lepton "marqué" issu d'un  $Z$  et l'efficacité est "sondée" pour la reconstruction de l'autre lepton) et prédite avec 1% de précision. L'efficacité d'isolation des leptons est estimée avec la méthode des "templates cinématiques", qui est une amélioration de la méthode dite "random cone" [138] (cône aléatoire). La méthode "random cone" consiste à générer aléatoirement quatre directions par évènement (correspondant à quatre leptons virtuels), et à calculer l'énergie déposée dans les cônes d'isolation, qui est censée être la même dans l'évènement sous-jacent et dans les zones de signal. La méthode des "templates cinématiques" remplace simplement les directions aléatoires par les directions de vrais leptons pris dans des évènements de signal puis appliqués aux bruits de fonds simulés, et à terme directement dans les données.

- *L'incertitude sur l'algorithme de signficance du paramètre d'impact* est évaluée à 1% pour le signal, et conservativement à 20% pour les bruits de fond  $t\bar{t}$  et  $Zbb$  (contre lesquels cette variable est très efficace).

- Enfin, *l'incertitude sur les fenêtres de masse* utilisées dans le calcul de la signficance ( $\pm 2\sigma$  autour de la valeur moyenne du pic de masse invariante  $m_{4l}$  ajusté, voir paragraphe 4.2.7) est évaluée à 2-3%. Cette valeur est obtenue en faisant varier de 10% les bornes supérieure et inférieure de la fenêtre. Ces 10% représentent l'erreur estimée sur la résolution du pic  $m_{4l}$  à partir de la résolution des leptons seuls dans des évènements de  $Z$ .

Les incertitudes systématiques sont ensuite incluses dans le calcul de la signficance et des limites d'exclusion.

#### 4.2.7 Résultats de l'analyse

Dans la note [135], la signficance attendue pour  $1 fb^{-1}$  de luminosité avec une énergie dans le centre de masse de 10 TeV, et les limites d'exclusion atteintes avec  $200 pb^{-1}$  et  $1 fb^{-1}$  sont estimées de nombreuses manières que nous ne détaillerons pas ici. La signficance a été estimée avec la méthode du profil de vraisemblance et la méthode hybride fréquentiste-bayésienne, tandis que pour les limites d'exclusion, la méthode bayésienne et la méthode fréquentiste modifiée ont été utilisées, dans le cas d'une simple expérience de comptage du nombre d'évènements dans la fenêtre de masse  $\pm 2\sigma$  autour de la valeur moyenne du pic de masse invariante  $m_{4l}$ . La moyenne  $m_{4l}$  et la résolution  $\sigma$  sont obtenues par ajustement du pic de signal simulé avec une fonction convoluant gaussienne et Breit-Wigner.

Les résultats sont indiqués sur la figure 4.9, dans le cas de la méthode du profil de vraisemblance pour la signficance et de la méthode bayésienne pour le rapport  $r$  de la section efficace d'exclusion à 95% de niveau de confiance divisée par la section efficace attendue du signal dans le modèle standard. Les autres méthodes donnent des résultats similaires. L'inclusion des erreurs systématiques dans le calcul de ces grandeurs a montré qu'elles étaient négligeables. La combinaison des trois canaux permet de doubler la signficance obtenue dans le canal  $2e2\mu$  et atteint  $2.5\sigma$  pour  $m_H \simeq 150$  GeV et  $m_H \simeq 190$  GeV, valeur inférieure aux  $5\sigma$  nécessaire pour une découverte. Le rapport  $r$  attendu n'est jamais en-dessous de 1 : il n'est donc pas possible d'exclure à 95% de niveau de confiance dans la simulation une gamme de masse dans ce canal avec une luminosité accumulée de  $1 fb^{-1}$ . Toutefois, une estimation complémentaire du rapport  $r$  qui tient compte de la forme des distributions en masse invariante du signal et bruit de fond (et non plus seulement une simple expérience de comptage) permet d'exclure la région  $185 < m_H < 230$

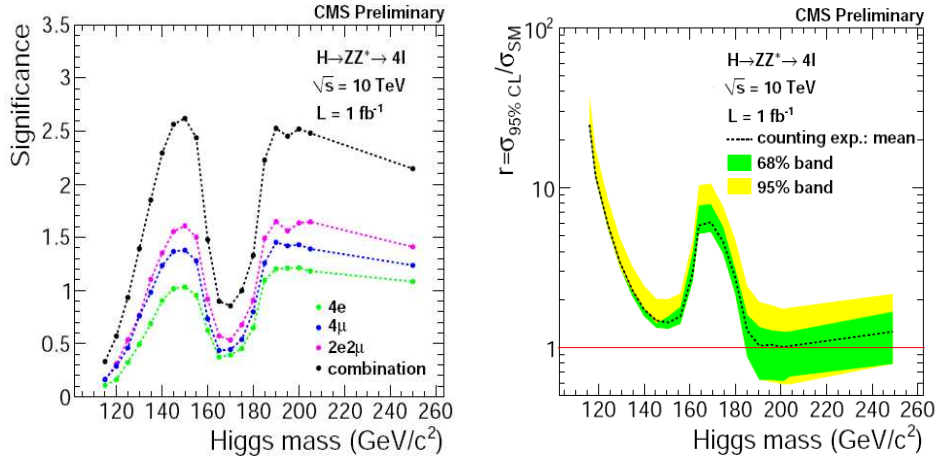


FIG. 4.9 – A gauche, signification pour chacun des canaux  $4e$ ,  $2e2\mu$ ,  $4\mu$  et combinés, estimée par la méthode du profil de vraisemblance. A droite, rapport de la section efficace nécessaire pour l’exclusion à 95% de niveau de confiance divisée par la section efficace attendue du signal dans le modèle standard, estimée par la méthode bayésienne. Chacun des deux graphiques est obtenu pour  $1 \text{ fb}^{-1}$  avec une énergie dans le centre de masse de 10 TeV [135]. Les incertitudes systématiques ne sont pas incluses.

GeV. Ces résultats n’incluent pas la récupération des photons de bremsstrahlung interne. Son impact sur la signification va être examiné section 4.4.

### 4.3 Description de la méthode de récupération “multi-brem”

Une première méthode de récupération des photons de bremsstrahlung interne a été mise en oeuvre dans un travail antérieur [133], pour le canal  $H \rightarrow ZZ^* \rightarrow 2e2\mu$ . Dans la suite, nous nous référerons à cette méthode sous le nom “PTDR” (il s’agit de la méthode utilisée dans le Physics Technical Design Report [88] de CMS), tandis que nous nous référerons à la méthode que nous allons proposer sous le nom “multi-brem”. Dans cette section, nous allons d’abord décrire les deux méthodes, avant de justifier par des considérations niveau particule le choix des critères de sélection appliqués dans la méthode “multi-brem”.

#### 4.3.1 Méthode de récupération “PTDR” et “multi-brem”

Les deux algorithmes de récupération tirent parti du fait que les photons émis par les leptons dans l’état final ont une forte tendance à être colinéaires aux leptons. La méthode “PTDR” ne récupère qu’un photon au maximum par événement tandis que la méthode “multi-brem” peut en récupérer un nombre variable.

##### Méthode “PTDR” [133]

L’algorithme “PTDR” de récupération des photons FSR procède comme suit :

- Tous les photons de l’évènement sont classés par ordre croissant de distance  $\Delta R(\text{lept}, \gamma)$  avec les leptons.
- Le photon le plus proche d’un des quatre leptons dans l’évènement est sélectionné s’il satisfait la condition  $\Delta R(\text{lept}, \gamma) < 0.3$ . Sinon, aucun photon n’est récupéré.

##### Méthode “multi-brem” [134, 135]

En réalité, un grand nombre de photons peuvent être émis par les leptons à l’état final. Pour tenir compte de cette propriété nous avons cherché à développer un algorithme capable de récupérer un nombre multiple de photons par événements. La récupération d’un nombre fixe de photons a été essayée pour différentes valeur du cône d’acceptance  $\Delta R(\text{lept}, \gamma)$  et pour différents nombre de photons mais n’a pas donné de résultats. Nous nous sommes donc tourné vers un algorithme de récupération d’un nombre variables de photons (méthode “multi-brem”), qui procède comme suit [134] (voir schéma 4.10) :

- Tous les paires possibles lepton-photon de l'évènement sont classées par ordre croissant de distance  $\Delta R(lept, \gamma)$ . L'algorithme boucle sur toutes les paires l'une après l'autre.
- La paire photon-lepton est rejetée si le photon a déjà été sélectionné ou si  $\Delta R(lept, \gamma) > 0.25$ . Sinon, la paire est sélectionnée sous les conditions suivantes : le nombre de photons sélectionnés au total dans l'évènement doit être inférieur ou égal à 3 et le nombre de photons sélectionnés appariés à ce lepton doit être inférieur ou égal à 2. De plus, le photon doit avoir une impulsion transverse  $p_T > 3$  GeV.
- Une amélioration de la méthode de récupération "multi-brem" a aussi été développée [135]. Afin de préserver les évènements qui sont déjà dans le pic de masse du boson  $Z$ , un critère additionnel est appliqué : si la masse invariante du dilepton  $M_{ll}$  répond à  $|M_{ll} - M_Z| < 3$  GeV, alors la récupération n'est pas effectuée sur ce dilepton. Ce critère permet d'améliorer la performance de l'algorithme spécialement dans le cas  $Z \rightarrow \mu^+ \mu^-$ , et n'est appliqué qu'aux dileptons provenant d'un  $Z$  sur sa couche de masse. Dans la suite, nous nous référerons à cette amélioration sous le nom "KeepCloseToZ".




FIG. 4.10 – Schéma de fonctionnement de la méthode "multi-brem". En bleu sont indiqués les leptons de l'évènement, en rouge les photons et en vert le cône  $\Delta R(lept, \gamma) < 0.25$ . Les photons 1 et 2 sont appariés au lepton 1, le photon 3 est apparié au lepton 2. Le photon 4 est bien compris dans le cône autour du lepton 3 mais n'est pas apparié par l'algorithme (récupération de 3 photons au maximum par évènement).

### 4.3.2 Optimisation des critères de sélection

Les critères de sélection de la méthode "multi-brem" ont fait l'objet d'une optimisation en deux temps. L'examen des distributions au niveau particule a permis de choisir les seuils des coupures appliquées, qui ont ensuite été vérifiées et améliorées au niveau reconstruit. Nous allons maintenant présenter quelques distributions au niveau particules qui permettront de quantifier les propriétés des photons FSR et de justifier le choix des coupures de l'algorithme.

L'énergie transverse moyenne  $E_T$  (voir graphique 4.11, gauche) des photons FSR est d'environ 2 GeV, de 9,6 GeV si une coupure  $E_T > 1$  GeV est demandée (pour une population de 21% de la population initiale), et de 16,3 GeV pour  $E_T > 5$  GeV (environ 10% des photons). Le graphique 4.11 de droite montre que les photons émis par les leptons ne sont pas toujours les photons les plus proches (le photon le plus proche est effectivement le photon émis dans seulement environ 40% des cas).

Les graphiques 4.12 montrent que pour des photons ayant une énergie transverse plus grande que 1 GeV ou 5 GeV, il est possible de récupérer jusqu'à 2 photons par lepton et 3 photons par évènement (au-delà le nombre de photons émis devient négligeable devant le nombre total). La distance  $\Delta R(lept, \gamma)$  optimale pour la récupération des photons FSR peut être lue sur les graphiques 4.13. Le point de fonctionnement au-delà duquel on trouve moins de photons FSR que de photons ISR ou issus de l'évènement sous-jacent se situe approximativement à  $\Delta R(lept, \gamma) = 0.25$  pour l'étude présente dans laquelle Pythia a été utilisée,

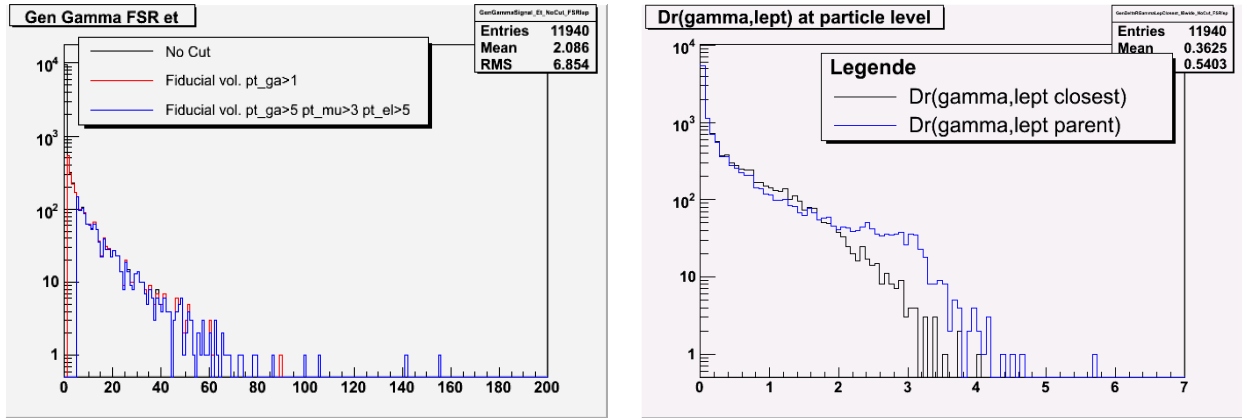


FIG. 4.11 – A gauche, énergie transverse  $E_T$  mesurée en GeV, au niveau particule de tous les photons FSR (en noir), pour les photons FSR ayant  $E_T > 1$  GeV (en rouge) et  $E_T > 5$  GeV avec un seuil en impulsion transverse  $p_T > 3$  GeV demandé sur les muons et  $p_T > 5$  GeV sur les électrons (en bleu), dans un échantillon  $H \rightarrow ZZ^* \rightarrow 2e2\mu$  avec une masse du boson de Higgs de 195 GeV. A droite, distance en  $\Delta R$  entre les photons FSR et le lepton qui les a émis (en bleu), et entre les photons FSR et le plus proche lepton (en noir).




FIG. 4.12 – A gauche, nombre de photons FSR émis par les leptons issus de la désintégration d’un boson  $Z^0$  ; à droite, nombre de photons FSR émis par évènement  $H \rightarrow ZZ^* \rightarrow 2e2\mu$  avec une masse du boson de Higgs de 195 GeV, pour des énergies transverses  $E_T > 0$  GeV (en noir),  $E_T > 1$  GeV et  $E_T > 5$  GeV.

à comparer avec  $\Delta R(lept, \gamma) = 0.3$  obtenue précédemment avec la génération des FSR par Photos[139], qui dispose d’une meilleure gestion des interférences entre les ISR et les FSR que Pythia. Enfin, la coupure sur l’énergie transverse des photons récupérés à  $E_T > 3$  GeV provient du point de fonctionnement lu sur le graphique 4.14 (pour  $E_T > 3$  GeV dans un cône  $\Delta R(lept, \gamma) < 0.25$ , on trouve moins de photons ISR ou issus de l’évènement sous-jacent que de photons FSR). L’intérêt du critère additionnel “KeepCloseToZ” sera justifié plus loin (voir 4.4.2) car il demande l’implémentation de l’algorithme au niveau reconstruit.

#### 4.4 Résultats obtenus avec la récupération des photons FSR

Le but premier de la récupération des photons de bremsstrahlung interne dans le cadre de l’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  est d’augmenter la sensibilité de l’analyse globale au signal, ce qui revient à augmenter la signification pour une luminosité donnée (ou à diminuer la luminosité nécessaire pour une exclusion). Dans la suite, les performances de la récupération des photons FSR sera évaluée pour chacun des trois canaux  $4e$ ,  $2e2\mu$  et  $4\mu$ , en terme des figures de mérite déjà évoquées plus haut (amélioration sur la résolution et sur la




FIG. 4.13 – Distance en  $\Delta R(lept, \gamma)$  au niveau particule entre les photons FSR et le lepton qui les a émis (en noir), et entre les autres photons de l’évènement et le lepton qui leur est le plus proche (en bleu). A gauche, l’émission des photons a été effectuée avec Pythia, à droite avec Photos [139] (graphique tiré de [133]). Pour obtenir une statistique suffisante, 18 échantillons de masses nominales du boson Higgs comprises entre 115 GeV et 600 GeV ont été combinés.




FIG. 4.14 – Energie transverse des photons FSR (en bleu) et des photons ISR ou issus de l’évènement sous-jacent (en noir), dans un cône  $\Delta R(lept, \gamma) < 0.25$  autour des leptons, pour une masse du boson de Higgs de 195 GeV.

hauteur du pic de masse divisée par la résolution) et en terme de signficance moyenne obtenue avec  $1 fb^{-1}$ , lorsque la récupération des FSR est appliquée au leptons du boson de Higgs candidat en fin d’analyse. La signficance moyenne sera ensuite estimée pour les trois canaux combinés. Les sources d’incertitudes systématiques liées aux photons seront discutées. Afin de vérifier les performances de l’algorithme, nous présenterons ensuite les performances obtenues dans le cas de “gedanken experiment” (expériences de pensée) sur de petits lots d’évènements de signal correspondant à la luminosité nécessaire pour une découverte.

#### 4.4.1 Sélection d’un lot de photons candidats

Les échantillons utilisés pour l’analyse sont les mêmes que ceux décrits dans la section 4.2, et contiennent ici aussi une simulation complète du détecteur CMS. Les données simulées ont été soumises à une reconstruction complète.

Avant d’opérer la récupération des photons FSR, la première étape de cette analyse consiste à sélectionner un lot de photons candidats dans chaque évènements, parmi lesquels certains seront récupérés comme candidats FSR conformément aux méthodes décrites plus haut (voir section 4.3).

La collection des photons reconstruits de CMSSW est utilisée. Depuis la version 2\_2\_X de CMSSW, le seuil en énergie transverse des photons a été élevé de  $E_T > 1$  GeV à  $E_T > 10$  GeV, ce qui est particulièrement problématique pour la récupération des photons FSR puisque leur spectre suit une exponentielle décroissante qui pique en 0 (pour  $E_T > 10$  GeV seuls 10% subsistent, voir figure 4.11). Il est donc nécessaire d’effectuer une re-reconstruction des objets photons en abaissant le seuil à  $E_T > 1$  GeV. Toutefois, les corrections appliquées aux super-clusters (reconstruits dès  $E_T > 1$  GeV) pour former les objets photons ont été optimisées pour la gamme  $E_T > 10$  GeV. L’utilisation des super-clusters sans tenir compte des corrections des photons donne des résultats comparables bien que moins bons qu’avec les photons.

Dans CMSSW, un photon reconstruit est créé pour chaque super-cluster même si ce super-cluster est également à l’origine de la reconstruction d’un électron. Un nettoyage est donc effectué, qui consiste à supprimer de la collection tous les photons qui partagent le même super-cluster qu’un électron. Les photons subsistants sont sélectionnés s’ils dans le volume d’acceptance du ECAL (restreinte à  $|\eta| < 2.5$  pour une meilleure efficacité de reconstruction).

#### 4.4.2 Reconstruction des pics de masse invariante des bosons $Z^0$ et du boson de Higgs

##### Comparaison des trois techniques de récupération

La récupération des photons FSR peut être appliquée à n’importe quelle étape de l’analyse dès lors qu’un candidat Higgs associé à quatre leptons est spécifié. Des performances comparables sont obtenues après préselection et en fin d’analyse. Le graphique 4.15 montre la masse invariante du boson de Higgs reconstruite après préselection dans un échantillon de signal ayant une masse nominale  $m_H = 195$  GeV, ainsi que la masse reconstruite  $Z \rightarrow \mu\mu$  et  $Z \rightarrow ee$ , avec et sans récupération des photons FSR. Pour le boson de Higgs, la méthode “PTDR” donne une résolution 0,5% moins bonne que la résolution obtenue sans récupération, tandis que la résolution obtenue par méthode “multi-brem” et “KeepCloseToZ” est meilleure (respectivement 0,6% et 3,0% d’amélioration). Un comportement semblable est obtenu pour  $h/\sigma$  (+4,0% pour “PTDR”, +5,5% pour “multi-brem” et +10,8% pour “KeepCloseToZ”). Les performances des trois techniques dans le canal  $2e2\mu$  sur la reconstruction des pics du  $Z$  et du boson de Higgs sont résumées sur le tableau 4.16 en terme de la figure de mérite  $h/\sigma$ . Une comparaison des performances obtenues avec les techniques “PTDR”, “multi-brem” et “KeepCloseToZ” dans le canal  $2e2\mu$  peut être trouvée figure 4.17 pour différentes masses du boson de Higgs dans la gamme  $115 < m_H < 250$  GeV ( $m_H = 115, 130, 145, 160, 175, 185, 195, 205, 250$  GeV). La méthode “KeepCloseToZ” donne les meilleurs résultats quelle que soit la masse du boson de Higgs, devant “multi-brem” suivi de “PTDR”. Pour les basses masses, la technique “PTDR” donne de moins bon résultats que si aucune récupération n’avait été appliquée.

##### Performances de la reconstruction du pic du $Z^0$

La performance sur la reconstruction du pic du  $Z$  est meilleure pour le canal  $2\mu$  que pour le canal  $2e$ . La baisse de performance dans le canal électronique atteint aussi bien la reconstruction du  $Z$  que celle du boson de Higgs, pour une raison sera expliquée plus loin en détail. D’un autre côté, la technique “KeepCloseToZ” marche particulièrement bien pour le canal  $2\mu$  et donne une amélioration significative par rapport à la méthode “multi-brem”, car le pic reconstruit  $Z \rightarrow \mu\mu$  est plus étroit ( $\sigma_{Z \rightarrow \mu\mu} \simeq 2.5$  GeV contre  $\sigma_{Z \rightarrow ee} \simeq 3$  GeV). Par conséquent, la technique “KeepCloseToZ” protège mieux le pic  $Z \rightarrow \mu\mu$  contre les faux FSR récupérés. Les trois techniques de récupération ont aussi été testées sur les pics de masse du  $Z$  dans les processus  $ZZ^*$  et  $Zbb$  et donnent des performances similaires.

##### Optimisation de la méthode “KeepCloseToZ”

La valeur du paramètre  $\sigma_Z$  de la méthode “KeepCloseToZ” (utilisé pour la non-récupération des photons dans la plage  $|M_{ll} - M_Z| < \sigma_Z$ ) a été optimisée dans le canal  $2e2\mu$  pour maximiser la résolution moyenne sur toute la plage de masse testée du boson de Higgs. La valeur finale retenue est  $\sigma_Z = 3$  GeV (voir fig. 4.18).

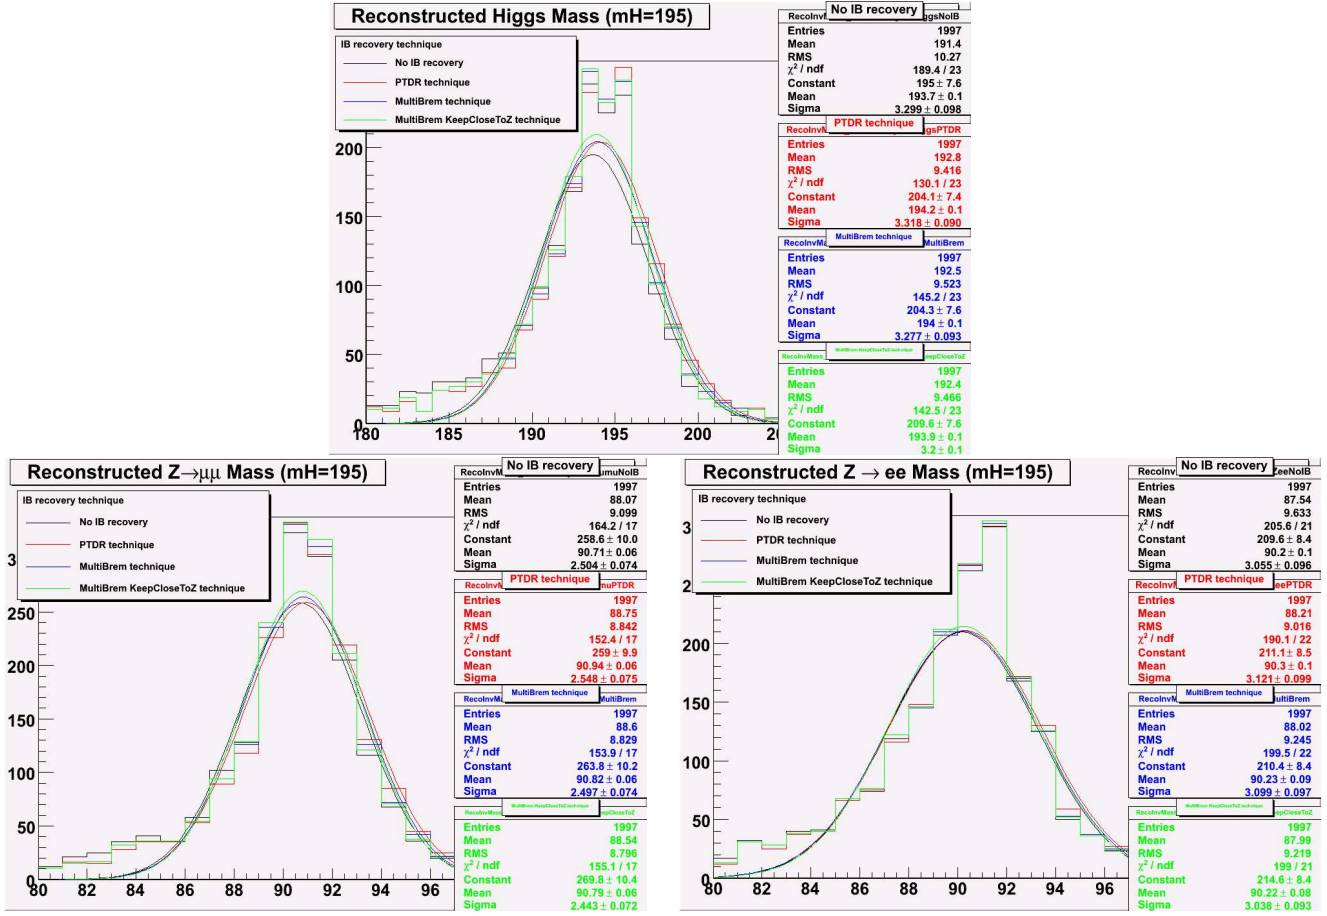


FIG. 4.15 – Masse invariante reconstruite du boson de Higgs (en haut), de  $Z \rightarrow \mu\mu$  (à gauche) et de  $Z \rightarrow ee$  (à droite), pour  $m_H = 195$  GeV dans le canal  $2e2\mu$ , sans récupération des FSR (en noir), avec récupération par la méthode “PTDR” (en rouge), “multi-brem” (en bleu) et sa variante “KeepCloseToZ” (en vert). Les résultats de l’ajustement de chaque histogramme avec une gaussienne sont donnés sur la droite.

Figure de mérite $h/\sigma$	Technique “PTDR”	Technique “multi-brem”	Technique “KeepCloseToZ”
$H \rightarrow ZZ^* \rightarrow 2e2\mu$	+4%	+5,5%	+10,8%
$Z \rightarrow \mu^+\mu^-$	-1,5%	+2,3%	+6,9%
$Z \rightarrow e^+e^-$	-1,4%	-1,0%	+2,9%

FIG. 4.16 – Performances au niveau particule de la récupération des photons FSR sur les pics de masse du boson de Higgs et des bosons  $Z$  issus de sa désintégration, pour un boson de Higgs de masse de 195 GeV dans le canal  $2e2\mu$ .

### Performances comparées des canaux $2e2\mu$ , $4e$ et $4\mu$

Nous présentons l’amélioration sur les figures de mérite  $\sigma$  et  $h/\sigma$  pour les trois canaux en fonction de la masse nominale du boson de Higgs avec la technique “KeepCloseToZ” sur la figure 4.19. La récupération améliore de 2,45% en moyenne la résolution sur la masse du boson de Higgs dans le canal  $4\mu$ , tandis que l’amélioration est seulement de 0.01% dans le canal  $4e$ , avec une performance intermédiaire pour le canal  $2e2\mu$  (un comportement similaire a déjà été noté plus haut pour les pics du  $Z$  dans le canal  $2e2\mu$ ). Cela est dû au fait que l’algorithme de reconstruction des électrons est conçu pour récupérer les dépôts d’énergie laissés par les photons de bremsstrahlung *externe* dans le calorimètre (qui ne se distinguent pas a priori des photons de bremsstrahlung interne). Les photons FSR recherchés par l’algorithme “multi-brem” à proximité des électrons sont donc déjà récupérés lors de la clusterisation, ce qui conduit à une baisse d’efficacité dans le canal  $4e$ .



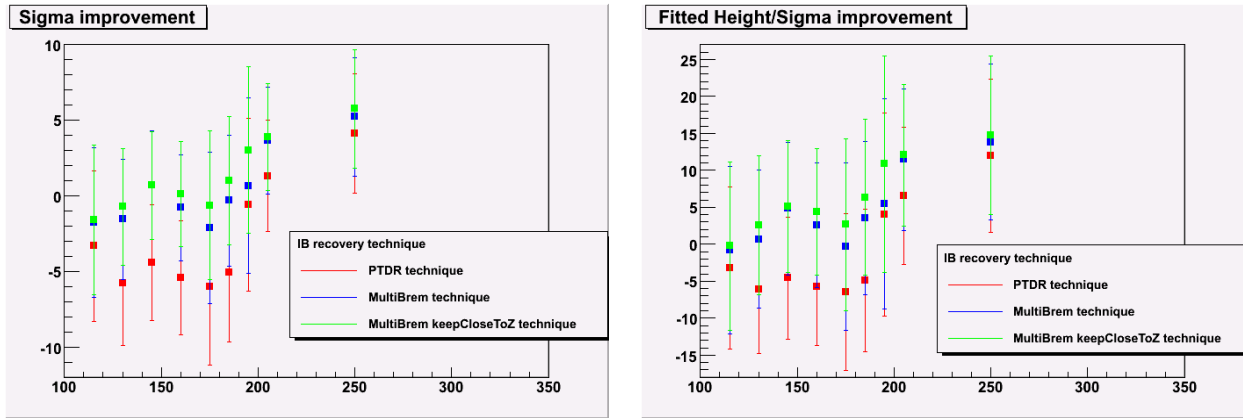


FIG. 4.17 – Amélioration sur la résolution  $\sigma$  sur la masse du boson de Higgs (à gauche) et sur  $h/\sigma$  (à droite) en fonction de la masse nominale du boson de Higgs dans le canal  $2e2\mu$ , pour les trois techniques de récupération “PTDR” (en rouge), “multi-brem” (en bleu) et “KeepCloseToZ” (en vert). Les barres d’erreurs incluent les incertitudes statistiques dues à la récupération et les incertitudes statistiques dues à l’analyse sans récupération.




FIG. 4.18 – Amélioration de la résolution sur la masse du boson de Higgs dans le canal  $2e2\mu$ , en fonction de la masse nominale pour 9 masses différentes comprises entre 115 GeV et 250 GeV. La plus grande amélioration (moyennée sur toutes les masses) est obtenue pour le paramètre  $\sigma_Z = 3$  GeV. Le code utilisé ici est CMSSW\_1\_6\_12 et les échantillons présentent plus de statistique que sur la figure 4.15, ce qui explique la différence de performance.

### Récupération des photons FSR dans les super-clusters des électrons

La baisse de performance pour la récupération dans les canaux électroniques peut être expliquée par la figure 4.20. A bas  $\Delta R(e, \gamma)$  on observe une baisse d’efficacité de la récupération des photons FSR proches des électrons, par opposition aux muons. L’efficacité est ici définie comme le nombre de photons reconstruits récupérés qui sont appariés avec un photon FSR niveau générateur dans un cône  $\Delta R < 0.1$ , divisé par le nombre total de photons récupérés. L’efficacité de récupération des photons FSR suit le même comportement pour les trois techniques en fonction de  $\Delta R$ , mais est plus haute pour la technique “PTDR” simplement parce que cette technique récupère plus de photons (FSR comme non FSR) en raison de son cône  $\Delta R(lept, \gamma) < 0.3$  plus large que celui de la technique “multi-brem” ( $\Delta R(lept, \gamma) < 0.25$ ).

### 4.4.3 Impact de la récupération sur la signficance

La récupération des photons FSR par la méthode “KeepCloseToZ” donne la meilleure amélioration sur la résolution  $\sigma$  du pic de masse invariante par rapport au cas où aucune récupération n’est effectuée,




FIG. 4.19 – Amélioration sur la résolution  $\sigma$  (à gauche) et sur  $h/\sigma$  (à droite) du pic de masse du boson de Higgs en fonction de la masse nominale du boson de Higgs, dans les canaux  $4e$ ,  $2e2\mu$  et  $4\mu$  pour la méthode de récupération “KeepCloseToZ”. Les barres d’erreurs incluent les incertitudes statistiques dues à la récupération et les incertitudes statistiques dues à l’analyse sans récupération.

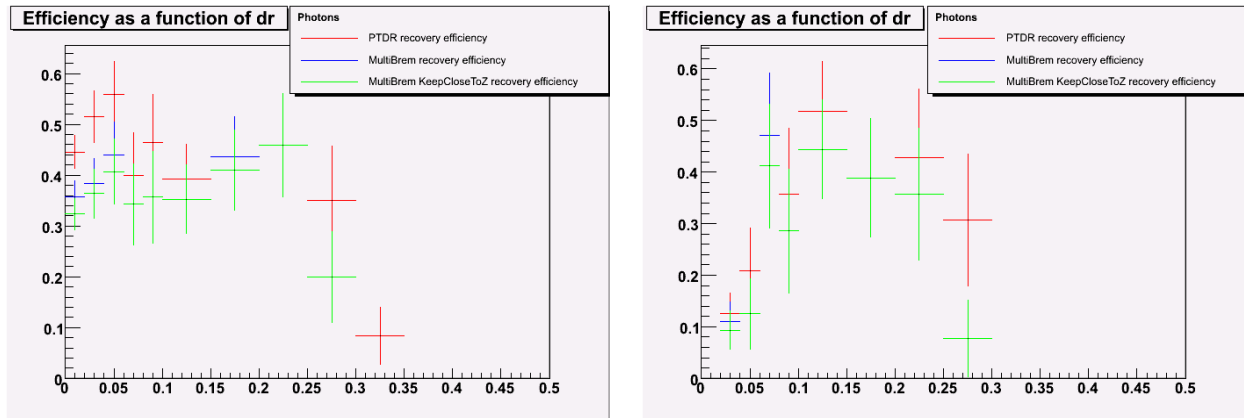


FIG. 4.20 – Efficacité de récupération de photons FSR en fonction de  $\Delta R(lept, \gamma_{FSR,gen})$  (où  $\gamma_{FSR,gen}$  est le photon FSR niveau générateur apparié dans un cône  $\Delta R < 0.1$  avec le photon reconstruit récupéré) dans le canal  $2e2\mu$  pour les muons (à gauche) et pour les électrons (à droite), pour les trois techniques de récupération des FSR.

quelle que soit la masse nominale du boson de Higgs considérée. Nous présentons ici un calcul de la signification par simple expérience de comptage du nombre d’évènements de signal et de bruit de fond dans la fenêtre de masse  $m_{4l}^{moy} - 2\sigma < m_{4l} < m_{4l}^{moy} + 2\sigma$  (où  $m_{4l}^{moy}$  est la valeur moyenne du pic de masse invariante obtenu par ajustement). La récupération des FSR entraîne une diminution de la largeur de la fenêtre ainsi qu’un déplacement léger de la valeur moyenne  $m_{4l}^{moy}$ . Il importe dans un premier temps de vérifier que les distributions de masse invariante du bruit de fond ne sont pas déplacées vers les valeurs plus hautes, ce qui pourrait augmenter le nombre d’évènements du bruit de fond dans la fenêtre de masse. Les distributions des masses invariantes des bruits de fond  $Zbb$  et  $t\bar{t}$  sont effectivement déplacées vers les plus hautes masses, tandis que le bruit de fond  $ZZ^*$  qui est de loin le plus important en fin d’analyse n’est pas déplacé (voir figure 4.21). Pour cette raison, on peut s’attendre à ce que la récupération des photons FSR se traduise par une augmentation de la signification.

Le calcul de la signification pour une expérience de comptage est donnée par la formule suivante :

$$S = \sqrt{2\ln Q} = \sqrt{2(N_S + N_B)\ln\left(1 + \frac{N_S}{N_B}\right) - N_S}$$

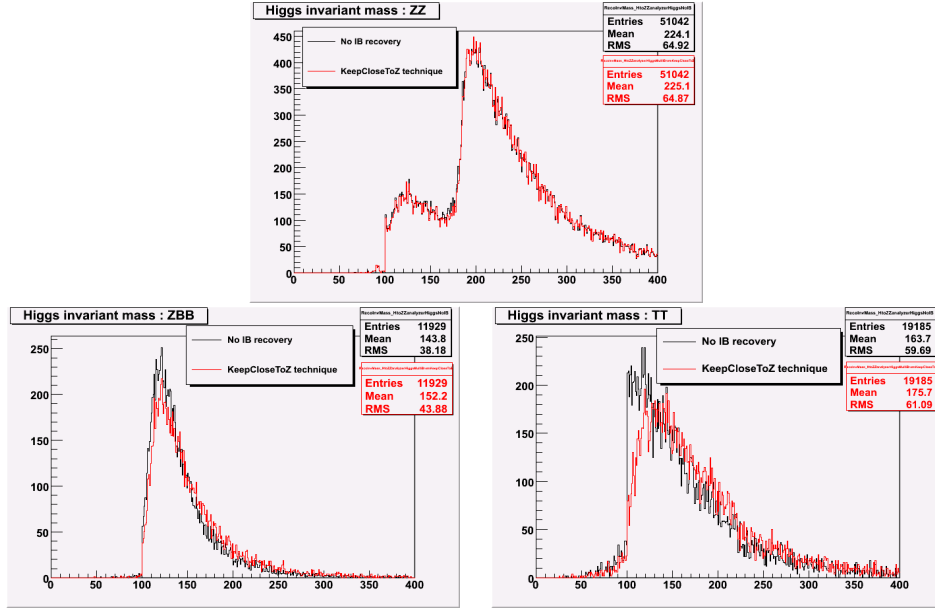


FIG. 4.21 – Masse invariante reconstruite du boson de Higgs dans les processus  $ZZ^*$  (en haut),  $Zbb$  (à gauche) et  $t\bar{t}$  (à droite), dans le canal  $2e2\mu$  avec et sans récupération des photons FSR par la méthode “KeepCloseToZ”.

Où  $Q$  est le rapport de vraisemblance,  $N_S$  le nombre d’événements de signal et  $N_B$  le nombre d’événements de bruit de fond dans la fenêtre de masse.

La signification moyenne est calculée dans le cas où aucune récupération des FSR n’est effectuée et dans le cas où la méthode “KeepCloseToZ” est appliquée en fin d’analyse, pour 9 masses nominales du boson de Higgs. La signification pour les trois canaux séparés  $4e$ ,  $2e2\mu$  et  $4\mu$  est montrée figure 4.22. Dans la mesure où le recouvrement entre les trois canaux est négligeable, la signification des trois canaux combinés est calculée à partir de la somme des nombres d’événements du signal et du bruit de fond dans chacun des canaux. Le résultat final est montré figure 4.23. Le gain sur la signification dû à la récupération des photons FSR est le plus élevée dans le canal  $4\mu$ , suivi de  $2e2\mu$ , et le plus bas dans le canal  $4e$  pour les raisons qui ont été évoquées plus haut (protection du pic  $Z \rightarrow \mu\mu$  par la technique “KeepCloseToZ” et perte d’efficacité à bas  $\Delta R(e, \gamma)$ ). La signification des trois canaux combinés montre une amélioration dès  $m_H > 120$  GeV et qui s’accroît avec  $m_H$ . L’amélioration atteint 5% dans la plage de masse  $m_H > 180$  GeV, où les deux bosons  $Z$  sont sur leur couche de masse. En conclusion, il peut être intéressant d’appliquer la technique de récupération “KeepCloseToZ” dans les trois canaux, spécialement si le boson de Higgs est recherché dans le domaine des hautes masses.

## 4.5 Incertitudes statistiques et systématiques

Dans cette section, nous discutons les incertitudes statistiques et systématiques qui affectent la méthode de récupération des photons FSR que nous proposons. Dans un premier temps, nous effectuerons des expériences de pensée (“gedanken experiment”) pour évaluer le gain moyen dû à la récupération pour un grand nombre d’expériences. Puis nous discuterons les sources des incertitudes systématiques avant de proposer un moyen de contrôler les plus importantes à partir des données.

### 4.5.1 Incertitudes statistiques et gedanken experiment

#### Commentaire sur les incertitudes statistiques

En addition des incertitudes systématiques mentionnées ci-dessus, les incertitudes statistiques jouent un grand rôle pour une découverte précoce du boson de Higgs. Au vu de la taille des barres d’erreur sur

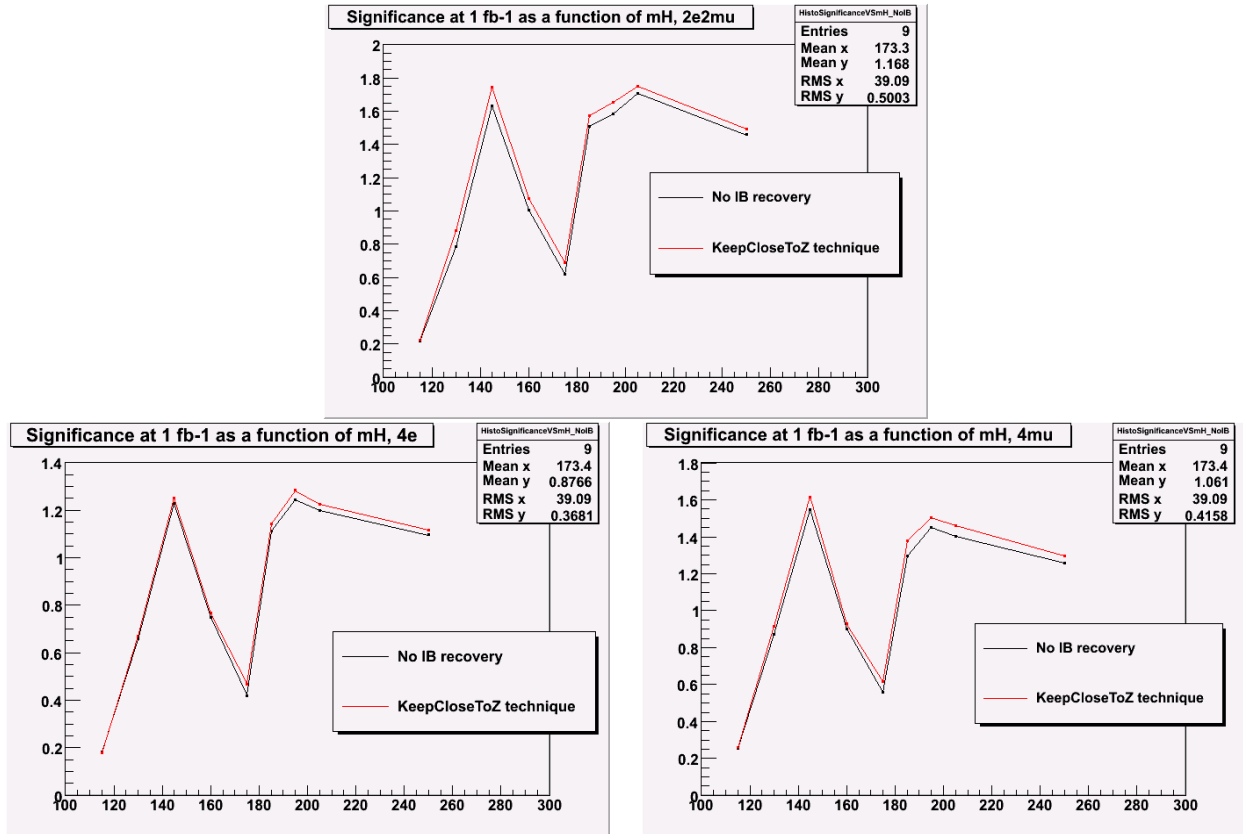


FIG. 4.22 – Significance obtenue avec 1  $fb^{-1}$  de luminosité intégrée et une énergie de 10 TeV dans le centre de masse, dans le canal  $2e2\mu$  (en haut),  $4e$  (à gauche) et  $4\mu$  (à droite) sans récupération de photons FSR (en noir) et avec récupération par la méthode “KeepCloseToZ” (en rouge), en fonction de la masse du boson de Higgs.

la figure 4.19, on peut légitimement se demander si la récupération des photons de bremsstrahlung interne n’induit pas une grande fluctuation statistique (du fait du faible nombre de photons récupérés) qui viendrait dégrader la résolution sur la masse du boson de Higgs pour un petit nombre d’évènements. En réalité le graphique inclut aussi bien les incertitudes statistiques issues de l’ajustement du pic de masse sans récupération qu’avec récupération. Comme le montre la figure 4.24, les deux résolutions sont du même ordre de grandeur, ainsi que les incertitudes statistiques (comme déjà montré, la résolution avec récupération est légèrement meilleure - d’où l’intérêt de la méthode proposée).

### Gedanken experiment

Toutefois, les résultats présentés jusqu’ici ont été obtenus en utilisant toute la statistique des échantillons disponibles (ce qui correspond à une luminosité supérieure à 100  $fb^{-1}$  pour le signal, et qui dépend du nombre d’évènements générés selon les échantillons). Dans le but d’évaluer les performances de la récupération avec la luminosité proche de la luminosité minimale nécessaire à une découverte, nous allons effectuer des “gedanken experiment” (expériences de pensée). L’exercice consiste à diviser les échantillons de signal en un ensemble de petits lots d’évènements. Pour chaque lot d’évènements, le pic de masse invariante du boson de Higgs est ajusté avec et sans récupération des photons FSR et les performances moyennées sur chaque lot d’évènement sont calculées pour les figures de mérites  $\sigma$  et  $h/\sigma$ . Nous avons choisi d’effectuer les “gedanken experiment” sur 109 (resp. 150) lots de 30 évènements de signal pour  $m_H = 195$  GeV ( $m_H = 120$  GeV), nombre suffisant pour permettre la convergence de l’ajustement et correspondant à une luminosité intégrée de signal de 1  $fb^{-1}$  pour  $m_H = 195$  GeV et 5,9  $fb^{-1}$  pour  $m_H = 120$  GeV (les bruits de fonds n’ont pas été pris en compte). Les distributions ainsi obtenues sont présentées figure 4.25 dans les cas aucune récupération, méthode “PTDR” et “multi-brem” (l’exercice devrait aussi être répété avec la méthode “KeepCloseToZ”). Les résultats en terme de  $\sigma$ ,  $h/\sigma$  et amélioration sur  $h/\sigma$  sont résumés sur

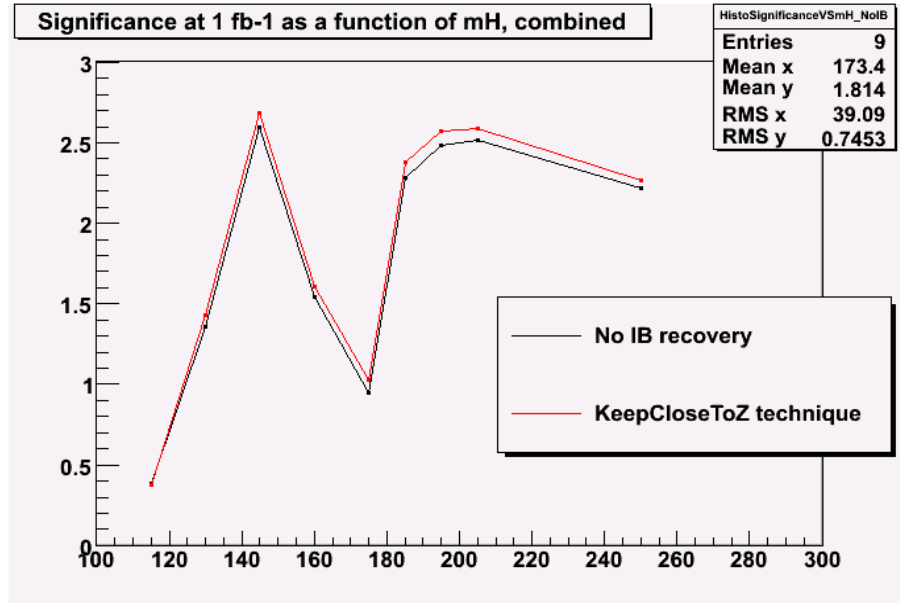


FIG. 4.23 – Significane obtenue avec  $1 \text{ fb}^{-1}$  de luminosité intégrée et une énergie de 10 TeV dans le centre de masse pour les trois canaux  $2e2\mu$ ,  $4e$  et  $4\mu$  combinés, sans récupération de photons FSR (en noir) et avec récupération par la méthode “KeepCloseToZ” (en rouge), en fonction de la masse du boson de Higgs.

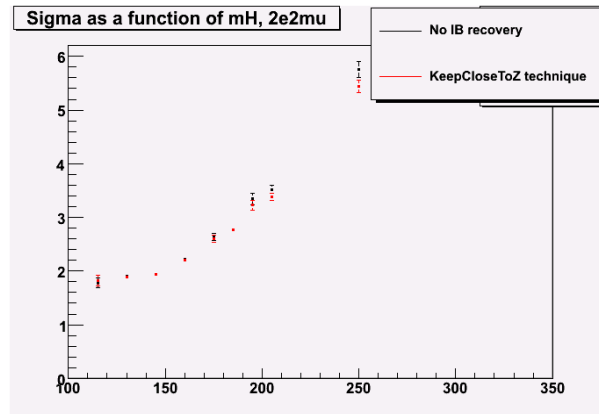


FIG. 4.24 – Résolution sur la masse reconstruite du boson de Higgs dans le canal  $2e2\mu$  en fonction de la masse nominale du boson de Higgs, sans récupération (en noir) et avec récupération par la technique “KeepCloseToZ” (en rouge). La taille des barres d’erreur statistique diminue avec le nombre d’évènements générés.

les tableaux 4.26 et 4.27. On vérifie ici que les performances obtenues sont meilleures pour la méthode “multi-brem” que pour la méthode “PTDR” et le cas où aucune récupération n’est effectuée. En particulier, l’amélioration sur la résolution pour  $m_H = 195 \text{ GeV}$  est de 1% avec la technique “multi-brem” par rapport au cas sans récupération. En conclusion, le gain obtenu par gedanken experiment est moins significatif que le gain moyen présenté plus haut en raison des fluctuations statistiques, mais pour un grand nombre de lots le résultat devrait converger vers les performances moyennes (théorème de la limite centrale).

#### 4.5.2 Source des incertitudes systématiques

Les photons reconstruits induisent de nouvelles sources d’incertitudes systématiques qui viennent s’ajouter à celle de l’analyse  $H \rightarrow ZZ^* \rightarrow 4l$ . On distinguera d’une part les incertitudes relatives aux photons

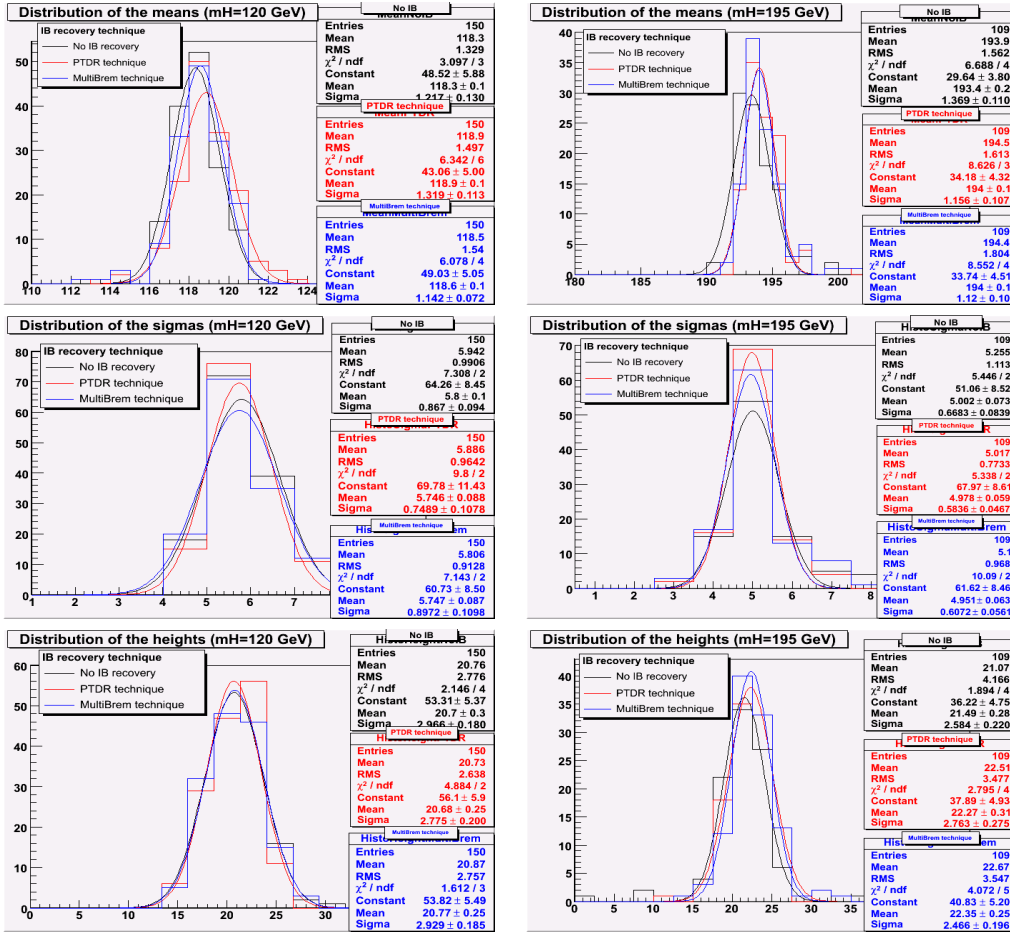


FIG. 4.25 – Résultats des “gedanken experiment” pour  $m_H = 120$  GeV (à gauche) et  $m_H = 195$  GeV (à droite) : valeurs moyennes du pic de masse invariante du Higgs (en haut), résolution  $\sigma$  (au milieu) et hauteur du pic (en bas) pour les lots de 30 évènements obtenus sans récupération (en noir), récupération avec la méthode “PTDR” (en rouge) et “multi-brem” (en bleu).

$m_H = 120$ GeV	Moyenne (GeV)	$\sigma$ (GeV)	$h$	$h/\sigma$	$\Delta h/\sigma$ (%)
Pas de récupération	$118.3 \pm 0.1$	$5.8 \pm 0.1$	$20.7 \pm 0.3$	$3.57 \pm 0.11$	—
Technique “PTDR”	$118.9 \pm 0.1$	$5.75 \pm 0.08$	$20.68 \pm 0.25$	$3.6 \pm 0.09$	$+0.95 \pm 0.05$
Technique “multi-brem”	$118.6 \pm 0.1$	$5.75 \pm 0.09$	$20.77 \pm 0.25$	$3.62 \pm 0.1$	$+1.39 \pm 0.07$

FIG. 4.26 – Résultats des “gedanken experiment” pour  $m_H = 120$  GeV.  $\Delta h/\sigma$  est le gain sur  $h/\sigma$  avec récupération par rapport au cas sans récupération.

$m_H = 195$ GeV	Moyenne (GeV)	$\sigma$ (GeV)	$h$	$h/\sigma$	$\Delta h/\sigma$ (%)
Pas de récupération	$193.4 \pm 0.1$	$5.00 \pm 0.07$	$21.49 \pm 0.28$	$4.3 \pm 0.12$	—
Technique “PTDR”	$194 \pm 0.1$	$4.98 \pm 0.06$	$22.27 \pm 0.31$	$4.48 \pm 0.12$	$+4.26 \pm 0.23$
Technique “multi-brem”	$194 \pm 0.1$	$4.95 \pm 0.06$	$22.35 \pm 0.25$	$4.52 \pm 0.11$	$+5.05 \pm 0.25$

FIG. 4.27 – Résultats des “gedanken experiment” pour  $m_H = 195$  GeV.  $\Delta h/\sigma$  est le gain sur  $h/\sigma$  avec récupération par rapport au cas sans récupération.

en eux-même, et d’autre part les incertitudes provenant de l’algorithme de récupération des photons FSR.

### Incertainces sur l’objet photon

- *Incertitudes sur l'efficacité de reconstruction des photons.* Les algorithmes de reconstruction des photons ont été développés pour la gamme d'énergie transverse  $E_T > 10$  GeV, or les photons qui nous intéressent ici ont une énergie transverse  $E_T > 3$  GeV. L'efficacité de reconstruction pour ces photons a été évaluée à  $\epsilon_{reco} \simeq 30\%$  seulement, ce qui s'explique par le fait que les photons FSR et non-FSR dans les événements  $H \rightarrow 4l$  sont typiquement non isolés. Un déclenchement sur des photons ayant  $E_T > 10$  GeV pour des processus contenant des photons prompts donnerait une efficacité de reconstruction supérieure à 90% [140], et l'incertitude systématique associée est généralement estimée à 1%. L'incertitude systématique sur l'efficacité de reconstruction n'a pas été réévaluée pour des photons non-isolés comme utilisés dans cette analyse.

- *Incertitudes sur la quadri-impulsion  $p_\gamma$  des photons,* calculée à partir de leur position et leur énergie mesurée dans le ECAL. La plupart des photons récupérés ont une énergie transverse faible devant celle du lepton apparié (typiquement  $E_{T,\gamma}/p_{T,lept} < 0,2\%$ ), et l'incertitude sur l'énergie des photons est typiquement de l'ordre de 1%. Lorsque les quatre leptons issus de la désintégration du boson de Higgs sont pris en compte, on obtient  $E_{T,\gamma}/m_{4l} < 0.05\%$ . Cette incertitude sera donc négligée devant les incertitudes provenant de la technique de récupération proprement dite.

- Les *incertitudes dues au budget matériel* devant le ECAL portent sur la fraction de photons qui convertissent, et n'ont pas été évaluées. La conversion des photons dans le trajectographe peut conduire à un dépôt d'énergie plus étalé (d'où un plus bas  $R9$ , et donc une évaluation différente de l'énergie du photons s'il passe en-dessous du seuil 0.94 (tonneau) ou 0.95 (bouchons)) et si les deux électrons convertis sont suffisamment éloignés (cas des conversions asymétriques), modifier la quadri-impulsions des photons candidats.

### Incertitudes provenant de la technique de récupération

- Les *incertitudes théoriques* sur les distributions des photons FSR jouent en revanche un grand rôle sur les performances de la technique de récupération. On a vu figure 4.13 que le choix du générateur utilisé (Pythia / Photos) change la valeur du paramètre  $\Delta R(lept, \gamma) < \Delta R_{max}$ . De plus, la simulation repose pour l'instant sur des paramètres de l'évènement sous-jacent qui doivent être ajustés avec les données à 7 TeV. Le choix du paramètre  $\Delta R_{max}$  est crucial et doit être mesuré à partir des données. Il y a deux manières de le faire : la première consiste à sélectionner un lot pur de photons du processus  $Z \rightarrow \mu\mu\gamma$  par une sélection sévère qui utilise les événements où le photon FSR est dur (une luminosité intégrée minimum de  $100 pb^{-1}$ ), et à tracer le même graphique que 4.13 pour déterminer le point de fonctionnement. La deuxième méthode est accessible dès  $10 pb^{-1}$  et consiste à ajuster la valeur de  $\Delta R_{max}$  en appliquant la méthode "multi-brem" dans des événements  $Z \rightarrow ll$  où il y a une radiation de photons mous à l'état final. Une première vérification de l'allure du spectre en  $\Delta R(lept, \gamma)$  et en énergie transverse des photons a de plus été mise en oeuvre dans les données de muons cosmiques (voir section 4.5.3) et montre un bon accord avec les prédictions théoriques dans la région  $\Delta R(\mu, \gamma) < 0.3$ .

- Les *incertitudes expérimentales liées à la méthode de récupération* proviennent du taux de photons récupérés qui ne sont pas des photons FSR (taux de faux) et de l'efficacité de récupération des photons FSR. L'incertitude sur l'efficacité de récupération n'a pas été évaluée mais pourrait l'être en faisant varier les critères de sélection des photons FSR de  $\pm 10\%$  par exemple, et de mesurer la variation de l'efficacité. Une méthode permettant la mesure du taux de faux dans les événements  $ZZ^*$  sera proposée section 4.5.3.

### 4.5.3 Incertitudes systématiques : contrôle de la méthode à partir des données

Il a été souligné que les deux sources d'incertitudes systématiques les plus importantes pour cette étude sont les incertitudes théoriques liées aux distributions des photons de bremsstrahlung interne, ainsi que l'incertitude expérimentale provenant du taux de faux photons FSR récupérés. La vérification de l'allure des distributions à partir des données nécessite de considérer un lot pur d'évènements, et une technique connue pour le faire consiste à les sélectionner dans le canal  $Z \rightarrow \mu\mu\gamma$ , ce qui n'est pas réalisable avant 100

$pb^{-1}$  de luminosité intégrée. Toutefois, nous disposons d'ores et déjà d'un lot presque pur de photons FSR dans les données de muons cosmiques de CRAFT 08 (Cosmic Run At Four Tesla), dont nous allons nous servir pour effectuer une première vérification du comportement des photons de bremsstrahlung dans les données. Par la suite, nous proposerons une méthode d'évaluation du taux de faux photons FSR récupérés à partir des événements  $ZZ^*$  (à partir de  $1 fb^{-1}$  de luminosité intégrée).

### Récupération des photons émis par les muons cosmiques

La prise de données de muons cosmiques a eu lieu en Octobre-Novembre 2008. Le détecteur dans son intégralité était installé dans la caverne et le champ magnétique avait été mis en marche à  $3.8 T$ . Deux gains ont été essayés pour les APD du calorimètre électromagnétique [32] : 150 millions d'événements ont été enregistrés au gain 50 (valeur usuelle et qui est aussi utilisée pour les données de collisions) et 88 millions au gain 200 (mieux adaptée aux prises de données cosmiques où le signal est faible et vient du minimum d'ionisation). L'énergie transverse seuil de déclenchement du ECAL a été mise à  $1 GeV$  sur deux tours adjacentes et  $750 MeV$  pour la tour d'énergie la plus haute. Le taux de déclenchement était typiquement de  $30-40 Hz$  sur toute la période d'acquisition.

#### Sélection des muons et des photons

Pour cette étude, la collection des muons au niveau reconstruit a été utilisée (muons formés à partir de l'information sur les chambres à muons et le trajectographe). Un seuil en énergie transverse  $E_T > 10 GeV$  a été demandé pour être consistant avec l'espace de phase peuplé dans les échantillons simulés avec le générateur CMSCGEN [141, 142]. CMSCGEN est un générateur de muons cosmiques, et tous les photons présents dans la simulation sont des photons bremsstrahlung externe dans la matière générés avec GEANT4 [29]. Afin de se restreindre aux régions pour laquelle la reconstruction fonctionne le mieux, seuls les muons ayant un angle azimutal  $\phi < 0$  sont considérés (ce qui correspond à des muons descendants). Un critère supplémentaire est demandé sur les paramètres d'impact longitudinal  $dz < 50 cm$  et transversal  $d0 < 100 cm$  pour imiter les muons provenant de collisions. L'impulsion transverse des muons est ensuite calculée en postulant que les muons passent par le centre du détecteur et en extrapolant leur trajectoire à l'entrée du calorimètre à partir des coups laissés dans le trajectographe.

Les collections de particules utilisées pour les photons sont les super-clusters reconstruits avec un algorithme dédié aux prises de données de muons cosmiques [30]. Les basic-clusters de  $5 \times 5$  cristaux sont reconstruits autour des cristaux germes s'ils ont une énergie supérieure à 15 coups ADC ( $139,5 MeV$ ), ou autour du cristal germe s'il a ainsi que son voisin une énergie supérieure à 5 coups ADC ( $46,5 MeV$ ). L'énergie du basic-cluster est obtenue par la somme des énergies des cristaux ayant plus de 2 coups ADC ( $18,5 MeV$ ). Les basic-clusters contigus sont ensuite regroupés en super-clusters. Seules les corrections d'inter-calibrations sont appliquées.

Le même critère  $\phi < 0$  est demandé sur les super-clusters. Le seuil en énergie transverse usuel  $E_T > 1 GeV$  est complété par un seuil en énergie  $E > 2 GeV$  requis par un écrémage propre aux analyses ECAL pour s'affranchir des dépôts d'énergie dus au minimum d'ionisation. Les dépôts d'énergie restant proviennent donc majoritairement du bremsstrahlung (il peut aussi s'agir de bruit). Les photons et les muons sont alors appariés par  $\Delta R(\mu, \gamma)$  croissant en tirant parti du fait que les photons sont émis principalement collinéairement aux muons. Un muon peut être apparié à plusieurs photons, mais l'inverse n'est pas possible.

Tous les graphiques montrés ci-après sont normalisés à 1. Avant appariement, le nombre de super-clusters reconstruits par événement est en grand désaccord entre les données et la simulation, en particulier pour le gain 50 (voir figure 4.28). L'accord est amélioré une fois les photons et les muons appariés (voir figure 4.29) mais une grande différence subsiste. Ceci est dû à une mauvaise modélisation du bruit électronique dans la simulation. Il a été remarqué avec les données de collisions que l'accord s'améliore lorsque les critères d'identification des photons sont durcis.



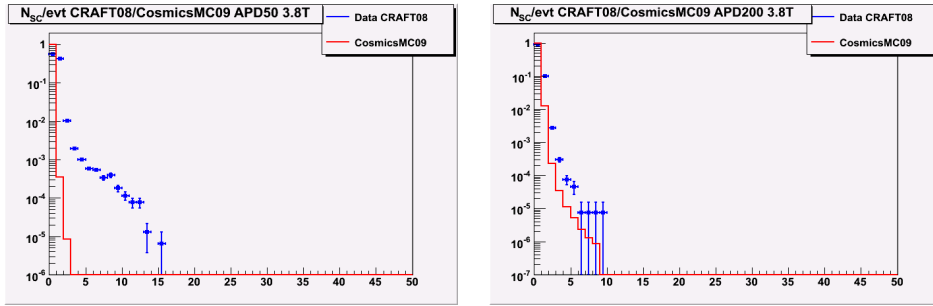


FIG. 4.28 – Nombre de super-clusters par évènement avant appariement avec les muons, pour le gain APD 50 (à gauche) et 200 (à droite).

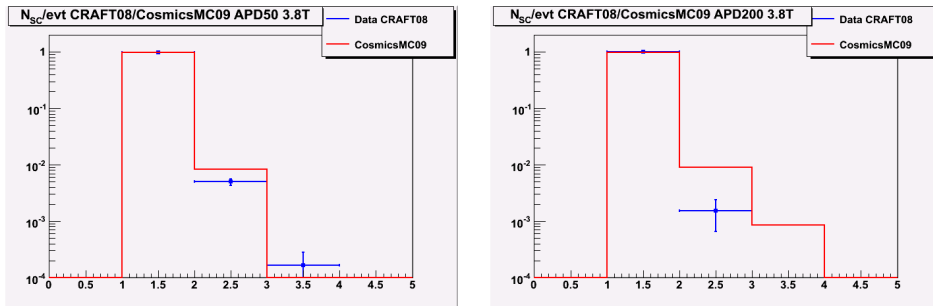


FIG. 4.29 – Nombre de super-clusters appariés aux muons, pour le gain APD 50 (à gauche) et 200 (à droite).

### Spectre des photons de bremsstrahlung interne

Le spectre en impulsion transverse des muons appariés aux photons est représenté figure 4.30 et montre un bon accord entre données et simulation pour les deux gains APD. L'énergie transverse  $E_T$  des photons est elle aussi en bon accord entre données et simulation (voir figure 4.31), spécialement à bas  $E_T$ . Pour les grandes valeurs de  $E_T$ , un manque de statistique dans les données avec un gain APD de 200 nous empêche de conclure. Il semble toutefois qu'il y ait un excès de données à grande impulsion transverse, ce qui pourrait être dû à la présence de "spikes" (cette analyse a été réalisée avant que le phénomène des "spikes" dans le ECAL ne soit connu). Enfin, les distributions de la distance  $\Delta R(\mu, \gamma)$  figure 4.32 montrent aussi un accord raisonnable pour les basses valeurs ( $\Delta R(\mu, \gamma) < 0.4$ ) où est concentrée la majeure partie des évènements, surtout en ce qui concerne le gain 50. Au-delà il semble qu'il y ait un désaccord entre données et simulation, mais le manque de statistique nous empêche ici aussi de conclure.

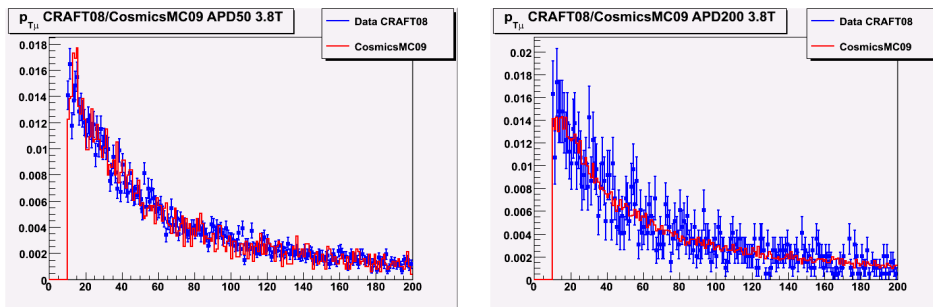


FIG. 4.30 – Impulsion transverse des muons appariés aux photons dans les données (en bleu) et dans la simulation (en rouge) pour le gain APD 50 (à gauche) et 200 (à droite).

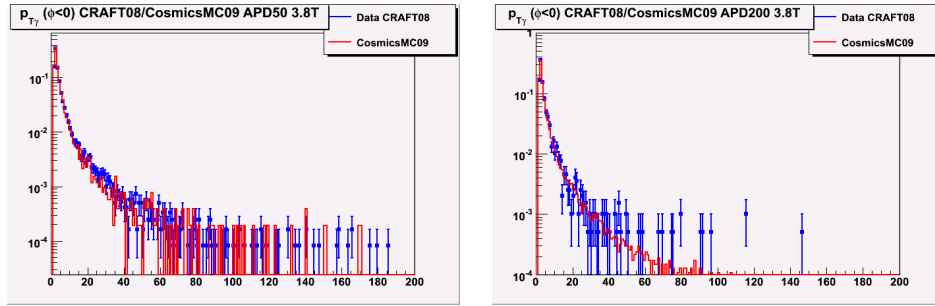


FIG. 4.31 – Energie transverse des photons appariés aux muons dans les données (en bleu) et dans la simulation (en rouge) pour le gain APD 50 (à gauche) et 200 (à droite).

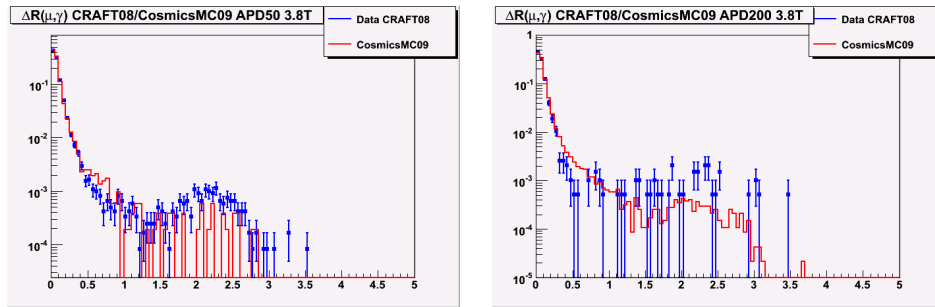


FIG. 4.32 – Distance  $\Delta R(\mu, \gamma)$  dans les données (en bleu) et dans la simulation (en rouge) pour le gain APD 50 (à gauche) et 200 (à droite).

En conclusion de cette étude, nous pouvons affirmer que le spectre en énergie transverse des photons à bas  $E_T$  ainsi que le spectre en impulsion transverse des muons est relativement bien reproduit dans la simulation dans la limite des incertitudes statistiques. La distribution de la distance  $\Delta R(\mu, \gamma)$  montre un bon accord dans la région  $\Delta R(\mu, \gamma) < 0.4$  qui est la région d'intérêt pour la récupération des photons FSR dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$ .

## Préparation pour l'évaluation du taux de faux à partir des événements $ZZ^*$ dans les données

### Méthode “random cone”

Au vu des performances obtenues en moyenne par la méthode de récupération “multi-brem” et sa variante “KeepCloseToZ”, on peut s'inquiéter de ce que le taux de faux photons FSR, s'il est estimé à partir de la simulation, ne dégrade la résolution sur le pic de masse invariante du boson de Higgs dans les données. Si cela est possible, le taux de faux doit donc être mesuré à partir des données. Nous proposons ici une technique nouvelle d'évaluation du taux de faux photons FSR récupérés dans les événements  $ZZ^*$  par une variante de la méthode “random cone” (ou cône aléatoire). La méthode “random cone” est une technique classique et éprouvée de mesure de l'efficacité d'isolation des leptons à partir des données qui repose sur le principe suivant [138] : on affecte aléatoirement la direction de “faux” leptons (ou leptons virtuels) dans tout l'espace de phase en  $\eta$ - $\phi$ . Pour chacune de ces directions, on mesure l'énergie dans un cône en  $\Delta R$ . Cette énergie est supposée être la même que l'énergie déterminée dans un même cône en  $\Delta R$  autour des leptons du signal, puisque la composition de l'évènement sous-jacent est censée être la même dans tout l'espace de phase. Dans la pratique cette composition varie en fonction de  $\eta$ , et l'énergie d'isolation doit donc être mesurée en fonction de  $\eta$ . Cette méthode fonctionne si le processus auquel elle est appliquée dispose d'une composition de l'évènement sous-jacent semblable à celle du processus de signal. Dans le cas où la méthode est appliquée dans le processus de signal, une attention particulière doit être portée au choix des directions aléatoires pour éviter de biaiser la méthode, de sorte que leurs cônes en  $\Delta R$  ne recouvrent pas des régions occupées par le signal. Le même principe peut être appliqué à notre étude, si

au lieu de mesurer l'énergie autour des directions aléatoires on leur applique la méthode de récupération "multi-brem". Le décompte des photons récupérés autour des directions aléatoires dans les zones où aucun photon FSR n'est attendu nous donne la possibilité d'évaluer le taux de faux FSR récupérés par la technique "multi-brem" dans le signal.

Pour cette étude, nous ne considérerons que des échantillons du processus  $ZZ^*$ , qui est le bruit de fond prépondérant en fin d'analyse et dont la composition de l'évènement sous-jacent est proche de  $H \rightarrow ZZ^*$ . Quatre directions  $\eta$ - $\phi$  aléatoires de leptons sont déterminées pour chaque évènement. Les directions choisies au hasard sont acceptées si  $\Delta R(dir, lepton) > 0.8$ , afin de se placer dans une région où aucun FSR n'est attendu (la contamination de vrais FSR dans cette région a été évaluée comme inférieure à 1%). Tous les photons récupérés par la méthode "multi-brem" appliquée à ces directions seront considérés comme faux FSR.

### Vérification Monte-Carlo

La deuxième étape consiste à déterminer par la vérité Monte-Carlo le nombre de faux FSR récupérés par la méthode "multi-brem" appliquée sur les leptons du signal. La technique usuelle pour ce faire consiste à marquer comme vrai FSR le photon reconstruit récupéré s'il est apparié avec un photon FSR niveau générateur dans un cône  $\Delta R(\gamma_{rec}, \gamma_{gen}) < \Delta R_{cone}$ , et comme faux FSR sinon. La valeur de  $\Delta R_{cone}$  est généralement prise à 0,7 ou 1. Ceci a été essayé, mais le taux de faux obtenu par cette technique est en désaccord avec le taux de faux obtenu par "random cone" pour les deux raisons suivantes. Premièrement, la valeur de  $\Delta R_{cone}$  est en fait une fonction de  $\eta$ , car elle dépend de la résolution spatiale sur la reconstruction des photons atteignant le ECAL. En réalité, un meilleur appariement est obtenu en considérant des rectangles en  $\eta$ - $\phi$  plutôt que des cônes en  $\Delta R$ . La valeur de la déviation entre l'angle du photon reconstruit et du photon généré  $\Delta\eta(\gamma_{gen}, \gamma_{rec})$  a été évaluée en fonction de  $\eta$  dans un échantillon de diphoton généré avec Pythia où l'évènement sous-jacent a été désactivé pour ne pas biaiser la reconstruction. Les plages de valeur de  $\Delta\eta(\gamma_{gen}, \gamma_{rec})$  indiquées dans la figure 4.33 (à droite) correspondent à 68%, 95%, 99,7% et 99,994% d'efficacité de reconstruction des photons.




FIG. 4.33 – A gauche,  $\Delta\eta(\gamma_{gen}, \gamma_{rec})$  dans la plage  $-2.5 < \eta < -2.25$ . A droite, valeurs de  $\Delta\eta(\gamma_{gen}, \gamma_{rec})$  pour 68%, 95%, 99,7% et 99,994% d'efficacité de reconstruction des photons.

La deuxième raison pour laquelle un cône  $\Delta R_{cone} < 0.1$  par exemple ne peut pas être utilisé repose sur la différence de comportement des électrons et des muons dans le calorimètre. On a déjà évoqué le fait que les photons émis colinéairement aux électrons sont regroupés dans un même super-cluster par la reconstruction. Ceci doit être pris en compte lors de l'appariement des photons reconstruits et générés. Au début de chaque évènement, tous les photons générateurs dont la direction est trop proche de celle des électrons reconstruits sont éliminés du lot de photons générés utilisé pour l'appariement, car ces photons seront reconstruits dans le même super-cluster que l'électron et risquent de biaiser l'évaluation du taux de faux. Ici encore, la proximité entre l'électron et le photon est mieux rendue par un rectangle  $\eta$ - $\phi$  qu'avec

un cône en  $\Delta R$ . Les valeurs de veto en  $\eta$  en-dessous desquelles les photons sont reconstruits dans le même super-cluster que l'électron ont été évaluées dans un échantillon de QCD Madgraph dans la plage  $100 < \hat{p}_t < 250$  GeV (où  $\hat{p}_t$  est la somme scalaire des impulsions transverses des partons de l'interaction dure), en considérant l'angle  $\Delta\eta(SC1, SC2)$  entre le super-cluster  $SC1$  ayant  $E_T > 5$  GeV (pour imiter les électrons) et  $SC2$  ayant  $E_T > 3$  GeV (pour imiter les photons récupérés par la méthode "multi-brem"). De la même manière que précédemment, les valeurs de  $\Delta\eta(SC1, SC2)$  sont données pour des efficacités de veto de 68%, 95%, 99,7% et 99,994% (voir figure 4.34).

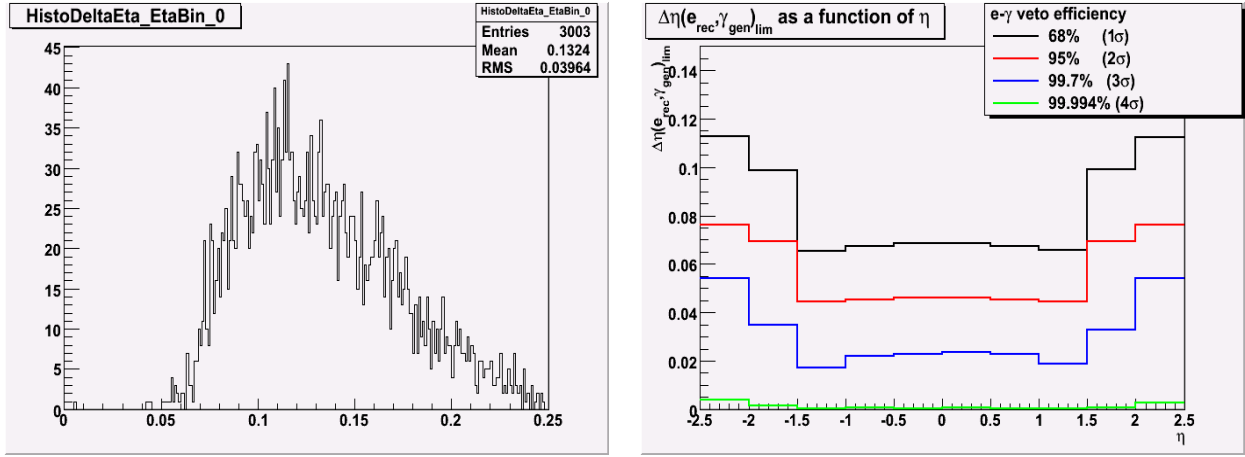


FIG. 4.34 – A gauche,  $\Delta\eta(e, \gamma)$  dans la plage  $-2.5 < \eta < -2.25$  calculé à partir des plus proches super-clusters par évènement dans un échantillon de QCD. A droite, valeurs de  $\Delta\eta(e, \gamma)$  pour 68%, 95%, 99,7% et 99,994% d'efficacité de veto des photons trop proches des électrons.

Les valeurs pour l'angle  $\eta$  maximum d'appariement entre les photons reconstruits et les photons niveau générateur sont choisies de telle sorte que l'efficacité de reconstruction soit de 99,7% sur toute la plage en  $\eta$ , et les valeurs de l'angle  $\eta$  minimum entre les électrons et les photons sont choisies de telle sorte que l'efficacité de veto soit de 68% sur toute la plage en  $\eta$  (une plus haute valeur de l'efficacité aurait pu être choisie si elle avait été calculée directement sur des photons et des électrons plutôt que sur des super-clusters). Le veto de proximité électron-photon est aussi appliqué aux directions aléatoires pour imiter les électrons dans les canaux  $2e2\mu$  et  $4e$ . L'angle  $\phi$  a aussi été considéré mais n'a pas montré changer les résultats. De plus, les photons reconstruits dans la région de transition entre le tonneau et les bouchons ( $1.4442 < |\eta| < 1.556$ ) ne sont pas considérés.

### Définition du taux de faux

Nous avons choisi de définir le taux de faux comme le nombre de leptons appariés avec au moins un faux photon FSR par la méthode "multi-brem", divisé par le nombre total de leptons, en fonction de  $\eta$  du lepton (plutôt que du  $\eta$  des photons pour éviter la migration entre les bins).

### Résultats

Les résultats pour la méthode "random cone" et la vérification Monte-Carlo sont présentés figure 4.35. Le taux de faux est bien reproduit par le Monte-Carlo pour le canal  $4\mu$  et pour le canal  $2e2\mu$ , tandis qu'il y a désaccord dans plus de la moitié des divisions dans le canal  $4e$ . Des problèmes subsistent quel que soit le canal dans les bouchons, qui nécessitent investigation. Il est à noter que le taux de faux défini de la sorte est inférieur à 1% quel que soit le canal, et semble augmenter lorsque des muons sont présents. Par rapport au nombre total de leptons, peu de faux photons FSR sont récupérés, et il y en a plus pour les muons que les électrons en raison de la clusterisation des photons colinéaires aux électrons. Ces résultats n'ont pas pu être vérifiés dans les canaux  $H \rightarrow ZZ^*$  en raison d'un manque de statistique.

En conclusion, la méthode proposée d'évaluation du taux de faux à partir des données semble fonctionner particulièrement dans les canaux  $2e2\mu$  et  $4\mu$ , mais nécessite une grande luminosité intégrée (prob-

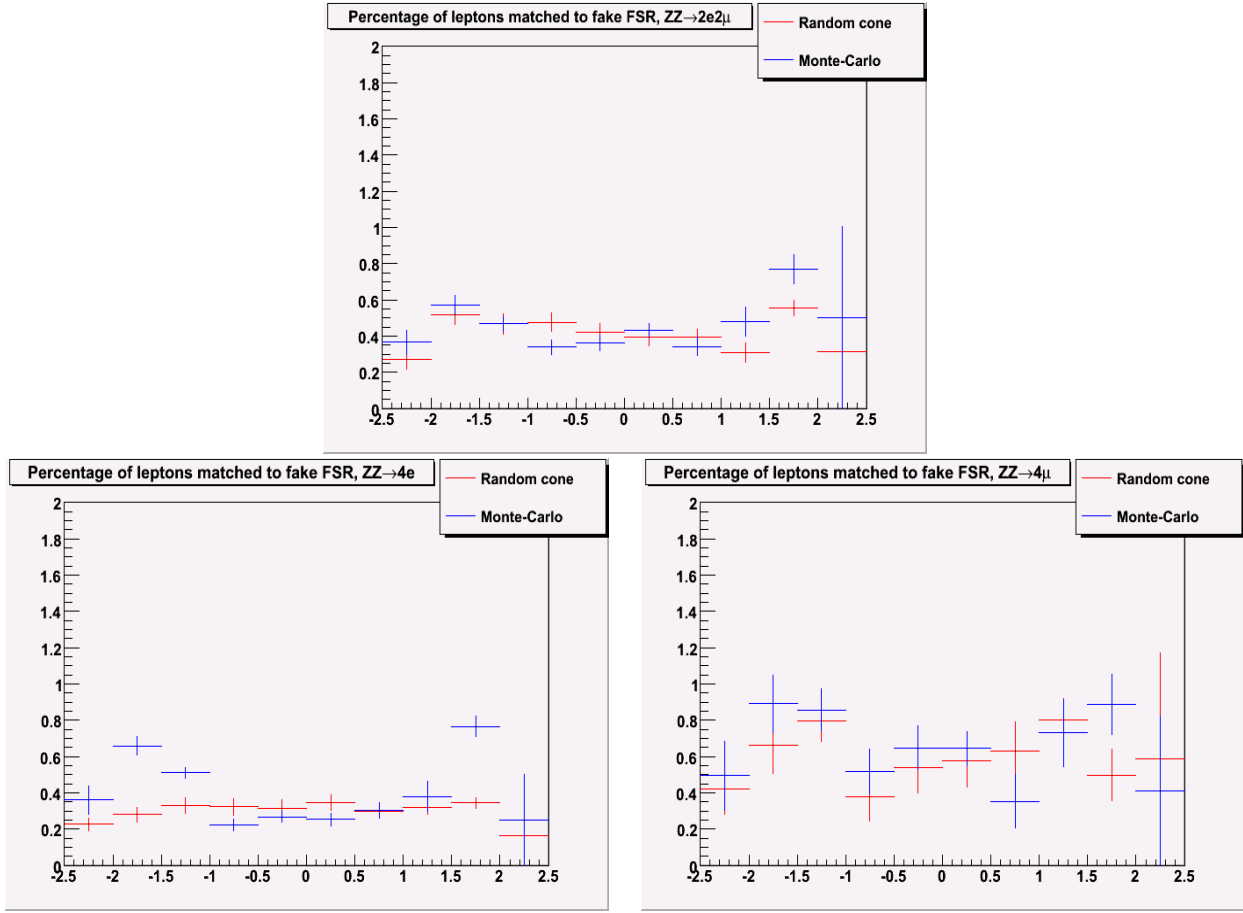


FIG. 4.35 – Taux de leptons appariés à au moins un faux photon FSR en fonction de  $\eta_{lept}$  dans le canal  $ZZ \rightarrow 4e$ ,  $ZZ \rightarrow 4\mu$  et  $ZZ \rightarrow 2e2\mu$ .

ablement supérieure à  $1 fb^{-1}$ ), car le taux de leptons appariés à des faux FSR est inférieur à 1%. Un travail complémentaire serait nécessaire pour comprendre pourquoi la méthode “random cone” et vérité Monte-Carlo sont en désaccord dans le canal  $4e$  et dans les bouchons, mais on peut supposer que le problème provient de la clusterisation des électrons et des photons et de la quantité de matière présente devant les bouchons. Une investigation plus avant pourrait permettre d’améliorer la méthode “multi-brem” elle-même en utilisant des rectangles de récupération  $\eta$ - $\phi$  plutôt qu’un cône  $\Delta R(lept, \gamma)$ .

## 4.6 Conclusions et perspectives pour la récupération des photons de bremsstrahlung interne

### Performances de la méthode “multi-brem”

Nous avons proposé une nouvelle technique “multi-brem” de récupération des photons de bremsstrahlung interne pour le canal  $H \rightarrow ZZ^* \rightarrow 4l$ , capable de récupérer un nombre variable de photons (jusqu’à 2 photons ayant  $E_T > 3$  GeV par lepton et 3 par événement dans un cône  $\Delta R < 0.25$ ). Les performances obtenues sont meilleures que celles obtenues précédemment par la méthode “PTDR” sur toute la gamme de masse du boson de Higgs testée. La méthode “multi-brem” améliore en moyenne la résolution des pics de masse invariante des bosons  $Z^0$  et du boson de Higgs, particulièrement dans le canal  $4\mu$  (2,45% d’amélioration sur la résolution du pic de masse du boson de Higgs) et dans le canal  $2e2\mu$  (1,30%). La technique fonctionne moins bien dans le cas  $4e$  et pour les pics des bosons  $Z \rightarrow ee$  en raison de la clusterisation des photons FSR dans les super-clusters des électrons. Le gain sur la signification des trois canaux combinés en fin d’analyse est de 5% sur la plage de masse  $m_H > 180$  GeV. Une implémentation de la

méthode “multi-brem” est présente dans le code de l’analyse  $H \rightarrow ZZ^* \rightarrow 4l$  de CMS. L’algorithme et ses performances sont décrites dans deux notes internes [134, 135].

Le faible nombre de photons récupérés par évènement rend la technique sujette à des fortes fluctuations statistiques. Les performances ont donc été vérifiées sur des petits lots d’évènements correspondant à une luminosité du signal de  $5,9 \text{ fb}^{-1}$  pour  $m_H = 120 \text{ GeV}$  et  $1 \text{ fb}^{-1}$  pour  $m_H = 195 \text{ GeV}$ . Les améliorations sur la résolution du pic de masse invariante du boson de Higgs sont plus faibles que l’amélioration moyenne mais sont compatibles avec les incertitudes statistiques.

Les incertitudes systématiques liées à la méthode “multi-brem” sont de deux types. Les incertitudes théoriques proviennent de la modélisation du phénomène de bremsstrahlung interne. Des cônes en  $\Delta R(\text{lept}, \gamma)$  de taille différentes ont été trouvés avec Pythia et Photos. Toutefois, la simulation semble en bon accord avec les données de muons cosmiques dans l’espace de phase utilisé par la récupération des FSR par la méthode “multi-brem”, où les dépôts d’énergie électromagnétique sont des photons de bremsstrahlung externe, issus de l’interaction des muons cosmiques avec la matière. L’autre source d’incertitudes systématiques provient de la méthode de récupération elle-même, qui admet un certain taux de faux. Nous avons proposé une méthode pour évaluer le nombre de leptons appariés à de faux photons FSR dans les évènements  $ZZ^*$ , qui devrait être utilisable dès  $1 \text{ fb}^{-1}$  de luminosité intégrée.

### Autres applications possibles

Les paramètres de la technique de récupération “multi-brem” pourraient être ajustés pour améliorer la précision sur la mesure de la largeur de désintégration du boson  $Z$  dans le canal  $Z \rightarrow ll + \text{jets}$ , spécialement  $Z \rightarrow \mu\mu$ . De plus l’analyse de ce canal constituerait une vérification croisée de la récupération dans le canal  $H \rightarrow ZZ^* \rightarrow 4l$ . Il y aurait aussi la possibilité de voir quelles seraient les performances dans le canal  $W + \text{jets}$  (où la situation est plus compliquée en raison de l’énergie manquante associée à la désintégration  $W \rightarrow l\nu$ ).

Une autre possibilité d’application consisterait à essayer la technique “multi-brem” dans les désintégrations de résonances hadroniques, pour voir si la récupération des photons FSR issus des quarks pourrait améliorer les algorithmes de reconstruction des jets. Avec une grande luminosité, la technique “multi-brem” pourrait éventuellement être un des élément d’une analyse visant à mesurer la fonction de fragmentation des quarks en photons.

## 4.6.1 Améliorations possibles

### Amélioration de l’analyse

L’étude présentée ici a été effectuée avec une énergie dans le centre de masse de 10 TeV. L’étude devrait être répétée à 7 TeV, en accord avec l’énergie de la première période d’exploitation du LHC.

Toute l’étude de la récupération des photons FSR devrait être répétée avec le générateur Photos, qui est connu pour modéliser plus précisément les radiations de photons que Pythia. En particulier, Photos prend en compte les interférences entre l’état initial et l’état final, tandis que dans Pythia ces deux états sont indépendants. L’utilisation de Photos pourrait conduire à un ajustement différent des paramètres de la technique “multi-brem”, mais la méthode en elle-même devrait rester valable. Dans tous les cas, le dernier mot devrait être laissé aux données, car tous les paramètres de la récupération seront ajustés à partir des données pour obtenir la meilleure performance possible.

Même si les principaux bruits de fond ( $ZZ^*$ ,  $Zbb$ ,  $t\bar{t}$ ) ont été pris en compte dans le calcul de la signifi-  
cance, les résultats devraient inclure tous les bruits de fonds. Les “gedanken experiment” devraient être répétées pour la méthode de récupération “KeepCloseToZ”. Une amélioration par rapport à la méthode “multi-brem” est attendue pour un faible nombre d’évènements, en accord avec les résultats obtenus en

utilisant toute la statistique.

### Amélioration de l'algorithme

Si on compare les performances obtenues sur la résolution en masse invariante (figure 4.15) au niveau reconstruit et au niveau générateur (figure 4.2), on peut voir qu'il reste encore une grande marge d'amélioration.

Une première idée pour améliorer les performances de l'algorithme serait d'accentuer le nettoyage du lot de candidats photons. Par exemple, une isolation hadronique des photons pourrait être demandée pour diminuer le taux de faux FSR récupérés, car les photons accompagnés d'une grande énergie laissée dans le HCAL sont plus probablement des photons (ou d'autres particules) provenant de l'évènement sous-jacent et issus d'un jet. Toutefois, le gain attendu pour une telle opération est plutôt faible, car une isolation est déjà appliquée sur les leptons qui émettent les photons FSR.

Jusqu'ici, les paramètres de l'algorithme n'ont pas été optimisés séparément pour les électrons et les muons. Les électrons sont de masse plus faible que les muons et émettent plus de photons FSR (qui sont rassemblés dans le super-cluster des électrons) : d'où l'idée d'optimiser le nombre de photons récupérables par lepton. La résolution sur le pic de masse invariante du boson  $Z^0$  est d'environ 3 GeV pour le canal  $2e$  et 2.5 GeV pour le canal  $2\mu$ . Le paramètre  $\sigma_Z$  de la méthode "KeepCloseToZ" gagnerait donc à être optimisé lui aussi séparément.

Les paramètres choisis ont été optimisés pour un boson de Higgs ayant  $m_H = 195$  GeV dans le canal  $2e2\mu$  (ce qui assure une homogénéité de traitement des électrons et des muons) et les performances ont ensuite été vérifiées dans la plage de masse  $115 < m_H < 250$  GeV pour les trois canaux. Une option envisageable consisterait à effectuer une optimisation des paramètres en fonction de la masse du boson de Higgs recherchée, au moins pour les trois régions de basse masse  $115 < m_H < 145$  GeV, de masse intermédiaire  $145 < m_H < 180$  GeV et de haute masse  $m_H > 180$  GeV. Une autre option a été essayée, qui consiste à 1) ne pas récupérer de 2<sup>ème</sup> photon pour des leptons ayant  $p_{T,lept} < P$  (il est peu probable qu'un lepton émette plusieurs photons si son impulsion transverse est trop faible); 2) admettre une taille de cône plus grande :  $\Delta R(lept, \gamma) < C$  avec  $C > 0.25$  pour des photons suffisamment durs qui répondent à  $E_{T,\gamma}/p_{T,lept} > r$ , et contribuant significativement à la masse du boson de Higgs (le spectre des photons FSR est plus dur que les photons de l'évènement sous-jacent). Les paramètres  $P$ ,  $r$  et  $C$  n'ont pas pu être déterminés indépendamment de la masse du boson de Higgs, c'est pourquoi cette option n'a pas été retenue dans l'analyse présentée dans ce chapitre. Un test pour une masse  $m_H = 195$  GeV (avec les paramètres optimisés  $P = 80$  GeV,  $C = 0.85$  et  $r = 0.7$ ) a montré une amélioration significative de 20% sur la figure de mérite  $h/\sigma$  par rapport au cas sans récupération (au lieu d'environ 10% pour "KeepCloseToZ").

Un problème que nous n'avons pas encore évoqué est lié au fait que la récupération des photons FSR est appliquée seulement en fin d'analyse. Il est vrai que l'émission de photons FSR a lieu avec une certaine probabilité quelle que soit le lepton. Par conséquent, il serait intéressant d'appliquer la récupération des photons FSR en début d'analyse, puis de fournir à la suite de l'analyse les quadri-impulsions des leptons incluant les photons émis afin de mesurer le gain en performances. De plus, la récupération des photons FSR avant que les critères d'isolation ne soient appliqués aux leptons pourrait permettre d'améliorer l'efficacité de sélection des leptons du signal. En effet, les photons émis collinéairement aux leptons déposent leur énergie à proximité des leptons dans le ECAL : des évènements peuvent donc être rejetés par ces critères d'isolation simplement parce qu'un photon FSR a été émis et compté dans l'énergie d'isolation.

Enfin, dans le but d'améliorer les performances de la récupération des photons FSR dans les canaux électroniques, l'étude d'un algorithme de clusterisation dédié aux électrons serait souhaitable. Si cela ne peut pas être mené à bien, une première idée serait de changer le critère de récupération des photons dans un cône  $\Delta R$  par un critère en  $\eta$ - $\phi$ , qui tiendrait compte du fait que les électrons (issus ou non de conversions) déviés dans la direction  $\phi$  par le champ magnétique émettent des photons sur une large plage

en  $\phi$ . Ceci pourrait en particulier améliorer l'accord entre simulation et méthode "random cone" pour l'évaluation du taux de faux dans les données.

#### 4.6.2 Plans pour les premières données

Une première vérification des distributions des photons FSR dans les données de muons cosmiques a montré un bon accord entre données et simulation pour les photons émis colinéairement aux muons. Maintenant que nous disposons de données de collisions, de nouvelles vérifications / optimisation vont devenir possibles :

- Dès aujourd'hui, il est possible d'utiliser la méthode "random cone" dans les données de biais minimum pour évaluer le taux de faux photons FSR qui seront récupérés lorsque la luminosité sera assez élevée pour donner lieu à de l'empilement.
- Dès  $10 \text{ pb}^{-1}$ , l'analyse des photons FSR dans les processus  $Z \rightarrow ee$  et  $Z \rightarrow \mu\mu$  pourra commencer : ajustement des paramètres de l'algorithme (nombre de photons par lepton et par évènement, énergie transverse des photons, valeur de cône en  $\Delta R(lept, \gamma), \sigma_Z$ ) pour obtenir la meilleure résolution possible sur la masse du  $Z$ . Il devrait aussi être possible d'extrapoler le nombre de photons récupérables par évènement dans le processus  $ZZ^*$ , en tirant parti du fait que cette distribution suit une loi de "Poisson" (faibles occurrences indépendantes).
- Dès  $100 \text{ pb}^{-1}$ , il devient possible d'utiliser un lot de photons certifiés sélectionnés par l'analyse du canal  $Z \rightarrow \mu\mu\gamma$ . Le point de fonctionnement de la distribution  $\Delta R(lept, \gamma)$  pourra alors être évalué à partir des données.
- Dès  $1 \text{ fb}^{-1}$ , un nombre suffisant d'évènements  $ZZ^*$  aura été accumulé, et l'évaluation du taux de faux à partir des données pourra être effectuée et comparée aux prédictions.
- Dès quelques  $\text{fb}^{-1}$ , il deviendra possible de mesurer l'impact de la récupération des photons FSR sur la signification obtenue à partir des données, et de voir si la méthode "multi-brem" peut aider à découvrir le boson de Higgs avec une luminosité intégrée inférieure à celle nécessaire pour l'analyse sans récupération.



## Chapitre 5

# Discrimination $\gamma/\pi^0$ à l'aide d'un réseau de neurones

Les photons durs et isolés, tels les photons issus de la désintégration  $H \rightarrow \gamma\gamma$ , constituent un important signal recherché dans l'expérience CMS. Le canal  $H \rightarrow \gamma\gamma$  est le canal de recherche privilégié pour une masse du boson de Higgs comprise entre 110 GeV et 140 GeV, en partie grâce à l'excellente résolution en énergie des photons mesurée dans le calorimètre électromagnétique [16]. La mesure des sections efficaces des processus  $\gamma+X$  et  $\gamma\gamma+X$  qui sont des bruits de fond pour la recherche du boson de Higgs revêt aussi un intérêt théorique en soi, et constitue une étape nécessaire à la compréhension de la détection des photons isolés dans CMS.

L'analyse des processus  $\gamma+X$ ,  $\gamma\gamma+X$  et  $H \rightarrow \gamma\gamma$  demande de disposer d'outils capables d'identifier les photons du signal (photons prompts issus de l'interaction dure ou de la désintégration du boson de Higgs) avec une grande pureté, ce qui revient à rejeter avec une grande efficacité les photons mal identifiés qui proviennent des jets des processus QCD. La plupart des photons mal identifiés proviennent de mésons  $\pi^0$ , produits copieusement du fait de leur faible masse dans les processus d'hadronisation des quarks et des gluons provenant de l'interaction dure, des ISR ou FSR ou encore de l'évènement sous-jacent et de l'empilement.

Nous proposons dans ce chapitre une nouvelle approche pour la discrimination  $\gamma/\pi^0$  à l'aide d'un réseau de neurones. Après avoir présenté les propriétés des photons et des  $\pi^0$  ainsi que l'ambiguïté rencontrée lors de leur identification, nous mentionnerons quelques unes des approches qui ont été essayées dans CMS pour les discriminer. Le bruit de fond de  $\pi^0$  au LHC ayant une très grande section efficace, un outil ayant un grand pouvoir de discrimination est nécessaire pour l'identification du signal. Dans la mesure où les photons et les  $\pi^0$  ont des propriétés très proches en terme de forme du dépôt d'énergie dans la gamme d'énergie où le signal est recherché, une approche basée sur un classifieur multivariable semble nécessaire. Nous avons choisi d'utiliser un réseau de neurone artificiel employé communément, le perceptron multicouches (MLP), car parmi tous les classifieurs essayés il est celui qui a donné la meilleure discrimination. De nombreuses variables d'entrée pour le MLP ont été essayées, et l'optimisation nous a porté vers le choix de deux catégories de variables : trois variables portant sur la forme latérale du cluster dans le ECAL et trois variables portant sur l'environnement énergétique autour des photons (ou  $\pi^0$ ) dans d'autres sous-détecteurs. Contrairement aux analyses précédentes dans CMS, cette méthode fonctionne aussi bien pour les photons convertis que pour les photons non-convertis. Les performances du MLP seront analysées dans la simulation et validées à partir des données du LHC avec une énergie dans le centre de masse de 7 TeV.

### 5.1 Position du problème

#### 5.1.1 Propriétés des photons et des pions neutres

Les pions neutres (ou  $\pi^0$ ) produits copieusement dans les jets des processus QCD se désintègrent majoritairement en une paire de photons (98,8% [8]). Si le  $\pi^0$  se désintègre en une paire de photons

très collimée (pour un  $\pi^0$  très boosté), les dépôts d'énergie des deux photons courent le risque d'être récupérés dans un seul super-cluster lors de la reconstruction, et donc d'être identifiés comme un photon unique (typiquement lorsque l'écartement entre les dépôts d'énergie associés aux photons est de l'ordre de quelques cristaux). On montre figure 5.1 un schéma qui illustre cette propriété. Des variables utilisant la forme latérale du cluster reconstruit peuvent alors permettre de discriminer entre les photons et les  $\pi^0$ . En effet, le dépôt d'énergie de la paire de photons issus du  $\pi^0$  aura une tendance à être plus "oval" et plus étalé, tandis que le dépôt d'énergie d'un photon du signal devrait être plus concentré et "circulaire". Malheureusement, les photons de signal qui se convertissent en une paire  $e^+/e^-$  dans le trajectographe risquent aussi de donner lieu à un dépôt plus étalé dans le ECAL du fait des deux points d'impacts de l'électron et du positon déviés par le champ magnétique de CMS.




FIG. 5.1 – Les deux photons issus d'un  $\pi^0$  sont reconstruits dans deux super-clusters différents (à gauche) et dans un seul super-cluster (à droite) suivant leur écartement  $d$  dans le calorimètre électromagnétique [143].

De plus, les  $\pi^0$  émis lors de l'hadronisation des quarks ou gluons sont souvent accompagnés d'autres produits de désintégration. Dans le ECAL, il s'agit principalement (en fin de chaîne de désintégration) de  $\pi^0$  supplémentaires,  $\eta$ ,  $\rho^0$  et  $w$ , particules additionnelles qui se désintègrent en électrons et en photons. Diverses particules chargées, comme les  $\pi^\pm$  et les kaons chargés peuvent laisser une trace dans le trajectographe avant de se désintégrer et déposer une partie de leur énergie dans une gerbe hadronique reconstruite à l'aide du HCAL, qui récoltera aussi l'énergie des particules neutres comme les  $K_{long}^0$  ou les neutrons.

En tirant parti de cette activité des jets autour des  $\pi^0$ , il est possible d'améliorer la discrimination. À l'inverse des  $\pi^0$  (ou des autres particules neutres se désintégrant en photons collimés), les photons prompts issus de l'évènement dur (dans le cas  $\gamma+X$  et  $\gamma\gamma+X$ ) ou de la désintégration  $H \rightarrow \gamma\gamma$  ne seront pas accompagnés d'une grande activité des jets. Les autres dépôts d'énergie détectés à leur proximité proviennent soit des jets de l'évènement sous-jacent (ou de l'empilement), qui ont une distribution homogène dans tout le détecteur, soit des jets ISR ou FSR. Les photons durs du signal peuvent donc être identifiés en utilisant des critères d'isolation. Les critères classiques d'isolation requièrent que l'impulsion transverse recueillie dans un cône  $\Delta R$  fixe autour du photon dans le trajectographe, le ECAL et/ou le HCAL soit inférieure à un certain seuil. La distance  $\Delta R$  entre le photon et la trace la plus proche dans le trajectographe est aussi une variable qui a montré un pouvoir discriminant [144].

Une subtilité concernant l'isolation des photons émis dans l'état initial ou final complique le tableau. De tels photons ne sont pas en général (mais cela dépend des définitions que l'on choisit) considérés comme des photons prompts issus de l'évènement dur, puisqu'ils sont émis par bremsstrahlung des quarks initiaux ou finaux. De tels photons, dits de fragmentation, disposent souvent d'une énergie comparable à celle des photons prompts de l'évènement dur et les critères de forme du cluster ne suffisent pas à les distinguer. En revanche, les photons de fragmentation sont généralement moins bien isolés que les photons prompts de l'évènement dur car ils ont tendance à être émis colinéairement au quark dont ils sont issus, qui peut aussi émettre des gluons ISR/FSR ou s'hadroniser et fragmenter. Si les critères de forme du cluster et d'isolation restent insuffisants, il reste toujours la possibilité d'utiliser les propriétés cinématiques de ces photons pour aider à la discrimination, notamment l'idée que les photons prompts issus de l'interaction dure reculent contre un jet (au LO, pour le processus  $\gamma$ +jet) ou contre un autre photon prompt (au LO pour le processus  $\gamma\gamma$  ou  $H \rightarrow \gamma\gamma$ ).

### 5.1.2 Utilisation d'un réseau de neurones

De nombreuses analyses de discrimination  $\gamma/\pi^0$  font usage d'un réseau de neurones. Parce que les dépôts d'énergie des  $\pi^0$  sont très semblables à ceux des photons, la combinaison de plusieurs variables dans un classifieur multivariables donne de meilleurs résultats, et l'un des plus puissants classifieurs est la famille des réseaux de neurones.

Un classifieur multivariable est un algorithme de classement statistique. Les classifieurs sont utilisés pour séparer deux populations différentes dans un même échantillon (en physique, signal et bruit de fond dans les données). Il existe un grand nombre de classifieurs différents, comme le discriminant linéaire de Fischer [145], les estimateurs de vraisemblance [146], les réseaux de neurones artificiels [147] ou les arbres de décisions boostés [148]. Le package TMVA [149] propose un grand nombre de classifieurs pour les analyses de physique, utilisables de façon simple et automatisée pour l'utilisateur, et interfacé avec ROOT [28]. Après de nombreux tests, nous avons trouvé (comme il sera montré plus loin, section 5.3.1) qu'un réseau de neurones artificiels (ANN) de type perceptron multi-couches (recommandé par les auteurs de TMVA parmi d'autres ANN) donne les meilleurs performances. Nous allons décrire son fonctionnement dans les lignes qui suivent.

#### Structure d'un réseau de neurones

Les premières tentatives d'élaboration d'un réseau de neurones proviennent de la neurologie et la biologie, et avaient pour but de modéliser la réponse des animaux face à une situation donnée [150]. Un réseau de neurones, en tant que classifieur multi-variables, est un algorithme qui accepte un nombre de variables fixe en entrée et fournit une variable en sortie qui est plus discriminante que chacune des variables d'entrée séparément. Il est constitué d'un certain nombre d'unités de calculs, les neurones, qui peuvent être reliées entre eux selon divers degrés de connexité. Chaque neurone fournit une réponse en fonction des autres neurones auxquels il est connecté. Un réseau de neurones est défini par le nombre de couches de neurones, les poids des interconnexions neuronales et la fonction de réponse des neurones.

Les perceptrons multi-couches (ou "multi-layer perceptron", MLP) sont des réseaux de neurones artificiels composés de plusieurs couches. Pour réduire la complexité de l'algorithme, chaque neurone d'une couche n'est connectée qu'aux neurones de la couche précédente. La première couche est appelée couche d'entrée et est simplement constitué d'un neurone par variable d'entrée  $x_{1\dots n}$ , tandis que la dernière couche (couche de sortie) fournit la sortie du réseau de neurones, l'estimateur  $y_{ANN}$ . Entre les deux, un MLP peut contenir plusieurs couches cachées (voir schéma 5.2). A chaque connection entre un neurone  $i$  d'une couche  $l$  et un neurone  $j$  de la couche suivante  $l + 1$  est associée un poid  $w_{ij}^l$ . La fonction de réponse des neurones est la composition  $\rho(\kappa(x))$  d'une combinaison linéaire  $\kappa$  des neurones de la couche précédentes et d'une fonction d'activation  $\rho$  (qui peut être une fonction de Heaviside, fonction tangente hyperbolique, fonction  $1/(1 + e^{-x})$  dite "sigmoïde"). Cela se traduit mathématiquement par les formules suivantes, pour le neurone  $j$  d'une couche  $l + 1$  :

$$\begin{aligned}\kappa : (y_1^l, y_2^l, \dots, y_n^l) &\rightarrow C_j^l = w_{0j}^l + \sum_i w_{ij}^l y_i^l \\ \rho : C_j^l &\rightarrow y_j^{l+1} = \tanh(C_j^l)\end{aligned}$$

Où  $C_j^l$  est la combinaison linéaire des entrées du neurone  $j$  pondérés par les poids  $w_{ij}^l$ .  $y_j^{l+1}$  est la réponse du neurone  $j$  de la couche  $l + 1$ . On a pris l'exemple d'une fonction d'activation tangente hyperbolique pour  $\rho$ . Il est à noter que la fonction d'activation de la couche de sortie est l'identité.

#### Entraînement et application

L'entraînement consiste à apprendre au réseau de neurone à discriminer entre signal et bruit de fond, ce qui revient à choisir les poids  $w_{ij}^l$  de sorte que la sortie du réseau de neurone soit proche de 1 pour le signal et de -1 pour le bruit de fond. Ceci est effectué par un algorithme d'entraînement supervisé : lors de l'entraînement, la réponse du réseau de neurones est connue pour chaque événement. Un ensemble




FIG. 5.2 – Structure d’un perceptron multi-couche avec une couche d’entrée (“input layer”), une couche cachée (“hidden layer”) et une couche de sortie (“output layer”), comportant quatre variables d’entrée et cinq neurones dans la couche cachée.

d’évènements de signal et de bruits de fond sont fournis au MLP dans deux échantillons séparés. Par défaut, TMVA sépare les échantillons en deux : la moitié pour l’entraînement et l’autre pour l’application. Le choix des poids est effectué en minimisant une fonction d’erreur par la méthode de descente du gradient (qui recherche les minima globaux). La fonction d’erreur est définie par :

$$E(w_{ij}^l) = \frac{1}{2} \sum_a^N \left( y_{ANN,a}(w_{ij}^l) - \hat{y}_a \right)^2$$

Où la somme est effectuée sur les  $N$  évènements fournis pour l’entraînement,  $\hat{y} = 0$  pour le bruit de fond et  $\hat{y} = 1$  pour le signal.

Une fois l’entraînement effectué, les poids calculés sont stockés dans un fichier texte. Le réseau de neurones est alors appliqué à l’autre moitié de l’échantillon. Si la réponse de l’échantillon test et de l’échantillon d’application fournissent une réponse en accord dans la limite des incertitudes statistiques, le réseau de neurones est robuste et peut être appliqué dans les analyses. Sinon, le réseau de neurone est surentraîné : l’entraînement a appris au MLP à reconnaître des fluctuations du signal plutôt que le signal lui-même et ne peut pas être utilisé dans l’analyse.

Afin de discriminer au mieux le signal du bruit de fond, les variables d’entrée du MLP doivent être choisies avec soin. Il est aussi possible de jouer sur le nombre de neurones et de couches cachées pour obtenir la meilleure performance (en prenant garde de ne pas surentraîner le réseau de neurones).

### 5.1.3 Discrimination $\gamma/\pi^0$ dans CMS

Diverses approches ont été proposées au cours des années précédentes dans l’expérience CMS pour discriminer les photons des  $\pi^0$ . La discrimination  $\gamma/\pi^0$  proprement dite (i.e. fondée sur la forme du cluster) a jusqu’ici été séparée en deux études, selon que le photon soit reconstruit comme un photon converti ou non. Dans les deux cas, un réseau de neurones a été construit et a donné de meilleures performances que l’utilisation de variables séquentielles. Le point de départ des deux analyses est la discrimination  $\gamma/\pi^0$  pour la recherche du boson de Higgs. Elles établissent les performances du réseau de neurones pour des photons ayant une grande impulsion transverse ( $p_T > 40$  GeV) et isolés. Nous insisterons particulièrement sur le cas des photons convertis, puisqu’il s’agit du point de départ du travail que nous présenterons par la suite. D’autres approches qui ne sont pas nommées explicitement discrimination  $\gamma/\pi^0$  mais méthodes de rejet des jets, utilisent aussi bien les variables de formes du cluster que les variables d’isolation.

### Discrimination $\gamma/\pi^0$ pour les photons convertis

La reconstruction des photons convertis dans CMS a été brièvement décrite section 1.3.2. Le super-cluster d'un photon peut être associé à zero, une ou deux traces dans le trajectographe par l'algorithme. Les analyses suivantes utilisent les catégories une et deux traces pour améliorer la discrimination.

L'analyse pionnière dans CMS de discrimination entre les photons convertis et les  $\pi^0$  [151] pour la recherche du boson de Higgs propose d'opérer selon le schéma suivant. Les photons ayant une énergie transverse  $E_T > 20$  GeV et  $|\eta| < 2.5$  sont sélectionnés dans des événements  $\gamma$ +jets et  $H \rightarrow \gamma\gamma$ . Des critères d'isolation dans le trajectographe, ECAL et HCAL sont préalablement appliqués sur les photons reconstruits. Les photons convertis sont ensuite sélectionnés en utilisant l'information du trajectographe et du ECAL. Le réseau de neurones est entraîné sur les photons convertis issus du boson de Higgs comme signal, et les jets de  $\gamma$ +jet identifiés comme photons pour bruit de fond. Les 6 variables utilisées comme entrée du réseau de neurones sont  $E/p$  (énergie du super-cluster divisée par l'impulsion des traces de conversions), la distance  $d$  entre les traces de l'électron et du positon extrapolée dans le ECAL, l'énergie  $S4$  des cristaux  $2 \times 2$  de plus haute énergie incluant le cristal de plus haute énergie dans le super-cluster divisé par l'énergie du super-cluster. Deux autres variables de sous-structure du cluster sont utilisées : la masse invariante  $m$  entre le photon converti et le plus proche basic-cluster dans un cône  $\Delta R < 0.3$  (en tirant parti du fait qu'un des photon issu du  $\pi^0$  peut se convertir et l'autre non), et une variable d'asymétrie  $A$  en énergie du super-cluster de part et d'autre de la ligne qui sépare les points d'impacts de l'électron et du positon dans le trajectographe. Un rejet du bruit de fond de 58% est obtenu pour une efficacité du signal de 90%.

Les variables utilisées dans cette analyse ont été testées dans des versions de CMSSW plus récentes, incluant une meilleure description du détecteur. Il a en particulier été montré [152] que le pouvoir discriminant de cinq des six variables utilisées (dont la variable d'asymétrie, précédemment la plus performante) est fortement réduit. Une meilleure description du calorimètre (avec notamment une meilleure prise en compte de l'électronique d'acquisition et des bruits associées) rend le niveau de description de sous-structure du cluster et des traces associées plus imprécis, d'où la baisse de performance. Un nouveau lot de 9 variables a alors été proposé :

- 3 variables de forme du cluster :  $cEP$  et  $cPP$  (covariance  $\eta\text{-}\phi$  et  $\phi\text{-}\phi$  entre les cristaux du basic-cluster autour du cristal de plus haute énergie) ainsi que  $E_{3 \times 3}/(E_{3 \times 3} - E_{1st} - E_{2nd})$  (où  $E_{3 \times 3}$  est l'énergie des cristaux  $3 \times 3$  centrée autour du cristal de plus haute énergie,  $E_{1st}$  l'énergie du cristal de plus haute énergie et  $E_{2nd}$  l'énergie du 2<sup>e</sup> cristal de plus haute énergie).
- 3 variables de conversion :  $E/p$ , la distance  $e^+/e^-$  à la surface de l'ECAL et  $(p_{T,track3} + p_{T,track4})/E_{T,\gamma}$ , où  $p_{T,track3}$  et  $p_{T,track4}$  sont les impulsions transverses de la première et deuxième trace qui n'ont pas été appariées au super-cluster par l'algorithme de reconstruction des photons convertis.
- 2 variables d'environnement : la distance  $\Delta R(\gamma, SC)$  entre le photon et le super-cluster le plus proche, et  $E_{T,\gamma}/p_{T,jet}$  l'énergie transverse du photon divisé par l'impulsion transverse du jet calorimétrique le plus proche.

Les variables sont fournies à un arbre de décision boosté [148] (BDT) plutôt qu'un réseau de neurones. La performance obtenue avec cette nouvelle analyse est de 55% de rejet du bruit de fond (dans le cas où une trace de conversion a été reconstruite) et 50% de rejection du bruit de fond (dans le cas où les deux traces ont été reconstruites) pour 90% d'efficacité de signal, pour des photons ayant une énergie transverse et une isolation semblables à l'analyse précédente. L'analyse a montré que les variables de conversions essayées avaient peu de pouvoir discriminant, tandis que la variable la plus discriminante est  $\Delta R(\gamma, SC)$  où  $SC$  est le super-cluster le plus proche du photon.

### Discrimination $\gamma/\pi^0$ pour les photons non-convertis

Il existe à ma connaissance trois analyses récentes de discrimination  $\gamma/\pi^0$  dans CMS portant sur les photons non-convertis. Toutes utilisent des variables de forme des dépôts d'énergie dans le ECAL. L'une d'elle utilise aussi l'information du détecteur pied de gerbe pour les photons dans les bouchons.

L'analyse utilisant le détecteur pied de gerbe [153] sélectionne les photons non-convertis de deux manières : soit en demandant qu'aucune trace de conversion n'ait été reconstruite pour le super-cluster, soit que la variable  $R9$  réponde à  $R9 > 0.93$  (en tirant parti du fait que le dépôt d'énergie des photons non-convertis est concentré sur  $3 \times 3$  cristaux dans le super-cluster). Un critère d'isolation demandant 0 traces dans un cône  $\Delta R < 0.3$  est appliqué autour des photons. L'analyse utilise 12 variables de forme du cluster dans le tonneau et 25 variables dans les bouchons, dont 22 variables utilisant l'énergie mesurée dans les 11 pistes en  $X$  et en  $Y$  du détecteur pied de gerbe autour du point d'impact du photon, et 3 variables d'énergie mesurée dans les cristaux des bouchons. Gardant 90% d'efficacité de signal, la performance obtenue est d'environ 60% de rejet dans les bouchons et de 40 à 75% dans le tonneau. La performance décroît lorsque l'énergie transverse des photons augmente de  $E_T = 20$  GeV à 80 GeV (énergies des photons issus du boson de Higgs et des processus  $\gamma$ +jets dans la plage de masse invariante  $115 < m_H < 125$  GeV).

Une autre analyse [154] réutilise une méthode développée dans l'expérience L3 qui propose de paramétrer la longueur latérale et la longueur longitudinale effective de la gerbe électromagnétique pour les photons non-convertis dans le tonneau, dont l'énergie est reconstruite dans un basic-cluster de  $5 \times 5$  cristaux. Elle a été validée avec les données du faisceau test d'électrons et appliquée aux photons de la simulation. Un ajustement est d'abord effectué dans l'hypothèse d'un seul photon, puis de deux. L'hypothèse donnant l'ajustement avec le meilleur  $\chi^2$  est sélectionnée. Si l'hypothèse deux photons est validée et que la masse invariante du diphoton est proche de la masse nominale du  $\pi^0$ , alors le photon a plus de chance d'être en réalité un  $\pi^0$ . 6 variables de la paramétrisation sont ensuite fournies à un BDT. Les performances obtenues sont de l'ordre de 50% de rejet des  $\pi^0$  dans le tonneau pour 90% d'efficacité de signal. Lorsque les 12 variables du tonneau dans l'analyse [153] sont combinées aux 6 variables de la paramétrisation dans le BDT, un gain de 6% en rejet est obtenu dans toute la plage d'énergie transverse  $E_T = 40$  GeV à 80 GeV par rapport aux 12 variables seules.

Une dernière analyse [143] propose de considérer des clusters de  $9 \times 9$  cristaux reconstruits autour du point d'impact de photons non-convertis, et de calculer le moment d'ordre 2 de la distribution en énergie des clusters. Le moment correspondant à l'axe majeur de développement de la gerbe, c'est-à-dire l'axe selon lequel deux dépôts d'énergie sont le plus écartés dans le cluster, est une variable discriminante. Cette variable a été combinée à d'autres variables plus complexes qui n'ont pas donné de véritable amélioration. La performance du moment majeur est d'environ 40% de rejection des  $\pi^0$  pour 90% d'efficacité des photons du signal.

## Identification des photons

D'autres outils qui ne portent pas nécessairement le titre de discrimination  $\gamma/\pi^0$  ont été développés pour diverses applications. Le groupe  $e/\gamma$  de CMS a en particulier élaboré un outil d'identification des photons basé sur des critères d'isolation. Quatre variables d'isolation et une variable de forme du cluster sont utilisées :

- Isolation Ecal "jurassic" : l'énergie transverse sommée des cristaux de plus de 80 MeV dans un cône  $0.06 < \Delta R < 0.4$  autour du photon, moins l'énergie du photon. L'énergie des cristaux dans une bande en  $\eta$  de 0.04 autour du photon n'est pas comptée dans la somme (prise en compte des conversions).
- Isolation  $H/E$  : l'énergie des tours du HCAL dans un cône  $\Delta R < 0.15$  autour du photon, divisée par l'énergie du super-cluster.
- Isolation HCAL : énergie transverse des tours du HCAL dans un cône  $0.15 < \Delta R < 0.4$  autour du photon.
- Isolation trajectographe : l'impulsion transverse des traces dans un cône  $0.04 < \Delta R < 0.4$  autour du photon.
- $\sigma_{i\eta i\eta}$  est la racine de la covariance  $i\eta-i\eta$  dans le basic-cluster de plus haute énergie, où  $i\eta$  est l'index en  $\eta$  du cristal (voir l'annexe A).

Trois niveaux de sélection par défaut des photons sont recommandés pour l'analyse des premières données (voir tableau 5.3).

Variable	EM	Photon Relâché	Photon Sévère
Iso Ecal	$< 4.2+0.004*p_T$	$< 4.2+0.004*p_T$	$< 4.2+0.004*p_T$
Iso Hcal	$< 2.2+0.001*p_T$	$< 2.2+0.001*p_T$	$< 2.2+0.001*p_T$
$H/E$	$< 0.05$	$< 0.05$	$< 0.05$
Iso Track		$< 2+0.001*p_T$	$< 2+0.001*p_T$
$\sigma_{i\eta i\eta}$			$< 0.013$

FIG. 5.3 – Critères de sélection par défaut pour l'identification des photons dans le tonneau.

De manière générale, les critères d'isolation des photons et de forme des dépôts d'énergie des super-clusters sont complémentaires pour l'identification des photons et le rejet des  $\pi^0$ . Une alternative à la variable  $\sigma_{i\eta i\eta}$  est la variable de largeur en  $\eta$  du super-cluster  $\sigma_\eta$  utilisée pour le calcul des corrections en énergie (voir section 1.3.2).

### Le réseau de neurones “NNisol”

Une autre approche de rejet massif des bruits de fonds QCD [144] a été mise en place et intégrée dans l'analyse  $H \rightarrow \gamma\gamma$  du TDR [88, 104]. Différentes variables d'isolation dans le trajectographe, le ECAL et le HCAL ont été testées, pour différentes valeurs de seuils en  $\Delta R$  et en énergie transverse. Parmi toutes les combinaisons de variables essayées, un réseau de neurones basé sur une variable de forme du cluster et quatre variables d'isolation (ou approchant) a prouvé donner la meilleure discrimination entre les photons isolés et les photons mal identifiés provenant des jets des processus QCD :

- L'énergie transverse dans le ECAL des basic-clusters dans un cône  $\Delta R < 0.3$  autour du photon, moins l'énergie du photon.
- La somme des énergies transverses des tours du HCAL dans un cône  $\Delta R < 0.35$  autour du photon.
- La somme en impulsion transverse des traces dans le trajectographe dans un cône  $\Delta R < 0.2$  autour du photon.
- La distance  $\Delta R$  entre le photon et la trace la plus proche ayant une énergie transverse de plus de 2 GeV.
- Enfin, la variable  $R9 = E_{3\times 3}/E_{SC}$  de forme du super-cluster dans le ECAL.

Pour 90% d'efficacité du signal  $H \rightarrow \gamma\gamma$  lorsque le réseau de neurone est appliqué à des photons *non isolés*, l'efficacité du signal divisé par l'efficacité du bruit de fond est d'environ 50 (soit une rejection du bruit de fond de 98%). Nous voyons ici qu'une approche d'isolation optimisée peut aider à la réduction massive du bruit de fond. La complémentarité entre variables de forme du cluster et variables d'isolation rend l'usage de ces deux techniques d'autant plus performantes.

## 5.2 Variables d'entrée du réseau de neurones

Le point de départ de ce travail a été l'étude de la discrimination  $\gamma/\pi^0$  pour les photons convertis, reprenant les mêmes 8 variables et catégories décrites ref. [152]. Une première phase d'optimisation a progressivement mené à sélectionner des variables avec un plus grand pouvoir discriminant. L'analyse était alors divisée en trois catégories, selon que le photon ait été reconstruit comme non-converti (7 variables), avec une trace de conversion (6 variables) ou deux (7 variables). La plupart des variables utilisées étaient communes aux trois catégories, avec en plus quelques variables spécifiques aux conversions. Comme les performances restaient similaires quelle que soit la catégorie, nous avons décidé de finalement rassembler toutes les catégories en une seule, qui ne tient plus compte des variables de conversion (qui ont montré un faible pouvoir discriminant). Cette approche a donné lieu à la publication [155]. Nous en présentons ici une version améliorée qui utilise seulement 6 variables, séparables en 3 variables de forme du cluster et 3 variables d'environnement. Ces variables d'entrée sont fournies à un réseau de neurones MLP implémenté dans TMVA. La performance obtenue est meilleure que les analyses précédentes pour une sélection

Processus	Sélection générateur	Section efficace (pb)	Nb évènements
QCD dijet	$\hat{p}_T > 15$ GeV	876200000.0	6190500
$\gamma$ +jet	$\hat{p}_T > 15$ GeV	192200.0	1223390
$\gamma\gamma$ Born	$10 < \hat{p}_T < 25$ GeV	236.4	534055
$\gamma\gamma$ Born	$25 < \hat{p}_T < 250$ GeV	22.37	750080
$\gamma\gamma$ Born	$\hat{p}_T > 250$ GeV	0.008072	210016
$\gamma\gamma$ Box	$10 < \hat{p}_T < 25$ GeV	358.2	550000
$\gamma\gamma$ Box	$25 < \hat{p}_T < 250$ GeV	12.37	543520
$\gamma\gamma$ Box	$\hat{p}_T > 250$ GeV	0.000208	216432
Fusion de gluons $gg \rightarrow H \rightarrow \gamma\gamma$	-	0.014380	108000
Fusion de bosons vecteurs $qq \rightarrow H \rightarrow \gamma\gamma$	-	0.003498	120820
Production associée $t\bar{t}H, WH, ZH, H \rightarrow \gamma\gamma$	-	0.002440	107930

FIG. 5.4 – Sections efficaces au LO à 7 TeV dans le centre de masse, pour le signal et les bruits de fond pour la discrimination  $\gamma/\pi^0$ .

similaire des photons.

Dans cette section, nous décrivons dans un premier temps les échantillons de simulation utilisés ainsi que les critères de préselection appliqués aux photons. Nous décrivons ensuite les trois variables de forme du cluster puis les trois variables d'environnement. Dans la section suivante, nous présenterons les performances du réseau de neurones.

### 5.2.1 Sélection des photons

Le but premier du réseau de neurones (NN) que nous présentons ici est l'identification des photons de signal provenant des processus  $H \rightarrow \gamma\gamma$ , mais aussi de  $\gamma\gamma+X$  et  $\gamma$ +jet. Le réseau de neurones a donc été optimisé pour fournir les meilleures performances dans le cas où une préselection stricte est appliquée aux photons. La préselection utilisée pour les histogrammes que nous présenterons dans cette section est toutefois relâchée, de sorte à convenir à une large gamme d'application. Par ailleurs, avons aussi accordé une grande importance à la vérification des performances du NN dans les premières données du LHC avec une énergie dans le centre de masse de 7 TeV, études pour lesquelles les critères de préselection ont été relâchés pour disposer d'une statistique suffisante avec une luminosité intégrée de quelques  $nb^{-1}$ .

Afin de vérifier le comportement du NN dans différents processus, les photons reconstruits de plusieurs échantillons de signaux différents ont été utilisés : les photons partoniques des processus  $\gamma$ +jet, de  $\gamma\gamma+X$  et de  $H \rightarrow \gamma\gamma$ . Pour le bruit de fond, les photons non ISR/FSR du processus QCD dijet ont été utilisés. On définit les photons partoniques (resp. les photons ISR/FSR) en appariant le photon reconstruit avec le photon partonique (resp. provenant d'un quark ou gluon pour les ISR/FSR - Pythia admet l'émission effective de photons par les gluons) niveau générateur dans un cône  $\Delta R(\gamma_{rec}, \gamma_{gen}) < 0.1$ . Le tableau 5.4 indique les sections efficaces LO des différents processus, tous générés avec Pythia [26].

Les critères de préselection appliqués demandent une énergie transverse des photons reconstruits  $E_T > 20$  GeV dans l'acceptance du détecteur  $|\eta| < 2.5$ . L'énergie transverse d'isolation "jurassic" dans le ECAL doit être inférieure à 4 GeV dans un cône  $\Delta R < 0.3$  autour du photon, l'énergie transverse dans le HCAL doit être inférieure à 2 GeV dans un cône  $\Delta R < 0.3$  autour du photon. Le calcul des énergies entrant dans le cône d'isolation est le même que pour les critères d'identification section 5.1.3. L'usage de la variable d'isolation demandant un nombre maximum de traces dans un cône  $\Delta R$  autour du photon [104] n'a pas été retenu pour deux raisons : d'une part, cette variable montre pour le moment un désaccord



entre la simulation et les données et d'autre part, il n'existe pas d'équivalent pour cette variable au niveau partonique, ce qui pose problème pour la procédure de repondération (voir chapitre 7).

### 5.2.2 Variables de forme du cluster

L'optimisation du choix des variables nous a conduit à retenir les trois variables de forme du cluster suivantes :  $cPP$ ,  $\sigma_\phi$  et  $R9$ . Chacune de ces trois variables est bien connue dans les analyses portant sur les photons et les électrons dans CMS. Chacune d'entre elles a montré un pouvoir discriminant, et présente un bon accord entre données et simulation.

La variable  $cPP$ , covariance  $\phi$ - $\phi$  entre les  $5 \times 5$  cristaux du basic-cluster contenant le cristal germe du super-cluster, est donnée par la formule suivante :

$$cPP = \sum_i^N w_i (\phi_i - \langle \phi_{BC} \rangle)^2$$

Où  $\phi_i$  est la position en  $\phi$  du cristal  $i$  dans le ECAL,  $w_i$  le poids qui lui est associé et  $\langle \phi_{BC} \rangle$  la position moyenne du basic-cluster dans le ECAL :

$$\langle \phi_{BC} \rangle = \frac{\sum_i w_i \phi_i}{\sum_i w_i}$$

$$w_i = \max \left[ 0; 4.2 + \log \left( \frac{E_i}{E_{BC}} \right) \right]$$

$E_i$  est l'énergie du cristal  $i$  et  $E_{BC}$  l'énergie du basic-cluster. Les poids  $w_i$  sont aussi utilisés pour calculer la position du basic-cluster. Dans le calcul du poids associé à chaque cristal, la profondeur de la gerbe électromagnétique est prise en compte. La profondeur de la gerbe varie en  $\log(E)$  (la formule précédente a été validé par comparaison de simulations GEANT4 [29] avec les données du faisceau test).

Le pouvoir de discrimination de  $cPP$  entre les  $\pi^0$  et les photons s'explique par le fait que lorsqu'un électron est dévié dans le champ magnétique dans la matière, il rayonne des photons par bremsstrahlung externe qui seront étalés en  $\phi$ . Le photon peut se convertir en une paire  $e^+/e^-$  en amont de l'ECAL, ou dans la gerbe électromagnétique déclenchée dans le ECAL. Un  $\pi^0$  se désintégrant en paire de photons aura donc plus de chance de donner lieu à une gerbe avec une déviation plus marquée en  $\phi$  et donc une corrélation  $cPP$  plus forte qu'un photon unique.

La variable  $\sigma_\eta$  est la largeur en  $\eta$  du super-cluster, utilisée pour le calcul des corrections en énergie. Elle est donnée par la formule :

$$\sigma_\eta = \sum_i \sqrt{\frac{E_i}{E_{SC}}} (\eta_i - \eta_{SC})^2$$

Où la somme est effectuée sur les  $i$  cristaux du super-cluster,  $E_i$  est l'énergie du cristal  $i$  et  $\eta_i$  sa position en  $\eta$ .  $E_{SC}$  est l'énergie du super-cluster et  $\eta_{SC}$  sa position.

La variable  $\sigma_\eta$  est discriminante en ce que le super-cluster rassemblant les dépôts d'énergie de deux photons issus d'un  $\pi^0$  aura un étalement plus important en  $\eta$  qu'un photon unique. Le super-cluster d'un  $\pi^0$  est attendu comme ayant deux foyers d'énergie plus ou moins distinguables sur cette bande, conduisant par la pondération en énergie dans la formule à un  $\sigma_\eta$  plus grand.

Enfin, la dernière variable utilisée est  $R9$ , donnée par :

$$R9 = \frac{E_{3 \times 3}}{E_{SC}}$$

Où  $E_{3 \times 3}$  est l'énergie dans les cristaux  $3 \times 3$  autour du cristal germe et  $E_{SC}$  l'énergie corrigée du super-cluster (qui tient compte de l'énergie associée dans le détecteur pied de gerbe). Le dépôt d'énergie des

photons convertis ou des  $\pi^0$  étant moins concentré que pour des photons non-convertis, on s'attend à ce que les  $\pi^0$  prennent des valeurs de  $R9$  petites, typiquement dans la gamme  $R9 < 0.93$ , alors que les photons non-convertis devraient plutôt répondre à  $R9 > 0.93$ .

On montre figure 5.5, 5.6 et 5.7 les distributions de  $cPP$ ,  $\sigma_\eta$  et  $R9$  pour les photons passant la présélection. On observe effectivement que les trois variables montrent un étalement plus prononcé pour les photons mal identifiés provenant du processus QCD dijet que pour les photons du signal.

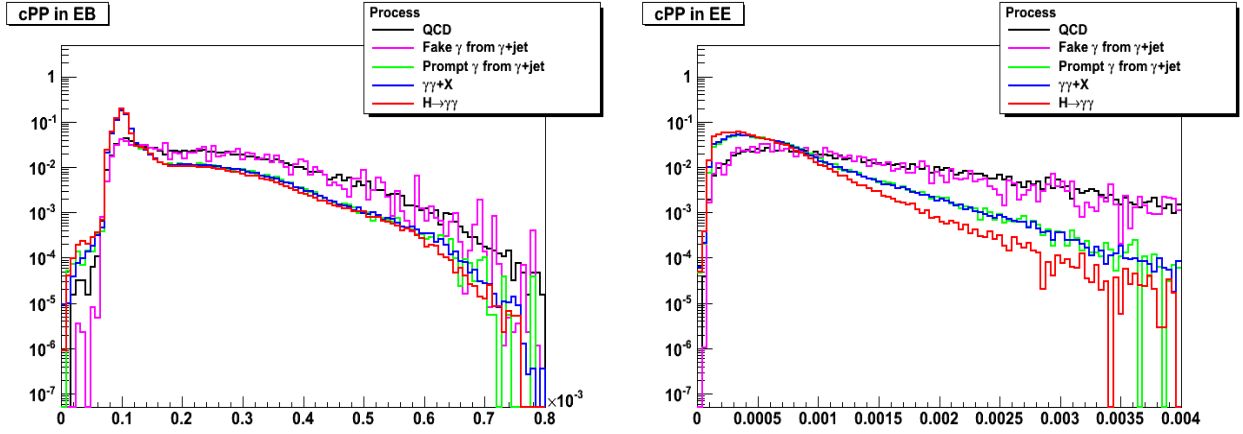


FIG. 5.5 – Distribution de la variable d'entrée de forme du cluster  $cPP$  dans le tonneau (à gauche) et dans les bouchons (à droite). Toutes les distributions sont normalisées à 1.




FIG. 5.6 – Distribution de la variable d'entrée de forme du cluster  $R9$  dans le tonneau (à gauche) et dans les bouchons (à droite). Toutes les distributions sont normalisées à 1.

### 5.2.3 Variables d'environnement

En plus des trois variables de forme du cluster  $cPP$ ,  $\sigma_\eta$  et  $R9$ , nous avons trouvé que trois variables “d'environnement” pouvaient aider à la discrimination. Nous entendons par “environnement” des variables qui tiennent compte des particules à proximité des photons, sans pour autant qu'il s'agisse des variables d'isolation classique. Les trois variables d'environnement que nous avons trouvé donner la meilleure discrimination sont  $\frac{PT_\gamma}{PT_{closestjet}}$ ,  $\Delta R(\gamma, closestSC)$  et  $\Delta R(\gamma, closesttrack)$ .




FIG. 5.7 – Distribution de la variable d’entrée de forme du cluster  $\sigma_\eta$  dans le tonneau (à gauche) et dans les bouchons (à droite). Toutes les distributions sont normalisées à 1.

La fraction  $\frac{p_{T,\gamma}}{p_{T,\text{closestjet}}}$  est le  $p_T$  du photon divisé par le  $p_T$  du jet calorimétrique le plus proche en  $\Delta R$ . Les jets non corrigés, reconstruits avec l’algorithme anti- $k_T$  ont été utilisés avec un cône  $\Delta R < 0.5$  (qui est l’algorithme recommandé dans CMS). Cet algorithme reconstruit tous les photons de  $p_T$  suffisamment élevé comme étant des jets. Par conséquent, la fraction  $\frac{p_{T,\gamma}}{p_{T,\text{closestjet}}}$  est censée piquer en 1 pour les photons du signal, tandis qu’elle aura une valeur différente de 1 (souvent plus petite) pour les photons mal identifiés des jets. Un critère  $p_{T,\text{closestjet}} > 15$  GeV est appliqué pour se conformer à la plage d’énergie pour laquelle l’algorithme de reconstruction des jets a été conçu.

$\Delta R(\gamma, \text{closestSC})$  est la distance entre le photon et le super-cluster le plus proche dans l’évènement (quelle que soit son énergie transverse). Cette grandeur donne une idée de l’activité des jets dans le calorimètre. Elle est complémentaire à un critère d’isolation dans le calorimètre dans la mesure où on ne se restreint pas à un certain cône en  $\Delta R$  autour du photon. Dans le bruit de fond, on s’attend à ce que la variable pique près de 0 puisque les particules des jets peuvent donner lieu à plusieurs dépôts d’énergie légèrement écartés l’un de l’autre dans le calorimètre. Pour le signal, on s’attend en revanche à ce qu’il y ait peu de super-clusters reconstruits près du photon sélectionné. Pour les processus  $\gamma$ +jet,  $\gamma\gamma$ +X et  $H \rightarrow \gamma\gamma$ , la variable  $\Delta R(\gamma, \text{closestSC})$  devrait piquer près de 3, ce qui correspond à un photon émis dos-à-dos avec un autre objet (jet pour  $\gamma$ +jet, photons sinon) et peut aider à discriminer le bruit de fond.

La variable  $\Delta R(\gamma, \text{closesttrack})$  est semblable à la précédente. Il s’agit de la distance entre le photon et la trace la plus proche dans le trajectographe. On ne considère dans le calcul de cette grandeur que les traces ayant une impulsion transverse  $p_T > 2$  GeV (pour éviter de considérer des traces qui sont en fait du bruit - c’est aussi le seuil qui a donné le plus de discrimination). Le nombre de particules chargées issus des jets de QCD (pions ou kaons chargés en particulier) est plus grand que le nombre de particules neutres donnant lieu à des dépôts d’énergie électromagnétiques, c’est pourquoi  $\Delta R(\gamma, \text{closesttrack})$  est plus piqué vers 0 pour le bruit de fond que la variable  $\Delta R(\gamma, \text{closestSC})$ .

Figure 5.8, on compare les distributions de  $\Delta R(\gamma, \text{closestSC})$ , l’énergie d’isolation dans le ECAL,  $\Delta R(\gamma, \text{closesttrack})$  et l’énergie d’isolation dans le trajectographe. Les photons du signal sont plus isolés que ceux du bruit de fond. Les variables d’environnement et d’isolation ne sont pas ou sont peu corrélées, comme le montre la figure 5.9.

Les distributions des trois variables d’environnement sont montrées figure 5.10, 5.11 et 5.12 pour le bruit de fond et différents signaux.

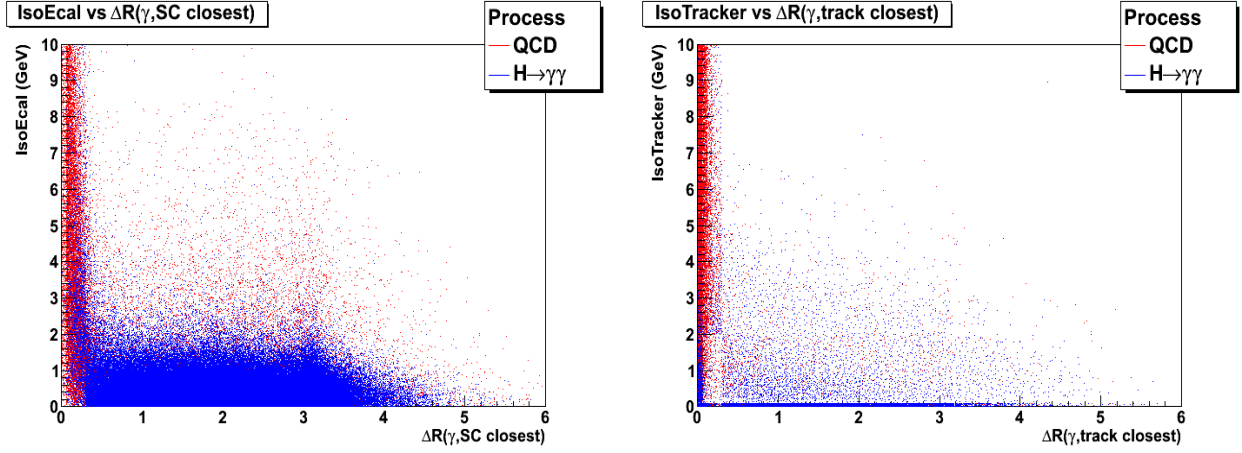


FIG. 5.8 – A gauche,  $\Delta R(\gamma, \text{closestSC})$  versus l'énergie transverse d'isolation dans le calorimètre. A droite,  $\Delta R(\gamma, \text{closesttrack})$  versus l'énergie transverse d'isolation dans le trajectographe.

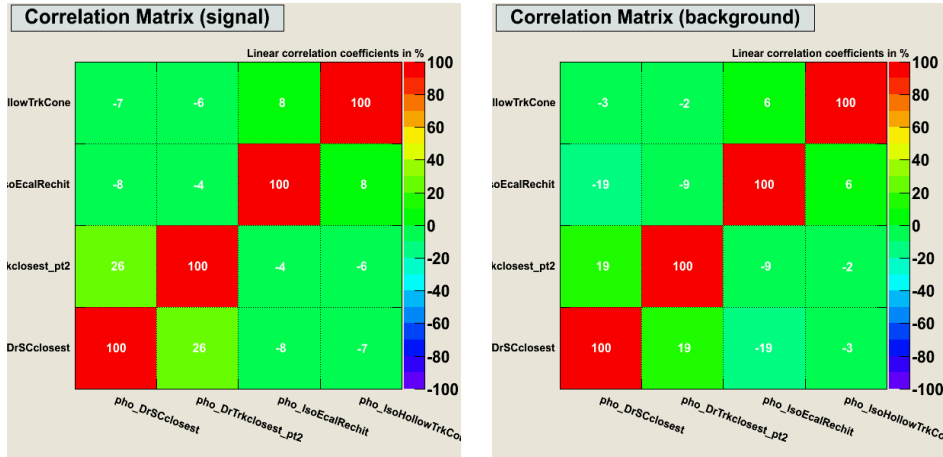


FIG. 5.9 – Corrélation linéaire entre  $\Delta R(\gamma, \text{closestSC})$  (pho\_DrScClosest), l'énergie transverse d'isolation dans le calorimètre (pho\_IsoEcalRecHit),  $\Delta R(\gamma, \text{closesttrack})$  (pho\_DrTrkClosest\_pt2) et l'énergie transverse d'isolation dans le trajectographe (pho\_IsoHollowTrkCone), pour les photons du processus  $H \rightarrow \gamma\gamma$  (à gauche) et de QCD (à droite).

### 5.2.4 Corrélation des variables d'entrée

Au contraire des fonctions de vraisemblance, les réseaux de neurones exploitent les corrélations entre les variables pour améliorer la discrimination. Les corrélations linéaires entre les six variables d'entrées sont données figure 5.13 pour le signal et le bruit de fond. On observe que les variables d'entrée sont plus corrélées pour les photons du signal que pour ceux du bruit de fonds. En particulier, la variable  $cPP$  dans le signal est très corrélée à  $\sigma_\eta$  (coefficient de corrélation de 75%) et dans une moindre mesure à  $\frac{PT,\gamma}{PT,\text{closestjet}}$  (41%),  $R9$  et  $\Delta R(\gamma, \text{closesttrack})$  (environ 25%). De plus  $R9$  est aussi corrélé à  $\frac{PT,\gamma}{PT,\text{closestjet}}$  et  $\Delta R(\gamma, \text{closesttrack})$  (environ 35%). Dans l'échantillon de bruit de fond, seule la corrélation entre  $cPP$  et  $\sigma_\eta$  sort du lot (72%).

## 5.3 Performances du réseau de neurones

L'étude des performances du réseau de neurones sera effectuée à chaque fois dans trois cas, selon que les variables d'entrée soient les trois variables de forme du cluster, les trois variables d'environnement ou les six variables rassemblées. Nous avons opté pour cette approche parce que variables de forme du cluster

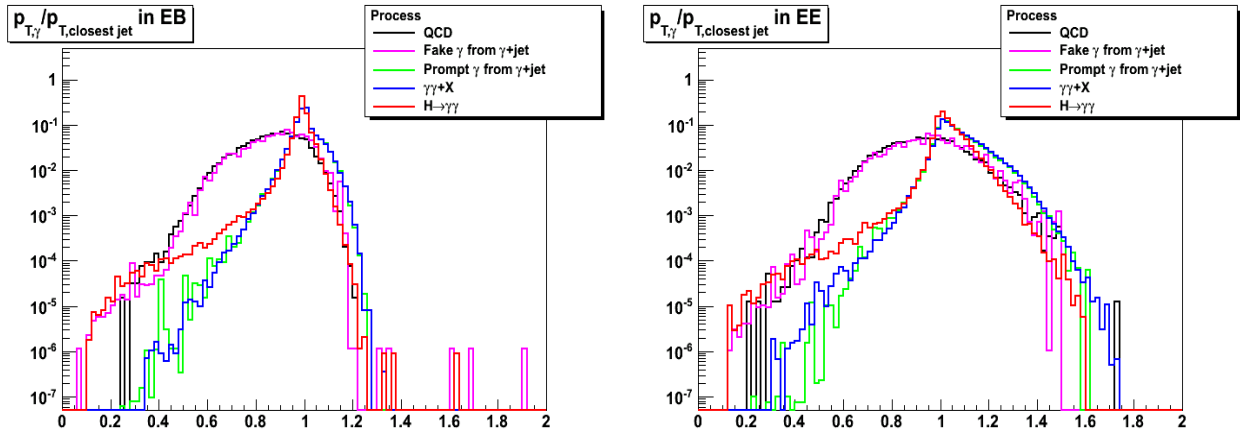


FIG. 5.10 – Distribution de la variable d’entrée d’environnement  $\frac{p_{T,\gamma}}{p_{T,closetjet}}$  dans le tonneau (à gauche) et dans les bouchons (à droite). Toutes les distributions sont normalisées à 1.

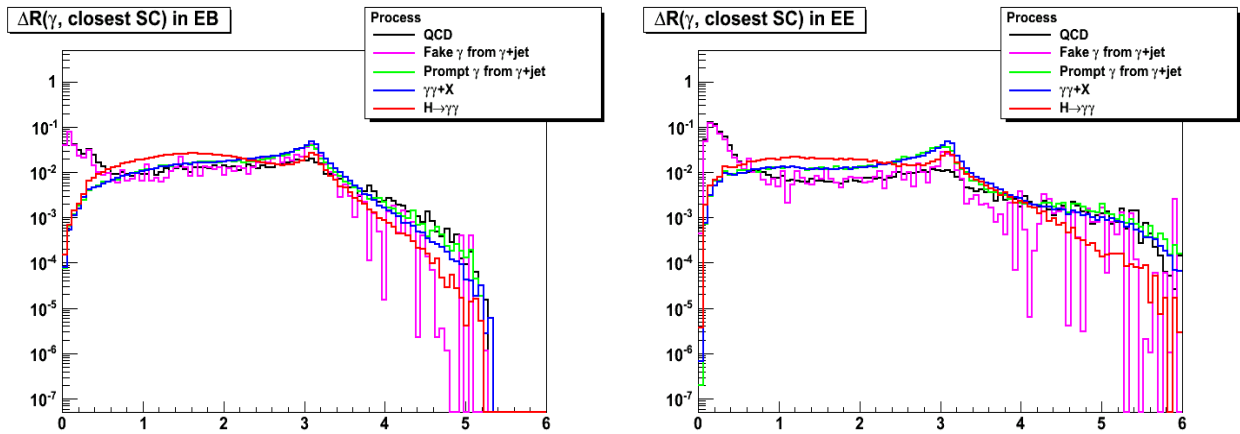


FIG. 5.11 – Distribution de la variable d’entrée d’environnement  $\Delta R(\gamma, closet SC)$  dans le tonneau (à gauche) et dans les bouchons (à droite). Toutes les distributions sont normalisées à 1.

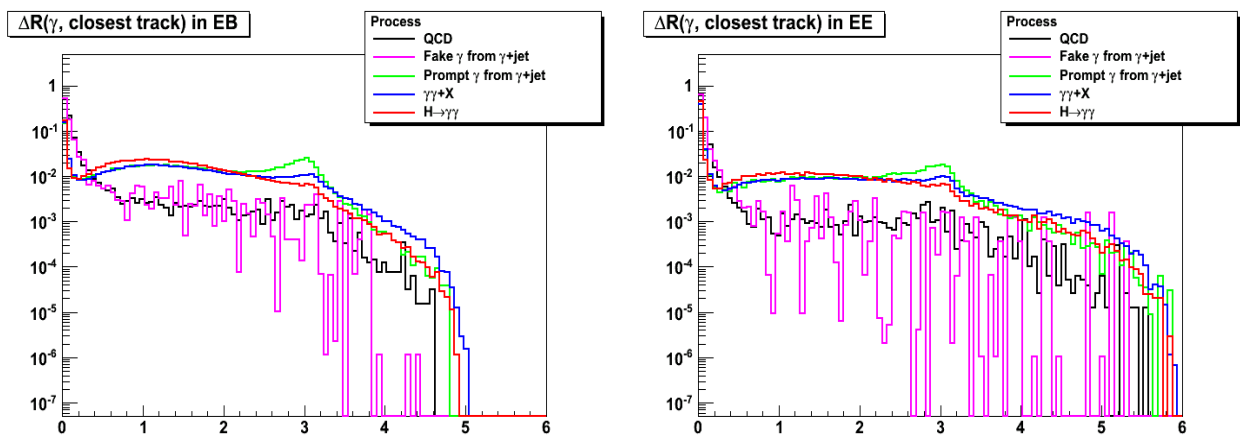


FIG. 5.12 – Distribution de la variable d’entrée d’environnement  $\Delta R(\gamma, closet track)$  dans le tonneau (à gauche) et dans les bouchons (à droite). Toutes les distributions sont normalisées à 1.




FIG. 5.13 – Corrélation linéaire entre  $cPP$  (pho\_cPP),  $R9$  (pho\_r9),  $\sigma_\eta$  (pho\_etawidth),  $\frac{PT,\gamma}{PT,closestjet}$  (pho\_ptoverjetpt\_pt15),  $\Delta R(\gamma, closestSC)$  (pho\_DrScClosest) et  $\Delta R(\gamma, closesttrack)$  (pho\_DrTrkClosest), pour les photons du processus  $H \rightarrow \gamma\gamma$  (à gauche) et de QCD (à droite).

et variables d'environnement sont de type très différents. Il est intéressant d'étudier les performances séparées et combinées, pour décider quelle est la meilleure approche pour un problème donné. De plus, si on souhaite entraîner le réseau de neurones à partir des données, cela semble plus aisé pour le réseau de neurones basé sur des variables de forme du cluster, indépendant du processus au contraire des variables d'environnement. Il est aussi plus aisé de contrôler les incertitudes systématiques pour un petit nombre de variables.

Dans un premier temps, nous démontrons que le choix du MLP délivre les meilleures performances en terme de rejet du bruit de fond, par rapport aux autres classifieurs proposés dans le package TMVA [149]. Nous décrivons l'architecture du réseau de neurones et effectuerons quelques études qui permettront d'en contrôler le comportement : classement de l'importance des variables d'entrée, suivi des performances de la discrimination pour chaque neurone séparément. Nous examinerons ensuite les performances pour différentes catégories de photons : dans le tonneau et les bouchons, pour les photons convertis et non-convertis et en fonction de l'impulsion transverse des photons. Les performances pour différents signaux (photons prompts des processus  $\gamma+jet$ ,  $\gamma\gamma$  et  $H \rightarrow \gamma\gamma$ ) et bruits de fond (photons des jets des processus de QCD dijet et  $\gamma+jet$ ) seront ensuite comparées. Nous comparerons enfin les performances du réseau de neurones que nous proposons avec celles obtenues avec le réseau de neurones NNisol [144] que nous avons décrit section 5.1.3, utilisé pour la recherche du boson de Higgs dans l'analyse du PTDR.

### 5.3.1 Choix du classifieur : le MLP

A partir de la préselection définie au paragraphe précédent, nous avons essayé plusieurs classifieurs du package TMVA [149], dans le but de choisir celui qui donne les meilleures performances :

- Discriminant linéaire de Fischer [145]. La variable de sortie du discriminant est simplement une combinaison linéaire des variables d'entrée.
- Fonction de vraisemblance ("likelihood"). Pour chaque événement, la vraisemblance d'avoir affaire à un événement de signal est égale à la multiplication des fonctions de probabilités des variables d'entrée, normalisé par la somme des vraisemblances du signal et du bruit de fond. Les fonctions de probabilités sont ajustées avec des fonctions polynomiales d'ordre 2.
- Arbre de décision boosté [148] (ou forêt de décision). Il s'agit d'un arbre de décision binaire répété 200 fois (forêt) avec des poids différents, ce qui permet de stabiliser la réponse du classifieur par rapport aux fluctuations statistiques des échantillons.
- Le réseau de neurones MLP implémenté par défaut dans TMVA, qui contient deux couches cachées, avec  $N + 1$  neurones dans la première couche cachée et  $N$  dans la seconde (où  $N$  est le nombre de variables d'entrée). L'entraînement est effectué sur 200 cycles et la fonction d'activation des neurones est une

tangente hyperbolique. Nous avons essayé de faire varier le nombre de couches cachées. Une seule couche cachée réduit les performances, et trois couches cachées donnent approximativement les mêmes résultats qu'avec seulement deux, paramètre de défaut que nous avons choisi de garder.

On montre figure 5.14 les performances des différents classifieurs dans le cas où les variables d'entrées sont les variables de forme du cluster seules, les variables d'environnement seules, les variables de forme du cluster et les variables d'environnement combinées. Les photons prompts de  $H \rightarrow \gamma\gamma$  ont été utilisés comme signal, et les photons non prompts des jets du processus de QCD dijet comme bruit de fond. Chaque point des courbes d'efficacité du signal  $\epsilon_S$  versus rejet du bruit de fond ( $1 - \epsilon_B$ , où  $\epsilon_B$  est l'efficacité du bruit de fond) est obtenu en sélectionnant tous les photons ayant une valeur de la sortie du classifieur supérieure à un certain seuil. En faisant varier ce seuil, on construit les courbes présentées ci-dessous.

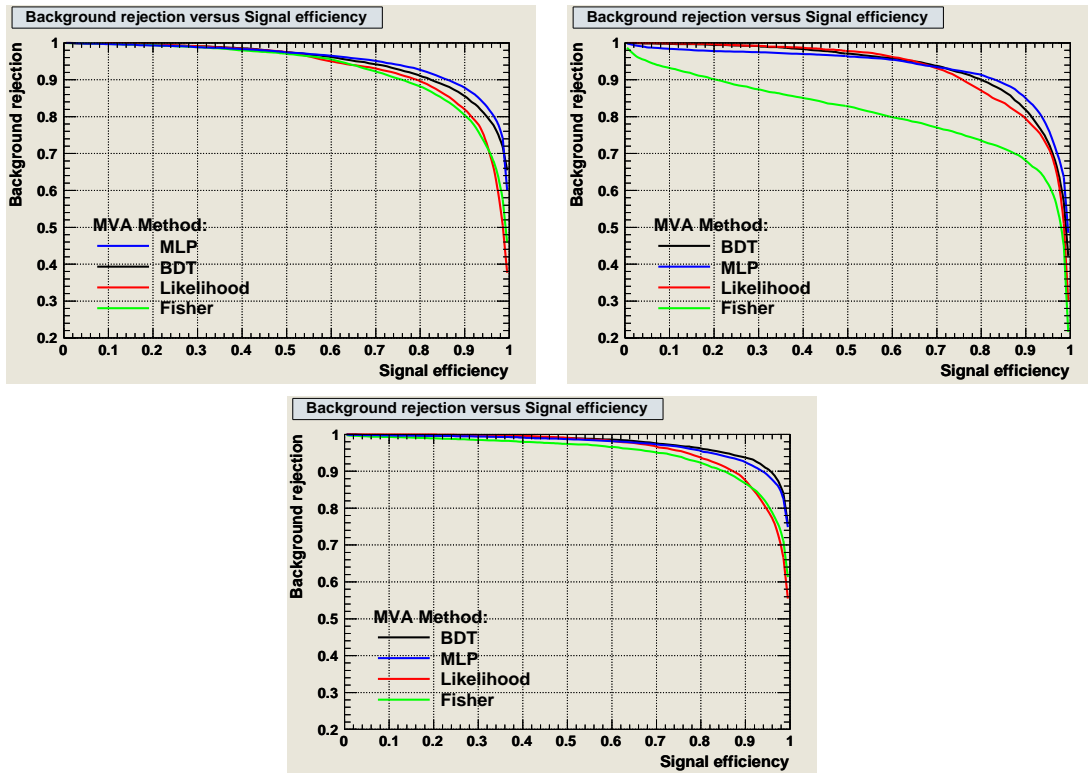


FIG. 5.14 – Efficacité du signal en fonction du rejet du bruit de fond pour différents classifieurs, dans le cas des 3 variables de forme du cluster seules (en haut à gauche), des 3 variables d'environnement seules (en haut à droite) et dans le cas des 6 variables combinées (en bas).

Le BDT obtient de très bonnes performances, mais comme le montre la figure 5.15, il est surentraîné (la sortie du BDT n'est pas la même sur l'échantillon d'entraînement et l'échantillon test) et ne peut donc pas être utilisé pour les analyses car il conduit à la reconnaissance des fluctuations du signal plutôt que le signal lui-même. Le réseau de neurones obtient les meilleures performances dans le cas variables de forme du cluster seules, et forme du cluster/environnement combinées sur toute la plage d'efficacité du signal. Dans le cas des variables d'environnement, le MLP est supplanté par la fonction de vraisemblance sur la plage d'efficacité du signal de  $\epsilon_S < 0.6$ . L'utilisation du MLP semble donc indiqué pour la plupart des applications.

### 5.3.2 Performances

Dans les lignes qui suivent les performances du réseau de neurones vont être détaillées. Dans un premier temps, le fonctionnement du réseau de neurones sera examiné : nous suivrons la progression de la discrimination pour chaque neurone, et l'importance des variables dans le réseau de neurones sera

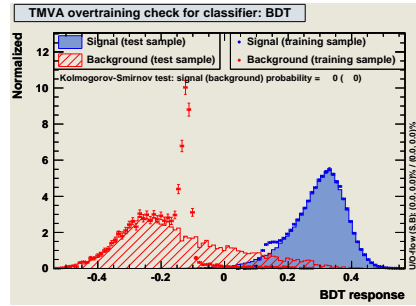


FIG. 5.15 – Sortie du BDT dans le cas des variables de forme du cluster et d’environnement combinées, pour l’échantillon d’entraînement et de test. Il y a surentraînement car les deux distributions ne se superposent pas dans la limite des incertitudes statistiques.

donnée. Nous effectuerons ensuite des comparaisons de la performance obtenue pour différentes catégories de photons (dans le tonneau ou le bouchon, si le photon est converti ou non, et en fonction de l’impulsion transverse). Enfin, nous comparerons les performances pour différents signaux et bruits de fond.

### Sortie du réseau de neurones

#### Performances de NNcluster, NNenv et NNcombiné

Les performances du réseau de neurone dans chacun des trois cas : variables de forme du cluster (“NNcluster”), d’environnement (“NNenv”), cluster et environnement combinées (“NNcombiné”) sont rassemblées figure 5.16. L’entraînement a été effectué après préselection, avec les photons du boson de Higgs comme signal et les photons mal identifié de QCD comme bruit de fond. Les performances sont les meilleures pour NNcombiné, suivi de NNcluster puis NNenv. Avec les critères de préselection utilisés, pour une efficacité de signal de 90%, le rejet du bruit de fond atteint 88% pour NNcluster, 82% pour NNenv et 93% pour NNcomb. Il faut souligner que les critères d’isolation de la préselection sont plutôt lâches, tant en isolation qu’en impulsion transverse. Nous présenterons plus loin une étude des performances en fonction des critères d’isolation et d’impulsion transverse. Pour ces critères de préselection, on montre les sorties du réseau de neurone pour le signal et le bruit de fond figure 5.17 pour les trois réseaux de neurones à l’issue de la phase d’entraînement et de test. Les trois réseaux de neurones ne sont pas surentraînés : ils sont plus robustes que le BDT. On observe la répartition du signal, qui pique en 1, et du bruit de fond qui pique en -1.




FIG. 5.16 – Efficacité du signal en fonction du rejet du bruit de fond pour pour le réseau de neurone entraîné dans le cas des 3 variables de forme du cluster seules, des 3 variables d’environnement seules et dans les cas des 6 variables combinées.






FIG. 5.17 – Sortie des réseaux de neurones, dans le cas des 3 variables de forme du cluster seules (à gauche), des 3 variables d’environnement seules (au milieu) et dans les cas des 6 variables combinées (à droite).

### Discrimination neurone par neurone

Au contraire d’une analyse basée sur des coupures séquentielles, l’utilisation des réseaux de neurones peut rendre difficile l’estimation des importances de chaque variable dans l’analyse. Dans le but de rendre moins obscur le fonctionnement du réseau de neurones, nous avons souhaité montrer à chaque étape de la discrimination les sorties des différents neurones de chaque couche pour le signal et le bruit de fond, dans le cas des variables de forme du cluster uniquement (pour plus de simplicité). Chaque sortie d’un neurone est la tangente hyperbolique d’une combinaison linéaire des neurones de la couche précédente. Les sorties des neurones montrent une discrimination qui progresse de la première couche cachée (voir figure 5.18) à la seconde (voir 5.19). Le réseau de neurones portant sur les variables d’environnement montre des distributions similaires (et un peu moins discriminantes).

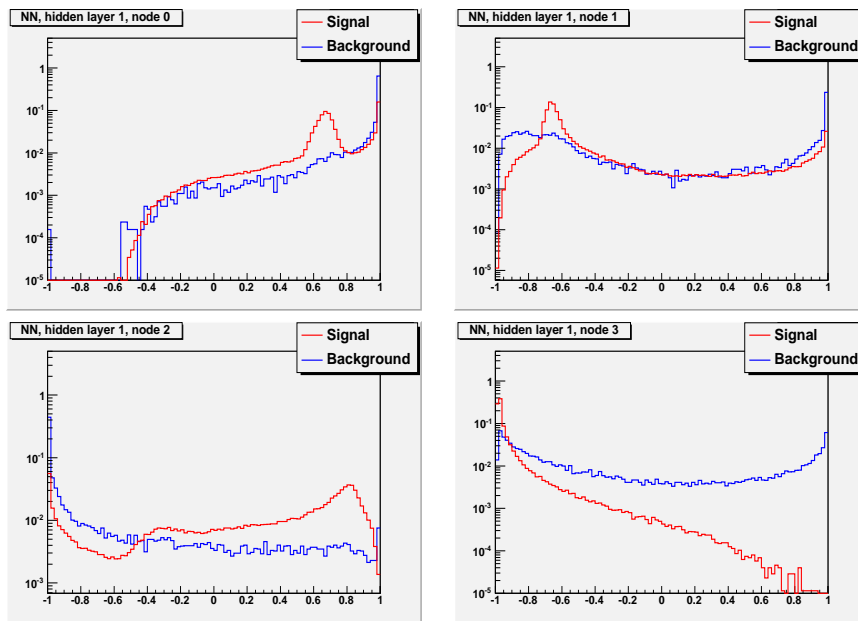


FIG. 5.18 – Distributions de sorties de chacune des quatre neurones de la première couche cachée, pour le réseau de neurone entraîné avec les variables de forme du cluster.

### Classement des variables d’entrée selon leur importance

A l’issue de la phase d’entraînement, TMVA propose un classement des différentes variables d’entrée selon leur importance dans le réseau de neurones. L’importance  $I_i$  de la variable d’entrée  $x_i$  est donnée par la formule :

$$I_i = \bar{x}_i \sum_j^{n_1} w_{ij}^{l_1}$$




FIG. 5.19 – Distributions de sorties de chacune des trois neurones de la seconde couche cachée, pour le réseau de neurone entraîné avec les variables de forme du cluster.

Importance $I_i$	NNcluster	NNenv	NNcombiné
$cPP$	$3.184 \times 10^6$	-	$1.302 \times 10^6$
$R9$	5.903	-	5.689
$\sigma_\eta$	$1.549 \times 10^4$	-	$4.210 \times 10^3$
$\frac{p_{T,\gamma}}{p_{T,closestjet}}$	-	$2.452 \times 10^{-1}$	$1.772 \times 10^{-1}$
$\Delta R(\gamma, closestSC)$	-	$6.945 \times 10^{-1}$	$2.670 \times 10^{-1}$
$\Delta R(\gamma, closesttrack)$	-	5.031	$2.811 \times 10^{-1}$

FIG. 5.20 – Importance des variables d'entrée dans les réseaux de neurones, donnée par TMVA à l'issue de la phase d'entraînement.

Où  $\bar{x}_i$  est la valeur moyenne de la variable d'entrée  $x_i$ , la somme est effectuée sur les  $n_1$  neurones de la première couche cachée et les  $w_{ij}^{l_1}$  sont les poids des connections entre les variables d'entrée et la première couche cachée. Le calcul de l'importance ne peut pas faire intervenir les autres couches cachées car la sortie de chacune de leur neurone dépend des sorties des neurones de la couche précédente seulement. D'une certaine manière, au-delà de la première couche, l'information sur l'importance des variables d'entrée se perd (d'autant plus que le nombre de couches cachées est grand). Le calcul de l'importance  $I_i$  donné par TMVA contient aussi un facteur multiplicateur  $\bar{x}_i$  qui rend difficile l'appréciation de l'importance réelle. On donne tableau 5.20 l'importance des différentes variables d'entrée utilisées dans les cas forme du cluster, environnement et les deux combinés. On peut voir que l'importance est d'ordres de grandeur très différents selon les variables, ce qui est probablement dû à la multiplication de la somme des poids par la valeur moyenne  $\bar{x}_i$ .

Nous avons essayé d'enlever tour à tour du réseau de neurone les variables les moins bien classées par une telle formule (entraîner avec  $N - 1$  puis  $N - 2$  variables) et des résultats surprenants ont été obtenus : les variables classées comme les moins performantes sont en fait celles qui, une fois supprimées, font le plus baisser les performances. Ceci peut être expliqué par deux raisons : d'une part la somme des poids est multipliée par la valeur moyenne de la variable (ce qui fausse les ordres de grandeur), et d'autre part l'importance des variables tient seulement compte de la première couche cachée. Une autre paramétrisation de l'importance des variables d'entrée a été proposée dans des études expérimentales [156], et utilisée référence [153] :

$$SI_i = \frac{\sum_j^{n_1} |w_{ij}^{l_1}|}{\sum_i^N \sum_j^{n_1} |w_{ij}^{l_1}|}$$

Dans cette formule, la somme des poids pour une variable donnée est normalisée par la somme des poids associés à toutes les variables. L'importance  $SI_i$  est un pourcentage, ce qui rend plus aisé la comparaison entre les variables. Les importances  $SI_i$  calculées de la sorte pour NNcluster, NNenv et NNcombiné sont données tableau 5.21. Pour NNcluster et NNenv, les trois variables d'entrée semblent d'importance à peu près égales, tandis que pour NNcomb, les variables de forme du cluster ainsi que  $\frac{p_{T,\gamma}}{p_{T,closestjet}}$  ont une im-

Importance $SI_i$ (%)	NNcluster	NNenv	NNcombiné
$cPP$	39.88	-	18.38
$R9$	27.07	-	20.71
$\sigma_\eta$	33.04	-	19.09
$\frac{p_{T,\gamma}}{p_{T,closestjet}}$	-	33.31	19.46
$\Delta R(\gamma, closestSC)$	-	29.39	12.22
$\Delta R(\gamma, closesttrack)$	-	37.30	10.14

FIG. 5.21 – Importance des variables d'entrée dans les réseaux de neurones en pourcentage, calculées selon [156] à l'issue de la phase d'entraînement.

portance double de celles obtenues par  $\Delta R(\gamma, closestSC)$  et  $\Delta R(\gamma, closesttrack)$ . Il semble donc qu'une importance plus grande soit accordée aux variables discriminantes qui sont corrélées pour les photons du signal (voir figure 5.13). Il faut toutefois se rappeler que ces importances sont seulement indicatives, dans la mesure où elles ne tiennent pas compte de la deuxième couche cachée et de la combinaison finale des neurones dans la sortie du réseau de neurones.

### Comparaison avec les performances des variables seules

Les performances de coupures sur les variables d'entrées seules ont été comparées à la performance obtenue avec un réseau de neurone entraîné sur ces variables d'entrée, dans le cas des variables de forme du cluster et d'environnement. La figure 5.22 montre que le réseau de neurone fait dans les deux cas mieux que chacune des variables d'entrées séparément. Dans le cas des variables de forme du cluster, le réseau de neurone donne une bien meilleure discrimination que les variables seules pour les hautes efficacités du signal (et une discrimination égale pour les basses efficacités du signal). Il est intéressant de noter que  $cPP$  utilisée seule semble être la variable la moins discriminante (alors que  $R9$  et  $\sigma_\eta$  ont un pouvoir de discrimination proches et plus élevé). Dans le cas des variables d'environnement, le réseau de neurone apporte partout une discrimination meilleure que les variables d'entrée seules.




FIG. 5.22 – Efficacité du signal versus rejection du bruit de fond pour les sorties des réseaux de neurones utilisant les variables de forme du cluster (à droite) et d'environnement (à gauche), comparées à la performance des variables d'entrées seules.

### Performances pour différentes catégories de photons

Nous nous intéressons maintenant aux performances des trois réseaux de neurones en fonction de diverses catégories de photons, dans le tonneau et les bouchons (figure 5.23), pour les photons convertis et non-convertis (figure 5.24), en fonction de plusieurs plages d'impulsion transverse (figure 5.25) et pour des critères d'isolation de plus en plus sévères (figure 5.26). L'entraînement est effectué une fois pour toute après préselection et les critères de sélection complémentaires sont demandés au moment de l'application (sur des échantillons différents de ceux utilisés pour l'entraînement). Dans un but d'optimisation, il serait

possible de ré-entraîner le réseau de neurone pour chacune des catégories, mais cela n'a pas été effectué ici.

Les trois réseaux de neurones montrent une bonne stabilité des performances en fonction des différentes catégories de photons (les performances sont proches les unes des autres quelle que soit la catégorie de photons). Les performances sont à peu près équivalentes dans le tonneau et les bouchons (sauf pour NNcluster qui semble être meilleur dans les bouchons). La discrimination est la meilleure pour les photons non convertis, suivis par les photons où dont les deux traces de conversions ont été reconstruites puis les photons où une seule trace a été reconstruite. D'une manière globale, les performances en fonction de l'impulsion transverse sont stables pour  $p_T > 30$  GeV et les variations semblent plutôt dues à l'incertitude statistique de chaque plage de  $p_T$ . La plage  $20 < p_T < 30$  GeV est peu peuplée par les photons du signal (qui ont plutôt une impulsion transverse de l'ordre de 60 GeV car issus du boson de Higgs) : le réseau de neurones n'a pas été entraîné pour reconnaître les photons de signal dans cette plage, ce qui explique la baisse de performance. Demander des photons de plus en plus isolés réduit le taux de bruit de fond rejeté par le réseau de neurone pour une même efficacité de signal (ce qui est compensé par le rejet du bruit de fond opéré par l'isolation elle-même). NNenv est le plus sensible à l'isolation, dans la mesure où les variables d'environnement sont corrélées aux variables classiques d'isolation.




FIG. 5.23 – Efficacité du signal en fonction du rejet du bruit de fond dans le tonneau (en rouge) et les bouchons (en bleu), dans le cas des 3 variables de forme du cluster seules (à gauche), des 3 variables d'environnement seules (au milieu) et dans les cas des 6 variables combinées (à droite).




FIG. 5.24 – Efficacité du signal en fonction du rejet du bruit de fond pour les photons non convertis (en rouge), les photons appariés à une (en bleu) et deux traces (en vert) de conversion, dans le cas des 3 variables de forme du cluster seules (à gauche), des 3 variables d'environnement seules (au milieu) et dans les cas des 6 variables combinées (à droite).

### Performance pour différents signaux et bruits de fond

Le réseau de neurone que nous présentons dans ce chapitre peut être utilisé dans toutes les analyses où on cherche une signature d'un ou plusieurs photons prompts (au moins pour les variables de forme du cluster). Si l'activité des jets autour des photons de signal est semblable à celle des échantillons de boson de Higgs, les variables d'environnement peuvent aussi être utilisées. Nous avons vérifié le comportement

tel-00598989, version 1 - 8 Jun 2011




FIG. 5.25 – Efficacité du signal en fonction du rejet du bruit de fond en fonction de l'impulsion transverse des photons :  $20 < p_T < 30$  GeV (en rouge),  $30 < p_T < 50$  GeV (en bleu),  $50 < p_T < 70$  GeV (en vert) et  $p_T > 70$  GeV (en orange), dans le cas des 3 variables de forme du cluster seules (à gauche), des 3 variables d'environnement seules (au milieu) et dans les cas des 6 variables combinées (à droite).




FIG. 5.26 – Efficacité du signal en fonction du rejet du bruit de fond pour des critères de plus en plus sévères d'isolation des photons, dans le cas des 3 variables de forme du cluster seules (à gauche), des 3 variables d'environnement seules (au milieu) et dans les cas des 6 variables combinées (à droite). En rouge :  $EcalIso < 4$  GeV et  $HcalIso < 2$  GeV. En bleu :  $EcalIso < 2$  GeV et  $HcalIso < 2$  GeV. En vert :  $EcalIso < 2$  GeV,  $HcalIso < 2$  GeV et  $TrackerIso < 2$  GeV. En rouge : comme précédemment, mais avec  $p_T > 40$  GeV ( $EcalIso$ ,  $HcalIso < 2$  et  $TrackerIso$  sont définies section 5.2.1).

des trois réseaux de neurones entraînés sur différents signaux et bruits de fond (voir figure 5.27). Les photons de  $H \rightarrow \gamma\gamma$ ,  $\gamma\gamma+X$  et  $\gamma+jet$  ont été essayés comme signal avec les photons non prompts issus des jets de QCD comme bruit de fond. Additionnellement, nous avons vérifié les performances du réseau de neurones pour les photons de signal issus du boson de Higgs et les photons non prompts issus des jets du processus  $\gamma+jet$  comme bruit de fond.




FIG. 5.27 – Efficacité du signal en fonction du rejet du bruit de fond en pour les réseaux de neurones entraînés sur différents signaux (“Sg”) et bruits de fond (“Bg”), dans le cas des 3 variables de forme du cluster seules (à gauche), des 3 variables d'environnement seules (au milieu) et dans les cas des 6 variables combinées (à droite).

Les performances des trois réseaux de neurones montrent une bonne stabilité en fonction des types de photons. Les photons du signal  $H \rightarrow \gamma\gamma$  donnent toujours de meilleures performances, que ce soit face aux photons non prompts des jets des processus QCD dijet ou  $\gamma$ +jet (la baisse de performance de ces derniers pour les variables d'environnement à haute efficacité du signal doit être due à une fluctuation statistique). Les photons du signal de  $\gamma\gamma+X$  et  $\gamma$ +jet donnent pratiquement les mêmes performances.

Nous avons aussi vérifié les performances pour différents générateurs. L'utilisation de Pythia [26] ou Madgraph [23] donnent les mêmes performances. Un gain substantiel de discrimination est obtenu en utilisant le générateur MC@NLO [122] au lieu de Pythia pour les photons du signal  $gg \rightarrow H \rightarrow \gamma\gamma$  [155].

Toutes les études précédentes ont été effectuées en sélectionnant les photons prompts dans le signal, et en supprimant les photons ISR/FSR du bruit de fond. L'inclusion des ISR/FSR dans le bruit de fond pour l'entraînement a été essayée et conduit à une dégradation des performances (les ISR/FSR ressemblent aux photons du signal même s'ils sont moins isolés). Nous avons aussi essayé de discriminer entre les photons prompts du signal et les photons ISR/FSR seulement, mais ni les variables de forme du cluster ni les variables d'environnement n'ont montré de réelle discrimination.

### 5.3.3 Comparaison avec une approche optimisée d'isolation

Les performances du réseau de neurone portant sur les six variables de forme du cluster et d'environnement ont été comparées avec celles obtenues par un réseau de neurone qui suit une approche optimisée d'isolation dite "NNisol" [144], que nous avons détaillée section 5.1.3. Pour plus de cohérence avec les valeurs seuils recommandées pour les analyses par les contributeurs de l'algorithme d'identification des photons, les cônes en  $\Delta R$  autour des photons ont été pris à une valeur de 0,3 (où les algorithmes de calcul de l'isolation sont les algorithmes officiels déjà décrit plus haut). Le réseau de neurone "NNisol" accepte cinq variables en entrée :  $R9$ ,  $\Delta R(\gamma, closesttrack)$ , l'énergie transverse d'isolation  $IsoEcal$  dans le ECAL,  $IsoHcal$  dans le HCAL et  $IsoTracker$  dans le trajectographe.




FIG. 5.28 – Efficacité du signal en fonction du rejet du bruit de fond pour différents réseaux de neurones. A gauche, comparaison des performances pour un réseau de neurones basé sur les 3 variables de forme du cluster NNcluster (en rouge), d'environnement NNenv (en bleu) et d'isolation (en vert). A droite, comparaison du réseau de neurone NNcomb (en rouge), NNisol (en bleu) et la combinaison de NNcomb et NNisol (en vert).

On trouve figure 5.28 (à gauche) une comparaison des performances de trois réseaux de neurones : NNcluster (variables de forme du cluster), NNenv (variables d'environnement) et les trois variables d'isolation. Avec les coupures de préselection, NNiso donne une performance égale à celle NNenv. A droite sur la figure 5.28, NNisol est comparé avec NNcomb. NNcomb donne de meilleures performances. Un gain peut être obtenu en combinant NNcomb et NNisol (9 variables au total : 3 de forme du cluster, 3 d'environnement et 3 d'isolation), mais un réseau de neurones basé sur 9 variables peut conduire à des incertitudes systématiques difficiles à contrôler à partir des données (et le gain apporté n'est pas tellement

grand). NNcomb obtient une performance bien meilleure que NNisol lorsque des critères d'isolation sévères sont appliqués ( $EcalIso < 2$  GeV,  $HcalIso < 2$  GeV et  $TrackerIso < 2$  GeV) pour des photons d'énergie transverse  $p_T > 40$  GeV, comme on peut le voir figure 5.29. L'espace de phase laissé à NNisol une fois ces critères d'isolation appliqué est restreint, ce qui explique la baisse de performance de NNisol, tandis que les trois variables de forme du cluster compensent la baisse de performance des variables d'environnement pour NNcomb.

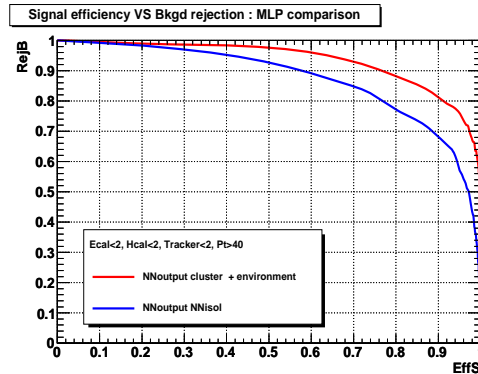


FIG. 5.29 – Efficacité du signal versus rejection du bruit de fond pour NNcomb (en rouge) et NNisol (en bleu), avec  $EcalIso < 2$  GeV,  $HcalIso < 2$  GeV et  $TrackerIso < 2$  GeV et  $p_T > 40$  GeV.

## 5.4 Incertitudes systématiques

Les réseaux de neurones permettent une discrimination du signal et bruit de fond supérieure à celles des critères de sélection sur variables seules par coupures séquentielles, mais ce sont des objets complexes. On ne peut s'en servir que si les incertitudes systématiques liées à leur utilisation sont évaluées et sous contrôle. Ces incertitudes dépendent en partie de la façon dont le réseau de neurone est utilisé (ce qui varie en fonction des besoins de l'analyse), mais il est déjà possible de lister les incertitudes liées à l'utilisation d'un réseau de neurone pour la discrimination  $\gamma/\pi^0$  et les moyens de les calculer. Nous montrerons un moyen de les déterminer à partir de la simulation, mais il serait encore plus intéressant de trouver des techniques pour les mesurer à partir des données. Nous proposerons ensuite de telles techniques, utilisables à différents stades d'accumulation de luminosité intégrée.

### 5.4.1 Source des incertitudes systématiques

Pour un réseau de neurones, on peut séparer les incertitudes systématiques en deux catégories. La première provient de l'algorithme par lequel est calculée la sortie du réseau de neurone (entraînement et application), et la seconde provient de la modélisation des variables d'entrée (qui va se répercuter sur la sortie du réseau de neurone). De ces deux incertitudes dépendent l'incertitude finale sur la sortie du réseau de neurone. Par la suite, cette incertitude se manifeste différemment selon que la forme de la distribution de la sortie du réseau de neurone est utilisée (par exemple pour une fonction de vraisemblance), ou qu'un critère de sélection sur cette sortie est appliqué.

#### Incertitude liées à l'algorithme du réseau de neurones

Les incertitudes liées à l'algorithme du réseau de neurones en lui-même peuvent être de plusieurs types :

- L'incertitude introduite par *l'entraînement du réseau de neurones*. Il est important de vérifier que le réseau de neurones n'a pas été surentraîné (si l'apprentissage a conduit le réseau de neurone à reconnaître des fluctuations du signal ou bruit de fond plutôt que le signal ou bruit de fond lui-même), ce qui s'effectue habituellement en comparant la sortie du réseau de neurone pour la phase d'entraînement et la phase de test. Si les deux distributions sont en accord dans la limite des incertitudes statistiques, il n'y a

pas surentraînement, ce qui est le cas pour les réseaux de neurones que nous avons présentés.

- Une fois entraîné, une *incertitude liée à son application* provient de la redondance des échantillons utilisés pour la phase d'entraînement et la phase d'application. Si certains évènements sont réutilisés pour l'application, un biais est introduit puisque les valeurs de sortie sont déjà connues. Il est nécessaire de vérifier qu'aucun évènement n'est présent en double dans l'échantillon d'entraînement et de test.

### Incertitude liées à la modélisation des variables d'entrée

Si on fait confiance à la sortie du réseau de neurones parce qu'il n'est pas surentraîné et qu'on a bien séparé l'échantillon d'entraînement et l'échantillon de test (comme c'est le cas pour celui que nous avons présenté), il reste à évaluer les incertitudes systématiques provenant de la modélisation des variables d'entrées. L'algorithme du réseau de neurone ne tient en effet pas compte des incertitudes (de mesure ou théoriques) sur les distributions fournies en entrée, mais seulement des valeurs des observables. Les incertitudes théoriques peuvent être évaluées par les méthodes habituelles de simulation (variation des paramètres de l'évènement sous-jacent et de fragmentation, des échelles d'énergie des processus considérés et des ensembles de densités partoniques). Il est possible de calculer par la simulation l'impact sur la sortie du NN introduit par une mesure biaisée, et les incertitudes de mesures et théoriques résiduelles peuvent ensuite être évaluées directement à partir des données.

Les *incertitudes de la simulation sur la réponse du détecteur* sont principalement introduites par la résolution du détecteur considéré et dues au bruit électronique et aux erreurs systématiques propres à la reconstruction des objets physiques (qui peuvent être calibrées à partir des données). Pour chaque mesure, il est possible de calculer l'incertitude systématique associée. Les auteurs de TMVA recommandent de calculer l'incertitude moyenne sur la variable d'entrée ayant le plus fort pouvoir discriminant, de déplacer artificiellement la moyenne de la distribution du bruit de fond dans le sens qui rend cette variable moins discriminante. Après entraînement, le biais est répercuté sur la sortie du réseau de neurone et peut être mesuré. Il est aussi possible d'ajuster les proportions de signal et bruit de fond dans la simulation de sorte que les distributions simulées des variables d'entrée soient les mêmes que dans les données.

Ces incertitudes doivent si possible être quantifiées à partir des données. L'idée est d'entraîner le réseau de neurone avec un lot d'échantillon de signal et/ou de bruit de fond sélectionné dans les données, et de quantifier l'écart par rapport aux prédictions. Dans le cas de la discrimination  $\gamma/\pi^0$ , nous proposons plusieurs analyses qui devraient permettre d'isoler un échantillon de signal ou de bruit de fond presque pur (voir section 5.4.2). Le risque est alors de contaminer l'échantillon de signal avec des évènements de bruit de fond (et vice-versa) puisque la pureté ne sera jamais de 100% : la stabilité du réseau de neurone face à ce problème doit aussi être démontrée.

Dans la mesure où CMS est maintenant en période de prise de données, nous n'insisterons pas sur le calcul des incertitudes systématiques à partir de la simulation. Nous effectuerons seulement quelques tests pour quantifier la performance obtenue lorsque le réseau de neurones est entraîné avec un échantillon de bruit de fond contaminé avec du signal (ou l'inverse). En revanche, nous proposons dans les lignes qui suivent quelques méthodes pour évaluer l'incertitude systématique directement à partir des données.

#### 5.4.2 Entraînement du réseau de neurones à partir des données

Dans la mesure où le modèle standard ne prédit aucune résonance qui se désintégrerait directement en photons durs ou isolés (à part le boson de Higgs qui n'a pas encore été découvert), il est toujours difficile de calibrer les observables sur les photons à partir des données. Les mésons neutres ( $\pi^0$  et  $\eta$  principalement) se désintégrant en paire de photons offrent une masse invariante trop faible et des photons non isolés ; et lorsque les photons émis sont durs, ils sont rassemblés dans le même super-cluster et deviennent un bruit de fond pour la recherche des signaux de photons prompts des processus  $\gamma+X$ ,  $\gamma\gamma+X$  et  $H \rightarrow \gamma\gamma$ . De ce point de vue, les analyses utilisant les électrons sont mieux loties, puisqu'elles bénéficient de la désintégration  $Z \rightarrow ee$  et  $W \rightarrow e\nu$  dont les masses sont bien connues et peuvent servir à différentes ap-



plications (calibration du ECAL, mesure des efficacités de reconstruction et d'identification des électrons par exemple).

Un réseau de neurones qui serait basé sur des variables d'isolation pourrait être entraîné à partir des données par la méthode "random cone" [138] (pour le bruit de fond). Dans le cas qui nous intéresse (variables de forme du cluster et variables d'environnement), l'utilisation d'une telle technique est impossible, car l'entraînement nécessite un lot réel de photons de signal ou du bruit de fond. La solution consiste à sélectionner un lot de photons pur de signal ou de bruit de fond, ou de sélectionner un lot d'évènements ayant des propriétés proches de celles du signal ou du bruit de fond.

Une technique a été proposée dans cette optique [153], qui consiste à utiliser de manière itérative la sortie du réseau de neurones pour sélectionner un lot pur de photons du signal et du bruit de fond dans les données. Dans les grandes lignes, l'idée consiste à entraîner le réseau de neurone sur des échantillons simulés et de l'appliquer ensuite aux données. Le bruit de fond pique en -1 et le signal en 1 : par des coupures sévères sur la sortie du réseau de neurones, il est possible de sélectionner un échantillon de photons enrichi en bruit de fond et un autre enrichi en signal. Les auteurs proposent ensuite d'utiliser ces lots de photons de données enrichies pour entraîner le réseau de neurone, et de le ré-appliquer aux données. Ce processus itératif nous paraît difficile à mettre en oeuvre, dans la mesure où à chaque itération un lot différent de données doit être utilisé pour ne pas biaiser le résultat. L'utilisation des mêmes variables pour la sélection des lots de photons enrichis et pour l'entraînement pourrait aussi biaiser le résultat. Une variante, dans notre cas, consisterait à sélectionner les lots de photons enrichis avec le réseau de neurone de forme du cluster (entraîné à partir de la simulation), et à entraîner avec ces lots le réseau de neurone d'environnement.

Nous proposons d'utiliser les photons certifiés issus du processus  $Z \rightarrow ll\gamma$  comme signal dès quelques centaines de  $pb^{-1}$ . Comme nous allons le montrer, l'utilisation des électrons du processus  $Z \rightarrow ee$  comme photons de signal est plus délicate à cause de la différence de comportement des électrons et des photons dans la matière. Nous proposons aussi une nouvelle technique pour sélectionner un lot de photons des jets des processus QCD et  $\gamma$ +jet comme bruit de fond. Enfin, il reste la possibilité d'utiliser les bandes de côtés autour de la fenêtre de masse  $\gamma\gamma$  dans laquelle est recherché le boson de Higgs pour sélectionner un lot de photons mal identifiés du bruit de fond.

### Entraînement avec les données dans les canaux de désintégration du $Z$

Pour estimer l'erreur systématique due à l'utilisation d'un réseau de neurones, il existe des solutions qui ont déjà fait leur preuve avec les données du Tevatron. Le canal  $Z \rightarrow ll\gamma$  ( $l = e, \mu$ ) peut être utilisé pour sélectionner un lot de photons certifiés avec une pureté supérieure à 95% [34]. La mesure de la section efficace  $\gamma\gamma+X$  de D0 [132] trouve un bon accord entre la sortie d'un réseau de neurone similaire au notre (basé sur des variables de forme du dépôt d'énergie) pour les photons de  $Z \rightarrow ll\gamma$  dans les données et les photons prompts de  $\gamma\gamma+X$  dans la simulation. Il est dès lors possible d'entraîner le réseau de neurone sur les photons certifiés de  $Z \rightarrow ll\gamma$  et de l'appliquer ensuite aux données dans les analyses recherchant des photons prompts.

Une autre solution consiste à utiliser le processus  $Z \rightarrow ee$  (dans lequel les électrons peuvent être sélectionnés avec une grande pureté) pour imiter les photons de signal. En tant qu'objet électromagnétique, les électrons se comportent d'une manière proche des photons dans la matière (gerbe électromagnétique). La difficulté réside ici en ce qu'il subsiste toujours des différences qui doivent être prises en compte dans des facteurs correctifs sur les grandeurs considérées.

Les figures 5.30 montrent les distributions des variables de forme du cluster pour les électrons de  $Z \rightarrow ee$  et les photons  $Z \rightarrow ll\gamma$ . Les distributions pour les photons de  $Z \rightarrow ll\gamma$  sont en excellent accord avec les distributions des photons des signaux  $\gamma$ +jet et  $\gamma\gamma+X$ . La désintégration  $H \rightarrow \gamma\gamma$  produit des photons plus durs, ce qui se traduit par des dépôts d'énergie plus concentrés. Les distributions pour les électrons de  $Z \rightarrow ee$  sont proches de celles de  $\gamma$ +jet et  $\gamma\gamma+X$  pour  $cPP$  et  $\sigma_\eta$  (avec un toutefois un léger

excès d'électrons pour  $\sigma_\eta > 0.04$ ). En revanche la distribution en  $R9$  est plus étalée pour les électrons que pour les photons du signal (sans toutefois être aussi étalée que les photons mal identifiés du bruit de fond). Ceci est dû au fait que les électrons commencent par émettre des photons de bremsstrahlung étalés en  $\phi$  durant leur passage dans la matière.




FIG. 5.30 – Distribution des variable de forme du cluster  $cPP$ ,  $R9$  et  $\sigma_\eta$  pour les électrons de  $Z \rightarrow ee$  et les photons prompts de  $Z \rightarrow ll\gamma$  comparées au bruit de fond et aux autres processus de signal.

Les mêmes études ont été effectuées pour les variables d'environnement (voir figure 5.31). Les distributions de  $\frac{PT_\gamma}{PT_{closestjet}}$  pour les électrons de  $Z \rightarrow ee$  et les photons de  $Z \rightarrow ll\gamma$  sont en bon accord avec les autres distributions de signal pour les valeurs au-dessus de 0.8. En-dessous, leur comportement est plus proche de celui des photons du bosons de Higgs.  $\Delta R(\gamma, closestSC)$  montre un bon accord entre les différents signaux.  $\Delta R(\gamma, closesttrack)$  est très différente pour les électrons, dans la mesure où la trace la plus proche du super-cluster est le plus souvent la trace associée à la trajectoire de l'électron dans le trajectographe.

Pour résumer, les distributions des variables d'entrée des photons de  $Z \rightarrow ll\gamma$  sont très proches de celles des autres processus de signal. Les électrons de  $Z \rightarrow ee$  ressemblent globalement aux photons du signal, mais sont plus étalés en  $R9$  et piquent beaucoup plus en 0 pour  $\Delta R(\gamma, closesttrack)$ . Ils ne peuvent donc pas être utilisés tels quels pour l'entraînement du réseau de neurone. Nous avons effectué une comparaison des différents types d'électrons pour la variable  $R9$  (voir figure 5.32). Les catégories "golden" et "big brem" présentent une distribution plus piquée en 1 que les électrons de gerbe ("showering") ayant émis de multiple photons de bremsstrahlung dans la matière. Aucune de ces trois catégories ne reproduit la forme de la distribution des photons de  $Z \rightarrow ll\gamma$ . Concernant  $\Delta R(\gamma, closesttrack)$ , la première chose à effectuer pour améliorer la similarité électron-photon serait d'enlever de la collection de traces celle qui serait appariée avec la trace reconstruite de l'électron.

En conclusion, les photons de  $Z \rightarrow ll\gamma$  peuvent être utilisés pour entraîner le réseau de neurone à

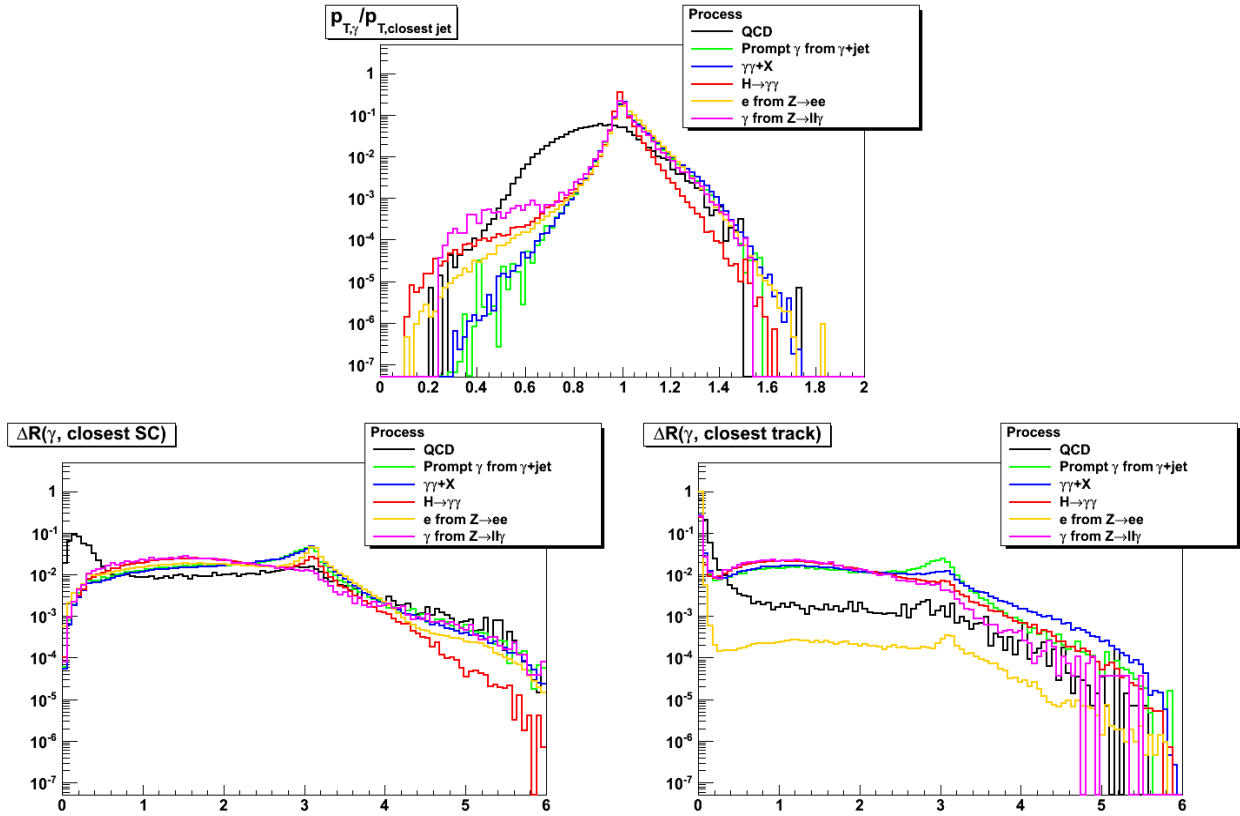


FIG. 5.31 – Distribution des variable d’environnement  $\frac{p_{T,\gamma}}{p_{T,closestjet}}$ ,  $\Delta R(\gamma,closestSC)$  et  $\Delta R(\gamma,closesttrack)$  pour les électrons de  $Z \rightarrow ee$  et les photons prompts de  $Z \rightarrow ll\gamma$  comparées au bruit de fond et aux autres processus de signal.

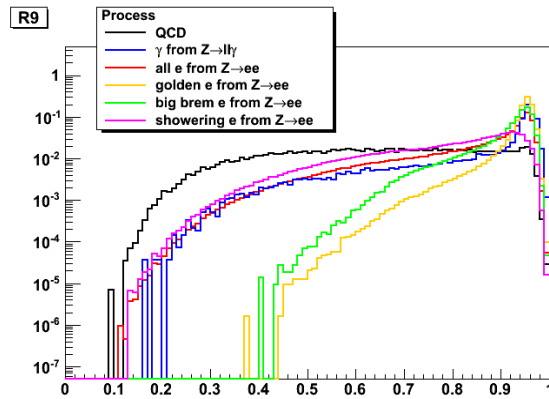


FIG. 5.32 – Distribution de  $R9$  pour différentes catégories d’électrons de  $Z \rightarrow ee$  et pour les photons prompts de  $Z \rightarrow ll\gamma$ .

partir des données, tandis que les électrons ne ressemblent pas suffisamment aux photons pour pouvoir être utilisés pour l’entraînement. En revanche, il est possible d’entraîner le réseau de neurone à partir de photons de signal simulé, et de comparer la sortie du réseau de neurone sur le processus  $Z \rightarrow ee$  dans les données et la simulation associée. La différence entre les deux distributions peut être comprise comme incertitude systématique [157] sur l’utilisation du réseau de neurones.

## Jets identifiés comme des photons dans le processus $\gamma$ +jet comme bruit de fond

A côté de ces deux techniques précédentes, nous voulons proposer une nouvelle méthode qui utilise la cinématique des événements  $\gamma$ +jet pour sélectionner un lot de photons non prompt des jets avec une grande pureté dans les données, qui sera expliquée plus en détail et mis en pratique section 6.3.

A l'arbre, le photon et le jet de l'interaction dure des événements  $\gamma$ +jet sont émis dos-à-dos, et presque dos-à-dos dans le cas d'une émission réelle d'un jet ou d'un photon mou dans l'état initial. En demandant deux photons pratiquement dos-à-dos dans l'événement, et en marquant le photon prompt par des critères d'isolation, on peut sélectionner le photon non prompt qui lui est opposé. Ceci conduit à la sélection d'un lot de photons du bruit de fond presque pur dans les données (provenant soit des processus  $\gamma$ +jet, soit QCD dijet). Il est toutefois nécessaire d'effectuer l'opération sur un petit lot d'événements et sans utiliser de critères d'isolation trop forts, sans quoi une contamination de photons de signal de  $\gamma$ +jet et  $\gamma\gamma$  peut biaiser l'entraînement.

## Bande de côté du processus $H \rightarrow \gamma\gamma$ comme bruit de fond

Enfin, lorsque une luminosité intégrée conséquente sera accumulée, il va devenir possible d'utiliser les bandes de côté de la distribution de masse invariante  $\gamma\gamma$  pour sélectionner un lot de photons du bruit de fond dans les données. Le boson de Higgs est cherché dans la plage de masse invariante  $100 < m_H < 150$  GeV. En sélectionnant les événements hors de cette plage de masse (sans demander des critères d'isolation trop sévères), il est possible de sélectionner un lot d'événements enrichi en photons du bruit de fond qui pourront être utilisés pour l'entraînement.

## 5.5 Validation à partir des données

Depuis les premières collisions à une énergie de 7 TeV dans le centre de masse, CMS a accumulé environ  $7 \text{ nb}^{-1}$  de données (au moment où j'écris ces lignes). Les algorithmes conçus à partir des événements simulés peuvent maintenant être testés dans les données. Nous présentons dans cette section la validation du réseau de neurones pour la discrimination  $\gamma/\pi^0$  dans les données avec une luminosité intégrée de  $6,7 \text{ nb}^{-1}$ . Dans un premier temps, les échantillons utilisés et les critères de sélection utilisés seront précisés, puis nous comparerons données et simulation pour les variables d'entrée et de sortie du réseau de neurones. Nous terminerons la validation par l'examen de la performance du réseau de neurones.

### 5.5.1 Sélection

Un échantillon de données avec une luminosité intégrée de  $6,7 \text{ nb}^{-1}$  à une énergie de 7 TeV dans le centre de masse a été utilisé. L'acquisition a été effectuée avec le déclenchement de haut niveau "e/gamma", constitué d'un "OU" de chacune des voies de déclenchement listées tableau 5.33. Les voies de déclenchement spécifiques "Jpsi", "Upsilon" et "eeRes" appliquent un critère de sélection supplémentaire sur la masse invariante. Pour les électrons, l'appariement avec un coup dans le détecteur à pixels est demandé, ainsi que le critère lâche  $H/E < 0.2$ . Un filtre correspondant à ces mêmes voies de déclenchement a aussi été appliqués aux échantillons simulés. Au total, l'échantillon contient 827825 événements. Un échantillon avec simulation complète du détecteur de QCD dijet et un autre  $\gamma$ +jet avec  $p_T > 15$  GeV générés avec Pythia [26] ont été utilisés.

Les critères de sélection suivants sont ensuite appliqués aux photons :

- On considère les photons dont le super-cluster reconstruit a une énergie transverse non corrigée  $E_T > 2$  GeV dans la région de pseudo-rapacité  $|\eta| < 2.5$ . Les super-clusters compris dans la région de transition entre le tonneau et les bouchons  $1.4442 < |\eta| < 1.566$  sont rejetés.
- Pour supprimer les "spikes" [38], un critère  $S4/S1 - 1 > 0.95$  est appliqué, où  $S4$  est la somme des énergies des quatre cristaux adjacents (haut, bas, gauche, droite) au cristal de plus haute énergie, et  $S1$  est l'énergie du cristal de plus haute énergie dans le super-cluster.
- On demande ensuite que les photons aient une énergie transverse  $E_T > 20$  GeV. Les mêmes critères

Voie de déclenchement	Objet	Seuil L1 (GeV)	Seuil HLT (GeV)
HLT_Photon10_L1R	Photon relaxé	5	10
HLT_Photon15_L1R	Photon relaxé	8	15
HLT_Photon15_LooseEcalIso_L1R	Photon isolé	8	15
HLT_Photon20_L1R	Photon relaxé	8	20
HLT_Photon30_L1R_8E29	Photon relaxé	8	30
HLT_DoublePhoton4_Jpsi_L1R	Double photon relaxé	2,2	4,4
HLT_DoublePhoton4_Upsilon_L1R	Double photon relaxé	2,2	4,4
HLT_DoublePhoton4_eeRes_L1R	Double photon relaxé	2,2	4,4
HLT_DoublePhoton5_Jpsi_L1R	Double photon relaxé	5,5 ou 8	5,5
HLT_DoublePhoton5_Upsilon_L1R	Double photon relaxé	5,5 ou 8	5,5
HLT_DoublePhoton5_L1R	Double photon relaxé	5,5	5,5
HLT_DoublePhoton10_L1R	Double photon relaxé	5,5	10,10
HLT_DoubleEle5_SW_L1R	Double électron relaxé	5,5	5,5
HLT_Ele20_LW_L1R	Electron relaxé	8	20
HLT_Ele15_SiStrip_L1R	Electron relaxé	8	15
HLT_Ele15_SC10_LW_L1R	Electron relaxé	8	15
HLT_Ele15_LW_L1R	Electron relaxé	8	15
HLT_Ele10_LW_EleId_L1R	Electron relaxé	5	10
HLT_Ele10_LW_L1R	Electron relaxé	5	10
HLT_Photon15_TrackIso_L1R	Photon isolé	8	15

FIG. 5.33 – Voies de déclenchement incluses dans le déclenchement “e/gamma” pour les premières données.

d’isolation demandant au maximum 4 GeV dans le ECAL et 2 GeV dans le HCAL dans un cône  $\Delta R = 0.3$  autour du photon sont ensuite appliqués (voir section 5.2.1).

On montre figure 5.34 les énergies d’isolation dans le ECAL et le HCAL pour les photons ayant  $E_T > 20$  GeV. Les distributions simulées sont globalement en accord avec les données, sauf en ce qui concerne le premier bin ( $0 < E_T < 0.5$  GeV) qui montre un excès d’évènement dans les données, ce qui est dû à la présence de “spikes” résiduels et à une simulation encore trop approximative du bruit électronique.




FIG. 5.34 – Distribution des énergies d’isolation dans le ECAL (à gauche) et le HCAL (à droite) dans les données et la simulation. Les distributions sont normalisées au nombre de photons dans les données.

Pour l’étude des variables d’entrées et de la sortie du réseau de neurones, tous les photons passant ces critères de préselection sont sélectionnés (photons déclenchant ou autres photons de l’évènement). Le

Coupure	Nombre de photons
Nombre initial	1101065
SC $E_T > 2$ GeV	1101064
Acceptance en $\eta$	995149
Suppression des "spikes"	754980
Photon $E_T > 20$ GeV	35497
Isolation ECAL	24627
Isolation HCAL	16269

FIG. 5.35 – Nombre de photons passant les coupures de préselection dans les données.

Particule	Quantité (%)
Electron	1.52
Photon partonique (de $\gamma$ +jet)	0.63
Photon issu d'un quark/gluon	3.19
Photon issu d'un $\pi^0$	81.10
Photon issu d'un $\eta$	10.89
Photon issu d'un $\rho$	2.15
Photon issu d'un $\omega$	0.01

FIG. 5.36 – Composition des échantillons QCD /  $\gamma$ +jet après préselection.

tableau 5.35 résume le nombre de photons passant chacune des coupures dans les données. La coupure sur l'énergie transverse du super-cluster enlève un seul photon car le seuil de reconstruction des photons est  $E_T > 5$  GeV. Après préselection, les photons reconstruits sont appariés avec la particule générateur la plus proche en impulsion transverse dans un cône  $\Delta R(\gamma_{rec}, \gamma_{gen}) < 0.1$ . Le tableau 5.36 résume la composition de l'échantillon QCD et  $\gamma$ +jet.

### 5.5.2 Variables d'entrée

On montre figure 5.37, 5.38, 5.39 les distributions des variables de forme du cluster dans les données et la simulation (échantillon de QCD et  $\gamma$ +jet). D'une manière générale, les distributions montrent un accord raisonnable entre les données et la simulation. Toutefois, les données présentent des événements aux basses valeurs de  $cPP$  et  $\sigma_\eta$  dans le tonneau. Ceci est du aux spikes résiduels qui n'ont pas été nettoyés par la préselection. Comme ces événements sont peu nombreux par rapport au nombre total, on ne s'en souciera pas pour la suite. Ils pourraient être éliminés avec un critère de sélection sur la synchronisation en temps [38].

Les distributions des variables d'environnement dans les données et la simulation sont présentées figures 5.40, 5.41, 5.42. Ici aussi, données et simulation s'accordent raisonnablement. Les queues des distributions  $\Delta R(\gamma, closesttrack)$  sont faiblement peuplées ce qui rend difficile de quantifier le désaccord s'il y en a un. L'exception à cet accord a lieu pour la variable  $\frac{PT_\gamma}{PT_{closestjet}}$  dans les bouchons. Ceci est du au fait que la collection des jets reconstruits calorimétriques utilisée n'est pas corrigée ; or les plus grandes corrections en énergie des jets sont attendues précisément à grand  $\eta$  (l'étude devrait être répétée avec les corrections et identification des jets). Le désaccord pourrait aussi provenir de tours bruyantes dans le HCAL (aucun algorithme d'identification des jets n'a été appliqué).

### 5.5.3 Entraînement et test des réseaux de neurones

Les trois réseaux de neurones (variables de forme du cluster, d'environnement et combinées) ont été entraînés avec les échantillons de simulation, avec comme signal tous les photons partoniques de  $\gamma$ +jet




FIG. 5.37 – Distribution de la variable d'entrée  $cPP$  dans les données et la simulation, dans le tonneau (à gauche) et les bouchons (à droite).




FIG. 5.38 – Distribution de la variable d'entrée  $R9$  dans les données et la simulation, dans le tonneau (à gauche) et les bouchons (à droite).




FIG. 5.39 – Distribution de la variable d'entrée  $\sigma_\eta$  dans les données et la simulation, dans le tonneau (à gauche) et les bouchons (à droite).

et comme bruit de fond tous les photons non ISR/FSR de QCD dijet (contenant aussi les faux photons instrumentaux) auxquels le filtre correspondant au déclenchement e/gamma a été appliqué. On montre la sortie du réseau de neurones pour la phase d'entraînement et de test ainsi que les comparaisons des performances des variables seules par rapport au réseau de neurone qui les combine figure 5.43 pour le

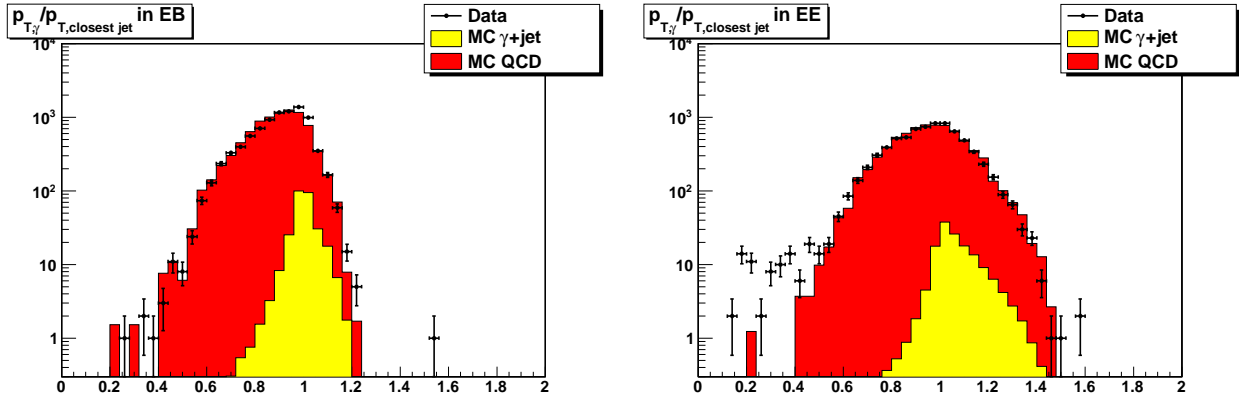


FIG. 5.40 – Distribution de la variable d’entrée  $\frac{p_{T,\gamma}}{p_{T,closest\ jet}}$  dans les données et la simulation, dans le tonneau (à gauche) et les bouchons (à droite).




FIG. 5.41 – Distribution de la variable d’entrée  $\Delta R(\gamma, closest\ SC)$  dans les données et la simulation, dans le tonneau (à gauche) et les bouchons (à droite).




FIG. 5.42 – Distribution de la variable d’entrée  $\Delta R(\gamma, closest\ track)$  dans les données et la simulation, dans le tonneau (à gauche) et les bouchons (à droite).

NN de forme du cluster, 5.44 pour le NN d’environnement et 5.45 pour leur combinaison. Les NN ne sont pas surentraînés et montrent plus de discrimination que les variables d’entrée seules, particulièrement à haute efficacité du signal. Le réseau de neurone combiné est plus performant que le réseau de neurones de forme du cluster et d’environnement séparément.

tel-00598989, version 1 - 8 Jun 2011



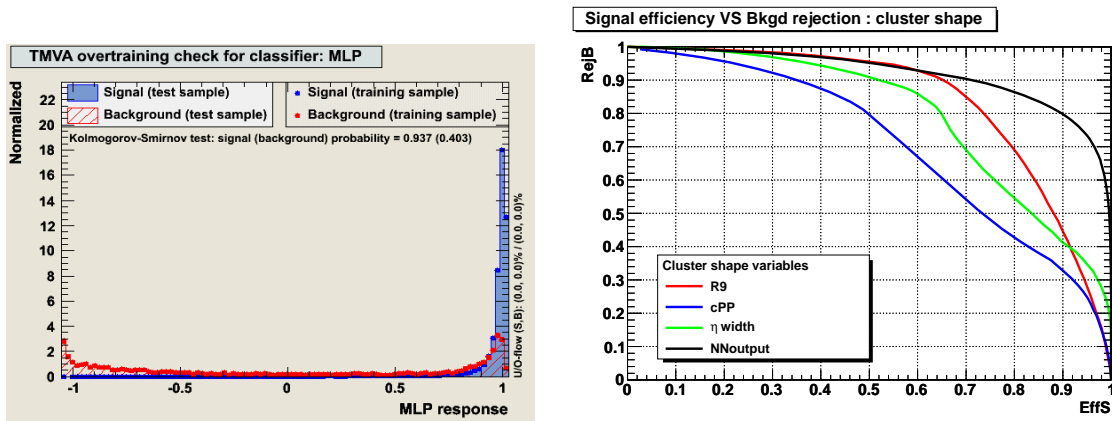


FIG. 5.43 – A gauche, comparaison des distributions de sortie du réseau de neurones de forme du cluster pour la phase d’entraînement et de test. A droite, efficacité du signal en fonction du rejet du bruit de fond pour les variables de forme du cluster seules comparées à leur combinaison dans le réseau de neurones.




FIG. 5.44 – A gauche, comparaison des distributions de sortie du réseau de neurones d’environnement pour la phase d’entraînement et de test. A droite, efficacité du signal en fonction du rejet du bruit de fond pour les variables d’environnement seules comparées à leur combinaison dans le réseau de neurones.

### 5.5.4 Sortie des réseaux de neurones dans les données

Lors de l’application des réseaux de neurones aux données, dans le but de montrer comment le signal peut apparaître dans les sorties des NN des critères supplémentaires d’isolation ont été appliqués qui ressemblent aux critères officiels recommandés pour l’identification des photons. En plus de la préselection, une énergie transverse d’isolation dans le trajectographe inférieure à 2 GeV est demandée dans un cône  $\Delta R < 0.3$  autour des photons, ainsi que  $H/E < 0.05$ . Pour chacun des trois réseaux de neurones, on montre figure 5.46, 5.47 et 5.48 les distributions de sortie dans les données et la simulation avec deux définitions différentes du signal et du bruit de fond. A gauche, est inclu comme signal tous les photons passant les coupures dans l’échantillon de  $\gamma$ +jet et comme bruit de fond tous les photons passant les coupures dans l’échantillon de QCD. A droite est défini comme signal tous les photons partoniques de  $\gamma$ +jet ainsi que les ISR/FSR provenant des échantillons  $\gamma$ +jet et QCD passant les coupures, et comme bruit de fond tous les autres photons (mal identifiés).

Les distributions de sortie du réseau de neurone de forme du cluster dans la simulation s’accordent particulièrement bien aux données (particulièrement pour les hautes valeurs où est concentré le signal),

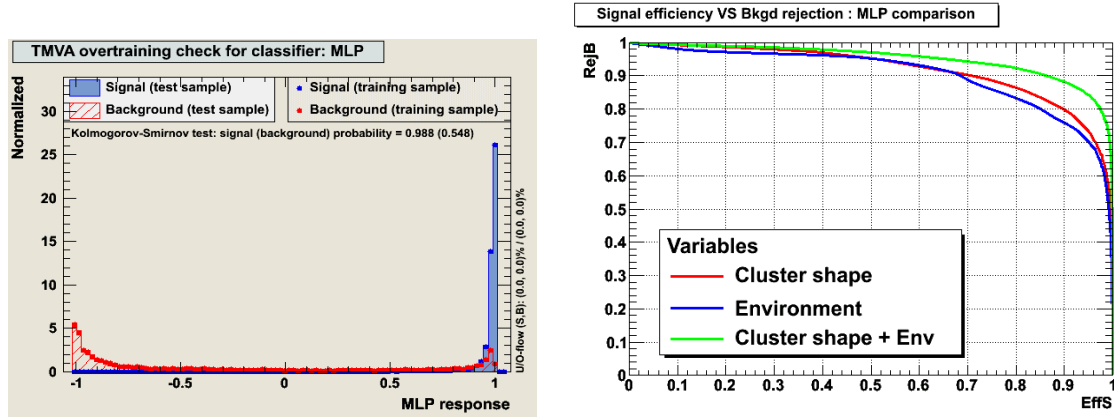


FIG. 5.45 – A gauche, comparaison des distributions de sortie du réseau de neurones de forme du cluster et environnement combiné pour la phase d’entraînement et de test. A droite, efficacité du signal en fonction du rejet du bruit de fond pour le réseau de neurones de forme du cluster, environnement et combiné.

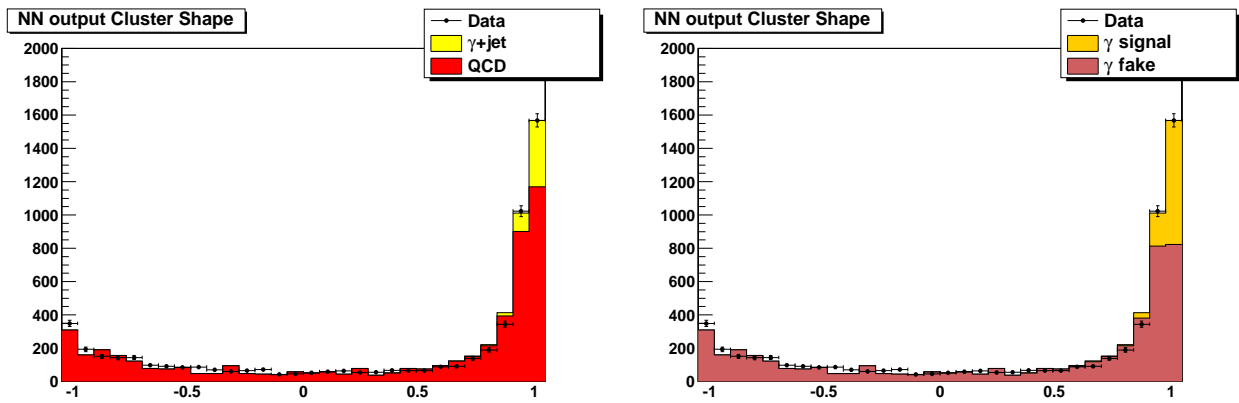


FIG. 5.46 – Sortie du réseau de neurone de forme du cluster dans les données et la simulation pour deux définitions du signal et du bruit de fond (voir texte).




FIG. 5.47 – Sortie du réseau de neurone d’environnement dans les données et la simulation pour deux définitions du signal et du bruit de fond (voir texte).

tandis que l’accord est raisonnable mais moins bon pour les réseaux de neurone d’environnement et combiné. Ceci est probablement dû à la variable  $\frac{PT,\gamma}{PT,closestjet}$  qui montre un désaccord dans les données et la simulation pour le tonneau, ou alors à une mauvaise simulation de la corrélation entre les variables




FIG. 5.48 – Sortie du réseau de neurone de forme du cluster et d’environnement combiné dans les données et la simulation pour deux définitions du signal et du bruit de fond (voir texte).

d’entrées. Après les coupures appliquées, le signal apparaît clairement et se différencie du bruit de fond en ce qu’il pique en 1, tandis que le bruit de fond est plus étalé (et pique légèrement en -1). Il est aussi intéressant de noter que la deuxième définition du signal et du bruit de fond (histogrammes de droite) présente un plus grand nombre d’évènements de signal que la première définition. C’est cette deuxième définition que nous allons utiliser pour la mesure de la section efficace inclusive  $\gamma+X$  chapitre 6.2.

## 5.6 Conclusions et perspectives

Nous avons proposé une nouvelle approche pour la discrimination  $\gamma/\pi^0$  basée sur un réseau de neurones (NN) qui accepte 6 variables d’entrée : 3 variables de forme du cluster ( $cPP$ ,  $R9$  et  $\sigma_\eta$ ) et 3 variables d’environnement ( $\frac{p_{T,\gamma}}{p_{T,closestjet}}$ ,  $\Delta R(\gamma,closestSC)$  et  $\Delta R(\gamma,closesttrack)$ ) non corrélées avec les variables d’isolation classiques. Le réseau de neurone est le classifieur qui donne les meilleurs résultats, en faisant usage des corrélations entre les variables d’entrée. Il est séparable en deux selon qu’on choisisse d’utiliser les 6 variables ou seulement les variables de forme du cluster ou d’environnement. Chaque réseau de neurone séparé donne une meilleure discrimination que l’usage des variables d’entrées seules. Les variables de forme du cluster donnent une meilleure performance que les variables d’environnement. Entraîné avec les photons du boson de Higgs comme signal, le rejet du bruit de fond pour 90% d’efficacité du signal atteint 87% avec les variables de forme du cluster, 85% pour les variables d’environnement et 93% pour leur combinaison. Ces résultats sont meilleurs que ceux obtenus dans les analyses de discrimination  $\gamma/\pi^0$  de CMS, avec un plus petit nombre de variables. De plus, l’analyse offre un traitement conjoint des photons convertis et non-convertis.

Le réseau de neurones montre une bonne stabilité en fonction des différentes catégories de photons. La performance est approximativement la même dans le tonneau et les bouchons, que le photon soit converti ou non (avec une meilleure performance obtenue pour les photons non-convertis), et dans les différentes plages d’impulsion transverse essayées. Les performances diminuent lorsque des critères d’isolation de plus en plus sévères sont appliqués (mais cela est compensé par le rejet du bruit de fond opérée par l’isolation même). Les performances sont les meilleures lorsque le réseau de neurone est entraîné sur les photons du signal  $H \rightarrow \gamma\gamma$ . Les performances obtenues avec entraînement sur les photons du signal  $\gamma+jet$  et  $\gamma\gamma+X$  sont équivalentes. Les performances du réseau de neurone a aussi été comparées à un réseau de neurones combinant  $R9$ ,  $\Delta R(\gamma,closesttrack)$  et les trois variables classiques d’isolation, utilisé pour l’analyse  $H \rightarrow \gamma\gamma$  du TDR et a donné de meilleures performances, surtout dans le cas où des critères d’isolation sévères sur des photons de  $p_T > 40$  GeV (typique des analyses de recherche du boson de Higgs) sont appliqués.

Les incertitudes systématiques liées à l'utilisation d'un réseau de neurones sont de deux types : intrinsèques au réseau de neurones (problème du surentraînement et du recouplement de l'échantillon de signal et de test), et extrinsèques (relatives à la mauvaise modélisation des variables d'entrée dans la simulation). Le réseau de neurones présenté n'est pas surentraîné (il est d'ailleurs sur ce point plus robuste que le BDT), et le choix d'un échantillon différent d'entraînement et de test a été effectué pour ne pas biaiser le résultat. En ce qui concerne les incertitudes portant sur les variables d'entrées et qui se propagent sur la sortie du réseau de neurones, plusieurs méthodes ont été proposées pour contourner le problème (en entraînant le réseau de neurones à partir des données), ou pour mesurer les incertitudes systématiques à partir des données. Dès  $200 \text{ pb}^{-1}$  de luminosité intégrée dans les données, un lot de 2000 photons certifiés sélectionné par l'analyse du canal  $Z \rightarrow l\gamma$  sera disponible et pourra être utilisé comme signal. Les électrons de  $Z \rightarrow ee$  sont disponibles plus tôt ( $10 \text{ pb}^{-1}$ ) mais ne peuvent pas être utilisés directement pour l'entraînement en raison de la différence de forme de la distribution  $R9$  par rapport aux photons du signal. En revanche, entraîner le réseau de neurone à partir d'un échantillon Monte-Carlo  $\gamma\gamma+X$  par exemple, et appliquer le réseau de neurone aux électrons de  $Z \rightarrow ee$  du Monte-Carlo et des données peut permettre une première estimation de l'incertitude systématique. Une autre méthode a été proposée, qui consiste à utiliser la cinématique des événements  $\gamma$ +jet pour sélectionner un lot de photons du bruit de fond presque pur. La technique sera démontrée section 6.3. Enfin, lorsque suffisamment de luminosité intégrée sera disponible, il deviendra possible d'utiliser les bandes de côtés de la distribution en masse invariante  $\gamma\gamma$  pour sélectionner un lot de photons du bruit de fond utilisable pour l'entraînement.

Les variables d'entrées et la sortie du réseau de neurones ont été validées dans les données, avec une luminosité intégrée de  $6,71 \text{ nb}^{-1}$ . La comparaison entre les données et la simulation montre un assez bon accord global. Quelques différences de forme subsistent en particulier pour  $\frac{p_{T,\gamma}}{p_{T,\text{closestjet}}}$ , pour laquelle les corrections en énergie des jets et une identification des jets devraient être appliquées. Il subsiste aussi quelques "spikes" qui passent la préselection et qui devraient être supprimés par des critères de synchronisation.

Pour améliorer les performances du réseau de neurone, il serait possible d'inclure l'information du détecteur pied de gerbe dans les bouchons, en particulier utiliser la variable  $ESratio = \frac{E_{3\text{avant}}+E_{3\text{arriere}}}{E_{21\text{avant}}+E_{21\text{arriere}}}$  (où  $E_{3\text{avant}}$  et  $E_{3\text{arriere}}$  sont les énergies des 3 pistes de la plaque avant et arrière centrées autour du cristal de plus haute énergie (idem pour  $E_{21\text{avant}}$  et  $E_{21\text{arriere}}$ )). Il serait aussi envisageable de ré-investiguer l'usage des variables de conversion.

Dans les chapitres qui vont suivre, le réseau de neurone que nous venons de décrire sera appliqué à différents canaux de physiques :  $\gamma+X$ ,  $\gamma\gamma+X$  et  $H \rightarrow \gamma\gamma$ .

## Chapitre 6

# Analyses du processus $\gamma+X$ dans les données

L'analyse des processus  $\gamma+X$  et  $\gamma$ +jet constitue une importante étape pour la recherche du boson de Higgs, en ce que leur étude fournit une première compréhension des photons isolés et de leurs propriétés. On entend par processus  $\gamma+X$  (photon inclusif) tous les processus de production d'un photon prompt (incluant  $\gamma$ +jets et  $\gamma\gamma$ +jets ainsi que les photons de fragmentation) lors de l'interaction dure, et par  $\gamma$ +jet(+X) tous les processus de production d'un photon prompt en association avec un jet de l'interaction dure. L'étude de ces canaux revêt aussi un intérêt théorique, car la mesure de la section efficace du processus  $\gamma$ +jet permet de sonder la précision des prédictions de la QCD perturbative et celle du processus  $\gamma+X$  d'apporter des contraintes supplémentaires aux ajustements des ensembles de distributions partoniques. Le processus  $\gamma$ +jet est également important du point de vue expérimental pour déterminer les corrections en énergie des jets.

On ne mentionnera pas le détail des différentes analyses  $\gamma+X$  effectuées au Tevatron par CDF et D0 (dernièrement [158] et [157]). Nous résumerons simplement la marche à suivre pour l'analyse inclusive. L'enjeu de ces analyses est la mesure de la section efficace différentielle de production inclusive de photons. Pour réaliser cette mesure, l'outil employé est la soustraction de bruit de fond par la méthode des "templates". Il existe plusieurs variantes de cette méthode (qui seront exposées plus loin). Toutes les méthodes reposent sur la construction d'une distribution "template" pour le signal et une autre pour le bruit de fond, utilisées pour déterminer la pureté de l'échantillon dans les données. Différentes variables sont utilisées pour la distribution des templates, l'essentiel étant que la variable ait un fort pouvoir discriminant entre signal et bruit de fond. Une fois la pureté calculée, le nombre d'événements de signal est dérivé. La méthode classique pour comparer ce nombre d'événements avec les prédictions théoriques consiste alors à corriger le nombre d'événements pour toutes les inefficacités expérimentales et à le diviser par la luminosité intégrée. Les sections efficaces mesurées peuvent alors être comparées aux sections efficaces théoriques.

Dans un premier temps, nous exposerons les prédictions théoriques de section efficace au NLO. Nous introduirons alors la configuration du réseau de neurones de discrimination  $\gamma/\pi^0$ , qui est l'outil par lequel nous obtiendrons les distributions templates pour le signal et le bruit de fond. L'incertitude systématique sur la luminosité est encore grande étant donné la luminosité accumulée dans les premières données. Suivant l'analyse [159], nous ne proposons pas dans ce chapitre une mesure de la section efficace différentielle inclusive mais seulement une mesure de la pureté et du nombre d'événements de signal mesuré dans les données : nous ne comparerons pas les résultats aux prédictions théoriques. Par la suite, nous présenterons une méthode pour entraîner le réseau de neurones à partir des données qui utilise la cinématique des événements  $\gamma$ +jet.

### 6.1 Signal $\gamma$ +jet attendu

La production d'un photon prompt lors de l'interaction dure peut être effectuée à l'arbre selon deux mécanismes : l'annihilation quark/anti-quark et la diffusion quark-gluon (plus important en terme de section efficace du fait de la haute luminosité en gluons au LHC). Les corrections de QCD au NLO incluent l'émission d'un jet supplémentaire et les corrections d'émission-absorption de gluons virtuels et de boucles virtuelles. De plus, le processus de fragmentation d'un quark en photon dans les processus de QCD du type  $q\bar{q} \rightarrow q\bar{q}$  (et diagrammes associés) peuvent aussi conduire à la production d'un photon prompt. Le programme JetPhox [160, 161] (des mêmes auteurs que le programme Diphox pour la production directe de diphotons) permet de prédire la section efficace de production inclusive de photons prompts, et inclut les processus à l'arbre et les processus de fragmentations jusqu'au NLO (voir figure 6.1 pour les diagrammes de Feynman associés).




FIG. 6.1 – Diagrammes de Feynman associés à la production d'un photon direct. A gauche, diagramme de diffusion quark-gluon. A droite diagramme de fragmentation (les deux au LO).

On montre figure 6.2 la section efficace différentielle de production inclusive de photons prompts en fonction de l'impulsion transverse  $p_T$  des photons (pour  $p_T > 15$  GeV), calculée avec JetPhox pour différentes énergies dans le centre de masse. Avec une énergie de 7 TeV dans le centre de masse, environ 220 photons de signal par  $nb^{-1}$  sont attendus.




FIG. 6.2 – Section efficace différentielle (en pb) en fonction de l'impulsion transverse des photons [159].

## 6.2 Mesure du spectre inclusif des photons par la méthode des templates dans les données

Dans cette section, nous nous laisserons guider par la stratégie développée dans la ref. [159]. Dans cette note, trois types de variables sont utilisées comme templates : une variable de forme du dépôt d'énergie ( $\sigma_{in\eta}$  dans le tonneau et  $ESratio$  dans les bouchons), une variable d'isolation ( $EcalIso + HcalIso + TrackerIso$ ) et une variable de conversion ( $p/E$ , où  $p$  est l'impulsion de la paire  $e^+/e^-$  mesurée dans le trajectographe et  $E$  l'énergie du super-cluster associé). Cette stratégie se base elle-même sur une publication de la collaboration CDF [158], où la variable de template principale était une variable d'isolation, tandis que les variables de forme du cluster et de conversions ont été utilisées pour des vérifications croisées. Une autre stratégie, utilisée par la collaboration D0 [157], fait usage de la sortie d'un réseau de neurones comme variable template. Ce réseau de neurones utilise trois variables d'isolation et une de forme du cluster. L'approche que nous allons développer ici est assez similaire dans la mesure où nous proposons d'utiliser le réseau de neurone de discrimination  $\gamma/\pi^0$  comme variable de template.

Dans un premier temps, nous expliciterons la sélection effectuée sur les photons, qui utilise le déclenchement technique ainsi que le déclenchement  $e/\gamma$ , suivi d'un premier procédé d'identification des photons basé sur l'isolation. Les configurations du réseau de neurone de discrimination  $\gamma/\pi^0$  utilisées dans l'analyse seront ensuite explicitées. Nous présenterons alors deux méthodes différentes de templates, la méthode simple "2 bins" (ou deux divisions) et la méthode d'ajustement par maximum de vraisemblance. Les résultats seront obtenus avec les deux méthodes, en utilisant comme template la sortie du réseau de neurones : pureté des photons du signal en fonction de l'impulsion transverse des photons, et spectre en impulsion transverse des photons. La construction de la distribution template à partir de photons des données sera ensuite évoquée, par la méthode des bandes de côtés dans le spectre d'isolation. Enfin, nous discuterons les incertitudes systématiques sur la mesure effectuée.

### 6.2.1 Préselection des photons

Pour cette analyse, un échantillon de données ayant une luminosité intégrée de  $10,24 \text{ nb}^{-1}$  a été utilisé. La préselection des photons dans les données et la simulation est effectuée selon plusieurs étapes. Les données sont acquises selon certaines voies de déclenchement afin de minimiser la bande passante utilisée tout en gardant une haute efficacité de signal. Les voies de déclenchement "e/gamma" utilisées pour l'échantillon de données sont résumées tableau 5.33 et concernent les objets électromagnétiques seulement (photons et électrons). Afin de ne considérer que les événements de collisions présentant une qualité suffisante pour les analyses, un filtre supplémentaire de "bonne collision" est appliqué. Ce filtre utilise le déclenchement technique déjà évoqué section 1.2.2 pour éliminer les événements qui ne correspondent pas à une collision. Il est composé d'un OU des deux critères de sélection suivant :

- Les BSC doivent avoir détecté le passage du faisceau. Les coups laissés dans les BSC ne doivent pas correspondre à un événement de collision entre le faisceau et le tube à vide ("beam-halo"). Chacun des deux BSC doit détecter le passage du faisceau dans le même événement.
- Un vertex reconstruit de bonne qualité doit être associé à l'événement à moins de 15 cm selon l'axe du faisceau et à moins de 2 cm du point d'interaction attendu dans le plan transverse. Un filtre supplémentaire demande que le nombre de traces longitudinales dans le trajectographe ayant une impulsion transverse supérieure à  $p_T > 0.25 \text{ GeV}$  ne soit pas plus grand que 10.

Les mêmes filtres et conditions de déclenchement doivent être utilisées dans la simulation. Les échantillons simulés qui ont été utilisés sont listés tableau 6.3, et ont été générés avec Pythia [26]. Le déclenchement "e/gamma" est utilisé pour l'acquisition des données seulement, tandis que le filtre "bonne collision" est appliqué aux données et à la simulation. Afin d'harmoniser les voies de déclenchement, une seule même voie de déclenchement est utilisée dans toute la suite pour les données et la simulation, demandant au moins un photon dans l'événement ayant une impulsion transverse  $p_T > 15 \text{ GeV}$  (HLT\_Photon15\_L1R).

Tous les photons des événements passant la voie de déclenchement HLT\_Photon15\_L1R et le filtre "bonne collision" sont ensuite sélectionnés s'ils satisfont aux critères suivants :

Processus	Sélection générateur	Section efficace (pb)	Nb évènements
QCD dijet	$\hat{p}_T > 15$ GeV	876200000.0	6190500
QCD dijet	$\hat{p}_T > 30$ GeV	60410000.0	5269664
QCD dijet	$\hat{p}_T > 80$ GeV	923800.0	3221800
$\gamma$ +jet	$\hat{p}_T > 15$ GeV	192200.0	1223390
$\gamma$ +jet	$\hat{p}_T > 30$ GeV	20070.0	1026794
$\gamma$ +jet	$\hat{p}_T > 80$ GeV	556.5	1287711

FIG. 6.3 – Sections efficaces au LO à 7 TeV dans le centre de masse, pour le signal et les bruits de fond utilisés.

- Le super-cluster du photon reconstruit doit avoir une énergie transverse non corrigée  $E_T > 2$  GeV et être situé dans la région de pseudo-rapacité  $|\eta| < 2.5$ . Les super-clusters compris dans la région de transition entre le tonneau et les bouchons  $1.4442 < |\eta| < 1.566$  ne sont pas considérés.
- Pour supprimer les “spikes”, le critère  $S4/S9 - 1 > 0.95$  est appliqué. Un critère supplémentaire de synchronisation en temps est appliqué pour éliminer les “spikes” qui passent cette coupure.
- L'énergie transverse du photon doit être supérieure à 15 GeV.
- Des critères d'isolation sévères sont ensuite appliqués pour l'identification des photons. L'énergie d'isolation dans un cône  $\Delta R < 0.3$  autour du photon doit être inférieure à 4 GeV dans le ECAL, 2 GeV dans le HCAL et 2 GeV dans le trajectrographe. Le rapport  $H/E$  doit aussi être inférieur à 0,05.

### 6.2.2 Discrimination $\gamma/\pi^0$ pour le canal $\gamma+X$

Pour cette analyse, seul le réseau de neurones portant sur les variables de forme du cluster est utilisé, parce qu'il est celui dont les variables d'entrée offrent le meilleur accord entre les données et la simulation. L'entraînement a été effectué sur la moitié de l'échantillon QCD dijet  $\hat{p}_T > 15$  GeV pour le bruit de fond et  $\gamma$ +jet  $\hat{p}_T > 15$  GeV pour le signal (l'autre moitié est réservée à l'application). Les photons partoniques de  $\gamma$ +jet ont été utilisés comme signal, et les photons non ISR/FSR de QCD dijet ont été utilisés comme bruit de fond. Les mêmes variables de forme du cluster décrites section 5.2 ont été utilisées pour l'entraînement du réseau de neurone. Le seuil en impulsion transverse des photons a toutefois été abaissé à  $p_T > 15$  GeV pour permettre de calculer la pureté dans une plus grande plage de  $p_T$ . Les mêmes critères d'isolation  $EcalIso < 4$  GeV et  $HcalIso < 2$  GeV ont été appliqués pour l'entraînement afin de disposer d'une statistique suffisante dans l'échantillon de bruit de fond.

La sortie du réseau de neurones va être utilisée dans la suite comme variable “template”. Au moment de l'application du réseau de neurone, les photons partoniques ou ISR/FSR de QCD dijet et  $\gamma$ +jet sont définis comme signal, et tous les autres photons comme bruit de fond. Il peut y avoir plus d'un photon sélectionné par évènement. On applique les critères de sélection supplémentaires  $TrackerIso < 2$  GeV et  $H/E < 0.05$  pour obtenir une pureté acceptable du signal recherché. On cherche à calculer la pureté dans les plages d'impulsions transverses suivantes :  $15 < p_T < 20$  GeV,  $20 < p_T < 30$  GeV,  $30 < p_T < 50$  GeV,  $50 < p_T < 80$  GeV et  $80 < p_T < 120$  GeV. Les sorties du réseau de neurones pour les données, le signal et le bruit de fond dans chacune plages d'impulsions sont montrées figure 6.4 dans le tonneau et 6.5 dans les bouchons. Les valeurs inférieures à -1 et supérieures à 1 proviennent du fait que l'entraînement du réseau de neurones n'a pas été effectué sur le même lot d'évènements que l'échantillon d'application (si on avait utilisé une statistique beaucoup plus grande pour l'entraînement, ceci ne devrait plus être le cas). En raison de la statistique limitée des échantillons, nous avons choisi d'adapter les échantillons de simulation utilisés à la plage en  $p_T$  des photons. Pour les plages  $15 < p_T < 20$  GeV et  $20 < p_T < 30$  GeV les échantillons avec  $\hat{p}_T > 15$  GeV ont été utilisés ; pour les plages  $30 < p_T < 50$  GeV,  $50 < p_T < 80$  GeV les échantillons avec  $\hat{p}_T > 30$  GeV ; pour la dernière plage,  $80 < p_T < 120$  GeV les échantillons ayant  $\hat{p}_T > 80$  GeV (il aurait fallu élever légèrement le seuil en  $p_T$  des photons pour chaque plage afin d'éviter l'éventuel biais du à la coupure en  $\hat{p}_T$ ).



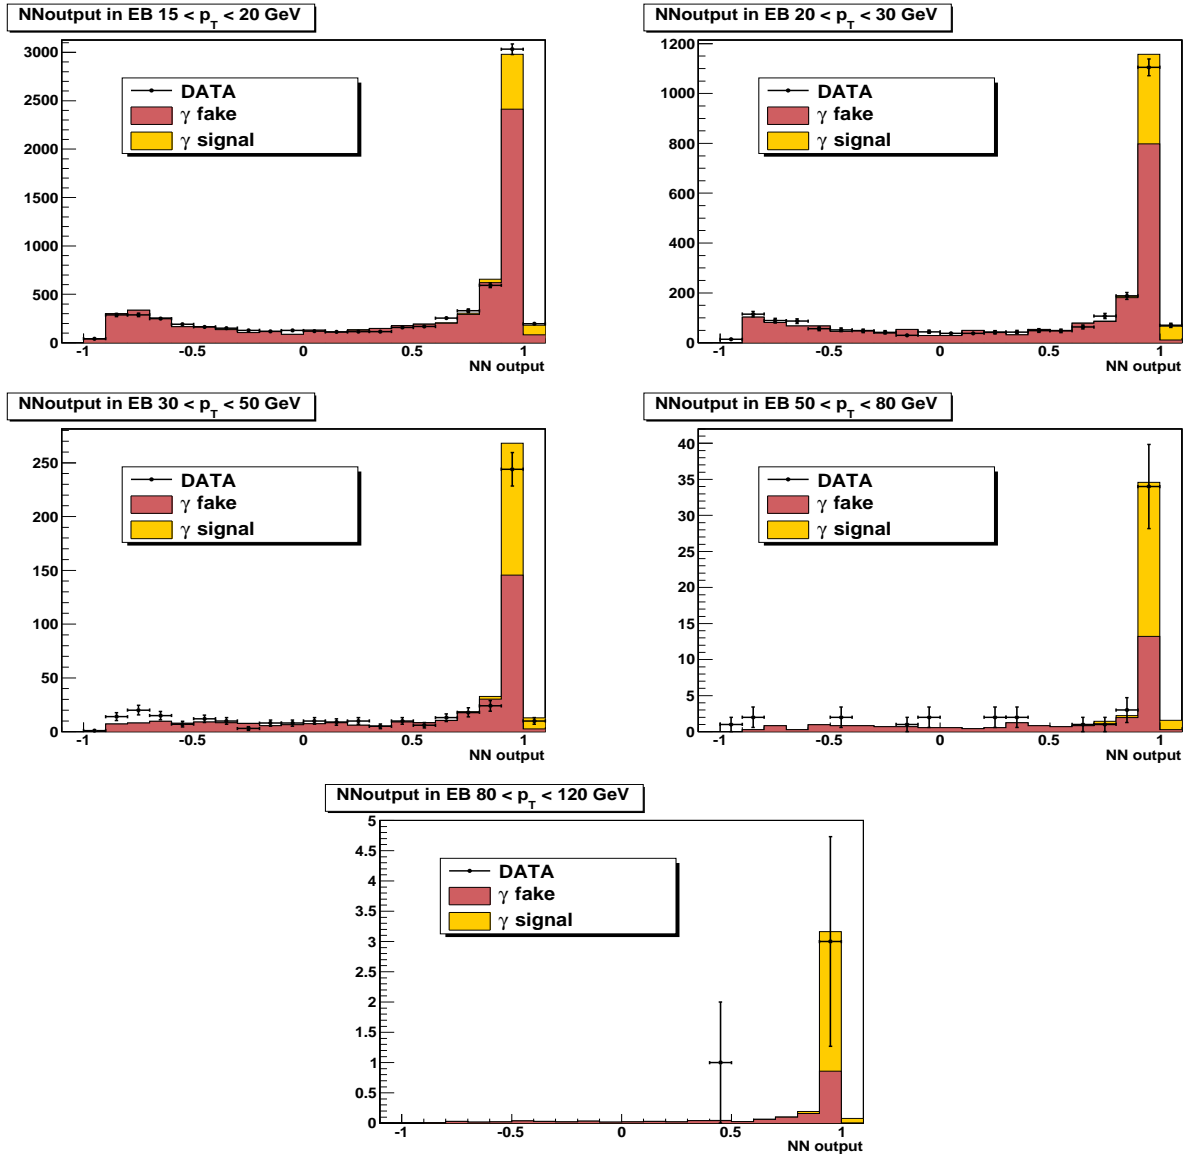


FIG. 6.4 – Sortie du réseau de neurone pour différentes plages d’impulsion transverse dans le tonneau, dans les données et la simulation.

### 6.2.3 Méthode “2 bins”

La méthode “2 bins” (ou deux divisions) est la plus simple des méthodes de templates. Dans un premier temps un lot de  $N$  photons dans les données est présélectionné, qui est composé d’un nombre a priori inconnu de  $N_S$  photons de signal et  $N_B$  photons de bruit de fond. Un critère de sélection est appliqué sur la variable template pour ce lot total de photons avec une efficacité  $\epsilon_{data}$  par rapport à la présélection. Ce faisant, une hypothèse est alors effectuée, qui consiste à considérer que l’efficacité de cette coupure dans les données pour le signal  $\epsilon_S$  et pour le bruit  $\epsilon_B$  sont égales aux efficacités de cette même coupure pour des échantillons de signal et bruit de fond pour la simulation, ce qui se résume par les deux équations suivantes :

$$N = N_S + N_B$$

$$\epsilon_{data}N = \epsilon_{S,MC}N_S + \epsilon_{B,MC}N_B$$

Où  $\epsilon_{S,MC}$  et  $\epsilon_{B,MC}$  sont les efficacités de la coupure dans la simulation du signal et du bruit de fond. A partir de ces deux équations, la pureté *pur* du signal *avant coupure* peut être évaluée par la formule

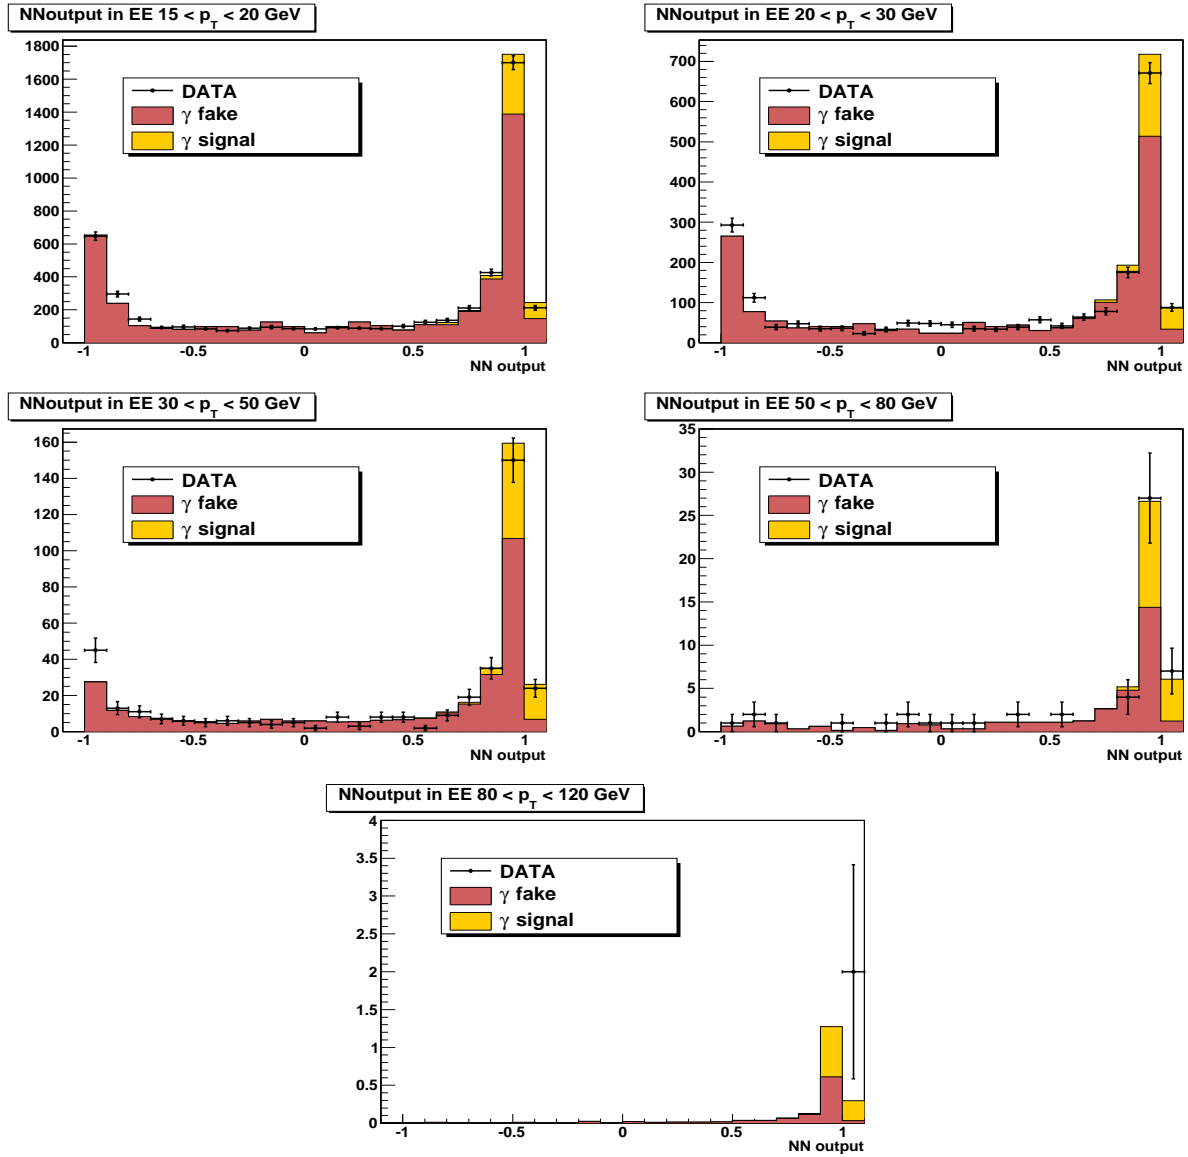


FIG. 6.5 – Sortie du réseau de neurone pour différentes plages d'impulsion transverse dans les bouchons, dans les données et la simulation.

suivante :

$$pur = \frac{N_S}{N} = \frac{\epsilon_{data} - \epsilon_{B,MC}}{\epsilon_{S,MC} - \epsilon_{B,MC}}$$

Le nombre de photons du signal avant coupure vaut alors :

$$N_S = pur * N$$

Et le nombre d'évènements de signal après coupure vaut :

$$\epsilon_{S,MC} N_S = \epsilon_{S,MC} * pur * N$$

Cette méthode a l'avantage d'être simple. Les seules suppositions effectuées concernent l'efficacité du signal et du bruit de fond pour un critère de sélection donné sur la variable de template. Dans un premier temps, on peut faire confiance à la simulation pour calculer les efficacités, mais dans un deuxième temps, il est important de vérifier ces efficacités du signal et des bruits de fond à partir des données. Plusieurs méthodes seront proposées en ce sens.

### 6.2.4 Méthode d’ajustement par maximum de vraisemblance

Au contraire de la méthode “2 bins”, la méthode d’ajustement par maximum de vraisemblance tient compte de toute la forme des distributions templates. Cette technique consiste à ajuster la distribution template dans les données avec les distributions templates simulées du signal et du bruit de fond. Pour réaliser cette opération, la classe “TFractionFitter” de ROOT [28] est utilisée. L’ajustement est réalisé en effectuant une maximisation de la fonction de vraisemblance (avec la pureté comme paramètre libre) entre les données et la simulation qui tient compte des incertitudes sur chacune des distributions d’entrée [162]. En sortie est fournie la pureté résultant de l’ajustement ainsi que son incertitude. Toutefois, si l’estimation de la pureté fournie en sortie est correcte, TFractionFitter renvoie une valeur incorrecte (surestimée) de l’incertitude sur la pureté [163].

### 6.2.5 Mesure de la pureté et du nombre de photons de signal inclusifs

Pour chaque plage d’impulsion transverse des photons, la méthode “2-bins” et la méthode d’ajustement par maximum de vraisemblance sont appliqués à la distribution des données. Pour la méthode 2-bins, la coupure choisie sur la variable template  $NN_{output}$  est  $NN_{output} > 0.9$  (qui rassemble la majeure partie du signal). Pour la méthode par ajustement du maximum de vraisemblance, les distributions templates sont considérées dans la plage  $-1.1 < NN_{output} < 1.1$  avec 22 divisions de 0,1. Ces choix ne sont pas pleinement optimisés mais sont plutôt des choix naturels si l’on considère la statistique disponible, sélectionnés dans un souci de simplicité.

#### Sortie du réseau de neurone comme outil d’identification des photons

Le critère de sélection  $NN_{output} > 0.9$  peut être vu comme un critère supplémentaire d’identification des photons, qui vient s’ajouter aux critères d’isolation déjà demandés. L’efficacité de ce critère de sélection par rapport à la préselection pour les photons du signal en fonction de leur impulsion transverse et pseudo-rapidité est montrée figure 6.6. L’efficacité est supérieure à 94% dans le tonneau, et supérieure à 82% dans les bouchons. L’efficacité augmente avec l’impulsion transverse (jusqu’à 97-98% pour des photons de plus de 80 GeV) et subit une baisse au niveau de la transition tonneau-bouchon.

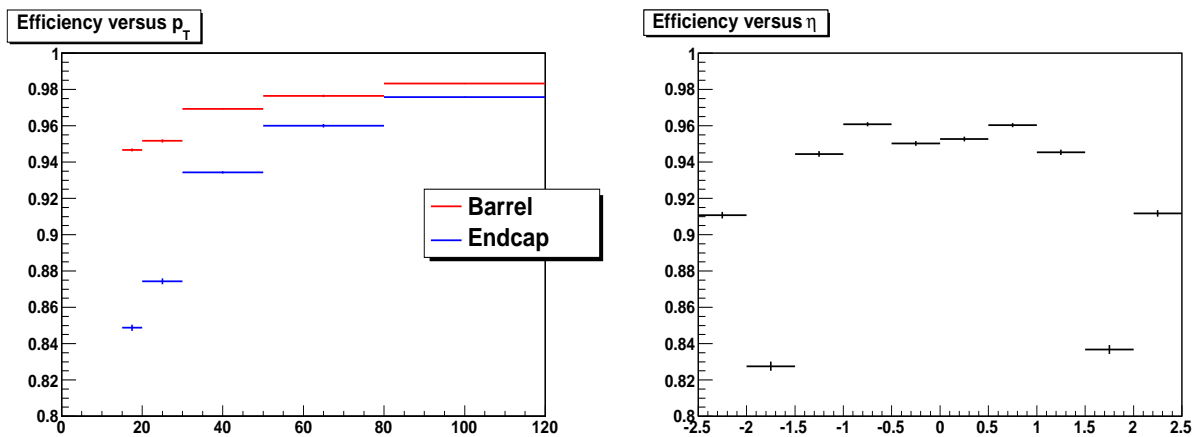


FIG. 6.6 – Efficacité de la coupure sur la sortie du réseau de neurone par rapport à la préselection pour les photons du signal, en fonction de l’impulsion transverse des photons (à gauche) et de leur pseudo-rapidité (à droite).

#### Application de la méthode des templates aux échantillons simulés

Avant de mesurer la pureté des photons du signal à partir des données, nous allons tester la méthode des templates à partir des échantillons simulés uniquement. Le but de cet exercice est de montrer que les résultats donnés par la méthode des templates dans la simulation sont en accord avec les résultats

utilisant l'information générateur. Tous les échantillons sont préalablement divisés en deux, la première moitié étant utilisée pour construire un échantillon de "données" simulées et la deuxième pour construire les distributions templates du signal et du bruit de fond. Dans le cas des deux premières divisions ( $15 < p_T < 20$  GeV et  $20 < p_T < 30$  GeV), la première moitié des échantillons  $\gamma$ +jet et QCD  $p_T > 15$  GeV a déjà été utilisés pour l'entraînement du réseau de neurone; la division en "données" et "templates" est alors effectuée sur la deuxième moitié seulement.

La pureté (figure 6.7) et le nombre d'évènements de signal (figure 6.8) obtenus avec les échantillons simulés donnent globalement un accord satisfaisant entre les prédictions et les résultats obtenus par la méthode 2-bins et d'ajustement. Seuls les deux premières divisions ( $15 < p_T < 30$  GeV) donnent un résultat différent, en raison des fluctuations statistiques induites par le plus petit nombre d'évènements disponibles.




FIG. 6.7 – Pureté prédite par la simulation (en rouge) et calculée dans la simulation par la méthode 2-bins (en bleu) et par la méthode d'ajustement du maximum de vraisemblance (en vert), en fonction de l'impulsion transverse des photons, dans le tonneau (à gauche) et les bouchons (à droite). Seules les incertitudes statistiques sont montrées.




FIG. 6.8 – Nombre de photons de signal prédit par la simulation (en rouge) et calculé dans la simulation par la méthode 2-bins (en bleu) et par la méthode d'ajustement du maximum de vraisemblance (en vert), en fonction de l'impulsion transverse des photons, dans le tonneau (à gauche) et les bouchons (à droite). Seules les incertitudes statistiques sont montrées.

### Application de la méthode des templates aux données

Les puretés obtenues dans les données avec la méthode 2-bins et avec la méthode d’ajustement du maximum de vraisemblance sont comparées avec la pureté obtenue par la simulation figure 6.10, dans le tonneau et les bouchons. On montre figure 6.9 pour l’exemple les résultats de l’ajustement pour une plage de masse,  $20 < p_T < 30$  GeV. Quelle que soit la méthode considérée ( $y$  compris dans la simulation), la pureté obtenue est plus grande dans le tonneau que dans les bouchons. L’incertitude statistique augmente avec l’impulsion transverse (car le nombre d’évènements dans les données diminue drastiquement). La pureté du signal augmente aussi avec l’impulsion transverse des photons : plus un photon reconstruit est dur dans les données, plus la probabilité est grande qu’il s’agisse d’un photon de signal.

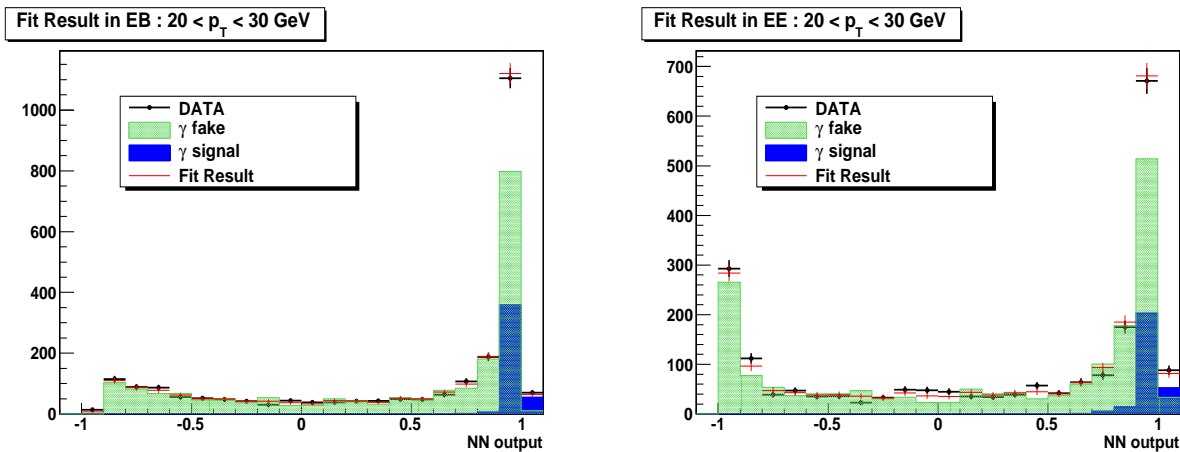


FIG. 6.9 – Résultats de l’ajustement par maximum de vraisemblance entre les données et les distributions templates dans la plage de masse  $20 < p_T < 30$  GeV dans le tonneau (à gauche) et dans les bouchons (à droite). Signal et bruit de fond ne sont pas superposés.

Comme attendu, les incertitudes calculées par la méthode d’ajustement semblent surestimées (elles sont plus grandes que les incertitudes 2-bins). On montre seulement la pureté prédite par la simulation dans la dernière plage d’impulsion transverse  $80 < p_T < 120$  GeV dans les bouchons, car l’ajustement n’a pas convergé et la méthode 2-bins renvoie une valeur supérieure à 1. Ceci peut s’expliquer par la localisation des photons dans les données en fonction de la sortie du réseau de neurones (voir figure 6.5) : il n’y a que deux entrées et elles sont situées dans la dernière division tandis que la simulation les attendrait plutôt dans l’avant-dernière division. Cette configuration semble peu probable, donc l’algorithme d’ajustement ne converge pas.

Il est intéressant de noter le désaccord entre les méthodes templates de détermination de la pureté dans les données par rapport aux prédictions de la simulation, tandis que les méthodes templates entre elles donnent un résultat comparable. Ceci est dû au fait que les contributions aux ordres supérieurs n’ont pas été prises en compte dans la simulation. Aucune repondération n’a été effectuée (pas même pour la détermination d’un “K-facteur” inclusif). Le nombre d’évènements relatifs entre le signal et le bruit de fond ainsi que les efficacités du signal et du bruit de fond peuvent être différentes aux ordres supérieurs.

Le nombre de photons de signal est déduit en multipliant simplement la pureté du signal par le nombre de photons dans les données (voir figure 6.11). Dans le tonneau, le nombre d’évènements de signal obtenu par simulation est systématiquement au-dessus du nombre mesuré pour  $p_T > 20$  GeV et en-dessous pour  $15 < p_T < 20$  GeV. Dans les bouchons, un comportement inverse est trouvé : les prédictions sont au-dessus des mesures pour  $p_T < 50$  GeV et en-dessous pour  $p_T > 50$  GeV. Les nombres présentés ici sont encore non-corrigés : il s’agit du nombre de photons de signal mesuré dans les données, sans avoir corrigé pour les inefficacités de détection (ce qui aurait donné le nombre de photons de signal produits dans les collisions, avant leur entrée dans le détecteur).

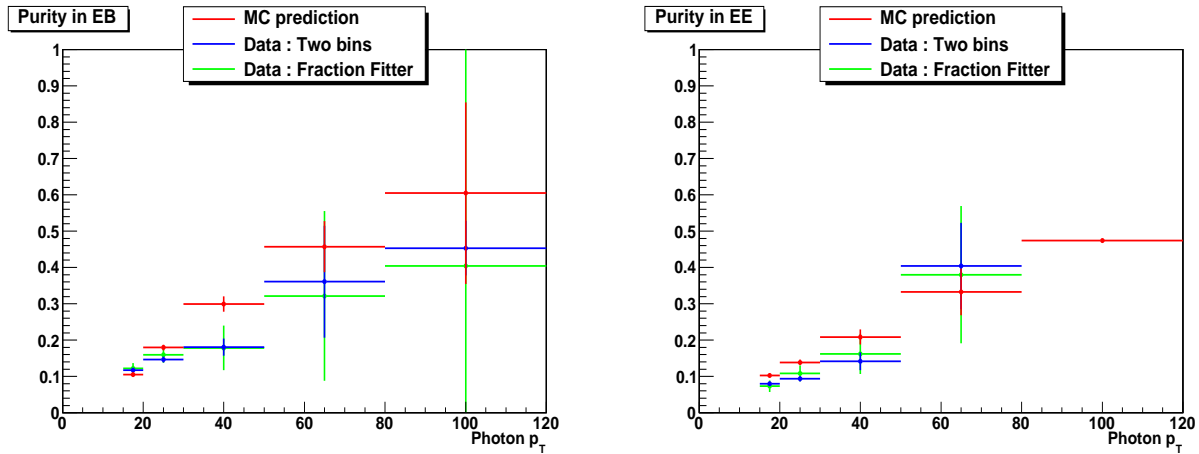


FIG. 6.10 – Pureté prédite par la simulation (en rouge) et calculée dans les données par la méthode 2-bins (en bleu) et par la méthode d’ajustement du maximum de vraisemblance (en vert), en fonction de l’impulsion transverse des photons, dans le tonneau (à gauche) et les bouchons (à droite). Seules les incertitudes statistiques sont montrées.

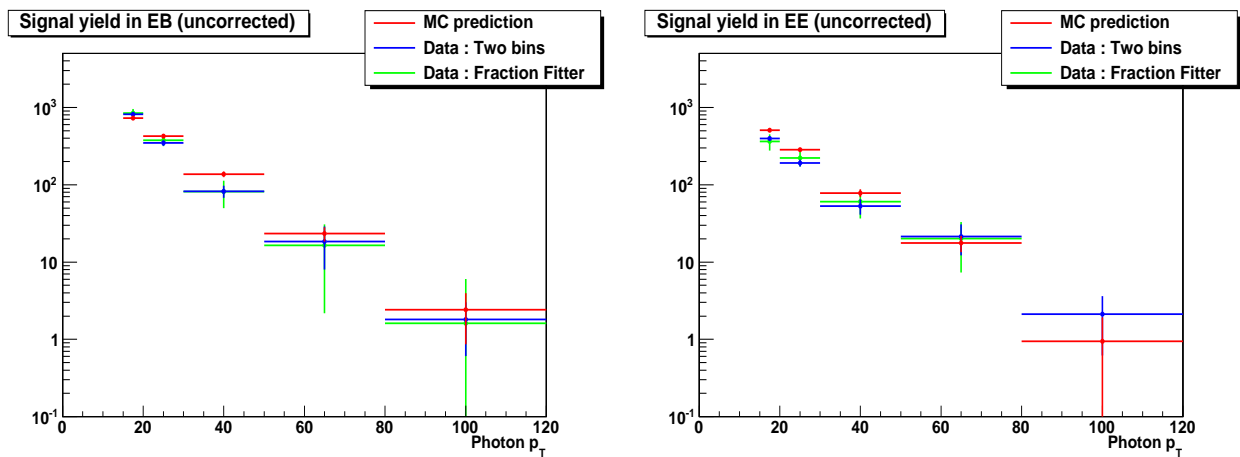


FIG. 6.11 – Nombre de photons de signal prédit par la simulation (en rouge) et calculé dans les données par la méthode 2-bins (en bleu) et par la méthode d’ajustement du maximum de vraisemblance (en vert), en fonction de l’impulsion transverse des photons, dans le tonneau (à gauche) et les bouchons (à droite). Seules les incertitudes statistiques sont montrées.

### 6.2.6 Construction d’une distribution template à partir des données pour le bruit de fond

Afin de vérifier les résultats obtenus pour la pureté et le nombre d’évènements de signal, nous aimerions pouvoir construire les distributions templates du signal et du bruit de fond à partir des données. L’écart entre les distributions templates simulées et les distributions templates construites à partir des données pourrait donner une estimation de l’erreur systématique introduite par la simulation. En ce qui concerne le signal il est difficile, pour le moment, de construire une distribution templates à partir des données, puisque nous ne disposons pas encore d’un échantillon de signal pur (ce qui sera possible dès quelques centaines de  $pb^{-1}$  avec les photons certifiés de  $Z \rightarrow l\bar{l}\gamma$ ). Pour le bruit de fond, nous proposerons deux techniques : la première consiste à sélectionner les photons dans les bandes de côtés de la distribution d’isolation, tandis que la deuxième méthode utilise la cinématique du processus  $\gamma$ +jet.

Les critères d'isolation que nous demandions jusqu'ici sont les suivants :  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV,  $TrackerIso < 2$  GeV et  $H/E < 0.05$ . L'inversion d'un de ces critères d'isolation devrait fournir un lot de photons principalement issus du bruit de fond, mais dans le but de conserver une distribution template du bruit de fond semblable à celle prédite par la simulation, tous ces critères ne peuvent pas être utilisés, car certains conduisent à des distributions trop différentes en forme. Nous avons trouvé que le meilleur critère à inverser pour cette application est l'énergie d'isolation dans le trajectographe  $TrackerIso < 2$  GeV. Toutefois, il n'est pas possible de sélectionner seulement tous les photons ayant  $TrackerIso > 2$  GeV car la plupart de ces photons seront non-isolés et une différence de forme subsistera. Nous avons essayé les bandes de côté  $2 < TrackerIso < 5$  GeV et  $2 < TrackerIso < 3$  GeV. La comparaison des formes des distributions d'isolation inversée dans les données par rapport à la distribution de bruit de fond simulé peut être trouvée figure 6.12 pour la plage  $15 < p_T < 20$  GeV dans le tonneau.

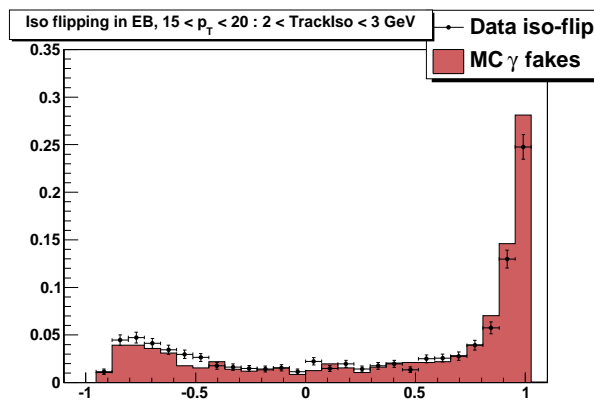


FIG. 6.12 – Distribution simulée des photons du bruit de fond et des photons des données dans les bandes de côté  $2 < TrackerIso < 3$  GeV. Les distributions sont normalisées à 1.

L'accord entre bandes de côté dans les données et simulation du bruit de fond est raisonnable dans la queue de la distribution mais est en désaccord pour lorsque la sortie du réseau de neurones tend vers 1. Les deux méthodes de templates, 2-bins et ajustement, ont été essayées avec la template simulée pour le signal et la template prise dans les bandes de côté d'isolation des données pour le bruit de fond. La méthode d'ajustement n'a convergé pour aucune plage d'impulsion transverse, tandis que la méthode 2-bins donne un résultat partout sauf pour la plage  $80 < p_T < 120$  GeV, où le manque de statistique empêche de construire une template convenable à partir des données. Les résultats, en terme de nombre de pureté et de nombre d'évènements de signal mesuré sont montrés figure 6.13 et 6.14. La distribution template du bruit de fond prise dans les données conduit presque systématiquement à une surestimation de la pureté, ce qui s'explique par le fait que le pic à 1 est réduit dans la distribution template de bande de côté des données par rapport à la distribution simulée : la méthode 2-bins en déduit la présence de plus de photons de signal qu'il ne devrait. La seule plage où le résultat obtenu est comparable aux autres techniques est  $20 < p_T < 30$  GeV dans le tonneau. En conclusion, il semble difficile d'utiliser une telle technique pour construire la distribution template du bruit de fond. Il faudrait aussi vérifier qu'il est possible d'utiliser cette méthode en l'appliquant à la simulation seule.

### 6.2.7 Incertitudes systématiques

La mesure de la pureté et du nombre d'évènements de signal du processus  $\gamma+X$  avec le réseau de neurones de discrimination  $\gamma/\pi^0$  est soumise à des incertitudes systématiques théoriques et expérimentales que nous allons discuter dans ce paragraphe. D'une manière générale, évaluer une incertitude systématique due à certains paramètres peut s'effectuer en faisant varier les paramètres en question et en répétant la mesure. L'écart entre les mesures obtenues quantifie l'incertitude systématique pour ce paramètre.

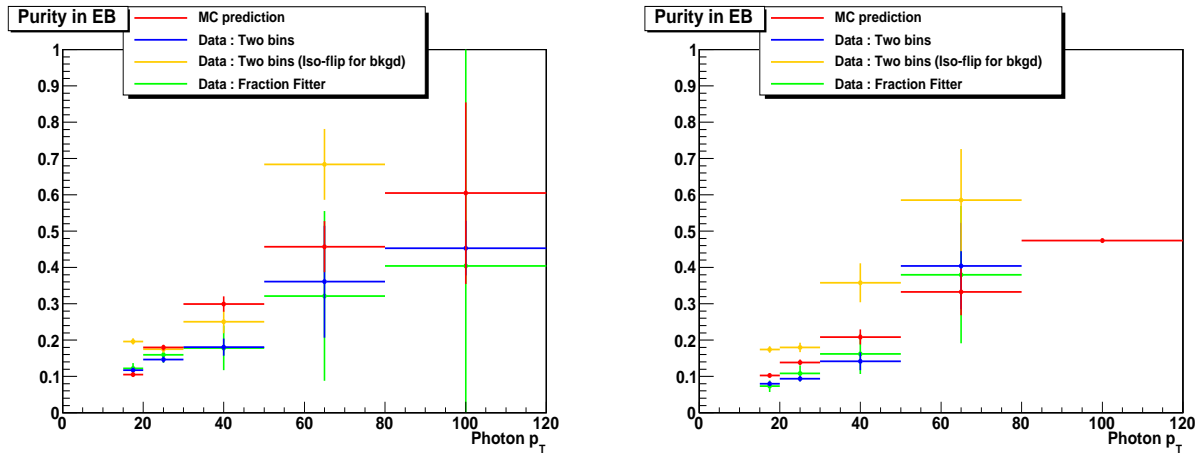


FIG. 6.13 – Pureté prédite par la simulation (en rouge), calculée dans les données par la méthode 2-bins avec les templates simulées (en bleu) et avec la template de bande de côté d’isolation pour le bruit de fond (en orange) et par la méthode d’ajustement du maximum de vraisemblance (en vert), en fonction de l’impulsion transverse des photons, dans le tonneau (à gauche) et les bouchons (à droite). Seules les incertitudes statistiques sont montrées.




FIG. 6.14 – Nombre de photons de signal prédit par la simulation (en rouge) et calculé dans les données par la méthode 2-bins avec les templates simulées (en bleu) et avec la template de bande de côté d’isolation pour le bruit de fond (en orange) et par la méthode d’ajustement du maximum de vraisemblance (en vert), en fonction de l’impulsion transverse des photons, dans le tonneau (à gauche) et les bouchons (à droite). Seules les incertitudes statistiques sont montrées.

### Incertitudes théoriques

- Incertitude dues à l’échelle d’énergie et aux densités partoniques sur les sections efficaces différentielles, tant pour le générateur à gerbe partonique utilisé pour la construction des templates que pour le générateur à élément de matrice NLO utilisé pour les prédictions théoriques. La première peut être évaluée en calculant la section efficace en divisant et multipliant par deux les échelles d’énergie (factorisation, renormalisation et fragmentation). La deuxième peut être évaluée en remplaçant l’ensemble de densité partoniques utilisé par un autre.
- Incertitude du modèle d’évènement sous-jacent, des radiations ISR/FSR, et de l’hadronisation, pour le générateur à gerbe partonique. Le modèle de l’évènement sous-jacent joue surtout sur l’efficacité d’isolation dans le critère d’identification des photons (voir plus loin). Pour ces trois modèles, les incertitudes systématiques peuvent être évaluées en répétant l’analyse en variant les paramètres dans le générateur à gerbe partonique.



### Incertitudes expérimentales

- Incertitude sur la **luminosité** : 15%, estimé au démarrage pour environ  $10 \text{ nb}^{-1}$  de luminosité intégrée.
- Incertitude sur les **distributions templates**, provenant de l'incertitude systématique sur la forme du dépôt d'énergie entre données et simulation. Un premier aspect concerne les distributions templates pour le signal. Pour quantifier l'incertitude, il est possible de remplacer les templates de photons partoniques ou ISR/FSR avec les templates construites avec ISR/FSR ou photons partoniques seuls (obtenues par la simulation). Pour le bruit de fond, il y a possibilité d'utiliser les bandes de côté d'une distribution pour enrichir les données en bruit de fond ; nous avons essayé l'inversion de l'isolation trajectographique, qui n'a pas donné de résultat. Une autre possibilité consiste à sélectionner des photons de bruit de fond grâce à la cinématique du processus  $\gamma+\text{jet}$  (utilisables aussi pour réduire l'incertitude systématique sur l'entraînement du réseau de neurones, voir section 6.3), mais il faudrait alors répéter l'analyse en entraînant le réseau de neurones sur des photons non isolés. De même lorsque suffisamment de luminosité sera disponible, les photons du signal de  $Z \rightarrow l\gamma$  pourront être utilisés.
- Incertitudes sur les **efficacités de détection** : déclenchement, de filtre "bonne collision". L'efficacité du filtre bonne collision est connue et proche de 100% pour des événements où au moins un photon est reconstruit, et l'incertitude peut être négligée. L'efficacité de déclenchement HLT est mesurée séparément.
- Incertitude du critère d'**identification des photons**. Un moyen de les évaluer consiste à faire varier de 5% chacun des critères d'isolation, et de quantifier les effets de cette variation sur la section efficace mesurée.
- Incertitude sur le **budget matériel** : la quantité de matière en amont du ECAL influe sur la proportion de photons qui convertissent dans le trajectographe. Ceci peut affecter les distributions templates et peut être évalué en variant la quantité de matière dans la simulation GEANT4.
- Incertitude sur l'**échelle d'énergie des photons**. Aujourd'hui, l'énergie des photons reconstruits n'est pas corrigée par un facteur absolu, même si les premières mesures de ce facteur ont été effectuées. Ce facteur a été mesuré à partir du processus  $W \rightarrow e\nu$  pour les électrons, et le sera pour les photons avec le processus  $Z \rightarrow l\gamma$ . Pour le moment, il est possible de mesurer l'incertitude associée en quantifiant l'écart des résultats des mesures avec et sans corrections. Dans le futur, la correction sera appliquée et l'incertitude évaluée à partir du processus utilisé pour la calculer.

## 6.3 Entraînement du réseau de neurones avec les jets de $\gamma+\text{jet}$

### 6.3.1 Sélection d'un lot de photons mal identifiés dans les données : principe

Le processus  $\gamma+\text{jet}$  offre la possibilité d'entraîner le réseau de neurones de discrimination  $\gamma/\pi^0$  à partir des données. A l'arbre, le photon et le jet émis lors de l'interaction dure sont exactement dos-à-dos dans le plan transverse. Les corrections dues aux boucles virtuelles donnent encore lieu à une telle cinématique. L'émission d'un jet supplémentaire (due aux corrections réelles) contraint le photon et le premier jet à dévier de cette géométrie (par conservation de l'impulsion). La déviation est d'autant plus grande que l'impulsion du deuxième jet (et des jets suivants aux ordres supérieurs) est grande. La majorité des événements peut donc être considérée comme ayant un photon et un jet approximativement dos-à-dos dans le plan transverse.

Il est possible d'utiliser cette propriété pour sélectionner un lot de jets purs donnant lieu à la reconstruction de photons provenant des jets. L'idée est la suivante : on peut marquer le photon de plus haute impulsion transverse (qui est en général le photon direct de  $\gamma+\text{jet}$ ) par des critères d'identification (typiquement des critères d'isolation) et sélectionner le photon qui lui est opposé dans l'événement. Ce second photon devrait être un photon de bruit de fond issu d'un jet (car la section efficace du processus  $\gamma\gamma+X$  est trois ordres de grandeur plus petite que la section efficace  $\gamma+\text{jet}$ ). En réalité, les données (avec une suffisamment basse luminosité) contiennent un mélange de photons mal identifiés de QCD (auquel cas la technique proposée sélectionnera systématiquement un photon de bruit de fond) et, avec une section efficace supprimée de plusieurs ordres de grandeur, des photons issus de  $\gamma+\text{jet}$ . Dans ce dernier cas, la méthode proposée protège contre la sélection d'un photon de signal. Toutefois, il reste possible que le photon sélectionné soit en fait un photon ISR ou FSR, ou même le photon direct de  $\gamma+\text{jet}$  qui aurait une

impulsion transverse moins grande que celle du jet opposé. Dans tous les cas, la sélection de ce lot de photons (attendus comme principalement des photons du bruit de fond) devrait permettre l'entraînement du réseau de neurones à partir des données pour le bruit de fond. La comparaison des performances après entraînement avec ce lot de photons et après entraînement avec les photons de signal de la simulation devrait permettre d'estimer l'incertitude systématique liée à l'utilisation du réseau de neurones, une fois vérifié que la pureté du lot de photons des données est acceptable.

### 6.3.2 La sélection

La sélection d'un lot de photons mal identifiés dans les données est opérée en plusieurs étapes :

- La même préselection consistant en un filtre de "bonnes collisions", en pseudo-rapacité, élimination des "spikes" que précédemment est effectuée dans les données. On ne demande pas de voie de déclenchement spécifique pour des raisons de statistique.
- Deux photons ayant une impulsion transverse  $p_T > 10$  GeV sont demandés par événement. Le deuxième photon de plus grande énergie transverse doit avoir un écart  $|\Delta\phi| > 2\pi/3$  par rapport au photon de plus grande énergie transverse (géométrie dos-à-dos).
- Entre les deux photons, le photon ayant l'énergie transverse d'isolation  $EcalIso + HcalIso$  la plus petite dans un cône  $\Delta R < 0.3$  autour du photon est marqué comme étant potentiellement le photon prompt de  $\gamma$ +jet, si  $EcalIso < 4$  GeV et  $HcalIso < 2$  GeV.
- Le deuxième photon (le moins isolé) est alors sélectionné si il est proche d'un jet :  $\Delta R(\gamma, jet) < 0.1$ .

En fin de sélection, 4383 photons de bruit de fond ont été sélectionnés (contre environ la moitié si on avait systématiquement isolé le photon de plus haut  $p_T$  et sélectionné le deuxième photon de plus haut  $p_T$ ). Toute la statistique disponible ( $10,24 \text{ nb}^{-1}$ ) a été utilisée.

### 6.3.3 Entraînement et test du réseau de neurones

Les performances et les sorties du réseau de neurones ont été comparées dans deux cas :

- Le réseau de neurones est entraîné et testé sur des échantillons seulement simulés, avec pour signal les photons partoniques de  $\gamma$ +jet et pour bruit de fond les photons non ISR/FSR de QCD dijet. Les photons doivent satisfaire  $p_T > 15$  GeV et  $H/E < 0.05$ . L'entraînement et l'application sont effectués chacun sur une moitié des échantillons initiaux (voire figure 6.15).
- Le réseau de neurone est entraîné sur les photons partoniques de la première moitié de l'échantillon  $\gamma$ +jet comme signal, et les photons de bruit de fond sélectionnés dans les données, avec les mêmes critères  $p_T > 15$  GeV et  $H/E < 0.05$ . Le réseau de neurone est ensuite testé sur l'autre moitié des photons partoniques de  $\gamma$ +jet comme signal et sur les photons non ISR/FSR de l'échantillon de QCD dijet comme bruit de fond (voir figure 6.16).

Les sorties du réseau de neurones ont une forme assez proches dans les deux cas, mais quelques différences subsistent, notamment le bruit de fond pique moins à -1 et plus à 1 dans l'entraînement à partir des données. Ceci peut provenir du manque de statistique dans les données pour permettre un entraînement acceptable, ou plus probablement du fait que l'échantillon de photon sélectionné dans les données peut être contaminé par des photons de signal. En effet figure 6.16 gauche la sortie du réseau de neurone pour le bruit de fond, présente nombre de photons qui pique à 1 légèrement plus grand dans l'échantillon d'entraînement (pris dans les données) que dans l'échantillon test (simulé). Toutefois, l'échantillon d'entraînement pris dans les données et l'échantillon de test simulé donnent approximativement la même réponse du réseau de neurones, de sorte que le rejet du bruit de fond est de 80% pour une efficacité du signal de 90% dans les deux cas - la différence est de moins d'1%. Il faudrait refaire l'étude avec une luminosité intégrée plus grande pour voir si la contamination par des photons du signal finit par dégrader les performances.

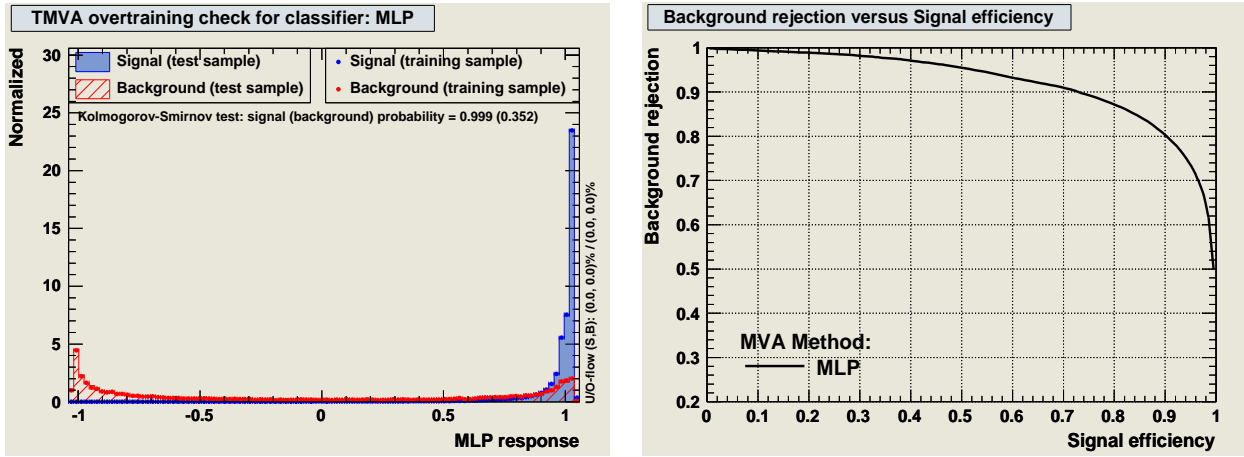


FIG. 6.15 – A gauche, sortie du réseau de neurone pour l'échantillon d'entraînement et de test. A droite, rejection du bruit de fond versus efficacité du signal (simulation seulement).




FIG. 6.16 – A gauche, sortie du réseau de neurone pour l'échantillon d'entraînement et de test. A droite, rejection du bruit de fond versus efficacité du signal (entraînement sur signal simulé et bruit de fond sélectionné à partir des données, test sur les échantillons simulés).

### 6.3.4 Construction de la distribution template du bruit de fond

Nous avons aussi investigué la possibilité d'utiliser les photons de bruit de fond sélectionnés dans les données pour construire une distribution template du réseau de neurones pour le bruit de fond. Pour ce faire, nous avons simplement testé sur les photons sélectionnés dans les données la sortie du réseau de neurone entraîné avec les échantillons simulés. Le résultat, figure 6.17, montre que pour des photons ayant  $p_T > 15$  GeV et  $H/E < 0.05$ , l'accord est globalement bon entre la simulation et les photons sélectionnés dans les données, bien qu'il y ait un léger désaccord vers 1 en raison de la difficulté à sélectionner un lot pur de photons du bruit de fond dans les données. La différence pourrait aussi provenir par exemple de l'ajustement des paramètres de l'évènement sous-jacent dans Pythia. En conclusion, les photons sélectionnés par cette méthode peuvent être utilisés pour la construction d'une distribution template pour le bruit de fond. Dans la mesure où nous avons utilisé toutes les données pour construire la distribution template, nous n'avons pas pu l'utiliser dans la détermination de la pureté et du nombre de photons de signal inclusif. Il faudrait de plus disposer de plus de données pour pouvoir renforcer les critères d'isolation marquant le photon prompt et le photon de bruit de fond.

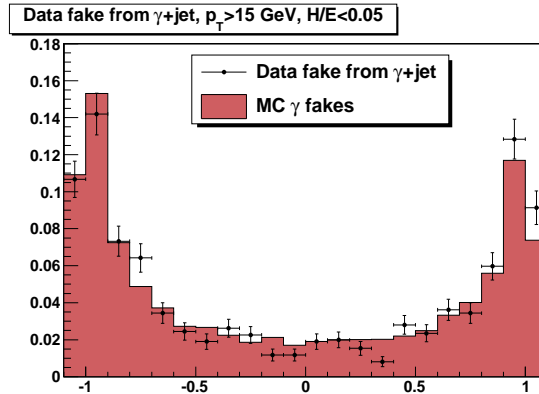


FIG. 6.17 – Distribution simulée des photons du bruit de fond, et des photons de bruit de fond sélectionné dans les données. Les distributions sont normalisées à 1.

## 6.4 Conclusion et perspectives

Le but de ce chapitre était de proposer une première application du réseau de neurone de discrimination  $\gamma/\pi^0$  dans les données. Nous avons montré qu’avec une luminosité intégrée de  $10,24 \text{ nb}^{-1}$  il est possible d’utiliser la sortie du réseau de neurone de forme du cluster comme variable “template” pour mesurer la pureté et le nombre inclusif de photons prompts et isolés dans cinq plages d’impulsion transverse. Les méthode de templates 2-bins et d’ajustement du maximum de vraisemblance ont été essayées et donnent des résultats similaires. Les mesures donnent des résultats différents de la prédiction de la simulation, qui ne prend pas en compte les effets NLO. Le réseau de neurones peut donc être utilisé comme complément aux critères d’identification des photons habituels, avec un pouvoir de discrimination plus grand.

Nous avons aussi essayé plusieurs méthodes pour contrôler les performances du réseau de neurone et sa capacité à être utilisé comme outil de mesure à partir des données. La première méthode consiste à inverser le critère d’isolation dans le trajectographe pour sélectionner un lot de photons enrichi en bruit de fond. L’utilisation de ces photons pour la construction d’une distribution template du bruit de fond donne des résultats en désaccord avec les templates simulés, en raison d’une contamination non négligeable des photons du signal. Ceci pourrait aussi bien être la différence entre données et simulations recherchée. La deuxième méthode consiste à sélectionner un lot de photons enrichi en bruit de fond dans les données à l’aide de la cinématique du processus  $\gamma+\text{jet}$ . L’entraînement du réseau de neurones sur ce lot de photons conduit à une performance et une sortie du réseau de neurone similaire à celles obtenues lors de l’entraînement sur les échantillons simulés seulement. De plus, la construction d’une distribution template du bruit de fond avec ces photons semble donner un meilleur résultat que la méthode d’inversion de l’isolation. Pour le moment, le réseau de neurone entraîné à partir des données et la distribution template associée n’ont pas été appliqués sur les données pour la mesure en raison d’une luminosité intégrée insuffisante. Une autre possibilité plus simple à essayer consisterait à sélectionner directement les photons non isolés dans les données (photons mal identifiés des jets de QCD), sans exclure le photon prompt attendu de  $\gamma+\text{jet}$ . Le photon du jet dos-à-dos avec le photon prompt de  $\gamma+\text{jet}$  est plus souvent un gluon que dans les processus de QCD multi-jets, et ceci peut fausser l’estimation de l’énergie d’isolation du bruit de fond pris dans les données.

Pour compléter ces études, il serait intéressant de considérer une autre mise en oeuvre de la méthode d’ajustement pour le calcul de la pureté des données en photons de signal, car la méthode TFractionFitter donne un résultat correct pour l’estimation de la pureté mais pas de l’erreur associée. Nous faisons donc pour l’instant plus confiance aux erreurs calculées par la méthode 2-bins. Les autres variantes du réseau de neurones (environnement, ainsi que forme du cluster et environnement combinés) devraient être essayées. Lorsque la précision sur la luminosité intégrée sera suffisante, les spectres mesurés corrigés pour les inefficacités de détection pourront être comparés avec les prédictions théoriques. Pour pouvoir comparer les

sections efficaces obtenues avec JetPhox [160], il sera nécessaire de répéter l'analyse en ne sélectionnant que le photons de plus haute impulsion transverse par évènement. Le deuxième photon (ou le photon le plus dos-à-dos avec le premier) pourra alors être utilisé pour l'entraînement du réseau de neurone ou pour construire la distribution template du bruit de fond sans risquer de biaiser l'analyse.

Une autre application intéressante de la méthode des templates dans ce canal consisterait à mesurer le spectre des photons du signal pour les variables d'entrée du réseau de neurone par la méthode des templates. Une façon de mener à bien cette étude serait de considérer chacune des six variables d'entrée une par une, d'entraîner le réseau de neurone avec les cinq autres, et d'appliquer la méthode des templates aux données. La faible luminosité intégrée rend l'opération délicate pour le moment et peu intéressante si elle ne permet de diviser les spectres qu'en cinq bins, mais avec plus de luminosité cela devrait devenir possible.

Enfin, les méthodes développées dans ce chapitre pourraient être appliquées à d'autres processus de production de photon prompts, tels la mesure de la section efficace différentielle exclusive du processus  $\gamma$ +jet, ou la mesure de la pureté des photons de signal dans les processus  $W+\gamma$  ou  $Z+\gamma$ . Nous l'utiliserons aussi chapitre 8 pour la mesure de la section efficace différentielle du processus  $\gamma\gamma+X$ .



## Chapitre 7

# Repondération pour les analyses $\gamma\gamma+X$ et $H \rightarrow \gamma\gamma$

Les générateurs à gerbe partonique utilisés pour la simulation de la plupart des analyses, tels Pythia [26] décrivent les processus durs au LO, tandis que la gerbe partonique est décrite au LL. La mise en oeuvre d'une gerbe partonique garantit la prise en compte des émissions réelles supplémentaires, bien que le spectre de ces émissions soit plus mou que celui décrit par des générateurs à élément de matrice aux ordres supérieurs et que la section efficace soit calculée au LO. Les effets dus aux ordres supérieurs sont généralement pris en compte par l'application d'un "K-facteur" global (inclusif), c'est-à-dire que le poids des événements simulés est multiplié par un facteur  $\sigma_{h.o.}/\sigma_{PS}$  (où  $\sigma_{h.o.}$  est la section efficace aux ordres supérieurs calculée par un générateur à éléments de matrices et  $\sigma_{PS}$  la section efficace calculée par le générateur à gerbe partonique).

Les deux grandes classes d'analyses expérimentales, les mesures de précision et la recherche de nouvelles particules, ont un rapport différent avec la prise en compte des effets dus aux ordres supérieurs. Dans le cas de la recherche (comme la recherche du boson de Higgs), pour prédire au mieux les spectres des observables il est nécessaire de tenir compte des effets dus aux ordres supérieurs tant pour le signal que pour le bruit de fond. Un "K-facteur" inclusif comme décrit précédemment peut alors suffire en première approche. Pour reproduire au mieux les distributions aux ordres supérieurs avec les événements simulés par les générateurs à gerbe partonique, une repondération à l'aide d'un K-facteur dépendant d'une ou plusieurs variables cinématiques serait plus appropriée, lorsque aucun générateur à gerbe partonique NLO n'est disponible pour le processus considéré. Dans le cas d'une mesure (par exemple la mesure de la section efficace différentielle du processus  $\gamma+X$  ou  $\gamma\gamma+X$ ), il est possible de prendre en compte directement dans l'analyse les effets dus aux ordres supérieurs par le moyen de la repondération, pour avoir la prédiction théorique la plus précise possible à utiliser pour la construction des distributions "templates" et la mesure du nombre d'événements de signal. Usuellement les nombres d'événements de signal mesurés sont ensuite corrigés pour toutes les inefficacités de détection, et la section efficace mesurée est alors comparée à la section efficace théorique. Une autre approche consisterait à repondérer les événements simulés avec les distributions aux ordres supérieurs pour comparer directement les distributions cinématiques prédites par la théorie et mesurées dans les données. Ceci n'a encore jamais été réalisée à ce jour à ma connaissance pour les processus  $\gamma+X$  ou  $\gamma\gamma+X$ .

Le principe de la repondération a déjà été exposé section 3.3.2. Dans ce chapitre, nous nous intéresserons plus particulièrement à la repondération des processus  $\gamma\gamma+X$  et  $H \rightarrow \gamma\gamma$ . Il n'existe pas à ce jour de générateur à gerbe partonique NLO pour le processus  $\gamma\gamma+X$ . Il en existe un pour  $H \rightarrow \gamma\gamma$  (MC@NLO [122]), mais il existe des codes partoniques qui décrivent ce processus au NNLO (tels HNNLO [86]). La repondération de ces processus à l'aide des distributions aux ordres supérieurs est nécessaire pour disposer des prédictions théoriques les plus précises possibles, pour le signal et le bruit de fond, à utiliser pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  (comme déjà effectué par l'expérience ATLAS [103]). D'autre part, il serait possible d'utiliser aussi la technique de repondération pour la comparaison entre données mesurées et prédictions théoriques de la section efficace différentielle du processus  $\gamma\gamma+X$ .

Générateur	ME/PS	Resommation	Born	1-frag	2-frag	Box
DIPHGX	ME	-	NLO	NLO	NLO	LO
GAMMA2MC	ME	-	-	-	-	NLO
RESBOS	ME	NNLL	NLO	LO	-	NLO
PYTHIA	PS	LL+	LO	-	-	LO
MADGRAPH + PYTHIA frag/had	ME+PS	LL+	LO + jusqu'à 2 jets	-	-	-

FIG. 7.1 – Générateurs pour les processus  $\gamma\gamma+X$ .

Dans un premier temps, nous exposerons les propriétés des générateurs aux ordres supérieurs et à gerbes partoniques disponibles pour la génération des processus  $\gamma\gamma+X$  et  $H \rightarrow \gamma\gamma$ . En ce qui concerne le signal de boson de Higgs, nous nous limiterons dans cette étude au mécanisme de production  $gg \rightarrow H$ , puisqu'il est celui ayant la plus grande section efficace au LHC (un ordre de grandeur devant les autres mécanismes) et qu'il bénéficie des prédictions théoriques aux ordres les plus haut (jusqu'à NNLO). Pour le canal  $\gamma\gamma+X$ , nous étudierons séparément les contributions Born et Box. Nous examinerons ensuite les variables cinématiques des processus considérés dans le cas LO et aux ordres supérieurs, d'une part pour repérer les variables les plus discriminantes entre le signal et le bruit de fond, d'autre part pour choisir les variables pertinentes pour la repondération. La définition de l'énergie d'isolation autour des photons est différente au niveau partonique, générateur et reconstruit, c'est pourquoi les critères d'isolation utilisés pour la repondération et les analyses doivent être choisis avec soins. Nous effectuerons une étude tenant compte des effets de reconstruction, ainsi que de l'évènement sous-jacent et de l'hadronisation au niveau générateur. Une fois cette étude effectuée, nous réaliserons la repondération des processus  $\gamma\gamma+X$  générés avec Pythia [26] et Madgraph [23] avec les distributions NLO obtenues avec Dipbox [110] et Gamma2MC [111], ainsi que la repondération du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  généré par MC@NLO [122] avec le code HNNLO [86] au NNLO. Une repondération dépendant de deux variables cinématiques s'est avérée nécessaire : l'impulsion transverse de la paire de photons  $q_T$  et sa masse invariante  $M_{\gamma\gamma}$  dans le canal  $\gamma\gamma+X$ ;  $q_T$  et la rapidité du boson de Higgs  $Y_{\gamma\gamma}$  dans le canal  $gg \rightarrow H \rightarrow \gamma\gamma$ .

## 7.1 Génération des processus $\gamma\gamma+X$ et $gg \rightarrow H \rightarrow \gamma\gamma$

Dans cette section, nous détaillerons les propriétés et les différences des générateurs à éléments de matrice et à gerbes partoniques disponibles pour la génération des processus  $\gamma\gamma+X$  et  $gg \rightarrow H \rightarrow \gamma\gamma$ . Nous exposerons ensuite les critères de sélection utilisés dans la suite.

### 7.1.1 Générateurs pour les processus $\gamma\gamma+X$ et $H \rightarrow \gamma\gamma$

#### Générateurs du processus $\gamma\gamma+X$

Le processus  $\gamma\gamma+X$  se divise en plusieurs contributions : la contribution *directe* des diagrammes Born et Box et la contribution de *fragmentation* des diagrammes de fragmentation simple ou double, décrits plus en détail section 3.1. Dans la contribution directe, les deux photons prompts sont issus directement de l'interaction dure (décrit adéquatement par la théorie perturbative de QCD), tandis que dans la contribution de fragmentation (processus à longue distance non perturbatif), un ou les deux photons prompts sont émis colinéairement aux quarks issus de l'interaction dure. En réalité cette définition est arbitraire du fait des interférences entre les différents diagrammes. Il est en particulier nécessaire d'établir un seuil en angle et en impulsion qui sépare les corrections au diagramme Born des diagrammes de fragmentation. Il existe plusieurs générateurs capables de décrire ces processus. Les plus utilisés sont résumés tableau 7.1.

**Dipbox** est un générateur ME capable de simuler le processus Born et les contributions de fragmentation simple et double au NLO, tandis que le diagramme Box est inclus seulement au LO. Dipbox n'effectue pas de resommation des gluons mous dans l'état initial. Il peut toutefois être considéré l'effectuer dans l'état final, dans la mesure où il y a utilisation d'une fonction de fragmentation explicite au-delà du LL, qui prend en compte la radiation d'un nombre arbitraire de gluons. **Gamma2MC** est un générateur ME



dédié à la simulation du processus direct Box au NLO. **Resbos** est un générateur ME capable de simuler les processus Born au NLO, fragmentation simple au LO et Box au NLO. Au contraire de Diphox, le calcul de la contribution de fragmentation simple est seulement effectif et n'utilise pas de fonction de fragmentation explicite. En revanche, Resbos effectue une resommation des gluons mous dans l'état initial avec la précision NNLL. Le calcul de la contribution Box est aussi effectué en incluant un diagramme supplémentaire négligé par Gamma2MC. On résume schéma 7.2 les propriétés et les différences de ces trois générateurs ME.

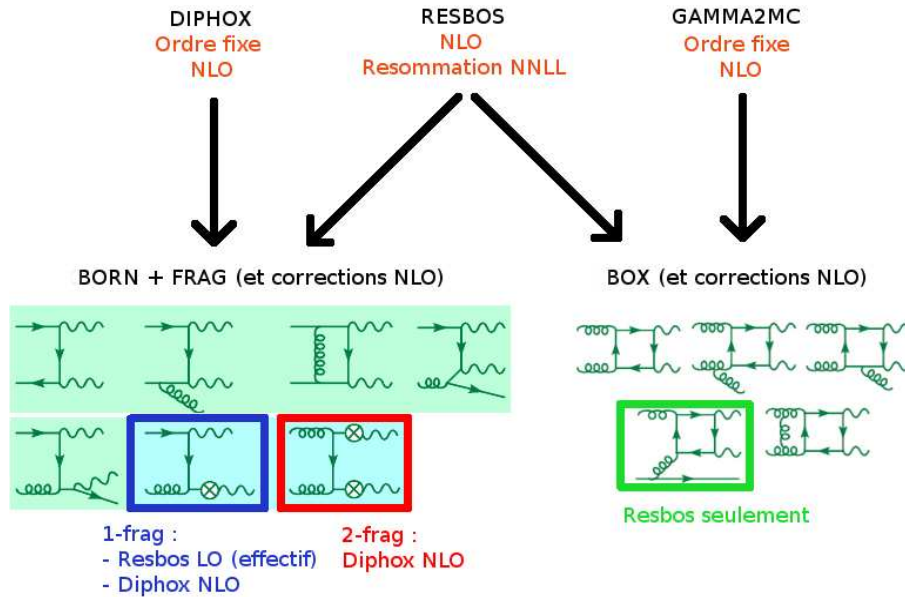


FIG. 7.2 – Différentes contributions aux processus  $\gamma\gamma+X$  prises en compte au NLO par les générateurs à éléments de matrice Diphox, Resbos et Gamma2MC.

Les générateurs à gerbes partoniques capables de générer les processus  $\gamma\gamma+X$  sont **Pythia** et **Sherpa** [119]. La disponibilité de ces processus dans Sherpa étant toute récente, nous n'avons pas pu l'inclure dans la présente étude. Pythia peut générer le processus Born et le processus Box au LO et inclut, de par la gerbe partonique, une description LL améliorée des émissions réelles (molles). Cette description est au-delà de LL puisqu'au contraire d'une resommation des gluons mous au niveau élément de matrice, il y a conservation de l'impulsion (l'approximation de la limite nulle de l'impulsion gluons n'est pas effectué) et l'effet de cohérence de couleur est modélisé par un ordonancement angulaire des radiations QCD. Pythia peut être interfacé avec Madgraph pour réaliser une description plus précise des jets dans le processus Born. Madgraph est un générateur ME capable de simuler les émissions réelles durs supplémentaires. Pour des raisons de temps de calcul, deux jets supplémentaires sont inclus dans le calcul. L'interfaçage de Madgraph avec Pythia garantit que jusqu'à deux jets durs supplémentaires sont décrits adéquatement par l'élément de matrice ; seuls les jets au-delà sont décrits par la gerbe partonique de Pythia (jets mous).

### Générateurs du processus $gg \rightarrow H \rightarrow \gamma\gamma$

Il existe plusieurs générateurs à éléments de matrices dédiés aux processus de production du boson de Higgs. Pour le mécanisme de fusion de gluons, **Fehip** [85] et **HNNLO** [86] sont capables de calculer les sections efficaces différentielles jusqu'au NNLO. La désintégration  $H \rightarrow \gamma\gamma$  est ensuite effectuée à l'arbre, puisqu'il a été montré que les corrections de QCD à ce diagramme (seulement virtuelles pour des raisons de conservation de la couleur) sont négligeables. Ces générateurs n'effectuent pas de resommation des gluons mous dans l'état initial (le programme HqT [118] effectue une resommation au NNLL avec un événement dur au NLO puis normalise la section efficace au NNLO - la cinématique n'est donc pas au NNLO). Dans la suite, nous utiliserons HNNLO.

Générateur	ME/PS	Resommation	Ordre
HNNLO	ME	-	NNLO
PYTHIA	PS	LL+	LO
MC@NLO + Herwig frag/had	ME+PS	LL+	NLO

FIG. 7.3 – Générateurs pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ .

Les générateurs **Pythia** et **MC@NLO** sont capables de générer des événements pour ce processus, et le processus dur est décrit respectivement au LO et au NLO. MC@NLO est interfacé avec Herwig [27] pour la fragmentation/hadronisation de la gerbe partonique. Dans Pythia comme dans Herwig, la gerbe partonique correspond à une resommation à la précision LL améliorée. Madgraph propose aussi la génération du processus dur au LO, mais nous ne l'utiliserons pas dans ce chapitre. Les générateurs ME et PS utilisés sont résumés tableau 7.3.

### 7.1.2 Configurations pour la repondération

La génération des processus  $\gamma\gamma+X$  avec les générateurs ME a été effectuée avec les échelles de renormalisation, de factorisation et de fragmentation fixées à  $\mu_R = \mu_F = M_f = M_{\gamma\gamma}$ , où  $M_{\gamma\gamma}$  est la masse invariante du système diphoton. Pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  avec HNNLO, nous avons fixé les échelles à  $\mu_R = \mu_F = M_H$  où  $M_H$  est la masse du boson de Higgs. Dans la plupart des cas, nous avons choisi comme référence  $M_H = 120$  GeV. Nous avons utilisé par défaut l'ensemble de densités partoniques CTEQ6M [79] pour  $\gamma\gamma+X$  et MRST2004 [80] pour  $gg \rightarrow H \rightarrow \gamma\gamma$ .

L'échantillon PS généré ou interfacé avec Pythia utilise l'ensemble de densités CTEQ6.1L. L'évènement sous-jacent, la fragmentation et l'hadronisation ont été pris en compte lors de la génération.

Les critères de sélection appliqués aux échantillons pour cette étude ont été choisis dans l'optique d'une mesure du processus  $\gamma\gamma+X$  avec les premières données du LHC :

- Energie dans le centre de masse : 7 TeV.
- Impulsion transverse des photons :  $p_T > 20$  GeV, dans la région de rapidité  $|y| < 2.5$ .
- Masse invariante de la paire de photons  $M_{\gamma\gamma} > 40$  GeV.
- Un critère d'isolation au niveau partonique est demandé : typiquement l'énergie transverse partonique dans un cône  $\Delta R$  autour des photons doit être inférieure à un certain seuil que nous déterminerons dans la section suivante.

## 7.2 Etudes d'isolation au niveau partonique, générateur et reconstruit

La génération des processus d'interaction dure proton-proton met en jeu plusieurs niveaux de descriptions, déjà évoqués section 1.2.2 (voir en particulier schéma 1.9) :

- Au *niveau partonique*, les particules entrant dans l'interaction dure et les particules issues de l'interaction sont décrites par un générateur à éléments de matrices. Un critère d'isolation partonique peut être appliqué aux photons issus de l'interaction dure. A ce niveau, une isolation partonique n'a de sens qu'aux ordres supérieurs, où des jets durs peuvent entrer dans le calcul de l'énergie d'isolation dans un cône  $\Delta R$  autour des photons. Au LO les photons sont isolés par défaut (pas d'émission réelle supplémentaire).
- Au *niveau générateur* (ou niveau particule), les générateurs à gerbe partonique modifient les impulsions des partons entrant (et sortant) dans l'interaction dure pour effectuer les émissions réelles (principalement de gluons ISR en ce qui concerne les processus diphotons) et leur hadronisation ainsi que celle des partons de l'évènement sous-jacent. Une énergie d'isolation niveau générateur peut être définie, qui dépend de l'énergie des particules de la gerbe partonique entrant dans le cône d'isolation autour des photons.
- Au *niveau reconstruit*, les particules stables générées en fin de gerbe partonique pénètrent dans la matière du détecteur pour y déposer leur énergie avant d'être reconstruites. On définit généralement une énergie d'isolation dans le ECAL, le HCAL et dans le trajectographe.

Dans le cas d'une comparaison des prédictions aux ordres supérieurs avec les données mesurées, le schéma pour les études d'isolation est le suivant. Une fois les critères d'isolation au niveau reconstruits déterminés, les effets de détection (niveau reconstruit) et les effets dus à l'évènement sous-jacent et l'hadronisation (niveau générateur) sont pris en compte en tant qu'inefficacités. Les données mesurées sont corrigées pour ces inefficacités de sorte que le résultat soit directement comparable avec les prédictions théoriques des générateurs à éléments de matrices. Le seuil en énergie d'isolation niveau générateur est en général pris égal au seuil niveau partonique. A la limite ce seuil peut être choisi arbitrairement tant que les efficacités sont calculées correctement.

Le schéma que nous proposons d'adopter pour les études d'isolation est un peu différent. Nous proposons de choisir les critères d'isolation en plusieurs étapes, selon une approche partant du niveau reconstruit et remontant jusqu'au niveau partonique :

- 1 - Etant donné un critère d'isolation niveau reconstruit, déterminer le critère d'isolation niveau générateur qui préserve une efficacité maximale. Compter à ce stade toutes les particules stables issues de la gerbe partonique dans l'énergie d'isolation.
- 2 - Corriger ensuite ce critère pour l'évènement sous-jacent et l'hadronisation, non en calculant une efficacité pour un même critère, mais en changeant le critère d'isolation de telle sorte que l'efficacité d'isolation soit identique dans le cas avec et sans évènement sous-jacent/hadronisation.
- 3 - Affecter au niveau partonique le critère d'isolation déterminé à l'étape 2. En principe, il faudrait aussi déconvoluer l'effet de la gerbe partonique sur le critère d'isolation, mais il s'agit d'un problème difficile que nous discuterons plus loin en détail.

Cette approche permet de préserver l'efficacité d'isolation propre au niveau partonique NLO, puis de garder une efficacité maximale du niveau de la gerbe partonique jusqu'au niveau reconstruit, en déconvoluant chacun des effets de la génération. Une autre possibilité pour l'étape 1 consisterait à égaliser l'efficacité d'isolation au niveau générateur et reconstruit, mais il faudrait alors prendre garde à éliminer la contribution à l'énergie d'isolation qui provient du bruit expérimental.

### 7.2.1 Proximité des critères de sélection niveau générateur et reconstruit

Afin de déterminer les critères d'isolation à affecter au niveau générateur et au niveau partonique, la première étape consiste à choisir un critère au niveau reconstruit et à déterminer le critère niveau générateur correspondant qui préservera une efficacité maximale par rapport au niveau reconstruit.

Pour le calcul de l'isolation générateur, nous compterons toutes les particules stables (i.e. de statut 1 dans Pythia) dans un cône  $\Delta R$  donné autour du photon et poserons un seuil en énergie transverse maximum admissible dans ce cône  $p_{T,iso}$ . Il y aurait eu possibilité de définir l'isolation de manière un peu différente, par exemple en séparant l'isolation en trois critères imitant l'isolation hadronique dans le HCAL, électromagnétique dans le ECAL et trajectographique, mais nous n'avons pas retenu cette solution car elle nous semblait compliquer inutilement les choses, étant donné qu'une telle séparation des énergies d'isolation ne peut pas être définie au niveau partonique. Une autre possibilité aurait été de sommer l'énergie transverse des jets générés (genJets avec l'algorithme anti-kt) tombant dans le cône d'isolation, mais le seuil en énergie des genJets par défaut dans CMSSW est de 5 GeV, ce qui exclut la possibilité d'effectuer des études fines où l'énergie d'isolation est de cet ordre de grandeur.

#### Choix du critère d'isolation générateur pour un critère donné niveau reconstruit

Le critère d'isolation niveau reconstruit que nous appliquons systématiquement dans les analyses ( $\gamma+X$  chapitre 6,  $\gamma\gamma+X$  chapitre 8) pour l'identification des photons du signal est le suivant :  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV,  $TrackerIso < 2$  GeV (où l'énergie transverse dans le ECAL, HCAL et trajectographe est sommée dans des cônes  $\Delta R < 0.3$  autour des photons) et  $H/E < 0.05$ . Maintenant que ce critère niveau reconstruit est fixé, nous allons effectuer un balayage de l'efficacité d'isolation niveau générateur, l'efficacité étant définie dans ce cas :

$$\epsilon_{gen} = \frac{N_{GenIso|RecoIso}}{N_{RecoIso}}$$

Où  $N_{RecoIso}$  est le nombre d'évènements où les diphotons passent la coupure d'isolation niveau reconstruit et sont associés à un diphoton générateur, et  $N_{GenIso,RecoIso}$  est le sous-lot de ces évènements pour lesquels le diphoton niveau générateur passe la coupure d'isolation niveau générateur. Le photon reconstruit est apparié à la particule générateur dont l'énergie transverse est la plus proche du photon reconstruit, dans un cône  $\Delta R(\gamma_{reco}, \gamma_{gen}) < 0.1$ .

Dans la mesure où nous avons défini le critère d'isolation reconstruit pour des cônes d'isolation  $\Delta R < 0.3$  autour des photons, nous garderons la même taille du cône pour l'isolation niveau générateur. Une fois ce cône fixé, l'énergie transverse maximum admissible dans le cône niveau générateur est variée dans la gamme  $1 < p_{T,iso} < 10$  GeV. L'efficacité d'isolation  $\epsilon_{gen}$  en fonction de  $p_{T,iso}$  pour les diphotons est représentée figure 7.4.

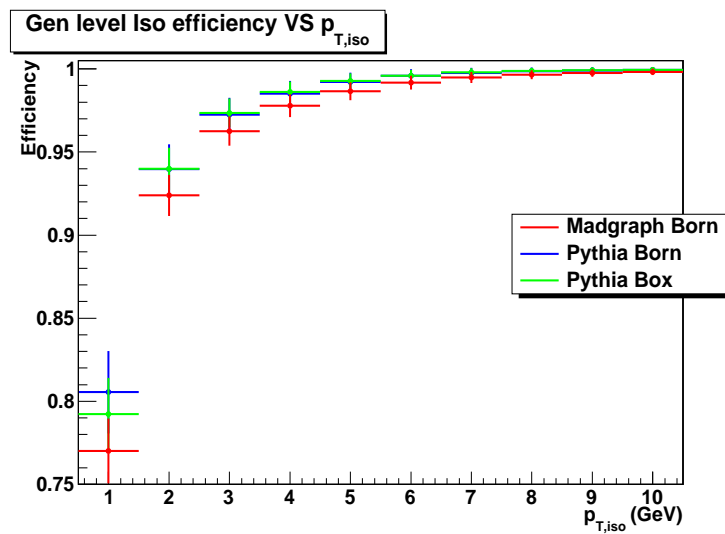


FIG. 7.4 – Efficacité d'isolation niveau générateur des échantillons PS Madgraph Born, Pythia Born et Pythia Box pour le critère donné d'isolation niveau reconstruit  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV,  $TrackerIso < 2$  GeV,  $H/E < 0.05$ . L'isolation est calculée dans un cône  $\Delta R < 0.3$  autour des photons.

L'efficacité d'isolation générateur  $\epsilon_{gen}$  augmente lorsqu'on admet une énergie d'isolation  $p_{T,iso}$  de plus en plus grande dans le cône (comme attendu) et tend vers 1 pour les valeurs grandes de  $p_{T,iso}$ . À la limite, si l'on souhaite garder tous les photons de signal pour le critère reconstruit choisi, il ne faudrait appliquer aucun critère niveau générateur. Dans la pratique, un critère d'isolation  $p_{T,iso} < 7$  GeV correspond à une efficacité de 99,7% environ (soit trois déviations standard pour une distribution gaussienne) pour les échantillons Pythia Born et Box, et de 99,5% pour l'échantillon Madgraph. L'efficacité pour Madgraph est partout inférieure à l'efficacité pour Pythia, car l'échantillon Madgraph génère jusqu'à deux jets durs supplémentaires par évènements, ce qui contribue légèrement à l'augmentation de l'énergie d'isolation dans le cône autour des photons. En conclusion, le critère niveau reconstruit choisi correspond à une énergie d'isolation maximum de  $p_{T,iso} < 7$  GeV au niveau générateur. Les 0,3% et 0,5% d'inefficacités pour Pythia et Madgraph peuvent être pris comme contribution à l'incertitude systématique de la repondération que nous allons effectuer.

### 7.2.2 Corrections au critère d'isolation dues à l'évènement sous-jacent et à l'hadronisation

L'étape suivante consiste à étudier l'effet de l'évènement sous-jacent et de l'hadronisation sur le critère d'isolation niveau générateur que nous venons de déterminer. Pour cela, la même procédure que précédemment pourrait être appliquée. En fixant le critère d'isolation reconstruit et générateur, et en définissant

une deuxième isolation générateur comptant seulement les quarks ou gluons ISR/FSR dans le cône d'isolation autour des photons (pour s'affranchir de l'évènement sous-jacent et de l'hadronisation), il serait possible de choisir un nouveau critère de telle sorte que l'efficacité soit proche de 1. Cette méthode n'est pas facile à mettre en oeuvre car l'information sur les quarks et les gluons ISR ou FSR n'est pas aisée à récupérer, du fait de l'hadronisation (had) et de l'évènement sous-jacent (UE).

Nous avons choisi une autre méthode qui devrait conduire à des résultats équivalents sans risque de se tromper dans la sélection des ISR/FSR. En plus des échantillons générés et reconstruits qui contiennent les effets de l'UE/had, nous avons générés avec Pythia un million d'évènements pour les processus Born et Box  $10 < \hat{p}_T < 25$  GeV et  $25 < \hat{p}_T < 250$  GeV, pour lesquels nous avons "éteint" l'UE (avec l'option  $MSTP(81)=0$ ) et l'hadronisation (avec l'option  $MSTP(111)=0$ ). Nous définissons l'énergie d'isolation niveau générateur sans UE/had par l'énergie transverse sommée des particules de status 1 (qui sont ici majoritairement des quarks ou des gluons) dans un cône  $\Delta R < 0.3$  autour des photons.

On peut dès lors comparer les efficacités d'isolation avec UE/had et sans UE/had, par rapport au cas où aucune isolation n'est demandée. Nous choisirons alors le critère d'isolation sans UE/had pour lequel une efficacité égale à celle avec UE/had est obtenue pour  $p_{T,iso} < 7$  GeV :

$$\epsilon_{Iso,UE/had} = \epsilon_{Iso,sansUE/had}$$

$$\frac{N_{Iso,UE/had}}{N_{NoIso}} = \frac{N_{Iso,sansUE/had}}{N_{NoIso}}$$




FIG. 7.5 – Efficacité d'isolation niveau générateur des échantillons Pythia Born et Pythia Box pour lesquels l'évènement sous-jacent et l'hadronisation a été éteint durant la génération, par rapport au cas où aucune isolation n'est appliquée.

On remarque figure 7.5 que l'efficacité est inférieure à l'efficacité figure 7.4 pour les grandes valeurs de  $p_{T,iso}$ , car ici aucune isolation n'est appliquée niveau reconstruit. Notons que l'efficacité pour le processus Box est inférieure à celle du processus Born. Ceci s'explique par le fait que le processus Born est initié par des quarks tandis que le processus Box est initié par des gluons. Les gluons portent une charge de couleur qui est deux fois celle des quarks et émettent donc plus de radiations ISR lors de la gerbe partonique, ce qui contribue à élever l'énergie tombant dans le cône d'isolation autour des photons.

Pour le critère générateur  $p_{T,iso} < 7$  GeV avec UE/had, l'efficacité d'isolation est de 97,5% pour le processus Born et 97,6% pour le processus Box. Les critères correspondant sans UE/had sont  $p_{T,iso} < 5$  GeV pour le processus Born et  $p_{T,iso} < 6$  GeV pour le processus Box (dans un cône  $\Delta R < 0.3$  autour des photons). La différence d'efficacités pour ces critères avec et sans UE/had est inférieure à 0,1%, valeur

qui peut être prise comme incertitude systématique pour cette étape.

### 7.2.3 Efficacités d'isolation au niveau partonique NLO

Normalement, l'étape suivante consisterait à corriger le critère de sélection que nous venons de définir sans UE/had pour les effets d'augmentation de l'énergie dans le cône d'isolation du fait de la gerbe partonique, par rapport au énergies qu'on obtiendrait au NLO. Une telle étude nous semble complexe et sera discutée dans la section suivante. Nous souhaitons simplement montrer dans cette section le comportement des générateurs aux ordres supérieurs en fonction de différents critères d'isolation.

L'énergie d'isolation niveau partonique pour les générateurs NLO est définie comme l'énergie sommée des partons dont la direction rentre dans le cône d'isolation  $\Delta R$  autour des photons. On montre figure 7.6 l'efficacité d'isolation partonique (par rapport au cas sans isolation) pour le générateur Diphox (processus Born et de fragmentation au NLO) et Gamma2MC (processus Box au NLO), pour différentes tailles du cône  $\Delta R$  et de  $p_{T,iso}$ .




FIG. 7.6 – Efficacité d'isolation niveau partonique pour Diphox (processus Born et fragmentations au NLO, en haut à droite), Gamma2MC (processus Box au NLO, en haut à gauche) et les deux combinés (en bas).

Les efficacités d'isolation calculées avec Diphox sont de l'ordre de 50% à 80% selon les valeurs de  $\Delta R$  et de  $p_{T,iso}$ , tandis que celles calculées avec Gamma2MC sont supérieures à 90%. Cette différence est due au fait que pour le processus Born et Box seul un parton supplémentaire est émis au NLO, tandis que pour les processus de fragmentations simple et double, le photon est émis colinéairement au quark, qui contribue de façon significative à l'énergie transverse d'isolation autour du photon.

Diphox montre un comportement non physique pour les petites tailles de cône  $\Delta R$  et les valeurs rela-

tivement faibles de  $p_{T,iso}$  (augmentation lorsque ces deux paramètres diminuent dans les petites valeurs). Ce comportement est connu [160] pour les programmes de la famille PHOX. Les auteurs recommandent de ne pas choisir de trop petites valeurs de  $\Delta R$  et de  $p_{T,iso}$ . Le comportement redevient physique à partir de  $\Delta R < 0.2$  et  $p_{T,iso} > 5$  GeV,  $\Delta R < 0.3$  et  $p_{T,iso} > 3$  GeV ou  $\Delta R < 0.4$  et  $p_{T,iso} > 2$  GeV, pour être valide dans toute la gamme de  $p_{T,iso}$  pour  $\Delta R < 0.5$ .

Gamma2MC souffre d'un autre problème : l'instabilité des sections efficaces calculées. Pour obtenir le graphique 7.6 droite, cinq séries de calculs ont été effectuées avec des graines différentes. Dans environ 20% des cas, l'incertitude donnée par Gamma2MC souffre d'une incertitude (liée à l'intégration) plus grande que dans les autres cas et la valeur renvoyée avec isolation peut être supérieure à la valeur sans isolation. Parmi ces cinq mesures, nous avons à chaque fois sélectionné la valeur donnant la plus petite incertitude. Malgré tout, l'allure de la courbe n'est pas réellement lisse, mais nous pouvons dégager le comportement global de Gamma2MC face à l'isolation. A part pour les grandes tailles de cône du type  $\Delta R < 0.5$  ou les petites énergies d'isolation du type  $p_{T,iso} < 3$  GeV, l'efficacité d'isolation est supérieure à 99%.

Les valeurs du critère d'isolation sans UE/had choisis étaient  $p_{T,iso} < 5$  GeV pour le processus Born et  $p_{T,iso} < 6$  GeV pour le processus Box. Ceci correspond à des efficacités d'isolation d'environ 60% et 99% respectivement. Une fois combinés, l'efficacité d'isolation NLO est conduite par Diphox et donne 66% à 66,5% pour  $p_{T,iso} < 5$  GeV et  $p_{T,iso} < 6$  GeV. Nous pouvons donc choisir comme critère final  $p_{T,iso} < 5$  GeV dans un cône  $\Delta R < 0.3$  pour les processus Born et le Box au niveau partonique, et admettre 0,5% d'incertitude systématique pour cette étape.

#### 7.2.4 Conclusion sur les études d'isolation

En conclusion, pour un critère d'isolation niveau reconstruit  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV,  $TrackerIso < 2$  GeV et  $H/E < 0.05$  appliqué aux deux photons dans un cône  $\Delta R < 0.3$  sur des événements  $\gamma\gamma+X$ , une isolation niveau générateur avec événement sous-jacent  $GenIso_{UE/had} < 7$  GeV dans un cône  $\Delta R < 0.3$  peut être appliqué avec une efficacité de 99,7% par rapport au niveau reconstruit pour les échantillons Pythia et 99,5% pour les échantillons Madgraph. L'efficacité d'isolation vaut alors 97,5%, ce qui correspond au critère d'isolation sans événement sous-jacent/hadronisation de  $GenIso_{UE/had} < 5$  GeV pour Pythia Born et  $GenIso_{UE/had} < 6$  GeV pour Pythia Box. Si l'on choisit  $GenIso_{UE/had} < 5$  pour les deux processus, l'efficacité d'isolation partonique NLO est de 66% environ. L'efficacité d'isolation niveau partonique est stable en fonction de  $p_{T,iso}$  (elle varie de moins de 0,5% si  $p_{T,iso}$  varie de  $\pm 1$  GeV). L'effet des émissions réelles par la gerbe partonique a été négligé. En étant conservatif, l'incertitude sur l'efficacité est de :

$$\begin{aligned}\Delta\epsilon_{iso} &= \epsilon_{iso,gen/reco} \oplus \epsilon_{iso,UE/had} \oplus \epsilon_{iso,NLO} \\ \Delta\epsilon_{iso} &= 0.5\% \oplus 0.1\% \oplus 0.5\% = 0.7\%\end{aligned}$$

Nous n'avons pas effectué cette étude pour les échantillons  $gg \rightarrow H \rightarrow \gamma\gamma$  Pythia et MC@NLO, mais nous n'attendons pas de grand changement. Le comportement de  $gg \rightarrow H \rightarrow \gamma\gamma$  pour les effets de reconstruction et d'événement sous-jacent/hadronisation devrait être similaire à celui du processus Box initié lui aussi par fusion de gluons. Pour le processus Born Madgraph qui contient jusqu'à deux jets durs supplémentaires, nous n'avons étudié que l'effet de la reconstruction. L'effet de l'événement sous-jacent ne devrait pas dépendre du processus. En conclusion, nous pouvons adopter les critères évoqués ci-dessus aussi pour ces autres échantillons.

Toutefois, l'effet de la radiation dans l'état initial sur le critère d'isolation a été négligé devant l'effet de l'événement sous-jacent et de l'hadronisation. Cet effet est difficile à estimer car la gerbe partonique de Pythia a seulement la précision LL et ne tient pas compte des jets durs NLO. La suppression de ces ISR mous devrait faire baisser l'énergie d'isolation pour une même taille de cône. En ne considérant que le quark/gluon de plus haute impulsion transverse dans la gerbe on se ramènerait à une topologie ressemblant à une topologie NLO, mais comme la radiation n'est pas dure l'efficacité d'isolation à ce niveau serait surestimée. De plus, une telle efficacité pourrait encore être calculée pour les processus Born et Box, mais

pas pour les processus de fragmentations NLO où il peut y avoir jusqu'à deux ou trois quarks supplémentaires (dont un ou deux sont les reliquats d'une fragmentation en photon), ce qui complique la topologie. Il serait possible de déconvoluer cet effet en considérant aussi les échantillons Pythia  $\gamma$ +jet où un des jets fragmente en photon FSR, ou bien en utilisant les échantillons Madgraph  $\gamma\gamma$ +jets où jusqu'à deux jets durs supplémentaires sont émis au niveau élément de matrice. Une alternative consisterait à utiliser un échantillon MC@NLO (par exemple pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ ) qui interface les effets NLO de radiation dure dans le générateur à gerbe partonique, de supprimer l'émission des ISR et de voir comment évolue l'énergie d'isolation pour une même efficacité d'isolation avec et sans ISR. Toutefois, ce processus n'est pas le même que celui étudié et la gerbe Herwig n'est pas la même que celle de Pythia, ce qui rend difficilement transposable les résultats au processus  $\gamma\gamma+X$ . De plus, on souhaite repondérer MC@NLO avec les sections efficaces différentielles NNLO et le problème se pose à nouveau pour ce processus.

### 7.3 Etude des variables cinématiques aux ordres supérieurs

Le but de cette section est multiple. Il s'agit pour une part d'examiner les différences entre les distributions cinématiques au LO et aux ordres supérieurs (NLO pour le processus  $\gamma\gamma+X$  et NNLO pour  $gg \rightarrow H \rightarrow \gamma\gamma$ ). Ceci devrait nous permettre de repérer les observables contenant le plus "d'information" sur les ordres supérieurs, que nous utiliserons ensuite pour la repondération. D'autre part, les incertitudes systématiques liées aux ensembles de densités partoniques ainsi qu'aux échelles d'énergie seront évaluées. Les études présentées dans cette section sont effectuées au niveau partonique et font seulement références aux générateurs à éléments de matrice NLO et NNLO eux-mêmes (il ne sera nulle part fait mention ici de générateurs à gerbes partoniques, dont les distributions pertinentes seront détaillées dans la prochaine section 7.4).

Toutes ces études sont effectuées dans l'hypothèse d'une énergie dans le centre de masse de 7 TeV. Les critères de sélection appliqués sont les suivants : impulsion transverse des photons  $p_T > 20$  GeV, masse invariante  $M_{\gamma\gamma} > 40$  GeV, énergie d'isolation niveau partonique  $GenIso < 5$  GeV dans un cône  $\Delta R < 0.3$  autour des photons. Nous présenterons d'abord les observables LO/NLO pour le processus  $\gamma\gamma+X$  avant d'étudier celles du processus  $gg \rightarrow H \rightarrow \gamma\gamma$ .

#### 7.3.1 Variables cinématiques jusqu'au NLO pour le processus $\gamma\gamma+X$

L'étude des variables cinématiques du processus  $\gamma\gamma+X$  sera effectuée avec les générateurs Diphox et Gamma2MC avant d'être comparée avec les distributions obtenues avec Resbos. Pour le processus Box au LO et au NLO Gamma2MC sera utilisé, tandis que Diphox sera utilisé pour le processus Born au LO et les processus Born et fragmentation simple et double au NLO (il n'est pas physique de considérer ensemble Born et fragmentations au LO puisque l'annulation des divergents arrive seulement au NLO).

Nous évaluerons les incertitudes théoriques avec Diphox et Gamma2MC seulement. Les incertitudes liées aux échelles d'énergie de factorisation  $\mu_F$ , de renormalisation  $\mu_R$  et de fragmentation  $M_f$  seront évaluées en faisant varier les échelles d'un facteur 2 par le haut et le bas autour de  $M_{\gamma\gamma}$  :  $M_{\gamma\gamma}/2 < \mu_F = \mu_R = M_f < 2M_{\gamma\gamma}$ . Pour évaluer l'incertitude associée à l'ensemble de densités partoniques choisis, nous avons essayé les ensembles CTEQ6M et MRST04 (les deux adaptés aux calculs NLO).

#### Comparaison des sections efficaces LO et NLO

Les sections efficaces calculées avec Gamma2MC et Diphox au LO et au NLO après sélection sont résumées tableau 7.7 avec les incertitudes théoriques dues aux ensembles de densités partoniques et échelles d'énergie. Les sections efficaces du processus Box au LO et au NLO sont très proches (2% de différence) pour les critères de sélection choisis en utilisant l'ensemble de densités partoniques CTEQ6. La section efficace Born LO est deux fois plus grande que la section efficace Box. La section efficace Box NLO représente environ 20% de la section efficace totale Box, Born, fragmentations au NLO.



Générateur / Processus	Section efficace	Densité partonique	Echelle d'énergie
Gamma2MC Box LO	12.64 pb	$\pm 6.18\%$	+14.74% -13.21%
Gamma2MC Box NLO	12.89 pb	$\pm 11.92\%$	+8.28% -19.16%
Diphox Born LO	23.46 pb	$\pm 0.77\%$	+12.16% -13.34%
Diphox Born + Frags NLO	42.59 pb	$\pm 1.13\%$	+1.68% -0.95%
Total Born + Box LO	36.10 pb	$\pm 2.67\%$	+3.28% -3.51%
Total Born + Box + Frags NLO	55.48 pb	$\pm 3.64\%$	+1.19% -3.16%

FIG. 7.7 – Sections efficaces pour le processus  $\gamma\gamma+X$  calculées avec Gamma2MC et Diphox, incertitudes théoriques incluses.

Les incertitudes dues à l'échelle d'énergie semblent comparables pour les sections efficaces Box LO et NLO, de l'ordre de 15%, tandis que pour le processus Born+fragmentations elles sont plutôt de l'ordre de 13% au LO et de 1% seulement au NLO. Cette suppression des incertitudes pour la variation de l'échelle d'énergie  $M_{\gamma\gamma}/2 \leq \mu \leq 2M_{\gamma\gamma}$  ( $\mu = \mu_F = \mu_R = M_f$ ) a déjà été notée par les auteurs de Diphox [110]. En revanche l'incertitude devrait être de l'ordre de 20% en faisant varier les échelles d'énergie de manière asymétrique (par exemple  $M_f = M_{\gamma\gamma}$  et  $\mu_F = \mu_R = M_{\gamma\gamma}/2$  jusqu'à  $\mu_F = \mu_R = 2M_{\gamma\gamma}$ ). Ces incertitudes se retrouvent fortement réduites si on considère la somme des sections efficaces calculées avec Diphox et Gamma2MC. Les incertitudes dues au choix de l'ensemble de densités partoniques est de l'ordre de 10% pour le processus Box, 1% pour le processus Born et 3% pour leur somme, aussi bien au LO qu'au NLO.

### Comparaison des sections efficaces différentielles LO et NLO pour $\gamma\gamma+X$

Nous montrons dans ce paragraphe les sections efficaces différentielles pour les processus Box LO et NLO (calculées avec Gamma2MC), ainsi que Born LO et Born+fragmentations au NLO (calculées avec Diphox) pour les observables de masse invariante  $M_{\gamma\gamma}$  (figure 7.8), impulsion transverse du diphoton  $q_T$  (figure 7.9), les distributions angulaires  $\cos(\theta^*)$  (figure 7.10),  $Y_{\gamma\gamma}$  (rapidité du diphoton, figure 7.11),  $Y^*$  (différence de rapidité des photons divisée par deux, figure 7.12), la différence angulaire azimuthale  $\Delta\phi$  (figure 7.13), l'impulsion transverse  $p_{T,lead}$  (photon ayant le plus haut  $p_T$ , figure 7.14) et  $p_{T,trail}$  (photon ayant le plus bas  $p_T$ , figure 7.15). Pour  $q_T$  et  $\Delta\phi$ , seules les distributions NLO sont montrées car au LO  $q_T = 0$  et  $\Delta\phi = \pi$  (photons dos-à-dos).

Certains spectres NLO présentent des divergences près des bords, ce qui est une caractéristique des générateurs éléments de matrice à ordre fixe. Pour les critères de sélection choisis, Diphox ne diverge pas pour  $M_{\gamma\gamma} \rightarrow 40$  GeV et  $\Delta\phi \rightarrow \pi$  tandis que Gamma2MC diverge pour ces deux limites. Les deux générateurs divergent en revanche dans la limite  $q_T \rightarrow 0$ . Près de ces limites, on ne peut pas faire confiance aux valeurs renvoyées par les générateurs Diphox et Gamma2MC, qui renvoient souvent des valeurs négatives. Il est alors possible de rendre physique le spectre en moyennant les valeurs obtenues dans une ou deux divisions près des bords (par exemple la plage  $0 < q_T < 8$  GeV), afin de rendre positif les valeurs de la section efficace différentielle sur toute la gamme observée. Une autre solution consisterait à utiliser plutôt un code comme Resbos qui renvoie des valeurs physiques près des bords en effectuant une resommation des gluons dans l'état initial (mais qui souffre d'autres problèmes).

Les distributions angulaires  $\cos(\theta^*)$ ,  $Y^*$  et  $Y_{\gamma\gamma}$  présentent une plus grande pente au NLO qu'au LO, mais leur allure est globalement la même. Outre  $q_T$  et  $\Delta\phi$  qui n'ont pas de spectre observable au LO, les plus grandes différences cinématiques apparaissent pour  $M_{\gamma\gamma}$ , qui présente un spectre plus dur au NLO qu'au LO, ainsi que pour  $p_{T,lead}$  et dans une moindre mesure  $p_{T,trail}$ .

Les incertitudes théoriques sur les sections efficaces différentielles semblent les plus importantes pour les hautes valeurs de  $M_{\gamma\gamma}$  de  $q_T$ ,  $p_{T,lead}$  et  $p_{T,trail}$ , les basses valeurs de  $\cos(\theta^*)$ , les valeurs centrales de  $Y^*$  et  $Y_{\gamma\gamma}$ , les basses valeurs de  $\Delta\phi$ . Elles sont les plus importantes pour les distributions angulaires  $\cos(\theta^*)$ ,  $Y^*$  et  $Y_{\gamma\gamma}$  par rapport aux autres variables.




FIG. 7.8 – Distribution de la masse invariante  $\gamma\gamma$  pour DiphoX (à gauche) et Gamma2MC (à droite) au LO et au NLO.

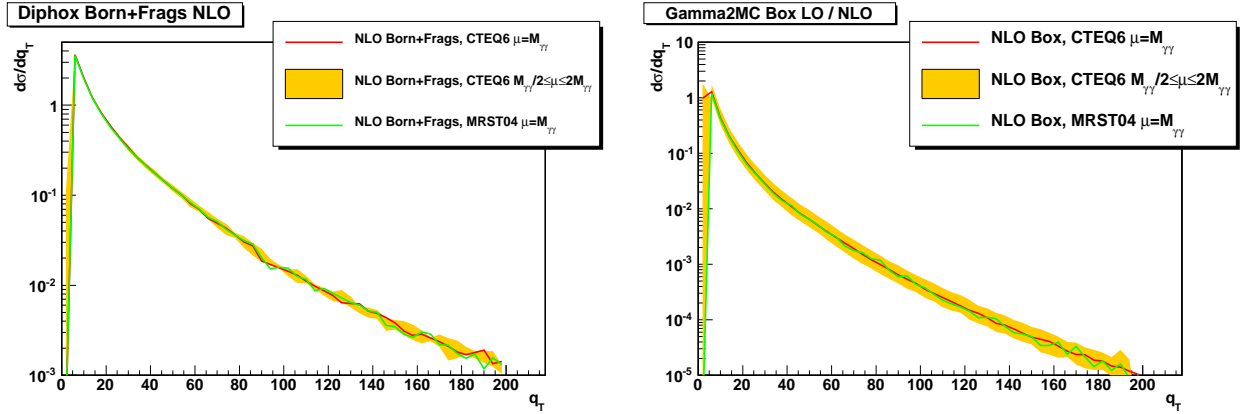


FIG. 7.9 – Distribution de l'impulsion transverse  $q_T$  du diphoton pour DiphoX (à gauche) et Gamma2MC (à droite) au LO et au NLO.

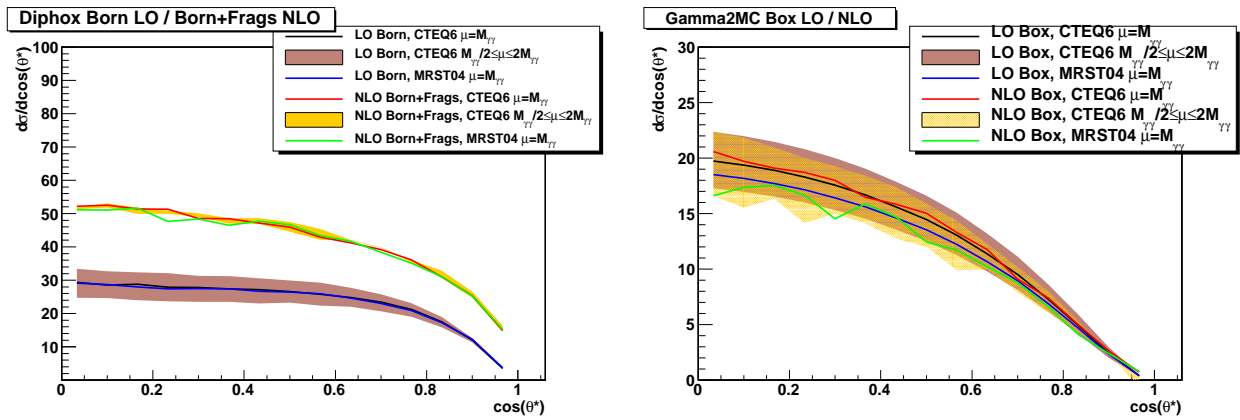


FIG. 7.10 – Distribution angulaire  $\cos(\theta^*)$  du diphoton pour DiphoX (à gauche) et Gamma2MC (à droite) au LO et au NLO.




FIG. 7.11 – Rapidité  $Y_{\gamma\gamma}$  du diphoton pour Diphox (à gauche) et Gamma2MC (à droite) au LO et au NLO.

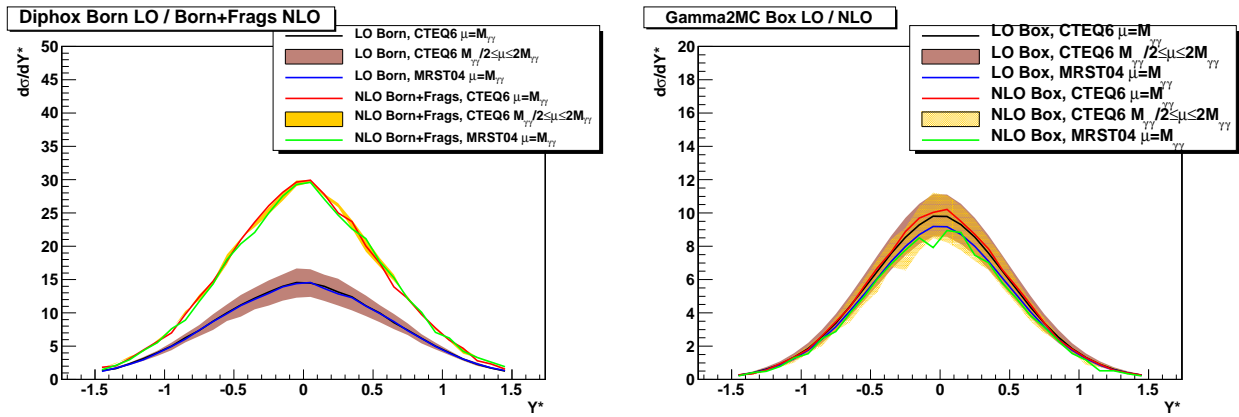


FIG. 7.12 – Différence de rapidité des photons divisée par deux  $Y^*$  pour Diphox (à gauche) et Gamma2MC (à droite) au LO et au NLO.

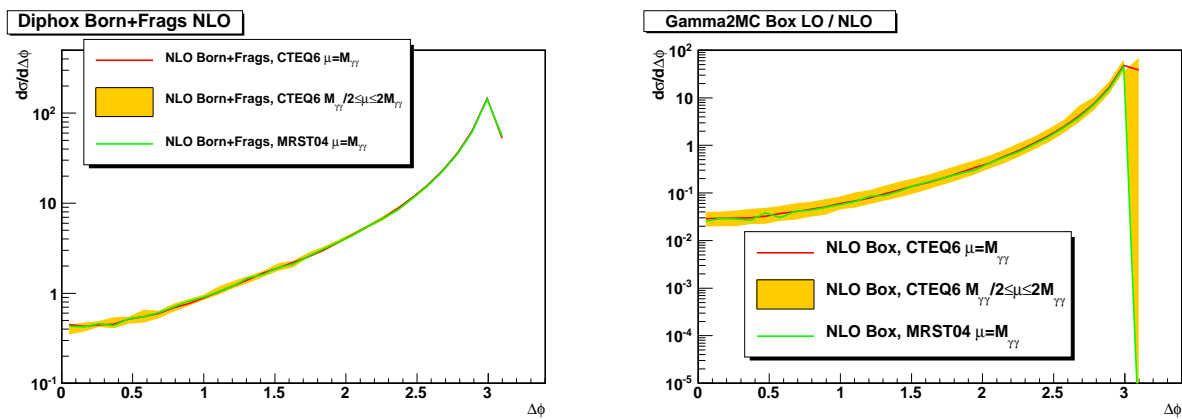


FIG. 7.13 – Différence angulaire azimuthale  $\Delta\phi$  des deux photons pour Diphox (à gauche) et Gamma2MC (à droite) au LO et au NLO.

### 7.3.2 Variables cinématiques jusqu'au NNLO pour le processus $gg \rightarrow H \rightarrow \gamma\gamma$

Pour l'étude des variables cinématiques du processus  $gg \rightarrow H \rightarrow \gamma\gamma$ , nous avons utilisé le générateur HNNLO. Le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  est soumis à de plus grandes incertitudes théoriques que le bruit de fond  $\gamma\gamma+X$ . Pour évaluer l'incertitude associée à l'ensemble de densités partoniques choisis, nous avons




FIG. 7.14 – Impulsion transverse  $p_{T,lead}$  du photon de plus haut  $p_T$  pour Diphox (à gauche) et Gamma2MC (à droite) au LO et au NLO.

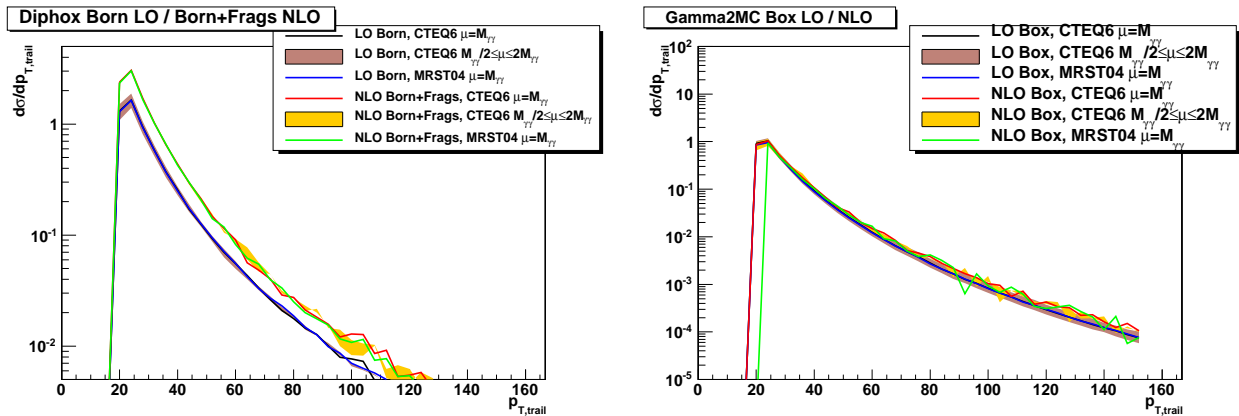


FIG. 7.15 – Impulsion transverse  $p_{T,trail}$  du photon de plus bas  $p_T$  pour Diphox (à gauche) et Gamma2MC (à droite) au LO et au NLO.

essayé les ensembles MRST04 (par défaut) et MRST02 (les deux adaptés aux calculs NNLO).

Dans un premier temps nous examinerons les sections efficaces LO, NLO, NNLO ainsi que les incertitudes théoriques pour ce processus, avant de nous pencher sur les sections efficaces différentielles. Nous étudierons ensuite l'influence de la masse du boson de Higgs sur les observables cinématiques. Enfin, nous comparerons signal et bruit de fond dans une région de l'espace de phase utilisé pour la recherche du boson de Higgs.

### Comparaison des sections efficaces LO, NLO et NNLO pour $gg \rightarrow H \rightarrow \gamma\gamma$

On montre tableau 7.16 les sections efficaces LO, NLO et NNLO calculées avec HNNLO, pour quatre masses du boson de Higgs, avec les incertitudes dues à l'ensemble de densité partonique (première incertitude en %) et dues à l'échelle d'énergie (incertitudes asymétriques en %).

Les sections efficaces différentielles pour les critères de sélection choisis au NLO sont de l'ordre de 2 à 2,5 fois les sections efficaces LO, et les sections efficaces NNLO de l'ordre de 3 fois les sections efficaces LO. Les sections efficaces diminuent lorsque la masse du boson de Higgs augmente. L'incertitude due aux échelles d'énergie est de l'ordre de 20% au LO, 15% au NLO et 10% au NNLO, tandis que les incertitudes dues au choix de l'ensemble de densités partonique reste de l'ordre de 1% au LO, 2% au NLO et 3% au NNLO.

HNNLO	LO	NLO	NNLO
$m_H = 110$ GeV	7.85 fb $\pm 1.8\%$ $^{+18.18\%}_{-15.18\%}$	17.37 fb $\pm 2.35\%$ $^{+17.25\%}_{-13.43\%}$	23.03 fb $\pm 3.35\%$ $^{+10.34\%}_{-9.08\%}$
$m_H = 120$ GeV	7.73 fb $\pm 1.73\%$ $^{+19.07\%}_{-15.71\%}$	17.09 fb $\pm 2.33\%$ $^{+17.42\%}_{-13.65\%}$	22.45 fb $\pm 3.22\%$ $^{+9.13\%}_{-8.66\%}$
$m_H = 130$ GeV	6.79 fb $\pm 1.65\%$ $^{+19.86\%}_{-16.20\%}$	14.95 fb $\pm 2.27\%$ $^{+17.60\%}_{-13.90\%}$	19.72 fb $\pm 3.71\%$ $^{+9.09\%}_{-9.49\%}$
$m_H = 140$ GeV	5.12 fb $\pm 1.54\%$ $^{+20.58\%}_{-16.63\%}$	11.25 fb $\pm 2.14\%$ $^{+17.68\%}_{-14.04\%}$	14.93 fb $\pm 3.88\%$ $^{+8.41\%}_{-10.43\%}$

FIG. 7.16 – Sections efficaces pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  calculées avec HNNLO, incertitudes théoriques incluses.

### Comparaison des sections efficaces différentielles LO, NLO et NNLO pour $gg \rightarrow H \rightarrow \gamma\gamma$

Nous montrons ici les sections efficaces différentielles calculées avec HNNLO pour les processus  $gg \rightarrow H \rightarrow \gamma\gamma$  au LO, NLO et NNLO pour une masse du boson de Higgs  $m_H = 120$  GeV, pour les observables d'impulsion transverse du boson de Higgs  $q_T$  (figure 7.17), les distributions angulaires  $\cos(\theta^*)$  (figure 7.17), la différence angulaire azimuthale  $\Delta\phi$  (figure 7.17),  $Y_{\gamma\gamma}$  (rapidité du boson de Higgs, figure 7.18),  $Y^*$  (différence de rapidité des photons divisée par deux, figure 7.18), l'impulsion transverse  $p_{T,lead}$  (photon ayant le plus haut  $p_T$ , figure 7.19) et  $p_{T,trail}$  (photon ayant le plus bas  $p_T$ , figure 7.19). Pour  $q_T$  et  $\Delta\phi$ , seules les distributions NLO et NNLO sont montrées car au LO  $q_T = 0$  et  $\Delta\phi = \pi$  (photons dos-à-dos).

On retrouve les divergences en  $q_T \rightarrow 0$  et  $\Delta\phi \rightarrow \pi$  dus aux calculs à ordres fixes au NLO et NNLO. Le spectre de  $q_T$  au NNLO est plus dur qu'au NLO, de même que les spectres en impulsion transverse des photons.

Le spectre en  $\cos(\theta^*)$  est plus plat pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  que pour  $\gamma\gamma+X$  (avec les critères de sélection choisis) et peut donc être utilisé comme variable discriminante pour la recherche du boson de Higgs. De même, le spectre en  $q_T$  et en impulsion des photons est plus dur pour le boson de Higgs que pour le bruit de fond, car un boson de Higgs ayant  $m_H = 120$  GeV se désintègre souvent en photons ayant une énergie de l'ordre de 60 GeV (ceci peut être aussi compris avec l'argument disant que les échelles d'énergie du bruit de fond varient avec  $M_{\gamma\gamma}$  tandis que celle du signal est de  $m_H = 120$  GeV).

Il est intéressant de noter que les incertitudes théoriques sont les plus faibles au NLO qu'au LO, et que les incertitudes théoriques NNLO sont plus faibles qu'au NLO, ce qui semble indiquer la convergence de la série perturbative de QCD. D'une manière générale, les incertitudes théoriques sont plus importantes que pour le processus  $\gamma\gamma+X$ .

### Influence de la masse du boson de Higgs sur les sections efficaces différentielles

Les observables sur lesquelles la masse du boson de Higgs influe le plus sont les observables d'impulsion transverse  $p_T$ . L'impulsion transverse du photon ayant le plus haut et le plus bas  $p_T$  est représentée figure 7.20 au NNLO. Comme attendu, le spectre en impulsion transverse devient plus dur à mesure que la masse du boson de Higgs augmente. Nous n'examinons pas les autres variables dans la mesure où la masse du boson de Higgs a une influence extrêmement faible sur leur spectre.

### Comparaison des spectres de $\gamma\gamma+X$ au NLO et de $gg \rightarrow H \rightarrow \gamma\gamma$ au NNLO

Afin de déterminer quelles sont les variables cinématiques discriminantes entre le signal  $gg \rightarrow H \rightarrow \gamma\gamma$  et le bruit de fond  $\gamma\gamma+X$  dans la région de l'espace de phase où le boson de Higgs est recherché, les distributions NLO pour le processus Born+Fragmentation et Box ont été générés avec Diphox et Gamma2MC avec les mêmes critères de sélection que précédemment, sauf la masse invariante  $\gamma\gamma$  qui doit satisfaire  $M_{\gamma\gamma} > 100$  GeV. Ces variables discriminantes seront utilisées chapitre 9 pour la recherche du boson de Higgs.




FIG. 7.17 – Sections efficaces différentielles pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ . A gauche, l'impulsion transverse du boson de Higgs  $q_T$  (au NLO et NNLO), à droite  $\Delta\phi$  (au NLO et NNLO) et en bas  $\cos(\theta^*)$  (au LO, NLO et NNLO).

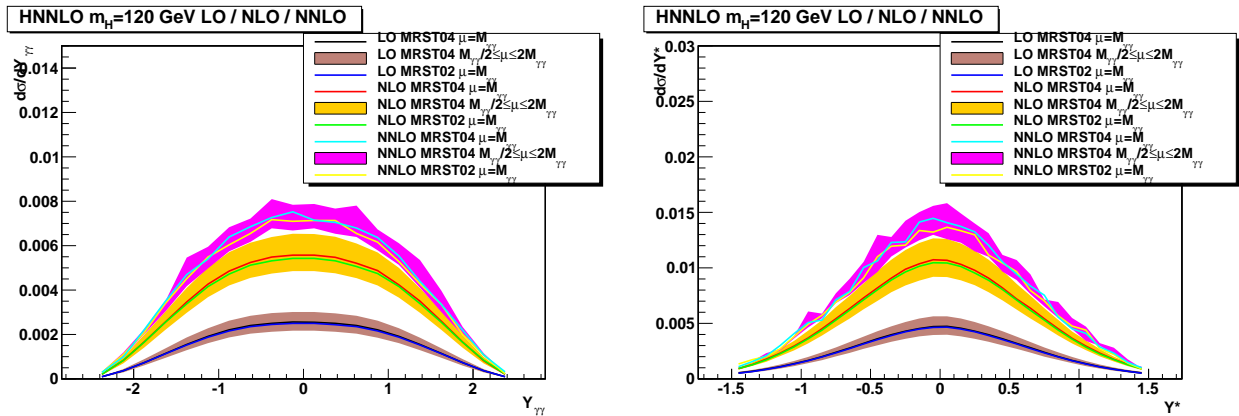


FIG. 7.18 – Sections efficaces différentielles pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ . A gauche la rapidité  $Y_{\gamma\gamma}$  du boson de Higgs (au LO, NLO et NNLO), à droite la différence de rapidité des photons divisée par deux  $Y^*$  (au LO, NLO et NNLO).

Les deux observables qui paraissent les plus discriminantes sont les distributions angulaires  $\cos(\theta^*)$  (voir figure 7.21) et  $Y^*$  (figure 7.23). Comme on peut le voir,  $\cos(\theta^*)$  est une observable dont la forme de la distribution dépend grandement des critères de sélection cinématiques appliqués (voir par contraste figure 7.10 avec  $M_{\gamma\gamma} > 40$  GeV). Pour  $M_{\gamma\gamma} > 100$  GeV,  $\cos(\theta^*)$  pique autour de 0,8 au contraire du signal.  $Y^*$  est beaucoup plus étalée pour le bruit de fond que pour le signal.

L'autre variable angulaire  $\Delta\phi$  semble aussi montrer un pouvoir discriminant qui semble toutefois




FIG. 7.19 – Sections efficaces différentielles pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ . A gauche l'impulsion transverse du photon de plus haut  $p_T$  (au LO, NLO et NNLO), à droite l'impulsion transverse du photon de plus bas  $p_T$  (au LO, NLO et NNLO).

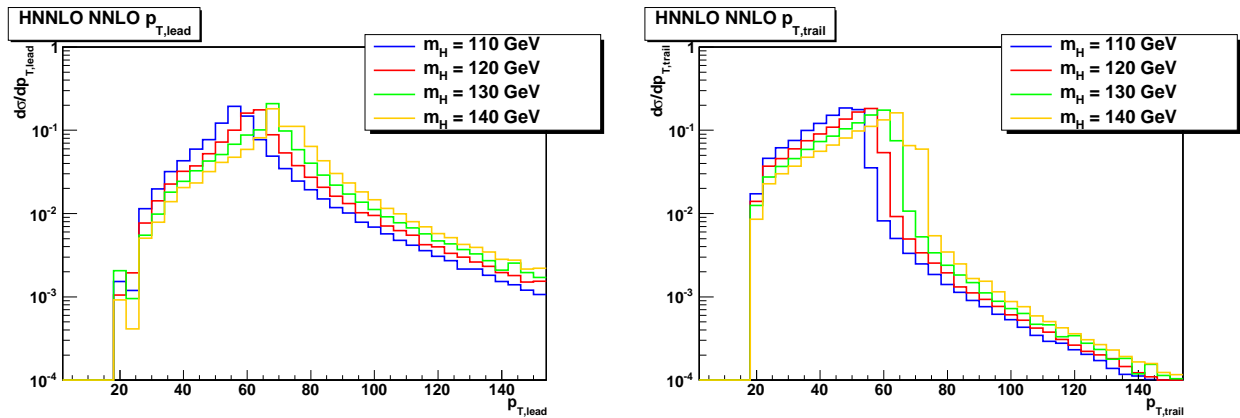


FIG. 7.20 – Sections efficaces différentielles NNLO pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ . A gauche l'impulsion transverse du photon de plus haut  $p_T$ , à droite l'impulsion transverse du photon de plus bas  $p_T$ , pour quatre masses nominales du boson de Higgs.

moins important, de même que l'impulsion transverse  $q_T$  dont le spectre est plus dur pour le signal que pour le bruit de fond. Enfin, les impulsions transverses des photons piquent à 60 GeV pour le signal et montrent aussi un pouvoir discriminant relativement important par rapport aux photons du bruit de fond. La rapidité  $\gamma\gamma$  ne montre aucun pouvoir de discrimination pour les critères de sélection testés.

## 7.4 Repondération des processus $\gamma\gamma+X$

Il y a deux applications à la repondération des processus  $\gamma\gamma+X$  : la première est la prédiction du bruit de fond pour la recherche du boson de Higgs et la seconde la comparaison des données et des prédictions théoriques pour la mesure de la section efficace  $\gamma\gamma+X$ . Pour la seconde application tout l'espace de phase de phase doit être couvert tandis que pour la première, la repondération peut être restreinte à la région de masse invariante  $90 < M_{\gamma\gamma} < 200$  GeV par exemple (pour la recherche de bosons de Higgs légers). Nous effectuerons dans un premier temps la repondération sur tout l'espace de phase avant de vérifier les propriétés des échantillons repondérés dans cette région plus restreinte.

Pour le processus Box nous disposons seulement d'un échantillon officiel généré au LO avec Pythia, tandis que pour le processus Born les échantillons officiels au LO Pythia et Madgraph (avec jusqu'à deux jets durs supplémentaires) sont disponibles. Nous investiguerons dans un premier temps la repondération

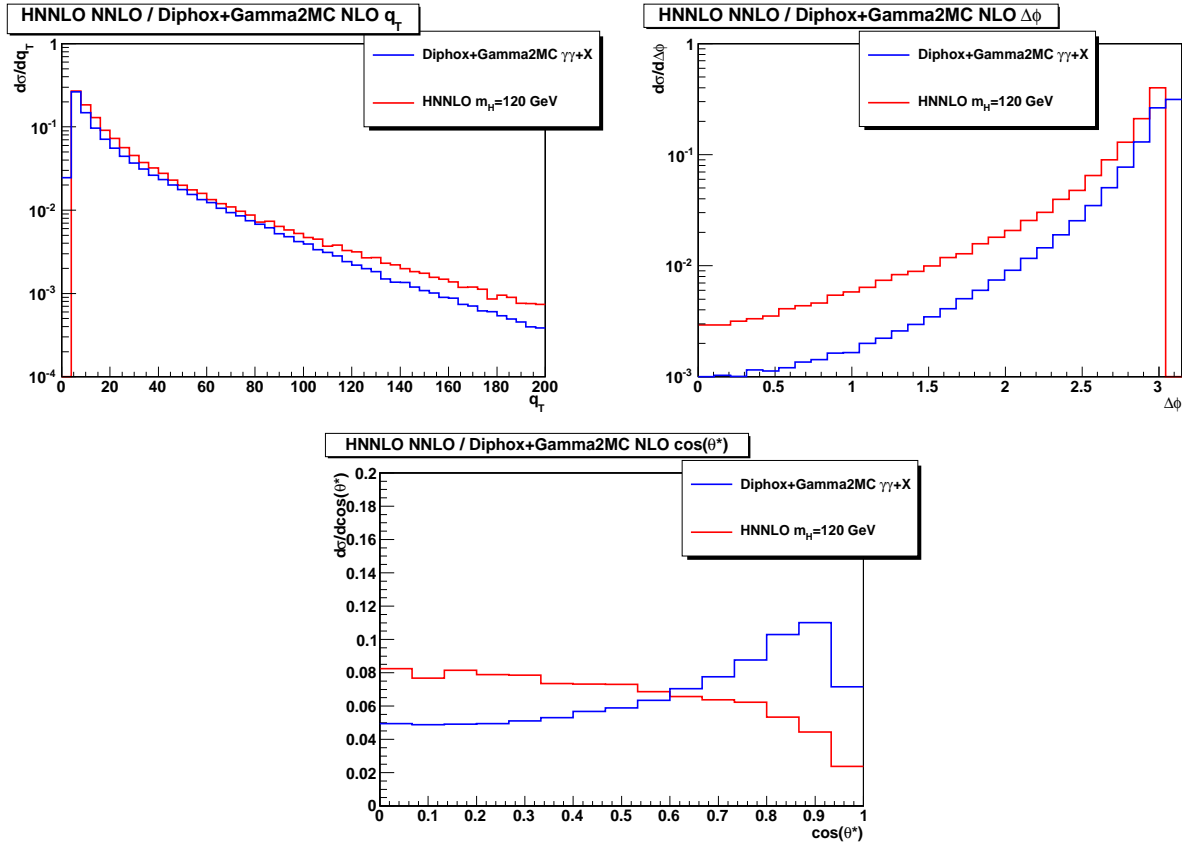


FIG. 7.21 – Sections efficaces différentielles NNLO pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  et NLO pour le processus  $\gamma\gamma+X$  dans la région de l'espace de phase où est recherché le boson de Higgs. A gauche, l'impulsion transverse  $\gamma\gamma$   $q_T$ , à droite  $\Delta\phi$  et en bas  $\cos(\theta^*)$ .

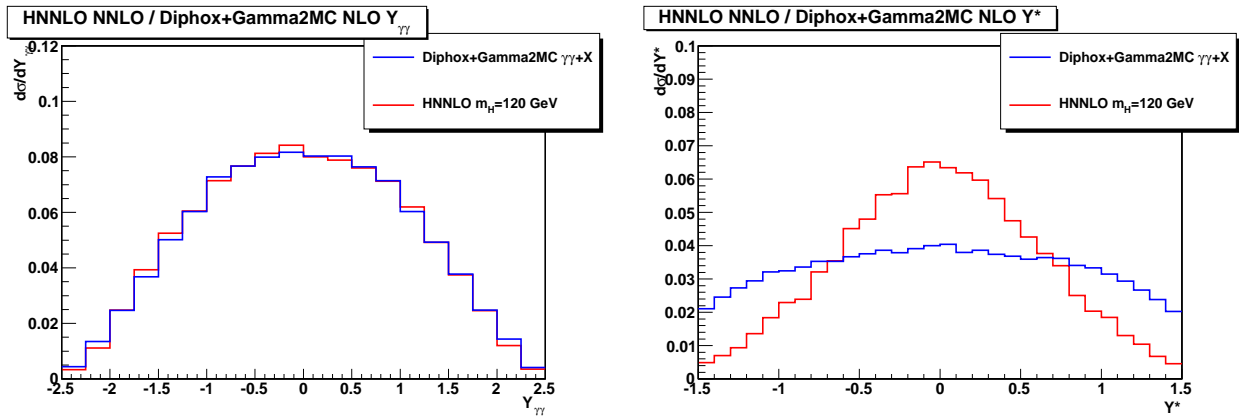


FIG. 7.22 – Sections efficaces différentielles NNLO pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  et NLO pour le processus  $\gamma\gamma+X$  dans la région de l'espace de phase où est recherché le boson de Higgs. A gauche la rapidité  $Y_{\gamma\gamma}$ , à droite la différence de rapidité des photons divisée par deux  $Y^*$ .

séparée de ces deux processus (Box avec Gamma2MC, Born avec Diphox) avant d'effectuer leur repondération conjointe.

Au niveau partonique, nous avons utilisé les critères suivants pour Diphox et Gamma2MC :  $p_T > 20$  GeV,  $M_{\gamma\gamma} > 40$  GeV et  $|\eta| < 2.5$  pour les deux photons. Le critère d'isolation appliqué demande une énergie transverse partonique  $E_T < 5$  GeV dans un cône  $\Delta R < 0.3$  autour de chaque photon. Au niveau générateur pour Pythia et Madgraph, nous demandons les mêmes critères d'impulsion transverse et de






FIG. 7.23 – Sections efficaces différentielles NNLO pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  et NLO pour le processus  $\gamma\gamma+X$  dans la région de l'espace de phase où est recherché le boson de Higgs. A gauche l'impulsion transverse du photon de plus haut  $p_T$ , à droite l'impulsion transverse du photon de plus bas  $p_T$ .

pseudo-rapidité, mais le critère d'isolation demande que l'énergie transverse de toutes les particules de statut 1 soit inférieure à 7 GeV dans un cône de  $\Delta R < 0.3$  (nous avons montré plus haut que les 2 GeV de différence étaient dus à la prise en compte de l'évènement sous-jacent et de l'hadronisation).

#### 7.4.1 Repondération du processus $\gamma\gamma+X$ avec les échantillons officiels

Afin de tenir compte au mieux des propriétés cinématiques NLO du processus  $\gamma\gamma+X$ , nous aimerions effectuer une repondération utilisant une ou deux variables. Plusieurs combinaisons de variables ont été essayées. La variable la plus importante semble être l'impulsion transverse du système diphoton  $q_T$ , qui est seulement non nulle au NLO pour les générateurs éléments de matrice, et au LL pour les générateurs à gerbe partonique. La référence [129] propose la repondération du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  à l'aide de  $q_T$  et  $Y_{\gamma\gamma}$ , la rapidité du système diphoton. Nous avons essayé cette option qui n'a pas posé de problème particulier avec Diphox. En revanche la génération des sections efficaces doublement différentielles dans le plan  $(q_T, Y_{\gamma\gamma})$  a mené à des divergences ingérables avec Gamma2MC. Notre choix s'est donc porté vers une autre variable discriminante, la masse invariante  $M_{\gamma\gamma}$ . Le découpage de l'espace de phase en régions de  $M_{\gamma\gamma}$  est plus naturel dans Gamma2MC (où l'option est implémentée explicitement dans l'interface).

#### Repondération du processus Born

La figure 7.24 montre les sections efficaces différentielles pour  $M_{\gamma\gamma}$  et  $q_T$  ainsi que les K-facteurs  $K = \sigma_{Diphox}/\sigma_{PS}$  (où  $PS$  se réfère à Madgraph ou Pythia) associés. On observe que la génération de deux jets supplémentaires avec Madgraph pour le processus Born donne lieu à un spectre en impulsion transverse plus dur que celui de Pythia et presque semblable à celui donné par Diphox. La différence avec Diphox est mince, mais il semble que  $K(q_T)$  soit légèrement inférieur à 1 pour la plage  $20 < q_T < 100$  GeV et supérieur à 1 au-delà. Il est aussi à noter que Diphox donne un résultat divergent dans la limite  $q_T \rightarrow 0$ . Un K-facteur négatif n'ayant pas de sens physique, nous avons choisi de rassembler les deux premières divisions de  $q_T$  (région  $0 < q_T < 8$  GeV) pour le rendre positif. La divergence à la limite cinématique  $M_{\gamma\gamma} \rightarrow 40$  GeV n'est pas visible avec les critères de sélection choisis ici mais peut apparaître avec d'autres critères. Nous avons choisi ici aussi de rassembler dans une seule division la région  $40 < M_{\gamma\gamma} < 50$  GeV.

On montre aussi figure 7.25 les K-facteurs  $K(q_T, M_{\gamma\gamma})$  pour Pythia et Madgraph. On constate que L'espace de phase  $q_T, M_{\gamma\gamma}$  est insuffisamment peuplé avec Pythia tandis qu'il l'est avec Madgraph. Toute la région  $q_T > M_{\gamma\gamma}$  ne contient aucun évènement Pythia, pour une raison physique : les jets supplémentaires dans Pythia sont issus de la gerbe partonique et non de l'évènement dur. La région des grands  $M_{\gamma\gamma}$  est elle aussi dépeuplée. Il est aussi à noter que pour Madgraph et Pythia, le K-facteur est soumis à




FIG. 7.24 – Sections efficaces différentielles en fonction de  $q_T$  (en haut à gauche) et  $M_{\gamma\gamma}$  (en haut à droite) du processus Born pour les générateurs Pythia, Madgraph et Diphox, ainsi que les K-facteurs associés (en bas).

des fluctuations statistiques. Déterminer un K-facteur plus lisse serait possible dans la limite des grandes statistiques mais poserait des problèmes pour son application aux événements reconstruits (la phase de simulation étant très gourmande en temps de calcul).




FIG. 7.25 – K-facteur en deux dimensions en fonction de  $q_T$  et  $M_{\gamma\gamma}$  pour le processus Born, pour le générateur Diphox au NLO par rapport à Madgraph (à gauche) et Pythia (à droite).

A partir des K-facteurs que nous venons de déterminer, nous effectuerons la repondération à chaque fois pour le cas d'un K-facteur constant  $K_{cte} = \sigma_{ME,NLO}/\sigma_{PS}$  (où  $\sigma_{ME,NLO}$  est la section efficace NLO calculée par Diphox/Gamma2MC et  $\sigma_{PS}$  la section efficace Madgraph/Pythia), et pour les trois K-facteurs dépendant des variables  $q_T$  et  $M_{\gamma\gamma}$  :  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ . Le résultat de la repondération sur les variables  $q_T$  et  $M_{\gamma\gamma}$  peut être lu figure 7.26 pour Pythia et figure 7.27 pour Madgraph, ainsi que sur la variable  $\cos(\theta^*)$  que nous montrons à chaque fois pour vérifier l'effet de la repondération sur une autre variable cinématique.

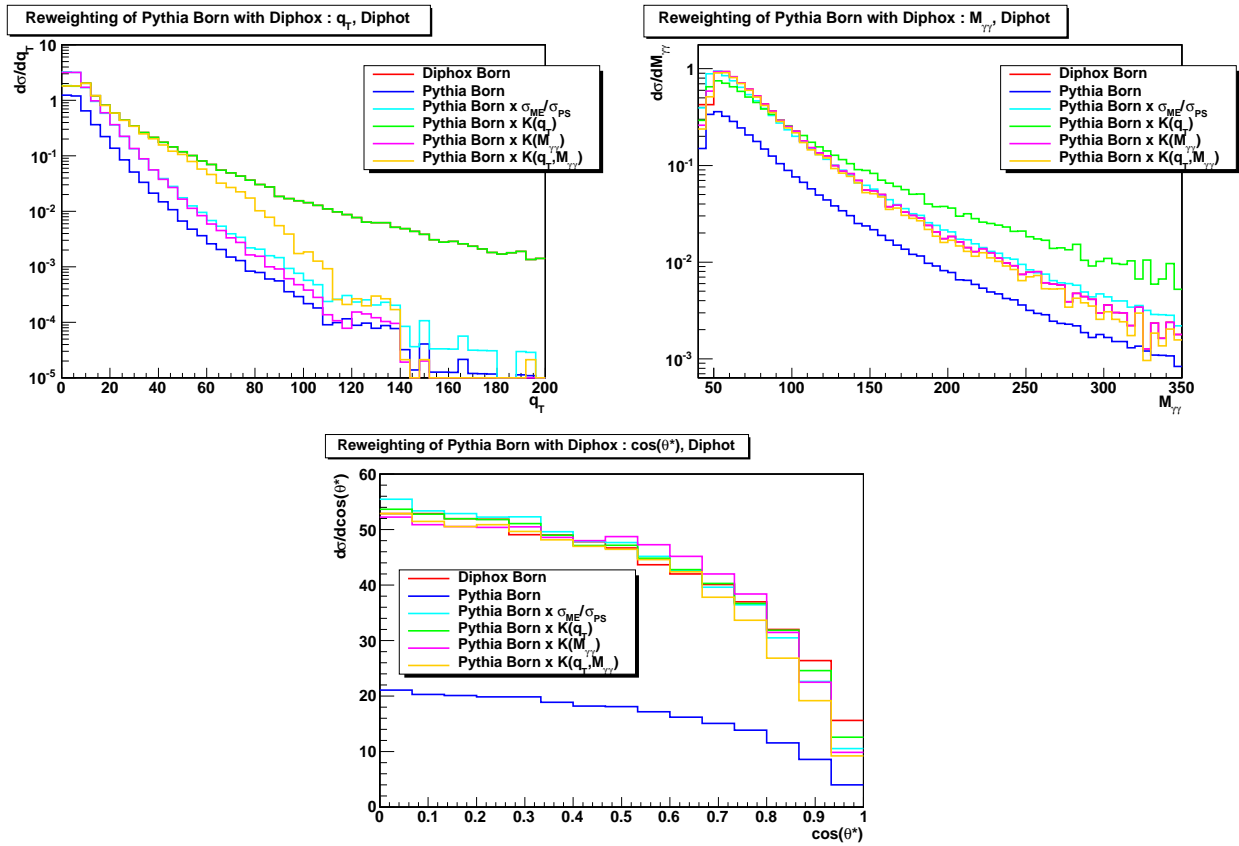


FIG. 7.26 – Distributions de  $q_T$  (en haut à gauche),  $M_{\gamma\gamma}$  (en haut à droite) et  $\cos(\theta^*)$  (en bas) pour le processus Born g n r  avec Diphox (fragmentations incluses), Pythia et Pythia repond r  avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .

Sur la figure 7.26, la distribution de  $q_T$  ( $M_{\gamma\gamma}$ ) g n r e avec Diphox et celle de Pythia repond r e avec  $K(q_T)$  ( $K(M_{\gamma\gamma})$ ) sont  videmment superpos es. Seul l'application de  $K(q_T)$  permet de reproduire correctement la distribution  $q_T$  de Diphox. L'utilisation du K-facteur en deux dimensions  $K(q_T, M_{\gamma\gamma})$  ne donne pas le r sultat escompt  pour la distribution de  $q_T$  pour  $q_T > 40$  GeV, car l'espace de phase  $(q_T, M_{\gamma\gamma})$  n'est pas correctement peupl  avec Pythia. En revanche, pour la distribution de  $M_{\gamma\gamma}$ , le K-facteur  $K(q_T, M_{\gamma\gamma})$  donne un r sultat proche de celui attendu avec  $K(M_{\gamma\gamma})$ , tandis que  $K(q_T)$  sous-estime le taux d' v nements   bas  $M_{\gamma\gamma}$  et le surestime   haut  $M_{\gamma\gamma}$ . La distribution  $\cos(\theta^*)$  de Diphox est la mieux reproduite   l'aide du K-facteur  $K(q_T)$  m me s'il subsiste des diff rences   haut  $\cos(\theta^*)$ . En conclusion, l' chantillon Pythia ne peut pas  tre utilis  pour la repond ration du processus Born avec Diphox du fait de l'espace de phase  $(q_T, M_{\gamma\gamma})$  qui n'est pas peupl  correctement.

La figure 7.27 montre les effets des diff rentes repond rations de l' chantillon Born Madgraph. On remarque sur la distribution de  $q_T$  que cette fois, le K-facteur  $K(q_T, M_{\gamma\gamma})$  donne les m mes r sultats que ceux obtenus avec  $K(q_T)$  jusqu'   $q_T < 140$  GeV environ avant de pr dire un taux d' v nement plus faible que celui attendu avec Diphox. Pour la distribution de  $M_{\gamma\gamma}$  les distributions obtenues avec  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$  sont pratiquement identiques, ainsi que celle obtenue avec  $K(q_T)$  (sauf pour les bas  $M_{\gamma\gamma}$ ), tandis qu'un K-facteur constant a tendance   surestimer le taux d' v nements. La distribution de  $\cos(\theta^*)$  de Diphox est le mieux reproduite avec  $K(q_T)$ . Madgraph peut donc  tre utilis  pour la repond ration du processus Born avec Diphox.

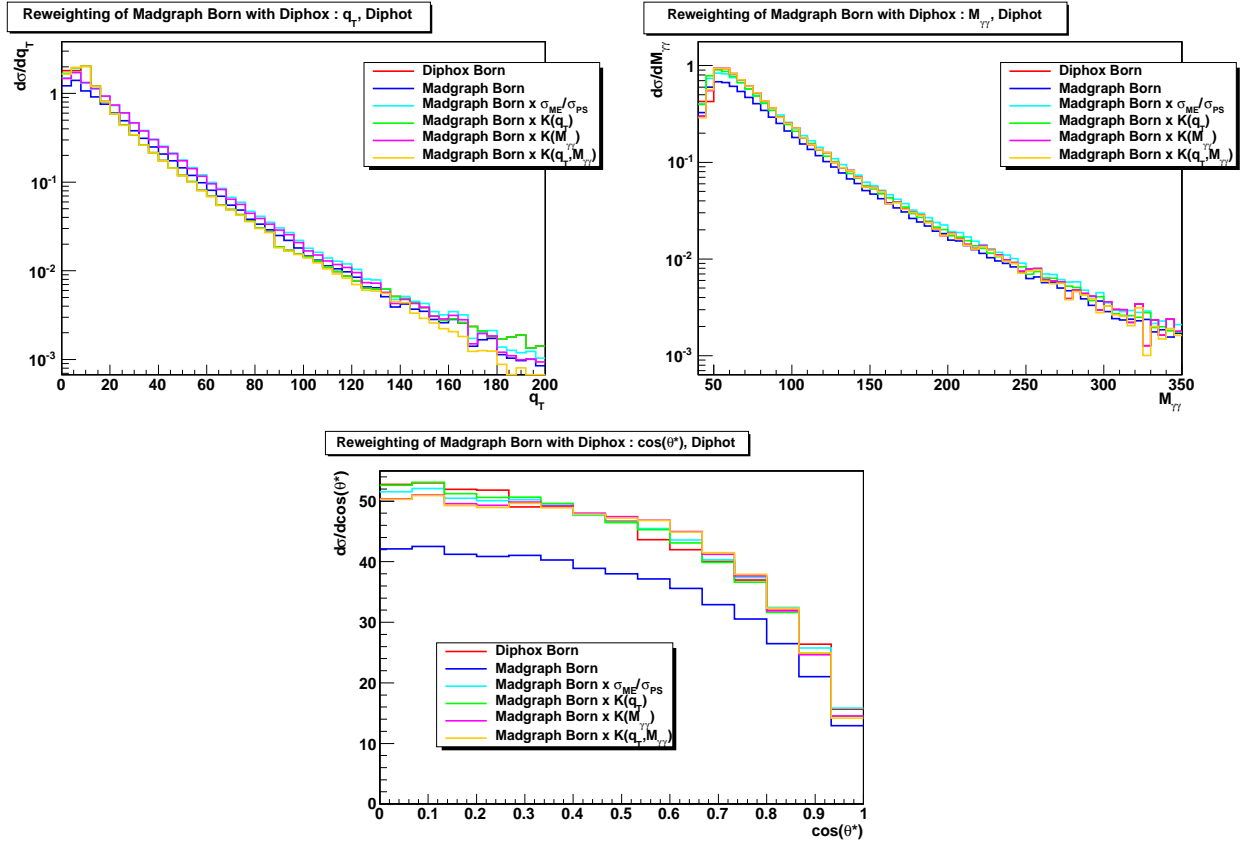


FIG. 7.27 – Distributions de  $q_T$  (en haut à gauche),  $M_{\gamma\gamma}$  (en haut à droite) et  $\cos(\theta^*)$  (en bas) pour le processus Born généré avec Diphox (fragmentations incluses), Madgraph et Madgraph repondéré avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .

### Repondération du processus Box

Pour repondérer le processus Box, nous disposons seulement de Pythia pour le générateur à gerbe partonique et de Gamma2MC au NLO pour le générateur à élément de matrices aux ordres supérieurs. La comparaison des distributions des sections efficaces différentielles  $q_T$  et  $M_{\gamma\gamma}$  pour Gamma2MC et Pythia est montrée figure 7.28 avec les K-facteurs associés. Pour la région  $10 < q_T < 60$  GeV, le K-facteur est inférieur à 1, ce qui peut s'expliquer par l'émission des gluons mous au LL avec Pythia. Au-delà le spectre est plus dur avec Gamma2MC du fait du jet dur supplémentaire au NLO. La distribution de masse invariante est très semblable pour Pythia et Gamma2MC avec un K-facteur proche de 1 sauf à bas  $M_{\gamma\gamma}$ . Comme précédemment pour le processus Born, nous avons posé un K-facteur constant pour les deux premières divisions des distributions du fait des divergences due au calcul à ordre fixe avec Gamma2MC.

On montre figure 7.29 le K-facteur en deux dimensions  $K(q_T, M_{\gamma\gamma})$  de Gamma2MC par rapport à Pythia pour le processus Box. Ici comme pour le processus Pythia Born, l'espace de phase est sous-peuplé. Les jets mous de Pythia ne parviennent pas à donner en même temps une haute impulsion transverse et une basse masse invariante au système diphoton.

Les résultats de la repondération pour le processus Pythia Box sont montrés figure 7.30. Le spectre en  $q_T$  est bien reproduit seulement avec  $K(q_T)$ . Le K-facteur  $K(q_T, M_{\gamma\gamma})$  ne suffit pas à reproduire correctement  $q_T$  dès  $q_T > 70$  GeV du fait de l'espace de phase sous-peuplé des événements Pythia. La distribution de masse invariante est plus molle avec  $K(q_T)$  qu'avec les autres K-facteurs.  $\cos(\theta^*)$  prédit par Gamma2MC est le mieux reproduit avec  $K(q_T)$ , mais au vu des problèmes évoqués,  $K(q_T)$  ne suffit pas à effectuer la repondération du processus Box.

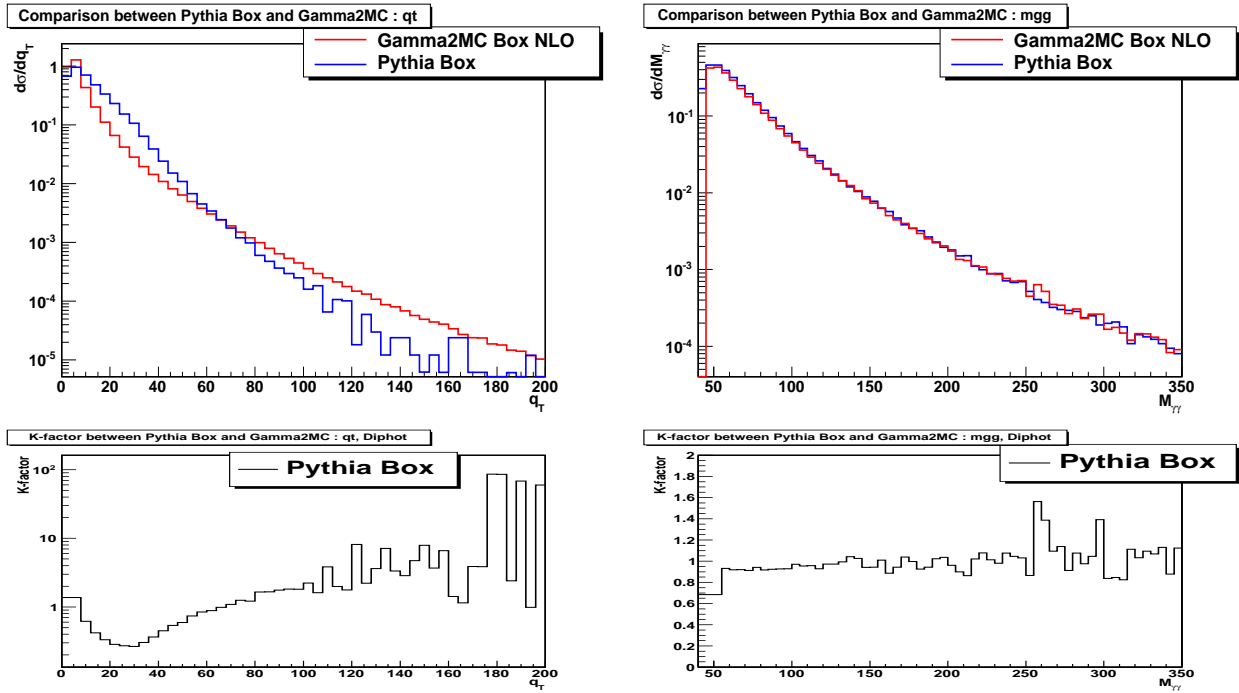


FIG. 7.28 – Sections efficaces différentielles en fonction de  $q_T$  (en haut à gauche) et  $M_{\gamma\gamma}$  (en haut à droite) du processus Box pour les générateurs Pythia et Gamma2MC, ainsi que les K-facteurs associés (en bas).

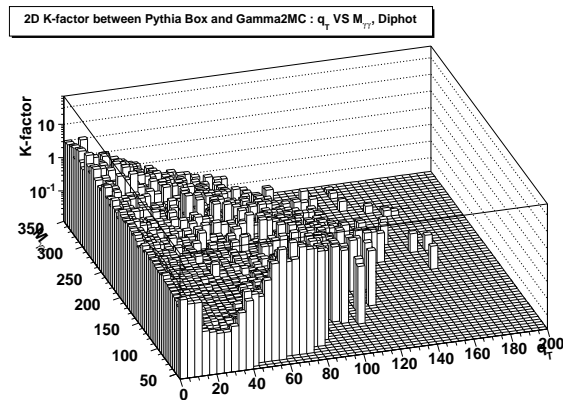


FIG. 7.29 – K-facteur en deux dimensions en fonction de  $q_T$  et  $M_{\gamma\gamma}$  pour le processus Box, pour le générateur Gamma2MC au NLO par rapport à Pythia.

### Repondération conjointe des processus Born et Box

Nous venons de voir que la repondération peut être effectuée pour le processus Born avec l'échantillon Madgraph, tandis que les échantillons Pythia Born et Box posent des problèmes de sous-population de l'espace de phase  $K(q_T, M_{\gamma\gamma})$  tandis que  $K(q_T)$  ou  $K(M_{\gamma\gamma})$  seuls ne suffisent pas. Il paraît dès lors naturel d'essayer de repondérer en même temps les processus Born Madgraph et Box Pythia avec Diphox et Gamma2MC, de sorte à profiter de l'espace de phase bien peuplé de Madgraph.

La figure 7.31 montre les effets de la repondération conjointe des processus Born Madgraph et Box Pythia avec Diphox (Born et fragmentations) et Gamma2MC (Box) au NLO. La distribution NLO de  $q_T$  est bien reproduite à l'aide des K-facteurs  $K(q_T)$  ainsi qu'avec  $K(q_T, M_{\gamma\gamma})$  jusqu'à  $q_T < 140$  GeV environ.  $K(q_T)$  sous-estime très légèrement le taux d'évènements prédit pour la distribution de masse invariante tandis que ce taux est prédit correctement avec les K-facteurs  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ . La distribution

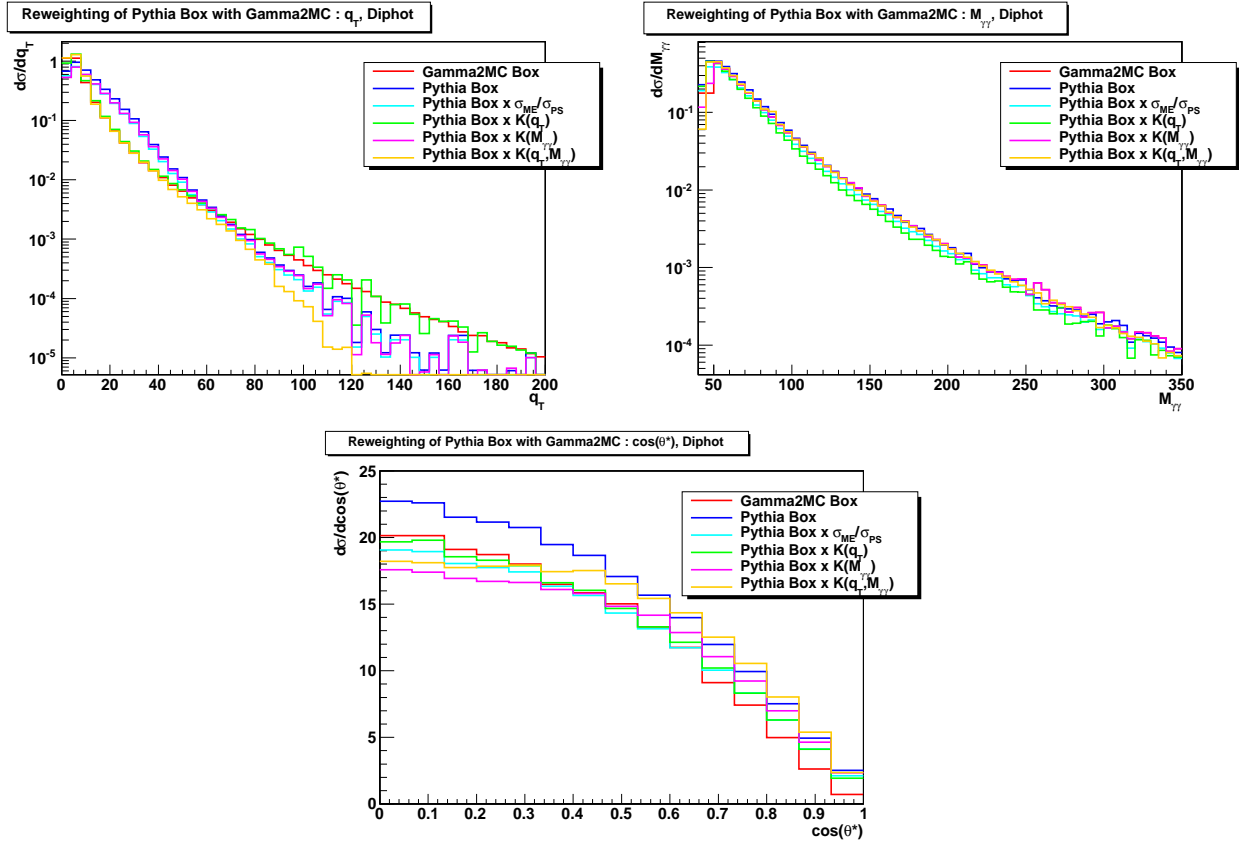


FIG. 7.30 – Distributions de  $q_T$  (en haut à gauche),  $M_{\gamma\gamma}$  (en haut à droite) et  $\cos(\theta^*)$  (en bas) pour le processus Box généré avec Gamma2MC, Pythia et Pythia repondéré avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .

de  $\cos(\theta^*)$  au NLO est le mieux reproduite avec  $K(q_T)$ , les K-facteurs  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$  ayant tendance à sous-estimer le taux d'événements à bas  $\cos(\theta^*)$  et à le surestimer dans la région  $\cos(\theta^*) > 0.5$ . En conclusion, la repondération conjointe des processus Born et Box peut être effectuée avec les échantillons officiels si l'échantillon Madgraph Born et Pythia Box sont utilisés. Si on ne s'intéresse qu'aux distributions de  $q_T$  et de  $M_{\gamma\gamma}$ , un K-facteur à deux dimensions  $K(q_T, M_{\gamma\gamma})$  peut être utilisé. Si on s'intéresse de plus à  $\cos(\theta^*)$ , on préférera repondérer ces échantillons avec  $K(q_T)$  seulement, quitte à sous-estimer légèrement le taux d'événements dans la distribution de  $M_{\gamma\gamma}$ .

Nous vérifions maintenant les effets de la repondération sur les autres variables cinématiques figure 7.32 pour  $Y_{\gamma\gamma}$ ,  $Y^*$  et figure 7.33 pour les impulsions transverses des photons. La distribution de  $Y_{\gamma\gamma}$  au NLO est bien reproduite quelle que soit le K-facteur utilisé et ne semble pas être une variable pertinente pour ce processus, ce qui justifie notre choix d'utiliser une autre variable que celle-ci pour la repondération. En revanche il est difficile de reproduire la distribution  $Y^*$  au NLO avec les différents K-facteurs. Il semble que le plus adapté soit  $K(q_T)$ , mais il n'est pas tout à fait suffisant pour les régions centrales. Les impulsions transverses des photons semblent relativement bien reproduites avec les K-facteurs essayés.

#### 7.4.2 Échantillons $\gamma\gamma+X$ repondérés pour la recherche du boson de Higgs

La repondération conjointe des échantillons Born Madgraph et Box Pythia a pour le moment été effectuée dans la région  $M_{\gamma\gamma} > 40$  GeV afin de préparer la comparaison des prédictions et des mesures des sections efficaces différentielles du processus  $\gamma\gamma+X$ . Le boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  est plutôt recherché dans la gamme de masse de masse invariante  $M_{\gamma\gamma} > 100$  GeV. Nous utiliserons donc les mêmes K-facteurs que calculés précédemment en nous restreignant à cette plage pour vérifier les propriétés ciné-

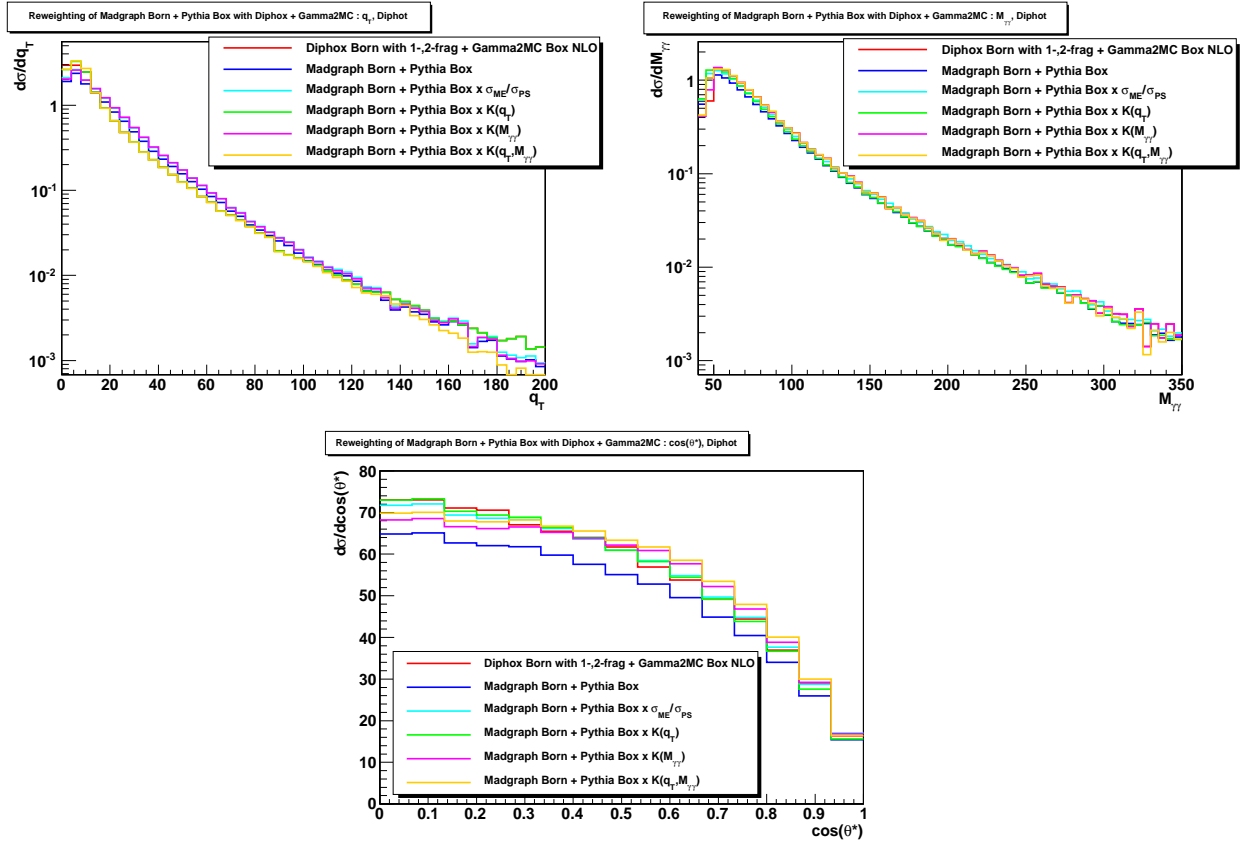


FIG. 7.31 – Distributions de  $q_T$  (en haut à gauche),  $M_{\gamma\gamma}$  (en haut à droite) et  $\cos(\theta^*)$  (en bas) pour le processus Born et Box généré avec DiphoX et Gamma2MC, Madgraph Born et Pythia Box sans et avec repondération avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .

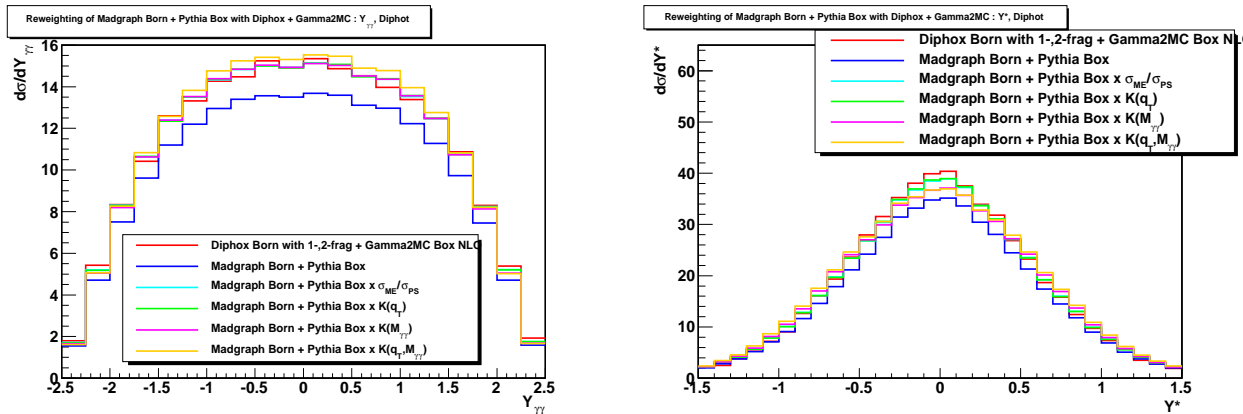


FIG. 7.32 – Distributions de  $Y_{\gamma\gamma}$  (en haut à gauche),  $Y^*$  (en haut à droite) pour le processus Born et Box généré avec DiphoX et Gamma2MC, Madgraph Born et Pythia Box sans et avec repondération avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .

matiques du processus  $\gamma\gamma+X$  avec et sans repondération pour la recherche du boson de Higgs.

Nous avons déjà vu figure 7.31 que la distribution de masse invariante au NLO dans cette zone est bien reproduite avec les K-facteurs  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$  tandis que  $K(q_T)$  a tendance à sous-estimer le taux d'évènements attendus. On montre figure 7.34 les effets de la repondération dans la gamme  $M_{\gamma\gamma} > 100$  GeV pour  $q_T$  et pour  $\cos(\theta^*)$ . Notons ici une fois de plus que la distribution NLO de  $q_T$  est bien reproduite avec les K-facteurs  $K(q_T)$  et  $K(q_T, M_{\gamma\gamma})$  jusqu'à  $q_T < 140$  GeV environ. Il est intéressant de noter que




FIG. 7.33 – Distributions de  $p_{T,lead}$  (à gauche),  $p_{T,trail}$  (à droite) pour le processus Born et Box généré avec Diphox et Gamma2MC, Madgraph Born et Pythia Box sans et avec repondération avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .

cette fois-ci, la distribution de  $\cos(\theta^*)$  est bien reproduite par  $K(q_T)$  et aussi par  $K(q_T, M_{\gamma\gamma})$ , ce qui signifie que nous pouvons utiliser avec confiance le K-facteur en deux dimensions  $K(q_T, M_{\gamma\gamma})$  pour la repondération de  $\gamma\gamma+X$  dans la zone de masse invariante où est recherché le boson de Higgs.




FIG. 7.34 – Distributions de  $q_T$  (à gauche),  $\cos(\theta^*)$  (à droite) pour le processus Born et Box généré avec Diphox et Gamma2MC, Madgraph Born et Pythia Box sans et avec repondération avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$  dans la gamme de recherche du boson de Higgs  $M_{\gamma\gamma} > 100$  GeV.

Nous effectuons enfin les dernières vérifications de mise sur les autres observables cinématiques, figure 7.35 pour les variables angulaires  $Y^*$  et  $Y_{\gamma\gamma}$  et figure 7.36 pour les impulsions transverses des photons. La distribution  $Y^*$  est soumise à des fluctuations statistiques et il semble difficile de conclure. En revanche,  $Y_{\gamma\gamma}$  est clairement le mieux repondérée avec  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$ .  $p_{T,trail}$  repondéré avec  $K(q_T, M_{\gamma\gamma})$  reproduit bien la distribution NLO tandis que  $p_{T,lead}$  au NLO est divergent dans la limite  $p_T \simeq 20$  GeV, ce qui fausse la comparaison avec les échantillons repondérés.

## 7.5 Repondération du processus $gg \rightarrow H \rightarrow \gamma\gamma$

Suivant la méthode de repondération [129] pour les processus de production du boson de Higgs  $gg \rightarrow H$ , nous utiliserons les variables d'impulsion transverse  $q_T$  et de rapidité  $Y_{\gamma\gamma}$  pour effectuer la repondération.  $q_T$  contient la plus grande partie de l'information sur les ordres supérieurs puisqu'au LO les deux photons



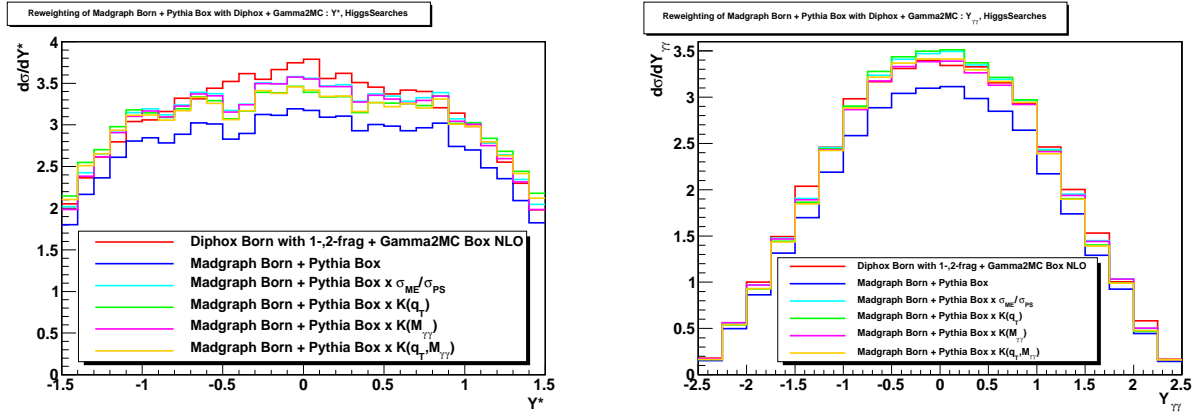


FIG. 7.35 – Distributions de  $Y^*$  (à gauche),  $Y_{\gamma\gamma}$  (à droite) pour le processus Born et Box généré avec Diphox et Gamma2MC, Madgraph Born et Pythia Box sans et avec repondération avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$  dans la gamme de recherche du boson de Higgs  $M_{\gamma\gamma} > 100$  GeV.

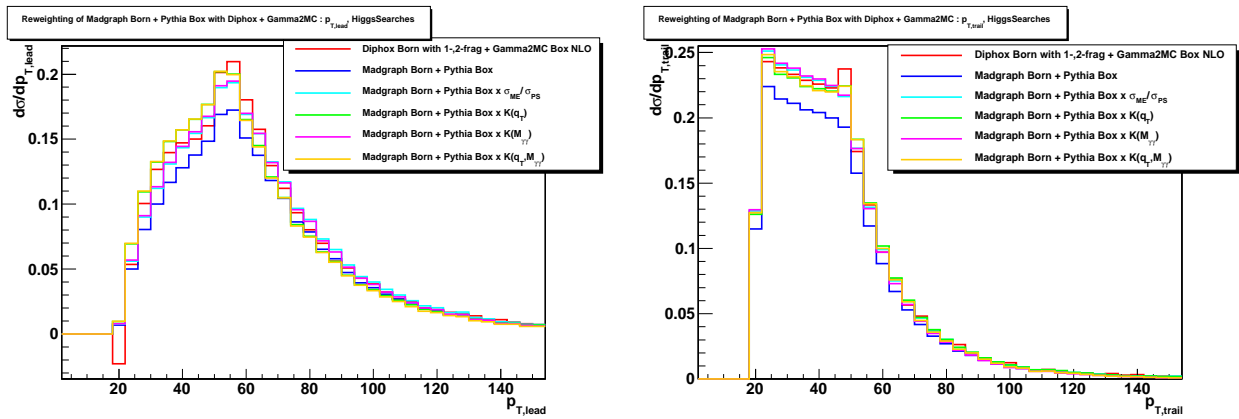


FIG. 7.36 – Distributions de  $p_{T,lead}$  (à gauche),  $p_{T,trail}$  (à droite) pour le processus Born et Box généré avec Diphox et Gamma2MC, Madgraph Born et Pythia Box sans et avec repondération avec  $K_{cte}$ ,  $K(q_T)$ ,  $K(M_{\gamma\gamma})$  et  $K(q_T, M_{\gamma\gamma})$  dans la gamme de recherche du boson de Higgs  $M_{\gamma\gamma} > 100$  GeV.

issus du boson de Higgs sont simplement dos-à-dos.  $Y_{\gamma\gamma}$  a aussi montré pouvoir aider à la reproduction des distributions aux ordres supérieurs. Afin de tirer parti des connaissances actuelles du processus  $gg \rightarrow H \rightarrow \gamma\gamma$ , nous aimerions repondérer les événements générés par MC@NLO avec les distributions NNLO calculées par HNNLO.

Nous comparerons toutefois certaines distributions avec celles obtenues avec le générateur Pythia. Au niveau partonique, nous avons utilisé les critères suivants pour HNNLO :  $p_T > 20$  GeV et  $|\eta| < 2.5$  pour les deux photons. Le critère d'isolation appliqué demande une énergie transverse partonique  $E_T < 5$  GeV dans un cône  $\Delta R < 0.3$  autour de chaque photon. Au niveau générateur pour Pythia et MC@NLO, nous demandons les mêmes critères d'impulsion transverse et de pseudo-rapidité, mais le critère d'isolation demande que l'énergie transverse de toutes les particules de statut 1 soit inférieure à 7 GeV dans un cône de  $\Delta R < 0.3$  (nous avons montré plus haut que les 2 GeV de différence étaient du à la prise en compte de l'évènement sous-jacent et de l'hadronisation).

### 7.5.1 Détermination des K-facteurs

Nous avons tout d'abord considérés deux générateurs à gerbe partonique, Pythia au LO et MC@NLO au NLO, dont nous comparons les distributions d'impulsion transverse  $q_T$  et de rapidité  $Y_{\gamma\gamma}$  avec celles de

HNNLO au NNLO figure 7.37. Les sections efficaces différentielles et K-facteurs pour Pythia sont montrés seulement à titre de comparaison. Nous montrons aussi les K-facteurs associés à ces deux distributions. Il nous a paru nécessaire de rassembler la région  $0 < q_T < 16$  GeV dans une seule division, car dans la limite  $q_T \rightarrow 0$ , le générateur HNNLO effectuant ses calculs à ordre fixe renvoie un résultat divergent. Nous préférons utiliser un K-facteur plat dans cette région et variant par divisions de 4 GeV ailleurs.

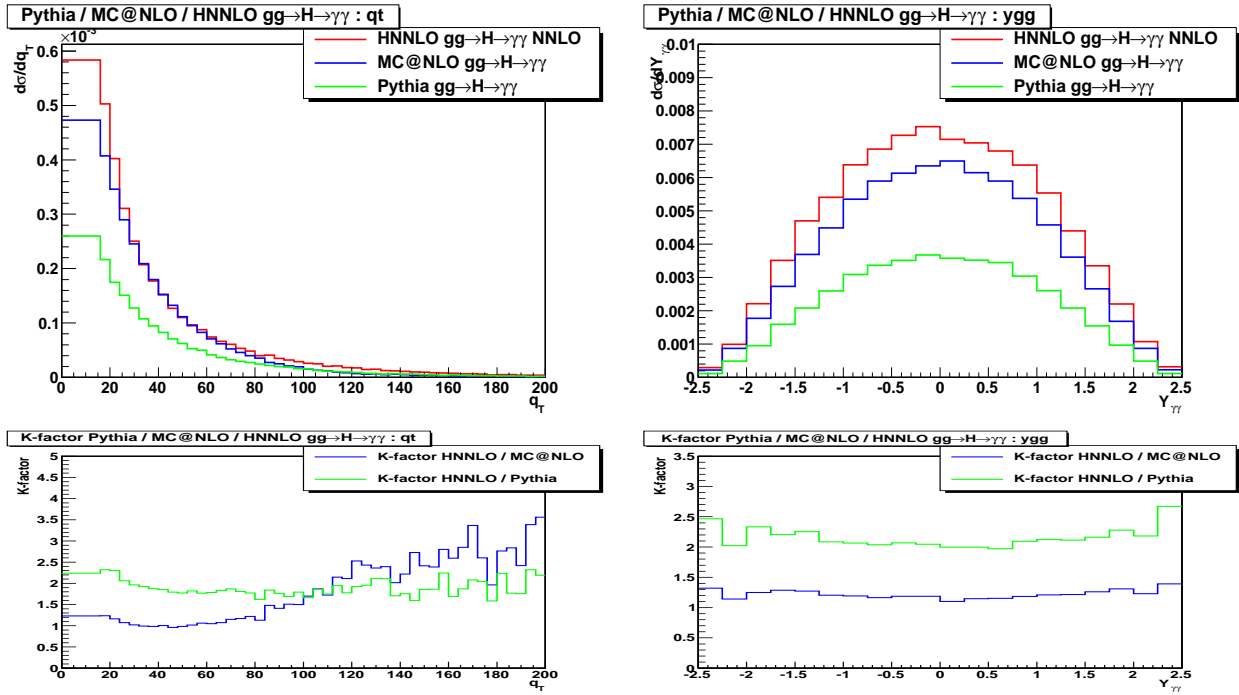


FIG. 7.37 – Sections efficaces différentielles en fonction de  $q_T$  (en haut à gauche) et  $Y_{\gamma\gamma}$  (en haut à droite) du processus  $gg \rightarrow H\gamma\gamma$  pour les générateurs Pythia, MC@NLO et HNNLO au NNLO, ainsi que les K-facteurs associés (en bas).

Pour les critères de sélection choisis, les K-facteurs globaux sont de l'ordre de 1,2 pour MC@NLO et 2,2 pour Pythia. En fonction de l'impulsion transverse  $q_T$ , le K-facteur  $K(q_T)$  n'est pas plat. Dans la zone  $20 < q_T < 70$  GeV, la forme des spectres obtenus avec Pythia et MC@NLO est plus dure que celle obtenue avec HNNLO. Ceci peut être expliqué par les radiations de gluons mous dans l'état initial pris en compte au LL dans ces générateurs à gerbe partonique. Au-delà, le spectre prédit par HNNLO est plus dur que celui de MC@NLO et surtout celui de Pythia, ce qui s'explique par le fait que HNNLO au NNLO génère au jusqu'à deux jets durs supplémentaires, tandis que MC@NLO un seul et Pythia aucun. En revanche le K-facteur  $K(Y_{\gamma\gamma})$  est pratiquement plat sur toute la gamme de rapidité étudiée. Il est le plus faible pour des rapidités centrales et le plus élevé à l'avant et à l'arrière. Ceci est plus sensible pour Pythia que pour MC@NLO.

Le K-facteur en deux dimensions  $K(q_T, Y_{\gamma\gamma})$  est montré figure 7.38 pour MC@NLO seulement, puisque nous souhaitons effectuer la repondération de MC@NLO avec HNNLO. On peut observer que pour  $q_T > 100$  GeV, le manque de statistique dans l'échantillon MC@NLO donne de grande fluctuations sur les valeurs des K-facteurs. Un traitement approprié de ces fluctuations nécessiterait la production d'un échantillon MC@NLO disposant de plus de statistique. La réduction des divisions en  $q_T$  pour cette région ne résoud pas le problème. Nous avons donc choisi d'utiliser ce K-facteur pour le moment, et de nous concentrer sur la région  $q_T < 100$  GeV (comme il en sera de même au chapitre 9).

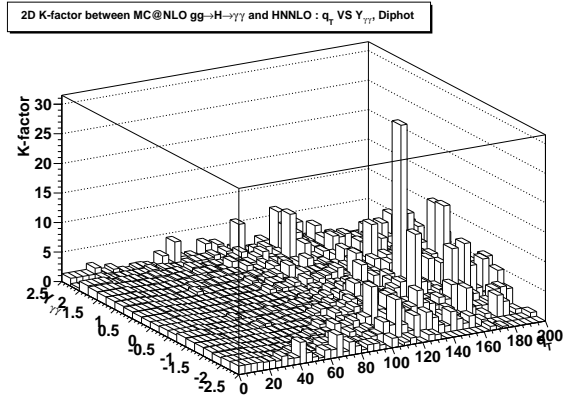


FIG. 7.38 – K-facteur en deux dimensions en fonction de  $q_T$  et  $Y_{\gamma\gamma}$  pour le processus  $gg \rightarrow H\gamma\gamma$  pour le g n rateur HNNLO au NNLO par rapport   MC@NLO.

### 7.5.2 Application des K-facteurs

Les K-facteurs que nous venons de calculer pour la repond ration de MC@NLO avec HNNLO vont maintenant  tre appliqu s aux  v nements g n r s avec MC@NLO. Le but de l'op ration est de s'assurer que les distributions MC@NLO repond r es reproduisent fid lement les distributions NNLO.

Les distributions de  $q_T$  et  $Y_{\gamma\gamma}$  obtenues avec MC@NLO avant et apr s l'application des K-facteurs  $K_{cte} = \sigma_{HNNLO}/\sigma_{MC@NLO}$  (les deux sections efficaces calcul es apr s crit res de s lection),  $K(q_T)$ ,  $K(Y_{\gamma\gamma})$  et  $K(q_T, Y_{\gamma\gamma})$  sont montr es figure 7.39 et compar es avec les distributions HNNLO. Evidemment, les distributions de  $q_T$  avec HNNLO et MC@NLO repond r e par  $K(q_T)$  se retrouvent superpos es, de m me que HNNLO et MC@NLO repond r e par  $K(Y_{\gamma\gamma})$  pour la distribution  $Y_{\gamma\gamma}$ .

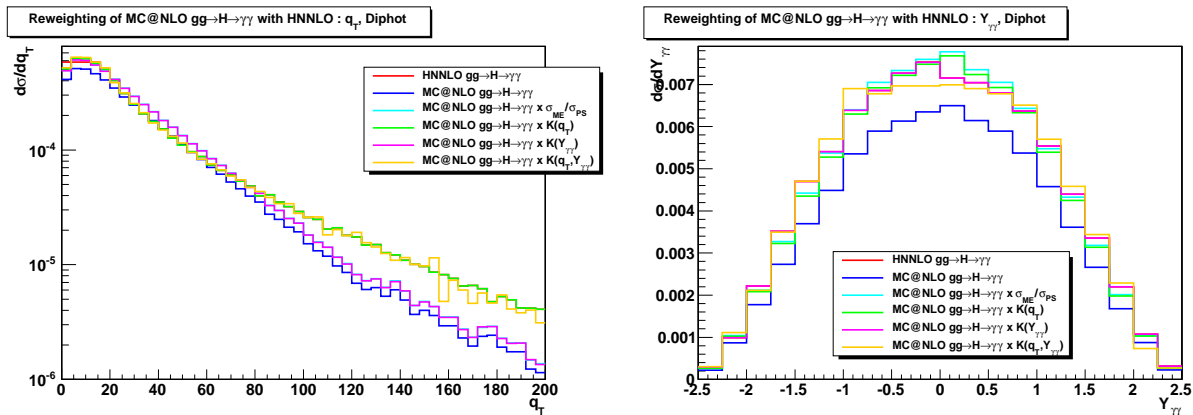


FIG. 7.39 – Sections efficaces diff rentielles en fonction de  $q_T$  (  gauche) et  $Y_{\gamma\gamma}$  (  droite) du processus  $gg \rightarrow H\gamma\gamma$  pour les g n rateurs HNNLO, MC@NLO et MC@NLO repond r es.

On observe que la distributions HNNLO de  $q_T$  est bien reproduite par MC@NLO repond r e avec  $K(q_T, Y_{\gamma\gamma})$ . Pour cette m me repond ration   2 dimensions, la distribution  $Y_{\gamma\gamma}$  est moins bien rendue pour les r gions centrales de rapidit  (sous-estimation), qui sont corr l es   la zone  $0 < q_T < 16$  GeV qui dispose d'un K-facteur constant. D'autre part, la partie centrale de la distribution  $Y_{\gamma\gamma}$  est aussi surestim e en utilisant seulement le K-facteur  $K(q_T)$  tandis qu'il y a sous-estimation pour les parties avant et arri re.  $K(Y_{\gamma\gamma})$  et le K-facteur global ne permettent pas de reproduire la distribution de  $q_T$  avec HNNLO.

### 7.5.3 RepondÉration appliquée aux autres observables

On montre les distributions de  $\cos(\theta^*)$ ,  $Y^*$ ,  $p_{T,lead}$ ,  $p_{T,trail}$  avec et sans repondÉration figure 7.40 et 7.41. Les distributions  $\cos(\theta^*)$  et  $Y^*$  gÉnÉrÉe avec HNNLO sont relativement bien reproduites par tous les K-facteurs essayés. En revanche les distributions d'impulsion transverse propres à chaque photon montrent un léger désaccord pour les valeurs les plus proches de  $p_T \simeq m_H/2$  et le spectre repondÉrÉ reste légèrement plus mou que le spectre NNLO.




FIG. 7.40 – Sections efficaces différentielles en fonction de  $\cos(\theta^*)$  (à gauche) et  $Y^*$  (à droite) du processus  $gg \rightarrow H\gamma\gamma$  pour les générateurs HNNLO, MC@NLO et MC@NLO repondÉrÉes.




FIG. 7.41 – Sections efficaces différentielles en fonction de l'impulsion transverse  $p_{T,lead}$  du photon de plus haut  $p_T$  (à gauche) et  $p_{T,trail}$  du photon de plus bas  $p_T$  (à droite) du processus  $gg \rightarrow H\gamma\gamma$  pour les générateurs HNNLO, MC@NLO et MC@NLO repondÉrÉes.

En conclusion de cette étude de la repondÉration des événements gÉnÉrÉs avec MC@NLO pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  avec HNNLO, une repondÉration avec le K-facteur  $K(q_T, Y_{\gamma\gamma})$  devrait être utilisée parce qu'elle décrit  $q_T$  aussi bien que mieux tant  $q_T$  que  $K(q_T)$  et donne une meilleure description de  $Y_{\gamma\gamma}$ . Il subsiste quelques différences pour les distributions d'impulsion transverse des photons.

## 7.6 Conclusion et perspectives sur la repondÉration

Nous avons présenté dans ce chapitre une étude des propriétés cinématiques aux ordres supérieurs ainsi que la repondÉration au NLO des processus  $\gamma\gamma+X$  et NNLO du processus  $gg \rightarrow H \rightarrow \gamma\gamma$ .

Les critères de sélection appliqués au niveau partonique et au niveau générateur ont été choisis à partir des critères usuellement utilisés pour l'identification des photons dans CMS. Pour déterminer le critère d'isolation au niveau partonique, l'évènement sous-jacent/hadronisation a été soustrait dans des échantillons générés spécialement par nos soins et sa contribution à l'énergie transverse déposée dans un cône  $\Delta R < 0.3$  autour des photons a été évaluée à 2 GeV. Des critères reconstruits demandant  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV,  $TrackerIso < 2$  GeV et  $H/E < 0.05$  dans un cône  $\Delta R < 0.3$  équivalent à demander un critère niveau générateur  $GenIso < 7$  GeV avec évènement sous-jacent/hadronisation ou  $GenIso < 5$  GeV sans. Nous avons aussi choisi ce critère au niveau partonique pour les codes Diphox, Gamma2MC et HNNLO dans la mesure où il nous a semblé difficile d'évaluer la contribution de la gerbe partonique ISR/FSR sur l'énergie d'isolation. Une autre étude possible consisterait à refaire ce travail avec le critère de Frixione [164] permettant la suppression des composantes de fragmentations.

Nous avons par la suite examiné les différentes observables cinématiques des processus  $\gamma\gamma+X$  jusqu'au NLO avec Diphox pour les contributions Born et fragmentations simple et double et Gamma2MC pour la contribution Box, et du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  jusqu'au NNLO avec HNNLO. Les incertitudes théoriques liées aux densités partoniques et aux échelles d'énergie ont été évaluées. Les incertitudes théoriques sur le processus  $\gamma\gamma+X$  évaluées de la manière habituelle (essai avec un autre ensemble de densités partoniques et division/multiplication par deux des échelles d'énergie) sont plus importantes pour Gamma2MC que pour Diphox, et plus importante au LO qu'au NLO, ce qui semble aller dans le sens d'une convergence de la série perturbative de QCD. La somme des contributions de Diphox et Gamma2MC au NLO donne une incertitude systématique due aux densités partoniques d'environ 3,5% et de 3% due aux échelles d'énergie. Avec HNNLO au NNLO, la variation des échelles d'énergie donne une incertitude d'environ 10% (contre environ 20% au NLO) et de 3,5% pour l'incertitude due aux densités partoniques. Les variables discriminantes entre signal et le bruit de fond ont été examinées, et il a été trouvé que les plus intéressantes sont la masse invariante  $M_{\gamma\gamma}$ , l'impulsion transverse du système diphoton  $q_T$  ainsi que les distributions angulaires  $\cos(\theta^*)$  et  $Y^*$ . Les impulsions transverses des photons ont aussi un pouvoir discriminant mais elles ne peuvent pas être utilisées dans une analyse de recherche du boson de Higgs (qui ne serait pas basée sur des coupures séquentielles), car elles sont corrélées à la masse invariante, comme on le verra au chapitre 9. Nous avons aussi effectué quelques études préliminaires sur Resbos que nous n'avons pas présenté ici.

Nous avons ensuite investigué la possibilité d'une repondération des évènements générés avec des générateurs à gerbe partonique pour prendre en compte les effets cinématiques dus aux ordres supérieurs de la série perturbative de QCD. Une repondération à l'aide de K-facteurs constants et dépendant d'une et deux variables ont été essayées. Pour le processus  $\gamma\gamma+X$ , nous avons trouvé que les échantillons Pythia seuls ne pouvaient pas être utilisés du fait de la sous-population de l'espace de phase. Nous avons retenu l'option de repondération conjointe de l'échantillon Madgraph Born (dont l'espace de phase est suffisamment peuplé) et de l'échantillon Pythia Box avec Diphox et Gamma2MC au NLO à l'aide d'un K-facteur en deux dimensions  $K(q_T, M_{\gamma\gamma})$ . Ce choix fonctionne pour les principales observables dans la région  $M_{\gamma\gamma} > 100$  GeV où est recherché le boson de Higgs et peut donc être utilisé pour la prédiction du bruit de fond dans une analyse de recherche d'un boson de Higgs léger. En revanche, ce choix présente quelques difficultés si on élargit l'espace de phase à  $M_{\gamma\gamma} > 40$  GeV, en particulier pour la distribution de  $\cos(\theta^*)$ , tandis que  $K(q_T)$  ne suffit pas à reproduire la distribution NLO de  $M_{\gamma\gamma}$  et que  $K(M_{\gamma\gamma})$  ne suffit pas à reproduire la distribution de  $q_T$ . Cette région  $M_{\gamma\gamma} > 40$  GeV est d'intérêt pour la comparaison des prédictions théoriques des sections efficaces différentielles du processus  $\gamma\gamma+X$  avec l'expérience. Si l'on souhaite donc comparer théorie et expérience pour ce processus, nous prescririons plutôt d'utiliser un K-facteur différent propre à chaque observable mesurée ( $K(q_T)$  pour la comparaison du spectre de  $q_T$ , de même pour chaque variable). Des K-facteurs dépendant d'autres variables pourraient être essayées (notamment  $\cos(\theta^*)$  et  $Y^*$ ), voire même un K-facteur dépendant de trois variables, si la statistique des échantillons le permet. Une autre solution, si l'on veut utiliser la repondération dans une analyse utilisant les mêmes critères de sélection que D0 [132] pour la mesure des sections efficaces différentielles, consisterait à se restreindre à la région  $q_T < M_{\gamma\gamma}$  qui elle est peuplée correctement avec les échantillons Pythia une fois une grande statistique générée. Pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ , nous avons effectué la repondération de

l'échantillon MC@NLO avec le K-facteur à deux dimensions  $K(q_T, Y_{\gamma\gamma})$  au NNLO calculé avec HNNLO. Un K-facteur en deux dimensions n'apporte pas beaucoup plus d'information des ordres supérieurs que le K-facteur  $K(q_T)$ , comme déjà noté référence [129].

Un des problèmes rencontrés lors de la repondération est le manque de statistique dans les échantillons générés avec les générateurs à gerbe partonique. Les K-facteurs obtenus ne sont pas lisses et un plus grand nombre d'évènements mériterait d'être généré pour les lisser. Ceci est plus aisé à accomplir au niveau générateur qu'à mettre dans la pratique au niveau reconstruit (si l'on veut prendre en compte les K-facteurs dans une analyse), où le temps de calcul nécessaire à la simulation du détecteur devrait rendre la tâche assez longue si l'on souhaite par exemple 20 millions d'évènements par échantillon. Une autre possibilité pour régler ce problème serait d'effectuer une repondération en utilisant moins de divisions pour les spectres de  $q_T$  et  $M_{\gamma\gamma}$ . Il faudrait alors vérifier l'effet du nombre de divisions sur la précision de la repondération, en fonction du nombre de divisions qu'on choisirait pour une analyse de mesure du processus  $\gamma\gamma+X$  ou de recherche du boson de Higgs à une luminosité donnée. Enfin, il y aurait possibilité d'effectuer un ajustement des K-facteurs pour les lisser ; mais leur application nécessiterait de même un grand nombre d'évènements au niveau reconstruit.

Le point faible de la méthode de repondération est le traitement inapproprié des jets mous supplémentaires présents dans les échantillons avec gerbe partonique. Après repondération des évènements, les distributions des variables cinématiques repondérées sont proches des distributions aux ordres supérieurs attendues. Toutefois, la cinématique événement par événement reste celle des générateurs à gerbe partonique, avec un processus dur ayant la précision LO et une gerbe à la précision LL. Ce paradoxe pourrait avoir des conséquences difficilement si des critères supplémentaires d'isolation sont demandés après repondération dans les analyses au niveau reconstruit. Un autre point posant question est le fait que nous avons utilisé un échantillon Madgraph Born avec jusqu'à deux jets durs supplémentaires par événement pour la repondération. Jusqu'à deux jets durs sont bien présents événement par événement, tandis que nous repondérons les évènements avec des distributions NLO qui ne proposent que jusqu'à un jet dur supplémentaire par événement.

Enfin, il serait intéressant d'effectuer la repondération pour les autres mécanismes de production du boson de Higgs, la fusion de gluons étant le plus important mais pas le seul à contribuer à la section efficace totale au LHC.

Au chapitre 8 nous discuterons de l'intégration de la repondération dans les analyses de mesure du processus  $\gamma\gamma+X$ , et au chapitre 9 nous intégrerons la repondération dans l'analyse de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$ .

## Chapitre 8

# Préparation pour la mesure de la section efficace du processus $\gamma\gamma+X$

Le processus  $\gamma\gamma+X$  de production d'une paire de photons directs lors de l'interaction dure est un bruit de fond irréductible pour de nombreux signaux se désintégrant en paire de photons qui n'ont pas encore été observé à ce jour : boson de Higgs, excitation du graviton dans des modèles avec dimensions supplémentaires, non-particules, états supersymétriques par exemple. La mesure précise de la section efficace du processus  $\gamma\gamma+X$  en fonction des différentes observables cinématiques qui le décrivent devrait permettre d'accroître la sensibilité des analyses de recherche de nouvelle physique. L'étude de ce processus revêt aussi un grand intérêt du point de vue théorique. Les données de CDF [130] et D0 [132] montrent des désaccords avec les prédictions NLO de Diphox [110] et Resbos [109] pour certaines régions de l'espace de phase. La production d'une paire de photons prompts par interaction dure implique plusieurs sous-processus : le processus "Born", les processus de fragmentation simple ou double et le processus "Box". La composante de fragmentation est un processus non-perturbatif qui pose aujourd'hui encore un problème théorique : il n'existe pas de code NLO incluant une fonction de double fragmentation d'un quark en deux photons.

Comme pour la mesure de la section efficace  $\gamma+X$ , les analyses de D0 et CDF utilisent la méthode des templates pour la mesure de la section efficace  $\gamma\gamma+X$ . Etant donné que la section efficace de production des diphotons est supprimée d'environ trois ordres de grandeurs par rapport à celle d'un seul photon, le pouvoir discriminant de l'analyse (et des variables templates) doit être plus grand. Le processus  $\gamma+X$  devient un bruit de fond pour cette analyse, ce qui complique aussi l'estimation du nombre d'évènements de signal par la méthode des templates. Comme variable de template, D0 utilise la sortie d'un réseau de neurone basé sur des variables d'isolation et de forme du cluster, tandis que CDF utilise l'énergie d'isolation dans le trajectographe (c'est la première fois que cette variable est utilisée en tant que template). Les deux analyses utilisent une méthode de templates de type 2 divisions basées sur l'inversion d'une matrice  $4 \times 4$  qui fournit la composition des données en évènements 2 photons prompts, 1 photon prompt 1 photon mal identifié et 2 photons mal identifiés.

Nous entamerons ce chapitre avec la prédiction du nombre d'évènements de signal attendus, donnés par les générateurs à éléments de matrices Diphox [110] et Gamma2MC [111]. Nous exposerons ensuite la sélection effectuée sur les photons et la configuration du réseau de neurones de discrimination  $\gamma/\pi^0$  dont nous utiliserons la sortie en tant que distribution template pour le signal et les bruits de fond. Les méthodes de templates à plusieurs divisions et à ajustement spécifiques à la détermination de la composition des données pour le processus  $\gamma\gamma+X$  seront ensuite expliquées, avant d'être appliquées à la simulation pour une luminosité intégrée de  $10 \text{ pb}^{-1}$ , pour laquelle une première mesure des spectres cinématiques du processus  $\gamma\gamma+X$  sera possible. Pour la comparaison entre la théorie et l'expérience, nous proposerons la repondération comme alternative à la méthode des corrections des inefficacités du détecteur. Enfin, nous analyserons les premiers évènements diphotons dans les données, dans une démarche de réduction progressive des bruits de fond. Une première mesure sera effectuée dans les données.

## 8.1 Signal $\gamma\gamma+X$ attendu

Pour la détermination des sections efficaces du processus  $\gamma\gamma+X$ , les programmes Diphox et Gamma2MC ont été utilisés. Ces générateurs ont déjà été décrit en détail section 3.1 et leurs propriétés ont été résumés section 7.1.1. Nous utilisons Diphox (description NLO des processus Born et de fragmentations) en combinaison avec Gamma2MC (NLO Box).

La figure 8.1 montre les sections efficaces  $\gamma\gamma+X$  attendues au LO et au NLO pour différentes énergies dans le centre de masse. Le résultat donné est la somme des contributions Born, de fragmentation simple et double (calculées avec Diphox) et de la contribution Box (calculée avec Gamma2MC), pour les énergies dans le centre de masse différentes de 900 GeV. A 900 GeV, la contribution Box a été calculée avec Diphox car Gamma2MC ne fournissait pas de résultat, et est donc calculée au LO seulement. Une coupure relativement basse en impulsion transverse  $p_T > 5$  GeV a été mise en oeuvre, afin d'obtenir une estimation la plus large possible du taux d'événements attendus (même si pour l'analyse les critères de sélection seront relevés). La section efficace NLO est toujours supérieure à la section efficace LO et leur rapport est de l'ordre de 1,5 à 2 selon les coupures et l'énergie dans le centre de masse. Comme attendu, les sections efficaces augmentent lorsque l'énergie dans le centre de masse augmente.




FIG. 8.1 – Sections efficaces  $\gamma\gamma+X$  attendues au LO et au NLO en fonction de l'énergie dans le centre de masse, pour des photons ayant une impulsion transverse  $p_T > 5$  GeV, et différents seuils en masse invariante.

Afin d'effectuer une première analyse des données avec une énergie de 7 TeV dans le centre de masse, un critère de sélection plus réaliste sur l'impulsion transverse  $p_T > 15$  GeV a été appliquées lors de la génération, ce qui réduit drastiquement (réduction par un facteur 10) les sections efficaces comme on peut le voir tableau 8.2. Nous avons aussi reporté dans le tableau les sections efficaces obtenues avec des critères de sélection typiques pour la mesure de la section efficace  $\gamma\gamma+X$  avec  $10 \text{ pb}^{-1}$  de luminosité,  $M_{\gamma\gamma} > 40$  GeV,  $p_T > 20$  GeV et une isolation partonique  $GenIso < 5$  GeV dans un cône  $\Delta R < 0.3$  pour chacun des photons.



Coupages	$\sigma_{Born+Frag}$ (pb)	$\sigma_{Box}$ (pb)	Total (pb)
$M_{\gamma\gamma} > 20$ GeV, $p_T > 5$ GeV	1957.15	299.47	2256.62
$M_{\gamma\gamma} > 20$ GeV, $p_T > 15$ GeV	176.87	33.65	210.52
$M_{\gamma\gamma} > 40$ GeV, $p_T > 20$ GeV, $GenIso < 5$ GeV	42.59	12.89	55.48

FIG. 8.2 – Sections efficaces NLO  $\gamma\gamma+X$  pour les premières données, calculées avec Diphox pour les processus Born et fragmentations, et Gamma2MC pour les processus Box.

## 8.2 Mesure de la section efficace $\gamma\gamma+X$ par la méthode des “templates” dans la simulation

La mesure de la section efficace du processus  $\gamma\gamma+X$  suit le même schéma que pour la section efficace  $\gamma+X$  exposé chapitre 6. Dans un premier temps, les distributions templates du signal  $\gamma\gamma$  et des bruits de fonds  $\gamma+jet$  et dijet sont construites à partir de la simulation. Une méthode de templates est alors appliquée dans les données pour mesurer la pureté et le nombre d'évènements de signal. Ce nombre d'évènements devrait être corrigé pour les inefficacités de détection et divisé par la luminosité, avant de pouvoir être comparé aux prédictions théoriques.

### 8.2.1 Méthode des “templates” pour $\gamma\gamma+X$

Pour mesurer la pureté et le nombre d'évènements du processus  $\gamma+X$ , nous avons utilisé deux méthodes de templates : la méthode à deux divisions et la méthode d'ajustement du maximum de vraisemblance. Pour cela, nous avons construit une distribution template pour le signal (photons prompts ISR/FSR ou partoniques) et pour le bruit de fond (tous les autres photons). Les mêmes techniques peuvent être utilisées pour le processus  $\gamma\gamma+X$ . A la différence de la mesure du processus  $\gamma+X$ , il y a maintenant un signal (deux photons prompts) et deux bruits de fonds (deux photons faux, un photon faux et un photon prompt). Les techniques doivent donc être aménagées pour la mesure de la pureté des diphotons.

#### Méthodes à deux ou trois divisions

La première possibilité de mesure par la méthode des templates consiste à utiliser la technique **deux divisions** (voir section 6.2.3). Il convient alors de construire la distribution template du signal en utilisant les évènements avec deux photons prompts ( $\gamma\gamma$ ), et la distribution template du bruit de fond avec tous les autres évènements : deux photons faux ( $jj$ ), un photon faux et un photon prompt ( $\gamma j$ ). Un critère de sélection sur la variable template est alors appliqué, qui permet de connaître les efficacités du signal et du bruit de fond et d'en déduire la pureté et le nombre d'évènements avant coupure.

Etant donné la présence de deux processus de bruits de fond pour un processus de signal, un raffinement de cette méthode peut être imaginé. Dans la méthode deux divisions, le résultat était donné par la résolution d'un système à deux équations avec deux inconnues. Ici, il est possible d'écrire un système de trois équations avec trois inconnues de la manière suivante (méthode **trois divisions**) :

$$\begin{aligned}
 N &= N_{\gamma\gamma} + N_{\gamma j} + N_{jj} \\
 \epsilon_1^{data} N &= \epsilon_1^{\gamma\gamma,MC} N_{\gamma\gamma} + \epsilon_1^{\gamma j,MC} N_{\gamma j} + \epsilon_1^{jj,MC} N_{jj} \\
 \epsilon_2^{data} N &= \epsilon_2^{\gamma\gamma,MC} N_{\gamma\gamma} + \epsilon_2^{\gamma j,MC} N_{\gamma j} + \epsilon_2^{jj,MC} N_{jj}
 \end{aligned}$$

Où  $N$  est le nombre d'évènements dans les données après préselection,  $N_{\gamma\gamma}$ ,  $N_{\gamma j}$  et  $N_{jj}$  le nombre d'évènements avec deux photons prompts, un prompt et un faux, et deux faux après préselection. Un premier critère de sélection sur la variable template est appliqué avec une efficacité  $\epsilon_1^{data}$  dans les données,  $\epsilon_1^{\gamma\gamma,MC}$  pour les évènements  $\gamma\gamma$ ,  $\epsilon_1^{\gamma j,MC}$  pour  $\gamma j$  et  $\epsilon_1^{jj,MC}$  pour  $jj$  sur les distributions templates. De même pour un deuxième critère de sélection donnant lieu aux efficacités  $\epsilon_2^{data}$ ,  $\epsilon_2^{\gamma\gamma,MC}$ ,  $\epsilon_2^{\gamma j,MC}$ ,  $\epsilon_2^{jj,MC}$ . Ce système à

trois équations et trois inconnues peut être réécrit de manière matricielle afin de simplifier le calcul :

$$\mathbf{B} = \mathbf{A} * \mathbf{X}$$

La matrice  $A$  contient les efficacités de la simulation :

$$\mathbf{A} = \begin{pmatrix} 1 & 1 & 1 \\ \epsilon_1^{\gamma\gamma,MC} & \epsilon_1^{\gamma j,MC} & \epsilon_1^{jj,MC} \\ \epsilon_2^{\gamma\gamma,MC} & \epsilon_2^{\gamma j,MC} & \epsilon_2^{jj,MC} \end{pmatrix}$$

La matrice  $B$  contient les efficacités dans les données :

$$\mathbf{B} = \begin{pmatrix} 1 \\ \epsilon_1^{data} \\ \epsilon_2^{data} \end{pmatrix}$$

L'inconnue est le vecteur  $X$  contenant les puretés :

$$\mathbf{X} = \begin{pmatrix} N_{\gamma\gamma}/N \\ N_{\gamma j}/N \\ N_{jj}/N \end{pmatrix}$$

La solution du système d'équation est donnée par :  $X = A^{-1}.B$ . La question est alors de savoir comment calculer correctement l'erreur sur les puretés, i.e.  $\Delta X$ . En différenciant la solution :

$$\Delta X = \Delta A^{-1}.B + A^{-1}.\Delta B$$

En utilisant la formule  $\Delta A^{-1} = -A^{-1}.\Delta A.A^{-1}$ , on obtient les incertitudes sur les puretés :

$$\Delta X = -A^{-1}.\Delta A.A^{-1}.B + A^{-1}.\Delta B$$

Les incertitudes  $\Delta A$  et  $\Delta B$  sont données par les écarts-types binomiaux de chacune des efficacités.

La méthode trois divisions a comme avantage sur la méthode deux divisions de mieux tenir compte de la forme de la distribution template puisque deux critères de sélections au lieu d'un lui sont appliqués. De plus, chacun des processus est mesuré. Le prix à payer est de faire confiance à un ensemble d'efficacités supplémentaires calculées avec les distributions templates simulées. Le problème pour ces deux méthodes est qu'au contraire du processus  $\gamma+X$  où les distributions du signal peuvent être construites à partir des photons certifiés  $Z \rightarrow ll\gamma$  (si suffisamment de luminosité), il n'existe pas de processus avec résonance accompagné d'une production d'un diphoton. Il est donc difficile de construire une distribution template du signal à partir des données. Une autre solution consisterait à considérer comme des photons les électrons issus du processus  $Z \rightarrow ee$ .

### Méthodes d'ajustement du maximum de vraisemblance

La méthode d'ajustement du maximum de vraisemblance décrite section 6.2.4 peut aussi être utilisée pour la mesure du processus  $\gamma\gamma+X$ . Ici encore il y a deux options. La première options consiste à fournir à la classe `TFractionFitter` de ROOT deux distributions templates : la première pour le signal  $\gamma\gamma$  et la deuxième pour le bruit de fond, incluant les processus  $\gamma j$  et  $jj$ . L'autre option consiste à fournir à `TFractionFitter` les trois distributions templates pour chacun des trois processus  $\gamma\gamma$ ,  $\gamma j$  et  $jj$ , avec le risque que l'ajustement ait plus de difficultés à converger du fait du plus grand nombre de paramètres introduits.

### Méthode de la matrice $4 \times 4$

En plus des deux méthodes de divisions et d'ajustement par le maximum de vraisemblance, il existe une autre méthode couramment utilisée dans les analyses des collaborations CDF [130] et D0 [132], appelée

méthode de la matrice  $4 \times 4$ . Il s'agit d'une variante plus complexe de la méthode deux divisions : un critère de sélection est appliqué sur une variable template. A la différence de la méthode deux divisions, un système à quatre équations et quatre inconnues est construit, utilisant le nombre d'évènements  $N_{pp}$  où les deux photons passent le critère,  $N_{pf}$  où le premier photon le passe et pas le deuxième,  $N_{fp}$  où le premier échoue et le deuxième le satisfait, et le dernier cas  $N_{ff}$  où les deux photons échouent à passer le critère. L'information sur le nombre d'évènements  $N_{\gamma\gamma}$ ,  $N_{\gamma j}$ ,  $N_{j\gamma}$  et  $N_{jj}$  en est tirée. L'équation à résoudre est la suivante :

$$\begin{aligned} N_{pp} &= \epsilon_{\gamma 1}\epsilon_{\gamma 2}N_{\gamma\gamma} + \epsilon_{\gamma 1}\epsilon_{j 2}N_{\gamma j} + \epsilon_{j 1}\epsilon_{\gamma 2}N_{j\gamma} + \epsilon_{j 1}\epsilon_{j 2}N_{jj} \\ N_{pf} &= \epsilon_{\gamma 1}(1 - \epsilon_{\gamma 2})N_{\gamma\gamma} + \epsilon_{\gamma 1}(1 - \epsilon_{j 2})N_{\gamma j} + \epsilon_{j 1}(1 - \epsilon_{\gamma 2})N_{j\gamma} + \epsilon_{j 1}(1 - \epsilon_{j 2})N_{jj} \\ N_{fp} &= (1 - \epsilon_{\gamma 1})\epsilon_{\gamma 2}N_{\gamma\gamma} + (1 - \epsilon_{\gamma 1})\epsilon_{j 2}N_{\gamma j} + (1 - \epsilon_{j 1})\epsilon_{\gamma 2}N_{j\gamma} + (1 - \epsilon_{j 1})\epsilon_{j 2}N_{jj} \\ N_{ff} &= (1 - \epsilon_{\gamma 1})(1 - \epsilon_{\gamma 2})N_{\gamma\gamma} + (1 - \epsilon_{\gamma 1})(1 - \epsilon_{j 2})N_{\gamma j} + (1 - \epsilon_{j 1})(1 - \epsilon_{\gamma 2})N_{j\gamma} + (1 - \epsilon_{j 1})(1 - \epsilon_{j 2})N_{jj} \end{aligned}$$

Où  $\epsilon_{\gamma 1}$  ( $\epsilon_{\gamma 2}$ ) est l'efficacité du critère de sélection sur le premier (deuxième) photon et  $\epsilon_{j 1}$  ( $\epsilon_{j 2}$ ) sur le premier (deuxième) jet. L'avantage de cette méthode est de ne nécessiter que les efficacités sur les photons uniques et jets uniques : il est plus aisé de construire les distributions templates à partir des données.

### 8.2.2 Discrimination $\gamma/\pi^0$ pour le canal $\gamma\gamma+X$

Comme lors de la mesure du nombre d'évènements de signal  $\gamma+X$  présenté chapitre 6, nous aimerions utiliser comme variable template la sortie du réseau de neurone de discrimination  $\gamma/\pi^0$ . Nous décrirons dans un premier temps la sélection appliquée aux évènements simulés et les conditions d'entraînement du réseau de neurone, avant de choisir la variable template qui sera utilisée pour la mesure. Pour cette analyse, nous nous concentrerons sur les échantillons simulés et effectuerons des études préparatoires à la mesure de la section efficace  $\gamma\gamma+X$ , qui sera réalisable dans les données dès qu'une luminosité intégrée de  $10 \text{ pb}^{-1}$  environ sera disponible.

#### Préselection des évènements

Les échantillons simulés utilisés sont listés tableau 8.3. Pour la préparation de l'analyse avec  $10 \text{ pb}^{-1}$ , les échantillons Madgraph officiels ont été utilisés chaque fois que c'était possible, pour permettre une meilleure estimation du bruit de fond pour des plus hautes masses invariantes diphotons que les échantillons Pythia.  $HT$  est la somme scalaire des impulsions transverses des partons de l'interaction dure, et  $\hat{p}_T$  l'impulsion transverse du parton de plus haute impulsion transverse.

Processus	Sélection	Section efficace (pb)	Nb évènements
Madgraph QCD jets	$100 < HT < 250 \text{ GeV}$	7000000	10875132
Madgraph QCD jets	$250 < HT < 500 \text{ GeV}$	171000	4907817
Madgraph QCD jets	$500 < HT < 1000 \text{ GeV}$	5200	3785908
Madgraph QCD jets	$HT > 1000 \text{ GeV}$	83	1668913
Madgraph $\gamma$ +jets	$40 < HT < 100 \text{ GeV}$	23620	2228981
Madgraph $\gamma$ +jets	$100 < HT < 200 \text{ GeV}$	3476	1005161
Madgraph $\gamma$ +jets	$HT > 200 \text{ GeV}$	485	781692
Madgraph $\gamma\gamma$ +jets (born)	$M_{\gamma\gamma} > 40 \text{ GeV}, p_T > 10 \text{ GeV}$	131	1091347
Pythia $\gamma\gamma$ box	$10 < \hat{p}_T < 25 \text{ GeV}$	358.2	550000
Pythia $\gamma\gamma$ box	$25 < \hat{p}_T < 250 \text{ GeV}$	12.37	543520
Pythia $\gamma\gamma$ box	$\hat{p}_T > 250 \text{ GeV}$	0.000208	216432

FIG. 8.3 – Echantillons simulés utilisés pour la préparation à la mesure de la section efficace  $\gamma\gamma+X$  (aucun K-facteur n'a été appliqué).

La préselection des photons est semblable à celle décrite section 6.2.1 pour l'analyse du processus  $\gamma+X$ . Le filtre "bonne collision" est appliqué aux échantillons simulés. Les photons sont sélectionnés s'ils sont dans l'acceptance du détecteur et s'ils ne sont pas localisés dans la région de transition tonneau-bouchon. La suppression des spikes est effectuée avec la variable de forme du cluster  $S4/S1$  et avec une coupure

sur la synchronisation en temps. Le critère  $H/E < 0.1$  est aussi demandé. Un “OU” de trois voies de déclenchement a été utilisé : HLT\_DoublePhoton10\_L1R, HLT\_Photon10\_L1R et HLT\_Photon15\_L1R.

L'évènement est ensuite préselectionné si il contient au moins deux photons ayant une impulsion transverse  $p_T > 20$  GeV (seuil minimum pour l'utilisation des échantillons  $\gamma$ +jets Madgraph). Un diphoton est formé avec les deux photons de plus grande impulsion transverse dans l'évènement, dont la masse invariante doit satisfaire  $M_{\gamma\gamma} > 40$  GeV (coupure minimale pour qu'il y ait cohérence avec la sélection générateur dans l'échantillon Madgraph  $\gamma\gamma$ +jets).

### Entraînement et application du réseau de neurone

Le but de cette analyse étant de mesurer la section efficace  $\gamma\gamma+X$ , nous utiliserons seulement le réseau de neurone dont les variables d'entrée sont les variables de forme du cluster. Le réseau de neurone est entraîné sur des photons d'impulsion transverse  $p_T > 15$  GeV répondant à  $EcalIso < 4$  GeV et  $HcalIso < 2$  GeV (signal : photons partonique de  $\gamma + jet$ , bruit de fond : photons non ISR/FSR de QCD). Nous avons déjà montré section 5.2 que les distributions des variables d'entrée étaient les mêmes pour les photons prompts de  $\gamma$ +jet et  $\gamma\gamma+X$ . Les échantillons sont bien séparés pour l'entraînement (échantillon Pythia QCD dijet  $\hat{p}_T > 15$  GeV) et l'application (échantillons Madgraph tableau 8.3). Pour l'application sur les événements diphotons passant la préselection, la sélection est complétée par les critères  $TrackerIso < 2$  GeV et  $H/E < 0.05$ .

### Choix de la variable template pour la mesure

La sortie du réseau de neurone va être utilisée pour construire les distributions templates des processus  $\gamma\gamma$ ,  $\gamma$ +jet et dijet. Dans la mesure où deux photons sont présents par évènement, il y a une plus grande marge de manoeuvre pour le choix de la variable template. Il est possible d'utiliser la sortie du réseau de neurone pour l'un des deux photons ou les deux. Plusieurs possibilités ont été essayées figure 8.4. Dans ce graphique, l'efficacité du signal et le rejet du bruit de fond sont calculés évènement par évènement (et non photon par photon). Les variables templates suivantes ont été essayées : sortie du réseau de neurone de chaque photon ( $NNoutput$ , deux entrées par évènement), du photon ayant l'impulsion transverse la plus grande ( $NNoutput_{lead}$ ), la plus petite ( $NNoutput_{trail}$ ), du photon ayant la valeur la plus grande de sortie du réseau de neurone ( $NNoutput_{max}$ ), la plus petite ( $NNoutput_{min}$ ), et la moyenne de la sortie du réseau de neurone pour les deux photons ( $(NN_1 + NN_2)/2$ ). La possibilité d'entraîner le réseau de neurone avec les trois variables de forme du cluster pour le premier et le deuxième photon n'a pas été investiguée, car nous préférons avoir une sortie par photon (et non par diphoton) pour plus de cohérence avec les autres analyses.

Le meilleur rejet du bruit de fond est obtenu pour  $NNoutput_{min}$  et pour  $(NN_1 + NN_2)/2$  : 72% de rejection pour une efficacité du signal de 90%. En effet,  $NNoutput$  est proche de 1 pour les photons prompts du processus  $\gamma\gamma$  et  $\gamma$ +jet et prend des valeurs inférieures à 1 pour les photons mal identifiés de QCD dijet et  $\gamma$ +jet. L'avantage de  $NNoutput_{min}$  est de rassembler le signal  $\gamma\gamma$  vers 1, tandis que le bruit de fond  $\gamma$ +jet et dijet prennent des valeurs inférieures ( $NNoutput_{min}$  est celui du photon mal identifié dans les deux cas). Il est intéressant de noter que le photon ayant l'impulsion transverse la plus faible dans les événements  $\gamma$ +jet n'est pas toujours le photon mal identifié (pouvoir discriminant plus faible pour  $NNoutput_{trail}$  que pour  $NNoutput_{min}$ ). Par souci de simplicité, la variable template  $NNoutput_{min}$  est retenue pour la suite.

### 8.2.3 Mesure de la section efficace $\gamma\gamma+X$ dans la simulation

Les observables pertinentes dans le cas du processus  $\gamma\gamma+X$  sont la masse invariante  $M_{\gamma\gamma}$ , l'impulsion transverse du diphoton  $q_T$ , le cosinus de l'angle entre la direction du diphoton et l'un des deux photons dans le repère associé au diphoton  $\cos(\theta^*)$  et l'écart angulaire en  $\phi$  entre les deux photons  $\Delta\phi$ . Il s'agit de variables déjà mesurées par les analyses de CDF [131, 130] et D0 [132].  $M_{\gamma\gamma}$  est intéressante car elle contient des informations sur la proportion relative des processus Born et Box (plutôt à basse masse invariante). Il s'agit aussi de la variable principale permettant la discrimination entre le signal résonant

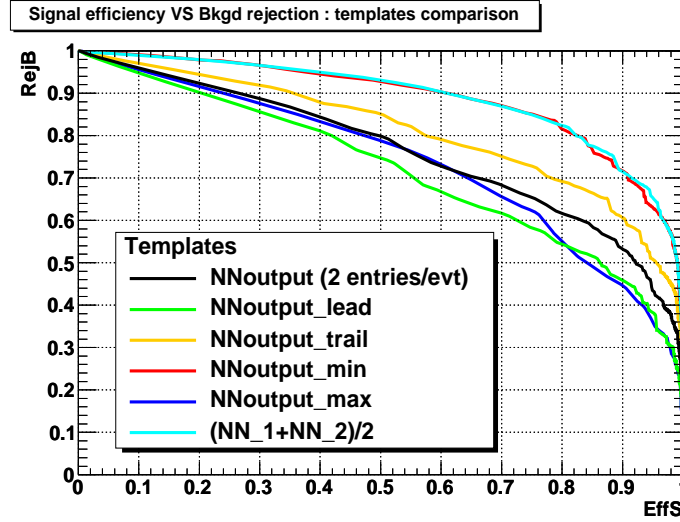


FIG. 8.4 – Efficacité du signal  $\gamma\gamma$  versus rejection du bruit de fond (incluant  $\gamma$ +jet et QCD dijet), pour différentes variables templates de sortie du réseau de neurones (entraîné une fois pour toute).

$H \rightarrow \gamma\gamma$  et le bruit de fond continu  $\gamma\gamma+X$ . La forme de la distribution  $q_T$  rend sensible les effets d'émission des gluons mous dans l'état initial (à bas  $q_T$ ). La distribution  $\cos(\theta^*)$  est très sensible aux critères de sélection sur les deux photons, et avec  $q_T$  forment un lot de variables additionnelles pour la discrimination entre boson de Higgs et le bruit de fond irréductible. Enfin  $\Delta\phi$  est sensible aux contributions de fragmentation : il est notamment attendu qu'à bas  $\Delta\phi$  la composante de fragmentation double du même quark soit à l'origine de l'excès dans les données par rapport aux prédictions théoriques.

En utilisant la variable template  $NNoutput_{min}$ , la mesure de la pureté et du nombre d'évènements de signal  $\gamma\gamma$  après préselection et identification des photons (par isolation) va être effectuée pour plusieurs divisions des distributions  $M_{\gamma\gamma}$ ,  $q_T$ ,  $\cos(\theta^*)$  et  $\Delta\phi$ . Comme nous allons le voir, l'analyse manque globalement de statistique pour le bruit de fond Madgraph QCD dijet, ce qui va grandement affecter les résultats (le même manque de statistique pose problème avec les échantillons officiels générés avec Pythia). Nous présentons les résultats suivants dans l'hypothèse d'une luminosité intégrée égale à  $10 \text{ pb}^{-1}$ . Dans la suite, les échantillons sont divisés en deux parties : la première pour la construction d'un échantillon de données artificielles ("Mock data") et la seconde pour la construction d'un échantillon simulé utilisé pour les distributions templates  $NNoutput_{min}$ . Les méthodes deux divisions, trois divisions, ajustement par maximum de vraisemblance avec deux templates et trois templates vont être essayées. La méthode deux divisions utilise le critère de sélection  $NNoutput_{min} > 0.9$ , et la méthode trois divisions  $NNoutput_{min} > 0.5$  et  $NNoutput_{min} > 0.9$ . Les méthodes d'ajustement utilisent 22 divisions de  $NNoutput_{min}$  dans la gamme  $-1.1 < NNoutput_{min} < 1.1$  avec un pas de 0,1.

### Distributions de masse invariante $M_{\gamma\gamma}$

On montre figure 8.5 la distribution de masse invariante après critères d'identification des photons et après application du critère  $NNoutput_{min} > 0.9$  pour l'échantillon de données artificielles et l'échantillon simulé. On observe le manque de statistique pour la contribution deux photons faux (QCD dijet), contribuant significativement à la fluctuation entre distributions de données artificielles et simulation. Les nombres d'évènements après ces deux critères sont résumés tableau 8.6. La pureté du signal après identification des photons est de 25,6%, tandis qu'elle vaut 49,4% après la sélection  $NNoutput_{min} > 0.9$ , qui rejette environ 86% des évènements dijet et 65% des évènements  $\gamma$ +jets. L'efficacité du signal pour cette coupure est de 88,6%.

Les quatre méthode templates (deux et trois divisions, ajustement utilisant deux et trois distributions templates) sont ensuite appliquées pour déterminer la pureté et le nombre d'évènements de signal non

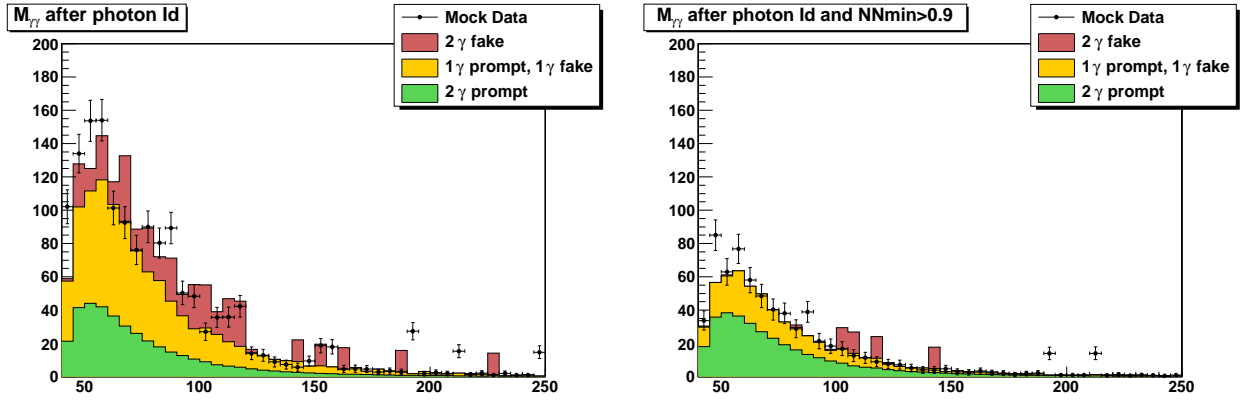


FIG. 8.5 – Distribution de la masse invariante  $\gamma\gamma$  dans les données artificielles et la simulation après identification des photons (à gauche) par isolation puis coupure sur le réseau de neurone (à droite).

Processus	Photon Id	Photon Id + $NN_{output_{min}} > 0.9$
Données artificielles	1502.45	689.90
Deux faux	397.83	56.00
Un prompt un faux	719.79	251.66
Deux prompts	384.76	340.71

FIG. 8.6 – Nombre d'évènements après identification des photons et après sélection  $NN_{output_{min}} > 0.9$ .

corrigé dans l'échantillon de données artificielles pour la plage de masse invariante  $40 < M_{\gamma\gamma} < 100$  GeV. Le résultat est obtenu figure 8.7. La méthode donnant des résultats les plus éloignés de la prédiction de la simulation est la méthode d'ajustement utilisant deux distributions templates (une pour  $\gamma\gamma$ , l'autre pour les deux bruits de fond). Ceci est dû au fait que la distribution template pour le bruit de fond QCD dijet est soumise à de fortes fluctuations statistiques du fait du faible nombre d'évènements passant les critères d'identification des photons, avec un poids grand devant les poids des processus  $\gamma\gamma+X$  et  $\gamma$ +jets, ce qui rend la convergence de l'ajustement difficile. L'ajustement utilisant trois distributions templates (une par processus) paraît donner des résultats plus stables, de même que la méthode trois divisions. Le poids des évènements QCD est compensé par la prise en compte des trois distributions. La méthode la plus stable est la méthode deux divisions, qui exploite seulement l'information sur le nombre d'évènements avec et sans coupure  $NN_{output_{min}} > 0.9$ .




FIG. 8.7 – Pureté et nombre d'évènements de signal en fonction de la masse invariante  $\gamma\gamma$  dans les données artificielles, estimées par quatre méthodes templates et dans la simulation.

Le fait que nous ne disposons pas d'une statistique suffisante pour construire une distribution template QCD dijet rendant compte d'effets moyens (non sensibles aux fluctuations statistiques) influe sur la stabilité du résultat obtenu. La méthode deux divisions semble donner les résultats les plus stables malgré ces deux effets. Avec une distribution template QCD dijet non biaisée, il devrait être possible de mesurer avec une meilleure précision la pureté et le nombre d'évènements de signal sur cette même plage de masse invariante. Si de plus la luminosité était augmentée (par exemple  $100 \text{ pb}^{-1}$ ), il devrait être possible de mesurer ces spectres sur une plus grande plage de masse invariante.

### Distributions d'impulsion transverse du diphoton $q_T$

La figure 8.8 montre le spectre en impulsion transverse  $q_T$  pour les données artificielles et la prédiction simulée. On voit qu'au delà de  $q_T > 40 \text{ GeV}$ , il va être difficile d'effectuer une mesure du fait du faible nombre d'évènements de signal attendu avec  $10 \text{ pb}^{-1}$ .

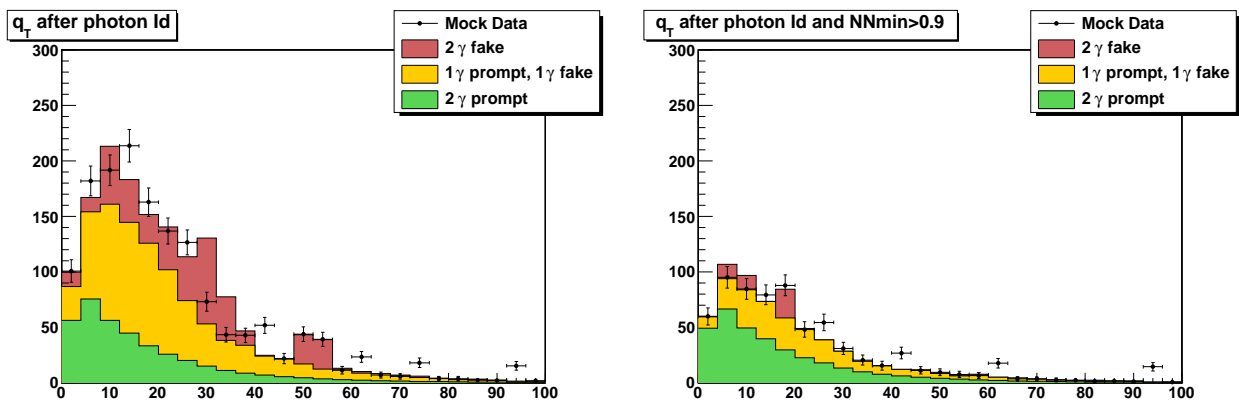


FIG. 8.8 – Distribution de l'impulsion transverse  $q_T$  du système diphoton dans les données artificielles et la simulation après identification des photons (à gauche) par isolation puis coupure sur le réseau de neurone (à droite).

La pureté et le nombre d'évènements de signal non corrigé pour la distribution d'impulsion transverse  $q_T$  des diphotons est donnée figure 8.9, dans la plage  $0 < q_T < 40 \text{ GeV}$ . A part pour les plages  $5 < q_T < 10$  et  $30 < q_T < 40$ , la méthode deux divisions renvoie les meilleurs résultats, suivie de près par la méthode trois divisions. Ici encore, la méthode d'ajustement avec trois distributions templates renvoie de meilleurs résultats qu'avec deux distributions templates, particulièrement en accord avec la prédiction pour  $0 < q_T < 10 \text{ GeV}$  (où le nombre d'évènements de signal ainsi que la pureté sont les plus grands).

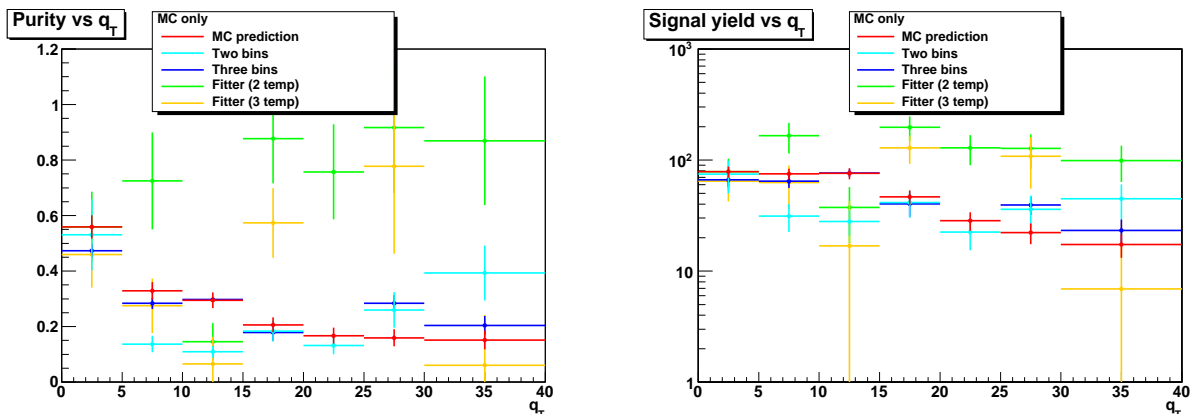


FIG. 8.9 – Pureté et nombre d'évènements de signal en fonction de l'impulsion transverse  $q_T$  dans les données artificielles, estimées par quatre méthodes templates et dans la simulation.

### Distribution angulaire $\cos(\theta^*)$

On montre figure 8.10 la distribution  $\cos(\theta^*)$  pour données artificielles et prédictions de la simulation. Du fait que la distribution est comprise entre 0 et 1, les événements de QCD dijet sont rassemblés (plutôt qu'être dispersés selon une loi exponentielle décroissante comme pour  $M_{\gamma\gamma}$  et  $q_T$ ), ce qui devrait améliorer les résultats obtenus avec les différentes méthodes templates.

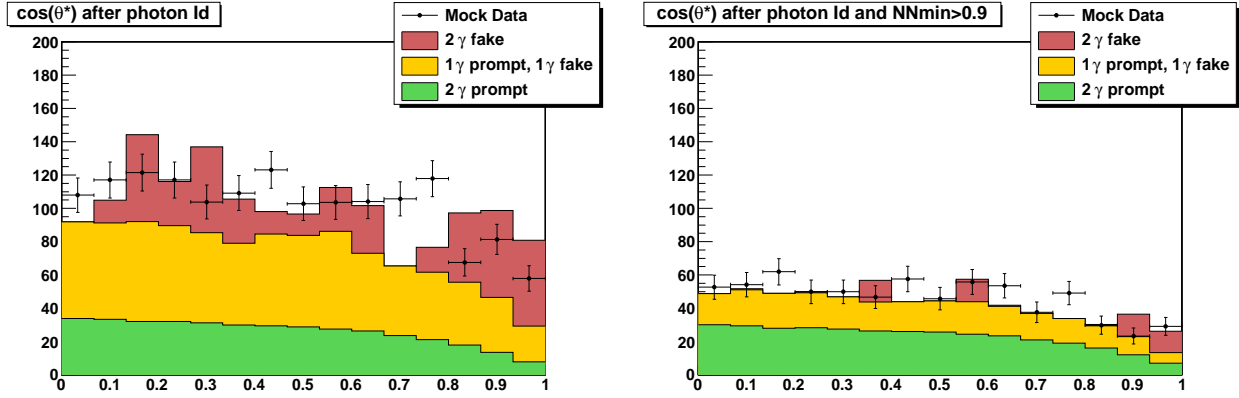


FIG. 8.10 – Distribution angulaire  $\cos(\theta^*)$  du système diphoton dans les données artificielles et la simulation après identification des photons (à gauche) par isolation puis coupure sur le réseau de neurone (à droite).

La figure 8.11 montre les résultats pour la pureté et le nombre d'évènements de signal non corrigés pour la distribution  $\cos(\theta^*)$ . Les méthodes d'ajustement donnent effectivement de meilleurs résultats que pour  $q_T$  et  $M_{\gamma\gamma}$ . La meilleure estimation de la pureté reste obtenue avec la méthode deux divisions, qui semble bien être la plus robuste.




FIG. 8.11 – Pureté et nombre d'évènements de signal en fonction de l'impulsion transverse  $q_T$  dans les données artificielles, estimées par quatre méthodes templates et dans la simulation.

### Distribution angulaire $\Delta\phi$

La distribution  $\Delta\phi$  pour données artificielles et simulation est montrée figure 8.12. On observe que pour  $\Delta\phi < 1.5$  il est difficile d'effectuer une mesure du fait du faible nombre d'évènements (correspondant à l'émission d'un jet dur supplémentaire reculant contre les deux photons).

Les résultats de la mesure sont donnés figure 8.13 pour la distribution  $\Delta\phi$ . Ici encore les meilleurs résultats sont obtenus avec les méthodes deux et trois divisions.






FIG. 8.12 – Distribution angulaire  $\Delta\phi$  du système diphoton dans les données artificielles et la simulation après identification des photons (à gauche) par isolation puis coupure sur le réseau de neurone (à droite).




FIG. 8.13 – Pureté et nombre d'évènements de signal en fonction de l'impulsion transverse  $q_T$  dans les données artificielles, estimées par quatre méthodes templates et dans la simulation.

### Conclusions sur l'application de la méthode des templates au processus $\gamma\gamma+X$

Nous avons effectué la mesure de la pureté et du nombre d'évènements non corrigés du signal  $\gamma\gamma+X$  à partir des échantillons Madgraph et pour quatre méthodes de templates différentes. Avec  $10 \text{ pb}^{-1}$ , il semble possible d'effectuer la mesure dans au moins cinq divisions des distributions  $M_{\gamma\gamma}$ ,  $q_T$ ,  $\cos(\theta^*)$  et  $\Delta\phi$ . La principale difficulté que nous avons rencontrée provient de la faible statistique des échantillons simulés QCD dijet (encore plus faible si nous avons utilisé Pythia, comme cela peut être vu figure 8.16). Les résultats obtenus peuvent donc être vus comme probant la stabilité des méthodes essayées face à de fortes fluctuations du bruit de fond. Malgré cette difficulté, la mesure semble être possible avec la méthode deux divisions, qui nous semble être la plus stable quelle que soit l'observable. Ceci s'explique par le fait que la méthode deux divisions est celle qui utilise le moins d'informations sur la forme des distributions. La méthode trois divisions donne souvent des résultats proches de ceux attendus, tandis que les méthodes d'ajustement (surtout avec deux distributions templates) renvoient les résultats les plus instables, conduisant quasi-systématiquement à la surévaluation de la pureté de l'échantillon. L'étude devrait être répétée avec un nombre plus important d'évènements simulés de bruit de fond (que ce soit par application d'un filtre niveau générateur ou reconstruit dans la production, ou avec un nombre plus important d'évènements générés).

Pour le moment, nous n'avons pas cherché à corriger les spectres obtenus pour les inefficacités de détection, dues aux filtre "bonne collision", au déclenchement, à l'acceptance et au critère d'identification des photons. L'obtention des sections efficaces différentielles s'effectuerait après ces corrections en divisant

le nombre d'évènements corrigés par la luminosité, et pour chaque division des spectres en divisant ce nombre par la largeur de la division. Il sera important d'effectuer ce travail une fois les problèmes de statistique dans les échantillons de simulation réglés.

### 8.2.4 Comparaison avec les prédictions théoriques par la méthode de repondération

La technique de repondération développée section 7.4.1 pourrait être utilisée pour comparer prédictions théoriques et données expérimentales des sections efficaces différentielles du processus  $\gamma\gamma+X$ . La repondération est effectuée au niveau générateur et ses effets sont présents au niveau reconstruit. Il s'agit de comparer directement les distributions repondérées reconstruites avec les distributions du nombre d'évènements mesurés, sans avoir besoin de corriger le taux pour les inefficacités de détection. La méthode a l'avantage de proposer des distributions repondérées qui tiennent compte des effets aux ordres supérieurs après simulation du détecteur et reconstruction. Elle a en revanche le désavantage d'introduire le biais de la simulation : ce ne sont pas les sections efficaces différentielles qui sont comparées, mais les distributions repondérées dont les évènements ont passé les critères de sélection de l'analyse.

La méthode proposée section 7.4.1 a montré fonctionner correctement pour la plage de masse invariante où est recherché le boson de Higgs ( $M_{\gamma\gamma} > 100$  GeV) mais s'est montrée imparfaitement valide dans la gamme  $M_{\gamma\gamma} > 40$  GeV qui nous intéresse ici. Un K-facteur dépendant de deux variables  $K(q_T, M_{\gamma\gamma})$  ne suffit pas à reproduire correctement toutes les distributions NLO. Des K-facteurs dépendant d'autres variables pourraient être utilisés. Il serait aussi possible d'effectuer une repondération séparée pour chaque distribution que l'on souhaite mesurer.

Dans la mesure où les échantillons de QCD jets manquent de statistique pour cette analyse, nous indiquerons seulement la marche à suivre pour un exercice de préparation à la mesure de la section efficace  $\gamma\gamma+X$ . Comme exercice, il serait intéressant de séparer les échantillons en deux : l'un pour la construction des templates, l'autre pour l'échantillon de fausses données. Seul l'échantillon de fausses données serait repondéré de sorte à imiter au mieux les évènements provenant des vraies données. La mesure est alors effectuée avec les templates sans repondération, et le résultat obtenu devrait alors refléter le fait que les fausses données ont été repondérées.

### 8.2.5 Incertitudes statistiques et systématiques

Dans la mesure où pour le moment, avec les échantillons Madgraph utilisés, l'incertitude sur la mesure provient surtout de l'incertitude statistique sur l'échantillon QCD dijet, nous n'effectuerons pas ici d'étude complète des incertitudes systématiques. Nous souhaitons toutefois les mentionner et dire quelques mots pour chacune d'entre elles. La plupart des incertitudes peuvent être évaluées de la même manière que pour la mesure du processus  $\gamma+X$  (voir section 6.2.7). Nous mentionnerons ici les spécificités propres au processus  $\gamma\gamma+X$ .

#### Incertainces théoriques

- Les incertainces dûes à l'échelle d'énergie et aux densités partoniques et le modèle d'évènement sous-jacent, des radiations ISR/FSR et de l'hadronisation peuvent être évaluées de la même manière que pour le processus  $\gamma+X$ .

#### Incertainces expérimentales

- Incertaince sur la luminosité : 10% attendus avec  $10 \text{ pb}^{-1}$  de luminosité intégrée.  
 - Incertaince sur les distributions templates. Un premier aspect concerne les distributions templates pour le signal. Pour quantifier l'incertaince, il est possible de remplacer les templates de diphotons partoniques avec les templates dont l'un ou l'autre des deux photons sont des ISR/FSR (obtenues à partir de la simulation). Il est plus difficile de construire les distributions templates du bruit de fond à partir des données pour le processus  $\gamma\gamma+X$  que pour  $\gamma+X$  : il faut maintenant deux photons mal identifiés par évènements. L'inversion de l'isolation trajectographique n'a pas été réessayé dans le cas diphoton et pourrait régler le problème. Une autre possibilité est de sélectionner des photons de bruit de fond grâce à

la cinématique du processus  $\gamma$ +jet (utilisables aussi pour réduire l'incertitude systématique sur l'entraînement du réseau de neurones), et d'associer deux photons sélectionnés dans des événements différents pour construire un événement dijet. De même lorsque suffisamment de luminosité sera disponible, un procédé similaire pourra être utilisé pour les photons du signal de  $Z \rightarrow l\bar{l}\gamma$ . Enfin, ce problème semble être évité par le principe de la méthode de la matrice  $4 \times 4$ , qui devra être essayée.

- Incertitudes sur les **efficacités de détection**, de **budget matériel** et d'**échelle d'énergie des photons** peuvent être évaluées de la même manière que pour le processus  $\gamma+X$ .
- Incertitude du critère d'**identification des photons**. Un moyen de les évaluer consiste à faire varier de 5% chacun des critères d'isolation, et de quantifier les effets de cette variation sur la section efficace mesurée. Contrairement au cas de  $\gamma+X$ , il faut prendre en compte les deux photons sélectionnés par événements et non un seul pour le calcul des efficacités.

### 8.3 Etudes des événements diphotons dans les données

Les études précédentes ont été effectuées dans l'hypothèse d'une luminosité intégrée de  $10 \text{ pb}^{-1}$ . Malheureusement, au jour où j'écris ces lignes la luminosité intégrée disponible n'est que de  $10,24 \text{ nb}^{-1}$ . Le nombre d'événements de signal calculé avec Diphox et Gamma2MC au NLO est environ 2,1. Le programme de mesure de la section efficace différentielle  $\gamma\gamma+X$  dans les données ne peut pas être accompli pour le moment en raison d'un trop petit nombre d'événements de signal. Ce qui peut en revanche être étudié avec cette basse luminosité, c'est l'inspection des différentes distributions diphotons avec des critères de sélection relâchés. Dans cette section, nous décrirons la sélection appliquée aux événements et montrerons les distributions de masse invariante  $\gamma\gamma$  pour différents critères d'identification des photons : isolation et coupure sur la sortie du réseau de neurone de forme du cluster. Nous montrerons alors les autres distributions des observables cinématiques importantes du processus  $\gamma\gamma+X$ . Enfin, nous essayerons une première mesure de la pureté et du nombre de diphotons du bruit de fond pour lequel un photon est un photon prompt et l'autre est un jet identifié comme un photon, avec la méthode des templates utilisant la sortie du réseau de neurones.

#### 8.3.1 Préselection des diphotons

La première partie de la préselection appliquée aux événements est semblable à celle décrite section 6.2.1 pour l'analyse du processus  $\gamma+X$ . Les échantillons de données d'une luminosité intégrée de  $10,24 \text{ nb}^{-1}$  déclenchés avec les voies "e/gamma" sont utilisés. Le filtre "bonne collision" est appliqué aux données et à la simulation. Les photons sont sélectionnés s'ils sont dans l'acceptance du détecteur et s'ils ne sont pas localisés dans la région de transition tonneau-bouchon. La suppression des spikes est effectuée avec la variable de forme du cluster  $S4/S1$  et avec une coupure sur la synchronisation en temps. Le critère  $H/E < 0.1$  est aussi demandé.

Pour harmoniser les voies de déclenchement entre les échantillons de données et simulés, un déclenchement utilisant un "OU" de trois voies est utilisé : HLT\_DoublePhoton10\_L1R, HLT\_Photon10\_L1R et HLT\_Photon15\_L1R. L'événement est alors sélectionné si il contient au moins deux photons d'impulsion transverse supérieure à 15 GeV. Un diphoton est formé avec les deux photons de plus grande impulsion transverse dans l'événement, dont la masse invariante doit être supérieure à 20 GeV. Les échantillons de simulation de bruit de fond QCD dijet Pythia et  $\gamma$ +jet avec une coupure niveau générateur  $p_T > 15 \text{ GeV}$  ont été utilisés, pour permettre une adéquation avec l'impulsion transverse des photons demandés.

Nous utiliserons le réseau de neurone de discrimination  $\gamma/\pi^0$  avec les variables de forme du cluster comme variables d'entrée. Il est entraîné sur des photons d'impulsion transverse  $p_T > 15 \text{ GeV}$  répondant à  $EcalIso < 4 \text{ GeV}$  et  $HcalIso < 2 \text{ GeV}$  (signal : photons partonique de  $\gamma + jet$ , bruit de fond : photons non ISR/FSR de QCD). Les échantillons sont bien séparés pour l'entraînement et l'application.

### 8.3.2 Masse invariante $\gamma\gamma$ pour différents critères d'identification des photons

Afin de classifier les évènements de signal et de bruit de fond, nous définissons trois catégories d'évènements à l'aide de l'information niveau générateur :

- **2 prompts** : lorsque le diphoton est composé de deux photons prompts. Nous définissons comme photon prompt tout photon étant un ISR, un FSR ou un photon partonique. Dans les évènements dijets il s'agit de deux ISR/FSR (composante de fragmentation double), dans les évènements  $\gamma$ +jet il peut s'agir de deux ISR/FSR ou d'un ISR/FSR et un photon partonique (fragmentation simple). Dans les évènements diphotons Born ou Box, il s'agit des deux photons partoniques.
- **1 prompt 1 faux** : lorsqu'un des deux photons est mal identifié et l'autre est un photon prompt.
- **2 faux** : lorsque le diphoton sélectionné est composé de deux photons mal identifiés (provenant en fait de jets). Il s'agit de tous les autres évènements qui ne comportent pas deux photons prompts ou un prompt et un faux.

La masse invariante diphoton après préselection dans les données et la simulation est montrée figure 8.14. Le nombre d'évènements simulés est normalisée au nombre d'évènements dans les données, après quoi la composition en évènements 2 prompts, 2 prompt 1 faux et 2 faux est calculée à l'aide de l'information générateur. Il y a un accord raisonnable sur la forme des distributions entre simulation et données. A ce stade, le signal 2 prompts n'est pas encore visible.




FIG. 8.14 – Distribution de la masse invariante  $\gamma\gamma$  dans les données et la simulation après préselection, avec une luminosité intégrée de  $10,24 \text{ nb}^{-1}$ .

A partir de la préselection, nous avons essayé trois différents critères d'identification des photons pour faire apparaître le signal de photons prompts tout en gardant un nombre suffisamment élevé de photons dans les données :

- Isolation ("Iso") :  $EcalIso < 4 \text{ GeV}$ ,  $HcalIso < 2 \text{ GeV}$ ,  $TrackerIso < 2 \text{ GeV}$  et  $H/E < 0.05$  (ce sont les mêmes critères que pour l'analyse basée sur la simulation présentés plus haut).
- Combinaison des trois variables d'isolation en une seule ("CombIso") :  $EcalIso+HcalIso+TrackerIso < 3 \text{ GeV}$ .
- Coupure sévère sur la sortie du réseau de neurone de forme du cluster ("NN") :  $NNoutput > 0.95$  et isolation "Iso".

Chacun de ces trois critères a été appliqué dans quatre cas : application du critère sur les deux photons, sur le photon d'impulsion transverse la plus haute, sur le photon d'impulsion transverse la plus basse, et sur le premier ou le deuxième photon. Le nombre d'évènements dans les données et pour les différentes contributions de la simulations sont donnés tableau 8.15. Les nombres d'évènements correspondant à une

Sélection	Données	2 faux	1 prompt 1 faux	2 prompts
Préselection	1422	1361.55	57.93	2.52
Iso les deux photons	40	23.89	13.87	2.24
Iso premier photon	190	133.23	53.66	3.10
Iso deuxième photon	157	120.65	33.69	2.66
Iso premier ou deuxième photon	307	231.84	71.99	3.16
CombIso les deux photons	37	20.91	13.80	2.29
CombIso premier photon	156	103.44	49.68	2.87
CombIso deuxième photon	126	90.99	32.41	2.59
CombIso premier ou deuxième photon	245	174.35	67.67	2.97
Iso + NN les deux photons	6	0.00	4.38	1.62
Iso + NN premier photon	72	17.69	51.61	2.71
Iso + NN deuxième photon	40	19.38	18.84	1.78
Iso + NN premier ou deuxième photon	106	39.27	63.94	2.79

FIG. 8.15 – Nombre d'évènements diphotons dans les données après divers critères de sélection.

des trois contributions peuvent être supérieures à la préselection parce que la normalisation est effectuée après identification. Les sections efficaces simulées ainsi que les efficacités correspondant aux trois contributions sont données par Pythia au LO et sont donc différentes dans les données.

Notons d'emblée que le seul critère d'identification capable de supprimer entièrement le bruit de fond "2 faux" (dans la limite des incertitudes statistiques de la simulation) est le critère d'isolation couplé à la coupure sur la sortie du réseau de neurones "Iso+NN" appliqué aux deux photons (voir figure 8.16 pour comparaison avec le critère d'isolation seul sur les deux photons - "CombIso" sur les deux photons donne des résultats similaires et n'est pas montré). Un tel critère (le plus sévère de tous ceux que nous présentons ici) ou un critère approchant sera plutôt utilisé pour la recherche du boson de Higgs. Il ne laisse dans les données que 6 évènements, dont 4,38 comportent un faux et un prompt, et 1,62 comportent deux prompts. En réalité, cette composition est sujette à de grandes incertitudes statistiques comme on peut le voir sur le graphique : il y a un évènement de QCD dijet simulé qui a donné lieu à un faux photon et un prompt (autour de  $M_{\gamma\gamma} = 115$  GeV qui possède un poids de 3,5 (beaucoup plus grand que les autres évènements simulés de  $\gamma+jet$  et  $\gamma\gamma$ ).




FIG. 8.16 – Distribution de la masse invariante  $\gamma\gamma$  dans les données et la simulation après identification des deux photons par isolation couplée à la coupure sur le réseau de neurone (à gauche) et isolation seulement (à droite).

On montre aussi figure 8.17 la distribution de masse invariante diphoton pour les trois critères d'identification appliqués au photon de plus haute énergie transverse, et figure 8.18 les trois critères appliqués

au premier ou au deuxième photon. Les critères d'isolation et d'isolation combinée donnent approximativement les mêmes résultats, l'isolation combinée étant légèrement meilleure en terme de rejet du bruit de fond "2 faux". L'utilisation du réseau de neurone conduit systématiquement à une suppression du bruit de fond "2 faux" et à l'apparition du bruit de fond suivant, "1 faux 1 prompt". Enfin, le meilleur compromis entre pureté du signal et nombre d'événements dans les données est obtenu avec l'application du critère d'identification sur le premier ou le deuxième photon, en particulier pour le critère isolation couplé avec le réseau de neurone.




FIG. 8.17 – Distribution de la masse invariante  $\gamma\gamma$  dans les données et la simulation après identification appliqué au photon de plus haute énergie transverse, par isolation seulement (en haut à gauche) et isolation combinée (en haut à droite) et isolation couplée à la coupure sur le réseau de neurone (en bas).

### 8.3.3 Autres distributions diphotons dans les données

Pour les autres distributions diphotons dans les données, nous avons choisi d'utiliser le critère d'identification des photons par isolation couplée à la coupure sur la sortie du réseau de neurone appliqué au premier ou au deuxième photon. Les distributions de l'impulsion transverse  $\gamma\gamma$  et d'impulsion transverse moyenne  $(p_{T1} + p_{T2})/2$  sont montrées figure 8.19. Les distributions angulaires  $\cos(\theta^*)$  et  $\Delta\phi(\gamma_1, \gamma_2)$  figure 8.20, la rapidité  $\gamma\gamma$  et la différence de pseudo-rapidité  $\eta^*$  divisée par 2 figure 8.21. Il y a globalement un accord raisonnable entre la simulation et les données. Lorsqu'une coupure  $M_{\gamma\gamma} > 40$  GeV laissera suffisamment d'événements dans les données, les échantillons officiels Madgraph pourront être utilisés (qui disposent d'une plus grande statistique et d'une meilleure description des jets).

### 8.3.4 Mesure du nombre d'événements de signal dans les données

Avec la luminosité intégrée de  $10,24 \text{ nb}^{-1}$  dont nous disposons, seulement 2,1 événements de signal sont attendus avec  $p_T > 15$  GeV et  $M_{\gamma\gamma} > 20$  GeV (chiffre issu d'un calcul NLO avec Diphox et Gamma2MC). Pythia est en accord avec cette prédiction, dépendant d'après quel critère d'identification des photons

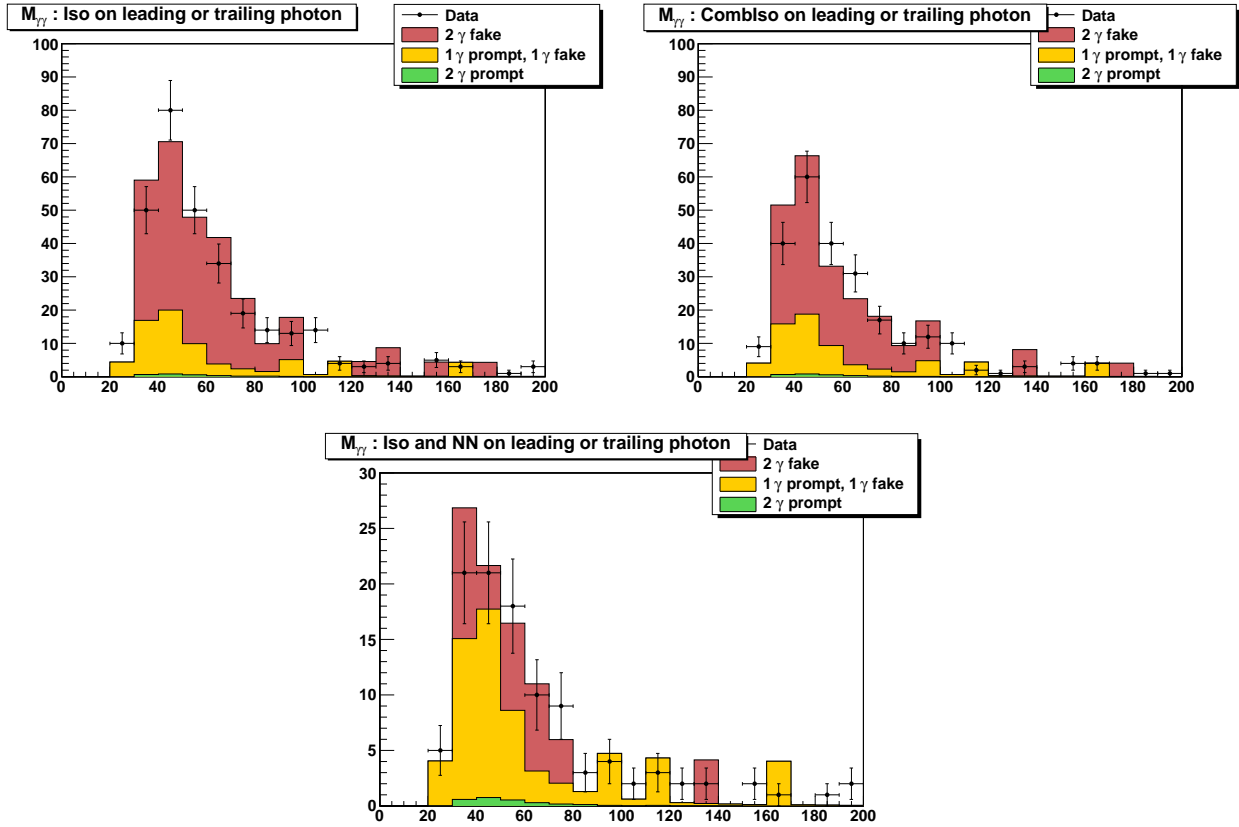


FIG. 8.18 – Distribution de la masse invariante  $\gamma\gamma$  dans les données et la simulation après identification appliqué sur le premier ou le deuxième photon, par isolation seulement (en haut à gauche) et isolation combinée (en haut à droite) et isolation couplée à la coupure sur le réseau de neurone (en bas).

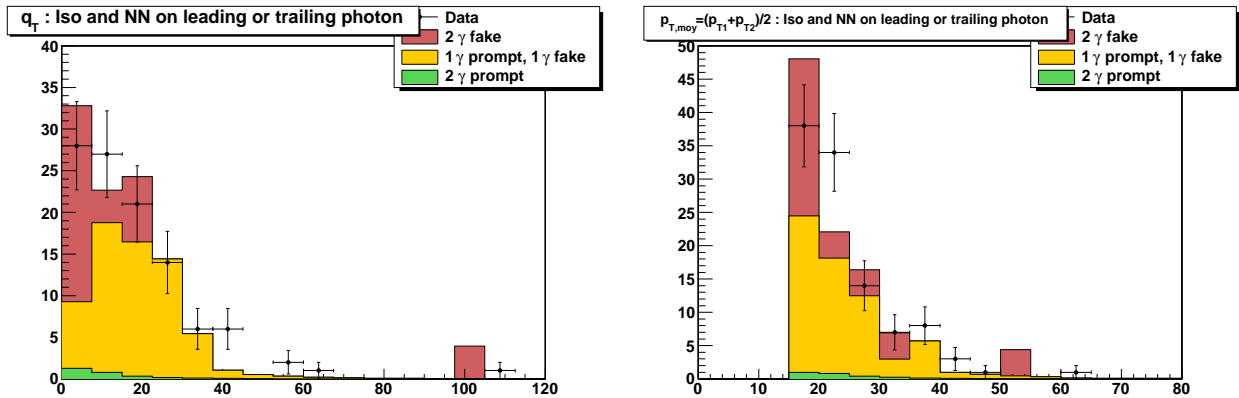


FIG. 8.19 – Distribution d'impulsion transverse  $\gamma\gamma$  (à gauche) et d'impulsion moyenne  $(p_{T1} + p_{T2})/2$  (à droite), après identification du premier ou du deuxième photon par isolation couplée à la coupure sur le réseau de neurone.

la comparaison de la simulation avec les données est effectuée (tant que l'incertitude systématique sur la luminosité est aussi haute, la normalisation par rapport à la luminosité ne peut pas être effectuée). Pour connaître le nombre réel de diphotons dans les données il faudrait être capable de le mesurer par la méthode des templates. Toutefois, une pureté inférieure à 5% environ rend la méthode des templates inapplicable. De plus, pour de tels critères de sélection, les échantillons de bruit de fond simulés manquent de statistique et il est difficile de construire les distributions templates. Nous avons donc plutôt choisi d'effectuer la mesure du processus 1 prompt 1 faux en négligeant la contribution du signal 2 prompts.

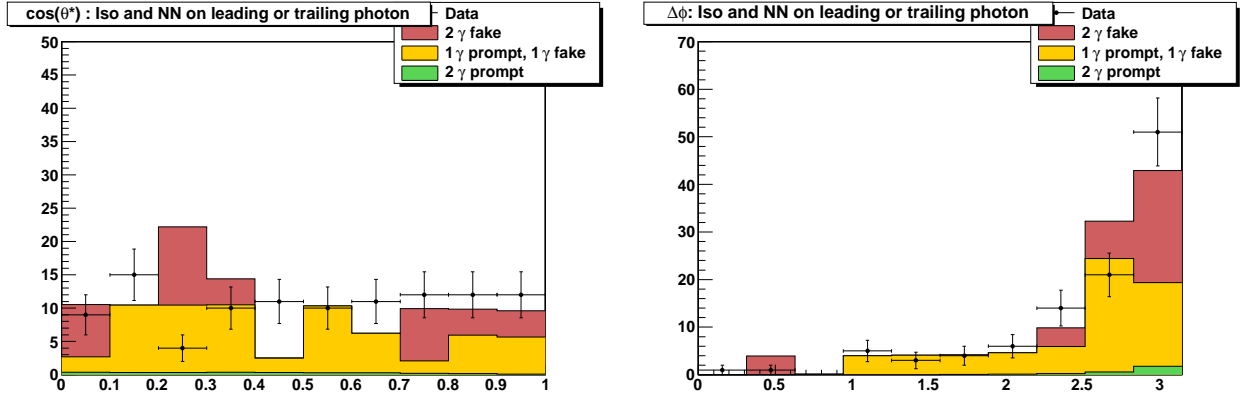


FIG. 8.20 – Distributions angulaires  $\cos(\theta^*)$  (à gauche) et  $\Delta\phi(\gamma_1, \gamma_2)$  (à droite), après identification du premier ou du deuxième photon par isolation couplée à la coupure sur le réseau de neurone.

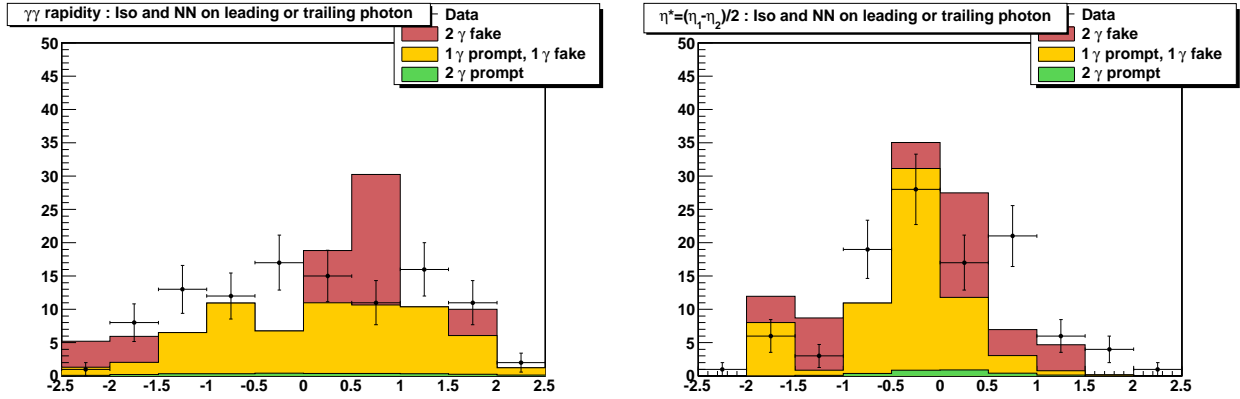


FIG. 8.21 – Distributions angulaires de rapidité  $\gamma\gamma$  (à gauche) et de différence de pseudo-rapidité  $\eta^* = (\eta_1 - \eta_2)/2$  (à droite), après identification du premier ou du deuxième photon par isolation couplée à la coupure sur le réseau de neurone.

Pour effectuer cette mesure, des critères d'isolation relâchés ont été appliqués sur les données et les échantillons simulés pour permettre au signal 1 prompt 1 faux d'apparaître avec une pureté de l'ordre de 10% tout en gardant un nombre d'évènements dans les données suffisant pour la mesure. L'isolation dans le trajectographe a été relâchée. Après la préselection décrite plus haut, on demande  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV et  $H/E < 0.05$ . On montre figure 8.22 la distribution de masse invariante obtenue ainsi que la distribution de sortie du réseau de neurone pour le photon ayant la plus basse valeur de cette sortie. L'inclusion du signal diphoton dans la distribution template ne changerait rien au résultat car les deux évènements de signal sont à l'intérieur de l'incertitude statistique. Pour ces critères de sélection, il y a 259 évènements dans les données. La simulation donne la composition suivante : 226.69 évènements 2 faux, 29,73 évènements 1 prompt 1 faux et 2,58 évènements 2 prompts.

Les méthodes de templates 2-divisions et d'ajustement par maximum de vraisemblance ont été utilisés. Les résultats obtenus en terme de pureté et de nombre d'évènements 1 prompt 1 faux sont résumés tableau 8.23. La pureté est d'environ 10%. La méthode 2 divisions est en accord avec l'information générateur, mais en désaccord avec les résultats de l'ajustement. Une plus grande luminosité semble nécessaire pour effectuer la mesure.



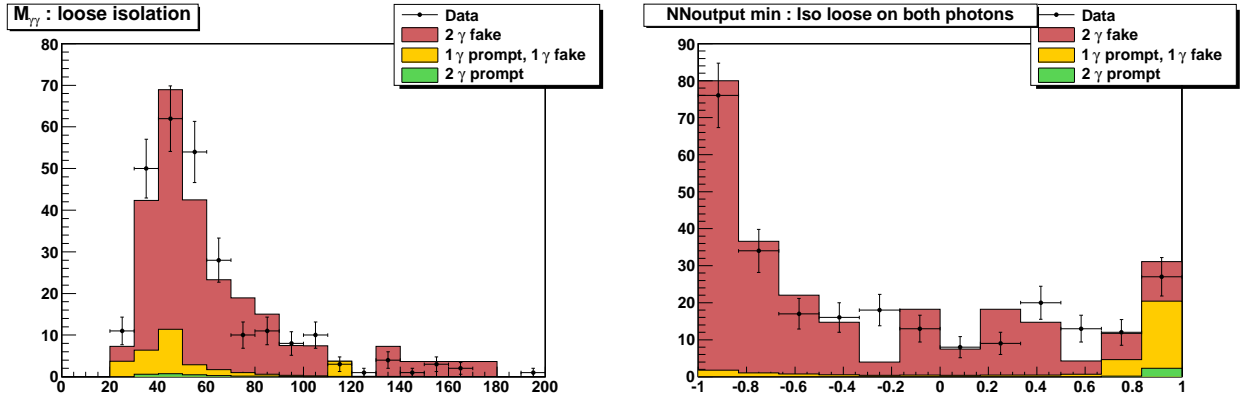


FIG. 8.22 – Distribution de masse invariante  $\gamma\gamma$  (à gauche) et de sortie de plus faible valeur du réseau de neurones (à droite) pour une sélection d'isolation lâche sur les deux photons.

Méthode	Pureté	Nb evt signal
Info gen	$0,094 \pm 0,016$	$30,222 \pm 5,560$
2 divisions	$0,104 \pm 0,034$	$34,237 \pm 13,038$
Ajustement	$0,167 \pm 0,069$	$54,915 \pm 25,873$

FIG. 8.23 – Pureté et nombre d'évènements 1 prompt 1 faux mesuré dans les données par la méthode des templates.

## 8.4 Conclusions et perspectives

La luminosité accumulée dans l'expérience CMS au jour où j'écris ces lignes ( $10 \text{ nb}^{-1}$ ) n'est pas suffisante pour effectuer une mesure de la pureté et du nombre d'évènements de signal  $\gamma\gamma+X$  dans les données. Une première mesure des spectres de masse invariante  $M_{\gamma\gamma}$ , d'impulsion transverse diphoton  $q_T$  et des distributions angulaires  $\cos(\theta^*)$  et  $\Delta\phi$  devrait être réalisable dès  $10 \text{ pb}^{-1}$ . Etant donné la faible luminosité actuelle où environ deux diphotons seulement sont attendus par prédiction NLO (avec Diphox et Gamma2MC), nous avons toutefois pu étudier les différentes distributions diphotons pour divers critères d'identification des photons, par isolation, isolation combinée et coupure sur la sortie du réseau de neurone de forme du cluster, en faisant confiance aux informations de la simulation quant à la composition de l'échantillon sélectionné. Nous avons aussi pu effectuer une première mesure du bruit de fond 1 prompt 1 faux à partir des données.

Nous avons aussi accompli une première étape en direction de la mesure de la section efficace  $\gamma\gamma+X$ , en préparant cette mesure à l'aide d'échantillons générés avec Madgraph (dans la production officielle de CMS). Nous avons présenté les spectres en pureté et nombre d'évènements de signal non corrigés pour cinq à sept divisions des distributions  $M_{\gamma\gamma}$ ,  $q_T$ ,  $\cos(\theta^*)$  et  $\Delta\phi$  après les critères d'identification des photons appliqués. La variable template utilisée pour la mesure est la sortie du réseau de neurone de forme du cluster  $NNoutput_{min}$  (i.e. minimum de  $NNoutput$  de chacun des deux photons), qui a montré le meilleur pouvoir de discrimination. Quatre méthodes templates ont été essayées : les méthodes à deux et trois divisions ainsi que la méthode d'ajustement par le maximum de vraisemblance utilisant deux distributions templates (signal  $\gamma\gamma$  et bruit de fond incluant  $\gamma$ +jet et dijet) et trois distributions templates ( $\gamma\gamma$ ,  $\gamma$ +jet et dijet). La faible statistique de l'échantillon QCD dijet après coupures rend plutôt instables les résultats obtenus par la plupart des méthodes, qui peuvent être vus comme probant la stabilité des méthodes face à une forte fluctuation du bruit de fond. La méthode la plus stable nous a semblé être la méthode deux divisions, en ce qu'elle est celle qui utilise le moins d'information sur la forme des distributions templates. Dans ces conditions, les incertitudes systématiques ont seulement été discutées et mériteraient d'être étudiées en détail avec des échantillons disposant d'une statistique plus importante. La prochaine

production officielle de CMS devrait permettre cela.

La méthode template de la matrice  $4 \times 4$  utilisée pour la mesure du processus  $\gamma\gamma+X$  au Tevatron devrait aussi être essayée. Elle pourrait permettre de construire les distributions templates plus facilement à partir des données, en ce qu'elle demande des templates pour les photons et les jets seulement, tandis que les autres méthodes présentées les demandent pour les combinaison  $\gamma\gamma$ ,  $\gamma$ +jet et dijet.

Un autre générateur à gerbe partonique, Sherpa [119] pourrait aussi être utilisé (il ne l'a encore jamais été dans les précédentes mesures du Tevatron), pour la préparation de la mesure mais aussi pour la comparaison avec la théorie. Ce générateur effectue un traitement démocratique des radiations QED et QCD pour la gerbe et l'appariement avec les émissions réelles au niveau élément de matrice. Il serait en particulier intéressant de comparer les composantes de fragmentation entre les générateurs Pythia, Madgraph et Sherpa.

## Chapitre 9

# Recherche du boson de Higgs dans le canal $H \rightarrow \gamma\gamma$

Depuis la fin des années 1960 où la théorie de l'interaction électrofaible a vu le jour, l'unification de l'interaction électromagnétique et de l'interaction faible est obtenue par l'introduction d'un champ scalaire dont la particule massive associée est le boson de Higgs. Le boson de Higgs n'a encore jamais été observé à ce jour. Sa recherche constitue un des enjeux majeurs de la physique des particules aujourd'hui, car l'étude de ses propriétés pourrait permettre une meilleure compréhension de la physique sous-tendant la brisure de la symétrie du secteur électro-faible. La recherche du boson de Higgs au LHC devrait conduire à sa découverte ou son exclusion pour toute la gamme de masse où il est attendu par la théorie. La désintégration  $H \rightarrow \gamma\gamma$  est le canal privilégié dans CMS pour la recherche d'un boson de Higgs de basse masse,  $110 < m_H < 140$  GeV. Pour cette plage de masse, la sensibilité de CMS est plus grande dans ce canal que dans les canaux  $H \rightarrow ZZ$  ou  $H \rightarrow WW$  et la désintégration en une paire de photon constitue une signature claire en raison de la bonne résolution du ECAL.

La méthode expérimentale pour une recherche est très différente de la méthode suivie pour une mesure. Le but ici n'est pas de mesurer les spectres cinématiques pour le processus  $H \rightarrow \gamma\gamma$  mais de certifier l'existence du boson de Higgs à une masse donnée, ou exclure son existence pour une plage de masse la plus large possible. Les outils utilisés sont aussi de nature statistique ; il ne s'agit plus de soustraire la composante du bruit de fond mais d'évaluer la signification pour une observation du signal, ou de discriminer entre deux hypothèses, signal plus bruit de fond ou bruit de fond seul. Deux grandes familles de méthodes peuvent conduire au résultat. Une première méthode d'analyse consiste à appliquer des critères de sélection très sévères sur les observables pertinentes (énergies d'isolation, variables de forme du cluster, variables cinématiques caractéristiques du processus  $H \rightarrow \gamma\gamma$ ) rassemblés ou non dans des réseaux de neurones [104, 88], et à évaluer la signification avec le lot très réduit d'événements passant les coupures avec des méthodes simples (expérience de comptage). Une alternative consiste à appliquer des critères de sélection moins sévères pour préserver un plus grand nombre d'événements dans les données, et à utiliser une méthode d'estimation de la signification plus sophistiquée, utilisant le spectre des principales observables cinématiques [103] (sur lesquelles on n'aura appliqué aucune sélection). A priori, la deuxième méthode est plus performante mais est aussi plus sensible aux incertitudes systématiques.

Dans ce chapitre, nous commencerons avec l'exposé des projections à 7 TeV [107] dans le centre de masse effectuées à partir du potentiel de découverte de l'analyse à 14 TeV du Physics Technical Design Report (PTDR) de CMS [104], travail auquel nous avons participé en ce qui concerne l'établissement du nombre d'événements de bruits de fond avec les générateurs NLO Diphox et Gamma2MC. Nous effectuerons par la suite une mise à jour de l'analyse la plus simple du PTDR avec une énergie de 7 TeV dans le centre de masse et une luminosité de  $1 \text{ fb}^{-1}$ . Plutôt qu'une analyse par coupure séquentielles avec un réseau de neurone utilisant les variables cinématique, nous construirons ensuite un rapport de vraisemblance multi-variables qui permettra d'améliorer la signification. Le bruit de fond sera mesuré à partir des bandes de côté de la distribution de masse invariante et les incertitudes systématiques seront estimées de la même manière. Enfin, la méthode de repondération proposée chapitre 7 pour le signal et le

bruit de fond sera mise en oeuvre et son impact estimé sur la sensibilité de l'analyse à 7 TeV et  $1 \text{ fb}^{-1}$ .

## 9.1 Sensibilité au canal $H \rightarrow \gamma\gamma$ : projections à 7 TeV et $1 \text{ fb}^{-1}$

Aucune analyse de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  dans CMS n'a été publiée depuis le PTDR [88], où l'analyse avait été effectuée pour une énergie de 14 TeV dans le centre de masse. Lorsqu'il a été décidé de démarrer l'exploitation du LHC avec une énergie dans le centre de masse de 7 TeV, l'analyse utilisée à 14 TeV n'a pas été ré-optimisée ni portée à 7 TeV pour des raisons de temps ; seuls les nombres d'évènements ainsi que les incertitudes statistiques et systématiques associées ont été mis à jour [107], de manière très conservatrice.




FIG. 9.1 – Rapport de la section efficace nécessaire pour exclure le boson de Higgs à 95% de niveau de confiance sur la section efficace dans le modèle standard, en fonction de la masse du boson de Higgs pour le canal  $H \rightarrow \gamma\gamma$ , pour une luminosité intégrée de  $1 \text{ fb}^{-1}$  et une énergie dans le centre de masse de 7 TeV dans CMS.

Pour produire le graphe d'exclusion avec  $1 \text{ fb}^{-1}$  de luminosité intégrée figure 9.1, seule l'analyse la plus simple de [88] a été utilisée. Cette analyse est basée sur des coupures séquentielles :

- portant sur la cinématique des photons :  $p_{T,1} > 40 \text{ GeV}$  et  $p_{T,2} > 35 \text{ GeV}$  dans l'acceptance du détecteur  $|\eta| < 2.5$
- portant sur les énergies d'isolation autour des photons dans le ECAL, HCAL et le trajectographe, ainsi que sur le nombre de traces autour des photons dans le trajectographe.

Suite à ces critères de sélection, l'analyse à 14 TeV prévoyait de séparer les évènements en plusieurs catégories, de pseudo-rapidité et  $R9$ . Ceci améliore la sensibilité de l'analyse en raison du rapport du nombre d'évènements de signal et de bruit de fond en fonction des catégories. Pour les projections à 7 TeV, aucune catégorie n'est définie (tous les évènements sont gardés dans une seule catégorie). L'alternative à l'analyse par coupures séquentielles utilisant plusieurs réseaux de neurones n'a pas non plus été utilisée pour ces projections.

Pour calculer le rapport des sections efficaces  $\frac{\sigma_{7\text{TeV}}}{\sigma_{14\text{TeV}}}$  pour le bruit de fond irréductible (voir figure 9.2), les évènements satisfaisant  $p_{T,1} > 40 \text{ GeV}$  et  $p_{T,2} > 35 \text{ GeV}$  dans l'acceptance du détecteur  $|\eta| < 2.5$  sont utilisés (aucun critère d'isolation n'est appliqué). Sur la plage de masse invariante  $100 < M_{\gamma\gamma} < 200 \text{ GeV}$ , le rapport moyen entre les sections efficaces à 7 TeV et 14 TeV vaut  $\frac{\sigma_{7\text{TeV}}}{\sigma_{14\text{TeV}}} = 0.446$ , valeur qui a été utilisée pour calculer les projections du nombre d'évènements du bruit de fond passant la sélection à 7 TeV à partir de ces nombres à 14 TeV.




FIG. 9.2 – A gauche, section efficaces différentielles du bruit de fond  $\gamma\gamma+X$  au NLO en fonction de la masses invariantes à 7 TeV et 14 TeV dans le centre de masse, calculées avec Diphox (contributions Born et fragmentations) et Gamma2MC (contribution Box). A droite, le rapport des sections efficaces différentielles à 7 TeV et 14 TeV en fonction de la masse invariante.

On montre figure 9.3 le rapport des sections efficaces 7 TeV / 14 TeV utilisées pour le signal, dont les sections efficaces à 7 TeV sont données référence [137] et à 14 TeV par l’analyse du PTDR. Dans l’analyse PTDR à 14 TeV, le processus de fusion de gluon était considéré au NLO tandis qu’il est considéré aujourd’hui au NNLO, ce qui conduit à un gain sur la section efficace totale du signal à 7 TeV d’environ 30%, tandis que les bruits de fond restent estimés au même ordre de la théorie des perturbations. Les sections efficaces sont calculées au NNLO pour le mécanisme de fusion de gluon avec HIGLU, au NLO avec VV2H pour la fusion de bosons vecteurs, au NLO pour la production associée avec un boson vecteur avec V2HV et au LO pour la production associée avec une paire  $t\bar{t}$  avec HQQ [137].




FIG. 9.3 – A gauche, rapport des section efficaces inclusives du signal 7 TeV / 14 TeV. A droite, le rapport des sections efficaces totales à 7 TeV, avec fusion de gluon au NNLO par rapport au NLO, si on garde la fusion de bosons vecteurs au NLO, la production associée avec un boson vecteur au NLO et la production associée avec une paire  $t\bar{t}$  au LO.

Le résultat obtenu figure 9.1 est très conservatif : seule l’analyse la plus simple, par coupure séquentielle et sans catégorie a été utilisée. D’autres analyses, utilisant des réseaux de neurones ou des outils statistiques plus sophistiqués devraient donner de meilleurs résultats, ce que nous allons montrer dans la suite de ce chapitre.

## 9.2 Préparation à la recherche du boson de Higgs dans le canal $H \rightarrow \gamma\gamma$ pour $\sqrt{s} = 7$ TeV et $1 fb^{-1}$

A part pour les projections à 7 TeV de l'analyse PTDR basée sur coupures séquentielles à 14 TeV, l'analyse PTDR n'a pas été mise à jour depuis 2006. Le but de cette section est double : mettre à jour l'analyse la plus simple du PTDR avec une énergie dans le centre de masse de 7 TeV, et proposer une nouvelle analyse plus sophistiquée. À titre d'exercice, les résultats seront présentés dans l'hypothèse d'une luminosité intégrée de  $10 fb^{-1}$  (notamment pour le calcul des significances, afin de rendre sensible les améliorations progressives de l'analyse), bien que les résultats finaux soient ceux concernant les limites d'exclusion à 95 % de niveau de confiance avec une luminosité de  $1 fb^{-1}$ .

Les critères de sélection de base pour l'analyse PTDR la plus simple (celle utilisée pour les projections à 7 TeV) sont l'impulsion transverse des photons et les critères d'isolation. Plusieurs ingrédients ont ensuite été proposés pour améliorer la sensibilité de l'analyse au signal (analyse du PTDR optimisée). Le rejet des bruits de fond est réalisée à l'aide de réseaux de neurones, NNisol pour le bruit de fond réductible (dont nous avons comparé les performances avec le réseau de neurones que nous proposons section 5.3.3), et un réseau de neurone utilisant les variables cinématiques pour le bruit de fond irréductible. De meilleurs résultats peuvent être obtenus si les événements sont classés en catégories en  $\eta$  et en  $R9$ . Pour les photons reconstruits par exemple dans le tonneau et ayant un  $R9$  proche de 1, un meilleur rapport signal sur bruit de fond est attendu. L'analyse prévoyait d'utiliser des critères de sélection plus ou moins sévères suivant le rapport signal sur bruit de fond de chaque catégorie. Enfin, la signification ainsi que les limites d'exclusion étaient calculées pour une expérience de comptage du nombre d'événements dans une fenêtre de masse invariante autour du pic du boson de Higgs.

L'analyse de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  que nous proposons est inclusive et basée sur un rapport de vraisemblance multi-variable pour l'estimation de la signification et des limites d'exclusion. Elle est plus proche de l'analyse du PTDR d'ATLAS [103] que de CMS [88]. Dans un premier temps, nous examinerons comment la sortie du réseau de neurone de discrimination  $\gamma/\pi^0$  peut être utilisée pour améliorer les performances de l'analyse. Nous utiliserons aussi les catégories en  $\eta$  et en  $R9$ . Nous étudierons ensuite les variables cinématiques discriminantes, mais au lieu de construire un réseau de neurones, nous utiliserons les histogrammes des distributions cinématiques dans un rapport de vraisemblance multi-variables. Nous souhaitons aussi que cette analyse fasse le plus confiance possible aux données elles-mêmes plutôt qu'à la simulation, c'est pourquoi nous estimerons le taux de bruit de fond à partir des données, en utilisant les bandes de côté de la distribution de masse invariante  $\gamma\gamma$ . Nous évaluerons les incertitudes systématiques pour le signal et le bruit de fond, qui seront incluses dans les résultats de l'analyse. Enfin, nous évaluerons l'impact de la repondération sur les résultats, dont la méthode a été expliquée chapitre 7.

Une autre approche aurait pu être choisie, qui consiste à utiliser toute la forme des distributions pour construire les densités de probabilité des observables et où l'estimation de la signification est effectuée avec un rapport de vraisemblance multi-variable utilisant les événements plutôt que les histogrammes. L'intégration du réseau de neurone de discrimination  $\gamma/\pi^0$  dans une telle analyse est en cours, mais n'est pas effectuée par mes soins et n'a pas pu être terminée au moment où j'écris ces lignes.

### 9.2.1 Échantillons et sélection de base des photons

Les échantillons utilisés pour la recherche du boson de Higgs sont listés tableau 9.4. Pour le mécanisme de production du boson de Higgs par fusion de gluons, nous utiliserons l'échantillon généré avec MC@NLO, qui intègre les effets NLO éléments de matrice et les effets LL de la gerbe partonique de Herwig. Les mécanismes de production associée avec un boson vecteur ou une paire  $t\bar{t}$  et de fusion de bosons vecteurs ont été générés avec Pythia. Tous les bruits de fond sauf le processus Box ont été générés avec Madgraph. Le processus QCD dijet généré avec Pythia est utilisé seulement pour l'entraînement du réseau de neurones.

Générateur / processus	Sélection	Section efficace	Nb événements
Pythia QCD dijet	$\hat{p}_T > 30$ GeV	60410000.0	5269664
Madgraph QCD jets	$100 < HT < 250$ GeV	7000000	10875132
Madgraph QCD jets	$250 < HT < 500$ GeV	171000	4907817
Madgraph QCD jets	$500 < HT < 1000$ GeV	5200	3785908
Madgraph QCD jets	$HT > 1000$ GeV	83	1668913
Madgraph $\gamma$ +jets	$40 < HT < 100$ GeV	23620	2228981
Madgraph $\gamma$ +jets	$100 < HT < 200$ GeV	3476	1005161
Madgraph $\gamma$ +jets	$HT > 200$ GeV	485	781692
Madgraph $\gamma\gamma$ +jets (born)	$M_{\gamma\gamma} > 40$ GeV, $p_T > 10$ GeV	131	1091347
Pythia $\gamma\gamma$ box	$10 < \hat{p}_T < 25$ GeV	358.2	550000
Pythia $\gamma\gamma$ box	$25 < \hat{p}_T < 250$ GeV	12.37	543520
Pythia $\gamma\gamma$ box	$\hat{p}_T > 250$ GeV	0.000208	216432
MC@NLO $gg \rightarrow H \rightarrow \gamma\gamma$	-	0.0253	148872
Pythia $WH/ZH/ttH$ , $H \rightarrow \gamma\gamma$	-	0.00244	107930
Pythia $WW, ZZ \rightarrow H \rightarrow \gamma\gamma$	-	0.003498	120820

FIG. 9.4 – Echantillons simulés utilisés pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$ .

La sélection de base des photons est la même que pour les analyses  $\gamma+X$  et  $\gamma\gamma+X$ . Le filtre “bonne collision” est appliqué aux échantillons. On sélectionne les photons ayant une énergie transverse plus grande que 20 GeV après suppression des “spikes” par les deux critères de forme du cluster et de synchronisation en temps. Le même critère d’identification des photons est ensuite appliqué, qui demande  $EcalIso < 4$  GeV,  $HcalIso < 2$  GeV,  $TrackerIso < 2$  GeV et  $H/E < 0.05$ . Nous avons choisi de ne pas utiliser le critère de sélection des photons demandant un nombre de traces inférieur à un certain seuil dans un cône en  $\Delta R$  autour des photons (comme c’était le cas pour l’analyse TDR), parce que cette observable n’offre pas encore un bon accord entre données et simulation. Nous avons donc préféré utiliser par cohérence le même critère que dans les autres analyses, même si il serait possible de durcir ce critère pour rejeter plus de bruit de fond réductible.

### 9.2.2 Discrimination $\gamma/\pi^0$ pour le canal $H \rightarrow \gamma\gamma$

La recherche du signal  $H \rightarrow \gamma\gamma$  passe par la réduction de deux types de bruits de fond, le bruit de fond réductible (processus QCD jets,  $\gamma$ +jets) et le bruit de fond dit irréductible ( $\gamma\gamma+X$ ). Le réseau de neurones de discrimination  $\gamma/\pi^0$  devrait surtout permettre la suppression du bruit de fond réductible. Ses trois configurations seront comparées (forme du cluster, environnement et combinés).

Pour l’entraînement du réseau de neurones, les photons de la désintégration  $gg \rightarrow H \rightarrow \gamma\gamma$  généré avec MC@NLO ont été utilisés comme signal, tandis que les photons du processus QCD dijet avec  $\hat{p}_T > 30$  GeV (ce qui correspond grossièrement à une masse invariante  $\gamma\gamma$  supérieure à 60 GeV) ont été utilisés comme bruit de fond. Pour l’application, nous utiliserons les échantillons Madgraph pour le bruit de fond. L’échantillon de signal MC@NLO a été préalablement divisé en deux pour séparer échantillon d’entraînement et d’application.

#### Pouvoir discriminant du réseau de neurone

On montre figure 9.5 l’efficacité du signal en fonction du rejet du bruit de fond pour la sortie du réseau de neurone du photon ayant la valeur minimum pour les variables d’entrée de forme du cluster, d’environnement, de forme du cluster et d’environnement combinés, et la sortie de NNisol (composé de  $R9$ ,  $\Delta R(\gamma, SC_{closest})$  et des trois énergies d’isolation dans le ECAL, HCAL et trajectographe). Tous les bruits de fond considérés sont inclus (QCD jets,  $\gamma$ +jets,  $\gamma\gamma+X$ ). Chaque diphoton est constitué des deux photons de plus haut  $p_T$  dans l’évènement, si sa masse invariante est telle que  $M_{\gamma\gamma} > 100$  GeV. Le meilleur pouvoir discriminant est atteint avec le réseau de neurone ayant pour variables d’entrées forme du cluster et environnement, avec un rejet du bruit de fond de 67% pour 90% d’efficacité de signal.




FIG. 9.5 – Efficacité du signal ( $gg \rightarrow H \rightarrow \gamma\gamma$  MC@NLO) contre rejet du bruit de fond (QCD jets,  $\gamma$ +jets,  $\gamma\gamma$ +X inclus), pour la sortie du réseau de neurone du photon ayant la plus faible valeur de sortie.

La figure 9.6 montre la sortie du réseau de neurone de forme du cluster et d’environnement pour chacun des processus de signal et du bruit de fond. Les photons du processus de QCD jets piquent à -1, tandis que les photons de  $\gamma$ +jets piquent à -1 (jet) et en 1 (photon prompt). Les photons issus du processus  $\gamma\gamma$ +X piquent bien en 1, mais de manière légèrement moins prononcée que les photons issus du boson de Higgs.

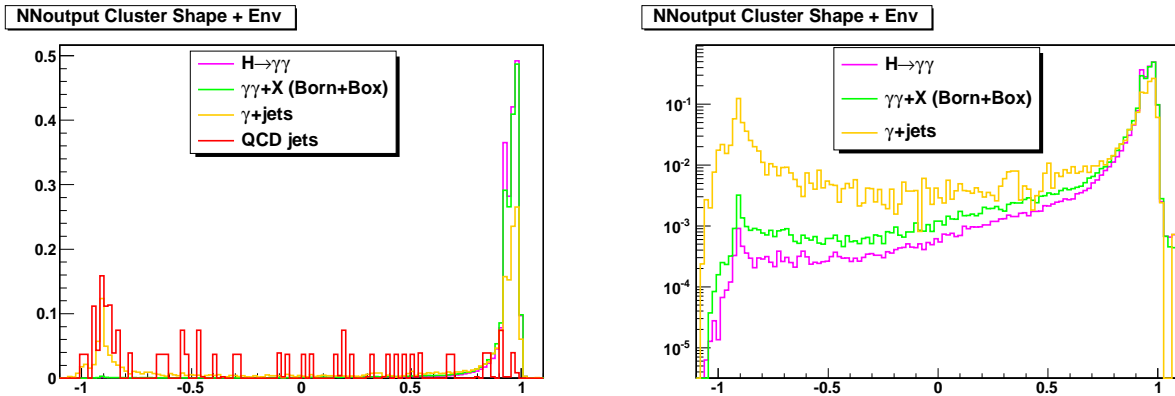


FIG. 9.6 – Sortie du réseau de neurone de forme du cluster et d’environnement pour les deux photons (deux entrées par évènement), en échelle linéaire à gauche et en échelle logarithmique à droite. Toutes les distributions sont normalisées à l’unité.

### 9.2.3 Construction des catégories

L’analyse du PTDR définit plusieurs catégories pour augmenter la signification d’une observation du boson de Higgs. Pour chaque évènement, on cherche parmi les deux photons sélectionnés :

- Le photon ayant la valeur minimum de  $R9$  ( $R9_{min}$ )
- Le photon ayant la valeur maximum de  $|\eta|$  ( $|\eta_{max}|$ )

L’idée est que si parmi les deux photons du diphoton, l’un des deux est reconstruit à grandes valeurs de  $\eta$  et à petites valeurs de  $R9$ , alors un faible rapport signal sur bruit de fond est attendu. Au contraire si les deux photons sont reconstruits à petit  $\eta$  et  $R9$  proche de 1, un rapport signal sur bruit de fond plus favorable est attendu. Quatre, six et douze catégories sont alors construites pour tirer parti de cette observation.

#### Quatre catégories

- Catégorie 0 si  $|\eta_{max}| < 1.479$  et  $R9_{min} > 0.93$



- Catégorie 1 si  $|\eta_{max}| < 1.479$  et  $R9_{min} < 0.93$
- Catégorie 2 si  $|\eta_{max}| > 1.479$  et  $R9_{min} > 0.93$
- Catégorie 3 si  $|\eta_{max}| > 1.479$  et  $R9_{min} < 0.93$

#### Six catégories

- Catégorie 0 si  $|\eta_{max}| < 1.479$  et  $R9_{min} > 0.948$
- Catégorie 1 si  $|\eta_{max}| < 1.479$  et  $0.9 < R9_{min} < 0.948$
- Catégorie 2 si  $|\eta_{max}| < 1.479$  et  $R9_{min} < 0.9$
- Catégorie 3 si  $|\eta_{max}| > 1.479$  et  $R9_{min} > 0.948$
- Catégorie 4 si  $|\eta_{max}| > 1.479$  et  $0.9 < R9_{min} < 0.948$
- Catégorie 5 si  $|\eta_{max}| > 1.479$  et  $R9_{min} < 0.9$

#### Douze catégories

- Catégorie 0 si  $|\eta_{max}| < 0.9$  et  $R9_{min} > 0.948$
- Catégorie 1 si  $|\eta_{max}| < 0.9$  et  $0.9 < R9_{min} < 0.948$
- Catégorie 2 si  $|\eta_{max}| < 0.9$  et  $R9_{min} < 0.9$
- Catégorie 3 si  $0.9 < |\eta_{max}| < 1.4442$  et  $R9_{min} > 0.948$
- Catégorie 4 si  $0.9 < |\eta_{max}| < 1.4442$  et  $0.9 < R9_{min} < 0.948$
- Catégorie 5 si  $0.9 < |\eta_{max}| < 1.4442$  et  $R9_{min} < 0.9$
- Catégorie 6 si  $1.4442 < |\eta_{max}| < 2.1$  et  $R9_{min} > 0.948$
- Catégorie 7 si  $1.4442 < |\eta_{max}| < 2.1$  et  $0.9 < R9_{min} < 0.948$
- Catégorie 8 si  $1.4442 < |\eta_{max}| < 2.1$  et  $R9_{min} < 0.9$
- Catégorie 9 si  $2.1 < |\eta_{max}| < 2.5$  et  $R9_{min} > 0.948$
- Catégorie 10 si  $2.1 < |\eta_{max}| < 2.5$  et  $0.9 < R9_{min} < 0.948$
- Catégorie 11 si  $2.1 < |\eta_{max}| < 2.5$  et  $R9_{min} < 0.9$

La répartition des différents signaux et bruits de fond en fonction des catégories est montrée figure 9.7, après les critères d'impulsion transverse et d'isolation sur les photons, et de masse invariante  $M_{\gamma\gamma} > 100$  GeV. Les événements des processus  $H \rightarrow \gamma\gamma$  et  $\gamma\gamma+X$  sont répartis approximativement équitablement selon les catégories (ce qui est vrai surtout dans le cas quatre et six catégories), tandis que les photons des bruits de fond réductibles  $\gamma$ +jets et QCD jets sont rassemblés vers les catégories à bas  $R9$ .

### 9.2.4 Optimization en fonction de la significace

Le signal  $H \rightarrow \gamma\gamma$  recherché est très ténu par rapport à la quantité colossale de bruit de fond. Pour établir ou infirmer la présence du boson de Higgs dans ce canal avec une luminosité donnée, un test statistique correspondant au résultat de l'expérience (présence ou non du signal) doit être mis en place. Un test statistique classique est le rapport de vraisemblance. A partir de son expression peuvent être calculés la significace d'une observation ainsi que les limites d'exclusion avec 95% de niveau de confiance.

#### Rapport de vraisemblance

Le rapport de vraisemblance est un test statistique correspondant au résultat de l'expérience selon deux hypothèses alternatives :

- L'hypothèse où les données sont composées de bruit de fond seul.
- L'hypothèse où les données sont composées de signal et de bruit de fond.

Soient  $s$  et  $b$  le nombre d'événements de signal et de bruit de fond attendus. Le rapport de vraisemblance  $Q(n)$  s'écrit comme le rapport des densités de probabilités des deux hypothèses :

$$Q = \frac{L(n, s + b)}{L(n, b)}$$

$$L(n, x) = \frac{e^{-x}}{n!} x^n$$




FIG. 9.7 – Répartition des événements selon 4 (en haut), 6 (au milieu), ou 12 (en bas) catégories en  $R9$  et  $\eta$ . A gauche, répartition du signal et des bruits de fond pour  $10 \text{ fb}^{-1}$  de luminosité intégrée. A droite, répartition pour le signal seulement (distribution normalisée à 1).

Pour une expérience de comptage,  $L(n, x)$  est la probabilité de Poisson d'observer  $n$  événements quand une valeur moyenne de  $x$  événements est attendue ( $x$  étant égal à  $b$  dans l'hypothèse bruit de fond seul et à  $s + b$  dans l'hypothèse signal plus bruit de fond). On définit le logarithme du rapport de vraisemblance (LLR, log-likelihood ratio) :

$$\ln(Q) = n \cdot \ln\left(1 + \frac{s}{b}\right) - s$$

Dans la limite des grandes statistiques, le test statistique  $-2\ln(Q)$  converge vers la différence de valeur du  $\Delta\chi^2$  entre un ajustement entre les données et la distribution du bruit de fond seul d'une part, et un ajustement entre les données et la distribution du signal plus bruit de fond d'autre part.

Dans le cas où l'expérience de comptage porte sur  $N$  variables aléatoires  $i$  indépendantes au lieu d'une

seule, il est possible d'écrire le rapport de vraisemblance comme :

$$Q = \prod_i^N \frac{L(n_i, s_i + b_i)}{L(n_i, b_i)}$$

Ces  $N$  variables aléatoires indépendantes peuvent correspondre soit à des observables en tant que telles (par exemple  $M_{\gamma\gamma}$ ,  $q_T$ ,  $\cos(\theta^*)$ ), soit aux  $N$  divisions considérées de l'histogramme de l'observable utilisée dans le test statistique (par exemple pour la distribution  $M_{\gamma\gamma}$ ), soit encore aux  $N$  catégories considérées pour l'observable dans le test statistique. Le rapport de vraisemblance logarithmique s'écrit alors :

$$\ln(Q) = \sum_i^N n_i \ln\left(1 + \frac{s_i}{b_i}\right) - s_i$$

### Calcul de la signficance

La signficance d'une observation du signal quantifie la probabilité pour que le nombre d'évènements observés ne soit pas du à une fluctuation du bruit de fond mais à la présence du signal. La signficance est souvent mesurée en "déviations standards", dans l'hypothèse d'une distribution gaussienne de la signficance. Plus la signficance est grande, plus la probabilité pour laquelle l'hypothèse du bruit de fond seul donne une distribution ressemblant à celle du signal est faible. Une découverte est réalisée lorsque cette probabilité est inférieure à  $5.7 \times 10^{-7}$  (cinq déviations standard pour une distribution gaussienne).

Dans la limite d'un grand nombre d'évènements, la formule approximée suivante peut être appliquée [165] :

$$S = \sqrt{2 \ln(Q)}$$

Dans la suite, les critères de sélection ainsi que les observables choisies seront optimisées pour obtenir une signficance maximum. On prendra  $n_i = s_i + b_i$ .

#### 9.2.5 Effet du réseau de neurone de discrimination $\gamma/\pi^0$ sur la signficance

A ce stade, il est d'ores et déjà possible de choisir un critère de sélection sur la sortie du réseau de neurones de sorte à maximiser la signficance d'une observation du boson de Higgs. Ceci est effectué dans l'hypothèse d'une luminosité intégrée de  $10 \text{ fb}^{-1}$ , pour la sortie du réseau de neurone de forme du cluster et environnement combinés du photon ayant la plus basse valeur de cette sortie ( $NNoutput_{min}$ , variable de discrimination  $\gamma/\pi^0$  qui a montré le meilleur pouvoir de discrimination). La figure figure 9.8 montre l'optimisation de la signficance en fonction de cette variable sans catégorie et avec quatre catégories. La signficance calculée par simple expérience de comptage dans la plage de masse invariante  $110 < M_{\gamma\gamma} < 130 \text{ GeV}$  est moins grande que celle obtenue si la plage de masse invariante est divisée en régions de 1 GeV pour le calcul du rapport de vraisemblance. On observe figure 9.7 que le critère de sélection sur  $NNoutput_{min}$  permettra de gagner en signficance pour les catégories à bas  $R9$  (catégories 1 et 3), où est rassemblé plus de bruit de fond que les catégories à haut  $R9$ . Pour l'instant, les erreurs systématiques sur le signal et les bruits de fond n'ont pas été prises en compte.

On résume tableau 9.9 les valeurs choisies pour les critères de sélection sur la sortie du réseau de neurones  $NNoutput_{min}$  par maximisation de la signficance. On observe que la division des évènements en catégories permet de relâcher la coupure sur  $NNoutput_{min}$  pour les catégories 0 et 2 à haut  $R9$ . La figure 9.10 (sans catégories) et 9.11 (pour les différentes catégories) montrent les distributions de masse invariante  $\gamma\gamma$  après coupure sur la sortie du réseau de neurone. A ce stade les évènements de QCD jets de plus bas  $HT$  ont tous été supprimés.

Les effets de l'utilisation de catégories et du réseau de neurones de discrimination  $\gamma/\pi^0$  sur la signficance peuvent être lus tableau 9.12. Trois cas différents sont comparés, chacun avec et sans utilisation des quatre catégories. Dans le premier cas la signficance est calculée à partir du spectre de masse invariante




FIG. 9.8 – Significace d’une observation du boson de Higgs en fonction de  $NNoutput_{min}$  pour une expérience de comptage dans la plage  $110 < M_{\gamma\gamma} < 130$  GeV à gauche, et avec divisions de cette plage par tranche de 1 GeV à droite, dans le cas sans catégories et dans le cas quatre catégories.

Catégories	Sélection	Significace
Sans catégories	$NNoutput_{min} > 0.86$	2.82
Catégorie 0	$NNoutput_{min} > 0.54$	2.77
Catégorie 1	$NNoutput_{min} > 0.84$	1.85
Catégorie 2	$NNoutput_{min} > 0.62$	0.95
Catégorie 3	$NNoutput_{min} > 0.86$	0.78

FIG. 9.9 – Résultats de l’optimisation de la significace en fonction de la sortie du réseau de neurones.




FIG. 9.10 – Distributions de masse invariante  $M_{\gamma\gamma}$  après coupure sur la sortie du réseau de neurone sans utilisation des catégories, pour une luminosité intégrée de  $1 fb^{-1}$ , une énergie dans le centre de masse de 7 TeV et une masse du boson de Higgs de 120 GeV.

$\gamma\gamma$  (avec des divisions de 1 GeV), dans le deuxième cas avec ce même spectre une fois un critère de sélection optimisé appliqué sur la sortie du réseau de neurones  $NNoutput_{min}$ , dans le troisième cas à partir des spectres de masse invariante  $\gamma\gamma$  et de  $NNoutput_{min}$  (avec 22 divisions de pas 0,1 entre -1,1 et 1,1).  $M_{\gamma\gamma}$  et  $NNoutput_{min}$  sont en effet dans une large mesure non corrélés et peuvent être utilisés dans un rapport de vraisemblance à deux variables indépendantes. Les meilleurs résultats sont obtenus avec quatre catégories pour lesquelles le critère de sélection sur la sortie du réseau de neurones est optimisé dans chaque cas (significace de 3.55 déviations standards) et dans le cas où tout le spectre  $NNoutput_{min}$  a été utilisé (significace de 3.63 déviations standards). On remarque que l’utilisation du spectre de  $NNoutput_{min}$  n’est pas aussi discriminante lorsqu’aucune catégorisation n’est effectuée.




FIG. 9.11 – Distributions de masse invariante  $M_{\gamma\gamma}$  après coupure sur la sortie du réseau de neurone pour chacune des quatre catégories, pour une luminosité intégrée de  $1 fb^{-1}$ , une énergie dans le centre de masse de 7 TeV et une masse du boson de Higgs de 120 GeV.

Observables	Catégories	Réseau de neurone (NN)	Significane
$M_{\gamma\gamma}$	Sans catégories	Sans NN	1.65
$M_{\gamma\gamma}$	4 catégories	Sans NN	3.10
$M_{\gamma\gamma}$	Sans catégories	$NNoutput_{min} > 0.86$	2.82
$M_{\gamma\gamma}$	4 catégories	Coupure $NNoutput_{min}$ (4 cat)	3.55
$M_{\gamma\gamma}, NNoutput_{min}$	Sans catégories	Spectre NN	2.36
$M_{\gamma\gamma}, NNoutput_{min}$	4 catégories	Spectre NN	3.63

FIG. 9.12 – Effets de l'utilisation des catégories et du réseau de neurones sur la significane pour une luminosité intégrée de  $10 fb^{-1}$ , sans utilisation du réseau de neurone, avec coupure sur la sortie du réseau de neurone et en utilisant tout le spectre de la sortie du réseau de neurones dans l'estimation de la significane par rapport de vraisemblance.

### 9.2.6 Utilisation des variables cinématiques pour la réduction du bruit de fond $\gamma\gamma+X$

La signature  $\gamma\gamma$  dans l'état final pour la recherche du boson de Higgs fait du processus  $\gamma\gamma+X$  un bruit de fond irréductible. Jusqu'ici, seuls les outils d'isolation et discrimination  $\gamma/\pi^0$  ont été utilisés, qui sont particulièrement performant pour le rejet des bruits de fond réductibles QCD jets et  $\gamma$ +jets. Pour réduire le bruit de fond  $\gamma\gamma+X$ , qui présente deux photons partoniques dans l'état final, il faudra utiliser d'autres outils relevant de la cinématique des événements. Le choix de la masse invariante  $M_{\gamma\gamma}$  comme observable utilisée pour le calcul de la significane tire déjà parti de cette idée, dans la mesure où le signal est piqué autour de  $m_H$  tandis que le bruit de fond décroît exponentiellement. Nous avons examiné section 7.3.2 les différences entre les distributions  $\gamma\gamma+X$  au NLO et  $gg \rightarrow H \rightarrow \gamma\gamma$  au NNLO. Dans cette partie, nous souhaitons utiliser les observables cinématiques discriminantes pour améliorer la significane d'une

observation du boson de Higgs. Dans un premier temps, nous étudierons les observables cinématiques pour les échantillons générés avec des générateurs à gerbe partonique. Nous construirons ensuite des rapports de vraisemblance multi-variables pour améliorer la signification, avant de comparer les résultats obtenus avec l'approche du PTDR qui utilise un réseau de neurone.

**Etude des variables cinématiques discriminantes**

Un certain nombre de variables cinématiques pour les processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV),  $\gamma\gamma+X$  et  $\gamma$ +jets sont montrées figures 9.13 pour  $M_{\gamma\gamma}$ , figure 9.14 pour l'impulsion transverse et longitudinale du système diphoton, figure 9.15 pour  $\cos(\theta^*)$  et  $\Delta\phi$ , figure 9.16 pour la rapidité  $Y_{\gamma\gamma}$  et la différence de pseudo-rapidité divisée par deux  $Y^*$ ) et figure 9.17 pour les impulsions transverses des photons.

La masse invariante  $M_{\gamma\gamma}$  est la variable la plus discriminante, car le signal pique pour  $M_{\gamma\gamma} = m_H$  tandis que le bruit de fond décroît exponentiellement. Nous avons souhaité montrer l'impulsion longitudinale des diphotons car cette observable est utilisée dans le réseau de neurones cinématique du PTDR, mais elle ne semble pas montrer de fort pouvoir discriminant. L'impulsion transverse est à l'inverse une variable discriminante, car son spectre est plus dur pour le signal que pour le bruit de fond. Enfin, les distributions d'impulsion transverse des photons montrent aussi un pouvoir discriminant.




FIG. 9.13 – Distribution de masse invariante  $M_{\gamma\gamma}$  pour les processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV),  $\gamma\gamma+X$  et  $\gamma$ +jets (normalisées à 1).




FIG. 9.14 – Distribution  $\gamma\gamma$  d'impulsion transverse  $q_T$  (à gauche) et longitudinale  $q_L$  (à droite) pour les processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV),  $\gamma\gamma+X$  et  $\gamma$ +jets (normalisées à 1).

Comme nous l'avons déjà noté pour les distributions aux ordres supérieurs section 7.3,  $\cos(\theta^*)$ ,  $Y^*$

sont des variables très discriminantes. Toutefois, la largeur de  $Y^*$  est dépendante de  $M_{\gamma\gamma}$  (voir figure ??) et ne peut pas être utilisée dans un rapport de vraisemblance. La discrimination est meilleure contre  $\gamma$ +jets que contre  $\gamma\gamma$ +X. Parmi les autres variables angulaires,  $\Delta\phi$  est un peu moins discriminante tandis que  $Y_{\gamma\gamma}$  ne montre pas de pouvoir discriminant.

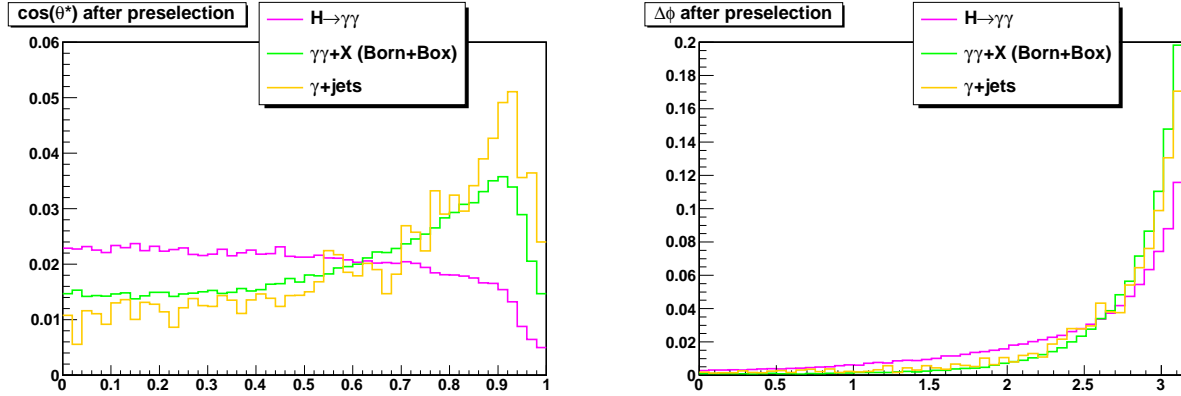


FIG. 9.15 – Distribution angulaires  $\cos(\theta^*)$  (à gauche) et  $\Delta\phi$  (à droite) pour les processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV),  $\gamma\gamma$ +X et  $\gamma$ +jets (normalisées à 1).




FIG. 9.16 – Distributions angulaires de rapidité  $Y_{\gamma\gamma}$  (à gauche) et de différence de pseudo-rapidité des photons divisée par deux  $Y^*$  (à droite) pour les processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV),  $\gamma\gamma$ +X et  $\gamma$ +jets (normalisées à 1).

Ces observations confirment les études aux ordres supérieurs que nous avons effectués. La seule différence intervient pour le spectre en impulsion transverse  $q_T$  qui nous semble plus discriminant avec les générateurs à gerbe partonique qu'avec les générateurs éléments de matrice aux ordres supérieurs. Ceci est probablement dû au fait que nous comparons ici un signal déjà NLO pour le mécanisme de fusion de gluons (généralisé avec MC@NLO) avec un bruit de fond LO (avec jets durs supplémentaires pour le Born), au lieu de comparer fusion de gluon au NNLO et  $\gamma\gamma$ +X au NLO.

### Optimisation à l'aide d'un rapport de vraisemblance multi-variables

Pour améliorer la signification d'une observation du boson de Higgs, il est possible de construire des rapports de vraisemblance multi-variables utilisant les variables cinématiques discriminantes. Nous avons déjà construit un tel rapport de vraisemblance en combinant  $M_{\gamma\gamma}$  et  $NN_{output_{min}}$ . Nous allons maintenant adjoindre à  $M_{\gamma\gamma}$  les variables cinématiques  $q_T$ ,  $\cos(\theta^*)$ ,  $Y^*$  en particulier, qui nous ont semblé être les plus discriminantes. La figure 9.19 montre que les variables cinématiques évoquées ainsi que la sortie

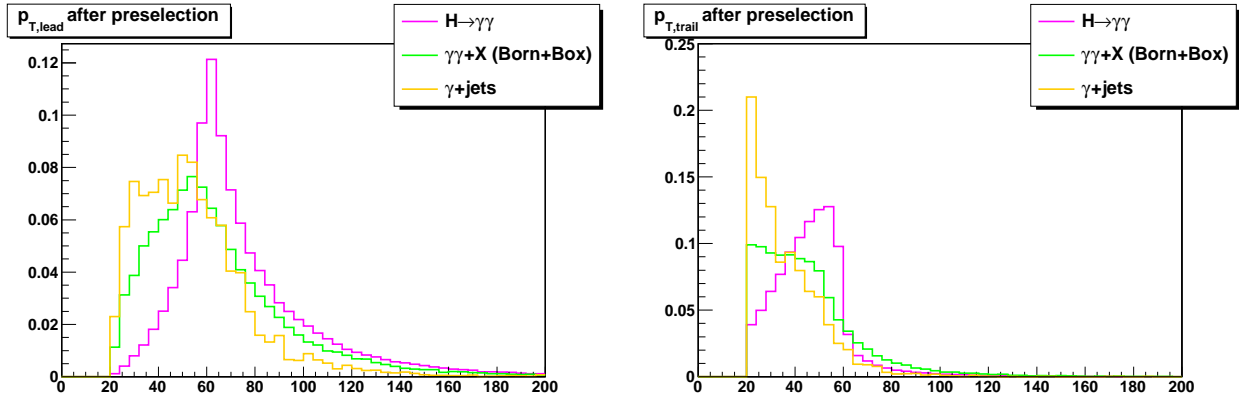


FIG. 9.17 – Distributions d'impulsion transverse pour les photons de plus haut  $p_T$  (à gauche) et de plus bas  $p_T$  (à droite) pour les processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV),  $\gamma\gamma + X$  et  $\gamma + jets$  (normalisées à 1).




FIG. 9.18 – Différence de pseudo-rapidité des photons divisée par deux  $Y^*$  pour le processus  $H \rightarrow \gamma\gamma$  ( $m_H = 120$  GeV), dans la plage  $110 < M_{\gamma\gamma} < 115$  GeV (à gauche) et  $125 < M_{\gamma\gamma} < 130$  GeV (à droite).

du réseau de neurone sont très peu corrélées entre elles et avec la masse invariante  $\gamma\gamma$ . Elles peuvent donc être utilisées dans un rapport de vraisemblance multi-variable, à l'exception de  $Y^*$  pour laquelle il n'y a pas de corrélation linéaire, mais dépendance de la largeur en fonction de  $M_{\gamma\gamma}$ . Les seules corrélations qui apparaissent concernent les variables d'impulsion transverse des photons, que nous n'utiliserons pas.

Les résultats en terme de signification pour une luminosité intégrée de  $10 fb^{-1}$  sont résumés tableau 9.20. Pour le moment, on ne tient pas compte des incertitudes systématiques sur le signal et le bruit de fond. Différentes combinaisons des variables cinématiques et de la sortie du réseau de neurone  $NN_{min}$  ont été essayées, dans quatre cas différents :

- 1 - Les événements ne sont pas divisés en catégories et aucune coupure sur la sortie du réseau de neurone n'est appliquée. Ceci permet en particulier de construire des rapports de vraisemblance dont l'une des variables est la sortie du réseau de neurone. La signification maximale est obtenue pour les combinaisons  $M_{\gamma\gamma}$ ,  $q_T$ ,  $NN_{min}$  avec  $\cos(\theta^*)$ .
- 2 - Les événements sont divisés en quatre catégories seulement pour la distribution de masse invariante et aucune coupure sur la sortie du réseau de neurone n'est appliquée. Les catégories sont seulement utilisées pour  $M_{\gamma\gamma}$  afin de simplifier la tâche d'estimation du bruit de fond (voir plus loin). La signification augmente le plus pour  $M_{\gamma\gamma}$  seul (+1,5 déviation environ) et augmente de 1 déviation pour des combinaisons plus complexes.
- 3 - Les événements sont divisés en quatre catégories seulement pour la distribution de masse invariante et une coupure sur la sortie du réseau de neurone  $NN_{min} > 0.86$  est appliquée préalablement. Ce critère permet de supprimer les événements de QCD de plus bas  $\hat{p}_T$ , ce qui conduit à une élévation appréciable






FIG. 9.19 – Matrice des coefficients de corrélation linéaire pour le signal  $gg \rightarrow H \rightarrow \gamma\gamma$  (à gauche) et le bruit de fond QCD,  $\gamma$ +jets,  $\gamma\gamma$ +X (à droite).

de la signification, de l'ordre de 0,5 à 0,8 déviations dépendant de la combinaison.

4 - Les événements sont divisés en quatre catégories seulement pour la distribution de masse invariante et une coupure sur la sortie du réseau de neurone dépendant de la catégorie de l'évènement est appliquée (les critères de sélection sont résumés tableau 9.9). Le gain en signification est marginal par rapport au cas  $NN_{min} > 0.86$  appliqué à toutes les catégories.

Observables	Significance Sans catégories	Significance $M_{\gamma\gamma}$ 4 cat.	Significance $M_{\gamma\gamma}$ 4 cat. $NN_{min} > 0.86$	Significance $M_{\gamma\gamma}$ 4 cat. $NN_{min}$ (4 cat)
$M_{\gamma\gamma}$	1.65	3.10	3.50	3.55
$M_{\gamma\gamma}, q_T$	2.51	3.63	4.30	4.34
$M_{\gamma\gamma}, q_T, NN_{min}$	3.03	4.00	-	-
$M_{\gamma\gamma}, \cos(\theta^*)$	2.07	3.34	3.95	4.00
$M_{\gamma\gamma}, q_T, \cos(\theta^*)$	2.80	3.84	4.67	4.71
$M_{\gamma\gamma}, q_T, \cos(\theta^*), NN_{min}$	3.27	4.20	-	-

FIG. 9.20 – Effets de l'utilisation des catégories, des variables cinématiques et du réseau de neurone de discrimination  $\gamma/\pi^0$  sur la signification pour une luminosité intégrée de  $10 fb^{-1}$ .

En conclusion de cette étude des rapports de vraisemblance multi-variables, l'option donnant le meilleur pouvoir discriminant semble être la combinaison des observables  $M_{\gamma\gamma}$ ,  $q_T$  et  $\cos(\theta^*)$  ou  $Y^*$ , dans le cas où la distribution de  $M_{\gamma\gamma}$  est séparée en quatre catégories et où le critère de sélection  $NN_{min} > 0.86$  a été préalablement appliqués à la suite de la préselection. La signification obtenue pour  $10 fb^{-1}$  est de 4,7 déviations standard environ, mais la incertitudes systématiques n'ont pas encore été prises en compte.

### 9.2.7 Incertitudes systématiques

Jusqu'ici, les incertitudes systématiques sur le signal et le bruit de fond n'ont pas encore été prises en compte. Afin de calculer au mieux la signification et les niveaux de confiance, il est nécessaire de les évaluer si possible à partir des données. Ceci peut être effectué pour le bruit de fond mais pas pour le

signal. Dans ce qui suit, nous travaillerons avec l'hypothèse d'une luminosité intégrée de  $1 \text{ fb}^{-1}$ . Nous essayerons de calculer les incertitudes systématiques pour plusieurs modèles, du plus simple où seule la masse invariante sans catégorie est utilisée, au plus élaboré où les distributions cinématiques ainsi que les catégories sont utilisées.

### Incertitudes sur le signal

Le signal  $H \rightarrow \gamma\gamma$  est prédit par la simulation : les incertitudes théoriques qui affectent sa section efficace et le spectre de ses observables sont avant tout théoriques. Jusqu'ici, seule la section efficace au NLO donnée par MC@NLO a été utilisée et aucun K-facteur n'a été pris en compte. Nous utiliserons les incertitudes théoriques NLO calculées de façon inclusive avec le programme HIGLU [137], avant d'utiliser la procédure de repondération. Nous avons considéré les incertitudes suivantes :

- Incertitude sur la luminosité intégrée mesurée avec  $1 \text{ fb}^{-1}$  :  $\pm 5\%$  (même hypothèse que pour les projections de l'analyse PTDR à 7 TeV).
- Incertitude théorique due à l'échelle d'énergie du processus au NLO pour la fusion de gluons (contribution principale) :  $\pm 18\%$ .
- Incertitude théorie due à l'ensemble de densité partoniques choisis :  $\pm 2\%$ .
- L'incertitude sur le filtre "bonne collision" peut être négligée puisque l'efficacité du filtre est de 0,3%.
- L'incertitude sur le déclenchement pourrait être négligée car après sélection, tous les photons passent la voie DoublePhoton10. Pour être conservatif nous l'évaluons à 1%.
- Incertitude sur la reconstruction des photons :  $\pm 1\%$  pour chaque photon.
- L'incertitude sur l'identification des photons par critères d'isolation a été évaluée en faisant varier chacun des critères *EcalIso*, *HcalIso*, *TrackIso* et *H/E* de  $\pm 5\%$ . La variation est la plus grande pour *TrackIso* (0,5%) et plus faible pour *EcalIso* ( $< 0.1\%$ ), *HcalIso* (0,1%) et *H/E* (0,1%). Nous choisissons pour être conservatif une incertitude totale de  $\pm 1\%$ .
- L'incertitude sur l'efficacité du critère de sélection sur la sortie du réseau de neurone a été évalué en faisant varier le critère de  $\pm 5\%$ . L'incertitude obtenue sur l'efficacité du signal est de  $\pm 6\%$  en moyenne et est asymétrique. Faire varier le critère vers le bas, où se situe la queue de la distribution, donne une différence relative d'efficacité plus faible que la variation par le haut où est concentrée la majorité du signal. Une façon plus rigoureuse d'estimer cette incertitude consisterait à utiliser les électrons du processus  $Z \rightarrow ee$  dans la simulation et les données.

Source	Incertitude systématique
Luminosité	5%
Echelle d'énergie $\mu$	18%
Densités partoniques	2%
Déclenchement	1%
Reconstruction des photons	2%
Isolation des photons	1%
Réseau de neurones	6%
Total	19.9%

FIG. 9.21 – Incertitudes systématiques sur le signal  $H \rightarrow \gamma\gamma$  pour une masse  $m_H = 120 \text{ GeV}$ .

Les différentes contributions aux incertitudes systématiques sur le boson de Higgs sont listées tableau 9.21. Au total, la somme quadratique des incertitudes relatives s'élève à 19,9%. On constate que l'incertitude sur le signal est principalement conduite par l'incertitude sur l'échelle d'énergie à laquelle est évaluée le processus.

**Incertitudes sur le bruit de fond**

La prédiction théorique du taux de bruit de fond est sujette à des incertitudes que nous ne détaillerons pas ici, puisqu’avec une luminosité intégrée de  $1 \text{ fb}^{-1}$  nous aurons la possibilité de mesurer le bruit de fond à partir des données. Dans CMS, cette mesure a en particulier été réalisée pour la distribution de masse invariante [88].

**Incertitudes sur les distributions de masse invariante**

La mesure du nombre d’évènements sous le pic de masse invariante du signal est effectuée à l’aide d’un ajustement à partir des bandes de côté. Plusieurs fonctions ont déjà été essayées [88] dans l’ajustement et il a été montré que l’ajustement le plus précis est effectué à l’aide d’une fonction exponentielle. Cette paramétrisation semble assez naturelle au vu de la décroissance du taux d’évènements avec la masse invariante. Il s’agit aussi de l’approche que nous avons adopté dans cette analyse. La procédure est la suivante : on considère la plage de masse invariante  $90 < M_{\gamma\gamma} < 200 \text{ GeV}$  à laquelle la fenêtre  $110 < M_{\gamma\gamma} < 130 \text{ GeV}$  où l’on cherche le boson de Higgs a été ôtée. L’ajustement est effectué avec une fonction exponentielle avec deux paramètres libres  $a$  et  $b$  :  $f(x) = e^{a+bx}$ . L’ajustement induit une incertitude statistique sur le nombre d’évènement dans la fenêtre, qui est donnée à partir du nombre d’évènements utilisés pour l’ajustement  $N_a$  par la formule  $1/\sqrt{N_a}$ . L’incertitude systématique due l’ajustement par les bandes de côté est évaluée par comparaison avec l’ajustement utilisant la plage complète de masse invariante  $90 < M_{\gamma\gamma} < 200 \text{ GeV}$  en incluant la fenêtre où est recherché le boson de Higgs. Les incertitudes sur les mesures du bruit de fond introduites par la procédure d’ajustement avec les bandes de côté pour  $1 \text{ fb}^{-1}$  sont exposées tableau 9.22. On montre le résultat des deux ajustements pour le cas sans catégorie figure 9.23.

Observable	Ajustement	Fenêtre	Total
$M_{\gamma\gamma}$	1.2%	1.2%	1.7%
$M_{\gamma\gamma}$ , cat0	3.7%	2.9%	4.7%
$M_{\gamma\gamma}$ , cat1	0.9%	2.4%	2.6%
$M_{\gamma\gamma}$ , cat2	0.9%	2.4%	2.6%
$M_{\gamma\gamma}$ , cat3	0.3%	2.3%	2.3%

FIG. 9.22 – Incertitudes systématiques liées à la procédure d’ajustement à partir des bandes de côté de la distribution de masse invariante pour  $1 \text{ fb}^{-1}$  après coupure sur la sortie du réseau de neurone de discrimination  $\gamma/\pi^0$ .




FIG. 9.23 – Résultat de l’ajustement avec et sans la fenêtre  $110 < m_H < 130 \text{ GeV}$  où est recherché un boson de Higgs de masse  $120 \text{ GeV}$ .

Les incertitudes dues au nombre d’évènements utilisés pour l’ajustement (en dehors de la fenêtre de masse) sont les plus faibles dans le cas sans catégories (1,2%), et diminuent à mesure que l’on choisit des

catégories ou le nombre d'évènements de bruit de fond augmente (de l'ordre de 2,5% en moyenne). Les incertitudes dues à l'ajustement à partir des bandes de côté, comparées à l'ajustement utilisant toute la plage de masse invariante sont de l'ordre de 1,2% sans catégorie et de 4% dans la catégorie avec le meilleur rapport signal sur bruit de fond, probablement à cause des fluctuations statistiques du bruit de fond.

La même procédure serait à répéter pour les autres masses nominales du boson de Higgs en faisant glisser la fenêtre de recherche. Il serait aussi possible de vérifier la paramétrisation avec un échantillon enrichi en bruit de fond dans les données, comme le fait l'expérience D0 [166] en inversant la coupure sur la sortie du réseau de neurone pour l'un des deux photons (l'échantillon est alors orthogonal avec celui utilisé pour la recherche du boson de Higgs).

**Incertitudes sur les autres variables cinématiques**

Les variables cinématiques  $q_T$  et  $\cos(\theta^*)$  que nous avons repéré comme discriminantes ne disposent pas du même régime de faveur que  $M_{\gamma\gamma}$ , parce que le signal ne présente pas de pic pour ces observables. Une première option consisterait à estimer les incertitudes systématiques sur les spectres de ces observables à partir des prédictions théoriques (échelle d'énergie et densités partoniques notamment) et en tenant compte des incertitudes expérimentales (luminosité, reconstruction et identifications des photons, etc). Une autre option serait d'utiliser ici aussi les bandes de côté de la distribution de masse invariante pour construire des distributions "templates" des variables cinématiques, tout comme on l'avait essayé pour la mesure du bruit de fond  $\gamma+X$  section 6.2.6 en utilisant les bandes de côté de l'énergie d'isolation trajectographique. On montre figure 9.24 (gauche) les distributions de  $q_T$  et  $\cos(\theta^*)$  prises dans la fenêtre de masse  $110 < M_{\gamma\gamma} < 130$  GeV et dans les bandes de côté.

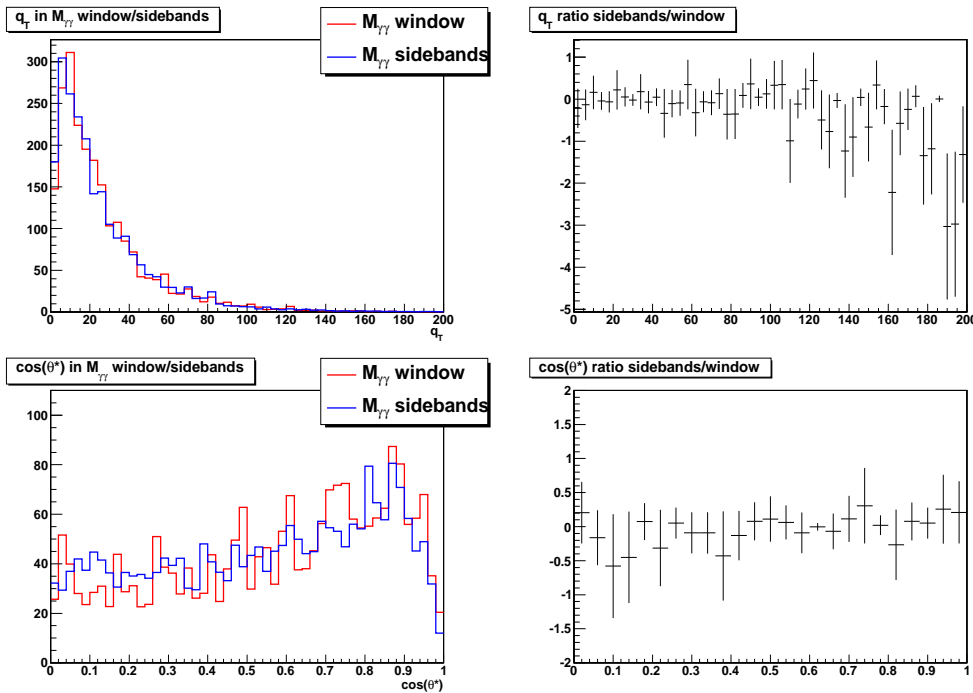


FIG. 9.24 – A gauche, distributions de  $q_T$  (en haut),  $\cos(\theta^*)$  (en bas) pour le bruit de fond, pris dans la fenêtre de masse  $110 < M_{\gamma\gamma} < 130$  GeV et hors de la fenêtre de masse normalisé au nombre d'évènements dans la fenêtre de masse. A droite, la différence relative des deux distributions.

Les formes des distributions cinématiques prises hors et dans la fenêtre de masse s'accordent relativement bien. Si nous voulons maintenant utiliser les distributions prises hors de la fenêtre pour calculer les niveaux de confiance, il nous faut quantifier l'incertitude systématique introduite par l'opération. La différence relative des distributions dans et hors de la fenêtre est montré figure 9.24 (droite) et est assez faible dans la plage  $0 < q_T < 100$  GeV (au-delà il semble que l'écart entre les distributions s'accroît -

tel-00598989, version 1 - 8 Jun 2011

de plus l'incertitude statistique rend difficile toute conclusion), sur toute la plage  $0 < \cos(\theta^*) < 1$ . La moyenne des différences relative entre les distributions dans et hors fenêtre de masse donnent l'incertitude systématique relative associée à l'utilisation des bandes de côté : 2,6% pour  $q_T$  entre 0 et 100 GeV ; 5,0% pour  $\cos(\theta^*)$ .

### Entraînement du réseau de neurones de discrimination $\gamma/\pi^0$ à partir des données

Afin de réduire les incertitudes liées au critère de sélection sur la sortie du réseau de neurone de discrimination  $\gamma/\pi^0$ , le réseau de neurone peut être entraîné à partir des données en utilisant encore une fois les bandes de côté de la distribution de masse invariante autour du pic attendu du boson de Higgs. Après identification des photons par les critères d'isolation, le bruit de fond comporte des diphotons issus des processus de QCD jets,  $\gamma$ +jets et  $\gamma\gamma$ +X. La difficulté consiste en ce que le bruit de fond n'est pas composé purement de jets mais aussi de photons prompts, qui contaminent l'échantillon de bruit de fond sélectionné dans les données avec des photons dont le comportement est proche de ceux issus du boson de Higgs. La perte de performance du réseau de neurone pourra être évaluée dans les données avec la luminosité intégrée de  $1 \text{ fb}^{-1}$  supposée dans cette analyse. Pour l'instant, la simulation ne nous permet pas de réaliser cette étude, en raison de la faible statistique des échantillons de QCD après identification des photons. Il serait toutefois possible de relâcher les critères d'isolation, ou bien d'utiliser la technique déjà étudiée section 6.3 pour l'entraînement du réseau de neurone utilisant la cinématique du processus  $\gamma$ +jet (pour des photons non isolés). Pour des photons isolés, on préférera entraîner le réseau de neurones à partir de la simulation et évaluer l'incertitude induite en comparant les distributions de sortie dans la simulation et les données pour le processus  $Z \rightarrow ee$ .

### 9.2.8 Résultats : signifiante et limites d'exclusion

Nous présentons dans cette section les résultats pour la recherche du boson de Higgs utilisant les rapports de vraisemblance multi-variables. Nous avons vu que les meilleurs résultats (sans incertitude systématique) étaient obtenus lorsque le rapport de vraisemblance est construit après application de la coupure sur la sortie du réseau de neurones. Pour tous les résultats présentés cette coupure sera donc appliquée. Nous comparerons l'utilisation des observables  $M_{\gamma\gamma}$  (aucune ou 4 catégories),  $q_T$  et  $\cos(\theta^*)$  avec et sans incertitudes systématiques pour deux figures de mérite : la signifiante pour une luminosité intégrée de  $10 \text{ fb}^{-1}$  et le rapport  $r = \sigma_{95CL}/\sigma_{SM}$  de la sections efficace nécessaires pour l'exclusion à 95% de niveau de confiance sur la section efficace du signal dans le modèle standard.

#### Niveaux de confiance

A partir du rapport de vraisemblance  $Q$ , il est possible de définir deux niveaux de confiance, pour l'hypothèse signal plus bruit de fond et pour l'hypothèse bruit de fond seul. Dans l'hypothèse signal plus bruit de fond, le niveau de confiance est défini par la probabilité qu'une expérience avec signal et bruit de fond donne un rapport de vraisemblance supérieur à la valeur observée :

$$CL_{s+b} = P_{s+b}(Q \leq Q_{obs}) = \int_0^{Q_{obs}} \frac{dP_{s+b}}{dQ} dQ$$

Où  $P_{s+b}$  est la densité de probabilité du test statistique  $Q$  pour une expérience avec signal et bruit de fond. De la même manière, on définit le niveau de confiance de l'hypothèse bruit de fond seul (ou hypothèse nulle) par l'expression suivante :

$$CL_b = P_b(Q \leq Q_{obs}) = \int_0^{Q_{obs}} \frac{dP_b}{dQ} dQ$$

Une recherche de particule se solde par une évidence si  $1 - CL_b < 2.7 \times 10^{-3}$  et par une découverte si  $1 - CL_b < 5.7 \times 10^{-7}$ . Ces valeurs correspondent à 3 et 5 déviations standards pour une distribution gaussienne de  $CL_b$ . La signifiante en terme de déviations gaussiennes peut être obtenue à partir de  $CL_b$  par la relation  $CL_b = \text{erf}(S/\sqrt{2})$ .

Les résultats que nous allons présenter ont été obtenus avec la méthode de fréquentiste modifiée [167, 168] implémentée dans la classe TLimit [169] de ROOT [28]. La méthode fréquentiste propose d'exclure la présence d'un signal dans les données en utilisant  $CL_{s+b}$  seul, tandis que la méthode fréquentiste modifiée propose d'utiliser la quantité normalisée  $CL_{s+b}/CL_b$  afin de se prémunir contre les fluctuations du bruit de fond. L'exclusion du signal avec 95% de niveau de confiance est réalisée lorsque  $CL_s = CL_{s+b}/CL_b < 0.05$ .

## Résultats

Les résultats obtenus pour une masse du boson de Higgs de 120 GeV sont résumés tableau 9.25 pour la significance dans l'hypothèse d'une luminosité intégrée de  $10 \text{ fb}^{-1}$  et tableau 9.26 pour le rapport des sections efficaces d'exclusion à 95% de niveau de confiance sur section efficace du boson de Higgs dans le modèle standard avec une luminosité de  $1 \text{ fb}^{-1}$ . Les quantités présentées ont été obtenues en générant  $10^5$  pseudo-expériences, une fois donnés les distributions du signal, du bruit de fond et de "fausses données". Les distributions sont divisées en segments de 1 GeV dans la plage  $110 < M_{\gamma\gamma} < 130$  GeV, de 4 GeV dans la gamme  $0 < q_T < 100$  GeV et de 0.04 dans la gamme  $0 < \cos(\theta^*) < 1$ . Les distributions du bruit de fond avec et sans catégories sont issues de la procédure de mesure du bruit de fond par les bandes de côté. Dans le cas de la masse invariante où les fluctuations statistiques étaient les plus grandes, les distributions de "fausses données" ont été obtenues par un ajustement du bruit de fond auquel a été ajouté la contribution du signal, tandis qu'aucun ajustement n'a été effectué pour les distributions de  $q_T$  et de  $\cos(\theta^*)$ .

Les valeurs données de la significance sont les résultats obtenus à partir du niveau de confiance  $CL_b$  observé dans les fausses données. Le rapport  $\sigma_{95CL}/\sigma_{SM}$  a été calculé en répétant les  $10^5$  pseudo-expériences en faisant à chaque fois varier la section efficace du signal  $H \rightarrow \gamma\gamma$ , jusqu'à trouver une valeur attendue du niveau de confiance  $CL_s < 0.05$ . L'inclusion des incertitudes systématiques est effectuée pour chaque canal en donnant la valeur moyenne de l'incertitude relative aux distributions du signal et du bruit de fond. Pour chaque pseudo-expérience, le nombre d'évènements du signal et bruit de fond est soumis à une fluctuation dans la limite des incertitudes systématiques.

Modèle	Significance $10 \text{ fb}^{-1}$	Significance $10 \text{ fb}^{-1}$
	sans syst	avec syst
$M_{\gamma\gamma}$	2.8	1.92
$M_{\gamma\gamma}$ 4 cat	3.41	2.36
$M_{\gamma\gamma}, q_T$	3.7	2.52
$M_{\gamma\gamma}$ 4 cat, $q_T$	3.98	3.09
$M_{\gamma\gamma}, q_T, \cos(\theta^*)$	3.98	2.92
$M_{\gamma\gamma}$ 4 cat, $q_T, \cos(\theta^*)$	3.29	2.60

FIG. 9.25 – Significance dans l'hypothèse d'une luminosité de  $10 \text{ fb}^{-1}$  avec et sans incertitudes systématiques, pour une masse du boson de Higgs de 120 GeV après coupure  $NN_{output_{min}} > 0.86$ .

La significance attendue (sans incertitudes systématiques) pour  $10 \text{ fb}^{-1}$  (voir tableau 9.25) est la plus faible pour  $M_{\gamma\gamma}$  seule et la plus grande pour quatre catégories de  $M_{\gamma\gamma}$  combinés avec  $q_T$  ou  $q_T$  et  $\cos(\theta^*)$ . Les significances sont du même ordre de grandeur - quoique légèrement plus faibles - que celles données tableau 9.20, où ni les  $10^5$  pseudo-expériences ni l'ajustement des distributions de  $M_{\gamma\gamma}$  n'avait été effectuées. La prise en compte des incertitudes systématiques fait baisser la significance d'environ 1 déviation standard pour  $M_{\gamma\gamma}$  avec ou sans catégorie, et  $M_{\gamma\gamma}$  sans catégories combiné avec  $q_T$ . La baisse est la moins grande si  $M_{\gamma\gamma}$  quatre catégories,  $q_T$  et  $\cos(\theta^*)$  sont combinés. Toutefois, le meilleur résultat avec incertitudes systématiques est obtenu pour le cas  $M_{\gamma\gamma}$  quatre catégories combiné avec  $q_T$ , cas pour le quel la significance est de 3,09 déviations standards. Il est à noter que dans le cas d'une recherche d'une résonance dans le spectre  $M_{\gamma\gamma}$  sans a priori sur le signal cherché, il n'y aurait pas eu besoin de tenir

compte de l'incertitude systématique sur le signal.

Modèle	$\sigma_{95CL}/\sigma_{SM} \text{ } 1fb^{-1}$ sans syst	$\sigma_{95CL}/\sigma_{SM} \text{ } 1fb^{-1}$ avec syst
$M_{\gamma\gamma}$	2.46	2.97
$M_{\gamma\gamma}$ 4 cat	2.02	2.19
$M_{\gamma\gamma}, q_T$	1.80	1.98
$M_{\gamma\gamma}$ 4 cat, $q_T$	1.60	1.66
$M_{\gamma\gamma}, q_T, \cos(\theta^*)$	1.60	1.71
$M_{\gamma\gamma}$ 4 cat, $q_T, \cos(\theta^*)$	1.46	1.51

FIG. 9.26 – Rapport des sections efficaces d'exclusion à 95% de niveau de confiance sur section efficace du boson de Higgs dans le modèle standard pour une luminosité de  $1 \text{ } fb^{-1}$ , avec et sans incertitudes systématiques, pour une masse du boson de Higgs de 120 GeV après coupure  $NN_{output_{min}} > 0.86$ .

Les rapports  $r_{95CL} = \sigma_{95CL}/\sigma_{SM}$  pour une luminosité de  $1 \text{ } fb^{-1}$  obtenues avec et sans incertitudes systématiques peuvent être lues tableau 9.26. La prise en compte des incertitudes systématiques semble moins affecter  $r_{95CL}$  que la signification à  $10 \text{ } fb^{-1}$ . La perte de sensibilité due aux incertitudes systématiques est la plus grande pour  $M_{\gamma\gamma}$  seul et la plus faible pour  $M_{\gamma\gamma}$  quatre catégories combinées avec  $q_T$  et  $\cos(\theta^*)$ . Dans le cas  $M_{\gamma\gamma}$  avec incertitudes systématiques, on atteint  $r_{95CL} \simeq 3$ , ce qui est plus performant que les projections de l'analyse PTDR à 7 TeV ( $r_{95CL} \simeq 4$ ), ce qui est du au rejet du bruit de fond opéré par la coupure sur la sortie du réseau de neurones. Le meilleur résultat est obtenu dans le cas  $M_{\gamma\gamma}$  quatre catégories combiné avec  $q_T$  et  $\cos(\theta^*)$ , où  $r_{95CL} \simeq 1.5$ .

### 9.2.9 Impact de la repondération sur les résultats obtenus

Jusqu'ici, aucun K-facteur n'a été utilisé. Nous aimerions maintenant appliquer la procédure de repondération élaborée chapitre 7 afin d'estimer leur impact sur la signification et les limites d'exclusion. Aucun K-facteur ne sera appliqué aux échantillons de QCD et aux échantillons  $\gamma$ +jets, ce qui justifie par le fait que Madgraph prend en compte des jets supplémentaires au niveau élément de matrice (il serait toutefois nécessaire de vérifier avec des générateurs NLO les sections efficaces). Pour les processus Born et Box, nous utilisons le K-facteur en deux dimensions  $K(q_T, M_{\gamma\gamma})$  qui a montré effectuer une repondération au NLO correcte pour toutes les distributions cinématiques diphotons que nous utilisons dans l'analyse dans la gamme de masse invariante où est recherché le boson de Higgs. Le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  est repondéré au NNLO avec le K-facteur en deux dimensions  $K(q_T, Y_{\gamma\gamma})$ . Un K-facteur inclusif est appliqué aux autres mécanismes de production du boson de Higgs, conformément aux sections efficaces [137] évaluées au NLO (voir tableau 9.27) pour la fusion de bosons vecteurs (VBF) et la production associée avec un boson vecteur (VH), et LO pour la production associée avec une paire de quarks top (ttH).

Processus	Ordre	Section efficace (fb)
VBF	NLO	2.90
ZH	NLO	0.76
WH	NLO	1.48
ttH	LO	0.50

FIG. 9.27 – Sections efficaces [137] pour les autres mécanismes de production que la fusion de gluon, pour un boson de Higgs de masse 120 GeV.

La masse invariante  $\gamma\gamma$  avant et après repondération est montrée figure 9.28. Le taux d'évènement diphoton est globalement multiplié par 1,14 tandis que le taux d'évènements total de bruit de fond est

multiplié par 1,1 et le taux d'évènements de signal est aussi multiplié par 1,14.




FIG. 9.28 – Distributions de masse invariante  $M_{\gamma\gamma}$  après coupure sur la sortie du réseau de neurone sans utilisation des catégories, pour une luminosité intégrée de  $1 \text{ fb}^{-1}$ , avant repondération (à gauche) et après repondération (à droite).

### Incertitudes systématiques du bruit de fond avec repondération

Les incertitudes systématiques pour la distribution  $M_{\gamma\gamma}$  du bruit de fond ont été ré-évaluées tableau 9.29. Dans la mesure où le nombre d'évènements de bruit de fond augmente par rapport au cas sans repondération, l'incertitude statistique du nombre d'évènements dans la fenêtre de masse invariante diminue légèrement. La repondération n'a pas d'effet notable sur l'incertitude systématique de l'ajustement en lui-même (qui peut être légèrement meilleur ou légèrement moins bon). L'incertitude systématique sur la distribution d'impulsion transverse  $q_T$  prise dans les bandes de côté a été ré-évaluée à 2,4% (au lieu de 2,6% sans repondération) dans la gamme  $q_T < 100 \text{ GeV}$  (nous avons vu auparavant que la repondération est valide jusqu'à  $q_T < 140 \text{ GeV}$ ). Pour  $\cos(\theta^*)$ , l'incertitude systématique est de 4,8% (au lieu de 5,0%), et pour  $Y^*$  de 10,4% (au lieu de 10,5%). Il semble donc que l'accord entre les distributions prises dans les bandes de côté ou la fenêtre de masse invariante soit le même avec le processus  $\gamma\gamma$ +X repondéré au NLO et au LO puisqu'ils donnent lieu à des incertitudes systématiques similaires.

Observable	Ajustement	Fenêtre	Total
$M_{\gamma\gamma}$	1.2%	1.2%	1.7%
$M_{\gamma\gamma}$ , cat0	3.3%	2.8%	4.3%
$M_{\gamma\gamma}$ , cat1	1.0%	2.3%	2.5%
$M_{\gamma\gamma}$ , cat2	0.8%	2.2%	2.4%
$M_{\gamma\gamma}$ , cat3	0.3%	2.1%	2.2%

FIG. 9.29 – Incertitudes systématiques liées à la procédure d'ajustement à partir des bandes de côté de la distribution de masse invariante pour  $1 \text{ fb}^{-1}$  après coupure sur la sortie du réseau de neurone de discrimination  $\gamma/\pi^0$  et après repondération.

### Incertitudes systématiques du signal avec repondération

La repondération du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  au NNLO par rapport à la section efficace NLO précédemment utilisée offre l'avantage de réduire les incertitudes théoriques dont le signal est affecté. Les incertitudes liées à la variation de l'échelle d'énergie se réduisent de 18% à 9%, tandis que les incertitudes liées à l'ensemble de densités partoniques augmentent de 2% à 3%. Nous négligeons les incertitudes



théoriques sur les autres mécanismes de production qui ont une section efficace environ dix fois moins importante. Nous n'avons pas réévalué les autres incertitudes systématiques pour le signal, qui ne devraient pas dépendre de ses propriétés cinématiques sur lesquelles la repondération a un impact. L'incertitude systématique totale sur le signal après repondération est de 12,5%.

### Significance et limites d'exclusion après repondération

La significance dans l'hypothèse d'une luminosité intégrée de  $10 \text{ fb}^{-1}$  ainsi que le rapport  $r_{95CL}$  ont été recalculés avec repondération et sont comparés au cas sans repondération tableau 9.30 et 9.31. Les incertitudes systématiques ont été prises en compte. D'une manière générale, la sensibilité de l'analyse au signal est améliorée, sauf dans le cas de la significance pour le cas  $M_{\gamma\gamma}$  seul (pour une raison inconnue que nous investiguons). On remarque que la significance obtenue est d'autant plus grande que le nombre de canaux pris en compte dans le rapport de vraisemblance est grand. Encore une fois, la significance est meilleure pour le cas  $M_{\gamma\gamma}$  dans quatre catégories que pour le cas  $M_{\gamma\gamma}, q_T, \cos(\theta^*)$  ou ce même cas avec quatre catégories. Ceci est dû aux distributions de fausses données, qui ont bénéficié d'un ajustement pour  $M_{\gamma\gamma}$ , et au fait que les incertitudes systématiques sont plus grandes pour  $q_T$  et  $\cos(\theta^*)$  que pour  $M_{\gamma\gamma}$ . Le gain dû à la repondération est d'environ une déviation standard pour les meilleurs résultats, ce qui provient du fait que le taux d'événements de signal et le bruit de fond est multiplié par environ 1,1, ce qui est équivalent à une élévation de la luminosité tandis que les incertitudes systématiques sur le signal et le bruit de fond sont plus faibles que sans repondération.

Modèle	Significance $10 \text{ fb}^{-1}$ sans repondération	Significance $10 \text{ fb}^{-1}$ avec repondération
$M_{\gamma\gamma}$	1.92	1.78
$M_{\gamma\gamma}$ 4 cat	2.36	2.56
$M_{\gamma\gamma}, q_T$	2.52	3.74
$M_{\gamma\gamma}$ 4 cat, $q_T$	3.09	4.42
$M_{\gamma\gamma}, q_T, \cos(\theta^*)$	2.92	3.9
$M_{\gamma\gamma}$ 4 cat, $q_T, \cos(\theta^*)$	2.60	3.7

FIG. 9.30 – Significance dans l'hypothèse d'une luminosité de  $10 \text{ fb}^{-1}$  avec et sans repondération, pour une masse du boson de Higgs de 120 GeV après coupure  $NN_{output_{min}} > 0.86$ . Les incertitudes systématiques ont été prises en compte.

Le rapport des sections efficaces d'exclusion à 95% de niveau de confiance sur la section efficace du modèle standard  $r_{95CL}$  est systématiquement meilleur (plus faible) après repondération qu'avant. Le gain moyen sur  $r_{95CL}$  quel que soit le canal est d'environ 0,2. Le choix d'observables conduisant à l'exclusion la plus forte dans l'hypothèse d'un bruit de fond seul reste la combinaison de quatre catégories de  $M_{\gamma\gamma}, q_T, \cos(\theta^*)$ , pour lequel  $r_{95CL} \simeq 1.34$  est obtenu.

## 9.3 Conclusions et perspectives

Dans ce chapitre a été présenté une analyse complète pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  à partir de la simulation, dans l'hypothèse d'une luminosité intégrée de  $1 \text{ fb}^{-1}$  et une énergie dans le centre de masse de 7 TeV. Le réseau de neurone de discrimination  $\gamma/\pi^0$  est intégré dans l'analyse et permet l'amélioration de la sensibilité de l'analyse au signal. Une repondération à l'aide de K-facteurs bi-dimensionnels  $K(q_T, Y_{\gamma\gamma})$  pour le signal et  $K(q_T, M_{\gamma\gamma})$  pour le bruit de fond a été effectuée. Les incertitudes systématiques ont été prises en compte pour le signal et pour le bruit de fond. Le bruit de fond a été mesuré à partir des bandes de côté de la distribution de masse invariante  $M_{\gamma\gamma}$ , pour la fenêtre de masse invariante elle-même et ce qui n'avait jamais été présenté dans CMS, pour les distributions d'impulsion transverse diphoton  $q_T$  et pour la distribution angulaire  $\cos(\theta^*)$ . Le test statistique utilisé est

Modèle	$\sigma_{95CL}/\sigma_{SM} 1fb^{-1}$ sans repondération	$\sigma_{95CL}/\sigma_{SM} 1fb^{-1}$ avec repondération
$M_{\gamma\gamma}$	2.97	2.63
$M_{\gamma\gamma}$ 4 cat	2.19	1.98
$M_{\gamma\gamma}, q_T$	1.98	1.73
$M_{\gamma\gamma}$ 4 cat, $q_T$	1.66	1.48
$M_{\gamma\gamma}, q_T, \cos(\theta^*)$	1.71	1.5
$M_{\gamma\gamma}$ 4 cat, $q_T, \cos(\theta^*)$	1.51	1.34

FIG. 9.31 – Rapport des sections efficaces d'exclusion à 95% de niveau de confiance sur section efficace du boson de Higgs dans le modèle standard pour une luminosité de  $1 fb^{-1}$ , avec et sans incertitudes systématiques, pour une masse du boson de Higgs de 120 GeV après coupure  $NN_{output_{min}} > 0.86$ . Les incertitudes systématiques ont été prises en compte.

un rapport de vraisemblance multi-variables. Plusieurs combinaisons de canaux ont été essayés parmi les suivantes :  $M_{\gamma\gamma}$  avec ou sans répartition en quatre catégories (en  $\eta$  et  $R9$ ),  $q_T$ , et  $\cos(\theta^*)$ . Les résultats obtenus ont été présentés sous la forme de deux figures de mérite : la signification pour une luminosité intégrée de  $10 fb^{-1}$  et le rapport de la section efficace d'exclusion du signal à 95% de niveau de confiance divisé par la section efficace  $H \rightarrow \gamma\gamma$  dans le modèle standard  $r_{95CL}$  pour une luminosité de  $1 fb^{-1}$  pour un boson de Higgs de masse 120 GeV. Les résultats sont meilleurs que ceux présentés pour les projections du PTDR à 7 TeV et  $1 fb^{-1}$  ( $r_{95CL} \simeq 4$ ). L'usage de la masse invariante seule avec coupure sur la sortie du réseau de neurone conduit à  $r_{95CL} \simeq 3$  (sans K-facteurs). Le pouvoir discriminant de l'analyse (sans K-facteurs) est encore accru si quatre catégories sont prises en compte pour  $M_{\gamma\gamma}$  et si  $q_T$  et  $\cos(\theta^*)$  sont aussi utilisés :  $r_{95CL} \simeq 1.5$ . Une fois la repondération du signal et du bruit de fond effectuée, la limite devient  $r_{95CL} \simeq 1.34$ , en raison de l'augmentation du taux d'évènements attendus au NLO pour le bruit de fond et au NNLO (pour la fusion de gluon) pour le signal, tandis que les incertitudes systématiques globales sur le signal sont réduites de 20% à 12,5%.

Les résultats ont pour l'instant été présentés seulement pour une masse du boson de Higgs  $m_H = 120$  GeV. L'étude devrait être répétée et réoptimisée pour les autres masses nominales du boson de Higgs. Nous avons aussi utilisé des critères d'identification des photons recommandés dans CMS, plutôt conçus pour l'identification des photons des processus  $\gamma+X$ . Ces critères d'isolation mériteraient d'être réévalués pour la recherche du boson de Higgs, dont les photons sont légèrement plus isolés que les photons de  $\gamma+X$  et  $\gamma\gamma+X$  (qui comprennent des ISR/FSR). Il serait aussi possible d'optimiser la coupure en  $p_T$  des photons pour améliorer la signification.

Les échantillons de QCD utilisés pour cette analyse souffrent d'un manque de statistique une fois appliqués les critères d'identification des photons. Pour cette raison, nous n'avons pas pu effectuer l'entraînement du réseau de neurone à partir des bandes de côté de  $M_{\gamma\gamma}$  (comme nous le ferions dans les données). Une solution à ce problème serait de générer plusieurs dizaine de millions d'évènement de QCD par simulation rapide (qui rendent compte des principaux effets de détection), ce qui aiderait aussi à rendre l'analyse plus robuste. Pour l'instant, nous n'avons pas tenu compte du processus  $Z \rightarrow ee$ , ce qui serait particulièrement important à réaliser en particulier pour la mesure du bruit de fond par les bandes de côté. Les électrons issus du boson  $Z$  sont aussi reconstruits comme des photons et dans l'absence d'un procédé pour éliminer ces évènements le pic du  $Z$  est une contribution non négligeable au bruit de fond. Il est possible de s'affranchir de ces évènements en demandant que les photons reconstruits n'aient pas laissés de coup dans le détecteur à pixel. Enfin, lorsque nous mesurons le bruit de fond par les bandes de côté, une vérification supplémentaire (dans l'absence d'un pic clair du boson de Higgs comme ce sera le cas avec  $1 fb^{-1}$ ) consisterait à mesurer sa composition en fonction des processus QCD dijet,  $\gamma$ +jets,  $\gamma\gamma$ +jets et éventuellement  $Z \rightarrow ee$ , par la méthode des templates que nous avons proposé chapitre 8. Ceci permettrait d'obtenir les véritables K-facteurs (en particulier pour les processus de QCD jets et  $\gamma$ +jets) à affecter aux bruits de fond pour l'estimation correcte des niveaux de confiance attendus, si l'on veut

pour vérification effectuer l'analyse en faisant confiance à la simulation sans la mesure du bruit de fond par les bandes de côté.

Pour le calcul de la signification et des niveaux de confiance, il serait possible d'améliorer la prise en compte des incertitudes systématiques. Nous avons en effet, selon la prescription [168], affecté seulement une erreur systématiques globale à chaque distribution utilisée dans le calcul du rapport de vraisemblance. Ceci peut être considéré comme une relativement bonne approximation pour la distribution de masse invariante du bruit de fond du fait de notre bonne connaissance de cette observable ajustable l'aide d'une distribution exponentielle. En revanche pour  $q_T$  et surtout  $\cos(\theta^*)$ , nous n'avons effectué aucun ajustement, et la forme de ces distributions prises dans les bandes de côté ou dans la fenêtre de masse invariante semble être légèrement différente (en particulier à bas  $q_T$  et bas  $\cos(\theta^*)$ ). Nous avons dans cette analyse fait l'hypothèse que la différence provenait de fluctuations statistiques, mais il resterait à le vérifier avec des générateurs NLO pour les processus QCD jets,  $\gamma$ +jets et  $\gamma\gamma$ +jets. En présence d'une incertitude systématique variant avec la plage de  $q_T$  ou  $\cos(\theta^*)$ , il faudrait en tenir compte dans le calcul du rapport de vraisemblance.

Le test statistique pourrait être raffiné par les deux techniques suivantes. Pour les distributions de "fausses données", nous avons seulement utilisé les prédictions de la simulation telles quelles. Il serait possible de générer (par exemple) 1000 pseudo-expériences conformément aux distributions simulées pour obtenir une distribution moyenne de données, ce qui affecterait les résultats pour la signification observée dans les fausses données. De même, ces pseudo-expériences pourraient être utilisées pour calculer 1000 valeurs de  $r_{95CL}$  et donc d'obtenir la densité de probabilité de  $r_{95CL}$ . Ceci permettrait d'obtenir la valeur moyenne attendue de  $r_{95CL}$  ainsi que les bandes à  $1\sigma$  et  $2\sigma$  utilisées couramment pour montrer les résultats.

Enfin, il faut mentionner que cette analyse s'inspire d'une analyse similaire dans CMS qui utilise un ajustement des distributions cinématiques pour construire les densités de probabilités des observables, qui sont incluses telles quelles dans un rapport de vraisemblance multi-variables utilisant les événements et non des histogrammes. Le réseau de neurone de discrimination  $\gamma/\pi^0$  que nous avons développé est en cours d'intégration dans cette analyse.



## Chapitre 10

# Recherche du boson de Higgs dans le canal $H \rightarrow \gamma\gamma$ au-delà du modèle standard

Si le boson de Higgs existe et qu'il est découvert au LHC, ses propriétés peuvent être conformes à celles prédites par le modèle standard ou non. De nombreux modèles au-delà du modèle standard prédisent l'existence d'un boson de Higgs comme un champ scalaire neutre avec des couplages proches de ceux du modèle standard (modèles "little Higgs", quatrième génération de fermions, supersymétrie, dimensions supplémentaires par exemple, voir section 2.1.3). Dans le cas où certaines observables du boson de Higgs auraient des valeurs différentes de celles attendues dans le modèle standard, cela pourrait donner une indication concernant le modèle décrivant la physique au-delà du modèle standard qui serait complémentaire à la recherche directe des éventuelles particules de cette nouvelle physique. Cette approche est mise en oeuvre dans la publication [93] pour un boson de Higgs léger,  $115 < m_H < 150$  GeV, se désintégrant en une paire de photons. Une nouvelle paramétrisation relevant de modèles effectifs y est proposée. Le boson de Higgs ne couplant pas directement aux gluons et aux photons, le mécanisme de production du boson de Higgs par fusion de gluon (prépondérant au LHC) et sa désintégration en paire de photons impliquent chacun une boucle de particules virtuelles. Dans la mesure où les particules de nouvelle physique couplant fortement au boson de Higgs interviennent dans ces boucles, la section efficace de production du boson de Higgs et sa largeur de désintégration vont être modifiées. L'écart par rapport au modèle standard peut être quantifié. Selon la position du boson de Higgs dans la région de l'espace de phase  $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$  (paramètres définis section 2.2.3) mesurée dans les données, certains modèles pourront être exclus ou favorisés.

Le but de ce chapitre est d'établir par la simulation quels modèles peuvent être éliminés dès  $1 \text{ fb}^{-1}$  de luminosité intégrée avec 7 TeV d'énergie dans le centre de masse, soit environ un an et demi de fonctionnement du LHC à 7 TeV. Dans la mesure où la luminosité nécessaire pour une découverte d'un boson de Higgs léger est plutôt de l'ordre de 7 à  $10 \text{ fb}^{-1}$ , nous nous intéresserons plutôt aux limites d'exclusion pouvant être posées avec la luminosité intégrée attendue. Dans un premier temps, nous décrirons le moyen par lequel la paramétrisation du modèle effectif [93], qui réécrit les couplages du boson de Higgs aux gluons et aux photons en terme des paramètres  $\kappa_{\gamma\gamma}$  et  $\kappa_{gg}$  qui dépendent de la nouvelle physique, peut être mise en oeuvre avec le générateur Madgraph [23]. Nous effectuerons un balayage du plan  $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$ , afin d'obtenir le rapport des sections efficaces au-delà du modèle standard sur celles du modèle standard en fonction de  $\kappa_{\gamma\gamma}$  et  $\kappa_{gg}$ . Ce résultat pourra alors être directement comparé avec le rapport des sections efficaces d'exclusion à 95% de niveau de confiance sur les sections efficaces du modèle standard pour les deux analyses suivantes : projection conservative à 7 TeV et l'analyse que nous avons présentée chapitre 9 utilisant un rapport de vraisemblance multi-variables.

### 10.1 Paramétrisation de la théorie effective dans Madgraph

La théorie effective du boson de Higgs (ou "HEFT", Higgs Effective Field Theory) de Madgraph permet l'implémentation de la paramétrisation  $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$  au-delà du modèle standard. Nous décrirons cette théorie avant de montrer comment effectuer la mise en oeuvre de la paramétrisation dans Madgraph.

### 10.1.1 Théorie effective du boson de Higgs (HEFT) dans Madgraph

Le générateur Madgraph est spécialisé dans le calcul automatisé de diagrammes avec émission réelle de QCD et ne contient pas de routine pour calculer explicitement les diagrammes à boucles. Pour générer le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ , Madgraph fait appel à une théorie effective. La théorie effective du boson de Higgs dans Madgraph [170] est un modèle où le boson de Higgs se couple non via une boucle de particules virtuelles (principalement quark top) mais directement aux gluons et aux photons [171, 172, 173]. Ce modèle est réalisé lorsque la masse du quark top  $m_t$  dans la boucle est prise égale à l'infini. Il s'agit d'une bonne approximation dans la limite d'un boson de Higgs léger, pour lequel  $m_H < m_t$ .

### 10.1.2 Implémentation de la paramétrisation $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$

Le modèle HEFT de Madgraph peut être utilisé pour implémenter facilement la paramétrisation  $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$ . Le code source Madgraph correspondant à la génération du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  dans le modèle HEFT a été obtenu via l'interface web de Madgraph [174]. La carte contenant les informations du processus (proc\_card.dat, voir figure 10.1) n'a pas été modifiée.

pp > h > aa
QCD=99
QED=99
HIG=1
HIW=1

FIG. 10.1 – Paramètres du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  dans le modèle HEFT, tel qu'il est implémenté dans Madgraph (fichier proc\_card.dat).

Afin d'implémenter la paramétrisation  $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$ , le fichier qui contient les informations sur le calcul des couplages du bosons de Higgs (couplings.f) doit être modifié de la façon suivante. Madgraph calcule les couplages du boson de Higgs aux photons et aux gluons dans la limite d'une masse du *top* et du *W* très grandes devant la masse du boson de Higgs, en effectuant un développement limité des expressions  $A_{1/2}^H(\tau_t)$  (pour le fermion *top*) et  $A_1^H(\tau_W)$  (pour le boson *W*) décrites section 2.2.3), où  $\tau_t = \frac{m_H}{4m_t}$  et  $\tau_W = \frac{m_H}{4m_W}$ . La série *series\_t* utilisée pour le couplage aux gluons fait seulement intervenir  $A_{1/2}^H(\tau_t)$  et s'écrit :

$$series\_t = 1 + \frac{7}{30}\tau_t + \frac{2}{21}\tau_t^2 + \frac{26}{525}\tau_t^3$$

Tandis que la série *series\_a* utilisée pour le couplage aux photons fait intervenir en  $A_{1/2}^H(\tau_t)$  et  $A_1^H(\tau_W)$  et s'écrit :

$$\begin{aligned} series\_a &= 1 + \frac{66}{235}\tau_W + \frac{228}{1645}\tau_W^2 + \frac{696}{8225}\tau_W^3 + \frac{5248}{90475}\tau_W^4 + \frac{1280}{29939}\tau_W^5 + \frac{54528}{1646645}\tau_W^6 \\ &\quad - \frac{56}{705}\tau_t - \frac{32}{987}\tau_t^2 \\ &= \left(1 + \frac{336}{987}\right) + \frac{66}{235}\tau_W + \frac{228}{1645}\tau_W^2 + \frac{696}{8225}\tau_W^3 + \frac{5248}{90475}\tau_W^4 + \frac{1280}{29939}\tau_W^5 + \frac{54528}{1646645}\tau_W^6 \\ &\quad - \frac{336}{987}\left(1 + \frac{7}{30}\tau_t + \frac{2}{21}\tau_t^2\right) \end{aligned}$$

Dans cette dernière équation, le terme unité a été réécrit pour apparaître dans la série en  $\tau_W$  et dans la série en  $\tau_t$ . Ceci est nécessaire car le paramètre  $\kappa_{gg}$  apparaît par définition comme facteur multiplicatif de la série  $A_{1/2}^H(\tau_t)$  pour le couplage aux gluons, et  $\kappa_{\gamma\gamma}$  apparaît comme facteur multiplicatif de  $A_{1/2}^H(\tau_t)$  seulement (pas pour  $A_1^H(\tau_W)$ ) pour le couplage aux photons. On remarque que pour le couplage aux photons,  $A_{1/2}^H(\tau_t)$  est développé à l'ordre 2 tandis que pour le couplage aux gluons ce terme est développé à l'ordre 3.  $A_1^H(\tau_W)$  est développé à l'ordre 6 (en raison d'une convergence plus lente de la série, du fait que  $\tau_W$  est plus proche de 1 que  $\tau_t$ ).

La paramétrisation  $\kappa_{\gamma\gamma}-\kappa_{gg}$  dans Madgraph peut donc être écrite :

$$\begin{aligned} series\_t &= \left(1 + \frac{7}{30}\tau_t + \frac{2}{21}\tau_t^2 + \frac{26}{525}\tau_t^3\right) \times (1 + \kappa_{gg}) \\ series\_a &= \left(1 + \frac{336}{987}\right) + \frac{66}{235}\tau_W + \frac{228}{1645}\tau_W^2 + \frac{696}{8225}\tau_W^3 + \frac{5248}{90475}\tau_W^4 + \frac{1280}{29939}\tau_W^5 + \frac{54528}{1646645}\tau_W^6 \\ &\quad - \frac{336}{987}\left(1 + \frac{7}{30}\tau_t + \frac{2}{21}\tau_t^2\right) \times (1 + \kappa_{\gamma\gamma}) \end{aligned}$$

Pour comparaison, l'approche [93] négligeait tous les termes en puissance de  $\tau_W$  et  $\tau_t$  (développement limité à l'ordre 0) afin de simplifier les calculs. La prise en compte de ces termes devrait améliorer le pouvoir prédictif du modèle. L'intérêt d'utiliser un générateur Monte-Carlo comme Madgraph est aussi de pouvoir disposer d'évènements plutôt que de calculer les sections efficaces de manière analytique.

## 10.2 Sections efficaces du boson de Higgs dans le plan $\kappa_{\gamma\gamma}-\kappa_{gg}$

Dans cette section, nous mettons en oeuvre la paramétrisation  $\kappa_{\gamma\gamma}-\kappa_{gg}$  avec Madgraph. Dans un premier temps, nous allons effectuer un balayage de l'espace de phase  $\kappa_{\gamma\gamma}-\kappa_{gg}$  pour obtenir les sections efficaces du processus  $gg \rightarrow H \rightarrow \gamma\gamma$ . Ensuite, nous déduirons les sections efficaces inclusives du processus  $H \rightarrow \gamma\gamma$ .

### 10.2.1 Rapport des sections efficaces $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}/\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$ dans le plan $\kappa_{\gamma\gamma}-\kappa_{gg}$

Afin d'obtenir un panorama global de l'évolution du rapport des sections efficaces non-standard/standard (BSM/SM), le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$  est scanné dans les plages  $-0.7 < \kappa_{gg} < 2$  et  $-0.7 < \kappa_{\gamma\gamma} < 2$  avec un pas de 0,1. Le plan est pavé avec 784 points correspondant aux valeurs du rapport des sections efficaces  $\sigma_{BSM}/\sigma_{SM}$ . 100000 évènements ont été générés pour chaque section efficace. Le résultat obtenu peut être lu figure 10.2. Seuls les rapports des sections efficaces  $gg \rightarrow H \rightarrow \gamma\gamma$  y sont représentées. La figure de gauche a été obtenue à l'aide de la formule suivante [93] :

$$\frac{\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}}{\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}} = \frac{\sigma_{gg \rightarrow H}^{BSM}}{\sigma_{gg \rightarrow H}^{SM}} \frac{BR(H \rightarrow \gamma\gamma)^{BSM}}{BR(H \rightarrow \gamma\gamma)^{SM}} \simeq (1 + \kappa_{gg})^2 \times \frac{BR(H \rightarrow \gamma\gamma)^{BSM}}{BR(H \rightarrow \gamma\gamma)^{SM}}$$

Les rapport BSM/SM des rapports de branchements s'écrit :

$$\begin{aligned} \frac{BR(H \rightarrow \gamma\gamma)^{BSM}}{BR(H \rightarrow \gamma\gamma)^{SM}} &= \frac{\Gamma_{H \rightarrow \gamma\gamma}^{BSM}}{\Gamma_{tot}^{BSM}} \times \frac{\Gamma_{tot}^{SM}}{\Gamma_{H \rightarrow \gamma\gamma}^{SM}} = \frac{\Gamma_{H \rightarrow \gamma\gamma}^{BSM}}{\Gamma_{H \rightarrow \gamma\gamma}^{SM}} \times \frac{\Gamma_{tot}^{SM}}{\Gamma_{H \rightarrow gg}^{BSM} + \Gamma_{H \rightarrow \gamma\gamma}^{BSM} + \Gamma_{autres}^{BSM}} \\ &\simeq \left(1 + \frac{\kappa_{\gamma\gamma}}{\frac{9}{16}A_1(\tau_W) + 1}\right)^2 \times \frac{\Gamma_{tot}^{SM}}{(1 + \kappa_{gg})^2 \Gamma_{H \rightarrow gg}^{SM} + (\Gamma_{tot}^{SM} - \Gamma_{H \rightarrow gg}^{SM})} \end{aligned}$$

On voit donc que le rapport des sections efficaces  $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}/\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$  dépend seulement des paramètres  $\kappa_{\gamma\gamma}$ ,  $\kappa_{gg}$ , de  $\tau_W$  et des largeurs de désintégration. À partir de la formule précédente, l'expression exacte de  $A_1(\tau_W)$  a été utilisée pour obtenir le graphique 10.2 gauche.

Le graphe du rapport des sections efficaces  $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}/\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$  dans le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$  a la même allure pour l'expression mathématique approchée et pour le calcul par éléments de matrices de Madgraph. Les courbes de niveaux suivent la même tendance. Notons deux principales différences :

- La dépendance de  $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}/\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$  en fonction de  $\kappa_{\gamma\gamma}$  est plus faible avec Madgraph qu'avec la formule approchée.
- La dépendance de  $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}/\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$  en fonction de  $\kappa_{gg}$  est environ deux fois plus forte avec Madgraph qu'avec la formule approchée.




FIG. 10.2 – Rapport des sections efficaces au-delà du modèle standard sur les sections efficaces du modèle standard pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  seulement ( $m_H = 120$  GeV), avec une énergie dans le centre de masse de 7 TeV. A gauche, obtenu avec la formule approchée (auteur : Jérémie Llodra-Perez) et à droite avec Madgraph.

### 10.2.2 Prise en compte des autres mécanismes de production

Jusqu'ici, nous avons seulement considéré le mécanisme de production du boson de Higgs par fusion de gluon. Ce mécanisme est implémenté dans le modèle HEFT de Madgraph. Nous avons essayé de construire les cartes Madgraph correspondant à la production du boson de Higgs par fusion de boson vecteurs et pour les mécanismes de production associée, mais nous n'avons pas trouvé qu'il était possible de le réaliser avec Madgraph si on voulait aussi forcer la désintégration du boson de Higgs en deux photons avec le modèle HEFT. Afin de prendre toute de même en compte les autres mécanismes de production, nous proposons d'utiliser Madgraph pour le calcul des sections efficaces du processus  $gg \rightarrow H \rightarrow \gamma\gamma$  comme précédemment, et d'utiliser le calcul approché pour tout ce qui concerne les autres mécanismes de productions. Pour ces autres mécanismes de production suivis de la désintégration du boson de Higgs en deux photons, nous utiliserons les sections efficaces données par Pythia.

Quelques reformulations mathématiques sont nécessaires avant de parvenir au résultat du rapport des sections efficaces  $\sigma_{H \rightarrow \gamma\gamma}^{BSM}/\sigma_{H \rightarrow \gamma\gamma}^{SM}$  dans le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$  présenté figure 10.3. Ce rapport s'écrit :

$$\frac{\sigma_{H \rightarrow \gamma\gamma}^{BSM}}{\sigma_{H \rightarrow \gamma\gamma}^{SM}} = \left( \frac{\sigma_{gg \rightarrow H}^{BSM} + \sigma_{VBF}^{SM} + \sigma_{VH, t\bar{t}H}^{SM}}{\sigma_{gg \rightarrow H}^{SM} + \sigma_{VBF}^{SM} + \sigma_{VH, t\bar{t}H}^{SM}} \right) \frac{BR(H \rightarrow \gamma\gamma)^{BSM}}{BR(H \rightarrow \gamma\gamma)^{SM}}$$

On divise cette expression en deux parties, la première dépendant des sections efficaces pour la fusion de gluon calculées avec Madgraph et la deuxième dépendant du calcul approché des rapports de branchements avec la paramétrisation  $\kappa_{\gamma\gamma}-\kappa_{gg}$  que nous avons développé à la section 10.2.1 :

$$\frac{\sigma_{H \rightarrow \gamma\gamma}^{BSM}}{\sigma_{H \rightarrow \gamma\gamma}^{SM}} = \frac{\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}}{\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM} + \sigma_{VBF, H \rightarrow \gamma\gamma}^{BSM} + \sigma_{VH, t\bar{t}H, H \rightarrow \gamma\gamma}^{SM}} + \frac{\sigma_{VBF}^{SM} + \sigma_{VH, t\bar{t}H}^{SM}}{\sigma_{gg \rightarrow H}^{SM} + \sigma_{VBF}^{SM} + \sigma_{VH, t\bar{t}H}^{SM}} \times \frac{BR(H \rightarrow \gamma\gamma)^{BSM}}{BR(H \rightarrow \gamma\gamma)^{SM}}$$

On voit qu'une fois connues les sections efficaces de production du boson de Higgs par fusion de boson vecteurs et par production associée ainsi que les rapports de branchements du boson de Higgs en deux photons dans le modèle standard, il est possible de calculer  $\sigma_{H \rightarrow \gamma\gamma}^{BSM}/\sigma_{H \rightarrow \gamma\gamma}^{SM}$ . Ces grandeurs nous sont données par Pythia pour les sections efficaces (désintégration incluses) et par HDECAY pour les rapports de



branchements (voir tableau 10.4). Toutes grandeurs utilisées sont calculées au LO, pour être consistant avec le calcul effectué avec Madgraph.




FIG. 10.3 – Rapport des sections efficaces au-delà du modèle standard sur les sections efficaces du modèle standard pour le processus  $H \rightarrow \gamma\gamma$  inclusif ( $m_H = 120$  GeV), avec une énergie dans le centre de masse de 7 TeV. A gauche, obtenu avec la formule approchée (auteur : Jérémie Llodra-Perez) et à droite avec Madgraph pour  $gg \rightarrow H \rightarrow \gamma\gamma$  et avec la formule approchée pour les autres mécanismes de production.

Paramètre	Valeur
Largeur totale $\Gamma_H$	0.003588 GeV
$BR(H \rightarrow \gamma\gamma)$	0.002219
$BR(H \rightarrow gg)$	0.07103
$\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$ (Madgraph)	23.07 fb
$\sigma_{VBF,H \rightarrow \gamma\gamma}^{SM}$ (Pythia)	3.45 fb
$\sigma_{VH,t\bar{t}H,H \rightarrow \gamma\gamma}^{SM}$ (Pythia)	2.44 fb

FIG. 10.4 – Paramètres utilisés pour le calcul de  $\sigma_{H \rightarrow \gamma\gamma}^{BSM} / \sigma_{H \rightarrow \gamma\gamma}^{SM}$  ( $m_H = 120$  GeV).

La pente en fonction de  $\kappa_{\gamma\gamma}$  est plus forte pour les sections efficaces inclusives figure 10.3 que pour les sections efficaces de production de gluon seule figure 10.2. En revanche, la pente en fonction de  $\kappa_{gg}$  est moins forte dans le cas inclusif que pour la production de gluon seule. Ceci s'explique par le fait que les autres mécanismes ne sont liés à  $\kappa_{gg}$  que par le biais du rapport de branchement en deux photons  $BR(H \rightarrow \gamma\gamma)^{BSM} / BR(H \rightarrow \gamma\gamma)^{SM}$ , de sorte que la variation de  $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM}$  avec  $\kappa_{gg}$  se trouve réduite. D'autre part, la désintégration du boson de Higgs en deux photons au-delà du modèle standard pour les autres mécanismes de productions induit une dépendance accrue en fonction de  $\kappa_{\gamma\gamma}$ .

### 10.3 Interprétations pour la recherche du boson de Higgs avec 7 TeV et $1 fb^{-1}$

Le but de cette section est d'évaluer la sensibilité des analyses de recherche du boson de Higgs dans CMS aux modèles non standards pouvant être décrits par la paramétrisation  $\kappa_{\gamma\gamma}$ - $\kappa_{gg}$ , que nous avons mis

en oeuvre avec Madgraph. Pour le moment, nous reporterons sur le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$  les limites d'exclusions à 7 TeV et  $1 fb^{-1}$  de deux analyses : celles obtenues avec les projections du PTDR à 7 TeV et celles obtenues au chapitre 9.

### 10.3.1 Projection de l'analyse du PTDR à 7 TeV

L'analyse de recherche inclusive du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  du PTDR projetée de 14 TeV à 7 TeV a été décrite section 9.1. Les projections de l'analyse TDR à 7 TeV demandent que les photons aient une impulsion transverse  $p_{T,1} > 40$  GeV et  $p_{T,2} > 35$  GeV. Dans Madgraph, nous demandons seulement  $p_T > 35$  GeV pour les deux photons car il n'est pas possible d'appliquer une coupure asymétrique. Le seuil a été varié de  $p_T > 35$  GeV jusqu'à  $p_T > 10$  GeV et les résultats pour le rapport des section efficace  $\sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{BSM} / \sigma_{gg \rightarrow H \rightarrow \gamma\gamma}^{SM}$  sont indépendants de l'impulsion des photons dans la limite des incertitudes statistiques, comme attendu (dans ce modèle, seule la section efficace change, pas la cinématique).

Avec 7 TeV et  $1 fb^{-1}$  de luminosité intégrée, aucune limite d'exclusion à 95% de niveau de confiance sur l'existence du boson de Higgs standard ne peut être posée dans la plage  $115 < m_H < 140$  GeV dans le canal  $H \rightarrow \gamma\gamma$ . Pour être exclu avec cette analyse, la section efficace d'un boson de Higgs de masse 120 GeV devrait être environ quatre fois plus grande celle du modèle standard. Il n'existe pas de modèle connu et "naturel" (bien qu'il soit toujours possible d'en construire un) prédisant une telle section efficace, mais il est intéressant de reporter cette limite dans le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$  figure 10.3 pour voir jusqu'à quel point la sensibilité de CMS se rapproche de modèles connus non standards. Avec cette analyse, il n'est pas encore possible d'exclure un des modèles "naturels" favoris mentionnés par les théoriciens.

### 10.3.2 Rapport de vraisemblance multi-variables

L'analyse de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  présentée section 9.2 utilise un critère de sélection plus léger sur l'impulsion transverse des photons,  $p_T > 20$  GeV. Nous n'avons pas réévalué les sections efficaces pour ce seuil puisque nous avons trouvé la dépendance en  $p_T$  négligeable. Nous utilisons le même graphique 10.3 pour reporter les limites de l'analyse  $H \rightarrow \gamma\gamma$  par rapport de vraisemblance multi-variable que pour les projections du PTDR. Les meilleurs résultats pour une analyse utilisant un rapport de vraisemblance ont été obtenus en combinant les observables de masse invariante  $M_{\gamma\gamma}$  dans quatre catégories, d'impulsion transverse du boson de Higgs  $q_T$  et la distribution angulaire  $\cos(\theta^*)$ . La limite posée à 95% de niveau de confiance sur la section efficace du boson de Higgs est de  $r_{95CL} \simeq 1.5$  (incertitudes systématiques comprises). Cela signifie que l'analyse devient sensible aux modèles prédisant une section efficace du boson de Higgs qui serait 1.5 fois celle du modèle standard, comme le modèle d'octet de couleur. Après repondération du signal et du bruit de fond, la limite devient  $r_{95CL} \simeq 1.34$ , ce qui se rapproche du modèle de dimension supplémentaires universelles. Cependant, pour être sûr d'exclure de tels modèles, il faudrait être sûr que la cinématique du modèle est la même que celle du modèle standard, ce qui n'est pas certain puisque les particules de nouvelles physique interviennent dans les corrections NLO et NNLO virtuelles.

## 10.4 Conclusions et perspectives

Dans ce dernier chapitre, nous avons mis en oeuvre avec le générateur Madgraph une paramétrisation développée par des collaborateurs phénoménologues pour le processus  $H \rightarrow \gamma\gamma$  au-delà du modèle standard [93]. Cette paramétrisation rend compte des variations des rapports de branchement et des sections efficaces du fait des particules de nouvelles physiques intervenant dans les boucles  $gg \rightarrow H$  et  $H \rightarrow \gamma\gamma$ , pour lesquelles deux paramètres  $\kappa_{gg}$  et  $\kappa_{\gamma\gamma}$  sont introduits. Ces paramètres rendent compte de l'importance de la déviation de la physique du boson de Higgs par rapport au modèle standard. Si le boson de Higgs est observé au LHC, la mesure de ces paramètres donnera une indication complémentaire à la recherche de nouvelles particules quant à la nature du modèle adéquat à la description des phénomènes

physiques aux énergies du LHC.

Nous avons implémenté la paramétrisation  $\kappa_{gg}-\kappa_{\gamma\gamma}$  dans Madgraph à l'aide de la théorie effective du boson de Higgs (HEFT). Seules quelques lignes de codes ont eu besoin d'être modifiées. Le plan  $\kappa_{gg}-\kappa_{\gamma\gamma}$  a ensuite été balayé pour évaluer la dépendance des sections efficaces au-delà du modèle standard par rapport à celles du modèle standard, pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  dans un premier temps, avec une énergie dans le centre de masse de 7 TeV. Dans un deuxième temps, le tableau a été complété par la prise en compte des autres mécanismes de production, de manière effective et suivant les approximations effectuées référence [93]. Les résultats obtenus avec Madgraph semblent en accord avec les formules théoriques approchées. La dépendance des sections efficaces en fonction de  $\kappa_{gg}$  et  $\kappa_{\gamma\gamma}$  suit les mêmes tendances. Il semble toutefois que la dépendance en fonction de  $\kappa_{gg}$  soit plus importante et la dépendance en fonction de  $\kappa_{\gamma\gamma}$  moins prononcée.

Le résultat a ensuite été comparé directement avec les limites d'exclusion attendues par les analyses de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  avec  $1 fb^{-1}$  : celles extrapolées à partir des résultats du PTDR à 14 TeV et celles obtenues section 9.2. L'analyse extrapolée du PTDR prédit que pour un boson de Higgs de masse 120 GeV, une limite d'exclusion à 95% de niveau de confiance pourra être posée pour des sections efficaces qui sont quatre fois celle du modèle standard. Aucun modèle "naturel" n'est trouvé dans cette zone dans le plan  $\kappa_{gg}-\kappa_{\gamma\gamma}$ . L'analyse présentée chapitre 9, si elle est confirmée par l'usage d'outils statistiques plus élaborés, exclut des sections efficaces plus grandes que 1,5 fois celle du modèle standard (incertitudes systématiques incluses, pas de repondération), amenant la sensibilité de CMS au niveau de modèle d'octet de couleur, qui pourrait donc être exclu pour une certaine gamme de paramètres à déterminer dès  $1 fb^{-1}$  de luminosité intégrée à 7 TeV. Avec repondération du signal et du bruit de fond à l'aide de générateurs aux ordres supérieurs, la limite devient 1,34 fois la section efficace du modèle standard. L'analyse devient alors sensible aux modèles de dimensions supplémentaires universelles.

Cette analyse gagnerait à être complétée en répétant l'analyse chapitre 9 avec des échantillons Madgraph pour les paramètres  $\kappa_{gg} = \kappa_{\gamma\gamma} = 0$  du modèle standard après simulation du détecteur et reconstruction. Pour le moment nous n'avons pas tenu compte de la cinématique des échantillons Madgraph mais seulement des sections efficaces. Il serait intéressant de comparer la cinématique obtenue avec Madgraph, Pythia, MC@NLO et HNNLO. D'autre part, il serait aussi possible d'implémenter la paramétrisation  $\kappa_{gg}-\kappa_{\gamma\gamma}$  avec d'autres générateurs pour les autres mécanismes de production du boson de Higgs, ce qui permettrait de se passer des formules approchées et vérifier la dépendance des autres processus en  $\kappa_{gg}$  et surtout  $\kappa_{\gamma\gamma}$ .

Il serait aussi intéressant d'utiliser la capacité de Madgraph à générer des jets durs supplémentaires pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  pour vérifier si cela influe beaucoup sur le résultat (jusqu'ici toutes les sections efficaces ont été évaluées au LO sans jets durs supplémentaires). Nous avons essayé cette possibilité avec Madgraph HEFT et il nous a semblé faisable de générer un ou deux jets supplémentaires, bien que les processus avec deux jets supplémentaires comprennent aussi bien les jets ISR pour la fusion des gluons et le mécanisme de fusion de bosons vecteurs. La prise en compte des effets cinématiques dus aux ordres supérieurs, si on veut aussi tenir compte des contributions virtuelles, pourrait être effectuée soit de manière théorique en raffinant le modèle des paramètres  $\kappa_{gg}-\kappa_{\gamma\gamma}$  à l'aide de calculs NLO (plutôt pour le mécanisme de fusion de gluon qu'on sait sensible aux ordres supérieurs - au contraire de la boucle intervenant dans la désintégration du boson de Higgs en deux photons), ou de manière effective en repondérant les échantillons Madgraph de la même manière que nous l'avons réalisé avec MC@NLO chapitre 7.

Enfin toute cette analyse a été effectuée pour un boson de Higgs de masse 120 GeV, une énergie dans le centre de masse de 7 TeV et dans l'hypothèse d'une luminosité intégrée de  $1 fb^{-1}$  : seules des limites d'exclusion sur la section efficace du boson de Higgs ont pu être posées. Après l'arrêt technique du LHC au bout d'un an et demi de fonctionnement à cette énergie, l'énergie dans le centre de masse devrait être proche de 14 TeV. L'analyse devra être répétée et lorsque suffisamment de luminosité aura été accumulée, si le boson de Higgs est découvert dans les canaux inclusifs et de fusion de bosons vecteurs, il deviendra

possible de donner une première mesure des paramètres  $\kappa_{gg}$  et  $\kappa_{\gamma\gamma}$ . Il sera alors important d'utiliser des générateurs spécifiques aux différents modèles pour connaître leur localisation précise dans le plan  $\kappa_{gg}$ - $\kappa_{\gamma\gamma}$ . L'indication finale quant au modèle approprié à la nouvelle physique ne viendra pas nécessairement de ce modèle effectif mais plutôt de la recherche directe de particules de nouvelle physique elle-même, au LHC ou dans l'un des futurs collisionneurs linéaires.

# CONCLUSION

Dans cette thèse, nous avons élaboré trois principaux outils. Nous avons proposé une nouvelle méthode de récupération des photons FSR émis par les leptons dans le canal  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  ( $l = e, \mu$ ), un outil de discrimination  $\gamma/\pi^0$  à l'aide d'un réseau de neurones que nous avons utilisé pour la mesure de la pureté et du nombre d'événements de signal des processus  $\gamma+X$  et  $\gamma\gamma+X$  ainsi que pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$ , et la repondération des processus  $\gamma\gamma+X$  et  $H \rightarrow \gamma\gamma$ , que nous avons inclus dans l'analyse de recherche du boson de Higgs. Nous avons aussi implémenté dans Madgraph la paramétrisation effective développée par des phénoménologues avec lesquels nous avons collaboré pour le processus  $H \rightarrow \gamma\gamma$  au-delà du modèle standard et interprété les résultats de l'analyse de recherche du boson de Higgs en terme de modèles pouvant être exclus dès une luminosité de  $1 fb^{-1}$  avec une énergie de 7 TeV dans le centre de masse.

La nouvelle méthode de récupération des photons émis par les leptons dans l'état final de la désintégration  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  ( $l = e, \mu$ ) permet la récupération d'un nombre variable de photons par événements, donne une meilleure performance que la méthode précédemment utilisée dans CMS et permet l'amélioration de la résolution sur la masse des bosons  $Z^0$  et du boson de Higgs, ainsi qu'un gain de 5% sur la signification d'une observation du boson de Higgs dans ce canal dans la gamme  $m_H > 180$  GeV. Nous avons vérifié les principales distributions cinématiques des photons FSR dans les données de muons cosmiques. Nous avons aussi proposé une méthode permettant la mesure du taux de faux à partir de quelques  $fb^{-1}$  de données de collisions, qui utilise une variante de la méthode "random cone". L'algorithme de récupération des photons FSR est implémenté dans le framework de l'analyse  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  de CMS et a donné lieu à la participation à deux notes internes et une note publique.

Un nouvelle approche pour la discrimination  $\gamma/\pi^0$  dans CMS a été proposée pour des photons boostés et isolés, qui utilise un réseau de neurones fondé sur trois variables de forme du cluster et trois variables d'environnement, ce qui constitue un plus petit nombre de variables que les approches proposées jusqu'ici. Les variables de forme du cluster donnent des meilleurs résultats que les variables d'environnement. Les performances du réseau de neurones sont approximativement les mêmes pour des photons convertis et non-convertis, dans le tonneau et le bouchon. Le réseau de neurones proposé donne des performances meilleures que le réseau de neurone utilisé pour l'analyse  $H \rightarrow \gamma\gamma$  du PTDR. Son utilisation a été validée à partir des données et les moyens de maîtriser les incertitudes systématiques ont été indiqués. Nous avons aussi proposé une méthode pour entraîner le réseau de neurone à partir des données, qui utilise la cinématique des événements  $\gamma+jet$ . La variable de sortie du réseau de neurone a ensuite été utilisée comme variable "template" pour la mesure de la pureté et du nombre de photons de signal du processus inclusif  $\gamma+X$  observé dans les données dans cinq plages d'impulsions transverses dans la gamme  $15 < p_T < 120$  GeV avec  $10,24 nb^{-1}$  de luminosité intégrée. Nous avons aussi préparé la mesure de la section efficace différentielle  $\gamma\gamma+X$  pour les observables  $M_{\gamma\gamma}$ ,  $q_T$ ,  $\cos(\theta^*)$  et  $\Delta\phi$  à partir de la simulation dans l'hypothèse d'une luminosité intégrée de  $10 pb^{-1}$  avec la sortie du réseau de neurone comme variable "template", qui serait à répéter en utilisant un échantillon de QCD jets disposant d'un plus grand nombre d'événements. Les premières distributions diphotons dans les données avec une luminosité de  $10,24 nb^{-1}$  ont été examinées.

Dans l'optique de la comparaison des données et des prédictions théoriques pour le processus  $\gamma\gamma+X$  ainsi que pour la prédiction la plus précise possible des distributions cinématiques du signal  $H \rightarrow \gamma\gamma$  et du bruit de fond diphoton, une repondération des événements simulés à l'aide d'un K-facteur en deux

dimensions obtenu avec des générateurs aux ordres supérieurs a été effectuée. Le choix des critères d'isolation a été investigué dans le détail et les incertitudes théoriques liées à l'échelle d'énergie et à l'ensemble des densités partoniques ont été estimées. Le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  est repondéré à l'aide du K-facteur  $K(q_T, Y_{\gamma\gamma})$  calculé au NNLO avec HNNLO par rapport à MC@NLO, tandis que les processus  $\gamma\gamma+X$  Born et Box sont pour la première fois repondérés avec un K-facteur  $K(q_T, M_{\gamma\gamma})$  calculé au NLO conjointement avec Diphox et Gamma2MC par rapport à Madgraph Born et Pythia Box. La repondération du bruit de fond fonctionne correctement dans la plage de masse  $M_{\gamma\gamma} > 100$  GeV où le boson de Higgs est recherché.

Nous avons ensuite intégré les outils de discrimination  $\gamma/\pi^0$  et de repondération à l'analyse de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$ . Les incertitudes systématiques pour le signal et le bruit de fond ont été évaluées et le taux d'événements de bruit de fond a été mesuré à partir des bandes de côté de la distribution  $M_{\gamma\gamma}$ . Un rapport de vraisemblance utilisant seulement la distribution de masse invariante après identification des photons par un critère de sélection sur la sortie du réseau de neurones conduit à un rapport  $r_{95CL}$  des sections efficaces d'exclusion à 95% de niveau de confiance sur la section efficace du boson de Higgs dans le modèle standard (ayant  $m_H = 120$  GeV) de  $r_{95CL} \simeq 3$  pour une luminosité intégrée de  $1 \text{ fb}^{-1}$ , tandis que les projections du PTDR de 14 TeV à 7 TeV n'utilisant pas de d'outil de discrimination  $\gamma/\pi^0$  donnaient  $r_{95CL} \simeq 4$ . Le test statistique qui a donné les meilleurs résultats est un rapport de vraisemblance multi-variables utilisant  $M_{\gamma\gamma}$  dans quatre catégories (en  $\eta$  et  $R9$ ),  $q_T$  et  $\cos(\theta^*)$ , une fois les photons identifiés avec un critère de sélection sur la sortie du réseau de neurones. Un rapport  $r_{95CL} \simeq 1.5$  a été obtenu, et une fois la repondération prise en compte le résultat final devient  $r_{95CL} \simeq 1.35$ . Repondérer au NLO le processus  $\gamma\gamma+X$  et au NNLO le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  conduit en effet à l'augmentation du taux de signal et de bruit de fond ainsi qu'à une réduction de l'incertitude systématique sur le signal de 20% à 12,5%.

Enfin, la paramétrisation du processus  $H \rightarrow \gamma\gamma$  au-delà du modèle standard dans le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$  a été implémentée dans Madgraph pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$ . Les sections efficaces calculées avec Madgraph suivent la même tendance en fonction de  $\kappa_{\gamma\gamma}$  et  $\kappa_{gg}$  que les calculs théoriques approchés, bien que la dépendance en fonction de  $\kappa_{\gamma\gamma}$  soit plus faible et en  $\kappa_{gg}$  plus importante. Les résultats obtenus pour la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  s'interprètent dans ce modèle comme pouvant conduire à l'exclusion (pour une certaine gamme de paramètres) des modèles d'une quatrième génération de fermions et de dimensions supplémentaires universelles dès  $1 \text{ fb}^{-1}$  de luminosité intégrée avec une énergie de 7 TeV dans le centre de masse.

## Perspectives

Les analyses dont les résultats sont présentés dans cette thèse pourraient être raffinées ou développées de bien des façons. Nous mentionnerons seulement ici les applications qui nous paraissent les plus prometteuses, et qui tirent parti du fait que nous disposons maintenant des données du LHC.

Au moment où j'écris cette conclusion, CMS a enregistré une luminosité intégrée d'environ  $1 \text{ pb}^{-1}$ . Les données du LHC offrent d'ores et déjà un nombre suffisant de bosons  $Z$  pour bien des applications. La méthode de récupération des photons FSR émis par les leptons pourrait être ré-optimisée et appliquée aux processus  $Z \rightarrow ll$  dans les données. L'optimisation des paramètres de la méthode séparément pour les électrons et les muons pourrait améliorer la performance de l'algorithme. Les électrons du processus  $Z \rightarrow ee$  pourraient aussi être utilisés pour mesurer l'incertitude systématique liée à l'utilisation du réseau de neurone de discrimination  $\gamma/\pi^0$  à partir des données.

En ce qui concerne la mesure de la section efficace du processus  $\gamma+X$ , il serait nécessaire de continuer à rechercher des méthodes permettant la construction des distributions "template" pour le bruit de fond à partir des données. Nous disposons aussi d'une luminosité intégrée suffisante pour effectuer la mesure en ayant entraîné le réseau de neurones en utilisant la cinématique du processus  $\gamma$ +jet pour sélectionner un lot de photons du bruit de fond dans les données. Avec la luminosité actuelle, il devient possible d'effectuer les premières mesures des sections efficaces différentielles du processus  $\gamma\gamma+X$  dans les données.

De ce point de vue, si l'on veut s'affranchir du manque de statistique dans les échantillons de QCD jets, il sera nécessaire d'utiliser d'autres méthodes que celles décrites dans cette thèse, comme la méthode de la matrice  $4 \times 4$ , où les distributions templates sont construites relativement aux photons et aux jets, et non aux diphotons ou aux dijets.

La procédure de repondération présentée pour le processus  $\gamma\gamma+X$  à l'aide du K-facteur  $K(q_T, M_{\gamma\gamma})$  a montré fonctionner correctement pour le domaine de masse invariante où est recherché le boson de Higgs, mais pas sur tout l'espace de phase. Si l'on souhaite aussi pouvoir comparer prédictions théoriques et expérience dès  $M_{\gamma\gamma} > 40$  GeV à l'aide d'une repondération effectuée une fois pour toute, d'autres K-facteurs pourraient être essayés qui dépendraient des distributions angulaires. Il reste toujours la possibilité d'effectuer la repondération pour chaque observable pour laquelle on souhaite comparer théorie et expérience. Utiliser le générateur Resbos, qui dispose de la resommation des gluons dans l'état initial, constituerait une importante vérification par rapport à l'utilisation de Diphox et Gamma2MC.

Les principales améliorations à apporter à l'analyse de recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  sont de deux types. Les incertitudes systématiques pour  $M_{\gamma\gamma}$ , mais surtout  $q_T$  et  $\cos(\theta^*)$  devraient être évaluées de sorte à dépendre de la valeur des observables. Le test statistique pourrait aussi être raffiné pour produire des distributions plus réalistes des fausses données et obtenir les bandes d'incertitudes sur les sections efficaces d'exclusion à 95% de niveau de confiance. Afin d'être certain de l'exclusion des modèles de quatrième génération et de dimensions supplémentaires universelles dans le plan  $\kappa_{\gamma\gamma}-\kappa_{gg}$ , des analyses dédiées à ces modèles seraient nécessaires pour déterminer dans quel gamme de paramètres ces modèles seraient exclus.

Quelques remarques enfin pour terminer. Nous espérons avoir montré dans cette thèse l'importance de la prise en compte des effets cinématiques dûs aux ordres supérieurs sur la sensibilité des analyses. La récupération des photons FSR émis par les leptons dans le canal  $H \rightarrow ZZ^{(*)} \rightarrow 4l$  et la repondération des processus  $\gamma\gamma+X$  et  $gg \rightarrow H \rightarrow \gamma\gamma$  conduisent tous les deux à une amélioration sensible de la signification d'une observation du boson de Higgs, le premier en améliorant la résolution sur la masse invariante du boson de Higgs et le second en permettant entre autre une description plus précise de l'impulsion transverse des diphotons. Il nous semble important de prendre en compte aussi bien les photons que les jets supplémentaires dans les analyses. Les progrès actuels des générateurs, notamment avec la prise en compte des interférences ainsi que des boucles virtuelles d'une manière plus systématisée (par exemple avec l'interfaçage des générateurs à éléments de matrice aux ordres supérieurs avec les générateurs à gerbe partonique) constituent un pas important dans cette direction.

Les différents outils développés dans cette thèse, de nature assez variée, pourraient être réunis dans un domaine d'application particulier. Le LHC n'est en général pas considéré comme un outil de mesure de précision au contraire du LEP. Le LEP a permis la mesure de la fonction de fragmentation des quarks en photons [175]. Il nous semble que la méthode de récupération des photons FSR pourrait être appliquée aux photons de fragmentation des quarks. Le réseau de neurone de discrimination  $\gamma/\pi^0$  pourrait alors être utilisé pour estimer le taux réels de photons prompts récupérés, et permettre la mesure de la fonction de fragmentation au LHC. Ces mesures pourraient ensuite être comparées aux prédictions théoriques de Jetphox et Diphox et permettre une meilleure connaissance de ce type de phénomènes à l'énergie de centre de masse atteinte au LHC.





## Annexe A

# Reconstruction et identification des photons à $\sqrt{s} = 7$ TeV

Dans cet appendice, nous reportons les résultats publics de CMS issus de la note [40] concernant la reconstruction et l'identification des photons dans les données de collision à 7 TeV, travaux auxquels nous avons participé. L'analyse utilise un échantillon de données ayant une luminosité intégrée de  $74 \text{ nb}^{-1}$ . Nous présenterons dans un premier temps la reconstruction des super-clusters et des photons, avant de détailler les critères d'identification des photons. Nous ne présentons ici que les résultats auxquels nous avons participé (se référer à la note [40] pour une présentation plus complète des résultats, notamment ceux sur les photons convertis et la contamination des photons en événements "beam-halo").

### A.1 Reconstruction des super-clusters et des photons

La reconstruction des super-clusters et des photons a déjà été décrite dans le détail section 1.3.2. Les super-clusters sont reconstruits avec l'algorithme "hybrid" dans le tonneau et "multi5x5" dans les bouchons. L'énergie des super-clusters est ensuite corrigée pour différents effets déjà discutés (perte d'énergie latérale, dépendance en énergie transverse des processus de conversion et de bremsstrahlung, quantité de matière devant le ECAL).

La sélection suivante est appliquée dans les données et la simulation :

- Les événements doivent passer le déclenchement de haut niveau HLT\_Photon15\_L1R.
- Les super-clusters doivent avoir une énergie minimum non corrigée  $E_T > 20$  GeV.
- Les super-clusters sont sélectionnés s'ils ont une pseudo-rapacité  $|\eta| < 2.5$  et s'ils ne sont pas dans la région de transition entre le tonneau et les bouchons,  $1.4442 < |\eta| < 1.566$ .
- Les "spikes" sont éliminés [38] par le critère de forme du cluster  $(1 - E4/E1) < 0.95$ , où  $E1$  est l'énergie du cristal de plus haute énergie dans le super-cluster et  $E4$  la somme des énergies des quatre cristaux voisins en  $\eta$ - $\phi$ . La synchronisation en temps est aussi utilisée.
- Un critère de sélection  $H/E < 0.05$  est appliqué pour rejeter les jets ayant une partie significative de leur énergie hadronique et pour éviter les différences vis-à-vis de la simulation du déclenchement de niveau 1 qui n'utilisait pas ce critère, au contraire du système d'acquisition des données.

On montre figure A.1 la pseudo-rapacité des super-clusters sélectionnés, figure A.2 leur énergie transverse non corrigée. Pour chaque distribution, on montre la contribution des photons de "signal" (ISR/FSR ou partoniques) et des autres photons, principalement issus de  $\pi^0$  ou d'autres désintégrations de mésons neutres et de faux photons instrumentaux. Pour toutes les distributions, la simulation est normalisée au nombre d'entrées dans les données après la sélection.

On montre figure A.3 la variable topologique  $R9 = E_{3 \times 3}/E_{SC}$  utilisée pour la reconstruction des photons à partir des super-clusters (voir section 1.3.2).




FIG. A.1 – Pseudo-rapidité des super-clusters reconstruits avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.

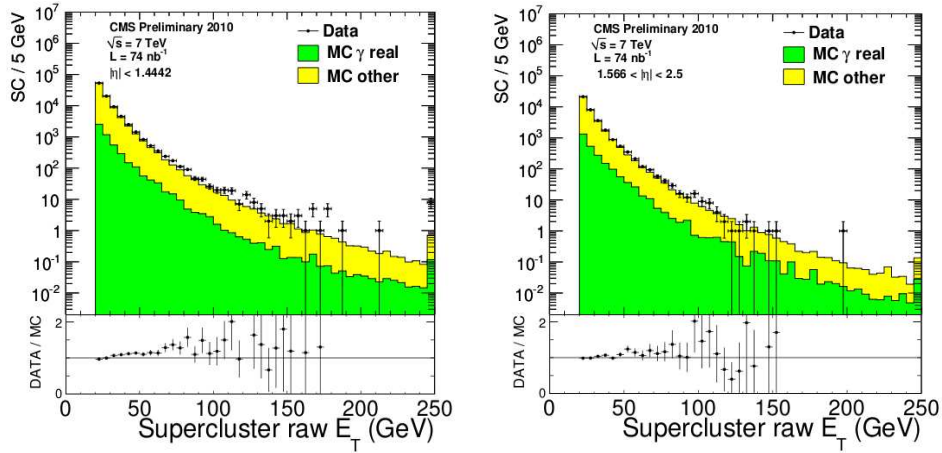


FIG. A.2 – Energie transverse non-corrigée des super-clusters reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.




FIG. A.3 – Variable topologique  $R9 = E_{3 \times 3}/E_{SC}$  des super-clusters reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.

## A.2 Identification des photons

Afin d'augmenter la pureté en signal de l'échantillon, les critères d'identification utilisant les grandeurs suivantes sont appliqués aux photons :

- On ne considère que les photons ayant une énergie transverse  $E_T > 30$  GeV.
- Il ne doit pas y avoir de coup dans le détecteur à pixel associé au super-cluster.
- Isolation ECAL ("jurassic") : la somme en énergie transverse dans le ECAL autour du photon candidat dans un anneau de rayon interne  $\Delta R = 0.06$  et un rayon externe  $\Delta R = 0.4$  doit être inférieure à 4,2 GeV. L'énergie transverse de trois cristaux en  $\phi$  autour du cristal central n'est pas considérée dans la somme.
- Isolation HCAL : la somme en énergie transverse dans le HCAL autour du photon candidat dans un anneau de rayon interne  $\Delta R = 0.15$  et un rayon externe  $\Delta R = 0.4$  doit être inférieure à 2,2 GeV.
- Isolation trajectographique : la somme scalaire de l'impulsion transverse des traces venant du vertex primaire dans un cône de rayon interne  $\Delta R = 0.04$  (choisi pour ne pas rejeter les photons convertis) et un rayon externe  $\Delta R = 0.4$  doit être inférieure à 2,0 GeV.
- $\sigma_{i\eta i\eta}$  est l'élément  $\eta$ - $\eta$  de la matrice de covariance  $\eta$ - $\phi$  du basic-cluster de plus haute énergie dans le super-cluster :

$$\sigma_{i\eta i\eta}^2 = \frac{\sum_i w_i (i\eta_i - i\eta_{seed})^2}{\sum_i w_i}$$

Où  $E_i$  est l'énergie du cristal  $i$ ,  $i\eta$  son index dans le basic-cluster de plus haute énergie,  $i\eta_{seed}$  l'index du cristal de plus haute énergie. Les poids  $w_i$  sont donnés par :

$$w_i = \max\left(0, 4.7 + \ln\left(\frac{E_i}{E_{BC}}\right)\right)$$

Où  $E_i$  est l'énergie du cristal  $i$  et  $E_{BC}$  est l'énergie du basic-cluster de plus haute énergie. On demande  $\sigma_{i\eta i\eta} < 0.01$  dans le tonneau et  $\sigma_{i\eta i\eta} < 0.03$  dans les bouchons.

Ces critères d'identification ont été optimisés pour permettre une efficacité d'identification plate en  $\eta$  et en  $E_T$ . On montre figure A.4 la pseudo-rapidité des photons, figure A.5 l'énergie transverse des photons et figure A.6 la variable  $R9$ , après identification. La pureté en photons de signal, calculée par la simulation, est supérieure à 50%.

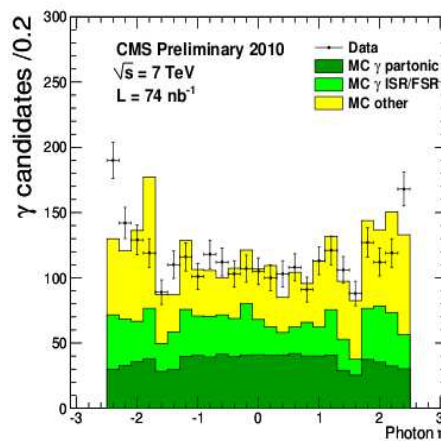


FIG. A.4 – Pseudo-rapidité des photons reconstruits après application des critères d'identification avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.

On montre aussi les distributions portant sur les critères d'identification, où tous les critères de sélection ont été appliqués sauf celui qui est montré sur le graphique ("distribution N-1"). L'isolation dans le ECAL, le HCAL et le trajectographe ainsi que l'isolation combinée (somme des énergies d'isolation),  $\sigma_{i\eta i\eta}$  et la présence d'un coup dans le détecteur à pixel sont montrés respectivement figure A.7, A.8, A.9, A.10, A.11




FIG. A.5 – Energie transverse des photons reconstruits après application des critères d'identification dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.




FIG. A.6 – Variable topologique  $R9 = E_{3 \times 3} / E_{SC}$  des photons reconstruits après application des critères d'identification dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.

et A.12. Données et simulation sont raisonnablement consistants.




FIG. A.7 – Distribution N-1 de l'énergie d'isolation dans le ECAL des photons reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.

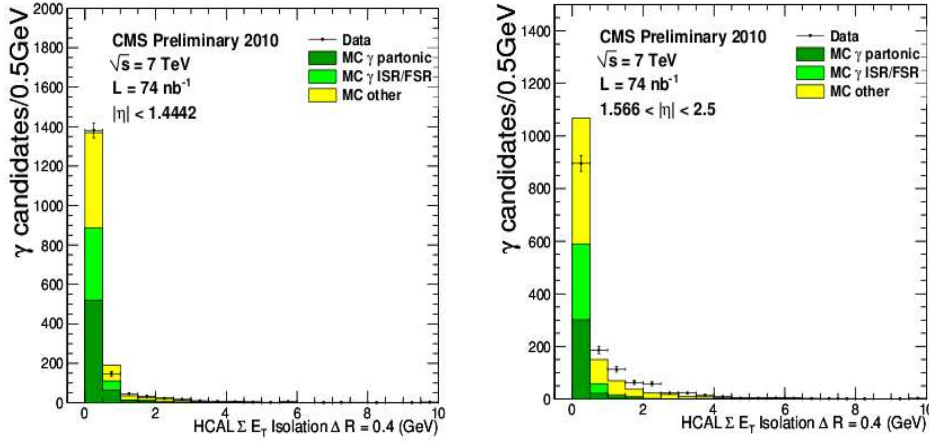


FIG. A.8 – Distribution N-1 de l'énergie d'isolation dans le HCAL des photons reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.




FIG. A.9 – Distribution N-1 de l'énergie d'isolation trajectographique des photons reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.




FIG. A.10 – Distribution de la somme de l'énergie d'isolation dans le ECAL, le HCAL et trajectographique des photons reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV. Tous les critères de sélection sauf les critères d'isolation ont été appliqués.




FIG. A.11 – Distribution N-1 de  $\sigma_{in|η}$  des photons reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.




FIG. A.12 – Distribution N-1 de la présence d'un coup dans le détecteur à pixel pour les photons reconstruits dans le tonneau (à gauche) et dans les bouchons (à droite) avec une luminosité intégrée de  $74 \text{ nb}^{-1}$  dans les données de collisions à 7 TeV.

# Bibliographie

- [1] T.S. Pettersson and P. Lefèvre. The large hadron collider : conceptual design. *CERN-AC-95-05 LHC*, 1995.
- [2] The CMS Collaboration. The compact muon solenoid technical proposal. *CERN/LHCC 94-38. LHCC-P-1*, 1994.
- [3] The ATLAS Collaboration. Atlas : technical proposal for a general-purpose pp experiment at the large hadron collider at cern. *CERN-LHCC-94-43; LHCC-P-2*, 1994.
- [4] The ALICE Collaboration. Alice : Technical proposal for a large ion collider experiment at the cern lhc. *CERN-LHCC-95-71; LHCC-P-3*, 1995.
- [5] The LHCb Collaboration. Lhcb : Technical proposal. *CERN-LHCC-98-004; LHCC-P-4*, 1998.
- [6] L. Evans and P. Bryant. Lhc machine. *JINST 3 S08001*, 2008.
- [7] CERN Communication group. Faq lhc. 2006.
- [8] C. Amsler et al. Review of particle physics.
- [9] R. Bailey and P. Collier. Standard filling schemes for various lhc operation modes. *LHC project Note 323*, 2003.
- [10] The CMS Collaboration. Physics technical design report, vol.i : Detector performance and software. *CERN/LHCC 2006-001*, 2006.
- [11] C. Augier et al. *Phys. Lett. B 315, 503*, 1993.
- [12] O. Nachtmann. Pomeron physics and qcd. *hep-ph/0312279. Contribution to the Ringberg Workshop on HERA physics*.
- [13] CERN. Geneva. DG. Summary of the analysis of the 19 september 2008 incident at the lhc. *Record 1135729*, 2008.
- [14] The CMS Collaboration. The tracker project technical design report. *CERN/LHCC 98-006. CMS TDR 5, Addendum CERN/LHCC 2000-016*, 1998.
- [15] CMS Collaboration. The cms experiment at cern lhc. *JINST 3 S08004*, 2008.
- [16] The CMS Collaboration. The electromagnetic calorimeter technical design report. *CERN/LHCC 94-033. CMS TDR 4, Addendum CERN/LHCC 2002-027*, 1997.
- [17] The CMS Collaboration. The hadron calorimeter technical design report. *CERN/LHCC 97-031. CMS TDR 2*, 1997.
- [18] The CMS Collaboration. The magnet project technical design report. *CERN/LHCC 97-010. CMS TDR 1*, 1997.
- [19] The CMS Collaboration. The muon project technical design report. *CERN/LHCC 97-32. CMS TDR 3*, 1997.
- [20] The cms offline workbook. <https://twiki.cern.ch/twiki/bin/view/CMS/WorkBook>, 2010.
- [21] CMS Collaboration. The tridas project technical design report, volume 1 : The trigger systems. *CERN/LHCC 2000-38. CMS TDR 6.1*, 2000.
- [22] CMS Collaboration. The tridas project technical design report, volume 2 : Data acquisition and high-level trigger. *CERN/LHCC 2002-26. CMS TDR 6.2*, 2002.
- [23] T. Stelzer and W. F. Long. Automatic generation of tree level helicity amplitudes. *Comput. Phys. Commun. 81, 357-371*, 1994.

- [24] A.D. Polosa M. Moretti M.L. Mangano, F. Piccinini and R. Pittau. Alpgen, a generator for hard multiparton processes in hadronic collisions. 2002.
- [25] P. Bartalini S. Belov E. Boos A. Buckley J.M. Butterworth L. Dudko S. Frixione L. Garren S. Gieseke A. Gusev I. Hinchliffe J. Huston B. Kersevan F. Krauss N. Lavesson L. L J. Alwall, A. Ballestrero. A standard format for les houches event files.
- [26] S. Mrenna T. Sjostrand and P. Skands. Pythia 6.4 physics and manual. 2006.
- [27] G. Marchesini S. Moretti K. Odagiri P. Richardson M.H. Seymour G. Corcella, I.G. Knowles and B.R. Webber. Herwig 6.5. *JHEP 0101, 010*, 2001.
- [28] Root : A data analysis framework. <http://root.cern.ch/drupal/>.
- [29] S. Agostinelli et al. GEANT4 Collaboration. Geant4 : A simulation toolkit. *Nucl. Instrum. and Methods A506, 250-303*, 2003.
- [30] The CMS Collaboration. Measurement of muon stopping power in lead tungstate. *JINST 5 P03007*, 2010.
- [31] V. Litvine M. Gataullin Y. Yang G. Franzoni P. Gras, M. Marionneau and T. Tabarelli de Fatis. Offline study of ecal readout options. *CMS internal document*, 2009.
- [32] The CMS Collaboration. Performance and operation of the cms electromagnetic calorimeter. *JINST 5 T03010*, 2010.
- [33] Y. Gershtein. Preparing for measurement of photon identification efficiency and energy scale using  $\mu\mu\gamma$  final state. *CMS Note 2005/040.*, 2005.
- [34] C. Baty. *Contribution à la calibration des photons par les désintégrations radiatives  $Z \rightarrow \mu\mu\gamma$ , dans l'expérience CMS au LHC*. PhD thesis, Institut de Physique Nucléaire de Lyon, Université Claude Bernard Lyon 1, 2009.
- [35] A.F. Barbuss D. Evans F. Ferri K. Kaadze Y. Maravin P. Meridiani M. Anderson, A. Askew and C. Seez. Review of clustering algorithms and energy corrections in ecal. *CMS IN-2010/008*, 2010.
- [36] N. Marinelli. Track finding of gamma conversions in cms. *CMS CR-2007/052*, 2007.
- [37] F. Ferri D. Futyan P. Meridiani I. Puljak C. Rovelli R. Salerno S. Baffioni, C. Charlot and Y. Sirois. Electron reconstruction in cms. *CMS NOTE 2006-40*, 2006.
- [38] The CMS Collaboration. Electronic calorimeter commissioning and first results with 7 tev data. *CMS NOTE 2010-012*, 2010.
- [39] The CMS Collaboration. Electromagnetic calorimeter calibration with 7 tev data. *CMS PAS EGM-10-003*, 2010.
- [40] The CMS Collaboration. Photon reconstruction and identification at  $\sqrt{s} = 7$  tev. *CMS PAS EGM-10-005*, 2010.
- [41] J.D. Jackson and L.B. Okun. Historical roots of gauge invariance. *Rev. Mod. Phys. 73, 663-680*, 2001.
- [42] L. O’Raifeartaigh and N. Straumann. Early history of gauge theories and kaluza-klein theories, with a glance a at recent developments. *arxiv :hep-ph/9810524v2*, 1999.
- [43] W. Pauli. Relativistic field theories of elementary particles. *Rev. Mod. Phys. 13, 203-232*, 1941.
- [44] C.N. Yang and R.L. Mills. Conservation of isotopic spin and isotopic gauge invariance. *Phys. Rev. 96, 191-198*, 1954.
- [45] M. Gell-Mann. Isotopic spin and new unstable particles. *Phys. Rev. 92, 833-834*, 1953.
- [46] S. Weinberg. Unified theory of weak and electromagnetic interactions. *Rev. Mod. Phys. 52, No.3, 515-523*, 1980.
- [47] R.P. Feynman and M. Gell-Mann. Theory of the fermi interaction. *Phys. Rev. 109, 193-198*, 1958.
- [48] S.A. Bludman. *Nuovo Cimento 9, 433*, 1958.
- [49] L.N. Cooper J. Bardeen and J.R. Schrieffer. Theory of superconductivity. *Phys. Rev. 108, 1175-1204*, 1957.



- [50] P.W. Anderson. Plasmons, gauge invariance, and mass. *Phys. Rev.* *130*, 439-442, 1962.
- [51] Y. Nambu and G. Jona-Lasinio. Dynamical model of elementary particles based on an analogy with superconductivity. i. *Phys. Rev.* *122*, 345-358, 1961.
- [52] J. Goldstone. *Nuovo Cimento* *19*, 54, 1961.
- [53] W. Heisenberg. *Z. Naturforsch.* *14*, 441, 1959.
- [54] P.W. Higgs. Broken symmetries, massless particles and gauge fields. *Phys. Lett.* *12*, 132-133, 1964.
- [55] P.G.O. Freund and Y. Nambu. Mass and coupling constant formulas in broken symmetry schemes. *Phys. Rev. Lett.* *13*, 221-225, 1964.
- [56] P.W. Higgs. Spontaneous symmetry breakdown without massless bosons. *Phys. Rev* *145*, 1156-1163, 1966.
- [57] S.L. Glashow. Partial symmetries of weak interactions. *Nucl. Phys.* *22*, 579-588, 1961.
- [58] S. Weinberg. A model of leptons. *Phys. Rev. Lett.* *19*, 1264-1266, 1967.
- [59] A. Salam and J.C. Ward. *Phys. Lett.* *13*, 168, 1964.
- [60] G.'t Hooft. Renormalizable lagrangians for massive yang-mills field. *Nucl. Phys. B*, *35*, 167-188, 1971.
- [61] T. Morii, C.S. Lim, and S.N. Mukherjee. *The Physics of the Standard Model and Beyond*. World Scientific, 2004.
- [62] T.D. Lee. A theory of spontaneous t violation. *Phys. Rev. D**8*, 1226, 1973.
- [63] J.F. Donoghue and L. F. Li. Properties of charged higgs bosons.
- [64] G.L. Kane H.E. Haber and T. Sterling. The fermion mass scale and possible effects of higgs bosons on experimental observables. *Nucl. Phys. B**161*, 493, 1979.
- [65] T.P. Cheng and M. Sher. Mass matrix ansatz and flavor nonconservation in models with multiple higgs doublets. *Phys. Rev. D**35*, 3484, 1987.
- [66] P. Fayet. Spontaneously broken supersymmetric theories of weak, electromagnetic and strong interactions. *Phys. Lett. B* *69*, 489, 1977.
- [67] S.P. Martin. A supersymmetry primer. *hep-ph/9709356v5*, 1997.
- [68] J.R. Espinosa and R.-J. Zhang. Complete two-loop dominant corrections to the mass of the lightest cp-even higgs boson in the minimal supersymmetric standard model. *hep-ph/0003246*, 2001.
- [69] A.G. Cohen N. Arkani-Ahmed and H. Georgi. Little higgs review. *Phys. Lett. B* *513*, 232.
- [70] E. Katz N. Arkani-Ahmed, A.G. Cohen and A.E. Nelson. The littlest higgs. *JHEP* *0207*, 034, 2002.
- [71] M. Schmaltz. The simplest little higgs. *JHEP* *0410*, 067, 2004.
- [72] M. Cirellia G. Cacciapaglia and G. Cristadorob. Gluon fusion production of the higgs boson in a calculable model with one extra dimension. *Phys. Lett. B* *531*, 105, 2002.
- [73] L. Randall and R. Sundrum. A large mass hierarchy from a small extra dimension. *Phys. Rev. Lett.* *83*, 3370, 1999.
- [74] Y. Hosotani. *Phys. Lett. B* *126*, 309, 1983.
- [75] A. Pomarol R. Barbieri and R. Rattazzi. Weakly coupled higgsless theories and precision electroweak tests. *Phys. Rev. Lett. B* *591*, 141, 2004.
- [76] R.P. Feynman. Very high-energy collisions of hadrons. *Phys. Rev. Lett.* *23*, 1547, 1969.
- [77] D.E. Soper. Parton density functions. *hep-lat/0609018V1*, 1996.
- [78] G. Altarelli and G. Parisi. Asymptotic freedom in parton language. *Nucl. Phys. B.* *126*, 298, 1977.
- [79] J. Huston H.L. Lai P. Nadolsky G. Pumplin, D.R. Stump and W.K. Tung. New generation of parton distributions with uncertainties from global qcd analysis. *hep-ph/0201195*, 2002.
- [80] W.J. Stirling A.D. Martin, R.G. Roberts and R.S. Thorne. Physical gluons and high  $e_t$  jets. *hep-ph/0410230v1*, 2004.

- [81] A. Djouhadi. The anatomy of electro weak symmetry breaking tome i : The higgs boson in the standard model. *hep-ph/0503172*, 2005.
- [82] M.E. Machacek H.M. Georgi, S.L. Glashow and D.V. Nanopoulos. Higgs bosons from two-gluon annihilation in proton-proton collisions. *Phys. Rev. Lett.* *40*, 692, 1978.
- [83] Frank Wilczek. Decays of heavy vector mesons into higgs particles. *Phys. Rev. Lett.* *39*, 1304, 1977.
- [84] H. Georgi and H.D. Politzer. Freedom at moderate energies : Masses in color dynamics. *Phys. Rev. D* *14*, 1829, 1976.
- [85] K. Melnikov C. Anastasiou and F. Petriello. Fully differential higgs boson production and the di-photon signal through next-to-next-to-leading order. *Nucl. Phys. B* *724*, 197-246, 2005.
- [86] S. Catani and M. Grazzini. An nnlo subtraction formalism in hadron collisions and its application to higgs boson production at the lhc. *Phys. Rev. Lett.* *98*, 222002, 2007.
- [87] .N. Cahn and S. Dawson. *Phys. Lett.* *136B*, 1984.
- [88] The CMS Collaboration. Physics technical design report, vol.ii : Physics performance. *CERN/LHCC 2006-021*, 2006.
- [89] D. Nanopoulos S.L. Glashow and A. Yildiz. *Phys. Rev. D* *18*, 1978.
- [90] M. Spira. Higgs and hdecay : Programs for higgs boson production at the lhc and higgs boson decay widths. *Nucl.Instrum.Meth. A* *389*, 357-360, 1997.
- [91] C. Quigg B.W. Lee and H.B. Thacker. *Phys. Rev. D* *16*.
- [92] M.K. Gaillard J. Ellis and D.V. Nanopoulos. A phenomenological profile of the higgs boson. *Nucl. Phys. B* *106*, 1976.
- [93] A. Deandrea G. Cacciapaglia and J. Llodra-Perez. Higgs to gamma gamma beyond the standard model. *JHEP* *06*, 054, 2009.
- [94] C. Quigg B.W. Lee and G.B. Thacker. *Phys. Lett. B* *142*, 883, 1977.
- [95] W. Marciano and S. Willenbrock. *Phys. Rev. D* *37*, 2509, 1988.
- [96] M. Luscher and P. Weisz. *Phys. Lett. B* *212*, 472, 1988.
- [97] M. Sher M. Lindner and H.W. Zaglauer. *Phys. Lett.* *228B*, 139, 1989.
- [98] L3 ALEPH, DELPHI and OPAL Collaborations. Search for the standard model higgs boson at lep. *hep-ex/0306033*, 2003.
- [99] The TEVNPH Working Group. Combined cdf and d0 upper limits on standard model higgs-boson production with up to  $6.7 \text{ fb}^{-1}$  of data. *hep-ex/1007.4587*, 2010.
- [100] D0 DELPHI L3 OPAL ALEPH, CDF and SLD Collaborations. Precision electroweak measurements and constraints on the standard model. *hep-ex/1012.2367*, 2010.
- [101] The TEVNPH Working Group. Combined cdf and d0 upper limits on standard model higgs-boson production with up to  $4.2 \text{ fb}^{-1}$  of data. *hep-ph/0903.4001*, 2009.
- [102] The CDF and D0 Collaborations. Combination of tevatron searches for the standard model higgs boson in the  $w^+w^-$  decay mode. *hep-ph/1001.4162*, 2010.
- [103] The ATLAS Collaboration. Expected performance of the atlas experiment : Detector, trigger and physics. *CERN-OPEN-2008-020*, 2008.
- [104] I. Fisk J. Letts V. Litvin M. Pieri, S. Bhattacharya and J.G. Branson. Inclusive search for the higgs boson in the  $h \rightarrow \gamma\gamma$  channel. *CMS NOTE 2006/112*, 2006.
- [105] J.-L. Agram C. Baty S. Gascon-Shotkin M. Lethuillier, O. Ravat and S. Perriès. Search for a neutral higgs boson with  $wh / zh, h \rightarrow \gamma\gamma$  channel.
- [106] S. Gascon-Shotkin M. Lethuillier D. Mercier J.-L. Agram, C. Baty and S. Perriès. Associated  $t\bar{t}h$  production with  $h \rightarrow \gamma\gamma$  in cms. *CMS AN 2006/064*, 2006.
- [107] The CMS Collaboration. The cms physics reach for searches at 7 tev. *CMS NOTE -2010/008*, 2010.
- [108] S. Catani et al. Qcd. *Proceeding of the CERN Workshop on Standard Physics (and more) at the LHC*, *hep-ph/0005025*, 2005.

- [109] S. Mrenna C. Balázs, E.L. Berger and C.-P. Yuan. Photon pair production with soft gluon resummation. *hep-ph/9712471*, 1997.
- [110] E. Pilon M. Werlen T. Binoth, J.P. Guillet. A full next to leading order study of direct photon pair production in hadronic collisions. *Eur. Phys. J. C16*, 311 [*hep-ph/9911340*], 2000.
- [111] L. Dixon Z. Bern and C. Schmidt. Isolating a light higgs boson from the diphoton background at the cern lhc. *Phys. Rev. D 66*, 074018, 2002.
- [112] M. Fontannaz L. Bourhis and J.P. Guillet. Quark and gluon fragmentation functions into photons. *Eur. Phys. J. C2*, 529-537, 1998.
- [113] P. Nadolsky C. Balázs, E.L. Berger and C.-P. Yuan. Calculation of prompt diphoton production cross sections at tevatron and lhc energies. *hep-ph/0704.0001*, 2007.
- [114] E.L. Berger P.M. Nadolsky, C. Balázs and C.-P. Yuan. *hep-ph/0702003*, 2007.
- [115] D.E. Soper J.C. Collins and G. Sterman. *Nucl. Phys. B 250*, 199, 1985.
- [116] D. de Florian S. Catani and M. Grazzini. Universality of non-leading logarithmic contributions in transverse-momentum distributions. *hep-ph/0008184*, 2000.
- [117] D. Graudenz M. Spira, A. Djouadi and P.M. Zerwas. *Nucl. Phys. B 453*, 17, 1995.
- [118] D. de Florian G. Bozzi, S. Catani and M. Grazzini. The  $q_t$  spectrum of the higgs boson at the lhc in qcd perturbation theory. *hep-ph/0302104*, 2003.
- [119] S. H T. Gleisberg. Sherpa 1.α, a proof-of-concept version.
- [120] S. Schumann S. Hoeche and F. Siegert. Hard photon production and matrix-element parton-shower merging. *Phys. Rev. D 81*, 034026, 2010.
- [121] G. Gustafson B. Andersson and C. Peterson. *Z. Phys C1*, 105.
- [122] S. Frixione and B.R. Webber. Matching nlo qcd computations and parton shower simulations. *JHEP 06*, 029, 2002.
- [123] P. Nason S. Frixione and G. Ridolfi. A positive-weight next-to-leading-order monte carlo for heavy flavour hadroproduction. *hep-ph/0707.3088*, 2007.
- [124] R. Kuhn S. Catani, F. Krauss and B.R. Webber. Qcd matrix elements + parton showers. *JHEP 0111*, 063, 2001.
- [125] S. H Matching parton showers and matrix elements.
- [126] S. H J. Alwall. Comparative study of various algorithms for the merging of parton showers and matrix elements in hadronic collisions.
- [127] W. Quayle K. Cranmer, B. Mellado and S.L. Wu. Application of k factors in the  $h \rightarrow zz^* \rightarrow 4l$  analysis at the lhc. *hep-ph/0307242*, 2003.
- [128] M. Dittmar M. Grazzini G. Davatz, G. Dissertori and F. Pauss. Effective k-factors for  $gg \rightarrow h \rightarrow ww \rightarrow l\nu l\nu$  at the lhc. *hep-ph/0402218*, 2004.
- [129] F. St G. Davatz. Combining monte carlo generators with next-to-next-to-leading order calculations : event reweighting for higgs boson production at the lhc.
- [130] The CDF Collaboration. Measurement of the cross section for prompt diphoton production with  $5.4 \text{ fb}^{-1}$  of cdf run ii data. *CDF note 10160*, 2010.
- [131] CDF Collaboration. Measurement of the cross section for prompt diphoton production in  $p\bar{p}$  collisions at  $\sqrt{s} = 1.96 \text{ tev}$ . *hep-ph/0412050*, 2005.
- [132] The D0 Collaboration. Measurement of direct photon pair production cross sections in  $p\bar{p}$  collisions at  $\sqrt{s} = 1.96 \text{ tev}$ . *hep-ex/1002.4917*, 2010.
- [133] D. Fortin D. Futyan and D. Giordano. Search for the standard model higgs boson in the two-electron and two-muon final state with cms. *CMS Note 2006/136*, 2006.
- [134] N. Chanon C. Charlot R. Clare M. Costa N. De Filippis A. Drozdetskiy C. Farrel F. Ferri D. Fortin S. Gascon-Shotkin N. Godinovic A. Graziano A. Korytov K. Lelas M. Lethuillier C. Mariotti G. Mitselmakher M. Musich A. Nikitenko Y. Pakhotin A. Pompili I. Puljak R. Salerno Y. Sirois D. Trocino S. Baffioni, C. Botta and R. Wilken. Search strategy for the higgs boson in the  $zz^{(*)}$  decay channel with the cms experiment. *CMS AN 2008/050*, 2008.

- [135] D. Bortoletto C. Botta C. Broutin P. Busson R. Casagrande N. Chanon C. Charlot M. Chen L. Coates M. Costa N. De Filippis A. Drozdetskiy S. Gascon-Shotkin S. Goldberg A. Graziano K. Johnson A. Korytov M. Kress A. Kumar C. Mariotti P. Merkel G. Mila G. Mitselmakher L. Nervo M. Nikolic C. Ochando Y. Pakhotin D. Piparo A. Pompili R. Plestina I. Puljak K. Ranjan R. Salerno G. Schott P. Sellers Y. Sirois N. Skhirtladze J. Smith M. Snowball F. St S. Baffioni, J. Bochenek. Search strategy for the higgs boson in the  $zz^{(*)}$  decay channel at  $\sqrt{s} = 10$  tev with the cms experiment.
- [136] Cms  $h \rightarrow zz^*$  analysis package on cvs. <http://cmssw.cvs.cern.ch/cgi-bin/cmssw.cgi/CMSSW/HiggsAnalysis/HiggsToZZ4Leptons/>.
- [137] F. Stoeckli and R. Gonzalez Suarez for the CMS Higgs Working-Group. Sm higgs production cross-section and branching-ratios at 10 tev and 7 tev. <http://wwweth.cern.ch/HiggsCrossSections/>.
- [138] P. Bartalini R. Cavanaugh-A. Drozdetskiy A. Korytov G. Mitselmakher Yu. Pakhotin B. Scurlock S. Abdullin, D. Acosta and A. Sherstnev. Sensitivity of the muon isolation cut efficiency to the underlying event uncertainties. *CMS NOTE 2006/033*, 2006.
- [139] P. Golonka and Z. Was. Photos monte carlo : a precision tool for qed corrections in z and w decays. *CERN-PH-TH/2005-091, hep-ph/0506026*, 2005.
- [140] L. Agostino and M. Pieri. High level trigger selection of electrons and photons. *CMS NOTE 2006/078*, 2006.
- [141] T. Hebbeker P. Biallass and K. Hoepfner. Simulation of cosmic muons and comparison with data from the cosmic challenge using drift tube chambers. *CMS NOTE 2007/024*, 2007.
- [142] P. Biallass and T. Hebbeker. Improved parametrization of the cosmic muon flux for the generator cmcscgen. *CMS IN 2007/033*, 2007.
- [143] S. Rahatlou D. Franci and D. del Re. Studies for photons and neutral pions identification in the ecal barrel region. *CMS AN-2008/075*, 2008.
- [144] K. Armour M. Pieri and J.G. Branson. Distinguishing isolated photons from jets. *CMS NOTE 2006/007*.
- [145] R.A. Fischer. The use of multiple measures in taxonomic problems. *Ann. Eugenics 7, 179*, 1936.
- [146] A.W.F Edwards. Likelihood. *Cambridge University Press, Cambridge (expanded edition, 1992, Johns Hopkins University Press, Baltimore)*, 1992.
- [147] David Kriesel. *A Brief Introduction to Neural Networks*. 2007. available at <http://www.dkriesel.com>.
- [148] J. Zhu Y. Liu I. Stancu B.P. Roe, H.-J. Yang and G. McGregor. Boosted decision trees as an alternative to artificial neural networks for particle identification. *physics/0408124*, 2004.
- [149] A. H`Tmva users guide.
- [150] W.S. McCulloch J.Y. Lettvin, H.R. Maturana and W.H. Pitts. What the frog's eye tells the frog's brain. *Proc. Inst. Radio Engr. 47, 1940-1951*.
- [151] G. Anagnostou. Discrimination between converted photons and neutral pions. *CMS NOTE IN-2007/032*, 2007.
- [152] Z. Zhang. *Sensitivity study of HWW coupling and  $H \rightarrow Z\gamma$  at CMS*. PhD thesis, Graduate University of Chinese Academy of Sciences, Beijing, China, 2009.
- [153] A. Kyriakis K. Karafasoulis and D. Maletic. Neutral pion rejection for isolated and unconverted photon candidates using cms ecal and preshower detector. *CMS AN-2008/063*, 2008.
- [154] M. Yang J. Tao and G. M. Chen. Gamma/pi0 discrimination : L3 method for unconverted case in ecal barrel. *DPG/PH egamma meeting, 19 janvier 2009*.
- [155] N. Chanon. Discrimination  $\gamma/\pi^0$  pour la recherche du boson de higgs dans le canal  $h \rightarrow \gamma\gamma$  dans l'expérience cms. *Proceeding des Journées de Rencontre Jeunes Chercheurs. A paraître*, 2009.
- [156] V. Breton et al. Application of neural networks and ceccular automata to interpretation of calorimeter data. *Nuclear Instrumentation and Methods in Physics Research A362, 478*, 1995.

- [157] The D0 Collaboration. Measurement of the isolated photon cross section in pp collisions at  $\sqrt{s} = 1.96$  tev. *Phys. Lett. B* 639, 151-158, 2006.
- [158] The CDF Collaboration. Measurement of the inclusive isolated prompt photon cross section in pp collisions at  $\sqrt{s} = 1.96$  tev using the cdf detector. *hep-ph/0910.3623*, 2009.
- [159] B. Choudhary P. Musella C.M. Kuo S.W. Li D. Mekterovic S.S. Yu R.S. Lu V. Chetluru V. Gaultney S.L.L. Linn Y. Kim Y.J. Lee A. Debenedetti R. Rusack T. Koldberg N. Marinelli C. Lin S. Ganjour, S. Ahuja and M. Anderson. Measurement of inclusive photon spectra in pp collisions at  $\sqrt{s} = 7$  tev using cms detector at lhc. *CMS AN-2010-114*, 2010.
- [160] J. Ph. Guillet S. Catani, M. Fontannaz and E. Pilon. Cross section of isolated prompt photons in hadron-hadron collisions. *JHEP* 0205, 028, 2002.
- [161] J.Ph. Guillet E. Pilon P. Aurenche, M. Fontannaz and M. Werlen. A new critical study of photon production in hadronic collisions. *Phys.Rev. D* 73, 094007, 2006.
- [162] R.Barlow and C.Beeston. *Comp. Phys. Comm.* 77, 219, 1993.
- [163] A. Nappi. A pitfall in the use of extended likelihood for fitting fractions of pure samples in mixed samples. *Comput. Phys. Commun.* 180, 269, 2009.
- [164] S. Frixione. Isolated photons in perturbative qcd. *Phys. Lett. B* 429, 369.
- [165] V. Bartsch and G. Quast. Expected signal observability at future experiments. *CMS NOTE 2005/004*, 2005.
- [166] The D0 Collaboration. Search for resonant diphoton production with the d0 detector. *Phys. Rev. Lett.* 102, 231801, 2009.
- [167] Workshop on confidence limits, proceedings. *CERN 2000-005*, 2000.
- [168] A.L. Read. Presentation of search results : the cls technique. *J. Phys. G : Nucl. Part. Phys.* 28 2693, 2002.
- [169] T. Junk. Confidence level computation for combining searches with small statistics. *CARLETON/OPAL PHYS 99-01*, 1999.
- [170] S. de Visscher R. Frederix M. Herquet F. Maltoni T. Plehn D.L. Rainwater H. Alwall, P. Demin and T. Stelzer. Madgraph/madevent v4 : The new web generation. *JHEP* 0709, 028, 2007.
- [171] M. B. Voloshin M. A. Shifman, A. I. Vainshtein and V. I. Zakharov. Low-energy theorems for higgs boson couplings to photons. *Sov. J. Nucl. Phys., vol. 30, 711-716*, 1979.
- [172] B. A. Kniehl and M. Spira. Low-energy theorems in higgs physics. *Z. Phys. C69, 77-88*, 1995.
- [173] S. Dawson and R. Kauffman. Qcd corrections to higgs boson production : nonleading terms in the heavy quark limit. *Phys. Rev. D49, 2298-2309*, 1994.
- [174] Madgraph version 4. <http://madgraph.hep.uiuc.edu/index.html>.
- [175] E.W.N. Glover and A.G. Morgan. Measuring the photon fragmentation function at lep. *Z. Phys. C* 62, 311-321, 1994.

NOM : CHANON	DATE de SOUTENANCE
Prénoms : Nicolas	6 octobre 2010

**TITRE : Observation des photons directs dans les premières données et préparation à la recherche du boson de Higgs dans l'expérience CMS au LHC (CERN)**

Numéro d'ordre : 194-2010

DIPLOME DE DOCT.	DOCTEUR- INGENIEUR	DOCTORAT D'ETAT	DOCTORAT DE 3e CYCLE	Spécialité : Physique des Particules
<b>X</b>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	

Cote B.I.U. - Lyon : T 50/210/19 / et bis

CLASSE :

**RESUME :**

Le LHC (Large Hadron Collider) fournit aux expériences du CERN (Laboratoire Européen pour la Physique des Particules) des collisions proton-proton avec une énergie de 7 TeV dans le centre de masse depuis fin Mars 2010. Le LHC a en particulier été conçu pour permettre la recherche du boson de Higgs, particule prédite par le modèle standard encore jamais observée à ce jour, dans toute la gamme de masse où il est attendu. Ce travail de thèse est une contribution à la recherche du boson de Higgs dans CMS (Compact Muon Solenoid), l'un des quatre grands détecteurs placés auprès du LHC, et développe plusieurs outils qui permettent la mesure des bruits de fonds et l'amélioration du potentiel de découverte.

Un nouvel outil de récupération des photons émis par les leptons dans l'état final de la désintégration  $H \rightarrow ZZ^{(*)} \rightarrow 4\ell$  ( $\ell = e, \mu$ ) a été développé dans cette thèse. Cette méthode permet la récupération d'un nombre variable de photons par événements, donne une meilleure performance que la méthode précédemment utilisée dans CMS et permet l'amélioration de la résolution sur la masse des bosons  $Z^0$  et du boson de Higgs, ainsi qu'un gain de 5% sur la signification d'une observation du boson de Higgs dans ce canal.

La deuxième partie de cette thèse traite de l'étude des bruits de fond et de la recherche d'un boson de Higgs léger ( $110 < m_H < 140$  GeV) dans le canal  $H \rightarrow \gamma\gamma$ . Un nouvel outil de discrimination  $\gamma/\pi^0$  à l'aide d'un réseau de neurone a été mis au point pour le rejet des photons provenant de la désintégration des  $\pi^0$  produits copieusement dans les jets de QCD. Les performances du réseau de neurone sont examinées dans le détail. Le réseau de neurone est alors utilisé comme variable "template" permettant la mesure du processus  $\gamma+X$  à partir des données avec  $10 \text{ nb}^{-1}$  de luminosité intégrée dans CMS. La mesure du processus  $\gamma\gamma+X$  est aussi préparée à partir de la simulation dans l'hypothèse d'une luminosité intégrée de  $10 \text{ pb}^{-1}$ .

La prise en compte des effets cinématiques aux ordres supérieurs, nécessaire pour la prédiction la plus précise possible du signal  $H \rightarrow \gamma\gamma$  et du bruit de fond, est effectuée dans cette thèse par la méthode de repondération, pour le processus  $gg \rightarrow H \rightarrow \gamma\gamma$  au NNLO et pour la première fois pour le processus  $\gamma\gamma+X$  au NLO, dans les deux cas à l'aide de distributions doublement différentielles. Les outils de repondération et de discrimination  $\gamma/\pi^0$  sont ensuite intégrés dans l'analyse pour améliorer la sensibilité de CMS à la recherche du boson de Higgs dans le canal  $H \rightarrow \gamma\gamma$  dans le modèle standard et au-delà, grâce à une paramétrisation effective développée par des phénoménologues avec lesquels nous avons travaillé.

**MOTS-CLES :** Physique des hautes énergies, collisions proton-proton, expérience CMS au LHC, calorimètre électromagnétique (ECAL), photons, discrimination photon/pi0 avec un réseau de neurones, processus de photon inclusif et diphoton, recherche du boson de Higgs, effets de QCD aux ordres supérieurs, repondration, modèles BSM

Directeurs de recherches : Suzanne Gascon-Shotkin et Aldo Deandrea

Composition du jury : G. Dissertori - G. Unal - B. Ille - J.-P. Guillet - R. Granier de Cassagnac

268 pages