

SIG-KBS/KBSE研究会
**大規模Webアーカイブの
時空間分析とその実際**

東京大学 生産技術研究所
戦略情報融合国際研究センター
豊田正史

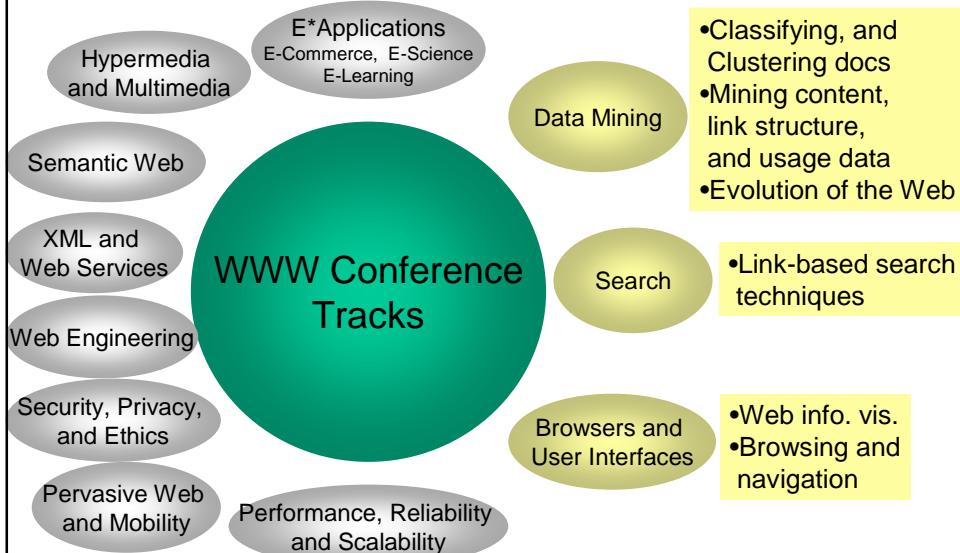
自己紹介

- 1996年 東京工業大学 情報理工学研究科
数理・計算科学専攻修了
- 1999年 東京工業大学 情報理工学研究科
数理・計算科学専攻 博士(理学)号取得
ズームを用いた閲覧・編集・検索ユーザインタフェース
- 同年 東京大学生産技術研究所ポスドク
- 2004年 同特任助教授
- 2006年 同助教授
主にWebに関する研究に従事

研究対象としてのWeb

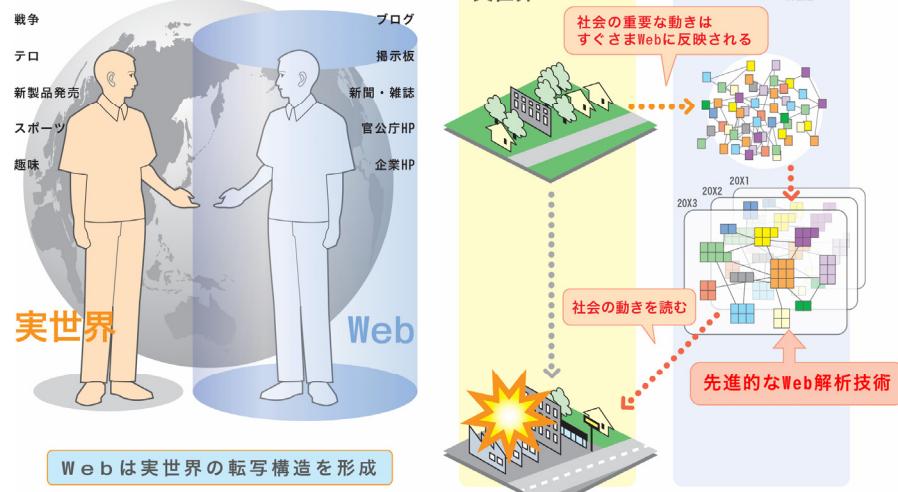
- 膨大な文書集合
 - 200億を超えるテキスト・画像・動画(Yahoo!発表2005/8)
 - 自然言語処理、情報検索、情報抽出、テキストマイニング
- 膨大なグラフ構造
 - 文書=ノード、リンク=エッジの膨大かつ疎な有向グラフ
 - グラフ理論(次数、直径、進化モデル)、情報検索への応用、グラフマイニング
- 動的
 - 持続的な成長(サーバ数は2000年から年平均36%増加 米Netcraft社)
無数の著者が日々文書を生成する一方、消滅する文書も多い。
 - 時系列解析(成長率、内容の変化、構造の変化)、社会学
- サービス提供の場
 - 広告、通信販売、メール、ブログ、写真共有、企業間取引
 - XML、Webサービス、セキュリティ、経済学

Webに関する研究領域と 豊田の興味



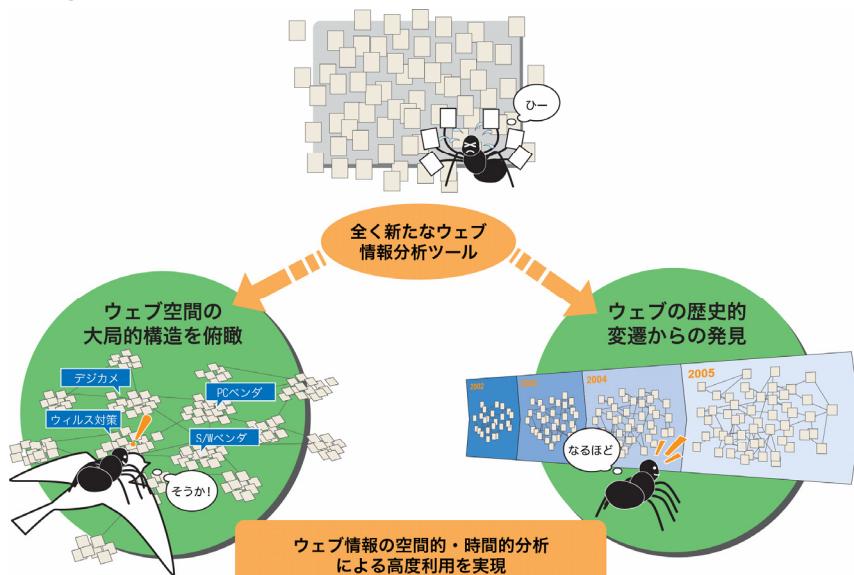
実社会の射影としてのウェブ

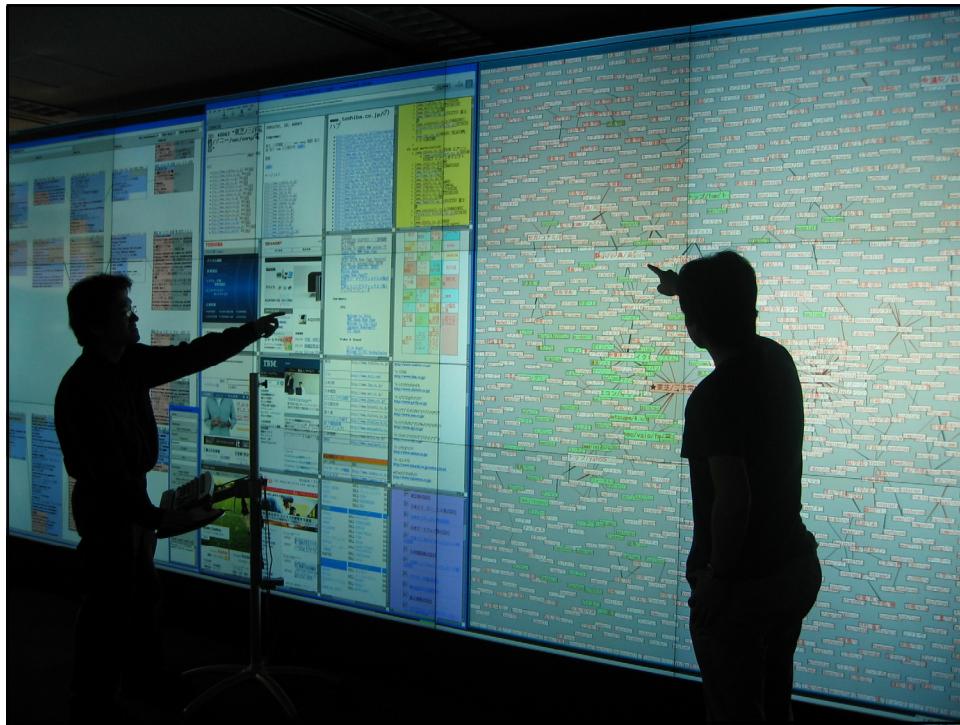
e-Society
文部科学省リーディングプロジェクト



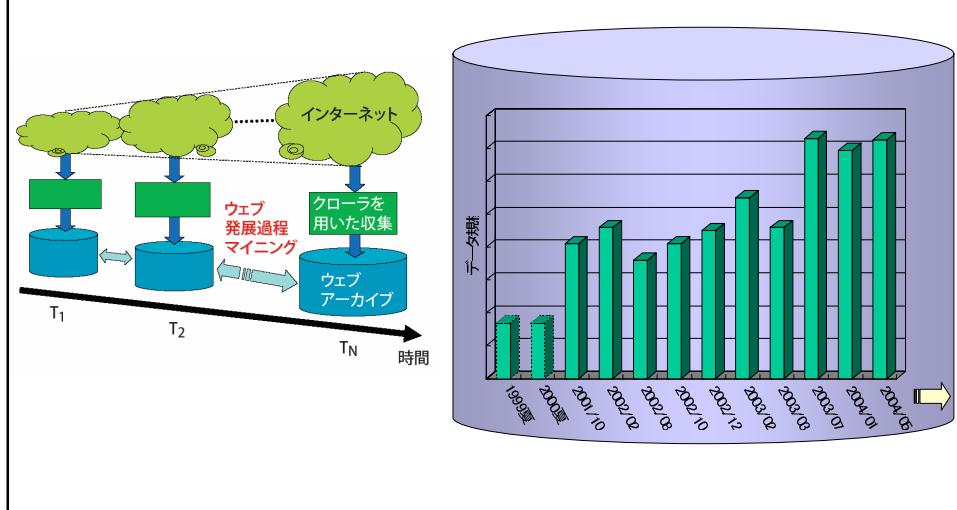
目的: ウェブ情報の高度利用システムの構築(WEBの時空間解析)

e-Society
文部科学省リーディングプロジェクト



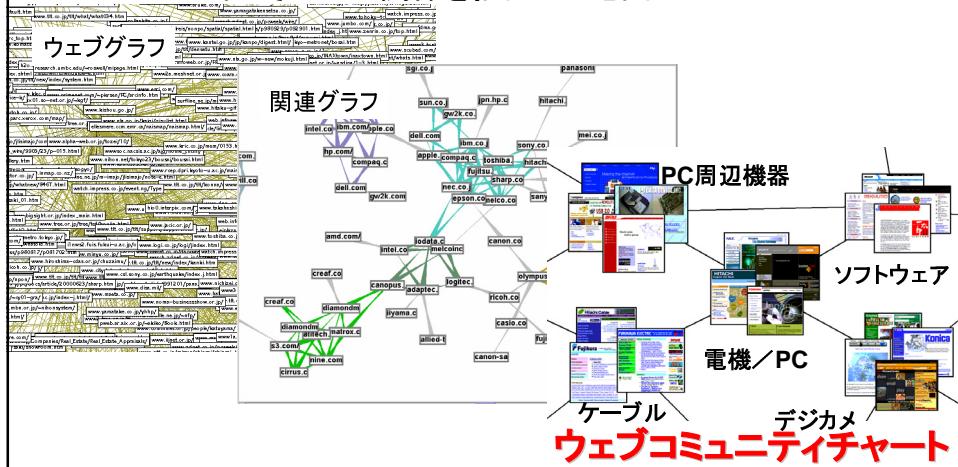


ウェブ時空間解析のための アーカイブ基盤構築



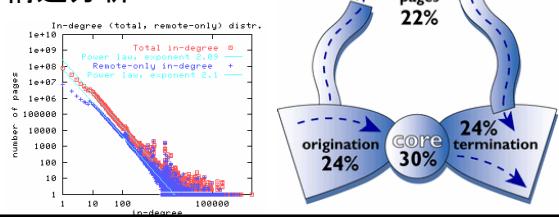
ウェブ空間の構造俯瞰 ウェブコミュニティチャート[ACM Hypertext 2001]

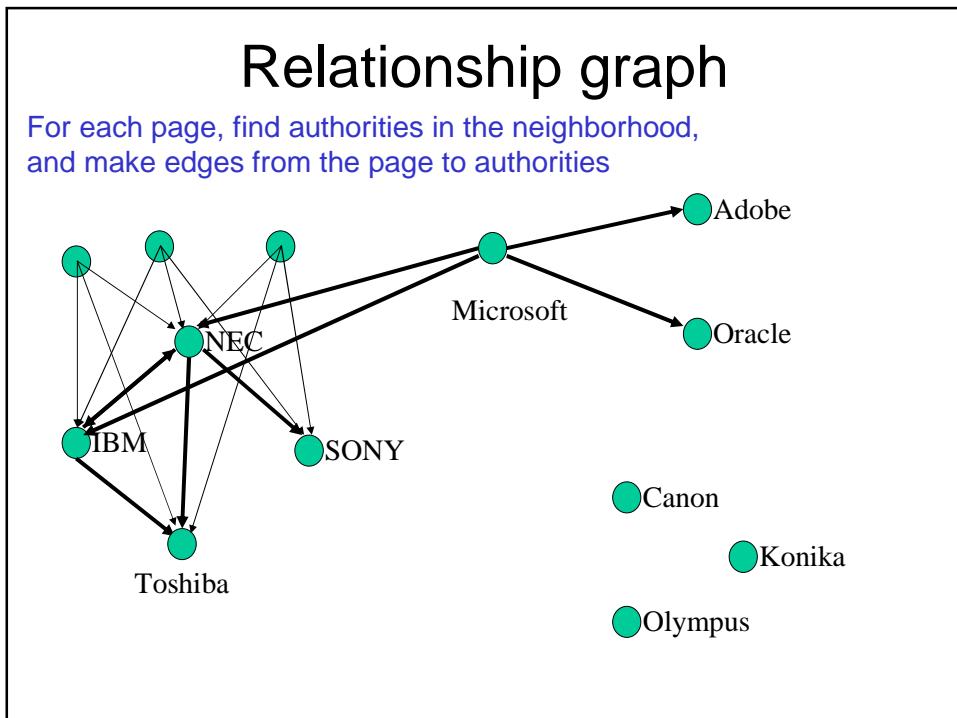
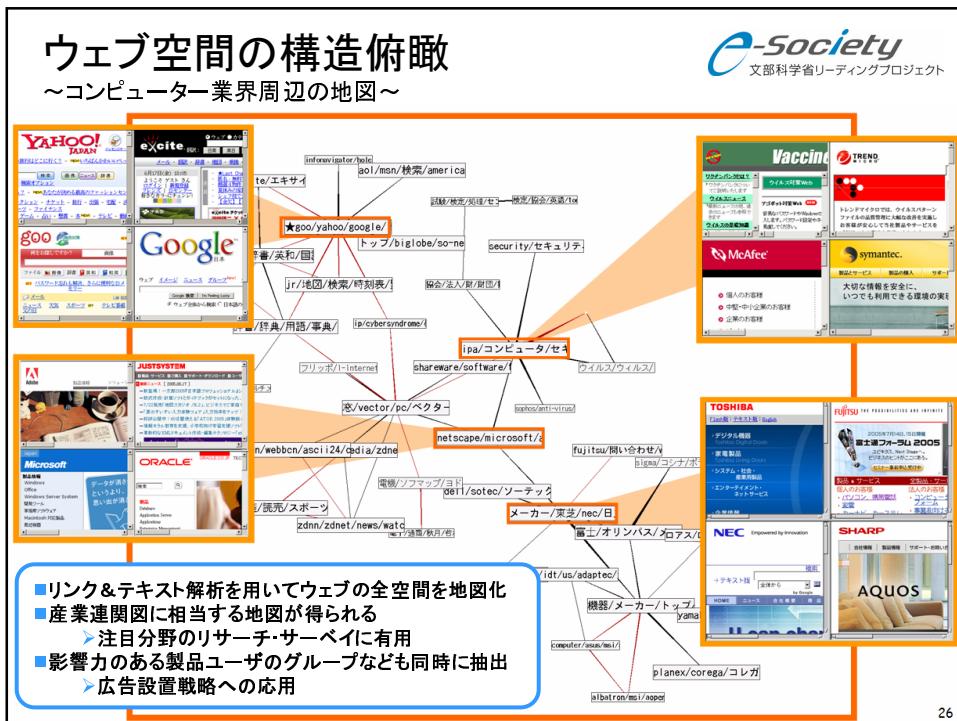
- ある話題に関する有用なページの集合はウェブグラフ上で稠密な構造を持つ(ウェブコミュニティ)
- 全コミュニティとそれらの関係を抽出して地図化



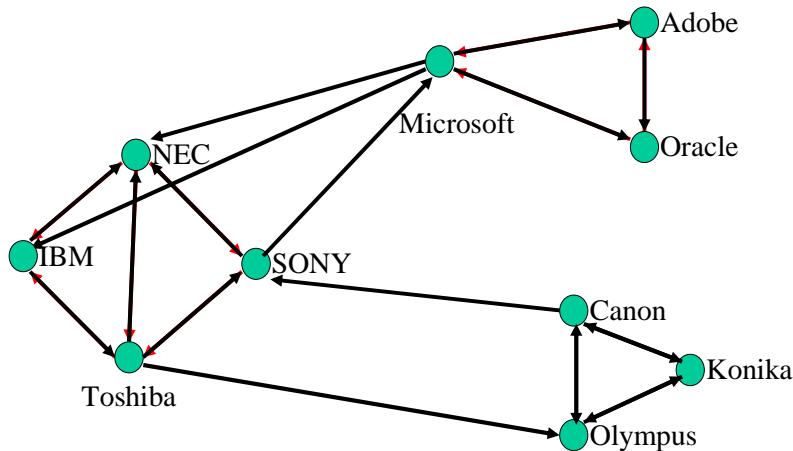
関連研究

- HITS [Kleinberg, 1997]
 - ハブとオーソリティから構成されるウェブコミュニティを抽出
- Trawling [Kumar et al, 1999]
 - 全ウェブコミュニティを列挙、KB化
- Graph Structure in the Web [Broder et al, 2000]
 - ウェブ全体のグラフ構造分析



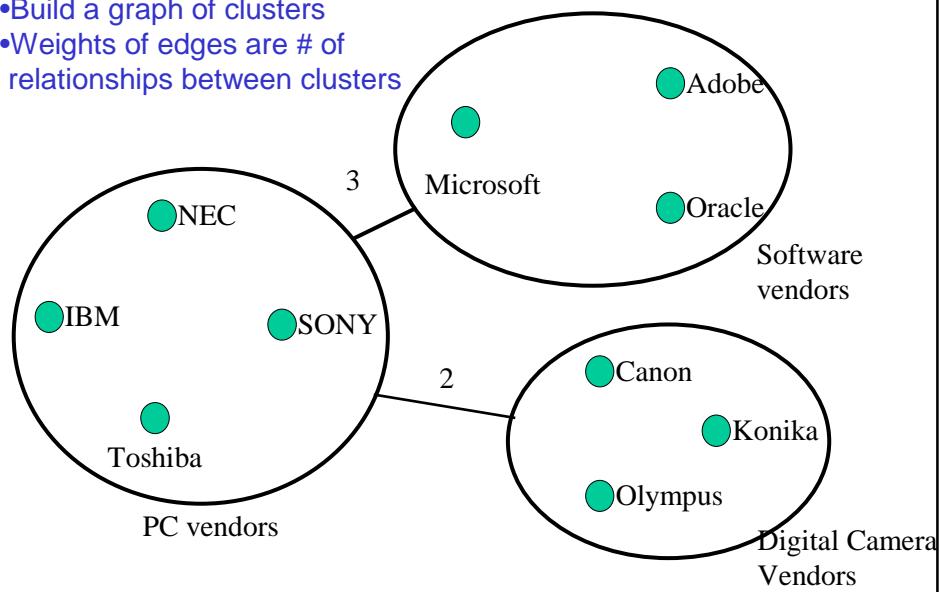


Relationship Graph



Web Community Chart

- Build a graph of clusters
- Weights of edges are # of relationships between clusters

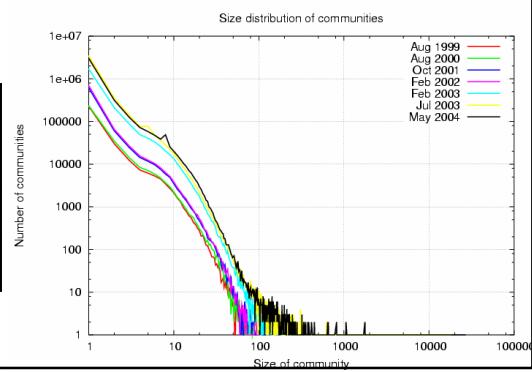


コミュニティチャート生成実験

- データセット
 - 日本中のウェブサイトからロボットを用いて収集したアーカイブ
1999~2004の7回分
- チャート生成
 - 3サイト以上からリンクを受けているページをシードとして使用
 - 上位10位のオーバーライドから関連グラフを作成
- サイズの分布
 - べき乗則に従う。SCC,WCCのサイズ分布と同様

データセット詳細

Year	#Pages	#seeds	#comms
1999/8	17M	671K	83K
2000/8	17M	741K	94K
2001/10	40M	1431K	158K
2002/2	45M	1583K	171K
2003/2	66M	4646K	554K
2003/7	97M	7870K	874K
2004/5	96M	8192K	849K



実験環境

- クローラ: 残念ながら企業秘密
- 解析系: Itanium2サーバ (8 CPU, 128GB Memory)
- 処理時間:
 - スナップショットのスキャンに1日
 - もろもろのデータベース作成に2日~3日
 - リンクDB (URL \leftrightarrow ID, ID \Rightarrow <OutLinks><InLinks>)
 - 2004/05時点では、ID \Rightarrow <OutLinks><InLinks>のDBは2.6Gノード(1999からの延べURL数に相当)、4.5Gリンクを、30GB程度に圧縮してオンコアDB化
 - タイトル、アンカーDB (URL \Rightarrow Title, URL \Rightarrow <AnchorTexts>)
 - チャート作成に半日

コミュニティチャートとYahoo!の比較 [吉田 2003]

◆共有URL数(2002年のデータを使用)

Yahoo!の重複を取り除いたURL	177,000
ウェブコミュニティチャートのURL	1,000,000
共有URL	81,000

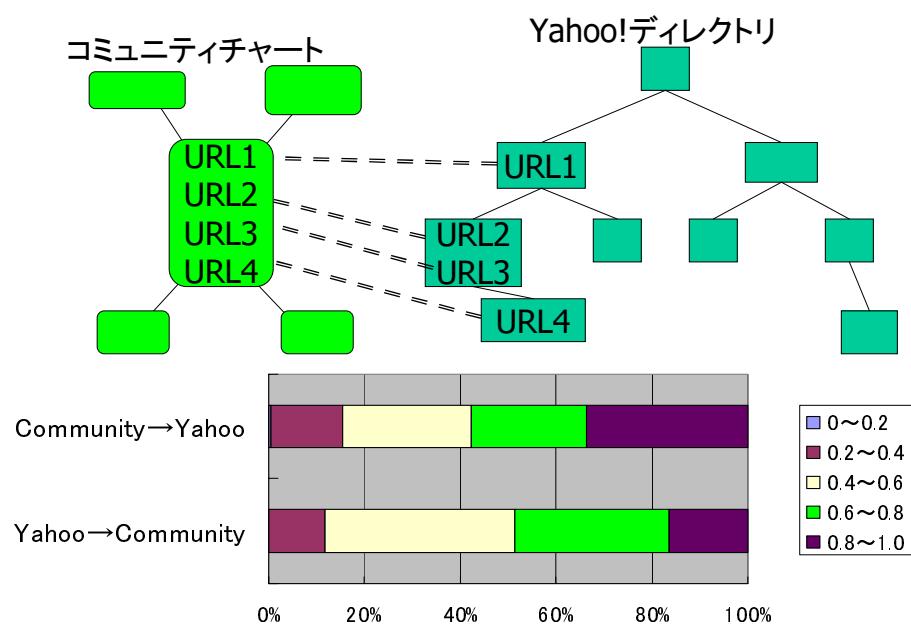
◆比較対象とするコミュニティとディレクトリ

◆共有部分内においてURL数5以上のもの

◆4079コミュニティ(33930URL 平均8.13)

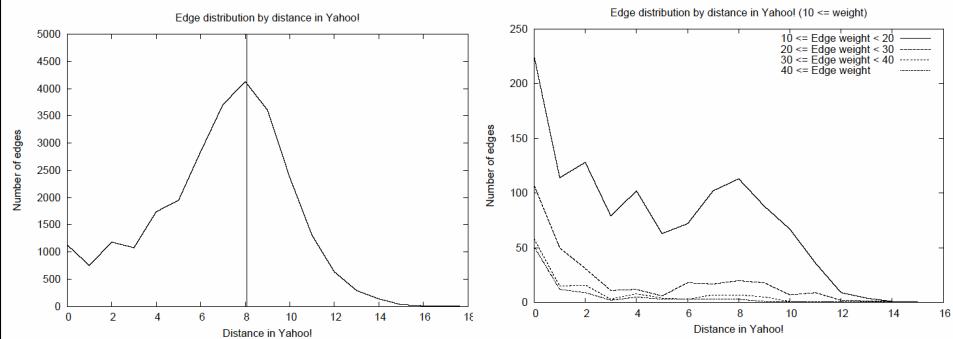
◆4965ディレクトリ(63757URL 平均12.84)

チャートとYahoo!の類似度



コミュニティ間の関速度

- 関速度の高い辺は近いカテゴリを結んでいる



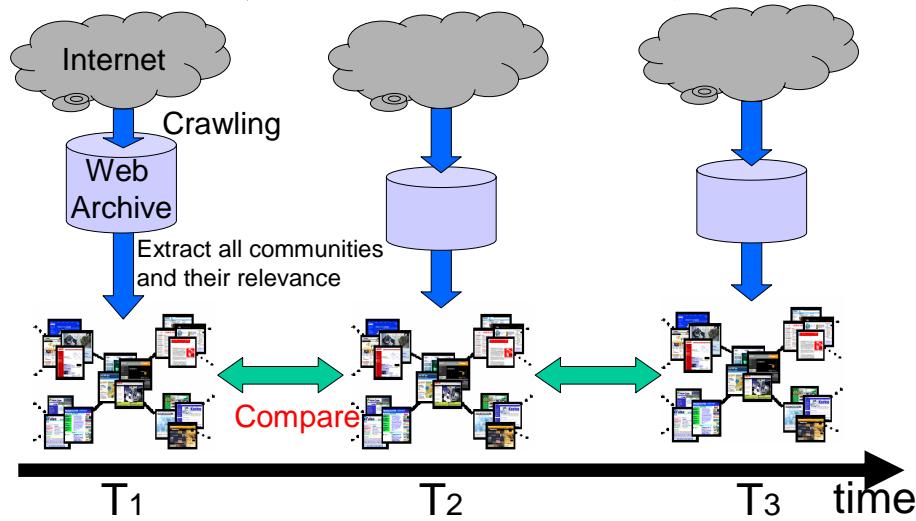
応用研究

- 地球環境ポータル構築の試み[菊池(高知大)]
 - DEWS2001
- ジェンダー関連ポータルサイト構築[増永,小山(お茶女)]
 - 重点研究「グローバル化とジェンダー規範」2000~2001
- Web Community Browser [福地(東工大)]
 - DEWS2002, WISS2002, FIT2002
- ウェブディレクトリとの比較[吉田]
 - DEWS2003, TOD22
- 大域ウェブアクセスログ解析[大塚]
 - TOD20, DEXA2004
- リンク解析による全文検索エンジンの精度向上[RICOH]
 - NTCIR3 Web

ウェブの時系列分析

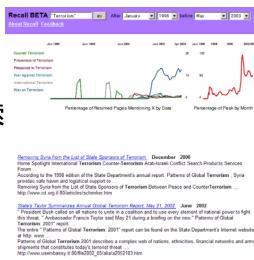
[ACM Hypertext 03]

- 定期的にウェブを大規模収集
- トピックの発展過程をコミュニティを通して観察



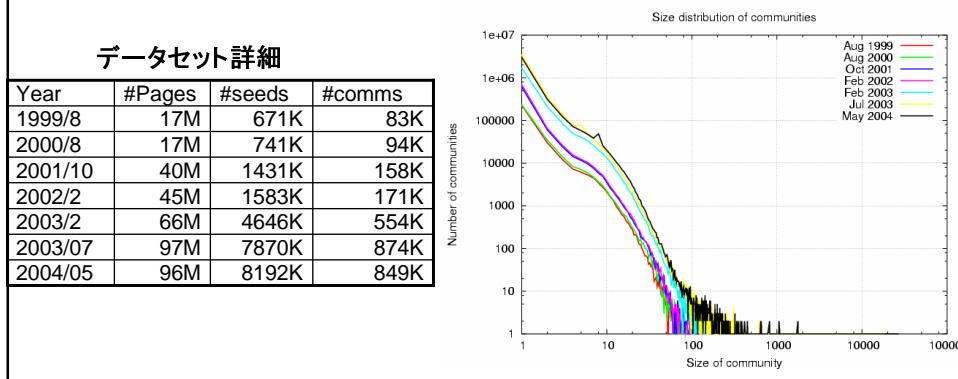
関連研究

- A Large-Scale Study of the Evolution of Web Pages [Fetterly et al 2003]
 - 1.5億ページを毎週1回11週間収集
 - 各ページの変化度合いを測定
- What's New on the Web? [Ntoulas et al 2004]
 - 著名な150サイトを取り尽す収集を週1回、1年間実施
 - 新規出現ページ・コンテンツの測定
- Recall (Internet Archive) [Patterson]
 - RecallはInternet Archiveの全文検索エンジン(現在停止中)
 - '96～'03までに収集した110億ページを索
 - 関連キーワードの出現頻度グラフを表示



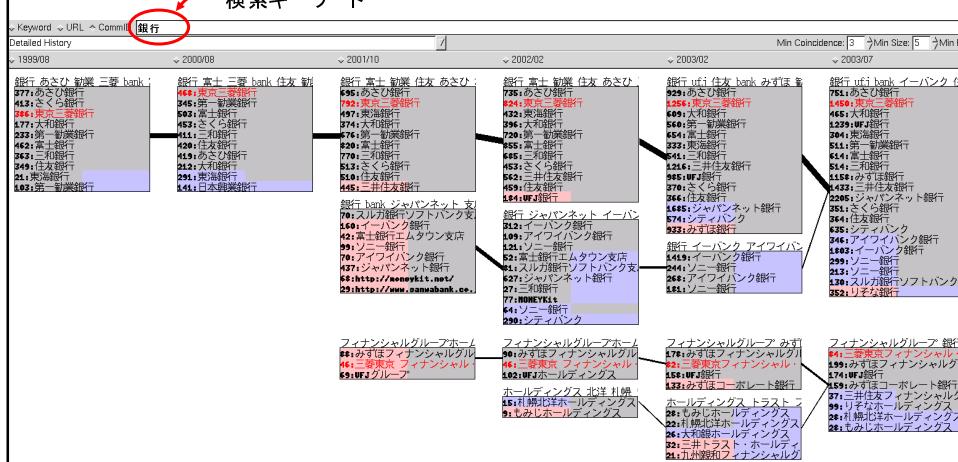
データセット

- 日本中のウェブサイトからロボットを用いて収集したアーカイブ
1999~2004の7回分

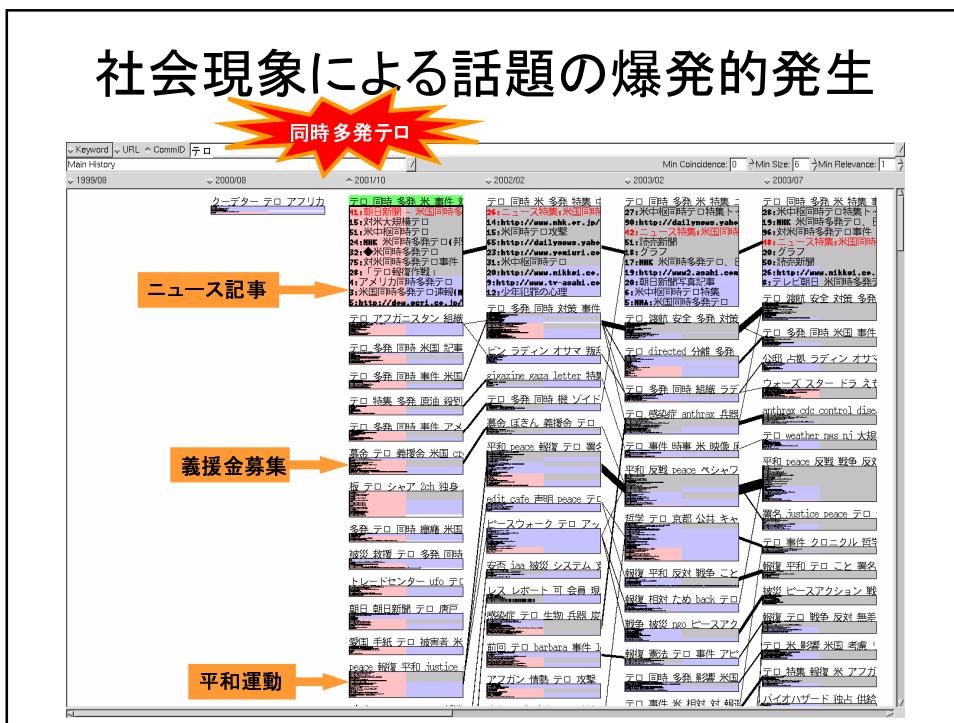


銀行業界の変遷

- インターネット銀行の出現と世間への浸透
- 合併した銀行の出現：三井住友、UFJ、みずほ、りそな

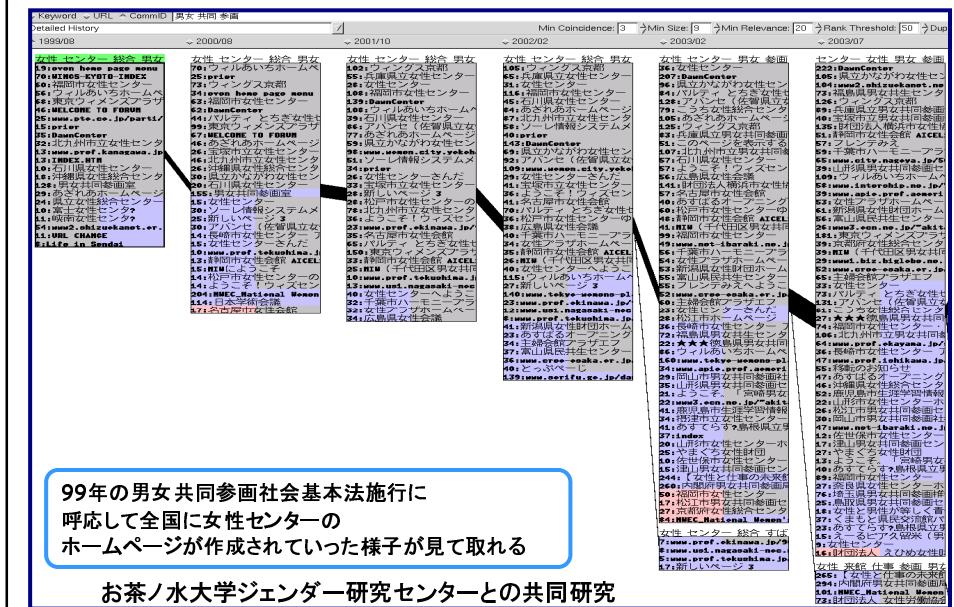


社会現象による話題の爆発的発生



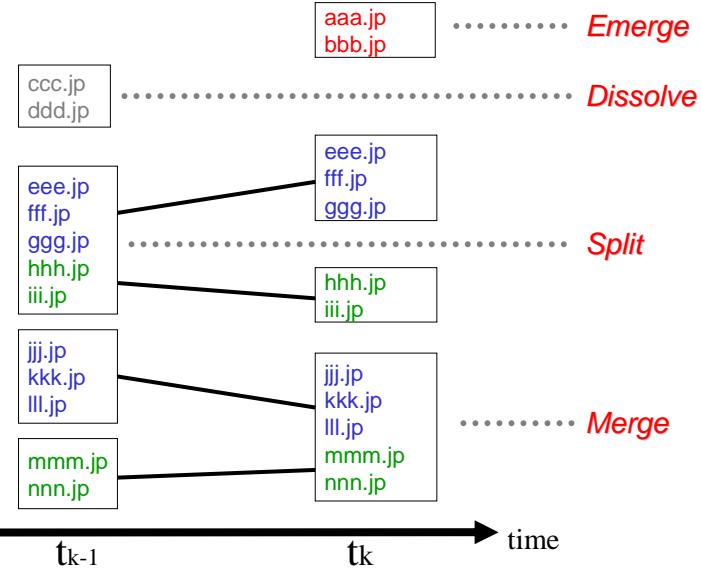
社会学への応用: ジェンダー活動の成長

e-Society
文部科学省リーディングプロジェクト



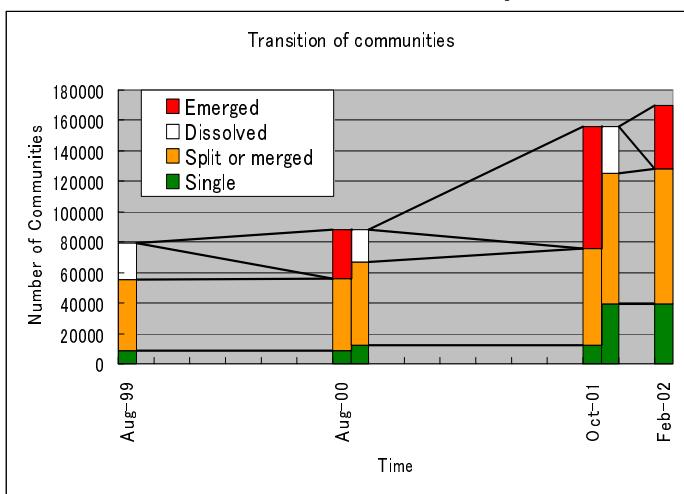
Types of Changes

Changes are detected by comparing neighboring charts



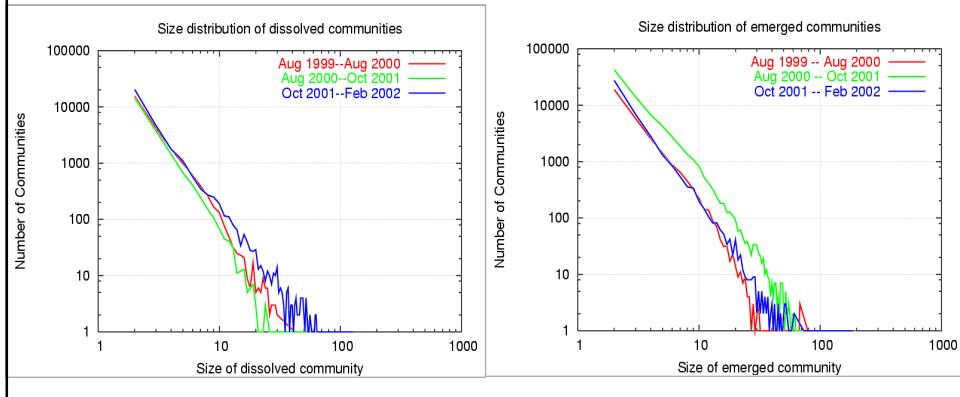
Types of Changes

- Structure of communities changes dynamically
- How the size distribution is kept unchanged?



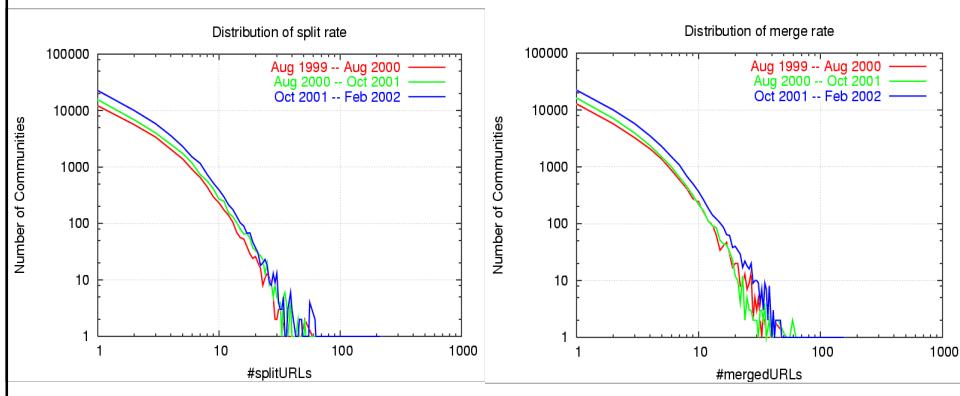
Emerged and Dissolved Communities

- Both size distributions follow the power-law
- Both exponents are greater than ones in size distribution of all communities



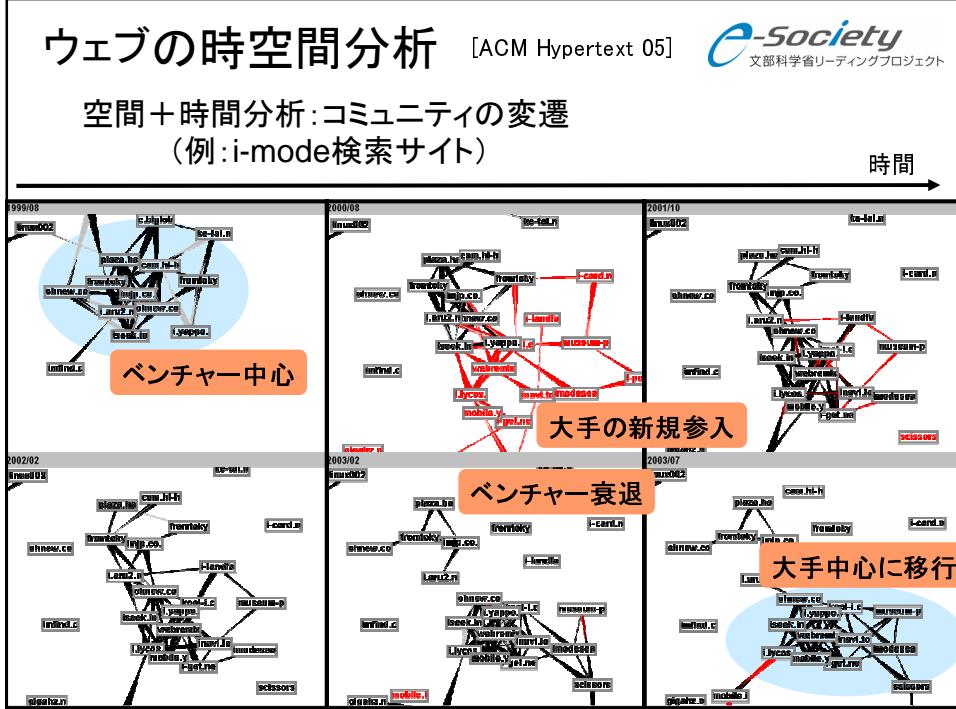
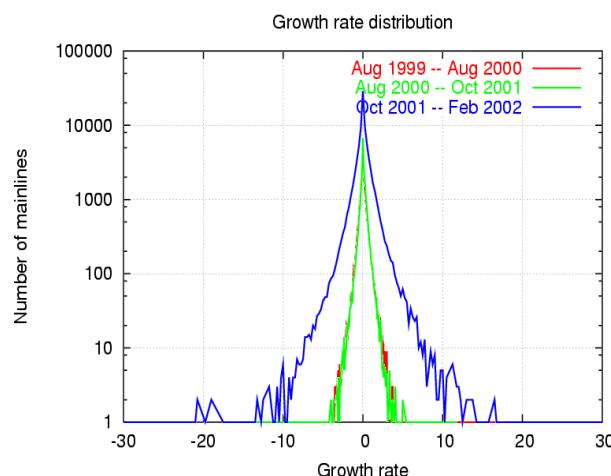
Split and Merged Communities

- # of split and merged URLs also follow the power-law, and have clear symmetry



Grown and Shrunken Communities

- Growth rate have clear y-axis symmetry



最近の成果と今後の展開

- 検索エンジンスパムの分析
 - 人工的な稠密構造による検索エンジン騙しの傾向分析[小野. DEWS2006]
- 不安定なアーカイブからの新規ページ抽出法
 - [Toyoda. WWW2006]
- より連續的な構造進化の解析
 - 収集間隔の短縮(月、週、毎日程度まで)
- 自然言語処理の導入による各手法の発展
 - コミュニティ抽出の精度向上
 - アーカイブ全文検索を用いたより詳細な話題伝播分析
- 社会学、マーケティングへの応用
 - お茶の水女子大ジェンダー研との研究
 - 電通・専修大経営学部との協力開始