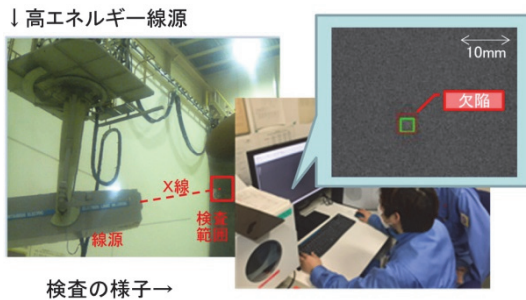


溶接部位のX線画像における高精度欠陥検出技術の開発

Development of High Accuracy Welding Defect Detection Technique for X-ray Images



松本 知浩*¹
Tomohiro Matsumoto

青山 慶子*²
Keiko Aoyama

五島 康二*³
Koji Goto

梶川 敬介*²
Keisuke Kajikawa

杉本 喜一*⁴
Kiichi Sugimoto

岩田 健司*⁵
Kenji Iwata

原子力発電プラントの蒸気発生器の溶接部非破壊検査では、高エネルギー線源とX線フィルムを用いた放射線透過試験 (RT:Radiographic Testing)を行う。蒸気発生器の溶接部は厚肉であるため、RT 画像での欠陥部位のコントラストは低く、検査員には溶接欠陥を識別する高いスキルと長時間の集中力が求められ、大きな負担となっている。そこで当社は、国立研究開発法人産業技術総合研究所と共同で、コントラストが低い欠陥を高精度に検出する画像処理アルゴリズムを開発した。当開発技術を、検査員の識別支援を行うための検査支援システムに適用する予定である。

1. はじめに

蒸気発生器の RT では、溶接継手に発生する、ポロシティ(小さな空洞)、溶け込み不良、スラグ(鉾さい)巻き込みといった欠陥が検出対象となる。図1に RT の模式図を示す。本検査は、厚さ100mm 程度の厚い金属材料を対象としており、RT 画像での欠陥部位のコントラストは低い。また、線源に起因するノイズ、量子モトル、フィルムの粒状性など、様々なノイズが発生し⁽¹⁾、視認性が悪い。このため、検査に高いスキルが必要である上に長時間の集中が求められ、検査員への負担が大きい。このような理由から、検査員を支援する自動欠陥検出技術が求められているが、モルフォロジー演算などの従来の画像処理アルゴリズムでは欠陥を高い精度で検出することが難しい。近年では、人間が判定に用いる特徴を深層学習によって抽出し、自動的に対象物検出を行う機械学習技術が実用されるようになったが、実際の現場では、学習に十分な欠陥部位の実サンプルを揃えられないため、適用が困難である。

我々は、RT 画像からコントラストが低い欠陥部位の識別に有効な画像特徴を抽出するため、ノイズに頑健な統計的リーチ特徴量 (SRF:Statistical Reach Feature)⁽²⁾と、高次局所自己相関特徴量 (HLAC:Higher-order Local Auto-Correlation)⁽³⁾の2つの特徴量を採用した。欠陥を含むサンプル画像は少数しか得られないため、欠陥の形状並びにノイズを模擬的表現した欠陥部位の画像を生成し、学習サンプルとした。その上で、機械学習手法の一つであるサポートベクターマシン (SVM:Support Vector Machine)による欠陥識別器を構築し、高精度で欠陥検出が可能なシステムを開発した。

*1 ICTソリューション本部 CIS部

*2 総合研究所 電気・応用物理研究部

*3 原子力セグメント 品質保証部

*4 ICTソリューション本部 CIS部 主席技師 技術士(情報工学部門)

*5 産業技術総合研究所 情報・人間工学領域 博士(工学)




図1 溶接部の RT の概要(左)と RT フィルム画像(右)

2. 欠陥の特徴量抽出

2.1 統計的リーチ特徴量 SRF

統計的リーチ特徴量 SRF は、画像中の着目点の明度 I_o と周辺領域 C との明度の大小関係を統計的に表現する特徴量である。具体的には、着目点よりも明度が大きい周辺領域の点数の割合を特徴量としたものであり、今回は式①、②のように定義した。 N_c は周辺領域 C に含まれる画素数、 I_i は周辺領域 C における i 番目の画素の明度を表す。

$$SRF = \frac{1}{N_c} \sum_{i=1, \dots, N_c} \rho(i)$$

$$\rho(i) = \begin{cases} 1 & \text{if } I_i - I_o > 0 \\ 0 & \text{otherwise} \end{cases}$$

SRF が 0.5 よりも大きければ着目点が周辺領域よりも明度が低く、0.5 よりも小さければ周辺よりも明度が高いと判定できる。図2に SRF の模式図を示す。ここでは、着目点を中心に半径 R の円周上の点として周辺領域 C を定義した。欠陥部位のように周囲領域より明度が高い場合、SRF は 0.5 より小さい値となることがわかる。

SRF を RT 画像の全画素にて算出し、固定しきい値にて2値化することにより、周辺領域に対して相対的に明度が異なればコントラストが低い欠陥部位でも、強調された画像を得ることができる(以下、これを SRF 画像と呼ぶ)。溶接部の空洞欠陥の場合、図3に示すように、着目点を中心とする円形を周辺領域と設定して、SRF を算出し、2値化した結果、図4のように欠陥部位を強調した2値画像を得ることができた。周辺よりも十分明度が高いことを判定するためにしきい値は 0.25 を採用した。

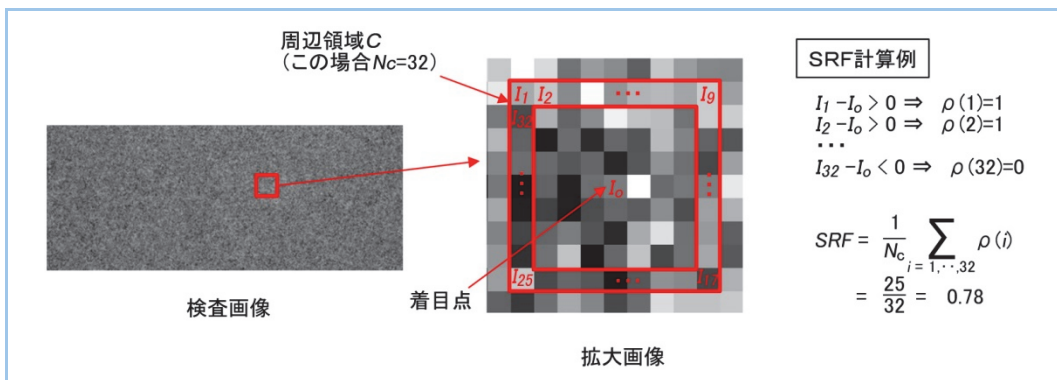


図2 SRF 模式図

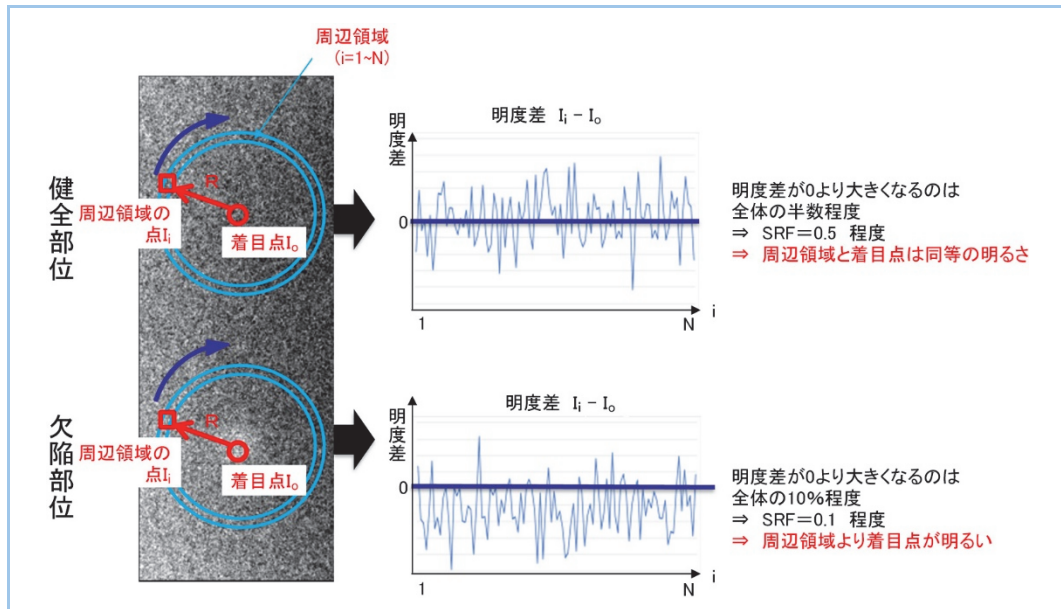


図3 溶接部の空洞欠陥に対するSRF




図4 入力画像(左)とSRFによって強調された欠陥像(右)

2.2 高次局所自己相関特徴量 HLAC

図4の SRF 画像は、RT 画像特有の量子モトル等の影響により、健全部位においてもまだら状の様子が現れている。そこで、SRF 画像より抽出した高次局所自己相関特徴量 HLAC を、小さな欠陥と健全部のまだら状模様を区別する指標として用いた。

HLAC は2値画像の局所的な形状を 25 次元のベクトルとして表現するものである⁽³⁾。これにより、局所的な形状の異なる欠陥と健全部のまだら状模様を異なるベクトルとして表現できる。また、ノイズが生じてベクトルには大きな変動が生じない。これらの特性を活かし、後述の機械学習にて、欠陥と健全部を高精度に区別することが可能となる。

3. 機械学習による欠陥識別器の構築

3.1 模擬画像の生成

一般に、機械学習では大量の学習サンプルが必要であるが、欠陥部位のサンプルは少数しか得られない。そのため、学習サンプルとして模擬的に欠陥部位の画像を大量に生成した。ただし、実画像相当の欠陥画像は参照画像が少ないこともあり生成が困難なため、前記2つの特徴量で表現できる“欠陥の形状”並びに“画像のノイズ”を模擬的に再現した。

模擬欠陥画像の生成プロセスは以下ようになる。円形の空洞欠陥を想定したシンプルな欠陥モデルを設定し、半径、濃度を乱数で変更した模擬欠陥を生成する。これに実 RT 画像相当のノイズを有する画像に重畳するが、ノイズの原因は線源、材質、フィルム等多岐にわたるため、モデル化が難しい。そこで、実際に撮影された RT 画像より、健全部位をランダムに切り出したものに模擬欠陥を重畳し、模擬欠陥画像を作成した。これにより、フィルムの傷など、様々なノイズのバリエーションを、欠陥部位の学習画像に含めた。

3.2 機械学習による2クラス識別器

まず、SRF 抽出処理により欠陥を強調した SRF 画像を生成した。次に、HLAC を抽出した⁽⁴⁾。これを機械学習による判別器により欠陥部位と健全部位の2クラスに分類した。機械学習には SVM を用い、模擬欠陥画像と健全部位の画像を用いて学習した。学習時における各種パラメータは、実際に撮影された欠陥部位画像、健全部位画像に対して、見逃がし0、誤検出最小となるように設定した。



健全部位の学習画像は、2段階で選出した。まず、多数ある健全部位の画像から、ランダムに数千程度を抽出し、機械学習を行った。この段階では、誤検出が多い。これらを健全部位として、2回目の機械学習に用いた。この誤検出は、フィルムの傷など多数の要因によるノイズであり、これらを再学習することで誤検出を抑えることができた。

3.3 実アプリケーションによる評価

今回開発したアルゴリズムの精度評価のため、従来の欠陥検出アルゴリズムとの比較実験を行った。ここでは、評価用のサンプルとして、27 箇所欠陥を含む 17 枚のフィルムをスキャンした画像を用いた。

評価結果を表1に示す。従来のRT画像からの溶接欠陥検出手法は、モルフォロジー演算と2値化によるセグメンテーションの後に、サイズ、最大輝度、平均輝度、輝度の分散といった特徴量をしきい値で判定する方法である。従来法では、見逃しが発生する上に、誤検出がフィルム1枚あたり 100 箇所以上検出された。一方、今回開発した手法では、欠陥の見逃しを0とした上で、1枚あたりの誤検出は平均 5.8 箇所とすることができ、従来アルゴリズムと比べ大幅な改善が見られた。

表1 検出率・見逃し数・誤検出数

| | 従来手法 | 開発手法 |
|------------|---|--|
| 検出結果 |  |  |
| 検知率[%] | 81.5 (22/27) | 100 (27/27) |
| 見逃し数[箇所] | 5 | 0 |
| 誤検知数[箇所/枚] | 115 | 5.8 |

4. まとめ

欠陥部位のコントラストが低い RT 画像より、特徴抽出手法と機械学習を用いて、自動で欠陥位置を検出するシステムを構築した。検査員の欠陥識別支援として十分実用に足る性能であり、検査のダブルチェックやスクリーニングに用いることで検査員の負担を大幅に低減することが期待できる。現在、検査員による実画像を用いた適用性評価中である。また、学習サンプルとして模擬欠陥生成が有効であることが確認されたことから、欠陥画像のサンプルが難しいアプリケーションにおいても、本システムを迅速に導入することが期待できる。

参考文献

- (1) 吉田彰:放射線画像の物理的画質 基礎的概念と理論, 人間と科学 県立広島大学保健福祉学部誌, 14, 1, pp.1-22, 2014
- (2) 尾崎竜史ほか:統計的リーチ特徴法に基づくサンプル学習型画像照合, 電学論C, 130, 9, pp.1622-1629, 2010.
- (3) N. Otsu and T Kurita: A new scheme for practical, flexible and intelligent vision systems, Proc. IAPR Workshop on Computer Vision, pp. 431-435, 1998.
- (4) B. Alexe, T. Deselaers and V. Ferrari : Measuring the Objectness of Image Windows, in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 34, no. 11, pp. 2189-2202, 2012