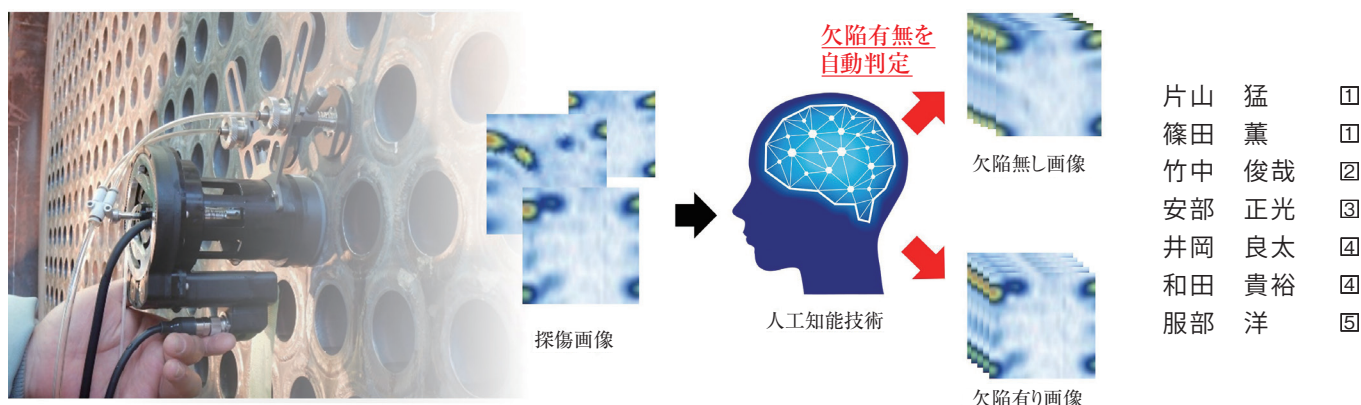


ディープラーニングを活用した管端溶接部におけるPAUT探傷データ解析手法の改善による高精度化



片山 猛 ①
 篠田 薫 ①
 竹中 俊哉 ②
 安部 正光 ③
 井岡 良太 ④
 和田 貴裕 ④
 服部 洋 ⑤

要旨

当社と株式会社ニチゾウテックは、多管式熱交換器における管端溶接部のフェーズドアレイ超音波探傷検査システムを開発し実機検査に適用してきた。本システムはAI技術である深層学習を用いて、管端溶接部に発生した有害な欠陥を精度高く検出する。これまでに5万箇所を超える管端溶接部の検査を行い、有用な検査手法としてユーザーに認知されてきた。本システムは画像化されたデータを用いて欠陥の有無を判定する特徴を有するが、画像中の探傷範囲を上手く抽出できないことや欠陥ではない反射エコーを過剰に検出することがあった。そこで、探傷範囲の抽出方法を改善し、新たなAI技術を活用することによって問題点を解決した。従来以上に高精度な検査が可能となり、様々な多管式熱交換器へ検査サービスを適用できるようになった。

キーワード

熱交換器, フェーズドアレイ探傷, Deep Learning, Semantic Segmentation, Deep Metric Learning

1. 緒言

プラントを構成する機器の1つである多管式熱交換器は円筒胴に多数の管を配置し胴側の流体と管側の流体で熱交換する機器である。多管式熱交換器において最も重要な溶接継手の一つである管と管板のシール溶接部（以下、管端溶接部）は液体や気体の漏洩によるプラントの緊急停止を防ぐため、使用条件に応じた高い品質が求められる。

当社は株式会社ニチゾウテックと協力して、2016年に世界初の管端溶接部用フェーズドアレイ超音波探傷試験装置（以下、管端PAUT装置）を開発した¹⁾²⁾³⁾。この装置は、多数の振動子から構成されるアレイ探触子が超音波ビームを送信するタイミングを制御し、合成された超音波波面を形成することで、管端溶接部における溶接欠陥の位置や大きさとその範囲を高精度に検出するものである。

従来のUT検査では、溶接欠陥の検出に複数回のスキャンが必要であったが、本装置を使用することで、伝

熱管の周縁部である管端溶接部の高精度な検査が1回のスキャンで可能となった。

検査サービス開始当初は、本装置で取得した探傷画像を検査員が1枚ずつ目視で欠陥有無を判定する必要があった。しかし、多管式熱交換器は数千から数万本の管を有することもあり、100万枚を超える膨大な画像を目視確認することは非常に困難であった。そこで、判定時間の短縮および検査員の負担軽減のため、AI技術である深層学習を活用して探傷画像から溶接欠陥の有無を自動判定するシステムを2020年に開発し、実機検査へ適用してきた⁴⁾。しかし、管の突出し長さが短いものでは探傷範囲を上手く抽出できない場合や、欠陥に酷似した反射エコーであるノイズを欠陥と誤って過剰に検出する事例が発生したため、システムを改良した。

本報で報告する、探傷範囲抽出方法の改善や新たなAI技術の活用により、それらの問題を解決し、管端PAUT装置で、より速く高精度に多管式熱交換器を検査できるようになった⁵⁾。

2. 管端PAUT装置

管端PAUT装置の外観を図1に示す。管端PAUT装置は、管内に挿入したアレイ探触子を使用して管端溶接部を管内表面側から探傷し溶接欠陥を検出する装置であ

① 脱炭素化事業本部 プロセス機器ビジネスユニット 生産技術部

② 脱炭素化事業本部 プロセス機器ビジネスユニット

③ 脱炭素化事業本部 開発センター 博士(工学)

④ 開発本部 技術研究所 知能機械研究センター

⑤ 株式会社ニチゾウテック 技術開発室 博士(情報学)

る。本装置を用いた管端溶接部の探傷方法を図2に示す。アレイ探触子面にウェッジを取り付け、管内表面に密着させる。そして、水などの接触媒質をポンプで自動供給しながら、管端溶接部全周を1°間隔で自動探傷を行い、360枚の探傷画像を取得する。



図1 管端PAUT装置




図2 管端溶接部の探傷方法

アレイ探触子は多数の振動子から構成されており、個々の振動子におけるパルスのタイミングを電子的に制御し、超音波ビームを任意の方向に伝搬させることができる。図3に示すリニアスキャンでは、複数の振動子を制御することで探傷面に対して垂直方向に超音波ビームを走査する。図4および図5に示すセクタースキャンでは、複数の振動子をあたかも一つの探触子のように振動制御することで探傷面に対して斜め方向に超音波ビームを走査する。このように、超音波を一定の焦点深度に設定し、任意の角度に偏向して送信させることにより、超音波ビームの位置および方向が変更できる。これにより、垂直方向に進展している管端溶接部の溶接欠陥だけでなく、斜め方向に進展している溶接欠陥の検出も可能となる。




図3 リニアスキャン




図4 セクタースキャン (管端側)



図5 セクタースキャン (管奥側)

3. 探傷画像例

人工穴を加工した管端溶接試験体のうち、管板面に平行で管軸に垂直な方向に径1 mmの穴(以下、Flat bottom hole、FBH)加工した試験体を探傷した画像データを図6に示す。探傷範囲に溶接欠陥などの反射源が存在する場合、その位置に反射したエコーが出現する。このエコー高さを0 ~ 100 %で示し、色付けを行うことで各スキャン方向における探傷画像が得られる。探傷画像中の管端溶接部は赤破線内であり、この範囲内にエコーがあるか否かを確認することで、溶接欠陥の有無を判定する。

上段中央はリニアスキャンの結果を示し、上段左右の画像はそれぞれ管端側および管奥側からのセクタースキャンの結果を示す。画像データの下段はCスコープと呼ばれる360°回転して得られた全周の画像データを示し、管端溶接部を示す赤破線帯の中にFBHの検出データが表示される。図6の赤丸で囲んだ部分にFBHは明瞭に検出されている。また、人工穴が斜め方向および管軸と平行方向に加工したものについても検出できている。また、管端溶接部の溶接金属高さを測定する機能を有しており、溶接金属高さが不足する場合は赤破線帯の幅が狭くなるため、健全な場合との比較が容易である。さらに、欠陥が発生した場合はCスコープの赤破線帯に反射エコーが示されるため、こちらも健全な部分との比較が容易である。




図6 探傷画像例

4. 溶接欠陥有無自動判定システム

4.1 溶接欠陥有無判定の処理フロー 本システムは画像化されたデータを用いて欠陥の有無を判定する特徴を有する。しかし、画像中の探傷範囲を上手く抽出できない事例や欠陥ではない反射エコーを過剰に検出する事例が発生した。そこで、欠陥有無判定における前処理の改善や追加により問題点を解決した。本システムの処理フローを図7に示す。青実線で示すYOLO^(6,7)による前処理を改善し、赤実線で示すSemantic Segmentation⁽⁸⁾、Deep Metric Learning (DML)⁽⁹⁾による前処理を追加した。

判定システムに入力された探傷画像に対して、3つの前処理を行った。まず、YOLOによって探傷範囲の抽出を行った。次に、誤判定の原因となる溶接ビード表面から反射したエコー(以下、ビード形状エコー)が出現した場合にSemantic Segmentationによってマスキングした。そして、誤判定の原因となる欠陥無し・ノイズ有り画像をDMLによって抽出した。それ以外の探傷画像は画像処理、Convolutional Neural Network (CNN)⁽¹⁰⁾を用いた画像分類、そしてAutoEncoder (AE)⁽¹¹⁾を用いた画像復元によって欠陥有無を判定した。さらに、各判定結果の確からしさ(以下、信頼度)を算出し、各手法の判定結果と信頼度をもとにアンサンブル判定を行い、判定結果を出力した。一方でDMLによって欠陥無し・ノイズ有りと判定された探傷画像は画像処理により判定結果を出力した。本判定システムにより欠陥有りと判定された画像を検査員が目視で2次判定した。それぞれの処理について以下に詳述する。

4.2 YOLOによる探傷範囲抽出

4.2.1 YOLO YOLOは高い処理速度と精度を兼ね備えた物体検出手法であり、画像内の物体の位置とクラスを同時に検出することができる。YOLOは画像をグリッドセルに分割し、各グリッドセルについて物体の存在確率やクラス確率を推定する。その後、グリッド

セルごとに得られた情報を統合し最終的な物体検出結果を出力する。

4.2.2 探傷範囲抽出 管端PAUT装置より取得される探傷画像は、管の厚さや寸法、管の突出し長さ、溶接条件、アレイ探触子の接触状態などにより構図は様々であるが、探傷画像における溶接欠陥が発生する範囲は、図8 (b) 中の管端溶接部である黒破線内である。そこで、YOLOを利用して溶接欠陥が発生する位置を含む赤破線内を探傷範囲として抽出した。

4.2.3 探傷範囲抽出方法の例と課題 YOLOを利用した探傷範囲抽出方法の例を図9に示す。抽出範囲は、管端溶接部の周縁部(管端側の管外表面および管奥側の管外表面)から反射したエコー(以下、底面エコー)である図9の【1】から【4】をターゲットに、管端溶接部が含まれる赤破線で囲んだ範囲を1つの矩形として物体検出し探傷範囲を抽出した。しかし、管の突出し長さが短い管では図10に示すような管端側の底面エコーが発生せず、この探傷範囲抽出方法では対応できない事例が発生した。

4.2.4 探傷範囲抽出方法の改善 YOLOを利用した探傷範囲の抽出方法を変更し問題点を解決した例を図11に示す。図11 (a) は管の突出し長さが長い場合、図11 (b) は管の突出し長さが短い場合である。図11 (a) は管奥側の底面エコーと管端側の底面エコーをYOLOにより物体検出した。さらに、探傷範囲となる矩形の高さは管端溶接部の開先幅に相当するため、図面情報を元にこの開先幅をソフトウェア上で予め設定しておくことで、探傷範囲を抽出した。

図11 (b) は管の突出し長さが短いため管端側底面エコーが発生しない。そこで、図12に示すように、管端部にゴムリングを設置して超音波が反射しない箇所を意図的に設けることで、探傷画像中に送信波が消失する部分(以下、送信波消失部)を発生させた。この送信波消失部を特徴点としてYOLOで物体検出することで探傷範囲となる矩形の幅を設定した。探傷範囲となる矩形の高さは図11 (a) と同様に図面情報を元に設定した。

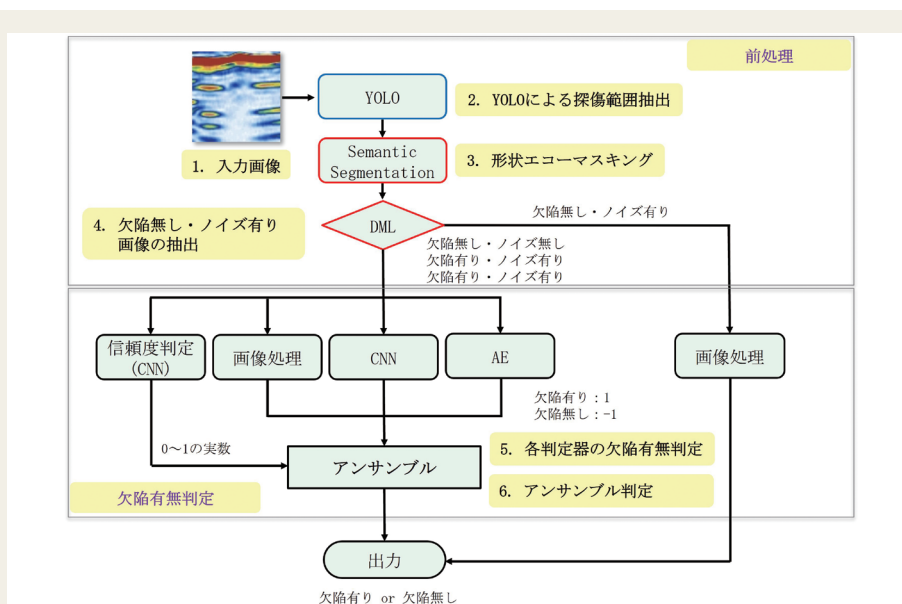


図7 溶接欠陥有無自動判定システムの処理フロー




図8 探傷画像例



図12 ゴムリングの設置

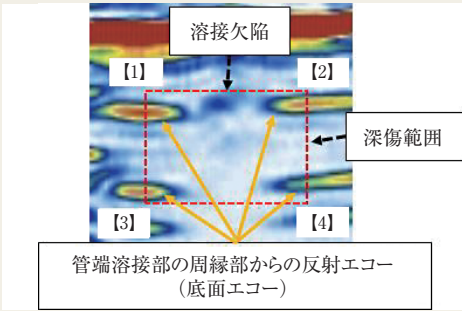


図9 YOLOによる探傷範囲抽出方法 (改善前)


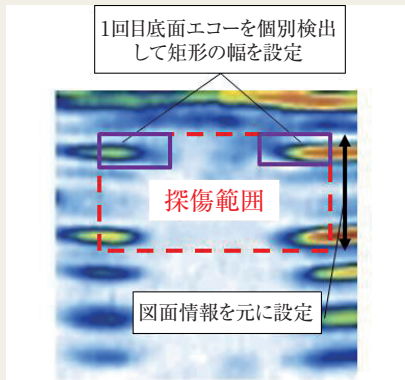
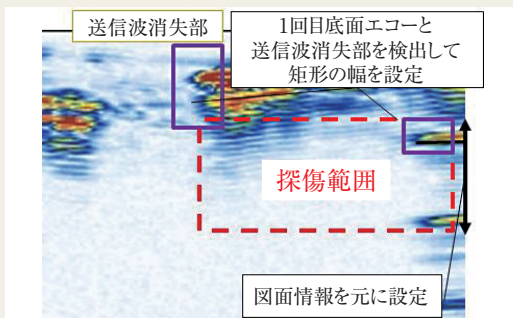


図10 管の突出し長さが短い場合の探傷画像



(a) 管の突出し長さが長い場合



(b) 管の突出し長さが短い場合

図11 YOLOによる探傷範囲抽出方法 (改善後)

4.3 Semantic Segmentationによるビード形状エコーのマスクング

4.3.1 Semantic Segmentation Semantic Segmentationは、画像内の各ピクセルを物体や背景などのクラスに分類するアルゴリズムである。CNNを用いて画像内の特徴を抽出し、各ピクセルのクラスを予測する。そして、予測されたクラスを元に、画像内の各ピクセルを色分けして、結果を出力する。

4.3.2 ビード形状エコーのマスクング 溶接ビード形状の影響によってビード表面から超音波が反射したエコーが欠陥のように表示されることがあった。この反射エコーは溶接ビード形状に沿って表示されるため、目視で欠陥ではないと明確に区別できるが、画像処理やAEでは正確に区別することが難しく、誤って欠陥と判定されることがあった。欠陥有り判定された画像は検査員が目視で判定するため、判定時間が増加する原因となっていた。

そこで、Semantic Segmentationを用いてビード形状エコーをマスクングし、マスクング後の画像を欠陥有無判定することにした。図13にマスクング前後の探傷画像を示す。ビード形状エコーの高さが20%以上の領域をアンノテーションしてSemantic Segmentationモデルに学習させた。学習済みモデルにテスト画像1,000枚を入力した結果、約98%のテスト画像に対して正確にマスクングすることができた。管本数4,844本、ビード形状エコーが90%の割合で発生する機器の場合、検査員の目視判定時間を1基当たり約218hから約4hに削減できると試算した。




図13 ビード形状エコーのマスクング

4.4 DMLによるノイズを含む画像の抽出

4.4.1 DML DMLは、特徴量空間上の距離によりデータ間の類似性を測定する手法であり、類似画像検索や顔認証、異常検知などに応用される。図14にDMLの概略図を示す。DMLは画像から特徴量を抽出し、特徴量空間上にプロットする。通常、本検討のように入力が画像の場合、特徴量の抽出にはCNNが利用される。空間上に埋め込まれた特徴量に対して、ユークリッド距離などの指標により、距離を測定する。画像から得られ

た特徴量同士の距離が近い場合、それらの画像は類似しており、特徴量同士の距離が遠い場合、それらの画像は類似していないことになる。このように、特徴量に対する距離を測定することで、画像の類似性を判断することが可能となる。

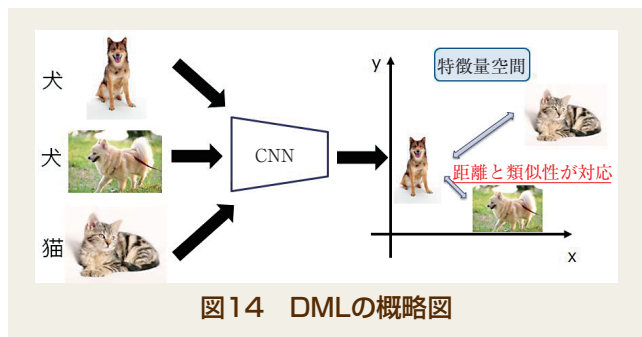


図14 DMLの概略図

4.4.2 ノイズを含む画像の抽出

管端溶接部の溶着金属と管の境界部にノイズが反射エコーとして表示されることがあった。図15に欠陥有り・ノイズ無し画像と欠陥無し・ノイズ有り画像を示す。図15 (a) に示すように、欠陥有り画像に比べて、図15 (b) の赤実線で示すノイズは反射エコー高さが低い。しかし、欠陥無し・ノイズ有り画像の中には画像分類や画像復元では欠陥有りと誤判定されるものがあつた。欠陥有りと判定された画像は検査員が目視で判定するため、検査時間が増加する原因となつていた。

そこで、DMLを用いて欠陥無し・ノイズ有り画像を予め抽出することにした。ノイズが発生していない欠陥無し画像と欠陥有り画像をDMLモデルに学習させた。学習済みDMLモデルにテスト画像4,400枚を入力し特徴量空間を出力した結果を図16に示す。青点で示す「欠陥無し・ノイズ無し」画像は右上に、赤点と橙点で示す「欠陥有り」画像はノイズの有無に関わらず左下にプロットされた。一方で、緑色のプロットで示す「欠陥無し・ノイズ有り」画像は前者3色の点から離れた位置にプロットされるため、これらの画像を抽出した。その結果、「欠陥無し・ノイズ有り」画像の約95%を抽出することができた。管本数4,844本、ノイズが20%の割合で発生する機器の場合、検査員の目視判定時間を1基当たり約70hから約4hに削減できると試算した。

DMLによって抽出した画像は4.5節に示す画像処理のみを用いて判定した。それ以外に分類された画像は、アンサンブル判定により欠陥有無を判定した。

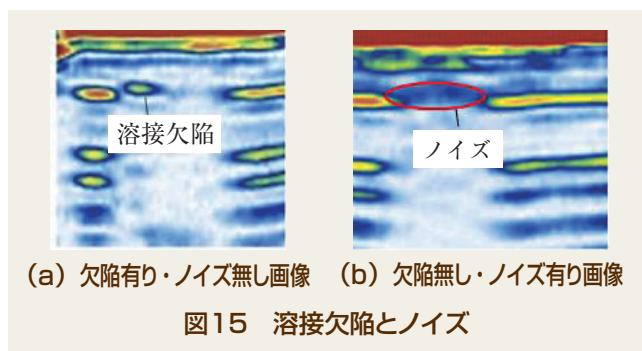


図15 溶接欠陥とノイズ




図16 欠陥無し・ノイズ有り画像の抽出

4.5 画像処理による欠陥有無判定 画像処理は予め設定した閾値で画像のピクセル値を区別する方法である。画像処理による探傷画像の欠陥有無判定は、YOLOを用いて探傷範囲を抽出後、底面エコーを除いた範囲内の全ピクセルのうち、閾値以上の高さを有するピクセル値が一定数以上ある場合に欠陥有りと判定した。

4.6 CNNを用いた画像分類による欠陥有無判定

4.6.1 CNN CNNは視覚野の特徴抽出の仕組みをモデル化しており、特に画像認識の分野にて用いられる。CNNは、主に畳み込み層、プーリング層、全結合層から構成される。畳み込み層は、入力データをフィルターで畳み込むことで、特徴マップを生成する。プーリング層は、特徴マップをダウンサンプリングすることで、計算量を削減し、特徴をより抽象化する。そして、全結合層は、特徴マップを1次元のベクトルに変換し、最終的な出力を生成する。

4.6.2 CNNによる欠陥有無判定 YOLOを用いて探傷範囲を抽出した画像のうち、溶接欠陥有り画像および溶接欠陥無し画像を学習データとして使用した。この学習データをもとに、CNNによる2クラス(溶接欠陥有り/無し)の分類モデルを作成した。学習済みの分類モデルに画像を入力すると、溶接欠陥有り/無し別の確信度(溶接欠陥有無の確率)が出力される。確信度は0~1の実数値をとり、合計すると1になる。ここでは、溶接欠陥有りの確信度が0.5以上の場合に「溶接欠陥有り」、0.5より小さい場合に「溶接欠陥無し」と判定した。

4.7 AEを用いた画像復元による欠陥有無判定

4.7.1 AE AEはデータの圧縮や特徴抽出に用いられるニューラルネットワークの一種である。AEはEncoderにより入力データを圧縮して、より低次元の表現に変換する。その後、Decoderにより復元して元のデータに戻す。この過程において、圧縮された表現がデータの特徴を捉えたものとなる。

AEを利用した異常検知では、正常データのみを学習して、次元削減した後にそれを復元するモデルを構築する。学習していない異常なデータを入力した場合は、異常箇所をうまく圧縮、復元できないため、入力されたデータとは異なるものが復元される。そのため、入力データと復元データを比較すると、それらの差が大きくなる。

この差を異常度とすることで、正常および異常の判定（異常検知）を行うことができる。

4.7.2 AEによる欠陥有無判定 YOLOで探傷範囲を抽出した画像のうち、欠陥無し画像のみをAEに学習させ、画像復元モデルを作成した。学習済みのAEモデルに、欠陥無し画像を入力すると、同様の画像が復元される。一方で、欠陥有り画像を入力すると、溶接欠陥部分がうまく復元されず、入力画像と異なる画像が復元される。そこで、入力画像と復元画像のピクセル値の差を計算し、これが大きい場合に「欠陥有り」と判定した。

しかし、入力画像および復元画像には、底面エコーの一部が含まれており、形状が画像ごとに異なるため、完全な復元が困難であった。そこで、底面エコー部を除去するマスキング処理を行い、溶接欠陥部分でのピクセル値の差を顕著にする工夫を行った。

溶接欠陥がある場合、溶接欠陥部分におけるピクセル値の差がそれ以外の領域と比べて大きくなるため、ピクセルに対する分散が大きくなる。一方、溶接欠陥がない場合は、ピクセル値の差が小さくなるため、相対的にピクセルに対する分散は小さくなる。そこで、分散を使用して溶接欠陥の有無を判定することにした。分散が一定値以上の場合に「溶接欠陥有り」、一定値より小さい場合に「溶接欠陥無し」と判定した。

4.8 各手法の判定結果 画像処理、CNN、AEの各手法を用いて、欠陥有り画像762枚を含むテスト用画像16,920枚を判定した結果の混同行列を表1～表3に示す。テスト用画像は実機の探傷データから無作為に抽出したものである。正解率は全画像に対して正しく欠陥有無分類できた割合、適合率は欠陥有りと予測された結果に対する実際の欠陥有り画像の割合、再現率は欠陥有り画像に対して正しく欠陥有りと判定できた割合、特異率は欠陥無し画像に対して正しく欠陥無しと判定できた割合である。

欠陥有り画像の見落としを抑制する目的で再現率の精度向上を重視しているため、相対的に適合率が低下した。また、各手法によって正解となる画像及び不正解となる画像が異なる場合があった。例えば、各手法単独では最も再現率が高いCNNによる判定で誤って判定した画像に対して、画像処理およびAEでは正しく判定されるということがあった。そこで、4.9節以降に示す信頼度判定とアンサンブル判定を導入した。

表1 画像処理の判定結果

		判定結果		正解率	98.4%
		欠陥有り	欠陥無し	適合率	74.0%
目視判定	欠陥有り	750	12	再現率	98.4%
	欠陥無し	264	15,894	特異率	98.4%

表2 CNNの判定結果

		判定結果		正解率	94.0%
		欠陥有り	欠陥無し	適合率	42.6%
目視判定	欠陥有り	759	3	再現率	99.6%
	欠陥無し	1,021	15,137	特異率	93.7%

表3 AEの判定結果

		判定結果		正解率	98.3%
		欠陥有り	欠陥無し	適合率	73.8%
目視判定	欠陥有り	741	21	再現率	97.2%
	欠陥無し	263	15,895	特異率	98.4%

4.9 判定の確からしさ(信頼度)の算出 画像処理、欠陥有無判定用CNNおよびAEにおける信頼度を算出するため、学習データに対して各手法で正解もしくは不正解であったかのラベル付けを行い、信頼度を判定するためのCNNモデルでこれらを学習した。信頼度を判定するCNNは、画像処理、欠陥有無判定用CNNおよびAEに入力された探傷画像に対して、学習データを基に算出された値を出力する。この値を各手法が正解する確率として用いた。探傷画像を入力した際、信頼度は判定手法ごとに算出され、入力した探傷画像ごとに出力した。入力された探傷画像が正解ラベルを付けられた学習データに似ている場合は1に、入力された探傷画像が不正解ラベルを付けられた学習データに似ている場合は0に近い値を出力した。

4.10 アンサンブル判定 アンサンブルによる判定は、式[1]に示す通り各判定手法の判定結果 x_i と信頼度 r_i の総和 y によるものとした。アンサンブルの結果、 $y > 0$ の場合は「溶接欠陥有り」、 $y < 0$ の場合は「溶接欠陥無し」、 $y = 0$ の場合は「判定不可」を最終的な判定結果として出力した。つまり、探傷画像に応じた信頼度により、各判定手法の判定結果を適切に考慮した溶接欠陥有無判定結果を得ることが可能となった。アンサンブルによる溶接欠陥有無の判定結果例を表4に示す。表4では、3つの判定手法のうちCNNのみが異なる判定結果となっているが、画像処理およびAEの信頼度が高いため、最終的な判定結果は「溶接欠陥有り」となった。

$$y = \sum x_i r_i \quad \dots [1]$$

ここで、

x_i : 各手法における判定結果

(欠陥有り: 1、欠陥無し: -1)

r_i : 各手法における信頼度 (0~1の実数値)

表4 アンサンブル判定の例

	判定結果		信頼度		アンサンブル y
	x		r		
画像処理	1	×	0.91	=	0.91
CNN	-1	×	0.56	=	-0.56
AE	1	×	0.87	=	0.87
					1.22 ($y > 0$)

4.8節で用いたテスト用画像16,920枚をアンサンブル判定した結果を表5に示す。欠陥有り画像762枚のうち1枚の見落としがあったが、各判定手法単体の結果と比べて全ての指標で判定精度が向上しており、欠陥有り画像の見落としだけでなく、欠陥無し画像の過剰な検出も抑制できた。各手法の判定結果と信頼度を用いたアンサンブル手法により、画像単位で約99%の判定精度を実現した。

表5 アンサンブル判定結果

		判定結果		正解率	99.4%
		欠陥有り	欠陥無し	適合率	88.6%
目視判定	欠陥有り	761	1	再現率	99.9%
	欠陥無し	98	16,060	特異率	99.4%

5. 実機検査への適用

本検査システムは、当社で新規製作した多管式熱交換器をはじめ、供用中機器のプラントメンテナンスや他社で製造中の機器へ国内外問わず幅広く適用しており、これまでに5万箇所以上の管端溶接部を検査した実績を有する。一例として検査の様子を図17に示す。当社工場内で行われた検査においては、昼夜2交代作業で600箇所/日程度、約16,000箇所の探傷データを取得した。そして、欠陥有無判定システムが「欠陥有り」と判定した探傷画像を検査員が目視で確認した。ここでは、欠陥有り画像が一定数連続した場合に不合格と判定することにした。また、欠陥有りと判定された画像の前後5枚程度も検査員が確認し、欠陥の見落としを防止した。この方法によって、探傷画像を目視で全数判定する場合と比較して、判定時間は75%以上削減できた。具体的には、目視判定のみで1,600h以上掛かると見込んでいた判定時間を約350hにまで短縮でき、実用的な期間で管端溶接部の全数検査が可能となった。前処理の改善・追加によって、速く高精度な検査が可能となり、様々な多管式熱交換器へ検査サービスを適用する機会の拡大につながった。



(a) 新規製作時検査

(b) 供用中メンテナンス

図17 多管式熱交換器における管端PAUT検査の様子

6. 結 言

多管式熱交換器の管端溶接部を検査する管端PAUT装置および取得した探傷画像の欠陥有無を自動判定するシステムを開発し実機へ適用している。本自動判定システムにおいて、正確に欠陥の有無を判定できない事例が発生したため、AI技術を活用して探傷データの解析手法を確立し、従来方法における問題点を解決した。その結果、従来以上に高精度な検査が可能となり、様々な多管式熱交換器へ検査サービスを適用できるようになった。本報のまとめを以下に示す。

- ① 探傷画像の探傷範囲を決定するための前処理として、YOLOを用いて探傷範囲を抽出した。底面エコーおよび送信波消失部を検出し、これら特徴点から矩形の幅を設定した。
- ② 探傷画像に現れる溶接ビード形状が判定結果に影響を及ぼさないための前処理として、Semantic Segmentationを用いてビード形状エコーをマスキングした。その結果、約98%のテスト画像に対して正確にマスキングすることができた。これにより検査員の目視判定時間を1基当たり約218hから約4hに削減できると試算した。
- ③ 管端溶接部の周辺に現れるノイズを含む画像を抽出する前処理として、DMLを用いて探傷画像中に発生した欠陥無し・ノイズ有り画像の約95%を抽出することができた。これにより検査員の目視判定時間を1基当たり約70hから約4hに削減できると試算した。
- ④ YOLO、Semantic Segmentation、DMLを利用した前処理後に画像処理、CNN、AEの3手法により、溶接欠陥の有無を判定した。ノイズが発生した画像や管の突出し長さが短いため底面エコーが出現しない画像は、欠陥の有無を正確に判定できないことが問題となっていたが、前処理の追加によって高精度な検査が可能となった。
- ⑤ 画像処理、CNN、AEの3手法の判定結果と信頼度を用いたアンサンブル手法により、画像単位で約99%の判定精度となった。
- ⑥ 本検査システムを利用することで探傷画像を目視で全数判定する場合と比較して、判定時間を75%以上削減できた。さらに、前処理の改善・追加によって、速く高精度な検査が可能となり、様々な多管式熱交換器へ検査サービスを適用する機会の拡大につながった。

SDGsに貢献する技術

多管式熱交換器の管端溶接部におけるPAUTにAI技術を適用することで、検査時間の短縮による生産性向上と検査員の作業負荷軽減を実現し、SDGs目標の「8.働きがいも経済成長も」に貢献する。

参考文献

- 1) Hitz技報 製品紹介 熱交換器の管端溶接部非破壊検査システム, **2016**, Vol.77, No.1, pp.48-49.
- 2) M.Abe, J.Murakami, N.Shinmura : Ultrasonic Testing and Photographic Imaging System for Tube to Tubesheet Weld of Heat Exchanger, ASME, **2017**, PVP2017-65569, pp.1-8.
- 3) 篠田薫, 安部正光, 村上丈一ほか : 多管式熱交換器における管端溶接部のPAUT検査技術, 溶接構造シンポジウム2019講演論文集, 大阪, **2019**-12-3/4.
- 4) Hitz技報 技術論文 管端溶接部の溶接欠陥有無自動判定システムの開発, **2020**, Vol.81 No.1, pp.2-8.
- 5) K.Shinoda, M.Abe et al. : Application of Phased Array Ultrasonic Testing for Tube-to-Tubesheet Weld of Heat Exchanger using Deep Learning, The 75th IIW annual Assembly and International Conference, **2022**.
- 6) J.Redmon ; S.Divvala ; R.Girshick et al. : You Only Look Once : Unified, Real-Time Object Detection, IEEE Conference on Computer Vision and Pattern Recognition, **2016**.
- 7) J.Redmon and A.Farhadi : YOLO9000 : Better, Faster, Stronger, IEEE Conference on Computer Vision and Pattern Recognition, **2017**.
- 8) Hengshuang Zhao, Jianping Shi, et al. : Pyramid Scene Parsing Network, Computer Vision and Pattern Recognition, **2017**.
- 9) Yandog Wen, Kaipeng Zhang, Zhifeng Li et al.:A Discriminative Feature Learning Approach for Deep Face Recognition, European Conference on Computer Vision (ECCV), Part VII, Lecture Notes in Computer Science book series (LNCS), **2016**, volume 9911, pp.499-515.
- 10) LeCun,Y. ; Boser,B. ; Denker, J.S. et al. : Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation, **1989**, 1(4), pp.541-551.
- 11) G.E.Hinton and R.R.Salakhutdinov : Reducing the Dimensionality of Data with Neural Networks. Science, **2006**, 313 (5786), pp.504-507.

文責者

日立造船株式会社 脱炭素化事業本部
 プロセス機器ビジネスユニット
 生産技術部 技術・開発グループ
 片山 猛
 e-mail : t_katayama@hitachizosen.co.jp

Higher Precision by Improving PAUT Flaw Detection Analysis Method for Tube to Tubesheet Welds Using Deep Learning

Abstract

Hitachi Zosen Corporation and NICHIZO TECH INC. had developed a phased array ultrasonic testing system for tube to tubesheet welds of multi-tube heat exchangers and applied it to actual inspections. The system uses deep learning AI technology to accurately detect harmful defects that occur in tube to tubesheet welds. Through inspections conducted on over 50,000 tube to tubesheet welds to date, the inspection method has been recognized by users as being useful. The system determines the presence or absence of defects using image data, but this feature had issues with not being able to extract the inspection range in the image and detecting excessive reflection echoes that are not defects. Therefore, we solved these problems by improving the method of extracting the inspection range and by utilizing new AI technology. This has made it possible to perform higher-precision inspections than before and apply our inspection services to various multi-tube heat exchangers.

Authors

Takeru Katayama (Hitachi Zosen Corporation, E-mail : t_katayama@hitachizosen.co.jp)
 Kaoru Shinoda Toshiya Takenaka Masamitsu Abe Ryota Ioka Takahiro Wada
 Hiroshi Hattori