

企画セッション | 部会・連絡会セッション：計算科学技術部会

■ 2018年9月7日(金) 13:00 ~ 14:30 | 会場 B棟 B32

[3H_PL] 人工知能技術の活用と将来展望

座長:伊藤 啓(京大)

[3H_PL01] 深層学習によるき裂進展予測のためのサロゲートモデルの構築

*和田 義孝¹ (1. 近大)

[3H_PL02] 計算力学シミュレーションを機械学習に置き換える技術の基礎的検討

*中林 靖¹ (1. 東洋大)

[3H_PL03] 画像処理、AI活用による原子炉検査の高度化

*細谷 直樹¹ (1. 日立)

計算科学技術部会セッション

人工知能技術の活用と将来展望

Application of Artificial Intelligence Technologies and its Future Prospects

(1) 深層学習によるき裂進展予測のためのサロゲートモデルの構築

(1) Construction of surrogate model for prediction of crack propagation using deep learning

*和田 義孝¹¹近畿大学 理工学部 機械工学科

1. はじめに

ILSVRC 2012 におけるディープラーニング（深層学習）⁽¹⁾の有効性が画像認識において示されその可能性に多くの人々が期待する状況になって久しい。しかし、計算力学や CAE といった分野こそ、ディープラーニングとの親和性が高いと期待するもののその応用方法・利用方法については先行研究事例が少ない。一方で、もともと多くのデータを必要とする分野（材料設計、流体工学等）においては特徴量を抽出する多次元非線形マッピングの技術としてディープラーニングの利用例が複数報告されている⁽²⁾。本研究では重合メッシュ法によるき裂進展データを大量に生成し、何をどのように学習するのがサロゲートモデルの構築に有効なのかをき裂進展挙動を通して考察する。

2. ディープラーニングの現状

画像認識に代表される文字認識、人認識、顔認識等のピクセル単位で学習するディープラーニング（＝大規模入力、多階層のニューラルネットワーク）の成功例⁽¹⁾から大規模な研究開発および IT 企業および自動車企業による投資が始まった。これらの動きに呼応する形で、例えば NVIDIA による GPGPU 開発のディープラーニング向けの開発⁽³⁾、各研究機関および大学によるディープラーニング向けの API の開発など加速した。これらの動向に対して CAE に対する AI およびディープラーニングへの適用の期待も高まっている^(4,5)。しかし、画像解析による応用はその事例は多数見受けられるが、一方で物理現象、工学設計における応用方法が全く示されていない現状がある。USNCCM2017（米国計算力学学会）において E. Haber によりディープラーニングの新しい学習方法の提案が Semi-plenary lecture⁽⁶⁾があった。この講演における要旨は、計算力学の手法をディープニューラルネットワークの学習に適用することにより計算科学研究者の提案よりさらに効果的な学習が達成できるという点である。学習手法にたいするブレークスルーを示唆する画期的な発表があった。複雑な問題、多入力・他出力のディープニューラルネットワークの学習方法の進歩に大きく貢献することが現在進行している。一方で、トヨタ自動車は、自動運転実現のためにはあと 142 億万kmの走行距離が必要だという試算を示している⁽⁷⁾。この数値は、技術のある運転手が 10000 人・台が一人 1 万³メートル以上の走行距離が必要だと示唆している。学習は人間の経験と相対するところがある。例えば、事故、回避などのアクシデント事例は特に学習が必要であるが、そういったケースは全体のデータに対する学習ケース（時間）は少ない。詳細は後述（5章）するが、荷重方向に対して角度を有するき裂は進展の直後少ない時間で進展方向を変える。つまり、学習するためのデータ数が少なくなる。このことは、多くの工学応用に関して常に問題となる。また、多くの工学問題ではどの場所のどのような物理量を学習させればよいのかの知見が全くないことが大きな課題であると指摘できる。

3. ディープラーニングを実現する技術

現在、ディープラーニングという言葉には次のような意味が込められていると考える。

*Yoshitaka Wada¹¹Department of Mechanical Engineering, Kindai University

「バックプロパゲーション(BP)法の改良および過学習の防止手法も含めた多入力多階層のニューラルネットワーク(NN)の学習手法およびそれらの学習で得た NN の重み係数」

つまり、ディープラーニングとはアルゴリズムを指し示すだけのテクニカルタームではない。このタームは自動運転や人工知能を実現するための重要な役割があることが同時に期待されていると昨今の報道⁽⁸⁾から理解できる。

ニューラルネットワークは、Fig.1 に示すノードとそれらを結ぶ結線によりモデル化される。すべての結線はノードから出力された値を変更する重み w_{ijk} とバイアス b_{ijk} が与えられる。各ノードは式 1 に表されるシグモイド関数（他の関数形式も存在する）により演算されることが一般的である。この関数の特徴は、Fig.2 に示すように、入力値が大きくなると 1 に漸近し、入力値が小さくなると 0 へ漸近する。入力値が 0 では 1/2（傾き 1/4）を出力する。

最も基本的な関数 $f(x)$ のフィッティングを行うには 1 入力 1 出力のニューラルネットワークの学習を行えばよい。一般的には入力、出力ともにベクトルないしマトリックスになる。画像の学習（文字認識、人や車の認識）は 1 ピクセル=1 入力となるためマトリックスがその入力になる。

ニューラルネットワークでは、大規模な重み重み w_{ijk} とバイアス b_{ijk} の逐次更新により学習を進める。学習が進んだニューラルネットワークはエンジニアが望んだ能力を獲得している状態を学習により達成する。具体的には、Fig.3 に示すような流れで学習を行う。これらの方法は、SOR 法などのような初歩的な反復法ソルバーと同じ程度のプログラミングが要求されているためニューラルネットワーク実現のための基本的な骨子の理解は極めて容易である。

本章の冒頭においても述べたように通常の誤差逆伝播学習では大規模なニューラルネットワークは学習ができなかった。それらの学習を可能にしたのがいくつかの学習方法の改善である。例えば、10 層以上の学習を確実に進めるためには、出力と入力に同じ値を用いて 1 層ずつ学習を進める方法がよくとられている。また、最新の研究結果では 2 階層のマルチグリッドであるコースグリッドコレクションを利用した学習方法も提案⁽⁹⁾されており、学習結果もより誤差が小さくなることも示されている。入力データに意図的に誤差を与えて学習をさせる方法も取られる。この方法の利点はデータセット数が簡単に数倍に増やせる点である。これらの学習を強化する方法を組み合わせるとディープラーニングが実装され様々な成果を生み出している。




Fig.1 ニューラルネットワークの構成

$$h_{mn}(x) = \frac{1}{1 + e^{-\sum_{i=1}^k (W_{mni}x + b_{mni})}} \quad (1)$$




Fig.2 シグモイド関数




Fig.3 ニューラルネットワークの学習

4. CAEにおけるサロゲートモデル

工学応用への問題を考えると、何を入力と出力にするのか。学習データはどのように準備するのが最大の問題となる。物理現象は空間、物性、物理量（変位、速度、ひずみ、応力、温度等）が入力または出力されることになる。物理量を学習（測定）する位置の取扱いを一般化しなければ座標系依存の学習となる。そこから法則を見出すことは困難である。例えば、同じ目的の部品においてもそのサイズが 10 倍も異なる場合サイズの違いをどのように扱うのかを定める必要がある。形状が決まっているのであれば、ノーマライズを行うことが入力のパラメータを減じることになる。ただし、ノーマライズを行った係数は学習対象となる。また荷重に関しても同様で特に弾性問題であれば単位力を想定して学習させる。

サロゲートモデルは代替モデルとして物理現象を模擬するモデルである。したがって、微分方程式を完全に代替するものではない。これまでパラメトリックに問題を解いていた場合、変数を可能な限り限定することにより現象の傾向を把握していた。例えば、ニューラルネットワークを使ったサロゲートモデルであれば多数の変数を用いて学習し、より自由度の高いサロゲートモデルの構築が可能となる。しかし、例えば非線形問題においては解析結果の取得に時間が必要であることと解析精度の低さが問題である。繰返

しの応力ひずみ関係はヒステリシスループを示し1つのひずみ（変位）に対して複数の応力（荷重）状態を示す。確実に学習できるとすれば降伏局面や背応力自体を学習させることである。しかし、実際の降伏現象は等方硬化、移動硬化の混合で生じているうえに降伏局面が連続であるとは限らない。ディープラーニングによる学習はそういったモデル化が困難な現象に対して学習できる可能性がある。したがって、今後どのような物理量を学習させることが精度よく実質的な時間で学習が行えるのかを調べる必要がある。

5. き裂進展サロゲートモデル

本稿では、疲労き裂進展を具体事例としてディープラーニング技術を適用しき裂進展挙動が予測できるかどうかを検証した。3つのフェーズを想定し、フェーズ1は応力拡大係数から進展方向ベクトルおよび進展速度を学習、フェーズ2はき裂先端近傍応力、変位から進展方向ベクトルおよび進展速度を学習、フェーズ3は初期き裂中心位置を原点としき裂先端位置およびき裂が向いている方向ベクトルから進展方向ベクトルおよび進展速度を学習、という3つの場合に分けた。実用上はき裂先端の位置および進展方向のベクトルから学習できることが望ましい。その理由は、き裂を画像的に扱うことにより直接その余寿命やき裂形状の予測が可能になるためである。


疲労き裂進展解析は、弾性計算（ポアソン方程式）、応力拡大係数、等価応力拡大係数、き裂進展速度、き裂進展方向を微小ステップで解析を行いその履歴（積分）として最終的なき裂進展形状が計算される。Fig.4に等価応力拡大係数、き裂進展速度およびき裂進展方向を決定する経験則による式を示す⁽⁹⁻¹¹⁾。ディープラーニングによりこれら式を陰的に再構成されるかどうか工学分野における応用のための提示すべき具体例である。

Crack growth direction: Richard's criterion

$$\varphi_0 = \mp \left[A \frac{|K_{II}|}{K_I + |K_{II}| + |K_{III}|} + B \left(\frac{|K_{II}|}{K_I + |K_{II}| + |K_{III}|} \right)^2 \right] \quad (*)1$$

$$\varphi_0 < 0^\circ \text{ for } K_{II} > 0 \text{ and } \varphi_0 > 0^\circ \text{ for } K_{II} < 0 \text{ and } K_I \geq 0$$

$$A=140^\circ, B=-70^\circ$$



Crack growth rate: Paris's law

$$da/dN = C(\Delta K_{eq})^n \quad (*)2$$

$$K_{eq} = \frac{K_I}{2} + \frac{1}{2} \sqrt{K_I^2 + 4(\alpha_1 K_{II})^2 + 4(\alpha_2 K_{III})^2} \quad (*)3$$

$$\alpha_1 = K_{Ic}/K_{IIc} \text{ and } \alpha_2 = K_{Ic}/K_{IIIc}$$

$$\alpha_1 = 1.155, \alpha_2 = 1.0$$

Material
A533B steel E=206GPa, ν=0.3
C=1.67×10⁻¹², n=3.23

Fig.4 き裂進展則にかかわる多くの法則とパラメータ(8、9)

学習データは重合メッシュ法(以下 s-FEM)によるき裂進展解析⁽¹¹⁾を用い約5,000におよぶデータを生成した。データをもとに、ノイズ混入、ノード停止などのテクニックを用いて総学習数12万回を行った。実用的観点からは12万回の学習数は極めて少ない。Fig.5にき裂進展速度の学習結果を示す。またその具体的な予測された数値を表1に示す。S-FEMによるき裂進展解析と同様にシミュレーションによるき裂進展速度の予測は1サイクル当たりの進展量ではない。理由は、1サイクル当たりの進展量は10⁻¹²のオーダーのためそのサイズではメッシュ生成ができない。したがって、最小メッシュサイズあたりに何サイクル必要か計算することで、き裂進展数値シミュレーションを連続的に行う。Fig.6から、き裂進展開始直後では大きな差異が左右のき裂先端部位でみられる。しかし、き裂進展が進むにつれS-FEMの結果と一致する。荷重方向に対して斜めに存在するき裂が繰返し荷重を受けると急激にその向きを変え、その後はほぼ水平に進展する。つまり、き裂の向きを変える学習が少ない。進展方向を変える学習データ数は全体の学習データ数のわずか4%程度にしか過ぎない。

本適用例は、CAEアプリケーション自体をデータ生成のための手法として利用することの提案である。

近年の配列計算機環境およびクラウドによる並列計算サービスの利用を考えればパラメトリックにバッチ処理を実行する技術的困難さはほとんどない。このような、状況を踏まえて CAE アプリケーションにデータを生成されば、意図的に境界領域（考えている解空間の端）およびデータ数の取得が相対的に少なくなる箇所（本適用例ではき裂進展直後）を適切に理解しデータの密度を適正化（必要なデータの密度の均質化）が可能となる。




Fig.5 き裂進展速度の予測結果と進展ステップ数



Fig.6 機械学習によるき裂進展予測と重合

メッシュ法によるき裂進展

(正解)：黒・初期き裂、赤・重合メッシュ法、
青・ニューラルネットワークによる予測

6. おわりに

ディープラーニングおよびそれらを実用化するための技術集積により実用化が進行している。また、学習方法も様々な分野の知見を適用することによりより効果的・効率的なサロゲートモデルの構築が可能となると考えられる。一方で現象の分析と効果的な学習パラメータ選定など知見の獲得が急務である。

参考文献

- (1) A. Krizhevsky, et al., ImageNet Classification with Deep Convolutional, Advances in Neural Information Processing Systems 25 (NIPS 2012), 2012
- (2) 日本機械学会第30回計算力学講演会講演論文集、大阪、2017
- (3) 井崎、NVIDIAのディープラーニング戦略と最新情報、GPU Technology Conference、Tokyo、2016
- (4) 和田、CAEにおけるディープラーニング活用の一考察（ディープラーニングによるき裂進展挙動予測）、第48回関西CAE懇話会、京都、2016
- (5) 和田、CAEにおけるディープラーニング活用～重合メッシュ法によるき裂進展挙動学習～、ADVENTURECluster ユーザー会 2017、Tokyo、2017
- (6) E. Haber、Deep Learning Meets Differential Equations and Optimal Control、14th U.S. National Congress on Computational Mechanics、Semi-plenary lecture、Montreal、2017
- (7) トヨタ社長「142億キロの試験走行」で自動運転実現を宣言、<https://forbesjapan.com/articles/detail/13813>、2016
- (8) 例えば http://monoist.atmarkit.co.jp/mn/subtop/features/automated_vehicle/ などの特定情報をクリップする記事
- (9) H. A. Richard、M. Fulland、M. Sander S. N., Fatigue Fract. Eng. Mater Struct., Vol. 28, pp. 3-12, 2005
- (10) P. C. Paris and F. Erdogan, J. bas. Eng. Mater. Trans. ASME, Ser. D, 85, pp. 528-533, 1963
- (11) 菊池、和田ら、重合メッシュ法を用いた疲労き裂進展シミュレーション(第2報二つの段違いき裂の相互作用の検討)、機論A、74巻、745、2008

計算科学技術部会セッション

人工知能技術の活用と将来展望

Application of Artificial Intelligence Technologies and its Future Prospects

(2) 計算力学シミュレーションを機械学習に置き換える技術の基礎的検討

(2) Preliminary Study of Technology for Replacing Computational Mechanics Simulation
with Machine Learning*中林 靖¹, 増田 正人², 田村 善昭¹¹東洋大学, ²東京大学

1. 緒言

近年の第3次人工知能ブームもしくは深層学習(Deep Learning)ブームにおいては様々な先端的な手法が提案されているが、中でも画像認識コンペティション[1]や Google の猫[2]などに代表される畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)[1][2]を用いた画像認識技術、また、再帰型ニューラルネットワーク(RNN: Recurrent Neural Network)[3]およびそれを拡張した長期短期記憶(LSTM: Long Short-Term Memory)[4]を用いた時系列データの学習技術は大きな成功を収めている。

一方、数値解析分野では超大規模解析や連成解析、マルチスケール解析などの計算機パワーを活かした高精度解析や複雑形状の解析などが盛んに行われている[5][6]。しかし、超大規模解析や複雑な解析には多くの時間を要し、1 ケース数日から数週間も計算に時間がかかる場合もある。そこで、予めある程度の解析結果を知ることができれば、得たい情報の詳細な解析への手がかりを得ることができ、解析の試行回数削減により、トータルの解析時間の短縮につながると考えられる。

本研究では、深層学習を用いた解析結果予測を最終目標として、ある解析時刻の状態から次の時刻の状態を予測するネットワークを構築する。数値解析では、解析結果は物理量を節点上に持つため、空間的な意味合いが非常に重要である。そのため、従来の LSTM では取り扱えていなかった空間情報を考慮した学習モデルである Convolutional LSTM(ConvLSTM)[7]を用いる。ConvLSTM は動画像から未来の画像を予測するために開発されたネットワークであるが、ここでは空間情報を節点情報とし、物理量は Convolutional 層の入力チャンネルとして対応させることで解析結果の予測を行うことが可能であると考えられる。本稿では、数値解析結果予測のために ConvLSTM を用いることを提案する。今回は解析結果予測することが可能であるかを検討するため、解析結果の渦度と圧力場を可視化した画像を用いて学習を行った。可視化画像を用いることで解析結果の物理量の一部を表現することができ、コーディングの単純化と学習の高速化が図れる。学習済みモデルを用いて解析結果を予測し、正しい画像と比較し、提案方法の有用性を示す。

2. Convolutional LSTM [5]

時間的な状態情報をもとに未来の状態を推定する方法の一種に LSTM がある。LSTM は従来 1 次元の特徴量情報を再帰的に呼び出し、予測時の入力情報として入力データとマージして扱う。Convolutional LSTM(以下 ConvLSTM) では従来 1 次元の特徴量情報を 2 次元の Convolutional 層に拡張し、空間情報として過去の入力情報を記憶することができる。つまり、シーケンシャルに空間情報を追跡することが可能となる。ConvLSTM の各ゲート及び活性化関数を以下に示す。

ここで、 X は入力群、 H は隠れ層状態、 C は cell の出力を表し、 i, f, o はそれぞれ input, forget, output のゲートを表す。これらの変数は 3 次元のテンソルであり、時刻 t と 2 次元の空間情報(row, column)を有する。計算記号である "*" は畳み込み積、"! " はアダマール積を表す。

$$\begin{aligned} i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} ! C_{t-1} + b_i) \\ f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} ! C_{t-1} + b_f) \\ C_t &= f_t ! C_{t-1} + i_t ! \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \end{aligned}$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} * C_t + b_o)$$

$$H_t = o_t \cdot \tanh(C_t)$$

3. 検証実験

3.1 学習用数値解析データ

深層学習やニューラルネットワークの学習には大量の学習データが必要となる．一般的に ConvLSTM は画像データを入力し，画像データを出力する．本研究で用いる入力データも同様に解析結果を可視化した画像とし，出力データも解析結果を可視化した画像を用いる．この画像データを解析結果の物理量に置き換えることで，解析結果の物理量を予測することが可能であるが，簡単のため，今回は可視化画像データとする．解析モデルは 2 次元円柱周りの流体解析であり，計算領域を 1250×800 の直交等間隔格子を用いて解析を行った．解析手法は疑似圧縮性法を用い，離散化に 3 次精度風上差分を用いた．

学習データは解析結果の速度分布と圧力分布を可視化した画像データであり，100 ステップ毎に 1 枚の画像を生成し，300 枚の画像を収集した．画像サイズは 512×476 ピクセルで，256 階調のグレースケールで表現することで，Convolutional 層のチャンネルを渦度と圧力場の 2 チャンネルとしている．画像は円柱と円柱後流の流れ場が捉えられるように 200×100 のサイズでトリミングを行った．本稿では過去 4 フレーム分の入力を与え，1 フレーム後の未来の渦度ベクトル場と圧力場の 2 つの画像を予測するように学習データを生成した．

3.2 学習器の構成

本研究では，画像サイズ(200, 100)であり，入力画像は 渦度ベクトルと圧力分布の可視化グレースケール画像で，チャンネル数は(2)となる．すなわち，入力ベクトルは(200, 100, 2)となる．本ネットワークは入力層から ConvLSTM を 4 層積層させ，最上層では 3 次元の Convolutional 層を配置した 6 層のネットワークを構築した．Fig.1 に 1 チャンネル分のネットワーク構造を示す．ConvLSTM のカーネルサイズはすべての層で (3×3) とし，3 次元 Convolutional 層の入力は(20, 4, 200, 100)となり，カーネルサイズは $(3 \times 3 \times 3)$ とした．ストライドはすべての層で(1, 1)と(1, 1, 1)とした．損失関数はクロスエントリー，最適化には Adadelata を用い，誤差逆伝搬法に従って学習を行った．




Fig.1 Convolutional LSTM Network Structure

3.3 学習結果

予測画像を Fig.2 に示す．Actual は正しい画像であり，Predicted は Actual に示されるような画像を前 4 フレーム分入力に与えて予測画像を生成している．本稿では学習済みデータの予測結果を示したが，未学習の学習データでも同様の結果が得られた．また，出力画像を MES(mean square error)と SSIM(Structural Similarity Index Measure)で評価した(Table 1)．MES は画像にどれだけ差が生じているかの指標であり，値が大きいほど差が大きい．

4. 結言

本研究では ConvLSTM を数値解析結果の予測に用いる手法について提案し，予備的な実証実験を行った．以下に，得られた結果をまとめる．

- (1) 過去 4 フレームの解析結果の可視化画像を入力に与え，次フレームの可視化画像を生成することに成功した．
- (2) MES と SSIM で評価を行った．SSIM で 70%以上の類似度を示す結果が得られた．また，MES では 1

ピクセルあたりの誤差が比較的小さいことがわかった。

(3) 当然、このままでは予測精度が低すぎて、数値解析の代替手法とはなり得ないが、数値解析の次のタイムステップの近似値の予測に用いて、ソルバーの初期値に使い収束を早めるなどの応用方法が考えられる。








	t-1	t	t+1	t+2
Actual (Vorticity)				
Predicted (Vorticity)				

Fig.2 Prediction of Analysis Result using Convolutional LSTM

Table 1 Result of MES and SSIM

	t	t+1	t+2
MES (Vorticity)	357.922	361.254	322.959
SSIM (Vorticity)	0.728	0.722	0.723

参考文献

- [1] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks, NIPS2012, 2012.
- [2] Quoc V. Le, Marc'Aurelio Ranzato, Rajat Monga, Matthieu Devin, Kai Chen, Greg S. Corrado, Jeff Dean, Andrew Y. Ng, Building High-level Features Using Large Scale Unsupervised Learning, International Conference on Machine Learning, 2012.
- [3] Alex Graves, Abdel-rahman Mohamed, Geoffrey Hinton, Speech recognition with deep recurrent neural networks, IEEE International Conference on Acoustics, Speech and Signal Processing, pp.6645-6649, 2013.
- [4] Klaus Greff, Rupesh Kumar Srivastava, Jan Koutník, Bas R. Steunebrink, Jürgen Schmidhuber, LSTM: A Space Odyssey, arXiv:1503.04069, 2015.
- [5] Xingjian Shi, Zhourong Chen, Hao Wang, Dit-Yan Yeung, Wai-kin Wong, Wang-chun Woo, Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting, arXiv:1506.04214v2, 2015.

*Yasushi Nakabayashi¹, Masato Masuda² and Yoshiaki Tamura¹

¹Toyo University, ²The University of Tokyo

計算科学技術部会セッション

人工知能技術の活用と将来展望

Application of Artificial Intelligence Technologies and its Future Prospects

(3) 画像処理, AI 活用による原子炉検査の高度化

(3) Advancement of Nuclear Reactor Inspection with Image Processing and AI

*細谷 直樹¹¹(株)日立製作所

原子力プラントでは、炉内構造物の健全性確認や予防保全等のため、計画的に検査が実施される。健全性を十分に確保するためには点検規制に則った厳格な検査が必要である。この検査作業は熟練検査員の技量に依存するところがあり、そのノウハウの伝承が課題となっている。また、海外プラントの新設においても、国内と同様に信頼性の高い検査が必要である。そのため、検査を自動化、簡易化することによって、検査員の負荷軽減や工数低減、ならびに検査結果の信頼性確保に寄与できる技術が求められている。

本研究は、原子炉検査に画像処理や AI 技術を活用することにより、上記課題の解決を図るものである。以下、原子炉検査で行われる目視検査 (Visual Testing : VT) と超音波探傷検査 (Ultrasonic Testing : UT) への取り組みについて紹介する。

画像処理活用による VT 高画質化技術

炉内構造物に対しては主に VT を実施する。VT は水中カメラから得られる 40 万画素程度のカラー動画像を基に行われる。水中カメラの位置はカメラ操作者により制御され、順次、検査対象領域にカメラを移動させながらリアルタイムで検査を行っている。炉内は放射線場であり、画像には放射線ノイズが重畳する。また、炉内構造物の形状は複雑であり、狹隘部等では検査用の照明が十分でない場合がある。検査作業の負担軽減のため、検査画像の高画質化が求められている。

本研究では VT 高画質化技術を提案する。本技術は検査中の動画像を対象として、ソフトウェア処理により高画質化を施す。具体的には、放射線ノイズ抑制、信号強調である。また、提案法の実用化において処理のリアルタイム性が重要である。提案法を並列演算可能な専用プロセッサに実装することで、リアルタイム動画像処理を実現する。本技術により検査員は視認性の高い画像を基に作業を行うことができる。

AI 活用による UT 評価技術

原子炉構造物の溶接部に対しては UT を実施する。UT は、構造物の表面に超音波を送受信する探触子を押し当て、内部に超音波を伝搬させる。超音波は内部の欠陥や裏面で反射して戻ってくるため、これをエコーデータとして受信する。検査員はエコー波形を参照し構造物内部の状態を把握する。UT では溶接部付近に生じる亀裂を欠陥として判定する必要がある。欠陥と疑似とのエコーデータは類似しているため、欠陥の判定には検査員の技量が重要である。

本研究では、エコーデータから欠陥候補を自動識別する UT 評価技術を提案する。本提案は、熟練検査員の知識と、エコーデータの波形に基づく学習とを合わせた識別である。学習型識別には十分な学習データ量が必要であるが、原子力プラントの供用開始後に欠陥が生じることは少ない。学習データ量を増やすため、エコーデータ合成によるデータオーグメンテーション手法を考案した。本技術により検査員の欠陥判定に有用な情報を得ることができる。

*Naoki Hosoya¹¹Hitachi Ltd.