

# AIによる検査計測技術の向上

## 1. はじめに

当社では、検査・計測の作業の効率化を目指し検査・計測システムを開発している。それらのシステムを開発するにあたり画像処理技術を適用してきた。近年、検査・計測における画像分析では、より高度な分析が求められるようになり、従来の画像処理技術単独では対応することが難しくなりつつある。このため、画像処理にAI（人工知能：Artificial Intelligence）の技術を取り入れることで、より効率的な画像分析の実現を図った。

本稿では、当社で取り入れているAI技術を紹介する。

## 2. AIを実現するDeep learning

AIを実現するための手法であるDeep learning（深層学習）の適用は、2011年に音声認識の研究分野において、従来の手法では超えられなかった性能の限界を上回り、大幅な性能改善を実現した<sup>(1)</sup>。また、この技術は、2012年に画像処理の研究分野の大規模な物体認識のコンペティションにおいても、大幅な性能改善を実現した<sup>(2)</sup>。これによりAIは、Deep learningの有効性が確認され、広く普及するようになり、画像認識や音声認識にとどまらず、自然言語処理や予測、異常検知などさまざまな分野への適用が進んでいる。

従来の画像処理では、作業員が入力データからエッジの強さや向きなどの特徴的な情報（特徴量）を抽出して認識するという方法を取っていた。しかしその手法では複雑な画像に対応することは困難であった。これに対し、画像処理にDeep learningを適用する方法では、大量のデータから共通する

認識に必要な特徴量を抽出して「学習」することができるため、複雑な画像に対しても高精度な認識ができるようになる。

当社では、これらのDeep learningによる画像処理を用い検査・計測画像を分析する技術を開発した。これらの高度な画像分析のために適用したAI技術について説明する。

### 2.1 AIの構造

当社では、図1のような入力層－出力層を数層も重ねたネットワーク構造を採用し、入力データをネットワークに流して認識結果を出力させることで、AIを実現している。また、AIが複雑な画像に対して認識処理を実施できるように、図2のような入力データである画像からエッジなどの隣り合う画素の特徴を抽出することができる畳み込み処理（フィルタ処理）を含む、さまざまな処理を複数組み込んでネットワークを深くしている。

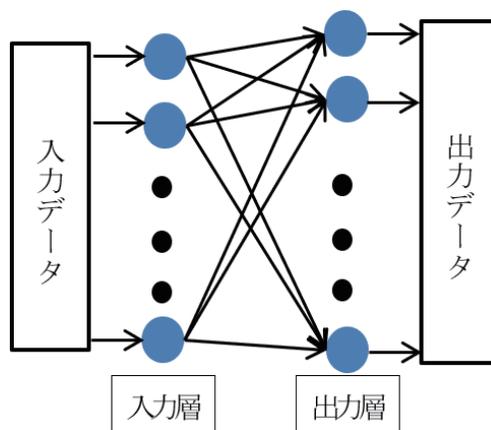


図1 ネットワーク構造の1要素

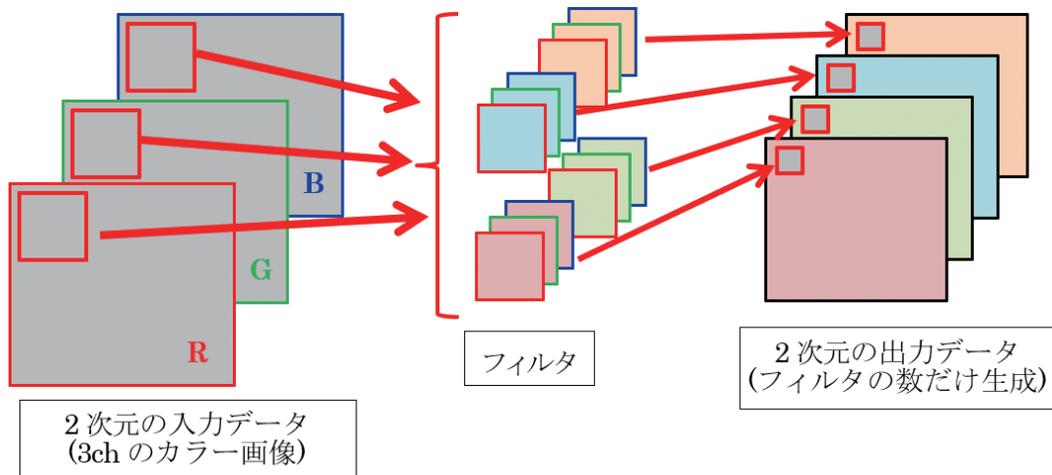


図2 畳み込み処理

## 2.2 少数のデータでの AI 開発

一般的な AI 技術では、入力データと正解ラベルをあらかじめ用意し、入力データをネットワークに流して得た出力値と正解ラベルとの誤差をできる限り小さくなるよう、ネットワークの各パラメータを調整することで AI を構築する。AI の技術は一般的には、数千もの大量の入力データと正解ラベルを用意して「学習」をさせることで、大量のデータから共通する認識に必要な特徴量を抽出することができ、さまざまな検査画像を適切に認識できる高度な性能を有する AI を開発できると言われている。しかし本開発では、検査・計測作業に用いるデータを大量に用意することは容易ではなく、少ないデータ数でも効率よく「学習」できるようにするため、2.2.1 項から 2.2.3 項で示す技術を取り入れている。

### 2.2.1 加工したデータを加える

画像を適切に認識できる高度な AI を構築するためには、データを大量に用意できることが理想的であるが、データ数が数百程度しか用意できない場合もある。本開発では、用意できたデータに対して加工を施したデータも学習用のデータとし

て使うことで、データ数を増やす手法を採用している。具体的には、画像の上下・左右反転や回転、画像をゆがませ傾けさせる、色調の調整などがあり、データ数を数倍に増やすことが可能である。

### 2.2.2 データの一部を欠損させる

一般的な AI 技術では、学習用のデータをすべてネットワークに入力して「学習」を数十から数百回繰り返すことで、データを認識できる AI を構築する。

しかし、繰り返しデータを入力して「学習」をさせる際に、ネットワークが学習用のデータに合わせたパラメータ調整をしすぎて、他のデータを正しく認識できない現象(過学習)が起こることが知られている。その現象を防ぐために、「学習」する際にデータの一部を欠損させる処理をネットワークに組み込ませた。例えばデータをネットワークに入力して「学習」する度にランダムにデータの一部を欠損させることで、同じデータでありながら毎回異なるデータであるかのように構築した。この方法を用いた AI は汎用性(用意したデータ以外のデータにも正しく認識できる)を高められることが期待できる。

### 2.2.3 転移学習を適用する

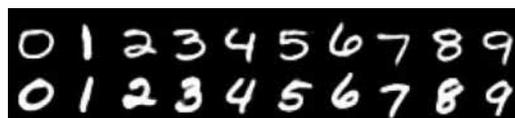
転移学習は、あらかじめ認識対象のデータとは異なるものの非常に数が豊富なデータセットで「学習」したネットワークに、認識対象のデータを入力して「学習」をする方法である。データ数が非常に豊富なデータで「学習」をすることで、データから特徴量を適切に抽出できるネットワークを構築できるため、データ数が少ない認識対象のデータで適切な特徴量を抽出してAIが適切に認識できることが期待できる。

しかし転移学習で認識精度を改善するには、認識対象のデータと類似したデータが必要になる。**図3**はX線検査装置で撮影したグレースケール画像を認識対象とした例である。これらの画像の認識精度を向上させるため、データ数が非常に豊富な風景や動物などのカラー画像のデータセットを用いて転移学習を適用したが、実現することはできなかった。これは、認識対象のX線画像と自然画像との違いが大きく、自然画像のデータセットの「学習」でX線画像の認識に必要な特徴量を抽出できなかったのが原因と考えられる。

一方、**図4**は渦電流探傷試験(ET)のデータの例である。ここでは、MNISTと呼ばれる手書き数字の画像データセットを用いた転移学習を適用し



(a) ETで取得したデータ



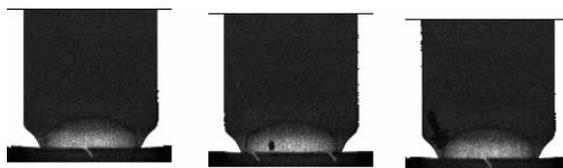
(b) MNISTの手書き数字画像

図4 ETの入力データと転移学習で用いた手書き数字画像

た。MNISTは、0～9までの手書き数字の白黒画像を集めたデータセットであり、ET探傷で取得したデータは白黒画像に変換してAIに入力することから相性は良い方と考えられる。MNISTは学習用データが60,000枚、検証用データが10,000枚用意されており、それらの豊富なデータを転移学習に用いることにより、ETの学習では、AIの認識率を約8%向上させることができた。

### 2.3 入力データに対する画像処理

AIによる画像処理では、Deep learningを適用することで、大量のデータから共通する認識に必要な特徴量を「学習」により抽出できるが、学習データ数が少ない場合にも、認識に必要な特徴量の抽



(a) 飲料の入った缶をX線で撮影した画像（右2枚の缶底に異物が混入している）



(b) 転移学習で用いた自然画像データセット

図3 X線で撮影した画像と転移学習で用いた自然画像

出漏れを無くして AI の認識性能を向上させるため、入力データの他に入力データに対する画像処理を施し生成したデータもネットワークに入力するという手法を検討した。

さらにエッジを強調する画像処理を適用することにより、AI が入力データの薄いエッジも認識できるようになり、認識精度が向上した。

## 2.4 AI ネットワークの自動生成

これまでに当社では、AI を開発してきた。しかし、今まで AI の開発に用いた学習用データは数百程度と、データ数が少ない。そのため検査・計測事業の業務では、新たに取得したデータも学習用データに加えて再学習を実施し、AI の認識性能を改善し続けていく必要がある。そのためには、検査・計測の業務担当者が新たなデータを用い AI の改善を図る必要がある。

そのため、AI 開発・プログラミングに不案内な検査・計測業務の実施担当者でも AI の開発・改善ができるようにするため、指定のフォルダに格納されているデータを用いて自動的に「学習」するプログラムを開発した。図 5 に示すこのプログラム

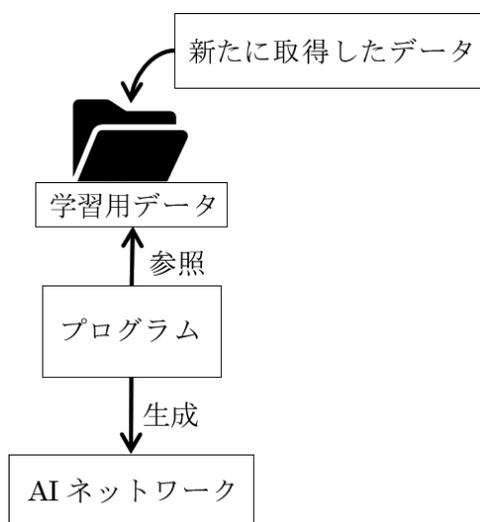


図 5 AI ネットワークの自動生成

は、AI 開発担当者以外の人でも AI ネットワークの生成が容易にでき、専門家による AI 開発・改善を必要とせずに AI ネットワークを生成することを可能としている。これにより、検査・計測業務などで新たに取得したデータをすぐに AI ネットワークに反映させ AI の認識性能を改善し続けられる。

## 3. これらの AI 技術の適用

### 3.1 Mobile EDDy® の AI 判定機能

携帯型渦流探傷装置 Mobile EDDy® 向けに開発した AI について紹介する。

転移学習などさまざまな技術を適用した結果、96.6%の認識精度を得られた。特に、傷がある箇所のデータを入力して「傷なし」と誤判定されるケースが少なくなっており、傷を見逃さないという観点において良好な結果を得られた。今後も継続的にデータを追加してデータ数を増やし、再学習を実施することで AI ネットワークを改善し、AI の安定性と認識性能の向上が期待できる。

### 3.2 作業時間の短縮

以前、検査・計測業務の実施担当者の負荷を軽減し作業時間を短縮するために、画像処理で検査・計測結果の画像を分析するソフトウェアを開発したが、画像ごとに画像処理パラメータを調整する必要があり、手間がかかるために実用には至らなかった。

そこで、画像処理のパラメータを調整する手間を無くして認識性能を向上させるため、AI を取り入れたソフトウェアを新たに開発した。そのソフトウェアは、画像を入力するだけで分析を実行できるようになっており、ユーザによる認識結果の修正もできるようにすることで、計測作業にかかる時間を約 50%短縮することができた。

このように画像認識と AI との組み合わせを、今

後も継続して AI の認識性能を改善することで、さらに作業時間の短縮と、作業員の負担軽減を図る。

#### 4. まとめ

当社では、検査・計測作業の効率化を目的としたシステムの開発をしており、画像分析機能の実現のために画像処理を適用している。

また、近年の高度な画像認識のニーズに対応するため、これまでに蓄積してきた AI 技術を適用しながら、画像処理と AI 技術とを連携したシステムを開発している。例えば Mobile EDDy® 向けの AI において認識精度 96.6% を得ることができた。また計測作業を自動化するための AI 適用ソフトウェアの開発では、作業時間を約 50% 短縮する成果が得られた。

AI 技術は日々進歩していることから、新しい AI 技術への挑戦と、画像処理と AI の連携技術の模索とを实践することが重要であり、今後も認識精度の改善と他案件への適用を視野に入れ開発する。

#### 文責

制御システム事業部 産業システム部  
製品・サービスグループ 畑 伸佳  
制御システム事業部 産業システム部  
製品・サービスグループ 部長 花形 徹

#### 参考文献

- (1) G. E. Hinton, L. Deng, Y. Dong, G. E. Dahl, A. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. N. Sainath and B. Kingsbury : Deep Neural Networks for Acoustic Modeling in Speech Recognition, Signal Processing Magazine, 2012, pp.82-97
- (2) A. Krizhevsky, S. Ilya, and G. E. Hinton : ImageNet Classification with Deep Convolutional Neural Networks, In Advances in Neural Information Processing Systems (NIPS) , 2012, pp.1097-1105