

技術動向レポート

# AIによる外観検査

情報通信研究部  
コンサルタント 橋本 大樹

## 1. はじめに

人手不足の深刻化や働き方改革が叫ばれる中、製造現場における製品検査の省人化は重要性を増している。また With/After コロナの世界において、新型コロナウイルスの感染症対策としても、その重要性は今後ますます拡大していくと考えられる。そのような状況の中、近年大きく発展を遂げている深層学習(ディープラーニング)をはじめとした人工知能(Artificial Intelligence、AI)による製品検査の自動化は注目すべき技術と考える。

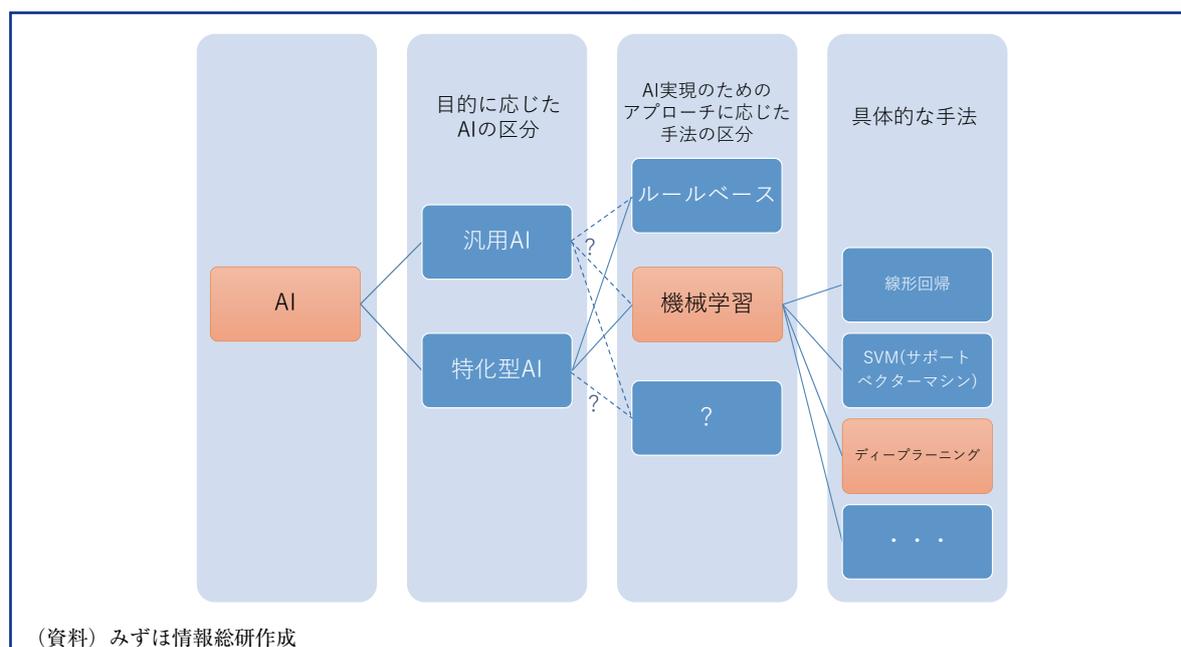
本稿では、はじめに AI や機械学習、ディ-

ープラーニングについて概説する。その上で、AIによる外観検査の現状および AI の普及拡大に向けて注目される技術の一端について、当社での研究開発事例を交えて紹介する。

## 2. AI と機械学習、ディープラーニング

筆者の考える AI と機械学習、ディープラーニングの関係性を図表1に図示する。AI (の中でも特化型 AI) を実現するためのアプローチに応じた手法の区分の1つが機械学習であり、さらにその機械学習の具体的な1手法がディープラーニングである。ただし人によりルールベース手法が AI に含まれるか等、図に示した関係

図表1 AI と機械学習・ディープラーニングの関係性



性と定義や認識が異なることがある。本章では、AI、機械学習、ディープラーニングについてそれぞれ概説する。

## (1) AI

AIには様々な定義があり、専門家においてもその立場により定義に差異があるものの、その目的の観点から大まかに汎用AIと特化型AIの2種類に分類することが出来る。

### ① 汎用AI

汎用AIは、特定の分野・用途に限定されることなく、様々な課題を処理可能なシステムのことをさす。例えば、SF小説の中に登場する会話や判断が出来る人型ロボットなどでイメージされるAIはこの汎用AIの1種と考えられる。汎用AIでは、事前に想定された条件からはずれた状況においても、ある程度は能力を応用して問題を正しく処理できるとされているが、筆者が知る限り実現には至っていない。

### ② 特化型AI

特化型AIは、特定の分野・用途に限定して性能を発揮するAIのことをさす。画像認識や音声認識・自然言語処理など、さまざまな分野において特化型AIの研究が進んでおり、一部では人間の判断能力を超える精度を達成している。例えば囲碁やチェスにおいてAIがトッププレイヤーを打ち破るといった出来事は、記憶に新しいであろう。

近年、特化型AIは目覚ましい性能向上を遂げ、外観検査を含む多くの分野で関心を集めている。本稿においても主に特化型AIのトピックについて取り上げる。

## (2) 機械学習

特化型AIを実現するための現状の手法は、そのアプローチに応じて、ルールベースと機械学

習の2つに大別することが出来る。

### ① ルールベース

ルールベースとは、明示的に人間がルールを与え、これに基づいて予測・識別する手法の総称である。既に予測・識別のためのルールや判断基準が確立している作業を自動化する場合などに適しているが、人間がルールを把握していない事象、あるいは明確な判断基準を定義できない事象に対する予測・識別の精度は低い。

### ② 機械学習

機械学習とは、事前にデータの特徴を学習することにより、予測・識別における人間の判断基準を自動的に法則化する手法の総称である。機械学習では、教師データとして人間の判断結果を大量に用意し、コンピュータで同様の予測・識別結果を得られるように学習する。データをもとにコンピュータが判断のルールを学習するため、判断基準が明確でない事象の予測・識別に対しても適用できる。データを十分に用意できる場合には、予測・識別を精度良く行うことができるが、データが不十分な場合には性能を発揮できない。また、学習で与えたデータから大きく外れるデータに対しては、一般的に精度が低下する。

## (3) ディープラーニング

ディープラーニングとは機械学習の1手法であり、生物の神経細胞のモデル化を目指した研究に端を発したニューラルネットワークにより予測・識別を行うものである。ニューラルネットワークは、層(Layer)と呼ばれる演算処理モジュールを組み合わせで構成される。入力から出力へ層が一直線につながる単純な構造から枝分かれや再帰構造をもつ複雑な構造まで、目的とするタスクに応じてさまざまなニューラルネットワーク構造が提案されている。大量のデータと豊富な計算資源が必要となるものの、近年の

計算機の性能向上と並列化などによる計算効率の向上に支えられ、活用が進んでいる。

ディープラーニングが注目を集め始めたきっかけの1つが、2012年の画像認識の国際コンテスト ImageNet Large Scale Visual Recognition Challenge 2012 (ILSVRC 2012)である。同コンテストの分類部門において、画像の1000クラス分類を競い、評価基準として上位5つの候補クラスの中に正解クラスが含まれていない割合である Top5エラー率が使われた。このコンテストで、ディープラーニングを用いない機械学習手法を用いたチームの Top5エラー率が26.2%以上であったのに対し、ディープラーニングを利用したチームは約16.4%の Top5エラー率を達成した<sup>(1)</sup>。さらに2015年には、人間の Top5エラー率といわれる5.1%<sup>(2)</sup>よりも低い4.94%という数字を達成する<sup>(3)</sup>など、急速に研究が進んでいる。2010年代以降、ディープラーニングは画像分野以外の機械翻訳や対話プログラム、コンピュータ囲碁など様々な分野に応用され、進化を続けている。

ディープラーニングの研究が急速に広まった理由の1つは、様々な分野の課題で得られた知見が共有可能であり、応用可能性が高いためと筆者は考えている。例えば、画像から工業製品の欠陥を検出する課題と、手書き文字を認識する課題は、入力データが画像である点は共通しているが、まったく別の課題である。それにもかかわらず入力データが画像データであるという共通点があるために、どちらに対しても多くの場合畳み込み層と呼ばれる層が有効に作用することが可能な層であり、学習によって決定されたエッジ強調フィルタや平滑化フィルタなどのフィルタ処理を行う。現在、画像データに対する畳み込み層のように、データの種類や予測・推定する内容に合わせて様々な「層」が研究・

提案されている。ディープラーニングはそれらの層を組み合わせることで多種多様な課題に対応が可能となるため、高い応用可能性を持つ。

### 3. AI による外観検査の現状

本章では、外観検査の分野において AI に要求されるタスクについて概説したのちに、AI を外観検査に適用した当社の研究開発事例について紹介する。

#### (1) 外観検査におけるタスク

外観検査において AI に要求されるタスクは、画像分類、物体検出、領域分割(画像セグメンテーション)の3つに大別できる。一般に後者ほど精度や処理時間の観点での難易度が高く、またアノテーション<sup>(4)</sup>作業のコストも大きくなるため、これらを考慮して AI で実現するタスクを決定することが必要である。

##### ① 画像分類

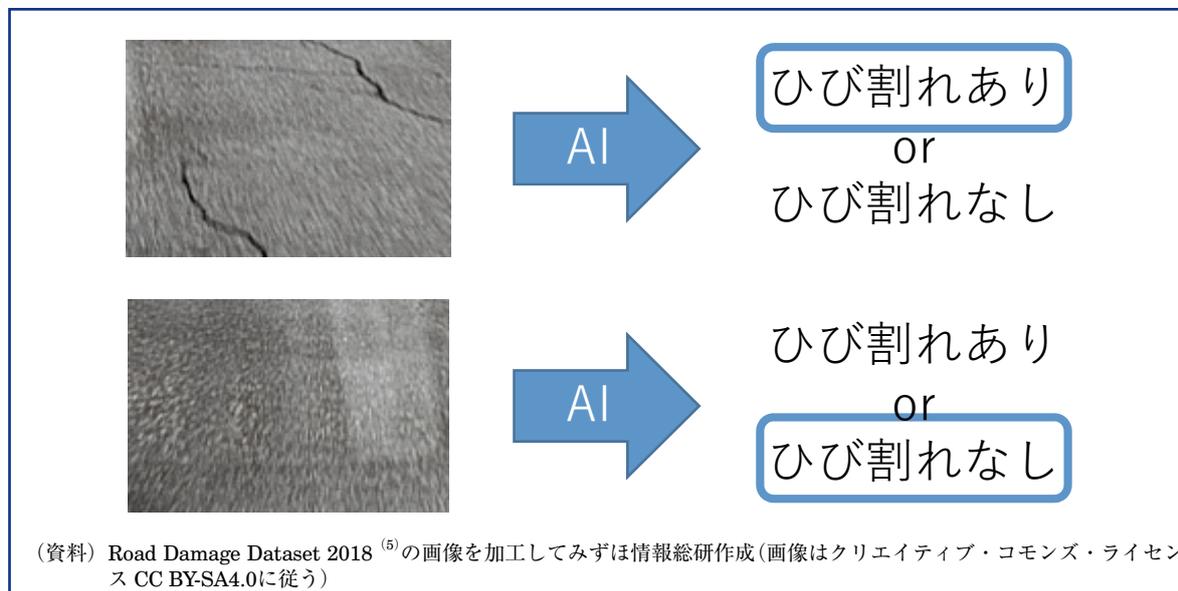
画像分類は一枚の画像全体に対し、その画像があらかじめ設定されたカテゴリの中のどのカテゴリに属するのかを判断するタスクである。画像に写っている製品の中に不良品が含まれているかどうかを判断することはこのタスクに相当する。

例として路面画像からのひび割れ検出に画像分類を適用した場合、事前に「ひび割れあり」「ひび割れなし」の2つのカテゴリを人間が設定し、AI は図表2のように各画像がどちらに属するかを判断する。

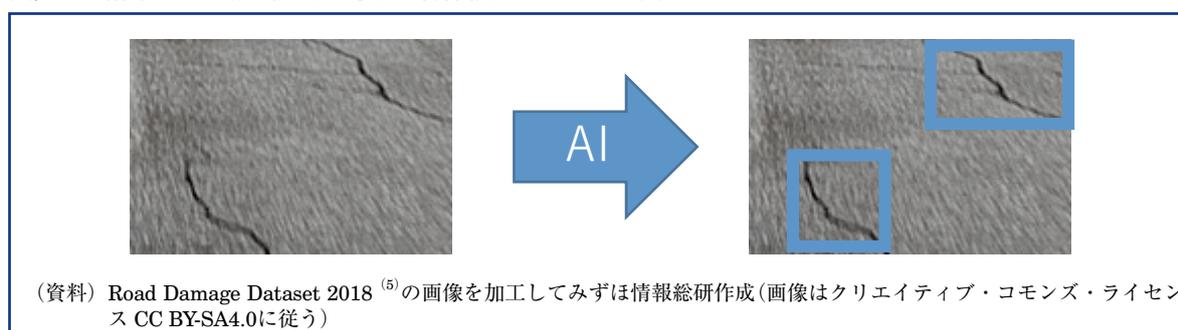
##### ② 物体検出

物体検出は特定カテゴリの物体や部位が、画像中のどの領域にあるのかを判断するタスクである。例えば画像中から、特定の部品や欠陥箇所の位置を特定することはこのタスクに相当する。

図表2 路面のひび割れ検出に対する画像分類のイメージ図



図表3 路面のひび割れ検出に対する物体検出のイメージ図



路面画像からのひび割れ検出に物体検出を適用した場合、図表3のようにAIはひび割れの存在する矩形領域を検出する。

### ③ 領域分割(画像セグメンテーション)

領域分割は画像中の各画素に対して、写っている物体のカテゴリを推定するタスクである。欠陥の位置だけでなく欠陥の形状まで推定する必要がある場合にはこのタスクが必要になる。ひび割れのように、欠陥のサイズや形状が多様で、どこからどこまでがひとまとまりの欠陥なのか明確でないようなものを検出する場合も、領域分割が適していることが多い。

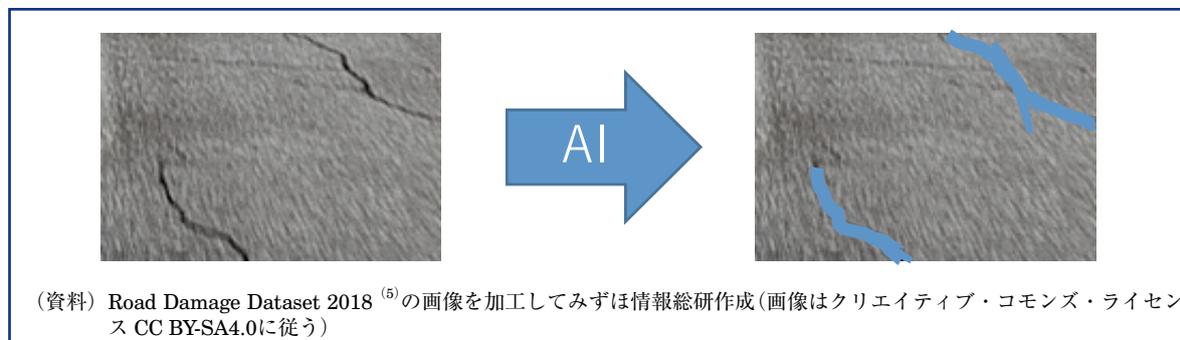
路面画像からのひび割れ検出に領域分割を適用した場合、図表4の青色で塗りつぶした領域のように、AIはひび割れの位置を画素単位で検出する。

### (2) X線CT画像からの鑄巣の検出事例

AIを外観検査に適用した当社での研究開発事例の1つとして、精密工学会画像応用技術専門委員会が主催する外観検査アルゴリズムコンテスト2019での、X線CT画像からの鑄巣検出を紹介する。

鑄造製品の内部に発生する鑄巣とよばれる空洞欠陥を、X線CTによる撮影画像から検出す

図表4 路面のひび割れ検出に対する領域分割のイメージ図



図表5 入力画像と鑄巣領域の正解ラベル・推定ラベル

	入力画像	正解ラベル	推定ラベル
例 1			
例 2			

(資料) 外観検査アルゴリズムコンテスト2019の検証用データを用いてみずほ情報総研作成(各鑄巣の色付けはランダムで行っているために、正解ラベルと推定ラベルの色は対応していない。)

ることにより、鑄造製品内部の非破壊検査が可能となる。鑄巣の位置や形状を正確に推定する必要があるため、この課題は領域分割(画像セグメンテーション)に分類される。

当社は、X線CT画像から鑄巣を検出するためのディープラーニング手法として、新しいニューラルネットワーク構造を提案した<sup>(6)(7)</sup>。このニューラルネットワークでは、画像の特徴を抽出する層を分岐させたことにより、低解像

度と高解像度の双方の特徴抽出を行うことができる。低解像度の特徴抽出構造により大域的なつながりを、高解像度の特徴抽出構造により鑄巣の詳細な形状を考慮することが可能となり、このニューラルネットワークを用いることで、図表5のように鑄巣の大域的な領域の連続性を保ちつつ細かな形状の推定が可能となった。図表5の入力画像の列は、X線CTによる撮影画像であり、明るい色の正方形部分が鑄造製品、内

部の色の濃い部分が鑄巣を表している。また正解ラベルの列はコンテストで正解として提示された鑄巣領域を、推定ラベルの列は当社の手法で推定した鑄巣領域を示している。正解ラベルと推定ラベルにおいて、同じ色で塗られた鑄巣は3次的につながつた空洞であることを表しているが、色はランダムに割り当てているために、正解ラベルと推定ラベルの色は対応していない。

この手法は、外観検査アルゴリズムコンテスト2019にて最高精度を達成し、最優秀賞を受賞した。

#### 4. AIによる外観検査の普及拡大に向けての課題と期待される技術

AIによる外観検査の実用化に際しては、現場の状況に応じて、解決しなければならない課題が数多く存在する。本章では、外観検査の実用化において課題となることの多い、異常データ不足とAIの推論根拠のブラックボックス化という2つの課題について取り上げ、各課題を解決できる可能性がある手法として関心が集まっている技術について紹介する。

##### (1) 半教師あり異常検知

外観検査による異常検知においては、歩留まりが高く異常データを多く収集できない場合や、発生し得るすべての異常パターンの収集が困難な場合があり、異常データを大量かつ網羅的に取得することが困難であることが多い。このようなケースにおいて、正常データのみを学習させて正常／異常データを判別する半教師あり<sup>(8)</sup>異常検知(1クラス分類、良品学習)と呼ばれる手法が考案されている。

半教師あり異常検知手法の1つに、画像の次元削減及び再構成を利用した方法がある。初めに画像データの特徴を保持しつつデータの成分

数を減らす次元削減構造と、その次元削減したデータから元の画像を作成する再構成構造の2つの構造を、正常データのみを用いた学習により構築する。この2つの構造は、正常データが元の画像に再構成されるように構築するため、正常データの次元削減・再構成に特化した構造となる。この次元削減・再構成構造に異常データを入力すると、再構成前後で異常個所の画像が変化して正常データに似た画像に再構成される傾向がある。これを利用し、再構成前後の差分である再構成誤差を評価することで良品か不良品かを判別するという仕組みである。

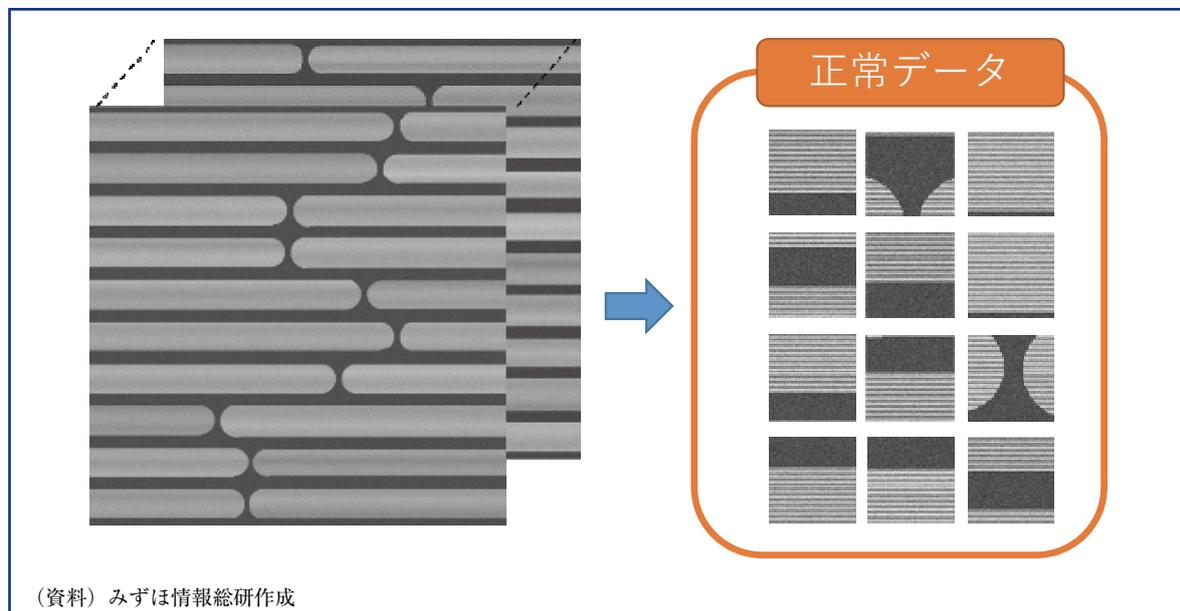
当社においても、画像の次元削減及び再構成構造に、Auto Encoder<sup>(9)</sup>やpix2pix<sup>(10)</sup>等、ディープラーニング手法を利用した場合の異常検知の性能について検証を進めている。ここでは、画像の次元削減及び再構成構造としてpix2pixを用いた場合の異常検知の検証事例<sup>(11)</sup>を紹介する。図表6に例示した電子基板を模した正常データに対してpix2pixを用いて次元削減・再構成構造を学習したところ、図表7に例示したシミ状欠陥および糸くず状欠陥の2種類の異常データに対し、正常な背景パターンはそのままに欠陥部分のみが消えた再構成画像が得られた。図表8にその1例を示す。この構造を利用し再構成誤差の評価による判別を行ったところ、ROC-AUC<sup>(12)</sup>がシミ状欠陥に対して0.934、糸くず状欠陥に対して0.948を達成し、異なる傾向をもつ2種類の異常に対してともに高い異常検出性能が得られた。

この事例では良品形状があまり複雑でない等、限定的な条件下ではあるものの、実用化に向けた今後の発展に期待が出来る技術と考えている。

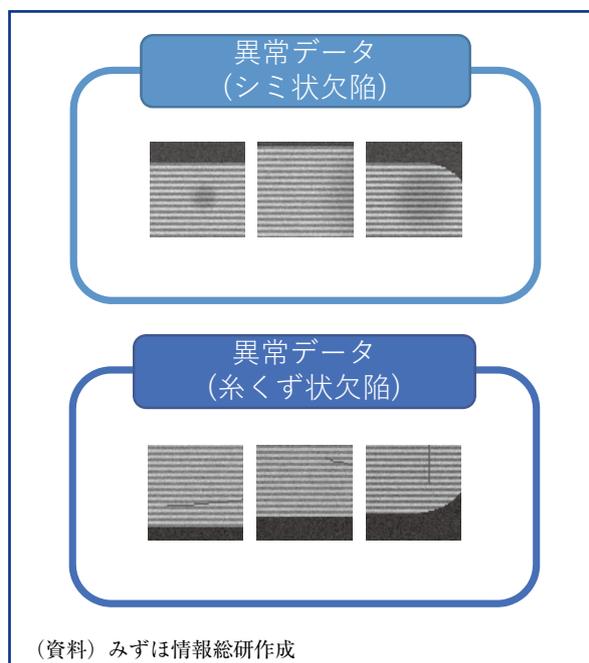
##### (2) 説明可能なAI

機械学習手法を用いたAIの実用化に際しての課題の1つに、AIが予測・識別した推論根拠

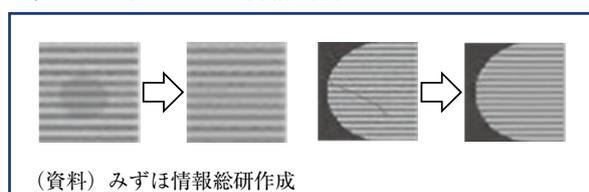
図表6 電子基板を模した画像(正常データ)



図表7 電子基板を模した画像(異常データ)



図表8 異常データの再構成例



が分からないという、推論根拠のブラックボックス化があげられる。特に複雑な判断をおこなえるディープラーニングではその傾向が強い。実用においては、推論の根拠が説明できない手法を使用することに対する抵抗感は強く、推論の根拠が明確な手法が好まれることが多い。推論の根拠を目に見える形で確認することができれば、不信を払しょくするだけでなく、精度向上に向けた有用な情報になりうる。この課題を解決するため、説明可能なAI (explainable AI、XAI)と呼ばれる、推論根拠が説明可能なAIに関してさまざまな研究が行われている。

当社では、機械学習による胸部X線画像の異常検知の実用化に向けた共同研究を公立大学法人福島県立医科大学とすすめており<sup>(13)</sup>、その中で説明可能なAIについての検討も行っている。この共同研究は、読影医の負担を軽減し、疑い例に対する読影時間を今以上に確保することを目的として、ディープラーニングを用いてX線画像から肺がんの疑いがあるものを推定する取

り組みである。福島県保健衛生協会から提供を受けた853枚(正常401枚+肺がん疑い452枚)の胸部X線の画像データを教師データとして用い、DenseNet<sup>(14)</sup>を改良したディープラーニング手法により肺がん疑いを推定して、ROC-AUC<sup>(12)</sup> 0.80を達成した。この数値は、実用に向けてはまだ不十分な精度ではあるものの、同じくディープラーニング手法を用いて肺疾患の推定を試みた Rajpurkar らの先行研究<sup>(15)</sup>における、(X線画像での見え方が肺がんに近い)結節の検出精度 ROC-AUC 0.78に匹敵するものである。実用的な精度の達成に向け、引き続きデータの拡充や医学的知見の活用を予定している。

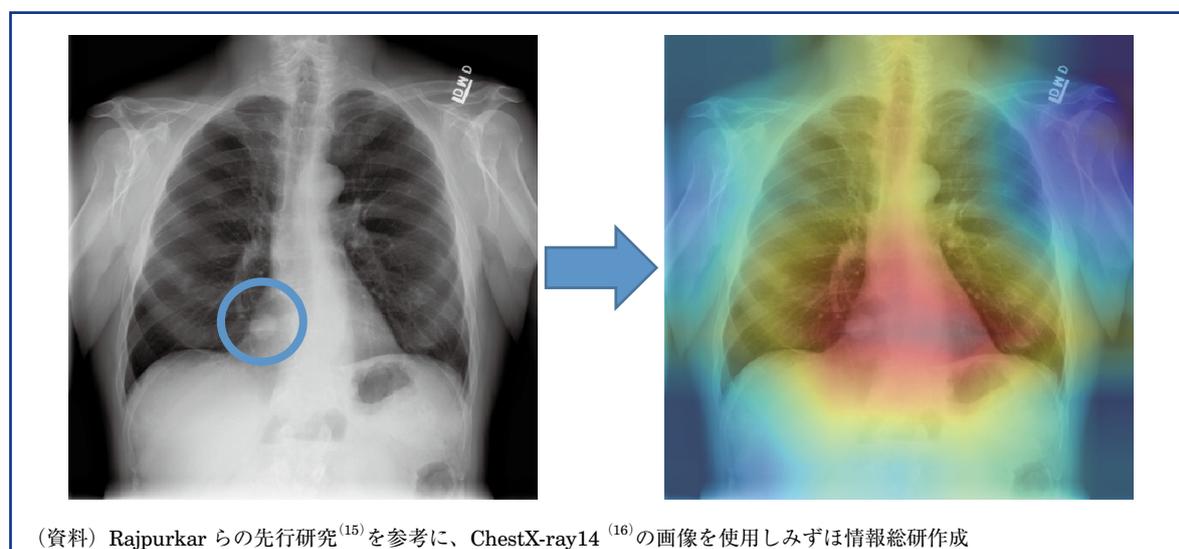
この共同研究においては、Rajpurkar らの先行研究<sup>(15)</sup>を参考に説明可能なAIの1手法であるCAM (Class Activation Mapping)を利用してディープラーニングの判断における注目領域の可視化を試みた。

図表9の左側の画像は、ChestX-ray14<sup>(16)</sup>にて結節と分類されているデータであり、当社の試行においても疾患の疑いがあると判定されたものである。読影医により疾患の疑いがあると判

断された領域を青丸で示した。同じ画像を入力としてAIが判定の際に着目した領域をCAMにより可視化した結果が図表9の右側の画像である。青色部分は反応が弱い部分、赤色部分は反応が強い部分である。肺の疾患の疑いがあると読影医によって判断された箇所にAIが強く着目していることが確認できる。ただし、AIの着目範囲は読影医の判断箇所よりも広く、この差異について、「AIの判断は不十分である」と捉えるか、実は人間も無意識のうちに周囲の箇所との比較により判定しているため「AIの判断は十分である」と捉えるか、これ以上の考察は難しい。

実のところCAMをはじめとする解釈可能なAI手法は、推論根拠を少しでも可視化しようとする試みとして高い注目を集めている一方で、本当に正しく可視化できているのかについても多くの手法で議論が続いており、課題は多い。機械学習手法を理解するための足掛かりとなる「これから」の技術として、説明可能なAIに対する最先端の技術をキャッチアップし、検証を続けることが必要だと筆者は考えている。

図表9 異常検知の可視化例



## 5. おわりに

本稿では、AIや機械学習、ディープラーニングについて概説した上で、AIによる外観検査の現状およびAIの普及拡大に向けて注目される技術の一端について、当社での研究開発事例を交えて紹介した。さまざまな分野でAIの活用が広がっている一方で、寄せられる期待も広がり、これまで以上の付加価値を持つAIが求められている。

With/After コロナの世界において、今後も外観検査の自動化の需要は増加していくと考えられる。現状、AIの利用にあたっては、その課題や特徴を「人間」が理解した上で、いかにツールとして有効に活用するかを「人間」が見極めることが必要である。本稿がAI導入への理解の一助になれば幸いである。

### 注

- (1) Olga Russakovsky\*, Jia Deng\*, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, Alexander C. Berg, Li Fei-Fei. (\*=equal contribution) "ImageNet Large Scale Visual Recognition Challenge." IJCV, 2015.
- (2) Russakovsky ら<sup>(1)</sup>によると、人間による分類精度の検証において、事前に評価データ以外のデータで分類に関して訓練した上で、被験者の一人が Top5 エラー率5.1%を達成している。ただしコンテストの評価データは10万枚と画像枚数が多く、上記の検証するには評価データの一部1500枚のみを使用しているため、この精度は参考数値となる。
- (3) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification." IEEE International Conference on Computer Vision (ICCV), 2015.
- (4) あるデータに対して、関連する情報を付与する作業。機械学習の分野では、主に画像やテキスト、音声などの学習に用いるデータに意味づけを行い、教師データを作成することを指す。
- (5) 被害状況がアノテーション済みの道路撮影画像のデータセット。データセットの画像は、Creative Commons Attribution-ShareAlike 4.0

International License (CC BY-SA 4.0)のライセンスの下で公開されている(<https://github.com/sekilab/RoadDamageDetector#license-1>)。Hiroya Maeda, Yoshihide Sekimoto, Toshikazu Seto, Takehiro Kashiya, Hiroshi Omata, "Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images." Computer-Aided Civil and Infrastructure Engineering.

- (6) 橋本大樹, 水谷麻紀子, 杉原裕規, 松下裕也, 永田亮, 重信薫, 永田毅, "U-Net ベースの新しいニューラルネットワーク構造による鑄巣検出." 外観検査アルゴリズムコンテスト, 2019.
- (7) みずほ情報総研, "AI (人工知能)・機械学習の技術開発・コンサルティング開発事例2【事例2】X線CT画像からの鑄巣(空洞欠陥)の検出." <https://www.mizuho-ir.co.jp/solution/research/telecom/system/machinelearning/ex02.html>
- (8) 異常検知の分野における慣習に法り、ここでは正常データのみを用いて学習する手法を「半教師あり」と表現している。一般に「半教師あり」は、教師データに少量のアノテーション実施済みデータと、大量のアノテーション未実施データが含まれる場合の学習手法のことを指すことが多い。
- (9) Geoffrey E. Hinton, Ruslan R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks." science 313.5786 (2006) : 504-507.
- (10) Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks." Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. 2017.
- (11) 橋本大樹, 永田毅, "深層学習・機械学習を取り入れた外観検査." 第34回エレクトロニクス実装学会春季講演大会, 官能検査システム化技術 5B1-04, 2020.
- (12) 横軸に偽陽性率(陰性データのうち、陽性と予測したデータの率)、縦軸に真陽性率(陽性データのうち、陽性と予測したデータの率)を取る受信者動作特性(receiver operating characteristic, ROC) 曲線の下側面積(area under the curve, AUC)。二値分類における評価指標であり、0から1の値を取る。1に近いほど分類の精度が高く、完全ランダムの場合0.5となる。
- (13) みずほ情報総研, "肺がん検診における AI 実用化に向けた共同研究を開始." <https://www.mizuho-ir.co.jp/company/release/2019/medicheck0729.html>
- (14) Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger "Densely connected convolutional networks." arXiv preprint arXiv:1608.06993, 2016.

- (15) Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Curtis Langlotz, Katie Shpanskaya, Matthew P. Lungren, Andrew Y. Ng, "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning." arXiv preprint arXiv: 1711.05225, 2017.
- (16) National Institutes of Health (NIH)のNIH Clinical Centerにより提供されている胸部X線データセット (<https://nihcc.app.box.com/v/ChestXray-NIHCC>)。Xiaosong Wang, Yifan Peng, Le Lu, Zhiyong Lu, Mohammadhadi Bagheri, Ronald Summers, "ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases." IEEE CVPR, pp. 3462-3471, 2017.