

製造現場における 目視検査の自動化を可能にする AI画像検査技術

Technology Enabling Autonomous Visual Inspection at Manufacturing Sites Using Deep Learning

AIの判定根拠の可視化と少量データでの学習を活用し、 製造現場へのAI画像検査の導入を目指す

生産性の向上と製品のトレーサビリティを実現する上で、製造現場における目視検査の自動化は重要な要素です。判断基準を数値化することが難しい目視検査に対し、ディープラーニングを用いたAI画像検査は安定した判定を可能にする有用な技術です。しかし、AIを活用するには、判定結果に対する信頼性の確保や、学習に要する多量のデータ、特に不良画像の準備に課題があります。

東芝は、これらの課題を解決するために、AIの判定根拠を可視化する技術と少量データでの学習技術を開発しました。学習技術では、模擬的に不良画像を生成するデータ拡張に加え、拡張されたデータの欠陥位置も学習に組み込むことで、欠陥認識精度の向上を実現しました。

はじめに

製造現場には、高い品質を保つために多くの検査工程が存在します。中でも目視検査は、一般的かつ有効な方法ですが、検査員の能力差による検査結果のばらつき改善や、雇用・教育コストの削減、トレーサビリティの確保などのために、自動化が求められています。目視検査には、対象を直接見るだけでなく、拡大鏡を使って観察する場合や、カメラなどで取得した画像を用いる場合があります。検査項目も、寸法・形状や、色むら・汚れ、キズ・異物など、多種多様です。自動化のために、多くの検査項目のそれぞれに対応したアルゴリズムを構築することは、容易ではありません。更に、寸法など基準が明確な検査項目は、基準に則して自動判定できますが、色むらなど基準が明確でない検査項目は、人の感覚に頼った判定であるため、その判断基準をプログラムとして書き下すことが困難でした。

そこで、東芝はディープラーニングを用いた画像認識手法を活用し、目視検査を自動化するAI画像検査技術を開発しています。ディープラーニングにより検査画像と検査結果を学習させることで、これまでは置き換えが困難であった人の感覚に頼った判定も、自動で行えるようになります。

しかし、実際にAI画像検査を製造現場へ展開するには、判定結果の信頼性や、学習に必要な多量のデータ準備が

必要になります。そこで、実用化に向け、AIの判定根拠の可視化技術、データ拡張と欠陥位置の教示による少量データでの学習技術(図1(a))を開発しました。

判定根拠の可視化技術

AIは、結果の正しさが説明しにくいと、製造現場に受け入れられにくいと考えられます。そのため、AIの判定根拠を可視化する技術として、検査画像内で結果に対する影響が大きい位置を、判定根拠として表示する技術を開発しました。従来の画像分類向けの可視化技術⁽¹⁾は、様々な画像の中で大きな特徴を抽出するのに適しています。画像分類は、様々な画像が入力となるのに対し、画像検査は、検査装置で取得された画像が入力となります。また、画像検査における欠陥は、画像内の微小な領域であることが多く、従来の画像分類とは抽出する特徴のサイズが大きく異なります。そこで、背景や検査対象内の正常部分の特徴を除去し、欠陥をより強調する可視化技術を開発することで、画像検査への適用を可能にしました。この技術により、図1(b)に示すように、判定根拠として注目した欠陥位置を確実に可視化できることを確認しました。

少量データでの学習技術

AI画像検査には、教師あり学習を採用しました。教師あ

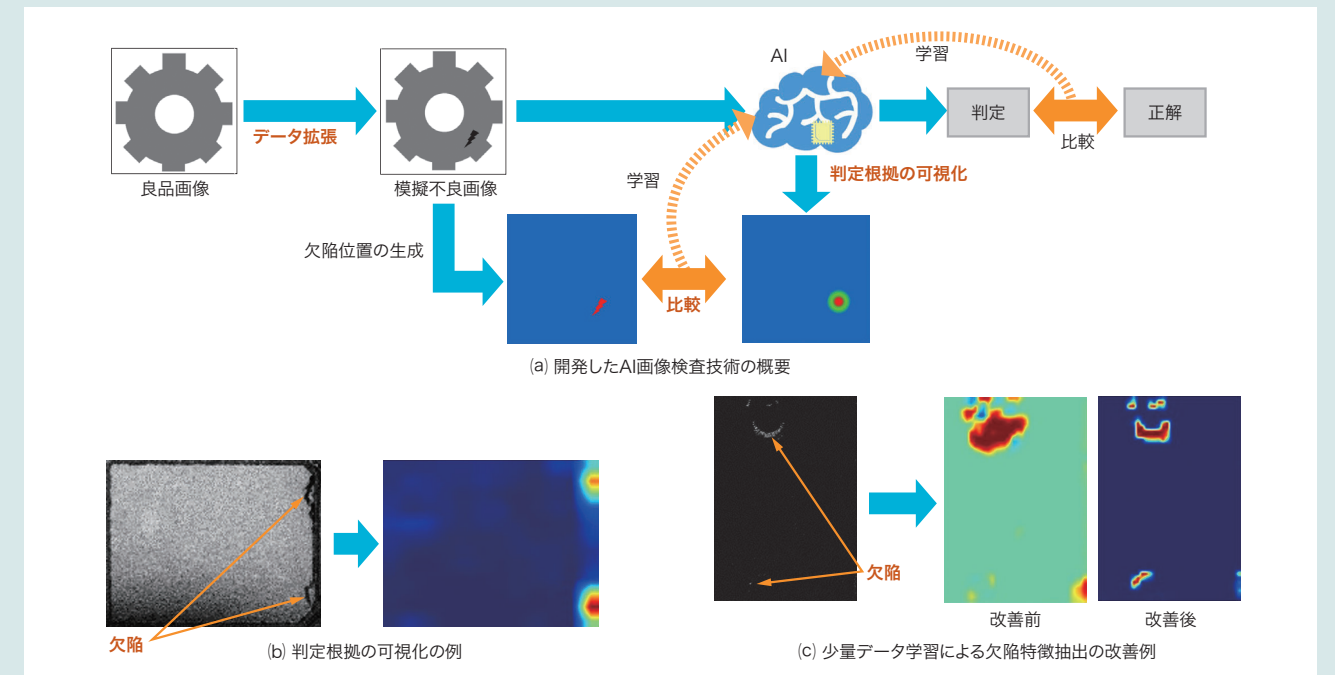


図1. 判定根拠の可視化技術と少量データでの学習技術の概要

データ拡張により良品画像から模擬的に不良画像を生成するとともに、判定根拠の可視化により欠陥特徴を抽出できていることを確認します。更に、欠陥位置を教示することで、特徴抽出精度を向上させます。

り学習では、検査対象となる入力画像と検査結果となる正解のペアを教師データとして学習することで、正解を導出するためのパラメータを自動的に適正化します。一般に、正しく推定するには、教師データとして数千～数万枚規模のデータセットが必要になりますが、製造現場では、特に不良画像の収集は困難です。データが少ない場合、教師データだけ判定精度が高く、未知のデータは判定精度が低い状態の過学習となってしまう。

過学習を抑制するための手法として注目を集めているのがデータ拡張で、一般的な手法としては、画像データの拡大、縮小、回転などの幾何学的な変換や、ランダムノイズの付与などが挙げられます。このような簡単な手法でも画像分類では効果が得られますが⁽²⁾、画像検査では教師データ近傍でのロバスト性の向上にとどまり、様々な不良画像への対応は困難でした。そこで、当社はこれに加え、あらかじめ準備した模擬欠陥や実欠陥を良品画像と合成することで、模擬的な不良画像の準備を可能にしました。これにより、良品画像と同規模以上の不良画像が生成可能になりました。

また、模擬的に生成した不良画像では、欠陥位置は自明です。そのため判定根拠を可視化した場合、注目点と欠陥位置は一致します。位置が異なる場合は、欠陥と異なる特徴を抽出しているため、過学習の可能性が考えられます。そこで、従来の学習と同時に、可視化画像と欠陥位置も学習

に組み込む手法を構築しました。これにより、少ないデータで鮮明に欠陥だけの特徴を認識した判定が可能になりました(図1(c))。

今後の展望

製造現場へのAI画像検査の適用に向けて、判定根拠の可視化技術と少量データでの学習技術を開発しました。これらの技術を活用し、様々な製造現場で、目視検査の自動化を加速していきます。更に、検査結果や、可視化による欠陥位置・サイズなどを製造工程のデータとひも付けることで、不良発生の原因推定や工程改善を可能にし、品質や生産性の向上を目指していきます。

文献

- (1) Selvaraju, R. R. et al. "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization". Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV 2017), Venice, Italy, 2017-10, IEEE, 2017, p.618-626.
- (2) Krizhevsky, A. et al. "ImageNet Classification with Deep Convolutional Neural Networks". Proceedings of 26th Annual Conference on Neural Information Processing Systems 2012 (NIPS 2012)-Volume 1. Lake Tahoe, NV, 2012-12, NIPS, 2012, p.1097-1105.

鷲谷 泰佑

生産技術センター 製造プロセス・検査技術領域
光学・検査技術研究部