

AI 画像検査における中間層データを用いた再学習時間の短縮

内田 美幸†, 鷲谷 泰佑†

株式会社東芝 生産技術センター 光学・検査技術研究部†

1. はじめに

近年, AI による画像分類の発展に伴い, 生産現場においても AI を使った外観画像検査が推進されている. しかし, 運用開始当初は高い検査精度であっても, 運用開始後に経時変化に伴って画像が徐々に変化し, 検査精度が低下する問題がある(図 1). その場合, 検査精度の低下が顕在化するまで異常に気付くことが出来ず, 検査の信頼性が損なわれる. 検査の信頼性を担保するためには, 検査精度をモニタリングすることが必要である. そして, 検査精度の低下を捉えたら, 必要なデータを収集し, 再学習によって精度を回復する(図 2). このような保守管理業務の作業負荷は大きく, 今後, さらなる AI 画像検査の普及に対応していくため, 保守管理の自動化が求められている. そこで, 我々は AI 画像検査の保守管理を効率化する技術を開発している.

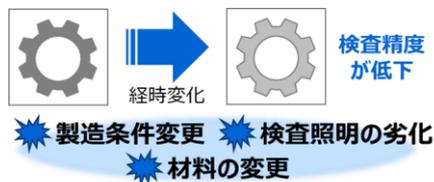


図 1 経時変化に伴う検査精度の低下

2. AI 画像検査の保守管理効率化

我々はこれまで, AI モデルの中間層における特徴量空間を利用した自動モニタリング技術を開発してきた^[1]. 中間層データには画像の特徴が数値化されているため, 高性能なモニタリングが可能であることを確認している^[2].

検査精度の低下が発生した際には, 一般に再学習により検査精度を回復することが必要である. しかし, 既存の学習データに新たな学習データを加えて再学習するため, データの蓄積に

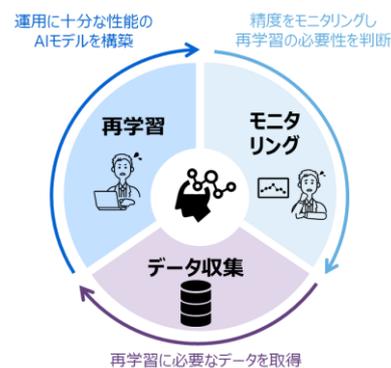


図 2 AI 画像検査の保守管理

より学習データ量が増大する. さらに, 学習データの偏りがある場合, 少数の特徴的なデータに対しては学習が進みにくい. そのため, 再学習に 1 週間以上の時間を要する場合もあり, 効率的な再学習技術が求められている.

3. 再学習時間を短縮する再学習手法

AI を活用した画像検査は, 多様なデータを学習することで高精度な検査が可能である. そこで, 学習データの多様性を保持しながら少数データに対する学習を促進することで, 再学習時間を短縮する再学習手法を開発した.

開発した手法の概要を図 3 に示す. はじめに, 再学習データを学習済みの AI モデルに入力し, 中間層データで画像をクラスタリングする(図 3(a)). そして, 再学習ではエポック毎に各クラスからランダムに均等の割合で再学習データを選び, 再学習を行なう(図 3(b)). このように学習データを選ぶことで, 学習データ数が異なるクラス A とクラス C に対して, 均等に学習を促進することが可能となる.

4. 検証

実際の外観検査画像への適用可能性を検証するため, 公開画像データセットである MVTec AD^[3]を用いた. MVTec AD には 15 の製品カテゴリーがあるが, 本検証では carpet 画像を 16 分割し, OK/NG の 2 クラスに分類する AI 検査モデルとした. NG 画像は OK 画像に疑似欠陥を付与し,

Faster re-training time using hidden layer in AI visual inspection

†Miyuki Uchida and Taisuke Washitani · TOSHIBA CORPORATION

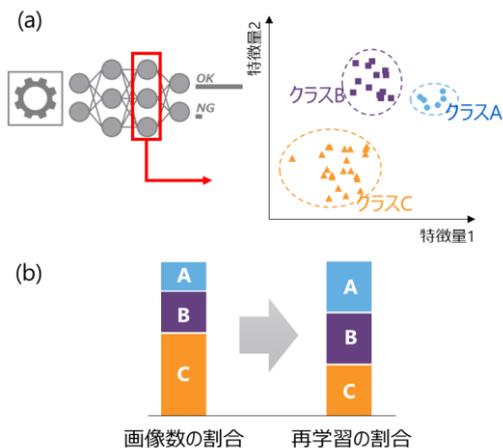


図3 再学習時間を短縮する再学習手法の概要

検査照明の変化を模擬するため画像輝度を変化させた画像を再学習データとした(図4)。検証に用いた画像データ数を表1に示す。

事前学習データで学習済みのAIモデルに、事前学習データと再学習データを入力し、中間層データでOK画像を5クラス、NG画像を5クラスにクラスターリングした。そして、各クラスからランダムに均等の割合で再学習データを選び学習させた開発手法と、通常の数に応じて学習させた従来手法で、全テスト画像に対する検査精度の推移をプロットした結果を図5に示す。なお、学習毎のバラつきを抑制するため、それぞれ10回ずつ再学習を実施し、平均値をプロットした。

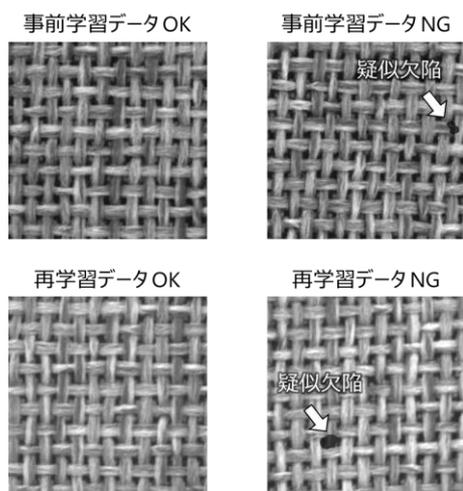


図4 学習画像例

表1 検証に用いた画像データ数

	学習用		テスト用	
	OK	NG	OK	NG
事前学習	1680	1680	112	112
再学習	560	560	112	112

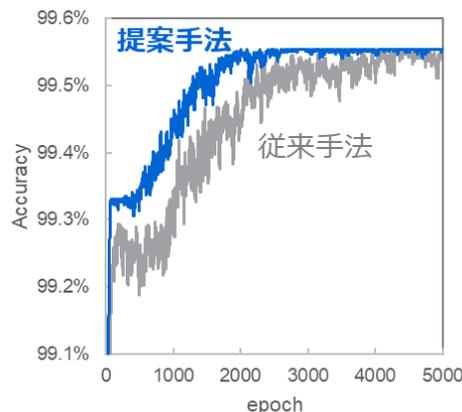


図5 学習時のテスト精度の推移

検証の結果、テスト精度が収束するまでに、従来手法は4095 epoch、提案手法は2006 epochとなり、従来手法よりも再学習時間を51%短縮できることを確認した。再学習時間が短縮できた要因として、事前学習モデルが特徴的であると認識した少数のデータに対して、従来手法よりも学習が促進されたためであると考えられる。

以上の結果より、中間層データを活用した再学習手法は、精度を保ちながら再学習時間の短縮に有効であることを確認した。

5. おわりに

AI画像検査の保守管理効率化に向けて、再学習時間を短縮する再学習手法を開発した。特徴量データを活用して学習データの多様な特徴を効率的に学習する本手法は、再学習時間の短縮に有効であることを確認した。

参考文献

[1] 内田美幸, 製造ラインのAI画像検査で生じる精度低下を自動で検知可能なモニタリング技術, 東芝レビュー 77-6, 2022.
 [2] 内田美幸, 鷺谷泰佑. “AI画像検査におけるモデル劣化検知の検討”. 情報処理学会第84回全国大会講演論文集. 愛媛大学, 2022-02, 情報処理学会. 2022, 2.57-2.58.
 [3] Paul Bergmann, Michael Fauser, David Sattlegger, and Carsten Steger. MVTEC AD - A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. In CVPR, 2019.