

【研究論文】

【令和5年度～令和7年度 地域企業競争力強化支援事業】

外観検査DXに資するAI画像処理デジタル技術開発と産業応用

高野 寛己、高久 悠杜、太田 晋一^{*1}

機械電子情報技術部(*1現 産業立地推進課)

製造現場における外観検査の自動化・デジタル化は、労働人口減少に伴う熟練検査員の確保や技能伝承という課題を解決するための重要な要素である。一方で、実際の現場では異常データの収集が困難なケースが多く、AI手法の導入を妨げる要因となっている。そこで本研究では、正常画像のみで高精度な判定が可能な最新の異常検知AIアルゴリズムPatchCoreを導入し、地域企業が外観検査や異常検知AI活用のイメージを持つデモシステムの開発に取り組んだ。

まずPatchCoreを用いた性能検証において、工業用画像の各種カテゴリで極めて高い判別性能(AUC値)を確認した。さらに、習得した異常検知AIモデルをエッジAIにて動作するよう実装し、製造現場での実際の活用を模擬した「見える化デモシステム」を構築した。このシステムは、信号灯、操作ボタン、I/Oターミナルと連携し、異常箇所をヒートマップで表示することで、現場の生産ラインにおける運用を再現している。今後は、構築したシステムやAIモデルを活用し、地域企業へのAI内製化支援や勉強会を通じて、異常検知AI技術の普及と県内ものづくり企業の競争力強化に貢献することを目指す。

キーワード: AI、画像処理、外観検査、異常検知AI、物体検出、画像分類、エッジAI

1 緒言

ものづくり企業において、製品の品質を担保する外観検査は極めて重要な工程である。現状、多くの現場では外観検査を熟練技術者の目視検査に頼っているが、労働人口の減少に伴い、熟練検査員の確保やその技能伝承が困難となっている。加えて、製品検査に対する要求水準が高度化しており、人の目視のみでは対応が困難な事例も増加している。

これらの課題を解決する手段として、AI画像処理技術を活用した検査の自動化・デジタル化によるデジタルトランスフォーメーション(DX)への期待が高まっている。しかしながら、中小企業においては、AIモデルの学習に必要な「不良品データ」の収集が困難であることや、高度なAIシステムを現場へ導入・運用するための技術的ハードルが高いという課題が存在する。そのため、具体的な活用イメージを持わずに導入を断念するケースも多い。

そこで本研究では、外観検査DXに資する、中小企業でも導入容易なAI画像処理技術の開発に取り組み、県内ものづくり企業の競争力強化を図った。具体的には、製造現場で広く課題となっている、正常画像データのみで学習可能(不良品データ不要)な異常検知AI技術の開発や、低コストかつ現場に組み込みやすいエッジ

AIを用いたシステムの構築を行い、現場でのAI活用能力向上に寄与する技術の確立を目指した。

2 異常検知AIモデルPatchCore

2.1 PatchCoreの概要

PatchCore¹⁾は、AI学習において正常画像のみを用いて正常と異常を判別できる異常検知AIモデルの一つである。事前学習済みのResNet²⁾などの畳み込みニューラルネットワークを特徴抽出器として用い、正常画像を入力して中間層から局所的なパッチ単位の特徴量を抽出する。これらの特徴量について、単一の画素単位ではなく、周辺のコテキストを包含した局所的な近傍特徴として抽出する。

同じ異常検知AIの一つであるPaDiM³⁾がマハラノビス距離を用いた多変量正規分布によるモデル化を行うのに対し、PatchCoreはメモリーバンク方式を採用する。学習段階において、画像から抽出される膨大なパッチ特徴量のすべてを保存すると、推論時の計算負荷が極大化してしまう。そこで、PatchCoreではCoreset Samplingと呼ばれる手法、具体的にはgreedy法(貪欲法)を用いることで、元の特徴空間の分布を最大限に維持したまま、データ数を数パーセント程度にまで削減し、効率的なメ

メモリーバンクを構築している。

異常検知のプロセスでは、評価画像から得られた各パッチの特徴量に対し、メモリーバンク内の最も近い(最近傍の正常パッチ特徴量との距離を算出する。この距離が閾値を超えて離れている場合、その箇所は未知のパターン、すなわち異常であると判定される。この手法は、分布を仮定する統計的モデルに比べて複雑な構造の欠陥にも強いという利点を持つ。これにより、正常画像のみの学習で高性能に正常と異常の判別が出来るというものである。

2.2 PatchCore性能検証

2.1で紹介したアルゴリズムの性能評価では、外観検査において著名なデータセットである MVTecAD⁴⁾が使用されている。MVTecADは製造業における産業用画像異常検知アルゴリズムの性能を評価するために作成された、標準的なベンチマークデータセットである。このうち工業製品7種の画像カテゴリに対して、筆者が画像単位の検知性能を検証した結果を表1に示す。ここでAUC値は1.0に近いほど良い検出性能を表す。表1の結果より、PatchCoreはいずれのカテゴリにおいても高いAUC値を示し、高精度な異常検知性能を有することが確認され、本アルゴリズムが工業製品の外観検査用途において有効であることが示唆された。

表1 PatchCoreを用いたAI性能(AUC値)

カテゴリ	AUC値
Bottle	1.00
Capsule	0.987
Metalnut	1.00
Screw	0.992
Carpet	0.996
Leather	1.00
Tile	0.988

3 エッジAIを用いた異常検知AIシステムの構築

3.1 エッジAI Jetsonとは

本研究では、エッジAI向け計算デバイスとして図1に示したJetson Orin NanoおよびJetson Orin AGXを使用した。Jetson シリーズは、GPUを内蔵した小型の組込み型デバイスであり、画像処理や深層学習推論をエッジ環境で実行できる。Jetson Orin Nanoは省電力でコンパ

クトな構成を特徴とし、現場設置を想定した用途に適している。一方、Jetson Orin AGXは高い演算性能を有し、計算負荷の大きい処理にも対応可能である。両デバイスはLinuxベースのOS上で動作し、GPUを活用したAI推論処理が可能である。本研究では、これらの特性を活かし、エッジ環境における異常検知デモ構築に用いた。



図1 Jetsonシリーズの外観写真
(左: Jetson Orin Nano 右: Jetson Orin AGX)

3.2 Google Colaboratoryを用いたPatchCore開発

従来AI開発を行うためには、高性能なパソコンの準備や複雑な環境設定が必要であり、導入の負担が大きいという課題があった。そこで本研究では、AI開発および検証環境としてGoogle Colaboratory(以下Colab)を採用した。Colabでは、第一に、高性能な計算資源を利用可能である点が挙げられる。Colabはクラウド型の開発環境であり、クラウド上の計算資源を利用できるため、手元のパソコンの性能に依存せずにプログラムを実行できる。第二に、環境構築を必要としない点である。従来の開発環境では、ライブラリの導入や各種設定など複雑な環境構築が必要であった。一方、Colabはウェブブラウザ上で利用可能であり、特別な設定を行うことなく、即座にデータ分析やAI開発を開始できる。

3.3 データセット

今回使用したデータセットはオリジナルデータのプラスチックキャップ(ミスミ プラスチックジョイント内キャップPJ503)表面の画像を用いた。表面が正常のもの、線キズのあるものをそれぞれ OK 品、NG 品とした。撮像キットとして、デジタルデータスタンド DS-4、USB カメラとして HOZAN L-837、C マウントレンズ(12 mm)、手製のバー照明を用いて、訓練用に OK 画像 20 枚、評価用に OK/NG 各 10 枚を撮影した。撮影した画像例を図 2 に

示す。




図 2 プラスチックキャップの
(a) OK 品と(b)NG 品の表面画像

3.4 使用機材

本研究では、AI 処理結果を物理信号として入出力する手段として、USB 接続型デジタル I/O ターミナル CONTEC DIO-0808LY-USB を用いた(図 3)。本デバイスは 8 点のデジタル入力および 8 点のデジタル出力を備え、外部センサからの ON/OFF 信号(状態検知、異常検出等)を取得するとともに、AI の推論結果に基づいて表示灯等の 12-24 V 駆動機器の制御を行うことが可能である。

この I/O ターミナルに入力として 24 V 駆動のボタン、出力として信号灯および緑ランプ、赤ランプを接続し AI 処理結果を可視化した。各種配線についてボタン、信号灯、ランプをそれぞれ図 4(a) (b) (c)の通り接続した。また撮像はカメラを固定し、バー照明を両側に配置し、評価対象のプラスチックキャップがカメラ中心に配置されるよう目印を設置している。



図 3 I/O ターミナル






図 4 (a) ボタン、(b) 信号灯、(c) ランプの配線図




図 5 使用機材の接続を示す外観写真

3.5 学習条件

今回 PatchCore の学習画像としてあらかじめ撮影したプラスチックキャップ OK 画像 20 枚を用いて PatchCore のモデルを学習した。その後、Colab 上で作成した学習済モデルをダウンロードした後 Jetson へ移し、Jetson 上で PatchCore の学習済モデルを読み込み、評価プログラムを動作させた。

4 結果

開発したエッジ AI を用いた異常検知 AI システムを図 6 に示す。今回 OK/NG の閾値を 3.5 に設定し、これ未満のものを OK、これ以上のものを NG とした。また NG の場合、画像のヒートマップ表示により異常領域箇所候補が赤系の色で表示されるように設定した。AI 推論結果例を図 7 に示す。

評価画像として用意したプラスチックキャップ OK、NG 各画像 10 枚については適切に閾値を設定することにより、正解率 100 % となり、リアルタイムデモにおいて、おおむね正しい判定ができるシステムとなった。また照明レベルや僅かな位置ズレの違いにより、OK 品が NG 品と誤判定される例(図 8)も多く、PatchCore の実際の運用において、照明強度を一定に保つことおよび撮像位置が性能担保のために重要であることが分かった。

また、本システムはものづくり現場での運用イメージに繋がることを期待し、AI 判定結果の出力をランプ等で可視化できる仕組みとなっている。具体的にはボタンを押すことで AI 判定が始まり、OK の場合、図 9(a)のように信号灯が青く光り、緑ランプが点灯する。一方 NG の場合、図 9(b)のように、信号灯が赤く光り、赤ランプも点灯する。

本システムについては当センター内で展示を行っており、今後も県内企業への AI 活用例に繋げていく。また、当センター主催で令和 8 年度開催の AI 内製化勉強会でのコンテンツとして活用し、県内企業への異常検知 AI の普及促進に取り組む予定である。




図 6 エッジ AI を用いた異常検知 AI システム




図 7 (a) OK、(b)NG の AI 推論結果例




図 8 OK 品を NG 品と誤判定した例




図 9 信号灯及びランプの様子

5 生成 AI を活用した欠陥画像の生成

本研究では、Jetson を用いたエッジ AI デモシステムにおいて、PatchCore による異常検知 AI を適用し、正常画像のみを学習データとして用いた正常／異常の 2 分類による外観検査の有効性を示した。PatchCore は少量データで高い判別性能を発揮する一方、異常の種類を直接分類することは想定しておらず、実際の製造現場で求められる異常の種類の判別には別のアプローチが必要となる。

この課題に対して、生成 AI (Diffusion モデル) を用いて異常画像を人工的に生成し、学習データを拡張する手法が考えられる⁵⁾。具体的には、実際の異常画像を少量用意し、LoRA⁶⁾等の手法により生成モデルを微調整することで、複数種類の異常を含む画像を生成することが可能となる。これにより、異常クラスを含む教師あり分類 AI の学習が可能となり、異常検知 AI では対応が難しい多クラス分類への展開が期待できる(図 10)。詳細については参考文献⁵⁾を参照されたい。




図 10 LoRA を用いた画像生成とマルチクラス異常分類

6 AI を活用した見える化デモシステムの開発

3 章と 4 章で異常検知 AI を活用したエッジ AI デモシステムを紹介した(図 6)。このほかに、AI 活用が見込める「見える化デモシステム」として、PC ベースのベルトコンベヤに乗るコイン電池表面の欠陥を画像分類と物体検出を用いて出力するベルトコンベヤシステムを作成した⁷⁾(図 11)。また、DOBOT 社のロボットを活用した物体検出 AI を用いたロボットシステムを開発した⁸⁾(図 12)。さらに DOBOT 社の協働ロボット NOVA2 を導入し、金属部品のピック&プレース作業が行えるシステムを開発した(図 13)。将来的に物体検出 AI などと組み合わせ、高性能、高機能化して企業の生産現場での活用を検討していく。




図 11 外観検査 AI 活用ベルトコンベヤシステム



図 12 ロボット+ベルトコンベアによる物品計数システム



図 13 協働ロボットによるピッキングシステム

7 結言

本研究では、外観検査の自動化・デジタル化によるDXを目的として、異常検知AI技術であるPatchCoreの導入および検証を行った。さらに、AIモデルを製造現場で実際に活用することを想定し、Jetson シリーズを用いたエッジAIデモシステムを構築した。本システムでは異常箇所をヒートマップとして可視化するとともに、I/Oターミナルを用いて判定結果を信号灯やランプへ出力することで、AIの判断を現場で直感的に把握できる仕組みを実現している。リアルタイムでのデモ運用の結果から、照明強度やワークの設置位置といったわずかな環境差が判定結果に影響を及ぼすことも明らかとなり、実運用における環境条件の維持の重要性がわかった。

また、製造現場でのAI活用をイメージしやすくするため、「見える化デモシステム」を開発した。ベルトコンベアやロボット等と接続することで、現場での活用やAI導入の検討に役立つデモシステムとなっている。今後は、

AIの内製化支援や技術普及を通じて、ものづくり企業でのAI活用につなげていきたい。

参考文献

- 1) Roth, K., Pemula, L., Zepeda, J., Scholkopf, B., Brox, T., and Gehler, P., "Towards total recall in industrial anomaly detection", Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 14318-14328, (2022)
- 2) H. Kaiming, Z. Xiangyu, R. Shaoqing, and S. Jian, "Deep Residual Learning for Image Recognition", Proc. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.770-778, (2016)
- 3) T. Defard, A. Setkov, A. Loesch, R. Audigier, "Padim: a Patch distribution modeling framework for anomaly detection and localization", The 25th International Conference on Pattern Recognition Workshops and Challenges (ICPR), pp.475-489, (2021)
- 4) P. Bergmann, et al., "Mvtec ad-a comprehensive real-world dataset for unsupervised anomaly detection", Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp.9584-9592, (2019)
- 5) 高野 寛己、高久 悠杜、太田 晋一. 生成画像を用いた工業画像マルチクラス分類と異常検知アルゴリズム性能との比較検証. 令和6年度宮城県 産業技術総合センター研究報告. 2024, No.22, pp. 49-54.
- 6) E. J. Hu, Y. Shen, P. Wallis, Z. Chen, V. Li, A. Singh, P. Rajpurkar, "LoRA: Low-Rank Adaptation of Large Language Models", Proceedings of the 10th International Conference on Learning Representations (ICLR), (2022)
- 7) 高久 悠杜、高野 寛己、太田 晋一. 製造現場環境を模した外観検査AI活用ベルトコンベヤシステムの開発. 令和5年度宮城県 産業技術総合センター研究報告. 2023, No.21, pp. 29-32.
- 8) 小泉 協、高久 悠杜、高野 寛己、太田 晋一. 画像AIおよびロボット+ベルトコンベアによる物品計数システムの開発と 最新画像AIアルゴリズムの産業応用検討. 令和6年度宮城県 産業技術総合センター研究報告. 2024, No.22, pp. 55-58.