

異常検知における精度向上の研究・先行研究で精度が低かったカテゴリへの適応 Improving Accuracy in Anomaly Detection: Application to Categories with Low Performance in Prior Work

芝 涼佑 中西 知嘉子
Shiba Ryouyusuke Nakanishi Chikako

1. はじめに

近年、製造業における AI を用いた異常検知技術が注目されている。異常検知はあらかじめ学習した正常データに対して、異なる特徴を持つデータを異常として判別する技術である。主に製造業における製品の不良品の検出など、外観検査への応用が進められている。

異常検知の研究や評価には、MVTec 社が提供する MVTec-AD データセットが広く利用されている。このデータセットは、製造業における典型的な異常(例：へこみや傷、異物混入)を対象としており、様々なカテゴリの物体画像が含まれている。

本研究では異常検知の高速化の研究を行っている。先行研究である「エッジ AI 向けの異常検知の高精度、高速化の検討」[1]では、PatchCore[2]と比較し、同等の精度を維持しつつ、処理時間を 1/3 に高速化する手法を提案している。以下、この手法を MRMG と呼ぶ。

本研究では、物体の向きが検出性能に与える影響に着目し、MVTec-AD データセットの中でも、先行研究において精度が相対的に低かったカテゴリである「Screw」に対して、PatchCore(2022 年に SOTA を達成)と本研究の提案手法の比較実験を行い、精度向上の可能性を検証する。

2. 使用モデル・手法

2.1 使用するデータセット

本研究では、MVTec 社が提供する異常検知用データセット MVTec-AD[3]を使用する。このデータセットは工場の部品やカーペットの画像など全 15 のカテゴリから構成されており、10 種類のオブジェクト系、5 種類のテクスチャ系に分類される。各カテゴリに対して、以下の 3 種類の画像が提供されている。学習用：正常画像、テスト用：正常画像、テスト用：異常画像。

2.2 PatchCore[2]

PatchCore は、工業製品の異常検知を目的として開発された教師なし手法であり、2022 年に MVTec-AD データセットにおいて SOTA(state-of-the-art)を達成した手法である。画像をパッチ単位に分割し、それぞれの領域から抽出した特徴ベクトルに基づいて異常スコアを算出する。ResNet50 などの事前学習済みモデルを特徴抽出に用い、近傍探索と貪欲法による特徴削減を組み合わせることで、高精度かつ高速な異常検知を実現している。

3. MRMG

MRMG では、画像全体から特徴ベクトルを抽出し、LOF (局所外れ値因子法)によって異常度を評価する軽量な異常検知手法である。既存手法である PatchCore がパッチ単位での特徴抽出と近傍探索を用いるのに対し、本手法では画像全体を対象としたグローバル特徴と密度ベースの判定により、高速かつ安定した異常検知を実現する。また、LOF の誤検出を抑制し、高速化するために、重心最短距離

削減手法を導入し、密度の均一化と、特徴量の削減を行っている。

3.1 特徴抽出方法

MRMG では、ResNet50 の中間層のうち 1 層を選択して特徴抽出を行い、画像全体からグローバルな特徴ベクトルを生成する。

特徴抽出を行う層は、ResNet50 の全 177 層に対して LOF を用いて異常検知精度を評価し、MVTec-AD データセット上で全体のバランスが最も良かった第 141 層を選択している。

3.2 LOF(局所外れ値因子法)[5]

異常スコアの算出には、局所外れ値因子法 (LOF) [5]を使用する。LOF は、あるデータ点の局所密度が近傍点に比べて著しく低い場合、その点を異常と判断する手法である。

LOF の計算は以下の流れで行われる：

- ① 正常データから得られた特徴ベクトル群に対し、LOF を構成する。
- ② テスト画像から抽出された特徴ベクトルの近傍密度を求め、異常度 (LOF スコア) を算出する。
- ③ LOF スコアが 1 より大きければ異常と判定し、1 に近いほど正常と見なす。

LOF は密度ベースの手法であるため、正常データが過度に密集している場合、正常データが異常と誤判定されるリスクがある。この問題に対応するため、次節で述べる重心最短距離削減手法を適用する。

3.3 重心最短距離削減手法

MRMG では、正常データの密度を均一化し、LOF の判定精度を向上させるために重心最短距離削減手法を導入している。この手法では、LOF の対象となる正常データを以下のように削減する：

- ① 正常データを LOF 空間に配置し、クラスタごとの重心を算出する。
- ② データ間の距離が最小となる 2 点を選出する。
- ③ その 2 点のうち、重心により近い方を削除する。
- ④ 上記手順を繰り返し、正常データを 10 個ずつ段階的に削減する。

削減するたびに異常検知精度を計測し、最も高精度を示した特徴数を記録することで、精度と処理速度のバランスを最適化する。

この削減手法により、LOF の計算コストを削減するとともに、過密な特徴空間による誤検出の抑制が可能となる。

4. 研究内容

異常検知の分野では、学習データの品質がモデルの精度に大きく影響を与える。本研究では、学習に使用する画像の角度や大きさを統一することで、特徴抽出のばらつきを抑え、より安定した識別能力を持つモデルの構築を目指した。また、異常検知に適した特徴抽出手法として、

PatchCore と MRMG の提案手法を用いる前と後の精度結果を比較し、それぞれの手法の特性や適用範囲について詳細に評価した。

4.1 画像の統一方法

精度低下の要因である画像のばらつきを抑えるために、学習画像・テスト画像・正解画像すべてに対して、向きと大きさの統一処理を手動で実施した。

画像の編集には、Windows 11 に標準搭載されている「フォト」アプリを使用し、以下の操作を行った。

- ・回転の統一：フォトアプリの回転機能を用いて、すべての画像において物体（ネジ）の向きを揃えた。
- ・大きさの調整：物体の表示サイズが大きく異ならないよう、視覚的に確認しながら統一感をもたせて編集を行った。

これらの処理により、画像ごとの視覚的差異を最小限に抑え、一貫性のあるデータセットを構築した。これによって、学習データとテストデータ間のばらつきが軽減され、異常検知モデルの学習安定性と検出精度の向上が期待される。

5. 結果

表 1 に提案手法を適用した場合の異常検知精度の結果を示す。

表 1 画像統一処理を適用した場合の異常検知精度

| | AUC(変更前) | AUC(変更後) | 増加量 |
|-----------|----------|----------|------|
| PatchCore | 0.76 | 0.91 | 0.15 |
| MRMG | 0.49 | 0.79 | 0.30 |

画像の向きに関しては、各 4 方向で検証を行い、最も精度が高かった「左下方向」を最終的に採用した。

本実験の結果、PatchCore および MRMG の両手法において精度の向上が確認された。特に MRMG においては、精度が 0.30 ポイント向上するという顕著な改善が見られた。

一方で、最終的な MRMG の精度は 0.79 であり、一般的に良好とされる 0.80 にはわずかに届かなかった点は今後の課題といえる。

6. 考察

学習に使用した画像の例を図 1 に示す。




図 1 学習に使用した画像

図 1 に示す通り、MVTec-AD の「Screw」カテゴリに含まれる学習用画像はスクリューの頭部が右上、ネジ先端が左下に向くような方向で撮影されており、微妙な傾きの違いがあることが確認された。また、物体の大きさにもばらつきが見られ、これら特徴抽出に影響を与えたと考えられる。

5.1 MRMG の考察

MRMG は、PatchCore と比較して回転による影響を受けやすいと考えられる。その理由として、MRMG は

ResNet50 の第 141 層から特徴を抽出しており、この層の特徴マップのサイズが 7×7 と小さく、画像全体を統合して扱う処理が行われる点にある。

つまり、画像の大域的な特徴を一括で表現する構成上、物体の向きの違いが特徴全体に及ぼす影響が大きくなるため、回転によるばらつきが精度低下の原因になっていたと推察される。

また、MRMG の精度向上の理由として、前処理によって物体の向きが統一されたことで、学習データにおける特徴のばらつきが軽減され、クラスごとの重心削減手法も効果的に機能した。その結果、異常判定の安定性が高まり、精度の大幅な向上 (+0.30) が確認された。

7. まとめ

本研究では、MVTec-AD の「Screw」カテゴリに対して、画像の向きおよび大きさのばらつきが異常検知精度に与える影響に着目し、PatchCore および MRMG の両手法において画像の統一前処理を適用した検証を行った。

その結果、両手法において精度向上が確認され、特に MRMG では +0.30 の大幅な改善が得られた。これは、画像全体を対象に特徴を抽出する MRMG が、物体の向きやスケールの不一致に対して敏感であり、統一処理が効果的に作用したことを示している。

今後の展望としては、以下の点があげられる。

- ・自動的な前処理技術の導入：今回の向き・スケール統一は手動によるものであったが、今後は画像整列やスケール正規化を自動化する手法の導入を検討する。
 - ・他カテゴリへの汎化性の検証：Screw 以外のカテゴリに対しても前処理の効果を検証し、適用可能性の範囲を広げる。
 - ・MRMG の構造改良：特徴抽出層の選択や、特徴のローテーション不変性を高める工夫を加えることで、よりロバストなモデル設計を目指す。
- このように、本研究は画像前処理の重要性とその有効性を定量的に示すとともに、異常検知モデルにおける精度向上のための今後の方向性を明らかにした。

参考文献

- [1] 先行研究
北野侑弥, 中西知嘉子, エッジ AI 向けの異常検知の高精度, 高速化の検討 電子情報通信学会 総合大会 (2023/03)
- [2] PatchCore
Roth, K., Pemula, L., Zepeda, J., Schölkopf, B., Brox, T., & Gehler, P. T. *Towards Total Recall in Industrial Anomaly Detection*. (2021)
- [3] MVTec-AD: MVTec Software
< <https://www.mvtec.com/company/research/datasets/mvtec-ad> >
- [4] ResNet
Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Deep residual learning for image recognition." CVPR, (2016)
- [5] LOF
Markus M. Breunig, Hans-Peter Kriegel, Raymond T Ng, Jörg Sander "Identifying Density-Based Local Outliers" (2000)

† 大阪工業大学 情報科学研究科 情報科学専攻
Graduate School of Information Science and
Technology Osaka Institute of Technology

‡ 大阪工業大学 情報科学部 情報知能学科
Department of Information and Computer Science
Osaka Institute of Technology