

画像の認識・理解シンポジウム MIRU2023 での研究発表

中世古 真 吾

Shingo NAKAZEKO

数理情報学専攻修士課程 2 年

1. はじめに

2023 年 7 月 25 日から 28 日にかけてアクトシティ浜松にて開催された画像の認識・理解シンポジウム「MIRU2023」に参加し“CNN から抽出した画像特徴量の線形回帰に基づく画像の異常検出”という題目で口頭とポスターでの発表を行った^[1]。

2. 研究背景と目的

画像識別タスクを学習した畳み込みニューラルネットワーク（CNN）を用いて画像特徴量を抽出し、それらの分布を利用して異常スコアを算出する手法が数多く提案されている。これらは高い異常検出精度を示すことで知られている^{[2][3]}。しかし、このような手法において特徴量から画素ごとの異常スコアを算出時の計算コストが大きいという問題がある。

そこで本研究では、特徴量間の関係を単純な線形回帰によってモデル化し、その予測誤差を異常スコアとする新たな方法を検討した。本研究では異常を高い精度で検出しつつ検出に必要な時間を削減することを目的とした。

3. 特徴量の予測に基づく異常スコアの算出

先行研究の異常検出手法は、学習画像から抽出した特徴量の分布をモデル化して、テスト画像から抽出した個々の特徴量の当てはまりの良さを異常スコアとしていと考えられる。これに対して本研究では、学習画像から抽出した特徴量間の関係を線形回帰によってモデル化し、テスト画像から抽出した個々の特徴量に対する予測誤差を異常スコアとする方法について検討している（図 1）。このような方法をとることで、入力画像の正常な箇所では予測誤

差が小さくなり、異常な箇所では予測誤差が大きくなることを期待できる。




図 1 提案手法の流れ

識別タスクを学習した CNN を利用して画像から特徴量を抽出し、線形回帰モデルの学習を行う。予測誤差を異常スコアとする。

4. 提案手法の異常検出精度と異常スコア算出時の計算コストを評価する実験

提案手法、PatchCore, PaDiM のそれぞれの手法を用いて異常検出精度と計算コストを比較する実験を行った結果を表 1 に示す。また、提案手法で MVTec AD データセット^[4]に対して提案手法で検出した結果を図 2 に示す。また、MVTec LOCO AD データセット^[5]のサブセットでも実験を行った。




図2 提案手法での検出結果の例
左は異常の画像、真ん中は検出結果のヒートマップを異常の画像と合成したもの、右は異常箇所を示す画像である。

表1 MVTEC AD での実験結果

異常検出精度の評価には画素単位の ROCAUC, PRO を用いた。異常スコア算出時の計算コストの評価は算出にかかる計算時間 (秒) である。

手法	ROC AUC	PRO	計算時間 GPU	計算時間 CPU
PatchCore	98.3	94.0	12.53 ± 0.09	332.79 ± 0.62
PaDiM	97.7 ± 0.0	92.8 ± 0.0	—	212.97 ± 2.18
Ours	97.7	92.1	1.05 ± 0.01	48.82 ± 0.06

表1より、PatchCore が最も高い検出精度を示した。提案手法は、PatchCore よりも少し低い精度であるがより短い算出時間で達成している。また、MVTEC LOCO AD のサブセットでの結果は、PatchCore と比較すると、少し低い異常検出精度を示したが、PaDiM と比べると少し良い精度という結果が得られた。計算時間は PatchCore の約6分の1で

あることが確認できた。PatchCore では、最近傍探索を行うため異常スコアの算出時に多くの計算を必要とする。これに対して、提案手法では線形回帰モデルを用いて予測値を算出し、その誤差を異常スコアとするだけで良いため計算時間を削減することができていると考えられる。

5. おわりに

抽出した特徴量に対して線形回帰を適用する手法を提案した。その結果、先行研究と同程度の精度をより短い異常スコア算出時間で達成できることが確認することができた。

発表の間では、他の研究者から「こんな単純な手法で高い精度が得られるのは興味深い」とったコメントを頂いた他、様々な意見交換ができた。今後は、いただいた意見も参考にして、他の手法との比較や提案手法の改善に取り組みたい。

参考文献

- [1] 中世古, 高橋, 「CNN から抽出した画像特徴量の線形回帰に基づく画像の異常検出」, MIRU2023, 2023.
- [2] K. Roth, et al. "Towards Total Recall in Industrial Anomaly Detection." CVPR. 2022.
- [3] T. Defard, et al. "PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization." ICPR. 2021.
- [4] P. Bergmann, et al. "The MVTEC Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection." IJCV. 2021
- [5] Paul Bergmann, Kilian Batzner, Michael Fauser, David Sattlegger, Carsten Steger, "Beyond Dents and Scratches: Logical Constraints in Unsupervised Anomaly Detection and Localization." IJCV. 2022.