

畳み込みニューラルネット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

中世古 真吾[†]高橋 隆史[‡][†] 龍谷大学大学院理工学研究科[‡] 龍谷大学先端理工学部

1 はじめに

教師なし学習に基づく画像の異常検出においては、画像識別タスクで学習済みの畳み込みニューラルネット (CNN) を用いて画像特徴量を抽出し、それらをもとに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。これらの手法は高い異常検出精度を示すことが知られている。しかし、画像特徴量から画素ごとの異常スコアを算出する過程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、画像特徴量に対して線形回帰を適用して異常スコアを算出する方法を検討する。MVTec AD データセット [1] に本手法を適用した結果、画素単位の平均 ROCAUC は 97.7%, PRO は 92.1% を達成している。

2 先行研究

画像識別タスクを学習した CNN を用いて画像特徴量を抽出し、その分布を利用して異常スコアを算出する異常検出手法について述べる。このような手法の代表例に、PatchCore[2] や PaDiM[3] などがある。これらは、MVTec AD などのベンチマークデータセットで高い異常検出精度を示している。

2.1 PatchCore

PatchCore では、正常画像から抽出した画像特徴量をデータベースに登録しておき、テスト画像から抽出した画像特徴量のそれぞれについて、ユークリッド距離を用いて最近傍探索を行う。そして、それらの距離をもとに画素位置ごとの異常スコアを算出する。実際には、CNN から抽出した特徴量そのままではなく、複数の層から抽出した特徴量を近傍で連結して、より高次元な特徴量として扱う。




図1 本手法の流れ。事前学習した CNN を用いて特徴抽出を行い、線形回帰を用いて予測モデルを作成する。モデルの予測誤差をもとに異常スコアを算出する。

PatchCore においては、異常スコア算出の計算量の大部分を、最近傍探索が占める。そのため、特徴選択を行ってデータベースに登録する特徴量の数を大幅に減らし、推論時に必要となる計算量を削減している。

2.2 PaDiM

PaDiM では、正常画像から抽出した画像特徴量に対して、特徴マップの位置ごとに正規分布を当てはめる。そして、テスト画像から抽出した特徴量と同じ位置に対応する正規分布との間のマハラノビス距離を求め、それをもとに画素位置ごとの異常スコアを算出する。PatchCore と同様に特徴量の連結などの前処理も行う。PaDiM では、計算量抑制のため、特徴量の変数をランダムに選択して次元削減する前処理が提案されている。

3 特徴量の予測に基づく異常スコアの算出

PatchCore や PaDiM は、特徴量の分布をモデル化して、テスト画像の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、CNN の特徴量間の関係を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ことを考える。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と期待する。

Anomaly Localization in images by Linear Regression using features extracted from CNN

[†] Graduate School of Science and Technology, Ryukoku University

[‡] Faculty of Advanced Science and Technology, Ryukoku University

3.1 特徴抽出

先行研究と同様に、事前学習済みの CNN の複数の層から画像特徴量を抽出し、前処理を行う。CNN の入力に近い側と出力に近い側のそれぞれから特徴マップを抽出する。入力側のマップの各位置から得られた特徴量を近傍で連結し、より高次元の特徴量とする。出力側のマップから抽出した特徴量は、入力側のマップと解像度を揃えるためにバイリニア補間を施す。

3.2 Ridge 回帰による画像特徴量の予測

入力側のマップ、出力側のマップそれぞれから得られた特徴量を $\mathbf{x}, \mathbf{y}$ とする。正常画像から抽出した $\mathbf{x}$ を説明変数、 $\mathbf{y}$ を目的変数として線形回帰によって予測モデルを構築する。本研究では、予測モデルの学習には、 L_2 正則化項を加えた Ridge 回帰を用いた。

3.3 異常スコアの算出

学習した予測モデルを用いて、テスト画像から抽出した特徴量 $\mathbf{x}$ から $\mathbf{y}$ の予測値 $\hat{\mathbf{y}}$ を求め、残差平方和の対数 $\log(\|\hat{\mathbf{y}} - \mathbf{y}\|^2)$ を算出する。その値を入力画像と同じ解像度にバイリニア補間し、異常スコアとする。

4 実験

本手法の異常検出精度と計算量を先行研究と比較するための実験を行った。精度の評価指標は、画素単位のアベラジ ROCAUC とアベラジ PRO[1]、計算量の評価指標はスコア算出に要した時間である。異常スコア算出時間は、全てのテストデータに対する時間の合計で評価を行った。

4.1 データと実験条件

実験には、15 品目の工業製品の画像データから成る MVTec AD[1] を使用した。このデータセットは、学習画像 3629 枚、テスト画像 1725 枚で構成されている。これらの画像の大きさを 256×256 に縮小して使用した。

特徴抽出には、ImageNet を識別するように学習した WideResNet101-2 を利用した。PatchCore を参考に、このネットワークの layer2 から入力側の特徴マップを抽出し、layer3 から出力側の特徴マップを抽出した。Ridge 回帰の正則化項の係数は 1.0 とした。この値を変化させても結果にはほとんど影響がなかった。実験には、CPU が Ryzen9 5900X、GPU が RTX3090、メモリが 32GB の PC を使用した。

比較のため、PatchCore や PaDiM でも同じ CNN から抽出した特徴マップを用いて異常スコアを算出した。

表 1 MVTec AD での実験結果

手法	ROCAUC	PRO	算出時間 (s)
PatchCore	98.1 $\pm$ 0.0	92.3 $\pm$ 0.0	11.41 $\pm$ 0.50
PaDiM	97.7 $\pm$ 0.0	92.8 $\pm$ 0.0	547.71 $\pm$ 5.94*
Ours	97.7 $\pm$ 0.0	92.1 $\pm$ 0.0	1.05 $\pm$ 0.01

* 異常スコア計算時に GPU を使用できていない

PatchCore では、特徴量を全体の 1% まで削減した。PaDiM では、特徴量の変数をランダムに選択することで次元を 550 に削減した。それぞれの実験には、参考 URL[4][5] で提供されているコードを利用し、異常スコア算出時間を測定するコードを追加して実験を行った。

4.2 実験結果

各手法 3 回ずつ実験を行った結果を表 1 に示す。異常検出精度については、ROCAUC、PRO 共に先行研究と同程度であった。一方、計算量について見ると、PatchCore の 10 分の 1 程度の計算時間となることがわかった。

5 おわりに

本研究では、CNN の複数の層から抽出した特徴量に対して、線形回帰を用いて異常スコアを算出する手法について検討した。特徴量の最近傍探索に基づく先行研究の手法と比べて、異常検出精度は同程度のまま、計算量を 10 分の 1 程度にできることがわかった。今後の課題として、より適切な特徴抽出やスコア算出の方法の検討や、MVTec AD 以外のデータセットでの検証などが考えられる。

参考文献

- [1] P. Bergmann, et al. The MVTec Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. IJCV. 2021
- [2] K. Roth, et al. Towards Total Recall in Industrial Anomaly Detection. CVPR. 2021.
- [3] T. Defard, et al. PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization. ICPR. 2021.
- [4] xiahaifeng1995.PaDiM-Anomaly-Detection-Localization-master. <https://github.com/xiahaifeng1995/PaDiM-Anomaly-Detection-Localization-master>.
- [5] amazon-science. patchcore-inspection. <https://github.com/amazon-science/patchcore-inspection>.