

# 画像異常検知における事前学習モデルを用いた特徴抽出に関する考察

小野 拓也, 森 純一郎<sup>†</sup>  
東京大学大学院 情報理工学系研究科<sup>†</sup>

## 1 はじめに

画像の異常検知は工業製品の外観検査、医療画像の診断、監視カメラシステムでの不正な行動検出など幅広いタスクに応用がなされている。この分野において従来は教師なし手法が主流であったが、最近では ImageNet 等の大規模データセットで事前学習した CNN による特徴抽出の有効性が示されている [1],[2]。これらのアプローチでは一般に、データ拡張、特徴抽出、次元削減、異常の推定、などが要素として存在する。しかしながら、従来研究はいずれも各要素をヒューリスティックに組み合わせたものであり、異常検知タスクにおける各要素の有効性については統一的な知見が示されるに至っていない。本研究では、MVTec データセット [3] を用い、転移学習アプローチによる異常検知（転移異常検知）の網羅的な評価実験を行った。その結果、CNN の深い層かつ主成分分析で寄与率の低い特徴量が有効であること。それらの特徴量を元にした k-NN や多変量ガウス分布 (MVG) などの単純な手法で十分な性能が得られることを確認した。

## 2 手法

転移異常検知の流れは以下のようである。

1. 訓練済み CNN の活性化層に任意の pooling を適用し 1 次元特徴を得る

2. 抽出した特徴に対して PCA による次元削減を行う
3. 推定モデルを用い、正常データの特徴量と類似度が低いサンプルを異常と分類する

従来研究では、ImageNet で学習した CNN を用いた画像からの特徴抽出と MVG による密度推定によって異常検知精度が向上すること、特徴量を PCA で次元削減を行い寄与率が小さい方から採用する negated PCA (NPCA) が有効であることが示されている [2]。

本研究では、まず事前学習モデルとして ResNet-18 と EfficientNet-B5 (ENB5) を用いる。その上で、データ拡張や CNN から特徴を抽出する際の pooling の方法、PCA による次元削減における次元サイズ、それぞれについて比較実験を行い、それらの効果の検証を行った。また、推定モデルとして MVG に加えて、k-NN や Normalizing Flow (NF) [4] を用いて評価を行った。

## 3 実験

### 3.1 データセットと実験方法

MVTec AD は計 15 種の工業製品からなる 5,000 枚ほどのデータセットである。画像に部分的な破損や染みが存在する場合に異常とみなされ、問題設定としては実際の工業製品外観検査に近い。実験において考慮した各手法とそのハイパーパラメータを表 1 に示す。すべての組み合わせを MVTec の 15 クラスに対して実行すると、実験の総試行回数は 11,550 通りになる。性能は 15 クラスの平均 AUC で評価する。

A study on Feature Extraction using Pre-trained Deep Convolutional Neural Networks for Image Anomaly Detection

<sup>†</sup> Takuya Ono, Mori Junichiro, The University of Tokyo

		活性化層							
事前学習モデル	ResNet-18	1	2	3	4	5	all		
	EfficientNet-B5	1	2	3	4	5	6	7	all
		次元削減率 [%]							
PCAによる次元圧縮	PCA	10	20	30	40	50			
	NPCA 削減なし	10	20	30	40	50			
推定モデル	MVG	近傍数 = 1, 5, 10							
	k-NN								
	Normalizing Flow								

表 1: 実験のパラメータ

次元削減率	0.1	0.2	0.3	0.4	0.5
PCA	0.808	0.847	0.864	0.873	0.880
NPCA	0.919	0.956	0.964	0.967	<b>0.972</b>
削減なし	0.889				

表 2: PCA による次元削減と AUC

### 3.2 実験結果

以下では、実験で性能が優れていた ENB5 を事前学習モデルに用いた際の結果を示す。表 3 に示すように、事前学習した CNN の活性化層からの特徴抽出については、ENB5 の第 7 層の特徴を用いる時、性能が最もよい。特徴量の次元削減について、表 2 に示すように NPCA が有効であり、削減なしよりも良好な性能を示した。また、次元削減率は 20% から 50% が適当である。

活性化層を ENB5 の第 7 層、次元削減を NPCA 50% に固定した上で、表 4 は、近傍数 1 の k-NN および MVG を異常の推定モデルに用いた時の性能を表している。k-NN では AUC 0.973 の性能を示した。なお近傍数 5, 10 と増やしたときの性能の向上は確認されなかった。MVG では AUC 0.975 と最も性能が高く、従来研究 [2] に従う結果が得られた。

pooling に関して、avg pooling が最もよい結果になった。また、データ拡張についてノイズのみのシンプルな方法では AUC は減少したものの、その差は MVG, k-NN 双方において 0.1 ポイント未満に留まった。よって、転移異常検知では従来議論されているようなデータ拡張の重要性は低いと考えられる。

クラス	活性化層							
	1	2	3	4	5	6	7	all
Bottle	0.74	0.84	0.93	0.97	0.99	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>
Cable	0.70	0.71	0.77	0.78	0.80	0.90	<b>0.99</b>	<b>0.99</b>
Capsule	0.73	0.73	0.72	0.90	<b>0.98</b>	0.95	<b>0.98</b>	<b>0.98</b>
Carpet	0.53	0.47	0.47	0.39	0.70	0.99	<b>1.00</b>	<b>1.00</b>
Grid	0.43	0.48	0.41	0.39	0.55	0.76	<b>0.84</b>	0.83
Hazelnut	0.77	0.84	0.82	0.81	0.95	0.98	<b>1.00</b>	<b>1.00</b>
Leather	0.52	0.25	0.34	0.65	0.81	0.98	<b>1.00</b>	<b>1.00</b>
Metal Nut	0.71	0.62	0.81	0.77	0.87	0.94	<b>0.98</b>	0.97
Pill	0.61	0.68	0.69	0.81	0.82	0.80	0.94	<b>0.95</b>
Screw	0.13	0.15	0.35	0.63	0.73	0.85	0.95	<b>0.96</b>
Tile	0.80	0.75	0.92	0.86	0.96	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>
Toothbrush	0.85	0.93	0.94	<b>0.96</b>	0.89	0.89	0.95	<b>0.96</b>
Transistor	0.73	0.80	0.83	0.85	0.92	0.89	<b>0.98</b>	<b>0.98</b>
Wood	0.79	0.79	0.52	0.47	0.82	0.91	<b>1.00</b>	0.99
Zipper	0.59	0.74	0.67	0.87	0.95	0.97	<b>0.98</b>	<b>0.98</b>
平均	0.64	0.65	0.68	0.74	0.85	0.92	<b>0.97</b>	<b>0.97</b>

表 3: k-NN と NPCA 50% による MVTEC の AUC

	min	max	avg	min + max	min + avg	max + avg	min + max + avg
MVG	0.952	0.957	<b>0.975</b>	0.962	0.972	0.973	0.966
k-NN (n=1)	0.953	0.955	<b>0.973</b>	0.962	0.960	0.961	0.960

表 4: pooling と AUC の関係

## 4 結論

本論文では転移学習アプローチによる異常検知の網羅的な評価実験を行った。実験の結果、CNN の深い活性化層における分散が小さい特徴を選択することで、MVG や k-NN など単純なモデルにおいて高い性能を得られることが確認された。今後の展望として、転移学習による異常領域のセグメンテーション、抽出された特徴量に対する分析と動作解明、MVTEC 以外のデータセットに対する有効性の検証などを行っていく。

## 参考文献

- [1] Thomas Defard, Aleksandr Setkov, Angelique Loesch, and Romaric Audigier. Padim: a patch distribution modeling framework for anomaly detection and localization, 2020.
- [2] Oliver Rippel, Patrick Mertens, and Dorit Merhof. Modeling the distribution of normal data in pre-trained deep features for anomaly detection, 2020.
- [3] P. Bergmann, M. Fauser, D. Sattlegger, and C. Steger. Mvtec ad — a comprehensive real-world dataset for unsupervised anomaly detection. 2019.
- [4] Marco Rudolph, Bastian Wandt, and Bodo Rosenhahn. Same same but different: Semi-supervised defect detection with normalizing flows, 2020.