

## PatchCore を用いた撮影環境に堅牢な異常検知

Robust Anomaly Detection Using PatchCore in Adverse Imaging Environment

大竹 智之† 黒木 啓之†  
Tomoyuki Otake Takashi Kuroki

## 1 はじめに

建設機材の製造・レンタルを行っている企業では、毎日使用された大量の機材が返却される。それらの機材は全て人間の目によって高圧洗浄が必要な強い汚れや曲げ歪み等の異常がないか一つ一つ確認を行っている。特に台車の持ち手として用いられるハンドガードは、一日に 1000 本を超える数を分別している。しかし人による分別では、分別する境界が曖昧で、作業者によって精度に差が生じてしまう。また大量の機材が運び込まれる環境では、分別に時間がかかり、高い人件費がかかってしまう等の問題点が挙げられる。このような正常な製品と洗浄が必要である異常な製品を効率よく分別する手段の一つとしてニューラルネットワークによる異常検知が挙げられる。しかし、異常検知は手法によって精度にばらつきがあり、また判別する製品によっても精度が悪くなる場合がある。さらに工場や建設現場のように撮影環境が異なる場合、時間帯や屋内外、雨・塵などのノイズによって画像の色が変わるなどニューラルネットワークにとって外乱となってしまう要素は多数存在する。これらをすべて網羅したニューラルネットワークを構築することは難しく、構築したとしても高精度な異常検知はできない可能性がある。

本研究では、ハンドガードの画像を用いて、機材を正常なものや汚れや歪みといった異常なものを分別し、また環境に影響されない異常検知手法を構築することを目的とする。

異常検知手法は、建設機材のような一般的でないものに対しても精度を維持でき、推論速度が高速な PatchCore を利用する。しかし、異常検知を行う対象によって異常検知手法の精度が異なる場合があるため、第一に異常検知でよく利用される AutoEncoder とそれを拡張した U-Net と比較し、PatchCore がハンドガードに対し最も精度の良い手法であるか実験を行う。第二に工場や建設現場といった異なる環境でも同様の精度を実現するため、撮影環境に影響しない異常検知手法を構築する。

## 2 U-Net, PatchCore

U-Net は AutoEncoder を拡張した手法で、AutoEncoder と同様にエンコーダとデコーダの 2 つで構成されている。また、特徴マップをデコーダとエンコーダで連結することで、物体の位置情報を捉えやすくする特徴がある。そのため U-Net を用いることで、異常個所をより正確に可視化することができる [2]。

PatchCore は、SPADE 及び PaDiM に類似した手法であり、浅い層で現れる画像の細かい特徴と、深い層で現れる学習済みモデルに現れる一般的な特徴を使用せず、中間層の特徴を用いることで、事前学習モデルに偏らない異常検知を行うことができる [1]。本研究では、ハンドガードのという一般的でない機材を使用しているため、この特徴によって他の学習済みモデルを使用した手法と比べ高精度になると考えられる。

## 3 実験方法

本研究では、実験対象をハンドガードとし、まず外乱を含まない画像を利用して最も異常検知精度の高い手法を選択する。ここでは、PatchCore の比較対象として、U-Net, AutoEncoder の 2 つの手法と精度の比較・評価を行う。また手法の比較に加え、学習するデータセットも 2 種類使用し、その手法にとって最も学習しやすい画像がどのような状態であるかについての実験も行う。実験で使用するデータセットは、回転や反転等のデータ拡張のみ行ったものをデータセット 1、データ拡張に加え背景を黒色に変更した画像をデータセット 2 とし実験を行う。

## 4 実験結果

図 1, 図 2, 図 3 に各手法の学習例を示す。図の上部が入力画像、中央が異常検知手法によって生成された画像、下部が入力画像と生成画像の差分を表した画像を示している。PatchCore に関しては、入力画像と異常検知

表 1 各異常検知手法による精度と AUC

データセット	AutoEncoder		U-Net		PatchCore	
	1	2	1	2	1	2
AUC	0.81	0.80	0.86	0.82	0.63	0.95
異常検知精度	78.79	76.51	81.06	75.00	66.60	90.90

によって生成されたセグメンテーションを示す。また、表 1 に 3 つの手法で学習した際の精度と AUC の結果を示す。図の下部から異常がある部分が白くなっていることがわかる。また、表から AutoEncoder と U-Net は背景が一定の画像に対して精度が高いが、PatchCore は逆に精度が悪くなってしまうことがわかる。

## 5 おわりに

本研究では、3 つの手法を比較し、PatchCore を用いた際に最も良く正常と異常を分別でき、精度が高いことがわかった。

これらの結果は、現状外乱を含まず、異常検知手法によって学習しやすい状態で行っている。今後の課題として、PatchCore による異常検知を行う前に、前述した撮影環境や天候・塵といった外乱を含む画像に対しても同等の精度を実現するため、色を調整するニューラルネットワークやノイズを除去するニューラルネットワークを事前に通すなどを行い、精度の向上を目指す。




図 1 AutoEncoder による学習例




図 2 U-Net による学習例




図 3 PatchCore による学習例

## 謝辞

本研究は、ジー・オー・ピー株式会社の助成と実験協力者により行われたことを記し、ここに謝意を表する。

## 参考文献

- [1] Karsten Roth et al. Towards total recall in industrial anomaly detection. *CoRR*, abs/2106.08265, 2021.
- [2] Olaf Ronneberger et al. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015.