ノート

ディープラーニングを用いた外観検査の精度向上 ～正常品のみの学習による判別方法の評価～

木嶋　祐太*　小林　豊*　石澤　賢太*

Study for Anomaly Detection using Deep Learning

KIJIMA Yuta*，KOBAYASHI Yutaka* and ISHIZAWA Kenta*

1. 緒　　言

工業製品の外観検査の自動化に関する県内企業からの要望は多く，ディープラーニングを活用することで，外観検査の自動化が進んでいく可能性がある。過去の研究[1)]では異常品だけを学習して異常品を検知する方法や，異常品と正常品を学習して異常品と正常品を分類する方法を実施した。しかし，工業製品の異常品は極端に少ないことや，学習に使っていないパターンの異常品は検出できないといった背景により，現場への適用まで至らないことがある。そこで，本研究ではネジ画像を対象として正常品のみを学習し，異常品を判別する方法について評価を行った。

2. 判別方法

正常品のみを学習して異常品を判別する 3 つの手法について検討した。

2.1 距離学習による判別

距離学習とは画像の特徴量を，似たデータ同士は近づき，似ていないデータ同士は離れるように特徴空間にマッピングする方法である。この距離学習を使用して，正常品およびそれと関係のない画像を学習すると，正常品の特徴量を得るネットワークを作成することができる。異常品は学習している画像ではないため，正常品よりも若干離れた空間にマッピングされることを利用して異常品を判別する。

距離学習の手法として，特徴抽出に Resnet101 を使っている ArcFace[2)]を用いた。正常品以外の画像としては，Google Open Images Dataset V5 から約 3,000 画像を抜き出した。特徴量ベクトルのサイズは 512 とし，正常品の画像すべての特徴量の平均値を基準とし，それと対象画像とのコサイン類似度を評価値とした。

2.2 オートエンコーダによる判別

オートエンコーダは，対象となる正常品画像をいったん低次元の潜在変数に圧縮し，それを元の画像に復元するネットワークである。学習されていない画像は元の画像に復元できないため，正常品だけで学習したオートエンコーダに異常品の画像を入力すると欠陥の部分が復元できなくなる。このことを利用して，圧縮前後の画像の類似度によって異常品が判別できる。

本研究では類似度計算に SSIM[3)]（Structual Similarity）を用いて，オートエンコーダによる判別を行った。

2.3 学習済み CNN から抽出した特徴量を用いた判別

CNN（Convolutional Neural Network）に画像を入力したときに CNN 内の各層の値が計算されていくが，その値には画像の特徴が抽出されていると考えられる。ビッグデータで学習した CNN を用いてその画像の特徴量を抽出し，正常品であればその特徴量はある範囲内に収まると考え，異常品を判別する方法がある。

* 下越技術支援センター

この異常品を判別する方法は複数提案されているが，本研究では PatchCore[4] という方法を評価した。評価にあたってはその実装である Industrial KNN-based Anomaly Detection[5] を使用した。

3.　ネジ頭の画像による評価

3.1　ネジ頭画像のデータセット

工業製品のデータセットとしてよく使われている MVTec AD（Anomaly detection dataset）[6] Screw の，ネジ頭部分だけを 320×320 で切り出した画像をデータセットとした。図 1 に正常品と異常品の例を示す。正常品の画像は 361 枚で，学習用 325 枚，検証用 12 枚（オートエンコーダと PatchCore は学習用として活用），テスト用 24 枚にランダムで分けた。異常品の画像は 24 枚ですべてテスト用である。

3.2　ネジ頭の画像の判別結果

3.1 で示したテスト用画像に対して判別を実施し，機械学習の評価指数としてよく使われる AUROC（Area Under Receiver Operating Characteristic）を求めた。その結果を表 1 に示す。図 2 の①に入力した画像，②にオートエンコーダの欠陥検出位置，③に PatchCore の欠陥検出位置を示す。欠陥と検出した部分は白く表示しており，オートエンコーダと PatchCore については欠陥の位置を正しく検出していた。

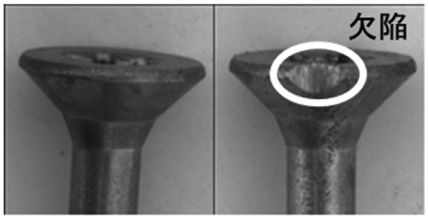

図 1　ネジ頭画像の例
（左：正常品，右：異常品）

表 1　ネジ頭画像の判別結果

判別方法	AUROC
距離学習	0.866
オートエンコーダ	1.000
PatchCore	1.000

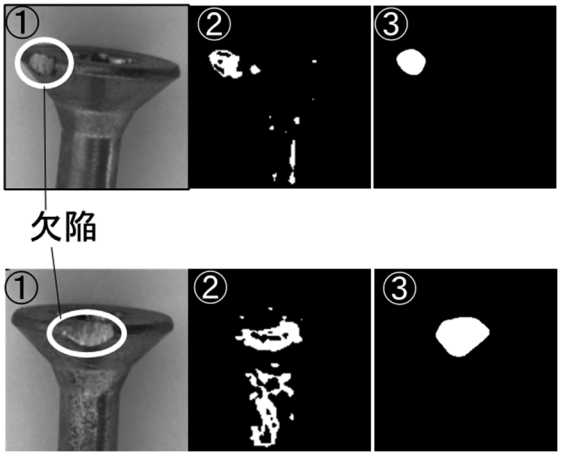

図 2　欠陥検出位置

図 3　ネジ全体画像の例

4.　ネジ全体画像による評価

4.1　ネジ全体画像のデータセット

オートエンコーダと PatchCore について，ネジ全体画像（図 3）に対して判別を実施した。正常品の画像は 361 枚で，学習用 242 枚，テスト用 119 枚にランダムで分けた。異常品の画像は 119 枚ですべてテスト用である。

4.2　オートエンコーダのネジ全体画像の判別

オートエンコーダでテスト用画像を判別した結果，AUROC は 0.775 であった。次に AUROC の改善のため，一つの画像に対する欠陥の面積比率を増やした場合と AE-grad[7] を用いた場合を評価した。

面積比率を増やす場合は，ネジの方向をそろえた画像を，図 4 のように 4 分割し，それぞれの部位ごとにオートエンコーダを学習した。

AE-grad は，オートエンコーダ出力の勾配を用いて，入力画像を繰り返し更新していく手法

で，図 4 の画像に対し AE-grad を適用した。

画像を 4 分割した場合は，評価値を 4 つの画像の評価値の最大値とした。結果は表 2 のとおりで，AE-grad を用いた手法が最も大きかった。しかし，図 5 のような小さい欠陥の画像に対しては，欠陥でない箇所も誤検出して，異常の評価値が高くなっている場合も見受けられたので，過大な AUROC となっている可能性があった。

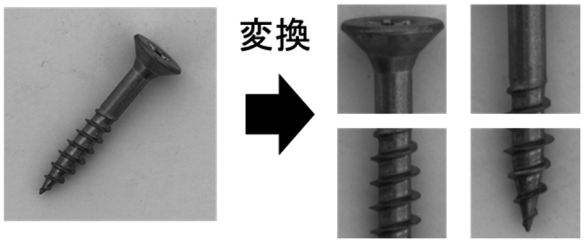

図 4　画像の分割

表 2　オートエンコーダでのネジ全体画像の判別結果

データセット	判別方法	AUROC
画像そのまま	オートエンコーダ	0.775
4 分割	オートエンコーダ	0.964
4 分割	AE-grad	0.998

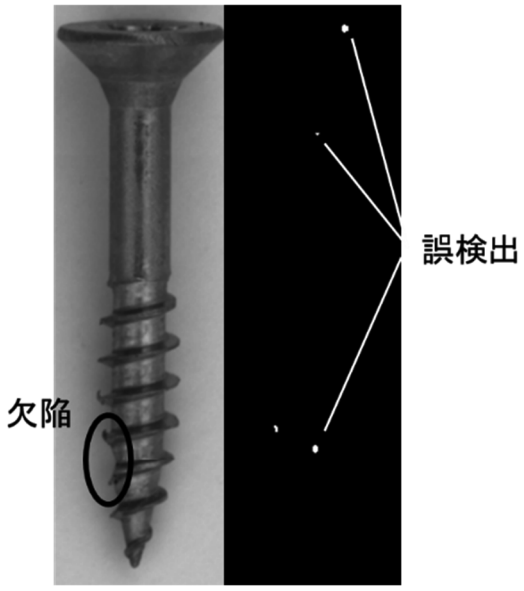

図 5　誤検出

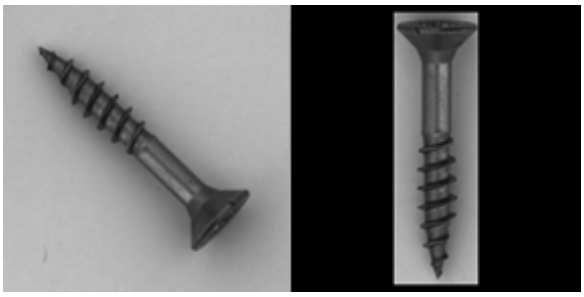

図 6　画像の変換（左：変換前，右：変換後）

表 3　PatchCore でのネジ全体画像の判別結果

データセット	AUROC
画像そのまま	0.885
図 6 の変換	0.961
4 分割	0.976

4.3　PatchCore でのネジ全体画像の判別

PatchCore でテスト用画像を判別した結果，AUROC は 0.885 であった。次に，4.2 と同様に 4 分割した画像と，4 分割せずに背景のみを除去した図 6 の変換を行った画像について評価した。評価結果は表 3 のとおりである。

4 分割した場合の AUROC が一番高くなったが，背景を除去するだけでも十分効果はあることがわかった。また，背景を除去しただけの場合に比べて 4 分割した場合は，小さい欠陥を検出しやすく，小さな正常部の変化を異常と誤検出する傾向があった。

5.　結　　言

(1) 正常品のみの学習による判別方法で，オートエンコーダや PatchCore といった手法が有効であった。

(2) 画像に対する欠陥の面積比率を増やすこと，AE-grad，背景の除去により性能が上がった。

参考文献

1) 木嶋祐太ほか，“AI を活用した金属製品の外観確認の自働化”，工業技術研究報告書，新

潟県工業技術総合研究所，No.50，2021，pp.20-24.

2）Jiankang Deng, Jia Guo, Stefanos Zafeiriou,“Arcface:Additive angular margin loss for deep face recognition”,Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2019, pp. 4690-4699

3）Z. Wang, A. C. Bovik, H. R. Sheikh, E. P. Simoncelli, “Image quality assessment: From error visibility to structural similarity”, IEEE Transactions on Image Processing, vol. 13, no. 4, pp. 600-612,2004.

4）Karsten Roth, Latha Pemula, Joaquin Zepeda, Bernhard Scholkopf, Thomas Brox, Peter Gehler,“Towards Total Recall in Industrial Anomaly Detection”, arXiv(2021), https://arxiv.org/pdf/2106.08265.pdf

5）https://github.com/rvorias/ind_knn_ad,Industrial KNN-based Anomaly Detection,2022 年 3 月 10 日

6）Paul Bergmann, Michael Fauser, David Sattlegger, Carsten Steger,“Mvtec ad – a comprehensive real-world dataset for unsupervised anomaly detection”, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*,2019, pp. 9592-9600

7）David Dehaene, Oriel Frigo, Sébastien Combrexelle, Pierre Eline, “Iterative energy-based projection on a normal data manifold for anomaly localization”, *Eighth International Conference on Learning Representations(ICLR)*,2020