

第 22 回情報科学技術フォーラム (FIT2023) に参加して

大 野 巧 成

Kousei OHNO

情報メディア学専攻修士課程 2 年

1. はじめに

2023 年 9 月 7 日、大阪公立大学中百舌鳥キャンパスで開催された FIT2023 にて「深層ニューラルネットワークを用いた鍛造部品の良品・不良品識別」というテーマで発表を行った。現在、鍛造部品の検査は目視による外見検査が主流である。しかし、目視を行う検査員の確保、検査員による検査精度のばらつきなどの問題がある。本研究は、深層ニューラルネットワーク (DNN) を用いた鍛造部品の良品および不良品の識別を目的とする。外観検査において、不良品の見逃しは最も避けたい事項であるため、不良品を正しく不良品と識別した上で良品の誤識別を低く抑えることが重要である。しかし、鍛造部品の中には良品または不良品の識別が困難なものがある。そこで、判定不能を意味する Unknown クラスを追加し、識別が困難な鍛造部品は Unknown クラスとすることで、良品および不良品の誤識別を減少させることを考えた。本研究では、主成分分析 (PCA) による欠陥部分の強調を前処理とし、DNN を特徴量抽出器として用い、良品および不良品に対応したふたつの OneClassSVM による識別を検討する。また、良品、不良品、Unknown に識別された各画像の確率は、モンテカルロ (MC)・ドロップアウトを用いて求めた。

2. データセット

本研究では、高橋金属 (株) が製造するネジの底面部を撮影した画像に対し、底面部以外は黒色にマスク処理されたものを用いる。データセットには、欠陥が見られない OK 画像、底面部に欠陥が見られる NG 画像があり、学習データ 1,800 枚 (OK 画

像: 900 枚, NG 画像: 900 枚)、テストデータ 300 枚 (OK 画像: 150 枚, NG 画像: 150 枚) に分割した。OK 画像の例を図 1, NG 画像の例を図 2 に示す。




図 1 OK 画像




図 2 NG 画像

3. 提案手法

3.1 PCA による欠陥部分の強調^[1]

前処理として PCA による欠陥部分の強調を行う。縦 1,024 画素×横 1,024 画素から縦 128 画素×横 128 画素にリサイズし、グレースケール化した対象画像を図 3, 対象画像の PCA による再構成画像を図 4, 対象画像と再構成画像との誤差画像を図 5 に示す。図 5 より、右下の欠陥部分が強調されていることがわかる。





図 3 対象画像 図 4 再構成画像 図 5 誤差画像

画像撮影時に生じる回転および細かな位置ずれを考慮するため、Keras の ImageDataGenerator を用いて、画像の水平または垂直方向における反転、幅全体または高さ全体の 2% の平行移動によるデータ拡張を行う。データ拡張を行った学習データの誤差画像を入力とし、DNN を用いた学習モデルを作成する。

3.2 DualOneClassSVM

DNN における全結合層より前までを特徴量抽出器とし、識別にふたつの OneClassSVM を用いる。特徴量抽出器に学習データの誤差画像を入力して得

られた特徴量のうち、OK 画像の特徴量を入力した OneClassSVM (OneClassSVM_OK), NG 画像の特徴量を入力した OneClassSVM (OneClassSVM_NG), これら2つの識別器を DualOneClassSVM と称し、テストデータの誤差画像に対して識別を行う。その際、DualOneClassSVM が出力した OK および NG 判定、どちらにも判定できないものを Unknown とする判定器を用いる。

3.3 MC ドロップアウト

各画像に対する NG の確率 (P_{NG}) を求める際に、MC ドロップアウトを用いた推論を行う。ドロップアウト層が含まれた DNN に対して学習時のみでなく、推論時にもドロップアウトを有効にし、100 回の推論結果の平均をとる。

4. 識別実験結果

特徴量抽出器に学習データの差分画像を入力して得られた OK 画像および NG 画像における特徴量の分布を図 6 に示す。図 6 より、OK 画像および NG 画像における特徴量の分布は大きくわかれるが、OK 画像の分布に近い NG 画像が 1 枚だけ見られた。




図 6 特徴量の分布

テストデータに対する混同行列を表 1 に示す。表 1 より、OK 画像および NG 画像に誤識別はなく OK 画像に 2 枚、NG 画像に 8 枚の Unknown が見られた。

テストデータにおける OK 画像および NG 画像に対する NG の確率のヒストグラムを図 7 に示す。

表 1 テストデータに対する混同行列

		Predict		
		OK	NG	Unk
True	OK	148	0	2
	NG	0	148	8

図 7 の横軸は NG の確率 (P_{NG}), 縦軸は画像の枚数を表す。図 7 より、ほとんどの NG 画像が高い確率で識別できているが、確率が低い NG 画像も数枚ほど見られた。




図 7 NG の確率 (P_{NG}) のヒストグラム

5. おわりに

PCA を用いた欠陥部分の強調および DualOneClassSVM を用いた Unknown クラスの追加により、OK 画像および NG 画像を誤識別することなく、識別が困難なものは判定不能とすることで、誤識別を減少できると考えられる。

また発表中、他大学の学生や企業の方など様々な方がメモを取られていたこと、発表後では限られた質疑応答の時間の中で、メモを取られていた方を筆頭にたくさんの質問を頂いたことから、聴講者の関心を寄せる発表であったのではないかと考える。しかし、奨励賞を受賞できなかった点では、自身の研究に対して創意工夫の余地がまだまだあり、更に突き詰めた研究を行う必要性があると考えます。

参考文献

- [1] 大野他: “深層学習を用いた鍛造部品の不良品検出”, FIT2022, I-014