

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

Discrimination of Defective Forged Parts Using Deep Neural Network

大野 巧成*
Kousei OHNO

藤田 和弘*
Kazuhiro FUJITA

中川 真言†
Makoto NAKAGAWA

世継 武志†
Takeshi YOTSUGI

1 はじめに

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grayクラスを追加し、識別が困難な鍛造部品はgray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、grayに識別された各画像の確率は、モンテカルロ・ドロップアウト(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[?]

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

* 龍谷大学大学院, Ryukoku University Graduate School

† 高橋金属株式会社, Takahashi Metal Industries Co.,Ltd.

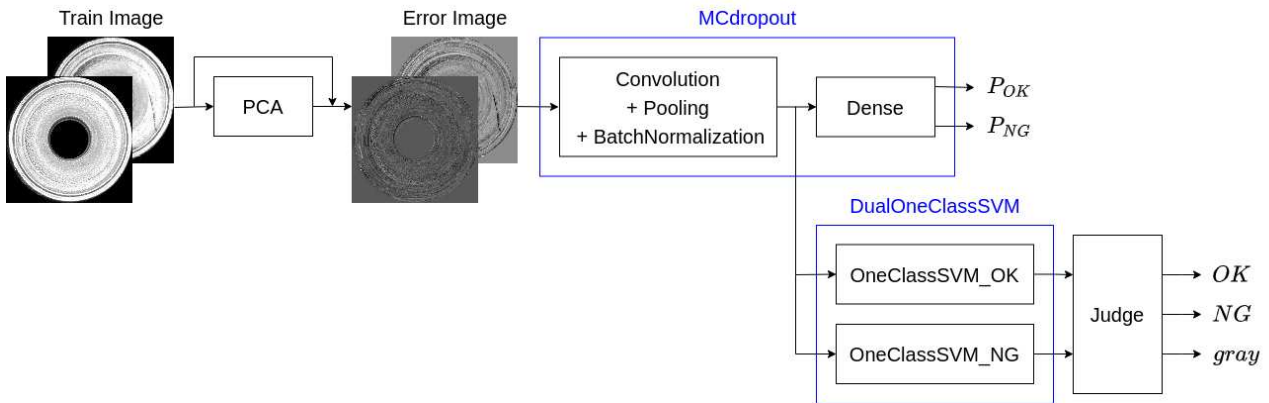


図6 識別アルゴリズム

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grayとする判定器を用いる。本研究の識別アルゴリズムを図6に示す。

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7に示す。図7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7 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画像には2枚、NG画像には8枚のgrayが見られた。

表1 テストデータに対する混同行列

		Predict		
		OK	NG	gray
True	OK	148	0	2
	NG	0	142	8

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8に示す。図8の横軸はNGの確率、縦軸は画像の枚数を表す。図8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8 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gray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。

参考文献

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