

I-014

深層学習を用いた鍛造部品の不良品検出

Detection of Defective Forged Parts Using Deep Learning

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。また、傷や打痕といった欠陥のうち、その大きさや発生部位はさまざまであるため、外観検査において欠陥の見落としが生じる可能性がある。本研究では深層学習を用いた鍛造部品の不良品検出を目的とする。畳込みニューラルネットワーク(以下CNN)に代表される深層学習手法に基づく識別は、稀に、人間では考えられないような誤識別を行うことがある。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、真陽性率=1.0のもとで偽陽性率を低く抑える必要がある。そのため、本研究では主成分分析(以下PCA)による欠陥部分の強調を前処理としたCNNによる不良品検出を検討する。

2 データセット

本研究では、共同研究を行う高橋金属(株)提供のネジの先端部を撮影した画像に対し、先端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、先端部に欠陥が見られるNG画像があり、学習データ2,100枚(OK画像:1,050枚, NG画像:1,050枚)、テストデータ300枚(OK画像:150枚, NG画像:150枚)に分割されている。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

前処理として、データセット内の画像を縦1,024画素×横1,024画素から縦256画素×横256画素にリサイズし、グレースケール化したものを対象画像とする。対象画像の画素を1次元化した列ベクトルを

\mathbf{x}_n , 学習データのOK画像に対してPCAを行い、得られた固有ベクトルを \mathbf{u}_k とする。展開係数を $a_{n,k}$ とし、対象画像 \mathbf{x}_n と固有ベクトル \mathbf{u}_k を用いて次式で求める。

$$a_{n,k} = \mathbf{x}_n^T \mathbf{u}_k \quad (1)$$

対象画像の再構成画像を $\hat{\mathbf{x}}_n$ とすると、展開係数と固有ベクトルを用いて次式により対象画像を再構成する。

$$\hat{\mathbf{x}}_n = \sum_k a_{n,k} \mathbf{u}_k \quad (2)$$

対象画像と再構成画像との差分画像を \mathbf{e}_n とし、次式で求めることで欠陥強調を行う。また、対象画像を図3、再構成画像を図4、差分画像を図5に示す。

$$\mathbf{e}_n = \mathbf{x}_n - \hat{\mathbf{x}}_n = \mathbf{x}_n - \sum_k a_{n,k} \mathbf{u}_k \quad (3)$$




図 3: 対象画像




図 4: 再構成画像




図 5: 差分画像

学習データの差分画像を入力とし、CNNを用いた学習モデルを作成する。CNNの構造を図7に示す。

識別は、対象画像 \mathbf{x} をそれぞれ $0, \pi, \frac{\pi}{2}, \frac{3}{2}\pi$ ずつ回転させたものに対して行い、NG画像と識別された各画像の確率の最大値を用いる。各回転角 θ でのNG画像と識別された確率を $P_{NG}^\theta(\mathbf{x})$ とし、最大値を次式で求める。

$$P_{NG}(\mathbf{x}) =$$

$$\max(P_{NG}^0(\mathbf{x}), P_{NG}^{\frac{\pi}{2}}(\mathbf{x}), P_{NG}^{\pi}(\mathbf{x}), P_{NG}^{\frac{3}{2}\pi}(\mathbf{x})) \quad (4)$$

4 識別実験結果

PCAにおいて次元数を決定するにあたり、ROC曲線におけるAUCの値が1.0に最も近くなる次元数を採用した。次元数に対するAUCの変化を表1に示す。

*龍谷大学大学院, Ryukoku University Graduate School
†高橋金属株式会社, Takahashi Metal Co.,Ltd.


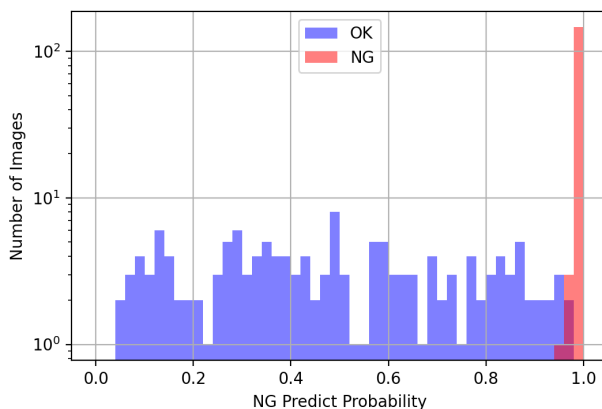


図 6: CNNの構造

表 1: 次元数に対する AUC

		AUC
PCA 次元数	1	0.973
	2	0.967
	4	0.980
	8	0.989
	16	0.999
	32	0.963

$P_{NG}(x)$ をもとに、テストデータにおけるOK画像およびNG画像の識別結果の分布を図7に示す。図7の横軸はNG画像と識別された確率 $P_{NG}(x)$ 、縦軸は画像の枚数を表す。図7より、NG画像は高い確率で識別できる結果となった。また、OK画像およびNG画像の識別における閾値は0.94とした。

図 7: $P_{NG}(x)$ の分布

ROC曲線を図8に示す。ROC曲線の横軸は偽陽性率(以下FPR)すなわち誤ってNG画像と識別されたOK画像の割合、縦軸は真陽性率(以下TPR)すなわち正しくNG画像と識別されたNG画像の割合を表す。図8より、 $TPR=1.0$ においてNG画像と誤識

別されたOK画像の割合は2.7%であった。




図 8: ROC曲線

図7より、閾値を0.94とした際のテストデータに対する混同行列を表2に示す。表2より、NG画像は誤識別することなく正しく識別できており、OK画像には4枚の誤識別が見られた。

表 2: テストデータに対する混同行列

		Predict	
		OK	NG
True	OK	146	4
	NG	0	150

5 おわりに

本研究では、鍛造部品におけるOK画像およびNG画像の識別を行うことで不良品検出の検討を行った。PCAを用いて欠陥強調を行うことにより、NG画像を誤識別することなく識別した上でOK画像の誤識別を少なく抑えることができた。今後は、アンサンブル学習やマルチモーダル学習による識別などについて検討していきたい。