

4C-02

人工知能を用いた自動外観検査アルゴリズムの溶接部への適用

Application of AI visual inspection algorithm to welding parts

山田理恵^{†1} 後藤美紀^{†1} 齊院龍二^{†2} 大門智博^{†2} 豊丸弘爾^{†1}

アイシン精機株式会社^{†1} アイシン・ソフトウェア株式会社^{†2}

1. はじめに

溶接部品の外観検査においては、現在目視での検査が行われている。検査員の経験の差や個人差により良品および不良品の判定基準がばらつき、品質にも影響を及ぼす。

近年画像認識技術の高まりから、外観検査においても Deep Learning を用いた自動化が注目されている。しかし、これらの技術を実際の検査工程に導入にあたり、判定根拠、特に部品の欠陥に注目して判定していることを説明する必要がある。

そこで、我々はセマンティックセグメンテーションタスクで用いられる U-Net 構造を用いて良品および不良品のクラス分類を行うことで、判定結果に加えて追加の計算を行うことなく判定根拠が可視化可能なネットワークを提案する。また、実際に工場で生産されている溶接部品の画像を用いて、本手法の有効性を検証する。

2. 提案手法

本研究では、主にセマンティックセグメンテーションの用途で用いられる U-Net[1]をベースとしたネットワークを発展させ、クラス分類に用いる。U-Net は Encoder-Decoder 構造を持ち、Encoder の各層で出力される特徴マップを Decoder の対応する各層の特徴マップと連結することで位置情報を保持し、入力画像と同等サイズとなる Decoder の出力画像における詳細な特徴の復元を可能にしている。

提案手法では、入力画像と同じサイズまで復元した層を 2 チャンネルに畳み込み、特徴マップを求める。Global Average

Pooling で各チャンネル平均を求め、最終出力を二次元として良品および不良品の 2 クラス分類とする。この際、不良品クラスの確率を求めたチャンネルを可視化に用いる。特徴マップを可視化した画像（ヒートマップ）の赤い箇所が不良品らしさを表し、青い箇所が良品らしさを表す。図 1 に本研究で用いたネットワークの構造を示す。その他、従来の U-Net からの変更点は以下の 3 点である。

①Encoder から Decoder の特徴マップの行列の連結を要素和としている。

②Encoder の下位層から上位層にかけてチャンネル数を一定としている。

③Encoder のダウンサンプリング時に、Max Pooling ではなくストライド 2 の畳み込み層としている。

ネットワークの判定根拠の可視化は Grad-CAM[2]や Grad-CAM++[3]などが提案されているが、いずれもクラス分類を行った後に追加の計算が必要である。提案手法では構築したネットワークに組み込まれており、追加計算不要で判定根拠が可視化可能になっている。

3. 実験

3.1 データセット

本研究では、実際に工場で生産されている溶接部品の画像を用いる。図 2(a)-(d)に、良品および不良品の欠陥モード別の元画像の代表例を示す。不良品の欠陥モードは、種類に注目して 3 つに分類すると、穴（大）、穴（小）およびゆがみである。各データセットの枚数を表 1 に示す。データセットの train, validation, test の用途は、それぞれモデルの重みを学

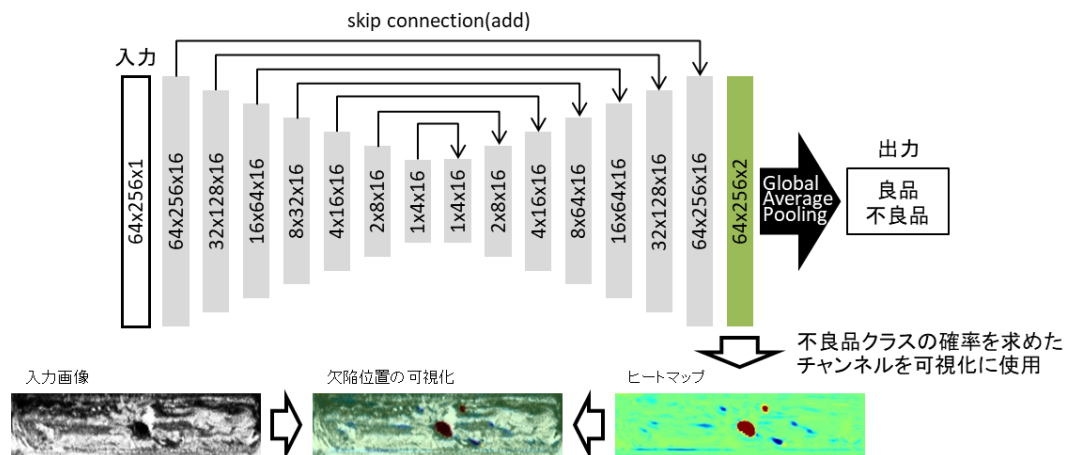


図 1 提案手法のネットワーク構造




図2 test データの良品画像と不良品画像（欠陥モード別）の代表例
((a)-(d)元画像、(e)-(h) (a)-(d)の入力画像とそれぞれのヒートマップの重ね合わせ画像)

表1 各データセットの良品および不良品の画像枚数

データセット	良品画像数[枚]	不良品画像数[枚]
train	7242	415
validation	2393	63
test	6520	32

習するため、検証で適切なハイパーパラメータを選定するため、モデルの評価に用いるためである。train および validation データは同時期に生産した溶接部品の画像であり、test データの画像とは生産期間が異なる画像で構成している。

元画像は全体的に輝度値が低いため、コントラストを上げるため入力画像はヒストグラム平坦化を行い、train データに対してはデータの水増しを行っている。

3.2 実験結果

学習は 1000epoch 回し、十分に収束した。test データの評価は、validation データにおける見逃し枚数が最小時の epoch 数のモデルを用いて行う。モデルの評価は、見逃し枚数および過検出率を用いる。なお、見逃しは不良品を良品として、過検出は良品を不良品として予測することを意味する。実際の現場では、不良品を流出させてはいけないため、見逃し数 0 は必須条件である。test データの Confusion Matrix を表 2 に示す。見逃しは 0 枚、過検出率は 3.6% を達成した。良品および不良品の欠陥モード別のヒートマップを入力画像に重ね合わせた画像の代表例を図 2(e)-(h) に示す。ヒートマップは不良品画像の欠陥位置に赤く反応し、良品および不良品の共通の特徴部分に青く反応しており、良品および不良品の

表2 test データの Confusion Matrix

		予測されたクラス	
		不良品	良品
実際の クラス	不良品	32	0
	良品	234	6286

特徴をどちらもよく捉えていると考えられる。

4. 結論

クラス分類の判定結果に加えて追加計算を行うことなく判定根拠が可視化可能なネットワークを提案し、実際に工場で生産されている溶接部品の画像を用いて本手法の有効性を検証した。その結果、見逃し 0 枚、過検出率 3.6% を達成した。また判定根拠の可視化したヒートマップは、欠陥位置に赤く反応しており、欠陥の特徴をよく捉えていると考えられる。したがって、本手法は実際に工場で生産されている溶接部品を用いた良品および不良品の分類において有効であることを明らかにした。

参考文献

- [1] O. Ronneberger, *et al.*, “U-net: Convolutional networks for biomedical image segmentation,” in MICCAI, 2015.
- [2] R. R Selvaraju, *et al.*, “Grad-cam: Visual explanations from deep networks via gradient-based localization,” in ICCV, 2017.
- [3] A. Chattopadhyay, *et al.*, “Grad-cam++: Generalized gradient-based visual explanations for deep convolutional networks,” in WACV, 2018.