

人工知能を用いた外観検査判定精度向上技術の研究

Research on Technology to Improve the Determination Accuracy of Visual Inspection Using Artificial Intelligence

福留祐太*・新見浩司**

Yuta Fukudome, Koji Niimi

*電子・有機素材研究所 電子システムグループ、**機械素材研究所 機械・計測制御グループ

近年、人手不足が進む中での生産性向上の実現に向け、画像処理技術を用いた外観検査の自動化が多く望まれているが、従来型の画像処理装置では、照明環境や欠陥の大きさが一定でない場合に、判定精度が大きく下がってしまう。そこで、本研究では、人工知能技術を活用し、照明環境や欠陥の大きさが変化する場合の外観検査に対する判定精度を向上させる技術の研究を行った。その結果、従来に比べて高い判定精度をもつ外観検査技術を確立した。

1. はじめに

鳥取県の人口は減少傾向が続いており、全国の10年先を進んでいると言われる老年人口割合の増加とも相まって、県内の企業からは、人手不足が進む中での競争力確保に向けた、ロボットや自動機械の導入による生産性の向上を望む声が多く寄せられている。特に、現在も多くの生産現場で検査員の目視による検査が依然行われている、外観検査工程の自動化に関する要望は多い。

外観検査工程を自動化する際、これまで「パターンマッチング」と呼ばれる画像処理手法が多くの場面で用いられてきた。例として、図1に「パターンマッチング」の最もオーソドックスな手法である「テンプレートマッチング」の説明図を示す。この手法では、検出したい欠陥の画像そのものをテンプレートとして登録し、対象の画像の一部分との類似性について、対象領域を切り替えながら検索していく。この方法により、対象の欠陥が画像内のどこに写っているか、いくつ写っているかといった情報を画像から抽出することができる。

しかしこの方法では、照明変化が大きい場合や欠陥の大きさが一定でないなど、基準となるモデル画像からの変化が大きい場合に、検出精度が大きく低下するという課題があった¹⁾。

そこで本研究では、近年注目されている人工知能

(AI) 技術を活用し、照明環境や欠陥の大きさが変化する場合の外観検査に対する判定精度を向上させる技術について実験に基づき検討したので報告する。

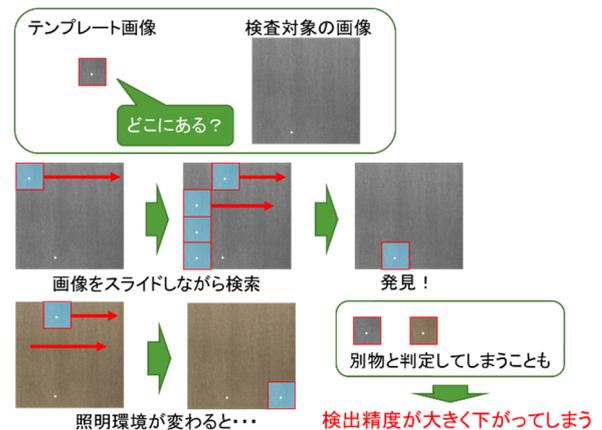


図1 テンプレートマッチング

2. 実験方法

2.1 検査対象

検査対象は図2に示すようなアルミ板製品とした。この検査対象の外観検査においては、表面上の圧痕・打痕・擦り傷などの有無がOK/NGの判断基準となるが、表面の反射率が非常に高いため、画像処理に適した照明環境の構築が難しい。

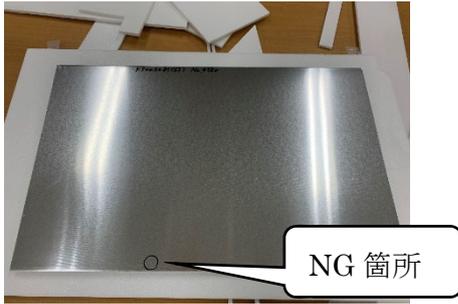


図2 検査対象の例

2.2 システム構成

図3に本研究で実験に用いたシステム構成を示す。カメラを上方に配置し、2個のLEDバー照明を用いて左右斜め方向から検査対象表面に向けて拡散光を照射している。



図3 システム構成

また、図2で示したサンプルをこのシステムで撮像した際の画像データを図4に示す。本来、画像処理技術を用いた外観検査を行う場合、照明が均一に照射されたムラのない画像を得ることが望ましい。

しかしながら、自動化を考慮すると外観検査の終了後はロボットによる搬送を行う必要がある。そのため、検査対象の上部に十分なスペースを用意しなくてはならない。この制約条件から、照明条件を十分なものにすることができず、画像データの左右がそれぞれ半円状に少し明るくなってしまっている。

このような照明条件下において、従来の「パターンマッチング」を活用した検査手法では安定した欠陥検出が難しい。

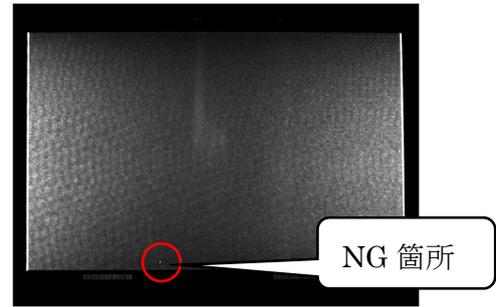


図4 撮像したデータの例

2.3 AIモデル

工業製品は一般的に不良品の数が少ない。したがって、得られるNGデータがOKデータに対して著しく少ないという特徴がある。このデータ比率の偏りに対する解決策として、本研究では以下の2つの異なるアプローチを試みた。

- ① OKデータのみで学習（教師なし学習）
- ② NGデータを水増しして学習

①のアプローチとしては、オートエンコーダ(AE)と呼ばれる、AIモデルについて検討を行った。AEの説明図を図5に示す。入力された画像データを一度圧縮し、重要な特徴量のみを残した後、再び元の次元に復元処理をする。

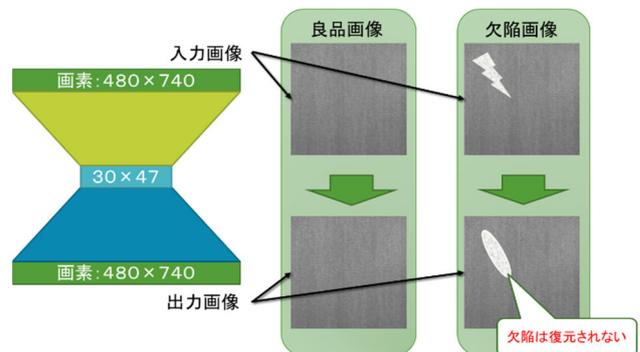


図5 オートエンコーダ(AE)

AEの学習にはOKデータのみを用いるため、欠陥は復元されない。つまり、入力画像と出力画像との差分をとることで欠陥の有無を判別することができ

る。AE の学習には約 4000 枚の OK データのみから構成される学習用データセットを作成し、実験を行った。

次に、②のアプローチとして、検査画像を分割して局所的に検査を行うとともに、図 6 に示す画像切り出しツールを作成し、NG データを水増しする手法を考案し、検討を行った。



図 6 画像切り出しツール

作成した画像切り出しツールでは、ツール画面上に表示された画像の欠陥箇所を選択することで、ランダムに座標をずらした分割サイズの NG 画像を任意の数だけ生成することができる。

この水増しした NG データと分割した OK データをそれぞれ約 6000 枚とした学習用データセットを作成し、畳み込みニューラルネットワーク (CNN) による AI モデルの作成を行った。例として、2 層の場合の CNN の説明図を図 7 に示す。CNN は画像認識分野において数多くのプロジェクトで採用されている AI モデルの一つである²⁾が、最適な層の数やパラメータ等は対象ごとに異なる。そのため、層数の異なる AI モデルを複数作成し、実験を行った。

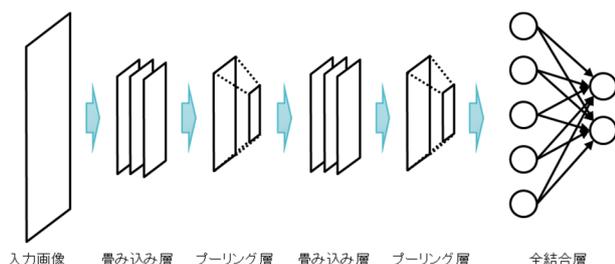


図 7 畳み込みニューラルネットワーク (CNN)

3. 結果と考察

実験の結果を表 1 に示す。評価の指標には正答率 (Accuracy) と適合率 (Precision) を用いた。正答率は評価に用いたデータの中で、実際に正しく予測できた割合を示し、適合率は OK と予測して、実際に OK だったものの割合を示す。本研究では、不良の見逃しを最小化するため、正答率よりも適合率を重視した。その結果、検査画像を分割するとともに、NG データを水増しし、CNN による AI モデルを作成することで、AE を用いた手法に比べて正答率、適合率ともに大きく改善し、層数 6 の CNN で適合率 96.54% を達成することができた。

表 1 AI モデル評価結果

AI モデル	層数	正答率	適合率
AE	4	0.7233	0.6753
CNN	2	0.9405	0.9519
	4	0.8655	0.9086
	6	0.9693	0.9654
	8	0.9651	0.9599
	9	0.9512	0.9116

4. おわりに

本研究では、近年注目されている人工知能 (AI) 技術を活用し、照明環境や欠陥の大きさが変化する場合の外観検査に対する判定精度を向上させる技術について、アルミ板を対象に検討を行った。

その結果、検査画像を分割するとともに、NG データを水増しし、CNN による AI モデルを作成する手法を考案し、正答率と適合率共に 90%以上を達成する AI モデルを開発した。

今後は、製造現場での活用を進めるため、データの蓄積を続け、検査精度の更なる向上を進める予定である。

謝 辞

本研究を進めるにあたり、検査対象のデータ取得にご協力いただいた株式会社片木アルミニウム製作所大山工場に厚くお礼申し上げます。

文 献

- 1) 新田 雅康; 金属表面検査における画像処理技術動向, 電気製鋼, 79(4), p.299-303(2008).
- 2) 久保田進也; Deep Learning の外観検査への適用と研究動向, 精密工学会誌, Vol.85, No.1, p.27-30(2019).