

## 機械学習を用いた画像判別に関する研究

生産技術部 ○上菌 剛, 谷山清吾

### 1. はじめに

近年, AI (人工知能) という言葉が当たり前のように使われている。AIにおける研究課題の一つに機械学習がある。機械学習とは, 「データから反復的に学習し, そこに潜むパターン (特徴) を見つけ出すこと」であり, 様々なアルゴリズムが提案されている。その中で, 現在のAIブームの火付け役となった技術がDeep Learningである。Deep Learningでは, コンピューターが自ら学習データから特徴量を抽出し, 予測モデルを構築することが可能であるため, 人間が介在して特徴量設計を行う必要がなく, 以前よりはるかに容易に機械学習を行うことができるようになった。本研究では, 工業製品の外観検査の自動化を目的に, Deep Learning技術を適用して良品, 不良品の判別を行う技術について検討した。

### 2. 実験方法

#### 2. 1 学習と評価に用いる画像

実験に供する工業製品 (以下, サンプル) は, 県内企業が目視検査で月産7万個程出荷する鋳造加工部品 (図1: ナット, 42mm角) を対象にした。一般的にDeep Learningでは膨大な画像データが必要であることが想定されたので, サンプル個々の全体画像ではなく, 1個のサンプルから多数の画像を得ることとした。鏡を利用してサンプル内側加工面のねじ山部分を撮像 (図2, 図3) して内面展開画像 (図4) を得て, そこから小さな画像 (図5) を多数切り出す。撮像に供するサンプルは4個とし, サンプル1には $\phi 0.5$  mm, 2には1.0mm, 3には1.5mm, 4には前述の3種類の大きさの貫通穴をドリルで開け疑似不良とした。切り出した小さな画像で, 貫通穴が写っていないものをOK画像, そうでないものをNG画像とした。

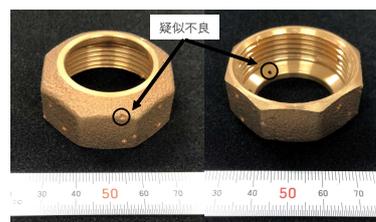


図1 鋳造加工部品 (ナット)

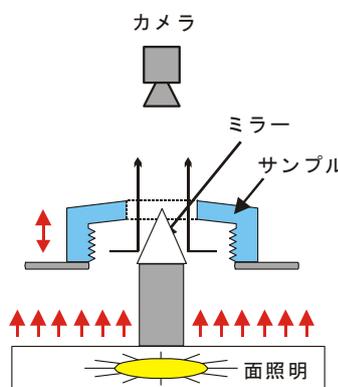


図2 内側加工面の撮像

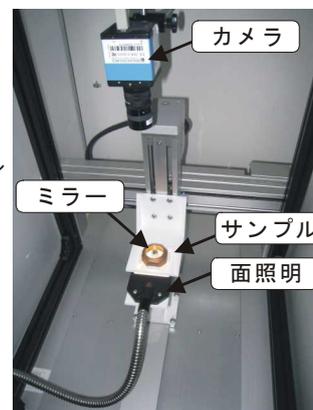


図3 構築したシステム



図4 内面の展開画像



a) OK画像 b) NG画像

図5 実験に供する画像

#### 2. 2 AIアルゴリズム

工業製品の外観検査において, 一般的には不良品の発生はそれほど多くないため, 不良品の情報がなくても学習できる教師無し学習でアプローチした。このような分野で, 現在主流となっている技術は, 距離学習 (Metric Learning) であり, 本研究ではこの技術を採用した。距離学習とは, データ間の計量 (距離や類似度など) を学習する手法である。本研究におけるAIモデルの全体像を

図6に示す。AIモデルのベースには、学習済みのモデル（MobileNetV2：2018年にGoogleが開発）を用いた。距離学習の損失関数（正解との誤差を表す指標）にはL2 Softmax Lossを使用し、その出力を基に特徴量を算出した。実験は①モデルの学習に、OK画像のみ9,000枚を用いた場合と、②OK画像9,000枚とNG画像100枚、合計9,100枚を用いた場合の2とおりの学習を実施した。評価は、4個のサンプルのOK画像とNG画像を、それぞれ1,000枚（合計8,000枚：学習には使用していない画像）を入力し各画像の特徴量を算出した。

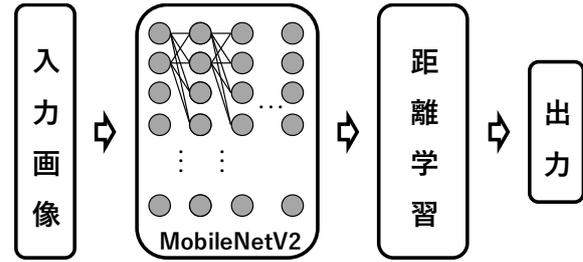


図6 モデルの全体像

### 3. 実験結果

実験①の学習画像にOK画像のみを使用した場合は、OK画像とNG画像を判別することはほとんどできなかった。これは、NG画像の不良領域（穴部分）の全体に占める面積が1～4%程度と小さく、ほとんどの場所でOK画像と同等の様相であることが原因と思われる。

実験②の学習画像に少量のNG画像100枚を追加して学習させた場合は、良好な結果を得た。結果を図7に示す。横軸は8,000枚分の評価画像で、左半分がOK画像、右半分はNG画像である。縦軸は異常スコアで、OK画像の特徴量を基準（0付近）として、そこからの特徴量の差を表している。右半分のNG画像の異常スコアが総じて大きくなっており、OK画像とは違うものであると判断していることが判る。サンプル1（φ1.5mm）とサンプル2（φ1.0mm）はOK画像とNG画像で異常スコアのオーバーラップがなく、明確に区別できており、判別率は100%である。しかし、サンプル3（φ0.5mm）とサンプル4（φ0.5mm, 1.0mm, 1.5mm）

ではオーバーラップを確認した。この結果から、現在のモデルでの検出限界はφ0.5mm～1.0mmの間となる。ただし、OK画像の99%程度は、NG画像の最小異常スコアより小さい値なので、OK画像として判別できることになる。残り1%を目視検査するという運用により、検査コストを大幅に軽減することができる。

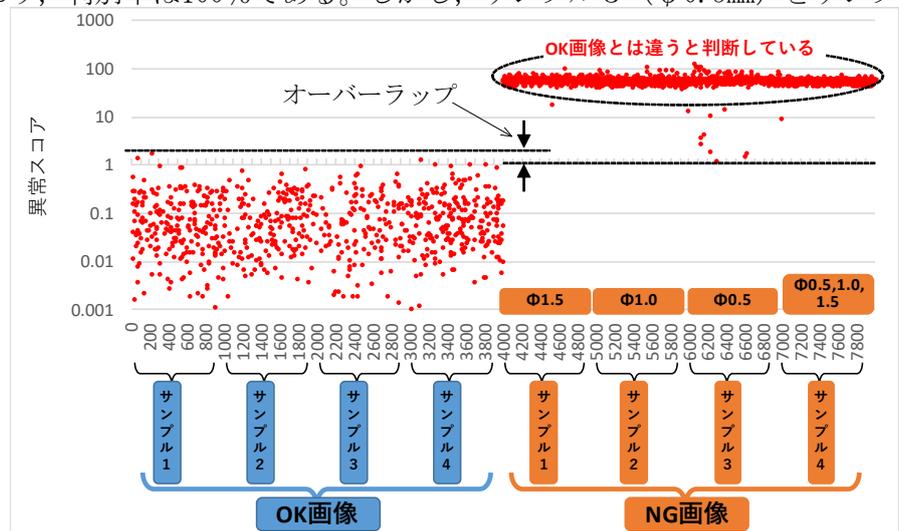


図7 評価結果（少量のNGを追加して学習）

### 4. おわりに

外観検査の自動化が実現していない鋳造加工部品の良否判定を対象に、Deep Learningによる機械学習を適用し、φ1.0mm及び1.5mmの疑似不良のNG画像を100%判別できた。今後はサンプルの全体画像を対象に本技術を適用することで、製品の不良判別が可能なシステムの構築を進める。