

畳み込みニューラルネットワーク (CNN) を用いた転移学習による ラップフィルムの不良品検出

—InceptionV3 の転移学習による CNN の設計と評価—

永田研究室 F117001 有馬 滉宜

1. 目的

製品の検査工程においては、検査員の作業負荷や検出基準の不確かさなど様々な問題が生産性の低下を招いている現状である。近年、このような問題を解決するため画像認識に特化させた機械学習の手法の一つである畳み込みニューラルネットワーク (CNN) を製品の欠陥検出に応用しようとする試みがなされている。本研究では、学習済み CNN モデルの転移学習により、ラップフィルム製品の製造工程で発生する欠陥の検出を試みる。

2. 研究内容

まず、治具を含むラップフィルム製品の全体画像に対してテンプレートマッチングを適用し、図 1 のようにラップフィルム部分のみを抽出する画像処理を行う。対象となる画像に対し、あらかじめオリジナル画像のフィルム部分のみをトリミングしたテンプレート画像を左上から右下にかけて 1 ピクセル移動させながらラスタースキャンさせ、相関係数の高い領域を抽出する。今回は実際の生産ラインに設置されたカメラで撮影された 640×480 の解像度を持つラップフィルム製品の画像を 347×347 の画像の解像度にダウンサイジングする。次に、学習済み CNN モデルの転移学習により新たな CNN を設計する。学習済みの CNN には InceptionV3 を用いる。転移学習により InceptionV3 の終段にある全結合層部を 2 クラス分類用に置き換える。この CNN に対して全層を追加学習させた CNN (IncA) と、終段にある全結合層部のみを追加学習させた CNN (IncB) を用いて分類性能を比較する。

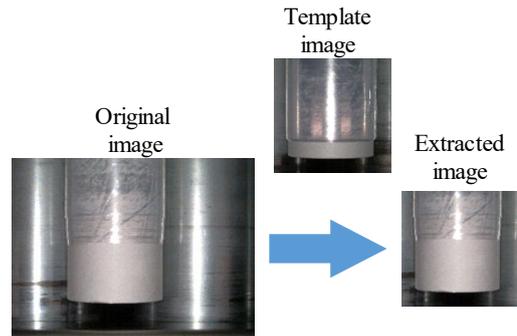


Fig. 1 An example of extracted image using the template matching technique.

IncA と IncB の共通条件として、汎化性を発揮できるように良品と不良品の画像それぞれ 34,482 枚と 2,233 枚からなるデータセットを用いる。ただし、不良品画像に対しては水平反転の画像処理 (画像オーギュメンテーション) を施し、画像データセットを拡張している。また、主な学習条件として最大エポック 4、ミニバッチサイズ 50、学習率を 0.0001 に設定し訓練を行う。訓練後には IncA と IncB の汎化性能を評価するため、未学習の良品と不良品の画像をそれぞれ 4,035 枚と 21 枚を用いて分類実験を行う。

3. 結果

転移学習によって新たに設計した IncA と IncB の分類実験により誤認識した合計枚数がそれぞれ 3 枚、22 枚となった。得られた分類結果を基に 4 つの評価基準となる認識率 A_c 、精度 P_r 、再現率 R_e 、 F 値 F を算出した結果を表 1 に示す。認識率はテスト画像データセットに対する正解率を、精度は不良品と判断された画像のうち実際に不良品であった割合を、再現率は実際に不良品である画像が正しく不良品と判断された割合を、さらに F 値は精度と再現率の調和平均の値をそれぞれ表す。IncA の認識率と再現率はそれぞれ 0.998、0.904 であった。再現率が高いということは、不良品画像をしっかりと認識し、正しく不良品と分類できていることになる。IncB は IncA に比べ誤認識枚数が多かったため 4 つの評価基準の値も IncA に比べ低くなった。これらの結果から、全層を追加学習させることでより高い分類性能を得られることが確認できた。今後の展開として、他の製品にも転移学習ベースの CNN による欠陥検出法を適用し、その有用性を評価していきたい。

Table 1 Evaluation results of IncA and IncB.

	Accuracy	Presision	Recall	F-measure
IncA	0.998	0.791	0.904	0.844
IncB	0.994	0.485	0.809	0.607