

CNN による欠陥検出と Grad-CAM による欠陥部分の可視化の性能を向上させる画像拡張法の一提案

永田研究室 F118002 阿部 凌真

1. 目的

様々な工業製品の検査工程の自動化に伴い、深層学習の技術を画像認識に特化させた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活発に行われている。本研究では、事前に3つの訓練データセットを作成し、学習済み CNN モデルの転移学習により新たな3つの CNN を設計し、工業製品の分類実験を行う。その後、製品の欠陥部分の可視化を行い不良品と判定した根拠となった領域を確認する。

2. 研究内容

本研究では学習済み CNN モデルである InceptionV3 の転移学習により、工業材料のための欠陥検出用 CNN を構築した。元画像のサイズは 300×300 ピクセルであり、製品の背景には製造工程の制約からブルーシートが含まれている。まず、良品と不良品画像それぞれ 1,380 枚、56 枚からなる訓練データセット A と良品と不良品画像それぞれ 64 枚、20 枚からなるテストデータセットを作成する。次に訓練データセット A に対して不良品画像にのみ水平反転処理を行い 112 枚に増やし、良品と不良品画像それぞれ 1,380 枚、112 枚とする。次に、画像内の製品部分のみを約 150×300 ピクセルで切り出し、それらを事前に用意した 7,500 枚の柄や文字の入った背景画像からランダムに抽出した 1 枚の中心にそれぞれ貼り付ける。これにより生成された良品と不良品画像それぞれ 1,380 枚、112 枚からなる訓練データセット B を作成する。さらに、7,500 枚の背景画像からランダムに抽出した 150 枚に対して、ある 1 枚の製品画像を貼り付け、位置を上部から下部へと 1 ピクセルずつずらす処理を行う。背景画像は 300×300 ピクセルであり、切り抜いた製品画像は約 150×300 ピクセルであるため、製品画像 1 枚につき 150 枚の新たな画像が生成され、良品が $1,380 \times 150 = 207,000$ 枚、不良品が $112 \times 150 = 16,800$ 枚の画像が得られる。最後に、良品画像が多いことによる過学習を防止するため、良品画像の中から 22,000 枚を無作為に抽出し、良品と不良品画像それぞれ 22,000 枚、16,800 枚からなる訓練データセット C を作成する。作成した訓練データセット A, B, C を用いて訓練した CNN をそれぞれ IncA, IncB, IncC とし、分類実験には良品と不良品画像それぞれ 64 枚、20 枚からなるテストデータセットを用いてそれぞれの分類精度を評価する。本研究では、分類したテストデータセットに対して Grad-CAM を用い判定した根拠となった領域をカラーマップで表示することで、それぞれの可視化性能を評価する。




Fig. 1 Examples of images of training dataset A, B and C.

3. 結果

3つの CNN ともに良品画像は 64 枚全て正しく分類することができた。一方、不良品画像では IncA が 15 枚、IncB が 4 枚、IncC が 1 枚をそれぞれ誤分類する結果となり、画像拡張に伴い分類精度は向上していることが確認できた。図 2 には例として、各 CNN がテストデータに含まれる不良品画像 1 枚を分類した際の判定の根拠となった部位を Grad-CAM で可視化した状況を示す。IncA ではブルーシートのしわや陰を注視しており、IncB では比較的注目箇所が製品部分へ近づき、さらに IncC では欠陥部分をより鮮明に注視できていることが確認できた。以上の結果より、提案する画像拡張法を用いることにより分類精度と可視化性能共に向上させることができた。今後の展望として、他の工業製品の生産ラインに対しても同様の分類精度と可視化性能を有する CNN を設計したい。




Fig. 2 Comparison of visualization performance of defect area by Grad-CAM .