

# Grad-CAMによる欠陥領域の可視化性能を向上させる画像拡張法と CNNによる分類時のスコアの影響

阿部 凌真† 有馬 滉宜† 清水 竜樹† 永田 寅臣† 加藤 博久‡ 渡辺 桂吾§  
†山口東京理科大学大学院工学研究科 ‡山口東京理科大学工学部機械工学科 §岡山大学  
E-mail: nagata@rs.socu.ac.jp

## 1 はじめに

様々な工業製品における欠陥の種類やサイズは多岐にわたり、最終的な検査作業は熟練した検査員の目視検査に頼ることが多い状況にある。しかし、検査員の育成には時間がかかり、また熟練の検査員でもその日の体調や気分によっては良品と不良品の判断基準の曖昧さが生じることがある。最近では、AI技術の中でも深層学習を画像認識に特化させた深層畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) [1] を応用し、製品の検査工程における不良品検出や欠陥検出を行おうとするシステムの開発が活発になっている。

例えば、T. Koeipensriらは、光沢のある金属製品の表面欠陥をCNNモデルであるVGGNetを用いて検出する手法の有効性を紹介した [2]。また、中島らは、筆記具部品の欠陥の有無をディープラーニングによる画像認識を用いて検査する研究を行っている [3]。しかしながら、類似した多くの画像の中から少ない頻度で発生する微小な欠陥を高精度に検出し、不良品として分類することは困難だけでなく、ソフトウェアに関する多くの高度な専門知識も必要とされるため製造メーカーが検査システムを自社開発する上での大きな課題となっている。

筆者らは、製造業が抱える品質管理に関する課題を解決するために、熟練した検査員のような不良品の識別能力を有するCNN, SVM(Support Vector Machine), CAE (Convolutional Auto Encoder) などのAIの設計と訓練を簡単な操作で効率的に実行できるように図1に示すような設計支援ツールの開発を行っている [4]。これまでの研究成果として、幾つかの工業製品についてそれぞれの製造メーカーが求める目標認識率を達成することが出来ているものの、不良品の根拠となった部分の可視化機能に対してはまだ十分に対応できていなかった [5]。

本研究では、事前に3つの訓練データセットを作成した後、CNN&SVM設計支援ツールを用いて学習済みCNNであるInceptionV3 [6]の転移学習により新たな3つのCNNを設計し、分類実験を行う。また、分類時のスコアが製品に含まれている欠陥領域の可視化性能にどのような影響を及ぼしているかを評価する。今回はMATLAB上で開発するアプリケーションにも実装が可能なGrad-CAMを可視化ツールに選択した。Grad-CAMを用いてCNNが分類のために注視している箇所をカラーマップで表示させ、欠陥と判定した根拠となった領域の可視化を試みる。

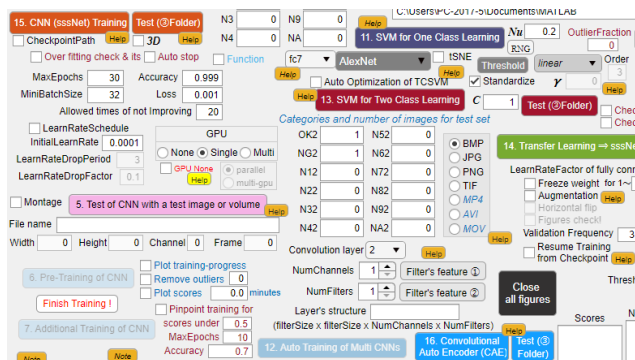


Figure 1 A part of main dialog developed on MATLAB system to user-friendly design CNN, SVM and CAE.

## 2 画像拡張法の提案

### 2.1 オリジナル画像

本研究では、まず、図2のような工業製品に含まれる欠陥の検出を行う。事前に $300 \times 300$ ピクセルの良品と不良品画像それぞれ1,444枚、76枚の計1,520枚を採集した。良品画像は1,380枚を訓練用に、残りの64枚をテスト用に用いる。また、不良品画像は不良品の発生頻度が低いために採集できた枚数が少ないものの、56枚を訓練用に、残りの20枚をテスト用に用いる。ここで得られた良品と不良品の画像それぞれ1,380枚、56枚を訓練データセットAとし、残りの良品と不良品の画像それぞれ64枚、20枚をテストデータセットとする。なお、製造工程上の制約から製品の背景にはブルーテープ(ブルーシート)が置かれてことに注意されたい。

### 2.2 ランダムに用意した背景の中心に製品を貼り付ける画像拡張法

次に、画像内に製品の背景として含まれてしまうブルーシートのしわや陰などが可視化性能に悪影響を及ぼすと判断されたため、製品の背景をテープ以外に変更させることで可視化実験の際によりいっそう製品部分に注目するのではと考察した。事実、これまでに実施されている物体検出の精度向上に関する研究では、同じ物体に対し背景を変更したデータセットを訓練に用いることで認識精度を向上できたという報告がある [8]。

また、生産ラインで安定的に製造される工業製品の場合、不良品の発生頻度が非常に低いことが多いため欠陥が含まれた画像を蓄積していくことが容易ではない。このため、不良品画像のみに対し画像拡張を施し、

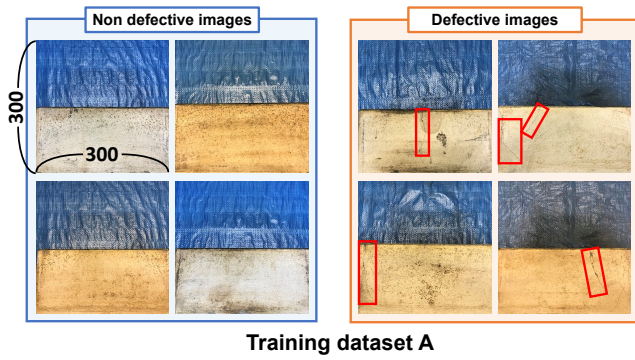


Figure 2 Examples of images of products included in dataset A.




Figure 3 Examples of augmented images included in dataset B.

画像データを増やすことが必要である。

具体的には、訓練データセット A の不良品画像にのみ水平反転の操作を行い、112 枚に増やすことによって良品と不良品画像それぞれ 1,380 枚、112 枚の計 1,492 枚とし、これとは別に 7,500 枚の背景用画像を用意する。図 3 のように 1,492 枚の画像内の製品のみをそれぞれ約  $150 \times 300$  ピクセルで切り抜き、それらを 7,500 枚の中からランダムに抽出した 1 枚の背景画像の中心にそれぞれ張り付けることで新たに 1,492 枚からなる訓練データセット B を作成する。

### 2.3 ランダムに抽出した背景画像に対して製品の貼り付け位置を変化させる画像拡張法

さらに、今回取り上げた工業製品とその生産ラインにおいては個々の製品を規則正しく固定することが困難であり、撮影される位置にはばらつきが発生していた。このような状況下でも十分な分類性能と可視化性能を發揮できる CNN を設計するために次のような画像処理を行う。具体的には、さきほどの背景画像 7,500 枚の中からランダムに抽出した 150 枚に対して、ある 1 枚の製品画像の貼り付け位置を上部から下部に 1 ピクセルずつずらすことで 150 枚の新たな画像が生成される。すなわち、背景画像は  $300 \times 300$  ピクセル、切り抜いた製品画像は約  $150 \times 300$  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可能となる。この拡張処理によって、良品画像が  $1,380 \times 150 = 207,000$  枚、不良品画像が  $112 \times 150 = 16,800$  枚の計 223,800 枚の画像が得られることになる。また、良品画像が多いことに




Figure 4 Examples of augmented images included in dataset C.

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、結果的に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 を作成した。図 4 にはデータセット C に含まれる幾つかの例を示す。

次節ではこれらの訓練データを用いて学習済み CNN である InceptionV3 の転移学習により新たな CNN を設計する。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 とする。なお、分類評価には第 2.1 節で説明した良品と不良品の画像それぞれ 64 枚、20 枚からなるテストデータセットを用いる。

## 3 転移学習と評価

### 3.1 IncA の学習と評価

訓練データセット A を用いた IncA の学習では、最大エポックを 1000、ミニバッチサイズを 40、畳み込み層の学習率を 0.0001、全結合層の学習率を 0.001 などの条件に設定して訓練を開始したところ、274 エポック付近で訓練データセットに対する認識率が 100 % に達成したため学習を終了させた。表 1 には、テストデータセットを IncA に分類させた結果を示す。良品画像は全て正確に分類され、不良品画像は 15 枚が誤認識されたことが確認された。これは訓練に用いた不良品画像の枚数が良品画像のそれと比べて非常に少なかったことが原因だと考えられる。

Table 1 Confusion matrix classified by IncA (row: predicted labels, column: true labels).

	Normal	Anomaly
Normal	64	15
Anomaly	0	5

### 3.2 IncB の学習と評価

次に、訓練データセット B を用いた IncB の学習及び分類実験は IncA と同様の条件で行い、学習については 82 エポック付近で訓練データセット B に対する認識率が 100 % に達成したため学習を終了させた。表 2 には、IncA の時と同じテストデータセットに対して IncB が分類した結果を示す。良品画像については IncA と同様に IncB も全て正確に分類できていた。誤分類された不

Table 2 Confusion matrix classified by IncB (row: predicted labels, column: true labels).

	Normal	Anomaly
Normal	64	4
Anomaly	0	16

良品画像の枚数は4枚に減少していたため、分類性能が改善できていることがわかる。

### 3.3 IncC の学習と評価

最後に、訓練データセット C を用いた IncC の学習及び分類実験は IncA, IncB と同様の条件で行い、学習については3エポックで訓練データセット C に対する認識率が100%に達成したため学習を終了させた。表3には、テストデータセットに対する IncC を用いた場合の分類結果を示す。

Table 3 Confusion matrix classified by IncC (row: predicted labels, column: true labels).

	Normal	Anomaly
Normal	64	1
Anomaly	0	19

IncA, IncB と同様に良品画像は全て正確に分類され、誤分類された不良品画像の枚数は1枚に減少させることができた。以上の結果から、今回取り上げた工業製品の欠陥検出用の CNN の設計においては提案する画像オーギュメンテーションの有効性が確認された。

次節では、これら IncA, IncB, IncC に対し Grad-CAM を適応し、欠陥領域の可視化性能を評価する。

## 4 Grad-CAM による欠陥領域の可視化と分類時のスコア

Grad-CAM は、CNN によりクラス分類が行われた際にその判定に影響を及ぼした重要なピクセルを勾配を用いて可視化する技術である。まず CNN を通してクラス分類を行い、その際に得られる畳み込み層の出力とクラス分類の結果を得る。このクラス分類の後に誤差逆伝搬を行い、畳み込み層の各要素に対する出力の勾配を計算する。次にそれぞれの畳み込み層の勾配の平均を求め、全ての畳み込み層を加算することで畳み込み層の活性化を可視化することが可能になっている [7]。Grad-CAM を用いることでラベル判定の根拠となった領域がカラーマップで表示されるようになっており、予測に強い影響を与えた領域ほど赤くマッピングされる。

図5、図6及び図7にはそれぞれ、IncA, IncB, IncC を用いて不良品のテストデータセットを分類したときの根拠となった領域を Grad-CAM により可視化したものを示す。赤枠は欠陥領域を示す。また、かっこ内の数値は分類時のスコアであり、OK と NG の予測の確からしさである。今回は誤分類された画像と正分類された画像それぞれでスコアが最大と最小であったものを示している。

図5に示した IncA の場合、誤分類した画像については欠陥領域以外のブルータープのしわや影を注視して




Figure 5 Examples of visualization results of defect areas obtained by applying Grad-CAM to IncA.




Figure 6 Examples of visualization result of defect areas obtained by applying Grad-CAM to IncB.




Figure 7 Example of visualization result of defect areas obtained by applying Grad-CAM to IncC.

おり、正分類した画像の内、最小スコアが0.53であった画像では欠陥領域の可視化の鮮明さを欠いていることが確認できる。

次に IncB の場合は、欠陥領域を注視できている画像枚数が IncA のときよりも増えており、正分類された画像では欠陥領域の可視化の鮮明さも向上していた。図6には可視化結果の例を示す。また、正分類した画像のスコアの平均値を確認すると、IncA では0.760、IncB では0.969であり、分類時のスコアについても向上していたことが確認できる。

IncC の場合は、IncB に比べて欠陥領域を注視している画像枚数がさらに増えていた。例として図7には良好に欠陥領域を注視できている例を示す。このとき、正分類した画像の最小スコアについても0.55から0.76と増加していることが確認できる。また、IncA, IncB のときと同様に正分類した画像のスコアの平均値を算出すると0.978であり、分類時のスコアについても向上していたことが確認できる。

今回の分類実験で用いたオリジナル画像(テストデータセット)では、製造ラインの構成上、製品部分が画像の下部に位置していた。IncB と IncC の結果より、Grad-CAM による可視化実験ではこのような画像下部の製品の欠陥領域を良好に注視できていたことがわかる。このことから、Grad-CAM は画像内に製品が含ま

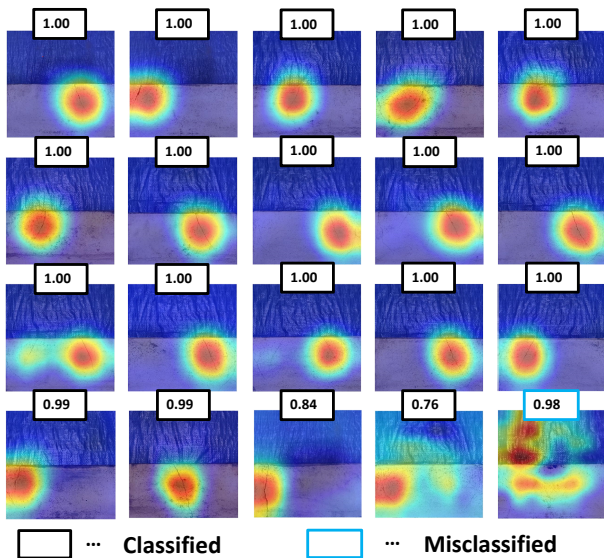


Figure 8 Visualization results of defect areas obtained by applying Grad-CAM to IncC.

れていればその位置に依存せず欠陥領域を注視できることが示唆された。図8にはIncCが分類した不良品画像20枚の可視化結果と分類時のスコアを示す。図8より、正分類した19枚の画像に対して欠陥領域が良好に注視されており、スコアが高いほどより鮮明であることが確認できる。

以上の結果から、製品と関係ない任意に用意した背景画像の中に製品画像を組み込む画像拡張法は、分類精度の向上に加えて、Grad-CAMによる欠陥領域の可視化性能も向上できることが確認できた。

## 5 おわりに

本研究では、InceptionV3の転移学習により新たな3つのCNN(IncA, IncB, IncC)の設計とテスト画像の分類実験を行い、Grad-CAMを用いて分類結果に影響を及ぼした欠陥領域の可視化を行った。さらに、欠陥領域の可視化と分類時のスコアの影響について評価した。その結果、製品の背景を変更する処理を施した画像を用いて訓練したIncBとIncCでは、オリジナル画像のみで訓練したIncAを用いたときと比較して分類精度と欠陥領域の可視化性能はともに向上させることができた。IncBの場合は背景画像の中心に製品画像を貼り付ける処理を、IncCの場合は背景画像に製品画像を貼り付ける位置を上部から下部へと移動させる処理をそれぞれ加えている。さらに、IncBとIncCを比較した結果、IncCの方が分類精度と欠陥領域の可視化性能ともに優れていた。また、分類時のスコアが高いほどより鮮明に欠陥領域を注視できていたことが確認できた。

以上の結果から、生産ラインにおいて撮影される製品の位置にばらつきがあり、規則正しく固定されていない場面でも提案手法を用いることで欠陥領域の認識精度とその可視化性能を改善できるものと期待される。今後は、提案した画像拡張法を他の工業製品にも適用しながら、より高い分類精度と欠陥領域の可視化性能を有するCNNの設計を行っていきたい。

## References

- [1] A. Krizhevsky, I. Sutskever, and G.E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Advances in neural information processing systems*, pp. 1–12, 2012.
- [2] T. Koeipensri, 保田俊行, 神代 充, “CNNを用いた画像分類に基づく電子部品の表面欠陥の検出”, 第63回自動制御連合講演会, pp. 268–269, 2020.
- [3] 中島彩奈, 田中雄太, 西谷一希, 茂木和弘, 白石洋一, “製品の外観検査における畳み込みニューラルネットワークのトレーニング”, 第32回エレクトロニクス実装学術講演大会, pp. 348–349, 2018.
- [4] 永田寅臣, “渡辺桂吾, 畳み込みニューラルネットワーク(CNN)・畳み込みオートエンコーダ(CAE)・サポートベクタマシン(SVM)のための設計支援ツールの開発”, 画像ラボ, Vol. 32, No. 12, pp. 20–26, 2021.
- [5] 阿部凌真, 有馬滉宜, 清水竜樹, 三木康平, 永田寅臣, 加藤博久, 渡辺桂吾, “CNNによる欠陥検出とGrad-CAMによる欠陥部分の可視化性能を向上させる画像拡張法の一提案”, 第22回計測自動制御学会システムインテグレーション部門講演会論文集, pp. 338–341, 2021.
- [6] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna “Rethinking the Inception Architecture for Computer Vision,” In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2818–2826, 2016.
- [7] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra. “Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization,” *Procs. of the IEEE Conference on IEEE European Conference on Computer Vision(ICCV)*, pp. 618–626, 2017.
- [8] D. Dwibedi, I. Misra, and M. Hebert, “Cut, Paste and Learn: Surprisingly Easy Synthesis for Instance Detection,” *Procs. of the IEEE Conference on International Conference on Computer Vision (ICCV)*, pp. 1301–1310, 2017.