

少量データによる AI 構築技術及び実応用に関する研究（画像合成を用いた検査）

前島 崇宏* 平間 毅** 行武 栄太郎**

1. はじめに

異物や欠陥等の検査にAI画像認識技術の適用が期待されているが、AIを構築するためには膨大な学習データが必要となる。このため、当センターでは画像合成の手法を用いて学習データ削減を検討している。

令和4年度は、実際に正常品に異物が混入した画像の代わりに、正常品のみ画像（背景や異物が写りこんでいない画像）と異物のみの画像（背景や正常品（正常箇所）が写りこんでいない画像）を合成した画像を用いて学習させ、検査精度に与える影響を評価した¹⁾。その結果、検査精度を維持しつつデータ数を7割削減できた。

しかし、実際の製造現場では、正常品の一部に異常がある製品（たとえば、欠けた食品）の画像や、背景が写りこんだ異物画像を検査する必要がある。CutMix²⁾の手法を用いてこれらの画像の一部をランダムに切り抜いて正常品画像に張り付けた場合、異物が全く含まれない合成画像が作成し、それを異物混入画像として学習する可能性があり、判別精度が低下する問題がある。

2. 目的

そこで、本研究ではAIが異物画像と判断した根拠箇所を可視化する手法であるGrad-cam++³⁾の結果を用いることで、背景や正常箇所が写りこんだ異物画像から異物位置を推定し、正常品画像と合成する手法を提案した。また、提案手法により合成した画像を用いて学習した場合の、検査精度に与える影響を評価した。

3. 研究内容

3.1 提案手法


本研究では、次の3クラスからなるデータセットを作成し、提案手法の有効性を評価した。

- ・正常品を模擬した M6 ボルト
 - ・混入時のリスクが低い異物を模擬した M6 皿ボルト
 - ・混入時のリスクが高い異物を模擬した M8 ボルト
- このデータセットを、Grad-cam++の判断根拠を用いて
- ・M8 ボルトの画像 A が占める面積の割合が λ
 - ・M6 皿ボルトの画像 B が占める面積の割合が $1-\lambda$
- となるように、前面画像 A の一部を背景画像 B に透過するためのマスク画像の作成方法を、図 1 に示す。


まず、画像 A を 7×7 の区画に分け、M8 ボルト画像と判断するのに最も貢献した区画が白（明度 1）、最も貢献していない区画が黒（明度 0）となるようなグレースケール画像を作成した。画像 B も同様に、M6 皿ボルトのグレースケール画像を作成した。

画像 A と画像 B のように、判別対象が右端にある画像を合成する場合、どちらか一方が隠れる可能性がある。それを解決する手段を、次に示す。

- 1) 各グレースケール画像の明度の平均が 1 となるように正規化後、明度の二乗和誤差が最大となるように画像 B を反転、回転（0 度、90 度、180 度、270 度）し、画像 C を作成した。
- 2) 画像 A のグレースケール画像の明度が最大の区画を求め、その区画の画像 A の透過率を 1 に設定した。
- 3) 同様に、画像 C の明度が最大の区画を求め、その区画の画像 A の透過率を 0 に設定した。
- 4) 透過率が設定済みの区画の場合は、次候補の区画を同様に設定した。
- 5) 画像 A の透過率が 1 の区画の割合が λ を超えるまで、または、画像 A の透過率が 0 の区画の割合が $1-\lambda$ を超えるまで、画像 A と画像 C のグレースケール画像を用いて、交互に透過率の設定を行った。
- 6) 画像 A の透過率が 1 の区画の割合が λ を超えた場合、画像 A の平均透過率が λ となるよう、端数分の区画の透過率を 0~1 の間に調整し、透過率が未設定の区画は画像 A の透過率を 0 に設定した。その後作成したマスク画像に対して平滑化処理を行った。



Grad-cam++により各画像の判断根拠箇所を求める



判断根拠箇所が重ならないように画像 B を反転、回転する



図 1 Grad-cam++を用いて作成したマスク画像の例

3.2 評価方法

正常品（M6 ボルト）画像、低リスク異物（M6 皿ボルト）が混入した異物画像、高リスク異物（M8 ボルト）が混入した異物画像の3クラスを判別する課題に対して、本手法の有効性を評価した。

3.3 学習・評価に用いた画像

画像合成を用いた学習用に M6 ボルト画像 1,000 枚、M6 皿ボルト画像 100 枚、M8 ボルト画像 100 枚の3種

類の画像を用意した。図2に画像合成を用いた学習用画像の例を示す。画像の合成方法は、CutMix、提案手法の2通りとし、 λ を0.1から0.9まで0.1ずつ変更しそれぞれ4,000エポック学習を行った（1エポック学習：用意した学習用画像を1周学習）。合成後の画像のクラスは、 λ の値に関わらず、合成前の画像のクラスのうちリスクが高い方のクラスとし学習を行った。



図2 画像合成を用いた学習用画像の例

図3に、学習後モデルの検査精度評価に使用した、実際に正常品の中に異物が混入している画像例を示す。




図3 評価用画像の例

提案手法を用いた学習の有効性を評価するため、従来手法である画像合成を行わずに学習した場合の精度を評価した。従来手法の学習には、表1に示した評価用とは別の正常品画像や異物混入画像を用いた。

また、提案手法によるデータ削減効果の評価するため、提案手法を用いた学習用データを1割ずつ減らした場合の精度の変化を調べた。

表1 従来手法による学習に用いた画像の種類と枚数

学習条件	①	②	③	④
従来手法1	1,000	100	100	0
従来手法2	1,000	100	100	10

4. 研究結果と考察

表2に、学習条件と各クラスの再現率の関係を示す。CutMixについては、各判別対象の再現率の平均値が最も高くなった $\lambda=0.4$ のときの結果を示す。同様に、提案手法については、 $\lambda=0.2$ のときの結果を示す。

また、表3に提案手法を用いて学習用データを1割ずつ減らして学習した場合の学習枚数と再現率の平均値

の関係を示す。（学習枚数1,200枚のみ $n=3$ ）

表2 学習条件と各クラスの再現率の関係（ $n=3$ ）

学習条件	評価用画像				平均値
	①M6 (正常品)	②M6皿+M6 (低リスク異物)	③M8+M6 (高リスク異物)	④M8+M6皿 (高リスク異物)	
従来手法1	0.999	0.988	0.992	0.611	0.897
従来手法2	1.000	0.988	0.992	0.983	0.991
CutMix	0.982	0.956	1.000	0.998	0.984
提案手法	0.994	0.991	0.999	0.999	0.996

表3 学習枚数と再現率の平均値の関係（ $n=1$ ）

学習枚数	λ								
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
120	0.964	0.967	0.979	0.963	0.958	0.948	0.915	0.854	0.757
240	0.982	0.978	0.986	0.988	0.985	0.983	0.938	0.880	0.693
360	0.984	0.989	0.991	0.984	0.976	0.986	0.973	0.881	0.732
480	0.986	0.988	0.992	0.987	0.975	0.981	0.977	0.959	0.812
600	0.989	0.983	0.989	0.989	0.986	0.987	0.977	0.932	0.820
720	0.979	0.996	0.966	0.987	0.981	0.976	0.975	0.973	0.847
840	0.991	0.993	0.991	0.991	0.993	0.981	0.967	0.972	0.838
960	0.987	0.996	0.985	0.991	0.989	0.973	0.983	0.954	0.847
1080	0.970	0.989	0.987	0.995	0.996	0.991	0.964	0.957	0.882
1200	0.993	0.996	0.996	0.994	0.989	0.987	0.983	0.971	0.880

5. まとめ

表2に示すように、提案手法の再現率の平均値は0.996と従来手法1、従来手法2、CutMixの再現率の平均値0.897、0.991、0.984を上回る結果となった。従来手法の学習にはアノテーションコストが高い異物混入画像が必要だが、提案手法により、アノテーションコストが低い異物画像を用いつつ検査精度が向上した。

提案手法と比較し、CutMixを用いた場合の検査精度が低くなった。異物画像から正常個所や背景の画像を正常品画像に張り付け、異物混入画像として学習したことにより、再現率が低下したためと考えられる。

表3に示したように学習枚数が480枚、 $\lambda=0.3$ のとき再現率の平均値が0.992と従来手法2の0.991を上回る結果となった。提案手法を用いることで検査精度を向上させつつ6割以上学習データを削減できた。

なお、本研究は令和2年度から令和6年度まで文部科学省特別電源所在県科学技術振興事業「少量データによるAI構築技術及びAIの実応用に関する研究」の一環として実施しているものである。

6. 参考文献等

- 1) 前島 崇宏、平間 毅、青木 邦知、格子状マスクを用いた画像合成による検査精度、学習データ削減効果の検証、茨城県産業技術イノベーションセンター研究報告、51、9-10、2023
- 2) Sangdoo Yun, Dongyoon Han, Seong Joon Oh, Sanghyuk Chun, Junsuk Choe and Youngjoon Yoo: Cutmix: Regularization strategy to train strong classifiers with localizable features, Proceedings of the IEEE International Conference on Computer Vision, pp. 6023-6032 (2019)
- 3) Chattopadhyay, A., Sarkar, A., Howlader, P., and Balasubramanian, Grad-cam++: Generalized gradient-based visual explanations for deep convolutional networks, 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), p. 839-847.