

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

前島 崇宏* 平間 毅** 青木 邦知**

1. はじめに

近年のAI技術の進歩により、人が行っていた判断をAIに代替させることが可能になりつつあることから、様々な業界でAI活用の動きが広がっている。

特に異物や欠陥等の目視検査の現場では、検査の判断基準が明確にできない場合にAI画像認識技術の適用が期待されている。しかし、AIを構築するためには一般的に膨大な学習データが必要とされ、学習データの収集にも労力がかかることから、学習データ数の削減が課題となっている。

2. 目的

令和3年度は画像中央の透過率が1となる正規分布を用いて作成したマスクにより合成した画像で学習した場合の検査精度と、データ削減効果に与える影響を評価した¹⁾。本年度は、提案手法である格子状マスクを用いて合成した場合の影響について同様に評価する。

3. 研究内容

3.1 画像合成を利用した学習効果の評価

本研究では、M6 ボルト（正常品を模擬）中に混入したM8 ボルト（異物を模擬）を検出する課題に対して、提案手法が検査精度やデータ削減効果に与える影響について評価を行った。

3.2 学習・評価用データセット

学習・評価用データセットとして正常品を模擬したM6ボルトのみが写った「正常品のみ画像」、異物を模擬したM8ボルトのみが写った「異物のみ画像」およびM6ボルト中にM8ボルトが混入した「異物混入画像」を用意した。「異物混入画像」については、異物の露出具合に応じて「easy」（露出8割以上）、「normal」（露出5割～8割）、「hard」（露出5割以下）の3種類に分別した。図1にデータセットの画像例を示す。



図1 学習・評価に用いたデータセットの画像例

3.3 提案手法（格子状マスクを利用した画像合成）

図2に示した6×6の区画に分けた格子を用いて、「正常品のみ画像」に「異物のみ画像」を透過する区画を選択するマスク画像の作成方法を示す。

「異物のみ画像」の割合が λ の場合、「異物のみ画像」を透過させる区画の数を $36 \times \lambda$ とし、その整数部分をX、小数部分をxとする。まず、格子中央の区画から透過個所をランダムにX+1個所選択する。中央の

区画がすべて選択済みの場合その外周からランダムに計X+1個所選択する。次に、「異物のみ画像」の平均透過率が λ となるよう最後に選択した区画の透過率をxとする。最後に、作成したマスク画像に平滑化処理を行う。図3に $\lambda=0.3$ の場合に提案手法を用いて作成したマスク画像の例を示す。




図2 格子(6×6)

図3 作成したマスク画像例
(左図：平滑化前、右図：平滑化後)

3.4 画像の合成方法

画像全体に占める「異物のみ画像」の割合が検査精度に与える影響を評価するため、「正常品のみ画像」と「異物のみ画像」を合成した場合は、「正常品のみ画像」の割合を $1-\lambda$ 、「異物のみ画像」の割合を λ として画像を合成した。

なお、比較のため合成方法はmixup²⁾、CutMix³⁾と提案手法を用いた画像合成の3種類とし、合成する画像の割合 λ を変更し学習を行った。

異物検査ではわずかな異物を含む場合でも適切に異物と判別される必要があることから、合成後の画像クラスは λ の値によらず異物クラスとして設定した。

3.5 学習・評価条件

正常品と異物の2クラス分類を行うため、ニューラルネットワークモデルであるImageNetで学習済みのResNet18⁴⁾を用い、「正常品のみ画像」と「異物のみ画像」をランダムに組み合わせて合成した画像により学習を行った。図4に合成画像を利用した学習・評価のフローを示す。

400エポック学習後、「正常品のみ画像」と「異物混入画像」のROC曲線(Receiver Operating Characteristic curve)から求めたAUC(Area Under the Curve)により検査精度の評価を行った。

また、画像合成を行わない従来手法との比較のため、従来手法として「正常品のみ画像」と「異物混入画像(easy)」を用いて学習後、同様の評価を行った。ここで、「正常品のみ画像」は画像合成時と同一の画像、「異物混入画像(easy)」は評価用とは異なる画像を使用した。

3.6 検査精度の評価

画像合成を用いた検査精度の評価には「正常品のみ画像」及び「異物のみ画像」をそれぞれ1,000枚用いて

学習した。表 1 に画像合成方法や λ の違いによる AUC を比較した結果を示す。画像合成を行わない従来手法（「正常品のみ画像」及び「異物混入画像（easy）」をそれぞれ 1,000 枚用いて学習）の「異物混入画像（easy、normal、hard）」の AUC はそれぞれ 1.000、0.985、0.851 であった(n=3)。

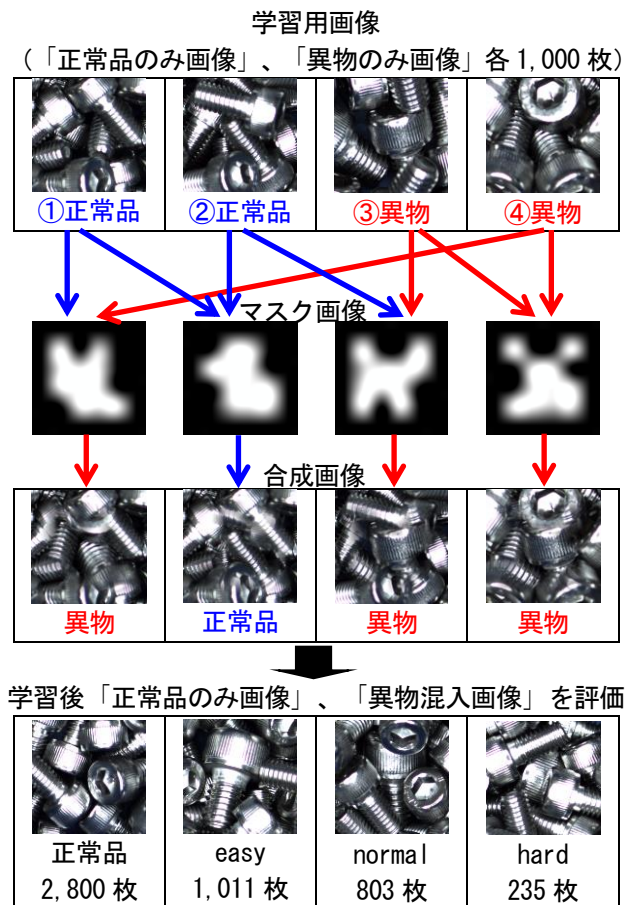


図 4 合成画像を用いた学習・評価の流れ
(提案手法 ($\lambda=0.3$) で合成した場合)

表 1 画像合成方法の違いによる AUC の比較(n=3)

λ	mixup			CutMix			提案手法		
	easy	normal	hard	easy	normal	hard	easy	normal	hard
0.1	0.840	0.757	0.651	0.932	0.835	0.674	1.000	0.994	0.970
0.2	0.814	0.752	0.690	0.997	0.961	0.844	1.000	0.995	0.965
0.3	0.790	0.741	0.666	1.000	0.988	0.914	1.000	0.994	0.942
0.4	0.900	0.826	0.717	1.000	0.986	0.898	1.000	0.991	0.908
0.5	0.996	0.947	0.816	1.000	0.978	0.836	1.000	0.984	0.854
0.6	0.971	0.801	0.582	0.999	0.970	0.783	1.000	0.980	0.818
0.7	0.940	0.716	0.533	0.999	0.948	0.726	1.000	0.967	0.770
0.8	0.944	0.726	0.552	0.998	0.899	0.670	0.999	0.937	0.718
0.9	0.972	0.789	0.575	0.991	0.857	0.640	0.996	0.903	0.671

3.7 データ削減効果の評価

提案手法を用いた学習により、画像合成を行わず実際に異物が混入した画像を用いて学習を行う従来手法と比較して、検査精度を維持したままの程度データが削減できるか検討を行った。

学習用の「正常品のみ画像」と「異物のみ画像」（従来手法は「異物混入画像（easy）」）をそれぞれ 100 枚ずつ増やしたときの検査精度を比較した。表 2 に学習画像枚数と AUC（平均値）の関係を示す。提案手法

の結果については最も削減効果が大きかった $\lambda=0.3$ の結果を代表して示している。

表 2 学習画像枚数と AUC の関係(n=3)

画像枚数	従来手法			提案手法		
	easy	normal	hard	easy	normal	hard
100	1.000	0.954	0.781	0.997	0.967	0.868
200	1.000	0.969	0.796	0.999	0.985	0.912
300	1.000	0.978	0.819	1.000	0.990	0.921
400	1.000	0.977	0.823	1.000	0.991	0.945
500	1.000	0.982	0.845	1.000	0.991	0.918
600	1.000	0.985	0.859	1.000	0.991	0.936
700	1.000	0.987	0.859	1.000	0.994	0.940
800	1.000	0.986	0.860	1.000	0.993	0.948
900	1.000	0.985	0.851	1.000	0.993	0.947
1000	1.000	0.985	0.851	1.000	0.994	0.942

4. 考察

表 1 によると、AUC の最大値は判別難易度によらず、mixup、CutMix、提案手法の順で大きくなった。これは評価画像と合成画像の類似具合を反映した結果と考えられる。

表 2 によると、従来手法で学習用画像枚数が各 1,000 枚のときの AUC が easy で 1.000、normal で 0.985、hard で 0.851 であったのに対し、提案手法では学習用画像枚数が各 300 枚のときの AUC が easy では同等精度を維持しつつ、normal では 0.990、hard では 0.921 と従来手法を上回る精度であった。提案手法では画像合成の組み合わせ数は学習画像枚数の二乗に比例して増加し、異物が混入した合成画像を大量に学習したため検査精度が向上したと考えられる。

5. まとめ

格子状マスクを用いて合成した画像を学習することで、異物検査の精度を維持しつつ画像合成を行わず実際に異物が混入した画像を学習する従来手法と比較し、データ数を 7 割削減することができた。

今後は、セグメンテーション等画像判別以外の手法を用いた検査についても画像合成を用いることで検査精度を向上できるか検討を行う。

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、西本 圭志、平間 毅、青木 邦知、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 (第 2 報)、茨城県産業技術イノベーションセンター研究報告、50、7-10、2022
- 2) Hongyi Zhang, et al., “mixup: Beyond Empirical Risk Minimization”, ICLR2018.
- 3) Sangdoon Yun, et al., “CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features”, ICCV 2019.
- 4) He, et al., “Deep residual learning for image recognition.” In proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778, 2016. 2).