

格子状マスクを利用した画像合成による検査精度の向上

前島 崇宏[†] 平間 毅[†]

茨城県産業技術イノベーションセンター[†]

1. はじめに

AI を活用した異物検査の精度を向上させるためには大量の正常品画像と異物混入画像を集める必要があるが、異物混入画像の収集やアノテーション作業には労力を要するという問題がある。筆者ら[1]は先行研究において、配置や姿勢を変えて正常品のみを撮影した画像と異物のみを撮影した画像の合成画像を実際の異物混入画像の代替として学習することで、画像収集やアノテーションを自動化しつつ検査精度を向上させた。

本研究では、検査精度をさらに向上させるため、格子状マスクを利用した画像合成手法を考案した。また、正常品である複数の M6 ボルトの中から異物を模擬した M8 ボルトを検出する課題に対して本手法の有効性を評価した。

2. 提案手法

図 1 に示した画像全体を 6×6 の区画に分けた格子を用いて、提案手法により異物混入画像を合成するためのマスク画像の作成方法を示す。

合成後の画像全体に占める異物のみ画像の割合を λ とした場合、異物のみ画像を透過させる区画の合計数は $36 \times \lambda$ となる。画像中央に異物を配置するため、画像中央の赤色で示した区画から異物画像のみを透過させる区画をランダムに選択する。異物のみ画像を透過させる区画の合計数が 4 を超える場合、黄色で示した区画から同様に追加でランダムに選択する。異物のみ画像を透過させる区画の合計数が 16 を超える場合、青色で示した区画から同様に追加でランダムに選択する。

異物のみ画像を透過させる区画の数の端数分は透過率を 0~1 の間とすることで異物のみ画像の平均透過率が λ となるように調整する。




図 1 異物混入画像合成用の格子 (6×6)

図 2 に $\lambda=0.3$ の場合のマスク画像の例を示す。合成した画像（提案手法①）を実際の異物混入画像に近づけるため、マスクに平滑化処理を行い正常品と異物の境界をなじませた場合の影響を評価した（提案手法②）。また、画像中央に異物を配置したことによる検査精度の影響を調査するため、透過する区画をランダムに選択した場合の影響も同様に評価した（提案手法③、提案手法④）。




図 2 マスク画像の例

3. 評価方法

学習には多クラス分類用のニューラルネットワークのモデルである ImageNet データベースで学習済みの ResNet18[2]を用いた。

合成方法は mixup[3], CutMix[4], 先行研究で用いた、画像中心の透過率が 1、画像全体の平均透過率を λ とした正規分布のマスクによる画像合成および、提案手法①~④の 7 種類とし、 λ を変更し学習を行った。mixup や CutMix では合成後の画像のクラスは λ の値に応じて割り振られるが、本研究では正常品のみ画像と異物のみ画像を合成した場合、異物のみ画像の割合を λ として画像を合成し、 λ の値に関わらず異物のクラスとして学習した。

図 3 に合成画像を用いた学習・評価の流れを示す。正常品のみ画像 1,000 枚及び異物のみ画像 1,000 枚をランダムに組み合わせ、各エポックで 2,000 枚の合成画像を作成し学習した。

表 1 画像合成方法の違いによる AUC の比較 (n=3)


λ	mixup			CutMix			先行研究			提案手法①			提案手法②			提案手法③			提案手法④		
	easy	normal	hard	easy	normal	hard	easy	normal	hard	easy	normal	hard	easy	normal	hard	easy	normal	hard	easy	normal	hard
0.1	0.840	0.757	0.651	0.932	0.835	0.674	0.997	0.987	0.945	1.000	0.995	0.969	1.000	0.994	0.970	0.813	0.755	0.707	0.720	0.690	0.589
0.2	0.814	0.752	0.690	0.997	0.961	0.844	1.000	0.994	0.959	1.000	0.995	0.965	1.000	0.995	0.965	0.776	0.797	0.783	0.768	0.814	0.764
0.3	0.790	0.741	0.666	1.000	0.988	0.914	1.000	0.994	0.949	1.000	0.995	0.948	1.000	0.994	0.942	0.908	0.918	0.890	0.987	0.962	0.887
0.4	0.900	0.826	0.717	1.000	0.986	0.898	1.000	0.993	0.927	1.000	0.988	0.890	1.000	0.991	0.908	0.998	0.981	0.933	0.999	0.979	0.921
0.5	0.996	0.947	0.816	1.000	0.978	0.836	1.000	0.985	0.854	1.000	0.979	0.842	1.000	0.984	0.854	1.000	0.983	0.918	1.000	0.984	0.918
0.6	0.971	0.801	0.582	0.999	0.970	0.783	0.999	0.939	0.736	1.000	0.973	0.807	1.000	0.980	0.818	0.999	0.969	0.846	0.999	0.973	0.867
0.7	0.940	0.716	0.533	0.999	0.948	0.726	0.992	0.866	0.632	0.999	0.959	0.758	1.000	0.967	0.770	0.999	0.931	0.756	0.998	0.947	0.775
0.8	0.944	0.726	0.552	0.998	0.899	0.670	0.983	0.833	0.622	0.999	0.914	0.683	0.999	0.937	0.718	0.996	0.896	0.695	0.997	0.914	0.711
0.9	0.972	0.789	0.575	0.991	0.857	0.640	0.986	0.852	0.637	0.995	0.890	0.666	0.996	0.903	0.671	0.994	0.876	0.662	0.993	0.873	0.660

400 エポック学習後のモデルを用いて正常品のみ画像と実際の異物混入画像の ROC 曲線から求めた AUC をそれぞれ求めることで検査精度の評価を行った。異物混入画像については異物の 8 割以上が露出した easy, 異物の 5 割~8 割が露出した normal, 異物の露出が 5 割以下の hard の 3 種類の画像に対してそれぞれ評価を行った。

学習画像（正常品のみ、異物のみ各 1,000 枚）



画像をランダムに組み合わせて合成し学習



(提案手法② ($\lambda=0.3$) で合成した場合)

正常品のみ画像、実際の異物混入画像を評価



図 3 合成画像を用いた学習・評価の流れ

4. 結果

画像合成を行わない従来手法と検査精度を比較するため、正常品のみ画像と実際の異物混入画像 (easy) を用いて同様に学習・評価を行った場合の AUC (easy, normal, hard) はそれぞれ 1.000, 0.985, 0.851 であった。

正常品のみ画像は画像合成を行う場合と同じ画像を、実際の異物混入画像 (easy) は評価用とは別に用意した画像をそれぞれ 1,000 枚用いた。

表 1 に画像合成方法の違いによる AUC を比較した結果を示す。

AUC の最大値は判別の難易度によらず提案手法①および提案手法②で最も大きくなり両者に大きな差は見られなかった。提案手法① ($\lambda=0.1$) の場合の AUC (hard) は 0.969 と従来手法の 0.851 や先行研究 ($\lambda=0.2$) の 0.959 を上回る結果となった。一方、異物の透過位置をランダムに選択した場合 (提案手法③, 提案手法④) は AUC が小さくなる傾向が見られた。

評価用の異物混入画像では異物は画像の中央に配置されている一方で、異物の露出の仕方にはばらつきがある。提案手法①および提案手法②では評価用の異物混入画像に近い画像を合成できたため検査精度が向上したと考えられる。

5. まとめ

自動で画像の収集やアノテーション作業が可能な正常品のみ画像と異物のみ画像から、6×6 の格子状マスクを用いて異物のみ画像が占める割合 (λ) が 0.1 となるように合成した異物混入画像で学習を行った。その結果、画像合成を行わない従来手法や先行研究と比較し検査精度を向上させることができた。

参考文献

- [1] 前島 崇宏, 平間 毅: 画像合成を利用した異物検査システムの開発, 情報処理学会第 84 回全国大会 (2022)
- [2] 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.
- [3] Hongyi Zhang, et al., "mixup: Beyond Empirical Risk Minimization", ICLR 2018
- [4] Sangdoo Yun, et al., "CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features", ICCV 2019