

画像合成を利用した異物検査システムの開発

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学習データを集める必要があるが、正常品にゴミなどの異物が混入した画像の収集やアノテーション作業は労力を要するという問題がある。

そこで本研究では、正常品と異物がそれぞれ入手可能な状況で学習データを効率的に収集するため、正常品や異物の配置や姿勢が異なる画像の自動収集装置を開発した。そして本装置で取得した画像から、異物が混入した画像を合成し学習する手法を検討した。また、正常品である M6 ボルト中に異物である 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. 画像自動収集装置による画像取得

検査対象部品の配置や姿勢が異なる画像を効率よく収集するため、自動で部品の攪拌や画像の収集が可能な装置を開発した。本装置を用いて取得した正常品のみ画像(M6ボルト400個)、異物のみ画像(M8ボルト250個)、異物混入画像(M6ボルト400個、M8ボルト1個)を切り抜き、学習・評価用データを作成した。図1に本装置で取得した画像と切り抜き後の画像例を示す。

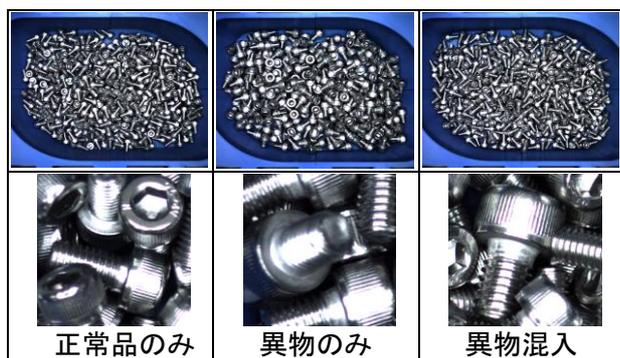


図1 画像自動収集装置で取得した画像(上)と切り抜き後の画像例(下)

Development of foreign matter inspection system using image composition

†Takahiro Maeshima, Hirama Takeshi

Industrial Technology Innovation Center Of Ibaraki Prefecture (ITIC)

3. 学習条件

切り抜き後の正常品のみ画像と異物のみ画像を用いて画像を合成し学習を行った。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[1]を用いて正常品と異物の2クラス分類を行った。

合成方法は mixup[2], Cutmix[3]と提案手法である正規分布を用いた画像合成の3種類とし、 λ (合成させる画像の割合)を変更し学習を行った。正規分布を用いた画像合成では画像中心の透過率が100%、画像全体の透過率の平均が λ となるマスクを用いて画像の合成を行った。

図2に各合成方法で用いたマスクと、合成後の画像の例を示す。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は異物のみ画像の割合が λ となるように画像を合成し、 λ の値に関わらず異物のクラスとして学習した。

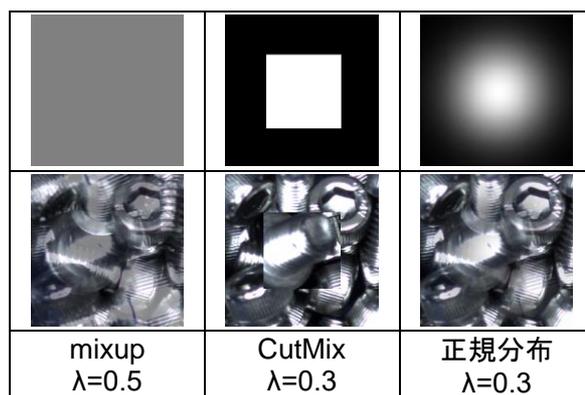


図2 画像合成に用いたマスク(上)と合成後画像例(下)

図3に合成画像を用いた学習・評価のフローを示す。学習用の正常品のみ画像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を行った。

400エポック学習後のモデルを用いて正常品の

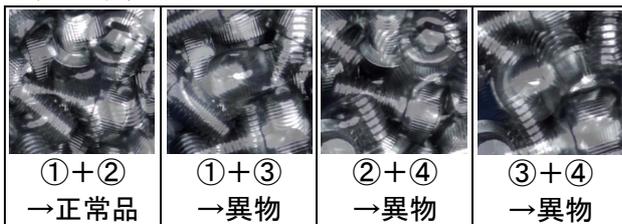
み画像と異物混入画像の ROC 曲線 (Receiver Operatorating Characteristic curve) から求めた AUC (Area Under the Curve) をそれぞれ求めることで検査精度の評価を行った。

異物混入画像については異物の 8 割以上が露出し判別が容易な easy, 異物の 5 割~8 割が露出している 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 (2,000 枚/エポック)



(mixup ($\lambda=0.5$) で合成した場合)



学習後, 正常品のみ画像, 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, 正常品のみ画像と異物混入画像 (easy) を用いて同様に学習・評価を行ったときの異物混入画像 (easy, normal, hard) の AUC はそれぞれ 1.000, 0.987, 0.869 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, 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 1000 枚用いている。

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。

表 1 画像合成方法の違いによる AUC の比較

λ	mixup			CutMix			正規分布		
	easy	normal	hard	easy	normal	hard	easy	normal	hard
0	0.947	0.734	0.611	0.947	0.734	0.611	0.947	0.734	0.611
0.1	0.787	0.703	0.604	0.961	0.876	0.730	0.995	0.971	0.922
0.2	0.667	0.655	0.602	0.999	0.967	0.878	1.000	0.991	0.948
0.3	0.778	0.748	0.684	0.999	0.980	0.914	1.000	0.994	0.943
0.4	0.843	0.811	0.729	0.999	0.982	0.886	1.000	0.989	0.912
0.5	0.994	0.953	0.847	1.000	0.974	0.816	1.000	0.979	0.859
0.6	0.949	0.791	0.566	1.000	0.967	0.793	0.998	0.933	0.711
0.7	0.940	0.751	0.552	1.000	0.950	0.738	0.991	0.898	0.686
0.8	0.959	0.769	0.589	0.998	0.913	0.671	0.985	0.856	0.662
0.9	0.986	0.853	0.641	0.985	0.839	0.618	0.979	0.831	0.622
1	0.993	0.884	0.675	0.993	0.884	0.675	0.993	0.884	0.675

mixup の場合, 評価画像の難易度に関わらず $\lambda=0.5$ のときに AUC が最大となった。評価画像の難易度が easy の場合は CutMix で $\lambda=0.5$, 正規分布で $\lambda=0.4$ のときに AUC が最大となったが, 評価画像の難易度が hard の場合は同様に $\lambda=0.3$, $\lambda=0.2$ のときに AUC が最大になるなど, 評価画像の難易度が easy, normal, hard と上がるにつれて λ が小さい方が検査精度が向上した。

AUC の最大値は mixup, CutMix, 正規分布の順で大きくなり, 正規分布 ($\lambda=0.2$) のときの AUC (normal:0.991, hard:0.948) は従来手法の AUC (normal:0.987, hard:0.869) を上回る結果となった。

5. 考察

画像合成方法の違いにより AUC に違いが生じた。これは評価画像に似ている合成画像を用いて学習を行った場合に検査精度が向上するためと考えられる。

6. まとめ

学習・評価用画像を効率的に収集可能な画像自動収集装置を開発した。

正常品のみ画像と異物のみ画像を合成し学習することでアノテーションコストを軽減しつつ検査精度を向上させることができた。

参考文献

- [1] 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)
- [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