ノート

ディープラーニングを用いた外観検査の精度向上

木嶋　祐太*　馬場　大輔*　山川　泰弘*

Study for Improved Accuracy of Visual Inspection through Deep Learning

KIJIMA Yuta*, BABA Daisuke* and YAMAKAWA Yasuhiro*

1. 緒　　言

工業製品の外観検査の自動化に関する県内企業からの要望は多く，ディープラーニングを活用することで，外観検査の自動化が進んでいく可能性がある。本研究では製造現場にディープラーニングを用いた外観検査システムを導入することを目的とし，外観検査の精度向上が期待できる手法として，ラベルなしデータによる再学習と画像データの背景除去を評価した。また，令和 3 年度の研究 [1]では PatchCore[2]による正常品のみの学習による外観検査システムを評価したが，この続きとして実際に県内企業で収集したデータに対しても評価した。

なお，本研究において外観検査システムの評価指標は AUROC(Area Under the ROC curve)を用いた。

2. ラベルなしデータによる DNN の再学習

学習した DNN(Deep Neural Network)を現場に導入する場合，学習データを作成したときと現場で環境が変わってしまう場合が想定される。この環境変化は外観検査システムの性能低下の要因となる。学習データを再度取得し，これにラベルを付けて学習し直すことは負担が大きいので，既に現場に設置された後ではこれが難しい場合がある。これを解決する方法として提案されている SHOT[3] (Source HypOthesis Transfer)と呼ばれる手法を評価した。

SHOT はラベルありデータによって学習された DNN を，環境変化後に取得したラベルなしデータで再学習することで変化後の環境に適応するよう DNN を修正する方法である。再学習では DNN の全結合層は凍結され特徴抽出層のみの学習となり，①特徴量が正常品と異常品のそれぞれにまとまるように，②情報量最大化になるように（全結合層からの出力があいまいにならずかつ結果が片方に偏らないように）学習される。

令和 3 年度に実施した共同研究 [4]では，ワークの冷間鍛造用 1 液潤滑剤の塗布量を判別する装置を開発した。その際，図 1 に示すモノクロカメラ，偏光カメラによる画像を撮影した。この塗布量が 0，1，20g/m^2 のワークが異常品で，5，10g/m^2 のワークが正常品である。モノクロカメラの画像は，図 2 のように明るさレベル 2（明るい）とレベル 1（暗い）で撮影していた。このレベル 2 の画像を開発段階で所持している画像，レベル 1 の画像を現場で撮影した画像と想定して SHOT を評価した。それぞれの試料数を表 1 に示す。

まず，レベル 2 の学習データで DNN を教師あり学習し，レベル 2 のテストデータで評価した。その後 SHOT 実施前の結果として，レベル 1 のテストデータで評価した。最後に SHOT 実施後の結果として，レベル 1 の学習データにて再学習してレベル 1 のテストデータで評価した。レベル 2 の学習データを 3 パターン作成し，それぞれで学習した DNN にて 3 回ずつ評価した結果の平均値を表 2 に示す。レベル 2 で学習した

* 下越技術支援センター

DNN はレベル 2 のテストデータに対しては良い結果であったが，レベル 1 のテストデータに対しては悪い結果となった。SHOT を実施することでレベル 1 のテストデータに対する結果は，レベル 2 の結果と同等になった。

現場では，例えば正常品が圧倒的に多いというように再学習用データの品質が良くないことが予想される。そこでレベル 1 の再学習用データの内訳を表 3 のように変え，先ほどと同様に評価した。評価結果を表 4 に示す。各 15 個と各 5 個の各塗布量がまんべんなくある再学習用データの結果が優位であった。5 と 10 は現場で得られやすい正常品のみの再学習用データであるが，この結果は SHOT 実施前よりは良かったものの，性能は大きく上がらなかった。

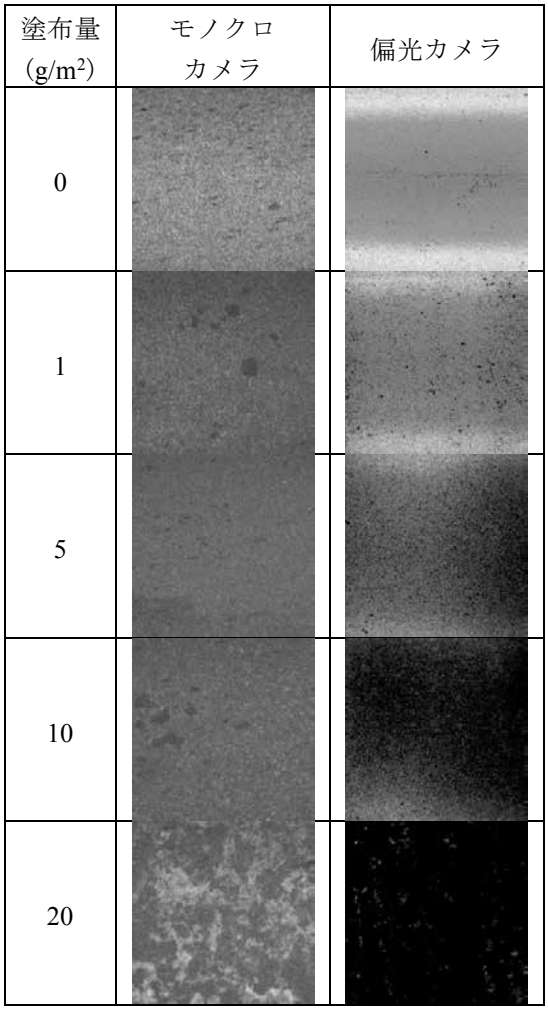

図 1　1 液潤滑剤画像の例

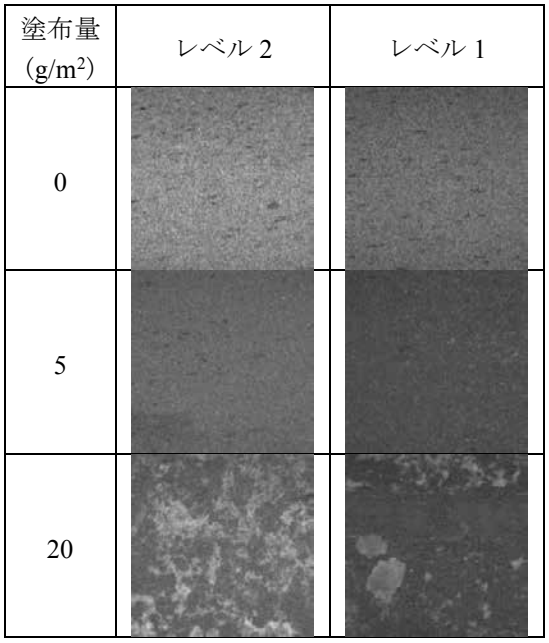

図 2　レベル 2 とレベル 1 の画像

表 1 試料数

	総数	学習用	検証用	テスト用
レベル 2	197	100	35	62
レベル 1	165	75	0	90

表 2　SHOT 実施前後の評価結果

	テストデータ	AUROC
SHOT 実施前	レベル 2	0.9996
	レベル 1	0.7114
SHOT 実施後		0.9993

表 3　各再学習データの塗布量ごとの個数

データ	塗布量(g/m²)				
	0	1	5	10	20
各 15 個	15	15	15	15	15
各 5 個	5	5	5	5	5
0 と 5	15	0	15	0	0
1 と 5	0	15	15	0	0
5 と 10	0	0	15	15	0
5 と 20	0	0	15	0	15

表 4　各データでの評価結果

データ	AUROC
各 15 個	0.9994
各 5 個	0.9995
0 と 5	0.9875
1 と 5	0.9963
5 と 10	0.9873
5 と 20	0.9963

3. 画像データの背景除去

セマンティックセグメンテーションは画像内の全画素にラベルやカテゴリを関連付けるディープラーニングのアルゴリズムである。令和 3 年度の研究[1)]では MVTec AD[5)] (Anomaly detection Dataset)の Screw 画像に対し PatchCore にて正常品と異常品の判別を行ったが，図 3 の画像変換により背景を除去すると結果が良くなった。セマンティックセグメンテーションを使用すると背景とねじの画素を認識できるので，さらに細かく背景を除去することができる。

今回の判別に使用する Screw 画像は 480 枚で，うち学習データは 100 枚（すべて正常品），テストデータは 380 枚（正常品 261 枚，異常品 119 枚）とした。学習データ，テストデータともに図 3 の変換をした画像を用いた。セマンティックセグメンテーションをするためには，アノテーションによりどの部分がねじでどの部分が背景であるかわかる正解を作成して，ファインチューニングする必要がある。学習データの中から無作為に選んだ 20 枚に対しアノテーションを実施して，ファインチューニングを実施した。この DNN をテストデータに用いると，図 4 のように画像の背景が除去された。これをすべてのテストデータに対して実施し，結果が問題ないことを目視で確認した。

背景除去した画像に対し PatchCore で評価した結果を表 5 に示す。図 5 は正常品の画像の一部であるが，図 5 の矢印部分のような背景が異常と判定されている画像が複数あり，それが結果として表れていると思われる。

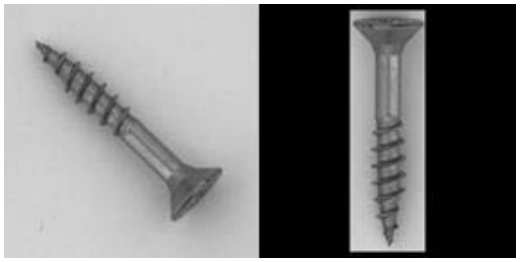

(a) 変換前　　(b) 変換後

図 3　画像の変換

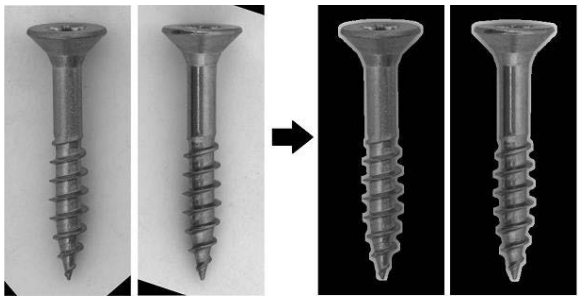

(a) 実施前　　(b) 実施後

図 4　セマンティックセグメンテーション

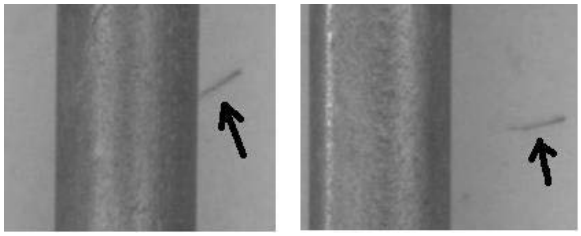

図 5　正常品の画像の一部

表 5　背景除去の効果(AUROC)

背景除去なし	背景除去あり
0.9915	0.9987

4. PatchCore の現場のデータによる評価

Screw 画像に対して良好な結果を出した PatchCore を製造業の現場で収集したデータにより評価した。

4.1　1 液潤滑剤の画像での評価

図 1 の 1 液潤滑剤の画像に対し PatchCore で評価した。所持している画像を約半分に分けて片方の中から正常品のみの画像を取り出しそれを学習データとした。もう一方から正常品と異常品が同数になるように画像を取り出しそれをテストデータとした。この画像の振り分けを 5 パターン作成しそれぞれ 3 回ずつ評価した結果の平均値を求めた。表 6 に試料数と評価結果を示す。モノクロカメラと偏光カメラの結果は大きく違っていた。

次に，偏光カメラの画像に対し 5，10g/m^2 が各 12 個，5，10g/m^2 が各 6 個，5g/m^2 が 12 個を学習データとしたときを比較した。また，教師

あり学習した ResNet-18[6]により評価した結果も参考に求めた。この場合は，学習データ数と検証データ数を 2:1 として交差検証を実施した際の平均値を求めた。評価結果を表 7 に示す。異常品も含め様々なデータで学習する ResNet-18 の結果は圧倒的ではあるが，正常品だけ学習する PatchCore の結果もそれなりに良かった。ただし，5g/m^2 が 12 個の結果はかなり悪くなっており，正常品だけといえども幅広く学習用の画像を集めることが必要であることを確認した。

4.2 金属製品の画像での評価

県内企業から提供いただいた図 6 に示す金属製品の画像を PatchCore で評価した。学習用の画像数は 2700 枚で，テスト用の画像数は 220 枚である。提供いただいた異常品の画像数が少なかったため，このような比率になっている。

PatchCore では学習した画像の特徴量と検査対象画像の特徴量との距離により検査対象が正常かを判定するが，学習画像枚数が多くなると判定に時間がかかるようになるため，判定に使用する特徴量は間引かれる。サンプリングレートはすべての学習用画像から得られた特徴量数に対する判定に使用する特徴量数の割合である。このサンプリングレートを 10%，1%，0.1%と変えて評価を実施した。サンプリングレートを変え 3 回ずつ評価した平均値を表 8 に示す。サンプリングレートを高くしたほうが結果は良くなった。

表 6　1 液潤滑剤画像の PatchCore 評価結果

画像	学習データ	テストデータ	AUROC
モノクロカメラ	5，10g/m^2 が各 24 個	96 個	0.7660
偏光カメラ	5，10g/m^2 が各 12 個	60 個	0.9774

表 7　偏光カメラ画像の評価結果

	学習（検証）データ	テストデータ	AUROC
PatchCore	5，10g/m^2 が各 12 個	60 個	0.9774
	5，10g/m^2 が各 6 個		0.9750
	5g/m^2 が 12 個		0.8257
ResNet-18	各塗布量各 12 個	60 個	0.9997

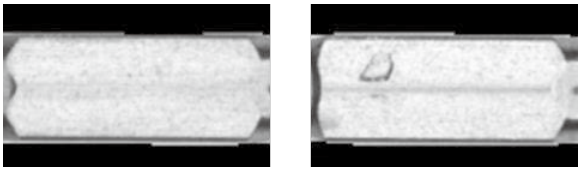

(a) 正常品　　(b) 異常品

図 6　金属製品の画像の一部

表 8　金属製品画像の評価結果 1

学習画像枚数	サンプリングレート	AUROC
2700	10%	0.9954
	1%	0.9947
	0.1%	0.9864

表 9　実行時間に関連する実行の環境

画像サイズ	1700×340
CPU	Intel Core i9 3.19GHz
GPU	NVIDIA RTX A6000

表 10　画像 1 枚あたりの実行時間

サンプリングレート	GPU 使用		特徴抽出のみ GPU		GPU なし
	時間	メモリ使用量	時間	メモリ使用量	時間
10%	0.8s	13GB	3.6s	4GB	5.3s
1%	0.7s	11GB	1.1s	4GB	2.8s
0.1%	0.7s	11GB	0.8s	4GB	2.5s

表 11　金属製品画像の評価結果 2

学習画像枚数	サンプリングレート	AUROC
2700	1%	0.9947
1350	2%	0.9923
540	5%	0.9892
270	10%	0.9876
135	20%	0.9850

今回評価した表 9 の環境での実行時間を計測した。GPU（Graphics Processing Unit）を使用する場合，特徴検出のみ GPU を使用する場合，GPU を使わない場合で 2700 枚の画像を学習した PatchCore の実行時間を測定した。画像 1 枚あたりの実行時間を表 10 に示す。GPU を使用した場合の実行時間が小さかったが，メモリ使用量が大きいので実装にはリソースが必要になる懸念があった。特徴抽出のみ GPU と GPU なしでは，サンプリングレートが上がるにつれて実行時間が増大した。

学習画像枚数が 135 枚，サンプリングレートが 10%の場合 GPU なしでの実行時間は 2.8s だった。表 10 のサンプリングレート 1%のときと同じだったので，学習用画像数×サンプリングレートが同じであれば同じ負荷であることを確認した。

この学習画像枚数×サンプリングレートが 27 になるように学習画像枚数を変えて評価した。学習用の画像から学習画像枚数分の画像をランダムに取り出した学習データを 5 パターン作成し，評価した平均値を表 11 に示す。学習画像枚数を増やすと結果が良くなる傾向があった。

5. 結　　言

(1) ラベルなしデータで DNN を修正する SHOT という手法の有効性を確認した。再学習に用いるラベルなしデータの品質が重要である。

(2) セマンティックセグメンテーションを画像の背景除去に活用した。Screw 画像に対して効果があった。

(3) PatchCore の有効性は検査対象によって変わることが確認された。

(4) PatchCore は学習画像枚数×サンプリングレートが増加すると実行時間が増加した。実行時間を変えずに学習画像枚数を多くしたい場合は，サンプリングレートを下げる必要がある。

参考文献

1) 木嶋祐太ほか，“ディープラーニングを用いた外観検査の精度向上”，工業技術研究報告書，新潟県工業技術総合研究所，No.51，2022，pp.35-38.

2) Karsten Roth, Latha Pemula, Joaquin Zepeda, Bernhard Scholkopf, Thomas Brox, Peter Gehler, “Towards Total Recall in Industrial Anomaly Detection”, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*,2022, pp. 14318-14328

3) Jian Liang, Dapeng Hu, Jiashi Feng,“Do We Really Need to Access the Source Data? Source Hypothesis Transfer for Unsupervised Domain Adaptation”, *International Conference on Machine Learning (ICML)*, 2020, pp. 6028-6039

4) 菅家章ほか，“AI を用いた 1 液潤滑剤塗布検出装置の開発”，工業技術研究報告書，新潟県工業技術総合研究所，No.51，2022，pp.15-20.

5) Paul Bergmann, Michael Fauser, David Sattlegger, Carsten Steger,“Mvtec ad – a comprehensive real-world dataset for unsupervised anomaly detection”, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*,2019, pp. 9592-9600

6) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun,“Deep Residual Learning for Image Recognition”, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*,2016, pp. 770-778