

外観検査に適した新たな深層ニューラルネットワークの提案

Proposal of a New Deep Neural Network for Visual Inspection

鎌田 祥平
Shohei Kamada

中塚 俊介
Shunsuke Nakatsuka

山本 治美
Harumi Yamamoto

要 旨

近年、工業製品の外観検査システムに深層学習が利用されており、これまで自動化が困難とされてきた目視検査工程でも自動化が進められている。従来の深層学習を用いた検査では良品と不良品を識別するために大量の学習用サンプルが必要で、現実には大量の不良品サンプルを確保することが困難である。そのため、品種展開が多い商材や不良品サンプルの入手が困難な商材の外観検査への適用は難しい。そこで、品種展開時に追加学習不要なテンプレート比較型ニューラルネットワーク（見比べNet）および良品データのみの学習で不良を判定する異常検知技術であるMulti-scale Patch Complementary GAN（MSP-CGAN）を提案・検証し有効性を示した。

Abstract

Deep learning has been used in visual inspection systems for industrial products in recent years. Automation has been promoted even in visual inspection processes that have been difficult to automate. In the conventional inspection using deep learning, a large amount of learning samples are required to distinguish a good product from a defective product. In reality, it is difficult to secure a large number of defective product samples. Therefore, it is difficult to apply it to the appearance inspection of commercial products with a large variety of product development or commercial products with few defective samples. We proposed and demonstrated the effectiveness of template comparison neural networks (Mikurabe-Net) and Multi-scale Patch Complementary GAN (MSP-CGAN), an anomaly detection technology that can detect defects by learning only good data.

1. はじめに

工業製品の製造工程において、出荷製品の品質安定化のために検査は必要不可欠である。特に外観検査工程では人による目視検査が主であるが、検査員ごとの判断基準のばらつきが長年の課題であった。近年では深層学習技術の進歩により、これまで困難とされてきた目視検査工程でも自動化が検討されている。当社でもこれまで深層学習を用いた画像検査機を開発し自社の工場に導入してきた。従来の深層学習では良品と不良品を識別するために大量の学習用サンプルが必要である。しかし実際には、大量のサンプルを確保すること、特に不良品の収集は工程不良率や工数を考えると困難を極める場合が多い。そのため、良品のみ、もしくは少数の学習サンプルから良否識別できる深層学習技術が求められている。

そこで筆者らは、一般的なクラス分類タスクのDNN（Deep Neural Network）と同等の学習枚数でありながら、学習画像と異なる品種であっても検査可能なニューラルネットワークを開発した。テンプレート画像を1枚差し替えるだけで品種対応できるこのネットワークを「見比べNet」と名付け、レーザ印字検査では印字パターンが変更された場合でも再学習なしで検査可能であること確認した[1]。

また、不良モードが定まっていない製品の場合、良品

以外は全て不良判定したいというニーズもある。この場合、識別すべき不良パターンをあらかじめ学習させる必要がある従来のクラス分類タスクでは対応できない。この問題に対応するために、良品のみの学習サンプルから補集合と多重解像度という概念を用いて、良品とそれ以外を識別する異常検知手法であるMulti-scale Patch Complementary Generative Adversarial Network (MSP-CGAN)を開発し、2019年に提案した[2]。

本稿では工業製品の外観検査に深層学習を応用するうえで課題となる点を克服した2つの深層ニューラルネットワーク「見比べNet」「MSP-CGAN」を紹介する。

2. 未学習の品種も検査可能なニューラルネットワーク「見比べNet」

1枚の検査画像を入力し良品・不良品の判定結果を出力する従来型のニューラルネットワークでは、品種が追加・変更される度に再度サンプルの収集を行い、学習し直す必要があった。そのため、ロット印字など日々刻印内容が変わるような印字検査へ深層学習を適用することは困難であった。一方で目視検査員は、品種が追加・変更された場合でも、目の前の検査対象物と良品サンプルもしくは良品画像とを見比べながら柔軟に検査を行うことができる。筆者らはこの点に着目し、良品画像（テンプレート画像）と検査画像の2枚を比較し良否識別を行う

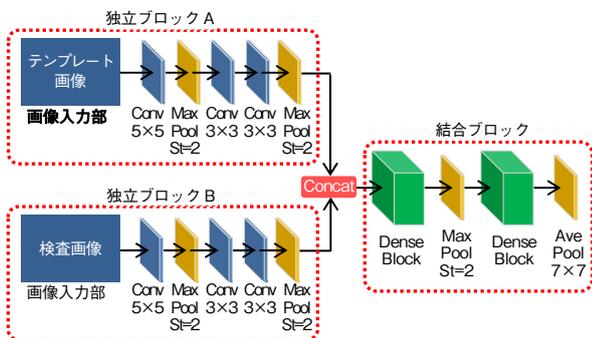
ニューラルネットワークを開発した.

2.1 見比べNetの構造

見比べNetの構成を第1図に示す.

2箇所ある画像入力部のうち一方には代表的な良品画像(テンプレート画像)を, もう一方には検査画像を入力する. 2枚の画像はそれぞれ図中の赤枠で記載されている独立ブロックを経て個別に特徴量を算出し, Concat部でチャンネル方向に結合する. それ以降は良不良識別(クラス分類)を行い, これを結合ブロックとする. また, 独立ブロックAとBで対応するConv層は重みを共有している. ここではHuangらが提案するDenseNetのDenseBlockを使用する[3]. 2入力構造をもつネットワークの代表例としてSiamese Network[4]が挙げられる.

Siamese Networkは出力が「同じ・異なる」の2クラスをもつことで類似度を求めるネットワークである. 一方で, 見比べNetは2入力のうち, 1入力は良品であるテンプレート画像であり, 出力が類似度ではなく各種不良モード(多クラス分類)とすることで, 未学習の品種に対して柔軟に不良判定ができることが特徴である.

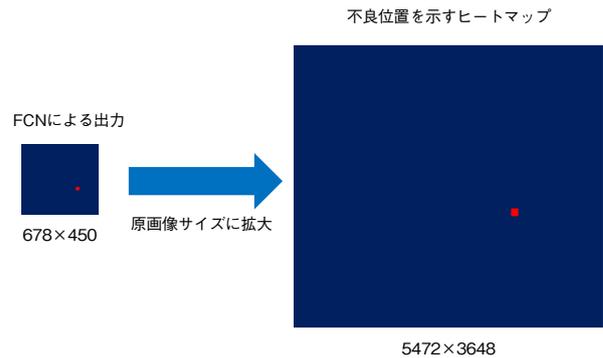


第1図 見比べNetの構成
Fig. 1 Structure of Mikurabe-Net

また, 見比べNetはFCN (Fully Convolutional Network) 構造を有している. 学習時は一定のサイズで切り出した画像を用いるが, 推論時にはカメラで撮影した画像全体を入力することで, 不良の位置をヒートマップとして出力することが可能となる. なお, 一般的なFCN構造のネットワーク[5]と異なり本ネットワークはアップサンプリングを行わないネットワークである. この構造を用いる利点として, 教師データにピクセルごとにラベル付けされた領域抽出データを用いる必要がなく, 入力画像に対して1つのラベルのみのクラス分類データで学習ができることである. 本実験の場合, 撮像により得られる画像サイズは5472×3648 pixである. 学習時はこのサイズの画像から56×56 pixに切り出して得られる入力画像に

し1つのラベルを学習させる. 入力画像はMax Pool (フィルタサイズ2×2, stride=2) が3回施されることでサイズが1/8に縮小し, 最後のAverage Pool (フィルタサイズ7×7, paddingなし) をかけることで最終的に1×1のサイズとなる. これは入力画像が良品または不良のどちらなのかを意味する値である. ここでMax Poolとは, 得られた特徴マップに対して近傍の入力値の最大値を出力し, Average Poolは平均値を出力することを意味する.

また, paddingとは特徴マップ周囲に特定の値を埋めることを意味する. 一方で推論時では, 5472×3648 pixの画像に対してMax Poolが3回施されることでサイズが1/8に縮小し, 最後のAverage Pool (フィルタサイズ7×7, paddingなし) において678×450のサイズとなる. これは不良の位置情報を示すヒートマップとなる. このヒートマップを第2図のように入力画像サイズに拡大し, 重ね合わせることで不良部の位置を大まかに特定することが可能となる (第3図).



第2図 FCNによる不良位置を示すヒートマップ
Fig. 2 Heat map of defective locations by FCN



第3図 原画像とヒートマップの重ね合わせ画像
Fig. 3 Overlaid image of the original image and heatmap

第3図は実際の印字検査で得られた不良画像を入力した例である. 実際の不良部(欠け)はヒートマップが不良と示している領域内に存在しており, 正しく位置検出が行われていることが確認できる.

2.2 印字検査における見比べNetの検証

見比べNetの品種対応能力を、印字検査画像を用いて評価する。

第1表に示すように、学習データとして、製品Aの画像100枚（カバー部50枚、本体部50枚）から印字部付近を56×56 pixで切り出した画像を3000枚（カバー部1500枚、本体部1500枚）準備した。

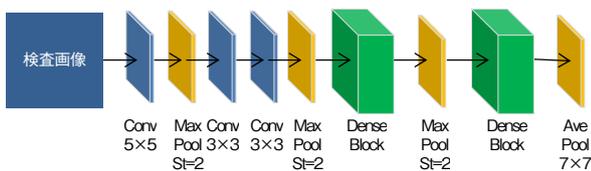
第1表 印字検査のデータセット
Table 1 Dataset for print inspection

	学習データ	テストデータ
①	製品A (N=3000) 良品1500, 不良1500	製品A (N=1000) 良品500, 不良500
②		製品B (N=1000) 良品500, 不良500

良品画像と不良画像の割合は1:1である。テスト用画像は、データセット①では学習用と同じ製品A、データセット②では学習用と異なる製品Bを各1000枚準備した。製品Bの画像は従来法および見比べNetともに未学習である。良品画像と不良画像の割合は、学習用と同じく1:1とした。なお、見比べNet入力時のテンプレート画像は、製品Aを検査するときは製品Aの、製品Bを検査するときは製品Bの代表的な良品画像1枚とする（第4図）。



第4図 製品A (左) と製品B (右)
Fig. 4 Product A (left) and Product B (right)



第5図 従来ネットワーク
Fig. 5 Single-input network

第5図より、従来ネットワークは見比べNetの独立ブロックAがない構造である。従来ネットワークと見比べNetの双方に第1表におけるデータセット①、②を入力し、

良否の正答率を調査する。テストデータは入力画像と同様に56×56 pixである。また、出力値は良品・不良の2クラスにおける0以上1以下の反応値である。本検証において、不良の反応値が0.5以上の場合に不良判定するように閾（しきい）値を設定した。

検証の結果、従来法では学習データと異なる品種の場合の正答率は44.3 %であった。一方で見比べNetの場合、学習データと異なる品種であっても正答率は99.6 %であり、学習データとテストデータが同じ場合と同等に高い性能を示した。また、見比べNetが誤判定した残り0.4 %を調査した結果、これらは全てテンプレート画像と検査画像の位置関係がずれていることが原因である。追加実験により、テンプレート画像と検査画像の位置関係を10 pixほどずらしたものを追加学習させたところ、テストデータ (N=1000) において判定精度は100 %を達成し見逃し・過検出ともに0であることを確認した。これより、見比べNetの印字検査への実用は十分可能であると考えられる。

3. 良品のみの学習で良否判定可能なMSP-CGAN

本章では、良品データのみの学習で良否判定可能な異常検知技術MSP-CGANを紹介する。

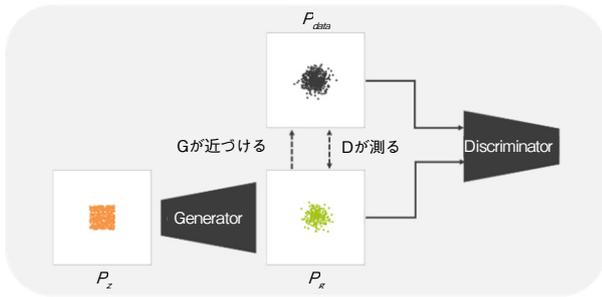
工業製品の欠陥画像は、大部分が良品と同じパターンであり欠陥の占める面積はごく一部という場合も珍しくない。異常検知に深層学習を用いる場合、一般的にAuto EncoderやRegular Generative Adversarial Networks (R-GAN) が用いられるが、特徴抽出の過程で、微小な欠陥の特徴が大部分を占める良品の特徴に隠されてしまう課題がある。

そこで筆者らは、Complementary GAN (CGAN) に、さまざまなスケールの不良を検出するため多重解像度マップをもたせたMulti-scale Patch Complementary GAN (MSP-CGAN) と呼ばれる異常検知手法を開発した。

次節より、一般的な敵対的生成ネットワーク (R-GAN)、Complementary GAN、そしてMSP-CGANの概要を述べる。

3.1 敵対的生成ネットワーク (R-GAN)

GAN (R-GAN) は生成モデルの1つで、ノイズからデータの生成過程を学習することで、ランダムなノイズから本物のような疑似データを生成することが可能である。GAN (R-GAN) はGeneratorとDiscriminatorと呼ばれる役割の異なる2つのネットワークを有する（第6図）。Generatorはノイズ P_z から疑似データを生成する役割をもち、Discriminatorはノイズから生成された生成分布 P_g と本物のデータ分布 P_{data} を識別する役割をもつ。GeneratorはDiscriminatorを騙（だま）すように学習を行い、本物と

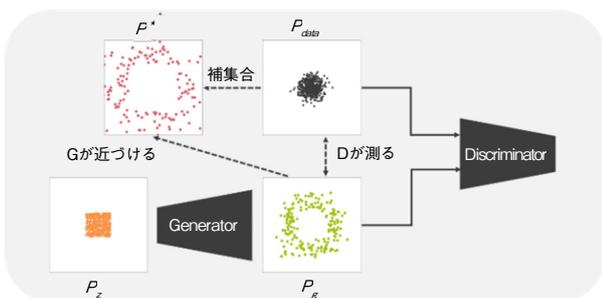


第6図 一般的なGAN (R-GAN) の概念図
Fig. 6 Conceptual diagram of Regular-GAN (R-GAN)

酷似した疑似データを生成する。一方で、Discriminatorは本物と疑似データをより正しく識別できるように学習を行う。このように学習則の異なる2つのネットワークを敵対的に交互に学習させることで、最終的には生成された疑似データは本物のデータに近い分布となる。Discriminatorは入力为本物のデータであるか疑似データであるかをより良く識別できるように学習を行うため、Discriminatorの識別結果を正常度として、異常検知を行う手法[5]も提案されている。しかし、Discriminatorが識別しているのは、本物のデータとノイズから生成された疑似データであり、異常データの情報は一切考慮されていない。そのため、Discriminatorは正しく異常検知を行うとは限らない。この問題を解決するためには新たに異常を定義することが必要である。

3.2 Complementary GAN (CGAN)

通常CGANのGeneratorは、生成分布を正常データの補集合分布に近づける学習をさせる。一方、Discriminatorは正常とそれ以外が識別できるようになり異常検知が行えるというモデルである。一般的なGAN (R-GAN)とは異なり、生成分布 P_g を本物のデータ分布 P_{data} に近づけるように学習を行うのではなく、第7図における生成分布 P_g が補集合分布に近づくように学習を行う。

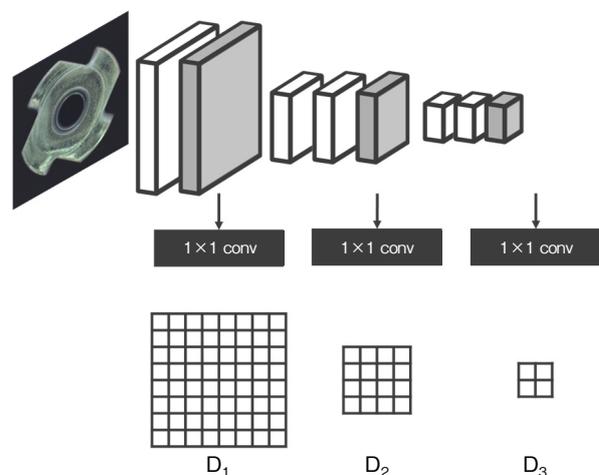


第7図 Complementary GAN (CGAN) の概念図
Fig. 7 Concept of Complementary GAN (CGAN)

一般的なGAN (R-GAN)とは異なり、CGANでは生成分布は補集合分布に近づき、Discriminatorは本物のデータ分布 P_{data} と補集合データ分布 P_g を識別することができる。また、本物のデータ分布を正常分布とするならば、補集合分布は異常分布であるといえる。そのため、CGANのDiscriminatorを用いることで正常と異常を識別することができる。CGANのDiscriminatorは異常検知において有用であるといえる。

3.3 Multi-scale Patch Complementary GAN (MSP-CGAN)

一般的なCGANにおけるDiscriminatorの出力は入力画像全体の異常度を示す数値となる。工業製品の外観検査においては、画像全体が不良データである場合は少なく、局所的にデータを見ると、良品データと区別がつかない場合がある。言い換えると、1枚の異常画像のなかに良品パターンの領域と不良パターンの領域が混在していることがほとんどである。このとき、不良パターンの領域が占める割合が大きければ、CGANの出力(正常度)は低くなるが、不良パターンの領域が占める割合が小さい場合、正常度が大きくなってしまふ。そのため、不良パターンの領域が画像全体に占める割合に依存することなく不良を検出できるように複数解像度のDiscriminationマップを出力することで、この問題を解決する。また、不良パターンにはさまざまな種類があり、その検出において最適な解像度は異なる。そのため、本手法では複数解像度のDiscriminationマップをDiscriminatorに出力させる。具体的には、第8図で示すようにDiscriminatorの異なる解像度をもつ複数の中間層から、 1×1 Convolutionを用いることで、階層ごとの出力(D_1, D_2, D_3)とする。これら。



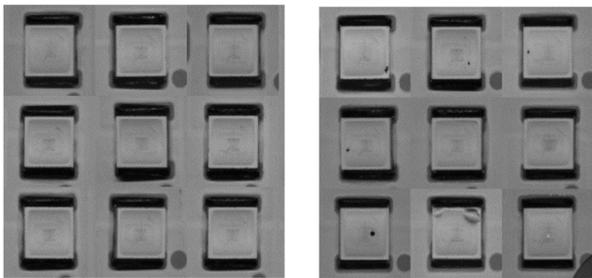
第8図 MSP-CGANのDiscriminatorの構造
(D_1, D_2, D_3 は各解像度における異常度マップ)
Fig. 8 Discriminator of MSP-CGAN
(D_1, D_2, D_3 are anomaly maps at each resolution)

の出力は各解像度における異常度マップであることを意味する。

本手法では、各解像度における異常度マップのなかの全要素から算出される異常度のなかで最も大きい値を異常度とする。

3.4 MSP-CGANの検証

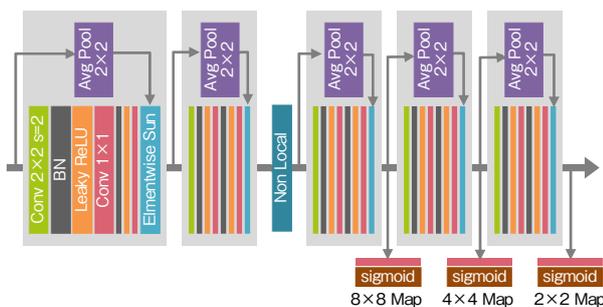
本実験のデータセットとしてLEDチップ画像を用いる。また、LEDチップ画像には第9図に示すような良品と不良品が存在する。



第9図 LEDチップの良品画像群 (左) と不良品画像群 (右)
Fig. 9 Non-defective LED chip (left) and defective LED chip (right)

不良の種類は欠けや汚れ・異物などであり、欠陥のサイズもさまざまである。

本実験で用いるMSP-CGANには、R-GANと同様GeneratorとDiscriminatorが存在する。MSP-CGANのDiscriminatorからは複数解像度のDiscriminationマップが出力されるが、本実験では8×8、4×4、2×2の3つのDiscriminationマップが出力されるように調整した。また、8×8、4×4、2×2の各マップの各画素が適切な受容野となるようDiscriminatorの構造を調整した。例えば、2×2のマップの左上の画素には入力画像を2×2に4分割した際の左上のROIの情報が埋め込まれている。具体的なDiscriminatorのネットワーク構造を第10図に示す。



第10図 Discriminatorの構造
Fig. 10 Structure of the discriminator

最終的な異常度は各正常度マップ内の最小値を求めることで算出される。これは小さな欠陥1部位でもワーク内に存在すれば不良であるという考えに基づいている。

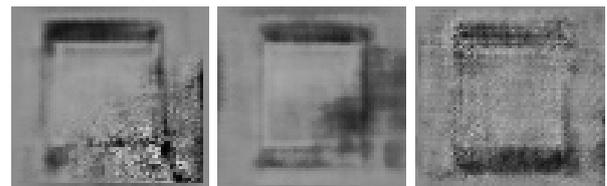
実験の結果を第2表に示す。本実験ではROC (Receiver Operating Characteristic) 曲線下の面積であるAUROC, Recall Precision曲線下の面積であるAUPRCを評価指標とした。AUROCとAUPRCは算出された異常度に対して、閾値を0.0から1.0まで0.01刻みで変動させて算出した。

第2表 実験結果
Table 2 Evaluation results

	AUROC	AUPRC
R-GAN	0.879	0.567
Autoencoder + CGAN	0.538	0.02
CGAN	0.747	0.191
Ours (MSP-CGAN)	0.954	0.664

第2表のとおり、MSP-CGANは他の手法 (R-GAN, Autoencoder + GAN, CGAN) と比較して高い精度で異常の検出が行えている。これは、MSP-CGANが複数の解像度 (8×8, 4×4, 2×2) からなるDiscriminationマップを出力することが、さまざまなスケールの不良、特に微小欠陥の検出に有効だったため考えられる。

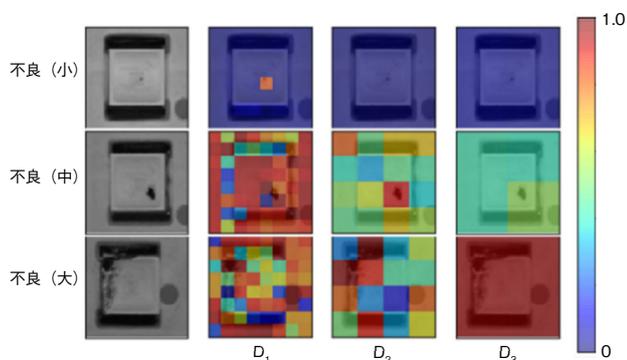
MSP-CGANのGeneratorにより生成された良品LEDチップの補集合画像を第11図に示す。生成された画像は良品のLEDチップには近いが、良品パターンには存在しないような画像となっていることが確認できる。



第11図 MSP-CGANのGenerator部により生成された良品LEDチップの補集合画像
Fig. 11 LED chip images generated by MSP-CGAN

第12図は各解像度における異常度マップを示したものである。例えば、不良 (小) はD₁が強く反応しており、D₂およびD₃は反応がない。これは、D₁の出力サイズが8×8であり、入力画像を64分割した各領域での異常度を意味しており、小さい不良に適したマップであるためである。同様にD₂は16分割、D₃は4分割した各領域の異常度を示すマップであるため、それぞれのサイズに適した不良 (中), 不良 (大) が反応している。異常度マップの欠陥箇所に対する位置精度は正確ではないものの、おおむね異常を検出できていることが確認できた。これより、

良品データのみ学習により不良を検出する手法の有効性を示すことができた。



第12図 MSP-CGANのDiscriminatorによる異常度マップ

Fig. 12 Anomaly map by MSP-CGAN

執筆者紹介



鎌田 祥平 Shohei Kamada
ライフソリューションズ社
ものづくり革新本部
Manufacturing Innovation Div.,
Life Solutions Company



中塚 俊介 Shunsuke Nakatsuka
ライフソリューションズ社
ものづくり革新本部
Manufacturing Innovation Div.,
Life Solutions Company



山本 治美 Harumi Yamamoto
ライフソリューションズ社
ものづくり革新本部
Manufacturing Innovation Div.,
Life Solutions Company

4. まとめ

本稿では、深層学習を用いた外観検査の課題を解決する2つのニューラルネットワークを紹介した。1つは、品種展開に対応可能なネットワーク（見比べNet）、もう1つは良品のみの学習で不良を検出するネットワーク（MSP-CGAN）である。見比べNetは印字検査において実用可能であることを示し、MSP-CGANはLEDチップの画像を用いて外観検査の異常検知手法として有効であることを示した。今後はこれらの製品だけでなく、あらゆる製品に対して適用可能な汎用性の高い外観検査技術を確立していきたい。

参考文献

- [1] 鎌田祥平 他, “テンプレート比較型ニューラルネットワークを用いた汎用印字検査の検討,” View2018 フルレングス講演論文集, pp.138-139, 横浜, Dec. 2018.
- [2] 中塚俊介 他, “多重解像度マップを持つ補集合GANを用いた正常データのみ学習による外観検査法,” View2019 フルレングス講演論文集, p.99, 横浜, Dec. 2019.
- [3] Gao Huang et al., “Densely Connected Convolutional Networks,” CVPR, Honolulu, July 2017.
- [4] J. Bromley et. al., “Signature verification using a “Siamese” time delay neural network,” International Journal of Pattern Recognition and Artificial Intelligence, vol. 7, issue. 04, pp. 669-688, 1993.
- [5] Jonathan Long, “Fully Convolutional Networks for Semantic Segmentation,” CVPR, Boston, June 2015.
- [6] T. Schlegl et al., “Unsupervised anomaly detection with generative adversarial networks to guide marker discovery,” Proceedings of International Conference on Information Processing in Medical Imaging 2017, pp. 146-157, 2017.