

AI 技術を活用した検査工程の省力化・効率化（第4報）

— 深層学習を用いた欠陥画像データ生成技術の検討 —

渡辺博己*、生駒晃大*、松原早苗*

A study on artificial intelligence for labor savings and efficiency improvements of inspection process (IV)

— Defect image generation using deep learning —

WATANABE Hiroki*, IKOMA Akihiro* and MATSUBARA Sanae*

深層学習を利用した画像分類では、多量の学習用データを必要とするが、生産ラインにおいては、欠陥画像を収集することが困難な場合がある。本研究では、敵対的生成ネットワークを用いて、少数の学習用データを拡張する方法を検討した。実験では、欠陥画像データセットを用いて、敵対的生成ネットワークに畳み込みニューラルネットワークを適用した深層畳み込み敵対的生成ネットワークにより欠陥画像生成モデルを構築した。その結果、欠陥画像生成モデルによる欠陥画像の生成が可能であることが確認できた。

1. はじめに

外観検査で畳み込みニューラルネットワーク¹⁾ (以下、CNN) を利用するためには、学習用データとして多量の正常画像データと欠陥画像データを必要とする。しかし、不良率の削減に重点を置き、改善に取り組んできた生産ラインにおいては、欠陥画像データの収集が困難な課題となっている。

この課題に対して、従来は、元データの画像に反転、回転、拡大等の幾何変形を施すことにより、データ数を水増し (以下、データ拡張) して、学習用データとして利用していた。しかし、近年では、深層学習を用いた画像生成手法によるデータ拡張が注目され、特に、敵対的生成ネットワーク²⁾ (以下、GAN) を利用したデータ拡張手法が有望とされている。

本研究では、GAN を利用した画像生成モデルを試作し、欠陥画像に対する画像生成実験を行ったので、その結果について報告する。

2. GAN

GAN は、データから特徴を学習することにより、実在しないデータの生成や、存在するデータの特徴に沿った変換が可能となる生成モデルである。図1に GAN の構造を示す。

GAN は、生成器と識別器の二つのネットワークから構成される。生成器は、入力されたランダムノイズ z を受け取り、偽物のデータ $G(z)$ を生成する。識別器は、本物のデータ X と生成された $G(z)$ を受け取り、本物か偽物かの識別が可能となるよう学習する。この時、生成器の目的は識別器を騙すことであり、識別器の目的は騙されないことである。そのため、二つのネットワークを競わせながら学習を進めることにより、生成器のデータ生成能力が向上するとともに、識別器の識別能力も同様に向上し、これらの結果として、生成器は、本物に近い

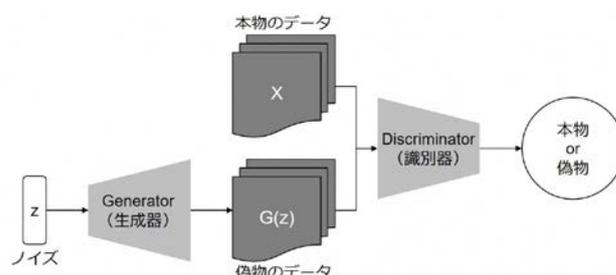


図1 GAN の構造

データを生成することが可能となる。

3. 実験

3.1 データセット

本研究では、データセットとして、昨年度報告した欠陥画像データセット⁴⁾を利用した。欠陥画像データセットは、欠陥15クラス、正常4クラス、計19クラスにラベル付けされたデータセットで、図2に画像例を示す。

画像は、 256×256 [pixel]のモノクロで、データセットには、部品の構造上、欠陥C、Hに示す画像のような欠陥 (暗) 領域が存在する画像や、照明によるハイライト (明) 領域が存在する画像が含まれている。そのため、全ての画像に暗領域が含まれている欠陥C、Hを除く17クラスについては、更に明暗領域 (欠陥に起因する領域を除く) の有無に分類した。表1に各クラスのデータ数を示す。

3.2 生成モデル

GAN には、学習が不安定になり、生成データに偏りが生じるという課題があった。そこで、提案されたのが、GAN のネットワークに CNN のような畳み込み層を適用した深層畳み込み GAN³⁾ (以下、DCGAN) で、本研究では、DCGAN を用いた欠陥画像生成モデルを試作した。図3に欠陥画像生成モデルにおける生成器と識別器のネットワーク構造を示す。なお、ネットワーク構造については、実験的に決定した。

学習においては、クラス毎に、生成器に128次元の一

* 情報技術部

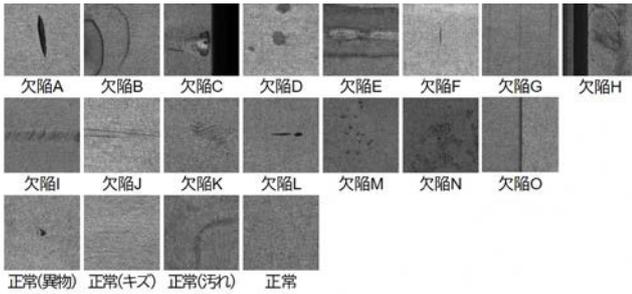
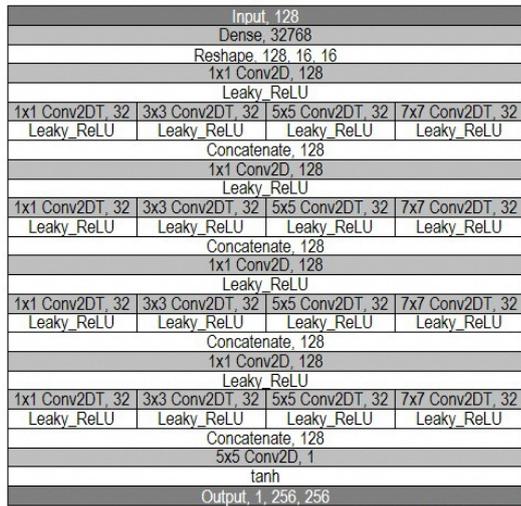


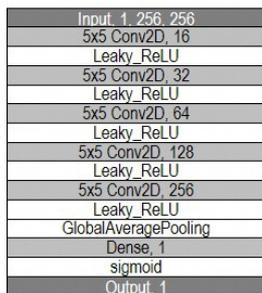
図2 欠陥画像データセットの画像例

表1 欠陥画像データセットにおけるデータ数

| 種別 | 明暗無 | 明暗有 | 種別 | 明暗無 | 明暗有 | 種別 | 明暗無 | 明暗有 |
|--------|-----|-----|--------|-----|-----|--------|-----|-----|
| 欠陥A | 709 | 139 | 欠陥B | 711 | 386 | 欠陥C | 800 | |
| 欠陥D | 714 | 89 | 欠陥E | 782 | 165 | 欠陥F | 701 | 108 |
| 欠陥G | 817 | 106 | 欠陥H | 800 | 800 | 欠陥I | 800 | 694 |
| 欠陥J | 704 | 241 | 欠陥K | 830 | 197 | 欠陥L | 762 | 38 |
| 欠陥M | 739 | 62 | 欠陥N | 741 | 162 | 欠陥O | 141 | 459 |
| 正常(異物) | 760 | 173 | 正常(キス) | 786 | 14 | 正常(汚れ) | 741 | 274 |
| 正常 | 715 | 89 | | | | | | |



(a) 生成器



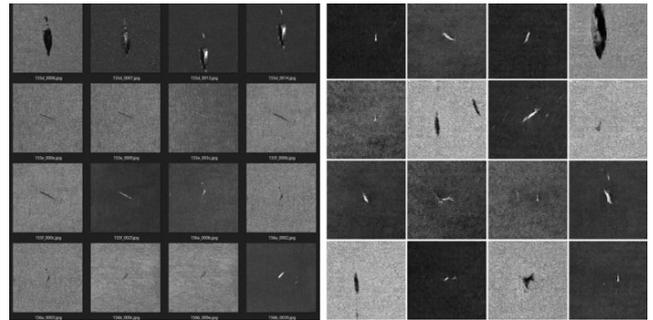
(b) 識別器

図3 欠陥画像生成モデルのネットワーク構造

様乱数を入力データとして与え、256×256[pixel]のモノクロ画像を出力データとして取得した。

4. 結果と考察

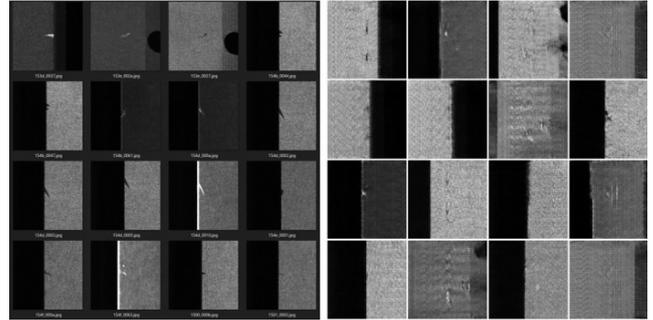
生成器から取得した画像例を図4に示す。明暗無クラスについては、欠陥Oを除き、全ての欠陥・正常クラスで概ね生成することができた。また、明暗有クラスについては、全ての欠陥・正常クラスで明暗領域を十分に



実画像(学習データ)

生成画像

(a) 欠陥A, 明暗無クラス



実画像(学習データ)

生成画像

(b) 欠陥A, 明暗有クラス

図4 生成画像の例

生成することができなかった。

この原因として考えられるのは、データ数の不足である。また、明暗有クラスの欠陥C、H、Iについては、明暗無クラスと同程度のデータ数であるが、画像中の明暗領域の位置が部品に対する欠陥の位置に依存するため、位置のバラ付きが大きいことが考えられる。

5. まとめ

本研究では、DCGANを用いた欠陥画像生成モデルを試作し、欠陥画像データセットにおける明暗領域の無い画像について、画像生成が可能であることを確認した。

今後は、様々な手法が提案されているGANについて、他の手法も検討するとともに、生成画像を利用した画像分類についても検討する。

【謝 辞】

本研究を遂行するにあたり、欠陥画像データセットをご提供いただきました株式会社前田精工の皆様へ深く感謝の意を表します。

【参考文献】

- 1) Y. LeCun, et al., Proc. IEEE, vol.86, no.11, pp.2278-2324, 1998
- 2) I. Goodfellow, et al., Proc. NIPS 2014, pp.2672-2680, 2014
- 3) A. Radford, et al., arXiv: 1511.06434, 2015
- 4) 渡辺ら, 岐阜県産業技術総合センター研究報告 No.1, pp.81-84, 2020