

第 199 回 ICS 研究発表会 発表原稿

敵対的生成ネットワークを利用した
異常検知の自動化

伊藤・Moustafa 研究室

メディア情報系

伊藤 優樹 伊藤 孝行 Ahmed Moustafa

1 はじめに

これまで機械を使った製品検査はサイズや温度など、センサーデータを使った検査装置が使われてきたが、ディープラーニング技術の登場により人にしかできなかった異常検知の自動化を実現することができるようになった。近年、異常検知技術の発展が製造業界において大きな注目を集めており、特に外観検査作業の自動化の需要が増大している。しかし、従来の異常検知技術は、数千、数万の正常データと異常データを学習させることが必要であり、製造業では良品に比べて不良品の発生率が極めて低いいため、そのような膨大な数の異常データを収集することが困難であることが課題となっている。

本研究の目的は、数百程度の正常データの学習のみから異常検知を行うことにある。これにより、手動的な製品検査による労力及び時間的コストの削減や、正常データのみでの学習からくる未知の異常品検出の可能性が期待できる。

2 関連研究

2.1 Generative Adversarial Networks[1]

適当なベクトルから学習した画像を生成するネットワーク Generator と画像が生成されたものか本物の画像かを判定するネットワーク判別機 Discriminator から構成されており、ノイズを入力として Generator は画像を生成し、本物の画像と混ぜながら Discriminator に本物か Generator で生成した画像かを判定させる教師なし学習である。多量の正常画像を学習すると、潜在空間の中に学習した正常画像を覚え込み、ランダムな入力ノイズに応じて覚え込んだ様々な正常画像を生成出来るようになる。

2.2 Deep Convolutional GAN[2]

Deep Convolutional Generative Adversarial Networks(DCGAN) とは、2016 年に提唱された GAN の発展技術である。DCGAN では、畳み込み層やバッチノーマライゼーションを用いることで、より高解像度、より自然な画像の生成を可能としている。DCGAN の研究例を図??に示す。

3 提案手法

3.1 概要

提案手法として、異常検知の自動化に GAN を用いる。GAN の構成要素である Generator の画像再構築可能性に基づき、元の画像と探索された潜在変数により再構成された画像の差分を取ることで、異常度の検出を行う。Generator に与えたテストデータに最もよく似た画像を生成できるノイズ z を求める必要



図 1: DCGAN によるベッドルーム画像の生成

があるが、この手順をエンコーダ E によって学習し、Generator, Discriminator と同時に学習を進める。図??に提案手法の概要図を示す。




図 2: 提案手法の概要図

Discriminator へ画像 x と入力ノイズ z のペアとして (x, z) を入力する。Discriminator は訓練データの画像と訓練データの画像に対してエンコーダ E で求めた入力ノイズのペアか Generator で生成した画像と生成時に使用した入力ノイズのペアか、すなわち $(x, E(x))$ か $(G(z), z)$ かを判別することになる。これらの学習により、Generator は、入力されたノイズに対して高解像度な画像を生成できるようになり、エンコーダ E は Generator が与えたテストデータに最もよく似た画像を生成できるノイズ z を求めることができるようになる。

3.2 提案手法のステップ

初めに GAN 及びエンコーダ E の学習を数百枚程度の正常データのみを用いて行う。学習後、エンコーダ E で求めた入力 z を Generator に渡し、与えたテストデータに最もよく似た画像を 1 枚生成する。生成画像と元のテストデータをピクセルレベルの比較を行い、その間の損失値の合計を計算する。GAN に正常データのみを学習させた場合、モデルは潜在空間上の z から異常データを生成できないことを利用し、画像を潜在空間上に写像し、 z から元の画像が復元できたら正常、そうでなかったら異常と判別する。

4 評価実験

実験は、工業製品や農作物の 15 のカテゴリがあり、各ドメインごとの欠陥、画像内の様々な配置、さらに欠陥領域のアノテーションデータを収集した MVTec-AD[3] データセットの中から Metal Nut 画像を用いて行った。異常データとして擦れ傷のついた Metal Nut 画像を用いた。全てのデータは 250×250 にリサイズして使用した。

5 実験結果と考察

与えたテストデータと、それに対する Generator による生成画像を図 3 に示す。また、それぞれの損失値を表 1 に示す。




図 3: テストデータ (上段) と生成画像 (下段)

表 1: テストデータと生成画像間の損失値

No.	データ種	損失値
1	正常	13594
2	正常	15761
3	正常	13549
4	正常	14552
5	異常	17035

図 3 を見ると、全てのテストデータにおいて、Generator による生成画像が Metal Nut の形、向き、位置を忠実に再現できていることがわかる。また、5 番目のテストデータを与えた際の Generator の生成画像では、テストデータについている擦り傷が再構築できていないことがわかる。この部分の損失が、表 1 に示す損失値において、5 番目のテストデータを与えた際の損失値が最大になっている要因である。

6 まとめと今後の展望

本研究の最大の目的は、正常データのみを学習した GAN モデルを用いることで、製品の外観検査の自動化を図ることである。現在多くの場合で、製品の外観検査は検査員に依存しており、検査員の能力差や疲労の度合いで作業品質に偏りが生じてしまう。また、外観検査に画像処理技術を導入している場合でも、莫大な量の異常データを集める必要があり、初期のパラメータ設定に時間的コストを有したりなど、多くの課題点が残っている。しかし、正常データのみで学習で異常検知を可能にすることで、異常データを集める手

間を省くことができ、未知の異常パターンを検出することにも対応できるようになる。さらに、検査員の労力的負担の大幅な軽減や、作業品質の均等化および製品の品質保持、高品質化が期待される。

参考文献

- [1] Mehdi Mirza Bing Xu David Warde-Farley Sherjil Ozair Aaron Courville Yoshua Bengio Ian J. Goodfellow, Jean Pouget-Abadie, "Generative Adversarial Networks", In NIPS, 2014.
- [2] Soumith Chintala Alec Radford, Luke Metz., "Unsupervised representation learning with deep convolutional generative adversarial networks", arXiv:1511.06434, 2016.
- [3] David Sattlegger Carsten Steger. Paul Bergmann, Michael Fauser., "Mvtec ad - a comprehensive real-world dataset for unsupervised anomaly detection", in: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 2019.