

Self-Attention による特徴抽出を用いた工場製品の異常検知

Anomaly Detection of Construction Equipment Using Feature Extraction by Self-Attention

長谷川 海太[†] 黒木 啓之[†]Kanata HASEGAWA[†] Takashi KUROKI[†]

1 はじめに

本研究で対象とした建設用仮設機材のレンタル企業において、製品が返却された際に付着した汚れや傷、変形といった外傷に対して、従業員が目視で外観検査を行っており、必要な人的コストは多くなってしまふ。それに加え、体調や熟練度によって判断基準が左右されてしまふといった問題点がある。

このような問題を解決するために、昨今ではディープラーニングを用いて製品の異常検知を行い、外観検査作業を自動化する需要が高まっている。ディープラーニングを用いた異常検知の手法の一つに GAN(Generative Adversarial Networks)[1] が挙げられる。これまで筆者らはこの GAN の中でも Efficient GAN[2] を用いた異常検知を試みてきた [3]。しかし、低次元の特徴量から高次元の特徴量へ転置畳み込み処理の繰り返しによって画像を生成するため、MNIST のような単純な画像に対しては正常に動作するのにに対し、製品の画像のような複雑な情報が入り混じる画像に対しては生成能力が著しく低下してしまうことがわかった。

そこで本研究では、Self-Attention による特徴抽出を導入した Efficient GAN を用いて工場製品の異常検知を行い、その性能を評価することを目的とする。

2 GAN を用いた異常検知

GAN はランダムなノイズからデータを生成する Generator と、生成されたデータと学習データを識別する Discriminator で構成される教師なし学習である。GAN を用いた異常検知では、正常データのみを学習させることによって、Generator は異常データが入力された際にそのデータを生成するのは困難となる。そこで、入力データと生成データから再構成誤差を求め、閾値より再構成誤差が大きければ異常、小さければ正常というように異常検知を行う。

3 Efficient GAN

Efficient GAN は、前章で示した一般的な GAN の構成である Generator と Discriminator に加え、図 1 に示すように入力された画像をノイズ $E(x)$ に変換する Encoder を加えた手法である。

従来の異常検知に用いられていた GAN では、推論時に入力されたデータを生成するためのノイズをモデルの学習とは別に学習させる必要があったため、推論時の画像生成に非常に多くの時間がかかってしまうという問題がある。しかし、Efficient GAN ではモデルの学習時にノイズを生成する Encoder も同時に学習することによって推論時に別途学習が必要なく、計算時間を大幅に削減可能である。

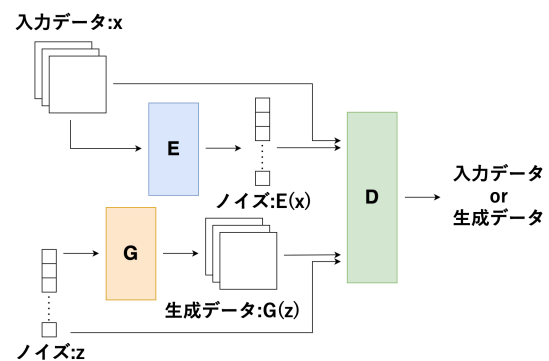


図 1 Efficient GAN の概要
(E:Encoder G:Generator D:Discriminator)

4 Self-Attention

Self-Attention は、自然言語処理分野において離れた単語間の関係性を考慮することができる仕組みである。この仕組みを用いることで RNN や CNN よりも計算量を削減しつつ文章内の単語の依存関係が掴みやすくなるというメリットがある。

最近ではこの仕組みは自然言語処理のみならず、Vision Transformer[4] といった画像認識分野への応用が

[†] 東京都立産業技術高等専門学校
Tokyo Metropolitan College of Industrial Technology

進んでいる。Self-Attention を画像認識に用いる場合、各画素に対して計算が行われるので、CNN のフィルタのような局所的な情報の集約ではなく、画像全体の依存関係を考慮することができるため、画像の生成能力の向上が期待できる。

5 提案手法

本研究では、これまでの研究成果に対する改善手法として、Efficient GAN をベースに Encoder と Generator, Discriminator に Self-Attention を導入した手法を提案する。

GAN 内の各ネットワークの中間層に Self-Attention を導入することで、前章で述べたように入力画像の大域的な情報を学習可能であり、これまでの課題であった複雑な情報を持つ画像の生成能力の低下に関して、画像生成能力の改善によって生成された画像がより鮮明になり、誤検知の防止につながるという異常検知の性能向上が期待できる。

6 実験

6.1 工場製品データセット

本研究において対象とした工場製品の画像のデータセットは、 274×38 [pixel] のカラー画像が訓練用画像 493 枚、検証用画像 74 枚で構成されている。図 2 にその例を示す。



図 2 工場製品データセットに含まれるデータ例

6.2 実験方法

本研究では、前章で示した提案手法を MNIST データセット、前節で示した工場製品データセットを用いて評価を行う。以下に実験の手順を示す。

1. 正常品画像のみで Efficient GAN を学習させ、学習済みの Generator, Encoder, Discriminator を得る。
2. 検証用画像を Encoder に入力し、出力として得られるノイズ $E(x)$ を Generator に入力し、画像を生成する。

3. 学習済み Generator によって生成された画像と入力画像から再構成誤差を算出する。
4. 再構成誤差に対して閾値を定め、その閾値異常であれば異常データ、そうでなければ正常データとして判別する。
5. 学習後に得られたモデルを ROC 曲線の下部分面積である AUC によって評価を行う。また、判別されたデータに対しても、全データのうち上位 20% を異常値とするように閾値を定め、再現率、適合率、F 値による評価を行う。

7 おわりに

本研究では、Efficient GAN を用いた工場製品の異常検知において、画像の生成能力向上のために Self-Attention を導入した手法を提案した。

今後は、提案した手法を実装し、MNIST データセットと実際に用いられている工場製品のデータセットに対して実験とその評価を行う。

謝辞

本研究は、ジー・オー・ピー株式会社の助成により行われたことを記し、ここに謝意を表する。

参考文献

- [1] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, ...Yoshua Bengio, "Generative Adversarial Nets", NIPS, pp.2672-2680, 2014.
- [2] Houssam Zenati, Chuan Sheng Foo, Bruno Lecouat, Gaurav Manek, Vijay Ramaseshan Chandrasekhar, "Efficient GAN-Based Anomaly Detection", ICLR, 2018.
- [3] 長谷川海太, 黒木啓之, "Efficient GAN を用いた建設機材の異常検知", 第 28 回 電子情報通信学会東京支部学生会研究発表会, No.130, 2023.
- [4] Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, ...Georg Heigold, Neil Houlsby, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale", ICLR, 2021.