

# 深層畳み込み敵対的生成アルゴリズムによる 識別器の特徴注目学習

日大生産工(学部) ○田崎 雅裕 日大生産工 山内 ゆかり

## 1. まえがき

DeepLearningを発端とする人工知能の発展と需要の高まりから、研究も盛んに行われており人工知能分野の一つに敵対的生成ネットワーク(Generative Adversarial Networks: GAN)[1]、と呼ばれる技術が存在する。GANは学習した画像に似たような画像を生成、識別できる点が特徴的である。同じ画像識別においては畳み込みニューラルネットワーク(Conditional Neural Networks:CNN)[2]が有効であり、CNNをGANのネットワークに適用される試みは行われていた。RadfordらはGANにCNNを適応させた深層畳み込み敵対的生成ネットワーク(Deep Convolutional Generative Adversarial Networks:DCGAN)[3]を提案した。DCGANでは教師なし学習を行い、GANと比べても自然な画像の生成に成功した。しかし、精度においては一般的な教師なし特徴学習で扱われるK-means法よりは高いパフォーマンスを実現したもののExemplarCNN[4]と比較すると精度が落ちている。

そこで本研究では識別器のネットワークをAttention Branch Network(ABN)[5]に置き換えることで識別器の機能向上を目指し、教師なし学習におけるさらなる精度向上を目標としている。

## 2. 従来手法

### 2-1. GAN

2014年にGoodFellowらによって提案された手法である。Generator(:G)によってノイズから生成された画像と実画像をDiscriminator(:D)で判別を行う。学習方法は一般的に誤差逆伝播で行い、目的関数を以下に示す

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_{gen}(z)} [\log (1 - D(G(x)))] \quad (1)$$

$x$ が実在画像、 $z$ が生成された画像の値である。 $\max_D$ は実在の画像 $\log D(x)$ と生成された画像 $[\log (1 - D(G(x)))]$ を最大の値となるように学

習させ、 $\min_G$ は最小の値となるように学習させる事を目的としている。

### 2-2. DCGAN

DCGANとは従来のGANにCNNを適用させたGANとなっている。GANの派生形には多くのアーキテクチャが存在するがDCGANの基本的な構造はGANと同じである。先行研究ではミニバッチSGDで更新し、逆伝播で学習していく。以下にGenerator、Discriminatorの設計図を示す




Fig.1 Generatorのアーキテクチャ




Fig.2 Discriminatorのアーキテクチャ

Gでは画像を生成するために転置畳み込みを行って画像サイズを大きくしている。Dでは画像の判別結果を出力するために畳み込みを行う。

特徴的な点として

- 隠れ層での全結合層を削除する
- Gのプーリング層を転置畳み込みに置き換え、Dのプーリング層を畳み込み層に置き換える

—Gの活性化関数にReLUを最終層にTanhを使用し、Dの全ての活性化関数にLeakyReLUを使用する

—バッチ正規化をGとDの両方に行うなどが挙げられる。

### 2-3. ABN

ABNとは福井宏らが提案した手法で、従来のネットワークがどこを注視していたか視覚的に確認できるAttentionマップを用いたAttention機構をCNNに導入することでCNNの性能の向上に繋がったネットワークである。ABNはFig.3で示してある。特徴抽出器、Attentionブランチ、パーセプションブランチの3つのモジュールから構成されている。CNNを分割した形で特徴抽出器、パーセプションブランチにそれぞれ分けて、Attentionブランチを追加している。なお誤差関数はクロスエントロピー誤差を用いており、以下に示す。

$$H(p, q) = - \sum_x p(x) \log(q(x)) \quad (2)$$

$p$ は正しい確率分布、 $q$ は推定した確率分布であり、確率分布が似ているほど値は小さくなっていく。

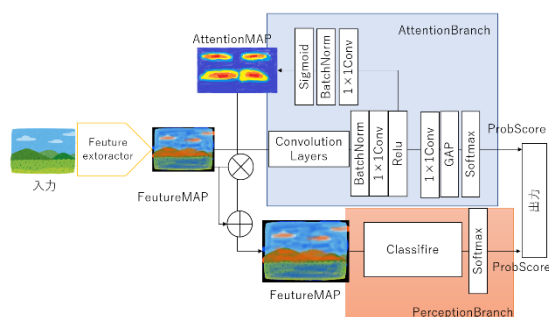


Fig.3 ABNのアーキテクチャ

### 3. 提案手法

識別器にABNを用いることで認識率の向上を計り、DCGANのパフォーマンスを向上させるABN+DCGANを提案する。本論文ではDにおけるCNNの左から3層を特徴抽出器に、最後の1層をパーセプションブランチに割り当てている。

### 4. 実験方法および測定方法

実験方法として従来のDCGANと提案手法のABN+DCGANを用いて画像の生成を行い、精度を計測する。

具体的にはCifar-10[6]と呼ばれる画像セットを用いて学習を行う。Cifar-10とは10クラス60000枚の32×32RGB画像で50000枚の訓練用データと10000枚のテストデータに分かれている。本研究では10000枚の訓練用データで学習を行い1000枚のテストデータを用いて本物の画像と生成された画像をそれぞれ比較してどちらの画像なのか識別器で比較を行う。提案手法を用いた画像の特徴表現により注視した識別を行うことで識別精度の改善を試みた。

### 5. まとめ

DCGANの従来の問題点であった精度が他アルゴリズムと比べ向上しない点に対して、ABNを識別器に導入して特徴注目学習を行うことによりさらなる識別機能向上を目指した。

### 参考文献

- [1] Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. C., and Bengio, Y. “Generative adversarial nets”. NIPS, 2014.
- [2] Y. LeCun, B. Boser, J. S. Denker, and D. Henderson..etc, “Backpropagation Applied to Handwritten Zip Code Recognition” AT&T Bell Laboratories 1989.
- [3] Alec Radford & Luke Metz and Soumith Chintala. “Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks”. ICIR 2016.
- [4] A. Dosovitskiy, P. Fischer, J. T. Springenberg, M. Riedmiller and T. Brox. “Discriminative Unsupervised Feature Learning with Exemplar Convolutional Neural Networks”. arXiv:1406.6906.
- [5] Hiroshi Fukui, Tsubasa Hirakawa, Takayoshi Yamashita and Hironobu Fujiyoshi “Attention Branch Network: Learning of Attention Mechanism for Visual Explanation”. CVPR 2019.
- [6] Alex Krizhevsky “Learning Multiple Layers of Features from Tiny Images”, 2009, <https://www.cs.toronto.edu/~kri/learning-features-2009-TR.pdf>, (参照 2020-10-14)