

CycleGAN を利用した循環的変換による連続的画像生成

Successive image generation through cyclic transformations using CycleGAN

田中 天也[†] 山口 裕[‡]
Takaya Tanaka **Yutaka Yamaguti**

1 はじめに

深層学習の発展により、記憶した画像や類似した画像を新たに生成できるネットワークは多く研究されている。特に、敵対的生成ネットワーク (GAN)[1] は、本物と見分けが付かないような新たなデータを生み出す生成モデルとして、2014 年に Ian J.Goodfellow らによって発表され、大きく注目された。さらに、それを発展したモデルの研究は広く進められており、GAN の一種として知られている CycleGAN[2] では、2 つの画像データセット同士の関係を学習することで画像変換を実現する。

一方、このような深層モデルを使って、記憶した画像やその類似画像を自律的に次々と生成するような研究例は少ない。また、深層学習の技術を取り入れた連想記憶モデルについても研究例は少ない。そこで本研究では、画像を次々と変換させるようなモデルを構築し、類似した画像の系列を生成させた。そして、この連続的画像変換の性質を力学系の観点から分析した。

2 CycleGAN

CycleGAN は、2 つの画像データセット同士の関係を学習して画像変換を実現する。2 つの画像データセット同士に対応は必要ない。図 1 に CycleGAN のモデル図を示す。データセット X から Y へ変換する G と、Y から X へ変換する F からなる 2 つの Generator(生成器)があり、それぞれの Generator の出力した画像が本物であるか、あるいは偽物であるかを識別する Discriminator(判別器)も 2 つずつ存在する。

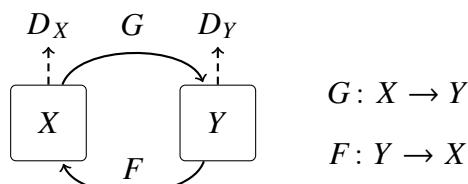


図 1 CycleGAN のアーキテクチャ

3 モデル

CycleGAN のモデルを組み合わせて、図 2 のように 3 つの画像を次々と変換できるようなモデルを実装した。このモデルには 2 つの Generator G, F が存在し、図 2 中にはそれぞれ破線と点線で表している。Discriminator は、 D_X , D_Y , D_Z の 3 つ存在する。同じ Generator を用いて 1 回前に出力された画像を次の入力画像として使う処理を繰り返すことで次々と変換することを実現する。

学習には手書き数字データセットである MNIST を使用し、本実験では X に 0, Y に 1, Z に 2 の手書き数字画

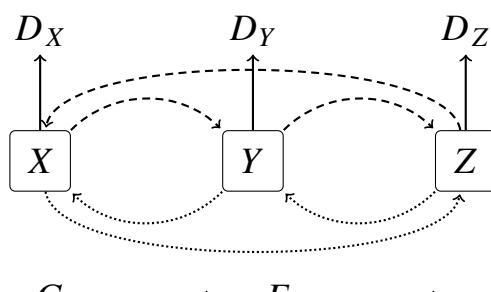
[†] 福岡工業大学大学院工学研究科 Graduate School of

Engineering, Fukuoka Institute of Technology

[‡] 福岡工業大学情報工学部 Faculty of information engineering,

Fukuoka Institute of Technology

像の集合をそれぞれ用いた。Generator G, F の訓練に用いる損失関数は、3 種の画像データ集合をそれぞれ一度変換した画像を、変換先の集合に対応する判別器で評価することにより計算される損失と、Cycle-consistency 損失 [2] の和からなる。



$G: \text{---} \rightarrow$ $F: \text{...} \rightarrow$

図 2 モデル図

4 結果と考察

訓練後のモデルを用いて、手書き数字画像を次々と変換させたところ、ほとんどの場合、次の数字に正しく変換され続けた。学習回数が不十分な Generator では、図 3 のように時折正しく次の数字に変換されないことがあったが、繰り返し変換を続けると元の数字に戻ってきた。

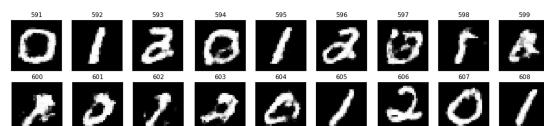


図 3 画像の連続変換の例

4.1 非周期的軌道の生成

周期性を確認するために、訓練後の Generator G を用いて、最初に入力した画像と同じ数字を 4000 回生成させ、後半の 2000 回で生成された画像と最後に生成された画像との距離を縦軸にとったグラフを図 4 に示す。周期性は確認できなかった。

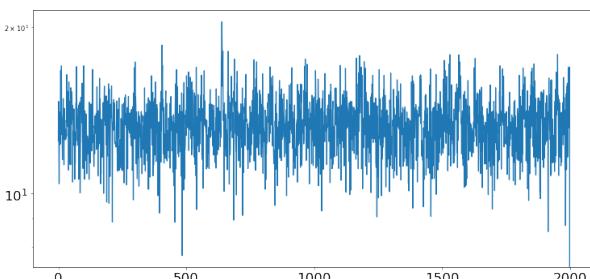


図 4 最後の画像との距離の変化

4.2 生成データ系列の分布

訓練後の Generator G を用いて、初期値を MNIST テストデータの 0 として 15000 回変換を行い、次元削減の手法である UMAP[3] を用いることで訓練データ（淡色）と生成データ（濃色）の分布を 2 次元上に表したものが図 5 である。3 つのクラスタが存在しており、それぞれ手書き数字の 0, 1, 2 に対応している。図 5 の 2 枚の分布画像は初期値が異なるものである。生成データは訓練データが存在する領域内に存在しているが、訓練データの分布を全体的にカバーすることはできていない。図 5 の上下の比較からは、二つの異なる初期値からの軌道がほぼ同じ集合に収束していることが示唆される。

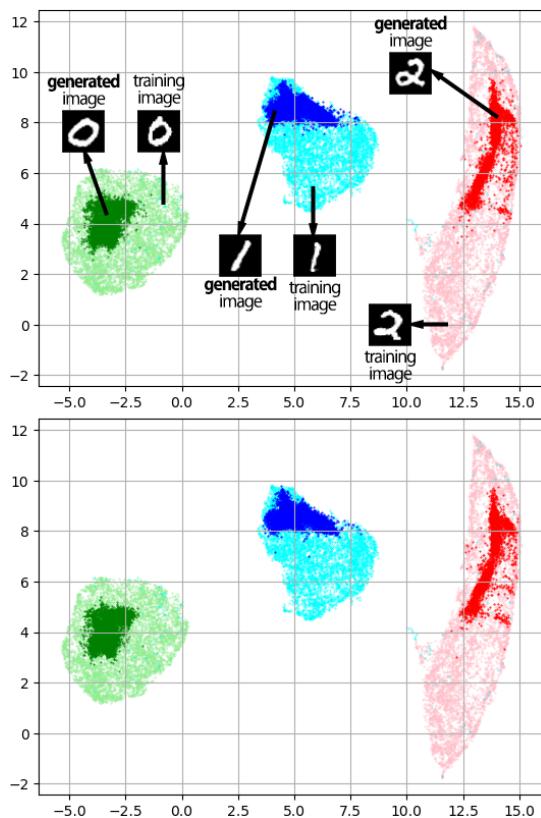


図 5 UMAP による生成データの分布

4.3 多量の初期値の変換による生成データの分布

訓練後の Generator G を用いて、多量の初期値（MNIST テストデータの 0 を 1000 点）に対して、同時に最大 15002 回の変換を行った。UMAP を用いて、変換によって生成されたデータの分布を 2 次元上に表したものが図 6 である。 x を初期値とし、Generator G による n 回の繰り返し変換を $G^n(x)$ と記した。図 5 と同様に、訓練データを淡色、生成データを濃色で示している。最初の数回の変換では多様な画像が生成されているが、変換を繰り返すうちに一部の領域に軌道が集まることが分かる。

5 まとめ

本研究では、CycleGAN のモデルを参考に、手書き数字画像を次々と別の数字に変換できるようなモデルを構築し、類似した画像を生成させることができた。構築したモデルを使って画像を繰り返し生成させたところ、基本的に、正しく次の数字に変換され続けることが確認で

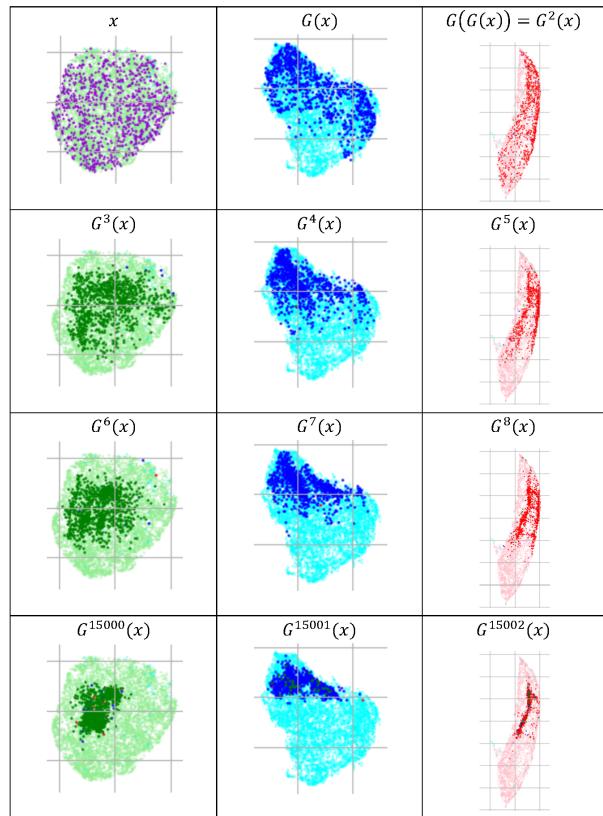


図 6 UMAP による多量の初期値の変換による分布

きた。学習回数が少ない Generator では、途中で正しく次の数字に変換されないこともあったが、さらに繰り返し生成を続けることによって、元の数字に戻ってくることが確認できた。

繰り返しの回数をさらに増やして、最後に生成された画像との距離をとった結果をグラフにて可視化したところ、周期性は確認できなかった。連続的変換を力学系と捉えると、軌道は非周期的であり、カオス的性質を持つことが示唆されることから、リアプノフ指数の推定に現在取り組んでいる。

次元削減の手法である UMAP を用いて生成データの分布を 2 次元上に表したところ、一つの軌道の中で多様な画像が生成できていることが確認できた。一対の画像変換を学習した CycleGAN の G と F を使い連続的に変換を行った場合、多くの小さなアトラクタが出現することが先行研究 [4] により報告されているが、今回の結果はそれと異なり、より多様な画像を生成するアトラクタが出現していることが示唆される。今後の課題としては、生成データの分布を訓練データの分布まで広げられるように、モデルを改良することが挙げられる。

謝辞

本研究は JSPS 科研費 20K11985 の助成を受けた。

参考文献

- [1] Ian Goodfellow et al. "Generative adversarial nets." In: Advances in Neural Information Processing Systems, Vol. 27 (2014).
- [2] Jun-Yan Zhu et al. "Unpaired image-to-image translation using cycle-consistent adversarial networks." In: IEEE International Conference on Computer Vision (ICCV) (2017).
- [3] Leland McInnes, Healy John, and Melville James. "UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction" In: arXiv:1802.03426 (2018).
- [4] 遠原由規, 山口裕. "CycleGAN を用いた繰り返し画像変換に現れるアトラクタダイナミクスの分析" In: 日本応用数理学会 2021 年度年会講演予稿集 (2021), pp.202-203.