

# GAN 追加学習のための Fréchet Inception Distance に基づく データセットの選別手法の提案\*

西澤桂祐<sup>†1</sup> 和田康孝<sup>‡1</sup>

<sup>1</sup> 明星大学情報学部

## 1 はじめに

GAN (Generative Adversarial Network) は画像生成のための AI として広く利活用されており、その生成する画像の精度は年々上がっている。しかし、その学習には膨大なデータセットと時間必要とする。そこで、本稿では、データセットに含まれる画像から、より学習の効果が高い画像を選別して GAN に与えることで学習の効率化をする手法を提案する。

提案手法では、FID (Fréchet Inception Distance) [1] と呼ばれる GAN の性能評価に使われる指標に注目し、より学習に寄与する画像を選別する。FID は 2 つの画像群の類似性から GAN を評価する指標であることから、既に把握している特徴を多く持つような画像を判別することが可能と考えられる。また、この提案手法が学習の効率化にどの程度寄与できるかを StyleGAN[2] の学習を通して実験した。

## 2 Fréchet Inception Distance (FID)

FID[1] は、GAN の評価に広く使われている指標である。Inception-v3 モデルによって各画像の埋め込み表現を計算し、各画像群についてその平均や共分散を取り、それを比較することによって FID が算出される。

FID の定義を式 1 に示す。生成モデルのサンプルの分布を  $p(\cdot)$ 、比較対象のサンプルの分布  $p_w(\cdot)$  とする。 $p(\cdot)$ 、 $p_w(\cdot)$  から得られる Gaussian の平均と共分散をそれぞれ  $(\mathbf{m}, \mathbf{C})$ 、 $(\mathbf{m}_w, \mathbf{C}_w)$ 、 $\text{Tr}$  をトレース (行列の対角成分の和) とすると、FID は式 1 のように表される。この時、FID の値は 0 以上であり、より 0 に近いほど類似度が高いといえる。

$$d^2((\mathbf{m}, \mathbf{C})(\mathbf{m}_w, \mathbf{C}_w)) = \|\mathbf{m} - \mathbf{m}_w\|_2^2 + \text{Tr}(\mathbf{C} + \mathbf{C}_w - (2\mathbf{C}\mathbf{C}_w)^{1/2}) \quad (1)$$

## 3 FID を用いたデータセット選別による GAN の学習効率化手法

本稿で提案する手法においては、GAN の学習の前にデータセットを一定数のサブセットに分割し、サブセット単位で学習させるかどうかを判断する。これにより、より学習効果の高い画像を優先的に学習に用い、画像生成の質を保ちつつ、学習に要する時間を短縮することを目指す。図 1 に、提案手法による GAN の学習の流れを示す。あるデータセットを学習に用いるかどうかを判断する際、既に GAN が学習したデータセットのサブセットと学習させようとしているデータセットのサブセットを 1 つ取り出して FID を算出することで、サブセット間の画像の類似度を見積もることができる。その FID の値が、予め決められた閾値を上回れば、未知のデータが多く含まれている可能性が高いと考えられるため、当該サブセットに含まれる画像を GAN の学習に用いる。このようにして、学習しても効果が薄いと考えられるデータセットの学習を省略することで、学習に要する時間を短縮する。

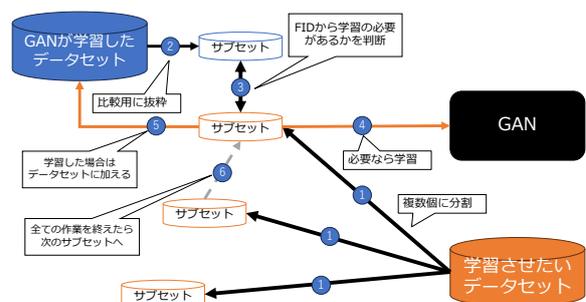


図 1 選別を加えた GAN の学習の流れ

\* Dataset Selection Method based on FID for GAN Additional Training

<sup>†</sup> Keisuke NISHIZAWA, Meisei University

<sup>‡</sup> Yasutaka WADA, Meisei University

この時、既に GAN が学習したデータセットから取り出す画像を複数回変更し、対象サブセットとの FID の平均を代表値として採用し、これを閾値と比較する。FID の計算においては、比較する 2 つのデータセットの間でデータ数に大きな偏りがあると公平な比較ができない。そのため、学習済みのデータセット全体と比較せず、一部を取り出して複数回 FID を計算する。

## 4 StyleGAN を用いた評価

本節では、提案手法を用いて GAN を学習させ、画像生成の品質および学習に要した時間から、提案手法の評価を行う。

### 4.1 評価環境・条件

本評価では、GAN 学習や FID の研究などで広く用いられている FFHQ[2] と CelebA[3] を利用する。また、FFHQ による学習済みモデルが提供されている StyleGAN を対象として、その学習の効果と時間を比較する。

FFHQ による学習済みモデルを基準として、これに CelebA を用いた追加学習を行う。この際、CelebA から 100,000 枚の画像をランダムに抽出しこれを全て学習に用いた場合と、5,000 枚のサブセットに分割し、サブセットごとに提案手法を適用して学習させるかどうかを判断した場合を比較することで、提案手法の効果を検証する。なお、king とは、学習に利用した画像の総枚数のことであり、1king であれば延べ 1,000 枚学習したことになる。この枚数は同じ画像を複数カウントする場合もある。また、提案手法を適用しない場合においては、抽出した 100,000 枚の画像を 1,000king 分学習させる。提案手法を適用した場合においては、学習に用いると判断した際、対照のサブセットに含まれる 5,000 枚の画像を 50king だけ学習させる。

提案手法による選別の際に用いる閾値は、次に示すような 3 つの方法により算出したものを用いた：

1. 7.535 : FFHQ から取り出した重なるの無い画像 5000 枚 2 グループ間の FID
2. 34 : FFHQ で学習済みの StyleGAN を LFW[4] で追加学習して計測した FID の値。
3. 55.965 : FFHQ と CelebA からそれぞれ 5,000 枚をランダムに取り出して求めた FID

提案手法において FID を用いるため、生成画像の評価には、別の評価指標である Kernel Inception Distance (KID) および Inception Score (IS) [5] を用いる。

## 4.2 評価結果

4.1 節で述べた閾値の算出方法により評価を行った結果を表 1 に示す。なお、“選別なし”は対象の 100,000 枚の画像を選別をせず、全て学習に用いる場合を指す。

表 1 StyleGAN による評価結果

閾値算出方法	KID ↓	IS ↑	延べ学習時間 [s]
1	0.01063	4.3352	103,417
2	0.01271	4.3294	41,640
3	0.01479	4.3481	10,428
選別なし	0.00960	4.2605	96,209

手法 1 は精度面では最も高かったが、学習時間では“選別なし”と比較して増加した。一方で手法 2 や 3 では学習時間が大幅に短縮された。手法 1 と 2、手法 2 と 3 をそれぞれ比較すると、KID の変化に対して学習時間の削減量は前者の方が大きい。これらから、閾値の設定方法によってトレードオフを最適化することができるとともに、より適切な閾値を設定できる可能性があると考えられる。

## 5 まとめ

本稿では、FID を用いて学習に用いる画像群を選別することで、GAN の品質を保ちつつ、学習に要する時間を短縮する手法を提案した。StyleGAN を対象とした評価から、学習の要否を判断する閾値により効果のある程度制御し、トレードオフを最適化できる可能性が示された。今後の課題として、学習の要否を判断する閾値の最適化などが挙げられる。

## 参考文献

- [1] Heusel, M. et al.: GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium, *Proceedings of NIPS'17*, pp. 6629–6640 (2017).
- [2] Karras, T. et al.: A Style-based Generator Architecture for Generative Adversarial Networks, *Proceedings of CVPR 2019*, pp. 4401–4410 (2019).
- [3] Liu, Z. et al.: Deep Learning Face Attributes in the Wild, *Proceedings of ICCV 2015*, pp. 3730–3738 (2015).
- [4] Huang, G. B. et al.: Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments, Technical Report 07-49, University of Massachusetts, Amherst (2007).
- [5] Salimans, T. et al.: Improved Techniques for Training GANs, *Proceedings of NIPS'16*, pp. 2234–2242 (2016).