

# 深層生成モデルに対する分類器を用いたファインチューニングと 住宅設計への適用

植田考哉<sup>†1</sup> 瀬尾昌孝<sup>†1</sup> 西川郁子<sup>†1</sup>

**概要:** 生成モデルは、多数の観測データから、そのデータの分布を獲得する教師なし学習器である。近年、深層生成モデルが多数提案されているが、その一つである Generative Adversarial Nets は、潜在変数空間における任意の確率分布からデータを生成する Generator、および、生成されたデータと実観測データとを識別する Discriminator の 2 つのニューラルネットワークが相互に学習することにより、Generator が実観測データの分布を獲得する。本報告では、学習済みの Generator に加えて、データに対する制約条件を学習した分類器を用いることで、条件を満たすデータのみを生成することを目標とし、その学習のためのファインチューニング法を提案する。計算機実験では、三次元構造物である一般住宅の部材配置設計に適用し、提案法の有効性を検証した。

**キーワード:** 生成モデル, Generative Adversarial Networks, 分類器, 建築部材配置設計

## 1. はじめに

Goodfellow ら [1] によって提案された Generative Adversarial Networks(GAN)は、生成モデルの 1 つである。GAN では Discriminator および Generator の 2 つの敵対的なネットワークが相互に学習することによりデータの分布を獲得する。このとき、Generator は、ある任意の分布からデータを生成し、Discriminator は Generator によって生成されたデータと実データとの分布間距離である JS ダイバージェンスを測る機能を担う。また、GAN とは別の分布間距離を使用するモデルとして Arjovsky ら [2] によって提案された Wasserstein GAN が存在する。WGAN では Earth-Mover(EM)距離を Discriminator が測り、Generator は求めた EM 距離を最小化することによりデータの分布を獲得する。

先に報告した研究 [3] では、3 階建て一般住宅の部材配置設計を対象に GAN を用いた配置設計の生成を行った。部材配置設計では柱や梁などの部材を耐震強度などに関わる制約条件を全て満たすように配置しなければならず、これらは全ての部材が揃ったうえで構造計算シミュレーションによって求められる。そのため、建築可能となる部材配置のみを GAN に学習させた場合、必ずしも生成されたデータが建築可能とはならず、不可能なデータも生成する可能性がある。本内容では、これに対し、制約条件の充足を学習した学習済みの分類器を GAN の学習に組み込むことにより、より建築可能なデータのみを生成を目指す。

## 2. Wasserstein GAN

GAN では、データの分布と Generator によって表現される分布との JS 距離を Discriminator が推定する。JS 距離では 2 つの分布の台が重ならない場合、Generator は有用な勾配を得られない場合がある [2]。それに対し WGAN では Earth-Mover(EM)距離を用いることにより前述の問題を解

決している。

WGAN では Generator(写像  $G$ )と Discriminator(写像  $D$ )が以下の min-max 問題を逐次的に解くことにより Generator はデータの分布を獲得する。

$$\min_G \max_D \mathbb{E}_{\mathbf{x} \sim p_{data}(\mathbf{x})} [D(\mathbf{x})] - \mathbb{E}_{\mathbf{z} \sim p(\mathbf{z})} [D(G(\mathbf{z}))] \quad (1)$$

このとき、 $p_{data}(\mathbf{x})$  はデータの分布であり、 $G(\mathbf{z})$  は任意の分布  $p(\mathbf{z})$  から生成されたデータを表している。式(1)を  $D$  について最大化することが EM 距離あるいは Wasserstein 距離を測ることに相当し、求めた距離を最小化するように  $G$  は学習する。なお  $D$  はリプシッツ定数 1 のリプシッツ連続な任意の写像である。

さらに Gulrajani ら [4] はリプシッツ定数 1 の Discriminator の獲得に対して、以下のようなペナルティを加えることにより学習している(以下 WGAN-GP)。

$$\max_D \mathbb{E}_{\mathbf{x} \sim p_{data}(\mathbf{x})} [D(\mathbf{x})] - \mathbb{E}_{\mathbf{z} \sim p(\mathbf{z})} [D(G(\mathbf{z}))] - \lambda \mathbb{E}_{\tilde{\mathbf{x}} \sim p(\tilde{\mathbf{x}})} [\|\nabla_{\tilde{\mathbf{x}}} D(\tilde{\mathbf{x}})\|_2 - 1]^2 \quad (2)$$

ただし、 $\tilde{\mathbf{x}} = \epsilon \mathbf{x} + (1 - \epsilon) \tilde{\mathbf{x}}$ ,  $\mathbf{x} \sim p_{data}(\mathbf{x})$ ,  $\tilde{\mathbf{x}} \sim G(\mathbf{z})$ ,  $\epsilon \sim U[0,1]$  である。

## 3. 分類器による GAN のファインチューニング

GAN の学習では、データの分布を獲得する。そのため学習済みの GAN では、学習データには似た特徴を持つ別のデータを生成する。このとき、設定した条件を満たすデータのみを学習データとして与えても、生成されるデータは必ずしも条件を満たすとは限らない。

そこで、本稿では設定した条件を満たすデータ(OK クラス)に対し、特徴的に似てはいるが条件を満たさないデータ(NG クラス)を 2 クラス分類タスクにより学習した分類器を用いてファインチューニングを行う。つまり、予め生成したい対象を学習した学習済みの GAN に対し、前述の条件で学習した分類器を用いて再度学習する。

<sup>†1</sup> 立命館大学  
Ritsumeikan University




図 1 分類器付き GAN モデル

学習モデルを図 1 に示す. 分類器(図中の Classifier)は OK を 1, NG を 0 とし [0,1] の範囲で出力するものとする. このとき, Discriminator の学習は OK データを用いて, 式(2)に従って学習し, Generator は以下の式(3)に従って学習する.

$$\min_G [-E_{z \sim p(z)} [D(G(z))] + \gamma E_{z \sim p(z)} [\max(T - C(G(z)), 0)]] \quad (3)$$

$\gamma$  はハイパーパラメータ,  $T$  は判定用の閾値である. 式(3)の第 2 項は Generator によって生成されるデータのうち, 分類器(式中の写像  $C$ )による出力が  $T$  を下回る場合についてのみペナルティが発生する. つまり, NG 判定されたデータについてのみ OK 判定となるように学習することになる.

#### 4. 一般住宅の部材配置設計の生成

本章では, 3 階建て一般住宅の部材配置データを用いて, 提案モデルでの検証を行う. 検証では, 提案法によるファインチューニングがある場合と, ない場合の 2 つのモデルに対し, 生成されたデータを構造計算によって評価する. なお, 分類器は部材配置構造の似たデータのうち, 力学的な制約条件を充足するデータと非充足なデータで学習したモデルを使用した.

##### 4.1 対象とする部材配置データ

建物の部材配置設計では, 部屋割り, 階段などの建物外形が与えられた下で柱や梁などの各部材を, 耐震強度を満たすように配置する必要がある. 一般に, 部材を増やすことにより強度は上がるが, 部材コストも増加する. そのため, 強度制約を充足するように部材コストを最小化する, 最適問題として見ることもできる.

学習対象としている 3 階建て一般住宅の部材配置状態は, 15cm 立方の枠内にある部材の体積占有率(部材量)をボックスセル値とした, 幅 35×奥行 81×高 6 のボックスセルデータである. 以下に学習に使用するデータを示す.

- Discriminator の学習: 制約条件を充足する建築可能な部材配置 15000 データ.
- 分類器の学習: Discriminator の学習に用いた 15000 データおよび, 満たさない制約条件が最低 1 つある建築不可能な部材配置 15000 データ. なお, 部材量, 部材配置は建築可能データと似た特徴を持つデータであり, 構造計算上でも同様である.

#### 4.2 生成実験

本実験で使用する学習済み分類器の性能は, テストデータの建築可能, 不可能それぞれ 1000 に対して 91% である. 学習済みの Generator, および, Discriminator は先行研究[2]で学習したモデルとし, Discriminator は建築可能データを用いて, 式(2)で学習し続ける. 同時に, 式(3)により Generator を学習する. 実験では, 分類器によって Generator を学習する場合(各パラメータは,  $\gamma = 0.05$ ,  $T = 0.9$ ). および, 比較用として, 分類器による学習をしない( $\gamma = 0$ )場合の 2 つの設定を用いる. なお, Generator のパラメータ更新回数は 3000 回とする.

図 2 に上記 2 つの設定に対する構造計算結果を示す. 図は Generator を 100 回更新するごとに, 200 サンプル分のデータを生成した中から, 構造計算により建築可能と判定されたデータ数を表している.

結果から, 最大でも分類器ありでは 65 データ(更新回数:2500), 分類器なしでは 66 データ(更新回数:2700)建築可能となり, 分類器を用いた学習による有意な差は見られなかった. このとき, 分類器による建築可能数の割合はそれぞれ 99% と 88% であった. 分類器における可能, 不可能の識別性能は 91% ほどであり, 必ずしも, 構造計算と同等の判別性能を有してはいない. そのため, GAN の学習においても有効な生成結果が得られなかったと考えられる.

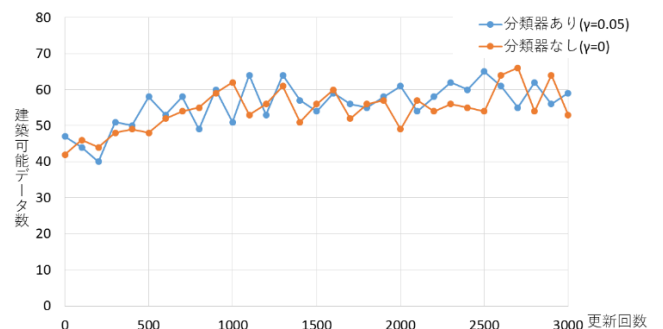


図 2 各学習過程における生成データの構造計算結果

#### 5. おわりに

分類器を用いることにより, 特定の条件のデータのみをより生成できるような Generator の獲得を試みた. 今後は, より条件に即した分類器を用いることにより, 学習の改善を検討する.

#### 参考文献

- [1] Generative Adversarial Nets, Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio, in NIPS 2014.
- [2] Wasserstein GAN, Martin Arjovsky, Soumith Chintala, and Leon Bottou, arXiv:1701.07875v2, 2017.
- [3] 植田考哉, 瀬尾昌孝, 西川郁子. 深層生成モデルとエンコーダを用いた自動修正法および住宅設計への適用. コンピュータショナル・インテリジェンス研究会. 2017.
- [4] Improved Training of Wasserstein GANs, Ishaan Gulrajani, Faruk Ahmed, Martin Arjovsky, Vincent Dumoulin, Aaron Courville, arXiv preprint arXiv:1704.00028, 2017.