

G-006

敵対的生成ネットワークを用いた別モダリティ画像の生成と評価に関する研究

Generation and Evaluation of Another Modality of Medical Images Based on GAN

山嵜 寛門¹ 戸崎 哲也¹ 千田 道雄²
Chikato Yamasoba Tetsuya Tozaki Michio Senda

1. はじめに

現在,医療診断にはCTやPET画像が多く用いられている。双方にはそれぞれ異なった長所,短所が存在し,がん診断などの際には複数の撮像方法で診断することが多い。しかし複数の撮像方法を用いると時間やコストがかかり患者の負担となってしまう。そこで本研究ではCT画像とPET画像間で片方の医療用画像から別モダリティの画像を生成することを目的とする。まず,擬似画像を生成する方法としては敵対的生成ネットワーク[1](Generative Adversarial Network)に着目した。本研究では始めに DCGAN[2]と CycleGAN[3]によって画像生成を行い,後者ではデータセットの変更による精度向上を試みた。その後,画像の差分を可視化するプログラムによって生成画像の評価を行った。

2. 理論

2.1 DCGANについて

DCGANとはGANに対して畳み込みを適用したものである。

このモデルはノイズから擬似的な画像を生成する生成器と入力された画像がサンプル画像なのか生成器によって生成されたものなのかを判別する識別器の2つからなる。生成器は識別器に見破られないような画像を生成することを目標とし,識別器は与えられた画像が偽物か本物かを見破ることを目標とする。そしてその2つを互いに競わせるように学習させることにより生成器はサンプル画像と似たような画像を生成することができるようになり,識別器は画像が本物かどうかを見破ることができるようになる。

2.2 CycleGANについて

CycleGANとはペアとなる訓練データなしにソースドメインからターゲットドメインへの画像の返還を行うことを最終的な目標としたGANである。

CycleGANの論文ではウマの画像をシマウマの画像に変換することや,写真をモネやゴッホなどの画風に変換することに成功している。

3. 実験方法

3.1 DCGAN

DCGANでは用意した128×128[px]の2860枚のPET画像と512×512[px]の2860枚のCT画像を用いた。

また,以下のように設定したHyperparameterによってDCGANの学習を行った。

初期学習率 : 0.0002
慣性項 : 0.5
バッチサイズ : 64

3.2 CycleGAN

CycleGANではCT,MRI合わせて4860枚を訓練用データ,540枚をテスト用データとして用いた。ここでCT画像は256×256[px]のモノクロ画像,PET画像は128×128[px]のカラー画像である。

今回は以下のように設定したHyperparameterによってCycleGANの学習を行った。

初期学習率 : 0.0002
慣性項 : 0.5
バッチサイズ : 1
L1 項の重み : 10.0 use
resnet : True
use lsgan : True

3.3 画像評価

生成した画像と元画像を比較して差分を取り,元画像と同じ部分は黒色,元画像と異なっている部分は白色で表示するプログラムを使い,3.2で生成したCT画像について評価を行った。

4. 実験結果

4.1 DCGAN

3.1に示した条件でCT画像をepoch100まで,PET画像をepoch522まで訓練した。生成された画像を図3.1に示す。

CT画像の生成では,学習を進めるほど精度の高い画像が生成されるようになっていったが,PET画像の生成では学習を進めても精度は向上しなかった。




図3.1 DCGAN を用いて生成した画像の一例

1 神戸市立工業高等専門学校 Kobe City College of Tech.
2 先端医療センター Institute of Biomedical Research and Innovation

4.2 CycleGAN

3.2に示した条件で胸部の画像をepoch16まで訓練した。胸部の画像のepoch16のときと頭部の画像のepoch30の出力画像を図3.2に示す。

胸部の学習ではCT画像は16世代目には骨などの描写は不鮮明であるが、人体の胸部の画像であると判断できる程の精度まで向上していた。PET画像生成では学習を進めると真っ黒の画像が生成されていた。




図3.2 CycleGANを用いて生成した画像の一例

4.3 画像評価

3.3節の方法でCycleGANを用いて生成したCT画像の精度を評価した。

胸部のみの場合のepoch1,12と頭部のみの場合のepoch1,56の評価画像を図3.3に示す。




図3.3 生成画像の評価の一例

5. 評価と考察

5.1 DCGAN

PET画像の生成がうまく行われなかった理由としてはCT画像と比べて元画像にあまり特徴となる部分がなかったからであると考えた。また,DCGANを使用する場合だと実際に医療現場で別モダリティの画像を取得したいときに画像を与えて変換するということができないため,初めから訓練を行わなければならない,本研究の医療画像の撮影時間短縮という目的が達成できないと考えた。

5.2 CycleGAN

PET画像の生成で真っ黒な画像が生成された理由としてはPET画像胸部には色の変化などの特徴が無く,判別器が本物の画像か偽物の画像か判断するのが難しくなったことから成長せず,生成器がどのような画像を生成しても評価関数の値が変化しなくなったからだと考える。

次に頭部の学習では,CT画像生成では学習を続けると鮮明な画像が生成されるようになった。また,PET画像でも位置ごとの色の違いのはっきりした画像が生成されたがそのまま学習を続けると色のついた部分が減り,元画像から離れてしまった。

5.3 画像評価

CycleGANを用いて生成したCT画像を2.3節の方法で評価した。すると,胸部の生成画像の場合では学習が進むにつれて輪郭を捉えることができるように成長した。しかし,内臓の生成精度はあまり向上しなかった。頭部の生成画像の場合は1世代目では生成された画像に色が付いていたため差分画像は大部分が白色になっているが,学習を進めるごとに精度が向上し,誤差の少ない画像を生成できた。画像右上の白い部分が固まっている箇所は訓練に用いたサンプル画像の,撮影時の腕の位置がばらばらであったからだと考えられる。

6. まとめと今後の課題

実験結果よりPET画像の情報量の多い頭部の画像生成では精度の高い画像が生成できたが,情報量の少ない胸部について精度の高い画像生成を行うという課題が残った。本研究ではDCGANとCycleGANを使用した,これらはGANの派生系の中では比較的古いものである。現在ではGANの派生系の論文が多く存在するのでその他の手法を用いて画像生成を行いたいと考えている。

参考文献

- [1] Goodfellow et al.(2014),Generative Adversarial Networks
- [2] Radford et al.(2015),Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks
- [3] Jun-Yan Zhu et al.(2017),Unpaired Image-to-image Translation using Cycle-Consistent Adversarial Networks