

機械学習に基づく PET 像からの疑似解剖画像生成
Generate of Pseudo Anatomical Images using Real FDG-PET Images
Based on Machine Learning

筈見 晃清¹⁾ 戸崎 哲也²⁾ 千田 道雄³⁾
Kousei Tomami Tetsuya Tozaki Michio Senda

1. はじめに

最近, 人間ドッグ等で実施されるがん診断で FDG-PET がよく用いられている. その際, がん診断やインフォームドコンセントにおいては, 組織の活動状況や臓器の詳細な位置情報等の解剖情報が必要となるが, PET 像はあくまで機能画像であるためそれらの情報は含まれていない. このため患者へ症状を説明する際には, 病変の位置等を細かく説明することが不可能である. そこで PET 像から対応する疑似解剖画像を生成することができれば, このような問題点を改善することができると思われる.

本研究では機能画像である PET 像から, 正確な人体の情報を持つ疑似解剖画像を作成することを目的とする. 手法には機械学習として知られる敵対的生成ネットワーク (Generative Adversarial Networks, 以下 GAN と呼ぶ) の一種であり, 画像変換の手法として知られる Pix2pix を用いる. 生成器と呼ばれる Generator と判別器と呼ばれる Discriminator の 2 つが, お互いに競い合う形で学習を進めることからそう呼ばれている. Pix2pix では学習用画像と目標画像の 2 つを設定することで, 目標画像に近い画像を生成できるように学習を進めていく. ここでは人体の頭部のみに限定することとし, 訓練用画像に濃度情報だけの PET 像, および 3 チャンネルに分解した PET 像, 目標画像に実際の解剖画像, それぞれを Pix2pix に適用することで疑似解剖画像を生成し, その評価を行う.

2. 研究内容

2.1 学習用画像の作成

はじめに学習用画像の作成を行なった. 本来の PET 像は 4 バイトの分解能を有しているため, 最初に 3 バイトと 1 バイトの画像に変換した. その後 3 バイトの画像にカラーマップを使用することで 3 種類の 3 チャンネルの画像, 1 バイトの画像に反転処理等を行うことで 2 種類の濃度情報だけの画像を作成し, 合計 5 種類の学習用画像を PET 像より作成した. 目標画像は実際の解剖画像を利用する. 図 1 に作成した学習用画像と目標画像を示す.





図 1 学習用画像(a)-(e)と目標画像(f)

図 1(a)~(c)の 3 チャンネルの画像を作成するには独自の RGB カラーマップを作成し使用した. パターン 1 の画像を作成する際に, R, G, B それぞれに設定した式を以下に示す.

$$\begin{cases} R = 255 \times (0.5 + \frac{3}{4} \pi + x) \\ G = 255 \times (0.5 + 0.5 \sin \frac{x}{2}) \\ B = 255 \times (0.5 + \frac{11}{86} \sin x) \end{cases} \quad (2.1)$$

パターン 2, パターン 3 の R, G, B の式については上式 (2.1) の右辺を入れ替えたものである. パターン 2 の場合を式 (2.2), パターン 3 の場合を式 (2.3) として以下に示す.

$$\begin{cases} R = 255 \times (0.5 + \frac{11}{86} \sin x) \\ G = 255 \times (0.5 + \frac{3}{4} \pi + x) \\ B = 255 \times (0.5 + 0.5 \sin \frac{x}{2}) \end{cases} \quad (2.2)$$

$$\begin{cases} R = 255 \times (0.5 + \frac{11}{86} \sin x) \\ G = 255 \times (0.5 + 0.5 \sin \frac{x}{2}) \\ B = 255 \times (0.5 + \frac{3}{4} \pi + x) \end{cases} \quad (2.3)$$

今回の R, G, B のそれぞれの式に使用したパラメータは経験値に基づいて設定した. ここで x は本来の PET 像の各画素の 4 バイトの分解能までの濃度値を $0 \sim 2\pi$ の範囲に縮小した値である. これを用いることで図 1 の (a)~(c) の画像を作成した.

2.2 評価方法の設定

評価方法には, 生成した疑似解剖画像と目標画像の相関値, 差分画像を参考とする. 相関値の算出方法は, テンプレートマッチングの手法の 1 つである ZNCC (正規化相互相関: Zero-mean Normalized Cross-Correlation) を使用する.

1) 神戸市立工業高等専門学校 電気電子工学専攻
2) 神戸市立工業高等専門学校 電子工学科
3) 先端医療センター

画像が全く異なる場合は 0 を、何かしらの相関がある場合は 0 以外の $-1 \sim 1$ の範囲で値を出力する。差分画像の作成は疑似解剖画像、目標画像の 2 つを国際規格の 1 つである BT. 601[1]の変換式より輝度値を算出してグレースケール化した後に、2 つの画像の差分の絶対値を画像の各画素に代入することで作成する。この差分画像はピクセルごとの輝度値の差がない、つまり黒一色の差分画像であるほど目標画像との類似度が高いと言える。

2.3 評価

作成した 5 種類の学習用画像 100 枚を入力画像として epoch 100 ~ 500 の範囲で Pix2pix にて各パターンで学習を行う。テスト用画像は輪郭の形や色付けなどを変化させた描き方の異なるスケッチ画像を 10 枚用意した。これを用いることで入力画像の違いと、スケッチ画像の違いによる生成された疑似解剖画像の変化について調べる。以下に作成した手書きのスケッチ画像を図 2 に示す。



図 2 手書きのスケッチ画像

学習後、生成した疑似解剖画像と目標画像から先述の評価方法にてそれぞれの画像で評価・考察を行う。

3. 研究結果

Pix2pix での学習結果から生成された疑似解剖画像は目標画像との違いがあったことに加えて、それぞれの場合で目視でも確認可能なほど実際の解剖画像とは類似度の異なるものが生成された。この結果より入力画像が異なると学習のパフォーマンスは変化することがわかった。それぞれの入力画像の場合で描き方の異なるスケッチ画像 10 枚から生成した疑似解剖画像の一例を図 3 に示す。

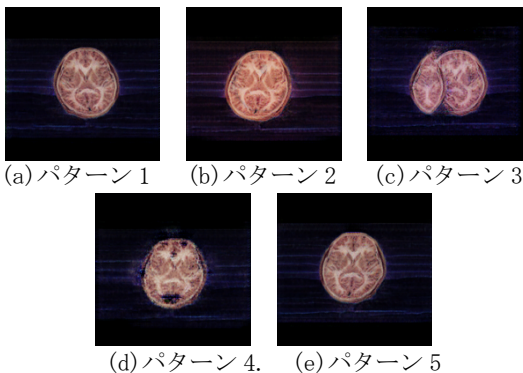


図 3 スケッチ画像から生成された疑似解剖画像

図 3 よりパターン 1、パターン 2、パターン 5 から作成された疑似解剖画像は目視で確認する中で、目標画像との類似度が非常に高いように感じた。反対にパターン 3 から生成された疑似解剖画像は脳組織のようなものが分裂して 2 つできているように見え、パターン 4 から得られたものはノイズが混じっているように感じた。このことから、入

力画像と似たテスト画像から生成された疑似解剖画像や、使用されている色の数が多い入力画像から生成された疑似解剖画像は目標画像と非常に似たような画像になるという結論を立てた。

次に疑似解剖画像を定量的に評価するため、図 3 の画像と目標画像から相関値の算出、差分画像の作成を行った。最も高い相関値は 0.657205、最も低いもので 0.00024 という値を得た。相関値の最も高い場合と低い場合で、作成した差分画像を図 4 に示す。



(a) 高い相関値の場合 (b) 低い相関値の場合

図 4 差分画像

上の差分画像より左のような類似度の高いものは黒に近く、右のような類似度の非常に低いものでは白い部分が多い、異なる像が出来上がっていることから目標画像とは大きく異なるものが生成されていることがわかる。

4. 考察

入力画像と同じようなテスト画像から生成されるものや、入力画像に使用されている色が多いほど目標画像との類似度が高くなるという結果を得た。これは Pix2pix における Generator, Discriminator に使用されている技術、PatchGAN, U-net[2]が影響を与えていると考えられる。PatchGAN は入力画像を小さなパッチ、つまりは小領域に分割しパッチごとに学習を行うことで学習の精度の向上につながり、U-net は多重フィルタ構造から構成されることで、より詳細に画像の情報を読み込むことができる。この時、学習される情報として各画素の輝度値・物体の位置情報などが挙げられる。この輝度値・物体の位置の情報が似ているものはテスト用画像でも順応することが容易となり、また使用されている色の種類が多いほど学習画像のパターン化によって引き起こされる過学習を抑制できると考えられる。よってこれらの条件を満足している入力画像から生成される疑似解剖画像の精度の向上に繋がっていると考えた。

5. まとめ

生成された疑似解剖画像の精度は全体的に高いとは言えないものであった。類似度向上の 1 つの方法としてはカラーマップの改良を行うことで学習用画像に使用される色の幅を大きくすることができると考えられる。またどのような画像の場合でも正確に所望の画像が得ることができるように改善する必要があると感じた。また使用している Pix2pix のアーキテクチャをさらに解析して理解を深め、内部のネットワーク構造の変更などといった異なる手法による検討を続けていく予定である。

参考文献

- [1] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks", IEEE Conference on Computer Vision and Pattern Recognition (2017)