

敵対的生成ネットワークを用いた水増しによる CT 画像中の肺結節の良悪性鑑別性能の向上

平野 靖^{*1}, 濱口 拓真^{*2}, 石田 博^{*1}

^{*1} 山口大学 医学部附属病院 医療情報部, ^{*2} 山口大学 大学院創成科学研究科

Improvement of performance of differential diagnosis for lung nodules by data augmentation using generative adversarial network

Yasushi Hirano^{*1}, Takuma Hamaguchi^{*2}, Haku Ishida^{*1}

^{*1} Medical Informatics and Decision Sciences, Yamaguchi University Hospital

^{*2} Graduate School of Sciences and Technology for Innovation, Yamaguchi University

抄録: Deep Learning によって診断支援システムを構築するためには, 膨大な数の学習データが必要となるが, 膨大な数の適切な医用画像を収集するためには多大な労力が必要となる. 本稿では, Deep Learning を用いて CT 画像中の肺結節の良悪性鑑別を行う際に必要となる学習画像を, 敵対的生成ネットワークを用いて水増しする方法を提案する. 提案手法によって生成された画像を用いて CNN (Convolutional Neural Network) を学習させたところ, 画像処理を用いた水増し手法によって生成された学習画像を用いた場合に比べて正診率が向上することが確認された. また, Geometry Score によって原画像と生成された画像の類似性を検討したところ, 提案手法の方が類似性が高いことが確認された. これにより, 提案手法によって, 原画像と類似した学習画像を生成することが可能であり, 診断支援システムの精度向上に利用できることが示された.

キーワード 敵対的生成ネットワーク, 良悪性鑑別, 肺結節, 胸部 CT 画像, コンピュータ診断支援システム

1. はじめに

近年, Deep Learning を用いた診断支援システムに関する研究が行われており, Deep Learning 以前に比べて, 簡便に高性能なシステムを構築できる可能性が高くなってきている. 一方で, Deep Learning で高性能なシステムを構築するためには, 大量の学習データ(入力データとそれに対する理想的な出力の組)が必要となり, その収集に多大な労力が必要となる. 画像診断支援システムにおいては, 入力画像の平行移動・回転・鏡映などを行うことによって, 画像数を増加させる(水増し)ことによって学習画像の不足を補うことが一般的である. しかし, このような水増しでは, 水増し画像の数に限度があるうえ, 実質的に学習画像の情報量を増加させることはできない. そこで, 本稿では, 敵対的生成ネットワーク(Generative Adversarial Network, GAN)[1]を用いて学習画像を生成する手法を提案する.

2. 敵対的生成ネットワーク(GAN)

GAN は識別器および生成器という 2 つのニューラルネットワークから構成される. 識別器は

入力された画像が本物であるか, あるいは生成器が生成した偽物であるかを正しく鑑別するように学習する. また, 生成器は, 識別器が本物であると判断する偽物の画像を生成するように学習を行う. これら 2 種類の学習を繰り返すことによって, 生成器が生成する画像の質が向上する.

1) DCGANs[2]

画像生成に特化した GAN である.

2) Conditional GANs[3]

分類対象のラベル(良性あるいは悪性)も識別器の入力とする. また, 生成器の入力として生成したい画像のラベルを与えることによりラベルに対応した画像を生成できるようにした GAN である.

3) Unrolled GAN[4]

生成器が同じような画像のみを生成する現象を抑制することを目的とした GAN である.

3. 提案手法

本研究では前述の 3 つの GAN を組み合わせた Unrolled Conditional DCGAN を構築し, 良悪性鑑別用 CNN(Convolutional Neural Network)のための学習画像(CNN 用学習画像)

を水増しする手法を提案する．まず，GAN 用学習画像として，CT 画像から肺結節の最大断面を含むスライスを選択し，肺結節とその周辺を切り出す．生成器にはランダムノイズと生成する画像のラベルを与えて肺結節画像を生成する．識別器には，GAN 用学習画像あるいは生成器によって生成された画像を与え，その画像がどちらであったかを正しく識別するように学習を行う．さらに，識別結果を基に生成器の学習を行う．識別器と生成器の学習を繰り返すことによって，生成器が本物の肺結節画像と類似した画像を生成できるようにする．

4. 実験

実験には，LIDC-IDRI[7]に収録された CT 画像 213 症例(結節数:272 個，良性:272 個，悪性 38 個)を用いた．これらの結節を 3:1:1 の割合で分割し，学習画像(CNN 用および GAN 用)，CNN の最適化結果の検証用および CNN の精度評価用に用いた．提案手法の有効性を確認するために，画像処理によって水増しした場合(従来手法)と，提案手法によって水増しした場合の良悪性鑑別精度を比較した．なお，良悪性鑑別には Optuna[5]によってネットワークの構造を最適化した CNN を用いた．

5. 結果

図 1 に実際の CT 画像と提案手法によって生成された画像の例を示す．従来手法と提案手法によって水増しされた学習画像を用いて CNN によって良悪性鑑別した結果，正診率は前者では 89.2%となり，後者では 95.3%となった．




図 1 実際の CT 画像と生成された画像

6. 考察

原画像と GAN で生成された画像群の類似性を評価するために Geometry Score が提案されており，この値が小さいほど類似性が高いとされる

[6]．原画像と従来手法の水増し画像間，および原画像と提案手法の水増し画像間の Geometry Score を計算したところ，それぞれ 0.002 および 0.001 であった．したがって，提案手法によって生成された画像の方が原画像に近いと言える．

7. 結語

本稿では，CNN による肺結節の良悪性鑑別のための水増し手法を提案した．CT 画像中の肺結節の良悪性鑑別に応用したところ，鑑別精度の向上が確認された．

参考文献

- [1] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, et al.: Generative adversarial nets, Advances in neural information processing systems 27, 2672-2680, 2014
- [2] Alec Radford, Luke Metz, Soumith Chintala: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, ICLR2016, 2016
- [3] Mehdi Mirza, Simon Osindero: Conditional generative adversarial nets, arXiv: 1411.1784, 2014
- [4] Luke Metz, Ben Poole, David Pfau, et al. : Unrolled Generative Adversarial Networks, ICLR2017, 2017
- [5] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, et al.: Optuna: A next-generation hyperparameter optimization framework, 25th ACM SIGKDD, 2019
- [6] Valentin Khrulkov, and Ivan Oseledets: Geometry Score: A Method for Comparing Generative Adversarial Networks, ICML2018, 2018
- [7] Armato SG III, McLennan G, Bidaut L, et al.: The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans. Med Phys 38, 915-931, 2011