

TSUBAME 共同利用 平成 30 年度 学術利用 成果報告書

利用課題名 機械学習を用いた逆問題解析の研究
英文: Analysis of inverse problem by using machine learning

利用課題責任者: 水澤 悟
First Name Surname: Satoru Mizusawa

所属: 電気通信大学
Affiliation: The University of Electro-Communications
URL: <https://www.uec.ac.jp/>

邦文抄録(300 字程度)

近年 X 線 CT(Computed Tomography)の再構成の方法として、X 線の投影密度を少なくできる逐次近似法が研究されてきた。逐次近似法には患者の負荷を低減でき、ノイズやアーティファクトを少なくできるといった特徴がある一方、再構成に時間がかかるという特徴があり、クリニカルユーズに耐えられるように、再構成時間を短くする研究がされてきた。

一方ディープラーニング技術の進展により、CNN を使った画像の高画質化の研究が盛んに行われており、ノイズリダクション、単一画像超解像、セグメンテーションなどで効果をあげている。ディープラーニングは、簡単に高精度なモデルが構築できるといった特徴がある一方、ラベル付きの学習用画像を多く用意しなくてはならない。

我々は Stacked U-Net というモデルを利用することで、医療用画像なしに、自然画像から復元用のモデルを学習した。この結果、アーティファクトとノイズが少ないモデルを作成できた。

英文抄録(100 words 程度)

Recently the, reconstruction of Computed Tomography by iterative methods were developed for reducing patients dose level. The iterative methods characterized by low noise and low artifacts. But it takes much reconstruction time.

On the other hand, the deep learning technique is achieved good results in the noise reduction, super resolution and segmentation domains of image processing. The deep learning can create high accuracy model easily. But it needs many labeled image for training.

We create reconstruction model by using natural images without medical images. As a result, we get low noise, and low artifact reconstruction time model.

Keywords: deep learning, reconstruction, inverse problem, computed tomography, U-Net

背景と目的

X 線 Computed tomography(CT)の再構成は、物体への様々な角度の x 線陽子の透過を検出器で捉えた“投影画像”を元に、物体の断面画像を復元する。

X 線の再構成の方法としては FBP 法に代表される直接法や、MLEM 法に代表される逐次近似法があるが、直接法に比べて X 線の投影密度を少なくできる逐次近似法が近年研究されてきた。逐次近似法には患者の負荷を低減でき、ノイズやアーティファクトを少なくできるといった特徴がある一方、再構成に時間がかかるという特徴があり、クリニカルユーズに耐えられるように、再構成時間を短くする研究がされてきた。

一方近年ディープラーニング技術の進展により、CNN を使った画像の高画質化の研究が盛んに行われており、ノイズリダクション、単一画像超解像、セグメンテーションなどで効果をあげている。

再構成においてもディープラーニングを用いて画像を復元する方法が研究されている。Jin らは CT 画像の再構成に FBP 法と U-Net と残渣学習を組み合わせ適用し、FBP 法により生じたアーティファクトとノイズを低減し既存手法より優れた結果を出した。

ディープラーニングを用いたモデル学習では精度を確保するために多数の学習用画像を用意する必要があるが、医療用画像は患者のプライバシーの観点や病気

の希少性により、多数の学習用画像を用意できないといった問題がある。

YangらはMRI画像の再構成にGANを適用し、サンプル数が少ない状況でも復元ができることを示した。

我々はStacked U-Netというモデルを利用することで、医療用画像なしに、自然画像から復元用のモデルを学習した。この結果、アーティファクトとノイズが少ないモデルを作成できた。

概要

今回作成したStacked U-Netの構造は図1に示す通りである。基本構造はU-Netと同じであるが、違う点を挙げると、閾値関数にはeReluを使用しており、max poolingではなくstride2の2x2 Convolutionにしており、それを6段繋げている。(図2)。



図1 提案 U-Net の構造

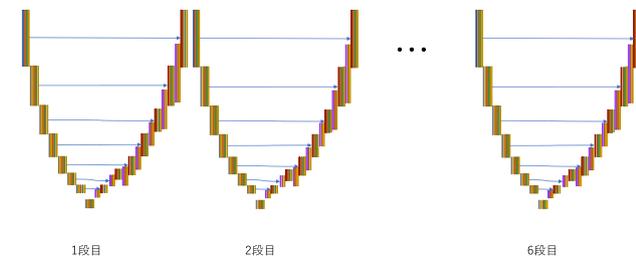


図2 Stacked U-Net

訓練データはImage Net から 28463 枚を training set に 1537 枚を validation set に使用した。test set としては[1][2]を使用した。それぞれのデータは 512x512 に線形補間で scale したのちに、円形に cropping し出力画像とし、出力画像を元に scipy の radon 関数を使用し投影画像を生成し入力画像とした。

学習環境としては Intel Xeon E5-2680 v4 2.4GHz × 2CPU 14 コア / 28 スレッド × 2CPU Memory 256GiB GPU NVIDIA TESLA P100 for NVlink-Optimized Servers × 4 を使用した。学習時間は 4GPU 動作で 85 時間だった。

結果および考察

図3に今回の学習したモデルの出力結果を示す

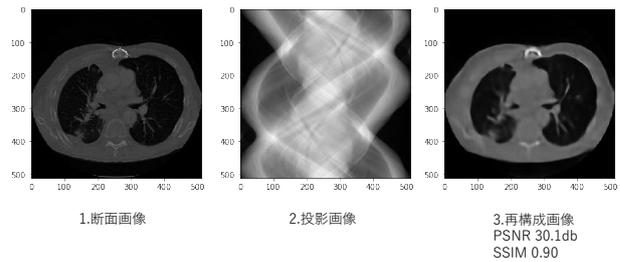


図3 学習済みモデルでの再構成結果

再構成は断面画像[1][2]をもとに投影画像を作成し、それを入力として学習済みモデルに入力し再構成画像を生成し評価を行った。断面画像を正解とした時の PSNR は 30.1db SSIM は 0.90 だった。

まとめ、今後の課題

作成したモデルは学習用の医療用画像なしに作成でき、512x512 の断面画像を復元ができる。

ただ、現状のモデルは FBP 法に U-Net を組み合わせたモデルと比べて PSNR が劣っており、精度向上が課題である。今後学習用画像の増加や、医療用画像を学習用画像に少し混ぜるなどを行い精度を上げていく必要がある。

References.

- [1] Albertina, B., Watson, M., Holback, C., Jarosz, R., Kirk, S., Lee, Y., ... Lemmerman, J. (2016). Radiology Data from The Cancer Genome Atlas Lung Adenocarcinoma [TCGA-LUAD] collection. The Cancer Imaging Archive. <http://doi.org/10.7937/K9/TCIA.2016.JGNIHEP5>
- [2] Clark K, Vendt B, Smith K, Freymann J, Kirby J, Koppel P, Moore S, Phillips S, Maffitt D, Pringle M, Tarbox L, Prior F. The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository, Journal of Digital Imaging, Volume 26, Number 6, December, 2013, pp 1045-1057. (paper)