

U-Net を用いた脳血流 SPECT の減弱補正手法

Attenuation Correction of Brain SPECT using U-Net

大和 龍平 *1
Ryuhei Yamato村田 泰輔 *2
Taisuke Murata黒澤 隆那 *2
Ryuna Kurosawa太田 丞二 *2
Joji Ohta堀越 琢郎 *3
Takuro Horikoshi横田 元 *3
Hajime Yokota森 康久仁 *4
Yasukuni Mori須鎗 弘樹 *4
Hiroki Suyari*1 千葉大学 工学部情報画像学科
Faculty of Engineering, Chiba University*2 千葉大学 医学部附属病院放射線部
Dept. Radiology, Chiba University Hospital*3 千葉大学 医学部附属病院放射線科
Dept. Radiology, Chiba University Hospital*4 千葉大学 大学院工学研究院
Graduate School of Engineering, Chiba University

SPECT is known to be one of nuclear medicine examinations. The attenuation problem in SPECT, the loss of detection of true coincidence events, increases image noises. The attenuation correction using CT is highly effective, but radiation exposure to patient cannot be avoided. In this paper, we propose a method to reproduce the attenuation correction using machine learning only instead of CT. For this purpose, we prepare one pair of SPECT images per one patient, uncorrected SPECT image and corrected SPECT image using CTAC. In our proposed method, the former image is given as input and the latter teacher image for the machine learning. Our method successfully obtains the attenuation correction in SPECT image as almost same as CTAC by using machine learning only.

1. はじめに

近年、我が国では高齢化に伴い、認知症等の脳の変性疾患が増えている。これらの脳機能の診断として核医学検査が用いられる。核医学検査のひとつに SPECT (Single Photon Emission Computed Tomography) がある。SPECT は放射性医薬品を体内投与し、薬剤が発するガンマ線の分布を測定することで機能、代謝、あるいは血流の測定を行う。特に認知症において、SPECT は疾患の早期発見や認知症のタイプの識別、進行度の評価に貢献している。

SPECT の撮像では、ガンマ線と人体組織の相互作用によって、吸収と散乱が起こり正確な放射分布が得られない。このような吸収と散乱による画質劣化を補正するために様々な手法が存在する。劣化因子の内、体内臓器によって吸収された光子数の補正を減弱補正 (Attenuation Correction; AC) [須田 14] と呼ぶ。減弱補正の主な手法として、Chang 法 [Chang 78] や CTAC (CT-based Attenuation Correction) [Tonge 05] 法がある。CTAC 法は優れた補正手法である一方、CT 撮影における放射線ばくによる健康被害が懸念される。また、CT 一体型の SPECT 装置は高価であり、導入へのコストもかかる。Chang 法は CT が不要であり処理も高速であるが、精度はあまり高くない。そこで、本研究では深層学習、特に画像の生成やセグメンテーションに特化した U-Net を用いて CTAC 法による減弱補正の再現を検討する。機械学習によってソフトウェア的に減弱補正を行うことが可能であれば、CT による放射線ばくを抑えることができ、また CT が撮影できない SPECT 装置でも利用可能であるため大きくコストを抑えることができると考えられる。

2. 提案手法

本実験では、CTAC 法によって補正された SPECT 画像 (CTAC) と補正する前の元画像 (NAC: Non Attenuation Correction) のセットを用いて機械学習を行う。ネットワークの教師として CTAC 画像、ネットワークの入力として NAC 画像を与え、入力画像が教師画像に近づくように学習させることで、CTAC の補正アルゴリズムを学習できることが期待される。

本研究ではモデル構造として U-Net を利用した。U-Net は、[Olaf 15] で提案された深層学習モデルである。目的関数は教師画像と入力画像の MSE (Mean Squared Error) に変更した。オプティマイザは Adam を用いて、各パラメータはそれぞれ $lr = 0.001, \beta_1 = 0.9, \beta_2 = 0.999$ とした。

3. データセット

学習に用いるデータセットは、千葉大学附属病院において撮影された、脳血流 SPECT49 症例を OS-EM 法 [横井 01] によって再構成した画像 (NAC) とその画像に CTAC 法によって減弱補正を行った画像のペアである。これらの画像を用いた研究は千葉大学医学部附属病院臨床研究倫理審査委員会の承認を得ている。データの形式は DICOM で、脳の水平面のマトリクスサイズは 64×64 、垂直方向のマトリクスサイズ (スライス枚数) は患者によって 35~45 枚であり、数枚のばらつきがある。また散乱補正はどのデータに対しても適用していない。疾患の有無や疾患の種類については、数に偏りがあるため考慮しなかった。比較評価を行うため同画像に Chang 法によって減弱補正を行った画像も用意した。

連絡先: 大和龍平, 千葉大学 工学部情報画像学科, 263-8522 千葉市稲毛区弥生町 1-33, email: ryuhei2537@chiba-u.jp, yasukuni@faculty.chiba-u.jp

表 1: 各実験における NMSE の値

	NMSE
U-Net	$1.05 \times 10^{-2} \pm 3.0 \times 10^{-3}$
Chang	1.47×10^{-1}

4. 実験

4.1 実験条件

本研究では、全 49 症例の中からランダムに 36 症例を訓練データとし、残りの 13 症例を学習監視用のバリデーションデータとして分離した。バリデーションデータはモデルの更新には一切用いず、最終的な学習結果のテストとしても利用する。学習結果はその都度ばらつきが出るため、5 回行った。

4.2 NMSE による定量的評価

定量的評価の指標と式 (1) で表される NMSE(Normalized Mean Squared Error) を計算した。ここで x_i はデータの値、 y_i は基準値である。

$$NMSE = \frac{\sum_{i=0}^n (y_i - x_i)^2}{\sum_{i=0}^n y_i^2} \quad (1)$$

結果を表 1 に示す。U-Net の NMSE の方が既存手法である Chang 法よりも優れていた。

4.3 視覚的評価

共同研究を行っている千葉大学附属病院の放射線技師 1 名が視覚的評価を行った。Chang, U-Net の出力の二種類それぞれの SPECT を CTAC と比較し、CTAC に近い順に順位付けを行った。評価基準は

- ・ CTAC と比べて減弱補正がどの程度綺麗に行われているか
 - ・ ボケたり構造が崩れている箇所がないか
- の二点とする。二種類の画像がどちらの結果かわからない状態で、テスト用のデータ 13 症例に対して順位付けを行った。

結果は U-Net の出力が全ての症例において Chang よりも良い順位となった。また、U-Net による出力は過剰に補正されてしまった部分が見られたがさほど問題ではなく、全体として非常に良好な結果であった。

4.4 視覚的分析

図 1 で各図に線で示した箇所を図 2 にプロファイルカーブとして表わす。図 2 を観察すると、脳の中心部において NAC, Chang, U-Net の中で U-Net が最も CTAC の形状に近いことがわかる。U-Net では、CTAC の 24 ピクセル付近に存在する小さな山が再現できていないが、おおむねの形状を維持して CTAC を再現できている。

5. まとめ

本研究では、U-Net を用いた脳血流 SPECT の減弱補正手法の提案を行った。U-Net による出力は定量的評価と視覚的評価の両方で Chang 法よりも評価が高かった。したがって既存の手法である Chang 法の代替方法としての利用が期待できる。しかし、今回の評価だけでは臨床的な意義の証明は不十分であるため、今後は疾患の種類別に評価を行い補正の精度を検証する必要があるだろう。

また、今回はデータセットも作成する際、疾患の種類やその疾患がデータセットに占める割合について全く考慮しなかった。今後の研究では、疾患の情報も考慮してデータセットを作成し学習に臨みたい。




図 1: プロファイル位置




図 2: プロファイルカーブ

参考文献

- [須田 14] 須田 匡也: 核医学技術の基礎「SPECT 装置による撮像から画像処理まで」, 臨床核医学, p.2(2014)
- [横井 01] 横井孝司: OSEM (ordered subsets-expectation maximization) 法による画像再構成, 日放技学誌, 57(5), pp.523-529(2001)
- [Chang 78] Chang L T: A method for attenuation correction of onnuclide computed tomography, IEEE Transactions on Nuclear Science, 25, pp.638-643(1978)
- [Olaf 15] Olaf Ronneberger, Philipp Fischer, and Thomas Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation, Medical Image Computing and Computer-Assisted Intervention, pp.234-241(2015)
- [Tonge 05] Tonge CM, Manoharan M, Lawson RS, et al: Attenuation correction of myocardial SPECT studies using low resolution computed tomography images, Nucl Med Commun, 26, pp.231-237(2005)