

深層学習を用いたピンホールSPECTシステム における空間分解能の改善

Shimada, Ryo / 島田, 良

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

64

(開始ページ / Start Page)

1

(終了ページ / End Page)

4

(発行年 / Year)

2023-03-24

(URL)

<https://doi.org/10.15002/00026402>

深層学習を用いたピンホール SPECT システム における空間分解能の改善

Improvement of the Spatial Resolution of a Multi-pinhole SPECT System With a Deep Learning Method

島田 良

Ryo Shimada

指導教員 尾川 浩一

法政大学大学院理工学研究科応用情報工学専攻修士課程

A method to improve the spatial resolution of images obtained with a stationary multi-pinhole SPECT system was proposed in this paper. A multi-pinhole SPECT system has an advantage of being able to measure dynamic functions of organs. However, the image quality is very sensitive to a pinhole size. In this work, a deep-learning based method to improve the spatial resolution was proposed, in which the projection images were converted to those measured with an infinitesimal pinhole system. The reconstructed images with the proposed method had significantly higher spatial resolution and reproduced more detailed structures than those with the conventional methods. These results demonstrated the effectiveness of the proposed method.

Key Word : stationary SPECT system, multi-pinhole collimator, deep learning

1. はじめに

単光子放出計算断層映像化法(SPECT:Single Photon Emission Computed Tomography) は、画像診断技術の1つであり、患者に RI(Radioisotope)を標識した放射性医薬品を投与し、コリメータを装着したガンマカメラを用いて体内から放出された γ 線を検出し、体内の放射能分布を画像化することができる。この放射能分布から、血流量や代謝機能などの情報を取得できるため、SPECT は脳血管障害や心疾患の診断に適している。現在の一般的な SPECT 装置は、パラレルホールコリメータを装着した回転型 SPECT システムとなっている。回転型 SPECT システムは、検出器を患者のまわりで、10分から20分ほど回転させることでデータ収集を行う。このデータ収集ではノイズの少ない再構成画像が得られるが、収集時間がかかるため、患者の負担が大きくなるだけでなく、モーションアーチファクトが発生しやすい。そこで現代医学では検出器を回転させない静止型 SPECT 装置の開発が時間情報や臓器の動的機能の計測を目的として進んでいる。この装置はコリメータに複数のピンホールを配置したマルチピンホールコリメータを採用しデータ取得を行うことで様々な角度から検出器に入射する光子を検出できる。これにより、1台の検出器に対し複数の投影を取得することができるため、大幅なデータ収集時間の短縮が可能に

なり、従来の回転型 SPECT 装置では得られなかった血流や臓器の動態情報も取得することが出来るという利点がある [1-2]。しかし、再構成画像の空間分解能はコリメータのピンホールサイズに大きな影響を受けるという欠点が存在する。特に、ピンホール径が 3 mm を超える場合には診断画像は大きく劣化してしまう。従来、空間分解能を改善するために 7-rays 法や 21-rays 法 [3] が広く適用されているが、ピンホールが大きい場合には十分な効果が得られない。そこで我々の研究室では、投影領域での空間分解能を大幅に向上させるデコンボリューションに基づく手法を開発した [2]。しかし、この方法は検出器ごとに正確な PSF を求める必要があることや、デコンボリューション処理に膨大な計算量がかかることなどの欠点がある。近年、深層畳み込みニューラルネットワーク (CNN) が小さな計算コストで画像再構成や雑音除去などの多くの画像処理で優れた結果を示している。そこで本論文では、比較的小さなデータセットで学習可能な U-net [4]、U-net++ [5] を用いて空間分解能を向上させる新たな画質改善手法を提案し、マルチピンホール SPECT 装置での画像再構成シミュレーションにより提案手法の性能評価を行った。

2. シミュレーション方法

本手法の実現性を評価するため、静止型マルチピンホール SPECT システムを用いたシミュレーションを行った。検出器のサイズを 512×256 pixel (ピクセルサイズ: $0.8 \text{ mm} \times 0.8 \text{ mm}$), 検出器の有効面積は $400 \text{ mm} \times 200 \text{ mm}$ とした。コリメータプレートの厚さは 10 mm , ピンホールの直径は 5 mm , ピンホールの数は 11 個であり, 各ピンホールはコリメータプレートの半分の深さにナイフエッジを持つ。ピンホールの開口角は 48 度とした。この 11 個のピンホールは, 対象物の投影像が重ならないように配置した。対象物の中心からコリメータまでの距離は 25 cm , コリメータから検出器までの距離は 7.6 cm であった [1]。以下の図 1 に本研究で用いて静止型 SPECT システムのジオメトリを, 図 2 にコリメータ上のピンホールの配置を示す。




図 1 静止型 SPECT システムのジオメトリ




図 2 ピンホールの配置

再構成領域は $128 \times 128 \times 128$ voxel, ボクセルサイズは $2.0 \text{ mm} \times 2.0 \text{ mm} \times 2.0 \text{ mm}$ とし。ファントムは, Allen Institute for Brain Science が無償で提供する MRI 画像の T2 強調画像 [6] をもとにコントラストの均等化を行った後, 二値化処理を行うことで作成された, 図 3 に示す脳ファントムを用いた。また, ファントム内の光子の輸送にはモンテカルロ法を用いており, 白質, 灰白質から放出する光子数はそれぞれ $1800, 600 \text{ K count / voxel}$ の理想的なカウントを得られる場合と, 光子数をそれぞれ $90, 30 \text{ K count / voxel}$ に限定し現実的な光子数を想定した場合の 2 つの条件でシミュレーションを行った。




図 3 脳ファントム (#64)

また, 検出器を 1 度だけ回転させた準静止型の検出器を想定し, 今回は簡単のため散乱光子を無視し, エネルギー分解能は考慮しなかった。これらの条件で得られた投影に対し深層学習を用いて投影データ上で空間分解能を補正し ML-EM 法で画像を再構成することで再構成画像の空間分解能の向上を目指した。以下の図 4 に本提案手法の概要図を示す。

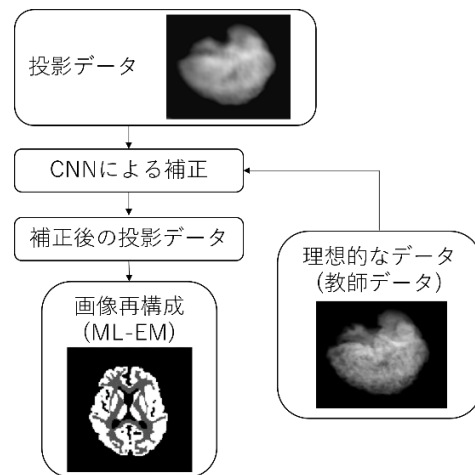


図 4 提案手法の概要

ML-EM 法を行う際の反復回数は 50 回とし, また, 7-rays 法と 21-rays 法を ML-EM 法に組み込んだ再構成画像を比較対象として用いた。

3. ニューラルネットワーク

(1) 学習データ

図 3 に示したファントムを用いて光子輸送シミュレーションを行うことで入力データとなる投影データを生成した。この時に取得する検出器の投影方向数は 18 方向とし, また, すべてのファントムに対して次元空間上でランダムに 6 回回転させることで 6 倍のデータの拡張を行っている。そのため, データセットとなる投影データ全部で 864 枚となっている。そして, このうちの 756 枚を訓練データ, 108 枚をテストデータとして分割した。正規化はそれぞれの投影データに対して上位 97% の画素値で乗算することで行った。これは, 最大値で正規化することで行った。

る統計的な雑音の影響を軽減するための処理である。また、教師データは無限小ピンホール想定した理想的な投影データとした。

(2) U-net の構成

U-net は縮小パス（左側）と拡張パス（右側）で構成されている。左側では 3×3 の畳み込み層に ReLU 関数が続き、 2×2 のマックスプーリング層で 2 回の畳み込み演算ごとに半分ずつダウンサンプリングしている。合計 3 回のダウンサンプリングで入力データは 512×256 [pixel] から 64×32 [pixel] に縮小され、各ダウンサンプリングにおいて、特徴チャンネル数は 2 倍になり、最初の層では 32 チャンネル、最深部の層では 256 チャンネルになる。拡張パスでは、縮小パスと同じ畳み込み演算を行いアップサンプリングによりデータを拡張している。

中央の青い矢印は、特徴マップを結合するためのものである。浅い層の特徴量と高い層の特徴量を結合し、局所の特徴を保持したまま全体的位置情報の復元を可能としている。最後の層は 1×1 畳み込みで、32 チャンネルの層から 2 次元画像の出力に対応させるために用いた。図 5 に本研究で使用した U-net の構成を示す。




図 5 U-net の構成

(3) U-net++ の構成

U-net++ は U-net の派生ネットワークの一種である。基本的な構成は U-net と同じであるが U-Net++ ではエンコーダの各階層から復元した結果を使いデコーダまで畳み込み層をプーリング層で接続している。図 6 に本研究で使用した U-net++ の構成を示す。




図 6 U-net++ の構成

(4) 学習方法

損失関数に平均二乗誤差を、最適化手法に Adam を採用した。結果はバッチサイズ 64、エポック数 10000 の学習パラメータに基づき得られた。

4. 結果と考察

脳ファントム内の白質、灰白質から放出する光子数をそれぞれ 1800, 600K count/voxel とした際の理想的なカウントで得られた再構成画像を以下の図 7 に示す。また、それぞれの再構成画像の PSNR 値を以下の表 1 に示す。




図 7 再構成画像の比較

(上段：訓練データ 下段：テストデータ)

表 1 PSNR 値による数値評価

	7rays	21rays	U-net	U-net++
訓練データ	16.57 dB	17.65 dB	27.33 dB	27.88 dB
テストデータ	15.70 dB	16.86 dB	20.48 dB	20.59 dB

図 7 の再構成画像より無限小のピンホールで得られた理想的な画像に比べ、7-rays 法や 21-rays 法で補正した画像は、ピンホール径の影響を受けかなりぼやけていることが分かる。一方、U-net 及び U-net++ で補正した画像は、訓練データとテストデータの両方で細部の構造を再現しており、理想的な画像に近いことが確認できる。また、PSNR 値も提案手法では訓練データとテストデータの両方で従来手法を上回る結果となった。より詳細な視覚的評価を行うため、図 8 に訓練データにおける再構成画像のプロファイルを示す。図 9 にテストデータにおける再構成画像のプロファイルを示す。プロファイルからも本提案手法による再構成画像は従来手法に比べ理想的な画像とかなり一致していることが確認できる。これらの結果から、投影のカウントが十分な場合には本提案手法は従来手法よりも正確な画像を取得できると考えられる。

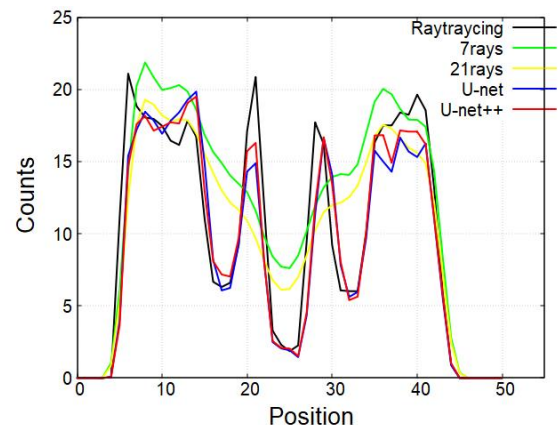


図 8 再構成画像のプロファイル(訓練データ)

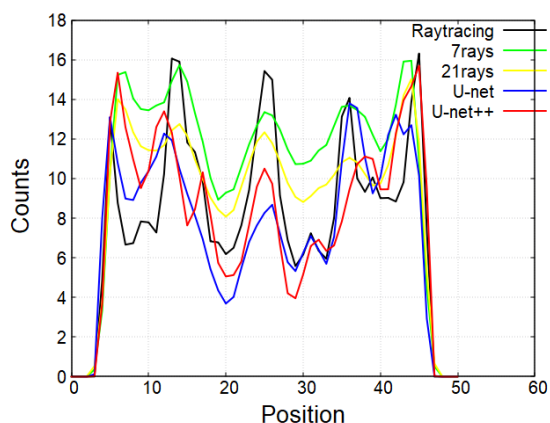


図9 再構成画像のプロファイル(テストデータ)

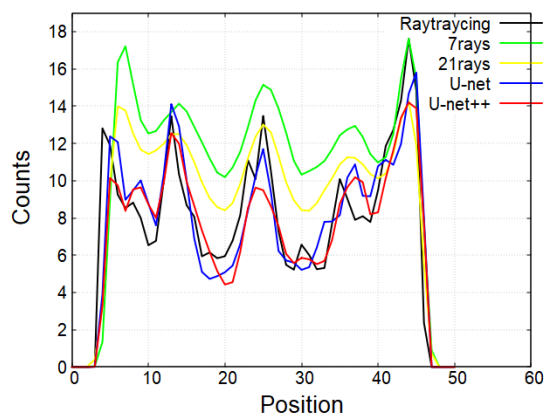


図12 再構成画像のプロファイル(テストデータ)

次に、脳ファントム内の白質、灰白質から放出する光子数をそれぞれ90, 30K count / voxelとしてカウントを限定し、より現実的な条件を想定した場合に得られた再構成画像を図10に、PSNR値を表2に示す。




図10 再構成画像の比較
(上段：訓練データ 下段：テストデータ)

表2 PSNR値による数値評価

	7rays	21rays	U-net	U-net++
訓練データ	16.65 dB	17.70 dB	25.68 dB	26.14 dB
テストデータ	15.67 dB	16.82 dB	17.48 dB	17.92 dB

図10の再構成画像より、本提案種は現実的な条件を想定した場合でもかなり理想的な再構成画像と近いことが確認できる。しかし、PSNR値は従来手法よりも高い値が得られたが、理想的な条件での場合と比べて低下していることが確認できる。図11、図12に訓練データ、テストデータにおける再構成画像のプロファイルを示す。

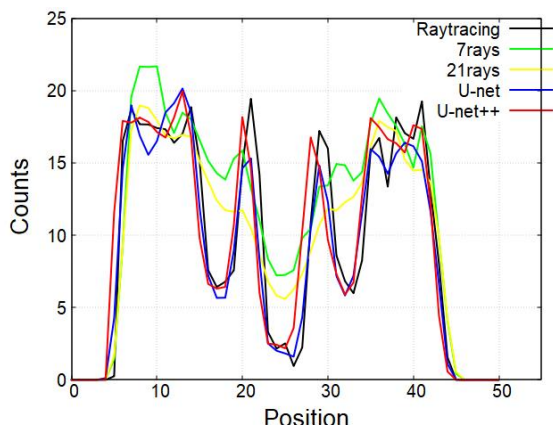


図11 再構成画像のプロファイル(訓練データ)

以上の結果から、提案手法は投影上で雑音が大きくなると学習時に各階層において周波数成分ごとに適切に特徴量を抽出することが難しくなるため雑音の影響を強く受けてしまうと考えられる。しかし、いずれの場合にも本提案手法による再構成画像は、従来手法を用いた再構成画像よりも視覚的また定量的に上回る結果となったことから、現実的な条件を想定した場合でも本提案手法は有用であることが示された。

5. まとめ

本研究では、静止型マルチピンホール SPECT システムにおいて深層学習を投影上で適応し、再構成画像の空間分解能向上させる新たな開口補正法を検討し、その有用性をシミュレーション上で検証した。結果、従来手法と比較して、視覚的・定量的に高精度な再構成画像が取得できることが示された。

参考文献

- 1) Fufishiro Y, Murata K, Motomura N et al: Comparison of a multi-pinhole stationary SPECT system and a parallel-hole high speed rotational SPECT system, IEEE Nucl. Sci. Symp. Conf. Record (NSS/MIC) 2019
- 2) Okoshi M, Murata K, Ogawa K et al: Improvement of the spatial resolution with a deconvolution method for a multi-pinhole SPECT system, IEEE Nucl. Sci. Symp. Conf. Record (NSS/MIC) 2021.
- 3) Andreyev A, Defrise M, Vanhove C et al: Pinhole SPECT reconstruction using blobs and resolution recovery, IEEE Trans. Nucl. Sci., vol. 53, no. 5, pp. 2719- 2728, 2006.
- 4) Ronneberger O, Fischer P, Brox T et al: U-net: Convolutional networks for biomedical image segmentation, Lecture Notes in Computer Science, vol. 9351, pp. 234-241, 2015.
- 5) Zongwei, Z, Mahfuzur M, et al: UNet++: A nested U-Net architecture for medical image segmentation, Deep Learn Med Image Anal Multimodal Learn Clin Decis Support (2018), vol. 11045, pp. 3-11, 2018.
- 6) Allen Human Brain Atlas, "MRI Doner Data," Allen Institute for Brain Science.
https://human.brain-map.org/mri_viewers/data