

法政大学学術機関リポジトリ

HOSEI UNIVERSITY REPOSITORY

PDF issue: 2025-09-03

ニューラルネットを用いたECTにおける2核種 画像の分離

松永, 亜貴夫 / OGAWA, Koichi / Matsunaga, Akio / 尾川,
浩一

(出版者 / Publisher)

電子情報通信学会

(雑誌名 / Journal or Publication Title)

電子情報通信学会技術研究報告. MI, 医用画像 / 電子情報通信学会技術研究報
告. MI, 医用画像

(号 / Number)

342

(開始ページ / Start Page)

25

(終了ページ / End Page)

30

(発行年 / Year)

1999-09-29

社団法人 電子情報通信学会
THE INSTITUTE OF ELECTRONICS,
INFORMATION AND COMMUNICATION ENGINEERS

信学技報
TECHNICAL REPORT OF IEICE.
MI99-30 (1999-09)

ニューラルネットを用いたECTにおける2核種画像の分離

松永 亜貴夫 尾川 浩一

法政大学大学院 工学研究科

〒184-8584 東京都小金井市梶野町3-7-2

0423-87-6215

matunaga@ogw.ei.hosei.ac.jp

あらまし

エミッショントの2核種同時データ収集において困難となっている散乱線推定を3階層型ニューラルネットを用いる事によって実現した。教師データをそれぞれの核種のプライマリ光子数と設定ウインドウ内の全光子数の比率として学習させ、ニューラルネットの重みや閾値を決定した。このニューラルネットによって得られた出力にそれぞれの核種の全光子数を乗じてプライマリ光子数を求めた。シミュレーション結果より2核種同時データ収集におけるニューラルネットワークを用いた正確な散乱線推定が可能であることが明らかになった。

キーワード SPECT, ニューラルネットワーク, モンテカルロシミュレーション, 散乱補正

Separation of Dual-radionuclide SPECT Images

by Using an Artificial Neural Network

Akio MATSUNAGA Koichi OGAWA

Division of Electrical Engineering,
Graduate School of Engineering, Hosei University

〒184-8584 3-7-2 Kajino-cho, Koganei, Tokyo

042-387-6215

matunaga@ogw.ei.hosei.ac.jp

Abstract

In dual-radionuclide Emission CT, it is hard to eliminate scattered photons from acquired data. This paper describes scatter correction method with a three layered Artificial Neural Network(ANN). The learning data consisted of ratios of ratios of primary photons to the total count acquired in a predefined energy windows for each radionuclide. The results of simulation showed the effectiveness of the proposed method.

key words SPECT, Artificial Neural Network, MonteCarlo Simulation, scatter correction

1 はじめに

SPECT(Single Photon Emission CT)では、投与した放射性同位元素の光電ピークを中心とする領域にエネルギー ウィンドウ(20%程度)を設定し、この ウィンドウ内の入射光子を検出しイメージングに用いてる。しかし、核種から放射された光子は、被検体内の媒質とコンプトン散乱を起こし、この散乱光子がデータ収集のためのエネルギー スペクトルに入る。そこで、プライマリ光子の正確な計測が困難となる。この結果、SPECT画像のコントラストや空間分解能は著しく低下する。よってこの散乱成分を除去することは定量的なSPECT画像を得るために必須条件となる。

線源が1種類(単核種)の場合、この散乱線を除去するための手法は幾つか提案されており実際に定量的な散乱線推定が可能となっている。しかしながら、線源が2種類(2核種)で、かつピークエネルギーが近接している場合、従来の手法では散乱線を除去できないという問題があった。これに対し我々はニューラルネットワークを用いることによって2核種の分離と散乱線の除去を可能とした。

ニューラルネットワーク[1],[2]とは、人工神経回路網(Artificial Neural Network:ANN)を意味し、脳における神経細胞の記憶のメカニズムに模してパターン認識を行うものである。ニューラルネットを用いた手法では、そのロバスト性により、ノイズの影響を抑える事ができ、より正確な散乱線の補正ができる。

本論文では、この手法を用いて散乱線補正のシミュレーションを行い、検討を行った。この結果、2核種の場合においても正確な散乱線推定が可能であることが明らかとなった。

2 ニューラルネットワークを用いた散乱線推定方法

散乱線の推定方法の概略を図1に示す。エネルギー スペクトルは、 ^{99m}Tc と ^{123}I を例としたものである。このスペクトルに対し、エネルギー ウィンドウの設定範囲を120～180keVとし、これを6keVずつ10個に分割する。そしてそれぞれの ウィンドウ内の光子のカウントを設定範囲内の全光子収集カウントで割ったものをニューラルネットに入力する。

ここで用いるネットワークは図2に示す階層型ネットワークと呼ばれる3層構造のネットワークで、入力層10個、出力層2個のユニットで構成した。

このネットワークの出力から、プライマリ光子数と設定エネルギー ウィンドウ内の全光子数の比率が

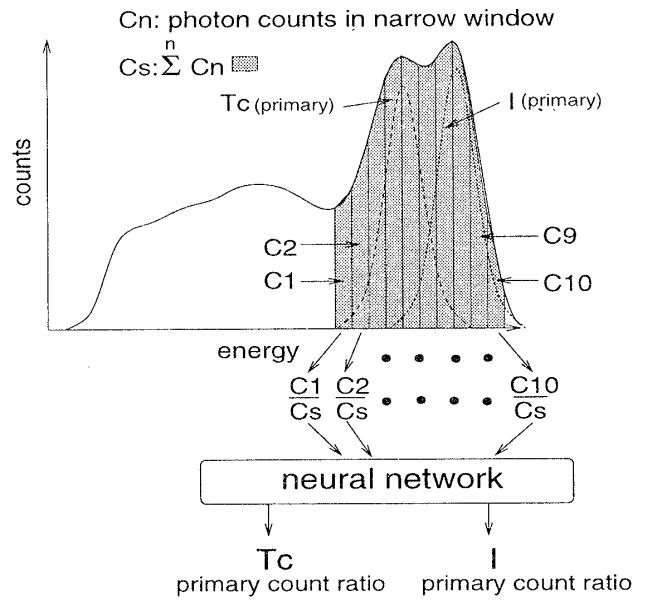


図1: 概略図

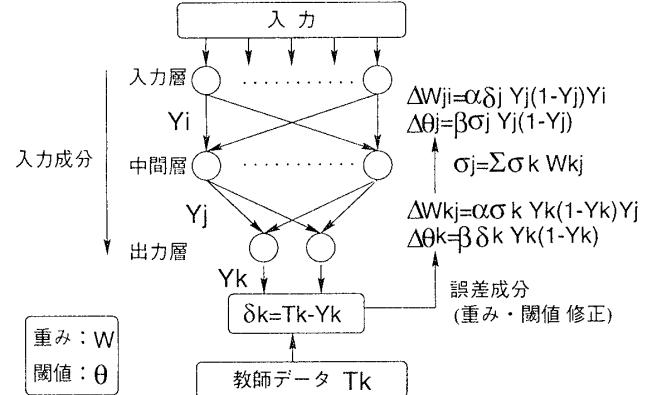


図2: 階層型ニューラルネットワーク

与えられ、この出力に全光子数を乗すればプライマリ光子数が求まる。このニューラルネットを学習させるために、教師データとして入力する各エネルギー ウィンドウ内のプライマリ光子および散乱光子の割合があらかじめわかっている必要がある。そこでモンテカルロシミュレーション[3],[4]を実行し、各エネルギー ウィンドウ内の散乱光子とプライマリ光子の値を計算し、この値を用いてネットワークの重みや閾値を決定した。

教師データの作成に際して、図3のようなファンタムを用意した。このファンタムは半径10cmの無限長の円柱全体に水が入ったものであり、その中心から5cm離れたところに、半径3cmの小円柱があり、放射性同位元素は(a)では外側の円柱に ^{99m}Tc

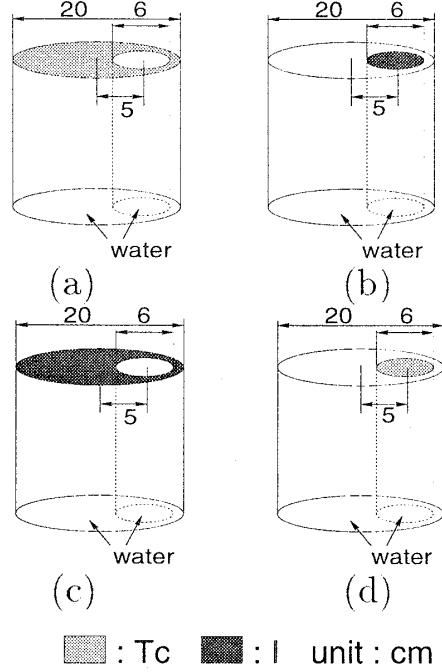


図 3: 教師データ収集に用いたファントム

を, (b) では内側の円柱に ^{123}I を, (c) では, 外側の円柱に ^{123}I を, (d) では内側の円柱に ^{99m}Tc を分布させた. これらのファントムについてモンテカルロシミュレーションを行い得られたエネルギースペクトルのうち, 図 4 に示した 3 つの投影角度で得られるエネルギースペクトル (1 方向あたり 40 個, 計 120 個) のみを教師データとして使用した. これは, この 3 方向 (0, 88, および 268deg.) のエネルギースペクトルがあれば, これらが全方向で得られるスペクトルをほぼ代表していると考えたためである. この教師データを使ってネットワークのパラメータ (重み, 閾値) を修正モーメント法を用いたバックプロパゲーション法によって学習させた. 重み修正係数 α , 閾値修正係数 β は, さまざまなシミュレーションにより, $\alpha = 0.2$, $\beta = 0.2$ と決定した.

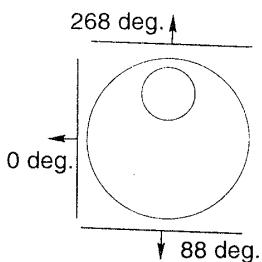


図 4: 投影角度

3 投影データの作成

モンテカルロシミュレーションを実行し, 投影データを作成した. そのシミュレーションの諸条件は以下に示す通りである. 放射性同位元素は ^{99m}Tc (光電ピークエネルギーが 141keV) と ^{123}I (同 159keV) で、光子がファントムの放射線源の部分から等方的に放射されるものとした. また相互作用としては, コンプトン散乱, 干渉性散乱, 光電効果を考慮した. 検出器のモデルとしては, 検出感度, 検出効率ともに 100 % とし, NaI(Tl) シンチレータのエネルギー分解能は ^{99m}Tc に対し, FWHM が 11 % であるものとした. 検出器はファントムの側面から 1cm 離れた位置に置き, 5mm × 5mm の無限小厚のコリメータに上下, 左右 ± 2deg. の角度で入射する光子をカウントした. データ収集マトリクスは 64 × 64 とした. 乱数には Mersenne Twister[8] を用いた. 投影数は 4deg. おきに 90 投影とした.

4 シミュレーション

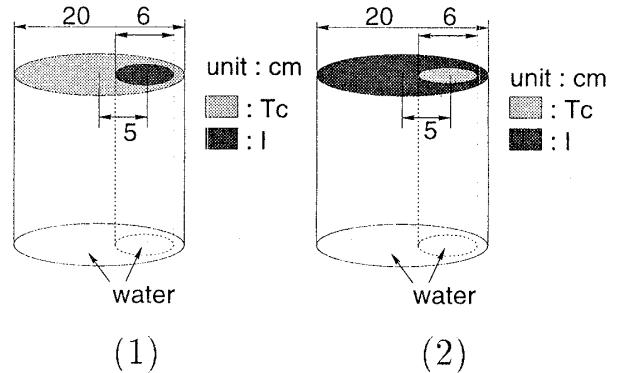


図 5: ファントム

図 5 に示したファントムの投影データの散乱除去を行った. 画像再構成には, Filtered-backprojection 法 [5] を用い, 吸収補正には, Chang 法 [6], [7] を用い, 吸収係数は 0.15cm^{-1} を用いた. ここでは, 次のような条件でシミュレーションを行い、比較, 検討を行った.

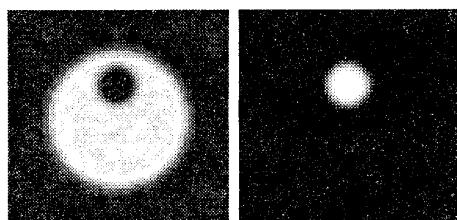
表 1: シミュレーションにおける発生光子数

ファントム (1) : 教師データ (a),(b)		
番号	評価データ	教師データ
A1	^{99m}Tc 10 億, ^{123}I 10 億	(a)10 億,(b)10 億
A2	^{99m}Tc 10 億, ^{123}I 10 億	(a)1 億,(b)1 億
A3	^{99m}Tc 1 億, ^{123}I 1 億	(a)10 億,(b)10 億
A4	^{99m}Tc 1 億, ^{123}I 1 億	(a)1 億,(b)1 億

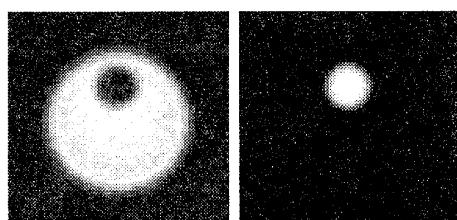
ファントム (2) : 教師データ (c),(d)		
番号	評価データ	教師データ
B1	^{99m}Tc 10 億, ^{123}I 10 儖	(a)10 億,(b)10 儖
B2	^{99m}Tc 10 億, ^{123}I 10 儖	(a)1 億,(b)1 儖
B3	^{99m}Tc 1 億, ^{123}I 1 億	(a)10 億,(b)10 儖
B4	^{99m}Tc 1 億, ^{123}I 1 儖	(a)1 儖,(b)1 儖

5 結果および考察

シミュレーションを行い、比較、検討を行った。まず図5のファントム(1)を散乱補正した結果を図6、プロファイルを図7に示す。



ファントム (1) の原画像
(左: ^{99m}Tc , 右: ^{123}I)



A1 の補正結果
(左: ^{99m}Tc , 右: ^{123}I)

図 6: 原画像と補正画像

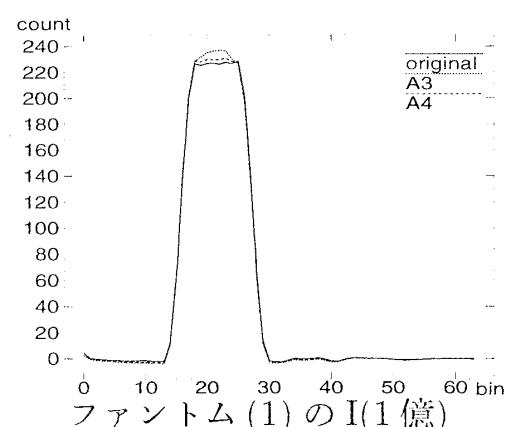
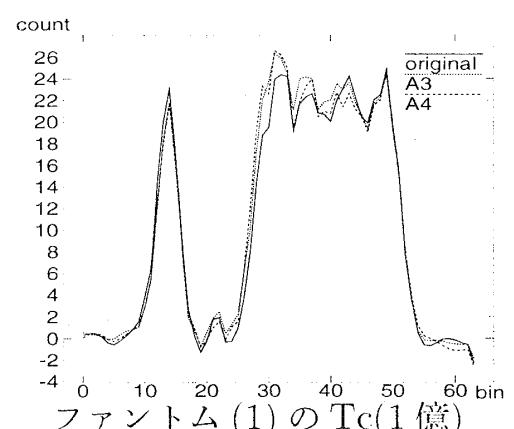
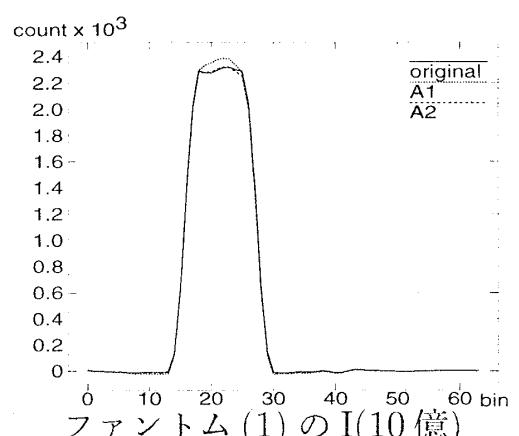
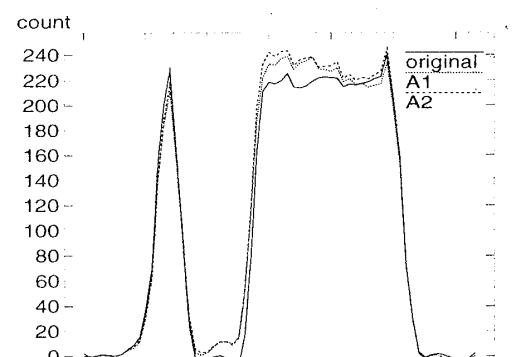
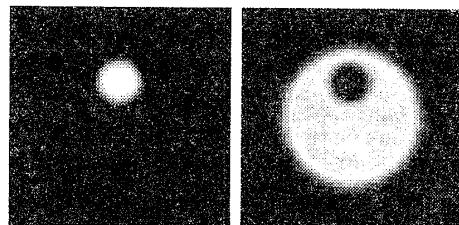


図 7: A1-A4 のプロファイル

図6の上段がファントム(1)の原画像、下段がA1の補正結果である。またここで原画像とはプライマリ光子のみの投影データを画像再構成したものである。これを見ると原画像とほぼ一致しているのが確認できる。

図7はこれらの画像の中心を通る位置で縦に切ったプロファイルである。1段目と2段目は、A1, A2の補正結果のプロファイルを原画像のプロファイルとともに上が ^{99m}Tc 、下が ^{123}I の順に示している。3段目と4段目は、A3, A4の補正結果のプロファイルをA1,A2のプロファイルと同じように示している。発生光子数の密度の高い ^{123}I について見てみるとどれを見てもほぼ正確に補正されているのが確認できる。 ^{123}I に比べて発生光子数の密度の低い ^{99m}Tc を見てみても多少ずれが見られるものの、ほぼ正確に補正できているのが確認できる。

次に図5のファントム(2)を散乱補正した結果を図8に、プロファイルを図9に示す。



phantom (2)の原画像
(左: ^{99m}Tc , 右: ^{123}I)

B1 の補正結果
(左: ^{99m}Tc , 右: ^{123}I)

図 8: 原画像と補正画像

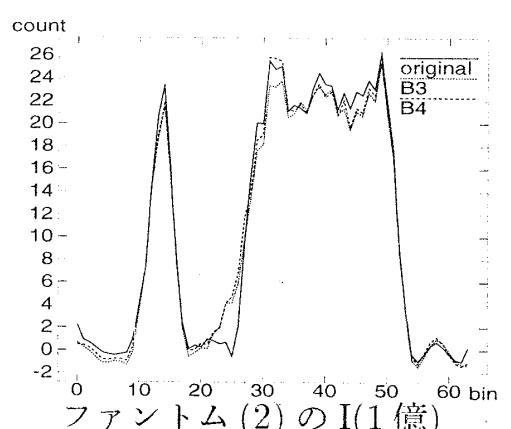
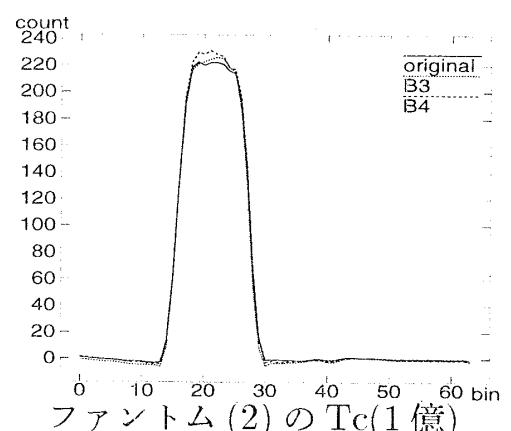
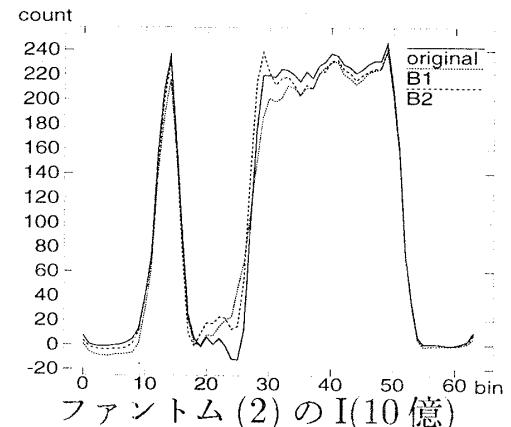
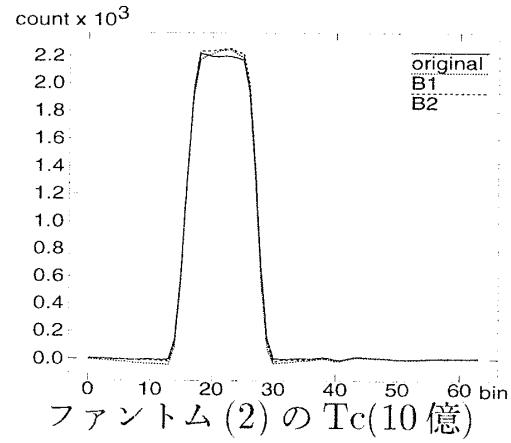


図 9: B1-B4 のプロファイル

図8の上段がファントム(2)の原画像、下段がB1の補正結果画像である。これを見ると原画像とほぼ一致しているのが確認できる。図9はこれらの画像の中心を通る位置で縦に切ったプロファイルである。図9でも図7と同様に発生光子数の密度の高い ^{99m}Tc 、発生光子数の密度の低い ^{123}I に関係なくほぼ正確に補正されているのがわかる。

全体的に見てファントムによって多少原画像の値とずれている部分もあるが、どの補正結果もほぼ原画像と一致していることがわかる。ネットワークの性能については、発生光子数の違う教師データを使用してもそれほど大きな違いは見られなかったので、ファントムが同じか、もしくは似ている形状であれば発生光子数の違いはそれほど重要ではないと思われる。

6まとめ

2核種同時データ収集型SPECTより得られる画像に混入する散乱線を除去するために、ニューラルネットワークを用いた手法を提案し、その性能を発生光子数の違いによるネットワークの汎化性も含めて検討した。この結果、この手法がかなり有効的なものであることが確認できた。

参考文献

- [1] D.E. Rumelhart, J.L. McClelland, R.J. Williams, et. al., "Learnig Internal Representations by Error Propagation," In: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol.1:Foundations.* MIT Press, Cambrige, pp. 318-362, 1986.
- [2] 脇本良則、田中宏一良、藤田啓介、他：“神経回路網の自己組織化” 中野馨編：“ニューロコンピュータの基礎” コロナ社、東京, pp 50-66, 1991.
- [3] D.E. Raeside, "Monte Carlo Principles and Applicalions," *Phys. Med. Biol.*, vol. 21, pp. 181-197, 1967.
- [4] 前田繁、尾川浩一：“モンテカルロ計算の核医学への応用” 日本核医学物理学会第10回研究発表会抄録集：79-80, 1993.
- [5] A.C. Kak, M. Slaney, *Principles of Computerized Tomographic Imaging*, New York: IEEE PRESS, , pp. 49-112.
- [6] L.T. Chang, "A method for attenuation correction in radionuclide computed tomography," *IEEE Trans. Nucl. Sci.*, vol. Ns-25, No. 1, pp. 638-643, February 1978.
- [7] 諸角健、中島真人、尾川浩一、他：“Single Photon Emission CT のための減衰補正法” 電子通信学会誌, J66-D, No.10, 1983.
- [8] M.Matsumoto and T.Nishimura, "Mersenne Twister: A 623-dimensionally equidistributed uniform pseudorandom number generator", ACM Trans. on Modeling and Computer Simulation Vol.8, No.1, Junuary pp.3-30 1998.