法政大学学術機関リポジトリ

HOSEI UNIVERSITY REPOSITORY

PDF issue: 2025-06-01

小動物SPECT画像の二核種分離

MUKAI, Hiroyuki / 向井, 広幸

```
(開始ページ / Start Page)
1
(終了ページ / End Page)
49
(発行年 / Year)
2015-03-24
(学位授与年月日 / Date of Granted)
2015-03-24
(学位名 / Degree Name)
修士(工学)
(学位授与機関 / Degree Grantor)
法政大学 (Hosei University)
```

平成26年度 (2014)

修士論文

小動物SPECT画像の二核種分離 Estimation of Activity in Small Animal Multi-isotope SPECT Study

指 導 教 授

尾 川 浩 一 教授

法政大学大学院 理工学研究科 応用情報工学専攻

th い ひろゆき 13R4134 **向井 広幸**

目 次

	Abstract	2
第1章	はじめに	4
第2章	提案手法	5
2.1	^{99m} Tc خ ¹¹¹ In の同時収集	5
	2.1.1 同時収集の利点	5
	2.1.2 同時収集の問題点	5
2.2	ニューラルネットを用いたプライマリ光子の推定方法	6
	2.2.1 ニューラルネットの構造とパラメータ	6
	2.2.2 エネルギーウィンドウの設定	7
	2.2.3 パラメータとユニット数の決定	8
	2.2.4 学習データ	9
	学習データとして用いるファントムと学習データ作成方法	9
	2.2.5 学習データとして用いる投影データの方向	10
	2.2.6 学習の際の注意	10
2.3	小動物 SPECT でのデータ 収集	18
	2.3.1 NanoSPECT/CT	18
	2.3.2 マルチピンホール	20
	2.3.3 ヘリカルスキャン	20
	2.3.4 画像再構成シミュレーション	21
	シミュレーション条件1	21
	シミュレーション結果1	22
	シミュレーション条件 2	24
	シミュレーション結果 2	$\frac{24}{25}$
		25
第3章	シミュレーション	28
3.1	シミュレーション条件	28
3.2	シミュレーション結果	31
第4章	考察	43
	3次元シミュレーションにおける再構成画像	43
	エネルギーウィンドウについて	43
	投影データについて	44
弗 5 草	まとめ	45

第6章	付録	46
6.1	ニューラルネットワークの理論	46
	6.1.1 ニューロン	46
6.2	学習モデル	47
6.3	単層ニューラルネットワークと多層ニューラルネットワーク	47
6.4	パーセプトロン	47
	6.4.1 基本パーセプトロン	47
	6.4.2 多重パーセプトロン	48
6.5	バックプロパゲーションについて	49
	6.5.1 一般化デルタルール	49
	6.5.2 バックプロパゲーション	51
	謝辞	53
	参考文献	54
	発表論文	55

Abstract

The aim of this study in to measure the distributions of multiple isotopes in small animal SPECT study. In multi-isotope SPECT system, images reconstructed with the counts of primary photons emitted from a low energy photopeak radionuclide is distorted by Compton scattered photons originating in a high energy photopeak radionuclide. In this paper,we applied an artificial neural network method to quantitatively measure the distribution of activities in the simultaneous data acquisition with a multiple isotope SPECT study and the accuracy of our proposed method was evaluated.

第1章 はじめに

現在の医療現場では画像診断方法の一つとして SPECT(single photon emission computed tomography) が用いられている. この SPECT を用いることで. 患者の体内の臓器の機能を非 侵襲的に画像化することができる、これは、病気の早期発見や臨床診断に有用であり、この技 術は重要な役割を担っている. 同様な技術として.X 線 CT がある. これは臓器の形状情報を 得ることが出来るが、SPECTでは臓器の機能情報が見られるという点に特徴がある.これに より、異常が形状として現れる前に、SPECTによる診断でその異常を発見できる。SPECTで は、検査の際に放射性同位元素 (RI) と呼ばれるものを患者の体内に投与する. この RI が対象 臓器に集積し、線を放出する.この 線を検出器で検出し、そのデータを元に画像再構成を 行うことでその分布状況を断層画像とする. この時使用される m RI としてはm c $m ^{99m}Tc$ や $m ^{201}Tl$ な どが一般的である. 通常の SPECT 検査では1種類の放射性核種が用いられるが、同時収集型 SPECT においては、2種類の放射性核種に対する動態を同時かつ同条件で見られることで、治 療方針の最適化や治療効果の評価が可能となる. しかし $,^{99m}\mathrm{Tc}$ と $^{111}\mathrm{In}$ の同時収集 SPECT の 場合, 99m Tc(141[keV])と 111 In(171[keV], 245 [keV])では光電ピークエネルギーが近接している ことや、高い光電ピークエネルギーの影響によって低いエネルギーのプライマリ光子の定量 性が失われてしまい、プライマリ光子の正確な推定が難しいという問題がある.この問題に対 しての有効な手法は、これまで開発されていない、そこで、本研究では 99m Tc と 111 In の 2 種類 の放射性核種を同時収集する SPECT に対し、それぞれの核種の断層画像を別々かつ正確に 再構成することを目的とする.

従来の散乱除去法では、TEW 法などにより散乱線が補正されプライマリ光子の推定が行われている。我々は、ニューラルネットを用いた散乱補正法を 2 核種に適用し、ニューラルネットを用いた 2 核種分離法を 1999 年に提案した [1]. ニューラルネットワークとは、脳神経系を模したモデルでパターン認識を行うものである。 従来のシステムでは、入力に対して、その出力を得るための計算のプロセスを人間が考えなければならない。 しかし、ニューラルネットでは、学習データを与えてやることで、ネットワーク自身が学習を行い出力が得られる。 さらにニューラルネットのロバスト性から雑音に強いという特徴もある。 これらの特徴は、ニューラルネットを同時収集型 SPECT に用いる際に有効であるといえる。 しかし、この手法を 99m Tc と 111 In の 2 核種同時収集型 SPECT に適用しても、前述したような問題によって散乱補正は困難となる。 そこで前述の手法を改良することで 2 核種分離を実現することとした。 さらに、あらかじめ学習させた重みや閾値といったデータを検出器へと組み込むことで、データ収集時に二核種の分離が可能となる。

今回, 小動物 SPECT をターゲットとして二核種分離のシミュレーションを行った. 小動物 SPECT とはその名の通りマウスのような小動物を対象とする SPECT である. 新規の薬剤開発や治療技術の研究などにおいて, マウスをはじめとした小動物実験は非常に重要である. つまり, 小動物 SPECT においてニューラルネットを用いた二核種分離が可能となることは, これらの研究に対し大きい利益がある. そこで本論文では, 実際の機器を想定した条件でのシミュレーションから本手法の有効性を検証した. 対象機器を小動物 SPECT/CT 装置である NanoSPECT/CT とし, データを収集した. その結果, 本手法において 99mTc と 111In を分離し, 別々に再構成することが可能であることが示された.

第2章 提案手法

2.1 ^{99m}Tcと¹¹¹Inの同時収集

2.1.1 同時収集の利点

現在,SPECT における検査では,1度に1種類の放射性核種が用いられるのが普通である.一度に2種類の放射性核種を用いた検査が行えれば,患者の負担軽減や検査時間の短縮といった利点がある.さらに,2種類の放射性核種に対する動態を同時かつ同条件で確認出来るため臨床的にも治療方針の最適化や治療効果の評価が可能となる利点がある.そこで,本研究は1度の SPECT 検査で2種類の放射性核種を用いて,それぞれの分布状況を別々かつ正確に画像再構成し定量化することを目的とした.

本研究では、 99m Tc と 111 In をターゲットとしている。ここで、これらを用いた SPECT 検査において使用される放射性医薬品について説明する。 99m Tc を用いたものでは、 99m Tc-MIBI、 99m Tc-HMPAO、 99m Tc-ECD などが挙げられる。 99m Tc-MIBI は心臓への集積が高いことから、心筋の血流イメージングに用いられる。臨床応用では、心筋梗塞の診断、虚血性病変部位の識別などである。 99m Tc-HMPAO、 99m Tc-ECD は、脳へ集積するため、脳血流のイメージングに使用される。臨床応用では、脳梗塞の診断、クモ膜下出血の診断、モヤモヤ病の診断、脳動脈閉塞および狭窄の診断などである。 111 In を用いたものでは、 111 In-DTPA が挙げられる。臨床応用では、脳髄液腔病変、髄液漏の診断に有効とされる。

2.1.2 同時収集の問題点

 99m Tc と 111 In の同時収集における問題点とは、それぞれの核種の光電ピークエネルギーが近接していることである。仮に同時収集で扱う 2 つの核種の光電ピークエネルギーが離れていた場合ならば、従来の散乱線補正手法である TEW 法などを用いることで、それぞれの核種のプライマリ光子を推定することができる。しかし、 99m Tc と 111 In では、その光電エネルギーのピークが近接しているため、従来のようなエネルギーウィンドウの設定を行うと、 99m Tc と 111 In(171 [keV]) 双方のウィンドウ内に、それぞれのプライマリ光子が混在してしまう。 さらに、 99m Tc と 111 In(171 [keV]) の両方に、 111 In(11

2.2 ニューラルネットを用いたプライマリ光子の推定方法

2.2.1 ニューラルネットの構造とパラメータ

 $^{99m}\mathrm{Tc}$ と $^{111}\mathrm{In}$ の 2 核種同時収集型 SPECT において、それぞれのプライマリ光子を正確に推定するために、我々はニューラルネットワークを用いた 2 核種分離法を提案した。その構造を以下の図に示す。

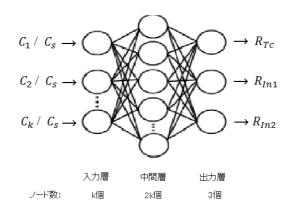


Fig. 2.1: ニューラルネットワーク構造

本手法では、ニューラルネットの入力層の数は設定したエネルギーウィンドウの数とし $3\sim7$ 個設定した、中間層はその2倍の数としている。出力層は $^{99m}\mathrm{Tc}(141[\mathrm{keV}])$ と $^{111}\mathrm{In}(171[\mathrm{keV}],245[\mathrm{keV}])$ の3つとしている。また、提案するニューラルネットに関しての概略図を以下に示す。

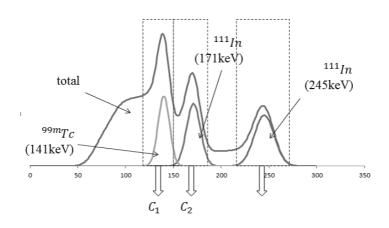


Fig. 2.2: ニューラルネットワーク概略図

ニューラルネットの入力層へ与える入力へは、設定したエネルギーウィンドウ内で測定されたカウントの総和に対する、k番目のエネルギーウィンドウで測定されたカウントの割合で与えられる。また、出力層から得られる出力は、エネルギーウィンドウ内に含まれるそれぞれの核種のプライマリ光子のカウントの割合となる。つまり、この出力に対して、全ウィンドウのカウント総和を乗算することによって実際のプライマリ光子数を推定することが出来る。

これらを式にまとめると、入力 (input data($C_1/C_s \sim C_k/C_s$))、出力 (output data(R_{Tc}, R_{In1}, R_{In2}))、 推定 (Estimation primary counts) の値は以下の式であらわされる. ここで, C_s はカウント総 和, C_k は k 番目のウィンドウ内のカウントを意味している.

$$\frac{C_i}{C_c}(i=1 \sim k) \tag{2.1}$$

$$R_{Tc} = \frac{primary counts of Tc}{C_c}$$
 (2.2)

$$R_{In1} = \frac{primary counts of In1}{C_s} \tag{2.3}$$

$$\frac{C_i}{C_s}(i = 1 \sim k) \tag{2.1}$$

$$R_{Tc} = \frac{primary\ counts\ of\ Tc}{C_s} \tag{2.2}$$

$$R_{In1} = \frac{primary\ counts\ of\ In1}{C_s} \tag{2.3}$$

$$R_{In2} = \frac{primary\ counts\ of\ In2}{C_s} \tag{2.4}$$

$$Estimation of Tc = R_{Tc} * C_s$$
 (2.5)

$$Estimation of In1 = R_{In1} * C_s (2.6)$$

$$Estimation of In2 = R_{In2} * C_s (2.7)$$

2.2.2 エネルギーウィンドウの設定

本研究で設定した 5 種類のウィンドウ (ANN1~5) を以下の図に示す.

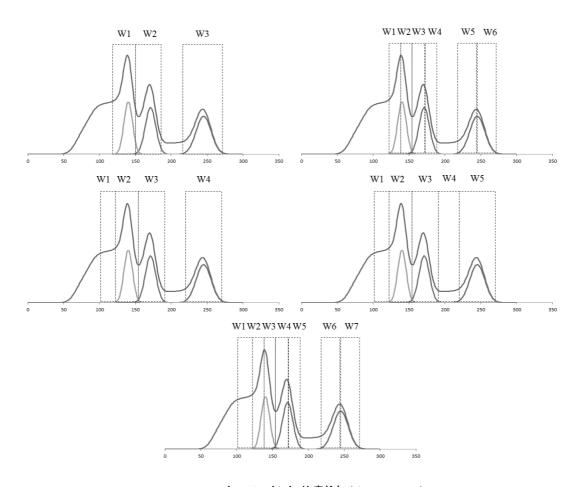


Fig. 2.3: ウィンドウ分割法 (ANN1~5)

また、詳細なエネルギーウィンドウ分割の値を以下の表に示す.

Table 2.1: エネルギーウィンドウ分割表

	ウィン	window1	window2	window3	window4	window5	window6	window7
	ドウ数							
ANN1	3	127 ~ 154	155 ~ 186	220 ~ 269				
ANN2	6	127 ~ 140	141 ~ 154	155 ~ 170	171 ~ 186	220 ~ 244	245 ~ 269	
ANN3	4	99 ~ 126	127 ~ 154	155 ~ 186	220 ~ 269			
ANN4	5	99 ~ 126	127 ~ 154	155 ~ 186	187 ~ 219	220 ~ 269		
ANN5	7	99 ~ 126	127 ~ 140	141 ~ 154	155 ~ 170	171 ~ 186	220 ~ 244	245 ~ 269

我々は、それぞれの核種のピーク値と散乱線に沿って $3\sim7$ 個のウィンドウを設定した。まず、ANN1 ではそれぞれの核種のエネルギーピークに対し FWHM10% の幅をウィンドウ幅とした 3 つのウィンドウを設定した。ANN2 では ANN1 のウィンドウをピーク値でに分割したものをウィンドウ幅とし、6 つのウィンドウを設定した。ANN3 では ANN1 のウィンドウ設定に加え、散乱線を考慮したウィンドウを設定し、4 つのウィンドウを設定した。ANN4 では、ANN3 で設定したウィンドウに加え、さらに散乱線を考慮したウィンドウを設定し、5 つのウィンドウを設定した。ANN5 では ANN3 で設定したウィンドウをピーク値でに分割したものをウィンドウ幅とし、7 つのウィンドウを設定した。

2.2.3 パラメータとユニット数の決定

本手法において、ネットワーク中のパラメータと中間層のユニット数をどのように設定するかという事は非常に重要である。ネットワークの学習にはバックプロパゲーションアルゴリズムを用いている。入力層の数はエネルギーウィンドウ数とし、ネットワーク中のパラメータは、学習係数、ゲインなどである。中間層は入力層の2倍のユニット数とし、学習係数は0.5、ゲインは1.0、学習回数は10万回と設定した。ニューラルネットワークの中で学習係数や中間層などのパラメータについては経験則で決定するのが一般的である。このことから、パラメータを理想的な結果の出力に十分かつ最小の値を経験的に設定した。

2.2.4 学習データ

学習データとして用いるファントムと学習データ作成方法

ニューラルネットワークの構築には、学習データが必要である。そこで本研究では、学習データをつくるために円柱ファントムを用いた。そして、実際の SPECT 検査の際の光子のふるまいを再現でき、プライマリ光子と散乱光子を別々に測定できるモンテカルロシミュレーションを使用した。ファントムは、高さを無限大とする半径 10cm の水で満たされた大円柱の中に半径 3cm の小円柱を左右に並べた。小円柱は大円柱の中心からそれぞれ 5cm ずつ離れたところに置き、それぞれの核種を配置した。各エリアの濃度は一様とし、ファントムの平面から光子を発生させ、相互作用には光電効果とコンプトン散乱を考慮した。

以下に、学習に使用したファントムのジオメトリを示す.

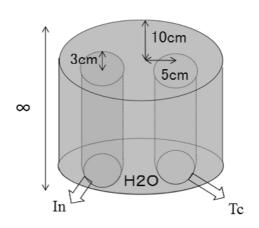


Fig. 2.4: 学習データ作成のためのファントム

さらに、検出器条件、光子発生数、シミュレーション条件を以下の表に示す.

Table 2.2: シミュレーション条件

10010 2.2. 7 ~ _	·
検出器サイズ	40pixel
投影数	90
コリメータ	パラレルホール
エネルギー分解能	10% FWHM
教師信号数	160(40x4)
発生光子数	10 億個
検出器感度	100%
開口角度	± 15 °

2.2.5 学習データとして用いる投影データの方向

まず、2 次元での学習に使用するデータの作成に使用したファントムの図を以下に示す。こ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、以下の図に示される 4 つの投影角度で得られるエネルギースペクトルを教師信号として使用した。エネルギースペクトルは各方向 40 個ずつの計 160 個とした。この 4 方向で全ての方向のエネルギースペクトルのパターンを表していると考えた。

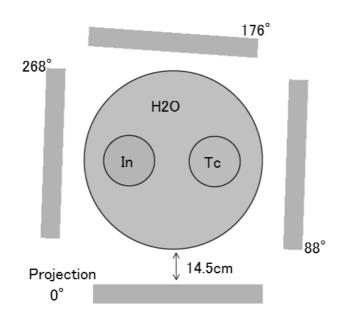


Fig. 2.5: 学習に用いた投影角度

2.2.6 学習の際の注意

本手法における学習の際の注意として、使用するのはデータの存在する部分のみとしなければならない。本論文では、円柱ファントムを用いており、水で満たされた円柱内のみのデータを使用し、円柱外のデータは使用していない。データの存在しない部分を学習の際に含めてしまうのは誤りである。また、本手法において、学習に用いるデータは十分なカウントが必要である。仮に、十分なカウントが用意されていない場合、正確な分離が行われない。

2.3 小動物 SPECT でのデータ収集

小動物 SPECT とは SPECT の中でも小動物を対象としたものである. 新規の薬剤開発や治療技術の研究において, 小動物を使用した実験は非常に重要な役割を持っている. 小動物用 SPECT/CT 装置はさまざまなものが開発されているが, その中でも我々は, 以下の図に示す NanoSPECT/CT を扱った.



Fig. 2.6: NanoSPECT/CT 装置

2.3.1 NanoSPECT/CT

NanoSPECT/CT には 4 つの検出器があり、検出器のサイズは全て $26.5 \times 26.5 \text{cm}$ である。各検出器には、9 つの孔の開いたコリメータが取り付けられている。ピンホールの開口は 1.4 mm であり、コリメータの厚さは 10 mm である。実際に使用されているコリメータを以下の図に示す。

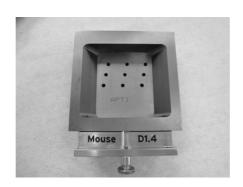


Fig. 2.7: 実際のマルチピンホールコリメータ

また、このコリメータは、物体面とシンチレーション面で穴の位置が異なる。この穴の位置を以下の図に示す。また、この穴の位置の違いより 9 つのピンホールは全て X 方向、Z 方向へ 16.7 °傾いていると考えられる。物体中心とコリメータの距離は $2.5 \,\mathrm{cm}$ であり、コリメータと検出器の距離は $14.5 \,\mathrm{cm}$ である。

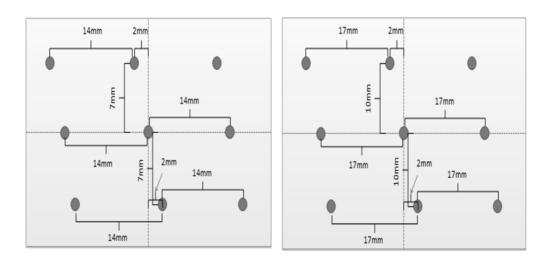


Fig. 2.8: ピンホールの位置 (左) 物体面 (右) シンチレーション面

この装置のピンホールの特徴としては、個々のピンホールから取得される投影データが一部重なりを起こしていることである。実際に収集された投影データを以下の図に示す。これにより、通常の多孔ピンホール以上の感度を可能としているが、これをそのまま再構成した場合アーチファクトの発生がおこる。しかし、実際には、再構成アルゴリズムやコリメータの設計などによりアーチファクトは目立たない。また、データの収集は、らせん状に回転しながらデータを収集するヘリカルスキャンで行われており、長軸 30cm の範囲の撮像を可能としている。収集されたデータは OS-EM アルゴリズムを用いて再構成される。

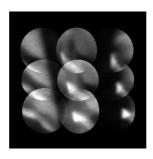


Fig. 2.9: 実際に収集された投影データ

2.3.2 マルチピンホール

ピンホールコリメータを用いることで広い視野角を得ることが出来る。これにより、マウスのような対象の小さい物体を拡大してデータを取得することが出来る。さらに、複数ピンホールコリメータを用いることで、視野を拡大させることができる。これは、機器の小型化という面で人体のような大きい物体に対しても利用されることがある。投影データの取得は、まず検出器の各画素から投影線をピンホールの孔に向かって伸ばしていく。開口角に収まった投影線を再び角度をつけ対象の物体へと伸ばしていき、物体の画素の大きさの間隔でサンプルポイントを取っていく。なお、検出器のピクセルサイズと再構成領域のピクセルサイズは別々に考えることが出来る。

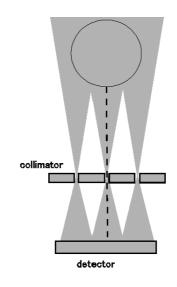


Fig. 2.10: マルチピンホール

2.3.3 ヘリカルスキャン

ヘリカルスキャンは検出器がらせん状に回転しながらデータを収集していく. ノンヘリカルスキャンに比べて走査時間が短縮できるという利点がある. らせん状に回転し, 投影を取っていくので,1 投影ごとに Z 軸をずらしていくことで投影データを収集する.

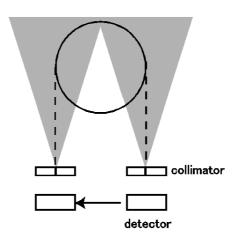


Fig. 2.11: ヘリカルスキャン

2.3.4 画像再構成シミュレーション

シミュレーション条件1

本節では今まで説明してきた条件を元に、実際の NanoSPECT/CT を想定したシミュレーションを行った。そのシミュレーション条件を以下に示す。

Table 2.3: シミュレーション条件

原画像サイズ	128*128*128pixel
検出器サイズ	256x256pixel
ピクセルサイズ	$0.03\mathrm{cm}$
検出器のピクセルサイズ	0.1035 cm
投影数	28(7*4)
1投影の回転量	12.8 °
ピンホール数	9
ピンホールサイズ	0.14cm
開口角	± 30 °
物体中心とコリメータの距離	2.5cm
コリメータと検出器の距離	14.5cm
ヘリカルでの移動量	3mm/step
物体 (shepp) のサイズ	$1.1 \mathrm{cm} / 2.5 \mathrm{cm}$

また使用した原画像も同様に以下に示す。本シミュレーションでは投影データの重なりによるアーチファクトを防ぐため、十分小さい物体 $(1.1\mathrm{cm}\ \mathrm{o}\ \mathrm{Shepp}\ \mathrm{Jr})$ を使用した。また、本章で述べた投影データの重なりによるアーチファクトの確認のため、それよりも大きい物体 $(2.5\mathrm{cm}\ \mathrm{o}\ \mathrm{Shepp}\ \mathrm{Jr})$ でも同様のシミュレーションを行った。

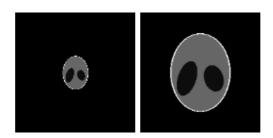


Fig. 2.12: 原画像 (左)1.1cm Shepp ファントム (右)2.5cm Shepp ファントム (slice:64)

シミュレーション結果1

1.1 cm の Shepp ファントムを使用した場合の再構成画像とプロファイルを以下に示す.

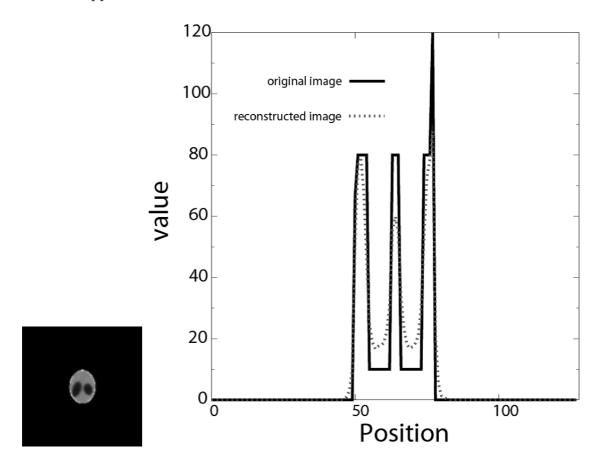


Fig. 2.13: **再構成画像** (slice:64)

また、2.5cm の Shepp ファントムを使用した場合の再構成画像とプロファイルを以下に示す.

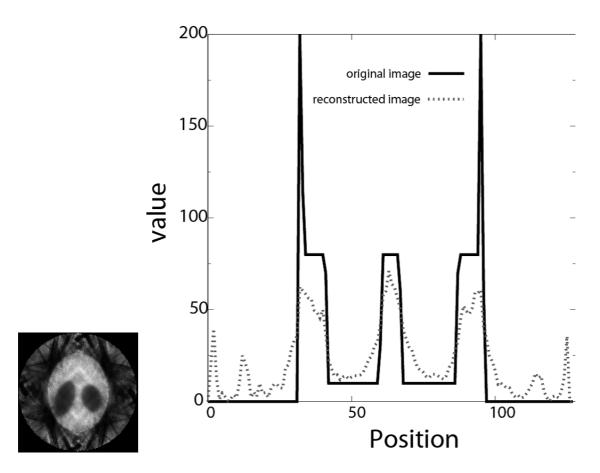


Fig. 2.14: **再構成画像** (slice:64)

ここで,1.1cm のファントムを使用した場合の投影データと 2.5cm のファントムを使用した場合の投影データを比較してみる. それぞれの投影データを以下に示す.

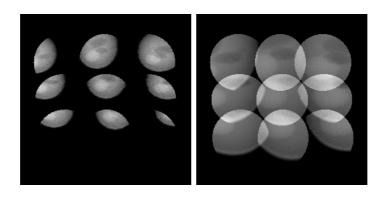


Fig. 2.15: 投影データ (左)1.1cm Shepp ファントム (右)2.5cm Shepp ファントム (angle:102.8)

2 つの画像を比較してみると,2.5cm の方は大きく重なりが起こっていることがわかる. さらに, 両者の再構成画像を比較すると重なりの大きい 2.5cm の再構成画像はアーチファクトが発生していることがわかる. このように, シミュレーションからもデータの重なりがアーチファクト発生の原因となることがわかった. 実験データにおいて, 重なりの起こっているデータを扱う場合は, 何らかの補正方法を考える必要がある.

シミュレーション条件2

さらにマルチピンホールとマルチへリカルでの比較を行った。マルチへリカルの条件・結果、シミュレーションに使用した画像はシミュレーション1のものと同じである。ここでマルチピンホールのシミュレーション条件を示す。

Table 2.4: シミュレーション条件

10010 2:1: / = /	7 - 7 7 7 1 1
原画像サイズ	128*128*128pixel
検出器サイズ	256x256pixel
ピクセルサイズ	$0.03 \mathrm{cm}$
検出器のピクセルサイズ	0.1035 cm
投影数	28(4 検出器 x7 投影)
1 投影の回転量	12.8 °
ピンホール数	9
ピンホールサイズ	0.14cm
開口角	± 30 °
物体中心とコリメータの距離	2.5cm
コリメータと検出器の距離	14.5cm
物体 (shepp) のサイズ	$1.1 \mathrm{cm}/2.5 \mathrm{cm}$

シミュレーション結果2

まず、 ノンヘリカルでのマルチピンホールでの結果を示す. 1.1 cm の Shepp ファントムを使用した場合の再構成画像とプロファイルを以下に示す.

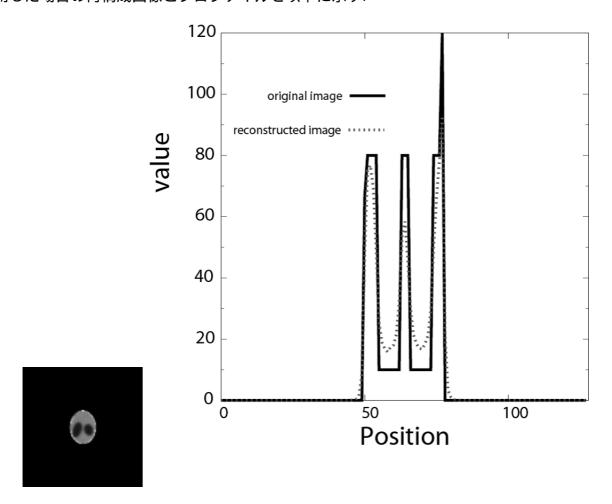


Fig. 2.16: **再構成画像** (slice:64)

また、2.5cm の Shepp ファントムを使用した場合の再構成画像とプロファイルを以下に示す.

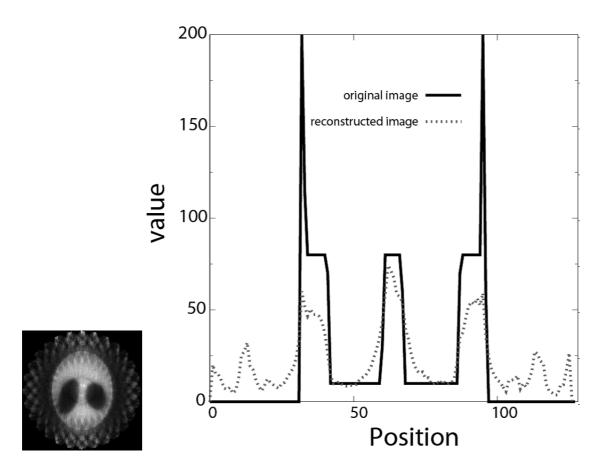


Fig. 2.17: **再構成画像** (slice:64)

ここで,1.1cm のファントムを使用した場合の投影データと 2.5cm のファントムを使用した場合の投影データを比較してみる. それぞれの投影データを以下に示す.

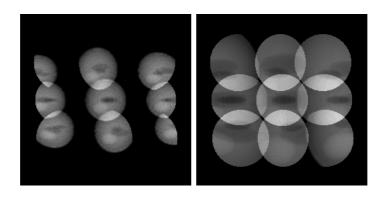


Fig. 2.18: 投影データ (左)1.1cm Shepp ファントム (右)2.5cm Shepp ファントム (angle:102.8)

ヘリカルの時では重なりの起きていなかった $1.1 \mathrm{cm}$ のファントムにおいて、ノンヘリカルでは重なりが起きていることがわかる.

ここで、ヘリカルとノンヘリカルの再構成画像でそれぞれ MSE を求めた.

$$MSE = (f_{original image}(x, y, z) - g_{reconstructed image}(x, y, z))^{2}$$
(2.8)

この結果を以下の表に示す.

Table 2.5: シミュレーション条件

SIZEm	ヘリカル	ノンヘリカル
1.1cm	5.06	5.51
2.5cm	274.97	460.96

 $1.1 \mathrm{cm}$ においてはヘリカルとノンヘリカルでそれほど違いはないが、 $2.5 \mathrm{cm}$ のファントムにおいてはノンヘリカルの方がよい結果となっている。これはヘリカルの方が、重なりが起きている部分が少ないためであると考えられる。

第3章 シミュレーション

3.1 シミュレーション条件

今回のシミュレーションでは2次元でのシミュレーションを行った. ニューラルネットの構成やパラメータ, 学習回数, 検出器条件, 発生光子数, シミュレーション条件などは前章に記述したとおりである. シミュレーションに使用したファントムは学習データの作成に使用したファントムと同一である. この学習に使用したファントムを以下に示す.

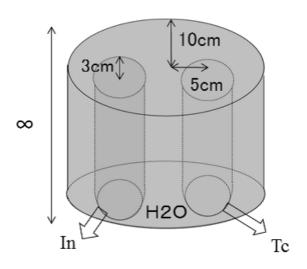


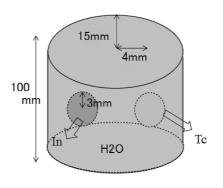
Fig. 3.1: 学習に用いたファントム

ここで学習したパラメータを用いて、3次元でのシミュレーションを行った.前章で述べた 実機を想定したジオメトリを設定したが、一部条件を変更している.検出器条件、発生光子数、 シミュレーション条件を以下の表に示す.

Table 3.1: シミュレーション条件

検出器サイズ	256x256pixel
投影数	28(7x4)
1投影の回転量	12.8 °
検出器のピクセルサイズ	0.1035 cm
コリメータ	9 ピンホール
ピンホールサイズ	半径 0.14cm
開口角	± 30
物体中心とコリメータの距離	2.5cm
コリメータと検出器の距離	14.5cm
ヘリカルでの移動量	8mm/step
エネルギー分解能	10%
発生光子数	10 億個
検出器感度	100%

このシミュレーションで使用したファントムを以下に示す.さらに,検出器とファントムの距離についても以下の図に示す.



Detector3

Detector4

Detector4

| 145mm | 145

Fig. 3.2: シミュレーションに使用したファントム

Fig. 3.3: 検出器とファントムの距離

さらに、このシミュレーションから得られたデータの再構成条件を以下に示す. 2次元での再構成条件は以下に示す通りである.

Table 3.2: 再構成条件 (2 次元)

	\
再構成法	ML-EM
反復回数	100
画像サイズ	64x64
ピクセルサイズ	0.5cm

3次元での再構成条件は以下に示す通りである. 111 In においては, 111 In(171 [keV]) と 111 In(245 [keV]) をそれぞれ再構成した後で足し合わせている.

Table 3.3: 再構成条件 (3 次元)

再構成法	OS-EM
サブセット数	7
反復回数	10
画像サイズ	128x128x128
ピクセルサイズ	$0.05 \mathrm{cm}$

以下の表に示すそれぞれの核種の吸収係数を使用して吸収補正を行った.

Table 3.4: 減衰係数

Table 9.4.	//% 4× //\\ XX
$^{99m}\mathrm{Tc}$	0.1535(1/cm)
$^{111}In(171[keV])$	0.1443(1/cm)
$^{111}In(245[keV])$	0.1277(1/cm)

3.2 シミュレーション結果

まず,2 次元のファントムで学習をした際に得られた 2 次元の分離結果について以下に示す. $^{99m}\mathrm{Tc}$ の $\mathrm{ANN1} \sim 5$ を用いた再構成結果を以下に示す.

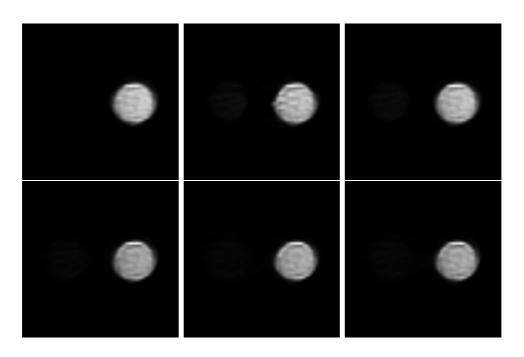


Fig. 3.4: 左上から (ideal ANN1 ANN2) 左下から (ANN3 ANN4 ANN5)

 111 In の ANN1 ~ 5 を用いた再構成結果を以下に示す.

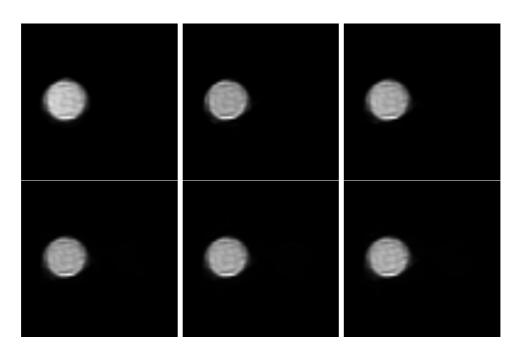


Fig. 3.5: 左上から (ideal ANN1 ANN2) 左下から (ANN3 ANN4 ANN5)

さらに画像の中央位置 (32pixel) でプロファイルを取った. 99m Tc の結果を示す.

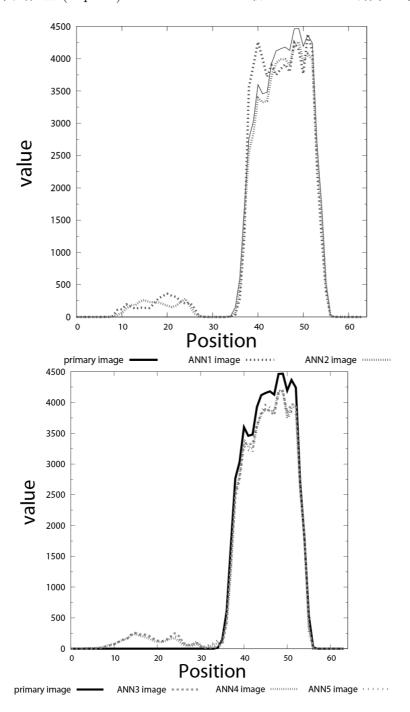


Fig. 3.6: Tc のプロファイル

次に,111 In の結果を示す.

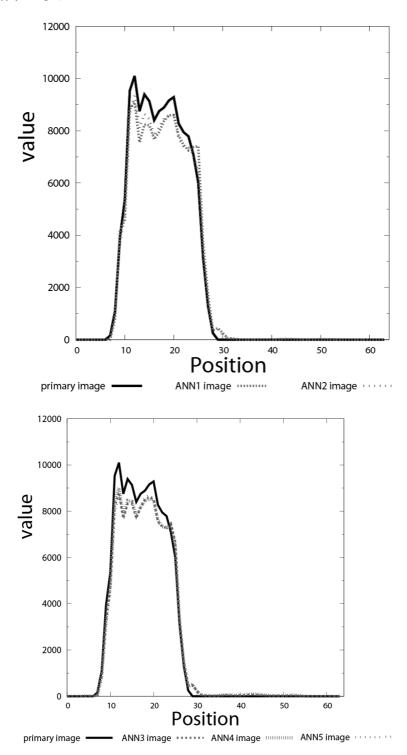


Fig. 3.7: In のプロファイル

次に、3 次元のファントムでシミュレーションを行った結果について示していく. $99m\mathrm{Tc}$ の $\mathrm{ANN1} \sim 5$ を用いた再構成結果を以下に示す.

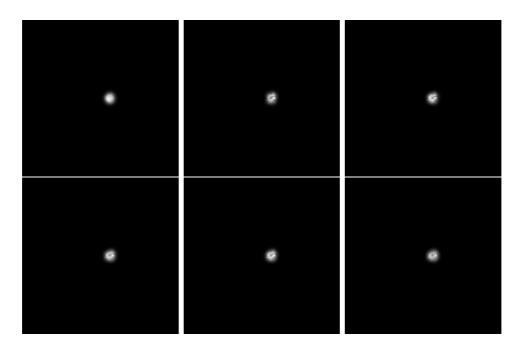


Fig. 3.8: 左上から (ideal ANN1 ANN2) 左下から (ANN3 ANN4 ANN5)(slice:64)

 111 In の ANN1 ~ 5 を用いた再構成結果を以下に示す.

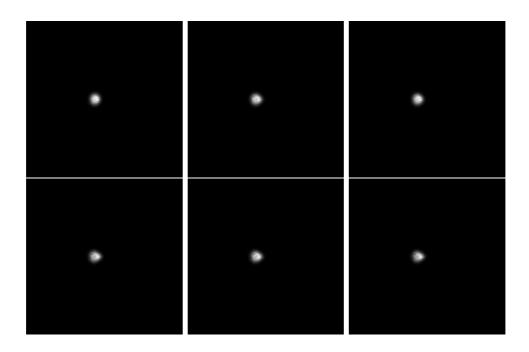


Fig. 3.9: 左上から (ideal ANN1 ANN2) 左下から (ANN3 ANN4 ANN5)(slice:64)

さらに画像の中央位置 (y=64pixel) でプロファイルを取った. ^{99m}Tc の結果を示す. 結果を示す.

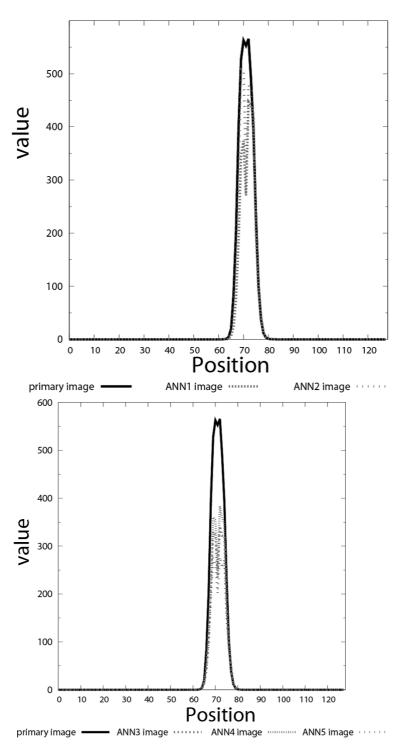


Fig. 3.10: Tc のプロファイル

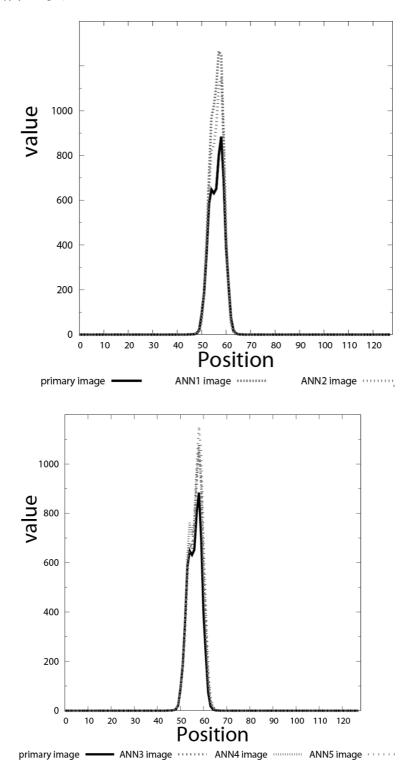


Fig. 3.11: In のプロファイル

また、それぞれの光子発生源に関心領域 (ROI) を設定し精度の比較を行った。まず1 つめの関心領域は、本来その核種が検出されるべき領域である、 $^{99m}\mathrm{Tc}$ について、この関心領域から以下の式を用いて RMSE を求めた。

$$RMSE(Tc)inTc_{cylinder} = \sqrt{\sum_{ROI}^{x} \sum_{Tc_{cylinder}}^{y} \sum_{Tc_{cylinder}}^{z} (f_{ideal}(x, y, z) - f_{corrected}(x, y, z))^{2}}$$
(3.1)

2 つめの関心領域は、本来もう一方の核種が検出されるべき領域である. $^{99m}\mathrm{Te}$ について、この関心領域から以下の式を用いて正規化 RMS 誤差 (RMSE) を求めた.

$$RMSE(Tc)inIn_{cylinder} = \sqrt{\sum_{ROI}^{x} \sum_{In_{cylinder}}^{y} \sum_{In_{cylinder}}^{z} (f_{ideal}(x, y, z) - f_{corrected}(x, y, z))^{2}}$$
(3.2)

同様に 111 In についても ROI を設定し、以下の式を用いて RMSE を求めた.

$$RMSE(In)inIn_{cylinder} = \sqrt{\sum_{ROI}^{x} \sum_{In_{cylinder}}^{y} \sum_{In_{cylinder}}^{z} (f_{ideal}(x, y, z) - f_{corrected}(x, y, z))^{2}}$$
(3.3)

$$RMSE(In)inTc_{cylinder} = \sqrt{\sum_{ROI}^{x} \sum_{Tc_{cylinder}}^{y} \sum_{Tc_{cylinder}}^{z} (f_{ideal}(x, y, z) - f_{corrected}(x, y, z))^{2}}$$
(3.4)

上式を用いて、再構成結果から求めた関心領域に対する RMSE を示す. $^{99m}\mathrm{Tc}$ の結果を示す.

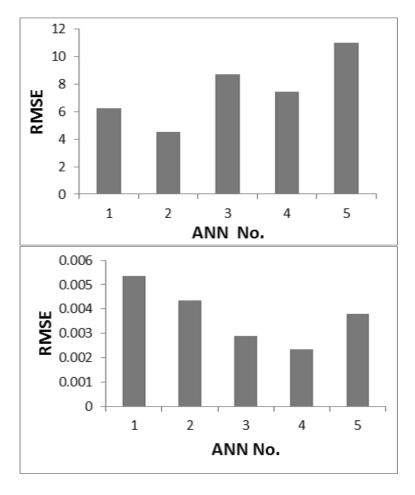


Fig. 3.12: Tc 再構成画像における Tc 円柱中の RMSE(右)In 円柱中の RMSE(左)

次に $,^{111}$ In の結果を示す.

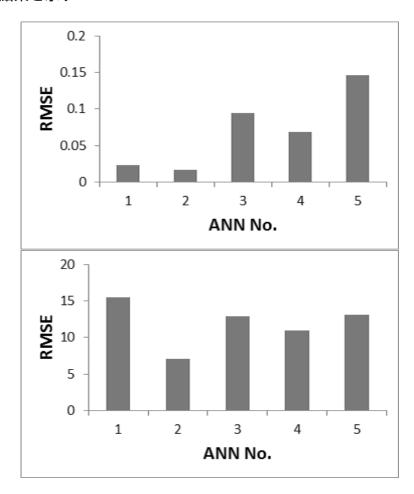


Fig. 3.13: In 再構成画像における In 円柱中の RMSE(右)Tc 円柱中の RMSE(左)

ニューラルネットによるシミュレーションを行った際, $^{111}In(171[\mathrm{keV}].245[\mathrm{keV}])$ の推定したデータの一部に著しくカウントが落ち込んでいる箇所が見られた. $^{111}In(171[\mathrm{keV}])$ の該当箇所の投影データを以下に示す. また, 比較のため理想投影データも同時に示す.

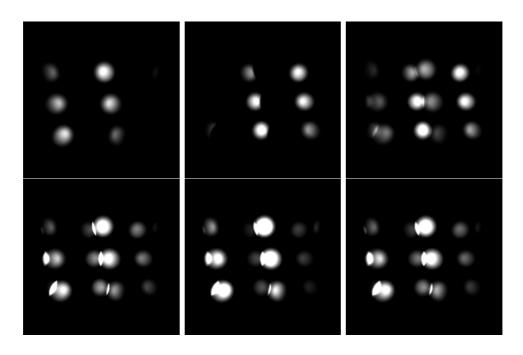


Fig. 3.14: 左上からプライマリ ANN1 ANN2) 左下から (ANN3 ANN4 ANN5)(angle:334.0°)

 $^{111}\text{In}(245[\text{keV}])$ においても同様の箇所にてカウントが落ち込んでいたが 99m Tc においてはこのような著しいカウントの落ち込みは見られなかった.

次に、該当箇所のプロファイルを見てみる。まず、 111 In Primary と 99m Te Primary の結果を示す。

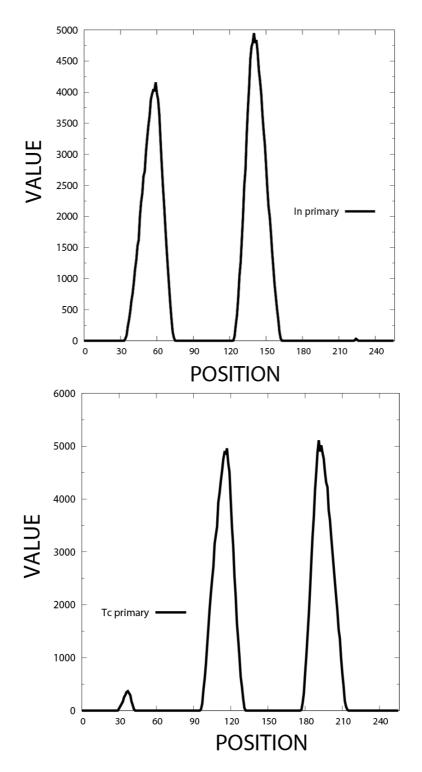


Fig. 3.15: In のプロファイル (上) Tc のプロファイル (下)

次に、ANN1~5のプロファイルを見てみる.以下にその結果を示す.

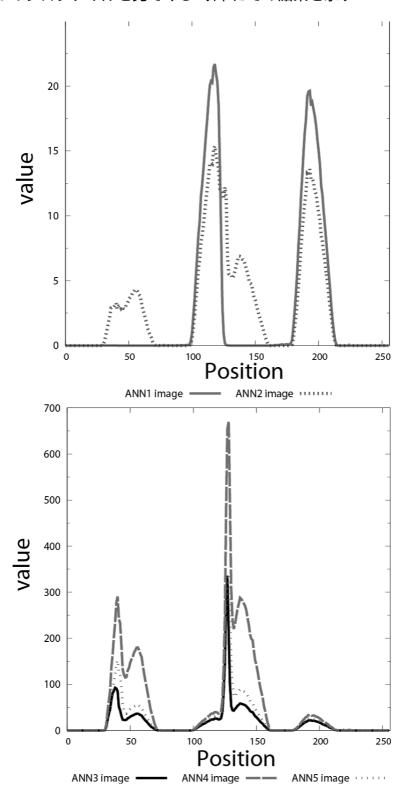


Fig. 3.16: In のプロファイル

これらの結果を見ると、ANN1,2とANN3~5でカウントの落ち方が異なることがわかる.

第4章 考察

4.1 3次元シミュレーションにおける再構成画像

2次元での再構成画像におけるプロファイル Fig.3.6, Fig.3.7 を見ると, 99m Tc の再構成画像においては 111 In 円柱のある領域に、111 In の再構成画像においては 99m Tc の円柱のある領域にそれぞれ値が表れていることがある。ここで、3 次元ファントムでシミュレーションを行った再構成画像におけるプロファイル Fig3.10, Fig3.11 を見てみると、2 次元では値が存在していた領域内にほとんど値が表れていないことがわかる。このような違いが表れた理由は、モンテカルロシミュレーションを用いた 3 次元でのデータの取得は、2 次元でのデータ取得に比べて格段にカウント数が減ることに起因すると考えられる。実際、本研究で用いた 3 次元ファントムのデータでは散乱線があまり生じていなかった。仮に、データ収集の際の発生光子数を増やし、多くのカウントが得られた状態で同じシミュレーションを行った場合、2 次元と同様にそれぞれの円柱の存在箇所にも値が生じてくると考えられる。しかしながら、本論文でのシミュレーションからも、そのような十分なカウントが得られ、散乱線が生じたデータにおいても、精度よくそれぞれのプライマリ光子を推定し、分離を行うことが可能であると考えられる。

4.2 エネルギーウィンドウについて

3次元シミュレーションにおいて、再構成結果から関心領域に対する RMSE を求めた. この結果より、それぞれの核種の推定に適切な ANN を考察する. まず、 99m Tc に関して、Fig. 3.12 を見ると、ANN3、4の結果がよいことがわかる. ANN3~5は、散乱線を考慮したウィンドウを設けた ANN であり、 99m Tc を推定したい場合は、散乱線を考慮したデータを用いた方がよいと考えられる. また、 111 In に関しては、Fig. 3.13 を見ると、ANN1、2の結果がよいことがわかる. ANN1、2は ANN3~5のような散乱線を考慮したウィンドウを設けていない. つまり、 111 In を推定したい場合は、散乱線を考慮しないデータを用いた方がよいと考えられる. これらの結果をまとめると、 99m Tc を推定したい場合は散乱線を考慮したデータを、 111 In を推定したい場合は散乱線を考慮していないデータを用いるとよい. ここで、ANN1 は ANN3 に含まれているということを考慮すると、ANN3 を用いて 111 In 推定の際には ANN1 の部分だけを用いるというのが最適であると考えられる.

ここで、本論文で用いたデータでは、前述したように散乱線があまり生じていないという点も考慮して考えてみる。前述した結果より、 $^{99m}\mathrm{Tc}$ 、 $^{111}\mathrm{In}$ それぞれの結果において、散乱線を考慮したウィンドウを設けたデータか否かで RMSE の値に開きがある。仮に、十分なカウントが取れ散乱線が生じたデータを用いた場合、この開きが大きくなるだけで、グラフの形自体に変化がないと考えられる。結論としてはやはり ANN3 のウィンドウを最適として問題ないと考えられる。

4.3 投影データについて

前章において、111 In(171 [keV],245 [keV]) の 334.0 °におけるデータにおいて著しいカウント の落ち込みが見られたことについて述べた.Fig.3.16 を見ると, この現象は,ANN1~5 の全て で起こっているが、ANN1、2とANN3~5でカウントの落ち方が異なっている.ANN1、2のプロ ファイルを見るとその形は $^{99m}\mathrm{Tc}$ のものに近い. つまりここで出ている値は $^{99m}\mathrm{Tc}$ のもので ある.この値は他の投影データにも見られるため、本来あるはずの111 Inのカウントが出ていな い.ANN3~5を見ると,¹¹¹In の形と近い形状をしている. しかし, カウント数が本来の 1/10 程 度まで落ち込んでしまっていることがわかる.ANN1,2とANN3~5の違いは散乱線を考慮し たウィンドウを設定しているかいないかである。この点にカウントが落ち込む原因がある可能 性は高いと考えられる、その他の要因についても考えてみる、これまで述べてきた3次元ファ ントムにおけるカウントの少なさという点で考えてみる。今回 $_{_1}^{111} {
m In}$ と $_{_2}^{99m} {
m Tc}$ で同程度のカウ ントが得られている.99mTc のデータに関しては、このような落ち込みが見られないため、カウ ントの少なさによる影響ではないと考えられる。そこで考えられるのが学習データとシミュ レーションデータでジオメトリが異なることである。今回、学習データには2次元の Fig.3.1 の ファントムを用いたが、シミュレーションでは3次元の Fig.3.2 のファントムを用いている.2 次元と3次元という違いなどが影響してこのようなカウントの落ち込みが見られた可能性は ある. 学習に十分なカウントが得られた3次元の学習データを用い、シミュレーションを行い、 今回のような欠損が見られなければ、この影響によるものと考えてよいと考えられる.

第5章 まとめ

提案手法であるニューラルネットを用いた二核種の分離を,実機を意識した3次元のファントムを用いてシミュレーションを行った.その結果,それぞれの核種を正確に分離することが出来た.さらにその結果より,入力データとして用いる最適なANNも考察した.このことから本手法の有効性を検証することが出来た.しかしながら,3次元でのシミュレーションは,2次元に比べ十分なデータが得られにくいという問題があり,本論文でのシミュレーションに用いたデータにおいてもカウントが少なく散乱線も少ないという問題はあったが,十分なカウントが得られたデータを用いた場合でも本手法は有効であると考えられる.今回,実機条件に近いシミュレーションを行ったので、今後は、臨床実験を行っていくことが必要である.

第6章 付録

6.1 ニューラルネットワークの理論

6.1.1 ニューロン

ニューロンとは神経細胞のことであり、情報処理と情報伝達に特化した機能を持っている. 人間の脳には約140億個のニューロンがあると言われている.ニューロンは網目のようにつ ながりネットワークを構築している、各ニューロンは、他の多数のニューロンと結合して信号 の送受信を行っている.これは、一つの神経細胞に複数の細胞からの入力があったり、活動電 位が起きる閾値の変化などが行われている. つまり脳の中では多くのニューロンが繋がり情 報処理を行っている.ニューロンは、主に3つの部分で構成されている.それは、細胞体、樹状 突起、軸索である、細胞体は細胞核があり、本体である、樹状突起はほかの細胞からの入力を 受ける入力部分、軸索はほかの細胞へと出力する出力部となっている、樹状突起と軸索をまと めて神経突起とも言う、軸索は途中で何本にも枝分かれし、他の多数のニューロンの樹状突起 へと繋がっている. このように、複雑に結合したニューラルネットを構成している. 軸索と樹 状突起のつながりをシナプスと呼び、ニューロンの情報はこのシナプスを介して伝えられる. ニューロンをコンピュータで設計するために、ニューロンのモデル化は不可欠である. ある 1 つのニューロンに n 個のニューロンから入力があったとする. このとき、ニューロンへの入力 を $x_i(1_{jijn})$ とする. また, 結合荷重を w_i とする. 結合荷重とは, シナプス結合の強さのことで あり、膜電位が入力の影響を受けて変化する大きさんことである。これは、入力への重みの役 割を果たす、入力信号により膜電位が上昇するということは、入力の強さに結合荷重を乗算し、 全ての入力に対しての総和をとるという操作になる。このとき膜電位の上昇量は、 $\sum_{i=1}^{w_i x_i}$ で表 される、この総和が閾値 θ を越えたとき、細胞が興奮すると考える、このようにして生じた興 奮が、細胞の出力になると考えられる、これを式で表すと次式のようになる、

$$u = \sum_{i=1}^{n} w_i x_i - \theta \tag{6.1}$$

$$y = f(u) \tag{6.2}$$

ここで \mathbf{u} は膜電位を表している. また $\mathbf{f}(\mathbf{u})$ は出力関数と呼ばれるものである. 入出力が $\mathbf{0}$ か $\mathbf{1}$ の $\mathbf{2}$ 値であるような $\mathbf{2}$ 値モデルであれば出力関数はステップ関数が用いられる.

$$f(u) = \begin{cases} 1, & (u > 0) \\ 0, & (u = 0) \end{cases}$$
 (6.3)

入出力が実数値をとるような連続モデルの場合には、一般的にシグモイド関数を用いる.

$$f(u) = \frac{1}{1 + \exp(-u)} \tag{6.4}$$

6.2 学習モデル

ニューラルネットの学習は、まず結合加重の初期設定を行う、この際、重みに関する何の知識もないようであれば適当な値にしておく、次に、重みに対して学習データを入力し、評価を行う、その後、評価結果に基づき重みの値を更新し再び評価を行う、このプロセスを繰り返し、値を最適値へと近づけていく、学習の指針として、ある入力に対し望ましい出力が外部から与えられる場合、これを教師信号と呼ぶ、ニューラルネットは、教師信号の有無で教師なし学習と教師あり学習の二種類に分けることができる。前者は主にデータ・クラスタリングなどに用いられ、後者は回答が用意されているような場合に用いられる。

6.3 単層ニューラルネットワークと多層ニューラルネットワーク

本章でニューロンについて述べたが、このニューロンを互いに繋ぎネットワークを構成することでニューラルネットワークが構築される. 単層ニューラルネットワークは最も単純なネットワークであり、入力層と出力層で構成される. ここで入力層は、単純に入力を出力層へと渡す役割しか持たず、計算を行うニューロンは出力層である.

ネットワークというものは一般的に大きく複雑であるほど優れた計算能力をもつ、つまり、多層のネットワークは単層のネットワークの能力を越える、多層ネットワークは単層ネットワークを単純に階層化することで形成されている.

6.4 パーセプトロン

パーセプトロンとは、視覚と脳の機能をモデル化したニューラルネットワークの一種で、パターン認識を行う. 一般に、パーセプトロンは入力の組に重み付きで結合した単層の人口ニューロンによって構成されている.

6.4.1 基本パーセプトロン

基本パーセプトロンは次式で表すことができる。

$$u = \sum_{i=1}^{n} w_i x_i - \theta \tag{6.5}$$

$$z = 1[u] = \begin{cases} 1, & (u = 0) \\ 0, & (u = 0) \end{cases}$$
 (6.6)

この素子の意味を Y のパターン空間上で考える. 上式 u に 0 を代入した式は, パターン空間上では結合加重 w_i と閾値 θ の値によって傾きと位置が決定する超平面を表す式となる. 逆に言えば,Y がその超平面上にあるとき,u は 0 となる. つまり Y がこの超平面上のどちら側にあるかで素子は 1 か 0 を出力する. つまり基本パーセプトロンはパターン空間上でこの超平面によって分離される 1 つのカテゴリを識別する能力を持っているといえる. このような超平面でパターンを 2 つに分類できるような問題を線形分離可能という. 基本パーセプトロンは線形分離可能な問題であれば, そのカテゴリを分類することができる.

6.4.2 多重パーセプトロン

多層パーセプトロンとは、前述した基本パーセプトロンを多層にしたものである。3層パーセプトロンにおいて、第一層は入力層と呼ばれ、外部から入力を受け、それを第二層へと送る。第二層は中間層と呼ばれ、入力層とのさまざまな結合によって入力信号を変換し、三層へと送る。第三層は出力層と呼ばれ、中間層から受け取った信号を送る。基本パーセプトロンは線形分離可能な問題をパターン分離することができるが、実際のところは線形分離可能な問題は少ない。

6.5 バックプロパゲーションについて

6.5.1 一般化デルタルール

パーセプトロンにおける学習則について説明する。まず、素子の特性を次のように一般化する。 ある素子 j の入力は、他の素子 i の入力 y_i に結合荷重 w_{ij} を乗算し、全ての入力の総和をとった u_i となる.

$$u_j = \sum_{i=1}^n w_{ji} y_i \tag{6.7}$$

そして、素子jの出力は、 u_j に出力関数として単調増加を施したものとしてあらわされるので以下のようになる.

$$y_i = f(u_i) \tag{6.8}$$

一般的にパーセプトロンでは、出力関数はステップ関数になるが、ここではより一般化して連続値モデルを考え、出力関数をシグモイド関数とする.

$$y(u) = \frac{1}{1 + \exp(-u)} \tag{6.9}$$

この関数は微分可能な関数なので解析的に問題を解くことが可能となる.

次に $,y_{j,c}$ をある入力ベクトル c に対して, 素子 f が出すべき望ましい出力, つまり, 教師信号とし $,y_{j,c}$ を素子 f の実際の出力とするf そして, 学習の評価をするために, 次のような誤差関数 f を考えるf

$$E = \frac{1}{2} \sum_{j,c} (y_{j,c} - \hat{y}_{j,c})^2$$
 (6.10)

このような誤差関数を最小にする手続きを一般に、最小二乗平均後作法という $y_{j,c}$ は、その時の素子間の結合荷重 w_{ij} で決まるため、誤差関数も結合荷重に依存した関数となる。従って、各重みの値を軸としてできる空間を考え、さらにこの誤差関数 E によって定義される価を高さと考えれば、E は重み空間上の超平面として誤差局面を与えることとなる。任意の重みの状態から、この誤差局面の最小値に達するには、例えば各重みを $\partial E/\partial w_{ji}$ に比例した量ずつ変化させていけばよいことになる。つまりその変化量は以下の式のようになる。

$$\Delta w_{ji} = -\epsilon \frac{\partial E}{\partial w_{ji}} \tag{6.11}$$

ここで ϵ は、学習係数と呼ばれる、この式は誤差曲面上を最も急な傾斜方向に進んでいくことを意味し、このような学習測を一般的に最急降下法という。

前述のように式が定義されていなければ, $\partial E/\partial w_{ii}$ は、以下のように表すことが出来る.

$$\partial E/\partial w_{ji} = \sum_{c} \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial u_j} \frac{\partial u_j}{\partial w_{ji}}$$
(6.12)

ここで微分により以下が得られる.

$$\frac{dy_j}{du_j} = f'(u_{ji})\frac{\partial y_j}{\partial u_j} = y_i \tag{6.13}$$

これを $\partial E/\partial w_{ji}$ に代入すると以下のようになる

$$\Delta w_{ji} = -\epsilon \sum_{c} \frac{\partial E}{\partial y_i} f'(u_j) y_i \tag{6.14}$$

ここでパーセプトロンのように中間層の結合荷重が変化しない場合, $\partial E/\partial y_j$ の項は微分により以下のように求めることが出来る.

$$\frac{\partial E}{\partial y_i} = (y_j \hat{y_j}) \tag{6.15}$$

これを代入して以下のような学習則が得られる.

$$\Delta w_{ji} = -\epsilon \sum_{c} (y_j \hat{y}_j) f'(u_j) y_i$$
 (6.16)

これを標準デルタルールという。たとえば f(u) が上部のシグモイド関数で与えられる場合

$$f'(u) = y(1-y) (6.17)$$

となる. このとき Δw_{ji} は以下のように求めることが出来る.

$$\Delta w_{ji} = -\epsilon \sum_{c} (y_j \hat{y}_j) y (1 - y) \tag{6.18}$$

6.5.2 バックプロパゲーション

バックプロパゲーション法は 1986 年に提案された,逐次的学習法のひとつであり,非線形問題も解けるようにした新しい学習法である.パーセプトロンにおいては線形分離不可能な問題を解決することが出来ないが,バックプロパゲーションを用いることでこれに対処する.このバックプロパゲーションのアルゴリズムについて説明する.まず,階層型のネットワークを考える.同じ層の素子間に結合はなく,どの素子も1つ前の層からの出力を入力として受け取る.このようなネットワークの中間層に対し,パーセプトロンにおける出力層と同様に学習則を導こうとしたとき, $\frac{\partial E}{\partial y_i}$ の値はすぐには求められない.そこで,この微分値を出力層から逆向きに計算していくことを考える.つまり出力の誤差を,前の層へと伝播させていく.すなわち,ある層の素子j の $\frac{\partial E}{\partial y_i}$ の値は,次の層の素子k の $\frac{\partial E}{\partial y_i}$ を用いて

$$\frac{\partial E}{\partial y_i} = \sum_{a} \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial u_k} \frac{\partial u_k}{\partial y_j} \tag{6.19}$$

と表すことができる.ここから以下の式のようになる.

$$\frac{\partial u_k}{\partial y_j} = w_{kj} \tag{6.20}$$

この式を $\frac{\partial E}{\partial y_i}$ へと代入する.

$$\frac{\partial E}{\partial y_i} = \sum_c \frac{\partial E}{\partial y_k} f'(u_k) w_{kj} \tag{6.21}$$

これがバックプロパゲーションにおけるアルゴリズムである。以下に、階層型ネットワークにおけるバックプロパゲーションアルゴリズムを用いた学習フローを示す。ここで、中間層と入力層の結合加重を \mathbf{w}_{ji} 、出力層と中間層の結合加重を \mathbf{w}_{kj} とし、中間層の閾値を θ_j 、出力層の閾値を θ_k として説明する。

- 1. 結合加重 $\mathbf{w}_{ji}, \mathbf{w}_{kj}$ と, 閾値 θ_j, θ_k をそれぞれ小さな値の乱数で初期化する.
- 2.1つめのパターンを学習パターンとする.
- 3. 学習パターンの値を入力層の出力 y_i に入れ、入力層と中間層の結合加重 $w_j i$ と中間層の 閾値 θ_j を用いて中間層への入力 u_j を求め、その入力を出力関数であるシグモイド関数 に通し、中間層の出力 y_j を求める.

$$u_j = \sum_i w_{ji} u_i + \theta_j y_i = f(y_i)$$

$$(6.22)$$

4. 中間層の出力 y_i と中間層と出力層の結合加重 w_{kj} , 出力層の閾値 θ_k を用いて出力層への入力 u_k を求め、その入力を出力関数であるシグモイド関数 f(u) に通し、出力層への出力 y_k を求める.

$$u_k = \sum_{i} w_{kj} y_j + \theta_k y_k = f(y_k)$$
 (6.23)

- 5. 現在の学習パターンに対する教師信号 \mathbf{t}_k と出力 \mathbf{y}_k の差から, 中間層と出力層の間の結合加重と出力層の閾値に対する誤差 $\delta_k = (\mathbf{y}_k \mathbf{t}_k) y_k (1 \mathbf{y}_k)$
- 6. 誤差 δ_k , 中間層と出力層の間の結合加重 \mathbf{w}_{kj} , 中間層の出力 \mathbf{y}_j から, 入力層と中間層の間の結合加重と, 中間層の閾値に対する誤差 δ_i を求める.

$$\delta_j = \sum_k \delta_k w_{kj} y_j (1 - y_j) \tag{6.24}$$

7. 出力層における誤差 δ_k , 中間層の出力 y_i , 学習係数 α の積を加算する事で, 中間層と出力層の間の結合加重 w_{kj} を修正する. また, 誤差 δ_k と学習係数 α の積を加算する事で, 出力層の閾値 θ_k を修正する.

$$w_{kj} = w_{kj} + \alpha \delta_k y_k \theta_k = \theta_k + \alpha \delta_k \tag{6.25}$$

8. 中間層における誤差 δ_j , 入力層の出力 y_i , 学習係数 α の積を加算することで, 入力層と中間層の間の結合加重 \mathbf{w}_{ji} を修正する. また, 誤差 δ_j と学習係数 α の積を加算する事で, 中間層の閾値 θ_i を修正する.

$$w_{ii} = w_{ii} + \alpha \delta_i y_i \theta_i = \theta_i + \alpha \delta_i \tag{6.26}$$

- 9. 次のパターンを学習パターンとし, すべてのパターンを学習し終えるまで 3 から 9 を繰り返す.
- 10. すべてのパターンを学習し終えたら, 学習回数を加算し, 学習回数が制限回数以下であれば 2 に戻る.

謝辞

本研究に当たり全般にわたってご指導いただきました尾川浩一教授,多くの面でお世話になりました貝吹太志氏,遠藤聡氏,市村雄太氏,および尾川研究室の方々に感謝いたします.

参考文献

- [1] A.Matsunaga and K.Ogawa, "Scatter correction in multiradioclide data acquisition by means of a neural network" Conf. Rec. IEEE Nucl. Sci. Symp. Med. Imag. Conf., vol.2, pp.948-952, 1999
- [2] 藤井博史, 梅田泉, 小島良紀, 「ライフサイエンスのためのアイソトープ測定器 (第五シリーズ) "ライフサイエンスイメージング" 」, 『SPECT 技術を用いた小動物イメージング』, P55-68, Japan Radioisotope Association
- [3] 馬場則夫・小島史男・小澤誠一(1994)『ニューラルネットの基礎と応用』共立出版
- [4] PHILIP D. WASSERMAN(1993) 『ニューラル・コンピューティング 理論と実際 』石 井直宏・塚田稔共訳 森北出版
- [5] 合原一幸(1988)『ニューラルコンピュータ 脳と神経に学ぶ』東京電機大学出版

発表論文

[1] H.Mukai,S.Endo,K.Ogawa,I.Umeda,H.Fujii "Estimation of Activity in Small Animal Multi-Isotope SPECT Study" The 7th Korea-Japan Joint Meeting on Medical Physics, September 25-27,2014,BEXCO,Busan,Korea