

平成 30 年 6 月 11 日現在

機関番号：35413

研究種目：挑戦的萌芽研究

研究期間：2015～2017

課題番号：15K15214

研究課題名(和文) 機械学習を用いた新しい原理にもとづく高速画像再構成法の開発

研究課題名(英文) Development of Fast Image Reconstruction Method based on Machine Learning

研究代表者

大倉 保彦 (Okura, Yasuhiko)

広島国際大学・保健医療学部・教授

研究者番号：80369769

交付決定額(研究期間全体)：(直接経費) 2,900,000円

研究成果の概要(和文)：医療において重要な検査装置であるX線CTやMRI、PETなどの画像診断装置では、生体から得られた信号から、体内の情報を断層像として構成し診断に役立つ画像を得る画像再構成法が必須の技術である。しかし、特に近年のX線CTやPETでは得られる情報が多いため、画像再構成に必要な演算が多く、診療に待ち時間を発生させるほど、計算に時間がかかる。一方、「大規模ニューラルネットワーク」は、信号を入力して出力を得る「推論処理」には比較的演算負荷が軽いことが知られている。本研究では、大規模ニューラルネットワークを利用して医用における高速な画像再構成が実現可能であることを明らかにした。

研究成果の概要(英文)：In medical image diagnostic system such as X-ray CT, PET, which give important inspection in medical situation, an image reconstruction method to obtain useful information for diagnosis by constructing images as tomograms from projection data of the patients is a very important technology. However, especially in recent X-ray CT and PET, there are many information to be obtained, so time to calculations necessary for image reconstruction is too long even if newer computer is used for calculation. Therefore, it takes more waiting time to calculate is generated in clinical practice. On the other hand, it is known that the "large-scale neural network" has a relatively light computation load for "inference processing" of obtaining output by inputting data. In this study, we clarified that high-speed image reconstruction in medical use can be realized by using large-scale neural network.

研究分野：医用画像処理

キーワード：画像再構成 機械学習 ニューラルネットワーク

## 1. 研究開始当初の背景

一般に、X線CTやSPECTなど断層像を得る医用画像装置では、患者周囲の多方向より投影データを得て、これを画像再構成処理することによって診断等に有用な断層像を得る。また、一般に画像再構成処理には、解析的手法である重畳積分逆投影法や、統計的手法である逐次近似法(特に統計的手法であるOSEM)が用いられている。

しかしこれらの計算手法では、計算量が比較的多く、結果である断層像を得るまでに多くの時間を要する。またX線CTでは、複数の検出器列を有するマルチディテクタCTが一般的であり、商用では320列検出器をもつものがある。このような多列検出器をもつX線CTで人体の断層像を得る場合、断層像の枚数は1000枚以上となる場合があり、近年の高性能な計算機を使用しても、再構成にかかる時間は、医療現場で待ち時間が必要になるほど長い。

一方、機械学習に関する研究は多くなされており、近年特にDeep Learningと呼ばれる新しい大規模ニューラルネットワークが注目されている。音声認識、画像認識、画質改善など多くの分野で応用され、高い性能をもつことが示されている(Hinton et al, IEEE Signal Processing, 2006など)。

機械学習では、まず、モデルを構築し、入力データと、結果となる出力のデータを用意しておき、これらを対にして「学習」を行うことで、入力から出力に至る「変換」等をモデルパラメータとして得る。ここで、あるモデルを構築し、入力データとしてCT等で得られる投影データ、出力データとして断層像とし、これらの組み合わせで「学習」を行えば、投影データから断層像を導く学習機械が得られると考えられる。

## 2. 研究の目的

ニューラルネットワークモデルを構成し、モデルによって投影データから断層像を得ることを目的とする。学習されたモデル入力として検出器で得られる投影データ、教師データを再構成画像として学習させ、学習させたニューラルネットワークに投影データを出力として利用することによって、画像再構成像を得る基礎的な手法の開発と評価を目指す。

## 3. 研究の方法

### (1) ニューラルネットワーク学習システムの構築

入出力データおよび計算量が膨大となるため、本研究のためのコンピュータには可能な限りメモリ搭載量が多く、GPUを複数搭載できるものを導入した。

### (2) データ収集

まず、大規模画像データベースを作成した。ILSVRC(ImageNet2012)で公開されている100

万枚を超える画像を使用した。train用の画像のうち、10万枚をランダムに選択し、64ピクセル×64ピクセル、256階調の画像セットに変換した。さらに、Pythonのsci-kit imageライブラリのradon関数によって、ラドン変換し、これを投影データとした。角度は180度、また投影角度ステップは1度とした。

また、シミュレーションにより作成した。CERNで開発された放射線像のためのモンテカルロシミュレーションソフトウェアGeant4をベースとした「GATE」(S Jan, G Santin, D Strul et al, GATE: a simulation toolkit for PET and SPECT, Phys. Med. Biol., 2004)を使用して、シミュレーションによる投影データを作成する。「GATE」は多くの文献により精度等が十分に検証されているソフトウェアであるため、これを使用する。

まず、現実に存在するファントムとSPECT検出器の形状および性質を数値モデル化する。そして「GATE」を使ったシミュレーションによる得られる投影データと再構成像を計算によって作成した。

### (3) 大規模ニューラルネットワークの画像再構成システムの構築

本研究でニューラルネットワークモデルを作成し、学習および推論を行うための基盤的ソフトウェアとして、Chainer ver.3.2(Preferred Networks, inc.)を使用した。これはニューラルネットワークを実装するためのライブラリであり、GPUを使った高速な演算が可能、柔軟な記法により様々なタイプのニューラルネットワークを実装可能、直感的なネットワーク構成を記述可能、などの特徴を有する。本研究では入出力となるデータが両者とも画像データであるため、一般のニューラルネットワークの適用領域である画像認識や音声認識に比較して、ネットワークの規模が大きく、またパラメータ数も膨大となることが予想された。したがって、高速演算のためのGPU(Graphics Processing Unit)が利用でき、かつ柔軟に大規模なネットワークが表現可能なChainerを用いた。

### (4) 構築した学習モデルと学習

本研究では、再構成に伴う諸問題を明らかにするため、また、学習効率などの特性を効率よく把握するために、ネットワーク構成は比較的シンプルなMLP(Multi-Layer Perceptron)とした。入力ノードから出力ノードの間の中間層として、1~3段を使用し、合計3~5段構成とした。中間層のノード数は、2000~8000の数を設定し、ネットワークを構成した。

すべての活性化関数には、ReLU(Rectified Linear Unit)を用い、最適化手法としてはAdam(Adaptive Moment Estimation)を用いた。学習のepoch数は、10000とした。

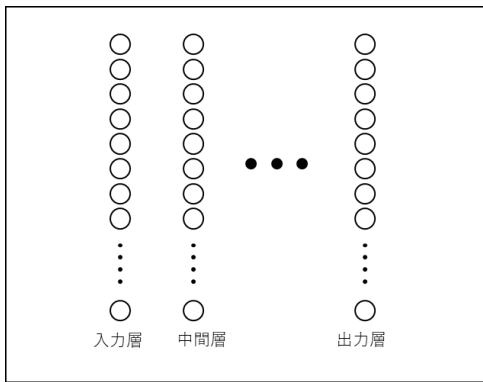


図 構築したネットワークの例

(5) 大規模ニューラルネットワークの学習

上記(2)で得られたデータを使用して、上記(3)で構築されたニューラルネットワークの学習を行った。

学習には 32GB のメモリを有するコンピュータと、これに内蔵する GPU(Nvidia 製 GeForce TITAN X)2 枚を使用した。学習(train)には 10 万枚のデータのうち 9 万枚を使用し、残り 1 万枚を検証用(validation)データとし、学習を進めた。

(6) 学習によって得られた大規模ニューラルネットワークによる画像再構成

学習済みモデルを使用して、投影データ(ここでは radon 変換されたサイノグラムデータ)から、出力画像である再構成像を得るプログラムを作成した。

4. 研究成果

ImageNet2012 の 64 × 64、180 度データを使用し学習を行った。下図には、データ画像数が 10 万の場合の、validation の loss 値の一例を示す。epoch 数 10000 程度であれば、loss 値はおよそ 0.01~0.05 の範囲で安定し、これ以降、同様であることが予想された。また、本研究で構築したすべてのモデルで、およそ同様の傾向であった。




図 epoch 数と loss 値の推移

中間層のユニット数と epoch 数 10000 時の loss 値の推移を図に示す。




図 中間層の数と loss 値

中間層を 500 から 8000 まで変化させ、loss 値を得た。中間層数が 500 から 2000 までは、中間層数が多くなるにしたがって loss 値が減少した。しかし、2000 より多くした場合、loss 値は有意に変化しなかった。64 × 64 ピクセルに限定した場合、中間層数は 2000 ~ 4000 程度が計算時間等とのバランスがよく、有効と考える。

サンプリング角度を変化させた場合の loss 値を下図に示す。loss 値は 0.015 から 0.02 の間であったが、一定の傾向はみられず、サンプリング角度の影響はあまりないように思われた。




図 サンプリング角度の影響

下図に、中間層のユニット数を 4000 に固定した場合の中間層数の変化に対する loss 値を示す。中間層数 3 から 7 まで単純減少の傾向がみられた。また、9 と 10 では、大きく loss 値が変動した。変動の原因はあきらかにできなかった。中間層数は 7 程度が最適と思われる。

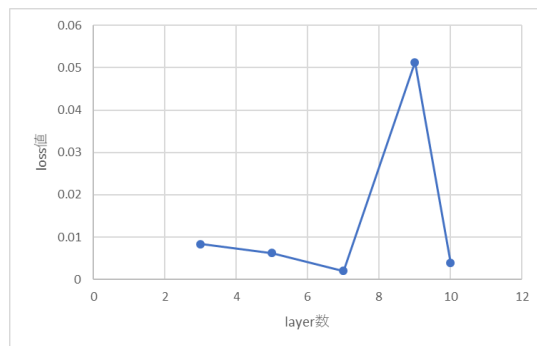



図 中間層数の影響

中間層数 5、ユニット数 4000 の MLP を用いて、ImageNet の画像を使用して学習を行い、学習した MLP を用いて投影データ(サイノグラム)から再構成した画像を下図に示す。上段は、ImageNet の画像を 64×64pixel、256 階調のグレースケールに変換したものであり、下段は上段の画像を投影データ(サンプリング角度は 1 度)に変換したのち、投影データから開発手法により再構成した像である。医用で使われる X 線 CT に例えると、上段の像が未知である真の減弱係数の分布であり、下段が得られる CT 像と対応づけられる。



(a) 対象像



(b) 再構成像

図 対象像と再構成した像の例

MLP で再構成した像では、一部の画像をのぞいて、全体的に鮮鋭性が低下しており、ボケた像となった。また、数ピクセルのソルト&ペッパーノイズも発生していることがわかった。

GATE によるシミュレーション像も用いて、再構成処理にかかる時間の測定結果を下表に示す。開発手法の再構成処理には CPU のみを用いて測定した。開発手法は GPU による処理に向いており、GPU の利用によって簡便に処理性能の向上が期待できる。すなわち、再構成処理時間については、他の手法に比較して有意に高速であることが明らかになった。

表 画像 10 枚の再構成にかかる時間

	時間 (sec)
CBP	0.377
OSEM	86.9
開発手法	0.160

本研究で開発した手法では、比較的構造が単純なモデルである MLP を使用し、基礎的な特性を明らかにすることを目的とした。したがって、得られる再構成像の画質に関しては、十分に最適化ができていない。

また、学習にかかる時間は長く、研究開始時点でほぼ最高の演算速度をもつ GPU を用いても、epoch 数 10000 の学習を終えるには 6 時

間から 10 日間が必要であった。モデルの最適化など、モデル構築にかかる研究を効率よく進めるためには、高速な演算器が必要である。

本研究の成果から、機械学習の一種のニューラルネットワークを用いて、画像再構成が可能であることが示された。本開発手法は、一般的に使用されている FBP(CBP)や OSEM に比較して短時間で画像再構成処理が可能であることが示された。しかしながら、画質に関して改善の余地は大きいこともあきらかになった。

ネットワークモデルの構造や活性化関数の選択、最適化法の選択、他の手法とのアンサンブル等、多くの検証すべき課題が明らかになった。

#### 引用文献

Deng J, ImageNet: A large-scale hierarchical image database, Proceeding of CVPR, 2009

S.Jan, G Santin, D Strul, et al, GATE: a simulation toolkit for PET and SPECT, Phys.Med.Biol, 49, 4543-4561, 2004

Tokui, K. Oono, S. Hido, and J. Clayton. Chainer: a Next-Generation Open Source Framework for Deep Learning, Proceedings of Workshop on Machine Learning Systems in NIPS, 2015

Diederik P. Kingma, Jimmy Ba, Adam: A Method for Stochastic Optimization, International Conference on Learning Representations, 2015

#### 5. 主な発表論文等

〔学会発表〕(計 2 件)

対向データを利用した補間法による SPECT 再構成法の開発, 山口雄貴, 大倉保彦, 山本めぐみ, 第 36 回日本医用画像工学会大会, 2017 年

Advanced method to reconstruct SPECT image from few number of projection data Yuki Yamaguchi, Yasuhiko Okura, Megumi Yamamoto, Annual meeting of European Association of Nuclear Medicine, 2017 年

#### 6. 研究組織

(1) 研究代表者

大倉 保彦 (OKURA, Yasuhiko)

広島国際大学・保健医療学部・教授

研究者番号: 80369769