

# PET 画像再構成のための深層学習

## —いくつかの最新アプローチ—

橋本 二三生<sup>\*1,a)</sup> Andrew J. READER<sup>\*2</sup>

### 要旨

深層学習が PET 画像再構成処理に応用されて久しい。本解説では、PET 画像再構成の歴史を紹介した後、深層学習 PET 画像再構成技術について、基本的な深層学習画像再構成の考えからいくつかの最新の研究まで、平易に解説する。

キーワード：PET 画像再構成，深層学習

### 1. はじめに

最初期の陽電子放射断層撮影法（Positron emission tomography, PET）画像再構成は、計測データの単純なモデルに基づいた従来の解析的手法によるものであった。具体的には、リストモード PET データを逆投影した後、点広がり関数（Point spread function, PSF）を逆畳み込み（Deconvolution）して再構成画像を取得する、Backproject then filter (BPF)とよばれている手法が用いられていた[1]。しかし、より一般的なサイノグラム再構成では、平行投影データに対し Ramp フィルタ（もしくはノイズ増幅を抑えるアポタイジングフィルタ）でフィルタリングした後、逆投影を行う、フィルタ補正逆投影法（Filtered back projection, FBP）とよばれるアプローチが一般的に利用されている[2]。

上記のように明示的なノイズモデリングをせず、単純な線積分モデル（Radon transform や X-ray transform とよばれる）を利用した解析的なモデルに基づいた方法では、一般的にノイズが増幅され空間分解能も悪化する傾向にある。

その後、より高度な統計的画像再構成手法が台頭してきた。1982年、Shepp と Vardi による期待値最大化（Expectation maximization, EM）を利用した最尤（Maximum likelihood, ML）再構成をテーマにした独創的な論文[3]では、Emission tomography の画像再構成分野に以下の2つの重要な技術が導入された。

- (1) サイノグラムデータのノイズをポアソン分布としてより正確にモデル化すること
- (2) 再構成画像の離散化とサイノグラムデータのイメージング物理を正確にモデル化すること

これら2つのモデリングの改善により、再構成画像の品質が劇的に改善したことが知られている。しかしこれらの改善があっても、MLEMは反復を増やすと再構成画像のノイズが増加するため、ノイズは依然として重要な課題であった。そのため、さらなる進歩を求めて、ポアソン尤度と同時に与えられた画像に対する事前確率を

---

\*1 浜松ホトニクス株式会社中央研究所

\*2 School of Biomedical Engineering and Imaging Sciences, King's College London, London, UK

a) 責任著者:

[fumio.hashimoto@crl.hpk.co.jp](mailto:fumio.hashimoto@crl.hpk.co.jp)

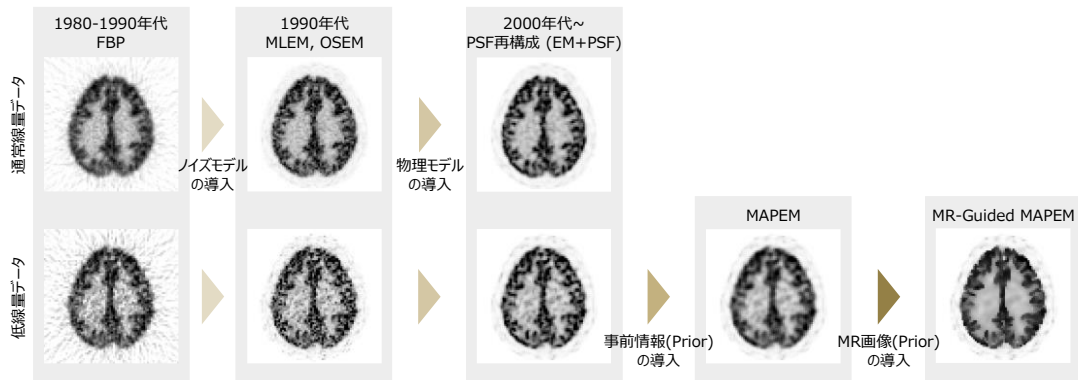


図1 深層学習登場以前のPET画像再構成の軌跡。単純なFBPから、MLEM（同一のイメージングモデル，ポアソンモデルの導入），物理モデリングの使用（ポアソンモデル，PSFの導入），正則化の使用（MAPEM），ガイド付き再構成までを時系列で示す。文献[16]のFigure1を改変。

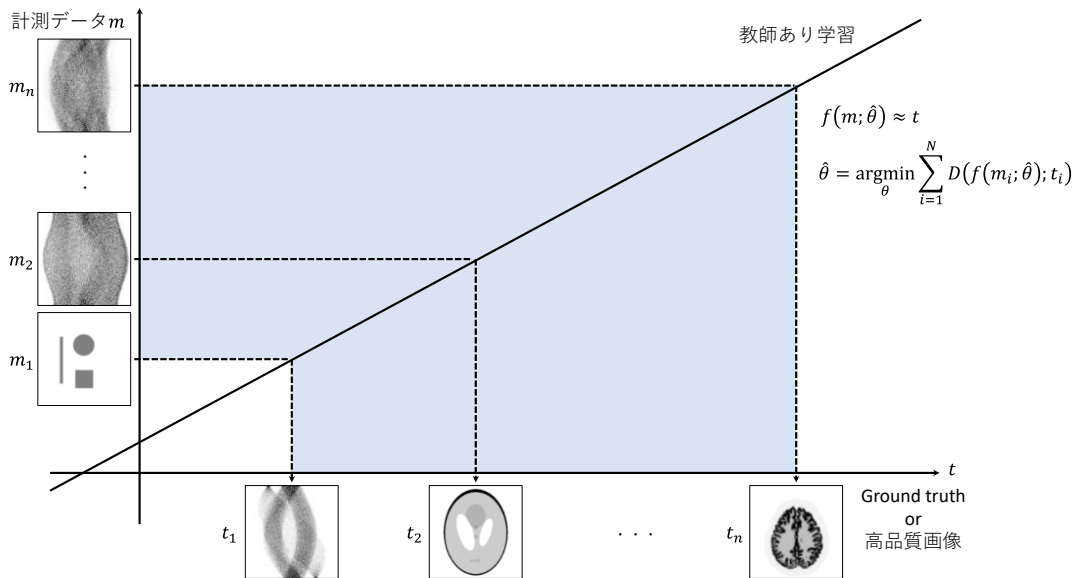


図2 計測データ（サイノグラム） $m$  から再構成画像  $t$  への高次元写像としての教師あり画像再構成の基本アイデア。例えば，図中のような計測データ-画像ペアを多数用意し学習させることで，青色の範囲の画像が獲得できる。

導入する，罰則付き（Penalized）ML法が提案された（これは，maximum a posteriori EM法やベイズ画像再構成ともよばれる）[4]。

ただ，ノイズを低減できたとしても空間分解能を向上させる技術は依然として必要である。おそらく一般的なPET画像再構成法の頂点は，PET画像再構成にガイド付き正則化

（regularization）を使用する方法である[5]。例えば，PETとMagnetic resonance imaging（MRI）の間でエッジが一致すると想定した場合，MRI

情報をガイドにすることで画像のエッジの空間分解能を向上させながらノイズ除去をすることが可能である。

図1に，深層学習登場以前の単純なFBPから，MLEM（同一のイメージングモデル，ポアソンモデルの導入），物理モデリングの使用（ポアソンモデル，PSFの導入），正則化の使用，ガイド付き再構成まで，PET画像再構成の軌跡を示す。このように，PET画像や物理，統計の厳密なモデリングによりPET画質が向上してきている。




図 3 AUTOMAP の概念図。




図 4 DeepPET の概念図。

## 2. 深層学習画像再構成の基本原

深層学習を利用した PET 画像再構成を行うためには、データを使って再構成アルゴリズムのさまざまな要素を学習する必要がある。原理上、画像再構成アルゴリズム全体は、入力と出力データの例を使用するだけでゼロから学習することが可能である。このとき、上記画像再構成アルゴリズムは入力ドメイン（測定データ）から出力ドメイン（再構成画像）への非常に高次元の回帰写像 (very high-dimensional regression mapping) をしているに過ぎない。図 2 に計測データ（サイノグラム）から再構成画像への教師あり画像再構成の基本アイデアを示す。例えば、図中のような計測データ-画像ペアを多数用意し学習させることで、青色の範囲の写像が獲得できる。言い換えると、このアイデアでは学習データセット群の範囲外の画像再構成ができないことを意味している。

初期の研究では、大量の学習データセット（100,000 以上の入出力サンプル）が必要であり、2次元 PET 再構成という限られた条件のもとで実施された。具体的には、automated transform by manifold approximation (AUTOMAP) [6] (図 3) や DeepPET [7] (図 4) の独創的な研究が深層学習を使った直接画像再構成の可能性を示した。

## 3. 深層学習画像再構成の反復法への応用

FBP や BPF のような従来の解析的画像再構成は、反復画像再構成の導入によって改良されていった。反復画像再構成法の主な利点は、システム行列（検出確率ともよばれる）を利用することによってイメージング物理モデルや、データにおけるノイズのより正確なモデルが組み込み可能な点である。これらは、ポアソンノイズモデルの場合には反復計算で求める必要があるが、ガウシアンノイズモデルの場合には原則として再構成を直接推定することが可能である。ただ現状の PET 画像再構成のような、自明ではないシステム行列モデルを使用した 3次元画像再構成やポアソンノイズモデリング、非負制約（ゼロ以下を許容しない制約）を使用するためには反復法でなければならない。これらの反復手法は再構成画像の滑らかさ、空間分解能、ノイズ特性といった特性を考慮した事前情報 (Prior) を導入したことで、性能の向上が顕著になった。

深層学習の登場に伴い、従来の反復画像再構成を強化するために深層学習がすぐに応用されていった。例えば、従来の反復画像再構成で使用されてきた Total variation やガイド付き quadratic penalty といった単純化された画像特性モデルに依存する代わりに、深層学習を利用することで PET 画像の確率密度関数をモデル化できる。

図 5 に統計的反復画像再構成に深層学習を組み込んだ方法の一例を示す。この方法では、MAPEM の枠組みを利用することで計測データとの整合性を図りながら (EM update)、畳み込みニューラルネットワーク (Convolutional neural network, CNN) によるノイズ低減を行う [8,9]。図 6 に、この方法で得られる具体的な再構成画像の例を示す。

## 3. Deep image prior を利用した画像再構成

大多数の深層学習 PET 画像再構成は、高品質な PET 画像データセットを学習させる教師あり学習を利用している。しかし、実際の医療現場では高品質な PET 画像を大量に用意するの

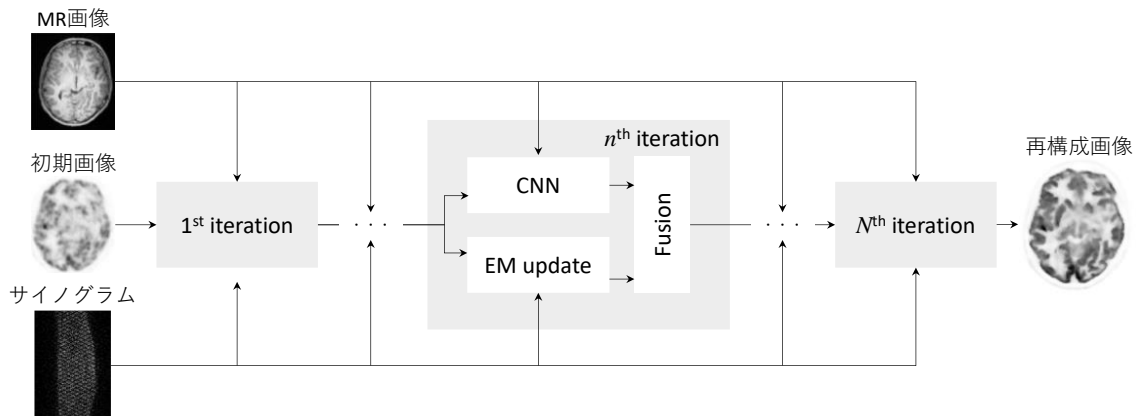


図 5 FBSEM-Net の概要図。MAPEM の枠組みを利用することで計測データとの整合性を図りながら (EM update), CNN によるノイズ低減を行う。




図 6 FBSEM-Net[8] (深層学習を利用した反復再構成法) の再構成画像の一例。© 2021 IEEE. Reprinted, with permission, from Mehranian et al. [8].

は難しく、学習データに含まれていなかった疾患や PET 薬剤に使用することは難しい。そこで最近では、Deep image prior (DIP) という教師なし学習技術を PET 画像再構成に応用する取り組みが多数報告されている[10-13].

DIP を PET 画像再構成に応用する最も単純な戦略は、深層学習の損失関数にイメージングモデルを導入する方法である。図 6 のように、CNN の出力画像に順投影演算をすることで、計測データ空間 (サイノグラム空間) での損失計算が可能となる[11]. 図 7 に再構成画像結果の例を

示す。この結果は、学習データセットがなくとも、深層学習を利用して高品質な画像再構成ができることを示している。ただし、これらの手法は通常の DIP と同様に、ノイズへの overfitting を避けるために反復を早期に停止することが必要である。

### 3. まとめ

本解説では、深層学習を利用した PET 画像再構成法についていくつか紹介した。本解説を読んで PET 画像再構成に興味を持った読者が、よ




図 7 Deep image prior を利用した画像再構成の例[11]. CNN の出力画像に順投影演算をすることで、計測データ空間（サイノグラム空間）での損失計算が可能になる. © 2022 IEEE. Reprinted, with permission, from Hashimoto et al. [11].

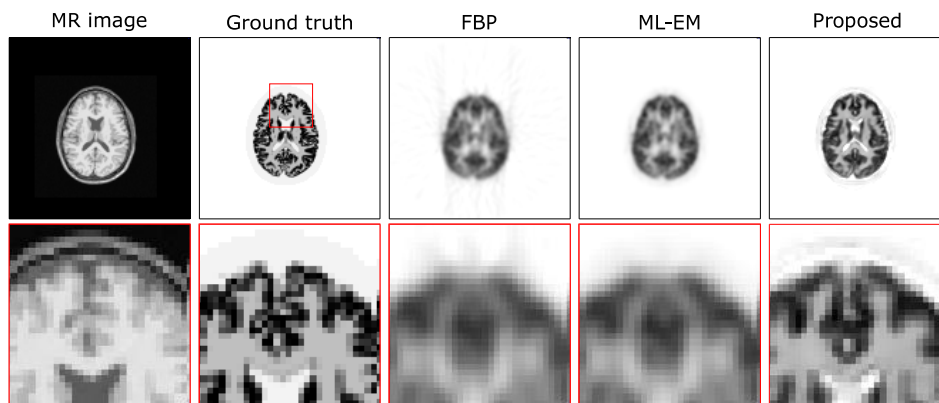


図 8 Deep image prior を利用した再構成画像の一例. © 2022 IEEE. Reprinted, with permission, from Hashimoto et al. [11].

り詳細な解説記事[9][14-16]を参考にして、PET 画像再構成の研究に従事してくれることを願う。

### 謝辞

本解説執筆にあたり貴重なご助言を賜った浜松ホトニクス中央研究所 大手希望氏に深謝いたします。本研究は JSPS 科研費 22K07762 の助成を受けたものです。

### 利益相反の有無

なし

### 文献

- [1] Chu G, K. Tam KC: 3-Dimensional Imaging in Positron Camera Using Fourier Techniques. Phys Med Biol **22**: 245, 1977
- [2] Reader AJ, et al: Intercomparison of four reconstruction techniques for positron volume imaging with rotating planar detectors. Phys Med Biol **43**: 823, 1998
- [3] Shepp LA, Vardi Y: Maximum likelihood reconstruction for emission tomography. IEEE Trans Med Imaging **1**: 113-122, 1982
- [4] Levitan E, Herman GT: A Maximum a Posteriori Probability Expectation

- Maximization Algorithm for Image Reconstruction in Emission Tomography. *IEEE Trans Med Imaging* **6**: 185-192, 1982
- [5] Mehranian A, et al: PET image reconstruction using multi-parametric anato-functional priors. *Phys Med Biol* **62**: 5975, 2017
- [6] Zhou B, et al.: Image reconstruction by domain-transform manifold learning. *Nature* **555**: 487-492, 2018
- [7] Häggström I, et al.: DeepPET: A deep encoder–decoder network for directly solving the PET image reconstruction inverse problem. *Med Image Anal* **54**: 253-262, 2019
- [8] Mehranian A, Reader AJ: Model-based deep learning PET image reconstruction using forward–backward splitting expectation–maximization. *IEEE Trans Radiat Plasma Med Sci* **5**: 54-64, 2021
- [9] Reader AJ, Pan B: AI for PET image reconstruction. *Br J Radiol* **96**: 1330-1333, 2023
- [10] Gong K, et al.: PET image reconstruction using deep image prior. *IEEE Trans Med Imaging* **38**: 1655-1665 2019
- [11] Hashimoto F, Ote K, Onishi Y: PET image reconstruction incorporating deep image prior and a forward projection model. *IEEE Trans Radiat Plasma Med Sci* **6**: 841-846, 2022
- [12] Hashimoto F, et al.: Fully 3D implementation of the end-to-end deep image prior-based PET image reconstruction using block iterative algorithm. *Phys Med Biol* **68**: 155009, 2023
- [13] Ote K, et al: List-Mode PET Image Reconstruction Using Deep Image Prior. *IEEE Trans Med Imaging* **72**: 1822-1834 2023
- [14] 橋本二三生, 他 : Deep learning PET 画像再構成への招待 *Med Imag Tech Under review*
- [15] Reader AJ, et al: Deep learning for PET image reconstruction. *IEEE Trans Radiat Plasma Med Sci* **5**: 1-25, 2020
- [16] Hashimoto F, et al: Deep learning-based PET image denoising and reconstruction: a review. *Radiol Phys Technol*, 2024. doi: 10.1007/s12194-024-00780-3

## Deep learning for PET image reconstruction: some current approaches

Fumio HASHIMOTO\*<sup>1</sup>, Andrew J. READER \*<sup>2</sup>

\*1 Hamamatsu Photonics K.K., Japan.

\*2 King's College London, London, UK.

Deep learning has long been applied to PET image reconstruction. In this brief review, we first cover a brief history of PET image reconstruction as well as a straightforward explanation of deep learning-based PET image reconstruction, from the basic ideas of deep learning reconstruction to some of the most recent research developments.

**Key words:** PET image reconstruction, deep learning

## 著者紹介



### 橋本 二三生 (はしもと ふみお)

2016年藤田保健衛生大保健学研究科修士課程了。千葉大学大学院融合理工学府博士後期課程在学中。浜松ホトニクス株式会社中央研究所研究員。診療放射線技師。

Radiological Physics and Technology 誌 士井賞 (2018年), Most Citation Award (2022年), 他受賞。日本医用画像工学会 (理事), 日本核医学会, 日本医学物理学会, 日本放射線技術学会, 各会員。医用画像処理, 特に PET 画像復元や画像再構成に興味がある。



### Andrew J. READER

Andrew J. Reader is a Professor of Imaging Sciences at King's College London, UK. He received his Ph.D. in medical physics from the University of London in 1999 on the subject of PET image reconstruction. Prior to joining the School of Biomedical Engineering and Imaging Sciences at King's College London in 2014, he was a Canada Research Chair at McGill University and the Montreal Neurological Institute for 6 years. He is an Associate Editor of IEEE TRPMS and has co-authored over 200 scientific outputs. His main research interests include PET-MR, multi-modal image reconstruction and medical image analysis, all now with a primary emphasis on exploiting deep learning.