

2. MRIの画像再構成技術の原理と研究開発, 臨床応用

宮坂 知樹^{*1}/舟山 慧^{*2}/玉田 大輝^{*2}/本杉宇太郎^{*3}
 森阪 裕之^{*2}/大西 洋^{*2}/寺田 康彦^{*1}

*1 筑波大学理工情報生命学術院数理物質科学研究群 *2 山梨大学医学部放射線医学講座 *3 甲府共立病院放射線科

ディープラーニングの技術をMRIへ応用した研究は活発に行われており、なかでも画像再構成は最も注力されている技術の一つである。しかし、ディープラーニングを用いた画像再構成と一口に言っても、アプローチの仕方はさまざまである。最も一般的なのは、自然画像処理でよく使われているように、大量の画像データなどを用意し、再構成に伴うノイズやアーチファクトを学習させて、これらを低減するアプローチであろう。一方で、昨今は、圧縮センシング(以下、CS)¹⁾やパラレルイメージングなどの高速化技術と組み合わせて利用するケースも増えており、よりMRIに特化したネットワークの開発も進んでいる。例えば、CSで行われる反復的な計算処理アルゴリズムを、ディープニューラルネットワーク(deep neural network: DNN)で置き換えたアーキテクチャも数多く報告されており、より高い性能を示すと期待されている。

本稿では、MRIの撮像時間の短縮を目的とするCSとディープラーニングを組み合わせた再構成技術に注目し、原理と臨床応用へ向けた研究開発について概説する。

CSとディープラーニング

CSとは、スパース性とインコヒーレントなサンプリングを利用して、少数のデータから反復計算により信号を復元する技術である。位相エンコードを間引いて信号を収集(アンダーサンプリング)することで、撮像時間の短縮が可能となるが、従来の反復処理による再構成には、処理時間が長いことやパラメータの決定が難しいといったデメリットがある。

一方で、ディープラーニングでは、学習データ(入力画像と教師画像のペア)を用いて、アンダーサンプリングに伴って生じるノイズやアーチファクトを除去するように、ネットワーク(関数)の適切な重みを事前に学習する。この学習には時間がかかるが、ひとたび重み係数を決めてしまえば、従来の反復計算に比べて短い時間での再構成を可能にする。さらに、ノイズやアーチファクトの除去性能も高いことが知られている。そのため、CSとディープラーニングのメリットを組み合わせることで、撮像時間と再構成の処理時間の短縮が実現できる。

ネットワークアーキテクチャ

MRIの画像再構成に用いられているDNNは、大きくデータ駆動型とモデルベースの2つに分類される²⁾。

MRIへの応用として最初に用いられたのは、データ駆動型である(図1 a)。

データ駆動型とは、大量のデータを用いて、ノイズやアーチファクトを学習させるDNNである。その中でも画像空間のみで学習を行うものとしては、ノイズ除去を目的としたDnCNN³⁾や、セグメンテーションを目的に提案され広く用いられているU-Net⁴⁾などが挙げられる。また、k空間データから画像空間へ直接変換を行うAUTOMAPや、k空間と画像空間を行き来して学習を行うKIKI-netなどもデータ駆動型である。

一方で、モデルベースとは、従来の定式化されたCSモデル[式(1)]と、DNNを組み合わせたアーキテクチャを持つネットワークを指す(図1 b)。

$$\hat{x} = \underset{x}{\operatorname{argmin}} \|F_u x - b\|_2^2 + \lambda R(x) \dots\dots\dots (1)$$

ここで、 \hat{x} は推定画像、 F_u はフーリエ変換とアンダーサンプリング、 x は求める画像、 b は測定したk空間データ、 λ はペナルティ定数、 R は正則化項である。CSでは、この最小化問題を反復的に計算して解を導き出すが、モデルベースのネットワークでは、第2項もしくは両項を畳み込みニューラルネットワーク(convolutional neural network: CNN)に置き換えている。モデルベースに分類されるネットワークとしては、deep cascadeやMoDL, Variational Network, ADMM-Netなどが挙げられる。

ここでは例として、MoDL⁵⁾についてもう少し詳しく解説を行う。先述したよ