

アーチファクト学習を導入した反復的再構成型 CNN による MR 圧縮センシング画像再構成

MR Compressed Sensing Image Reconstruction Introducing Artifact Learning in Unrolling Model based CNN

宮本 裕大[†] 伊藤 聡志[†]

Yuta MIYAMOTO[†] Satoshi ITO[†]

[†] 宇都宮大学大学院地域創生科学研究科

[†] Graduate School of Regional Development and Creativity, Utsunomiya University

1. はじめに

圧縮センシング(Compressed Sensing: CS)をMRIの撮像時間短縮に利用するCS-MRIでは反復処理を必要とするために画像再構成に多くの計算時間がかかる。近年、再構成時間の大幅な短縮と高画質化が期待できる方法として深層学習(Deep Learning: DL)の利用が大きな注目を集めている。DLを利用する画像再構成には様々な方法があるが、本研究では位相画像に対応可能な反復的再構成をモデルとするDLを利用し、この方式では初めてアーチファクトを学習するネットワークを導入した。本方法による再構成性能の改善について報告する。

2. CNNを利用した画像再構成

本研究では、MRIに応用した反復的再構成をネットワーク化したモデル(ISTA-Net)^[1]をもとに、図1に示す2種類の方法を提案する。橙色部分が従来法と異なる箇所であり、いずれも畳み込みConvおよび活性化関数ReLUを利用した改良である。入力信号に対して提案法①または提案法②を適用し、MR画像を得る。

- 提案法① 直列型アーチファクト学習 (図1 左側部分)
通常のISTA-Netに対してConv+ReLUからなる層群ALを直列的に接続し、目標画像との誤差成分推定する。
- 提案法② 並列型アーチファクト学習 (図1 右側部分)
ISTA-NetにおけるISTA処理と並行してConv+ReLUによる層群Rによって並列的に画像を再構成したのち、重み w による加重平均像を得る。




図1 提案法①および提案法②の概要

3. 画像再構成シミュレーション

学習およびテストにはIXIデータセット^[2]に含まれる絶対値画像を使用した。




図2 信号収集点分布

表1 信号収集点分布の詳細

信号収集法	1D ランダム
収集信号率	30%
連続収集行	30

学習には1000枚、テスト時には学習に使用していない30枚の画像を使用し、学習および再構成のテストにはGPU(NVIDIA GeForce RTX2080 SUPER)を使用した。信号は図2、表1に従って計算機内で間引き収集を行った。

従来法である通常のISTA-Netと、2種類の提案法を比較した。表2にPSNRおよびSSIM^[3]、図3には再構成像を示す。表2より、提案法はいずれも従来法の値を上回る結果となった。図3より、拡大図の黄色枠内を確認すると、従来法においてみられる縦に入る黒いアーチファクトが、提案法①において軽減され、提案法②においてはおおむね除去され、目標画像により近い構造の再現ができた。

表2 PSNR および SSIM (30 枚の平均値)

	従来法	提案法①	提案法②
PSNR [dB]	28.97±2.08	29.08±2.14	29.22±2.27
SSIM	0.919±0.012	0.921±0.012	0.923±0.013

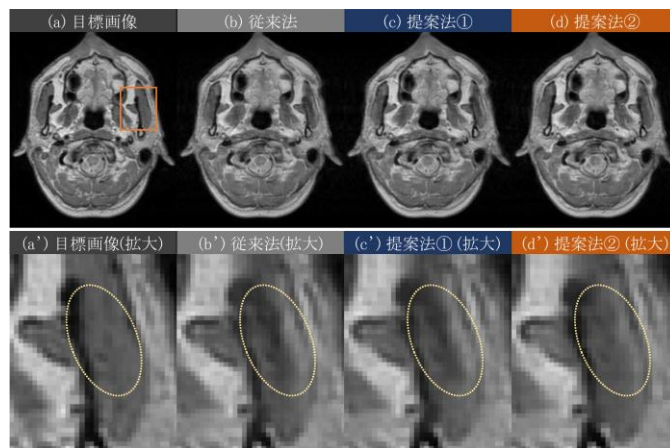


図3 各CNNによる再構成像比較

4. まとめ

反復的再構成をネットワーク化したモデルをもとに、アーチファクトを学習する直列型と並列型のネットワークを提案した。定量的評価および構造面で従来法を上回る結果が得られた。今後は他の深層学習再構成法においても同様の手法を施すことによる再構成性能の向上を図る予定である。

参考文献

[1] J. Zhang et al, IEEE CVPR, pp.1828-1837, 2018.
 [2] "IXIdataset", <https://brain-development.org/ixi-dataset/>
 [3] Z. Wang et al, IEEE Tran Image Proc, Vol.13, pp.600-612, 2004.