

DL技術の活用による前臨床fMRI用Zero TEイメージング高速化

Accelerating Zero TE Imaging for Preclinical fMRI Using Deep Learning Technology



藤田 直人¹, 寺田 康彦¹
¹筑波大学 理工情報生命学術院 数理物質研究群

研究背景・目的

Zero-TE imaging for functional MRI


- ✓ Zero Echo Time (ZTE) シーケンス
通常のMRIでは見ることのできない組織の信号を捉えられる→骨・肺イメージング, fMRI
- ✓ 特にfMRIでは経時的な信号変化による脳活動評価を行う→**dynamic撮像が必須**
- ✓ 高時間分解能のためには加速係数 (AF) が大きくする必要がある → **アーチファクトの描出**
高速化技術: Compressed sensing(CS), Parallel imaging(PI), **Deep learning(DL)**

本研究の目的

Deep learningを使用した高時間分解能撮像の実現

実験手法

データ間引き (アンダーサンプリング) による高速化



画像再構成問題とDLへの部分的拡張

画像再構成問題 (深層学習ベースL2正則化) [6]

$$x_{rec} = \underset{x}{\operatorname{argmin}} \left\| \sqrt{W_{\Omega}} (y_{\Omega} - F_{\Omega} x) \right\|_2^2 + \lambda \|x - D(x; \theta)\|_2^2$$

Data-consistency (DC) **DNN-based L2-Regularizer (R)**

x_{rec} Reconstructed image
 y_{Ω} Measured k-space in trajectory Ω
 F_{Ω} Non-uniform fast Fourier transform (NUFFT) operator in trajectory Ω
 W_{Ω} Density compensation in trajectory Ω
 $D(x; \theta)$ DNN denoiser parameterized by θ

- ✓ 深層学習ベース再構成では正則化項 (R) をDeep Neural Network(DNN)に置き換える
→ **既存の正則化項に比べてより柔軟で複雑な表現の獲得ができる**

ゼロショット自己教師あり学習

- ✓ 教師あり学習法の問題点 → 臨床ではアンダーサンプリング (US) が一般的フルサンプリング (FS) を含む教師ペアを準備できない

自己教師あり学習の登場: **USデータ (= 自己) から教師ペアを合成する手法**

自己教師あり学習 (SSL) Yaman et. al. (2020)

USデータ
複数枚を用意

教師ペア
を作成

利点
学習用データとして
USデータを使用できる

欠点
複数のUSデータを
別途用意する必要がある

ゼロショット自己教師あり学習 (ZSSSL) Yaman et. al. (2022)

実際に使用する
USデータを教師に
(学習枚数が0枚)
→ゼロショット
実使用時のUSデータ

教師ペア
を作成

利点
学習のためのデータを
別途用意する必要がある

欠点
テスト時に
毎回学習が必要

- ✓ 自己教師あり学習法の戦略 → **サブセットの片方をモデルのパラメータ決定用に使用する**





US k-space Ω

サブセット Λ

サブセット Θ

入力用

パラメータ決定用 (評価)



パラメータ θ を更新

適切に再構成できれば、同じ値をとるはず

再構成結果がネットワークに入力していない領域の観測値と一致するようにパラメータを決定する

実験条件

比較モデル: 提案手法 + ベースライン2種

1. **Gridding reconstruction**
2. **Conjugate gradient (CG法)**
3. **Non-cartesian ZS-SSL**

- 正則化はResidual Network(ResNet)を採用

実験 1: Non-cartesian 再構成法のみ評価


- 3D数値ファントム (Shepp-logan) を使用
- k-spaceの最大強度0.5%の複素ガウシアンノイズを加えてシミュレート
- Peak-signal to noise ratio(PSNR)にて数値評価

実験 2: Deadttime補完を含めたZTEシーケンスへの適用

- Bruker 9.4T MRI, 1chボリュームコイル
- TR=1.018ms, flip angle (FA) = 3°


実験結果

Simulation study



- ✓ 視覚的にも数値評価的にもZS-SSLが最も良い
- ✓ NUFFTは全体的にノイズレベルの高い印象
- ✓ CG法では、AF=8で特に強いアーチファクトが残存している
- ✓ ZS-SSLではこれらを効果的に除去

In-vivo study



- ✓ NUFFT, CG法に比べZS-SSLによる再構成画像の方がアーチファクト、ノイズ共に少なく、明瞭な画像が得られた。
- ✓ AF = 8においては、NUFFTはノイズが増大しているのに対し、ZSSSLでは増大が抑えられた。

結論・今後の展望

- ✓ ZS-SSLの性能はシミュレーションにおいて数値的、視覚的に高い性能
- ✓ Deadttime補完等を含めたZTEシーケンスにおいても同様に適用が可能
撮像されたIn-vivoデータにおいても同様に良好な撮像結果

今後の展望

- ✓ ネットワーク構造の最適化
- ✓ 時間方向のトラジェクトリ設計によるさらなる高速化
- ✓ 時間方向の正則化の組み込みによる再構成性能の向上