

2026年2月12日
卒業研究発表会

深層学習を利用した 三次元医用画像超解像における 学習時の計算削減

-知覚損失設計・モデル規模・学習入力設計の検討-

宮崎大学工学部工学科情報通信工学プログラム

西岡 駿

60222509

指導教員: 椋木 雅之 教授

研究背景と課題

3次元医用画像における高解像度化の必要性と障壁

理想

3次元医用画像

正確な診断のためには、腫瘍や血管の「立体的構造」と「連続性」の把握が不可欠

しかし「ハードウェア」での解決は困難

現実の壁

物理的制約

- 高性能機器の導入はコストが高額すぎる
- 撮像時間の延長は患者への身体的負担が大きい

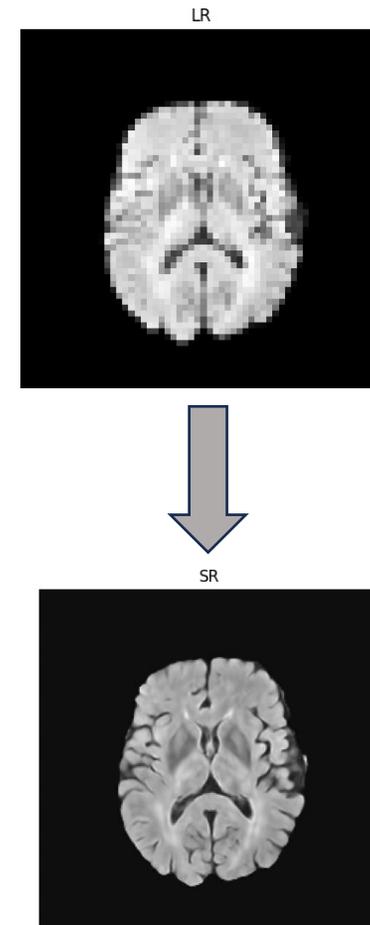
そこで「ソフトウェア（超解像）」が必要だ

既存手法1:二次元超解像

計算は軽いがスライス間の
奥行きの整合性が取れない
(血管が途切れたり、形状が歪んだり)

既存手法2:三次元超解像

立体構造は保てるが
計算コストが膨大すぎる
(メモリ不足・学習時間が長い)



■ 本研究の目的

高品質な 3次元超解像モデルを
品質を維持したまま計算量を削減する

実用的な学習時間・計算リソースでの運用を目指す

提案手法:計算削減へのアプローチ

3次元超解像における3つの学習にかかるコストの削減方針

1

知覚損失の近似

全スライス計算



ランダムサンプリング

計算時間を大幅に短縮

2

モデル規模の検討

RRDBブロック数の
調整と決定

性能飽和点を見極め
過剰な計算をカット

3

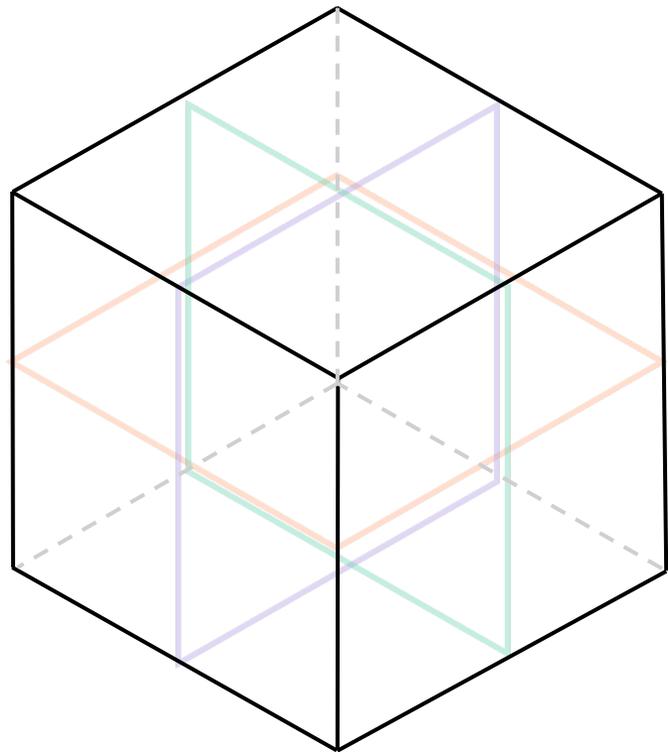
入力設計の検討

パッチサイズの
影響検証

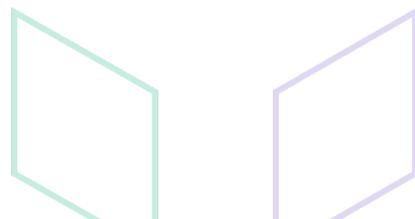
「三次元コンテキスト」と
「品質」の関係を調査

知覚損失:2.5D VGGについて

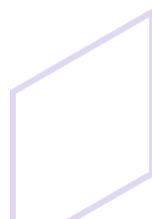
各平面ランダムサンプリングの概要



XY平面



XZ平面



YZ平面

知覚損失とは：

- 画素値のズレではなく人間の視覚的な印象を測る指標
- VGGなどの学習済みモデルを使い
人間が見てリアルな画像の生成を促す

VGG(知覚損失の計算モデル)：二次元の画像認識で高い性能を持つ標準的なモデル。入力は**二次元画像に限定される**

課題： 3次元データは**直接VGGに入力できない**
→ 3方向のスライス画像に分解して入力(2.5DVGG)

提案： ランダムサンプリングによる近似。
全スライスの計算は**膨大なコスト**がかかる。
→ スライスランダム抽出し知覚損失を近似計算する

入力設計の検討

パッチングについて

3Dパッチ学習とは

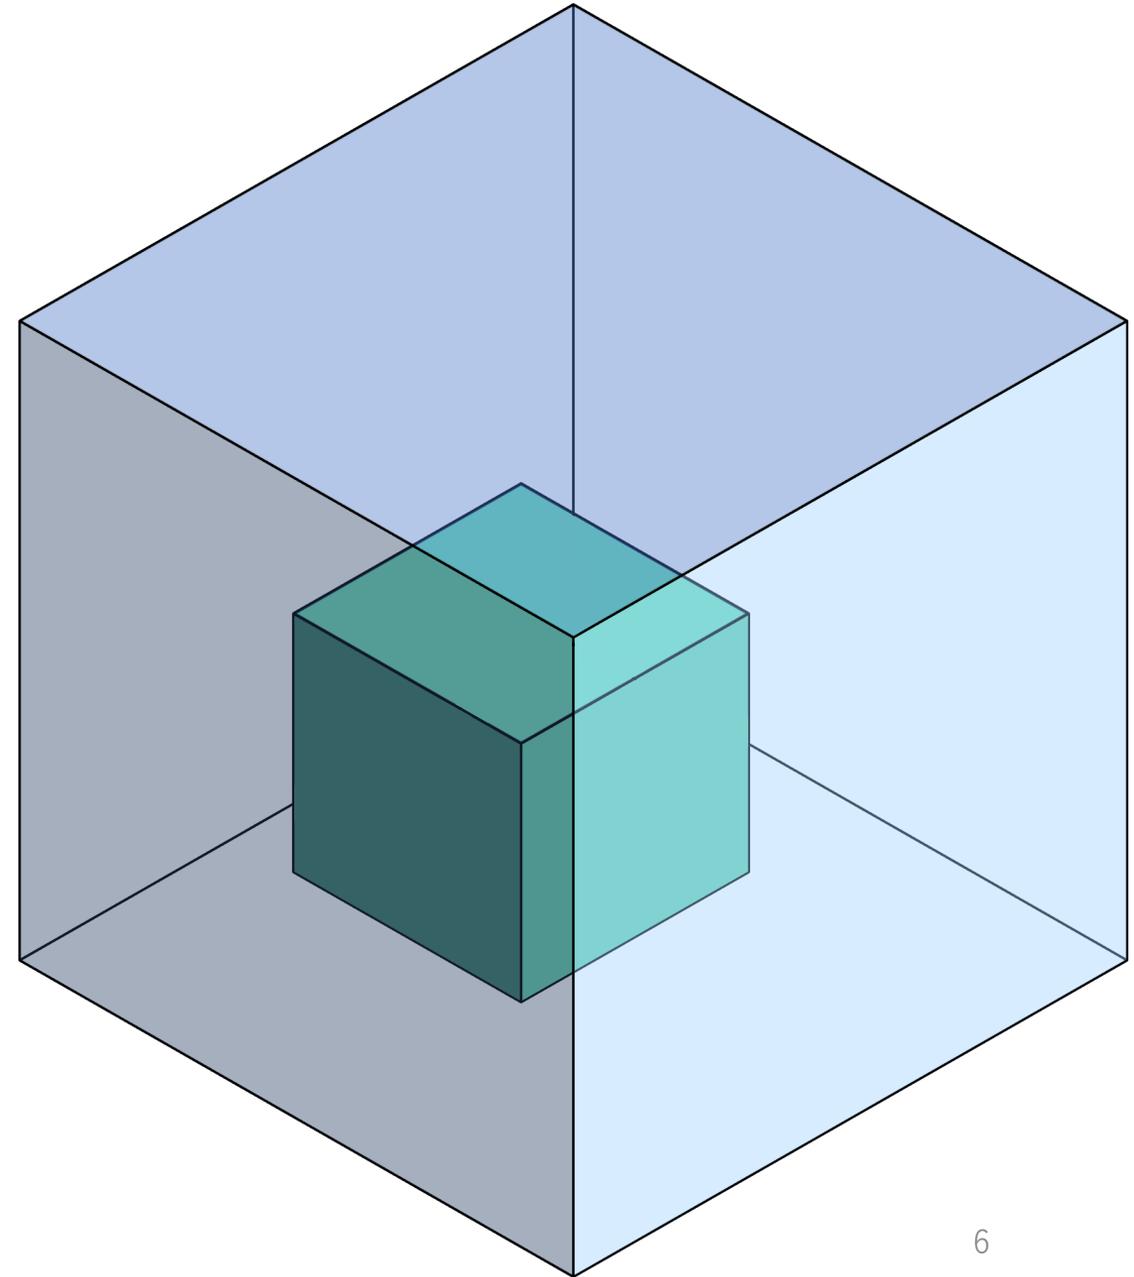
メモリ制約を回避するために、
巨大なMRI画像から**小さな立方体(パッチ)**
を切り出して学習させる手法

重要なトレードオフ

サイズを縮小しすぎると「**3次元コンテキスト**」
が欠損し、画質が劣化する
(周囲の構造との連続性がわからなくなる)

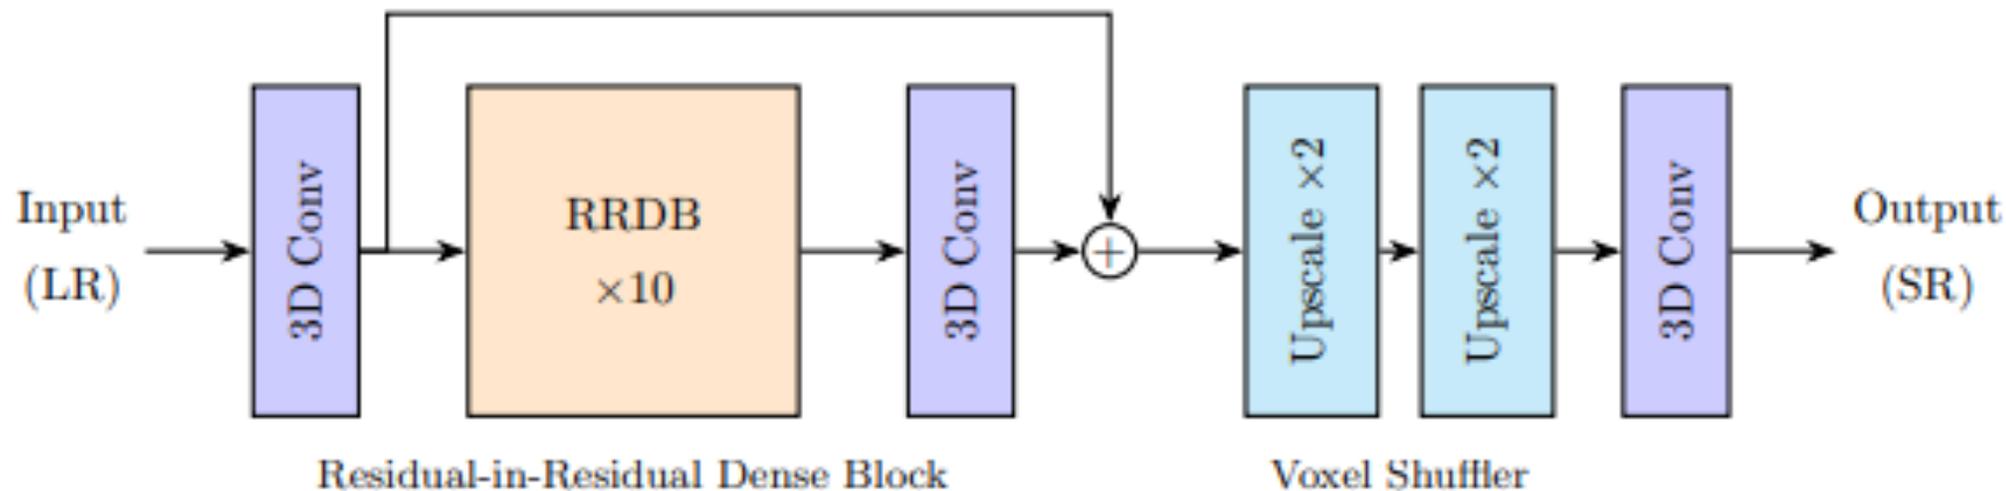
検証の目的

品質を維持しつつパッチサイズはどこまで
落とせるのかを検証し計算量の削減を図る



ネットワーク構造:3D RRDB-Net

Generator,Discriminatorおよび損失関数の設計



Generator構成

- 3D畳み込み+RRDBブロック×10
- 残差結合(Global Residual)
- Voxel Shufflerによる4倍スケールング

Discriminator構成

- 3D CNNによる真偽判定
- Adversarial Loss
- 生成画像のもっともらしさを評価

損失設計

$$\mathcal{L}_{total} = \mathcal{L}_{MSE} + (1 - SSIM) + 0.001\mathcal{L}_{adv} + 0.2\mathcal{L}_{vgg}$$

実験条件と評価指標

データセット、タスク設定、及び定量評価基準

データセット

使用データ

MSD Task01
Brain Tumour [1](MRI)

学習データ(Train)

484症例 × 8パッチ
= **3872**パッチ

テストデータ(Test)

266ボリューム
(フルサイズ)

タスク設定

倍率

4倍超解像

学習時 入出力

30_30_20→120_120_80

評価時 入出力

60_60_39→240_240_156

評価指標

信号忠実度

MSE ↓ : 画素値の誤差
PSNR ↑ : 信号対雑音比
SSIM ↑ : 構造的な類似度

知覚品質

LPIPS ↓ : 知覚的な距離

計算コスト

学習にかかった時間

実験結果:VGGサンプリング枚数の影響

計算コストと知覚品質(LPIPS)のトレードオフ検証

VGG Sampling (枚/平面)	MSE ↓	PSNR ↑	SSIM ↑	LPIPS ↓ (知覚品質)	Time/epoch [min]	Total Time (200ep) [h]
0枚 (VGGなし)	0.000284	35.79	0.9662	0.0584	5.16	17.23
10枚 (提案) Proposed	0.000307	35.47	0.9608	0.0324	8.75	29.24
Full (計320枚)	0.000313	35.45	0.9608	0.0289	16.64	55.53

知覚品質の劇的な改善

0枚(VGGなし)と比較しわずか10枚のサンプリングでLPIPSが大幅に改善した

提案手法の優位性

10枚サンプリングは,Fullに近い高品質を維持しつつ、計算コストを約半分に削減することができた

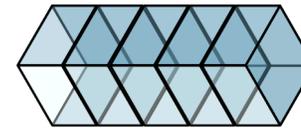
実験結果:モデル規模の影響調査

RRDBブロック数の調整と決定

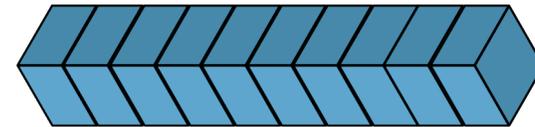


RRDBブロック

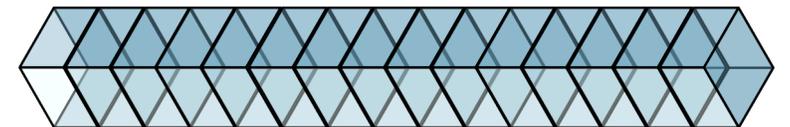
5



10



15

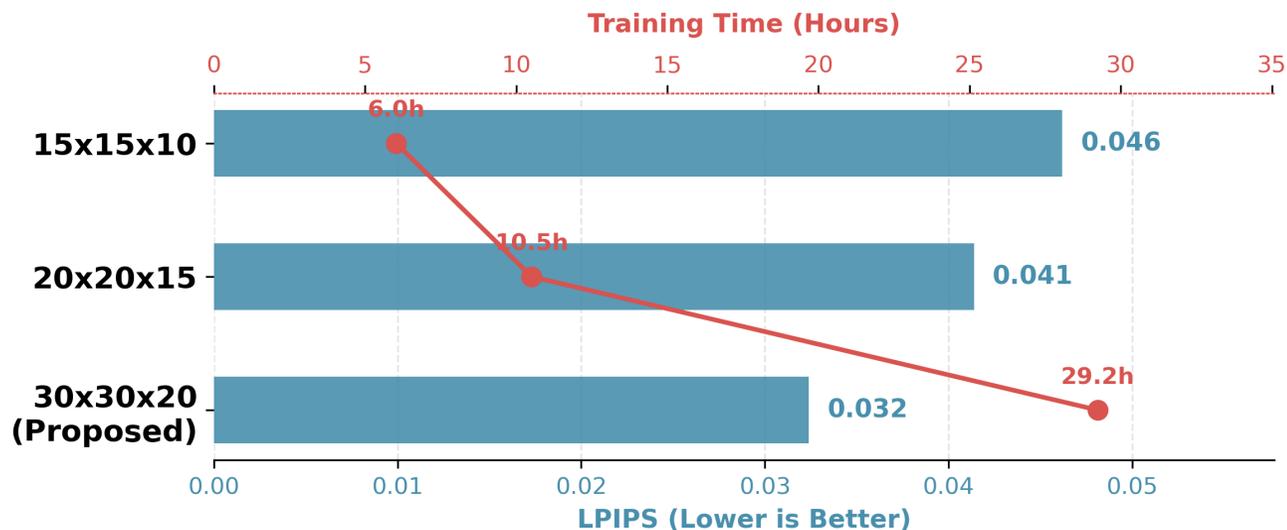


RRDBブロック数

5→10→15と増やすと知覚品質は向上するが差は僅差。
RRDB10が計算量を抑えつつ品質は良好

実験結果:入力設計の検討

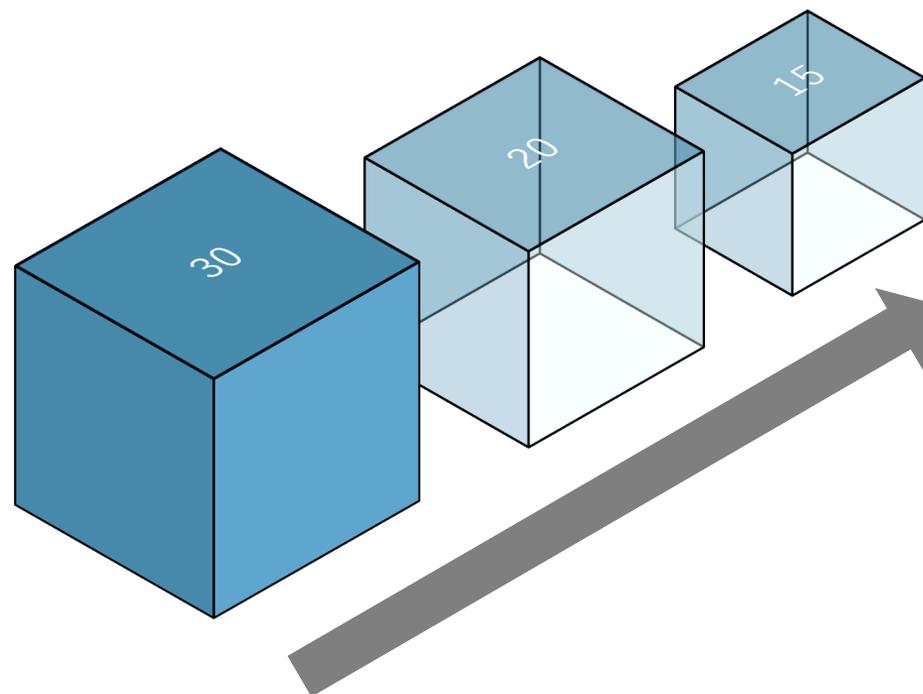
パッチサイズの影響検証



パッチサイズ

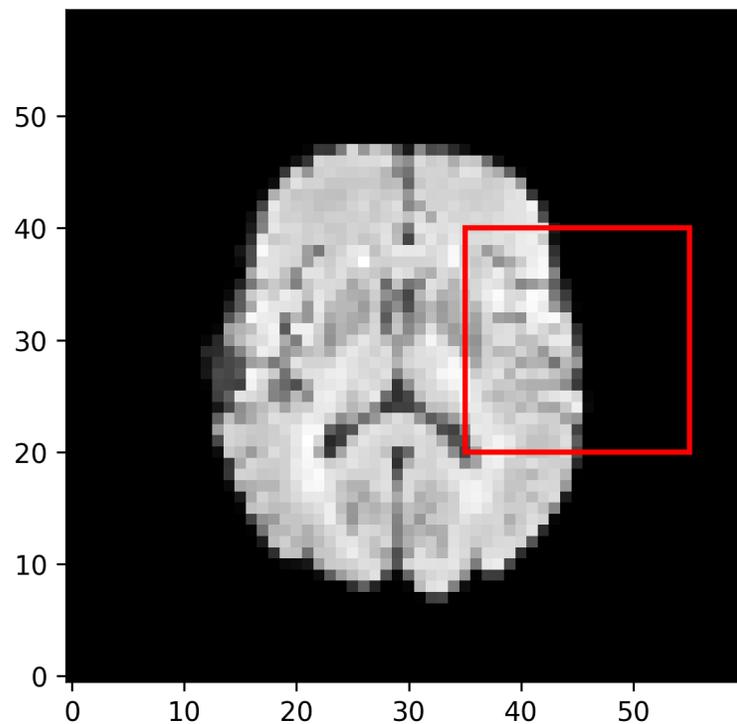
30 × 30 × 20(提案)から縮小するとLPIPSが大幅に悪化。

パッチサイズ比較



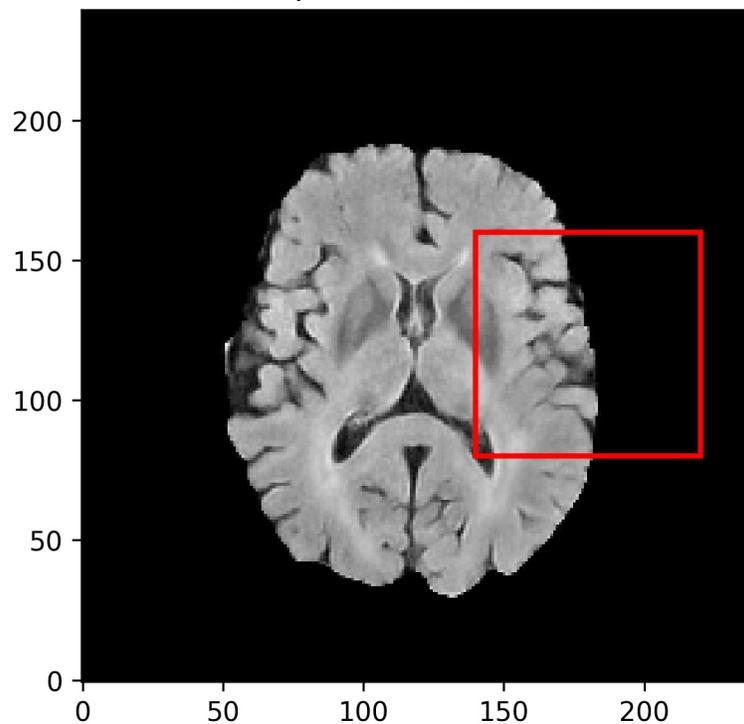
定性評価:提案手法の視覚品質

[LR] XY (idx=19)



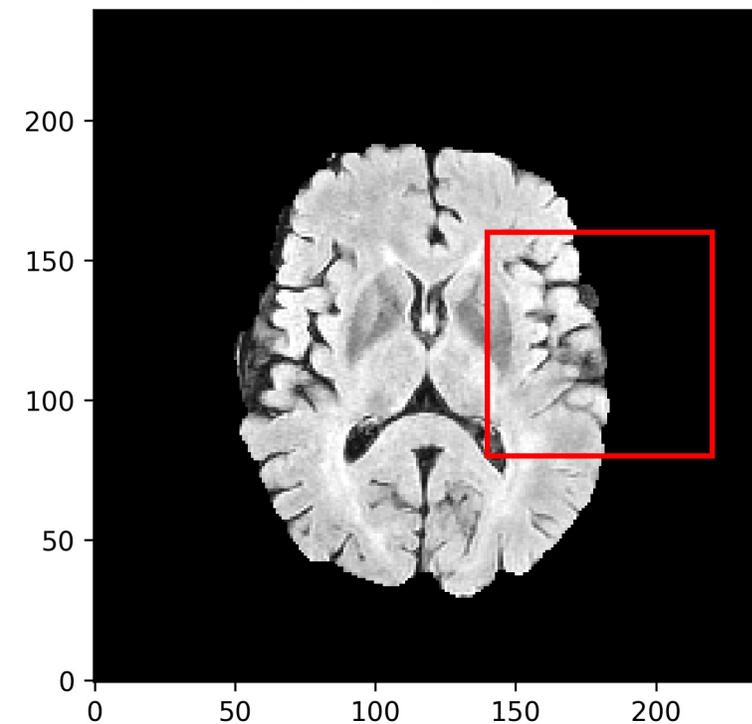
LR(低解像入力)

[Proposed] XY (idx=76)



提案手法

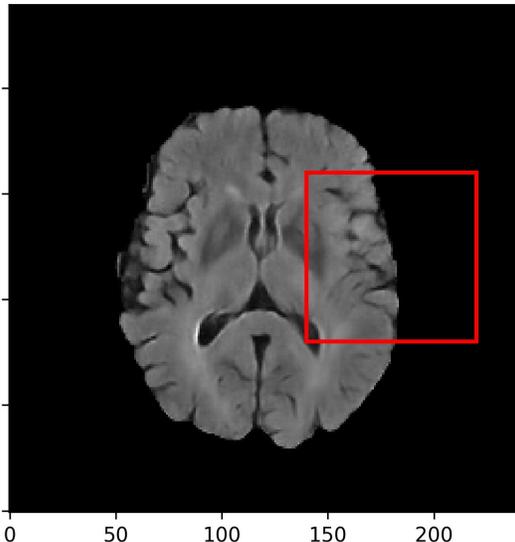
[HR] XY (idx=76)



HR(高解像度:お手本)

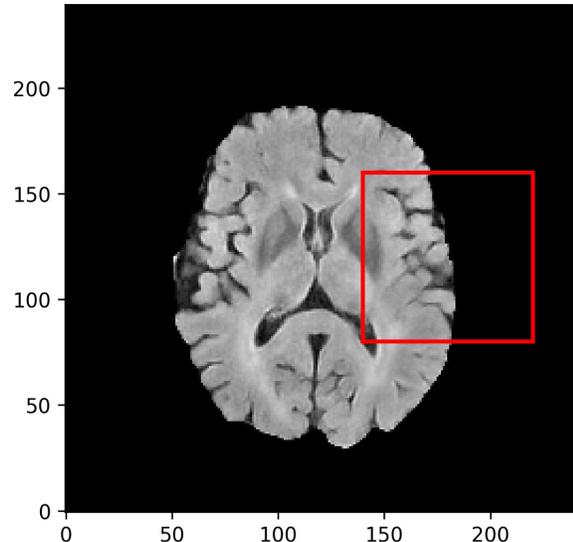
定性評価:視覚的品質の比較 (全体)

[Small Patch] XY (idx=76)



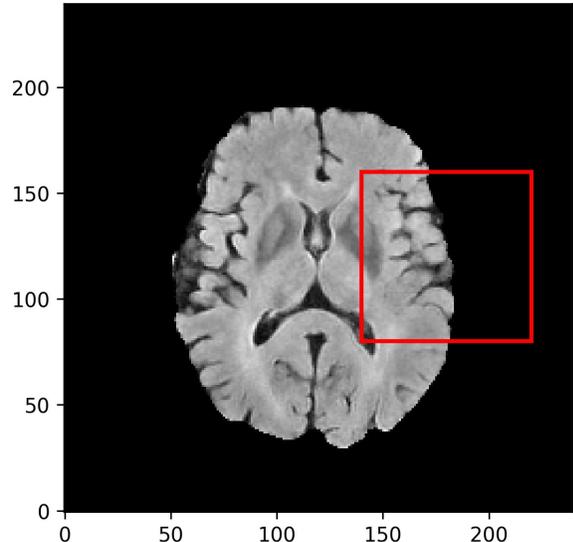
小パッチ学習

[Proposed] XY (idx=76)



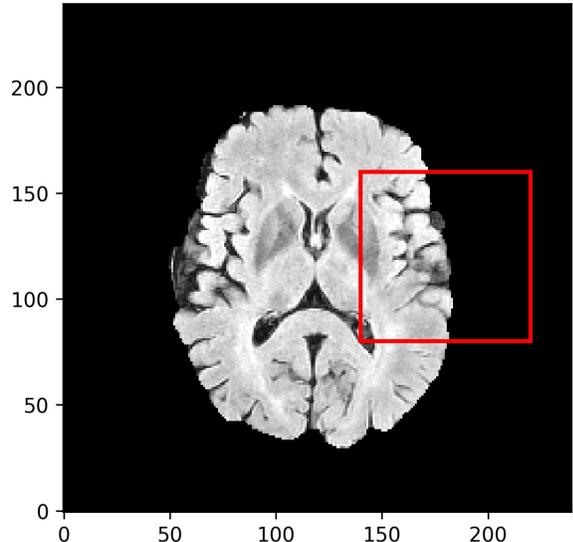
提案手法

[Full VGG] XY (idx=76)



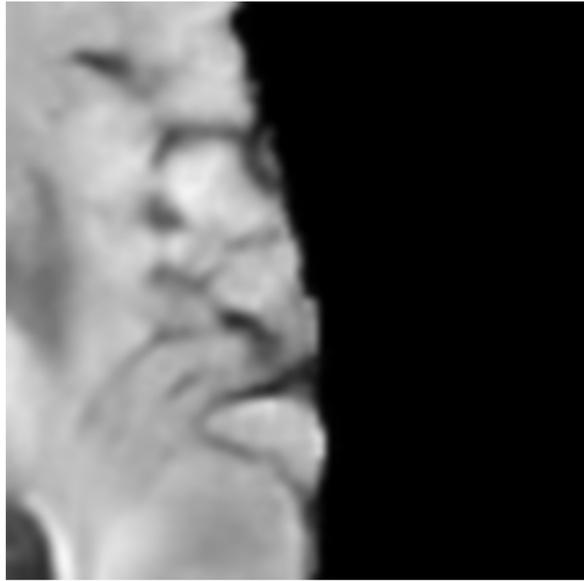
FullVGG

[HR] XY (idx=76)



HR画像(正解)

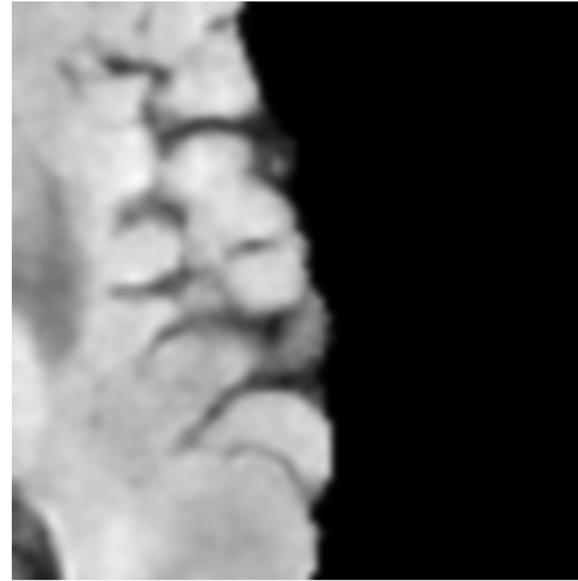
定性評価:視覚的品質の比較 (拡大)



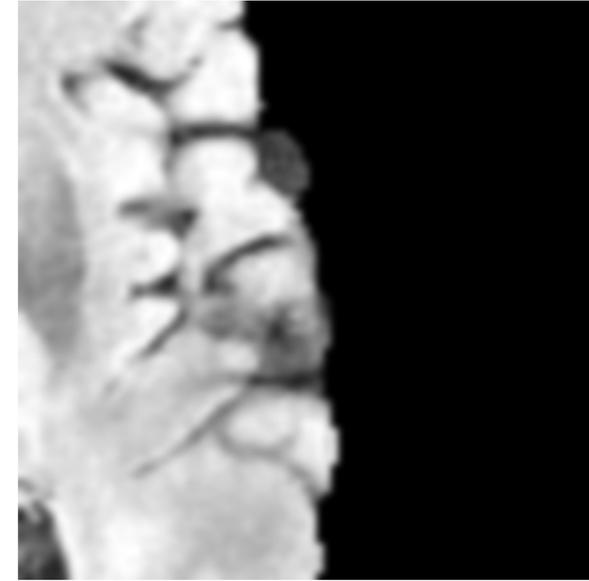
小パッチ学習



提案手法



FullVGG



HR画像(正解)

確認された事実

- 提案手法はFullVGGと遜色ない微細構造を復元
- 小パッチ学習モデルでは全体的に平滑化が残り、ぼやけて見える

総合考察: 3次元超解像における設計指針

計算コストと品質のトレードオフに関する検討結果

検討項目

提案モデルの仕様

決定の根拠(考察)

モデル規模
(RRDB Blocks)

10Blocks

15ブロックまで増やしても品質改善は限定的であった。
計算コストと性能のバランスが最も良好な
スイートスポットとして採用

学習入力設計
(パッチサイズ)

30 × 30 × 20

学習時に入力するパッチサイズの過度な縮小は
大幅な品質の低下を招く。「**3次元的な文脈(Context)**」
の確保が高品質化の生命線である

知覚損失計算
(VGG)

**ランダム
10スライス**

全スライス計算と比較して同等の品質を維持しつつ
計算時間を約半分に削減。ランダムサンプリングにより
ボリューム全体の特徴を十分に近似可能。

結論

3次元医用画像超解像における計算効率化を検討



- **知覚損失のランダムサンプリングが極めて有効であった**
フル計算に対し、品質を過度に落とすことなく学習時間を約半分に



- **3次元コンテキストの重要性を確認**
過度なパッチサイズの縮小は
コンテキスト不足で品質劣化を招くことを確認

意義: 計算資源の制約下における実用的な学習設計指針を提示

今後の課題

実臨床への応用を見据えた信頼性と汎用性の向上

ハルシネーションの抑制

- 01 生成モデル特有の「実在しない構造の捏造」リスク。
不確実性推定や整合性チェック機構などの導入により医療安全性を担保する

データセットの多様性確保

- 02 現在は脳MRIのみで検証。
他部位（腹部・胸部）やほかモダリティ（CT・PET）へ適用しモデルの汎用性を高める

実際の医師による臨床評価

- 03 数値指標だけでなく、放射線科医による読影実験の実施
「診断に資する画質か」という定性的な視点での検証を行うこと

参考文献

- [1]A. L. Simpson *et al.*, “A large annotated medical image dataset for the development and evaluation of segmentation algorithms,” *arXiv preprint arXiv:1902.09063*, 2019. (Medical Segmentation Decathlon)
- [2]J. Ha, N. Wang, S. Maharjan, and X. Zhang, “3D Volumetric Super-Resolution in Radiology using 3D RRDB-GAN,” in *Proc. IEEE Int. Symp. Biomed. Imaging (ISBI)*, 2024, pp. 1-5.
- [3]X. Wang *et al.*, “ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks,” in *Proc. ECCV Workshops*, 2018.