

Patch-wise 学習を用いた少量データによる脳 MRI 画像の超解像

生田薫平[†]彌富仁[†]大石健一[‡][†]法政大学 理工学部 応用情報工学科[‡]Department of Radiology and Radiological Science
Johns Hopkins University School of Medicine

概要

解像度の高い MRI 画像は、早期・正確な診断のために不可欠である。一方、解像度の高い画像の撮影には、機器や時間的な制約による困難を伴う。この問題に対するアプローチとして、近年 敵対的生成ネットワーク (GANs) を用いた超解像技術が高い精度を達成している。しかし、GANs の学習は多量のデータを必要とするため、撮影が難しい高解像度の MRI 画像で学習することは困難であった。本研究では 3 次元 MRI 画像を小領域に分割して学習・推論を行う Patch-wise 学習および、その際に発生するノイズを抑制する独自の学習の工夫により、極めて少量の 3 次元学習データのみから高精度な超解像を実現した。

1 はじめに

医療現場において、解像度の高い MRI 画像は傷病の早期発見や正確な診断、コンピュータによる定量的な解析に役立つ。しかし、高い解像度の画像を撮影するためには、高価・大型な撮影設備と長い撮影時間が必要であるため、臨床の現場で撮影するのは現実的でない。この問題に対するアプローチとして、比較的撮影が容易である低解像度の画像を入力とし、対応する高解像度の画像を出力する超解像技術が注目されている [1]。一般の 2 次元画像の超解像においては、近年の画像認識分野で大きな発展を遂げている深層学習、特に敵対的生成ネットワーク [2] を用いた SRGAN [3] や ESRGAN [4] が提案され、高い精度を達成している。

一方で 3 次元 MRI 画像に対しては、学習に大量のデータが必要であるという GANs 特有の性質から、GANs による超解像手法を直接適用するのは困難であった。Sánchez ら [5] は撮影が容易である 3 テスラ機で撮像された画像を大量に用い SRGAN を適用することで、脳 MRI 画像に対する GANs ベースの超解像適用の可能性を示した。しかし、この成果は自身のデータ

A Patch-wise Learning for Super-resolving 3D MR Images with a Small Amount of Data

[†]Kumpei IKUTA, Hitoshi IYATOMI (Hosei University) and
[‡]Kenichi OISHI (Department of Radiology and Radiological Science Johns Hopkins University School of Medicine)

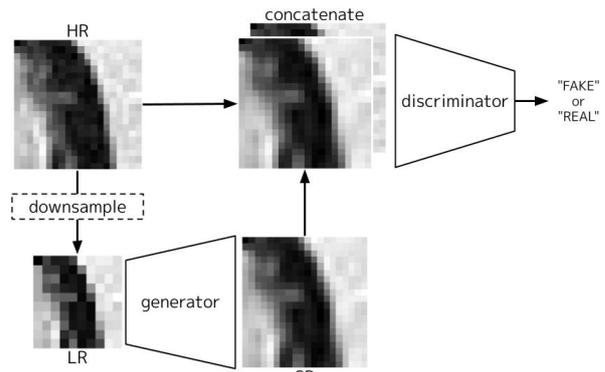


図 1: ネットワーク構造

をダウンサンプルしたデータに対する高解像度化の試みであり、7 テスラ機で得られるような本質的な高解像度化を目指す研究は、必要となる大量の教師データの入手困難もあり未だ達成されていない。そこで本報告では、極めて少量の画像からでも十分な解像度の向上を達成するため、1 つの MRI 画像を複数の小さな領域に分割して超解像ネットワークの学習を行いつつ、分割に伴い発生するノイズを抑制する Geometry-guided 学習を提案する。実験により、学習データと同一のデータセットからサンプルした MRI 画像に対する超解像画像および、学習に用いないテストデータから生成した超解像画像に対し、医師による視覚的な評価を行い、本手法の有用性を検証する。

2 Geometry-guided Patch-wise 学習

提案手法は、高解像度 3 次元 MRI 画像による学習を効果的に行うことで、得られる学習データが極めて少ない状況においても高精度な超解像を目指すものである。超解像の基本アーキテクチャとして ESRGAN を用いた。ESRGAN は、低解像度 (LR) 画像を入力とし、対応する超解像 (SR) 画像を出力する生成器ネットワークと、入力された画像が元の高解像度 (HR) 画像か SR 画像かどうかを識別する識別器ネットワーク

からなり、両者を交互に学習させることで超解像処理を実現する。ただし、ESRGANでは誤差関数の計算に一般物体認識用データセットのImageNet [6]で事前学習を行ったVGG-19 [7]モデルの特徴量を用いており、3次元MRI画像の特徴量を計算することはできないため、VGG-19と同様の構造のオートエンコーダを事前学習させることによって特徴抽出器とした。

小領域への分割 7テスラ機で撮像された、高解像度な $384 \times 384 \times 384$ pixelsの学習用画像から、ランダムな位置より $20 \times 20 \times 20$ pixelsの領域を1症例あたり1000領域切り出し、これをHR画像とした。小領域の切り出しの際、脳組織が全く写っていない領域と、鼻孔・耳孔内の空気によりノイズが生じている領域は避けるように選択した。さらに、切り出されたそれぞれの小領域を、スプライン補間を用いて $10 \times 10 \times 10$ pixelsのLR画像に縮小し、対応するHR画像とLR画像のペアを学習データとした。

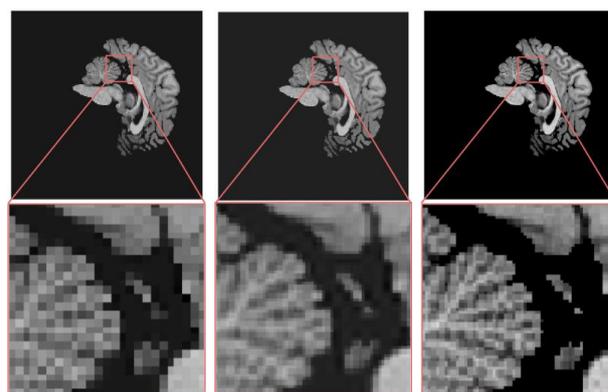
位置情報の付与によるノイズの抑制 本研究のアルゴリズムでは、分割されたそれぞれの小領域を独立に処理するため、単純にそれぞれの超解像を行って結合すると、小領域ごとにトーンが異なるノイズが生じてしまう。そのため、生成されたSR画像とHR画像を同時に識別器に入力することで、どの小領域を処理しているのかを暗的に識別器へ入力し、ノイズの抑制を行う。全体のネットワーク構造の概略図を図1に示す。

3 結果と考察

実験として、forrestデータセット¹ 20症例のうち、18症例を学習データ、2症例を検証データとしESRGANとPatch-wise学習による超解像を行った。検証データにおけるSR画像と、入力LR画像およびターゲットのHR画像との比較を図2に示す。なお、学習・推論の際には前処理として頭蓋骨の除去および輝度の正規化を行なった。さらに、学習に用いていないADNI²データセットのMRI画像数例をテストデータとし、超解像を適用した結果を図3に示す。いずれの実験においても、SR画像はLR画像に比べ視覚的な改善が医師により確認された。

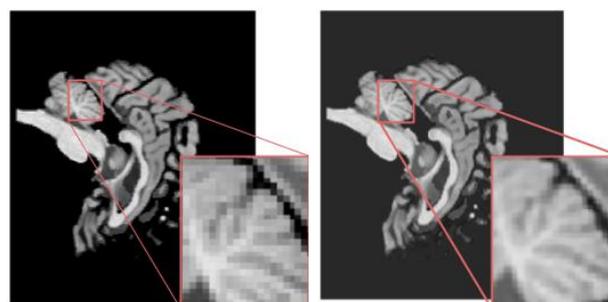
4 おわりに

Geometry-guided Patch-wise学習によるMRI画像に対する超解像が、少量の学習データしか得られない状況において有効であることが示唆された。さらなる精度向上のため、今後はより良い特徴抽出器の構造や、効率的なデータ拡張の導入について検討する必要がある。



(a) LR 画像 (b) SR 画像 (c) HR 画像

図 2: 検証データにおける超解像結果の比較



(a) LR 画像 (b) SR 画像

図 3: テストデータにおける超解像結果の比較

参考文献

- [1] H. Greenspan, "Super-resolution in medical imaging," *The Computer Journal*, vol. 52, no. 1, pp. 43–63, 2008.
- [2] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial nets," in *Advances in neural information processing systems*, pp. 2672–2680, 2014.
- [3] C. Ledig, L. Theis, F. Huszár, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, et al., "Photo-realistic single image super-resolution using a generative adversarial network," in *IEEE Proc. CVPR*, pp. 4681–4690, 2017.
- [4] X. Wang, K. Yu, S. Wu, J. Gu, Y. Liu, C. Dong, Y. Qiao, and C. Change Loy, "EsrGAN: Enhanced super-resolution generative adversarial networks," in *Proceedings of the European Conference on Computer Vision (ECCV)*, pp. 0–0, 2018.
- [5] I. Sánchez and V. Vilaplana, "Brain MRI super-resolution using 3d generative adversarial networks," *CoRR*, vol. abs/1812.11440, 2018.
- [6] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *IEEE Proc. CVPR*, pp. 248–255, 2009.
- [7] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *CoRR*, vol. abs/1409.1556, 2014.

¹<https://www.openfmri.org/dataset/ds000113/>

²<http://adni.loni.usc.edu>