

脳MRI画像における3次元オートエンコーダーによる 特徴抽出時の中間表現の改善

藤山真悟[†] 音賀優颯[†] 新井颯人[†] 茶山祐亮[†] 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

MRI (magnetic resonance imaging) 画像を用いた類似症例検索の実現ためには、症例ごとの要素数が大きい元の特徴を維持した上での次元圧縮が必要不可欠である。我々はこれまで約500万要素(次元)からなる脳MRI画像データを、3D-CAE (3D convolutional autoencoders) によって神経科医が着目する特徴を保持しつつ150次元への圧縮を実現したが、得られた特徴表現には改善の余地が残されていた。本研究では、 γ 補正を元にした輝度値の標準化、ResNet構造および、構造特徴の再現に重点を置いた誤差関数の導入を行い、得られる再構成画像の改善を試みた。評価実験における定量評価および視覚的評価により改善を確認した。

1 はじめに

脳疾患の診断にMRI (magnetic resonance image) が広く使用され、多大な数の撮影画像が様々な患者情報と共に記録されている。これらは診断支援を目的とした再利用も行われており、その際必要となるのがデータ検索技術である。現在、文字列をキーに用いるデータ検索方式が用いられているが、適切なキーの指定には豊富な知識や経験を必要とするため容易ではない。そのため、撮像した画像をキーに使用する検索技術であるcontent based image retrieval (CBIR) の実現が望まれている [1]。しかし、現在の脳MRI画像は1,677万要素から構成され、CBIRのためのクラスタリングには次元削減が必要である。そこで、我々はCBIRのための特徴抽出法として3D-CAE (3D convolutional

autoencoders) による脳MRI画像の次元削減法を提案した [2]。3D-CAEは脳MRI画像を150次元まで情報を圧縮しても重要な脳構造をある程度保存していたが、CBIR用途のためには改良の余地が残されていた。本研究では、(1)撮影環境による症例ごとの輝度値の差を補正するために γ 補正による前処理の導入、(2)3D-CAEにresidual network (ResNet) [3]の構成要素であるresidual feedback構造の導入、(3)3D-CAEが構造的特徴により注目するように評価指標SSIM(structural similarity)[4]を利用した損失関数導入を行い、得られる中間表現の改善を試み、再構成画像による定量評価を行った。

2 手法

2.1 データセット

本研究ではMRIによって撮影された患者の3次元脳画像のデータセットであるADNI2¹を使用した。まず、訓練用画像として正常 (Amyloid-negative cognitively normal: CN) 360症例とアルツハイマー型認知症 (Amyloid-positive Alzheimer's disease: AD) 290症例を使用し、テスト用画像として早期認知機能障害 (early mild cognitive impairment: EMCI) 147症例を使用した。そして実験に用いたすべての画像に対し、MRICloud²を用いた前処理により撮影画像より頭蓋骨の除去と脳の形状および大きさの整形を行った [5]。また、本研究では、近年の機械学習分野でMRI画像を扱う研究と同様に各辺を半分のサイズにした上で、対象外領域を削除しデータサイズを80×96×80 pixelsにしたものを使用した。

2.2 3D-CAE アーキテクチャ

本研究ではEncoderとDecoderそれぞれで4段階の畳み込み処理とプーリング処理を行うモデルを使用し

¹<http://adni.loni.usc.edu/datasamples/mri/>

²<https://www.MRICloud.org>

Improvement of Feature Embedding for Brain MRI with 3D-CAE

[†]Shingo FUJIYAMA, Yuto ONGA, Hayato ARAI, Yusuke CHAYAMA, Hitoshi IYATOMI (Hosei University)

[‡]Kenichi OISHI (Department of Radiology and Radiological Science, Johns Hopkins University School of Medicine)

{shingo.fujiyama.5a@stu., iyatomi@}hosei.ac.jp

表 1: EMCI に対する復元精度比較

Model	RMSE [%]	SNR [db]	SSIM
従来 CAE	7.00	9.81	0.920
Res-CAE	6.83	10.21	0.926
Res-CAE + γ 補正	6.15	10.52	0.931
Res-CAE + γ 補正 + SSIM	6.09	10.63	0.932

た. Encoder は 614,400 要素の入力画像を 150 次元に圧縮し, Decoder は圧縮された特徴表現から入力画像と同次元の再構成画像を出力する. さらに, 画像認識分野において高い認識精度を達成している ResNet の residual feedback を適用した 3D-CAE アーキテクチャを構成し, 従来モデルの精度との比較を行なった.

2.3 γ 補正による前処理

MRI の 3 次元脳画像の輝度値分布は撮影時に医師や技師により決定される. 本研究では症例ごとの輝度値のばらつきによる影響を最小限とするため, 画像 x の平均値 \bar{x} , 統一する平均値 μ としたとき, 画像ごとに $\gamma = \frac{\mu}{\bar{x}}$ を用いて $|\bar{x} - \mu| < \epsilon$ を満たすまで再帰的に γ 補正を行い, 各症例の平均輝度の統一化を図った. 目標とする輝度値 μ は予備実験により決定した.

2.4 SSIM を用いた損失関数

先行研究では 3D-CAE の損失関数に平均二乗誤差 (mean square error: MSE) を用いていた. 本研究では再構成画像の精度向上のため, 構造的特徴をより再現するため, 画像間の相関に着目した評価指標である構造類似性 (structural similarity: SSIM) [4] を損失関数とし学習を行った.

3 結果と考察

学習データに含まれない早期認知機能障害 (EMCI) の症例に対する復元精度を表 1 に示す. 評価は RMSE, SNR, SSIM によって行った. また, それぞれの再構成画像を図 1 に示し, 図 1 における画像の脳室上の輝度プロファイルを図 2 に示す.

まず, residual feedback を追加した結果 (ResCAE) は, RMSE, SNR, SSIM すべての評価指標において従来モデルの精度を上回ることが確認できた. また, γ 補正の追加でもすべての評価指標で改善が確認でき, 図 1 から, 視覚的に改善が確認できる. これは, γ 補正による輝度平均値の統一化の副産物として, 画像のコントラストが強調され明暗差がはっきりしたことによるものだと考えられる. 損失関数を SSIM に変更することでもすべての改善を確認できた. 図 1,2 より, 輝




図 1: 再構成画像例の比較




図 2: 再構成画像例の輝度プロファイル

度の相関のような変量を損失関数とした SSIM を用いることで, 従来の MSE を使用したモデルと比較してコントラストがさらに明確になり, 元画像の輝度の濃淡をより詳細に再現できている.

4 まとめ

本研究では, 3 次元脳画像を用いた類似症例検索システムのための特徴抽出法における中間表現の改善方法を提案した. 結果, 定量的評価から再構成画像の精度向上を確認し, 中間表現の改善を達成した.

参考文献

- [1] S. Murala and Q. J. Wu, "Local mesh patterns versus local binary patterns: biomedical image indexing and retrieval," *IEEE Journal of Biomedical and Health Informatics*, vol. 18, no. 3, pp. 929–938, 2014.
- [2] H. Arai, Y. Chayama, H. Iyatomi, and K. Oishi, "Significant dimension reduction of 3D brain mri using 3D convolutional autoencoders," *IEEE Proc. EMBC*, pp.5162-5165, 2018.
- [3] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *IEEE Proc. CVPR*, pp.770-778, 2016.
- [4] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Trans. Image Processing*, vol. 13, no. 4, pp. 600–612, 2004.
- [5] X. Tang, K. Oishi, A. V. Faria, A. E. Hillis, M. S. Albert, S. Mori, and M. I. Miller, "Bayesian parameter estimation and segmentation in the multi-atlas random orbit model," *PLoS one*, vol. 8, no. 6, p. e65591, 2013.