

類似症例検索のための3次元脳MRI画像における 解釈性の高い低次元表現の獲得

西牧慧[†] 生田薫平[‡] 彌富仁[†]

[†]法政大学 理工学部 応用情報工学科 [‡]理工学研究科 応用情報工学専攻

1 概要

脳神経領域の診断支援のため、脳MRI画像を対象とした類似症例検索 (CBIR) 技術の実現が望まれている。3次元脳MRI画像は高次元情報であるため、CBIRの実現には病気の特徴を保持しつつ解釈性の高い低次元表現の獲得が必要である。しかし、従来の手法により得られる低次元表現は解釈性に乏しく、信頼性などに課題が残されている。本報告では、 β -変分オートエンコーダ (β -VAE) により得られる低次元表現の各次元が脳の局所領域を表現する制約を導入することで、得られる低次元表現に独立性と解剖学的解釈性をもたせることができる Localized-VAE を提案する。

2 はじめに

3次元脳MRI画像は要素数の大きい高次元データであるため、Content-based image retrieval (CBIR)[1]の実現のためには疾病の特徴を保持した状態での次元削減が必要である。これまでに、3D-Convolutional Autoencoder (3D-CAE) を用いて疾病の特徴をある程度保持しながら約500万次元から150次元までの圧縮を実現する手法[2]や、3D-CAEと距離学習を用いて、病徴を反映した低次元表現を獲得する手法[3]が考案されている。しかし、これらの次元削減手法では、獲得した低次元表現の可読性は考慮されておらず、CBIRにおいて重要なモデルの解釈性や信頼性に課題が残されていた。実用的なCBIRを実現するためには、病徴情報を保持し、低次元表現の各次元が独立した上で、医学的な知見に基づく脳の局所領域に対応するといった可読性の高さを有していることが望ましい。

本報告では、これらの要件を満たすために低次元表現

の各次元が独立した正規分布になるような学習を行う β -変分オートエンコーダ (β -VAE)[4] を元に、低次元表現の各次元の影響を局所化する独自の制約を追加したエンコーダである Localized-VAE を提案する。Localized-VAE は、低次元表現の各次元の独立性が高く、それぞれが $N(0, 1)$ に近い分布を持ち、3次元脳MRI画像の局所領域に対応するような低次元表現を獲得できる。提案する Localized-VAE により得られる低次元表現の表現能力および局所性についての比較・評価を行った。

3 方法

3.1 データセットと前処理

本報告では Alzheimer's Disease Neuroimaging Initiative-2 (ADNI2)¹ のデータセットの内、Cognitively normal (CN) 1,121 例、Alzheimer's disease (AD) 674 例、Mild cognitive impairment (MCI) 926 例、Late-MCI (LMCI) 995 例を使用した。全ての画像に対して MRICloud² を用いた頭蓋骨除去、位置補正、体積補正、bicubic 補間による $80 \times 96 \times 80$ pixels へのリサイズ並びに、輝度の正規化を行った。

3.2 Localized-VAE の概要

提案する Localized-VAE の構造図を図1に示す。損失関数の第1項と第2項は β -VAE と同様であり、本提案で追加するのは第3項の損失である。

$$E = -\mathbb{E}_{q(z|x)}[\log p(x|z)] + \beta D_{KL}[q(z|x) \| p(z)] + \gamma H$$

β -VAE はあるデータを生成する潜在変数の生成分布を推定する生成モデルである。入力 x から潜在変数 z を獲得するエンコーダ $q(z|x)$ と、潜在変数 z から生成を行うデコーダ $p(x|z)$ から構成される。第1項は入力と出力の再構成誤差、第2項はエンコーダによって得られた潜在変数 z の生成分布と目標とする分布 $p(z) = N(0, 1)$ との KL 情報量である。Localized-VAE は β -VAE の損失に、低次元表現の各次元の影響を局

Acquisition of Highly Interpretable Low-Dimensional Representations of 3D Brain MR Images for Content-based Image Retrieval

KEI NISHIMAKI[†], KUMPEI IKUTA[‡] and HITOSHI IYATOMI[†]

^{†‡}Applied Informatics, {Faculty, Graduate School} of Science and Engineering, Hosei University
184-8584, Tokyo, Japan

{kei.nishimaki.6b@stu., kumpei.ikuta.5x@stu., iyatomi@}hosei.ac.jp

¹<https://adni.loni.usc.edu>

²<https://mricloud.org/>




図 1: Localized-VAE の構造

所化させるような制約を加える．具体的には，低次元表現 z からランダムに選択した特定の 1 次元に対して $+\sigma$ または $-\sigma$ の摂動の有無による 2 つの再構成を取得する．これらの差分画像を確率分布とみなした D に対する平均情報量 H を各次元の局所性に対応する新たな損失として加える．

$$H = - \sum D \log D$$

これにより低次元表現の各次元の情報に対応する脳の影響範囲が狭くなるように学習が行われるため，局所的な低次元表現の獲得が期待できる．また，Localized-VAE のモデル構造において，CBIR での次元削減による低次元表現の獲得に必要な箇所はエンコーダのみであり，デコーダによる局所性の貢献の影響を防ぐ必要がある．そのため，Localized-VAE ではエンコーダとデコーダの重みが対になる Tied Weights[5] を導入する．

4 実験と結果

実験で用いた VAE モデルはエンコーダ・デコーダ層共にバイパス構造を有する 14 層の CNN モデルであり，低次元表現 z の次元数は 150 である．Localized-VAE の有効性を検証するため，脳 MRI 画像から得られる低次元表現の表現能力 (RMSE, AUC) と，可読性に関連した各次元の局所性 (Entropy) について β -VAE と β -VAE (Tied Weight:TW) との比較を 5-分割交差検証で行い，表 1 に結果をまとめた．RMSE は低次元表現からデコーダを介して再構成された脳画像との再構成誤差を表す．AUC は低次元表現がもつ潜在的な病気の診断能を表し，獲得した低次元表現から構築されたロジスティック回帰モデルにおける CN と AD の症例予測の ROC 曲線下の面積を表す．Entropy は，低次元表現の各次元が保持する影響範囲の定量的な評価であり，各モデルで獲得した低次元表現の任意の 1 次元に -3σ と $+3\sigma$ の摂動を付与した際の 2 つの再構成画像の差分画像を確率分布とみなした場合の平均情報量の




図 2: 差分画像

表 1: 得られる低次元表現の定量評価

モデル	RMSE	AUC	Entropy
β -VAE	0.0945	0.754	4.78
β -VAE (TW)	0.0955	0.752	4.74
Localized-VAE	0.0956	0.752	4.11

期待値である．この値が小さいことは低次元表現の各次元の影響が脳領域において局所的であることを示す．また図 2 に，獲得した低次元表現における CN と AD の平均ベクトルの内，差分が最大である次元に同様の摂動を付与した際の 2 つの再構成画像の差分画像を示した．

5 考察とまとめ

図 2 から β -VAE の低次元表現が与える影響は脳の比較的広範囲に及んでいるのに対し，Localized-VAE はアルツハイマー型認知症の診断に重要な脳の中心部への局所化が確認できる．Localized-VAE が作る低次元表現は，元となる β -VAE と同等の病徴表現能力を有しながら，各次元の情報が対応する脳領域の局所性が向上した．これは課題であった低次元表現の可読性向上を意味し，CBIR 実現の重要な要素である．

参考文献

- [1] A. Kumar, J. Kim, W. Cai, M. Fulham, and D. Feng, "Content-based medical image retrieval: a survey of applications to multidimensional and multimodality data," *JDI*, vol. 26, no. 6, pp. 1025–1039, 2013.
- [2] H. Arai, Y. Chayama, H. Iyatomi, and K. Oishi, "Significant dimension reduction of 3d brain mri using 3d convolutional autoencoders," in *IEEE EMBC 2018*. IEEE, 2018, pp. 5162–5165.
- [3] Y. Onga, S. Fujiyama, H. Arai, Y. Chayama, H. Iyatomi, and K. Oishi, "Efficient feature embedding of 3d brain mri images for content-based image retrieval with deep metric learning," in *IEEE BigData 2019*. IEEE, 2019, pp. 3764–3769.
- [4] I. Higgins, L. Matthey, A. Pal, C. Burgess, X. Glorot, M. Botvinick, S. Mohamed, and A. Lerchner, "beta-vae: Learning basic visual concepts with a constrained variational framework," *ICLR 2017*, 2017.
- [5] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, P.-A. Manzagol, and L. Bottou, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," *JMLR*, vol. 11, no. 12, 2010.