

類似症例検索を目的とした3次元脳MRI画像における 撮像環境に不変な特徴表現の獲得

戸張 柊也[†] 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

概要

診断支援を目的とした脳MRI画像に対する類似症例検索 (CBIR) 技術の実現が望まれている。そのためには病徴を反映した特徴表現の獲得が重要であるが、各撮像拠点のスキナやプロトコル等の環境の違いにより生じるドメイン差が、時に病徴差より支配的であることが近年明らかになっている。我々は、脳MRI画像の特徴表現からドメイン識別が困難になるような敵対的な学習を行うことで、ドメイン差を低減し病徴をより反映する新しい低次元特徴表現の獲得法を提案する。ADNI, PPMI の2つのデータセット計4,168例からなる脳MRI画像を用いた実験により、提案手法は脳画像の復元性を大きく下げることなく、データセット間の違いを大きく低減し、症例分類の macro F1 値を3.8%向上させることを確認した。

1 はじめに

高分解能な脳MRI画像は要素数が大きく、Content-based Image Retrieval (CBIR) 実現には適切な次元削減が不可欠である。Arai ら [1] は3次元畳み込み自己符号化器 (3D-CAE) による次元圧縮により、脳MRI画像の低次元表現の獲得に成功した。しかし、獲得された特徴表現には各撮像拠点のスキナやプロトコルなどの違いにより生じるドメイン差が存在し、疾病に基づく特徴抽出に大きな影響を及ぼしている。

一方、ドメイン差の調和についてはこれまでに多くの方法が提案されてきている。調和画像を生成してドメイン調和を行う生成ベース [2] [3] の手法では、サイズや形状について大きく変えることができないことから、ドメイン間で脳の大きさが大きく異なる場合に調




図 1: 提案モデル概略

和を行うことが困難であった。Tzeng ら [4] により提案された敵対的ドメイン適応は、主たる任意のタスクを実現するモデルと、ドメイン予測の識別器を敵対的に学習させることで、ドメインに依存する情報を低減した良好な低次元特徴表現獲得を可能とした。Dinsdale ら [5] はこのドメイン適応処理をMRI画像のドメイン調和に適用し優れた成果を示した。しかし、この手法は特徴表現の獲得に重きを置いておらず、U-net 構造のバイパス中心部分に位置する特徴表現には脳全体の情報が保持されていないためCBIRには適さない。

本研究ではCBIRを目的とした撮像環境に不変な特徴表現を得る新しい効果的な手法を提案する。提案手法はDinsdaleらの手法を参考に、3D-CAEに敵対的ドメイン適応を適用するとともに、ドメイン調和の能力を高めるために新たにドメイン毎のデコーダを備える。

2 方法

2.1 提案手法とモデル概要

提案モデルの概要を図1に示す。この例はA,B,2つのドメイン(データセット)の調和を試みたモデルであり、Encoderと、調和対象のドメインに合わせて個々のDecoder(D_A, D_B)をもつ3D-CAEと、それにより抽出された低次元特徴表現 L からドメインの分類を行う分類器 C によって構成される。 d は分類器 C に

Acquisition of Low-Dimensional Representation of 3D Brain MR Images Invariant to Imaging Environment for Content-Based Image Retrieval

Shuya TOBARI[†], Kumpei IKUTA[†] and Hitoshi IYATOMI[†]
Applied Informatics, {[†]Faculty, [‡]Graduate school} of Science and Engineering, Hosei University
184-8584, Tokyo, Japan
{shuya.tobari.7b@stu., kumpei.ikuta.5x@stu., iyatomi@}hosei.ac.jp

より得られる入力 x のドメイン帰属確率を示している。このモデルの目標は、入力画像 x を正しく復元できる特徴表現 L を実現しつつ、そこからドメイン予測に資する情報を除去すること、つまり十分に優れたドメイン分類器 C を用いても分類結果 d が各ドメイン一様になるように学習することである。本提案で Decoder をドメインごとに定義したのは、ドメイン情報が失われた L から元のドメイン情報をもつ入力画像の再構成をより良好に実現し、ドメイン調和の能力を高めるためである。このモデルの学習は以下の 3 ステップの反復により実現される。(i) 再構成画像を入力画像と近づけるために Encoder と Decoder を学習。(ii) 特徴表現 L からドメインの分類が出来るように、ドメイン分類器 C を学習。(iii) L からドメインの分類が出来ないように Encoder のみを学習。(i),(ii),(iii) の学習にはそれぞれ平均二乗誤差、交差エントロピー誤差、ドメイン分類器の出力の情報量を最大化する損失関数を用いた。また本実験に用いた Encoder と Decoder はバイパス構造を持つ 12 層の CNN で構成され、特徴表現の次元数は 150 とした。ドメイン分類器には 2 層の全結合ニューラルネットを用いた。

2.2 データセットと前処理

本実験では ADNI2¹ と、PPMI² の T1 強調 MRI 画像データセットを使用した。ADNI2 から、健全 (CN)1121 例、アルツハイマー型認知症 (AD)674 例、軽度・末期認知障害 (MCI・LMCI) 各 926, 995 例を学習に使用した。PPMI からは健全 (Control) 114 例とパーキンソン病 (PD) 338 例を学習に使用した。ADNI2 の CN と PPMI の Control は医学的に同等で、また T1 強調 MRI では PD 関連の解剖学的特徴はないため、本実験では PPMI データはいずれも健全 (CN) とみなした。また、用いた全ての画像は MRICloud³ による頭蓋骨の除去と体積補正、輝度値の正規化を行った。データ数の少ない PPMI の学習時にはオーバーサンプリングを行った。学習と評価は 3-分割交差検証で学習と評価データに同じ患者が混在しないよう行った。

3 実験と結果

提案手法で得られる特徴表現の有効性の検証のため、脳画像の再現性、病気の診断性、特徴空間での病気間の距離について、単純な 3D-CAE、ドメイン適用による調和モデル (+Harmonize)、提案するドメイン毎に

表 1: 通常学習と調和学習の評価比較

	RMSE	F1[%]	$D_{CN-Ctrl}$
3D-CAE	0.0871	72.1	1.995
+Harmonize	0.0879	72.4	1.244
+Harmonize +MD (提案手法)	0.0898	75.9	0.978

Decoder をもつ調和モデル (Multi-Decoder: MD) とで比較、評価を行った (表 1)。脳画像の再現性は入力画像を 0~1 に正規化したときの RMSE で評価した。病気の診断性はロジスティック回帰による AD, CN の二値分類を、ADNI2 の AD, CN のみの特徴表現を学習に用い、評価時に未知のデータとして PPMI の Control・PD を CN として加えたときの F1 スコアである。特徴空間距離 ($D_{CN-Ctrl}$) は、特徴空間上の AD と CN の平均点間の距離を 1 としたときの CN・Control 間の距離を表しており、小さい方が望ましい。

3D-CAE に調和学習を導入することで、データセット間の健常者画像の分布の違いを大きく低減できたが改善の余地が大きく残された。提案手法では、低次元表現からの再構成画像の劣化がほぼなく、データセット間の違いをさらに低減するとともに、AD・CN 分類評価の macro F1 スコアを通常学習時より 3.8 % 向上させることができた。

4 考察とまとめ

提案手法は、ドメイン毎に定義したデコーダをもつ 3D-CAE と敵対的ドメイン適応技術を用いることで、良好なドメイン調和を実現し、脳全体の情報を保持しつつ撮像環境に頑健で病気の診断性が向上した特徴表現を獲得することに成功した。今後はより大規模、多数のドメインでの検証を行う。

参考文献

- [1] H. Arai *et al.*, “Significant dimension reduction of 3d brain mri using 3d convolutional autoencoders,” in *IEEE Proc EMBC*. IEEE, 2018, pp. 5162–5165.
- [2] B. E. Dewey *et al.*, “Deepharmy: A deep learning approach to contrast harmonization across scanner changes,” *Magnetic resonance imaging*, vol. 64, pp. 160–170, 2019.
- [3] H. Arai *et al.*, “Disease-oriented image embedding with pseudo-scanner standardization for content-based image retrieval on 3d brain mri,” *IEEE Access*, vol. 9, pp. 165 326–165 340, 2021.
- [4] E. Tzeng *et al.*, “Simultaneous deep transfer across domains and tasks,” in *IEEE proc. ICCV*, 2015, pp. 4068–4076.
- [5] N. K. Dinsdale *et al.*, “Deep learning-based unlearning of dataset bias for mri harmonisation and confound removal,” *NeuroImage*, vol. 228, p. 117689, 2021.

¹<https://adni.loni.usc.edu>

²<https://www.ppmi-info.org>

³<https://mricloud.org>