

脳 MRI 画像の局所特徴量に基づく年齢推定手法と 縦断データベースを用いた性能評価

近藤 千裕[†], 伊藤 康一[†], 呉 凱[‡], 佐藤 和則^{*}, 瀧 靖之^{*}, 福田 寛[§], 青木 孝文[†]

[†] 東北大学 大学院情報科学研究科, [‡] 華南理工大学,

^{*} 東北大学 加齢医学研究所, [§] 東北薬科大学

1 はじめに

人間の脳は、正常加齢に伴って、その形態が変化することが知られている [1]。アルツハイマー病のような病気の場合は、老化の進行（形態的变化）が早いため、脳の形態から推定される年齢と実年齢の差を調べることで、このような病気の早期発見や診断支援につながると考えられる。そのため、脳 MRI 画像から脳年齢を正確に推定することは、病気の診断において重要である。従来の脳年齢推定手法 [2] では、全ボクセルを特徴量として用いたり、推定に用いる特徴量が多かったりするため、医学的解釈にフィードバックしにくい問題がある。これに対して、本稿では、脳を解剖学的意味を持つ複数の領域に分割し、その領域の体積を局所特徴量として機械学習により年齢を推定する。一方で、脳は加齢に伴って形態的变化が見られるが、脳の形態および変化は個人ごとに異なっている。そのため、実年齢と推定年齢との比較が必ずしも正確な評価にならない。本稿では、経時変化のある同一人物の脳画像からそれぞれの年齢を推定し、推定した経過年数と実際の経過年数を比較することで提案手法の有効性を評価する。青葉脳画像リサーチセンターおよび仙台市鶴ヶ谷プロジェクトで収集された縦断データベースを用いた実験を通して、提案手法の臨床応用の可能性について検討する。

2 脳 MRI 画像を用いた年齢推定

提案手法は、(i) T1 強調画像からの局所特徴量の抽出、(ii) 線形回帰分析を用いた特徴量の正規化、(iii) 機械学習を用いた年齢推定で構成される [3]。 (i) T1 強調画像からの局所特徴量の抽出では、図 1 に示す一連の画像処理を行う。画像処理は、解剖学的標準化、組織分画、領域分割の 3 つの処理で構成される。解剖学的標準

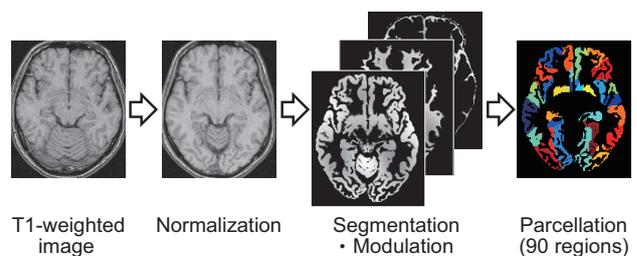


図 1: 局所特徴量抽出の流れ

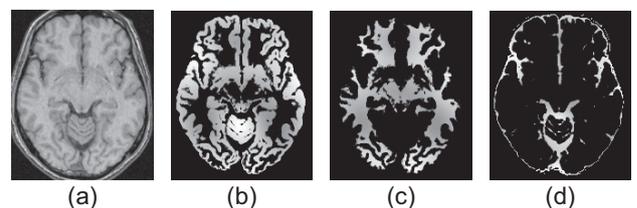


図 2: T1 強調画像からの組織分画: (a) 標準化された T1 強調画像, (b) 灰白質, (c) 白質, (d) 脳脊髄液腔

化では、個人の脳形態を標準的な脳の形態に合わせこむ。組織分画では、図 2 のように脳組織を灰白質 (GM)、白質 (WM)、脳脊髄液腔 (CSF) に分ける。領域分割では、解剖学的脳アトラス (AAL アトラス [4]) に基づいて脳を 90 領域に分割する。分割された GM の体積を Regional GM Volume (RGMV) とし、同様に分割された WM と CSF の体積をそれぞれ RWMV と RCSFV とする。これらの画像処理は、Statistical Parametric Mapping 2 (SPM2)^{*1} および SPM2 のツールボックスである Voxel-Based Morphometry 2 (VBM2)^{*2} を用いて行う。脳の体積は、年齢の他に性別や頭の大きさなどの影響を受けている。(ii) 線形回帰分析を用いた特徴量の正規化では、線形回帰分析を用いることにより、年齢以外の要因を除去する。(iii) 機械学習を用いた年齢推定では、正規化された RGMV, RWMV, RCSFV を組み合わせて 1 つの特徴ベクトルとし、機械学習により年齢を推定する識別器を構築する。本稿では、識別器として関連ベクトルマシン (Relevance Vector Machine: RVM [5]) を使用する。

[†]Age Estimation Method Using Local Features of Brain MRI Images and Longitudinal Evaluation

[†]Chiro KONDO, [†]Koichi ITO, [‡]Kai WU, ^{*}Kazunori SATO, Yasuyuki TAKI, [§]Hiroshi FUKUDA, [†]Takafumi AOKI

[†]Graduate School of Information Sciences, Tohoku University

[‡]South China University of Technology

^{*}Institute of Development, Aging and Cancer, Tohoku University

[§]Tohoku Pharmaceutical University

^{*1}<http://www.fil.ion.ucl.ac.uk/spm/software/spm2/>

^{*2}<http://dbm.neuro.uni-jena.de/vbm/vbm2-for-spm2/>

3 性能評価実験

提案手法を用いて T1 強調画像から年齢を推定し、提案手法の性能を評価する。実験では、青葉脳画像リサーチセンターおよび仙台市鶴ヶ谷プロジェクトで収集された脳 MRI 画像からなるデータベース（青葉 1 [6], 青葉 2, 鶴ヶ谷 1）を用いる。青葉 2 は、青葉 1 の被験者を対象に平均 7 年後に収集されたデータベースで、青葉 1 と組み合わせることで縦断データベースとして使用することができる。これらの画像データは、同一の 0.5T MRI スキャナで撮像された。データベースに格納されている画像のうち、健常者の T1 強調画像 (256×256×124 [voxel]) を用いて、提案手法の精度を評価する。学習データとして、青葉 1 および鶴ヶ谷 1 から 20~75 歳（平均年齢 46.1 ± 17.1 歳）の健常な男性 436 名および女性 409 名のデータを使用する。一方、テストデータとして、青葉 1 および青葉 2 から、青葉 1 撮像時 20~75 歳（平均年齢 51.3 ± 12.1 歳）の健常な男性 116 ペアおよび女性 185 ペアのデータを使用する。なお、学習データとテストデータは、重複なく選択されていることに注意されたい。提案手法を用いて年齢を推定し、実年齢および同一人物間の推定年齢との誤差を評価する。

図 3 に、青葉 1 撮像時の年齢と青葉 1 および青葉 2 の推定年齢の分布を示す。また、表 1 に、青葉 1 撮像時の年齢と比較した場合の Mean Absolute Error (MAE) と Correlation coefficient (Corr.) を示す。図 3 および表 1 より、青葉 1, 青葉 2 のどちらも推定年齢と実年齢に相関があること、青葉 1 では 4.4 歳の誤差で年齢を推定できていることが確認できる。脳の形態および変化には個人差があるため、実年齢と推定年齢との比較が必ずしも正確な評価にならない。そこで、経時変化のあるデータに対して、経過年数を推定することで、個人差を吸収した上での推定年齢の評価ができると考えられる。表 2 に、青葉 2 の推定年齢と青葉 1 の実年齢および推定年齢との差を示す。表 2 より、青葉 1 の実年齢と比較するよりも、青葉 1 の推定年齢と比較した方が標準偏差が小さく、青葉 1 と青葉 2 の撮像間隔である約 7 年に近い値が得られている。このことから、実際の経過年数に近い値を推定することができたため、提案手法は年齢を正しく推定できていると言える。また、この結果から、推定した経過年数と実際の経過年数とを比較することで、アルツハイマー病などの診断支援にも提案手法が有効であると考えられる。

4 まとめ

本稿では、脳 MRI 画像の局所特徴量に基づく年齢推定手法を提案した。また、縦断データベースを用いた

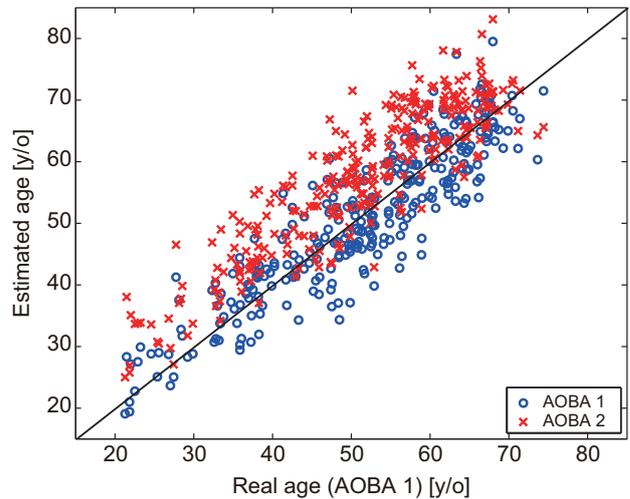


図 3: 青葉 1 の実年齢と各推定年齢の分布（丸印は青葉 1 の、バツ印は青葉 2 の推定年齢を示す）

表 1: 青葉 1 の実年齢と比較した場合の実験結果

Project	MAE [y/o]	Corr.
青葉 1	4.434	0.898
青葉 2	7.089	0.891

表 2: 青葉 2 の推定年齢と青葉 1 の年齢との差

比較対象	Mean±SD [y/o]
青葉 1 の実年齢	6.34±5.59
青葉 1 の推定年齢	6.71±3.61

実験を通して、提案手法の有効性を確認した。

参考文献

- [1] Y. Taki et al., “Correlations among brain gray matter volumes, age, gender, and hemisphere in healthy individuals.,” PLoS One, vol.6, no.7, pp.e22734–1–e22734–13, April 2011.
- [2] K. Franke et al., “Estimating the age of healthy subjects from T1-weighted MRI scans using kernel methods: Exploring the influence of various parameters,” NeuroImage, vol.50, no.3, pp.883–892, April 2010.
- [3] 近藤千裕ほか, “脳局所特徴量に基づく年齢推定手法と脳 MRI 画像データベースを用いた性能評価, %j” 映像情報メディア学会技術報告, vol.38, no.32, pp.15–18, Aug. 2014.
- [4] N. Tzourio-Mazoyer et al., “Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of the MNI single-subject brain,” NeuroImage, vol.15, no.1, pp.273–289, Jan. 2002.
- [5] M.E. Tipping, “Sparse Bayesian learning and the relevance vector machine,” J. Machine Learning Research, vol.1, pp.211–244, 2001.
- [6] K. Sato et al., “Neuroanatomical database of normal Japanese brains,” Neural Networks, vol.16, no.9, pp.1301–1310, Nov. 2003.