

機械学習による脳構造 MRI からの個人属性の推定

1215085 笹谷 健文 【 知能情報学研究室 】

Prediction of Personal Property by applying Machine Learning from Brain Structural Magnetic Resonance Imaging

1215085 SASATANI, Takenobu 【 Intelligent Informatics Laboratory 】

1 はじめに

高齢化社会に伴い, MRI データ等の医療データを用いた分析手法が注目されている, CAD(Computer Aided Diagnosis) の分野では, 画像認識を用いた画像診断による診断支援も行われてきた. 近年では機械学習を用いた診断の自動化が研究されている. しかし, これらは腫瘍や出血, 形態異常など目視でわかるものの認識が主であり, 近年は, 未病の患者の健康状態, さらに未来の健康状態予測が望まれている [1][2]. 人の遺伝的な性質や嗜好が健康状態に影響を及ぼすと考え, その結果として, 脳構造にも影響をあたえようとする研究も存在する [3].

そこで本研究では, 人の生物学的な違いとして最も基本的な, 性別を対象として, 脳構造のデータと機械学習アルゴリズムのみでそれを予測することができるかを検証することで脳構造と人間の状態に関係性があるかを検証する.

2 MRI 脳画像の前処理

本実験で用いる画像データは, MRI 構造画像のうち, 基本的な T1 強調画像を用いる(灰白質・白質の信号値が高い). また, 患者ごとにスライスが異なるため, スライス枚数が 185 枚になるように, 背景画像(全てのボクセル値が 0)を補間して入力データサイズを合わせる.

3 MRI 構造画像からの要素推定

3.1 推定タスク

MRI 構造画像を用いて, 脳構造から人の属性推定を行なう. 性別 (2 クラス分類), 年齢 (回帰) の推定モデルを構築する. 加えて, 脳に影響を及ぼす環境的要因として, 喫煙習慣を喫煙・禁煙・未経験の 3 クラス分類の推定モデルも構築する.

3.2 データセット

368 人の 22-85 歳の健康な脳ドック検診者のデータ (男/女 = 200/158, 平均年齢 = 56.48 ± 11.19 (標準偏差)) のデータを用いる.

3.3 推定モデル

図 3.3 に各タスクの推定に用いた畳み込みニューラルネットワーク (Convolutional Neural Network: CNN)

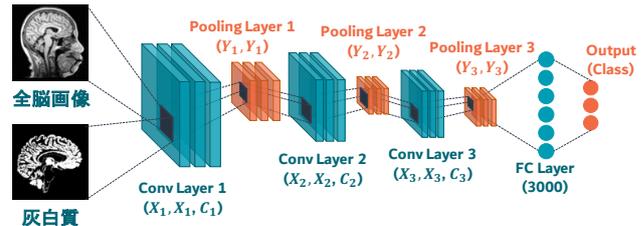


図 1 推定モデル

を示す. 8 層の CNN で構成され, Model 1, Model 2, Model 3, 畳み込み層のフィルタ数は $C_{1,2,3} = 10, 20, 30$ とし, フィルタサイズは $X_{1,2,3} = 5$ で固定している. プーリング層のサイズは $Y_1 = 6, Y_{2,3} = 4$ で固定している. Model4 は出力層に近づくほどフィルタの規模を縮小させるために, $C_1 = 30, C_2 = 20, C_3 = 10, X_1 = 5, X_2 = 4, X_3 = 3$ の畳み込み層と, $Y_1 = 4, Y_2 = 3, Y_3 = 2$ とするプーリング層で構成されている.

3.4 モデルの評価

各モデルの評価として, 分類タスクである性別・喫煙推定は精度 (Accuracy), 回帰タスクである年齢推定は平均絶対誤差 (Mean Absolute Error: MAE) を用いる. また, データのばらつきによる評価値の変動を避けるため, 5-分割交差検証法を用いて各モデルで 5 回シミュレーションを行い, 算出された評価値の平均値を各モデルの評価値とする.

4 結果

4.1 性別推定

4.1.1 全脳画像

表 1 に各モデルにおける全脳画像を用いた性別推定の結果を示す. 全ての断面方向の画像で 95%以上の識別モデルが構築出来たため, スライス断面, 及び, それに直交する面に沿った有用な画像特徴量が存在すると考える. また, ネットワークのフィルタ数などの変化による精度の変化が見られない為, 性別推定に寄与する比較的単純な特徴が存在すると考える.

4.1.2 灰白質画像

表 2 は灰白質画像を用いた推定結果を示す. 全ての断面方向の画像で 80%以上の識別率を持つモデルが構築

表 1 性別の推定精度 — 2D-CNN — 全脳画像

	Model1	Model2	Model3	Model4
Horizontal	90.47%	94.31%	94.29%	92.91%
Coronal	97.00%	95.93%	95.63%	93.75%
Sagittal	92.96%	89.73%	96.50%	96.00%

表 2 性別の推定精度 — 2D-CNN — 灰白質

	Model1	Model2	Model3	Model4
Horizontal	83.42%	82.62%	84.51%	85.32%
Coronal	83.95%	84.76%	84.78%	83.98%
Sagittal	79.33%	80.43%	82.33%	83.69%

表 3 性別の推定精度 — 3D-CNN

	Model1	Model2	Model3	Model4
全脳	80.14%	97.01%	80.51%	70.51%
灰白質	83.71%	77.47%	68.17%	78.55%

可能なため、スライス断面に特徴が存在すると考える。

4.1.3 3D-CNN モデルによる推定

表 3 は、3DCNN で性別推定の結果を表す。全脳では 97.01%と 2DCNN の精度を超えるモデルも構築できたが、残りのモデルでは、80%前後と 2DCNN を用いた場合と比較して、10%精度が低下した。

この要因として、3DCNN のパラメータ数の低さが考えられる。Model4 の構成をした 2DCNN のパラメータ数は 2,585,012 であるのに対し、3DCNN は 152,582 とパラメータ数に大きな差があるため、一つのパラメータが識別率に大きく寄与し、モデルの初期化時点での乱数分布によって精度が大きく変動すると考える。

4.1.4 Brodmann Area ごとの精度評価

性別に寄与している部位を特定するために、Brodmann Area の各部位のみで 2DCNN で性別推定を行った結果を図 4.1.4 に示す。チャンスレベル 57.26%に対して、一部の領域では、80%に達する部位も観測された。主に、思考・認知・運動企図に関する前頭前連合皮質 (BA44)、形態視に関する視覚性下側頭野、聴覚・言語に関する高次聴覚皮質 (BA45)、思考・認知・計画的行動に関するブローカ野及び前頭前連合皮質 (BA46,47) に 75%を超える識別率が観測された。これらの認知機能に男女差が影響すると考える。

4.2 年齢推定

表 4 は、全脳画像を用いた年齢推定の結果を示す。2DCNN では 8 歳前後の MAE で推定可能であり、3DCNN では、平均して 0.7 歳 MAE が高くなった。これは、性別推定同様、モデル内のパラメータ数がタスクに対して不足していると考えられる。

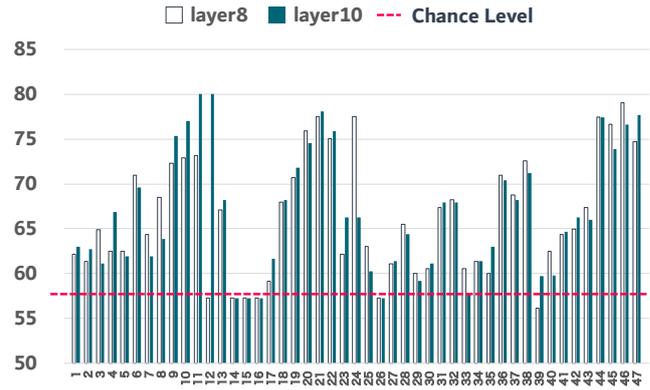


図 2 Brodmann Area 別性別推定結果

表 4 年齢の推定精度

	Model1	Model2	Model3	Model4
全脳—2D	8.76	7.86	7.89	7.08
全脳—3D	8.68	8.20	8.68	8.68

表 5 喫煙有無の推定精度

	Model1	Model2	Model3	Model4
全脳—2D	54.34	52.43	49.18	49.18
灰白質—2D	52.17	47.30	51.08	47.82

4.3 喫煙推定

表 5 は、全脳画像を用いた喫煙推定の結果を示す。未経験が多い分布のためチャンスレベルが 54%となるため、用いたモデルでは、脳構造から喫煙の傾向を推定することは困難である。

5 まとめ

脳構造データを基にした機械学習アルゴリズムによって人間の性別推定が可能なモデルを構築した。2DCNN モデルでは安定して約 95%の精度で推定可能であり、脳構造から一部の個人の属性が推定可能なことを示した。

参考文献

- [1] J. Liu et.al., “Applications of deep learning to mri images: a survey,” Big Data Mining and Analytics, vol.1, no.1, pp.1-18, 2018.
- [2] T. Sasatani, K. Park, S. Yoshida, “Prediction of Brain Disposition by applying Convolutional Neural Network to Magnetic Resonance Imaging”, ISCIIA 2018, 3A1-3-4, China, 2018.
- [3] S. Karama et.al., “Cigarette smoking and thinning of the brain’s cortex,” Molecular psychiatry, vol.20, no.6, p.778, 2015.