

fMRI を用いた 1Hz 差識別における機械学習手法の比較

— 個人解析と集団解析の検討 —

Comparison of Machine Learning Methods in 1Hz Difference Discrimination Using fMRI: Examination of Individual and Group Analyses

知能機械工学コース

ヒューマンダイナミクス研究室 大屋敷 佳貴

1 緒言

ブレインデコーディングは、fMRI(functional Magnetic Resonance Imaging)などの脳活動から身体状態や心理状態を解読する技術であり、神経科学において広く研究されている。近年、機械学習技術の発展によりブレインデコーディングはさらに注目を集めている。本研究グループでは、ブレインデコーディングの中でも聴覚刺激をデコード対象にした聴覚野デコーディングの研究を実施しており、研究の成果は病気の早期発見や認知機能低下の検出への応用に繋がると考えている。これまでに本研究グループにおいて既報⁽¹⁾では、fMRI 活性化パターンから深層学習を用いて 124.5(Hz)差の 2 音識別を行った。しかし、先述した病気の早期発見に近づくためにはさらに小さな周波数差における検討が求められると考え、本研究では 1(Hz)差識別にチャレンジしている。本研究におけるこれまでの成果として、既報⁽²⁾では、fMRI 実験における相反した特徴を持つ 2 つの撮像デザイン(事象関連デザイン、ブロックデザイン)を用いた比較実験を実施した。結果から個人解析における 1(Hz)差識別手法として、撮像デザインにブロックデザインを用いることが有効であるとの見通しがたつた。

これまでの成果をベースとして本研究の目的は、1(Hz)差識別手法をさらにロバストな方法論として確立することであり、以下に述べる 3 つのアプローチを実践する。1 つ目の挑戦は、ROI(Region of Interest:関心領域)の再検討による識別精度の向上である。既報⁽²⁾では ROI を BA(Brodman Areas:ブロードマン領野)41, 42 に設定した結果、識別精度が 63.4(%)となった。一般に機械学習ではデータ拡張により精度が向上すると言われる。そこでデータ拡張の 1 手法として ROI に BA22 を追加し、脳賦活画像に含まれる情報量の増加による識別精度の向上を図る。2 つ目の挑戦は、複数の実験協力者による 1(Hz)差識別手法の再現性の検証である。既報⁽²⁾では実験協力者が 1 名であるため、この実験協力者において偶然、高い識別精度を得た可能性を否定しきれない。そのため、実験協力者を増やし 1(Hz)差識別を実施することにより再現性を確認する。本要旨ではページ数の都合上、2 つの挑戦の詳細については割愛するが、複数の実験協力者にて識別精度 100(%)を得た。結

果から 1(Hz)差の 2 音を 3DCNN(Convolutional Neural Network)を用いて識別する手法として、撮像デザインはブロックデザイン、ROI は BA41, 42, 22 に設定する⁽³⁾ことが、再現性を担保すると同時に有効な方法論であることが判明した。3 つ目の挑戦は、SVM(Support Vector Machine)との比較による、1(Hz)差識別における 3DCNN の妥当性の検証であり、本要旨ではこれについて詳述する。

2 1Hz 差識別における 3DCNN の妥当性の検証手法

一般に機械学習手法を用いる研究では、提案手法の妥当性を示すために他の学習アルゴリズムとの比較が行われている。本研究では脳の 3 次元的な構造を保ったまま特徴抽出が可能という利点から 3DCNN を識別手法として採用している。ただし、fMRI は専用の設備を必要とし実験中も多くの制約があるため、多量なデータの取得が困難である。よって本研究で扱うデータ数には限界がある。一般に深層学習は多量の学習データを要するため、データ数が限られる本研究では必ずしも最適とは限らない可能性がある。一方で、機械学習手法は深層学習手法と比較して少量のデータでも学習が可能であることが知られている。そこで 3 つ目の挑戦では、代表的な機械学習手法である SVM を比較対象として選択し、3DCNN との性能比較を行うことで、1(Hz)差識別における 3DCNN の妥当性を検証する。

本研究では、fMRI 装置で脳賦活画像を取得し、脳画像解析ソフト SPM12(Statistical Parametric Mapping 12)を用いて前処理、統計画像作成、ROI 設定を行う。前処理では主に脳賦活画像に対して動などの補正を行う。統計画像作成では、脳賦活の特徴抽出およびデータ数増加を目的として、画像をランダムに複数選択して統計解析を行い、コントラストを作成する。本研究における学習データは、前処理済みの脳賦活画像 2 スキャンから 1 つの統計画像を作成し、それらの組み合わせを変更することで作成する。ROI は、1 つ目の挑戦の結果から BA41, 42, 22 に設定⁽³⁾し、1 コントラストごとに賦活情報と位置情報を CSV 形式で取得する。賦活情報は 0.0~1.0 に正規化された 1×N 次元データである。3DCNN 用のデータは

Table 1 The average discrimination accuracy (performance of each method) and standard deviation (stability of each method) obtained from optimal parameter settings for each combination of methods and datasets.

Method	Performance and Stability (Average and Standard Deviation)
3DCNN Method in Individual Analysis	99.3±1.6(%)
SVM Method in Individual Analysis	85.9±16.5(%)
3DCNN Method in Group Analysis	59.1±12.7(%)
SVM Method in Group Analysis	60.6±16.6(%)

位置情報を基に賦活情報を H41×W50×D15 の 3 次元データへと変換する。SVM 用のデータは賦活情報を使用する。

先述のように識別手法として、深層学習手法の 1 つである 3DCNN と機械学習手法の 1 つである SVM を使用する。また、個人解析と集団解析も併せて実践する。個人解析では、学習と評価が同じ実験協力者であるため、事前にデータ取得が可能な場合を想定した、個人に特化した識別手法である。既報⁽²⁾や 1 つ目と 2 つ目の挑戦も個人解析にて実施した。集団解析では、評価データに用いる実験協力者を学習データには用いないため、事前のデータ取得が困難な場合を想定した、汎化性の検証も実施する。つまり個人解析 3DCNN 手法、個人解析 SVM 手法、集団解析 3DCNN 手法、集団解析 SVM の 4 つの手法にて識別実験を行う。

3 1Hz 差識別実験

本実験では、聴覚に異常のない成人男性 6 名を対象とする。本研究は高知工科大学倫理審査委員会の承認を得て実施し、事前に実験内容を説明した上で同意を得て行った。

脳画像取得には、SIEMENS 社の 3 テスラ fMRI 装置 (MAGNETOM Prisma3T) を使用し、Steinberg 製 Nuendo10.3 で作成した音源を fMRI の動作音を軽減する Active Noise Control 方式薄型ヘッドホン Opto ACTIVE を用いて聴覚刺激として呈示する。聴覚刺激は、周波数を 523(Hz) と 524(Hz)、音圧を 78 ~ 85(dB) とする。撮像デザインはブロックデザインを採用し、Task が 9(s)、Rest が 15(s)にて作成する。

取得した脳賦活画像に対して 2 章にて述べた前処理、統計画像作成、ROI 設定を行う。1 名あたりデータ数は、学習用が 320、評価用が 32 である。その後、3DCNN と SVM を用いて脳賦活画像の学習と評価を実施する。個人解析では実験協力者ごとに学習と評価を実施する。集団解析では 5 名の実験協力者にて学習モデルを作成し、1 名の評価データにて評価を実施する。

4 結果と考察

2 章にて述べた 4 つの手法それぞれで 6 通りの学習・評価の組み合わせの識別精度を得た。それぞれの手法における識別精度の平均値と標準偏差を求め、これを「各手法の識別性能と安定性」と呼称し、表 1 に示す。ここで安定性とは、学習データと評価データの組み合わせでどれだけばらつきが存在するかを表す指標として用いる。

先行研究より、脳神経科学の分野において精度が 50(%)を上回れば分類できているとみなせ⁽⁴⁾、60(%)を上回れば十分に信頼できる精度である⁽⁵⁾。したがって本研究では、絶対評価基準を 60(%)と設定する。表 1 より、各手法における識別性能と安定性が判明した。個人解析 3DCNN 手法は平均値が 99.3(%)と、高い識別性能を示した。また、標準偏差は 1.6(%)と、高い安定性を示した。個人解析 SVM 手法は平均値が 85.9(%)であり、個人解析 3DCNN 手法には及ばないものの高い識別性能を示した。一方、標準偏差は 16.5(%)であり、個人解析 3DCNN 手法と比較して低い安定性を示した。集団解析は、3DCNN 手法の平均値が 59.1(%)、SVM 手法の平均値が 60.6(%)であり、個人解析ほどの識別性能ではなかったものの、本研究にて定める絶対評価基準と同程度であり信頼できる識別性能となった。また、標準偏差は 3DCNN 手法が 12.7(%)、SVM 手法が 16.6(%)であり、個人解析 3DCNN 手法ほど高い安定性は有していないが、集団解析においては 3DCNN 手法が比較的高い安定性を示した。

以上の結果から個人解析では、3DCNN 手法が SVM 手法を上回る識別性能および安定性を示したため、1(Hz)差識別にお

ける妥当性を示すことができた。これにより 1(Hz)差識別手法のロバスト化に成功した。また集団解析では、3DCNN 手法および SVM 手法ともに個人解析ほどの識別性能は得られなかったものの、両者ともに絶対評価基準である 60(%)程度となった。そのため集団解析における 1(Hz)差識別手法として 3DCNN の妥当性を明確に示すほどに至らなかったものの、信頼できる手法であることが判明した。

個人解析において 3DCNN 手法が SVM 手法を上回る結果となった原因については以下のように考察する。3DCNN は脳の 3 次元的な構造を保ったまま特徴抽出が可能である。個人解析では同一の実験協力者を学習に用いるため、構造的特徴が統一しており、後述する実験協力者ごとに異なる特徴などの 2 音の特徴抽出に影響を与え識別性能を低下させる可能性のある要素がなかったため、高い識別性能に至ったと考える。一方、SVM 手法は入力が 1 次元ベクトルであるため、構造的な特徴を特徴抽出に活かすことができず、3DCNN 手法より識別性能が劣ったと考える。この考察は Vu ら⁽⁶⁾の見解とも一致する。

集団解析における識別性能低下は、本来抽出したい 2 音の特徴抽出に加えて、実験協力者ごとに異なる特徴(脳の構造の違いや生理学的反応の違いによる賦活情報の違い)も抽出したことが原因だと考える。つまり過学習が起きていると考える。過学習が起きる原因として Hawkins ら⁽⁷⁾などの多くの研究者が述べているように、学習パラメータが多い、学習データ数が少ないことが挙げられる。そこでさらなる識別性能向上には、これらの対策が有効であると考えられる。学習パラメータを減らすためには、Srivastava ら⁽⁸⁾が述べているように Dropout が有効である。学習データの増加には、実験協力者の増加が有効であると考えられる。

5 結言

本研究では、1(Hz)差識別手法をさらにロバストな方法論として確立すべく 3 つのアプローチを実践した。1 つ目は ROI の再検討による識別精度の向上、2 つ目は複数の実験協力者による 1(Hz)差識別手法の再現性の検証、3 つ目(本要旨)は、SVM との比較による、3DCNN の 1(Hz)差識別における妥当性の検証を行った。結果、個人解析では 3DCNN 手法において非常に高い識別性能となり、妥当性を示した。集団解析では個人解析ほどの識別性能は得られなかったものの、信頼できる手法であり、一定の汎化性を有することが判明した。以上の結果から手法のロバスト化に成功した。

今後の展開として、追加の fMRI 実験によりさらに多くの実験協力者のデータ数を確保することで、学習データ数が増え過学習対策に繋がる。これにより、集団解析におけるさらなる識別性能向上が見込める。

文献

- (1) Shigemoto, et al., IEEE, Global Conference on Life Sciences and Technologies, (2019), pp. 212-213
- (2) 大屋敷 他, 日本機械学会, 2024 年度年次大会, (2024), 講演番号 J162p-21
- (3) Ooyashiki, et al., IARIA, HEALTHINFO2025, (2025), pp. 1-4
- (4) Carlson, et al., arXiv, qbio.NC, (2019), 1905.04820
- (5) Robinson, et al., Annual Review of Vision Science, vol. 9, (2023), pp. 313-335
- (6) Vu, et al., NeuroImage, vol. 223, (2020), pp. 117328
- (7) Hawkins, et al., Journal of Chemical Information and Computer Sciences, vol. 44, no. 1, (2004), pp. 1-12
- (8) Srivastava, et al., Journal of Machine Learning Research, vol. 15, no. 1, (2014) pp. 1929-1958