

深層学習技術の応用による 生体情報から精神疾患・発達障害を推定するモデルの構築

鈴木圭¹ 菅谷みどり¹

概要: 近年、うつ病や双極性障害などの精神疾患や ADHD などの発達障害の患者数が増加している。患者数が増加している精神疾患や発達障害には診断が難しい病気もあるため、医者と患者との面談等の主観的な診断のみならず、客観的な手法による診断の補助が必要であるが、手法が確立していない。そこで本研究では、人の精神に関わる客観的な情報の一つとして認められている脳波を用い、深層学習技術の応用により、精神疾患・発達障害の診断を補助するモデルの構築を目的とする。モデル構築のため、精神疾患または発達障害と診断されたことのある 6 名と診断されたことのない 3 名を対象に、開眼安静時の脳波を利用した計測を行い、データを収集した。脳波の生データを説明変数とし、精神疾患または発達障害とそうでない人との 2 値を目的変数として学習を行なった。テストデータと訓練データに同一の実験参加者のデータを含めず、モデルの学習と精度検証を行った。テストデータによる精度検証の結果、平均精度 70%程度のモデル構築が可能であることが示唆された。

キーワード: 生体情報, 深層学習

1. 背景

近年、国内外問わず精神疾患患者数が増加している。平成 29 年では、国内の精神疾患患者数が 400 万人を超えた。特にうつ病患者数などの著しい増加、国内自殺者数が年初来の新型コロナの死者数を上回るなど深刻な問題となっている[1]。また、世界的にも人口の約 30%である 2 億 6400 万人の人が何らかの精神疾患を抱えると予測されている[2]。さらに、発達障害の患者数も増加しており、特にその一種である Attention-Deficit/Hyperactivity Disorder (ADHD) の治療薬は 2007 から 2012 年にかけて 560 万件から 1600 万件へと増加していることも報告されている[3]。

このように増加している精神疾患や発達障害の患者に対し、適切に治療を行うためには適切な診断が必要である。現状の診断方法は臨床医による面接などであり、診断が臨床医の主観に依存する課題がある[4]。精神疾患や発達障害の中には判別な困難な病が存在する。そのため、臨床医の主観だけでなく、客観的な評価により臨床医の診断をサポートすることが求められる。近年では、DSM-5[5](Diagnostic and Statistical Manual of Mental Disorders, DSM) などの国際標準に準拠した質問紙を用いた問診により一致性 (信頼性) 向上が図られている。しかし、基準に生物学的な客観的指標が含まれていない課題が指摘されている[4]。

生物学的で客観的な指標による計測評価により診断をサポートできる可能性が示唆された研究として、生体活動をセンサにより計測し、その情報を利用する研究がなされている[2,4]。これらの生体活動の例として脳や心臓の活動があげられる。脳の活動を頭皮上に設置した電極により計測した脳波を利用した試みにおいては、精度約 70%-100%

で精神疾患や発達障害を患っている人と患っていない人との 2 値分類の判別が可能であることが示唆されている[2]。また、心臓の活動を指先の血管の血流量の変化により計測することや心臓付近の電極により計測した情報を利用することで算出される心拍変動指標により、精神疾患や発達障害を患っている人と患っていない人との 2 値分類の判別が可能であることが示唆されている[6]。

このように、精神疾患や発達障害の判別が可能と示唆されている脳波や心拍などの生体情報であるが、これらの生体情報を複数用いれば、より多角的に病を評価できる可能性が増え、結果として病を患っている人か患っていない人かの 2 値分類の判別精度の向上が期待できる。しかし、複数の生体情報を用いて判別を試みた研究は十分に提供されていない。

そこで、本研究では、複数の生体情報を利用した精神疾患や発達障害の判別を目的とし、データ計測およびモデル構築を行った。データ計測においては、生体計測をする実験参加者を募集し、生体情報として脳波と心拍のデータを収集した。質問票により、どのような精神疾患や発達障害を患っているのかを実験参加者に質問することで、病を患っているか否かの 2 値のラベル付けをするための情報を収集した。また、病の判別に対する生体情報の有用性を評価するために、生体情報を用いた判別モデルを、深層学習技術を応用することにより構築した。閉眼安静時の脳波データのみを用いて、精神疾患や発達障害を患っている人と患っていない人との 2 値分類の判別モデルを構築し、その精度を交差検証により評価した。

精度評価の結果、平均精度は 67.47%、標準偏差が 19.84% となった。この精度となる要因の分析にあたり、どの実験参加者のいつの脳波データが 2 値分類を難しくしているの

¹ 芝浦工業大学
Shibaura Institute of Technology

かを分析するためにデータごとの loss 値を分析した。また、判別にあたりデータに注視箇所を設けることができる Attention 機構の入出力を可視化することで、判別モデルが脳波データのどこに注視しているのかを確認した。これにより、データ計測の前半が判別を難しくしていることが判明するとともに、脳波電極のどこに注視することで判別しているのかを分析した。その結果、判別に有用な電極位置が F7, F3, O1, O2, T8, FC6, F4, F8, AF4 であることが示唆された。

本研究の構造は次のとおりである。第二節に深層学習に用いるデータ収集機材・手順・方法について述べる。第三節に、収集したデータの事前処理方法や説明変数・目的変数などのデータセットの構築方法について述べる。第四節に学習させるモデルの構造や精度指標・交差検証の方法について述べる。第五節に交差検証の結果とその考察について述べる。第六節に本研究のまとめについて述べる。

2. データ収集

深層学習に用いるデータを収集するために実験を行った。実験参加者は精神疾患や発達障害と診断されたことのない成人男性 3 名、精神疾患や発達障害と診断されたことのある成人男性 5 名・成人女性 1 名の計 9 名である。

2.1 データの計測機器

生体情報のデータ収集には、脳波計、光電脈波計、心電計の 3 種類を用いた。

脳波計には EMOTIVE 社の EMOTIVE EPOC X を用いた。サンプリングレートは 256hz に設定した。電極数は 14 個であり、電極位置は国際 10-20 法における AF7, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 である。電極位置の模式図を図 1 に示す。

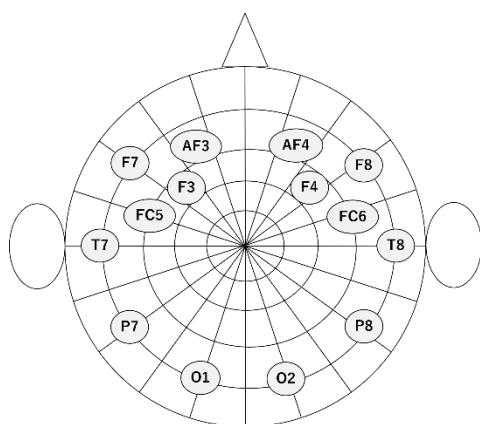


図 1 国際 10-20 法の模式図

光電脈波計には SWITCH SCIENCE 社から購入した心拍センサと Arduino を組み合わせたものを用いた。左の手のひらを上に向け、左の手の人差指に装着した。サンプリングレートは 500hz に設定した。

心電計にはユニオンツール株式会社の myBeat 心拍センサを用いた。サンプリングレートは 128hz である。

2.2 データ計測手順

主なデータ収集の手順は次に示す 1)-5) である(図 2)。




図 2 データ収集の手順

- 1) 5 分間の開眼安静
- 2) 5 分間の閉眼安静
- 3) 5 分間のストループ課題
- 4) 5 分間の休憩
- 5) 1)-4)を一回繰り返す。

1)5 分間の開眼安静では、実験参加者が目を開けているため意図しない視覚的な刺激が実験参加者に及ぼされる可能性が存在する。この可能性を低減するために、背景が灰色で中央に十字が表示された画像を PC に提示した(図 3)。実験参加者にはその十字の中央に可能な限り視点を置くように指示をすることで、意図しない視覚的な刺激が実験参加者に及ぼされることを低減した。




図 3 閉眼安静時の画像

2)5 分間の閉眼安静では、実験参加者は目を閉じて安静の状態であることを指示した。

3)5 分間のストループ課題では、図 4 に示す課題を実験参加者に提示した。実験参加者は文字の意味ではなく文字の色を回答する。実験参加者は図 4 の下部にある白いボタンをマウス操作により回答した。




図 4 ストループ課題

4)休憩では、実験参加者はデータ計測することを気にせずリラックスした。

2.3 精神疾患・発達障害の評価方法

生体情報の計測に参加した実験参加者が精神疾患や発達障害を患っているか否かを質問票により評価した。実験参加者は診断されている病名を答える質問票に回答した。診断されている病名が無い場合は空白とした。本研究の質問票により集計された精神疾患の病名は不安障害、躁鬱(双極性障害)、うつ病である。発達障害における病名は、発達障害、ADHD、Autism Spectrum Disorder(ASD)、アスペルガー症候群である。なお、実験参加者の中にはこれらの病を併発している人も含まれた。

2.4 データ計測環境

実験参加者は椅子に座った状態で机に向かって実験を実施した。机には開眼安静の開始・終了やストループ課題への回答開始などの実験の指示を案内するPCやデータ計測を行うPCが配置されている。実験時には、実験参加者はイヤホンを装着することで聴覚への意図しない刺激を低減できるようにした。

3. データセットの構築

本節ではデータ収集により集めたデータを深層学習に用いるにあたり実施した前処理やデータ水増しについて述べる。なお、本研究では閉眼安静時の脳波データによる深層学習のみを行ったため、脳波データに対して行った前処理やデータ水増しについて述べる。

3.1 前処理

脳波データは様々な要因によりノイズが混入する。これらの混入したノイズを除くために前処理を行った。前処理にはEEGLAB[7]やそのプラグインにより提供される機能を用いた。

3.1.1 2hzのハイパスフィルタ

汗によるノイズや後に行うノイズ除去方法である独立成分分析への悪影響を低減させるために、2hzのハイパスフィルタを用いた。なお、この処理はEEGLABのpop_eegfiltnew関数を用いた。

3.1.2 100hzのローパスフィルタ

頭皮に電極を装着して脳波を計測するが、高周波数帯の脳波は頭蓋骨により妨げられ計測が困難である。こうした計測が困難な周波数帯のデータが計測される場合はノイズである可能性が高い。そこで、100hz以上の高周波数帯を低減させるために100hzのローパスフィルタを用いた。なお、この処理はEEGLABのpop_eegfiltnew関数を用いた。

3.1.3 50,60hzのバンドストップフィルタ

交流電源によりもたらされるハミングノイズを低減するために50hz、60hz付近のバンドストップフィルタを用いた。なお、この処理はEEGLABのpop_cleanline関数を用いた。

3.1.4 電極データの除去

ノイズが多く混入しノイズの除去が困難な電極から得られた脳波データはすべて除去した。また、電極が頭皮と接触していないことで脳波が計測できていない電極から得られたデータはすべて除去した。なお、この処理はEEGLABのClean_rawdataプラグインにおけるpop_clean_rawdata関数を用いた。

3.1.5 Artifact Subspace Reconstruction (ASR)による再構成

Artifact Subspace Reconstruction (ASR)アルゴリズムにより、ノイズが混入したと推論できる時間帯のデータを再構成した。ノイズの含むデータを除去するのではなく再構成することで、除去によるデータ長の減少を防いだ。なお、この処理はEEGLABのClean_rawdataプラグインにおけるpop_clean_rawdata関数を用いた。

3.1.6 再参照

実験参加者ごとの脳波データは、平均値を算出し、その平均値をすべての電極の脳波データに対して減算することで再参照した。なお、この処理はEEGLABのpop_reref関数を用いた。

3.1.7 独立成分分析

まばたきや眼球運動、筋電位、心拍等の脳以外の生体活動によるノイズを低減するために独立成分分析を用いた。独立成分分析によりノイズが混入した脳波データがいくつかの成分に分離させる。その成分のうちノイズである可能性が高いデータを除去することでノイズの低減を行った。成分がノイズである可能性を調べるためにEEGLABのICLabelプラグイン[8]を用いた。ICLabelプラグインにより、70%以上の確率で脳波データと判定された成分以外を除去した。

3.1.8 除去された電極データの補完

電極ごと脳波データを除去する操作が行われていた場合、その除去された電極のデータをEEGLABによるSphericalスプラインにより補完した。なお、この処理にはEEGLABのpop_interp関数を用いた。

3.2 データ水増し

本原稿で行った実験では実験参加者数が9名である。これら実験参加者からそれぞれ1つずつのデータを生成する場合、深層学習に用いるデータ数としては少量となる。そのため、本原稿では、データ水増しにより、実験参加者1名あたりから深層学習に用いるデータを複数個作成した。本原稿では2つ計測された5分間の閉眼安静時のデータをそれぞれ10秒ごとに切り分けることでデータ水増しを行った。これにより実験参加者1名あたり、60個のデータとなる。

3.3 データセットの構築

実験参加者から得られた生の脳波データを説明変数とした。なお、3.2データ水増しにて説明した10秒ごとに切り分けられたデータを説明変数として用いた。目的変数に関

しては、実験参加者が精神疾患や発達障害と診断されたことのある場合 1、診断されたことのない場合 0 として設定した。これにより、精神疾患や発達障害を患った人のデータが 360 個、患ったことのない人のデータが 180 個の計 540 個のデータセットを構築した。

4. 学習

4.1 モデルの構造

脳波を学習させた深層学習モデルの構造を図 5 に示す。なお、図の左側にはレイヤー名、右側にはレイヤーのバッチサイズを含めない入力次元数を記載した。

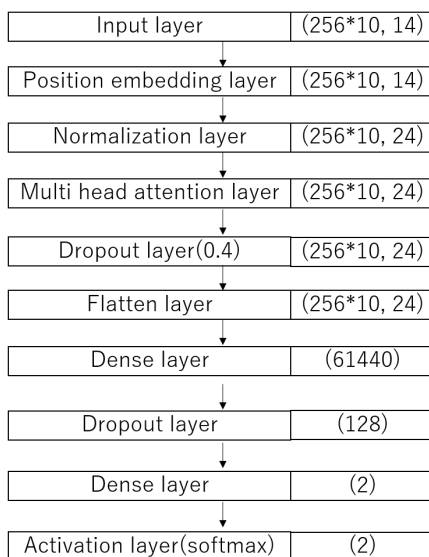


図 5 深層学習モデルの構造

モデルの Input layer には前処理によるノイズ除去等やデータ水増しを行った脳波の生データを入力する。14 チャンネルでサンプリングレートが 256hz の脳波データの 10 秒間分のデータが入力されるため、入力次元数は(256*10, 14)である。時系列データである脳波データに時間情報を加えるため Position embedding layer を用いた。なお、10 次元のデータにより時間情報を表すように設定したため、次の層の入力次元数は(256*10, 24)となった。Normalization layer では脳波の各チャンネルデータを正規化した。Multi head attention layer は、データの注意箇所を学習するレイヤーである Attention 機構である。この層により、モデルが学習において注意すべき箇所を学習するため、精度向上につながる可能性がある。Dropout layer では過学習防止のために設けた。Flatten layer では多次元のデータを平坦にするために設けた。そのあとに続く Dense layer により 2 値分類のための Activation layer へと出力された。なお、このモデルの学習にあたり、バッチサイズ 64、エポック数 30、学習率 0.001 で学習を行い、オプティマイザーには AdamW を用いた。AdamW とは、モデルを構築する際にデファクトスタンダ

ートとして用いられる Adam が改良されたものである。Adam よりも AdamW を用いることで性能が向上することが実証的に示されており[9]、本原稿では性能向上を期待しこのオプティマイザーを用いた。以上のモデルの実装にはプログラミング言語 python の tensorflow[10],keras[11]ライブラリを用いた。また、Position embedding layer にはライブラリを用いた[12]。

4.2 交差検証

交差検証の際には訓練データとテストデータに同一の実験参加者のデータを含めずに行った。また、テストデータには精神疾患や発達障害と診断されたことのある実験参加者のデータと、診断されたことのない実験参加者のデータの計 2 名分のデータを用いた。精神疾患や発達障害と診断されたことのある実験参加者は 6 名、診断されたことのない実験参加者は 3 名である。そのため、考えられるテストデータの組合せは 3*6=18 通り存在する。本研究ではこの 18 通りのテストデータと訓練データで交差検証を行った。なお、乱数による精度の影響を加味し、18 通りのテストデータと訓練データのそれぞれの組合せで 2 回の学習と精度検証を行った。そのため、18*2=36 と計 36 回の学習と精度検証を行った。

精度評価指標には、Macro F1 指標を用いた。Macro F1 指標とは、F1-score を拡張したものである。F1-score の算出方法は、以下の式(1)、(2)、(3)により算出される。

$$precision = \frac{TP}{TP + FP} \quad (1)$$

$$recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1-score = \frac{2 * recall * precision}{recall + precision} \quad (3)$$

正例と負例の 2 値分類において、式(1)、(2)、(3)における変数の意味は次になる。TP:予測値が正例で、その予測が正しいデータ数。TN:予測値が負例で、その予測値が正しいデータ数。FP:予測値が正例で、その予測が誤りであるデータ数。FN:予測値を負例として、その予測が誤りであるデータ数である。

precision は、誤検知を少なくしたい場合に重視される精度指標であり、recall は、正例の見逃しを避けたい場合に重視される精度指標である。F1-score はこれらの精度指標の調和平均をとることにより、バランスをとった指標である。Macro F1 とは F1-score を正解データの種類ごとに算出し、それらの平均値を算出した精度指標である[13]。

5. 結果と考察

5.1 交差検証結果

交差検証において行った 36 回の学習と訓練データ・テストデータにおけるそれぞれの精度検証とそれらの平均値

および標準偏差を表 1 に示す。

表 1 交差検証の結果

交差検証の回数	訓練データの macro fl	テストデータの macro fl
0	98.23%	90.63%
1	89.73%	41.49%
2	99.74%	98.43%
3	93.97%	65.78%
4	94.30%	62.67%
5	99.22%	92.19%
6	96.21%	76.03%
7	89.77%	35.80%
8	94.99%	67.61%
9	93.86%	66.19%
10	95.07%	64.37%
11	96.72%	80.57%
12	92.89%	53.93%
13	94.19%	61.35%
14	88.29%	30.64%
15	99.75%	98.43%
16	95.50%	61.90%
17	94.22%	63.88%
18	94.22%	53.62%
19	92.99%	71.65%
20	94.14%	64.02%
21	98.42%	92.19%
22	95.21%	67.61%
23	96.63%	85.77%
24	92.20%	54.78%
25	100.00%	100.00%
26	99.75%	96.85%
27	92.27%	48.96%
28	96.35%	68.59%
29	92.77%	42.03%
30	89.33%	33.79%
31	90.50%	42.98%
32	94.37%	64.02%
33	93.75%	58.71%
34	95.38%	71.63%
35	100.00%	100.00%
平均	94.86%	67.47%
標準偏差	3.19%	19.84%

精度検証の結果、訓練データの平均精度が 94.86%、標準偏差が 3.19%と安定的に高い精度であった。一方、テスト

データの平均精度は 67.47%、標準偏差が 19.84%とあまり精度が高くないうえ、安定した精度でなかった。

5.2 要因分析

交差検証により算出されたテストデータにおける精度の要因を次の 4 つ観点で分析・考察した。

- 1) モデルの予測と正解との誤差である loss 値
- 2) モデルにおける Attention 機構への入出力
- 3) 精神疾患・発達障害を患っている脳波データを同一の説明変数に含めた点
- 4) 説明変数の信頼性

5.2.1 モデルの予測と正解との誤差である loss 値

交差検証の中で、テストデータにおける精度が最も低いものに 14 回目の 30.64%がある。この施行において、どの実験参加者のいつの脳波データが 2 値分類を難しくしているのかを調査するためにデータごとの loss 値を分析した。調査にあたり、この施行における訓練データとテストデータの loss 値を分析した。

結果を表 2、表 3 に示す。表はそれぞれ訓練データとテストデータにおける実験参加者の loss 値の平均とマン・ホイットニーの U 検定に有意確率($p \leq 0.05$ ならば*, $p \leq 0.01$ ならば**)と、上付き文字追加)を示す。なお、Trial 0 とは一回目の閉眼安静時、Trial 1 とは二回目の閉眼安静時を表す。マン・ホイットニーの U 検定では Trial 0 と Trial 1 の二群間におけるそれぞれのデータの loss 値を比較した。

表 2、表 3 によると、実験参加者 ID 3、8、9 以外で Trial 0 よりも Trial 1 の方が、loss 値が低い傾向が見受けられた。その中には、有意に loss 値が低いものも存在する。loss は学習されたモデルによる出力値と、正解データとの誤差を表す。そのため、この loss 値が低ければ低いほど正解データとの誤差が少ないため、モデルがより正しく正解を推定できたと考えられる。このことから、Trial 0 よりも Trial 1 の方が、より正しく正解を推定ができることが示唆された。なお、この傾向は 14 回目の交差検証の学習結果のみならず、精度が高い 35 回目の交差検証の学習結果(表 4、表 5)などにもこの傾向が存在した。

この原因として、実験協力者の緊張を考える。Trial 0 は実験の前半に行われるものであるため、実験参加者が抱く緊張は後半の Trial 1 よりも大きいものだと考えられる。この緊張が脳波データに反映され、緊張の度合いが強い Trial 0 のデータが安静時の状態の脳波と異なることで判別が困難となり、結果としてモデルの loss 値が高くなるとともに精度が低下したと考える。

表 2 14 回目の交差検証における
訓練データの loss 値

実験参加者	Trial 0	Trial 1	有意確率

ID			
1	62.07E-07	94.13E-08	58.29E-04**
3	79.16E-07	42.76E-07	40.70E-02
5	11.76E-04	56.74E-06	36.02E-06**
7	57.96E-08	54.50E-08	77.52E-02
8	62.21E-07	36.51E-06	48.54E-05**
9	42.12E-06	85.36E-06	46.72E-06**
10	52.98E-09	29.80E-09	29.31E-03*
平均	17.71 E-05	26.34 E-06	-

表 3 14 回目の交差検証における
テストデータの loss 値

実験 参加者 ID	Trial 0	Trial 1	有意確率
2	26.78E-01	44.35E-02	95.87E-06**
6	57.41E-01	25.10E-01	85.16E-05**
平均	42.09E-01	14.77E-01	-

表 4 35 回目の交差検証における
訓練データの loss 値

実験 参加者 ID	Trial 0	Trial 1	有意確率
1	90.55E-07	53.39E-06	70.02E-02
2	87.88E-06	13.28E-07	48.28E-05**
5	10.07E-05	33.87E-05	32.27E-02
6	35.69E-04	47.73E-05	36.79E-03*
8	13.41E-08	25.57E-06	20.18E-07**
9	15.34E-06	91.78E-06	27.00E-02
10	54.59E-07	44.15E-10	13.52E-02
平均	54.10E-05	14.11E-05	-

表 5 35 回目の交差検証における
テストデータの loss 値

実験 参加者 ID	Trial 0	Trial 1	有意確率
3	22.85E-08	82.12E-04	45.28E-07**
7	22.40E-03	34.13E-05	22.60E-04**
平均	11.20E-03	42.77E-04	-

5.2.2 モデルにおける Attention 機構への入出力

交差検証の中で、テストデータにおける精度が最も高いものに 35 回目の 100.00%がある。35 回目の交差検証で学習したモデルが脳波データのどこに注目し精度よく推定できているのかを確認するために、モデルの Attention 機構の

入出力をプロットした。その図の一例を図 6, 図 7 に示す。




図 6 Attention 機構への入力される脳波データ




図 7 Attention 機構から入力される脳波データ

図 6, 図 7 を比較すると電極 AF3, FC5, T7, P7, P8 のデータが比較的平坦となり Attention 機構により注目されていないことが伺える。それらに対して、電極 F7, F3, O1, O2, T8, FC6, F4, F8, AF4 のデータ(図 7 における赤線で囲った電極)は比較的平坦になっていないことから Attention 機構により注目されていることが伺える。そのため、脳波による精神疾患や発達障害の経験者や非経験者を電極 F7, F3, O1, O2, T8, FC6, F4, F8, AF4 のデータにより判別可能であることが示唆された。

5.2.3 精神疾患・発達障害を患っている脳波データを同一の説明変数に含めた点

発達障害や精神疾患は脳波に現れる病の特徴が異なる可能性が考えられる。本研究では、発達障害や精神疾患を患っている人の脳波データを同じ説明変数として扱ったが、病により及ぼされる脳波の特徴が異なるデータを同じ説明変数にすることで、深層学習モデルの判別精度が低下したことが考えられる。今後は、説明変数の種類を病名ごとに増やすことを検討する。

5.2.4 説明変数の信頼性

本研究では、説明変数に用いる病に関する情報を、実験参加者が診断された病を質問票に記載することで収集した。実験参加者が診断された方法が統一されていないため、診断方法にばらつきが存在することが考えられる。その結果、

目的変数のつけ方にばらつきが生じることで、モデル精度に影響が及ぼされる可能性が存在する。また、実験参加者には処方された薬を服用している人もいた。その薬により症状が改善され、病により及ぼされる脳波の特徴が低減・消失することも考えられる。その特徴が低減・消失することで、深層学習モデルによる学習が困難になったがために、精度が低下したことが予測できる。以上のようなデータに対しては説明変数の変更やデータそのものの除去が必要であるが、今後はその方法を検討する。

6. まとめ

本研究では、閉眼安静時の脳波データのみを用いた、精神疾患や発達障害を患っていない人と患っている人との2値分類を行う手法の検討を行った。

生の脳波データを説明変数とし、病を患っているか否かを目的変数として深層学習を行い、2値分類を行うモデルを構築した。そのモデルの交差検証の結果、テストデータの平均精度は67.47%、標準偏差が19.84%とあまり精度が高くないうえ、安定した精度とはならなかった。

この要因を調査するために、交差検証において、精度が低い学習結果のloss値を調査した。休憩を挟んで生体情報の計測を行った前半後半のデータの二群間において、前半のデータは有意にloss値が高いものが存在し、後半のデータと比較して正確に2値分類できていないこと傾向が存在することが判明した。この原因をデータ計測に参加した実験参加者の緊張によるものだと考える。一方、交差検証において精度が高い学習結果における、Attention機構の入出力を可視化した。

その結果、電極AF3, FC5, T7, P7, P8のデータが平坦となり、2値分類への影響が少なくなるようになっていた。一方、電極F7, F3, O1, O2, T8, FC6, F4, F8, AF4のデータは比較的平坦になっていないことから、これらの電極の脳波データにより2値分類が可能であることが示唆された。

精神疾患・発達障害を患っている脳波データを同一の説明変数に含めたことで学習が困難となることが考えられる。また、病が及ぼす脳波データの特徴が薬により低減されることで学習が困難となることが考えられる。今後は、これらのような精度が低下する要因への対応を検討する。

謝辞 本研究は、General Partners 株式会社 atGP ジョブトレ 秋葉原第2 虫生玲 様、芝浦工業大学 客員准教授 駒沢真人 先生のご協力により実現しました。ここに厚く御礼申し上げます。尚、本研究は国立研究開発法人科学技術振興機構 研究成果展開事業 “研究成果最適展開支援プログラム(A-step) 産学共同(本格型): with/post コロナにおける社会変革への寄与が期待される研究開発課題への支援” の助成を受けて実現しました。ここに厚く感謝申し上げます。

参考文献

- [1] 厚生労働省, “精神疾患のデータ,” 精神疾患のデータ | 専門的な情報 | メンタルヘルス | 厚生労働省. [Online]. Available: <https://www.mhlw.go.jp/kokoro/speciality/data.html>. [Accessed: 20-May-2021].
- [2] M. de Bardeci, C. T. Ip, and S. Olbrich, “Deep learning applied to electroencephalogram data in mental disorders: A systematic review,” *Biol. Psychol.*, vol. 162, p. 108117, May 2021.
- [3] P. Marshall, J. Hoelzle, and M. Nikolas, “Diagnosing Attention-Deficit/Hyperactivity Disorder (ADHD) in young adults: A qualitative review of the utility of assessment measures and recommendations for improving the diagnostic process,” *Clin. Neuropsychol.*, vol. 35, no. 1, pp. 165–198, Jan. 2021.
- [4] 伸池田, “精神医学におけるAI活用の現状, 課題, そして可能性,” 人工知能学会全国大会論文集, vol. JSAI2019, pp. 2N5J1303-2N5J1303, 2019.
- [5] American Psychiatric Association, *Diagnostic and Statistical Manual of Mental Disorders*. American Psychiatric Association, 2013.
- [6] E. Moon, S.-H. Lee, D.-H. Kim, and B. Hwang, “Comparative Study of Heart Rate Variability in Patients with Schizophrenia, Bipolar Disorder, Post-traumatic Stress Disorder, or Major Depressive Disorder,” *Clin. Psychopharmacol. Neurosci.*, vol. 11, no. 3, pp. 137–143, Dec. 2013.
- [7] A. Delorme and S. Makeig, “EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis,” *J. Neurosci. Methods*, vol. 134, no. 1, pp. 9–21, Mar. 2004.
- [8] L. Pion-Tonachini, K. Kreutz-Delgado, and S. Makeig, “ICLabel: An automated electroencephalographic independent component classifier, dataset, and website,” *Neuroimage*, vol. 198, pp. 181–197, Sep. 2019.
- [9] I. Loshchilov and F. Hutter, “Decoupled Weight Decay Regularization,” *arXiv [cs.LG]*, 14-Nov-2017.
- [10] Martín Abadi *et al.*, “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems.” 2015.
- [11] F. Chollet and Others, “Keras,” 2015. [Online]. Available: <https://keras.io>.
- [12] H. G. Zhao, *keras-pos-embd: Position embedding layers in Keras*. Github.
- [13] 門脇 大輔, 阪田 隆司, 保坂 桂佑, 平松 雄司, *Kaggle で勝つ データ分析の技術*. 技術評論社, 2019.