

不均衡データセットを考慮した脳波による感情認識

常田 友貴^{†1} 中沢 実^{†1}

概要：

昨今、新型コロナウイルス感染症や DX 化によりオンライン上でコミュニケーションを行う機会が多くなった。しかし、オンライン上での相互の親密なコミュニケーションを必要とする場合では、参加者の満足度低下が余儀なくされている。このような問題を解決するために脳波を用いた感情フィードバックの研究を先行研究として行ってきた。しかし、この研究で収集された脳波・感情データセットは不均衡データセットであり、作成した感情認識モデルでは各クラスで計算された Recall の平均絶対偏差が 9.25 % となり、不均衡データの影響を強く受けた結果となった。そこで本研究では、不均衡データを考慮した SHAP による特徴選択手法を提案し、不均衡な脳波データセットを用いて精度比較を行った。この時、脳波データセットの特徴量数は 14 点と少ないため、脳波周波数帯を用いた特徴抽出により特徴量数を 56 点に増加させたデータに対して特徴選択を行い、既学習・未学習者データにおける精度評価によりキャリブレーションの必要性についても検証を行った。この結果、未学習者データでは大きな精度向上は見られなかったが、既学習者データでは特徴抽出を利用することにより約 30 % の精度向上が得られ、データ性質に着目した特徴選択手法により不均衡データの影響を減少させることができた。

1. はじめに

昨今、オンラインコミュニケーションの増加に伴いオンライン上での相互の親密な意思伝達の困難さ [12] や意思決定を伴う状況でのプレゼンテーションにおいて対面の開催を発表者・参加者共に好むことが指摘されている [11]。この問題を解決する手法として脳波 [10][13][14][16] やカメラ [18] を利用したオンラインコミュニケーション支援ツールが研究されている。この中でも脳波を利用した手法では、通常の感情のみならず無意識や消極的な感情のような外見から予測できない感情を共有する目的に利用され、動作を伴わずにオンライン上においてリアルタイムかつ高精度で感情を共有する手法として期待できる。

このことから講演視聴者の感情を脳波から検出するオンライン講演を対象とした感情フィードバックに関する研究 [14] を行った。しかし、この研究で収集された脳波データセットは不均衡データセットであり、多数派クラスの検出率 (Recall) と少数派クラスの検出率に約 30 %、全体の平均絶対偏差では 9.25 % の差があり、不均衡データの影響が強く残る結果となっている。

また、一般的な脳波を利用したシステムでは、キャリブレーションとして事前に用意したデータセットとは別に新

たに使用者の脳波データを収集し、再学習することにより使用者への予測精度を向上させるが、使用者から収集した脳波データによってはこの不均衡性がさらに高くなることが予想される。さらに、先行研究 [14] のように主観評価を利用するデータセットでは、個人ごとに脳波や感情の評価基準が異なることから、それぞれの脳波や感情の評価基準に適した教師データや学習データの抽出を行うことにより、さらなる精度向上が予想されるが、この個人に適したデータ抽出を行うことにより、データセットの不均衡性はより強くなることが予想される。

そこで、本研究では不均衡な脳波データセットにおける感情認識の精度向上を目的として、オンライン講演視聴時の感情を収集した脳波データセットを用いて XGBoost と SHAP を用いた特徴選択手法の提案と評価を行った。特徴抽出では、脳波データによく利用される Bandpass フィルタを用いて測定された脳波を 4 つの周波数帯に抽出し、特徴量を 14 点から 56 点に増加させた。評価では、脳波データを既学習者・未学習者に分割し、精度評価を行い、既存・提案手法における精度と予測に適したデータ性質による特徴選択への貢献について検証を行い、キャリブレーションや個人ごとに適したデータの必要性について考察を行った。

以降、2 章では脳波における特徴抽出と SHAP を用いた特徴選択と脳波データセットについて、3 章では本研究で提案する SHAP を用いた特徴選択手法について、4 章では

^{†1} 現在、金沢工業大学大学院 工学研究科情報工学専攻
Presently with Department of Information Engineering
Kanazawa Institute of Technology

本提案手法と既存手法を用いた実験概要と結果・考察について、5章では本研究の結論について述べる。

2. 関連研究

2.1 周波数帯による特徴抽出

人見ら [15] によると脳波はその周波数帯により δ 波 (0.5~3Hz), θ 波 (4~7Hz), α 波 (8~13Hz), β 波 (14~30Hz) の4種類に分類されることが説明されている。また、脳波による AI モデルではこれらの周波数帯が利用されることが多く、実際に特徴量として抽出される周波数帯は研究により異なるが、概ねこの4つの周波数帯に近い値が利用されている [7][13]。

入戸野ら [17] によると脳波の分析に利用されるデジタルフィルタは FIR (Finite Impulse Response) フィルタと IIR (Infinite Impulse Response) フィルタの2種類があり、FIR フィルタは波形に及ぼす効果が予測しやすいが計算量が膨大になり、IIR フィルタは波形に及ぼす効果が完全に予測できないが計算量が少ないことが述べられており、脳波ではゼロフェーズフィルタ (zero-phase filter) と呼ばれる位相のずれがないフィルタが優れているといわれ、多くの脳波分析ソフトウェアではこのフィルタがデフォルトあるいは唯一のフィルタとなっていることが説明されている。

2.2 SHAP を用いた特徴選択

特徴選択 (FS: Feature-Selection) はさまざまな手法が提案されており、近年では AI モデルのブラックボックスを説明することができる説明可能な AI (XAI) を用いた手法が研究されている。

Marcilio ら [6] は、SHAP を用いた特徴選択手法について一般的に用いられる相互情報量 (Mutual Information), 再帰的特徴量削減 (Recursive Feature Elimination), 分散分析 (ANOVA) の3つの特徴選択手法を用いて F1 スコアによる評価と比較を行った。SHAP (SHapley Additive exPlanations) [4] は、説明可能な AI (XAI) と呼ばれる機械学習モデルのブラックボックスを説明する手法の1つでシャープレイ値 [9] を用いた手法である。このとき、SHAP を用いた特徴選択では図1のような手法で計算され、 $E_{n \times m}^c$ が各クラスにおいて計算される SHAP 値マトリックス、 c がクラス、 n がデータ数、 m が特徴量数を示している。SHAP では各クラスごとに計算された SHAP 値が $mean(|SHAP_Value|)$ のように計算され、平均絶対値として利用された。この手法では各クラスごとに計算された平均絶対値を全て加算し、その値を順位付けすることにより重要な特徴量を選択している。結果として、SHAP は比較を行った3つの特徴選択手法よりも優れた結果を得ることが示された。

他にも特徴選択手法では、異なるランダムシードを用いて複数回特徴選択を行うと最も重要な特徴量の変動し、こ

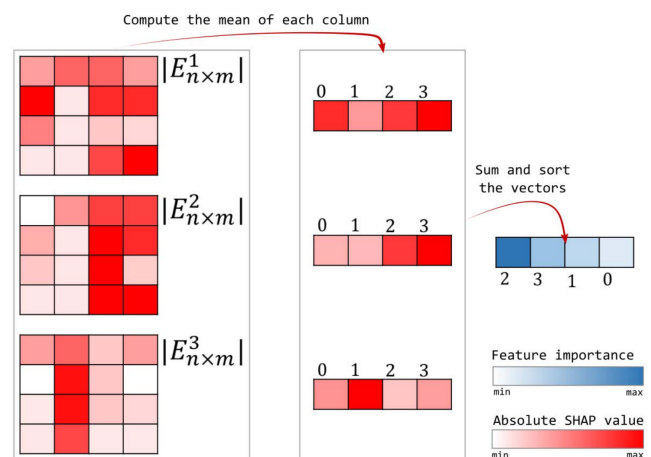


図1 SHAP を用いた特徴選択手法 [6]

の変動が大きくなると適切な順位を計算できなくなるという問題があることから、特徴選択ではランダムシードによる影響が少ない手法が好ましい。そこで、Man ら [5] は特徴選択における順位付けの安定性を不安定性指数 (instability index) と呼ばれる特徴選択時に行われるランダムな繰り返しにおける順位付けのばらつきを評価することができる指標を提案し、SHAP, LIME[8], MDA[2] の3つの特徴選択手法における順位付けの安定性と精度について、2つの合成データセットと2つの公開データセットを利用して評価を行った。この結果として、SHAP と LIME は MDA よりも安定性が高いことが示され、SHAP は比較的安定性が高い手法であることが分かった。

また、本研究では、脳波と各感情との明確な関係が不明であるため、脳波と各感情に適した近傍 (カーネル幅) を定義することは困難であることから、パラメータの設定が不要な SHAP を利用して実験を行う。

2.3 脳波を用いた感情フィードバック

著者らの先行研究 [14] では、オンライン講演を対象に TED 動画5本を使用し、主観評価を用いた複数感情による感情認識と脳波特性分析を行った。この実験には10人の被験者が参加し、視聴ビデオの字幕スライド5枚おきに「通常」、「困惑」、「面白い」、「退屈」の4つの感情で評価を行った。脳波計には非侵襲式ウェアラブル脳波計の EMOTIV EPOCH+^{*1} を使用し、256Hz でサンプリングを行った。また、収録されたデータセットは不均衡なデータセットであることから感情認識と脳波特性分析においては多数派クラスのみデータを削除したデータセットが利用された。感情認識では XGBoost[3] を利用し、データセットを学習用に70%、テスト用に30%を使用してランダムにデータ分割を行った。また、作成した XGBoost と SHAP を利用して重要な脳波特性の分析を行い、XGBoost と SHAP が脳

*1 EMOTIV: EPOCH+ 14-Channel Wireless EEG Headset, 測定電極: 14チャンネル, リファレンス電極: 4チャンネル

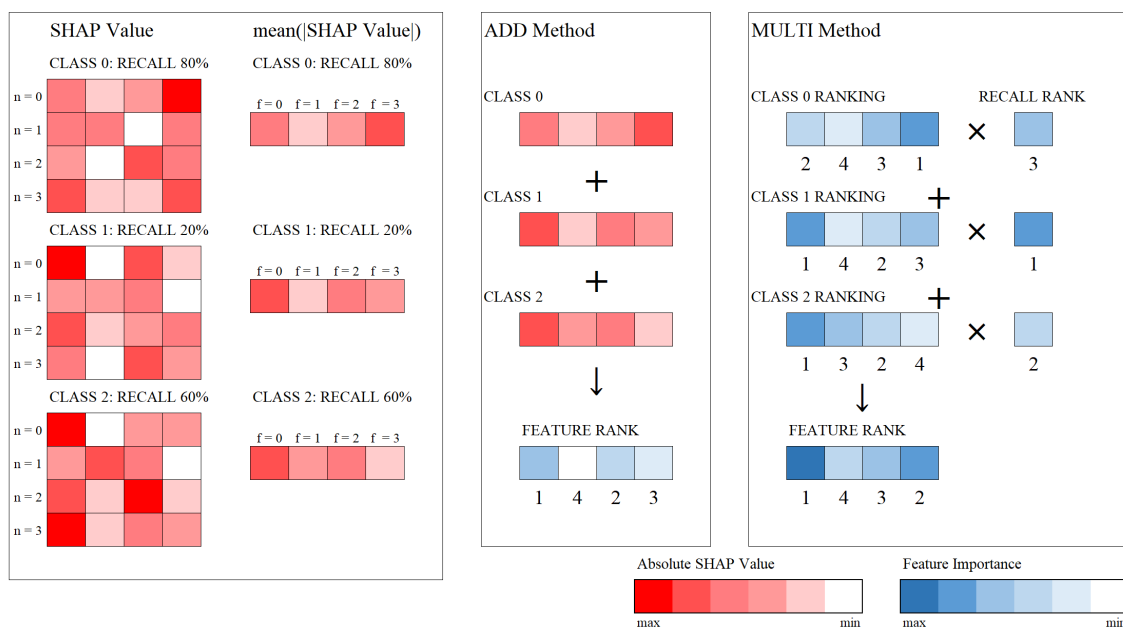


図2 SHAP を用いた特徴選択における既存手法 (Addition Method) と提案手法 (Multiplication Method)*2

波と感情に関わりのある特徴を捉えているのか分析を行った。この結果、XGBoostにより72.47%の予測精度で感情認識を行えるAIモデルとSHAPを利用して脳波特性分析を行い、AIモデルでは感情と脳波の関係が指摘されている前頭葉周辺の脳波を重視していることやF4とO2と呼ばれる脳波測定チャンネルにおいて脳波電圧値と各クラスのSHAP値に相関関係があることを報告した。しかし、不均衡データの影響で多数派クラスと少数派クラスにおいてRecallの差が最大で30%、平均絶対偏差が9.25%となり、不均衡データの影響を強く受けている結果となっている。

また、脳波特性分析では、テスト用データを使用して分析を行ったことから脳波特性分析を行ったデータセットには、AIモデルが識別可能な約70%の正解データと識別不可能な約30%の不正解データが含まれており、追加検証として「全てのデータ」、「正解データのみ」、「不正解データのみ」にデータを分割してSHAPを計算したところ、この3つのデータ性質において重要とされる脳波特性が変化することがわかったため、本研究ではこの「全てのデータ」、「正解データのみ」、「不正解データのみ」についても評価を行い、特徴選択におけるデータ抽出の必要性について考察を行う。

3. 提案手法

前述したように、SHAPを用いた特徴選択手法[6]ではSHAPで計算されたSHAP値を利用して各クラスにおける各特徴量の平均絶対SHAP値を計算し、この結果を加算して順位付け計算が行われる(図1)。この手法を脳波データセットのような不均衡データに対して適用する場合、少数派クラスの精度を向上させる必要があるにもかかわらず全

てのクラスが平等に計算されるため全クラスで重視されている特徴量が高い順位で計算され、少数派クラスのみで重視されている特徴量が低い順位で計算されることになり、少数派クラスの検出率向上(Recall)が期待できない。そこで本研究では、不均衡データセットにおいて少数派クラスの検出精度を向上させるために各クラスの検出率を考慮した特徴選択手法を提案することにより不均衡データにおいて各クラス間検出率の差を最小化することを目指した。

本手法と既存手法[6]の比較を図2に示す。ここでは、本手法を「MULTI Method」、既存手法[6]を「ADD Method」として示す。既存手法(ADD Method)では、図2のように各クラスごとに計算されたSHAP値から平均絶対SHAP値を算出し、各クラスごとの平均絶対SHAP値の合計値を特徴重要度(Feature Importance)として降順で順位付けを行い、AIモデルで重要になっている特徴量を求める。この手法に対し、本手法では、各クラスごとの平均絶対SHAP値に対して降順の順位付けを行い、ここで計算された順位に各クラスのRecallを昇順で順位付けした順位を乗算し、順位付けの合計値に対して再度、降順の順位付けを行い、AIモデルで重要になっている特徴量を求める。本手法では、各クラスの平均絶対SHAP値の順位を利用することにより、各クラスで計算される平均絶対SHAP値の変化による影響を削減し、各クラスごとの順位のみを対象として計算することができるため、既存手法よりも各クラスにおける順位をより重視した計算を行うことができる。

また、SHAPは安定性が比較的高い特徴選択手法である

*2 nはサンプル数、fは特徴量数を示している
図ではサンプル数4の時、特徴量を4つ使用して3つのクラスを予測した際の例を示している

が学習データの変動により計算された順位が変動することから [1][5], 安定性を高めるために 5 分割交差検証を用いて 5 つの AI モデルから特徴量の順位を計算し, この合計値から順位を計算する. この時, 不均衡データを扱うため通常の 5 分割交差検証では少数派クラスを含まないデータ分割を行う可能性があることから, 本手法ではデータの分布比率を維持したままデータ分割を行うことができる層化 5 分割交差検証を利用した.

他にも, AI モデルが予測可能・不可能なデータごとに SHAP 値を計算すると重要とされる特徴量の変動するというデータ性質に着目した順位付けによる, キャリブレーション時の個人に適したデータ抽出の検証として, 「全てのデータ」, 「正解データのみ」, 「不正解データのみ」の 3 種類のデータ性質を用いた特徴選択を行い, 特徴選択に使用されるデータ性質によってモデルの精度がどのように変化するか検証を行った.

4. 実験

本実験では不均衡な脳波データセット [14] を利用して, SHAP を用いた特徴選択手法により各クラス間検出率がどのように変化するかについて評価実験を行った. この実験では, Intel Core i9-9900K CPU, GeForce RTX 3090 及び 64GB メモリを搭載した Ubuntu 20.04.2 LTS を使用し, Python 3.6.9 と XGBoost 1.4.2 及び SHAP 0.40.0 で検証環境を構築し, SHAP Value の計算では Tree SHAP を利用した.

4.1 データセット

先行研究 [14] では学習とテスト共に不均衡なデータを削減したデータセットが利用されたが, 本研究では学習には不均衡なデータを削減したデータセット, テストには削減してないデータセットを利用することで実環境に合わせた精度で評価した. また, 先行研究 [14] では未学習者データを用いた検証をしていなかったが, 本研究では未学習者における精度の検証も行った. したがって, 学習用には対象者以外の削減したデータセットの 70%, 既学習者のテスト用に 30%, 未学習者のテスト用には対象者の無削減のデータセットの 100% を利用し, sklearn の random_state を 64 としてそれぞれ 10 人分の既学習・未学習者の精度を評価した. また, 特徴選択における学習では学習用のデータに対して層化 5 分割交差検証を用いて, 学習用データを 5 分割し, 5 分割された学習データの 70% を学習用, 30% を検証用として特徴選択を行った. そして, この特徴選択結果による AI モデルを全ての学習データを用いて作成し, この AI モデルを利用して既学習・未学習者のテスト用データを評価した.

表 1 XGBoost のハイパーパラメータ

| Parameters | Value |
|-----------------------|----------------|
| booster | gbtree |
| eta(learning_rate) | 1 |
| max_depth | 12 |
| tree_method | gpu_hist |
| objective | multi:softprob |
| eval_metric | mlogloss |
| num_round | 3000 |
| early_stopping_rounds | 10 |

4.2 特徴抽出

特徴抽出では, δ 波 (0.5~3Hz), θ 波 (4~7Hz), α 波 (8~13Hz), β 波 (14~30Hz) [17] の周波数帯を Bandpass フィルタを用いて抽出し, 実装は脳波の処理関数が豊富な MNE^{*3}を使用した. 周波数帯を分けるために利用した Bandpass フィルタ (-6dB/oct) では, ゼロフェーズフィルタを採用し, ハミング窓を利用した FIR フィルタで設計した. また, フィルタの長さは波形歪みが少なく, MNE で推奨されている 6.605 秒間 (1691 サンプル) を使用し, 7 秒間のデータに対してフィルタリングを行い, 中間の 1 秒間を利用した. したがって, 計算手順としては脳波データから平均値を減算し, そのデータに対して Bandpass フィルタを実行し, 平均値を加算することで元の脳波データに近いデータを計算している. この時, 元のデータ数が変化しないようにデータの始端, 終端において直近 1 秒間の平均値を 3 秒間の穴埋めに利用した.

4.3 実験設定

AI モデルでは, 先行研究のモデル (XGBoost Prev) [14] を利用すると複数のモデルを利用する本研究では計算量が膨大になることから表 1 のハイパーパラメータを利用した. 表 1 では, ハイパーパラメータの学習率 (eta) を 1 にすることにより最大学習回数 (num_round 数) が減少するため, 指定回数モデルに改善がない場合, 学習を停止することにより過学習を防止する early_stopping_rounds を 10 として実験を行った. また, XGBoost において不均衡なデータに対応するために学習データによって得られる重みに対して (最も少ないクラスのデータ割合) / (そのクラスのデータ割合) を加えることにより学習データの学習率にデータの不均衡性を考慮した重みを利用した.

本研究では以上の設定により, 以下の項目に関する検証を行った.

- (1) SHAP を用いた特徴選択手法におけるデータ性質の精度
- (2) 既学習・未学習者における各クラス間における精度のばらつきを最小にする手法
- (3) 既学習・未学習者における最良の特徴量数

*3 <https://mne.tools/stable/index.html>

表 2 SHAP を用いた特徴選択におけるデータ選択による精度比較 (1) (2)

| Model | Features | Method | Data Info | Acc±SD | Recall±SD | MAD Rec±SD | Precision±SD | MAD Pre±SD |
|----------------|----------|--------|-----------|---------------------|---------------------|---------------------|---------------------|---------------------|
| Learned Data | | | | | | | | |
| XGBoost Prev | 14 | None | None | 66.71±1.30 % | 64.71±1.27 % | 4.62±0.81 % | 66.67±1.49 % | 0.83±0.39 % |
| XGBoost | 56 | None | None | 99.01±0.08 % | 98.90±0.10 % | 0.25±0.05 % | 99.06±0.08 % | 0.14±0.02 % |
| XGBoost+FS | 14 | ADD | All | 98.82±0.17 % | 98.71±0.18 % | 0.27±0.05 % | 98.88±0.16 % | 0.15±0.03 % |
| XGBoost+FS | 14 | ADD | Correct | 98.82±0.16 % | 98.71±0.19 % | 0.26±0.07 % | 98.87±0.16 % | 0.15±0.03 % |
| XGBoost+FS | 14 | ADD | False | 98.63±0.12 % | 98.51±0.14 % | 0.31±0.05 % | 98.69±0.12 % | 0.15±0.04 % |
| XGBoost+FS | 14 | MULTI | All | 99.02±0.18 % | 98.92±0.21 % | 0.23±0.06 % | 99.06±0.16 % | 0.13±0.04 % |
| XGBoost+FS | 14 | MULTI | Correct | 99.03±0.17 % | 98.94±0.20 % | 0.22±0.06 % | 99.08±0.15 % | 0.13±0.04 % |
| XGBoost+FS | 14 | MULTI | False | 98.76±0.20 % | 98.64±0.23 % | 0.29±0.07 % | 98.82±0.20 % | 0.15±0.04 % |
| Unlearned Data | | | | | | | | |
| XGBoost Prev | 14 | None | None | 31.56±3.47 % | 27.64±3.48 % | 12.54±3.38 % | 30.68±8.48 % | 12.79±5.30 % |
| XGBoost | 56 | None | None | 33.97±5.97 % | 29.38±5.19 % | 17.58±5.80 % | 32.80±8.75 % | 13.48±5.14 % |
| XGBoost+FS | 14 | ADD | All | 32.10±4.26 % | 27.65±4.10 % | 15.96±5.63 % | 31.16±8.21 % | 12.74±5.22 % |
| XGBoost+FS | 14 | ADD | Correct | 32.30±4.16 % | 27.86±3.85 % | 15.98±5.75 % | 31.44±8.27 % | 12.76±5.22 % |
| XGBoost+FS | 14 | ADD | False | 31.86±4.02 % | 27.38±3.85 % | 16.16±5.70 % | 31.06±8.37 % | 12.92±5.61 % |
| XGBoost+FS | 14 | MULTI | All | 31.99±4.15 % | 27.56±3.67 % | 16.27±5.25 % | 30.84±7.86 % | 13.10±5.01 % |
| XGBoost+FS | 14 | MULTI | Correct | 31.99±4.03 % | 27.56±3.84 % | 16.12±5.43 % | 31.14±7.88 % | 12.76±5.09 % |
| XGBoost+FS | 14 | MULTI | False | 31.93±4.76 % | 27.56±3.78 % | 16.50±5.75 % | 31.00±8.32 % | 13.13±5.29 % |

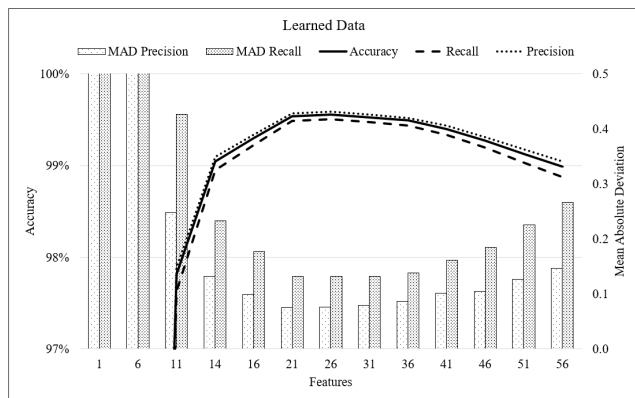


図 3 Correct のみを利用した特徴選択の検証データにおける結果 (3)

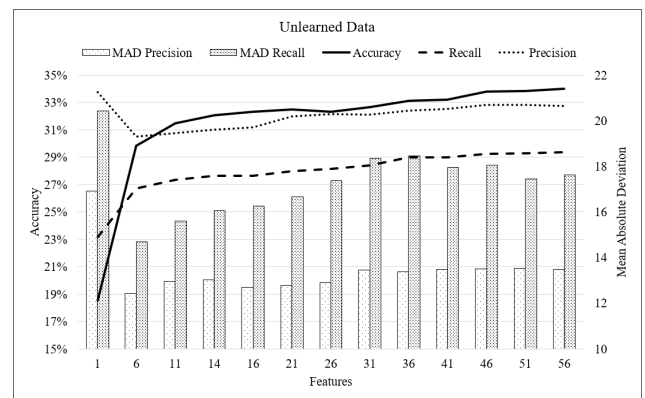


図 4 Correct のみを利用した特徴選択のテストデータにおける結果 (3)

したがって、評価方法では使用するデータセットが多クラス分類かつ不均衡なデータセットであるため、Accuracyの他に各クラスの Recall (検出率) と Precision (信頼性) の平均値と平均絶対偏差 (MAD: Mean Absolute Deviation) で評価し、これらは被験者 10 人の平均値であることから被験者間のばらつきを評価するために各指標ごとに不偏標準偏差 (SD: Standard Deviation) を計算した。

また、特徴選択では先行研究 [14] の特徴量が 14 点であることから 14 点まで特徴量を選択して実験を行った。

4.4 実験結果

(1), (2) の結果について表 2 に示す。表中では SHAP による特徴選択手法を Method, データ性質を Data Info, 被験者ごとの平均精度を Acc, Recall, Precision, 各クラスの Recall と Precision の平均 MAD を MAD Rec, MAD Pre, 被験者ごとの不偏標準偏差を SD (Standard Deviation) と

して示す。

既学習者による検証結果 (Learned Data) より、周波数帯による特徴抽出 (XGBoost) では先行研究の脳波電圧値 (XGBoost Prev) を利用した AI モデルよりも予測精度が約 30 % 向上し、各クラス間における精度のばらつきも減少させることができた。この AI モデルにおける SHAP を用いた特徴選択の結果、既存手法では精度、各クラス間における精度のばらつきの全てにおいて精度が低下ことに対して、提案手法では全ての精度、各クラス間における精度のばらつきにおいて最良の精度を得ることができた MAD Rec が他の手法よりも低い結果であったことから既存手法よりも各クラス間における Recall のばらつきを減少させることができた。また、データ性質では既存・提案手法を通して「全てのデータ」、「正解データのみ」の精度が同等または高くなり、「不正解データのみ」の精度は低下したが、提案手法においては「正解データのみ」の精度が最も高い

精度となった。他にも被験者間のばらつきでは、周波数帯による特徴抽出を利用することで先行研究よりも減少させることができたが、特徴選択による影響は見られなかった。

未学習者による検証結果 (UnLearned Data) より、周波数帯による特徴抽出では先行研究の予測精度よりも数%高くなったが、各クラス間における精度のばらつきは増加した。この AI モデルにおける SHAP を用いた特徴選択の結果、既存・提案手法共に Accuracy, Recall, Precision の精度は低下したが、各クラス間における精度のばらつきは減少した。また、データ性質では既存手法において「正解データのみ」は、「全てのデータ」の精度と同等または高くなり、「不正解のデータ」の精度は低下していたが、提案手法ではほぼ同等の精度であった。他にも被験者間のばらつきでは、周波数帯による特徴抽出を利用することで全ての精度が低下し、各クラス間における精度のばらつきは先行研究より増加したが、特徴選択を行うことにより MAD Pre 以外の精度を向上させることができた。

(3) の結果については、(1)、(2) の結果から最も高精度が見込める提案手法 (MULTI) の「正解データのみ」を使用した AI モデルにおいて、特徴量数と精度における実験を行った結果を図 3、4 に示す。図中では、精度を Accuracy, 各クラスの平均値を Recall, Precision として折れ線グラフ、各クラスの Recall と Precision の平均絶対偏差を棒グラフ、特徴量数は 1~56 個の間を 5 個間隔で示す。既学習者の結果 (図 3) より、特徴選択は特徴量数が 26 個の時に Accuracy, Recall, Precision が最も高くなり、21 個の時に各クラス間における精度のばらつきが最も小さくなることが分かった。未学習者の結果 (図 4) より、Accuracy は徐々に低下し、各クラス間における精度のばらつきではある程度精度を保ったまま特徴量数が減少するにつれ、ばらつきも減少していくことが分かった。

4.5 考察

(1) では既学習者データでは提案手法が、未学習者データでは既存手法が「正解データのみ」の精度が他のデータ性質よりも精度が同等または高くなったことから、「正解データのみ」のデータ性質に着目することにより、特徴選択手法が重要な特徴量だと計算される特徴を強化することができると考えられる。また、既学習者データでは提案手法が優れ、未学習者データでは既存手法が優れていたことから、既存手法では学習データ全体の特徴量、提案手法では学習データ固有の特徴量を重視していることが考えられる。しかし、このデータセットでは、各被験者による主観評価を利用した教師データを用いているため、各被験者ごとの評価基準と脳波特徴が一致しているかが未検証であり、既存・提案手法において重視している特徴量については、過学習か学習データにおける被験者の評価基準に最適化されているかは不明のままである。また、本実験では周

波数帯を用いた特徴抽出により (図 2 中の既学習者データにおける XGBoost) 99.01 % という非常に精度の高い AI モデルを利用していることから、「不正解データのみ」に着目したデータ性質では、使用できるデータが非常に少ないことから各精度低下の原因がデータ量であるのか、データセット中に含まれる外れ値であるかは不明のため、未学習者データの一部を利用して AI モデルを作成し、この AI モデルを利用したデータ性質に着目した既学習者データからの個人に適したデータ抽出による精度評価を行い、データ性質によるデータ抽出手法がキャリブレーション時の再学習モデルへの精度向上に有効かどうかといった検証が必要である。

(2) では既学習者データでは提案手法を利用することにより各精度が向上し、MAD Rec, MAD Pre といった各クラス間における精度のばらつきが減少していたことから提案手法により、全ての特微量を使用した際の Accuracy を保ったまま、各クラス間における精度のばらつきを減少させる特微量を選択することができた。また、未学習者データでは、既存・提案手法共に Accuracy, Recall, Precision の精度は低下したが、既存手法を利用することにより、比較的高い精度を保ったまま各クラス間における精度のばらつきを減少させることができたが、前述のように脳波データでは個人ごとで脳波特徴が大きく変化することがあることから未学習者データにおいてはその脳波特徴そのものが、既学習者データとは異なる場合があることから、未学習者データにおける結果が過学習か最適化された結果であるのかは不明のままとなっている。

(3) では特徴選択を利用することで既学習者データでは精度を向上させ、各クラス間における精度のばらつきを減少させることができ、未学習者データでは徐々に各精度が低下したが、各クラス間における精度のばらつきもおおむね減少させることができた。このことから提案手法では既学習者データは 26 個の特徴量を使用することで 99.56 % の精度で予測し、各クラス間における精度や被験者のばらつきも最小限にすることができ、未学習者データは 51 個の特徴量を使用することで 33.82 % の精度で予測し、被験者や各クラス間における精度のばらつきも減少していたことから、提案手法において最も精度が期待できる特徴量数を見つけることができた。しかし、未学習者データにおいては各精度が低いことから既学習者データと異なる特徴を持っていることが考えられるため、キャリブレーションでは未学習者データの一部を学習した AI モデルを利用してデータ性質に着目したデータ抽出を行い、未学習者データの脳波特徴に近いデータを抽出することが必要だと考える。

5. 結論

本研究では、不均衡な脳波データセットにおいて各クラス精度の検出率 (Recall) を改善するために、SHAP と

Recall を利用した特徴選択手法を提案し、脳波周波数帯を用いた特徴抽出を行ったデータに対して既学習・未学習者における精度評価を行うと共に、各クラス間における精度のばらつきを最小限にする感情認識モデルの検証とキャリブレーションや個人ごとに適したデータの必要性について実験と考察を行った。結果として、脳波周波数帯を用いた特徴抽出により先行研究と比較して 30 %近い精度が向上し、SHAP を用いた特徴選択により「全てのデータ、正解データのみ」を使用した提案手法が比較的高い精度かつ各クラス間における精度のばらつきを最小化し、不均衡データセットの影響を減少させることができた。また、データ性質に着目することにより、精度を向上させることができたことから、キャリブレーションにおいて未学習者データの一部を学習し、その予測結果から「正解データのみ」のデータを利用することにより、個人に適したデータを抽出できる可能性があることが分かった。しかし、脳波データでは一般的に個人ごとに重要視される特徴が異なることや主観評価による教師データでは個人ごとの感性による違いが発生することが想定されることから、未学習者データでは、この結果が過学習によるものなのか、既学習者データに含まれる個人ごとの感性による教師データに最適化したものなのか断言することができないことから、このデータセットにおける各被験者ごとの教師データと脳波特性が同一のものか分析が必要という課題を見つけることができた。

今後は、このモデルを使用した感情フィードバックシステムの実装やキャリブレーションを必要としない感情認識モデルを目指して、SHAP を用いた特徴選択だけでなく、GAN を利用したデータ拡張や学習データから使用者に適したデータを抽出する手法について検討を行っていききたい。また、本研究において被験者ごとの教師データと脳波特徴が一致しているか未検証であるという課題を見つけることができたため、SHAP を用いて類似の貢献度を持つデータにおける脳波電圧と貢献度を比較し、その特徴分析により、AI モデルが重要視している脳波を可視化し、どのような波形や脳波電圧値を重視しているのかを検証していききたい。

参考文献

- [1] Alaiz-Rodríguez, R. and Parnell, A. C.: An information theoretic approach to quantify the stability of feature selection and ranking algorithms, *Knowledge-Based Systems*, Vol. 195, p. 105745 (online), available from (<https://mural.maynoothuniversity.ie/16236/>) (2020).
- [2] Breiman, L.: Random Forests, *Machine Learning*, Vol. 45, pp. 5–32 (online), DOI: 10.1023/A:1010950718922 (2001).
- [3] Chen, T. and Guestrin, C.: Xgboost: A scalable tree boosting system, *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785–794 (2016).

- [4] Lundberg, S. M. and Lee, S.-I.: A Unified Approach to Interpreting Model Predictions, *Advances in Neural Information Processing Systems*, Vol. 30, Curran Associates, Inc., (online), available from (<https://proceedings.neurips.cc/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf>) (2017).
- [5] Man, X. and Chan, E. P.: The Best Way to Select Features? Comparing MDA, LIME, and SHAP, *The Journal of Financial Data Science*, Vol. 3, No. 1, pp. 127–139 (online), DOI: 10.3905/jfds.2020.1.047 (2021).
- [6] Marçílio, W. E. and Eler, D. M.: From explanations to feature selection: assessing SHAP values as feature selection mechanism, *2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pp. 340–347 (online), DOI: 10.1109/SIBGRAPI51738.2020.00053 (2020).
- [7] Parui, S., Bajiya, A. K. R., Samanta, D. and Chakravorty, N.: Emotion recognition from EEG signal using XGBoost algorithm, *2019 IEEE 16th India Council International Conference (INDICON)*, IEEE, pp. 1–4 (2019).
- [8] Ribeiro, M. T., Singh, S. and Guestrin, C.: "Why Should I Trust You?": Explaining the Predictions of Any Classifier, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, CA, USA, August 13-17, 2016*, pp. 1135–1144 (2016).
- [9] SHAPley, S. M.: A VALUE FOR n-PERSON GAMES, *Contributions to the Theory of Games*, Vol. 2, pp. 307–317 (1953).
- [10] Wang, H., Li, Y., Hu, X., Yang, Y., Meng, Z. and Chang, K.-m.: Using EEG to Improve Massive Open Online Courses Feedback Interaction., *Proceedings of the AIED Workshops* (2013).
- [11] 一般社団法人プレゼンテーション協会: オンライン/オフライン・プレゼンテーションに関する意識調査, 入手先 (<https://presen.or.jp/2020/10/2495/>) (参照 2022-03-10).
- [12] 横井豊彦, 佐藤真治: 対面と非対面のコミュニケーションのプロセスの違いについて, *大阪産業大学 人間環境論集*, Vol. 18, pp. 65–78 (2019).
- [13] 三ツ木萌, 丸山一貴: 脳波と皮膚電気活動を用いた観客の盛り上がり推定の試み, *エンタテインメントコンピューティングシンポジウム論文集*, Vol. 2021, pp. 370–374 (2021).
- [14] 常田友貴, 中沢実: 脳波を利用したオンライン講演の感情フィードバック, 第 29 回マルチメディア通信と分散処理ワークショップ論文集, pp. 57–63 (2021).
- [15] 人見健文, 池田昭夫: 脳波の基礎知識, *臨床神経生理学*, Vol. 42, No. 6, pp. 365–370 (オンライン), DOI: 10.11422/jscn.42.365 (2014).
- [16] 長瀬綾佑, 藤田晃佑, 唐山英明, ギョームロベズ, 戸辺義人: 脳波を利用した遠隔通信相手集中度計測システムの設計と実装, 第 79 回全国大会講演論文集, Vol. 2017, No. 1, pp. 335–336 (2017).
- [17] 入野野宏, 小野田慶一: 事象関連電位の波形に及ぼすフィルタの効果, *生理心理学と精神生理学*, Vol. 26, No. 3, pp. 237–246 (オンライン), DOI: 10.5674/jjppp1983.26.237 (2008).
- [18] 林晃世, 平林真実, 小林昌廣: ハートトゥハートオンラインコミュニケーション, *エンタテインメントコンピューティングシンポジウム論文集*, Vol. 2021, pp. 11–14 (2021).