



卒業研究報告書

令和6年度

研究題目

個人差を含むプログラミング理解時の脳波
に対するクラスタリングの特徴分析

指導教員 上野秀剛 准教授

氏名 村上拓也

令和7年1月23日 提出

奈良工業高等専門学校 情報工学科

個人差を含むプログラミング理解時の脳波

に対するクラスタリングの特徴分析

上野研究室 村上 拓也

プログラミング教育の分野において作業員に対する理解支援が求められている。それにあたり、作業員の理解状態を正しく把握し作業員に対して適切な支援を行うことが必要となる。作業員の理解状態を正しく把握する手段として脳波に着目した手法が提案されている。プログラム理解に関する研究において、脳波は周波数帯域によって δ 波、 θ 波、 α 波、 β 波、 γ 波の5種類に分類される。これらの周波数成分について、脳活動によって強く表れてくる成分が異なり、プログラム理解においては α 波、 β 波に理解時の特徴が強く表れるといわれている。周波数成分は δ 波、 θ 波、Low- α 波、High- α 波、Low- β 波、High- β 波、Mid- γ 波、Low- γ 波の8種類に細分化でき、細かく分類を行うことでプログラム理解時の特徴がより明確に表れるとされている。また、プログラム理解時の脳波においてはその時系列により重要度に差があることが知られており、時系列分析が有効とされている。時系列分割したデータをそれぞれ理解時のデータ、未理解時のデータとしての2ラベルで教師有学習を行うことでプログラムの理解状態を予想する研究も存在する。しかし、脳波には個人差が含まれておりプログラムの理解、未理解の脳波のデータの特徴が1つに限定されるとは考えられないため、脳波の周波数成分をクラスタリングすることにより、プログラムの理解状態の周波数成分の特徴を分析した研究も存在する。本研究では、クラスタリングを行った脳波データに対して観点の異なる複数の指標を用いた分析を行うことで、脳波の個人差の分類分けとしてクラスタリングがどの程度有用化を調査する。分析では、8種類の周波数成分と時系列分割数8の64次元のデータに対してPCA圧縮を行い、得られたデータに対してk-means法を用いてクラスタ数は2から20まで可変とし、クラスタリングを行った。得られたクラスタリング結果に対してDBIおよびシルエットスコアの値を計算し、分析を行った。PCA圧縮後に得られたデータをクラスタリングすると、ほとんどすべてのクラスタ数において特定のデータのみが単独でクラスタに分類されていたため、このデータを外れ値とし、149のデータに対して分析を行った。結果として、シルエットスコアとDBIの間にはトレードオフの傾向が見られた。また、得られたクラスタリング結果および各被験者のタスクごとの理解状態をもとに各クラスタ数における各クラスタに含まれているデータの内訳を調査すると、クラスタにデータが1つしか分類されていない単独クラスタが複数存在し、この単独クラスタの数が増えるとDBIによる評価値は上昇した。この単独クラスタとして分類されているデータには個人差を含んでいると考えられ、単独クラスタに分類されているデータを追跡すると、すべての単独クラスタについて、それぞれ特定の被験者における特定のタスク実行時の脳波データが分類されていたことが確認できた。本研究の結果として、クラスタリングを用いることで、単独クラスタとして分類されたデータの精査を行うことで個人差を含むデータの特徴が可能になったといえる。

目次

1	はじめに	2
2	関連研究	3
3	脳波	6
3.1	測定方法	6
3.2	周波数帯域	6
3.3	脳波の個人差	7
4	実験	9
4.1	実験環境	9
4.2	タスク	9
4.3	実験手順	10
4.4	分析	11
4.4.1	データの正規化	11
4.4.2	PCA圧縮	11
4.4.3	k-means法	12
4.4.4	シルエットスコア	12
4.4.5	DBI	12
5	結果と考察	13
5.1	PCA圧縮による次元圧縮	13
5.2	クラスタリング	14
5.2.1	シルエットスコアとDBI	14
5.2.2	より詳細な分析	15
6	おわりに	19
	謝辞	21
	参考文献	22

1 はじめに

プログラミング教育の分野において,学習者の理解の度合いを把握した上で適切な補助をすることが求められる.しかし,プログラミング作業の大部分は思考プロセスが占めているため,学習者の外観などから理解度を把握することは困難である.学習者の理解度を把握する手法としてヒアリングやアンケート調査といった手法も考えられるが,学習者の学習を中断させることになるため非効率的である.

学習者のプログラムに対する理解度を把握するための手段として脳波があげられる[1].脳波は人間の脳活動を測定・分析する手段の1つであり,対象者の思考状態と特定の周波数帯域における振幅の強さが関連することが分かっている.脳波の測定には脳波計測装置を装着し,作業を行ってもらうことで作業中のデータの測定が可能となるため,口頭によるヒアリングやアンケートと比較すると学習者の負担は減少するため学習を中断および妨害する可能性は低くなると考えられる.プログラム理解時の脳波を分析した先行研究[2]では,8種類の周波数成分(δ 波, θ 波,High- α 波,Low- α 波,High- β 波,Low- β 波,High- γ ,Mid- γ 波)を対象に分析を行っている.プログラム理解タスク中の被験者を計測して得られる脳波を等間隔な時間に1~10分割し,それぞれの脳波から算出される周波数成分を特徴量として機械学習をした結果,プログラムの理解状態を最高で86.5%の精度で判別している.

一方で,脳波には個人差があり,同じ理解している状態でも周波数成分の特徴が異なる被験者がいる場合がある[3].プログラム理解状態の判別の精度を向上させるには,脳波の個人差の特徴を明らかにする必要がある,個人差の特徴を考慮した分析を行う必要がある.図1に脳波データのクラスタリング結果のイメージ図を示す.石田らの研究[7]において立てられた仮説の下では,脳波データが図1の実線のようにそれぞれ1つのクラスタとなると考えられている.しかし,脳波データに含まれている個人差により,同じ被験者であっても特徴の異なるデータが存在するため,図1の点線のように,同じ理解状態でも異なるクラスタとして分類されることが考えられる.そこで本研究では,個人差による異なる特徴を持つデータがどのようにクラスタリングされるかについて分析を行った.

橋本は,脳波データを等間隔な時間に8分割し,それぞれから8つの周波数成分を算出した64次元のデータをPCA圧縮したのちにクラスタリングを行い,各クラスタにおける正答率を以って個人差の分類を行っていたが,十分な成果が得られていない.

本研究はクラスタリングを用いることで個人差をどの程度分類できるかを分析する.クラスタリング結果を評価するいくつかの指標があり,その中でも本研究ではシルエットスコアおよびDBIについて注目し,分析を行う.これらの指標はそれぞれ異なる観点でクラスタリング結果を評価する指標であり,これらの評価

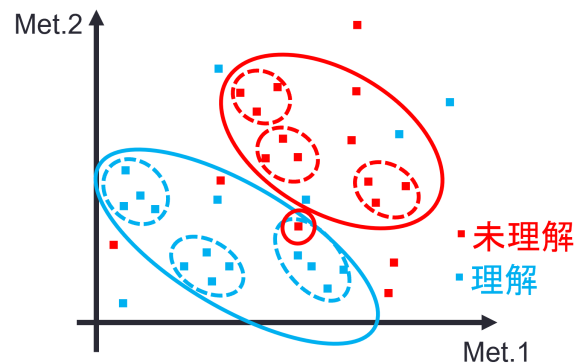


図1 脳波データのクラスタリング結果のイメージ図

指標において評価結果に違いがみられれば今後の研究においてクラスタリング手法の改善や,正規化手法の改善につながる有用な知見が得られると考えられる. 具体的には以下の2つの問い (Research Question) を立て, 分析を行う.

RQ1 クラスタ数を増やしていくことで新たに分割されるクラスタの特徴は何か

RQ2 DBIおよびシルエットスコアのそれぞれに対して,クラスタ数を変動させた際の評価値の変化の仕方についての違いがみられるかどうか

以下, 2章では関連研究について説明し, 3章では脳波について,4章では実験環境,手順および分析方法について説明し,5章ではその結果と考察を述べる.6章では本研究におけるまとめと今後の展望について述べる.

2 関連研究

プログラムを理解しているかどうかについて,生体情報を利用することで定量的に評価を行っている研究が数多く存在する. 生体情報とは,視線や脳波,心音などの生体活動のために行われている体内活動のことを指す. 近年では脳波計測装置の普及に伴い,プログラム理解と脳波の計測とを組み合わせた研究が数多く存在している.

Siegmundらは脳の血流変化を測定する装置であるfMRIを用いてプログラム理解時の脳活動を観測した. 脳は領域ごとに役割がわかれており,思考状況により特定の領域が活性化する. fMRIを用いることでプログラムを理解している際の血流変化を測定し,どの領域が活性化しているかを測定することができる. Siegmundらの研究の結果によると,プログラムを理解する際に被験者の問題解決や記憶,文章理解に関する領域が活性化することが示されている [1]. fMRIを用いた計測ではどの領域が活性化しているかを明らかにでき,プログラム理解と特定の脳

部位の関係性について明らかにすることができる。しかしfMRIでは、被験者が装置の中に横たわって測定する必要があるため、被験者の体動や思考を強く制限してしまい、教育現場や仕事場などの実際のプログラム環境において理解状態を計測し、プログラム理解を支援することは難しい。そこで、fMRIでの計測と比べて体動の制限が少ない脳波計測装置を用いた研究が注目されている。

この結果を受けてMartinらは脳波計測装置を用いてプログラム理解における脳活動を記録した。脳波を計測することで、異なる種類の短いソースコードに対する脳の反応が異なるかどうかを調査し、その結果認知的負荷が高い場合には、 α 波と θ 波のパワースペクトルが増加することが示されている[5]。Klimeschは、 α 波が記憶能力に応じて変化することを観測している。この研究では α 波の中でもHigh α 波が意味記憶に対して、Low α 波が集中している時に反映されることが示されている[6]。

石田はバグを探しているプログラマの状態を知るために視線と脳波の分析を試みた。プログラマの状態を把握するにあたり、視線や脳波の計測を行う研究は多く行われていたが、視線と脳波を組み合わせた研究は行われていなかった。石田はプログラマの状態をプログラムの動作を理解しているか、またバグを正しく判断出来るかの2つに分け、2つの状態時の分析を行った。分析の結果、プログラム動作を理解している時には α 波が増幅し、バグを判断出来た時には β 波が増幅することが確認できた[4]。また、別の研究では、視線と脳波に対して同期した時系列分析を行うために、デバッグを行うプログラマの理解過程を時系列に計測することを目的とした脳波特徴の時系列分析を試みた。実験の結果、プログラムの動作を理解をしている被験者はタスク開始時と終了時の α 波と β 波が他の時系列の脳波と比較して有意に高く、バグを正しく判断している被験者はタスク開始時と終了時の α 波が他の時系列の脳波と比較して有意に高くなることが示されている[7]。このような結果から、脳波は被験者の状態によって逐次変化する為、リアルタイムでの支援を行う為には時系列分析が有効とされている。

山本の研究では、プログラミング中に計測した脳波から周波数成分の時系列変化の分析を試みた。分析の結果、最大で全被験者の平均より倍近い α や β が計測される場合があり、その原因として、ノイズ除去処理によって取り除くことができなかった筋電位によるノイズや個人差であるとしている[8]。これを受け、松山の研究ではプログラム理解を行う開発者の脳波に対して複数の周波数成分の時系列分析を行い、機械学習を用いることで理解の有無を自動で判別できるかの評価を試みた。分析においては、被験者の平均値についてパワースペクトルを正規化し、個人差によって受けた影響を考慮した分析を行った。分析の結果として、脳波の周波数成分に大きな個人差が見られたものの、被験者の半数以上で解法の見当たっていた時の α 波が有意に大きかったため、個人差の影響は受けるもののプログラミング作業者の状態を把握する指標として有用であるとしている[2]。

橋本の研究では,個々の理解/未理解の脳波データを2つ以上のクラスタとして分類することを目的とし,プログラム理解状態の周波数成分の特徴を分析した.分析結果として,正答率が8割を超えるようなクラスタが複数存在し,これらの複数のクラスタへの分類パターンを個人差であるとしている [3].

本研究では,クラスタリングを行った脳波データに対して,観点の異なる複数の指標を用いた分析を行うことで,プログラム理解の分野において現れる脳波の個人差の分類分けとしてクラスタリングがどの程度有用かを調査する.

3 脳波

3.1 測定方法

脳波とは,脳から発生する微小な電気活動における電位を縦軸に,時間を横軸として記録したものであり,被験者の頭皮上の複数の電極から計測される.測定に当たり,電極の配置は以下図に示す国際式10-20電極法にのっとり行う[9].国際式10-20電極法では前後は鼻根から後頭結節,左右は耳の穴同士のそれぞれの半球に対して10:20の比率で間隔を定め,その交点の間に電極を配置する[10].




図2 国際式10-20電極法

脳波の導出方法には主に2つの方法があり,基準電極導出法と双極導出法が挙げられる.基準電極導出法は一对の入力端子に対して,一方の端子には探查電極を,もう一方には基準電極をつなぐことで両電極間の電位差を記録する方法である.双極導出法は基準電極導出法とは異なり基準電極を持たず,すべての端子を探查電極とする方法である.計測用電極間の距離が狭い場合に電位差を計測する際には基準電極法を,脳における部位差を強調する目的で計測する場合には双極導出法を使用する[11].本研究で扱ったデータは基準電極導出法を用いて記録された[12].

3.2 周波数帯域

脳波は異なる複数の周波数の波形が組み合わされたものから成り,周波数帯域ごとに異なる成分として分類される.各成分は異なる特徴を持ち,心理や認知活動の状態によって変化する.周波数成分を抽出する手段として,高速フーリエ変換(FFT:Fast Fourier Transform)や短時間フーリエ変換(STFT:Short Time Fourier Transform)がある.

表1に脳波の周波数成分ごとの代表的な分類と特徴を示す. δ 波および θ 波は睡眠時に出現し,覚醒状態ではほぼ出現しない. α 波は閉眼安静時でリラックスした状態の時に後頭部を中心によく現れる成分とされている. β 波は前頭葉を中心に

広がり,外部からの刺激やストレスに対する反応として現れることが多い。 γ 波は不安な状態や,興奮している状態の時に出現しやすい[13].

表1 脳波の周波数成分と心理状態

周波数成分	周波数帯域 [Hz]	心理状態
δ 波	0.5~2.75	ノンレム睡眠, 無意識
θ 波	3.75~6.75	直感的, 創造的, 想起, 空想, 夢
Low α 波	7.5~9.25	リラックス, 平穏, 意識的
High α 波	10~11.75	リラックスしているが集中している, 統合的
Low β 波	13~16.75	思考, 自己及び環境の認識
High β 波	18~29.75	警戒, 動揺
Low γ 波	31~39.75	記憶, 高次精神活動
Mid γ 波	41~49.75	視覚情報処理

本研究が対象とするプログラミング理解時における脳波を分析した過去の研究において,プログラムの理解状態の判別には α 波, β 波が特に有用であることがわかっている[2]. また,周波数成分を細かく分類すると,プログラム理解の状態により *Low β* , *High β* , *Mid γ* , *Low γ* 波に差があることが示されている[14].

3.3 脳波の個人差

脳波にはその波形の出方に個人差が存在する[15]. 山本の研究[8]においては,プログラム理解タスク時の α 波と β 波に理解/未理解時の差が観測されている. 一方で, 同じ理解状態であっても,他のデータとは傾向が異なる脳波が観測されており,個人差であると考察している

脳波を分析する際には個人差による影響を考慮する必要がある. 脳計測を行っている研究の多くでは,一部の被験者について特定の周波数における値が他の被験者と比較して極端に異なる場合や,反対の傾向が表れてくるような場合が存在することが報告されている[16]. 他にも,被験者により,特徴量の出やすい周波数の組み合わせが異なる例も報告されている[15]. プログラム理解の分野においては,学習者から得られた脳波データをもとにプログラムを理解できているのかを推測することが求められる. しかし,同じタスクを理解している学習者でも他の学習者と比較して極端に異なる特徴や,反対の傾向が表れた場合に理解していないと判断されてしまう可能性が問題点として挙げられる.

松山の研究[2]では,脳波の各周波数成分ごとのパワースペクトルに対してその被験者におけるパワースペクトルの平均値で割ることによって正規化を行い,個人間の周波数成分の増加量による個人差を軽減している. この方法では,特定の周波数成分における特徴量の現れ方の大小については対応可能であるが,一方で異なる周波数成分の組み合わせに対して発生する個人差には対応できていない.

橋本 [3] は、同じ理解状態であっても、その周波数成分の特徴は複数存在する可能性があることからクラスタリングを用いた周波数成分による個人差を考慮した分析を行っている。結果として、正答率が8割を超えているクラスターが複数存在したことからプログラムを理解した際の脳波の複数パターンへの分類が可能であり、このパターンが個人差であるとしている。個人差の観点からみると、どのようなデータが同じパターンとして分類されているか、どのような基準で分類されているかを精査する必要がある。

そこで本研究ではクラスタリングを用いて得られた被験者の脳波データを時系列ごとに8分割したものと周波数成分とを組み合わせた64次元のデータに対してクラスタリングを行い、クラスタリング結果をDBIおよびシルエットスコアを用いて分析することでプログラム理解時の個人の脳波をクラスタリングによりどの程度分類できるのかを明らかにする。

4 実験

4.1 実験環境

先行研究[12]の実験において取得された脳波データを用いて分析を行う。先行研究で行われた被験者実験では、プログラムの動作を理解するタスクを被験者に提示し、タスク中の脳波を測定した。実験の対象者は奈良高等専門学校の学生10人で、年齢は19歳から20歳、被験者全員がJavaプログラミングの基礎講義を受講済みであった。

被験者実験は、被験者1名と実験者2名の計3名のみがいる静かな部屋の中で実施された。被験者には、自身の体動によるデータのゆがみや破損を避けるために、ひじ掛けおよび足置きを備えた椅子で頭と体を動かさないように指示が行われた。実験には、脳波計測装置、タスク提示用のPC、脳波計測用のPC、記録用のPC、回答タイミングを伝える為のコントローラーを用いた。脳波計測に用いるハードウェアはナノテックイメージ社製Nexus-10 MARK IIと計測用のノートPC1台である。図3にNexus-10 MARK IIの外観を示す。Nexus-10 MARK IIの計測周期は256Hzで、計測された脳波はBluetooth経由で脳波計測用PCに転送され、1-45Hzの周波数の脳波データがCSVファイル形式で出力される。



図3 Nexus-10MARKIIの外観

4.2 タスク

被験者実験では1人の被験者ごとに16のタスクを与える。被験者には日本語で記述されたプログラムの仕様と、対応するJavaソースコード1組を実験用のツールを用いて提示された。各タスクは2つのステップで構成されており、動作理解ステップとバグ判定ステップから成る。

動作理解ステップでは、被験者に対してプログラムの仕様とソースコード、プログラムの動作に関する質問を提示する。質問に対する回答が分かった被験者はコントローラーのボタンを押した後に口頭で回答する。実験者は回答が事前に用意していた解答と一致する場合にプログラムを理解していると判別する。回答の制限時間は2分30秒で回答は1度のみとし、解答の正誤は被験者に提示しない。

バグ判断ステップでは、被験者に対してプログラムの仕様と動作理解ステップで見せたソースコードの一部を改変したソースコードを提示し、被験者に改変後のソースコードが仕様を満たしているか質問する。動作理解ステップと同様に、質問に対して被験者には口頭で回答してもらい、事前に用意していた解答と一致する場合に正しく判断していると判別する。回答の制限時間は1分で回答は1度のみとし、解答の正誤は被験者に提示しない。

本実験において、分析データの総数としてプログラムを正しく理解している際の脳波データとそうでない場合の脳波データが同数程度になるようにタスクの難易度を調整する。表2にタスクの一覧を示す。本研究では本実験のデータのうち動作理解ステップにおけるデータのみを使用する。

表2 タスクの一覧

タスク番号	難易度	仕様
1	低	階乗の計算
2		最大値検索
3		素数判定
4		中央値検索
5		思考,自己及び環境の認識
6		警戒,動揺
7		記憶,高次精神活動
8		文字列の反転
9	高	ハノイの塔
10		経路数の導出
11		順列の列挙
12		組み合わせを漸化式から導出
13		支払う硬貨の組み合わせの導出
14		文字列の組み合わせの導出
15		2014年情報オリンピック予選問題3
16		最小公倍数と最大公約数の導出

4.3 実験手順

実験は以下に示す手順で行う。

1. 実験概要の説明

実験の概要および脳波計測を行う際の注意点を説明する。

2. 装置の装着・設定

脳波計測装置 NeXus-10MARKII を被験者に装着し設定を行う。

3. 練習問題

1タスクの流れを被験者に把握してもらうために練習問題を実施する。

4. 動作理解タスクの実施

2分30秒間タスクを表示し,被験者はプログラムの動作に関する質問に口頭で回答する.

5. バグ判断タスクの実施

1分間タスクを表示し,被験者は改変後のソースコードが仕様を満たしているか口頭で回答する.

6. すべてのタスクの実施

上記4と5の手順を1タスクにつき1回, 16個のタスクに対して行う.

4.4 分析

本研究では,得られた被験者の脳波データを時系列ごとに8分割したものと周波数成分とを組み合わせた64次元のデータに対してPCA圧縮を行い,次元数を削減したうえでクラスタリングを行う. その結果をシルエットスコアおよびDBIを用いて評価・考察することによりプログラム理解時の個人の脳波をクラスタリングによりどの程度分類できるのかを明らかにする.

4.4.1 データの正規化

分析を行うにあたり,データの正規化を行う. 松山の研究[2]では個人の脳波データの各周波数成分の特徴量について,その変化量に対して個人のパワースペクトルの平均値を用いた正規化を行うことで分析を行っていた. しかし,本研究では個人差を含む脳波データのクラスタリング結果についての分析を行うため,全被験者のパワースペクトルの最大値を1,最小値を0とするような正規化を行う.

4.4.2 PCA圧縮

被験者1人の1つのタスクに対して,周波数成分8種類×時間帯8分割で64次元の特徴量を持つデータが得られる. 松山の研究[2]では,機械学習をする際の周波数成分の重要度は時間軸によって変化していた. このことから本研究で扱う64次元の特徴量についてもそれぞれ異なる重要度を持っていることが考えられる.

そのため,本研究では64次元の特徴量に対してPrimaryComponentAnalysis(PCA)を用いた次元圧縮を行う. 次元圧縮とは,データの可読性の向上や処理の高速化,特徴抽出,ノイズの削減などを目的として多次元データの次元数の削減を図るものである. この次元圧縮の手法の一つとしてPCAが挙げられる. PCAは主成分分析とも呼ばれており,元データにおいて最も大きい分散を持つような方向を第1主

成分の方向とし,この方向に垂直な方向でかつ最も分散が大きい方向に第2主成分の方向をとる手法である [17].

本研究においては,最終的な次元数は最尤推定を用いて決定する.

4.4.3 k-means 法

本研究ではPCA圧縮により次元圧縮を施したデータをk-means法を用いてクラスターリングする. k-means法は非階層的クラスターリング方法の1つであり,データセットの中からランダムに指定した数のクラスターの中心となる点を決定する.その後,決定した点を重心とし,すべての点に対して各重心からの距離を基準にクラスターに分類する.分類されたクラスターに対して重心を再計算し,再度クラスターに分類する.この操作をクラスターの重心が移動しなくなるまで繰り返すことでクラスターリングを行う. k-means法ではデータセット及びクラスター数が一致していればクラスターリング結果も必ず同一のものになるという性質もある [18].

4.4.4 シルエットスコア

シルエットスコアとは,クラスターリング結果を評価する指標の一つであり,クラスターの内的な凝集度と他クラスターとの乖離度およびクラスター内の結束度を考慮して計算される.計算した結果は-1から1までの間の値として算出され,1に近ければ近いほどクラスター内の結束度が高いことを示している.0に近い場合はクラスター同士が重なってしまっている可能性があることを示し,負の値の場合は誤ったクラスターリングが行われている可能性が示唆される [19].

4.4.5 DBI

DBIとは,ダビーズボウルディング指数(Davies-Bouldin Score)のことを指し,クラスター間の分散と他クラスターとの乖離度を考慮して計算される.値は0以上の範囲をとり0に近いほど各クラスター内の分散が小さいことを示している.一方でDBIの値が大きいほどクラスターリング結果が悪いことを示しており,クラスター間の乖離度が小さいほどDBIの値は大きくなり,各クラスター内の分散が大きいほどDBIの値は大きくなる [20].

5 結果と考察

被験者10人に対して1人当たり16タスク分のデータがあり,うち10件のデータに破損が見られた.また,クラスタリングの結果,常に単独で1つのクラスタとなるデータが存在した.そこで,先行研究でも重要度の高い α,β 成分の特に全被験者の全タスクにおける時系列順で8番目の $High-\alpha,Low-\beta$ 成分に着目して箱ひげ図を作成した.作成した箱ひげ図を図4に示す.

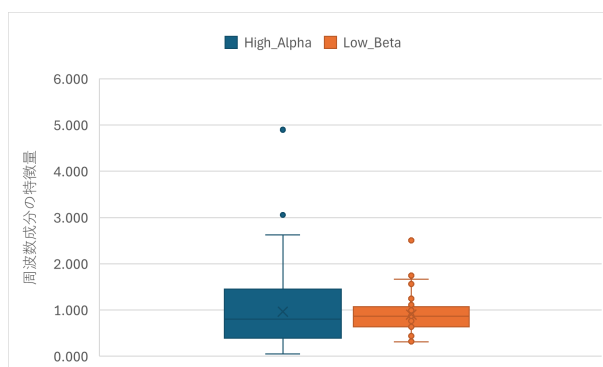


図4 時系列順で8番目の $High-\alpha,Low-\beta$ 成分の箱ひげ図

図4において,前述した常に単独でクラスタリングされているデータの時系列順で8番目の $High-\alpha,Low-\beta$ 成分のデータの値はそれぞれ約61.92と74.90であり,同グラフ上にプロットするとその他のデータの分布がわかりづらくなるため含めなかった. $High-\alpha$ であればせいぜい5.00以下にすべてのデータが存在しており, $Low-\beta$ では3.00以下に存在している.以上のことから常に単独でクラスタリングされているデータが外れ値であると考え,これを除外し149件のデータに対して分析を行った.

5.1 PCA 圧縮による次元圧縮

8つの周波数成分 \times 8つの時系列分割データの64次元の脳波データに対して最尤推定を用いてPCA圧縮を適応した結果,64次元のデータは62次元まで圧縮された.松山の研究[2]では,プログラム理解状態の判別においては α 波および β 波が特に有用であると述べているが,次元圧縮の結果より周波数成分及び時系列について分割した64次元のデータが62次元にまでしか圧縮されていないことより,ほとんどの次元のデータについて重要なデータが含まれていると考えられる.脳波の個人差には個人によって特徴量の出やすい周波数成分の組み合わせが異なる例が報告されている[15].このことからプログラム理解状態を脳波の個人差を含めた分析を行う際にはほとんどすべての周波数成分における特徴量が必要であることが考えられる.

5.2 クラスタリング

5.2.1 シルエットスコアとDBI

PCA圧縮を行った62次元のデータに対して、クラスタ数を2から20まで変化させた時のクラスタリング結果を図5に示す。横軸はクラスタリングした際のクラスタ数、縦軸は左側第1軸にDBI、右側第2軸にシルエットスコアの値を示す。シルエットスコアはクラスタ数が2から4において他のクラスタ数における結果よりも良い一方で、DBIはクラスタ数が2,3の時は悪いが4以降ではよい評価をしている。

橋本の研究[3]では、クラスタリングにおける最適なクラスタ数をエルボー法を用いて策定しており、その数は6であるとしている。また、6以降のクラスタ数においてデータ数が2以上であるクラスタのデータ件数と理解状態のデータの件数からクラスタの状態分けを行っている。本研究では、クラスタ数を変動させることでどのようにクラスタリングされているかの様子を観察し、各被験者の理解状態の脳波データおよび未理解状態の脳波データがどのようにクラスタリングされているか分析する。

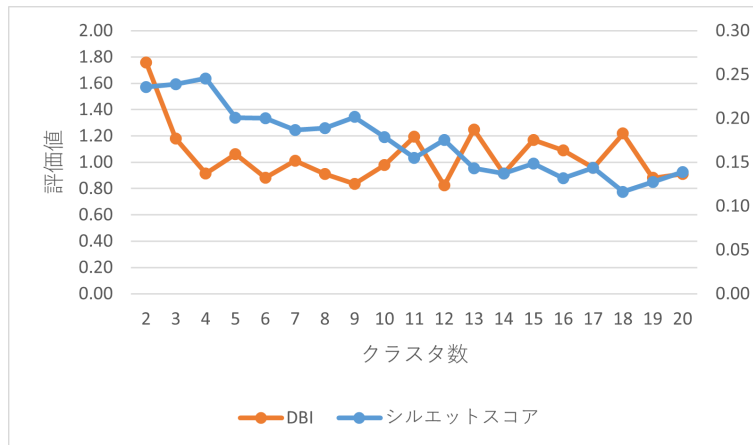


図5 各クラスタ数におけるDBIおよびシルエットスコアの推移

5.2.2 より詳細な分析

得られたクラスタリング結果および各被験者のタスクごとの理解状態をもとに各クラスタ数における各クラスタに含まれているデータの内訳を分析する。以降ではクラスタリング後のあるクラスタに分類されているデータがただ1つであるようなクラスタのことを**単独クラスタ**と表現する。表3に各クラスタ数における被験者と理解状態および対応するクラスタとの関係を示した集計表の一部を示す。

表3は各被験者の理解、未理解状態のデータのクラスタへの分類件数を表にしたものである。それぞれのクラスタに対してクラスタ数2の時には、クラスタIDが0,1のSbj.AからDまでの全員のデータが含まれていることが確認できた。一方でクラスタ数が3に増えると、IDが2のクラスタにSbj.Bのデータだけが1件だけ分類された。以上のことからクラスタ数3におけるIDが2のクラスタは単独クラスタであり、クラスタ数を増やすとこのように単独クラスタが出現することが確認できた。

以上を踏まえてRQ1(クラスタ数を増やしていくことで新たに分割されるクラスタの特徴は何か)へ回答する。

表3 各クラスタ数における被験者と理解状態

クラスタ数	クラスタID	Sbj.A		Sbj.B		Sbj.C		Sbj.D	
		理解	未理解	理解	未理解	理解	未理解	理解	未理解
2	0	7	0	5	2	8	0	5	3
	1	3	4	4	3	2	5	0	7

3	0	7	0	4	1	8	0	5	2
	1	3	4	5	3	2	5	0	8
	2	0	0	0	1	0	0	0	0

4	0	7	0	4	1	8	0	5	3
	1	3	4	5	3	2	5	0	7
	2	0	0	0	1	0	0	0	0
	3	0	0	0	0	0	0	0	0

5	0	0	0	0	0	0	0	0	0
	1	3	4	2	2	2	5	0	8
	2	7	0	1	0	8	0	5	2
	3	0	0	0	1	0	0	0	0
	4	0	0	6	2	0	0	0	0

6	0	0	0	6	2	0	0	0	0
	1	7	0	1	0	8	0	3	2
	2	3	4	2	2	2	5	2	8
	3	0	0	0	0	0	0	0	0
	4	0	0	0	1	0	0	0	0
	5	0	0	0	0	0	0	0	0

RQ1への回答

クラスタ数を増やすことによって個人の脳波データのクラスタへの分類として以下のようなものが考えられる。

- 被験者によるクラスタへの分類
- タスク内容によるクラスタへの分類
- 理解,未理解の状態によるクラスタへの分類
- 上記の内容の各組み合わせによる分類

表3ではクラスタ数が2から3へと増加させた際に単独クラスタが発生した。以上のようなことから,RQ1への回答として「クラスタ数を増加させることで単独クラスタが出現した」という回答が得られた。

表3において,特にクラスタ数が2と3との間ではクラスタ数が2の時の集計表か

らは単独クラスタは見受けられなかったが,クラスタ数が3の時の集計表では単独クラスタが存在している.表4に各クラスタ数におけるDBI及びシルエットスコアの推移を示す.

表4 各クラスタ数におけるDBI及びシルエットスコアの推移

	クラスタ数	2	3	4	5	6	7	8	9
評価値	シルエットスコア	0.24	0.24	0.25	0.20	0.20	0.19	0.19	0.20
	DBI	1.76	1.18	0.91	1.06	0.88	1.01	0.91	0.84
変化量[%]	シルエットスコア	1.47	2.74	-18.33	-0.16	-6.87	1.25	6.73	-11.36
	DBI	-32.84	-22.65	16.32	-16.90	14.45	-8.5	-8.25	17.17

クラスタ数が2と3の間では,シルエットスコアにおいて,約0.0035ほど値が上昇しこれはクラスタ数が2の時と比較すると約1.47%の上昇が発生した. DBIについては約1.75から1.18までに変動し,これは約32.84%ほど評価値は小さくなった.これらのことからシルエットスコアの変動はDBIと比較すると変動が小さかったことがわかった.また,このような異なる連続したクラスタ数間の集計表において単独クラスタの数が増えているような点は合計11あった.

以下表5に各被験者のデータを各クラスタ数におけるクラスタリングを行った際の分類後のクラスタのラベルをまとめた表のSbj.Xについての結果を示す.

表5 各被験者と実行タスクおよびクラスタのラベルについての表

ID	タスク名	理解状態	クラスタ数								
			2	3	4	5	6	7	8	9	
15	4	Yes	0	0	0	4	0	1	6	5	
16	5	Yes	0	0	0	4	0	1	6	5	
17	3	No	0	0	0	4	0	1	6	5	
18	6	Yes	0	0	0	2	1	6	3	8	
19	2	No	1	1	1	4	0	1	6	5	
20	7	Yes	0	1	1	4	0	1	6	5	
21	1	Yes	0	0	0	4	0	1	6	5	
22	8	Yes	1	1	1	4	0	1	6	5	
23	9	No	1	1	1	1	2	0	0	1	
24	15	No	0	2	2	3	4	2	4	3	
25	10	No	1	1	1	1	2	0	0	1	
26	14	Yes	1	1	1	1	2	0	0	1	
27	13	Yes	1	1	1	1	2	0	0	1	
28	12	Yes	1	1	1	4	0	1	1	0	

表3において,横にはクラスタ数を,縦には対応する脳波データのタスク番号を示した.例として,クラスタ数が2の時のタスク4のデータはラベル0のクラスタにクラスタリングされていることを示している.クラスタ数が2の時はクラスタラベル0で分類されていたタスク15のデータについて,クラスタ数が3になると1件

だけラベル2として分類されていたことがわかる。このデータに対して、ほかの被験者においてもラベル2として分類されているデータはなく、このデータは単独クラスタとして分類されていた。このとき、表4においてもクラスタ数が2から3にかけてDBIの評価値は上昇している。

このようなクラスタ数の変化により単独クラスタが新たに生まれているような点すべてにおいてDBIの値は評価が高くなるような変動が起こっていた。以上のことから、単独クラスタとして分類されているデータには個人差が含まれており、個人差を含むデータを単独で異なるクラスタとして分類することによりDBIによる評価値が上昇したのではないかと考えられる。一方で、シルエットスコアについては単独クラスタによるスコアの変動との関連性がみられなかったことから、シルエットスコアの変動については別の要因があると考えられる。以上の内容からRQ2で提示した、観点の異なる評価指標を計測し違いがみられるかどうかについての回答は以下のとおりである。

RQ2への回答

単独クラスタの数の変動が起こっている点は11点あり、これらのすべての点においてDBIの評価値はよい結果を示すような変動が発生した。一方でシルエットスコアについては単独クラスタの数の変動とは関係が見受けられなかった。また、表4からもシルエットスコアにおいてはクラスタ数が2から4の間で最良であったが、DBIではクラスタ数が4以降で良い評価をしている。以上のことからRQ2に対しての回答は「はい」である。

単独クラスタにクラスタリングされていたデータの特徴として以下のような特徴が見受けられた。

- 単独クラスタにクラスタリングされているデータの被験者が限定されていた。
- 複数のクラスタ数において全く同じ被験者、理解状態のデータが単独クラスタとして分類されていた。
- 大半の単独クラスタにおいて、クラスタ数が増加しても単独クラスタとして分類されていた。

また、表5を例に挙げると、タスク15のデータはクラスタ数が2の時に単独クラスタとして分類されており、その後もクラスタ数を増やしても変わらず単独クラスタとして分類されていた。他の単独クラスタにおいても、このような特徴がみられた。このような結果からクラスタリングを用いることにより発生した単独クラスタのデータの内容を追跡することにより、個人差を含むようなデータの特定が可能になったと考えられる。

6 おわりに

本研究では,クラスタリングを用いることで個人差をどの程度分類することができるかを明らかにすることを目的とした. 分析には先行研究[4]の脳波データを用いた. 脳波データを周波数成分(δ 波, θ 波, High- α 波, Low- α 波, High- β 波, Low- β 波, Low- γ , Mid- γ 波)ごとに8分割,時系列分割数8の64次元のデータに対してPCA圧縮を行い圧縮後の150のデータに対してk-means法を用いたクラスタリングを行った. クラスタ数は2から20まで可変とし,各クラスタ数におけるクラスタリング結果に対してDBIおよびシルエットスコアを計算し評価を行ったが,クラスタリング結果として特定のデータのみがほぼすべてのクラスタ数において単独でクラスタリングされていたことからこのデータを外れ値として分析対象から除外した. 除外した後の149のデータに対する分析結果としてDBIとシルエットスコアとの間にトレードオフの傾向が見られた.

各クラスタ数におけるクラスタリング結果をもとに被験者の各データがどのクラスタに分類されているかを合わせた分析した結果,クラスタに対してデータが一つしか分類されていないようなクラスタ(以降単独クラスタと呼ぶ)が複数見られた. これらの異なる連続したクラスタ数における単独クラスタの数が増えるとDBIの値は良い結果を示す方向に変動したが,シルエットスコアとはあまり関係が見られなかった. そのため,これらの単独クラスタとして分類されていたデータには個人差を含んでおり,個人差を含むデータを単独クラスタとしてはじき出すことによりDBIの値は上昇したのではないかと考えられる.

また,単独クラスタに見られた特徴として,分類されているデータの被験者が限定されていたこと,複数のクラスタ数における単独クラスタにおいて,全く同じ被験者,同じ理解状態のデータが分類されていたこと,大半の単独クラスタにおいて,クラスタ数が増加しても変わらず単独クラスタとして分類されていたことが挙げられる. 単独でクラスタリングされているデータの内訳を追跡すると,すべての単独クラスタにおいて,特定の被験者における特定のタスク実行時の脳波データのみが単独クラスタとして分類されていた. したがって,クラスタリングを用いることで,単独クラスタとして分類されたデータを精査することで個人差を含むデータの特定が可能になると考えられる.

本研究の分析結果より,クラスタリングにより個人差をどの程度分類できるかは明らかにできなかったが,クラスタリングを用いることで,個人差を含むデータの特定が可能であることが明らかになった. しかし,本研究の課題点として,個人差を含むデータの特定ができてデータの中の成分に個人差が表れているかを明らかにできていない点が挙げられる. よって今後の展望としては,シルエットスコアの変動の要因の精査および分析と,個人差を含むデータに対して周波数成分に着目した分析などが挙げられる. これらの結果をもとに機械学習を行うことで個

人差を考慮した脳波データの分析が可能になるのではないかと考えられる.

謝辞

本論文の執筆および研究を進めるにあたり,多くの方々にお力添えをいただきました.指導教員である上野准教授には,お忙しい中研究に対する助言や論文の添削など,多くの助力をいただきました.また,お忙しい中論文の査読対応に快く対応してくださった岩田教授にも御礼申し上げます.上野研究室研究生の橋本さんには研究データの引継ぎやデータの見方に対しての助言など多くの助力をいただきました.この場をお借りして感謝を申し上げます.本当にありがとうございました.

参考文献

- [1] J. Siegmund, C. Kanster, S. Apel, C. Parnin, A. Bethmann, T. Leich, G. Saake, A. Brechmann: "Understanding Understanding Source Code with Functional Magnetic Resonance Imaging", Proceedings of the International Conference on Software Engineering (ICSE), pp.378-389 (2014).
- [2] 松山 鼓, 上野 秀剛, "脳波の周波数成分の時系列変化を用いたプログラム理解の識別", FIT2023 論文集 (2023).
- [3] 橋本 悠希, "脳波の個人差に着目したプログラム理解の判別", 奈良工業高等専門学校情報工学科令和5年度卒業研究論文 (2024).
- [4] Toyomi Ishida, Hidetake Uwano, and Yoshiharu Ikutani, "Combining Biometric Data with Focused Document Types Classifies a Success of Program Comprehension," In the 28th IEEE/ACM International Conference on Program Comprehension (ICPC 2020).
- [5] Martin K.-C. Yeh, Dan Gopstein, Yu Yan, Yanyan Zhuang, "Detecting and comparing brain activity in short program comprehension using EEG", 2017 IEEE Frontiers in Education Conference (FIE), pp.18-21 (2017).
- [6] W. Klimesch, "EEG- α rhythms and memory processes", International Journal of Psychophysiology, vol.26, pp.319-340 (1997).
- [7] Toyomi Ishida, Hidetake Uwano, "Time Series Analysis of Programmer's EEG for Debug State Classification," In the 5th Edition of the Programming Experience Workshop (PX 2019).
- [8] 山本 愛子, 上野 秀剛, "プログラムの実装戦略推定時における脳波の時系列分析", IPSJ SIG Technical Report Vol.2016-SE-193 No.6(2016).
- [9] 村上 侑也, "イラストレクチャー 認知神経科学", 株式会社オーム社 (2013).
- [10] "脳波の概要と知識" -生体計測屋より見た脳波の活用入門-, 織 消誌, Vol.43, No.9, pp.16-23 (2002).
- [11] 青山 敦, 上田 一貴, 川崎 真弘, 渡部 宏樹, 辰岡 鉄郎, "脳波計測・解析の実用ハンドブック～計測の留意点、解析データの取り扱い、最新応用事例～", 株式会社 R & D 支援センター (2024).
- [12] Toyomi Ishida, Hidetake Uwano, and Yoshiharu Ikutani, "Combining Biometric Data with Focused Document Types Classifies a Success of Program Comprehension", In the 28th IEEE/ACM International Conference on Program Comprehension (2020).
- [13] 堀 忠雄, "生理心理学-人間の行動を生理指標で測る", 培風館 (2008).

- [14] 柴田海翔, ”複数の周波数成分に着目したプログラム理解の把握”, 奈良工業高等専門学校情報工学科令和3年度卒業研究論文(2022).
- [15] 伊藤伸一, 満倉靖恵, 福見稔, 赤松則男, ”脳波の個人特性を考慮した脳波分析法の提案”, 電気学会論文誌-電子情報通信学会論文誌, Vol.124, No.6, pp.1259-1266(2004).
- [16] 中川尊雄, 亀井靖高, 上野秀剛, 門田暁人, 松本健一, ”脳血流計測に基づくプログラム理解行動の定量化”, ソフトウェア工学の基礎ソフトウェア工学の基礎ワークショップ FOSE2013), pp.191-196(2013).
- [17] 赤穂昭太郎, ”カーネル主成分分析”, 岩波書店(2008).
- [18] 佐藤義治, ”多変量データの分類: 判別分析・クラスター分析”, 朝倉書店(2009).
- [19] Ketan Rajshekhar Shahapure, Charles Nicholas, ”Cluster Quality Analysis Using Silhouette Score”, 2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA), pp.747-748(2020).
- [20] Tie Li, Gang Kou, Yi Peng, Philip S. Yu, ”An Integrated Cluster Detection Optimization and Interpretation Approach for Financial Data”, IEEE TRANSACTION ON CYBERNETICS VOL.52 NO.12(2022).