



卒業研究報告書

令和5年度

研究題目

脳波の個人差に着目したプログラム理解の判別

指導教員 上野秀剛 准教授

氏名 橋本悠希

令和6年3月8日 提出

奈良工業高等専門学校 情報工学科

脳波の個人差に着目したプログラム理解の判別

上野研究室 橋本悠希

ソフトウェア開発組織や学校などのプログラミング作業の現場では、作業者の理解支援が求められる。そのためには、作業者の理解状態を正しく把握し、作業者の理解状態にあった支援をする必要がある。作業者の理解状況を把握する方法として、脳波に着目した手法が挙げられる。プログラム理解に関する研究において、脳波はその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とが多い。この周波数成分は、脳活動によって強く表れる成分に特徴があり、プログラム理解においては α 波と β 波に理解時の特徴が強く表れるとされている。周波数成分の分類は、 δ 波、 θ 波、High α 波、Low α 波、High β 波、Low β 波、Low γ 波、Middiam γ 波の8種類に細分化でき、細かな分類をする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。さらに、プログラム理解時の脳波はその時系列によって重要度に差があるため、時系列分析が有効とされており、時系列分割した脳波データを「理解時のデータ」、「未理解時のデータ」の2つをラベルとして、教師あり学習をさせてプログラム理解を予測する研究も存在する。しかし、脳波には個人差が含まれるため、プログラム理解時、未理解時の脳波データの特徴がそれぞれ1つに限られるとは考えられない。そこで本研究では、プログラム理解を行う作業者の脳波に対して8種類の周波数成分で時系列分析を行い、教師なし学習であるクラスタリングを用いて脳波データを分類することで、プログラム理解時、未理解時の脳波の特徴がどのように出現するかを明らかにする。クラスタリングを用いて脳波データを周波数成分の特徴ごとに複数のクラスタに分類することで、プログラム理解時、未理解時の脳波の特徴が複数パターンある場合でもそれぞれの特徴を拾うことができる。分析では、プログラム理解時の脳波データを8種類の周波数成分を時系列分析をするため等しい間隔で分割する。分割数は先行研究で有用とされた8分割とする。時系列データにFFTを用いて各分割ごとの周波数成分のパワースペクトルを求め、求めた周波数成分のデータに対してPCAによる次元圧縮を行い、クラスタリングに使用するデータとし、クラスタリングを行う際は、クラスタ数をエルボー法を用いて決定する。実験の結果、元データに対してPCAを行うと、次元数が64から62まで削減された。削減された次元数が少ないため、元データのほぼすべての情報が分析に重要であることが確認できた。PCAより求めた主成分データに対し、エルボー法を用いた最適クラスタ数6でクラスタリングを行うと、データ数が1つのみのクラスタ4つと、正答データの割合が0.53と0.75のクラスタに分けられたため、理解、未理解データを分類できたとは言えずクラスタ数6は適切でないといえる。これを受け、クラスタ数6~20におけるクラスタリングの精度を分析すると、クラスタ数12の時に一番高い精度となり、正答データを8割持つ理解クラスタが2つ存在し、それぞれHigh α 波と θ 波が顕著に表れていた。以上の結果は、プログラム理解時の脳波の特徴が少なくとも2つ存在することを示し、プログラム理解時の脳波の特徴における個人差であるといえる。

目次

1	はじめに	2
2	脳波	4
2.1	測定方法	4
2.2	周波数帯域	4
2.3	脳波の個人差	5
3	実験	7
3.1	実験環境	7
3.2	タスク	7
3.3	実験の手順	8
3.4	分析	9
3.4.1	特徴量	9
3.4.2	次元圧縮	10
3.4.3	クラスタリング	10
4	結果と考察	12
4.1	PCAによる次元圧縮	12
4.2	クラスタリング	13
4.2.1	エルボー法で決定したクラスタ数	13
4.2.2	任意のクラスタ数ごとのクラスタの評価	14
5	おわりに	16
	謝辞	18
	参考文献	19

1 はじめに

ソフトウェア開発組織や学校などプログラミング作業の現場では、作業員へ適切な支援や指導をするために作業員のプログラム理解状態を正しく把握する必要がある。作業員のプログラム理解状態を正しく把握できていないと、作業員の理解度を誤って認識してしまい必要な支援が行き届かずに、作業員の理解度が停滞してしまう恐れがある。しかし、プログラミング作業の大部分は思考作業であるため、作業員の外観から理解状態を把握することが困難である。また、プログラム理解状態を把握する手法として口頭での質問やアンケートが挙げられるが、それらを実施する際には作業員が作業を1度中断し、質問やアンケート内容を把握してから回答する必要があるため、作業員の負担となってしまう問題点がある。

そこで、プログラム理解状態を把握する手法として脳波が挙げられる。脳波は人の脳活動を測定する手段の1つで、一般的に δ 波、 θ 波、 α 波、 β 波、 γ 波の5種類の周波数成分から構成されており、個人差はあるものの対象者の思考状態によって各周波数成分の強さが変化する。測定の際は、脳波計測装置を装着するのみで作業員は作業を中断することなくデータの測定ができるため、作業員への負担は、口頭での質問やアンケートと比べはるかに小さい。また、脳波は時系列データであるため、一連のプログラム作業の理解状態把握の分析に適しており、時系列ごとの重要度を考慮した分析が可能である。

プログラム理解時の脳波を分析した先行研究[1]では、分析データとして、先述した5種類の周波数成分に加え、 α 波、 β 波、 γ 波をそれぞれ周波数帯域で2分割した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、Low γ 波、Mid γ 波）を用いている。また、時系列ごとのデータの重要度を考慮するために脳波データを等間隔で1~10分割し、各分割数で周波数成分の時系列分析を行っている。この研究ではプログラム理解タスク時の脳波を、プログラム理解状態である「理解した」または「理解していない」の教師データに分類し機械学習することで、最高86.5%の精度でプログラム理解状態を判別している。しかし、脳波には個人差があるため、プログラムの理解状態が同じでも周波数成分の特徴は複数の傾向を持つと考えられる。従って、脳波の周波数成分は個人差に考慮して分析する必要がある。一方で、プログラム理解における脳波の個人差についてはこれまで分析されておらず、個人差がどのように表れるかといった個人差の特徴も明らかになっていないため、理解状態の判別時にどのように考慮すべきか明らかになっていない。これまでの研究における脳波の傾向から、理解した状態、理解していない状態それぞれに複数のパターンが存在することが示唆されており、個々の脳波がどのパターンに分類されるか明らかになれば予測精度の向上に繋がると考えられる。

本研究はプログラム理解タスクにおける脳波の周波数成分に対しクラスタリングを行うことで、プログラム理解状態の周波数成分の特徴を分析する。クラスタリングでは、プログラム理解状態による周波数成分の特徴を複数のクラスターに分類することで、脳波の個人差による特徴の傾向を含めた分析が可能になる。分析によって得た周波数成分の特徴は、プログラム理解状態の予測に有用な知見となる。

以下、2章では分析データである脳波について関連研究を含めて説明し、3章で実験設定、実験手順、分析方法について説明し、4章では実験の結果と考察を説明する。5章では本研究のまとめと今後の発展について説明する。

2 脳波

2.1 測定方法

脳波とは，脳から生じる電気活動の電位を縦軸，時間を横軸にとって記録したものである [2]. 脳波は，頭皮上に装着した複数の電極から計測される．電極の配置は図1に示す国際式10-20電極法に則って行う [3]. 国際式10-20電極法では，鼻，耳，外後頭隆起を結ぶ円周を中心に向かって10%,20%に区切り，その経線上に電極を張り付ける [3].

脳波の導出法には主に基準電極導出法と双極導出法の2種類がある．

基準電極導出法は，一对の入力端子に対して，一方に探査電極を，もう一方に基準電極をつない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，基準電極を持たず，どちらも探査電極とする方法である．計測用電極の電極間隔が狭い場合に電極差を計測する際は基準電極導出法を，優勢な背景成分を除去して部位差を強調する目的で計測する際には双極導出法を選択する [4].




図1 国際式10-20電極法

2.2 周波数帯域

脳波は異なる周波数の波形を合成したものから成り，その周波数帯域ごとに成分として分類されており，それぞれ異なる特徴を持つ．周波数成分を抽出する方法としてFFT(Fast Fourier Transform)やSTFT(Short Time Fourier Transform)があり，これ

表1 脳波の分類

周波数成分	周波数帯域	心理状態
δ波	0.5~2.75[Hz]	ノンレム睡眠, 無意識
θ波	3.5~6.75[Hz]	直観的, 創造的, 想起, 空想, 夢
Low α波	7.5~9.25[Hz]	リラックス, 平穏, 意識的
High α波	10~11.75[Hz]	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[Hz]	思考, 自己および環境の認識
High β波	18~29.75[Hz]	警戒, 動揺
Low γ波	31~39.75[Hz]	記憶, 高次精神活動
Mid γ波	41~49.75[Hz]	視覚情報処理

らを用いて周波数帯域ごとのパワー(パワースペクトル)を求める方法が存在する。

脳波の周波数成分の代表的な分類を表1に示す。δ波やθ波は睡眠状態の時に出現する。α波は安静閉眼状態の時で振幅、連続性ともに最も高いが、リラックス状態といった安静状態の時も出現する。また、α波は覚醒が低下すると振幅が低下し、不連続になる。β波は緊張興奮状態や不快な感情といったストレスが強い時に出現する。γ波は不安状態や興奮状態の時に出現しやすい[4]。このように各周波数帯域は心理状態によって変化する。

本研究が対象とするプログラム理解においては、過去の研究ではα波、β波はプログラム理解状態の判別に特に有用であること明らかになっている[1, 5]。また、周波数成分を細かく分類した際には、理解状態によってLow β波, High β波, Low γ波, Mid γ波に差があることが示されている[6]。

2.3 脳波の個人差

脳波は出現する特徴波に個人差がある[7]。そのため、脳波からある事象や性質についての分析を行う際は個人差を原因とする影響を考慮して、分析対象の事象・性質による影響と区別する必要がある。先行研究においても、プログラム理解タスクの脳波には個人差が表れると考察されている。山本の研究[8]では、プログラム理解タスク時のα波、β波は同じ理解状態であったとしても、周りのデータと比較した際に、極端な外れ値が含まれていることがあることを示しており、これをプログラム理解時のα波とβ波の個人差であると考察している。また、脳波の周波数成分のうちα波、β波はともに個人差が大きいものの、その増加量は個人内で安定しているということも示している。

これを受けて、松山の研究[1]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、その被験者のパワースペクトルの平均値によって割ることで、個人内の脳波の増加量に対して正規化を行うことで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。しかし、この正規化方法では、たとえ同じ理解状態の時でも、被験者によって出現する周波数成分が異なるといったようなプログラム理解状態によって発生する周波数成分パターンによる個人差を軽減することはできず、個人差を考慮した分析であるとは言えない。そこで本研究では、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と考え、それぞれ異なるグループとすることで、プログラム理解状態によって発生する周波数成分による個人差を考慮して分析する。そのグループ分けの手法として、節 3.2.3 で後述するクラスタリングを用いる。

3 実験

本研究では、先行研究[5]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。実験では、プログラム課題に関するタスクを被験者に提示し、その間の脳波を測定する。被験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、全員がJavaプログラミングの基礎講義を受講済みである。

3.1 実験環境

実験は被験者1名と実験者2名のみが居る静かな部屋で実施する。体動によるアーチファクトを抑えるために、ひじ掛け・足置きを備えた椅子で、できるだけ頭部と体を動かさないように指示する。

実験に使用する器具は、脳波計測装置、タスク提示用PC、脳波計測用PC、記録用PCである。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。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2に装置の外観を示す。



図2 脳波計測用装置

3.2 タスク

タスクは、被験者1人につき16問与えられる。実験用のタスク提示ツールを用いて、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

提示する。各タスクは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、被験者にプログラムの仕様、ソースコード、そのプログラムに関する質問をを提示し、質問がわかったタイミングで被験者は口頭で回答する。解答の内容が事前に用意したものと一致すれば動作を理解している、一致しなければ理解していないとみなす。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、被験者に動作理解ステップで見たソースコードの一部を改変したソースコードを提示する。被験者は、そのソースコードが仕様を満たしているかどうかを解答する。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。

本実験では、分析データとしてプログラム理解成功時の脳波と失敗時の脳波が同程度の件数計測できるように、タスクの難易度を調整する。タスクの難易度は低難易度、高難易度共に8つ用意する。表2にタスクの一覧を示す。

なお本研究では、先行研究[5]の2つのステップのうち、動作理解ステップの測定データのみ使用する。

表2 タスク一覧

	難易度	仕様
1	低	階乗の計算
2		最大値検索
3		表数判定
4		中央値検索
5		思考,自己および環境の認識
6		警戒,動揺
7		記憶,高次精神活動
8		文字列を反転させる
9	高	ハノイの塔
10		経路数を求める
11		順列を列挙する
12		組み合わせを漸化式から求める
13		支払う硬貨の組み合わせを求める
14		文字列の組み合わせを求める
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を求める

3.3 実験の手順

実験の順序を以下に示す。

1. 実験の説明

実験概要、脳波・視線計測時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，視線計測装置 Eye Tracker 4C を PC に装着し，設定する．

3. 練習問題

1タスクの流れを被験者に確認してもらうために，練習タスクを実施する．

4. 動作理解タスクの実施ディスプレイにタスクを2分30秒間提示し，プログラムの動作を理解する．

5. バグ判断タスクの実施ディスプレイに改編後のタスクを1分間提示し，仕様を満たすか判断してもらう．

6. 解答被験者は，問題に対し仕様を満たすかどうかを判断できたときにコントローラーのボタンを押して答えを口述する．

7. 全タスクの実施1タスク当たり手順4~6を1回行う．これを全タスク分(16回)繰り返す．

3.4 分析

本研究では，プログラムを理解した時，しなかった時それぞれの場合における脳波の周波数成分の特徴を明らかにするためにクラスタリングを用いて分析する．先行研究 [1, 5, 6] の結果に基づいて複数の周波数成分の時系列変化を時間帯で分割して算出されるパワースペクトルを特徴量として用いる．すべての周波数成分，すべての時間帯がクラスタリングに有用とは限らないため，次元圧縮を行い，より有用な特徴量からクラス分割を行う．

3.4.1 特徴量

先行研究 [6] では脳波の周波数成分をより細かく分割した Low β 波, High β 波, Low γ 波, Mid γ 波などに理解の有無による差が見られている．本研究では脳波を表1で示した8種類 (δ 波, Θ 波, Low α 波, High α 波, Low β 波, High β 波, Low γ 波, Mid γ 波) の周波数成分に分割し，それぞれのパワースペクトルの時系列変化を特徴量とする．時系列分析では被験者の各タスクの脳波データをN個の均等な時間長に分割するが，分割数Nは先行研究 [1] においてプログラム理解状態の予測精度が一番高かった8つとする．

8分割したそれぞれの脳波データに対し，FFTを用いて表1の周波数成分ごとのパワースペクトルを求める．各パワースペクトルはそのタスクにおけるすべての周波数成分の合計値によって割ることで正規化を行う．

3.4.2 次元圧縮

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次元の特徴量が得られる。先行研究[1]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。そのため、本研究における64次元の特徴量についてもそれぞれ重要度が異なると考えられる。また、脳波の周波数成分同士には相関関係があることが知られている[9]。

そこで、本研究では64次元の特徴量に対してPrimary Component Analysis(PCA)を用いた次元圧縮を行う。次元圧縮とは、多次元データにおいて次元数を削減することである。次元圧縮は、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行われる。

PCAは主成分分析とも呼ばれる、次元圧縮の方法の1つである。PCAでは、元データの分散が最も大きい方向に新たな変数を取り、その向きをこれを第1主成分の方向とする。第1主成分の方向に直交する条件下で、最も分散が大きい方向に第2主成分を取る。これを繰り返していくことで、指定した次元数まで元データが圧縮される。

本研究では圧縮後の次元数は最尤推定を用いて決定する。圧縮後の各次元を構成する元々の特徴量の寄与率を分析することで、プログラム理解の有無の分類に有用な特徴量を明らかにできる。

3.4.3 クラスタリング

PCAで次元圧縮した特徴量を用いてクラスタリングを行う。クラスタリングとはデータをそれぞれの類似度からいくつかのグループ(クラスタ)に分割する統計的手法である。本研究ではクラスタリングの手法にはk-means法を用いる。k-means法は非階層的クラスタリング方法の1つで、データセットを事前に指定したk個のクラスタ数に分割する手法である。k-means法ではデータセットからランダムに指定したクラスタ数のデータポイントを選び、各クラスタの中心し、各データポイントを最も近いクラスタ中心に割り当てる。割り当てたないようからクラスタとクラスタの中心を更新し、これをクラスタの中心が変化しなくなるまで繰り返すことで、クラスタに分類する。

最適なクラスタの個数はエルボー法を用いて決定する。エルボー法はSSE(クラスタ内誤差平方和)をクラスタ内のばらつきを示す尺度として、クラスタ数の評価を行う。各クラスタのデータポイントを X_{ij} 、対応するクラスタの重心を C_i 、クラスタ数を K 、 n_i を各クラスタのデータポイントの数とした時、SSEは式3.4.1のように表せる。

$$SSE = \sum_{i=1}^k \sum_{j=1}^{n_i} \|X_{ij} - C_i\|^2 \quad (3.4.1)$$

SSEが小さいほど、データポイントがクラスター中心に集中していることを示し、クラスター内のばらつきが小さいことを意味する。クラスター内のばらつきが小さいほど同じクラスター内のデータの類似度が高いと言える。エルボー法では、異なるクラスター数におけるSSEをプロットし、クラスター数が増加するにつれてSSEがどの程度減少しているかを考える。クラスター数が増加するとSSEは減少するが一定のポイントで減少が緩やかになり、肘（エルボー）のように見えるポイントが現れる。この位置を適切なクラスター数とする。

4 結果と考察

4.1 PCAによる次元圧縮

周波数成分8種類×時系列分割数8の64次元のデータにPCAを用いて主成分分析を行なった結果、62次元の主成分データに圧縮された。この時の62次元の主成分データに対する元データの寄与率は0.99999...であり、1に非常に近いため、主成分データは元データの特徴をほぼ失っていない。また、被験者1~10のデータのうち、被験者1~5と6~10のグループに分けて主成分分析をすると、元データに対する寄与率は被験者1~5のグループにおいて0.99であるのに対し、被験者6~10のグループでは0.85であった。分割するグループによって寄与率に違いが現れることから、時系列分割数8における周波数成分には個人差があると考えられる。よって元データの圧縮がほぼされていない原因の1つとして個人差が挙げられる。

次に、表3に主成分データにおける各時系列分割数ごとの周波数成分の寄与率を示す。周波数成分の寄与率は、その9割以上が1.0%~1.9%の間に存在しておりそれぞれの差は大きくないと言える。また、各時系列分割における寄与率の合計に大きな差がみられないことから8等分の各分割の類似度が小さいことが分かる。よって時系列分析において、測定データを8分割することは改善の余地があり、元データの圧縮がほぼされていない原因の1つであると考えられる。ただし、時系列分割の8分割目は比較的周波数成分の寄与率が低く、特にHigh α 、Low β 、High β 、Low γ 、Mid γ は他の周波数成分と比べて寄与率が低い。このことから、次元圧縮の際に圧縮されたのは主に8分割目の周波数成分の情報であり、情報の重要度が比較的小さいと考えられる。

表3 周波数成分の寄与率 [%]

	δ	Θ	Low α	High α	Low β	Hogh β	Low γ	Mid γ	合計
div1	1.4	1.8	1.7	1.7	1.4	1.3	1.4	1.6	12.3
div2	1.4	1.9	1.8	1.6	1.5	1.5	1.5	1.6	12.9
div3	1.6	1.7	1.8	1.6	1.7	1.6	1.7	1.8	13.6
div4	1.7	1.8	1.7	1.5	1.5	1.6	1.7	1.5	13.0
div5	1.5	1.8	1.7	1.7	1.8	1.6	1.7	1.7	13.5
div6	1.6	1.8	1.6	1.6	1.5	1.3	1.6	1.5	12.6
div7	1.4	1.7	1.8	1.6	1.8	1.6	1.7	1.7	13.3
div8	1.3	1.6	1.5	1.0	1.1	0.8	0.8	0.8	8.8
合計	12.1	14.1	13.5	12.3	12.5	11.3	12.1	12.2	100.0




図3 クラスタ数増加によるSSEの変化

4.2 クラスタリング

PCAによって次元圧縮したデータを元にクラスタリングを行い、クラスタ数や分割されたデータを分析する。

4.2.1 エルボー法で決定したクラスタ数

図3にクラスタ数を変化させたときのSSEの値を示す。クラスタ数6を境にSSEの減少量がそれ以前よりもなだらかになっている。よって、エルボー法を用いると最適なクラスタ数は6であると言える。

表4にクラスタ数6でクラスタリングしたときの、クラスタごとのデータ数と理解したタスク数（正答数）、正答率を示す。各クラスタのデータ数に着目するとデータを1件しか含まないクラスタが4個（クラスタ0,2,4,5）あり、いずれも外れ値のデータを持つクラスタであると考えられる。他の2つのクラスタ（クラスタ1,3）は複数のデータを含んでおり、クラスタ3はデータ数の内訳が正答数が多いほうに偏っている一方で、クラスタ1はその割合が約半分となっており、プログラムを理解したデータとできなかったデータを分類できているとは言えない。よって、クラスタ数6は脳波の周波数成分のクラスタリングにおいて適切な数ではないと考えられる。

表4 クラスタの内訳(クラスタ数6)

Cluster	データ数	正答数	正答率
0	1	1	1
1	94	50	0.53
2	1	0	0
3	52	39	0.75
4	1	1	1
5	1	0	0

4.2.2 任意のクラスタ数ごとのクラスタの評価

クラスタ数をエルボー法で決定した6よりも増加させたときのクラスタの内容をそのデータの内訳から評価した。クラスタ内データの正答率が8割以上のクラスタを理解クラスタ, 2割以下のクラスタを未理解クラスタとする。理解クラスタのうち正答しているデータと, 未理解クラスタのうち正答していないデータをクラスタリング成功として, データ全体におけるクラスタリング成功の割合をクラスタの精度として分析する。なお, データ数が1であるクラスタは, データの状態がクラスタの状態に直結しており, 必ずクラスタリング成功データとなるため分析から除外した。

クラスタ数を6~20に設定した際の精度の変化を図4に, データ数が1のクラスタを除いたクラスタ数の変化を図5に示す。図4の精度はデータ数が2以上のクラスタにおけるクラスタリング成功データの割合(クラスタ内のデータに対する, 理解クラスタのうち正答しているデータと未理解クラスタのうち正答していないデータを合わせた割合)。図4より, クラスタ数10までは出現していなかったクラスタリング成功データが, クラスタ数11から出現していることが分かる。これは, 理解, 未理解データの差よりも外れ値との差のほうが大きく, 外れ値が優先してクラスタに格納されてしまうため, 理解, 未理解データを分類するのに十分なクラスタ数が確保されていなかったと考えられる。なお, クラスタ数6~20でクラスタリング精度が最高となったのはクラスタ数12で, 精度は0.25であった。

クラスタ数6~20において, クラスタリング精度の最も高いクラスタ数12個の内訳を表5に示す。

表5よりクラスタ数12において, データ数が1のクラスタは6個(クラスタ1,3,5,6,7,10)存在する。これらは, 外れ値のデータを持つクラスタで, 理解, 未理解データの集団よりも優先してクラスタに格納されたと考えられる。また, データ数が1のクラスタを除いた状態での正答率8割以上の理解クラスタは2個(ク




図4 クラスタ数6~20におけるクラスタリングの精度

ラスタ2,9)存在し, クラスタ数12と同様に, クラスタ数12以上のクラスタ数においても理解クラスタが複数存在するクラスタが確認できた. また, 理解クラスタ(クラスタ2,9)の重心に注目すると, クラスタ2ではHigh α 波, クラスタ9では θ 波が顕著に表れることが確認できた. 周波数成分ごとの心理状態として, High α 波は集中, θ 波は想起などが挙げられ, 理解時の心理状態と深く関わりがあると考えられる. これは, プログラムを理解した際の脳波の特徴は1種類に集約されるのではなく, 複数のパターンに分類することができることを示す. つまり, プログラムを理解した際の脳波の周波数成分の特徴は複数存在すると考えられる. この複数のパターンに分類される原因は個人差であると考えられる.

一方で, データ数が1のクラスタを除いた状態での正答率2割以下の未理解クラスタは存在しなかった. クラスタ数を12以上にした場合でも, データ数が2以上で正答率2割以下の未理解クラスタは理解クラスタ数と比べて出現が少なかった. よって, 未理解クラスタへの分類は理解クラスタの分類よりも難しく, 脳波の特徴としては理解状態のほうが顕著に表れるのではないかと考えられる.




図5 データを複数持つクラスタ数の変化

5 おわりに

本研究はプログラム理解タスクにおける脳波を時系列分析して抽出した周波数成分を特徴量としてクラスタリングを行うことで、脳波の個人差による特徴の傾向を含めた分析を行うことを目的として行った。分析には、先行研究[5]の脳波データを用いた。脳波データを8分割し、各分割データで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、Low γ 波、Middle γ 波)ごとのパワースペクトルを求め特徴量とした。

分析データに主成分分析による次元圧縮を行い、重要データの洗い出しを試みたが、次元圧縮後の主成分データにおける元データの寄与率は0.99999...と非常に1に近い値となり、その原因として、個人差と時系列分析の手法(データを8等分)が考えられる。主成分分析によって求めた主成分データの特徴量として、エルボー法を用いて最適なクラスタ数を6とし、クラスタリングを行うと、データ数が1つのみのクラスタ4つと、複数のデータを持つクラスタ2つに分かれた。複数のデータを持つクラスタは、それぞれデータ(タスク)の正答率が0.53と0.75であり、正答率0.75のクラスタにはプログラムを理解したデータへの偏りが見えるが、正答率0.53はその割合が約半分となっており、プログラムを理解したデータとできなかったデータの分類ができていないとは言えず、クラスタ数6は適切なクラスタ数でないことが明らかになった。そこで、クラスタ数を6~20へと順に変化させていった際のデータに対するクラスタリングの精度を分析すると、クラスタ数

表5 クラスタの内訳(クラスタ数12)

Cluster	データ数	正答数	正答率
0	30	18	0.60
1	1	0	0
2	30	24	0.80
3	1	1	1
4	6	3	0.50
5	1	0	0
6	1	1	1
7	1	0	0
8	42	18	0.43
9	15	12	0.80
10	1	0	0
11	21	14	0.67

12の時の精度が最も高かった。クラスタ数12のうち、正答率8割以上のクラスタが2つ存在し、それと同様にクラスタ数12以上のクラスタ数においても正答率が8割以上のクラスタが複数存在した。よって、プログラムを理解した際の脳波の特徴は複数パターンに分類することができることが明らかになった。また、この複数パターンへの分類は個人差であると言える。

本研究の分析結果から、プログラム理解状態の脳波の特徴には個人差があり、複数のパターンに分類できることが明らかになった。しかし本研究の課題点として、分析に用いたデータは被験者の主観的理解を反映したものではない点と、時系列分析でデータを8等分した分割ごとの関連性が低いと考えられる点が挙げられる。よって、今後の展望として主観的データを用いた分析と、新たな時系列分析の手法の提案が挙げられる。その結果を用いて機械学習を行うことで、個人差に考慮した脳波データの分析が可能になると考えられる。

謝辞

本論文の執筆，研究を進めるにあたって，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，論文の添削など多くの助力をいただきました．査読教員である山口智弘先生には，今後の展望に関連する大変価値のある助言をいただきました．上野研究室専攻科1年の松山さんには，研究データの引継ぎや脳波を分析するプログラム作成など多くの助力をいただきました．この場をお借りして深くお礼申し上げます．本当にありがとうございました．

参考文献

- [1] 松山鼓, ”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判別”, 奈良工業高等専門学校情報工学科令和4年度卒業研究論文 (2023).
- [2] 音茂龍司, 辻貞敏: ”よくわかる脳波判読第3版”: 金原出版株式会社 (2015).
- [3] 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).
- [4] 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).
- [5] 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).
- [6] 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).
- [7] 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).
- [8] 山本愛子, ”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”, 奈良工業高等専門学校電子情報工学専攻平成29年度専攻科特別研究論文 (2017).
- [9] 田中博昭, 林田祐樹, 村上伸樹, 伊賀崎伴彦: ”相互相関活動を持つヒト脳内複数信号源の推定～タッピング運動時の脳波及び筋電図測定データを用いた解析～”, 一般社団法人日本臨床神経生理学会-臨床神経生理学, Vol.41, No.1, pp.7-17 (2013).