

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 Identification of Program Comprehension using Time-series Changes in EEG Frequency Components

松山 鼓¹⁾ 上野 秀剛¹⁾
Matsuyama Tsuzumi Uwano Hidetake

1 はじめに

プログラム理解はソフトウェア開発における主要な作業の1つである。例えば、プログラム教育現場において指導者側から学習者がプログラムを十分に理解できているか確認することで、理解が不十分な学習者に対して集中した支援が可能になる。理解が不十分な学習者を特定することは、各学習者に口頭で確認することでも可能だが、学習者の中には心理的要因から理解していないことを報告しにくい人もいる可能性があり、プログラム理解に対する支援を充分に行えない状況が存在する。また、多数の学習者に対する指導が必要な場合は口頭確認の手間も大きく、近年普及が進んでいる遠隔講義においても容易ではないため、自動で理解状態を把握できる環境が必要となる。学習者のプログラム理解状態を指導者側から自動で識別するシステムがあれば、指導者は学習者への効率的なプログラム理解支援が可能になる。しかし、プログラミング作業には思考作業が多く含まれる為、指導者側が外観から理解状態を識別することは難しい。

プログラム理解状態を把握するための方法として、脳活動や視線情報などの生体情報に着目する手法がある。生体情報の1つである脳活動は、思考状態や心理状態と関係があることが知られており、プログラム理解を測定するための様々な研究で用いられている [1, 2]。脳活動を計測する為の手法の中でも、脳波はミリ秒単位で記録が行え、時系列ごとの細かな変化を把握することが可能なことから、時間分解能が高い。プログラム作業中ではリアルタイムで思考が変化する為、時間分解能が高いと思考の変化をより詳細に分析することが可能である。その為、脳波による分析法は理解状態の識別に適している手法だと考えられる。脳波は国際脳波学会によって定められた周波数成分ごとに名称が付けられており、被験者の心理状態によって各周波数成分の強さが変化することがわかっている。例えば、リラックス時などの安静状態では α 波が、ストレスがある状態では β 波が多く出現する [3]。先行研究により、被験者の集中や思考状態によって脳波が変化するという特徴からプログラムの理解状態を識別できることが分かっている [?]。また、被験者にソースコードを読んで理解するタスクを与えた際、脳波はタスクを理解しているのか、理解していないのかなど、タスクに対する思考状態によって逐次変化することが予想される。その為、タスクを一定時間ごとに分割し、時系列分析することで理解状態の把握に必要な情報が得られると考えられる。

プログラム理解時の脳波を計測した従来の研究では、脳波の複数の周波数成分に着目し、*Low β* 波、*High β* 波、*Low γ* 波、*Mid γ* 波がプログラム理解の有無を把握する

指標となる可能性があることがわかっている [4]。また、プログラムのプログラム理解の有無によって α 波と β 波の時系列変化に有意な差があることがわかっている [5]。一方で、 α 波、 β 波以外の周波数成分において時系列変化に差があるかは明らかにされていない。

本研究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変化を特徴量とした機械学習を用いることで理解の有無を自動で識別できるか評価する。機械学習では、タスク中の周波数成分を等間隔に複数の領域に分割し、各領域ごとの周波数成分を求める。全ての時間領域の周波数成分を1タスクの特徴量としたデータセットを作成し、プログラムの理解の有無をラベルとして付与する。実験ではどの時間領域、周波数成分がプログラム理解の有無の識別に有用か評価する。

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の説明する。4章では実験内容について説明し、5章では実験結果の考察、6章で本研究での結論を述べる。

2 関連研究

プログラムの理解状態の定量的な評価に生体情報を利用した研究が数多く存在する。生体情報とは視線、脳波、心音などの生体活動を調節する体内活動に関する情報のことであり、その中でも近年、脳波計測装置の高性能化・低価格化に伴い、プログラム理解と脳計測を組み合わせた研究が数多くある。

Siegmund らは脳の血流変化を測定する装置である functional Magnetic Resonance Imaging (fMRI) を用いてプログラム理解時の脳活動を観測した [1]。脳は脳領域ごとに役割が分かれており、注意や言語理解をしている際など、活動に応じた特定の脳領域が活性化される。fMRI は脳の血流変化を測定することでどの領域が活性化するかリアルタイムに測定する。Siegmund らの研究の結果、プログラムを理解する時に、被験者の問題解決、記憶、および文章理解に関する脳領域が活性化することが示されている。fMRI を用いた計測は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できる一方、被験者が装置の中に横たわり、ノイズを減らす為に固く固定する必要があり、被験者の行動や姿勢、計測環境を強く制限する。その為、教育現場や職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。

fMRI での計測と比べて姿勢と体動の制限が少ない脳波計測装置を用いた研究も多数行われている。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計測し、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実験した [6]。実験の結果、高難易度のソースコードを理解するときなど、認知的負荷が高い場合に *High 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。Klimesch は *High α* 波のパワース

1) 奈良工業高等専門学校情報工学科. Department of Information Engineering, National Institute of Technology (KOSEN), Nara College.

表 1 脳波の分類 [13]

周波数成分	周波数帯域	生体活動・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, 幻想, 夢
Low α 波	7.5~9.25[Hz]	リラクセス, 平穩, 意識的
High α 波	10~11.75[Hz]	リラクセスしているが集中している, 統合的
Low β 波	13~16.75[Hz]	思考, 自己及び環境の認識
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

ベクトルと意味記憶の能力の間に、Low α 波と集中の有無に相関が見られたことを報告している [7]。石田らの研究ではプログラム動作を理解するタスクにおいて正しく理解できた被験者の α 波が有意に大きく、バグの有無を判断するタスクにおいて正しく判断できた被験者の β 波が有意に大きかった [8]。また、石田らは別研究 [5] においてプログラム理解タスクにおける時系列の変化を分析し、プログラムの動作を正しく理解できた被験者は α 波と β 波のパワースペクトルがタスク開始時からタスク終了にかけて増加しており、バグの有無を正しく判断した被験者は α 波のパワースペクトルが有意に増加することを示した。柴田はプログラム理解タスクにおける脳波を計測し、細かく分けた周波数成分ごとのパワースペクトルとタスクの正答、未回答、誤回答の関係を調査した [4]。実験の結果、Low β 波、High β 波、Low γ 波、Mid γ 波において 3 つの状態間に有意差が見られた。

脳波などの生体情報を用いて機械学習を行った研究も存在する。Fritz らは視線、皮膚電気活動、脳波を計測し、被験者がタスクに対して困難と感じているかどうかを機械学習を用いて推定した [9]。結果として、タスクの難易度 (易しい/難しい) を 65.0%の精度、64.6%の再現率で予測し、被験者が初めて行うタスクの場合 84.4%の精度、69.8%の再現率で予測できた。

本研究では従来の研究結果を踏まえ、プログラム理解中の脳波における複数の周波数成分に対して時系列分析を行い、機械学習を用いることでプログラム理解状態を予測し、予測精度への影響の強い要素を明らかにする。

3 脳波

3.1 測定方法

脳波とは脳から生じる電気活動を縦軸、時間を横軸にとって記録したものである [10]。脳波は頭皮上に装着した電極から計測される。電極の配置は国際式 10-20 電極法に則って行う [11]。国際式 10-20 電極法では頭皮が 10%もしくは 20%の等間隔で区切られており、検査や研究の用途によって電極配置位置を決定する。

脳波には基準電極導出法と双極導出法の 2 種類の導出法がある。基準電極導出法では、脳電位の電場内に装着した探査電極と、電場外に装着した基準電極の 2 つの電極の電位差として脳電位を測定する。探査電極は国際式 10-20 電極法に従って測定したい部位に装着する。双極導出法では、基準電極を用いず、2 つの電極を脳電位の電場内において記録を行う。2 つの電極のそれぞれがとらえた脳電位の差が記録される。優劣な背景成分を除去して部位差を強調する目的で使うことが多い [12]。

3.2 周波数帯域

脳波は異なる周波数をもつ波形を合成したものであり、周波数帯域ごとに異なる特徴をもつ成分として分類される。周波数成分のパワースペクトルを抽出するために FFT (Fast Fourier Transform) や STFT (Short Time Fourier Transform) が多くの研究で用いられる。脳波の周波数成分の代表的な分類は以下の通りである。

- δ 波: 0.5~4Hz
- θ 波: 4~8Hz
- α 波: 8~14Hz
- β 波: 14~30Hz
- γ 波: 30Hz 以上

δ 波や θ 波は睡眠状態にあるときに出現する。 α 波はリラックス時や、ストレスが少ない時などの安静状態に出現する。他の周波数帯域の波と比較して振幅も連続性も最も高い。また、 α 波は開眼すると大幅に減少し、閉眼すると再び出現する。この現象を一般的に α 波減衰と呼ぶ。 β 波は緊張や不快な感情を抱いている時など、ストレスが強い時に出現する。 γ 波は、不安で興奮している時に出現しやすい [12, 3]。

周波数帯域は更に細かい分類が定義されており、その特徴を表 1 に示す [13]。このように各周波数帯域が被験者の心理状態によって変化する特徴を持つ。これまでの研究において α 波、 β 波はプログラム理解に関係があることが明らかになっている [8]。また、周波数帯域を細かく区分した際には Low β 波、High β 波、Low γ 波、Mid γ 波がプログラム理解と関係があることが示されている [4]。時系列分析を行った際においても、これらの周波数帯域がプログラム理解時の特徴として変動することが期待できる。

4 実験

本研究では先行研究 [8] で取得した脳波データを用いる。先行研究の実験環境を 4.1 節に、タスクを 4.2 節に、実験手順を 4.3 節に示す。

実験は日本語と Java で記述されたプログラム課題を被験者に提示し、処理内容を理解する間の脳波を計測する。被験者は奈良工業高等専門学校の学生 5 人で、年齢は 19 歳から 20 歳、全員が Java によるプログラミングの基礎講義を受講済みである。

4.1 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に座り、頭部と体をできるだけ動かさないように指示する。

実験に使用するのは、脳波計測装置、タスク提示用

表2 タスク一覧

難易度	仕様
1	階乗の計算
2	最大値検索
3	表数判定
4	中央値検索
5	累乗検索
6	2つの数値の入れ替え
7	指定した文字列が含まれているか判定
8	文字列を反転させる
9	ハノイの塔
10	経路数を求める
11	順列を会列挙する
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	雲の軌道予測
16	最小公倍数と最大公約数

PC, 脳波計測用 PC, 記録用 PC である。脳波計測装置にはナノテックイメージ社製 Nexus-10 MARK II を用いる。本計測装置は計測周期は 256Hz であり、計測された脳波は Bluetooth 経由で脳波計測用 PC に転送され、CSV ファイル形式で出力される。本計測装置の制御とデータ取得には BioTrace+ Software を用いる。

4.2 タスク

提示するプログラム課題の処理内容を理解するタスクを被験者 1 人につき 16 問与える。実験用に作成したタスク提示ツールを用いて、被験者に日本語で記述されたプログラムの仕様と対応する Java のソースコード 1 組を提示する。各タスクは動作理解ステップとバグ判断ステップで構成される。動作理解ステップでは、被験者にプログラムの仕様とソースコードを提示し、動作を理解しているか質問する。質問には口頭で回答してもらい、事前に用意した回答と一致していれば動作を理解している、一致していなければ理解していないとみなす。バグ判断ステップでは、被験者に動作理解タスクで見せたソースコードの一部を改編したソースコードを見せる。被験者には改編後のソースコードが仕様を満たすかどうかを回答してもらう。回答の正誤は被験者には伝えず、制限時間は 1 分とする。

本実験では、プログラムに対する理解の有無が同程度の件数計測できるように、タスクの難易度と制限時間を調整する。タスクの難易度は低難易度と高難易度をそれぞれ 8 件用意する。低難易度は main メソッドのみからなり、1 重の繰り返し文や条件分岐で構成された理解が容易と思われるソースコードを使用する。高難易度のソースコードは複数メソッドの使用や再帰構造を持ち、制限時間以内での理解が難しいと期待できる複雑なアルゴリズムを使用する。制限時間はそれぞれのステップごとに設定し、低難易度の理解には十分で、かつ高難易度の理解に不十分であることを予備実験によって確認している。また、各タスクを提示する順番は、順序効果を考慮し、カウンターバランスを行う。表 2 にタスク一覧を示す。

なお、2 つのステップの内、本稿では動作理解ステップから得たデータのみを対象に分析する。

4.3 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-10 MARKII 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、練習タスクを実施してもらう。
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してもらう。
5. 解答
被験者には動作を理解した時にコントローラのボタンを押して答えを口述してもらう。
6. 変更後タスクの実施
ディスプレイに変更後のタスクを 1 分間提示し、仕様を満たすか判断してもらう。
7. 解答
被験者には仕様を満たすか判断できた時にコントローラのボタンを押して答えを口述してもらう。
8. 全タスクの実施
1 タスク当たり手順 4~7 を 1 回を行う。全タスクである 16 タスクを行うため、手順 4~6 を 16 回繰り返す。

4.4 分析

本研究では複数の周波数成分に対して時系列分析する為、各被験者のタスクごとの脳波データを複数の時間領域に分割する。図 1 にパワースペクトル算出法を示す。被験者 s のタスク t から得られた脳波 $BW_{s,t}$ から、図 1 に示したような形で、各周波数成分毎のパワースペクトルを fft を用いて算出する。また、被験者 s のタスク t を D 等分し、それぞれの等分データ毎に同様の方法でパワースペクトルを算出する。脳波の個人差を考慮し、被験者 s 、タスク t の時間帯 d における周波数成分 Freq を、被験者 s の全てのタスクにおける全周波数成分の平均で正規化する。

$$\text{Norm.Freq}_{s,t,1} = \frac{\text{Freq}_{s,t,1}}{\text{Average}(\delta_{s,1} \cdots M\gamma_{s,1} \delta_{s,T} \cdots M\gamma_{s,T})} \quad (1)$$

正規化した各時間帯の周波数成分をメトリクスとして Random forest によって機械学習させる。正解集合として実験時に集計した、被験者の自己申告による理解の有無を用いる。Leave one out 法を用いてすべてのタスクデータに対して理解状態の有無を Yes か No で予測し、精度を算出する。Random forest のパラメータ設定は決定木モデル数 n_{tree} を 500、使用メトリクス数 m_{try} を予備実験で行ったモデルチューニングにおいてエラー率の小さかった 1 から 16 までの値を用いて分析する。Random forest には R 言語の randomForest パッケージを、その他の分析には dplyr, pforeach パッケージを用いた。パワースペクトルを算出する際に用いる周波数成分の分類の違いが予測精度に与える影響を評価するため

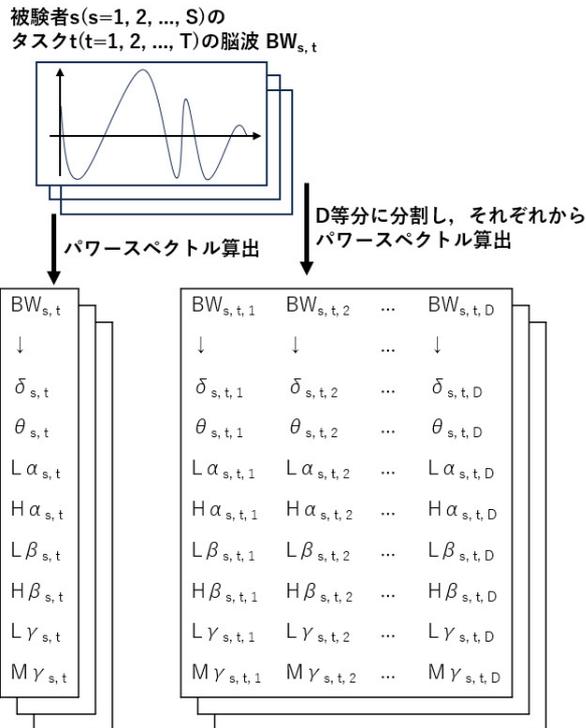


図1 パワースペクトル算出法

に、5種類 ($\delta, \theta, \alpha, \beta, \gamma$) の分類と、 α 波、 β 波を Low, High に、 γ 波を Low, mid にそれぞれ分類した 8 種類 ($\delta, \theta, L\alpha, H\alpha, L\beta, H\beta, L\gamma, M\gamma$) の分類を用いる。また、時間の分割数 D についても分割数による予測精度の差を評価するため、1 分割 (分割無し) から 10 分割まで変化したデータセットを作成し、予測精度を比較する。

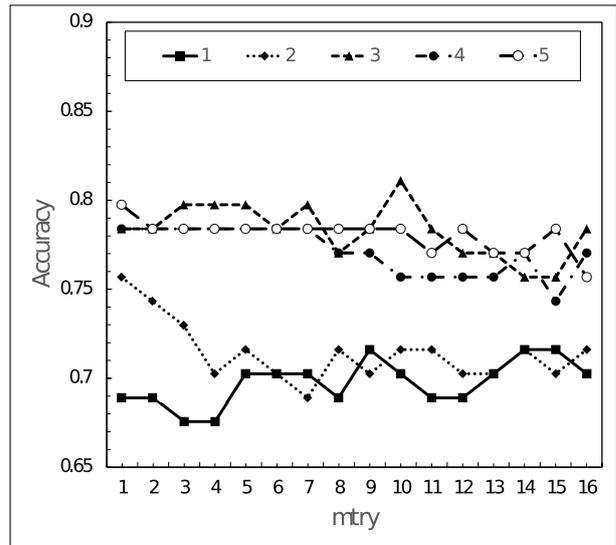
5 結果と考察

実験の結果、被験者 1 人につき 16 タスク、5 人 \times 16 タスクの合計 80 件のデータを取得した。その中から異常値を含む 6 件を削除した 74 件の脳波データを用いて分析する。データセットは脳波を 8 種類の周波数成分とした $d=1\sim 10$ の 10 個と、脳波を 5 種類の周波数成分とした $d=1\sim 10$ の 10 個の計 20 個について評価する。

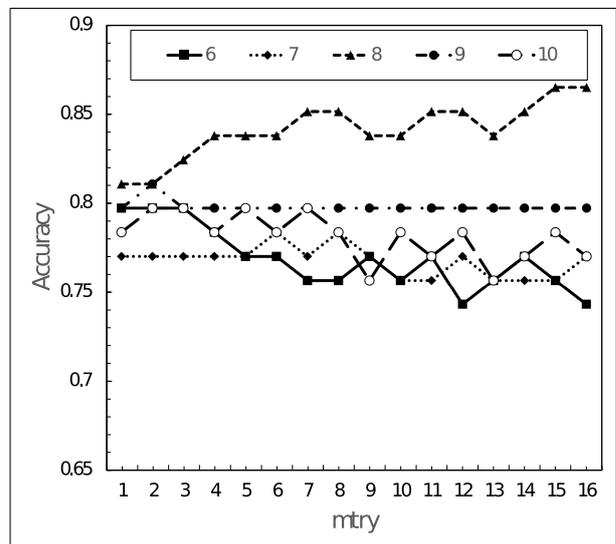
5.1 予測精度

図 2 に 5 種類の周波数成分を用いた場合の予測精度を示す。図の横軸は $mtry$ 、縦軸は予測精度、線の種類は分割数を表し、(a) が $d=1\sim 5$ 、(b) が $d=6\sim 10$ を示す。分割数が 1 (分割無し) の時にもっとも精度が低く 69.0% ($mtry = 3, 4$) \sim 71.6% ($mtry = 9, 14, 15$) だったのに対して、分割数が 3 以上の時に精度が高く、分割数 8 で 81.1% ($mtry = 1, 2$) \sim 86.5% ($mtry = 15, 16$) となった。分割数 8 においては $mtry$ の値が大きくなるにつれて精度も上昇している。8 種類の周波数成分を用いた場合にも 5 種類の場合と同様の傾向が見られ、分割数が 1 (分割無し) の時にもっとも精度が低く 68.9% ($mtry = 1\sim 4, 9, 10$) \sim 73.0% ($mtry = 7$)、分割数が 8 の時にもっとも精度が高く 78.4% ($mtry = 8$) \sim 83.8% ($mtry = 1, 4, 5$) だった。

図 3 に周波数成分 8 種と 5 種それぞれにおける、分割数 d ごとの予測精度の平均を示す。横軸は分割数 D 、縦軸は予測精度の平均値、線の種類は周波数成分の種類数を表す。周波数成分が 5 種、8 種ともに分割数 1 (分割



(a) $D=1\sim 5$



(b) $D=6\sim 10$

図2 予測精度 (周波数成分 5 種類)

なし) で精度が 70% 程度と最も低く、分割数 3 以降と 7% 以上の差がある。また、周波数成分 5 種、8 種ともに分割数 8 で最も精度が高く、5 種で 84.1%、8 種で 81.8% だった。それ以外の分割数については精度に大きな差は見られない。

図 4 に $mtry$ ごとの予測精度の平均を示す。横軸は $mtry$ 、縦軸は予測精度の平均値、線の種類は周波数成分の種類数を表す。周波数成分 8 種と 5 種のいずれにおいても $mtry$ ごとの予測精度の平均値に差異が少ないことから、 $mtry$ は予測精度への影響は少ないと考えられる。 $mtry$ は予測に用いるメトリクス数を表すことから、多くの周波数成分を用いて予測を行っているのではなく、一部の周波数成分が予測結果に強い影響を与えていることが考えられる。

これらの結果から、プログラムを理解した際に現れる特徴は分割数が 3 以上のデータに強く出現することが確認できた。本研究では、タスクを理解していた被験者と理解をしていなかった被験者の比率は、およそ 6 : 4 と

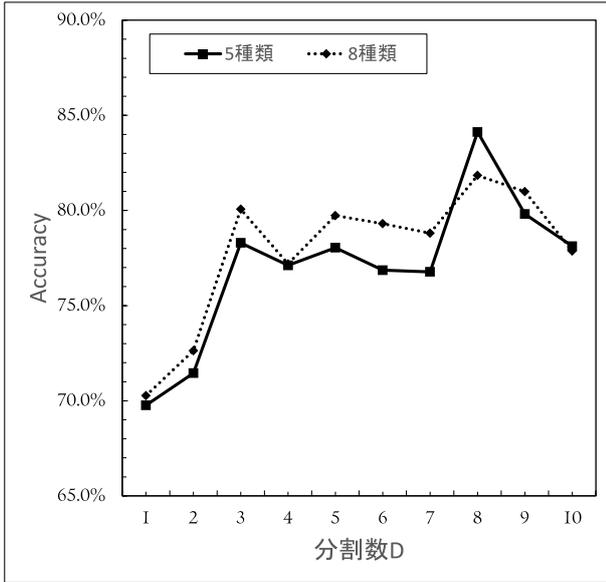


図3 分割数ごとの精度平均

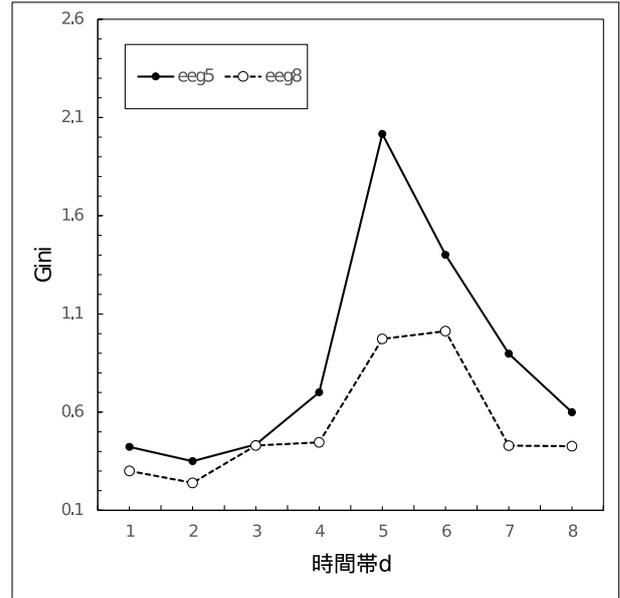


図5 各時間帯の重要度 (分割数 D=8, メトリクス数 mtry=16)

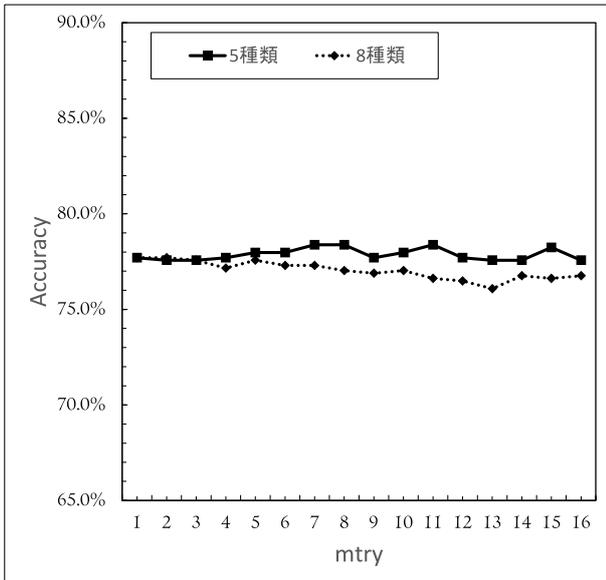


図4 mtryごとの精度平均

なっている。従って、本研究の予測結果がプログラム理解の予測に対して重要な情報であったと言える。また、分割数が 1, 2 の時に精度が低い理由として、分割数が 3 未満の時に算出される周波数成分のパワースペクトル (たとえば α_1) データには予測に必要なデータが多く含まれていることが要因だと考えられる。従って、本データにおいて、予測には 3 分割数以上した際に表れる一部の時間軸のデータが必要で、8 分割数した際にそのデータが最も表れやすいと言える。

5.2 時間軸ごとの重要度

時間軸ごとに抽出した各周波数成分について、それぞれが予測精度に与える影響を分析する。本節では、周波数成分 5 種の時間分割数 $D = 8$ 、メトリクス数 $mtry = 16$ を用いた際の結果を示す。Random forest は予測に使用したメトリクスが予測精度に与える影響を示す Gini 係数を出力できる。図 5 に各周波数成分の Gini

係数について時間帯ごとの平均値を示す。周波数成分 5 種, 8 種の双方において 8 分割した時間帯の 5 番目, 6 番目の脳波から算出した周波数成分がもっとも精度の向上に寄与していた。プログラムを正しく理解した被験者はタスク開始からソースコードを読み始め、細部の動作を理解することでプログラム全体の理解に到達したと考えられる。そのため、タスク時間が半分以上経過した時間帯の周波数成分がプログラム理解の予測に寄与している可能性がある。

5.3 周波数成分ごとの重要度

図 6 に (a) 周波数成分 5 種と (b) 8 種の時間分割数 $D = 8$ と $D = 10$ における各周波数成分の Gini 係数を示す。周波数成分 5 種の場合、分割数が 8 と 10 のどちらにおいても α 波, β 波の Gini 係数が高い。周波数成分 8 種の場合も同様に分割数が 8 と 10 の両方で α 波と β 波の Gini 係数が高く、特に *High α* 波の Gini 係数が高い。したがって、どちらの時間分割数においても α 波, β 波はプログラム理解の予測に重要な情報であるということが言える。8 種類の周波数成分について分析した先行研究 [4] の結果とは異なり、タスク中の脳波を複数の時間帯に分割した本研究の分析では γ 波の Gini 係数が低い結果となった。今後の研究において各時間帯の周波数成分のパワースペクトルが示す意味について分析する必要がある。

6 おわりに

本研究ではプログラムのプログラム理解状態を予測するために、複数の時間帯に分割した理解中脳波から得られる周波数成分を特徴量として Random forest を用いた機械学習を行った。被験者のタスクごとの脳波を、1 分割 (分割なし) から 10 分割まで、一定の時間ごとに分割し、周波数成分ごとのパワースペクトルを算出した。周波数成分を 5 種類 ($\delta, \theta, \alpha, \beta, \gamma$) と 8 種類 ($\delta, \theta, Low\alpha, High\alpha, Low\beta, High\beta, Low\gamma, Middle\gamma$) とした場合のデータセットを作成し、それぞれを用いた場合の予測精度を比較した。予測には Random forest を用いた。実験の結

果、周波数成分が 8 種類、時間帯の分割数が 8,9 の際に予測精度が 83.8%と最も高いのに対して分割数が 1 の場合に 68.9%と最も低く、時間帯を複数に分割することで精度が向上することが確認できた。また、時間帯としては中盤より後ろ、周波数成分としては周波数成分 5 種で α 波と β 波、8 種で High α 波が特に重要であることが分かった。

今後、時間帯ごとの周波数成分から得られるパワースペクトルの特徴を分析することでより精度を高められると考えられる。また、本稿の分析では異なる作業時間を持つタスクについても均一の分割数で時間帯の分割を行ったため、被験者やタスクによってパワースペクトルを求める脳波の時間長が異なっている。時間長を固定した分割法や分割数をより多くしたデータセットを用いた予測の精度を評価することは本研究の興味深い発展である。

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] 中川尊雄, 亀井靖高, 上野秀剛, 門田暁人, 鶴林尚靖, 松本健一, "脳活動に基づくプログラム理解の困難さ測定", コンピュータソフトウェア, Vol.33, No.2, pp.78-89 (2016).

[3] 宮田洋, 藤澤清, 柿木昇治, 山崎勝男: "新生理心理学-生理心理学の基礎", 北大路書房 (1998).

[4] 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 平成 31 年度卒業研究論文 (2020).

[5] 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).

[6] 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).

[7] W. Klimesch, "EEG- α rhythms and memory processes", International Journal of Psychophysiology, Vol.26, pp.319-340 (1997).

[8] Toyomi Ishida, Hidetake Uwano, 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.

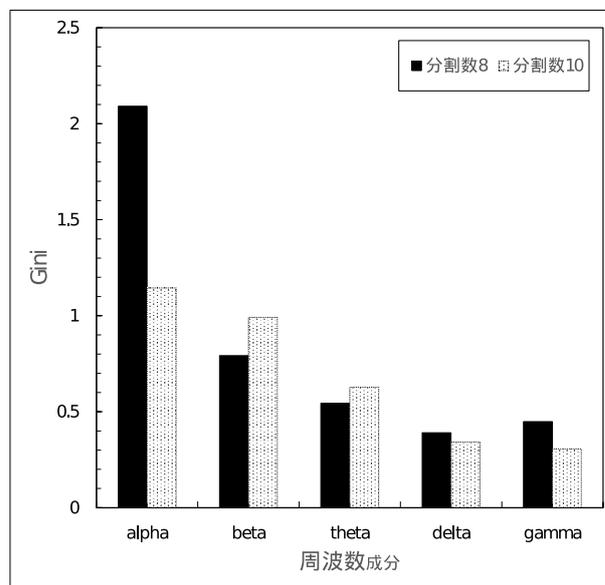
[9] T. Fritz, A. Begel, S. C. Miller, S. Yigit-Elliott, M. Zger, "Using Psycho-Physiological Measures to Assess Task Difficulty in Software Development", In Proceedings of the International Conference on Software Engineering (ICSE), pp.402-413 (2014).

[10] 村上郁也: "イラストレクチャー認知神経科学", オーム社 (2013).

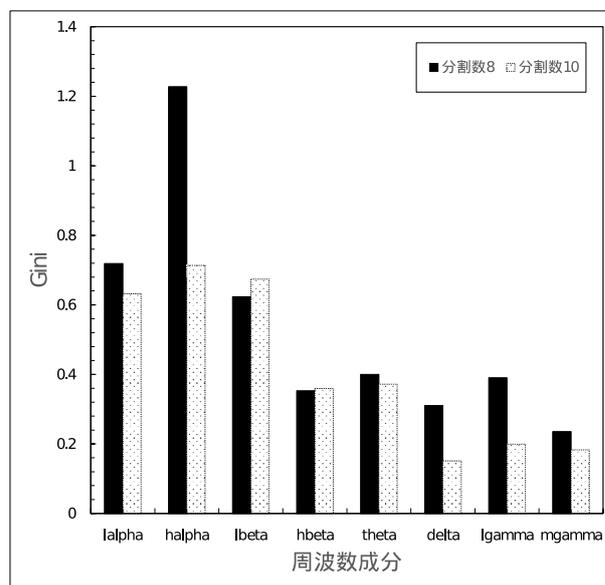
[11] 音茂龍司, 辻貞敏: "よくわかる脳波判読第 3 版": 金原出版 (2015).

[12] 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).

[13] 坂本佑太, 吉田幸二, 宮地功: "簡易脳波計による学習時の思考と記憶の比較分析", マルチメディア, 分散, 協調とモバイル (DICOMO)2012 シンポジウム論文集, pp.724-729 (2012).



(a) 周波数成分 5 種



(b) 周波数成分 8 種

図 6 周波数成分ごとの Gini 係数