

公立はこだて未来大学 2025 年度 システム情報科学実習 グループ報告書

Future University Hakodate 2025 Systems Information Science Practice
Group Report

プロジェクト番号/Project No.

11

プロジェクト名/Project Name

Make Brain Project

グループ名

グループ D

Group Name

Group D

プロジェクトリーダー/Project Leader

角脇輝映 Akira Kadowaki

グループリーダー/Group Leader

逸見千佐 Chisa Hemmi

グループメンバー/Group Member

薄井優太 Yuta Usui

門脇大造 Taizo Kadowaki

小林柊斗 Shuto Kobayashi

千葉皓仁 Hiroto Chiba

西村颯真 Soma Nishimura

指導教員

香取勇一 栗川知己 島内宏和 佐藤直行

Advisor

Yuichi Katori Tomoki Kurikawa Hirokazu Shimauchi Naoyuki Sato

提出日

2026 年 1 月 21 日

Date of Submission

Jan. 21, 2026

概要

近年、脳波をもとに視覚情報を再構成する技術が注目されており、ブレイン・コンピュータ・インターフェース (BCI) や脳型人工知能の分野での研究が活発化している。本プロジェクトは、このような背景を踏まえ、人が視覚刺激を受けたときの脳波データをもとに、対応する視覚情報 (画像) を予測・再構成する人工知能の開発を目的とする。これにより、人間がどのように視覚情報を脳内で処理しているのか、そのメカニズムの理解を目指す。本プロジェクトにより、脳波から視覚情報を推定する人工知能が実現されることが期待される。さらにこの成果は、画像から脳波を生成するモデルの開発や、BCI を応用した次世代型ユーザインタフェースの実現にもつながる可能性がある。

キーワード 脳波, 脳型人工知能, BCI

(※文責: 小林柊斗)

Abstract

In recent years, technology for reconstructing visual information based on electroencephalograms (EEG) has attracted attention, spurring active research in the fields of brain-computer interfaces (BCI) and brain-inspired artificial intelligence (AI). This project aims to develop an AI system that can predict and reconstruct corresponding visual information (images) based on EEG data obtained when a person is exposed to visual stimuli. This will help us understand the mechanisms by which humans process visual information in the brain. This project is expected to lead to the realization of AI that can infer visual information from EEG. Furthermore, these results may lead to the development of models that generate EEG data from images and to the realization of next-generation user interfaces that utilize BCI.

Keyword EEG, brain-inspired artificial intelligence, brain-computer interface (BCI)
(※文責: 小林柊斗)

目次

第 1 章	はじめに	1
1.1	背景	1
1.2	先行研究	1
1.3	プロジェクトの動機	1
1.4	プロジェクトの目的・意義	2
第 2 章	関連研究 (以前に行われた研究や過去に行われたプロジェクト学習)	3
2.1	本プロジェクトで必要なスキルと知識	3
2.2	関連性の高い本学の専門科目	3
第 3 章	プロジェクト学習の目標	5
3.1	脳波測定班	5
3.2	人工脳波生成班	5
第 4 章	手法	6
4.1	脳波測定および脳波解析の手順	6
4.1.1	脳波の測定	6
4.1.2	測定データの解析	7
4.1.3	解析結果を用いた Web アプリケーション開発	9
4.1.4	精度向上のためのモデルの調整	9
4.2	人工脳波の作成手順	10
4.2.1	データセット	10
4.2.2	人工脳波生成モデル	10
4.2.3	学習手法および損失関数	11
4.2.4	評価タスク	12
4.2.5	実験環境	12
第 5 章	結果	13
5.1	脳波測定班の結果	13
5.2	人工脳波生成班の結果	14
5.2.1	脳波生成・検索タスク	14
5.2.2	脳波の可視化	15
第 6 章	考察	17
6.1	脳波測定班	17
6.1.1	得られた知見	17
6.1.2	今後の展望	17
6.2	人工脳波生成班	17
6.2.1	得られた知見	17

6.2.2 今後の展望	18
参考文献	19

第 1 章 はじめに

1.1 背景

近年、脳波 (Electroencephalogram: EEG) を活用したブレイン・コンピュータ・インターフェース (Brain-Computer Interface: BCI) の研究が進展しており、医療・福祉・エンターテインメントなど多様な分野での応用が期待されている。BCI とは、脳活動を計測・解析し、その情報を用いて外部システムと情報のやり取りを行う技術であり、身体的な操作を必要としない新しいインターフェースとして注目されている。

特に近年では、視覚刺激に対する脳の反応を解析し、人が見ている情報や感じている内容を推定・再構成する研究が活発に行われている [1][2]。このような研究では、外界からの刺激に対して脳内で形成される主観的な知覚や認知の状態が重要な対象となる。この脳内の状態は、しばしば内的表象と呼ばれ、言語や行動として直接表出しない情報を含んでいる。脳波を用いてこれらの内的表象を推定する試みは、人間の知覚過程を可視化する新たなアプローチとして位置づけられる。

さらに、視覚刺激に対する脳波解析は、注意や覚醒といった意識の状態を推定する研究へと発展している [3]。ここでいう意識の状態解読とは、脳活動の特徴量から、刺激への注目度や知覚内容といった認知的状態を推定することを指す。この分野は、神経科学と人工知能が融合する研究領域として近年急速に発展している。

1.2 先行研究

視覚情報の再構成に関する研究は、機能的磁気共鳴画像法 (functional Magnetic Resonance Imaging: fMRI) や EEG を用いた脳活動解析を基盤として進められてきた。中でも「DreamDiffusion」は、脳波を画像生成 AI (Stable Diffusion) に入力することで、被験者が見た画像を再構成する技術として注目を集めている [4]。この研究では、視覚イメージの脳内活動を、AI に入力可能な特徴ベクトルとして抽出し、視覚復元を実現している。また、視覚刺激に応じて生じる EEG 信号を対象に、時間情報および周波数情報を含む多次元特徴量を深層学習で学習する手法も提案されている [5]。ノイズが多く個人差の大きい EEG 信号からでも、深層学習を用いることで視覚的意味に対応する頑健な表現を学習可能であることを示した。

しかし、これらの先行研究の多くは、複数被験者を対象とした性能の向上を主目的としており、被験者ごとの特性を積極的に活用する設計には至っていない。また、高い性能を得るために、多チャンネル EEG や大規模データを前提とする場合が多い。

1.3 プロジェクトの動機

脳波を用いた視覚情報推定は、脳波に視覚刺激と直接関係しない成分が多く含まれることや、脳波では脳のどの位置が活動したかを正確に特定することが難しいことから、高精度な解析が困難であるとされてきた。そのため、従来研究の多くは、多チャンネル EEG や多数の被験者データを用いることで、統計的に安定した特徴を抽出する方向に進められてきた。しかしこのアプローチは、計測環境の複雑化やデータ収集の負担が大きく、実用性の観点では課題が残る。

本プロジェクトの動機は、被験者を一人に絞って継続的に計測を行うことで、個人内で一貫した脳波特性を学習できるのではないかという仮説に基づいている。EEG 信号は被験者間で大きな差異が見られる一方、同一被験者内では刺激条件に対する反応パターンが比較的安定して現れる可能性がある。そこで本プロジェクトでは、この個人内の安定性に着目し、少数電極（8 チャンネル）という制約下においても、意味のある視覚情報が抽出可能であるかを検証することを目的とした。

また、脳波には試行ごとのばらつきや計測環境の影響によるノイズが含まれるという困難点がある。これに対して本プロジェクトでは、時間的変化および周波数帯ごとの活動を含む特徴表現と深層学習を組み合わせることで、信号中に内在する構造的なパターンを学習的に抽出できると考えた。近年の表現学習および生成モデルは、不安定で変動の大きいデータからでも意味的な構造を捉える可能性を示しており、これらを EEG 解析に応用することには意義がある。

さらに、本プロジェクトでは補助的な検討として、複数被験者から収集されたデータセットを用い、画像を入力として対応する脳波を人工的に生成するタスクにも取り組んだ。この人工脳波生成は、刺激条件と脳波との対応関係を逆方向から捉える試みであり、視覚情報が脳波の時間構造や周波数特性としてどの程度再現可能であるかを検証するための探索的課題として位置づけられる。これにより、単一被験者・少数電極という主タスクで得られた知見を補完し、視覚刺激と脳波との関係性の一般性について考察することを目的とした。

以上より本プロジェクトは、計測条件を簡素化した環境下において、視覚刺激、特に色刺激に対応する脳波特徴をどの程度捉えられるかを明らかにするとともに、人工脳波生成を通じて、視覚情報と脳波との対応関係を多角的に検討することを本プロジェクトの動機とする。

1.4 プロジェクトの目的・意義

本プロジェクトの主目的は、視覚刺激、と脳波との対応関係を定量的に明らかにすることである。具体的には、赤・青などの色刺激を提示した際に計測された脳波を解析し、視覚刺激に依存した脳波特徴を抽出するとともに、抽出した特徴量を用いて、「被験者が何色を見ていたか」を推定する機械学習モデルを構築し、少数電極・単一被験者という制約条件下での識別可能性を検証する。

これに加えて、本プロジェクトでは、過程で得られた解析結果や学習モデルの挙動を分かりやすく提示するため、脳波から色刺激を推定する処理を実装した Web アプリケーションを開発した。この Web アプリケーションは、成果の可視化およびモデル挙動の理解を支援するためのデモおよび評価支援ツールとして位置づけられ、実用化を直接の目的とするものではない。

一方で、本プロジェクトでは他に、複数被験者から収集されたデータセットを用い、画像情報を入力として対応する脳波を人工的に生成する実験も行った。この人工脳波生成タスクは、色刺激推定とは異なる設定のもとで、視覚情報と脳波との関係性をモデルがどの程度学習可能であるかを調べるための補助的・探索的課題である。特に、脳波が視覚刺激条件からどの程度再現可能であるかを検証することで、視覚刺激と脳波との対応関係について考察することを目的とした。

本プロジェクトの意義は、色刺激という限定された条件下において、刺激に応じた脳波の特徴がどの程度捉えられるかを示した点にある。また、画像から人工的に脳波を生成することで、実際に計測した脳波だけではなく、視覚情報と脳波との関係を別の視点から調べた点にも意義がある。これらの結果は、脳波と視覚の関係理解を深める知見となり、将来的な BCI 技術や視覚支援技術への応用につながる事が期待される。

(※文責: 小林柊斗)

第 2 章 関連研究 (以前に行われた研究や過去に行われたプロジェクト学習)

2.1 本プロジェクトに必要なスキルと知識

本プロジェクトを始めた段階では、脳波に関する基礎知識、機械学習に関する知識、および Arduino を用いた計測制御に関する知識の三点が不足していた。本プロジェクトでは、これらの課題を一つずつ補いながら、脳波計測から解析、モデル構築までを一貫して実施した。まず、脳波に関する知識として、EEG の計測原理や電極配置、サンプリング条件、ならびに瞬目や筋電などのアーティファクトが与える影響について理解を深めた。これにより、計測された脳波をそのまま解析するのではなく、前処理や解析手法の選択が結果に大きく影響することを認識した。次に、信号処理技術として、脳波信号の周波数特性を捉えるために Welch 法を用いたパワースペクトル密度解析を行った。Welch 法により、試行ごとのばらつきや一時的な変動の影響を抑えつつ、周波数帯ごとのエネルギー分布を安定して推定することが可能となった。本プロジェクトでは、この周波数特徴を視覚刺激に対応する特徴量として利用した。さらに、機械学習に関する知識として、抽出した特徴量を用いた分類モデルの構築に取り組んだ。具体的には、特徴量の重要度を解釈しやすい手法としてランダムフォレストを用いるとともに、特徴抽出と分類を同時に行える手法として畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を導入した。これにより、手設計特徴に基づく分類と、学習的に特徴を獲得する手法との比較を行い、それぞれの特性を検討した。また、Arduino に関する知識として、視覚刺激の提示タイミングと脳波計測を同期させるための基礎的な制御を学習した。これにより、刺激条件と計測データの対応関係を明確にし、解析に適したデータ収集環境を構築した。以上のように、本プロジェクトを通じて、脳波計測、Welch 法による信号解析、機械学習・深層学習による分類、および Arduino を用いた計測制御といった技術を統合的に習得した。これにより、視覚刺激と脳波の関係を工学的に分析・検証するための基礎的スキルを獲得することを学習目標として達成した。

2.2 関連性の高い本学の専門科目

本プロジェクトを進めるにあたり、特に関連性の高い専門科目として「データサイエンス基礎」と「機械学習」の 2 科目が挙げられる。これらの科目で学んだ内容は、プロジェクトの各段階において具体的に活用された。まず、「データサイエンス基礎」で習得した知識は、脳波データの前処理および特徴量設計の段階で活用された。具体的には、データの可視化による信号の傾向把握、統計的な視点に基づくばらつきの確認、ならびに教師あり・教師なし学習の基本的な考え方をを用いた解析方針の検討に役立った。これにより、脳波データをそのまま機械学習に入力するのではなく、データの性質を理解した上で解析手法を選択する姿勢を身につけることができた。一方、「機械学習」で学んだ内容は、分類モデルの構築および性能評価の段階で直接的に活用された。ランダムフォレストによる分類では、特徴量の重要度を確認しながらモデルの挙動を解釈する際に役立ち、CNN を用いた解析では、過学習の回避やハイパーパラメータ調整の考え方を実装に反映した。これにより、モデル性能を比較・検討しながら解析を進めることが可能となった。一方で、本プロ

Make Brain Project

プロジェクトに強く関連する分野として、脳波の神経系に関する基礎知識およびマイコン制御に関する知識が挙げられるが、これらについては体系的に学ぶ機会が当時は十分に整っていなかった。脳波の神経系に関する内容については、「ブレインサイエンス」が本年度より一年次向け科目として新たに開講された科目であり、本プロジェクト実施時点では履修機会がなかった。そのため、視覚情報処理や脳波の発生機構に関する基礎知識については、関連文献の調査を通じて補完しながらプロジェクトを進めた。また、Arduino を用いた刺激提示および計測同期に関しては、「情報処理演習」においてマイコン制御を扱う科目内容と高い関連性があったが、実装段階では講義内容を先取りする形で試行錯誤を行った。この過程を通じて、入出力制御やタイミング管理といったマイコン制御の基礎を実践的に習得することができた。本プロジェクトは、既存の専門科目で学んだ知識を応用するだけでなく、新設科目や未履修分野に対応する知識を自主的に補完しながら進めた。この経験は、複数分野にまたがる研究テーマに取り組む上で必要となる主体的な学習姿勢を養う機会となった。

(※文責: 門脇大造)

第3章 プロジェクト学習の目標

3.1 脳波測定班

本班の目的は、人が特定の色刺激（赤・青・緑など）を見た際に計測される脳波を解析し、提示された色刺激を脳波から識別可能であるかを検証することである。具体的には、脳波信号から色刺激に対応する特徴を抽出し、機械学習モデルによって「どの色を見ていたか」を推定する人工知能の構築を目標とした。本班では、被験者を1名に限定して実験を行った。この点は結果の一般化という観点では明確な制約であるが、個人差による変動を排除し、同一被験者内における刺激依存の脳波変化を安定して分析することを優先した設計である。本班では、被験者内での一貫性に着目することで、限られた計測条件下においても有効な特徴抽出およびモデル学習が可能かを検証対象とした。脳波データに対しては、まず前処理として Butterworth フィルタによる不要周波数成分の除去を行い、続いて Welch 法を用いたパワースペクトル密度推定により周波数帯ごとの特徴量を抽出した。これらの処理により、視覚刺激に依存した周波数特性を安定して表現することを目指した。分類モデルとしては、ランダムフォレストと CNN の2種類を用いた。ランダムフォレストは、少量データに対しても安定した性能が期待でき、特徴量の重要度を通じてモデルの判断根拠を解釈しやすい点から採用した。一方、CNN は、入力特徴量から識別に有効なパターンを学習的に獲得できる点に着目し、手設計特徴に基づく手法との比較対象として導入した。本班では、分類精度およびモデルの安定性を主な評価指標とし、両モデルの性能を比較した。

(※文責: 薄井優太)

3.2 人工脳波生成班

本班の目的は、視覚刺激として提示される画像を入力とし、それに対応する脳波を人工的に生成することで、視覚情報と脳波との関係を明らかにすることである。具体的には、ImageNet 画像から深層学習モデルを用いて視覚的特徴を抽出し、それに基づいて多チャンネルの時系列脳波データを予測・生成する人工知能モデルの構築を目標とした [6][7]。本班では、複数被験者から計測された脳波データを用いて学習を行った。被験者間には脳波の振幅やノイズなどに個人差が存在するが、本プロジェクトではそれらを統合的に扱うことで、特定の被験者に依存しない学習を目指した。この設計により、視覚刺激に共通して現れる脳波の特徴がモデルによってどの程度捉えられるかを検討した。脳波データに対しては、サンプルごとに正規化を行い、チャンネル数および時間長を統一した上で学習に用いた。これにより、計測条件や試行間のばらつきの影響を抑え、脳波の時系列的な変化に着目した解析が可能となるよう配慮した。一方、画像データについては、学習時にはデータ拡張を行い、評価時には入力条件を固定することで、モデルの汎化性能と評価の再現性の両立を図った。モデル構成としては、画像特徴抽出部と脳波生成部からなる深層ニューラルネットワークを用いた。画像特徴抽出には ImageNet で事前学習された畳み込みニューラルネットワークを使用し、高次の視覚特徴を抽出した [6][7]。得られた特徴をもとに、脳波を生成することで、画像と脳波との対応関係を学習させた。

(※文責: 逸見千佐)

第4章 手法

4.1 脳波測定および脳波解析の手順

本班では、人が色刺激を見た際に計測される脳波を用いて、被験者が「どの色を見ていたか」を推定する人工知能の構築を目的とした。この目的を達成するため、本班では脳波データの測定、解析、モデルの作成、および Web アプリケーション開発といった各工程において、複数の手法や条件を検討・比較しながら検証を進めた。これにより、モデル精度の向上を図り、目的の達成を目指した。

脳波信号には、刺激に由来する成分だけでなく、瞬目や筋電、計測環境の揺らぎなど、視覚刺激とは直接関係しない成分が多く含まれる。さらに、被験者ごとの生理的特性の違いや、少数電極による計測制約により、一度の測定・解析のみで安定した推定モデルを構築することは困難であった。特に本班では、被験者を一人に限定しているため、データ量の不足や測定条件の違いが結果に直接影響しやすいという課題があった。

これらの問題に対処するため、本班では、特定の解析手法や学習モデルを固定して適用するのではなく、実測した脳波データの特性に応じて、測定条件、信号処理方法、特徴量設計、および学習モデルの構成を段階的に見直す方針を採用した。具体的には、測定条件やノイズ処理手法を調整しながら特徴抽出を行い、その結果を機械学習モデルの設計やパラメータ設定に反映させることで、精度向上につながる要因を検討した。

また、Web アプリケーション開発を工程に含めた理由は、推定結果やモデルの挙動を可視化し、解析結果を直感的に確認できる環境を整えることで、どの手法や条件が有効であったかを判断しやすくするためである。この可視化は、精度評価だけでなく、各工程で行った検討内容を振り返り、次の改善方針を検討するための重要な判断材料として機能した。

本章では、以上の考え方にに基づき、本班で実施した手順を以下の順に説明する。まず、色刺激提示下における脳波の測定方法について述べる。次に、測定データに対する信号処理および特徴抽出の手法を示す。続いて、解析結果を用いた Web アプリケーションの開発について説明し、最後に、モデル精度向上を目的として行った各工程での検討内容について述べる。

4.1.1 脳波の測定

被験者を一人に限定し、赤・青・緑に加えて黄色や紫など、複数の色刺激を提示した際の脳波を測定した。測定には 8 チャンネルの脳波計測システム (AvaterEEG(図 4.1)) を使用し、視覚領域である後頭部 (P3, P2, P4 など) を中心に電極を配置した。サンプリング周波数は 500Hz であり、具体的には、10-20 法を参考に図 4.2 のように配置した [8]。刺激はモニタ上に単色画面として提示し、休憩 (黒) 3 秒、計測 (提示色) 5 秒を 10 回繰り返す条件で統一した。これにより、脳波の変化を刺激条件の違いではなく、色そのものの違いによるものとして比較できるようにした。また、測定環境は室内テント (KSTB25HBK)、机、椅子、ノート PC、AvaterEEG を使用し、座った状態で暗く静かな環境で行った。

また、本班では視覚刺激として単色刺激を用いた。これは、刺激条件を単純化することで、色以外の要因 (形状、輝度変化、動きなど) による脳波変動を最小限に抑え、特定の色刺激に起因する

Make Brain Project

脳波変化を明確に捉えることを目的としたためである。単色刺激を用いることで、周波数帯に着目した解析結果と刺激条件との対応関係を解釈しやすくなり、脳波特徴抽出および分類モデルの検証を行う上で適切な条件設定となる。



図 4.1 AvaterEEG

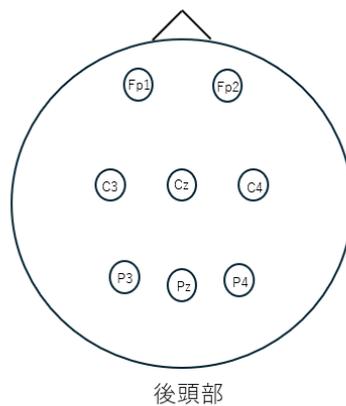


図 4.2 本実験におけるチャンネルの配置

4.1.2 測定データの解析

本班では、脳波信号に含まれる視覚刺激と直接関係しない成分の影響を抑えるため、前処理として特定の周波数帯のみを抽出した。これは、脳波に含まれる低周波のドリフト成分や高周波ノイズが、解析結果に大きな影響を与えるためである。

この前処理を実現するため、測定によって得られた脳波データに対し、Python を用いて Butterworth フィルタを適用し、低周波のドリフト成分および高周波ノイズを除去した。これによ

り、視覚刺激に関連する脳波成分を強調した信号を得た。

次に、連続的に計測された脳波信号を短い時間区間に分割し、各区間に対してフーリエ変換を適用した。フーリエ変換は、時間的に変化する信号を周波数成分の分布として表現する手法であり、脳波信号を周波数帯ごとの特徴として捉えることを可能にする。この処理により、刺激条件に対応した脳波の周波数成分を安定した特徴量として抽出した。次に、脳波の周波数特性を定量的に評価するため、パワースペクトル密度 (Power Spectral Density: PSD) を算出した。PSD の推定には Welch 法を用いた。Welch 法は、信号を複数の短い区間に分割し、各区間に対してスペクトル解析を行った後、その結果を平均化する手法であり、試行ごとのばらつきや一時的なノイズの影響を抑えた安定した周波数特性の推定が可能である。

本班では、Welch 法によって推定したパワースペクトル密度 (PSD) をもとに、各電極チャンネルごとに周波数帯別のパワーを算出し、これらの特徴量として用いた。具体的には、8 チャンネルそれぞれについて、 θ 波 (4–8 Hz)、 α 波 (8–13 Hz)、 β 波 (13–30 Hz)、 γ 波 (30–45 Hz) の 4 帯域における平均パワーを求めた。

これにより、1 チャンネルあたり 4 次元、合計で $8 \times 4 = 32$ 次元の特徴ベクトルを構成した。各次元は「特定チャンネルにおける特定周波数帯のパワー」を表しており、空間的 (電極配置) および周波数的な情報を同時に保持する特徴表現となっている。

この 32 次元特徴量は、電極数が限られた条件下においても、各周波数帯の活動強度を安定して比較できるよう設計したものであり、過度に高次元化することによる過学習を抑制しつつ、色刺激に依存した脳波特性を捉えることを目的としている。このうち、 δ 波帯は、電極のずれや姿勢変化などに起因する低周波ドリフト (slow drift) の影響を受けやすく、脳活動由来の成分との区別が困難になることが指摘されている。[9] 実際に、脳波解析ではこのような低周波ドリフトを抑制するため、高域遮断フィルタやデトレンド処理が一般的に用いられている。特に、本班のように少数電極かつ単一被験者の条件下では、低周波帯域におけるノイズの影響が解析結果に与える影響が大きくなる可能性がある。そのため、本班では解析の信頼性を優先し、 δ 波帯を特徴量から除外し、 θ 波以上の周波数帯に基づく特徴量を用いてモデルを構築した。



図 4.3 手順イメージ図

4.1.3 解析結果を用いた Web アプリケーション開発

解析によって構築した機械学習モデルを用い、測定済みの脳波データを入力することで色刺激（赤・青）を判別できる Web アプリケーションを開発した。本 Web アプリケーションは、本場で構築したモデルの動作確認および評価を支援するための実験補助ツールとして位置づけられる。

本 Web アプリでは、ブラウザ上で CSV 形式の脳波データをアップロードすることで、サーバ側において前処理、特徴抽出、および機械学習モデルによる分類を実行し、その結果をブラウザ上に表示する。推論処理はすべてバックエンド側で実行されており、フロントエンドは入力操作および結果表示を担う。開発には Python を用い、バックエンドには Flask、フロントエンドには HTML/CSS および JavaScript を使用した。機械学習モデルの実装および推論処理には、scikit-learn および TensorFlow を利用した。

本 Web アプリケーションの評価は、主に分類結果の正確性および処理の即時性の観点から行った。具体的には、既に正解ラベルが分かっている脳波データを入力し、判定結果が正解と一致するかを確認するとともに、入力から結果表示までの処理時間が実験補助として十分に短いことを確認した。

さらに、Web アプリケーションを用いた試験運用を通じて、誤分類が生じた条件や傾向を分析し、その結果を特徴量設計や学習データの見直しに反映させた。このように、本 Web アプリケーションは単なる成果物としてではなく、モデル改良のためのフィードバックループを構成する重要な要素として機能した。

4.1.4 精度向上のためのモデルの調整

本場では、脳波測定および解析によって得られた特徴量を用い、機械学習モデルの性能向上を目的として様々な検証を行った。初期段階では過学習が起きており、原因はデータ数が少ないためであると考えられる。そのため、データ数を集めることに着目し検証を行った。しかし、過学習は改善されなかった。そのため次に注目した点は、モデルのパラメータである。初めに特徴量の次元数を減らすことを行った。元々、256 次元の特徴量を用いてモデルを構築していた。しかし、今回は電極数が少なかったため特徴量の次元数が多いと細かすぎるため過学習が起きていたと考えた。そこで、今回の脳波計の電極数である 8 チャンネルで δ 波を除いた 4 つの周波数帯のパワーを用いた 32 次元を特徴量としてモデルを構築した。これにより、過学習は改善され精度は 8 割であった。その後、ランダムフォレストの主要なハイパーパラメータである、木の木数、木の深さ、葉の数の三つの最適化をグリッドサーチで行った（図 4.4）。これより、これらのパラメータは、木の木数は 1100 本、木の深さが無制限、葉の数が 8 で精度が最大であり、87.3%であった。ここで、木の深さを無制限とした設定は、分割条件を満たす限り決定木を成長させるものであり、過学習を抑制する役割はランダムフォレストのアンサンブル構造および葉ノード数の制約によって担保されている。

```

n= 700, depth=None, leaf= 4 → acc=0.868
n= 700, depth=None, leaf= 8 → acc=0.868
n= 800, depth= 3, leaf= 1 → acc=0.802
n= 800, depth= 3, leaf= 4 → acc=0.802
n= 800, depth= 3, leaf= 8 → acc=0.801
n= 800, depth= 5, leaf= 1 → acc=0.832
n= 800, depth= 5, leaf= 4 → acc=0.834
n= 800, depth= 5, leaf= 8 → acc=0.833
n= 800, depth= 10, leaf= 1 → acc=0.861
n= 800, depth= 10, leaf= 4 → acc=0.859
n= 800, depth= 10, leaf= 8 → acc=0.865
n= 800, depth=None, leaf= 1 → acc=0.868
n= 800, depth=None, leaf= 4 → acc=0.866
n= 800, depth=None, leaf= 8 → acc=0.868

```

図 4.4 ハイパーパラメータの最適化（グリッドサーチ）の一部抜粋

(※文責: 千葉皓仁)

4.2 人工脳波の作成手順

本章では、視覚刺激に対応する人工脳波を生成するために用いたデータセット、モデル構成、および評価タスクについて記述する。本班では、画像を入力として脳波を生成し、その妥当性を量的および定性的に検証する一連の実験手順を設計した。

4.2.1 データセット

本班では、画像刺激と脳波の対応関係を学習するため、ImageNet 画像とそれらに対応する EEG データを含む公開データセットを用いた [6][7]。各サンプルは、1 枚の画像と、それを被験者が視覚的に観測した際に計測された脳波から構成される。全サンプル数は 1995 枚であり、80% を訓練用、残りの 20% をテスト用として使用した。脳波は複数チャンネルからなる時系列データであり、被験者ごとの差異を排除するため、6 人の被験者が測定した脳波データを使用した。また、全ての脳波データは、チャンネル数 128、時間長 500 に統一した。

画像データについては、学習用と評価用で異なる前処理を行った。学習時には、画像の一部をランダムに切り取ったり左右反転したりするデータ拡張を行うことで、画像の位置や大きさの違いに影響されにくい特徴を学習させた。これにより、画像と脳波の対応関係をより安定して学習できるようにした。一方、評価時には、画像の中央部分を用いるなど前処理を固定することで、入力条件をそろえ、結果を公平かつ再現性のある形で評価できるようにした。

4.2.2 人工脳波生成モデル

人工脳波生成に用いたモデルを図 4.5 に示す。まず、入力画像から視覚特徴を抽出するために、ImageNet で事前学習された ResNet50 を用いた [10]。ResNet50 は画像認識タスクにおいて高い汎化性能を示すことが知られており、視覚刺激に含まれる特徴を安定して抽出できるため採用し

た。抽出された高次視覚特徴は全結合層を通して低次元の潜在表現へと変換される。

次に、この潜在表現を時間方向に展開することで、脳波の基盤となる特徴マップを生成した。この時間方向展開は、静的な画像特徴から時系列信号である脳波を生成するために必要な処理であり、「各時刻に共通する視覚的意味表現」を基盤として、時間発展を学習させる設計となっている。さらに、各時間ステップに対して位置埋め込みを加えることで、時刻間の区別を明示的に与え、時間的変化や位相構造をモデルが学習可能とした。最後に、Conv1D を用いて、128 チャンネルの脳波を出力した。Conv1D は、時間軸に沿った局所的な依存関係を捉えることが可能であり、脳波に特有の時間的連続性や周波数構造を効率的に表現できる。この構成により、各チャンネル間で共有される時間的パターンを保持しつつ、実際の脳波に近づけることを目指した。

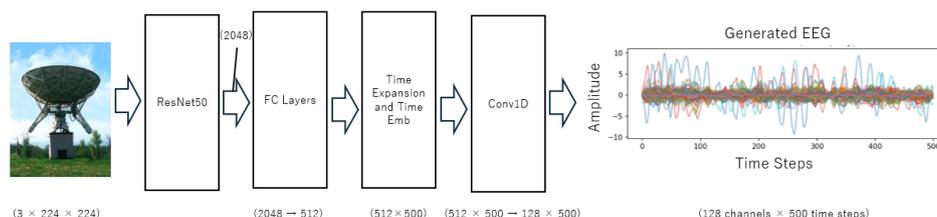


図 4.5 人工脳波生成モデル

4.2.3 学習手法および損失関数

本班では、入力画像から生成された人工脳波と、対応する実際の脳波との誤差を最小化する教師あり学習を行った。学習には、振幅誤差、波形形状、および周波数特性の一致を同時に考慮するため、以下の複合損失関数を用いた：

$$\mathcal{L} = \mathcal{L}_{\text{mse}} + \lambda_{\text{cos}} \mathcal{L}_{\text{cos}} + \lambda_{\text{freq}} \mathcal{L}_{\text{freq}}, \quad (4.1)$$

ここで、本班では $\lambda_{\text{cos}} = 0.3$, $\lambda_{\text{freq}} = 0.2$ と設定した。各損失項の重みは、学習の安定性と生成脳波の質を考慮し、経験的に設定した。

まず、 \mathcal{L}_{mse} は生成脳波 $\hat{\mathbf{E}} \in R^{C \times T}$ と実脳波 $\mathbf{E} \in R^{C \times T}$ の間の平均二乗誤差として定義される：

$$\mathcal{L}_{\text{mse}} = \frac{1}{CT} \sum_{c=1}^C \sum_{t=1}^T \left(\hat{E}_{c,t} - E_{c,t} \right)^2. \quad (4.2)$$

次に、 \mathcal{L}_{cos} は、各チャンネルにおける時間方向の波形ベクトル間のコサイン類似度に基づく損失であり、以下のように定義する：

$$\mathcal{L}_{\text{cos}} = 1 - \frac{1}{C} \sum_{c=1}^C \frac{\hat{\mathbf{E}}_c \cdot \mathbf{E}_c}{\|\hat{\mathbf{E}}_c\| \|\mathbf{E}_c\|}, \quad (4.3)$$

ここで $\hat{\mathbf{E}}_c, \mathbf{E}_c \in R^T$ はチャンネル c における時間波形ベクトルを表す。

さらに、 $\mathcal{L}_{\text{freq}}$ は、生成脳波および実脳波に対して時間方向に高速フーリエ変換 (FFT) を適用し、その振幅スペクトル間の平均二乗誤差として定義する：

$$\mathcal{L}_{\text{freq}} = \frac{1}{C} \sum_{c=1}^C \left\| \left| \mathcal{F}(\hat{\mathbf{E}}_c) \right| - \left| \mathcal{F}(\mathbf{E}_c) \right| \right\|_2^2, \quad (4.4)$$

ここで $\mathcal{F}(\cdot)$ は高速フーリエ変換を表す。

この複合損失関数により、振幅の一致だけでなく、波形の形状的類似性および周波数特性の整合性を同時に考慮した学習を行った。

4.2.4 評価タスク

本班では、入力画像から生成された人工脳波と、全データセット内の実際の脳波との類似度に基づく検索タスクを実施した。具体的には、生成された人工脳波と各実際の脳波との平均二乗誤差を計算し、最も誤差が小さい脳波を検索した。このとき、入力画像に対応する脳波と同じラベル（船、パラボラアンテナなど）の場合を「正解」と定義した。検索タスクは、無作為に抽出した 100 サンプルの入力画像に対して実行した。100 サンプルという設定は、計算コストを抑えつつ、モデルの生成傾向を統計的に把握するための評価数として設定した。

さらに定性評価として、検索によって得られた最も近い実際の脳波に対応する画像と、入力画像とを並列に可視化し、視覚的な対応関係を確認した。これにより、人工脳波が実際の脳波に近い形を再現しているかを直感的に評価した。

4.2.5 実験環境

本プロジェクトの実験は Ubuntu 24.04.2 LTS 上で実施した。実行環境には Python 3.8.5, PyTorch 1.12.1 (CUDA 11.6) を使用した。主に用いたライブラリとして NumPy (1.23.5), SciPy (1.10.1), scikit-learn (1.1.3), pandas (2.0.3), pytorch-lightning (1.6.5), transformers (4.46.3) が挙げられる。

また、NVIDIA Tesla V100 (PCIe, 32GB) を利用し、学習および推論処理を GPU 上で行った。Image → EEG 変換モデルは ResNet50 を基盤とし、総パラメータ数は約 29M である [10]。入力画像は 224×224 RGB, 出力 EEG は 128 チャンネル \times 500 samples とした。学習は batch size 16, epoch 10, optimizer に Adam ($lr=5 \times 10^{-5}$) を用いて実施した。さらに、再現性確保のため、Python標準ライブラリ, NumPy, PyTorchおよびCUDAに対し乱数シードを固定した。また、PyTorchのCuDNNバックエンドに対してdeterministic=Trueを設定し、演算の非決定性を排除した。依存パッケージ一覧については、本報告書の最後に記載した。

(※文責: 西村颯真)

第5章 結果

本プロジェクトでは、視覚刺激に対して計測される脳波から、被験者が知覚していた情報を推定することを目標とした。具体的には、色刺激提示時の実際に測った脳波を用いた機械学習による分類と、画像刺激から対応する脳波を生成する人工脳波生成モデルの構築・評価を行った。これらを通して、視覚刺激と脳波との対応関係を検証した。

5.1 脳波測定班の結果

まず、赤・青・緑など複数の色刺激をそれぞれ提示した際の脳活動を、被験者一人を対象として脳波測定器により取得した。しかし、赤および青以外の色刺激については、計測時期や計測回数が異なっており、解析の結果、赤・青とは異なる特徴量が観測されたものの、それらの差異が色刺激そのものに起因するものか、あるいは計測条件やその他の要因によるものかを明確に判別することができなかった。そのため、本班では解析条件を統一する観点や時間が限られていることから、赤および青の脳波データのみを用いて判別モデルを構築した。取得した脳波データに対して Python を用いた解析を行い、はじめにフーリエ変換を適用することで信号を構成する周波数成分を抽出し、脳波の周期的特徴の把握を試みた。

さらに、計測した脳波データに Welch 法を適用して周波数帯域ごとのパワースペクトル密度を推定し、得られた特徴量を用いて機械学習による分類を行った。分類モデルにはランダムフォレスト (Random Forest) を採用した。その結果、学習済みモデルに脳波データを入力することで、被験者に提示された色を交差検証で 8 割を超える精度で推定可能であることが示された。

また、特徴量重要度を算出したところ、 γ 波帯域の重要度が最も高く、他の周波数帯域を上回る結果となった。このことから、本班で扱った課題においては、 γ 波成分が分類性能に強く寄与しており、視覚刺激処理に関連する高周波活動が重要である可能性が示唆された。

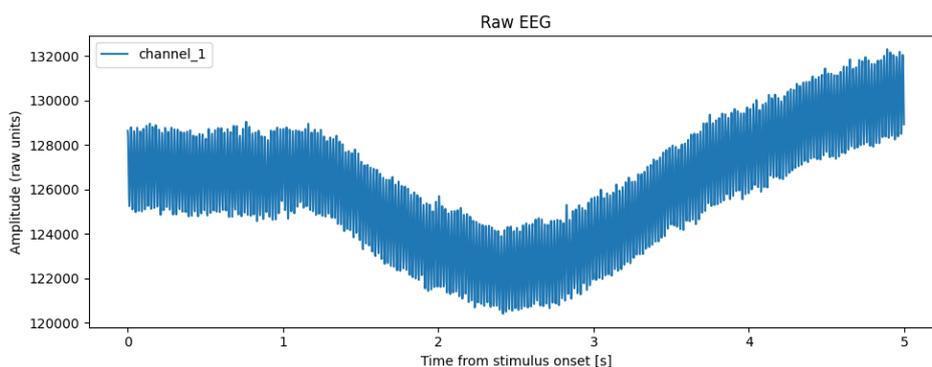


図 5.1 青色を見たときの生の脳波データの一部抜粋

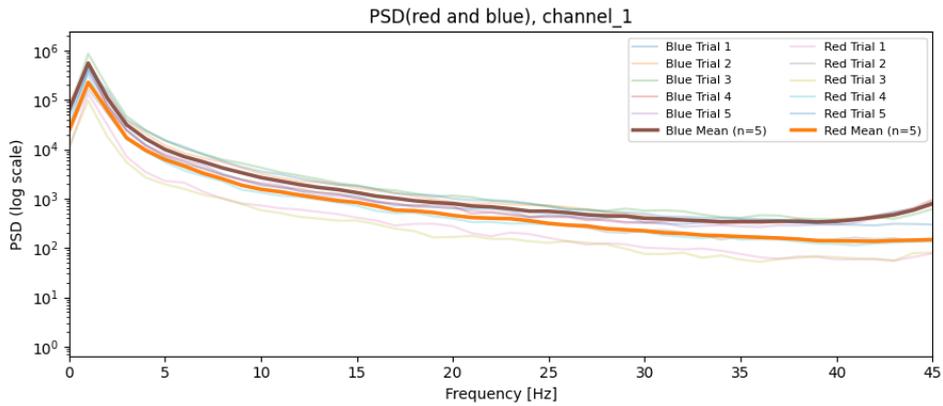


図 5.2 青と赤を見たときの脳波のパワースペクトル密度

feature	importance
ch5:gamma	0.0878477
ch3:gamma	0.0800299
ch6:gamma	0.0686341
ch7:gamma	0.0650206
ch2:delta	0.0619581
ch8:gamma	0.0463579
ch1:gamma	0.0457918
ch2:gamma	0.0418744
ch4:gamma	0.0335393
ch1:delta	0.0326816
ch6:beta	0.0274377

図 5.3 機械学習モデルにおける特徴量重要度の上位 11 個

(※文責: 小林柊斗)

5.2 人工脳波生成班の結果

5.2.1 脳波生成・検索タスク

本班では、画像を入力して人工脳波を生成し、生成された脳波が入力刺激に関する情報をどの程度保持しているかを、脳波検索タスクによって評価した。

モデルは学習過程において、訓練損失および検証損失はいずれも減少傾向を示したが、エポック数が 10 以降ではほとんど減少せず、過学習傾向が観測された (図 5.4)。

次に、生成された人工脳波と、テストデータに含まれるすべての実際の脳波との間の平均二乗誤差を計算し、誤差が最小となる脳波を検索する脳波検索タスクを実施した。検索を 100 回行った結果、生成元の画像に対応する実際の脳波人工脳波のラベルが一致した回数は 2 回であり、正解率は 2% であった。

これらの結果から、画像と脳波を直接対応付ける手法では、入力刺激の違いを十分に反映した脳波を生成することが難しいことが分かった。

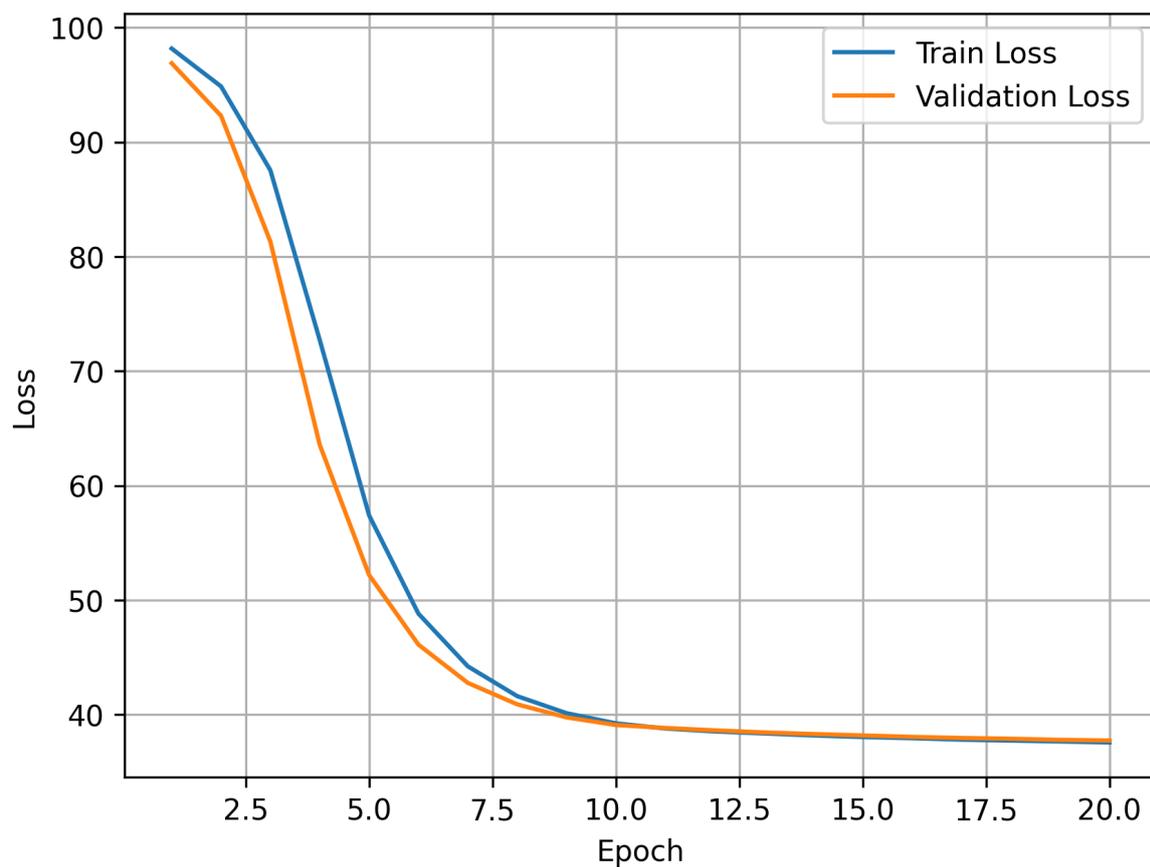


図 5.4 学習過程における訓練損失および検証損失の推移

5.2.2 脳波の可視化

生成された人工脳波の特性を定性的に評価するため、入力画像、対応する実際の脳波、およびモデルによって生成された人工脳波を可視化した。さらに、人工脳波と最も類似すると判定された実際の脳波との比較を行った（図 5.5）。

可視化結果から、生成された人工脳波は、振幅変動や時間的構造といった脳波としての基本的な形状を再現していることが確認された。一方で、入力画像に対応する実際の脳波と人工脳波の間には差異が見られ、視覚刺激に依存した特徴が十分に反映されていない可能性が示唆された。

Make Brain Project

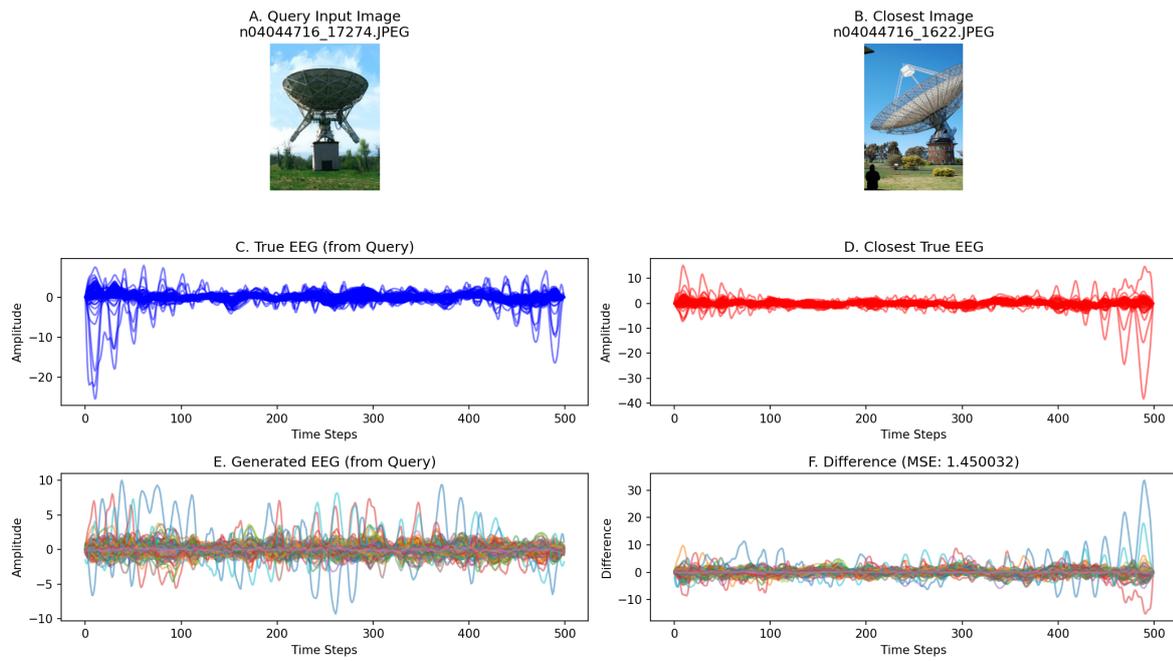


図 5.5 A: 入力画像, B: 予測された画像, C: 入力画像の脳波, D: 人工脳波に近い脳波, E: 人工脳波, F:D と E の誤差

(※文責: 逸見千佐)

第6章 考察

6.1 脳波測定班

6.1.1 得られた知見

第5章でも述べたとおり、本研究における色判別では、 γ 波が最も高い寄与を示した。 γ 波は、注意や認知処理を伴う課題条件下において活動の変化が観測されることが報告されている [11]。そのため、本研究においても、視覚刺激に対する認知処理の過程が特徴量として反映された可能性が考えられる。また、 γ 波は脳内ネットワーク間の同期や情報統合に関与するとされており、本課題ではこれらの機能が結果として強く表れたと解釈できる。

さらに、本研究では、被験者を一人に限定した場合であっても、十分なデータ量を確保することで、機械学習により提示されている色の推定が可能であることが示された。一方で、脳波には個人差が存在するため、本研究で得られたモデルを他の被験者に適用した場合には、判別精度が変化する可能性がある。したがって、本研究の知見は被験者依存の条件下で得られた結果である点に留意する必要がある。

6.1.2 今後の展望

今後は提示する視覚刺激を画像などの、より複雑なものを推定可能なモデルを製作することで、視覚刺激と脳波との関係性をより明確に理解していきたい。また、今回の実験では被験者を一人にし測定や解析を行ってきたが、複数人の脳波を測定し誰の脳波データでも推定可能なモデルをつくることも視野に入れていきたい。

(※文責: 門脇大造)

6.2 人工脳波生成班

6.2.1 得られた知見

本実験の結果、画像と脳波の対応関係を直接学習する手法では、生成された人工脳波と実測脳波との一致度は低く、正確な再現が難しいことが明らかになった。その要因として、脳波は計測ノイズや被験者の注意状態の影響を受けやすく、同一刺激であっても波形にばらつきが生じること、また、脳波は時間的に変化する信号であり、静的な画像との対応が必ずしも一対一にならないことが考えられる。

一方で、生成された人工脳波を用いた脳波検索タスクでは、ラベルは一致しなかったものの、平均二乗誤差に基づき、形状が類似した実際の脳波が選択される傾向が確認された。この結果は、生成された人工脳波が視覚刺激固有の情報を十分に保持しているとは言えないものの、脳波としての基本的な特徴を再現できていることを示している。

6.2.2 今後の展望

今後の課題として、まず、データ数およびデータ多様性の不足が、刺激固有の識別的情報の学習を困難にした可能性が挙げられる。脳波は個人差や計測条件の影響を強く受けるため、試行数や被験者数が十分でない場合、刺激に依存した情報が平均化されやすい。このため、データ数の増加や被験者の多様化により、モデルの汎化性能を向上させることが、刺激識別性能の改善につながると考えられる。

次に、本班では汎用的な深層生成モデルを用いたが、静的な視覚刺激から時系列信号である脳波を生成する課題に対して、必ずしも最適な構成とは言えない。脳波は長期的な時間依存性を持つ信号であるため、拡散型時系列生成モデルや Transformer 系の時系列モデルなど、時間構造の表現に特化した手法を導入することで、刺激に依存したダイナミクスをより適切に捉えられる可能性がある。

さらに、脳波はノイズの影響を強く受けるため、前処理や特徴抽出の方法も改善の余地がある。ノイズを低減することで、刺激ごとの差異をより明確に抽出でき、識別的情報の保持に寄与すると期待される。

(※文責: 逸見千佐)

参考文献

- [1] H. Pan, Z. Li, Y. Fu, X. Qin, and J. Hu, “Reconstructing Visual Stimulus Images from EEG Signals Based on Deep Visual Representation Model,” *arXiv preprint arXiv:2403.06532*, 2024.
- [2] M. Choi and H. Ishikawa, “BrainDecoder: Style-Based Visual Decoding of EEG Signals,” *arXiv preprint arXiv:2409.05279*, 2024.
- [3] Y. Yao, W. De Swaef, S. Geirnaert, and A. Bertrand, “EEG-Based Decoding of Selective Visual Attention in Superimposed Videos,” *IEEE Journal of Biomedical and Health Informatics*, vol. 29, no. 10, pp. 7248–7261, 2025.
- [4] Y. Bai, X. Wang, Y.-P. Cao, Y. Ge, C. Yuan, and Y. Shan, “DreamDiffusion: Generating High-Quality Images from Brain EEG Signals,” *arXiv preprint arXiv:2306.16934*, 2023.
- [5] P. Singh, D. Dalal, G. Vashishtha, K. Miyapuram, and S. Raman, “Learning Robust Deep Visual Representations from EEG Brain Recordings,” in *Proc. IEEE/CVF Winter Conf. on Applications of Computer Vision (WACV)*, pp. 7538–7547, 2024.
- [6] S. Palazzo, C. Spampinato, I. Kavasidis, D. Giordano, J. Schmidt, and M. Shah, “Decoding Brain Representations by Multimodal Learning of Neural Activity and Visual Features,” *IEEE Trans. Pattern Analysis and Machine Intelligence (TPAMI)*, vol. 42, no. 9, pp. 2391–2404, 2020.
- [7] C. Spampinato, S. Palazzo, I. Kavasidis, D. Giordano, N. Souly, and M. Shah, “Deep Learning Human Mind for Automated Visual Classification,” in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, pp. 6809–6817, 2017.
- [8] H. H. Jasper, “Report of the committee on methods of clinical examination in electroencephalography,” *Electroencephalography and Clinical Neurophysiology*, vol. 10, no. 2, pp. 370–375, 1958.
- [9] A. de Cheveigné and D. Arzounian, “Robust detrending, rereferencing, outlier detection, and inpainting for multichannel data,” *NeuroImage*, vol. 172, pp. 903–912, 2018.
- [10] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016.
- [11] P. Fries, “Neuronal Gamma-Band Synchronization as a Fundamental Process in Cortical Computation,” *Trends in Cognitive Sciences*, vol. 13, no. 9, pp. 399–406, 2009.

依存パッケージ一覧

absl-py==2.3.1 aiohappyeyeballs==2.4.4 aiohttp==3.10.11 aiosignal==1.3.1 antlr4-python3-runtime==4.8 async-timeout==5.0.1 attrs==25.3.0 cachetools==5.5.2 certifi==2025.7.14 charset-normalizer==3.4.2 click==8.1.8 contourpy==1.1.1 cyclerc==0.12.1 docker-pycreds==0.4.0 dreamdiffusion==0.0.1 einops==0.3.0 filelock==3.16.1 fonttools==4.57.0 frozenlist==1.5.0 fsspec==2025.3.0 gitdb==4.0.12 gitpython==3.1.44 google-auth==2.40.3 google-auth-oauthlib==1.0.0 grpcio==1.70.0 hf-xet==1.1.5 huggingface-hub==0.33.4 idna==3.10 imageio==2.35.1 importlib-metadata==8.5.0 importlib-resources==6.4.5 joblib==1.1.0 kiwisolver==1.4.7 kornia==0.7.3 kornia-rs==0.1.9 lazy-loader==0.4 lpips==0.1.4 markdown==3.7 markupsafe==2.1.5 matplotlib==3.7.5 natsort==8.4.0 networkx==3.1 numexpr==2.8.4 numpy==1.23.5 oauthlib==3.3.1 omegaconf==2.1.1 packaging==25.0 pandas==2.0.3 pathtools==0.1.2 pillow==9.0.1 pip==24.0 promise==2.3 propcache==0.2.0 protobuf==3.20.1 psutil==7.0.0 pyasn1==0.6.1 pyasn1-modules==0.4.2 pydeprecate==0.3.2 pyparsing==3.1.4 python-dateutil==2.9.0post0 python-tzdata==2025.2 pytorch-lightning==1.6.5 pytz==2024.1 pywavelets==1.4.1 pyyaml==6.0.2 regex==2024.11.6 requests==2.32.4 requests-oauthlib==2.0.0 rsa==4.9.1 safetensors==0.5.3 scikit-image==0.21.0 scikit-learn==1.1.3 scipy==1.10.1 sentry-sdk==2.33.0 setproctitle==1.3.6 setuptools==75.1.0 shortuuid==1.0.13 smmap==5.0.2 tensorboard==2.14.0 tensorboard-data-server==0.7.2 threadpoolctl==3.5.0 tifffile==2023.7.10 timm==0.5.4 tokenizers==0.20.3 torch==1.12.1+cu116 torch-fidelity==0.3.0 torchmetrics==0.9.2 torchvision==0.13.1+cu116 tqdm==4.64.0 transformers==4.46.3 typing-extensions==4.13.2 urllib3==2.2.3 wandb==0.12.21 werkzeug==3.0.6 wheel==0.44.0 yarl==1.15.2 zipp==3.20.2