

# ニューラルネットワークによる単一試行脳波信号を用いた 音声文中の統語誤り検出

本村駿乃介<sup>†</sup> 田中宏季<sup>†</sup> 中村哲<sup>†</sup>

<sup>†</sup> 奈良先端科学技術大学院大学 情報科学研究科  
〒630-0101 奈良県生駒市高山町 8916-5

E-mail: †{motomura.shunnosuke.mj1,hiroki-tan,s-nakamura}@is.naist.jp

あらまし 本研究では、文中の統語誤りを検出するため、脳波信号を用いたニューラルネットワークモデルによる手法を提案する。文の理解において統語処理が脳波信号に反映することにより、統語誤りを含んだ文に対して P600 と呼ばれる事象関連電位が確認されている。しかし、脳波信号中の統語処理を反映した信号の SN 比は小さく、単一試行の脳波で統語誤りの検出について報告は少ない。我々は単一試行の脳波信号から音声文中の統語誤り単語を含む文を検出における、Stacked autoencoder (SAE) と Long-short term memory (LSTM) を用いた手法を評価した。18 名の実験協力者が一部の文に統語誤り単語を含む文を音声で聞き、その文の正誤をキーボードのボタンにより応答を行い、その聴取時の脳波信号を収録した。統語誤りに対する脳波信号の分類について SAE と LSTM を評価するため、既存手法である Support vector machine (SVM) と比較を行った。実験の結果、LSTM による手法が 61.3% の分類精度で、SAE の 58.3% と SVM の 58.4% と比較してより良い精度を得られることを示した。

キーワード 脳波 (EEG), 事象関連電位 (ERPs), P600, Stacked Autoencoders, Long-Short Term Memory

## Detection of Syntactic Anomalies in Spoken Sentences from Single-trial EEG Signals with Neural Networks

Shunnosuke MOTOMURA<sup>†</sup>, Hiroki TANAKA<sup>†</sup>, and Satoshi NAKAMURA<sup>†</sup>

<sup>†</sup>

E-mail: †{motomura.shunnosuke.mj1,hiroki-tan,s-nakamura}@is.naist.jp

**Abstract** In this paper we propose a method with neural networks for detecting syntactic anomalies in sentences using electroencephalogram (EEG) signals. To the best of our knowledge, there have been few studies for detecting syntactic anomalies from single-trial EEG signals. Eighteen participants listened to sentences, some of which included syntactically anomalous words, and answered the correctness of the sentences by pressing a button. During this procedure, we recorded EEG signals of the participants. We evaluated Stacked autoencoders (SAE) and Long-short term memory (LSTM) and a baseline model, Support vector machine (SVM), for classifying EEG signals with respect to syntactic anomalies.

**Key words** Electroencephalogram (EEG), event-related potentials (ERPs), P600, Stacked Autoencoders, Long-Short Term Memory

### 1. ま え が き

コミュニケーションにおいて、人間は文中の統語の誤りや違和感を認識することがある。例えば、語学学習者を含む人間同士のコミュニケーションや、言語を介した人間と機械のインタラクションでは、しばしば言語の誤りや違和感を含むことがある。そのような場合に対して、語学学習者や機械の文を作り出

す能力を評価する方法があり、その一つに、人間の評価者が文に対して点数を手で割り当てることで、文を生成したシステムを評価する主観評価法がある。しかし、この評価法では、評価者により点数の割り当て方が異なりやすく、評価に曖昧性を含むため、正確な評価を保証することはできない。

本研究では、自動的に言語中の誤りを検知するための機械学習モデルを提案する。評価者の文中の統語に関する認識につい

て調べる上で、主観評価法では得ることができない客観性を担保するため、我々は脳波信号を用いた。脳波信号は自発的に発生するため、行動測定実験における反応速度などの、認識だけでなく評価者による行動が含まれる指標などとは異なり、恣意的でない、調べたい認識処理に特定の情報を得ることができると考えられる [1]。

脳波は人間の脳の電気的な活動を測る方法であり、脳波計は比較的小型で装着が容易であり、また、信号は高い時間分解能を有している。先行研究により、P600 と呼ばれる事象関連電位 (ERPs) の成分が、文の理解における統語処理を反映していることが示されており、文中に文法の誤りや統語の違和感が含まれている場合に観測されることが知られている [2]。そのため、この P600 成分は、文の統語構造に単語を統合する際にかかる認知負荷を反映していると考えられている。ERP 成分は、脳波信号中の信号雑音比が低いため、複数回試行の脳波を加算平均することにより観測され、一般的に 50 試行や 100 試行ほどの加算平均回数を要する [1]。

一方で、脳波信号を用いたブレイン・コンピュータ・インタフェース (BCI) が、人間同士や人間と機械のコミュニケーションの向上を目的に開発されている。例えば、P300 スペラーと呼ばれる技術では、被験者がマトリクス上に配置された文字に注視することで、脳からの信号だけで文字を入力することを実現した。ERP 成分の一つである P300 は、比較的高い信号雑音比を持っており、BCI の性能評価の指標として用いられることも多い。そのため、単一試行の脳波で、P300 成分の信号を元に分類問題に取り組んだ研究は多い [3], [4]。また、近年の研究では、ニューラルネットワークモデルを用いた脳波の分類についての研究が、高次元で非線形な問題という観点から注目されている。Vareka らは、P300 検知課題において、Stacked autoencoders (SAE) というニューラルネットワークモデルが、69.2% の分類精度で既存手法を上回ったことを報告した [5]。また、Long-short term memory (LSTM) による手法が、脳波信号の分類に有効であったことが示された例もある [6]。しかし、上述の通り、言語の違反に関する脳波の分析には、加算平均による方法が一般的であり、単一試行による方法は脳波の信号雑音比の低さにより難しく、言語に関連した脳波信号の分類を、単一試行で取り組んだ研究は少ない [7]。特に有効性が期待される、ニューラルネットワークモデルによる手法に言語を対象に取り組んだ研究は数少ない。

Tanaka らは、音声文中の統語的と意味的な違反について、単一試行の脳波信号の分類に取り組み、SVM、ランダムフォレスト、多層パーセプトロンによる手法の性能を評価した [8]。特徴ベクトルとして、時間領域の特徴量 (刺激オンセットから 200-300 ミリ秒, 300-500 ミリ秒, 500-800 ミリ秒の各区間の電位の平均値) と周波数領域の特徴量 ( $\delta$  帯,  $\theta$  帯,  $\alpha$  帯,  $\beta$  帯の各周波数帯のパワーの平均値) を、ERP 成分 (P600 と N400) に関する特定の事前知識に基づいて、分類に重要な時間の範囲と周波数の範囲を選択することで抽出している。その結果、統語の違反に関する脳波の分類では 57.7% の分類精度を示した。

しかし、ニューラルネットワークモデルによる手法が脳波の

分類に有効であることが示されており、上述のような特定のな特徴量の抽出を行わずに分類が可能であることが考えられる [6]。統語違反の検知を目的に、ERP 成分の時間や周波数についての特定のな事前知識を用いずに得られた特徴量を用いて、手法の評価を行った。本稿では、ニューラルネットワークモデル (SAE と LSTM) による手法が、統語違反に関する脳波の分類にどの程度有効であるかを評価した。

## 2. 提案手法

### 2.1 分類モデル

本稿では、脳波の分類において、SAE [9] と LSTM [10] による手法を提案する。本節では、それらのモデルについて説明する。

#### 2.1.1 Stacked Autoencoders

Autoencoder (AE) とは、2 層構造のニューラルネットワークモデルであり、入力層と出力層に同じデータを用いて学習を行うことで、次元の低い中間層による入力ベクトルの次元圧縮を学習する [11]。SAE では、層ごとに AE の学習を行うことで、多層のニューラルネットワークが入力ベクトルについて、より低い次元で高い表現を学習することができる [12]。層ごとの AE の学習では、はじめに中間層が 1 層だけの AE を学習し、その中間層を入力層とみなした AE を学習することで、多層の AE の学習を行う。分類などの教師あり学習に適用するためには、SAE のエンコーダの層のみを利用し、その最後の中間層をソフトマックス関数を有した出力層に入力することで分類を行う。多層の AE により、入力ベクトルを低次元で高表現のベクトルとして、分類問題に適用することが可能になる [9]。

#### 2.1.2 Long-Short Term Memory

Long-short term memory (LSTM) は、1997 年に初めて提案されたモデルであり、標準的な Recurrent Neural Networks の問題点であった勾配消失問題を解消するために、ゲート・セルが導入された。各時刻において、隠れ状態と記憶セルを有している。

### 2.2 実験

本研究では、Tanaka ら [8] の実験設計に従った。以下にその説明をする。

#### 2.2.1 実験刺激

音声文中の統語違反に関する脳波信号の分類について、各モデルの性能を評価するため、実験を行った。実験刺激として、文中の言語の違反を引き起こすために二種類の違反 (意味違反と統語違反) を設定した。しかし、本研究では統語違反の場合のみを取り扱い、また、二重主格構文のみを統語違反として定めた。統語違反を含む文は、[13] と [14] を参考に人手により作成した。統語違反文では、文の 2 つ目の単語に主格の繰り返しを含んでいるため、2 つ目の単語の助詞の提示時刻を、刺激の同期オンセットとした。

以下は、統語の正しい文と統語違反の文の対の例である：

b のアスタリスクから始まる文は、統語的に正しくない文である。各実験参加者に提示する文は、全 360 文から 200 文を選んだ：40 文が意味の正しい文、40 文が意味違反文、40 文が統

- a. 学生-が 建築家-を 助け-た  
学生-NOM 建築家-DAT 助け-PAST  
学生が建築家を助けた。
- b. \*学生-が 建築家-が 助け-た  
学生-NOM 建築家-NOM 助け-PAST

NOM: 主格助詞;  
DAT: 与格助詞;  
PAST: 過去時制形態素。

語の正しい文, 40 文が統語違反文, 40 文がフィラー文である。フィラー文は分析に用いないダミー文であり, 意味と統語ともに正しい文である。テキストに書き起こした後, 専門の女性ナレータによる発話音声録音した。

### 2.2.2 実験協力者

本研究における実験は, 奈良先端科学技術大学院大学の研究倫理委員会の推奨に従って行われた。すべての実験協力者はヘルシンキ宣言に従いインフォームド・コンセントに同意した。19名の大学院生(16名の男性, 3名の女性)が実験に参加し, 年齢は22歳から41歳(平均: 24.2歳)であった。全員がネイティブの日本語話者であり, 精神病の経験や聴覚の障害は無かった。

### 2.2.3 実験設定

実験と脳波収録は音響室で行われた。実験参加者は画面中心の十字マークを注視し, 瞬きや体を動かすことを抑制した状態で実験を行った。実験の手順は次の通りである: (1) スクリーン上の十字マークを1秒間注視する; (2) ランダムに選択された音声文をイヤフォンを通して4秒間聞く; (3) 2秒の間に提示文が正しい文であったか否かを, キーボードのボタンにて応答した。図1は, これらの手順を示している。1人の実験参加者にかかる時間は25分以内で完了した。




図1 単一試行脳波の収録の実験の流れ

### 2.2.4 脳波データ収録と前処理


脳波収録には, 32チャンネルのアクティブ電極を持つ脳波計であるBrain Products製ActiCAPと, 増幅のためBrain Products製BrainAmp DCを使用した。収録した脳波の前処理には, FieldTrip使用し[15], 以下の手順で行った: (1) リファレンスチャンネル(TP9とTP10)の平均電位にて最基準電極配置を行った; (2) 0.3Hzにて, FIRハイパス・フィルタリングを行った; (3) 同期オンセット(2つ目の単語の助詞)の-100ミリ秒から900ミリ秒の間の脳波をエポッキングして切り出した; (4)  $-350\mu V$ 以下, もしくは,  $350\mu V$ 以上の電位を含むエポックをリジェクトした。この際, 瞬きのアーチファクトの影響

を大きく受ける電極である, FP1とFP2の電位は考慮していない; (5) 筋電位の自動アーチファクト除去と目視による筋電位の影響の大きなエポックのリジェクトを行った; (6) 250Hzにダウンサンプリング; (7) 独立成分分析により, 瞬きや視線のアーチファクトの除去を行った。眼球由来のアーチファクト成分を特定には, 電極FP1と電極FP2の波形との相関を計算する方法と, トポグラフィと波形の目視による方法が用いられた; (8) 二段階目のアーチファクト除去として,  $-120\mu V$ 以下, もしくは,  $120\mu V$ 以上の電位を含むエポックのリジェクトを行った。ちなみに, 以上の手順を経て, 1人の実験参加者のデータで30%以上のエポックがリジェクトされたため, その被験者のデータは分析から除外した。これらの手順は[8]に詳述されている。

## 2.3 特徴量と分類

### 2.3.1 特徴量抽出

エポッキングされた脳波データの特徴量抽出方法として, 先行研究[3]にて用いられている, windowed means paradigmと呼ばれる方法を用いた。この方法では, 図2のように, 脳波信号から複数の時間区間を指定して, 各時間区間内の電位の平均値を抽出することで, 一つのエポックにおける一つのチャンネルの特徴ベクトルが得られる。



(Nは総時間区間)

図2 windowed means paradigmによる脳波信号からの特徴量抽出

本研究では, 同期オンセットの100ミリ秒後から800ミリ秒後の間の, 50ミリ秒の時間区間ごとの電位の平均値を特徴ベクトルとして得た。そのため, 1エポックにおける各チャンネルの特徴ベクトルが持つ次元数は14である。特徴量抽出を行う時間区間の開始時間(同期オンセットから100ミリ秒後)と終了時間(同期オンセットから800ミリ秒後)は, [8]と一致させている。本研究では, P600などのERP成分についての事前知識に基いた, 成分に特徴的な特定の時間区間(200-300ミリ秒, 300-500ミリ秒, 500-800ミリ秒[8])の人手での選択を行っておらず, 時間区間をより細かく区切った特徴量を得ることにより, より大きな次元の特徴ベクトルからより多くの情報を得られることを期待した。

SAEの学習には, すべてのチャンネルの特徴ベクトルを連結したベクトルを, 一つのエポックの特徴ベクトルとして扱った。そのため, 一つのエポック, すなわち, 一つのデータの特徴ベクトルの次元数は434であった。各ベクトルの平均値が0, 標

準偏差が1になるようにデータを正規化した。SAEを用いた、特徴量抽出と分類の流れを図3に示している。




図3 SAEの特徴量抽出と構造

SAEの場合とは異なり、脳波データを時系列の特徴ベクトルとしてLSTMに入力することができる[16]。各時間区間にて、チャンネル数である31次元の特徴ベクトルを入力し、それを時間区間の総数である14回、時系列方向に繰り返した。よって、特徴ベクトルの形は14\*31次元となり、SAEの場合と同様の方法で正規化した。最後の中間層の出力をソフトマックス関数を有する出力層に渡すことで分類を行った。LSTMを用いた、特徴量抽出と分類の流れを図4に示している。




図4 LSTMの特徴量抽出と構造

### 2.3.2 分類

単一試行脳波の分類において、線形カーネルを用いたSVMをベースライン・モデルとして、SAEとLSTMを評価した。SVMに入力する特徴ベクトルの形はSAEのものと同様である。

訓練データは14名の実験参加者のデータを連結したものをを用いた。統語の正しい文と統語違反文のデータの数が訓練データ内で等しくなるようにデータ数を調整したため、各条件で520個の脳波データが訓練データ内に存在している。訓練データ内でのチャンスレベルが50%になるため、テストデータ内でも同様に、各条件のデータ数を揃えた(各条件につき、157個の脳波データ)。すべてのモデルは訓練データによって学習を行い、訓練データに含まれない4名の実験参加者のデータによりテストを行った。これにより、未知の実験参加者に対する

汎化性能という観点でモデルを評価した。

ハイパーパラメータの最適化のため、訓練データ内にて10分割交差検証によるグリッドサーチを行い、最適なハイパーパラメータでテストデータにてモデルの評価を行った。グリッドサーチに使用したハイパーパラメータは次のとおりである、SVMでは、 $C = \{0.001, 0.01, 0.1, 1, 10, 100\}$ ; SAEでは、中間層の次元数 $\{10, 50, 100, 200, 300\}$ 、中間層の数 $\{1, 2, 3\}$ 、活性化関数(シグモイド関数, Rectified Linear Unit); LSTM(中間層の数は1)では、中間層の次元数 $\{5, 10, 15, 20, 25, 30\}$ 、活性化関数(シグモイド関数, Rectified Linear Unit)。最適なハイパーパラメータを決定した後、すべての訓練データにて学習を行いテストデータにてモデルを評価した。その際、SAEとLSTMの学習には、訓練データのうち2名分の被験者のデータを検証データとして、ニューラルネットワークの学習の最適な終了点を見つけるために用いた。

最後に、単一試行脳波において最も精度の高かったモデルとハイパーパラメータを用いて、複数試行(2回から20回)の脳波を加算平均した脳波データに対しても分類精度を調べた。各加算平均回数( $n$ )において、統語の条件(統語が正しい/統語違反)が同じ $n$ 個の脳波データを各実験参加者内でランダムに選択し、その $n$ 個の脳波データの特徴ベクトルを平均したものを特徴ベクトルとして、学習と予測を行った。この際、訓練データとテストデータに含まれるデータ数は、どの $n$ 試行加算平均データにおいても、単一試行の場合と等しい。また、訓練用の実験参加者とテスト用の実験参加者を分けているため、どの $n$ 試行加算平均データにおいても、訓練データ内の加算平均に用いられる試行に、テストデータでの試行が含まれることはない。

## 3. 実験結果

表1は、各モデルのテストデータにおける分類精度を示している。LSTMの精度がSVMとSAEのものを上回り、LSTMでは、60%を上回る分類精度であり、チャンスレベルを統計的に有意に上回った(両側二項検定;  $p < 0.01$ )。

表1 各モデルの分類精度

モデル	分類精度 (%)
SVM	58.4
SAE	58.3
LSTM	61.3

図5は、テストデータ内の実験参加者ごとの分類精度を示している。

図6は、最も精度の高かったモデル(LSTM)とハイパーパラメータによる、複数回加算平均データごとの分類精度を示している。加算回数が増加するごとに、分類精度が徐々に向上する傾向が見て取れる。

## 4. 考察

本研究では、音声文中の統語違反の検知を脳波信号により行




図5 SVMとSAE, LSTMの各実験参加者ごとの分類精度




図6 LSTMの加算平均回数ごとの分類精度

うため、ニューラルネットワークモデル (SAE: 58.3%, LSTM: 61.3%) とベースラインモデル (SVM: 58.4%) を評価した。時系列のニューラルネットワークモデルである LSTM による分類精度が、他のモデルを上回ったため、統語処理に関わる脳波信号の分類において、時系列の情報が有効であったと考えられる。

先行研究 [8] では、統語違反条件だけでなく、意味違反条件についても分類精度が調べられており、意味違反条件では 59.5% の分類精度が得られたことが報告されている。しかし、意味違反条件においては、同期オンセットを文中の最後の単語の発音が始まった瞬間に定めているため、単語の認識のタイミングが単語により変わることが考えられ、本研究の統語違反条件とは異なり、文の正誤の認識のタイミングが曖昧である。

P300 成分の検知の研究では、ニューラルネットワークモデルによる手法が、70% や 80% の分類精度を示したことが報告されている [5] [17]。P300 に関する実験では、P300 成分がおおよそ 20 回試行の加算平均により観測できると言われている [18]。そのため、比較的高い信号雑音比を持つ P300 成分とは異なり、P600 成分は比較的小さな振幅でしか観測されず、これらのことから、P300 成分の検知の研究のような高い分類精度を得られないと考えられる。

複数試行の加算平均の分類精度について、図 6 では、加算平均

することにより、分類精度が向上することが見て取れる。ERP 成分が複数回試行を加算平均することで観測できること [1] と、P300 検知の研究では、加算平均試行データを用いることでおおよそ 100% の分類精度を得られていることから、この結果は妥当であると考えられる。

## 5. あとがき

我々は、音声文中の統語違反を、単一試行の脳波信号を用いてニューラルネットワークモデルによる手法で検知することを行った。18 名の実験参加者の脳波データから、LSTM による手法が 61.3% の分類精度を得られ、また、その特徴量抽出には、経験的な特定の時間領域や周波数領域の選択を必要としないことを示した。そのため、時系列のニューラルネットワークモデルが、時系列データである脳波信号の分類に有効であると考えられる。

今後の課題として、本研究では、同期オンセットのタイミングをすべての試行で統一したが、その時間を移動させた場合の特徴量抽出による精度の変化を確認したい。また、オンセットの遅れを推定する手法 [19] によって、試行ごとのオンセットのずれを考慮することも可能であると考えられる。

LSTM での分類では、最後の中間層の出力のみを分類に用いていたが、時刻ごとに出力を分類に用いることで、時刻ごとの精度の変化を調べることも考慮したい。

また、時間区間での平均値を使用するのではなく、生の脳波データを時系列の分類モデルに入力することで、より多くの情報による分類精度の向上を実現したいと考えている。また、脳波データや特徴ベクトルにノイズを加えることによるデータ拡張を用いて、モデルの汎化性能を向上させることも考えていきたい [20]。

## 文 献

- [1] S.J. Luck, An Introduction to the Event-Related Potential Technique, MIT Press, 2014.
- [2] L. Osterhout and P.J. Holcomb, "Event-related brain potentials elicited by syntactic anomaly," Journal of Memory and Language, vol.31, no.6, pp.785–806, 1992.
- [3] B. Blankertz, S. Lemm, M. Treder, S. Haufe, and K.-R. Müller, "Single-trial analysis and classification of erp components—a tutorial," NeuroImage, vol.56, no.2, pp.814–825, 2011.
- [4] F. Lotte, L. Bougrain, A. Cichocki, M. Clerc, M. Congedo, A. Rakotomamonjy, and F. Yger, "A review of classification algorithms for eeg-based brain-computer interfaces: a 10 year update," Journal of neural engineering, vol.15, no.3, p.031005, 2018.
- [5] L. Vařeka and P. Mautner, "Stacked autoencoders for the p300 component detection," Frontiers in neuroscience, vol.11, p.302, 2017.
- [6] S. Alhagry, A.A. Fahmy, and R.A. El-Khoribi, "Emotion recognition based on eeg using lstm recurrent neural network," Emotion, vol.8, no.10, pp.355–358, 2017.
- [7] F. Putze, M. Schünemann, T. Schultz, and W. Stuerzlinger, "Automatic classification of auto-correction errors in predictive text entry based on eeg and context information," Proceedings of the 19th ACM International Conference on Multimodal Interaction ACM, pp.137–145 2017.
- [8] H. Tanaka, H. Watanabe, H. Maki, S. Sakriani, and S. Nakamura, "Electroencephalogram-based single-trial de-

- tection of language expectation violations in listening to speech,” *Frontiers in Computational Neuroscience*, vol.13, p.15, 2019.
- [9] A. Ng, J. Ngiam, C. Foo, M. Y, and S. C, “Ufldl tutorial,” [http://ufldl.stanford.edu/wiki/index.php/UFLDL\\_Tutorial](http://ufldl.stanford.edu/wiki/index.php/UFLDL_Tutorial).
- [10] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol.9, no.8, pp.1735–1780, 1997.
- [11] G.E. Hinton and R.R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science*, vol.313, no.5786, pp.504–507, 2006.
- [12] Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle, “Greedy layer-wise training of deep networks,” *Advances in neural information processing systems*, pp.153–160, 2007.
- [13] S. Takazawa, N. Takahashi, K. Nakagome, O. Kanno, H. Hagiwara, H. Nkakajima, and etal., “Early components of event-related potentials related to semantic and syntactic processes in the japanese language,” *Brain Topography*, vol.14, pp.169–177, 2002.
- [14] J. Mueller, A. Hahne, Y. Fujii, and A. Friederici, “Erp evidence for different strategies in the processing of case markers in native speakers and non-native learners,” *BMC neuroscience*, vol.8, p.18, 2007.
- [15] R. Oostenveld, P. Fries, E. Maris, and J.-M. Schoffelen, “Fieldtrip: Open source software for advanced analysis of meg, eeg, and invasive electrophysiological data,” *Computational Intelligence and Neuroscience*, vol.1, pp.1–9, 2011.
- [16] J. Fedjaev and J. Conradt, “Decoding eeg brain signals using recurrent neural networks,” <https://www.grin.com/document/455235>, 2017.
- [17] A. Dittaporn, N. Banluesombatkul, S. Ketrat, E. Chuangsuwanich, and T. Wilaiprasitporn, “Universal joint feature extraction for p300 eeg classification using multi-task autoencoder,” 07 2018.
- [18] J. Cohen and J. Polich, “On the number of trials needed for p300,” *International Journal of Psychophysiology*, vol.25, no.3, pp.249–255, 1997.
- [19] A. Kiesel, J. Miller, P. Jolicœur, and B. Brisson, “Measurement of erp latency differences: A comparison of single-participant and jackknife-based scoring methods,” *Psychophysiology*, vol.45, no.2, pp.250–274, 2008.
- [20] S. Stober, D.J. Cameron, and J.A. Grahn, “Classifying eeg recordings of rhythm perception.,” *ISMIR*, pp.649–654, 2014.