

時系列注意機構モデルによる脳波を用いた 音声文の意味誤り検出

本村駿乃介[†] 田中 宏季[†] 中村 哲[†]

[†] 奈良先端科学技術大学院大学 先端科学技術研究科 〒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 音声文中の意味誤りを検出するため、単一試行脳波信号を用いた注意機構付きリカレントニューラルネットワークによる手法を提案する。文中の意味誤りに対する脳波の反応が知られているが、単一試行脳波での検出に関する報告は少ない。17名の実験協力者が一部の文に意味誤り単語を含む文を音声で聞き、その正誤をキーボードのボタンにより応答を行った際の脳波信号を収録した。文全体の脳波信号を用いることで、誤り単語のオンセット情報を利用せずに文の正誤を分類することを可能にした。脳波の生信号を入力した注意機構付き RNN により、有意な分類精度が示された。注意機構による、誤り単語のオンセット付近に重みが付き分類が行われている事例も確認した。

キーワード 脳波, 事象関連電位, N400, 注意機構付きリカレントニューラルネットワーク

Shunnosuke MOTOMURA[†], Hiroki TANAKA[†], and Satoshi NAKAMURA[†]

[†] Department of Science and Technology, Nara Institute of Science and Technology
Takayama-cho 8916-5, Ikoma-shi, Nara, 630-0101 Japan
E-mail: †{motomura.shunnosuke.mj1,hiroki-tan,s-nakamura}@is.naist.jp

1. ま え が き

人間は、言語を用いたコミュニケーションにおいて、文中の意味的な誤りや違和感を認識することがある。例えば、語学学習者による作文や発話、また、文を生成するシステムを介した機械とのコミュニケーションにおいて、その文を評価する方法として、主観評価法がある。しかし、主観評価法で文や単語の意味的な評価を行う際、評価者ごとに意味の解釈やその程度が異なるため、明確な評価基準を設けることが難しく、評価にバイアスが含まれる可能性がある [1]。

我々は、脳波信号を用いた文の評価を目的とした、音声文中の意味誤り検出の手法を提案する。脳波信号は、脳の神経細胞の電気活動による自発信号であ

り [2]、また、反応時間などの行動指標とは異なり、刺激と反応の間の、認知に特定な処理についての関係を調べることができる [3]。自発的な生体信号であるという点で、バイアスを排除した客観的な評価への応用が可能であると考えられる。また、脳波信号は数ミリ秒単位の高い時間分解能を有しており、文の認識処理など、時系列のオンライン処理について調べることが可能である。

言語の意味的な処理については、N400 と呼ばれる事象関連電位 (ERPs) の脳波の反応が、文中の意味的な誤りや違和感を含んだ単語に対して起こることが知られており [4]、この反応の大きさが、先行する文脈から予測される次の単語との意味的な距離 (Cloze 確率によって定量的に求められる [4]) に相関すると考え

られている [5].

ERP 成分の観測には、一般的に 50 試行から 100 試行の加算平均回数を要するが [3], 一つの文に対する評価を行うためには、単一試行脳波での分析が必要である。文中の言語に関連した単一試行の脳波信号を扱った研究は少ないが [6] [7], 中でも、音声文中の意味的な誤りに関する脳波信号の分類を行ったものとしては、Tanaka ら [8] の研究がある。[8] では、文中の特定の位置に意味違反が起こる文を用い、その特定の単語に対する脳波信号を切り出して分類を行っており、59.5%の分類精度を示している。しかし、文中の他の単語の認識時の脳波信号も分類に有効である可能性があること、また、実際の状況では、文中のどの位置の単語で意味違反が起こるのかが分からないこと（同様に、音声中でその単語の意味を認識するタイミングが曖昧であること）などから、文全体の認識時の脳波信号を分類に用いる手法の評価が必要であると考えられる。

また、単一試行脳波の分類に関して、近年の研究では、ニューラルネットワークモデルによるものが多く提案されており [9] [10] [11] [12], そのうち、Recurrent neural network (RNN) によって、時系列信号として脳波信号を扱うことで有効な予測が可能になった報告もある [13] [14] [15] [16]. また、注意機構 [17] により、時系列の中で予測に重要な部分を用いる学習を行うことで、予測の精度が向上すると考えられており、音声 [18] [19] や脳波 [20] [21] の信号の分類に有効であった例が示されている。しかし、我々の知る限り、言語処理などの認知処理に関連した脳波の分類において、注意機構モデルが用いられているものはない。

前述の通り、文中の意味誤りに関する単一試行脳波の分類において、文全体の脳波を入力として用いる手法の評価が必要であり、その際、意味違反の認識時の脳波信号が分類に重要であると考えられるため、入力の脳波信号の系列の中から、分類に重要な部分を見つけ出す注意機構による分類が有効であると考えられる。このことから、本研究では、文全体の脳波信号を用いた注意機構付き RNN による意味違反検出手法を提案する。本稿における貢献点を、以下に示す。

- 文全体の脳波信号を用いて、意味違反文の検出を行った。
- 言語に関連した脳波信号に対して、注意機構付

きモデルを評価した。

- 各文中の脳波信号における、注意機構が予測にどの部分を重要視しているのかを分析した。

2. 提案手法

2.1 分類モデル

本稿では、RNN を用いた分類モデルとして、双方向の Gated recurrent unit (GRU) を用いた。また、系列からラベルを予測する注意機構のモデルを用いた。本節では、それらのモデルについて説明する。

2.1.1 Gated Recurrent Unit

Gated recurrent unit (GRU) [22] は、ゲート付き RNN の一種である。標準の RNN における勾配消失問題を解消するための手法として提案された Long short-term memory [23] の派生であり、各時刻で隠れ状態を保持し、reset ゲートと update ゲートを導入した RNN である。また、本稿では、系列を双方向に学習するモデルを使用した。

2.1.2 系列によるラベル予測のための注意機構

文全体に対する脳波信号の系列の中で、すべての時刻における信号が等しく分類に有効なわけではない。そのため、全系列から分類に重要である時刻を取り出し、組み合わせることのできる注意機構モデル [24] を用いた RNN を使用した。RNN の時刻 t における出力を h_t としたとき、以下のように、各時刻の注意機構による重みを計算する。

$$e_t = h_t^\top w \quad (1)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_t \exp(e_t)} \quad (2)$$

$$v = \sum_t \alpha_t h_t \quad (3)$$

ただし、 w は注意ベクトル、 h_t と w の類似度を取ることによって (e_t)、時刻 t の重要度を測っている。ソフトマックス関数によって正規化された重み α_t を用い、すべての時刻 t における重みつき和を求めることで、系列のベクトル v を得ることができる。このベクトルは、系列全体を符号化した表現となり、ソフトマックス関数による分類に適用することができる。 w はランダムに初期化され、ネットワークと同時に学習される。図 1 に、このネットワークの構造を示す。




図1 注意機構モデルを導入した RNN

2.2 実験

時系列注意機構モデルによる文理解時の脳波を用いた分類手法を評価するため、言語の違反を引き起こす文を音声にて呈示し、その際の実験協力者の脳波信号を収録するための実験を行った。本研究の実験刺激は、Tanaka ら [8] が使用したものと同一のものである。以下に詳述をする。

2.2.1 実験刺激

文中の言語違反として、意味違反と統語違反の二条件を設定した。本研究では、そのうち意味違反条件のみを扱う。Takazawa ら [25] を参考に、意味的に正しい文と、意味違反を引き起こす二種類の文を同じ数だけ作成した。表 1 は、対応する二種類の文の例である：

表 1 意味の正しい文と違反文の例

- a. 太郎-が 旅行-に 出かけた
太郎-NOM 旅行-DAT 出かけ-PAST
太郎が旅行に出かけた。
- b. #太郎-が 辞書-に 出かけた
太郎-NOM 辞書-DAT 出かけ-PAST

NOM: 主格助詞;
DAT: 与格助詞;
PAST: 過去時制形態素。

b の # から始まる文は、意味的に逸脱している文である。各実験協力者に呈示する文は、意味の正しい文が 40 文、意味違反文が 40 文、統語の正しい文が 40 文、統語違反文が 40 文、分析に用いないフィラー文が 40 文の全 200 文である。専門の女性ナレータによる発話音声を録音したものを刺激として使用した。

2.2.2 実験参加者

本研究の実験は、奈良先端科学技術大学院大学の研

究倫理委員会の承認を受けて行われた。すべての実験参加者はインフォームドコンセントに同意した。19 名の大学院生（男性 16 名、女性 3 名）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。全員が日本語母語話者であった。

2.2.3 実験設定

実験と脳波収録は音響室で行った。実験参加者は画面中央の十字マークを注視し、イヤホンを通して音声聞いた。また、実験中は、瞬きや体を動かすことを抑制した状態であった。実験の手順は次の通りである：(1) 画面上の十字マークを 1 秒間注視する；(2) ランダムに選択された音声文を 4 秒間聞く。この間に必ず音声の再生が終了するため、実験参加者は静止状態である；(3) 2 秒の間に呈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 2 に、これらの手順を示している。1 人の実験参加者に要する時間は 25 分以内であった。




図 2 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

脳波データの収録には Brain Product 製の 32 チャンネル脳波計である Acticap と、増幅のための BrainAmp DC を使用した。脳波データの前処理には EEGLAB [26] と Python MNE [27] を使用した。前処理は次の手順で行った：(1) リファレンス電極 (TP9 と TP10) の平均電位にて、再基準電極配置を行った。またその際、収録時のリファレンス電極であった FCz のチャンネルを追加したため、以降の分析では 31 チャンネルの信号を扱った；(2) 1Hz にて、FIR ハイパスフィルタリングを行った；(3) 各文の音声の開始時刻から終了時刻の間の脳波を、エポッキングして切り出した。また同時に、開始時刻の 500 ミリ秒前から開始時刻までの脳波を用いて、ベースライン補正を行った；(4) エポッキングされた脳波のうち、300 μ V を上回った、もしくは、-300 μ V を下回ったエポックを除外した。この際、瞬きによる電位への影響が大きい電極 (FP1 と FP2) での電位は考慮していない；

(5) 250Hz にダウンサンプリング; (6) ADJUST [28] を使用し, 独立成分分析を用いた瞬き, 眼球運動由来の成分を除去した. 以上の手順を経て, 2 名の実験参加者のデータを除外し, また, 17 名のデータのうち 1.8% のエポックを除外した.

2.3 特徴量と分類

2.3.1 特徴量抽出

本研究では, 脳波信号の特徴量として, 31 チャンネルの電位を 20Hz にローパスフィルタリングしたものをを用いた. そのため, 各時刻に 31 次元の特徴ベクトルを持つこととなる. 近年の研究では, ニューラルネットワークモデルによる自動的な特徴量獲得の学習により, 脳波信号特有の特徴量抽出を行わずに, 生の脳波信号を入力に用いる手法が多く提案されている [29] [30] [31]. ちなみに, 一つのエポックを一つのデータとして扱っているため, 各音声文と同じ秒数の脳波データを入力として扱っている.

2.3.2 分類

訓練データは 13 名の実験参加者のデータで, うち, 2 名のデータは, 適切な時点で学習を打ち切るために使用する検証用データとして用いた. それ以外の 4 名のデータをテストデータとすることで, 未知の実験参加者に対する汎化性能によりモデルを評価した [10]. モデルの評価にあたり, 訓練データに対するテストデータの量は十分であると, [8] [32] [33] を参考に考えられる. 訓練データには 1012 エポック (うち, 検証用データは 156 エポック), テストデータには 310 エポックのデータが存在している. またすべてのデータ内で, 意味の正しい文と意味違反文の数を揃えているため, 分類のチャンスレベルは 50% となっている. 訓練データ内での, 各特徴ベクトルの平均値と標準偏差を用いることで標準化を行った (すなわち, 訓練データ内では標準化によって, 各特徴ベクトルの平均値が 0, 標準偏差が 1 となった). 式 4 は, 時刻 t における特徴ベクトル x_t の標準化を行う手順である (ただし, μ_{train} と θ_{train} は, それぞれ訓練データ内の平均値と標準偏差である).

$$x_t = \frac{x_t - \mu_{train}}{\theta_{train}} \quad (4)$$

脳波データのデータ数の少なさによる過学習を抑制するため, ニューラルネットワークの学習において有効であるとされているデータ拡張を行った. [34] と同

様に, 単純にガウスノイズを訓練データ内の脳波信号に加えることにより, 訓練データを拡張した. 式 5 により, 時刻 t における元のベクトル x_t を用いて, 拡張されたベクトル $x_{t.aug}$ を生成した.

$$x_{t.aug} = x_t + 0.1 \cdot \mathcal{N}(0, 1) \quad (5)$$

分類モデルには, 注意機構付きの 1 層の双方向 GRU (GRU w/ att.) を使用した. モデルのハイパーパラメータの最適化のため, 訓練データ内での 10 分割交差検証を行い, 最良であったハイパーパラメータを用いてテストデータでのモデルの評価を行った. 中間層の次元数 (5, 10, 20), データ拡張のサイズ (5 倍, 10 倍, 20 倍), L2 正則化の重み (0, 0.1, 0.001, 0.0001) の順に検証を行い, ハイパーパラメータを決定した. また, 注意機構の有無による性能比較のため, 同様のハイパーパラメータで注意機構の無いモデル (GRU w/o att.) の精度の検証も行った.

3. 実験結果

3.1 分類精度

表 2 は, 双方向 GRU (GRU w/o att.) と注意機構付き双方向 GRU (GRU w/ att.) の分類精度と, 意味違反検出の再現率, 及び適合率を示している. 注意機構付き双方向 GRU が, 63.5% の分類精度を示し, 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: $p < 0.01$). [8] では, 意味違反の分類において, 多層パーセプトロンで 59.5% の分類精度 (再現率: 63.1%, 適合率: 44.3%) を示しており, 文全体の脳波信号を用いた注意機構による手法が比較的有效であることが示された.

表 2 各モデルの分類精度と再現率, 適合率

モデル	分類精度	再現率	適合率
GRU w/ att.	0.635	0.716	0.616
GRU w/o att.	0.554	0.470	0.565

図 3 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. 注意機構付きのモデルは, どの実験参加者のデータに対しても安定して 60% 前後の分類精度を示した.

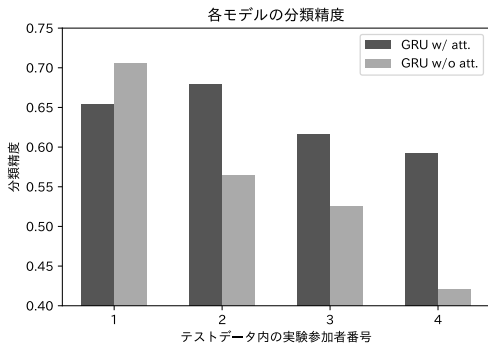


図3 各実験参加者ごとの分類精度

3.2 音声文に対する注意機構の重み

音声文中の、どの時刻の信号を分類に利用しているのかを確認するため、時系列方向の注意機構の重みを可視化した。図4は、そのうち分類に成功した場合の例である。意味が正しいと予測する場合と、意味違反と予測する場合とで、注意機構の重みのパターンが異なることが分かった。また、意味違反と予測する場合は、違反を認識する単語である最後の単語の表示時刻（図中の赤色の破線）付近に、注意を向けるように学習していることが見て取れる。




図4 注意機構の音声文に対する重み（左図：違反文と予測した場合、右図：正しい文と予測した場合）

4. 考 察

音声文中の意味誤り単語の検出において、文全体に対する脳波信号を入力として分類を行った場合、注意機構付きモデルを用いることで有意に分類が可能であることを示した。文全体の信号を入力することで、違反単語を聞いた前後の信号の関係を比較することにより分類が行われている可能性があり、特定の位置の単語の脳波をエポッキングするよりも、多くの情報を予測に用いることができると考えられる。また、注意機構付き GRU と注意機構のない GRU の性能比較において、前者の分類精度が高かったことから、文全体の

脳波信号の時系列の中で、注意機構による重み付けが分類に有効であったことが考えられる。

注意機構の重みの可視化により、モデルの予測が注意機構の重みのパターンに依存することが分かった。つまり、文中最後の単語の表示時刻付近に重みが付くと、意味違反の予測確率が上昇していることから、その時刻付近の信号が予測に有効であるとモデルが学習していると見られる。しかし、今回の実験設定では、3番目の単語の認識により意味違反か否かが判明することから、どの文においても、時系列中で比較的近い場所で違反の認識が起こる。そのため、今回の実験では、注意機構の過度な学習が起きている可能性があるため、文長の異なる文による実験が必要であると考えている。

予測の結果と文の特徴との関係を調べるため、注意機構付きモデルの予測確率に対して、事前にクラウドソーシングによって求めた文の Cloze 確率 [8] との相関と、文の音声長との相関をそれぞれ調べたが、両方とも有意な相関は認められなかった。

5. あとがき

本稿では、音声文中の意味違反を脳波信号から検出する手法として、文全体の脳波を用いた注意機構付きリカレントニューラルネットワークモデルによるものを提案した。実験参加者のうち17名の脳波データを用い、特別な特徴量抽出を行わずに生の脳波信号を特徴量として分類を行ったところ、注意機構付きモデルによって63.5%の分類精度を示した。文全体の脳波信号を用いて、時系列においてより多くの情報を分類に利用できること、また、注意機構により時系列からの予測のための特徴抽出が有効に働いていることが示された。

今後の展望として、本研究では一文の単語数を固定したが、様々な文長を持った文を用いることで、実際の文の評価の状況に近づけることや、注意機構による時系列中の特徴抽出の性能を確かめることが挙げられる。また、文中の単語の意味的な正しさを、Cloze 確率（先行する文脈から目的の単語が次に続く確率を、多くの評価者による回答によって求める [35]）によって定義し、その確率の予測を脳波により学習することで、意味違反か否かの分類にとどまらない定量的な予測が可能になると考えている。

謝 辞

本研究の一部は、JST, CREST, JPMJCR19A5の支援を受けたものである。

文 献

- [1] A. Bakarov, “A survey of word embeddings evaluation methods,” *CoRR*, vol.abs/1801.09536, 2018.
- [2] J.C. Henry, “Electroencephalography: Basic principles, clinical applications, and related fields, fifth edition,” *Neurology*, vol.67, no.11, pp.2092–2092–a, 2006.
- [3] S.J. Luck, *An Introduction to the Event-Related Potential Technique*, MIT Press, 2014.
- [4] M. Kutas and S.A. Hillyard, “Brain potentials during reading reflect word expectancy and semantic association,” *Nature*, vol.307, no.5947, p.161, 1984.
- [5] J.B. Debruille, “The n400 potential could index a semantic inhibition,” *Brain research reviews*, vol.56, pp.472–7, 01 2008.
- [6] 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*, pp.137–145, ACM, 2017.
- [7] S. Motomura, H. Tanaka, and S. Nakamura, “Detecting syntactic violations from single-trial eeg using recurrent neural networks,” *Adjunct of the 2019 International Conference on Multimodal Interaction, ICMI '19*, pp.4:1–4:5, 2019.
- [8] H. Tanaka, H. Watanabe, H. Maki, S. Sakriani, and S. Nakamura, “Electroencephalogram-based single-trial detection of language expectation violations in listening to speech,” *Frontiers in Computational Neuroscience*, vol.13, p.15, 2019.
- [9] 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.
- [10] L. Vařeka and P. Mautner, “Stacked autoencoders for the p300 component detection,” *Frontiers in neuroscience*, vol.11, p.302, 2017.
- [11] Y. Yuan, G. Xun, Q. Suo, K. Jia, and A. Zhang, “Wave2vec: Learning deep representations for biosignals,” *2017 IEEE International Conference on Data Mining (ICDM)*, pp.1159–1164, Nov 2017.
- [12] Y. Ding, B. Huynh, A. Xu, T. Bullock, H. Cecotti, M. Turk, B. Giesbrecht, and T. Höllerer, “Multimodal classification of eeg during physical activity,” *2019 International Conference on Multimodal Interaction, ICMI '19*, pp.185–194, ACM, 2019.
- [13] T. Zhang, W. Zheng, Z. Cui, Y. Zong, and Y. Li, “Spatialtemporal recurrent neural network for emotion recognition,” *IEEE Transactions on Cybernetics*, vol.49, no.3, pp.839–847, March 2019.
- [14] 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.
- [15] Z. Ni, A.C. Yuksel, X. Ni, M.I. Mandel, and L. Xie, “Confused or not confused?: Disentangling brain activity from eeg data using bidirectional lstm recurrent neural networks,” *Proceedings of the 8th ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*, pp.241–246, ACM, 2017.
- [16] M. Sakthi, A. Tewfik, and B. Chandrasekaran, “Native language and stimuli signal prediction from eeg,” *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp.3902–3906, May 2019.
- [17] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, L. Kaiser, and I. Polosukhin, “Attention is all you need,” *CoRR*, vol.abs/1706.03762, 2017.
- [18] C.W. Huang and S. Narayanan, “Attention assisted discovery of sub-utterance structure in speech emotion recognition,” *Interspeech*, pp.1387–1391, 09 2016.
- [19] Z. Zhao, Y. Zheng, Z. Zhang, H. Wang, Y. Zhao, and C. Li, “Exploring spatio-temporal representations by integrating attention-based bidirectional-lstm-rnns and fcns for speech emotion recognition,” *Interspeech*, pp.272–276, 09 2018.
- [20] H. Phan, F. Andreotti, N. Cooray, O.Y. Chén, and M. De Vos, “Automatic sleep stage classification using single-channel eeg: Learning sequential features with attention-based recurrent neural networks,” *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp.1452–1455, IEEE, 2018.
- [21] X. Zhang, L. Yao, S.S. Kanhere, Y. Liu, T. Gu, and K. Chen, “Mindid: Person identification from brain waves through attention-based recurrent neural network,” *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, vol.2, no.3, pp.149:1–149:23, Sept. 2018.
- [22] K. Cho, B. van Merriënboer, Ç. Gülçehre, F. Bougares, H. Schwenk, and Y. Bengio, “Learning phrase representations using RNN encoder-decoder for statistical machine translation,” *CoRR*, vol.abs/1406.1078, 2014.
- [23] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol.9, no.8, pp.1735–1780, 1997.
- [24] B. Felbo, A. Mislove, A. Søgaard, I. Rahwan, and S. Lehmann, “Using millions of emoji occurrences to learn any-domain representations for detecting sentiment, emotion and sarcasm,” *arXiv preprint*

arXiv:1708.00524, 2017.

- [25] S. Takazawa, N. Takahashi, K. Nakagome, O. Kanno, H. Hagiwara, H. Nakajima, and et al., “Early components of event-related potentials related to semantic and syntactic processes in the Japanese language,” *Brain Topography*, vol.14, pp.169–177, 2002.
- [26] A. Delorme and S. Makeig, “Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis,” *Journal of neuroscience methods*, vol.134, no.1, pp.9–21, 2004.
- [27] A. Gramfort, M. Luessi, E. Larson, D. Engemann, D. Strohmeier, C. Brodbeck, R. Goj, M. Jas, T. Brooks, L. Parkkonen, and M. Hmlinen, “Meg and eeg data analysis with mne-python,” *Frontiers in Neuroscience*, vol.7, p.267, 2013.
- [28] A. Mognon, J. Jovicich, L. Bruzzone, and M. Buiatti, “Adjust: An automatic eeg artifact detector based on the joint use of spatial and temporal features,” *Psychophysiology*, vol.48 2, pp.229–40, 2011.
- [29] Y. Roy, H.J. Banville, I. Albuquerque, A. Gramfort, T.H. Falk, and J. Faubert, “Deep learning-based electroencephalography analysis: a systematic review,” *CoRR*, vol.abs/1901.05498, 2019.
- [30] K.G. Hartmann, R.T. Schirrmeyer, and T. Ball, “Eeg-gan: Generative adversarial networks for electroencephalographic (eeg) brain signals,” 2018.
- [31] I. Sturm, S. Lapuschkin, W. Samek, and K.R. Müller, “Interpretable deep neural networks for single-trial eeg classification,” *Journal of Neuroscience Methods*, vol.274, pp.141 – 145, 2016.
- [32] A.K. Vail, E. Liebson, J.T. Baker, and L.P. Morency, “Toward objective, multifaceted characterization of psychotic disorders: Lexical, structural, and disfluency markers of spoken language,” *Proceedings of the 20th ACM International Conference on Multimodal Interaction, ICMI '18*, pp.170–178, ACM, 2018.
- [33] P. Saha, M. Abdul-Mageed, and S.S. Fels, “SPEAK YOUR mind! towards imagined speech recognition with hierarchical deep learning,” *CoRR*, vol.abs/1904.05746, 2019.
- [34] F. Wang, S.h. Zhong, J. Peng, J. Jiang, and Y. Liu, “Data augmentation for eeg-based emotion recognition with deep convolutional neural networks,” *MultiMedia Modeling*, Cham, pp.82–93, Springer International Publishing, 2018.
- [35] M. Kutas and K.D. Federmeier, “Thirty years and counting: finding meaning in the n400 component of the event-related brain potential (erp),” *Annual review of psychology*, vol.62, pp.621–647, 2011.