

Transformer による BCI のためのリアルタイム脳波識別

Real-time EEG Classification for BCI by Transformer

奥村 ヒョービ

指導教員 菊池 眞之

東京工科大学 大学院バイオ・情報メディア研究科 コンピュータサイエンス専攻
ブレインコンピューティング研究室

キーワード：BCI, EEG, 機械学習, Transformer, クラス分類

1. はじめに

脳波(EEG)とは、頭の上から脳の活動を電氣的に記録することで得られる波形である。脳波は比較的安価で簡単に取得できるため、脳波を活用するための研究が盛んである。活用先として、医療やブレイン・コンピュータ・インタフェース(BCI)などの方面での研究が行われている。BCIは、脳波をコンピュータで処理し扱えるようにする技術であり、サポートベクトルマシンや深層学習などの各種のクラス分類器が用いられている。

近年深層学習では、自然言語の高精度分析にTransformer[1]が注目されている。Transformerには、離れた入力データ同士の関係性の検出にも優れているAttentionという機構が用いられていることで自然な文章を生成が行えるようになった。また、Transformerの枠組みを画像分類に応用したVision Transformer(ViT)も考案されている。

本研究では、Attentionを用いて自然言語での長文の理解処理を可能としたTransformerに注目し、運動識別BCIにおいて被験者が静止しているのか、動作中なのか、切り替わる最中なのかといったリアルタイムな脳波の識別を目指す。

2. 実験

2.1. データ

本実験では、109人からなる運動時の脳波データセット[2]のうちの1人分を使用する。

データセットのベースライン（開眼かつ運動無しの安静状態）とタスク時（左右どちらかの拳の連続的開閉の反復）を使用し、2択分類でモデルを評価する。テストデータは、全体のデータの10分の1でランダムに選び、全体の10分の9を学習データとした。またTransformerへは、1試行分の脳波データのうちの時間的に連続する n 個を時刻0より順次シフトさせつつ入力してゆく。 n の値には学習の結果最も安定した40とした。

2.2. モデル

Transformerを自然言語処理で使用する際、エンコーダー部分で元の文を解析し、デコーダー部分で予測を行いながら文を生成する。しかし、本実験では、脳波を解析し分類するため、エンコーダー部分のみを使用する。

2.3. 入力方法

本研究ではTransformerへの脳波データの入力方法として図1から図4に示す4通りを考えた。各図の右端の「Transformer」は、Transformerのエンコーダー部分に繋がることを示す。正解ラベルは、「安静状態」と「拳開閉状態」の2種類のデータに対してそれぞれ付与した。

図1, 2では、経時的な連続 n 回分の64ch計測データの配置を示す。Transformerの入力形式に合わせるために、数値をベクトル表現に変換する機構Embeddingを使用する。Embeddingは、0以上の数値を変換するが、今回使用する脳波の数




図1 脳波データのTransformerへの入力形式
(1): チャンネルを基準に配置する




図2 脳波データのTransformerへの入力形式
(2): 時間軸を基準に配置する




図3 脳波データのTransformerへの入力形式
(3): 脳波をベクトルとして扱う




図4 脳波データのTransformerへの入力形式
(4): 全結合による脳波のベクトル表現への変換

値の範囲である $\pm 1,000$ では合わない. そのため Embedding の変換用に, $-1,000 \sim +1,000$ の範囲の計測データに対して $2,000 \times$ チャンネル番号(1~64)の値を加算した.

図3は, 同一サンプリングで得られる 64ch のデータを 1 つのベクトルとして扱い, Transformer へは経時的な連続 n 回のサンプリングに対応する n 本のベクトルを同時投入する.

図4は ViT を参考にし, Transformer に入力する前の図3の1ベクトル 64ch に線形変換 (Linear) を行い, 経時的な連続 n 回のサンプリングに対応する n 本のベクトルを Transformer へ同時投入する.

2.4. 結果

それぞれの入力形式で計6回の学習を行って得られた識別率の平均を図5示す. なお, エラーバーは標準誤差を表す. このときの学習回数は, 1,000epoch であり, 学習時の識別率は全てが 100% になって学習を終えた. また, 全て入力形




図5 (1)~(4)の各入力形式での識別率の平均
(エラーバーは標準誤差)

式において, 精度の平均が 50.0% であるチャンスレベル付近になった.

3. 考察

入力形式(1), (2)では, 1 つの入力値に対して 1 つのベクトルを生成するため, 個々のデータの関係性を捉え難いものであったことや, 投入されるデータの次元の高さに対しサンプルデータの個数が少なかったこと等が, 結果の精度が低かったことの要因と考えられる. 一方, 入力形式(3), (4)では, 複数ベクトルに分割しての投入になっているものの, 精度は向上していない. 今後, 脳波に対する事前学習を行えば, データの特徴をとらえやすくなるのではないかと考えられる.

4. まとめ

本研究では, Transformer を用いてリアルタイム処理できるように入力方法を施行した. 4 つの入力形式を用いて実験を行ったが, いずれもチャンスレベル付近になった. 今後は, 事前学習を行って精度向上を図る.

参考文献

- [1] Ashish Vaswani, Noam Shazeer, Niki Parmar et. al. "Attention Is All You Need", 31st Conference on Neural Information Processing Systems(NIPS), 2017.
- [2] PhysioNet, www.physionet.org/content/eegmmidb/1.0.0/ (2021/10/18 現在)