

## 深層学習による BCI コミュニケーションのための脳波状態分類

圓城寺 純矢\*<sup>1</sup> チャンポーンパックディー インオン\*<sup>1</sup> 安藝 史崇\*<sup>2</sup> 木村 達洋\*<sup>3</sup>  
山崎 清之\*<sup>4</sup>

### EEG classification using deep learning for BCI based communication

by

Enjoji Junya, Ingon Chanpornpakdi, Fumitaka Aki, Tatsuhiro Kimura and Kiyoyuki Yamazaki

(Received: October 31, 2019, Accepted: )

#### Abstract

Patients with Amyotrophic Lateral Sclerosis (ALS) eventually have total locked-in syndrome (TLS), a condition in which they cannot even move their eyes. These patients have the extreme difficulty in communication with people around them. In order to improve their quality of life, a brain computer interface (BCI) has attracted attention as an alternative communication system. In this paper, we studied BCI using Steady State Visual Evoked Potentials (SSVEP) as a stimulus. EEG classification by machine learning is often used for SSVEP based BCI data processing. However, it is not easy to extract features of SSVEP input data by machine learning, due to the large individual differences of the SSVEP response. For this reason, we studied on the possibilities to construct an efficient BCI system by deep learning, that expected to learn autonomously to extract features of SSVEP based BCI system.

Key Words: BCI, SSVEP, Deep Learning, Checker Board Pattern

#### 1. はじめに

##### 1.1 補助代替コミュニケーション

筋萎縮性側索硬化症(Amyotrophic Lateral Sclerosis:以下、ALS)とは、原因不明の神経疾患で、罹患すると運動神経が選択的に障害されることで徐々に運動機能が低下していく進行性の難病である。ALSは一般に思考能力は正常であるが、症状の進行に伴う運動機能の低下により意志疎通が極めて困難となる<sup>[1]</sup>。運動機能の低下が進行し口腔筋の機能障害が生じた状態を閉じ込め症候群(Locked-in Syndrome)と呼び、最終的には眼球さえ動かさせない状態である完全閉じ込め症候(Totally Locked-in Syndrome:以下、TLS)となる。そこで、これらの患者に対する補助代替コミュニケーションシステムが必要となる。このような補助代替コミュニケーションシステムには、補助コミュニケーションシステムと代替コミュニケーションシステムの2つの側面がある。補助コミュニケーションシステムは脳から運動神経に対する信号を使

用してコミュニケーションを図るシステムで、用いられる信号には眼電図や筋電図などがある。TLSになる前のALS患者であれば、眼球などの運動神経が障害されていないために補助コミュニケーションシステムは有効であるが、TLSに至ると運動神経が障害されてしまうために使用できない。これに対して、代替コミュニケーションシステムであれば脳波などの生体信号を使用するため、運動神経が障害による影響がなく、TLS患者に対しても使用することができる。これらのことから、現在代替コミュニケーションシステムに関する研究が盛んに行われており、眼球運動を利用したもの<sup>[2]</sup>や、脳波を利用したブレインコンピューターインターフェース(Brain Computer Interface:以下、BCI)などがある。

##### 1.2 SSVEP を利用した BCI

BCIとは、脳波(Electroencephalogram:EEG)などの脳機能を反映する生体信号から機能状態を推定することで、ユーザの意志を汲み取ることを目的とするシステムである。BCIに使用される脳波にはP300やN100など様々な種類があるが、本稿では処理時間の点で有利な定常状態視覚誘発電(Steady State Visual Evoked Potential:以下、SSVEP)に注目した。SSVEPは連続的な

\*<sup>1</sup>東海大学大学院 工学研究科 医用生体工学専攻 修士課程

\*<sup>2</sup>東海大学 工学部 医用生体工学科 助教

\*<sup>3</sup>東海大学 基盤工学部 医療福祉工学科 准教授

\*<sup>4</sup>東海大学 工学部 医用生体工学科 教授

点滅光を刺激として提示することで出現し、点滅光の周波数と同じ周波数成分における脳波のパワースペクトルが上昇する。したがって、どの周波数成分における脳波のパワースペクトルが上昇したかを確認すれば、異なる周波数の刺激を複数提示したとしても、ユーザがどの提示周波数の刺激に注意を向けているのか判別することができる。SSVEP を使用する利点として以下の3つが挙げられる。1 点目は、SSVEP は点滅刺激という外部刺激によって生じるため、被験者に依存しない安定した測定が可能である。2 点目は、BCI の中にはユーザが使用する前にトレーニングを要求するものもあるが、SSVEP を使用した BCI であればユーザに点滅光に注意を向けてもらうだけでユーザの意図を抽出できるため、トレーニングが必要ないことである<sup>[3]</sup>。3 点目は、上述した BCI に使用される P300 や N100 などの脳波は、データの処理方法として加算平均が用いられるためデータ処理に一定の時間を要するが、SSVEP であれば高速フーリエ変換(Fast Fourier Transform: 以下、FFT)によって解析できるため、データの処理時間を P300 や N100 の場合よりも短縮することができる。

### 1.3 本研究の目的

我々はこれまで、刺激のための点滅光としてチェッカーボードパターン刺激を使用した SSVEP による BCI の研究を行ってきた<sup>[4]</sup>。この研究においては、3Hz と 6Hz の 2 種類の周波数のチェッカーボードパターン刺激を用意し、5つの条件で提示した際に、チェッカーボードパターン刺激のサイズが 8×8 と 32×32 のどちらのほうがユーザの注意している刺激をより判別できるかについて調査した。この結果、8×8 のほうが 32×32 よりもほとんどの条件で判別において効果的であることが分かった。そこで、実用的な BCI システム構築に向けて、8×8 のサイズにてチェッカーボードパターン刺激を提示して測定した SSVEP を、高精度で分類できる深層学習モデルの構築を試みた。

深層学習モデルを適用したのは、SSVEP の誘発電位の大きさが視覚や強度などの刺激条件によって変化してしまう<sup>[5]</sup>ことを考慮したためである。SSVEP の分類手法には、FFT の振幅を比較する手法<sup>[5]</sup>や、機械学習による手法<sup>[6]</sup>、深層学習による手法<sup>[7]</sup>がある。従来行われてきた FFT の振幅を比較する手法の場合、実用性を考慮すると刺激条件を一定にすることは困難であるため、SSVEP の振幅の変化によっては分類精度が低下してしまう可能性があり、信頼性は高くないと考えられる。また機械学習による手法の場合、解析者自らが判別に有意な特徴量を抽出する必要があり、判別に有意でない特徴量を抽出し

機械学習で学習させても高精度で分類することはできない。このため、SSVEP が刺激に対して同期しないような場合には、機械学習による判別は困難となってしまう。したがって、刺激条件や周囲の環境などを一定にできる保証のない実環境での使用を想定すると、機械学習による分類も振幅を比較する手法と同様に信頼性は高くないと考えられる。これらの手法に対し、深層学習であれば特徴量を解析者が抽出する必要はなく、深層学習モデルが特徴量を自動で抽出し学習することができるため、ロボラスティックのある分類を可能にすることができる<sup>[7]</sup>。これらのことから、客観的な決定に向けた検討として深層学習モデルの適用を試みた。深層学習を用いて SSVEP の分類を行っている研究は本研究以外にもある。

Nicholas らの研究では、1 秒間に相当するデータを使って深層学習モデルに入力し、12 クラス分類を行っている<sup>[7]</sup>。しかし、深層学習では1秒間に相当するデータを用いて学習を行った場合、未知のデータを入力して判断する際にも1秒間に相当するデータでしか判断することができない。よって、この深層学習モデルで BCI システムを構築すると、ユーザは1秒間刺激に注意を向けただけでモデルによる分類結果が出力されることになる。実際のシステムを想定した場合、1秒間や2秒間などの短時間でも注意を向けるだけで結果が出力されてしまうのはユーザによってかえって不便であると考え、本研究では、8×8 のチェッカーボードパターン刺激を 3Hz と 6Hz の 2 種類用意し、対提示し片方だけに注意を向けさせた際の 10 秒間に相当する脳波を深層学習モデルに学習させることで、ユーザが不便と感じない程度の短時間かつ高精度でユーザが注意している刺激を判別可能な効率的な BCI システムの構築を行うことを目的とする。

## 2. 深層学習

### 2.1 深層学習とは

機械学習の1手法にパーセプトロンがある。パーセプトロンは、バイアスと入力信号それぞれに対する重みを適切な数値にすることで入力信号の分類を行うことを目的とするモデルである。パーセプトロンの問題点としては重みとバイアスを手動で変更しなければならず、層が多層になればなるほど適切な数値を見つけ出すのに時間を要してしまうことである。そこで、重みやバイアスのようなパラメータの最適な数値を自動で学習できるようにしたものニューラルネットワークであり、ニューラルネットワークの層を多層にして能力を高めることで、入力データに含まれる抽象度の高い特徴量も自動で学習できるようにしたもの深層学習である<sup>[8]</sup>。

## 2.2 畳み込みニューラルネットワーク

深層学習のモデルの1つに畳み込みニューラルネットワーク(Convolutional Neural Network:以下、CNN)がある。CNNは畳み込み層とプーリング層と呼ばれる2つの特徴的な隠れ層を持つモデルで、畳み込み層により入力データから局所的な特徴量を抽出し、プーリング層により特徴量の位置ずれに対してロバストになる<sup>[8]</sup>。画像認識において高い性能を持つため画像認識の分野で用いられることが多かったが、最近では時系列データである脳波に対して応用される報告例もみられるようになった<sup>[9]</sup>。

### 2.2.1 畳み込み層

畳み込み層では、入力データに対してフィルタを畳み込むことで、画像処理の「フィルタ演算」に相当する処理を行う。チャンネル数 $c$ の三次元配列データに対してサイズが $m \times n \times c$ のフィルタを1つだけ畳み込むことで、 $i \times j \times 1$ の三次元配列データを作成する場合を考える。入力するデータを $X$ 、フィルタを $F$ 、生成されたデータを $G$ と表現すれば、畳み込み演算の式は以下のようになる。

$$G(i, j, 1) = \sum m \sum n \sum c X(i - m, j - n, c) F(m, n, c) \dots (1)$$

式1で、左辺の生成されたデータ $G$ のチャンネル数 $c$ を1としているが、これは畳み込み層のフィルタ数を1つだけにしたことを意味する。畳み込み層では、チャンネルごとに対応するフィルタを畳み込み、得られた出力を最終的に全チャンネルで合算するため、入力データが複数チャンネルであったとしても、フィルタ数を1にすれば出力データのチャンネル数は1チャンネルになる。畳み込み層におけるフィルタの数は複数用意することができるため、フィルタを $k$ 個使用した場合の出力データ $G$ は $G(i, j, k)$ となる。さらに出力 $G$ のチャンネルごとにバイアスが存在するため、畳み込み層の最終結果は以下のようになる。 $b(k)$ は $k$ チャンネルにおけるバイアス、 $F(m, n, c, k)$ はフィルタ数 $k$ 、チャンネル数 $c$ 、サイズが $m \times n$ のフィルタである。

$$G(i, j, k) = \sum m \sum n \sum c X(i - m, j - n, c) F(m, n, c, k) + b(k) \dots (2)$$

式2の左辺である畳み込み層の出力 $G(i, j, k)$ を特徴マップと呼び、入力データから局所的な特徴量を抽出した三次元データとなる<sup>[8]</sup>。

### 2.2.2 プーリング層

プーリングの方法にはAverageプーリングとMaxプーリングの2種類がある。Averageプーリングでは前層からの入力データに対して対象領域の平均を計算し、Maxプーリングでは対象領域の最大値を抽出する。本稿ではMaxプーリングについてのみ述べることにし、以降「プーリング」とはMaxプーリングを示すことにする。特徴量の小さなズレが生じて、プーリングの対象領域内であれば同様な結果を返すため、特徴量の位置ずれに対してモデルがロバストなものとなる<sup>[8]</sup>。

## 2.3 BCIと深層学習

SSVEPを使用したBCIでは、高精度での判別をできるようにする目的で、サポートベクターマシン(Support Vector Machine:以下、SVM)<sup>[6]</sup>や正準相関解析(Canonical Correlation Analysis:以下、CCA)<sup>[10]</sup>などの機械学習が用いられることがある。しかし、機械学習では得られたデータから特徴量を解析者自ら抽出する必要があり、特徴抽出のための専門知識が要求される。またすでに述べたようにSSVEPが刺激に同期しないような場合には、機械学習に入力させる特徴量抽出が困難となる。

これらのことから、機械学習によって高精度での判定をできるようにするためには、SSVEPに関する知識と判別に寄与する特徴量抽出に費やす時間が必要となる。これに対して、深層学習であれば自律的に特徴量を抽出させることができるため、処理時間を削減することができ、かつ機械学習と同等の精度での判定も可能となる。深層学習モデルとしてCNNを採用した理由は、局所的な特徴量を抽出できるという点がSSVEPの判定において有利に働くと考えたからである。SSVEPは点滅刺激の周波数に同期して現れるが、点滅刺激の周波数に完全に一致しているとは限らず、明瞭なスペクトルピークをなさない場合もあるため、局所的な特徴量を抽出でき、かつ特徴量の位置ずれに対してロバスト性のあるCNNは解析に有効であると考えられる。

## 3. 実験方法

被験者は健康人20名(男性:19名、女性:1名)で、平均年齢は22歳である。brain vision V-AMP(BRAIN PRODUCTS製)を使用してシールドルーム内で脳波の測定を行った。電極は10-20法に基づきC3, C4, P3, P4, O1, O2に配置し、両耳朶を基準とした単極導出を行った。サンプリング周波数は100Hzに設定し、測定した脳波データに0.53~30Hzのバンドパスフィルタをかけた。刺激には8×8の区画数のチェッカーフラグを反転させる

チェッカーボードパターン刺激を用い、刺激の色は白と黒の2色にした (Fig. 1)。刺激の色に白と黒の2色にしたのは、ALS 患者に対してこの二色で刺激を提示したときのほうが高い精度を得られたという Ryan らの結果に基づくものである<sup>[11]</sup>。チェッカーフラグは 3Hz と 6Hz の二種類の周波数で反転させた。3Hz と 6Hz にしたのは脳波の  $\alpha$  成分である 8~13Hz を避けるためである。




Fig. 1 チェッカーボードパターン刺激

Fig. 1 の刺激を使用して、表 1 のようなプロトコルで実験を行った。

表 1 実験プロトコル

測定条件	安静閉眼	休憩	安静開眼	休憩	単独提示 (3)	休憩	単独提示 (6)	休憩	単純対提示	休憩	対提示 (3)	休憩	対提示 (6)
時間	2 分間	1 分間	2 分間	1 分間	2 分間	1 分間	2 分間	1 分間	2 分間	1 分間	2 分間	1 分間	2 分間

チェッカーボードパターン刺激を用いた実験を行う前に安静閉眼と安静開眼時の脳波をベースラインとして記録した。表 1 の単独提示では 3Hz もしくは 6Hz の片方のみを提示する条件で、() 内の数字は刺激の周波数を表している。単純対提示とは 3Hz と 6Hz の 2 つの刺激を対提示 (3Hz と 6Hz の 2 つの刺激を同時に提示) してはいるが、被験者にどちらの刺激も注意を向けさせない条件のことである。対提示の () 内の数字は被験者が注意を向けている刺激周波数を表している。

各条件における測定時間は 2 分間、各測定条件間には 1 分間の休憩をはさむようにした。単独提示、単純対提示、対提示のどの条件でも、被験者に対してシールドルーム内に設置したモニタにより刺激を提示しながら脳波測定を行った。モニタは目の高さに配置し、被験者とモニタまでの距離は 50cm とした。被験者に提示する刺激は刺激と背景のコントラストを明確なものとするために、背景色には刺激色と異なる緑色を採用した (Fig. 2)。




Fig. 2 対提示時の刺激  
(左図:3Hz、右図:6Hz)

#### 4. 解析方法

##### 4.1 前処理

解析には表 1 の測定条件のうち、対提示 (3) と対提示 (6) 中に測定した脳波だけを使用した。この 2 つの測定条件のみのデータを使用したのは、実際に BCI システムとして使用することを想定した場合に、対提示で刺激を提示してもユーザが注意を向けている刺激を分類できるほうが望ましいと考えたためである。brain vision V-AMP により得られた脳波を解析してから深層学習に投入、学習させるまでの一連の処理は python で作成したプログラムによって行った。初めに C3, C4, P3, P4, O1, O2 から得られた脳波データに、両耳を基準としたリモンタージュを行った。リモンタージュ後のデータから 10 秒間に相当する 1000 点ずつデータを重ならないよう抽出することで、2 分間の測定データを 12 個のユニットに分けた。ユニットごとの平均値を減算することで直流成分を除去し、その後ハニング窓をかけ、FFT によりパワースペクトルを求め、得られたパワースペクトルに対して式 (3) で表される標準化を、全てのユニットに対して行った。X は標準化により得られたデータ、x は入力データ、 $\mu$  は平均値、 $\sigma$  は標準偏差を示している。

$$X_i = \frac{x_i - \mu}{\sigma} \quad \dots (3)$$

これらの処理を全被験者の全電極データに対して行った。

##### 4.2 学習及び評価方法

奥行きを電極数 (チャンネル数)、行をパワースペクトル値、列を周波数とする三次元データを 1 つの入力データとして、これを 4.1 の方法で処理した全被験者のデータで作成した。1 つの入力データの形状は Fig. 3 のように

(チャンネル数=6, 行=1, 列=500)となる。




Fig. 3 入力データの形状

全入力データを k-分割交差検証によって訓練データと検証データに分割し、学習及び評価を行った。k-分割交差検証では全入力データを k 個に分割し、1つを検証データ、残りの k-1 個のデータを学習データに分割して学習及び評価を行うことを k 個に分割したデータ全てが検証データになるまで繰り返す。そして k 回の学習及び評価によって得られた k 個の学習データに対する精度、k 個の検証データに対する精度それぞれの平均を算出することで、学習データに対する精度と検証データに対する精度を求める。本研究では入力データを 10 個に分割したため、10-分割交差検証となる。k-分割交差検証ではホールドアウト法と比べれば正確な精度を得られるが、測定毎に精度にばらつきが生じるため、本研究では 10-分割交差検証による学習及び評価を 1 回のみではなく 5 回行い、5 回分の平均を算出した。

#### 4.3 CNN の構成とパラメータ設定

CNN は python の chainer を用いて構築した。構築した CNN の構成を Fig. 4 に示す。Fig. 4 の CNN は曾我らのモデル<sup>[12]</sup>を参考にして構築した。ただし、Fig. 4 では入力層は省いている。

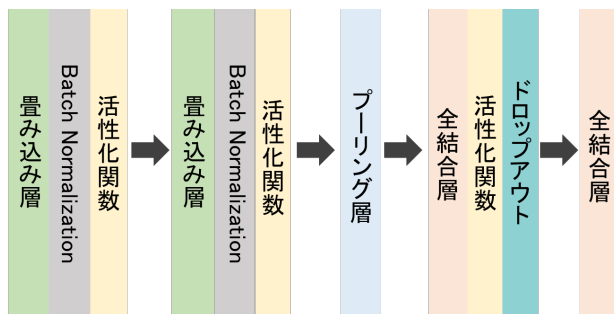


Fig. 4 CNN の構成

また、表 2 に Fig. 4 の CNN におけるパラメータと各層における出力データの形状を示す。表 2 のフィルタは出力フィルタ数、サイズはフィルタサイズを示している。

フィルタサイズ及びストライドの () 内の数字は、左の数値が行方向、右の数値が列方向を示しており、フィルタサイズが (1, 4) であれば行方向に 1、列方向に 4 の大きさであることを意味し、ストライドが (1, 4) であれば行方向に 1 つ、列方向に 4 つ分ストライドを行うという意味である。2 次元で表現しているのは、プログラムでは 2 次元的にフィルタサイズやストライドを設定したためである。出力は全結合層を除きチャンネル数×行数×列数の 3 次元で表現した。

表 2 各層のパラメータ及び出力

層の種類	フィルタ	サイズ/ ストライド	出力
畳み込み	2	(1, 1)/(1, 1)	2×1×500
畳み込み	2	(1, 4)/(1, 4)	2×1×125
プーリング		(1, 3)/(1, 2)	2×1×62
全結合			32
全結合			2

1 つ目の畳み込み層ではチャンネル数の削減を行い、2 つ目の畳み込み層では周波数軸方向に重ならないようにフィルタを適用することでダウンサンプリングを行っている。各畳み込み層の出力に対して Batch Normalization を行うようにした。活性化関数には ReLU 関数を採用した。過学習の低減と精度の向上を目的として、プーリング層では周波数軸方向に重なるようにフィルタサイズとストライドを設定しプーリングを行った<sup>[12]</sup>。全結合層の中間層における出力に対して 50% ドロップアウトを行った。全結合層の出力層におけるノード数を 2 としているのは、刺激を対提示した際に、3Hz の刺激に注意を向けさせた場合の脳波と、6Hz の刺激に注意を向けさせた場合の脳波の 2 値分類を行うためである。最後に、全結合層の出力層からの出力に対してソフトマックス関数を適応させた。エポック数を 500、バッチサイズを 32、Weight decay を 0.01 に設定し、更新手法には Adam を使用した。学習率はデフォルトのまま行った。

#### 5. 結果

分類精度の指標には Accuracy を使用した。Accuracy は以下の式のように表現される<sup>[13]</sup>。

$$\text{Accuracy} = \frac{TP+TN}{\text{全サンプル}} \dots (4)$$

真陽性 (True Positive: TP) は実際に陽性であるもののうち、陽性であると判定されたサンプルの割合のことで

あり、真陰性 (True Negative:TN) は実際に陰性であるもののうち、陰性であると判定されたサンプルの割合のことである。Accuracy が 1(100%)に近づくほど正答率が高いことを意味し、0(0%)に近いほど正答率が低いことを意味する。

5 回分の 10-分割交差検証によって得られた学習データに対する精度と、検証データに対する精度を表 3 にまとめた。

表 3 学習データ及び検証データに対する 5 回分の精度

回数	学習[%]	検証[%]
1	87.9	81.7
2	90.0	85.6
3	80.6	74.0
4	86.6	80.7
5	88.3	81.2

表 3 の 5 回分の学習データに対する精度の平均値を求めると 86.7%、検証データに対する精度の平均値を求めると 80.6%であった。

## 6. 考察

検証データに対する精度の中で最も高い精度を得られたのは 2 回目の 85.6%、最も低いのは 3 回目の 74.0%と、10%程度異なっていた (表 3)。この原因としては、入力データは個人内であっても性質に幅広いばらつきがあることが考えられる。学習データからバッチサイズずつ取り出す際にランダムに取り出しているが、入力データが大きな分布を持っているために、取り出したデータのばらつきも大きくなってしまおうと収束が困難になり精度が低くなっている可能性がある。また、一般に脳波は個人差などで分散が大きいので、入力データが大きな分布を持つことは予測されたことから、本研究ではデータの分割方法に k-分割交差検証を採用した。深層学習に対する入力データの分割方法として広く使用されているものにホールドアウト法がある。ホールドアウト法では全入力データのうち任意の割合のデータを学習データに分けて、残りを検証データに分ける方法で、学習と評価は 1 度しか行われぬ。このため入力データの分散が大きい場合にホールドアウト法でデータを分割すると、分割されるデータによって精度が大きく異なってしまう、正しい汎化性の評価ができない。これに対して、k-分割交差検証では全ての分割データが検証用データになるまで k 回学習と評価を繰り返し平均することで精度を算出するため、汎化性を正確に評価することができる。加え

て 10-分割交差検証による学習及び評価を 1 回だけでなく、5 回行ってその平均を求めて精度としたため、より正確な汎化性の評価を行えたと考えられる。

## 7. 結論

本研究では被験者が不便に感じない程度のリアルタイムに近い判定を実現するための検討として 1 つの入力データを 10 秒間に設定し、SSVEP の判定を行った。検証データに対して平均で 80.6%と 2 値分類としては比較的良好な精度が得られた。しかし、より実用的な BCI システムの構築のためにはさらなる精度の向上が必要となるだろう。今後はさらに高い精度を得るために、モデル構成の再検討と十分な入力データ数を得るための augmentation の実装を行っていきたい。

## 8. 謝辞

本研究の一部は、公益財団法人フジクラ財団の研究助成を受けて行われた。ここに記して深謝いたします。

## 9. 文献

- [1]加納尚之. 完全閉じ込め症候群(TLS)となった ALS 患者のコミュニケーション-脳波(ERP)を用いた Android スマートフォンアプリの開発-. 看護理工学会誌. 2019, 6 巻 (2), p. 63-69
- [2]R. Spataro, *et al.* . The eye-tracking computer device for communication in amyotrophic lateral sclerosis. Acta Neurologica Scandinavica. 2014, Volume 130, p. 40-45  
DOI:10.1111/ane.12214
- [3]脇田健哉、船瀬新王、内匠逸. チェッカーボードの格子サイズと SSVEP の関係性. 生体医工学. 2015, 53 巻 (Supplement), p. S446-S449  
DOI: <https://doi.org/10.11239/jsmbe.53.S446>
- [4] Ingon Chanpornpakdi, *et al.*. Fundamental study on noninvasive BCI communication using checkerboard pattern reversasl stimulus. Proceedings of International Conference On Interfaces and Human Computer Interaction 2019
- [5]松井大輔、霧 浩二. 定常状態視覚誘発電位を用いたブレインコンピューターインタフェースの性能向上と測定システムに関する研究. 大分工業高等専門学校紀要. 2015, 52, p. 27-36

[6]Mohammadreza Asghari Oskoei, John Q Gan, Huosheng Hu. Adaptive schemes applied to online SVM for BCI data classification. Proceedings of the 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 2009, p. 2600-2603

[7]Nicholas Waytowich, *et al.*. Compact convolutional neural networks for classification of asynchronous steady-state visual evoked potentials. Journal of Neural Engineering. 2018, Volume 15(6)  
DOI:10.1088/1741-2552/aae5d8

[8]斎藤康毅『ゼロから作る Deep Learning python で学ぶディープラーニングの理論と実装』株式会社オーム社. 2018 年, p. 298

[9] Nhan Duy Truong, *et al.*. Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram. Neural Networks. 2018, Volume 105, p. 104-111  
DOI: <https://doi.org/10.1016/j.neunet.2018.04.018>

[10]Suefusa K, Tanaka T. Asynchronous brain-computer interfacing based on mixed-coded visual stimuli. IEEE Transactions on Bio-medical Engineering. 2017, 65(9), p. 2119-2129

[11]D. B. Ryan, *et al.*. Enhancing brain-computer interface performance in an ALS population: checkerboard and color paradigms. Proceedings of the Fifth International Brain-Computer Interface Meeting 2013  
DOI:10.3217/978-3-85125-260-6-26

[12]曾我洋史ら. 脳波解析における畳み込みニューラルネットワークの適用. DEIM Form. 2018, C3-1

[13]Ihsan Ullah, *et al.*. An automated system for epilepsy detection using EEG brain signals based on deep learning approach. Expert Systems with Applications. 2018, Volume 107, p. 61-71