

# チャンネル間相関低減を用いたブレインコンピュータ インタフェースの性能の向上

著者	西山 幸孝, 平野 晃宏
雑誌名	第31回信号処理シンポジウム講演論文集 = Proc. of 31th SIP Symposium
巻	2016
ページ	376-380
発行年	2016-11-07
URL	<a href="http://hdl.handle.net/2297/46404">http://hdl.handle.net/2297/46404</a>

# チャンネル間相関低減を用いたブレインコンピュータインタフェースの性能の向上

## Performance Improvements of Brain Computer Interface Using Correlation Reduction Between Channels

西山幸孝 平野晃宏  
金沢大学 自然科学研究科 電子情報科学専攻

Yukitaka NISHIYAMA Akihiro HIRANO  
Kanazawa University

### アブストラクト

本稿では、脳波計の電極間の距離によって生じる脳波の到来時間差を用いてブレインコンピュータインタフェースの性能を向上させる方法を提案する。どの電極へ脳波が最も早く到達するかという特徴を、各チャンネルの到来時間が早い脳波を抽出しチャンネル間相関低減を行うことで強調する。これまでに提案された Gram-Schmidt の直交化を用いたチャンネル間相関低減とは異なり直交化の順による多数の組み合わせを検証する必要のない、適応フィルタを用いたチャンネル間相関低減を用いることで学習に要する時間を少なくする。分類精度の正誤比を最大 0.013 改善した。

### 1 はじめに

現在、人間とコンピュータをつなぐインタフェースとして、キーボードやマウスなど、様々なものが使用されている。最近では音声や視線など生体に関わるものをインタフェースとして用いることも多くなっている。そのような中で、近年、注目されているのが、ブレインコンピュータインタフェース (Brain Computer Interface : BCI) である。

BCI は脳から得られる情報を利用して、思考によりコンピュータなどの機器を操作しようというものであり、これは人間とコンピュータの間における究極のマンマシンインタフェースであると言える。脳から得られる情報としては、脳波計で計測される脳波 (EEG) がよく用いられる。脳波はその性質上、日常生活の様々な場面において特徴的な波形を検出することができる。BCI の技術を応用することにより、重度の運動障害を抱える患者の生活の質 (Quality Of Life : QOL) を向上させることが可能である。

BCI を実用化させるには高い分類精度があるとともに、

処理時間を短くすることが必要となる。従来、分類精度を向上させるために脳波を Gram-Schmidt の直交化を用いてチャンネル固有の特徴量を抽出するという方法が用いられている [1]。しかし、分類精度の向上は Gram-Schmidt 直交化の順番に大きく依存するため順番の組み合わせが多数あり、その中から最適な順番を見つけることが困難であり、多くの時間が必要となる。

そこで本研究では、適応フィルタを用いてチャンネル固有の特徴量を強調するとともに、更なる分類精度の向上を目指す。第二節では BCI の概要を示し、第三節で従来の Gram-Schmidt 直交化を用いた BIC について説明する。第四節で適応フィルタを用いた BCI の方法を提案し、第五節で従来法と提案法の性能評価と比較を行う。

### 2 ブレインコンピュータインタフェースの概要

BCI は脳から得られる情報を機器の操作に繋げるシステムであり、その流れは大まかに Recording (脳波測定)、PreProcessing (前処理)、Feature Extraction (特徴抽出)、Feature Classification (特徴分類)、Device Control (機器の操作) の 5 つである [2][3]。

#### 2.1 脳波測定

BCI では、まず始めに被験者の脳波を計測する。分類が容易な事項 (メンタルタスク) をイメージさせ、その時の脳波を計測する。脳波の測定法には大きくわけて頭皮に電極を装着して測定する非侵襲性のものと直接皮下に電極を刺入するものの 2 種類がある。

#### 2.2 前処理

測定された脳波データは、脳波以外の信号や雑音が混入する。脳波を分類するにあたり、余計な情報が含まれていると、分類精度が低下するだけでなく、計算量や計算時間の増加にもつながる。これらを除去するために、また、信号のフィルタリングや増幅のために前処理を行う。

## 2.3 特徴抽出

ユーザーが考えていることを推定するために、測定した脳波から特徴量を抽出する。測定した脳波データの波形分類として、フーリエ変換の振幅スペクトルや自己回帰モデル係数など、多くの特徴量抽出方法が用いられてきた。分類の精度を向上させるためには、有効な特徴量を抽出することが重要である。

## 2.4 特徴分類

脳波から抽出した特徴に基づいて、ユーザが想起したメンタルタスクを推定する。分類器としては、ニューラルネットワーク [4] などが用いられる。

## 2.5 機器の操作

特徴分類で用いた分類器の分類結果を使って、実際に機器を操作する。しかし、分類結果によってはリジェクト (判定不能) となり、操作が行なわれない場合もある。

## 2.6 BCI の問題点

BCI に存在する問題点として、脳波の変化、学習期間の長さ、フィードバックの退屈さ、速さ・精度などの有用性があげられる。BCI の実用上、この中でも学習時間の長さや分類の精度は特に大きな問題となる。

## 3 多チャンネル脳波の直交化を用いた BCI [1]

図 1 に BCI に用いられる脳波データの一例を示す。コロラド州立大学が公開しているもので、5 種類のメンタルタスクに対応している。




図 1: 脳波データ

脳波をニューラルネットワークの入力データにするに当たり、特徴抽出を行なう。チャンネル間の相関除去を行い分類精度を上げる方法として Gram-Schmidt の直交化が知ら

れており、抽出した脳波に対してこの処理を行う。Gram-Schmidt の直交化法は線形独立なベクトルの組を互いに直交するベクトルの組にするものであり、以下の式で表される。ある線形独立なベクトルの組を  $x_1, x_2, x_3, \dots, x_k$  とし、以下の手順で直交化する。

$$v_1 = x_1 \quad (1)$$

$$v_2 = x_2 - \frac{v_1^T x_2}{v_1^T v_1} v_1 \quad (2)$$

$$v_3 = x_3 - \frac{v_1^T x_3}{v_1^T v_1} v_1 - \frac{v_2^T x_3}{v_2^T v_2} v_2 \quad (3)$$

⋮

$$v_k = x_k - \sum_{i=1}^{k-1} \frac{v_i^T x_k}{v_i^T v_i} v_i \quad (4)$$

こうして得られた  $v_1, v_2, v_3, \dots, v_k$  は互いに直交するベクトルの組となる。

脳波を分類する上での特徴量として、前述の各セグメントごとに、脳波をフーリエ変換して得られるパワースペクトルの振幅を用いる。図 2 に脳波スペクトルの一例を示す。




図 2: フーリエ変換の振幅

フーリエ変換により得られるパワースペクトルをそのまま入力データとしてしまうのではサンプル数が多く、サンプル数が多いと入力ユニットが多くなる、計算に時間がかかる、メモリの消費が多くなるといった問題がある。この問題を解決するために、サンプル数を低減させる。パワースペクトルは対称なので入力には周波数帯域の半分だけを用いる。また計算時間削減のためにも、フーリエ変換により算出された値を、連続する複数サンプルで平均することにより、1ch 分のサンプル数を 10 サンプルまで低減させ、それを 7ch 分並べたものを図 3 に示す。

図 3 より小さな値をもつサンプルが多いことがわかる。このままでは値の小さな部分の特徴が有効に利用されない。そこで小さな値を伸長し、大きな値を圧縮するため




図 3: サンプル平均化

に、式 (5) を用いて、非線形な正規化を行なう。用いる非線形関数を図 4 に、図 3 のデータを非線形正規化したものを図 5 にそれぞれ示す。これをニューラルネットワークへの入力データとする。

$$y = \log(x - \min + 1) / \log(\max - \min + 1) \quad (5)$$




図 4: 非線形正規化関数




図 5: 非線形正規化後

その後、ニューラルネットワークを用いた教師あり学習を行い、脳波を分類する。

上記の Gram-Schmidt の直交化を利用した BCI は、直交化するチャンネルの順番に分類精度が大きく依存してい

るが、直交化順の数が非常に多いため、最適な順番を見つけることが困難であり、処理に多大な時間が必要となる。

そこで本研究では、適応フィルタを用いて脳波から各チャンネルの到来時間が最も早い脳波を抽出してチャンネル間の相関除去を行う方法を提案する。

## 4 適応フィルタを用いたチャンネル間相関除去

### 4.1 メンタルタスク固有の特徴抽出

メンタルタスクの分類精度を向上させるためには各メンタルタスク固有の特徴を抽出することが重要である。脳は使用目的によって使用する領野が異なり、体性感覚野、前運動野、言語野などに区別されている。そこで、メンタルタスクごとに使用する脳の領野に特徴があると推測し、チャンネル間で相関除去することで各チャンネルの特徴が強調され、それに伴いメンタルタスクの特徴が強調されることを期待する。

本稿では、各チャンネルに対して到来時間が最も早い脳波を取り出しそれ以外の脳波を低減する方法を検討する。16 倍にオーバーサンプリングした脳波のチャンネル間相互相関を図 6 に示す。これより、16 分の 1 サンプル程度の時間差があることがわかる。信号の遅延が 1 サンプル以上にするために、信号を 16 倍にオーバーサンプリングしてチャンネル間の相関低減を行う。




図 6: 16 倍オーバーサンプリング後の Ch1 と Ch6 の相関関数

### 4.2 チャンネル間の相関低減

図 7 に相関低減回路を示す。入力  $X_1(n)$  から、他のチャンネル  $X_2(n)$  から  $X_6(n)$  と相関のある成分を取り除く。  $X_2(n)$  から  $X_6(n)$  には遅延  $T$  が挿入されているため、  $X_1(n)$  に最も早く到達した成分のみを取り出せる。 Ch7 は目の電気的な活動(まばたき等)を測定するチャンネルで

あり、他のチャンネルよりも信号が大きい。そのため、チャンネル間相関低減は行わない。

また、以下のパラメータを可変数とする。

- フィルタ係数の数 (タップ数) :  $N$
- ステップサイズ :  $\mu$




図 7: NLMS フィルタを用いた相関低減

可変パラメータを以下のように設定し、NLMS フィルタを用いて相関低減した脳波 (赤) と相関低減前の脳波 (青) を図 8 に示す。また、相関低減した脳波を従来の前処理を適用してニューラルネットワークへの入力データを作成する。このときのニューラルネットワークの入力データを図 9 に示す。このとき、パラメータを以下のように設定する。

- フィルタ係数の数 (タップ数) :  $N=4$
- ステップサイズ :  $\mu=0.01$

図 8 は上から順に Ch1~Ch6 が並んでいる。相関低減後の脳波はすべてのチャンネルで信号が小さくなっておりチャンネル間の相関が低減されていることがわかる。また、図 9 より、ピークに注目してみると相関低減前よりも低減後のほうが少しチャンネル間の差異が分かりやすい。

## 5 性能評価

本研究ではコロラド州立大学が公開している脳波を用いている。Baseline, Multiplication, Letter-Composing, Rotation, Counting という 5 種類のメンタルタスクがあり、各メンタルタスクにに対して 10 回ずつ測定を行なっているため、合計 50 個のデータセットがあり、このうち 40 個 (各タスク 8 個ずつ) を学習に、残りの 10 個 (各タスク 2 個ずつ) をテストに用いる。学習・テストデータの組合せを変えて、5 回シミュレーションを行ない、その平均値で分類性能を評価する。




図 8: 青:相関低減前の脳波/赤:相関低減の脳波




図 9: 青:相関低減前の脳波/赤:相関低減後の脳波

### 5.1 各種パラメータの設定

以降のシミュレーションにおいては、ニューラルネットワークのパラメータを以下のように設定する。

- 学習率  $\eta$ : 0.2
- 結合荷重の初期値: -0.1~+0.1 の範囲でランダム
- 学習回数: 5000 回
- リジェクトのための閾値: 0.8

また前章より、NLMS フィルタの可変のパラメータを以下のように設定してシミュレーションを行った。

- フィルタ係数の数 (タップ数) :  $N=2,4,6,8,16$
- ステップサイズ :  $\mu=1,0.1,0.01$

## 5.2 分類結果

$N=4, \mu = 0.1$  の時の分類結果について性能評価を行う。

- 従来法

表 1: 各被験者のテストデータに対する分類性能

被験者	正答率 [%]	誤答率 [%]	比
被験者 1	62.0	8.0	0.886
被験者 2	46.0	20.0	0.697

- 提案法

表 2: 各被験者のテストデータに対する分類精度

被験者	正答率 [%]	誤答率 [%]	比
被験者 1	62.0(↑ 0.0)	4.0(↓ 4.0)	0.939(↑ 0.053)
被験者 2	44.0(↓ 2.0)	18.0(↓ 2.0)	0.710(↑ 0.013)

このとき、

$$\text{正答率} = \frac{\text{正答数}}{\text{全データ数}} \quad (6)$$

$$\text{誤答率} = \frac{\text{誤答数}}{\text{全データ数}} \quad (7)$$

$$\text{比} = \frac{\text{正答率}}{\text{正答率} + \text{誤答率}} \quad (8)$$

である。

従来法と提案法の分類結果を比べてみると、被験者 1 は正答率は変わらず誤答率が下がったため比は向上し、被験者 2 は正答率は下がったが誤答率も下がったため比は向上した。

## 6 まとめ

BCI において各チャンネルの到来時間の早い脳波を取り出すことでチャンネル固有の特徴を抽出する方法を提案した。到来時間の早い脳波を取り出すために適応フィルタで相関除去を行った。提案法により NLMS フィルタのパラメータを  $N=4, \mu=0.1$  とした場合に被験者 1 の正誤比と被験者 2 の正誤比が向上した。しかし、NLMS フィルタのパラメータの設定次第で分類精度にばらつきがみられ、被験者によって分類精度が向上したパラメータが異なったため、パラメータ設定にはさらなる検討が必要となる。また、NLMS フィルタ以外の相関除去の方法についても更なる検討が必要である。

## 参考文献

- [1] 堀田大貴, 中山謙二, 平野晃宏, ”脳波のチャンネル間直交化と階層形ニューラルネットワークの多重並列構成による BCI”, 第 24 回 信号処理シンポジウム講演論文集, pp. 390-395, Nov. 2009
- [2] Charles W. Anderson, ”Classification of Electroencephalogram Signals for Brain-Machine Interface”, <http://www.cs.colostate.edu/eeg/>
- [3] 稲垣清人, 中山謙二 ”ニューラルネットワークによる脳波に基づくメンタルタスクの分類”, 信学技法 vol.105,no.174,SIP2005-54,pp.25-30,5,2005
- [4] Akira Iwata & Toshiyuki Matsubara, ”ニューラルネットワーク入門” <http://mars.elcom.nitech.ac.jp/java-cai/neuro/menu.html>,1996