

# 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

Neural Network Based BCI by Using Orthogonal Components of Multi-Channel  
Brain Waves

堀田大貴<sup>†</sup>                      中山謙二<sup>†</sup>                      平野晃宏<sup>†</sup>  
<sup>†</sup>金沢大学大学院 自然科学研究科 電子情報工学専攻

Hiroki HORITA<sup>†</sup>                      Kenji NAKAYAMA<sup>†</sup>                      Akihiro HIRANO<sup>†</sup>

<sup>†</sup>Graduate School of Natural Science and Technology, Kanazawa Univ.

E-mail: nakayama@t.kanazawa-u.ac.jp

**アブストラクト** 直交化した脳波と階層形ニューラルネットワーク (MLNN) を多重並列構成した分類器を用いるBCIを提案する。多チャンネル脳波の特徴を強調するために、Gram-Schmidtの直交化を適用する。この手法ではICAなどで発生するパーミュテーション問題が発生しない。Gram-Schmidtの直交化では、初期のチャンネルが元の情報を多く保持し、後半のチャンネルは、それ以前のチャンネルと直交化する情報のみを有する。ゆえに、直交化するチャンネル順を変えることにより異なる特徴を持った多種類の直交化脳波データが生成される。提案法では、この多種類の直交化脳波を用いてそれぞれ分類器を構成し、並列化することにより分類を行う。更に、汎化能力向上のためにMLNNの学習時に入力に乱数を付加する方法を検討する。

**Abstract** A BCI System, in which orthogonalized EEG data sets and parallel multiple multilayer neural networks(MLNNs) are used in classifying mental tasks, is proposed. In order to emphasize feature of multi channel EEG data, Gram-Schmidt orthogonalization has been applied, which can avoid a Permutation problem appears in ICA. In the Gram-Schmidt orthogonalization process, the earlier channels can retain their own information, and the latter channels hold only the orthogonal components to the previous channels. Therefore, many kinds of orthogonalized data sets, which have different features, can be generated for one EEG data set by changing the channel order to be orthogonalized. In the proposed method, several channel orders are used to generate different kind of feature sets, which are effectively applied to multiple MLNNs. Furthermore, in order to achieve high generalization performance, a learn-

ing method, in which random numbers are added to the MLNN input data, is applied.

## 1 はじめに

近年、身体にハンディキャップを持つ人々のインターフェイスが発達する中で、ブレイン・コンピュータ・インターフェイス (BCI) が注目されている [1],[2]。BCIを実現する手法としては、パワースペクトルを用いた非線形分類、適応自己回帰モデルを用いた線形分類、空間パターンを用いた線形分類、隠れマルコフモデルなどがある [3],[4]。更に、ニューラルネットワークを用いる手法についても活発に検討されている [5],[6],[7],[8],[9],[10]。これまで、脳波 (EEG) のFFTと階層型ニューラルネットワーク (MLNN) を用いたBCIについて検討した。メンタルタスクの分類精度を向上させるための前処理も行なった [15]。更に、MLNNの汎化能力を向上させる手法についても検討を行った [16]。また、MEGを用いたBCIにおけるセンサ位置の影響についても検討している [17]。

脳波は複数センサにより多チャンネルで計測される。多チャンネルの脳波から重要な情報を抽出する手法としては独立成分分析、ブライント信号源分離など、様々な手法が提案されている [11],[12]。しかしながら、これらの手法はパーミュテーション問題により、抽出した情報を元の順番に戻すことが困難となる。よってニューラルネットワークで分類を行うには適していない。

これまでの研究では、多チャンネル脳波から直交成分を抽出するためにGram-Schmidtの直交化を適用してきた [18]。この手法ではパーミュテーション問題が生じないが、分類性能が直交化するチャンネル順に依存する。

本稿では、多重並列に構成したMLNNを用いたBCIシステムを提案する。

## 2 FFT と MLNN による BCI

### 2.1 MLNN によるメンタルタスクの分類

FFT, 前処理 (PP), MLNN, を用いた BCI のブロック図を図 1 に示す [15].  $x_i$  はチャンネル  $i$  の脳波をベクトルで表したものである. FFT の振幅をニューラルネットワークへの入力データとし,  $K$  番目の出力でメンタルタスク  $K$  を表現する. MLNN は  $K$  番目メンタルタスクの入力データに対して出力  $(y_k, y_j), j \neq k$  が  $(1, 0)$  に近づくように学習する.




図 1: BCI の流れ

### 2.2 脳波の前処理

これまで, 脳波の前処理として様々な手法が提案されており [15], 本稿で用いた手法について記述する.

脳波の時間領域での変化による影響を除去するために, 脳波を高速フーリエ変換し, その振幅を用いる. また, MLNN の計算量, 脳波に含まれる雑音の影響を低減させるために, サンプル間で平均化を行った. FFT の振幅は広く分布しており, 小さな値を持つサンプルにもメンタルタスクの分類において重要な情報が隠れている可能性がある. しかし, MLNN では大きな値を持つサンプルによる影響が大きい. そこで, 本稿では入力データに対して非線形な正規化を適用した [15].

## 3 多チャンネル脳波の直交成分

### 3.1 直交成分分析

直交成分分析の方法として, ブラインド信号源分離 (BSS), 独立成分分析 (ICA), 主成分分析 (PCA) などの手法があるが, これらの手法では, パーミュテーション問題により, 異なる試行で同じ順に成分を出力するという保証がない [11],[12]. これは直交成分を MLNN への入力データとする場合問題となる [18].

そこで本研究では Gram-Schmidt の直交化を脳波に適用する. 直交化するチャンネル順で任意に出力順を制御できるため, パーミュテーション問題は生じない.

### 3.2 Gram-Schmidt の直交化 BCI への適用

ベクトル  $\{x_1, x_2, \dots, x_M\}$  で表される  $M$  チャンネルの脳波が線形独立であるとする, これらのベクトルは Gram-Schmidt の直交化によってそれぞれ互いに直交するベクトル  $\{v_1, v_2, \dots, v_M\}$  に変換される [19].  $x_1$  を  $v_1$  とすると,  $v_2$  は  $v_1$  に直交な  $x_2$  の成分となる. 以下同様に,  $v_k$  は  $v_1, v_2, \dots, v_{k-1}$  に直交するベクトルとなる.

2.2 節で述べた方法で  $v_i$  の FFT の振幅に前処理 (PP) を行い, MLNN への入力データとする. Gram-Schmidt の直交化を用いた場合の BCI の流れを図 2 に示す.

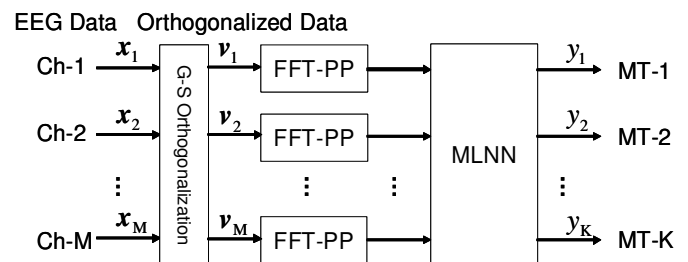


図 2: Gram-Schmidt の直交化を用いた場合の BCI

Gram-Schmidt の直交化を行う場合, 直交化を行うチャンネル順には自由度が存在する. 1 番目のチャンネルは全ての情報を保持し, 以降のチャンネルは以前のチャンネルと直交する成分のみを保持する. ゆえに, 直交化の順番はメンタルタスクの分類に影響を及ぼし, その効果について検討されている [18].

## 4 MLNN の多重並列構成

### 4.1 直交化データ $L$ 種類, $L$ 個の並列 MLNN を用いた分類

直交化するチャンネル順は, チャンネル数  $M$  に対して  $M!$  通り考えられる. すなわち, 1 つの脳波のデータセットから, それぞれ異なる特徴を持つものを複数生成することができる. これらの異なる順で直交化した脳波を用いることにより, アンサンブル識別器を構成し, BCI の精度を向上させることができる [18]. 図 3 に多重並列に構成した BCI のブロック図を示す.

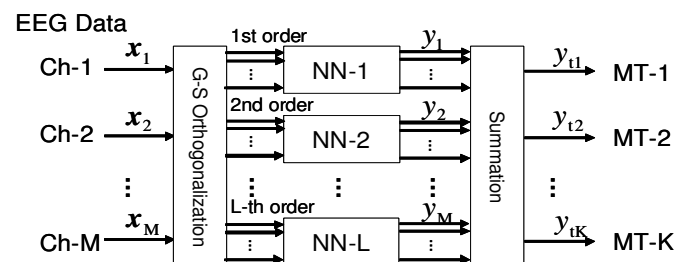


図 3: 多重並列化した MLNN による BCI

異なる順番で直交化した脳波を各MLNNに独立に入力し、学習する。そして式(1)で与えられる出力 $y_t$ を分類結果とする。

$$y_t = \frac{1}{L} \sum_{i=1}^L y_i \quad (1)$$

#### 4.2 従来法のMLNN並列化

本稿で提案する図3に示す方式では複数のMLNNを要する。従来法を用いた、これに類似する構造のものを図4に示す[20]。各MLNNは多入力単出力(MISO)となっている。NN-i,  $i = 1 \sim K$ は同じ入力データ( $x_1, x_2, \dots, x_M$ )を受け、メンタルタスクに対応する1出力を得る。つまりNN-iは入力に対して出力があるメンタルタスクのときだけ1に近づくように学習し、残りのメンタルタスクの場合は全て0に近づくように学習する。提案法が直交化した脳波を用いるのに対して、図4の方式では元の脳波をそのまま用いる。3.2節で述べたように、Gram-Schmidtの直交化では直交化する順番を変えることにより、異なる直交化データを生成することができる。つまり、チャンネルの特徴を強調し、複数のMLNNに適用できる異なる種類の特徴量を生成することができる。提案法ではこれらの二点がメンタルタスクの分類性能向上に貢献する。




図4: 多重並列化したMLNNによるBCI

#### 5 ノイズ付加による汎化能力の向上

脳波は健康状態や測定する環境によって容易に変化しやすい。よって汎化能力の向上はBCIをMLNNで実現する上で非常に重要になってくる。その手法として、本稿では汎化能力向上の手法として、学習におけるMLNNの入力データにノイズ付加を行なう[14],[16]。

### 6 シミュレーションと考察

#### 6.1 メンタルタスク

本稿では、コロラド州立大学が公開している脳波データを用いた[13]。使用しているメンタルタスクは、次の5種類である。

- できるだけリラックスする (Baseline)
- 掛け算の暗算を行なう (Multiplication)
- 手紙の文を考える (Letter)

- 回転する3次元物体を想像する (Rotation)
- 数字を順番に書くことを想像する (Counting)

#### 6.2 シミュレーション条件

##### 学習とテスト

脳波データは5種類のメンタルタスクに対して、10秒間の測定を10回ずつ行なったので、合計50セットのデータがある。このうち、40セットを学習に、残り10セットをテストに用いる。テストに用いるデータセットの選択方法を5回変えて分類を行ない、その平均値で分類を評価する[3]。

##### 推定結果の評価

メンタルタスクの推定結果は以下の式のような、正答率( $P_c$ )、誤答率( $P_e$ )、正答率と誤答率の比( $R_c$ )を用いて表す。

$$P_c = \frac{N_c}{N_t} \times 100\%, P_e = \frac{N_e}{N_t} \times 100\% \quad (2)$$

$$R_c = \frac{N_c}{N_c + N_e}, N_t = N_c + N_e + N_r \quad (3)$$

$N_c, N_e, N_r$ はそれぞれ、正答数、誤答数、リジェクトデータ数を表す。 $N_t$ はテストに用いた全データ数である。 $R_c$ はリジェクトデータ数を除いた正答率を評価するために用いる。

##### ニューラルネットワークのパラメータ

活性化関数にはシグモイド関数を用いた。隠れユニット数は20、判定不能とする出力におけるリジェクトの閾値は0.7とし、学習にはbackpropagationを用いた。

#### 6.3 直交化データを用いた分類

脳波を直交化するにあたり、計測されたチャンネル数は7チャンネルであり、そのうち1チャンネルはまばたき検出(EOG)のため固定し、残りの6チャンネルで互いに直交化を行なった。 $6! = 720$ 通りの直交化順が存在する。図5,6,7に720通りの直交化データを用いたときの正答率、誤答率、比の分布を、表3に従来法、平均値、分類性能が向上した最良値をそれぞれ示す。




図5: 直交化データを用いた分類結果:正答率




図 6: 直交化データを用いた分類結果:誤答率




図 7: 直交化データを用いた分類結果:比

表 1: 直交化データを用いた分類結果

	正答率	誤答率	比
従来法	70	10	0.875
平均	71.5	12.1	0.855
最大	84	2.0	0.975

横軸が正答率, 誤答率, 比の値となり, 縦軸が度数を示す。赤は従来法, すなわち直交化を行なわないときの値が分布する場所を示す。これらの図より, 直交化の順番により, 従来法よりも劣化するものと改善するものがある。つまり, 分類性能は直交化順に依存することがわかる。

表 2: 直交化データを用いた分類結果

	正答率	誤答率	比
Ch3,4,1,6,5,2	84	2	0.977
Ch3,4,6,2,5,1	78	2	0.854
Ch2,5,3,6,4,1	78	2	0.907
Ch2,3,1,6,5,4	78	2	0.902
Ch3,4,6,5,2,1	76	2	0.854

表 2 の直交化データを用いた分類結果のうち, 分類性能が向上した 5 種類の結果を示す。7 種類のチャネル順を用いて直交化した。直交化したデータを用いることにより,  $P_c$  は最大で 70% から 84% に上昇し,  $P_e$  は 10% から 2% へと抑圧され,  $R_c$  は 0.875 から 0.977 に上昇した。

#### 6.4 直交化データ $L$ 種類, $L$ 個の並列 MLNN を用いた分類

このシミュレーションでは, 表 2 に示した良い性能が得られた直交化データを用いて図 3 で示す方式で分類を行った。従来法,  $L = 2 \sim 5$  においてリジェクト閾値を変化させたときの分類結果を表 3~7 にそれぞれ示す。結果,  $L$  を変化させた場合,  $P_c = 76\%$ ,  $P_e = 0\%$ ,  $R_c = 1.000$  となり, どの分類においても誤答率を大幅に低減することができた。

表 3: 従来法の分類結果

閾値	正答率	誤答率	比
0.5	80	10	0.889
0.6	78	10	0.886
0.7	70	10	0.875
0.8	70	6	0.921

表 4: 直交化データを用いた分類結果 ( $L = 2$ )

閾値	正答率	誤答率	比
0.5	82	6	0.931
0.6	80	4	0.952
0.7	78	2	0.975
0.8	74	0	1.000

表 5: 直交化データを用いた分類結果 ( $L = 3$ )

閾値	正答率	誤答率	比
0.5	82	4	0.953
0.6	80	4	0.952
0.7	72	0	1.000
0.8	72	0	1.000

表 6: 直交化データを用いた分類結果 ( $L = 4$ )

閾値	正答率	誤答率	比
0.5	80	4	0.952
0.6	76	4	0.950
0.7	74	0	1.000
0.8	74	0	1.000

表 7: 直交化データを用いた分類結果 ( $L = 5$ )

閾値	正答率	誤答率	比
0.5	82	4	0.953
0.6	78	4	0.951
0.7	76	0	1.000
0.8	72	0	1.000

### 6.5 ノイズ付加による汎化能力の向上

MLNN の学習において、ノイズを付加を行ない汎化能力の向上を図った。付加するノイズの幅は  $[-0.05, 0.05]$  とした。結果を表 8~12 にそれぞれ示す。この手法は MLNN の汎化能力向上に非常に有効である。従来法では、分類性能が大きく向上し、 $P_c = 88\%$ ,  $P_e = 4\%$ ,  $R_c = 957$  となった。更に、 $L$  を変化させた場合、 $P_c = 94\%$ ,  $P_e = 2\%$ ,  $R_c = 979$  となり、どの分類においても正答率が大幅に向上した。

表 8: 従来法 ノイズ付加を適用した分類結果

閾値	正答率	誤答率	比
0.5	90	6	0.938
0.6	88	6	0.936
0.7	88	4	0.957
0.8	76	4	0.956

表 9: ノイズ付加を適用した分類結果 ( $L = 2$ )

閾値	正答率	誤答率	比
0.5	84	8	0.913
0.6	80	6	0.930
0.7	78	4	0.951
0.8	78	2	0.973

表 10: ノイズ付加を適用した分類結果 ( $L = 3$ )

閾値	正答率	誤答率	比
0.5	88	8	0.917
0.6	82	6	0.932
0.7	80	2	0.976
0.8	76	2	0.974

表 11: ノイズ付加を適用した分類結果 ( $L = 4$ )

閾値	正答率	誤答率	比
0.5	94	2	0.979
0.6	86	2	0.977
0.7	80	0	1.000
0.8	76	0	1.000

表 12: ノイズ付加を適用した分類結果 ( $L = 5$ )

閾値	正答率	誤答率	比
0.5	92	2	0.979
0.6	86	2	0.977
0.7	80	2	0.976
0.8	78	0	1.000

### 6.6 従来法の MLNN 並列化

6.5 節では図 3 で示した直交化データを用いた複数の MLNN を並列化したものが良好な性能となることを示した。これとの比較のため、図 4 で示す従来法の MLNN 並列化についても評価を行なった。また、汎化能力向上のためノイズ付加も行なった。各 MLNN は一つのメンタルタスクに対してのみ出力が 1 に近づき、他のメンタルタスクに対しては 0 に近づきよう学習されているので、テストの段階では全体的に出力値が低くなる。よって他の手法より、閾値は低めに設定する。このときの分類結果を表 13,14 に示す。結果として、 $P_c, P_e$  は他の手法より劣化した値となった。最も良いもので、閾値が 0.4 のときに  $P_c = 70\%$ ,  $P_e = 2\%$ ,  $R_c = 0.971$  だが、提案法よりも性能は劣化した。この結果より、元の脳波を用いて複数 MLNN を並列化しても、分類性能を向上させることは困難であることがわかる。

表 13: 従来法の MLNN 並列化における分類結果

閾値	正答率	誤答率	比
0.2	60	8	0.882
0.3	58	8	0.879
0.4	58	8	0.879
0.5	52	8	0.867

表 14: 従来法の MLNN 並列化におけるノイズ付加を適用した分類結果

閾値	正答率	誤答率	比
0.2	72	8	0.900
0.3	70	4	0.946
0.4	70	2	0.972
0.5	68	2	0.971

### 6.7 被験者への依存

脳波は被験者により異なるため、ニューラルネットワークは被験者ごとに最適化しなければならず、同一のニューラルネットワークで異なる被験者の脳波を分類することは難しい。これまでの研究により、直交化における最適なチャンネル順は被験者により異なることがわかっているが、学習データを用いて事前に調べることはできる。他の被験者においても直交化データを用いることにより同様な改良が見られた。

## 7 まとめ

直交化脳波を用いて複数の MLNN を多重並列構成した BCI システムを提案した。異なる特徴を有する入力

データを複数の MLNN に適用し、従来の方式を多重並列したものと評価を行なった。また、汎化能力向上の手法についても検討した。提案法により、メンタルタスクの分類性能は  $P_c = 70\%$ ,  $P_e = 10\%$ ,  $R_c = 0.875$  から  $P_c = 94\%$ ,  $P_e = 2\%$ ,  $R_c = 1.000$  に向上した。

#### 参考文献

- [1] G. Pfurtscheller, C. Neuper, C. Guger, W. Harkam, H. Ramoser, A. Schlögl, B. Obermaier, M. Pregenzer, "Current trends in Graz braincomputer interface(BCI) research", IEEE Trans. Rehab.Eng., vol.8, pp.216-219, 2000.
- [2] B. Obermaier, G. R. Muller and G. Pfurtscheller, "Virtual keyboard" controlled by spontaneous EEG activity," IEEE Trans. Neural Sys. Rehab. Eng., vol. 11, no. 4, pp.422-426, Dec. 2003.
- [3] C. Anderson and Z. Sijercic, "Classification of EEG Signals from Four Subjects During Five Mental Tasks," In Solving Engineering Problems with Neural Networks: Proceedings of the Conference on Engineering Applications in Neural Networks (EANN'96), ed. by Bulsari, A.B., Kallio, S., and Tsaptsinos, D., Systems Engineering Association, PL 34, FIN-20111 Turku 11, Finland, pp.407-414, 1996.
- [4] G. Pfurtscheller and C. Neuper, "Motor imagery and direct brain-computer communication," Proc. IEEE, vol. 89, no. 7, pp.1123-1134, July 2001.
- [5] J. R. Millan, J. Mourino, F. Babiloni, F. Cincotti, M. Varsta, J. Heikkonen, "Local neural classifier for EEG-based recognition of mental tasks," IEEE-INNS-ENNS Int. Joint Conf. Neural Networks, July 2000.
- [6] K. R. Muller, C. W. Anderson, and G. E. Birch, "Linear and non-linear methods for brain-computer interfaces" IEEE Trans. Neural Sys. Rehab. Eng., vol. 11, no. 2, pp.165-169, 2003.
- [7] J. R. Millan, "On the need for on-line learning in brain-computer interfaces," Proc. IJCNN, pp.2877-2882, 2004.
- [8] G. E. Fabiani, D. J. McFarland, J. R. Wolpaw, and G. Pfurtscheller, "Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)," IEEE Trans. Neural Sys. Rehab. Eng., vol. 12, no. 3, pp.331-338, Sept. 2004.
- [9] B. Obermaier, C. Neuper, C. Guger, G. Pfurtscheller, "Information transfer rate in a five-classes brain-computer interface", IEEE Trans. Neural Sys. Rehab. Eng., vol.9, no.3, pp.283-288, 2001
- [10] C. W. Anderson, S. V. Devulapalli, E. A. Stolz, "Determining mental state from EEG signals using neural networks", Scientific Programming, Special Issue on Applications Analysis, vol.4, no.3, pp.171-183, Fall, 1995.
- [11] A. Kachenoura, L. Albera, L. Senhadji and P.comon, "ICA:A potential tool for BCI systems" ,IEEE Signal Processing Magazine, pp.57-68,jan2008.
- [12] S. Wang and C. J. James, "Enhancing evoked responses for BCI through advanced ICA techniques", Proc.,3rd Int. Conf. on Advances in Medical, Sibnal and Information Processing(MEDSIP2006). Stevenage, UK, 2006.
- [13] Colorado State University:  
<http://www.cs.colostate.edu/eeg/>
- [14] J. Robert, M. Burton and G. J. Mpitsos, "Event-dependent control of noise enhances learning in neural networks", Neural NetWorks, vol.5, no.4, pp.627-637,1992.
- [15] K. Nakayama and K. Inagaki, "A brain computer interface based on neural network with efficient pre-processing", Proc.IEEE, ISPACS2006, Yonago, Japan, pp.673-676, Dec.2006.
- [16] K. Nakayama, Y. Kaneda and A. Hirano, "A brain computer interface based on FFT and multilayer neural network-Feature extraction and generalization-", Proc. IEEE, ISPACS2007, Xiamen, China, pp.101-104, Dec.2007
- [17] K. Nakayama, Y. Kaneda and A. Hirano and Y. Haruta, "A BCI using MEGvision and based and multilayer neural network - Channel optimization and main lobe contribution analysis -", Proc. IEEE, ISPACS2008, Bangkok, Thailand, pp.316-319, Feb.2009
- [18] K. Nakayama, H. Horita and A. Hirano, "Neural Network based BCI by using orthogonal components of multi-channel brain waves and generalization," Proc. ICANN2008, Prague, Czech Republic, pp.879-888, Sept. 2008.
- [19] G.Stang, "Liner Algebra and its Applications", Academic Press, Inc., New York,1976.
- [20] R.Caruana, "Multitask Learning", Machine Learning, Vol28, No.1, pp.41-75, 1997.