

多チャネル脳波の直交成分を用いたニューラルネットワークによる ブレイン・コンピュータ・インターフェイス

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

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

Hiroki HORITA[†] Kenji NAKAYAMA[†] Akihiro HIRANO[†]

[†]Graduate School of Natural Science and Technology, Kanazawa Univ.

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

アブストラクト

階層形ニューラルネットワークによるブレイン・コンピュータ・インターフェイス (BCI) において、メンタルタスク固有の特徴を抽出するために、脳波の個々のチャネルの特徴を強調する方法を提案している。7チャネルの脳波を7つのベクトルと見なすことにより、チャネル間でグラムシュミットの直交化を適用した。直交化するチャネルの順番には自由度が存在するので、直交化するチャネル順による分類精度について検討した。次に、2種類のチャネル順で直交化した脳波をニューラルネットワークの入力データととする方法を検討した。更に、汎化能力を向上させるために、入力データにランダムノイズを付加する方法を検討した。シミュレーションには、コロラド州立大学が公開している脳波データを用いた。直交化したデータを用いることにより、分類の正答率は70%から78%に上昇し、誤答率は10%から8%に低下した。正答率と誤答率の比は0.875から0.907に上昇した。異なるチャネル順により直交化した2つの入力データを用いた場合には、誤答率は10%から2%へと大幅に低下し、比も0.973に上昇した。

Abstract

FFT and Multilayer neural networks (MLNN) have been applied to 'Brain Computer Interface' (BCI). In this paper, in order to extract features of mental tasks, individual feature of brain waves of each channel is emphasized. Since the brain wave in some interval can be regarded as a vector, Gram-Schmidt orthogonalization is applied for this purpose. There exists degree of freedom in the channel order to be orthogonalized. Effect of the channel order on classification accuracy is investigated. Next, two channel orders are used for generating

the MLNN input data. Two kinds of methods using a single NN and double NNs are examined. Furthermore, a generalization method, adding small random numbers to the MLNN input data, is applied. Simulations are carried out by using the brain waves, available from the Colorado State University website. By using the orthogonal components, a correct classification rate P_c can be improved from 70% to 78%, an incorrect classification rate P_e can be suppressed from 10% to 8%. As a result, a rate $R_c = P_c = (P_c + P_e)$ can be improved from 0.875 to 0.907. When two different channel orders are used, P_e can be drastically suppressed from 10% to 2%, and R_c can be improved up to 0.973. The generalization method is useful especially for using a single channel order. P_c can be increased up to 84~88% and P_e can be suppressed down to 2~4%, resulting in $R_c = 0.957 \sim 0.977$.

1 はじめに

近年、脳波を用いてコンピュータや車椅子などを制御するシステムであるブレイン・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]。身体にハンディキャップを持った人々への介助となることが期待されている。BCIの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、空間パターンと線形分類、隠れマルコフモデル、などがある [3],[4]。さらに、ニューラルネットワークを用いた手法についても活発に検討されている [5],[6],[7],[8],[9],[10]。

本研究では、脳波のFFTと階層型ニューラルネットワーク (MLNN) を用いてBCIの性能を評価する。メンタルタスクの分類精度を上げるための前処理も行なった [16]。更に、汎化能力向上のための手法として、ニューラルネッ

トワークの入力データにノイズ付加を行なった [17].

多チャンネルの脳波には、異なるチャンネル間で共通する特徴を持ち、メンタルタスクの分類において、それが分類に影響を与える可能性がある。個々のチャンネルの独立性を高める手法としては独立成分分析 (ICA)、ブライント信号源分離 (BSS) などが存在するが、順序問題により、ニューラルネットワークを用いる場合には、扱いが難しい。そこで、多チャンネル脳波をベクトルと見なし任意に順序を描えることのできる Gram-Schmidt の直交化を用いてチャンネル間を独立にする前処理を行ない、直交化した脳波を用いて BCI の評価を行なった。

2 脳波とメンタルタスク

2.1 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つである。

- 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-composing)
- 回転する 3 次元物体を想像する (Rotation of 3D object)
- 数字を順番に書くことを想像する (Computing numbers)

2.2 脳波測定

脳波の測定における電極の位置は図 1 のようになる。これに、まばたきなどの眼球運動検出のための電極 EOG を含めたは 7 チャンネル存在する。本稿では簡単のため、C3, C4, P3, P4, O1, O2, EOG の順に Ch1, Ch2, ..., Ch7 と記述する。脳波は各メンタルタスクにつき、7 チャンネルで 10 秒間、サンプリング周波数 250Hz で測定されており、1 つのチャンネルにつきサンプル数は 2500 個となる。

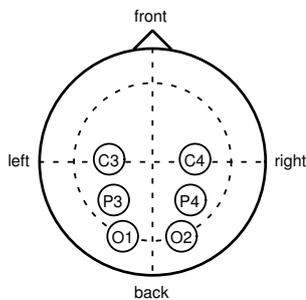


図 1: 電極の位置

2.3 ニューラルネットワークを用いたメンタルタスクの分類

分類に用いたニューラルネットワークは隠れ層が 1 層の階層型ニューラルネットワークである。隠れ層と出力層に用いた活性化関数はシグモイド関数である。入力層は 70 ユニット、隠れ層 20 ユニット、出力層 5 ユニットである。5 つの出力が 5 つのメンタルタスクに対応しており、1 つのメンタルタスクに対して、(1, 0, 0, 0, 0) のように、1 ユニットが 1 で、その他が 0 を出力するように目標値を設定した。推定過程では、5 つの出力のうち最大値を持つユニットに該当するメンタルタスクを推定結果とする。また、出力に閾値を設け、閾値より低い出力の場合にはどのメンタルタスクにも該当しないリジェクトデータとする。ニューラルネットワークの学習には誤差逆伝搬法を用いた。

3 脳波の前処理

ニューラルネットワークで分類するための前処理として、様々な手法が検討されている [16].

3.1 脳波のフーリエ変換の振幅

脳波の時間変化の影響を避けるため、フーリエ変換により得られるパワースペクトルを特徴量とする。

3.2 サンプル平均化

ニューラルネットワークの計算量、ノイズの影響を低減させるためにサンプル平均化を行なう。更に、パワースペクトルは対象なので周波数帯域の半分だけ用いることにより 1ch のサンプル数を 10 サンプルに低減した。

3.3 非線形正規化

フーリエ変換のパワースペクトルは広く分布している。小さな値を持つサンプルにもメンタルタスクを分類する際の重要な情報が含まれている。しかしながら、ニューラルネットワークでは、大きな値をもつサンプルが効力を持つ。もし、大きな値のサンプルに、重要な情報が含まれない場合、正しい分類をするのが難しくなる。そこで、式 1 を用いて非線形な正規化を行なう [17]. x は正規化前のフーリエ変換のパワースペクトルで、 $f(x)$ は正規化された値となる。式 1 では、 x_{min} と x_{max} は全てのチャンネルの x の最小値と最大値を表す。これにより、小さな値を伸長し、大きな値は圧縮される。本稿では、直交化した脳波に対する非線形正規化の有効性についても検討する。

$$f(x) = \frac{\log(x - x_{min})}{\log(x_{max} - x_{min})} \quad (1)$$

比較のため、 $f_{linear}(x) = (x - x_{min}) / (x_{max} - x_{min})$ で表される線形正規化についても検討した。

4 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を実現する上で非常に重要になってくる。その手法として、これまでの研究ではニューラルネットワークの入力データにノイズを付加する方法と Weight-Decay 法を用いてきており、前者の方法では良い結果が得られている [14],[15],[17]。

本稿では汎化能力向上の手法として、ニューラルネットワークの入力データにノイズ付加を行ない、多チャンネル脳波を直交化した入力データに対しての有用性を調べる。

5 脳波の直交成分

5.1 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) などの方法がある。これらの方法では、成分の並び替え (Permutation) という問題がある。すなわち、複数の測定データに対して、同じ特徴が同じ順番で現れるとは限らない。この点をもう少し、具体的に述べる。

M 個のチャンネルがあるとする。あるメンタルタスクに対して、M チャンネルの脳波が測定される。これを $\mathbf{X} = [\mathbf{x}_1^T, \mathbf{x}_2^T, \dots, \mathbf{x}_M^T]^T$ とする。 \mathbf{x}_i は i チャンネルの脳波データである。これに対する直交成分を $\mathbf{V} = [\mathbf{v}_1^T, \mathbf{v}_2^T, \dots, \mathbf{v}_M^T]^T$ とする。 \mathbf{V} は適当な前処理を経て、階層形ニューラルネットワーク (MLNN) の入力として用いられる。このとき、MLNN にとって \mathbf{V} における \mathbf{v}_i の順番が重要な情報となる。ここで、同じメンタルタスクに対して、2 回の測定で得られたデータに対する直交成分 $\mathbf{V}_1, \mathbf{V}_2$ を考える。 \mathbf{v}_{1i} と \mathbf{v}_{2j} は \mathbf{V}_1 及び \mathbf{V}_2 における、 i 番目と j 番目のベクトルである。もし、 \mathbf{v}_{1i} が $\mathbf{v}_{2j}, i \neq j$ に最も類似しているとき、すなわち、 $\mathbf{v}_{1i}^T \mathbf{v}_{2j} / \|\mathbf{v}_{1i}\| \|\mathbf{v}_{2j}\|$ が最も 1 に近いとき、これらは同じ特徴を表している。しかし、 \mathbf{V}_1 及び \mathbf{V}_2 における順番は異なる。すなわち、 \mathbf{V}_1 と \mathbf{V}_2 は同じメンタルタスクに対するデータであるにも関わらず、MLNN の入力としては、同じ特徴を表現できていない。

このように、BSS, ICA 及び PCA などは、Permutation 問題のために、同じメンタルタスクに対する、異なる測定データに対して、その直交成分で表現される特徴を同じ順番に並べることが出来ない [11],[12]。これは、直交成分を MLNN の入力として用いるときには、大きな問題となる。

このような理由から、本稿では、測定データ $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\}$ に対して Gram-Schmidt の直交化法を適用する。直交成分の順番は直交化するチャンネル順によって決まり、Permutation の問題は生じない。この方法は、チャンネル固有の成分を抽出することに相当する。

また、直交化後の各ベクトルに含まれる成分は直交化のチャンネル順に依存する。

5.2 Gram-Schmidt の直交化

ベクトル $[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M]$ が M チャンネルの脳波を表しているとし、線形独立であるとする。これは Gram-Schmidt の直交化によりそれぞれ互いに直交なベクトル $[\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_M]$ に変換することができる [18]。 \mathbf{x}_1 を \mathbf{v}_1 とすると、 \mathbf{v}_2 は \mathbf{v}_1 に直交な \mathbf{x}_2 の成分となる。以下同様に、 \mathbf{v}_k は $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{k-1}$ に直交するベクトルとなる。

5.3 直交化の順番

Gram-Schmidt の直交化では、直交化を行なうチャンネルの順番には自由度が存在する。1 番目のチャンネルはもとの情報をそのまま保持し、後の順序になるにつれて保持する情報は減っていく。それゆえ、直交化するチャンネル順が分類性能に影響する。その影響について検討した。

5.4 直交化の順番を変えた 2 つの入力データによる分類

前述したように、直交化の際には複数のチャンネル順が考えられ、それらをニューラルネットワークへの入力データとして用いることができる。そこで、2 種類のチャンネル順で直交化した脳波を入力データとして用いてメンタルタスクの分類を行なった。ここで、2 つの入力データをそれぞれ I_1, I_2 とする。

ニューラルネットワークを 1 つ用いる方法 学習過程では I_1, I_2 を同一のニューラルネットワークで学習させ、テスト過程では I_1 を入力して得られた出力 O_1 と、 I_2 を入力して得られた O_2 の平均値を出力として分類を行なう。

ニューラルネットワークを 2 つ用いる方法 学習過程では I_1 をニューラルネットワーク 1 で学習、 I_2 をニューラルネットワーク 2 で学習させ、出力過程では I_1 をニューラルネットワーク 1 に入力し得られた出力 O_1 と、 I_2 をニューラルネットワーク 2 に入力して得られた出力 O_2 の平均値を出力として分類を行なう。

6 シミュレーション

6.1 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, リジェクトの閾値は 0.7, 学習係数は 0.02 とする.

6.2 直交化後の脳波

図 2~8 に直交化前 (青) 直交化後 (赤) の脳波を示す. 直交化のチャンネル順は Ch1,2,3,4,5,6,7 の順である. 直交化後の脳波はチャンネル順に減少していることがわかる. Ch7 は眼球運動検出のチャンネルのため, 他のチャンネルとの独立性が高く, あまり変化していない.

更に, 図 9 にこれらの脳波を用いて作成した入力データを示す. 青が従来の処理による入力データを示し, 赤が直交化したデータを用いた場合のものである.

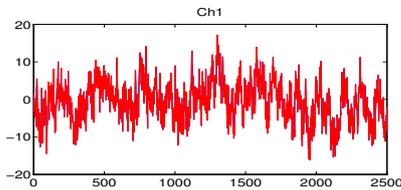


図 2: Ch1

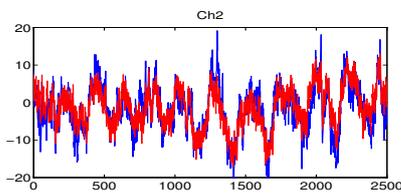


図 3: Ch2

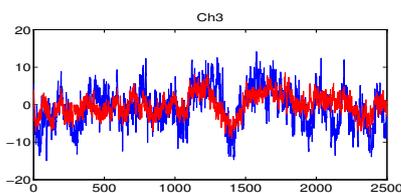


図 4: Ch3

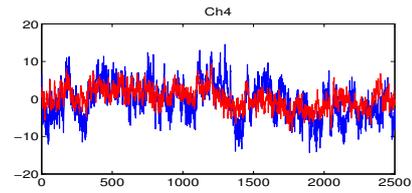


図 5: Ch4

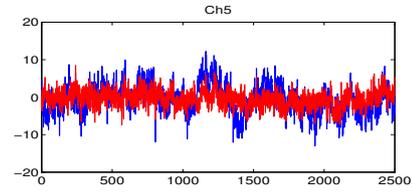


図 6: Ch5

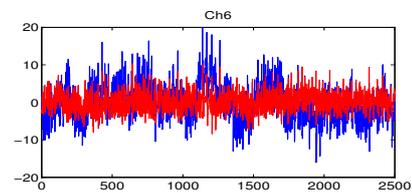


図 7: Ch6

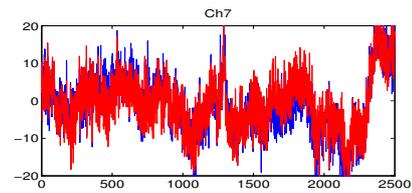


図 8: Ch7

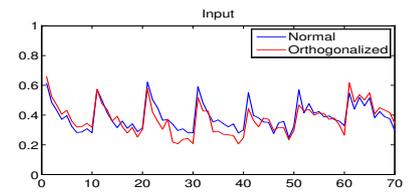


図 9: 入力データ

6.3 直交化データを用いた分類

表 1 に 7 種類のチャンネル順で直交化したデータを用いた分類結果を示す. 7 種類のチャンネル順を用いて直交化した. 従来法は, 直交化していない脳波をそのままを用いて分類したときの結果を示す [16]. 直交化したデータを用いることにより, P_c は 70% から 78% に上昇し, P_e は 10% から 8% へと抑圧され, R_c は 0.875 から 0.907 に上昇した. 表 1 から, 分類性能は直交化するチャンネル順により変化することがわかる. 中でも, Ch2,3,4,5,6,7,1 と Ch3,4,5,6,7,1,2 で直交化したときに良い性能を示している.

更に, Ch2,3,4,5,6,7,1 順のデータのニューラルネットワークの学習において, 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 ± 0.1 , ± 0.05

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
Ch1,2,3,4,5,6,7	70	12	0.854
Ch2,3,4,5,6,7,1	78	8	0.907
Ch3,4,5,6,7,1,2	74	8	0.902
Ch4,5,6,7,1,2,3	70	12	0.854
Ch5,6,7,1,2,3,4	68	12	0.850
Ch6,7,1,2,3,4,5	66	24	0.733
Ch7,1,2,3,4,5,6	70	12	0.854
ノイズ付加 ± 0.1 Ch2,3,4,5,6,7,1	88	4	0.957
ノイズ付加 ± 0.05 Ch2,3,4,5,6,7,1	84	2	0.977

の2通り行なった。結果、 P_c は78%から最大で88%、 P_e は8%から最低で2%となり、 $R_c = 0.957 \sim 0.977$ へと上昇した。

3.3節で述べた線形正規化 $f_{linear}(x)$ についても検討した。このとき、最適なチャンネル順は Ch5,6,7,1,2,3,4 順であり、 $P_c = 62\%$ 、 $P_e = 14\%$ 、 $R_c = 0.816$ となり、非線形正規化よりも劣る結果となった。

6.4 2通りのチャンネル順を用いた分類

表 1 で良い性能を示した 2通りのチャンネル順 Ch2,3,4,5,6,7,1, と Ch3,4,5,6,7,1,2 で直交化したデータを用いて分類を行なった。

表 2 に結果を示す。1つのニューラルネットワークを用いる方法ではそれほど良い性能は得られなかったが、2つのニューラルネットワークを用いる方法では、 P_e の低下が著しく、 R_c が上昇している。更に、ノイズ付加を行なうことにより、 $P_c = 82\%$ 、 $P_e = 2\%$ 、 $R_c = 0.976$ となり、1つのチャンネル順の直交化データを用いた場合とほぼ同等な結果が得られた。

6.5 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。

表 2: 2通りの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
1つの NN	66	8	0.892
ノイズ付加 ± 0.1	76	6	0.927
ノイズ付加 ± 0.05	78	8	0.907
2つの NN	72	2	0.973
ノイズ付加 ± 0.1	82	2	0.976
ノイズ付加 ± 0.05	72	4	0.947

7 まとめ

本稿では、脳波のフーリエ変換の振幅と階層型ニューラルネットワークを用いてメンタルタスクの分類を行なった。特に、多チャンネル脳波の直交成分をニューラルネットワークへの入力データとした場合について検討した。直交化には Gram-Schmidt の直交化を用いた。それにより、 P_c は70%から78%、 P_e は10%から2%となり、 R_c は0.875から0.907へと上昇した。2通りの直交化データを用いた分類では特に誤答率の抑制が顕著で、 P_e が10%から2%へと低下し、 R_c が0.973に上昇した。汎化能力向上のためのノイズ付加も有用であり、 P_c は88%、 P_e は2%となり、 R_c は0.977となった。

参考文献

- [1] G. Pfurtscheller, C. Neuper, C. Guger, W. Harkam, H. Ramoser, A. Schlögl, B. Obermaier, M. Pregegnier, "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] N. K. Treadgold and T. D. Gedeon, "Simulated annealing and weight decay in adaptive learning:The SARPROP algorithm" , *IEEE Trans. Neural NetWorks*, vol.9, no.4, pp.662-668,july 1998.
- [16] 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.
- [17] 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
- [18] G.Stang, "Liner Algebra and its Applications", *Academic Press, Inc.*, New York,1976.