

NNを用いたBCIにおける自己組織化マップによる 多チャンネル脳波の特徴抽出法の検討

On Feature Extraction from Multi-Channel Brain Waves Used for Brain Computer Interface

齋藤宏哉[†]

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

Hiroya SAITO[†]

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

脳波の高速フーリエ変換(FFT)と階層形ニューラルネットワーク(MLNN)を用いるブレイン・コンピュータ・インターフェイス(BCI)に関して、脳波から多くの情報を得るために頭部の複数箇所(多チャンネル)で測定される場合が多く、多チャンネルのデータから如何に特徴を抽出するかという問題がある。

本研究では、多次元データのクラスタリング手法である自己組織化特徴マップ(SOFM)を用い、写像空間に投影した脳波データをニューラルネットワークで構成されるBCIの入力とする方法により、分類性能の向上を図る。また、SOFMのパラメータや拡張形、構成の見直しを行うことによる性能変化を調査し、最適な構成法を提案する。

ABSTRACT

FFT and Multilayer Neural Networks (MLNN) have been applied to 'Brain Computer Interface' (BCI). In the BCI systems, how to extract individual features of mental tasks from multi-channel brain waves is an important problem.

Self-Organizing Feature Map (SOFM) is one of clustering methods for multi-dimensional data. In this paper, SOFM is applied to generating the MLNN input data. Classification performance can be improved by increasing dimension of the SOFM output. Furthermore, The performance is investigated based on parameters, modified forms and constructions. A useful realization using SOFM and MLNN is proposed.

1 まえがき

近年、人間とコンピュータをつなぐインターフェイスとして様々な新しいインターフェイスが検討されており、その中で、人間の脳波を解析して、コンピュータとのイ

ンターフェイスとする、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。BCIの基本原理は、被験者の脳波や脳磁波を多チャンネルで測定し、そのデータの特徴を解析して、被験者がイメージしたこと(メンタルタスク)を推定し、それに基づいてコンピュータや機械を操作することである[1][2]。

BCIの方式としては、帯域のパワースペクトルと非線形分類、ARモデルと線形分類、空間パターンと線形分類、隠れマルコフモデル、などを用いる方法がある[3]、[4]。また、ニューラルネットワークのBCIへの応用も活発に検討されている[5]-[9]。これまでの研究で脳波のフーリエ変換と階層形ニューラルネットワークを用いる方法について、有効な前処理の方法が提案され、ある程度の分類性能を持つBCIが構築されている[11]-[12]。

特徴抽出法に脳波のフーリエ変換に加えて自己組織化特徴マップ(SOFM)を用いる方式では、特徴空間の分解能を調整することで、従来法と同程度の分類性能における入力データ量の削減、入力データ量を増やした際の分類性能は向上を確認することができた。しかし、従来法による分類性能が低い被験者のデータを入力とした場合、SOFMを用いた方式では分類性能が低下することが分かった。これは、メンタルタスク想像時の被験者の脳波データの差異が、データベクトルの距離を用いるSOFMを行なう際に影響し特徴を損失したと思われる。このことは、BCIにおいて脳信号データ測定の被験者の訓練量や精神状態が、個々の分類性能に大きく影響することからも推察できる。

本稿では、SOFMのパラメータや拡張形による分類性能の変化を解析し、SOFMとMLNNによるBCIの性能向上と共に、どの被験者に対しても分類性能を発揮できる汎用性の高い構成を目指す。

2 脳波の測定とメンタルタスク

本稿では、コロラド州立大学が Web 上で公開している脳波データを用いる [10]。脳波の測定の際に、用いられたメンタルタスクは、次の5つである。

- できるだけリラックスする (Baseline)
- 掛け算を暗算でする (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)
- 数字を順番に書くことを想像する (Counting)

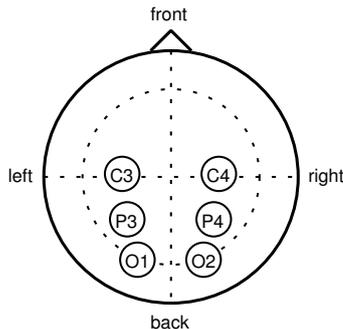


図 1: 電極の位置

脳波を測定する際の電極の位置を、図 1 に示す、C3, C4, P3, P4, O1, O2, EOG の 7 チャンネルである。EOG は、まばたきなどの眼球の運動による信号を検出する電極である。各メンタルタスクに対して、10 秒間測定し、250Hz でサンプリングされたので、1 チャンネルあたり $250\text{Hz} \times 10\text{sec} = 2,500$ サンプルのデータがある。

7 チャンネル分のデータが、1 つのデータセットとなる。

3 脳波データの特徴抽出

脳波データをニューラルネットワークに入力するにあたり、有用な特徴量を抽出するために以下のような処理を行う [11]-[12]。

- フーリエ変換による特徴量抽出
- 平均化によるサンプル数低減
- データの非線形正規化

以上のような特徴抽出を経て、ニューラルネットワークの入力データとしては、7 チャンネル分並べたものを用いる。

4 階層形ニューラルネットワークによるメンタルタスクの分類

メンタルタスクの分類には隠れ層が 1 層の 2 層形ニューラルネットワークを用いる。活性化関数として、シグモイド関数を用いる。入力ユニット数が 1 チャンネルあたり、10 サンプルを 7 チャンネル分用意するので、合計 70 個であり、出力ユニットは 5 種類のメンタルタスクに対応して 5 個用いる。目標出力としては、該当するメンタルタスク

に対応する出力ユニットに 1、その他は 0 を割り当てる。最も大きな値を持つ出力ユニットに該当するメンタルタスクを推定結果とする。もし、出力が全体的に小さい値のときは、判定不能 (リジェクト) とする。結合荷重の学習はバックプロパゲーション (BP) 法で行った。

4.1 シミュレーション条件

5 種類のメンタルタスクに対して、10 秒間の測定を各被験者について、10 回ずつ行っただけで、合計 50 組データセットがある。そのうち、40 セットを学習に、残りの 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、分類を行い、その平均値で推定能力を評価する [3]。ニューラルネットワークの各種パラメータは以下のように設定する。正答率の向上を目的に分類性能を比較するため、リジェクトのための閾値は 0 とする。

- ・活性化関数: シグモイド関数
- ・隠れ層のユニット数: 20
- ・セグメント分割: 無し
- ・学習係数: 0.1
- ・学習回数: 50000 回
- ・結合荷重の初期値: ± 0.1 の範囲でランダム
- ・リジェクトする閾値: 0

以下の表 1, 2 が、フーリエ変換と誤差逆伝搬 MLNN により、二人の被験者の測定データを分類したものである。以降はこの分類性能と比較して特徴抽出法を検討する。

タスク	B	M	L	R	C	平均
正答率 [%]	90	90	60	80	100	84

表 1: 従来法による分類結果 (被験者 1)

タスク	B	M	L	R	C	平均
正答率 [%]	80	80	60	80	80	76

表 2: 従来法による分類結果 (被験者 2)

5 自己組織化特徴マップと階層型ニューラルネットワークによるメンタルタスクの分類

5.1 自己組織化特徴マップ (Self-Organizing Feature Map:SOFM)

自己組織化特徴マップ (SOFM)[13][14] は、ニューラルネットワークの一種で、中間層の無い 2 階層型の教師無し競合学習モデルである。

SOFM は入力層と出力層であるマップ層の二つの層から構成されている。マップ層には M 個のノードが直線状、格子状や球状等 (本稿では 2 次元の格子状) に配置され、 n 次元の入力層は、入力データの次元と等しい数の入力ノードから構成されている。マップ層の各ノードと入力層に属

する全てのノードの間には結合荷重 w_j , $j = 1, 2, \dots, M$ が与えられている. 図 2 に SOFM の概念図を示す.

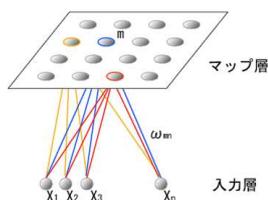


図 2: SOFM の概念図

以下に SOFM のアルゴリズムを示す.

Step1 ネットワークの初期化

入力層とマップ層の間の全ての重みの初期値 $w_j(0)$ をランダムに設定する.

Step2 入力ベクトルの入力

入力層に入力ベクトル $\mathbf{x} = (x_1, x_2, \dots, x_n)$ を入力する.

Step3 マップ層で入力ベクトルとの距離を計算し, 最小ノードを選択

マップ層では, 各ノードの重みベクトルと入力ベクトルとの距離を計算する. ここで距離の算出には様々な方法があるが, 本稿ではユークリッド距離を用いる.

$$|\mathbf{x} - \mathbf{w}_c| = \min |\mathbf{x} - \mathbf{w}_j| \quad j = 1, 2, \dots, M \quad (1)$$

上式より, 距離が最小となるノード c を選択し, このノードを勝者ノードとする.

Step4 重みベクトルの学習

勝者ノードとその近傍ノードの重みベクトルが次式により更新される.

$$\mathbf{w}_j(t) = \begin{cases} \mathbf{w}_j(t) + \eta(t)[\mathbf{x}(t) - \mathbf{w}_j(t)] & j \in \Lambda_c \\ \mathbf{w}_j & \text{Otherwise} \end{cases} \quad (2)$$

ここで, $\eta(t)$ は学習回数に応じて減衰する学習率であり, Λ_c は勝者ノード c の近傍ノードの範囲を決定する近傍関数である. こちらも学習回数に応じて縮小する. 本稿では,

$$\eta(0) = 0.1$$

$$\eta(t) = \eta(0) \left(1 - \left(\frac{t}{T}\right)^2\right)$$

により, 学習率を決定する. T は学習回数, t は現在の学習回数を表す. $T = 1000$ の学習率を図 3 に示す.

近傍関数は, SOFM によって様々な形状を取り入れることができるが, 本稿では $(c+d, c+d)$, $(c-d, c+d)$, $(c+d, c-d)$, $(c-d, c-d)$ を頂点とする正方形形状の内部を

近傍関数 Λ_c とする. d は学習回数と共に減少し, 次式で表される.

$$d(0) = \text{round}(0.3\sqrt{(M_{\text{row}})(M_{\text{cul}})})$$

$$d(t) = \text{round}(d(0) \left(1 - \left(\frac{d(0) - 1}{d(0)}\right) \left(\frac{t}{T}\right)^2\right))$$

$\text{round}()$ は $()$ 内の数の小数点以下の四捨五入を表す. $T = 1000$ の時の $d(t)$ を図 4 に示す.

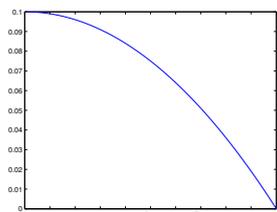


図 3: 学習率 $\eta(t)$

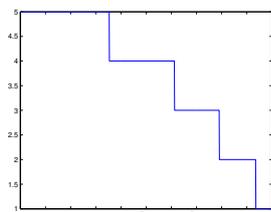


図 4: 近傍距離 $d(t)$

Step5 Step2 へ戻る

Step2~Step5 の動作を繰り返して, 重みを学習していく.

5.2 SOFM の特徴空間における分類

以下の条件で, 従来の MLNN への入力データを SOFM の特徴空間に射影する.

- ・マップ層 (正方形型) の一辺のノード数:50
- ・学習回数:500

特徴空間における入力データの最近傍点の一例を図 5, 色毎のメンタルタスクを表 3 で示す.

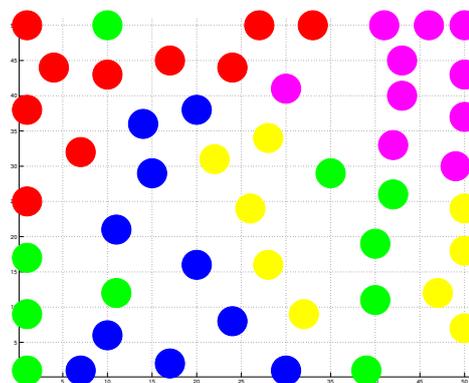


図 5: 特徴空間における入力データの最近傍点

色	メンタルタスク
青	Baseline
赤	Multiplication
緑	Letter-composing
ピンク	Rotation
黄	Counting

表 3: メンタルタスク対応表

SOFMにおける各ノードと脳波データとのユークリッド距離を、メンタルタスクの特徴量としてMLNNの入力とする。入力データの一例を図6に示す。赤くなっている部分が距離が短く、青が長い。

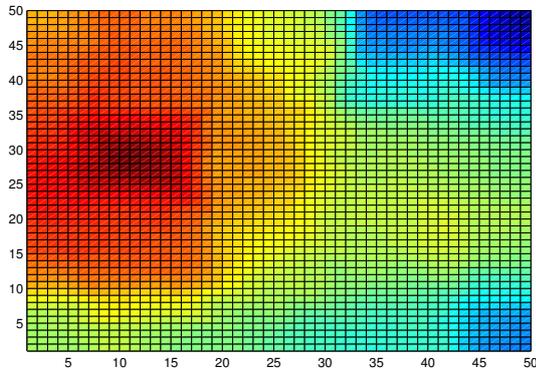


図 6: 脳波データとマップ上の各ノードとの距離

5.3 階層形ニューラルネットワークによるメンタルタスクの分類

以下の条件で、SOFMに前処理後の入力データを学習させ、MLNNへの入力データを作成する。特徴空間の大きさがそのまま入力データの大きさとなるため、情報量の変更により、分類性能にどのように影響するかを検討する。

- ・マップ層(正方形型)のノード数:25(5x5), 225(15x15), 625(25x25)
- ・学習回数:500

その他のパラメータは第4.1節と同じである。SOFMでは重みの初期値を乱数で決定するため、シミュレーション毎に正当率が若干異なる。本研究では、予め定めた5通りの重みの初期値に対してシミュレーションを行ない、その平均で評価することとする。

分類結果を表4, 表5に示す。

ノード数	B	M	L	R	C	平均(%)
25(5×5)	90	80	70	90	90	84
225(15×15)	100	90	70	90	90	88
625(25×25)	100	90	70	100	90	90

表 4: SOFM を用いた場合の分類結果 (被験者 1)

ノード数	B	M	L	R	C	平均(%)
25(5×5)	46	52	30	64	72	52.8
225(15×15)	72	72	38	62	90	66.8
625(25×25)	74	72	56	72	86	72

表 5: SOFM を用いた場合の分類結果 (被験者 2)

被験者1の場合、従来方では、入力データのサンプル数は70サンプルなので、 $5 \times 5 = 25$ 個のノードでSOFMを用

いた場合、正答率は低下せずに入力データ量を約36%に削減できていることが分かる。また、SOFMのノード数を増やした場合では、ノード数すなわちMLNNの入力データ量の増加に伴い、正答率も向上した。これは、特徴空間の増大により空間の分解能が上がり、分類に有効な特徴量が増加したからと考えられる。

しかし、被験者2の場合、どのノード数においても従来法の正当率を上回らなかった。これは、被験者1と比べ従来法の正当率が低いことから、各メンタルタスクにおける脳波データの類似性が低く、それがデータベクトルの距離を用いるSOFMにおいて顕著に現れ、特徴を損失したと考えられる。

そこで、どの被験者に対しても分類性能の向上を可能にする、汎化能力の高いSOFMによる特徴抽出法について検討する。

5.4 パラメータによる分類性能への影響の解析

SOFMでは、学習率・近傍距離を決める近傍関数・学習回数と、設定すべきパラメータが多くある。今節では各パラメータの改変による被験者毎の分類性能への影響について調査する。

下の図7~図9は、被験者1, 2それぞれの学習率の初期値, 近傍関数の初期値, 学習回数を変更した際の正答率である。なお、変更するパラメータ以外の数値は前節のシミュレーションと同条件, MLNNの入力となるSOFMのマップサイズは225(15×15)とした。以下は改変しないパラメータの共通の値である。

- ・学習率(初期値):0.1
- ・近傍距離(初期値):5
- ・学習回数:500

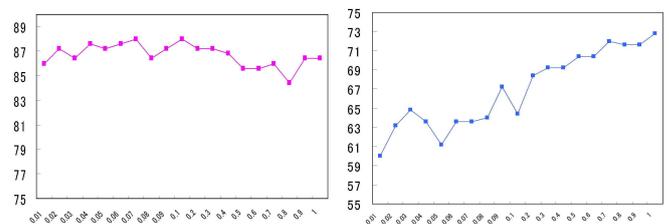


図 7: 学習率の初期値 (左:被験者 1, 右:被験者 2)

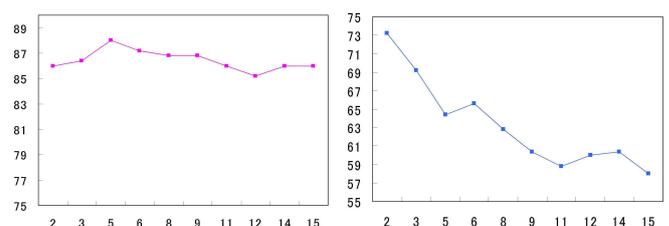


図 8: 近傍距離の初期値 (左:被験者 1, 右:被験者 2)

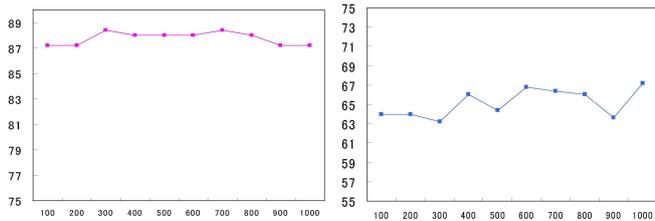


図 9: 学習回数 (左:被験者 1, 右:被験者 2)

上図より、被験者 1 はどのパラメータにおいても正答率は従来法を越えており、パラメータ改変による影響は見受けられない。それに対し被験者 2 は分類性能が学習率と近傍距離に依存していることが分かった。被験者 2 のデータには、狭い範囲で大きく学習させる方が正答率は上昇する傾向にある。学習回数の変化に対して傾向が見られないのは、学習率と近傍距離の関数が、学習回数が変わっても一定の勾配で減少する関数に設定しているからだと思われる。

この結果を踏まえて、被験者 2 のデータに適したパラメータに変更してシミュレーションを行なった結果が表 6 である。

- ・学習率の初期値:0.1 → 0.6
- ・近傍距離の初期値:5 → 3
- ・学習回数:500 → 800

タスク	B	M	L	R	C	平均
正答率 [%]	84	78	52	78	82	74.8

表 6: パラメータ最適値での分類結果 (被験者 2)

これにより、パラメータ改変により被験者 2 の正答率を 8% 上昇させることが出来たが、従来法よりは若干低い。

5.5 SOFM の距離尺度と近傍範囲の改良

被験者 2 の SOFM による特徴抽出で分類性能が低くなるのは、SOFM の学習がうまくいかず、マップ上で同じメンタルタスク毎にグルーピングしていないからである。

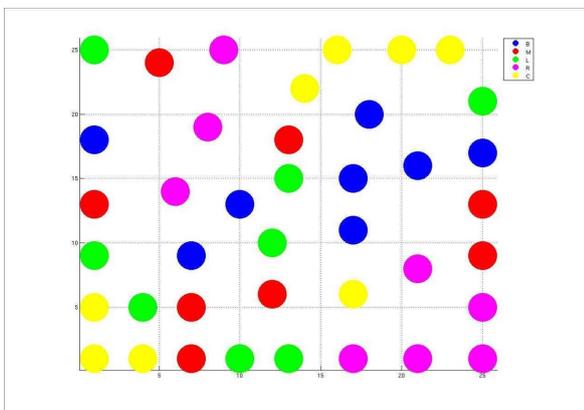


図 10: 被験者 2 の学習データの最近傍点の分布

そこで、SOFM の距離尺度を変更することで、被験者 2 に対してもうまくクラスタリングできるのではと考え、以下の 3 種類を試みた。

マンハッタン距離 (Manhattan Distance)

$$d_{Man}(\mathbf{a}, \mathbf{b}) = \sum_{i=1}^n (a_i - b_i)$$

標準ユークリッド距離 (Standard Euclidean Distance)

$$d_S(\mathbf{a}, \mathbf{b}) = \sqrt{\sum_{i=1}^n w_i (a_i - b_i)^2}$$

$$\left(w_i = \frac{1}{i \text{ における分散}} \right)$$

マハラノビス距離 (Mahalanobis Distance)

$$d_{Mah}(\mathbf{a}, \mathbf{b}) = \sqrt{(\mathbf{a} - \mathbf{b}) \sum_{COV}^{-1} (\mathbf{a} - \mathbf{b})^T}$$

$$\left(\sum_{COV} = \text{分散共分散行列} \right)$$

標準ユークリッド距離は、値の分散を標準化した上でユークリッド距離であるため、ある次元でのデータの差異が非常に大きく、それが全体の距離の差異に大きく影響するということがなくなる。マハラノビス距離では分散共分散行列を掛け合わせることで次元間の相関の影響を受けにくくしている。

次に、近傍領域の形状を変更する。ここまでは正方形形状であったが、ここでは正方形型のノード配列をベースに、六角格子型・円環面型の 2 種類を検討してみる。六角格子型は正方形に比べ円形に近く、より近傍という概念で近いノードを学習の対象とする。円環面型は、重みの初期値や学習順等により本来距離が近いはずのデータがマップの隅で固定されることを解消する。それぞれの領域の図解を図 11 に示す。

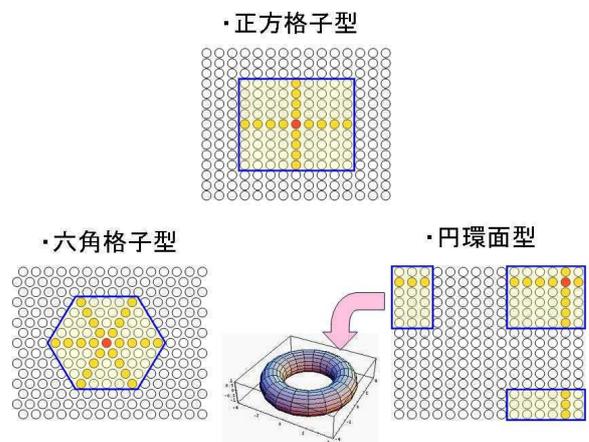


図 11: 近傍領域の形状

以上の距離尺度と近傍領域についてシミュレーションを行なったものを表7, 表8に示す。なお, シミュレーション条件はパラメータ変更前の第5.3節, 第5.4節と同じとする。表中に数字は正答率を表す。

正答率 (%)	正方格子	六各格子	円環面
ユークリッド距離	88	88	87.6
マンハッタン距離	87.2	86.8	88.8
標準ユークリッド距離	86	87.2	88.4
マハラノビス距離	77.6	83.6	74.8

表 7: 距離測度と近傍領域の改良 (被験者 1)

正答率 (%)	正方格子	六各格子	円環面
ユークリッド距離	66.8	67.6	69.6
マンハッタン距離	68.8	67.6	63.6
標準ユークリッド距離	64.4	70.2	70.8
マハラノビス距離	65.2	63.2	61.2

表 8: 距離測度と近傍領域の改良 (被験者 2)

距離測度と近傍領域の組み合わせ毎に見ると, 被験者 1 は改良前の方式に比べて正答率は余り上昇しておらず, マハラノビス距離では全ての組み合わせで大幅に精度が低下した。円環面型においてわずかながら正答率は向上した。被験者 2 は多くの組み合わせで改良前より正答率は上昇した。特に標準ユークリッド距離・円環面型の時 4% 上がった。この組み合わせは被験者 1 においても向上が見られた。

6 まとめ

脳波の高速フーリエ変換と, 他次元データのクラスタリング手法である自己組織化特徴マップ (SOFM) を用いた特徴抽出を行なう MLNN による BCI において, 分類性能向上を目的とした SOFM の解析と改良を行なった。

2 人の被験者に対してシミュレーションを行なったところ, 元のデータにより特徴抽出性能が異なり, 従来法と比べ分類性能が被験者により上昇/下降することが分かった。次に, パラメータの解析を行なうことで被験者毎に違う特性を持つことが分かり。パラメータの最適化により性能が低下した被験者において正答率が 8% 向上した。また, データの写像空間へのマッピングの際に重要となる距離尺度と近傍領域をより実データのクラスタリングに適した形に変更し, この BCI における最適な構成は標準ユークリッド距離・円環面型近傍領域であることが分かった。

参考文献

- [1] G.Pfurtscheller, C.Neuper, C.Guger, W.Harkam, H.Ramoser, A.Schlögl, B.Obermaier, and M.Pregenzer, "Current trends in Graz brain-computer 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, and J.Heikkonen, "Local neural classifier for EEG-based recognition of metal 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] C.W.Anderson, S.V.Devulapalli, and 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.
- [10] <http://www.cs.colostate.edu/eeg/>
- [11] 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", 電子情報通信学会, 信学技法, Vol.105 No.174 pp.25-30, SIP2005-54, 2005.07.
- [12] 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.
- [13] 須藤一郎, 湯野智己, 田向権, 関根優年, "適応型木構造 SOM の提案と画像分類への応用", 電子情報通信学会, 信学技法.
- [14] T.コホネン, "自己組織化マップ 改定版", シュプリンガー・フェアラーク東京, 2005.