

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・インターフェイスの検討

On Brain Computer Interface by Using Multilayer Neural Networks

稻垣 清人[†]

Kiyoto Inagaki

中山 謙二[‡]

Kenji Nakayama

[†]金沢大学大学院 自然科学研究科 電子情報工学専攻

Division of Electrical and Computer Engineering

Graduate School of Natural Science and Technology, Kanazawa Univ.

[‡]金沢大学大学院 自然科学研究科 電子情報科学専攻

Division of Electrical Engineering and Computer Science

Graduate School of Natural Science and Technology, Kanazawa Univ.

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

あらまし

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) に関する検討を行った。脳波は Web で公開されているデータを用い、特徴量としては周波数特性の振幅を用いた。まず、特徴抽出における時間幅とサンプル数の影響を調べた。次に、非線形正規化の方法を提案し、有効性を確認した。さらに、汎化能力を高める学習法の有効性を調べた。その結果、正答率、誤答率共に低下するが、正答率／誤答率は向上することを確認した。被験者及びメンタルタスクの内容による正答率のばらつきを調べた。被験者によるばらつきが大きいこと、メンタルタスクの種類や数によるばらつきも大きいことが確認された。これらの結果より、個人ごとに、分離しやすい脳波を発生するためのメンタルタスクを決めることが重要であることが分かった。

ABSTRACT

Brain Computer Interface (BCI) implemented by using a multilayer neural network is investigated. The brain wave forms are obtained from some web site. Amplitude responses of the frequency response are used for classifying the mental tasks. First, effects of time interval and the number of samples of the brain wave forms are investigated. Next, a nonlinear normalization method is proposed, and its usefulness is confirmed. Furthermore, efficiency of the learning algorithms, which can improve generalization, is investi-

gate. As a result, the rate of correct answers and also that of incorrect answers are both decreased. However, the ratio of them can be increased. Effects of subjects and mental tasks on the rates of the correct answers are investigated. Accuracy of BCI is highly dependent on the subjects, and also, on the mental tasks. From these investigations, it is very important how to determine the mental tasks in order to emphasize differences in the brain wave forms.

1 まえがき

人間とコンピュータのインターフェイスとして、様々なものが使用され、また、検討されている。健常者に取っては、キーボードやマウスが主流であるが、身体障害者の場合は、機能する部位に依存して、様々なインターフェイスが検討されている。

そのような中で、人間の脳波を解析して、コンピュータとインターフェイスをとる Brain Computer Interface (BCI) が近年注目されている。BCI の基本的な処理は、被験者の脳波を多チャネルで測定し、その脳波の特徴を解析して、被験者がイメージ（意図）したことを推定し、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 [4]-[11]。応用として、重度の運動障害を抱える患者が、コンピュータや車イスなどの機器を操作するために用いることが期待されている [9]。また、バーチャルリアリティ (VR) の世界にいる人物を自分の意志で動かすことにより、VR の世界で様々な仮想体験をすることが可能となる。例えば、危機回避の訓練を VR で

行うことが出来る。

BCI の方式としては、帯域のパワーと非線形分類、適応形自己回帰モデルと線形分類、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 [6]。また、ニューラルネットワークの応用も活発に検討されている [5], [8]。

本稿では、階層形ニューラルネットワークを用いたブレイン・コンピュータ・インターフェイスについて、検討を行う。階層形ニューラルネットワークを用いて、脳波に基づくメンタルタスクの分類を行い、その性能を評価する。また、汎化能力を向上させる手法の効果や、使用するメンタルタスク数を減らした場合の推定精度への影響、などを検討する。

2 BCI の流れ

BCI の処理の流れは、以下のようになる。まず、被験者がやりたいことを想像し、そのときの脳波を測定する。その後、前処理した脳波から抽出した特徴に基づいて、脳波を分類し、被験者の意図したことを推定する。そして、その推定結果に基づいて、機器を操作する。

2.1 脳波の測定

脳波の測定方法には、2種類ある。それは、電極の付いたキヤップを被る方法と、直接電極を挿す方法である。

2.2 前処理

脳波を測定する際には、脳波以外の信号や雑音が混入する。これらを除去するために前処理を行う。

2.3 特徴抽出

脳波から特徴を抽出してメンタルタスクの分類を行う。波形分類のための特徴量としては、従来からフーリエ変換やスペクトル、自己回帰モデルで表現したときの係数など多くの特徴がある。脳波によるメンタルタスクの分類においても有効な特徴を抽出することが重要である。

2.4 特徴分類

抽出した特徴に基づいて、メンタルタスクを推定する。この特徴分類には、ニューラルネットワークや確率モデルなどが用いられる。

2.5 機器の操作

メンタルタスクの分類結果に基づいて、機器を操作する。

3 脳波データと特徴抽出

本稿では、シミュレーション用データとして、コロラド州立大学が公開している脳波データを用いる [1]。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 (Rotation)
- 数字を順番に書くことを想像 (Counting)

脳波を測定する際の電極の位置は、図1に示す、C3, C4, P3, P4, O1, O2, EOG の7チャネルである。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チャネル分のデータが、1つのデータセットとなる。

3.1 セグメント分割

1チャネルあたり10秒間の脳波データ（図2）を、0.5秒（125サンプル）のセグメントに分割する（図3）。分類結果は、0.25秒ごとに出す（図3の↓の部分）。

3.2 特徴量

特徴量として、フーリエ変換の振幅（絶対値）を用いた。セグメントごとにフーリエ変換し、その振幅を求める（図4）[2]。

3.3 平均化によるサンプル数低減

連続する複数サンプルで平均化することにより、データのサンプル数を20に低減する（図5）。

3.4 データの非線形正規化

脳波の周波数特性は一様に分布しておらず、値の小さいサンプルが多い。そこで、小さい値を伸張し、大きな値を圧縮する非線形な正規化を行う。非線形関数として式(1)を用いた。その形を図6に示す。

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

振幅は、対称なので、半分だけ用いる。これを、7チャネル分並べたものが、ニューラルネットワークへの入力となる(図8)。

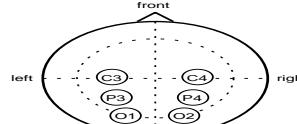


図1: 電極の位置

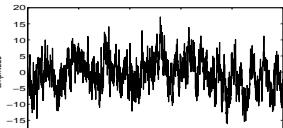


図2: 1チャネルの脳波

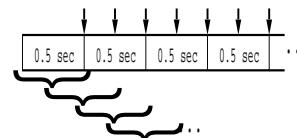


図3: セグメント分割

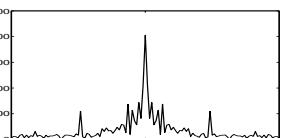


図4: フーリエ変換の振幅

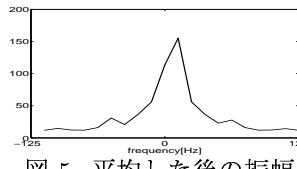


図5: 平均した後の振幅

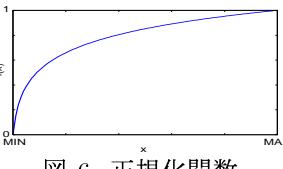


図6: 正規化関数

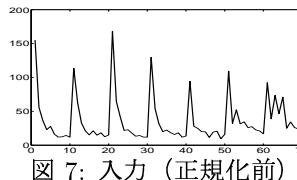


図7: 入力(正規化前)

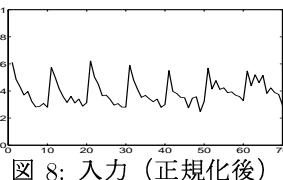


図8: 入力(正規化後)

4 ニューラルネットワークによる分類

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2層形ニューラルネットワークである。隠れ層、及び出力層で用いるユニットの活性化関数はシグモイド関数を用いる。入力ユニット数が($\frac{\text{脳波データのサンプル数}}{2}$) $\times 7$ チャネルであり、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。各出力ユニットは1個のメンタルタスクを表現する。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に1、その他は0を割り当てる。推定過程では、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

ト)とする。結合重みの学習はバックプロパゲーション(BP)法で行った。

5 シミュレーションの準備

5.1 脳波データ

5種類のメンタルタスクに対して、10秒間の測定を10回ずつ行ったので、合計50組の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]。

5.2 推定結果の評価

メンタルタスクの推定結果は、正答・誤答表を用いて表す。「行」が実際に行われたメンタルタスクを表し、「列」がニューラルネットワークによって分類されたメンタルタスク(リジェクトを含む)を表す。正しく分類された結果は対角線上に現れる。この表から、正答率と誤答率を計算する。

$$\begin{aligned} \text{正答率} &= \frac{\text{正答数}}{\text{全データ数}} \\ \text{誤答率} &= \frac{\text{誤答数}}{\text{全データ数}} \\ &= \frac{\text{全データ数} - (\text{正答数} + \text{リジェクト数})}{\text{全データ数}} \end{aligned}$$

ここで、正答数は、正しく分類されたデータ数、誤答数は、誤って正しくないタスクに分類されたデータ数、リジェクト数は、リジェクトされたデータ数を表す。つまり、

$$\text{全データ数} = \text{正答数} + \text{誤答数} + \text{リジェクト数}$$

となる。また、正答率と誤答率から、その比を計算する。

$$\text{比} = \frac{\text{正答率}}{\text{正答率} + \text{誤答率}}$$

5.3 各種パラメータの設定

- 隠れ層のユニット数: 20
- 学習係数: 0.2
- 重みの初期値: -0.2~+0.2の範囲でランダム
- リジェクトのための閾値: 0.8
- 学習回数: 5000

6 シミュレーション結果

6.1 被験者による違い

2人の被験者の脳波を用いて、それぞれシミュレーションを行った。

学習・テストデータに対する正答率は、図9、図10、学習・テストデータに対する誤答率は、図11、図12のようになった。

また、学習・テストデータに対する正答率・誤答率を、学習回数4001回～5000回にわたって平均した値を表1に示す。

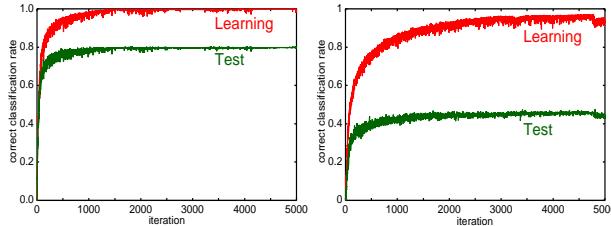


図9: 被験者1の正答率 図10: 被験者2の正答率

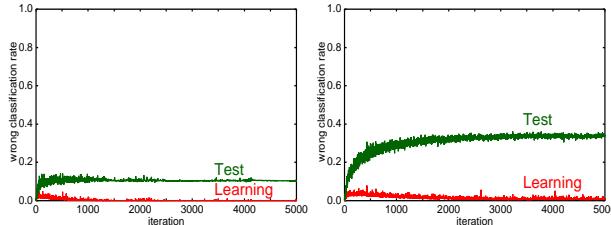


図11: 被験者1の誤答率 図12: 被験者2の誤答率

表1: 学習・テストデータに対する正答・誤答率

被験者	学習データ			テストデータ		
	正	誤	比	正	誤	比
1	99.7	0.1	0.99	79.7	10.5	0.88
2	95.5	0.8	0.57	45.5	33.7	0.99

テストデータに対する正答率は、被験者1では、約80%に達しているのに対し、被験者2では、約45%にとどまっている。学習データに対する正答率は高いので、学習自体はうまくできているが、テストデータに対する汎化能力が十分でないことがわかる。テストデータに対する推定精度が低い場合には、ニューラルネットワークの汎化能力の向上が必要である。

6.2 汎化能力の向上

汎化能力を向上させる手法として、

- 重みの抑制制御 (Weight Decay 法)
- 入力にランダムノイズを加える方法

について、その効果を検討する。被験者2の脳波データに対して、それぞれシミュレーションを行った。

6.2.1 重みの抑制制御 (Weight Decay 法)

重みの更新式(式(2))を式(3)のように変更する。

$$\omega_{ij} \leftarrow \omega_{ij} - \eta \frac{\partial E^2}{\partial \omega_{ij}} \quad (2)$$

$$\omega_{ij} \leftarrow \omega_{ij} - \eta \frac{\partial E^2}{\partial \omega_{ij}} - \alpha \omega_{ij} \quad (3)$$

これにより、不要な重みが0に近付き、汎化能力の向上が期待される。

$\alpha=0.000001, 0.000002, 0.000005, 0.00001$ に対して、シミュレーションを行った。

テストデータに対する正答率、誤答率は、図13、図14のようになった。また、テストデータに対する正答率・誤答率を、学習回数4001回～5000回にわたって平均した値を表2に示す。

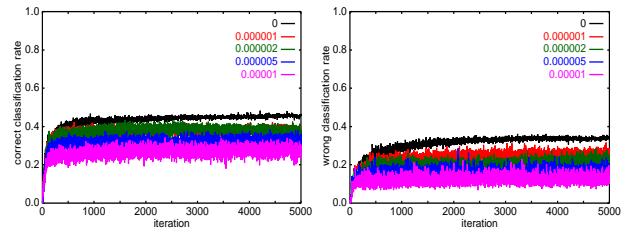


図13: 正答率(重みの抑制) 図14: 誤答率(重みの抑制)

表2: 正答率・誤答率の平均値(重みの抑制制御)

α	正答率	誤答率	比
0	45.5	33.7	0.57
0.000001	38.2	25.5	0.60
0.000002	37.8	21.9	0.63
0.000005	32.5	16.3	0.67
0.00001	27.7	12.7	0.69

α が大きくなるにつれて、正答率、誤答率ともに減少しているが、その比は大きくなっている。用途により、正答率が少々低くなても、誤答率を低くすることが重要な場合には、この手法は有効であると考えられる。

6.2.2 入力にランダムノイズを加える方法

入力にノイズを付加することにより、学習データがカバーする領域を広げ、汎化能力の向上を図る。

付加するノイズ幅土0.05、土0.1、土0.2に対して、シミュレーションを行った。

テストデータに対する正答率、誤答率は、図15、図16のようになった。また、テストデータに対する正答

率・誤答率を、学習回数 4001 回～5000 回にわたって平均した値を表 3 に示す。

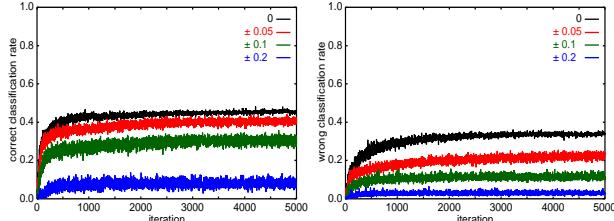


図 15: 正答率 (ノイズ)　図 16: 誤答率 (ノイズ)

表 3: 正答率・誤答率の平均値 (入力にノイズ付加)

ノイズ幅	正答率	誤答率	比
0	45.5	33.7	0.57
± 0.05	40.5	22.1	0.65
± 0.1	31.0	11.3	0.72
± 0.2	8.2	2.9	0.74

ノイズ幅が大きくなるにつれて、正答率、誤答率ともに減少しているが、その比は大きくなっている。用途により、正答率が少々低くあっても、誤答率を低くすることが重要な場合には、この手法は有効であると考えられる。

6.3 使用するメンタルタスク数による違い

これまで、分類するメンタルタスクは 5 種類であったが、使用するメンタルタスクの数を減らした場合について、検討を行う。

ここで、5 種類のメンタルタスクを用いた場合の被験者ごとのテストデータに対する正答・誤答表を、表 4、表 5 に示す。

正答・誤答表をみると、メンタルタスクにより、正答率・誤答率に差があることがわかる。被験者 1 では、L (手紙の文を考える)、被験者 2 では、M (掛け算で暗算をする) と R (回転する 3 次元物体を想像) に対する正答率が低く、誤答率が高い。

6.3.1 使用するメンタルタスク数 4 の場合

そこで、5 種類のメンタルタスクを用いて学習を行ったニューラルネットワークにより、使用しないメンタルタスク以外の脳波を分類した場合と、初めから 1 種類のメンタルタスクを除外して、4 種類のメンタルタスクで学習を行った場合について、正答率・誤答率の変化を調べた。

それぞれの場合のテストデータに対する正答率・誤答率は、表 6、表 7 のようになった。

表 4: 被験者 1 のテストデータに対する正答・誤答表

	B	M	L	R	C	rej	正	誤
B	326	11	12	0	2	39	83.6	6.4
M	18	328	8	0	9	27	84.1	9.0
L	23	2	258	14	34	59	66.2	18.7
R	2	1	26	326	4	31	83.6	8.5
C	8	11	9	1	328	33	84.1	7.4

表 5: 被験者 2 のテストデータに対する正答・誤答表

	B	M	L	R	C	rej	正	誤
B	217	40	29	14	8	82	55.6	23.3
M	65	106	31	44	45	99	27.2	47.4
L	48	23	223	31	16	49	57.2	30.3
R	8	65	14	155	65	83	39.7	39.0
C	21	44	10	48	205	62	52.6	31.5

表 6: 被験者 1 の正答率・誤答率 (1 タスク不使用)

不使用	5 種類で学習			初めから除外		
	正	誤	比	正	誤	比
B	79.6	7.6	0.91	84.0	8.9	0.90
M	79.4	8.7	0.90	81.0	9.4	0.90
L	84.0	4.3	0.95	85.9	7.6	0.93
R	79.5	9.4	0.89	78.9	12.6	0.86
C	79.4	7.5	0.91	80.6	13.3	0.86
全て使用	80.3	10.0	0.89			

表 7: 被験者 2 の正答率・誤答率 (1 タスク不使用)

不使用	5 種類で学習			初めから除外		
	正	誤	比	正	誤	比
B	44.9	28.3	0.61	47.6	34.9	0.58
M	51.8	20.1	0.72	56.5	27.9	0.67
L	44.0	30.2	0.59	46.3	35.3	0.57
R	48.6	24.4	0.67	52.5	30.9	0.63
C	45.3	26.6	0.63	50.3	35.6	0.59
全て使用	46.5	34.3	0.58			

5種類のメンタルタスクで学習・分類したときと比べて、被験者1では、L（手紙の文を考える）、被験者2では、M（掛け算で暗算をする）とR（回転する3次元物体を想像）を使用しなかった場合の正答率が上がり、誤答率が下がった。これは、各被験者において、正答率が低く、誤答率が高かったメンタルタスクである。うまく推定できないメンタルタスクを使用しないことによって、推定精度が向上することがわかった。

また、5種類のメンタルタスクを用いて学習を行ったニューラルネットワークに対して、使用しないメンタルタスク以外の脳波を入力した場合と、初めから1種類のメンタルタスクを除外して、4種類のメンタルタスクで学習を行った場合とを比べると、正答率・誤答率とともに、全体的に後者のほうがやや高いが、その比は、前者のほうが優れていることがわかる。

6.3.2 使用するメンタルタスク数3の場合

被験者2の脳波に対して、使用するメンタルタスク数を3にした場合について、同様に正答率・誤答率の変化を調べた。それぞれの場合のテストデータに対する正答率・誤答率は、表8のようになった。

表8: 被験者2の正答率・誤答率(2タスク不使用)

	5種類で学習			初めから除外		
	正	誤	比	正	誤	比
B,M	51.2	15.8	0.76	63.6	25.8	0.71
B,L	40.6	27.2	0.60	51.4	34.6	0.60
B,R	47.1	14.6	0.76	60.8	28.2	0.68
B,C	42.4	18.3	0.70	54.7	32.7	0.63
M,L	50.0	14.2	0.78	62.2	24.5	0.72
M,R	55.8	11.4	0.83	68.5	18.3	0.79
M,C	51.9	12.6	0.81	67.0	23.6	0.74
L,R	46.1	19.3	0.70	58.3	26.9	0.68
L,C	41.7	20.5	0.67	55.3	31.1	0.64
R,C	47.2	20.3	0.70	55.8	31.4	0.64
全て使用	46.5	34.3	0.58			

前節と同じ傾向であるが、M,RやM,Cを除外した場合の正答率が70%近くになり、メンタルタスクを選ぶことにより、正答率を高くすることが可能である。

7 まとめ

階層形ニューラルネットワークを用いたブレイン・コンピュータ・インターフェイスについて検討を行った。特徴抽出における、短時間波形や少ないサンプル数でも高い正答率が得られた。非線形正規化の方法を提案し、

有効性を確認した。個人差やメンタルタスクの種類や組み合わせによる正答率のばらつきが大きいことを確認した。このために、汎化能力を高める学習法を適用したが、正答率は減少した。しかし、正答率／誤答率は向上したので、効果もあることが確認された。正答率を高めるにはメンタルタスクの種類の組み合わせも重要であり、分類が容易になる脳波を発生するためのメンタルタスクを個人調整(バイオフィードバック)することも重要である。

参考文献

- [1] <http://www.cs.colostate.edu/eeg/>
- [2] 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”, 信学技報, vol. 105, no. 174, SIP2005-54, pp. 25-30, 2005年7月.
- [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] K. R. Muller, J. Kohlmorgen, A. Ziehe, and B. Blankertz, “Decomposition algorithms for analysing brain signals,” Adaptive Systems for Signal Processing, Communications and Control, pp. 105-110, 2000.
- [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] G. Pfurtscheller and C. Neuper, “Motor imagery and direct brain-computer communication,” Proc. IEEE, vol. 89, no. 7, pp. 1123-1134, July 2001.
- [7] Janne Lehtonen, ”EEG-based Brain Computer Interfaces,” Helsinki University of Technology, Master’s Theses, 2002.
- [8] 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.
- [9] 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.
- [10] J. R. Millan, “On the need for on-line learning in brain-computer interfaces,” Proc. IJCNN, pp. 2877-2882, 2004.
- [11] 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.