

脳波のスペクトルとニューラルネットワークによるBCIにおける 特徴抽出と汎化能力について

On Feature Extraction and Generalization in BCI Based on Spectra of Brain Waves and Neural Network

金田 泰明[†] 中山 謙二[‡] 平野 晃宏[‡]
Kiyoto Inagaki Kenji Nakayama Akihiro Hirano

^{†‡} 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.

E-mail: [†]kaneda@leo.ec.t.kanazawa-u.ac.jp, [‡]{nakayama, hirano}@t.kanazawa-u.ac.jp

あらまし

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ブレイン・コンピュータ・インタフェース (BCI) に関して、前処理の方法を提案し、メンタルタスクの分類性能を向上させる方法が報告されている。本稿では、この方法においてどのような特徴が抽出されているか解析した。まず、隠れ層から出力層の結合荷重を解析し、メンタルタスクに対して独立になる傾向があることが分かった。次に、入力層から隠れ層への結合荷重を解析し、相関係数が、同じメンタルタスクでは大きく、異なるメンタルタスクでは小さくなる傾向を明らかにした。更に、分類精度の低い被験者では、この傾向が明確に出ていないことも分かった。次に、汎化能力に関して、ニューラルネットワークの入力に乱数を加える方法と学習中に重み係数を抑圧する方法を検討し、前者のほうがより効果が高いことを確認した。

ABSTRACT

Multilayer neural networks have been applied to Brain Computer Interface (BCI), which is one of hopeful interface technologies between humans and machines. In this paper, first, features extracted by the neural network are analyzed based on correlation coefficients of connection weights from the input layer to the hidden layer. There some relations between the correlation coefficients and classification accuracy. Second, two kinds of generalization techniques, including adding small random noises to the input data and decaying connection weight magnitude, are applied. Their usefulness are analyzed and compared. The former is better than latter. In our previous work, the classification accuracy

of 64% ~ 74% have been achieved. By applying the generalization techniques the accuracy is improved up to 80% ~ 88%.

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ものが使用され、また、新しいインターフェイスも検討されている。健常者にとっては、キーボードやマウスが一般的であるが、身体に障害を持つ人の場合は、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、コンピュータとのインターフェイスとする、Brain Computer Interface (BCI) が近年注目されている。BCIの基本的な原理は、被験者の脳波を多チャンネルで測定し、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を操作することである [1]。BCIの技術を応用することで、重度の運動障害を抱える患者が、コンピュータや車いす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 [2]。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思で自由に操作することにより、VRの世界で様々な仮想体験をすることが可能となる。

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 [14]-[16]。

本稿では、脳波の特徴量について、階層形ニューラルネットワークの結合荷重の大きさに基づいて解析する。また、汎化能力を向上する方法を提案し、分類性能の評価を行なう。

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 (Rotation)
- 数字を順番に書くことを想像 (Counting)




図 1: 電極の位置




図 2: 1チャンネルの脳波

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250Hz×10sec=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。あるチャンネルにおける脳波データの一例を図2に示す。

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 [14]-[16]。

3.1 セグメント分割

BCIにおける、応答時間を短縮するために、1チャンネルあたり10秒間の脳波データを、0.5秒 (125サンプル)のセグメントに分割する。分類結果は0.25秒ごとに出力するものとする。

3.2 特徴量

脳波の特徴量として、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。

3.3 平均化によるサンプル数低減

連続する複数周波数帯域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。実際のスペクトルは、対称性をもつので、入力データとしては1チャンネルあたり10サンプルまで低減される。

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。

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

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 汎化能力の向上

脳波は非常に微弱な電位変動を捉えるので、被験者の健康状態や、同じ被験者でも、測定環境に大きく左右される。ニューラルネットワークを学習する際に用いられる脳波データと実際の分類に用いられる脳波データの間でばらつきが生じる。そのため、BCIにとって、ニューラルネットワークの汎化能力は非常に重要である。

メンタルタスクを分類する境界面を学習データの分布よりも広げ、かつ、隣接するメンタルタスクの領域との調整も必要である。本稿では、ニューラルネットワークでよく用いられる2つの手法を適用する。まず、入力にランダムなノイズを付加する方法 [11]。もう1つは、Weight Decay法を用いて、結合荷重の大きさを抑制する方法である [12],[13]。

4.1 入力に乱数を付加

学習のエポック毎に異なる乱数をニューラルネットワークの入力データに付加する。これにより、学習データ近傍で分類境界を広げ、汎化能力を高めることができる。但し、付加する乱数の分布範囲については調整する必要がある。

4.2 Weight Decay による結合荷重の抑制

ニューラルネットワークの学習においては、境界面を学習データから広げる方法として、学習中に活性化関数の傾きを緩くする方法がある。これは、等価的に重み係数を抑制することで行われる。抑制の程度については、問題に応じて調整する必要がある。

5 シミュレーション条件

5.1 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、隠れ層では tanh 関数を用い、出力層では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。

5.2 測定条件と各種パラメータ設定

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]。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。

- ・活性化関数: 隠れ層: tanh 関数
出力層: シグモイド関数
- ・隠れ層のユニット数: 20
- ・学習係数: 0.02
- ・結合荷重の初期値: -0.2~+0.2の範囲でランダム
- ・リジェクトのための閾値: 0.7

5.3 推定結果の評価

メンタルタスクの推定結果は、正答率・誤答率を用いて表す。

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

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。

$$\text{正誤比} = \frac{\text{正答率}}{\text{正答率} + \text{誤答率}}$$

6 ニューラルネットワークによる特徴抽出

本節では、学習後のニューラルネットワークの結合荷重に基づいて、抽出された特徴量を解析する。




図 3: 隠れ層から出力層への結合荷重の分布 (被験者 1)




図 4: 入力層から隠れ層への結合荷重の分布

6.1 隠れ層から出力層への結合荷重

ニューラルネットワークの学習の過程で、脳波データの特徴がどのように抽出されているか、ネットワークの結合荷重を見ることで解析する。隠れ層から出力層への結合荷重の分布を図3に示す。横軸は隠れユニットを、縦軸は出力ユニットを表している。ここで、出力ユニットは各メンタルタスクと対応している。各ユニットの色が

赤くなればなるほど、結合荷重が正の値で大きいことを示している。逆に色が、青になるほど、結合荷重は負の値を大きく示す。例えば、4番と9番の隠れユニットはタスク1と強く結合を示している。また、1番と7番と17番の隠れユニットはタスク3と強く結合していることがわかる。これらの隠れユニットと他の出力ユニットの結合荷重はあまり大きくない(他のタスクにとって重要な隠れユニットではない)ので、タスク1・3にとって、前述の隠れユニットが重要な役割を担っている。

6.2 入力層から隠れ層への結合荷重

前節で示したように、隠れユニットとメンタルタスクの関係が明確であるので、入力層から隠れ層への結合荷重が各メンタルタスクの特徴量を表している。この結合荷重を図4に示す。横軸が入力ユニットの番号、縦軸が隠れユニットの番号である。

入力層から隠れ層への結合荷重の特徴を解析するために相関係数を用いる。すなわち、同じメンタルタスクに対する結合荷重の相関係数と異なるメンタルタスクに対する相関係数を比較することにより、結合荷重がどの程度特徴を表現しているかを解析する。

各タスクごとに、独立して大きな値を示す隠れユニットを抽出し、同一タスク間・異タスク間における相関係数を表1に示す。()内の数字は隠れユニット番号を表し、2段目の数値はそれぞれの結合荷重の大きさを表している。表1より、同一タスク間では、全体的に正の相関がある。同一タスク内でも相関性があまり顕著に現れていない3番のタスクについては、表2より、他のタスクに比べ、分類精度が良くない。よって、3番のメンタルタスクに関しては、ニューラルネットワークでの特徴が安定していないことがわかる。

表 1: メンタルタスク間の相関係数 (被験者 1)

Task(Hidden No)	1(4)	1(9)	2(11)	2(16)	3(7)
Weight	6.52	9.77	4.31	8.02	10.1
Task1(4)	1.0	0.73	-0.56	-0.89	-0.06
Task1(9)	0.73	1.0	-0.06	-0.49	-0.30
Task2(11)	-0.56	-0.06	1.0	0.82	-0.65
Task2(16)	-0.89	-0.49	0.82	1.0	-0.35
Task3(7)	-0.06	-0.30	-0.65	-0.35	1.0
Task3(17)	-0.21	-0.11	0.43	0.47	-0.51
Task4(5)	0.24	-0.06	0.17	-0.10	-0.32
Task4(6)	0.70	0.59	-0.13	-0.44	-0.40
Task5(2)	-0.31	-0.35	0.45	0.32	-0.16
Task5(8)	-0.59	-0.53	0.40	0.47	0.13

Task(Hidden No)	3(17)	4(5)	4(6)	5(2)	5(8)
Weight	9.69	3.41	5.26	9.09	8.20
Task1(4)	-0.21	0.24	0.70	-0.31	-0.59
Task1(9)	-0.11	-0.06	0.59	-0.35	-0.53
Task2(11)	0.43	0.17	-0.13	0.45	0.40
Task2(16)	0.47	-0.10	-0.44	0.32	0.47
Task3(7)	-0.51	-0.32	-0.40	-0.17	0.13
Task3(17)	1.0	0.30	0.16	0.09	0.04
Task4(5)	0.30	1.0	0.31	0.67	0.32
Task4(6)	0.16	0.31	1.0	-0.43	-0.75
Task5(2)	0.09	0.67	-0.43	1.0	0.88
Task5(8)	0.04	0.32	-0.75	0.88	1.0

表 2: メンタルタスクごとの分類精度

タスク	B	M	L	R	C
B	8	1	1	0	0
M	1	8	1	0	0
L	1	1	6	1	1
R	0	1	0	9	0
C	0	0	0	0	10

6.3 被験者による違い

ここでは、正答率の低い被験者について特徴を解析する。まず、隠れ層から出力層への結合荷重を図5に示す。図3のように各メンタルタスクに対応する隠れユニットが明確になっていない。

さらに、各メンタルタスクに対して比較的大きな結合荷重を有する隠れユニットへの入力層からの結合荷重を用いて相関係数を求めた結果を表3に示す。これからも分かるように、同じメンタルタスク内での相関係数が必ずしも大きくなく、各メンタルタスクを表す特徴が充分に抽出されていないことが分かる。




図 5: 隠れ層から出力層への結合荷重の分布 (被験者 2)

7 汎化能力の向上

7.1 乱数を加える方法

階層形ニューラルネットワークの入力データは、非線形関数により、0 から 1 に正規化される。ここでは汎化

表 3: メンタルタスク間の相関係数 (被験者 2)

Task(Hidden No)	1(5)	1(11)	2(9)	2(14)	3(7)
Weight	9.03	8.42	7.17	2.76	7.73
Task1(5)	1.0	0.53	-0.45	0.08	-0.53
Task1(11)	0.53	1.0	0.13	-0.08	0.31
Task2(9)	-0.45	0.13	1.0	0.29	0.79
Task2(14)	0.08	-0.08	0.29	1.0	-0.01
Task3(7)	-0.53	0.31	0.79	-0.01	1.0
Task3(12)	0.24	0.87	0.12	-0.09	0.37
Task4(3)	-0.51	-0.73	0.06	0.21	-0.26
Task4(18)	-0.22	-0.41	0.07	0.47	-0.25
Task5(10)	0.01	-0.33	-0.38	0.31	-0.30
Task5(20)	-0.11	0.05	-0.13	-0.12	0.25

Task(Hidden No)	3(12)	4(3)	4(18)	5(10)	5(20)
Weight	5.13	10.1	5.72	17.33	5.53
Task1(5)	0.24	-0.51	-0.22	0.01	-0.11
Task1(11)	0.87	-0.73	-0.41	-0.33	0.05
Task2(9)	0.12	0.06	0.07	-0.38	-0.13
Task2(14)	-0.09	0.21	0.47	0.31	-0.12
Task3(7)	0.37	-0.26	-0.25	-0.30	0.25
Task3(12)	1.0	-0.44	-0.14	-0.30	-0.03
Task4(3)	-0.44	1.0	0.81	0.09	-0.49
Task4(18)	-0.14	0.81	1.0	0.33	-0.49
Task5(10)	-0.30	0.09	0.33	1.0	0.26
Task5(20)	-0.03	-0.49	-0.49	0.26	1.0

能力を向上するために、 ± 0.1 に一様に分布する乱数を、学習時に入力データに重畳する。ここで、乱数の振幅は経験的に決定される。表 4, 5 に 2 人の被験者についての分類性能を示す。被験者 1 では、乱数を加える方法において、正答率が 10 数%上昇している。誤答率も同時に減少し、汎化能力は大きく向上している。他方、被験者 2 でも同様に、正答率・誤答率共に改善し、両被験者とも、汎化能力を向上する方法として、ランダムノイズを加える方法は有効である。

7.2 結合荷重の抑制制御

ニューラルネットワークの学習時に、式 (2) のような更新式を用いて、各層の結合荷重を定数倍する。

$$g(n) = g_0 + (1 - g_0) \frac{1 - e^{2\pi an}}{1 + e^{2\pi an}}, \quad n \geq 0 \quad (2)$$

$$\hat{w}(n) = g(n)w(n) \quad (3)$$

g_0 は Weight Decay を始める際の初期値で、0.99~0.994 の範囲で設定し、 a は学習の収束性に依じて、いつまで結

合荷重を抑制するかを決定するもので、0.5~1.0 の間で設定する。いずれの変数も経験的に決定する。 $\hat{w}(n)$ は修正後の結合荷重で、次のエポックに用いられる。Weight Decay を用いたときの分類性能を表 4, 5 に示す。被験者 1 では、正答率・誤答率共に改善し、汎化能力を向上する手法を適用しない場合に比べ、分類性能は向上した。しかしながら、汎化能力の向上は、乱数を加える方が顕著であった。他方、被験者 2 では、正答率こそ上昇したが、誤答率も同時に上昇してしまった。この場合、乱数を加える方法がまだ良好な性能を持っている。

7.3 Weight Decay&スケーリング

Weight Decay では学習における境界は、異なるクラス間のちょうど中央に形成される。しかしながら、クラス間の境界付近にあるデータの場合、結合荷重の抑制を行なっただけでは、はっきりとした出力が得られない可能性がある。そこで、Weight Decay により、結合荷重の抑制を行なった後に、全ての結合荷重を 1.5~2 倍することにより、よりはっきりとした出力を得ることができる。Weight Decay 後のスケーリングによる分類性能を表 4, 5 に示す。両被験者ともに、正答率は大きく向上しているが、同時に誤答率も高くなってしまふ。

表 4: 汎化能力の向上 (被験者 1)

方式	被験者 1		
	正答率	誤答率	比
従来法	74.0	6.0	0.925
乱数を加える	88.0	2.0	0.978
Weight Decay	82.0	4.0	0.954
Weight Decay&スケーリング	88.0	12.0	0.88

表 5: 汎化能力の向上 (被験者 2)

方式	被験者 2		
	正答率	誤答率	比
従来法	64.0	8.0	0.889
乱数を加える	80.0	4.0	0.952
Weight Decay	60.0	4.0	0.938
Weight Decay&スケーリング	84.0	16.0	0.84

7.4 各種方法の比較

乱数を付加する方法は個々の学習データに乱数を付加するので、学習データの回りで境界面が拡大する。また、学習データが密な領域ではその効果が顕著であり、粗な領域では学習回数が少ないためにその効果が現れにくい。すなわち、学習データの分布状況まで考慮できる。これに対して、Weight Decay 法は、等価的に活性化関数の傾

きを緩くすることで分離点を制御しており、学習データの分布状況が反映されにくい。

Weight Decay でスケーリングを行う方法は、学習後に等価的に活性化関数の傾きを急峻にすることになり、無効になっていた分類を正当な分類とすることができる。しかし、分岐点がずれていると、誤答率も増加することになる。

8 まとめ

階層形ニューラルネットワークを用いたBCIにおいて、抽出された特徴の解析と、汎化能力の検討を行った。正答率の高い被験者では、入力層から隠れ層への結合荷重で特徴が抽出されていることを相関係数を用いて確認した。また、相関係数の大きさや分布状況とメンタルタスクの分類精度に関連性があることが確認できた。汎化能力に関しては、ニューラルネットワークの入力に乱数を付加する方法が有効であった。

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 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] 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] 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.
- [12] 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.
- [13] M.Tonomura and K. Nakayama, "A hybrid learning algorithm for multilayer perceptrons to improve generalization under sparse training data conditions", *Proc. IJCNN2001*, Washington DC, pp.967-972, July, 2001.
- [14] 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.
- [15] 稲垣清人, 中山謙二, "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・インターフェースの検討", *電子情報通信学会, 第20回信号処理シンポジウム(高知)*, 2005.11.
- [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] 金田泰明, 中山謙二, 平野晃宏, "FFTと階層型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・インターフェース:特徴抽出と汎化能力の向上について", *電子情報通信学会, 信学技法*, Vol.107 No.101 pp.1-6, 2007.06.