

MEGと階層形ニューラルネットワークによる BCIにおけるチャンネル最適化と特徴解析

A BCI Using MEGvision and Multilayer Neural Network - Channel Optimization and Main Lobe Contribution

金田 泰明[†] 中山 謙二[‡] 平野 晃宏[‡] 春田 康博
Yasuaki Kaneda Kenji Nakayama Akihiro Hirano Yasuhiro Haruta

[†] 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 and Computer Science

Graduate School of Natural Science and Technology, Kanazawa Univ.

横河電機株式会社

Yokogawa Electric Corporation

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 (FFT) と階層形ニューラルネットワークを使ったブレイン・コンピュータ・インターフェイス (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手法が報告されている。

本稿では、横河電機株式会社の脳磁計測システム MEGVision を使って被験者の脳活動を測定する。MEGVision は 160 個のセンサーを持つ全頭型脳磁計測システムであり、使用するセンサー位置は「前頭葉・頭頂葉・側頭葉・後頭葉」から左右合わせて 8 チャンネル選択する。最適チャンネルを最も高い分類性能が得られるように初期状態から移動させることで探索する。2 人の被験者について 4 つのメンタルタスク (リラックス, 暗算, 体を動かす, 回転体のイメージ) を測定する。

分類テストの結果、初期状態では分類性能は 77.5~86.88 % だったのに対し、チャンネル位置の最適化を行うことで、88.75~93.75 % まで分類性能は向上した。加えて、8 つの部位間の特徴解析を行った。

ABSTRACT

Multilayer neural network (MLNN) and the FFT amplitude of brain waves have been applied to 'Brain Computer Interface' (BCI).

In this paper, a magnetoencephalograph (MEG) system, 'MEGVision' developed by Yokogawa Corporation, is used to measure brain activities. MEGvision is

a 160-channel whole-head MEG system. Channels are selected from 8 main regions, a frontal lobe, a temporal lobe, a parietal lobe and an occipital lobe, located at the central point in the 8 lobes, are initially selected. Optimum channels are searched for in the same lobe as the initial channels in order to achieve high classification accuracy. Two subjects and four mental tasks, including relaxed situation, multiplication, playing sport and rotating an object, are used. The brain waves are measured 10 times for one subject and one mental task.

Among them, 8 data sets are used for training the MLNN, and the remaining 2 data sets are used for testing.

5 kinds of combinations of 2 data sets are selected for testing. Rates of correct classification by using the initial channels are 77.5 ~ 86.88 %. By optimizing the channels, the accuracy is improved up to 88.75 ~ 93.75 %, which is very high accuracy. Furthermore, contributions of the brain waves in the 8 lobes are analyzed.

1 まえがき

人とコンピュータをつなぐインターフェイスとして、近年ブレイン・コンピュータ・インターフェイス (BCI) が活発に研究されている [1], [2]. 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でもコンピュータを操作し、他者とのコミュニケーションを円滑に進めることができる。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、隠れマルコフモデルを用いる方法などがある [3], [4]。その中でニューラルネットワークを用いる方式が報告されている [5], [6], [7], [8], [9], [10]。また、脳波のFFTと階層形ニューラルネットワーク (MLNN) を用いる方式について、有用な前処理の方法と正規化手法、さらには汎化能力を向上させる入力にランダムノイズを加える方式について提案した [12], [13]。

本研究では脳波 (EEG) ではなく、脳磁 (MEG) のFFTと階層形ニューラルネットワークを用いたBCIを構築する。脳磁の測定法として、横河電機株式会社の脳磁計測システム MEGvision を用いる。MEGvision は 160 個のセンサーを持つ全頭型の脳磁計で、高い時間解像度と空間解像度をもつ。本研究では、使用するセンサー位置は左右両半球から 8ch とし、使用するセンサー位置の最適化を行い、分類性能に与える影響について解析を行う。また、メンタルタスク分類において、大脳における各部位の影響の解析を行う。さらに、結合荷重を用いて、8ch の部位間の特徴解析を行う。

2 MEGvision

MEG は脳の神経細胞が活動することにより発生する磁場を計測したものである。MEGvision は MEG を高い時間・空間解像度で非侵襲的に測定することができる。MEG では、SQUID (超伝導量子干渉素子) 等の技術を用いて、脳の極めて微弱な磁場を計測する [14]。MEGvision は 160ch の全頭をカバーする SQUID を用いて、高い空間解像度を持った脳活動を測定することができる。また被験者は仰臥するだけで測定ことができ、被験者に対する負担も極めて小さい。

3 メンタルタスクと MEG の測定

3.1 メンタルタスク

本研究では以下の 4 つのメンタルタスクを用いる。

- 何も考えずリラックスする (Baseline).
- 3 桁 × 1 桁のかけ算を暗算で行う (Multiplying).
- 体を動かす様子をイメージする (Sport).
- 被験者に任意の回転する 3 次元物体をイメージする (Rotation).




図 1: MEGvision におけるチャンネル位置

3.2 MEG の測定

MEGvision における 160 個のセンサ位置は図 1 のようになる。青い点が頭部における実際の位置であり、チャンネルとも呼ばれる。MEG はこれら 160 のチャンネルで一度に測定される。測定後、0.3Hz の HPF, 500Hz の LPF でフィルタリングを行い、計算機に出力される。

被験者は MEGvision により、30 秒間安静閉眼状態で行う。30 秒間の測定波形のうち、中央 10 秒間を BCI に用いるデータとして抽出する。これはメンタルタスクのイメージにおいて、測定開始直後と測定終了間際は、メンタルタスク以外の外乱を受けやすいため、各メンタルタスク固有の特徴をうまく抽出するには不適切なデータであると考えられるためである。MEG はサンプリング周波数 1.2kHz で標本化されている。したがって、10sec × 1200Hz = 12000 点のデータがそれぞれのチャンネル、それぞれのメンタルタスクに含まれる。MEG は一つのメンタルタスクについて 10 回測定を行う。したがって、全てのメンタルタスクを測定すると、40 個のデータセットが存在する。




図 2: 初期状態におけるチャンネル位置 (被験者 1)




図 3: 最適化後のチャンネル位置 (被験者 1)

4 チャンネル最適化

本研究では、チャンネルの選び方として、脳の主要な8つの部位のチャンネルを選択する。すなわち、左右両半球の前頭葉・頭頂葉・側頭葉・後頭葉から2chずつ選択する。

これは各メンタルタスクにおいて、活発に活動する部位が異なると考えられ、その特徴をうまく抽出するには、主要な部位をカバーするようにチャンネルを選択することが重要ではないかと考えられるからである。チャンネル選択の方法として、まず初期状態として、前述の4つの部位の中心付近にチャンネルを設定する。最適チャンネルは、各部位ごとに分類性能を最大化するようにチャンネルを遷移することで探索を行う。被験者1の初期状態8chのチャンネル位置を図2に示す。

各部位でのチャンネルの探索は、まず初めに前頭葉から分類性能を最大化するように探索を行う。同様に他の部位についても、前の部位の探索が終わり次第、探索を行う。各部位での探索の方法として、初期状態の周囲で暫定の最適チャンネルを探索し、さらにその周囲で新たな最適チャンネルを探索する操作を繰り返す。図3に最適化後のチャンネル位置を示す。また、図4、図5に初期状態と最適化後の脳磁波形を示す。




図 4: 初期状態の脳磁波形 (被験者 1)




図 5: 最適化後の脳磁波形 (被験者 1)

5 脳磁データの前処理

脳波 (EEG) の前処理の方法はいくつか報告されており、本研究では、脳磁波形にもその前処理の方法を適用する。以下に大まかな前処理の概要を示す。

5.1 FFT の振幅

サンプリング周波数 1.2kHz の時間波形を FFT により周波数変換し、その振幅を用いる。

5.2 サンプル平均化

MLNN の規模を縮小し、計算量を削減するために、FFT 後のスペクトルを隣接する複数サンプル間で平均化する。これにより、20 サンプルまで低減される。また、スペクトルは対称性をもつため、20 サンプルのうち、10 サンプルのみ用いる。

5.3 非線形正規化

脳磁の周波数特性は一様に分布しておらず、帯域によっては値の小さなサンプルも多い。もし、値の小さいサンプルに MLNN での分類上、重要なデータが含まれていた場合、そのまま入力すると、値の大きなデータが支配的になり、学習がうまくいかない可能性が考えられる。そこで式 (1) に示す非線形関数により、正規化を行う。これにより値の大きいサンプルは圧縮され、値の小さいサンプルは伸張される。よって値の小さいサンプルに含まれる情報も効率的に利用することができる。式中の max , min は全チャンネルのデータにおける、最大値・最小値である。

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

6 階層形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

6.1 シミュレーション条件と分類性能の評価方法

階層形ニューラルネットワークとして、隠れ層が1層の2層型 MLNN を用いる。活性化関数として、隠れ層には tanh 関数を、出力層にはシグモイド関数を用いる。

入力層のユニット数は80、隠れ層のユニット数は30である。4つのメンタルタスクを分類するため、4つの出力ユニットに各メンタルタスクを対応させる。学習にはバックプロパゲーション法を用い、テストデータを入力した際、最も出力値の大きいユニットをネットワークが分類したメンタルタスクとして判断する。

測定した40個のデータセットの中で、8試行分に相当する32個のデータを学習し、残り2試行分に相当する8個のデータを用いて、分類性能のテストを行う。テストデータの組合せを20通り変えて評価を行う。各試行において、評価の基準として、式(2)~(4)で表される正答率、誤答率を用いて評価を行う。

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

$$P_e = \frac{N_e}{N_t} \times 100\% \quad (3)$$

$$N_t = N_c + N_e \quad (4)$$

- N_t :全テストデータ
- N_c :正しく分類されたデータ
- N_e :誤って分類されたデータ

6.2 各被験者についての分類性能

表1に各被験者の分類性能を示す。表1より、チャンネル最適化により、各被験者とも分類性能は向上した。特に被験者2において分類性能の向上が顕著である。

次に、20通りの平均値としての分類性能ではなく、各メンタルタスクごとにどれだけ正しく分類されているか、表2~4にメンタルタスクごとの分類性能を示す。

表2~3、表3~4より最適化を行うことで、分類性能の低かったメンタルタスクの分類数が底上げされていることが確認できた。両被験者とも、最適化を行うことで、リラックスした状態 (Baseline) を判別しやすくなっている。

表 1: 各被験者におけるチャンネル最適化の影響

チャンネル	被験者 1	被験者 2
初期状態	$P_c = 86.88\%$	$P_c = 77.5\%$
最適化後	$P_c = 93.75\%$	$P_c = 88.75\%$

表 2: 初期状態の分類性能 (被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	27	8	5	0	67.5%	32.5%
Multiplication	1	38	1	0	95.0%	5.0%
Sport	6	0	34	0	85.0%	15.0%
Rotation	0	0	0	40	100%	0%
				Av	86.88%	13.12%

表 3: 最適化後の分類性能 (被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	38	2	0	0	67.5%	32.5%
Multiplication	2	38	0	0	95.0%	5.0%
Sport	6	0	34	0	85.0%	15.0%
Rotation	0	0	0	40	100%	0%
				Av	93.75%	6.25%

表 4: 初期状態の分類性能 (被験者 2)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	22	16	0	2	55.0%	45.0%
Multiplication	7	33	0	0	82.5%	17.5%
Sport	0	0	30	10	75.0%	25.0%
Rotation	0	0	1	39	97.5%	2.5%
				Av	77.5%	22.5%

表 5: 最適化後の分類性能 (被験者 2)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	35	5	0	0	87.5%	12.5%
Multiplication	0	40	0	0	100%	0%
Sport	4	0	30	6	75.0%	25.0%
Rotation	0	0	3	37	92.5%	7.5%
				Av	88.75%	11.25%

7 各部位が分類性能に与える影響

MLNN を用いたメンタルタスクの分類において、各部位がどれだけ分類に影響を与えているか解析するため、8つのチャンネルから1つのチャンネルを除去して分類性能を評価した。ここで用いるチャンネル位置は最適化後のチャンネル位置とする。テストデータの組合せを20通り変えて、各部位を除去したときの分類性能を表6に示す。

さらに詳しく、各部位ごとに1ch除去したときのメンタルタスクごとの分類結果を表7~表15に示す。右頭頂葉がSportに、左側頭葉がBaselineとMultiplicationに影響を与えている。また、左頭頂葉と右後頭葉以外はSportに影響を与えている。よって、Sportは多くの部位に関係している可能性がある。

表7~表12から、被験者1について、左側頭葉を1ch除去したとき、BaselineとMultiplicationのタスクの分類が悪くなっていることが確認された。1ch除去することで、正答率が向上する場合があるが、被験者による差異が見られる。部位の影響は被験者により異なるので、メンタルタスクと部位の普遍的な関係に関しては、さらに検討が必要である。

表 6: 1ch 除去したときの分類性能

除去する ch	P_c (被験者 1)	P_c (被験者 2)
前頭葉 (左)	94.37%(↑0.62)	85.62%(↓3.13)
前頭葉 (右)	93.13%(↓0.62)	86.25%(↓2.5)
頭頂葉 (左)	96.88%(↑3.13)	86.25%(↓2.5)
頭頂葉 (右)	90.0%(↓3.75)	81.25%(↓7.5)
側頭葉 (左)	78.12%(↓15.63)	90.0%(↑1.25)
側頭葉 (右)	96.25%(↑2.5)	90.62%(↑1.87)
後頭葉 (左)	93.13%(↓0.62)	86.25%(↓2.5)
後頭葉 (右)	96.88%(↑3.13)	78.75%(↓10)

表 7: 1ch 除去後の分類性能 (左前頭葉・被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	38	2	0	0	95.0%	5.0%
Multiplication	1	39	0	0	97.5%	2.5%
Sport	5	0	35	0	87.5%	12.5%
Rotation	0	0	0	40	100%	0%
				Av	95.0%	5.0%

表 8: 1ch 除去後の分類性能 (左頭頂葉・被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	37	3	0	0	92.5%	7.5%
Multiplication	2	38	0	0	95.0%	5.0%
Sport	0	0	40	0	100%	0%
Rotation	0	0	0	40	100%	0%
				Av	96.88%	3.12%

表 9: 1ch 除去後の分類性能 (右頭頂葉・被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	38	2	0	0	95.0%	5.0%
Multiplication	2	36	2	0	90.0%	10.0%
Sport	5	5	30	0	75.0%	25.0%
Rotation	0	0	0	40	100%	0%
				Av	90.0%	10.0%

表 10: 1ch 除去後の分類性能 (左側頭葉・被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	21	19	0	0	52.5%	47.5%
Multiplication	9	31	0	0	77.5%	22.5%
Sport	6	1	33	0	82.5%	17.5%
Rotation	0	0	0	40	100%	0%
				Av	78.12%	21.88%

表 11: 1ch 除去後の分類性能 (右側頭葉・被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	40	0	0	0	100%	0%
Multiplication	0	40	0	0	100%	0%
Sport	6	0	34	0	85.0%	15.0%
Rotation	0	0	0	40	100%	0%
				Av	96.25%	3.75%

表 12: 1ch 除去後の分類性能 (右後頭葉・被験者 1)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	39	1	0	0	97.5%	2.5%
Multiplication	2	38	0	0	95.0%	5.0%
Sport	2	0	38	0	95.0%	5.0%
Rotation	0	0	0	40	100%	0%
				Av	96.88%	3.12%

表 13: 1ch 除去後の分類性能 (左前頭葉・被験者 2)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	35	5	0	0	87.5%	12.5%
Multiplication	2	38	0	0	95.0%	5.0%
Sport	6	0	27	7	67.5%	32.5%
Rotation	0	0	3	37	92.5%	7.5%
				Av	85.62%	14.38%

表 14: 1ch 除去後の分類性能 (右頭頂葉・被験者 2)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	34	5	1	0	85.0%	15.0%
Multiplication	0	40	0	0	100%	0%
Sport	9	0	23	8	57.5%	42.5%
Rotation	0	0	7	33	82.5%	17.5%
				Av	81.25%	18.75%

表 15: 1ch 除去後の分類性能 (右後頭葉・被験者 2)

メンタルタスク	B	M	S	R	P_c	P_e
Baseline	33	7	0	0	82.5%	17.5%
Multiplication	7	33	0	0	82.5%	17.5%
Sport	8	0	24	8	60.0%	40.0%
Rotation	0	0	4	36	90.0%	10.0%
				Av	78.75%	21.25%

8 結合荷重による特徴解析

学習後の MLNN における結合荷重に基づいて、主要な 8 つの部位における、メンタルタスクの分類に対する貢献度を解析する。ここでは、測定した全てのデータセットを用い、MLNN を学習する。図 6 は隠れ層から出力層への結合荷重の分布を示したものである。横軸は隠れユニットの番号、縦軸は出力ユニットの番号、すなわち下から Baseline, Multiplication, ... のように各メンタルタスクに対応している。

図 6 より、一つのメンタルタスクに対して、いくつかの隠れユニットが独立して大きな値を示していることがわかる。例えば、Baseline (縦軸の最底部) において、16番と 30番の隠れユニットが大きな値を示している。他のメンタルタスクに対しても同様の傾向が確認できる。

図 7 に入力層から隠れ層への結合荷重の分布を示す。横軸は入力ユニットの番号、縦軸は隠れユニットの番号となる。横軸の入力ユニットは左から ch1, ch2, ... のように、各チャンネルは横軸に 10 ノードずつ合計 80 ノード配置されている。図 7 より、図 6 で示した、メンタルタスクごとに値の大きくなる隠れユニットへの影響の大きさを各チャンネルごとにまとめると表 16 のようになる。

表 16 より、チャンネルごとにメンタルタスクへの影響の大きさを 3 段階 ($H = High$, $M = Middle$, $L = Low$) で評価する。例えば、Baseline のタスクにおいて、ch5 の脳磁から抽出したデータ、つまり左側頭葉が重要な役割を果たしていることが確認できる。また、Sport のタスクでは、ch4、つまり右頭頂葉からの特徴量が重要である。他方、Rotation のタスクでは、ch1,2,6 に若干の貢献が確認されるに留まった。




図 6: 隠れ層から出力層への結合荷重 (被験者 1)




図 7: 入力層から隠れ層への結合荷重 (被験者 1)

表 16: メンタルタスクに対する主要 8 部位の貢献度

tasks	ch								
	H-units	1	2	3	4	5	6	7	8
Base	16,30		L			H	L		
Mul	2,4,24,27		M		L			M	
Sport	18,26		M	H					
Rot	15,25	L	L				L		

9 まとめ

本研究では、階層形ニューラルネットワークとFFTを用いたBCIを構築した。脳活動として、従来から用いられている脳波に代わり、MEGvisionを用いて脳磁波形を測定した。2人の被験者について、4つのメンタルタスクを選択し、脳の主要8領域の脳磁波形を用いて分類を行った。その結果、初期状態として用いたセンサー位置よりも最適化を行ったセンサー位置の方が正答率がおよそ7~10%程度向上した。加えて主要8chのメンタルタスク分類に対する貢献度を解析した。その結果、BaselineとSportのタスクで特定の部位が重要な役割を果たしていることが確認できた。

今後の課題として、チャンネル最適化の手法を検討する必要がある。本研究では分類性能を考慮して、チャンネルの最適化を行ったが、オンラインでの使用を考慮した場合、分類性能を算出しないで、ある程度良好な分類性能が得られるチャンネルを推定する必要がある。

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] Colorado State University: <http://www.cs.colostate.edu/eeg/>

[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] 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

[14] M. Shimogawara, H. Tanaka, K. Kazumi, Y. Haruta, "Megvision:Magnetoencephalograph system and its applications", Yokogawa Technical Report English Edition, No.38, p.23-27, 2004

generative model for single-trial EEG classification," Artificial Neural Networks, ICANN 2002, pp. 1156-1161, Springer, 2002.