

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

稻垣 清人[†] 中山 謙二^{††}

[†] 金沢大学大学院自然科学研究科電子情報工学専攻

^{††} 金沢大学大学院自然科学研究科電子情報科学専攻

〒 920-1192 金沢市角間町

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

あらまし 階層形ニューラルネットワークを用いて脳波解析に基づくメンタルタスクの推定を行った。5種類のメンタルタスクを対象とし、7チャネルの電極で測定した脳波を用いた。脳波をフーリエ変換して特徴を抽出した。値が小さいサンプルが多いので、非線形正規化を行った。1チャネル当たり2,500サンプルの脳波データを平均化により圧縮を行ったが、1チャネル当たり20サンプルの場合が良好な結果を得た。ニューラルネットワークの出力が小さい場合は「判定不能」とするが、そのための閾値によって、(正答率、誤答率)は(78%,0%)~(92%,8%)の範囲で変化する。閾値が低いほど、正答率が向上するが、同時に誤答率も高くなる。今回用いたメンタルタスクの種類に差はあまり大きくなかった。脳波は個人差も大きい。3人の被験者に対して個別にニューラルネットワークを学習した場合でも、42%~78%の開きがあった。さらに、2人の被験者の脳波データを単一のニューラルネットワークで学習した場合の正答率は、個別学習の78%, 72%から65%に低下しており、推定が難しくなっている。

キーワード ブレイン・コンピュータ・インターフェース、メンタルタスク、ニューラルネットワーク、学習、正規化、フーリエ変換

Classification of Mental Tasks by Using Neural Networks Based on Brain Waves

Kiyoto INAGAKI[†] and Kenji NAKAYAMA^{††}

[†] Division of Electrical and Computer Engineering, Kanazawa University

^{††} Division of Electrical Engineering and Computer Science

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

Abstract A multilayer neural network has been applied to estimation of mental tasks based on brain waves. Five kinds of the mental tasks are used. The brain waves were measured by using 7-channels. Features are extracted through Fourier transform. Since many samples have small value, the nonlinear normalization is employed. 2,500 samples are included in a channel. The number of the samples is compressed by taking average of the successive several samples. 20 samples per a channel can provide good estimation results. When the outputs of the neural network are small, the estimation results are not reliable and are rejected by using some threshold. (Correct and mis-judgement rate) vary from (78% and 0%) to (92% and 8%). As the threshold is increased, both correct and mis-judgement are decreased. The brain waves are different from person to person. The correct judgement rates for three persons are 42% ~ 78%. Furthermore, when a single neural network is applied to the brain wave data of two persons, the correct judgement rate decreases from 78% and 72% to 65%.

Key words Brain Computer Interface, Mental tasks, Neural networks, Learning, Normalization, Fourier transform

1. まえがき

人間とコンピュータのインターフェースとして、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[3]-[16]。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[11]。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[5]。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[4], [6], [7], [9]。

本稿では、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う問題を扱う。階層形ニューラルネットワークの学習過程や汎化能力におけるパラメータ設定の影響や、脳波の個人差の影響等について検討を行い、パラメータの最適化や階層形ニューラルネットワークによるBCIの性能評価を行う。個々の問題として、入力データ数の圧縮や入力データ値の正規化、判定不能を判断するためのニューラルネットワークの出力に対する閾値の影響、などを検討する。

2. BCIの流れ

BCIの流れは、以下のようになる。

- 脳波の測定
- 前処理
- 特徴抽出
- 特徴分類
- 機器の操作

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

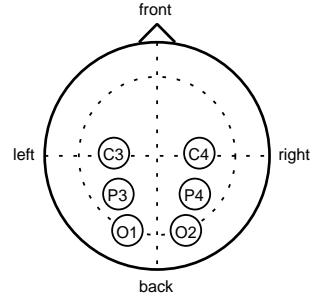


図1 電極の位置

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。

各メンタルタスクを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。

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。まず、1チャネル当たり10秒間の脳波データ（図2）をフーリエ変換し、その振幅を求めた（図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低減した（図4）。このサンプル数の影響についてはシミュレーションで確認する。

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5に示す。

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

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（脳波データのサンプル数）×チャネル数であり、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。ターゲットとしては、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

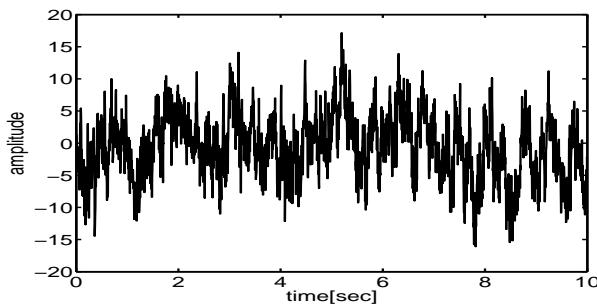


図 2 1 チャネル分の脳波データ

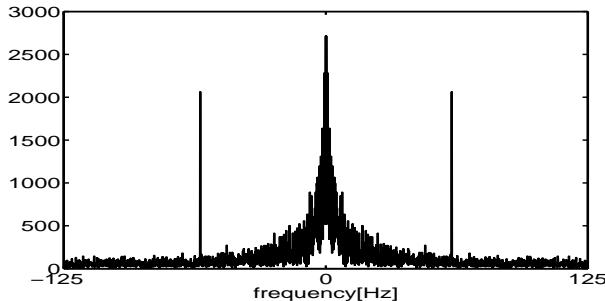


図 3 フーリエ変換の振幅

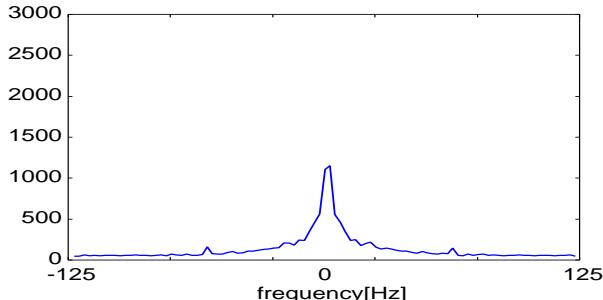


図 4 平均した後の振幅

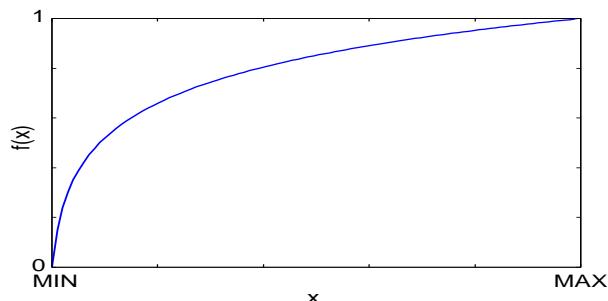


図 5 正規化のために用いた関数

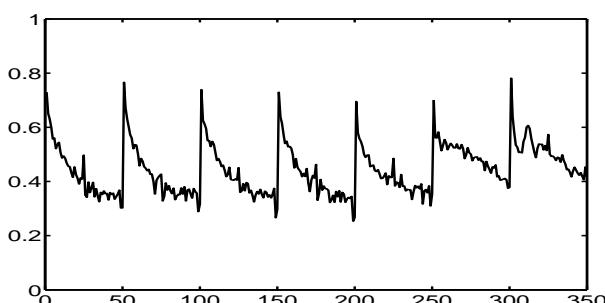


図 6 7 チャネル分の入力データ

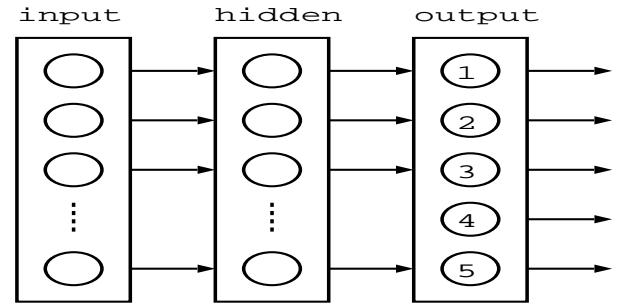


図 7 ニューラルネットワークの構造

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。結合重みの学習はバックプロパゲーション（BP）法で行なった。

5. メンタルタスクの分類におけるパラメータの影響

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[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。

$$\text{正答率} = \frac{\text{正答数}}{\text{全データ数}}$$

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

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、

$$\text{全推定数} = \text{正答数} + \text{誤答数} + \text{リジェクト数}$$

となる。

シミュレーション条件と評価内容

シミュレーション条件として、重みの初期値は、-0.2～+0.2の範囲でランダムに与え、リジェクトのための閾値0.8、学習回数5000回とした。

シミュレーションにより、次の項目が推定精度に与える影響について評価した。

- 入力サンプル数
- 推定不能判定のための閾値
- 被験者の個人差

5.1 入力サンプル数による違い

サンプル数20, 50, 100, 250に対して、隠れ層のユニット数、学習係数を変えながら、シミュレーションした結果を表1～

表 1 サンプル数 20 の場合の正答率と誤答率

ユニット数	20		10		5	
学習係数	正答率	誤答率	正答率	誤答率	正答率	誤答率
0.05	0.75	0.04	0.74	0.02	0.74	0.04
0.10	0.74	0.04	0.76	0.04	0.76	0.04
0.20	0.78	0.00	0.76	0.06	0.74	0.04

表 2 サンプル数 50 の場合の正答率と誤答率

ユニット数	50		25		15	
学習係数	正答率	誤答率	正答率	誤答率	正答率	誤答率
0.05	0.66	0.08	0.64	0.08	0.68	0.08
0.10	0.64	0.08	0.68	0.08	0.70	0.06
0.20	0.70	0.06	0.70	0.06	0.72	0.06

表 3 サンプル数 100 の場合の正答率と誤答率

ユニット数	100		50		25	
学習係数	正答率	誤答率	正答率	誤答率	正答率	誤答率
0.05	0.56	0.08	0.58	0.10	0.58	0.06
0.10	0.62	0.08	0.64	0.06	0.66	0.08

表 4 サンプル数 250 の場合の正答率と誤答率

ユニット数	250		125		75	
学習係数	正答率	誤答率	正答率	誤答率	正答率	誤答率
0.05			0.48	0.04	0.50	0.04
0.10	0.56	0.04	0.56	0.04	0.60	0.04

表 5 正答・誤答表：サンプル数 20, 隠れユニット数 20, 学習係数 0.2

Mental Task	B	M	L	R	C	reject	正答率	誤答率
Baseline	7	0	0	0	0	3	0.70	0.00
Multiplication	0	8	0	0	0	2	0.80	0.00
Letter-composing	0	0	7	0	0	3	0.70	0.00
Rotation	0	0	0	8	0	2	0.80	0.00
Counting	0	0	0	0	9	1	0.90	0.00

表 6 正答・誤答表：サンプル数 50, 隠れユニット数 15, 学習係数 0.2

Mental Task	B	M	L	R	C	reject	正答率	誤答率
Baseline	6	0	1	0	0	3	0.60	0.10
Multiplication	0	9	0	0	0	1	0.90	0.00
Letter-composing	1	0	5	0	1	3	0.50	0.20
Rotation	0	0	0	9	0	1	0.90	0.00
Counting	0	0	0	0	7	3	0.70	0.00

表 4 に示す。

隠れ層のユニット数, 学習係数に対して, 入力サンプル数, すなわち 1 チャネル当たりの入力サンプル数として 20 の場合が, もっともよい結果となっている。

また, 各入力サンプル数に対して, 最も結果のよかつた条件におけるテストデータに対する正答・誤答表を表 5~表 8 に, 正答率を図 8 に示す。

5.2 推定不能判定のための閾値による違い

リジェクトのための閾値を変えた場合の結果は, 表 9 のようになる。条件は, 入力サンプル数 20, 隠れ層のユニット数 20, 学習係数 0.2 とした。

閾値が低いほど, リジェクトされるデータが減少し, 正答率

表 7 正答・誤答表：サンプル数 100, 隠れユニット数 25, 学習係数 0.1

Mental Task	B	M	L	R	C	reject	正答率	誤答率
Baseline	5	0	1	0	0	4	0.50	0.10
Multiplication	0	9	0	0	0	1	0.90	0.00
Letter-composing	1	0	4	0	1	4	0.40	0.20
Rotation	0	0	0	8	0	2	0.80	0.00
Counting	1	0	0	0	7	2	0.70	0.10

表 8 正答・誤答表：サンプル数 250, 隠れユニット数 75, 学習係数 0.1

Mental Task	B	M	L	R	C	reject	正答率	誤答率
Baseline	5	0	0	0	0	5	0.50	0.00
Multiplication	0	9	0	0	0	1	0.90	0.00
Letter-composing	1	0	3	0	0	6	0.30	0.10
Rotation	0	0	0	8	0	2	0.80	0.00
Counting	1	0	0	0	5	4	0.50	0.10

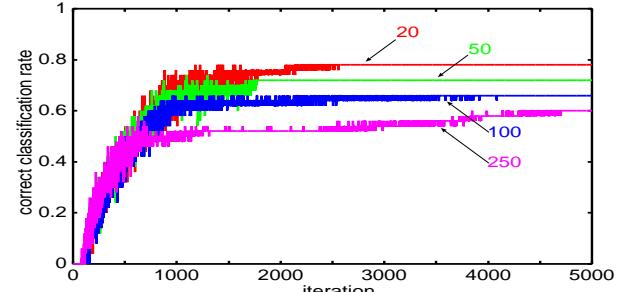


図 8 テストデータに対する正答率

表 9 閾値を変えた場合の正答率と誤答率

閾値	正答率	誤答率
0.8	0.78	0.00
0.6	0.88	0.04
0.4	0.90	0.08
0.2	0.92	0.08

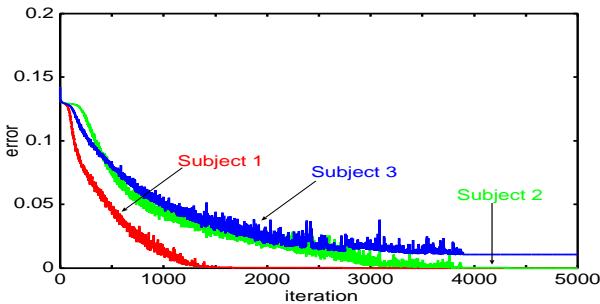


図 9 学習誤差

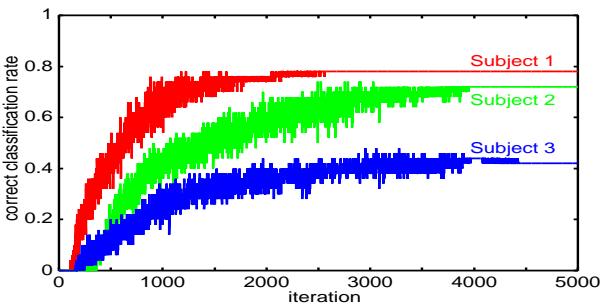


図 10 テストデータに対する正答率

表 10 各被験者に対する正答率と誤答率

被験者	正答率	誤答率
1	0.78	0.00
2	0.72	0.12
3	0.42	0.14

が向上するが、誤答率も高くなってしまう。最適な閾値を見つけることが課題となるが、誤答率を小さくするためには、なるべく閾値は大きい方がよい。

6. 被験者の個人差による推定精度の違い

6.1 ニューラルネットワークを各被験者に対して学習

これまで用いた被験者 (Subject1) の脳波に加えて、他に 2 人の被験者 (Subject2, 3) の脳波を用いて、シミュレーションを行った。条件は、入力サンプル数 20, 隠れ層のユニット数 20, 学習係数 0.2 とした。

これらの結果から、推定精度に対して、個人差が大きいことが分かる。ニューラルネットワークは各被験者に対して学習されているが、結果的に、推定精度に対して差が生じる。このため、BCI としての性能を評価するために、出来るだけ多くの被験者の脳波データを用いる必要がある。さらに、正答率の低い被験者に対して、脳波データの特徴解析や正答率を向上するための学習法の工夫も必要である。

6.2 単一ニューラルネットワークによる複数被験者の脳波分類

これまでには、一つのニューラルネットワークで一人の被験者の脳波を分類したが、ここでは、单一のニューラルネットワークで二人の被験者の脳波をまとめて分類する。条件は、入力サンプル数 20, 隠れ層のユニット数 20, 学習係数 0.2 とした。

個別学習においては、正答率は、被験者 1 が 78%, 2 が 72%,

表 11 各被験者の組み合わせに対する正答率と誤答率

被験者	正答率	誤答率
1 と 2	0.65	0.13
1 と 3	0.53	0.18

3 が 42% であったが、被験者を組み合わせた場合は、ともに低下している。例えば、被験者 1, 2 の組み合わせでは、78% と 72% から 65% に低下している。これらのことから、一つの BCI で多くの人の脳波を扱うことは難しく、個人用として学習する必要がある。

今回は、ある条件下で測定された脳波を用いたが、脳波は被験者が置かれた環境やそのときの体調に寄っても変化する。BCI をいろいろな環境で使用することを考えると、このような幅広い脳波データを対象とする必要があり、ニューラルネットワークの学習が難しくなることが予想される。

7. まとめ

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った。脳波をフーリエ変換して、その振幅値を用いたが、小さな値をとるサンプルが多いため、小さな値を伸張する非線形正規化が有効であった。また、10 秒間にわたって脳波を観測しており、1 チャネル当たりのサンプル数が 2,500 点であったが、これを連続する複数のサンプルを平均化することにより、入力サンプル数を低減した。シミュレーションにより、20 まで低減できることが示された。これは、メモリ容量や計算時間の大幅な短縮が可能であることを示唆している。ニューラルネットワークの出力が小さい場合は判定不能となるが、これに対する閾値も重要なファクターとなることが示された。脳波は被験者の個人差が大きいことが予想されたが、シミュレーション結果でもこのことが示された。正答率で 78%~42% の開きがあった。また、単一のニューラルネットワークを複数人の脳波データに適用した場合も、個々の正答率からの低下が見られ、BCI は個人用に学習する必要があることも分かった。

今回は、ある条件下で測定された脳波を用いたが、脳波は被験者が置かれた環境やそのときの体調に寄っても変化する。BCI をいろいろな環境で使用することを考えると、このような幅広い脳波データを対象とする必要があり、ニューラルネットワークの学習が難しくなることが予想される。

謝辞 日頃、ご討論頂く、本学、適応システム研究室の平野講師、並びに学生諸氏に感謝致します。

文 献

- [1] <http://www.cs.colostate.edu/eeg/>
- [2] 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.
- [3] 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.

- [4] 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.
- [5] G. Pfurtscheller and C. Neuper, "Motor imagery and direct brain-computer communication," Proc. IEEE, vol. 89, no. 7, pp. 1123-1134, July 2001.
- [6] B. Blankertz, G. Curio, and K. R. Muller, "Classifying single trial EEG: Towards brain computer interfacing," Advances in Neural Inf. Proc. Systems (NIPS 01), vol. 14, pp. 157-164, 2002.
- [7] J. Kohlmorgen and B. Blankertz, "A simple generative model for single-trial EEG classification," Artificial Neural Networks, ICANN 2002, pp. 1156-1161, Springer, 2002.
- [8] Janne Lehtonen, "EEG-based Brain Computer Interfaces," Helsinki University of Technology, Master's Theses, 2002.
- [9] 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.
- [10] P. Sajda, A. Gerson, K. R. Muller, B. Blankertz, and L. Parra, "A data analysis competition to evaluate machine learning algorithms for use in brain-computer interfaces," IEEE Trans. Neural Sys. Rehab. Eng., vol. 11, no. 2, pp. 184-185, 2003.
- [11] 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.
- [12] J. R. Millan, "On the need for on-line learning in brain-computer interfaces," Proc. IJCNN, pp. 2877-2882, 2004.
- [13] 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.
- [14] K. R. Muller, M. Krauledat, G. Dornhege, G. Curio, and B. Blankertz, "Machine learning techniques for brain-computer interfaces," Biomed. Tech., vol. 49, no. 1, pp. 11-22, 2004.
- [15] T. Hinterberger, S. Schmidt, N. Neumann, J. Mellinger, B. Blankertz, G. Curio, and N. Birbaumer, "Brain-computer communication with slow cortical potentials: Methodology and critical aspects," IEEE Trans. Biomed. Eng., vol. 51, no. 6, pp. 1011-1018, 2004.
- [16] M. Krauledat, G. Dornhege, B. Blankertz, F. Losch, G. Curio, and K. R. Muller, "Improving speed and accuracy of brain-computer interfaces using readiness potential features," in Proceedings of the 26th Annual International Conference IEEE EMBS on Biomedicine, San Francisco, 2004.