

pdi-Boosting 法を用いた計算行為 NIRS データの識別

鶴背 慎二*1

林 勲*2

Discrimination of NIRS Signal Data of Calculation Task Using pdi-Boosting Method

Shinji Tsuruse*1

Isao Hayashi*2

Abstract – Brain-computer interface(BCI) and brain-machine interface(BMI) have been come into the research limelight. The outer computer and machine are controlled by brain activity and the discriminated boundary, which are detected with near-infrared spectroscopy(NIRS) or electroencephalograph(EEG). In this paper, we propose a new boosting algorithm for BCI using probabilistic data interpolation. In our model, interpolated data are generated by probabilistic distribution and assorted around errors instead of weights in the conventional Adaboost. By the interpolated data, the discriminated boundary is identified to control the outer machine effectively. After verifying a robustness of our method to numerical data added noise, we apply our method to arithmetic test with NIRS, and discuss the usefulness of our method.

Keywords : Brain-Computer Interface, Boosting Algorithm, Probabilistic Data Interpolation

1. はじめに

近年、脳からの情報により機械・システムの制御を行う BCI(Brain-Computer Interface) や BMI(Brain-Machine Interface) の研究 [1], [2] が盛んに行われている。一般には、近赤外分光法 (NIRS) [3] や脳波計測 [4] の装置から脳活動信号を計測し、得られた信号のクラスター間の相違を判別モデルで同定して、機器を制御する。しかし、従来の判別モデルでは、データクラスターを構成するのに多量のデータが必要となる。また、計測時に環境が動的に変動する場合が多く、過去に検出された脳活動データを用いて判別モデルを同定しても、動的な環境変化に追従できない場合がある。一方、パターン識別の分野において、学習データに対する複数の判別器を構成し、それらを統合的に組み合わせることにより全体の判別精度を向上させるアンサンブル学習 [5], [6] に対する関心が高まっている。アンサンブル学習の一手法に Adaboost が提案されている [7]。Adaboost では、データに付与する重みを定義し、その重みにより選択的にデータを抽出して学習データを構成し、複数の判別器を同定する。同定された判別器を統合的に組み合わせることによって、全体の判別精度を高めることが可能となる。

本論文では、Boosting アルゴリズムを用いて、確率的データ補間による新たな BCI における判別法を提案し、その特性を明らかにする。ここでは、本手

法を pdi-Boosting(Probabilistic Data Interpolation-Boosting) と呼ぶ [8], [9]。Adaboost のようなデータ付与の重みによるデータの選別ではなく、脳活動データの特異性を考慮して定義された確率密度関数により補間データを誤判別データの近傍に補充しデータを構成する。Adaboost では学習データ量は増加されないが、pdi-Boosting では補間データを補填するので、データ数不足による判別器の信頼度低下を防ぐことができる。また、識別に多量のデータを必要としないことから、BCI 機器の使用環境が変動した場合も、容易にモデルの再構築を行える利点がある。ここでは、まず、本手法のアルゴリズムについて議論する。その後、本手法の特性を明らかにするために、観測データではなく、あらかじめ用意した数値データに外乱を加えて、そのロバスト性を議論する。さらに、本手法を脳活動計測による観測データに適用して、その実用性を検討する。

2. pdi-boosting の提案

アンサンブル学習とは、判別器を複数個用意し、各判別結果を統合することにより高い認識率を得る統合的な判別モデルを構築する学習法である。

アンサンブル学習の一つに Boosting 手法があり、Boosting 手法の代表として、Adaboost がある。Adaboost では、単純な識別器 $M_1, M_2, \dots, M_i, \dots$ を設定し、学習データ (TRD) に対して各モデルを同定して結果を算出する。ただし、次ステップでのモデル同定のための TRD を構成する際に、各データの重みを用いて、誤判別となったデータが全データ中で 50% 以上になるようにデータを選択し、新たな TRD を構成

*1: 関西大学

*2: 関西大学

*1: Kansai University

*2: Kansai University

する．段階毎の結果を用いて重みは順次更新され，判別モデルによる同定が繰り返される．最終的には，評価用データ (CHD) を判別器に入力し，出力を多数決で勘案して統合結果を得る．

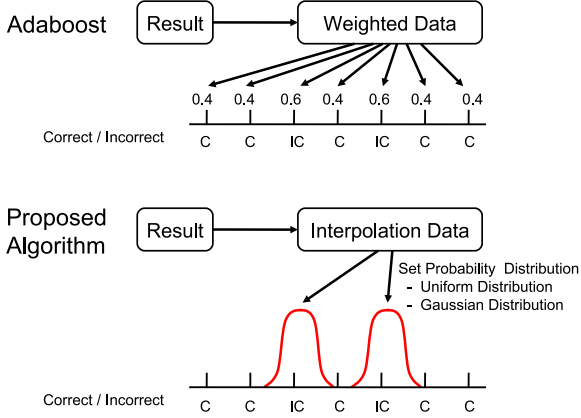


図 1 Selection of Error Data by Data Interpolation

pdi-Boosting では，確率密度関数に応じた補間データを誤判別のデータ近傍に発生させ，それらを TRD へ補充することで，誤判別の性質を持つデータを増加させる．図 1 に本手法のデータ選択法を説明する．いま， TRD による CHD の判別結果において，誤判別されたデータが第 s 番目とする．この第 s 番目のデータの第 j 番目の属性値を $x_j(s)$ で表す．補間データ $x_j^{new}(s)$ は，属性値 $x_j(s)$ を平均とする確率密度関数 $f(x_j)$ から，その確率に基づいて選択される．

$$x_j^{new}(s) = \{x_j \in A \mid P(A) = \int_A f(x_j) dx_j\} \quad (1)$$

確率密度関数 $f(x_j)$ として，正規分布や一様分布などを設定する．ここでは，下記の一様分布を用いる．

$$f(x_j) = \begin{cases} \frac{1}{x_j^{max} - x_j^{min}} & ; \text{ for } x_j^{min} \leq x_j \leq x_j^{max} \\ 0 & ; \text{ for } x_j < x_j^{min} \text{ or } x_j > x_j^{max} \end{cases} \quad (2)$$

ただし， x_j^{max} と x_j^{min} は，次の値とする．

$$x_j^{min} = \frac{3x_j(s) + x_j(s-1)}{4} \quad (3)$$

$$x_j^{max} = \frac{3x_j(s) + x_j(s+1)}{4} \quad (4)$$

ここで， $x_j(s-1)$ は第 $s-1$ 番目のデータ， $x_j(s+1)$ は第 $s+1$ 番目のデータである．

確率的データ補間法により，誤判別されたデータ付近に新たなデータが増加され，次ステップで同定される判別器は，より誤判別のデータに適合する判別器が得られる．pdi-Boosting の概念図を図 2 に示し，アルゴリズムを以下に示す．

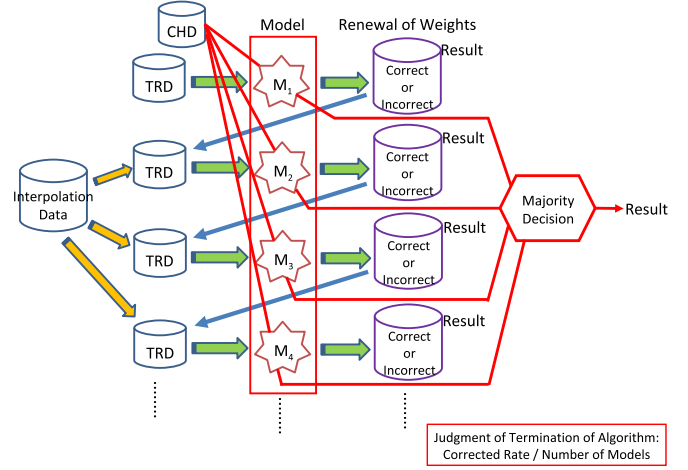


図 2 pdi-Boosting Algorithm

- Step 1 NIRS 計測装置の各計測点から W 個の脳信号データ D が得られたとし， D を学習に用いるための学習データ (D^{TRD} , W^{TRD} 個) と評価用に用いるための評価データ (D^{CHD} , W^{CHD} 個) に分割する．ここで， $W^{TRD} + W^{CHD} = W$ である．また， D から構成される補間データを D^{INT} とする．
- Step 2 D^{TRD} を第 i 番目の判別器 M_i に入力し，結果 R_i の認識率 r_i^{TRD} を得る．
- Step 3 D^{TRD} において，誤判別された第 s 番目のデータを抽出する．第 s 番目のデータの第 j 番目の属性値 $x_j(s)$ に対して，式 (2) ~ 式 (4) により，確率密度関数 $f(x_j)$ を設定し，補間データ $x_j^{new}(s)$ を発生させて， D^{INT} に保存する．
- Step 4 結果 R_i において，正判別したデータと誤判別したデータとが同数になるように， D^{INT} からデータを補充する．ただし，補充データ数 d は
$$d \geq \frac{W}{2} - W^{TRD}(1 - r_i^{TRD}) \quad (5)$$
とする．
- Step 5 D^{CHD} を M_1, M_2, \dots, M_i に適応して，結果の認識率 r_i^{CHD} を得る．
- Step 6 Step2 から 5 までを繰り返し，あらかじめ決められたしきい値 θ に対して， $r_i^{CHD} \geq \theta$ を満足した時点，あるいは，繰り返し回数 M に対して， $i \geq M$ を満足した時点でアルゴリズムを終了する．

3. pdi-boosting のロバスト性

通常、近赤外分光法 (NIRS) や脳波計測の装置より脳活動信号を計測する場合、得られた観測信号には、多くの外乱が含まれている。ここでは、本手法の対外乱特性を議論するため、特に、ヘモグロビン変化量に加わる外乱性について議論する。ヘモグロビン変化量に対する外乱特性以外にも、データ長、反応開始時間、反応区間、反応回数、属性選定に対する外乱なども考えられるが、ここでは、誤判別を誘発しやすいヘモグロビン変化量に対する外乱特性に焦点を絞って、本手法のロバスト性について議論する。

いま、酸化ヘモグロビン変化量 (oxy-Hb) と還元ヘモグロビン変化量 (doxy-Hb) が $[0,1]$ で与えられているとする。この時系列データに、正規乱数により発生した外乱を付与する。正規乱数の平均値 m と標準偏差 s を変化させ、以下の4つのパターンのノイズデータを作成した。

- パターン A $m = 0, s = 0.2$ の正規乱数で発生
- パターン B $m = 0, s = 0.4$ の正規乱数で発生
- パターン C $m = 0, s = 0.6$ の正規乱数で発生
- パターン D $m = 0, s = 0.8$ の正規乱数で発生

ただし、クラス数は2とし、定常状態を0で、賦活状態を1で表す。

ここでは、データ長を 50sec、反応開始時間を計測開始から 10sec 後、反応回数を 1 回、反応区間を 10sec として数値データを作成した。数値データの4つのパターンの例を図3から図6に示す。図3では、人が判断した場合でも、定常状態と賦活状態が判別できるが、図4から図6では、外乱が加わり、識別が困難である。




図3 Data Pattern A




図4 Data Pattern B




図5 Data Pattern C

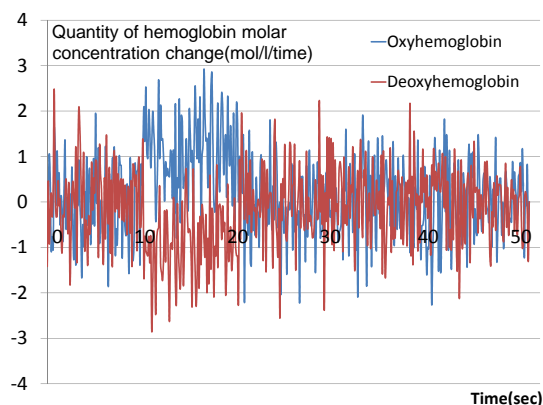


図6 Data Pattern D

本手法による識別結果を表1に示す。ただし、識別は各パターンとも各10回の外乱データを生成して、認識率を算出した。また、Boosting法の識別器は決定木法の一つである Reptree を用い、繰り返し回数を $M = 3$ とする回数による終了判定を採用した。本手法と他手法とを比較すると、標準偏差 s が 0.2 から 0.6 までのデータに対しては、特に、本手法と他手法の認識率に大きな差は認められないが、本手法の優位性が示されている。また、標準偏差が 0.8 であるパターン D に対しては、本手法の認識率が他手法よりも高く、

その優位性が明らかである．特に，Boosting を適用しない場合，つまり，REPTree との比較では，約 10% 程度の差が認められた．4 つのパターンの認識率を平均した結果では，本手法が他の手法よりも明らかに認識率が高く，本手法の優位が明らかである．これらの結果から，本手法は，他の Boosting 法や REPTree と比較して，外乱データに対する高いロバスト性を示すことがわかる．

表 1 Correct Rate for Data Pattern Added Noise

| Data | pdi-B. (%) | Adaboost (%) | Multiboost (%) | REPTree (%) |
|-----------|---------------|-----------------|-------------------|----------------|
| Pattern A | 99.82 | 99.80 | 99.76 | 99.37 |
| Pattern B | 97.33 | 96.57 | 94.84 | 97.14 |
| Pattern C | 92.65 | 91.22 | 91.22 | 92.41 |
| Pattern D | 88.78 | 88.63 | 88.55 | 79.54 |
| Ave. | 94.65 | 94.06 | 93.59 | 92.11 |

4. 脳活動計測への応用

pdi-Boosting の有用性を検討するため，被験者に簡易計算のタスクを課し，NIRS 計測装置を用いて脳信号を計測した．本研究では，提案手法の有用性を検討することが目的であるので，比較的少数の電極の方が手法の有用性を検討する際に確実であり，ここでは，2ch の簡易型 NIRS 計測装置 (エクセルオブメカトロニクス社，YN-502) を用いた．本装置は，周期 0.098s で，波長 770nm と 840nm の 2ch の電極を持ち，それぞれの電極で酸化ヘモグロビン (oxy-Hb) と還元ヘモグロビン (doxy-Hb) を計測するので，全体で 4 入力の信号データを構成する．

NIRS 計測の対象タスクとして，小学一年生程度の桁上がりのない加算を被験者に課した．図 7 に実験風景を示す．被験者には，計測前に年齢，性別，利き腕，健康状態，特殊な計算技能の訓練の有無等を確認して，特殊な計算技能を習得していない被験者のみを選択した．計測実験のタスクは，前レストを 10s，算術計算の実行を 10s，後レスト区間の 30s を 1 試行として構成し，5 試行を 1 セットとする合計 250s で構成する．図 8 に算術計算実験のタイミングプロトコルを示す．

被験者は男 2 名 (RM,SY)，女 2 名の計 4 名 (KS,RY) とし，各被験者に対して数日間をかけて 12 セットを実施した．ただし，被験者 SY のみ 20 試行の計測とした．なお，国際 10-20 法に基づき，NIRS 計測点は，測定位置 F_{p1} と F_{p2} (大脳前頭前野域) の 2 箇所を設置した．採取したデータから，乱数により 1 人 10 試行ずつのデータを抽出し，脳信号のデータ集合 D を構成した．



図 7 Experiment




図 8 Timing Protocol of Experiment

5. 結果と考察

NIRS により検出された被験者 RY の脳血流量変化量の時系列の一例を図 9 から図 12 に示す．例えば，図 9 は，被験者 RM の左電極の oxy-Hb と doxy-Hb を示している．脳血流量変化量は，タスク実行開始とともに，酸化ヘモグロビンの変化量の増加が始まり，還元ヘモグロビン変化量の減少が起こり，タスク実行終了の合図とともに緩やかに平常状態に戻っていくのがわかる．

ここでは，このような特徴を持つ脳信号データを用いて，被験者がタスク実行中であるか，あるいは，レスト中であるかを判別器により同定する．定式化した pdi-Boosting のアルゴリズムの手順にしたがって，NIRS による脳信号データの同定の手順を説明しよう．ただし，判別器として REPTree を使い，終了判定は $M = 3$ とする回数による終了判定を採用した．NIRS 計測装置の周期が 0.098s であり，1 試行が 50s であるので，全データ集合 D として， $W = 490$ 個の脳信号データが採取される．ただし，本実験では， $D = D^{TRD} = D^{CHD}$ とする．したがって， $W = W^{TRD} = W^{CHD} = 490$ となる．




図 9 Waveforms of Left Chanel Detected by NIRS: Subject RM




図 10 Waveforms of Left Chanel Detected by NIRS: Subject KS




図 11 Waveforms of Left Chanel Detected by NIRS: Subject RY

まず、 D_1^{TRD} を第 1 番目の判別器 M_1 に入力し、結果 R_1 の認識率 $r_1^{TRD} = r_1^{CHD} = 91.22\%$ を得る。次に、補間データを作成する。 R_1 における誤判別データ数は 43 個となり、式 (2) ~ 式 (4) によって、各誤判別データの周辺に補間データ $x_j^{new}(s)$ を発生させ、 D^{INT} に保存する。 R_1 における誤判別データに補間データを加えた個数が正判別データの個数と等しくなるまで、

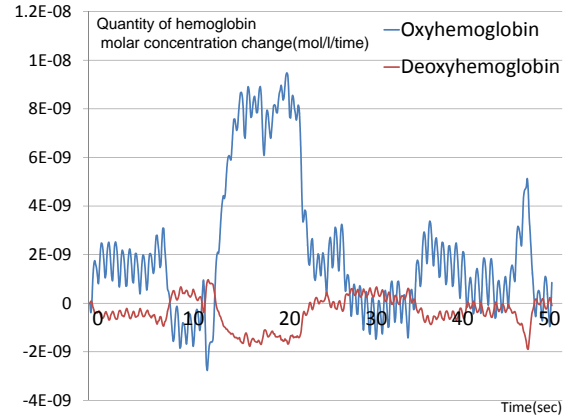


図 12 Waveforms of Left Chanel Detected by NIRS: Subject SY

D^{INT} から補間データを加える。この新たなデータ集合 D_2^{TRD} は、 R_1 における補間データ数 d_1 が 404 個であるので、 $W_2^{TRD} = 894$ 個となる。

D_2^{TRD} を第 2 番目の判別器 M_2 に入力し、結果 R_2 の認識率 $r_2^{CHD} = 92.24\%$ を得る。この結果、新たに補充するデータ数は $d_2 = 414$ となり、 M_3 における D_3^{TRD} を $W_3^{TRD} = 904$ として構成する。 M_3 による認識率は $r_3^{TRD} = 93.67\%$ となるが、終了判定の $M = 3$ により、アルゴリズムを終了する。

以上の経過から、それぞれの結果 R_1, R_2, R_3 が得られ、多数決原理により結果を統合して、最終の認識率 95.31% を得る。この各ステップでの補間データの数量と認識率を表 2 に示す。

表 2 Correct Rate and Number of Interpolation Data

| Model | Corrected Rate(%) | Inter. Data (for next step) | TRD | CHD |
|--------------|-------------------|-----------------------------|-----|-----|
| M_1 | 91.22 | 404 | 490 | 490 |
| M_2 | 92.24 | 414 | 894 | 490 |
| M_3 | 93.67 | 428 | 904 | 490 |
| pdi-B. (TRD) | 95.31 | | | |

各ステップごとの平均認識率を表 3 に示す。被験者 KS において、 r_1^{CHD} の識別率は 93.69% であり、 $r_2^{CHD} = 93.47\%$ 、 $r_3^{CHD} = 93.33\%$ であるので、第 1 の判別モデルの認識率より下回っているが、統合の認識率は、どの判別モデルの認識率よりも 1.0% 以上で高い認識率を示している。この傾向は、被験者 RY において、最も顕著に表れているが、これは判別モデルが各ステップごとに特異なデータに適合し、統合結果として認識率が高まる Boosting の特徴を示している。すなわち、NIRS データに対する本手法の有用性を示している。

表 3 Correct Rate for Subjects

| Sub. | $r_1^{CHD}(\%)$ | $r_2^{CHD}(\%)$ | $r_3^{CHD}(\%)$ | T.R.(%) |
|------|-----------------|-----------------|-----------------|---------|
| RM | 90.33 | 90.29 | 90.51 | 91.04 |
| KS | 93.69 | 93.47 | 93.33 | 94.78 |
| RY | 92.92 | 88.37 | 88.10 | 94.16 |
| SY | 94.57 | 91.65 | 94.24 | 95.42 |
| Ave. | 92.87 | 91.52 | 89.21 | 93.85 |

最後に、pdi-Boosting と REPtree との比較、および、他の Boosting 手法との比較を行った。比較の結果を表 4 に示す。pdi-Boosting と REPtree との比較では、0.97% の認識率の向上がみられ、有意差 0.05% 水準での t 検定において、有意 ($p = 0.01638$) な差が認められた。

判別器を REPtree とし、終了判定を $M = 3$ とする同条件下において、他の Boosting 手法との比較を行った。被験者 RM に対しては、Adaboost と比較して 0.71% の認識率の向上が見られ、Multiboost と比較しても 0.66% の向上が見られた。また、被験者 KS に対しては、同様に、Adaboost と比較して 0.54% の向上が見られ、Multiboost と比較しても 1.21% の向上が見られた。しかし、被験者 RY に対しては、Multiboost と比較して 1.2% の向上が見られたものの、Adaboost と比較して 0.23% の低下が見られた。被験者 SY でも、Multiboost と比較して 1.85% の向上が見られたが、Adaboost と比較して 0.53% の低下が見られた。

4 名の被験者に対する平均では、Multiboost に対して、有意差 0.05% 水準での t 検定において有意 ($p = 0.064551$) な差が認められた。一方、Adaboost に対しては、0.12% の向上が見られたが、有意差 0.05% 水準での t 検定において有意 ($p = 0.856851$) な差は認められなかった。

以上の結果から、pdi-Boosting は、他の Boosting 手法と比較して同等以上の認識率を確保することができるという。

表 4 Comparison between Proposed Model and Others

| Sub. | pdi-B. (%) | Adaboost (%) | Multiboost (%) | REPtree (%) |
|------|---------------|-----------------|-------------------|----------------|
| RM | 91.04 | 90.33 | 90.38 | 90.33 |
| KS | 94.78 | 94.24 | 93.57 | 93.69 |
| RY | 94.16 | 94.39 | 92.96 | 92.92 |
| SY | 95.42 | 95.95 | 93.57 | 94.57 |
| Ave. | 93.85 | 93.73 | 92.62 | 92.88 |

6. おわりに

本論文では、Boosting アルゴリズムを用いて、確率的データ補間による新たな BCI における判別法を提案し、外乱データに対するロバスト性と NIRS 計測装置を用いた脳活動計測の実験に適用して、その有用性を検討した。今後、選択確率分布の設定方法や他のロバスト性について、さらに議論する必要がある。

なお、本研究の一部は「文部科学省私立大学戦略的研究基盤形成支援事業（平成 20 年度～平成 24 年度）」によって行われた。

参考文献

- [1] M.A.Lebedev, J.M.Carmera, J.E.O'Doherty, M.Zacksenhouse, C.S.Henriquez, J.C.Principe, and M.A.L.Nicolelis, "Cortical ensemble adaptation to represent velocity of an artificial actuator controlled by a brain-machine interface," *Journal of Neuroscience*, Vol.25, No.19, pp.4681-4693 (2005).
- [2] T.O.Zander, C.kothe, S.Welke, and M.Roetting: Enhancing Human-Machine Systems with Secondary Input from Passive Brain-Computer Interfaces, *Proceeding of 4th Internatinal BCI Workshop*, pp.44-49 (2008).
- [3] 新出, 坪根, 和田: 近赤外線分光法を用いた動作肢の判別, 信学技報, No.NC2007-44, pp.9-96 (2008)
- [4] 井上: 脳波からヒトの状態を探る, 日本知能情報フレンジ学会第 5 回脳と知覚研究部会ワークショップ特別講演 (2008)
- [5] 金森, 畑埜, 渡辺: ブースティング, 森北出版 (2006)
- [6] 中島, 荘司: ファジアンサンプル識別器構築におけるデータ分割の効果, 第 25 回ファジィシステムシンポジウム講演論文集, No.3E2-01 (2009)
- [7] 村田, 金森, 竹ノ内: ブースティングと学習アルゴリズム: 三人寄れば文殊の知恵は本当か? 電子情報通信学会誌, Vol.88, No.9, PP.724-729 (2005)
- [8] 林, 鶴背: 確率的データ補間を用いた BCI のための Boosting アルゴリズムの提案, 信学技報, Vol.109, No.461, pp.303-308 (2010)
- [9] 林, 鶴背: 脳コンピュータインタフェースのための pdi-Boosting の提案, 第 26 回ファジィシステムシンポジウム講演論文集, pp.288-291 (2010)