

BCIにおける逐次学習型判別器のための順列データ構成法の提案

A Proposal of Permutation Data Structure Method for Sequential Learning Type Classifier in Brain Computer Interface

林 勲
Isao Hayashi
関西大学大学院
Kansai University

宮内 初美
Hatsumi Miyauchi
関西大学
Kansai University

Abstract Brain computer interface (BCI) for controlling outer machine by brain signal has been getting an attractive topic recently. It is necessary to classify observation data to conduct a control command when outer machine is controlled by brain signal, and we use clustering method to identify it generally. However, the accuracy of identification class is not high if the amount of observation data is small. In addition, the outer machine will not follow to a change of environment dynamics when the identification class was discriminated by past data. In this paper, we propose a permutation data method which is called PDSM (Permutation Data Structure Method). PDSM determines the permutation of electroencephalographic signal data for improving accuracy of identification class when the observation data is learned consecutively. In PDSM, we select sampling data from observed data for testing learning, and change data permutation to improve accuracy of identification class. We propose 15 kinds of PDSMs by the viewpoint of strategic methods which distinguish data pattern and data structure which the changes data order and the class order. We discuss usefulness of PDSM by applying numerical sample data to PDSM and estimating accuracy of identification class.

1. はじめに

近年、脳からの信号により外部機器を制御する BCI (Brain computer interface) の研究が盛んに行われている [1, 2]. 学習モデルによって、制御以前に外部機器の制御種別ごとに脳波信号を分別しておき、実観測時に学習モデルによるオンライン学習で脳信号の制御出力のクラスを識別する。このため、学習モデルには一般的に逐次学習型判別手法が用いられる。しかし、脳波信号の観測データが逐次学習型判別器に逐次的に投入されるので、少量データしか得られない学習開始時では、判別器の識別精度は悪い。逆に、一定の識別精度を確保するためには計測時間が必要で、その間、外部機器が環境の動的変化に追従できない場合がある。

逐次学習型判別器の一つに TAM (Topographic Attentive Mapping) ネットワーク [3, 4] がある。TAM ネットワークは、入力層、基盤層、カテゴリー層、出力層の 4 層構造からなる。入力層は脳内視覚入力を受容野を想定し、入力のぼかしを取り扱うため入力データを分布データとして取り扱う。基盤層は脳内高次視覚野への中継機能と興奮性・抑制性による学習機能を構造化している。カテゴリー層では、ノードの追加機能により受容野のデータパターンを構造化する。出力層は脳内高次視覚野を想定しており、パターン識別の推定を可能とする。入力層に観測データが投入され、出力層に教師信号が与えられて、教師値と出力値に差がある場合には、興奮性学習、フィードバック信号とビジランスパラメータによる抑制性学習、およびカテゴリー層ノードの追加機能によ

り、TAM ネットワークの出力パターンは教師パターンに近似する。

本論文では、逐次学習型判別器の精度を向上させるため、観測データに対する新たなデータ構成法を提案する。判別器の精度を向上させるため、判別器の学習機能に注目するのではなく、判別器に投入する脳波の観測データの配列に注目し、観測データの順列を変更して判別器の精度を向上させる。例えば、発生時刻の通りに観測データを逐次的に判別器に投入する場合と比較し、事前に観測データの座標位置や分散、観測データの大きさなどを考慮して観測データの投入順序を変更すれば、識別精度が良くなることが期待できる。この観測データの順序を変更するデータ構成法を順列データ構成法 (PDSM: Permutation Data Structure Method) と呼ぶ。

PDSM では、判別器による時間差のオンライン学習を想定している。学習開始時に観測データをオンライン学習せずサンプルデータとして蓄積して、一定の規範にしたがいサンプルデータの順列を変更する。その後、実観測の観測データをサンプルデータの順列を参考にして並び替えオンライン学習を行う。観測データの順序は、データのクラス内順列とクラス外順列から決定する。クラス内順列では、同一のクラス内においてのみデータの順列を変更する。クラス外順列では、全クラス内でクラス間の比較を行い、どのクラスを優先的に判別器に投入するかを決める。クラス内順列におけるデータ順列のみを変更する場合と比較して、クラス外順列によるデータ順列も変更することにより、その識別率は良くなること

が期待できる．したがって、ここではデータの並び替えとクラスの並び替えの2種類の方法でデータ順列を決定する．具体的には、クラス内順列では、乱数、クラス中心からの距離、原点からの距離、クラス対の距離の4種類の順列選出基準によりデータの並び替えを行う．また、クラス外順列では、乱数、占有率、クラス中心の距離、原点からの距離、クラス対の距離の5種類の順列選出基準によりクラスの並び替えを行う．したがって、PDSMでは、順列選出基準とデータ順列、クラス順列との組み合わせにより、合計15種類のデータ構成法を提案する．ここでは、まず、判別器としてのTAMネットワークを概説し、次に、PDSMを提案して、最後に、脳波データを模擬した数値例により、PDSMの有用性を検討する．

2. 逐次学習型判別器

逐次学習型判別器としてのTAMネットワークの構造を図1に示す．下位層から上位層に向かって、入力層、基盤層、カテゴリー層、出力層の4層からなる．

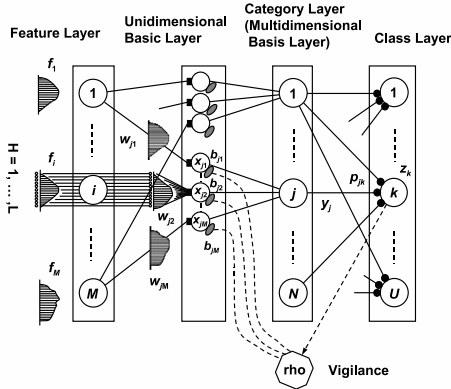


Fig. 1: TAM Network

いま、与えられたデータ集合 D が M 個の入力属性と 1 個の出力属性からなる R 個のデータとする．第 i 番目の入力属性における第 s 番目のデータを f_{si} , $s = 1, 2, \dots, R$ で表し、その出力値を k とする． f_{si} をランク法を用いて各属性ごとに正規化し、 I_{si} とする．入力層では、この I_{si} を用いて受容野での信号入力を分布データ f_{sih} として受信する．

$$f_{sih} = \frac{\exp[-0.5(LI_{si} - h + 0.5)^2]}{\sum_{h'=1}^L \exp[-0.5(LI_{si} - h' + 0.5)^2]} \quad (1)$$

ただし、 h は分布の離散量 $h = 1, 2, \dots, L$ を表す．なお、入力層への入力信号はデータ集合 D から 1 個ずつ逐次的に入力されるので、以後、簡素化のため、入力 f_{sih} を f_{ih} として表記する．

基盤層では、シナプス荷重 w_{jih} により j 番目のノードでの活性値 x_{ji} を計算し、第 1 視覚野の出力層から選択的注意のフィードバック信号を受ける．また、カテゴリー層では、基盤層の信号を統合し、出力層への出力 y_j

を計算する．

$$x_{ji} = \frac{\sum_{h=1}^L f_{ih} w_{jih}}{1 + \rho^2 b_{ji}} \quad (2)$$

$$y_j = \prod_{i=1}^M x_{ji} \quad (3)$$

ただし、 b_{ji} は抑制のためのシナプス荷重であり、 ρ はフィードバック信号を表すビジランスパラメータである．

出力層の k 番目の出力ノードでは、 j 番目のカテゴリーノードとのシナプス荷重 p_{jk} を介して出力値 z_k を計算する．最大値を有するノード番号 K が TAM ネットワークの出力値として出力される．

$$z_k = \sum_{j=1}^N y_j p_{jk} \quad (4)$$

$$K = \{k | \max_k z_k\} \quad (5)$$

いま、 K^* を正しい教師値としよう．TAM ネットワークの出力値 K が K^* と一致しない場合には、ビジランスパラメータ ρ を初期値 $\rho = 0$ から $\rho^{(step)}$ 分だけ上昇させ、 b_{ji} とともにカテゴリー層のノードの活性値 x_{ji} を抑制し、相対的に他のノードの活性値を上昇させる．

ρ は $z_{K^*}/z_K \geq OC$ の条件が満足されるか最大値 $\rho^{(max)}$ になるまで上昇を続ける．ただし、 OC は評価のしきい値であり、 $0 \leq OC \leq 1$ である．ビジランスパラメータ ρ が最大値 $\rho^{(max)}$ を越えた場合には、現在のカテゴリー層のノード構成では K^* を十分に表現できないと考え、カテゴリー層のノードを新たに 1 個分増加させる．

If $z_{K^*}/z_K < OC$ then repeat

$$(a) \rho = \rho + \rho^{(step)}$$

$$(b) \text{equation (3) - (6)}$$

until either $z_{K^*}/z_K \geq OC$ or $\rho \geq \rho^{(max)}$

一方、 $z_{K^*}/z_K \geq OC$ を満足する場合には、現在のネットワーク構造で K^* を正しく表現していると考え、出力値 K をより K^* に近似させるため、学習モードに入る．

学習モードでは、まず出力層からカテゴリー層へのフィードバック信号 y_j^* を計算する．

$$z_k^* = \begin{cases} 1 & ; \text{ if } k = K^* \\ 0 & ; \text{ otherwise} \end{cases} \quad (6)$$

$$y_j^* = \frac{\prod_{i=1}^M x_{ji} \times \sum_{k=1}^U z_k^* p_{jk}}{\sum_{j'=1}^N \prod_{i=1}^M x_{j'i} \times \sum_{k=1}^U z_k^* p_{j'k}} \quad (7)$$

シナプス荷重 b_{ji} , p_{jk} , w_{jih} は次式により更新される．

$$\Delta b_{ji} = b_j^{(rate)} y_j^* (x_{ji} - b_{ji}) \quad (8)$$

$$\Delta p_{jk} = p_j^{(rate)} y_j^* (z_k^* - p_{jk})$$

$$\Delta w_{jih} = w_j^{(rate)} y_j^* (f_{ih} - w_{jih})$$

$$p_j^{(rate)} = \frac{\alpha}{\alpha + n_j} \quad (9)$$

$$w_j^{(rate)} = \frac{\alpha}{\alpha\beta(M) + n_j} \quad (10)$$

ただし,

$$\beta(M) = \frac{\lambda^{1/M}}{1 - \lambda^{1/M}}, \quad \lambda \in (0, 1) \quad (11)$$

$$\Delta n_j = \alpha y_j^* (1 - n_j) \quad (12)$$

であり, α と λ は係数である. なお, $b_j^{(rate)}$, $p_j^{(rate)}$, $w_j^{(rate)}$ は学習係数であり, $b_j^{(rate)}$ は定数, $p_j^{(rate)}$ はシミュレティッドアニーリング法の補正值, $w_j^{(rate)}$ はさらに入力次元 M による補正項 $\beta(M)$ を加えた係数である.

なお, 学習は TAM ネットワークに入力データ f_{ih} を逐次的に投入することに行い, 全学習データはデータ集合 D を 1 エポックとして数エポック回数分とする.

3. 順列データ構成法

順列データ構成法 (PDSM) による判別器の処理過程を図 2 に示す. まず, 脳波の観測データが得られたとする. 乱数を用いたサンプリングにより観測データからサンプルデータを構成する. 次に, PDSM の各手法により, このサンプルデータのクラスの順序とデータ順序を変更する. 最後に, サンプルデータの変更順序に基づいてその後に観測されるデータの順列を変更し, 判別器に投入してオンライン学習を行う. したがって, PDSM は時間差をもつオンライン学習法といえる.

提案する PDSM を表 1 に示す. PDSM は順列選出基準, クラス順序, データ順序の 3 つの組み合わせにより構成される. 順列選出基準として 5 種類を定義し, クラス順序とデータ順序の組み合わせから, 合計 15 種類を提案する. 例えば, 順列選出基準としてクラスの中心点を計算し (クラス中心), クラス順列としてクラス中心間の距離比較から距離が最も短いクラス順序で判別器に投入するが (短クラス), データ順列としてそのクラス内のデータ順序をクラス中心から拡散方向に並び替えて投入する (拡散) 方法を CA-短クラス・拡散法と呼ぶ. このような組み合わせにより, 合計 15 種類の手法を提案した. 2 属性 2 クラス問題での PDSM の一例を図 3 に示し, 各 PDSM の概要を以下に示す.

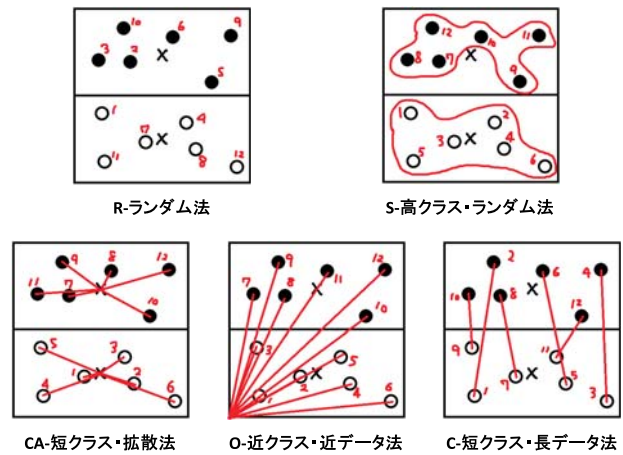


Fig. 3: Examples of PDSM

(1) R-ランダム法

観測データのクラス順序もデータ順序も偏りがないように一様乱数を用いて並び替える.

(2) S-高 (低) クラス・ランダム法

観測データからサンプリング抽出したサンプルデータに対し, 推定クラスの中で最も占有度が高いクラスのデータを判別器に投入する (高クラス). あるいは, 最も占有度が低いクラスのデータを判別器に投入する (低クラス). なお, 同一クラス内のデータは一様乱数を用いて並び替える.

(3) CA-短 (長) クラス・拡散 (集約) 法

サンプルデータに対し, クラスごとに属性の平均値のクラス中心点を計算し, クラスの中心点から他のクラスの中心点までの距離が最も短いクラス (短クラス), あるいは, 最も長いクラス (長クラス) に所属するデータをクラス中心から拡散方向に並び替えて判別器に投入する (拡散), あるいは, その逆方向 (集約) に並び替えて判別器に投入する.

(4) O-近 (遠) クラス・近 (遠) データ法

原点からの距離が最も近いクラス (近クラス), あるいは, 最も遠いクラス (遠クラス) に対し, 所属するデータを原点から近い順 (近データ), あるいは, 原点から遠い順 (遠データ) に並び替えて判別器に投入する.

(5) C-短 (長) クラス・短 (長) データ法

クラス間のデータを組み合わせるクラス対を構成し, 全クラス対の中でクラス間距離が短いクラス対 (短クラス), あるいは, 長いクラス対 (長クラス) に対し, 所属するデータを他クラスのデータとのクラス対の距離が短い (短データ), あるいは, 長い (長データ) 順に並び替えて判別器に投入する.

PDSM による判別器の処理手順は次のようになる.

Step 1 脳信号の観測データからサンプリングによりサンプルデータを抽出する.

Step 2 PDSM により, サンプルデータのクラス順序とデータ順序を変更する.

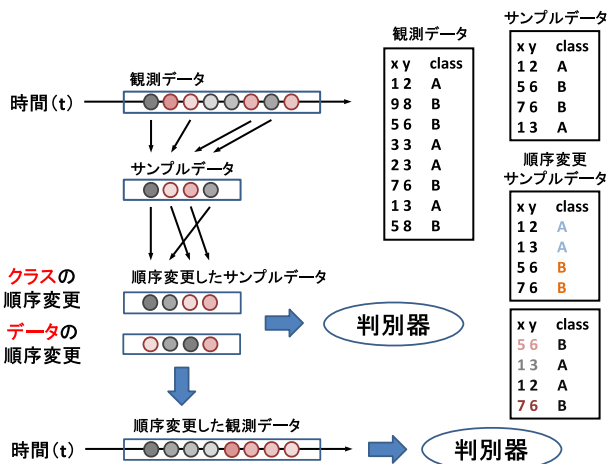


Fig. 2: PDSM

Table 1: Proposed PDSM

順列選出基準	クラス順序 (クラス外順列)		データ順序 (クラス内順列)	
	ランダム	—	ランダム	—
無作為 (R)	ランダム	—	ランダム	—
占有度 (S)	高クラス	低クラス	ランダム	—
クラス中心 (CA)	短クラス	長クラス	拡散	集約
原点 (O)	近クラス	遠クラス	近データ	遠データ
クラス対 (C)	短クラス	長クラス	短データ	長データ

Step 3 サンプルデータを識別器に投入し、最も識別率の高いデータ順列を決定する。

Step 4 サンプルデータの最も識別率の高いデータ順列にしたがい、その後に観測される観測データのデータ順列を変更し、判別器に投入する最終のデータ順列を決定する。

4. 各手法の結果と考察

脳波データを模擬して発生させた数値データを用いて、識別率およびデータ数とクラス分割の困難性の傾向から、PDSMの有用性を検討した。なお、ここで取り扱っているのは数値データであるので、ここでは、観測データとサンプルデータを同一のデータ集合として検証している。いま、脳信号計測装置のサンプリングタイムを $1kHz$ から $2kHz$ として、観測時間を $1000ms$ とし、得られる最大の観測データ数を 1000 個から 2000 個と仮定する。したがって、数値データのデータ数として、少量の観測データも想定して、その個数を 50, 100, 200, 400, 1000, 2000 個の 6 種類とした。クラス個数は 2 個とした。また、クラス間で 0.0, 12.0, 24.0, 36.0, 48.0, 60.0% のデータの重複を許した。この領域重複率 (%) はその値が高いほど、クラス内で他のクラスのデータが混在するので、クラスの識別が困難となる。数値データの一例を図 4 に示す。データ個数が 50 個の場合には、データ数が極度に少ないので、重複率の高低に関係なく識別が困難といえる。また、2000 個のデータ個数では、重複率が高い場合に特に識別が困難であることがわかる。

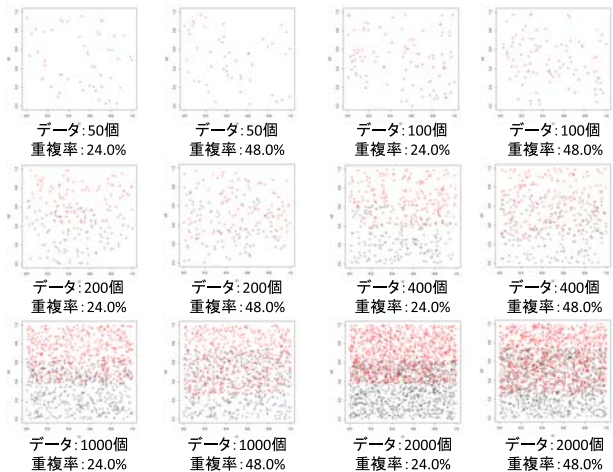


Fig. 4: Numerical Data

識別率の良いPDSMの結果を表 2 に示し、そのデータ数と領域重複率の組み合わせによる識別率の詳細を表 3 から表 7 に示す。ここでは、6 種類のデータ個数と 6 種類の領域重複率の組み合わせの合計 36 種類の条件で、TAM ネットワークを 5 回試行して、その平均識別率を求めた。したがって、表 2 では、各データ個数や各領域重複率での識別率は 30 回の平均値であり、最終行の全ての平均識別率は 180 回の平均値である。

表 2 において、データ数が少ない場合、R-ランダム法以外のPDSM法はR-ランダム法よりも高い識別率を示している。また、領域重複率の変化では、R-ランダム法を含めた全ての手法は、重複率が 36% や 48%, 60% の高い場合、識別率は 0.8 以下となっているが、12% や 24% などの低い重複率では、0.75 以上の高い識別率を示している。特に、重複率が高い場合、R-ランダム法以外のPDSM法はR-ランダム法と比較して識別率が同等かそれ以上を示している。C-長クラス・長データ法は、全てのデータ数と領域重複率に対してPDSM法の中で最も高い識別率を示し、平均値でも 0.79 と高い。

C-長クラス・長データ法は、異なるクラス間でデー

Table 2: Classification Rate of PDSM

		R-ランダム法	S-高クラス・ランダム法	CA-短クラス・集約法	O-近クラス・近データ法	C-長クラス・長データ法	平均値
データ数 (個)	50	0.75	0.79	0.78	0.78	0.79	0.78
	100	0.75	0.78	0.77	0.77	0.78	0.77
	200	0.78	0.79	0.79	0.79	0.79	0.79
	400	0.78	0.79	0.79	0.79	0.79	0.79
	1000	0.78	0.78	0.78	0.78	0.79	0.78
	2000	0.79	0.79	0.78	0.77	0.79	0.78
領域 重複率 (%)	0.0	0.97	0.97	0.97	0.97	0.97	0.97
	12	0.86	0.89	0.89	0.89	0.89	0.88
	24	0.79	0.82	0.82	0.82	0.82	0.81
	36	0.73	0.73	0.73	0.73	0.74	0.73
	48	0.65	0.68	0.67	0.68	0.68	0.67
	60	0.60	0.62	0.62	0.61	0.62	0.61
平均値		0.77	0.79	0.78	0.78	0.79	0.78

Table 3: Classification Rate of R-Random Method

		データ数 (個)						
		50	100	200	400	1000	2000	平均
領域 重複 率 (%)	0.0	0.97	0.96	0.97	0.97	0.98	0.97	0.97
	12	0.86	0.88	0.88	0.90	0.90	0.89	0.89
	24	0.76	0.73	0.80	0.81	0.81	0.81	0.79
	36	0.70	0.72	0.76	0.74	0.73	0.73	0.73
	48	0.64	0.62	0.62	0.67	0.68	0.67	0.65
	60	0.55	0.56	0.63	0.60	0.61	0.63	0.60
	平均	0.75	0.75	0.78	0.78	0.78	0.79	0.77

Table 4: Classification Rate of S-High-Class-Random Method

		データ数 (個)						
		50	100	200	400	1000	2000	平均
領域 重複 率 (%)	0.0	0.96	0.97	0.98	0.97	0.97	0.97	0.97
	12	0.86	0.89	0.89	0.90	0.89	0.89	0.89
	24	0.84	0.81	0.81	0.83	0.81	0.81	0.82
	36	0.72	0.72	0.76	0.73	0.73	0.74	0.73
	48	0.70	0.67	0.67	0.67	0.68	0.68	0.68
	60	0.63	0.60	0.65	0.62	0.62	0.63	0.62
	平均	0.79	0.78	0.79	0.79	0.78	0.79	0.79

タ対を構成し、そのクラス間距離が長いクラスを優先的に、また、そのクラス内のデータで他クラスのデータとのデータ対の距離が長い順に観測データを並び替える手法である。クラス対距離が最も長く、また、データ対距離が最も長いデータを優先的に投入する手法が、逐次学習型判別器の TAM ネットワークへのデータ投入順序として最も高い識別率を得たことは、TAM ネットワークがクラスの境界線付近に存在するデータを観測データの最後尾に配置することでクラス境界線の微調整を行っていることを示し、データ順列の配置方法の観点からも大変興味深い。

さて、観測データからサンプルデータを生成する場合、もしサンプルデータの各クラスの占有パターンが識別率と一定の関係性をもって存在するならば、クラスの占有パターンの傾向から識別率を予測できる。この観点から、クラスの占有率と識別率との一致度を次の評価値

Table 5: Classification Rate of CA-Short-Class-Aggregation Method

		データ数 (個)						
		50	100	200	400	1000	2000	平均
領域 重複 率 (%)	0.0	0.96	0.97	0.97	0.97	0.97	0.97	0.97
	12	0.88	0.87	0.89	0.91	0.89	0.89	0.89
	24	0.84	0.82	0.81	0.83	0.80	0.81	0.82
	36	0.72	0.72	0.75	0.73	0.74	0.73	0.73
	48	0.66	0.66	0.68	0.68	0.68	0.67	0.67
	60	0.61	0.58	0.65	0.63	0.62	0.63	0.62
	平均	0.78	0.77	0.79	0.79	0.78	0.78	0.78

E で定義する。

$$E = \sum_{i,j,i \neq j} E_{i,j} / 2R(i,j) \tag{13}$$

$$E_{i,j} = \begin{cases} E_i & ; O(i|i \rightarrow j) \geq O(j|i \rightarrow j) \\ E_j & ; O(j|i \rightarrow j) \geq O(j|i \rightarrow j) \end{cases} \tag{14}$$

$$E_i = w_1 O(i|i \rightarrow j) + w_2 C(i \rightarrow j) \tag{15}$$

$$E_j = w_1 O(j|i \rightarrow j) + w_2 C(i \rightarrow j) \tag{16}$$

ただし、 $R(i,j)$ はクラス i とクラス j の組み合わせ実験回数、 $O(i,j|i \rightarrow j)$ は、クラス i の次にクラス j の順序でデータを投入した際に占有率が高くなるクラス i またはクラス j の回数、 $C(i \rightarrow j)$ は、クラス i の次にクラス j の順序でデータを投入した際に識別率が高くなる回数を示す。なお、 $0 \leq w_1, w_2 \leq 1, w_1 + w_2 = 1$ である。

結果を図 5 から図 8 に示す。横軸はデータ個数を示し、縦軸は領域重複率を示す。また、太い実線円の半径は識別率を示し、淡い実践円の半径は一致度 E の値を示す。領域重複率が低いデータでは、識別率が高い場合に一致度が高くなっており、クラスの占有率から識別率が予測でき、占有率が高い場合には識別率も高い。特に、図 8 の C-長クラス・長データ法では、領域重複率が低いデータでは、多くの場合で一致度が高く、クラスの占有率の高低から識別率の高低が予測できる。また、領域重複率が高いデータでも、一致度が比較的高くなっており、クラスの占有率から識別率が予測できる。

この結果は、一致度の解析からも、C-長クラス・長データ法の有用性の高さが示され、PDSM の中では、C-長クラス・長データ法が最も実用的な手法であるといえる。

5. おわりに

本論文では、逐次学習型判別器への観測データの順列を変更し、識別率の精度を向上させる新たなデータ構成法 (PDSM) を提案した。数値例から、15 種類の PDSM の中では、C-長クラス・長データ法が最も実用的な手法であるといえた。

今後、本手法を実際の脳信号によるパターン分類に応用し、実際の BCI での有用性を検討する必要がある。

Table 6: Classification Rate of O-Close-Class-Close-Data Method

		データ数 (個)						
		50	100	200	400	1000	2000	平均
領域 重複 率 (%)	0.0	0.96	0.97	0.97	0.97	0.97	0.96	0.97
	12	0.88	0.87	0.89	0.91	0.89	0.89	0.89
	24	0.83	0.82	0.81	0.82	0.81	0.80	0.82
	36	0.71	0.71	0.75	0.73	0.74	0.72	0.73
	48	0.71	0.67	0.67	0.68	0.67	0.66	0.68
	60	0.62	0.59	0.63	0.63	0.62	0.59	0.61
	平均	0.78	0.77	0.79	0.79	0.78	0.77	0.78

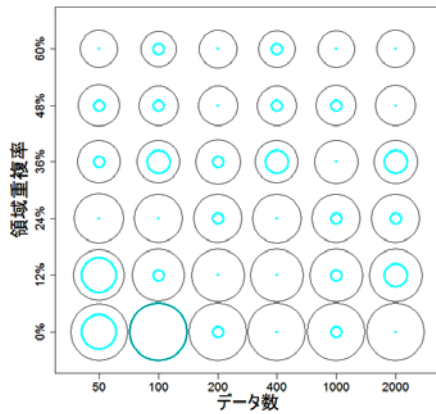


Fig. 5: Degree of Coincidence in S-High-Class-Random Method

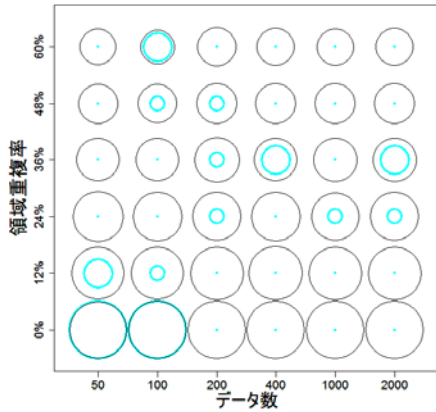


Fig. 6: Degree of Coincidence in CA-Short-Class-Aggregation Method

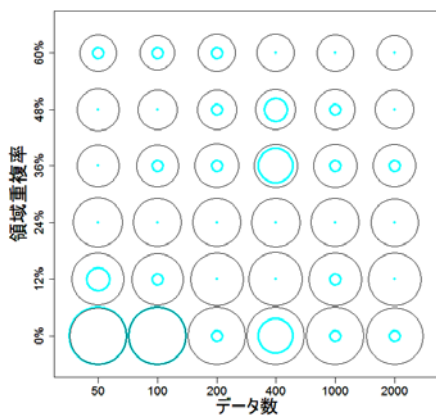


Fig. 7: Degree of Coincidence in O-Close-Class-Close-Data Method

Table 7: Classification Rate of C-Long-Class-Long-Data Method

		データ数 (個)						平均
		50	100	200	400	1000	2000	
領域重複率 (%)	0.0	0.95	0.97	0.98	0.98	0.97	0.97	0.97
	12	0.88	0.87	0.89	0.90	0.89	0.89	0.89
	24	0.85	0.82	0.81	0.82	0.81	0.81	0.82
	36	0.75	0.71	0.76	0.73	0.73	0.74	0.74
	48	0.70	0.68	0.67	0.67	0.68	0.68	0.68
	60	0.62	0.59	0.65	0.62	0.63	0.63	0.62
	平均	0.79	0.78	0.79	0.79	0.79	0.79	0.79




Fig. 8: Degree of Coincidence in C-Long-Class-Long-Data Method

参考文献

- [1] 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 International BCI Workshop*, pp.44-49 (2008).
- [2] 井上：脳波からヒトの状態を探る，日本知能情報ファジィ学会第5回脳と知覚研究部会ワークショップ特別講演 (2008)
- [3] 林，Williamson: TAM Network のプルーニング手法の提案, *システム制御情報学会論文誌*, Vol.17, No.2, pp.81-88 (2004)
- [4] 林，ウィリアムソン: ガボール型受容野をもつ TAM ネットワークの提案, *知能と情報*, Vol.18, No.3, pp.434-442 (2006)

[連絡先]

林 勲 関西大学大学院 総合情報学研究科
 〒 569-1095 大阪府高槻市霊仙寺町 2-1-1
 tel. 072-690-2448
 fax. 072-690-2491
 e.mail ihaya@cpii.kutc.kansai-u.ac.jp