

# 脳波から求めた複数特徴量の組合せによる生体認証

石川 由羽<sup>1,a)</sup> 西畑 かおり<sup>1</sup> 高田 雅美<sup>1</sup> 城 和貴<sup>1</sup>

受付日 2016年10月5日, 再受付日 2016年12月5日,  
採録日 2016年12月18日

**概要:** 脳と機械を直結する Brain Machine Interface (BMI) 技術の研究がさかんに行われている。我々は BMI で使用される認証技術として、脳波を用いた個人認証を提案する。本論文では、従来研究で提案されている複数特徴量を組み合わせることで、より精度の高い脳波認証を目指す。特徴量の組合せには AdaBoost を使用する。特徴量と使用電極の配置パターンを考慮することで、より適切な識別器の生成を行う。登録者 32 人と侵入者 18 人で提案手法の検証を行った結果、得られた認証率は EER0.52%である。

**キーワード:** 生体認証, 脳波, 特徴抽出, アンサンブル学習

## Biometric Authentication Based on Multi-feature Combination Using EEG

YU ISHIKAWA<sup>1,a)</sup> KAORI NISHIBATA<sup>1</sup> MASAMI TAKATA<sup>1</sup> KAZUKI JOE<sup>1</sup>

Received: October 5, 2016, Revised: December 5, 2016,  
Accepted: December 18, 2016

**Abstract:** The Brain-Machine Interface technology (BMI) directly linking brain with machine has been actively studied. As authentication technologies are used in BMIs, we propose a personal authentication method using electroencephalogram. In this paper, we try to improve the accuracy of an EEG-based authentication with multi-feature combination proposed in existing researches. AdaBoost is used for multi-feature combination. A more suitable classifier is generated by considering the combination patterns of both features and electrode placements. The proposed method obtains Equal Error Rate of 0.52% by using 32 registrants and 18 intruders.

**Keywords:** biometric authentication, electroencephalogram, feature extraction, ensemble learning

### 1. はじめに

脳と機械を直結する Brain Machine Interface (BMI) 技術が注目されている。特に、健常者が安全かつ容易に利用できる手法として、脳波を用いた非侵襲 BMI の開発がさかんに行われている。現在では、脳波で操作する義手・義足や、脳波を読み取り自律移動する車いす制御システム、人から人への脳波の直接通信等、様々な分野で研究が進められている。また、人の感情を察知して動くデバイス「necomimi」[1]、Google Glass を脳波で操作するアプリケーション「MindRDR」[2] 等、すでに市販されている

BMI 技術がある。今後の BMI 技術の発展により、ユーザインタフェースとしての脳波利用が考えられる。脳波を用いてコンピュータ等の操作を安全に行うために、認証技術の向上が求められる。従来の認証技術では、主に ID とパスワードを用いた個人認証が利用されている。しかし、盗用や、総当たり方式で認証試行された場合には容易に詐称される可能性がある。そのため、従来の手法では、安全性の面から必ずしも確実な手段とはいえず、近年ではバイオメトリック認証が利用されている。

バイオメトリック認証とは、生体情報を用いた個人認証のことである。指紋、虹彩、顔、声紋等の生体認証が研究・開発されており、これらの生体情報を用いた認証は従来のパスワード認証に比べて盗用が困難である。特に、指紋や

<sup>1</sup> 奈良女子大学  
Nara Women's University, Nara 630-8506, Japan  
<sup>a)</sup> ishikawa-yu0804@ics.nara-wu.ac.jp

虹彩は認証性能が高く、実用化されている。ただし、これらを用いた認証システムが詐称されることがある。その原因の1つとして、認証に必要な指紋や虹彩に関する情報がつねに外部にさらされている点があげられる。

この原因に対処可能な認証として、脳波を用いた生体認証が考えられている。脳波を使用する場合、内部情報かつ専用の計測器が必要であるため、盗用が困難である。また、BMIで利用することを考慮すると、取得脳波を認証に併用できるため、他の生体認証を用いるよりも効率が良い。脳波を用いた生体認証の研究は、すでに多方面から進められており、個人によって異なる特徴を示すことが明らかにされている。本論文では複数の特徴量を組み合わせることで、既存の手法 [3], [4], [5], [6], [7], [8], [9], [10], [11], [12], [13], [14], [15], [16], [17], [18], [19] よりも精度の良い認証システムを提案する。

また、近年脳波計の進歩も著しい。これまで、多チャンネルの脳波計は、非常に高価な機器であるため、医療分野でのみ使用され、装着には専門の技師が必要であった。しかし、現在では、日常生活で利用可能な多チャンネル脳波計が数多く開発されており、個人でも計測が可能となっている。既存の脳波認証に関する研究では、電極数が1-3チャンネルと少ないものが多いが、本論文では、16チャンネルの電極数を持つ多チャンネル脳波計を使用することで、より多くの個人特徴を取得する。

本論文の流れは以下のとおりである。2章では脳波認証の関連研究を紹介する。3章では個人認証システムの提案を行う。4章では提案手法の評価のために実験を行い、その結果について述べる。

## 2. 関連研究

脳波の個人認証では主に、脳波計測、特徴抽出、分類・認証手法について考慮すべきである。脳波はつねに一定ではなく、様々な内部刺激や外部刺激によって変化する。そのため、あらゆる計測状態での脳波認証が研究されている。たとえば、安静時の脳波 [3], [4], [5], [6], [7], [8], [9], [18], [19], メンタルタスク時の脳波 [10], [11], [17], 視覚誘発電位 (VEP: Visual Evoked Potentials) [12], [13] や事象関連電位 (ERP: Event Related Potentials) [14], [16] を対象とする研究がある。脳波認証で使用されている特徴量としては、周波数解析で得られるスペクトル情報を用いた研究 [3], [4], [7], [8], [11], [13], [15], [17], [18], [19] が主流である。また、電極間の位相・振幅の関係を表すためにコヒーレンスを用いた研究 [7], [8], [9], [19], 空間情報として電極間の類似度を算出する相互相関係数や相互情報量を利用した研究 [7], [8], [18], [19], 自己回帰 (AR: Auto Regressive) モデルを用いた研究 [3], [4], [5], [6], [7], [8] がある。特徴量の学習方法としては、機械学習である判別分析 (DA: Discriminant Analy-

sis) [5], [7], [8], [16], サポートベクタマシン (SVM: Support Vector machine) [18], [19], ニューラルネットワーク (NN: Neural Network) [6], [11], [13] を用いた手法が主流である。

バイOMETリック認証の性能は、主に分類率と等価エラー率 (EER: Equal Error Rate) から求められる。分類率は、クラスタリングにより、本人が本人であると正しく分類された確率である。EERは、本人であるにもかかわらず本人ではないと判断される本人拒否率 (FRR: False Rejection Rate) と、他人であるにもかかわらず本人であると判断される他人受入率 (FAR: False Acceptance Rate) から求められる。FRRとFARの交点がEERである。既存研究では、分類率のみで性能評価を行っている研究 [5], [6], [9], [11], [12], [13], [14], [18] が多く、EERの結果を求めているもの [3], [4], [7], [8], [10], [15], [16], [17], [19] は比較的少ない。分類率を算出する場合、認証システムに登録されている登録者のデータのみを使用する。認証要請データは登録者内のいずれかに必ず分類されるため、システムに登録されていない侵入者を考慮していないと考えられる。一方、EERを求める場合、登録者のデータと侵入者のデータの双方を用いて評価する手法が一般的である。そのため、侵入者を考慮したシステム性能が得られる。

脳波を用いた分類・認証の研究成果を紹介する。安静時の脳波を用いた研究は古くから行われている。1999年、Poulosらにより報告された研究 [3] では、脳波から得られるスペクトル情報とARモデルを用いることで学習ベクトル量子化法 (LVQ: Learning Vector Quantization) により分類が行われている。4人の登録者と75人の侵入者で認証を行った結果、EER21%、分類率72-84%が得られている。さらに、計算幾何学アルゴリズムにより手法を改良することで、EER9.2%、分類率95%に精度が向上している [4]。2001年、Parajanpeらは40人で実験を行い、脳波から得られるARモデルをDAに適用し、79-85%の分類率を実現している [5]。2006年、Mohammadiらの報告では、10人の脳波のARモデルをNNで学習させることで、80-100%の分類率を得ている [6]。2008年、RieraらはARモデル、コヒーレンス、相互相関係数等の、複数の特徴量を用いてDAを行うことで、51人の登録者と36人の侵入者の脳波からEER3.5-5.5%、分類率97.5-98.1%を得たと報告している [7]。2012年、Safontらは、Rieraら同様、複数の特徴量をDAや分類木等を用いて分類した結果、50人の登録者と20人の侵入者の脳波から、EER2.4%、分類率93.8%を得ている [8]。2014年には、La Roccaらにより、電極間のコヒーレンスにマハラノビス距離を適用した分類が行われている。その結果、108人の脳波から97.5-100%の分類率が得られている [9]。また、メンタルタスク時の脳波に関する研究では、2007年、Marcelらにより、ガウス混合モデルと最大事後確率モデルを使用する

手法が提案され、運動想起時や言語想起時の脳波を用いて9人の認証を行った結果、6.6-7.1%のEERが得られている[10]。2008年、Hemaらは、6人の読書時と計算時の脳波からβ波を抽出し、NNで学習させることによって、91.6-97.5%の分類率を得ている[11]。VEPを用いた研究では、2005年、Raviらは、simplified fuzzy ARTMAPとk近傍法により脳波を分類した結果、20人で92-95.3%の分類率を得ている[12]。さらに、手法の改良を行い、2007年には、スペクトル情報とElman NNを用いることで、40人で97.5-98.1%の分類率に改善している[13]。ERPに関する研究では、2016年、Ruiz Blondetらにより、複数の画像を見せることで得られるERPを使用するCEREBRE (Cognitive Event-Related Biometric REcognition) システムが開発され、50人で100%の分類率が得られている[14]。これらの既存研究のうち、電極数が3チャンネル以下の脳波計を用いたものは文献[3], [4], [5], [6], [7], [8], [9], [11], 30チャンネル以上のもは文献[10], [12], [13], [14]であり、電極数が少ない状態を対象とする研究が多い。

国内で行われている脳波認証に関する研究を紹介する。Nakanishiらは、主に運転時の継続的な脳波認証に関する研究を行っており、2013年、α波-β波の周波数帯域から認証に最適な周波数帯域の検証を行うことで、22%のEERを得ている[15]。2014年、唐山は、α波とERPを組み合わせた手法により、7人の被験者実験の結果、室内安静状態では86.8%、屋外安静状態では74.8%、屋外歩行状態では68.4%の分類率である報告している[16]。我々は、これまでにメンタルタスク時や安静時の脳波を用いて研究を行っており、2014年、メンタルタスク時の脳波を周波数解析し、コサイン類似度を用いることで、10人からEER2.9%を得ている[17]。また、26人の安静時の脳波を用いた実験では、2015年、複数の特徴量を組み合わせてSVMで分類させることで分類率98.6%[18]、2016年、AdaBoostを用いた手法に改良することでEER2.0%[19]を得ている。

### 3. 認証システム

本論文では、短時間での脳波認証を目標とするため、メンタルタスクや外部刺激を必要とすることのない、安静時の脳波を用いて認証を行う。提案する認証システムの流れを図1に示す。システムは登録フェーズと認証フェーズで構成される。

登録フェーズでは、まず、登録者の脳波を一定時間計測し、1秒ごとに分割する。各データに前処理を施し、特徴抽出を行う。得られた特徴量から、それぞれ弱識別器を生成する。AdaBoostを用いて、複数の弱識別器を組み合わせることで、強識別器を構成する。これが認証システムの学習モデルとなる。

認証フェーズでは、登録フェーズ同様に、認証者のデータを一定時間計測し、1秒ごとに前処理、特徴抽出を行う。

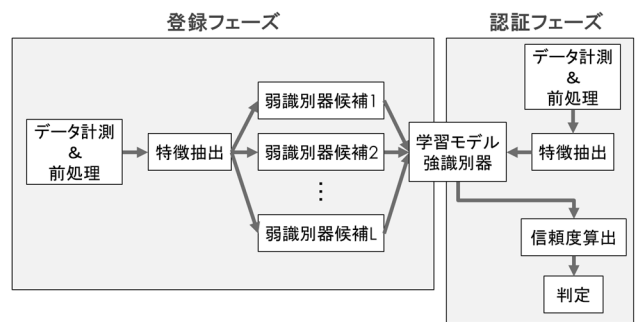


図1 認証システムの概略図

Fig. 1 Authentication system flow.

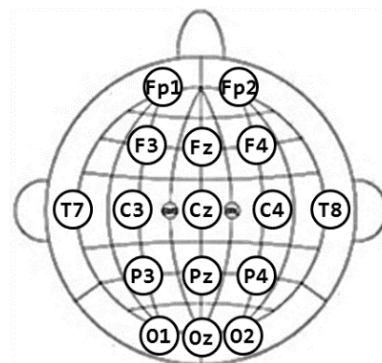


図2 電極配置図

Fig. 2 Electrode placement.

得られた特徴量に登録フェーズで生成された学習モデルを適用する。次に、認証者が登録者である信頼度を算出する。この際、計測データすべての信頼度の平均値を認証者の信頼度とする。認証者の信頼度とあらかじめ設定した閾値を比較することで、認証者の受理・拒否の判断を行う。

以下の節では、データ計測と前処理、特徴抽出、学習モデル生成、判定の詳細を説明する。

#### 3.1 データ計測と前処理

本論文では多チャンネル脳波計であるBioSemiを用いて計測を行う。基準電極の導出には双極誘導法を使用する。脳波計のサンプリング周波数は最大2,048 Hz、搭載可能な電極数は最大256チャンネルである。提案する認証システムでは、サンプリング周波数2,048 Hz、電極数16チャンネルにより計測を行う。電極配置は国際10-20法[20]に従い、図2のように配置する。

まず、脳波を一定時間計測し、1秒ごとに分割する。以下の手順に従い、各データに前処理を施し、特徴抽出に適したデータに補正する。

- i. バンドパスフィルタ
- ii. ノイズ除去
- iii. 正規化

手順iでは、バンドパスフィルタを用いて、計測データから4-40 Hzの周波数帯域のみを抽出する。この周波数帯域

は、主に脳波の活動がさかんに観察される帯域である。一般的に1-3 Hzはδ波と定義されているが、脳波以外の筋電位や眼球運動、心拍等の生体現象によるアーチファクトを多く含むため、本論文では除外する。また、50 Hz, 60 Hzに現れる交流障害等の環境に起因するアーチファクトもバンドパスフィルタにより取り除く。バンドパスフィルタ内で使用する窓関数として、ハミング窓を適用する。手順iiでは、一時的に現れるパルスノイズを補正するため、バンドパスフィルタ後のデータの標準偏差を求め、 $3\sigma$ を超えるデータを $3\sigma$ に補正する。手順iiiにおいて、ノイズ除去後のデータを0-1に正規化する。これらの処理により、バイアス等を取り除き、より認証に適したデータに再構築する。

### 3.2 特徴抽出

前処理後のデータから特徴量を抽出する。本システムではスペクトル情報、コヒーレンス、相互相関係数、相互情報量の4種類の特徴量を用いる。また、個人認証に適した電極を確認するため、電極配置部位の違いを特徴量として与える。使用する電極配置パターンは10種類である。これらの組合せである40 ( $4 \times 10$ ) 種類を特徴量とする。以下の項では、各特徴量と電極配置パターンを説明する。

#### 3.2.1 スペクトル情報

脳波の解析で最も一般的な手法である周波数解析として、高速フーリエ変換 (FFT) を用いたスペクトル情報を適用する。脳波は周波数により分類され、周波数帯域ごとに性質が異なるとされている。そのため、脳波の特徴を表すことができる周波数解析が有効である。

本提案手法では、スペクトル情報として振幅スペクトルを使用する。FFTを行う際に、前処理同様、ハミング窓を適用する。電極  $a$  の振幅スペクトル  $PS_a$  は、以下の式により、FFTにより得られる実部  $Re_a$  と虚部  $Im_a$  から求められる。

$$PS_a = \sqrt{Re_a^2 + Im_a^2} \quad (1)$$

得られたスペクトル情報  $PS$  から、 $\theta$  波 (4-8 Hz),  $\alpha$  波 (8-14 Hz),  $\beta$  波 (14-26 Hz),  $\gamma$  波 (26-40 Hz) の周波数帯域ごとに平均含有率を算出し、ベクトル長4の特徴量とする。平均含有率とは、各周波数帯域における1データあたりのスペクトル含有率を平均化したものである。

#### 3.2.2 コヒーレンス

電極間の波形の位相・振幅の関係を得るため、コヒーレンスを使用する。コヒーレンスは振幅スペクトルとクロススペクトルから求められる。電極  $a, b$  間のコヒーレンス  $COH$  は次の式によって計算される。

$$COH = \frac{CPS_{ab} CPS_{ab}}{PS_a PS_b} \quad (2)$$

$$CPS_{ab} = \sqrt{(Re_a Re_b + Im_a Im_b)^2 + (Re_a Im_b + Im_a Re_b)^2} \quad (3)$$




図3 電極配置パターン

Fig. 3 Electrode placement patterns.

得られたコヒーレンスをスペクトル情報同様に4種類の周波数帯域ごとに平均含有率を算出し、ベクトル長4の特徴量とする。

#### 3.2.3 相互相関係数

電極間の類似性を特徴量とするため、相互相関係数を用いる。相互相関係数は快・不快の感情推定や運動時の脳波解析等、様々な分野で使用されている。

電極  $a, b$  間の相互相関係数  $CC$  は次の式で表される。

$$CC = \frac{\sum_{i=1}^K (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^K (a_i - \bar{a})^2} \sqrt{\sum_{i=1}^K (b_i - \bar{b})^2}} \quad (4)$$

$K$  はデータ長である。 $a_i, b_i$  はそれぞれ電極  $a, b$  の時系列データであり、 $\bar{a}, \bar{b}$  は電極  $a, b$  の時系列データの平均値である。係数が1の場合は正の相関あり、0の場合は相関なし、-1の場合は負の相関ありと判断される。

#### 3.2.4 相互情報量

電極間の相互依存を使用するため、相互情報量が必要である。電極  $a, b$  間の相互情報量  $MI$  は

$$MI = \sum_{i=1}^K \sum_{j=1}^K p(a_i, b_j) \log \frac{p(a_i, b_j)}{p(a_i)p(b_j)} \quad (5)$$

によって求められる。ここで、 $p(a, b)$  は  $a$  と  $b$  の同時確率分布関数、 $p(a)$  と  $p(b)$  はそれぞれ  $a$  と  $b$  の周辺確率分布関数である。前処理としてデータの各値をリスケールする必要がある。

#### 3.2.5 電極配置パターン

電極配置パターンを図3に示す。本論文では10種類用意する。黒い電極が使用電極、白い電極が不使用電極を表す。電極配置パターンの詳細を表1に示す。電極数・電極部位の異なるパターンを複数使用することで、これらが個人認証に与える影響を考察することができる。

### 3.3 学習モデル生成

複数の特徴量を用いて個人認証を行うために、特徴量の組合せ手法としてAdaBoostを適用する。AdaBoostとは、Boostingによって複数の弱識別器を組み合わせるアンサンブル学習の一種であり、学習データの重みを適応的に更新する手法である。クラスタリング結果は弱識別器の重み付き多数決により決定される。アルゴリズムは以下のとおり

表 1 電極配置パターンの詳細  
Table 1 Details of electrode placement patterns.

パターン番号	電極数	電極部位	部位名称
1	9	F3, Fz, F4, C3, Cz, C4, P3, Pz, P4	頭頂部周辺
2	10	Fp1, Fp2, F3, Fz, F4, T7, C3, Cz, C4, T8	前頭部周辺
3	11	T7, C3, Cz, C4, T8, P3, Pz, P4, O1, Oz, O2	後頭部周辺
4	10	Fp1, F3, Fz, T7, C3, Cz, P3, Pz, O1, Oz	左半球全体
5	10	Fp2, Fz, F4, Cz, C4, T8, Pz, P4, Oz, O2	右半球全体
6	6	Fp1, F3, Fz, T7, C3, Cz	左半球前頭部周辺
7	7	T7, C3, Cz, P3, Pz, O1, Oz	左半球後頭部周辺
8	7	Cz, C4, T8, Pz, P4, Oz, O2	右半球後頭部周辺
9	6	Fp2, Fz, F4, Cz, C4, T8	左半球前頭部周辺
10	16	全電極	頭部全体

である。

- 1 特徴量  $x_n$  ( $n = 1, \dots, N$ ) の重み  $w_n$  を  $1/N$  に初期化する。
- 2  $L$  個の弱識別器候補  $f_l$  ( $l = 1, \dots, L$ ) を計算する。
- 3 3.1-3.6 を繰り返す。学習回数を  $m$  とし、 $m=1$  から開始する。
  - 3.1 3.1.1 を  $L$  回繰り返す。
    - 3.1.1 弱識別器候補のエラー率  $\epsilon_m$  を算出する。 $f_l(x_n)$  の目標値を  $t_n$  とする。

$$\epsilon_m = \frac{\sum_{n=1}^N w_n I(f_l(x_n))}{\sum_{n=1}^N w_n} \quad (6)$$

$$I(f_l(x_n)) = \begin{cases} 0, & f_l(x_n) = t_n \\ 1, & \text{otherwise} \end{cases} \quad (7)$$

- 3.2 弱識別器候補から最もエラー率の小さい弱識別器  $y_m(x_n)$  を選択する。 $y_m(x_n)$  は弱識別器の出力である。
- 3.3 選択した弱識別器のエラー率から信頼度  $\alpha_m$  を算出する。

$$\alpha_m = \frac{1}{2} \ln \left( \frac{(1 - \epsilon_m)}{\epsilon_m} \right) \quad (8)$$

- 3.4 エラー率が 0.5 以上の場合、 $m$  を  $M$  に代入し、

4へ進む。

- 3.5 重みを更新する。ただし、重みの合計はつねに 1 とする。

$$w_n^{(m+1)} = w_n^{(m)} \exp(\alpha_m I(y_m(x_n))) \quad (9)$$

$$w_n^{(m+1)} = \frac{w_n^{(m+1)}}{\sum_{n=1}^N w_n^{(m+1)}} \quad (10)$$

- 3.6  $m$  に 1 を加算する。

#### 4 強識別器を構成する。

$$Y_M(x) = \sum_{m=1}^M \alpha_m y_m(x_n) \quad (11)$$

手順 1 では、特徴量として 3.2 節の 40 種類を使用する。 $N$  は教師データ数である。手順 2 では、これらの特徴量にそれぞれ SVM を適用して、40 種類の弱識別器候補を生成する。SVM のカーネルには RBF を使用する。手順 3, 4 で生成された強識別器が個人認証の学習モデルとなる。本論文では、AdaBoost の結果から得られる信頼度を個人認証として使用するため、強識別器構成後、使用される弱識別器の信頼度の累計が 100% になるように補正する。

#### 3.4 判定

認証者は脳波計測を行い、「登録者」を指定する。本システムでは、認証者が指定した登録者である信頼度を求めることで判定する。計測データは、登録時同様に 1 秒ごとに前処理、特徴抽出が行われる。抽出された特徴量を、登録フェーズで生成された学習モデルに適用する。学習モデルにより、指定した登録者と認証者の信頼度が算出される。計測データを 1 秒ごとに分割して処理するため、データ長が 2 秒以上であれば、複数の信頼度が得られる。これら複数の信頼度の平均を、認証者の信頼度とする。信頼度の範囲は 0-100% である。認証者の信頼度が、あらかじめ設定された閾値以上であれば、本人であると見なし受理する。また、閾値未満であれば、他人であると見なし拒否する。

#### 4. 評価

提案システムの性能を検証する。本システムの性能は EER と分類率から求める。被験者は健康な 20 代女性 50 人である。50 人のうち、登録者 32 人、侵入者 18 人で実験を行う。本論文は脳波認証の基礎研究であるため、計測時は座位、安静、閉眼状態で行う。登録者は 1 回あたり 60 秒の計測、侵入者は 10 秒の計測を 1 人あたり 50 回行う。全データ数は 50 名 × 50 個の計 2,500 個である。EER 算出に使用するデータ数は登録者 32 人のデータ 1,600 個、侵入者 18 人のデータ 900 個である。分類率算出に使用するデータ数は登録者 32 人のデータ 1,600 個である。結果の算出には 10 交差検定を使用する。実験では、認証時に使用するデータとして、計測データから初めの 6 秒間のデータを切り出し、検証する。

表 2 各特徴量のクラスタリング結果  
Table 2 Classification rate of each feature.

特徴量	EER (%)	分類率 (%)
スペクトル情報	2.83	92.19
コヒーレンス	2.55	93.69
相互相関係数	1.75	96.69
相互情報量	1.17	98.25
提案手法	0.52	99.06

4.1 提案手法の性能評価

特徴量の性能を比較するため、EER と分類率を求める。結果を表 2 に示す。特徴量として、スペクトル情報、コヒーレンス、相互相関係数、相互情報量の 4 種類を使用した手法と、4 種類の特徴量を AdaBoost により組み合わせた提案手法を比較する。表の値は 10 交差検定後の平均値をパーセンテージで表示している。4 種類の特徴量では、16 チャンネルすべてを使用したデータを SVM により分類し、その結果から EER と分類率を算出する。データ計測と前処理、特徴抽出、判定方法は提案手法と同様である。4 種類の特徴量より、相互情報量、相互相関係数、コヒーレンス、スペクトル情報の順に低い EER、高い分類率が得られている。AdaBoost により複数の特徴量を組み合わせた提案手法は、EER0.52%、分類率 99.06%と高い性能が得られている。これは、4 種類の特徴量と比較して、最も良い結果である。特に、EER は唯一 1%未満であり、単一特徴量の中で最も低い EER を得ることができる相互情報量の半分以下のエラー率である。これにより、提案手法による特徴量の組合せは、単一の特徴量を使用する場合よりも、認証手法として有効であると考えられる。

次に、認証精度を調べるために、以下の 3 種類の検証を行う必要がある。

- A) 登録者の正式な認証
- B) 登録者のなりすましによる認証
- C) 侵入者のなりすましによる認証

検証 A) は、登録者本人の認証が正式に行われる場合、検証 B) は、登録者が別の登録者になりすました場合、検証 C) は、侵入者が登録者になりすました場合を検証するものである。提案手法により得られた全データの信頼度を示した図が図 4 と図 5 である。横軸が認証者の番号であり、縦軸は登録者の番号である。図 4 は、検証 A), B) の信頼度である。認証者の番号と登録者の番号が一致する場合は検証 A) の正式な認証の結果であり、一致しない場合は検証 B) のなりすましによる認証の結果である。つまり、対角成分が検証 A), 対角成分以外が検証 B) の結果を示

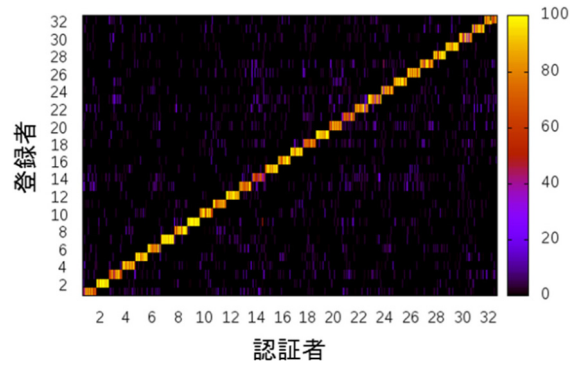


図 4 検証 A), B) の信頼度  
Fig. 4 Reliability of validation A), B).

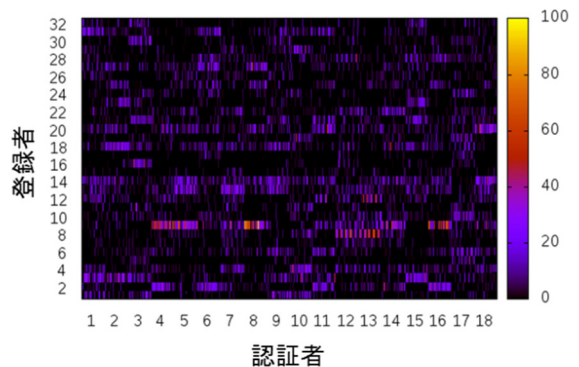


図 5 検証 C) の信頼度  
Fig. 5 Reliability of validation C).

している。図 4 より、認証者と登録者が一致する場合は信頼度が高く、一致しない場合は信頼度が低いことが明らかである。それぞれの成分の信頼度の平均値は、検証 A) が 80.54%、検証 B) が 0.63%である。このため、登録者のなりすましを防ぐことは可能であると考えられる。図 5 は、検証 C) の信頼度である。すべての成分が検証 C) の結果を示している。検証 C) はシステムに登録されていない侵入者のデータであるため、登録者番号と認証者番号は一致しない。検証 A) と比較すると検証 C) は信頼度が低いことが明らかである。検証 C) の全成分の信頼度の平均値は 3.12%である。検証 B) に比べて信頼度は高いものの、検証 A) との差は歴然である。ゆえに、検証 A) と検証 C) の信頼度の間に閾値を設定することで、精度の高い認証システムを構築できると考えられる。

提案手法の FRR と FAR の交差検定結果の一例を図 6 に示す。この例では、閾値 35%の場合、FRR0%, FAR0.35%, EER0.18%である。FAR を 0.1%未満にする場合、閾値は 52%以上が必要であり、FRR は 5%以上となる。また、FAR を 0%にする場合、閾値は 64%以上が必要であり、FRR は 18%以上となる。

認証時に使用するデータ長を変化させた場合の EER と分類率を図 7 と図 8 に示す。横軸はデータ長を 1-10 秒間で変化させたものであり、縦軸はそのときの EER と分

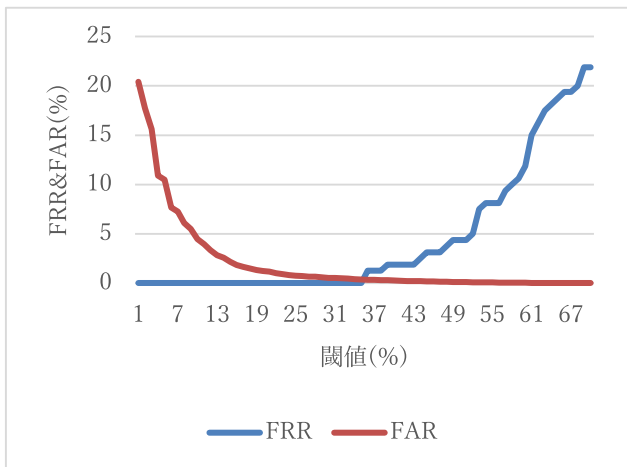


図 6 FRR & FAR  
Fig. 6 FRR & FAR.




図 7 EER (データ長を変化させた場合)  
Fig. 7 EER (case of changing data length).




図 8 分類率 (データ長を変化させた場合)  
Fig. 8 Classification rates (case of changing data length).

類率である。これらの図は、使用するデータ長が長くなるほど、EER、分類率ともに精度が向上することを表している。データ長が1秒間の場合、EERと分類率はそれぞれ3.61%と90.50%であり、十分な認証精度とはいえない。データが分割されないため、平均をとることができず精度

が低いと考えられる。EERが1%未満になる平均数は4以上であるため、最短のデータ長は4秒以上必要である。また、分類率99%以上になる平均数は6以上であるため、最短のデータ長は6秒以上必要である。データ長を10秒間を使用する場合、EERと分類率はそれぞれ0.43%と99.19%であり、ともに最も良い結果が得られている。

2章の関連研究で紹介した既存研究 [3], [4], [5], [6], [7], [8], [9], [10], [11], [12], [13], [14] と提案手法の比較を行う。EERと分類率の結果を表3に示す。既存研究には、被験者として、登録者のみを用いて検証を行っている研究と、登録者と侵入者を用いて行っている研究がある。侵入者の検証を行っている場合は登録者数の後ろに侵入者数を表記する。また、既存研究によって認証時の状態も多様であるが、安静時はresting、メンタルタスク時はmental、視覚誘発電位を用いた場合はVEP、自称関連電位を用いた場合はERPと表記する。手法では、認証に使用される特徴量と分類方法を示す。提案手法の結果は、10交差検定後のEERと分類率の平均値であり、それぞれ0.52%、99.06%である。なお、この結果はデータ長6秒の場合であり、既存研究の中で最も短いデータ長を用いて認証を行っているSafant 2016 [8]と同じ長さとしている。その他の既存研究 [3], [4], [5], [6], [7], [9], [10], [11], [12], [13], [14] では24秒から数分間のデータ長を使用している。すべての既存研究と比較して、EERの提案手法の認証精度が高いことが明らかである。特に、既存研究の中で最もEERの低い2.4%の1/4以下である。分類率では、Mohammadiら [6], La Roccaら [9], Ruiz Blondetら [14]の報告により、100%が得られている。そのうち、本提案手法と同様に安静時の脳波を用いたMohammadiら [6]とLa Roccaら [9]は、データ長がそれぞれ24秒と60秒であり、本実験で使用したデータ長より4倍以上必要とする。そのため、短時間のデータを用いた場合の提案手法の分類率は高いと考えられる。

#### 4.2 複数特徴量の組合せ結果

提案手法の特徴量の組合せ結果について考察する。

まず、提案手法で使用するAdaBoostの学習回数とEERの推移の例を図9に示す。横軸はAdaBoostで繰り返される学習回数の値であり、縦軸はそのときのEERの値である。初めの数回の学習により、EERの減少が確認できる。この例では、学習は24回で終了し、学習回数14回以降はEERに変化がなく一定である。学習終了後の各特徴量の信頼度を表4に示す。10交差検定後の平均値をパーセンテージで表示している。スペクトル情報、コヒーレンス、相互相関係数、相互情報量の信頼度の合計は、それぞれ、15.61%、20.08%、21.61%、42.70%である。相互情報量が全体の半数近く占めており、スペクトル情報は最も少ない。スペクトル情報の信頼度が低い原因として、本提案

表 3 既存研究と提案手法の比較

Table 3 Comparison of existing studies & proposed method.

研究	被験者	状態	手法	EER (%)	分類率 (%)
Poulos 1999 [3]	4, 75	Resting	スペクトル情報, AR / LVQ	21	72-84
Poulos 1999 [4]	4, 75	Resting	スペクトル情報, AR / 計算幾何学アルゴリズム	9.2	95
Parajanpe 2001 [5]	40	Resting	AR / DA	n/a	79-85
Ravi 2005 [12]	20	VEP	Simplified fuzzy ARTMAP / k 近傍法	n/a	92-95.3
Mohammadi 2006 [6]	10	Resting	AR / NN	n/a	80-100
Palaniappan 2007 [13]	40	VEP	スペクトル情報 / NN	n/a	92.9-98.1
Marcel 2007 [10]	9	Mental	ガウス混合モデル, 最大事後確率モデル	6.6-7.1	n/a
Riera 2008 [7]	51, 36	Resting	AR, スペクトル情報, 相互相関係数, 相互情報量, コヒーレンス / DA	3.5-5.5	97.5-98.1
Hema 2008 [11]	6	Mental	スペクトル情報 / NN	n/a	91.6-97.5
Safont 2012 [8]	50, 20	Resting	AR, スペクトル情報, 相互相関係数, 相互情報量, コヒーレンス, 歪度と尖度, 独立成分分析, 自己共分散, 時間逆転性 / DA, 分類木	2.4	93.8
La Rocca 2014 [9]	108	Resting	コヒーレンス / マハラノビス距離	n/a	97.5-100
Ruiz Blondet 2016 [14]	50	ERP	正規化相互相関	n/a	100
提案手法	32, 18	Resting	スペクトル情報, コヒーレンス, 相互相関係数, 相互情報量 / SVM, AdaBoost	0.52	99.06




図 9 AdaBoost の学習回数と EER の推移

Fig. 9 Error rate by number of learning epochs using AdaBoost.

手法では、データから 1 秒ごとに特徴抽出を行っているため、1 秒ではスペクトル情報からの個人差が十分に得られていないことがあげられる。特徴抽出を行うデータ長を伸ばすことで、スペクトル情報でも十分な信頼度が得られる可能性がある。電極配置パターンに着目すると、パターン 10 は全体の 93.53% を占めている。その他は、パターン 3 のみ使用されている。パターン 3 は 11 個の電極を使用しており、パターン 10 の次に多い電極数であるため、使用電極数が結果に大きく影響しているものと考えられる。また、後頭部は前頭部より眼球運動等のノイズが少ないため、

表 4 AdaBoost 後の各特徴量の信頼度

Table 4 Reliability of each feature after AdaBoost.

信頼度 (%)	電極配置パターン									
	1	2	3	4	5	6	7	8	9	10
スペクトル情報	0	0	0.03	0	0	0	0	0	0	15.58
コヒーレンス	0	0	0.05	0	0	0	0	0	0	20.03
相互相関係数	0	0	0	0	0	0	0	0	0	21.61
相互情報量	0	0	6.39	0	0	0	0	0	0	36.31

高い信頼度が得られているものと思われる。40 種類の組合せの中で、1 度も使用されていない組合せは 33 通りある。よって、使用される特徴量は限られている。

そこで、認証に適した特徴量の組合せとして、信頼度の高い上位数個を選択する。40 種類の組合せを信頼度の高い順に累計した結果を表 5 に示す。使用する特徴量数を 1-7 個まで増加させた場合の、選択された特徴量と電極配置パターン、信頼度の累計、EER、分類率を表示している。表より、使用する特徴量数が増加するにつれて、EER が減少



表 5 特徴量の信頼度の累計と認証精度

Table 5 Total reliability &amp; authentication accuracy of features.

特徴量数	特徴量	電極配置パターン	信頼度の累計 (%)	EER (%)	分類率 (%)
1	相互情報量	10	36.31	1.17	98.25
2	相互相関係数	10	57.92	0.76	98.69
3	コヒーレンス	10	77.96	0.57	98.87
4	スペクトル情報	10	93.54	0.56	98.94
5	相互情報量	3	99.92	0.52	99.06
6	コヒーレンス	3	99.97	0.52	99.06
7	スペクトル情報	3	100.00	0.52	99.06

し、分類率が増加していることが分かる。そのため、特徴量の組合せが認証精度の向上につながると考えられる。また、特徴量数5のときに信頼度の累計は99%を超えて、それ以降一定である。このときのEERと分類率は、それぞれ0.52%, 99.06%であり、AdaBoostにより選択されたすべての特徴量を使用した結果と同等である。したがって、特徴量数5で十分な学習が行えているものと考えられる。選択された組合せは(相互情報量, パターン10), (相互相関係数, パターン10), (コヒーレンス, パターン10), (スペクトル情報, パターン10), (相互情報量, パターン3)である。この組合せは、交差検定10回とも同じ結果であるため、認証において有効な組合せである。

## 5. おわりに

本論文では、脳波を用いた複数特徴量の組合せによる生体認証の提案を行った。特徴量にはスペクトル情報、コヒーレンス、相互相関係数、相互情報量の4種類と脳波計の使用電極を変更した10パターンの40種類の組合せを使用した。これらの組合せからAdaBoostを用いて最適な特徴量を選択することで、認証精度の向上に成功した。提案手法を適用した結果、認証時に使用するデータ長を6秒間とした場合のEERは0.52%である。これは、既存研究と比較しても、明らかに良い結果が得られている。

認証に使用するデータ長により、選択される特徴量が変化するものと考えられるが、本提案手法であるAdaBoostによる特徴量の組合せを採用することで、データ長に適した特徴量が選択される。今後は、全電極の組合せを考慮して、認証に有効な電極配置の特定を目指す。

本論文では、既存研究と提案手法の結果を比較することで性能評価を行った。今後、有効性を示すための課題としては、同じ実験データを用いて既存手法との比較を行うことである。脳波による生体認証を確立するために、将来的には、大規模な脳波データベースの整備が求められる。

謝辞 本研究は特別研究員奨励費(16J10436)の助成を受けたものである。

## 参考文献

- [1] Neurowear Projects/nekomimi, available from ([http://neurowear.com/projects\\_detail/nekomimi.html](http://neurowear.com/projects_detail/nekomimi.html)) (accessed 2016-12-04).
- [2] This Place MindRDR, available from (<http://mindrdr.thisplace.com/static/index.html>) (accessed 2016-12-04).
- [3] Poulos, M., Rangoussi, M., Chrissikopoulos, V. and Evangelou, A.: Person identification based on parametric processing of the EEG, *IEEE International Conference on Electronics, Circuits and Systems*, Vol.1, pp.283-286 (1999).
- [4] Poulos, M., Rangoussi, M., Chrissikopoulos, V. and Evangelou, A.: Parametric person identification from the EEG using computational geometry, *IEEE International Conference on Electronics, Circuits and Systems*, Vol.2, pp.1005-1008 (1999).
- [5] Paranjape, R.B., Mahovsky, J., Benedicenti, L. and Koles, Z.: The electroencephalogram as a biometric, *Canadian Conference on Electrical and Computer Engineering*, Vol.2, pp.1363-1366 (2001).
- [6] Mohammadi, G., Shoushtari, P., Molaee Ardekani, B. and Shamsollahi, M.B.: Person identification by using AR model for EEG signals, *World Academy of Science, Engineering and Technology*, Vol.11, No.EPFL-CONF-153223, pp.281-285 (2006).
- [7] Riera, A., Soria-Frisch, A., Caparrini, M., Grau, C. and Ruffini, G.: Unobtrusive biometric system based on electroencephalogram analysis, *EURASIP Journal on Advances in Signal Processing*, Vol.1, pp.1-8 (2008).
- [8] Safont, G., Salazar, A., Soriano, A. and Vergara, L.: Combination of multiple detectors for EEG based biometric identification/authentication, *IEEE International Carnahan Conference on Security Technology*, pp.230-236 (2012).
- [9] La Rocca, D., Campisi, P., Vegso, B., Cserti, P., Kozmann, G., Babiloni, F. and Fallani, F.D.V.: Human brain distinctiveness based on EEG spectral coherence connectivity, *IEEE Trans. Biomedical Engineering*, Vol.61, No.9, pp.2406-2412 (2014).
- [10] Marcel, S. and Millán, J.D.R.: Person authentication using brainwaves (EEG) and maximum a posteriori model adaptation, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.29, No.4, pp.743-752 (2007).
- [11] Hema, C.R., Paulraj, M.P. and Kaur, H.: Brain signatures: A modality for biometric authentication, *International Conference on Electronic Design*, pp.1-4 (2008).
- [12] Ravi, K.V.R. and Palaniappan, R.: Leave-one-out authentication of persons using 40 Hz EEG oscillations, *International Conference on Computer as a Tool*, Vol.2, pp.1386-1389 (2005).
- [13] Palaniappan, R. and Mandic, D.P.: Biometrics from brain electrical activity: A machine learning approach, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.29, No.4, pp.738-742 (2007).

- [14] Ruiz-Blondet, M.V., Jin, Z. and Laszlo, S.: CEREBRE: A Novel Method for Very High Accuracy Event-Related Potential Biometric Identification, *IEEE Trans. Information Forensics and Security*, Vol.11, No.7, pp.1618-1629 (2016).
- [15] Nakanishi, I., Fukuda, H. and Li, S.: Biometric verification using brain waves toward on-demand user management systems: performance differences between divided regions in  $\alpha$ - $\beta$  wave band, *International Conference on Security of Information and Networks*, pp.131-135 (2013).
- [16] 唐山英明: ウェアラブル型 BMI 操作のための屋外脳波個人認証, *知能と情報*, Vol.26, No.2, pp.606-616 (2014).
- [17] Ishikawa, Y., Yoshida, C., Takata, M. and Joe, K.: Validation of EEG Personal Authentication with Multi-channels and Multi-tasks, *International Conference on Parallel and Distributed Processing Techniques and Applications*, Vol.2, pp.182-188 (2014).
- [18] Ishikawa, Y., Yoshida, C., Takata, M., Kamo, H. and Joe, K.: A Personal Classification Method Using Spatial Information of Multi-channel EEG, *International Conference on Parallel and Distributed Processing Techniques and Applications*, Vol.1, pp.229-235 (2015).
- [19] Ishikawa, Y., Nishibata, K., Takata, M., Kamo, H. and Joe, K.: Biometric Authentication based on Multi-feature Combination using EEG, *International Conference on Parallel and Distributed Processing Techniques and Applications*, Accepted.
- [20] Jasper, H.H.: The ten twenty electrode system of the international federation, *Electroencephalography and clinical neurophysiology*, 10, pp.371-375 (1958).




高田 雅美 (正会員)

1977年生。2004年奈良女子大学大学院人間文化研究科複合領域科学専攻修了。博士(理学)を同大学より取得。2004年独立行政法人JST 戦略的創造研究推進事業において、京都大学大学院情報科学研究科にて委嘱研究員。2006年奈良女子大学大学院人間文化研究科助手。2007年同大学同研究科助教。2013年同理学部講師, 2014年同大学生生活環境学部講師。数値計算ライブラリの開発, 分散メモリ環境を対象とする並列プログラムの開発に関する研究に従事。



城 和貴 (正会員)

大阪大学理学部数学科卒業。日本DEC, ATR 視聴覚研究所(日本DECより出向), (株)クボタ・コンピュータ事業推進室で勤務の後, 1993年奈良先端科学技術大学院大学情報科学研究科博士前期課程入学, 1996年同研究科後期課程修了, 同年同研究科助手。1997年和歌山大学システム工学部講師, 1998年同助教授。1999年奈良女子大学理学部教授, 2014年同生活環境学部教授, 現在に至る, 博士(工学博士)。情報処理学会論文誌数理モデル化と応用副編集委員長。



石川 由羽 (学生会員)

2014年奈良女子大学大学院人間文化研究科博士前期課程情報科学専攻修了(理学修士), 同年同大学院同研究科博士後期課程複合現象科学専攻入学, 2016年日本学術振興会特別研究員DC2, 現在に至る。パターン認識に関する研究に従事。



西畑 かおり

2016年奈良女子大学理学部情報科学科卒業, 同年同大学院人間文化研究科博士前期課程情報科学専攻入学, 現在に至る。認証技術に関する研究に従事。