

多チャンネル脳波の空間情報を利用した個人分類手法

石川由羽[†] 吉田智奈美[†] 高田雅美[†] 鴨浩靖[†] 城和貴[†]

様々な生体情報を使用した生体認証の研究が多くの研究者によって行われている。我々は生体情報の中でも脳波に着目し、個人認証として使用可能な特徴量の抽出を研究する。また、近年脳波計の進歩も著しく、多チャンネル脳波計を用いて比較的容易に複数個所の脳波計測が行える。そこで、本稿では、脳波の特徴量に、多チャンネル脳波計から得た電極間の相互相関を使用する手法を提案する。提案手法に関する詳細な検証を行うことで、電極間相互相関の個人認証の特徴量としての可能性について検討する。

A Personal Classification Method Using Spatial Information of Multi-channel EEG

Yu Ishikawa[†] Chinami Yoshida[†] Masami Takata[†] Hiroyasu Kamo[†] Kazuki Joe[†]

Biometric authentication using various biological information is studied by many researchers. We study a feature extraction method available for personal authentication by focusing on EEG in the biological information. In addition, since electroencephalograph technology has advanced significantly in recent years, multi-channel EEG is possible to be relatively easily measured. Therefore, in this paper, as EEG features, we propose a method using a cross-correlation between electrodes obtained from the multi-channel electroencephalograph. By detailed validations about the proposed method, we evaluate the possibility of the cross-correlation between electrodes as features for the personal authentication.

1. はじめに

近年、不正アクセスを防止するための認証技術として、生体情報を使用するバイオメトリック認証の研究が盛んに行われている[1]。生体情報の中でも、脳波は、大脳皮質にある神経細胞の活動が検出された体内情報であり、脳波計を装着しないと取得できないため、指紋や声紋などの生体情報よりも秘匿性に優れている。従来の研究では、特徴抽出に自己回帰モデルやニューラルネットを使用する手法が提案されているが、多大な演算量がシステム負荷を増大させている。そのため、演算量の少ない特徴量の抽出が求められる。また、近年脳波計の発展も著しく、個人が日常生活で使用可能なレベルにまで進歩しているため、容易に多チャンネルの脳波を計測できる。多チャンネル脳波計は単一チャンネル脳波計では得られない空間的な情報が得られる。この特徴量を用いることで、少ない演算量での特徴抽出を目指す。以上の点から、本稿では、個人認証の特徴量として、多チャンネル脳波から得られる空間的な情報の利用可能性について検証を行う。個人認証を行う際、課題となるのが、認証に有効な特徴量の抽出と判定に使用する閾値の設定である。本稿では、1つ目の課題である脳波認証に有効な特徴量の抽出に焦点を当てるため、個人認証ではなく個人分類とし、閾値の設定については言及しない。

2. 個人分類手法の提案

脳波の個人分類に使用する特徴量として、電極間の相互

相関係数を使用した5種類(特徴量1-5)を提案する。

1. 計測データの電極間相互相関係数
2. 前処理後の計測データの電極間相互相関係数
3. 前処理後の計測データの時間ごとの電極間相互相関係数
4. 周波数解析後の電極間相互相関係数
5. 時間周波数解析後の電極間相互相関係数

特徴量1では、計測後のオリジナルデータの電極間相互相関係数を特徴量として使用する。特徴量2-3では、計測後のオリジナルデータに前処理を行う。前処理としてバンドパスフィルタを使用する。計測脳波にはアーチファクトが含まれるため、脳波を含まないとされる低周波数帯域と高周波数帯域の周波数を除去し、波形を再構成する。特徴量2では、再構成後のデータから特徴量1と同様に電極間相互相関係数を求め、これを特徴量とする。アーチファクトが除去されているため、脳波周波数帯域のみの相互相関を使用できる。特徴量3では、再構成後のデータに窓関数を用いて信号を切り出し、それぞれの電極間相互相関係数を求める。これにより、時間変化を考慮した特徴量を算出する。特徴量4-5では、周波数解析後の電極間相互相関係数を求める。周波数解析には高速フーリエ変換(FFT)を適用する。FFT後のデータから脳波周波数帯域のみを切り取り使用する。この処理は、前述の前処理と同様、アーチファクト除去のためである。特徴量4ではFFT後のデータの電極間相互相関係数を特徴量とする。特徴量5では、オリジナルデータに窓関数を用いて信号を切り出した後、それぞれの電極間相互相関係数を求める。これにより、特徴量3と同様、時間変化を考慮することが可能である。

[†]奈良女子大学
Nara Women's University




Figure 1 電極配置図

最後に、抽出された特徴量を元にサポートベクターマシン (SVM) を使用して個人分類を行う。各特徴量が脳波個人認証に適用可能であるか交差検定を用いて評価する。

3. 実験

3.1 データ計測

本稿では多チャンネル脳波計として BioSemi を使用して計測を行う。サンプリング周波数 2048Hz、電極数 16 チャンネルで計測を行う。電極配置は国際 10-20 法に従い、Figure 1 のように配置する。被験者は健康な 20 代女性 26 名である。1 回当たり 10 秒の計測を 1 人当たり 50 回行う。全データ数は 26 人 × 50 個の計 1300 個である。計測時は座位、安静状態で行う。SVM の k-交差検定では k=5,3,2 とする。(教師データ数, テストデータ数) は、それぞれ、k=5 の場合 (1040, 260), k=3 の場合 (867, 433), k=2 の場合 (650, 650) である。教師データとテストデータはランダムに選択する。それぞれ k 回の平均を分類率の結果とする。結果は全てパーセンテージで表示する。

3.2 最適な特徴量の検証 (検証 1)

検証 1 は、2 章で説明した 5 つの特徴量 (特徴量 1-5) と、既存研究 [2] [3] の特徴量である周波数解析を利用した 2 種類の特徴量 (特徴量 6-7) を比較する。

6. 周波数解析後のデータ

7. 時間周波数解析後のデータ

提案手法の周波数解析と前処理のバンドパスフィルタでは使用周波数の範囲を 4-40Hz とする。これは一般的に脳波解析に使用される脳波周波数帯域である。

検証 1 の結果を Table 1 に示す。各特徴量を使用した時の k=5, 3, 2 の交差検定の分類成功率を表示する。まず、この結果から、特徴量 1 の分類率が 30% 台であり、その他の特徴量と比較して著しく低下していることがわかる。これは、その他の特徴量が 4-40Hz の周波数帯域のみを使用することで、ノイズ除去が行われているためである。以上のことから、周波数解析若しくはバンドパスフィルタによるノイズ除去が必要であるといえる。次に、提案手法である特徴量 1 から特徴量 5 に着目する。特徴量 1 は前述の通りノイズを多大に含むため、考察から除外する。その他の 4 つの特徴量の中では、特徴量 3 が唯一 90% 以上であり、最も分類率が良い。電極間の相互相関係数を特徴量として使用

Table 1 検証 1, 検証 2 の結果

検証	手法	k=5	k=3	k=2
検証 1	特徴量 1	35.5	32.9	31
	特徴量 2	80.1	78.2	74.3
	特徴量 3	94.3	93.3	88.9
	特徴量 4	82.2	78.8	75.1
	特徴量 5	77.9	76.1	71.8
	特徴量 6	92.3	91.4	89.8
	特徴量 7	96.4	95.7	93.5
検証 2	特徴量 8	98.3	97.9	96.9

する場合、パワースペクトルよりも時系列データが個人差を有しているといえる。ただし、窓関数を使用して、時間変化を考慮すべきである。既存の手法である特徴量 6 と特徴量 7 は、どちらも 90% 以上の分類率であるが、時間による変化を特徴量として考慮した特徴量 7 の方が高い分類率を得た。全ての手法の中で 90% 以上の分類率を得たのは、高い方から順に特徴量 3, 特徴量 6, 特徴量 7 である。特徴量 3 は特徴量 7 より分類率は少し劣るものの、非常に高い分類率である。以上より、電極間相互相関係数を使用した特徴量は、個人認証の特徴量として有効であるといえる。

3.3 新たな特徴量の提案と検証 (検証 2)

検証 1 の結果から、特徴量 3 と特徴量 7 の分類率が良いことがわかる。そこで、特徴量 3 と特徴量 7 の 2 種類を使用する特徴量を特徴量 8 とする。まず、計測データにバンドパスフィルタを使用してノイズ除去を行う。その後、再構成後のデータに窓関数を用いて信号を切り出し、電極間相互相関係数を求めて、特徴量とする。同時に、計測データに STFT をかけて時間周波数解析を行い、時間ごとに各領域のパワースペクトル平均を求めて、特徴量とする。この 2 種類の特徴量を SVM に与えて特徴量 8 の評価をする。

検証結果は Table 1 の通りである。特徴量 1-7 のどの手法よりも分類率が良い結果となった。特に k=5 の場合 98% を超えており、エラー数は 260 個中 5 個未満である。

3.4 最適なパラメータの検証 (検証 3)

検証 3 では、3.3 節で提案し、最も分類率の高い結果を得た特徴量 8 のパラメータの検証を行う。パラメータとして以下の値を検証する。

- 最適な周波数帯域の検証 (検証 3a)
- 最適な窓の個数・大きさの検証 (検証 3b)
- 最適値を使用した場合の検証 (検証 3c)
- データ長と窓の個数の検証 (検証 3d)

検証 3a では、バンドパスフィルタと STFT に使用する周波数帯域を変更することで、分類率の比較を行う。検証 3b では窓の個数・大きさを変更する。窓の大きさが 0.5 秒未満の場合、周波数分解能が 4Hz となり、提案手法の平均スペクトルが算出できないため、窓の大きさは 0.5 秒を最小値とする。検証 3c では、検証 3a と検証 3b の結果から得ら




Figure 2 検証 3a の結果




Figure 3 検証 3b の結果

れた最適なパラメータを使用したときの個人分類率を算出する。検証 3d では、分類データ長による分類率の変化を特徴量 7 と比較する。計測データは 8 秒であるため、8 秒以下であり、かつデータ長が 2 のべき乗となる場合のデータ長を比較する。また、それぞれ窓の個数を変更した場合も比較する。使用する周波数帯域は、検証 3a で得られた最適な結果を採用する。

検証 3a の結果を Figure 2 に示す。各周波数帯域の $k=5,3,2$ の平均値と比較すると、 θ 波、 γ 波、 α 波、 β 波の順で分類率が高い。 θ 波のみを使用した場合、分類率は著しく低下する。これは、低周波数にはノイズが入りやすいためである。 θ 波を除く ($\alpha+\beta+\gamma$) を使用した場合、全周波数帯域を使用した (all) と比較しても $k=5,2$ ではより良い結果が得られている。このことから、最適な周波数帯域は、8-40Hz とする。次に、検証 3b の結果が Figure 3 である。窓の個数・大きさが (8, 1) の場合、平均分類率は 98.3 となり最も高い分類率が得られる。(1, 8) の場合は、窓の数が 1 つであり、特徴量が少なく分類率が低くなったと考えられる。以上より、(8, 1) を最適な窓の数・大きさとする。検証 3c では、検証 3a と検証 3b から得た最適なパラメータとして、周波数帯域は 8-40Hz、窓の数・大きさは (8, 1) を使用する。これらを用いて分類を行った結果、 $k=5,3,2$ の分類率は、それぞれ 98.6, 98.3, 98.2 であった。 $k=5$ の場合、これまでで最も良い分類率が得られる。検証 3d の結果は Table 2 の通りである。今回は 5-交差検定の結果のみ表示する。全ての場合において、特徴量 8 は特徴量 7 より分

Table 2 検証 3d の結果

データ長 (秒)	窓	特徴量 8	特徴量 7	差分
8	(1,8)	95.2	93.6	1.6
	(2,4)	95.8	95.3	0.5
	(4,2)	98.2	96.5	1.7
	(8,1)	98.4	96.9	1.5
	(16,0.5)	98.3	96.4	1.9
4	(1,4)	92.4	92.1	0.3
	(2,2)	93.8	93.6	0.2
	(4,1)	97.1	93.9	3.2
	(8,0.5)	96.8	93.4	3.4
2	(1,2)	92.2	88.5	3.7
	(2,1)	91	89.2	1.8
	(4,0.5)	93	87.8	5.2
1	(1,1)	86	81.5	4.5
	(2,0.5)	84.5	80.6	3.9

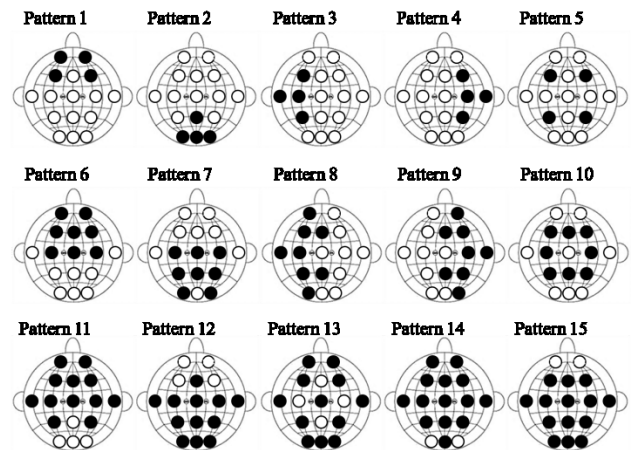


Figure 4 電極配置パターンの配置図

類率が高い。また、データ長が長くなるほど、分類結果は向上する。データ長 2 秒 (4, 0.5) の特徴量 8 の結果を除いて、窓の大きさが 1 秒の場合の分類率が最も良い。これより、窓の個数よりも大きさが重要である。次に、特徴量 8 と特徴量 7 の差分を比較すると、データ長が短くなるにつれて、差分が広がる傾向にある。つまり、特徴量 8 は少ないデータ数でも高い分類率得られる。

3.5 電極位置と組み合わせに関する検証 (検証 4)

検証 1-3 では電極数を 16 チャンネルに固定して検証したが、検証 4 では、個人分類に有効な電極数・電極配置の検証として、以下の検証を行う。

- 電極の組み合わせの検証 (検証 4a)
- 電極数と配置パターンの検証 (検証 4b)

パラメータは、これまでの検証で一番良い分類率を得た検証 3c と同じものを使用する。データ長は 8 秒、周波数帯域は 8-40Hz、窓の個数・大きさは (8, 1) である。この条件で 5-交差検定を行う。検証 4a では、2 チャンネルの電極を

Table 3 検証 4a の結果

ch	Fp2	F4	Fz	F3	T7	C3	Cz	C4	T8	P4	Pz	P3	O1	Oz	O2
Fp1	58	68	71	66	68	67	69	72	70	78	69	79	84	83	84
Fp2		68	70	67	67	65	68	69	68	78	70	82	84	82	83
F4			69	68	74	70	70	74	73	82	71	82	87	86	86
Fz				70	78	74	71	78	77	82	71	85	89	87	88
F3					74	71	71	74	73	82	74	83	87	88	88
T7					70	72	77	72	83	75	82	85	85	85	86
C3							69	75	70	84	77	84	88	87	87
Cz								73	71	82	71	83	86	86	86
C4				Top 10%					74	82	74	84	88	87	86
T8									81	72	82	83	84	85	85
P4				Top 20%						76	86	88	88	86	86
Pz											77	85	82	83	83
P3				Top 30%									87	86	86
O1														83	86
Oz															83

使用した場合の分類率を算出し、個人認証に有効な電極の組み合わせを検証する。16チャンネル全てを使用した場合、2チャンネルの組み合わせは120通りである。その中で分類率の高い組み合わせを検証する。検証4bでは、使用する電極数と電極配置パターンを変化させた場合の分類率について検証する。電極配置パターンの配置図をFigure 4に示す。配置図内の黒丸が使用電極である。

検証4aの結果をTable 3に示す。120通りの平均分類率は78.1であり、電極数が2チャンネルでもある程度個人分類できる。最小値、最大値の分類率を得た組み合わせは、それぞれ(Fp1, Fp2)の57.8%、(Fz, O1)の89.1%である。使用電極により大きな分類率の違いがあることが明らかである。Fp1, Fp2は一番眼球に近い電極であり、眼球運動によるノイズの影響を最も受けやすい。そのため、個人分類には適さない電極である。FzとO1の組み合わせは2チャンネルで90%近い分類率を得ているため、認証において非常に有効な電極の組み合わせであることがわかる。次に、分類率が上位30%に当たる電極に着目すると、ほとんどの電極が後頭部であるO1, Oz, O2との組み合わせである。ただし、Fp2との組み合わせで上位に当たるものはない。上位20%に着目すると、Fp2に続き、Fp1, Fp2, T8, Pzを含む組み合わせは除外される。上位10%では、T7, Czが除外される。つまり、上位10%に含まれない電極は、前頭部(Fp1, Fp2)、側頭部(T7, T8)、中心部(Pz, Cz)である。特に、O1, Oz, O2との組み合わせはFz, F3の分類率が高く、全て上位10%に属している。この結果から、電極間の距離がある方が良く考えられる。この5つの電極を使用した場合、分類率は94.3%であった。検証4bの結果をTable 4に示す。電極数が4個、8個、12個、14個の各パターンの平均分類率は、それぞれ89.8, 96.2, 98.2, 98.4である。使用電極数が増すたびに上昇している。次に、配置パターンの前方と後方を比較すると、全ての電極数で後方の分類率が高い。使用電極数が増すほど、前後の分類率の差は減少する。前頭部周辺の電極には眼球運動によるアーチファクトが多くみられるため、バンドパスフィルタに

Table 4 検証 4b の結果

pattern	電極数	位置	k=5
1	4	前	81.3
2		後	91.8
3		左	92.3
4		右	90.9
5		中央	92.5
6	8	前	94.5
7		後	97.6
8		左	96.4
9		右	96.4
10		中央	96.2
11	12	前	98.3
12		後	98.4
13		中央	97.9
14	14	前	98.3
15		後	98.5

よるノイズ除去後であっても個人分類に影響を与えていると考えられる。そのため、ノイズの少ない後頭部での分類率が高い結果となったといえる。電極数が少ない場合、電極配置位置によって分類率が大きく左右される。

4. おわりに

本稿では、電極間の相互相関を特徴量として使用した個人分類手法の可能性について検証を行った。その結果、時間周波数解析を用いた分類手法よりも、電極間相互相関を組み合わせることで、より高精度な個人分類が可能となることがわかった。また、後頭部に位置する電極にはノイズが少ないため高い分類率が得られた。より少ない電極数で認証を行いたい場合、前頭部よりも後頭部の電極を使用すると良い。しかし、今回検証に使用したデータは、比較的計測間隔が近いものであった。データ計測時の間隔を変動させることで、分類率にも変化がでると考えられる。今後は、データ計測の間隔を変化させることで、脳波に出る影響を検証すべきである。これをもとに、計測間隔に影響されない個人認証に利用可能な特徴量の抽出を目指す。

参考文献

- 1) 小松尚久, 内田薫, 池野修一, 坂野鋭, バイオメトリクスのおはなし, 日本規格協会, 2008.
- 2) I. Nakanishi, H. Fukuda and S. Li, Biometric Verification Using Brain Waves toward On-Demand User Management Systems Performance differences between divided regions in $\alpha - \beta$ wave band, Proc. of the 6th International Conference on Security of Information and Networks, 2013, pp. 131-135.
- 3) Y. Ishikawa, C. Yoshida, M. Takata and K. Joe, Validation of EEG Personal Authentication with Multi-channels and Multi-tasks, vol. 2, In Proceedings of 2014 International Conference on Parallel and Distributed Processing Techniques and Applications, 2014, pp. 182-188.