

生体情報計測による感性可視化のための 機械学習的クラスタリング手法の開発

富山県立大学工学部電子・情報工学科 指導教員：奥原浩之
1415004 麻生 到

1 はじめに

バイオメトリック認証とは、生体情報として指紋、顔、血管パターン、虹彩などの身体的特徴、あるいは筆跡、音声などの行動的特徴を用いて個人認証を行う技術である [1]。

特に、指紋は認証性能が高く、デバイスのログイン手法として、すでに iPhone などでも普及されている。しかし、認証に必要となる生体情報が常に外部にさらされているため、生体情報を入手されやすく、実際に指紋認証を偽装した事件も起きている。

一方、脳波を生体情報として利用したバイオメトリック認証は偽装される危険性が非常に小さいと考える。脳波は個人により違った特徴を示すが、同一人物でもイメージするものによって変化する。この特徴を利用することで、生体情報であっても、イメージするものを変化させることで、生体情報を変化させることが可能となる [2]。

従来の脳波を用いた個人認証の研究では、電極配置が 16 チャンネルすべてを使用したが行われている。

しかし、実際には 16 チャンネルを用いた脳波の個人認証は脳波を計測する上で計測される人とコストの面においても負担が大きく、あまり実用的ではないと考えている。

そこで本研究では、実用性の高い脳波を用いた個人認証システムの検証を行う。16 チャンネルを使用した認証精度からなるべく精度を下げず、チャンネル数を減らし認証を行えるシステムを作成することで脳波の個人認証に効果的な測定部位やチャンネル数を提案する。

本研究によって提案された必要最低限の測定箇所を用いることで、脳波個人認証専用やコストのかからない認証デバイスのシステム作成を目指す。

2 従来研究

2.1 実験概要

単チャンネルと 16 チャンネルの多チャンネルを用いた認証システムの検証を行っていた。

また、認証システムを作成するにあたり被験者には深呼吸 (breathing)、指を上下に動かすイメージ (finger)、好きなスポーツをするイメージ (sport)、好きな歌を歌うイメージ (song)、機械音を聞き、その後一点を注視 (audio)、赤・緑・青・黄から一色選び、表示された画像の中に選択した色が含まれている個数をカウント (color)、好きなパス思考をイメージ (pass) のように 7 つのタスクを行ったときの脳波を計測していた。

2.2 特徴抽出

θ 波から γ 波までの 4-40Hz の脳波を使用した。

3Hz 以下の脳波には EOG (眼球運動) が多く含まれているため、解析では使用しない。 θ 波帯域を 2 領域、 α 波帯域を 3 領域、 β 波帯域を 5 領域、 γ 波帯域を 3 領域、計 13 領域に分割し、データごとに各領域のパワースペクトル平均を求めて、これを特徴量として利用した。

3 特徴抽出とクラスタリング

3.1 特徴量抽出に用いる手法

本研究で用いる特徴抽出のための解析手法を紹介する。

3.1.1 主成分分析

主成分分析とは、互いに相関のある変数について観測されたデータの持つ情報をできるだけ失うことなく、もとの変数の線形結合で表されるより少数個の変数に要約するための手法である [3]。

以下にアルゴリズムを示す。まず、各個体の特徴を捉える D 個の変数を、 $x = (x_1, x_2, \dots, x_D)^T$ とする。この D 個の変数に関して観測された N 個の D 次元データ x_1, x_2, \dots, x_N に対して、次の標本分散共分散行列を求める。

$$S = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T \quad (1)$$

ただし、 \bar{x} は D 次元標本平均ベクトルである。次に、 D 個の変数の線形結合で表される射影軸

$$y = w_1 x_1 + w_2 x_2 + \dots + w_D x_D = w^T S w \quad (2)$$

上へ N 個の D 次元データを射影し、1 次元データ $y_i = w^T x_i$ ($i = 1, 2, \dots, N$) に変換する。ただし w は、係数ベクトル $w = (w_1, w_2, \dots, w_D)^T$ である。主成分軸を求める問題は、この係数ベクトル w を求めることに帰着される。射影軸上の平均と分散は、

$$\bar{y} = w^T \bar{x}, s^2 = w^T S w \quad (3)$$

と表される。データを、 $y = w^T x$ 軸上に射影したときの分散が最大になる係数ベクトル w の決定問題は、 $s^2 = w^T S w$ の最大化の問題に帰着される。 w に制約がなければ、 s^2 はいくらでも大きくなるので、 $w^T w = 1$ という制約を付けて最大化する。これは、ラグランジュの未定乗数法を用いて解くことができ、 λ をラグランジュ未定乗数とすると、次の標本分散共分散行列 S の固有値問題となる。

$$S w = \lambda w \quad (4)$$

上の式より S の固有方程式を解き、解である D 個の固有値を大きさの順に

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_D \geq 0 \quad (5)$$

とし、それぞれに対応する固有ベクトルを w_1, w_2, \dots, w_D とする。これにより、 D 個の主成分は、

$$y_1 = w_1^T x \quad (6)$$

3.1.2 独立成分分析

多次元信号を独立な成分に分離することが独立成分分析の目的である。

以下にアルゴリズムを示す。

統計的に独立な N 個の信号源から発せられた信号 $s(t) = [s_1(t), s_2(t), \dots, s_N(t)]$ があり、これらの信号が A のような正則行列によって信号 $x(t) = [x_1(t), x_2(t)]$ が合成された場合を考える。時間遅れを考えなければ、

$$x(t) = A s(t) \quad (7)$$

と表すことができる。信号 $x(t)$ を原信号 $s(t)$ に分離するためには、 A の逆行列を求めるればよいことがわかる。実際には、行列 A は未知であるため

$$u(t) = W x(t) \quad (8)$$

を考え、 $u(t)$ の各成分が独立となるような行列 W を求めることになる。 $u(t)$ の独立性は Kullback-Leibler 情報量によって表すことができる。ICA では $u(t)$ の各成分間の相互情報量を見ながら、それを最小するように学習していき、 W の値を更新していく [4]。

3.2 クラスタリングに用いる手法

本研究のクラスタリングに用いる解析手法を紹介する。3.2.1 SVM

サポートベクターマシンはカーネル関数を用いて線形分離可能な高次元空間で線形的なアプローチで学習を行うアルゴリズムである。 x を入力ベクトル、 $y(x)$ は出力 (分類問題のときはクラスのラベル、回帰問題のときは数値)、 $\phi(x)$ を特徴空間変換関数とすると、通常の線形回帰、線形判別の問題では

$$y(x) = w^T \phi(x) + b \quad (9)$$

といった線形モデルを用いる。入力ベクトル x と教師信号の組からパラメータ w, b を学習するのが目的となる。分類境界と訓練データの間の

最短の距離のことを マージンと言い、マージンの最大化する分類境界を探す。超平面 $y(\mathbf{x}) = 0$ から点 \mathbf{x} までの距離は $|y(\mathbf{x})|/\|\mathbf{w}\|$ で与えられるため、

$$\arg \max_{\mathbf{w}, b} \frac{1}{\|\mathbf{w}\|} \min_n [t_n(\mathbf{w}^T \phi(\mathbf{x}) + b)] \quad (10)$$

のように最適化問題を定義することができ、この問題を解くことでマージンを最大化する \mathbf{w}, b を求めることができる。ここで \mathbf{w} は n に依存せず、境界に最も近い点においては $t_n(\mathbf{w}^T \phi(\mathbf{x}) + b) = 1$ と示すことが可能で、

$$\arg \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (11)$$

$$\text{subject to } t_n(\mathbf{w}^T \phi(\mathbf{x}) + b) \geq 1, n = 1, \dots, N \quad (12)$$

といった最適化問題を解くことでマージンを最大化する \mathbf{w}, b を求めることができる [5].

4 脳波個人認証の精度の向上のための機械学習

4.1 被験者ごとの脳波個人認証システムの提案

実験に用いる画像は、それぞれの被験者だけが認識のある画像 (例えば、富山県立大学の学生が被験者の場合は大学の外装の画像や富山県立大学と書かれた文字の画像) を使用する。

被験者に見せる画像の認識の差が脳波にも影響し、より認識率が上がると考えている。

画像の提示方法や提示時間は検討中。

4.2 解析手順

前処理では、瞬きによって脳波の振幅のずれを防ぐために眼電アーチファクトを独立成分分析により除去し、 Θ , α , β 波を用いるため、バンドパス処理を行う。

特徴抽出では、特微量として、パワースペクトルの平均を用いるため FFT によりスペクトル解析を行い、判別で SVM を用いる際に高次元のデータを学習は機能を低下させることが考えられるため、主成分分析による次元削減を行う。

判別では、ソフトマージン SVM やハードマージン SVM、非線形 SVM を試して判別する。試してうまくいかない場合は、データを分割し、複数の判別機による重み付き多数決で分類を行う。

5 数値実験結果ならびに考察

5.1 チャンネル数と測定部位の検討

作成した脳個人認証システムを用いて、チャンネル数と測定部位の検討を行う。

選定方法は、16 チャンネルそれぞれ 1ヶ所だけで測定した認識率を求め、認識率の高い部位を優先的に採用していき、選定を行おうと考えている。

5.2 機械学習による脳波個人認証の実用性向上の有意差検定

選定したチャンネル数と測定部位による認証精度が 16 チャンネルを用いた認証精度とあまり変化のない結果となれば、作成した認証システムの有効性を示すことができる。

6 まとめと今後の課題

6.1 随伴陰性変動 (CNV) 事象関連電位の一つで、予測や期待、注意などの心理学的生理学的要因を反映して、その振幅や面積が変化することが知られている [6].

予告刺激—命令刺激—運動反応からなる反応時間課題を用意し、予告刺激提示から 2 秒間の脳波に CNV が現れる。

6.2 今後の方針 複数チャンネルの加算平均した随伴陰性変動を利用することで、脳波個人認証にかかる時間を短縮することを目的とする。

また、本研究では反応時間課題としてじゃんけんのスライドを用意する。予告刺激画像には、「勝ち」、「負け」、「あいこ」にする命令、命令刺激は、「グー」、「チョキ」、「パー」の画像を使用する。

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] 石川由羽, 吉田智奈美, 高田雅美, 城和貴, 脳波個人認証のための特徴抽出, 情報処理学会研究報告, 2014
- [3] 小野原 拓, 確率的主成分分析と次元圧縮,

[4] 池田 思朗, 独立成分解析, 2004

[5] 有吉 智貴, 個人性を考慮した EEG 感情分類システムの構築, 2014

[6] 松本清, 佐久間春夫, 事象関連電位からみた競争ストレスの影響について