

# 信号処理における 機械学習的クラスタリング手法の開発\*

\*Note: Sub-titles are not captured in Xplore and should not be used

1<sup>st</sup> Given Name Surname  
dept. name of organization (of Aff.)  
name of organization (of Aff.)  
City, Country  
email address

2<sup>nd</sup> Given Name Surname  
dept. name of organization (of Aff.)  
name of organization (of Aff.)  
City, Country  
email address

3<sup>rd</sup> Given Name Surname  
dept. name of organization (of Aff.)  
name of organization (of Aff.)  
City, Country  
email address

4<sup>th</sup> Given Name Surname  
dept. name of organization (of Aff.)  
name of organization (of Aff.)  
City, Country  
email address

5<sup>th</sup> Given Name Surname  
dept. name of organization (of Aff.)  
name of organization (of Aff.)  
City, Country  
email address

6<sup>th</sup> Given Name Surname  
dept. name of organization (of Aff.)  
name of organization (of Aff.)  
City, Country  
email address

**Abstract**—This document is a model and instructions for L<sup>A</sup>T<sub>E</sub>X. This and the IEEEtran.cls file define the components of your paper [title, text, heads, etc.]. \*CRITICAL: Do Not Use Symbols, Special Characters, Footnotes, or Math in Paper Title or Abstract.

**Index Terms**—component, formatting, style, styling, insert

## I. はじめに

現代社会には様々な信号が存在しており、機械学習を用いてその信号の中の隠れた因子や成分を見つけ出し分析する技術は多くのことに応用することができ、重要な技術といえる。

従来、音声に含まれる感情と音声の特徴との関係を見つけて、その音声から知覚される感情とを対応づける研究がある。この研究では、統計的な手法と主観評価値を用いて、主成分分析によって声の高さや抑揚といった物理的基底と因子分析によって心理的基底をそれぞれ音声データから獲得している。そして、獲得した基底を用いて重回帰分析を施すことにより、音声の物理量と感情との間の対応情報を得ている [1]。

また、医療分野では血小板の時系列データを用いて、B 型肝炎の患者と治療のためにインターフェロンを投与した C 型肝炎の患者、インターフェロンを投与していない C 型肝炎の患者を分類している。この研究ではクラスタリングの手法としては決定木を用いており、用いる特徴量は時系列データに対する各特徴パターンとの相違度である [2]。

また、ラジオ体操第一の 10 種類の動作を 3 次元時系列座標データとして取得し、データ間の類似度を求める Dynamic Time Warping(DTW) を拡張した連続 DP を用いてクラスタリングを行っている。この研究では、それぞれの動作を複数の学習データセットから多数決によってアルゴリズムを

統合する Bagging で再調整して最終的な分類結果を得ている [3]。

さらに、楽器の音声データから楽器の種類をクラスタリングを行う研究もある。この研究では、学習データである楽器音データは高音が重要な特徴量となることに着目し、平均を基本周波数の関数としている多次元正規分布を使用している。この多次元分布が F0 依存多次元分布であり、この多次元分布を用いて音色の高さと変化の特徴量を作成している。F0 依存多次元分布は実験では、19 種類の楽器を主成分分析と線形判別分析による次元削減を行い、判別器としてベイズ決定法則を用いてクラスタリングを行う [4]。

測定部位を頭頂部のみを使用して脳波データを用いてジャンケン動作のクラスタリングを行う研究がある。この研究では、周波数解析で 4Hz 帯と 8Hz 帯のパワースペクトルを特徴量としており、主成分分析で次元削減を行いマハラノビス距離関数でそれぞれのジャンケン動作を分類し、精度は 37.5 % といった結果となっている。[5]

従来の脳波データを用いたジャンケン動作分類の研究では、使用する測定部位の数が 1 つしかないことと周波数帯の範囲が狭いことが問題として挙げられる。また、運動準備電位を利用していることから加算平均が必要なためリアルタイム解析が不可能となり、実用性があまり高くないと考えられる。

よって、本研究では 8 チャンネルの測定部位を使用し、周波数帯の範囲を広げて多くの情報から次元削減を行い有用な情報を取得する。また、次元削減では主成分分析と線形判別分析の組み合わせを検討することでより分類しやすい特徴量に変え機械学習であるランダムフォレストによる分類を行うことで分類精度の向上を目指す。

以上の処理を適用して使用者の脳波データからジャンケン動作を分類して、分類結果をもとに使用者が出したジャンケンの手に勝つシステムを作成する。実験では作成したシステムを用いて分類精度を求める。さらに、作成システムは背

Identify applicable funding agency here. If none, delete this.




Fig. 1. 環境の変化への対応

景脳波を使用していることから準リアルタイム処理が可能であることからすぐにジャンケン動作の脳波データを分析・分類をすることができる。そのため、従来の研究より実用性が高いシステム作成する。

## 2 処理の流れ

### 2.1 環境の変化への対応

複数の異なる環境で取得した学習データをそれぞれ用意する。図 1 のように用意した複数の学習データと取得したデータとの相関を求めてどの環境が取得したデータの環境と近いかを選定する。

選定基準には相関係数を用いる。取得データと相関係数の最も高い学習データを用いてクラスタリングを行っていく。

### 2.1 前処理

本研究では、まず取得したデータに対して窓関数をかける。ここでは、Hamming 窓を用いる。窓関数をかけた後、高速フーリエ変換を用いてパワースペクトル  $PS$  を求める。 $PS$  は高速フーリエ変換によって得ることができる実部  $Re$  と虚部  $Im$  を用いて以下の式から求める。

$$PS = \sqrt{Re^2 + Im^2} \quad (1)$$

そして、3-50Hz のパワースペクトルを分類のための特徴量として用いる。

### 2.2 分類

本研究では、ベイズ理論を用いて高次元ベクトルが従う確率分布を学習することによって分類を行う。特徴量であるパワースペクトルはガウス分布であると仮定のもとガウス分布のパラメータである平均ベクトルと分散共分散行列を推定することで、各クラスの確率分布を推定できるので分類が可能となる。

まず、 $M$  クラスの訓練データを用いて以下の式が与えられる。

$$\bar{x}_k = \frac{1}{N_k} \sum_{n=1}^N x_n \quad (2)$$

$$S_k = \frac{1}{N_k} \sum_{n=1}^N (x_n - \bar{x}_k)(x_n - \bar{x}_k)^T \quad (3)$$

$N_k$  は各クラスの要素数であり、 $\bar{x}_k$  は各クラスの訓練データの平均ベクトルと  $S_k$  は各クラスの分散共分散行列である。

そして、高次元ベクトルが従う確率分布は以下の式で与えられる。

$$q(\mu_k, \Lambda_k) = N(\mu_k | m_k, (\beta_k \Lambda_k)^{-1}) W(\Lambda_k | W_k, \nu_k) \quad (4)$$

ここで、以下のようにパラメータを定義した。

$$\beta_k = \beta_0 + N_k \quad (5)$$

$$m_k = \frac{1}{\beta_k} (\beta_0 m_0 + N_k \bar{x}_k) \quad (6)$$

$$W_0 = \alpha E \quad (7)$$

$$W_k^{-1} = W_0^{-1} + N_k S_k + \frac{\beta_0 N_k}{\beta_0 + N_k} (x_n - \bar{x}_n)(x_n - \bar{x}_n)^T \quad (8)$$

$$\nu_k = \nu_0 + N_k \quad (9)$$

$E$  は以下のような単位行列で表される。 $D$  は観測データの次元数である。

$$\left\{ \underbrace{\begin{pmatrix} 1 & 0 & 0 & \cdots & 0 \\ 0 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 1 & \cdots & 0 \\ \vdots & & & \ddots & \\ 0 & 0 & 0 & \cdots & 1 \end{pmatrix}}_{D \text{ 列}} \right\}_{D \text{ 行}}$$

ここで、新しく  $\widetilde{\Lambda}_k$  を導入する。

$$\ln \widetilde{\Lambda}_k = \sum_{i=1}^D \psi\left(\frac{\nu_k + 1 - i}{2}\right) + D \ln 2 + \ln |W_k| \quad (10)$$

$\psi(\cdot)$  はディガンマ関数を用いられている。以上のパラメータを各クラスの訓練データから求める。そして、求めた各クラスごとのパラメータから以下の近似式を導出する。

$$\ln r_{nk} \simeq \frac{1}{2} \ln \widetilde{\Lambda}_k - \left\{ -\frac{D}{2\beta_k} - \frac{\nu_k}{2} (y_n - m_k)^T W_k (y_n - m_k) \right\} \quad (11)$$

ここで、 $r_{nk}$  は負担率、 $y_n$  はテストデータである。負担率を用いてテストデータが各クラスに対する採択確率を求めて分類を行う。各クラスの負担率ベクトル  $\ln r_n$  を以下に示す。

$$\ln r_n = \{\ln r_{n1}, \ln r_{n2}, \dots, \ln r_{nM}\} \quad (12)$$

負担率ベクトル  $r_n$  の中の最大値を  $c$  とし、各要素で引く

$$\ln r_n - c = \{\ln r_{n1} - c, \ln r_{n2} - c, \dots, \ln r_{nM} - c\} \quad (13)$$

そして、ベクトルの要素を自然対数  $e$  のべき乗をとる

$$e^{(\ln r_n - c)} = \{e^{(\ln r_{n1} - c)}, e^{(\ln r_{n2} - c)}, \dots, e^{(\ln r_{nM} - c)}\} \quad (14)$$

ベクトル (14) の総和  $S_r$  を求め、各要素を総和  $S_r$  で割ることで採択確率のベクトル  $p$  を求める。

$$S_r = \sum_{k=1}^M e^{(\ln r_{nk} - c)} \quad (15)$$

$$p = \left\{ \frac{e^{(\ln r_{n1} - c)}}{S_r}, \frac{e^{(\ln r_{n2} - c)}}{S_r}, \dots, \frac{e^{(\ln r_{nM} - c)}}{S_r} \right\} \quad (16)$$

採択確率のベクトル  $p$  の中で最も大きい値をもつクラスにテストデータを分類する。

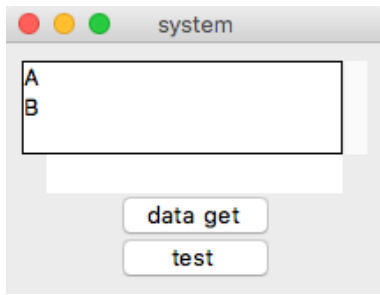


Fig. 2. GUI



Fig. 3. data get のスライドの流れ

## II. 作成システム

### A. システムの概要

脳波を利用してジャンケンで利用者に勝つシステムを作成する。また、このシステムは使用者の負担を小さくすることを前提としている。作成するシステムの GUI を図 3 に示す。

システムにジャンケンを使用したのは、実験で脳波から意思伝達の検証するためには実験前に特別な訓練を時間をかけて行う必要があることが多い。

しかし、ジャンケンは慣習活動であることから特別な訓練が必要がないことからジャンケンを採用した。

### B. data get

data get の項目では、学習データを取得する。利用者には図 2 ような流れで表示されるスライドを見てもらい 3・2 とカウントダウンされた後にランダムでグー・チョキ・パーのジャンケンスライドを 1 秒間表示する。その後に表示される 1 秒間の真っ白の画像が表示されている間に使用者はランダムに表示されたジャンケンスライドの手に勝つ手を出す。

### C. test

test 項目では、実際に data get 項目で取得した学習データを用いてジャンケンを行う。表示するスライドは図 2 の流れと同じスライドだが黒い画面の表示時の 1 秒前から 1 秒後のデータを未知のテストデータとして用いて黒い画面の表示後にその分析結果をグー・チョキ・パーの画像によって表示する。例として分析結果としてグーが表示された時のスライドを図 4 に示す。

## III. 評価実験

### A. 実験方法

本実験に使用する脳波データは、OpenBCI 製のヘッドセットである ULTRACORTEX MARK 4 と Cyton Board を用いて取得する。この脳波計の主な特徴を以下に示す。

- サンプリング周波数 250Hz
- 5-50Hz のバンドパス処理を行ったデータを送信
- 1-8 チャンネルのデータ以外にも角速度とタイムスタンプも計測可能



Fig. 4. data get のスライドの流れ




Fig. 5. 脳波計の装着の様子

- Wi-Fi と Bluetooth の 2 種類の無線通信方法が可能

OpenBCI 製の脳波計はドライタイプのウェアラブル脳波計であるため頭皮のある部位からでも計測可能といった特徴をもつ。

ウェットタイプのウェアラブル脳波計では接触インピーダンスを低下させるために導電性ジェルを必要とすることから使用者は使用後に洗髪する必要がある。そのため、ドライタイプのウェアラブル脳波計は使用者への負担が他のウェアラブル脳波計より小さい [6]。

しかし、デメリットとして抵抗インピーダンスを低下させていない分ノイズがのりやすい。

実際に脳波計を装着している様子を図 4 に示す。また、本実験で使用する 10-20 法に従った脳波の測定部位を図 5 に示す。

data get で取得した 60 個のデータセットを訓練データとして用いて実験を行う。被験者は 1 人で test 項目を行う回数は 40 回行った。

また、環境変動を考慮したシステムを作成するために、5 日間に渡ってデータを取得した。データを取得した期間は、2018 年 5 月 8 日から 2018 年 5 月 11 日、2018 年 5 月 14 日である。

### B. 環境変動について

環境の変動を確認するために、図 3 で示したスライドの流れの中の 3 と 2 が表示されている間の 2 秒間のデータに対して FFT で周波数解析を行った。5 日間のデータに対するそれぞれ 8 チャンネル毎のパワースペクトルのグラフを

a) 環境変動なしの分類: 環境変動を考慮していない場合では、訓練データとテストデータを取得する際に脳波計を外さずにつけたまま両方のデータを取得した。

2.2 で示した分類手法を用いて分類を行う。使用するパラメータの値を以下に示す。

- $\beta_0 = 0.1$
- $m_0 = 0$




Fig. 6. Fp1 と Fp2 の周波数解析のグラフ




Fig. 7. C3 と C4 の周波数解析のグラフ

- $\nu = 94$
- $D = 94$
- $M = 3$

本研究では、変動させるパラメータは  $\alpha$  のみであり、 $\alpha$  の値と精度の関係を図 6 に示す。

## REFERENCES

- [1] 森山 剛, 斎藤 英雄, 小沢 慎治, 音声における感情表言語と感情表現パラメータの対応づけ, 電子情報通信学会論文誌, Vol.J82-D No.4 pp.703-711, 1999
- [2] 杉村 博, 松本 一教, 時系列データベースにおける特徴パターンの抽出, <https://kaigi.org/jsai/webprogram/2011/pdf/507.pdf>, 2018.4.25
- [3] 大崎 竜太, 嶋田 光臣, 上原 邦昭, 速度に基づく切り出しとクラスタリングによる基本動作の抽出, 人工知能学会誌, 15 巻 5 号 (2000 年 9 月)
- [4] 北原 鉄朗, 後藤 真孝, 奥乃 博, 音高による音色変化に着目した楽器音の音源同定:F0 依存多次元正規分布に基づく識別手法, 情報処理学会論文誌, Vol.44 No.10, Oct.2003
- [5] 田中久弥, 長嶋裕二, 井出英人, 脳波の周波数解析による運動様式の判別に関する研究,T.IEE Japan, Vol. 118 - C, No11, 98
- [6] 成瀬 康, 横田 悠 右, ウェアラブル脳波計によるポータブルな脳波実験系の構築, 日本 神経回路学会誌 Vol. 23, No.3, 2016
- [7] 本多 慶大, 工藤 卓, Air Brain を利用した脳波 BCI システム, 30th Fuzzy System Symposium (Kochi, September 1-3, 2014)
- [8] 入戸野 宏, P300 応用 認知科学の立場から, 臨床神経生理学 41 巻 2 号
- [9] 松田 俊, 随伴陰性変動 (contingent negative variation: CNV) と有意味材料の記憶検索, Japanese Journal of Physiological Psychology and Psychophysiology Vol.1.1983,19-25.




Fig. 10. パラメータ  $\alpha$  と精度のグラフ




Fig. 8. P7 と P8 の周波数解析のグラフ




Fig. 9. O1 と O2 の周波数解析のグラフ