

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 st Given Name Surname <i>dept. name of organization (of Aff.)</i> <i>name of organization (of Aff.)</i> City, Country email address	2 nd Given Name Surname <i>dept. name of organization (of Aff.)</i> <i>name of organization (of Aff.)</i> City, Country email address	3 rd Given Name Surname <i>dept. name of organization (of Aff.)</i> <i>name of organization (of Aff.)</i> City, Country email address
4 th Given Name Surname <i>dept. name of organization (of Aff.)</i> <i>name of organization (of Aff.)</i> City, Country email address	5 th Given Name Surname <i>dept. name of organization (of Aff.)</i> <i>name of organization (of Aff.)</i> City, Country email address	6 th Given Name Surname <i>dept. name of organization (of Aff.)</i> <i>name of organization (of Aff.)</i> City, Country email address

Abstract—This document is a model and instructions for L^AT_EX. 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る。

従来では、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行われてきた。この研究では、統計的な手法を用い、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、医療分野において血小板(PLT)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]。

他には、動作を3次元時系列座標データをしてクラスタリングを行っている。ラジオ体操第一の10種類の動作をモーションキャプチャシステムで動作データとして記録し、データ間の類似度を求める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。

そして、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]。

楽器の音声データから楽器の種類をクラスタリングを用いている研究も行われている。音の高さによって音色の変化を関数として表現するF0依存多次元分布を利用して特徴量を作成している。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k-NN法とベイズ決定法則を用いてクラスタリングする[4]

以上のように、信号処理に用いられる技術は様々な分野の解析に用いることが可能ということがわかる。このように、信号処理は重要な技術だといえる。

本論文では、8つの複数コンポーネントから構成されている脳波データの分析を行うシステムを作成する。使用する脳波計はOpenBCI製の計測器を用いており、サンプリング周波数は250Hzである。

この脳波計はドライタイプのウェアラブル脳波計に分類される。このタイプの脳波計は頭皮がある部位からでも計測可能である。また、脳の測定部位は10/20法で定義されてい Fp1,Fp2,C3,C4,P7,P8,O1,O2を使用した。

作成するシステムでは、グー・チョキ・パーのジャンケン動作から発生する脳波を分析し未知のジャンケン動作のデータに対しての分類を試みる。

II. 処理の流れ

A. 前処理

従来の研究として、1秒間の脳波のデータを4分割し、Hanning窓をかけFFTでパワースペクトルを求める。そして、4-32Hz間の全体のパワースペクトルと4Hzと8Hzの周波数成分比を特徴量としている[5]。

しかし、この手法では4Hzと8Hzの周波数成分しか用いていないため効果的な情報を得られていない可能性がある。

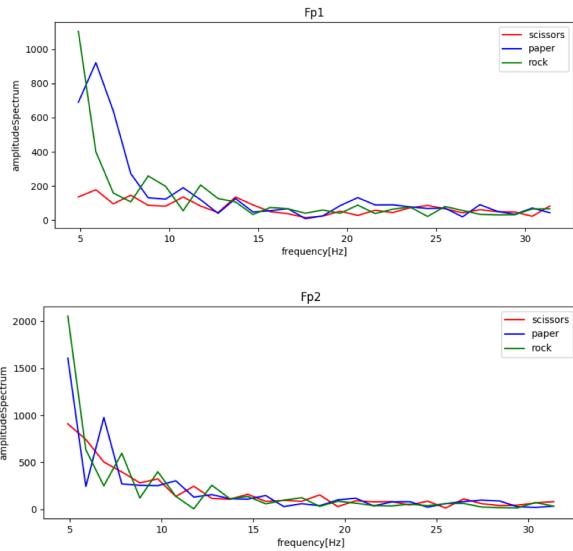


Fig. 1. Fp1 と Fp2 の周波数解析のグラフ

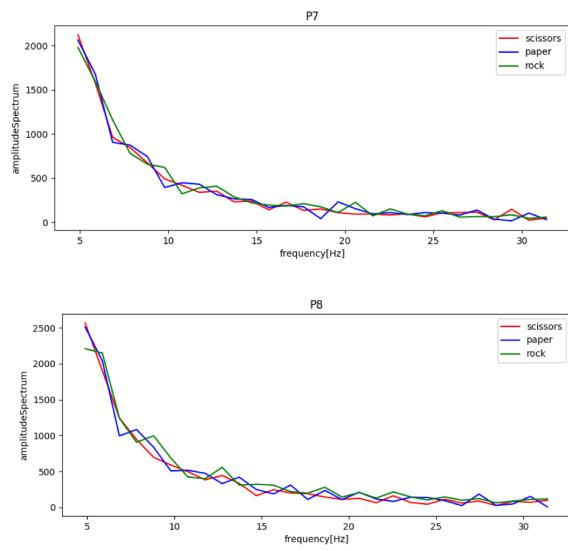


Fig. 3. P7 と P8 の周波数解析のグラフ

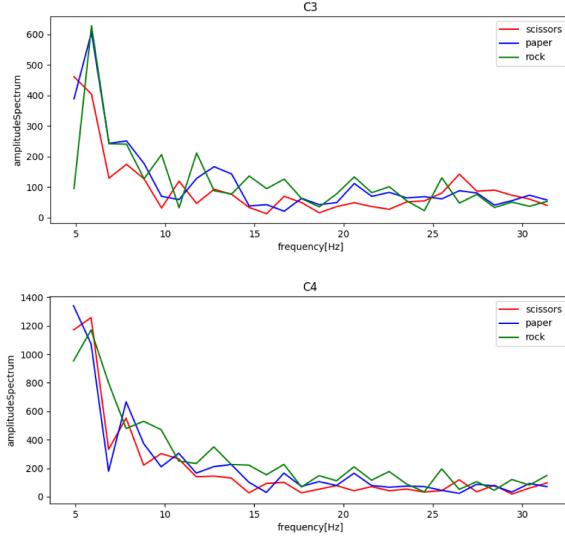


Fig. 2. C3 と C4 の周波数解析のグラフ

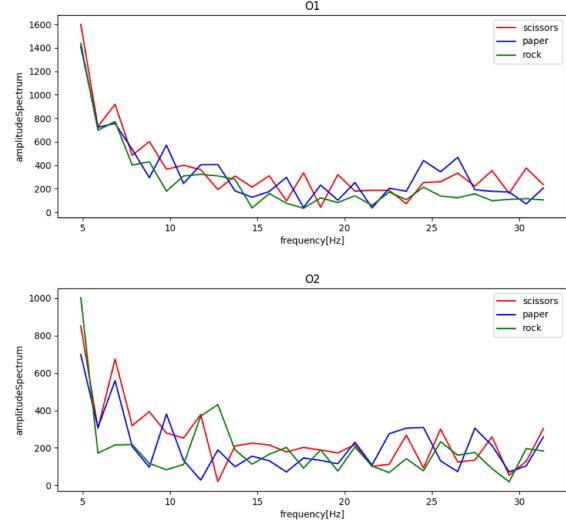


Fig. 4. O1 と O2 の周波数解析のグラフ

よって、脳波の分類において知られている α 波、 β 波、 θ 波を特徴量成分として用いる。本論文では、まず同様に1秒間のデータに対して時間で4分割し窓関数をかける。ここでは、Hamming 窓と Blackman 窓での検討を行う。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。

図1～図8に各測定部位に対する高速フーリエ変換を行った時のグラフを示す。

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

図1～図8に各測定部位に対する高速フーリエ変換を行った時のグラフを示す。

そして、 θ 波帯と呼ばれる4-7Hz間の平均パワースペクトルと α 波帯と呼ばれる8-13Hz間の平均パワースペクトル、14-32Hz間の平均パワースペクトルをそれぞれ求めたパワースペクトルを4-32Hz間の合計のパワースペクトルで割った周波数成分比を特徴量として用いる。

また、表1に分析するデータの分析時間区分を示す。

TABLE I
分析時間区分

T1	-1000ms ~ -750ms
T2	-750ms ~ -500ms
T3	-500ms ~ -250ms
T4	-250ms ~ 0ms

B. 特徴抽出

使用する 1 つの特徴量については、8 チャンネル分のデータをそれぞれ 4 分割し、さらに 3 つの周波数帯の周波数成分比を用いているため $8 \times 4 \times 3$ 次元のデータつまり 96 次元のデータを用いる。

グー・チョキ・パーのデータ M 個の総データを用いたデータ行列 X の式を以下に示す。例としてはデータ行列 X の要素 x_{31a} はデータ 3 個目の T1 における α 波帯の周波数成分比、 x_{12s} はデータ 1 個目の T2 における θ 波帯の周波数成分比、 x_{44b} はデータ 4 個目の T4 における β 波帯の周波数成分比

$$X = \begin{pmatrix} x_{11s} & x_{11a} & \dots & x_{14b} \\ x_{21s} & x_{21a} & \dots & x_{24b} \\ \vdots & \vdots & \ddots & \vdots \\ x_{M1s} & x_{M1a} & \dots & x_{M4b} \end{pmatrix}$$

作成したデータ行列 X に対して次元削減を行う。本論文では、次元削減を行う手法として主成分分析と線形判別分析を適用した。

主成分分析は、データを分散が最大となるような主成分軸上に順次に射影することによってデータの持つ情報の大部分を失うことなく元のデータより低い次元数で表現することができる手法である。本論文では、累積寄与率が 99 % となる 45 次元まで圧縮した。

一方、線形判別分析はクラス内分散・クラス間分散比を最大にする空間部分を求める手法であり、識別を考慮した次元削減法である。

C. クラスタリング

これまでに述べた前処理と特徴抽出の手法を用いて特徴量となるデータを作成する。クラスタリングを行う判別器としてランダムフォレストと SVM の手法を用いて比較する。

III. 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・1 とカウントダウンされた後の黒い画像の表示時に任意のグー・チョキ・パーの手を出してもらう。分析には黒い画像の表示時の 1 秒前から 1 秒後のデータを用いる。

data get 項目では、図 2 の流れを 1 セットとすると 90 セットのデータを取得する。そして、その取得したデータを学習データとして使用する。

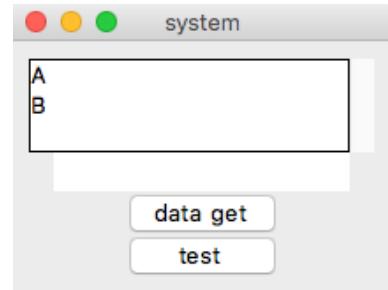


Fig. 5. GUI



Fig. 6. data get のスライドの流れ

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 3 に示す。

IV. 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
- 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

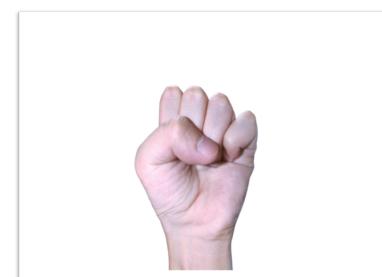


Fig. 7. data get のスライドの流れ

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 90 個のデータセットを用いて実験を行う。被験者は 1 人で test 項目を行う回数は 15 回を 1 セットとして合計 3 回行った。

a) データの次元削減: 本システムの前処理で行う次元削減について以下の 3 パターン比較することにおいて次元削減法を検討する。

- 主成分分析により 45 次元に削減した場合 (累積寄与率:99 %)
- 主成分分析により 45 次元に削減したのちに線形判別分析により 2 次元までに削減した場合
- 主成分分析により 2 次元までに削減した場合 (累積寄与率 51 %)

判別器であるランダムフォレストのパラメータはグリッドサーチにより算出した。また、グリッドサーチによる探索範囲を以下に示す。

- 決定木の数 : 10, 20, 50, 80, 100, 200
- 決定木の深さ : 1 ~ 6
- 分割する枝の数の最小値 : 3, 5, 10, 15, 20, 25, 30, 40, 50, 100
- 分割を探索する際に用いるデータ数 : None, 1, データ数の平方根

そして、分割を行う際の指標としてジニ係数を用いた。

B. 実験結果

以上の実験により得られた勝率の結果を表 2 に示す。

TABLE II
実験結果

	PCA (45 次元)	PCA+LDA	PCA(2 次元)
1 セット目	53 %	60 %	33 %
2 セット目	33 %	47 %	20 %
3 セット目	47 %	53 %	47 %
平均	44 %	53 %	33 %

表 2 の結果より、PCA と LDA を組み合わせた次元削減法による分析を行った場合が最も勝率が高いという結果になった。

LDA ではやはりクラス内での分散やクラス間での分散比を元に部分空間を求めていたため本論文のような教師ありの判別において優位であると考えられる。

また、PCA のみを用いて 2 次元に削減する場合では累積寄与率が 51 % と半分のデータ情報量を損なってしまっている。

一方、LDA を用いることで本論文でも用いている PCA と LDA を組み合わせた場合には PCA で 45 次元に削減した累積寄与率が 99 % のまま LDA で情報量を損なわずに 2 次元に削減できているためより低次元での分析が可能となっている。

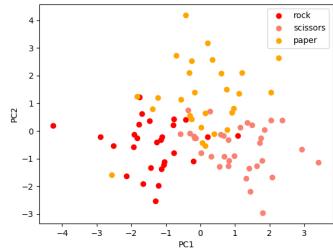


Fig. 8. PCA と LDA による次元削減のデータ分布

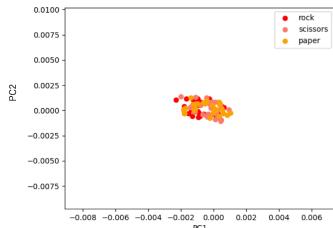


Fig. 9. PCA による次元削減のデータ分布

そこで、PCA で 45 次元に削減した後に LDA で 2 次元に削減した学習データと PCA だけを用いて 2 次元に削減した学習データの可視化を行った。可視化を行ったグラフをそれぞれ図 12 と図 13 に示す。

PCA と LDA を用いた次元削減の可視化のグラフでは、多少クラス間で重ねている部分も見られるが学習データではうまくクラスごとに分布しているといえる。

しかし、PCA のみを用いた次元削減の可視化のグラフでは中心にデータ分布が集まっていることからクラス別にデータの分布を分けることができていないことがわかる。

よって、分類を行う場合には LDA を用いることが有効的であると考えられる。

次に、判別器のランダムフォレストの比較として SVM を用いた場合の勝率の実験を行った。実験結果を以下の表 3 に示す。本論文では、カーネル関数による非線形 SVM を用いた。

TABLE III
実験結果

	PCA (45 次元)	PCA+LDA	PCA(2 次元)
1 セット目	33 %	53 %	33 %
2 セット目	53 %	33 %	47 %
3 セット目	33 %	40 %	27 %
平均	40 %	43 %	36 %

表 3 より、どの次元削減を用いたデータに対してもランダムフォレストを用いた場合の方が高い勝率となった。

C. 考察

1) 脳波計と脳波について: ジャンケンの勝率が高くなかった理由として、本論文で用いた脳波計がドライタイプの計測器でありノイズが混入していることから分類を困難にさせていると考えられる。

そのためアクティブ電極を用いてノイズを削除したデータを分析することで精度が向上すると考えられる [7].

また、脳波の分析手法として事象関連電位がある。本論文では、使用者の負担があまりかからないシステムを作成していたため背景脳波を使用していた。

背景脳波であると加算平均の必要がないために準リアルタイム処理が可能である。また、学習データを獲得するために事象関連電位と比べて必要なデータ数がとても少ない。しかし、注意の指標として用いられる P300 や集中や期待に関連して生じる CNN に注目して脳波を分析することでよりクラス別に異なった特徴を得られると考えられる [8],[9].

2) 分析手法について: 前処理では、次元削減について着目して分析を行った。本論文で用いた次元削減の手法は主成分分析と線形判別分析を用いた。

線形判別分析は教師ありの次元削減であることから分類を行う処理では有効的な手法であることがわかった。

また、線形判別分析判別では各クラス間の分離度が最も大きくなるように特徴空間に射影しているが、その特徴空間に相関の高い成分が含まれているとくまく各クラス間での分離がうまくいかない。

そこで、主成分分析により直交化し相関の高い成分を削減することにより、線形判別での次元削減がよりうまくいくと考えられる。

D. おわりに

本論文では、信号処理において機械学習を用いてクラスタリングを行う手法を検討した。そして、脳波を用いた簡易的なシステムを作成することで実際に実験を行った。

作成システムでは、学習データとしてグー・チョキ・パーの 3 クラスのデータを獲得し、獲得したデータをもとに学習して未知のデータを分類した。その分類結果に勝つジャンケンの手をスライドで表示した。

分析手法は、窓関数と高速フーリエ変換を用いて前処理した後、主成分分析と線形判別分析で次元削減を行いランダムフォレストで分類を行った。分類精度は 53 % となった。

本論文では実験のデータとして脳波データを用いたが、他にも信号として音声データや金融データなどがあるので、他の分野の信号にも適用できるような分析手法の提案に取り組むとともに、精度の向上として深層学習など他の判別器の適用も検討する。

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/jsei/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 靖, Air Brain を利用した脳波BCI システム, 30th Fuzzy System Symposium (Kochi, September 1-3, 2014)