

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

1st Itaru Aso

Dept. Information Systems Engineering
Toyama Prefectural University
Kurokawa, Imizu, Toyama, Japan
t855001@st.pu-toyama.ac.jp

2nd Mamoru Ota

Dept. Information Systems Engineering
Toyama Prefectural University
Kurokawa, Imizu, Toyama, Japan
ota@pu-toyama.ac.jp

3rd Koji Okuhara

Dept. Information Systems Engineering
Toyama Prefectural University
Kurokawa, Imizu, Toyama, Japan
okuhara@pu-toyama.ac.jp

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

昨今の計測技術の発展により多種の大規模データが蓄積可能となってきた。そして、その取得データ全体に対する網羅的な分析の需要が増し、計算機による自動分析技術として知られる機械学習手法の適用事例が増えてきている。特に、状態の識別や予測といった目的に対して、金融・音声・生体データなどの広範な信号データを活用するための機械学習手法の研究が多く行われている。一つの例として、音声に含まれる感情と音声の特徴との関係性を学習し、音声信号から知覚される感情を識別する研究がある [1]。この研究では、アンケートにより得た感情の主観評価値をもとに、計測音声信号の特徴基底を主成分分析と因子分析を用いて推定し、音声信号と感情の関係性は、得られた基底による重回帰分析を用いた評価から捉えている。さらに、3次元時系列座標データを用いたラジオ体操第一の10種類の動作識別や、楽器の音声信号から楽器の種類判別への応用研究がある [3, 4]。前者には、複数の分類器出力から多数決をとり最終的な動作の分類結果を得る Bagging が用いられ、後者には、主成分分析と線形判別分析を用いた入力データの次元削減と、ベイズ推論に基づく判別器が利用された。また医療分野では、(どういう入力データ?) から B 型肝炎の患者と C 型肝炎の患者の分類する問題に対して、機械学習手法の一つである決定木を用いた研究 [2] があるほか、単一測定点の脳波信号データを用いてジャンケン動作の判別をマハラノビスの汎距離に基づき行った研究がある [5]。このように、時系列信号データを機械学習手法を用いて分析する事例は数多くあり、今後より一層応用分野が広がることが予想される機械学習技術の確立は重要であるといえる。

一方で、データの計測状況が多様化していくこと鑑みると計測環境の状態とその変動の影響を考慮する必要があると考えられる。すなわち、計測器のキャリブレーションだけ

でなく外的要因 (例えば天候や生体データの場合には体調) とその変動の影響を受けたデータしか取得できない状況下では、機械学習の著しい性能劣化を招く恐れがある。データの質を向上するためには、環境の影響を受けにくい計測を実施できることが望ましいが、計測に多くの制約がある場合には、環境の影響に対してロバストなデータ分析手法が必須となる。

本研究では、環境の変動にも対応することができる多変量信号からの高精度分類器の学習アルゴリズムの提案を行う。提案手法は、ベイズ推論による少数データからの確率分布推定を軸として、環境と判別対象とする状態の特徴を確率分布の母数により表現し、その母数を推定する。また、類似環境下での既存データセットのベイズ決定則により適切に選択し、その学習結果を利用することで、環境がもたらす影響への対処を図る。提案手法により高い判別性能が得られることを実観測された脳波信号データを用いて検証する。また、環境変動を考慮していない場合との比較を行うことで提案手法が環境の影響に対応していることを示す。

II. 提案する状態識別手法

本節では、 D 次元データをそれぞれ計測可能な C 個の計測機器から N 個のデータが取得されたとき、それらを用いて環境の影響を考慮した上で K 個の状態識別を行う提案手法について述べる。

A. 問題設定

C 個の計測機器から D 次元の計測データを N 回取得した場合の計測データセット

$$\mathbf{X} = \left\{ \mathbf{X}^{(c)} \mid c = 0, 1, \dots, C-1 \right\} \quad (1)$$

が得られていると仮定する。ここで、

$$\mathbf{X}^{(c)} = \left\{ \mathbf{x}_n^{(c)} \in \mathbb{R}^D \mid n = 0, 1, \dots, N-1 \right\} \quad (2)$$

は、計測機器 c により得られたデータを表す。また、それと共に M 個の計測環境種別を与える教師ラベル

$$\mathbf{E} = \left\{ \mathbf{e}_n \in \mathbb{T}_M \mid n = 0, 1, \dots, N-1 \right\} \quad (3)$$

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

と、 K 個の識別対象状態を表す教師ラベル

$$\mathbf{Z} = \{ \mathbf{z}_n \in \mathbb{T}_K \mid n = 0, 1, \dots, N-1 \} \quad (4)$$

がそれぞれ付与されていると仮定する。ここで、

$$\mathbb{T}_L \equiv \left\{ \mathbf{z} \in \{0, 1\}^L \mid \sum_{\ell=0}^{L-1} [z]_{\ell} = 1 \right\} \quad (5)$$

である。また、ある計測環境種別 \mathbf{e} と識別対象状態 \mathbf{z} に対応するデータを抜き出した集合を

$$\mathbf{X}_{(\mathbf{e}, \mathbf{z})} = \left\{ \mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid c = 0, 1, \dots, C-1 \right\} \quad (6)$$

と定義する。ここで、

$$\begin{aligned} \mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)} &\equiv \left\{ \mathbf{x}_n^{(c)} \in \mathbb{R}^D \mid (\mathbf{e}_n, \mathbf{z}_n) = (\mathbf{e}, \mathbf{z}), n = 0, 1, \dots, N-1 \right\} \\ &\quad (7) \end{aligned}$$

とした。各 $\mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)}$ の計測データは、その指定された環境と状態に応じた特徴をもつデータセットとなる。提案手法では、各 $\mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)}$ の特徴を学習するためにベイズ推論を用いる。データが従う確率分布を多変量ガウス分布と仮定し、そ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。

B. 確率分布のベイズ推論による学習則

前項の仮定のもとで、データセット $\mathbf{X}_{(\mathbf{e}, \mathbf{z})}$ に対する平均ベクトル $\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}$ と精度行列 $\boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}$ の事前分布を

$$\begin{aligned} P_0(\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)}, \boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)}) &= \mathcal{N}_D(\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid \mathbf{m}_0, (\beta_0 \boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)})^{-1}) \\ &\quad \times \mathcal{W}_D(\boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid \alpha \mathbf{I}_D, \nu_0) \end{aligned} \quad (8)$$

とすると、事後分布は、

$$\begin{aligned} Q(\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)}, \boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid \mathbf{X}^{(c)}) &= \mathcal{N}_D(\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid \mathbf{m}_{(\mathbf{e}, \mathbf{z})}^{(c)}, (\beta_{(\mathbf{e}, \mathbf{z})}^{(c)} \boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)})^{-1}) \\ &\quad \times \mathcal{W}_D(\boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid \mathbf{W}_{(\mathbf{e}, \mathbf{z})}^{(c)}, \nu_{(\mathbf{e}, \mathbf{z})}^{(c)}) \end{aligned} \quad (9)$$

となる。ここで、 $\mathcal{N}_D(\mathbf{x} \mid \boldsymbol{\mu}, \boldsymbol{\Lambda}^{-1})$ は、平均ベクトル $\boldsymbol{\mu}$ 、分散共分散行列 $\boldsymbol{\Lambda}^{-1}$ の D 変量ガウス分布の確率密度関数を表す。また、 $\mathcal{W}_D(\boldsymbol{\Lambda} \mid \mathbf{W}, \nu)$ は、 D 次元 Wishart 分布の確率密度関数を表す。さらに、 \mathbf{I}_D は D 次元の単位行列である。事後分布を既定する各ハイパーパラメータは次式により計算できる。

$$\mathbf{m}_{(\mathbf{e}, \mathbf{z})}^{(c)} = \frac{\beta_0 \mathbf{m}_0 + N_{(\mathbf{e}, \mathbf{z})}^{(c)} \bar{\mathbf{x}}_{(\mathbf{e}, \mathbf{z})}^{(c)}}{\beta_0 + N_{(\mathbf{e}, \mathbf{z})}^{(c)}} \quad (10)$$

$$\beta_{(\mathbf{e}, \mathbf{z})}^{(c)} = \beta_0 + N_{(\mathbf{e}, \mathbf{z})}^{(c)} \quad (11)$$

$$\begin{aligned} (\mathbf{W}_{(\mathbf{e}, \mathbf{z})}^{(c)})^{-1} &= \alpha^{-1} \mathbf{I}_D + N_{(\mathbf{e}, \mathbf{z})}^{(c)} \mathbf{S}_{(\mathbf{e}, \mathbf{z})}^{(c)} + \frac{\beta_0 N_{(\mathbf{e}, \mathbf{z})}^{(c)}}{\beta_0 + N_{(\mathbf{e}, \mathbf{z})}^{(c)}} \\ &\quad \times (\bar{\mathbf{x}}_{(\mathbf{e}, \mathbf{z})}^{(c)} - \mathbf{m}_0)(\bar{\mathbf{x}}_{(\mathbf{e}, \mathbf{z})}^{(c)} - \mathbf{m}_0)^T \end{aligned} \quad (12)$$

$$\nu_{(\mathbf{e}, \mathbf{z})}^{(c)} = \nu_0 + N_{(\mathbf{e}, \mathbf{z})}^{(c)} \quad (13)$$

ここで、

$$N_{(\mathbf{e}, \mathbf{z})}^{(c)} \equiv \left| \mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)} \right| \quad (14)$$

$$\bar{\mathbf{x}}_{(\mathbf{e}, \mathbf{z})}^{(c)} \equiv \frac{1}{\left| \mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)} \right|} \sum_{n=0}^{N-1} \mathbb{I}[(\mathbf{e}_n, \mathbf{z}_n) = (\mathbf{e}, \mathbf{z})] \mathbf{x}_n^{(c)} \quad (15)$$

$$\begin{aligned} \mathbf{S}_{(\mathbf{e}, \mathbf{z})}^{(c)} &\equiv \frac{1}{\left| \mathbf{X}_{(\mathbf{e}, \mathbf{z})}^{(c)} \right|} \sum_{n=0}^{N-1} \mathbb{I}[(\mathbf{e}_n, \mathbf{z}_n) = (\mathbf{e}, \mathbf{z})] \mathbf{x}_n^{(c)} (\mathbf{x}_n^{(c)})^T \\ &\quad - \bar{\mathbf{x}}_{(\mathbf{e}, \mathbf{z})}^{(c)} (\bar{\mathbf{x}}_{(\mathbf{e}, \mathbf{z})}^{(c)})^T \end{aligned} \quad (16)$$

であり、また

$$\mathbb{I}[(\mathbf{e}_n, \mathbf{z}_n) = (\mathbf{e}, \mathbf{z})] \equiv \begin{cases} 1 & (\mathbf{e}_n, \mathbf{z}_n) = (\mathbf{e}, \mathbf{z}) \\ 0 & (\mathbf{e}_n, \mathbf{z}_n) \neq (\mathbf{e}, \mathbf{z}) \end{cases} \quad (17)$$

である。環境 \mathbf{e} と識別対象状態 \mathbf{z} が与えられたとき、データ $\{\mathbf{x}^{(c)}\}$ がその状況で計測されたことを支持する度合いは、特定の状況が起こりやすいなどの偏りがない場合には、

$$\begin{aligned} P(\mathbf{e}, \mathbf{z} \mid \mathbf{X}, \{\mathbf{x}^{(c)}\}) &\propto \prod_{c=0}^{C-1} \int \int \mathcal{N}_D(\mathbf{x}^{(c)} \mid \boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)}, (\boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)})^{-1}) \\ &\quad \times Q(\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)}, \boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)} \mid \mathbf{X}^{(c)}) d\boldsymbol{\mu}_{(\mathbf{e}, \mathbf{z})}^{(c)} d\boldsymbol{\Lambda}_{(\mathbf{e}, \mathbf{z})}^{(c)} \end{aligned} \quad (18)$$

与えられる。これは、

$$\sum_{(\mathbf{e}, \mathbf{z}) \in \mathbb{T}_M \times \mathbb{T}_K} P(\mathbf{e}, \mathbf{z} \mid \mathbf{X}, \{\mathbf{x}^{(c)}\}) = 1 \quad (19)$$

を満たすように規格化される。

M が大きく様々な環境下での学習データが用意できている場合には、 $\{\mathbf{x}^{(c)}\}$ の計測環境は学習データの計測環境種別内に類似したものがみつかると等である。したがって、 $\{\mathbf{x}^{(c)}\}$ の計測環境 \mathbf{e} は \mathbb{T}_M の要素として扱うことができる。式 (18) で与えられる支持度から状態を判別する手法は複数考えられる。まず、簡単な例として計測環境の周辺化により、

$$P(\mathbf{z} \mid \mathbf{X}, \{\mathbf{x}^{(c)}\}) = \sum_{\mathbf{e} \in \mathbb{T}_M} P(\mathbf{e}, \mathbf{z} \mid \mathbf{X}, \{\mathbf{x}^{(c)}\}) \quad (20)$$

から得られる支持度を最大とする状態を判別結果とする方式が考えられる。すなわち、

$$\mathbf{z}^* = \arg \max_{\mathbf{z} \in \mathbb{T}_K} P(\mathbf{z} \mid \mathbf{X}, \{\mathbf{x}^{(c)}\}) \quad (21)$$

を状態判別結果として用いるものである。

次に、キャリブレーション用に計測データ $\{\mathbf{x}_{\text{cal}}^{(c)}\}$ と、識別対象状態 \mathbf{z}_{cal} が与えられた場合について考えると、その情報を活用して計測環境の同定を行うことができる。このとき、最大事後確率法に基づき最適な環境 \mathbf{e}^* は

$$\begin{aligned} \mathbf{e}^* &= \arg \max_{\mathbf{e} \in \mathbb{T}_M} P(\mathbf{e} \mid \mathbf{X}, \{\mathbf{x}_{\text{cal}}^{(c)}\}, \mathbf{z}_{\text{cal}}) \\ &= \arg \max_{\mathbf{e} \in \mathbb{T}_M} P(\mathbf{e}, \mathbf{z}_{\text{cal}} \mid \mathbf{X}, \{\mathbf{x}_{\text{cal}}^{(c)}\}) \end{aligned} \quad (22)$$

Fig. 1. GUI

Fig. 2. data get のスライドの流れ

から推定できる. キャリブレーションデータから推定された最適環境を用いることで以降の連続計測データ $\{x^{(c)}\}$ の状態判別は

$$z^* = \arg \max_{z \in \mathbb{T}_K} P(e^*, z | X, \{x^{(c)}\}) \quad (23)$$

により行うことができる. この判別方式は式 (21) に比べて類似環境の同定手続きが加わり周辺化を行わないため, 計測環境によるデータの性質変化に対して安定して高精度な判別が行えるものであると期待できる. 次節では, 上述の二つの判別方式 (式 (21) と式 (23)) の性能評価を, 実観測された脳波データを用いて行う.

III. 脳波データを用いた提案手法の評価

A. 評価実験の概要

本研究では, OpenBCI 製のヘッドセットである ULTRA-CORTEX MARK 4 と Cyton Board を用いて取得した脳波データを用いて, 動作なし状態とジャンケンの 3 状態を合わせた計 4 状態を考慮する識別問題に提案手法を適用し性能を評価した. 脳波は信号データの 1 つの例であり, 複数の測定部位を用いることで多次元のデータとして表現することができる. 脳波は生体データのため使用者の体調の変化だったり脳波計の着脱の際の多少のずれにより, 毎回同じ様式のデータが得られるとは限らない. 脳波を用いて機械学習による動作予測を行う場合そのようなデータの様式の変化が精度低下を招く危険性がある. そこで, 提案手法である環境の影響に対してロバストなデータ分析により, 脳波を計測する際に伴う脳波計の着脱や被験者の体調といった環境がもたらす影響への対処を行う. 脳波も信号の 1 種であることから, 提案手法を用いた実験の有効性を示すことができれば他の信号へ適用することが可能であると示唆される.

1) *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.

2) *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.

Fig. 3. data get のスライドの流れ

Fig. 4. 脳波計の装着の様子

Fig. 5. テストデータのパラメータ α と精度のグラフ

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 9 日から 2018 年 5 月 11 日, 2018 年 5 月 14 日である.

B. 脳波データへの提案識別手法の適用

(2 章で定義した変数との対応関係が分かるように書く. ベクトルは太字にする.) 脳波を取得する際に, 基準電位を耳朶から取る場合と各チャンネルの平均値を引く場合がある. 本研究では各チャンネルの平均値を引く場合の手法を採用した.

チャンネル H の脳波データ $x_n^{(c)} = [x_{(1,n)}^{(c)}, x_{(2,n)}^{(c)}, \dots, x_{(h,n)}^{(c)}]$ が与えられたとすると平均 μ は

$$\mu = \frac{\sum_{h=1}^H x_n^{(c)}}{N} \quad (24)$$

各チャンネルで平均値 μ を引いた脳波データ $X_n^{(c)}$ は

$$X_n^{(c)} = \{x_{1,n}^{(c)} - \mu, x_{2,n}^{(c)} - \mu, \dots, x_{h,n}^{(c)} - \mu\} \quad (25)$$

本研究で使用する脳波計は 8 チャンネルの測定部位が存在する. 取得したデータ X 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.

$$PS = 20 \log_{10} \sqrt{Re^2 + Im^2} \quad (26)$$

そして, 3-50Hz 間の PS を分類のための特徴量として用いる.

また, 使用するパラメータの初期値は $\beta_0 = 0.1$, $m_0 = 0$, $\nu = 94$, $D = 94$. $K = 3$ とした.

C. 提案手法の性能結果

1) 環境変動への対応なしの分類: 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. 2.1 で示した分類手法を用いて分類を行う.

2018.5.9(Day1), 2018.5.10(Day2), 2018.5.11(Day3), 2018.5.14(Day4) の 4 日間の取得したデータに対してそれぞれ訓練データ 60 個とテストデータ 40 個に分けて分類を行った. その分類結果を表 1 に示す.

本研究では, 変動させるパラメータは α のみであり, α の値と精度の関係を図 6 に示す.

TABLE I
環境変動への対応なしの分類精度

	Day1	Day2	Day3	Day4
α	0.2919	0.0076	0.038	0.0051
train(accuracy)	0.517	0.367	0.517	0.418
test(accuracy)	0.450	0.475	0.450	0.475

Fig. 6. 訓練データのパラメータ α と精度のグラフ

テストデータにおいて分類で最も分類精度と訓練データの分類精度の値があまり変わらないことから提案した判別手法は汎化性能が高いことがわかる。

2) 環境変動への対応ありの分類: まず、環境変動の有無を確認するために環境のデータに対して周波数解析を各測定部位ごとに行った。環境変動を考慮した場合は、4日間のデータそれぞれに対してどの日のデータが残りの3日間のデータの中で最も近いかを KL ダイバージェンスを用いて求めた。そして、KL ダイバージェンスの値が低い日のデータの40個をテストデータとして分類を行った。

また、比較としてそれぞれ日のデータに対して残りの3日間のデータを40個ずつテストデータとして用いた場合の分類も行った。

以下に最も低かった KL ダイバージェンスの値と環境変動への対応の有無それぞれの分類結果を示す。KL ダイバージェンスを用いて環境変動への対応を行った。Day1 と Day2, Day3 は環境が近い日同士で分類を行うと環境変動への対応が無しの場合より精度が高くなった。

Day4 が環境変動への対応を考慮しても低くなった理由としては、Day4 の KL ダイバージェンスの値が高いことから似ている環境が実験で用意してある環境の中になかったことが示唆される。Day4 と近しい環境を用意することが可能であれば精度は向上すると考えられる。

Fig. 9. C3 の周波数解析のグラフ

Fig. 10. C4 の周波数解析のグラフ

Fig. 11. P7 の周波数解析のグラフ

Fig. 12. P8 の周波数解析のグラフ

Fig. 13. O1 の周波数解析のグラフ

Fig. 14. O2 の周波数解析のグラフ

TABLE II
環境変動への対応ありの分類精度

	Day1	Day2	Day3	Day4
α	0.2919	0.0076	0.038	0.0051
KL ダイバージェンス	11.5423	9.7056	10.3993	17.0014
test(環境変動への対応無し)	0.4083	0.3833	0.4083	0.3917
test(環境変動への対応有り)	0.425	0.425	0.425	0.375

Fig. 7. Fp1 の周波数解析のグラフ

Fig. 8. Fp2 の周波数解析のグラフ

IV. おわりに

(まだ保留しておきますが, ほぼ問題ないです.) 本研究では, 環境変動を考慮した信号の分類手法を提案した. 分類手法としてはベイズ推論から学習される確率分布を用いて分類を行い, 環境変動への対応としてはあらかじめ複数の環境の訓練データを用意しておき, KL ダイバージェンスによって用意した複数の訓練データとテストデータとの類似度をそれぞれ求めることによって環境への対応を試みた.

実験では脳波を測定し, 取得した脳波からじゃんけんの動作の分類を行った. その際に, 4 日間の脳波データを訓練データとテストデータに分けて提案手法の精度を検証した. まず, 環境変動を考えない同一の環境下の訓練データとテストデータを用いた際の分類精度の平均は 46.25 % となった.

また, 環境変動を考慮して KL ダイバージェンスによって環境の選択を行ってから分類を行った際の精度の平均は 41.25 % となった. 比較として環境変動を考慮せずに異なった環境での訓練データとテストデータを用いた場合での分類精度の平均は 39.25 % となった.

この実験結果から本研究の環境変動への対応は効果的であったと示唆される. しかし, Day4 に関しては環境変動への対応を行ったが精度が下がったが, その時の KL ダイバージェンスの値が大きくなっていたことから Day4 へ対応できる環境が用意できていなかったことが考えられる. よって, 分類を行う際には環境の選定が重要であることがわかった.

本研究では, 脳波データを用いて提案手法の検証を行ったが他の音声データや金融データなどの信号に対しても適用が可能であるかを検証する必要がある.

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/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) と意味材料の記憶検索, Japanese Journal of Physiological Psychology and Psychophysiology Vol.1.1983,19-25.