

マルチモーダル移動行動データからの 高速な頻出共起ルール抽出手法

田一鳴^{1,a)} 前川卓也^{1,b)} 天方大地^{1,c)} 原隆浩^{1,d)} 松本祥子^{2,e)} 依田憲^{2,f)}
藤岡慧明^{3,g)} 濱井郁弥^{4,h)} 福井大^{5,i)} 飛龍志津子^{6,j)}

受付日 2018年5月29日, 採録日 2018年12月4日

概要: 本論文では, 移動体から得られたマルチモーダル時系列データから高速に頻出ルールを抽出する手法の提案を行う. 近年, センサ技術の進展により小型センサデバイスを動物に添付し, GPS により動物の移動軌跡を計測するとともに, 環境・生体センサにより移動にまつわる時系列センサデータも同時に計測することが可能となりつつある. 本研究では, 移動およびセンサの時系列データを, それぞれ複数のモードにセグメントし, 異なるモードを跨いだ頻出ルールを高速に抽出する手法を提案する. たとえば移動軌跡から抽出された「局所探索」モードと生体センサから抽出された「緊張」モードが共起することが多いといったルールを抽出する. モードのセグメントに用いられるパラメータは様々な値をとる可能性があるため, 得られるルールの有用性に基づきそれらを自動的に決定する. 実データを用いた実験の結果から, 提案手法は高速にルールを抽出できることを確認した.

キーワード: 軌跡データ, セグメンテーション, 頻出ルール

Fast Frequent Co-occurrence Rule Extracting Method from Multi-modal Trajectory Data

YIMING TIAN^{1,a)} TAKUYA MAEKAWA^{1,b)} DAICHI AMAGATA^{1,c)} TAKAHIRO HARA^{1,d)}
SAKIKO MATSUMOTO^{2,e)} KEN YODA^{2,f)} EMYO FUJIOKA^{3,g)}
FUMIYA HAMAI^{4,h)} DAI FUKUI^{5,i)} SHIZUKO HIRYU^{6,j)}

Received: May 29, 2018, Accepted: December 4, 2018

Abstract: This paper proposes a fast method that extracts frequent patterns from multi-modal time-series data obtained from a moving object. Due to the recent advance in sensing technologies, we can measure trajectories of animals from GPS modules as well as time-series sensor data related to locomotion from environmental and bio-sensors using small sensor nodes attached to the animals. The proposed method first segments time-series data, i.e., trajectory and sensor data, into multiple modes, and then extracts cross-modal frequent patterns from the segmented time-series. For example, we extract a rule describing that a “local search” mode extracted from trajectory data usually co-occurs with a “stress” mode extracted from bio-sensor data. Our method finds good parameters used in the segmentation according to the usefulness of rules. Our experiments using real datasets demonstrate the efficiency of our proposed method.

Keywords: trajectory data, segmentation, frequent rule

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology
Osaka University, Suita, Osaka 565-0871, Japan
² 名古屋大学大学院環境学研究科
Graduate School of Environmental Studies Nagoya University,
Nagoya, Aichi 464-8601, Japan
³ 同志社大学研究開発推進機構
Organization for Research and Development
Doshisha University, Kyotanabe, Kyoto 610-0394, Japan

⁴ 同志社大学大学院生命医科学研究科
Graduate School of Life and Medical Sciences Doshisha University,
Kyotanabe, Kyoto 610-0394, Japan
⁵ 東京大学大学院農学生命科学研究科
Graduate School of Agricultural and Life Sciences, The University of Tokyo,
Bunkyo, Tokyo 113-8657, Japan
⁶ 同志社大学生命医科学部
Doshisha University Faculty of Life and Medical Sciences,
Kyotanabe, Kyoto 610-0394, Japan

1. はじめに

センサデバイスの小型化やバッテリー技術の進展により、センサノードを移動体に添付して移動行動のセンシングを行う研究がさかんに行われており、人や車にセンサノードを添付して移動行動を観測する研究が多く行われてきた [14], [31]. 近年のさらなるノードの小型化により海鳥などの動物にノードを添付し、移動行動を観測する手法の研究がユビキタスコンピューティングの研究分野などでも行われつつある [2].

動物の行動情報をセンサデバイスを用いて記録する手法はバイオリギングと呼ばれ [25], 位置座標 (軌跡) だけでなく、環境データや生体データなどの様々な時系列データをセンサにより同時に計測することで、多くの研究者が動物の移動メカニズムの解明を目指している. 多くの既存研究において、得られたセンサデータに対して研究者の経験に基づき特徴抽出を行ったあと、分類分析やクラスタリングなどの手法が適用されている [28]. 軌跡データなどの単一のモーダルのみを用いた研究が大部分を占めており、軌跡のセグメント分割や行動分類などの手法が開発されている [13], [32]. しかし、外的/内的要因と動物の移動行動の相互関係を明らかにするためには、軌跡情報のみでなく、同時に計測された時系列センサデータを同時に解析して、知識抽出を行う必要がある.

一般的に動物の移動は複数のモードから構成される. たとえば、餌などの探索を局所的に行う「局所探索」や、餌場間などの移動を行う「長距離移動」などから構成されている. 一方で、環境センサや生体センサから得られたデータにもモードは存在し、たとえば脳波の時系列データから、動物の状態を「リラックス」モードと「緊張」モードに分けることもできる. 動物から得られた複数のモーダルの時系列センサデータ (軌跡, 環境データ, 生体データなど) をそれぞれこのようなモードにセグメントし、異なるモーダルをまたいだ頻出パターンを抽出することで、生態学者にとって異なるモード間の相互関係を理解しやすい有用な知見を提供できる. たとえば、ある動物が「長距離移動」モードにあるときは、「リラックス」モードであることが多いといった頻出ルールが考えられる.

このような、時系列データ (軌跡データやセンサデータ) からのモードの抽出には、系列データクラスタリング手法

が用いられてきた. しかし、これまでの手法では、数ある特徴量の中からクラスタリングに用いる特徴量およびそのパラメータを、研究者の先験的な知見から主観的に一意に決定していた. そこで、本研究ではそのような特徴量や閾値を自動的に選択し、頻出ルールの抽出を行う手法を開発する. ここで、本研究が対象とする動物のデータからの頻出ルール抽出の最終目標は、有用度の高い頻出ルールを見つけることであるため、得られる頻出ルールの有用度が最も高くなるようなパラメータを同時に発見する (有用度の定義は後述する). すなわち、それぞれの系列データにある特徴量とクラスタリングパラメータを用いてクラスタリングし、それらの結果から頻出ルールの抽出およびその有用度の計算を行う. この手順を、利用する特徴量とパラメータを変えながら何度も行い、高い有用度が得られたモード分けを、もっともらしいモード分けであると考え、ここで、時系列データをどの特徴とパラメータを使ってクラスタリングすればよいかには正解はない. しかし、何らかの特徴とパラメータにより得られた2つのモードが非常に頻繁に共起している場合、そのモード分けには何らかの意味があるはずであり、その結果を生態学者に提示することで、生態学的な知見が得られることが期待される.

しかし、軌跡データや時系列データから抽出される特徴量は数多く存在し、クラスタリングパラメータも様々な値をとりうる. そのため、時系列データのクラスタリングを何度も繰り返し行う必要があり、その計算量は膨大となる. そこで本研究では、パラメータを変更して何度も繰り返すクラスタリング処理を高速化して頻出ルールを導出する手法を提案する. 時系列データのクラスタリングでは、(1) まず時間的に近傍かつ値の類似しているデータポイントどうしをグループ化 (セグメント化) した後、(2) スペクトラルクラスタリング [20] を用いて時間的に離れたグループどうしを何らかの距離指標に基づいて併合することが多い. すなわち、系列データのクラスタリングが2つのフェーズに分けられることに着目し、前半のフェーズを、前半のフェーズで利用されるパラメータ値を用いて計算したあと、その結果を用いて後半のフェーズを、後半のフェーズで利用されるパラメータ値を変更して何度も繰り返すことで、計算の高速化を実現する.

また、ある値のパラメータを用いて前半のフェーズの計算を行う際、他の値のパラメータで事前に計算された結果を再利用することで、高速化を行う. 前半のフェーズでは、センサデータのシンボル化・離散化を行った後にセグメント化を行うが、大きなシンボル数で計算した離散化の結果は、小さなシンボル数での離散化の計算に再利用できることに着目する. さらに、後半のフェーズでは各セグメントをノードとするグラフのスペクトラルクラスタリングを行う. その際に離散化された同じ値を持つノードどうしの距離が0であることに着目して、元のグラフを同様のクラス

a) tian.yiming@ist.osaka-u.ac.jp
 b) maekawa@ist.osaka-u.ac.jp
 c) amagata.daichi@ist.osaka-u.ac.jp
 d) hara@ist.osaka-u.ac.jp
 e) s.matsumoto@nagoya-u.jp
 f) yoda.ken@nagoya-u.jp
 g) efujioka@mail.doshisha.ac.jp
 h) ctub1009@mail4.doshisha.ac.jp
 i) fukuidai@uf.a.u-tokyo.ac.jp
 j) shiryu@mail.doshisha.ac.jp

タリング結果が得られる小さなグラフに変換することで、その計算時間を削減する。実データを用いた実験から、提案手法は比較手法に比べて大幅に計算時間を削減していることを確認した。

本論文の構成。以下では、2章で関連研究について述べ、3章で提案手法を説明する。4章で性能評価のために行った実験の結果を紹介し、5章で本論文のまとめを行う。

2. 関連研究

時系列クラスタリングに関する研究、および複数の時系列データ間の相関を計算する研究について紹介する。

時系列クラスタリング問題。時系列クラスタリングは多くのアプリケーションに利用される基本的な処理であるため、これまでに高速化に焦点を当てた研究が数多く行われている [1]。時系列データは高次元データとみなせる。時系列クラスタリングでは、データ間の類似度（または距離）を計算する必要があるが、高次元データにおける類似度の計算コストは無視できない大きさである。そのため、データ間の類似度の計算回数を削減することが高速化を実現するために重要である。文献 [7] では、ランダムサンプリングを利用し、クラスタの中心を高速に決定するアルゴリズムを提案している。文献 [21], [22] では、相互相関と k -means 法に基づいたクラスタリングアルゴリズムを提案しており、Dynamic time warping などの距離指標よりも正確かつ高速にクラスタリングできることを示している。

1つの時系列データにおける部分シーケンスをクラスタリングする問題では、モチーフ [15] によるクラスタリング [24] や、動径分布関数を利用してクラスタを決定するアルゴリズム [6] が提案されている。これらの研究は、時系列データのクラスタリング自体を目的としているが、本研究では、有用度が高い頻出ルールを導くことを主目的としている。文献 [10] では、クラスタの数をノンパラメトリックベイズにより自動的に決定する手法が提案されている。本研究も同様にクラスタリングのパラメータを自動的に決定するが、本研究では有用度が高い頻出ルールが導かれるようにパラメータを決定する。

上述のとおり、単一の時系列データのセグメンテーション/クラスタリングの高速化に関する研究は多く行われている。後述する提案手法では、SAX [16] を用いて時系列データのシンボル化を行ったあと、スペクトラルクラスタリングを行う。シンボル化の高速化に関しては、文献 [4] などの研究が行われている。文献 [4] では、後述する提案手法と同様に、シンボル数が2倍のときのシンボル化の結果を再利用して、SAXの高速化を行っている。後述する提案手法では、さらにシンボルの代表値を計算する際にもシンボル数が2倍のときのものを再利用している。また、本研究ではスペクトラルクラスタリングの高速化のために、スペクトラルクラスタリングに用いられるグラフの削減を行っ

ている。クラスタリングの高速化という観点からは、多数の先行研究 [22], [30] が存在しており、基本的には多くの手法を提案手法に用いることが可能である。ただし、本研究では類似しないシンボルどうしが同じクラスタに割り当てられることを防ぐため、スペクトラルクラスタリングを用いている（これらの詳細は後述する）。

時系列データ間の相関計算問題。1つのデータからは特徴が抽出できないが、複数のデータ間で共起する特徴が存在する場合があります。これに焦点を当てた研究が行われている。文献 [33] は、ユーザが指定した条件（たとえば、パターンの出現するデータの個数）に該当するパターンを抽出する問題に取り組んでいる。文献 [9], [23] では、異なるドメインのトランザクションの集合が入力された際、同時に出現するデータの組合せが閾値以上の回数で出現するものを抽出する問題に取り組んでいる。これらの研究では、パターンの頻出回数を効率的に計算することに焦点を当てており、本研究が行う有用度の高いルールが現れるパラメータを自動的に発見する問題とは異なる。

文献 [19] では、グラフクラスタリングを用いて1次元の頻出モチーフをグループ化し、頻繁に共起する異なる次元のモチーフを発見することで、高次元の頻出モチーフを発見する手法を提案している。文献 [27] では、確率的グラフィカルモデルを用いることで、人によるジェスチャとロボットのアクションの関係を導く手法を提案している。一方本研究では、固定長のモチーフではなく、動物の移動データやセンサデータから得られるモードから共起するモードを発見する。

3. 提案手法

概要。図 1 に提案手法の概要を示す。提案手法は、移動軌跡（位置座標の時系列データ）と任意の次元数の時系列データ（環境センサデータなど）を入力とする。また、これらの時系列データは同時に記録されたものとする。これらの時系列データをそれぞれ、 P と S とする。まず、それぞれの時系列データから特徴を抽出して、複数の1次元の特徴時系列データを計算する。 P から P_0, P_1, \dots, P_N の特徴時系列データが、 S から S_0, S_1, \dots, S_M が得られる（ただし、 S に含まれる1つの次元のデータのみを抽出して S から抽出される特徴時系列データとしてもよい）。そして、それぞれの P_n と S_m のペアについて、ルールとそのスコアを導出する。スコア導出について説明する。 P_n と S_m それぞれに対して様々なパラメータを用いて時系列クラスタリングを行うと、パラメータごとに時系列クラスタリング結果、 $P_{n,\theta_0}, P_{n,\theta_1}, \dots, P_{n,\theta_i}$ と $S_{m,\theta_0}, S_{m,\theta_1}, \dots, S_{m,\theta_j}$ が得られる。 P_{n,θ_i} と S_{m,θ_j} の組合せごとに、ルールとその有用度（スコア）のペア群を導出する。提案手法の擬似コードを Algorithm 1 に示す。

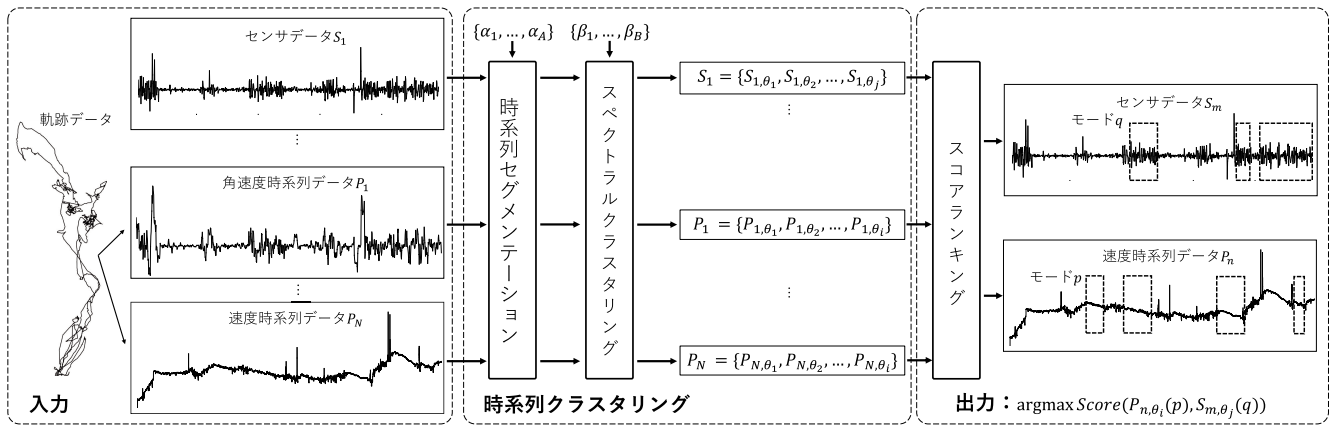


図 1 提案手法の概要

Fig. 1 Overview of the proposed method.

Algorithm 1: Framework

```

Input:  $T$ : a set of time-series with different attributes,
 $\alpha_{max}$ : maximum #symbols,  $\alpha_{min}$ : minimum
#symbols,  $\beta_{max}$ : maximum cluster size,  $\beta_{min}$ :
minimum cluster size
1 /* Clustering time-series */
2 for  $\forall t_i \in T$  do
3    $\mu, \sigma \leftarrow \text{COMPUTE-MEAN-VARIANCE}(s)$   $\triangleright \mu$  is mean
   and  $\sigma$  is standard deviation
4   for  $j = \alpha_{max}$  to  $\alpha_{min}$  do
5      $\text{SAX}(t_i, \mu, \sigma, j)$ 
6      $\text{REPRESENTATIVE-VALUE-COMPUTATION}(\cdot)$ 
        $\triangleright$  compute a representative value of each
       symbol
7      $\text{MERGE-SYMBOLS}(\cdot)$   $\triangleright$  merge the data with the
       same symbol into one segment
8      $\text{SIMILARITY-COMPUTATION}()$   $\triangleright$  compute
       similarities between all segments
9      $V \leftarrow \text{LAPLACIAN-EIGENMAPS}()$   $\triangleright V$  is a set of
       eigenvectors
10    for  $k = \beta_{min}$  to  $\beta_{max}$  do
11       $C \leftarrow k\text{-MEANS}(V, k)$   $\triangleright C$  is a set of
        clusters
12       $R \leftarrow R \cup \langle i, j, k, C \rangle$   $\triangleright$  store the
        clustering-result along with the
        related paramteres
13 /* Scoring clustering-result */
14  $s^* = 0, \langle i, i' \rangle = \emptyset, j^* = 0, k^* = 0$ 
15 for  $\forall r \in R$  do
16   for  $\forall r' \in R \setminus \{r\}$  s.t.  $r.j = r'.j \wedge r.k = r'.k$  do
17      $s \leftarrow \max_{c \in r, c' \in r'.C} \text{USEFULNESS}(c, c')$ 
18     if  $s^* < s$  then
19        $s^* \leftarrow s, \langle i, i' \rangle = \langle r.i, r'.i \rangle, j^* = r.j, k^* = r.k$ 
20 Return  $s^*, \langle i, i' \rangle, j^*, k^*$ 

```

3.1 特徴抽出

P からは、速度や角速度などの移動に関する特徴量の時系列データが導出される。 S からは、そのセンサデータに応じた特徴量の時系列データが導出される。4.1節にて、実験に用いたデータセットごとに利用した特徴を説明する。

3.2 時系列クラスタリング

得られた P_n (もしくは S_m) に対して、与えられたパラメータごとに網羅的に時系列クラスタリングを行う。時系列クラスタリングは、(1) 時系列セグメンテーションと (2) スペクトラルクラスタリングの2つの手順に分けられる。それぞれの手順においてパラメータが1つずつ存在 (シンボル数: α とクラスタ数: β) し、それぞれのパラメータのとり値が与えられている ($\alpha = [3, A], \beta = [2, B]$)。ただし、 A と B はそれぞれ α と β の最大値である。そして、パラメータのとり値のあらゆる組合せ $\theta_i = (\alpha_a, \beta_b)$ ごとにクラスタリングを行う。このとき、たとえば (α_a, β_b) のパラメータの組を用いて時系列クラスタリングを行うとき、事前に (α_a, β_{b-1}) のパラメータの組を用いて計算を行っていた場合は、 α_a を用いた時系列セグメンテーションの結果を再利用する。ただし、シンボルを併合してクラスタを形成するため、 $\alpha_a > \beta_b$ となる。まず α_a を用いて時系列データを大まかにシンボル化・セグメント化し、さらに β_b を用いて詳細にクラスタ化を行うため、 $\alpha_a > \beta_b$ を満たす必要がある。

3.2.1 時系列セグメンテーション

ここでは、時間的かつ値的に近いデータポイントを1つのセグメントとして併合することで、(2) スペクトラルクラスタリングの計算時間を削減する。さらに、この処理の計算時間を削減するため、この手順を以下のように手順 1-1 と手順 1-2 に分ける。

手順 1-1. まず、 P_n に含まれる全データポイントの平均と分散 (標準偏差) を計算する。(アルゴリズム 3 行目) この処理はパラメータ α_a を必要としないため、この結果は




図 2 SAX の例. 値域ごとに対応するシンボルを割り当て、それぞれのポイントシンボル化する

Fig. 2 Example of SAX. Assigning symbols to each range and then symbolize each point.




図 3 代表値の集約の例. $\alpha = 2$ のときのシンボル a の代表値は、 $\alpha = 4$ のときのシンボル a と b の結果から計算可能

Fig. 3 Example of aggregation of representative values. The representative value of 'a' when $\alpha = 2$ can be calculated from the result of 'a' and 'b' when $\alpha = 4$.

異なる α_a を用いてセグメンテーションするときも再利用する。

手順 1-2. SAX [16] を用いて各データポイントのシンボル化を行う。SAX では、図 2 に示すように、データ集合が正規分布に従うと考え、 α_a 個のシンボルにシンボル化する場合、その正規分布の面積を α_a 等分にするよう $\alpha_a - 1$ 個の区切り点を定める。区切り点を定める際に、手順 1-1 で計算した全データポイントの平均と分散を再利用する。そして、それぞれのデータポイントがどのシンボルに対応する領域に入るかを判定することで、シンボル化を行う。この処理にかかる処理を削減するため、他の α_a を用いて計算された結果を再利用する。提案手法では、 α のとりうる値を降順に並べ、大きい α の値から計算を行う。たとえば図 3 に示すように、 $\alpha = 4$ のときのシンボル a もしくは b に割り当てられたデータポイントは、 $\alpha = 2$ のときは必ずシンボル a に割り当てられるため、 $\alpha = 2$ のときはどのデータポイントがどのシンボルに対応するかの処理を省略できる (アルゴリズム 5 行目)。

次に、(2) スペクトラルクラスタリングが必要となる、各シンボルの代表値 (平均) を求める。すなわち、あるシンボルに割り当てられたデータポイントの値の平均を求める。この代表値の計算にかかる処理を削減するため、他の α_a を用いて計算された結果を再利用する。たとえば図 3 に示

すように、 $\alpha = 2$ のときのシンボル a の代表値は、 $\alpha = 4$ のときのシンボル a と b の代表値とそれぞれのシンボルに割り当てられたデータポイント数 (n_a, n_b) を用いて下記のとおり計算できる。すなわち、 $\alpha = 2$ のときのシンボル a に割り当てられた全データを用いる必要がない。

$$\bar{a}(\alpha_a) = \frac{n_a \bar{a}(2\alpha_a) + n_b \bar{b}(2\alpha_a)}{n_a + n_b}$$

ただし、 $\bar{a}(\alpha_a)$ は、 $\alpha = \alpha_a$ のときのシンボル a に対応するデータポイントの平均である (アルゴリズム 6 行目)。

最後に、時間的に隣接する同じシンボルを持つデータポイントをセグメントと考え、併合する。これにより、次の手順において扱うデータポイントの数を削減できる (アルゴリズム 7 行目)。

3.2.2 スペクトラルクラスタリング

次に、(1) 時系列セグメンテーションの結果のクラスタリングを、グラフ分割手法の 1 つであるスペクトラルクラスタリング [20] を用いて行う。スペクトラルクラスタリングのアルゴリズム自体は既存のものを用いるが、提案手法ではクラスタリングに用いられるグラフのノードを削減することで計算コストを削減する。ここでは、1 つのセグメントをグラフの 1 つのノードとし、ノード (セグメント) 間のエッジ (ノード間の類似度) の重みは、そのセグメントに対応するシンボルの代表値間の差の絶対値の逆数とする。たとえば、シンボル a と b に対応するノード間のエッジの重みは下記のとおりである (アルゴリズム 8 行目)。

$$w_{a,b} = \frac{1}{|\bar{a}(\alpha_a) - \bar{b}(\alpha_a)|} \quad (1)$$

そして、スペクトラルクラスタリングでは、カットするエッジの重みが最小となるように、グラフを β_b のサブグラフに分割する。ただし、長時間の時系列データの場合、ノード数が膨大となるため、グラフのノードの削減を行うことでスペクトラルクラスタリングの計算時間を削減する。また、さらに計算時間を削減するため、この手順を以下のよう手順 2-1 と手順 2-2 に分ける [29]。

手順 2-1. まず、(1) 時系列セグメンテーションの結果からグラフを作成する。 $P_{n,\alpha_a} = [s_0, s_1, \dots, s_i, \dots]$ を時系列セグメンテーションの結果とすると、 s_i は i 番目のセグメントを表し、各セグメントがそれぞれノードとなるグラフを作成する。また、同じシンボルもしくは隣接するシンボル (たとえば図 2 において、シンボル b に隣接するシンボルは a と c) を持つノード間にエッジを設定する。これは、後述するスペクトルクラスタリングの処理において、隣接しないシンボルどうしが、間のシンボルをまたいで同じクラスタに割り当てておくことを防ぐためである (たとえば、シンボル a と c に対応するノードが同じクラスタになり、b に対応するノードが別のクラスタに割り当てられるような状況)。 i 番目と j 番目のセグメント間のエッジの重みは

式 (1) に定めたとおりである。

次に、以降のスペクトラルクラスタリングにおける計算時間の削減を行うため、グラフのノード数の削減を行う。このとき、削減前のグラフと同様の結果が得られるようなノード数の削減を行う。スペクトラルクラスタリングでは、グラフ G を k 個のサブグラフ G_1, G_2, \dots, G_k に分割する。このとき、分割によりカットされるエッジの重みの和は下記のとおり表される。

$$RatioCut(G_1, G_2, \dots, G_k) = \sum_{i=1}^k \frac{Cut(G_i, \bar{G}_i)}{|G_i|} \quad (2)$$

$$Cut(G_i, G_j) = \sum_{n \in G_i, m \in G_j} w_{s(n), s(m)} \quad (3)$$

ただし、 $s(n)$ は n 番目のノードに対応するシンボル、 \bar{G}_i は G から G_i を除いたグラフ、 $|G_i|$ は G_i のノード数である。式 (2) を最小化するカットを見つけることで、類似したノードが同じクラスタになるようなクラスタリングを行うことができる。ここで、式 (1) のとおり、同じシンボルを持つノードどうしの類似度は無限大（計算不能）とみなし、同じシンボルを持つノードが異なるサブグラフ G_i と G_j に含まれる場合は、式 (2) の値は ∞ となる。すなわち、 $k < \alpha_a$ ($k = \beta_b$) を満たす場合は同じシンボルのノードは同じサブグラフに属するため、同じシンボルのノード間のエッジがカットされることはない。そこで、提案手法では、同じシンボルを持つノードを 1 つに併合することで、ノード数の削減を行う。これにより、併合後のグラフにおける各ノード間の距離は下記のように表される。

$$W_{M_a, M_b} = \sum_{n \in S_a, m \in S_b} w_{s(n), s(m)} \quad (4)$$

ただし M_a をシンボル a を持つノードを併合したノード、 S_a をシンボル a を持つノードの集合とする。このようなノードの併合を行った後でも、下式のとおり、併合後のノード間のカットは併合前の同じシンボルを持つノードの集合間のカットと同じとなるため、元のグラフと同じ分割結果が得られる。

$$Cut(S_a, S_b) = W_{M_a, M_b} = Cut(\{M_a\}, \{M_b\})$$

このノード数を削減したグラフを用いてスペクトラルクラスタリングを行う。スペクトラルクラスタリングでは、ノード間の類似度を示すラプラシアン行列を計算したあと、その行列の固有値分解を行うことで、固有ベクトルと固有値を求める。上記の処理は、パラメータ β_b を必要としないため、この結果は異なる β_b を用いてクラスタリングするときも再利用する（アルゴリズム 9 行目）。

手順 2-2. スペクトラルクラスタリングでは、上記手順で求めた固有ベクトルを基に、k-means++法 [3] を用いてノードのクラスタリングを行う。k-means++法のパラメー

タであるクラスタ数として β_b を用いる（アルゴリズム 11 行目）。

3.3 ルールとその有用度の導出

上記の手順で得られた P_{n, θ_i} と S_{m, θ_j} ごとに、ルールとそれに紐づく有用度（スコア）を計算する。

そして、すべての P_{n, θ_i} と S_{m, θ_j} の組合せから得られたスコアの高いルールをユーザに提示する。ここで、 $P_{n, \theta_i}(p) = \{s_{p,1}, s_{p,2}, \dots\}$ を P_{n, θ_i} から抽出した p 番目のモード（クラスタ）に属するセグメントの集合、 $S_{m, \theta_j}(q) = \{s_{q,1}, s_{q,2}, \dots\}$ を S_{m, θ_j} から抽出した q 番目のモードに属するセグメントの集合とする。上述した時系列クラスタリング手法はルールとスコアの算出方法に影響を受けるものではないが、本研究ではルールとスコアの算出方法を下記のとおり定めた。

- Rule($P_{n, \theta_i}(p), S_{m, \theta_j}(q)$): $P_{n, \theta_i}(p)$ は $S_{m, \theta_j}(q)$ とよく共起する。
- Score($P_{n, \theta_i}(p), S_{m, \theta_j}(q)$) = Corr($P_{n, \theta_i}(p), S_{m, \theta_j}(q)$) - Freq($P_{n, \theta_i}(p), S_{m, \theta_j}(q)$)
- Corr = $\frac{\text{Overlap}(P_{n, \theta_i}(p), S_{m, \theta_j}(q))}{\sum_i |s_{q,i}|}$
- Freq = $\frac{\max(\sum_i |s_{p,i}|, \sum_i |s_{q,i}|)}{L}$

ただし、 $|s_{p,i}|$ はセグメント $s_{p,i}$ の長さとし、Overlap($P_{n, \theta_i}(p), S_{m, \theta_j}(q)$) は $P_{n, \theta_i}(p)$ と $S_{m, \theta_j}(q)$ に含まれるセグメントがオーバーラップしている時間の長さ、 L は軌跡全体のデータ長とする。Corr は、 p 番目のモードと q 番目のモードの共起度を表すが、ほぼすべてのデータ点を含むような無意味なクラスタどうしは Corr が非常に高くなってしまふ。そこで本研究では、ほぼ定常的に起こっているモードどうしに関するルールに対してペナルティを与えるスコアの算出手法を提案する。そのため、Freq はモードの出現時間の割合としており、これにより定常的なモードを含むルールのスコアを下げるができる。

3.4 計算量

時系列データ X_i が与えられたときの計算量を検証する。SAX と MERGE-SYMBOLS の計算量は $O(|X_i|)$ である。スペクトラルクラスタリングに用いるグラフの構築にかかる計算量は $O(\alpha^2)$ で済むが、固有値分解には $O(\alpha^3)$ かかってしまう [17]。k-means++の一回の実行には $O(\alpha\beta)$ かかり [5]、これらの処理がある α ごとに $(\beta_{max} - \beta_{min} + 1)$ 回繰り返されるため、 $O(|X_i| + \alpha^3 + \sum_{\beta} \alpha\beta)$ の計算量となる。すなわち、すべての α に対して処理をすると、総計算量は $O(\sum_{\alpha} (|X_i| + \alpha^3 + \sum_{\beta} \alpha\beta))$ となる。

実際の α と β の値は小さいため、提案手法は短時間で時系列セグメンテーションを行うことができる。実際の実行時間に関する評価は次章にて行う。

4. 評価実験

本章では、提案手法の性能評価のために行った実験について説明する。

4.1 データセットと特徴量

提案手法の評価を、下記に示す2種類の動物の移動データを用いて行う。

海鳥. 新潟県岩船郡粟島に生息するオオミズナギドリ (*Calonectris leucomelas*) に取り付けたセンサデータロガー (Axy-Trek, Technosmart, Italy) から得られた GPS と水深センサデータを用いる。オオミズナギドリは、飛行中に海中へ飛び込むため、水深センサデータを取得している。これらのデータを提案手法を用いて分析することで、飛び込み行動と移動モードの関係性に関するルールが抽出されることが期待される。データ取得の詳細は文献 [18] に示す通りである。GPS データのサンプリング間隔は約1分であり、水深センサのサンプリングレートは1.0 Hz である。分析に用いた軌跡の数は39であり、その平均長は364時間、平均データ点数は17,677である。複数の軌跡を提案手法で分析するため、抽出した特徴時系列データを連結して提案手法に入力した。

移動軌跡からは、速度 [m/s]、加速度とその絶対値 [m/s²]、角速度 [rad/s]、速度の移動平均・移動分散、加速度の移動平均・移動分散、角速度の移動平均・移動分散を計算した。移動平均・分散の窓幅は10, 20, 30, 40, 50分に設定してそれぞれ計算した。すなわち、移動軌跡からは34の特徴時系列データを抽出した。クラスタリングパラメータである α は4から20、 β は2から7まで1きざみで変化させた。

水深センサデータは、1分おきに平均をとることで、GPS データのサンプリング間隔に合わせた。そして、そのデータに対して微分を計算したあと、絶対値を計算した。この処理により、オオミズナギドリが海に飛び込んだタイミングを表す時系列データが得られる。水深センサデータからは、1つの特徴時系列データを抽出した。クラスタリングパラメータである α は4から20まで1きざみで変化させ、 β は2と3とした。

コウモリ. 北海道大学苫小牧研究林において16chのマイクロホンアレイを用いて計測した採餌飛行中のモモジロコウモリ (*Myotis macrodactylus*) の3次元座標のデータを用いる。コウモリが採餌のために利用する池の周囲を4基のマイクロホンアレイで囲み、3次元座標および超音波の放射間隔を計測した。マイクロホンアレイによるデータ取得の詳細は文献 [8] に示すとおりである。コウモリが超音波を発した際、三辺測定の原理を用いてその3次元座標を計測する。また、コウモリは虫を捕食するタイミングで、通常の探索時よりもきわめて短い間隔で超音波を発するため [8]、いつどこで捕食を行ったかを知ることができる。分

析に用いた軌跡の数は7であり、その平均長は67.97秒、平均データ点数は971である。

移動軌跡からは、3次元空間での速度、2次元水平面での速度、鉛直方向の速度 [m/s] および加速度 [m/s²]、角速度 [rad/s]、それらの移動平均と移動分散を計算した。移動平均の窓幅は1, 2, 3, 4, 5秒に設定してそれぞれ計算した。すなわち、移動軌跡からは70の特徴時系列データを抽出した。クラスタリングパラメータである α は4から20、 β は3から7まで1きざみで変化させた。

移動軌跡とともに分析するセンサデータとしては、コウモリの捕食位置から算出した、コウモリの現在位置周辺の虫の密度の情報を用いた。捕食対象とする虫は短時間では群をなして1カ所に停滞しているとみなし、捕食位置から虫の空間密度を求めた。具体的には、コウモリの現在位置から半径 r メートル以内に存在する捕食位置の数をすべての捕食回数で割った値の時系列データを特徴時系列データとした。 r は、0.5, 1.0, 1.5, 2.0に設定してそれぞれ計算した。すなわち、4の特徴時系列データを抽出した。クラスタリングパラメータである α は20から4、 β は3から7まで1きざみで変化させた。

4.2 評価手法

本実験では、以下の手法を評価した。

- Proposed: 提案手法
- w/o symbol: 手順1-2におけるシンボル化の結果を再利用しない手法
- w/o reduce: 手順2-1におけるグラフのノード数を削減しない手法

上のすべての手法の出力は同じであるため、本実験では計算時間による比較を行った。すべての手法はC++で実装されており、実験は、3.4 GHz Intel Core i7 および 16 GB RAM で構成される PC 上で行った。

4.3 評価結果

上記の手法をオオミズナギドリとモモジロコウモリのデータセットに適用した際の評価結果を表1と表2に示す。表に示すとおり、w/o reduceの結果では、データポイント数のノードから構成されるグラフのスペクトラルクラスタリングに非常に長時間を要する。Proposedでは、グラフのノード削減により大幅に計算時間を削減できている。削減を行わなかった場合のノード数はオオミズナギドリとモモジロコウモリのデータセットにおいて、11,292 および 6,805 であり、Proposedではそれらをシンボル数にまで削減している。w/o symbolと比較すると、Proposedのセグメンテーションに要する時間は2/3程度となっている。削減割合は小さいものの、SAXに要する計算時間が長い場合、オオミズナギドリのデータでは約2秒ほどの削減となっている。実験の設定では α の最大値が20であるた

表 1 オオミズナギドリのデータセットを用いた際の各手法の時系列クラスタリングに要した計算時間 (秒).

Table 1 Efficiency evaluation of Streaked Shearwater: Running time [sec].

	セグメンテーション	クラスタリング	合計
Proposed	4.41	6.45	10.86
w/o symbol	7.07	6.47	13.54
w/o reduce	4.43	1.50×10^5	1.50×10^5

表 2 モモジロコウモリのデータセットを用いた際の各手法の時系列クラスタリングに要した計算時間 (秒).

Table 2 Efficiency evaluation of Japanese Large-footed Bat: Running time [sec].

	セグメンテーション	クラスタリング	合計
Proposed	6.12	6.47	12.59
w/o symbol	8.93	6.50	15.43
w/o reduce	6.20	1.00×10^4	1.00×10^4

表 3 Proposed と w/o reduce のメモリ使用量 (メガバイト).

Table 3 Memory usage of Proposed and w/o reduce [MB].

	オオミズナギドリ	モモジロコウモリ
Proposed	2.09×10^1	1.13×10^1
w/o reduce	2.04×10^3	7.68×10^2

め, シンボル化の結果の再利用ができるのは α が 10 以下となつてからである.

表 3 に, Proposed と w/o reduce のメモリ使用量を示しており, グラフのノード数の削減が, メモリ使用量にも大きな効果があることが分かる (w/o symbol のメモリ使用量は Proposed と同様である). Proposed のメモリ使用量は非常に小さく, オオミズナギドリ (モモジロコウモリ) において, Proposed のメモリ使用量は, w/o reduce の約 1/100 (1/70) である. また, w/o reduce は, データ点の数が多いたデータはメモリに乗らないことが予測され, メモリ使用量の観点からも実践性に乏しい.

最後に, それぞれのデータセットから得られた最も有用性の高かったルールを紹介する. なお, ルールの検証はオオミズナギドリおよびコウモリを専門とする生物学者と行ったものである. オオミズナギドリのデータセットから得られた最も有用性の高かったルールは, 「加速度の絶対値の時系列 ($\alpha = 16, \beta = 9$)」と「深度センサの微分の絶対値の時系列 ($\alpha = 7, \beta = 3$)」のモード分けから得られたものであった. 「加速度の絶対値の時系列」から得られた, 「加速度の絶対値が大きいモード (約 2 m/s^2 以上)」と「深度センサの微分の絶対値が大きいモード (約 0.7 Pa/s 以上)」がよく共起していた. Corr の値は 0.37, Freq の値は 40405/547990 であった. 図 4 に, それぞれのモードに対応するセグメントを赤色でハイライトした, ある個体から収集された軌跡データを示す. また, その際のそれぞれの時系列データも示す. 赤色でハイライトされたデータ点

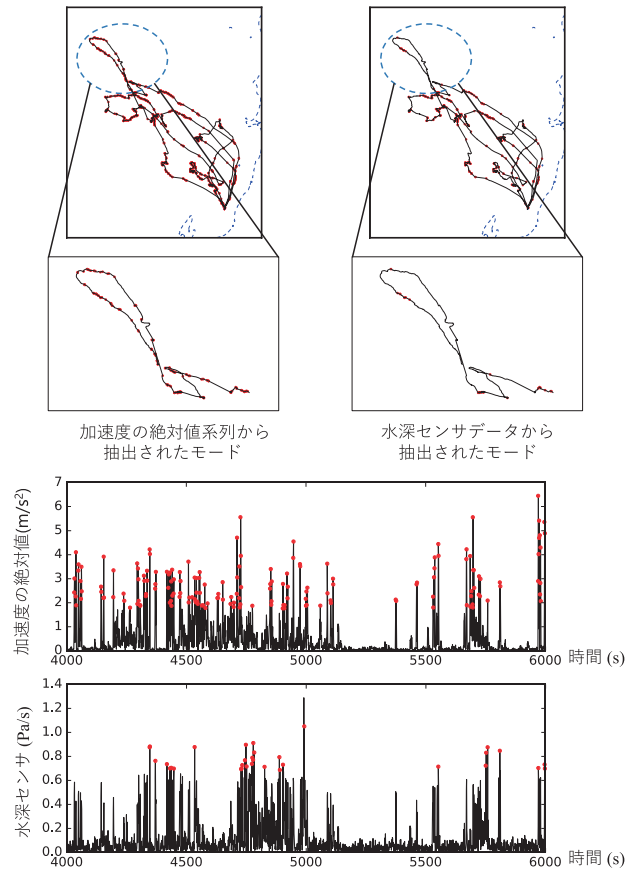


図 4 オオミズナギドリのデータから得られたルールの例

Fig. 4 Example result of Streaked Shearwater.

が, 上記のモードに対応するデータ点である. 加速度の絶対値から得られたモードは「速度を急激に変更するモード」, 深度センサの微分の絶対値から得られたモードは「海に深く飛び込むモード」ということができる. 採餌行動中のオオミズナギドリは頻りに速度を変更するため, この結果は採餌行動中に餌を見つけた際に深く飛び込んで魚を捕まえていることを示している. 一方で, 高速移動を行う「巡航モード」中にも飛び込みを行っており, オオミズナギドリは移動モードによって海への飛び込み方が異なることが示唆される. 巡航モード中は移動速度が早いため, 海面付近の魚をとらえるもしくはまったく別の理由で飛び込みを行ったと考えられる. 以上のような, 移動モードによって飛び込み方を変更するといった知見は, オオミズナギドリの研究ではこれまでになかったものであり, 時系列データを網羅的に検証する提案手法によって得られたものである.

モモジロコウモリのデータセットから得られた最も有用性の高かったルールは, 「水平面速度の時系列 ($\alpha = 8, \beta = 3$)」と「コウモリの現在位置周辺の虫の密度の時系列 ($\alpha = 13, \beta = 3, r = 0.5 \text{ m}$)」のモード分けから得られたものであった. 「水平面速度が遅いモード (約 2 m/s 以下)」と「コウモリの現在位置周辺の虫の密度が高いモード (約 0.06 以上)」がよく共起していた. Corr の値は 0.53, Freq

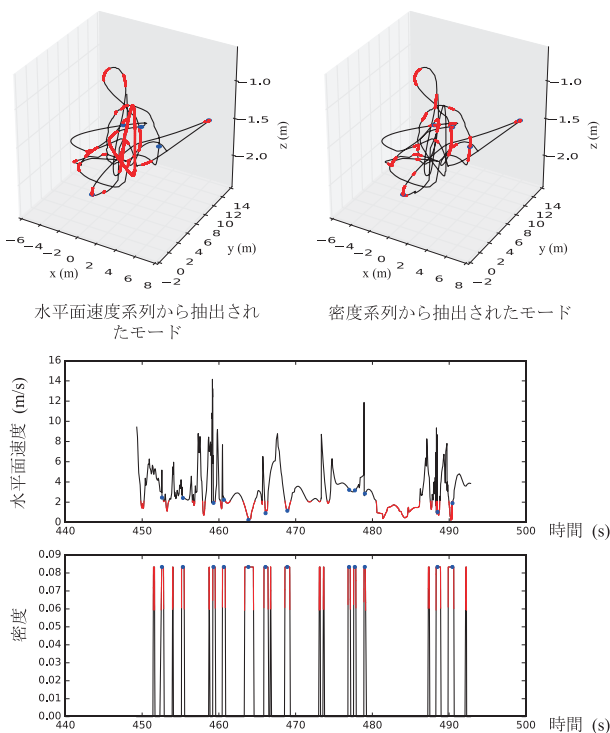


図5 モモジロコウモリのデータから得られたルール
Fig. 5 Example result of Japanese Large-footed Bat.

の値は 92592/403249 であった。すなわち、コウモリの周囲 0.5 m 以内の虫の密度（すなわち過去と未来を通じて起こった捕食地点の密度）が高いとき、遅い速度で移動していた。図5に、それぞれのモードに対応するセグメントを赤色でハイライトした、ある個体から収集された3次元軌跡データを示す。また、その際のそれぞれの時系列データもグラフに示す。赤色のセグメントが抽出されたモードに対応し、青色のドットはコウモリが餌を捕食したタイミングを示す。密度の時系列データに示すとおり、コウモリは高速で移動しているため、0.5 m 以内に捕食地点が含まれる時間は短く、密度の値が瞬間的に上昇している。また多くの場合、この瞬間的な上昇は捕食のタイミングに対応している。すなわち、餌にアプローチしているタイミングで速度が遅くなるということができ、コウモリが尾膜*1で餌をすくい取る際に、速度に制限をかけている可能性が示唆された。この知見は、モモジロコウモリ以外のコウモリでは検証されているが [11], [12], [26], モモジロコウモリに関して捕食と速度の関係に関する研究は行われていない。また、この知見が移動データの網羅的検証により、計算機により自動的に得られたものであることに価値があると考ええる。

5. おわりに

本論文では、移動体から得られたマルチモーダル時系列データから高速に頻出ルールを抽出する手法の提案を行っ

*1 コウモリの尾と後ろ足の間の膜であり、餌の採取に用いられる。

た。これまでの時系列データからのクラスタリングでは、数ある特徴量の中からクラスタリングに用いる特徴量およびそのパラメータを、研究者の先験的な知見から主観的に一意に決定していた。一方、提案手法ではルール抽出と同時に特徴およびパラメータ選択も同時に行う。このとき、適切な特徴およびパラメータを発見するため、高速にクラスタリングを繰り返しつつルール抽出を行う。評価実験では、提案手法を用いて海鳥およびコウモリから得られた軌跡データの分析を行い、計算時間削減を行わない単純な手法に比べて大幅な計算時間の削減を確認した。今後は、それぞれの動物から得られた頻出ルールの生物学的意味の詳細な検証を行う予定である。

謝辞 本研究の一部は、JSPS 科研費 JP16H06539, JP16H06542, JP16H06541 の研究助成によるものである。ここに記して謝意を表す。

参考文献

- [1] Aghabozorgi, S., Shirkhorshidi, A.S. and Wah, T.Y.: Time-series clustering – A decade review, *Information Systems*, Vol.53, pp.16–38 (2015).
- [2] Alippi, C., Ambrosini, R., Longoni, V., Cogliati, D. and Roveri, M.: A lightweight and energy-efficient Internet-of-birds tracking system, *IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp.160–169 (2017).
- [3] Arthur, D. and Vassilvitskii, S.: k-means++: The advantages of careful seeding, *ACM-SIAM Symposium on Discrete Algorithms (SODA)*, pp.1027–1035 (2007).
- [4] Camera, A., Shieh, J., Palpanas, T., Rakthanmanon, T. and Keogh, E.: Beyond one billion time series: Indexing and mining very large time series collections with iSAX2+, *Knowledge and Information Systems*, Vol.39, No.1, pp.123–151 (2014).
- [5] Christopher, D.M., Prabhakar, R. and Hinrich, S.: Introduction to information retrieval, *An Introduction To Information Retrieval*, Vol.151, p.177 (2008).
- [6] Denton, A.M., Besemann, C.A. and Dorr, D.H.: Pattern-based time-series subsequence clustering using radial distribution functions, *Knowledge and Information Systems (KIS)*, Vol.18, No.1, pp.1–27 (2009).
- [7] Ding, R., Wang, Q., Dang, Y., Fu, Q., Zhang, H. and Zhang, D.: Yading: Fast clustering of large-scale time series data, *PVLDB*, Vol.8, No.5, pp.473–484 (2015).
- [8] Fujioka, E., Aihara, I., Watanabe, S., Sumiya, M., Hiryu, S., Simmons, J.A., Riquimaroux, H. and Watanabe, Y.: Rapid shifts of sonar attention by *Pipistrellus abramus* during natural hunting for multiple prey, *The Journal of the Acoustical Society of America*, Vol.136, No.6, pp.3389–3400 (2014).
- [9] Gwadera, R. and Crestani, F.: Discovering Significant Patterns in Multi-stream Sequences, *IEEE International Conference on Data Mining (ICDM)*, pp.827–832 (2008).
- [10] Johnson, M.J. and Willsky, A.S.: Bayesian Nonparametric Hidden Semi-Markov Models, *Journal of Machine Learning Research*, Vol.14, No.1, pp.673–701 (2013).
- [11] Jones, G. and Rayner, J.: Flight performance, foraging tactics and echolocation in free-living Daubenton's bats *Myotis daubentoni* (Chiroptera: Vespertilionidae), *Jour-*

- nal of Zoology*, Vol.215, No.1, pp.113–132 (1988).
- [12] Jones, G. and Rayner, J.: Flight performance, foraging tactics and echolocation in the trawling insectivorous bat *Myotis adversus* (Chiroptera: Vespertilionidae), *Journal of Zoology*, Vol.225, No.3, pp.393–412 (1991).
- [13] Kabra, M., Robie, A.A., Rivera-Alba, M., Branson, S. and Branson, K.: JAABA: Interactive machine learning for automatic annotation of animal behavior, *Nature Methods*, Vol.10, No.1, pp.64–67 (2012).
- [14] Krumm, J. and Brush, A.B.: Learning time-based presence probabilities, *International Conference on Pervasive Computing*, pp.79–96 (2011).
- [15] Li, Y., Yiu, M.L., Gong, Z., et al.: Quick-motif: An efficient and scalable framework for exact motif discovery, *IEEE International Conference on Data Engineering (ICDE)*, pp.579–590 (2015).
- [16] Lin, J., Keogh, E., Wei, L. and Lonardi, S.: Experiencing SAX: A novel symbolic representation of time series, *Data Mining and Knowledge Discovery*, Vol.15, No.2, pp.107–144 (2007).
- [17] Liu, J., Wang, C., Danilevsky, M. and Han, J.: Large-scale spectral clustering on graphs, *IJCAI*, pp.1486–1492 (2013).
- [18] Matsumoto, S., Yamamoto, T., Yamamoto, M., Zavalaga, C.B. and Yoda, K.: Sex-related differences in the foraging movement of Streaked Shearwaters *Calonectris leucomelas* breeding on Awashima Island in the Sea of Japan, *Ornithological Science*, Vol.16, No.1, pp.23–32 (2017).
- [19] Mohammad, Y., Nishida, T. and Okada, S.: Unsupervised simultaneous learning of gestures, actions and their associations for Human-Robot Interaction, *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.2537–2544 (2009).
- [20] Ng, A.Y., Jordan, M.I. and Weiss, Y.: On spectral clustering: Analysis and an algorithm, *Advances in Neural Information Processing Systems*, pp.849–856 (2002).
- [21] Paparrizos, J. and Gravano, L.: k-shape: Efficient and accurate clustering of time series, *ACM SIGMOD International Conference on Management of Data*, pp.1855–1870 (2015).
- [22] Paparrizos, J. and Gravano, L.: Fast and Accurate Time-Series Clustering, *ACM Trans. Database Systems (TODS)*, Vol.42, No.2, p.8 (2017).
- [23] Peng, W.-C. and Liao, Z.-X.: Mining sequential patterns across multiple sequence databases, *Data Knowledge Engineering (DKE)*, Vol.68, No.10, pp.1014–1033 (2009).
- [24] Rakthanmanon, T., Keogh, E.J., Lonardi, S. and Evans, S.: Time series epenthesis: Clustering time series streams requires ignoring some data, *IEEE International Conference on Data Mining (ICDM)*, pp.547–556 (2011).
- [25] Rutz, C. and Hays, G.C.: New frontiers in biologging science (2009).
- [26] Schnitzler, H.-U., Kalko, E., Miller, L. and Surlykke, A.: The echolocation and hunting behavior of the bat, *Pipistrellus kuhli*, *Journal of Comparative Physiology A: Neuroethology, Sensory, Neural, and Behavioral Physiology*, Vol.161, No.2, pp.267–274 (1987).
- [27] Vahdatpour, A., Amini, N. and Sarrafzadeh, M.: Toward Unsupervised Activity Discovery Using Multi-dimensional Motif Detection in Time Series, *Proc. 21st International Joint Conference on Artificial Intelligence, IJCAI'09*, pp.1261–1266 (2009).
- [28] Valletta, J.J., Torney, C., Kings, M., Thornton, A. and Madden, J.: Applications of machine learning in animal behaviour studies, *Animal Behaviour*, Vol.124, pp.203–220 (2017).
- [29] White, S. and Smyth, P.: A spectral clustering approach to finding communities in graphs, *Proc. 2005 SIAM International Conference on Data Mining*, pp.274–285, SIAM (2005).
- [30] Yan, D., Huang, L. and Jordan, M.I.: Fast approximate spectral clustering, *the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.907–916, ACM (2009).
- [31] Yuan, J., Zheng, Y., Zhang, C., Xie, W., Xie, X., Sun, G. and Huang, Y.: T-drive: Driving directions based on taxi trajectories, *SIGSPATIAL International Conference on Advances in Geographic Information Systems (GIS)*, pp.99–108 (2010).
- [32] Zhang, J., O'Reilly, K.M., Perry, G.L.W., Taylor, G.A., Dennis, T.E.: Extending the Functionality of Behavioural Change-Point Analysis with k-Means Clustering: A Case Study with the Little Penguin (*Eudyptula minor*), *PLOS ONE*, Vol.10, No.4, pp.1–14 (2015).
- [33] Zhu, X. and Wu, X.: Discovering relational patterns across multiple databases, *IEEE International Conference on Data Engineering (ICDE)*, pp.726–735 (2007).



田一鳴 (学生会員)

2015年ハルビン工業大学卒業。2018年大阪大学大学院情報科学研究科博士前期課程修了。同年同大学院情報科学研究科博士後期課程在学中。動物における時系列パターンの認識に関する研究に従事。



前川卓也 (正会員)

2006年大阪大学大学院情報科学研究科博士後期課程修了。2006年NTTコミュニケーション科学基礎研究所入所。2012年より大阪大学大学院情報科学研究科マルチメディア工学専攻准教授、現在に至る。ユビキタスコンピューティング、ウェアラブルセンシングに関する研究に従事。2010年度情報処理学会山下記念研究賞、2013年度日本データベース学会上林奨励賞、2015年電気学会優秀論文発表A賞等受賞。IEEE, ACM, 電気学会, 日本神経科学会, 日本データベース学会の各会員。




天方 大地 (正会員)

2012年大阪大学工学部電子情報工学科卒業。2014年同大学大学院情報科学研究科博士前期課程修了。2015年同大学院情報科学研究科博士後期課程修了後、同年同大学院情報科学研究科マルチメディア工学専攻助教となり、現在に至る。情報科学博士。データベース、ネットワーク環境におけるデータ検索技術に関する研究に従事。IEEE, ACM, 日本データベース学会の各会員。



原 隆浩 (正会員)

1995年大阪大学工学部情報システム工学科卒業。1997年同大学大学院工学研究科博士前期課程修了。同年同大学院工学研究科博士後期課程中退後、同大学院工学研究科助手、2002年同大学院情報科学研究科助手、2004年同大学院情報科学研究科准教授。2015年より同大学院情報科学研究科教授となり、現在に至る。工学博士。1996年本学会山下記念研究賞受賞。2000年電気通信普及財団テレコムシステム技術賞受賞。2003年本学会研究開発奨励賞受賞。2008年、2009年本学会論文賞、2015年日本学術振興会賞受賞。2017年大阪科学賞受賞。モバイルコンピューティング、ネットワーク環境におけるデータ管理技術に関する研究に従事。IEEE, ACM, 電子情報通信学会, 日本データベース学会の各会員。



松本 祥子

名古屋大学大学院環境学研究科博士後期課程在籍。2013年名古屋大学大学院環境学研究科博士前期課程修了、修士(環境学)。専門は、海鳥の行動生態学。



依田 憲

京都大学理学部卒業後、同博士課程修了、博士(理学)。京都大学大学院理学研究科リサーチフェロー、日本学術振興会海外特別研究員・特別研究員を経て、2014年より名古屋大学大学院環境学研究科教授。日本動物行動学会、日本バイオリギング研究会等の会員。



藤岡 慧明

博士(工学)。2013年同志社大学大学院生命医科学研究科博士後期課程修了、同年、JST FIRST 最先端数理モデルプロジェクト研究員、2014年同志社大学特別任用助手、2016年より同志社大学特別研究員、現在に至る。専門は生物音響工学。日本音響学会、海洋音響学会、生物音響学会、日本バイオリギング研究会等の会員。



濱井 郁弥

2017年同志社大学生命医科学部卒業、同年同志社大学大学院生命医科学研究科博士前期課程に入学、現在に至る。野生コウモリの採餌行動、特に同一餌場での個体間の相互作用の研究に興味を持つ。



福井 大

2004年北海道大学大学院農学研究科博士後期課程修了。博士(農学)。学振特別研究員(森林総合研究所北海道支所)、韓国国立生物資源館外国人特別研究員、和歌山大学特任助教、東京大学特任助教を経て、15年より東京大学助教、現在に至る。13年日本哺乳類学会奨励賞。日本哺乳類学会、日本生態学会、生物音響学会会員。



飛龍 志津子

1999年日本アイ・ビー・エム株式会社に入社。2006年同志社大学大学院工学研究科博士後期課程修了。博士(工学)。2008年同志社大学生命医科学部助教、2017年教授。2014年JST さきがけ研究員。2013年文部科学大臣表彰若手科学者賞、2018年日本学術振興会賞受賞。日本音響学会、海洋音響学会、動物行動学会各会員。