

# センサデータによる行動認識のための ベイズ的隠れマルコフモデルの拡張と適用

菅野 隼<sup>1,a)</sup> 松重 龍之介<sup>1</sup> 岡留 剛<sup>1,b)</sup>

受付日 2016年12月22日, 採録日 2017年7月4日

**概要:** センサデータから日常生活行動を分類することを目的として, 10 から 100 個程度の比較的少数の学習データから高い精度で時系列分類する教師あり学習手法を提案する. 具体的には, Tied-Mixture Hidden Markov Model (TM-HMM) をベイズモデルに拡張し, また, HMM の潜在変数の状態数を自動決定する Infinite Hidden Markov Model (I-HMM) を援用した手法, BTM-HMM を提案する. TM-HMM は, 時系列分類モデルである HMM をクラスごとに用意し, 各クラスの HMM の出力を無限混合としたモデルである. 本研究では, パラメータの事前分布としてディリクレ過程を導入し TM-HMM をベイズ的に取り扱い, 事後確率の最大化により, HMM の状態数や混合分布の要素数を自動的に決定する. また, 提案手法は, 日常生活行動にともなう加速度データから, 「歩く」や「走る」といった周期的な動作と, 「椅子に座る」などの非周期的な動作をランダムフォレストにより選別し, それぞれのタイプに対して異なる特徴量を用いて BTM-HMM で多クラス分類を行う. 比較的少数の学習データによる学習において, ベースラインとする SVM (Support Vector Machine) や KLR (Kernel Logistic Regression) より高く, また TM-HMM と同等以上の識別率を示した.

**キーワード:** センサデータ, 行動認識, 隠れマルコフモデル, ディリクレ過程, ノンパラメトリックベイズ

## Daily Activity Recognition from Sensor Data Based on Nonparametric Bayesian HMM

JUN KANNO<sup>1,a)</sup> RYUNOSUKE MATSUSHIGE<sup>1</sup> TAKESHI OKADOME<sup>1,b)</sup>

Received: December 22, 2016, Accepted: July 4, 2017

**Abstract:** The learning method proposed here constructs a classifier that classifies daily living activities from sensor data that consist of 10 to 100 samples for each of activity classes. The method uses a model, BTM-HMM, that extends the Tied-Mixture Hidden Markov Model (TM-HMM) to a Bayes model by introducing a Dirichlet process into parameters as their priors and determines the number of components in the mixture model by maximizing the posteriors. The BTM-HMM also assumes the Infinite Hidden Markov Model (I-HMM) that determines the number of states in HMM by introducing a Dirichlet process into latent variables as their priors. Furthermore, the learning method divides the daily activities into two types: the periodic activities such as “walk” and “run” and the aperiodic activities such as “sit on a chair.” For learning, it uses different features for the two types of the activities and it infers the activity type of the test data by the Random Forests. The experiments using acceleration data show that the precisions and recalls of multi-class classification by the method are higher than those by SVM and KLR.

**Keywords:** sensor data, activity recognition, hidden Markov model, Dirichlet process, nonparametric Bayes

### 1. はじめに

センサの普及にともない, 人やモノに装着したセンサから得られるデータを解析し, 人の行動やモノの状態を推定する研究が活発に行われている. たとえば, HASC (Human

<sup>1</sup> 関西学院大学  
Kwansei Gakuin University, Sanda, Hyogo 669–1337, Japan  
<sup>a)</sup> jun.kanno@kwansei.ac.jp  
<sup>b)</sup> tokadome@acm.org

Activity Sensing Consortium) [14] と呼ばれる研究団体は、さまざまな大学や研究機関で取得されたセンサデータを収集して大規模なデータベースを構築・公開し、行動認識に関する研究を促進している。行動認識の技術は、周辺機器の制御や介護支援などの多様なコンテキストウェアサービスへの応用が期待されている。

センサデータから日常生活行動を分類する場合には、通常、教師あり学習を用いて多クラス分類器を作成する。教師あり学習による行動認識の研究は数多く存在し、それらは、データの時系列性を加味せずに、単一行動の全時間区間における加速度の平均値やゼロクロスといった多次元の量の特徴として分類器を作成するものと、単一の行動時間区間を短い時間区間に分け各区間の特徴量を用いて、データの時系列性を反映させるように、たとえば隠れマルコフモデル (HMM) により分類器を構築するものとに大別される。

時系列性の情報を落として学習する場合でも、十分な数の学習データがあれば精度が高い分類器ができる。しかし、大量のデータの収集や、データのラベル付けに対するコストが問題となる。それに対し、学習データ数が少ない場合でも、内在する情報を十分に活用すれば比較的少数のデータでも分類精度の向上が期待できる。また、日常生活行動は人体の運動そのものであり、そこから得られる加速度やジャイロなどのセンサデータは時系列構造を有する。それゆえ、とりわけ比較的少数の学習データからの学習において、時系列性を考慮した分類器は時系列情報を取り扱うため、時系列性を加味しない分類器よりも高い精度の分類結果が得られると期待される。一般に、認識課題におけるデータの時系列性を反映されるために HMM が用いられているが、出力がガウス分布など単峰性の分布を仮定する識別学習を用いた HMM では、たとえば、個人差などに起因する出力の多峰性により精度向上に限界が生じる。

これに対し、Tied-Mixture Hidden Markov Model (TM-HMM) [3] は、出力に混合分布を導入することによりこの問題を回避している。しかし、本論文 6 章で示すように、TM-HMM における学習では、多峰性分布の尤度最大化によるため計算が発散することがしばしば起こる。この発散は、学習のデータ数が少ない場合に特に顕著である。また、TM-HMM では、出力分布の混合数をあらかじめ定めておく必要があるが、それは一般には明らかではない。

また、学習で用いるデータのラベル付与は、通常、人手で行われるため、大量のデータにラベルを付与するのにコストがかかる。したがって本研究では、比較的低コストでのラベル付与が可能と思われる 10 個から 100 個の学習データを用いる。

本研究は、各クラス 10 から 100 個程度の比較的少数の学習データで高い精度を出す分類器の構築を目指し、TM-HMM を拡張して、そこに、潜在変数およびパラメータの

事前分布を導入したベイズモデルを提案する。とりわけ提案手法は、パラメータに対する事前分布を仮定することにより計算の発散問題を回避し、潜在変数にディリクレ過程事前分布を導入して、事後確率の最大化に基づき HMM の状態数および混合分布の要素数を観測データから自動的に決定する。HMM の状態数および混合分布の要素数は、日常生活行動の種類ごとに異なる可能性があり、これをとらえることは認識率の向上に寄与すると考える。事後確率の最大化は、誤識別率の最小化と等価 [4] であり、その意味でも、センサデータからの行動分類器構築において有用なモデルであると考えられる。

本研究では、さらに、日常生活行動を、(1)「歩く」や「走る」といった周期的な身体動作をとともなう行動（以下、周期的な運動）と、(2)「椅子に座る」や「立ち上がる」・「横たわる」といった周期的な動作を含まない単発的な行動（以下、非周期的な運動）とに大別し、それぞれ異なる特徴量を用いて学習データから上記のベイズ化された TM-HMM により周期的・非周期的な運動のそれぞれに対する分類器を作成する。新たにきたデータに対しては、まずランダムフォレストにより周期・非周期のどちらに属するかを推定し、その推定結果に応じた上記分類器で行動を分類する。

本研究では、(1) 周期的な運動をとともなう行動からなる HASC (Human Activity Sensing Consortium) の加速度データセット、(2) 非周期的な運動をとともなう行動と、周期的な運動をとともなう行動の両者を含む Daily and Sports Activities の加速度データセットを使用して、比較的少数の学習データによる分類実験を行った。その実験において、本提案手法はベースラインとする SVM (Support Vector Machine) や KLR (Kernel Logistic Regression) より高く、また TM-HMM と同等以上の識別率を示した。

以下、2 章では、センサデータによる行動認識や時系列分類モデルに関する先行研究を概観し、3 章では、隠れマルコフモデルの混合モデルについて詳述する。4 章では、時系列データの分割手法と、TM-HMM をベイズモデルに新たに拡張した手法、BTM-HMM、を提案する。5 章では、本研究で使用する行動の加速度データを紹介し、3 軸加速度データから抽出する特徴量を述べる。6 章では、提案手法を周期的・非周期的な運動の 3 軸加速度データに適用した実験結果を示す。7 章では、実験結果に対する議論を行い、8 章でまとめる。

## 2. 関連研究

### 2.1 行動認識

数多くの先行研究があるが、ここでは代表的なものと、近年の成果をあげる。Bao ら [1] は、「歩く」や「走る」・「自転車に乗る」・「掃除をする」・「食事をする」などの 20 種類の行動を分類している。20 名の実験参加者の手首や肘・腰・足首・膝の 5 カ所に、サンプリングレートが 76.25 Hz

の2軸加速度センサを取り付け、行動データを収集している。文献[1]で用いられている特徴量は、平均やエネルギー・エントロピー・相関である。本研究では、加速度データから特徴量を抽出する際に、これらの特徴量を参考にしている。

文献[5]では、ユーザがバランス良くウェイトトレーニングを行えるように9種類のダンベルを用いた行動を識別し、各々の行動に対して実行回数を自動的に数えるシステムを提案している。実験参加者の手首と腰の2カ所に3軸加速度センサを取り付け、ダンベルを用いた9種類の動作を分類している。この研究では、動作ごとに3軸の中で加速度の変化量が最大となる主軸を決定し、加速度信号の主軸成分から特徴量を抽出している。特徴量には、切り出した窓ごとの速度、正・負方向のピーク値の平均が用いられている。分類器には、ナイーブベイズと隠れマルコフモデル(HMM)が用いられている。

文献[7]では、1軸加速度センサ(ADXL05)を利用して行動を推定する研究を行っている。1軸加速度センサを腕、背中に取り付け、ジャケットを装着し、「立つ」、「座る」、「寝る」、「歩く」、「走る」の静止状態や行動の状態を対象として識別を行っている。特徴量には、加速度データの垂直方向の最大と最小加速度の差分、重力加速度の大きさ、交差数が用いられている。

文献[19]では、HASC 2010 corpusを利用して、一般的な特徴量から新たな特徴量を加えて行動推定を行った。3軸加速度センサを実験参加者の腰に取り付けて、「静止」、「歩く」、「座る」、「スキップ」、「階段を上る」、「階段を下る」の6種類の行動を対象として識別を行っている。特徴量には、平均、分散、周波数領域ごとのエネルギー(3.91~6.25 Hz, 7.03~12.50 Hz, 13.28~25.00 Hz, 25.78~50.00 Hz)、零点交差率、加速度の積分値が用いられている。分類器には、決定木が用いられている。

文献[13],[24]は、「血圧測定」や「採血」・「車いす介助」などの22種類の看護師行動を分類している。看護師の両手首や胸ポケット・腰の4カ所に3軸加速度センサを取り付け、行動データを収集している。文献[24]で用いられている分類器は、決定木やランダムフォレスト・隠れマルコフモデルなどであり、隠れマルコフモデルが最も高い識別率を示している。本研究においても、隠れマルコフモデルを用いた時系列分類法を検討する。

文献[16]は、加速度データのコンテキスト認識に関する研究を行っている。加速度値の自己相関を用いてコンテキストを姿勢と行動・ジェスチャに分類し、適切な方法でコンテキストを認識する手法を提案している。5種類の行動の中にある7種類のジェスチャに対する認識のリコールと精度を評価し、従来手法に比べて高い識別性能を得ている。

一般的に行動分類を行う研究では、前処理を行わずすべての行動を混同させて分類する手法と、前処理を行い行動

を大きな集合に分けてから行動を分類する手法に大別される。文献[1]は、周期的な身体動作をとまなう行動と、周期的な動作を含まない行動を分けるような前処理を行わず、同じ特徴量と分類器を用いて、それらの行動の学習と分類を行っている。それに対し、文献[16]では、周期的な運動以外にも認識するため、前処理として自己相関を用いて動作や状態の違いを明確にして行動を認識する。本研究でも、後者の前処理を行う手法を用いる。さらに、日常生活行動に含まれる周期的な運動だけでなく、非周期的な運動も正確に分類するための前処理として、運動の加速度データからパワースペクトルや差分値・加速度の大きさを特徴量とし、周期的な運動と非周期的な運動を大別する手法を提案する。

次に、本研究でも用いる階層ディリクレ過程を行動認識の手法に用いている研究について述べる。文献[10],[20]は、行動の認識に階層ディリクレ過程隠れマルコフモデル(HDP-HMM)を用いて、隠れマルコフモデルの状態数を観測データから自動で決定している。文献[10]は、センサデータから異常な行動を検知するモデルとして、HDP-HMMとFisherカーネルをOne-Class Support Vector Machine(OCSVM)モデルに組み込んだモデルを組み合わせた異常行動検知モデルを提案している。文献[20]は、骨格関節位置に基づく特徴を用いて、連続深度画像において生じる人間の動作を分類する研究を行っている。分類モデルとして、HDP-HMMを使用している。

本研究は、文献[10],[20]と異なり、階層ディリクレ過程を用いて隠れマルコフモデルの状態数を観測データから自動的に決定するだけでなく、隠れマルコフモデルの出力分布に混合ガウス分布を仮定し、混合分布の要素数もデータから自動的に決定する。さらに、混合分布の決定において、事前分布を導入しベイズ的に扱うことにより、パラメータ推定の計算が発散する問題と過学習の問題を回避する。

## 2.2 ディリクレ過程混合モデル

分類モデルの1つに混合分布モデル[17]がある。混合分布モデルは、各クラスのデータがある分布に従うと仮定し、各クラスの分布を混合したモデルである。たとえば、各クラスのデータがガウス分布に従うと仮定し、各クラスのガウス分布を混合した混合ガウスモデルなどがある。さらには、潜在変数の事前分布にディリクレ過程[8]を導入することにより、事後確率の最大化に基づき混合分布の要素数を観測データから自動的に決定する、ディリクレ過程混合モデル(Dirichlet Process Mixture model; DPM)が提案されている。以下で、DPMに関する研究を簡単にまとめる。

文献[21]は、ネスト型無限混合ガウスモデルを提案している。これは、各クラスのデータが混合ガウス分布に従うと仮定し、各クラスの混合ガウス分布を混合させたモデルである。文献[23]は、DPMに基づく拡張結合混合モデル

(Extended Tied-Mixture model; ETM) を提案している。これは、各クラスのデータが混合分布に従うと仮定し、各クラスの混合分布を混合させたモデルである。上述のネスト型無限混合ガウスモデルが各クラスごとに独立な混合分布を用いているのに対し、DPM-ETM はすべてのクラスで共通な混合分布を用いている。すなわち、ネスト型無限混合ガウスモデルは、DPM-ETM の特殊な場合に相当する。

ネスト型無限混合ガウスモデルや DPM-ETM は、各クラスのデータが単一のガウス分布に従うと仮定する Semi-Supervised Gaussian Mixture Model (SSGMM) と比較して、データに対する分布の仮定が柔軟なモデルである。しかし、両モデルは時系列データに対応していない。本研究では、加速度の時系列データを分類するため、DPM に基づく時系列分類モデルを構築する。

### 3. 隠れマルコフモデルの拡張

提案手法のもととなる、隠れマルコフモデルの混合モデルについて詳述する。まず通常の HMM と HMM を拡張したモデルである I-HMM について述べる。次に教師あり学習の Tied-Mixture Hidden Markov Model を概観する。

#### 3.1 隠れマルコフモデル

時系列分類モデルの 1 つに隠れマルコフモデル (Hidden Markov Model; HMM) [6] がある。HMM は、潜在変数のマルコフ連鎖で構成される状態空間モデルである。HMM を混合させることにより、時系列データに対応した混合モデルが得られる。

#### 3.2 Infinite Hidden Markov Model

Infinite Hidden Markov Model (I-HMM) [15] は、観測データから HMM の潜在変数の状態数を自動的に決定するモデルである。通常の HMM を拡張したモデルであり、状態遷移確率分布が階層ディリクレ過程 (HDP) [22] に従っているとし、HDP を用いて潜在変数の状態を推定する。潜在変数の状態の確率の計算は、中華料理店過程 (Chinese restaurant process: CRP) に基づいており、学習ごとに潜在変数の状態の確率と状態数を更新していく。本研究では I-HMM を採用する。

#### 3.3 Tied-Mixture Hidden Markov Model

Tied-Mixture Hidden Markov Model (TM-HMM) [3] は、HMM の出力確率分布に混合ガウス分布を仮定したモデルである。図 1 に、TM-HMM のグラフィカルモデルを示す。

以下、 $\{(\mathbf{X}_i, y_i)\}_{i=1}^l$  をラベルつきデータ、 $l$  をラベルつきデータの個数、 $N_r$  を  $r$  番目の時系列データの長さ、 $Y$  をクラス数、 $D$  を次元数とする。すなわち、入力  $\mathbf{X}_i$  に対するラベルが  $y_i \in \{1, \dots, Y\}$  である。また、 $x_{r,n,1}$  のような表記に対しては  $x_{r,n,1}$  のように「,」を略記して示す。




図 1 TM-HMM のグラフィカルモデル。  $l$  はラベルつきデータの個数、 $\mathbf{x}_{r,n}$  は  $r$  番目の時系列データの時刻  $n$  における  $D$  次元の特徴ベクトル、 $\mathbf{z}_{r,n}$  は  $r$  番目の時系列データの時刻  $n$  の状態、 $\mathbf{m}_{r,n}$  は  $r$  番目の時系列データの時刻  $n$  の混合分布の要素、 $N_r$  は  $r$  番目の時系列データの長さを表す

Fig. 1 Graphical representation of TM-HMM, where  $l$  denotes the number of labeled data,  $\mathbf{x}_{r,n}$  represents the  $D$ -dimensional feature vector at time  $n$  in the  $r$ -th time series,  $\mathbf{z}_{r,n}$  represents the state at time  $n$  in the  $r$ -th time series,  $\mathbf{m}_{r,n}$  represents a component of the Gaussian mixture at time  $n$  in the  $r$ -th time series, and  $N_r$  denotes the length of the  $r$ -th time series.

ここで、 $\mathbf{X}_r = \{\mathbf{x}_{r,1}, \dots, \mathbf{x}_{r,N_r}\}$  は  $r$  番目の時系列データ、 $\mathbf{x}_{r,n} = (x_{r,n,1}, \dots, x_{r,n,D})^T$  は  $\mathbf{X}_r$  の時刻  $n$  における  $D$  次元の特徴ベクトルである。

まず、状態を表す潜在変数  $\{\mathbf{Z}_r\}_{r=1}^l$  を導入する。ここで、 $\mathbf{Z}_r = \{\mathbf{z}_{r,1}, \dots, \mathbf{z}_{r,N_r}\}$ 、 $r$  番目の時系列データの時刻  $n$  の状態  $\mathbf{z}_{r,n} = (z_{r,n,1}, \dots, z_{r,n,U^y})^T$ 、 $z_{r,n,i} \in \{0, 1\}$ 、 $\sum_{i=1}^{U^y} z_{r,n,i} = 1$ 、 $U^y$  はクラス  $y$  の HMM の状態数である。次に、混合分布の要素を表す潜在変数  $\{\mathbf{M}_r\}_{r=1}^l$  を導入する。ここで、 $\mathbf{M}_r = \{\mathbf{m}_{r,1}, \dots, \mathbf{m}_{r,N_r}\}$ 、 $r$  番目の時系列データの時刻  $n$  の混合分布の要素  $\mathbf{m}_{r,n} = (m_{r,n,1}, \dots, m_{r,n,K})^T$ 、 $m_{r,n,k} \in \{0, 1\}$ 、 $\sum_{k=1}^K m_{r,n,k} = 1$ 、 $K$  は混合分布の要素数である。

初期状態  $\mathbf{z}_{r,1}$  の周辺分布は以下で書き表せる。

$$p(\mathbf{z}_{r,1} | y_r) = \prod_{i=1}^{U^{y_r}} \pi_i^{y_r z_{r,1,i}}$$

ここで、 $\{\boldsymbol{\pi}_y\}_{y=1}^Y$ 、 $\boldsymbol{\pi}_y = (\pi_1^y, \dots, \pi_{U^y}^y)^T$ 、 $\pi_i^y \equiv p(z_{r,1,i} = 1 | y)$ 、 $0 \leq \pi_i^y \leq 1$ 、 $\sum_{i=1}^{U^y} \pi_i^y = 1$  である。

状態  $\mathbf{z}_{r,n}$  の確率分布は直前の状態  $\mathbf{z}_{r,n-1}$  に依存する。条件つき確率分布  $p(\mathbf{z}_{r,n} | \mathbf{z}_{r,n-1})$  は遷移確率分布と呼ばれ、以下で書き表せる。

$$p(\mathbf{z}_{r,n} | \mathbf{z}_{r,n-1}, y_r) = \prod_{j=1}^{U^{y_r}} \prod_{i=1}^{U^{y_r}} a_{ij}^{y_r z_{r,n-1,i} z_{r,n,j}}$$

ここで、 $\{\mathbf{A}_y\}_{y=1}^Y$ 、 $\mathbf{A}_y$  は  $(i, j)$  成分が  $a_{ij}^y$  で与えられる  $U^y \times U^y$  の行列、 $a_{ij}^y \equiv p(z_{r,n,j} = 1 | z_{r,n-1,i} = 1, y)$ 、 $0 \leq a_{ij}^y \leq 1$ 、 $\sum_j a_{ij}^y = 1$ 、 $\mathbf{a}_i^y = (a_{i1}^y, \dots, a_{iU^y}^y)^T$  である。

混合分布の要素  $\mathbf{m}_{r,n}$  の確率分布はその時刻の状態  $\mathbf{z}_{r,n}$  に依存する。条件つき確率分布  $p(\mathbf{m}_{r,n} | \mathbf{z}_{r,n})$  は以下で書き表せる。

$$p(\mathbf{m}_{r,n} | \mathbf{z}_{r,n}, y_r) = \prod_{k=1}^K \prod_{j=1}^{U^{y_r}} c_{jk}^{y_r z_{r,n,j} m_{r,n,k}}$$

ここで、 $\{\mathbf{C}_y\}_{y=1}^Y$ ,  $\mathbf{C}_y$  は  $(j, k)$  成分が  $c_{jk}^y$  で与えられる  $U^y \times K$  の行列、 $c_{jk}^y \equiv p(m_{rnk} = 1 \mid z_{rnj} = 1, y)$ ,  $0 \leq c_{jk}^y \leq 1$ ,  $\sum_k c_{jk}^y = 1$ ,  $\mathbf{c}_j^y = (c_{j1}^y, \dots, c_{jK}^y)^T$  である。

観測変数の条件つき確率分布  $p(\mathbf{x}_{rn} \mid \mathbf{z}_{rn})$  は出力確率分布と呼ばれ、以下で書き表せる。

$$p(\mathbf{x}_{rn} \mid \mathbf{z}_{rn}, y_r) = \sum_{\mathbf{m}_{rn}} p(\mathbf{x}_{rn}, \mathbf{m}_{rn} \mid \mathbf{z}_{rn}, y_r) \\ = \sum_{\mathbf{m}_{rn}} p(\mathbf{x}_{rn} \mid \mathbf{m}_{rn}, \mathbf{z}_{rn}, y_r) p(\mathbf{m}_{rn} \mid \mathbf{z}_{rn}, y_r),$$

ここで、 $\mathbf{m}_{rn}$  で条件づけたときに、 $\mathbf{x}_{rn}$  と  $\mathbf{z}_{rn}$ ,  $y_r$  は条件つき独立である。したがって、出力確率分布は以下で書き表せる。

$$p(\mathbf{x}_{rn} \mid \mathbf{z}_{rn}, y_r) = \sum_{\mathbf{m}_{rn}} p(\mathbf{x}_{rn} \mid \mathbf{m}_{rn}) p(\mathbf{m}_{rn} \mid \mathbf{z}_{rn}, y_r).$$

混合分布の要素  $\mathbf{m}_{rn}$  が与えられたもとで観測データ  $\mathbf{x}_{rn}$  が得られる確率はガウス分布に従うとする。すなわち、

$$p(\mathbf{x}_{rn} \mid \mathbf{m}_{rn}, \phi) = \prod_{k=1}^K \mathcal{N}(\mathbf{x}_{rn} \mid \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)^{m_{rnk}},$$

ここで、 $\phi = \{\phi_k\}_{k=1}^K$ ,  $\phi_k = \{\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$  はガウス分布の平均と分散である。

観測変数と潜在変数の同時分布は以下で書き表せる。

$$p(\mathbf{X}_r, \mathbf{Z}_r, \mathbf{M}_r \mid \Theta_{y_r}) \\ = p(\mathbf{z}_{r1} \mid y_r) \left[ \prod_{n=2}^{N_r} p(\mathbf{z}_{rn} \mid \mathbf{z}_{r,n-1}, y_r) \right] \prod_{n=1}^{N_r} p(\mathbf{x}_{rn} \mid \mathbf{z}_{rn}, y_r),$$

ここで、 $\Theta_{y_r} = \{\pi_{y_r}, \mathbf{A}_{y_r}, \mathbf{C}_{y_r}, \phi\}$  である。

#### 4. 提案手法

本研究で使用する分類器は、TM-HMM を拡張したベイズモデルである。以下では、これを BTM-HMM と呼ぶ。本研究では、潜在変数およびパラメータの事前分布を導入し、事後確率の最大化に基づき HMM の状態数および混合分布の要素数を観測データから自動的に決定する。本章では、時系列データを周期的な運動と非周期的な運動に分ける推定手法と、提案モデルについて詳述し、パラメータの推定方法について述べる。

##### 4.1 行動の周期・非周期判定

日常生活行動は、「歩く」や「走る」といった一定の時間間隔で同じ状態が繰り返される行動と、「座る」や「立つ」のような一定の時間間隔で同じ状態が表れない行動に大別される。行動分類の特徴として、周期的な運動に適した特徴は、非周期的な運動には適さないことも起こりうる。本研究では、データに応じて、周期的な運動と非周期的な運動に判別することでこの問題に対処する。すなわち、あらかじめ周期的な運動に属する行動の学習データで

BTM-HMM により学習した分類器と、非周期的な運動に属する行動の学習データで学習した分類器を作成する。新たにきたデータに対しては、周期・非周期どちらかを推定し、適切な時間窓幅の設定と特徴抽出を行い、周期・非周期の推定結果に応じた分類器で分類を行う。テストデータに対する周期的か非周期的かの判別には Random Forests (RF) [26] を用いて 2 値分類を行う。RF に使用する特徴量については 5 章で詳しく述べる。

##### 4.2 提案モデル：BTM-HMM

まず、初期確率  $\pi_y$  および遷移確率  $\mathbf{a}_i^y$  の事前分布として、ディリクレ分布を導入する。

$$\pi_y \sim \text{Dir}(\pi_y \mid \alpha\beta_1^y, \dots, \alpha\beta_{U^y}^y), \\ \mathbf{a}_i^y \sim \text{Dir}(\mathbf{a}_i^y \mid \alpha\beta_1^y, \dots, \alpha\beta_{U^y}^y),$$

ここで、 $\beta = \{\beta_y\}_{y=1}^Y$ ,  $\beta_y = (\beta_1^y, \dots, \beta_{U^y}^y)$  である。 $\beta_y$  はディリクレ分布に従うとする。

$$\beta_y \sim \text{Dir}(\beta_y \mid \frac{\gamma}{U^y}, \dots, \frac{\gamma}{U^y}).$$

ここで、 $U^y \rightarrow \infty$  の極限を考えると、これはディリクレ過程 [8] となる。すなわち、初期確率  $\pi_y$  および遷移確率  $\mathbf{a}_i^y$  はディリクレ過程  $\text{DP}(\alpha, G_i^y)$  に従う。ここで、 $\alpha$  はディリクレ過程の集中度パラメータである。ただし、各時刻で状態を共有する必要があるため、基底分布  $G_i^y$  自体が、もう 1 つのディリクレ過程からのサンプル  $G_i^y \sim \text{DP}(\gamma, G_0^y)$  であるとする。これは、可能な遷移先とその事前確率を各状態間で共有することを意味する。ディリクレ過程が階層化されているため、これは階層ディリクレ過程 [22] と呼ばれる。ここで、 $G_0^y = \sum_{k=1}^{\infty} \beta_k^y \delta_{\phi_k}$ ,  $G_i^y = \sum_{j=1}^{\infty} a_{ij}^y \delta_{\phi_j}$  である。

次に、混合分布の要素を選択する確率  $\mathbf{c}_j^y$  の事前分布として、ディリクレ分布を導入する。すなわち、

$$\mathbf{c}_j^y \sim \text{Dir}(\mathbf{c}_j^y \mid \sigma\lambda_1^y, \dots, \sigma\lambda_K^y),$$

ここで、 $\boldsymbol{\lambda} = \{\boldsymbol{\lambda}_y\}_{y=1}^Y$ ,  $\boldsymbol{\lambda}_y = (\lambda_1^y, \dots, \lambda_K^y)$  である。 $\boldsymbol{\lambda}_y$  は以下のようにディリクレ分布に従うとする。

$$\boldsymbol{\lambda}_y \sim \text{Dir}(\boldsymbol{\lambda}_y \mid \frac{\eta}{K}, \dots, \frac{\eta}{K}).$$

ここで、 $K \rightarrow \infty$  の極限を考え、混合分布の要素の選択確率  $\mathbf{c}_j^y$  はディリクレ過程  $\text{DP}(\sigma, H_j^y)$  に従うとする。ここで、 $\sigma$  はディリクレ過程の集中度パラメータである。ただし、各状態で混合分布の要素を共有する必要があるため、分布  $H_j^y$  自体がもう 1 つのディリクレ過程からのサンプル  $H_j^y \sim \text{DP}(\eta, H_0)$  であるとする。すなわち、混合分布の要素とその事前確率を各状態間で共有する。ここで、 $H_0 = \sum_{k=1}^{\infty} \lambda_k^y \delta_{\phi_k}$ ,  $H_j^y = \sum_{k=1}^{\infty} c_{jk}^y \delta_{\phi_k}$  である。

このもとで、BTM-HMM は以下で書き表せる。

$$\beta_y \mid \gamma \sim \text{GEM}(\gamma),$$

$$\begin{aligned} \pi_y &| \alpha, \beta_y \sim \text{DP}(\alpha, \beta_y), \\ \mathbf{a}_i^y &| \alpha, \beta_y \sim \text{DP}(\alpha, \beta_y), \\ \lambda_y &| \eta \sim \text{GEM}(\eta), \\ \mathbf{c}_j^y &| \sigma, \lambda_y \sim \text{DP}(\sigma, \lambda_y), \\ \phi_k &| H \sim H, \\ \mathbf{z}_{r1} &| \pi_y \sim \pi_y, \\ \mathbf{z}_{rn} &| \mathbf{z}_{r,n-1}, (\mathbf{a}_i^y)_{i=1}^\infty \sim \mathbf{a}_{\mathbf{z}_{r,n-1}}^y, \\ \mathbf{m}_{rn} &| \mathbf{z}_{rn}, (\mathbf{c}_j^y)_{j=1}^\infty \sim \mathbf{c}_{\mathbf{z}_{rn}}^y, \\ \mathbf{x}_{rn} &| \mathbf{m}_{rn}, (\phi_k)_{k=1}^\infty \sim F(\phi_{\mathbf{m}_{rn}}), \end{aligned}$$

ここで、GEMは棒折り過程で、 $H$ は基底分布、 $F$ は出力分布である。

### 4.3 BTM-HMMのパラメータ推定

本研究では、ギブスサンプリングにより各パラメータを求める。以下、 $\mathbf{X} = \{\mathbf{X}_r\}_{r=1}^l$ ,  $\mathbf{y} = \{y_r\}_{r=1}^l$ ,  $\mathbf{Z} = \{\mathbf{Z}_r\}_{r=1}^l$ ,  $\mathbf{M} = \{\mathbf{M}_r\}_{r=1}^l$ ,  $\phi = \{\phi_k\}_{k=1}^K$ とする。

#### ・状態 $\mathbf{Z}$ の推定

状態  $\mathbf{Z}$  の推定には、beam sampling [9] を用いる。まず、補助変数  $u_{rn}$  を導入する。 $u_{rn}$  は状態  $\mathbf{z}_{r,n-1}$  と  $\mathbf{z}_{rn}$  に基づき一様分布からサンプリングされる。すなわち、

$$u_{rn} \sim \text{Uniform}(0, a_{\mathbf{z}_{r,n-1}\mathbf{z}_{rn}}^{y_r}).$$

この  $u_{rn}$  の確率密度関数は以下で書き表せる。

$$p(u_{rn} | \mathbf{z}_{r,n-1}, \mathbf{z}_{rn}, y_r) = \frac{\delta(0 < u_{rn} < a_{\mathbf{z}_{r,n-1}\mathbf{z}_{rn}}^{y_r})}{p(\mathbf{z}_{rn} | \mathbf{z}_{r,n-1}, y_r)},$$

ただし、 $\delta(C)$  は、条件  $C$  が成立するとき1、そうでないときに0をとる関数である。

次に、前向きのメッセージを伝播し、バックトラックの際に状態  $\mathbf{z}_{rn}$  をサンプリングする。前向きのメッセージは以下で書き表せる。

$$\begin{aligned} \hat{\alpha}(\mathbf{z}_{rn} | y_r) &= p(\mathbf{z}_{rn} | \mathbf{x}_{r1:r,n}, u_{r1:r,n}, y_r) \\ &\propto p(\mathbf{z}_{rn}, u_{rn}, \mathbf{x}_r | \mathbf{x}_{r1:r,n-1}, u_{r1:r,n-1}, y_r) \\ &= p(\mathbf{x}_{rn} | \mathbf{z}_{rn}, y_r) \sum_{\mathbf{z}_{r,n-1}: u_{rn} < a_{\mathbf{z}_{r,n-1}\mathbf{z}_{rn}}^{y_r}} \hat{\alpha}(\mathbf{z}_{r,n-1} | y_r). \end{aligned}$$

すなわち、 $a_{\mathbf{z}_{r,n-1}\mathbf{z}_{rn}}^{y_r} > u_{rn}$  を満たす状態遷移のみが非零の確率を持つ。前向きのメッセージを伝播する際に、状態  $\mathbf{z}_{r,n+1}$  の  $U^y$  個の各々の値に対する最大化に対応する  $\mathbf{z}_{rn}$  の値を記録しておく。いったんメッセージが鎖の終端まで伝播し、 $\mathbf{z}_{rN_r}$  の最も確からしい状態が求めれば、鎖を後戻りしてたどっていくことにより、 $\mathbf{z}_{rn}$  が得られる。 $r = 1, \dots, l$  について状態系列  $\mathbf{Z}_r$  を求める。

#### ・混合分布の要素 $\mathbf{M}$ のサンプリング

混合分布の要素  $\mathbf{M}$  をサンプリングするために、上述の beam sampling を応用する。まず、補助変数  $v_{rn}$  を導入す

る。 $v_{rn}$  は、状態  $\mathbf{z}_{rn}$  と混合分布の要素  $\mathbf{m}_{rn}$  に基づき一様分布からサンプリングされる。すなわち、

$$v_{rn} \sim \text{Uniform}(0, c_{\mathbf{z}_{rn}\mathbf{m}_{rn}}^{y_r}).$$

この  $v_{rn}$  の確率密度関数は以下で書き表せる。

$$p(v_{rn} | \mathbf{z}_{rn}, \mathbf{m}_{rn}, y_r) = \frac{\delta(0 < v_{rn} < c_{\mathbf{z}_{rn}\mathbf{m}_{rn}}^{y_r})}{p(\mathbf{m}_{rn} | \mathbf{z}_{rn}, y_r)}.$$

混合分布の要素  $\mathbf{m}_{rn}$  の事後分布は以下で書き表せる。

$$\begin{aligned} p(\mathbf{m}_{rn} | \mathbf{m}_{r,\setminus n}, \mathbf{M}_{\setminus r}, \mathbf{X}, \mathbf{y}, \mathbf{Z}, \Theta) \\ \propto p(\mathbf{m}_{rn}, v_{rn}, \mathbf{x}_{rn} | \mathbf{z}_{rn}, y_r) \\ = p(\mathbf{x}_{rn} | \mathbf{m}_{rn}) \delta(v_{rn} < c_{\mathbf{z}_{rn}\mathbf{m}_{rn}}^{y_r}). \end{aligned}$$

すなわち、 $c_{\mathbf{z}_{rn}\mathbf{m}_{rn}}^{y_r} > v_{rn}$  を満たす混合分布の要素のみが非零の確率を持つ。ここで、 $\mathbf{m}_{r,\setminus n}$  は  $\mathbf{m}_{r1}, \dots, \mathbf{m}_{rN_r}$  から  $\mathbf{m}_{rn}$  を除いたもの、 $\mathbf{M}_{\setminus r}$  は  $\mathbf{M}_1, \dots, \mathbf{M}_{l+1}$  から  $\mathbf{M}_r$  を除いたもの、 $\mathbf{x}_{r,\setminus n}$  は  $\mathbf{x}_{r1}, \dots, \mathbf{x}_{rN_r}$  から  $\mathbf{x}_{rn}$  を除いたものを表す。 $r = 1, \dots, l$  および  $n = 1, \dots, N_r$  について、混合分布の要素  $\mathbf{m}_{rn}$  をサンプリングする。

#### ・パラメータ $\mathbf{A}$ の更新

初期確率  $\pi_y$  および遷移確率  $\mathbf{a}_y$  と、状態数  $U^y$  を更新する。

初期確率  $\pi_y$  および遷移確率  $\mathbf{a}_i^y$  の事前分布にディリクレ分布を仮定したため、事後分布は以下のディリクレ分布で書き表せる。

$$\begin{aligned} \pi_y &\sim \text{Dir}(\pi_y | \alpha\beta_1^y + n_1^y, \dots, \alpha\beta_{U^y}^y + n_{U^y}^y, \alpha \sum_{k=U^y+1}^\infty \beta_k^y), \\ \mathbf{a}_i^y &\sim \text{Dir}(\mathbf{a}_i^y | \alpha\beta_1^y + n_{i1}^y, \dots, \alpha\beta_{U^y}^y + n_{iU^y}^y, \alpha \sum_{k=U^y+1}^\infty \beta_k^y), \end{aligned}$$

ただし、 $n_i^y$  は、クラス  $y$  の HMM において、初期状態  $i$  が選ばれた回数で、 $n_{ij}^y$  は、クラス  $y$  の HMM において、状態  $i$  から状態  $j$  に遷移した回数である。新たな状態が出現する確率は、 $\alpha \sum_{k=U^y+1}^\infty \beta_k^y$  である。

$\beta_y$  をサンプリングするために、補助変数  $h_{ij}$  を導入する [9]。

$$p(h_{ij} | \mathbf{Z}, \beta_y, \alpha) \propto S(n_{ij}^y, h_{ij}) (\alpha\beta_j^y)^h$$

ここで、 $S(\cdot, \cdot)$  は第1種スターリング数である。 $h_{ij}$  を用いて、 $\beta_y$  の事後分布は以下のディリクレ分布で表せる。

$$\beta_y \sim \text{Dir}(\beta_y | h_{\cdot 1}, \dots, h_{\cdot U^y}, \gamma),$$

ここで、 $h_{\cdot j}^y = \sum_{i=1}^{U^y} h_{ij}$  である。詳細については、文献 [22] を参照されたい。

#### ・パラメータ $\mathbf{C}$ の更新

混合分布の要素を選択する確率  $\mathbf{c}_j^y$  と混合要素数  $K$  を更新する。

混合分布の要素を選択する確率  $\mathbf{c}_j^y$  の事後分布は以下の

ディリクレ分布で書き表せる.

$$\mathbf{c}_j^y \sim \text{Dir}(\mathbf{c}_j^y \mid \sigma \lambda_1^y + m_{j1}^y, \dots, \sigma \lambda_K^y + m_{jK}^y, \sigma \sum_{i=K+1}^{\infty} \lambda_i^y),$$

ただし  $m_{jk}^y$  は, クラス  $y$  の HMM において, 状態  $i$  のときに混合分布の要素  $k$  が選択された回数である. 新たな混合分布の要素を選択する確率は,  $\sigma \sum_{i=K+1}^{\infty} \lambda_i^y$  である.

$\lambda_y$  をサンプリングするために, さらに補助変数  $k^*$  を導入する [25].

$$k^* \sim 1 + \text{Poisson}(-\sigma \log v^*)$$

ここで,  $v^* = \min(v_{1n}, \dots, v_{rn})$  で,  $\text{Poisson}(\zeta)$  はパラメータ  $\zeta$  のポアソン分布である. したがって,  $\lambda_y$  の事後分布は以下のディリクレ分布で書き表せる.

$$\lambda_y \sim \text{Dir}(\lambda_y \mid \frac{\eta}{K} + m_{\cdot 1}^y, \dots, \frac{\eta}{K} + m_{\cdot K}^y, k^*),$$

ここで,  $m_{\cdot k}^y = \sum_{j=1}^{U^y} m_{jk}^y$  である. 詳細については, 文献 [25] を参照されたい.

・パラメータ  $\phi$  の更新

混合分布の要素  $\mathbf{M}$  の値が決まれば, 事前分布  $H(\phi_k)$  およびクラス  $k$  に所属するデータに対する尤度  $p(\{\mathbf{x}_{rn} \mid \mathbf{x}_{rn} \in k\} \mid \phi_k)$  を用いて, ベイズの定理より事後分布が得られる. 事前分布には, ガウス分布の共役事前分布であるガウス-ウィシヤート分布を用いる.

$$H(\phi_k) = \mathcal{N}(\boldsymbol{\mu}_k \mid \mathbf{m}_0, (\beta_0 \boldsymbol{\Lambda}_k)^{-1}) \mathcal{W}(\boldsymbol{\Lambda}_k \mid \mathbf{W}_0, \nu_0).$$

事前分布に共役事前分布を用いることで, 事後分布もガウス-ウィシヤート分布となる.

$$\begin{aligned} p(\phi_k \mid \{\mathbf{x}_{rn} \mid \mathbf{x}_{rn} \in k\}) &= \frac{p(\{\mathbf{x}_{rn} \mid \mathbf{x}_{rn} \in k\} \mid \phi_k) H(\phi_k)}{p(\{\mathbf{x}_{rn} \mid \mathbf{x}_{rn} \in k\} \mid \phi_k)} \\ &= \frac{H(\phi_k) \prod_{\mathbf{x}_{rn} \in k} p(\mathbf{x}_{rn} \mid \phi_k)}{\int H(\phi_k) \prod_{\mathbf{x}_{rn} \in k} p(\mathbf{x}_{rn} \mid \phi_k) d\phi_k} \\ &= \mathcal{N}(\boldsymbol{\mu}_k \mid \mathbf{m}_k, (\beta_k \boldsymbol{\Lambda}_k)^{-1}) \mathcal{W}(\boldsymbol{\Lambda}_k \mid \mathbf{W}_k, \nu_k), \end{aligned}$$

ただし, 以下のように定義した.

$$\begin{aligned} \bar{\mathbf{x}}_k &= \frac{1}{N_k} \sum_{\mathbf{x}_{rn} \in k} \mathbf{x}_{rn}, \\ \mathbf{S}_k &= \frac{1}{N_k} \sum_{\mathbf{x}_{rn} \in k} (\mathbf{x}_{rn} - \bar{\mathbf{x}}_k)(\mathbf{x}_{rn} - \bar{\mathbf{x}}_k)^T, \\ \beta_k &= \beta_0 + N_k, \\ \mathbf{m}_k &= \frac{1}{\beta_k} (\beta_0 \mathbf{m}_0 + N_k \bar{\mathbf{x}}_k), \\ \mathbf{W}_k^{-1} &= \mathbf{W}_0^{-1} + N_k \mathbf{S}_k + \frac{\beta_0 N_k}{\beta_0 + N_k} (\bar{\mathbf{x}}_k - \mathbf{m}_0)(\bar{\mathbf{x}}_k - \mathbf{m}_0)^T, \\ \nu_k &= \nu_0 + N_k. \end{aligned}$$

$N_k$  は  $k$  番目の混合要素に属するデータの数である.

$k = 1, \dots, K$  についてパラメータ  $\phi_k$  を更新する. 新たな混合分布の要素が選択されたときには, 1 つの観測データのみを用いてその新たな混合分布の要素のパラメータを決定する. なお, 超パラメータ  $\mathbf{W}_0$  は対角行列であり, 予備実験により各対角要素を 0.28 とした. また,  $\nu_0$  は自由度で次元数より大きくなければならないという制約があるので, 特徴量の次元数に 1 を足した値とした.

#### 4.4 BTM-HMM による識別

上記の手法を用いることで, 行動の種類ごとにパラメータを推定した BTM-HMM がクラス分だけ構築される. すなわち, 各クラスの BTM-HMM のそれぞれが異なる状態遷移確率および出力確率を有する.

未知の時系列データに対しては, 各クラスの BTM-HMM にそのデータを与えたときに, 各クラスの BTM-HMM の中で出力確率が最大となるクラスをそのデータのクラスとして出力する.

### 5. 行動の時系列データ

本研究では, 運動の 3 軸加速度データを使用して行動認識を行う. まず使用する時系列データについて紹介し, 次に 3 軸加速度データから抽出する特徴量について詳述する.

#### 5.1 HASC

HASC [14] は, 人間行動理解のための装着型センサによる大規模データベースの構築を目的とした研究団体であり, 毎年 HASC Challenge を開催している. 本研究では, HASC Challenge 2010 の成果から, 性別などのメタデータが不明なデータを削除し, 新たに収集した 20 名分のデータを加えたものである HASC2011corpus の 3 軸加速度データを使用して行動分類を行う. また, 1 つのデータの計測時間は 20 秒である.

#### 5.2 Daily and Sports Activities

また本研究では, 周期的・非周期的な運動を含むデータセットとして Machine Learning Repository より提供されている Daily and Sports Activities という時系列データを使用する [2]. このデータは, スポーツや日常生活行動のデータを, それぞれ胸, 両腕, 両足に取り付けられた 3 軸加速度センサ, 3 軸ジャイロセンサ, 3 軸マグネットセンサから取得した時系列データである. 男女各 4 名の合計 8 名の実験参加者より取得しており, 本研究では 3 軸加速度データを使用して行動分類を行う. また, 1 つのデータの計測時間は 5 秒である.

#### 5.3 特徴抽出

##### 5.3.1 周期・非周期推定に用いる特徴量

まず, 加速度の 3 軸方向の中から振幅が最も大きい軸に

着目し、ここではそれを  $x$  軸とする。予備実験により推定精度が高かった以下の特徴を用いる。まず、 $x$  軸の加速度のパワースペクトルの最大値から前後の幅 1, 2, 3 点を最大値からの近傍と見なして平均と 25% 値, 中央値, 75% 値を求める。また、 $x$  軸の加速度データの 1 つ前の時間の値との差分と 25% 値, 75% 値を求める。さらに同様に  $x$  軸の加速度の値の 25% 値, 75% 値を求める。以上合計 10 個を特徴量とし、RF に入力として与えることでテストデータが周期的・非周期的かの推定を行う。ここで、周期推定に用いた特徴量が行動のどのような特徴をとらえているかを示す。まず、加速度のパワースペクトルは、行動の加速度が持つ特定の周波数成分の強度をとらえる。加速度の差分値や加速度は、各行動が持つ時間的な変化と行動の大きさをとらえると考えられる。なお、RF の木の数は、予備実験により最も高い精度が得られた 500 と設定する。

### 5.3.2 行動分類のための特徴量

はじめに周期的な運動に属する行動の分類に用いる特徴量について述べる。

加速度データからの教師あり学習に関する先行研究 [1] や [11], [19] を参考にして、本研究では、周期的な運動の加速度データに対して、以下で述べる 16 の特徴量を用いる。ある時間幅の窓を設定し、窓長の 50% のオーバーラップでずらしながら時間窓ごとに 16 の特徴量を抽出する。本研究では、各時系列データに自己相関関数を適用して周期を求め、その 2 倍の値を窓幅に設定した。

3 軸加速度センサから得られるデータは、デバイスの保持姿勢によって値が変化するので、重力成分を推定し、除去する必要がある [11]。3 軸加速度センサにはつねに 1G の重力がかかるので、一定の時間幅  $w_G$  での XYZ 軸の平均ベクトルを重力ベクトルと推定する。すなわち、時刻  $t$  での重力ベクトル  $v_G(t)$  は、3 軸加速度ベクトル  $v(t)$  を用いて以下で書き表せる。

$$v_G(t) = \frac{\sum_{i=t-w_G}^t v(i)}{w_G}.$$

3 軸加速度ベクトルから重力ベクトルを減算し、正規化された運動加速度ベクトルを得る。時刻  $t$  での正規化された運動加速度ベクトル  $v_n(t)$  は以下で書き表せる。

$$v_n(t) = v(t) - v_G(t).$$

まず、正規化された加速度ベクトルから特徴量として、以下のベクトル長  $F_1(t)$  と重力ベクトルとの内積値  $F_2(t)$ 、重力ベクトルとの外積値  $F_3(t)$  を算出する。

$$F_1(t) = \|v_n(t)\|,$$

$$F_2(t) = v_n(t) \cdot v_G(t),$$

$$F_3(t) = v_n(t) \times v_G(t).$$

文献 [11] では、 $F_1(t)$ ,  $F_2(t)$ ,  $F_3(t)$  それぞれについて平

均値, 最大値, 最小値, 分散値の 4 種類の統計量を計算しているが、これらの統計量は外れ値の影響を受ける可能性がある。そのため、本研究では、25% 値, 中央値, 75% 値の 3 種類の統計量を用いた。また、「歩く」や「走る」などの行動は、周期的に繰り返される動作であるので、周波数軸方向における特徴量を考慮する。本研究では、エネルギーと周波数領域エントロピーの 2 種類の特徴量を用いる [18]。フーリエ変換をする際には、切り出した時系列データにハニング窓関数をかける。エネルギーは、各データに関して FFT を行い、得られた周波数成分の絶対値の合計で表される。すなわち、

$$E_n = \frac{1}{N} \sum_{i=2}^n |F_i|^2.$$

本研究では文献 [19] を参考にして、周波数帯域ごとのエネルギー (1~3 Hz, 4~6 Hz, 7~12 Hz, 13~25 Hz, 26~50 Hz) も特徴量に加えた。周波数領域エントロピーは、FFT の全成分の総和で各成分を正規化し、確率分布  $p$  を求め、そのエントロピーで表される。すなわち、

$$p(i) = \frac{|F_i|^2}{\sum_{i=2}^n |F_i|^2},$$

$$FDE = - \sum_{i=2}^n p(i) \log p(i).$$

重力成分を取り除いた加速度ベクトルのベクトル長と、重力ベクトルの内積値・外積値は、重力成分を取り除き 3 軸を合成した行動の大きさの特徴をとらえる。重力成分を取り除いた加速度データのエネルギーは、重力成分を取り除き 3 軸を合成した加速度データの周波数成分の強度を示す。同様に、重力成分を取り除いた加速度データのエントロピーは、重力成分を取り除き 3 軸合成の加速度データが持つ行動の不規則性を反映する。

得られた 16 次元の特徴量に対して、白色化 (ホワイトニング) を行う [4]。すなわち、各データ点  $\mathbf{x}_n$  に対して、

$$\mathbf{y}_n = \mathbf{L}^{-1/2} \mathbf{U}^T (\mathbf{x}_n - \bar{\mathbf{x}}),$$

で与えられる変換値を定義する。ここで、 $\mathbf{L}$  は、データ集合の共分散行列の固有値  $\lambda_i$  を持つ対角行列で、 $\mathbf{U}$  は、 $i$  番目の列が固有ベクトル  $\mathbf{u}_i$  で与えられる直交行列、 $\bar{\mathbf{x}}$  はサンプル平均である。これにより、特徴空間の各軸が無相関化される。

次に非周期的な運動に属する行動の分類に用いる特徴量について述べる。これは、先行研究 [2] を参考に、各軸の加速度データについての最小値と最大値・平均・分散・歪度・尖度・フーリエ変換の最大値の合計 21 種類を特徴量として選択した。これらの特徴量は、非周期的な運動が持つ加速度データの大きさや歪み・形状・周波数成分の特徴をとらえている。なお、予備実験により推定精度が最も高い値を窓幅とし 800 ms とする。21 次元の特徴量に対して、周期的な運動の特徴量と同様に白色化を行う。



## 6. 評価

窓をかけずに運動の全区間に対する上記特徴量を用いた KLR と SVM をベースラインとして分類性能を比較する。KLR と SVM を比較に用いた理由は、本研究の 1 つの発展方向として BTM-HMM を半教師あり学習に拡張することを考えており、KLR と SVM は半教師あり学習に拡張されている手法だからである。それに対し、ナイーブベイズやニューラルネットワークは半教師あり学習に対応させることが難しい。なお、本研究の評価環境には、R の ver3.1.3 を使用している。

評価の方法として、複数の分類器による教師あり学習による評価を行う。それぞれの評価において、全データの 1 割をテストデータとし、残りの 9 割を学習データとして交差確認を行う。実際に分類器の学習に使用するデータは、学習データとして分けられた各クラスデータから 5%、10%、30% の割合で抽出されたデータとする。なお、提案手法と同様に KLR と SVM、TM-HMM の学習では、周期的な運動に属する行動と、非周期的な運動に属する行動に対してはそれぞれ異なる特徴量を用いて別々の分類器を作成した。

### 6.1 実験条件

本研究では、HASC の 3 軸加速度データからは、「静止」や「歩く」・「走る」・「スキップ」・「階段を上る」・「階段を下りる」の 6 種類であり、すべて周期的な運動である。Daily and Sports Activities の 3 軸加速度データからは、「座る」、「立つ」、「後ろに横たわる」、「右に横たわる」、「エレベータで立つ」の非周期的な運動 5 種類と「階段を上る」、「階段を下りる」、「エレベータで動き回る」、「駐車場を歩く」、「時速 4km の速さでランニングマシンを平坦な道で走る」、「時速 4km の速さでランニングマシンを傾斜した道で走る」、「時速 8km の速さでランニングマシンを走る」、「ステップで運動する」、「クロストレーナで運動する」、「水平な位置で自転車を漕ぐ」、「垂直な位置で自転車を漕ぐ」、「船を漕ぐ」、「ジャンプする」、「バスケットをする」の周期的な運動 14 種類を用いる。

HASC データは、HASC2011corpus からサンプリングレートが 100 Hz のセンサを腰に付けた実験参加者 32 名の 3 軸加速度データを用いた。ここで、1 クラスのデータ数を 200 とし、合計 1,200 のデータを用いた。Daily and Sports Activities データは、Machine Learning Repository からサンプリングレートが 25 Hz のセンサを左足に付けた男女 4 名の合計 8 名の実験参加者の 3 軸加速度データを用いた。ここで、1 クラスがデータ数を 480 とし、合計 9,120 個のデータを用いた。

各分類器におけるそれぞれのパラメータは、予備実験を通して次のように設定した。まず、SVM の正則化係数は  $C = 1$ 、 $C^* = 1$  とした。また、カーネル関数にガウスカ

ネルを使用し、その精度パラメータを 0.1 とした。KLR も SVM と同様に、カーネル関数にガウスカネルを使用し、その精度パラメータを 0.1 とした。BTM-HMM については、 $\alpha = 1$ 、 $\gamma = 1$ 、 $\sigma = 1$ 、 $\eta = 1$  とした。また、TM-HMM の潜在変数の状態数や混合数は、予備実験により最も高い精度が得られた値を使用し、状態数と混合数ともに 6 と設定している。

### 6.2 実験結果

HASC と Daily and Sports Activities の両方ともに、全学習データと、その 5%、10%、30% を用いてそれぞれ学習を行った。

#### 6.2.1 HASC データによる評価

HASC データの場合は、6 行動すべて周期的であるので、周期的な運動用の特徴量で学習し、テストもそれで行った。

学習に用いるデータの割合が各クラスの全学習データの 5%、10%、30% のとき、各クラスの学習データの個数は、それぞれ 9 個、18 個、54 個である。すなわち、クラス数は 6 なので全学習データ数はそれぞれ 54 個、108 個、324 個である。時系列性を加味していない分類器 (KLR と SVM) と、時系列性を加味した BTM-HMM と TM-HMM の F 値の平均を図 2 に示す。図 2 に示したように、BTM-HMM の F 値は、KLR や SVM、TM-HMM の F 値よりも大きい。BTM-HMM の F 値の平均は、各クラスの学習データ数が 5% のとき 70.9%、10% のとき 77.5%、30% のとき 83.1% であり、全学習データを使用したときは 84.7% である。分散分析の結果、手法とデータ数の主効果は統計的に有意である ( $p < 0.001$ )。また BTM-HMM と TM-HMM では、いずれのデータ数においても BTM-HMM が高い F 値の平均を示した。ただし、テューキーの HSD (honestly significant difference) による F 値の差の多重比較では、BTM-HMM と TM-HMM の F 値の差は統計的に有意ではない。




図 2 HASC データに対する各分類器の F 値の平均と標準偏差 (ヒゲ) を表す

Fig. 2 The average F-values and the standard deviations of classification results by SVM, KLR, TM-HMM, and BTM-HMM for HASC data.

6.2.2 Daily and Sports Activities データによる評価

Daily and Sports Activities データの場合は、学習に用いるデータの割合が各クラスの全学習データの5%、10%、30%のとき、各クラスの学習データの個数は、それぞれ22個、43個、130個である。各テストデータを、RFによって周期的・非周期的かを推定し、推定結果に応じた特徴量を用いてクラス分類したときの19種類の運動に対する各分類器のF値の平均を示す。

図3に、周期的な運動と非周期的な運動が混在している総合的なF値の平均を示し、その内訳として、図4に、周期的な運動のF値の平均、図5に、非周期的な運動のF値の平均を示す。

提案手法のF値は、学習データ数が各クラスデータの5%のとき74.9%、10%のとき77.5%、30%のとき82.0%であり、全学習データを使用したときは84.4%である。図3に示したように、提案手法が最も高いF値を示した。ただし、5%と10%のときは、TM-HMMの学習が収束しなかつ




図3 Daily and Sports Activities データに対する各分類器のF値の平均と標準偏差(ヒゲ)を表す。5%と10%に対するTM-HMMの結果は欠損

Fig. 3 The average F-values and the standard deviations of classification results by SVM, KLR, TM-HMM, and BTM-HMM for Daily and Sports Activities data.




図4 非周期的な運動と推定されたデータに対する各分類器のF値の平均と標準偏差(ヒゲ)を表す

Fig. 4 The average F-values and the standard deviations of classification results by SVM, KLR, TM-HMM, and BTM-HMM for the data that are judged as a non-cyclic activity.

たので図に結果は示されていない。分散分析の結果、手法とデータ数の主効果は統計的に有意である ( $p < 0.001$ )。また、30%と100%のデータ数の結果を見ると、提案手法とTM-HMMでは、いずれのデータ数においても提案手法が高いF値の平均を示した。ただし、テューキーのHSDによるF値の差の多重比較では、提案手法とTM-HMMのF値の差は統計的に有意ではない。

次に、RFにより非周期的な運動と推定されたテストデータに対する各分類器のF値の平均を図4に示す。BTM-HMMの非周期的な運動のF値の平均は、学習データ数が各クラスデータの5%のとき87.8%、10%のとき88.9%、30%のとき89.7%であり、全学習データを使用したときは90.5%である。図4に示したように他の分類器のF値と比べて最も高い値を示した。

同様に、周期的な運動と推定されたテストデータに対する各分類器のF値の平均を図5に示す。なお、Daily and Sports Activitiesの周期的な運動のデータは取得時間が非常に短いため、自己相関による時間窓幅の設定によって十分な数の時間窓を得るために、元の5秒のデータとまったく同じデータを20個連結した時系列データを生成して、特徴量を抽出している。これは学習に用いる周期的な運動のデータだけでなく、テストに用いるRFによって周期的と推定された運動のデータに対しても行っている。BTM-HMMの周期的な運動のF値の平均は、学習データ数が各クラスデータの5%のとき62.0%、10%のとき66.2%、30%のとき74.3%であり、全学習データを使用したときは78.3%である。またTM-HMMは、学習データ数の割合が30%よりも小さくなるとパラメータ推定における計算の発散が頻繁に起こるため、5%、10%のときの分類結果が得られなかった。ここで、TM-HMMの分類結果について述べる。学習データ数の割合が5%のときは、10回の試行の中でパラメータ推定の計算がすべて発散してしまい分類結果が得




図5 周期的な運動と推定されたデータに対する各分類器のF値の平均と標準偏差(ヒゲ)を表す。5%と10%に対するTM-HMMの結果は欠損

Fig. 5 The average F-values and the standard deviations of classification results by SVM, KLR, TM-HMM, and BTM-HMM for the data that are judged as a cyclic activity.

られなかった。学習データ数の割合が10%のときは、10回の試行の中で2回は発散せずに学習することができ、そのときのF値は69.2%と67.6%である。

Daily and Sports ActivitiesのテストデータをRFによって周期的か、非周期的かを推定したときの精度を示す。Precisionが98%で、Recallが97%で周期的な運動と非周期的な運動に分けることができ、高い精度を達成している。非周期的な運動の中で周期的な運動と推定されたものは、「立つ」、「後ろに横たわる」、「エレベータで立つ」の3種類である。1クラス480個のデータの中で誤分類数はそれぞれ、「立つ」が11個、「後ろに横たわる」が3個、「エレベータで立つ」が39個である。周期的な運動の中で非周期的な運動と推定されたものは、「エレベータで動き回る」のみである。1クラス480個のデータの中で「エレベータで立つ」の誤分類数は120個である。

最後に、BTM-HMMを用いて、Daily and Sports Activitiesのテストデータの19種類の運動に対して周期的・非周期的かを推定せずに、周期的な運動の加速度データの時間窓幅の設定手法と16種類の特徴量を用いて行動分類を行った結果についてまとめる。学習データ数を各クラスデータ数の30% (130個) としたとき、19種類の運動に対するF値の平均は56.6%である。Daily and Sports Activitiesのテストデータの19種類の運動に対し周期・非周期の推定をした提案手法のF値と比較すると、周期・非周期の判別をしたときのF値の方が高い値を示した。

## 7. 議論

TM-HMMにおける学習では、多峰性分布の尤度最大化によるため計算が発散することがしばしば起こる。この発散は、学習のデータ数が少ない場合に特に顕著であり、実際にDaily and Sports Activitiesの学習データのうち周期的なものに対してパラメータの学習を行ったとき、1つのクラスの学習データ数が130個よりも下回ると、乱数を1,000回振り直してもすべて計算が発散した。また、TM-HMMでは、出力分布の混合数をあらかじめ定めておく必要があるが、それは一般には明らかではなく、学習するデータのクラス数が増えるほど出力分布の混合数を、たとえば予備実験などで決定することが困難になる。

これに対し、提案したBTM-HMMでは、発散が起らず、少数の学習データでモデルを学習することができる。TM-HMMにベイズモデルを導入し、事後確率最大化によってパラメータの推定を行っているためと考えられる。また提案手法では、HMMの状態数および出力分布の混合数をデータから事後確率最大により自動的に決定している。実験の結果より、従来のTM-HMMよりも高いF値を示したことからBTM-HMMはTM-HMMの問題点を克服したモデルといえる。

比較的少数の学習データより、時系列性を考慮して学習し

たときのBTM-HMMのF値は、時系列性を加味しない分類器であるSVMやKLRと比較しても高い。また、少数の学習データにおけるF値を全学習データを用いたときのF値と比較しても、BTM-HMMのF値に大きな低下は見られない。このことから、BTM-HMMは比較的少数の学習データによる学習において、高い識別率を示すことがいえる。

図2から図5を見ると、BTM-HMMのF値の推定精度はTM-HMMやSVMのそれよりも大きいことが分かる。この理由は、明確ではないが、学習データに対して推定したHMMの状態数や混合数がテストデータに対しても適切であれば大きいF値となり、逆にテストデータにあてはまらない場合は比較的低いF値となるため、全体としてバラツキが大きくなった可能性が考えられる。

同様に、周期的な運動と非周期的な運動の2種類に対し、各々に適切な時間窓幅の設定と特徴量を選択したときの方が、周期・非周期にかかわらず同じ時間窓幅の設定と特徴量を選択する手法よりも高いF値が得られた。このことから、各周期ごとに適切な時間窓幅の設定と特徴量を選択することが、時系列データの分類において重要であることが分かる。

また、前処理を施したBTM-HMMの分類結果と前処理を行わずに周期・非周期的な運動に対して同じ特徴量を用いて学習を行ったBTM-HMMの分類結果を比較すると、前処理を行ったBTM-HMMの方が高い分類精度が得られた。このことから、少数の学習データに対する学習において、前処理が重要であることが分かる。

最後に、BTM-HMMのDaily and Sports Activitiesデータの周期的な運動の分類結果がKLRと比べてやや低い精度となった理由を考察する。主な原因として、Daily and Sports Activitiesの周期的な運動データに対して十分な数の時間窓を生成することができなかったことが考えられる。周期的な運動の時系列データであるHASCデータのサンプリングレートが100 Hzで、30秒間で取得されているのに対し、Daily and Sports Activitiesの時系列データはサンプリングレートが25 Hzで、5秒間で取得されている。したがって、Daily and Sports Activitiesデータに自己相関を適用して時間窓幅を決めた場合は、データによって得られる時間窓数が十分に得られないことが起こりうる。非周期的な運動の時系列データがこれに影響を受けないのは、十分な数の時間窓を確保できるようにあらかじめ時間窓幅を設定しているためである。図6にDaily and Sports Activitiesの元の5秒間の時系列データ、5秒間の時系列データを10個連結した50秒間の時系列データ、同様に20個連結した100秒間の時系列データをBTM-HMMに分類させたときのF値の平均を示す。図6より、十分な長さを持った100秒間の時系列データに対し、BTM-HMMは最も高いF値を示していることが分かる。時系列を加味しないSVMやKLRの結果には、BTM-HMMのように大きな変化は見られず、F値の平均はほぼ同じ値をとっている。




図 6 Daily and Sports Activities の周期的な運動の長さ 5 秒と 50 秒・100 秒中の時系列データに対する BTM-HMM による F 値の平均と標準偏差 (ヒゲ) を表す

Fig. 6 The average F-values and the standard deviations of classification results by BTM-HMM for the time series of 5 sec, 50 sec, and 100 sec in length in data of the cyclic activities in the Daily and Sports Activities dataset.

なお, TM-HMM を半教師あり学習に対応したモデルとして Extended Tied-Mixture Hidden Markov Model (ETM-HMM) [12] がある. ETM-HMM を拡張する形で BTM-HMM を半教師学習に対応させることは比較的容易に行える.

### 8. 結論

本研究では, センサデータから日常生活行動を分類するための, 教師あり学習に基づく時系列分類法として, Tied-Mixture Hidden Markov Model (TM-HMM) をベイズモデルに拡張した手法, BTM-HMM を提案した. BTM-HMM は, 潜在変数およびパラメータの事前分布を導入し, 事後確率最大化により HMM の状態数や混合分布の要素数を観測データから自動的に決定することが可能になる. BTM-HMM と, TM-HMM, 時系列を加味しない既存の教師あり学習モデルである SVM と KLR に, 周期的な運動に対する加速度のデータセット, 非周期的な運動に対する加速度のデータセット, さらにそれらの両者の運動を含むデータセットに対して分類性能の比較検討を行った. 本提案手法は, 比較的少数のデータに対しても, 結果が安定しており, 高い精度の認識率を示した.

謝辞 本研究の一部は, 文部科学省私立大学戦略的研究基盤形成支援事業 (2014 年~2019 年) の支援を受けて実施しております.

### 参考文献

[1] Bao, L. and Intille, S.S.: Activity recognition from user-annotated acceleration data, *Proc. 2nd International Conference on Pervasive Computing* (2004).  
 [2] Barshan, B. and Yuksek, M.C.: Recognizing daily and sports activities in two open source machine learning environments using body-worn sensor units, *The Computer Journal*, Vol.57, No.11, pp.1649–1667 (2014).  
 [3] Bellegarda, J.R. and Nahamoo, D.: Tied mixture contin-

uous parameter modeling for speech recognition, *IEEE Trans. Acoustics Speech and Signal Processing*, Vol.38, No.12, pp.2033–2045 (1990).  
 [4] Bishop, C.M.: *パターン認識と機械学習*, 丸善出版 (2012).  
 [5] Chang, K., Chen, M.Y. and Canny, J.: Tracking free-weight exercises, *Proc. 9th International Conference on Ubiquitous Computing* (2007).  
 [6] Elliott, R.J., Aggoun, L. and Moore, J.B.: *Hidden Markov Models: Estimation and Control*, Springer (1995).  
 [7] Farrington, J., Moore, A. Tilbury, N. Church, J. and Biemond, P.: Wearable sensor badge & sensor jacket for context awareness, *Proc. 3rd International Symposium on Wearable Computers*, pp.107–113 (1999).  
 [8] Ferguson, T.S.: A Bayesian analysis of some non-parametric problems, *Annals of Statistics*, Vol.1, No.1, pp.209–230 (1973).  
 [9] Gael, J.V. et al.: Beam sampling for the infinite hidden Markov model, *Proc. 25th International Conference on Machine Learning*, pp.1088–1095 (2008).  
 [10] Hu, D.H. et al.: Abnormal activity recognition based on HDP-HMM models, *Proc. IJCAI*, pp.1715–1720 (2009).  
 [11] 池谷直紀, 菊池匡晃, 長 健太, 服部正典: 3 軸加速度センサを用いた移動状況推定方式, *電子情報通信学会研究報告, ユビキタス・センサネットワーク (USN)*, Vol.108, No.138, pp.75–80 (2008).  
 [12] Inoue, M. and Ueda, N.: Exploitation of unlabeled sequences in hidden Markov models, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.25, No.12, pp.1570–1581 (2003).  
 [13] Inoue, S., Ueda, N., Nohara, Y. and Nakashima, N.: Mobile activity recognition for a whole day: Recognizing real nursing activities with big dataset, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.1269–1280 (2015).  
 [14] Kawaguchi, N. et al.: HASC2012corpus: Large scale human activity corpus and its application, *Proc. 2nd International Workshop of Mobile Sensing: From Smartphones and Wearables to Big Data*, pp.10–14 (2012).  
 [15] Matthew, J.B. et al.: The Infinite hidden Markov model, *Advances in Neural Information Processing Systems*, Vol.14, pp.577–584 (2014).  
 [16] Murao, K and Terada, T.: A motion recognition method by constancy-decision, *Proc. 14th International Symposium on Wearable Computers (ISWC2010)*, pp.69–72 (2010).  
 [17] Nigam, K. et al.: Text classification from labeled and unlabeled documents using EM, *Machine Learning*, Vol.39, No.2-3, pp.103–134 (2000).  
 [18] 小川兼人, 伊藤雄一, 安部登樹, 岸野文郎: 実物体によるモーションクエリを用いた 3 次元形状モデル検索, *情報処理学会シンポジウム論文集*, Vol.4, pp.9–16 (2009).  
 [19] 小川延宏, 梶 克彦, 河口信夫: HASC2010corpus を用いた被験者数と人間行動認識率の相関分析, *マルチメディア, 分散, 協調とモバイル (DICOMO 2011) シンポジウム論文集*, pp.76–82 (2011).  
 [20] Raman, N. and Maybank, S.J.: Action classification using a discriminative multilevel HDP-HMM, *Neurocomputing*, Vol.154, pp.149–161 (2015).  
 [21] Sasaki, Y., Yoshii, K. and Kagami, S.: A nested infinite Gaussian mixture model for identifying known and unknown audio events, *Proc. International Workshop on Image Analysis for Multimedia Interactive Services*, pp.1–4 (2013).  
 [22] Teh, Y.W. et al.: Hierarchical Dirichlet process, *Jour-*

*nal of the American Statistical Association*, Vol.101, No.476, pp.1566–1581 (2006).

- [23] 上田修功, 山田武士, 桑田修平: デイリクレ混合過程モデルに基づく半教師有り学習, 電子情報通信学会技術研究報告, パターン認識・メディア理解 (PRMU), Vol.107, No.115, pp.87–92 (2007).
- [24] 上田修功, 田中祐典, 中島直樹: メタ学習に基づく加速度センサからの看護師行動識別, マルチメディア, 分散, 協調とモバイル (DICOMO 2013) シンポジウム論文集, pp.663–667 (2013).
- [25] Walker, S.G.: Sampling the dirichlet mixture model with slices, *Communications in Statistics–Simulation and Computation*, Vol.36, No.45 (2007).
- [26] 波部 齊: ランダムフォレスト, 情報処理学会研究報告, Vol.2012-CVIM-182, No.31 (2010).




**菅野 隼**

2016年関西学院大学理工学部人間システム工学科卒業。現在、関西学院大学大学院理工学研究科人間システム工学専攻。



**松重 龍之介**

2014年関西学院大学理工学部人間システム工学科卒業。2016年関西学院大学大学院理工学研究科人間システム工学専攻修了。現在、オリンパス株式会社。



**岡留 剛** (正会員)

関西学院大学理工学部教授。同大学人工知能研究センター長。1988年東京大学大学院理学系研究科情報科学専攻博士課程修了。博士(理学)。同年NTT基礎研究所入所。2009年より現職。IEEE, ACM, 人工知能学会, 認

知科学会各会員。