

## 時系列データ分割を目的とした Partitioned HMM の提案 \*

後藤 直人<sup>†</sup>      林 朗<sup>‡</sup>      末松 伸朗<sup>§</sup>      神原 利彦<sup>¶</sup>  
 広島市立大学大学院<sup>†</sup>    広島市立大学大学院<sup>‡</sup>    広島市立大学大学院<sup>§</sup>    広島市立大学大学院<sup>¶</sup>

### 1. はじめに

近年、動画像、音声、手書き文字認識等の時系列データに対する研究が盛んに行われている。本稿では一本の時系列データを動的特性に基づき複数の部分時系列データに分割(セグメンテーション)する方法を提案する。提案する手法の大きな特徴は訓練データにセグメンテーション時刻を与えることで、セグメンテーションに関する情報を直接モデルに学習させることである。また、学習に使用したモデルは隠れマルコフモデル(HMM)をセグメンテーション時刻によって得られる情報が学習可能となるように拡張したものである。我々はこのモデル、Partitioned HMM とその学習法を提案する。

### 2. 提案手法

セグメンテーションされた部分時系列(セグメント)はある動的特性を持っていると考えられる。つまり一本の時系列データは複数のセグメントから成り、セグメンテーションはデータの動的特性が変化したときに起ると考える。セグメンテーションを行うためには動的特性の変化を捕らえる必要がある。しかし、時系列データより動的特性の変化を自動的に抽出することは困難であり、また複雑な解析を必要とする。我々は予めセグメンテーションされた時系列データを訓練データとして扱うことで、より簡単にセグメント間の関係やセグメントの動的特性を学習できると考える。

我々はこのような動的な事象を取り扱うために音声認識等の様々な時系列データに対し広く使われている隠れマルコフモデル(HMM)に着目した。HMMはモデルより動的特性を持つ時系列データを生成することができる生成モデルでもある。よって各セグメントはHMMから生成され、セグメンテーションが起るとき、観測系列を出力するHMMが変化すると仮定した。以下、セグメント単位を出力するHMMをサブモデルと呼ぶ。

また、認識を行う際にセグメントの長さは未知であるから個別にサブモデルを学習することは望ましくない。そこで、複数のサブモデルが結合した構造を持つHMMを提案する。我々はこのHMMをPartitioned HMMと名付けた。

#### 2.1 Partitioned HMM

Partitioned HMMは異なるサブモデルの状態間にも遷移確率が存在する。つまりサブモデルの概念を無視すれば、一般的なHMMと等しい構造をしている。大きな変更はサブモデル外(他のサブモデルの状態)への遷移がセグメンテーションであると定義したことである。こ

れによって認識時には一般的なHMMと同様にビタービアルゴリズムを用いて最適状態系列を出力させ、サブモデル間の遷移した時刻をセグメンテーション時刻と推定する。

図1に2状態3サブモデル Partitioned HMMの例を示す。

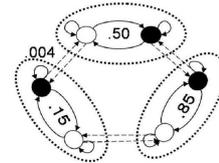


図1: 3サブモデル Partitioned HMM

点線の楕円がサブモデルを示し、波線の矢印は全て確率0.004の状態遷移を表す。サブモデル内の遷移はそれぞれ確率0.5, 0.15, 0.85で他状態へ遷移する。状態の出力確率は $N(0, 0.5)$ (白)と $N(5, 0.5)$ (黒)である。3章ではこのモデルを使用した実験を示す。

#### 2.2 学習アルゴリズム

訓練データは予めセグメンテーションの時刻が与えられている。よって学習時に限り各状態の遷移確率が部分的に制限される。つまり、時刻 $t$ が動的特性が変化するとき、同じサブモデルに属する状態 $i, j$ 間の遷移確率は

$$P(q_{t+1} = j, q_t = i) = 0 \quad (1)$$

であり、また時刻 $t$ が動的特性が変化しないとき、同じサブモデルに属さない状態 $i, j$ 間の遷移確率もまた式1である。その他は通常のHMM学習に用いられるBaum-Welchアルゴリズムに従う。

#### 2.3 Baum-Welch アルゴリズム

ここでは学習アルゴリズムの詳細を述べる。ここでBaum-Welchアルゴリズムで使用される確率変数 $\gamma_t(i), \alpha_t(i), \beta_t(i)$ を式2,3,4にしめす。

$$\gamma_t(i) = P(q_t = i | \mathbf{O}, \lambda) \quad (2)$$

$$\alpha_t(i) = P(o_1, \dots, o_t, q_t = i | \lambda) \quad (3)$$

$$\beta_t(i) = P(o_{t+1}, \dots, o_T | q_t = i, \lambda) \quad (4)$$

$\alpha$ と $\beta$ はそれぞれ式5,6に示すForward-Backward処理によって求まる。

$$\alpha_1(i) = \pi_i b_i(o_1)$$

$$\alpha_{t+1}(i) = \left[ \sum_j \alpha_t(j) a_{ji} \right] b_i(o_{t+1}) \quad (5)$$

$$\beta_T(i) = 1$$

$$\beta_t(i) = \sum_j a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \quad (6)$$

\*Partitioned HMM for segmentation of time series

<sup>†</sup>Naoto Gotou · Graduate School, Hiroshima City University

<sup>‡</sup>Akira Hayashi · Graduate School, Hiroshima City University

<sup>§</sup>Nobuo Suematu · Graduate School, Hiroshima City University

<sup>¶</sup>Toshihiko Kanbara · Graduate School, Hiroshima City University

ここで  $\pi_i$  は初期状態確率であり、 $b_i(o_t)$  は状態  $i$  で観測値  $o_t$  を出力する確率である。また  $a_{ij}$  は状態  $i$  から  $j$  への遷移確率であり、提案手法の場合は式 1 の制限が加えられる。 $\gamma_t(i)$  は  $\alpha_t(i), \beta_t(i)$  より求まり

$$\begin{aligned} \gamma_t(i) &= \frac{P(\mathbf{O}, q_t = i | \lambda)}{P(\mathbf{O} | \lambda)} \\ &= \frac{\alpha_t(i) \beta_t(i)}{\sum_i \alpha_t(i) \beta_t(i)} \end{aligned} \quad (7)$$

である。

## 2.4 提案手法の意味

提案手法では、 $t_1 + 1, t_2$  があるセグメントの開始時刻と終了時刻である場合、式 1 より

$$\begin{aligned} \gamma_t(i) &\simeq P(\lambda_t^{sub} = \lambda_k | \mathbf{O}, \lambda) \\ &\times P(q_t = i | o_{t_1+1}, \dots, o_{t_2}, \lambda_k) \end{aligned} \quad (8)$$

となる。ここで  $\lambda_t^{sub}$  は時刻  $t$  でのサブモデルを示し、 $t_1 + 1 \leq t \leq t_2$  である。さらに、式 8 の第 2 要素は式 2 のモデル  $\lambda$  をサブモデル  $\lambda_k$ 、観測系列  $\mathbf{O}$  をセグメント  $o_{t_1+1}, \dots, o_{t_2}$  とすると

$$P(q_t = i | o_{t_1+1}, \dots, o_{t_2}, \lambda_k) = [\gamma_t(i) | \lambda = \lambda_k, \mathbf{O} = o_{t_1+1}, \dots, o_{t_2}] \quad (9)$$

となる。式 8,9 より提案した学習手法は時系列内のセグメントを隣り合うセグメント同士の重複がないように重み  $P(\lambda_t^{sub} = \lambda_k | \mathbf{O}, \lambda)$  でサブモデルに割り当てるソフトクラスタリングに類似した結果を与える。また計算量は通常の Baum-Welch アルゴリズムと等しく  $O(Tn^2)$  <sup>||</sup> である。

## 3. 実験

Partitioned HMM とその学習法の有効性を示すため人工データを使用して実験を行った。訓練、テストデータは図 1 の 2 状態 3 サブモデル Partitioned HMM から生成し、訓練データにおいてはサブモデルが変化した時刻を付加した。訓練データ、テストデータ共に長さ 5000 出力させた。

学習後のモデルを使いビタービアルゴリズムをテストデータに対して行った結果を図 2 に示す。横軸がサブモデルを示し、縦軸が時刻を表す。上の波線が推定結果、下の実線が実際に出力を行ったサブモデル(真値)である。

さらに Partitioned HMM から生成させたデータ以外にも実験をおこなった。この人工データは 3 つのサブモデルを想定し、パラメータ  $\theta^k = \{a_i^k, b_i^k | 1 \leq i \leq 3\}$  を 3 セット ( $1 \leq k \leq 3$ ) 用意した。各  $a_i, b_i$  は区間 (0,1) の乱数より発生させた。このパラメータは観測時間ごとに確率  $1/150$  で他のパラメータへ等しく変化させた。このパラメータを使い式 10 より長さ 10000 の時系列データを生成させた。

$$o_t = \sum_{i=1}^3 a_i^k \sin((\pi/2^i)t) + b_i^k \cos((\pi/2^i)t) \quad (10)$$

<sup>||</sup> $T$  は時系列の長さ,  $n$  は Partitioned HMM 全体を通しての状態数

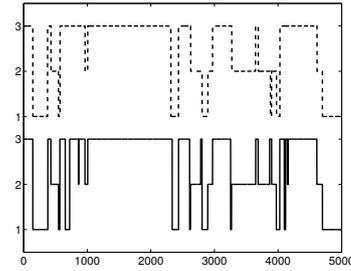


図 2: テストデータと推定結果

はじめの時刻 5000 までのデータを訓練データ、その他をテストデータとし、2 状態 3 サブクラス Partitioned HMM に学習させた。

図 3 にテストデータのパラメータ番号とビタービアルゴリズムによる推定結果を示す。上の波線が推定されたサブモデル、下の実線が実際に出力に使用したパラメータの種類(真値)である。

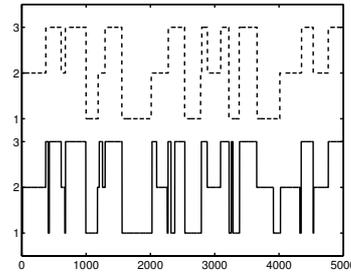


図 3: テストデータと推定結果

この 2 つの実験に共通して櫛の歯のような瞬間的な変化を捕らえることはできなかった。しかし、このような瞬間的な動的特性の変化は人手によっても困難である。よって我々が提案したアルゴリズムは人工データにおいて良好であったといえる。

## 4. まとめ

予めセグメンテーションされた時系列データを訓練データとしてモデル学習を行い、新たな時系列データをセグメンテーションする方法を提案した。人工データを使用した実験では良好な結果が得られた。今後、実データに対しても実験を行いう予定である。

## 参考文献

- [1] S.Fine Y.Singer and N.Tishby .The Hierarchical Hidden Markov Model:Analysis and Applications. Machine Learning.vol.32,pp41-62.1998
- [2] Z.Ghahramani G.E.Hinton .Variational Learning for Switching State-Space Models. Graphical Models:Foundations of Neural Computation ,pp315-348.2001