

階層ディリクレ過程による動作クラス数推定を導入した GP-HSMM による連続動作からの基本動作抽出

長野匡隼[†] 中村友昭[†] 長井隆行[†] 持橋大地[‡] 小林一郎^{††} 金子正秀[†]

[†]電気通信大学 [‡]統計数理研究所 ^{††}お茶の水女子大学

1 はじめに

人は知覚した連続的な情報を意味をもつ単位に分節化することで認知している。例えば、人の連続的な動作を分節化することで単位動作を認識することができる。人は、分節点や組み合わせに無数の可能性がある中から、明示的な分節点を与えられることなく自ら学習し、情報を分節化している。ロボットにおいても、言語や動作等を柔軟に学習するために、教師なしで分節化する能力は非常に重要であると言える。

そこで、我々は隠れセミマルコフモデルにおける出力をガウス過程とした Gaussian Process - Hidden Semi-Markov model (GP-HSMM) を用いることで、時系列データの分節化を可能とした。類似する単位動作はガウス過程によって表現されており、観測される系列は各クラスから生成された単位系列を結合させることで生成される。観測系列のみからモデルのパラメータを学習することで、教師なしで分節点と各单位系列のクラスを推定することができる。モデルの学習には文献 [1] で提案された Forward filtering-Backward sampling を用いた。しかし、この手法では、分類する単位動作のクラス数を予め与える必要があった。そこで、この問題を解決するため GP-HSMM に Hierarchical Dirichlet Process (HDP) [2] を導入し、ノンパラメトリックベイズモデルへと拡張した HDP-GP-HSMM を提案する。

このような教師無しで動作を分節化する研究はいくつか行われているが、ヒューリスティックな仮定をおいているものが多い。しかしながら、ヒューリスティックな仮定が全ての動作に対して有効に働くかは定かではない。また単位動作の表現に Hidden Markov Model (HMM) を用いることで、教師無しで分節化する手法が提案されている [3, 4, 5, 6]。HMM は、連続的な動作を状態へと離散化することで、連続動作を表現している。一方、我々は離散化せずに動作を表現可能な Gaussian Process (GP) を用いており、GPの方が複雑な動作を表現するのに適していると考えている。

2 ノンパラメトリックベイズ

2.1 ディリクレ過程

ノンパラメトリックベイズモデルでは、無限個のクラスを仮定している。そのために無限次元の多項分布を生




図 1: グラフィカルモデル

成する必要がある。その構成法の1つが Stick Breaking Process (SBP) である。SBP では、長さ 1 の棒をベータ分布からサンプリングされる値により、折り続けることで無限次元の多項分布を構成している。

$$v_k \sim \text{Beta}(1, \gamma) \quad (k = 1, \dots, \infty) \quad (1)$$

$$\beta_k = v_k \prod_{i=1}^{k-1} (1 - v_i) \quad (k = 1, \dots, \infty) \quad (2)$$

これにより無限次元の多項分布のパラメータ β を構成することができる。このプロセスは一般的に $\beta \sim \text{GEM}(\gamma)$ と表記される。

2.2 階層ディリクレ過程

SBP によって各状態の遷移確率を構成するだけでは、状態毎に可能な遷移先が異なることになる。HMM のようなモデルの場合、全ての状態において可能な遷移先が共有されており、その遷移確率が状態毎に異なる分布を構成しなければならない。そのために、SBP によって生成した分布 β を基底測度とし共有し、状態 c 毎に異なる遷移確率 π_c を DP によって生成する。

$$\pi_c \sim \text{DP}(\alpha, \beta) \quad (3)$$

このような、二段階の DP によって無限次元の確率分布を構成する手法は、Hierarchical Dirichlet Process (HDP) と呼ばれている。

3 HDP-GP-HSMM

図 1 が提案手法のグラフィカルモデルである。 $c_j (j = 1, 2, \dots, J)$ が単位系列のクラスを表しており、無限個のクラス数を仮定している。 π_c は、クラス c から各クラスへの遷移確率を表しており、 γ をパラメータとする GEM 分布 (Stick Breaking Process) によって生成さ

Basic Motion Pattern Extraction From Continuous Motion by GP-HSMM with Hierarchical Dirichlet Process

Masatoshi Nagano[†], Tomoaki Nakamura[†], Takayuki Nagai[†], Daichi Mochihashi[‡], Ichiro Kobayashi^{††} and Masahide Kaneko[†]

[†]The University of Electro-Communications, 182-8585, Japan

[‡]The Institute of Statistical Mathematics, 190-8562, Japan

^{††}Ochanomizu University, 112-0012, Japan

nm1424057.7621.1207@uec.ac.jp

れた β と, α をパラメータとする DP から生成される.

$$\beta \sim \text{GEM}(\gamma) \quad (4)$$

$$\pi_c \sim \text{DP}(\alpha, \beta) \quad (5)$$

j 番目のクラス c_j は, $j-1$ 番目のクラス c_{j-1} と遷移確率 π_c によって決定される. ここでは, クラスと対応した \mathbf{X}_c をパラメータとするガウス過程から単位系列 \mathbf{x}_j が生成されることを仮定している.

$$c_j \sim P(c|c_{j-1}, \beta, \alpha) \quad (6)$$

$$\mathbf{x}_j \sim \mathcal{GP}(\mathbf{x}|\mathbf{X}_{c_j}) \quad (7)$$

ただし, \mathbf{X}_c はクラス c に分類された単位系列の集合である. これらの単位系列を結合することで, 観測系列 $\mathbf{S} = \mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_J$ となる.

3.1 学習

提案モデルでは, 観測系列内の単位系列とそのクラスをサンプリングすることで推定する. 効率的に計算するために, 1つの観測系列内の単位系列とそのクラスを一括でサンプリングする Blocked Gibbs Sampler を用いる. まず, 全ての観測系列をランダムに分節・分類することで初期化する. 次に, ある観測系列 \mathbf{s}_n を分節して得られた単位系列 $\mathbf{x}_{nj} (j = 1, 2, \dots, J_n)$ を, それらが分類されているクラスからすべて削除し, 各クラスのガウス過程のパラメータ \mathbf{X}_c と遷移確率 $P(c|c')$ を更新する. 次に, 行動の長さでクラスを組み合わせを効率的に計算可能な Forward filtering-Backward sampling を用い, 単位系列 $\mathbf{x}_{nj} (j = 1, 2, \dots, J_n)$ とそれらのクラス $c_{nj} (j = 1, 2, \dots, J_n)$ を推定し, 各クラスと対応したガウス過程のパラメータ \mathbf{X}_c と遷移確率 $P(c|c')$ を更新する. 以上の操作を全ての系列に対して繰り返すことで, 観測系列の分節点とガウス過程のパラメータを交互に最適化することができる.

4 実験

提案手法の有効性を検証するために, 空手の型のモーションキャプチャデータの分節化を行った¹. また, HDP-HMM[3] や HDP-HMM+NPYLM[4], BP-HMM[5], Autoplait[6] の手法と比較した. 空手の型には図2の単位動作が含まれている. 分節化には, 計測した動作の両手両足の奥行きを除いた左右 (x) と上下 (y) の二次元の座標を用いた. 観測系列に対して各手法で分節化を行った結果が表1である. 正規化ハミング距離は, 正解と比較したときの誤り率であり, 小さいハミング距離がより正解に近いことを表している. 提案手法でも誤分類はあるが, 他の手法と比較して少なく, 正解に最も類似した分類がされていることが分かる. また, 正解のクラス数は7であり, 提案手法で分節化を行った結果, クラス数は7と正しく推定された.

5 まとめ

本稿では, ガウス過程を出力分布とした隠れセミマルコフモデルにディリクレ過程を導入することで, 動作のクラス数を推定しつつ動作を分節・分類する手法を提案した. 提案手法では, 動作の切れ目と, 動作のクラスを Forward filtering-Backward sampling により同時に推定し, クラス数をノンパラメトリックベイズモデルにより推定することで動作の分節化を行った. 実

¹<http://www.mocapdata.com/>




図 2: 空手の型の単位動作

表 1: 各手法による分節化結果

	ハミング距離	推定された単位動作数
HDP-GP-HSMM	0.21	7
HDP-HMM	0.66	10
HDP-HMM+NPYLM	0.47	9
BP-HMM	0.55	5
Autoplait	0.60	3

験により, 動作のクラス数の推定をしつつ, 分節・分類が可能であることが示された. しかし, 分類や分節点に誤りが含まれているので, 引き続き精度の向上について調査を行う. また, 他の手法と比較すると計算時間が長いといった問題があり, 計算コストの削減について検討する予定である. さらに, 今後全身の特徴量を使用することで, より複雑な動作を扱うことを考えている.

謝辞

本研究は JST CREST JPMJCR15E3, JSPS 科研費 JP17K12758 の助成を受け実施したものである.

参考文献

- [1] K. Uchiumi, T. Hiroshi, and D. Mochihashi, "Inducing Word and Part-of-Speech with Pitman-Yor Hidden Semi-Markov Models," Joint Conference of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, pp.1774–1782, 2015.
- [2] Y. W. Teh, M. I. Jordan, M. J. Beal, and D. M. Blei, "Hierarchical Dirichlet processes," Journal of the American Statistical Association, vol.101, no.476, pp.1566–1581, 2006.
- [3] Beal, M. J., Ghahramani, Z., and Rasmussen, C. E., "The infinite hidden markov model," In Advances in neural information processing systems, pp.577–584, 2001.
- [4] Taniguchi, T., and Nagasaka, S., "Double articulation analyzer for unsegmented human motion using pitman-yor language model and infinite hidden markov model," In IEEE/SICE International Symposium on System Integration, pp.250–255, 2011.
- [5] E. B. Fox, E. B. Sudderth, M. I. Jordan, and A. S. Willsky, "Joint modeling of multiple related time series via the beta process," arXiv preprint arXiv:1111.4226, 2011.
- [6] Y. Matsubara, Y. Sakurai, and C. Faloutsos, "Autoplait: Automatic mining of co-evolving time sequences," ACM SIGMOD International Conference on Management of Data, pp.193–204, 2014.