

Factorial Hidden Markov Models を用いた 部分観測データからの全身運動復元 Whole Motion Recovery from Partial Observation Data using Factorial Hidden Markov Models

○ 正 李 東姫 (東京大学) 正 クリッチ ダナ (東京大学) 正 中村 仁彦 (東京大学)
Dongheui LEE, The University of Tokyo, dhlee@yml.t.u-tokyo.ac.jp
Dana KULIĆ, The University of Tokyo, dana@yml.t.u-tokyo.ac.jp
Yoshihiko NAKAMURA, The University of Tokyo, nakamura@yml.t.u-tokyo.ac.jp

Abstract: This paper proposes a method to recover missing data during observation by factorial hidden Markov models (FHMMs). By combining the *motion recognition from partial observation* algorithm and the *proto-symbol based duplication of observed motion* algorithm, whole body motion imitation from partial observation can be achieved. The algorithm for *missing data recovery* uses the same basic strategy as the *whole body motion imitation from partial observation*, but requires more accurate spatial representability. FHMMs allow for more efficient representation of a continuous data sequence by distributed state representation compared to hidden Markov models (HMMs). The proposed algorithm is tested with human motion data and the experimental results show improved representability compared to the conventional HMMs.

Key Words: factorial hidden Markov model (FHMM), mimesis, motion recovery

I. はじめに

神経科学でのミラーニューロンの発見はロボットの模倣学習の研究に影響を与えた。その中で隠れマルコフモデル (hidden Markov model, HMM) は時系列データを効率的に抽象化するため人間の動作をモデリングによく使われてきた [1][2] [3]。しかし, HMM の利用では運動認識と運動生成の間でトレードオフがある。特に状態の数の選択に大きく関連する [4]。状態数が少ない場合はいい汎化性能, 認識性能を持つが, 動作の表現力性能が落ちる。状態数が多い場合は表現力性能がいい反面, 過学習 (overfitting) 問題が起こりやすい。HMM のモデル選択は Bayesian [5] と Akaike [6] 情報を基準に研究されてきたが, これらは認識だけを考慮したものである。予測プログラミング (prediction programming) 方法では [7], HMM の構造とパラメータをオンラインで学習する。マニピュレータ軌道予測の簡単なタスクに適用されたが, 人間の運動のような複雑なタスクには検証されていない。Kulić ら [4] は FHMM を用いた人間動作表現を提案した。

ヒトの運動の認識生成の実装においては部分観測への対応を解決しなければならない。著者らは部分観測データからの全身運動の見真似のアルゴリズムを開発してきた [8][9][10]。これらの研究の共通部分は部分観測からの運動認識アルゴリズムと観測データに条件付けられた運動生成アルゴリズムである。この二つの方法により, 部分的情報から全身運動の見真似が可能になる。運動データの一部が欠落した部分観測から全身運動復元も上記の見真似のアルゴリズムで実現できる。しかし, 隠れマルコフモデルの離散の状態から生じる復元の正確性の限界がある。この問題は認識と生成の間の性能のトレードオフと類似している。隠れマルコフモデルの状態の数が少ないと, 新しい動作に対する認識の性能は良くなるが生成される表現力が劣化する。その一方で状態の数が多いと, 動作の表現力は増すが過学習によって, 新しい動作に対する認識の性能が悪くなる。また学習の際, 計算上のオーバーフローあるいはアンダーフローの問題がよく起こる。本稿では図 2 のような Factorial 隠れマルコフモデルを利用した missing データの復元の正確性を高める方法を提案する。




Fig. 1. Factorial Hidden Markov Model




Fig. 2. The proposed strategy: Abstraction is done by the FHMM exact training [11]. Recognition is implemented by an adaptation of the forward-backward algorithm [11]. Reproduction is implemented by the greedy generation algorithm [4] or a stochastic generation algorithm. Algorithms of *motion recognition from partial observation* and *proto-symbol based duplication of observed motion* for FHMMs are developed. By combining the two algorithms, missing observation data are recovered accurately.

II. FHMM による動作表現

隠れマルコフモデル (hidden Markov model, HMM) は人間の動作をモデリングによく使われてきた [1] [3]。Inamura らは [3]HMM を用いてミメシスモデルを提案した。ミメシスモデルに求められる特徴は, 行動学習, 認識, 生成という三つの機能を統合することに

ある。学習では、時系列行動データは原始シンボルとして抽象化される。認識は、観察の最も適当な原始シンボルを見つけることである。生成は、原始シンボルからの時系列行動データの出力である。

原始シンボルは HMM のパラメータ $\lambda = \{A, B, \pi\}$ として表現される。 $A = \{a_{ij}\}$ i 番目の状態から j 番目の状態へ遷移する確率 a_{ij} の集合である状態遷移確率分布, $B = \{b_i\}$ i 番目の状態から o を出力する確率分布 $b_i(o)$ の集合である状態遷移確率分布, $\pi = \{\pi_i\}$ 初期状態確率分布で表される。

Factorial hidden Markov model (FHMM) は図 1 に示すように分散型の状態を持つ隠れマルコフモデルである。FHMM は複数の隠れマルコフチェーンで構成される。各チェーンは初期状態確率分布, 状態遷移確率分布, 出力確率分布で表される。データを生成する時, 各チェーンは独立的に時系列行動データを出力し, 全てのチェーンからの出力データの和をとる。

様々な FHMM の学習方法が開発された: Exact 方法 [11], mean field approximation [11], backfitting アルゴリズム [12], sequential training 方法 [13]。Exact 方法 [11] は Baum-Welch アルゴリズムの適用で, 計算負担が高い。その他は Exact 方法より計算量が少ないが, 学習性能が Exact 方法より悪い。一旦 FHMM が学習されたら, forward-backward アルゴリズム [11] のアダプテーションで観測データを認識できる。そして, FHMM からその代表的な時系列データを生成出来る [4]。

従来の HMM に比べて FHMM は表現力の観点から見ると効率的である。HMM が認識と生成の間でトレードオフを持つ反面, FHMM は認識のためのよりよい劣化性と生成のためのよりよい詳細を結合する効率的な方法を提供する。HMM でよく直面する状態数が多い時の過学習 (overfitting) 問題と状態数が少ない時の悪い生成性能を避けるために, Kulić [4] は FHMM を用いた人間動作表現を提案した。

III. FHMM を用いた MISSING データ復元

実際のアプリケーションにおいては部分観測への対応を解決すべきである。著者らは部分観測データからの全身運動の見真似方法を開発してきた [8]。部分観測からの運動認識アルゴリズムと観測データに条件付けられた運動生成アルゴリズムが提案された。

観測データに条件付けられた運動生成は観測された運動に近い運動の見真似を可能にする。Viterbi アルゴリズムによって計算された最適な状態時系列は生成される運動が観測データと時間的同期されるようにする。したがって同じ原始シンボルに対応するやや違う動作がそれぞれの違う同期をとることになる。

この二つの方法 (部分観測からの運動認識と観測データに条件付けられた運動生成) により, 部分的情報から全身運動の見真似が可能になる。欠落されたデータの復元もミメシスモデルを使う同じ戦略で可能となる。しかし, 隠れマルコフモデルの離散状態から生じる復元の正確性の限界がある。この問題は認識と生成の間の性能のトレードオフと類似している。隠れマルコフモデルの状態の数が少ないと, 新しい動作に対する認識の性能は良くなるが生成される表現力が落ちる。その一方で状態の数が多いと, 動作の表現力は増すが過学習によって次のような問題が生じる。新しい動作に対する認識の性能が悪くなる。隠れマルコフモデルのパラメータを学習する際, 計算上のオーバーフローあるいはアンダーフローの問題が起こる可能性が増える。復元の場合, 最適な状態遷移時系列の計算性能が落ちる。本稿では図 2 のような Factorial HMM を利用した欠落されたデータの復元の正確性を高める方法を提案する。

A. 部分観測からの動作認識

他者の行動を認識は, 観測された行動パターンが各原始シンボルによって生成される確率を用いて, 複数の原始シンボルの集合から

最大の確率を持つ原始シンボルを求めることである。

$$\lambda^* = \arg \max_{\lambda} P(x|\lambda) \quad (1)$$

Factorial HMM に対して対数尤度 $\log P(x|\lambda)$ は forward-backward アルゴリズムのアダプテーションから計算される [11]。入力行動データ x_t で観測できない行動要素がある時, ガウス分布の線形結合で表される出力確率分布 $b_i(x_t)$ が変更される。

$$b_i(x_t) = \frac{\exp\{-\frac{1}{2}(x_t - \mu_i)^T \Sigma_i^{-1} (x_t - \mu_i)\}}{\sqrt{(2\pi)^M \det \Sigma_i}} \quad (2)$$

観測されていない行動要素 $\{x_k\}_t$ に対しては, その欠落された運動要素が出力確率分布関数に影響与えないように式 (3) 又は式 (4) を代入する。

$$\{x_k\}_t - \mu_{ij} = * \quad (3)$$

$$\Sigma_{ij} = \infty \quad (4)$$

式 (3) の * は定数で, 本稿の実験ではその定数を 0 にとしている。

B. 観測データに条件付けられた原始シンボルからの運動生成

運動生成では, 運動パターンが原始シンボルから出力される。運動生成には 2 つのプロセス (状態遷移列の生成および出力行動要素の生成) で構成される。不観測運動要素は, 出力運動パターンが原始シンボルと現在の観測データから生成されることにより復元される。

HMM モデルにおいて与えられた観測データを最もよく表現する最適な状態系列を求めるアルゴリズムである Viterbi アルゴリズム [14] を用いて最適状態経路を探す。最適経路が得られる後, 出力運動パターン y がノード s_i の出力確率分布 $b_i(x)$ によって計算される。最適状態経路によって観測データと時間的同期とられた全身運動の生成が可能になる。

FHMM 用の Viterbi アルゴリズムを提案する。(1) N 個の状態を持つ M 個のチェーンで表現されている FHMM を N^M 個の状態を持つ HMM へ展開する。その展開は exact 学習方法から抜き出す [11]。(2) N^M 個の状態を持つ HMM から観測データを生成する最適な状態時系列 S^* を従来の Viterbi アルゴリズムによって計算する。時間 t の最適な状態 s_t^* は 1 から N^M 中の整数になる。(3) シングルチェーンの最適な状態時系列 S^* を M 個のチェーンに対応するように変換する。時間 t の i 番目チェーンの最適な状態 s_{it} は 1 から N 中の整数になる。

最適な状態時系列を計算する際, 出力確率分布が用いる。ここでも, 不観測行動要素が出力確率分布関数に影響与えないように, 不観測運動要素に対して式 (3) 又は式 (4) を適用する。最適な状態時系列に従って, 各チェーンの各状態ノードから出力ベクトルを出力させる。毎時刻, 各チェーンからの出力ベクトルの和をとって, 出力時系列パターンを得る。その後, 実際のヒューマノイドロボットに与える滑らかな制御入力を求めるためにスムージング技術を使用する。

FHMM を利用して観測データに条件付けられた運動生成を疑似コードで要約する。

Step1 FHMM λ (M chains of N states) を HMM λ' (N^M states) へと展開する。

Step2 λ' から与えられた観測データを生成する最適な状態時系列 $S^* = [s_1^*, \dots, s_T^*]$ を従来の Viterbi アルゴリズムによって計算する。

Step3 S^* を M 個のチェーンに対応する $S = [S^1, \dots, S^M]^T$ に変換する。

Step4 最適な状態時系列に従って、各チェーンの出力ベクトルを出力させる。毎時刻、各チェーンからの出力ベクトルの和をとって、出力時系列パターンを得る: $y_t = \sum_{m=1}^M B^m(s_t^m)$, for $0 < t < T$.

IV. 実験

欠落されている運動要素復元において FHMM の性能を HMM と比較する。光学式モーションキャプチャーシステムを使ってキャプチャーされた行為者の運動データを用いた。ラベリングされたマーカの 3 次元位置データを逆運動学によって 20 自由度のヒューマノイドロボットモデルにマッピングする。運動データセットには 28 個の足踏み (step), 15 個の万歳 (cheer), 14 個のダンス (dance), 19 個のキック (kick), 14 個のパンチ (punch), 15 個の相撲のしこ (sumo stomp), 14 個のうずくまる (squat), 13 個の投げ (throw), 15 個のしゃがみこみ (bow) の 9 種類の動作がある。図 3 は足踏み行動の様子である。




Fig. 3. Sample Walking Motion - Animated from joint angle data provided by the motion capture system. (1, 11, 21, 31, 41, 51 and 61 frames)




Fig. 4. Partially Observed Walking Motion - Animated from joint angle data. Right shoulder, arm, and leg are invisible. (1, 11, 21, 31, 41, 51 and 61 frames)




Fig. 5. Recovered Walking Motion using FHMM - Animated from recovered joint angle data using the trained walk motion model by the proposed method. (1, 11, 21, 31, 41, 51 and 61 frames)

その運動データから 9 個の HMM と 9 個の FHMM が学習された。各 FHMM は 10 個状態ノードを持つ HMM 二つで構成される。それに対して違う数の状態ノードを持つ 3 種類の HMM を用いる。FHMM の学習の方法中 [11] [12] [13], exact 学習方法 [11] を利用する。Kulić らは [4] 認識と生成に関して HMM と FHMM の比較を行い、原始シンボルを明確に区別するために原始シンボル空間の混雑している領域では FHMM を使うことを提案した。本稿では不観測データの復元の性能の比較を中心に行う。

実験 1 では、各 FHMM は 10 個の状態ノードを持つマルコフチェーン二つで構成され、各 HMM は 20 個の状態ノードを持つ。各運動は七つの複数のデータから学習される。図 4 のように右半分が見えない足踏みの観測データを復元する。この観測データは学習には使ってなかったデータである。図 5 は本稿で提案した FHMM を用いる方法からの復元した全身運動である。図 6 は左右膝関節の軌道を表す。観測データに対する最適な状態時系列から出力した平

均値で、スムージングを行う前の値である。この図から見られるように、状態数が多い FHMM の方がシングルチェーンの HMM よりよい精度を得ることが分かる。




Fig. 6. Comparison of missing motion data recovery results of HMM (10 states) and FHMM (2 chains of 10 states) for the right and left knee joints during a walking motion. In observed data, joint angles for right half of the body was missing. Invisible right knee joint angle is recovered closely to the true value.

実験 2 では、FHMM は実験 1 と同様で、各 HMM は 10×2 個の状態ノードを持つ。図 4 の部分観測データを用いて比較する。図 7 は復元後の左右膝関節の軌道を表す。スムージングを行う前の値である。FHMM と HMM は両方とも 20 個の状態ノードを持つが、FHMM は分散型状態を factorizing する事により最大 10^2 個の状態表現力を持つため、よい精度を得ることが分かる。




Fig. 7. Comparison of missing motion data recovery results of HMM (10×2 states) and FHMM (2 chains of 10 states) for the right and left knee joints during a walking motion, before any post processing is applied.

実験 3 では、FHMM は実験 1 と同様で、各 HMM は 10^2 個の状態ノードを持つ。図 4 の部分観測データを用いて比較する。図 8 は復元後の左右膝関節の軌道を表す。FHMM の表現力に等しい 10^2 個の状態を HMM は持つが、FHMM が HMM よりよい精度を得た。その理由は HMM は状態数が多くなると過学習に落ちりやすくなるからである。その結果新しい運動パターンに対する最適状態経路の計算性能が悪くなる。反面に FHMM は新しい運動パターンに対しても汎化性能に優れ、最適状態経路の計算性能もよい。

HMM を実装する際、計算的なオーバーフローあるいはアンダーフローを回避するため、スケーリングパラメータ [15] と対数尤度などを用いる。これ以外にも多くの研究で [16] [2] [4] 共分散行列の対角化、最低共分散値の設定等の対策がとられている。オーバーフローあるいはアンダーフローの理由の一つは HMM の過学習である。実験 4 では、複数のモデル構造に対して過学習の傾向を調べるため、最低共分散制限なしの非対角共分散行列 (full covariance matrix) を用いる。28 個の足踏み, 15 個の万歳, 14 個のダンス, 19 個のキック, 14 個のパンチ, 15 個の相撲のしこ, 14 個のうずくまる, 13 個の投げ, 15 個のしゃがみこみから 9 つの行動が学習された。各運動は次の八つのモデル構造へと学習された: 周期型 HMM

TABLE I
TRAINING SUCCESS RATIO WITHOUT OVER/UNDERFLOW [UNIT: %]

model	periodic HMM 10 states	periodic HMM 20 states	periodic HMM 100 states	periodic FHMM 2 chains of 10 states	LR HMM 10 states	LR HMM 20 states	LR HMM 100 states	left-to-right FHMM 2 chains of 10 states
walk	33	15.6	3.6	44.6	29.7	20.7	0	61
cheer	100	100	32	100	100	99.4	0	100
dance	100	100	32.6	100	100	100	0.3	100
kick	100	98.8	29.6	100	99.9	99.5	0	100
punch	100	100	46.67	100	100	100	0	100
SUMO	100	100	33.67	100	100	99.8	0.2	100
squat	100	100	39	100	100	99.7	0	100
throw	100	100	41.8	100	100	99.8	0	100
bow	100	100	26	100	99.8	98.4	0	99.9




Fig. 8. Comparison of missing motion data recovery results of HMM (10^2 states) and FHMM (2 chains of 10 states) for the right and left knee joints during a walking motion, prior to any post-processing.

(状態数 10), 周期型 HMM (状態数 20), 周期型 HMM (状態数 100), 周期型 FHMM (状態数 10, チェーン数 2), left-to-right 型 HMM (状態数 10), left-to-right 型 HMM (状態数 20), left-to-right 型 HMM (状態数 100), left-to-right 型 FHMM (状態数 10, チェーン数 2). 各運動の各モデルへの学習は 1000 回行い, その中で計算的なオーバーフローあるいはアンダーフローの問題なく学習効率を調べ, 表 I に示す. この表から, 状態 10 個のマルコフチェーン二つで構成されている FHMM が状態 10 個の HMM よりも過学習に落ちにくいことが分かる. 10^2 個の状態を持つ HMM は学習に成功しても, 抽象化した形で運動時系列を表現するミメシスモデルのシンボリック意味が弱くなる短所がある.

V. おわりに

本稿は FHMMs(factorial hidden Markov models) を利用して部分観測データの不観測要素を復元する方法を提案した. この方法は部分観測から全身運動見真似のアルゴリズムと類似な戦略をとる. 動作の表現力を改善できる FHMM を用いた. FHMM は分散型の状態を持つため, 過学習問題に落ちなく, よい動作表現ができる. FHMM 用の Viterbi アルゴリズムを開発し, 原始シンボルと観測データに条件付けられた運動生成に適応した. 実験では, 人間の運動を観察して見えない関節角の時系列を推定した. 実験結果から, HMM に比べて FHMM の方が過学習問題なく復元の精度も改選することを確認した.

本研究は, 平成 18 年度科学研究費補助金基盤研究 (S)「知能の力学的情報処理モデルの展開」と文部科学省「先端融合領域イノベーション創出拠点の形成: 少子高齢社会と人を支える IRT 基盤の創出」の支援を受けて実施したものである.

REFERENCES

[1] W. Takano, H. Tanie, and Y. Nakamura, "Key feature extraction for probabilistic categorization of human motion patterns," in *the 12th IEEE*

International Conference on Advanced Robotics (ICAR'05), Seattle, USA, July 2005, pp. 424–430.

- [2] W. Takano, K. Yamane, T. Sugihara, K. Yamamoto, and Y. Nakamura, "Primitive communication based on motion recognition and generation with hierarchical mimesis model," in *IEEE International Conference on Robotics and Automation*, Orlando, Florida, USA, May 2006, pp. 3602–3609.
- [3] T. Inamura, Y. Nakamura, and I. Toshima, "Embodied symbol emergence based on mimesis theory," *International Journal of Robotics Research*, vol. 23, no. 4, pp. 363–377, 2004.
- [4] D. Kulić, W. Takano, and Y. Nakamura, "Representability of human motions by factorial hidden markov models," in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'07)*, 2007.
- [5] A. Billard, S. Calinon, and F. Guenter, "Discriminative and adaptive imitation in uni-manual and bi-manual tasks," *Robotics and Autonomous Systems*, vol. 54, pp. 370–384, 2006.
- [6] D. Kulić, W. Takano, and Y. Nakamura, "Incremental on-line hierarchical clustering of whole body motion patterns," in *IEEE International Symposium on Robot and Human Interactive Communication*, 2007.
- [7] K. R. Dixon, J. M. Dolan, and P. K. Khosla, "Predictive robot programming: Theoretical and experimental analysis," *International Journal of Robotics Research*, vol. 23, pp. 955–973, 2004.
- [8] D. Lee and Y. Nakamura, "Mimesis from partial observations," in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'05)*, Edmonton, Canada, August 2005, pp. 1911–1916.
- [9] —, "Mimesis scheme using a monocular vision system on a humanoid," in *IEEE International Conference on Robotics and Automation (ICRA'07)*, Rome, Italy, April 2007, pp. 2162–2168.
- [10] —, "Motion capturing from monocular vision by statistical inference based on motion database: Vector field approach," in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'07)*, San Diego, USA, 2007, pp. 617–623.
- [11] Z. Ghahramani and M. I. Jordan, "Factorial hidden markov models," in *Machine Learning*, vol. 29, 1997, pp. 245–275.
- [12] R. A. Jacobs, W. Jiang, and M. A. Tanner, "Factorial hidden markov models and the generalized backfitting algorithm," *Neural Computation*, vol. 14, pp. 2415–2437, 2002.
- [13] D. Kulić, W. Takano, and Y. Nakamura, "Incremental learning of full body motions via adaptive factorial hidden markov models," in *7th International Conference on Epigenetic Robotics*, 2007.
- [14] L. R. Rabiner, "A tutorial on hidden markov models and selected applications in speech recognition," *Proc. IEEE*, pp. 257–286, 1989.
- [15] H. Juang, B. and R. Rabiner, L., "A probabilistic distance measure for hidden markov modeling," *AT&T Tech. J.*, vol. 64, no. 2, vol. 64(2), pp. 391–408, 1985.
- [16] D. Lee and Y. Nakamura, "Stochastic model of imitating a new observed motion based on the acquired motion primitives," in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'06)*, Oct. 10–13 2006, pp. 4994–5000.