

Coupled GP-HSMM を用いた時系列マルチモーダル情報の分節化に基づくインタラクションのモデル化

押川 慧¹ 中村 友昭¹ 長井 隆行² 岩橋 直人³
船越 孝太郎⁴ 竹内 誉羽⁵ 中野 幹生⁵ 金子 正秀¹

¹電気通信大学 ²大阪大学 ³岡山県立大学 ⁴京都大学 ⁵HRI-JP

¹{s.oshikawa, nakamura, kaneko}@radish.ee.uec.ac.jp

²nagai@sys.es.osaka-u.ac.jp ³iwahashi@c.oka-pu.ac.jp

⁴funakoshi.k@i.kyoto-u.ac.jp ⁵{johane.takeuchi, nakano}@jp.honda-ri.com

1 はじめに

近年、ロボットは様々な場面で活躍しており、今後インタラクションを行いながら我々の日常生活をサポートすることが予想される。その際、より自然なインタラクションが行われることが望ましい。しかし、地域や文化によって様々なインタラクションのルールが存在しているため、そのようなインタラクションのルールを事前に全て作りこむことは困難である。人間の場合、他者とのインタラクションや他者同士のインタラクションの観察から、インタラクションの中で行われる発話や動作の関係性を見つけ、インタラクションのルールを学習することができる。また、幼児は身近な人のふるまいを見て模倣し遊ぶことがあり、その模倣を通して動作やインタラクションを学習している。ロボットが人間と共存していくためには、人間と同様にインタラクションの観察によって学習することが重要であるといえる [1][2][3]。

そこで本稿では、連続動作や発話といったマルチモーダルな時系列情報を行動へと分節し、二者間の行動の関係を推定することで、その間で行われているインタラクションを教師なしで学習するモデルを提案する。本稿における連続動作とはインタラクション内の一連の動きのことであり、行動とはマルチモーダル情報から意味のある単位ごとに分節・分類された単位動作及び単位発話のペアである。本稿では、このようなインタラクションとして、旗揚げゲームを扱う。旗揚げゲームでは指示者の「赤上げて」といった発話と対応して、演者が旗を上げ・下げするゲームである。提案モデルではこのようなインタラクション内における連続動作と発話を分節し、類似した行動ごとに分類する。さらに分類された行動間関係も同時に学習する。本稿では、行動間関係がインタラクションのルールであると考え、提案モデルにより教師無しでインタラクションを学習することが可能となる。連続動作を教師なしで分節する手法として、GP-HSMM [6] や Autoplait [4], BP-HMM [5] などが提案されている。本稿では、その中でも分節化の精度が良いと報告されている GP-HSMM を、インタラクションが学習可能なモデルへと拡張した Coupled GP-HSMM を提案す




図 1: Coupled GP-HSMM

る。提案モデルでは、二者間の行動の関係を推定することで、双方のマルチモーダル情報から相補的に学習するため、分節化の精度向上が可能となる。

2 Coupled GP-HSMM に基づくインタラクションのモデル化

提案手法では、 α と β の二者の連続動作 S_α , S_β と発話 L_α , L_β を分節することによって得られる単位動作 x_α , x_β と単位発話 w_α , w_β と、その行動クラス c_α , c_β の関係を教師なしで学習する。図 1 が提案する Coupled GP-HSMM のグラフィカルモデルであり、灰色が観測ノードを表している。 X_c はクラス c のガウス過程のパラメータであり、単位動作 $x_{\alpha j'}$, $x_{\beta j}$ は $X_{c_{\alpha j'}}$, $X_{c_{\beta j}}$ をパラメータとするガウス過程によって生成される。 θ_c はクラス c における単語の発生確率であり、単位発話 $w_{\alpha j'}$, $w_{\beta j}$ は $\theta_{c_{\alpha j'}}$, $\theta_{c_{\beta j}}$ をパラメータとする多項分布から生成される。GP-HSMM では、 β の j 番目のクラス $c_{\beta j}$ は直前のクラスによってのみ生成される。一方、提案モデルにおいては β 自身の $j-1$ 番目のクラス $c_{\beta, j-1}$ と、それと対応する α のク

ラス $c_{\alpha j'}$ によって生成されることを仮定し、以下のような生成過程で表現される。

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

$$c_{\beta j} \sim P(c|c_{\beta, j-1}, c_{\alpha j'}) \quad (2)$$

$$\mathbf{x}_{\alpha j'} \sim \mathcal{GP}(\mathbf{x}|\mathbf{X}_{c_{\alpha j'}}) \quad (3)$$

$$\mathbf{x}_{\beta j} \sim \mathcal{GP}(\mathbf{x}|\mathbf{X}_{c_{\beta j}}) \quad (4)$$

$$\mathbf{w}_{\alpha j'} \sim P(\mathbf{w}|\boldsymbol{\theta}_{c_{\alpha j'}}) \quad (5)$$

$$\mathbf{w}_{\beta j} \sim P(\mathbf{w}|\boldsymbol{\theta}_{c_{\beta j}}) \quad (6)$$

生成されたそれぞれの単位動作と単位発話を結合することによって観測系列 \mathbf{S}_α , \mathbf{S}_β , \mathbf{L}_α , \mathbf{L}_β が生成される。この Coupled GP-HSMM は二人の行動が相互に影響するモデルとなっており、実際のインタラクションからこのモデルのパラメータを学習することで、連続動作と発話を行動へと分節しながら、二人の行動の関係を推定することが出来る。

2.1 単位動作の生成モデル

行動に含まれる単位動作 \mathbf{x} のタイムステップ i における出力値 x_i をガウス過程回帰で学習することで、連続的な分布として表現する。ガウス過程ではクラス c に属する単位動作のタイムステップ i における出力 x の複数のペア $(\mathbf{I}, \mathbf{X}_c)$ が得られた時、タイムステップ i^{new} における出力 x^{new} の予測分布は次式のガウス分布となる。

$$p(x^{new}|i^{new}, \mathbf{X}, \mathbf{I}) \propto \mathcal{N}(\mathbf{k}^T \mathbf{C}^{-1} \mathbf{I}, c - \mathbf{k}^T \mathbf{C}^{-1} \mathbf{k}) \quad (7)$$

ただし、 $k(\cdot, \cdot)$ をカーネル関数として、 \mathbf{I} の u 番目と v 番目を i_u, i_v とすると、 \mathbf{C} は、

$$\mathbf{C}(i_u, i_v) = k(i_u, i_v) + \epsilon^{-1} \delta_{uv} \quad (8)$$

を u 行 v 列の要素に持つ行列であり、 ϵ は観測値に含まれるノイズの精度を表すハイパーパラメータである。 δ_{uv} は、 $u = v$ のとき 1、それ以外は 0 となるデルタ関数である。また、 \mathbf{k} は $k(i_u, i^{new})$ を u 番目の要素に持つベクトルであり、 $c = k(i^{new}, i^{new})$ である。

動作が多次元ベクトルの場合、各次元が独立に生成されることを仮定し、 \mathbf{x}_i がクラス c に対応するガウス過程から生成される確率 $\mathcal{GP}(\mathbf{x}_i|\mathbf{X}_c)$ を以下のように定義する。

$$\begin{aligned} \mathcal{GP}(\mathbf{x}|\mathbf{X}_c) &= p(x_0|i, \mathbf{X}_{c,0}, \mathbf{I}) \\ &\quad \times p(x_1|i, \mathbf{X}_{c,1}, \mathbf{I}) \\ &\quad \times p(x_2|i, \mathbf{X}_{c,2}, \mathbf{I}) \cdots \end{aligned} \quad (9)$$

この確率を用いることで似た単位行動を同じクラスに分類することが出来る。

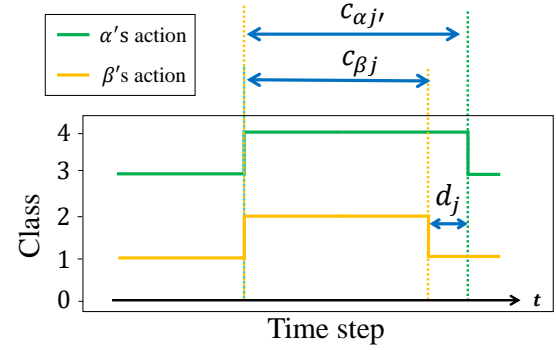


図 2: インタラクションの時間差

2.2 単位発話の生成モデル

各クラスに対応した単位発話内の単語の発生確率を多項分布で表現する。単位発話 \mathbf{w} は単語 w_0, w_1, \dots が連結されて生成されたと考え、多項分布のパラメータを $\boldsymbol{\theta}_c$ とすると、クラス c から単位発話 \mathbf{w} 生成される確率 $p(\mathbf{w}|\boldsymbol{\theta}_c)$ は以下ようになる。

$$p(\mathbf{w}|\boldsymbol{\theta}_c) = \prod_n p(w_n|\boldsymbol{\theta}_c) \quad (10)$$

ただし、

$$p(w|\boldsymbol{\theta}_c) = \frac{N_{cw} + \phi}{N_c + W\phi} \quad (11)$$

であり、 N_c はクラス c に分類された単語数、 N_{cw} はクラス c に分類された単語 w の個数を表している。また、 W は単語の種類数を、 ϕ は多項分布の事前分布であるディリクレ分布のパラメータである。

2.3 インタラクション内の行動の時間差

現実のインタラクションでは、二者間の対応する行動が必ずしも同時に行われるわけではなく、図 2 のように時間差が生じる場合がある。提案手法ではこの時間差も教師なしで推定する。時刻 i に α が行動 $c_{\alpha j'}$ を、 β が行動 $c_{\beta j}$ をしている場合、このインタラクションの時間差 d_j がガウス分布に従うと仮定している。

$$p(d_j) = \mathcal{N}(d|0, \sigma^2) \quad (12)$$

この確率に基づき、行動間の時間差 d_j も同時に推定する。

2.4 学習

提案手法では、時系列マルチモーダル情報の行動（単位動作と単位発話）とそのクラスをサンプリングすることで、モデルのパラメータを推定する。これには、一つの観測系列の行動とそのクラスをまとめてサンプリングする Blocked Gibbs Sampler を用いる。

2.4.1 Blocked Gibbs Sampler

提案手法では、観測系列内の行動とそのクラス、行動の時間差をサンプリングすることでパラメータを

推定する．まず，全ての観測系列をランダムに分節・分類し，一つの観測系列をクラスから除き，各クラスのガウス過程のパラメータ \mathbf{X}_c ，単語発生確率のパラメータ θ_c ，遷移確率 $P(c|c')$ ，行動間の関係を表現する確率分布 $P(c_\alpha|c_\beta)$ のパラメータを更新する．その後，次式に従い単位動作 \mathbf{X}_α ，単位発話 \mathbf{W}_α ，クラス C_α ，二者の行動間の時間差 D_α をサンプリングする．

$$\begin{aligned} & \mathbf{X}_\alpha, \mathbf{W}_\alpha, C_\alpha, D_\alpha \\ & \sim P(\mathbf{X}_\alpha, \mathbf{W}_\alpha, C_\alpha, D_\alpha | \mathbf{S}_\alpha, \mathbf{S}_\beta, \mathbf{L}_\alpha, \mathbf{L}_\beta) \end{aligned} \quad (13)$$

ただし，

$$\mathbf{X}_\alpha = (\mathbf{x}_{\alpha 1}, \dots, \mathbf{x}_{\alpha J'}) \quad (14)$$

$$\mathbf{W}_\alpha = (\mathbf{w}_{\alpha 1}, \dots, \mathbf{w}_{\alpha J'}) \quad (15)$$

$$C_\alpha = (c_{\alpha 1}, \dots, c_{\alpha J'}) \quad (16)$$

$$D_\alpha = (d_{\alpha 1}, \dots, d_{\alpha J'}) \quad (17)$$

このようにしてサンプリングされた観測系列の全ての分節とクラスを用いて，各クラスのガウス過程のパラメータ \mathbf{X}_c ，単語の発生確率 θ_c ，遷移確率 $P(c|c')$ ，相互関係 $P(c_\alpha|c_\beta)$ を更新する．その後グラフィカルモデルの α と β を反転させ，観測系列 \mathbf{S}_β に対して同様に単位動作，単位発話，クラス，二者の行動間の時間差をサンプリングし，パラメータを更新する．これらの操作を繰り返すことで，双方の観測系列の分節とモデルのパラメータを交互に最適化する．

2.4.2 Forward filtering-Backward sampling

Blocked Gibbs Sampler では，式 (13) によるサンプリングが必要となる．しかし，式 (13) では行動，クラス，行動間の時間差のあらゆる組み合わせを計算しなければならず計算量が膨大になってしまう．そこで，文献 [7] と同様に Forward filtering-Backward sampling を用いて式 (13) を効率的に計算する．Forward filtering-Backward sampling では，行動とそのクラス，時間差を隠れ変数とみなして，同時にサンプリングする．Forward filtering では観測系列のあるタイムステップ t を終点とする長さが k の分節 $\mathbf{x}_{t-k:t}$ ， $\mathbf{w}_{t-k:t}$ がクラス c となり，その時相手との行動のずれが d である確率 $A_\alpha[t][k][c_\alpha][d]$ を次のように計算する．

$$\begin{aligned} A_\alpha[t][k][c_\alpha][d] = & \mathcal{GP}(\mathbf{x}_{t-k:t} | \mathbf{X}_{c_\alpha}) p(c_\alpha | \bar{c}_{\beta, t+d}) p(\mathbf{w}_{t-k:t} | \theta_{c_{\alpha j'}}) p(d) \\ & \times \sum_{k'=1}^K \sum_{c'=0}^C \sum_{d'=-D}^D p(c_\alpha | c'_\alpha) A_\alpha[t-k][k'][c'] [d'] \end{aligned} \quad (18)$$

C はクラス数， K は行動の最大の長さ， D はずれの最大値となる． $p(d)$ はガウス分布であり， $\bar{c}_{\beta, t+d}$ は時刻 $t+d$ における α の行動クラスを表している．また，クラスの遷移確率 $p(c_\alpha | c'_\alpha)$ と二者間の行動の相互関係

$p(c_\alpha | c_\beta)$ は，次式のようになる．

$$p(c_\alpha | c'_\alpha) = \frac{N_{c'_\alpha c_\alpha} + \lambda}{N_{c'_\alpha} + C\lambda} \quad (19)$$

$$p(c_\alpha | c_\beta) = \frac{N_{c_\beta c_\alpha} + \gamma}{N_{c_\beta} + C\gamma} \quad (20)$$

ただし， $N_{c'_\alpha}$ と $N_{c'_\alpha c_\alpha}$ はそれぞれ，クラスが c'_α となった行動の数と，クラスが c'_α から c_α に遷移した回数を表している．また， N_{c_β} と $N_{c_\beta c_\alpha}$ はそれぞれ，クラスが c_β となった β の行動の数と， β がクラス c_β の行動をしている時に α がクラス c_α の行動をした回数を表している．式 (18) において， k' ， c' ， d' は一つ前の $t-k$ を終点とした行動の長さ，クラス，時間差を表しており，その可能性を周辺化している．

次に Forward filtering によって求めた確率に従い，Backward sampling を行うことで観測系列の全ての分節，クラス，時間差を後ろ方向からサンプリングすることで決定する．

3 実験

提案手法によりインタラクションの学習ができるか確認するために，旗揚げゲームを行う二人のデータを想定した 2 組のデータを生成し，予備実験を行った．旗揚げゲームは，指示者が「赤上げて」「赤下げて」「白上げて」「白下げて」のいずれかを指示し，もう一方の人物（演者）がその指示に合わせて手に持った旗を上げ・下げするゲームである．図 3(a) と (b) が旗揚げゲームを想定した発話と連続動作の一例である．図 3(a) では，横軸が時間，縦軸が単語となっており，話者が発話した単語が点で表現されている．図 3(b) は，演者の両手の奥行きを除いた x 座標（左右）と y 座標（上下）である．

Coupled GP-HSMM では，クラス数を事前に設定する必要があるため，本実験ではクラス数 C を 9 とした．図 3(c) が，これらの発話と動作を分節した結果である．結果より，分節された各行動 ID は以下のような行動を表していると考えられる．

1. 右手を上上げる動作
2. 「赤下げて」と発話
3. 「白上げて」と発話
4. 「白下げて」と発話
5. 「赤上げて」と発話
6. 右手を下に下げる動作
7. 左手を上あげる動作
8. 左手を下に下げる動作

この図より，例えば指示者の発話「赤」と「上げて」が単位発話として行動 ID5 に分類されており，一つのまとまった行動であることが学習されている．さらに，指示者の発話と対応して，演者の右手の y 座標が大きくなる動作，すなわち赤旗を上げる動作が単位動




図 3: 旗揚げゲームでの (a) 指示者の発話, (b) 演者の動作, (c) 分節結果

作として行動 ID1 となっている。それに続いて、指示者の「赤」と「下げて」という発話が単位発話として行動 ID2 に分類されており、それと対応した右手の y 座標が小さくなる動作が、単位動作として行動 ID6 となっている。このように、Coupled GP-HSMM により、二者間の発話と動作の関係性が捉えられていることがわかる。

4 まとめ

本稿では、二者間の連続動作と発話といったマルチモーダルな系列を、単位発話と単位動作で構成される行動へと分節し、その行動間の関係を学習するモデルである Coupled GP-HSMM を提案した。実験では、旗揚げゲームを想定した発話と連続動作のデータを用いて、提案手法の有効性を検証した。非常にシンプルな発話と連続動作であるが、提案手法によって適切に分節されていることが確認できた。

今後、実際に人同士がゲームをしているシーンの発話と動作を利用し、Coupled GP-HSMM で学習可能かを検証する予定である。さらに、例えばターンテイクングや、発話と動作の組み合わせによって次に続く行動が変わるような、より複雑なルールを含むインタラクションに適用することを考えている。

参考文献

- [1] A. Billard, S. Calinon, R. Dillmann, and S. Schaal, "Robot programming by demonstration," Springer Handbook of Robotics, pp. 1371–1394, 2008
- [2] B. D. Argall, S. Chernova, M. Veloso, and B. Browning, "A survey of robot learning from demonstration," Robotics and autonomous systems, vol. 57, no. 5, pp. 469–483, 2009
- [3] S. Schaal, "Is imitation learning the route to humanoid robots?," Trends in cognitive sciences, vol. 3, no. 6, pp. 233–242, 1999
- [4] 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
- [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] T. Nakamura, T. Nagai, D. Mochihashi, I. Kobayashi, H. Asoh, and M. Kaneko, "Segmenting continuous motions with hidden semi-Markov models and Gaussian processes," Frontiers in Neurobotics, vol. 11, article 67, 2017
- [7] K. Uchiumi, H. Tsukahara, and D. Mochihashi, "Inducing word and part-of-Speech with Pitman-Yor hidden semi-Markov models," in Proc. ACL-IJCNLP, pp. 1774–1782, 2015