

業務分析のためのトピックモデルを用いた行動推定

Activity Recognition using Topic Models for Work Analysis

村上 知子 田中 俊明 内平 直志
Tomoko Murakami Toshiaki Tanaka Naoshi Uchihira

株式会社東芝 研究開発センター
Corporate R&D Center, Toshiba corporation

The downsizing of sensors and the development of radio technologies have allowed us to collect data related to human activities for a long term. It is expected that activity recognition is applied to health management, business support service in medical and health service and so on. Human activities are generally estimated from sensor data using supervised learning, in which class labels are usually annotated by the subject. Since activities are so diverse from simple activities such as posture to complicated workings, the task of annotating activities is heavy for the subject. In this paper we propose a method to estimate complicated working activities using unsupervised learning. We assume that complicated working activities are upper activities composed of the combination of various simple activities and apply topic model to estimate those upper activities. We also verify the proposed method through the experiment of housework estimation using mobile acceleration sensor data.

1. はじめに

センサや記録デバイスの小型化、無線技術の発展により、人体の動作や生体活動に関する情報を長期間収集することが可能になった。センサや音声などの様々なデータから人がどのような行動を行っているかを推定する行動推定技術は、健康管理支援、医療や介護などの業務支援、異常検知などの様々なサービスへの応用が期待されている。

従来、行動推定の研究は主にユビキタス、ウェアラブル系研究者等によって精力的に進められ、センサデータに対して様々な機械学習手法を用いた行動の推定が試みられてきた [BL 07, Hu 08, NR 05, DP 03, LB 04]。行動推定においては、一般的に、センサデータから生成される特徴量を説明変数、実際の行動を表すクラス情報を目的変数として分類モデルを学習することによって行動を推定する。クラス情報は、被験者自身の手によって、姿勢や体勢などの基本的な行動や比較的長期におよぶ複雑な行動や業務に対してアノテーションされることが多く、それらに要する人的負荷は非常に高い。

本論文では、アノテーションされたクラス情報を用いない教師なし学習によるセンサ情報からの行動や業務の推定手法を提案する。行動や業務は、姿勢や体勢などの基本的な行動に相当する下位行動の複雑な組み合わせとして表される上位行動であると仮定し、センサ情報から得られる下位行動に対してトピックモデルを適用することによって上位行動を推定する。また、装着型加速度センサからの家事行動の推定実験を通じて提案手法を評価する。

本論文は以下のように構成される。2章で行動推定の従来研究を紹介する。3章でトピックモデルを用いた行動推定に関して述べる。4章で家事行動の推定実験に関して説明する。5章で結論と今後の展望を述べる。

2. 関連研究

行動推定の研究は、人の状態や活動をセンシングおよび記録するセンシング技術の分野と記録されたデータから特徴量を選択および生成して行動を推定するデータマイニング技術の主に2つの重要な研究分野から成る。人々の生活に各種センサが浸透し多種多様なデータを持続的に収集されるに伴い、行動推定における両分野の研究活動もますます活発化している。

行動推定の対象は、姿勢や体勢、移動手段、場所、日常生活行動や業務の大きく4種類に分類することができる。立位や歩行などの基本的な行動に相当する姿勢や体勢を推定する研究は、近年、携帯電話などの端末に加速度センサが標準で搭載されるようになったために盛んになってきている [SP 09, HASC]。さらに、日常生活行動や業務の推定は、4種類の対象のうち最も複雑であるため推定が困難である。しかし、それらが実現した際の応用範囲の広さから、センサを備えた実験用施設でデータ収集し日常生活における活動・家事の推定を試みる研究が精力的に進められている [SI 06, ET 06]。

行動の推定には、決定木 [RQ 93]、ナイーブベイズ [DP 97]、クラスタリング [SM 99]、ダイナミックベイジアンネットワーク [DT 89]、条件付き確率場 [JL 01]、隠れマルコフモデル [LB 70]、サポートベクタマシン [CC 95] などの機械学習手法が用いられており、特にナイーブベイズと決定木は広く適用されている。一般的に、センサデータと教師データの両方を用いる教師あり学習による行動推定は、被験者や観測者が観察・推測してクラス情報をアノテーションする作業のコストが高いという問題がある。さらに、日常生活や業務における行動は、比較的長時間におよぶ複雑な行動であるため、業務においては個人によって差があること、同一人物による業務においても毎回行動内容に差があることなどの特徴がある。そのため、行動の順序や構造、モデルを固定しない推定手法が適していると考えられる。

本論文では、クラス情報を用いない教師なし学習によるセンサ情報からの行動や業務の推定方式を考える。その際、教師なし学習のひとつであるトピックモデル [DB 03] を用いて行動を推定する。次章でトピックモデルを用いた行動推定を説明する。

連絡先: 村上 知子, (株) 東芝研究開発センター,
住所: 〒 212-8582 川崎市幸区小向東芝町 1
電話番号: 044-549-2406
メールアドレス: tomoko.murakami@toshiba.co.jp

表 1: 姿勢及び体勢の出現頻度と推定評価値

姿勢および体勢	時間	precision	recall	fmeasure	AUC	MAE
腰を曲げた姿勢 (bending)	1196	0.2974362	0.197698	0.237408	0.766912	0.160302
膝まづく姿勢 (kneeling)	658	0.3446757	0.496656	0.406181	0.827574	0.072101
座位 (sitting (state))	1603	0.7308748	0.910344	0.810683	0.966244	0.052939
しゃがんだ姿勢 (squatting)	489	0.3292587	0.328582	0.328138	0.771739	0.062677
立位 (standing still (state))	5126	0.5338643	0.826313	0.648547	0.790655	0.327753
歩行 (walking)	2979	0.3832273	0.445415	0.411605	0.727409	0.316889

3. トピックモデルの行動推定への適用

行動や業務の多くは粒度に応じて階層化され、階層の上位の行動は下位の行動から構成されていることが多い。また、上位の行動において下位の行動がどの程度を観測されるのかは、人や機会に応じて差があるという特徴がある。例えば家事行動を挙げてみよう。家事には炊事、洗濯、掃除などいくつかの種類が存在し、そのうちのひとつである炊事には食材や器具の準備や調理、片付けなどの様々な作業が含まれる。さらに、炊事において食材や器具の準備、調理、片付けにどの程度時間を割くかは献立等に応じて毎回異なってくる。本論文では、行動や業務などの上位行動はより粒度の細かい下位行動の確率的な組み合わせで表されると考え、トピックモデルを適用することによって上位行動を推定する。

トピックモデルは自然言語処理の研究分野で誕生した手法で、文書は様々なトピックから成り立ち、また、トピックは様々な単語の確率分布で表されるという基本的な考えに基づいて、文書の話題抽出や文書分類に応用されている。トピックモデルの行動推定への適用においては、上位行動 z をトピック、下位行動 w を単語と見なした。そして、下位行動から構成される動作系列データ d が与えられた時、各動作データ d における上位行動の分布 $P(z) = \theta^d$ 、各上位行動 z における下位行動の分布 $P(w, z) = \phi^z$ 、各下位行動 w に対して割り当てる上位行動 $P(z|w)$ の 3 つの潜在変数を推定することによってモデルを生成する。

モデル生成においては、観測されるある特定の下位行動 w_i に対して、それ以外の下位行動に対して上位行動 (z_{-i}) が割り当てられている場合の、上位行動 j が割り当てられる条件付き確率を計算することによって θ や ϕ を推定する。条件付き確率は以下の式で求められる。

$$P(z_i = j | z_{-i}, w_i, d_i, \cdot) = \frac{C_{w_i j}^{WT} + \beta}{\sum_{w=1}^W C_{w j}^{WT} + W\beta} \frac{C_{d_i j}^{DT} + \alpha}{\sum_{t=1}^T C_{d_i t}^{DT} + T\alpha}$$

ここで、 C^{WT} は下位行動と上位行動の頻度行列 ($W \times T$) を、 C^{DT} は動作データと上位行動の頻度行列 ($D \times T$) を表わす。 W, D, T はそれぞれ下位行動数、動作データ数、上位行動数を表わし、 α, β はシステム設計者が与えるパラメータを指す。潜在変数の推定モデル生成は、変分ベイズ [DB 03] やギブスサンプリング [TG 04] などの一般的によく知られている近似計算方法を利用する。近似計算によって、上位行動 j における下位行動 w_i の確率を ϕ_{ij}^j 、動作データ d における上位行動 j の確率を θ_j^d とすると、以下の式でパラメータ ϕ と θ の推定値が計算される。

$$\phi_{ij}^j = \frac{C_{ij}^{WT} + \beta}{\sum_{k=1}^W C_{kj}^{WT} + W\beta} \quad (1)$$

$$\theta_j^d = \frac{C_{dj}^{DT} + \alpha}{\sum_{k=1}^T C_{dk}^{DT} + T\alpha} \quad (2)$$

式 (1) から上位行動に占める下位行動の分布、式 (2) から各動作データに占める上位行動の分布が計算されると同時に、各下位行動に対して上位行動が割り当てられる。

4. 実験

4.1 データ

本実験では、MIT PlaceLab の公開データセットのひとつ PLIA1(PlaceLab Intensive Activity 1)[MITPL] を利用した。PLIA1 は、1 名の被験者が 2005 年 3 月 4 日 9 時から 12 時までの 4 時間、多種類のセンサを設置した実験住宅で生活した際のデータで、センサデータと被験者自身が付与した実際の行動を表わす行動ラベルデータから成る。

本実験では、業務分析への応用の立場から、装着型人物加速度センサで収集されたデータを利用した。加速度センサは被験者の腕と膝にそれぞれ装着され、得られるデータは x, y, z 軸方向計 6 次元の加速度で連続値 [0-1023] をとる。行動ラベルは、実験住宅に設置された 4 台のカメラで撮影された映像を被験者自身が視聴し確認する作業によって、以下の情報が付与されている。

- 姿勢や体勢に関する 14 種類の基本動作
(例) 座位 (sitting(state)), 立ったまま静止 (standing still(state)), しゃがんだ姿勢 (squatting)
- 家事オントロジで定義された 9 種類の大分類, 82 種類の小分類家事行動
(例) 大分類: 掃除 (Cleaning), 小分類: 拭き掃除, モップ掛け, 掃除機掛け, ゴミ捨て等

4.2 下位行動の推定

本実験ではまず、センサ情報から姿勢や体勢に関する 14 種類の基本動作を推定した。実験の前処理として、センサデータを 1 秒の時間窓で分割した後、時間窓内のデータの中央値を 1 事例として、各事例に対して行動ラベルを付与することによって実験用データを作成した。従来研究で最も広く用いられている naive Bayes を利用して推定し、それらの結果は MCCV(Monte Carlo Cross Validation) を用いて検証した。具体的には、ランダムにデータを 2 分割して半分のデータを用いた学習と残り半分のデータを用いた予測を 5 回繰り返し、その平均評価値を計算した。評価指標には適合率、再現率、F 値、AUC(Area Under the Curve)、MAE(Mean Absolute Error) を用いた。

14 種類の基本動作のうち、全データ 14,079 秒のうち少なくとも 10% 以上出現する動作のみを推定の対象とした。姿勢

表 2: 家事行動と上位行動との相関

家事行動	上位行動 0	上位行動 1	上位行動 2	上位行動 3	上位行動 4	上位行動 5	上位行動 6
MealPreparation	0.3649	0.0006	0.2541	0.0583	0.0891	0.1953	0.0377
Laundry	0.1937	0.0020	0.1252	0.0724	0.3014	0.3014	0.0039
Personal	0.0193	0.7954	0.0092	0.0092	0.1550	0.0119	0.0000
Hygiene	0.0000	0.0000	1.0000	0.0000	0.0000	0.0000	0.0000
Cleaning	0.1589	0.0008	0.1177	0.2287	0.2525	0.0991	0.1423
Dishwashing	0.4960	0.0000	0.1952	0.0483	0.0752	0.1817	0.0036
Infomation/Leisure	0.0641	0.1363	0.0511	0.1322	0.4981	0.0330	0.0852

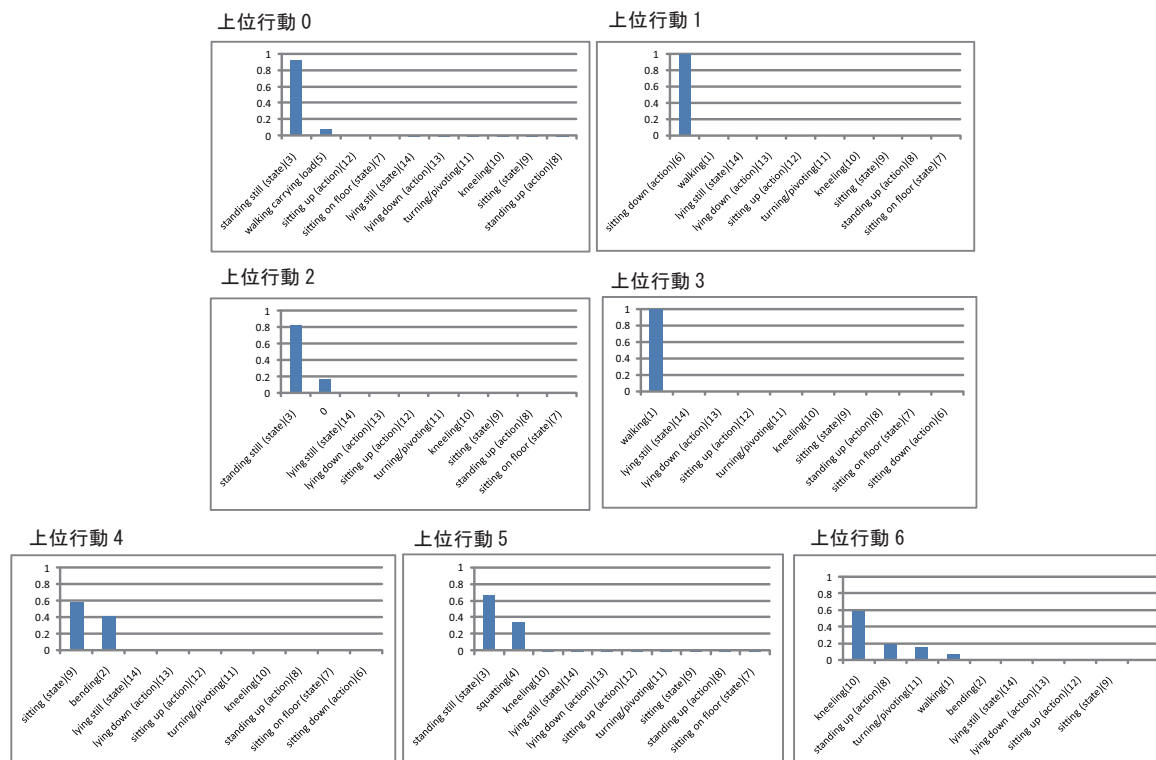


図 1: 上位行動における下位行動の分布 (ϕ)

や体勢別の出現時間と評価値を表 1 に示す．表 1 から，しゃがんだ姿勢が最も短く約 489 秒間，立って静止している立位が約 5126 秒間で最も長いことが分かる．さらに，座位の推定に関して適合率，再現率，F 値，AUC による評価値がいずれも最高で，かつ MAE が最低であることから最も良い性能を示しており，次いで立位の推定が良いことが分かるが，他の姿勢および体勢の推定は 20% から 30% の適合率のためうまく推定できていないことが分かる．

4.3 上位行動の推定

次に，トピックモデルを適用することによって，姿勢や体勢などの下位行動から上位行動に相当する家事行動の推定を試みた．推定する家事行動は，家事オントロジで定義された 82 種類の家事行動のうち，最も大きな分類カテゴリに相当する炊事 (MealPreparation)，洗濯 (Laundry)，身仕度・運動などの個人活動 (Personal)，衛生 (Hygiene)，掃除 (Cleaning)，皿洗い (Dishwashing)，レジャー (Infomation/Leisure) の 7 種類

とした．人手で付与された姿勢や体勢などの行動ラベルを下位行動 (w) として，下位行動の系列データを時間幅 $s = 60$ (秒) で分割して動作データ (d) を作成し，トピックモデルの入力情報とした．分割データ数 D は 229 個，下位行動数 W は 14 個，上位行動数 T は 7 個となった．提案手法によって，各動作データにおける上位行動の分布 (θ) (式 (2)) と各上位行動における下位行動の分布 (ϕ) (式 (1))，各下位行動データに対して割り当てられる上位行動 (z) の 3 つの潜在変数を推定する．潜在変数の推定には処理速度と性能のバランスから collapsed Gibbs sampling [TG 04] を用いた．パラメータは経験的に $\alpha = 50.0/T$ ， $\beta = 0.1$ とした．

実験の結果を表 2 と図 1 に示す．表 2 は実際の各家事行動に対する上位行動の出現頻度分布を表し，表中の各行の値を比較して他より比較的大きな値を太字で示している．個人活動，衛生，レジャーに対してはそれぞれ上位行動 1, 2, 3 の値が高いことから，他の家事行動と重複せずに上位行動が一意に決まることが分かる．また，炊事と皿洗いに関しては共に上位行動 0

の値が高く、上位行動が一意に決まるものの割り当てられた上位行動が他の家事行動と重複することが分かる。一方、洗濯、掃除に関しては比較的大きな値が複数存在することから、上位行動が一意に決まらない様子がうかがえる。

さらに、図1は各上位行動における下位行動の分布を示している。図1から、個人活動と関連の高い上位行動1は立位や歩行動作から座る行動(sitting down(action))が99%占めていることが分かる。衛生と関連の高い上位行動2は立ったまま静止している状態(standing still(state))が83%、ラベルのない行動が16%を占めていること、レジャーと関連の高い上位行動4は座っている状態(sitting(state))が57%、腰を屈めた状態(bending)が42%を占めていることが分かる。以上の結果から、個人活動、衛生、レジャーに関しては、妥当な下位行動分布を持つ上位行動が割り当てられていることが確認できた。一方で、炊事と皿洗いに割り当てられた上位行動0は、立って静止している状態(standing still(state))が92%、物を運びながら歩く行動(walking carrying load)が6%を占めているため、下位行動の分布としては妥当であるが両者の弁別が困難であることがうかがえる。洗濯に関しては歩行(walking)が99%を占める上位行動3と上位行動4、掃除に関してはstanding still(state)66%、しゃがむ体勢が33%を占める上位行動5と上位行動4が同程度割り当てられていることから、まったく異なる下位行動の分布を持つ複数の上位行動が割り当てられていることから行動自体が複雑で分類が困難な上位行動であることが分かる。

5. 終わりに

本論文では、クラス情報を用いない教師なし学習によるセンサー情報からの上位行動推定手法を提案した。提案手法では、業務や日常行動などの上位行動は姿勢や体勢などのより粒度の細かい下位行動の確率的な組み合わせで表されると仮定し、トピックモデルを適用することによって上位行動を推定した。また、装着型加速度センサからの家事行動の推定実験を通じて方式を評価した。今後は、本方式によって推定される上位行動に対して事前知識などを利用したアノテーションをすることによって、医療や介護などの業務支援への応用を検討していく。

謝辞

本研究は独立行政法人科学技術振興機構(JST)の「問題解決型サービス科学研究開発プログラム」の支援を受けて行われた。

参考文献

- [HASC] 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構築 Human Activity Sensing Consortium(HASC), <http://hasc.jp/>.
- [SM 99] 宮本定明: クラスター分析入門 ファジィクラスタリングの理論と応用, 森北出版株式会社, (1999).
- [LB 04] L. Bao and S. Intille: Activity recognition from user-annotated acceleration data, In Proc. of Int'l Conf. on Pervasive Computing (PERVASIVE), pp.1-17, (2004).
- [LB 70] L. E. Baum et al.: A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains, The Annals of Mathematical Statistics, Vol. 41, No.1, pp.164-171, (1970).

- [DB 03] D. M. Blei et al.: Latent Dirichlet Allocation, J. of Machine Learning Research (JMLR), Vol.3, pp.993-1022, (2003).
- [CC 95] C. Cortes and V. Vapnik: Support-vector networks, Machine learning, Vol.20, No.3, pp.273-297, (1995).
- [DT 89] T. Dean and K. Kanazawa: A model for reasoning about persistence and causation, J. of Computational Intelligence, Vol.5, No.3, pp.142-150, (1989)
- [DP 97] P. Domingos and M. Pazzani: On the optimality of the simple Bayesian classifier under zero-one loss, J. of Machine Learning, Vol.29, No.2-3, pp.103-130, (1997).
- [TG 04] T. L. Griffiths and M. Steyvers: Finding scientific topics, In Proc. of the National Academy of Sciences of the United States of America(PNAS), Vol.101, No.Suppl.1, pp.5228-5235 (2004)
- [Hu 08] D. Hao Hu et al.: Real World Activity Recognition with Multiple Goals, In Proc. of Int'l Conf. on Ubiquitous Computing (UbiComp), pp.30-39, (2008).
- [SI 06] S. Intille et al.: Using a live-in laboratory for ubiquitous computing research, In Proc. of Int'l Conf. on Pervasive Computing (PERVASIVE), pp.349-365, (2006).
- [JL 01] J. Lafferty, A. McCallum, and F. Pereira: Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data, Int'l Conf. on Machine Learning(ICML), (2001).
- [BL 07] B. Logan et al.: A Long-Term Evaluation of Sensing Modalities for Activity Recognition, In Proc. of Int'l Conf. on Ubiquitous Computing (UbiComp), pp.483-500, (2007).
- [MITPL] MIT PlaceLab: http://architecture.mit.edu/house_n/data/PlaceLab/PlaceLab.htm
- [DP 03] D. J. Patterson et al.: Inferring high-level behavior from low-level sensors, In Proc. of Int'l Conf. on Ubiquitous Computing (UbiComp), pp.73-89, (2003).
- [SP 09] S. J. Preece et al.: Activity identification using body-mounted sensors? a review of classification techniques, J. of Physiological Measurement, Vol.30, No.4, R1-R33, (2009).
- [RQ 93] R. J. Quinlan: C4.5: Programs for Machine Learning, Morgan Kaufmann, San Mateo, CA, (1993).
- [NR 05] N. Ravi et al.: Activity Recognition from Accelerometer Data, In Proc. of the National Conf. on Artificial Intelligence (AAAI), pp.1541-1546, (2005).
- [ET 06] E. Tapia et al.: The design of a portable kit of wireless sensors for naturalistic data collection, In Proc. of Int'l Conf. on Pervasive Computing (PERVASIVE), in Proc. of PERVASIVE 2006, pp.117-134, (2006).