

# マルコフ性を仮定した混合ディリクレ分布を用いた 日常生活行動モデリング

Modeling of activities of daily living using Dirichlet mixture and Markov property

佐土原健<sup>\*1</sup> 児島 宏明<sup>\*1</sup> 二瓶 美里<sup>\*2</sup> 大中 慎一<sup>\*3</sup> 井上 剛伸<sup>\*4</sup>  
Ken Sadohara Hiroaki Kojima Misato Nihei Shinichi Onaka Takenobu Inoue

<sup>\*1</sup>産業技術総合研究所

<sup>\*2</sup>東京大学

National Institute of Advanced Industrial Science and Technology (AIST) The University of Tokyo

<sup>\*3</sup>日本電気株式会社  
NEC Corporation

<sup>\*4</sup>国立障害者リハビリテーションセンター研究所  
Research Institute of National Rehabilitation Center for Persons with Disabilities

This paper is concerned with the modeling of activities of daily living (ADLs) from time-series data in the smart home applications. Given a sequence of events of motion sensors in the home of a user, an unsupervised algorithm builds a model of ADLs for the user and predicts a sequence of activities. The model is based on a Dirichlet mixture (DM) distribution and assumes Markov property for both activities and sensors. For the learning of the model and the prediction of activities, a Gibbs sampler is presented. An empirical study on real-life data shows that the presented model outperforms LDA and DM.

## 1. はじめに

社会の高齢化に伴って、独り暮らしの高齢者が増加しており、厚生労働省の平成 26 年度国民生活基礎調査 [厚労省 14] によれば、65 歳以上の独居高齢者世帯数は、およそ 596 万世帯 (全世帯数の 11.8%) にのぼっている。本研究は、独居高齢者の安全かつ健康的で自立した生活を支援するために、情報技術を活用して居住者の日常生活に関する情報を収集・分析し、異常を検知したり適応的な生活支援を行うことを目指している。

このような日常生活見守り技術における中核技術のひとつは、居室内に設置した多数のセンサの情報を集め、居住者の日常生活行動をモデル化する技術である。センサについては、これまでにマイク、カメラ、加速度センサ、床圧センサなど多種多様なセンサが用いられているが、本研究では、設置・維持コストが小さいこと、居住者のプライバシー漏えいのリスクが小さいことを考慮して、主として人感センサを用いている。このようなセンサを居室内に多数設置して生活動線を捕捉し、居住者の生活モデルを構築する。

しかし、人感センサのような情報量の乏しいセンサから、生活環境や行動様式といった個人性を汎化して、不特定多数の利用者に適用可能な生活行動モデルを構築することは困難である。そこで、個人毎に取得したデータから、その個人に特化したモデルを構築することが必要になるが、人手でモデルを構築することはコスト的に許容できない。機械学習を用いて、モデルを (半) 自動的に学習させる場合でも、ある行動に該当するデータ区間の切り出しや、その区間に行動ラベルを付与するといった、データのアンノテーション作業にかかるコストが許容できない場合が多い。しかも、生活環境や行動様式は時間とともに変化するので、アンノテーション作業は、システムの導入前に一度行えば済むものではなく、システム利用中、継続的に作業を行う必要がある。このようなシステムの導入・維持コストに係る現実的な要請を踏まえると、教師なし学習を用いて個人毎の行動モデルを自動的に構築する必要がある。

本研究では、生活行動モデルの自動構築のためにトピックモデリング技術を活用する。つまり、単語をセンサ、トピックを

行動と読み替え、潜在する行動に依存して観測可能なセンサ出力が生成されると仮定する。当初、様々な分野に応用されている Latent Dirichlet Allocation (LDA) [Blei 03] を適用してみたが、十分な行動の予測精度が得られなかった。その理由としては、文書のトピックモデリングにおいては、文書が複数のトピックから生成されるという LDA の多重トピック性が効くものに対して、本研究が対象としている生活行動モデリングにおいては、センサ出力系列が複数の行動から生成されると仮定することは、不必要に自由度の高いモデルを用いることによる過適応を惹起しているからではないかと考えられる。そこで、文書に単一のトピックを割り当てるトピックモデル [貞光 05] で用いられている Dirichlet Mixture (DM) を用いたモデル化を試みる。ただし、本研究の行動モデリングにおける“文書”は、センサ出力系列を時間窓で切り取った部分系列であり、時間窓が一定のシフト幅でずれることから、隣接する“文書”の相関が強いという特徴がある。そこで、行動の生起確率分布が直前の行動に依存するという 1 次マルコフ性を仮定する。これにより、外出前には、外出準備を行うというような行動間の依存関係もモデル化できると考えられる。さらに、センサについても、あるセンサが発火するときには、引き続いて空間的に隣接するセンサが発火する可能性が高いので、センサの生起確率分布は、該当する時間窓の行動のみならず、直前に発火したセンサにも依存するという 1 次マルコフ性を仮定する。これにより、生活動線を考慮に入れた行動のモデル化が可能になると考えられる。

このような行動モデルの学習と行動系列の推定のために、マルコフ連鎖モンテカルロ法 [伊庭 05] を用いることができる。そのために、上記生活行動モデルのためのギブスサンプラーの導出を行った。

また、有料老人ホームに居住する独居高齢者の居室に 7 つの人感センサを設置し 1 ヶ月に渡りデータを収集した。このデータを用いて、上記生活行動モデル化技術を用いて推定した行動系列の予測精度を評価した。

本稿は、以下のように構成される。まず、次節で、既存のトピックモデリング技術と本研究との関連を述べる。続いて、本研究で用いる行動モデルとその学習・推論法について説明す

る。その後で、実際に有料老人ホームにおいて収集したデータを用いて、本研究で提案する行動モデル化手法による行動の予測精度を評価する。

## 2. 関連研究

本研究では、生活行動のモデリングに文書のトピックモデリングを適用する。すなわち、単語はセンサに、文書は時間窓に含まれるセンサ系列に、トピックは行動に対応する。

文献 [Huynh 08] では、トピックモデルとして LDA を用いて、日常生活の中で繰り返される行動パターンの発見を行う手法が提案されている。本研究の生活行動モデルにおいては、LDA の多重トピック性がモデルの自由度を高めすぎると考え、文書毎にトピックを割り当てるモデルを採用する。具体的には、文献 [貞光 05] において考察されている、混合ディリクレ分布を用いたトピックモデルを用いるが、混合比にも事前分布を仮定する点と、単語とトピックに 1 次マルコフ性を仮定する点が異なる。

単語のみならずトピックにもマルコフ性を仮定する理由は、本研究で対象とする“文書”は時間窓であるため、隣接する時間窓との相関が強いためである。LDA については、文献 [Wallach 06] において、単語のマルコフ性が考慮されている。一方で、トピックのマルコフ性の導入は、LDA が多重トピックモデルであるため単純には拡張できない。文献 [Du 12] では、トピックの上位階層に、文書におけるストーリー展開に対応するより抽象的なトピックの階層を設け、この階層にマルコフ性を導入している。本研究では、文書に一つのトピックを割り当てるモデルを用いるので、トピックの階層に直接マルコフ性を導入することができる。

モデルの学習と行動列の推定には、文献 [Griffiths 04] 同様の Collapsed Gibbs sampler を用いる。ただし、文書にトピックが割り当てられているので、ひとつの文書に関わる確率変数全体を、それ以外の変数の条件下でサンプリングする Blocked Gibbs Sampling を行う。

## 3. 行動モデル

本研究では、トピックモデルとして用いられている混合ディリクレ分布のトピックと単語に一次マルコフ性を導入し、トピックを行動、単語をセンサ発火と読み替えて、日常生活行動をモデル化する。

### 3.1 モデルの構造

図 1 は、モデルの構造を表しており、 $T$  は行動の集合、 $V$  はセンサの集合、 $M$  はフレームの数を表している。観測されたセンサの発火系列は、一定の窓幅でフレームに分割され、 $m$  番目のフレームのセンサの発火は行動  $z_m$  に依存する。潜在する行動  $z_m$  は、直前のフレームの行動  $t$  に依存して  $\theta^t$  をパラメータとするカテゴリカル分布から生成される。 $m$  番目のフレームの行動を  $t$  とするとき、 $i$  番目のセンサ  $w_{m,i}$  は、 $t$  と直前に発火したセンサ  $v$  に依存して、 $\phi^{t,v}$  をパラメータとするカテゴリカル分布から生成される。なお、カテゴリカル分布  $\theta^t$  と  $\phi^{t,v}$  の事前分布として、それぞれ  $\alpha^t$   $\beta^{t,v}$  をハイパーパラメータとするディリクレ分布を仮定する。すなわち、行動系列  $Z$  とセンサ発火系列  $W$  の同時分布は、

$$p(Z, W; \alpha, \beta) = p(Z; \alpha)p(W | Z; \beta)$$

$$p(Z; \alpha) = \int \text{Cat}(Z | \Theta) \text{Dir}(\Theta | \alpha) d\Theta$$

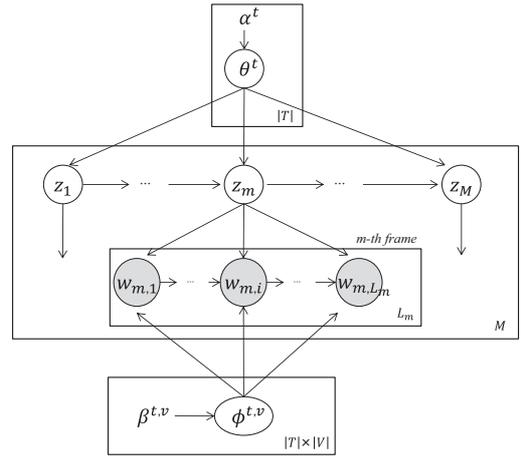


図 1: 行動モデルの構造:  $w_{m,i}$  は観測されたセンサ、 $z_m$  は潜在する行動で、共にカテゴリカル分布から生成される。

$$p(W | Z; \beta) = \int \text{Cat}(W | Z, \Phi) \text{Dir}(\Phi | \beta) d\Phi.$$

ここで、 $\text{Cat}(\cdot)$  はカテゴリカル分布を表し、

$$\text{Cat}(Z | \Theta) = \prod_{q \in T} \prod_{t \in T} (\theta_t^q)^{n_{q,t}}$$

であり、 $n_{q,t}$  は、行動  $q$  の直後に行動  $t$  が現れる頻度とする。また、

$$\text{Cat}(W | Z, \Phi) = \prod_{t \in T} \prod_{u \in W} \prod_{w \in W} (\phi_w^{t,u})^{n_{u,w}^{t,u}}$$

であり、 $n_{u,w}^{t,u}$  は、行動  $t$  において、センサ  $u$  の直後にセンサ  $w$  が出現する頻度とする。 $\text{Dir}(\cdot)$  はディリクレ分布を表し、簡単のために、 $\alpha_t^q = \alpha$ 、 $\beta_w^{t,u} = \beta$  とすると、

$$\text{Dir}(\Theta | \alpha) = \prod_{q \in T} \frac{\Gamma(|T|\alpha)}{\Gamma(\alpha)^{|T|}} \prod_{t \in T} (\theta_t^q)^{\alpha-1}$$

$$\text{Dir}(\Phi | \beta) = \prod_{t \in T} \prod_{u \in W} \frac{\Gamma(|V|\beta)}{\Gamma(\beta)^{|V|}} \prod_{w \in W} (\phi_w^{t,u})^{\beta-1}.$$

これらから、

$$p(Z; \alpha) = \prod_{q \in T} \frac{\Gamma(|T|\alpha)}{\Gamma(\alpha)^{|T|}} \prod_t \frac{\Gamma(n_{q,t} + \alpha)}{\Gamma(n_{q,\cdot} + |T|\alpha)} \quad (1)$$

$$p(W | Z; \beta) = \prod_{t \in T} \prod_{u \in V} \frac{\Gamma(|V|\beta)}{\Gamma(\beta)^{|V|}} \prod_w \frac{\Gamma(n_{u,w}^{t,u} + \beta)}{\Gamma(n_{u,\cdot}^{t,\cdot} + |V|\beta)} \quad (2)$$

と表すことができる。ただし、 $n_{q,\cdot} = \sum_{t \in T} n_{q,t}$  であり、 $n_{u,\cdot}^{t,\cdot} = \sum_{w \in V} n_{u,w}^{t,u}$  とする。

### 3.2 モデルの学習・推論

行動モデルの学習、行動列の推定には、マルコフ連鎖モンテカルロ法 [伊庭 05] を用いる。以下の式に従って  $m$  番目のフレームの行動を、それ以外のフレームを固定してギブスサンプリングする。

$$p(z_m = t | Z(-m), W)$$

$$\propto p(z_m = t | Z(-m), W(-m)) \times$$

$$p(W(m) | z_m = t, Z(-m), W(-m))$$

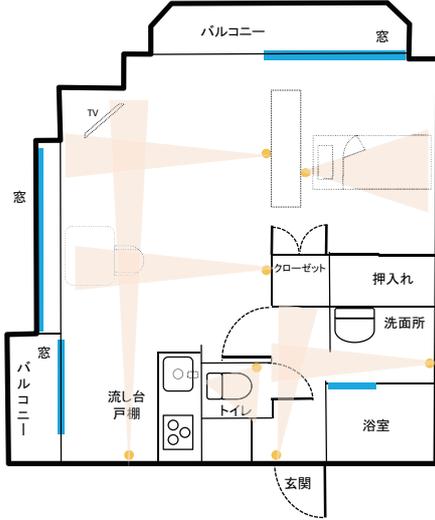


図 2: 居室見取り図および人感センサ設置位置

ただし,  $m$  番目のフレームを除く行動列を  $Z(-m)$ ,  $m$  番目のフレームのセンサ列を  $W(m)$ ,  $W(m)$  以外のセンサ列を  $W(-m)$  と表す. 右辺第 1 項は式 (1) から

$$p(z_m = t \mid Z(-m), W(-m)) = \frac{n_{q,t}(-m) + \alpha}{n_{q,\cdot}(-m) + |T|\alpha} \frac{n_{t,r}(-m) + \alpha}{n_{t,\cdot}(-m) + |T|\alpha} \quad (3)$$

と書ける. ただし, 頻度  $n$  に対して  $n(-m)$  で  $m$  番目のフレームに係る頻度を除いた頻度を表し,  $m-1$  番目の行動を  $q$ ,  $m+1$  番目の行動を  $r$  としている. 第 2 項は式 (2) から

$$p(W(m) \mid z_m = t, Z(-m), W(-m)) = \prod_u \frac{\prod_w \prod_{\ell=1}^{S_{u,w}(m)} (n_{u,w}^t(-m) + \beta + \ell - 1)}{\prod_{\ell=1}^{S_{u,\cdot}(m)} (n_{u,\cdot}^t(-m) + |V|\beta + \ell - 1)} \quad (4)$$

と書ける. ただし,  $S_{u,w}(m)$  は  $m$  番目のフレームにおいて  $u$  の直後に  $w$  が発火する頻度を表し,  $S_{u,\cdot}(m) = \sum_{w \in V} S_{u,w}(m)$ . 紙数の都合で, センサと行動に 1 次マルコフ性を仮定する場合についてだけ記述したが, それ以外の場合も同様なサンプリングを行うことができる.

## 4. 実験

このような日常生活行動モデル化手法の行動予測精度を評価するために, 有料老人ホームに暮らす独居高齢者の居室に人感センサを設置し, 30 日に渡りデータを取得した. 図 2 は, ワンルームタイプの居室の見取り図と 7 つの人感センサの設置位置を表している. 本来センサは天井にすることが望ましいが (行動位置との対応関係が自明であるので), 設置上の制約から, 今回は検知範囲を絞った上で居室の壁面に設置した.

センサから得られるデータは, 焦電センサからの出力電位が変化した (以降発火と呼ぶ) 日時と, 10 秒以上出力電位が変化しなくなった日時の列からなる. このようなデータに対して, 窓幅 120 秒の時間窓を 60 秒毎に動かしフレーム列を生成し, 各フレームの中で発火しているセンサーをフレーム内に順に記述する. もし, フレーム内でどのセンサーも発火していないときには, 特別な記号 “0” を記述する.

このようにして得られるデータを 1 日毎に分割し, メンテナンスなどを行った日を除いた 22 日分のデータを leave-one-out cross validation で評価した. すなわち, ある 1 日のデータを評価用のデータとし, 残り 21 日分のデータでモデルを学習した後, 評価用データの行動系列を予測し, その精度を評価した.

評価した行動モデルは, LDA, DM, DM の行動にマルコフ性を仮定したもの (DM + a2s1) および DM の行動とセンサにマルコフ性を仮定したもの (DM + a2s2) の 4 種類である. LDA によるモデルの学習および行動の推論にはギブスサンプラー [Griffiths 04] を使い, DM およびその拡張モデルに対しては 3.2 節のギブスサンプラーを用いている. ハイパーパラメータは,  $\alpha = 1$ ,  $\beta = 1$  を用いた.

### 4.1 評価指標

評価の際に用いた行動ラベルは, 就寝, トイレ, 洗面, 外出準備, 外出中, 帰宅, リラックス, ロボットとの会話, 電話, 服薬およびその他の 11 種類で, センサの発火の様子を可視化するツールの画面を操作しながら人手で付与した. その際, ラベル付与の参考にするために収録した音声を, ツール上で任意区間随時再生させながらラベルを付与した. このように付与された行動ラベルに対して, 予測された行動系列  $Z = t_1, \dots, t_n$  の推定精度を以下のように評価した.

まず, 推定された行動  $t \in T$  に対して最もよく一致するラベル  $\ell \in L$  を対応付けるような写像  $cor(\cdot) : T \rightarrow L$  を以下のように定義する.

$$cor(t) = \arg \max_{\ell \in L} \sum_{i=1}^n \delta(t_i = t) int(t_i, \ell).$$

ここで,  $int(t_i, \ell)$  は,  $t_i$  の時区間と  $\ell$  の時区間の共通部分 (秒) であり, 隣接する  $t_i$  と  $t_{i+1}$  の時区間は重なりがないように,  $t_i$  の終了時刻と  $t_{i+1}$  の開始時刻の間を,  $t_i$  の終了時刻かつ  $t_{i+1}$  の開始時刻となるように調整するものとする.

次に, 写像  $cor(\cdot)$  に基づいて,  $t_i$  を行動ラベルに変換し, 人手で付与した行動ラベルとの一致率を以下のように計算する.

$$\text{一致率}(Z) = \frac{\sum_{i=1}^n int(t_i, cor(t_i))}{\sum_{i=1}^n dur(t_i)}.$$

ただし,  $dur(t_i)$  は,  $t_i$  の継続時間 (秒) を表す.

### 4.2 実験結果

図 3 は, 11 種類の行動との一致率を表しており, 図 4 は, それを除いた 10 種類の行動との一致率を表している. グラフから分かるように, 本研究のデータにおいては, DM の方が LDA よりも良い予測性能を示していることが分かる. しかも, LDA は行動の数  $|T|$  を増やすにつれて性能が劣化していくが, DM は性能が変化していない.

図 5 は, 縦軸に, 実際に予測された行動の種類数を示している. このグラフから分かるように, LDA は多重トピック性を持つため, 最大行動数  $|T|$  の増加に比例して多くの種類の行動がサンプリングされている. 一方, DM は, センサ出力に係る項 (4) に強く制約されるため, 最大行動数  $|T|$  を増やしても, 実際には一定種類の行動しかサンプリングされていないことが分かる.

また, 図 3 および図 4 からは, DM の行動にマルコフ性を仮定すると (DM + a2s1), DM よりも予測性能が向上し, さらにセンサにマルコフ性を仮定すると (DM + a2s2), さらに性能が向上することが分かる. 図 5 を見ると, 行動系列に係る項 (3) により, センサ出力に係る項 (4) の影響が緩和され,

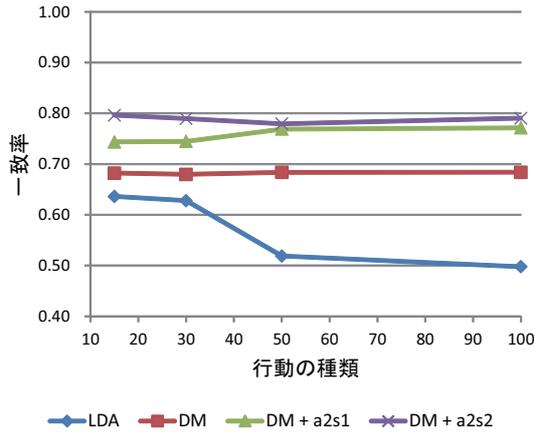


図 3: 11 種類の行動との予測一致率

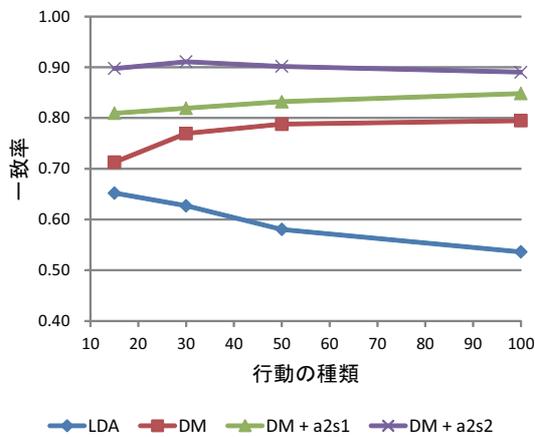


図 4: その他を除く 10 種類の行動の予測一致率

DM よりも多くの種類の行動を生成していることが分かる。また、DM + a2s2 は、センサにマルコフ性を仮定した分だけセンサ出力に係る項 (4) の影響が強くなり、DM + a2s1 よりも DM に近い挙動を示すことも分かる。

最後に、LDA は、許容する行動の数  $|T|$  の影響が大きいので、 $|T|$  を調節する何らかの手法が必要になるが、DM およびマルコフ性を導入した DM においては、 $|T|$  をある程度決め打ちしても、あまり性能に影響を与えないという利点がある。

## 5. まとめ

独居高齢者の日常生活行動をモデル化するために、トピックモデルを適用し、行動をトピック、単語を居室内に設置したセンサの発火に対応付け、生活行動のモデル化を行う手法について考察した。行動様式や間取り等、個性が強い生活行動のモデル化には、個人毎にモデルを適応させることが不可欠であるが、データのアノテーション作業等、個人適応に大きなコストがかけられず、しかも、時間が経つにつれ行動モデルが変動し得るという要請に応えるため、LDA のように教師なし学習でモデルの構築を自動的に行う手法が望ましい。しかし、本研究が対象とする生活行動データにおいては、センサ系列が単一の行動から生成されると仮定すれば十分であり、トピック多重性を持つテキストを取り扱うことに適した LDA は、モデルの自

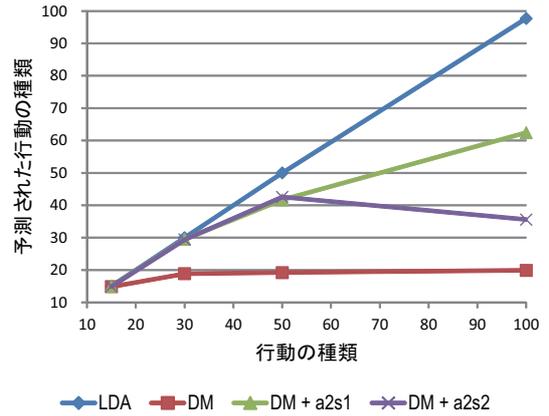


図 5: 行動の種類  $|T|$  vs. 実際に予測された行動の種類

由度が高すぎて過適応を起こすことが分かった。そこで、文書に単一トピックを仮定する、混合ディリクレ分布 (DM) を用いたトピックモデルに基づき、行動とセンサにマルコフ性仮定したモデルを検討し、モデルの学習と行動系列の推定のためにギブスサンプラーを導出した。このような日常生活行動モデル化法を、実際に独居高齢者の生活データに適用し、行動の予測精度の評価を行い、LDA よりも DM が、さらに、DM よりもマルコフ性を導入した DM の方が性能が良いことを確認した。

## 謝辞

本研究にご協力頂いた (株) 生活科学運営と施設の入居者の皆様に謝意を表す。本研究は、JST 戦略的イノベーション創出推進プログラムの支援を受けて実施した。

## 参考文献

- [Blei 03] Blei, D. M., Ng, A. Y., and Jordan, M. I.: Latent dirichlet allocation, *Journal of Machine Learning Research*, Vol. 3, pp. 993–1022 (2003)
- [Du 12] Du, L., Buntine, W., Jin, H., and Chen, C.: Sequential latent Dirichlet allocation, *Knowledge and Information Systems*, Vol. 31, No. 3, pp. 475–503 (2012)
- [Griffiths 04] Griffiths, T. L. and Steyvers, M.: Finding scientific topics, *Proc. of the National Academy of Sciences*, Vol. 101, pp. 5228–5235 (2004)
- [Huynh 08] Huynh, T., Fritz, M., and Schiele, B.: Discovery of activity patterns using topic models, in *Proc. of Ubiquitous Computing*, pp. 10–19 (2008)
- [Wallach 06] Wallach, H. M.: Topic modeling: beyond bag-of-words, in *Proc. of Machine Learning*, pp. 977–98 (2006)
- [伊庭 05] 伊庭 幸人: マルコフ連鎖モンテカルロ法の基礎, 統計科学のフロンティア 12, 岩波書店 (2005)
- [厚生省 14] 厚生労働省: 平成 26 年国民生活基礎調査, <http://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa14> (2014)
- [貞光 05] 貞光 九月, 三品 拓也, 山本 幹雄: 混合ディリクレ分布を用いたトピックに基づく言語モデル, 電子情報通信学会論文誌 D, Vol. 88, No. 19, pp. 1771–1779 (2005)