

人間行動センシングデータに基づく生活リズム解析

下坂 正 倫*

* 東京大学 大学院情報理工学系研究科 知能機械情報学専攻
東京都文京区本郷 7-3-1* Department of Mechano-Informatics, Graduate School of Information
Science and Technology, The University of Tokyo, 7-3-1 Hongo, Bunkyo-
ku, Tokyo, Japan

* E-mail: simosaka@ics.t.u-tokyo.ac.jp

キーワード：行動センシング (behavior sensing), 統計的行動モデリン
グ (statistical activity modeling), 階層ベイズ (hierarchical bayes), 焦
電センサ (pyroelectric sensors), ディリクレ過程混合 (dirichlet process
mixtures).

JL 0007/14/5307-0611 ©2014 SICE

1. はじめに

高齢化社会の今，独居高齢者に安心・安全をいかにして提供するかが課題の一つとして挙げられる．独居高齢者が安全・安心に生活するためには在宅訪問などの福祉サービスの拡充だけでなく生活のモニタリングとモニタ結果に基づいた支援サービスに期待が寄せられている．居住者モニタリングのためのセンサとして焦電センサのような活動量計測器は，安価で省電力であるために生活行動の長期蓄積に向いていることから近年注目を浴びている．

本稿では，家庭内に設置された安価な動きセンサで得られる居住者の生活リズム解析について述べる．具体的には一日のうち，どの時間帯にどの程度の活動が観測されるか，どこに滞在するか，といったマクロな視点で生活様式を記述するモデリング法について述べる．ここで注目すべきは人の活動は曜日等の社会的制約により「活動量」や「場所」が変化することであり，長期間の活動量データから複数の典型的な生活パターンを抽出する必要があるということである．ここでいう典型的な生活パターンとは「通院日」，「安息日」というように，ある種の定型的なイベントにより特徴付けられる生活のパターンを意味するものである．本稿で紹介するモデルは，外出や帰宅のタイミングの推定に基づく効率的な空調管理や，高齢者見守りサービスにおける異変検知といったさまざまな応用につながるものとして期待できるものである．

これらの典型的なパターンは，個人の生活スタイルに大きく依存し，また，典型的といえるパターン数も異なることが技術的な難しさを引き起こしている．われわれはこの問題に対し，簡潔な生活リズムを記述する統計モデルの開発と，それらのリズムを自律的に抽出する枠組みとして，階層ベイズ法のひとつであるディリクレ過程¹⁾を用いた適応的クラスタリングによる自動パターン抽出法を提案している．本稿では生活リズム解析の意義，リズムの記述モデル，実際の生活データからの生活パターン抽出について言及する．本稿ではディリクレ過程についての理論的な詳細は割愛し，抽出された生活パターンの表現方法やその抽出の手順に着目し説明を行う．

2. 生活リズム解析の意義

本稿で紹介する何時頃に活動を開始し，外出し帰宅するかといった情報は，さまざまな分野へ応用が期待できる．たとえば，初老期の外出行動の頻度がその数年後の生活動作 (ADL, Activities of Daily Living) の良し悪しを決定することが示されていたり²⁾，その人が家に居るか否かを予測，推定することができれば，それは住居内でのエネルギーコストの削減に繋がると分析されている³⁾．その一方で，たとえば文献²⁾では外出頻度をアンケートによる調査で行っているが，その個々の外出行動把握に基づく分析は，作業量の観点から自動処理で行うことが望ましい．自動で人々の外出行動のモデリングを行うことができれば，ライフログや，医学的分析など，多くの分野でその応用が可能であるとわれわれは考える．

3. 生活リズムを表現する統計モデル

本稿ではわれわれの生活リズム解析の研究事例として，活動量と滞在場所に関して時間帯に着目した統計モデルの定式化の例を紹介する．活動量の分布は，ある時間帯における対象イベントの発生回数（非負整数）を表現するものであり，一方滞在場所に関するモデル化は離散事象の発生確率を表現するものである．

3.1 活動量に関する統計モデル

ここでは人間の行動の特性指標の基本として，いつ頃活動的でいつ頃就寝するかといった時間帯と活動量との関係を扱う枠組みを述べる．

焦電センサを利用することで，人の動きを検知し，それを活動量（検知回数）として記録することが可能である．したがって，各時間帯にどの程度センサが人の動きを検知するかの回数を予測できれば人の活動が大まかに捉えることができよう．この課題に対し，日常の活動の巨視的挙動を表現する統計モデルとしてポワソン過程による表現法を紹介する⁴⁾ (注1)．

(1) ポワソン分布

本節ではポワソン過程の基礎となるポワソン分布について説明を行う．ポワソン分布は，単位時間あたりの事象の

(注1) 本節は文献⁴⁾ をベースに執筆している

発生回数を変数とする確率分布として古くから広く用いられている⁵⁾。この分布は事象の発生回数 $k \in \mathbb{N}_0$ の尤度を

$$p(m|\lambda) = \frac{1}{m!} \lambda^m \exp(-\lambda) \quad (1)$$

として定式化している。ここで \mathbb{N}_0 は非負整数の集合であり、 $\lambda > 0$ は分布のパラメータである。この分布に従って生成された発生回数 m の期待値は λ である。このことから λ は発生頻度を表現するパラメータとみなすことができる。

(2) 時変ポワソン過程

ポワソン過程は事象の発生回数を時間関数で表現することで、時々刻々と発生頻度が変化する事象への適用が可能となる確率統計モデルである。本研究では、事象は焦電センサによる人の身体運動の検知を意味する。ここで、時刻 0 から t までに事象が M_t 回発生したとすると、 t_1 と $t_2 > t_1$ の期間で事象が発生する回数 $m = M_{t_2} - M_{t_1}$ がポワソン分布

$$p(m|\lambda(\cdot)) = \frac{1}{m!} \left[\int_{t_1}^{t_2} \lambda(t) dt \right]^m \exp \left\{ - \int_{t_1}^{t_2} \lambda(t) dt \right\}$$

に従うものとして定式化したものがポワソン過程である。ポワソン分布ではパラメータ λ が時不変であることを前提としていたのに対し、ポワソン過程では時変であることを陽に扱っている。時刻 0 から T (本研究の場合 24 時) までに事象を $N = M_T$ 回観測し、それぞれの時刻を $0 \leq \tau_1 < \tau_2 < \dots < \tau_N \leq T$ とおくと系列全体の尤度は

$$p(\{\tau_n\}_{n=1}^N | \lambda(\cdot)) = \exp \left\{ - \int_0^T \lambda(t) dt \right\} \prod_{n=1}^N \lambda(\tau_n)$$

として表現される。ここで λ_0 を $\lambda(t)$ の正規化定数、すなわち

$$\lambda_0 = \int_0^T \lambda(t) dt \quad (2)$$

として、 $f(t) = \lambda(t)/\lambda_0$ とすると $1 = \int_0^T f(t) dt$ が成り立つため、

$$p(\{\tau_n\}_{n=1}^N | \lambda_0, f(\cdot)) = \exp(-\lambda_0) \lambda_0^N \prod_{n=1}^N f(\tau_n) \quad (3)$$

として定式化される。(3) から $\exp(-\lambda_0) \lambda_0^N$ を除外すると、単変量の確率密度の積としてみなすことができる。

(3) 離散データに対する時変ポワソン過程

ここでは、活動検知のタイミングを記録したデータではなく、ある一定期間ごとに検知回数が記録されたデータが得られたときの推定について述べる。焦電センサにより時刻 0 から T までの間 $\Delta = T/S$ ごとに検知回数を記録し

ていくものとし、時刻 $s\Delta$ から時刻 $(s+1)\Delta$ まで事象を h_s 回検知したものとす。一日の活動量データは $\{h_s\}_{s=1}^S$ から構成されるものとする。このとき (3) の密度関数 $f(\cdot)$ が間隔 Δ で一定の値

$$f(t) = r_s, \quad \forall t \in [s\Delta, (s+1)\Delta)$$

を取るとすると

$$p(\{h_s\}_{s=1}^S | \lambda_0, \mathbf{r}) = \exp(-\lambda_0) \lambda_0^N \prod_{s=1}^S r_s^{h_s} \quad (4)$$

が成立する。ただし $N = \sum_{s=1}^S h_s$ であり $f(\cdot)$ の条件から

$$\sum_{s=1}^S r_s = 1, r_s \geq 0 \quad (5)$$

である必要がある。 r_1, \dots, r_S をまとめた列ベクトルを \mathbf{r} とし、(5) を満たす \mathbf{r} の集合を $\mathbb{R}_{\text{SIM}}^S$ と表記する。

3.2 時変ベルヌーイ分布に基づく滞在場所モデリング

活動量と共に、人がいつごろどこに居るかといった情報は、個々人の活動状況を要約することに加え、HEMS といった課題に有益である。この節では、時間帯に応じた滞在場所を予測する確率モデルについて述べる。具体的にはわれわれの取り組みである、外出・帰宅タイミングの予測の基盤となる外出行動のモデリングについて紹介する⁶⁾(注2)。

人の外出行動はある時刻において外出しているか否かという形で、二値に分類することができる。すなわち、外出を 1、自宅にいることを 0 と表現すれば、それはベルヌーイ分布に従う確率変数と考えられる。また、各時刻の外出傾向は異なるため、各時刻の観測値を $x_t = \{0, 1\}$ 、時刻 t に於けるパラメータを μ_t とすると、一日の外出パターンが生じる確率は以下の式で表わされる。

$$p(\mathbf{x} | \boldsymbol{\mu}) = \prod_{t=1}^T \mu_t^{x_t} (1 - \mu_t)^{1-x_t} \quad (6)$$

ここで、 T は一日の観測値の数を表わしており、たとえば 30 分周期であれば $T = 48$ である。 μ_t を時系列に並べた一日の外出を表現するパラメータの例を図 1 に示す。こ




図 1 外出行動の記述

(注2) 本節は文献⁶⁾をベースに執筆している

の場合では 8 時付近と 18 時付近に二度の外出を行い、夜と正午付近は自宅にいるような観測値に対して尤度が高くなる。

本稿では研究事例として滞在場所を 2 カ所に限定したものであるが、たとえば自宅と職場とその他といった複数の場所にも多項分布を利用することで拡張は容易である。

3.3 活動モデルの既存研究

一日の終わりと翌日の始まりが本質的に同一時間帯であることに着目し、繰り返し表現を前提とした von-Mises 分布を用いた手法⁷⁾がある。von-Mises 分布のパラメータの事後分布の推定には共役事前分布が存在しないため、拡張変数を用いる方法⁸⁾や棄却⁷⁾を用いたサンプリングが提案されているが、大量データにおいて集中パラメータのサンプリングが困難であるという問題がある。その他、ベータ混合分布を用いた活動量モデリングも提案されている⁹⁾が、von-Mises 分布の場合と同様パラメータの事後分布のサンプリングの効率の悪さが問題となる。

対数 Gauss-Cox 過程¹⁰⁾は活動量モデリングとして古くから提案されている一方、解析的な事後分布からのサンプリングが不可能であることが問題となっていた。近年、これに代わるシグモイド Gauss 過程を事前分布とするポワソン過程が提案された¹¹⁾が、大規模なデータに適用することは計算量の観点で難しい。大規模データへの適用を可能とするポワソン過程の事前分布として混合正規分布を利用する方法¹²⁾があるが、このモデルでは複数の活動パターンのモデル化にモデル選択の技法が必要となり、活動パターンの自動検出の実現には至っていない。

4. 階層ベイズによる生活リズム抽出

時間変動を前提とした行動モデルでは、時間帯が一致すれば発生頻度や滞在確率は日を問わず一定という仮定をおいていた。しかしながら、人間の日常生活の行動パターンを表現するにはこれでは不十分である。たとえば、独居高齢者の生活パターンを考えた場合、ある曜日は午前中に通院し午後以降は自宅で休養する一方で、別のある曜日では夕方に散歩を行うといったように、ある種の定期イベントにより時間帯が同じであったとしても活動量が大きく変動する可能性があるからである。

これに対するアプローチとして、日々の生活リズムは曜日ごと、また平日で同様のパターンをとると仮定し、モデリングを行なっているものがある¹³⁾。しかしながら、日々のパターンは必ずしも曜日のみで決まるものではなく、天候、体調、その他さまざまな要因の影響が考えられ、また、人々の取りうるパターンはその人個人で異なることが想定される。すなわち、典型的なパターンの抽出にはあらかじめパターン数を指定することができない。他にも、日々の行動データから活動量を推定する研究は多数存在する^{7), 11)}が、それらは時間帯ごとの活動の集中量に着目したものが

多く、また、人々の行動パターン分類を行う研究も存在する¹²⁾、この手法では、パターン数をあらかじめ指定しておく必要がある。

この問題を解決する基本的方策は、上述のようなイベントに応じて活動モデルをそれぞれ用意し、たとえば通院日モデル、散歩モデル、というような一日を表現する活動パターンを複数用意し、加法的なモデルとして表現することである。Ihler らは曜日別に行動モデルを構築しモデルの精緻化を試みている¹⁴⁾が、7つの行動モデルが必要十分な生活パターンである保証はなく、モデルの表現力が過剰もしくは不足する可能性が否めない。

われわれはこの問題に対し、階層ベイズの一つであるディリクレ過程によりパターン抽出法を具現化している。以下、ディリクレ過程の概要を述べ、パターン抽出を具現化するアルゴリズムの手順を概説する。

4.1 ディリクレ過程

ディリクレ過程は 1970 年代に統計学において提唱された階層ベイズ法の一つ¹⁵⁾であり、その柔軟なモデリング能力から近年になって機械学習の研究領域で注目されているものである。本稿では、ディリクレ過程の基本的性質は Escobar と West による説明¹⁶⁾に委ね、ディリクレ過程のデータ生成の過程を示す。まず、観測量 \mathbf{h} に対しパラメータ $\boldsymbol{\theta}$ を用いて確率モデル $f(\mathbf{h}|\boldsymbol{\theta})$ を定義し、パラメータの事前分布を $\phi(\boldsymbol{\theta})$ とする。ここで Stick-breaking 表現¹⁾に基づくディリクレ過程では、 k 番目の生活パターンを生成する確率 π_k を

$$\begin{aligned}\gamma &\sim \mathcal{G}(\gamma|g_1, g_2) \\ v_k &\sim \mathcal{B}(v_k|1, \gamma), \pi_k = v_k \prod_{l=1}^{k-1} (1 - v_l) \\ \boldsymbol{\theta}_k &\sim \phi(\boldsymbol{\theta})\end{aligned}$$

として表現する。ここで $\mathcal{B}(\cdot)$ はベータ分布を示し、 $\mathcal{B}(x|b_1, b_2) \propto x^{b_1-1}(1-x)^{b_2-1}$ である。 d 日目に観測した活動量データ $\mathbf{h}^{(d)}$ はパターンの選択とパターンに応じたポワソン過程によりデータを生成することとなる。

$$z_d \sim \mathcal{M}(z_d|\boldsymbol{\pi}), \mathbf{h}^{(d)} \sim f(\mathbf{h}^{(d)}|\boldsymbol{\theta}_{z_d}) \quad (7)$$

$\mathcal{M}(\cdot)$ は多項分布であり $\mathcal{M}(z|\boldsymbol{\pi}) = \pi_z$ である。このとき厳密なディリクレ過程では $\boldsymbol{\pi} \in \mathbb{R}_{\text{SIM}}^{\infty}$ が求められるが、計算機での実現は不可能でありため、代わりに適当な巨大な自然数 K を用いて $\boldsymbol{\pi} \in \mathbb{R}_{\text{SIM}}^K$ で近似することが一般である（切断近似と呼ばれる）。

4.2 統合モデルに基づく生活パターンマイニング

前節ではディリクレ過程に基づくセンサデータの生成過程について述べた。本節では与えられたセンサデータからのモデル獲得、すなわち生活パターンの自動抽出の方法について述べる。本稿では、学習データ \mathbf{H} から各日のパター

ンカテゴリ z_1, \dots, z_D と各カテゴリに応じた生活パターンのパラメータ $\theta_1, \dots, \theta_K$ の事後分布を推定することを自動抽出とよぶ。事後分布の推定は解析的に導出が不可能であるため、ここではマルコフ連鎖モンテカルロ法 (MCMC 法) の一つである Gibbs サンプリング⁵⁾ により推定する。 z_1, \dots, z_D と γ について適当な初期値を与えた後、以下の 3 手順を繰り返す。

1. 同一カテゴリに属するデータ群をまとめ生活パターンを記述するパラメータの事後分布を定義し、パラメータ群 θ をサンプリング
2. サンプリングにより得られたパラメータと重み π に従い、カテゴリ情報 z_1, \dots, z_D をサンプリング
3. カテゴリ情報に従い γ をサンプリング

5. 適用事例

5.1 活動量に注目した生活リズム解析の適用事例

前節までに述べた、時変ポワソン過程のディリクレ過程モデルを独居高齢者宅に数個の焦電センサの長期蓄積データに適用した例を示す。本報告では、手法の挙動の一例として、抽出された生活パターンを示すこととする。

(1) データ

この例では独居高齢者宅に玄関、台所、寝室、廊下、部屋の 5 箇所に設置し 1 年以上の長期にわたり計測した焦電センサの検知データから、連続した 3ヶ月分 (90 日) の台所での検知データを利用して自動抽出した例を示す。なお、この検知データは検知時刻を記録したものではなく、1 分間ごとの検知回数を記録したものとなっている^(注3)。なお、1 分あたりの検知回数の上限は 15 となっており、 $\lambda(t)$ は必然的に 15 以下になる。台所における検知回数は 3ヶ月間で総計 123,085 回検知したものとなっており、24 時間平均で




図2 台所における平均的な活動パターン




図3 3ヶ月間の蓄積データからの台所における典型的な活動パターン $\lambda(t)$

(注3) $S = 1440$ を意味する

約 1300 回、1 分平均で述べると約 0.95 回検知したものである。ディリクレ過程を行わない、2 節で述べたモデル (生活変動を考慮しないモデル) では平均挙動として図 2 に示すパターンが得られる。

(2) 適用例

前述のモデルの定式化と MCMC 法によるパターン抽出を行った結果、抽出された生活パターン数は 4 つとなり、各時間帯に対する活動量パターンは図 3 に示すものとなった。各パターンの占める日数は、パターンから順に 40 日、40 日、5 日、5 日であった。図 2 では一見すると朝昼夜 3 回共にある程度決まった時間帯に食事準備をするものと思われるが、提案する手法により朝食と昼食の準備が共起することが少ないことがわかる。また、朝食をとる時間はほぼ一定となっていることが予想される一方で、朝食の準備が行われない日の台所の利用時間帯には幅があることもわかる。蓄積データの大半はある程度活動的に夕食準備をしているが、活動量そのものが非常に小さい日が存在することを検知することができた。

5.2 外出行動に注目した生活リズム解析の適用事例

前節までに述べた、時変ベルヌーイ試行のディリクレ過程モデルを、20 代男性 2 名の外出行動データに適用した例を示す。このデータは筆者らが 2005 年から 2011 年まで参画した JST CREST「移動体センシング」のプロジェクトにて取得したものである。

(1) データ

本事例で示すデータは 2 人の、それぞれ 239 日 (被験者 A)、350 日 (被験者 B) の外出、帰宅時刻履歴である。両被験者はともに、独居用アパート内に複数のレーザレンジファインダを導入した移動軌跡計測システム¹⁷⁾ で異なる時期に生活しており、玄関付近で居住者の追跡を終了し、10 分以上経て再び玄関から居住者の追跡を再開した場合のシステムが居住者を追跡していない間を外出時間と推定している。

被験者 A についてモデルの学習、分析を行った事例を示す。この事例では一日の開始時刻を 6 時としている。

図 4 は属する日数が 5 日以上のパターンを、属する日数が多い順に並べたものである。これらの典型パターンの累

計は234日で全日数の98%をカバーしており、この被験者の例ではパターンは9つ程度となることがわかる。図中の横軸は時刻を示しており、縦軸は事後分布から得られる μ_t の期待値である。たとえば、図中最上段のパターンは11時前後に外出して1時前後に帰宅する確率が高いパターンであり、他にも、上から3つ目は旅行などでそもそも一日中家にいないパターンであったり、また、5つ目は一日中自

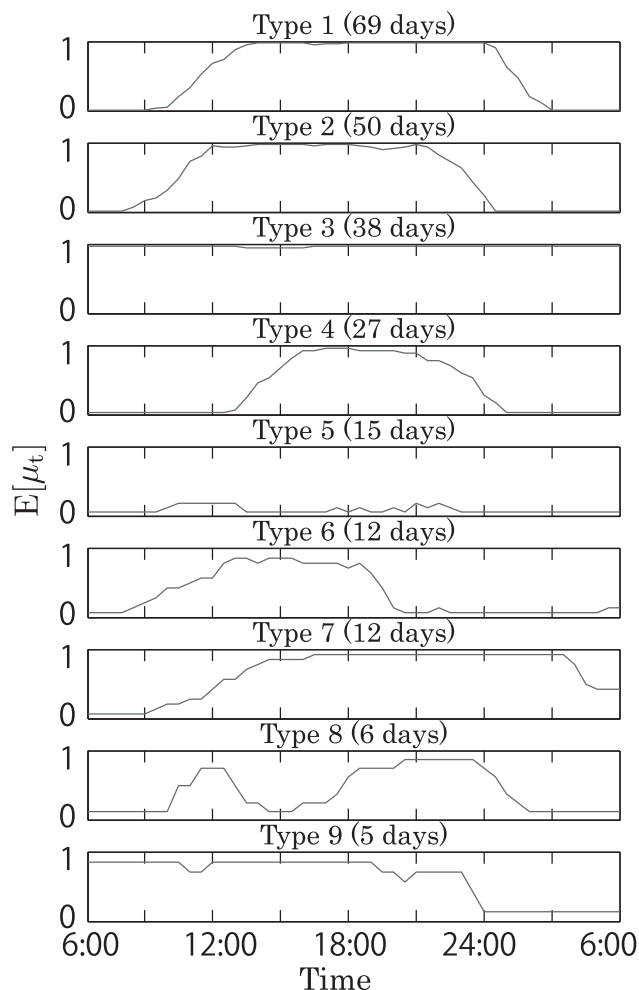


図4 提案法により抽出した被験者Aの典型的な生活パターン

宅にいないしほとんど外出しない日に尤度が高くなるパターンであるなど、外出のパターンが種々存在していることがわかる。このパターンから外れた4日のデータに関しては、3つが12時から17時、22時から2時の2度外出するパターンとして抽出され、残りの1つは13時まで外出し、その後自宅に居続けたというデータであり、外れ値として処理されている。前者に関してはデータ日数が増えればパターンとして抽出される可能性があり、属する日数の少ないパターンに関しては全データ日数に対するパターン抽出時の日数の閾値に依存を受ける可能性が高いと考えられる。

図5は被験者Aの連続する20週間の外出傾向をグラフ化したものである。図中の各パターンの番号は図4の上からの番号と対応している。各パターンと曜日との相関性は高くなく、日々の外出行動は異なると仮定し、個々の日の外出行動を自動で分類、把握するわれわれの手法の優位性が見受けられる。一方で、計5日存在したパターン9の前日はすべてパターン3であった。ほかにも、パターン1, 2, 3は一度観測されれば連続して生じることが多かったりと、日付の前後でのパターンに何らかの相関性が存在すると考えられる。なお、2人の被験者の、計約600日間の外出データを用いた評価では、市販のノートパソコンで実行した場合、各人0.5秒程度の計算時間で済む。

6. 結論

本事例紹介では、筆者らが開発してきた生活リズム解析法の概略とその適用事例を扱った。古くから人の活動リズムをどのように統計的に記述すればよいかが考えられてきた。実際、犯罪の発生件数、炭坑における事故発生回数といった単一の事象のみを扱う課題に適した統計モデルは古くから存在し、中でも時変ポワソン過程はその中心的な存在として機能していた。一方、大量のセンサデータが容易に集積されるようになった今、単一の事象のみを扱うリズム記述では不十分であり、本稿で紹介したような混合モデルとしての生活リズム記述の重要性が増々高まっている。さ

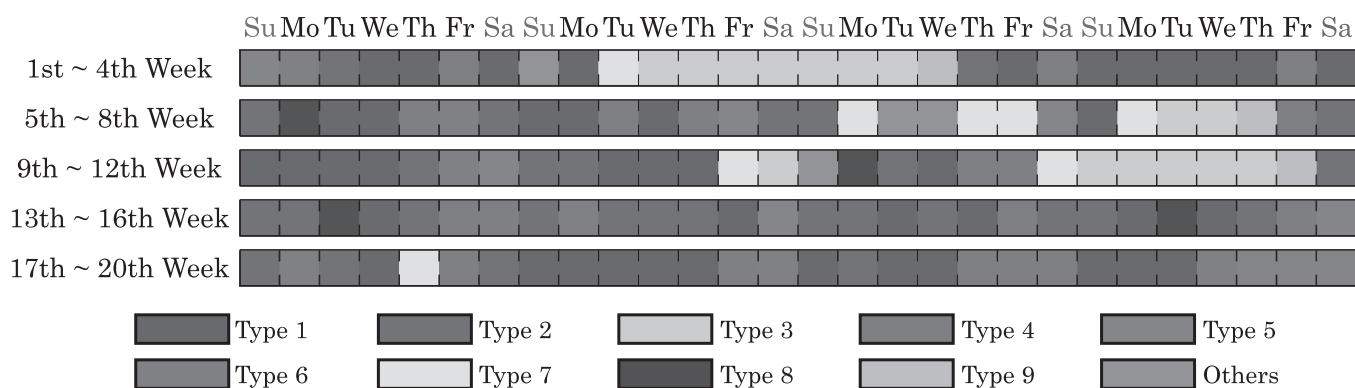


図5 140日間の生活パターンの変遷

さまざまなデータへの対応を可能とするため、表現力の豊かさを追求するとともに、大規模データに適用が可能であることを踏まえたモデルの設計が大切である。

最後に、この領域の研究を発展させる意味でも、山積する課題を列挙しておく。本稿で紹介した統計モデルは各人に適合した生活リズムの記述法であるが、生活活動を記録するセンサシステムがさらに普及した場合、リズムの抽出を各人に特化する形で行うことが本当に有効に機能するだろうか。ある特定の高齢者の生活機能低下といった異変を引き起こす生活リズムは何か、定性的な知識だけでなく統計モデルとして再利用することはできないだろうか？この場合、本稿で紹介したようなディリクレ過程では不十分であり、入れ子構造のディリクレ過程¹⁸⁾の導入が必要となる。

つぎなる課題は自動抽出した生活パターンモデルを用いたアプリケーション開発である。たとえば外出行動モデリングに基づく HEMS アプリケーションでは、帰宅時間の予測だけでなく、居住者の快適性を踏まえた空調の制御が不可欠であり、単純な統計モデルだけでは最適化はヒューリスティックなものになりがちである。行動のモデリングを含め、ユーザへのフィードバックを通じた制御系の最適化という困難な問題が残っている。

生活リズムを記述する統計モデルそのものもさらなる改善が不可欠である。本稿で紹介した生活リズム確率モデルはいわば確率のパラメータを時間という1変数で制御するものであるが、それだけでは表現力に乏しいこともある。特に生活者の行動パターンは社会的、天気、季節といった複合的な要因により決定されるはずである。このような素性を組み入れつつ、推論計算をむやみに複雑化させないモデルの開発が不可欠と言えよう。

本稿で紹介したモデルは理論的な背景はともかく実装は単純である。外出行動のパターンモデリングに関する実装を公開している¹⁹⁾ので、興味をもった読者はぜひとも試していただきたい。

謝辞

本研究に取り組みにあたり、東京大学大学院情報理工学系研究科 知能機械情報学専攻 協調知能システム研究室の教職員、学生の協力を感謝いたします。

(2014年5月30日受付)

参考文献

- 1) D. Blei and M. Jordan, Variational Methods for the Dirichlet Process, *Proc. of ICML* (2004)
- 2) A. Kono and I. Kai and C. Sakato, and L. Rubenstein: Frequency of going outdoors predicts long-range functional change among ambulatory frail elders living at home, *Archives of Gerontology and Geriatrics*, **45**-3, 233/242 (2007)
- 3) M. Gupta and S. Intille, and K. Larson: Adding GPS-Control to Traditional Thermostats: An Exploration of Potential Energy Savings and Design Challenges, *Proc. of Pervasive Computing*, 95/114 (2009)
- 4) 下坂正倫, 佐藤知正, 森 武俊: 活動量センサの長期記録からのディリクレ拡張時変ボワソン過程に基づく生活パターンマイニング, 第10回計測自動制御学会システムインテグレーション部門講演会論文集, 800/803 (2009)
- 5) D. J.C. MacKay: Information Theory, Inference, and Learning Algorithms, *Cambridge University Press* (2003)
- 6) 富永将至, 下坂正倫, 福井 類, 佐藤知正: 階層ベイズ法による外出時間帯の典型パターン抽出, 第12回計測自動制御学会システムインテグレーション部門講演会論文集, 2084/2087 (2011)
- 7) J. Gill and D. Hangartner: Bayesian circular-linear regression, *Seminar on Bayesian Inference in Econometrics and Statistics* (2009)
- 8) P. Damien and S. Walker, A Full Bayesian Analysis of Circular Data Using the von Mises Distribution, *Canadian J. of Stats.*, **27**-2, 291/298 (1999)
- 9) A. Kottas: Dirichlet Process Mixtures of Beta Distributions, with Applications to Density and Intensity Estimation, *Proc. of Workshop on Learning with Nonparametric Bayesian Methods (conjunction with ICML)* (2006)
- 10) J. Moller and A. Syversveen, and R. Waagepetersen: Log Gaussian Cox processes, *Scandinavian J. of Stats.*, **25**-3, 451/482 (1998)
- 11) R. Adams and I. Murray, and D. MacKay: Tractable nonparametric Bayesian inference in Poisson processes with Gaussian process intensities, *Proc. of ICML* (2009)
- 12) A. Ihler and P. Smyth: Learning Time-Intensity Profiles of Human Activity using Non-Parametric Bayesian Models, *Advances in NIPS* **19**, 625/632 (2007)
- 13) J. Krumm and A. Brush: Learning Time-Based Presence Probabilities, *Proc. of Pervasive*, 79/96 (2011)
- 14) A. Ihler and J. Hutchins and P. Smyth: Adaptive event detection with time-varying Poisson processes, *Proc. of KDD 2006*, 207/216
- 15) T. Ferguson: A Bayesian Analysis of Some Nonparametric Problems, *Annals of Stats.*, **1**-2, 209/230 (1973)
- 16) M. Escobar and M. West: Bayesian density estimation and inference using mixtures, *J. of the American Stats. Assoc.*, **90**-430, 577/588 (1995)
- 17) H. Noguchi and R. Urushibata and T. Sato and T. Mori, and T. Sato: System for Tracking Human Position by Multiple Laser Range Finders Deployed in Existing Home Environment, *Aging Friendly Technology for Health and Independence*, 226/229 (2010)
- 18) A. Rodriguez and D. Dunson, and A. Gelfand: The Nested Dirichlet Process, *J. of the American Stats. Assoc.*, **103**-483, 1131/1144 (2008)
- 19) <http://ics.t.u-tokyo.ac.jp/software/>

[著者紹介]

しも 下 坂 正 倫 君 (正会員)



2001年東京大学工学部機械情報工学科卒業。06年東京大学大学院情報理工学系研究科知能機械情報学専攻博士課程修了。06年4月より同専攻助手、現在同専攻講師。人間行動センシングとそれにまつわるデータ解析技術の研究に従事。ほかに日本ロボット学会、電子情報通信学会、人工知能学会、自動車技術会、ACM、IEEEなどの会員。博士(情報理工学)。