

焦電型活動量センサからの 時変ポワソン過程に基づく生活パターンモデリング

Detecting human activity profiles from pyroelectric sensors via inhomogeneous Poisson processes

下坂 正倫 佐藤 知正 森 武俊
Masamichi Shimosaka Tomomasa Sato Taketoshi Mori

東京大学
The University of Tokyo

This paper describes an activity pattern mining method via inhomogeneous Poisson point processes (IPPPs) from time-series of count data generated in behavior detection by pyroelectric sensors. IPPP reflects the idea that typical human activity is rhythmic and periodic. We also focus on the idea that activity patterns are affected by exogenous phenomena, such as the day of the week, and weather condition. Because single IPPP could not tackle this idea, Dirichlet process mixtures (DPM) are leveraged in order to discriminate and discover different activity patterns caused by such factors. The use of DPM leads us to discover the appropriate number of the typical daily patterns automatically. Experimental result using long-term count data shows that our model successfully and efficiently discovers typical daily patterns.

1. はじめに

高齢化社会の悪しき象徴といえる独居高齢者の孤独死が近年問題となっている。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く支援サービスの実現が不可欠である。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が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。

焦電センサで得られたデータに基づく行動モデリング手法として筆者らは居住者の異変検知に応用可能な行動ラベリング法を提案している [Fujii 08]。これは生活者の活動場所と活動量に着目し行動を推定するものである。一方、塚本らによれば活動的な時間帯の把握が異変検知サービスの精緻化に重要であると述べており [塚本 09]、時間帯に着目したモデル化手法も重要であることがわかる。

この考えから、本研究ではどのような時間帯にどの程度の活動が観測されるかというマクロな観点で生活様式を把握するための行動モデリング法を提案する。特に、曜日等の社会的要因によって活動量や活動的な時間帯が変化することに着目し、長期間の活動量データから典型的な生活パターンを自動抽出するアルゴリズムを提案する。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。典型的なパターン数が人により異なるため、本研究では、必要十分な活動パターンの抽出を可能にする技術の構築を狙う。計算技法の観点では、本研究は大規模データへの適用を念頭に、Dirichlet-ガンマ分布を事前分布とするヒストグラムデータに対する Poisson 過程 [Ihler 06] を一日の活動パターンモデルとして採用し、さらに Dirichlet 過程 [Blei 04] の導入により人の活動パターンの自動抽出を実現するものとなっている。

1.1 関連研究

時間帯と活動量との関係を扱う行動モデリングとして、一日の終わりや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 [Gill 09] 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 [Damien 99] や棄却 [Gill 09] 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 [Kottas 06] 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 [Moller 98] 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、これに代わるゲモイド Gauss 過程を事前分布とする Poisson 過程が提案された [Adams 09] が、本研究で扱うような大規模なデータに適用することは困難である。大規模データへの適用を可能とする Poisson 過程の事前分布として混合正規分布を利用する方法 [Ihler 07] 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。

2. 時変 Poisson 過程に基づく活動モデル

人の日常の生活パターンは大まかに時間帯に依存した生活行動をとるものと考えられ、焦電センサのような簡易なセンサにより検知される活動量（検知回数）が時間帯に依存することが予想される。このような考え方にに基づき、日常の活動の巨視的挙動を表現する統計モデルとして本研究では Poisson 過程を導入する。

2.1 Poisson 分布

本節では Poisson 過程の基礎となる Poisson 分布について説明を行う。Poisson 分布は、単位時間あたりの事象の発生回数を表現する確率分布として古くから広く用いられている [MacKay 03]。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

連絡先: 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, {simosaka,tmori}@ics.t.u-tokyo.ac.jp

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．

2.2 時変 Poisson 過程

Poisson 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 Poisson 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 Poisson 過程である．Poisson 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，Poisson 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．

2.3 ヒストグラムデータからのモデル化

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，ある一定期間毎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 $\Delta = T/S$ 毎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．なお，このようなモデル化を行うことで，複数個 (C 個) のセンサが組み込まれた際， $\mathbf{r} \in \mathbb{R}_{\text{SIM}}^{CS}$ としてモデル化を行えば，簡単に拡張が可能である．

2.4 階層ベイズ法によるモデルの学習

2.4.1 事前分布の設計

(4) のパラメータ λ_0 と \mathbf{r} を推定することがデータからの学習ということになる．ここでは次節で述べる生活パターンマイニングへの展開を踏まえ，ベイズ推定により学習を行わせることを考える． $\lambda_0 > 0$ の事前分布はガンマ分布

$$p(\lambda_0) = \mathcal{G}(\lambda_0 | a, b) \propto \lambda_0^{a-1} \exp(-b\lambda_0) \quad (6)$$

に従うものとして $\mathbf{r} \in \mathbb{R}_{\text{SIM}}^S$ の事前分布は Dirichlet 分布

$$p(\mathbf{r}) = \mathcal{D}(\mathbf{r} | \boldsymbol{\alpha}) \propto \prod_{s=1}^S r_s^{\alpha_s - 1} \quad (7)$$

に従うものとするのがもっとも単純な計算になる．

2.4.2 事後分布の導出

学習は複数日分の活動量データを用いて行うものとし，その際， D 日分のデータを用意できたとする． d 日目の s 番目の空間の検知回数を $h_s^{(d)}$ とし， d 日目の活動量データをまとめたベクトルを $\mathbf{h}^{(d)} \in \mathbb{N}_0^S$ ， $\mathbf{H} = \{\mathbf{h}^{(d)}\}_{d=1}^D$ とおく．また， $N_d = \sum_{s=1}^S h_s^{(d)}$ とする．このとき \mathbf{H} が与えられた下でのパラメータ λ_0 の事後分布は

$$p(\lambda_0 | \mathbf{H}) = \mathcal{G}(\lambda_0 | \tilde{a}, \tilde{b}) \quad (8)$$

に従う．ただし $\tilde{a} = a + \sum_{d=1}^D N_d$ ， $\tilde{b} = b + D$ である． \mathbf{r} の事後分布は Dirichlet 分布

$$p(\mathbf{r} | \mathbf{H}) = \mathcal{D}(\mathbf{r} | \tilde{\boldsymbol{\alpha}}) \quad (9)$$

に従う． $\tilde{\boldsymbol{\alpha}} = \boldsymbol{\alpha} + \sum_{d=1}^D \mathbf{h}^{(d)}$ である．

2.4.3 周辺尤度と予測分布の算出

上記モデルに対する学習データ \mathbf{H} の周辺尤度は

$$p(\mathbf{H}) = \int d\lambda_0 d\mathbf{r} p(\mathbf{r}) p(\lambda_0) \prod_{d=1}^D p(\mathbf{h}^{(d)} | \lambda_0, \mathbf{r}) \quad (10)$$

$$= \frac{\Gamma(\tilde{a}) b^a \Gamma(\sum_{s=1}^S \alpha_s)}{\Gamma(a) \tilde{b}^a \Gamma(\sum_{s=1}^S \tilde{\alpha}_s)} \frac{\prod_{s=1}^S \Gamma(\tilde{\alpha}_s)}{\prod_{s=1}^S \Gamma(\alpha_s)} \quad (11)$$

となる．一方新規なデータ $\{h_s^*\}_{s=1}^S$ に対する予測分布は

$$p(\{h_s^*\}_{s=1}^S | \mathbf{H}) = \frac{\tilde{b}^{\tilde{a}}}{(\tilde{b} + 1)^{\tilde{a} + N^*}} \frac{\Gamma(\tilde{a} + N^*)}{\Gamma(\tilde{a})} \frac{\Gamma(\sum_s \tilde{\alpha}_s)}{\Gamma(N^* + \sum_s \tilde{\alpha}_s)} \frac{\prod_s \Gamma(\tilde{\alpha}_s + h_s^*)}{\prod_s \Gamma(\tilde{\alpha}_s)}$$

となり，簡便な計算で尤度が得られることがわかる．ここで $N^* = \sum_s h_s^*$ とした．

3. Dirichlet 過程混合による生活パターンマイニング

時間変動を前提とした Poisson 過程では，時間帯（前節では変数 s に相当）が一致すれば発生頻度 r_s 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．例えば，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。

この問題を解決する基本的な方針は、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、例えば通院日モデル、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 [Ihler 06] 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。

本研究ではこの問題の解決に注力し、生活パターンの自動抽出につなげることを目指す。一日の生活パターンを表現する Poisson 過程の混合により複数ある生活パターンのモデル化を考える。具体的には混合数が未知の問題に対するモデル化に相当するため、Dirichlet 過程混合により解決を図る。一般に、Dirichlet 過程混合の導入に伴い問題となるのは、パラメータの事後分布の推定や隠れ変数の推定が複雑になることであるが、前節で述べたヒストグラムデータに基づく Poisson 過程では解析的に事後分布並びに周辺尤度が計算可能であるため、複雑さはそれほど問題にならない。次節では Dirichlet 過程混合について基本的な説明を述べ、次に Dirichlet 過程混合と Poisson 過程を統合したモデルから、生活パターンの自動抽出 (マイニング) について述べる。

3.1 Dirichlet 過程混合

Dirichlet 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 [Ferguson 73] 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、Dirichlet 過程の基本的性質は Escobar と West による説明 [Escobar 95] に委ね、Dirichlet 過程混合のデータ生成の過程を示す。まず、観測量 h に対しパラメータ θ を用いて確率モデル $f(h|\theta)$ を定義し、パラメータの事前分布を $\phi(\theta)$ とする。 θ は λ_0 と r を意味し、 $\phi(\cdot)$ はガンマ分布と Dirichlet 分布、 $f(\cdot)$ は時変 Poisson 過程を意味する。ここで Stick-breaking 表現 [Blei 04] に基づく Dirichlet 過程混合では、 k 番目の生活パターンを生成する確率 π_k を

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

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 $h^{(d)}$ はパターンの選択とパターンに応じた Poisson 過程によりデータを生成することとなる。

$$z_d \sim \mathcal{M}(z_d|\pi), h^{(d)} \sim f(h^{(d)}|\theta_{z_d}) \quad (12)$$

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

3.2 統合モデルに基づく生活パターンマイニング

前節では Dirichlet 過程混合に基づく事変 Poisson 過程のデータ生成について述べた。本節では与えられた活動量デー

タからのモデル獲得、即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 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が自動抽出に相当する。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 MCMC 法の一つである Gibbs サンプリング [MacKay 03] 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 (8), (9) で定義された Dirichlet 分布とガンマ分布の事後分布を定義しパラメータ群 θ をサンプリング
2. (4) 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. [下坂 09] と同様の手順で γ をサンプリング

3.3 タイムスタンプデータに対するモデル化

本稿では計算効率をより高くするためにヒストグラムデータを前提とした Dirichlet 分布を事前分布に用いた計算法について注力しているが、以下、タイムスタンプデータが得られた場合のモデル化について簡単に触れておく。

$$f(t) = \sum_{k=1}^K w_k \mathcal{K}(t|\theta_k) \quad (13)$$

なる混合分布としてモデル化すれば良い。即ち $w \in \mathbb{R}_{\text{SIM}}^K$ である。本来対象とするデータには何らかの時系列周期性があることから 24 時と 0 時には相関性を持たせることが望ましく、von-Mises 分布の利用などが考えられるが、Bayes 推定の観点で計算の簡便さを追求するため、 $\mathcal{K}(\cdot)$ に正規分布を導入し θ に対してガンマ正規分布を仮定すれば、 t の属するインデックス (k に相当) が与えられた下で、前節のように解析的に θ の事後分布が求まる。モデルの推定にはパターンの割り当てだけでなく、混合数 K の設定やインデックスの推定が必要となる。この問題に対しては、混合分布に Dirichlet 過程混合を導入し、入れ子構造の Dirichlet 過程として定式化 [Rodriguez 08] すれば、計算が可能である。一般に、入れ子構造の Dirichlet 過程混合は計算効率の問題や MCMC 法における収束速度の低さが問題であり、実用上については、今後さらなる計算効率の向上が課題となる。

4. 評価実験

前節までに述べた、時変 Poisson 過程の Dirichlet 過程混合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。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。

データ本実験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た。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 分間毎の検知回数を記録したものとなっている*1。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 時間平均で約 1300 回、1 分平均で述べると約 0.95 回検知

*1 $S = 1440$ を意味する




図 2: Extracted activity patterns $\lambda(t)$ at kitchen from 3 months dataset

したものである．Dirichlet 過程混合を行わない，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 Fig. 1 に示すパターンが得られる．実験では，1 分当たりで得られた検知回数を直接利用するものとし，タイムスタンプデータに対するモデル化ではなくヒストグラムデータに対するモデル化を行うものとする．




図 1: Mean activity pattern at kitchen

結果 $\alpha_s = 50$ として，また， a, b については 90 日分のデータで各日の検知回数の平均と分散から初期値として与え， $K = 30$ として解析を行った．その結果，抽出された生活パターンは 4 となり，各時間帯に対する活動量パターンは Fig. 2 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．Fig. 1 では一見すると朝昼夜 3 回共有す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出来た．抽出パターンにおける深夜（23 時～24 時）の活動量が Fig. 1 のそれより大きいのは，事前分布のハイパーパラメータ α_s の値に影響されたためである．なお，事前分布のハイパーパラメータ a, b の与え方によって抽出結果に影響は小さいが， α の与え方によっては，抽出される生活パターンの数が変動するという問題があり，結果として過剰に活動パターンが抽出されてしまうことがある．過剰な活動パターンが抽出される場合，特に 1～2 日程度から活動パターンを作ることがあり，この場合，パターンの解析における解釈を困難にするばかりでなく，推定の統計的な信頼性の低下が問題となる．この問題を回避するための新たな方策を検討することが今後の課題といえる．

5. おわりに

本研究では，居住者の活動のモニタリングを想定し，生活者の活動時間帯と活動量に着目した時変 Poisson 過程による行動モデリング手法を提案した．特に，生活者の行動パターンは

社会的要因により複数存在することからそのようなパターンの効率的な検出として，階層的 Bayes 法の一つである Dirichlet 過程を導入している点が本研究の貢献の一つである．

今後は，我々が既に関与している行動ラベリング手法と本稿で述べた時間帯に着目した手法を統合し，異常検知サービスの高精度化や生活パターンの分析者の手助けとなるツールの実現を目指す．また，実験で得られた結果の通り，階層 Bayes におけるハイパーパラメータの自動選定についても開発を行う予定である．

参考文献

- [Adams 09] Adams, R. P., Murray, I., and MacKay, D. J.: Tractable Nonparametric Bayesian Inference in Poisson Processes with Gaussian Process Intensities, in *Proc. of ICML* (2009)
- [Blei 04] Blei, D. and Jordan, M.: Variational Methods for the Dirichlet Process, in *Proc. of ICML* (2004)
- [Damien 99] Damien, P. and Walker, S.: A Full Bayesian Analysis of Circular Data Using the von Mises Distribution, *Canadian J. of Stats.*, Vol. 27, No. 2 (1999)
- [Escobar 95] Escobar, M. and West, M.: Bayesian density estimation and inference using mixtures, *J. of the American Stats. Assoc.*, Vol. 90, No. 430 (1995)
- [Ferguson 73] Ferguson, T.: A Bayesian Analysis of Some Nonparametric Problems, *Annals of Stats.*, Vol. 1, No. 2 (1973)
- [Fujii 08] Fujii, A., Mori, T., Noguchi, H., Shimosaka, M., Baba, A., and Sato, T.: Behavior Description Algorithm Based on Home Sensor Data Using Nonlinear Transformations, in *Proc. of INSS* (2008)
- [Gill 09] Gill, J. and Hangartner, D.: Bayesian Circular-Linear Regression, Seminar on Bayesian Inference in Econometrics and Statistics (2009)
- [Ihler 06] Ihler, A., Hutchins, J., and Smyth, P.: Adaptive event detection with time-varying Poisson processes, in *Proc. of KDD* (2006)
- [Ihler 07] Ihler, A. T. and Smyth, P.: Learning Time-Intensity Profiles of Human Activity Using Non-Parametric Bayesian Models, in *Advances in NIPS 19* (2007)
- [Kottas 06] Kottas, A.: Dirichlet Process Mixtures of Beta Distributions, with Applications to Density and Intensity Estimation, in *Proc. of Workshop on Learning with Nonparametric Bayesian Methods (conjunction with ICML 2006)* (2006)
- [MacKay 03] MacKay, D. J.: *Information Theory, Inference, and Learning Algorithms*, Cambridge University Press (2003)
- [Moller 98] Moller, J., Syversveen, A., and Waagepetersen, R.: Log Gaussian Cox processes, *Scandinavian J. of Stats.*, Vol. 25, No. 3 (1998)
- [Rodriguez 08] Rodriguez, A., Dunson, D. B., and Gelfand, A. E.: The Nested Dirichlet Process, *J. of the American Stats. Assoc.*, Vol. 103, No. 483, pp. 1131–1144 (2008)
- [下坂 09] 下坂 正倫, ラクシンチャランサク ボンサトーン, 永井 正夫, 森 武俊, 佐藤 知正: 個別適合型運転支援のためのベイズの協調回帰, RSJ2009 予稿集 DVD-ROM (2009)
- [塚本 09] 塚本 吉俊, 高松 周一, 池谷 薫, 森 武俊: 高齢者生活データの可視化と生活状況の把握, RSJ2009 予稿集 DVD-ROM (2009)