

# 確率的状態遷移モデルを用いた家電の消費電力変動予測

黒瀬 祐平<sup>†</sup> 川嶋 宏彰<sup>†</sup> 加藤 丈和<sup>†</sup> 松山 隆司<sup>†</sup>

<sup>†</sup> 〒 606-8501 京都市左京区吉田本町 京都大学大学院情報学研究所

**あらまし** 本稿では、家電の消費電力の変動パターンのモデル化と、それを用いた消費電力予測アルゴリズムについて述べる。一般に家電機器は、ユーザの操作や環境変動、事前にプログラムされた処理手順に従って内部の動作モードを切り替えながら動作する。このような動作モードの切り替え時には、消費電力が非連続かつ急激に変化することが多い。そのため、単峰性のガウシアンモデルやカルマンフィルタなどの線形フィルタによる変動予測は困難である。そこで本研究では、動作モードの変化を表す状態遷移モデルと動作モード内の電力変動を表すモデルを組み合わせたハイブリッドモデルにより消費電力変動をモデル化する。各動作モードは家電の特性や使用環境に応じた固有の持続長と次に遷移する動作モードの確率分布を持つと考え、モード持続長分布のパラメータを持つ隠れセミマルコフモデルを用いて消費電力の変動パターンを記述する。本稿では、実際に計測した家電の消費電力データから EM アルゴリズムにより隠れセミマルコフモデルのパラメータを学習し、学習したモデルを用いて将来の電力変動の予測を行う方法を示す。また、実験ではエアコンと冷蔵庫の消費電力データを用いて本手法の有効性を示す。

**キーワード** 隠れセミマルコフモデル, 消費電力変動モデル, 消費電力変動予測, エネルギーマネジメント

## A Stochastic State Transition Model for Estimating Appliance Power Consumption

Yuhei KUROSE<sup>†</sup>, Hiroaki KAWASHIMA<sup>†</sup>, Takekazu KATO<sup>†</sup>, and Takashi MATSUYAMA<sup>†</sup>

<sup>†</sup> Graduate School of Informatics, Kyoto University, Yoshida-Honmachi Sakyo-ku Kyoto-shi, 606-8501, JAPAN

**Abstract** This paper describes a modeling, learning, and prediction method for fluctuation of power consumption of home appliances. Generally, home appliances generate complex power consumption patterns because they often switch their internal functional modes according to user's operations and environment changes. Therefore, it is difficult to predict the power consumption by using simple model such as unimodal gaussian model, Kalman-filter and so forth. To solve this problem, we propose a hybrid power consumption pattern representation by hidden semi-Markov model. We also propose a learning method for the model parameters and a prediction method for future power consumption from measured power consumption data at the real-time. In experiment we show results that we applied our method to fluctuation of home appliances.

**Key words** Hidden semi-Markov Models, modeling home appliance power consumption, prediction of home appliance power consumption, energy management

### 1. はじめに

家庭やオフィスなどにおいて、使用電力の監視、管理をおこなう HEMS (Home Energy Management System) / BEMS (Building Energy Management System) [1] が注目されている。これらのシステムでは、電力需要が制限を超えそうになると警告を出したり、自動制御によってエアコンや照明などの電力を削減することでピーク電力をおさえたり、不要な家電を停止して消費電力を削減したりすることを目的としている。このよう

なシステムでは需要家内の消費電力の変動パターンを予測することで、より効率的な電力管理が実現できると考えられる。

現在でも、電力会社の発電計画などでは電力需要予測を行っているが、このような場合には地域一帯やサービス区域全体の電力需要を対象としており、地域内に多数の需要家が存在するため、ならし効果によって急激な需要変動はみられない。そのため比較的単純なモデルで需要予測を行うことが可能であるが、一方で HEMS/BEMS が対象とする需要家内の需要予測では、一需要家のみ消費電力を対象とするため、使用している個々

の家電機器の電力変動が需要家全体の消費電力変動に与える影響は大きくなる。また、一般に家電機器は内部にマイコンやセンサを持ち、プログラムされた動作手順や環境変動に応じて内部の動作モード（保温ポットのサーモスタットにオン・オフ制御など）を自律的に切り替えながら動作するため、動作モードの切り替え時に急激な電力変動を起こすことが多く、カルマンフィルタのような線形フィルタや単峰性のガウシアンモデルなどで電力変動を予測することは困難である。

このような問題に対して、我々は [2], カルマンフィルタを家電の動作モードの変化にあわせて切り替える Interval-based Switching Kalman Filters を提案した。しかし、この手法はモデルパラメータが複雑であり、学習に大量のデータを必要とするため、環境変化などに対して再学習が困難である。また、予測のための計算量が多く、リアルタイム予測が難しいという問題があった。そこで本研究では、動作モード内の電力変動を単峰性のガウシアンでモデル化した隠れセミマルコフモデル [3] を用いて電力変動モデル化することにより、より少量のデータによる学習や環境変化に対するインクリメンタルな学習、リアルタイムの電力変動予測を目指す。

## 2. 消費電力変動モデル

本研究では各家電ごとに消費電力変動をモデル化することを考える。家電の消費電力変動には、図 1 に示すように、(1) 安定して同じ変動パターンが継続する時区間と、(2) ある変動パターンから別の変動パターンに急激に変化する瞬間がある。これは、家電が事前にプログラムされた動作手順や環境変動に応じて、内部で動作モードを切り替えながら動作しているためと考えられる。そこで本研究では、(1) の同じ変動パターンが継続する時区間を家電のモードと呼び、(2) のある変動パターンから別の変動パターンへの移り変わりをモードの遷移として記述する。このとき、各モードはそれぞれ固有の持続長と、次に遷移する遷移先モードを確率分布として記述できる。本研究では、あるモード内の電力値の分布を単峰性のガウシアンで表現し、かつ各モードの持続長分布を明示的にモデル化できるような隠れセミマルコフモデル [3] で記述する。

まず、家電が持つモードの数を  $M$  とし、以下の集合を定義する。

- $M$ : 家電が持つモードの数
- $Q$ : 家電が持つモードの集合 ( $Q = \{q_1, q_2, \dots, q_M\}$ )
- $\Delta$ : 家電の各モードがとりうる持続長の集合 ( $\Delta \subset \mathbb{N}$ )

ここで、家電系列は 30 秒ごとに  $y_t (t = 1, 2, \dots)$  のようサンプリングされているものとし、 $t$  を単に時刻と呼ぶ。したがって、上述の持続長、および以下で述べるモデルおよびアルゴリズムの動作もこのサンプリングされた時刻を基準とする。ここで、時刻  $t$  におけるモードを表す確率変数を  $s_t$ 、時刻  $t$  におけるモードが次にモードを変化させるまでの残り時間を表す確率変数を  $\tau_t$  とする。このとき、本研究で扱うモデルのパラメータは下記のように表される。

- $\pi_m := P(s_1 = q_m), m = 1, \dots, M$ : 観測開始時刻における家電のモードが  $q_m \in Q$  である確率

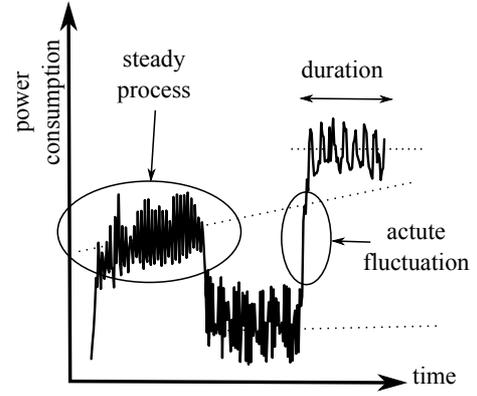


図 1 消費電力変動の特徴

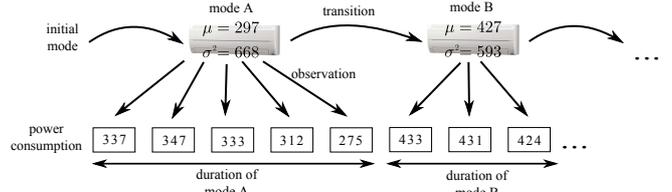


図 2 隠れセミマルコフモデルによるモデル化

- $a_{mn} := P(s_{t+1} = q_n | s_t = q_m, \tau_t = 1), m, n = 1, \dots, M$ : 時刻  $t + 1$  においてモード  $q_m \in Q$  から  $q_n \in Q$  へ遷移する確率 ( $m \neq n$ )
- $b_m(y_t) := P(y_t | s_t = q_m), m = 1, \dots, M$ : モード  $q_m \in Q$  において観測値  $y_t$  が得られる確率密度分布。これを以下では出力確率分布と呼ぶ。(本研究では平均  $\mu_m$  と分散  $\sigma_m^2$  のガウス分布  $\mathcal{N}(\mu_m, \sigma_m^2)$  を用いる)
- $p_m(d) := P(\tau_t = d | s_t = q_m, \tau_{t-1} = 1)$ : モード  $q_m \in Q$  が  $d \in \Delta$  だけ持続する確率 (持続長ごとのヒストグラムとして表す)

この確率的状態遷移モデルによって、家電の消費電力変動を次のように生成されると考える。まず、家電は初期分布  $P(s_1; (\pi_m)_{m=1}^M)$  に従うモード  $s_1$  から動作を開始、持続長分布  $p_{s_1}(d)$  によって決まる時間  $d \in \Delta$  だけ同じモードを継続する。その後モード遷移確率に従って別のモードへ遷移する。このとき、遷移後のモード  $s_{1+d}$  の持続長は  $p_{s_{1+d}}(d)$  によって決まる。このようなモード遷移をくりかえすことで各時刻におけるモード  $s_t$  が決まり、そのときのモード  $s_t$  に対応する分布  $b_{s_t}(y)$  に従って、消費電力値  $y_t$  を発生する (図 2)。

このモデルに基づき、実際の家電の消費電力変動に適合するモデルパラメータを学習する。本研究では Expectation-Maximization (EM) アルゴリズムによる最尤推定を用いて学習を行う。学習用のある家電の消費電力系列が与えられたとき、まず、E ステップにおいては、初期値もしくは前回の M ステップで計算されたモデルパラメータを用いて、各時刻のモードの事後確率分布を推定する。具体的な確率計算アルゴリズムとしては、[4] で提案されているフォワード・バックワードアルゴリズムを用いることで、従来の隠れセミマルコフモデルにおけるフォワード・バックワードアルゴリズムに比べ少ない計算量と

することができる。

次の M ステップでは、E ステップで得られたモード系列の確率分布に対して観測値を得る尤度が最大となるモデルパラメータを計算し、家電の消費電力変動のモデルパラメータとして更新する。

この E ステップと M ステップを繰り返すことで、モデルパラメータに対する学習データ系列の尤度は上がっていくことが期待できる。この尤度の値が、学習の繰り返しに対して十分収束した時に、対象となる学習データについて学習を終了する。

なお実験では、モード数  $M$  は 5 に固定とし、持続長を  $\Delta = \{1, 2, \dots, 50\}$  とした。またパラメータ  $\pi_m, a_{mn}, p_m(d)$  の初期値はランダムに与え、 $b_m(y_t)$  の各モードの平均  $\mu_m$  については  $[0, y_{\max}]$  の範囲の一様分布から得られた乱数、分散  $\sigma_m^2$  は学習データ全体の分散値を初期値とした。ただし、 $y_{\max}$  は学習データの電力値の最大値とする。

この学習では、観測値データが得られるごとに、現在のモデルパラメータを初期値として順次学習データを差分更新（フィードバック）することで、オンライン学習に適用することも可能である。

予測時においては、リアルタイムに得られる時刻  $\hat{t}$  までの観測データに対してフォワードアルゴリズムを適用することで  $P(s_{\hat{t}}, \tau_{\hat{t}} | y_{1:\hat{t}})$  を計算することができる。これは、時刻  $\hat{t}$  までの観測が得られた条件の下で、時刻  $\hat{t}$  における家電モードが  $s_{\hat{t}}$  であり、かつそのモードがそれ以降持続する残り時間が  $\tau_{\hat{t}}$  である確率分布を表す。ここから、 $\hat{t}$  より未来の任意の時刻  $t (> \hat{t})$  におけるモードおよび観測値の予測を行うことができる。まず、フォワードアルゴリズムと類似した再帰的確率計算によって時刻  $t$  におけるモードの確率分布  $P(s_t | y_{1:t})$  が得られる。そして、この分布と各モードの出力確率分布  $b_m(y_t), m = 1, \dots, M$  とを用いることで、時刻  $t$  における観測値の予測分布  $P(y_t | y_{1:t}) = \sum_m b_m(y_t) P(s_t = q_m | y_{1:t})$  を求めることができる。

### 3. 実験

提案手法のモデル学習、およびその結果に基づいた予測を、実際の家電に適用した結果について述べる。ここでは、エアコンと冷蔵庫の例を示す。ある時区間にわたって計測されたデータについて、EM アルゴリズムで 10 通りの異なる初期値を与えて学習し、もっとも対数尤度の高いモデルパラメータを最終的なモデルパラメータとした。また、得られたモデルパラメータと、ある時刻までに得られた観測値の時系列データから、その時刻より先の時点の消費電力変動の予測を行った。

図 3、図 4 に EM アルゴリズムによるモデルパラメータの学習結果を示す。上から順に、元の消費電力データ系列（縦軸：消費電力 [W]）、それぞれの時刻の推定されたモード（縦軸：確率）、モードの持続長分布（縦軸：確率）、横軸はいずれも時間 [s] である。また、図 5、図 6 に予測の結果を示す。上から順に、元の消費電力データ系列（縦軸：消費電力 [W]）、消費電力予測分布（黒から白になるほど確率が高い、縦軸：消費電力 [W]）、モード予測（縦軸：確率）、フォワードアルゴリズム

による各時刻におけるモード推定（縦軸：確率）、消費電力予測分布の元データ系列に対する対数尤度の変動（縦軸：対数尤度）、横軸はいずれも時刻 [s] である。グラフの線分の色は、家電が持つそれぞれのモードを示す。

まず、学習結果について考察する。図 3 のように、消費電力変動において時間的に独立な変動が支配的である場合、各時刻におけるモードの区別がうまくいっており、モードの持続長分布も各モードが単峰型の分布を持つように学習されている。一方で、図 4 のように、時間経過とともになだらかに変化するような消費電力変動が支配的である家電については、モードの区別が曖昧になり、モードの持続長分布が一つのモードについても分散した結果となってしまっている。これは、各モードの観測値の出力確率の分布を時間独立なガウシアンでモデル化しているため、平均が徐々に変化していくような変動を表現出来ず、複数のモードに分割されるためであると考えられる。この問題に対処するためには、観測値の出力確率分布  $b_m(y)$  に一次や二次の線形変化のモデルを加えるなどの拡張が必要と考えられる。

次に、予測結果について述べる。図 5 のように、学習結果としてモードの持続長や統計量が狭い範囲に分布している場合、あるいは同じモードが学習データ内に繰り返し現れる場合には、モード予測とフォワードアルゴリズムによる各時刻におけるモード推定結果が合致しており、精度のよい予測ができていく。一方、図 6 のように、一つのモードが多数の持続長分布の重ね合わせで表現される学習結果で表わされると、現在時刻から離れるに従って予測される電力値の分散が大きくなってしまふことが分かる。さらに、図 6 の 4500 秒から 5000 秒付近の時区間において、尤度が極端に下がっている。このように学習データ内に出現する回数が少ないモードについては、その発生を予測することが難しいため、高精度の予測を実現するためには、今後より多くの学習データからモデルパラメータの学習を行う必要がある。

### 4. まとめ

本稿では、家電の消費電力変動を、家電の内部モードの遷移とその持続長に着目した隠れセミマルコフモデルでモデル化することを提案し、その有効性を検討した。その結果、対象となる家電が持つ持続長程度の予測区間においては、妥当なモードの予測が可能であり、さらにモード内の電力変動が時間的に独立な変動のみの場合においては、本研究の消費電力の出力確率のモデルで妥当な予測ができることを示した。

モードの持続長程度の時区間における消費電力変動の予測が効果的な応用例として、分散電源の制御が挙げられる。家庭やオフィスにおいて、複数の電源が存在する場合、各電源の特性を考慮した配電ができることが望ましい。単一の電源では対応できないような急激な消費電力の発生時に、その発生を事前に予測することができれば、前もって電源の切替や出力の変更などを行うことで対応することができる。

今後の課題としては、まず、家電の設置場所の環境変化に応じたモデルパラメータの更新のために、新たな観測値を得ながらオンラインで学習を行うアルゴリズムを追加することが

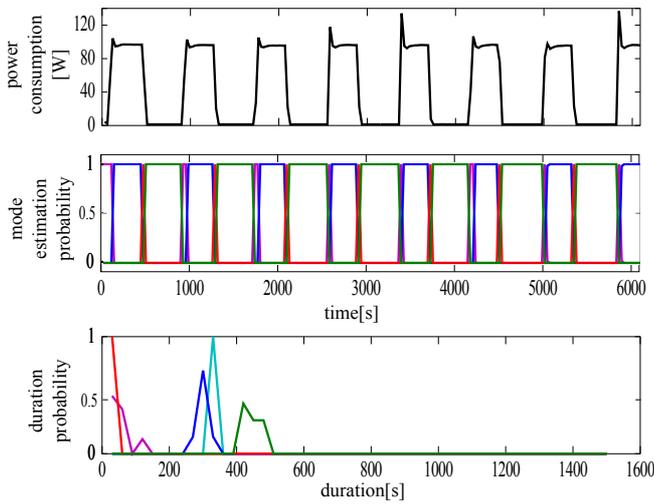


図 3 冷蔵庫の消費電力変動の学習結果

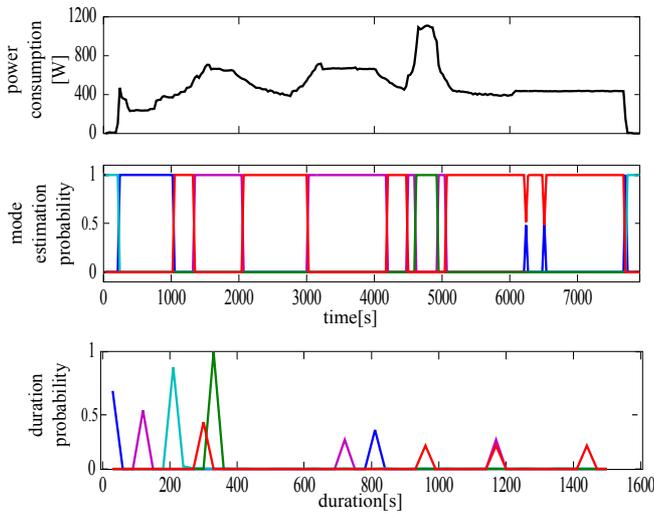


図 4 エアコンの消費電力変動の学習結果

挙げられる。また、家電の消費電力変動はエアコンの例のように、時間経過とともに自然に変わっていくものも多く存在する。モード内の観測値出力確率を線形な変化を加えるように拡張することで、こうした変動を表現することが可能になると考えられる。

**謝辞** 本研究の一部は、独立行政法人科学技術振興機構、CREST の助成を受けたものである。

### 文 献

- [1] 独立行政法人新エネルギー・産業技術総合開発機構, “人の好みや行動パターンに応じた HEMS/BEMS 技術の研究開発,” 2007.
- [2] 土師浩平, 加藤丈和, 松山隆司, “Interval-based switching Kalman filters による家電の電力消費モデル推定,” 信学技報, vol.112, no.31, pp.39-44, 2012.
- [3] S. Levinson, “Continuously variable duration hidden Markov models for speech analysis,” IEEE International Conference on Acoustics, Speech, and Signal Processing, vol.11, pp.1241-1244, 1986.
- [4] S.Z. Yu and H. Kobayashi, “An efficient forward-backward algorithm for an explicit-duration hidden Markov model,” Signal Processing Letters, IEEE, vol.10, no.1, pp.11-14, 2003.

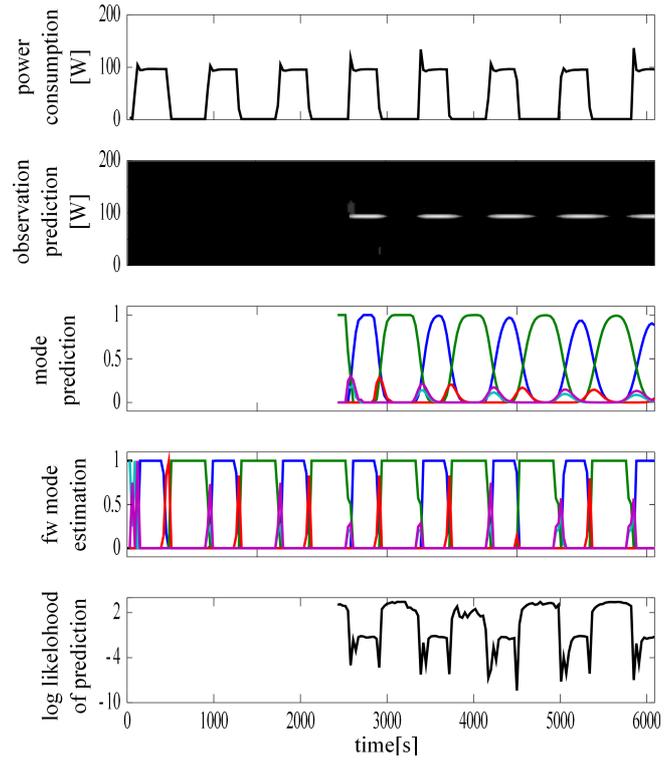


図 5 冷蔵庫のモード・消費電力変動の予測結果

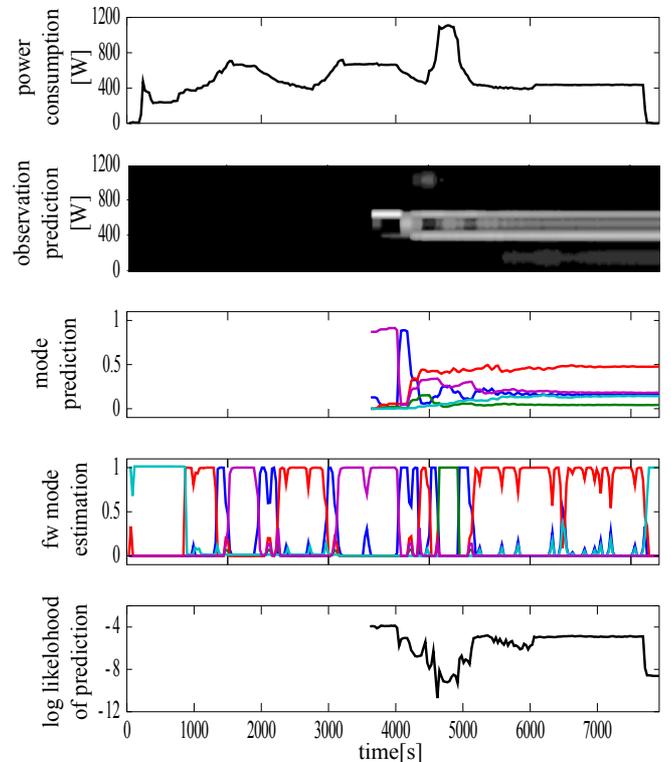


図 6 エアコンのモード・消費電力変動の予測結果