# Interval-based switching Kalman filters による 家電の電力消費モデル推定

土師 浩平 加藤 丈和 松山 隆司

† 〒 606-8501 京都市左京区吉田本町 36-1 京都大学大学院情報学研究科 †† 〒 606-8501 京都市左京区吉田本町 36-1 京都大学学術情報メディアセンター E-mail: †{haze,tkato,tm}@vision.kuee.kyoto-u.ac.jp

あらまし 本稿では、電気機器の電力消費の変動パターンをモデル化し、そのパラメータを学習によって推定する方法について述べる。電力消費パターンを学習することで、電気機器の動作状態の推定や機器の故障診断、電力消費パターンの予測などを行うことが可能となり、家庭やオフィス内のエネルギーマネージメントへの応用が期待できる。現在一般的に使用されている電気機器は、多様な動作モードを持ち、電力消費の変動パターンも様々である。このような電気機器のモデルとして、本研究では、複数の Kalman Filter の切り替えによって連続・非連続なダイナミックスを表現する Interval-based switching Kalman Filters (ISKF)を提案する。ISKFは、単一の動的システムで記述できる電力消費パターンをモードと呼び、各モードの継続時間とモード遷移を確率時間オートマトンによって表現する。本稿では、情報量規準に基づいたモデル推定によって学習データから ISKF のパラメータを推定する方法と、学習した ISKF を用いて家電の電力消費パターンを予測する方法について述べる。また実験では、洗濯機や洗濯機など実際の家電に対するモデル推定と電力消費予測を行い、提案手法の有効性を示す。

キーワード カルマンフィルタ、確率時間オートマトン、電力消費モデル、scale-space filter、電力消費予測

# Modeling home appliance power consumption by interval-based switching Kalman filters

Kohei HAZE<sup>†</sup>, Takekazu KATO<sup>††</sup>, and Takashi MATSUYAMA<sup>†</sup>

† Graduate School of Informatics, Kyoto University, 36-1 yoshidahonmachi sakyo-ku kyoto-shi, 606-8501, Japan

†† Academic Center for Computing and Media Studies, Kyoto University, 36-1 yoshidahonmachi sakyo-ku kyoto-shi, 606-8501, Japan

E-mail: †{haze,tkato,tm}@vision.kuee.kyoto-u.ac.jp

Abstract This paper describes power consumption pattern modeling for home appliances. The power consumption model realizes power consumption prediction, appliance status recognition and irregularity detection. The technology is expected to effective home energy management systems. Recently, home appliances have various patterns of power consumption caused by intelligent power control function against environment factors. Cope with this problem; we proposed a new dynamical system model, which call it Interval-based switching Kalman Filters (ISKF). It has some continuous dynamic systems and switches the systems discontinuously according to the probabilistic timed automaton. We proposed leaning algorithm for ISKF and power consumption prediction algorithm by ISKF. Experimental result shows effectiveness of the proposed method by leaning / prediction of the power consumption pattern for home appliances, heir dryer, cleaner and a washing machine.

**Key words** Kalman filter, timed-automaton, modeling home appliance power consumption, scale-space filter, home appliance consumption prediction

## 1. はじめに

近年、電力需要の急激な変動や事故・災害時における電力供給能力の急激な減少などによる電力需給の逼迫が問題となっており、家庭やオフィスにおける電力の見える化や電力マネージメントなどの技術が注目されている。我々はこのような問題に対し、電力を中心としたエネルギーの流れを情報化して、予測・制御を行う「エネルギーの情報化」というコンセプトを提案し、研究開発を行なっている[1].

家庭・オフィス内の電力マネージメントにおいては、どのような家電がどのような状態で動作しているかといった電気機器の認識[2] やその状態推定、どのように電力需要が変化するかといった電力消費パターンの予測が重要となる。本研究の目的は、家電の電力変動モデルを推定し、推定した電力変動モデルを用いて家電の動作状態の推定や電力変動の予測を行うことである。

旧来、電気機器は白熱球や電熱線などの抵抗負荷、動力などの誘導負荷が多くその電力消費パターンも単純かつ連続的な変化であった。しかし、近年では、予めマイコンにプログラムされた挙動や環境条件をフィードバックしながら内部の自律的な運転モード制御に従って動作状態を様々に切り替えながら動作する家電が多く、単純な線形予測法で需要予測を行うことは難しい。

そこで本研究では、自律的な動作状態の切替を含めた家電の電力変動モデルを定義し、電力変動モデルを学習する方法と、 それを用いた電力変動の予測法を提案する。

# 2. 家電の電力変動モデル

### 2.1 家電の電力変動モデル

一般的に,実生活で用いられる家電は,連続的な出力変化だけでなく,人為的・自動的な内部回路の切り替えによって動作状態を変える「知的な」動作をするものが多い.このような家電では,不連続な電力変動を行うため,単一の動的システムで表現することが難しい.そこで本研究では,家電の電力変動を複数の動的システムの組み合わせによってモデル化する.すなわち,家電が有している複数の動作モードをそれぞれ個別の動的システム  $\mathcal{D}_i$  の切り替わりを状態遷移モデルとして記述する.

#### 2.1.1 動作モードの遷移モデル

本研究では、不連続な動作状態の切り替わりを、連続状態の 状態変数と区別するために動作モードと呼ぶ。一般に状態遷移 モデルではモード遷移の順序だけが定義されるが、家電の電力 消費パターンを表現するには順序だけでなく持続時間も重要で あると考え、オートマトンに状態の持続時間を導入した確率時 間オートマトンによってモード遷移をモデル化する。

ある家電の動作モード  $q_i$  に持続時間  $\tau$  を加えた時区間  $I=\langle q_i,\tau\rangle$  として表す。これにより、家電の電力変動は持続長を持つ時区間系列  $\mathcal{I}=\{I_1,\ldots,I_K\}$  で表される。このとき時区間同士の遷移確率は、モード遷移確率  $P(q_j|q_i)$  とモード  $q_i$  の持続長分布  $P(\tau|\tau_p,q_i)$  より  $P(I_n=\langle q_j,\tau\rangle|I_{n-1}=\langle q_i,\tau_p\rangle)=$ 

 $P(q_i|q_i)P(\tau|\tau_p,q_i)$  と表現することが出来る.

#### 2.1.2 家電の動的システム

本研究では、ある時区間の動的システム  $\mathcal D$  を Kalman Filter [3] によってモデル化する。このときの変動モデルとしては、定加速度モデルを用いる。

ある動作モードの家電の内部状態ベクトル  $\mathbf{x}_t$  を,電力値  $p_t$  と電力変動速度  $\dot{p}_t$ ,電力変動加速度  $\ddot{p}_t$  を用いて  $\mathbf{x}_t = (p_t \ \dot{p}_t \ \ddot{p}_t)^T$  と定義する。このとき,F を遷移行列, $w^{(i)}$  を平均ベクトル  $\mathbf{0}$ , 共分散行列  $Q^{(i)}$  の正規分布に従うシステムノイズとすると状態方程式は以下のように与えられる。添字 i が付随しているパラメータはそれぞれ線形システム  $D_i$  のパラメータである。

$$\mathbf{x}_t = F\mathbf{x}_{t-1} + \mathbf{w}^{(i)} \ (\mathbf{w}^{(i)} \sim \mathcal{N}(\mathbf{0}, Q^{(i)})) \tag{1}$$

$$F = \begin{bmatrix} 1 & \delta t & \frac{1}{2}\delta t^2 \\ 0 & 1 & \delta t \\ 0 & 0 & 1 \end{bmatrix}$$
 (2)

また,H を観測行列, $v^{(i)}$  を平均 0,分散  $R^{(i)}$  の正規分布に従う観測ノイズとすると,観測方程式は次式のようにモデル化できる.

$$y_t = H\mathbf{x}_t + v^{(i)} \ (w^{(i)} \sim \mathcal{N}(0, R^{(i)}))$$
 (3)

$$H = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \tag{4}$$

このとき,時刻 t の電力値  $p_t$  の事後確率密度  $P(p_t|\mathbf{x}_t)$  は次式のように推定される.

$$P(p_t|\mathbf{x}_t, d_t = D_i) = \mathcal{N}(p_t|H^{(i)}\mathbf{x}_t, R^{(i)})$$
 (5)

$$P(\mathbf{x}_t|\mathbf{x}_{t-1}, d_t = D_i) = \mathcal{N}(\mathbf{x}_t|F\mathbf{x}_{t-1}, Q^{(i)})$$
(6)

ただし、 $d_t = D_i$  は時刻 t で動的システム  $D_i$  にしたがって電力変動をしていることを意味する。また、時刻 t までの観測が得られた条件の下で、n 時刻先の状態および観測を推定することが出来る。以下、系列  $y_a, ..., y_b$  を  $y_a^b$  のように表す。

$$P(\mathbf{x_t}|\mathbf{y_1^{t-1}}, \mathbf{d_t} = \mathbf{D_i}) = \mathcal{N}(\mathbf{F^{(i)}}\mathbf{x_{t-1}}, \mathbf{V_{t|t-1}^i})$$
 (7)

$$P(y_t|y_1^{t-1}, d_t = D_i) = \mathcal{N}(H^{(i)}x_{t|t-1}^i, HV_{t|t-1}^i(H^{(i)})^{\mathrm{T}} + R^i)$$
(8)

ここで、 $x_{t|t-1}^i$  と  $V_{t|t-1}^i$  は Kalman Filter の更新式に基づいて 更新される.

本研究では、電力変動のモデルを、継続時間と動作モードを持つ時区間の切り替えと、各動作モードに対応する Kalman Filter で表現した動的システムによって表現する。このような変動モデルを本研究では Interval-based Switching Kalman Filters (ISKF) と呼ぶ。

# 2.2 ISKF を用いた家電の電力変動予測

本章では、現在までの観測データから将来の電力値を予測する方法について述べる。この問題は、現時刻 t までの観測データから予測される n 時刻先の電力値  $\rho$  の確率分布を  $P_{t+n|t}(\rho)$  を求める問題と考えることができる。

現在の時刻 t における電力値の確率分布を  $P_{t|t}(\rho)$  とする。また、現在の動作モードを  $q_i$  であり、このモードが現在までに

時間  $\tau_1$  だけ継続している確率を  $P(q_i,\tau_1)$ , モード  $q_i$  が現在から時間  $\tau$  後に別のモードに遷移する確率を  $P_{q_i}(\tau)$ , モード  $q_i$  からモード  $q_j$  に遷移する確率を  $P(q_j|q_i)$  とする.また,時刻  $t+\tau$  からモード  $q_j$  に遷移した場合に時刻 t+n の電力値の確率分布を  $P_{q_j,\tau}(\rho)$  とすると, $P_{t+n|t}(\rho)$  は以下のように求められる.

$$\begin{split} P_{t+n|t}(\rho) &= \sum_{\tau} \sum_{i} \sum_{j} \quad \left\{ P_{t|t}(\rho) P(q_i, \tau_1) P(q_j|q_i) \right. \\ &\left. P_{q_i}(\tau) P_{q_j, \tau}(\rho) \right\} \end{split}$$

ここで, $P(q_i, \tau_1)$ , $P(q_j|q_i)$ , $P_{q_i}(\tau)$  は事前学習によっられる.また,確率分布  $P_{t|t}(\rho)$ , $P_{q_j,\tau}(\rho)$  は Kalman F よって計算することができる.確率分布  $P_{t+n|t}(\rho)$  の期求めることで n 時刻先の電力値を推定することができる.

# 3. ISKF の学習

本章では、家電の電力計測データから ISKF のパラメータを 学習する方法について述べる。 ISKF は複数の線形システムか らなるため、計測データがどのような動的システムで構成され ているかという問題と、計測データのどの部分がどの動的シス テムに対応しているかという問題を同時に解く必要がある。

本研究では、まず計測データを同じ動的システムで表現できる時区間毎に分節化し、分節化された各時区間のなかで同じ動的システムに属するグループ毎にクラスタリングすることで各モードとその動的システムを学習する。なお、分節化やクラスタリングの判断には情報量規準を用いる。

## 3.1 電力変動データの分節化

電力計測データを分節化する手法について述べる.

3.1.1 Scale-space filter による分節化トーナメントの作成本研究では、ある動的システムに対応する電力計測データは時間的に連続であり、動作モードが変化して動的システムが切り替わる時点で電力値が不連続に変化すため、計測データの不連続な点を見つけて分節化すれば良い。しかし、家電の電力変動の大きさは家電によって様々であり、また計測データにはノイズも含まれるため、適切なスケールで不連続点を見つけることが難しい。そこで、多重解像度解析手法の一つであるScale-space Filter (以下 SSF)を用いて分節点候補を再帰的に検出し各時区間に対して Kalman filter をフィッティングしてその当てはまりの良さを情報量基準で判断することで分節点を決定する.

電力計測データを原信号 f(z) とする.これに対して SSF を 適用する次式のようにスケール  $\sigma$  で平滑化された信号が得られる.

$$F(z,\sigma) = f(z) * g(z,\sigma)$$
 (10)

$$g(z,\sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp(-\frac{z^2}{2\sigma^2})$$
 (11)

ただし \* は畳み込み演算子, $g(z,\sigma)$  は標準偏差  $\sigma$  のガウス関数である.このとき,スケール $\sigma$  の値を 0 から徐々に大きくしていくことで平滑化された信号を得る事が出来る.

ここで、スケール $\sigma$ を変化させて多段に平滑化した信号の変曲点を算出する事により、フィンガープリント図と呼ばれる以

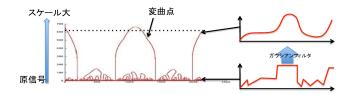


図 1 Scale Space Filter とフィンガープリント図

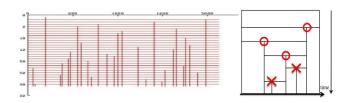


図 2 分節点トーナメントと分節点候補

下のような変曲点の集合図 1 を得ることが出来る。変曲点位置 は以下の式 12 で求めることが出来る。ここで  $\partial^i F(z)/\partial z^i$  は 信号 F(z) の i 次微分を表す。

$$\frac{\partial^2 F(z,\sigma)}{\partial z^2} = 0, \frac{\partial^3 F(z,\sigma)}{\partial z^3} \neq 0 \tag{12}$$

このフィンガープリント図の変曲点位置をスケールの大きい方から追跡することにより、図 2 に示すような再帰的な分節点(分節化トーナメント)が算出される。そして、図 2(右)に示すようにスケールの大きい分節点候補から分節化を再帰的に進める。

#### 3.1.2 情報量規準による分節化の判定

この節では、得られた分節点候補について各時区間に動的システムをあてはめ、観測値との誤差とモデルの複雑さを赤池情報量規準によって評価し分節化の判定を行う方法について述べる.

### a) 動的システムの学習

与えられた時区間に対して誤差が最小となる Kalman Filter のパラメータを求めることで,動的システムを学習した.このとき,第 2.1.2 節で説明した時系列の電力値データに対する電力値の初期値  $\mathbf{x}_{\text{ini}}^{(i)}$  と観測ノイズの分散  $R^{(i)}$ ,系列長 $_{T}$  を学習する.ここで,添字 $_{I}$  は動的システム  $_{L}$  に対応し,状態遷移行列  $_{I}$  については全ての動的システムで固定値を与えた.このとき,初期値  $_{I}$  なるように推定した.

### b) 情報量規準による分節化判断

分節化トーナメントによって再帰的に定義した分節点候補について動的システムの情報量が最も小さくなるように分節化判定を行う。情報量規準としては赤池情報量規準[5]を用いた。これは、モデルの複雑さとデータとの適合度とのバランスを評価するための指標である。本研究では、Kalman Filter のデータとの適合度と自由パラメータ数を評価するために以下のように、AIC を定義した。

$$AIC = -2\ln(L_{\text{obs}}) + 2k \tag{13}$$

このとき  $L_{\text{obs}}$  は観測モデル (式 3) の最大尤度, k はモデルの

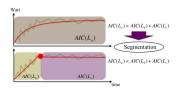


図 3 AIC による分節化判定

持つ自由パラメータの数で観測ノイズの分散 R, 初期値  $\mathbf{x}_{\text{ini}}$ , 初期値の分散  $V_{\text{ini}}$  で k=10 である。なお,自由パラメータ数は項の値は電力変動の複雑さに合わせて変化するため,チューニングパラメータ  $\alpha$  を導入して実際には次のような式で AIC を算出している。

$$AIC = -2\ln(L_{\rm obs}) + 2\alpha k \tag{14}$$

観測モデルの最大尤度は以下のように求める。まず,Kalman filter で時刻 t で観測値  $y_t$  が得られたときの電力値の更新値を  $\mathbf{x}_{\mathbf{t}|\mathbf{t}}$  とすると,観測誤差  $e_y(t)$  は,

$$e_y(t) = |H\mathbf{x_{t|t}} - \mathbf{y_t}| \tag{15}$$

のように求まる.そして,観測誤差から誤差分散  $\sigma_{e_y}^2$  を算出 する

$$\sigma_{e_y}^2 = \frac{1}{N} \sum_{t=1}^{N} (e_y(t) - \bar{e_y})^2$$
 (16)

そして、時刻tの $L_{
m obs}(t)$ は

$$L_{\text{obs}}(t) = \frac{1}{\sqrt{2\pi\sigma_{e_y}^2}} \exp(-\frac{e_y(t)^2}{2\sigma_{e_y}^2})$$
 (17)

のように表される. よって、観測モデルの最大尤度  $\ln(L_{\mathrm{obs}})$  は、以下の数式で表される.

$$\ln L_{\text{obs}} = \sum_{t=1}^{N} \ln L_{\text{obs}}(t)$$
$$= \sum_{t=1}^{N} -\frac{1}{2} \ln(2\pi\sigma_{e_y}^2) - \frac{e_y(t)^2}{2\sigma_{e_y}^2}$$

ここで、式16より、上式は次のように展開できる、

$$\ln L_{\text{obs}} = \sum_{t=1}^{N} -\frac{1}{2} \ln(2\pi\sigma_{e_y}^2) - \frac{1}{2}$$

と表される.

分節化トーナメントに従って、各分節点候補にたいして、分割しなかった場合の時区間で算出した AIC と、分割した場合のそれぞれの時区間で算出した AIC の和を比較し、情報量が小さくなるように分節化の判定を行う(図3参照).

# 3.2 分節化された時区間のクラスタリング

本説では、分節化された各時区間を同じ動的システムで記述できる時区間にクラスタリングすることによって、動作モードの数を推定する.

ここで、初期状態では、1つの時区間が1つの動的システム とし、類似する動的システムを持つ時区間の動的システムを併



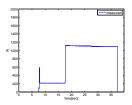


図 4 左:計測環境, 右: 計測データの例

合することでクラスタリングを行う.以下、併合の順序をきめるための動的システム同士の類似性評価と、実際に併合するかどうかを判断する評価基準について述べる.

#### 3.2.1 動的システム間距離

ここでは、動的システム  $D_i(i=1,2,...,M)$  の近い順にクラスタリング判定を行うため、モデルの近さの指標として、動的システム  $D_i$  の初期値パラメータ  $\mathbf{x}_{\mathbf{ini}}^{(i)}$  のマハラノビス距離を用いる。動的システム  $D_i$  の初期値パラメータを  $\mathbf{x}_{\mathbf{ini}}^{(i)} = (p_{\mathbf{ini}}^{(i)}, \dot{p}_{\mathbf{ini}}^{(i)}, \ddot{p}_{\mathbf{ini}}^{(i)})$  とすると、動的システム  $D_i$  と  $D_j$  のマハラノビス距離  $d(\mathbf{x_i}, \mathbf{x_j})$  は以下のような数式で表される。

$$d(\mathbf{x_i}, \mathbf{x_j}) = \sqrt{(\mathbf{x_i} - \mathbf{x_j})^{\mathrm{T}} \mathbf{\Sigma_x} (\mathbf{x_i} - \mathbf{x_j})}$$
(18)

ここで、 $\Sigma_x$  は分節化された全時区間における初期値パラメータ  $\mathbf{x}$  の分散共分散行列である。そして  $d(\mathbf{x_i}, \mathbf{x_j})$  を動的システム  $D_i$ ,  $D_j$  のモデル間距離  $Dist_{ij}$  とし、このモデル間距離  $Dist_{ij}$  が小さい順に動的システムの併合判定を行う。

### 3.2.2 情報量規準による併合判定

併合の判定基準としては,分節化の判定に用いた赤池情報量 規準を用いる.

$$AIC = -2\ln(L_{\text{obs}}) + 2\alpha k \tag{19}$$

動的システム  $D_i$  と  $D_j$  を併合するとき、動的システム  $D_i$  をもつ時区間が N 個、動的システム  $D_j$  をもつ時区間が M 個あるとする。それぞれの時区間に対して AIC を算出し、動的システム  $D_i$  と  $D_j$  を持つ時区間を一つに併合した場合の動的システム  $D_{ij}$  の AIC を算出する。そして併合前と併合後の AIC を比較して  $AIC(D_i) + AIC(D_j) > AIC(D_{ij})$  の場合に併合する。

## 4. 実 験

本章では、実際に測定した家電の電力値データに対して提案 した変動モデルの学習法と電力変動予測を行った結果を示す.

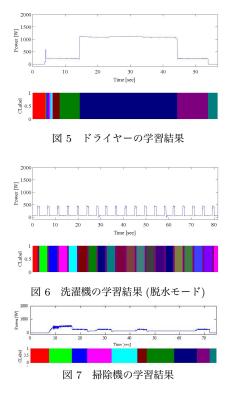
# 4.1 電力値データの計測

計測した電力データは、交流周期 60Hz の 1 周期ごとの有効電力とした。事前学習で用いる家電の計測データ以下図 4 に計測環境と計測した電力値データの例を示す。また、本実験では実際のセンサーネットワークを想定し、間欠的に送信される電力変動値データを擬似的に作成し予測への入力データとして用いた。0.5 秒間隔の電力値を取り出し、テストデータとした。

# **4.2 ISKF** のモデル推定結果

# a) 人為的なモード遷移を持つ家電に対する学習結果

人為的にモード遷移を行う家電としてドライヤーに対して 学習した結果を図5に示す。図の上段は学習に用いた電力計



測データ、下段は学習結果を示す。学習結果のエリアは分節化された時区間を表し、色は動的システムの種類を表している。このときのドライヤーのモード遷移は OFF モード→弱 HOT モード→中 HOT モード→ サHOT モード→ サHOT モード→ サHOT モード・ サイフ を切り替えて行った。学習結果に関して、最初の弱 HOT モードが余分に細分化されているが、これは OFF モードから弱 HOT モードへのモード遷移の瞬間発生する突入電流の部分の影響によるものと考えられる。また、中HOT モード→強 HOT モード→中HOT モードへのモード遷移が一つのクラスタとして分節化されているが、図5の1段目より、モード遷移時の電力変動が微笑であったためと考えられる。

#### b) 周期的な自動モード遷移を持つ家電に対する学習結果

自動的に周期的なモードを行う家電として、洗濯機に対して 学習した結果を図6に示す。洗濯機は、洗濯槽を回転させる 回転モードと回転を止めている停止モード、また逆向きの回転 モードと遷移すると考えられる。学習結果より、これらの2つ のモードが分類されているものの停止モードが複数の動的シス テムとして学習されていることがわかる。これは停止モードに 遷移するときの制動時に発生する逆起電力の影響などによるも のと考えられる。

c) 非周期的な自動モード遷移を持つ家電に対する学習結果環境フィードバックにより自動的なモード遷移を行う「知的な」家電として、掃除機を学習した結果を図 a) に示す。このとき掃除機は OFF モード→強パワーモード→エコ自動モード(22 秒から 75 秒) → OFF モードと人為的に切り替えを行った。エコ自動モードとは掃除機内部に内蔵されたセンサによって吸引口が接地している床の種類や接地しているかどうかを判断し

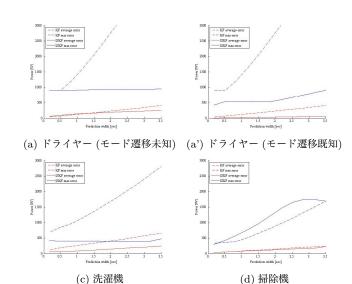


図8 電力変動予測の最大誤差,平均誤差

てに設置して吸引力を制御するモードであり、内部的には自動的なモード遷移を繰り返しているものと考えられる。この結果より、ゆーざによる人為的なモード切り替えだけでなく、エコ自動モードにおける内部の自動的なモード遷移もうまく学習されていることがわかる。

# 4.3 ISKF による電力変動予測結果

この章では、学習した電力変動モデルを用いて間欠的な電力データに対して電力変動予測を行いった結果を Kalman filter で予測した場合と比較する.

予測結果の平均誤差と最大誤差を比較したグラフを図8に示す。図の横軸は何秒後を予測したかを表す予測時間幅(秒),縦軸は平均誤差と最大誤差(W)を表している。破線(KF)がKalman Filterの結果,実践(ISKF)が提案手法の結果である。各グラフはそれぞれ前節の学習結果を用いて電力変動予測を行った場合の結果です。

# a) 人為的なモード遷移を持つ家電に対する予測結果

図 8(a) のドライヤーの予測誤差では、予測時間幅が 0.1 秒から 0.5 秒のときは 平均誤差、最大誤差共に Kalman filter と提案手法で大きな差はない。しかし、予測時間幅が 0.5 秒以上になると Kalman filter による最大誤差が急峻に増加にしたのに対し、ISKF では 900W 付近でほぼ一定の値を保っていることがわかる。

図 9(a) に予測時間幅 1 秒の場合の予測結果の例を示す。このグラフより,電力が大きく変動したときに Kalman Filter でオーバーシュートしているが,提案手法ではオーバーシュートが低く抑えられていることがわかる。一方で,ドライヤーのように人為的な操作によってモード遷移を行う家電の場合,モード遷移のタイミングに規則性がなく予測が難しく,間違えて遷移したと判断されていることがわかる。

そこで、将来的にネットワーク対応家電が普及し、人為的な操作のによるモード遷移のタイミングをシステムに通知できる場合を想定し、動作モードの遷移タイミングが既知であると仮定した場合の結果を図 9(a')、その時の誤差を 8(a') に示す、遷

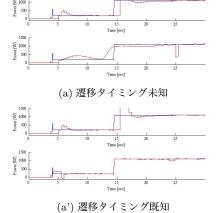


図 9 ドライヤーの電力変動予測結果 (予測時間幅 1 秒) 上段:Kalman Filter, 下段:提案手法 (ISKF)

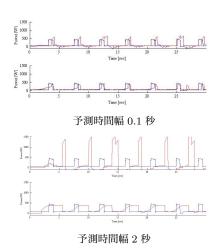


図 10 洗濯機の電力変動予測結果 (上段:Kalman filter, 下段:提案 手法 (ISKF))

移タイミングが未知の結果に比べて、平均誤差と最大誤差がさらに抑えられていることがわかる。特に、平均誤差はほとんど50W程度の値から変化しない結果となった。

b) 周期的な自動モード遷移を持つ家電に対する予測誤差 前節の b) に示した洗濯機の学習結果を用いて電力変動予測 を行った結果を図8(b)に示す. 予測時間幅を3.5秒まで大きく したとき、平均予測誤差に関して、Kalman filter では 550W 程度まで変動するのに対し、提案手法(ISKF)では 250W 程 度と半分以下の誤差となっていることが確認できる。また、最 大誤差に関しても Kalman filter は 3000W まで増加する対し て、提案手法では500Wと6分の1以下の誤差に収まってい ることがわかる. この結果から Kalman filter に対し提案手法 では予測時間幅が大きくなっても特に最大誤差が低く抑えられ るということがわかった。図 10 に洗濯機の電力変動に対して 予測時間幅 0.1 秒と 2 秒の場合の予測結果を示す。この結果よ り、予測時間幅が大きくなるとオーバーシュートは抑えられる ものの、モード遷移が遅れて予測されていることがわかる。こ れは今回提案した電力変動予測では予測時間幅内に一回以下の モード遷移が起きることを仮定しているためであり、二回以上 のモード遷移が起きる場合にこのようなずれが生じてしまうためであると考えられ、今後二回以上のモード遷移に対応させる必要がある.

c) 非周期的な自動モード遷移を持つ家電に対する予測誤差 前節のc)に示した掃除機の学習結果を用いて電力変動予測 を行った結果を図8(c)に示す.

平均誤差に関しては、わずかに提案手法のほうが小さくなっているが、最大誤差に関しては Kalman Filter のほうが小さいという結果となった。これは、エコ自動モードにおいて、不規則、かつ、頻繁におきる自動的な動作モード遷移を予測することができず、モード遷移の予測ミスが頻発しているためであると考えられる。

# 5. ま と め

本研究は、複数の動作モードを持ちそれらを切り替えながら動作する家電の電力消費パターンを、複数の Kalman Filter の切り替えによってモデル化する Interval-based Kalman Filters (ISKF) を提案し、情報量基準に基づく ISKF の学習法と、学習した ISKF を用いた電力変動予測法を示した。また、実験ではドライヤー、洗濯機、掃除機についてモデル推定と電力変動予測実験を行い、提案手法の有効性を示した。

提案手法では、家電の機能や操作モードとして、要に提示されていないような、家電内部の自律的な制御にともなうモード 遷移のモデルを学習することができ、規則的なモード遷移をするような家電に対しては精度よく電力変動の予測が可能であることがわかった。一方で、環境フィードバックなどによる不規則なモード遷移をおこなう家電では、モード遷移の予測が外れるため、推定精度も悪くなることがわかった。今後、このような問題に対して、過去の電力消費パターンや他のセンサ情報などからモード遷移の予兆を検出し、モードの予測に用いることを検討する予定である。また、電力変動予測だけでなく、家電の状態推定や故障診断など他の用途への拡張を検討している。

謝辞 本研究の一部は、科学研究費補助金若手研究(B) (23700169) の助成をうけたものである。

# 文 献

- [1] 松山隆司: "エネルギーの情報化とは-背景、目的、基本アイディア、実現手法-",情報処理学会誌, vol.51 No.8, pp.926-933, 2010.8
- [2] Takekazu KATO, Hyun Sang Cho, Dongwook Lee, Tetsuo Toyomura, and Tatsuya Yamazaki. Appliance Recognition from Electric Current Signals for Information-Energy Integrated Network in Home Environments. International Journal of Assistive Robotics and Systems (IJARS), Vol. 10, No. 4, pp. 51–60, (2009).
- [3] Kalman, Rudolph Emil. A New Approach to Linear Filtering and Prediction Problems. Transactions of the ASME– Journal of Basic Engineering, vol. 82, Series D, pp. 35–45, 1960.
- [4] Yee Leung, Jiang-She Zhang, Zong-Ben Xu, Clustering by Scale-Space Filtering, IEEE TRANSACTIONS ON PAT-TERN ANALYSIS AND MACHINE INTELLIGENCE, 22, 12, 2000, 12.
- [5] 山口 健太郎, 特集:モデル 統計学におけるモデル: 情報量基準の観点から, 科学哲学科学史研究, 2008, http://hdl.handle.net/2433/56989