目標達成型HEMSのための在室予測と環境依存型家電の需要度の導出

市川 昌宏[1] 向井 政貴[1] 安積 卓也[2] 西尾 信彦[2]

概要：近年の省電力化への要求の高まりから，家庭内でのエネルギーの需要と供給を管理するHEMSが注目されている．我々は，特にユーザが省電力目標を達成するためのアドバイスを提示できるHEMS（目標達成型HEMS）の構築を目標としている．今回，目標達成型HEMSを実現するための構成要素である需要度の導出と在室予測について述べる．在室予測では，パラメトリックベイズ法を用いてn人m部屋の場合の家庭の生活パターンモデルを抽出する．さらに，パラメトリックベイズ法によって抽出された各々の生活パターンモデルとリアルタイムに観測された値を用いて，24時間先までの各部屋の在室予測を行う．評価では，抽出した生活パターンモデルの妥当性と2人2部屋における在室予測精度の評価を行なった．その結果，モデルの妥当性は，2人2部屋の場合において76．8%，片方の部屋に着目した場合は平均88．85%となった．在室予測では，2人2部屋の場合において平均75．2%，片方の部屋に着目した場合は平均81．8%となり，一定の評価を得た．．需要度の導出では，ユーザが家電に対して感じる需要の数値化を行う．需要を数値化する際に，ユーザに手動入力してもらうことはユーザに負担を強いることになるため，ユーザによる入力が不要であることが望ましい．また，ユーザによって嗜好が異なるため，ユーザに応じた需要度の導出が必要となる．本論文では，ユーザの家庭に設置した環境センサや電力センサの情報から，指数分布の確率密度関数を用いて自動的にユーザに応じた需要度を導出する手法を提案する．その結果，導出した需要度から推定した行動と実際の行動は約69 %で一致し，一定の評価を得た．

Masahiro Ichikawa[1] Masaki Mukai[1] Takuya Azumi[2] Nobuhko Nishio[2]

1. はじめに

経済産業省資源エネルギー庁によると[5]，オフィスや家庭などの民生部門のエネルギー消費量は2010年度と，1980年度や1990年度とを比較すると大きく増加しており，エネルギー消費量全体の約33 %を占める民生部門におけるエネルギーの削減が求められる．そこで，企業や研究機関ではさまざまな省電力化の方策を講じている．

近年では，建物で使われるエネルギーの需要と供給を管理し，効率的に運用する技術としてEMS(Energy Management System)が注目されている．EMSでは，スマートメータや環境情報を取得する環境センサを使い，各機器の消費電力量を計測・表示することでユーザは省エネ意識を高めることができる．

我々はEMSの中でも特に，住宅一戸のエネルギーを管理するHEMS（Home Energy Management System）に注目している．さらに，HEMSのひとつとして，我々はユーザの目標使用電力以内で生活できるようにアドバイスする機能を持ったHEMSの構築を目指している．このHEMSを構築するためには，電力需要予測やユーザに適したアドバイスの生成のような解決しなければならない課題が複数ある．本論文ではそれらの課題の中からユーザがどの部屋に居るかという在室予測と，家電に対してユーザが感じる需要の推定を扱う．需要を数値として表したものを需要度と定義する．在室予測と需要度の2つを導出することが出来れば，目標達成型HEMSに必要な家庭の使用電力の予測も可能と考えられる．さらに，需要度を導出することで，夏場の猛暑日にエアコンを使用できるように，設定温度を

1 立命館大学大学院 理工学研究科
Graduate School of Science and Engineering, Ritsumeikan University
2 立命館大学 情報理工学部
College of Information Science and Engineering, Ritsumeikan University

普段から高めに設定するといった，できるだけユーザに負担をかけない省エネアドバイスが可能となる．

2. 目的とする HEMS

HEMS にはユーザが十分な節電をしながら生活できる行動を自動的にアドバイスする機能があることが望ましい．我々が最終的に目的としているのは，ユーザが目標とする消費電力以内で生活できるようにアドバイスできる目標達成型 HEMS の構築である．

目標達成型 HEMS を構築するためには，複数の構成要素が必要である．以下に各構成要素について述べる．

2.1 目標達成型アドバイス機能付き HEMS の構成要素

目標達成型アドバイス機能付きの HEMS の構成要素を列挙し，個々の役割について述べる．

環境のセンシング

家庭ごとに異なる電力の使用傾向を把握するためには，家庭内のさまざまな環境情報を計測，蓄積する必要がある．

使用電力量予測

電力の使用量は常にある程度一定というわけではなく，生活パターンによって変化する．したがって，一定期間で指定された電力量以内で生活するためには，生活パターンに応じた電力需要の予測が必要である．

行動認識

消費電力の大きさはユーザの生活と密接に関係している．そのため，ユーザが在宅しているか，どの部屋にいるか，どのような行動をしているか，などの各々の状況の違いを把握することによって状況に応じた HEMS が構築できる．

家電の需要の推定

最適なアドバイスを生成するには，家電が消費する電力と家電に対する需要のバランスを考えなくてはならない．消費電力と需要のバランスをとるためには，消費電力と需要をシステムが扱える形で表さなければならない．消費電力はもともと数値として取得できるため，そのまま扱える．しかし，需要は明らかな数値として現れていないため，システムが扱える形で推定する必要がある．

生活プランの生成

省電力化を達成するアドバイスを生成するためには，一定期間で許容される使用電力量の上限を定める必要がある．使用電力の予測から，ユーザにとって負担が少ない省電力な生活のプランをたてなければならない．

アドバイス生成

家電の消費電力，需要，及び電力の需要予測を考慮して，目標とする消費電力量以下で生活できるように家電の使い方についてのアドバイスを生成する．

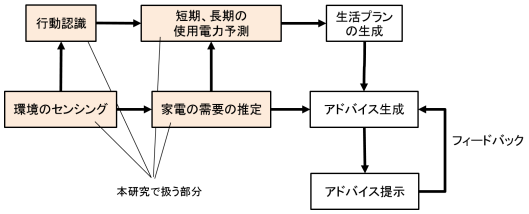

図 1 各構成要素の関係

アドバイスの提示

自動的に生成したアドバイスは，必ずしもユーザが許容し得るものとは限らない．なので，ユーザにはアドバイスに対する選択権や拒否権を与える必要がある．

2.2 要素間の関係

列挙した構成要素間の関係について，**図 1** を用いて説明する．まず，環境のセンシングによって，電力や環境情報が得られる．需要推定は，得られた電力や環境情報から環境に対する家電の使われ方を分析することで行う．同様に，人の動きや家電の使い方を分析することで，人の生活パターンの認識が行える．行動認識の結果からユーザの行動パターンを把握することで，詳細な電力需要予測を行う．さらに，電力の需要予測から一定期間で許容される使用電力量を生活プランとして生成する．需要推定と，生活プランの結果から，任意の電力以内で生活できるようなアドバイスが生成され，そのアドバイスに対する是非をユーザに問いつつ省エネが達成される．

2.3 本研究で扱う家電

我々は，家電を 2 種類に大別している．すなわち，エアコンのような温度や湿度といった環境に依存して利用する環境依存型の家電と，テレビのように時間帯に依存して利用する時間依存型家電である．このうち，環境に影響を与える環境依存型家電の方が消費電力が大きい傾向にあり，節電の観点で重要度が大きいと考えたため，本研究では環境依存型家電を扱う．

3. 関連研究

本研究で扱う HEMS の構成要素のひとつである需要の推定と在室予測に関連する研究と，それらの研究における問題点を述べる．そのうえで，本研究が扱う課題についてまとめる．

3.1 需要推定の関連研究

ユーザの需要を数値化する研究は数多く行われている [3][7][2][4]．これらの研究は，ユーザに需要に関するアンケートに答えてもらうことによって，需要の数値化を試みている．しかし，詳細に需要を数値化しようとすると，いくつもの環境下でアンケートに答えてもらったり，アン

ケート項目を多くする必要があり，ユーザへ負担を強いることになってしまう．複数ユーザに対してアンケートを実施することで，一人ひとりの負担を軽減することもできるが，一方で個人の嗜好が失われてしまうという問題がある．

湯浅ら [9] はユーザが設定した省エネ制約に従ってできるだけ快適性を損なわずに，節電するためのオンデマンド型電力制御システムを提案している．このシステムでは，ユーザが電力を必要としたときに，各機器から電力マネージャに対して電力のリクエストが送られる．電力マネージャは電力要求の優先度と設定された省エネ制約を元にして配給する電力量を自動決定している．この研究では，カテゴリごとに既定の優先度という形でユーザの快適性を考慮しつつ省エネを達成しようとしている．この優先度は電力調整可能な家電のカテゴリ，待機可能な家電のカテゴリ，一時停止可能な家電のカテゴリの 3 つに分けて事前に設定されている．そのため，ユーザに特化した快適性までは考慮されていない．

3.2 在室予測に関する関連研究

人の位置を特定するための手法として，デッドレコニングの研究 [6] が挙げられる．デッドレコニングを用いるためにはユーザが特定の端末を保持している必要がある．しかし，本研究の環境では家の中での生活を想定しているため，ユーザが常時，特定の端末を持っているという前提は難しい．そのため，本研究ではユーザが一切デバイスを持たないという状況での在室予測を行う必要があると考える．そこで，村尾ら [8] は照度センサを用いてユーザの移動経路の判定を行なっている．過去 W 秒までに得られた照度センサの ID 列と各移動軌跡の正解データを DP マッチングを応用した手法によりマッチングさせることで，移動情報を検出している．しかし，村尾らの手法では直近の移動に関しては把握することができるが，数時間・数十時間先にユーザがどの部屋に居るかを予測することはできない．

一方，富永らは [1] 多項分布とベルヌーイ分布を用いて各家庭の外出行動パターンをモデル化し，未来の外出を予測する研究を行なっている．この手法を適用することで，ある部屋における人の有無のパターンのモデル化と，未来における人の有無の予測を行うことができる．しかし，富永らの研究では,1 人 1 部屋 (1 つの家) におけるモデルを構築しているにすぎず，人の数，部屋の数が増えると対応できないという問題がある．

4. 需要度導出のための予備実験

4.1 生活センシング

被験者の自宅 1 戸に電力タップと環境センサを設置し，日常生活中のデータを観測した．実験対象家庭の間取りと電力タップ，環境センサの設置場所を図 2 に示す．対象の家庭は学生一人，主婦一人の 2 人暮らしである．この家庭

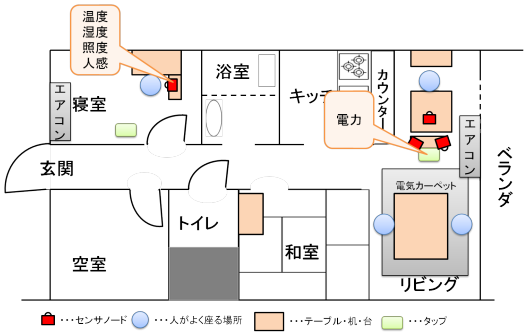

図 2 実験環境

表 1 計測データの詳細

センサの種類	計測周期	単位	分解能
温度	1 分	° C	0.1
湿度	1 分	%	0.1
照度	5 秒	lux	1
人感	1 秒	true/false	-
電力	5 秒	W	1

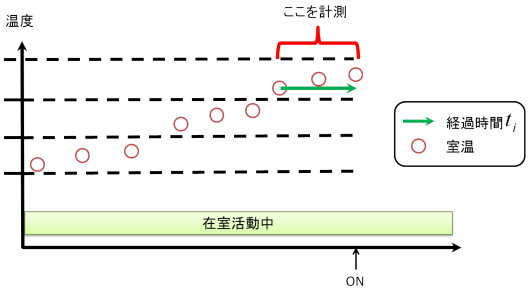

図 3 経過時間の計測方法

において，電力タップを家電機器別に接続し，一定時間毎に電力を測定した．さらに，環境センサを学生の部屋とリビングにそれぞれ設置した．環境センサが計測できるデータは，温度，湿度，照度，人感の 4 種類であり，それぞれの詳細と電力タップで計測する電力についての詳細を表 1 に示す．計測期間は 2011 年の 6 月頃から約 1 年 6 ヶ月間である．

4.2 センシング実験からの考察

環境依存型家電であるエアコンについて述べる．予備実験の結果，エアコンを起動させる要因として，温度，湿度の他にエアコン起動までの経過時間を考えた．各環境においてのエアコン起動までの経過時間の計測方法を図 3 とともに説明する．説明を簡単にするために温度別の経過時間の計測方法について述べる．ユーザの在室期間中において，ユーザがエアコンを起動したときの温度（1 度単位）に達したときの時間からエアコンを起動したときまでの時間を経過時間とする．湿度別の場合は湿度 10%ごとで同様のことを行う．結果を図 4，図 5 に示す．結果から，温度や湿度別に経過時間を計測したとき，その分布が指数分布に従うと仮定する．

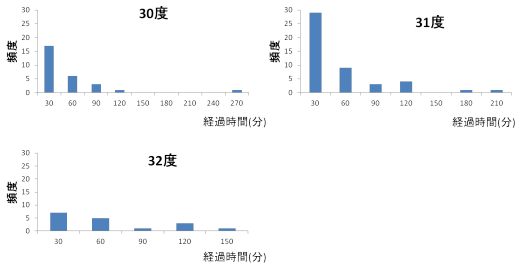

図 4　温度別経過時間の分布

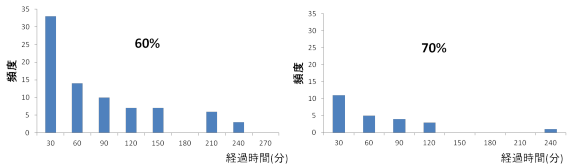

図 5　湿度別経過時間の分布

5.　需要度の導出

ある時刻の温度と湿度の組み合わせをある時刻の**環境**と定義する．さらに，ユーザが現在の環境で感じる家電機器の需要を**需要度**と定義する．

5.1　直近需要度

直近需要度は，0〜1 の値で表され，値が高いほど家電の需要が高いことを意味する．本節では，この直近需要度の導出方法について提案する．

5.1.1　需要度の算出

直近需要度は需要度を求める時刻の直近の環境のみから需要度を求める手法である．この直近の環境の継続時間を指数分布に与えて得られる確率分布を直近需要度とする．直近需要度は式 1 で与えられる．指数分布のパラメータ λ はユーザが入室してからエアコンを起動するまでの経過時間を意味する．λ は温度と湿度によって変化すると考えられるため，環境ごとに λ を推定しなければならない．

$$demand = 1 - exp(-\lambda t) \tag{1}$$

5.1.2　パラメータ λ の推定

指数分布は式 2 で表される確率密度関数に従い，単位時間当たりに事象が発生する平均回数 λ がパラメータとなる．

$$f(x;\lambda) = \begin{cases} \lambda exp(-\lambda x) & (x \geq 0) \\ 0 & (x < 0) \end{cases} \tag{2}$$

今回の場合，事象とはエアコンを起動することを指す．環境によって需要は変化するので，それぞれの環境について

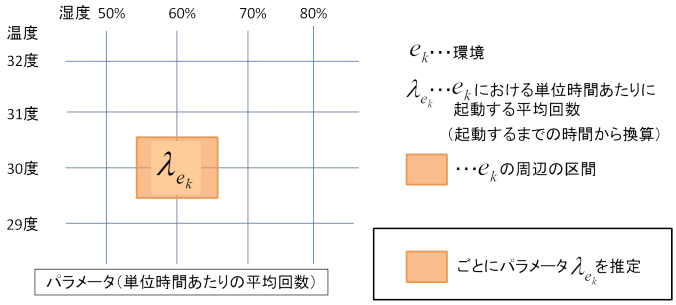

図 6　特定環境における分布のパラメータ

適したパラメータ λ を推定することが必要となる．ここで，温度や湿度のような連続値のままでは扱いにくいので，ある程度の粒度で離散化し，離散化した環境毎にパラメータ λ の推定を行う（図 6）．パラメータ λ の推測には最尤推定法を用いる．最尤推定法は観測値を任意の尤度関数に与えることで，パラメータ λ の値を推測する手法である．尤度関数の結果として得られる尤度が最も大きくなるようなパラメータ λ を最も真の分布を表すパラメータとして選択する．今回用いる尤度関数を式 3 に示す．

$$L(\lambda) = \prod_{i=1}^{n} (\lambda exp(-\lambda x_i))^{\delta_i} (exp(-\lambda x_i))^{1-\delta_i} \tag{3}$$

$$\delta = \begin{cases} 1 & (\text{起動}) \\ 0 & (\text{非起動}) \end{cases}$$

5.1.3　パラメータ曲面の近似

観測されたことのない未知の環境に対してもパラメータ λ を推定する必要がある．そこで、既に推定されている環境のパラメータ λ の値から未知の環境のパラメータを推定する．未知の環境におけるパラメータは既知のパラメータに対する近似曲面を生成することで推測する．近似には多項式による最小二乗法を用いる．

5.2　累積需要度

累積需要度では直近の環境だけでなく、環境の変化を考慮した需要度の導出手法について述べる．実際は環境として温度と湿度を考慮するが，説明を簡単にするために環境を温度のみとして考える．

5.2.1　累積需要度の導出

累積需要度の導出方法について図 7 に示す．まず，赤線で示される時点の需要度を求めたいとする．累積需要度は入室時から赤線の時点までの，ある温度で継続して経過した時間（緑矢印）ごと指数分布の累積確率 (式 1) を算出し，それらの合計を累積需要度とする．累積需要度はふたつのパラメータ α と β によって決定される．α と β の推測方法については以下で述べる．

5.2.2　パラメータ α の推定

まず前提として，温度が高いほどエアコンを必要とし，低いほど必要としないとする．さらに，エアコンを全く必

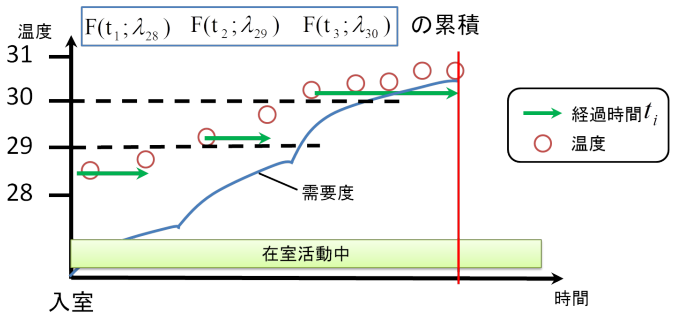

図 7 累積需要度の導出

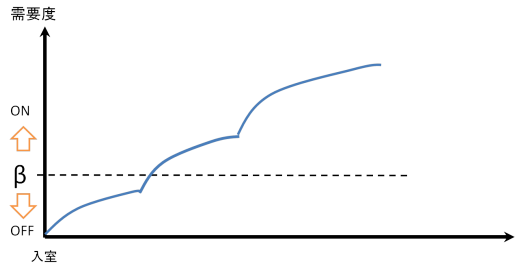

図 9 パラメータ β

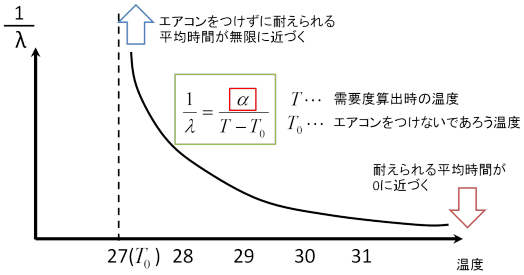

図 8 パラメータ α

要としなくなる温度 T_0 が存在するとする．すると，指数分布のパラメータ λ と環境との関係は図 8 のように表される．これは，$T = T_0$ と $1/\lambda = 0$ を漸近線とした関数である．この関数は $1/\lambda = \alpha/(T - T_0)$ で表される．つまり，指数分布のパラメータ λ を推定することは，α を推定することと同義である．需要度の推測結果が最も良くなるような α を求めたいので，α を変化させながら推測結果の精度を測り，推測結果が最も良くなる α を探索する．推測結果の精度を測る指標として，一致率を導入する．一致率の詳細は 5.2.4 節で述べる．直近需要度では需要度が 0 から 1 の値で表わされるので，0.5 を閾値として需要度からユーザの行動を推測することができる．しかし，累積需要度は後述する性質上 1 以上の値をとることもあるため，一概にいくら以上の値であればユーザがエアコンをつけるという推測ができない．そこで，ユーザの行動を需要度から推測するためのパラメータ β を導入し，需要度が β 以上であれば，エアコンをつけ，β 未満であればつけないという推測をすることにする．

5.2.3 パラメータ β の推定

β は需要度がいくら以上のときにユーザの行動は家電をつけるのかを判定するための閾値である．パラメータ β のイメージを図 9 に示す．需要度が β 以上であればユーザが家電を必要としていると推測し，逆に β 未満であれば必要としていないと推測する．β も α と同様に一致率が最も高くなるように選択する．

5.2.4 一致率

一致率は需要度から推測したユーザの行動と実際のユーザの行動が一致する割合を意味する．一致率は式 4 で導かれる．

$$\text{一致率} = \frac{C_{OFF,OFF} + C_{ON,ON}}{C_{ON,ON} + C_{OFF,ON} + C_{OFF,OFF} + C_{ON,ON}} \tag{4}$$

$C_{ON,OFF}$ ･･･期待の行動が ON で実際の行動がOFF である数

6. 在室予測

在室予測は，生活パターンのモデル化と作成したモデルを用いた予測の 2 段階に分かれる．本節では，それぞれ順を追って説明する．

6.1 生活パターンのモデル化

3 章で述べたように，富永らは [1] の研究は，1 人 1 部屋 (1 つの家) における外出モデルを構築しているにすぎず, 一般の家庭において，基本的に人の数, 部屋の数は複数であり，それぞれの部屋における人の有無には相関関係がある．したがって，本研究では,1 人 1 部屋に限った生活パターンのモデルを作成するのではなく，n 人 m 部屋を考慮したモデルを作成する必要がある．以降，n 人 m 部屋の時に取りうる在室パターンを記号 C として式中に表わす．

6.1.1 m 部屋における一日の人の存在の有無のモデル

m 部屋における人の存在の有無は C 個のパターンに分けることができる．また，これら C 個のパターンはそれぞれ同時に発生することはない．このことから，m 部屋におけるある時刻の人の存在の有無は式 5 のような c=1~C の多項分布の確率変数に従うことが分かる．しかし，式 5 はあくまで，ある時刻における m 部屋，C 個のパターンの出現確率を表したモデルである．そこで，各時刻において m 部屋，C 個のパターンの出現確率を表したモデルに拡張する必要がある．そこで，拡張した式を式 6 に記す．ここで，変数 T はある期間において観測されたデータの数を表しており，ある時刻での C 個のパターンの出現確率を t=1 から T まで掛け合わせることにより，m 部屋における 1 日の人の存在パターンが生じる確率としている．

$$p(x|\theta) = \prod_{c=1}^{C} \theta_c^{x_c} \tag{5}$$

$$(x_c \in \{0,1\}, \sum_c x_c = 1)$$

$$(\sum_c \theta_c = 1, \quad \theta = \{\theta_1 ... \theta_C\}, \quad 0 \leq \theta \leq 1)$$

$$p(x|\theta) = \prod_{t=1}^{T} \prod_{c=1}^{C} \theta_c^{x_c} \tag{6}$$

$$(x_c \in \{0,1\}, \sum_c x_c = 1, \sum_c \theta_c = 1)$$

$$(\theta = \{\theta_1 ... \theta_C\}, \quad 0 \leq \theta \leq 1)$$

6.1.2 潜在的カテゴリを考慮した m 部屋における一日の人の存在の有無のモデル

「人の生活パターンは，一日中遊んでいる日」,「リビングでずっとテレビを見ている日」,「午前中に授業で学校に行き，午後は自室で作業をしている日」といったように様々なカテゴリがある．これらのカテゴリを本研究では潜在的カテゴリと呼び，$Z_{n,k} ... \left\{ z_{n,k} | z_{n,k} = 0,1, \sum_k z_{n,k} = 1 \right\}$ で表す．ここで，$n = 1...N$ はある 1 日を表す変数であり，$k = 1...K$ はある潜在的カテゴリを表す変数である．$\{z_{n,k} = 0,1\}$ はある日の潜在カテゴリが k でない場合は 0 を, k の場合は 1 を示すことを表している．このような z_n をパラメータ $\pi(\pi_1 ... \pi_k)$ の多項分布を用いて $z_n \sim M(z_n|\pi)$ と表すことができる. ここで，パラメータ π はある日の潜在的カテゴリが k となる確率を表すパラメータであるまた，各潜在カテゴリにおける潜在パターン c=1 C がそれぞれ出現する確率を表すパラメータは $\theta_k = (\theta_{k,1} ... \theta_{k,T})^T$ で表すことができ，上記より，潜在的カテゴリを考慮した 2 部屋における一日の人の存在の有無のモデルは式 7 で表すことができる．

$$p(x_n|Z, \Theta) = \prod_{k=1}^{K} \prod_{t=1}^{T} \prod_{c=1}^{C} [\theta_{k,t,c}^{x_{k,t,c}}]^{Z_{n,k}} \tag{7}$$

$$(\theta_{k,t} = (\theta_{k,t,1} ... \theta_{k,t,C})^T, \theta_k = (\theta_{k,1} ... \theta_{k,T})^T)$$

$$(\Theta = (\theta_1 ... \theta_k), 0 \leq \theta \leq 1))$$

6.1.3 パラメトリックベイズ法によるモデル抽出

上述したデートに行く日，家でずっとテレビを見ている日などの生活パターンは家庭によって様々であり，前項の π や θ といったパラメータを事前に決定することができない．したがって，本研究ではそれらのパラメータに事前分布を設定し，学習を行うパラメトリックベイス法を用いて，生活パターンの抽出を行う．ここで，上述した潜在カテゴリのパラメータ π と各時刻の 2 部屋における一日の人の存在の有無のパラメータ θ は，どちらも多項分布によりモデル化されている．したがって，これらのパラメータの事前分布として多項分布の共役事前分布であるディリクレ分布を用いる．また，パラメータ π の事前分布のパラメータ (ハイパーパラメータ) を α，パラメータ θ のハイパーパラメータを β とする．これより，各々のパラメータは式 8, 式 9 から生成される．

$$\pi \sim D(\pi|\alpha) \propto \prod_k \pi_k^{\alpha_k - 1} \tag{8}$$

$$\theta_{k,t} \sim D(\theta_{k,t}|\beta) \propto \prod_{c=1}^{C} \theta_c^{\beta_c - 1} \tag{9}$$

6.2 在室時間予測

ハイパーパラメータ α , β が決まるとパラメータ π,θ も決定する．このとき，パラメトリックベイズ法によって抽出されたモデルから，観測値であるユーザの生活パターン $x_1 : x_t$ が生起する度合いは式 10 によって表される．本式の $p(x_{1:T}|\alpha_{k,1:T,1} ... \alpha_{k,1:T,4})$ 部分はハイパーパラメータ α が決まったときにカテゴリ k の分布から，観測値 $x_1 : x_t$ が生起する度合いを表しており，π_k はそれぞれのカテゴリが出現する度合いを示している．そのため，これらを乗算し全てのカテゴリに対して加算することで観測値 $x_1 : x_t$ がパラメトリックベイズ法によって抽出された各々のモデルから生起する度合いを求めることができる．

$$p(x_{1:T}|\alpha, \beta) = \sum_k \pi_k p(x_{1:T}|\alpha_{k,1:T,1} ... \alpha_{k,1:T,C}) \tag{10}$$

ここで右辺の $p(x_{1:T}|\alpha_{k,1:T,1} ... \alpha_{k,1:T,C})$ は式 11 のように展開することができる．ここで，Γ はガンマ関数である．

$$p(x_{1:T}|\alpha_{k,1:T,1} ... \alpha_{k,1:T,C}) \tag{11}$$

$$= \prod_{t=1}^{T} \frac{1}{Z} \int p(x_t|\theta) D(\theta_c|\alpha_{c,t,1} ... \alpha_{c,t,C}) d\theta$$

$$= \frac{\Gamma\left(\sum_{c=1}^{C} \beta_c\right)}{\prod_{c=1}^{C} \Gamma(\beta_c)} \times \frac{\prod_{c=1}^{C} \Gamma(x_c + \beta_c)}{\Gamma\left(\sum_{c=1}^{C} (x_c + \beta_c)\right)}$$

$$(\frac{1}{Z} = \frac{\Gamma\left(\sum_{c=1}^{C} \beta_c\right)}{\prod_{c=1}^{C} \Gamma(\beta_c)})$$

このとき，ある日の当日に観測されたデータを $x_1 : x_{t_p}$ としたとき，ある日 n がカテゴリ k に属する確率は式 12 で表すことができる. 式 12 で算出した γ_k を基に**図 6.2** のように各カテゴリごとに加重平均をとり，次の日の生活パターンを算出する．さらに，時刻 t 毎に 4 つのパターンの生起確率を比べ，最も生起確率が高いパターンを時刻 t の予測値とする．

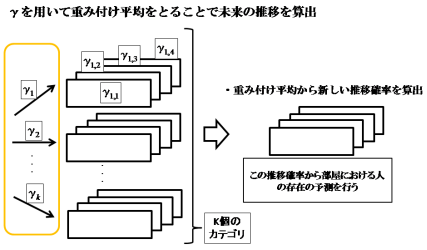

図 10　予測値の出し方

$$\gamma_k = \frac{p\left(x_{1:t_p}, z_k = 1|\alpha\right)}{\sum_c p\left(x_{1:t_p}, z_c = 1|\alpha\right)} \tag{12}$$

7.　評価

7.1　需要度の評価に用いるセンシングデータ

評価に用いるのは 4.1 節で述べた家庭で観測したデータである．分布パラメータを推定するためにトレーニングデータと，テストデータを用意する．トレーニングデータとテストデータの間で環境の偏りが生じないようにするために，トレーニングデータとテストデータを偶数日のデータと奇数日のデータにして評価を行う．

7.2　需要度から推測した行動と実際の行動との比較

需要度から推測した行動と実際の行動がどの程度一致しているかを評価する．行動とは，ユーザの一回の滞在でエアコンを起動するか否かである．評価では，一回の滞在を 1 ケースとし，1 ケースごとに需要度に基いて行動を推測し，実際の行動と比較する．比較は，ユーザがエアコンを起動したとき，もしくはエアコンを起動せずに退室したときの行動に対して行う．エアコンを起動したときの行動を”ON”，起動せずに退室したときを行動を”OFF”と呼ぶことにする．さらに，導出した需要度が 0.5 以上であれば行動を”ON”，0.5 未満であれば行動を”OFF”と推測する．このように需要度から推測された行動と実際の行動の一致性を評価する．

直近需要度の評価を図 11，累積需要度の評価を図 12 に示す．それぞれの図中に記されている ON-OFF や OFF-OFF などのラベルは，左側が需要度から推測した行動，右側が実際の行動を意味している．したがって，ON-OFF は推測した行動が ON であるが，実際の行動は OFF であり，推測が誤っていることを意味する．一方，OFF-OFF は推測した行動と実際の行動が両方とも OFF であり，推測が正しいことを意味する．比較すると，累積需要度による推測の方が直近需要度により推測よりも若干精度が高い．

さらに，直近需要度から推測した行動と実際の行動との一致率を図 13，累積需要度から推測した行動と実際の行動との一致率を図 14 に示す．被験者である学生がエアコンを起動する可能性のある 28 度以上の温度帯において，直近

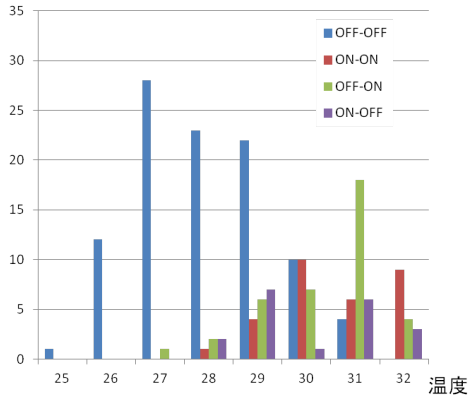

図 11　直近重要度による推測の結果

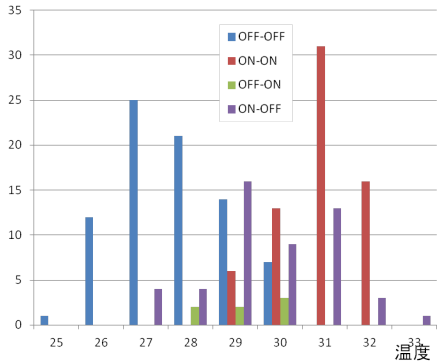

図 12　累積需要度による推測の結果

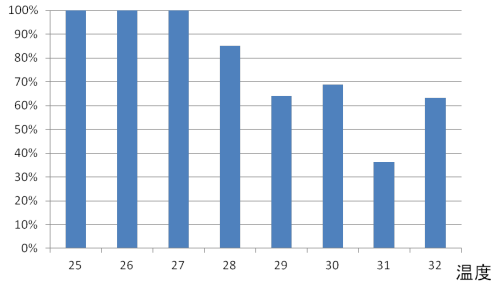

図 13　直近需要度の一致率

需要度の平均一致率は約 63 %であり，累積需要度の平均一致率は約 69 %であった．ここで，直近需要度の一致率と累積重要度の一致率の推移を比較する．直近需要度の一致率の推移は高低が交互に表れているが，累積需要度の一致率の推移は 29 度の一致率を最低として V 字に推移している．これは，29 度が，被験者がエアコンをつけるか悩む温度であり，最も需要の判断が難しいためと考えられる．V 字の推移は温度が低くなったり高くなったりすると需要の推測がしやすいという直感的な感覚と一致する．

7.3　生活パターンモデルの生成結果と評価

人の有無の予測を行うにあたり，まず初めに前章で述べた手法によりモデルを生成した．潜在的カテゴリ K に関しては，経験的に K=3 を採用した．**図 15** には，学習期間に

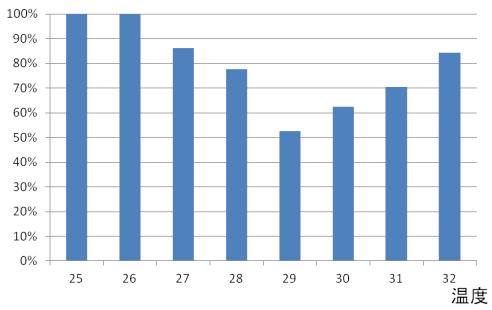

図 14　累積需要度の一致率

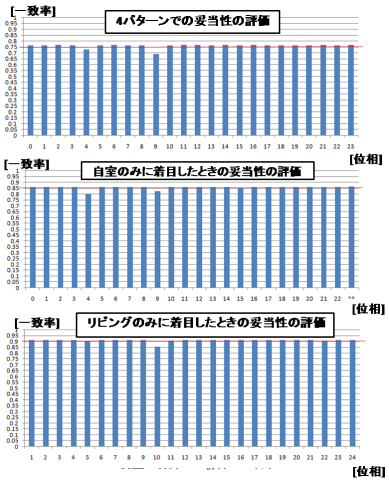

図 16　生活パターンモデルの妥当性

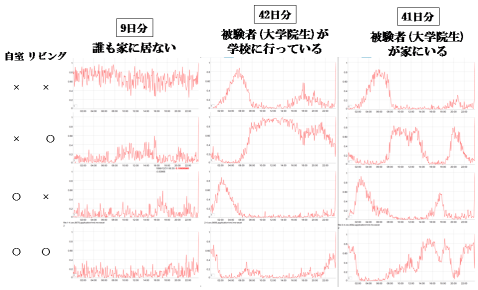

図 15　K=3 の時の生活パターンモデル

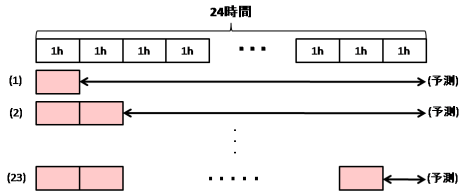

図 17　当日予測に用いる時間の分け方

2012 年 9 月 1 日 2012 年 11 月 30 日を用いて生成したモデルを記す．また，学習期間で生成したモデルが実際にどの程度，学習日を適切にモデル化できているかの妥当性を測定するため，生成したモデルと学習に用いた日それぞれの生活パターンを生成し, その一致率を評価した．評価結果を**図 16** に記す. ここで, 一致率は生成した 3 つのモデルの中で最も高いものをその日の一致率として採用した．その結果，モデルの妥当性は，2 人 2 部屋の場合において 76.8%，自室に着目した場合は 86．4%，リビングに着目した場合は 91.3%となった．

7.4　2 部屋における在室予測の評価

本節では 2 部屋における在室予測に関する評価方法と評価結果について述べる．ここで，在室予測に人が居るか居ないかという実データは，人感センサが反応しているか照度センサが一定以上の値を示している場合とした．さらに，データ取得感覚は 5 分とした．

7.4.1　評価期間と評価方法

2 部屋における在室予測を行う際の学習期間と評価する際の予測期間は, 学習期間「2012 年 9 月 1 日 ~2012 年 11 月 30 日」評価期間「2012 年 12 月 5 日 ~2012 年 12 月 17 日」である．ここで，本手法により，学習によって生成されるモデルは 1 日単位のモデルであるが，1 日という単位を設けることで，1 日を何時から何時の区切りにするかという問題が生じる．そこで，本研究の評価では「0:00:00~23:59:59」の区切り「1:00:00~23:59:59」の区切りといったように 1 時間ごとに 1 日の区切りを変え，全ての区切りで予測を行い評価する．(この区切りのことを以降では位相と呼ぶ) さらに，1 日のうち何時間を使って残りの時間を予測を行うかといった問題もある．そこで，本研究では**図 7.4.1** のように初めの 1 時間を用いて残りの 23 時間を予測する，初めの 2 時間を用いて残りの 22 時間を予測するといったように全ての場合に関して予測を行い，その平均値を位相別一致率とした．評価方法は，各時間ごとに予測値と実測値が同じであるかの一致率を求める．その際に，本手法において算出した 2 部屋における 4 つのパターンの一致率と，自室のみに着目した自室に人が居るか居ないかの 2 つのパターンの一致率，リビングのみに着目したリビングに人が居るか居ないかの 2 つのパターンの一致率の 3 つの一致率を算出した．

7.4.2　評価結果

図 18 は評価期間における位相別の一致率である．図を

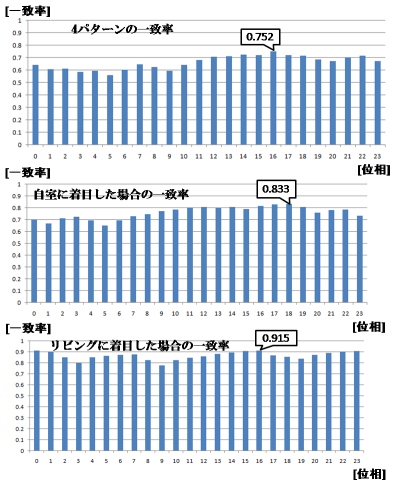

図 18　位相別一致率 (12 月 4 日 ∼12 月 17 日)

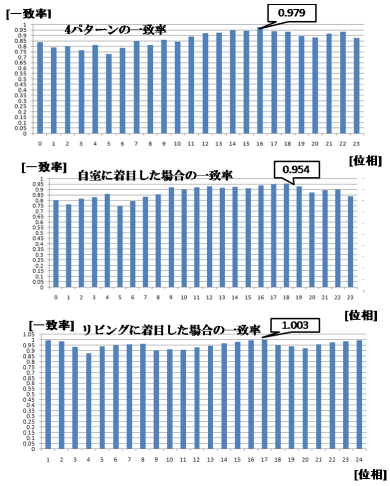

図 19　妥当性を考慮した予測結果 (位相別)

見ると，全ての場合において位相 16,17,18 で最も高い一致率を算出した．これは，図 15 より被験者宅の大部分を占める 2 つのカテゴリの差が 16 時 ∼18 時で最も顕著に現れるからだと考えられる．

次に，一致率を見ると 4 パターンの一致率は 75.2 %，自室は 83.3 %，リビングは 91.5 %が最大値となっている．ここで，リビングで最も良い値が出た理由としては，リビングにおける被験者宅の大部分を占める 2 つのカテゴリの人の存在確率の推移は，自室に比べると差が少ないためであると考えられる．しかし，リビングの人の存在確率の推移が 2 つのカテゴリで似ているのは，今回人が居るという判定に照度センサを使っているため，昼間はずっと人が居ると判定されてしまっているためであると考えられる．そのため，リビングに着目した際の一致率の高さに関しては一概に良かったと言い切ることはできない．

一方, 今回の予測は図 15 で記した生活パターンモデルを用いていることから, 図 16 で記した生活パターンモデルの妥当性以上の予測値が出るとは考えづらい．そこで, 図 16 で記した生活パターンモデルの妥当性の結果を 100 %と見なし, 評価したグラフを**図 19** に記す．図 19 から, 生活パターンモデルの妥当性の結果を 100 %と見なすと 4 パターンのとき, 自室のみ, リビングのみ全てにおいて最も良い位相のときには 95 %以上の一致率が出ていることが分かる．ここで, リビングにおける一致率が 100 %を上回っていることに関しては, たまたま学習時よりも一致率の高いデータで評価を行なったというだけだと考えられる．これらのことより，本手法における人の有無の評価に関しては一定の成果が出せたと考えられるが，今後精度を上げていくためには, より粒度の細かい生活パターンモデルを生成していく必要があると考えられる．

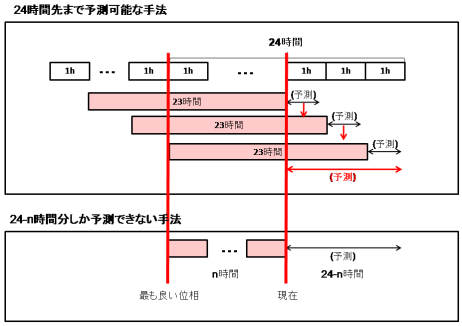

図 20　24 時間先まで人の有無の予測が可能な予測手法

7.5　24 時間先まで人の有無の予測が可能な予測手法とその評価

上記で述べた方法では, 当日の n 時間を用いて 24-n 時間を予測するため, 常に 24 時間先までの人の有無を予測することができない．そのため, 本節では 24 時間先まで人の有無の予測が可能な手法を提案しその評価を記す．24 時間先まで予測可能な手法は**図 7.5** のように, 従来の手法が現在から最適位相 (最適時間) までの n 時間を用いて残りの 24-n 時間を予測していたのに対し, 位相をずらしながら, 予測値を次の 1 時間の予測に用いることで 24 時間先までの予測を可能としている．この手法を用いて, 自室にのみ着目した場合の予測結果を**図 7.5** に記す．この図より, 本手法は従来手法に比べて約 4%予測精度が落ちることが分かる．また,24 時間先の予測結果は 59.4%となった．この精度は上記と同様に生活パターンモデルをより詳細に生成することで向上することでできると考える．しかし, 今回は潜在カテゴリ K が非常に小さかったため, 予測値を次の予測に使用するという本手法においても従来手法と同程度の予測精度が保てた可能性が考えられる．そこで, 今後は潜在カテゴリ K が大きいときの予測評価を行い,K の数によって従来手法と本手法を使い分けて予測していく必要があると考える．

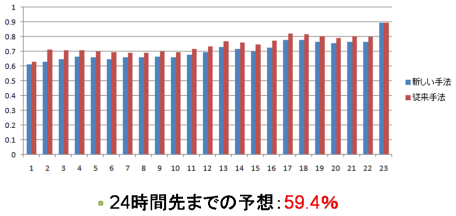

図 21 24 時間先まで予測可能な手法による評価結果

8. まとめと今後

本研究では，家庭に設置した環境情報を計測・蓄積できるセンサと家電ごとの消費電力を計測・蓄積できるスマートタップを用いて，手動での入力なしでユーザの環境依存型家電に対する需要を数値化する手法とパラメトリックベイズを用いた家庭内の在室予測手法について述べた．需要度に関しては，今後，温度・湿度・滞在時間以外の要因を見つけることで導出した需要度の精度向上を図る必要がある．さらに，時間依存型家電の需要度の導出も考えていく必要がある．在室予測に関しては，潜在カテゴリ K を動的に求めるため，生活パターンの抽出方法をノンパラメトリックベイズモデルに拡張し, 潜在カテゴリ K も観測データから推測できるようなモデルの構築を行う必要がある. さらに，今回は n 人 m 部屋のモデルを作成し,2 人 2 部屋の環境において評価を行なった. しかし, 実際に本モデルを 3 部屋以上の部屋の場合に当てはめると指数関数的に出現パターン (自室には人が居て, リビングには居ないなど) が増えてしまい, 非常に多くの観測データがないと学習することが困難となってしまう. そこで, 今後は隠れマルコフモデルなどを用いて各出現パターンに対して人が居る確率を算出するようなモデルを構築し, 複数の部屋へ対応していく必要がある.

参考文献

[1] Shoji Tominaga, Masamichi Shimosaka, Rui Fukui, and Tomomasa Sato. A unified framework for modeling and predicting going-out behavior. In *Proceedings of the 10th international conference on Pervasive Computing*, Pervasive'12, pp. 73–90, Berlin, Heidelberg, 2012. Springer-Verlag.

[2] Shinya Yamamoto, Naoya Kouyama, Keiichi Yasumoto, and Minoru Ito. Maximizing users comfort levels through user preference estimation in public smartspaces. In *PerCom Workshops*, pp. 572–577. IEEE, 2011.

[3] 岡村将誉, 三井浩康. ホームネットワークシステムを用いた消費電力抑制システムの提案. 全国大会講演論文集, Vol. 2011, No. 1, pp. 259–261, mar 2011.

[4] 久保新悟, 青木真吾, 中野雅之, 辻洋, 井上修紀, 三村英二. 快適性と身体部位の温冷感の構造方程式モデリング (＜特集＞日常生活行動コンピューティング). 知能と情報：日本知能情報ファジィ学会誌：journal of Japan Society for Fuzzy Theory and Intelligent Informatics, Vol. 20, No. 2, pp. 164–170, apr 2008.

[5] 資源エネルギー庁. 省エネ性能カタログ 2012 年夏版.

[6] 上坂大輔, 村松茂樹, 岩本健嗣, 横山浩之. 手に保持されたセンサを用いた歩行者向けデッドレコニング手法の提案. 情報処理学会論文誌, Vol. 52, No. 2, pp. 558–570, feb 2011.

[7] 上野剛, 中野幸夫. 居住者の選好を考慮した省エネルギー方策選択支援ツールの開発. エネルギー・資源 = Energy and resources, Vol. 32, No. 5, p. 319, sep 2011.

[8] 村尾和哉, 寺田努, 矢野愛, 松倉隆一. 人感センサを用いた住宅内人物移動推定におけるセンサ配置の最適化. 情報処理学会研究報告. MBL, [モバイルコンピューティングとユビキタス通信研究会研究報告], No. 18, pp. 1–8, aug 2011.

[9] 湯浅健史, 加藤丈和, 松山隆司. スマートタップネットワークを用いたオンデマンド型電力制御システム (ユビキタス・センサネットワークの要素技術, コンテクストの抽出, スマートスペース, ユビキタス生活支援, 一般). 電子情報通信学会技術研究報告. USN, ユビキタス・センサネットワーク, Vol. 111, No. 134, pp. 31–36, jul 2011.