Vol.2018-DPS-174 No.25
Vol.2018-CSEC-80 No.25
2018/3/6

在不在と家電利用データの集約による家庭内行動認識システムの試作と展開

本田 美輝[1,a)]　山口 弘純[1,b)]　東野 輝夫[1,c)]

概要：センシングやネットワークの最新技術を家庭内に導入することで，人々が健康的で快適に暮らすことができるスマートホームが普及しつつある．一方で，独居の高齢者などが家庭内でも十分な運動量が確保できているかや，閉じこもりがちで鬱傾向がみられないかなど健康な日常生活のための情報を，プライバシに配慮しながら既設住宅で低コストに見守る技術の実現も望まれる本稿では，配置が容易でかつプライバシ侵害リスクが少ない赤外線ポータブル人感センサー及びタップ消費電力モニターを複数利用し，それらを用いた家庭内行動推定手法を提案する．提案手法ではセンサーの出力値を入力とし，Markov Logic Network（MLN）を用いてセンサーと行動の関連規則をソフト論理式として表現する．これをもとに，それらの規則がどの程度対象者の行動推測に即しているかを数日間の正解行動データで学習し推定する手法を提案する．実家庭から得たセンサーデータを用いて行動推定を行なった結果について述べる．また，クラウドとの通信やコスト，およびクラウドにセンサーデータを預ける潜在的プライバシリスクを回避するため，安価な小型ゲートウェイ端末（Raspberry Pi 3）を試作し，それらの行動推定を家庭内の端末内で完結するシステムを開発し，実家庭に設置しているため，その報告を行うとともに今後の展開について述べる．

Prototyping and Deployment Home Activity Recognition System

Yoshiki Honda[1,a)]　Hirozumi Yamaguchi[1,b)]　Teruo Higashino[1,c)]

1. はじめに

センシングやネットワーク技術の向上によって，その技術を家庭内に導入し，より豊かで快適な暮らしを可能にするスマートホームが普及しつつある．スマートホームでは，HEMS（Home Energy Management System）を構築し，家電や設備機器を自動制御することで省エネルギー化を図る事例が多い．一方で，人は家庭内での生活時間が一番長いことから，肥満防止や家族のコミュニケーションなど，家庭における生活改善支援においても IT 技術の活用が期待されている [1]．我々の研究グループでは，家庭内の行動モニタリングに基づいて人々に活発で自発的な日常行動を促すことにより，家庭内行動のみえる化やエネルギー効率化，同居者のコミュニケーション促進などを図る方法論を検討してきている [2][3]．

一方で，日本を始めとした先進諸国においては急速に高齢化が進んでおり，日本では 2035 年には 3 人に 1 人が 65 歳以上になると予想されている．さらに，人口が少ない過疎地域の市町村数は全国の市町村数の 4 割以上という報告がある．これらが原因で，地方の公共交通事業者が不採算路線から撤退し，周辺は移動困難地域となってさらなる過疎化が進むという負の連鎖が発生している．このような環境下で生活をする多くの高齢者は，社会との関わりや活動量が減少することで精神衛生や肉体的健康に悪影響を与えるケースも少なくない．そういった悪影響を排除し，高齢者の生活の質（Quality of Life, QoL）を向上させるためには，健康上の問題がない状態で日常生活を送れる期間である健康寿命を長寿化し，活発に生活を送ってもらうことが重要である．そのためには家庭内の行動を把握するのはも

[1] 大阪大学 大学院情報科学研究科
Graduate School of Information Science & Technology, Osaka University,
1-5 Yamadaoka, Suita, Osaka 565–0871, Japan
[a)] y-honda@ist.osaka-u.ac.jp
[b)] h-yamagu@ist.osaka-u.ac.jp
[c)] higashino@ist.osaka-u.ac.jp

© 2018 Information Processing Society of Japan

ちろんのこと，その生活パターンに応じた QoL 改善のレコメンドを提供することで活動意欲を向上させることが望まれる．

センサーを用いた家庭内での居住者の行動推定については様々な手法が提案されている．文献 [4] では居住者の手足に加速度センサーを装着し，ドアや窓の開閉めや植物の水やりといった行動を推定している．また文献 [5] では，Kinect を用いて人の関節の動きを検知することで，人の姿勢や行動を推定している．しかし，文献 [4] などウェアラブル機器を前提とした手法では，機器装着負担が大きく，特に家庭内では現実的でなく，かつ高齢者への適用は難しい．また文献 [5] では常時 Kinect を稼働させて動画を取得する必要があり，プライバシーリスクの点で普及には課題が多い．我々の先行研究 [2], [3] では，家庭内行動を把握するため，配置が容易なポータブル型人感センサー及び消費電力モニターを複数利用し，直観的なルールに基づく簡易な行動推定を行い，居住者に生活改善のレコメンドを促す手法を提供している．しかしこの方法では，キッチンに設置されたセンサーが反応すれば料理をしているといった簡易な教師あり学習に基づく推定のみを前提としており，多くの真値を必要とし居住者に負担をかけるため，特に高齢者に応じた現実的な推定法は確立できていない．また，現状のシステムでは居住者の在不在や家電利用の有無の情報をクラウドサーバに保存しており，通信手段の確保，リモートサーバにおけるプライバシ漏洩への懸念の解消などが必要とされる．

本稿では，配置が容易でかつプライバシ侵害リスクが少ない赤外線ポータブル人感センサー及びタップ消費電力モニターを複数利用し，それらを用いた居住者の家庭内行動の推定手法を提案する．提案手法ではセンサーの出力値を入力とし，Markov Logic Network（MLN）を用いてセンサーと行動の関連規則を表現する．MLN は一階述語論理と Markov Network を組み合わせたもので，記述した論理式の一部が充足されないことも許される．各論理式の重みは学習により決定され，満たされない論理式の重みがなるべく小さくなるような述語の確率が導出されることで，学習した重みに沿った推論が行われる．この MLN に対し，例えば「寝室にいるならば寝ている」，「掃除機が稼働しているならば掃除をしている」といった，ある時間での場所情報や家電情報と行動との相関ルール（SA ルール：Sensor-Activity Rule）を一階述語論理で記述し，この論理式の重みを訓練データで学習する．この推定法をもとに，それらの規則がどの程度対象者の行動推測に即しているかの値をセンサー設置後数日間の正解行動データで学習し推定するバッチ推定法，ならびに居住者への簡易な質問を介して規則の尤度を徐々に学習することで居住者による正解行動データの記録を必要としないインタラクティブ推定法を提案している．我々は実際に 2 つの高齢者宅にセンサーを設置してそれぞれ 1 週間データを収集し，この推定法の精度や計算コストについて評価した．また，クラウドとの通信やコスト，およびクラウドにセンサーデータを預ける潜在的プライバシリスクを回避するため，安価な小型ゲートウェイ端末（Raspberry Pi 3）を試作し，センサーデータ集約と行動推定を家庭内の端末内で完結するシステムを開発し，実家庭に設置しているため，その報告を行うとともに今後の展開について述べる．

本稿の構成は以下のとおりである．2 章では，既存の行動推定手法や推定結果を活用する既存研究について紹介した上で，本研究の位置付けについて述べる．3 章では，行動認識システムの利用環境，機能並びにシステムアーキテクチャについて述べる．4 章では，同システムの人感センサー並びに消費電力センサーから得られるデータを用いた家庭内行動推定手法について述べる．5 章では，実家庭から得たセンサーデータを適用した場合の結果について述べる．6 章ではその推定結果を活用したシステムの試作について述べる．7 章では，本研究のまとめと今後の課題について述べる．

2. 関連研究

2.1 スマートデバイスや行動トラッキングによる生活支援

近年，IT 技術を利用し，居住者に対してスマートな生活環境を提供するシステムやアプリケーションが多数提案されており，商用化事例も多い．それらのいずれも，ヒトやモノへのセンサーの装着，あるいは部屋へのセンサーの設置により行動認識を行い，それを用いてサービスを提供する．

ライフログや健康支援では，日常の細やかな行動を記録するため，ヒトやモノへの装着型デバイスを用いることも多い．例えば Mother[6] は，加速度計を組み込んだ小型センサーを歯ブラシやコップなどに取り付けることにより，「今日はまだ歯を磨いていない」など日々の行動を記録する．SmartBand[7] は腕時計型のデバイスであり，消費カロリーや睡眠時間といった基本行動情報だけでなく，視聴した楽曲名や通話時間といったエンターテイメント性のある行動情報についても記録を行う．これらは装着型デバイスのメリットを活用し，詳細な行動把握に焦点を当てている．これらは健常状態・異常状態の検出が最大の目的であり，そのために用意された特別なデバイスを用いているため，一般的な家庭内行動推定とは異なる場合が多い．

2.2 屋内トラッキング技術

人々がどの部屋にいるか，部屋のどこにいるか，あるいはどの部屋を移動しているかといった屋内トラッキング情報は様々なアプリケーションに応用できる．そういったトラッキングにはコスト面の優位性から，赤外線焦電型センサーを利用した人感センサーもよく用いられているが，焦

© 2018 Information Processing Society of Japan

電型センサーを用いた人感センサーの多くは集光した光の変化による動作の有無を検知しバイナリー値を出力するため，単純な存在反応のみから居住者の位置を取得することは容易でない．これに対し，文献 [8] は，人感センサーを室内や廊下の天井に設置し，居住者の室内軌跡情報を認識する方法を提案している．また，文献 [9] は人感センサーを用いて人の在不在を検出し，それに合わせた照明制御手法を提案している．

2.3 家庭内行動認識技術

居住者の行動を汎用的に把握する技術は現在も多くの研究がなされており，利用するセンサーの種別や特性に応じた様々な手法が提案されてきている．文献 [10] は，家電の稼働と消費電力量を紐付ける手法を取り扱っており，消費電力から使用者の行動を推定するアルゴリズムを提案している．文献 [11] は，バイナリーセンサーや家電センサーを用い，転移学習の概念を用いてセンサー配置が異なる状況でも汎用的に利用可能な行動認識手法を提案している．特に異なる家庭のレイアウトにおいても容易に転用可能なモデルを構築しておくことは重要であり，本手法は複数家庭へのシステム展開時における訓練データセット取得の手間を低減できるメリットがある．

2.4 本研究の位置付け

家庭内の行動推定については多くの関連研究があるが，本研究では以下の点で目的が異なる技術の確立を目指している．(1) まず，装着の必要性がないバイナリ型人感センサーが部屋あたり 1 つ程度配置された状態，およびいくつかの家電に消費電力モニターが装備された低コストなセンシング環境において，居住者がどのような行動をしているかが推定可能な手法を提案している．提案手法は簡易なセンシングデータから部屋レベルの存在推定を行い，一般的な居住者の行動パターンの事前知識をベースに精度を向上させる．一般的な行動パターンからの学習で，異なる対象者に対しても高い推定精度を実現することを目指している．また，行動パターンを簡易に記述できるルールベースの推論を採用していることも特徴である．(2) 次に，(1) の提案手法を用いて居住者の行動パターンを把握するためのシステムを開発し，実用的な観点からの評価を実施している点も挙げられる．汎用的で安価な小型端末を利用し，家庭内ゲートウェイで上述の学習および推定処理を完結させるコンセプト実装を行い，その実現可能性を評価している．

3. 家庭内行動認識システム

想定する家庭内行動認識のシステム環境を図 1 に示す．本研究では，1 日に 1 回の頻度で推定することを想定しており，推定する行動は日常生活動作 (ADL：Activities of Daily Living) で定義される食事，睡眠，入浴などの，家庭内での基本的行動である [12]．

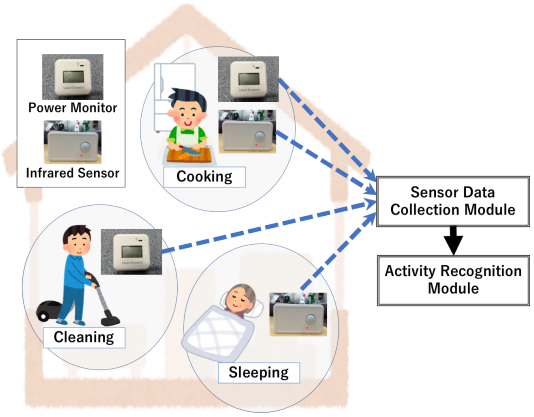

図 1 家庭内行動認識のシステム環境

家庭内行動は，TV 鑑賞，掃除など家電製品の使用を伴う行動と，身支度，調理などその行動の一部にだけ家電製品の使用を伴う行動，食事，睡眠など家電製品の使用を伴わない行動の三種類に分類できる．家電の使用を伴う行動は電力の消費を必ず伴うため，消費電力モニターにより計測された消費電力量から行動を推定することができる．単純な例では，掃除機の稼働を把握すれば居住者が掃除していると判断できる．一方，家電の使用を伴わない行動は必ずしも電力の消費が伴わないため，消費電力モニターのみからこれらの行動を推定することは困難である．これに対し，居住者の位置を計測できる人感センサーを導入することで，それにより計測された人の位置に基づき行動を推定することも可能である．例えば，ダイニングのテーブル付近に滞在している居住者は食事をしていると推定することができる．行動の一部に家電製品の使用を伴う行動に対しては，消費電力センサーと人感センサーの両方を使用し，その行動を推定する．例えば，調理には，冷蔵庫の開閉や IH の稼動，電子レンジの稼動など家電製品の使用を伴う動作と，シンクで野菜を洗う，まな板の上で肉を切るなどの家電製品の使用を伴わない動作が含まれている．そこで，電子レンジやトースター，冷蔵庫等の稼動が消費電力モニターにより検出された時，およびキッチンに居住者がいることが人感センサーにより検出された時に調理が実施されていると推定することができる．

3.1 ポータブルセンサー

本システムで用いる人感センサーは研究グループで開発しており，赤外線焦電センサーと TWE-Lite から構成されている [13]．子機は 幅 69 mm × 奥行 115 mm x 高さ 28 mm，200 g 程度の小型センサーであり，電池稼動するため，電源制約を受けず，天井や壁などにも設置できる．赤外線焦電センサーは検出範囲内の熱源の移動により変化する集光の偏りを検出して反応するため，検知範囲内で人が移動すれば反応するが，検出範囲内でもしばらく静止して

© 2018 Information Processing Society of Japan

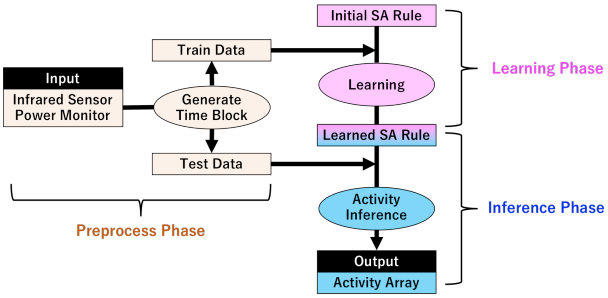

図 2　アルゴリズム概要 (手法 1)

いると検知できなくなるという性質がある．

また，本システムでは消費電力モニターとして，ENEGATE 社製のスマートエコワット [14] を用いる．この消費電力モニターは親機と子機から構成され，子機にはコンセント口とコンセントプラグが備えられており，家電製品の消費電力量計測が可能である．子機により計測された消費電力量は無線で親機に送信され，複数の子機から集約された 15 分間の蓄積消費電力データを取得できる．

4. 推定アルゴリズム

本章では行動推定アルゴリズムについて述べる．本稿では，行動ラベルデータに基づく行動推定手法 (手法 1) とフィードバックに基づくインタラクティブ行動推定手法 (手法 2) の 2 つの手法を提案する．両手法の入力ならびにモデルは共通であり，1 日分の人感センサーデータから得られる，居室やスペースの存在／非存在バイナリ情報と，消費電力モニターから得られる家電の利用／非利用バイナリ情報を入力とし，その日の時間スロット毎の行動推定結果を行動推定列として出力する．先述した ADL で定義される日常生活活動を推論するモデルとして Markov Logic Network（MLN）の拡張モデルを用いる．MLN の詳細については文献 [15] を参照されたい．MLN は確率論理モデルの一つで，一階述語論理 F_i と実数値の重み w_i の組 (F_i, w_i) の集合である．重み w_i で事象の曖昧性が表現可能な点が通常の論理モデルとは異なり，w_i が大きいほど成立する可能性がより高いことを示す．このように，一階述語論理式によって定義されるハードな推論と，各論理式に重みを割り当て学習することによって，確率的な事象をうまく表現できるソフトな推論を兼ね備えており，日常生活行動の推定に適したモデルであるといえる．

4.1 行動ラベルに基づく行動推定手法

図 2 は提案手法アルゴリズムの概要である．提案手法では，人感センサーの生データから「タイムブロック」を生成し，MLN の入力形式に変換するフェーズ（前処理フェーズ），人感センサー位置情報や家電の使用情報から各タイムスロットにおける行動を，MLN の論理で規定されるセンサーと行動を関連付ける推論規則（SA ルール）を学習

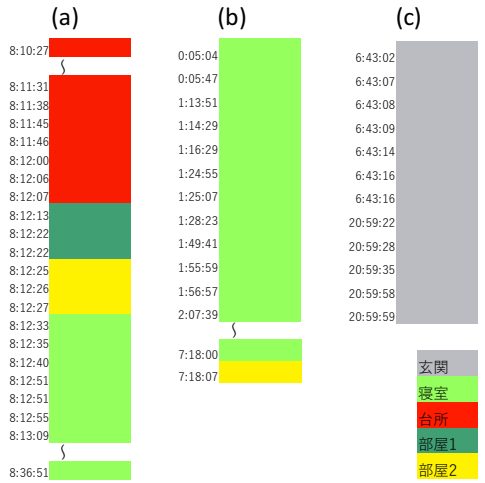

図 3　実家庭での人感センサーの時系列データ (一部抜粋)

データに基づいて学習するフェーズ（学習フェーズ），ならびに学習済みのルールに基づいて推定し，1 日の行動列を出力するフェーズ（推定フェーズ）からなる．

4.1.1 前処理フェーズにおけるタイムブロック生成

行動推定の前処理として，人感センサーデータから MLN の入力を生成する必要がある．本研究で対象とする行動は，ある場所で一定時間滞在する行動であることから，滞在行動のみを正しく検出するためには，移動による通過で反応したセンサーデータを除去することが望ましい．また，3.1 章で述べたように，焦電センサーの性質上，検知範囲内で人が静止状態に近くなると検知が難しくなるため，それを加味したうえで MLN の入力とする必要がある．さらに外出時状態（センサーの無反応時間）を検出する必要もある．この目的のため，センサーが設置された各部屋（スペース）に対し，滞在時間帯（開始および終了時刻）を表す「タイムブロック」を以下のように生成する．

- パターン 1：例えば図 3(a) では，台所から寝室に移動する間に，部屋 1 と部屋 2 に数秒程度存在していることがわかるが，これらの滞在時間は十分に短く，単なる通過であると判定できる．移動時ではこういった短時間内に複数箇所にセンサーが反応するため，予めた定めた最低滞在時間（本研究では 30 秒）より短い滞在時間は移動と判定する．図 3(a) では (台所,8:10:27,8:12:07) と (寝室,8:12:33,8:36:51) のタイムブロックを生成する．
- パターン 2：図 3(b) のように，00:05:04〜01:13:51 は実際は寝室にいるが，人感センサーの反応がなく寝室にいることが単純には判断できない．また図 3(c) のように 06:43:16〜20:59:22 に実際に外出している状況も存在する．そこで玄関で人感センサーの反応が止まれば外出，それ以外はその前後の場所での滞在とみなし，無反応時間を補完する．すなわち，図 3(b) では (寝室,00:05:04,7:18:00) のタイムブロックを生成し，図 3(c) では (玄関,06:43:02,06:43:16)，(屋

Vol.2018-DPS-174 No.25
Vol.2018-CSEC-80 No.25
2018/3/6

表 1　初期 SA ルールの例

行動の種類	SA ルール
睡眠	$Pos(t, Bedroom) => Do(t, Sleep)$
食事	$Pos(t, Dining) => Do(t, Meal)$
家事	$Pwr(t, Microwave) \wedge Pos(t, Kitchen) => Do(t, Housework)$

外,06:43:16,20:59:22)，(玄関,20:59:22,20:59:59) のタイムブロックを生成する．

これらにより得られたデータを MLN の入力して与える．

4.1.2　学習，推定フェーズにおけるモデルの定式化

学習，推定フェーズで用いる定数を以下で定義する．

$$Activity = \{Sleep, Meal, Housework, Relax, Bath, GoOut, \cdots\} \quad (1)$$

$$Location = \{Bedroom, Bathroom, Outdoor \cdots\} \quad (2)$$

$$Name = \{TV, Microwave, Kotatsu, \ldots\} \quad (3)$$

$$Time = \{0, 1, 2, \cdots, Timeslot\} \quad (4)$$

$Activity$，$Location$，$Name$ は集合であり，その要素はそれぞれ行動の種類，家庭内の場所，家電の名前である．なお，家事（$Housework$）は ADL で定義される家庭内での家事（洗濯，料理，洗い物など）全般を指し，くつろぎ（$Relax$）はテレビ視聴，読書，会話などの身体をあまり動かさない行動全般を指す．$Time$ はタイムスロットの集合であり，本研究では 15 分毎の行動推定を行うため，$Timeslot = 95$ として実装する．また，以下の述語を定義する．

$$Pos(t, l) \quad (t \in Time, l \in Location) \quad (5)$$

$$Pwr(t, n) \quad (t \in Time, n \in Name) \quad (6)$$

$$Do(t, a) \quad (t \in Time, a \in Activity) \quad (7)$$

Pos は人感センサーと位置との関係を表し，例えば，$Pos(2, Bedroom)$ は居住者がタイムスロット 2（0 時 30 分〜45 分）に寝室に滞在していれば真となる．Pwr は消費電力モニターから得られる家電利用情報を表し，例えば $Pwr(60, TV)$ は 15 時 00 分〜15 分にテレビが利用されれば真となる．Do は行動を表し，例えば $Do(47, Meal)$ は 11 時 45 分〜12 時 00 分に食事をしていることを表す．これらを用いてセンサー情報と行動を紐付けた SA（Sensor-Activity）ルールを定義する．表 1 は初期 SA ルールの一例である．ルールは一階述語論理で定義し，$\wedge$ は論理積，$=>$ は論理包含を表す．例えば「寝室にいるならば睡眠をしている」は

$$Pos(t, Bedroom) => Do(t, Sleep) \quad (8)$$

のように記述する．なお，各ルールの重みの初期値については，クラウドソーシングアンケートを用い，44 名の 65 歳以上の高齢者に SA ルールが当てはまる頻度をアンケート形式で回答してもらい，その頻度に応じて重みを設定することで，より多くの高齢者に沿ったルールとなるようにしている．この初期 SA ルールに対して，数日分のセンサー情報と実際の行動の情報を教師データとして与えて学習させる．

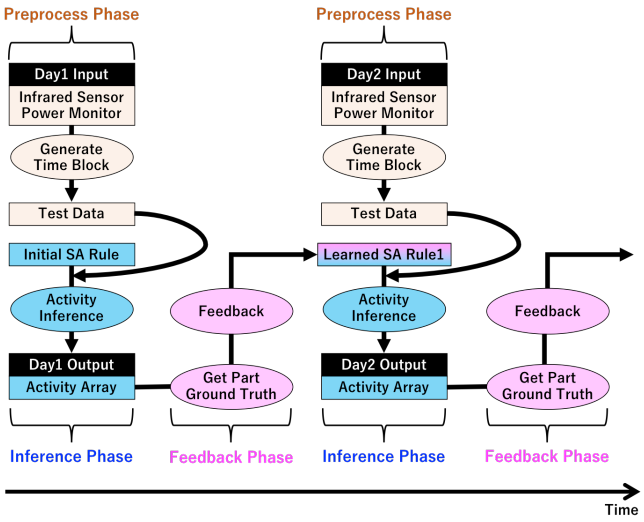

図 4　アルゴリズム概要 (手法 2)

学習によって重みが変動した SA ルール（学習済 SA ルール）はあるタイムスロットにおけるセンサーと行動の関係を重みとして保持している．MLN の行動推定は 1 日のセンサー情報を入力とし，各時間および場所での行動の尤度が確率として出力され，各タイムスロットの行動尤度が最大のものを MLN の行動推定結果とする．

4.2　インタラクティブ行動推定手法

手法 1 ではセンサー情報に対する実行動情報を訓練データとして用いるため，正解データを必要とする点で居住者，特に高齢者への負担は少なくない．これに対し，手法 2 では訓練データの代わりに簡易な質問を生成し，そのフィードバックから学習を行う．図 4 に手法 2 の概要を示す．手法 1 と同様に 3 フェーズからなり，前処理フェーズと推定フェーズは手法 1 と共通である．手法 2 では学習フェーズは存在せず，代わりにフィードバックフェーズが存在する．

4.2.1　質問とフィードバックによる再学習

以下ではフィードバックフェーズについて述べる．フィードバックは居住者に簡単な質問に答えてもらうことで行う．質問の生成方針はいくつか挙げることができる．ひとつに，先の推定フェーズで得た 1 日の行動推定列に対し，行動尤度が低いスロットをいくつか選択し，それらのスロットに対応する質問を居住者に問いかけ，それに対する簡単な回答を得る方法がある．例えば，スロット 88〜90(22 時 00 分〜22 時 45 分) において低い尤度で睡眠していると出力された場合，「22 時 00 分〜22 時 45 分にあなたは寝ていましたか？」という質問を居住者に問いかけ「はい／いいえ」で答えてもらうことで，スロット 88〜90 での実際に

© 2018 Information Processing Society of Japan

図 5　家庭 A におけるセンサー設置場所

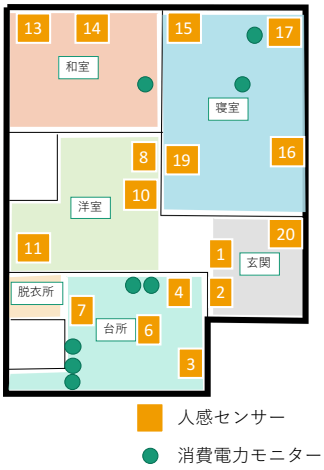

図 6　家庭 B におけるセンサー設置場所

行った行動情報を部分的に得る．また，学習量が多く必要な食事，入浴などの 1 日のうちに数回しか発生しない行動のみに注目して質問を問いかける方法がある．例えば，「今日は 3 回食事をしましたか？」，「今日は何時頃に入浴しましたか？」などの質問が挙げられる．回答においては，実施の有無（はい／いいえ）の回答のみならず，複雑にならない範囲で複数選択肢（はい／いいえ／昼食を食べていません／夕食後は洗い物をしました，など）でより詳細な情報を得ることも考えられる．この回答で得られた結果に基づき誤った推定を更新し，その他の行動推定結果はそのまま用いて SA ルールの重み再学習を行う．

5. 評価

5.1 データ取得環境

3 章で説明したシステムを用いて単身高齢者 2 世帯に対し，人感センサーならびに消費電力モニターデータの収集を行い，提案手法の有用性について評価した．対象家庭は 69 歳の独居女性 (家庭 A) と 84 歳の独居女性 (家庭 B) である．間取り図，ならびに人感センサーと消費電力モニターの設置位置，人感センサーの検出範囲を図 5 および図 6 にそれぞれ示す．

表 2　行動別の適合率と再現率 (家庭 A)

行動	適合率 (%)	再現率 (%)
睡眠	97.0	100
食事	83.3	56.7
くつろぎ	96.1	95.9
入浴	87.5	100
家事	85.0	90.0
外出	100.0	100

表 3　行動別の適合率と再現率 (家庭 B)

行動	適合率 (%)	再現率 (%)
睡眠	87.8	100
食事	86.7	69.7
くつろぎ	96.3	93.5
入浴	66.7	72.7
家事	82.8	76.1
外出	100	99.0

5.2 行動ラベルに基づく行動推定手法の評価

提案手法 1 に基づいてセンサーデータをそれぞれの家庭につき 7 日間収集し，居住者には 7 日分の行動とその行動場所を 15 分毎に記録してもらい，それを行動推定の真値とした．うち 6 日分を学習データ，1 日分をテストデータとして交差検証を行った結果を述べる．表 2，3 は行動種類別の適合率と再現率である．なお，特定時間での行動ではなく，1 日の行動パターンや行動の流れを把握できたかどうかを確かめるため，これらは推定したスロットに対し，2 スロット（30 分）のズレを許容した場合の精度となっている．2 世帯ともに平均の適合率と再現率は 85% を上回る結果になった．行動別に見ると特に外出は適合率，再現率共に高い推定精度となった．この結果より，居住者が外出状態であることがほぼ確実に判断できていることがわかる．また，睡眠やくつろぎに関しては，その時間帯に習慣性があり，かつ場所に強く依存した行動であったために高精度な推定ができている．

全体的に見ると特に適合率が高いという結果が得られたことから，推定したものが実際に行われている確率が高いことが言える．これらの精度は 2 スロットのズレを許容したものとなっているが，1 日の行動パターンの把握や 1 日の消費カロリーを算出することを目的とするならば，これらは十分高い精度と言える．食事の再現率が他と比べて低かったことに関して，実際に食事をしている時間帯を調べてみると，両家庭とも朝食，昼食，夕食とは別に不定期に発生する「間食」をしているケースが多く見受けられた．このため精度が低くなる結果になったと考えられる．また，

© 2018 Information Processing Society of Japan

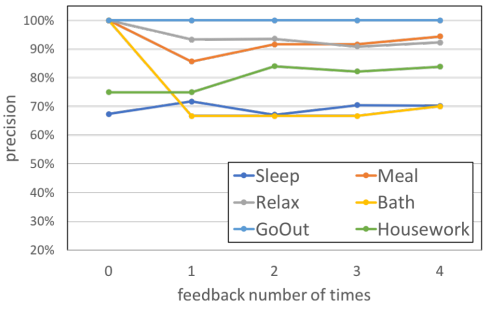

図 7　ユーザーフィードバックによる適合率の変化

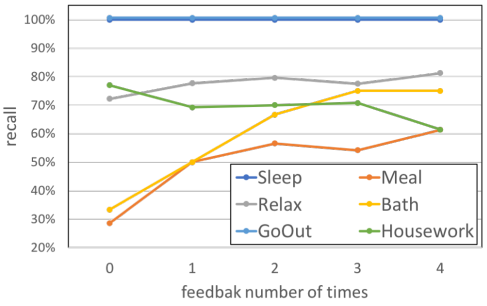

図 8　ユーザーフィードバックによる再現率の変化

家庭 A では精度が高く，家庭 B では精度が低かった入浴に関して，家庭 A は脱衣所が他の部屋と区切られていたことに対し，家庭 B は脱衣所と台所に明確な区切りがなかったことが精度に大きく影響していると考えられる．本質的にこれらの精度を向上させるためには，より習慣性が出る長期データでの学習が必要であると考えられる．

5.3　フィードバックに基づくインタラクティブ行動推定手法の評価

ユーザーフィードバックに基づくインタラクティブ行動推定手法の評価を述べる．データ取得環境は家庭 B のデータを用いて 4 回のユーザーへのフィードバックを行った．1 回のユーザーへのフィードバックで多くの質問をするのは居住者の負担になることを考慮して，今回は 4 つの質問を 1 回のフィードバックで行った．図 7，8 はフィードバック回数を重ねたことによる各行動の累積適合率，および累積再現率を表したものである．睡眠や外出，くつろぎといった行動はユーザーフィードバックによる修正をしなくても高い精度を得ることができた．また，食事に関してはユーザーフィードバックを重ねるごとに適合率，再現率ともに向上したことが読み取れる．全体的にはユーザーフィードバックを重ねるごとに精度が向上した．事前の学習データを必要としない本手法は，システム導入開始時は手法 1 に比べて精度が低いが，ユーザーフィードバックを重ねるごとに精度が向上することが期待できるため，居住者，特に高齢者のシステム導入の初期負担が小さい手法であり，より実用的な手法と言える．一方で，様々なユーザーフィードバックの生成方法があるため，最も適切なフィードバックを選ぶ方法について今後検討を重ねていく．

表 4　端末別の推定実行時間

マシン名	CPU	メモリ	学習時間	推定時間
Mac book Pro	2.9 GHz	16 GB	6.5 秒	10.8 秒
Raspberry Pi 3	1.2 GHz	1 GB	31.1 秒	48.9 秒

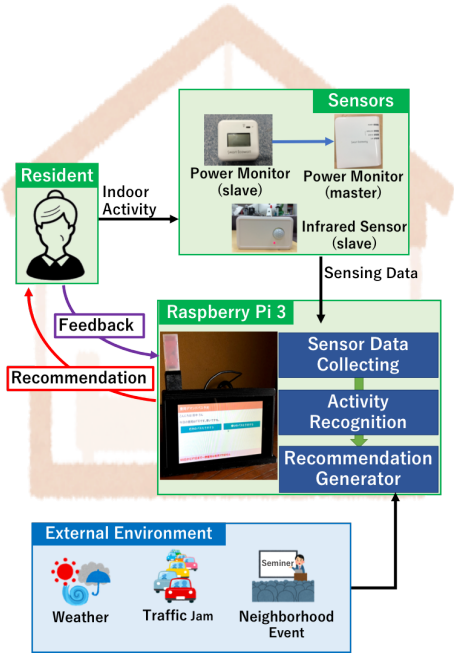

図 9　GUI 一体型データ集約システムのアーキテクチャ

5.4　実行時間についての評価

提案手法が実用的なシステムに適用できるかどうか評価する．表 4 は推定プログラムを 2 つの端末で実行した時の 1 日分の学習時間および推定時間を示している．比較的処理能力が低い端末（Raspberry Pi 3）においても 10 秒オーダーの実行時間であることがわかった．これは 1 日数回の頻度で推定すると考えるとシステム運用に支障がない実行速度であると言える．これにより，家庭内に小型端末を設置し行動認識処理機能を備えたシステムとして十分実現できることが判断できる．

6.　GUI とデータ集約一体型システムへの応用

本章では，4 章で述べた提案手法を用いた GUI とデータ収集一体型システムへの応用について述べる．図 9 は本システムのアーキテクチャである．これは 3 章で述べた行動推定システムをもとにして，センサーデータの集約と行動推定，さらに GUI アプリケーション提供の 3 つの機能を兼ね備えたディスプレイ付き小型端末（Raspberry Pi 3）を使用している．

GUI アプリケーションは行動推定で得た居住者の行動パターン等を活用して新たな価値を提供するものと想定している．現在，我々は兵庫県豊岡市，全但バスならびに近畿大学との共同プロジェクトで，路線バスの設定がなく，

© 2018 Information Processing Society of Japan

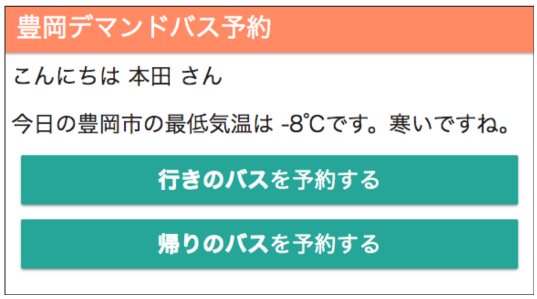

図 10　開発したアプリケーション（試作）

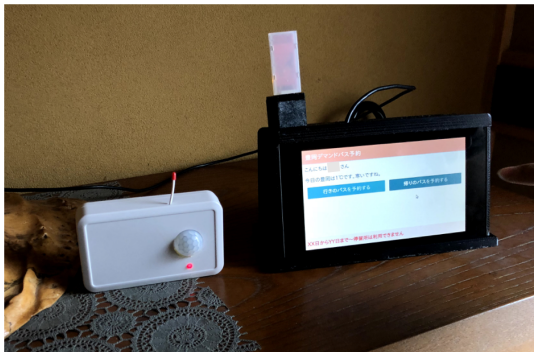

図 11　GUI 一体型データ集約システム導入の様子

交通利便性の低い地域に対し，低コストで運用可能な「セミデマンドバス」の提供を行い，住民に移動機会を提供するための実証実験を行なっている．現在，このセミデマンドバスの予約システムはスマートフォンからの利用を主としているが，本稿で構成した試作システムを一体化し（図 10），明日の天気やオススメのお出掛け情報，スーパーの特売情報といった居住者が興味をもつ情報を最近の行動パターンを考慮して提示し，外出の機会を増やすことを目指したレコメンドシステムを一家庭に試験的に導入している（図 11）．今後は本レコメンドシステムが外出意欲を増やし，セミデマンドバス利用機会向上や居住者の QoL 向上などに寄与することを定量評価していきたいと考えている．

7. まとめ

本稿では，配置が容易でかつプライバシ侵害リスクが少ない赤外線ポータブル人感センサー及びタップ消費電力モニターを複数利用した高齢者の家庭内生活での行動推定手法を 2 つ提案した．また，2 つの家庭から実際にセンサーデータを収集し，推定精度や実行時間の観点からの性能を評価した．最後に，提案手法の活用例として，GUI とセンサーデータ集約一体型システムの開発と今後の展開について述べた．

謝辞

実験にご協力いただきました世帯の皆様にお礼申し上げます．また，本研究の一部は JSPS 科研費 JP26220001 の助成を受けたものです．

参考文献

[1] Byun, J., Hong, I. and Park, S.: Intelligent Cloud Home Energy Management System Using Household Appliance Priority Based Scheduling Based on Prediction of Renewable Energy Capability, *IEEE Transactions on Consumer Electronics*, Vol. 58, No. 4, pp. 1194–1201 (2012).

[2] 中村笙子，志垣沙衣子，廣森聡仁，山口弘純，東野輝夫：大衆の生活ノウハウの定量化とモデル化によるスマートライフ支援システム，情報処理学会論文誌，Vol. 56, No. 8, pp. 1621–1633 (2015).

[3] Nakamura, S., Shigaki, S., Hiromori, A., Yamaguchi, H. and Higashino, T.: A Model-based Approach to Support Smart and Social Home Living, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing (UbiComp '15)*, pp. 1101–1105 (online), DOI: 10.1145/2750858.2805835 (2015).

[4] Michael, H., Nguyen-Dinh, Long-Van, Alberto, C., Gerhard, T. and Daniel, R.: Enhancing action recognition through simultaneous semantic mapping from body-worn motion sensors, *Proceedings of the 2014 ACM International Symposium on Wearable Computers*, pp. 99–106 (2014).

[5] Gaglio, S., Re, G. L. and Morana, M.: Human Activity Recognition Process Using 3-D Posture Data, *IEEE Transactions on Human-Machine Systems*, Vol. 45, No. 5, pp. 586 – 597 (online), DOI: 10.1109/THMS.2014.2377111 (2015).

[6] ST マイクロエレクトロニクス：Mother, Motion Cookies, `https://www.sen.se/`.

[7] Sony Mobile Communications Inc.: `http://www.sonymobile.co.jp/product/smartwear/`.

[8] 村尾和哉，藤堂智史，寺田努，矢野愛，松倉隆一，塚本昌彦：住宅内に設置した人感センサを用いた住人の移動推定手法，マルチメディア、分散協調とモバイルシンポジウム 2011 論文集，Vol. 2011, pp. 315–322 (2011).

[9] 江田政聡，賀新剛，中根傑，横山昌平，福田直樹，峰野博史，石川博：赤外線センサを用いた在席推定に基づく照明制御手法の提案，第 4 回データ工学と情報マネジメントに関するフォーラム A10-4 (2012).

[10] S., R. and N., B.: Using rule mining to understand appliance energy consumption patterns, *Proceedings of 2014 IEEE International Conference on Pervasive Computing and Communications (PerCom 2014)*, pp. 29–37 (2014).

[11] Ordonez, F., Englebienne, G., de Toledo, P., van Kasteren, T., Sanchis, A. and Krose, B.: In-Home Activity Recognition: Bayesian Inference for Hidden Markov Models, *IEEE Pervasive Computing*, Vol. 13, No. 3, pp. 67–75 (2014).

[12] Logan, B. and Healey, J.: Sensors to Detect the Activities of Daily Living, *Proceedings of 2006 Int. Conf. of the IEEE Engineering in Medicine and Biology Society*, IEEE (2006).

[13] 超小型 ZigBee モジュール TWE-Lite：Tokyo Cosmos Electric Co.,Ltd, `http://tocos-wireless.com/jp/products/TWE-001Lite.html`.

[14] ENEGATE: Smart Ecowatt, `https://www.enegate.co.jp/smarteco\_portal/index.html` (2012).

[15] Richardson, M. and Domingos, P.: Markov logic networks, *Machine learning*, Vol. 62, No. 1, pp. 107–136 (2006).

© 2018 Information Processing Society of Japan