

センサデータ粒度が宅内行動認識精度に与える影響について

上田 健揮¹ 荒川 豊¹ 諏訪 博彦¹ 安本 慶一¹

概要: 効果的な省エネ家電制御や見守りなどのコンテキストウェアサービスを実現するためには、家庭内における生活行動の認識が必須である。これまで、行動認識に関する研究は数多く行われているが、(1) 多数のセンサを使用するため導入・維持コストが高い、(2) カメラやマイクを使用するためプライバシーを侵害する、(3) 認識できる行動種類が少ないまたは認識精度が低いなどの課題が残されている。我々はこれまで、上記の課題(2)を解決することを目標に、電力センサおよび屋内位置センサのみを使った生活行動認識手法を開発し、6種類の生活行動を80%以上の精度で識別できることを確認した。本稿では、課題(3)の解決に向け、より多種類の行動をより高精度に識別するため、異なる機械学習アルゴリズムの適用や教師データとして用いるセンサデータの最適な時間幅の探索を行うとともに、課題(1)の解決に向け、屋内位置センサの精度や使用する電力センサの数といったセンサデータの粒度が生活行動の識別精度に与える影響について調査する。評価実験の結果、10種類の対象行動に対して、センサデータの粒度が最大の場合(位置推定誤差: ~0.1m, 電力計: 16個)91.3%, 最少の場合(位置推定誤差: ~1m, 電力計: 3個)84.5%の識別精度を達成した。この結果から、屋内位置センサと電力計のみを用いて、90%以上の高い識別精度を達成できること、より低コストのセンサセットを用いた場合でも、80%以上の識別精度が達成できることが分かった。

1. はじめに

近年、スマートフォンをはじめとする様々なセンシングデバイスが普及している。これに伴い家庭内においても温度や湿度などの環境情報だけでなく、個々のデバイスの使用状況や人間の生活行動を理解するための研究が盛んに行われている。家庭での生活行動を自動認識することで、省エネ家電制御 [1][2] や高齢者見守りシステム [3][4] などの生活支援・行動支援アプリケーションへの応用が期待できる。これらのアプリケーションでは多種類の行動を高精度で認識することが重要であり、これまで様々なセンシング手法や機械学習等を用いた生活行動の推定手法が研究されている。行動認識の手法の1つとしてカメラを用いた行動推定システム [5][6] があるが、カメラは「監視されている感覚」が強く、ユーザのプライバシーを侵害するという問題がある。また、家庭内のあらゆる物に接触センサを付けることで高い行動認識率を達成する手法 [7] が提案されているが、導入及び維持コストが高く、普及性の面から現実的ではない。さらに、加速度センサなどのウェアラブルセンサを用いてユーザの行動を認識する手法 [8] も提案されているが、ユーザの姿勢や、「歩く」「走る」などのユーザの動きに基づいた行動しか認識できず、家庭内での多様な

生活行動の認識は困難である。

本研究では、行動認識に関する既存研究における、(1) 多数のセンサを使用するため導入・維持コストが高い、(2) カメラやマイクを使用するためプライバシーを侵害する、(3) 認識できる行動種類が少ないまたは認識精度が低いという3つの課題を全て解決することを目指した生活行動認識システムを提案する。我々はこれまで課題(2)を解決することを目標に、電力センサおよび屋内位置センサのみを使った生活行動認識手法を開発し、6種類の生活行動を80%以上の精度で識別できることを確認した [9][10]。本稿では、課題(3)の解決に向け、より多種類の行動をより高精度に識別するために、教師データのサンプル長、特徴量の種類、機械学習アルゴリズムの様々な組み合わせに対し、最も認識精度が良くなる組み合わせを探究する。さらに、課題(1)の解決に向け、屋内位置センサの精度や使用する電力センサの数といったセンサデータの粒度が生活行動の識別精度に与える影響について調査する。

提案システムの有用性を評価するため、奈良先端科学技術大学院大学内に設置したスマートホーム設備 (1LDK) にて、日常的に生活した際の生活行動の識別率を測定した。今回の実験で対象とする生活行動は、料理、食事、読書、テレビ視聴、食器手洗い、風呂、掃除、仕事・勉強(PC使用)、睡眠、外出の10種類とした。4人の被験者による3日

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

表 1 生活行動区分の例

1 次活動	睡眠 身の回りの用事 食事
2 次活動	通勤・通学 仕事 (収入を伴う仕事) 学業 (学生が学校の授業やそれに関連して行う学習活動) 家事 介護・看護 育児 買い物
3 次活動	移動 (通勤・通学を除く) テレビ・ラジオ・新聞・雑誌 休業・くつろぎ 学習・自己啓発・訓練 (学業以外) 趣味・娯楽 スポーツ ボランティア活動・社会参加活動 交際・付き合い 受診・療養 その他

間ずつの生活に伴うセンサデータを用いて評価実験を行った。その結果、教師データのサンプル長として 5 分、特徴量として消費電力の平均値と位置の中央値、機械学習アルゴリズムとして Random Forests を用いて行動認識モデルを構築することで、10 種類の生活行動を平均 91.3% の精度で識別することができた。また、導入・維持コストの抑制を想定し、電力センサおよび屋内位置センサのデータの粒度が粗い環境下で評価した結果、誤差 1 m 程度の屋内位置センサと各部屋の消費電力データを併用することで、平均 84.5% の精度で行動を識別することができた。

2. 宅内行動認識システム

2.1 対象の生活行動

本研究で対象とする生活行動について述べる。平成 23 年総務省統計局では、表 1 のように 1 日の主な行動を 20 種類に分類し、1 次活動 (睡眠、食事など生理的に必要な活動)、2 次活動 (仕事、家事など社会生活を営む上で義務的な性格の強い活動)、3 次活動 (1 次活動、2 次活動以外で各人が自由に使える時間における活動) と定義している [11]。本研究では、これらの中から宅内の行動で発生頻度が高い、1 次活動の「食事」、「入浴」、「睡眠」、2 次活動の「料理」、「食器手洗い」、「掃除」、3 次活動の「テレビ視聴」、「仕事・勉強 (PC 使用)」、「外出」の計 10 種類を認識の対象とした。

2.2 スマートホームでのセンサデータ収集

本研究では、図 1 に示すスマートホーム (奈良先端大内に設置されている 1LDK の実験用住宅設備) において、被験者に実際に生活してもらいデータを収集する。スマートホームには、各家電に取り付けられている消費電力セン




図 1 実験で用いたスマートホームの間取り

サ、環境センサ (温度、湿度、照度、人感センサを搭載、数か所に設置)、超音波位置センサ [12]、ドアセンサ、水栓センサが設置されている。このうち、本研究で行動認識に使用するセンサは、超音波位置センサと消費電力センサである。超音波位置センサの位置推定精度は、公称値は誤差 50cm であるが、センサを静止させた状態での実測値は誤差 10cm 以内であることを確認している。サンプリング周期は、毎秒 2 回である。消費電力センサは、家電 (100V 用) の消費電力を 1 分間に 2 回のサンプリング周期でセンシングできる。データは、0 以上の実数 (小数点以下 2 桁) のワットで示される。また、スマートホーム内に CT センサという照明や給湯器といった設備に内蔵されている消費電力を計測するセンサがある。本研究では、この CT センサも使用する。両センサとも、計測したデータは ZigBee で天井裏の中継機に送信され、サーバに自動蓄積される。センサの詳細については、著者らの文献 [9][10] を参照していただきたい。

図 1 に各行動に使用される家電や家具の位置を示す。リビングルームの「TV」の位置にテレビが設置されており、「SF」のソファ、「TB」のダイニングテーブルの位置から視聴される。料理は「IH」の IH ヒータを使用して調理を行い、食事はダイニングテーブルかソファ前のテーブルで行われ、食器手洗いは「SK」の流し台で行われる。仕事・勉強 (PC 使用) は寝室のデスク「PC」の位置で行われる。浴室は「BT」、ベッドは寝室の「BD」の位置にある。

2.3 生活行動の認識手法

生活行動の認識手法について述べる。本システムでは機械学習により生活行動を識別する。機械学習の適用過程は、(1) 学習に使用する教師データの取得、(2) 取得した教師データの特徴量の抽出、(3) 生活行動の学習モデルの構築、の 3 つのフェーズから構成される。以下にそれぞれのフェーズの概要について述べる。

(1) 教師データの取得

機械学習を行うにあたって、あらかじめセンサデータの集合がどの生活行動に対応するかを示した教師データが必要である。著者らは、文献 [13] において、教師

表 2 センサおよび特徴量の概要

	消費電力センサ	屋内位置センサ
単位	ワット (W)	ミリメートル (mm)
サンプリング周期	2 回/分	2 回/秒
取り付け位置	各家電または天井裏	被験者の右腕
使用データ	各部屋の照明 各部屋のエアコン テレビ, オーディオ PC, IH ヒータ 冷蔵庫, 炊飯器 電子レンジ 給湯器, ドライヤー 掃除機, 洗濯機	x 座標, y 座標
時間窓幅	5 分, 1 分, 30 秒	
特徴量	各時間窓における 平均値	各時間窓における 中央値

データを容易に取得するための、生活行動ラベリングツールを開発した。本ツールは、スマートホームにおいて収集した多種類のセンサデータの可視化に加え、グラウンドトゥルースとして撮影したビデオを同期して再生する機能を備え、発見した生活行動に対し、対応する時間区間のセンサデータに当該行動のラベル付けを行うことを支援する。ラベル付けされた各時間におけるセンサデータは、ラベルが示す生活行動に紐付けて保存され、教師データとして使用される。

(2) 特徴量の抽出

特徴量とは、生活行動に対応するセンサデータの集合から、それらの行動を識別するために有効なデータの特徴のことである。手順として、まずそれぞれの生活行動に対するセンサデータを収集し、次にそれらを一定の時間間隔のデータに区切り、最後に必要な特徴量を抽出する。抽出する特徴量は予備実験で幾つかの統計量を試した結果、電力データの平均値と位置データ (x 座標, y 座標) の中央値を使用した場合が最も認識精度が高くなったため、本研究ではこれらの特徴量として用いた。収集する電力データは、各部屋の照明とエアコン、テレビ、オーディオ、PC、IH クッキングヒーター、冷蔵庫、炊飯器、電子レンジ、給湯器、ドライヤー、掃除機、洗濯機の 16 種類とする。センサおよび特徴量の概要を表 2 にまとめる。

(3) 行動学習モデルの構築

生活行動ラベリングツールによりラベル付けしたセンサデータ区間の特徴量を教師データとする機械学習モデルを構築する。分類器の構築はデータマイニングツールである Weka [14] を用いた。Weka は多数の機械学習アルゴリズムに基づく分類器を実装しており、本研究では、代表的な機械学習アルゴリズムである SVM (Support Vector Machines: サポートベクター

マシン)、C4.5 決定木、Random Forests の 3 つの手法を用いて各生活行動における特徴量に対して学習モデルを構築する。

2.4 センサデータの粒度

本研究で使用しているセンサデータの粒度に関して述べる。本研究では、高精度の超音波位置推定システムを使用しており、センサを静止させた状態での推定誤差は実測値 10cm 以内であることを確認している。また、消費電力センサは各家電および照明や給湯器などの設備内にも多数設置されており、電気機器に応じた電力の使用状況を取得することができる。しかし、導入・維持コストを考慮すると、このような高精度センシングシステムの一般家庭への普及は現状では難しい。そのため、より安価な行動認識システムを実現するためには、高い認識精度を保ったままセンサデータの粒度をできるだけ低下させることが重要である。そこで、本稿では位置センサおよび消費電力センサのデータの粒度を段階的に低下させた場合における認識精度への影響を調査するための評価実験を行う。

3. センサデータの粒度が行動認識精度に与える影響の分析

3.1 実験概要

2.1 節で述べた通り、今回の評価実験において識別対象とする行動は、料理、食事、読書、テレビ視聴、食器手洗い、風呂、掃除、仕事・勉強 (PC 使用)、睡眠、外出の 10 種類とした。4 名の被験者 (20 代男性 3 名, 20 代女性 1 名) に、前述のスマートホームにそれぞれ 3 日間ずつ住んでもらい、計 12 日間分のデータセットを収集した。被験者には超音波位置センサの送信機を 1 つ装着してもらい、通常の生活をしてもらう。

データを収集した後、生活行動ラベリングツールを用いて、グラウンドトゥルースの映像を確認しながら、センサデータに対して各生活行動に応じたラベル付けを行う。ラベル付けされた全てのデータを一定の時間間隔で分割し、その中から各生活行動につき 30 個のサンプルを教師データとしてランダムに抽出する。その後、前述の手順で特徴量を抽出し、位置情報および電力情報の粒度が異なる学習アルゴリズムを構築し、センサデータの粒度が認識精度に及ぼす影響を分析する。評価に使用したテストデータは、教師データに用いたサンプル以外の中から各生活行動につき 30 個をランダムに抽出した。

3.2 評価結果

評価には Precision, Recall, F 値を用いる。Precision (適合率) は、その生活行動であると認識されたデータのうち、実際にその生活行動であった正しいデータの割合である。

表 3 学習アルゴリズム・時間窓幅ごとの平均 F 値

学習アルゴリズム	時間窓幅		
	5 分	1 分	30 秒
SVM	86.3%	78.7%	81.3%
C4.5 決定木	87.7%	79.7%	81.2%
Random Forests	91.3%	85.5%	86.3%

表 4 位置センサおよび電力計のデータの粒度が最も細かい場合における混同行列

真 \ 予測値	真									
	a	b	c	d	e	f	g	h	i	j
a=料理	28	0	2	0	0	0	0	0	0	0
b=食事	0	24	1	4	1	0	0	0	0	0
c=食器洗い	0	0	29	1	0	0	0	0	0	0
d=テレビ	0	4	0	20	4	1	1	0	0	0
e=読書	0	0	0	5	25	0	0	0	0	0
f=入浴	0	0	0	0	0	29	0	0	0	1
g=掃除	0	0	0	0	0	1	29	0	0	0
h=仕事・勉強	0	0	0	0	0	0	0	30	0	0
i=睡眠	0	0	0	0	0	0	0	0	30	0
j=外出	0	0	0	0	0	0	0	0	0	30

表 5 位置センサおよび電力計のデータの粒度が最も細かい場合における評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	100.0	93.3	96.6
食事	85.7	80.00	82.8
食器洗い	90.6	96.7	93.5
テレビ	66.7	66.7	66.7
読書	83.3	83.3	83.3
入浴	93.5	96.7	95.1
掃除	96.7	96.7	96.7
仕事・勉強	100.0	100.00	100.0
睡眠	100.0	100.0	100.0
外出	96.8	100.00	98.4
平均	91.3	91.3	91.3

Recall (再現率) は該当する生活行動のうち、その生活行動であると正しく認識されたデータの割合である。F 値は、Precision と Recall の調和平均であり、次式で表される。

$$F = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$

以降の評価結果における認識精度は全て F 値を示す。

予備実験として、表 3 に、SVM, C4.5 決定木, Random Forests の 3 つの学習アルゴリズムを使用した場合における、時間窓幅ごとの認識精度を示す。それぞれの学習アルゴリズムで、5 分, 1 分, 30 秒の 3 つの時間窓幅を試した。表 3 より、全ての学習アルゴリズムで 5 分が、また、全ての時間窓幅で Random Forests による識別が最も高い認識精度となっていることがわかる。この結果に基づき、以降の評価結果では学習アルゴリズムに全て Random Forests を使用し、時間窓幅を 5 分とする。




図 2 2m 四方のセルによる位置情報の粒度変更 (最大誤差 1m)

3.2.1 センサデータの粒度が最大の場合における評価結果

センサデータの粒度が行動認識精度に与える影響を分析するために、まず位置センサおよび電力計のデータの粒度が最も細かい場合における評価結果を表 4, 表 5 に示す。表 4 の混同行列において、各行は実際の生活行動を示し、各列は識別モデルによって予測された生活行動を示す。表 5 は各生活行動における Precision, Recall, F 値を示す。

全ての行動の平均 F 値は 91.3% となり、高い認識精度を得ることができた。各生活行動の個別の F 値を見ると、食事、テレビ視聴、読書以外の行動は 90% 以上の認識精度が得られた。仕事・勉強 (PC 使用)、睡眠の行動はどちらも F 値 100% となったが、これは、電力、位置情報共に他の行動とは大きく異なる特徴があるためだと考えられる。テレビ視聴に関しては F 値 66.7% と最も低い結果となったが、これは、表 4 に示すように、食事や読書の行動を誤ってテレビ視聴と識別しており、テレビの電源を入れたまま別の行動を同時に行うといった、複合的な行動が原因だと考えられる。

3.2.2 位置情報の粒度が与える影響について

今回の実験環境では、高価な超音波センサを用いた高精度位置推定システムを使っているが、現状では一般家庭への普及は難しい。そこで、より低コストの位置推定システムの利用を想定し、図 2 のように部屋を複数のセルに分割して、セルの中心座標を推定位置とすることで位置情報の精度を意図的に低くした場合の認識精度への影響について評価する。2m 四方のセルに分割した場合 (=最大誤差 1m) の評価結果を表 6 に示す。使用した電力データは各家電の消費電力データを使用している。個別の行動を見ると、表 5 と比べて食器手洗いの認識精度が 10% 程低下している。これは、位置精度を低くすることでキッチンにおける IH ヒーターと流し台の位置の区別がなくなることが原因として考えられる。しかし、全行動の平均 F 値は 90.2% となり、表 5 と比べても 1% 程度しか低下していないことがわかる。したがって、宅内の行動識別では誤差 1m 程度の安価な位置推定システムで十分可能であることが確認できた。

表 6 位置情報の粒度を粗くした場合 (最大誤差 1m) の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	93.5	96.7	95.1
食事	67.6	83.3	74.6
食器洗い	88.9	80.0	84.2
テレビ	68.0	56.7	61.8
読書	96.4	90.0	93.1
入浴	93.8	100.0	96.8
掃除	96.7	96.7	96.7
仕事・勉強	100.0	100.0	100.0
睡眠	100.0	100.0	100.0
外出	100.0	100.0	100.0
平均	90.5	90.3	90.2

表 7 電力情報の属性数を削減した場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	90.9	100.0	95.2
食事	74.2	76.7	75.4
食器洗い	93.1	90.0	91.5
テレビ	57.7	50.0	53.6
読書	76.7	76.7	76.7
入浴	100.0	96.7	98.3
掃除	93.3	93.3	93.3
仕事・勉強	96.8	100.0	98.4
睡眠	100.0	100.0	100.0
外出	96.8	100.0	98.4
平均	87.9	88.3	88.1

3.2.3 消費電力情報の粒度が与える影響について

機械学習に用いた特徴量は、位置情報 (x 座標, y 座標) の中央値, 各家電の電力データ (各部屋の照明とエアコン, テレビ, オーディオ, PC, IHクッキングヒーター, 冷蔵庫, 炊飯器, 電子レンジ, 給湯器, ドライヤー, 掃除機, 洗濯機) の平均値であり, 属性数は合計 18 である. 低コストでの実現のためには, 電力計は少数の方が望ましい. そこで, 電力情報の属性数を削減した場合の認識精度の変化について評価する. Weka の属性選択機能を使用し, 最良優先探索により行動認識に有用な属性を抽出した. その結果, 位置情報 (x 座標, y 座標) の中央値と, 電力に関しては, リビングの照明, 洗面所の照明, テレビ, IH ヒータ, 掃除機, オーディオが有用であることが確認できた. これらの特徴量を使用した場合の Random Forests による識別結果を表 7 に示す. 平均 F 値は 88.1% となり, 属性数を 18 から 8 に削減したが, 認識精度は 3% しか低下していない. つまり, 電力計を全ての家電に取り付ける必要はなく, 抽出した 6 種類の電力データを使用することで生活行動の認識は十分可能であることが確認できた.

また, 本実験では各家電に電力計を取り付けているが, 追加の実験として, 各部屋に 1 つの電力計が設置されていることを想定し, 部屋ごとの消費電力を足し合わせた電力データを教師データに使用した場合における認識精度への

表 8 消費電力データの粒度変更

LDK	照明, エアコン, テレビ, オーディオ IHヒータ, 電子レンジ, 炊飯器, 冷蔵庫
寝室	照明, エアコン, PC, 掃除機
その他	照明, 給湯器, 洗濯機, ドライヤー

表 9 消費電力データの粒度を 3 部屋とした場合の評価結果

生活行動	Precision(%)	Recall(%)	F 値 (%)
料理	93.5	96.7	95.1
食事	66.7	80.0	72.7
食器洗い	96.6	93.3	94.9
テレビ	50.0	46.7	48.3
読書	80.0	66.7	72.7
入浴	90.3	93.3	91.8
掃除	92.6	83.3	87.7
仕事・勉強	93.8	100.0	96.8
睡眠	100.0	100.0	100.0
外出	96.8	100.0	98.4
平均	86.0	86.0	85.8

表 10 各センサデータの粒度ごとの平均 F 値

	消費電力データの粒度		
	各家電 (16 個)	6 個の家電	3 部屋
位置推定誤差: ~0.1m	91.3%	88.1%	85.8%
位置推定誤差: ~1m	90.2%	87.1%	84.5%

影響を評価する. 部屋はリビングダイニングキッチン, 寝室, その他 (浴室, 洗面所など) の 3 つに分割し, 表 8 に示すように各家電の消費電力データを足し合わせる. 電力計の精度を 3 部屋として意図的に精度を低下させた場合の評価結果を表 9 に示す. 平均 F 値は 85.8% となり, 各家電に電力計を取り付けた場合の平均 F 値である 91.3% から数% しか低下していない. つまり, 家庭での基本的な生活行動の認識には, 各家電の消費電力データは必要なく, 部屋単位での消費電力データと位置情報を組み合わせること, ある程度識別可能であることがわかった.

3.2.4 各センサデータの粒度ごとの評価結果

位置センサおよび電力計のデータの粒度ごとの平均 F 値を表 10 に示す. 電力計のデータの粒度は, 全ての家電 (16 種類), 前述の抽出した 6 種類の家電, 3 部屋の 3 パターンを用意し, 位置情報の粒度は高精度の位置センサ (位置推定誤差: ~0.1m) と, 前述のセルによる分割 (位置推定誤差: ~1m) の 2 パターンを用意した. 各センサデータの粒度を粗くするほど, 認識精度が悪化していることがわかる. しかし, 両方のセンサデータの粒度を最も粗くした場合 (位置推定誤差: ~1m, 電力計: 3 個) でも平均 F 値は 84.5% となり, 粒度が最も細かい場合の 91.3% と比べても, 7% の低下にとどまっている. つまり, 家庭内における生活行動は, 今回の実験で使用したような高価な高精度の位置推定システムや全ての家電の消費電力データは必ずしも必

要ではなく、誤差 1m 以下のおおまかな位置が検出できる低コストの位置推定システムと、各部屋の消費電力データを併用することである程度高精度に認識可能であることが確認できた。

4. おわりに

本稿では、スマートホームにおいて取得したセンサデータを用いて機械学習により居住者の生活行動を識別するシステムを提案した。提案システムでは、住人のプライバシーの確保や導入・維持コストを抑えるために電力計と屋内位置センサのみを使用した。予備実験では教師データのサンプル長、特徴量の種類、機械学習アルゴリズムの様々な組み合わせを試し、最も認識精度が高い組み合わせを決定した。さらに、導入コストの抑制を想定し、屋内位置センサの精度や使用する電力センサの数といったセンサデータの粒度が生活行動の識別精度に与える影響について調査する評価実験を行った。結果、10種類の行動に対して、センサデータの粒度が最も細かい場合（位置推定誤差：～0.1m, 電力計：16個）では91.3%、最も粗い場合（位置推定誤差：～1m, 電力計：3個）では84.5%の識別精度が得られた。この結果から、提案手法により宅内の基本的な行動に対して90%以上の高い識別精度を達成できることに加え、センサデータの粒度が粗い安価なセンシングシステムを用いた場合でも、80%以上の識別精度が達成できることが分かった。

今後の予定としては、対象とする生活行動の種類を増やし、複合的な行動や複数人への対応も検討していきたい。その際に、認識精度を維持するために、行動の発生時刻や移動履歴などの新たな特徴量の使用を検討する。また、リアルタイムで行動を認識するためのオンラインアルゴリズムについても検討を進める。

謝辞

本研究は、戦略的情報通信研究開発推進事業(SCOPE:Strategic Information and Communications R&D Promotion Programme)の支援のもと行なった。ここに記して謝意を示す。

参考文献

- [1] J. Scott, B. Brush, J. Krumm, B. Meyers.: "PreHeat: Controlling Home Heating Using Occupancy Prediction," in Proc. of UbiComp 2011.
- [2] B. Sean, M. Aditya, I. David, S. Prashant.: "SmartCap: Flattening Peak Electricity Demand in Smart Homes," Proc. of Percom 2012, pp.67-75, 2012.
- [3] P. Rashidi, A. Mihailidis.: "A Survey on Ambient Assisted Living Tools for Older Adults," IEEE Journal of Biomedical and Health Informatics, vol.17, no.3, pp.579-590, 2013.
- [4] J. Kim, J.Soh, S.Kim, K.Chung.: "Emergency Situa-

- tion Alarm System Motion Using Tracking of People like Elderly Live Alone." Information Science and Applications(ICISA), 2013 International Conference on. IEEE, 2013.
- [5] J. Hoey, J. James.: "Value-directed human behavior analysis from video using partially observable Markov decision processes," IEEE transactions on Pattern Analysis and Machine Intelligence, vol.29, no.7, pp.1118-1132, 2007.
- [6] L. Fiore, D. Fehr, R.Bodor, AA. Drenner, G. Somasundaram, N. Papanikolopoulos.: "Multi-Camera Human Activity Monitoring," Journal of Intelligent and Robotic Systems, vol.52, no.1, pp-5-43, 2008.
- [7] L. Chen, C. Nugent and H. Wang.: "A Knowledge-Driven Approach to Activity Recognition in Smart Homes," IEEE Trans. on Knowledge and Data Engineering, vol.24, no.6, pp.961-974, 2012.
- [8] S.W Lee, K. Mase.: "Activity and location recognition using wearable sensors," IEEE Pervasive Computing, vol.1, no.3, pp.24-32, 2002.
- [9] 上田 健揮, 玉井 森彦, 安本 慶一: "スマートホームにおける複数のセンシングデータに基づいた生活行動データ抽出システムの提案," DICOMO2014 シンポジウム論文集, pp.1884-1891, 2014.
- [10] K. Ueda, M. Tamai, K. Yasumoto.: "A Method for Recognizing Living Activities in Homes using Positioning Sensor and Power Meters," The 2nd IEEE PerCom Workshop on Smart Environments: Closing the Loop, 2015
- [11] 総務省統計局: 平成 23 年社会生活基本調査, available from <<http://http://www.stat.go.jp/data/shakai/2011/>> (accessed 2014-12-01).
- [12] L. Song, Y. Wang.: "3D Accurate Location Stream Tracking and Recognition Using an Ultrasound Localization System," Proc. of the 2011 International Conference on Indoor Positioning and Indoor Navigation, 2011.
- [13] 上田 健揮, 大木 浩武, 水本 旭洋, 玉井 森彦, 安本 慶一: "複数のセンシングデータの可視化および関連付けによる生活行動の理解支援システム," 第 21 回マルチメディア通信と分散処理ワークショップ (DPSWS2013) 論文集, pp.116-118, 2013.
- [14] Weka 3:Data Mining Software in Java, available from <<http://www.cs.waikato.ac.nz/ml/weka/>>(accessed 2015-01-20).