スマートホームにおける先行行動の継続時間分類に基づく行動予測手法の検討

Daily Living Activity Prediction in Smart-Home based on Activity Duration Classification

佐々木 渉 † 藤本 まなと † 荒川 豊 † 安本 慶一 †
Wataru Sasaki Manato Fujimoto Yutaka Arakawa Keiichi Yasumoto

1. はじめに

近年，宅内での人の位置を推定し，その推定した位置情報を元に動作するサービスが多く登場している．例えば，家に人がいる時間帯やその人が設定する温度の好みを学習して自動で快適な温度設定を実現する Nest Thermostat[1]や，人やモノの位置を検知し，その位置にしぼって冷暖房の風向き変更を行う ECO NAVI[2]がある．このようなサービスは人の位置を特定することによって，今まで消費していた電力を削減できることや空調温度や風向など機械による自動制御をすることで生活がより快適になることを目指している．

宅内での位置の推定のみでなく，人の行動認識を行う研究も多く行われている．例えば，位置情報センサや電力センサの情報を特徴量として使用し，宅内での日常生活における行動の認識を行う研究 [1] がある．このような研究は，日常生活における行動認識を行うことで，現在の行動に関して，自動的に家電を制御するようなサービスを提供することを目指している．例えば，リビングで TV を見ている時に，寝室の照明がついている場合，寝室の照明の消費電力は無駄遣いであると認識して，自動で寝室の照明を消すようなサービスが考えられる．

しかし，行動の認識のみでは，次に起こる行動を見通したサービス提供はできない．例えば，夏の暑い日の夜寝る前にエアコンで寝室を涼しくしておこうと思い，スイッチを入れたとする．しかし，行動認識の結果，人はリビングにいるので，無駄遣いと判断してエアコンの電源を消してしまうかもしれない．つまり，寝る前に自動で寝室を涼しくしてくれるようなサービスを実現するには，行動予測は必要不可欠である．また，行動の予測を行うことは省エネにも効果が期待できると分析されている [2].

行動予測を行うためのアプローチとして，行動のパターン（料理をした後は食事をとる，食事をした後は食器洗いをするなど）や行動が起こる時間帯（3 時にはおやつを食べる，夜にはお風呂に入るなど）を分析することで予測できるのではないかと考えている．

また，行動時間の長さの違いによる行動予測手法が可能かもしれない．このアプローチでは，例えば晩御飯を食べるときを考えると，他にやらなければならない作業が残されている時には，急いで食事を済まし，その作業に時間を費やす．一方で，特にやることがなければ，ゆっくりと食事を済ませ，TV やゲームなどの余暇の時間に当てると考えられる．このように同じ行動でも行動時間が変わることで次の行動が変化するという特徴に注目して，行動時間の長さの違いによる遷移確率を分析することで行動予測精度を向上させることができると考えた．

本稿ではスマートハウス内における行動継続時間分類に基づいた日常生活の行動予測を行う手法について検討を行う．

2. 関連研究

関連研究としては，先述した宅内行動認識の研究が挙げられる．例えば上田ら [1] は超音波位置センサや電力センサの情報を特徴量として使用し，宅内での日常生活における 10 種類の行動を平均 91.3%で認識している．しかし，超音波位置センサは非常に高価であり，一般家庭への導入は難しい．また，柏本ら [3] は焦電型赤外線センサとドア開閉センサを行動認識に使用することで，宅内での日常生活における 20 種類の行動を 68.6%で認識している．これらの研究の成果として，様々なセンサ情報を用いて機械学習を行うことで，現在の行動を認識することは可能であるということがわかっている．そこで，このような行動認識の結果を利用して，現在の行動の判別を行い，その上で行動予測を行いたいと考えている．

行動予測の研究についてもいくつか行われている．石川 [4] はベイジアンネットワークによる幼児の行動を予測する研究を行なっている．具体的には，魚眼カメラによる画像と超音波センサによる位置情報を基に 8 種類の行動を予測している．しかし，カメラを使用するのはプライバシーの問題があることや，予測できる行動の種類が 8 種類と少ないことが問題である．本稿の提案手法ではカメラを使用せずに，16 種類の行動を予測する．また，下坂 [5] は人間行動センシングデータに基づく生活リズムを解析する研究を行なっている．この研究では，独居高齢者宅の玄関，台所，寝室，廊下，部屋の 5 箇所に設置された焦電センサのデータ 3ヶ月分を使用して，被験者の生活リズムについて分析している．この手法では，焦電センサによる反応回数のみを収集しているので，行

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

[1] Nest Thermostat: https://nest.com/
[2] ECO NAVI: http://panasonic.jp/aircon/16feature/econavi/

動の種類までは判別することができない．私たちは位置情報のみではなく，行動を予測する．

3. 提案手法

3.1 課題

宅内における行動認識では以下の 5 つのような課題の解決が望まれている．[6]

(a) 監視機器を設置することによるプライバシーの侵害
(b) 認識が可能な行動の種類の少なさ
(c) 行動認識そのものの精度の低さ
(d) 認識を行うための機器やその維持コストの高さ
(e) 認識ができるまでの時間の長さ

この 5 つの課題の解決は，行動予測おいても同様に解決する必要があると考え，行動に費やす時間の差による行動遷移の違いを分析する手法を考えた．図 1 に食事における行動時間の分布イメージを示す．人の生活リズムは基本的にはパターン化されており，通常の食事では食事に費やす時間の平均時間に近い時間かかると考える．しかし，まれに忙しくて食事にかける時間が少ない場合や，酔っ払っていて食事にかける時間が長い場合がある．これらを統計すると，宅内行動における時間の分布は平均時間付近を中心として山なりに分布しているのではないかという仮説を立てることができる．行動の時間が通常とは異なる時はその時の人の状態（忙しい，眠たい，酔っているなど）が関与していると考えられる．例えば，食事や風呂などを考えると，忙しい時はより短い時間で済ませ，眠たい時や酔っている時は長い時間かかる．また，その後に予想される次の行動もまた，状態によって左右される．そこで，本稿では宅内行動の時間分布を元に分析を行うことで，行動予測確率を上げる手法を検討する．

3.2 本稿で提案する手法

まず各行動の行動時間 *Time(T)* と行動から行動への遷移確率を算出する．また，行動ごとの平均行動時間 *Mean Time(MT)* と標準偏差 σ を算出する．その計算結果に対して，2 つのパターンで行動の分類を行う．

1 つ目は (1) 平均時間 *Mean Time(MT)* を境に行動時間 *Time(T)* がそれより短ければ *Short(S)* とし，それより長い時間であれば *Long(L)* と分ける分類である．

(a) $Short(S) : T \leq MT$
(b) $Long(L) : MT < T$

2 つ目は (2) 標準偏差 σ を元にした，3 つの行動時間範囲での分類である．行動時間 *Time(T)* が平均行動時間 *Mean Time(MT)*$\pm$ 標準偏差 σ の範囲内の時間であれば

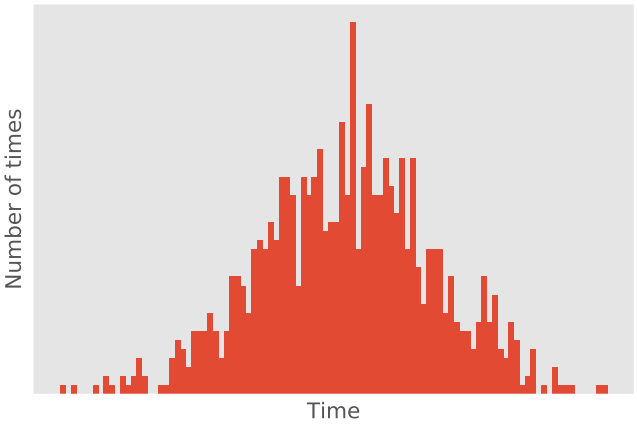

図 1: 食事における行動時間の分布イメージ

Middle(M) とし，それより短い時間であれば *Short(S)*，それより長い時間であれば *Long(L)* と分類する．

(a) $Short(S) : T < MT - \sigma$
(b) $Middle(M) : MT - \sigma \leq T \leq MT + \sigma$
(c) $Long(L) : MT + \sigma < T$

これら 2 つの時間分類で行動遷移を分析することにより，分類しなかった場合の行動遷移より予測確率が上がるかどうかを検証する．(1) の分類では行動時間が長いか短いかだけに注目しているが，(2) の分類で平均的な行動時間だった場合にどのような行動遷移が起こるのかを見ることができる．

4. データ収集

実験は，奈良先端科学技術大学院大学が保有するスマートホーム設備（1LDK）で行った．4 人の被験者に 1 人あたり 3 日間ずつスマートハウスで生活をしてもらい，計 12 日間のデータを集めた．なお事前に，各被験者にはあらかじめ定義した 16 種類の行動（料理: Cooking，食事: Meal，掃除: Cleaning，睡眠: Sleeping，外出: GoOut，長時間外出: LongGoOut，食器洗い: WashDishes，PC，入浴: Bath，テレビ視聴: TV，読書: Reading，風呂掃除: CleaningBath，テレビゲーム: Game，スマホ操作: Smartphone，洗濯: Laundry，洗面: WashFace）をできるだけ 1 日 1 回以上，3 日間の中で最低 1 回以上行ってもらうように依頼している．さらに，宅内をカメラで撮影しておき，被験者各自が 10 秒おきの行動についてラベル付けをしてもらった．定義された行動以外の行動については「その他」とラベルづけした．スマートホーム内のトイレは使用できないため，「トイレ」という行動は「外出」の中に含まれている．なお，撮影した動画データに関しては，プライバシーの問題から，当人のみが確認できるように配慮している．

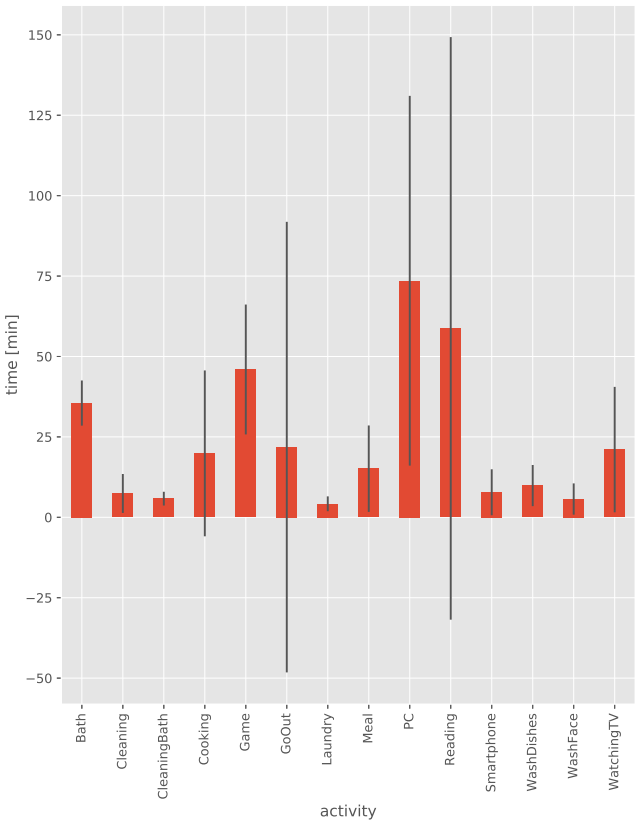

図 2: 分析した行動の平均時間と標準偏差

5. データ分析

5.1 分析の概要

今回の分析では，集めた 12 日間のデータの中から，データが正常に取れていた 10 日間のデータを使用して分析を行った．定義した行動の遷移確率を見るため，ラベルが「その他」とラベルづけされていたデータは前の行動をそのまま継続していたとして，データの処理を行った．また，図 2 にそれぞれの行動の平均時間と標準偏差を示す．なお，外出，睡眠の行動時間は他の行動に比べて長いため除いている．標準偏差について注目すると，料理，食事，掃除，外出，テレビ視聴，読書は分散が大きいことがわかり，行動時間にばらつきがあることがわかる．分散が大きいと，標準偏差も大きくなり (2) の分類で *Short* または *Long* と判定される行動数が少なくなってしまう．

5.2 食器洗いから次の行動への行動遷移確率

そこで，今回は行動時間の分散が平均的な食器洗いに注目した．図 3(a) に食器洗いにおける通常の行動遷移確率を，図 3(b) に標準偏差によって二段階分割した時の遷移確率を，図 3(c) に標準偏差によって三段階分割した時の遷移確率を示す．図 3(a) では 8 種類への行動への遷移確率が示されており，特に遷移確率の高い遷移先は見当たらない．一方で，図 3(b) では *Short* での行動の遷移先は 7 つ，*Long* での行動の遷移先も 6 つである．特に，掃除は *Short* でのみ存在しており，読書は *Long* でのみ存在している．この 2 つの行動に関しては，時間的な区別ができていることになる．また，図 3(c) では *Short* での行動の遷移先は 3 つ，*Long* での行動の遷移先も 3 つである．特に，読書は *Long* でのみ，洗濯と洗面は *Middle* でのみ遷移先として存在する．こちらも同様に 3 つの行動の時間的分割ができたといえる．これらより，行動時間は，行動の遷移先選択に影響しているのではないかと考えることができる．一方で，TV やテレビゲームのように行動時間が長くても短くても遷移するような行動もあることがわかる．

表 1 に食器洗いから次の行動への遷移確率を示す．食器洗いから掃除への遷移に注目すると，分類しない場合では 15%で遷移しているが，平均による 2 段階分類では *Short* の場合に 25%で遷移しており，分類する前と比べて 10%向上している．さらに，標準偏差による 3 段階の分類では *Short* では 33%，*Long* では 15%で遷移することがわかり，*Short* の場合は 18%向上している．これより，遷移の確率が 2 倍近く上がったことがわかる．一方で，食器洗いから PC への遷移に注目すると，分類なしの場合は 5%の確率で遷移しているが，平均による 2 段階分類では *Short* の場合に 8%で遷移しており，3%しか向上していない．同様に，標準偏差による 3 段階の分類でも *Middle(M)* の場合に 8%で遷移しており，3%しか確率が向上していない．これは，食器洗いから PC に遷移した行動の遷移回数が少なく，平均時間に近い場合の遷移だったためである．つまり，低い確率で遷移する行動や平均時間に近い時間で遷移する行動では確率の向上が期待できないことがわかる．

5.3 全ての行動における行動遷移確率

また，表 2 に全ての行動の行動時間による分類によって遷移先をどう分けられたかを示す．*Short* でまたは *Long* での遷移先が一つの場合であるところに注目すると，その行動時間をかけて行われる動作が次の行動を予測するために大きな可能性があることを示していると読み取れる．しかし，料理，食事，掃除，外出，長時間外出，読書のように，元の行動遷移の種類と分割後の種類が一致しているようなものも見られる．これより，この手法は全ての行動に対して，一律に行動予測の精度を上げることはできない．

これらの結果より，行動に費やす時間を二段階もしくは三段階に分割することで，短い食器洗いの時間であれば，次の行動は掃除である可能性が高いなど，行動遷移に特徴が現れることがわかった．

(a) 分類前

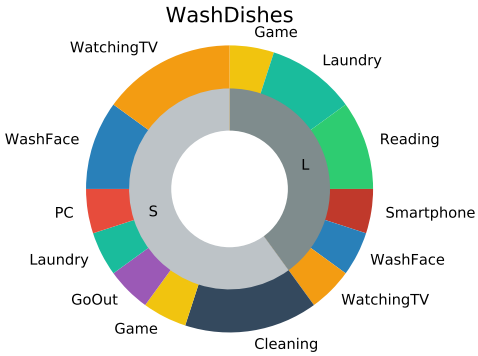

(b) 平均時間による 2 段階分類

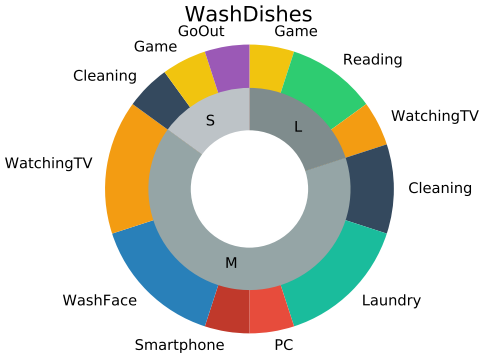

(c) 標準偏差による 3 段階分類

図 3: 食器洗いからの行動遷移確率

表 1: 食器洗いから次の行動への遷移確率

行動	遷移先の行動の種類					
	分類なし	平均分類		標準偏差分類		
		S	L	S	M	L
料理	0	0	0	0	0	0
食事	0	0	0	0	0	0
掃除	0.15	0.25	0	0.33	0.15	0
睡眠	0	0	0	0	0	0
外出	0.05	0.08	0	0.33	0	0
長時間外出	0	0	0	0	0	0
PC	0.05	0.08	0	0	0.08	0
入浴	0	0	0	0	0	0
テレビ視聴	0.2	0.25	0.13	0	0.23	0.25
読書	0.1	0	0.25	0	0	0.50
風呂掃除	0	0	0	0	0	0
テレビゲーム	0.1	0.08	0.13	0.33	0	0.25
スマートフォン	0.05	0	0.13	0	0.08	0
洗濯	0.15	0.08	0.25	0	0.23	0
洗面	0.15	0.17	0.13	0	0.23	0

表 2: 行動の回数と行動遷移の変化

行動	回数	遷移先の行動の種類					
		分類なし	平均分類		標準偏差分類		
			S	L	S	M	L
料理	24	6	6	2	-	6	1
食事	20	3	3	1	-	3	1
掃除	9	4	4	1	-	4	1
睡眠	8	3	2	2	1	3	1
外出	26	9	9	3	-	9	1
長時間外出	10	2	2	1	-	2	1
食器洗い	20	9	7	6	3	6	3
PC	17	8	6	4	2	6	3
入浴	9	5	3	3	1	4	1
テレビ視聴	16	7	6	4	-	6	3
読書	13	5	5	3	-	5	1
風呂掃除	5	5	4	1	-	4	1
テレビゲーム	8	5	4	2	1	4	1
スマートフォン	24	10	7	6	1	9	3
洗濯	14	8	6	4	1	7	2
洗面	21	8	6	5	1	7	2

6. まとめ

本稿では，行動に費やす時間の違いによる行動遷移の違いを分析する手法を新しく提案した．行動時間を長さで (1) 平均時間による二段階分割 (Short, Middle) と (2) 標準偏差を利用した三段階分割（Short, Middle, Long）の 2 パターンによって分類し，行動遷移確率を分析した．結果としては，行動時間が行動の遷移先に関係している行動はいくつかあり，行動時間ごとの分類によって遷移先が変化することが分かった．また，全ての行動に対して分類をすることで，遷移特性が変わるわけでないということもわかった．

しかし，今回の実験では，10 日間のデータを使用しており，データ数が不十分であったために，行動によっては十分なサンプル数が確保できなかった．また，今回は被験者 4 人のデータを累計して分析を行ったため，行動時間による違いか個人の生活リズムによる違い（入浴が短い人は風呂上がりにゲームをして，入浴が長い人は風呂上がりに読書をするなど）か判別できない場合があった．

今後の展望としては，まずは多くのテストデータを用意することが必要だと考える．テストデータを多くすることで，より様々な状況でのデータが取れ，予測精度が上がっていくと考える．さらに，特定の個人を対象としたデータが増えることで，個人の生活リズムパターンを分析することができ，対象者に限定して，どのような状態であれば次の行動が何かを分析していくことができるので，より精度を上げることができると考えている．

そして，今回提案した手法を行動予測の一つの手段として取り入れることで，行動予測精度がどのように向上するのかを検証していきたい．

参考文献

[1] 上田健揮, 玉井森彦, 荒川豊, 諏訪博彦, 安本慶一ほか. ユーザ位置情報と家電消費電力に基づいた宅内生活行動認識システム. 情報処理学会論文誌, Vol. 57, No. 2, pp. 416–425, 2016.

[2] Manu Gupta, Stephen S Intille, and Kent Larson. Adding gps-control to traditional thermostats: An exploration of potential energy savings and design challenges. In *International Conference on Pervasive Computing*, pp. 95–114. Springer, 2009.

[3] 柏本幸俊, 秦恭史, 中川愛梨, 諏訪博彦, 藤本まなと, 荒川豊, 繁住健哉, 小宮邦裕, 小西健太, 安本慶一ほか. エナジハーベスト焦電型赤外線・ドア開閉センサと家電消費電力に基づいた宅内生活行動認識システム. 情報処理学会論文誌, Vol. 58, No. 2, pp. 409–418, 2017.

[4] 石川詔三. 日常生活行動における確率的因果構造モデルの構築と行動推論. 人工知能学会全国大会, 2008, 2008.

[5] 下坂正倫. 人間行動センシングデータに基づく生活リズム解析. 計測と制御, Vol. 53, No. 7, pp. 611–616, 2014.

[6] Eri Nakagawa, Kazuki Moriya, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Toward real-time in-home activity recognition using indoor positioning sensor and power meters. In *Pervasive Computing and Communications Workshops (PerCom Workshops), 2017 IEEE International Conference on*, pp. 539–544. IEEE, 2017.