

移動型センサーを想定した家庭内行動検出手法

中原 啓太¹ 山口 弘純¹ 東野 輝夫¹

概要：本研究では、お掃除ロボットや見守りロボットなど、現在および将来において一般家庭に普及が進むロボットに Microsoft Kinect を付加し、高齢者の骨格認識に基づいて日常行動 (ADL) を推定し、各行動内における運動量蓄積を行うための手法を提案する。本手法では Kinect を用いた人追跡は実現できているとの前提で、ロボットが高齢者の周辺に移動し、側面など正面でない角度から得られる 3D 深度情報から関節検出を行い、身体のパーツ (体幹 (頭部, 頸部, 胸部, 腹部, 尾部) および体肢 (上肢 (上腕, 前腕) および下肢 (大腿, 下腿)) を検出したうえで、現在どのような日常行動を行っているかの認識ならびにその日常行動における 3 次元空間でのパーツの運動量を測定する。骨格認識には既存のソフトウェアを活用するが、ロボットは必ずしも高齢者を正面から捉えられるわけではないため、提案手法では正面以外の角度から測定した値に基づく行動認識アルゴリズムならびに運動量取得を検討している。実家庭における実験の結果、歩行のような特徴のある行動の認識に関しては高い精度で認識することができた。また、日常行動の認識とともに歩行速度や歩幅、手の速さや腕の回転角速度などの運動量取得にどの程度の誤差が生じるかを確認した。

A Study on In-home Activity Recognition Using Mobile Sensors

KEITA NAKAHARA¹ HIROZUMI YAMAGUCHI¹ TERUO HIGASHINO¹

1. はじめに

世界規模で人口が増加している一方、先進国では特に高齢化が進行している。我が国では世界に先駆けて高齢化が進んでおり、総務省統計局による平成 25 年現在の統計調査 [1] では、65 歳以上の人口比率が総人口の 25% に到達し、過去最高を記録している。また、高齢化と同時に少子化も進み、今後も人口構成における高齢者比率の一層の増加が避けられず、内閣府の平成 26 年版高齢社会白書によれば、2012 年における 65 歳以上の高齢者を含む世帯の 50% 以上は単身または夫婦世帯である。そういった現実もあり、老老介護などが社会問題となっている日本や先進諸国では、家族や近親者による介護や見守りに期待できないため、今後は高齢者が心身共に健康かつ健全で、医師や介護士に頼らず自立した生活をできるだけ長期にわたっておくってもらい、生活の質 (Quality of Life, QoL) を向上させることが、社会全体での介護福祉への負担を減らすために極めて

重要となる。

そのためには、生活習慣病などを防止し、日常から QoL を重視した積極的な生活指導やアドバイスを行うことも重要とされる。例えば我々は文献 [2, 3] において、高齢者を含む居住者の家庭内行動を検出および認識し、一日のタイムテーブルやそれに伴う電気使用量や運動量等から、省エネルギーや運動の推薦、更には家族間のコミュニケーションの促進を推薦するリコメンデーションを提案しており、クラウドソーシングによる調査を利用して、集合知を活用したりリコメンデーションルール構成と QoL 基準の設定を行い、実家庭における実証実験を実施している。また、近年大きな社会問題となっている認知症の予防も欠かせない。認知症は発症すると回復が困難である疾病であるものの、認知症の前段階である軽度認知障害 (Mild Cognitive Impairment, MCI) を早期発見することにより、認知症の発症をできる限り遅らせることができ、QoL の向上につながるとの報告もなされている [4]。さらに、MCI は早期発見によりその 10% が回復可能であり、40% は改善可能であることも知られている。

¹ 大阪大学 大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

日常生活における行動 (Activities of Daily Living, ADL) においてどの程度の活動量であるかを把握することは、健康維持のみならず、異常検知の重要な指標となる [5]。例えば MCL の兆候として、肉体的な身体運動能力の低下、および無気力に起因する活動量低下があげられており MCL 患者は歩行速度が 80cm/s 以下になるとの報告もある [6]。したがって、例えば毎日の食事など自然な行動における腕の振りの速度や回数、調理中の移動歩数、廊下における歩行速度などを数値データとして記録すれば、そういった身体能力低下を客観的なデータとして記録でき、デイケア施設や医師による異常検知の判断の目安にもなり得るため、そういった「運動能力指標」を日常生活の様々な行動の中で自然に測定できることが望ましい。これに対し、高齢者にモーションセンサーを装着し、運動量を測定する方法も多く行われているが、侵襲性の問題から現状では適切でない。また、箸や食器等にセンサーを内蔵する方法も行われている [7] もの、様々な状況で利用されるモノが発する大量のデータの中から個人の運動を特定し運動量を把握することは容易でない。一方、Kinect などの 3D センサーを家庭内に設置し、高齢者の行動を把握することは容易で正確な方法であると考えられるが、家庭内の様々な部屋や場所における日常生活行動をとらえるために多数のセンサーを多数の場所に設置することは望ましくなく、プライバシーの観点からも適切でない。また家具の移動などによりセンサー視野に遮蔽が発生する状況も考えられる。したがって高齢者の位置をトラックして適切な位置から適切なタイミングで行動を把握し、運動指標データを蓄積できるスキームが望まれる。

本研究では、お掃除ロボットや見守りロボットなど、現在および将来において一般家庭に普及が進むロボットに 3D センシング機器を付加し、高齢者を認識・追跡して日常行動を把握し、その各行動内における運動量蓄積を行うための手法を提案する。本手法では 3D センシングによるロボット人追跡は実現できるものとの前提で、ロボットが高齢者の周辺に移動し、横など正面でない角度から得られる 3D センサーデータから関節検出を行い、身体のパーツ (体幹 (頭部、頸部、胸部、腹部、尾部) および体肢 (上肢 (上腕、前腕) および下肢 (大腿、下腿)) を検出したうえで、現在どのような日常行動 (食べる、飲む、電話する、歩く、書く、読む、掃除する、料理する) を行っているかの認識、ならびにその日常行動における 3 次元空間での移動量を測定する。測定には既存の kinect 用骨格認識ソフトウェアを活用するが、ロボットは必ずしも高齢者の正面に移動できるわけではないため、正面以外の角度から測定した値に基づき認識ならびに運動量取得を行う。

実家庭における 3 人の被験者を対象とした行動認識試験ならびに運動量取得実験を行った結果、歩くや飲食などの行動には平均して 6 割を越える精度で認識を行うことがで

きた。全ての行動に対しては約 5 割の認識精度であった。また、評価指標に対して身体の運動量取得がどの程度正確に抽出することができるかを確認した。

2. 関連研究

文献 [8] では、kinect の骨格認識技術とその実装が述べられている。同手法では、深度画像から素早く正確に関節認識および位置推定を行う手法として kinect for Windows SDK ライブラリに実装されており、本研究ではこの手法およびライブラリを用いている。文献 [9] では、kinect を用いた行動認識の際、オクルージョン (遮蔽) による骨格推定の誤りを補正する手法を提案しており、文献 [10] では、通常ライト下および赤外線ライト下のもとの web カメラからの映像、ならびに kinect からの深度画像において、行動認識を行う技術を開発し、昼夜を問わず行動認識を行う方法を提案している。また、[11] は深度画像を用いてキッチンにおける詳細な行動認識手法を提案するなど、深度画像を用いたアプローチは kinect の低価格さも相まって以前から注目を集めている。

今日、家庭エネルギー管理システム (HEMS) を導入することによって、人々の生活をより快適にするスマートホームに関する様々な研究が行われている。スマートホームは家電や設備機器などの最適な制御を行うことで居住者の要求に応じた生活環境の実現を目指すことから始まり、現在では進歩した IT 技術を導入することで、生活支援に関するサービスがより一層拡大しつつある。我々の研究グループでは、文献 [2,3] において、家電や家庭用バッテリー、電気自動車などの稼働状況をモデル化することによる生活改善指標の定量化と家庭内に設置した赤外線センサーやコンセントの使用状況から行動を推定し、算出した生活改善指標と併せることで生活改善アドバイスを行うシステム SLSA を提案している。そういった家庭向けサービスの高度化のためにはスマートホームにおける居住者の行動認識が不可欠であり、そのためのシステムは以前より多く設計されている [12-16]。例えば文献 [13] では、赤外線のモーションセンサーを用いた行動認識の手法を提案しており、行動レベル、移動レベル、無行動期間といった特徴量を集計して SVM による行動推定を行っている。文献 [16] では RFID を用いた行動推定について提案している。[17] ではドアに設置したセンサーによる部屋レベルの家庭内追跡について述べている。文献 [18] は測域センサーを用いた家庭内行動センシングを行っている。

認知症予防や自立生活支援をターゲットとした取り組みも多くあり、例えば文献 [19] では、監視カメラと映像処理によって高齢者の自立生活支援とケアの効率化を図るアプローチを提案している。また、文献 [20] においては、マイクロコンテキストの取得といった観点から認知症発見の可能性について議論しており、文献 [4] では軽度認知障害の

行動からの発見方法を述べている。

これに対し、本研究では、定点センサを利用せず、お掃除ロボットなど家庭に普及する簡易なロボットに kinect センサを搭載し、移動体からの深度画像を想定した行動認識を行う点で前述の多くの手法とは異なる。日本の一般家庭は居住空間に余裕がそれほどなく、家具も多く見通しが悪い場合も考えられるため、画像センサーを天井に設置するなどの必要があり、行動認識技術の導入は容易でない。センサー位置に自由度を持たせ、制御された場所およびタイミングで高齢者の行動をとらえることができ、かつ行動内容までを把握することができれば、認識した行動の「マイクロアクション」をいわゆる運動ログとして蓄えることができ、日常生活における運動量や MCI の兆候検出、運動能力の低下を検知できる。

3. 想定環境

3.1 アプローチ概要

本研究では、日常生活動作と高齢者の日常生活に関する意識調査 [21] を基に多くの高齢者が日常的に行う行動を選択し、認識する対象行動とする。

日常生活動作とは日常生活を行っていく上で不可欠と考えられる行動と定義されており、食事・更衣・移動・排泄・整容・入浴などが挙げられる。家庭内でセンシングを行うにあたって、センサは居住者の安心・安全と快適な暮らしを実現すべき手段であり、不快感を与えたり生活の妨げになってはいけないことを考慮し、日常生活動作からは「食事」と「移動」を取り上げる。また、高齢者の日常生活に関する意識調査は全国の高齢者 6000 人に対し行われた調査であり、日常生活の状況、生活の満足度、衣食住をはじめ、家事、外出、日常的楽しみ、日常生活の情報に関する満足度など、高齢者の日常生活全般の意識について回答を集めたものである。これらの項目のうち、生活を送る上で楽しみとする行動について意見を集計した「日常的楽しみ」に着目し、家庭内で行われやすい行動として「読む」、「書く」を選択した。さらに、家事を含めた 8 種類の生活行動（食べる (Eating)、飲む (Drinking)、調理する (Cooking)、読む (Reading)、書く (Writing)、電話する (Calling)、掃除する (Cleaning)、歩く (Walking)) を図 1 に示し、本研究での認識対象の行動とする。

また、日常行動の身体状態として、図 2 に示す 4 状態を想定する。起立状態 (Standing) は脚を伸ばして身体を支えている状態、着座状態 (Sitting) は椅子などに腰かけている状態、平臥状態 (Lying) は場所に関わらず横になっている状態であり、移動状態 (Moving) は身体の重心が移動している状態とする。状態は Standing, Sitting, Lying の間で遷移し、Moving へは Standing からのみ遷移するものとする。前述の Eating, Drinking, Reading, Writing, Calling




図 1 提案手法で扱う認識対象の日常行動




図 2 想定する行動状態

は状態 Sitting で、Walking は状態 Standing で、Cooking, Cleaning は状態 Standing でそれぞれ実行されるとする。また、状態 Sitting での行動は、Eating を除き、片手で行うものと両手で行うものに区別する。以上から、身体状態遷移と各状態で取りうる行動の関係を図 3 のように定義し、この前提のもとで 8 種類のいずれかの行動が行われている時間を推定する。

図 1 にみられるように、身体状態や行動ごとに体幹および体肢の位置関係は大きく異なる。本研究では kinect と骨格情報ライブラリにより取得した対象者の身体の関節位置情報を利用し、身体の上腕、前腕、背骨、大腿部、膝下などの関節間をベクトルとみなし、関節位置情報からベクトルを計算する。骨格位置情報 (図 6) や各ベクトル (図 7) から身体状態を推定し、閾値ベースに基づく行動分類を行う比較的シンプルな方法を採用する。行動 action を認識すると、その行動が実施された時間 time の組 (action, time) を行動ログに蓄積する。加えて、各行動において実施された運動 (腕の上下運動など) を表す指標を定義し、モーショ

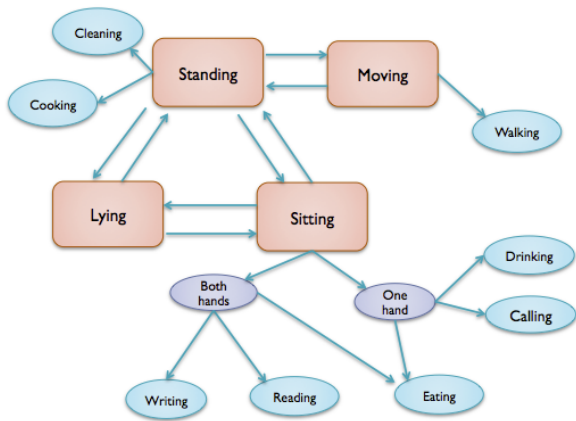


図 3 状態遷移と行動のフロー図

ンログに蓄積する。モーションログは、

(*walking_speed*,
step_size,
angle_velocity[upperarm][left],
angle_velocity[upperarm][right],
angle_velocity[forearm][left],
angle_velocity[forearm][right],
hand_speed[left],
hand_speed[right],
time)

の 9 項組で構成する。これらは 4.4 節で定義する。

3.2 システム構成と移動型センサ

本研究で試作するシステム HALS (Health and Activity Logging System) の構成を図 4 に示す。HALS は iRobot 社製のロボットである Roomba にセンサとして kinect v2, Microsoft Surface Pro4 および kinect へ電源供給を行うためのバッテリーを搭載する (図 5)。kinect を三脚に取り付け roomba の上に載せた構成となっており。三脚と roomba の接着はグルーガンで行っている。また、センサは三脚と roomba の上に載っていることにより高さが約 60cm となっている。

Roomba などのお掃除ロボットは 2020 年には国内の市場規模が 100 万台を超えると予想されており [22], kinect は RGB カメラや赤外線カメラによる安価で高精度なセンサーとして利用可能である。本研究ではプライバシーを考慮し、RGB カメラは利用することなく、赤外線を物体に投光しその反射時間から求められた深度画像により得られる図 6 の 25 の骨格について、骨格毎の 3 次元座標を利用する。なお、kinect v2 は人検出距離範囲が 500mm-4500mm, 水平視野角 70 度, 垂直視野角 60 度という測定範囲が制限されているため、設置型の測定であれば観測空間に制約を受けるが、kinect を自立移動可能な Roomba に搭載することで空間的な課題を解決する。Surface は kinect を接続し、

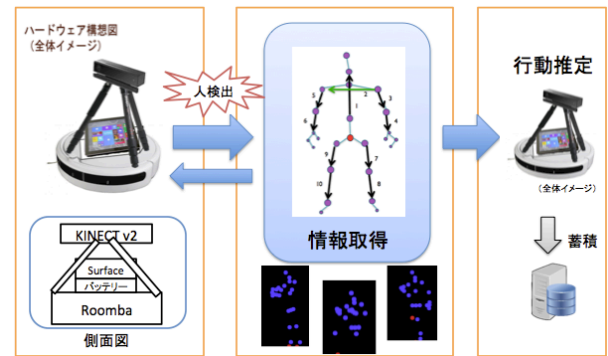


図 4 HALS 構成図



図 5 HALS 試作品

収集した被観測者の骨格情報から身体状態および行動を認識するとともに、身体各部分のモーションベクトルの変化をログする。なお、データの取得頻度は 200ms に 1 回取得している。

4. 動作特徴抽出と行動認識

4.1 骨格ベクトルの抽出

本研究では行動認識や運動能力把握のため、身体の関節を結んだベクトルによって表現し、身体各部を想定したベクトルから得られる角度や移動量などを用いる。kinect を利用すると図 6 に示すように体の中心線上の 5 カ所と両腕両脚を合わせた合計 25 カ所の関節 i ($i = 0, 1, \dots, 24$) について 3 次元座標を取得することができる。本節では、図 7 に示す 10 本の関節間を結んだ骨格ベクトル V_j ($j = 0, 1, \dots, 9$) の抽出方法について述べる。

3 次元空間の座標軸は kinect から対象者に向かって水平方向左向きに x 軸、鉛直方向上向きに y 軸、奥行きに z 軸が

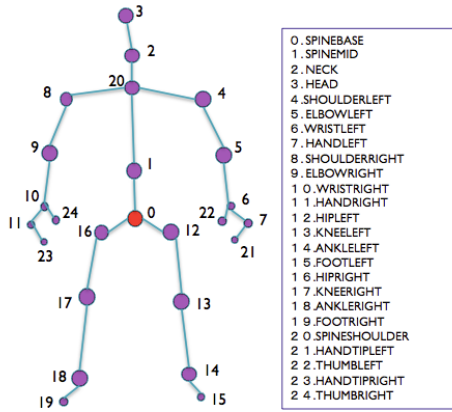


図 6 kinect により取得可能な関節と呼称

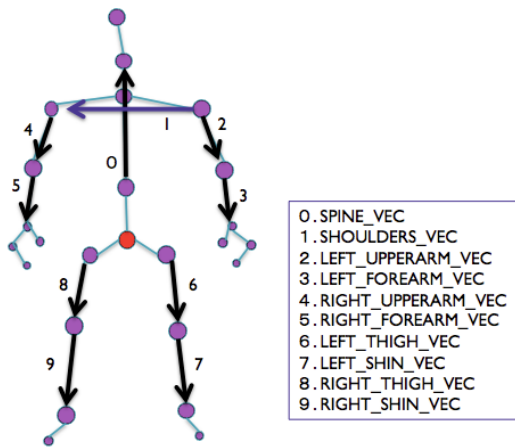


図 7 骨格ベクトルと呼称

設定されており、それぞれの関節 i について kinect に対する相対座標 $P_{i0} = (x_{i0}, y_{i0}, z_{i0})$ を取得することができる。本研究では、骨格ベクトル取得のため骨盤部分に当たる関節 SPINEBASE を基準とした相対座標 $P_i = (x_i, y_i, z_i)$ を用いるため、以下の式 (1) により得る。

$$P_i = P_{i0} - P_{spinebase} \quad (1)$$

式 (1) により算出した座標 P_i を用いて、骨格ベクトルの両端に当たる関節 i ($i = 2, 4, 5, 6, 9, 10, 13, 14, 17, 18$) に対して以下の式 (2) により骨格ベクトル V_j を得る。

$$V_j = \begin{cases} P_i - P_{i-1} (i \neq 4) \\ P_{i+4} - P_i (i = 4) \end{cases} \quad (2)$$

4.2 動作の特徴抽出

動作の把握と行動認識のための特徴として、2種類の角度(天頂角 θ 、方位角 ϕ)を用いる。図 8 のように天頂角 θ は y 軸の正の部分から成す角度 ($0 \leq \theta \leq \pi$) であり、方位角 ϕ は x 軸方向正の部分から成す角度 ($-\pi < \phi \leq \pi$) である。方位角については正と負の値を取るが、 z 座標が負の値のとき $\phi < 0$ となり、正の値のとき $0 < \phi$ となる。




図 8 天頂角 θ と方位角 ϕ

4.1 節の方法で取り出した関節の位置ベクトル V_j の x 成分、 y 成分、 z 成分を引数として式 (3) に与えることにより天頂角 θ を得る。天頂角は主に骨格ベクトルの上下の動きを把握するために用い、例えば、立ち状態や着座状態といった身体状態認識や腕の上下動の動作認識に用いる。

$$\theta(x, y, z) = \arccos \frac{y}{\sqrt{x^2 + y^2 + z^2}} \quad (3)$$

方位角 ϕ は式 (4) に対し関節の位置ベクトル V_j の x 成分、 y 成分、 z 成分と式 (3) により求めた θ を引数として与えることにより得る。正弦関数の逆関数 $y = \arcsin x$ は値域が ($-\frac{\pi}{2} \leq y \leq \frac{\pi}{2}$) であるため、式 (4) のように $\frac{\pi}{2}$ を加えることで値域を ($0 \leq y \leq \pi$) としている。

$$\phi(x, y, z, \theta) = \arcsin \frac{x}{\sin \theta \times \sqrt{x^2 + y^2 + z^2}} + \frac{\pi}{2} \quad (4)$$

更に、式 (4) によって得た方位角の正規化のため、図 7 の全ベクトルと SHOULDERS_VEC[ϕ] との差分から図 8 のような方位角 ϕ を得る。ただし、

$$\begin{aligned} \phi > 0 (z < 0) \\ \phi < 0 (z > 0) \end{aligned} \quad (5)$$

とする。

また、連続するフレーム間での各関節の移動量 $Move[joint]$ をデータ取得時間で除することにより、関節毎に着目した動作の速さを取得することができる。式 (1) より得たフレーム t での座標 $P_{(joint,t)}$ を $P_{(joint,t)} = (x_{(joint,t)}, y_{(joint,t)}, z_{(joint,t)})$ とし、角関節の移動量 $Move[joint]$ を式 (6) で求める。

$$\begin{aligned} Move[joint] &= \sqrt{X^2 + Y^2 + Z^2} \\ X &= x_{(joint,t)} - x_{(joint,t-1)} \\ Y &= y_{(joint,t)} - y_{(joint,t-1)} \\ Z &= z_{(joint,t)} - z_{(joint,t-1)} \end{aligned} \quad (6)$$




図 9 認識する身体の状態と特徴




図 10 Standing と Moving 状態から起こる行動と特徴

4.3 身体状態判定と行動認識

図 1 および図 2 に示すように、身体状態および行動に対しては骨格形状に差が生じており、個人差はあるもの、おおよそ行動毎の骨格形状は一般的に類似していると考えられる。したがって、ベクトル角度や骨格移動量に閾値を設定することで身体状態および行動分類を行う。なお閾値決定に際しては、データセット収集の労力を考慮し学習ベースの決定は行わず、ヒューリスティックに設定したが、今後は様々な決定方法や個人差の吸収方法の検討も行う予定である。

図 3 に示す身体の状態判定と行動の認識方法について述べる。

4.3.1 状態の判定

対象者の身体の状態として「立っている (Standing)」、「座っている (Sitting)」、「動いている (Moving)」、「横になっている (lying)」の 4 種類に分け、それぞれの特徴を考慮して判定する。各状態は図 9 に示すような形状をしており、図中に矢印で示したベクトル SPINE_VEC, RIGHT_THIGH_VEC, LEFT_THIGH_VEC 及び関節 SPINEBASE の移動量を指標とすれば判別が可能である。よって、これらの指標の間に閾値を設定し判別する。判定した結果は *state* として保持しておく。

(1) Standing の判定

両脚の大腿部が上を向いている、かつ移動していない。
すなわち

- (a) $LEFT_THIGH_VEC[\theta] > Th_{stand_thigh_0}$
 - (b) $RIGHT_THIGH_VEC[\theta] > Th_{stand_thigh_0}$
 - (c) $Move[SPINEBASE] \leq Th_{stand_spine_move}$
- {(a)∪(b)}∩(c) のとき *state* =Standing とする。

(2) Sitting の判定

Standing と同様に両脚の大腿部に着目し、大腿部が横に倒れていて背骨が上を向いているとき、すなわち

- (a) $LEFT_THIGH_VEC[\theta] < Th_{sit_thigh_0}$
 - (b) $RIGHT_THIGH_VEC[\theta] < Th_{sit_thigh_0}$
 - (c) $SPINE_VEC[\theta] < Th_{sit_spine_0}$
- {(a)∪(b)}∩(c) のとき *state* =Sitting とする。

(3) Moving の判定

骨格ベクトルの角度に関わらず関節 SPINEBASE の

移動量のみに着目し、一定の移動量が継続して観測されたとき、対象者が移動しているとする。すなわち

- (a) $Move[SPINEBASE] > Th_{moving_spine_move}$
 - (b) $time > Th_{moving_time}$
- (a)∩(b) のとき *state* =Moving とする。

(4) Lying の判定

両大腿部に加えて背骨の方向を考慮し、これらが横に倒れているとき、すなわち

- (a) $LEFT_THIGH_VEC[\theta] < Th_{lie_thigh_0}$
 - (b) $RIGHT_THIGH_VEC[\theta] < Th_{lie_thigh_0}$
 - (c) $SPINE_VEC[\theta] > Th_{lie_spine_0}$
- (a)∩(b)∩(c) のとき *state* =Lying とする。

4.3.2 行動の認識

3.1 節で述べたように、想定する行動には骨格の形状に差が生じている。よって、これらの行動の判別を行うため図 7 に示すベクトルの天頂角と関節の移動量 $Move[joint]$ を指標として用いる。図 3 に従って、4 つの状態に付随する 8 種類の行動を識別するための分類を指標に対する閾値により行う。ただし、Lying に関しては横になるという 1 つの状態とし行動ではないとするため Standing, Moving, Sitting について述べる。行動認識のルールとして以下のアルゴリズムで判定された行動が 400ms の間で続けて判定されたとき、初めて認識されその行動を *Action* として保持しておく、一度認識された行動は別の行動が認識されるまで *Action* に保存されるものとする。例えば、Drinking では実際に行うアクションの回数は少ないが、*Action* = Drinking である間は飲む行為をしていなくても他の行動が認識されなければ継続して *Action* = Drinking とする。また、時間カウンタを $time[ms]$ とする。

(1) *state* =Moving のとき

state =Moving のときに起こり得る行動は「歩く」のみである。図 10 に示すように、人の歩行についての特徴として踏み出す脚に対して逆側の手が必ず動いていることが挙げられる。よって、

- (a) *state*=Moving
- (b) $Move[ELBOWLEFT] > Th_{walk_elbowL_move}$
- (c) $Move[KNEERIGHT] > Th_{walk_kneeL_move}$
- (d) $Move[ELBOWRIGHT] > Th_{walk_elbowR_move}$

(e) $Move[KNEELEFT] > Th_{walk_kneeR_move}$

(a) $\cap \{((b) \cap (c)) \cup ((d) \cap (e))\}$ ならば,

Walking と判定する。

(2) $state = Standing$ のとき

$state = Standing$ のとき, 起こり得る行動は「掃除」と「料理」である。図 10 に示すように, 「掃除」では一般的に, 片手に掃除機を持って前後に動かすという動作が考えられるため, 一定時間内に片手の移動が連続して行われたとき, すなわち

(a) $state = Standing$

(b) $Move[HANDTIPLEFT] > Th_{clean_handtipL_move}$

(c) $Move[HANDTIPRIGHT] < Th_{clean_handtipR_move}$

(d) $Move[HANDTIPRIGHT] > Th_{clean_handtipR_move}$

(e) $Move[HANDTIPLEFT] < Th_{clean_handtipL_move}$

(f) $LEFT_FOREARM_VEC[\theta] > Th_{clean_forearm_0}$

(g) $RIGHT_FOREARM_VEC[\theta] > Th_{clean_forearm_0}$

(a) $\cap \{((b) \cap (c)) \cup ((d) \cap (e))\} \cap ((f) \cup (g)) \cap$

$time < Th_{clean_time_ms}$ のうちに繰り返されたとき, Cleaning と判定する。次に「料理」についての特徴であるが, 料理には主に洗浄, 選別と成型, 加熱, 調味, 盛りつけなどの動作があるがいずれも直立の状態でも腕が上がっている状態になるため前腕の上がり方と継続時間から判断する。すなわち,

(h) $state = Standing$

(i) $LEFT_FOREARM_VEC[\theta] < Th_{cook_forearm_0}$

(j) $RIGHT_FOREARM_VEC[\theta] < Th_{cook_forearm_0}$

(h) $\cap ((i) \cup (j))$ が $time > Th_{cook_time}$ 継続して観測されたとき Cooking と判定する。

(3) $state = Sitting$ のとき

$state = Sitting$ のとき, 図 3 のように, 行われる動作が片手のものと両手のものに分かれる。そこで, 両腕全体の 4 本のベクトルの状態で図 11 のように 2 つのグループに分ける。グループ間の区別は両腕の前腕がともに上がっている状態と片方だけが上がっている状態の差異である。これらを判別指標とし以下のように判別する。

(a-0) $LEFT_FOREARM_VEC[\theta] < Th_{sit_bothfore_0}$

(b-0) $RIGHT_FOREARM_VEC[\theta] < Th_{sit_bothfore_0}$

(a-0) \cap (b-0) を満たすとき両手の行動 (グループ 2) とし,

(c-0) $LEFT_FOREARM_VEC[\theta] \leq Th_{sit_forearm_0}$

(d-0) $RIGHT_FOREARM_VEC[\theta] \geq Th_{sit_forearm_0}$

(e-0) $RIGHT_FOREARM_VEC[\theta] \leq Th_{sit_forearm_0}$

(f-0) $LEFT_FOREARM_VEC[\theta] \geq Th_{sit_forearm_0}$

((c-0) \cap (d-0)) \cup ((e-0) \cap (f-0)) を満たせば片手の行動 (グループ 1) とする。前述の通り「食べる」という行動については片手と両手どちらの状況でも起こり得




図 11 Sitting 状態での行動と特徴

ることを考慮している。まずは両手で行われる行動について述べていく。

両手で行われる行動「読む」、「書く」、「食べる」のうち両手を口元まで上げる「食べる」動作が最も特徴的であるため, 最初に判定する。

(a-1) $Th_{eat_bothfore_min\theta} < RIGHT_FOREARM_VEC[\theta]$

(b-1) $RIGHT_FOREARM_VEC[\theta] < Th_{eat_bothfore_max\theta}$

(c-1) $Th_{eat_bothfore_min\theta} < LEFT_FOREARM_VEC[\theta]$

(d-1) $LEFT_FOREARM_VEC[\theta] < Th_{eat_bothfore_max\theta}$

(e-1) $Th_{eat_bothup_min\theta} < RIGHT_UPPERARM_VEC[\theta]$

(f-1) $RIGHT_UPPERARM_VEC[\theta] < Th_{eat_bothup_max\theta}$

(g-1) $Th_{eat_bothup_min\theta} < LEFT_UPPERARM_VEC[\theta]$

(h-1) $LEFT_UPPERARM_VEC[\theta] < Th_{eat_bothup_max\theta}$

これら (a-1) ~ (h-1) すべてに当てはまるとき, Eating と判定する。

「読む」と「書く」では, 骨格の形状が類似しており区別する必要がある。これらの差異として, 一般的に本を読むとき身体が静止していることが多いと考えられ, 逆に書くときには手の動きが生じる。よって関節 HAND_TIP に着目し, 移動量が一定以下である状態が継続するとき「読む」と判定し, 動きが観測されるならば「書く」と決定する。

(i-1) $Th_{read_bothfore_min\theta} < RIGHT_FOREARM_VEC[\theta]$

(j-1) $RIGHT_FOREARM_VEC[\theta] < Th_{read_bothfore_max\theta}$

(k-1) $Th_{read_bothfore_min\theta} < LEFT_FOREARM_VEC[\theta]$

(l-1) $LEFT_FOREARM_VEC[\theta] < Th_{read_bothfore_max\theta}$

(m-1) $Th_{read_bothup_min\theta} < RIGHT_UPPERARM_VEC[\theta]$

(n-1) $RIGHT_UPPERARM_VEC[\theta] < Th_{read_bothup_max\theta}$

(o-1) $Th_{read_bothup_min\theta} < LEFT_UPPERARM_VEC[\theta]$

(p-1) $LEFT_UPPERARM_VEC[\theta] < Th_{read_bothup_max\theta}$

(i-1) ~ (p-1) がすべて当てはまり, かつ,

(q-1) $Move[HANDTIPRIGHT] < Th_{read_both_move}$
 (r-1) $Move[HANDTIPLEFT] < Th_{read_both_move}$
 となった時間 $time$ を計測し, $time > Th_{read_time}$ と
 なるとき Reading と判定する.

(s-1) $Th_{write_bothfore_min\theta} < RIGHT_FOREARM_VEC[\theta]$
 (t-1) $RIGHT_FOREARM_VEC[\theta] < Th_{write_bothfore_max\theta}$
 (u-1) $Th_{write_bothfore_min\theta} < LEFT_FOREARM_VEC[\theta]$
 (v-1) $LEFT_FOREARM_VEC[\theta] < Th_{write_bothfore_max\theta}$
 (w-1) $Th_{write_bothup_min\theta} < RIGHT_UPPERARM_VEC[\theta]$
 (x-1) $RIGHT_UPPERARM_VEC[\theta] < Th_{write_bothup_max\theta}$
 (y-1) $Th_{write_bothup_min\theta} < LEFT_UPPERARM_VEC[\theta]$
 (z-1) $LEFT_UPPERARM_VEC[\theta] < Th_{write_bothup_max\theta}$

のとき, Writing と判定する.

最後に, 片手で行う行動の判定について述べる. 一般的に通話をするとき電話を持った手を耳に当てた状態が継続される. よって, 前腕が顔付近に上がった状態で時間を計測し, 一定時間継続されて行われていた場合「電話」と判定する. 「飲む」と「食べる」では図 10 より, 上腕に多少の差異が見られるため, これを特徴とする. 以下に示すは**左手の場合**であり, 右手については左右対称であるため省略する.

(a-2) $Th_{eat_fore_min\theta} < RIGHT_FOREARM_VEC[\theta]$
 (b-2) $RIGHT_FOREARM_VEC[\theta] < Th_{eat_fore_max\theta}$
 (c-2) $Th_{eat_fore_min\theta} < LEFT_FOREARM_VEC[\theta]$
 (d-2) $LEFT_FOREARM_VEC[\theta] < Th_{eat_fore_max\theta}$
 (e-2) $Th_{eat_up_min\theta} < RIGHT_UPPERARM_VEC[\theta]$
 (f-2) $RIGHT_UPPERARM_VEC[\theta] < Th_{eat_up_max\theta}$
 (g-2) $Th_{eat_up_min\theta} < LEFT_UPPERARM_VEC[\theta]$
 (h-2) $LEFT_UPPERARM_VEC[\theta] < Th_{eat_up_max\theta}$

(a-2)~(h-2) を全て満たすならば Eating と判定するが, 時間 $time$ を計測し $time > Th_{call_time}$ となったとき Calling と判定する. 次に,

(i-2) $Th_{drink_fore_min\theta} < RIGHT_FOREARM_VEC[\theta]$
 (j-2) $RIGHT_FOREARM_VEC[\theta] < Th_{drink_fore_max\theta}$
 (k-2) $Th_{drink_fore_min\theta} < LEFT_FOREARM_VEC[\theta]$
 (l-2) $LEFT_FOREARM_VEC[\theta] < Th_{drink_fore_max\theta}$
 (m-2) $Th_{drink_up_min\theta} < RIGHT_UPPERARM_VEC[\theta]$
 (n-2) $RIGHT_UPPERARM_VEC[\theta] < Th_{drink_up_max\theta}$
 (o-2) $Th_{drink_up_min\theta} < LEFT_UPPERARM_VEC[\theta]$
 (p-2) $LEFT_UPPERARM_VEC[\theta] < Th_{drink_up_max\theta}$

(i-2)~(p-2) を全て満たすとき, Drinking と判定する. このときも同様に時間 $time$ を計測し $time > Th_{call_time}$ となったとき Calling と判定する. 最後に $state = Sitting$ での行動分類についてま

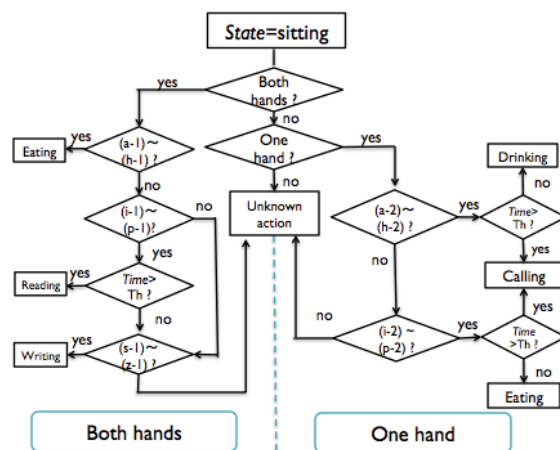


図 12 Sitting 状態での行動判別フロー図

とめたフロー図を図 12 に示す.

4.4 モーションログ

3.1 節で述べたように, 本研究では認識された行動毎のモーションをロギングする. モーションログの構成要素については以下で定義する. なお, データは 200ms 毎に取得するが, 速度を計算する際には座標や角度などのデータ取得時間をフレーム間で記憶しておき, そのデータ取得時間差を用いて計算する.

- *walking_speed* (cm/s): 連続フレーム間での骨盤部分の関節 SPINEBASE (図 6) の移動量をデータ取得時間差で除した歩行速度
- *step_size* (cm): 観測された左右の ANKLE の座標から求めた 2 足間の距離で表される歩幅
- *angle_velocity* (deg/s): 図 7 に示した左右の上腕及び前腕の振りについて, 各ベクトルの角速度の絶対値を用いて回転の速さを表したもの. 連続フレーム間でのデータ取得時間差で天頂角の変化量を除することで得る
- *hand_speed* (cm/s): 連続フレーム間での関節 HAN-DLEFT 及び HANDRIGHT の移動量をデータ取得時間差で除した, 手の移動速度
- *time*: データ取得時間

5. 性能評価

本章では HALS の性能評価のために, まず移動センサを使用した場合の全身の骨格ベクトル動作角について認識精度を評価する. 次に, 実環境において取得したデータを用いて行動認識の精度と検出された行動における骨格ベクトルの特徴を複数の被験者間で比較を行う.

5.1 HALS の骨格認識精度

移動センサを用いて家庭内センシングを行う場合, 対象者に対してセンサの観測角度が一様でなく, それに伴うオク

表 1 観測角度別の骨格追跡状態割合および平均誤差

| | Tracked- Tracked | Tracked- Inferred | Inferred- Tracked | Inferred- Inferred |
|------|---------------------|----------------------|----------------------|-----------------------|
| 0° | 1.00 0° | 0.00 | 0.00 | 0.00 |
| 30° | 1.00 7.76° | 0.00 | 0.00 | 0.00 |
| 60° | 1.00 6.47° | 0.00 | 0.00 | 0.00 |
| 90° | 0.97 13.74° | 0.03 16.97° | 0.00 | 0.00 |
| 120° | 0.60 57.15° | 0.38 51.43° | 0.02 56.37° | 0.00 |
| 150° | 0.63 24.69° | 0.37 48.51° | 0.00 | 0.00 |
| 180° | 0.59 56.22° | 0.40 76.46° | 0.00 | 0.01 25.29° |
| 210° | 0.00 | 0.00 | 0.00 | 1.00 80.61° |
| 240° | 0.65 47.06° | 0.35 52.99° | 0.00 | 0.00 |
| 270° | 0.17 22.88° | 0.00 | 0.48 32.66° | 0.36 35.77° |
| 300° | 0.78 14.61° | 0.01 16.09° | 0.21 11.19° | 0.00 |
| 330° | 1.00 5.00° | 0.00 | 0.00 | 0.00 |
| 合計 | 8.38 | 1.55 | 0.70 | 1.37 |

ルーションにより身体が部分的に認識されなくなる場合がある。したがって本節では、骨格追跡状態とベクトル天頂角 θ の平均誤差の関係について評価を行う。kinect を 2 台用意し、一方を（正面を 0° とし時計回りに）身体の周囲 30° 毎に順番に設置し、RIGHT_FOREARM_VEC[θ] のみに着目し、取得した値を観測値とする。また、他方の kinect を身体の正面に固定し、取得した RIGHT_FOREARM_VEC[θ] を真値とする。被験者 1 名が直立した状態で右肘を最大まで曲げ、その後元に戻すことを 5 回繰り返した。なお、その他の身体の動きはないものとする。

まず、上記に示した方法で、観測角度毎の「骨格追跡状態」の割合、およびその状態における真値との平均誤差を表 1 に示す。ここで、骨格の追跡状態とは、骨格ベクトルの根の認識状態とベクトルの先端の認識状態の組で表現され、Tracked-Tracked, Tracked-Inferred, Inferred-Tracked, および Inferred-Inferred の 4 状態のいずれかである。また、表 1 に示した各観測角度および各骨格追跡状態における平均誤差に対し、表 2 のように骨格追跡状態毎に正規化した出現割合を乗じて全角度の重み付き平均とした値を表 3 に示す。この結果より、ベクトルの先端が認識されていれば（すなわち *Tracked の 2 状態であれば）どのような観測角度に対してもおよそ 20° 程度の角度誤差で収まることがわかる。骨格の認識状態は取得可能であるため、適切な骨格認識状態における行動認識およびモーションログ取得を行うことで高い精度での推定が実現できると考えられる。

5.2 行動認識に関する評価

実在の一般家庭（3 人家族）内において HALS を用いてセンシングを行い、被験者の行動を認識できるかの評価も行った。被験者家族は A（男性）、B（女性）、C（男性）の 3 人からなり、身長はそれぞれ 171cm, 147cm, 165cm である。被験者は身体にセンサ等身につけることはなく、休日のリラックスできる服装をしていた。実験は図 13 に示すようなセンサと被験者の位置配置で行い、場所 1 では

表 2 観測角度別にみた追跡状態の重み

| | Tracked- Tracked | Tracked- Inferred | Inferred- Tracked | Inferred- Inferred |
|------|---------------------|----------------------|----------------------|-----------------------|
| 0° | 0.119 | 0.000 | 0.000 | 0.000 |
| 30° | 0.119 | 0.000 | 0.000 | 0.000 |
| 60° | 0.119 | 0.000 | 0.000 | 0.000 |
| 90° | 0.116 | 0.0018 | 0.000 | 0.000 |
| 120° | 0.072 | 0.246 | 0.025 | 0.000 |
| 150° | 0.075 | 0.241 | 0.000 | 0.000 |
| 180° | 0.071 | 0.257 | 0.00 | 0.005 |
| 210° | 0.000 | 0.000 | 0.000 | 0.732 |
| 240° | 0.077 | 0.228 | 0.000 | 0.000 |
| 270° | 0.020 | 0.000 | 0.679 | 0.262 |
| 300° | 0.093 | 0.009 | 0.296 | 0.000 |
| 330° | 0.119 | 0.000 | 0.000 | 0.000 |

表 3 追跡状態別にみたベクトル角度認識誤差

| | Tracked- Tracked | Tracked- Inferred | Inferred- Tracked | Inferred- Inferred |
|------|---------------------|----------------------|----------------------|-----------------------|
| 平均誤差 | 19.24° | 56.57° | 26.89° | 68.56° |

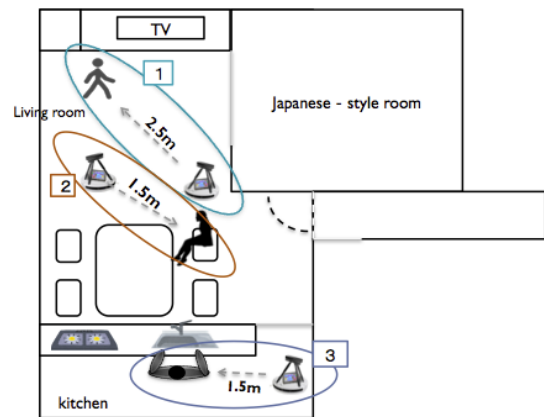


図 13 実験環境とセンサ-被験者位置関係

Walking, Cleaning, 場所 2 では Sitting 状態から起こり得る行動を観測し、場所 3 では Cooking の観測を行った。ただし、Eating に関して片手で行うものとした。被験者は表 4 に示す実験インストラクションに従って行動を行い、例えば、

- (17:30~17:31, B, 電話, 座, 左手)

のように時刻と行動内容、行動実施者を手記することで真値を記録した。

なお、行動は Eating, Drinking, Cleaning のように腕を動かす動作自体が行動となるもの（回数指定）と、Calling, Walking, Writing, Reading, Cooking のように継続した動作が行動となるもの（時間指定）とに分類される。

行動認識を行うためには 4.3 節で定めた閾値を決定する必要がある。Standing 状態と Moving 状態の各行動は特徴が類似していないため、今回は経験的に閾値を決定した。

表 4 実験インストラクション

| | 行動別インストラクション |
|----------|---|
| Drinking | 両手は膝の上に置いた状態から観測を開始する。机の上にあるコップを片手で持って飲み物を飲む。その後、コップを机の上に戻して1回とし、これを5回繰り返す。 |
| Eating | Drinkingと同様に開始し、目の前の食べ物を取って片手で食べる。その後、手を膝の上まで戻して1回とし、これを5回繰り返す。 |
| Calling | 観測を始めてから耳元に電話を添えて通話し、1分間通話の様子を観測する。なお、使う手はどちらでもよい。 |
| Walking | 止まっている状態から観測し、いつも通りに歩く（3秒以上） |
| Writing | 1分間紙に文字を書く動作を継続して行う。その他の動作はない。 |
| Reading | 1分間本を読む動作を継続する。 |
| cleaning | 片手に掃除機を持って左前方、正面、右前方に各3回ずつ腕を前後に動かす。 |
| Cooking | 台所で調理を1分間継続して行う。具体的な行動は指示しない。 |

しかし、Sitting 状態の行動は類似した動作が含まれているため、家族の中で最も中庸体型であった C が実際に各行動を行った事前データを基に、5.1 節の表 3 で示した誤差を考慮に入れて閾値を決定した。この事前データ取得については C の正面に kinect を置き、その前で各行動を行ったときの上腕及び前腕の天頂角 θ を記録したものである。なお、この際も表 4 のインストラクションに従うよう指示をした。この結果、図 14 のような数値結果が得られたため、これをもとに前述の平均誤差 $15^{\circ} \sim 20^{\circ}$ を考慮に入れ、閾値を決定した。

行動認識について、行に推定結果を、列に正解を示し、要素にその判定割合を示した行列を図 15 に示す。これは回数指定の行動では動作が行われている間の検出率を、時間指定の行動では指定された時間内での動作の検出率をそれぞれ算出したものになっている。認識対象とした 8 種類の行動およびそれらに当てはまらない場合の unknown について、unknown を除いた正答率（すなわち適合率）は十分高いといえる。なお、unknown の原因としては、特定の被験者から得た行動別の角度や関節移動量の事前データを考慮した閾値設定を行ったものの、実際には被験者の体格差による個人差が生じたためであると考えられる。unknown 状態の判定率を下げ、再現率を向上させることが今後の課題である。

5.3 運動能力に関する評価

5.2 節と同様の家族に対し HALS を用いたセンシングを行い、フレーム毎の骨格座標変化や全身のベクトル変化から、動作速度と歩幅の検出精度について評価した。評価では被験者の正面に kinect を 1 台と図 13 に示した位置に観測用 kinect を 1 台設置して行った。正面の kinect により得た *walking_speed*, *step_size*, *hand_speed*, *angle_verocity* をそれぞれの指標の真値とし、観測用 kinect と共に平均値を調べた。*walking_speed* と *step_size* のロギングは walking 時の観測データとし、*hand_speed* と *angle_verocity* のロギングは Eating 時の観測データとした。なお、被験者は動作の際に表 4 のインストラクションに従うものとする。

表 5 *Walking_speed* の平均値

| | 観測値 | 真値 |
|---|------|------|
| A | 72.7 | 82.2 |
| B | 72.5 | 68.2 |
| C | 69.8 | 68.4 |

表 6 *Step_size* の平均値

| | 観測値 | 真値 |
|---|------|------|
| A | 36.1 | 37.0 |
| B | 29.4 | 26.1 |
| C | 32.9 | 34.2 |

表 7 *Hand_speed[right]* の平均値

| | 観測値 | 真値 |
|---|------|------|
| A | 34.2 | 39.9 |
| B | 33.7 | 41.6 |
| C | 42.5 | 52.5 |

表 8 *Angle_verocity[right][fore]* の平均値

| | 観測値 | 真値 |
|---|------|------|
| A | 0.8 | 1.01 |
| B | 1.05 | 0.74 |
| C | 1.24 | 1.27 |

walking_speed についての結果を表 5 に、*step_size* についての結果を表 6 に、*hand_speed[right]* の結果を表 7 に、*angle_verocity[right][fore]* の結果を表 8 にそれぞれ示す。これらより、真値に十分近い値での動作記録ができていることが確認できる。

6. おわりに

本研究では、お掃除ロボットや見守りロボットなど、現在および将来において一般家庭に普及が進むロボットに Microsoft Kinect を付加し、高齢者の骨格認識に基づいて日常行動を推定し、各行動内における運動量蓄積を行うための手法を提案している。被観測者の側面など正面でない角度から得られる深度情報から関節検出を行い、身体の体幹および体肢（骨格）を検出したうえで、日常行動の認識ならびにその日常行動におけるモーションを測定する。実家庭における実験の結果、歩行のような特徴のある行動の

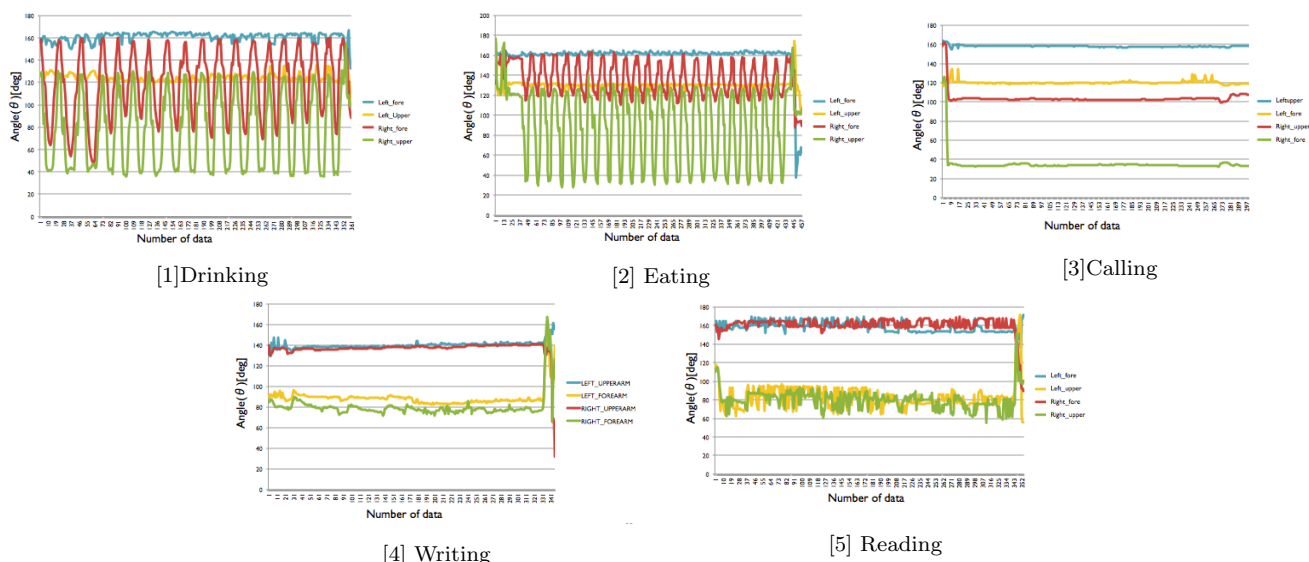


図 14 Sitting 状態で起こり得る行動の天頂角の変化

| | Drinking | Eating | Calling | Walking | Writing | Reading | Cleaning | Cooking | unknown |
|----------|----------|--------|---------|---------|---------|---------|----------|---------|---------|
| Drinking | 0.46 | 0.24 | 0 | 0 | 0 | 0 | 0 | 0 | 0.3 |
| Eating | 0.34 | 0.59 | 0 | 0 | 0 | 0 | 0 | 0 | 0.07 |
| Calling | 0 | 0.05 | 0.26 | 0 | 0 | 0 | 0 | 0 | 0.69 |
| Walking | 0 | 0 | 0 | 0.89 | 0 | 0 | 0 | 0 | 0.11 |
| Writing | 0 | 0 | 0 | 0 | 0.25 | 0.06 | 0 | 0 | 0.69 |
| Reading | 0 | 0 | 0 | 0 | 0.09 | 0.4 | 0 | 0 | 0.51 |
| Cleaning | 0 | 0 | 0 | 0.38 | 0 | 0 | 0.42 | 0 | 0.2 |
| Cooking | 0 | 0 | 0 | 0.07 | 0 | 0 | 0.11 | 0.43 | 0.38 |

図 15 行動推定結果

認識し関しては高い精度で認識することができた。

謝辞

本研究の一部は JSPS 科研費 15H02690 ならびに 15K12019 の助成を受けたものです。

参考文献

- [1] 総務省統計局. 統計トピックス no.72 統計からみた我が国の高齢者(65歳以上). <http://www.stat.go.jp/data/topics/topi720.htm>, 2013.
- [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, aug 2015.
- [3] Shoko Nakamura, Saeko Shigaki, Akihito Hiromori, Hirozumi Yamaguchi, and Teruo Higashino. A model-based approach to support smart and social home living. In *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, UbiComp '15, pp. 1101–1105, New York, NY, USA, 2015. ACM.
- [4] D. Riboni, C. Bettini, G. Civitarese, Z. H. Janjua, and R. Helaoui. Fine-grained recognition of abnormal behaviors for early detection of mild cognitive impairment. In *Pervasive Computing and Communications (PerCom), 2015 IEEE International Conference on*, pp. 149–154, March 2015.
- [5] Laurin D, Verreault R, Lindsay J, MacPherson K, and

- Rockwood K. Physical activity and risk of cognitive impairment and dementia in elderly persons. *Archives of Neurology*, Vol. 58, No. 3, pp. 498–504, 2001.
- [6] NHK スペシャル. シリーズ認知症革命. <http://www.nhk.or.jp/special/ninchi/index.html>.
- [7] Cuong Pham, Nguyen Ngoc Diep, and Tu Minh Phuong. A wearable sensor based approach to real-time fall detection and fine-grained activity recognition. *J. Mob. Multimed.*, Vol. 9, No. 1-2, pp. 15–26, November 2013.
- [8] Jamie Shotton, Andrew Fitzgibbon, Mat Cook, Toby Sharp, Mark Finocchio, Richard Moore, Alex Kipman, and Andrew Blake. Real-time human pose recognition in parts from a single depth image. In *CVPR. IEEE*, June 2011.
- [9] Wei Shen, Ke Deng, Xiang Bai, T. Leyvand, Baining Guo, and Zhuowen Tu. Exemplar-based human action pose correction and tagging. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, pp. 1784–1791, June 2012.
- [10] T. Banerjee, J. M. Keller, M. Skubic, and E. Stone. Day or night activity recognition from video using fuzzy clustering techniques. *IEEE Transactions on Fuzzy Systems*, Vol. 22, No. 3, pp. 483–493, June 2014.
- [11] Jinna Lei, Xiaofeng Ren, and Dieter Fox. Fine-grained kitchen activity recognition using rgb-d. In *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*, UbiComp '12, pp. 208–211, New York, NY, USA, 2012. ACM.
- [12] Julie A Kientz, Shwetak N Patel, Brian Jones, ED Price, Elizabeth D Mynatt, and Gregory D Abowd. The Georgia Tech aware home. In *CHI'08 Extended Abstracts on Human Factors in Computing Systems*, pp. 3675–3680, 2008.
- [13] J. H. Shin, B. Lee, and K. Suk Park. Detection of abnormal living patterns for elderly living alone using support vector data description. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 15, No. 3, pp. 438–448, May 2011.
- [14] Ifat Afrin Emi and John A. Stankovic. Sarrima: Smart adl recognizer and resident identifier in multi-resident accommodations. In *Proceedings of the Conference on Wireless Health*, WH '15, pp. 4:1–4:8, New York, NY, USA, 2015. ACM.

- [15] Rim Helaoui, Mathias Niepert, and Heiner Stuckenschmidt. Recognizing interleaved and concurrent activities using qualitative and quantitative temporal relationships. *Pervasive Mob. Comput.*, Vol. 7, No. 6, pp. 660–670, December 2011.
- [16] Michael Buettner, Richa Prasad, Matthai Philipose, and David Wetherall. Recognizing daily activities with rfid-based sensors. In *Proceedings of the 11th International Conference on Ubiquitous Computing, UbiComp '09*, pp. 51–60, New York, NY, USA, 2009. ACM.
- [17] Timothy W. Hnat, Erin Griffiths, Ray Dawson, and Kamin Whitehouse. Doorjamb: Unobtrusive room-level tracking of people in homes using doorway sensors. In *Proceedings of the 10th ACM Conference on Embedded Network Sensor Systems, SenSys '12*, pp. 309–322, New York, NY, USA, 2012. ACM.
- [18] T. Matsumoto, M. Shimosaka, H. Noguchi, T. Sato, and T. Mori. Pose estimation of multiple people using contour features from multiple laser range finders. In *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 2190–2196, Oct 2009.
- [19] Z. Zhou, X. Chen, Y. C. Chung, Z. He, T. X. Han, and J. M. Keller. Activity analysis, summarization, and visualization for indoor human activity monitoring. *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 18, No. 11, pp. 1489–1498, Nov 2008.
- [20] Jit Biswas, Mounir Mokhtari, Jin Song Dong, and Philip Yap. Mild dementia care at home - integrating activity monitoring, user interface plasticity and scenario verification. In *Proceedings of the Aging Friendly Technology for Health and Independence, and 8th International Conference on Smart Homes and Health Telematics, ICOST'10*, pp. 160–170, Berlin, Heidelberg, 2010. Springer-Verlag.
- [21] 内閣府. 平成 26 年度 高齢者の日常生活に関する意識調査. <http://www8.cao.go.jp/kourei/ishiki/h26/sougou/zenta/index.html>.
- [22] 株式会社シード・プランニング. 「おそうじロボット」のユーザー調査と 2020 年までの市場予測. <https://www.seedplanning.co.jp/press/2015/2015031201.html>, 2015.