1次元輝度分布による 生活行動の認識およびその丁寧さ判定*

島吉 翔太[†]・岡村 瞬[†]・梶原 祐輔[‡]・島川 博光[‡]

Recognizing Housework and Figuring Out Its Conscientious Degree from One-Dimensional Brightness*

Shota SHIMAYOSHI[†], Shun OKAMURA[†], Yusuke KAJIWARA[‡] and Hiromitsu SHIMAKAWA[‡]

The lack of helpers in facilities to take care of the elderly has become a serious problem in Japan, because of the rapid increase of the elderly. It is necessary for the elderly living alone to keep their living willingness enough to stay in a status free from case. The method uses the brightness distribution sensors to collect movement logs in order to protect the privacy of the elderly. The brightness distribution acquired by the sensors brings information significant enough for a machine to discern living activities. This study figures out the conscientious degree with the difference of the body trunk movement of the person carrying out of the living activities. In an experiment for the elderly, the f-measure with which the method has recognized activities of cleaning, cooking, and washing are 0.975, 0.912, and 0.927, respectively. The experiment shows 0.599, which indicates conscientious degree of cleaning. It justifies the proposed method uses the movement of body trunk to figuring out the conscientious degree.

1. はじめに

近年、日本では少子高齢化が急速に進行しており、2025年には介護職員の数が不足することが予測されている。そのため、今後は高齢者が自己の健康を管理し、自立した生活を営む必要がある[1]。高齢者が継続的に健康的で、自立した生活を営むには、独力で日常生活を営もうとする意欲を高く維持する必要がある。本論文では、この意欲のことを生活意欲とよぶことにする。生活意欲の低下は日常生活の乱れに現れる。日常生活が乱れ始めると、独居高齢者は身体的かつ精神的に衰えていると考えられる。怠惰な生活様式が高齢者の自立度や健康状態に悪影響を与えることも検証されている[2]。そのため、日常生活の乱れを検出すれば生活意欲の低下を早期に発見できる。したがって、日常生活の乱れを発見できれば、独居高齢者の生活意欲を再び向上させるための対策を講

じることができる。IADL (Instrumental Activities of Daily Living) 基準には生活行動の実施度合いや丁寧さが規定されている[3]。IADLとは、最低限の生活を営むうえでは必要ないが、その実施が生活の質を向上させる行動であり、炊事や洗濯などの行動を指す。つまり、IADLを基準とした生活行動を定期的に実施する高齢者は生活意欲が高いと判断できる。そのため、日常実施しているIADLを丁寧に実施しなくなったとき、普段の生活行動の実施度合いが低下したと考えられ、生活意欲の低下を発見できる。

既存手法として、IADLを認識し、それぞれのIADLにおける回数や実施時期の変化をみることで、健康状態の異常などの事態の悪化を検知するものは多く存在する[4,5]。一方、既存手法では丁寧さなどの行動の質は考慮していない。生活行動を丁寧に実施しなくなれば、その行動に対する意欲が低下したと考えられ、将来的にその行動を実施しなくなると考えられる。

そこで本論文では丁寧さを判定するモデルを提案する。IADLの丁寧さ度合いを既存手法に付加することで、生活意欲低下をさらなる精度向上と早期発見への貢献が期待できる。まず、輝度分布センサ[6]から得られる輝度を用いて、機械学習によって生活行動を識別する。輝度分布センサは視野の水平方向の1次元情報しか取得しな

* 原稿受付 2015年7月31日

[†] 立命館大学 大学院 情報理工学研究科 Graduate School of Information Science and Engineering, Ritsumeikan University; 1-1-1 Noji-Higashi, Kusatsu city, Shiga 525-8577, JAPAN

[‡] 立命館大学 情報理工学部 College of Information Science and Engineering, Ritsumeikan University; 1-1-1 Noji-Higashi, Kusatsu city, Shiga 525-8577, JAPAN

Key Words: elderly, IADL, privacy, brightness, sensor.

いため、高齢者の顔や服は判別できない。そのため、高齢者のプライバシーは守られる。つぎに、識別された各生活行動における人の体幹の動かし方の違いから生活行動の丁寧さを判定するモデルを作成する。既存研究で輝度分布センサを用いて転倒を検知できることは明らかになっているが、複雑な日常生活行動を検知できることを示した研究はない[6]。そのため、本論文では輝度分布センサから得られる輝度を用いて、機械学習によって複数の生活行動を識別し、識別結果を定量的に評価する。評価結果から輝度分布センサを用いることで、プライバシーを考慮しつつ日常生活行動を識別できることを示す。つぎに、識別した行動のなかでも今回は掃除、調理、食器洗いの行動に着目し、丁寧さ判定モデルを構築する。評価結果からプライバシーを守りつつ、行動の質を測定できることを示す。

以下、本論文では2章で関連研究について述べる。3章では輝度分布センサを用いて生活行動を識別する手法と、識別された生活行動の丁寧さを判定する手法について述べる。4章で輝度分布センサを用いて日常生活行動を識別した結果と、結果に対する考察を述べる。5章で輝度分布センサを用いた生活行動の丁寧さモデルを評価し、その結果を考察する。6章で本論文のまとめと今後の展望を述べる。

2. 関連研究

2.1 行動認識

高齢者を自動で見守る方法として、住宅内にカメラを設置して日常生活動作を自動認識する手法がある[7]。しかし、カメラを用いたシステムは日常生活動作とは関係ない情報を多く取得する。そのため、カメラを用いたシステムは高齢者のプライバシーを侵害する。このことは高齢者がストレスをためる原因にもなる。それゆえ、高齢者の家庭にカメラを設置することは実現困難である。また、Kinectを用いて生活行動を認識する手法[8]は、カメラと同様に取得する情報量が多いため、プライバシー保護の観点で問題がある。

プライバシーを考慮した家庭内での行動認識手法として、加速度センサを用いた手法[9]、赤外線センサを用いた手法[10]、レーザーレンジファインダを用いた手法[11]が挙げられる。加速度センサを用いた手法は、生活行動を認識できるが、装着型のセンサであるため、人によっては抵抗を感じることや、装着忘れのため行動を取得できない問題がある。赤外線センサを用いた手法は、発作などの大きな異常を検知できる。しかし、高精度な認識を実現するためには複数設置する必要がある。設置するための高いコストと広い場所が必要となる。レーザーレンジファインダを用いた手法は、データ取得範囲が広い上に、姿勢を検知できるほどの高い性能をもつ。しかし、高価なセンサであるため、一般家庭に設置することは困難である。

Fig. 1 Outline of the method

2.2 生活意欲測定

高齢者の生活の質を向上させることを目的として、IADLの実施を家庭内で自動認識する研究は多く存在する。人の存在を検知するセンサ、接触を検知するセンサ、家電の電源を管理するセンサを用いる手法がある[12]。これらの行動がルーチンワークであることに着目し、実施時期を取得することで介護に役立てることができる。また、高齢者の自立度を測るための行動として、薬の服用、電話、コーヒーメーカーの使用といった行動に着目する手法がある[13]。これらの行動は、それぞれの機器にセンサを設置することで行動の実施を自動で取得できる。行動の実施を長期的に取得することで、高齢者の自立度を向上させるための改善を図ることができる。しかし、ある行動を高齢者が実施しなくなったとき、その行動を実施する能力が失われている可能性もある。そのような場合、実施しているか否かを検知できたとしても、身体能力が衰えているため、生活習慣を改善することは困難である。

3. 輝度分布を用いた行動識別と丁寧さ判定

本論文では、複数の生活行動を自動で識別し、識別した生活行動が丁寧に実施されているのかどうかを算出する手法を提案する。独居高齢者の日常生活を把握するために、この手法に基づく見守りシステムを設置する。提案するシステムの概要をFig. 1に示す。まず、センサを設置した空間で生活することで輝度データを取得する。その輝度データから特徴抽出して機械学習することによって、IADLに基づく複数の行動を自動識別し、生活行動の実施時期を明らかにする。識別した結果からモデルを選択する。また生活行動を実施している際の輝度分布値を抽出する。各生活行動を実施している際の輝度分布値から人の動線を求める。この動線を各丁寧さモデルに入力し、丁寧度を出力させる。丁寧度は0に近いほど不丁寧であることを示している。各生活行動の丁寧さは、別々の指標で評価される。しかし、本研究で用いる輝度

分布センサはカメラとは異なり大まかな動きしか取得できない。そこで、輝度分布センサを用いて取得できる体幹の動きから行動の丁寧さを判定する。本論文では生活行動の中でも掃除、調理、食器洗いに着目し、モデル構築を行う。掃除は、調理などと比べてシンプルな動作である。一方で、日常生活を送るうえで必ずしも必要でない行動であるため、生活意欲も現れやすい。また掃除の丁寧さは調理や食器洗いと比較して第三者が見て、容易に判断できる。生活意欲が高い高齢者は他の IADL においても丁寧に実施する傾向がある。そのため、ビデオ行動観察法 [14] で客観的な指標を得ることができ、構築したモデルの評価も定量的に行うことができる。

3.1 輝度分布センサ

本手法ではプライバシーを守るために輝度分布センサ [6] を用いる。輝度分布センサの視野角は 51 度であり、一般的な Web カメラと同等の視野角を有する。輝度分布センサは、一般の Web カメラで用いられるレンズの代わりに Fig. 2 に示す円柱状のロッドレンズを用いる。

ロッドレンズは垂直方向の輝度を集光する。これは垂直方向の輝度値を積分することを意味する。したがって、輝度分布センサを用いれば垂直方向の輝度値に対する積分値を 1 次元の情報として取得できる。また、集光後の情報から垂直方向の輝度値を復元するのは困難であり、撮像対象者のプライバシーが保護される。

Fig. 3 にカメラ画像に対する輝度分布を示す。輝度分布センサは人が存在する位置の輝度値の変化から、水平方向における人の存在を認識する。本手法では、Fig. 4 に示すように 2 個の輝度分布センサをそれぞれのデータ取得領域の中心線が直交するように設置する。このように設置することで、2 次元で人の位置を認識できる。

輝度分布センサは、カメラと比較すると輝度のみを取得するので情報が少ない。第三者は輝度分布値を見て、輝度分布を設置された家に在宅している人の顔や行動を容易に判断することができない。よってプライバシーを保護できる。輝度分布センサは市販の Web カメラのレンズをロッドレンズに交換すれば作成できる。その場合輝度分布センサは、横幅が 640pixels, 30fps で輝度データを取得する。カメラと同様に広範囲のデータを取得するため、多くのセンサを必要としない。そして、安価で小型なセンサであるから省スペースに、かつ低コストで設置できる。

3.2 局所特徴による行動識別

本手法では、各生活行動の輝度データから固有の特徴を抽出するため Bag-of-Features 手法 [15] を用いる。Bag-of-Features 手法とは、局所特徴をクラスタリングし、各クラス内での点の数でヒストグラムを構築し、このヒストグラムを映像の特徴とする手法である。

本手法では、背景差分値、ピクセル差分値、フレーム差分値の三つの局所特徴を用いる。三つの局所特徴は輝

Fig. 2 One-dimensional data is gained with rod lens

Fig. 3 Difference between Web camera and brightness distribution sensor

Fig. 4 Location of two brightness distribution sensors

度データから取ることのできる主要要素である。この三つの局所特徴から座標空間を作る。フレーム番号を f 、ピクセル番号を p とおいたときの輝度値を $b(f, p)$ とし、背景差分値を $B_s(f, p)$ 、ピクセル差分値を $P_s(f, p)$ 、フレーム差分値を $F_s(f, p)$ とする。さらに、人の映り込んでいない背景を表すフレーム番号を 0 とすると、三つの局所特徴はそれぞれ (1) 式、(2) 式、(3) 式で表せる。

$$B_s(f, p) = b(f, p) - b(0, p) \quad (1)$$

$$P_s(f, p) = B_s(f, p) - B_s(f, p-1) \quad (2)$$

$$F_s(f, p) = B_s(f, p) - B_s(f-1, p) \quad (3)$$

背景差分値とは、データ取得範囲内に人が存在するときの輝度値と背景を表す輝度値の差をとった値であるため、人の存在を表す特徴である。ピクセル差分値とは、前後のピクセル間で背景差分値の差をとった値であるため、人が存在する位置と存在しない位置の境目を表す特徴で

Fig. 5 Constructing histogram from division brightness data

ある。フレーム差分値とは、前後のフレーム間で背景差分値の差をとった値であるため、人の移動を表す特徴である。そして、この三つの局所特徴をそれぞれ軸とした座標空間上にプロットされた特徴点を k-means++ を用いてクラスタリングする [15]。各クラスタに属する点の数を表すヒストグラムを構築する。

しかし、Bag-of-Features 手法によって構築したヒストグラムは座標空間における特徴点の分布である。そのため、このヒストグラムには生活行動を識別するために必要な位置情報が備わっていない。たとえば、掃除のような部屋全体を動き回る生活行動と食器洗いのような特定の位置で実施する生活行動を識別するとき、位置は識別するに当たって重要な情報である。

そこで、画像を分割してヒストグラムを構築することで、位置情報を反映する手法 [16] を輝度データに適用する。この分割手法を輝度データに適用したときの概要を Fig. 5 に示す。1 個の輝度分布センサにおいてデータ取得範囲全体を表す輝度データ、2 等分した輝度データ、3 等分した輝度データそれぞれから計 6 個のヒストグラムを構築する。このように輝度データを分割することで、掃除のような部屋全体を動き回る生活行動であれば、6 個のヒストグラムすべてに人の存在があらわれる。本手法では、輝度分布センサを 2 個用いるため、ひとつのある生活行動から 12 個のヒストグラムが得られる。

つぎに、多クラスへの識別結果を離散値として出力する教師あり学習を適用する。本研究では、多数の生活行動の識別を目的とし、各行動は独立であるため離散値として出力する必要がある。また、各生活行動には固有の動作特徴がある。教師あり学習は、説明変数と目的変数をラベル付けして訓練データとするアルゴリズムであるため、本手法において有効である。ここで、説明変数は 12 個のヒストグラムであり、目的変数は掃除、調理などの生活行動である。

3.3 動線データを用いた丁寧さ判定

3.3.1 動線の抽出

生活意欲のより小さな変化を見つけるために、生活行動の丁寧さに着目する。生活行動の丁寧さには、さまざま

な生活行動においておのこの指標がある。しかし、本手法で用いる輝度分布センサは大きな動きしか取得できない。そこで本手法では、さまざまな生活行動において人にとって最も重要な部位である体幹に着目し、体幹の動かし方の違いから人ごとの生活行動の丁寧さを判定する。この体幹の動きを動線と定義する。

まず、各センサにおいて輝度値から人の体幹の位置を推定する。センサ範囲内に人が存在すると輝度値は変化する。体幹とは人の胴体部分であり、面積が最も大きい部位である。本手法では、水平方向 1 次元で取得した輝度値を使用するため、垂直方向において背景を表す輝度を変化させる面積の広さが重要である。ゆえに、人の体幹の位置は輝度値の変化が最も大きいと考えられる。そのため、背景差分値 B_s の絶対値が最大となる地点をみる。つまり、フレーム番号が f 、ピクセル番号が p であるとき、体幹の位置 T は (4) 式で表される。

$$T = \arg \max_{0 \leq p \leq 639} |B_s(f, p)| \quad (4)$$

つぎに、全フレームで体幹の位置を取得し、時系列に並べることで動線データを作成する。動線データは体幹の位置がどのように遷移するのかをピクセル単位で表現したものである。この動線データを用いて体幹の動きに着目し、生活行動が丁寧かどうかを判定する。

3.3.2 HMM による丁寧さモデルの構築

生活行動が丁寧であるかどうかによる動線データの相違を取得するために、HMM (Hidden Markov Model) [17] を用いる。HMM は、時間的に連続である非定常なデータを、複数の定常状態からなるモデルに変換する手法である。これは、家具が配置された複雑な環境や、あらゆる生活行動における時系列の動作を想定するため、本研究において有効な手法である。HMM は、Baum-Welch アルゴリズムによって状態に関するパラメータを推定し、そのあと Viterbi アルゴリズムで時系列の中での状態遷移を決定する [17]。状態遷移は、遷移確率で表される。

遷移確率は状態遷移における状態同士の関連性を測る指標である。遷移確率は、ある状態から他の状態への遷移確率と同じ状態への遷移確率が存在する。状態から状態への遷移確率のうち、同じ状態への遷移確率は自己遷移確率とよばれる。状態はそれぞれ異なる平均値と分散値をもつ。HMM を用いて、動線データから状態遷移図を作成する例を Fig. 6 に示す。図で示す動線データのグラフは横軸を時系列、縦軸をピクセル番号として体幹の位置をプロットしたものである。これは体幹の動きにあてはめて考えると、どのような位置でどのように動作しているのかを時系列で表している。平均値は体幹の位置を表す。分散値は体幹の動作幅を表す。したがって、各状態が遷移することは、体幹の位置や体幹の動作幅が変化することを表している。

ある状態が他の状態に遷移することは、動作の変化を

Fig. 6 State change diagram converts from flow lines

意味する。他の状態に遷移する確率を用いて丁寧さモデルを構築した場合、その確率は作業手順や移動順序に依存する。よって頻繁に作業手順や移動順序を変化させる人には適用できない。これらの理由から自己遷移のみに着目し、丁寧さモデルを作成する。これらのことから本論文では自己遷移確率に着目し、丁寧さモデルを作成する。

自己遷移確率を説明変数、丁寧であるかどうかを目的変数として丁寧さ判定モデルを作成する。本手法では、目的変数が質的変数であるため Logistic regression[18]を用いる。このとき作成されるモデルは、被験者 i に対して説明変数を s_i としたとき、丁寧さ Pr_i を (5) 式によって算出する。

$$Pr_i = \frac{1}{1 + \exp(-(as_i + b))} \quad (5)$$

3.3.3 最適なモデルの選択

HMM による複数の状態が存在するため、説明変数もその状態の数だけ存在する。複数の説明変数から最適なモデルを選択するために AIC (Akaike Information Criteria) [18] を用いる。AIC は値が小さくなるほど、目的変数に影響がある説明変数を選択することになる。すべての説明変数に影響あるものとは限らないため、必要な説明変数のみ選択する必要がある。そのため、AIC が最小になる説明変数の組合せを選択することによって、丁寧さの判定において最適なモデルを選択できる。

4. 識別実験

4.1 環境

本実験では、輝度値のみで生活行動が識別可能かを検証後、体幹の動かし方の違いから丁寧さを判定可能かを検証した。Fig. 7 に実際に用いた実験環境を示す。図のように実験環境は一般家庭のダイニングキッチンを用いた。実験環境の行動範囲は約 3m 四方である。センサの死角を減らすために部屋の隅を 2 箇所指定し、高さ 80cm の地点でセンサを水平に設置した。センサ設置の様子を Fig.

Fig. 7 Experimental environment

Fig. 8 Location of sensor

8 に示す。本実験で使用したセンサは、Web カメラに内蔵されている 1/4 インチの CMOS センサと $\phi 2.0\text{mm}$ のロッドレンズで構成されており、51 度の視野角で輝度を取得する。また、光軸の向きが壁面から 45 度となるようにセンサを設置した。本実験の被験者は、60 歳から 70 歳の男性 8 名と女性 12 名からなる計 20 名の高齢者である。実験方法は、IADL の基準に従い、掃除、調理、食器洗いといった三つの生活行動を指定した。掃除は次の手順で実施した。行動範囲全体を箒で掃いた後にモップをかける。調理の手順は次のようなものである。卵を割った後好みに応じて調味料を加え、かき混ぜる。そのあと、フライパンで火を通してから皿に盛り付ける。食器洗いでは、シンクで食器を洗い続ける。1 回の生活行動を 3 分以内としてそれぞれ 3 回ずつ実施した。疲労により行動の丁寧さに変化が現れないようにするため説明時間を含め、実験時間が 1 人あたり 1 時間以内になるように設定した。また、指定する生活行動の数、行動時間、行動回数は、被験者の負担を考慮し決定した。

4.2 評価

各行動から Bag-of-Features 手法によって特徴抽出するとき、指定するクラス数は総当りの結果 25 が最適であると判断した。本実験における生活行動の識別率は、機械学習による識別結果から算出される F 値で評価した。F 値は適合率と再現率の調和平均である。適合率は、システムが行動 X と予測した結果のうち、実際に行動 X が含まれる割合であり結果の正確性指標である。再現率は、実際に行動 X であるもののうち、システムが行動 X と予測した割合であり結果の網羅性指標である。本研

究では、適合率と再現率のバランスが重要であるため、(6)式によってF値を算出する。

$$F \text{ 値} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (6)$$

たとえば、システムに生活行動を示す輝度データを入力したとき、適合率が高ければ識別結果の精度が高いといえるが、その識別結果の中にどれだけシステムに入力された生活行動が含まれているのかわからない。そこで、F値を用いることで適合率と再現率の両方を評価する。

そして汎化性能を評価するために、20名の被験者全員がテストデータとなるように20 fold cross validationで識別を繰り返す。機械学習に用いるアルゴリズムは、Random Forest[19]、Naive Bayes[20]、linear SVM(Support Vector Machines)[21]の三つのアルゴリズムである。これらのアルゴリズムは目的変数が多数存在するときにおいても高い識別性能をもつアルゴリズムであるため、生活行動の識別に適していると考えられる。

4.3 実験結果

三つの教師あり学習を用いて識別した結果の適合率、再現率、F値をTable 1、Table 2、Table 3に示す。表より、最も高いF値を出した機械学習アルゴリズムはRandom Forestである。Naive Bayesは高次元の説明変数を入力すると識別率が下がる。また、Linear SVMは線形分離可能でないと識別率が下がる。これらの性質から、本手法の特徴量は線形分離不可能でかつ、高次元であるため、Random Forestが最もよい結果を出したと考えられる。Random Forestを用いた識別結果は、どの行動も9割を超えるF値となった。ある1日の行動データから生活意欲を測定するとした場合、1割程度の誤識別であっても大きな問題となる。しかし本手法では、生活行動を長期的に取得することで、実施度合いの変遷から生活意欲を測定する。たとえば、今まで定期的に行っていた行動を一定期間実施しなくなれば生活意欲が低下したと考えられる。つまり9割を超える精度であれば、誤識別を連続で繰り返すことも考えられないため、実用に耐えうる精度であると判断できる。

各行動に対する識別結果は、掃除のF値が0.975となり最も誤識別の少ないものとなった。最も誤識別の多い生活行動は調理となり、これは行動の実施位置が近い食器洗いと誤識別されることが多かった。調理は実施位置がセンサの設置位置から遠いため、とくに動作の小さい被験者のデータはどの行動における特徴にも当てはまらないことがある。そのため、調理は食器洗いだけでなく掃除にも誤識別されたと考えられる。したがって、取得したい生活行動を偏りなく高い精度で識別するためには、センサの最適な設置位置に関する調査も必要である。また生活意欲に影響しない生活行動や、動作の似ている生活行動を比較し、必要な生活行動のみ取得できるのかを調査する必要もある。

Table 1 Precision values in the detection using the three Supervised learning algorithm

—	Cleaning	Cooking	Washing
Random Forest	0.967	0.945	0.905
Naive Bayes	0.737	0.807	0.822
linear SVM	0.919	0.912	0.881

Table 2 Recall values in the detection using the three Supervised learning algorithm

—	Cleaning	Cooking	Washing
Random Forest	0.983	0.881	0.950
Naive Bayes	0.949	0.780	0.617
linear SVM	0.967	0.881	0.867

Table 3 F-measure values in the detection using the three Supervised learning algorithm

—	Cleaning	Cooking	Washing
Random Forest	0.975	0.912	0.927
Naive Bayes	0.830	0.793	0.705
Linear SVM	0.942	0.897	0.874

5. 丁寧さ判定モデルの評価実験

5.1 方法

本実験では、丁寧さ指標を得るために生活行動として掃除、調理、食器洗いに着目した。掃除、調理、食器洗いは、多くの人が普段からしているIADLに基づく生活行動である。本実験では丁寧さ指標を得るために、掃除の実験風景をビデオで撮影しておき、そのビデオを用いてアンケート評価を実施した。掃除はシンプルな動作で第三者が見て容易に丁寧さを判定できる行動である。掃除は、日常生活を送るうえで必須でないため、生活意欲が高くないと、その実施は丁寧さに欠ける。また、生活意欲の高い高齢者は、他の行動も丁寧に実施する傾向がある。このビデオは、4章で行った実験時に撮影した。したがって、ビデオに映っている実験風景は4章と同様である。被験者も4章と同様に60歳から70歳の高齢者20名である。ビデオの数は、4章の被験者数×行動分存在する。20代の男性12名、女性3名からなる計15名に、ビデオに撮影された各高齢者の掃除行動を見てもらい、掃除行動の丁寧さをアンケート形式で評価してもらった。アンケートは5段階評価であり、1が丁寧でない、5が丁寧である、とした。全被験者の評価結果の平均をとった後に四捨五入して、4以上となった高齢者は生活行動が丁寧であると判断し、2以下となった高齢者は生活行動が丁寧でないとして判断した。掃除の丁寧さは、第三者が容易に判断できる。そのため、ビデオ行動観察法により掃除の丁寧さの妥当な指標を得ることができる。

Table 4 Criteria of the conscientious degree in the questionnaire

—	Number of persons
Fineness in movement of hands	10 / 15
How to put force	8 / 15
Area within range of action	7 / 15
Fineness in movement of body trunk	7 / 15
Repetition within area of action	4 / 15
Length of time	3 / 15
How to wash mop	3 / 15
Presence of periodicity	1 / 15
Good quality of posture	1 / 15
Dustpan after sweeping with broom	1 / 15
Whether cleaned place is seen or not	1 / 15

また、掃除を丁寧に実施する被験者は他の行動においても丁寧であるとして評価する。同時に、丁寧さの評価基準を自由記述式で調査した。

本実験では、全被験者の動線データを用いて HMM を構築した。HMM の状態数は 5 とした。状態数は、状態数 2 から状態数 10 で総当たりし、被験者ごとに差がみられた状態数を採用した。構築した HMM に各被験者の動線データを入力し、時系列の状態遷移データを出力する。

各被験者の自己遷移確率を説明変数、丁寧であるかどうかを目的変数として Logistic regression に基づき、丁寧さ判定モデルを作成した。作成したモデルの当てはまりの良さを評価するために Nagelkerke R^2 [22] を用いた。Nagelkerke R^2 は Logistic regression によって作成したモデルの当てはまりの良さを表している。Nagelkerke R^2 は 0 から 1 の値を取り、値が 1 に近づくほどモデルの当てはまりが良い。

5.2 実験結果

各被験者の行動実施における丁寧さのアンケート結果から、丁寧である被験者が 6 人、丁寧でない被験者が 3 人となった。また、丁寧さの評価基準をまとめると、Table 4 に示す結果となった。これは、各項目を基準として丁寧さを評価した人数を表している。アンケート結果から、手の動きや移動の細かさが多くの人で評価基準となり、動きが大きすぎると丁寧でなくなるといったものである。動きの大きさは地点ごとの滞在時間に影響することから、自己遷移確率は掃除の丁寧さ判定の指標として有意なものであることがわかる。

5.2.1 掃除

センサ 1、センサ 2 に関して、各状態における平均値と分散値を Table 5 に示す。状態の自己遷移確率を説明変数として Logistic regression にかけた結果、センサ 2 における状態 4 の自己遷移確率のみを説明変数として与

Table 5 Mean and variance of the position in each state for Sensor 1 and Sensor 2 in cleaning

—	Sensor 1		Sensor 2	
	Mean	Variance	Mean	Variance
State 1	230.72	539.89	119.65	672.40
State 2	302.77	405.63	174.07	140.13
State 3	366.44	280.97	222.12	293.70
State 4	443.98	791.77	337.07	1506.93
State 5	551.06	1845.38	489.45	3777.47

Fig. 9 Difference of the self transition probability of each state derived from Sensor 1, when the subject stay in State 4 of Sensor 2 in cleaning

えたときに最適な AIC を出力した。このとき、(5) 式に示す Logistic regression の係数は $a = 113.4$ 、 $b = -107.4$ となった。また、Nagelkerke R^2 は 0.599 となったため、モデルの当てはまりは悪くないと判断できる。よってセンサ 2 が状態 4 のときのセンサ 1 の状態に加えて、丁寧な場合と丁寧でない場合の位置関係の差を Fig. 9 に示す。図では、横軸がセンサ 1 の状態番号を表しており、縦軸がセンサ 2 が状態 4 のときにセンサ 1 における状態番号の割合を丁寧さ別に平均値で表す。丁寧である被験者と丁寧でない被験者の間で、状態 1 と状態 5 の割合に大きな差がみられた。Table 5 の結果から考え、丁寧である被験者は Fig. 9 に示す A 地点で滞在する比率が 0.123 高く、丁寧でない被験者は Fig. 9 に示す B 地点で滞在する比率が 0.135 高くなった。つまり、アンケートで掃除が丁寧であると感じた人は、A 地点のような部屋の隅を重点的に掃除しているかどうかによって掃除の丁寧さを判断しているといえる。このように、特定の場所における滞在時間の長さから丁寧さがわかる。

5.2.2 調理

センサ 1、センサ 2 に関して、各状態における平均値と分散値を Table 6 に示す。状態の自己遷移確率を説明変数として (5) 式に適用した結果、センサ 2 における状態 4 の自己遷移確率のみを説明変数として与えたときに最適な AIC を出力した。調理は掃除と異なり、自己遷移

Table 6 Mean and variance of the position in each state for Sensor 1 and Sensor 2 in cooking

—	Sensor 1		Sensor 2	
	Mean	Variance	Mean	Variance
State 1	371.20	8608.97	92.44	566.01
State 2	512.14	68.69	160.32	305.95
State 3	532.83	31.40	269.97	2198.28
State 4	565.04	107.40	401.84	419.59
State 5	616.15	210.34	551.79	3072.74

Fig. 10 Difference of the self transition probability of each state derived from Sensor 1, when the subject stay in State 4 of Sensor 2 in cooking

確率が低いほど丁寧であるという結果が得られた。このとき、(5)式の係数は $a = -28.47$, $b = 27.63$ となった。また、Nagelkerke R^2 は0.337となり、掃除に比べて低い値を示した。ここで、センサ2が状態4のときのセンサ1の状態に加えて、丁寧な場合と丁寧でない場合の位置関係の差をFig. 10に示す。図では、横軸がセンサ1の状態を表し、縦軸がセンサ2が状態4のときにセンサ1の各状態に滞在する割合を表す。丁寧である被験者と丁寧でない被験者の平均を比較したところ状態3と状態5の割合に大きな差がみられた。Table 6と照合し、Fig. 10において丁寧である被験者はC地点で滞在する比率が0.202高く、丁寧でない被験者はD地点で滞在する比率が0.309高くなった。

5.2.3 食器洗い

センサ1、センサ2に関して、各状態における平均値と分散値をTable 7に示す。AICに基づき調べたところ、センサ1における状態4の自己遷移確率のみを説明変数として(5)式の回帰を施すのが最適と判明した。食器洗いは自己遷移確率が高いほど丁寧であるという結果が得られた。このとき、(5)式の係数は $a = 14.01$, $b = -12.12$ となった。また、Nagelkerke R^2 は0.336となり、掃除に比べて低い値を示した。ここで、センサ1が状態4のときのセンサ2の状態に加えて、丁寧な場合と丁寧でない場合の位置関係の差をFig. 11に示す。図の横軸はセ

Table 7 Mean and variance of the position in each state for Sensor 1 and Sensor 2 in washing

—	Sensor 1		Sensor 2	
	Mean	Variance	Mean	Variance
State 1	292.10	2844.37	118.28	1358.20
State 2	410.95	91.55	212.94	646.60
State 3	432.92	13.33	331.42	1032.14
State 4	457.22	108.25	425.68	1005.74
State 5	553.89	2441.98	540.12	1157.96

Fig. 11 Difference of the self transition probability of each state derived from Sensor 2, when the subject stay in State 4 of Sensor 1 in washing

ンサ2の状態、縦軸はセンサ1が状態4のときにセンサ2の状態に滞在する割合を示す。食器洗いは図に示すE地点で実施するが、丁寧さの有無により状態の滞在に大きな差はみられなかった。

5.3 考察

5.3.1 掃除

丁寧さ判定モデルに関しては、最適な説明変数として選択された自己遷移確率は、センサ2における状態4の自己遷移確率となった。アンケート結果から、多くの回答で評価基準となった手の動きや移動の細かさは、動きが大きすぎると掃除が丁寧でなくなり、自己遷移確率が下がることを表していると考えられる。また、行動範囲の広さを基準とする回答も多く、これは部屋の隅における滞在時間に差があらわれたことと関係するものと考えられる。一方で時間を丁寧さの基準とした回答は少ないが、これは今回の実験では行動実施時間を指定していたため被験者間での差が小さく、丁寧さを決定する基準にならなかったと考えられる。作成したモデルのNagelkerke R^2 は0.599となったが、力の入れ具合などの本手法では考慮されていない基準を説明変数として加えることができれば、当てはまり度合いの向上が期待できる。

また、丁寧である被験者と丁寧でない被験者とでは、特定の状態に滞在する割合に差が出るということがわかった。状態に差が出るということは、動作の大きさや位置に差

が出るということが考えられる。丁寧である被験者のデータは、センサ 2 が状態 4 のとき、センサ 1 の状態 5 における割合が高くなった。センサ 2 が状態 4 のとき、センサ 1 の状態 5 における滞在時間の割合が上がるとセンサ 1 の状態 1 における滞在時間の割合が下がるとも考えられる。したがって、本実験の環境下においてセンサ 1 の状態 5 の比率、あるいはセンサ 1 の状態 1 の比率に着目すれば丁寧さを判定できると考えられる。通路になる位置とは異なる部屋の隅は、結果から念入りに掃除する人でないと滞在しない地点であることがわかったため、丁寧さを判定するうえで重要な地点になったと考えられる。これらから、掃除の丁寧さを判定するうえで体幹の動きは有用な指標であると考えられる。

5.3.2 調理

調理で説明変数として選択されたセンサ 2 の状態 4 は調理台付近の動作をあらわすと考えられる。また、調理は掃除と異なり、選択された説明変数の自己遷移確率が低いほど丁寧であるという結果が得られた。Fig. 10 から、丁寧である被験者はどの状態にも均等に滞在している。一方で、丁寧でない被験者は C 地点での滞在が少なく、D 地点に多く滞在している。このような違いが自己遷移確率に差をつける要因になったと考えられ、調理では多くの地点を移動しながらの手際よい作業が丁寧と判定されると考えられる。しかし、Nagelkerke R^2 は 0.337 と掃除に比べ低いことから、調理の丁寧さを表す指標は位置以外の要素が存在することが示唆される。

5.3.3 食器洗い

食器洗いに関しては、説明変数としてセンサ 1 の状態 4 が選択された。また、選択された説明変数の自己遷移確率が高いほど丁寧であるという結果が得られた。Fig. 11 から、AIC によって選択されたセンサ 1 は、シンクの近くに設置したため、腕の動きを取得している。一方、センサ 2 は被験者の位置を取得している。AIC によってセンサ 1 が選ばれ、センサ 2 が選択されなかったことから、手や腕の動きが重要であるといえる。一方、Nagelkerke R^2 が 0.336 と低い。輝度分布センサでは十分に腕の動きをとらえきれなかったことが示唆される。

6. おわりに

本論文では、高齢者の生活意欲が低下したことを早期発見し改善をうながすために、輝度分布センサを用いて体幹の動きから生活行動を識別し、識別した行動の丁寧さを判定する手法を提案した。評価実験として、掃除、調理、食器洗いといった三つの生活行動における識別率と、これら生活行動の丁寧さを判定するモデルの当てはまり度合いを検証した。結果の F 値はそれぞれ 0.975, 0.912, 0.927 となり、すべての生活行動で 9 割を超える精度で識別した。また、丁寧さ判定モデルの当てはまりの良さを表す Nagelkerke R^2 は掃除、調理、食器洗いそれぞれ 0.599, 0.337, 0.336 となった。

本システムを運用する場合、間取りが大きく変わらないマンションや福祉施設を想定したとき、あらかじめ機械的に学習させておいたシステムをそのまま適用できる。一軒家など独特な間取りの場合でも、1 週間程度の学習期間さえ確保すれば、本手法は適用可能である。

今後の課題は、さまざまな場所でより多くの生活行動を比較し、手法の適用範囲を広げることである。また、ほかの指標と組み合わせ、丁寧さ判定の精度向上を図る。

参考文献

- [1] H. Kanai, G. Tsuruma, T. Nakada and S. Kunifuji: Notification of dangerous situation for elderly people using visual cues; *IUI '08 Proceedings of the 13th international conference on Intelligent user interfaces*, pp. 345–348 (2008)
- [2] F. Portet, M. Vacher, C. Golanski, C. Roux and B. Meillon: Design and evaluation of a smart home voice interface for the elderly: acceptability and objection aspects; *Personal and Ubiquitous Computing*, Vol. 17, No. 1, pp. 127–144 (2013)
- [3] M. P. Lawton and E. M. Brody: Assessment of older people: Self maintaining and instrumental activities of daily living; *Gerontologist*, Vol. 9, pp. 179–186 (1969)
- [4] S. M. Hwang, K. J. Kim, W. Huang, V. Foo, A. Tolstikov, A. Aung, M. Jayachandran and J. Biswas: Multi-modal sensing smart spaces embedded with WSN based image camera; *PETRA '10 Proceedings of the 3rd International Conference on Pervasive Technologies Related to Assistive Environments*, No. 63 (2010)
- [5] R. Jain, L. Jalali and M. Fan: From health-persona to societal health; *WWW '13 Companion Proceedings of the 22nd international conference on World Wide Web companion*, pp. 1329–1334 (2013)
- [6] S. Nakashima, Y. Kitazono, L. Zhang and S. Serikawa: Development of privacy-preserving sensor for person detection; *Procedia Social and Behavioral Sciences*, Vol. 2, pp. 213–217 (2010)
- [7] 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 (2008)
- [8] T. Banerjee, J. M. Keller and M. Skubic: Building a framework for recognition of activities of daily living from depth images using fuzzy logic; *2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pp. 540–547 (2014)
- [9] A. Dalton, S. Patel, A. R. C. M. Welsh, T. Pang, S. Schachter, G. O'Laighin and P. Bonato: Development of a body sensor network to detect motor patterns of epileptic seizures; *IEEE Transactions on Biomedical*

- Engineering*, Vol. 59, No. 11, pp. 3204–3211 (2012)
- [10] J. H. Shin, B. Lee and K. S. 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 (2011)
- [11] T. Matsumoto, M. Shimosaka, H. Noguchi, T. Sato and T. Mori: Pose estimation of multiple people using contour features from multiple laser range finders; *The 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2009)*, pp. 2190–2196 (2009)
- [12] L. Caroux, C. Consel, L. Dupuy and H. Sauzeon: Verification of daily activities of older adults: A simple, non-intrusive, low-cost approach; *ASSETS '14 Proceedings of the 16th international ACM SIGACCESS conference on Computers & accessibility*, pp. 43–50 (2014)
- [13] M. L. Lee and A. K. Dey: Sensor-based observations of daily living for aging in place; *Personal and Ubiquitous Computing*, Vol. 19, No. 1, pp. 27–43 (2015)
- [14] 斎藤: ビデオ観察法による食行動に関する研究—観察方法と食事摂取スタイル—; *民族衛生*, Vol. 61, No. 5, pp. 276–284 (1995)
- [15] M. R. Abid, P. E. Meszaros, R. F. d. Silva and E. M. Petriu: Dynamic hand gesture recognition for human-robot and inter-robot communication; *2014 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, pp. 12–17 (2014)
- [16] Y. Peng, Y. Yan, W. Zhu and J. Zhao: Vehicle classification using sparse coding and spatial pyramid matching; *2014 IEEE 17th International Conference on Intelligent Transportation Systems (ITSC)*, pp. 259–263 (2014)
- [17] J. Mannil, M. M. Bidmeshki and R. Jafari: Rejection of irrelevant human actions in real-time hidden Markov model based recognition systems for wearable computers; *WH '11 Proceedings of the 2nd Conference on Wireless Health*, No. 8 (2011)
- [18] H. Chen, L. Chen, T. P. Albright and Q. Guo: Improved logistic regression approach to predict the potential distribution of invasive species using information theory and frequency statistics; *Sixth IEEE International Conference on Data Mining - Workshops (ICDMW'06)*, pp. 873–877 (2006)
- [19] L. Breiman: Random forests; *Machine Learning*, Vol. 45, No. 1, pp. 5–32 (2001)
- [20] G. H. John and P. Langley: Estimating continuous distributions in Bayesian classifiers; *UAI'95 Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*, pp. 338–345 (1995)
- [21] T. Joachims: Training linear SVMs in linear time; *KDD '06 Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 217–226 (2006)
- [22] N. J. D. Nagelkerke: A note on a general definition of the coefficient of determination; *Biometrika*, Vol. 78, No. 3, pp. 691–692 (1991)

著者略歴

しま よし しょう た
島 吉 翔 太

2015年3月立命館大学情報理工学部情報システム学科卒業。現在、同大学大学院情報理工学研究科情報理工学専攻博士前期課程計算機科学コース在学中。データ工学の研究に従事。情報処理学会会員。

おか むら しゅん 瞬
岡 村 瞬

2014年3月立命館大学情報理工学部情報システム学科卒業。2016年3月同大学大学院情報理工学研究科情報理工学専攻博士前期課程計算機科学コース修了。データ工学の研究に従事。情報処理学会会員。

かじ わら ゆう すけ
梶 原 祐 輔

2009年東京電機大学理工学部情報システム工学科卒業。2011年金沢大学大学院自然科学研究科博士前期課程修了。2013年金沢大学大学院自然科学研究科博士後期課程修了。同年、立命館大学情報理工学部助教。現在に至る。医用画像処理やヒューマンインターフェースに関する研究に従事。

しま かわ ひろ みつ
島 川 博 光 (正会員)

京都大学大学院博士後期課程修了。三菱電機(株)にて実時間制御システムの研究に従事。2002年より立命館大学教授。現在に至る。データ工学、教育工学の研究に従事。博士(工学)。IEEE、ACM各会員。