

レーザセンシングシステムと階層的隠れマルコフモデルによる居住者の行動推定

Indoor Human Behavior Estimation by combining Hierarchical Hidden Markov Model and Laser Sensing System

杉野原 和也 (九州大学) 諸岡 健一 (九州大学)
 ○正 辻 徳生 (九州大学) 正 倉爪 亮 (九州大学)

Kazuya SUGINOHARA, Kyushu University
 Ken'ichi MOROOKA, Kyushu University, morooka@ait.kyushu-u.ac.jp
 Tokuo TSUJI, Kyushu University, tsuji@ait.kyushu-u.ac.jp
 Ryo KURAZUME, Kyushu University

This paper presents a system for estimating indoor human behavior using laser range finders on the floor. The proposed method uses hierarchical hidden Markov model(H-HMM) composed of an action estimate layer and a behavior estimate layer. The former is constructed by two kinds of HMMs: one is the HMM for estimating each action, and the other is the HMM for deciding the human action considering the action continuity. In the latter layer, one HMM learns each behavior by using as the features the relative relationship among the actions and the furniture. Our behavior estimation using such features enable to recognize the behaviors robustly even though the indoor environment is changed.

Key Words: Behavior estimation, Hidden Markov Model, Laser Range Finder, Privacy protection

1 緒言

高齢社会となった日本をはじめ、多くの先進国で高齢者の介護や生活支援に関する諸問題が生じている。この問題の解決策として、高齢者を見守りながら、日常生活を支援するロボットやシステムが期待されている。この生活支援システムを実現するために、我々は、環境に固定センサを配置し、センサから得られるデータから居住者の行動や環境内の物品位置などの環境情報を管理する、環境情報構造化 [1] という概念を提案している。本研究では、情報構造化環境下で居住者の動作・行動を認識するシステムの構築を目的とする。

これまで、環境に分散配置したステレオカメラや RGB カメラを用いて、動作・行動認識の研究が多く行われている [2]。しかし、画像には、顔などのプライバシー情報も記録され、したがって、プライバシー保護の観点から画像を用いることは、居住者にとって好ましくない。これに対し、レーザレンジファインダ (Laser Range Finder:LRF) を使って居住者の追跡と行動予測を行う手法 [3, 4] がある。しかし、文献 [3] の行動予測は、人物位置の遷移に基づくため、静止時や転倒時など、位置の遷移がない間は推定できない。また文献 [4] は、多くの要素を手動で決定しているため、限定された環境でしか適用できず、汎化性が低い。

そこで、本研究では、情報構造化環境内で LRF によって得られたデータから、行動の確率モデルを使って居住者の動作・行動を推定する手法を提案する。提案手法では、人の行動を、複数の基本的な動作と、家具との相対位置関係の組み合わせで記述し、この記述法を使って行動の確率モデルを隠れマルコフモデル (Hidden Markov Model:HMM) によって学習する。基本動作を識別する HMM と、その結果を用いて行動識別を行う HMM、の多層構造を持つシステムを構築する。動作識別をする HMM は、人のクラスタのサイズや移動速度から動作を学習する。一方、行動識別をする HMM は、動作と家具の相対関係から行動を学習する。提案手法では、室内の絶対座標を用いず、家具との相対的な特徴量のみを用いることで、人や室内環境が変化しても、再学習の必要なく汎用性の高いシステムである。

2 フロアセンシングシステム

本研究では、床上に設置した 2 基の LRF からなるフロアセンシングシステム (図 1) を用いて、人物を追跡する。LRF は、

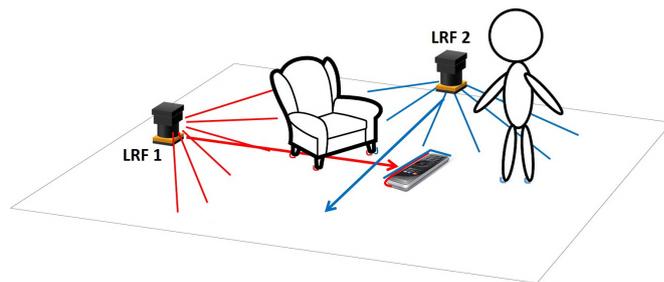


Fig.1 Floor sensing system using two LRFs

レーザの走査面が床上約 2.7cm で水平になるよう設置されており、毎秒 40 フレームで床上を走査する。通常、壁や家具までの距離を計測する、一方、人の足や物体などが床上にあるときは、得られる距離値が通常より小さい。この差分より物体を検出することで、床上に現れる人の足や物体の輪郭を点群 (クラスタ) として得る。我々は、フロアセンシングシステムで計測したデータから、床上の物体および人の足を識別する手法 [4] を構築している。したがって、本研究では、この手法により居住者の足のクラスタを得る。

ここで、通常、手法 [4] によって各時刻の観測データから 1 つの足クラスタが抽出される。しかし、動作や足の動かし方によっては、足クラスタが複数得られる可能性がある。このような計測時のクラスタ数の動的変化に対応するために、各フレームにおいて観測される全クラスタの重心座標の平均値を、そのフレームでの人の位置データとする。さらに、あるフレームで計測された複数のクラスタのサイズの和を、そのフレームでの人のクラスタサイズとする。

3 階層的 HMM による居住者の行動推定

本研究では、環境変化に柔軟な動作・行動識別を行うために、図 2 に示す 2 層からなる階層的な HMM を提案する。第 1 層では、各時刻における人の動作を推定し、その識別結果を第 2 層に送る。第 2 層では、第 1 層で得られた人の動作に加え、室内の

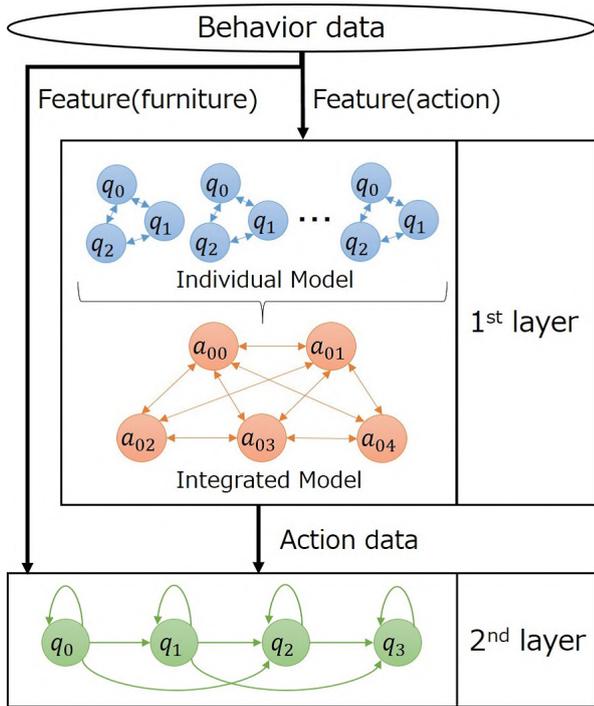


Fig.2 Schema of our hierarchical HMM for estimating human behavior

家具との相対関係を考慮した行動推定を行う。各 HMM はパラメータとして、各状態間の状態遷移確率行列 \mathbf{A} 、各状態における各シンボルの出力確率分布 \mathbf{B} 、初期状態分布 $\boldsymbol{\pi}$ を持つ。モデル $M = (\mathbf{A}, \mathbf{B}, \boldsymbol{\pi})$ と観測されたシンボル系列 $\mathbf{O} = (o_0, o_1, \dots, o_T)$ がある。

3.1 第 1 層：動作推定層

第 1 層では、1 秒毎の動作を識別する。本研究では、周囲の家具に依らない人の体の動きを「動作」と定義し、日常生活における動作として、「歩行」「静止」「床座」「横臥」を識別する。まず、各動作を認識する HMM（以後、動作モデル）を構築する。その後、学習した複数の動作モデルを統合し、1 つの大規模な HMM（以後、統合動作モデル）を生成する。

3.1.1 動作モデルの構築

フロアセンシングシステムにより得られた人の足のクラスタ情報から、動作の特徴量を抽出する。動作特徴を、フレーム間の速度ベクトルの大きさと、クラスタサイズ、の集合である 2 次元ベクトルとする。歩行を例とすると、まず、歩行データを、前後のデータと 1 秒間のデータの重なりがあるように、2 秒 (80 フレーム) 毎に分割し、新たなデータの配列 $\mathbf{O}^{walk} = (\mathbf{O}^{walk}(0), \mathbf{O}^{walk}(1), \dots)$ とする。各データ $\mathbf{O}^{walk}(i)$ は、長さ 80 の配列である。他の動作データについても、同様の処理を行い、観測データ $\mathbf{O} = (\mathbf{O}^{walk}, \mathbf{O}^{stop}, \mathbf{O}^{sit}, \mathbf{O}^{lie})$ を生成する。 \mathbf{O} を用いて、各動作モデル $M^{walk}, M^{stop}, M^{sit}, M^{lie}$ を Ergodic 型 HMM で学習する。

3.1.2 動作モデルの統合

まず、歩行のデータ $\mathbf{O}^{walk}(i) \in \mathbf{O}^{walk}$ に対し、各動作モデルの尤度を求め、4 つの尤度からなるベクトル \mathbf{p}_i を得る：

$$\mathbf{p}_i = \begin{pmatrix} P(\mathbf{O}^{walk}(i) | M^{walk}) \\ P(\mathbf{O}^{walk}(i) | M^{stop}) \\ P(\mathbf{O}^{walk}(i) | M^{sit}) \\ P(\mathbf{O}^{walk}(i) | M^{lie}) \end{pmatrix} \quad (1)$$

\mathbf{p}_i は歩行時の各動作モデルの尤度の関係を表す。これを \mathbf{O}^{walk} のすべてのデータに対して行い、得られた配列 $\mathbf{P}^{walk} = (\mathbf{p}_0, \mathbf{p}_1, \dots)$

を新たな特徴データとする。他動作についても同様に処理を行い、新たな時系列特徴データ $\mathbf{P} = (\mathbf{P}^{walk}, \mathbf{P}^{stop}, \mathbf{P}^{sit}, \mathbf{P}^{lie})$ を生成する。この \mathbf{P} を観測シンボルとして、1 つの Ergodic 型 HMM に学習させる。

統合動作モデルの各状態 q_i における出力確率分布 B_i は 4 次元正規分布 $\mathcal{N}_i(\mathbf{o}, \boldsymbol{\mu}, \mathbf{S})$ であり、それぞれの次元が 4 つの各動作の尤度に対応している。この尤度によって、各状態に、対応する動作のラベル付けする。具体的には、状態 q_i における B_i の 4 次元平均ベクトル $\boldsymbol{\mu}$ 中の尤度の最大値と 2 番目の値を、それぞれ μ_{i1}, μ_{i2} とする。曖昧度を $vague = \mu_{i1}/\mu_{i2}$ と定義する。この時、

- $vague < 0.99$ の時、「尤度最大の動作モデルのラベル」を状態 q_i にラベル付けする。
- $vague \geq 0.99$ の時、この状態は 2 つの動作の尤度がほぼ同一であり、曖昧な動作であると解釈し、「曖昧な動作」を状態 q_i にラベル付けする。

動作の認識法として、動作モデルごとに認識を行い、最も尤度が高い動作を選択する方法がある。しかし、この方法は、動作間の連続性を考慮していないため、突発的に異なる動作と誤認識する可能性がある。一方、本統合動作モデルにより、動作間の連続性や順序関係を考慮した動作識別を行うことができ、上記の誤認識を減らす可能性がある。

3.1.3 統合動作モデルによる動作識別

Viterbi アルゴリズムによって、観測された動作時の時系列データに対応する最適状態遷移系列 $\mathbf{Q} = (q_0, q_1, \dots, q_T)$ を推定する。各状態がある動作に対応しているため、 \mathbf{Q} を動作の時系列データとみなすことができる。曖昧な動作と識別された箇所は、識別後にユーザによって補完することが可能である。

3.2 第 2 層：行動推定層

本研究での行動とは、複数の連続して行われる動作の組と、その時の家具との相対関係で表される。情報構造化環境では、室内の家具の位置は既知であるため、人物と家具の位置関係は容易に決まる。そこで、第 2 層では、第 1 層で推定した動作系列と、室内の家具との相対関係を特徴量として、Left-to-Right 型 HMM による行動学習を行う。識別対象の行動として、棚、冷蔵庫、ベッド、イスに対する、「棚から物を取る」「冷蔵庫から物を取る」「ベッドに座る」「イスに座る」という 4 つの行動を識別する。

観測された行動データについて、3.1.1 節と同様に分割処理を行い、 $\mathbf{O}^b = (\mathbf{O}^b(0), \mathbf{O}^b(1), \dots, \mathbf{O}^b(T))$ を得る。まず、統合動作モデルを用いて、 \mathbf{O}^b から動作を表す特徴量 \mathbf{F}_{act} を抽出する。次に、 \mathbf{O}^b から、動作時の各家具との相対関係を表す特徴量 \mathbf{F}_f を抽出する。

抽出した \mathbf{F}_{act} と \mathbf{F}_f をすべて結合し、行動モデルを学習する方法が考えられる。しかし、全ての家具との相対関係を使用すると、家具同士の位置関係も学習に含まれてしまう。この学習法では、室内の家具位置が変化した際、再学習が必要になる。そこで、提案手法では、行動データに対応する家具についての \mathbf{F}_f を \mathbf{F}_{act} と結合し、得られた行動特徴量をモデルで学習する。これにより、各行動モデルは、行動に関する家具との相対関係のみを学習するため、室内の家具配置が変化しても、家具の座標が既知であれば、行動を識別することが可能になる。

3.2.1 動作特徴量の抽出

Forward アルゴリズムを利用して、各時刻の観測データ $\mathbf{O}^b(t) \in \mathbf{O}^b(t = 0, 1, \dots, T)$ について、統合動作モデルの各状態に存在する確率 α^b を求める：

$$\alpha^b = \left(\begin{pmatrix} \alpha_0^b(0) \\ \alpha_1^b(0) \\ \vdots \\ \alpha_N^b(0) \end{pmatrix}, \begin{pmatrix} \alpha_0^b(1) \\ \alpha_1^b(1) \\ \vdots \\ \alpha_N^b(1) \end{pmatrix}, \dots, \begin{pmatrix} \alpha_0^b(T) \\ \alpha_1^b(T) \\ \vdots \\ \alpha_N^b(T) \end{pmatrix} \right) \quad (2)$$

α^b を動作特徴量として使用する場合、状態数 N により HMM のモデルパラメータの次元数が増大する。これにより、計算時間が増えるだけでなく、 $\alpha^b(t)$ が小さくなり、学習できない可能性がある。そこで、 α^b の各時刻について、同じ動作ラベルを割り振られた状態の尤度の和を取り、行動データの動作特徴量 \mathbf{F}_{act} を求める：

$$\mathbf{F}_{act} = \left(\left(\begin{array}{c} \alpha_{walk}^b(0) \\ \alpha_{stop}^b(0) \\ \alpha_{sit}^b(0) \\ \alpha_{lie}^b(0) \end{array} \right), \dots, \left(\begin{array}{c} \alpha_{walk}^b(T) \\ \alpha_{stop}^b(T) \\ \alpha_{sit}^b(T) \\ \alpha_{lie}^b(T) \end{array} \right) \right). \quad (3)$$

この時、あいまいな動作でラベル付けされた状態は、最大尤度の動作ラベルを持つとみなす。

3.2.2 家具との相対特徴量の抽出

家具との特徴量として、居住者と家具との距離と、家具に対する速さを抽出する。棚を例とすると、時刻 t での観測データ $\mathbf{O}^b(t) \in \mathbf{O}^b$ について、各フレームにおける人と棚の距離と、人の棚に対する速さを求める。全フレームについて、棚に対する距離と速さを求め、それぞれの平均 $d_s^b(t), v_s^b(t)$ を算出する。この処理を全ての観測データに対し行い、棚についての相対特徴量 $\mathbf{F}_f(shelf)$ を得る：

$$\mathbf{F}_f(shelf) = \left(\left(\begin{array}{c} d_s^b(0) \\ v_s^b(0) \end{array} \right), \dots, \left(\begin{array}{c} d_s^b(T) \\ v_s^b(T) \end{array} \right) \right). \quad (4)$$

他の家具についても同様の処理を行い、行動時の家具との関係を表す特徴量 \mathbf{F}_f を得る：

$$\mathbf{F}_f = \left\{ \begin{array}{c} \mathbf{F}_f(shelf) \\ \mathbf{F}_f(refrigerator) \\ \mathbf{F}_f(bed) \\ \mathbf{F}_f(chair) \end{array} \right\} \quad (5)$$

3.2.3 行動モデルの構築

抽出した動作特徴量と、家具との相対特徴量を結合する。例えば、「棚から物を取る」というデータに対しては、 \mathbf{F}_{act} と $\mathbf{F}_f(shelf)$ を使用し、行動特徴量 \mathbf{F}^b を生成する：

$$\mathbf{F}^b = \left(\begin{array}{c} \mathbf{F}_{act} \\ \mathbf{F}_f(shelf) \end{array} \right) = \left(\left(\begin{array}{c} \alpha_{walk}^b(0) \\ \alpha_{stop}^b(0) \\ \alpha_{sit}^b(0) \\ \alpha_{lie}^b(0) \\ d_{shelf}^b(0) \\ v_{shelf}^b(0) \end{array} \right), \dots, \left(\begin{array}{c} \alpha_{walk}^b(T) \\ \alpha_{stop}^b(T) \\ \alpha_{sit}^b(T) \\ \alpha_{lie}^b(T) \\ d_{shelf}^b(T) \\ v_{shelf}^b(T) \end{array} \right) \right). \quad (6)$$

その後、生成された \mathbf{F}^b を Left-to-Right 型 HMM に学習させ、棚に関する行動モデルを生成する。他の行動データに対しても、同様にして行動特徴量を計算し、行動モデルを生成する。

3.2.4 行動モデルによる行動識別

行動モデルを用いた行動識別では、まず、行動データに対し、 \mathbf{F}_{act} と \mathbf{F}_f を求め、各家具に対応する行動特徴量を生成する。次に、対応する行動モデルと行動特徴量の組から、行動データの尤度をそれぞれ求め、尤度が最大の行動を、居住者の行動として認識する。この識別方法により、室内に新しい家具が設置された場合や、既存の家具が除かれた時にも、その家具に対する行動モデルの学習・除去を行うことで、同様に識別が可能である。

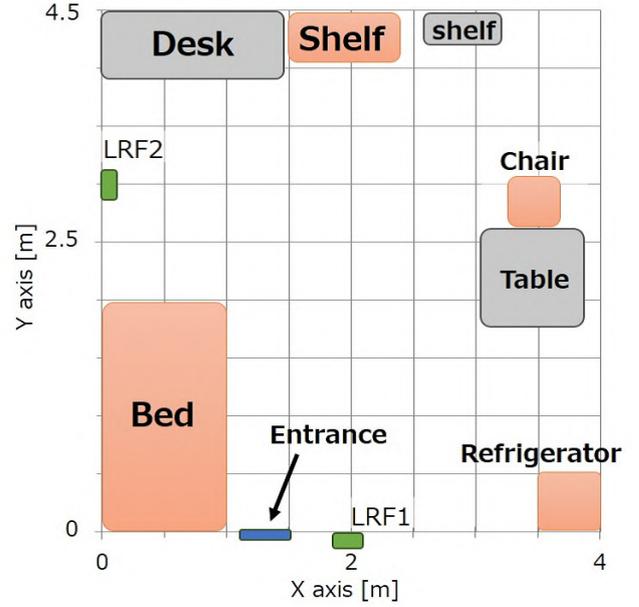


Fig.3 Experimental environment

Table 1 Result of action recognition for the test data

	Recognition results					Recognition rate
	Walk	Stop	Sit	Lie	Amb	
Walk	738	33	16	14	57	0.85±0.05
Stop	6	390	15	0	2	0.94±0.06
Sit	0	18	386	5	7	0.92±0.07
Lie	0	0	9	375	17	0.93±0.06

4 実験

4.1 動作識別実験

提案手法の有効性を示すために、図 3 に示す実験環境において、動作識別実験を行った。男性 17 名、女性 3 名を被験者とし、各動作について、次に示すシナリオのように環境内で 20~30 秒の実験を行い、データを取得した。

歩行 (Walk) 出入口から入室し、室内を自由に歩き回り退出

静止 (Stop) 出入口から入室し、ベッドおよびテーブルにそれぞれ近づき数秒間静止した後退出

床座 (Sit) 出入口から入室し、室内中央に移動し数秒間床座した後退出

横臥 (Lie) 出入口から入室し、室内中央に移動し数秒間横臥した後退出

いずれの動作も室内への進入から開始するため、静止・床座・横臥シナリオには歩行が、床座・横臥シナリオには歩行・静止が、横臥シナリオには床座がそれぞれ含まれている。評価法は、1 名の被験者の動作データをテストデータとし、残りの 19 人のデータを学習データとした、交差検証法を用いた。実験時に録画した画像を真値とし、各時刻における推定結果と比較して識別率を計算した。

表 1 に、統合した動作モデルでの識別の結果を示す。曖昧な動作は、Amb として表記している。提案手法により、全動作について、85% 以上の識別率を得た。平均識別率は 91.6% であった。

Table 2 Result of behavior recognition for the test data

	Recognition results				Recognition rate
	SHELF	FRIDGE	BED	CHAIR	
SHELF	19	0	0	1	0.95
FRIDGE	0	18	0	2	0.90
BED	1	0	19	0	0.95
CHAIR	1	0	0	19	0.95

Table 3 Result of behavior recognition for the test data (after furniture placement changed)

	Recognition results				Recognition rate
	SHELF	FRIDGE	BED	CHAIR	
SHELF	429	0	27	4	0.89±0.008
FRIDGE	6	387	5	11	0.89±0.009
BED	44	1	133	0	0.89±0.022
CHAIR	2	0	0	213	0.93±0.009

4.2 行動識別実験

動作識別実験と同じ環境で、行動識別実験を行った。男性 17 名、女性 3 名を被験者とし、各行動について、次に示すシナリオのように環境内で 10~30 秒の実験を行い、データを取得した。

棚から物を取る (SHELF) 出入口から入室し、棚まで行き、物品を取って退出

冷蔵庫から物を取る (FRIDGE) 出入口から入室し、冷蔵庫まで行き、物品を取り出し退出

ベッドに座る (BED) 出入口から入室し、ベッドまで行き腰掛ける、その後立ち上がり退出

イスに座る (CHAIR) 出入口から入室し、イスまで行き座る、その後立ち上がり退出

学習では、全ての行動について、家具から 2m まで接近した時点を行動開始とし、家具から 2m 離れた時点を行動終了としたデータを使用する。実験では、ある被験者の 1 つの行動データをテストデータとし、残りのデータを学習データとした、交差検証法を用いて、提案手法を検証した。

表 2 に、テストデータに対する、行動識別結果を示す。平均識別率は 93.6% であった。結果より、「冷蔵庫から物を取る」が「イスに座る」に誤認識されるケースが確認された。

4.3 家具位置を変更した行動識別実験

提案手法の有効性を示すため、家具の配置を変更して行動識別を行う。まず、図 3 中の、「ベッド」と「イス (机)」の配置を変更した。次に、男性 5 名、女性 1 名を被験者とし、行動データを計測した。計測の結果、「棚から物を取る」「冷蔵庫から物を取る」「ベッドに座る」「イスに座る」について、それぞれ 13 個、12 個、5 個、6 個のテストデータが得られた。4.2 節で構築した行動モデルを用いて、テストデータに対して行動識別を行った。

表 3 に、テストデータに対する、行動識別結果を示す。テストデータの平均識別率は、それぞれ 89.9% であった。

4.4 考察

提案した統合動作モデルにより、どの動作を行っているかはつきりと識別できない「曖昧な動作」を識別できている。特に、歩行データが曖昧な動作と認識されているのは、他動作の学習データに歩行が含まれているためであると考えられる。しかし、提案手法により、動作の順序関係を学習したため、個別の動作モデルを用いた 1 秒毎の動作識別時に発生していた突発的な誤認識が現象したことを確認しており、提案手法は有効であると言える。

4.2 節での行動識別実験において、提案手法により高い行動識別率を得た。また、家具の配置を変更しても、約 90% の精度で行動を識別できている。一方、「棚から物を取る」と「ベッドに腰掛ける」の間で誤認識が多く見受けられた。この原因は、家具の配置が変化したことにより、家具への近づき方が変化するためだと考えられる。このような変化に対しても頑強な識別を実現できる、特徴量や HMM の構造の選択が今後の課題である。

5 結言

個人差のある動作・行動や室内環境の変化に対応するため、HMM を階層的に組み合わせることで居住者の行動を認識する手法を提案した。動作識別層では、個別の動作を識別する動作 HMM と、全ての動作 HMM を統合し、動作の順序関係を考慮した推定を行う、統合動作モデルを構築した。行動識別層では、統合動作モデルの識別結果と、動作時の周囲の家具との相対関係を学習し、家具に対する行動モデルを生成した。実験により、動作識別・行動識別共に高い識別率を得た。さらに、学習データ取得時と異なる家具の配置に変更した状態で、既存の行動モデルを使用し、行動を識別できることを確認した。今後の課題として、識別可能な行動の種類を増やすことや、一つの家具についての行動モデルで、複数の行動を識別可能にすることが挙げられる。

References

- [1] 村上剛司, 長谷川勉, 木室義彦, 千田陽介, 家永貴史, 有田大作, 倉爪亮, “情報構造化環境における情報管理の一手法”, 日本ロボット学会誌, Vol.26, No. 2, pp.192-199, 2008
- [2] Pau-Choo Chung, Chin-De Liu, “A daily behavior enabled hidden Markov model for human behavior understanding”, Pattern Recognition, Vol.41, Issue.5, pp.1572-1580, 2008
- [3] Taketoshi Mori, Shoji Tominaga, Hiroshi Noguchi, Masamichi Shimosaka, Rui Fukui, and Tomomasa Sato, “Predicting Behaviors of Residents by Modeling Preceding Action Transition from Trajectories”, Journal of Robotics and Mechatronics, Vol.24, No.2, pp.320-329, 2012
- [4] 長谷川勉, Pyo Yoonseok, 田中真英, 辻徳生, 諸岡健一, 倉爪亮, “床上センシングシステムを用いた生活環境における移動物体の位置計測と居住者の行動推定”, 日本ロボット学会誌, Vol.31, No.8, pp.769-779, 2013