

# ライフスタイルにあわせた行動パターンの個別化

山原 裕之<sup>†</sup> 高田 秀志<sup>††</sup> 島川 博光<sup>††</sup>

我々は、ユーザが特別な操作を行わなくとも、日常のふるまいから推測した意図に応じて先行的にサービスを提供する知的空間“Tagged World”を構築している。Tagged Worldでは、ユーザが携帯する小型計算機がユーザのふるまいを認識する。限られたメモリ容量とCPUパワーの中で効果的にふるまいを認識するためには、ユーザの日常における癖に着目する必要がある。本論文は、認識に用いる行動パターンをユーザのライフスタイルに応じて個別化し、低負荷な処理でユーザのふるまいを認識する手法を提案する。

## Personalization of Behavioral Pattern to Individual Lifestyle

HIROYUKI YAMAHARA,<sup>†</sup> HIDEYUKI TAKADA<sup>††</sup>  
and HIROMITSU SHIMAKAWA<sup>††</sup>

We develop an intelligent space “Tagged World” which infers user intention from user behavior to provides proactive services without special operations. This paper proposes a method to personalize a behavioral pattern to user habits in his lifestyle and to recognize user behavior with the pattern by light weight processing on a portable computer in the Tagged World.

### 1. はじめに

本研究はコピキタス環境においてユーザに先行的なサービスを提供することを目指している。たとえば、ユーザが外出するときに火の元が閉まっていることを確認するというサービスが考えられる。ユーザにストレスを与えることなく適切なサービスを提供するためには、ユーザのふるまいから意図をつかむ必要がある。我々は、ユーザが触れたオブジェクトを特定することでユーザのふるまいを認識する知的空間 Tagged World を構築している。Tagged World は、実際のユーザの行動ログとあらかじめ意図ごとに用意した行動パターンを照合することによって認識したユーザのふるまいから、ユーザの意図を推定する。精度の高いふるまい認識を行うために、行動パターンは個人の習慣を学習することで個別化されなければならない。本論文は、特定のふるまいを検知するために、ユーザの行動パターンを個別化する手法を提案する。実験の結果、10個以下の少ないサンプルケースを用いて短時間で個別

化された行動パターンによって、90%以上の割合で正しくふるまいを検知することができた。

### 2. ユーザの接触物に着目したふるまい検知

#### 2.1 Tagged World

我々は、ユーザのふるまいを認識する知的空間 Tagged World を構築している。Tagged World は、特定の状況におけるユーザのふるまいを検知することで、ユーザの意図を推定し、意図に応じて先行的なサービスを提供することを目的としている。たとえば、ユーザが外出するさいに火の元が閉まっていないことを警告したり、エレベータをあらかじめユーザの階まで呼んでおくといったサービスが考えられる。これらのサービスは、ユーザの危険の芽を事前に摘んだり、ユーザの生活をより快適にすることができる。

Tagged World は、財布、携帯電話、ドアノブ、カップなど、人間の生活空間におけるさまざまなオブジェクトに RFID タグが貼り付けられた、あるいは内蔵された知的空間である。オブジェクトに貼り付けられた RFID タグには、タグを識別するために一意のタグ ID が記録されており、タグ ID を用いてオブジェクトを識別することができる。Tagged World において、人間は指に装着する近距離型の RFID リーダを内蔵した小型の携帯型計算機を所持する。人間は特定の意図を達成するさいに、特定のオブジェクトを使用す

<sup>†</sup> 立命館大学大学院 理工学研究科  
Graduate School of Science and Engineering, Ritsumeikan University

<sup>††</sup> 立命館大学 情報理工学部  
Department of Information Science and Engineering,  
Ritsumeikan University

る．そこで、ユーザが携帯する小型計算機は、意図に応じて適切なサービスを提供するために、ユーザの触れたオブジェクトからユーザの意図を推定する．この小型計算機が Tagged World における人間のアシスタントとして機能することから、これをポケットアシスタントと呼ぶ．ユーザがオブジェクトに触れると、ポケットアシスタントはタグ ID と接触時の時刻印を記録する．この時系列はユーザの動作の対象を表す詳細な行動ログであり、ユーザの意図や目的を示唆している．Tagged World では、この行動ログをあらかじめ用意した行動パターンと照合することで、ユーザのふるまいを認識する．

## 2.2 個人ごとの習慣的行動

ユーザに先行的にサービスを提供するためには、ユーザのふるまいからその意図をつかむことが重要である．日常生活において、ユーザは常にサービスを必要としているわけではない．一般的にユーザとしては、ユーザ自身のモードが大きく変化する場面で、サービスを提供されることが望ましい．ユーザが外出する場面を考えると、一度家の外に出た後に火の元を閉め忘れたことに気付いたために、家の中に戻ることは労力を要する行為であろう．外出時以外にも、ユーザのモードが大きく変化する場面として、帰宅時、起床時、就寝時が考えられる．Tagged World では、ユーザの意図を推定することで、モードが変わる前に先行的にサービスを提供することを目指している．

人間は日常生活の特定の状況において、習慣的な行動をとる．これは、特定の状況において習慣的に同じオブジェクトに触れることを意味する．たとえば、外出する状況における人間のふるまいには“財布を持つ”“腕時計を着ける”“トイレに行く”というさまざまな行動が含まれる．腕時計を着けない人やトイレに行かない人もいるため、外出のふるまいに含まれる行動の種類やその順序は、個人の習慣に依存する．

本研究では、ユーザの意図を正しくつかむために、ユーザ個々のライフスタイルにおける習慣に着目する．ユーザの習慣は個人の行動パターンとして表現される．Tagged World では、特定の意図のもとに行われるユーザのふるまいにおける特徴的なパターンを行動パターンと呼ぶ．行動パターンは個人ごとの習慣を表現するために、日々の行動から得られるユーザ個人の行動ログを用いて、個別化されなければならない．

Tagged World では、特定の状況においてユーザが触れたオブジェクトの種類とその順序を記録した行動ログで、行動パターンを個別化する．ユーザにストレスを与えることなくサービスを提供しなければならない

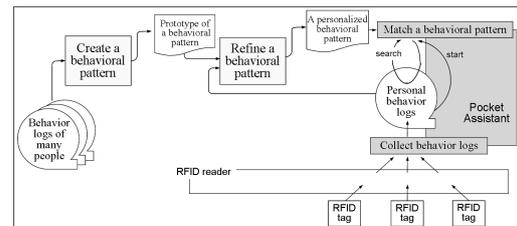


図 1 機能モデル図

いので、実用性を考えると、行動パターンの個別化は短期間で急速に行われる必要がある．Hidden Markov Model(HMM) などの既存手法<sup>1),2)</sup> では、パターンを個別化するための学習に多くのサンプルケースが必要であり、個人への適応に時間がかかるため、Tagged World に適用することはできない．

## 2.3 携帯型小型計算機上でのふるまい検知

Tagged World では、ユーザの意図を推定するためにポケットアシスタント上で行動ログを解析する．ポケットアシスタントは小型計算機であるため、メモリ容量と CPU パワーが限られている．そのため、認識精度を下げることなく、かつ、負荷の軽い処理によって、ユーザのふるまいを認識する必要がある．

既存の研究では、ジェスチャや移動経路など、ユーザの動作そのものを計測対象としている<sup>1),3)~5)</sup>．これらはいまいち性を多く含む連続量として計測される．そのため、似た動作をした異なる意味の行動を区別するために負荷の大きな処理が必要となる．

## 3. 携帯型小型計算機における急速な個人適応

### 3.1 個人のライフスタイルへの適応

本論文は、行動パターンを個人のライフスタイルに適応させ、個別化する手法を提案する．図 1 は提案手法において行動パターンの個別化を行うための機能モデルを示している．行動パターンは個人ごとに異なる．本手法はあらかじめ特定の状況における個人の行動ログをもとに生成される行動パターンを用いて、ユーザのふるまいを検知する．行動パターンは検知すべきふるまいごとに生成される．ユーザがオブジェクトに触れるとユーザの装着した RFID リーダがタグ ID を読み取る．その履歴が行動ログとして記録される．ユーザのふるまいはこの行動ログと行動パターンを照合することで検知される．

ユーザ個人の行動ログが得られていない段階では、有用な行動パターンを生成することは難しい．そこで、最初に多人数の行動ログを用いて行動パターンの雛型が生成される．行動パターンの雛型は個人の習慣に適応していないため、認識の精度は高くない．ユーザが

ポケットアシスタントを使用し始めると、日々の生活の中でユーザ自身の習慣を含んだ行動ログを収集することができる。行動パターンの雛型はユーザ個人の行動ログを用いて洗練される。洗練された行動パターンは、個人の習慣に適應して個別化された行動パターンであるため、認識精度は向上する。行動パターンの洗練は、ユーザの最新の行動ログを用いて繰り返される。

### 3.2 確率推論と順序照合の分離

本論文は、ふるまい検知のための順序照合を確率推論から分離した2段階検知手法を用いて、ユーザのふるまいを以下の2段階で検知する。

- (1) ユーザが触れたオブジェクトの種類を検査する
  - (2) ユーザがオブジェクトに触れた順序を検査する
- 第1段階では、ユーザが触れたオブジェクトの種類のみを考慮し、確率モデルを用いてふるまいを推定する。外出時のふるまいを考えてみる。外出時にユーザが触れるオブジェクトは、料理や食事のときに触れるオブジェクトとは異なる。この場合、オブジェクトの種類を検査するだけで、高い確率でユーザの外出のふるまいを検知することができる。しかし、外出時に触れるオブジェクトは帰宅時に触れるオブジェクトと似ていることを考えると、第1段階だけでユーザのふるまいを特定することはできない。第2段階では、ユーザがオブジェクトに触れた順序に着目することで、より詳細に行動ログを評価し、ふるまいを検知する。2段階検知は第1段階における確率推論と第2段階における順序照合を分離することによって、ふるまい検知に必要なポケットアシスタントの負荷を軽減する。

既存手法でユーザの行動認識に用いられるHMMのような確率モデルは、確率推論と順序照合を統合した処理を行う。ふるまいを2状態間の状態遷移の連続として捉えているため、確率的に稀な行動を含むふるまいをうまく認識できない可能性がある。2段階検知手法は、ふるまい検知の計算コストと検知精度の両面において、既存手法より効果的であると考えられる。本手法は、順序照合を毎回行うのではなく、第1段階で確率推論を用いてふるまいの候補を粗く選別することによって、ポケットアシスタントの負荷を軽減する。第2段階では確率モデルを用いずに詳細な順序の検査を行うため、確率的に稀な行動を含むふるまいを検知することができる。

## 4. 確率推論を用いたふるまい候補の選別

### 4.1 ふるまいの3階層モデル

第1段階では、ベイジアンネットワークによって表現された行動パターンを用いてユーザのふるまいを検

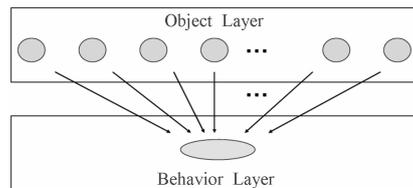


図2 2階層の確率推論ネットワーク

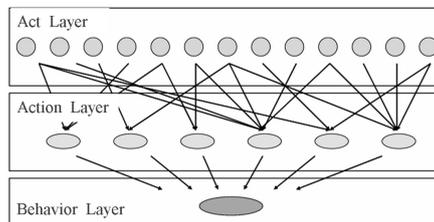


図3 3階層の確率推論ネットワーク

知する。目的は、その行動パターンで検知すべきふるまいであると推定できる行動ログの候補を粗く選別することにある。第1段階では、目的のふるまい以外のふるまいを多少誤って検知したとしても、目的のふるまいを確実に検知することが望ましい。

確率推論の精度はベイジアンネットワークの構造に大きく依存する。統計データから最適なネットワーク構造を自動的に決定するための手法としてK2アルゴリズムがよく知られている。K2アルゴリズムを用いると、多数の循環パスが出現する複雑なネットワーク構造となり、確率伝播計算が停止しない可能性がある。

これらの問題に対処するために、提案手法はベイジアンネットワークの構造に制限を加えた確率推論ネットワークを用いる。循環パスを持たないネットワーク構造として図2に示す2階層ネットワークが考えられる。2階層ネットワークは、ユーザの生活空間に存在するオブジェクトへの接触からふるまいの生起確率を求める。しかし、ひとつのノードが多数の親ノードと持つ場合、ネットワークのメモリ量が増大する危険がある。携帯型小型計算機であるポケットアシスタントはメモリ容量に制約があるため、そのようなサイズの大きいベイジアンネットを保持しておくことは難しい。ゆえに提案手法は、図3に示す3階層ネットワークを用いる。3階層ネットワークは人間の行動を以下の3種類の粒度に階層化してモデル化する。

- act: ユーザのオブジェクトへの接触。センシング可能な人間の行いの最小単位。
- action: 意図や目的を達成するために実施するactの並び。
- behavior: 特定状況で習慣的に行うactionの集合体。

3階層ネットワークはこれらの act, action, behavior をそれぞれノードとして構成する, まず act 層の各 act の発生の有無を証拠として, action 層の各 action の発生確率が計算される. そして action からさらに確率伝播が行われ, 最終的にふるまいの生起確率が計算される. この3階層ネットワークは循環パスを持たないため, 確率伝播計算は必ず停止する. また, ひとつのノードが持つ親ノードの数が比較的少ないため, ネットワークのメモリサイズを抑えることができる.

#### 4.2 確率推論ネットワークの洗練

提案手法は, 最初に多人数の行動ログを用いて確率推論ネットワークの雛形を生成する. 多人数の行動ログは, 検知すべきふるまいごとにあらかじめ収集しておく. その後, 確率推論の精度をより高くするために, 多人数の行動ログに対して個人の習慣を含んだ行動ログを加えて, 確率推論ネットワークを洗練する.

ネットワークを洗練する方法として, ネットワークの構造を作り直す方法と構造は変更せずにノード間の依存関係を示す条件付確率表 (CPT) の値を再計算する方法の2つが考えられる. ベイジアンネットワークの構造を決定するための計算コストは, 学習のために CPT を再計算する計算コストよりも大きい. そのため本手法は, ネットワークの雛形を生成する時点でネットワークの構造は決定しておき, CPT を再計算することによってネットワークを洗練する.

### 5. 接触物の離散順序に基づくふるまい検知

#### 5.1 順序対集合で表現する行動パターン

提案手法は第2段階において, ユーザが触れたオブジェクトの順序からふるまいを検知するために, あらかじめ特定の状況における行動パターンを用意しておく. 行動パターンは, オブジェクトの順序対で表現される. 以下に外出の行動パターンを例に挙げて, 行動パターン生成の流れを示す. 行動パターンは,

- (1) 行動ログを収集する
- (2) 順序対を列挙する
- (3) 各順序対の出現回数をカウントする
- (4) 出現回数が閾値以上の順序対を抽出する

という流れで生成される.

本論文では, 行動パターンの生成に用いる行動ログのサンプルケース数をウィンドウサイズと呼ぶ. サンプルケースとして, 外出時の個人の行動ログを  $w$  ケース収集する. 各ケースの行動ログに含まれるオブジェクトは異なる. 行動ログ中で  $m$  個のオブジェクトに順に触れていた場合, 行動ログ  $l$  は接続  $\{o_1, o_2, \dots, o_i, \dots, o_m\}$  で表現される. ただし,  $o_{i-1} \neq o_i (1 < i \leq m)$

である. 次に, 収集した行動ログから2つのオブジェクト間の順序対を列挙する. あるオブジェクト  $o_i$  に触れてからオブジェクト  $o_j$  に触れていた場合, 順序対  $p$  を  $\{o_i \rightarrow o_j\}$  と表記する. このとき,  $o_i = o_j$  の場合も除外しない. 行動ログ中で連続して触れられたオブジェクトの対だけでなく, 隣りあっていないオブジェクトの組も順序対として列挙する. たとえば, 行動ログ  $\{o_1, o_2, o_3\}$  から列挙される順序対は,  $p_1: \{o_1 \rightarrow o_2\}$ ,  $p_2: \{o_1 \rightarrow o_3\}$ ,  $p_3: \{o_2 \rightarrow o_3\}$  となる.

すべてのサンプルケースにおける順序対を列挙した後に, 各順序対の出現回数をカウントする. 1つのサンプルケースにおいて同一の順序対が何回出現しているかには注目せず, 各順序対が  $w$  個のサンプルケースのうち何ケースに出現しているかをカウントする.

最後に, 列挙された順序対集合の中から, 出現ケース数が閾値  $e$  よりも多い順序対のみを抽出する. 抽出された  $n$  個の順序対の集合で表現される行動パターン  $\pi$  は以下のように定義できる.

$$\pi = \{p_1, p_2, \dots, p_n\}, \text{ occur}(p_i) > e,$$

ここで, 関数  $\text{occur}(p_i)$  は順序対  $p_i$  の  $w$  個のサンプルケース中の何ケースに出現したかを返す.

既存の研究において時間軸に沿った人間の行動パターンを生成するさいに用いられている HMM では, 時間的に連続である2状態間の遷移確率を考慮して行動パターンが生成される. しかし実際の人間の行動を局所的に見れば, 同じ行動を行う場合にも毎回順序が細かく入れ替わっていることが多い. また, 大局的に見れば行動順序の規則性が存在することは明らかである. このような, 行動順序に規則性のある部分とならない部分が混在する複雑な人間の行動を, 時間的に連続な2状態に注目した行動パターンでは表現することは難しい. これに対して提案手法は, 行動ログ中で隣りあった2つのオブジェクトの順序対だけでなく, 隣りあっていないオブジェクトの順序対も考慮して行動パターンを生成することで, 複雑な人間の行動を柔軟に, かつ簡潔に表現できるという利点を持つ. 結果として, 小型計算機上で低負荷なふるまい認識を行うために不可欠である単純さを保っている.

#### 5.2 ふるまいの検知

提案手法は特定のふるまいを検知するために, あらかじめ生成した順序対集合の行動パターンと, 実際の人間の行動から得られる行動ログを照合する. 第2段階において, 照合対象の行動ログが行動パターンに適合している度合いを示す値を特徴ポイントと呼ぶ.

照合手法を図4を用いて説明する. 図の右上には, あらかじめ生成した行動パターンが示されている. こ

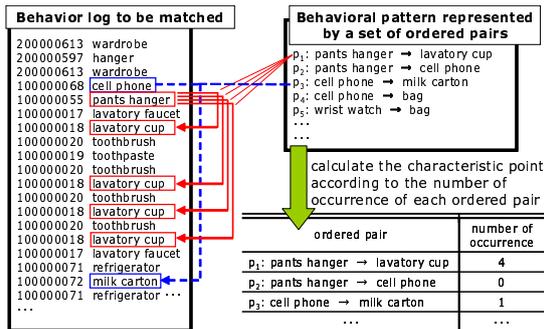


図 4 行動パターンの照合

れに対して図の左側に示されているのは、現在行動している人間から得られた行動ログである。まず最初に、行動パターンに含まれる各順序対が照合対象の行動ログに含まれている回数をカウントする。図 4 では、順序対  $p_1$  : {pants hanger  $\rightarrow$  lavatory cup} は照合対象の行動ログ中に 4 回出現する。同様に、順序対  $p_2$  : {pants hanger  $\rightarrow$  cell phone} は 0 回、順序対  $p_3$  : {cell phone  $\rightarrow$  milk carton} は 1 回、というようにカウントする。次に、順序対の出現回数から特徴ポイントを求める。行動パターン  $\pi$  :  $\{p_1, p_2, \dots, p_n\}$  に対して、特徴ポイント  $CP$  は以下の計算式で求める。

$$CP = \sum_{i=1}^n \text{calcAddedPoint}(\text{occur}(p_i)).$$

ここで、

$$\text{calcAddedPoint}(k) = \sum_{i=1}^k \text{point}(i).$$

とする。本手法では、同じ順序対が複数回出現した場合、出現するたびに異なるポイントが加算される。 $\text{point}(k)$  は同じ順序対が  $k$  回目出現したときに加算されるポイントを示す。たとえば、ある順序対が行動ログ中に 3 回出現した場合、その順序対によって加算される特徴ポイントの値は、 $\text{calcAddedPoint}(3) = \text{point}(1) + \text{point}(2) + \text{point}(3)$  である。加算されるポイントは、順序対の種類には依存しない。行動パターンと行動ログを照合した結果、得られた特徴ポイント  $CP$  があらかじめ設定した検知閾値以上であれば、ふるまいを検知する。

既存研究で用いられている HMM は、2 状態間の遷移確率と各状態における記号出力確率の積を計算することで、観測した記号列が出力される確率を求める。そのため、出力確率が稀な記号が観測記号列の一部に存在した場合、観測記号列が出力される確率が低くなる。実際の人間の行動を例に考えると、“外出時に玄関

ドアを開けるさい、ドアノブに手をかけてからチェーンがかかっていることに気付いてチェーンをはずした”というような、普段はあまり現れない動作の順序の一部に存在しただけで、HMM は外出のふるまいを上手く検知できない可能性がある。これに対して提案手法は、順序対の出現回数に応じて特徴ポイントを加算することによって、特徴的な行動順序が存在することのみを基準にふるまいを検知する。出現確率の低い順序対は、行動パターンを生成する時点で排除されている。提案手法は、行動パターンの照合において、あえて確率モデルを排除することで、確率的には稀な行動が出現した場合でも、柔軟なふるまい検知が可能である。

## 6. 評価

### 6.1 実験概要

提案手法の有効性を検証するために、行動パターン個別化とふるまい検知に関する実験を被験者 15 人に対して行った。本論文では、検知すべきふるまいの行動ログを正の事例、検知すべきでないふるまいの行動ログを負の事例と呼ぶ。実験では、検知すべきふるまいを外出のふるまいに設定した。Tagged World を構築した実験空間において、正の事例と負の事例の両方を収集した。負の事例としては、外出のふるまいと触れるオブジェクトが似ているために、誤って検知してしまう可能性がある帰宅のふるまいを収集した。またその他に、外出時に行われる可能性がある行動や外出時と行動や移動経路が似ていると考えられる行動も、負の事例として収集した。被験者 1 人あたりに収集した行動ログは、正の事例 20 ケース、負の事例 10 ケースである。合計で、正の事例 300 ケース、負の事例 150 ケースを収集した。

### 6.2 確率推論ネットワークのメモリサイズ

第 1 実験では、K2 アルゴリズムを用いた構築したネットワークおよび 2 階層ネットワークと 3 階層ネットワークの構造を評価する。K2 アルゴリズムによる確率推論ネットワークを生成すると、ノード数が 2 つの時点で循環パスが発生し、確率推論が停止しなくなる。2 階層ネットワークのメモリサイズは図 5 に示すように、ノード数が 13 を超えると指数関数的に増大する。一方、3 階層ネットワークはノード数が 50 以下であればほとんどメモリサイズが増加しない。実験の結果から、3 階層ネットワークが小型計算機でふるまい認識を行うためのメモリ制約の問題に対して有効であることは明らかである。

### 6.3 確率推論ネットワークの個別化

第 2 実験では、確率推論ネットワークの洗練の有効

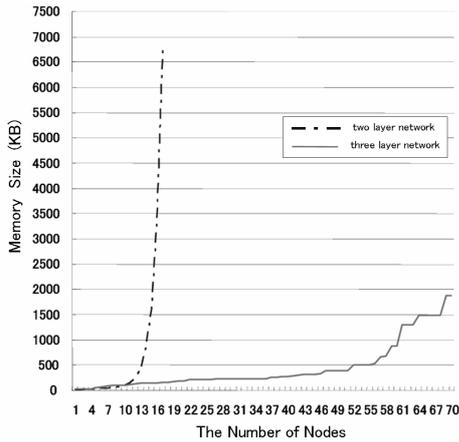


図5 確率推論ネットワークのメモリ量

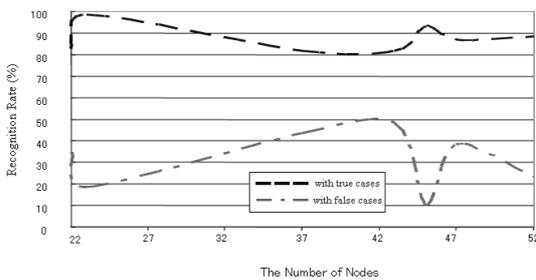


図6 確率推論ネットワークの洗練

性を評価する。ふるまいの推定は、ネットワークにおける behavior ノードの初期確率を閾値として行う。

洗練前の確率推論ネットワークを用いると、ノード数が20個以下の場合には正の事例の認識率は高いが、負の事例の認識率は低い。ノード数が少ない場合、act 層の各ノードがふるまい層のノードと強い依存関係を持つため、正の事例の認識率が高くなる。しかし、それらの act がその他のふるまいとも強い依存関係をもつ act であれば、本来検知すべきでないふるまいを誤って検知してしまうと考えられる。そのため、確率推論ネットワークはより多くのノードで構成することが望ましい。しかし、ノード数を20個以上に増やすと、ノード数の増加に応じて負の事例の認識率は上昇していくが、一方で正の事例の認識率は徐々に低下する。

図6は洗練後の確率推論ネットワークによる、ノード数の変化に伴うふるまい認識率を示している。ネットワークは個人の行動ログによって洗練されている。ノード数が増加した場合、負の事例の認識率は上昇するが、正の事例の認識率が80%を下回ることはない。確率推論ネットワークの役割は、ふるまいの候補を絞り込むことなので、負の事例の認識率を上昇させるために、正の事例の認識率を低下させることは好ましく

表1 順序対の出現回数に応じた特徴ポイント計算関数の値

	point(1)	point(2)	point(3)	point(4)
alg-0	16	16	16	16
alg-3	16	0	0	0
alg-11	16	8	4	2

ない。実験の結果、確率推論ネットワークの洗練は、ふるまいの認識精度を上げるために有効だと言える。

#### 6.4 順序照合における検知手法

第3実験では、ふるまい検知の第2段階における行動パターン照合時の特徴ポイント加算方式と検知閾値の設定を評価する。特徴ポイント加算方式として、12個のアルゴリズムを比較評価する。表1は、algorithm-0 から algorithm-11 までの12個のアルゴリズムのうち、代表的なものに関して、同じ順序対が複数回出現したときに特徴ポイントに加算されるポイントを示している。 $point(k)$  は順序対が  $k$  回目に出現したときの加算ポイントである。各アルゴリズムは、順序対の出現回数に関する重み付けが異なるため、同じ順序対が複数回出現した場合に、2回目以降の出現で加算されるポイントの値が異なる。たとえば algorithm-3 は、順序対の出現回数をユーザのふるまいに関する特徴であると捉えないため、最初に出現したときのみポイントを加算する。どのアルゴリズムも5回目以降の出現に対してはポイントを加算しない。

検知閾値は過去の特徴ポイントの値から計算する。第3実験では、以下の検知閾値の設定を比較する。

1. 平均値タイプ 過去の特徴ポイントの平均値  $Avg$  を計算し、その値の90%から10%の値を検知閾値に設定する。 $(Avg*90\% \sim Avg*10\%)$
2. 標準偏差タイプ 過去の特徴ポイントの平均値  $Avg$  および標準偏差  $\sigma$  を計算し、平均値から  $-\sigma$ ,  $-2\sigma$  の値を検知閾値に設定する。 $(Avg-\sigma, Avg-2\sigma)$
3. 最小最大中間値タイプ 過去の正の事例の特徴ポイント最小値と負の事例の特徴ポイント最大値の平均値を検知閾値に設定する。(Mid Of MinMax)
4. 平均中間値タイプ 過去の正の事例の特徴ポイントの平均値と負の事例の特徴ポイントの平均値の中間値を検知閾値に設定する。(Mid of Avg)
5. 標準偏差中間値タイプ 過去の正の事例の特徴ポイントの平均値を  $M$  として、 $M-\sigma$ ,  $M-2\sigma$  の値を求める。同じく、過去の負の事例の特徴ポイントの平均値を  $m$  として、 $m+\sigma$ ,  $m+2\sigma$  の値を求める。 $M-\sigma$  と  $m+\sigma$  の中間値、 $M-2\sigma$  と  $m+2\sigma$  の中間値を検知閾値として設定する。 $(Mid\ of\ Avg-\sigma, Mid\ of\ Avg-2\sigma)$

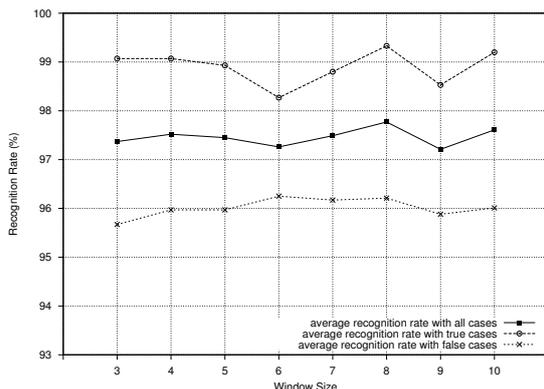


図7 ウィンドウサイズと認識率の相関関係

1, 2 は正の事例の特徴ポイントのみから検知閾値を設定する。3, 4, 5 は正負両方の事例から得られる特徴ポイントを組み合わせで検知閾値を設定する。

第3実験は、正の事例20ケースからランダムで選出した10ケースと負の事例10ケースを用いて、ウィンドウサイズを5に設定した行動パターンの生成と照合を繰り返し、特徴ポイント加算アルゴリズムと検知閾値設定の全ての組み合わせにおける正負の事例の分類精度を比較する。

実験の結果、最も分類精度が高い組み合わせは algorithm-3 と Avg\*50 である。algorithm-3 は同じ順序対が複数回出現した場合でも、2回目以降の出現に関しては特徴ポイントを加算しないため、正の事例の中でもケースごとに特徴ポイントのばらつきが発生しない。そのため、検知閾値の値が安定し、精度が高くなる。正負の事例から得られる特徴ポイントを組み合わせると、正の事例の特徴ポイントのみを用いた場合よりも望ましい検知閾値が計算できる可能性を考慮したが、実験の結果、正の事例の特徴ポイントのみから検知閾値を計算した場合と同程度の認識率であった。むしろ、負の事例はケースごとの特徴ポイントのばらつきが大きく、負の事例から得られる特徴ポイントが最適でない場合、正の事例の特徴ポイントのみから検知閾値を計算した場合よりも認識率は低い。

### 6.5 ふるまいの認識率

第4実験は、提案手法が正の事例を正しく検知し、負の事例を誤って検知しないことを実証するために、行動パターンの生成と照合を繰り返してふるまいの認識率を評価する。また、ウィンドウサイズの変化による認識率の違いから行動パターンの個人への適応速度についても考察する。ここでは、第3実験では用いなかった正の事例10ケースを照合対象の行動ログとして用いる。以下に、実験の流れを示す。

表2 被験者ごとの外出のふるまい認識率

going out $w = 4$	Recognition Rate (%)	
	True Cases	False Cases
Subject A	100.00	100.00
Subject B	100.00	92.60
Subject C	100.00	97.40
Subject D	98.00	99.80
Subject E	100.00	90.00
Subject F	100.00	94.20
Subject G	98.00	90.80
Subject H	100.00	100.00
Subject I	100.00	100.00
Subject J	100.00	98.20
Subject K	96.00	100.00
Subject L	100.00	90.00
Subject M	94.00	90.20
Subject N	100.00	96.40
Subject O	100.00	100.00
Average	99.07	95.97

- (1) 第3実験で生成した5つの行動パターンから1つを選ぶ。
- (2) 正の事例10ケースの中からまだ照合対象に選ばれていない1ケースを選んで照合する。同時に、負の事例10ケースとも照合を行う。
- (3) 照合した1ケースの行動ログをウィンドウに加えて、行動パターンを学習する。
- (4) (2)(3)を10回繰り返して正の事例、負の事例それぞれの認識率を求める。
- (5) (1)~(4)を5回繰り返して、平均認識率を求める。

以上の操作を、ウィンドウサイズ3~10の設定でそれぞれ行う。初期閾値は第3実験の結果から設定する。

第4実験の結果として得られたウィンドウサイズごとの認識率を図7に示す。また、被験者ごとの認識率を表2に示す。正の事例は98%以上、負の事例は95%以上の高い認識率を示した。第2段階における認識率は、第1段階における確率推論による認識率と比較して、正の事例と負の事例の両方に関して高い認識率を得られる。ウィンドウサイズの変化による認識率の違いはほとんど見られない。提案手法はユーザの動作の対象オブジェクトに注目することで、簡潔で少ないパラメータからふるまいを認識することができる。これは、提案手法は少ないサンプルケースを用いて短期間のうちに行動パターンを個々のユーザに適応させることができることを示している。一般に、記号列パターンの生成と照合に良く用いられているHMMなどの既存手法は、パターンを生成するためにはあらかじめ多数の学習用サンプルが必要とされている。これに対して、提案手法はパターン生成に多くのサンプルを必要とせず、行動パターンを短期間で個別化できる

点において有効だと言える。

外出以外のふるまいを検知する例として、帰宅のふるまいに関して同様の実験を行った。ウィンドウサイズは4に設定した。正の事例の認識率は93.20%、負の事例の認識率は92.28%の認識率を示した。帰宅のふるまいは外出のふるまいに比べて、触れるオブジェクトの数が少ないことから、正の事例の特徴ポイントと負の事例の特徴ポイントの値の差が小さくなり、やや認識率が下がったと考えられる。

## 7. 関連研究

文献6)のパターンマイニング技術は、多くのサンプルケースの中から最大頻出集合を見つけ出すことを目的としている。我々が対象とする人間の複雑な行動は、最大頻出集合では表現できない。行動パターンは少ないサンプルケースによって個人に適應されなければならない。文献1), 2), 7)のようにHMMやマルコフ連鎖を用いる手法は、個人に適應するために多くのサンプルケースを必要とする。また、それらの手法は多くのあいまい性を含むユーザの動作そのものに注目しているため、処理の負荷が重い。モーションキャプチャやカメラ映像を用いている文献3), 8), 9)の手法も、負荷の重い処理が必要となる。これらの手法は軽量の処理を必要とする我々の問題には適用できない。

文献10)はWebから行動パターンを取得する。しかし、行動パターンを個人に適應させないため、個人の意図に応じたサービスを提供することはできない。

## 8. おわりに

本論文は、ユーザのふるまいを検知するために、個々のユーザの習慣に応じて行動パターンを短期間で個別化する手法を提案した。提案手法は、少ないサンプルケースを用いて急速に行動パターンを個別化することができる。順序照合を確率推論と分離した2段階検知によって、軽量の認識処理を実現する。実験の結果、90%以上の確率でユーザのふるまいを検知した。

今後は、空間の情報を個人のふるまいと組み合わせ、詳細な状況判断を基にサービスを提供する予定である。

## 参考文献

- 1) Aoki, S., Iwai, Y., Onishi, M., Kojima, A. and Fukunaga, K.: Learning and Recognizing Behavioral Patterns Using Position and Posture of Human Body and Its Application to Detection of Irregular State, *IEICE Transactions (D-II)*, Vol.J87-D-II, No.5, pp.1083-1093 (2004).
- 2) Fukuda, T., Nakauchi, Y., Noguchi, K. and Matsubara, T.: Time Series Action Support by Mobile Robot in Intelligent Environment, *Proc. 2005 IEEE International Conference on Robotics and Automation(ICRA2005)*, pp.2908-2913 (2005).
- 3) Kidd, C.D., Orr, R.J., Abowd, G.D., Atkeson, C.G., Essa, I.A., MacIntyre, B., Mynatt, E., Starner, T.E. and Newstetter, W.: The Aware Home: A Living Laboratory for Ubiquitous Computing Research, *Proc. the 2nd International Workshop on Cooperative Buildings (CoBuild 1999)*, *Lecture Notes in Computer Science*, vol 1670, pp.191-198 (1999).
- 4) Matsuoka, K.: Smart house understanding human behaviors: who did what, where, and when, *Proc. the 8th World Multi-Conference on Systems, Cybernetics, and Informatics*, pp.181-185 (2004).
- 5) Mori, T., Noguchi, H., Takada, A. and Sato, T.: Sensing Room: Distributed Sensor Environment for Measurement of Human Daily Behavior, *Proc. the 1st International Workshop on Networked Sensing Systems (INSS2004)*, pp.40-43 (2004).
- 6) Cheung, Y.-L. and Fu, A. W.-C.: Mining Frequent Itemsets without Support Threshold: With and without Item Constraints, *IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING*, Vol. 16, No. 9, pp.1052-1069 (2004).
- 7) Isoda, Y., Kurakake, S. and Nakano, H.: Ubiquitous Sensors based Human Behavior Modeling and Recognition using a Spatio-Temporal Representation of User States, *Proc. the 18th International Conference on Advanced Information Networking and Applications (AINA'04)*, pp.512-517 (2004).
- 8) Barbič, J., Safonova, A., Pan, J.-Y., Faloutsos, C., Hodgins, J.K. and Pollard, N.S.: Segmenting Motion Capture Data into Distinct Behaviors, *Proc. the 2004 conference on Graphics interface*, pp.185-194 (2004).
- 9) Mori, T., Segawa, Y., Shimosaka, M. and Sato, T.: Hierarchical Recognition of Daily Human Actions Based on Continuous Hidden Markov Models, *Proc. the 6th International Conference on Automatic Face and Gesture Recognition (FG2004)*, pp.1-8 (2004).
- 10) Perkowski, M., Philipose, M., Patterson, D.J. and Fishkin, K.: Mining Models of Human Activities from the Web, *Proc. the 13th International World Wide Web Conference (WWW 2004)*, pp.573-582 (2004).