独居高齢者の行動パターンに注目した非日常状態の検出

非会員 青木 茂樹* 正員 大西 正輝**
正員 小島 篤博*** 正員 福永 邦雄****

Detection of a Solitude Senior's Irregular States Based on Learning and Recognizing of Behavioral Patterns

Shigeki Aoki*, Non-member, Masaki Onishi**, Member, Atsuhiko Kojima***, Member,
Kunio Fukunaga****, Member

Recently, attention is paid to monitoring systems that watch behavior of a solitude person in home as the population of solitude seniors has increased. This paper proposes a monitoring system focused on behavioral patterns of a solitude senior. In general, the number of behavioral patterns are limited in the case of aged person in a room. It is possible for a system like a HMM to learn the frequently appeared behavioral patterns. By utilizing HMMs to deal with behavioral patterns, the system can detect irregular pattern by the degree of likelihood in the case when non-daily behavioral patterns appeared. Such a case could be an irregular state of the living life of the person. Soon after, the system reports an alarm of occurrence of the irregular state according to demand.

キーワード：行動パターン，焦電型センサ，HMM

Keywords: Behavioral Pattern, Infrared Sensor, HMM

1. まえがき

近年の高齢者人口の急速な増加を背景として，介護支援システムが注目されている。特に，少子化の影響もあって，一人暮らしの高齢者が急増していることから，独居高齢者などの要介護者を対象とした介護支援システムに対する需要が高まりつつある。

要介護者の介護支援システムとしては，ペンダント型ス

イッチを被介護者に配布し，緊急時に被介護者がそのスイッチを押すことによって介護者に異常を通報するシステム⁽¹⁾や，被介護者が毎日血圧や体温，脈拍などのヘルスデータを保健センターに送信し，そのデータに応じて保健師やヘルパーなどを派遣するシステム⁽²⁾が実用化されている。これらのシステムでは，被介護者自身が緊急事態を知らせることや，医療スタッフが脈拍などの医療データを確認することが可能であるため，被介護者の状況を的確に把握することができる。しかし，“スイッチを押す”，“脈拍を測る”など被介護者自身が情報を通知する必要があり，スイッチを押すことが難しい状況では対応できないことや，長期間に亘ってヘルスデータを送信しなければならないことに対して，煩わしさを感じることなどの問題があった。

これに対して，被介護者に負担を強くない方法として，被介護者を無意識下でモニタリングし，状況を通知するシステム⁽³⁾や，無意識下でのモニタリング結果を基に異常を検出するシステム^{(4)~(8)}が提案されている。文献(3)では被介護者が使用する電気ポットの使用状況をインターネットで介護者に知らせるサービスが提案されている。これは，家族などの介護者が被介護者の状況を直接見守るため，被介護者の状況を的確に把握することができるものの，緊急事態の通報は考慮されていない。文献(4)では居間や風呂，トイレなどに設置した赤外線センサを利用したシステム，文献(5)では家庭電気機器のオン・オフを監視するシステ

* 熊本電波工業高等専門学校 電子制御工学科
〒 861-1102 熊本県菊池郡西合志町須屋 2659-2
Department of Electronic Control Engineering, Kumamoto National College of Technology

2659-2, Suya, Nishigoshi, Kikuchi, Kumamoto 861-1102

** 理化学研究所 バイオ・ミメティックコントロール研究センター
〒 463-0003 名古屋市守山区下志段味穴ヶ洞 2271-130
Bio-Mimetic Control Research Center, RIKEN
2271-130 Anagahora, Shimoshidami, Moriyama-ku, Nagoya, Aichi 463-0003

*** 大阪府立大学 総合教育研究機構
〒 599-8531 堺市学園町 1-1
Faculty of Liberal Arts and Sciences, Osaka Prefecture University
1-1, Gakuen-cho, Sakai, Osaka 599-8531

**** 大阪府立大学 大学院工学研究科
〒 599-8531 堺市学園町 1-1
Graduate School of Engineering, Osaka Prefecture University
1-1, Gakuen-cho, Sakai, Osaka 599-8531

ム、文献(6)～(8)では赤外線センサと電気機器のオン・オフを監視するシステムが提案されている。これらのシステムでは、被介護者がトイレや風呂に長く留まっている場合や、朝起きてこない場合などに、異変が発生したことを介護者に自動的に通知することができる。しかし、被介護者の健康状態や精神状態の変化から生じる行動パターンの変化を把握したい場合には、どの時刻に人物がどこにいるかを示す図1のような被介護者の行動パターンの表示を家族などの介護者が直接確認する必要があると考えられる。上記のシステムでは、家族らが被介護者の行動パターンをチェックして、異常がある場合に被介護者に連絡したりすることで、被介護者と介護者の絆が深まり、被介護者の独居の寂しさが紛れたりすることなどの効果が期待できる反面、家族らが常にチェックし続けることは負担が大きく、保健師やヘルパーがチェックをする場合には、プライバシーなどの点で問題が生じる可能性がある。

一方、人物の行動パターンを自動的に分類して学習する手法⁽⁹⁾⁽¹⁰⁾では、全方位視覚センサから得られる入力画像を用いて、人物の位置や姿勢の情報をもとに人物の動作や行動パターンを行動パターン毎に分類して学習し、観測された行動パターンの日常性を計測することができる。この手法では、全方位視覚センサを用いているために、人物が部屋の中で比較的短い時間内に行う動作や行動を詳細に知ることができる反面、風呂やトイレなどカメラを設置することが難しい環境では適用が難しいことや、一日や1週間単位など比較的長い時間間隔で行われる人物の大局的な行動パターンへの適用が難しいことなどが課題となっていた。

そこで本論文では、焦電型センサや電気機器から得られる情報を用いて人物の行動パターンを抽出し、抽出した行動パターンを行動パターンの種類毎に分類して学習⁽⁹⁾することによって、観測された人物の行動が日常的であるか非日常的であるかを判断する手法を提案する⁽¹¹⁾。本手法では、被験者の手を煩わせることなく取得した情報を用いて、自動的に人物の行動パターンの日常性を、設定した単位時間毎にチェックすることができるため、プライバシーや人的負担などの問題が生じない介護支援システムの構築が可能となる。

図1 行動パターンの表示例

Fig. 1. The example of the behavioral patterns.

以下、2. で人物の行動パターンを抽出する手法について述べ、3. で行動パターンを学習し、人物の非日常状態を検出する手法について説明する。その後、4. で実験と考察を行い、5. でまとめる。

2. 人物の行動パターンの抽出

2・1 人物行動の検出 人物が家の中でどのような行動を行っているかを知るためには、人物の位置情報や家電製品の動作状況などが重要であると考えられる。例えば、人物が寝室にいる場合には“就寝”という行動が行われたと考えることができるし、テレビが動作している場合であれば、“テレビを見る”という行動が行われたと捉えることができる。そこで、本研究では玄関、居間、風呂など人物の行動を把握するために重要な位置に焦電型センサを設置して、人物の位置情報を検出する。また、テレビや冷蔵庫などに稼働モニタを取りつけることによって、家電品の動作状況を検出する。

本論文では、高齢者在宅データアルゴリズムコンテスト⁽¹²⁾で公開されているデータを用いて、独居高齢者の行動パターンを抽出する。データは、独居高齢者の行動把握に重要と思われる箇所に設置した24種類のセンサが動作した時間を2001年1月1日から2001年7月26日までの207日間に亘って記録したものである。なお、本データの獲得は被験者に対し、文書ならびに口頭にてその内容・目的について説明し、同意を得た上で行われている。各センサの設置箇所を表1のセンサ名の項目に示し、焦電型センサの配置図を図2に示す。図中の“S”が設置した焦電型

表1 各センサ名と対応づけたラベル

Table 1. The sensors and the labels to detect the behavior of the person.

Label	Sensor
A	Entrance1, Entrance2, Kitchen Door1, Kitchen Door2
B	Refrigerator1, Refrigerator2, Refrigerator3, Refrigerator4
	Bibcock, Microwave Oven, Gas Cooker
C	Living Room
D	Bedroom1, Bedroom2
E	Washing Machine
F	Washroom, Lavatory
G	Dressing Room, Bathroom
H	Buddhist Altar
H	Sunroom1, Sunroom2
J	TV
K	Table

図2 焦電型センサの配置図

Fig.2. The arrangement figure of the infrared sensors.

センサを示している。ただし、冷蔵庫などその他のセンサの設置位置については公開されたデータ中に記述されていない。データの収集期間中に対象者は2回(5月21日, 7月26日)体調を崩しており, 対象者の行動パターンの変化を調べることによって, 体調を崩した日を検出する。

2・2 行動パターンの抽出 一般に, 人物の行動には1日単位で規則性や習慣性が存在すると考えられる。そこで, センサから収集される人物の行動を1日毎にまとめ1日単位で行動パターンを抽出する。

ここでは表1のセンサ名の項目に示す通り, 冷蔵庫に4つのセンサを設置しているなど, きめ細かくセンサを設置してデータを収集しているため, 人物の詳細な動作を検出することができる。しかし, 同一の行動を行っている場合に反応するセンサが多数あるために, センサから出力される情報をそのまま用いると, 正しく行動を検出できない可能性が考えられる。例えば, “炊事” という同一の行動を“電子レンジ”を使用する場合と, 使用しない場合で異なる行動と識別する問題が生じる。また, 2つのセンサの間で人物が行動した場合などに2つのセンサが交互に反応し, 収集したデータ中にノイズ成分が含まれる可能性がある。このため, 人物が移動していないにもかかわらず移動したと判断してしまい, 正しい行動パターンが得られない可能性が考えられる。また, 人物の行動パターンを長期間に亘って観測する場合, 局所的に行われた“動作”よりも大局的に行われた“行動”が重要であると考えられる。

一般に, 人物が行う行動には何らかの目的が存在し, 行動の目的毎に人物の位置や使用する家電製品が異なると考えられる。そこでまず, 同一の行動を行っている時に反応すると考えられるセンサを, センサの設置位置を考慮してまとめ, それらのセンサに同一のラベルをつける。ここでは, 被験者の一日の行動を“外出”, “炊事”, “くつろぎ1”, “就寝”, “洗濯”, “排泄”, “入浴”, “礼拝”, “くつろぎ2”, “テレビ鑑賞”, “食事”の11種類に分類して考え, それぞれの行動によって反応すると考えられるセンサに対して表1に示すようにA~Kのラベルを割り当てている。例えば, ラベルAでは“外出”という行動を表すセンサとして, “玄関1”, “玄関2”, “勝手口1”, “勝手口2”の各センサをまとめている。ここで, “くつろぎ”という行動については, センサの設置位置の距離が離れているために, 同じ“くつろぎ”行動でも目的や行動を行うタイミングが異なる可能性が大きいと考え, 2種類に分割している。

次に, 観測単位時間毎に単位時間内のセンサの反応回数をセンサに与えたラベル毎に調べ, 反応回数が最大のラベルがその単位時間の行動を最も反映していると考えて, そのラベルによって人物の行動パターンを表現する。ただし, 単位時間内に反応したセンサが存在しない場合は, 前の時間に出したラベルに関係する行動を継続中であると考えて, 前の時間のラベルにダッシュをつけた値を用いる。ここではノイズの影響などを考慮し, 観測単位時間を10分としている。以上の処理によって, 人物の1日の行動パター

ンをA~K, A'~K'の22種類のラベルにより長さ144の記号列で表現する。

3. 人物の非日常状態の検出

2で抽出した人物の行動パターンを用いて, 行動の非日常性を判定する。人物の行動が日常的か非日常的かを判断するとき, それまでに観測された全ての行動パターンと現在の行動パターンの類似度を測定する方法が考えられる。しかし, 長期間のモニタリングを行う場合, 得られる行動パターンの数が膨大となるため現実的ではない。そこで本研究では, 記号列パターンの認識などに用いられているHidden Markov Model (HMM)によって, 行動パターンを学習する。HMMは, 時間軸方向の移動・伸縮にロバストなため, 本手法のように個人差の大きい記号列の学習に適している⁽¹³⁾⁽¹⁴⁾。

3・1 行動パターンの学習 人物の1日の行動パターンを記号列で表現した時, 人物が同じようなパターンで行動した場合には類似した記号列が観測され, 異なるパターンで行動した場合には, 当然ながら異なる記号列が観測される。例えば, 朝起きてから同じように振る舞った複数の日の行動を記号化すると類似した記号列が観測されるが, 外出しない日と外出した日のように, 行動が異なる場合には, 異なる記号列が観測される。一般にHMMを用いた認識手法では, モデル毎にあらかじめ用意した学習用記号列でHMMを学習させておき, 入力記号列を最も高い出力確率で出力するHMMのモデルを認識結果として選択する手

図3 行動パターンの学習アルゴリズム

Fig. 3. The learning algorithm of the behavioral pattern.

法が用いられている。しかし、一般的な環境下で行われる行動パターンを認識する場合には、人物の行う行動の種類が膨大となるためにそれらすべてのモデルをあらかじめ作成しておくことは現実的ではない。また、一般には人物が何種類のパターンで行動を行っているかは個人差があり既知でないため、あらかじめ作成しておくべき HMM の数も既知ではない。そこで、図 3 に示すアルゴリズムを用いて人物の行動パターン毎のモデルを順次作成していくことによって、行動パターンを学習する。

このアルゴリズムは 2 つのループで構成されており、図 3 中の〈Loop 1〉で単一の行動パターンに対応する HMM を作成し、〈Loop 2〉で注目している日までに人物が行った各行動パターンに対応する HMM を作成する。〈Loop 1〉では、まず、全ての記号列の集合 Seq_1 を学習データとして HMM を作成する。この HMM で学習に用いた全記号列の出力確率を求め、最も高い出力確率で各記号列の出力確率を割った値が、しきい値以上となるような記号列のみで Seq_1 を更新し、改めて HMM を作成する。以上の処理を Seq_1 の全ての学習記号列が出力可能になるまで繰り返すことによって、一つの行動パターンに対応する HMM を作成する。〈Loop 2〉では、〈Loop 1〉で削除した記号列の集合 Seq_2 を学習データ Seq_1 として、同様の処理を繰り返すことによって人物の各行動パターンに対応した HMM を作成している。そして、以上の処理で作成した全ての HMM を行動パターンの学習結果として保存しておく。

3.2 日常行動の表現 HMM を用いて人物の行動パターンを表現する時、ある行動パターンの記号列が別の行動パターンの部分記号列である場合には、両方の行動に対応する HMM から観測された記号列が出力され、人物がどちらの行動パターンで行動を行っているかを判断できない場合があった。そこで、3.1 で行動パターンの学習に用いた全ての記号列を行動パターンの全ての HMM で出力し、各記号列毎にしきい値以上の確率で出力する HMM を調べる。そして、出力する HMM の集合により人物の日常的な行動パターンを表現する。つまり、HMM 1, 2 で同時に出力される記号列は全て同一の行動パターンと考え、HMM 2, 3 で同時に出力される記号列は、HMM 1, 2 で同時に出力する行動パターンとは異なる行動パターンであると考え。そして、出力する HMM の集合 $\{1, 2\}$, $\{2, 3\}$ を保存し、これを HMM の出力パターンと呼ぶ。

以上のように一つの記号列で同時に出力する HMM の集合を保存しておくことによって、部分記号列の影響を受けずにどの行動パターンで行動が行われたかを認識することができる。

3.3 非日常状態の検出 人物の行動パターンを、3.2 で調べた HMM の出力パターンを用いて認識する。まず、観測された記号列を行動パターンの全ての HMM で出力し、観測記号列を出力する HMM の集合 N を調べる。次に、得られた HMM の集合 N と保存しておいた日常の行動パターン i の出力パターン M_i を次式で比較する。

$$\gamma_i = \begin{cases} \frac{|N|}{|M_i|} & \text{if } N \subset M_i \\ 0 & \text{otherwise} \end{cases} \dots\dots\dots (1)$$

ここで、 $|M_i|$ は集合 M_i の要素数を示している。例えば、保存している HMM の出力パターンが $M_i = \{1, 2, 3, 5\}$ で観測記号列を出力する HMM の集合が $N = \{2, 3, 5\}$ の場合、 $|M_i| = 4$, $|N| = 3$ であり、 γ_i は 0.75 となる。

そして、保存している全ての出力パターンについて γ_i を求め、 γ_i が最大の行動パターン i を認識結果とする。ただし、最大の γ_i がしきい値未満の場合は、人物が日常的に行わないようなパターンで行動を行ったと判断する。

以上の処理によって、人物の行動パターンを各行動パターン毎に自動的に分類して学習し、人物がどの行動パターンで行動を行ったかを認識することができる。さらに、過去に観測された行動パターンとの類似度を算出することによって、人物行動の非日常性を検出することができる。

4. 実験および考察

4.1 実験 本手法の有効性を確認するために実験を行った。まず、注目している日の直前の 30 日間に観測された記号列 (記号列長 144) を学習用記号列として HMM で人物の行動パターンを学習した。ただし、30 日を過ぎるまでの間は直前の日までに得られた全ての記号列を学習用記号列に用いている。学習に用いた HMM の出力シンボル数はラベルの総数の 2 倍、状態数は 16 とした。また、HMM の学習には Baum-Welch アルゴリズムを用い、記号列の出力確率は Viterbi アルゴリズムで算出したシンボル出力確率を系列長で正規化した値を用いた。次に、作成された全ての HMM で学習に用いた全ての記号列を出力させて、HMM の出力パターンを調べた。その後、作成した HMM と HMM の出力パターンを用いて、注目している日の注目している時間までの行動パターンが日常的であるか非日常的であるかを 2 時から 24 時まで 1 時間毎に調べた。

図 4 に実験結果の例を示す。図 4 中の帯グラフの左に示す数字は何日のデータであるかを表しており、帯グラフは 2 の手法で記号化した人物の 1 日の行動パターンを各センサに与えたラベル毎に濃淡値を変えて表したものである。その下に示す“0”、“X”、“?”の系列は、以下の基準にしたがって判断した人物の状態を示している。

“0” 式 (1) で求めた値がしきい値以上であり、日常的な行動パターンと判断したもの。

“?” 式 (1) で求めた値はしきい値未満であるものの、観測記号列を出力する HMM は存在し、日常的であるか非日常的であるかを判別しにくいもの。

“X” 観測記号列を出力する HMM が存在しないため、非日常的な行動パターンであると判断したもの。

実験の結果より、学習データの少ない 1/11 頃までは頻繁に“X”や“?”が表示されているが、それ以後は 1/12~1/14 などのように過去のパターンと類似している場合に“0”を、

図 4 実験結果の例

Fig. 4. Examples of experimental results.

図 5 行動パターンの日常性の検出結果

Fig. 5. The sum of regular time zone of one day.

1/23,1/24のように過去に観測されていない非日常的なパターンの場合に“X”を正しく出力できていることが確認できる。

図 5 に各日毎に日常的であると判断した時間帯の合計を調べた結果を示す。図は横軸に何日のデータであるかを示し、縦軸に日常的と判断した時間帯の総数を示している。例えば、すべての時間帯で“X”が出力されている1/3や1/24などは最小値の“0”となり、1/12~1/14などのようにすべての時間帯で日常的であると判断した場合は2時から24時までの間で“0”が出力されるため、最大値の23となる。この図からも、十分な学習データが得られている1/12以降からは安定して被験者の行動パターンを識別できていることが確認できる。1/24や2/5頃、5/3などの値が0の日

は、センサの誤反応や、初めて外泊した日などを検出していると考えられる。

図 5 中の 5/2 頃から 5/30 頃までの間で、全体的に低い値となっていることが確認できる。これは、被験者に体調の変化などがあり、行動パターンが激しく変化したために日常的と判断できる時間帯が減少したためと考えられる。この結果は、高齢者在宅データ解析アルゴリズム開発コンテストで公表された被験者の体調が悪化した日である 5/21 の前後となっている。図 4 の 3 列目上部には 5/17 から 5/23 までの行動パターンを認識した結果を示している。この結果から、被験者の体調が悪化した 5/21 には“X”は出力していないものの、“?”を頻繁に出力しており、また、5/21 の前後で“X”や“?”を多数出力していることが確認できる。

同様に、7/6 から 7/10 でも低い値が連続しており、この期間にも体調の変化や、外泊があったものと考えられる。また、図 4 の 3 列目下部に示した 7/25,26 の結果から、被験者が入院した 7/26 には“0”や“?”を多く出力しているものの、前日の 7/25 には“X”を常に出力していることを確認できる。

さらに、一日のうち 8 割以上の時間帯 (18 時間以上) で“X”を出力している日を“非日常日”と設定して“非日常日”を検出する実験を行った。実験の結果、“非日常日”と検出された日を表 2 に示す。ただし、学習が十分でないと考えられる 1/11 以前については、実験結果中に含めてい

表 2 非日常日の検出結果

Table 2. Results of detection of irregular day.

1/24	2/5	2/11	2/17	4/6	5/3	5/9	5/10	5/11	5/14
5/18	5/20	5/30	6/15	6/24	7/1	7/4	7/7	7/16	7/25

ない。この結果から，“非日常日”として検出された日は20日あり，被験者が体調を崩した日の近傍（5/3～5/30，7/1～7/25）で“非日常日”を多く検出できていることが確認できる。

4・2 考 察 本論文では，独居高齢者などの要介護者を対象とした，非日常状態の検出手法を提案した。以下，提案手法の特徴について考察する。

(1) これまでに提案されている様々な手法では，トイレや風呂に留まっている場合や，起きてこない場合など長時間行動が行われない場合に警報を出すことを目的としていた。これに対して本手法では，被験者の手を煩わせることなく収集した情報を用いて人物の行動パターンを学習し，行動パターンが日常と異なる場合に，非日常的であることを自動的に検出し介護者に通知することができる。行動パターンの非日常性をチェックしているため，センサの反応の有無をチェックするだけでは分からない，独居高齢者の体調の変化なども捉えられると考えられる。

(2) 行動のパターンに注目した従来手法では，パターンの変化を家族などの介護者がチェックすることを前提としていた。そのため，介護者の負担が大きくなる可能性が高く，負担を軽減するためにパターンのチェックを保健師やヘルパーなどに依頼する場合には，プライバシーなどの点で問題が生じる可能性があった。本手法では，被介護者の行動パターンの変化をシステムが自動的にチェックすることができるため，介護者の負担を軽減することが可能であると考えられる。また，非日常状態を検出したときのみ通知するような運用を行うことなどによって，被介護者のプライバシーに配慮したシステム設計も可能であると考えられる。

(3) 人物の大局的な行動パターンを知るために，設置されたセンサの位置と行動の関係を考慮して，センサのラベルづけを手で行い，さらに観測単位時間（10分間）における反応回数が最も多いセンサのラベルを用いて行動パターンを表現した。観測単位時間を10分としているため，10分間隔で被介護者の行動パターンの日常性を検出することができ，緊急事態が生じた場合にも対応可能であると考えられる。ただし，本論文では可読性を高めるために1時間間隔で，非日常性を検出する実験としている。観測単位時間内における反応回数が最大のセンサを用いているために，センサの反応回数が少なくても重要な行動を見落とす可能性がある。また，焦電型センサと家電品の稼働センサなど出力特性の異なるセンサを同様に扱って行動パターンを表現した。各センサの出力特性を考慮した記号化を行うことで，更に高精度に非日常性を検出することが可能になると考えられるが，今後の課題とする。

(4) 予め用意した学習セットを用いて学習させたモデルを用意するのではなく，注目している日の前日までの行動パターンを自動的に分類して学習し，注目している日の行動パターンの日常性を検出する手法を明らかにした。学習期間中に観測された被介護者自信の行動パターンを用いているため，被介護者に固有の情報を考慮することができ，予めモデルを与えておく手法よりも高精度に非日常状態を検出できると考えられる。

(5) 本手法では，人物の行う行動のパターンに注目しているため，人物が動作を行った場合には，位置などの順序性を基に日常性を判別できる。しかし，トイレなどのように日常的に行う時間が決まっていらないような行動を行わない場合には，非日常状態を検出することは難しい。これに対しては，センサの反応時間を調べるような従来の手法と本手法を組み合わせることで解決できると考えられる。

(6) 本論文では，高齢者在宅データ解析アルゴリズムコンテストで公開されたデータに対して本手法を適用して実験を行い，被験者の体調が悪化した5/21の前後で非日常状態を検出することができた。被験者が入院した7/26は“非日常日”として検出していないものの，前日の7/25には非日常状態を検出している。一般に入院する必要がある場合のように大きく体調を崩す時には，体調変化の予兆があると考えられ，提案手法を用いることで体調変化によって変化する行動パターンを検出できた可能性がある。また，実際に入院した7/26は外出した場合のパターンなど過去のパターンと類似したために非日常状態を検出しなかったものと考えられる。

今回の実験では，1日の8割以上の時間帯で“X”を出力した場合を“非日常日”と設定し，被験者が体調を崩した日（5/21，7/26）の近傍で“非日常日”を検出することができた。しかし，学習期間内に非日常的な行動パターンが含まれる場合，正しく検出できない可能性も考えられる。また，被験者によっては“非日常日”の設定を変更した方がより高精度に非日常状態を検出できる場合も存在すると考えられる。このような問題に対しては，非日常状態を検出した時に被験者や介護者に連絡し，体調を崩している場合や外出している場合など，日常の行動パターンと異なる場合には，学習データから除外することや，“非日常日”の設定を変更することなどで解決できると考えられる。

一方，1/24や5/3などのように被験者が体調不良を訴えていない場合にも非日常状態を検出している。これは，文献(15)でも述べられている通り，被験者が気づかない体調不良を検出している可能性も考えられるが，提供されているデータのみで検証することは難しい。このような問題に対しては，文献(16)で提案されているように，センサなどから得られる情報だけでなく，被験者の心理状態などに関するデータも蓄積し，相関を調べることによって検証できると考えられるが，今後の課題とする。

5. む す び

本論文では、独居高齢者宅に設置したセンサから得られる情報を基に高齢者の行動パターンを学習し、高齢者の行動パターンが日常的か、非日常的かを判断する手法を提案した。今後の課題としては、さらに多くの高齢者宅での実験を行い、本手法で非日常状態を検出したときの被験者の状況を詳しく調べることなどが挙げられる。

謝 辞

本論文で用いたデータを公開して頂いた、電子情報通信学会「ME とバイオサイバネティクス研究会」、日本 ME 学会、計測自動制御学会システム情報部門「生体・生理工学部会」をはじめとする関係各学会、関係諸氏に感謝致します。

(平成 16 年 7 月 30 日受付, 平成 16 年 12 月 22 日再受付)

付 録

高齢者在宅データ解析アルゴリズムコンテスト

本論文で使用したデータは、電子情報通信学会「ME とバイオサイバネティクス研究会」が主催した「高齢者在宅データ解析アルゴリズムコンテスト」によって公開されたデータである。全てのデータは、実験に際し被験者に対して文書ならびに口頭でその内容について説明を行い、同意を得た上で獲得されている。また、図 2 に示す赤外線センサの配置図は文献 (12) を参考に作成した。

青 木 茂 樹 (非会員) 1975 年生。1998 年 3 月大阪府立大学総合科学部卒業。2004 年 3 月同大大学院工学研究科博士後期課程修了。同年熊本電波高専電子制御工学科助手、現在に至る。コンピュータビジョン、パターン認識に関する研究に従事。工博。電子情報通信学会、日本ロボット学会各会員。

大 西 正 輝 (正員) 1973 年生。1997 年 3 月大阪府立大学工学部情報工学科卒業。2002 年 3 月同大大学院博士後期課程修了。同年理化学研究所バイオ・ミメティックコントロール研究センターフロンティア研究員、現在に至る。ロボットの認知・知識処理に関する研究に従事。工博。電子情報通信学会、日本ロボット学会、映像情報メディア学会各会員。

小 島 篤 博 (正員) 1967 年生。1990 年 3 月大阪府立大学工学部電気工学科卒業。1992 年 3 月同大大学院博士前期課程修了。同年富士通(株)入社。1996 年 9 月より同大総合情報センター助手。現在、同大総合教育研究機構助教授。画像情報から自然言語への変換に関する研究に従事。工博。電子情報通信学会、情報処理学会、人工知能学会各会員。

福 永 邦 雄 (正員) 1945 年生。1967 年 3 月大阪府立大学工学部電気工学科卒業。1969 年 3 月同大大学院修士課程修了。同年同大学工学部電気工学科助手。現在、同大大学院工学研究科教授。コンピュータビジョン、グラフ理論とその応用などの研究に従事。工博。情報処理学会、人工知能学会、システム制御情報学会、IEEE 各会員。

文 献

- (1) 東北電気通信管理局: “在宅福祉支援システム”, “<http://www.ttb.go.jp/tetuduki/catv/usage/kitaonmaki.html>”
- (2) 東北電気通信管理局: “滝野町 CATV ネットワーク事業”, “<http://www.ttb.go.jp/tetuduki/catv/usage/takino.html>”
- (3) 象印マホービン: “みまもりほっとライン”, “<http://www.mimamori.net/>”
- (4) 太田 茂: “高齢者のためのモニタリングシステム”, 情報処理, Vol.41, No.6, pp.639–643 (2000)
- (5) T. Matsumoto, Y. Shimada, K. Shibasaki, H. Ohtsuka, and S. Kawaji: “Creating behavior model of a senior solitary life and detecting an urgency”, Proc. International ICSC Congress on Intelligent Systems & Applications (ISA2000), Vol.2, pp.234–238 (2000)
- (6) 山口晃史・上山直浩・山越憲一・菅原康博・八木沢博史・金戸正人: “高齢者の生活支援情報計測・運用システムの開発”, 第 38 回日本 ME 学会大会要項集, p.134 (1999)
- (7) 上山直浩・山口晃史・山越憲一・菅原康博・八木沢博史・金戸正人: “人感センサによる行動モニタリングシステム”, 第 38 回日本 ME 学会大会要項集, p.376 (1999)
- (8) 菅原康博: “介護支援情報システム”, 計測制御, Vol.40, No.5, pp.379–383 (2001)
- (9) 青木茂樹・大西正輝・小島篤博・福永邦雄: “HMM による行動パターンの認識”, 信学論 (D-II), Vol.J85-D-II, No.7, pp.1265–1270 (2002-7)
- (10) 青木茂樹・岩井嘉男・大西正輝・小島篤博・福永邦雄: “人物の位置・姿勢に注目した行動パターンの学習・認識と非日常状態検出への応用”, 信学論 (D-II), Vol.J87-D-II, No.5, pp.1083–1093 (2004)
- (11) 青木茂樹・大西正輝・小島篤博・福永邦雄: “人物の行動パターンの学習・認識と独居高齢者の非日常状態検出への応用”, 第 18 回生体・生理工学シンポジウム論文集, 3B1-3, pp.311–314 (2003)
- (12) 中島一樹・南部雅幸・田村俊世: “データベースの構造および利用などに関する説明”, 第 17 回生体・生理工学シンポジウム論文集, 2C4-5, pp.295–298 (2002)
- (13) Andrew D. Wilson and Aaron F. Bobick: “Parametric Hidden Markov Models for Gesture Recognition”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.21, No.9, pp.884–900 (1999)
- (14) B. Clarkson, K. Mase, and A. Pentland: “Recognizing User Context via Wearable Sensors”, ISWC2000, pp.69–76 (2000)
- (15) 南部雅幸・田村俊世・木竜 徹・野城真理: “高齢者在宅データ解析アルゴリズムコンテストに関する報告”, 第 18 回生体・生理工学シンポジウム論文集, 3B101, pp.303–306 (2002)
- (16) 松岡克典: “住宅内行動の長期蓄積に基づく異常検知手法の検討”, 信学技報, MBE2002-128 (2003)