

画像フロー情報の One-Class SVM に基づく 独居高齢者非日常行動検出システムの構築

田島 和博

千葉工業大学 工学研究科 電気電子情報工学専攻

1. 背景と目的

〈1.1〉 背景

我が国の総人口は、平成 23 (2011) 年 10 月 1 日時点で、1 億 2,780 万人であった。65 歳以上の高齢者人口は、過去最高の 2,975 万人 (前年 2,925 万人) となり、総人口に占める割合 (高齢化率) も 23.3% (前年 23.0%) となった。

今後さらに、高齢者数は 2040 年頃まで増加し続け、2020 年には高齢化率が 30% 近くに達すると見込まれるなど、高齢化の水準は世界でも群を抜いたものとなる。

また、近年我が国では少子高齢化により一人暮らしの高齢者の人口が増加しており、それにより高齢者の一人暮らしでの心筋梗塞や脳卒中などの突発的な疾病や不慮の事故などによる孤独死が増加している。

その中でも、家庭内での事故 (階段等からの転倒、転落等) は年々増加しており、特に高齢者の場合、家庭内事故死は、交通事故死の約 1.7 倍にもなっていることから、孤独死は社会的な問題となっている。

〈1.2〉 目的

孤独死を防ぐためには、図 1 のような生活空間に各種センサを用いてモニタリングし、高齢者の体調の変化、普段と異なる行動 (非日常行動) をできるだけ早く把握、検出するシステムを構築する必要がある。これまでの高齢者モニタリングの研究例として、全方位カメラを用いた事例⁽²⁾⁽³⁾、赤外線センサを用いた事例⁽⁴⁾、ガスセンサを用いた事例⁽⁵⁾、ニオイセンサを用いた事例⁽⁶⁾などがある。

本研究では、全方位カメラを用いた独居高齢者の非日常行動を検出するシステムの実現を目指し、全方位画像中のオプティカルフローの特徴量 (フローの総数、重心、分散) に One-Class SVM を適用することで日常行動ともがくや倒れて動かなくなるなどの非日常行動を判別するシステムを構築することが目的となる。

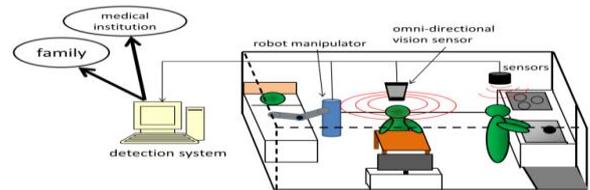


図 1 高齢者モニタリングシステム

2. 非日常行動の定義

実際の高齢者の家庭内生活における不慮の事故とは、平面、階段などの段差における転倒や転落、浴槽での溺死、食物を詰まらせての窒息などがあり、以上の三例だけで大半を占めている。この他にも事故につながりかねないような行動や予兆、何らかの体調の変化による行動パターンの変化がある。このような非日常行動をモニタリングによって検出されることが理想的である。ここで、全方位カメラで検出可能と考えられる高齢者の非日常行動について、以下に定義する。

(A) 学習画像と異なる行動パターン

部屋で倒れている場合、普段とは異なる場所に行こうとしている場合など。

(B) 時間軸に基づく行動パターン

行動そのものは学習画像の中にも存在しうるが、それが行われる時間帯が学習と異なる場合がある。例えば、一日中ベッドで寝ている場合、深夜に学習ではベッドで睡眠しているが、ベッドから離れて歩き回っている場合など。

(C) 動きが止まるパターン

人間は常に微動をしていると考えられるため、長時間に亘って微動すらしめないようなパターンは異常とみなすべきである。例えば、深夜にベッドで寝返りをうたなくなったり、その場で動きが止まるという場合など。

(D) 部屋外から長時間戻らないパターン

ワンルームの家を想定したとき、外出時を除けば、全方位カメラに映らないトイレや風呂、ベランダ等に数十分程度以上滞在することは異常と考えられる。

3. 実験内容

〈3・1〉 実験環境

本研究では高齢者の一人暮らしを模した 8 畳程度の一部屋をモニタリングすると想定し、図 3 のような実験用の部屋を作成した。

この部屋にはベッド、机、テレビ、テレビ台、座布団を配置し、なるべく死角を作らないように配慮し、全方位カメラは中央に設置して高さ 150cm で撮影を行った。



図 2 全方位カメラ

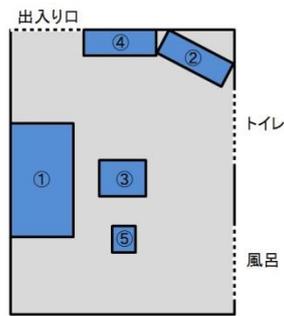


図 3 模擬実験部屋

図 3 の各番号には以下の家具が配置されている

- ①ベッド ②テレビ台 ③テーブル
- ④キッチン ⑤座布団

〈3・2〉 撮影実験

通常のカメラを使うのではなく、360 度撮影可能な全方位カメラを用いる。図 4(a)は実際に全方位カメラで模擬実験を撮影した画像である。撮影間隔は 1 秒ごとに 1 枚撮影とし、画像のサイズは 640×480 ピクセルとする。

本研究では、画像解析にオプティカルフローという手法を用いており、この手法では全方位カメラで撮影した画像（以下、全方位画像）よりも全方位画像をパノラマ展開した画像（以下、パノラマ展開画像）の方がより正確な特徴量を取得できるのでパノラマ展開処理を行う。画像のサイズは 900×200 ピクセルとする（図 4(b)）。



(a)全方位画像



(b)パノラマ展開画像

図 4 撮影画像

4. 画像特徴量抽出

〈4・1〉 オプティカルフロー

オプティカルフローとは、時間連続な画像列を利用して、画像の速度場（物体の速度+カメラの速度）を求め、それ

をベクトル集合（フロー）で表現したものである。これにより、画像間の人物の動きを速度ベクトルというパラメータで表現することが出来る。オプティカルフローを用いた事例として、エレベーター内の異常事態検知がある⁽¹⁰⁾。

図 6 は出力結果であり、青色に近いフローは大きさ小、緑色に近いフローは大きさ中、赤色に近いフローは大きさ大とする。

処理として、株式会社ライブラリーの流体画像解析ソフトウェア「Flow-vec」を用いる。これにより、カラー画像をグレースケールに変換してから特徴量を抽出する。抽出法として、時間的に連続する 2 画像から行う。図 5 のように 1 フレーム目と 2 フレーム目で抽出、2 フレーム目と 3 フレーム目で抽出となる。

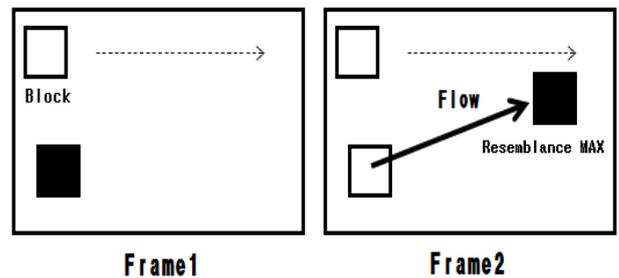


図 5 オプティカルフロー

図 6 では、人物以外の場所にフローが表示されている。これは、家具の影などに反応してしまうことが原因である。

そこで、本研究では前処理として背景差分を行っている。背景差分を行った後にオプティカルフローをしたものが図 7 になる。図 7 では人物以外の場所にはフローが出ていないことがわかる。

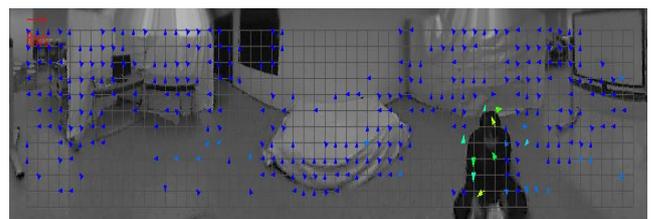


図 6 オプティカルフロー（背景差分前）

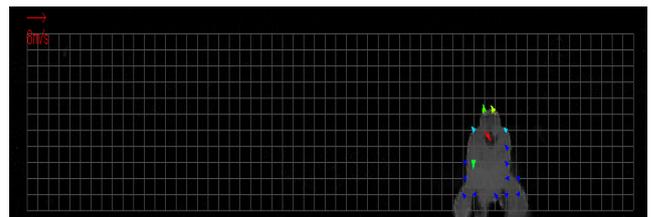


図 7 オプティカルフロー（背景差分後）

5. 本実験の非日常行動検出方法

〈5・1〉検出する行動

本研究では、非日常行動とその前兆の検出が目的となる。例えば、座布団に座って作業をしているとき、床に倒れて動かなくなる前の動作（不審な動作）から非日常行動と判別することのできるシステムを提案する。

〈5・2〉非日常行動検出システム

本システムは、日常行動を学習し、それを基にして新規行動が日常行動か非日常行動かを判別する。特徴量として、フローから動きの速さや大きさを示すフローの大きさごと（小、中、大）の頻度、画像中の人物の位置を示す重心（ G_X, G_Y ）、姿勢を示す分散（ V_X, V_Y ）の7つの特徴量を抽出し、これらを7次元特徴量としてひとまとめで扱う。

1回のフロー情報のみを用いると、日常行動の中で一瞬大きな動きをただけでも非日常行動であると誤判別してしまうことがあるので安定化するために、20回分（過去20秒）のフロー情報から特徴量 \vec{s} を求め（1秒毎の各フローの総数は加算、重心と分散は平均）、日常行動と非日常行動の判別を行う。

$$\vec{s} = (s_1, s_2, \dots, s_7) \dots \dots \dots (1)$$

表1 特徴量

s_1	フローの大きさ”小”の総数
s_2	フローの大きさ”中”の総数
s_3	フローの大きさ”大”の総数
s_4	人物の位置（重心 G_X ）
s_5	人物の位置（重心 G_Y ）
s_6	人物の姿勢（分散 V_X ）
s_7	人物の姿勢（分散 V_Y ）

高齢者のモニタリングでは、日常行動のみが入手可能であり、これ以外の様々な起こりうる非日常行動はあらかじめ用意することができない。つまり教師データを用いることが出来ず、日常行動のデータのみを使って学習を行い、これと異なるデータはすべて非日常行動と判定しなければならない。一種の外れ値検出と言え。そこで、行動判別の手法として、外れ値検出の代表的な手法であり、教師なし学習である One-Class SVM を用いて検出する方法を提案する。

〈5・3〉One-Class SVMによる非日常行動検出

One-Class SVM とは、データ空間内における正しいデータを含む領域を推定するための方法である。そのような領域内のデータはインライア（日常）とみなせるので、データの分布の推定を行えるだけでなく、逆に領域外のデータを検出することで、アウトライア（非日常）除去も行える。通常インライアはデータ空間において密度の高い領域に

あり、アウトライアは密度が低い領域にある。そこで、データ間の距離をガウシアンカーネルを用いて特徴空間へ写像すれば、アウトライア、すなわち他から離れたデータは原点近くに写像される。

この性質を利用して、図8のように原点近くのデータ群と他のデータ群を識別する最大マージンを持つ超平面を設定し、以下のようにはずれ具合の指標を求める。式(2)の識別関数を式(3)を用いて計算して、式(4)を最適化することにより、原点とすべてのサンプルが最も離れるような識別関数が決定され、あらかじめ設定したパラメータによって決まる割合のサンプルがはずれ点となる。

$$f(x) = \text{sign}(\sum_i \alpha_i K(x_i, x) - \rho) \dots \dots \dots (2)$$

$$K(x_i, x) = \exp\left(-\frac{\|x_i - x\|^2}{\sigma^2}\right) \dots \dots \dots (3)$$

$$\min_{\alpha} \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j K(x_i, x_j) \dots \dots \dots (4)$$

$$0 \leq \alpha_i \leq \frac{1}{vn} \quad \sum_{i=1}^n \alpha_i = 1 (i=1, \dots, n)$$

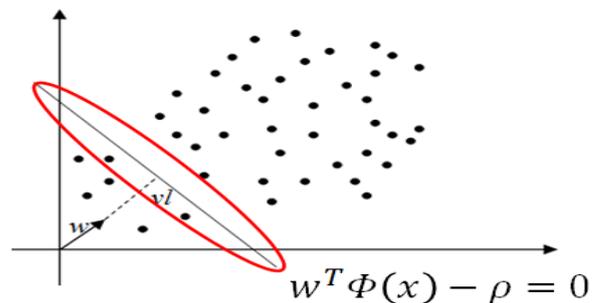


図8 One-Class SVM

6. 実験による検証

〈6・1〉実験概要

行動認識実験として、二つの Case に対して学習データと新規行動データを用意する。それぞれの Case で学習データを6セット用意し、新規行動データとして日常行動と非日常行動を各20セット用意する。

1セットのサンプル数は全て100個であるので、日常行動、非日常行動ともに2000個のサンプルを用いる。

これに、One-Class SVMによる非日常行動検出を行い、正答率を求める。

$$\text{正答率} = \frac{\text{認識が正しかった総サンプル数}}{\text{実際の総サンプル数}} \dots (5)$$

SVM出力は正の値であれば日常行動であり負の値であれば非日常行動とする。

One-Class SVMによる分析には株式会社NTTデータ数理システムの汎用データマイニングツール「Visual Mining Studio」を用いた。

〈6・3〉非日常行動検出実験

【Case I】

家事をしている最中にうずくまって動きが大きくなり、床に倒れて最終的に動きがなくなるという2節で定義した(A)(C)を含む非日常行動を行った(図9~12)。

図9は日常行動のみの出力結果であり、図14は30秒後からうずくまり、1分後から倒れてもがき、1分30秒後から動かなくなるという非日常行動の出力結果である。図14のように約40秒後以降、出力は負になり、非日常行動の判定が可能であることがわかる。

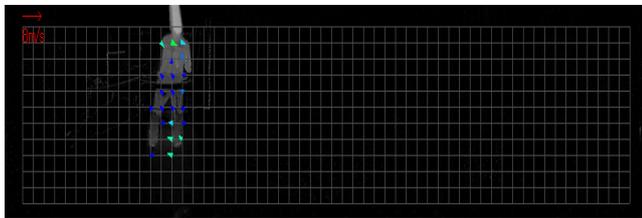


図9 日常行動(Case I)



図10 うずくまる(Case I)

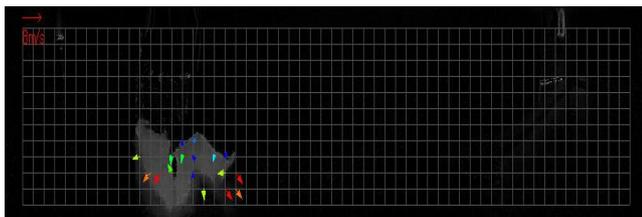


図11 もがく(Case I)

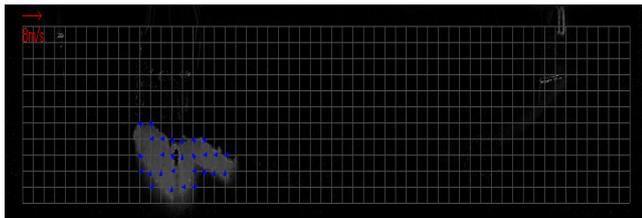


図12 動かなくなる(Case I)

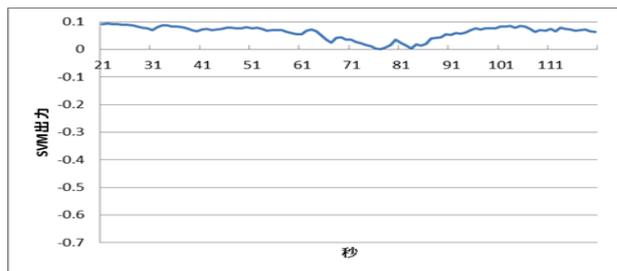


図13 日常行動(Case I)

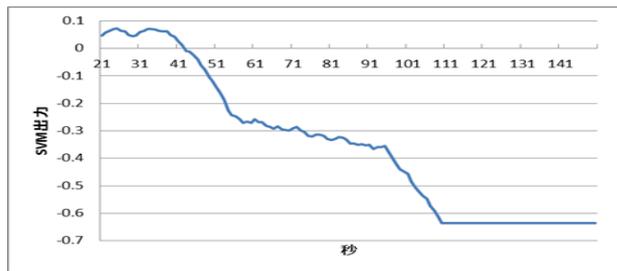


図14 非日常行動(Case I)

【Case II】

食事をしている最中にうずくまって動きが大きくなり、床に倒れて最終的に動きがなくなるという2節で定義した(A)(C)を含む非日常行動を行った(図15~18)。

図19は日常行動のみの出力結果であり、図20は30秒後からうずくまり、1分後から倒れてもがき、1分30秒後から動かなくなるという非日常行動の出力結果である。

先ほどと同様に、出力は負になっていることから非日常行動の判定が可能であることがわかる

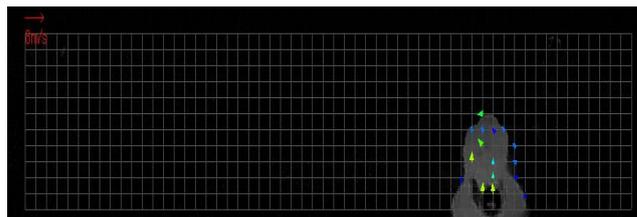


図15 食事(Case II)

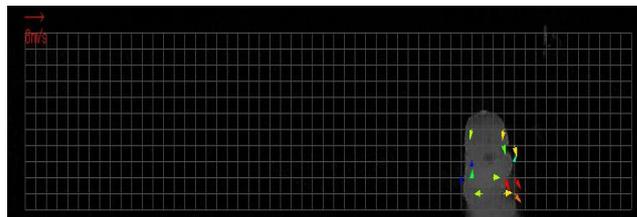


図16 うずくまる(Case II)

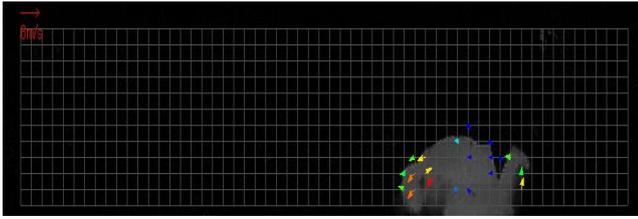


図 17 もがく(Case II)

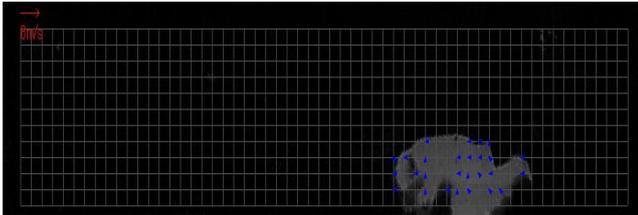


図 18 動かなくなる(Case II)

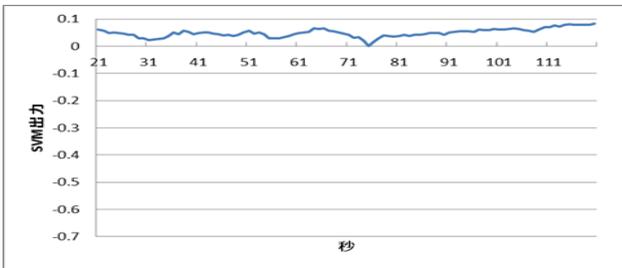


図 19 日常行動(Case II)

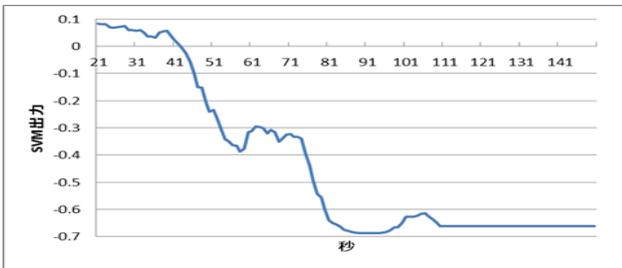


図 20 非日常行動(Case II)

〈6・4〉実験結果

以下の表に Case I、Case II それぞれの実験結果を示す。

今回の実験では Case I、Case II ともに非日常行動の認識率は 100% となっているが日常行動では一部が非日常行動であると誤判別されている。

この原因は学習データが全て日常行動で構成されていることに関係しており、学習方法を改善する必要がある。

表 2 【Case I】

		予測されたクラス	
		日常	非日常
実際のクラス	日常	1938	62
	非日常	0	2000

表 3 【Case II】

		予測されたクラス	
		日常	非日常
実際のクラス	日常	1978	22
	非日常	0	2000

表 4 正答率

	正答率
日常行動【Case I】	96.9%
非日常行動【Case I】	100%
日常行動【Case II】	98.9%
非日常行動【Case II】	100%

7. 学習方法の改善

〈7・1〉改善方法

One-Class SVM ではインライアのみ学習データを用いて識別超平面を求めており、超平面の位置は設定した $0 < v \leq 1$ に近いデータ数が原点側に残るように決められる。

つまり、インライアのみデータの中で設定した $0 < v \leq 1$ に近いデータ数だけアウトライアであるとされてしまい、この値に近い値のインライアのデータもアウトライアであると判別されてしまう。

本項では、改善方法として学習データ全てがインライアとなるような仮想的なアウトライアを求め、これを学習データに加える Virtual Outliers を用いた One-Class SVM を提案する。

本研究では 7 次元の特徴量を用いており、この 7 つ全てを基に仮想的なアウトライアを求めることは困難である。

そこで、情報を集約し総合化することができる主成分分析を用いて仮想的なアウトライアを求める。

〈7・1〉検証

主成分分析では、主成分スコアに固有ベクトルの転置行列を掛けることで元のデータを復元することが出来るため、この性質を利用して仮想的なアウトライアを求める。

加えるアウトライアは学習データのそれぞれの主成分の絶対値の最大の“+”を max、“-”を min として式(6)のように表し、式(7)でこの全ての組み合わせを求め、これに固有ベクトルの転置行列を掛けることで作成する。

$$\mathbf{x}_j \in \{x_j \max, x_j \min\} \dots (6)$$

$$j = 1 \dots n$$

$$\mathbf{x}_i = (\mathbf{x}_1 \dots \mathbf{x}_n)^T \dots (7)$$

$$i = 1 \dots 2^n$$

今回は、第一主成分のみに注目したものから第五主成分までの主成分に注目したものまでの 5 パターンの仮想的な

アウトライアを加えた学習データを用いて、どの主成分まで注目するのが適切なのか検証を行う。

〈7・2〉検証結果

図 21 が Case I、図 22 が Case II の各主成分ごとの正答サンプル数を比較したものであり、図 23 は上記の二つの図をまとめたものである。

日常行動では、注目する主成分の数を増やすと正答サンプル数が増えていることがわかるが、Case I では第四主成分から非日常行動の正答サンプル数が減っていることがわかる。これは、注目する主成分を増やすとそれだけ学習データの値から離れていくため、加えた仮想的なアウトライアが実際のアウトライアに近い値になってしまったためである。

よって注目する主成分は多ければ良いと言うわけではなく適切なものを選択する必要がある。今回の検証では第三主成分までに注目した時に Case I、Case II の日常行動と非日常行動の正答率が 100% となったため、Case I、Case II では第三主成分までの主成分に注目して 8 通りの仮想的なアウトライアを学習データに加えるのが適切である。

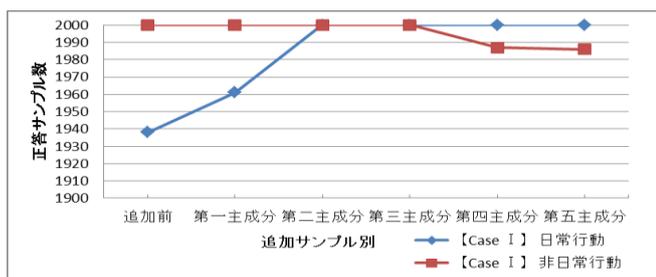


図 21 【Case I】

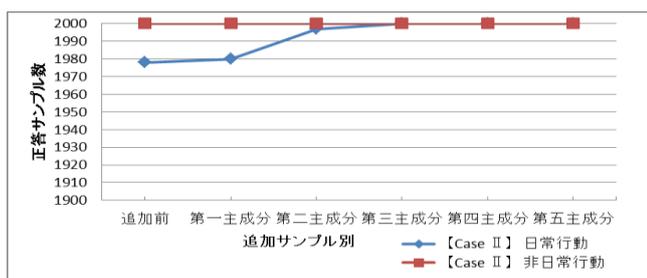


図 22 【Case II】

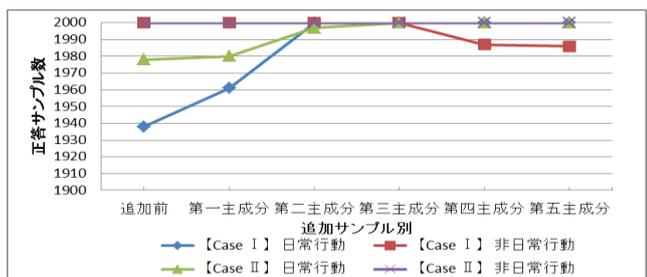


図 23 【Case I】 【Case II】

表 5 正答率（第三主成分までの主成分に注目）

	正答率
日常行動【Case I】	100%
非日常行動【Case I】	100%
日常行動【Case II】	100%
非日常行動【Case II】	100%

〈7・3〉考察

今回の検証では仮想的なアウトライアを加えることで日常行動の一部の誤判別を無くすことができた。しかし、加える仮想的なアウトライアの数を増やしすぎると今度は非日常行動の一部が誤判別されてしまうケースがあることがわかったため、より多くのデータを用いて検証を行う必要がある。

8. 結言

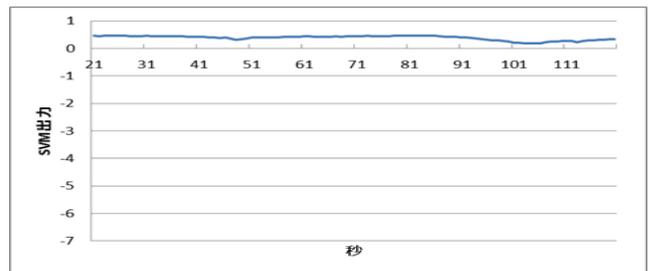
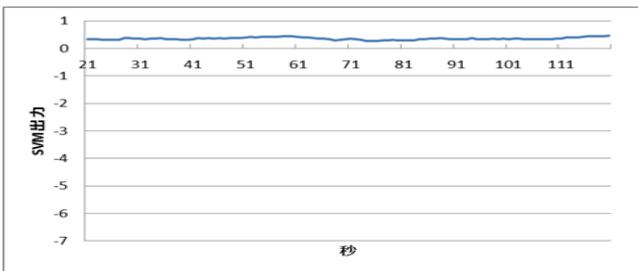
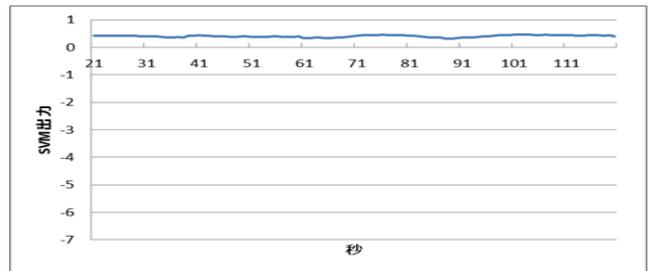
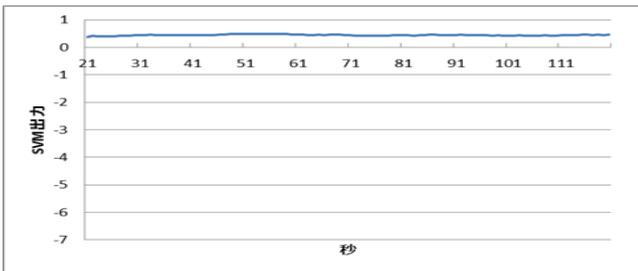
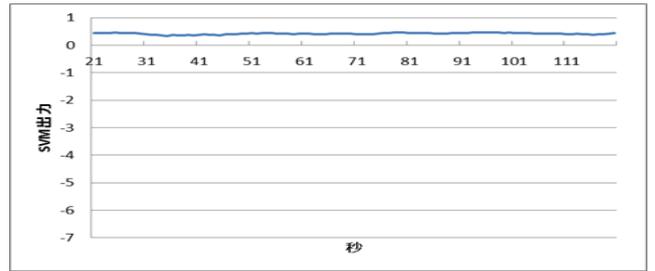
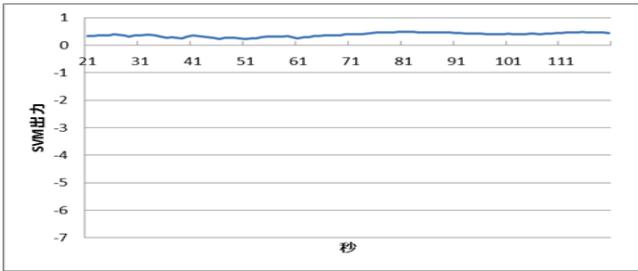
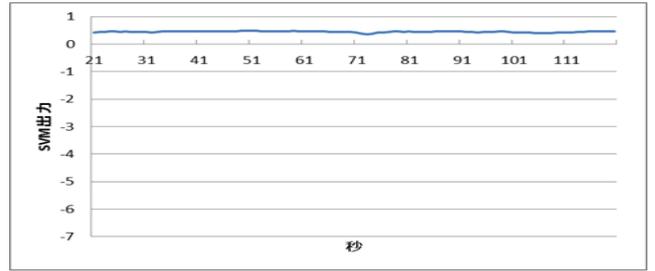
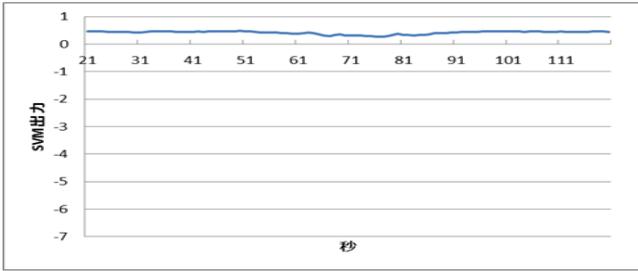
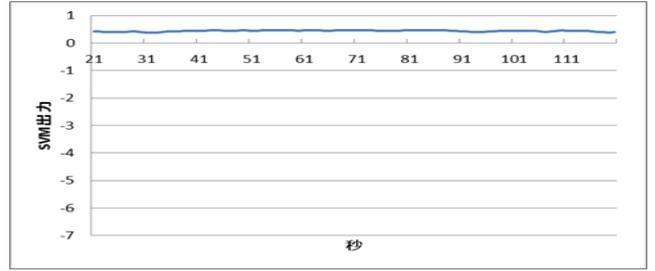
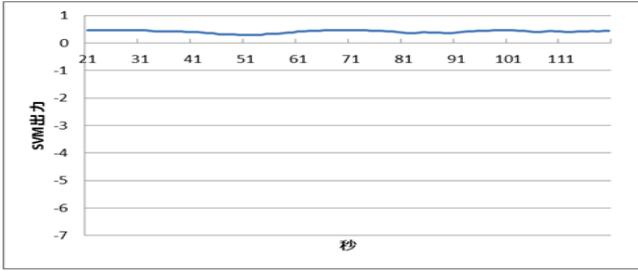
本稿では、独居高齢者非日常行動検出システムの基礎的検討として、One-Class SVM を用いた非日常検出方法を提案し、模擬的なくつかの実験的検証を行った。

今後の課題として、本研究では 2 章の (A) と (C) に対しての検証のみ行っているため、(A) ~ (D) の幅広い非日常行動に対しての検証を行う。また、どのようなケースでも正答率を改善できる学習方法について検討していく必要がある。

文 献

- (1) 厚生省,平成 21 年~人口動態統計~上巻
- (2) 関弘和・堀洋一:「高齢者モニタリングのためのカメラ画像を用いた異常動作検出」,電学論 D,vol.122-D,2,pp.182-188(2002-2)
- (3) 関弘和・多田限進:「全方位センサのバイジアンネットワーク表現に基づく高齢者非日常行動検出モニタリングシステム」,電学論 D, vol.128-D,8,pp.1052-1059(2008-8)
- (4) 品川佳満,・岸本俊夫・太田茂:「独居高齢者の居室滞在時間の分析と自動緊急通報システムへの応用」,ライフサポート,vol.13,3, pp.72-79(2001-10)
- (5) 西川龍彦・広林茂樹・松浦吉展・大藪多可志:「複数の酸化スズ系ガスセンサによる独居高齢者世帯モニタリング」,電学化学センサ研資, vol.CS-96,6,pp.147-156(1996-11)
- (6) 沢田史子・大藪多可志,・南戸秀仁・吉田武稔:「ニオイセンサのマハラノビスの距離による人間のふるまい判別」,電学ケミカルセンサ研資,vol.CHS-00,56,pp.5-10(2000-9)
- (7) 田中仁・中内靖:「ユビキタスセンサによる独居高齢者見守りシステム」,機学論,vol.75,760,pp.116-124(2009-12)
- (8) 多田昌裕・大村廉・納谷太・野間春生・鳥山朋二・小暮深:「無線加速度センサを用いた運転者行動計測に基づく模範運転動作からの逸脱検出」,信学技報,vol.107,115,pp.117-122(2007-6)
- (9) 教藤恭子・若林佳織・荒川賢一・安野貴之:「長時間の監視映像からの非定常シーケンスの検出」,情処学研報,vol.2005,112,pp.77-82 (2005-11)
- (10) 塩崎秀樹・関真規人・林健太郎:「モーションサーチによるエレベーター内の異常事態検知」,設備と管理,vol.40,no.8,pp.44-48(2006-8)

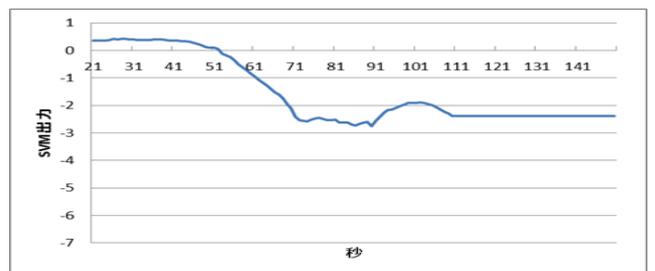
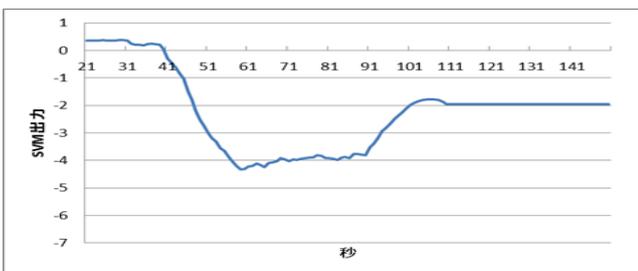
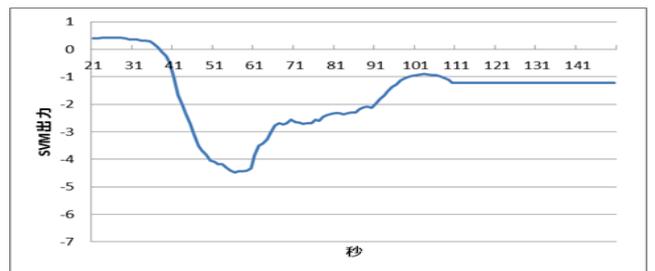
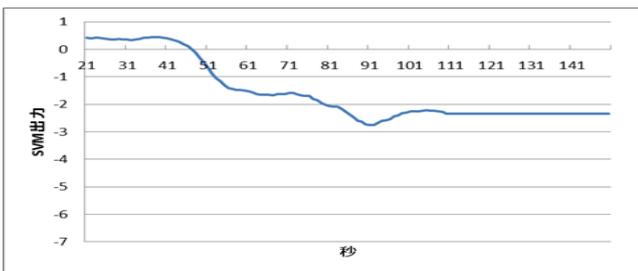
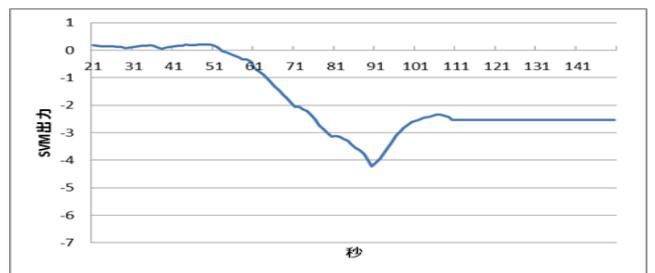
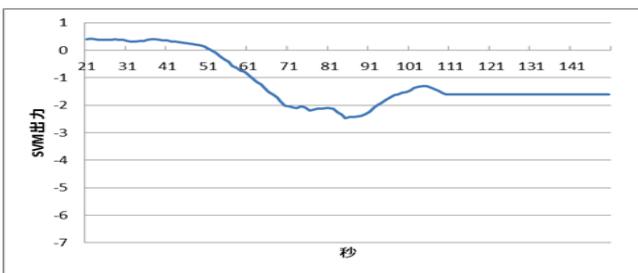
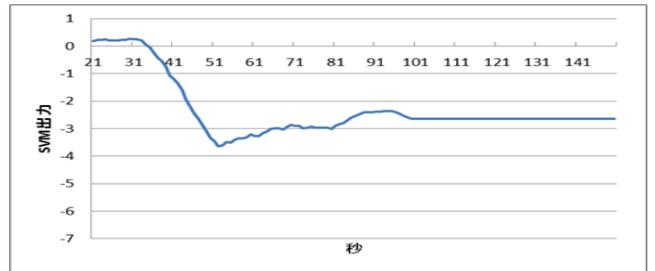
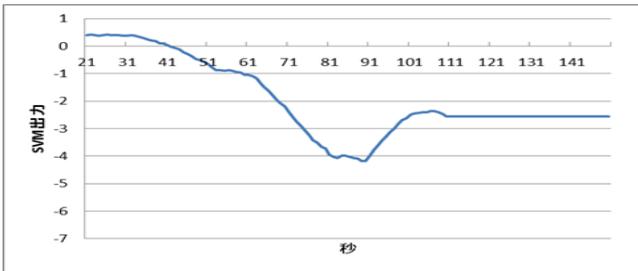
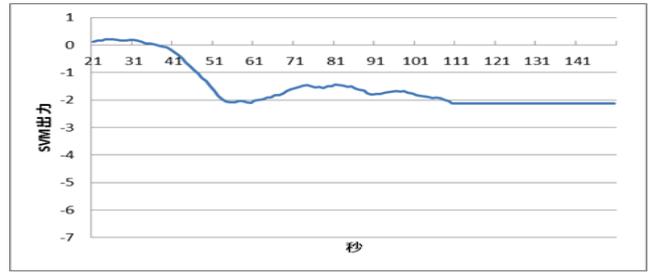
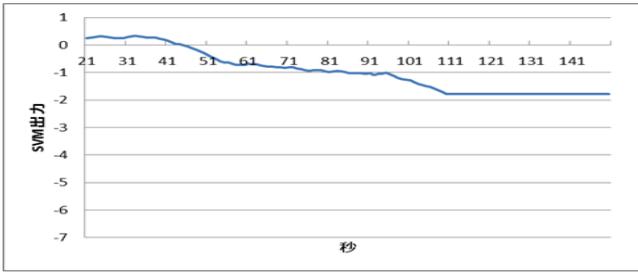
付録



1~5 セット

6~10 セット

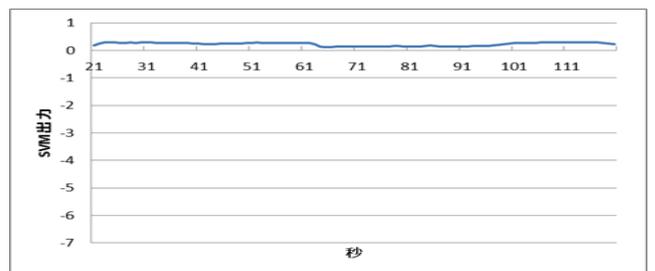
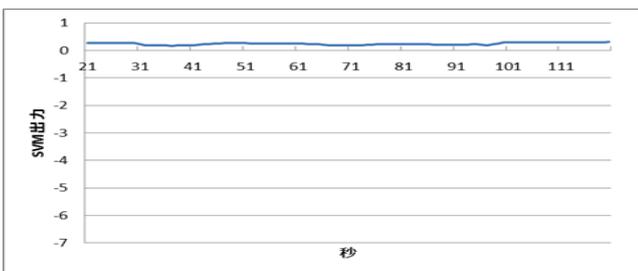
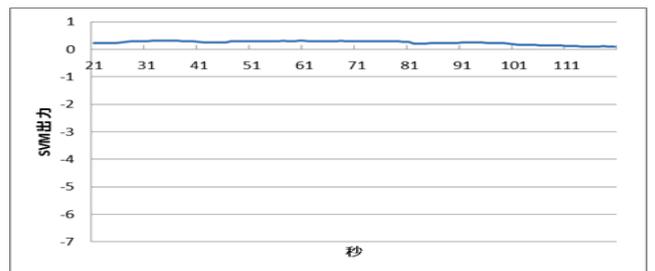
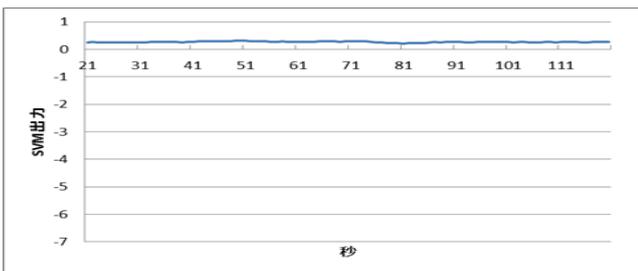
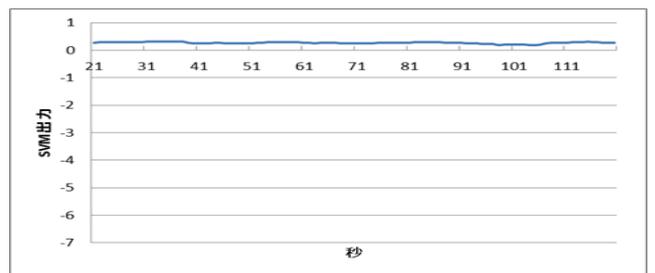
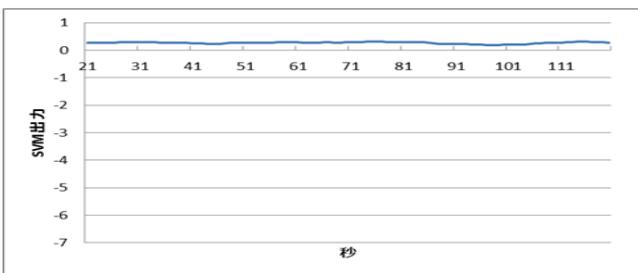
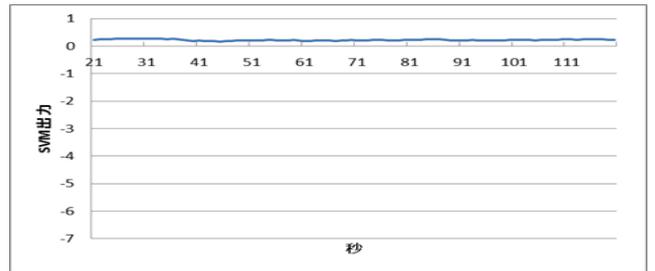
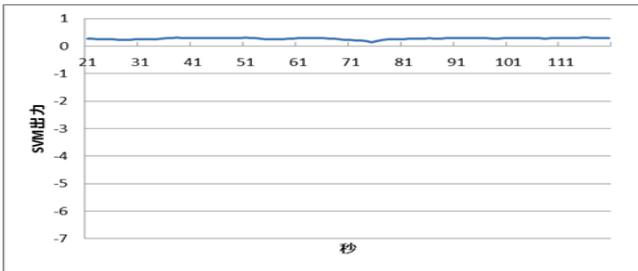
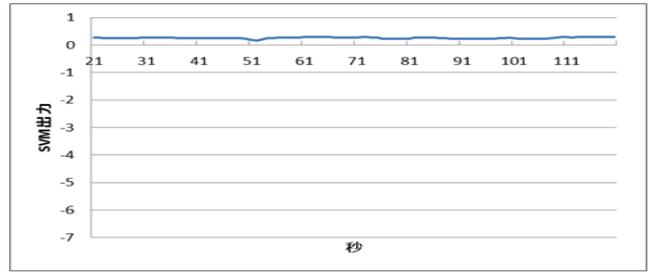
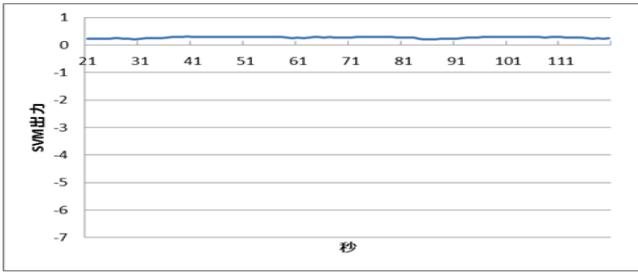
日常行動【Case I】(1~10セット：第三主成分までの主成分に注目)



1~5セット

6~10セット

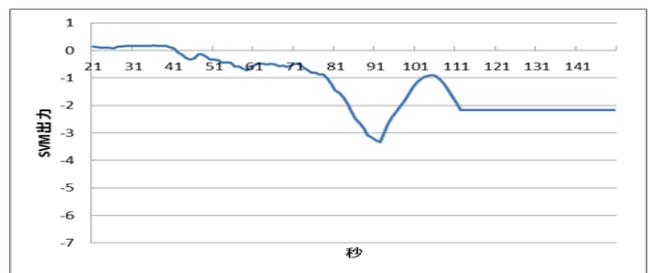
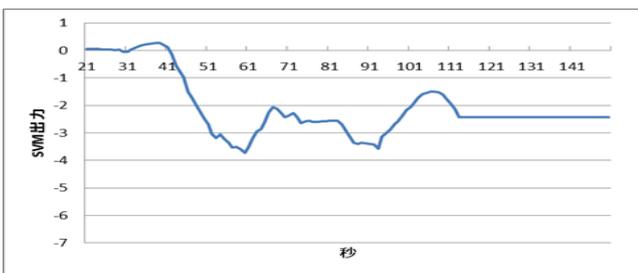
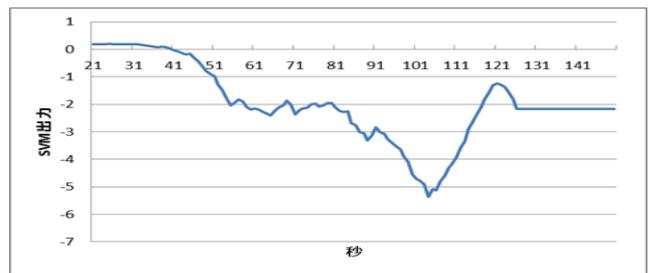
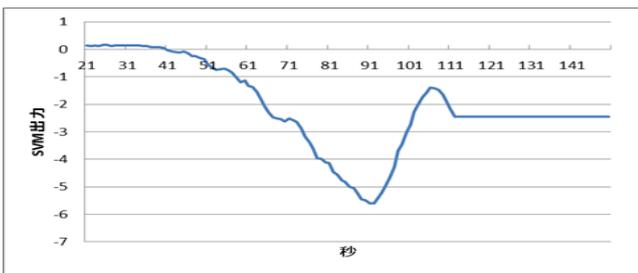
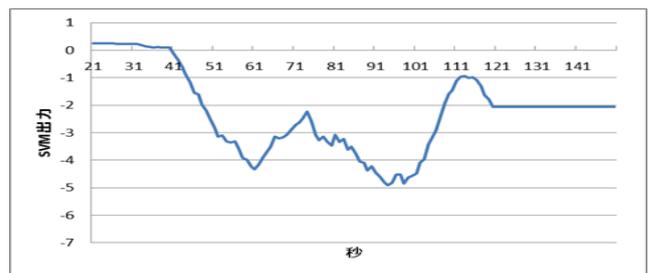
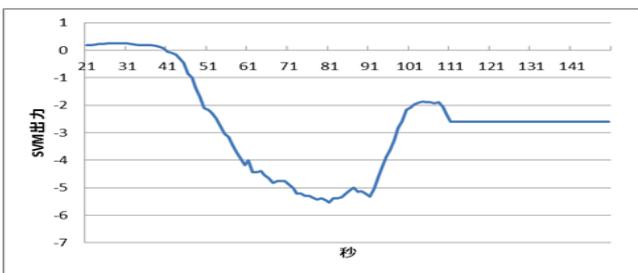
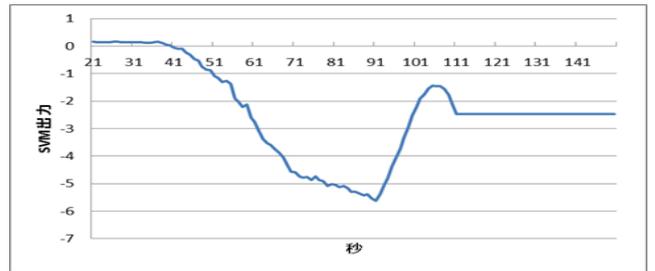
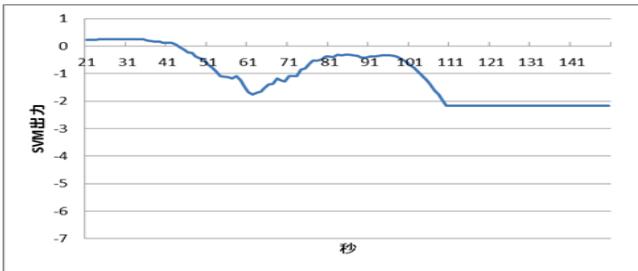
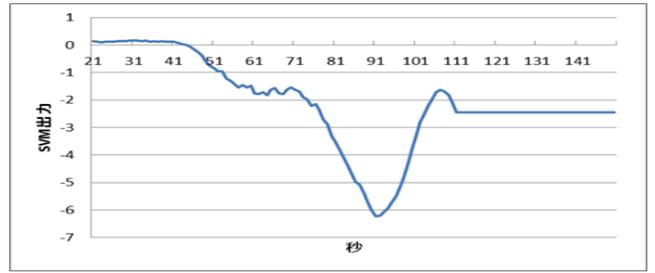
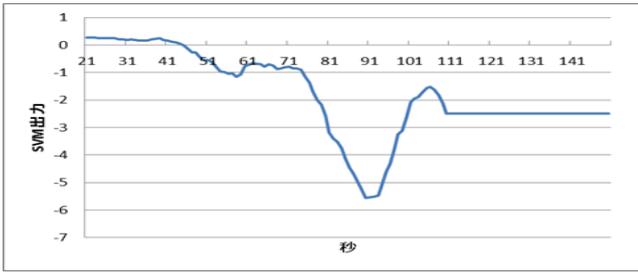
非日常行動【Case I】(1~10セット：第三主成分までの主成分に注目)



1~5 セット

6~10 セット

日常行動【Case II】(1~10 セット：第三主成分までの主成分に注目)



1~5 セット

6~10 セット

非日常行動【Case II】(1~10セット：第三主成分までの主成分に注目)