

修 士 論 文 の 和 文 要 旨

研究科・専攻	大学院 情報理工学 学研究科 情報・通信工学 専攻 博士前期課程		
氏 名	鄭 希	学籍番号	1531073
論 文 題 目	マイクロ波センサを用いた高齢者の異常検知手法		
<p>要 旨</p> <p>近年，高齢者問題は各国でも深刻な社会問題になっている．高齢者は身体機能が低下している，また一人暮らしの場合が多く，事故にあっても助ける人がおらず，命に危険性をもたらす可能性が高い，そのような状況を防ぐために，高齢者を見守り，異常状態を検知することが日々重要になってきている．現在，異常状態の検知は介護者が行うか，センサを用いて行うかである．しかし，（１）前者は介護者にとって負担が大きい．（２）後者は主に視覚センサと加速センサが用いられているが，視覚センサは高齢者の個人プライバシーを侵害する恐れがあり，加速センサは接触センサであるため，高齢者に精神的な負担を与える．</p> <p>一方，現在，非接触型センサの研究が進んでいる．人や動物などの心拍・呼吸・体動などの生体情報を接触せずに検知できるマイクロ波センサという装置が開発されている．</p> <p>そこで，本研究では非接触型のマイクロ波センサを用い，人体情報取得・学習し，状態間の変化点を利用して，高齢者によく見られる４種類の異常を検知する．４種類の異常は １）急な状態変化，２）認知症に対する特定な状態パターン，３）意識不明，４）日常行動が徐々に緩くなる，である．これらの異常を検知するために，本手法には状態認識モデルと変動検知モデルという２つのモデルを含めている．状態認識モデルは，心拍・呼吸・体動情報を用いて，分類アルゴリズムで状態を認識することである．変動検知モデルは，特異スペクトルで体動波形の変化を定量化することである．このような手法で，高齢者の異常を検知し，事故を防ぎ，高齢者に貢献することを図る．</p> <p>提案した異常検知手法を検証するために，単身用の学生寮室で２つのマイクロ波センサを用いて実験を行った．そして，４ケースの状態認識モデルの正解率を示し，変動検知モデルの衰弱の予測可能性があることを示した．最後に，実験結果を考察して発見した問題点をまとめて，今後の課題を述べた．</p>			

1

平成 27 年度 修士論文

マイクロ波を用いた高齢者の異常検知手法

電気通信大学情報理工学系研究科

情報・通信工学専攻

学籍番号 : 1531073

氏名 : 鄭 希

主任指導教員 : 沼尾 雅之 教授

指導教員 : 小花 貞夫 教授

提出日 : 2017. 1. 31

要 旨

近年、高齢者問題は各国でも深刻な社会問題になっている。高齢者は身体機能が低下している、また一人暮らしの場合が多く、事故にあっても助ける人がおらず、命に危険性をもたらす可能性が高い、そのような状況を防ぐために、高齢者を見守り、異常状態を検知することが日々重要になってきている。現在、異常状態の検知は介護者が行うか、センサを用いて行うかである。しかし、(1)前者は介護者にとって負担が大きい。(2)後者は主に視覚センサと加速センサが用いられているが、視覚センサは高齢者の個人情報プライバシーを侵害する恐れがあり、加速センサは接触センサであるため、高齢者に精神的な負担を与える。

一方、現在、非接触型センサの研究が進んでいる。人や動物などの心拍・呼吸・体動などの生体情報を接触せずに検知できるマイクロ波センサという装置が開発されている。

そこで、本研究では非接触型のマイクロ波センサを用い、人体情報取得・学習し、状態間の変化点を利用して、高齢者によく見られる4種類の異常を検知する。4種類の異常は 1) 急な状態変化、2) 認知症に対する特定な状態パターン、3) 意識不明、4) 日常行動が徐々に緩くなる、である。これらの異常を検知するために、本手法には状態認識モデルと変動検知モデルという2つのモデルを含めている。状態認識モデルは、心拍・呼吸・体動情報を用いて、分類アルゴリズムで状態を認識することである。変動検知モデルは、特異スペクトルで体動波形の変化を定量化することである。このような手法で、高齢者の異常を検知し、事故を防ぎ、高齢者に貢献することを目指す。

提案した異常検知手法を検証するために、単身用の学生寮室で2つのマイクロ波センサを用いて実験を行った。そして、4ケースの状態認識モデルの正解率を示し、変動検知モデルの衰弱の予測可能性のあることを示した。最後に、実験結果を考察して発見した問題点をまとめて、今後の課題を述べた。

目次

第1章 はじめに	1
1.1 背景	1
1.2 本研究の目的	3
1.3 本論文の構成	4
第2章 既存研究	5
2.1 異常状態の検知について研究	5
2.2 行動認識について研究	7
2.3 人体センサについて研究	8
2.4 非接触センサの比較	9
2.4.1 マイクロ波センサ	9
2.3.2 圧力センサ	10
2.3.3 非接触センサの比較結果	11
2.4 分類アルゴリズムの比較	12
2.4.1 サポートベクターマシン	12
2.4.2 K近傍法	14
2.4.3 ランダムフォレスト	15
第3章 高齢者の健康管理	17
3.1 高齢者の生活環境	17
3.2 高齢者の生活状態	19
3.3 高齢者の異常	21
第4章 異常検知の手法	22
4.1 本研究の異常の定義	22
4.2 異常検知の手法	24

4.3	生活状態の検出	26
4.3.1	時系列の機械学習	26
4.3.2	先行研究の3つの分類アルゴリズムの比較	26
4.4	状態変化の検出	31
4.4.1	特徴的なパターンの算出	31
4.4.2	変化度の定義	33
4.4.3	変化度の検知手順	33
第5章	実験と評価	34
5.1	状態認識モデル実験	34
5.1.1	特徴の抽出	34
5.1.2	ランダムフォレストのパラメータの決定法	37
5.1.3	ウィンドウ幅によるモデルの比較	38
5.1.4	4種類状況の実験結果	39
5.1.5	状態認識モデルの考察	41
5.2	変動検知モデル	42
5.2.1	変動検知モデルのパラメータ	42
5.2.2	変動検知モデルによる衰弱予測	44
5.2.3	変動検知モデルの評価	47
第6章	おわりに	48
	謝辞	49
	参考文献	50
	付録	52

第1章 はじめに

1.1 背景

近年、日本の少子高齢化現象が世界でも早いスピードで進んでいる。平成28年の総務省[1]の統計では、65歳以上の高齢者人口は3461万人で、総人口に占める割合は27.3%となっている。平成27年から比較すると、73万人と大きく増加しており、人口、割合共に過去最高となった。高齢者の総人口に占める割合の推移をみると、昭和25年以降一貫して上昇が続いており、昭和60年に10%、平成17年に20%を超え、平成28年は27.3%となった。

日本に限らず、14億の人口を持つ中国も同じ問題を抱えている。中国産業新聞[2]によると、中国で60才以上の高齢者人口は2.12億人、総人口に占める割合は15.5%である。そして、一人暮らしの高齢者も1億人いる。

そして、一人暮らしの高齢者は身体機能の低下により、様々な不測の事故に遭う危険性がある。東京都監察医務院が公表しているデータによると、東京23区内における一人暮らしで65歳以上の人の自宅での死亡者数は平成25年に2869人となっている。それらの危険を早く察知するために、高齢者見守りの重要性も高くなっている。

現在、高齢者の見守りを行っているのは多くの場合高齢者介護センター職員である。しかし、高齢者の不測な事故を防ぐため、介護者は基本24時間に高齢者の傍に付いている。そちらの理由により、介護者にとって、高齢者の介護は大変な仕事である。そして、厚生労働省の調査により、「介護に関してストレスがある」と答えた職員の割合は60%を超えている。更に職員の転職も徐々に頻繁になってきている。もし、高齢者の異常を早く発見できれば、高齢者の命もちろん、介護者の負担を減らすことができる。そこで、異常検知が重要だと考えられている。




図 1: 日本の高齢者人口及び割合の推移




図 2: 中国の高齢者人口の推移

1.2 本研究の目的

1.1 節では高齢者の異常検知の重要性を指摘した。

異常検知には、主に視覚センサ（カメラ）と接触センサ（加速度センサ）が利用されてきた。しかし、視覚センサには、個人プライバシーを侵害する恐れがあり、人に嫌悪感をもたらす可能性がある。そして、接触センサには、人に身体的・精神的負担を与える可能性がある。

一方、マイクロ波を利用して人の人体情報を取得できる非接触センサ、即ちマイクロ波センサについて研究が進んでいる。

本研究では、異常検知手法と行動認識手法について先行研究を参考し、非接触型のマイクロ波センサを用いて人体情報のデータを得た。その人体情報（心拍・呼吸・体動）を利用し、機械学習により、状態認識モデルに高齢者の状態を認識させた。更に、変動検知モデルで変化度を算出した。その結果に基づいた4つの異常の検知方法を提案した。最後に、実験により、提案した異常検知手法の有効性を検証した。



図3 研究概要

1.3 本論文の構成

第 1 章

研究背景と本研究の目的を述べる。

第 2 章

異常検知と行動認識の既存研究について述べ、それらの問題点を述べる。

第 3 章

現在高齢者の生活環境を調べ、行動状態を分析した。また、高齢者の病気を調べ、異常状態がどんなものかを分析した。その結果、実験環境と高齢者の状態、検知する異常について決定した。

第 4 章

提案する異常検知手法を述べる。また、提案した状態認識モデルと変動検知モデルについて述べる。

第 5 章

実験について述べる。状態認識モデルと変動検知モデルのパラメータを決定し、また上記の 2 つのモデルの評価を行った。最後、異常検知手法の評価を行った。

第 6 章

本研究のまとめと今後の課題を述べる

第2章 既存研究

2.1 異常状態の検知について研究

布勢ら[3]では，人物動態のモニタリングにより，日常的に得られるデータから正常状態を階層ディリクレ過程隠れマルコフモデルで学習し，異常状態検知手法を提案した．

関ら[4]では，高齢者行動パターンと時間を分析し，非日常性を定義した上で，全方位視覚センサを用い，非日常行動を自動的に検出するシステムを提案した．具体的に，まず総務省統計局の生活行動時間データにより，日常的に家庭内で生活していると考えられる高齢者の行動パターンと時間を分析する．20 種類ほどの行動のうち上位を占めるものについて一週間での行動時間を調べた．非日常性を以下の 4 種類に分類し定義する(A)学習にない異常行動：部屋で倒れている場合や普段とは異なる場所にいる場合などである．(B)時間軸に関する異常行動：行動そのものは日常起こりうるものであってもその時間帯が学習とは異なる．例えば一日中ベッドで寝ている場合や夜中にベッドから離れて歩き回っている（徘徊している）ような場合などである．(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ないようなパターンは異常とみなすべきである．例えば夜中にベッドで寝返りをうたなくなったり，その他の場所で動きが止まったりという場合が考えられる．(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センサ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．

田中ら[5]では，ファジィ理論とルールベースを利用し，生活行動認識システム，生活パターン生成システム，異常状態検出システムを構成した．これら 3 つのシステムにより，緊急度あまり高くない異常状態検知手法を提案した．「生活行動認識システム」は主に，ユビキタスセンサによるセンシングとルールベースシステムで行動認識の 2 つの要素から構成される．ルールベースシステムによる行動認識においては，それぞれのセンサに対応した動作を設定し，動作の組み合わせによって行動が決まるようなルールを作成する．「生活パターン生成システム」はファジィ理論の概念を用い，以下の 4 種類のファジィ集合を生成する．

1. 「時刻ファジィ集合」 2. 「継続時間ファジィ集合」 3. 「行動時間ファジィ集合」 4. 「行動回

数ファジィ集合」である。「異常状態検出システム」は上記の 4 種類ファジィ集合に基づいて現在認識した行動から、異常状態を検知する。

岩澤ら[6]では、Kinect の RGB カメラや距離カメラなどの各種センサを利用し、行動の習慣を捉え、毎日発生している習慣を生活習慣行動として定義した。定義した生活行動習慣からずれる行動を異常行動として検知する。

長井ら[7]では、スマートフォン（Android）を用い、取得したデータを決定木で学習し、センサデータの情報と高齢者からの自発的情報を組み合わせ、異常状態アルゴリズムを提案した。

鈴木ら[8]では、学習させる正常データと診断させるデータとがどれだけ似ているかあるいは似ていないかを主成分分析で適切に数値化し、異常検知手法を提案した。

及川ら[9]では、多種のパケット情報を統合し、ネットワーク状態を数値表現することにより、統計的クラスタリング手法で通常状態から逸脱したものを検出する方法について提案した。

前川ら[10]では、居住者への物理的かつ精神的な負担が少ない非侵襲性センサを用い、居住者の位置情報や環境情報の実測値から異常行動の早期発見、健康管理ができるシステムの開発を目的とし、要件を定義した。

以上まとめると、異常検知については、センサを利用し、取得したデータを処理し、異常を検知する。そして、異常検知手法は主に 2 つの種類がある。1 つは学習されていないクラスを異常として検知する。例えば行動習慣、行動パターンからずれる行動などである。もう 1 つは特定の行動を異常として検知する。例えば分類アルゴリズムを利用し（決定木など）、転倒などの動作を検知することである。

2.2 行動認識について研究

Bao ら[11]では、加速度センサを用い、加速度データから 3 種類の特徴値（平均、F F T 係数、相関係数）を抽出し、動作の認識手法を提案した。

Ravi ら[12]では、加速度センサを用い、8 種類の動作を 6 種類の分類アルゴリズムで分類し、評価した。

森ら[13]では、特異スペクトル変換（SST）を利用して変化点のスコア値を計算した。スコアを設けて閾値より高いものだけを変化点として採用する。変化点によって区切られたデータセグメントに対して HMM を適用し、その結果を K-means によってクラスタリングを行うことでラベルを割り振る。

佐藤ら[14]では、腕時計タイプのセンサから収集した加速度データや脈波データ、体温、GSR などを用い、決定木を利用してモデル構築を行うことで各行動を高精度に識別する。

安部ら[15]では、脳波センサを用い、一般的な人間の状態を対象とし、人間の状態がどの程度認識できるのかについて実験を行った。

村尾ら[16]では、加速度波形の定常性を判定し、DTW（Dynamic Time Warping）などのテンプレートマッチング手法を用い、ジェスチャの部分に対してのみジェスチャ認識を行うことで姿勢、運動、ジェスチャを認識するシステムを提案した。

以上まとめると、行動認識には、教師あり、教師なしと半教師認識手法がある。教師あり学習にはサポートベクターマシン（SVM）、決定木などがある。教師なし学習には、隠れマルコフモデル（HMM）や K-means などがある。そして、データの前処理も手法（DTW）などがある。

教師あり学習は特定の行動の検知に応用されているが、教師なし学習は主に正常パターンからずれる行動の検知に応用されている。

2.3 人体センサについて研究

浅沼ら[17] では 3 軸加速度情報を動作情報と体温・心電図を生体情報を組み合わせて両者をまとめたものをユーザ情報とした。この情報を用い、判定できるコンテキスト数の増加と判定精度の向上を図った。

乾ら[18] ではマイクロ波センサを用い、低外乱下で人が横になっている状態での呼吸の有無について、サポートベクターマシン(SVM) による識別方法を提案した。呼吸成分は 0.3Hz 近辺に、心拍成分は 1.2Hz 近辺に分布することから、最初に高周波成分の除去を行う。そこで、観測波形に対して 0~2.0Hz を通すローパスフィルタを適用する。ローパスフィルタ適用後のデータに対して式を用いて I-Q 信号の瞬時振幅の生成を行う。I-Q 信号の瞬時振幅の平均、分散、最大値、最小値、尖度、歪度に着目し、これらの値を SVM で用いる特徴量とする。また計算時には窓幅を 1000 サンプルに設定し、1 サンプルずつシフトさせながら算出する。そして I-Q 信号の瞬時振幅の波形に対して振幅、周波数、位相の推定を行う。最後 Gaussian カーネルを用いた SVM によって呼吸の有無の認識を行う。

三浦ら[19]では就学前児童を対象とし、加速度データと心拍データの両方を用いて行動を識別することである。「散歩」「室外遊び」「食事」「室内遊び」といった 4 つの行動をする就学前児童 5 名から加速度データと心拍データを計測する実験を行い、得られたデータをスペクトログラムなどで分析することで 4 つの行動を識別する

安部ら[20]ではいくつかの種類の行動をとった時の人間の脳波データを簡易脳波センサ MindTune によって測定し、測定したデータを解析することで行動の種類を判別することがどの程度可能であるかを実験した。

2.4 非接触センサの比較

本節では、2つの非接触センサ、マイクロ波センサと圧力センサを比較した。

2.4.1 マイクロ波センサ

マイクロ波とは、周波数 300MHz から 300GHz（波長が 1m から 1mm）の電波のことをいう。マイクロ波は強い直進性を持つため、通信だけでなく、レーダーによる移動物体監視システムなど様々な分野にも応用されているが、最近、医療分野でも広く応用されている。

マイクロ波センサは、マイクロ波を発射し、物体に当て、反射してきたマイクロ波の周波数と発射したマイクロ波の周波数を比較することにより物体の動きを検出する。物体が動いている場合はドップラ効果により反射波の周波数が変化し、これにより物体が動いているか、静止しているか知ることができる。医療分野には、人に対してマイクロ波を照射し、心臓や肺の動きによって僅かに振動する体の表面から反射するマイクロ波の変化から、心拍や呼吸数を検知できる。

本研究ではワイヤレスコミュニケーション研究所の 24GHz 帯マイクロ波センサを使用した。

サンプリング周波数：50Hz

送信時間:10 秒

使用したマイクロ波センサの測定範囲は図 5 に示す。




図 4 マイクロ波センサ




図 5 : 24GHz マイクロ波センサの測定範囲

2.3.2 圧力センサ

圧力センサとは気体や液体の圧力をダイヤフラムを介して、感圧素子で計測し、電気信号に変換し出力する機器である。人間や動物の体は呼吸や心拍などによって常に動いており、適切な位置で体表や体重の一部の変動を空気圧変動に置き換え観察することによって呼吸、心拍、体動などを総合的にあるいは単独で検出することができる。



図 6 圧力センサ

本研究ではワイヤレスコミュニケーション研究所のマットセンサを使用した。

サンプリング周波数 : 50Hz

送信時間 : 120 秒

2.3.3 非接触センサの比較結果

本研究では、マイクロ波センサと圧力センサを用い、センサを比較した。具体的には、まず、マイクロ波センサと圧力センサで同時に次の3つの状態データを取得した。

1. 寝ている
2. 座っている
3. 歩いている

上記の状態の身体情報を取って、状態認識実験を行った。その結果を表1に示す。

表1：マイクロ波センサと圧力センサの実験結果

	寝ている	座っている	歩いている
マイクロ波センサ	100.0%	93.3%	96.7%
圧力センサ	95.2%	41.0%	86.8%

表1により、マイクロ波センサの各状態の正確率は、寝ている状態（100%）、座っている状態（93.3%）、歩いている状態（96.7%）である。圧力センサの各状態の正確率は、寝ている状態（95.2%）、座っている状態（41.0%）、歩いている状態（86.8%）である。マイクロ波センサの正確率が高いことが分かった。その理由を以下と考えられる。1つの圧力センサは距離による変化を表示できないと考えられる。よって、座っている状態と歩いている状態を区別にくい。マイクロ波センサは信号の強度により、距離を表示できるため、圧力センサよりもっと情報を得られると考えられる。更に、マイクロ波センサの測定範囲が圧力センサより広いので、本研究に使用されるセンサをマイクロ波センサとする。

2.4 分類アルゴリズムの比較

2.4.1 サポートベクターマシン

サポートベクトルマシンは、現在もっとも広く利用されているパターン認識学習アルゴリズムの 1 つで、最大マージンを実現する 2 クラス問題の線形識別関数構成法である。マージン最大化は、与えられた不等式制約条件下で最適化問題を学習データを用いて解くことにより得られる。上記のように、サポートベクトルマシンは 2 クラス分類アルゴリズムであるが、多分類の場合は、 $(K-1)$ 個の 1 対他サポートベクトルマシンで実現することが多い。最適識別超平面について、次に紹介する。

クラスラベル付き学習データ集合を $D_L = \{(t_i, x_i)\}$ ($i = 1, \dots, N$) とする。 $t = \{-1, +1\}$ は教師データであり、学習データ $x_i \in R^d$ がどちらのクラスに属するのかを指定する。

図 7 のように、線形識別関数のマージンを κ とすれば、すべての学習データで

$$|\omega^T x_i + b| \geq \kappa$$

が成り立つ。係数ベクトルとバイアス項をマージン κ で正規化したものを改めて ω と b とおけば、線形識別関数は、

$$t_i = +1 \text{ の場合 } \omega^T x_i + b \geq +1$$

$$t_i = -1 \text{ の場合 } \omega^T x_i + b \leq -1$$

となる。この場合分けは、

$$t_i(\omega^T x_i + b) \geq 1$$

のようにまとめることができる。




図7 サポートベクトルマシンによるマージン最大化の原理

クラス間マージンは、各クラスのデータを ω の方向へ射影した長さの差の最小値

$$\rho(\omega, b) = \min \frac{\omega^T x}{\|\omega\|} (x \in C_{y=+1}) - \max \frac{\omega^T x}{\|\omega\|} = \frac{1-b}{\|\omega\|} - \frac{-1-b}{\|\omega\|} = \frac{2}{\|\omega\|}$$

で与えられる．最適な超平面の式を $\omega_0^T x + b_0 = 0$ とすれば、この超平面は最大クラス間マージン

$$\rho(w_0, b_0) = \max \rho(\omega, b)$$

を与える．最大マージン D_{max} は最大クラス間マージンの $1/2$ で与えられる．従って、最適識別超平面は、 $t_i(\omega^T x_i + b) \geq 1$ ($i = 1, \dots, N$) の制約の下で、 ω のノルムを最小にする解

$$w_0 = \min \|\omega\|$$

として求めることができる[21].

2.4.2 K 近傍法

近傍法とは、認識したい入力データとすべての学習データとの距離計算を行って、認識したい入力データをもっとも近い学習データが所属するクラスに識別する方法である。最近傍法は学習データが多ければ極めて精度の良い認識系を構成することができるが、計算時間はかかる。

そして、K 近傍法とは、もっとも近い 1 つの学習データのクラスに識別する代わりに、もっとも近い k 個の学習データを選び、所属する学習データの数が最も多いクラスに識別する方法である。例えば、図 8 のような場合を考える。 $k = 3$ の時、最も近い 3 個の学習データのうち、クラス 1 に属する数は 2、クラス 2 に属する数は 1 なので、データはクラス 1 に識別される。 $k = 4$ の時は同数、 $k = 8$ では逆にクラス 2 に分類される。

学習データの集合を $T_n = \{x_1, \dots, x_n\}$ 、それらが所属するクラスの集合を $\Omega = \{C_1, \dots, C_K\}$ 、 i 番目の学習データが所属するクラスを $\omega_i \in \Omega$ とする。入力 x にもっとも近い k 個の学習データの集合を $k(x) = \{x_{i_1}, \dots, x_{i_k}\}$ とし、これらの学習データのうちクラス j に属する学習データの数を k_j とする。 $k = k_1 + \dots + k_K$ が成り立っている場合、K 近傍法の識別規則は、

$$\text{識別クラス} = \begin{cases} j & \{k_j\} = \max\{k_1, \dots, k_K\} \text{ の時} \\ \text{リジェクト} & \{k_i, \dots, k_j\} = \max\{k_1, \dots, k_K\} \text{ の時} \end{cases}$$

となる。上記の規則では、得票数に同数がある場合はリジェクトとしているが、ランダムにどれかのクラスに識別するような規則でも良い。




図 8 : K 近傍法

2.4.3 ランダムフォレスト

ランダムフォレストとは、バギングを改良し、図 9 に示すように、決定木の各非終端ノードにおいて識別に用いる特徴を、予め決められた数だけランダムに選択することで、相関の低い多様な決定木を生成できるようにした手法である。学習は単純であるが、サポートベクトルマシンやアダブーストなどと同様、あるいは問題によってはそれら以上の性能を持つことが知られている。

サポートベクトルマシンが、2 つクラス問題の識別器であるに対して、ランダムフォレストは多数決により、多クラス ($K > 2$) 問題に自然に拡張することができる。ランダムフォレストを生成するアルゴリズムを次に示す[21]。

- (1) $m=1$ から M まで以下を繰り返す
 - (a) N 個の d 次元学習データからブートストラップサンプル Z_m を生成する
 - (b) Z_m を学習データとし、以下の手順により各ノードを分割し、決定木 T_m を成長させる。終端ノードのデータ数の下限は 1 とする。
 - (i) d 個の特徴からランダムに d' の特徴を選択する。
 - (ii) d' 個の中から最適な分割を与える特徴と分割点を求める。
 - (iii) ノード t を分割点で left (t) と right (t) に 2 分割する。

- (2) ランダムフォレスト $\{T_m\}_{m=1}^M$ を出力する.
- (3) 入力データ x に対する m 番目の決定木の識別結果を $y_m(x) \in \{C_1 \cdots C_K\}$ とする.
 ランダムフォレスト $\{T_m\}_{m=1}^M$ の識別結果を $C_i = \arg \max |C_j|$ とする. $|C_j|$ はクラス C_j と判断した決定木の数である.

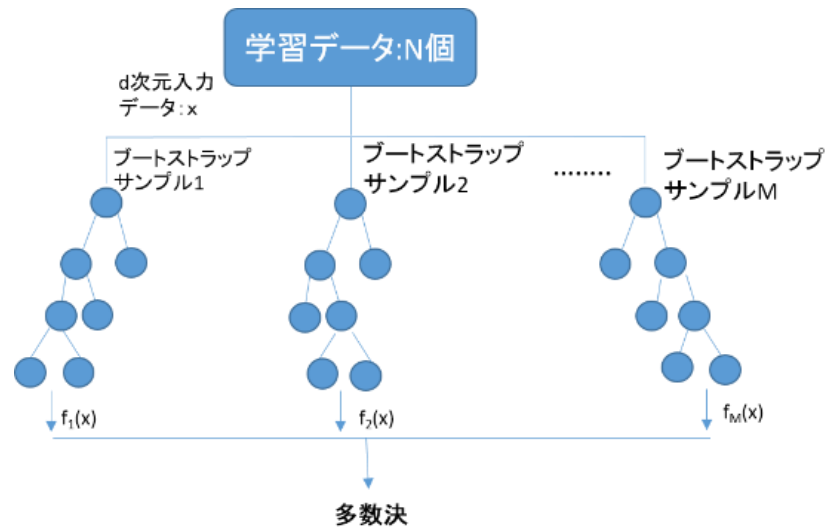


図 9 : ランダムフォレスト

第3章 高齢者の健康管理

3.1 高齢者の生活環境

内閣府の平成 27 年度版高齢社会白書[22]により、次のことがわかった。子供と同居している高齢者は減少しており、一人暮らしの高齢者は増加傾向にある。1 人暮らしの高齢者が高齢者人口に占める割合は、昭和 55 年には男性 4.3%，女性 11.2%であったが、平成 22 年には男性 11.1%，女性 20.3%になっている。




図10：1人暮らしの高齢者

そして、老人ホーム（図11）を参考に、次のように1人暮らしの部屋を実験環境として、実験を行った。マイクロ波センサとカメラを図12のように設置した。



図 11 : 1 人暮らしの老人ホーム




図 12 : 実験環境

3.2 高齢者の生活状態

内閣府の平成 27 年度版高齢社会白書[22]によると，孤独死と考えられる事例が多数発生していた．東京都監察医務院が公表しているデータによると，東京 23 区内における一人暮らしで 65 歳以上の人の自宅での死亡者数は平成 25 年に 2869 人となっている．高齢者の孤独死を防ぐため，高齢者の日常状態を把握する必要があることが分かった．




図 13：1 人暮らしの者の死亡数推移

ここで，総務省統計局の平成 23 年度の「曜日，男女，ふだんの就業状態，年齢，行動の種類別総平均時間，行動者平均時間及び行動者率」（表 2）[23]のデータを参考にし，下記の 9 種類の状態を本研究で認識する高齢者の日常状態（表 3）とする．

表 2 高齢者の 1 週間の行動時間

行動	平均時間(分/週)
睡眠	523
テレビなど	250
その他の活動	159
休養・くつろぎ	124
食事	120
身の回りの用事	87
興味	49

表 3 認識する高齢者の日常行動

class	behavior
1	移動
2	外出
3	食事
4	睡眠(rem)
5	睡眠(norem)
6	ベッドから起き上がる
7	ベッドで横になる
8	デスク作業
9	テレビを見る

3.3 高齢者の異常

高齢になると、身体機能の低下などによって様々な病気や疾患にかかりやすくなる。主な病気や疾患について述べる。

厚生労働省「国民基層生活調査」平成 25 年度[24]より、高齢者の要介護度を表 4 に示す。そのうち、介護が必要となった主な病気について以下に述べる。

認知症とは、様々な原因で脳の細胞が死んだり、働きが悪くなったりすることによって、生活に支障が出ている状態である。その症状として、家の中や外での徘徊、不眠、睡眠障害、摂食障害など症状がある。

高齢による衰弱には、筋力の衰え、歩行速度の低下、活動量の低下、疲労、体重減少の 5 つの症状がある。これらの症状が複合的に作用した結果、諸々の潜在能力が十分に発揮できなくなっている状態、即ち衰弱に陥ることによって、介護が必要な状態になる。転倒、骨折、最悪の場合は死を招くことにもなりかねない。

脳血管疾患は、がん、心臓病に次いで日本における死因の第 3 位となっている。脳血管疾患は発生前に、一過性脳虚血発作（TIA）という初期症状がある。その初期症状には、口の動きの異変（構音障害）、言葉が出なくなる（失語症）、顔に歪みが出る（片側顔面まひ）、片方の目に膜がかかったように見えなくなる（一過性黒内障）、片方の手足に力が入らなくなる（片まひ）などがある。一旦、病気が発生した時、顔が蒼白になり、脈と血圧の低下、脈拍の上昇などを伴い、意識不明に陥る。

表 4： 要介護度別にみた介護が必要となった主な原因

(単位:%)			平成25年			
要介護度	第 1 位		第 2 位		第 3 位	
総 数	脳血管疾患(脳卒中)	18.5	認知症	15.8	高齢による衰弱	13.4
要支援者	関節疾患	20.7	高齢による衰弱	15.4	骨折・転倒	14.6
要支援 1	関節疾患	23.5	高齢による衰弱	17.3	骨折・転倒	11.3
要支援 2	関節疾患	18.2	骨折・転倒	17.6	脳血管疾患(脳卒中)	14.1
要介護者	脳血管疾患(脳卒中)	21.7	認知症	21.4	高齢による衰弱	12.6
要介護 1	認知症	22.6	高齢による衰弱	16.1	脳血管疾患(脳卒中)	13.9
要介護 2	認知症	19.2	脳血管疾患(脳卒中)	18.9	高齢による衰弱	13.8
要介護 3	認知症	24.8	脳血管疾患(脳卒中)	23.5	高齢による衰弱	10.2
要介護 4	脳血管疾患(脳卒中)	30.9	認知症	17.3	骨折・転倒	14.0
要介護 5	脳血管疾患(脳卒中)	34.5	認知症	23.7	高齢による衰弱	8.7

第 4 章 異常検知の手法

4.1 本研究の異常の定義

本研究では 3.3 節に紹介した症状をふまえて、高齢者の異常を以下の検知可能な 4 種類の状況として定義する。

異常 1. 急な状態間変化

異常 2. 認知症に対する特定な状態

異常 3. 意識不明

異常 4. 日常行動が徐々に緩慢になる。

まず、異常 1、異常 2、異常 3 は病気がある高齢者に危険が発生した時の症状により、定義した異常である。異常 4 は高齢者の衰弱を予測するため、定義した異常である。次に、各異常について詳しく説明する。異常 1 の急な状態間変化は高齢者による衰弱の転倒など危険の検知を目標とする。異常 2 の認知症に対する特定状態は認知症の検知を目標とする。異常 3 の意識不明は脳血管疾患による意識不明を目標とする。異常 4 の日常行動が徐々に緩慢になるは高齢者の衰弱の予測を目標とする。

異常 1 の急な状態変化については、衰弱した高齢者は、正常人を比べて、日常行動の動作スピードが緩慢であると考えられる。従って、高齢者の行動スピードより速い即ち突然な状態の変化をすると、移動中の転倒、ベッドから起き上がる中の転倒など異常が発生したことが考えられる。そして、異常を検知し、介護者に通知できる。

異常 2 の認知症に対する特定な状態については、認知症が発生した時、認知症の特定な状態を検知して、早く介護者に通報できる。ここで、認知症の特定な状態については、3.3 節に紹介した認知症の症状により、以下の 3 つの状態に分類する

状態 1. 深夜 2 時～4 時に移動状態

状態 2. 深夜 3 時まで寝ていない

状態 3. 食事継続時間 3 時間以上

認知症の特定状態は主に時間に関する状態である。状態 1 の深夜 2 時～4 時に移動状態は、家の中の徘徊の検知を目標とする。状態 2 の深夜 3 時まで寝ていない状態では、不眠や

睡眠障害の検知を目標とする．状態 3 の食事継続時間 3 時間以上状態では，摂食障害の検知を目標とする．

異常 3 の意識不明について，様々な原因で，高齢者は意識不明の状態に落ちる．本研究の意識不明とは，脳血管疾患により意識不明である．ここで，脳血管疾患の意識不明の特徴を用い，意識不明の検知を目標とする．意識不明を検知してから，介護者に報告し，意識不明に陥った高齢者を早く救うことができる．

異常 4 の日常行動が徐々に緩慢になるは，高齢による衰弱の早く発現を目標とする．人の身体衰弱は 1 日で衰弱することではなく，徐々に衰弱している．上記の特徴を持ち，高齢者の毎日の状態変化の遅さを検知することによって，衰弱の傾向を早期発見できると考えられる．異常 4 を検知してから，介護者に報告し，高齢者の飲食，運動などを調整できる．

上記の異常を検知するために，本研究では，状態認識モデルと変動検知モデルという 2 つのモデルを提案する．状態認識モデルは異常 1 急な状態変化と異常 2 認知症に対する特定な状態を検知することである．変動検知モデルは異常 3 意識不明と異常 4 日常行動が徐々に緩慢になるを検知することである．具体的の異常検知手法を 4.2 節で説明する．

表 5：症状に対する異常

高齢者の衰弱による転倒	⇒	異常 1. 急な状態変化
認知症	⇒	異常 2. 認知症に対する特定な状態
脳卒中による意識不明	⇒	異常 3. 意識不明
高齢者の衰弱	⇒	異常 4. 日常行動が徐々に緩慢になる

4.2 異常検知の手法

本節では状態認識モデルと変動検知モデルを用いた異常検知手法を提案する．具体的な処理流れを図 14 に示す．

異常 1（急な状態変化）の検知では，状態を認識してから，特定な状態遷移あるいは状態遷移動作の時間により，異常として検出する．ここで，特定な状態遷移とは，状態 X から状態 Y になる過程である．

状態 X : class1（移動），class3（食事），class4（睡眠 rem），class5（睡眠 norem），class8（デスク作業），class9（テレビを見る）

状態 Y : class2（外出），class7（ベッドで横になる）

状態遷移動作は class6（ベッドから起き上がる）

異常 2（認知症に対する特定な状態）は，認識した状態と 4.1 節に定義した認知症の特定の状態とが一致した場合，異常として検知する．

表 6：認知症の症状による特定な状態

家の中の徘徊	⇒	状態 1：深夜 2 時～4 時に移動状態
不眠	⇒	状態 2：深夜 3 時まで寝ていない
摂食障害	⇒	状態 3：食事継続時間 3 時間以上

異常 3（意識不明）は，心拍や呼吸が正常より低く，かつ体動の標準偏差が低いこととして定義する．高齢者の心拍数の範囲は 60~80, 成人の呼吸数の範囲は 14~20 である．従って，心拍，呼吸が上記の最小値より低く，かつ体動の標準偏差が 0 に近い場合，異常として検知する．

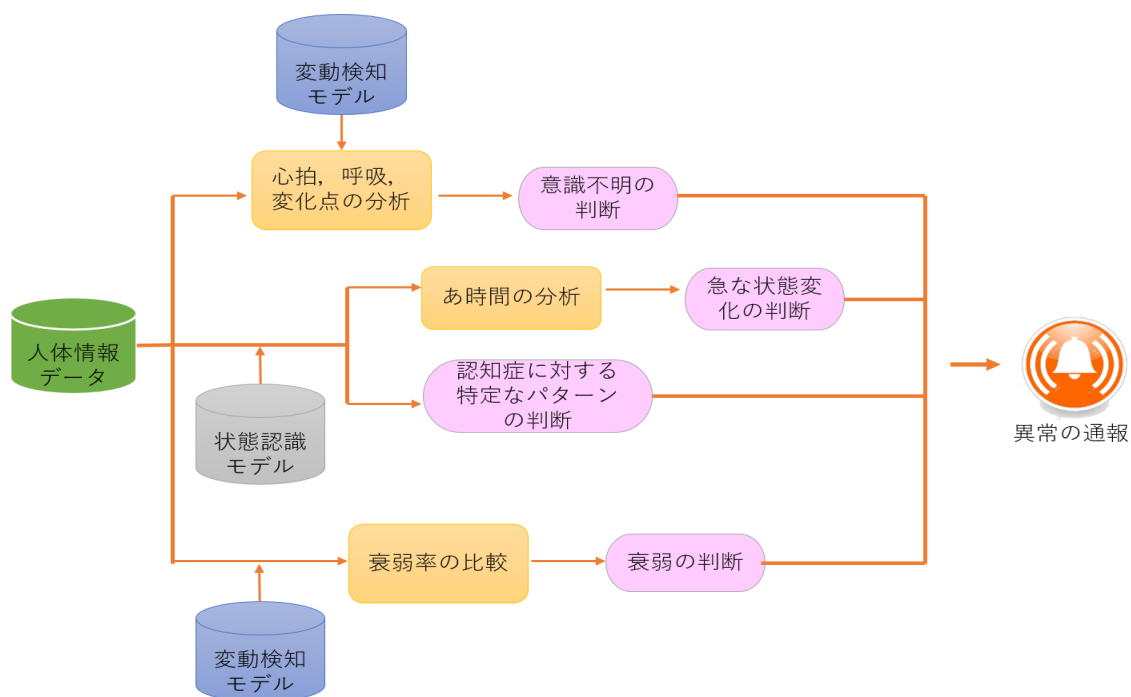


図 14：提案手法の流れ

異常 4（日常行動が徐々に緩慢になる）とは、各状態遷移時の変化度を記録し、1 週間変化度の低下が続いている場合、異常として検知する。具体的な手順では、まず毎日の変化度を求め、各状態間の平均変化度のみを抽出し、各センサの各状態間の平均変化度を記録する。各日の状態間の平均変化度の変化を記録し、以下の式で衰弱率を算出する。

$$\text{衰弱率}_{(d_1, d_2)} = \frac{(\text{d}_1 \text{ 日の各状態間の平均変化度} - \text{d}_2 \text{ 日の各状態間の平均変化度})}{(\text{d}_1 \text{ 日の各状態間の平均変化度})}$$

最後に、衰弱率が 1 週間続く低下している。更に、30%を超える場合、異常 4 を検知する。上記の 4 種類の異常を検知することを目的とする。

4.3 生活状態の検出

生活状態の検出とは、状態認識モデルを用い、表 3 に示した状態を検知することである。状態認識モデルとは、分類アルゴリズムを利用し、状態を認識することである。本研究では複数クラスを分類するため、サポートベクターマシン、 K 近傍法、ランダムフォレストという 3 つの分類アルゴリズムを比べ、実験結果により、ランダムフォレストを選んだ。

4.3.1 時系列の機械学習

従来の時系列データの処理は、一般的にはあるパターンを含む数秒間（ウィンドウ）のデータの平均値や分散値を求め、分類アルゴリズムを使って、パターンを認識することである。本研究では 2.2 節に述べた先行研究を参考し、スライディングウィンドウを用い、ウィンドウ内の波形から平均と標準偏差を抽出して、それらを特徴ベクトルとして与える手法を利用した。

4.3.2 先行研究の 3 つの分類アルゴリズムの比較

2.4 節に紹介した 3 つの分類アルゴリズムを用いて、以下の 4 種類の状態の分類実験を予備実験として行った。

状態 1. ベッドに寝ている

状態 2. ベッドで横になる

状態 3. 机前に作業している

状態 4. 部屋に歩いている

特徴量として次の 11 個変数

心拍数の平均値 MH ，心拍数の標準偏差 DH ，呼吸数の平均値 MB ，呼吸の標準偏差 DB ，体動の平均値 $MSDI$ ，体動の標準偏差 $DSDI$ ，体動波形の平均値 MM ，体動波形の標準偏差 DM ，そして，心拍数と呼吸数の相関係数 $crHB$ ，心拍数と体動の相関係数 $crHM$ ，呼吸数と体動の相関係数 $crBH$ 。




図 15 : gini 係数

そして，GINI 係数を計算した結果（図 15）により，最終的にを特徴値として決めた．

1. 平均値（心拍数，呼吸数，体動，体動波形）
2. 標準偏差（心拍数，呼吸数，体動，体動波形）

次に，分類アルゴリズムの正確性はパラメータにより違いが生じる．図 16，図 17，図 18 により，各分類アルゴリズムのパラメータを決める．




図 16 : サポートベクターマシン




図 17 : ランダムフォレストのパラメータ




図 18 : K 近傍法のパラメータ

SVM のパラメータを図 16 に示す : Cost=10 Gamma=0.1

ランダムフォレストのパラメータを図 17 に示す : mtry=2,ntree=38

k 近傍法を図 18 に示す : k=11

上記のパラメータに決めた.

更に、以下の 5 つケースで実験を行った.

case1 : 1 人, 1 日間のデータ

case2 : 1 人, 2 日間のデータ

case3 : 2 人それぞれ違う日のデータ

case4 : 1 人, 1 日間データを訓練データとし、2 日目のデータをテスト

case5 : 1 人, 1 日間データを訓練データとし、違う人の 1 日間のデータをテスト

表 7 : 各分類アルゴリズムの正解率

	SVM	KNN	randomforest
case1	97.51%	89.78%	96.92%
case2	97.07%	80.54%	91.98%
case3	73.03%	61.18%	80.85%
case4	83.32%	79.35%	85.47%
case5	52.89%	42.56%	65.43%

結果を表 7 に示す. case1, case2 の正解率が 3 種のアルゴリズムに全てで一番高い. 5 つのケースごとに比較すると, ランダムフォレストの評価が一番良い, KNN が一番低いことが分かった. その理由は以下と考えられる. ランダムフォレストはデータと特徴をランダムで選択し, 投票即ち多数決による分類結果を得る. KNN はデータとデータ間の距離により, 分類結果を得る. 従って, KNN はノイズを含めるすべてのデータを使用した. ランダムフォレストはランダムサンプリングでノイズを除け, 更に, 多数決もノイズの影響を抑える. そして, 各アルゴリズムの正確率により, 今回のマイクロ波センサのノイズは大きいことが分かった.

本実験では予備実験よりもっと多くの状態(9 種類の状態)进行分类するため, 多数決により多クラス問題に自然拡張することができ, 過剰適合現象(汎化能力が低い)を抑えることができるランダムフォレストを採用した.

4.4 状態変化の検出

状態変化の検出とは、変動検知モデルを利用し、状態間の変化を数値化することである。変動検知モデルとは、体動から、前のパターンと後のパターンの食い違いを数値化することである。即ち、外れ値の検出である。時系列の外れ値を検出する手法には、近傍法と特異ベクトル変化法などがある。本研究で使われたマイクロ波センサは体動を測定するが、ノイズを含む可能性が高い。従って、本研究では時系列データからノイズを取り除くことができる特異スペクトル変換法[25]を利用し、特徴的なパターンを算出し、その特徴的なパターンの食い違いを数値化し、状態間の変化を検知する。

4.4.1 特徴的なパターンの算出

まず、特徴的なパターンの算出を紹介する。例えば、観測値として長さ W の時系列 $D = \{\xi_1, \xi_2, \dots, \xi_t\}$ があるとする。時刻 t の過去側と現在側において、 M 本の部分時系列を使って、2つのデータ行列 X_1 と X_2 を以下の式のように構成する。 X_1 は過去行列と呼ぶ。それに対して、 X_2 は未来行列と呼ぶ。

$$X_1^{(t)} \equiv [x^{(t-M-W+1)}, \dots, x^{(t-W-1)}, x^{(t-W)}] \quad (1)$$

$$X_2^{(t)} \equiv [x^{(t-M+L-W+1)}, \dots, x^{(t-W+L)}] \quad (2)$$

データにおいて特徴的なパターンを捉える最も素朴な方法は、部分時系列（列ベクトル）の1次結合を考えることである。「特徴的なパターン」とは、各ベクトルが似たような方向を向いて強め合った結果である。したがって、最適な1次結合を求めると

$$\|X_1^{(t)} v^{(t)}\|^2 \rightarrow \text{最大化} \quad \text{subject to } v^{(t)T} v^{(t)} = 1$$

となる。従って、以下ようになる。

・ $X_1^{(t)}$ の上位 m 個の左特異ベクトル $(u^{(t, 1)}, u^{(t, 2)}, \dots, u^{(t, m)})$ が過去側の主部分区間の基底。

・ $X_2^{(t)}$ の上位 m 個の左特異ベクトル ($q^{(t, 1)}, q^{(t, 2)}, \dots, q^{(t, m)}$) が未来側の主部分区間の基底.

上記主部分区間をまとめて、次のような $W \times m$ 行列を定義しておく.

$$U_m^{(t)} \equiv [u^{(t, 1)}, u^{(t, 2)}, \dots, u^{(t, m)}]$$

$$Q_m^{(t)} \equiv [q^{(t, 1)}, q^{(t, 2)}, \dots, q^{(t, m)}]$$

上記のように、特異値分解し、時系列データの特徴パターンを求める.

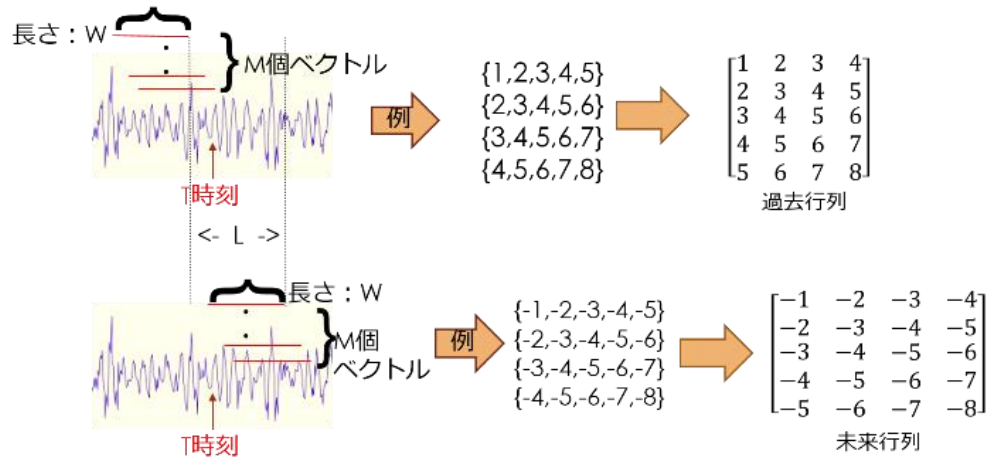


図 19 : 過去行列と未来行列

本研究ではマイクロ波センサで取得した体動波形の変化点を検出するため、 t 時刻の過去行列と未来行列の特徴パターンを求めて、両者の食い違いの定量化を変化度として定義する.

4.4.2 変化度の定義

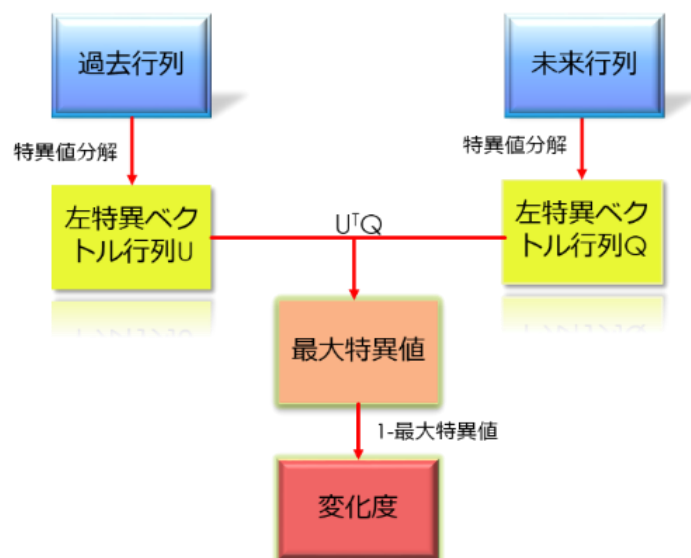


図 20：変化度の定義

時刻 t において過去と現在側の特徴パターンが求めたとすれば，両者の食い違いを定量化することでその時刻の変化度を定義できる．行列 2 ノルムを利用して，変化度は以下の式のように定義する．

$$a(T) = 1 - \left\| U_m^{(T)} Q_m^{(T)} \right\|_2^2 = 1 - \left(U_m^{(T)} Q_m^{(T)} \text{の最大特異値} \right)^2 \quad (3)$$

4.4.3 変化度の検知手順

検知手順をまとめると，以下のようになる

例えば，時系列 $D = \{\varepsilon^{(1)}, \varepsilon^{(2)}, \dots, \varepsilon^{(T)}\}$ を用意し，窓幅 W ，過去行列の列サイズ M ，ラグ L ，パターン数 m を決める時， $t = (W+M), \dots, (T-L+1)$ において次の計算を行う．

1. 行列の作成：過去行列と未来行列:式 (1) と式 (2) から $X_1^{(T)}$ と $X_2^{(T)}$ を作る．
2. 特異値分解： $X_1^{(T)}, X_2^{(T)}$ を特異値分解し，左特異ベクトルの行列 $U_m^{(T)}, Q_m^{(T)}$ を求める．
3. スコアの計算： $U_m^{(T)T} Q_m^{(T)}$ の最大特異値を計算し，式 (3) に代入することで変化度 $a(t)$ を計算する．

第5章 実験と評価

5.1 状態認識モデル実験

5.1.1 特徴の抽出


まず，マイクロ波センサから取得した行動データを観察する（心拍波形・呼吸波形・体動波形）．センサ1の食事の体動波形を例として示す．図21aはセンサ1の食事の体動波形グラフであり，図21bは図21aのデータを高速フーリエ変換したものである．

状態については食事の他に移動睡眠がある．移動を状態1，食事を状態2，睡眠を状態3とする．それらの状態における，心拍数，呼吸数，体動の激しさを以下に示す．


心拍数： 状態1>状態2>状態3

呼吸数： 状態1>状態2>状態3

体動の激しさ： 状態1>状態2>状態3



a：センサ1の食事の体動波形



b : センサ 1 の食事体動 FFT

図 21 : センサ 1 の食事データ

これらから、以下の 7 種類に特徴があると言える.

最大 FFT 係数 (心拍・呼吸・体動)


最大 FFT 係数に対応する周波数 (心拍・呼吸・体動)

波形標準偏差 (体動)


そして、これらの特徴を 4.3.1 節で述べたスライディングウィンドウで処理し、そらの
 平均値と標準偏差から 14 個の特徴値が得られた.

独立の特徴値の個数が多ければ、精度が高まると考えられる. 本研究では、2 つのマイク
 ロ波センサを用いたので、上記 14 個の特徴値を 2 倍して、総計 28 個の特徴値を得た.

28 個の特徴値の重要度を判断し、最終特徴値を決めた. 特徴値の重要度とは、ある特徴
 の変動に対し、各要因がどれだけ影響しているかを表したものである. したがって、本研
 究では、MeanDecreaseAccuracy 特徴量加工による重要度 と MeanDecreaseGini Gini 係数に
 よる重要度 を重要度の指標とし、特徴値の重要度を決定した. その結果を図 22 に示す.



a : 各特徴値の MeanDecreaseAccuracy



b : 各特徴値の MeanDecreaseGini

図 22 : 各特徴値の MeanDecreaseAccuracy と MeanDecreaseGini

これらの結果から、重要度が非常に低い特徴値がみられなかったため、本研究では上記 28 個の特徴値を用いることに決めた。

5.1.2 ランダムフォレストのパラメータの決定法

2.4.3 節で述べたランダムフォレストのアルゴリズムには、決定木の数 (M) と各決定木の
特徴数 (d') という 2 つの重要パラメータがある。本研究では R というソフトで 2 つのパラ
メータを決定する。

一般には、 d は \sqrt{d} にするが、本研究では R の「randomforest」というライブラリの関数
tuneRF (data, label, doBest=T) を用い、特徴量数を決めた。この関数は、モデルを構築す
る際に使用する特徴量の個数を貪欲的な方法により求める。各決定木の最尤特徴数を 20 と
した。

各決定木の特徴量数を決めた後、決定木の数 M を決める必要がある。そこで Out-of-bag
(oob) error と時間に基づき、決定木の最尤数を決める。結果を図 23 に示す。

oob error とは、ランダムフォレスト評価手法の 1 つである。即ち、サンプリングしていな
いデータをテストデータとして、モデルを評価する。その結果により、決定木数を 2000 ま
で試したが、収束できないクラスがあることが分かった。図 23 から時間など要素を総合的
に考え、決定木の数 500 とした。




図 23：決定木数による誤り率の変化

5.1.3 ウィンドウ幅によるモデルの比較

3.3 節に述べた 9 種類のデータの特徴値を算出し、5.1.2 節でパラメータを決めたランダムフォレストを使って、oob error を求めた。

条件 1: ウィンドウ幅 $w=20$ /秒, ずれ幅 $\text{shift}=10$ /秒

条件 2: ウィンドウ幅 $w=60$ /秒, ずれ幅 $\text{shift}=30$ /秒

2 つの条件におけるモデル認識の結果を表 8 に示す。(横: 分類したクラス, 縦: 正解クラス)

分類結果 1: 条件 1 の正確率 74.5%

分類結果 2: 条件 2 の正確率 66.5%

分類結果 1 と分類結果 2 を考察し、ウィンドウ幅が小さい方の正確率が高くなることが分かった。

表 8: 2 つのケースの結果

a: 分類結果 1

	1	2	3	4	5	6	7	8	9	class. error
1	50	0	5	0	0	0	22	17	5	0.49494949
2	2	72	0	0	34	0	16	2	0	0.42857143
3	0	0	227	0	0	0	4	142	0	0.39142091
4	0	0	3	569	313	0	50	11	6	0.40231092
5	0	6	1	17	2489	0	42	16	4	0.0339806
6	0	0	0	0	2	44	9	3	7	0.25301205
7	2	6	3	10	74	0	1250	55	114	0.17437252
8	1	0	27	0	1	0	24	1657	22	0.04330254
9	2	0	0	1	7	0	68	18	1145	0.07735697

b : 分類結果 2

	1	2	3	4	5	6	7	8	9	class. error
1	13	0	4	0	0	0	8	5	2	0.59375
2	0	20	0	1	15	0	4	1	0	0.51219512
3	0	0	66	0	0	0	0	48	0	0.42105263
4	0	0	0	128	154	0	22	8	2	0.59235668
5	0	0	0	6	826	0	17	6	0	0.03391813
6	0	0	0	0	2	11	3	0	7	0.54166667
7	1	1	3	2	5	0	364	11	57	0.18018018
8	0	0	5	0	0	0	4	535	8	0.0307971
9	0	0	0	0	2	0	36	4	371	0.11320755

従って、本研究では、分類結果 1 のモデルを状態認識モデルとする。

5.1.4 4 種類状況の実験結果

更に、状態認識モデルの汎用性を評価するために、Ravi らの研究を参考にし、以下の 4 種類の状況で実験した

状況 1. 1 人の複数日のデータを混ぜて、oob-error を計算する。

状況 2. 2 人の複数日のデータを混ぜて、oob-error を計算する。

状況 3. 1 人の 1 日のデータを学習し、同じ人の他の 1 日データをテストとして、正解率を計算する。

状況 4. 1 人の 1 日のデータを学習し、他の人の 1 日データをテストとして、正解率を計算する。

状況 1 では複数日のデータをランダムで学習データとテストデータに分けて、その認識分類正解率を求め、状況 2 では複数日の複数人のデータをランダムで学習データとテストデータに分けて、その認識分類率を求め、状況 3 では日に対する状態認識モデルの汎用性を評価する、状況 4 では人に対する状態認識モデルの汎用性を評価する。

状況 1 の正解率は 86.44%である。状況 2 の正解率は 88.64%である。状況 3 の正解率は 41.63%である。状況 4 の正解率は 17.70%である。具体的な結果を表 9 に示す（横軸：分類したクラス、縦軸：正解クラス）

表 9 : 4 ケースの結果

a : ケース 1 の結果

	1	2	3	4	5	6	7	8	9	class. error
1	50	0	5	0	0	0	22	17	5	0.49494949
2	2	72	0	0	34	0	16	2	0	0.42857143
3	0	0	227	0	0	0	4	142	0	0.39142091
4	0	0	3	569	313	0	50	11	6	0.40231092
5	0	6	1	17	2489	0	42	16	4	0.0339806
6	0	0	0	0	2	44	9	3	7	0.25301205
7	2	6	3	10	74	0	1250	55	114	0.17437252
8	1	0	27	0	1	0	24	1657	22	0.04330254
9	2	0	0	1	7	0	68	18	1145	0.07735697

b : ケース 2 の結果

	1	2	3	4	5	6	7	8	9	class error
1	228	0	9	0	1	0	26	30	4	0.23489933
2	0	206	0	2	17	0	15	0	1	0.14522822
3	1	0	353	0	0	0	3	81	0	0.19406393
4	2	9	3	487	28	0	45	7	5	0.16894198
5	1	3	1	12	462	0	37	0	4	0.11153846
6	3	0	0	0	0	65	10	3	5	0.24418605
7	2	4	3	12	25	3	1516	47	59	0.09275883
8	4	0	38	0	0	0	29	1273	5	0.05633803
9	0	0	0	0	0	0	74	6	708	0.10152284

c : ケース 3 の結果

	1	2	3	4	5	6	7	8	9	正確率
1	7	3	0	8	8	5	12	7	68	0.059322
2	0	56	0	0	7	0	0	0	0	0.8888889
3	33	2	9	8	11	0	1	81	139	0.0316901
4	1	139	0	298	49	4	0	10	28	0.563327
5	0	253	0	33	102	3	0	0	11	0.2537313
6	0	0	0	4	6	9	0	0	8	0.3333333
7	0	101	1	263	483	113	486	33	13	0.3255191
8	2	5	6	244	233	0	0	496	185	0.4235696
9	0	0	0	28	7	46	0	0	530	0.8674304
										0.4163124

d : ケース 4 の結果

	1	2	3	4	5	6	7	8	9	正確率
1	3	0	154	0	0	0	34	0	102	0.01023891
2	0	114	0	336	45	10	0	0	23	0.21590909
3	132	0	3	48	25	5	56	328	185	0.00383632
4	0	18	0	739	178	0	0	0	123	0.69848771
5	0	26	0	1242	284	4	0	0	462	0.1407334
6	26	0	0	0	0	2	2	23	48	0.01980198
7	0	2	0	62	18	0	5	0	653	0.00675676
8	0	0	89	5	0	4	0	4	125	0.01762115
9	0	6	0	855	329	1	0	0	1099	0.47991266
										0.17703311

5.1.5 状態認識モデルの考察

4つの状況の具体的なクラス分類結果は、食事、移動、デスク作業の正解率が低い、睡眠、テレビを見る正解率が相対的に高い。状態認識モデルの汎用性の実験結果により、同じ日の混ぜたデータを学習した場合（状況 1、状況 2）の正確率が高いが、違う日（状況 3）は低く、また、別人のデータを認識する場合（状況 4）は更に難しい。状況 3 と状況 4 で正確率が低くなった理由は以下のように考えられる。


まず、認識したい状態では複数の行動が含まれている可能性がある。例えば、デスクでパソコンを操作する、デスクでレポートを書くなどは、全てデスク作業（クラス 8）に含まれる。

次に、長時間の状態認識は複数の短時間動作から構成される。例えば、歩くという状態は足を前に出すという短時間動作の反復で構成されている。しかし、デスク作業の場合は同じ動作の繰り返しではない。更に、人によって、同じ動作でも特徴が違う可能性が高い。


5.2 変動検知モデル

5.2.1 変動検知モデルのパラメータ


4.3 節で提案した変動検知モデルには4つのパラメータがある．その4つのパラメータを以下で示す． w は過去データと未来データの長さ， k は過去データと未来データの数， l は過去データと未来データの距離， m はパターン数です．高齢者の行動が緩慢であるため，一定範囲内，例えば，窓幅が 60 秒内のパラメータを試し，変化点を検知できる最適パラメータを決定する．図 24 はパラメータによるセンサ 1 の変化度である．図 24a $w=60$ 秒 $L=120$ 秒 $m=3$ $k=3$ で，図 24b $w=60$ 秒 $L=120$ 秒 $m=2$ $k=2$ で，図 24c $w=60$ 秒 $L=60$ 秒 $m=3$ $k=3$ である．



a : $w=60$ 秒 $L=120$ 秒 $m=3$ $k=3$



b : w=60 秒 L=120 秒 m=2 k=2



c : w=60 秒 L=60 秒 m=3 k=3

図 24 : パラメータによるセンサ 1 の変化度

図 24a を見ると、 m と k が 3 の時、スコアが 0 から 1 の変化度を得た。図 24b は m と k が 2 の場合であり、スコアが負の値となり変化度として適さない。よって、 m と k を 3 に決定した。次に、 w と L の数値を推定する。

まず、変化度の平均値と標準偏差を求めて、 $(\text{変化度}) \geq (\text{平均値}) + (\text{標準偏差})$ の時間点を抽出し、最後に抽出した時間点と正解データと比べ、式 1 で状態変化抽出率を算出する。状態変化抽出率が高い時の w と L を変動検知モデルのパラメータとする。

$$(\text{状態変化抽出率}) = \frac{(\text{正しい抽出した変換点数})}{(\text{全て抽出した変化点数})} \quad \text{式 1}$$

図 24c では、抽出した変化点数は 1051 個で、状態変化抽出率=38%、図 24a では抽出した変化点数は 1065 個で、状態変化抽出率=36%が得られた。これより、 $w = 60$ 秒、 $L = 60$ 秒、 $m = 3$ 、 $k = 3$ と決定した。

5.2.2 変動検知モデルによる衰弱予測

高齢者の衰弱を予測するために、異常 4（日常行動が徐々に緩慢になる）を検知したい。ここで、その 5.2.1 節で決定したパラメータを用いた変動検知モデルの有効性を検証する。

本研究では、同じ行動パターンを 2 種類の状態で行い、変化度を比べる。行動パターンを以下のようにする。

ベッドで横になる->ベッドから起き上がる->移動->ベッドに倒れる->ベッドで横になる。

高齢者のデータを取ることが難しいので、三和の高齢者疑似体験教材を参考にする（図 25）。また、本研究では衰弱を筋力衰弱としているため、おもりバンド（筋力の低下による動作の遅さや平衡感覚を体験できる）を参考にした。上記の行動パターンを行う際、手と足には着けず、左肩に重りを着けることにした。重りは水が入ったペットボトルである。

図 25：水を入れたペットボトル




同じ行動パターンを，正常状態と水が入ったペットボトルを着けている状態で実験した．結果を表 10 に示す．結果により，正常な状況より筋力の衰弱状態の方が状態間の変化度が低い．


状態間の変化度とは，状態変化の間での最も高い変化度である．衰弱予測の具体的な手順は，毎日の変化度を求め，各状態間の平均変化度のみを抽出し，各センサの各状態間の平均変化度の平均を記録する．具体例として，本実験の各センサの各状態間の平均変化度を表 10 に示す．データは全てデータベースに保存する．そして，各日の状態間の平均変化度の変化を記録し，以下の式で衰弱率を算出する．

$$\text{衰弱率}_{(d_1, d_2)} = \frac{(\text{d}_1 \text{ 日の各状態間の平均変化度} - \text{d}_2 \text{ 日の各状態間の平均変化度})}{(\text{d}_1 \text{ 日の各状態間の平均変化度})}$$

最後に，衰弱率が 1 週間続く，または 15% 低下していたなら，衰弱を予測する．



a: 正常行動の変化度



b: 肩にペットボトルを掛けている変化度

図 26 : 正常行動と腰にペットボトルを掛けている変化度の比較

表 10：各状態間の変化度

	1	2	3	4	5	6	7	8	9
1	\	0.17	0.37	0.21	0.33	0.16	0.11	0.19	0.17
	\	0.15	0.07	0.37	0.1	0.26	0.15	0.12	0.16
2	0.19	\	0.16	0.81	0.000376	0.57	0.43	0.67	0.33
	0.56	\	0.01	0.11	0.00318	0.23	0.28	0.03	0.22
3	0.26	0.23	\	0.18	0.21	0.38	0.22	0.51	0.35
	0.68	0.16	\	0.38	0.18	0.32	0.31	0.15	0.33
4	0.17	0.53	0.13	\	0.07	0.52	0.42	0.66	0.23
	0.51	0.55	0.56	\	0.48	0.37	0.19	0.7	0.61
5	0.31	0.32	0.3	0.27	\	0.27	0.2	0.16	0.3
	0.45	0.31	0.3	0.33	\	0.63	0.31	0.36	0.3
6	0.17	0.28	0.08	0.34	0.58	\	0.19	0.29	0.28
	0.37	0.45	0.38	0.56	0.34	\	0.51	0.42	0.88
7	0.27	0.2	0.35	0.43	0.44	0.45	\	0.31	0.48
	0.15	0.44	0.73	0.41	0.44	0.42	\	0.1	0.33
8	0.45	0.28	0.34	0.24	0.4	0.57	0.33	\	0.37
	0.46	0.05	0.02	0.1	0.05	0.29	0.26	\	0.22
9	0.2	0.36	0.14	0.5	0.43	0.83	0.2	0.47	\
	0.36	0.24	0.35	0.32	0.41	0.43	0.56	0.14	\

更に、変動検知モデルの衰弱の予測の有効性を評価するために、次の実験を行った。以下の3つの変化の衰弱率を求め。

変化1：正常状態 ⇒ 正常状態

変化2：正常状態 ⇒ 衰弱状態

変化3：衰弱状態 ⇒ 正常状態

上記の3つの衰弱率は以下である。

変化1の衰弱率は8.45%，変化2の衰弱率は23.08%，変化3の衰弱率は-18.57%である。

5.2.3 変動検知モデルの評価

図26により、肩にペットボトルを着けている状態の変化度が正常状態より低いことが分かった。よって、状態間の変化度に基づいて高齢者の状態間の変化が区別できる。

変動検知モデルの衰弱予測の有効性の実験結果により、同じ状態間の変化、人の不確定性により（日により）、変化度が一定範囲で変わる。したがって、一定範囲の衰弱率の変化が正常状態である。よって、衰弱を正しく予測するために、その範囲を決めるべきと考えられる。即ち、衰弱率が一定時間内連続正值で、更に一定範囲を超えるなら、衰弱を予測できる。本研究は、その一定時間は1週間、一定範囲は30%とする。

第6章 おわりに

本研究では、非接触型のマイクロ波センサを用い、人体情報（心拍・呼吸・体動）を利用し、変化点を使い、機械学習で高齢者の状態を認識した上、4.2 節に提案した手法で高齢者の特定な異常の検知し、そして提案した手法を評価した。定義した 4 つの異常をまとめて、その結果を表に示す。

表 11：4 つの異常検知手法のまとめ

異常	手法	評価
1.急な状態変化	状態認識モデル	正解率：74.5%
2.認知症にたいする特定な状態	状態認識モデル	正解率：66.93%
3.意識不明	心拍，呼吸数	心拍： 60 以上，呼吸： 14 以下
	変動検知モデル	睡眠・外出の変化度 < 0.1
4.日常行動が徐々に緩慢になる	変動検知モデル	衰弱率を算出できる

4.1 節に定義した異常 1，異常 2 の検知手法は状態認識モデルを用い、状態認識を認識した。そして、3.2 節に述べた 9 種類の状態を認識した。表 8a の結果を見ると、状態認識正確率は 74.5%である。更に、状態認識モデルの汎用性の実験により、異常 1 の正解率は 74.5%である。異常 2 の正解率は 66.93%である。状態認識モデルの相関実験により、状態認識モデルが 1 人の状態が認識できるが、汎用性が足りないことが分かった。異常 3 は変動検知モデルとマイクロ波センサの生データを組み合わせて検知する。異常 4 は変動検知モデルで衰弱率により、衰弱を予測する。変動検知モデルの相関実験により、衰弱率による検知の有効性があると考えられる。しかし、2.3.1 節，5.1.4 節，5.2.3 節で分析した原因を考えると、次の課題が残っている。1.状態認識モデルの汎用性，2 マイクロ波センサのノイズ問題，3.衰弱予測の閾値の精度

謝辞

本研究に関して，多大なご指導およびご支援をいただきました沼尾雅之教授に深く感謝を申し上げます．また沼尾研究室のみなさまには，日頃の議論などを通じ多大なるアドバイスをいただきましたことを御礼申し上げます．

参考文献

- [1]総務省の高齢者人口データ, <http://www.stat.go.jp/data/topics/topi900.html>
- [2]中国の人口データ, <http://www.chyxx.com/industry/201510/352441.html>
- [3]布施孝志, “人物動態のモニタリングに向けた統計的異常検知” 東京大学大学院工学系研究科社会基盤学専攻
- [4]関弘和, “One-Class SVM を用いた高齢者異常検出モニタリングシステム”
- [5]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” 電子情報通信学会技術 Transactions of the Japan Society of Mechanical Engineers. C 75 (760), 3244-3252, 2009-12-25
- [6]岩澤雄太, 川澄正史, 小山裕徳, “行動モデルを用いた独居高齢者見守りシステムの提案”, LIFE2012 2012 年 11 月 2 日-4 日 愛知 (名古屋大学)
- [7]長井渉, 諏訪敬祐, “スマートフォンを利用した高齢者見守りシステムの異常検出精度向上に関する研究”, 東京都市大学横浜キャンパス情報メディアジャーナル = Journal of information studies (14), 61-68, 2013-04
- [8]鈴木英明, 内山宏樹, 湯田晋也, “データマイニングによる異常検知技術”, [O]perations research as a management science [r]esearch 57 (9), 506-511, 2012-09-01
- [9] 及川達也, 和泉勇治, 太田耕平, 加藤寧, 根元義章, “統計的クラスタリング手法によるネットワーク異常状態の検出” IEICE technical report 102 (349), 83-88, 2002-09-24
- [10]前川泰子, 中島智晴, 今西昇, 樋口由美, “居住空間のスマート化に向けた高齢者見守りシステム開発の取り組み”, ヒューマンケア研究学会誌 5 (2), 51-54, 2014
- [11]Bao and Stephen S, “IntilleActivity Recognition from User-Annotated AccelerationnData”, Pervasive, volume3001ofLectureNotesinComputer Science, page1-17. Springer, (2004)
- [12]Nishkam RaviActivity, ” recognition from accelerometer data “, IAAI'05 Proceedings of the

17th conference on Innovative applications of artificial intelligence - Volume 3 Pages 1541-1546

[13]森武俊, 藤井昭徳, 野口博史, 下坂正倫, 馬場章, 佐藤知正, ” 室内センサデータの変化点検出を用いた生活行動ラベリグ” , [No. 08-4] Proceedings of the 2008 JSME Conference on Robotics and Mechatronics, Nagano, Japan, June 5-7, 2008

[14]佐藤誠, 森田千絵, 土井美和子, ” 生体データと加速度を用いた行動認識” , 情報処理学会 65 回全国大会

[15]安部弘通, 高野茂, 馬場謙介, 村上和彰, ” 簡易脳波センサを用いた行動認識に関する研究” , IPSJ SIG Technical Report 2013 Information Processing Society of Japan

[16]村尾和哉, 寺田努, “加速度センサの定常性判定による動作認識手法” , 情報処理学会論文誌 Vol.52 No.6 1968-1979 (June 2011)

[17]浅沼伸洋, 関田格, 新津善弘, “生体センサを用いたサービス推薦のための状態判定方式” , 平成 20 年度電子情報通信学会東京支部学生会研究発表会

[18]乾秀平, “マイクロ波ドップラーセンサを用いた SVM による呼吸の有無認識”

[19]三浦右士, 浜中雅俊, 岩本畿輝, 李昇姫本, “ウェアラブルセンサを用いた子どもの行動識別” , 情報処理学会創立 50 周年記念(第 72 回)全国大会

[20]安部弘通, 高野茂, 馬場謙介, 村上和彰, “簡易脳波センサを用いた行動認識に関する研究” , 情報処理学会研究報告

[21]平井有三, “はじめてのパターン認識”

[22]内閣府の平成 28 年版高齢社会白書, <http://www8.cao.go.jp/kourei/whitepaper/w-2015/html/gaiyou/index.html>

[23] 総務省統計局 <http://www.stat.go.jp>

[24]厚生労働省「国民基層生活調査」平成 25 年, <http://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa13/>

[25]井手剛, “入門機械学習による異常検知”

付録

本研究のプログラムを全部 R というソフトで書いた．下記は本研究の一部のプログラムを示す．（生データの処理と状態認識モデルについてプログラムを省略する）

```
Function: ARfADsingle (.GlobalEnv)
1  function(frame)
2  {
3    mf<-data.frame(t(apply(frame,2,mean)))
4    vf<-data.frame(t(apply(frame,2,sd)))
5    #   colnames(mf)<-c("MB","MH","MSDI","MM")
6    #   colnames(vf)<-c("DB","DH","DSDI","DM")
7    d<-frame
8    df<-data.frame(cbind(mf,vf))
9    return(df)
10 }
11 |
```

図 A-1：データの平均と標準偏差を求め

```

1 extract <- function(dataframe,ws,shift)
2 {
3   feature <- NULL
4   for(j in 1:9)
5   {
6     result <- NULL
7     data <- dataframe[dataframe$label == j,-15]
8     i <- 1
9     while(TRUE)
10    {
11      if(i+shift*2>nrow(data)) break;
12      frame<-data[i:(i+ws),]
13      df<-ARFADsingle(frame)
14      if(class(df)=="data.frame") result<-rbind(result,df)
15      i<-i+shift
16      # result <- cbind(result,label)
17    }
18    label <- rep(j, nrow(result))
19    result <- cbind(result, label)
20    feature <- rbind(feature, result)
21  }
22  # label<-rep(Label,nrow(result))
23  # label<-data.frame(label)
24  # frame<-data.frame(cbind(result,label))
25  # result <- cbind(result,)
26  index<-sample(2, nrow(feature), replace = T, prob = c(0.7,0.3))
27
28  train <- feature[index == 1,]
29  test <- feature[index == 2,]
30  return(list(train,test,feature))
31 }

```

図 A-2 : スライディングウィンドウの処理

```

ChangePoint<-function(dt,w,m,k,L ){
  dt<-as.numeric(dt)
  Tt <- length(dt)
  score <- rep(0,Tt)
  for(t in (w+k):(Tt-L+1)){
    tstart <- t-w-k+1
    tend <- t-1
    X1 <- t(embed(dt[tstart:tend],w))
    X1 <- X1[w:1,]

    tstart <- t-w-k+1+L
    tend <- t-1+L

    X2 <- t(embed(dt[tstart:tend],w))
    X2 <- X2[w:1,]

    U1 <- svd(X1)$u[,1:m]
    U2 <- svd(X2)$u[,1:m]
    sig1 <- svd(t(U1)%*%U2)$d[1]
    score[t] <- 1-sig1^2
  }
  return (score)
}

```

図 A-3 : 変化度の算出