

マイクロ波センサを用いた異常状態検知手法

鄭希^{†1} 沼尾雅之^{†1}

概要: 本論文では、非接触式マイクロ波センサを用いて得たバイタルデータから状態認識をすることによって、転倒、認知症や脳卒中など、高齢者に特有の異常を検知する手法について説明する。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。状態認識モデルとは、心拍、呼吸と体動情報を用い、分類アルゴリズムで状態を認識することである。変動検知モデルとは、特異スペクトルで体動波形の変化を定量化するものである。最後に、2つのモデルを評価し、結果を得られた。この結果により、提案手法は異常検知分野に応用されることが期待できると考えられる。

キーワード: 異常検知, 機械学習, 状態認識, 特異スペクトル

abnormality detection method for elderly people by microwave sensors

XI ZHENG ^{†1} MASAYUKI NUMAO ^{†1}

Abstract: In this paper, we propose a method to detect abnormalities for the old people, such as falling, dementia, and cerebrovascular disease by recognizing the state from the vital data using the noncontact microwave sensor. This method includes two models, state recognition model and variation detection model. The state recognition model is to recognize the state by classification algorithm using heartbeat, respiration and body motion information. The variation detection model quantifies the intensification of body movement by specific spectrum. Finally, we evaluated the two models and get the result. Based on this result, it can be expected that the proposed method can be applied to the abnormality detection field.

Keywords: Abnormality detection, Machine learning, State recognition, Specific spectrum

1. 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 27 年度総務省[1]の統計より、日本の高齢者人口は 3,384 万人、総人口に占める割合は 26.7%と、共に過去最高 80 歳以上人口が初めて 1,000 万人を超える。

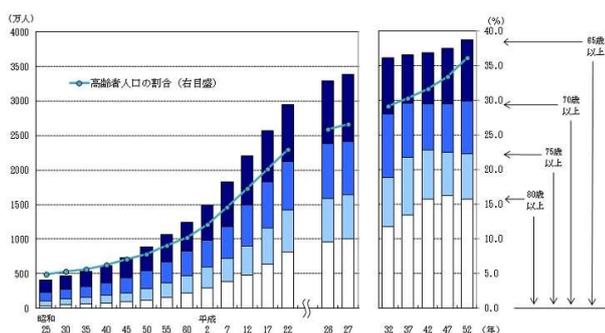


図 1: 日本の高齢者人口及び割合の推移[1]

日本に限らず、14 億人口数の中国も同じ問題を抱えている。中国産業新聞[2]によると、中国に 60 才以上の高齢者人口数は 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 億人がある。

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り。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、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。

1.2 本論文の目的

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。

本稿では、異常検知手法と行動認識手法について先行研

^{†1} 電気通信大学
The University of Electro-Communications.

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、状態間の変化点を用い、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。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。

2. 関連研究

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な状態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、全方位視覚センサを用い、非日常行動の自動的に検出するシステムを提案した。

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築した。3つのシステムにより、あまり高くない緊急度の異常状態検知手法を提案した。

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に定義した。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。

異常検知については、主に2つの種類がある。1つは学習にされていないクラスを異常として検知し、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つは特定な行動を異常として検知し、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[9]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、FFT係数、相関係数)を抽出し、動作の認識手法を提案した。

Raviら[10]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[11]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[12]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。

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。

教師あり学習が特定な行動の検知に応用されているが、教師なし学習が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。

3. 高齢者の健康管理

3.1 高齢者の生活環境

内閣府の平成28年度版高齢社会白書[13]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。そして、老人ホームを参考に、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2のように設置した。

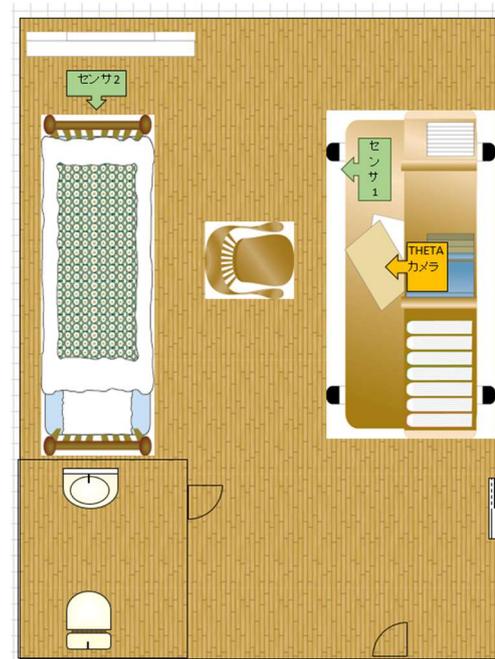


図2: 実験環境

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[13]により、孤立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2,869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。

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」[14]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1)とする。

表1: 認識する高齢者の日常状態

| 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[15]より、高齢者の要介護度を表2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。

表2: 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 | 第4位 | 第5位 | 第6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 | |

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、口の動きの異常(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。

4. 異常検知の手法

4.1 異常の定義

本稿では3.3節で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. 急な状態間の変化
- 異常2. 認知症に対する特定な状態パターン
- 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については、衰弱した高齢者は、普通の行動に限らず、動作が緩慢であると考えられる。よって、いきなり状態が変化すると、転倒など異常が発生したことがわかり、介護者に通知できる。

異常2については、認知症が発生した時、認知症の特定なパターンを検知して、早く介護者に通報できる。更に、異常2については、3.3節で紹介した認知症の症状により、以下の3つのパターンに分類する

- パターン1. 深夜2時~4時に移動状態
- パターン2. 深夜3時まで寝ていない
- パターン3. 食事継続時間3時間以上

パターン1では、家の中の徘徊として検知する。パターン2では、不眠や睡眠障害として検知する。パターン3では摂食障害として検知する。

異常3については、脳血管疾患により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は、高齢は徐々に衰弱する。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。

上記の異常を検知するために、本研究では異常検知手法には2つのモデル、変動検知モデルと状態認識モデル、を適用している。異常検知手法

上記の異常の検知を目標として、本論文の異常検知手法には2つのモデル(変動検知モデル・状態認識モデル)を含めている。

本稿では4.3と4.4章で紹介したモデルで異常検知手法を提案する。具体的処理流れを図3に示す。

急な状態変化の検知手法では、状態を認識上に、状態遷移時間が閾値 r より低いなら、異常を検出する。

認知症に対する特定な状態の手順に組み込んでいるのは、認識した状態からの状態パターンと定義した不合理な状態パターンと一致なら、異常として検知する。

意識不明とは、心拍、呼吸が正常より低いと体動の標準偏差が低いことである。高齢者の心拍数の範囲が 60~80、成人の呼吸数の範囲が 14~20 である。心拍、呼吸が上記の範囲以下なら、異常として検知する。

日常行動が徐々に緩くなるとは、各状態遷移時の変化度を記録し、1 週間に変化度の低下が続いていると、異常として検知する。

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、状態遷移時間が閾値 r より低いなら、異常として検出する。

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

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。

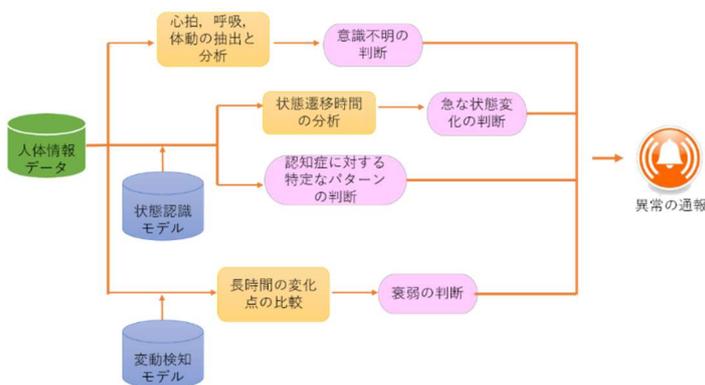


図 3: 提案手法の流れ

4.3 生活状態の検出

生活状態の検出では、状態認識モデルを用いた、表 1 に示した状態の検知である。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。本論文では複数クラスを分類するため、ランダムフォレストという分類アルゴリズムを利用した。

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 ランダムフォレスト

ランダムフォレストとは、図 4 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。

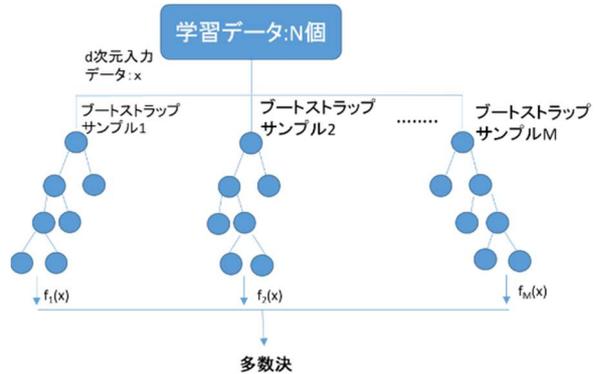


図 4: ランダムフォレスト

ランダムフォレストは多数決により多クラス問題に自然拡張することができる。更に、ランダムサンプリングされトレーニングデータと特徴を用い、多くの決定木を作るという手法により、ランダムフォレストでは過剰適合現象(汎化能力が低い)を抑えることができる。従って、本稿ではランダムフォレストを利用する。

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[15]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。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 を以下の式によ

に構成する。\$X_1\$は過去行列と呼ぶ。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」というのは、ベクトルのイメージで言えば最も人気のある方向のことである。即ち、各ベクトルが似たような方向を向いて強め合った結果。したがって、最適な1次結合を求め問題は

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

となる。従って、次のことが分かった。

1. \$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。
2. \$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。

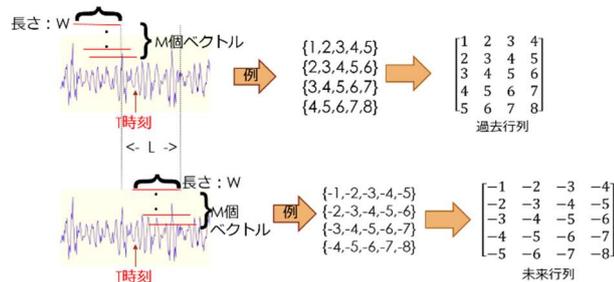


図 5 : 過去行列と未来行列

本稿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

時刻 \$t\$ において過去と現在側の特徴パターンが求まるとすれば、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。

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

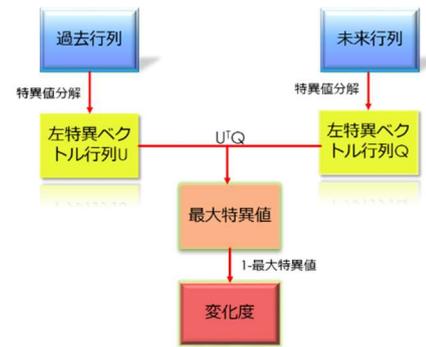


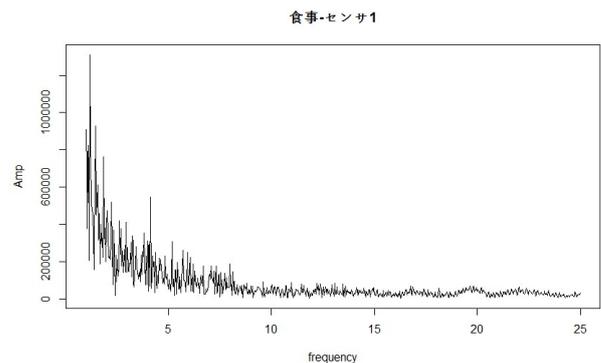
図 6: 変化度の定義

5. 実験と評価

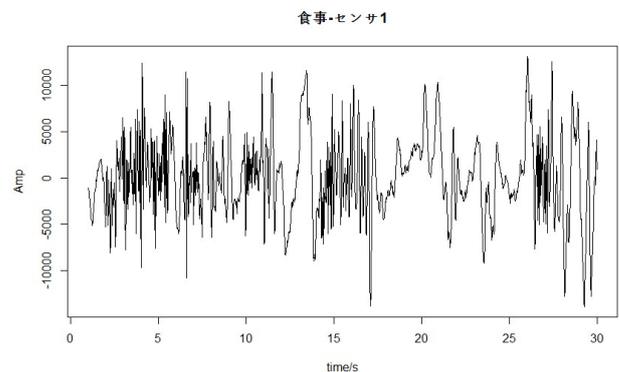
5.1 状態認識モデル実験

5.1.1 特徴値の抽出

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 7a はセンサ 1 の食事の体動波形グラフであり、図 7b は図 7a のデータを高速フーリエ変換したものである。



a: センサ 1 の食事 FFT



b: センサ 1 の食事波形データ

図 7 : 波形データ

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 従って、次の 3 種類

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)

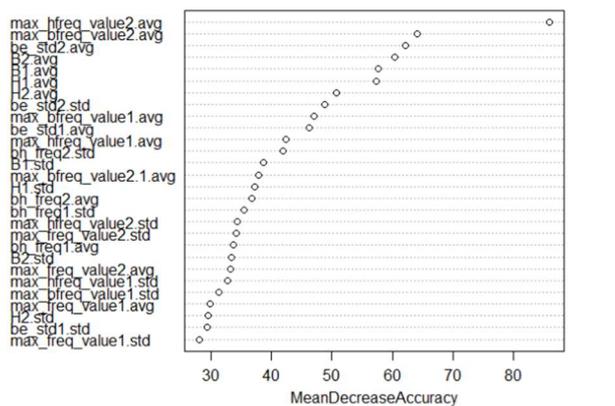
最大 FFT 係数に対応する周波数(心拍・呼吸・体動)

波形標準偏差(体動)

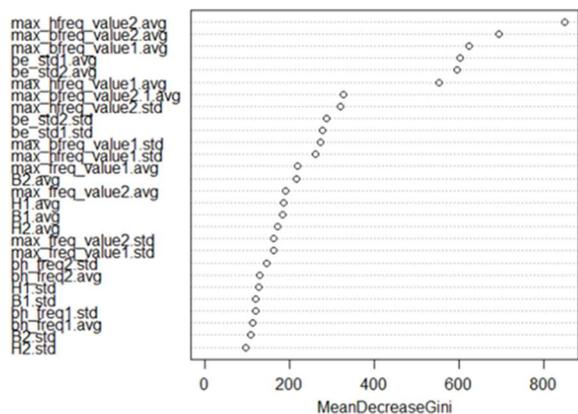
そして、これらの特徴を 4.3.1 節で述べたスライディングウィンドウで処理し、それらの平均値と標準偏差から 14 個の特徴値が得られた。

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 8 に示す。



a: MeanDecreaseAccuracy



b: MeanDecreaseGini

図 8: 特徴量の 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、本稿では上記 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

4.3.2 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 つの重要なパラメータがある。本稿では 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 9 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 9 から時間など要素を総合的に考え、決定木の数 を 500 とした。

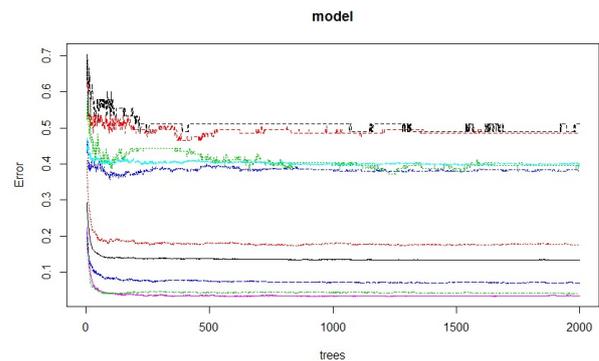


図 9: 決定木数による誤り率の変化

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 9 から時間など要素を総合的に考え、決定木の数 を 500 とした。

5.1.3 窓幅によるモデルの比較

3.3 節に認識したい 9 種類のデータの特徴値を算出し、5.1.2 節のパラメータを決めたランダムフォレストを利用し、OOB を求め。

Case1: 窓幅 w=20/秒, ずれ幅 shift=10/秒

Case2: 窓幅 w=60/秒, ずれ幅 shift=30/秒

2 つのモデル認識結果を表 3 に示す。

表 3: 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 |

Case1 の正確率: 74.5%

Case2 の正確率: 66.5%

結果 1 と結果 2 を比べて、窓幅が小さい方の正確率が高くなるのが分かった。

5.1.4 4 種類ケースの実験結果

Ravi らの研究を参考し、以下の 4 種類の状況

- 1 人の複数日のデータを混ざって、oob-error を計算する。
- 2 人の複数日のデータを混ざって、oob-error を計算する。
- 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。
- 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。

を実験した。

状況 1: 86.44%

状況 2: 88.64%

状況 3: 41.63%

状況 4: 17.70%

5.1.5 状態認識モデルの考察

状態認識モデルの実験結果により、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 各状態間の変化度

4.3 章に提案した変動検知モデルでは様々なパラメータがある。高齢者行動の速さにより、データの長さ(W)=60 秒、ズレ長さ(L)=120 秒、パターン数(M)=3、ベクトルの数(K)=3 とする。

m と k が 3 の時、スコアが 0 から 1 の変化度を得た。よって、m と k を 3 にする。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、(変化度)>=(平均値)+(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、(状態変化抽出率)=
$$\frac{\text{(正しい抽出した変換点数)}}{\text{(全て抽出した変化点数)}}$$
を算出する。これより、w = 60 秒、L = 60 秒、m = 3、k = 3 と決定した。

本稿では、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。

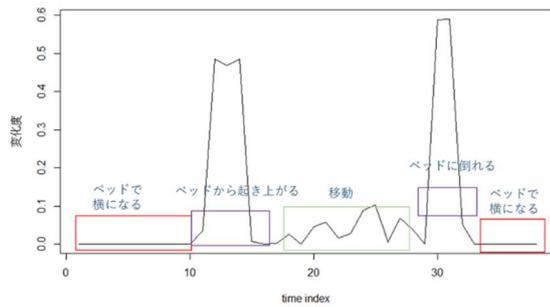
ベッドで横になる->ベッドから起き上がる->移動->ベッドに倒れる->ベッドで横になる。

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。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、左腰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。正常状態間の変化度とボトルを掛けている状態間の変化度を以下の図 10 に示す。

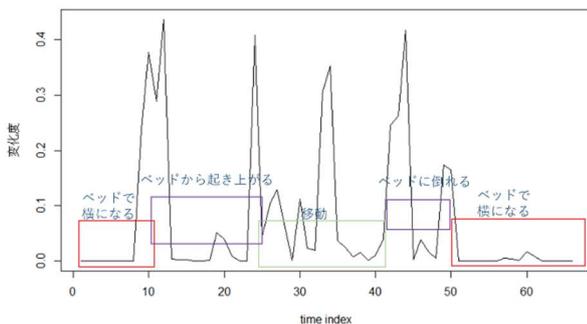
状態間の変化度とは、状態変化の間での最も高い変化度である。衰弱予測の具体的な手順は、毎日の変化度を求め、各状態間の平均変化度のみを抽出し、各センサの各状態間の平均変化度の平均を記録する。具体例として、本実験の各センサの各状態間の平均変化度を表 4 に示す。データは全てデータベースに保存する。そして、各日の状態間の平均変化度の変化を記録し、以下の式で衰弱率を算出する。

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

最後に、衰弱率が 1 週間続く、または 15%低下していたら、衰弱を予測する。



a: 正常状態の変化度



b: 腰にペットボトルを着けている変化度

図 10: 正常行動と腰にペットボトルを着けている変化度

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

5.2.2 変動検知モデルの評価

図 10 により、腰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筋力衰弱予測の有効性があると考えられる。

筋力の衰弱による行動の変化は、筋力がある正常状態と違って、一気に変わることはない。変化度のピークは筋力の衰弱の方が多い。この変化特徴を用い、より良い状態認識ができる可能性があると考えられる。

6. まとめ

本稿では、非接触型のマイクロセンサを用い、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。

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上、異常を検知することである。3.2 節の 9 種類の状態を認識した。そして、表 3a の結果を見ると、状態認識正確率は 74.5%である。異常 3 の検知はマイクロセンサの機能で呼吸数と心拍数を正常範囲内の判断である。異常 4 の検知手法は変動検知モデルを用い、状態間の変化度を抽出し、求めた衰弱率の判断である。更に、変動検知モデルで模擬した筋力の衰弱と正常状態を比べ、衰弱の予測可能性を検証した。

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.htm>
- [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]Bao and Stephen S, "IntilleActivity Recognition from User-Annotated AccelerationnData", Pervasive, volume3001ofLectureNotesinComputer Science, page1-17. Springer, (2004)
- [10]Nishkam RaviActivity, "recognition from accelerometer data", IAAI'05 Proceedings of the 17th conference on Innovative applications of artificial intelligence - Volume 3Pages 1541-1546
- [11]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ング", [No. 08-4] Proceedings of the 2008 JSME Conference on Robotics and Mechatronics, Nagano, Japan, June 5-7, 2008
- [12]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
- [13]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>
- [14]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/>
- [15]井手剛, "入門機械学習による異常検知"