

## K-24

## 加速度データを用いた行動認識

## Human action recognition using acceleration data

森田 千絵\*  
Chie Morita

佐藤 誠\*  
Makoto Sato

土井 美和子†  
Miwako Doi

## 1 はじめに

計算機とセンサの小型化技術、無線技術の発展により、人体に装着可能(ウェアラブル)なセンサ付き小型計算機が開発されている。ウェアラブルコンピュータにより計測した生体データから装着者の行動を認識する技術は、健康管理や危機管理などさまざまなリアルタイムサービスの基礎となるものである。本研究では、そのようなサービスへの応用に向けて、日常生活で表れる、歩行、走行、等の比較のおおまかな行動を生体データを分析することによって認識することを目的とする。

その最初の段階として、本稿では腕時計型の加速度センサで計測された2次元の時系列データを用いた行動認識について述べる。歩行、走行、起立、デスクワークという4つの行動を対象としてデータ収集と分析を行なった結果、9割以上の精度で認識することができた。この事前処理も重要であり、計測された値をそのまま用いた場合とフーリエ変換による前処理をした場合との結果の違いについても述べる。

## 2 加速度データ

分析の対象とした加速度データについて説明する。




図1: 2軸加速度センサ

図1に示すような腕時計型の2軸加速度センサ [1][2] を用いて、手首の前後方向(x軸と呼ぶ)の加速度と、肘から手に沿った方向(y軸と呼ぶ)の加速度を計測した。計測された加速度データは2次元の時系列として記録され、1点は1/20秒に対応する。この加速度センサは無線通信機能を有しており、計測した加速度値を一定時間ごとにPCやPDA端末などに送信することができる。

図2は、歩行中と走行中における加速度センサの出力波形の例である。横軸は時間(1/20秒単位)、縦軸は加速度の強さを表している。本研究で用いた加速度センサの検出加速度範囲は $\pm 2G$ であり、それを0-1023に正規化した値を縦軸に用いている。実線が図1でのx軸、点線がy軸を示す。




図2: 歩行中(左図)と走行中(右図)の加速度

## 3 予備実験

{歩行、走行、起立、デスクワーク}の4つの行動を認識するにあたり、最終的には個人差や状況による差(例えば歩行時に鞆を持っているかどうかによる差)に対して頑健であることが求められるが、それに先立って一人の被験者による基本的な状況(鞆等を持たずに歩く、など)の行動認識を試みた。

このデータを、データに重複なく固定区間(0.5秒、1.0秒、1.5秒)で区切り、2系列分並べたデータと、それをフーリエ変換してパワースペクトル係数を特徴量としたデータを用意した。これを、クラスタリングとニューラルネットワークそれぞれで分析した。

**クラスタリング** 反復k-means法を適用した。反復k-means法は、初期クラスタを変えてk-means法を複数回繰り返し、WGSS(the within group sum of squared errors)と呼ばれる評価値の最も小さなクラスタ構造を採用することで、k-means法のもつ局所探索性という欠点を緩和したアルゴリズムである。

クラスタ数が5の場合と10の場合で実験したところ、5クラスタの場合は歩行と起立が同じクラスタに含まれるなど、4つの行動を分離しきれなかったことがあった。10クラスタでは100%区別できるが、理想的なクラスタ数(=4)よりも多い。これははずれ値のような少数のデータもカバーしようとするために、より多くのクラスタを必要としていると考えられる。

**ニューラルネットワーク** 3層のニューラルネットワークを用いて、誤差逆伝播法によって学習させた。入力素子には、計測された加速度データやパワースペクトル係数などの属性変数を、出力素子には4つの行動の一つずつに対応させた。中間素子数については、少なくとも2としてニューラルネットワークの学習が終了しない場合に増やすこととし、荷重値の初期値を変えて10通り学習することとした。

中間素子数は2~3で学習は収束し、行動認識の精度も10通りの平均で95%と高精度であった。

**前処理による違い** いずれの手法においても元のデータのまま利用するよりも、パワースペクトル係数を特徴量とし

\* (株) 東芝 研究開発センターコンピュータ・ネットワークラボラトリー

† (株) 東芝 研究開発センターマルチメディアラボラトリー 研究主幹

た方が高精度に分類することができた。

時系列データを区切る区間については、1.0 秒毎が最も良い結果となった。長めに区切れば一つの事例に含まれる情報は多くなるが、モデル構築にかかる計算量の増加、サンプル数の減少などの問題が発生する。今回の実験では、1.0 秒程度で区切るのが適当と思われる。

1.0 秒毎に時系列データを区切り、パワースペクトル係数を用いた場合にはいずれの手法でも 95%以上の精度で認識できた。

#### 4 実験

広範囲の応用を考えると、個人差や状況の多様性による差に対して頑健な手法が必要である。個人差、性別、年齢などによって加速度データに本質的な差があるのか、状況差（荷物を持って歩いている場合とそうでない場合の差）があるのかを見極めなければならない。そこでつぎに、複数の被験者に対して日常生活の多様性を考慮した状況での加速度データを収集し、予備実験で得られた知見に基づいて行動認識を試みた。

##### 4.1 加速度データの収集

被験者は、左利き、右利きの両方を含む 6 人（男性 5 人、女性 1 人）で、年齢は 20～40 代であった。加速度センサは左手首に装着し、状況の多様性を考慮してつぎのような状況を含めた加速度データを収集した。

- 歩行：平地、階段、手に鞆を持っている、手にファイルを持っている、という状況。平地の歩行に関しては、それぞれ加速度計を装着した側の手と反対側の手に荷物を持っている時。
- 走行：鞆を装着側と反対側に持っている状況。
- 起立：鞆を装着側と反対側に持っている状況。
- デスクワーク：{PC 作業、書類を読む、書類を書く、自由行動}という状況。

前処理として、予備実験と同様にデータに重複なく 1.0 秒ごとに区切る。予備実験では区切る区間を変えて試したが、1.0 秒で区切るのがよいことがわかったので今回はそれを採用する。その結果、事例数は 7803 となった。このうち、約 7 割を学習（モデル構築）用に、残りの約 3 割をテスト用に分割し、テスト用データは学習には使わず評価に使う。また、予備実験でフーリエ変換のパワースペクトル係数が有効であることがわかったので今回もそれを適用する。

##### 4.2 クラスタリングによる分析

予備実験と同様の分析を行なったが、クラスタ数を 20 まで増やしても 100%正しくは分類できなかった。個人差、状況差による影響に敏感であると思われる。

##### 4.3 ニューラルネットワークによる分析

荷重値の初期値をランダムに変更して 10 回ずつ学習させた。全体に、ニューラルネットワークの学習精度は予備実験の際の学習精度よりも悪く、出力素子ごとの平均距離誤差は 0.02、最大では 0.43 に達した。学習の反復回数を重ねたり中間素子数を増やしても学習精度の向上は見られなかった。

しかし、学習精度が悪くてもクラスの認識精度は高く、特にフーリエ変換のパワースペクトル係数を用いた場合は認識精度は 9 割を超えた。一方、元のデータをそのまま用いた場合の精度は、平均では 86%程度を達成しているが、クラスごとのばらつきが高く、例えば「走行」を正しく認識したのは

77%であった。フーリエ変換を行なわない場合は、走行を歩行と間違えた例や、歩行を起立と間違えた例が特に多く見られた。

##### 4.4 回帰木による分析

CART 型の 2 進分類木 [3] によって認識モデルを構築した。ニューラルネットワークに比べると、どの属性変数が行動認識に影響を与えているのかをユーザが知ることができるという利点がある。ノード分割の尺度には Gini 統計量 [3] を用いた。

その結果、元のデータをそのまま属性変数として用いた場合は認識精度は平均で 77%、パワースペクトル係数を用いた場合は 96%と、ニューラルネットワークと同様にパワースペクトル係数が有効であった。

また、前述のように、回帰木では強い影響を持つ属性変数をユーザが知ることができるのが利点の一つである。パワースペクトル係数を用いて生成した回帰木によると、今回の実験において最も影響が強い属性変数は、y 軸の平均値であった。y 軸は肘から手に沿った方向の加速度を示している（図 1）。これは立っている時と座っている時とで異なる値を示す、すなわち、これによってまずデスクワークとそれ以外が分類されることが考えられる。その他、回帰木全体において y 軸に関わるパワースペクトル係数が多く用いられることがわかった。

#### 5 おわりに

加速度データを用いて行動を認識する実験について述べた。歩行、走行、起立、デスクワーク、の 4 つの行動に関して複数の被験者から加速度データを収集し、クラスタリング、ニューラルネットワーク、回帰木によって 9 割以上の精度で認識することができた。被験者による違いや荷物を持って歩くなどの多様性に対しても、ニューラルネットワークや回帰木では適切に処理できることが確認された。また、いずれの手法に対しても計測された値をそのまま用いるよりも前処理としてフーリエ変換を行ないパワースペクトル係数を用いる方が高精度に認識できることがわかった。

今回得られた知見に基づき、今後はより自然な状態である連続動作での行動認識を目指す。また、脈拍や皮膚温等の加速度データ以外のデータも含めた行動認識、特に健康管理や在宅医療等への応用のために食事の開始と終了の認識に着目した分析を行なっていく。

#### 謝辞

本研究の一部は文部科学省の平成 14 年度科学技術振興調整費「人間支援のための分散リアルタイムネットワーク基盤技術の研究」の一環として行われた。

#### 参考文献

- [1] 鈴木 琢治, 大内 一成, 土井 美和子: LifeMinder: ウェアラブル健康管理システム, 電子情報通信学会技術研究報告 ヒューマン情報処理, Vol.101, No.699, pp.33-38 (2002).
- [2] Ouchi, K., Suzuki, T. and Doi, M.: LifeMinder: A Wearable Healthcare Support System Using User's Context, *Proc. of ICDCS2002 Workshops (IW-SAWC2002)*, pp.791-792 (2002).
- [3] Breiman, L., Friedman, J. H., Olshen, R. A. and Stone, C. J.: *Classification and Regression Trees*, Wadsworth Int. Group, Belmont, California, USA (1984).