



センサのピーク値を用いた状況認識手法

村尾, 和哉
ファンラルホーフェン, クリストフ
寺田, 努
西尾, 章治郎

(Citation)

情報処理学会論文誌, 51(3):1068-1077

(Issue Date)

2010-03-15

(Resource Type)

journal article

(Version)

Version of Record

(URL)

<https://hdl.handle.net/20.500.14094/90002102>



センサのピーク値を用いた状況認識手法

村 尾 和 哉^{†1} クリストフ ファン ラールホーフェン^{†2}
寺 田 努^{†3} 西尾 章治郎^{†1}

ウェアラブルコンピューティング環境では小型の装着型センサを用いて取得した行動や状況（コンテキスト）を利用するさまざまなアプリケーションが提案されている。装着者のコンテキストを取得する際に、センサの値に対して特徴量抽出と呼ばれる前処理が行われる。この特徴量抽出ではこれまで、判別性能の高さから平均や分散、FFT係数などが多くの研究で採用されてきたが、これらはデータサイズが元のデータよりも大きくなるため、センサは生データの状態でコンピュータに送信し、その後特徴量抽出と認識が行われる。しかし、生データの通信やセンサ内のメモリへの書き込みによって消費する電力は大きく、低消費電力ハードウェアにとって負担となるものであった。本論文では、従来の特徴量と同等の性能を示しつつデータサイズは小さい新たな特徴量として、加速度波形のピークの高さと幅を提案する。提案する特徴量を用いることでセンサ内で特徴量変換を行いデータサイズを削減したうえでメインコンピュータに送信するため、消費電力の削減につながる。

A Method for Context Recognition Using Peak Values of Sensors

KAZUYA MURAO,^{†1} KRISTOF VAN LAERHOVEN,^{†2}
TSUTOMU TERADA^{†3} and SHOJIRO NISHIO^{†1}

In wearable computing environments, various applications are assumed to get a richer sense of context via a set of wearable sensors. When obtaining the wearer's context, raw sensor values typically have to be pre-processed before recognition can take place. This process of feature-extraction in wearable sensing has thus far favored combinations of mean, variance, and Fourier coefficients over a sliding window as highly-discriminative features and have been used extensively so far in the literature. Since the size of the features tends to become larger than that of the raw data itself, sensors send raw data to a main computer, then feature-extraction and recognition take place. However, raw data consume large power for wireless communication and writing to their memories, conflicting with the often low-power hardware in wearable comput-

ing. In this research, we suggest width and height of peaks as features that perform in the range of conventional features but that have smaller data size. By using our proposal, sensors shrink data and send these to the main computer after feature-extraction, which would conserve power.

1. はじめに

近年、マイクロエレクトロニクス技術の発展によるコンピュータの小型化や軽量化により、コンピュータを常時身に着けて生活するウェアラブルコンピューティングに注目が集まっている。さまざまなセンサやコンピュータを身に着けるウェアラブルコンピューティングは、従来のコンピュータの利用形態と比較して次の3つの特徴を持つ¹⁾。(1) ハンズフリー：コンピュータを身体に装着しているため、両手を使用せずに情報を参照できる。(2) 常時電源ON：コンピュータはつねに電源が入っており、使いたいときにすぐに使える。(3) 個人適応：センサなどの利用によりユーザの詳細情報を得て、きめ細かなサービスが提供できる。ウェアラブルコンピューティングの発展にともない、加速度センサやジャイロセンサ、筋電計²⁾や心電計³⁾、GSR (Galvanic Skin Reflex：皮膚電気反射)⁴⁾といったさまざまなセンサを用いてユーザの行動や状況（コンテキスト）を認識し、コンテキストに依存した適切なサービスを提供するシステム（コンテキストウェアシステム）が提案されている。

例として、LifeMinder⁴⁾は日常生活での行動を温度センサ、GSR センサ、加速度センサ、光電脈波センサ、地磁気センサ、ジャイロセンサを用いて認識し、生活習慣の改善などのアドバイスをを行う。具体的には、腕時計型センサを用いて装着者の行動（食事、歩行、仕事など）を認識し、運動不足や過労を警告する。看護師の行動認識システム⁵⁾は、加速度センサと赤外線ID受信器を用いることで、位置情報や手の動きから点滴や車椅子の補助といった看護師の行動を認識・記録する。

また、ウェアラブルセンサの省電力化についてはこれまでに Groggy Wakeup⁶⁾をはじめとするフレームワークや Porcupine⁷⁾などのセンサデバイスが提案されており、それらはセンシングデータに応じてセンサの構成や電力消費モードを変更する機能を持つ。これら

^{†1} 大阪大学大学院情報科学研究科

Graduate School of Information Science and Technology, Osaka University

^{†2} ダルムシュタット工科大学

Department of Computer Science, Darmstadt University of Technology, Germany

^{†3} 神戸大学大学院工学研究科

Graduate School of Engineering, Kobe University

の先行研究は、センシングデータを処理するアルゴリズムをセンサ側に近づける、つまりセンサハードウェア内部に組み込むことでコンテキストの認識精度を維持しながら消費電力の大幅な削減を実現している。

センシングデータを用いた認識を行う場合、早く正確な認識を行うために生データから特徴量への変換を行う必要がある。特徴量として、従来までは一定サンプルの平均や分散、フーリエ係数などが用いられており、高い判別性能を持つことが示されている。しかし、生成された特徴量のデータサイズが生データのデータサイズを上回るためストレージや通信のオーバーヘッドを生み出し、低消費電力なハードウェアには大きな負担となるため、通常行動認識システムではセンサが生データをメインコンピュータに送信した後に特徴量計算が行われる。そのため、従来研究では限られた電源容量やメモリしか持たないマイクロコントローラを基盤とするウェアラブルデバイス上で特徴量計算を行う場合のコストについては考慮されていなかった。

そこで、本論文では従来の特徴量と比較して判別性能は同等かつデータ量を大幅に削減できる新たな特徴量として、加速度波形のピークの幅と高さの利用を提案する。提案する特徴量を用いることでセンサ内部で特徴量計算を行い、生データよりもデータサイズを削減してメインコンピュータに送信するため、消費電力の削減につながる。

以下、2章では想定環境について述べ、3章では従来のコンテキストウェアシステムで用いられる特徴量および提案する特徴量について述べる。その後、4章で評価を行い、5章で本論文をまとめる。

2. 想定環境

本論文では腕、腰、足に加速度センサを装着し、装着者のコンテキストを取得する環境を想定する。この装着者のコンテキストを認識（ウェア）するシステム、あるいはコンテキストに応じたサービスを行うシステムをコンテキストウェアシステムと呼ぶ。コンテキストウェアシステムにおける処理の流れを図1に示す。コンテキストウェアシステムでは、はじめにセンサから取得した生データを特徴量に変換する。その後、認識器は特徴量を用いて装着者のコンテキストを推測する。ここで、複数のセンサのデータを統合する必要があり、かつセンサデバイスの処理能力は高くないため、認識器は個々のセンサではなくメインコンピュータが保持することが一般的である。

ここで、コンテキストウェアシステムの利用環境として以下の2種類が想定される。1つ目は取得したセンシングデータをセンサ自身が保持し、後から解析を行う環境である。こ




図1 コンテキストウェアシステム

Fig.1 A common structure of context awareness system.




図2 本論文で使用するセンサ：Porcupine

Fig.2 A sensor used in this paper: Porcupine.

のような環境の例として、活動中の装着者のセンシングデータを蓄積しておき、後からデータを解析する運動支援システム^{8),9)}などがある。最近の健康への意識の高まりから生体センサを装着する機会が増えているが、PCとともに常時用いることは現実的ではなく、将来センサデバイスのみで長時間の状況を取得可能になればコンテキストウェアシステムの普及につながると考える。2つ目は取得したセンシングデータをセンサは保持せず、逐次無線経由でメインコンピュータに渡して蓄積および処理する環境である。このような環境の例として作業者をサポートするシステム^{5),10)}やユーザの状態に応じた情報提示システム¹¹⁾、健康管理システム⁴⁾などがある。前者の環境ではデータはセンサデバイス上のメモリに蓄積しておく必要があり、ストレージの容量の制約や読み書きのオーバーヘッドの問題が存在する。また、後者の環境ではセンサとメインコンピュータがつねに通信をする必要があるため通信量の問題がある。このようにセンサデバイス上で生データをデータサイズの小さな特徴量に変換しておくことは両者のシステムに対して有効である。

本論文で使用するセンサは図2に示す小型記録プラットフォーム Porcupine⁷⁾に搭載された3軸加速度センサ（ADXL 330）である。Porcupineは内部のマイクロコントローラに

専用の OS が搭載されておりセンシングデータの収集やコンピュータからのコマンドへの応答などを行う。バッテリーは小型の 2 次電池を採用しておりサンプリング周波数 150 Hz において加速度データを採取した場合約 2 日間連続稼働する。また、mini USB ポートを搭載し、バッテリーの充電と同時にセンサの設定および蓄積したセンシングデータの読み出しを行うことができる。さらに、動作確認用 LED、タグ付け用ボタンが搭載されている。Porcupine には加速度センサのほかに 9 軸のバイナリ傾きセンサ、照度センサが搭載されているが、本論文では使用しない。本論文ではセンサのサンプリング周期を 150 Hz とし、採取したデータは特徴量に変換されたのちにセンサ上の micro SD カードに記録される。

3. 特徴量

本章では従来のコンテキストウェアシステムで用いられている特徴量および本論文で提案する加速度波形のピークを用いた特徴量について述べる。

3.1 平均値

平均値はコンテキストウェアの分野で最も用いられている特徴量の 1 つである。平均値は現在から一定時間遡った時点まで（ウィンドウ）のセンシングデータの平均から求める。「座る」や「寝る」などの静止した状態において、平均値は動きに関する情報は持たないため高い判別性能を示す。

3.2 分散値

分散値は平均値と併用して用いられる特徴量である。平均値同様に一定ウィンドウ内の分散を計算することで得られる。加速度データにおいて、分散はどれだけ激しく動いているかを表現し、「立つ」や「歩く」、「走る」などの平均的な体の位置は同じであるが動きの大きさが異なるコンテキストに対して高い判別性能を示す。

3.3 最大値および最小値

最大値および最小値は一定ウィンドウ内の最大および最小である。加速度データにおいてこれらは「軽く触れる」や「ドンと叩く」「ノックする」といった衝撃の大きさを効果的に抽出する。

3.4 FFT のパワースペクトル

これまでに紹介した特徴量に加えて、フーリエ係数も用いられることが多い。フーリエ係数は計算機上では高速フーリエ変換 (FFT) を用いて求められ、そのスペクトルの最大値などが特徴量として用いられるが、FFT は前述の特徴量と比較して計算量が多くなる。本論文ではセンサがメモリを搭載しており特徴量への変換および記録あるいは生データの記

録をマイクロコントローラ上で行う。しかし、マイクロコントローラの処理能力および消費電力の観点から FFT は困難であると考えられるため、本論文では取り扱わない。

3.5 ピーク値

ピーク値はセンサ信号に見られる基本的な情報であり、観測値と移動平均との交点で挟まれた領域内の極値の持つ値である。加速度波形において、姿勢や動きによって波形のピークの形状に違いがあるため判別性能が高く、同じ行動を行った場合に類似の波形が繰り返し出現しているため再現性も高いと考えられる。そこで本論文では、ピークの幅と高さを用いた新たな特徴量を提案する。ピーク抽出アルゴリズムを図 3 に示す。センサは現在時刻 t から過去 Δt 秒間（ウィンドウ）のセンシングデータの平均 $m(t)$ を計算する。ここで、Epsilon tube と呼ばれる領域を $m(t) \pm \varepsilon$ に設け、1 度波形が Epsilon tube 外に出てから再び Epsilon tube 内に戻るまでの波形をピークとして検出する。加速度波形が Epsilon tube 内で変動している間はピークは検出しないため、Epsilon tube を設けることでノイズなどによる微小なピーク検出を防ぐことができる。センサが 1 つのピークを検出すると、そのピークの情報（幅、高さ、平均 $m(t)$ 、発生時刻 t ）をメインコンピュータに送信する。メインコンピュータでは受信したピークを発生時刻をもとに情報を時系列上に並べる。ただし、メインコンピュータはピークの情報しか受信しないため、復元した時系列データはセンサが




図 3 ピーク抽出手法
Fig. 3 Method to extract peaks.




図 4 ピーク情報からの特徴量抽出手法

Fig. 4 Method to extract features from peak information.

取得している滑らかな加速度波形ではなく矩形となる。このように提案手法ではピークの情報のみを送信するため、センシングしたすべての生データを送信する場合と比較してデータ量を削減できると考える。

次に、受信したピーク情報から認識に用いる特徴量の抽出方法を述べる。図 4 に受信したピーク情報からの特徴量抽出方法を示す。1 つの繰り返し行動に存在する加速度波形のピークは動作開始時の動作、主要な動作、動作終了時の動作からなる。主要な動作にその行動の情報が最も多く含まれており、その前後の部分は開始前の動作および終了後の動作に関する情報が含まれているためノイズが多い。そこで、主要な動作はある一定時間内の最も大きな動作であることに着目し、ウィンドウにおける最大のピークを第 1 ピークとした連続 5 ピークを抽出することで開始前および終了後の動作を除いた。

本論文ではピークの幅と高さに加えて、ピークの形状が認識に有効かを確かめるためにピークの勾配も特徴量候補として採用した。勾配はピークの頂上周辺の変化量で、頂上を含む 3 点（頂上 t および $t \pm 2$ の 2 点）を用いて、次式で定義する。

$$\text{Gradient}(t) = |x_t - x_{t-2}| + |x_t - x_{t+2}|$$

上記の特徴量に加えて、ピークの加速度値の分布形状の尖度および歪度を特徴量として追加することを試みたが、予備実験の結果より上記の特徴量と比較して判別性能が大幅に低く、特徴量として適さないことを確認している。

装着者が静止していたり、ウィンドウ内の最大のピーク（第 1 ピーク）がウィンドウの終わりに出現したりすると、抽出されるピーク数が 5 個に満たない場合がある。その場合は欠損したピークの幅、高さ、Gradient を 0 として扱う。ウィンドウ内に 1 つもピークが存在しない場合はすべてのピーク特徴量を 0 として扱う。

4. 評価

4.1 解析手法

本節では特徴量の判別性能を評価するための 2 つの手法について述べる。一方はクラスタリングの精度を評価する手法であり、純粋にデータの距離によって分類するため認識器に依存しない結果が得られる。もう一方は、実際に認識器を用いて認識した際の精度を評価する手法である。

4.1.1 クラスタリング精度

クラスタリングはあるデータセット内のデータを距離の近いものどうしでグループ化することでデータ構造を明らかにする手法である。Cluster precision¹²⁾ はデータの属するクラスおよびクラス内に属するデータの割合からデータセットの判別性能を測る手法である。Cluster precision を用いることでクラスタリング後のデータの分散度の観点から特徴量を順位付けできる。本論文ではクラスタリング手法として文献 12) で採用されている k-means を用いた。

完全な判別性能を有する場合、1 つのクラスに属するデータはすべて同じコンテキストのものとなる。これは特徴量を各コンテキストごとに完全に分離可能で認識器の入力として適していることを意味する。最悪の場合、それぞれのクラスに属するデータの各コンテキストのラベルの割合がデータ全体に対する各コンテキストのラベルのデータの割合（事前確率）と一致する。これは特徴量を各コンテキストごとにまったく分類できておらず認識器の入力として適していないことを意味する。

Cluster precision では、はじめに各クラス i における各コンテキストのラベル j のデータ分布

$$p_{i,j} = \frac{|C_{i,j}|}{\sum_j |C_{i,j}|}$$

を調べる。ここで、 $C_{i,j}$ はクラス i に属するデータのうちコンテキストのラベルが j であるデータの集合である。続いて次式に従いこれらの重み付け和をとることで各コンテキスト j の Cluster precision p_j を得る。

$$p_j = \frac{|\sum_i p_{i,j} C_{i,j}|}{\sum_i |C_{i,j}|}$$

上式において、Cluster precision が 1 に近いコンテキストが属するクラスデータの大部分はそのコンテキストのデータであり、判別性能が高いことを意味する。また、各クラス

のデータサンプル数を重みとして用いることで、小さなクラスタの影響を小さくしている。

4.1.2 サポートベクタマシン

サポートベクタマシン (SVM) は現存する認識器の中で最も性能が良いとされるものの 1 つである¹³⁾。学習データセット $(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_J, y_J)$ を 2 クラスに分類すると想定する。ここで、 $\mathbf{x}_i \in \mathbb{R}^N$ および $y_i \in \{-1, +1\}$ は特徴量ベクトルおよびクラスラベルである。この 2 クラスを超平面 $f(\mathbf{x}_i) = \mathbf{w} \cdot \mathbf{x}_i + b$ で分割可能であると仮定し、データの分散に関して事前知識が得られていないものとする。この 2 クラスを分割する超平面と超平面に最も近いデータとの距離をマージンと呼び、マージンが最大になるときに識別超平面は最適となる。最適超平面の $\mathbf{w}$ および b は次式で表される最小化問題を解くことで得られる。

$$\min \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{subject to } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \forall i = 1, \dots, n$$

上式に対し Lagrange の未定乗数法を用いると次式の識別関数が得られる。

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^n \lambda_i y_i \mathbf{x}_i^T \cdot \mathbf{x} + b \right)$$

ここで、学習データの大部分の Lagrange 未定乗数 λ_i が 0 となり、 $\lambda_i > 0$ となる $\mathbf{x}_i$ のみで識別関数が決定され、このような $\mathbf{x}_i$ をサポートベクトルと呼ぶ。また、分離不可能な場合、Lagrange 未定乗数を $0 \leq \lambda_i \leq C$ ($i = 1, \dots, n$) に修正する。ここで C は誤識別に対するペナルティである。この処理をソフトマージンと呼び、SVM の性能が良い理由の 1 つである。

非線形識別および線形識別 ($C=5000, 10000, 50000, 100000, 500000$) におけるいくつかの方式を実装し予備実験を行ったところ、 $C=50000$ の線形 SVM が最も良い性能を示したため評価は線形 SVM で行った。本来 SVM は 2 クラス分類器であるが、1 クラスとそれ以外のクラスを認識する SVM をすべてのクラスに対して構築することで N クラスを分類する SVM とした。

4.2 データセット

評価では手首、腰、足首の 3 カ所に 3 軸加速度センサを装着した 1 人の被験者から採取したデータを用い、オフラインで解析した。サンプリング周波数は 150 Hz である。採取したコンテキストは歩く、ゆっくり歩く、自転車を押しながら歩く、階段を昇る、エレベータで昇る、立つ、バスの中で立つ、バスの中で座る、座る、座って食事をする、座って仕事をする、走る、膝立ち、階段を降りる、エレベータで降りる、自転車に乗るの 16 種類である。

採取したデータサンプル数は 965,380 で、107 分に相当する。収集したデータには手動でラベル付けした。評価実験で用いる特徴量を以下に示す。

- F1: 平均, 分散

データフォーマットは $[mean_x, var_x, mean_y, var_y, mean_z, var_z]$, ただし $mean_x$ および var_x は x 軸のデータの平均および分散である。

- F2: 平均, 分散, 最大, 最小

データフォーマットは $[mean_x, var_x, max_x, min_x, mean_y, var_y, max_y, min_y, mean_z, var_z, max_z, min_z]$, ただし max_x および min_x は x 軸のデータの最大および最小である。

- F3: ピークの幅, 高さ, 平均

データフォーマットは $[L1_x, H1_x, \dots, L5_x, H5_x, mean1_x, L1_y, H1_y, \dots, L5_y, H5_y, mean1_y, L1_z, H1_z, \dots, L5_z, H5_z, mean1_z]$, ただし $L1_x$ および $H1_x$ は x 軸のデータの第 1 ピークの幅および高さ, $mean1_x$ は x 軸のデータの第 1 ピークの平均である。ただし、F3 の次元数が高いため、主成分分析によって次元数を削減した。主成分分析とは統計手法の 1 つで、複数の変数間の共分散を主成分と呼ばれる少数の合成変数で説明する手法である。 n 種類の変数がある場合、主成分も n 個存在する。第 1 主成分は元のデータの散らばりを最もよく表現し、第 2, 第 3 となるにつれ、持つ情報が小さくなる。元の F3 は各軸に対して 10 個のピーク特徴量と 1 つの平均を持っている。本論文では第 5 主成分までを採用し、次元数削減後のデータフォーマットは $[s1_x, \dots, s5_x, mean1_x, s1_y, \dots, s5_y, mean1_y, s1_z, \dots, s5_z, mean1_z]$ となる。ただし、 $s1_x$ は x 軸のピーク特徴量の第 1 主成分である。また、主成分分析においてリアルタイムアプリケーションではすべてのデータを用いて主成分を計算できないため、あらかじめ採取したデータの一部の分散共分散行列を用いて残りのデータの主成分を計算した。

- F4: ピークの勾配, 平均

データフォーマットは $[G1_x, \dots, G5_x, mean1_x, G1_y, \dots, G5_y, mean1_y, G1_z, \dots, G5_z, mean1_z]$, ただし $G1_x$ は x 軸のデータの第 1 ピークの勾配, $mean1_x$ は x 軸のデータの第 1 ピークの平均である。

各ピーク特徴量 (F3 および F4) に平均を含めているのは、ピークだけでは位置に関する情報を持たないためである。センサから送信されるピーク情報は 1 つのピークに対して 1 つの平均値を含んでいるため、ピーク特徴量の平均値は第 1 ピークの平均値を利用する。ウィンドウ内に 1 つもピークが存在しない場合は直近のピークから現在までピークが発生して

いないため平均値には大きな変化はないと考え、直近のピークの平均値を利用する。また、ピーク特徴量に関して、1軸につきピーク特徴量は5次元である一方、平均は1次元であるため、平均の違いによるデータ間の差異が表れにくくなる。そこで、予備実験の結果から各平均値を5倍することでピークによる影響と平均値による影響を同等にした。

ここで、これらの特徴量はスケールが異なり等価に扱うことができないため、 $\mathbf{Z}(t) = (\mathbf{X}(t) - \mathbf{M})/\mathbf{S}$ に従い標準化し、 N 次元の特徴ベクトル $\mathbf{Z}(t) = \{z_1(t), z_2(t), \dots, z_N(t)\}$ (平均0, 分散1) を得る。ここで $\mathbf{M} = \{m_1, m_2, \dots, m_N\}$ および $\mathbf{S} = \{s_1, s_2, \dots, s_N\}$ は標準化前のデータ $\mathbf{X}(t) = \{x_1(t), x_2(t), \dots, x_N(t)\}$ の各成分の平均および標準偏差であり、 $m_i = \frac{1}{T} \sum_{t=1}^T x_i(t)$ および $s_i^2 = \frac{1}{T} \sum_{t=1}^T \{x_i(t) - m_i\}^2$ で定義される。ただし、リアルタイムアプリケーションでは未来のデータは取得できないため、全データの平均および標準偏差を用いて標準化を行うことは不可能である。本論文では採取したデータの一部の平均および標準偏差を用いて、残りのデータを標準化して評価用データセットとした。予備実験より静止時においてセンサが出力するノイズが50 mG程度であることを確認したため、本論文では $\varepsilon = 100$ [mG] とした。また、ウィンドウの幅 Δt を2秒と設定した。

4.3 クラスタリング精度による判別性能の評価

4.1.1 項で説明した Cluster precision を用いた評価結果について述べる。評価で用いた k-means は予備実験の結果からクラス数を50とした。また、データ全体の10%を用いて残り90%のデータを標準化および主成分分析して評価用データとした。結果を表1に示す。表中の行はコンテキスト、列は特徴量を示す。各特徴量の Cluster precision の平均を比較すると、提案手法である F3 および F4 は従来手法である F1 および F2 と同等の高い値を示しており、ピークの幅と高さおよび勾配は分散と同等の判別性能を示すことが分かる。また、F1 と F2 を比較すると平均や分散を特徴量として用いている場合、最大値と最小値を付加してもほとんど判別性能が向上していないことが分かる。

4.4 SVM による判別性能の評価

Cluster precision と同様に SVM を用いた評価結果について述べる。SVM は Cluster precision と異なり、事前に学習が必要である。本論文では5-fold cross validation で評価した。評価用データの標準化および主成分分析には学習用データを利用した。結果を表2に示す。各特徴量の再現率および適合率は Cluster precision の結果とほぼ同じであり、わずかながら提案手法である F3 および F4 は従来手法の F1 および F2 よりも良い結果が得られた。

表1 Cluster precision の結果

Table 1 Results of cluster precision.

コンテキスト	F1	F2	F3	F4
自転車	0.941	0.941	0.945	0.943
エレベータ下降	0.507	0.482	0.472	0.469
階段下り	0.929	0.943	0.978	0.933
膝立ち	0.974	0.967	0.985	0.973
走る	0.995	1.000	0.997	0.999
座る (バス)	1.000	0.991	0.889	0.994
座る (仕事中)	0.901	0.944	0.923	0.920
座る (食事中)	0.910	0.943	0.958	0.928
座る	0.947	0.936	0.842	0.903
立つ (バス)	1.000	1.000	1.000	0.997
立つ	0.986	0.987	0.982	0.976
エレベータ上昇	0.562	0.537	0.529	0.525
階段昇り	0.930	0.933	0.979	0.926
歩く (自転車を押す)	0.985	0.986	0.977	0.978
歩く (ゆっくり)	0.974	0.967	0.981	0.952
歩く	1.000	1.000	1.000	1.000
平均	0.909	0.910	0.902	0.901

表2 SVM の結果

Table 2 Results of SVM.

コンテキスト	F1		F2		F3		F4	
	再現率	適合率	再現率	適合率	再現率	適合率	再現率	適合率
自転車	0.944	0.996	0.984	0.984	0.999	1.000	0.999	0.997
エレベータ下降	0.451	0.555	0.865	0.543	0.929	0.582	0.970	0.577
階段下り	1.000	0.993	1.000	0.999	1.000	1.000	1.000	1.000
膝立ち	0.986	1.000	0.989	1.000	1.000	1.000	0.987	1.000
走る	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
座る (バス)	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
座る (仕事中)	0.957	0.983	0.960	0.995	1.000	1.000	0.999	1.000
座る (食事中)	0.989	1.000	0.999	1.000	0.997	1.000	1.000	0.999
座る	0.991	1.000	0.991	1.000	1.000	1.000	1.000	1.000
立つ (バス)	1.000	0.981	1.000	1.000	1.000	1.000	1.000	1.000
立つ	1.000	0.958	1.000	0.981	1.000	0.998	1.000	1.000
エレベータ上昇	0.667	0.563	0.270	0.675	0.335	0.821	0.300	0.908
階段昇り	0.993	0.994	0.999	0.998	1.000	1.000	1.000	1.000
歩く (自転車を押す)	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
歩く (ゆっくり)	1.000	0.955	1.000	0.961	0.999	1.000	1.000	1.000
歩く	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
平均	0.936	0.936	0.941	0.946	0.954	0.963	0.953	0.968

表 3 他人のデータを用いた学習における SVM の結果
Table 3 Results of SVM trained with others' data.

学習に利用したデータ	F1	F2	F3	F4
本人 (1 人分) のデータ	0.940	0.945	0.916	0.906
全員 (5 人分) のデータ	0.878	0.893	0.781	0.784
他人 (4 人分) のデータ	0.647	0.629	0.450	0.500

4.5 個人差による判別性能の評価

4.4 節の評価では学習データと評価データは同一人物のものであった。しかし、実際にシステムを配布する場合は事前に他人のデータで作成した共通学習データを用いることで利用者が事前に学習をせずに利用できることが望ましい。本節では SVM による評価において他人のデータを用いて学習した場合の認識精度を評価した。評価では手首、足首、腰の 3 カ所に加速度センサを装着した男性 3 人、女性 2 人の計 5 人の被験者から採取したデータを用いて解析した。サンプリング周波数は 20 Hz である。採取したコンテキストは立つ、座る、膝立ち、歩く、走る、階段を昇る、階段を下りる、自転車に乗るの 8 種類である。本人のデータのみを用いて学習した場合、本人を含む 5 人全員のデータを用いて学習した場合、および本人を除く 4 人のデータを用いて学習した場合の認識精度を表 3 に示す。他人のデータのみを利用した場合は、アプリケーション作成者が一般に配布する際に事前に学習を済ませておき、利用者は学習を行わずにそのまま利用する場合と想定できる。しかし、他人のデータのみではすべての特徴量において認識精度が低下している。一方、利用者本人のみのデータではすべての特徴量において認識精度が大幅に改善されていることが分かる。また被験者全員のデータを用いて学習した場合でも、大幅に精度が改善されているが、本人のデータのみを用いた場合と比較して劣っていることが分かる。これは学習データに他人のデータが含まれると、それがノイズとして働くと考えられるため、利用前に本人のデータを用いて学習する必要がある。ただし、これは提案手法に限らず、従来の特徴量においてもいえることであり、この結果が提案手法の有効性を否定するものではないと考える。

4.6 データサイズの評価

各特徴量をデータサイズの観点から評価する。ただし、4.3 節および 4.4 節の結果から提案するピーク特徴量の中ではピークの幅および高さを用いたものが最高の性能を示していたため、本評価においては提案手法として F3 についてのみ議論する。また、F1 および F2 を利用する際、通信や蓄積される形式は生データであるため、比較手法は生データである。評価環境は 4.2 節と同じである。




図 5 加速度波形とピーク：歩く（上），座る（下）
Fig. 5 Raw data and peaks of walk (upper) and sit (lower).

表 4 10,000 サンプル（約 67 秒）あたりのデータサイズ
Table 4 Data size per 10,000 samples (ca 67 sec.).

	コンテキスト	ピーク数 [個]				データサイズ [バイト]
		手首	腰	足首	計	
生データ	—	—	—	—	—	210,000
F3	自転車	5,949	2,137	3,426	11,512	80,584
	エレベータ下降	13	0	8	21	147
	階段下り	1,265	2,318	3,001	6,584	46,088
	膝立ち	79	46	13	138	966
	走る	1,351	3,272	3,671	8,294	58,058
	座る (バス)	8	0	0	8	56
	座る (仕事中)	73	27	25	125	875
	座る (食事中)	690	167	151	1,008	7,056
	座る	53	37	35	125	875
	立つ (バス)	93	49	321	463	3,241
	立つ	1	3	4	8	56
	エレベータ上昇	16	0	3	19	133
	階段昇り	981	1,584	2,431	4,996	34,972
	歩く (自転車を押す)	5,145	2,021	2,734	9,900	69,300
	歩く (ゆっくり)	275	275	739	1,289	9,023
	歩く	1,145	2,342	3,096	6,583	46,081
	平均	1,071	892	1,229	3,192	22,344.44

まずはじめに、ピーク数によって提案する特徴量のデータサイズが決定するため、加速度波形に現れるピークの数について述べる。加速度波形およびピークを図 5 に示す。図中の上の波形は「歩く」データ、下の波形は「座る」データであり、コンテキストによって出現するピーク数が異なることが分かる。特に静止しているコンテキストでは、加速度波形が Epsilon tube 外に出ず、ピークとして検出されないためピーク数が少ない。また、表 4 に 10,000 サンプルあたりの出現ピーク数を示す。表中のピーク数は 3 軸の合計である。表よ

りコンテキストによって出現ピーク数が大きく異なることが分かる。分散値と同様に行動の激しさとピーク数に相関がある。たとえば、「走る」データは 8,294 個のピークが出現しているのに対し、「歩く」データは 6,583 個のピーク、「ゆっくり歩く」データでは 1,289 個のピーク、「立つ」データでは 8 個のピークが出現しており、これは行動の激しさと一致する。

データサイズの列は生データおよび生成されたピーク特徴量 (F3) のデータサイズを表している。ただし、コンテキストのラベルは含まれていない。センサがコンピュータに送信する生データのフォーマットは [x 軸の値 (1), y 軸の値 (1), z 軸の値 (1), タイムスタンプ (4)] の 7 バイト, ピーク情報のフォーマットは [ピークの幅 (1), ピークの高さ (1), 平均値 (1), タイムスタンプ (4)] の 7 バイトとする。ただし () 内の数字はバイト数である。ここでタイムスタンプを 4 バイトとした理由は時刻をミリ秒単位で記録しなければならず多くの桁数を必要とするためである。3 バイトでは 5 時間弱までしか表現できないため数日単位の長時間利用する環境では容易にオーバフローが発生するためタイムスタンプを 4 バイトで表現した。4 バイト使用すると 50 日弱まで表現可能であり、実際に市販されている無線加速度センサ¹⁴⁾でもタイムスタンプを 4 バイトで表現している。

結果より, 10,000 サンプルの生データは $10,000 \times 7 \times 3 = 210,000$ バイト, 提案手法であるピーク特徴量 (F3) は「自転車」が最大のデータサイズで 80,584 バイト, 平均で 22,344.44 バイトであり, すべての行動を均等に行った場合のデータサイズは生データと比較して 89.4%削減できていることが分かる。

4.7 周波数変化に対するデータサイズおよび判別性能の評価

サンプリング周波数を変えた場合の判別性能について評価する。評価ではサンプリング周波数が 150 Hz, 75 Hz, 50 Hz, 30 Hz, 25 Hz, 15 Hz, 10 Hz, 5 Hz, 3 Hz, 1 Hz の場合に, その他の条件は 4.2 節と同じ環境で 1 分あたりの生データおよびピーク特徴量 (F3) のデータサイズ (データレート) および Cluster precision を比較した。結果を表 5 に示す。表より, 30 Hz におけるピーク特徴量 (F3) のデータレートは 11,060 バイト/分であり, 生データで同等のデータレートである 12,600 バイト/分ではサンプリング周波数 10 Hz である。生データで送信後の平均・分散特徴量 (F1) およびピーク特徴量 (F3) の Cluster precision はそれぞれ 0.884 および 0.907 であり, 同一データレートでは提案するピーク特徴量が従来の平均・分散特徴量よりも若干ではあるが優位であることが分かる。

4.8 実生活データにおけるデータサイズの評価

前節の結果では同一データレートでの判別性能は若干ピーク特徴量が優位であると述べたが, 評価結果は採取した 16 種類のコンテキストが同頻度で発生した場合の平均的な数値

表 5 各サンプリング周波数におけるピーク特徴量および平均・分散特徴量のデータレートと認識精度
Table 5 Peak features vs. mean+var features by changing sampling frequency.

周波数	生データ送信後の平均・分散特徴量 (F1)		ピーク特徴量 (F3)	
	データレート [バイト/分]	Cluster precision	データレート [バイト/分]	Cluster precision
150 Hz	189,000	0.909	20,110	0.902
75 Hz	94,500	0.917	17,537	0.900
50 Hz	63,000	0.905	15,068	0.897
30 Hz	37,800	0.902	11,060	0.907
25 Hz	31,500	0.906	9,825	0.894
15 Hz	18,900	0.897	7,312	0.873
10 Hz	12,600	0.884	5,597	0.875
5 Hz	6,300	0.890	3,071	0.853
3 Hz	3,780	0.821	1,692	0.804
1 Hz	1,260	0.716	597	0.675




図 6 24 時間の加速度波形

Fig. 6 Waveform of acceleration for 24 hours.

であり, 実生活では静止している時間が活動している時間よりも長い。文献 15) では 16 日間のモニタリングにより約 4,100 分間のうち約 3,000 分が「座る」である結果が得られている。またこの結果には睡眠は含まれておらず, 睡眠を含めた 24 時間で考えると静止している時間は大部分を占めると考えられる。そこで最後に本論文では, 腰に加速度センサを装着し, サンプリング周波数 20 Hz において入浴を除く 24 時間のデータを 1 人の被験者から採取した。得られた加速度波形を図 6 に示す。図 6 より睡眠時はピークの出現回数が少なく, 活動時にはピークが現れているように見えるが, 活動時の加速度波形を拡大すると静的な動作が多いことが確認できた。また, ピーク特徴量 (F3) と生データのデータサイズはそれぞれ 12,096,000 バイトと 366,002 バイトとなり, ピーク特徴量は生データと比較してデータサイズを 97.0%削減できており, 前述のすべての行動を平均的に行った場合と比較しても

データサイズ削減率が改善されていることが分かる。

4.9 評価のまとめ

評価結果についてまとめる。クラスタリング精度および SVM による各特徴量の 16 種類のコンテキストに対する判別性能の評価より、従来手法である平均・分散特徴量 (F1)、平均・分散・最大・最小特徴量 (F2) および提案手法であるピークの幅・高さ特徴量 (F3)、ピークの勾配特徴量 (F4) が同等の高い性能を示すことが分かった。また、提案手法のうち性能の良かった F3 と生データをサンプリング周波数 150 Hz における 10,000 サンプル (約 67 秒) あたりのデータサイズを比較すると、F3 は生データと比較して 89.4% データサイズを削減することが分かった。さらに、24 時間の行動データによる評価では、生活の大部分を静的な動作 (姿勢) が占めるため、提案手法によるデータサイズ削減率は生データと比較して 97.0% となり、提案手法は日常生活においても有効であることを示した。加えて、サンプリング周波数を変更して同一データレートにおいて F1 と F3 の認識精度を比較したところ、F3 と同等のデータレートにするためには F1 のサンプリング周波数を大幅に低下させなければならず認識精度が低下したことを確認した。これらの結果から本論文で提案する加速度波形のピークの高さと幅を用いた特徴量は、従来の平均・分散を用いた特徴量と同等の性能を示しつつそのデータサイズを大幅に削減できることが分かる。

5. ま と め

本論文ではウェアラブルコンピューティング環境における行動認識システムにおいて用いられるいくつかの特徴量を判別性能とデータサイズの観点から評価した。特徴量として、平均、分散、最大、最小、波形のピークを比較した。具体的には、16 種類のコンテキストが同頻度で含まれているデータに対しピークの幅と高さを用いた特徴量が従来の平均や分散と同等の性能を示しつつ、データサイズを 89.4% 削減できることを確認した。また、24 時間の生活データを用いた評価では提案手法は生データと比較してデータサイズを 97.0% 削減され、実際の生活では提案手法がより有効に働くことを確認した。

提案する特徴量計算アルゴリズムをセンサデバイスに組み込むことで従来の特徴量の持つ判別性能を維持したままデータサイズの小さな特徴量に変換できる。これにより、メインコンピュータへのデータ送信に要する電力を抑え、長時間のウェアラブルセンシングが可能となり、ウェアラブルコンピューティングの発展に貢献できると考える。

今後は、実生活において採取したより長時間にわたるデータセットを用いて、実際に削減できるデータ量および消費電力 (稼働時間) について評価する予定である。

謝辞 本研究の一部は、科学研究費補助金基盤基盤 (A) (20240009)、特定領域研究 (21013034) および特別研究員奨励費 (21-249) の支援によるものである。ここに記して謝意を表す。

参 考 文 献

- 1) Miyamae, M., Terada, T., Tsukamoto, M. and Nishio, S.: Design and Implementation of an Extensible Rule Processing System for Wearable Computing, *Proc. IEEE Int'l Conf. on Mobile and Ubiquitous Systems: Networking and Services (MobiQuitous 2004)*, pp.392-400 (Aug. 2004).
- 2) Toda, M., Akita, J., Sakurazawa, S., Yanagihara, K., Kunita, M. and Iwata, K.: Wearable Biomedical Monitoring System using TextileNet, *Proc. IEEE Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.119-120 (Oct. 2006).
- 3) Shen, C.L., Kao, T., Huang, C.T. and Lee, J.H.: Wearable Band Using a Fabric-Based Sensor for Exercise ECG Monitoring, *Proc. IEEE Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.143-144 (Oct. 2006).
- 4) Ouchi, K., Suzuki, T. and Doi, M.: LifeMinder: A wearable Healthcare Support System Using User's Context, *Proc. Int'l Workshop on Smart Appliances and Wearable Computing (IWSAWC 2002)*, pp.791-792 (July 2002).
- 5) Naya, F., Ohmura, R., Takayanagi, F., Noma, H. and Kogure, K.: Workers' Routine Activity Recognition using Body Movement and Location Information, *Proc. IEEE Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.105-108 (Oct. 2006).
- 6) Benbasat, A.Y. and Paradiso, J.A.: A Framework for the Automated Generation of Power-Efficient Classifiers for Embedded Sensor Nodes, *Proc. Int'l Conf. on Embedded Networked Sensor Systems (Sensys 2007)*, pp.219-232 (Nov. 2007).
- 7) Laerhoven, K.V. and Gellersen, H.W.: Spine versus Porcupine: A Study in Distributed Wearable Activity Recognition, *Proc. IEEE Int'l Symposium on Wearable Computers (ISWC 2004)*, pp.142-149 (Oct. 2004).
- 8) Nike+iPod. <http://www.apple.com/ipod/nike/>
- 9) Kawahara, Y., Sugimoto, C., Arimitsu, S., Morandini, A., Itao, T., Morikawa, H. and Aoyama, T.: Context Inference Techniques for a Wearable Exercise Support System, *Proc. ACM Int'l Conf. on Computer Graphics and Interactive Techniques (SIGGRAPH 2005)*, p.95 (July/Aug. 2005).
- 10) Stiefmeier, T., Ogris, G., Junker, H., Lukowics, P. and Tröster, G.: Combining Motion Sensors and Ultrasonic Hands Tracking for Continuous Activity Recognition in a Maintenance Scenario, *Proc. IEEE Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.97-104 (Oct. 2006).

- 11) Ho, J. and Intille, S.S.: Using Context-Aware Computing to Reduce the Perceived Burden of Interruptions from Mobile Devices, *Proc. ACM Conf. on Human Factors in Computing Systems (CHI 2005)*, pp.909–918 (Apr. 2005).
- 12) Huynh, T. and Schiele, B.: Analyzing Features for Activity Recognition, *Proc. Joint Conf. on Smart Objects and Ambient Intelligence: Innovative Context-aware Services: Usages and Technologies (sOcEuSAI 2005)*, pp.159–163 (Oct. 2005).
- 13) Vapnik, V.: *The Nature of Statistical Learning Theory*, Springer (Aug. 1995).
- 14) Wireless Technologies, Inc. <http://www.wireless-t.jp/>
- 15) Huỳnh, T., Fritz, M. and Schiele, B.: Discovery of Activity Patterns using Topic Model, *Proc. Int'l Conf. on Ubiquitous Computing (UbiComp 2008)*, pp.10–19 (Sept. 2008).

(平成 21 年 6 月 21 日受付)

(平成 21 年 12 月 17 日採録)



村尾 和哉 (学生会員)

2006 年大阪大学工学部電子情報エネルギー工学科卒業。2008 年同大学大学院情報科学研究科博士前期課程修了。現在、同大学院博士後期課程に在籍。ウェアラブルコンピューティング、コンテキストウェアネスの研究に興味を持つ。日本データベース学会の学生会員。



クリストフ ファン ラールホーフェン

1999 年ベルギー、ブリュッセル大学修士課程修了。2005 年英国、ランカスター大学博士課程修了。2006 年よりドイツ、ダルムシュタット工科大学研究員。2009 年より同大学エンベデッドセンシンググループ長。現在に至る。博士 (コンピュータサイエンス)。ベルギー、英国、ドイツにおいて多数の国際プロジェクトに従事。ユビキタスコンピューティング、ウェアラブルコンピューティング、機械学習の研究に従事。IEEE の会員。



寺田 努 (正会員)

1997 年大阪大学工学部情報システム工学科卒業。1999 年同大学大学院工学研究科博士前期課程修了。2000 年同大学院工学研究科博士後期課程退学。同年より大阪大学サイバーメディアセンター助手。2005 年より同講師。2007 年神戸大学大学院工学研究科准教授。現在に至る。2002 年より大阪大学院情報科学研究科マルチメディア工学専攻助手、2005 年より同講師を併任。2004 年より特定非営利活動法人ウェアラブルコンピュータ研究開発機構理事、2005 年には同機構事務局長を兼務。2002 年には NEC インターネットシステム研究所客員研究員、2004 年には英国ランカスター大学客員研究員、2007 年 1 月より ATR 客員研究員を兼務。博士 (工学)。アクティブデータベース、ウェアラブルコンピューティング、ユビキタスコンピューティングの研究に従事。IEEE、電子情報通信学会、日本データベース学会、ヒューマンインタフェース学会の各会員。



西尾章治郎 (フェロー)

1975 年京都大学工学部数理工学科卒業。1980 年同大学大学院工学研究科博士後期課程修了。工学博士。京都大学工学部助手、大阪大学基礎工学部および情報処理教育センター助教授、大阪大学大学院工学研究科情報システム工学専攻教授を経て、2002 年より大阪大学大学院情報科学研究科マルチメディア工学専攻教授となり、現在に至る。2000 年より大阪大学サイバーメディアセンター長、2003 年より大阪大学大学院情報科学研究科長、その後 2007 年より大阪大学理事・副学長に就任。この間、カナダ・ウォータールー大学、ビクトリア大学客員。データベース、マルチメディアシステムの研究に従事。現在、Data & Knowledge Engineering 等の論文誌編集委員。本会理事を歴任。本会論文賞を受賞。電子情報通信学会フェローを含め、ACM、IEEE 等 8 学会の各会員。