

加速度センサの定常性判定による動作認識手法

村尾和哉^{†1,†2} 寺田 努^{†2,†3}

近年、計算機の小型化・軽量化によりコンピュータを装着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。特に行動認識の分野では、加速度センサを用いたシステムが数多く提案されてきた。従来の行動認識システムで認識可能なコンテキストはその波形の形状から「座る」などの姿勢、「歩く」などの運動、「円を描く」などのジェスチャの3種類に分類できる。姿勢と運動は一定時間継続される状態であり、特徴量を用いて認識される。一方、ジェスチャは1回きりの動作であり、波形自体を用いて認識される。このような認識手法の違いから運動中のジェスチャ認識は困難とされてきた。また、従来のジェスチャ認識はジェスチャの開始点を明示するためにいったん停止したりボタンを押したりする必要があった。そこで本論文では、加速度波形の定常性を判定し、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する。評価結果より、5種類の運動中に行った7種類のジェスチャ認識のRecallとPrecisionは従来手法では0.75および0.59であるのに対し、提案手法では0.93および0.92と改善した。提案システムを用いることで運動中でもジェスチャによる入力や機器の操作が可能になる。

A Motion Recognition Method by Constancy Decision

KAZUYA MURAO^{†1,†2} and TSUTOMU TERADA^{†2,†3}

The downsizing of computers has led to wearable computing that has attracted a great deal of attention. In the area of context awareness, many context-aware systems using accelerometers have been proposed. Contexts that have been recognized are categorized into postures (e.g., sitting), behaviors (e.g., walking), and gestures (e.g., draw a circle). Postures and behaviors are states lasting for a certain length of time, which are recognized with several feature values over a window. Gestures, however, are once-off actions. It has been a challenging task to find gestures on real environments where gestures are buried in other contexts. In this paper, we propose a method that classifies contexts into postures, behaviors, and gestures by using the autocorrelation of the acceleration values and recognizes contexts with an appropriate method. We evaluated the performance of recognition for seven kinds of gestures while five kinds of behaviors; The conventional method gave recall and precision of

0.75 and 0.59 whereas our method gave 0.93 and 0.92, respectively. Our system enables a user to input by gesturing even while he or she is performing a behavior.

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付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。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²¹⁾ や心電計¹⁸⁾、GSR (皮膚電気反射)¹⁵⁾、あるいは独自のデバイス⁹⁾といったさまざまな装着型センサを用いてユーザの状態を認識し、状態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^{14),15),19)}。例として、LifeMinder¹⁵⁾ 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食事や歩行、仕事などの装着者の行動を認識し、運動不足や過労を警告する。位置・動作情報を検出するセンサとして加速度センサのほかにはカメラやGPS、ジャイロ、地磁気センサなどがあげられるが、これらのセンサは装着性や精度の低さ、動きと静止時の方向が同時に取得不可能といった問題点を持つ。一方加速度センサは装着部位の動きを検出可能であり、静止時でも地球の重力を検出することによりその方向が取得可能であるため使い勝手が良い。また、精度および分解能が高く、小型で容易に装着可能である。このように既存センサの中では加速度センサがコンテキストウェアシステムの構築に適している。

ここで、コンテキストウェアシステムの研究において認識されるコンテキストは「座る」などの姿勢と「歩く」などの運動である。姿勢や運動は一定時間継続される状態であり、一般的に数秒間の加速度データから体の向きや運動強度を表現する特徴量に変換した後、SVM (Support Vector Machine)²²⁾ などの認識器を用いて認識される。一方、日常生活におけ

†1 日本学術振興会特別研究員 PD
Research Fellow of Japan Society for the Promotion of Science

†2 神戸大学大学院工学研究科
Graduate School of Engineering, Kobe University

†3 科学技術振興機構さきがけ
PRESTO, Japan Science and Technology Agency

る重要なコンテキストにはジェスチャも含まれる。ジェスチャはその直観性や利用の容易さから、携帯電話などの端末の入力方式として注目を集めており¹²⁾、またボタンなどの従来のインタフェースでは入力が高難度であった図形などの入力も容易である⁴⁾。ジェスチャは姿勢や運動などの状態と異なり1回きりの動作であり、運動の軌跡が重要な意味を持つため、一般的にはジェスチャ部分の波形を切り取った後、DTW (Dynamic Time Warping)¹³⁾などのテンプレートマッチング手法を用いて認識する。ここで、ジェスチャ部分の波形を切り取るために従来システムではジェスチャ開始前後にユーザに静止させるなど日常生活には適用困難な制約を課していた^{24),25)}。そのため、姿勢、運動、ジェスチャを認識する単一のシステムは提案されていない。本論文では、「歩く」や「走る」などの運動はあるデータの繰返しからなることに着目し、加速度データの自己相関を求めることで運動の定常性を判定する。定常性がある間は運動の認識を行い、定常性が崩れた場合にジェスチャの認識を行う。自己相関を用いた定常性の判断を行うことでユーザが歩行中でもジェスチャ部分を自動的に発見し認識できる。

以降、2章で関連研究をあげ、3章で提案機構の構成について述べる、4章で提案システムの評価を行い、5章で本論文をまとめる。

2. 関連研究

ウェアラブルセンサを用いた行動認識に関する研究はこれまでに数多く行われている。Maurerらは6個の加速度センサおよび照度センサを左手、ベルト、ネックレス、ズボンの右ポケット、シャツのポケット、鞆に配置して、走る、歩く、立つ、座る、階段上り、階段下りの6種類の行動を認識している¹¹⁾。Raviらは掃除機かけや、歯磨きを含む8種類の行動を骨盤に配置した1個の加速度センサで認識する手法を提案している¹⁷⁾。Tapiaらは歩行やポート漕ぎなどのジムでの運動を強度を変えて30種類を認識している²⁰⁾。Pärkkäらは22種類のセンサを用いて横になる、漕ぐ、走る、雪上を歩く、自転車、歩く、座る、立つを認識している¹⁶⁾。Lesterらはマイクロフォンや加速度センサなど7種類のセンサを搭載したMSB (Multi-modal Sensor Board)を用いて座る、立つ、歩く、階段上り、階段下り、エレベータ上り、エレベータ下り、歯磨きを認識している¹⁰⁾。しかし、これらの研究で取り扱われている研究はいずれも姿勢あるいは運動である。上記の研究のほかにも文献1)において行動認識に関する10個の研究が紹介されているが、それらで取り扱われている行動のほとんどが歩行や姿勢である。一方、その中の1つである文献8)では、握手を取り扱っているが、握手しているという状態を認識したものである。また、その中の1つである文献2)

は加速度センサを用いたビデオアノテーション手法を提案しており、チョップや肘打ち、パンチを認識している。しかし、扱われている行動はジェスチャのみであり、運動中のジェスチャは想定していない。これらに対し、装着型センサを用いたジェスチャ箇所の発見手法が提案されている⁵⁾。この手法ではSWBA (Sliding-Window and Bottom-up Algorithm)⁷⁾を用いてリアルタイムでセグメント化した時系列データを特徴量変換し、HMM (Hidden Markov Model)で分類している。受話器を上げるやボタンを押すなどの10種類のジェスチャを認識しているが、他の動作中にジェスチャを行った場合は想定していない。これに対し、本論文で提案する手法は時系列データを姿勢、運動、ジェスチャの3種類に分類して認識するため動作中のジェスチャも認識できる。

3. 認識機構の構成

これまでの行動認識に関する多くの研究で扱われてきた姿勢や運動は一定時間継続される状態であり、ある加速度波形のパターンの繰返しからなる。これらの行動は一般的にはその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、FFT (Fast Fourier Transform)係数などに変換した後、SVMなどの認識器を用いて認識される。このような手法を用いることでウィンドウ内のすべてのデータを計算に用いる必要がなく、高速に認識処理ができる。また、特徴量に変換することでデータの時間軸を破棄するため、認識する時点においてたとえばユーザが歩行時の足を上げた瞬間なのか着地した瞬間なのかといったウィンドウが動作のどの部分を含んでいるかを考慮しなくてよいことも特徴の1つである。一方、ジェスチャは姿勢や運動と異なり、開始点と終了点を持つ1回きりの動作である。上で述べた特徴量は動き方に関する情報は持たず、腕の右回しと左回しなどの類似したジェスチャを区別できないため、姿勢や運動の認識手法を適用できない。そこで一般的にはジェスチャ部分の波形を切り取った後、DTWなどのテンプレートマッチング手法を用いて認識する。この手法を用いることで動き方を考慮した詳細な認識処理ができる。ジェスチャ部分の波形を切り取るために従来研究ではジェスチャ開始前にユーザが静止したり、ジェスチャ中にボタンを押したり、ジェスチャを開始するためのジェスチャを行ったりすることでジェスチャの開始点を明示する必要があったが^{24),25)}、ジェスチャを行うたびに静止したり別の動作を行わなければならないかという制約を日常生活に適用することは困難である。また、ジェスチャ中にボタンを押すために何らかのデバイスを取り出したり、常時把持しておいたりすることも考えにくい。ジェスチャの開始点や終了点を考慮せずに単にDTWを適用すると認識とジェスチャのタイミングが合わずに運動に埋もれたジェスチャを見逃した

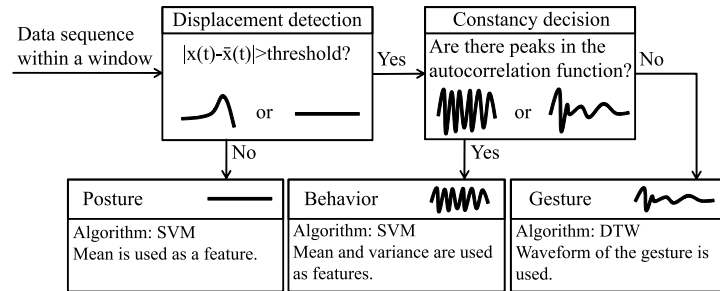


図 1 認識フロー
Fig. 1 Recognition procedure.

り誤認識したりする．提案手法では対象となる行動を姿勢，運動，ジェスチャに分類して，ジェスチャには DTW を適用し，姿勢と運動には SVM を適用する．

本章では時系列データを姿勢，運動，ジェスチャの 3 種類に分類して認識する機構について述べる．提案機構では図 1 の認識フローに示すように，2 段階でコンテキストの種類判定を行う．1 段階目の変動検出フェーズでは装着者の動きを検出する．装着者に動きがある場合は 2 段階目の定常性判定フェーズにおいて，その動きが定常的なものであるかを自己相関を用いて判定する．以下に各判定フェーズについて詳しく述べる．本論文では，手首，腰，足首の 3 カ所に 3 軸加速度センサを装着し，20 Hz でデータを取得する環境を想定している．センサの装着箇所に関しては，より多くのセンサを装着する研究も存在するが手，腰，足が一般的である．また周波数は研究によってさまざまであるが，日常動作の認識には 10 Hz 以上であれば問題ない⁶⁾．4 章の評価実験では 4 種類の姿勢（座る，立つ，横になる，膝立ち），5 種類の運動（歩く，走る，自転車，階段上り，階段下り）および 7 種類のジェスチャ（チョップ，投げる，パンチ，時計回りの円を描く，反時計回りの円を描く，ジャンプ，キック）のデータを用いる．

3.1 変動検出フェーズ

システムはセンシングデータ取得時にデータに変化があるかを判定する．現在時刻を $t = T$ とすると，時刻 $t = T$ から過去 20 サンプル（1 秒）のセンシングデータの移動平均 $\bar{x}(T)$ と現在のセンシングデータ $x(T)$ の差の絶対値が閾値 ε を超えた場合に，装着者に動きがあると判定する．




図 2 変動検出
Fig. 2 Displacement detection.

$$\begin{aligned} \text{if } |x(T) - \bar{x}(T)| > \varepsilon &\Rightarrow \text{Behavior or Gesture} \\ \text{otherwise} &\Rightarrow \text{Posture} \end{aligned} \quad (1)$$

この移動平均 $\bar{x}(t) \pm \varepsilon$ の領域を Epsilon tube と呼ぶ．Epsilon tube を設けることでセンサのノイズや意図しない小さな動作による変動を除去することができる．本論文の評価で使用するデータの静止時の加速度の変動が 100 mG 程度であったため，それらを除去するために ε を 200 mG に設定した．運動およびジェスチャによって生じる加速度の変動は 200 mG より大きいためこれらが検出されないことは基本的にない．また，運動中でも現在のデータ $x(T)$ が一時的に Epsilon tube 内に存在する可能性があるため，連続 0.25 秒以上 Epsilon tube 内にとどまった時点で姿勢と判断する．さらに，静止中でも接触などの衝撃によって現在のデータ $x(T)$ が一時的に Epsilon tube 外に出る場合があるが，一瞬のセンシングデータの変動は装着者が意図しないものであると判断し，1.6 秒以内の乖離は無視する．これらの値は予備実験の結果から設定した．図 2 に示すように，センシングデータが Epsilon tube 内にとどまっている間はシステムは装着者が何らかの姿勢を継続していると判断して，姿勢のみを学習した SVM を用いて姿勢を認識する．認識されるコンテキストは姿勢のみであり分散値はほぼ 0 であるため，特徴量は平均値のみを用いた．センシングデータに動きがある場合は次に述べる定常性判定フェーズに進む．

3.2 定常性判定フェーズ

「歩く」や「走る」，「自転車に乗る」，「階段昇降」などのコンテキストはある一定のデータの繰返しからなる．定常性検出フェーズでは，自己相関関数（ACF: Auto-Correlation Function）を用いて装着者の動作内の繰返しを検出し，運動かジェスチャかの判断をする．入力信号に繰返しがある部分で ACF の値が大きくなる．つまり，ACF に周期的なピークが現れることは，入力信号も周期的であり，装着者が周期的な運動をしていることを意味す




図3 「歩く」と「チョップ」の加速度波形(左)および「歩く」(右上)と「チョップ」(右下)の自己相関関数
Fig. 3 Acceleration of chop while walking (left) and autocorrelation of walking (upper right) and chop (lower right).

る．離散値入力信号 $x(t)$ のずれ τ における ACF は次式で定義される．

$$R_{xx}(\tau) = \sum_{t=0}^{N-1} x(t)x(t-\tau) \quad (2)$$

ただし、 N は ACF を計算するウィンドウサイズで、本論文では 64 サンプル (3.2 秒) とした． N が小さすぎると繰返しをとらえることができず、大きすぎると計算負荷が大きくなるためこの値とした．さらに、自己相関は、ずれ $\tau = 0$ において最大値を示すため、次式に従い $[-1, +1]$ に正規化した．

$$R'_{xx}(\tau) = R_{xx}(\tau)/R_{xx}(0) \quad (3)$$

自己相関の計算後、定常性の有無を判断する必要がある．図 3 に「歩いて、チョップをして、歩く」動作の加速度波形および歩行とチョップの各自己相関関数を示す．歩行時は 1 歩に対応する波形が繰り返されているが、チョップは 1 回きりの動作であり繰返しは見られない．ただし、本論文では 1 回きりの動作の繰返しはその動作をしている状態と見なすため運動と定義する．図より定常性を有するコンテキストの自己相関には明らかなピークが現れているが、定常性を有さないコンテキストの自己相関には高いピークは現れていない．本論文では、第 1 のピーク $R'_{xx}(n)$ ($n > 0$) の高さが $\alpha \cdot (1 - n/N)$ を超える場合に定常性ありと判断する．

$$\begin{aligned} \text{if } R'_{xx}(n) &\geq \alpha \cdot (1 - n/N) &\Rightarrow & \text{Behavior} \\ \text{otherwise} &&\Rightarrow & \text{Gesture} \end{aligned} \quad (4)$$

ここで、ずれ τ の増加にともない自己相関は線形的に減少し、正弦波などの完全な周期波形

のピークの高さは $1 - n/N$ となる．ただし、 α ($0 \leq \alpha \leq 1$) は係数であり、本論文では 0.8 とした．この値は運動中にジェスチャを行うデータに対して α を 0.5 から 1.0 まで 0.1 刻みで定常性判定を行った結果から決定した． α が大きすぎる場合、定常性が現れにくくなり、運動時をジェスチャと誤判定する割合が増加する．逆に α が小さすぎる場合、定常性が現れやすくなり、ジェスチャが検出されない割合が増加する．本論文では 3 軸加速度センサを 3 個用いているため、9 軸のデータが入力される．9 軸すべてにピークが出現しない場合は定常性なしと判断し、1 軸でも定常性が出現する場合は定常性ありと判断する．定常性がある場合は特徴量として平均値と分散値を計算した後、SVM を用いて運動を認識する．定常性がない場合はそのウィンドウの波形を切り出して DTW を用いてジェスチャを認識する．

3.3 認識アルゴリズム

本節では、姿勢と運動を認識するためのサポートベクタマシン (SVM)²²⁾、およびジェスチャを認識するためのダイナミックタイムワーピング (DTW)¹³⁾ について述べる．

3.3.1 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²²⁾．学習データセット $(x_1, y_1), (x_2, y_2), \dots, (x_J, y_J)$ を 2 クラスに分類すると想定する．ここで、 $x_i \in R^N$ 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 $w * x_i + b$ 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 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．

$$\min \frac{1}{2} \|w\|^2 \quad \text{subject to } y_i(w * x_i + b) \geq 1, \forall i = 1, \dots, n \quad (5)$$

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．

$$f(x) = \text{sign} \left(\sum_{i=1}^n \lambda_i y_i x_i * x + b \right) \quad (6)$$

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 x_i のみで識別関数が決定され、このような 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、サポートベクタマシン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 を実現した。

3.3.2 ダイナミックタイムワーピング

時系列データは科学や医学、経済学、工学などさまざまな分野で取り扱われており、これらの分野ではデータマイニングのために時系列データの類似度の計算が求められてきた。類似度計算の最も簡単な手法はユークリッド距離であるが、時間的歪みの影響を受けやすく、比較するデータのサンプル数が同じでなければならないなどの欠点がある。DTW はユークリッド距離の持つ欠点を克服した時系列データの類似度計算手法である。DTW の特徴として、時間的非線形圧縮距離を計算することで時系列のスケールや部分的な速度に違いがあるデータ間やサンプル数の異なるデータ間の類似度が求められる。たとえば、「空中に円を描く」データが 2 つある場合、片方が速く回し、もう一方が遅く回したとしても DTW は両者が類似していると判定する。仮に、円の一部分のみを速く描いたとしても非線形伸縮距離を求めるため、両者は高い類似度を示す。DTW と同様に時系列データの認識を行うアルゴリズムとして HMM があげられる。両者の違いは DTW は学習モデルをテンプレートとして保持するのに対し、HMM では遷移確率やシンボル出力確率として保持する点である。そのため、DTW は学習したデータに対して強く、HMM は未学習のデータに対して強いという特徴を持つ。しかし、HMM のモデル構築には DTW と比較して多くのデータサンプルが必要であり、センサを用いた行動認識において各ジェスチャのデータを大量に採取することは困難であると考え本論文では DTW を採用する。

具体的なアルゴリズムを以下に示す。長さ m と n の 2 つの離散波形 $X = (x_1, \dots, x_m)$ と $Y = (y_1, \dots, y_n)$ を比較する際、 $m \times n$ 行列 $d(x_i, y_j) = (x_i - y_j)^2$ を定義する。次に、 X および Y のインデックスのペアからなるワーピングパス $W = (w_1, \dots, w_k)$ を探索する。ワーピングパスは以下の 3 つの条件を満足する。

- 境界条件

$$w_1 = (1, 1), w_k = (m, n)$$

- 連続性

$$w_k = (a, b), w_{k-1} = (a', b') \Rightarrow a - a' \leq 1 \wedge b - b' \leq 1$$

- 単調性

$$w_k = (a, b), w_{k-1} = (a', b') \Rightarrow a - a' \geq 0 \wedge b - b' \geq 0$$

距離最小のパスを探索するために、以下の手順を適用する。

(1) Initialization:

$$DTW(0, 0) = 0$$

$$DTW(i, 0) = \infty \text{ for } i = 1, \dots, m$$

$$DTW(0, j) = \infty \text{ for } j = 1, \dots, n$$

(2) Do for $i = 1, 2, \dots, m$:

Do for $j = 1, 2, \dots, n$:

$$DTW(i, j) = d(x_i, y_j) + \min \begin{cases} DTW(i-1, j-1) \\ DTW(i-1, j) \\ DTW(i, j-1) \end{cases}$$

(3) Output:

Return $DTW(m, n)$

上式によって得られたコスト $DTW(m, n)$ が X と Y の距離となる。コンテキストを認識する際は、波形と正解ジェスチャのラベルの組である複数のテンプレートを保持しておく。入力データとすべてのテンプレートとの距離を計算し、最短距離のテンプレートに付与されているジェスチャラベルを結果として出力する。

4. 評価

本章ではまず、定常性判定の妥当性に関する評価を行う。次に提案手法および比較手法について識別性能の評価を行う。

4.1 予備実験

認識を含めた評価実験を行う前に、定常性判定の挙動を確認するために予備実験として歩行中にジャンプしたときの加速度波形に対して一定時間間隔で定常性判定を行った。センサは右手首、腰、右足首の 3 カ所に装着した。使用したセンサは 3 軸無線加速度センサ²³⁾、サンプリング周波数は 20 Hz である。結果を図 4 に示す。図中の横軸は経過時間、縦軸は加速度を示す。また、図中の 6,000 mG の線上にある印は定常性判定の結果であり、+ が定常性あり、・ が定常性なしを示している。図より、歩行中は定常性があり、すべての「ジャンプ」の部分で定常性なしとなっていることが分かる。歩行中にもかかわらず定常性なしと判定されている箇所があるが、4 回連続で定常性がなしと判断された場合のみジェスチャ認識を行うとするフィルタを介することで誤判定は除去できる。この理由として、ウィンドウは 16 サンプルずつ移動しており、ウィンドウサイズの 1/4 にあたる。ジェスチャ発生時に




図 4 定常性判定の結果
Fig. 4 Results of constancy decision.

表 1 運動時にジェスチャ認識が行われる割合

Table 1 Percentage of gesture recognition while behavioral contexts.

Contexts	Without filter [%]	With filter [%]
Walking	6.8	0.43
Running	6.9	0.32
Bicycling	9.0	0.69
Ascending	36	3.3
Descending	15	0.99

そのジェスチャの波形は最低 4 回はウィンドウに含まれる。ジェスチャのように明らかに定常性を有さない動作の場合 4 回連続で定常性なしと判定される。一方、一瞬の運動の崩れなどで定常性なしと判定される回数は 1 回や 2 回程度であり、除去できる。

フィルタの性能を確認するために、ジェスチャを行わず運動のみを継続している状況でジェスチャ認識が行われる割合を調べる。採取した 5 種類の運動（歩く、走る、自転車、階段上り、階段下り）のデータに対してジェスチャ認識を行う割合を表 1 に示す。「フィルタなし」は 1 回定常性なしと判定された時点でジェスチャ認識を行い、「フィルタあり」は 4 回連続で定常性なしと判定された時点でジェスチャ認識を行う。結果よりフィルタを適用しない場合、運動中にもかかわらずジェスチャ認識が行われる割合は 6.8% から 36% 程度とばらつきがある。これはつねに同じペースでその運動を行っているわけではないため、ペースが変わったところで一瞬定常性が崩れるためである。特に階段昇降は、段を飛ばしたり、疲労によって同じペースが維持されないため結果が悪くなったと考えられる。これに対してフィルタを適用した場合、ジェスチャ認識の割合が 0.32% から 3.3% 程度に抑制されている。センサのサンプリング周波数を変化させた場合でも同様の結果を得ている。ただし、10 Hz 以下のような低いサンプリング周波数ではサンプリングが粗くなり、データの繰返しが現れ

ない場合がある。しかし、そのような低いサンプリング周波数では行動認識自体の精度が低下することから⁶⁾、一般的な行動認識では 10 Hz より高い周波数でサンプリングされるため問題ないとする。

ここで、文献 3) において Intille らは実環境におけるデータ採取に着目しており、実環境での歩行の加速度データは著しくばらついていると述べている。しかし、実環境において日や時間単位ではデータにばらつきが生じるが、秒単位では波形は周期的である。これは、大学内で 500 m 程度離れた地点に缶ジュースを購入しに行くことのみを指示した行動データを用いて定常性判定を行った結果より、歩行や自転車、階段昇降などの運動中には定常性が現れることから確認している。この実験において被験者は単独で移動しており研究関係者は帯同しておらず、被験者に取り付けた小型カメラで撮影した動画をもとに正解の行動ラベルを取得しており、限りなく実環境に近いデータである。このように、本論文で用いるデータは評価のために非実環境で採取したものであるが、実環境においても運動には定常性が現れるため、運動とジェスチャを分離する手法として定常性判定は妥当であるとする。

4.2 評価環境

評価では手首、腰、足首の 3 カ所に加速度センサを装着した 20 代の被験者 4 人から採取したデータを用い、オフラインで解析した。被験者らは 4 種類の姿勢（座る、立つ、横になる、膝立ち）、5 種類の運動（歩く、走る、自転車、階段上り、階段下り）および 7 種類のジェスチャ（チョップ、投げる、パンチ、時計回りの円を描く、反時計回りの円を描く、ジャンプ、キック）を行った。ジェスチャのデータは静止時および 5 種類すべての運動中に採取した。ただし、自転車に乗りながらジャンプおよびキックは行えないため除外した。単体の動作を 16 通り、運動とジェスチャを組み合わせた動作を 33 通り、合計 1 時間の姿勢および運動データと各ジェスチャ約 100 回分のデータを採取した。ここで、本論文で想定するコンテキストは姿勢、運動、ジェスチャのいずれかに分類されるものとし、「歩きながら投げる」といった 2 種類のコンテキストが同時発生する状況は想定しない。本論文で用いる「歩きながらジェスチャする」といった表現はジェスチャ中は歩行動作をいったん中止しジェスチャのみを行うことを意味する。しかし、ジェスチャと運動間はスムーズに遷移しており、データの分割の目印になるような静止状態はない。加えて、被験者らは上記の行動を行うことのみ指示され、運動を一定のペースで行うような指示は行っていない。使用したセンサは予備実験で使用したのと同じ 3 軸無線加速度センサ²³⁾、サンプリング周波数は 20 Hz である。データを取得するウェアラブルコンピュータとしては SONY VAIO VGN-UX90PS（インテル CoreSolo プロセッサ 1.2 GHz）を使用した。

4.2.1 特徴量抽出

SVM などの認識アルゴリズムを用いて行動認識する場合、一般的にセンシングデータの値をそのまま使うのではなく、センシングデータの挙動を効率的に把握するために特徴量抽出と呼ばれる前処理を行う。本論文では、現在時刻 $t = T$ と仮定し、9次元(3軸×3個)のセンシングデータ $x_i(T)$ ($i = 1, \dots, 9$) の過去 3.2 秒間の平均 $\mu_i(T)$ および分散 $\sigma_i^2(T)$ を特徴量とする。運動認識には平均値と分散値の両方を用いるが、姿勢認識では分散値はほぼ 0 であるため平均値のみを用いる。ここで、平均 μ と分散 σ^2 はスケールが異なり等価に扱うことができないため、18次元のベクトル $X(T) = [\mu_1(T), \dots, \mu_9(T), \sigma_1^2(T), \dots, \sigma_9^2(T)]$ を $Z(T) = (X(T) - M)/S$ に従い標準化し、特徴ベクトル $Z(T)$ を得る。ここで M および S は X の各成分の平均および標準偏差である。この結果、 $Z(T)$ の各成分は平均 0、分散 1 になる。

一方、DTW では時系列データをそのまま用いる。装着者が動いている間はずねに 64 サンプルのデータを用いる。1回の動きの長さが 64 サンプルに満たない場合はその長さを用いる。本論文では、9次元(3個のセンサ×3軸)のデータを用いる。各軸における DTW 距離の和が最小のテンプレートに付与されているラベルを結果のコンテキストとする。

4.2.2 ラベリングおよび学習データ

ユーザにセンサを装着して採取したデータは手でラベル付けが行われ、全データの 10% を学習用データ、残り 90% を評価用データとして使用した。ジェスチャの学習用データは静止時に行ったものを用いた。ここで、変動検出および定常性判定後の SVM あるいは DTW を用いた認識は教師ありの認識であるが、提案手法である姿勢、運動、ジェスチャの分類はあらかじめ決められたルールベースで行うため正解データを利用しない。

4.2.3 評価手法

評価では、SVM のみ、DTW のみ、提案手法の 3 種類の認識手法を用いて姿勢、運動、ジェスチャを認識する。前者 2 手法は単純に単一の認識アルゴリズムを用いる従来手法である。後者はコンテキストの種類に応じて SVM と DTW を使い分ける提案手法である。提案手法は認識を行う前にコンテキストの種類を分類するため、姿勢をとっていると判断されると「座る」、「立つ」、「寝る」、「膝立ち」のみを学習した SVM で認識する。運動と判定されると「歩く」、「走る」、「自転車」、「階段上り」、「階段下り」のみを学習した SVM で認識する。ジェスチャが発生したと判断されると「チョップ」、「投げる」、「パンチ」、「時計回りの円を描く」、「反時計回りの円を描く」、「ジャンプ」、「キック」のみを学習した DTW で認識する。一方、従来手法ではコンテキストの種類を特定できないため、16 種類すべての

表 2 コンテキスト分類の Recall および Precision
Table 2 Recall and precision of context classification.

	Recall	Precision
Posture	1.00	1.00
Behavior	1.00	1.00
Gesture	1.00	0.98

コンテキストを学習したモデルを用いて認識する。

4.3 結果

はじめに、提案手法である変動検出および定常性判定による行動分類の Recall および Precision を表 2 に示す。表より姿勢の Recall および Precision が 1.00 であり、姿勢を動きと判定したり、動きを姿勢と判定したりすることはないことが分かる。運動およびジェスチャの場合はすべて定常性判定において運動かジェスチャに分類される。ここでは運動をジェスチャとして分類するミスが発生するためジェスチャの Precision が 0.98 となる。一方、運動と判定する回数はジェスチャに比べて多いため、運動の Recall は近似値で 1.00 となる。ジェスチャを運動と分類するミスは発生しないため運動の Precision およびジェスチャの Recall は 1.00 である。

次に、各運動中にジェスチャを行った場合の 3 種類の認識手法による Recall および Precision を表 3 に示す。表中のジェスチャの結果は 5 種類の運動中の結果の平均値であり、SVM の Recall および Precision は著しく低い。DTW と提案手法の結果を比較すると、提案手法が高い性能を示していることが分かる。提案手法の Recall および Precision が高い理由として、提案手法は事前に 3 種類のコンテキストに分類し、認識候補を絞っていることがあげられる。また、提案手法の Precision がより大きく改善している理由として、提案手法はジェスチャ部分のみに DTW を用いてジェスチャ認識しており、誤認識数が少ないことがあげられる。提案手法では運動をしているにもかかわらず一時的な定常性の崩れによってジェスチャとして誤分類される場合があるが、比較手法で発生するジェスチャの誤認識数と比較して少ないため、提案手法が優位であることが分かる。ここで、ジェスチャを複数回認識しないために、認識に用いるウィンドウサイズ 64 サンプルに対して 16 サンプルずつずらして認識を行うのではなく、64 サンプルずつずらして認識を行った場合、DTW の認識回数は削減できるが、その 64 サンプルの中にジェスチャを表すパターン全体が含まれるかどうかは確率的な問題となる。パターン全体が含まれれば正しく認識できるが、一部分しか含まなければ 1 回しかないその認識は誤認識となるため、16 サンプルずつずらして認識し

表 3 運動中のジェスチャ認識および運動認識の Recall および Precision

Table 3 Recall and precision of gesture recognition and behavior recognition between behaviors.

Contexts	SVM		DTW		Proposal	
	Recall	Precision	Recall	Precision	Recall	Precision
Chop	0.13	0.05	0.94	0.50	0.96	0.91
Throw	0.65	0.17	0.90	0.55	0.91	0.93
Punch	0.35	0.30	0.60	0.68	0.97	0.93
Clockwise	0.32	0.19	0.83	0.55	0.92	0.90
Anticlockwise	0.40	0.17	0.74	0.55	0.86	0.90
Jump	0.45	0.30	0.58	0.74	0.93	0.90
Kick	0.18	0.37	0.65	0.64	0.98	0.98
Average	0.37	0.21	0.75	0.59	0.93	0.92
Walking	0.88	0.96	0.73	0.84	0.86	0.95
Running	0.81	0.85	1.00	0.87	0.97	0.85
Bicycling	0.93	0.85	1.00	0.98	0.92	0.99
Ascending	0.99	0.73	0.94	0.79	0.98	0.84
Descending	0.87	0.85	0.92	0.77	0.88	0.90
Average	0.90	0.85	0.92	0.85	0.92	0.91

た場合と同様の結果となる．さらに，表 3 の運動の認識結果より，提案手法は運動中の認識候補を運動のみに限定しているため SVM や DTW と同程度かより高い性能を示している．これらの結果より，提案手法はすべての種類のコンテキスト認識に対して高い性能を示すことを確認した．

以降では，各手法による結果の違いについて詳しく述べる．

4.4 考 察

4.4.1 静止時におけるジェスチャ認識

表 4 に各コンテキストを単独で行った場合の認識精度を示す．表中のジェスチャは静止時に行われたものである．表中の SVM の結果より，ジェスチャ以外のコンテキストの Recall および Precision は高い値を示している．これは特徴量は姿勢の向きや運動の強度に関する情報は持っているが，動き方に関する情報を持たないためである．具体的には，「投げる」の Recall と「チョップ」および「パンチ」の Precision が低い理由は両者が類似した手のジェスチャであるためである．また，すべての「時計回りの円を描く」ジェスチャが「反時計回り」と誤認識され，「時計回り」の Recall と「反時計回り」の Precision が低下している．「時計回り」と認識された回数が 0 回であったため「時計回り」の Precision は N/A となっている．加えて，足を出す動作が歩く動作の 1 歩なのか，キックなのか区別できない

表 4 単体でのコンテキスト認識の Recall および Precision

Table 4 Recall and precision of the recognition of contexts performed by itself.


Contexts	SVM		DTW		Proposal	
	Recall	Precision	Recall	Precision	Recall	Precision
Sitting	1.00	1.00	1.00	1.00	1.00	1.00
Standing	1.00	0.99	0.97	0.99	0.99	1.00
Lying	1.00	1.00	1.00	1.00	1.00	1.00
Kneeling	1.00	1.00	1.00	1.00	1.00	0.99
Walking	1.00	0.98	1.00	0.99	1.00	1.00
Running	1.00	1.00	1.00	1.00	1.00	1.00
Bicycling	1.00	1.00	1.00	1.00	1.00	1.00
Ascending	0.99	1.00	1.00	0.99	1.00	1.00
Descending	0.98	0.99	0.98	1.00	1.00	1.00
Chop	1.00	0.83	1.00	1.00	1.00	1.00
Throw	0.88	1.00	1.00	1.00	1.00	1.00
Punch	1.00	0.86	1.00	0.75	1.00	1.00
Clockwise	0.00	N/A	0.92	1.00	0.92	1.00
Anticlockwise	1.00	0.51	1.00	0.91	1.00	0.91
Jump	1.00	1.00	0.93	1.00	0.97	1.00
Kick	0.88	1.00	1.00	1.00	1.00	0.97

ため「キック」の Recall が低くなっている．一方，DTW はジェスチャを含むすべてのコンテキストで高い認識精度を示している．これは DTW が時系列データを用いて軌跡を見て認識しており，特徴量では認識困難であったジェスチャが認識できたためである．提案手法の結果より，提案手法は DTW 同様の高い認識精度を示している．提案手法は SVM と DTW の融合手法であり，両者の長所を活かした手法である．ここで DTW のみを用いれば問題がないように見受けられるが，運動中にジェスチャを行った場合に DTW のみと提案手法に違いが表れる．


4.4.2 運動時におけるジェスチャ認識

歩く，走る，自転車，階段上り，階段下りの順に運動中に各ジェスチャを行った場合の各手法の認識結果を図 5 に示す．横軸は経過時間を，縦軸はコンテキストを示している．図中の ○ は実際に行ったコンテキスト (Ground truth)，× は認識結果を示している．○ と重なっている × は正しい認識，× のみは誤認識を意味する．また，運動の各コンテキストの線上に多数の ○ と × が重なって太い直線が存在するが，これはジェスチャ間の運動の Ground truth と認識結果である．


図 5 (a) に示す SVM の結果より，ほとんどのジェスチャが正しく認識されず多数の誤認



(a) SVM.



(b) DTW.



(c) Proposal.

図 5 運動中のジェスチャ認識結果

Fig. 5 Recognition results of gestures between behaviors.

識結果が出力されたりしている．また、歩きながらの「キック」や走りながらの各ジェスチャは運動に埋もれてしまい認識結果がジェスチャにすら割り当てられていない．これらの原因は波形を特徴量に変換したことでジェスチャの情報が消えたためであると考えられる．図 5 (b) に示す DTW の結果は SVM の結果と比較して ○ に × が重なっており、正しいジェスチャの認識結果が出力されているが、同時に正しい認識結果が複数回出力された




図 6 単純に 16 サンプルごとに DTW を用いた場合の認識結果

Fig. 6 Detailed recognition results with DTW simply shifted over the data in steps of 16 samples.

り、異なるジェスチャや運動の認識結果が出力されたりしている．詳細な結果を図 6 に示す．このデータは歩行中に「投げる」ジェスチャを行ったときのものです．ウィンドウサイズ 3.2 秒、スライディング幅 0.8 秒で認識している．初めの認識結果は正しく「歩く」と認識しているが、ジェスチャ開始直後から「階段を下りる」および「キック」と誤認識している．これは DTW の認識に用いる時系列データに「歩く」と「投げる」の波形が混合しているためである．認識に用いる時系列データの大部分が「投げる」になると正しく「投げる」と認識しているが、その後はジェスチャ開始直後と同じ理由で誤認識している．ここで問題となるのは、人がこの波形と結果を見れば正しい認識結果の位置が推測できるが、機械で認識を行う場合に正しい認識結果と誤った認識結果が混合した中からどの結果を信頼すべきかの判断が困難であることである．これに対し図 5 (c) に示す提案手法の結果から、提案手法は定常性判定によってジェスチャ部分を特定してから認識しているため、装着者がジェスチャを行ったとき、正しいジェスチャを 1 度だけ出力し、他の誤った認識結果を出力していないことが分かる．

4.4.3 処理時間

最後に、提案手法の処理時間について議論する．変動検出、定常性判定および SVM と DTW での認識に要する時間を表 5 に示す．使用したコンピュータは本論文の評価において使用したウェアラブルコンピュータと同じ SONY VAIO VGN-US90PS (インテル CoreSolo プロセッサ 1.2 GHz) である．処理を行うプログラムは Microsoft Visual Studio 2008 Visual C++ で実装した．結果は各処理を 10 万回実行した際の時間をもとに 1 回あたりの処理時間を算出したものである．同じ SVM や DTW でも手法によって処理時間が異なるのは、認識するコンテキストの種類が比較手法では 16 種類であるのに対し、提案手法では姿勢 4 種

表 5 比較手法および提案手法の処理時間 [ミリ秒]

Table 5 Processing time for comparison methods and proposed method [msec].

	SVM	DTW	Proposal		
			Posture	Behavior	Gesture
Displacement detection	-	-	0.00141		
Constancy decision	-	-	-	0.0452	
Recognition with SVM	0.0514	-	0.00203	0.0510	-
Recognition with DTW	-	34.9	-	-	15.3
Total	0.0514	34.9	0.00344	0.976	15.3

類, 運動 5 種類, ジェスチャ 7 種類であるためである. SVM は特徴量変換に要する時間も含まれており処理時間の大部分を占めるため, 認識するコンテキストの種類の影響は少ない. 提案手法の姿勢の SVM は特徴量として平均値しか計算していないため運動の SVM より短い処理時間となっている. DTW のテンプレートの数は 1 コンテキストあたり 1 サンプルとしており, コンテキストの種類に比例する処理時間を要する. 結果より, 提案する変動検出および定常性判定に要する時間は認識処理に要する時間より短く, 認識間隔である 800 ミリ秒よりも短いため, 提案手法は実時間処理にも用いることができる.

5. ま と め

本論文では姿勢, 運動, およびジェスチャを認識する新たなコンテキスト認識機構を提案した. 提案方式では, 加速度波形の自己相関を計算することで運動の定常性を判定するため, 運動中にジェスチャを行ったとしても, ジェスチャの認識が可能となる. 従来手法では, SVM は姿勢および運動は高速かつ高精度で認識可能であったが, 類似したジェスチャは認識困難であった. 一方, DTW は類似したジェスチャも認識可能であるが, SVM と比較して多くの計算を必要としていた. また, 歩行動作から静止せずにジェスチャを行った場合, 認識する波形に複数のコンテキストの波形が含まれて, DTW は正しい認識結果と同時に複数の正解および不正解の認識結果を出力する. 本論文では, ジェスチャが発生した場合のみ DTW を用い, それ以外は SVM を用いることで両者の特徴を活かした認識機構を構築した. 評価より, 運動中のジェスチャ認識において従来手法の SVM のみを用いる手法では Recall 0.37, Precision 0.21, DTW のみを用いる手法では Recall 0.75, Precision 0.59 が得られたが, 提案手法では Recall 0.93, Precision 0.92 と大幅に改善された.

ここで, 定常性判定ではコンテキストの変化を検出できるため, 自己相関が定常性を示している間はコンテキストが変化しておらず, 認識を行う必要はないと考えられる. しかし,

自己相関では「歩く」から「階段昇降」のようなスムーズなコンテキストの変化は検出できない. これは, 十数段おきに踊り場が存在する階段を昇降した場合のデータに対する定常性判定の結果において, 階段から踊り場へ移動する際に定常性が崩れない場合があることから確認している.

現在はすべてのセンサを統合して定常性判定や認識を行っているが, 今後は各センサを独立して取り扱うことを考えている. たとえば, 歩行中に腕を振って携帯電話などのデバイスに入力する際, 腕は「振る」ジェスチャをしているが, 足は「歩く」運動をしている. このような同時発生する複数種類のコンテキストを認識するために各センサごとに認識アルゴリズムを切り替える手法を提案する予定である.

謝辞 本研究の一部は, 科学技術振興機構戦略的創造研究推進事業(さきがけ)および科学研究費補助金基盤基盤(A)(17200006), 特定領域研究(21013034), 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) Bao, L. and Intille, S.S.: Activity Recognition from User-annotated acceleration data, *Intl. Conference on Pervasive Computing (Pervasive 2004)*, pp.1-17, Springer (2004).
- 2) Chambers, G.S., Venkatesh, S., West, G.A.W. and Bui, H.H.: Hierarchical Recognition of Intentional Human Gestures for Sports Video Annotation, *Intl. Conference on Pattern Recognition (ICPR '02)*, pp.1082-1085 (2002).
- 3) Intille, S.S., Bao, L., Tapia, E.M. and Rondoni, J.: Acquiring In Situ training data for context-aware ubiquitous computing application, *ACM Conference on Human Factors in Computing Systems (CHI 2004)*, pp.1-9 (2004).
- 4) Jiayang, L., Zhen, W., Lin, Z., Jehan, W. and Venu, V.: uWave: Accelerometer-based personalized gesture recognition and its applications, *Intl. Conference on Pervasive Computing and Communication (PerCom 2009)*, pp.1-9 (2009).
- 5) Junker, H., Amft, O., Lukowicz, P. and Tröster G.: Gesture spotting with body-worn inertial sensors to detect user activities, *Pattern Recognition*, pp.2010-2024 (2008).
- 6) Junker, H., Lukowicz, P. and Tröster, G.: Sampling Frequency, Signal Resolution and the Accuracy of Wearable Context Recognition Systems, *Intl. Symposium on Wearable Computers (ISWC 2004)*, pp.176-177 (2004).
- 7) Keogh, E., Chu, S., Hart, D. and Pazzani, M.: An Online Algorithm for Segmenting Time Series, *Intl. Conference on Data Mining (ICDM 2001)*, pp.289-296, IEEE (2001).

- 8) Kern, N., Schiele, B. and Schmidt, A.: Multi-sensor Activity Context detection for Wearable Computing, *European Symposium on Ambient Intelligence (EUSAI)*, pp.220–232, Springer (2003).
- 9) Laerhoven, K.V. and Gellersen, H.W.: Spine versus Porcupine: A Study in Distributed Wearable Activity Recognition, *Intl. Symposium on Wearable Computers (ISWC 2004)*, pp.142–149 (2004).
- 10) Lester, J., Choudhury, T. and Borriello, G.: A Practical Approach to Recognize Physical Activities, *Intl. Conference on Pervasive Computing (Pervasive 2006)*, pp.1–16, Springer (2006).
- 11) Maurer, U., Smailagic, A., Siewiorek, D.P. and Deisher, M.: Activity Recognition and Monitoring Using Multiple Sensors on Different Body Positions, *Intl. Workshop on Wearable and Implantable Body Sensor Networks (BSN 2006)*, pp.113–116, IEEE (2006).
- 12) Moeslund, T.B. and Norgaard, L.: A Brief Overview of Hand Gesture used in Wearable Human Interfaces, Technical Report CVMT 03-02 ISSN 1601-3646 (2003).
- 13) Myers, C.S. and Rabiner, L.R.: A comparative study of several dynamic time-warping algorithms for connected word recognition, *The Bell System Technical Journal*, Vol.60, pp.1389–1409 (1981).
- 14) Naya, F., Ohmura, R., Takayanagi, F., Noma, H. and Kogure, K.: Workers' Routine Activity Recognition using Body Movement and Location Information, *Intl. Symposium on Wearable Computers (ISWC 2006)*, pp.105–108, IEEE (2006).
- 15) Ouchi, K., Suzuki, T. and Doi, M.: LifeMinder: A wearable Healthcare Support System Using User's Context, *Intl. Workshop on Smart Appliances and Wearable Computing (IWSAWC 2002)*, pp.791–792 (2002).
- 16) Pärkkä, J., Ermes, M., Korpiä, P., Mäntyjärvi, J., Peltola, J. and Korhonen, I.: Activity Classification Using Realistic Data From Wearable Sensors, *IEEE Trans. on Information Technology in Biomedicine*, Vol.10, pp.119–128, IEEE (2006).
- 17) Ravi, N., Dandekar, N., Mysore, P. and Littman, M.L.: Activity Recognition from Accelerometer Data, *American Association for Artificial Intelligence (AAAI 2005)*, pp.1541–1546 (2005).
- 18) Shen, C.L., Kao, T., Huang, C.T. and Lee, J.H.: Wearable Band Using a Fabric-Based Sensor for Exercise ECG Monitoring, *Intl. Symposium on Wearable Computers (ISWC 2006)*, pp.143–144, IEEE (2006).
- 19) 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, *Intl. Symposium on Wearable Computers (ISWC 2006)*, pp.97–104, IEEE (2006).
- 20) Tapia, E.M., Intille, S.S., Haskell, W., Larson, K., Wright, J., King, A. and Friedman, R.: Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart rate monitor, *Intl. Symposium on Wearable Computers (ISWC 2006)*, pp.97–104, IEEE (2006).
- 21) Toda, M., Akita, J., Sakurazawa, S., Yanagihara, K., Kunita, M. and Iwata, K.: Wearable Biomedical Monitoring System Using TextileNet, *Intl. Symposium on Wearable Computers (ISWC 2006)*, pp.119–120, IEEE (2006).
- 22) Vapnik, V.: *The Nature of Statistical Learning Theory*, Springer (1995).
- 23) Wireless Technologies Inc. <http://www.wireless-t.jp/>
- 24) 金 春善, 藤波香織: 格納動作パターンを用いた携帯電話の所有場所判定, 情報処理学会研究報告 (コピキタスコンピューティングシステム研究会 2009-UBI-21), No.17, pp.23–30 (2009).
- 25) 篠原正幸, 平子久智, 岡村将志, 五百蔵重典, 田中 博: ウェアラブル加速度センサを用いた動作認識による周辺機器操作のアーキテクチャの提案と実証, 電子情報通信学会コピキタスシステムネットワーク研究会, pp.97–102 (2010).

(平成 22 年 10 月 25 日受付)

(平成 23 年 3 月 7 日採録)



村尾 和哉 (正会員)

2006 年大阪大学工学部電子情報エネルギー工学科卒業。2008 年同大学院情報科学研究科博士前期課程修了。2010 年同大学院情報科学研究科博士後期課程修了。2009 年より独立行政法人日本学術振興会特別研究員 DC2。2010 年より同特別研究員 PD。現在に至る。博士 (情報科学)。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従事。IEEE, 日本データベース学会の各会員。



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．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．2004年には英国ランカスター大学客員研究員，2010年より科学技術振興機構さきがけ研究員を兼務．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．
