

# ウェアラブルセンサを用いた行動認識技術の 欠損特徴量補完による耐故障性向上

内田 稜真<sup>†1,a)</sup> 大村 廉<sup>†1,b)</sup>

**概要:** ウェアラブルセンサを身につけて用いる行動認識技術は、コンテキストウェアシステムを実現するための重要な技術のひとつである。しかしながら既存の行動認識技術では、あらかじめ想定された状況からセンサが1つでも欠損してしまうと、識別アルゴリズムが動作しなくなり、まったく行動が認識できなくなるという問題が存在する。そこで本研究では、ウェアラブルセンサを用いた行動認識技術を対象とし、いくつかのセンサデータが欠損した場合でも正常に動作する他のセンサから欠損データの特徴量を補完して、正常な行動認識結果を得るための手法を提案する。具体的には、重回帰またはカーネル法を使用して、取得可能なセンサデータから欠損した特徴量を補完する。提案手法の有用性を確認するため、評価実験を行った。その結果、行動認識技術において、ウェアラブルセンサの欠損によって識別アルゴリズムが動作しなくなる問題を欠損した特徴量の補完を行うことで解決し、欠損データを補完しない場合はF値の認識率が69.8%であったのに対し、重回帰では70.7%、カーネル法では71.1%となり、認識精度を1.0%以上向上させることができた。

**キーワード:** 行動認識, 耐故障性向上, 欠損データ補完

## Improving Fault Tolerance of Wearable Sensor-based Activity Recognition Technique by Completing Defective Feature Value

UCHIDA RYOMA<sup>†1,a)</sup> OMURA REN<sup>†1,b)</sup>

**Abstract:** Activity recognition techniques with wearable sensors are one of the most important technologies to achieve context-aware systems. However, existing recognition techniques are lack of fault tolerance in case of sensors data loss, such as communication disconnection and sensor failure. Our study proposes two methods to improve the fault tolerance by completing missing feature values with available some sensor. Our methods use multiple regression and the kernel method. We had some experiments to verify the usefulness of proposed methods. As a result, our method is confirmed to be able to improve fault tolerance of activity recognition technique. F-Measure rate is 69.8% in case of sensors data loss. Our method's F-Measure rate of multiple regression and kernel method are 70.7% and 71.1% that improved more than 1.0% than case of sensor data loss.

**Keywords:** Activity recognition, improving fault tolerance, completing defective value

<sup>1</sup> 情報処理学会  
IPJSJ, Chiyoda, Tokyo 101-0062, Japan  
<sup>†1</sup> 現在, 豊橋技術科学大学  
Presently with Toyohashi University of Technology  
<sup>a)</sup> ryoma@usl.cs.tut.ac.jp  
<sup>b)</sup> ren@tut.jp

## 1. はじめに

ユビキタス社会の到来において、人々が体にコンピュータを常に身につける環境が整い始めている。このような環境のなかで、ユーザの状況に合わせて、コンピュータを自

動的に制御することで、ユーザの快適性を向上させたり、ユーザの行動を支援するコンテキストウェアシステムが求められている。そのなかでもウェアラブルセンサを用いた行動認識技術は、コンテキストウェアシステムを実現するための、重要な技術のひとつである。行動認識技術が応用できる分野として、飛行機の整備士、歩行支援、ライフログと多様な場面が考えられる。例えば、歩行支援では、車が近づいてきたときに、歩行者が車に気付かずに歩いている場合、行動を認識し、車の危険を振動などで知らせ、止まるように促すアプリケーションが提案されている [1]。

これらのアプリケーションで用いられる行動認識技術では、加速度や角速度を計測できるウェアラブルセンサを体の一つ以上装着し、ウェアラブルセンサから得られるデータ信号をあらかじめ学習させた過去のデータと照合することで、「ユーザが何をしているのか」という行動の結果を得ることができる。特に、複雑な行動を対象としたシステムでは、手や足などの複数の体の部位の動きを取得するために、複数のウェアラブルセンサが用いられることが多い。過去のデータと照合を行う行動認識には、人間の行動に伴って観測できる動いた軌跡の規則性や習慣性から、行動パターンを識別する方法 [2] や、加速度データの平均と標準偏差を特徴抽出し、行動パターンのクラスごとに CART 型の分類木で識別する方法 [3] などがある。

しかし、実際には複数のウェアラブルセンサを使用する際に、1つ以上のウェアラブルセンサが、通信切断や故障するなどの事が原因で、データの取得が完全に途絶する場合がある。そうなると、あらかじめ学習させておいたセンサデータの数よりも、得られるセンサデータの数が減り、両データの互換性がなくなってしまい、適切に照合を行うことができなくなってしまう。この理由から、既存の行動認識技術の識別アルゴリズムは動作しなくなり、まったく行動認識が行えなくなるという問題が発生する。

このような照合アルゴリズムにおける欠損したデータの扱いは、統計的手法に基づいた音声認識技術 [4] の分野では研究されているが、行動認識の分野においてはあまり考慮されていない。近年、行動認識技術が普及しているなかで、欠損データへの対応は早急に解決すべき問題である。

センサが欠損した時に、データを補完し、識別アルゴリズムを動作させている研究として Hesam らの研究がある [6]。Hesam らの研究では、あらかじめ学習させている訓練データを基にして、正常に動作している分類器による、認識結果の各クラスの出力結果を用いて、欠損データと一致する分類器の認識結果の確率を行列計算で推定している。Hesam らの研究を用いれば、センサの欠損によって識別アルゴリズムが動作しない分類器が発生しても、正常に動作する分類器の結果を利用して、行動認識システムの欠損出力を補完し、行動認識を行うことが可能である。しかしながら Hesam らの研究では、あらかじめ分類器を2つ以上

用意する必要があり、分類器を1つだけ用いた行動認識を行った場合に、センサ欠損が発生してしまうと、正常に動作する分類器の出力が得られなくなるので、補完ができずに行動認識を行うことができなくなる問題が考えられる。

また、中島らはサンプリング周波数の低下によって生じる欠損データを補完し、認識精度を維持しつつ消費電力を削減できる手法を提案している [7]。しかし、この研究は、センサデータが完全にそろった状態でサンプリング周波数を疑似的に細かくすることを行っており、そもそもあるセンサについて、データ全体が欠如した状態を補完する方法ではない。

そこで本研究では、ウェアラブルセンサを用いた行動認識技術を対象とし、センサデータの補完方法を提案する。本研究で提案する手法では、行動認識に用いる特徴量を対象とし、データが欠損することによって計算が不可能となる特徴量を、正常に動作する他のセンサの特徴量に回帰させることで、回帰式を導いて補完する。具体的には、重回帰およびカーネル法を使用して、取得可能なセンサデータから欠損した特徴量を補完する。重回帰では、欠損したセンサデータの特徴量を目的変数に置き、正常に動作するセンサデータの特徴量を説明変数に置くことで、目的変数の特徴量ごとに線形回帰モデルを生成し、欠損データの特徴量の補完を行う。カーネル法では欠損したセンサデータの特徴量と、正常に動作するセンサデータの特徴量を、目的変数と説明変数に置き換えた後、特徴ベクトルを非線形写像し高次元の特徴空間で線形モデルを用いて、欠損データの特徴量の補完を行う。

以下、本論文では、2章で行動認識技術と問題点について述べ、3章で提案手法の原理と、本研究での扱い方を述べ、4章では評価実験の結果から提案手法の有用性を評価し、5章で得られた評価に対しての考察を述べ、6章で本論文のまとめを述べる。

## 2. 行動認識技術と問題点

一般に行われている行動認識の手法について述べる。行動認識技術において、加速度センサ、角速度センサといったウェアラブルセンサが1つ以上用いられる。各センサからは図1のように、加速度や角速度などのセンサデータを取得できる。取得したデータを、特徴量変換し、あらかじめ学習させている訓練データと照合を行うことで、ユーザは行動の認識結果を得ることができる。訓練データと照合を行う際の識別アルゴリズムには、機械学習の手法の一つである、教師あり学習のアルゴリズムが多く用いられている。訓練データには、特徴量のベクトル（特徴量ベクトル）と、その特徴量ベクトルに対応するラベル（行動認識では「走る」といった行動の内容）とのペアであらかじめ学習させる。そして、特徴ベクトルの全部あるいは一部の要素とラベルとの間の代表的な対応づけや、特徴ベクトルから判




図 1 行動認識  
 Fig. 1 Activity recognition

別のための式を導出する。そして、識別時には、正常に動作しているウェアラブルセンサから取得した、識別対象となる特徴ベクトルを上記のような既知の特徴ベクトルや判別式に当てはめてもっともらしいと思われるラベルを推定する。

しかしながら、既存の行動認識技術には複数のウェアラブルセンサを使用する際に、1つまたはいくつかのウェアラブルセンサが、通信切断や故障するなどの事が原因で、欠損したセンサからのデータ取得が完全に途絶する場合がある。そのような場合に行動認識を行おうとすると、あらかじめ学習させている訓練データと照合を行う際に、学習時と識別時のベクトルの次元数が変化してしまう。その結果、訓練データと正常に動作をしているセンサとの間に、行動認識技術に必要な特徴量の互換性がなくなり、照合そのものができなくなる。特徴量の全部を用いるようなアルゴリズムでは、識別アルゴリズムは全く動作しなくなる問題が発生する。訓練データと、ユーザに装着して取得するセンサデータとの間に互換性を保つためには、あらかじめ学習させてある訓練データの特徴量ベクトルの次元数と、同じ次元数の特徴量ベクトルを生成しなければならない。よって、ユーザは行動認識を行うことができなくなってしまう。

そこで、正常に動作するセンサから得られたセンサデータの特徴量を使って、欠損した特徴量の補完を行い、識別アルゴリズムの訓練データと互換性を持たせることができれば、欠損する前と同じように行動認識を行うことができる。つまり、特徴量補完を行えば、欠損しているセンサを、正常に動いているかのように扱うことができる。

### 3. 提案手法

本研究では、正常に動作するウェアラブルセンサから取得可能な特徴量に基づき、欠損特徴量を推定する手法を提案する。取得可能な特徴量と、欠損特徴量を変数として扱い、欠損特徴量を求める関係式(回帰式)を求めることによって、欠損特徴量を推定する

本研究では、多変量「線形」回帰として重回帰、多変量「非線形」回帰としてカーネル法を用いる。

表 1 データ構造

Table 1 Data structure

No.	$x_1$	$x_2$	...	$x_p$	$y$
1	$x_{11}$	$x_{12}$	...	$x_{1p}$	$y_1$
2	$x_{21}$	$x_{22}$	...	$x_{2p}$	$y_2$
⋮	⋮	⋮	⋮	⋮	⋮
$i$	$x_{i1}$	$x_{i2}$	...	$x_{ip}$	$y_i$
⋮	⋮	⋮	⋮	⋮	⋮
$n$	$x_{n1}$	$x_{n2}$	...	$x_{np}$	$y_n$

### 3.1 重回帰

重回帰は、単回帰を説明変数2つ以上に拡張した方法である。ここで、取り扱うデータ構造が表1のようになっていたと仮定すると、次のような重回帰モデルを生成できる。

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon_i \quad (1)$$

式(1)で示される重回帰モデルの式構造は、線形回帰モデルであることがわかる。このときの $y$ を目的変数、 $x$ を説明変数、 $\epsilon$ を誤差、 $\beta$ を回帰母数という。この時、説明変数が1つならば、線形モデルは2次元の構造を表すことができ、説明変数が2つならば、線形モデルは3次元の構造を表すことができるといったように、式モデルの説明変数に対する次元数をいくらでも増やすことができる。

重回帰を用いて補完を行うには、あらかじめ、欠損したセンサデータの特徴量を目的変数に置き、そのほかに正常に動作しているセンサデータの特徴量を説明変数に置いて、式(1)に当てはめることで、回帰母数のパラメータ $\beta$ の値を求めることができる。求められた回帰母数のパラメータ $\beta$ を式(1)に当てはめて、目的変数の各特徴量ごとに重回帰モデルの式を生成する。これにより目的変数の特徴量を説明変数の特徴量の値に基づいて、予測と制御を行い、補完する値を決定できる。しかし、重回帰では図2のように、生成することができるモデル式が、線形モデルになってしまうので、データ構造が単純な線形構造になっていない限り、各データごとに必ず誤差が生じる。つまり重回帰分析では、説明変数と目的変数が線形で表せない関係を持つ場合、予測誤差が大きくなるという問題がある。

### 3.2 カーネル法

カーネル法は、パターン認識に使われる手法のひとつで、判別分析などのアルゴリズムと組み合わせ利用される。カーネル法では、データ空間をカーネル関数と呼ばれる特殊な関数を使用して高次元空間へ写像する。このとき、一般に、写像する関数は非線形にデータ空間を写像する。これを特徴量抽出と呼ぶ(図3)。特徴抽出すると、高次元空間では線形モデルを当てはめられるようになる。その結果、もとのデータ空間では、非線形モデルを用いていることと同じ意味を持たせることができる。このとき生成できる




図 2 説明変数が 2 次元の重回帰分析  
 Fig. 2 Two dimensional multiple regression




図 3 特徴量抽出  
 Fig. 3 Extraction feature value

カーネル回帰モデルは、式 (2) のように表すことができる。

$$y_i = \sum_{i=1}^n \beta_i K(x_i, x) + \beta_0 \quad (2)$$

この時の  $K$  はカーネル関数を表す。

線形モデルでは、センサデータの特徴量のサンプルがいくら増えても直線に近似されてしまう。しかし、カーネル関数を使ったカーネル回帰モデルは、回帰母数  $\beta$  については線形性をもち、入力データである説明変数については非線形な関数を実現している。

カーネル法を用いて補完を行うには、重回帰と同じようにあらかじめ欠損したセンサデータの特徴量を目的変数に置き、そのほかに正常に動作しているセンサデータの特徴量を説明変数に置いて、式 (2) に当てはめることで、回帰母数のパラメータ  $\beta$  の値を求める。カーネル関数  $K$  には、多項式カーネルやガウスカーネルなどがある。カーネル関数によって、非線形モデルをより誤差の少ないモデルに近似させて、正常に動作するウェアラブルセンサから得られる説明変数である特徴量と求めた回帰母数のパラメータ  $\beta$  を用いて、欠損した特徴量の値を予測し補完を行う。

#### 4. 評価実験

提案手法の有用性を確認するために、実験を行った。重回帰とカーネル回帰のそれぞれの手法で回帰モデルを生成し、欠損したウェアラブルセンサの特徴量を補完した。それぞれの提案手法の有用性の評価において、補完前と補完



図 4 WAA-006  
 Fig. 4 WAA-006



図 5 ウェアラブルセンサの装着図  
 Fig. 5 Wearing of wearable sensors

後の認識精度を比較するために、適合率、再現率、F 値を用いた。

#### 4.1 実験環境

ウェアラブルセンサには図 4 の ATR-Promotions 社の小型無線ハイブリットセンサ WAA-006 を使用した [8]. WAA-006 は、X 軸、Y 軸、Z 軸の加速度センサと、X 軸、Y 軸、Z 軸の角速度センサを搭載している。また、Bluetooth による無線通信機能を搭載しているため、WAA-006 で観測した加速度データと角速度データを、PC などの Bluetooth ホストデバイスで、リアルタイムに受信することができる。本研究では、加速度と角速度の両データについての X 軸、Y 軸、Z 軸を観測データとして扱った。

ウェアラブルセンサを装着させる体の位置は、図 5 のように右手の甲、左手の甲、右足首、左足首、胸ポケット、腰の 6 か所とした。この理由としては、行動パターンが、どれだけ手の動きと足の動きに依存するのかを比較し、また、携帯電話に内蔵している加速度センサを使用した場合を想定するためである。

センサデータのサンプリングレートは100Hzとし、各センサからは、X軸、Y軸、Z軸の加速度と角速度の両データを受信した。各軸のセンサデータを、平均値と分散値の2種類に特徴量変換を行った。特徴量へ変換する際に、幅2560msecのスライディングウィンドウを使用した。また、スライディングウィンドウのずらし幅は、ウィンドウ幅の半分の1280msecとした。

被験者として、5名の大学生にセンサを装着してもらい、8種類の動作を含む約30分のシーケンスデータの作成を行った。

識別対象とする動作は、「Standing」のクラス名で、直立の姿勢で立ち続ける静止動作、「Walking」のクラス名で、行進をするように手を軽く振って歩く定常動作、「Running」のクラス名で、軽くジョギングをするように走る定常動作、「Skipping」のクラス名で、歩くよりかは早く移動するようにスキップをする定常動作、「Jumping」のクラス名で、その場で繰り返し跳躍をする定常動作、「Sitting」のクラス名で、椅子に腰かけて、座った状態を続ける静止動作、「Clapping」のクラス名で、立った状態で拍手をする定常動作、「CrossArm」のクラス名で、立った状態で腕を組み、そのままの状態にいる静止動作の8種類とした。

#### 4.2 実験方法

今回使用した学習データは、8種類の動作含むもので、その場から移動する動作パターンの作成方法については、「Walking」は手を通常よりも歩いていることを強調する為に大きく振って歩き、「Running」は手をしっかりと前後させて走り、「Skipping」はしっかりと手を振りながら高く跳びすぎないようにスキップして学習した。

1つのウェアラブルセンサからは、12種類の特徴量データが作成できる。6か所のセンサのうち、1つのセンサとのコネクションが切断した場合、切断したセンサから計算される各軸のセンサデータの平均値と分散値が失われるので、失った特徴量を目的変数として補完を行うため、提案手法を用いた。

提案手法の1つ目である重回帰分析については、オープンソースの統計解析向けプログラミング言語であるR言語を使用した。R言語で重回帰を行うことで、目的変数ごとの重回帰回帰モデルを生成した。

提案手法の2つ目であるカーネル法については、オープンソースのデータマイニングツールであるWekaを使用した[9]。今回は多項式カーネル関数を用いた、SMOregアルゴリズムを利用して、カーネル回帰モデルを生成した。

6か所のセンサが正常に動作している状態を「正常時」、6か所のセンサのうち1か所のセンサのコネクションを意図的に切断し、5つのセンサデータのみを用いた状態を「欠損時」、5つのセンサデータから、コネクションを切断したセンサのデータを、重回帰で補完を行った状態を「重回帰」、

カーネル法で補完を行った状態を「カーネル」とした。

また、それぞれの状態における、8種類の行動パターンごとの適合率、再現率、F値( $2 \times \text{適合率} \times \text{再現率} / (\text{適合率} + \text{再現率})$ )を算出し比較することで、提案手法が有用であるか評価と検討を行った。行動の識別には、WekaのSMOアルゴリズムによるSVMを用いた。

#### 4.3 実験結果

それぞれの手法で、被験者5人についての行動ごとの認識結果における適合率、再現率、F値について求めた後、5人の平均を算出した結果を、図6~図8に示す。

図6の結果から適合率を比較すると、「CrossArm」、「Jumping」、「Standing」の動作時において、欠損時よりも、提案手法によって欠損特徴量補完を行ったほうが、適合率が向上していることが確認できた。また、カーネル法ではさらに、「Sitting」の動作でも適合率の向上を確認できた。次に、図7の結果から再現率を比較すると、「Clapping」、「Sitting」の動作時において、欠損時よりも、提案手法によって欠損特徴量補完を行ったほうが、再現率が向上していることを確認できた。さらにカーネル法では、「CrossArm」、「Jumping」、「Skipping」の動作でも再現率の向上を確認できた。次に、図8の結果からF値を比較すると、「Clapping」、「CrossArm」、「Jumping」、「Sitting」、「Standing」の動作時において、欠損時よりも、提案手法を用いることで、F値の向上を確認できた。しかし、行動パターンの「Running」、「Walking」、「Skipping」についてのF値が、提案手法を用いても下がってしまったことも確認できた。

#### 5. 考察

今回の実験から、ウェアラブルセンサの故障などが原因で、センサデータが欠損してしまった時、提案手法を用いることで識別アルゴリズムを動作させることができた。さらに、8種類の動作を用いて検証を行うと、ウェアラブルセンサが6つのうち1つ欠損した場合、残りの正常に動作するセンサのみで行動認識を行うよりも、提案手法を用いて補完を行ったほうが、多くの行動パターンの適合率、再現率、F値を向上させることができた。具体的には、8種類の行動パターンのうち、「Clapping」、「CrossArm」、「Jumping」、「Sitting」、「Standing」の5種類のパターンでF値の向上が得られた。

しかし、「Running」、「Skipping」、「Walking」の行動パターンについては、補完方法を用いてもF値が向上しなかったことが確認できる。この理由として考えられるのは、あらかじめ学習させてある訓練データが、被験者の加速度データに相応しくなかったと考えられる。実験を考察すると、「Skipping」クラスにおいて、スキップの動作は、被験者によって動作に違いがあった。上に高く跳びながら




図 6 適合率グラフ

Fig. 6 Precision graph




図 7 再現率グラフ

Fig. 7 Recall graph




図 8 F 値グラフ

Fig. 8 F-Measure graph

スキップの動作をする者もいれば、手をあまり動かさずにスキップを行う者もいた。上に高く跳びながらスキップを行った被験者の動作の一部は、「Jumping」クラスとして識別されてしまった。また、ゆっくりとした動作でスキップを行った被験者の動作の一部は、「Walking」クラスとして識別されてしまった。「Running」の行動パターンについても同様に、大きく手を動かして走る被験者もいれば、手をあまり振らないで走る者もいた。ゆっくりと走る被験者の「Running」パターンの多くが、「Jumping」として認識されてしまった。「Jumping」として誤った認識が多かったために、図 8 の結果から、「Jumping」の行動パターンは、もっとも F 値が低い結果となってしまったと考えられる。今回使用した学習データは、基本となる模範行動のみ

を学習させていたため、その人の本来の動作パターンまでは学習させていなかった。このような事から、訓練データには、1 種類の動作パターンでも、あらゆる動作方法を想定して、学習をさせておくことで、適合率、再現率、F 値の低下を防ぐことができ、その訓練データから、重回帰分析における補完式、およびカーネル法における補完式を作成することで、補完後の認識精度の低下を防ぐことができると考えられる。

また、6 か所のセンサのうち、1 つのセンサが欠損している状態としては、6 パターンを考えられるが、それぞれの状態について、提案手法がどの程度有用であったか、各センサ部位による 5 人の行動ごとの F 値の平均を求めた結果を、図 9～図 14 に示す。

もっとも F 値が低かった「Jumping」の行動パターンについては、図 13 では、胸ポケットのセンサが欠損する前が 25.7%であったのに対して、欠損後は 95.3%まで向上した。「Jumping」のほか、「Clapping」、「Running」、「Sitting」、「Skipping」、「Standing」、「Walking」の行動パターンでも、欠損状態の認識精度のほうが、正常に動作している時よりも、高くなっていることが分かる。また、欠損からさらに提案手法で補完を行うことにより、欠損時よりも認識精度が高くなっていることから、あらかじめ学習させている胸ポケットに対する訓練データが、被験者にとってふさわしくなかったと考えられる。胸ポケットの学習データを作成するときには、動作時に、ポケットの中でセンサが傾いたり、裏返ったりしないように、センサにハンカチをあてることで固定を行った。同じように、被験者で実験を行う際にも、胸ポケットにハンカチを入れて、センサをポケット内で固定した。同じ環境をつくりだしているにもかかわらず、欠損した場合が F 値が良くなっていることから、一つの動作パターンでも、人によって異なる動作の特徴パターンがあり、特に胸ポケットに関しての訓練データを作成するには、その人ごとに学習させる必要があると考えられる。

次に提案手法の 2 つのうち、どちらがより優れた手法か確認するため、全体をまとめたときの適合率、再現率、F 値の平均を求めた。その結果を表 2 と図 15 に示す。

表 2 と図 15 の結果から、欠損時における適合率の平均が 70.0%であったのに対して、重回帰における欠損特徴量補完後の適合率の平均は 72.7%、カーネル法における欠損特徴量補完後の適合率の平均は 72.5%であった。適合率に関しては重回帰による手法のほうが優れていることが確認出来た。次に、欠損時における再現率の平均が 69.6%であったのに対して、重回帰における欠損特徴量補完後の再現率の平均は 68.8%、カーネル法における欠損特徴量補完後の再現率の平均は 69.8%であった。再現率に関してはカーネル法のほうが優れていることが確認できた。また、欠損時における F 値の平均が 69.8%であったのに対して、重回帰分析における欠損特徴量補完後の F 値の平均は 70.7%、カー




図 9 右手欠損時の F 値 (%)  
 Fig. 9 F-Measure of completing right hand(%)




図 12 左足欠損時の F 値 (%)  
 Fig. 12 F-Measure of completing left leg(%)




図 10 左手欠損時の F 値 (%)  
 Fig. 10 F-Measure of completing left hand(%)




図 13 胸ポケット欠損時の F 値 (%)  
 Fig. 13 F-Measure of completing chest pocket(%)




図 11 右足欠損時の F 値 (%)  
 Fig. 11 F-Measure of completing right leg(%)




図 14 腰欠損時の F 値 (%)  
 Fig. 14 F-Measure of completing waist(%)

ネル法における欠損特徴量補完後の F 値の平均は 71.1%であった。F 値に関してもカーネル法のほうが優れていることが確認出来た。F 値の結果から、全体ではカーネル法による特徴量補完法が、より有用であったと考えられる。

## 6. おわりに

本論文では、複数のウェアラブルセンサを用いた行動認

識技術において、センサの通信切断や故障により、識別アルゴリズムが動作しなくなる問題を、欠損したウェアラブルセンサデータの特徴量を補完することで解決した。欠損特徴量の補完方法として、重回帰分析を用いる方法とカーネル法を用いる方法の 2 種類を提案した。

重回帰モデルとカーネル回帰モデルでは、あらかじめウェアラブルセンサ 6 つが正常に動作するときの特徴量を

表 2 全体の平均 (%)  
 Table 2 Mean of all probability (%)

	適合率	再現率	F 値
欠損時	70.0	69.6	69.8
重回帰	72.7	68.8	70.7
カーネル	72.5	69.8	71.1




図 15 全体の平均グラフ  
 Fig. 15 Mean graph of all probability

求めておき、仮想的にウェアラブルセンサの欠損状態をつくりだす時に、欠損したセンサの特徴量を目的変数に置き、残りの正常に動作するセンサの特徴量を説明変数に置くことで、重回帰による線形回帰モデルおよびカーネル法による非線形回帰モデルを生成した。結果的に、重回帰を用いる欠損特徴量補完法と、カーネル法を用いる欠損特徴量補完法の両方で、認識精度を向上させることができた。また、全体の F 値の平均を求めたところ、欠損時では 69.8%、重回帰では 70.7%、カーネル法では 71.1%であったことから、重回帰よりもカーネル法のほうがより特徴量補完法として有用であった。

今後の課題としては、あらかじめ学習させる訓練データをより多くのデータから学習させ、重回帰とカーネル法でより最適な回帰モデルを作成し、行動パターンを増やした時の適合率、再現率、F 値が向上できるか検証を行い、欠損したセンサの数を増やした時に、提案手法は有用であるか検討を行う必要があると考えられる。

#### 参考文献

- [1] Miyamae, M., Kishino, Y., Terada, T., Tsukamoto, M. and Nishio, S.: An Event-driven Navigation Platform for Wearable Computing Environments, in it Proc. of the 9th IEEE International Conference on Wearable Computers, pp.100-107(2005)
- [2] 青木 茂樹, 大西 正輝, 小島 篤博, 福永 邦雄.: HMM による行動パターン認識, 電子情報通信学論文誌, Vol. 7, pp.1265-1270(2002).
- [3] 佐藤 誠, 森田 千絵, 土井 美和子.: 生体データと加速度データを用いた行動認識, 情報処理学会全国大会講演論文集, Vol. 65, pp.239-242(2003)
- [4] 後藤 真孝, 伊藤 克亘, 秋葉 友良, 速水 悟.: 音声補完: 音声入力インタフェースへの新しいモダリティの導入, イ

ンタラクティブシステムとソフトウェア VIII, 近代科学社, pp.153-162(2000).

- [5] 大内 一成, 土井 美和子.: 加速度と音で日々の生活行動を認識する ActivityAnalyzer, インタラクション 2011, 1CR3-7(2011)
- [6] Hesam Sagha, José del R. Millán and Ricardo Chavarriaga.: A Probabilistic Approach to Handle Missing Data for Multi-Sensory Activity Recognition, *UbiComp '10, Opportunistic Ubiquitous Systems-50-*, W14(2010).
- [7] 中島悠貴, 村尾和哉, 寺田努, 塚本昌彦.: サンプル制御とデータ補完による行動認識システムの省電力化手法, 情報処理学会論文誌ジャーナル, Vol.52 No.8 Page.2455-2466.
- [8] ATR-Promotions: 小型ハイブリッドセンサ WAA-006, 入手先 (<http://www.atr-p.com/sensor06>) (参照 2012-03-29).
- [9] University of Waikato.: Weka, available from (<http://www.cs.waikato.ac.nz/ml/weka/>) (accessed 2012-03-29).