

ARAR アルゴリズムによる欠損データ補完を用いた ウェアラブルセンサ行動認識技術の耐故障性向上

内田 稜真^{a)} 堀野 豊人^{b)} 大村 廉^{c)}

概要: ウェアラブルセンサを用いた行動認識技術において、既存の行動認識技術では、通信切断やセンサの故障などにより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、識別アルゴリズムは動作しなくなり、まったく行動認識ができなくなるという問題が存在する。そこで本研究では、センサデータが欠損した時、その直前のセンサデータを利用して欠損データの補完を行うことで、正しく行動認識を行えるようにする手法を提案する。具体的には、センサデータの欠損が生じた場合、それまでに得られたセンサデータの時系列から ARAR モデルを作成し、欠損データの値を予測し補完を行う。提案手法の有用性を確認する為ために、評価実験を行った。正常に取得できた過去の 256 サンプルのセンサデータをもとに、1~5window 先のセンサデータの値を提案手法より予測し補完を行った。欠損データを補完しない場合では F 値の認識率が 73.4%であったのに対し、1~2window 分が生じた場合は、提案手法によって予測精度を 76.8%に引き上げることができた。

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 using Completing Defective Value by ARAR Algorithm

Abstract: Existing wearable sensor-based activity recognition techniques are lack of fault tolerance in case of sensors data loss, such as communication disconnection and sensor failure. Our study proposes a method to compensate the missing sensor data using ARAR algorithm. ARAR algorithm is an algorithm to predict future data from existing sequence data, applying memory shortening transformation and fitting AR model to the transformed data, and is known as good prediction performance in many sequence data. In our proposed method, an ARAR model is created from obtained sensor data when data is lost. Then, missing data is compensated by the model for making the succeeding recognition work normally. We had some experiments to verify the usefulness of proposed methods. Specifically, the prediction performance was evaluated by applying the ARAR compensation to one to five succeeding windows. F-Measure rate is 73.4% in case of sensors data loss. Our method's F-Measure rate of ARAR compensation to one and two succeeding window are improved to 76.8%.

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

1. はじめに

ユビキタス社会の到来により、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、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、重要な要素技術のひとつである。ウェアラブルセンサを用いたコンテキストウェアシステムの例として、例えば、飛行機の整備士、歩行支援システム、ライフログ、ウェイトとレーニング支援システム、農業支援システム、健康管理システムなどが行われている [1], [2], [3].

ウェアラブルセンサを用いた行動認識技術は、図 1 のよ

¹ 豊橋技術科学大学大学院
Toyohashi University of Technology

a) ryoma@usl.cs.tut.ac.jp

b) horino@usl.cs.tut.ac.jp

c) ren@tut.jp

うに動作する。まず、一般に加速度センサや角速度センサを体に一つ以上装着し、これらのセンサから得られる加速度や角速度といったデータ信号を取得する。取得したデータを窓関数にかけて時系列で分割し、各ウィンドウごとに特徴量変換を行う。そして、取得した特徴量とあらかじめ学習し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。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を用いることが多い。過去のデータと照合を行う方法では、機械学習による手法が一般に用いられる [4], [5]。この時、訓練データと、ユーザに装着したセンサから取得するセンサデータとの互換性を保つために、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。

しかし、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数よりも得られるセンサデータの数が減り、特徴量ベクトルの次元数が変化する。その結果、両データの互換性が無くなるため、適切に照合を行うことができなくなってしまいう状況が発生する。つまり、センサデータの一部の欠落によ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。

データ取得が途絶し欠損データが発生した場合、行動認識システムでは、欠損データの値を補完することで問題が解決できる。図1の行動認識システムにおいて欠損データの補完は、識別アルゴリズムを動作させる時の識別器レベル、センサデータの特徴抽出を行う時の特徴量レベル、センサデータを受信した時の波形レベルで対応が可能と考えられる。まず、識別器レベルでの対応には、既存研究として Hesam らの研究 [7] がある。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もとにして、正常に動作している識別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識別器の認識結果の確率を推定している。しかし、Hesam らの研究では、あらかじめ識別器を2つ以上用意する必要があるうえに、認識結果の確率を推定するとき、多くの計算量を必要とする。

次に特徴量レベルでの補完を行う研究として [9] や [10] がある。[9] では、複数のウェアラブルセンサを用いることを前提とした行動認識システムにおいて、重回帰またはカーネル回帰で欠損特徴量の値を補完している。しかしながら、ウェアラブルセンサを1つのみ使用する行動認識システムには、手法を適用することができないという問題がある。また、村尾らの研究 [10] は欠損データへの対応が目的でなく省電力化を目的としたものであるが、重要度の低いセンサ、消費電力の大きなセンサ、精度の低いセンサを意図的に電源切断させ、受信での電力消費を抑えている。こ

の時、電源切断したことで受信データが不完全ケースとなるので、疑似データをつくり、受信しているように見せかけ、次元数の変化と認識精度の低下を防いでいる。この手法では、あらかじめすべてのセンサが正常に動作している時のセンサデータを記録しておき、欠損させるセンサデータについて、通常動作するセンサの値を元にデータベースから、過去にもっとも近い値を取得し、そのまま欠損した値に置き換える。しかし、この手法は補完する値が固定されてしまい、未知のデータに対応できないことと、[9] 同様、センサを1つのみ用いる行動認識システムには適用できない問題がある。

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、使用するウェアラブルセンサの数に固定されないでセンサデータを補完する方法を提案する。本研究で提案する手法では、センサデータが欠損した時、その欠損前のセンサデータから欠損データの補完を行うことで、正しく行動認識を行えるようにする。具体的には、ARAR アルゴリズムを用いてセンサデータの補完を行う。ARAR アルゴリズムは、既得の系列データに対して記憶短期化変換を適用し、変換された系列にサブセット AR モデルを当てはめることで将来のデータを予測する手法であり、精度の高い予測が可能であることが知られている。

以下、本論文では、2章で提案手法の原理と、本研究での扱い方を述べ、3章では評価実験の結果から提案手法の有用性を評価し、4章で得られた評価に対して考察を述べ、5章で本論文のまとめを述べる。

2. 提案手法

本研究では、センサデータが欠損した時、その直前のセンサデータから欠損データの補完を行うことで正しく行動認識を行えるようにする手法を提案する。具体的には、欠損する前の過去の正常なセンサデータから現在欠損しているセンサデータの値を推定し補完を行う。

図2のようにセンサデータが途絶した場合、正常に取得した過去の実線のセンサデータを用いて、点線のように欠損してしまったセンサデータを推定し補完を行う。欠損データを推定する方法としては、過去のセンサデータの関係から回帰式を生成し、欠損データを回帰補完をする。本研究では、回帰式を生成する方法として ARAR アルゴリズムを用いる。

2.1 ARAR アルゴリズム

ARAR アルゴリズムは直前のデータの時系列から将来のデータの時系列を予測する手法である。文献 [11] に基づき、以下、ARAR アルゴリズムの概略を説明する。

ARAR アルゴリズムは、正常に取得できた過去のセンサデータの時系列が、発散するような長期記憶的なデータであるなら記憶短期化変換を適用し、有限確定な短期記憶的




図 1 行動認識システム

Fig. 1 Activity recognition system




図 2 提案手法のイメージ

Fig. 2 Image of proposed method

なセンサデータの時系列に変換できたら、サブセット AR モデルを当てはめる。サブセット AR モデルは一般的な AR モデルと違い、AR モデルの一部のみを使用する。今回は、説明変数を 4 つ使用したサブセットとした。生成されたサブセット AR モデルを用いることで、欠損したセンサデータの値を推定し補完を行う。以下、より詳細な説明を行う。

ARAR アルゴリズムでは、はじめに過去のセンサデータの時系列が発散するような長期記憶的なデータであるか有限確定な短期記憶的であるかを判別する。長期記憶的であるか、短期記憶的であるかを判別し、長期記憶的であった場合に、センサデータの時系列を短期記憶的に変換するために、文献 [11] を参考にして以下のアルゴリズムに当てはめる。まず、 $\tau=1,2,\dots,15$ のそれぞれについて、式 (1) に当てはめる。

$$f(\phi, \tau) = \frac{\sum_{t=\tau+1}^n [Y_t - \phi Y_{t-\tau}]^2}{\sum_{t=\tau+1}^n Y_t^2} \quad (1)$$

この時の ϕ は係数をあらわし、 Y_t は過去の正常なセンサデータの値を用いる。 $\tau=1,2,\dots,15$ のなかで、最も式 (1) が最小となる時の係数 ϕ の値を $\hat{\phi}(\tau)$ とおく。次に、 $\hat{\phi}(\tau)$ を用いて $\tau=1,2,\dots,15$ をそれぞれ式 (2) へ代入する。

$$f(\hat{\phi}(\tau), \tau) = \frac{\sum_{t=\tau+1}^n [Y_t - \hat{\phi}(\tau) Y_{t-\tau}]^2}{\sum_{t=\tau+1}^n Y_t^2} \quad (2)$$

この時、式 (2) が最小となる $\tau=1,2,\dots,15$ のいずれかの値を $\hat{\tau}$ とし、以下のいずれかの条件に当てはめ、長期記憶的、少々長期記憶的、短期記憶的に分類する。

- $\frac{\sum_{t=\hat{\tau}+1}^n [Y_t - \hat{\phi}(\hat{\tau}) Y_{t-\hat{\tau}}]^2}{\sum_{t=\hat{\tau}+1}^n Y_t^2} \leq 8/n$ ならば、過去のセンサデータの時系列が長期記憶的であると判別し、式 (3) を用いて過去のセンサデータを記憶短期化変換して、時系

列データ $\{\tilde{Y}_t\}$ を構成する。

- $\hat{\phi}(\hat{\tau}) \geq 0.93$ かつ $\hat{\tau} > 2$ ならば長期記憶的である判別し、式 (3) を用いて過去のセンサデータを短期記憶化変換して、時系列データ $\{\tilde{Y}_t\}$ を構成する。
- $\hat{\phi}(\hat{\tau}) \geq 0.93$ かつ $\hat{\tau}=1$ または 2 ならば、 $\sum_{t=3}^n [Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2}]^2$ を最小にする ϕ_1 と ϕ_2 の値 $\hat{\phi}_1, \hat{\phi}_2$ を求め、過去のセンサデータの時系列が少々長期記憶的であるとして、式 (4) を用いて短期記憶化変換を行い、時系列データ $\{\tilde{Y}_t\}$ を構成する。
- $\hat{\phi}(\hat{\tau}) < 0.93$ ならば過去のセンサデータの時系列が短期記憶的であると判定する。

$$\tilde{Y}_t = Y_t - \hat{\phi}(\hat{\tau}) Y_{t-\hat{\tau}} \quad (3)$$

$$\tilde{Y}_t = Y_t - \hat{\phi}_1 Y_{t-1} - \hat{\phi}_2 Y_{t-2} \quad (4)$$

ここで、過去のセンサデータの時系列を短期記憶化変換している場合は、変換後の時系列データが、短期記憶的であるか、長期記憶的であるかを判別するために、アルゴリズムに当てはめる。これは、変換後のセンサデータの時系列が短期記憶的であると判定されるまで、繰り返し行われる。変換された過去のセンサデータの時系列 $\{\tilde{Y}_t\}$ が、有限確定な時系列であり短期記憶的であると判定されたのならば、つぎにサブセット AR モデル (自己回帰モデル) の式を生成する。

サブセット AR モデルを生成するためにまず、過去のセンサデータ $\{Y_t\}$ の時系列を記憶短期化変換して得た、短期記憶的なセンサデータの時系列を $\{S_t, t = k+1, \dots, n\}$ とする。また、 \bar{S} を S_{k+1}, \dots, S_n の標本平均とおく。平均値を調整したセンサデータの時系列を

$$X_t = S_t - \bar{S} \quad (t = k+1, \dots, n) \quad (5)$$

と置くことができる。この時系列に対してサブセット AR モデルを当てはめる。あてはめるモデルの形は、 $\{Z_t\} \sim WN(0, \sigma^2)$ として式 (6) となる。

$$X_t = \phi_1 X_{t-1} + \phi_{l_1} X_{t-l_1} + \phi_{l_2} X_{t-l_2} + \phi_{l_3} X_{t-l_3} + Z_t \quad (6)$$

ただし、 $1 < l_1 < l_2 < l_3$ とする。与えられたラグ l_1, l_2, l_3 に対し、係数 ϕ_j はユール・ウォーカー方程式 (7)

$$\begin{bmatrix} 1 & \hat{\rho}(l_1-1) & \hat{\rho}(l_2-1) & \hat{\rho}(l_3-1) \\ \hat{\rho}(l_1-1) & 1 & \hat{\rho}(l_2-l_1) & \hat{\rho}(l_3-l_1) \\ \hat{\rho}(l_2-1) & \hat{\rho}(l_2-l_1) & 1 & \hat{\rho}(l_3-l_2) \\ \hat{\rho}(l_3-1) & \hat{\rho}(l_3-l_1) & \hat{\rho}(l_3-l_2) & 1 \end{bmatrix} \begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \hat{\phi}_3 \end{bmatrix} = \begin{bmatrix} \hat{\rho}(1) \\ \hat{\rho}(l_1) \\ \hat{\rho}(l_2) \\ \hat{\rho}(l_3) \end{bmatrix} \quad (7)$$

から求めることができ、さらにホワイトノイズの分散 σ^2 は

$$\sigma^2 = \hat{\gamma}(0)[1 - \phi_1\hat{\rho}(1) - \phi_{l_1}\hat{\rho}(l_1) - \phi_{l_2}\hat{\rho}(l_2) - \phi_{l_3}\hat{\rho}(l_3)] \quad (8)$$

より求められる。ただし $\hat{\gamma}(j)$, $\hat{\rho}(j)$, $j = 0, 1, 2, \dots$ は, $\{X_t\}$ の標本自己共分散と標本自己相関関数である。

記憶短期化で得られた記憶短期化フィルタが係数 $\psi_0 (=1), \psi_1, \dots, \psi_k$, ($k \geq 0$) をもつとき、記憶短期化済み系列は式 (9) のように表される。

$$S_t = \psi(B)Y_t = Y_t + \psi_1 Y_{t-1} + \dots + \psi_k Y_{t-k} \quad (9)$$

ただし $\psi(B)$ は、遅延演算子の多項式 (10) である。

$$\psi(B) = 1 + \psi_1 B + \dots + \psi_k B^k \quad (10)$$

同様に、サブセット AR モデルを当てはめるとき、サブセット AR モデルの係数が $\phi_1, \phi_{l_1}, \phi_{l_2}, \phi_{l_3}$ ならば、平均調整済み系列 $\{X_t = S_t - \bar{S}\}$ に対する AR モデルは式 (11) となる。

$$\phi(B)X_t = Z_t \quad (11)$$

ただし, $\{Z_t\} \sim WN(0, \alpha^2)$ であり, $\phi(B)$ は式 (12) である。

$$\phi(B) = 1 - \phi_1 B - \phi_{l_1} B^{l_1} - \phi_{l_2} B^{l_2} - \phi_{l_3} B^{l_3} \quad (12)$$

である。式 (9) と式 (11) より、

$$\xi(B) = \psi(B)\phi(B) = 1 + \xi_1 B + \dots + \xi_{k+l_3} B^{k+l_3} \quad (13)$$

とおくと

$$\xi(B)Y_t = \phi(1)\bar{S} + Z_t \quad (14)$$

を得る。サブセット AR モデル式は式 (14) と表せる。それぞれの t に対しホワイトノイズ項 Z_t が $\{Y_j, j < t\}$ と無相関であると仮定すると, $n > k + l_3$ に対し, $\{1, Y_1, \dots, Y_n\}$ による Y_{n+h} の最小平均二乗誤差線形予測量 $P_n Y_{n+h}$ を漸化式 (15) を生成できる。 $\phi(1)$ は (12) において $B = 1$ を当てはめる。

$$P_n Y_{n+h} = \sum_{j=1}^{k+l_3} \xi_j P_n Y_{n+h-j} + \phi(1)\bar{S} \quad (h \geq 1) \quad (15)$$

ただし、初期条件は $h \leq 0$ に対し

$$P_n Y_{n+h} = Y_{n+h} \quad (16)$$

である。

本実験では、式 (15) を用いて、欠損したセンサデータの値を予測する。 $P_n Y_{n+h}$ を推定する欠損データの値, ξ_j を回帰係数, $P_n Y_{n+h-j}$ を予測する欠損データよりも過去のセンサデータ, \bar{S} を記憶短期化して得られた過去のセンサデータの時系列の標本平均を当てはめて、欠損したセンサデータを補完する。



図 3 WAA-006
Fig. 3 WAA-006

3. 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。提案手法の予測精度を求めるため ARAR アルゴリズムによって 1~5 ウィンドウ先を予測した時の認識精度をそれぞれ求めた。提案手法の有用性の評価では、補完前と補完後の認識精度を比較するために、適合率と再現率を求め、それぞれの調和平均の F 値を用いた。

3.1 実験環境

ウェアラブルセンサには図 3 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 [13]。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ので、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、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。

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、7 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、表 (1) のように 7 種類の行動パターンとした。

3.2 実験方法

今回使用した学習データは、7 種類の動作を含んだ、約 10 分のシーケンスデータを使用した。1 つのウェアラブルセンサから、12 種類の特徴量データが作成できる。6 か所

表 1 識別する行動の種類

Table 1 The kind of activity

行動の種類	動作内容
Standing	直立姿勢での静止動作
Walking	手を軽く振って歩く定常動作
Running	ジョギング程度の速さで走る定常動作
Skipping	歩くよりは速くスキップする定常動作
Sitting	椅子に腰をかけて座り続ける静止動作
Clapping	直立状態で拍手する定常動作
CrossArm	直立状態で腕を組み続ける静止動作




図 4 1~2 ウィンドウ先の予測

Fig. 4 Prediction from 1 to 2 window point

のセンサのうち、1つのセンサとの接続が切断したと仮定し、切断したと仮定するセンサから得られる各軸のセンサデータの加速度、角速度の値を提案手法を用いて補完した。

提案手法の有用性を確認するために、7種類の行動パターンごとの適合率と再現率を求め、それぞれの調和平均であるF値を算出し、比較することで検討を行った。行動の識別には、オープンソースのデータマイニングツールであるWeka[14]のSMOアルゴリズムによるSVMを用いた。

$$F - measure = \frac{2 * Precision * Recall}{Precision + Recall} \quad (17)$$

3.3 実験結果

ARARアルゴリズムによる補完方法を用いて、1~5window先のセンサデータの値の推定を行った。推定の仕方は図4のように、1window先の予測は実線部分のみのウィンドウから提案手法によって次の実線と点線を含むウィンドウのセンサデータの値を推定したときの認識精度を求めた。また、2window先の予測は実線と点線を含むウィンドウから、点線のみを含むウィンドウのセンサデータの値を予測したときの認識精度とした。同じように、3window先、4window先、5window先とセンサデータの予測を行い、それぞれの認識精度を求めた。今回使用し正常な過去のセンサデータである実線部分のウィンドウについては、正常に取得できていた過去のセンサデータ256サンプルを使用した。これは、欠損して行動認識できなくなった現在のウィンドウの直前の1window分のセンサデータを用いることに相当する。

今回は、6個のセンサをすべて使用し、センサデータの欠損が全くない状態を正常時とした。また、欠損したと仮

定する1個のセンサがあらかじめ存在しないものとし、残りの5個のセンサデータのみを用いて識別器を学習させ、被験者の5個のセンサデータを用いて、行動認識を行った場合を欠損時とした。次に提案手法を用いて推定補完をした場合をそれぞれのウィンドウの数として認識精度の比較を行った。

具体的な認識精度の結果について、部位ごとのセンサを分けたものを図5~図10に示す。両手首の甲と両足首のセンサについて、認識精度は、1window先、2window先までの予測であれば、提案手法の認識精度が向上していることが分かった。胸ポケットのセンサの結果をみると提案手法よりも欠損時であるセンサ5個による行動認識のほうが認識精度が良くなっていた。腰の位置にあるセンサの結果をみると、腰の位置のセンサの1window先および2window先までの予測については、欠損時とほぼ変わらない認識精度となったことが分かる。

4. 考察

部位ごとで認識精度の結果を比較し、どの部位であれば提案手法が有用であり、全体的には補完したほうが良いのか、また、補完した場合はどれほど先まで予測が可能かを考察する。

まず、各部位ごとで提案手法が有用であるか考察する。左手の甲、右手の甲、右足首、左足首のセンサについては提案手法を用いることで、センサの数を減らして行動認識を行うよりも、認識精度を向上させることができると分かった。両手首と両足首については加速度の変化が大きいため、部位ごとに特徴が出やすいということから、ARARアルゴリズムで作成できるモデル式が、非常に精度が高く作成できているということが分かる。よって、加速度の変化が大きい部位については、1window先までの予測、2window先までの予測については提案手法による補完方法が有用であると分かる。しかしながら、3window先、4window先、5window先までの予測を行うと、どの部位でも認識精度が非常に悪くなっていることが分かる。つまり、予測した時系列から、さらに予測を繰り返していくということは、非常に難しいことを示しており、その結果認識精度が下がっていると考えられる。予測した時系列のセンサデータが悪ければ、その悪いセンサデータからさらに次を予測するということになるので、認識精度が下がることは自然であると考えられる。

図9は、胸ポケットのセンサの認識精度を示しているが、6個すべてのセンサを使った正常時よりも胸ポケットのセンサ1個を減らした欠損時である行動認識のほうが、認識精度が良くなってしまった。この原因は、被験者が実験の動作をしても、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当てるなどして固定を行ったのだが、被験者の実験終了時に胸ポケットのセ




図 5 左手の甲センサの認識精度 (%)
 Fig. 5 F-measure of left arm(%)




図 8 右足首センサの認識精度 (%)
 Fig. 8 F-measure of right ankle(%)




図 6 右手の甲センサの認識精度 (%)
 Fig. 6 F-measure of right arm(%)

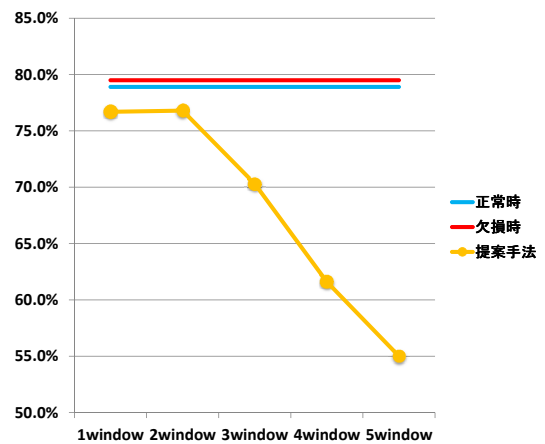


図 9 胸ポケットのセンサの認識精度 (%)
 Fig. 9 F-measure of chest pocket(%)




図 7 左足首センサの認識精度 (%)
 Fig. 7 F-measure of left ankle(%)




図 10 腰センサの認識精度 (%)
 Fig. 10 F-measure of waist(%)

ンサを確認すると、センサの向きが傾いていたり、逆さまになっていた被験者がいた。このことから6個すべてのセンサを使用した行動認識では、胸ポケットのセンサデータが認識精度を下げていると考えられる。また、提案手法を利用してセンサデータの補完を行うと、欠損時よりも認識

精度が低下してしまっていることが分かった。提案手法で欠損データを予測し補完する場合は、センサが傾いた場合、逆さまになった場合の過去のセンサデータを用いて、欠損した胸ポケットのセンサデータの予測を行うことは難しいと考えられる。よって、しっかりと固定できない場所につ

表 2 全体の平均 (%)

Table 2 Mean of all probability (%)

	正常時	欠損時	1window	2window	3window	4window	5window
F 値	78.9	73.4	76.8	76.8	69.2	61.2	54.9




図 11 全体の平均グラフ

Fig. 11 Mean graph of all probability

いては、提案手法が有用に活用できないと分かった。

腰の位置にセンサを固定した場合の認識精度について、腰の位置というのは、スマートフォンを、ズボンのポケットに入れたことを想定している。この結果、センサの数を減らしてそのまま行動認識を行う方法と、提案手法で、センサデータを補完する方法については1window先および、2window先までの予測までほとんど変化がないことが分かった。腰ポケットのセンサが切断し、データが欠損してしまった場合は、センサを除外してセンサの数を減らした学習データで行動認識を行うか、または補完方法を用いて同じ学習データで行動認識を行う場合でも、どちらも認識精度に変化がないと考えられる。

次に、全体的に提案手法が有用であったかを確認するために、提案手法で、被験者5人のF値の平均を算出した結果を図11と表2に示す。

全体の認識精度の比較を行った結果、正常時では認識精度のF値が78.9%であったのに対し、ひとつのセンサのコネクションが切断された場合にセンサの数を減らした学習データで行動認識を行った欠損時が73.4%まで下がっていることが確認出来た。しかし、我々の提案手法を適用することで、推定された値で補完を行うと、2window先まで予測を行えば、76.8%と、センサの数を減らして行動認識を行う欠損時より認識精度が良くなることが確認出来た。よって提案手法は、2window先までの予測に有用であると考えられる。しかし、3window先まで予測を行うと69.2%、4window先まで予測を行うと61.2%、5window先まで予測を行うと54.9%と、いずれも欠損時よりも認識精度が下がることが確認出来た。このことから、予測した値から、さらに予測を行うことは難しいと分かる。

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、センサ6個のうち1個のセンサが欠損した場合、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1window先または2window先まで予測して補完を行ったほうが、F値を向上させることができた。

本研究の提案手法は、加速度、角速度の生データレベルでの補完を行うことで、比較的短時間のセンサデータの欠損であれば、高精度の補完が行えることがわかった。一方、データの欠損時間が長ければ長いほど認識精度は低下してしまう。このことから、センサの通信切断による比較的短時間のセンサデータの欠損であれば提案手法を用いた行動認識は有効であるが、センサの故障によって長時間センサデータが欠損すると考えられる状況であれば、例えば、関連研究として挙げた手法などを組み合わせ、他の補完方法を用いた方が有効であると考えられる。つまり、通信切断している時間の長さによって、補完方法を用いるレベルを切り替え、補完方法も同時に使い分けることで、より耐故障性が向上した行動認識が可能になると考えられる。

5. おわりに

本論文では、行動認識技術において、使用するウェアラブルセンサの数に関係なく、センサの通信切断や故障などにより、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の加速度、角速度のデータを補完することで解決した。補完方法としてはARARアルゴリズムを用いて、回帰モデルを作成し、値を推定する方法を提案した。

ARARアルゴリズムでは、ウェアラブルセンサが欠損する直前の、正常に受信できていた過去のデータをもとに、短期記憶化変換を行った後、サブセットARモデルを生成した。結果的に、1window先の予測及び、2window先の予測までは認識精度を向上させることができた。また全体的にF値の平均を確認してみると、センサが欠損してしまった場合は73.4%であったのに対して、1window先までを予測していくと76.8%、2window先までを予測していくと76.8%と、認識精度が3.0%以上向上していることから、短時間であればARARアルゴリズムを用いて補完を行ったほうがより有用であった。

今後の課題としては、行動の種類をさらに増やし、より実用的で複雑な行動パターンでの検証が必要であると考えられる。また、欠損時間によって補完方法を切り替えることによって、さらに高精度の行動認識を行えるかという検証が必要であると考えられる。

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] Keng-hao Chang, Mike Y. Chen, and John Canny.: Tracking Free-Weight Exercises, 9th International Conference on Ubiquitous Computing(UbiComp2007), pp.19-37(2007).
- [3] Ouchi, K., Suzuki, T. and Doi, M.: LifeMinder: A Wearable Healthcare Support System Using User's Context, IEEE International Workshop on Smart Appliances and Wearable Computing(IWSAWC 2002), pp.791-792(July 2002).
- [4] 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).
- [5] 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).
- [6] 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).
- [7] 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).
- [8] Zhen-Yu, Lian-Wen Jin.: Activity Recognition From Acceleration Data Using AR Model Representation and SVM, Proceedings of the Seventh International Conference on Machine Learning and Cybernetics, Kunming(ICMLC 2008), pp.2246-2250(2008)
- [9] 内田 稜真, 大村 廉.: 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, 研究報告ユビキタスコンピューティングシステム (UBI), Vol.2012-UBI-34, No.31.
- [10] 村尾 和哉, 竹川 佳成, 寺田 努, 西尾 章治郎.: ウェアラブルコンピューティングのためのセンサ管理デバイスの設計と実装, 情報処理学会論文誌, Vol.49, pp.3327-3339(2008).
- [11] P.J. ブロックウェル, R.A. デービス 著, 「時系列解析と予測」, シーエービー出版.
- [12] 田中 勝人 著, 「現代時系列分析」, 岩波書店出版.
- [13] 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 2013-02-04).
- [14] University of Waikato.: Weka, available from (<http://www.cs.waikato.ac.nz/ml/weka/>) (accessed 2013-02-04).