

# ウェアラブルシステムのための装着型センサの故障を考慮した センシングデータ補完手法

村尾 和哉<sup>†</sup> 竹川 佳成<sup>†</sup> 寺田 努<sup>††</sup> 西尾章治郎<sup>†</sup>

<sup>†</sup> 大阪大学大学院情報科学研究科 〒565-0871 大阪府吹田市山田丘 1-5

<sup>††</sup> 大阪大学サイバーメディアセンター 〒567-0047 大阪府吹田市美穂ヶ丘 5-1

E-mail: <sup>†</sup>{muraao.kazuya,takegawa,nishio}@ist.osaka-u.ac.jp, <sup>††</sup>tsutomu@cmc.osaka-u.ac.jp

あらまし 近年、コンピュータを装着して常時利用するウェアラブルコンピューティングへの注目が高まっている。ウェアラブル環境では、複数のセンサを装着することでシステムはユーザの状況（コンテキスト）を認識して状況に応じたサービスを提供するが、常時センサを装着して生活するため衝撃や水分などでセンサが頻繁に故障したり異常値を発生させる。既存の状況認識（コンテキストウェア）システムの研究の多くは、認識精度の向上に着目しているものが多いが、センサの故障により認識精度は大幅に低下する。そこで、本研究ではセンサの故障を考慮したコンテキストウェアシステムのためのセンシングデータ補完手法を提案する。提案手法では、通常動作時にセンシングデータの組を学習させておくことで、故障時にセンシングデータを補完して認識精度の低下を抑える。提案手法を用いることで、信頼性の高いコンテキストウェアシステムが構築できる。

キーワード ウェアラブルコンピュータ、コンテキストウェアネス、データ補完

## A Sensed Data Complementing Method Considering Breakdowns of Wearable Sensors for Wearable Computing Systems

Kazuya MURAO<sup>†</sup>, Yoshinari TAKEGAWA<sup>†</sup>, Tsutomu TERADA<sup>††</sup>, and Shojiro NISHIO<sup>†</sup>

<sup>†</sup> Graduate School of Information Science and Technology, Osaka University Yamadaoka 1-5, Suita-shi, Osaka, 565-0871 Japan

<sup>††</sup> Cybermedia Center, Osaka University Mihogaoka 5-1, Ibaraki-shi, Osaka, 567-0047 Japan

E-mail: <sup>†</sup>{muraao.kazuya,takegawa,nishio}@ist.osaka-u.ac.jp, <sup>††</sup>tsutomu@cmc.osaka-u.ac.jp

**Abstract** Recently, there has been increasing interest on researches for wearable computing that we put on a computer and use it anytime. In wearable computing environments, though a computer provides various services according to the user's situation by recognizing contexts, the wearing sensors frequently breakdown or make non-standardized data because we put on them all day long and they are damaged by exposure. Most of conventional studies of context-aware systems focus on improvement of accuracy but the accuracy deteriorates to a large extent by reason of sensor breakdowns. Therefore, we propose an sensed data complementing method considering breakdowns of sensors for context-aware systems. The proposed method complements data for broken sensors and keeps the accuracy high by learning the sets of sensed data beforehand. Using our method, we can construct context-aware systems with high reliability.

**Key words** wearable computing, context-awareness, data completion

### 1. ま え が き

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つの特徴をもつ[1], [2]。

- 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。
- 常時電源 ON：コンピュータは常に電源が入っており、使いたいときにすぐに使える。

● 生活密着：常にコンピュータを装着した状態で日常生活を行う。

このようなウェアラブル環境では、コンピュータはユーザが装着している各種センサ（ウェアラブルセンサ）から得られたデータ（センシングデータ）を用いてユーザの行動や状況を認識することで、ナビゲーションシステム [3]，健康管理システム [4]，スケジューリングシステム [5] といったさまざまなサービスを実現している。

これまで提案されてきたウェアラブルシステムの多くは、全てのデータが不足なく入力されることが前提とされている。しかし、屋外利用を想定しているウェアラブルコンピューティング環境では外部からの衝撃や雨などの水分で故障する頻度が高く、システムの信頼性は低い。

そこで本研究では、ウェアラブルシステム、特に行動認識システムにおけるセンサの故障を考慮したデータ補完手法を提案する。提案手法では、システムにあらかじめ全てのセンサが正常に動作している場合のセンシングデータの組を学習させておき、故障したセンサのデータを補完することで認識精度の低下を抑える。提案手法を用いることで、信頼性の高いウェアラブルシステムを構築できる。

以下、2章で提案手法について述べ、3章で評価を行い、4章で本研究のまとめを行う。

## 2. センシングデータの補完

これまでにさまざまな行動認識システムが提案されている。近年では異種のセンサを組み合わせたり、複数の同種のセンサを用いることで、高い精度で複雑な動作の認識をめざす研究が多い。具体的には Stiefmeier らは自転車のメンテナンスを対象とし、超音波センサを用いた位置情報と慣性センサを用いた行動情報から「ネジを閉める・緩める」「空気を入れる」といった 21 個の複雑な動作を認識するシステムを提案した [6]。また、納谷らは看護師の髪に着けられた IR-ID 発信器と部屋の扉の両側に取り付けられた受信器から看護師のいる部屋を認識し、さらに両上腕、胸ポケット、後ろの腰の 4 箇所に取り付けられた無線加速度センサで「車椅子を押す」「点滴の準備をする」など看護師の仕事に特化した複雑な動作を認識するシステムを提案した [7]。

一方、新たな行動認識用のデバイスも開発されている。Kristof らは Porcupine [8] と呼ばれる行動認識のためのデバイスを開発した。Porcupine は  $x, y, z$  平面にそれぞれ縦横斜めの 4 本の軸をもち、合わせて空間に 9 本の軸をもち、それぞれの軸は 0 か 1 の出力しかもたず、軸の方に加速度が加われば 1、逆向きに加速度が加われば 0 を出力する。Porcupine の特徴は、従来の加速度センサなどの行動認識用センサと比較して消費電力や製作コスト、データ量が小さい点である。

このようにさまざまなシステムやデバイスが提案および開発されているが、いずれも全てのデータが不足なく入力されることが前提となっている。したがって、実際の運用でセンサが故障してしまった場合、対応できずに誤認識が頻発する可能性がある。

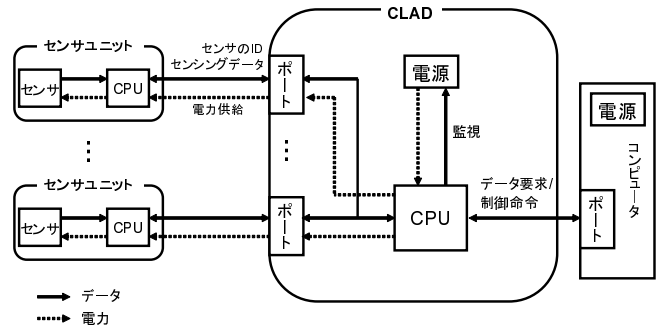


図 1 CLAD のシステム構成

Fig.1 System structure of CLAD

一方、センシングデータを補完する手法として GPS と慣性センサの利用がある [11]。ナビゲーションシステムなどで位置情報を利用する際に一般的に GPS を利用するが、GPS は屋内や周りに高い建物があると測位できない。そこで加速度センサやジャイロセンサなどの慣性センサを用いて移動体の移動した方向および距離から位置を算出する。しかし、慣性センサによる位置情報は誤差が蓄積するため長時間の利用に向かない。また、慣性センサはあくまでも GPS の代替であり、精度の違いはあるが冗長化の一種である。本研究で想定しているウェアラブルセンサは体の 1 箇所に 1 個のセンサしか装着せず、冗長化されていない状況でも値の補完を行うことを考えるため上記手法とは本質的に異なる。このようなセンサの値補完を行うことを目的とした研究は筆者らの知る限りこれまで存在しない。

本研究ではシステムにあらかじめ全てのセンサが正常に動作している場合のセンシングデータの組を学習させ、故障したセンサのデータを補完することで認識率の低下を防ぐ。センサの故障検出は筆者らが提案している CLAD (Cross-Linkage for Assembled Devices) [9] を用いる。以下、提案手法で利用する CLAD およびデータ補完手法について詳細に説明する。

### 2.1 CLAD

ウェアラブル環境ではナビゲーションシステムを利用しながら健康管理システムを利用するといったように、複数のサービスを同時に稼働させることが多い。一方、バッテリーは有限であるため、消費電力の削減は重要な問題のひとつである。したがって、サービス提供に利用される多数のセンサの電源を独立に制御する必要がある。さらに、屋外利用を想定しているウェアラブル環境では、衝撃や熱などでセンサの故障が頻繁に生じる。誤ったセンシングデータはシステムの信頼性の低下につながるため、センサの故障や原因を特定する必要がある。そこで筆者らの研究グループではこれらの問題を解決するセンサ管理デバイス CLAD を提案している [9]。

#### 2.1.1 システム構成

図 1 に CLAD のシステム構成を示す。CLAD は内部に専用の電源と CPU を備えており、CLAD や CLAD に接続しているセンサへの電源供給を独立に制御できる。また CLAD は、専用電源の電圧・電流を監視し、過電圧・過電流を検出する。

CLAD を利用するセンサは、コマンドを用いて PC へのデータ形式を変更できる GPS [10] のように、マイクロコンピュー

タを搭載し、センサの種類、精度、出力範囲、起動時間、動作電圧、動作電流に関するプロファイル情報を保持している。

### 2.1.2 CLAD の機能

CLAD は CLAD 内部の電源電圧や電流量を常に監視している。電圧不足を検出した場合、重要度・消費電力・希少度・精度・起動時間などをもとにセンサへの電力供給を停止する。また、過電流を検出した場合、CLAD 全体の電力供給を停止する。

さらに、CLAD はセンサの異常を検出した場合、故障したセンサの電力供給を停止するといったハードウェアレベルの制御だけでなく、センシングデータの出力値が正常な範囲を超えている、センサからの応答がないといったエラーの内容をコンピュータに通知する。複数の対応方法がある場合、あらかじめアプリケーションで指定された順に従う。例えば、CLAD とセンサ間の断線の場合、電源を切断後に代替センサに切替えるかあるいは何もしないかを選択できる。また、電源の供給電圧低下のエラー情報を受けたコンピュータはユーザに電源の交換を促すメッセージを提示するといった処理も行える。

### 2.2 データ補完手法

CLAD によりセンサの故障を検出した場合、提案手法では故障したセンサの代わりに擬似的にセンシングデータを補完する。図 2 に擬似データの生成過程を示す。なお、図 2 は 5 個のセンサを用いて行動認識している状態で 5 番目のセンサが故障してしまった状況を想定している。処理手順は以下のとおり。

#### Step 0. 前処理

あらかじめ全コンテキストについて、全てのセンサが正常に動作しているときのセンシングデータ（ペアベクトル）を収集し、ペアデータベースを構築する。

#### Step 1. 認識用ベクトルの取得

認識用ベクトルを取得する。なお、センサ 5 が故障しているという情報は CLAD から得られている。

#### Step 2. ペアデータベースからのペアベクトルの抽出

認識用ベクトルとペアベクトルの間で k-NN 法を用いて最近傍のペアベクトルを求める。k-NN (k-Nearest Neighbor) 法とはクラス判別におけるノンパラメトリック手法の一つであり、学習データと入力サンプルを比較し、ユークリッド距離やマンハッタン距離などを計算する。本手法ではユークリッド距離を採用している。そして、距離が近い学習データの上位 k 個を取り出し、目的変数が質的変数の場合は多数決、量的変数なら平均値や中央値をとる。例では k-NN 法の対象となるのは稼働しているセンサ 1~4 のみである。

#### Step 3. ペアデータから擬似データの抽出

抽出したペアベクトルにおけるセンサ 5 のデータと認識用ベクトルのセンサ 5 のデータを置き換える。

補完の精度は、Step2 においていかに正しいペアベクトルを抽出するかに依存している。したがって、本研究では以下に示す 3 つのペアベクトル抽出アルゴリズムを提案する。

#### 2.2.1 All Alive (AA) 手法

この手法は認識用ベクトルとペアベクトルの間で k-NN 法を用いる際に故障していない全てのセンサを対象とする。認識用

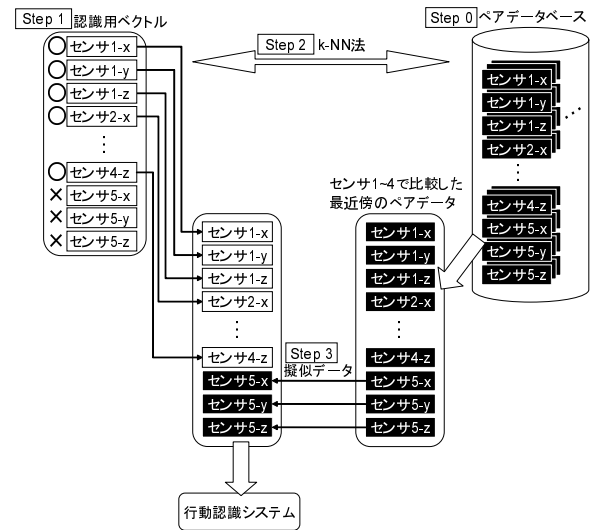


図 2 擬似データの生成過程

Fig. 2 Pseudo-data generation

ベクトル  $X = (x_{1x}, x_{1y}, x_{1z}, \dots, x_j, \dots, x_{5x}, x_{5y}, x_{5z})$  とペアベクトル  $P_i = (p_{i1x}, p_{i1y}, p_{i1z}, \dots, p_{ij}, \dots, p_{i5x}, p_{i5y}, p_{i5z})$  ( $i = 1, \dots, N$ ) からユークリッド距離  $r_i$  を求める。ただしペアデータベースのサンプル数を  $N$  とする。

$$r_{1i} = \sqrt{\sum_{j \in \text{unbroken}} \{x_j - p_{ij}\}^2}$$

ペアデータベース内の全てのペアデータと認識用ベクトルとのユークリッド距離を算出し、距離が最短となるペアデータ  $P_I$  を探す。ただし、 $I$  は最近傍のペアデータの番号である。認識用ベクトルの壊れたセンサに当たるデータを最近傍の該当するデータと置き換えることで補完された認識用ベクトル  $C = (c_{1x}, c_{1y}, c_{1z}, \dots, c_j, \dots, c_{5x}, c_{5y}, c_{5z})$  が得られる。

$$c_j = \begin{cases} x_j & (j \in \text{unbroken}) \\ p_{Ij} & (j \in \text{broken}) \end{cases}$$

#### 2.2.2 Correlative Alive (CA) 手法

AA 手法では壊れていない全てのセンサに k-NN 法を適用していた。そのため、ある 2 つのコンテキストの稼働センサのデータがほぼ同じで、故障センサのデータが異なる場合、AA 手法では両者のコンテキストのペアベクトルとの距離はほぼ等しくなり、最近傍が真のコンテキストのデータであるかはランダムになってしまう。そこで、センサ同士の値の振る舞いには相関があり、相関係数の高いセンサに k-NN 法を適用すると高精度で補完ができると考える。相関係数はピアソンの積率相関係数を採用し次式で定義する。

$$\text{correlation} = \begin{cases} \left| \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \right| & (x \neq y) \\ 0 & (x = y) \end{cases}$$

また、相関係数の解釈は一般的に表 1 のようになっている。ただし、自分自身との相関係数は 1 であるが、相関を利用して

表 1 相関係数の解釈

Table 1 An explanation of correlation

相関係数の絶対値	解釈
0.0 ~ 0.2	ほとんど相関関係がない
0.2 ~ 0.4	やや相関関係がある
0.4 ~ 0.7	かなり相関関係がある
0.7 ~ 1.0	強い相関関係がある

あるセンサのデータ補完を行う場合、そのセンサは故障しているため距離を求めることはできず相関係数も必要ないため 0 とする。また、相関の有無に注目しているため相関係数の絶対値をとる。以降、相関係数によって補正を加えたユークリッド距離を相関距離と呼ぶ。

### Threshold(CA-Th) 手法

CA-Th 手法では相関係数に閾値を設けて、閾値以上の相関があるセンサに対して k-NN 法を適用する。

$$r_{2_i} = \sqrt{\sum_{j \in \text{unbroken}} \{X(j) - P(j)\}^2 \cdot a}$$

$$a = \begin{cases} 1 & (\text{if correlation} > \text{threshold}) \\ 0 & (\text{otherwise}) \end{cases}$$

本手法では k-NN 法が適用されるセンサの数は毎回変化し高い相関があるものは全て適用されるため、より高精度の補完が実現できると考えられる。

### Distance\*Correlation (CA-DistCor) 手法

CA-DistCor 手法は AA 手法同様、稼動している全てのセンサに対して k-NN 法を適用する。ただしユークリッド距離をそのまま用いるのではなく次式で表すユークリッド距離に相関係数を除したものの和を相関距離とする。

$$r_{3_i} = \frac{\sqrt{\sum_{j \in \text{unbroken}} \{X(j) - P(j)\}^2}}{\text{correlation}}$$

この手法はで相関の大きなセンサとの距離はそのまま反映され、相関の小さいセンサとの距離が大きくなる。CA-Th 法ではあらかじめ閾値を決めておかなければならないが、想定環境ではペアデータベースのリアルタイム更新を想定しており、そのような環境では相関係数は変化するため閾値も動的に変化させる必要がある。しかし、CA-DistCor 手法では閾値を設定する必要はない。

## 3. 評価

本章では提案手法の評価を行う。評価として、両手首、両足首、腰の計 5 箇所に加速度センサを装着して、歩く、走る、階段を昇る・降りる、垂直に飛ぶ、自転車を運転する、横になる、膝をつく、座る、立つの 10 個のコンテキスト [12] ~ [15] に対し、5 個のセンサがすべて故障する以外の場合のすべてのセンサ故障の組合せ (計 31 通り) について認識精度を評価した。センサはワイヤレステクノロジー社 [16] の小型無線化速度センサ (WAA-001) を利用した。サンプリングレートは 20Hz

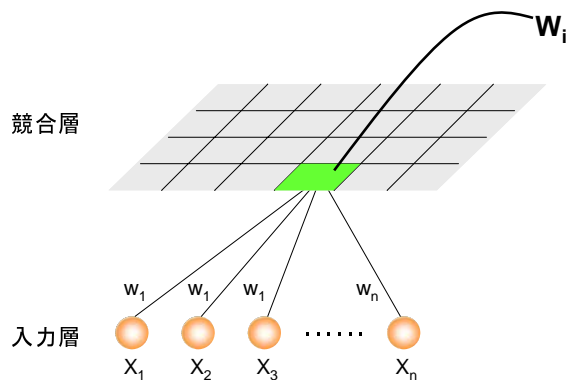


図 3 SOM の概念図

Fig. 3 A conceptual diagram of SOM

である。コンテキスト認識には自己組織化マップ [17] を採用した。自己組織化マップ (Self-Organizing Maps, 以下 SOM) とは Kohonen によって開発された大脳皮質の神経機能をモデル化したニューラルネットワークである。SOM は階層型ニューラルネットワークの一種であり、図 3 に示すように、2 層のネットワークからなる。第 1 層は n 次元の入力層  $X(t)$  であり、第 2 層は競合層と呼ばれ、出力を視覚的に見るため一般的に 2 次元配列となっている。競合層のベクトルはコードブックベクトル  $W_i(t)$  で表現され入力層の次元と同様に n 個の要素をもつ。SOM の学習は教師なし競合学習である。学習のステップは以下ようになる。

#### Step 0.

全てのコードブックベクトル  $W_i$  の要素をランダムに初期化する。

#### Step 1.

学習用データからランダムに入力ベクトル  $X(t)$  を与える。このとき、次式に示すように  $X(t)$  とのユークリッド距離を最小にするニューロン  $i$  を探し、そのニューロンを  $c$  とする。

$$\|X(t) - W_c\| = \min \|X(t) - W_i\|$$

そして、コードブックベクトル  $W_c$  を持つニューロンを勝者ユニットとする。

#### Step 2.

勝者ユニットおよびその近傍集合  $N_c$  内のユニットは次式に従って入力ベクトルを学習する。近傍集合  $N_c$  外のユニットは学習しない。

$$w_i(t+1) = \begin{cases} w(t) + h_{ci}(t)\{x(t) - w_i(t)\} & (\text{if } i \in N_c(t)) \\ w_i(t) & (\text{otherwise}) \end{cases}$$

ただし、 $N_c$  および  $h_{ci}(t)$  は勝者ユニットの近傍集合および近傍関数であり、以下のように定義する。 $t$  は学習回数、iteration は総学習回数である。

$$N_c(t) = \left\{ i \mid \|w_i(t) - w_c(t)\| < r = h_0 \left( 1 - \frac{t}{\text{iteration}} \right) \right\}$$

$$h_{ci}(t) = \alpha(t) \cdot \eta_{ci}(t)$$

$\eta_{ci}(t)$  は指数減少や線形減少を試みた結果、 $\eta_{ci}(t) =$

$\exp\left(\frac{2\|w_i(t)-w_c(t)\|^2}{r^2}\right)$  を採用する． $\alpha(t)$  は学習率係数であり，以下のように定義する． $N_c$  の半径および  $\alpha(t)$  は学習が進むにつれて単調減少し， $t = \text{iteration}$  で 0 に収束する．

$$\alpha(t) = \alpha_0 \left\{ 1 - \frac{t}{\text{iteration}} \right\}$$

### Step 3.

$t$  が  $\text{iteration}$  に達するまで Step 1. ~ Step2. を繰り返し，学習を行う．

本研究では，SOM に必要なパラメータを以下のように設定した．

- 入力層ノード数：30
- 競合層ノード数：144
- 競合層のトポロジ：1辺12ノードの2次元正方形
- 競合層のノードの重みの初期値：[-3,3] の一様分布
- 総学習回数（学習フェーズで入力として与えられるベクトルの総数）：経験的に妥当とされている  $\text{iteration} = 100000$  回に設定
- 初期近傍半径： $h_0 = 1.5$
- 初期学習率： $\alpha_0 = 0.9$

SOM は（特に学習の初期段階では）以前の学習データを上書きする．そのため競合層の各参照ベクトルのコンテキストもその都度更新される．実装では最後の誤った上書きを避けるため  $k$  平均法を採用した．各参照ベクトルに対し過去  $k$  回のコンテキストを保持し，多数決をとる．本研究では  $k=11$  とした．

なお，学習に用いたデータにおけるセンサ間の相関係数行列は表 2 に示すとおりとなった．太字は 0.7 以上である．

#### 3.1 AA 手法

図 4 に AA 手法の評価結果を示す．なお，比較手法として故障したセンサから常に同じ値が入力されるもの（比較手法 1）と，故障したセンサのデータを他のデータの平均値とするもの（比較手法 2）を用意した．横軸は正常なセンサと故障したセンサの組合せ（ は稼動，空白は故障）を示し，縦軸は認識精度を示す．図 4 の評価結果からセンサが故障した場合はあらゆる場合において AA 手法を用いることで精度を改善できることが明らかとなった．しかし，稼動センサ数が 2 個以下では組合せによって認識精度に大きな差が見られる．

#### 3.2 CA-Th 手法

図 5 に CA-Th 手法の評価結果を示す．評価では分散の相関係数を用い，0 から 0.8 まで 0.2 刻みで閾値を設けた．Th=0 の結果は全てのセンサを  $k$ -NN 法に適用しているので AA 手法の結果と一致する．評価結果から稼動センサ数が 3 個では一部の組合せを除き Th=0, 0.2, 0.4 は同様の結果となった．しかし，稼動センサ数が 2 個以下では Th=0, 0.2 が優位である．Th=0.6 以上に関しては明らかに劣ることがわかった．

#### 3.3 CA-DistCor 手法

図 6 に CA-DistCor 手法の評価結果を示す．比較のために AA 手法を示す．評価結果から生データ，平均，分散のいずれの相関係数を用いた CA-DistCor 手法とも AA 手法はほぼ同等

である．しかし，本実験では相関性を利用した方式の有効性は明らかにならなかった．これは，本実験で採用したコンテキストにおいてはセンサ間の相関が全体的に高く偏りが無かったためであると考えられる．次章で提案手法および相関係数が有効な場合について考察する．

### 3.4 考 察

すべての評価結果より AA 手法と CA-DistCor 手法は同等で認識精度が高い．CA-Th 手法は相関係数と閾値に依るが，閾値で区切る事で高い認識精度は得られなかった．

次に，提案手法の認識器からの独立性について考察を行う．本研究で提案する補完プロセスは認識プロセスと完全に切り離されているが，補完されたデータが他の認識器でも利用可能か検証するために別の認識器を用いて評価を行う．用いる認識器は記憶ベース推論である．記憶ベース推論 (Memory Based Reasoning, 以下 MBR) はデータを多次元空間上の点とみなしデータベースを構築する．未知の入力データの近傍となるデータをデータベースから探し，予測を行う．具体的な処理を以下に示す．

時刻  $t=T$  に加速度センサが生成する 15 次元のセンシングデータ（認識用ベクトル）の各成分  $c_{i,T}$  について時刻  $T$  から遡った 20 サンプル分の平均  $\mu_{i,T}$  および分散  $\sigma_{i,T}$  を求める．

$$\mu_{i,T} = \frac{1}{20} \sum_{t=T-19}^T c_{i,t}$$

$$\sigma_{i,T} = \frac{1}{20} \sum_{t=T-19}^T \left\{ c_{i,t} - \mu_{i,T} \right\}^2$$

上記  $\mu_{i,T}$  および  $\sigma_{i,T}$  から成る 30 次元のベクトル  $X_T$  について，次式で標準化したものを特徴ベクトル  $Z_T$  とした．なお， $M_T$  および  $S_T$  はそれぞれ  $X_T$  の平均および分散である．

$$Z_T = \frac{X_T - M_T}{S_T}$$

認識させたい特徴ベクトル（認識用特徴ベクトル）とあらかじめ学習させた全ての特徴ベクトル（学習済特徴ベクトル）のユークリッド距離を算出し， $k$ -NN ( $k=1$ ) を用いることでコンテキストを認識する．

図 7 に MBR における評価結果を示す．結果は SOM と同様の挙動を示し，提案手法は認識器によらず認識精度を維持することが分かる．

相関係数については追加実験を行った．図 8 は腕を回しながらスクワット（図 9 参照）と腕を回さずスクワットの 2 つのコンテキストの認識結果である．表 4 に相関係数（太字は 0.7 以上）を示す．直感的な相関と同じく，手首同士，足首同士の相関が高い．さらに腰の  $y$  軸（体の軸方向）と両手首の相関も高い．図 8AA 手法を上回っている組合せが複数あり，平均的に見ても相関係数を利用した手法が勝っている．このように類似したコンテキストを分類する際は相関係数を用いた方が優位であることがわかる．

続いて，処理時間に関する考察を行う．表 3 に提案手法の処理時間を示す．実験では，SONY 社の VGN-U50 (Claron M

表 2 センサ間の相関係数行列

Table 2 A correlation coefficient matrix between the sensors

	左足首 x	左足首 y	左足首 z	左手首 x	左手首 y	左手首 z	腰 x	腰 y	腰 z	右手首 x	右手首 y	右手首 z	右足首 x	右足首 y	右足首 z
左足首 x	1.000	0.423	0.617	<b>0.825</b>	0.468	<b>0.777</b>	0.461	0.422	0.483	<b>0.830</b>	0.661	0.302	<b>0.938</b>	0.415	0.365
左足首 y	0.423	1.000	0.623	0.262	0.585	0.233	0.499	0.579	0.423	0.216	0.535	0.141	0.391	<b>0.925</b>	0.676
左足首 z	0.617	0.623	1.000	0.517	0.573	0.431	0.644	0.565	0.537	0.463	0.626	0.288	0.648	0.624	0.686
左手首 x	<b>0.825</b>	0.262	0.517	1.000	0.586	<b>0.846</b>	0.453	0.539	0.329	<b>0.946</b>	<b>0.780</b>	0.360	<b>0.883</b>	0.308	0.208
左手首 y	0.468	0.585	0.573	0.586	1.000	0.509	0.562	<b>0.924</b>	0.246	0.535	<b>0.918</b>	0.189	0.476	0.680	0.361
左手首 z	<b>0.777</b>	0.233	0.431	<b>0.846</b>	0.509	1.000	0.407	0.404	0.398	<b>0.881</b>	0.690	0.381	<b>0.798</b>	0.292	0.160
腰 x	0.461	0.499	0.644	0.453	0.562	0.407	1.000	0.608	<b>0.805</b>	0.439	0.593	0.658	0.490	0.570	0.539
腰 y	0.422	0.579	0.565	0.539	<b>0.924</b>	0.404	0.608	1.000	0.229	0.479	<b>0.884</b>	0.188	0.439	0.665	0.379
腰 z	0.483	0.423	0.537	0.329	0.246	0.398	<b>0.805</b>	0.229	1.000	0.360	0.318	0.682	0.465	0.448	0.522
右手首 x	<b>0.830</b>	0.216	0.463	<b>0.946</b>	0.535	<b>0.881</b>	0.439	0.479	0.360	1.000	<b>0.719</b>	0.390	<b>0.845</b>	0.259	0.187
右手首 y	0.661	0.535	0.626	<b>0.780</b>	<b>0.918</b>	0.690	0.593	<b>0.884</b>	0.318	<b>0.719</b>	1.000	0.258	<b>0.709</b>	0.637	0.363
右手首 z	0.302	0.141	0.288	0.360	0.189	0.381	0.658	0.188	0.682	0.390	0.258	1.000	0.326	0.262	0.192
右足首 x	<b>0.938</b>	0.391	0.648	<b>0.883</b>	0.476	<b>0.798</b>	0.490	0.439	0.465	0.845	<b>0.709</b>	0.326	1.000	0.402	0.399
右足首 y	0.415	<b>0.925</b>	0.624	0.308	0.680	0.292	0.570	0.665	0.448	0.259	0.637	0.262	0.402	1.000	0.644
右足首 z	0.365	0.676	0.686	0.208	0.361	0.160	0.539	0.379	0.522	0.187	0.363	0.192	0.399	0.644	1.000




図 4 AA 手法の評価結果

Fig.4 An evaluation of AA method




図 5 CA-Th 手法の評価結果

Fig.5 An evaluation of CA-Th method

900MHz) をウェアラブルコンピュータとして使用した。表よりいずれの手法も入力データ間隔である 50 ミリ秒 (20Hz) を下回っており、リアルタイム処理が可能である。故障センサ数に対して処理時間が単調増加でない理由は、故障センサ数が増えると補完するべきセンサ数は増えるが、ペアデータからの検索に利用する稼働センサ数も減り、計算量が減るためである。

また、行動認識システムに限らずセンシングデータの値が相互に関係している場合は、データ補完が可能であるといえる。例えば、センサネットワークにおいて一箇所のセンシングノ

表 3 提案手法の処理時間

Table 3 Processing time of the proposals

故障個数	手法	AA 手法 [msec]	CA-Th 手法 [msec]	CA-DistCor 手法 [msec]
1 個		8.008	21.936	23.329
2 個		6.964	35.167	37.256
3 個		5.571	40.738	42.479
4 個		3.830	38.301	39.345




図 6 CA-DistCor 手法の評価結果  
 Fig. 6 An evaluation of CA-DistCor method




図 7 記憶ベース推論における評価結果  
 Fig. 7 Results in MBR




図 8 追加実験の評価結果  
 Fig. 8 An evaluation on additional experiment

ドが故障してもその周囲のセンシングノードの測定値と、過去の測定値の組み合わせから故障したノードがある地点のデータが推測可能である。

#### 4. おわりに

本研究ではウェアラブルシステムのための装着型センサの故障を考慮したセンシングデータ補完手法を提案した。提案手法

ではあらかじめ全てのセンサが正常に動作している場合のセンシングデータの組を学習させておき、センサが故障した場合に故障していないセンサから壊れたセンサのデータを推測し補完する。評価ではセンサ間の相関を用いるなどして4つの手法を提案した。この補完手法はセンシングデータの間に関連性があれば行動認識システムに限らず、失われたデータの補完が可能である。また評価では行動認識システムを用いて提案手法の有

表 4 追加実験におけるセンサ間の相関係数行列

Table 4 A correlation coefficient matrix between the sensors on additional experiment

	左足首 x	左足首 y	左足首 z	左手首 x	左手首 y	左手首 z	腰 x	腰 y	腰 z	右手首 x	右手首 y	右手首 z	右足首 x	右足首 y	右足首 z
左足首 x	1.000	0.679	0.641	0.590	0.583	0.501	0.280	0.598	0.317	0.621	0.625	0.415	0.549	0.478	0.424
左足首 y	0.679	1.000	<b>0.804</b>	0.600	0.580	0.444	0.235	0.547	0.210	0.604	0.623	0.317	0.569	0.641	0.565
左足首 z	0.641	<b>0.804</b>	1.000	0.439	0.425	0.310	0.198	0.394	0.194	0.447	0.469	0.232	0.431	0.590	0.524
左手首 x	0.590	0.600	0.439	1.000	<b>0.843</b>	<b>0.859</b>	0.389	<b>0.835</b>	0.341	<b>0.901</b>	<b>0.896</b>	<b>0.764</b>	0.693	0.521	0.594
左手首 y	0.583	0.580	0.425	<b>0.843</b>	1.000	<b>0.742</b>	0.401	0.781	0.360	<b>0.896</b>	<b>0.936</b>	0.688	<b>0.705</b>	0.492	0.485
左手首 z	0.501	0.444	0.310	<b>0.859</b>	<b>0.742</b>	1.000	0.404	<b>0.816</b>	0.346	0.753	<b>0.760</b>	<b>0.908</b>	0.580	0.432	0.538
腰 x	0.280	0.235	0.198	0.389	0.401	0.404	1.000	0.384	0.460	0.174	0.413	0.395	0.373	0.217	0.190
腰 y	0.598	0.547	0.394	<b>0.835</b>	<b>0.781</b>	<b>0.816</b>	0.384	1.000	0.460	<b>0.844</b>	<b>0.832</b>	<b>0.731</b>	<b>0.728</b>	0.527	0.520
腰 z	0.317	0.210	0.194	0.341	0.360	0.346	0.174	0.460	1.000	0.348	0.339	0.348	0.300	0.249	0.253
右手首 x	0.621	0.604	0.447	<b>0.901</b>	<b>0.896</b>	<b>0.753</b>	0.413	<b>0.844</b>	0.348	1.000	<b>0.945</b>	0.677	<b>0.765</b>	0.526	0.514
右手首 y	0.625	0.623	0.469	<b>0.896</b>	<b>0.936</b>	<b>0.760</b>	0.395	<b>0.832</b>	0.339	<b>0.945</b>	1.000	<b>0.704</b>	<b>0.764</b>	0.533	0.527
右手首 z	0.415	0.317	0.232	<b>0.764</b>	0.688	<b>0.908</b>	0.373	<b>0.731</b>	0.348	0.677	<b>0.704</b>	1.000	0.520	0.374	0.500
右足首 x	0.549	0.569	0.431	0.693	<b>0.705</b>	0.580	0.217	0.728	0.300	<b>0.765</b>	<b>0.764</b>	0.520	1.000	0.645	0.534
右足首 y	0.478	0.641	0.590	0.521	0.492	0.432	0.169	0.527	0.249	0.526	0.533	0.374	0.645	1.000	<b>0.700</b>
右足首 z	0.424	0.565	0.524	0.594	0.485	0.538	0.190	0.520	0.253	0.514	0.527	0.500	0.534	<b>0.700</b>	1.000



図 9 追加実験における動作

Fig. 9 A movement in additional experiment

効性を証明した。提案手法は行動認識部とは独立しており、補完されたデータは自己組織化マップ (SOM)、記憶ベース推論 (MBR) に限らずサポートベクタマシン (SVM) や隠れマルコフモデル (HMM) など他のアルゴリズムに適用できる。

今後はさらに認識精度が高く、遅延時間の少ないセンシングデータ補完手法の提案を考えている。また、提案手法ではデータ補完を行うことでセンサを全て稼働させなくとも高精度での認識が可能であるため、状況に応じてセンサの組合せを変えることで高い認識精度を維持しながら消費電力の削減が可能な行動認識システムを構築できる。

謝辞 本研究の一部は、文部科学省 21 世紀 COE プログラム「ネットワーク共生環境を築く情報技術の創出」、および基盤研究 (A)(17200006) の研究助成によるものである。ここに記して謝意を表す。

#### 文 献

[1] M. Miyamae, T. Terada, M. Tsukamoto, and S. Nishio: "Design and Implementation of an Extensible Rule Processing System for Wearable Computing," in *Proc. of the 1st IEEE Int'l Conference on Mobile and Ubiquitous Systems: Networking and Services (MobiQuitous 2004)*, pp. 392-400 (Aug. 2004).

[2] 塚本昌彦: モバイルコンピューティング, 岩波新書 (2000).

[3] M. Kanbara, R. Tenmoku, T. Ogawa, T. Machida, M. Koeda, Y. Matsumoto, and K. Kiyokawa: "Nara Palace Site Navigator: A Wearable Tour Guide System Based on Augmented Reality," in *Proc. of the 3rd CREST/ISWC Workshop on Advanced Computing and Communicating Tech-*

*niques for Wearable Information Playing*, pp. 7-14 (Oct. 2004).

[4] 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 第 65 回全国大会論文集*, Vol. 5, pp. 239-242 (Mar. 2003).

[5] 山根隼人, 長尾確: "AcTrec: 状況認識・記録による個人行動支援," *情報処理学会 第 66 回全国大会論文集*, Vol. 5 (Mar. 2004).

[6] T. Stiefmeier, G. Ogris, H. Junker, P. Lukowicz, and G. Tröster: "Combining Motion Sensors and Ultrasonic Hands Tracking for Continuous Activity Recognition in a Maintenance Scenario," in *Proc. of the 10th IEEE Int'l Symposium on Wearable Computers (ISWC '06)*, pp. 97-104 (Oct. 2006).

[7] F. Naya, R. Ohmura, F. Takayanagi, H. Noma, and K. Kogure: "Workers' Routine Activity Recognition using Body Movement and Location Information," in *Proc. of the 10th IEEE Int'l Symposium on Wearable Computers (ISWC '06)*, pp. 105-108 (Oct. 2006).

[8] K. V. Laerhoven and H. W. Gellersen: "Spine versus Porcupine: a Study in Distributed Wearable Activity Recognition," in *Proc. of the 8th IEEE Int'l Symposium on Wearable Computers (ISWC2004)*, pp. 142-149 (Oct. 2004).

[9] K. Murao, Y. Takegawa, T. Terada, and S. Nishio: "Design and Implementation of a Sensor Management Device for Wearable Computing," in *Adjunct Proc. of the 10th IEEE Int'l Symposium on Wearable Computers (ISWC '06) Student Colloquium*, pp. 17-19 (Oct. 2006).

[10] 株式会社 システムプロデューサアソシエイツ: マークユリー 48, <http://www.spa-japan.co.jp/>.

[11] シリコンセンシングシステムズジャパン株式会社: "歩行者用慣性ナビユニット ポイントマン DRM", <http://www.spp.co.jp/sss/j/pointman.htm/>.

[12] J.Farrington, A. Moore, N. Tilbury, J. Church, and P. Biemond: "Wearable Sensor Badge & Sensor Jacket for Context Awareness," in *Proc. of the 3rd IEEE Int'l Symposium on Wearable computers (ISWC'99)*, pp. 107-113 (Oct. 1999).

[13] A. R. Golding and N. Lesh: "Indoor navigation using a diverse set of sheap, wearablesensors," in *Proc. of the 3rd IEEE Int'l Symposium on Wearable computers (ISWC'99)*, pp. 29-36 (Oct. 1999).

[14] N. Kern, B. Schiele, H. Hunker, P. Lukozicz, and G. Tröster: "Wearable Sensing to Annotate Meeting Recordings," in *Proc. of the 5th IEEE Int'l Symposium on Wearable Computers (ISWC '02)*, pp. 186-196 (Oct. 2002).

[15] K. Van Laerhoven and O. Cakmakci: "What Shall We Teach Our Pants?," in *Proc. of the 4th IEEE Int'l Symposium on Wearable Computers (ISWC 2000)*, pp. 77-83 (Oct. 2000).

[16] ワイヤレステクノロジー株式会社: <http://www.wireless-t.jp/>.

[17] Kohonen. T: *Self-Organizing Maps Third Edition*, Springer Series in Information Science, 2001.