



ウェアラブルコンピューティングのための消費電力を考慮したコンテキストウェアシステムの構築

村尾, 和哉
寺田, 努
竹川, 佳成
西尾, 章治郎

(Citation)

情報処理学会論文誌, 50(5):1456-1466

(Issue Date)

2009-05-15

(Resource Type)

journal article

(Version)

Version of Record

(URL)

<https://hdl.handle.net/20.500.14094/90002109>



ウェアラブルコンピューティングのための消費電力を考慮したコンテキストウェアシステムの構築

村 尾 和 哉^{†1} 寺 田 努^{†2}
竹 川 佳 成^{†3} 西 尾 章 治 郎^{†1}

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。ウェアラブルコンピューティング環境では、複数の装着型センサを用いてさまざまなアプリケーションが提供される。特にコンテキストウェアの分野では、細かい動作や状態を認識するために複数の加速度センサを用いるが、多数のデバイスをを用いているにもかかわらず消費電力の低減は考慮されていなかった。そこで本研究では、低消費電力なコンテキストウェアシステムの実現を目的とする。提案システムは、消費電力と認識精度を考慮して最適なセンサの組合せを決定し、不要なセンサの電源をオフにすることで消費電力を低減させる。稼働センサ数を変更しても、筆者らの提案するデータ補完手法を用いることで、認識精度を維持しつつ低消費電力なコンテキストウェアシステムを利用できる。

Construction of a Context-aware System Considering Energy Consumption for Wearable Computing

KAZUYA MURAO,^{†1} TSUTOMU TERADA,^{†2}
YOSHINARI TAKEGAWA^{†3} and SHOJIRO NISHIO^{†1}

In wearable computing environments, a wearable computer runs various applications using various wearable sensors. In the area of context awareness, though various systems use multiple accelerometers to recognize very minute motions and states, energy consumption was not taken into consideration. We propose a context-aware system that reduces energy consumption. The proposed system changes sensor combination in terms of energy consumption and accuracy, and turns unused sensors off. Even if the number of sensors changes, no extra classifiers or training data are required because the data for shutting off sensors is complemented by our proposed algorithm. By using our system, power consumption can be reduced without large losses in accuracy.

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つ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（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。

例として、LifeMinder⁴⁾は日常生活での行動を温度センサ、GSR（Galvanic Skin Reflex：皮膚電気反射）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。

ここで、両研究をはじめとする行動認識に関する研究の多くが加速度センサを用いている。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、加速度センサは空間的な装着部位の動きが検出可能であり、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

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

^{†3} 神戸大学自然科学系先端融合研究環
Organization of Advanced Science and Technology, Kobe University

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．一方，従来システムは使用するセンサの数があらかじめ固定され，高い認識精度を得るために多数のセンサを装着するため，つねにすべてのセンサを必要とするとは限らず冗長な構成になっている場合がある．したがって，柔軟に電源制御を行い必要なセンサだけを利用すれば，認識精度を維持しつつ消費電力を削減できる．

そこで本論文では，筆者らの研究グループでこれまでに構築した，センサへの電源供給を制御する機能やセンサ故障時に故障したセンサのデータを疑似的に生成する機能を持つ CLAD を基盤として用い，アプリケーション要求や状況の変化に基づき高度な電源管理を行うことで低消費電力・高精度の行動認識システムを構築する．

以降，2 章で筆者らの先行研究を紹介し，3 章で提案システムの構成について述べ，4 章で提案システムの評価を行い，5 章で本研究をまとめる．

2. 先行研究

本章では，これまでに筆者らの研究グループで開発したセンサ管理デバイス CLAD およびその機能の一部である，故障センサのデータ補完機能について述べる．

2.1 CLAD

CLAD⁶⁾ は，ユーザが複数個および複数種のセンサを装着する環境において，ウェアラブルコンピュータとセンサの間に位置するセンサ管理デバイスである．CLAD はセンサへの電源供給制御による省電力および柔軟なデータ管理によるデータの高信頼性を実現する．CLAD のプロトタイプを図 1 に示す．CLAD とコンピュータおよび CLAD とセンサ間は通信速度 9,600 bps の RS232C で通信し，CLAD は最大 5 個のセンサを制御できる．CLAD の処理装置としては Microchip 社の PIC16F873A を用いている．

CLAD は内部に電源を持ち，電源電圧および電流を監視し，低電圧や過電流を検出する．センサはマイクロコンピュータ（PIC16F84）を搭載し CLAD の要求に応えたり，種類や精度，出力範囲などのプロファイル情報を保持しており，CLAD はプロファイル情報をもとにセンサを制御する．CLAD は以下に示す 2 つの特徴を持つ．

電源管理

センシングデータが出力範囲を逸脱したりセンサが CLAD からの呼びかけに応じなかったりした場合は通信路やセンサ自身に異常があると判断しセンサへの電源供給を停止し，代替機器の検索もしくは後述の疑似データ利用によりシステムの稼動状態を維持する．また，CLAD は内部電源をつねに監視している．電圧低下時は優先度の低いセンサや消費電力の




図 1 CLAD
Fig. 1 CLAD.

大きいセンサを切るといった取捨選択ポリシーに従い，いくつかのセンサへの電源供給を停止して消費電力を低減させる．

データ管理

アプリケーションによっては必要なすべてのセンサのデータが継続的に入力されないと機能しないものがある．特に行動認識システムではセンシングデータが欠損値を含むと認識精度は著しく低下する．そこで CLAD は正常時のデータをもとに，故障したセンサの代わりに疑似的にセンシングデータを生成する機能を持つ．疑似データ生成機能により，アプリケーションの稼働を維持でき，システム全体の動作信頼性が向上する．CLAD はエラー検出機能と従来データマイニングなどで利用されてきた高度なデータ補完アルゴリズムを連動させることで疑似データ生成機能を実現するものである．

2.2 データ補完

CLAD の機能のうち最も特徴的なものは疑似データ生成である．本節では CLAD のデータ補完メカニズムについて説明する．図 2 に疑似データ生成の例を示す．この例では 5 個の 3 軸 (x, y, z) 加速度センサを用いた行動認識システムを利用し，5 つ目のセンサ（センサ 5）が故障した状況を想定している．疑似データ生成手順を以下に示す．

Step 0. ペアデータベースの構築 CLAD は正常稼動時に，あらかじめすべてのコンテキストに対してセンシングデータの組を蓄積している．これらをペアデータと呼び，ペアデータが蓄積されたデータベースをペアデータベースと呼ぶ．

Step 1. 認識ベクトルの取得 センサの故障などでデータに欠損が含まれている場合，欠




図 2 疑似データ生成手順
Fig. 2 Pseudo data generation.

損部分を除いたデータを作成し、これを認識ベクトルと呼ぶ。

Step 2. ペアデータの抽出 認識ベクトルと一番近いペアデータをデータベースから検索する。一番近いとはユークリッド距離が一番近いものであり k 最近傍 (k -NN) 法 ($k = 1$) を用いる。

Step 3. 疑似データの抽出 センサ 5 のデータを最近傍のペアデータのセンサ 5 の部分と置き換えることで補完ベクトルを生成する。この補完ベクトルがコンテキストウェアシステムの入力となる。

疑似データ生成において、認識ベクトル $\mathbf{X} = (x_{1x}, x_{1y}, x_{1z}, \dots, x_{jx}, \dots, x_{5x}, x_{5y}, x_{5z})$ およびペアデータ $\mathbf{P}_i = (p_{i1x}, p_{i1y}, p_{i1z}, \dots, p_{ijx}, \dots, p_{i5x}, p_{i5y}, p_{i5z})$ ($i = 1, \dots, N$) から距離を計算する。ただし、添え字の $1x$ や $5y$ はセンサ 1 の x 軸成分やセンサ 5 の y 軸成分のデータを表し、ここでは任意のセンサの軸を j と表記する。 x_{1x} などの各成分はスカラー値である。また N はペアデータベース内のペアデータのサンプル数であり、ここでは任意のペアデータを i と表記する。ここで、単純にユークリッド距離を採用すると、2つのコンテキストの稼動センサのデータが類似し、欠損部分のみが異なっている場合、認識ベクトルと両者のコンテキストのペアデータとの距離はほぼ等しくなり、正しいペアデータの抽出が困難である。そこで、センサは人間が装着するため、センサ間には何らかの相関が現れることに着目し、相関を用いることでより高精度な補完ができると考える。センサ α のデータとセ

ンサ β のデータの相関 $correlation(\alpha, \beta)$ として次式に示すピアソンの積率相関係数を採用する。

$$correlation(\alpha, \beta) = \left| \frac{\sum_{i=1}^N (\alpha_i - \bar{\alpha})(\beta_i - \bar{\beta})}{\sqrt{\sum_{i=1}^N (\alpha_i - \bar{\alpha})^2 \sum_{i=1}^N (\beta_i - \bar{\beta})^2}} \right|, (\alpha \neq \beta)$$

ユークリッド距離の和に相関係数を乗じたものを相関距離 d とする。相関係数はペアデータの分散値から計算される。ここで、相関係数を重みとして利用した理由について述べる。分散値の相関係数はセンサ装着部位の動きの相関を表す。つまり右腕と左腕のセンシングデータの相関が高い場合、片方のセンサが動いている場合もう一方のセンサも動いており、片方が止まっている場合はもう一方も止まっていることを意味する。相関が低い場合は互いの動きの連動性は低いことを意味する。このように右腕のセンシングデータを補完する場合、右腕と連動性の低いセンサを参考にするよりも、連動性の高いセンサを参考にするほうが高精度の補完が可能であると考え。予備実験より 5 人の被験者に対して 5 個の加速度センサを利用し 9 種類のコンテキストを認識する環境において相関を用いた場合と用いない場合で平均 5.36% の認識精度の改善を確認した。

具体的には、非稼動センサ m のデータを補完する場合、稼動センサ k のデータと比較対象となるペアデータ i のセンサ k のデータとの差分の 2 乗に、センサ m とセンサ j の相関係数を乗じたものをすべての稼動センサ $j \in working$ に対して計算し、その和をとる。この作業をペアデータベース内のすべてのペアデータに対して行い、 $d_{m,i}$ が最小になるペアデータ I のセンサ m のデータを用いてセンサ m のデータを補完する。補完すべきセンサが複数存在する場合はすべての補完すべきセンサに対して $d_{m,i}$ を求め、補完する。

$$d_{m,i} = \sqrt{\sum_{j \in working} \{x_j - p_{ij}\}^2 * correlation(x_m, x_j)}$$

最終的に最近傍のペアデータ $\mathbf{P}_{I=\arg \min_i (d_{m,i})}$ を検索し、補完ベクトル $\mathbf{C} = (c_{1x}, c_{1y}, c_{1z}, \dots, c_{jx}, \dots, c_{5x}, c_{5y}, c_{5z})$ を生成する。

$$c_j = \begin{cases} x_j & (j \in working) \\ p_{Ij} & (j \in malfunctioning) \end{cases}$$

2.3 関連研究

ウェアラブルコンピューティング環境における省電力化問題に関しては、コンピュータや

センサなどのデバイス自体を省電力化する方法⁷⁾がこれまで提案されているが、中間ハードウェアを用いた電源制御により問題を解決する取り組みはこれまでに行われていない。Phidget⁸⁾は加速度、温度などのセンサやモータやLEDなどのアクチュエータをPhidget Interfaceという中継機器に接続して使うキットであるが、データ管理や電源管理はまったく行っていない。

ポイントマン DRM⁹⁾ではGPS、加速度、ジャイロなど慣性航行に必要なセンサを搭載している。慣性航行による位置取得に加えて、GPS利用可能時はGPSを用いて精度や誤差を改善しており複数センサを冗長化しているが、それらの電源制御は行っていない。また組み込まれたセンサのほかのサービスでの利用やセンサの追加が難しく汎用性は低い。

疑似データ生成に関連するものとして、Kanagalらの研究¹⁰⁾ではカルマンフィルタや隠れマルコフモデル、パーティクルフィルタを用いて欠損値の補完や観測できない値の推測を行っている。しかし、カルマンフィルタを用いて予測を行うにはシステム方程式と観測方程式を立式しなければならず、行動認識のように人間の体に装着した加速度センサの値を予測するには人間の骨格から方程式を立式する必要があるため適用は困難である。隠れマルコフモデルを用いた手法ではセンシングデータの振舞いからセンサが壊れているか否かの粒度の低い推測にのみ用いられており、そのままセンシングデータの予測に適用することは困難である。さらに文献10)中ではパーティクルフィルタを用いて時刻から温度や湿度の推測を行っているが、本研究で取り扱っている加速度センサなどのデータは他の絶対的なパラメータとの関連性が低く、時刻などから予測することは難しい。

また、サンプリング周波数を変えることで消費電力を削減している手法¹¹⁾もあるが、評価に用いているデバイスは単にサンプリングレートを下げるだけでなくCPUのクロックも低下させるなどの特殊な待機状態を実装したものであり汎用性が少ない。加えて、サンプリング周波数を変化させると特徴量が変化し、それまでに蓄積した学習データが使えなくなるため現実性が低い。

3. システム構成

前章で紹介したCLADにおける疑似データ生成の目的はセンサのハードウェア面での異常による認識精度低下を防ぐためであった。一方、疑似データを用いることでセンサ故障時に限らず平常時でも意図的に冗長なセンサの電源を切って消費電力を抑えられる。そこで、本研究ではユーザ状況やアプリケーション（以下、シチュエーション）によって、認識すべきコンテキストの種類や要求される認識精度が異なる点に着目する。シチュエーションごと

に認識するコンテキストの選択肢を変化させ、要求される認識精度を満たす範囲でセンサの数を減らす低消費電力なコンテキストウェアシステムを提案する。本章では、提案システムの詳細およびシチュエーションに基づいた消費電力削減方法について述べる。

一般的に行動の認識に用いられるセンサの多くは加速度であるため、以降は簡単のため利用するセンサを加速度センサに限定して議論する。ただし、提案手法はジャイロセンサなどのその性質が似ており値に相関があるデータであれば加速度センサ以外の利用にも適用可能であり、この仮定が提案手法の適用範囲を限定することはない。

3.1 要求される認識精度を考慮した省電力

シチュエーションによって冗長なセンサは変化する。たとえば、人命に関わる環境で利用する場合にはつねに最高の精度が要求される一方、日常生活の利用では精度よりも長い稼働時間を求めるユーザもいる。たとえば、厳しい環境下では認識精度の下限値を90%に設定し、90%を下回らず最もセンサ数の少ない組合せを選択する。一方、ふだんの生活では下限値を70%に設定して稼働センサ数を減少させる。このように、提案システムを用いることで認識精度と消費電力のトレードオフに柔軟に対応できる。一方、単にセンサの電源を切るだけでは認識精度も低下してしまう。以降では認識するコンテキストの選択肢に着目して、認識精度を維持したまま消費電力を抑える手法を提案する。

3.2 コンテキスト粒度を考慮した省電力

従来の認識システムは多数のコンテキストを高精度で認識するために複数のセンサを装着するものが多い。しかし、実際の生活でつねに学習したすべてのコンテキストの中から正確に答えを選ぶ必要はない。具体的には、健康管理システムであれば正確な運動量を計算するために詳細なコンテキストを認識する必要があるが、HMDに情報を提示するシステム¹²⁾がユーザ静止時にのみ情報を提示するといったサービスを提供する際には動いているかどうかだけを判断すればよく、そのような簡単なコンテキストの認識に多数のセンサは必要ない。

そこで本論文では、要求されるコンテキストの粒度が大きい場合、いくつかのコンテキストをまとめて「コンテキスト群」とする。コンテキスト群とはコンテキスト全体の部分集合である。たとえば、図3に示すシチュエーションを定義する。シチュエーション1はユーザが動いているか否かさえ分かればよいアプリケーションを用いる場合、シチュエーション2はユーザが医者に激しい運動を禁止されていて、激しい運動を行ったときに警告を与えるアプリケーションの利用を想定している。さらにシチュエーション3は詳細なコンテキスト情報を利用し正確な消費カロリーを計算する健康管理システムの利用を想定している。この想




図 3 コンテキスト群
Fig. 3 Context groups.

表 1 コンテキスト遷移
Table 1 Context transition.

現コンテキスト	遷移可能コンテキスト
歩く	(全コンテキスト)
走る	歩く, 走る, 階段昇降, 自転車, 立つ
階段昇降	歩く, 走る, 階段昇降, 立つ
自転車	歩く, 自転車, 立つ
寝る	歩く, 寝る, 膝立ち, 座る, 立つ
膝立ち	歩く, 寝る, 膝立ち, 座る, 立つ
座る	歩く, 寝る, 膝立ち, 座る, 立つ
立つ	(全コンテキスト)

定のもとで、利用アプリケーションに従ってシチュエーションを選択し、3.1 節で述べた精度の閾値を満たしセンサ数が最小の組合せを採用することで低消費電力化を行う。適切なコンテキスト群が存在しない場合、新たにコンテキスト群を定義する。たとえば、ユーザの生死を確認したい場合、「横になる」や「膝立ち」、「座る」を 1 つに、それ以外のコンテキストを 1 つにまとめたコンテキスト群を定義する。前者のコンテキスト群が長時間続いた場合、ユーザが危険な状態にあると判断できる。シチュエーション 1 であれば 1 つのセンサでも認識可能であると思われるため、冗長なセンサの電源を切り、切ったセンサのデータを補完することで認識機の調整や学習データの追加を必要とせず認識精度を維持したまま低消費電力なコンテキストウェアシステムが構築できる。

3.3 ユーザの行動遷移を考慮した省電力

人間の行動は、基本的に現在行っている動作をそのまま継続し、次に遷移する動作は現在の動作によって制限される。あるユーザの行動遷移を見ると表 1 のようになった。表より、




図 4 システム構成
Fig. 4 System construction.

自転車に乗っているユーザが次にとる行動の選択肢は「自転車に乗り続ける」や「自転車を降りて移動する」であり、「寝る」や「膝立ち」に遷移することはない。このように、次に起こりうるコンテキストの種類を制限することで認識精度が向上する。また、従来の認識システムではコンテキスト遷移時に遷移前と遷移後の行動のデータが混ざることによって認識ミスが起こっていたが、提案方式によって遷移時の精度低下が改善され、必要とするセンサ数を減らすことができる。認識すべきコンテキスト数が増えた場合、全コンテキストを選択肢としては誤認識が増えるため、遷移するコンテキストを制限することの効果はより大きくなる。

3.4 コンテキストウェアシステム

本論文で提案するコンテキストウェアシステムの構成を図 4 に示す。コンテキストウェアシステムとはユーザのコンテキストに応じた処理を行うシステムであり、行動認識システムは其中でセンシングデータの意味を解析し装着者の行動を認識する部分である。提案システムは、センシングデータの情報を CLAD を経由して取得し、その際誤ったデータが存在する場合に補完部で補完処理を行う。その後、認識部でセンシングデータの意味を解析し、コンテキストの粒度および遷移を考慮してユーザの行動を認識し、ルールエンジンに認識結果を渡す。ここで、GPS の位置情報や温度情報など解析の必要がないものはルールエンジンに直接渡される。イベント駆動型ルールエンジン¹³⁾ではイベント・コンディショ

ン・アクションの3つの命令で記述されたルールに従ってサービスを提供する。アクション部には出力および入力装置の制御に関する記述もあり、プラグイン経由あるいはCLAD経由で装置の制御を行う。たとえば、脈拍データを受け取った場合、その脈拍値が180以上であれば危険であるため警告を表示するルールや、ユーザが立ち止まったときにその位置での地図を表示するルールなどが記述できる。

また、提案システムでは、認識アルゴリズムとして多くの研究で用いられている記憶ベース推論¹⁴⁾、自己組織化マップ¹⁵⁾およびサポートベクタマシン¹⁶⁾を用いることが可能である。予備実験よりそれぞれの認識アルゴリズムは同様の挙動を示し、サポートベクタマシンが最高の性能を示したため、本論文ではサポートベクタマシンについてのみ述べる。

サポートベクタマシン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¹⁶⁾。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、 $x_i \in \mathbb{R}^N$ 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 $f(x_i) = w \cdot x_i + b$ 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。

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

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。

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

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 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、 $C = 50,000$ 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。

4. 評価

4.1 評価環境

評価では両手首、両足首、腰の5カ所に加速度センサ装着した20代の被験者5人（男性3人、女性2人）から採取したデータを用い、オフラインで解析した。被験者らは表2に示すシナリオに従って行動した。指示は簡単でかつ、偶然途中で知人と出会って会話するなど自由度は高く、データは日常生活に限りなく近い環境のものである。シナリオ中には歩く、走る、階段を昇る、階段を降りる、自転車に乗る、横になる、膝立ち、座る、立つの基本的な9つの行動⁷⁾が含まれている。

使用したセンサは3軸加速度センサ¹⁷⁾、サンプリング周波数は20Hzである。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 1.2GHz）を使用した。評価では採取したデータをオフラインで解析したが、図5に示すオンラインで補完・認識するシステムも構築済みである。構築システムでは、現在のコンテキストの3Dオブジェクトの再生や、遷移可能なコンテキストの表示、加速度センサのグラフ表示をリアルタイムで行い、要求する認識精度の設定、補完の有無、遷移考慮の有無を設定できる。システムは要求する認識精度を満足し最も移動センサ数が少ないセンサの組合せの中から最も精度の良いものを検索しセンサの電源制御を行い、電源を切断したセンサのデータを補完して認識する。認識可能なコンテキストは本評価で用いたものと同じ9種類である。

図6に被験者のうち2人の生データと手作業で付けたコンテキストを示す。図より基本的な行動の流れは類似しているが、細部で異なる点があることが分かる。上図の被験者は歩行中に何度か止まっているのに対し、下図の被験者はコンテキストの変化が少ない。さらに、自転車に乗る前に上図の被験者は止まっているのに対し、下図の被験者は歩いている。このように、評価データにはさまざまな状況が含まれており、評価データとして適切である。

表2 評価実験のシナリオ

Table 2 Scenarios performed in the evaluation.

屋外	指示：自転車で生協までジュースを買いに行く
	研究室 → 階段を下りる → 廊下を通り駐輪場へ行く → 自転車で生協へ → 自動販売機でジュースを購入 → 研究室に戻る
屋内	指示：論文誌を読み、休憩後、用事のために上の階へ行く
	本棚から論文誌を探す → 椅子に座って論文誌を読む → ソファで休憩する → 用事のため急いで上の階へ行く → 研究室に戻る




図 5 オンラインアプリケーション

Fig. 5 On-line application.

一般的に状況認識を行う際、センシングデータの値をそのまま使うのではなく、挙動を効率的に把握するために特徴量抽出と呼ばれる処理を行う。本研究では、現在時刻 $t = T$ と仮定し、次式に従い 15 次元のセンシングデータ（認識ベクトル） $c_i(T)$ ($i = 1, \dots, 15$) の過去 20 サンプル（1 秒）の平均 $\mu_i(T)$ および分散 $\sigma_i(T)$ を特徴量とする。なお、サンプル数を変化させた場合も認識精度に大きな影響はないことを確認している。

$$\mu_i(T) = \frac{1}{20} \sum_{t=T-19}^T c_i(t)$$

$$\sigma_i(T) = \frac{1}{20} \sum_{t=T-19}^T \left\{ c_i(t) - \mu_i(t) \right\}^2$$

ここで、平均 μ と分散 σ はスケールが異なり等価に扱うことができないため、30 次元のベクトル $\mathbf{X}(T) = (\mu_1(T), \dots, \mu_{15}(T), \sigma(T) \cdots \sigma_{15}(T))$ を次式に従い標準化し、特徴ベクトル $\mathbf{Z}(T)$ （平均 0, 分散 1）を得る。ここで $\mathbf{M}$ および $\mathbf{S}$ は $\mathbf{X}$ の各成分の平均および標準偏差である。

$$\mathbf{Z}(T) = \frac{\mathbf{X}(T) - \mathbf{M}}{\mathbf{S}}$$

ユーザにセンサを装着して収集したデータには手動でラベル付けし、全データの 10% を学習用およびペアデータベース構築用、残り 90% を評価用データとして使用した。




図 6 生データおよび手作業によるコンテキスト付与

Fig. 6 Raw data and hand-labeled context of test subjects.

4.2 ハードウェアの評価

初めに CLAD およびセンサの消費電力を測定した。電源電圧 5.18 V における稼働センサは 40.9 mW、非稼働センサは CLAD からの信号に応答するために 11.4 mW を消費する。CLAD のみの消費電力は 92.2 mW である。5 つのセンサをすべて稼働させた場合（以下、フル稼働）、5 つの稼働センサと CLAD で 296.7 mW 消費する。ここで、本論文における評価は CLAD を基盤として用いており、消費電力はセンシングや通信に用いられるだけでなく、エラー検出や電源制御にも用いられている。将来さらに低消費電力のセンサが開発された場合でも、同様に CLAD も低消費電力化されると予想されるため、省電力効果は生じる。また、より細かな動作を検出するために多数センサを用いる環境では電源制御によってさらなる省電力効果が得られる。

また、本論文では CLAD プロトタイプメモリの少なさから疑似データ生成を PC 上で行ったが、補完に使用するメモリはペアデータベースを含めて約 6 MB であり、十分オンメ





図 7 各シチュエーションにおけるコンテキストの認識結果の Confusion Matrix
Fig. 7 Confusion matrices for each situation.

モリで動作する。また、補完に要する消費電力は PC の駆動時間から間接的に計測した結果、約 20 mW であった。高性能マイコンを用いて CLAD 内に補完処理を実装することは今後の課題であるが、その場合でも低消費電力版 SH マイコンなどを用いると、その消費電力は 100 mW 程度となる。

4.3 コンテキスト群の評価

はじめに 3.2 節で述べたコンテキスト群に対する認識精度の評価を行う。評価結果を図 7 に示す group × group の Confusion Matrix で表す。この結果は 5 個すべてのセンサを稼働させ、補完処理はまったく行っていないときのものである。各セルはコンテキスト出力結果の回数を示している。対角線上の色の着いたセルが正しく認識が行えたときのものである。たとえば、シチュエーション 3 において「歩く」データが入力された場合、17,513 回正しく認識し、75 回走っていると誤認識している。Confusion Matrix を用いることで各コンテキストの認識の難易度が分かる。図 7 より自転車や横になるというコンテキストは認識が容易だが「階段降りる」や「膝立ち」は認識が困難であるなど、コンテキストごとに




図 8 各センサ組合せにおける各コンテキスト群の認識精度
Fig. 8 Accuracy vs. sensor combination in each situation.

認識率が大きく異なることが分かる。このようにコンテキストごとに認識精度が異なるため、各コンテキストのデータ量が均一でない環境では、データ全体に対しての認識精度を求めることは正しい結果とはいえない。つまり、「自転車」のデータを多く含んでいるデータセットと「横になる」データを多く含んでいるデータセットでの認識精度は前者の方が必然的に良くなる。本論文では公正な認識結果を得るためにコンテキストごとの認識精度を求め、それらの平均値を求めることで全体の認識精度とした。結果より、シチュエーション 1、シチュエーション 2 およびシチュエーション 3 での平均認識精度はそれぞれ 92.94%、92.43%、87.69% となり、粗いグループの方が認識率が良いことが分かる。

次に、各コンテキスト群に対してセンサ数を変化させ補完手法を用いた場合の認識精度を図 8 に示す。横軸はすべてのセンサが壊れた場合を除く 31 通りのセンサの組合せを示しており、○ は稼働、空白は非稼働を意味する。縦軸は認識精度を示す。図 8 中の仕切りは稼働センサ数ごとに区切って見やすくするためのものである。先にも述べたとおり、粗いシチュエーションほど認識精度が良いことが分かる。また、稼働センサ数が減るにつれて認識精度が低下しているが、2.2 節に述べた補完手法により認識精度の低下は小さい。比較のため、補完手法を用いず非稼働センサを稼働センサのセンシングデータの平均値で補完したものも図中に示す。これにより単純な補完では稼働センサ数の減少につれて認識精度が大幅に低下することが分かる。結果より、シチュエーション 1 において稼働センサ数 1 個以上の認識精度はフル稼働時と同等であり、シチュエーション 2 においても同様の傾向である。シチュエーション 3 においても同様であるが、コンテキストが細かく認識が困難であるた

Table 3 Optimal sensor combinations and their power consumption.

表 4 コンテキスト適用前後のコンテキスト認識精度
Table 4 Change in accuracy by context-transition.

[illegible]

図 9 全センサ組合せにおけるコンテキスト遷移適用前後の認識精度

Fig. 9 Accuracy vs. sensor combination before and after applying context-transition.

© 2009 Information Processing Society of Japan

4.5 考 察

処理時間について 本章の評価における被験者の1人のサンプル数1,226個のペアデータベースにおいて疑似データ生成の処理時間を測定した結果、稼働センサ数2個の場合が最大で1サンプルあたり19.6ミリ秒であった。一方、サポートベクタマシンの認識に要する時間は0.1ミリ秒以下であり、補完処理と比較すると無視できる。提案手法はリアルタイムで用いることを想定しているが、処理時間は評価環境におけるデータ取得間隔50ミリ秒より短い。また、文献18)では、サンプリング周波数10~100Hzまでの10Hz刻み、分解能1ビット~16ビットまで1ビット刻みの各組合せで認識精度を評価しており、周波数10Hzまたは分解能1ビットの組合せのみ認識精度が大きく低下している。提案システムの周波数は20Hz、分解能は8ビットであるため、本条件が認識精度に与える影響は少ない。

無線接続への応用について 提案手法の無線接続への応用可能性について述べる。有線接続では電源供給を停止したのに対し無線接続ではスリープコマンドを送信することで提案手法は応用可能である。したがって、BluetoothやZigBeeなどの通信機構を持つセンサデバイスによって構築される無線ウェアラブルセンサシステムにおいても、提案する省電力機構は適切に動作すると考えられる。また、無線化した場合はセンサが電源を持つ。腰やカバンの中など邪魔にならない部分に装着するウェアラブルコンピュータとは異なり、センサは手首や足首などに装着するため装着性が重要視される。そのためバッテリー容量は小さくなくてはならず、センサの電源制御をウェアラブルコンピュータのリソースを用いて行うことは有用である。

5. ま と め

本論文では消費電力を考慮してセンサの組合せを変更するコンテキストウェアシステムを提案した。ユーザの状況や利用しているアプリケーションによって認識すべきコンテキストの種類が異なると想定し、いくつかのコンテキストをまとめた「コンテキスト群」やユーザの行動遷移を考慮することで最適なセンサの組合せになるようにセンサの電源制御を行った。その結果、提案システムを用いることで認識精度を維持しつつ消費電力を削減したコンテキストウェアシステムが構築できた。提案システムは稼働センサ数が変化しても、欠損しているセンサの値を補完するため、新たに認識器や学習データを用意する必要はなく、他の研究者が開発した認識アルゴリズムに容易に応用可能である。

現在では可視光や紫外線センサによって屋内外の検出を95%以上の精度で行える¹⁹⁾。またGPSや、PHSやLANの電波基地局からの電波強度などによる位置検出も可能である²⁰⁾。

現段階では状況の検出をこのようなデバイスを用いて行うか、ユーザ自身の手で切り換えなければならないが、将来研究として、加速度センサのみでコンテキスト履歴やコンテキストの共起関係などからユーザの状況を推測し、状況に応じて自動的にセンサの組合せを変更するメカニズムを開発する予定である。

謝辞 本研究の一部は、独立行政法人情報処理推進機構2006年度下期未踏ソフトウェア創造事業「ウェアラブルコンピューティングのためのイベント駆動型ミドルウェア開発」、文部科学省科学研究費補助金基盤研究(A)(20240009)、および特定領域研究(19024046)によるものである。ここに記して謝意を表す。

参 考 文 献

- 1) 塚本昌彦：モバイルコンピューティング，岩波新書(2000)。
- 2) Toda, M., Akita, J., Sakurazawa, S., Yanagihara, K., Kunita, M. and Iwata, K.: Wearable Biomedical Monitoring System Using TextileNet, *Proc. Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.119-120 (2006)。
- 3) Shen, C.L., Kao, T., Huang, C. and Lee, J.H.: Wearable Band Using a Fabric-Based Sensor for Exercise ECG Monitoring, *Proc. Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.143-144 (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 (2002)。
- 5) Naya, F., Ohmura, R., Takayanagi, F., Noma, H. and Kogure, K.: Workers' Routine Activity Recognition using Body Movement and Location Information, *Proc. Int'l Symposium on Wearable Computers (ISWC 2006)*, pp.105-108 (2006)。
- 6) 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, No.9, pp.3327-3339 (2008)。
- 7) Laerhoven, K.V. and Gellersen, H.W.: Spine versus Porcupine: A Study in Distributed Wearable Activity Recognition, *Proc. Int'l Symposium on Wearable Computers (ISWC 2004)*, pp.142-149 (2004)。
- 8) Phidgets Inc. <http://www.phidgets.com/>
- 9) 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.sssj.co.jp/>
- 10) Kanagal, B. and Deshpande, A.: Online Filtering, Smoothing and Probabilistic Modeling of Streaming data, UMD CS Technical Report, CS-TR-4867 (2007)。
- 11) Krause, A., Ihmig, M. and Rankin, E.: Trading off Prediction Accuracy and Power Consumption for Context-Aware Wearable Computing, *Proc. Int'l Symposium on*

Wearable Computers (ISWC 2005), pp.20–26 (2005).

- 12) Ho, J. and Intille, S.S.: Using Context-Aware Computing to Reduce the Perceived Burden of Interruptions from Mobile Devices, *Proc. Conference on Human Factors in Computing System (CHI 2005)*, pp.909–918 (2005).
- 13) Wearable Toolkit. <http://wearable-toolkit.com/>
- 14) 山口和範, 高橋淳一, 竹内光悦: 図解入門よくわかる多変量解析の基本と仕組み—巨大データベースの分析手法入門, 秀和システム (2004).
- 15) Kohonen, T.: *Self-Organizing Maps*, Springer (1996).
- 16) Vapnik, V.: *The Nature of Statistical Learning Theory*, Springer (1995).
- 17) Wireless Technologies, Inc. <http://www.wireless-t.jp/>
- 18) Junker, H., Lukowicz, P. and Tröster, G.: Sampling Frequency, Signal Resolution and the Accuracy of Wearable Context Recognition Systems, *Proc. Int'l Symposium on Wearable computers (ISWC 2004)*, pp.176–177 (2004).
- 19) 林 智天, 川原圭博, 田村 大, 南 正輝, 森川博之, 青山友紀: マルチセンサを用いたユーザコンテキストの推定に関する一検討, 電子情報通信学会ソサイエティ大会, B-15-3 (2003).
- 20) 長谷川幹雄, 井上真杉, ウダーナ・バンダーラ, 南 正輝: コンテキストウェアサービスモビリティとスマートスペース, 情報通信研究機構季報, Vol.52, No.4, pp.101–110 (2006).

(平成 20 年 3 月 3 日受付)

(平成 21 年 2 月 3 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。



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。2000 年同大学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。2004 年には英国ランカスター大学客員研究員を兼務。博士 (工学)。ウェアラブル・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。



竹川 佳成 (正会員)

2003 年三重大学工学部情報工学科卒業。2005 年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修士課程修了。2007 年同専攻博士課程修了後, 神戸大学自然科学系先端融合研究環重点研究部助教となり, 現在に至る。博士 (情報科学)。音楽情報科学, ウェアラブルコンピューティングの研究に従事。



西尾章治郎 (正会員)

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。