

センサの組合せ制御機構をもつ低消費電力な コンテキストウェアシステムの開発

村尾 和哉^{†1} 寺田 努^{†2}
竹川 佳成^{†3} 西尾 章治郎^{†1}

本研究では、稼働させるセンサの数を柔軟に制御することで低消費電力を実現するコンテキストウェアシステムを提案する。単純に稼働センサ数を減らすだけでは状況認識の精度が低下してしまうため、利用環境に適したコンテキストの粒度での認識および人間の行動遷移を考慮した認識を行うことで少ないセンサでも十分な認識精度を得られるようにする。提案システムでは、稼働センサ数を変更しても非稼働センサのデータを補完するため、追加の認識器や学習データは必要ない。提案システムを用いることにより、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が実現できる。

Development of a Low-Power Context-Aware System with a Sensor Combination Control Mechanism

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

In this paper, we propose a low-power context-aware system by changing a number of active sensors. Although the decrease of a number of active sensors causes a drop in accuracy, the accuracy can be recovered by recognition with appropriate granularity of contexts and with consideration of human context transition. Even if the number of sensors changes, since the data for shut-off sensors is complemented by our proposed algorithm, no extra classifier and no extra training data are required. Our experiments make it clear that power consumption is reduced without large accuracy decrement by using our system.

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⁾。(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：コンピュータは常に電源が入っており、使いたいときにすぐに使える。(3)

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。ウェアラブルコンピューティングの発展に伴い、筋電計²⁾や心電図³⁾、GSR(皮膚電気反射)⁴⁾、自作デバイス⁵⁾といったさまざまなセンサを用いたコンテキストウェアシステムが提案されている。コンテキストウェアシステムは健康管理⁴⁾や看護師の日常行動認識⁶⁾、組立てやメンテナンスタスクのサポート⁷⁾などさまざまなサービスに応用されている。健康管理システム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行う。具体的には、腕時計型センサがBluetoothでPDAにセンシングデータを送信し、PDAは装着者の行動(食事、歩行、仕事など)を認識する。運動不足や過労を検知すれば、警告を表示する。

看護師の日常行動認識システムは、看護師が毎日同じように行う作業を支援する。看護師はお互いにコミュニケーションをとり薬剤の二重投与などの医療事故を防ぐために看護日誌にその日の出来事を記録しなければならないが、記録は面倒で、誤記入の可能性も

^{†1} 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
Department of Multimedia Engineering, Graduate
School of Information Science and Technology, Osaka
University, Japan
^{†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境重点研究部
Core Research Division, Organization of Advanced Sci-
ence and Technology, Kobe University

ある。このシステムは加速度センサと IR-ID 受信器を用いることで、位置情報や手などの動きから点滴や車椅子の補助などの看護師の行動を認識・記録する。

両研究共通に、加速度センサが行動認識における主要な役割を担っているが、従来の加速度センサを用いたアーキテクチャは消費電力と認識精度の観点から見ると最適であるとはいえない。従来のシステムは使用するセンサの数はあらかじめ固定され、かつ高い認識精度を得るために多数のセンサを装着しており、常に全てのセンサを必要とするとは限らないために冗長な構成になっている場合がある。しかし、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。

筆者らの研究グループではこれまでに、これらの問題を解決するためのウェアラブルコンピュータとセンサの中継デバイスである CLAD(Cross-Linkage for Assembled Devices)を開発してきた⁸⁾。一般的にウェアラブルコンピューティング環境ではユーザに特化したサービスを利用するために、ユーザは複数のセンサを装着する必要がある。しかし、複数のセンサを装着する際に以下の3つの問題点が生じる。

- 電源管理
ウェアラブル環境では電源は有限であり、複数のセンサ利用によって消費電力が増大する
- センサの動的切替え
アプリケーションの同時利用や切替のためにセンサの動的な切換えが必要
- 故障対策
衝撃や水分などでデバイスが頻発に故障する

CLAD は必要なセンサにのみ個別に電源供給を行う。また、通電中に脱着可能なホットプラグに対応する。さらに、故障・電圧低下・異常値などのトラブルの自動検出や代替機器への切替え、擬似的なデータ生成を行うことでこれらの問題点を解決している。しかし、電源管理に関しては、電源容量の少ないときに駆動時間を延ばすことを目的としていたため、積極的な電源制御による低消費電力化は行えていなかった。

そこで本論文では、CLAD を基盤として用い、電源管理を柔軟に行う機構を実現することで低消費電力・高精度の行動認識システムを構築する。

以降、2章で我々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. CLAD

本節では、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、故障したセンサのデータを補完する擬似データ生成機能について述べる。CLAD は、ウェアラブルコンピューティング環境においてユーザが複数個およ

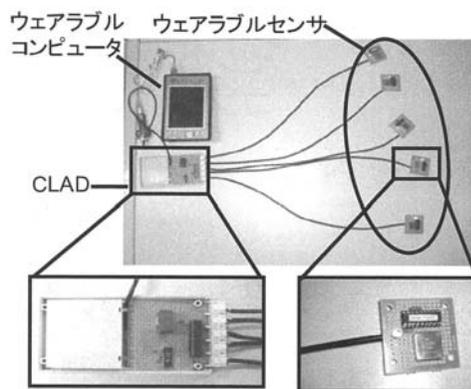


図 1 CLAD

び複数種のセンサを装着する状況を想定して、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 は柔軟な電源制御による省電力化および柔軟なエラー制御によりデータの通信信頼性を実現する。図 1 に CLAD のプロトタイプを示す。CLAD のサイズは幅 76mm×高さ 13mm×奥 70mm、センサのサイズは幅 45mm×高さ 12mm×奥 45mm である。CLAD は内部に電源をもち、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 (CPU) を搭載し CLAD の要求に答えたり、種類、精度、出力範囲、起動時間、動作電圧、動作電流などのセンサに関するプロフィール情報を保持し、接続しているセンサのプロファイル情報は CLAD が把握している。CLAD は以下に示す特徴をもつ。

- 代替機器検索/切替
CLAD は連続したデータの異常や欠損からセンサの異常を検出する。異常検出時には、接続されているデバイスから代替機器を特定し、存在すれば起動して利用する。
- 省電力
CLAD は内部電源を常に監視している。電圧低下時は優先度の高いセンサを残したり、消費電力の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消費電力を低減する。
- 過電流検出
過電流検出時、装着者の感電や装着機器の発火の恐れがあるため、安全のために全てのセンサへの電源供給を停止する。
- エラー検出
CLAD は範囲外のデータやバッテリー残量の低下などの問題を検出する。CLAD がそれらの問題を PC に知らせることで、アプリケーションはバッテリーの交換を画面に表示するなど問題に対して個

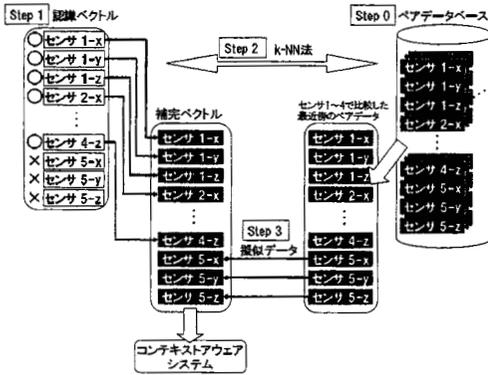


図2 擬似データ生成手順

別に対応できる。

● 擬似データ生成

上記の代替機器検索の結果、代替機器が存在しない場合、CLADは過去のセンシングデータや他のセンサとの相関を用いて擬似データを生成する。アプリケーションによっては、データが得られないと提供するサービスの質が低下し、最悪の場合システムが停止する。センシングデータの欠損値を擬似データによって補完することでアプリケーションの動作信頼性が向上する。

CLADの機能のうち最も特徴的なものは擬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に擬似データ生成の例を示す。この例では5個の加速度センサを用いたコンテキストウェアシステムを利用し、5つ目のセンサ(センサ5)が故障している想定している。擬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は正常稼働時に、あらかじめ全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. 擬似データの抽出

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。

擬似データ生成アルゴリズムはセンサの種類やコンテキストウェアアルゴリズムに依存しないため、提案手法はどのようなシステムにも適用可能である。

擬似データ生成において、いかに真値に近いデータで補完できるかは、Step 2. のペアデータの抽出に依存する。単純に各センシングデータ間のユークリッド距離をとるだけでは2つのコンテキストの稼働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、正しいコンテキストのペアベクトルの抽出が困難である。センサは人間が装着するため、センサ間に何らかの相関が現れ、相関を用いることでより高精度の補完ができると考えられる。センシングデータxとセンシングデータyの相関の表現として次式に示すピアソンの積率相関係数を採用する。相関係数はペアベクトルの分散値から計算される。

$$cor(x, y) = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}, \quad (x \neq y)$$

認識ベクトル $X = (x_{1x}, x_{1y}, x_{2x}, \dots, x_j, \dots, x_{5x}, x_{5y}, x_{5z})$ およびペアベクトル $P_i = (p_{i1x}, p_{i1y}, p_{i1z}, \dots, p_{ij}, \dots, p_{i5x}, p_{i5y}, p_{i5z})$ ($i = 1, \dots, N$) から、次式に示す距離 $dist_{m,i}$ が最小となるペアデータを選択する。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、 x_{1z} 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る。

$$dist_{m,i} = \sqrt{\sum_{j \in working} \frac{\{x_j - p_{ij}\}^2}{cor(x_m, x_j)}}$$

具体的には、センサ m のデータを補完する場合、稼働センサ j のデータとペアデータベース内の i 番目のペアベクトルのセンサ j のデータとの距離を求め、センサ m とセンサ j の相関係数で除したものを全ての稼働センサに対して和をとる。この作業をペアデータベース内の全てのペアベクトルに対して行い、 $dist_{m,i}$ が最小になるペアベクトルのセンサ m のデータを用いてセンサ m のデータを補完する。ここで、補完に用いられるペアベクトルは1つとは限らず、故障センサのデータごと異なる。本手法では、ユークリッド距離では等距離にあるデータでも、相関の弱いものは距離が大きくなり、そのペアデータが最近傍のものとして選ばれにくくなる。最終的に最近傍のペアベクトル $P_{I_m} (I = \arg \min \{dist_{m,1}, \dots, dist_{m,N}\})$ を検索し、補完ベクトル $C = (c_{1x}, c_{1y}, c_{1z}, \dots, c_m, \dots, c_{5x}, c_{5y}, c_{5z})$ を生成する。

$$c_m = \begin{cases} x_m & (m \in working) \\ p_{I_m} & (m \in malfunctioning) \end{cases}$$

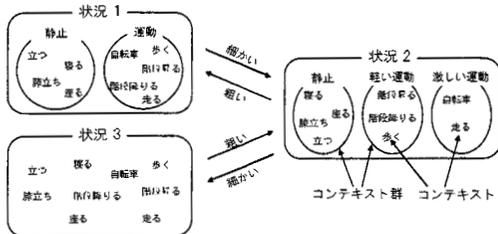


図3 コンテキスト群の例

3. システム構成

CLADにおける擬似データ生成の目的はセンサのハードウェア面でのエラーによる認識精度低下を防ぐためであった。一方、擬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制御することで消費電力を抑えられる。そこで、我々はユーザの状況や利用しているアプリケーション（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し、次節以降に述べる3つの省電力機構もつコンテキストウェアシステムを提案する。

3.1 要求される認識精度を考慮した省電力

要求される認識精度はシチュエーションによって変化する。例えば、人命に関わる環境で利用する場合には常に最高の精度が要求される一方、日常生活の利用では認識精度より稼働時間を求めるユーザもいる。具体的には激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探す。一方、普段の生活では下限値を低く設定する。このように、従来のシステムでは常に全てのセンサを用いなければならなかったのに対し、閾値を設定す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。

3.2 コンテキストの粒度を考慮した省電力

従来のコンテキストウェアシステムは高精度で認識するために多数のセンサを用いていた。しかし、実際の生活では学習した全てのコンテキストから答えを出す必要はない。つまり、健康管理システムは詳細なコンテキスト情報を要求するため多数のセンサが必要であるのに対し、HMDの情報提示システム⁹⁾は動いているか否かの簡単な情報しか要求しないため少数のセンサで十分である。

本研究では、コンテキスト群と呼ぶ学習データの部分集合を定義する。例えば、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を想定している。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

現行動	次行動									
	歩く	走る	階段降りる	階段昇る	自転車	横になる	膝立ち	座る	立つ	
歩く	○	○	○	○	○	○	○	○	○	○
走る	○	○	○	○	○	○	○	○	○	○
階段降りる	○	○	○	○	○	○	○	○	○	○
階段昇る	○	○	○	○	○	○	○	○	○	○
自転車	○	○	○	○	○	○	○	○	○	○
横になる	○	○	○	○	○	○	○	○	○	○
膝立ち	○	○	○	○	○	○	○	○	○	○
座る	○	○	○	○	○	○	○	○	○	○
立つ	○	○	○	○	○	○	○	○	○	○

図4 コンテキスト遷移

行った時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。この想定のもとで、初めにユーザや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する。次に、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探す。もしユーザが所望のコンテキスト群がない場合、新たにコンテキスト群を定義する。例えば、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器の調整や学習データの追加を必要とせず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 コンテキスト遷移を考慮した省電力

人間の行動遷移に着目すると、人間は基本的に今の行動を続け、次に発生するコンテキストは現在のコンテキストに制限される。5人の被験者（男性3名、女性2名）に一定時間行動させ、そこから9つの行動（歩く、走る、階段降りる、階段昇る、自転車に乗る、横になる、膝立ち、座る、および立つ）に対して行動遷移を調べた結果を図4に示す。表より、自転車からの遷移先の候補は「自転車に乗り続ける」か「自転車から降りる」しかなく、「横になる」や「膝立ち」などは考えにくい。次に全ての遷移元コンテキストに対して認識器を学習する。現在のコンテキストで次に起こりうるコンテキストの候補を制限することで誤認識を削減し認識精度の向上を図る。認識すべきコンテキストの種類が増えるほど、本手法は効果的に働くことが期待できる。

4. 評価

本節では認識精度と消費電力の点から提案システムの評価を行う。

表 1 評価で行われたシナリオ

屋外	指示: 生協まで自転車でジュースを買いに行く 研究室 → 下階へ → 廊下を通り自転車置き場へ → 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、休憩後用事を思い出し上階へ 本棚から論文誌を探す → 椅子で論文誌を読む → ソファで休憩 → 用事を思い出し上階へ → 研究室に戻る

4.1 評価環境

評価では両手首、両足首、腰の5箇所に加速度センサを装着した5人の被験者から採取したデータを用いた。被験者は表1に指示されたシナリオに従って行動した。いずれの指示も単純であり、被験者によっては道で出会った友人と話すために立ち止まったり、異なるルートで生協に向かうなど自由度の高いものとなっている。シナリオは歩く、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9つの行動⁵⁾から構成され、前者5行動は動的、後者4行動は静的なものである。使用したセンサは3軸加速度センサ、サンプリング周波数は20Hzである。コンテキストウェアアルゴリズムは我々はこれまでに記憶ベース推論(MBR)や自己組織化マップ(SOM)¹⁰⁾、サポートベクタマシン(SVM)¹¹⁾を用いてきたが結果の傾向はどのアルゴリズムも共通しており、その中でもSVMの性能が最も高かったためSVMを採用した。図5に2人の被験者の生データと実験後に手作業で付けたコンテキストのラベルを示す。図に示すように、両者のデータは全体的な流れは似ているが、細かい点では異なる。例えば、上図の被験者は歩くと止まるを短い周期で繰り返す一方、下図の被験者は細かな行動の変化は少ない。さらに自転車に乗る前に上図の被験者は立っているのに対し、下図の被験者は歩いている。このように評価に用いたデータはさまざまな特徴があり、評価データとして適しているといえる。

一般的に、コンテキストウェアアルゴリズムに対してセンサから得られた生データをそのまま使わず、特徴量抽出と呼ばれる前処理を行うことでセンシングデータに含まれる情報を把握する。そこで本論文では、現在時刻を $t = T$ として、15次元のセンシングデータ(認識ベクトル) $c_i(T)$ ($i = 1, \dots, 15$) に対し過去20サンプルの平均 $\mu_i(T)$ および分散 $\sigma_i(T)$ をとる。

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

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

30次元のベクトル $X(T) = [\mu_1(T), \dots, \mu_{15}(T), \sigma_1(T), \dots, \sigma_{15}(T)]$ を正規化し特徴ベクトル $Z(T)$ を得る。ここで M および S は、それぞれ X の平均および標準偏差である。

表 2 消費電力 @ 5.18 V

ハードウェア	消費電力 [mW]
CLAD のみ	92.2
稼動センサ	11.4
非稼動センサ	40.9

ここで M および S は、それぞれ X の平均および標準偏差である。

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

正規化後、 $Z(T)$ の各成分は平均0、分散1となる。

採取したデータに対し手作業でラベル付けし学習用データを作成した。学習用データは採取したデータ全体の20%であり、テストデータとは異なる。ペアデータの量は学習用データの量と同等である。

4.2 評価結果

はじめに、CLAD およびセンサの消費電力を測定した。表2に結果を示す。非稼動センサはスタンバイ状態で11.4mW消費する。「CLADのみ」とはセンサを一つも接続せずCLADのみの消費電力を示す。この表から、5つのセンサが全て稼動している状態で297mW消費することがわかる。

4.2.1 コンテキスト群の評価

まず初めに、3.2節で述べたコンテキスト群に関して認識精度の点から評価を行う。結果を図6に示すグループ×グループのconfusion matrixで表現する。この結果は5個全てのセンサを利用し、補完は行っていないときのものである。各セルは各行動が入力(行)されたときの結果(列)の回数で、網掛けした対角線上のセルの数字が正解を選んだ回数である。認識精度は入力回数に対する正解数の割合である。図下部の平均認識精度はコンテキスト毎の精度の平均値であり、データ全体に対する正解の割合ではない。コンテキストごとに利用したデータサンプル数が異なる環境下ではデータ全体に対して平均を取るとデータサンプル数の多いコンテキストに偏るため、コンテキスト毎の平均値を採用した。Confusion matrixを用いることで各コンテキストの認識の容易さが明らかになる。図より、コンテキストによって認識精度に大きな違いが見られる。例えば、「自転車に乗る」と「横になる」は高いが「階段を降りる」「膝立ち」は低い。結果より、コンテキストをグループ化することで認識率が向上していることが分かる。

次に、各シチュエーションにおいて補完手法を用いた場合の認識精度を図7に示す。横軸は31通りの稼動センサの組合せ(○は稼動、空白は非稼動)を、縦軸は認識精度を示す。図中の縦の仕切りは稼動センサ数の変化する境界を示す。先に述べたようにコンテキスト群が大きいほど認識精度は良く、稼動センサ数が少ないほど精度が減少していることが分かるが、2章で述べた補完手法を用いているために精度の減少は小

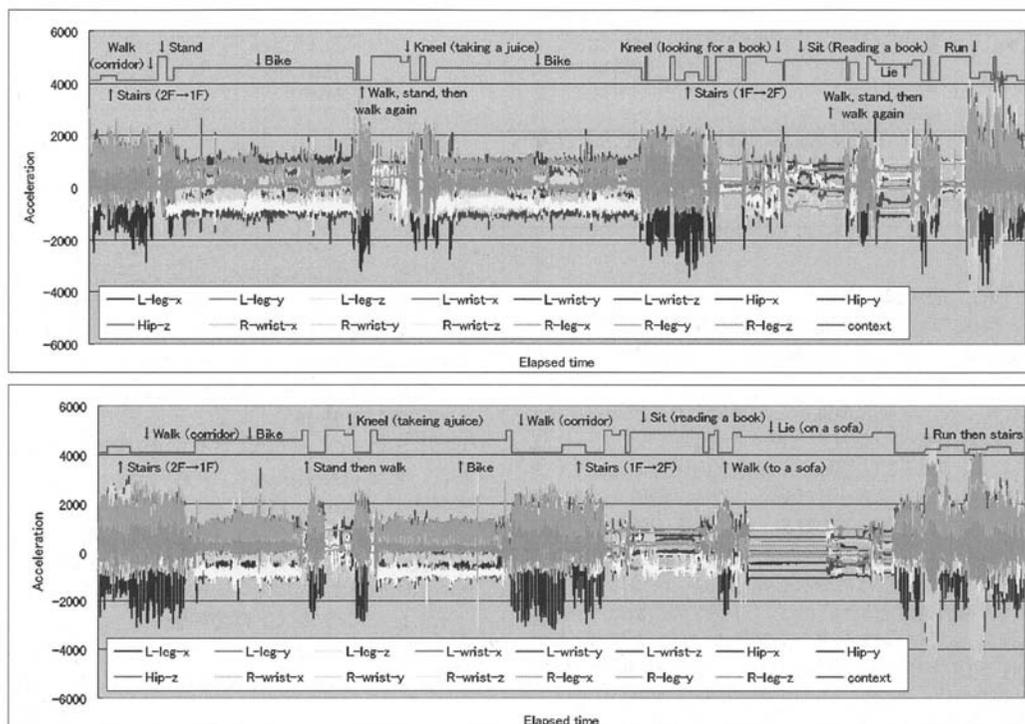


図 5 生データおよび手作業によるコンテキスト

さく済んでいる。比較手法として欠損値を他の稼働センサのデータの平均値で補完したものを示す。正しく補完しない場合、精度は大きく減少している。結果より、シチュエーション 1 の稼働センサ数が 2 個以上において、認識精度はセンサが 5 個稼働時（以下、フル稼働時）と同等である。シチュエーション 2 においても同様の傾向が見られる。シチュエーション 3 においても同様の傾向が見られるが、コンテキスト群が細かいため認識精度は劣る。つまり、センサを切ることによって精度を維持したまま消費電力を削減でき、適したシチュエーションで認識することで認識精度が上昇する。

各シチュエーションにおける最適なセンサの例を表 3 に示す。許容精度は 94,90,87% とする。許容精度とはユーザやアプリケーションによって定義される精度の閾値であり、危険な環境下において許容精度は高く設定され、日常生活において長い稼働時間を求めるのであれば低く設定される。各シチュエーションおよび許容精度において、許容認識精度を満たし、稼働センサ数が最小で、認識精度が最高のセンサの組合せをシステムが選択する。消費電力は表 2 から算出した値であり、一例として 4 つのセンサが稼働している場合、 $92.2 + 40.9 \times 4 + 11.4 \approx 267[mW]$ となる。低減率はフル稼働時と比較した消費電力が減少した割合であ

る。いずれの組合せにおいても許容精度を満たさない場合はフル稼働時のものを示す。94%の許容精度においてはシチュエーション 1 で約 20%の消費電力削減に成功している。さらに、87%許容すると全てのシチュエーションにおいて 5 個のセンサすべてを使わずともよいことが分かる。

4.2.2 コンテキスト遷移の評価

表 4 に示すコンテキスト遷移を考慮した場合の認識率を表 3 に示す。これらの結果は 5 個全てのセンサが稼働時のものである。結果より、全てのコンテキストにおいて認識精度が向上している。例えば、自転車に乗っているユーザが歩く場合、図 6 より行動遷移を考慮しないとシステムは 75 回「走る」、147 回「座る」と誤認識しているのに対し、遷移を考慮すると「走る」や「座る」は「自転車に乗る」から遷移する先のコンテキストの候補から除外され、3.99%改善して 91.74%の認識精度を示している。

最後に、コンテキスト群およびコンテキスト遷移の併用の可能性について議論する。シチュエーション 1 における静的および動的のコンテキスト群は互いに遷移可能であり、シチュエーション 2 における 3 つのコンテキスト群に対しても同様に互いに遷移可能であるため、本稿においてコンテキスト遷移をコンテキスト

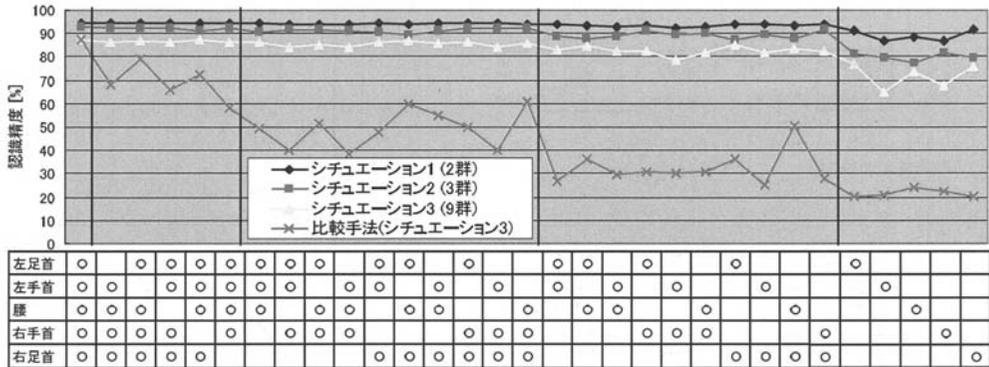


図7 各シチュエーションにおける補充手法による認識精度

表3 最適なセンサの組合せと消費電力

許容認識精度	シチュエーション	稼働センサ数	センサ組合せ	認識精度 [%]	消費電力 [mW]	低減率 [%]
94%	1	3	左手首, 腰, 右足首	94.30	238	19.9
	2	5	全てのセンサ	92.72	297	0
	3	5	全てのセンサ	87.38	297	0
90%	1	1	右足首	92.03	179	39.8
	2	2	右足首, 右手首	91.50	208	29.8
	3	5	全てのセンサ	87.38	297	0
87%	1	1	右足首	92.03	179	39.8
	2	2	右手首, 右足首	91.50	208	29.8
	3	3	左足首, 腰, 右足首	87.08	238	19.9

群に適用し、認識精度を評価することは難しい。しかし、コンテキストの数がさらに増え、コンテキスト群の数も同様に増えた場合、提案手法を同時に利用し、コンテキスト群間の遷移可能性を考慮することで同様の性能が得られる。この点に関する評価は今後の課題である。

5. まとめ

本研究では、稼働しているセンサの組合せを変更することで消費電力を考慮するコンテキストアウトウェアシステムを構築した。認識すべきコンテキストの粒度がシチュエーションによって異なると想定し、いくつかの類似したコンテキストを1つにまとめたコンテキスト群を定義した。さらに人間の行動遷移に着目し、次に起こす行動の候補を絞ることで認識精度の向上を図った。提案システムはユーザのシチュエーションや利用アプリケーションに応じてコンテキスト粒度を変更し、最適なセンサ組合せに電源を制御する。評価より、シチュエーションによっては全てのセンサを利用する必要がなく、提案システムによって消費電力を低減できることがわかった。提案システムの長所は稼働センサ数が変化しても、電源を切ったセンサに対して補完処理を行うため認識器に入力されるセンシング

表4 コンテキスト遷移による認識精度の変化

現コンテキスト	次コンテキスト	精度 [%]	
		適用前	適用後
走る	歩く	87.75	90.49
	走る	84.72	87.10
	階段降りる	78.02	82.31
	階段昇る	82.45	84.21
	自転車に乗る	98.42	98.47
	立つ	85.02	88.17
階段昇り/降り	歩く	87.75	92.32
	走る	84.72	88.03
	階段降りる	78.02	84.35
	階段昇る	82.45	85.79
	立つ	85.02	89.31
自転車に乗る	歩く	87.75	91.74
	自転車に乗る	98.42	98.58
	立つ	85.02	88.89
横になる 膝立ち 座る 立つ	歩く	87.75	93.19
	横になる	98.68	99.24
	膝立ち	79.35	91.14
	座る	94.75	97.53
	立つ	85.02	87.52

データの次元数が変化せず、追加の認識器や学習データを必要としない点である。

将来研究として、現在のシチュエーションを自動的に認識し、動的にセンサの組合せを変更するシステム

		認識精度		
静止	22561	2338	90.61%	静止 22364 1676 879 89.75% 軽い運動 1671 23884 873 91.35% 激しい運動 474 821 32797 96.19%
運動	2564	53835	95.28%	

(a) シチュエーション 1: 平均認識精度 92.94%

		認識精度		
静止	22364	1676	879	89.75%
軽い運動	1671	23884	873	91.35%
激しい運動	474	821	32797	96.19%

(b) シチュエーション 2: 92.43%

		認識精度										
歩く	17513	75	102	155	308	12	68	147	1578		87.75%	
走る	132	2001	118	98	0	0	0	0	13		84.72%	
階段降りる	580	13	2340	20	0	0	0	0	46		78.02%	
階段昇る	489	14	15	2457	5	0	0	0	0		82.45%	
自転車に乗る	304	4	6	23	31141	0	0	35	127		98.42%	
横になる	4	0	0	0	0	5684	0	44	28		98.68%	
膝立ち	130	0	0	22	138	0	1641	21	168		79.35%	
座る	147	0	0	3	35	46	20	7183	147		94.75%	
立つ	835	51	23	41	160	0	223	51	7856		85.02%	

(c) シチュエーション 3: 87.69%

図 6 各シチュエーションにおける Confusion matrix

を構築することを考えている。現行の我々のシステムではシチュエーションを手入力か外部デバイスから与えているが、コンテキストの共起関係などから現在のシチュエーションを推定できるのではないかと考えている。

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)(17200006)、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) M. Miyamae, T. Terada, M. Tsukamoto, and S. Nishio: "Design and Implementation of an Extensible Rule Processing System for Wearable Computing," in *Proc. of MobiQuitous 2004*, pp. 392-400 (Aug. 2004).
- 2) M. Toda, J. Akita, S. Sakurazawa, K. Yanagihara, M. Kunita, and K. Iwata: "Wearable Biomedical Monitoring System Using TextileNet," in *Proc. of ISWC 2006*, pp.119-120 (Oct. 2006).
- 3) Kawahara, Y., Sugimoto, C., Arimitsu, S., Morandini, A., Itao, T., Morikawa, H. and

Aoyama, T.: "Context Inference Techniques for a Wearable Exercise Support System," in *Proc. of SIGGRAPH 2005*, pp.95, (2005).

- 4) K. Ouchi, T. Suzuki, and M. Doi: "Life-Minder: A wearable Healthcare Assistant," in *Proc. of IWSAWC 2002*, pp. 791-792 (July 2002).
- 5) K. V. Laerhoven and H. W. Gellersen: "Spine versus Porcupine: a Study in Distributed Wearable Activity Recognition," in *Proc. of ISWC 2004*, pp. 142-149 (Oct. 2004).
- 6) F. Naya, R. Ohmura, F. Takayanagi, H. Noma, and K. Kogure: "Workers' Routine Activity Recognition using Body Movement and Location Information," in *Proc. of ISWC 2006*, pp. 105-108 (Oct. 2006).
- 7) T. Stiefmeier, G. Ogris, H. Junker, P. Lukowics, and G. Tröster: "Combining Motion Sensors and Ultrasonic Hands Tracking for Continuous Activity Recognition in a Maintenance Scenario," in *Proc. of ISWC 2006*, pp. 97-104 (Oct. 2006).
- 8) K. Murao, Y. Takegawa, T. Terada, and S. Nishio: "CLAD: a Sensor Management Device for Wearable Computing," in *Proc. of IWSAWC 2007*, (June 2007).
- 9) J. Ho and S. S. Intille: "Using Context-Aware Computing to Reduce the Perceived Burden of Interruptions from Mobile Devices," in *Proc. of CHI 2005*, pp. 909-918 (Apr. 2005).
- 10) T. Kohonen: "Self-Organizing Maps," Springer, (1996).
- 11) V. Vapnik: "The Nature of Statistical Learning Theory," Springer, (1995).