

動作推定のための個人適応性を考慮した センサデータ処理手法の一検討

宮本 真梨子^{†1} 今井 信太郎^{†1}
新井 義和^{†1} 猪股 俊光^{†1}

センサで取得した観測対象者の加速度データをホストにおいて解析・処理して行動推定を行うシステムでは、センサの増加に伴うネットワーク負荷の増大が問題となる。この問題に対して、センサの近傍においてデータを処理し、ネットワークに流すデータ量を削減することが有効である。また、動作推定においては、年齢や健康状態の異なる観測対象に対応するため、推定のための基準を個人に対応させて決定することが有効である。そこで本研究では、センサノード近傍に存在するホスト（中間ホスト）における、動作推定のための個人適応性を考慮したセンサデータ処理手法を提案する。そして、実際に高頻度でデータが生成される加速度センサを用いて行動推定を行うプロトタイプシステムを作成し、実験を行った。その結果、提案手法により、センサデータ解析・処理のための方針を自律的に変更でき、さらに外部ネットワークへの負荷を軽減できることを示した。

A Sensor Data Processing Method Taking Account of Personalization for Human Motion Estimation

MARIKO MIYAMOTO,^{†1} SHINTARO IMAI,^{†1}
YOSHIKAZU ARAI^{†1} and TOSHIMITSU INOMATA^{†1}

A human motion estimation system that analyzes and processes data of acceleration acquired from sensor nodes at a server far from the sensor nodes tends to consume network resources. To solve the problem, reducing the data amount from the sensor nodes by processing them at a server near them is effective. To maintain the accuracy of the motion estimation, it is important to modify criteria of estimation according to characteristics of the target persons: age, condition, sex, and so on. In this paper, we propose a data processing scheme considering modification of criteria according to target persons at a server near the sensor nodes. Experimental results using practical data obtained from a prototype show that the proposed scheme can reduce the network traffic with-

out degradation of estimating accuracy.

1. はじめに

現在、小型の無線センサデバイスを用いることで実世界に存在する人間や物体、実空間の環境をリアルタイムに観測し、様々なサービスを提供するシステムが提案されている。このようなシステムの例として、独居高齢者の介護、在宅モニタリングを目的とした見守りサービスがあげられる。これは、観測対象者の身体に複数のセンサを取り付け、加速度や脈拍、体温などのデータをリアルタイムで取得し、解析・処理することによって現在の行動や健康状態など推定し、見守る側の利用者に情報を通知するサービスである。

このようなサービスを実現するために必要な要素技術のひとつに観測対象者の動作推定がある。これは、観測対象者に取り付けられた加速度センサや角速度センサなどのモーションセンサからのデータを解析・処理し、観測対象者の動作の変化の検知や、現在どのような動作を行っているかを推定するための技術である。観測対象者の転倒を検知して利用者に通知するようなサービスの場合、観測対象者の動作推定は高い即応性と情報の正確性が求められるため、より重要である。本研究では、特に加速度センサを用いた観測対象者の動作推定を対象とする。

加速度センサの特徴として、高いサンプリング周波数でデータを取得するため他のセンサに比べてデータ量が多くなることがあげられる。加速度センサから取得したデータの解析・処理には、ネットワークへデータを送信して外部のホストコンピュータで行う場合と、センサノード上で行う場合がある。外部のホストでデータの解析・処理を行う場合、高度なデータ解析・処理が可能となる一方、取得したデータを逐次ネットワークへ送信するため、センサノードの増加に伴いネットワークに与える負荷が問題となる。センサノード上でデータの解析・処理を行う場合は、センサノード上で取得した加速度データの解析・処理を行うため、データ送信量を減らすことが可能である。しかし、計算資源が乏しいため、パターン認識のような高度な解析・処理を行うことは困難となる。このため、閾値判定など単純な解析・処理による動作推定となり、個人に対応した動作推定基準の構築などの個人への適応性

^{†1} 岩手県立大学 ソフトウェア情報学研究科

Iwate Prefecture University Graduate School of Software and Information Science

が低くなる可能性がある。

以上の背景から、筆者らの研究グループでは、ネットワークの負荷軽減と、高度なセンサデータ解析・処理の両立を目的としたセンサノードの近傍に存在するホスト（中間ホスト）によるセンサデータの解析・処理手法を提案している^{1),2)}。これらの研究では、動作推定の識別手法として単純な閾値判定を用いている。中間ホストにおいて、高度なデータ解析・処理を行う手法が蔡らによって提案されている³⁾。この研究では、識別手法として教師なしデータ分類手法の K-means 法を用いている。しかし、K-means 法による動作推定では推定精度の初期値への依存が大きいためという問題がある。このため、観測対象者の各個人に対し動作推定のための適切な初期値を設定しなければならないという問題がある。

そこで本研究では、1) ネットワークの負荷軽減と、2) 個人に適応した動作推定の実現を目的とし、中間ホスト上でのセンサデータ解析・処理において、パターン認識手法の中でも高い汎化能力を持つ Support vector machine (SVM) を用いて動作推定を行うセンサシステムを提案する。これにより、新たな観測対象者に対する動作推定において、観測対象者同士の状況比較から適切な初期値を求めて設定する必要はなく、SVM を用いて構築した識別のための基準を使用することで、推定精度を大きく落とさずに動作推定することが期待できる。また、中間ホストは推定結果に基づきセンサノードへ動作設定の変更指示を行う。これにより、ネットワークの負荷軽減が期待できる。

2. 中間ホストにおけるセンサデータ解析・処理

2.1 関連研究

センサノード上で加速度センサからのデータの解析・処理を行って動作推定を行う手法として、センサノードで取得した傾きを 4bit 信号に変換して送信する研究⁵⁾ などがある。これらの手法ではセンサノード上でデータ解析・処理を行い抽出したコンテキストを外部のホストへ送信するため、外部のネットワークへのデータ送信量を削減することが可能である。しかし、センサノードの計算資源は大きくないため、高度なデータ解析・処理が困難である。

取得した加速度データを外部のホストで解析・処理する研究は数多く行われている。スペクトル分析を用いた研究⁶⁾ や、決定木を用いた研究⁷⁾⁸⁾⁹⁾ の他に、音声認識や文字認識などで用いられるパターン認識技術を用いた研究も多く行われており、SVM を用いた研究⁷⁾⁸⁾ や、Nearest Neighbor(NN) を用いた研究⁷⁾⁸⁾、隠れマルコフモデルを用いた研究¹⁰⁾ などがある。これらの研究では、センサノードから取得した大量の加速度データは、解析・処理のために外部ホストへと集められる。外部ホストはセンサノードに比べ計算資源が大きい

め、前述のパターン認識技術などの高度な解析・処理が可能である。しかし、加速度センサは高頻度でデータを取得してそのままネットワークに送信するため、センサノードの消費電力が大きくなるという問題や、ネットワークに大きな負荷を与えるという問題がある。

児玉らの研究では、高頻度に発生する加速度データをセンサノード上で処理するためのルール型動作制御方式を提案している¹¹⁾。この方式では、センサノード上での加速度データ処理だけでなく、センサノードのルール変更による外部ホストでのデータ解析・処理を実現している。

これらの研究に対して、筆者らの研究グループではセンサノード近傍に存在するホスト（中間ホスト）においてセンサデータを解析・処理する手法を提案している¹⁾²⁾。この手法では、高頻度に発生するセンサデータを中間ホスト上で解析・処理し、抽出したコンテキストや処理済みデータなどを必要に応じて外部ホストへ送信する。中間ホストはデータ解析・処理結果に基づき、センサノードの動作設定を動的に変更する。これにより、ネットワークへのデータ送信回数の削減やセンサノードのセンサデータ送信回数の削減が実現される。実際に動作推定を行うプロトタイプシステムを用いた実験では、センサノードから送信されるデータ量を 50.8 %削減することができている。表 1 に、従来手法と、中間ホスト上でのセンサデータ解析・処理手法との比較を示す。

また、蔡らの研究³⁾ では、高度なデータ解析・処理として教師なし分類手法の K-means 法を用いて動作推定を行っている。プロトタイプシステムを用いた実験において提案手法ではデータ送信回数を全体で 41 %削減できている。また、精度を大きく落とさずセンサノードからのデータ送信回数の削減ができることを確認している。しかし、K-means 法による動作推定ではランダムに決定されるクラスタの初期中心によって、生成される推定の基準が変化する。このため、推定精度がクラスタの初期中心に大きく依存するという問題があった。これに対して、蔡らは年齢や性別などの近い観測対象者の既知のクラスタ中心を用いて推定基準を作成することを提案している。しかし、この提案手法では観測対象者らの状況比較から適切な初期値を割り当てるための、年齢や性別などの詳細な情報を大量に保存・管理する必要があるという問題がある。

2.2 中間ホストにおけるセンサデータ解析・処理の概要

図 1 に、中間ホストにおけるセンサデータ解析・処理の概要を示す。

中間ホストにおけるセンサデータ解析・処理では、ネットワークを内部ネットワークと外部ネットワークに区別している。中間ホストとセンサノード間のセンサシステムに係した通信のみを内部ネットワークとし、インターネットや LAN を外部ネットワークとする。

表 1 従来手法と提案手法の比較

Table 1 Comparison of the proposed method and conventional method

	センサノード上での処理	外部ホストでの処理	中間ホストでの処理
外部のネットワークへの負荷 高度なデータ解析・処理	×	×	

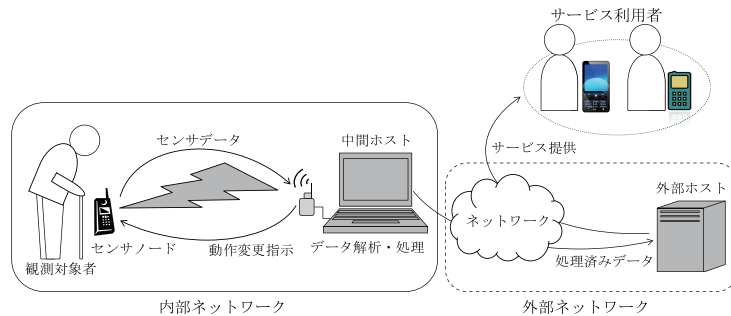


図 1 中間ホストにおけるセンサデータ解析・処理の概要

Fig.1 Method for sensor data analysis and processing using a neighborhood host

中間ホストは、観測対象者に取り付けたセンサノードから送信される加速度データを解析・処理し、観測対象者の動作推定を行う。動作推定結果に基づき、必要に応じて中間ホストは外部ネットワークを介して外部のホスト（以後、このホストを外部ホストと呼ぶ）へとコンテキスト等の処理済みデータを送信する。外部ホストは、処理済みデータを用いて利用者にサービスを提供する。さらに、中間ホストはセンサノードへ加速度データ取得間隔の変更などの動作変更命令を送信する。

2.3 中間ホストを用いたセンサデータ解析・処理の流れ

図 2 に、提案手法におけるセンサノードと中間ホスト、外部ホスト間の処理の流れを示す。処理は、基本動作と不定期動作からなる。

(1) 基本動作

サービス終了まで繰り返される動作である。観測対象者に取り付けた加速度センサから取得したセンサデータの解析・処理を行い、動作推定を行う。

(a) センサデータ取得、センサデータ送信：

センサノードは設定された動作に従い、加速度センサのデータを取得して中間ホストへ送信する。

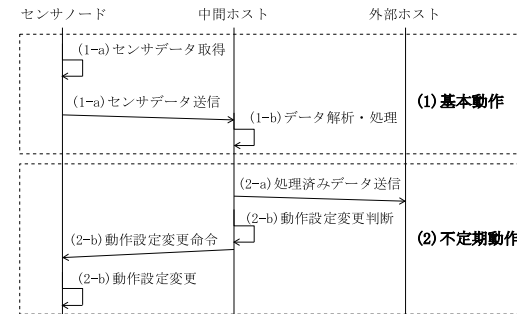


図 2 提案手法の処理の流れ

Fig.2 The flow of proposed method

(b) センサデータ解析・処理：

中間ホストは受信した加速度データの解析・処理を行い、その結果から観測対象者の動作推定を行う。

(2) 不定期動作

中間ホストの動作推定結果に基づき、必要と判断された場合に行われる動作である。中間ホストは動作推定結果からセンサノードの動作設定の変更が必要であるか否かの判断を行い、必要であればセンサノードへ動作設定変更命令を送信する。また、外部ホストへの処理済みデータ送信も、中間ホスト側で必要と判断した場合のみ送信される。

(a) 処理済みデータ送信：

中間ホストは必要に応じて外部ホストへ処理済みデータを送信する。

(b) 動作設定変更判断、動作設定変更命令、動作設定変更：

中間ホストは解析・処理結果に基づき、センサノードの動作設定の変更が必要と判断した場合、センサノードに動作変更命令を送信する。命令を受信したセンサノードは、命令に従って動作設定の変更を行う。

2.4 動作推定方法

本研究では、教師あり学習の SVM⁽⁴⁾¹⁴⁾ を中間ホストにおける動作推定のための識別器として用いる。教師あり学習では、事前に与えられるデータ集合（訓練データ）を元に学習を行う。本研究で用いる訓練データは、加速度データから抽出した特徴量（特徴ベクトル）と、対応する識別対象の動作の種類（クラス）の組の集合である。

SVM は 2 クラスに対するパターン識別器であり、特徴としてマージン最大化がある。多くの学習アルゴリズムでは、訓練データを反映した特徴空間上においてクラスの異なるベクトルをいくつか選び、クラスを分類するための識別境界となる超平面を決定するのが目標である。これに対して、SVM では、訓練データを用いて特徴空間上で他クラスとの境界に最も近いベクトルを基準として、識別境界とのマージンが最大になるような超平面を決定する。これにより、未知のパターンに対しても高い識別性能、すなわち高い汎化能力が期待できる。

本研究では、SVM の学習・識別アルゴリズムとして、2 クラス識別器の SVM をマルチクラス識別器に拡張した SVM アプリケーションの Multiclass SVM を用いた¹⁵⁾。

2.5 特徴量の抽出

SVM などの識別器を用いたパターン認識を実現するには、取得した加速度データから特徴量を求めることが必要である。本研究では、加速度データを用いた動作推定において、取得したデータを一定時間のスライディング・ウィンドウに分割し、特徴量を求める手法¹²⁾¹³⁾に基づいた田淵らの研究⁷⁾を参考とした。田淵らの研究ではサンプリング周波数 50Hz、1 ウィンドウ内のサンプル数を 256 とし、128 サンプルずつオーバーラップするように各ウィンドウを配置する。1 ウィンドウの長さは 5.120 秒である。

図 3 に本研究でのスライディング・ウィンドウによるデータの分割を示す。本研究ではデータのサンプリング周波数を 10Hz、1 ウィンドウ内のサンプル数を 64 サンプルとし、32 サンプルずつオーバーラップさせた。したがって、1 ウィンドウの長さは 6.4 秒となる。中間ホストが動作の推定結果に応じてサンプリング周波数の変更命令をセンサノードに送信した場合、ウィンドウの長さは変更せず、1 ウィンドウ内のデータのサンプリング周波数に比例させ、特徴量を計算する。例えば、サンプリング周波数を 10Hz から 5Hz に変更した場合、1 ウィンドウ内のサンプル数も 64 から 32 へと変更し、16 サンプルずつオーバーラップする。本研究では 1 ウィンドウごとに、取得した加速度データの (x, y, z) の 3 軸それぞれの平均、標準偏差を計算して特徴量とする。

3. 実験

3.1 加速度データの取得

実験環境を表 2 に示す。本実験では、「歩行」、「静止」、「階段昇り」、「階段降り」の 4 種類の動作を識別対象（クラス）とした。観測対象者は男性 3 名、女性 5 名の計 8 名。年代別では 20 代が 3 名 (A,B,C)、50 代が 1 名 (D)、70 代が 4 名 (E,F,G,H) である。4 名いる




図 3 スライディング・ウィンドウによるデータの分割
Fig. 3 Data Partitioning by a sliding window

70 代の観測対象者らの健康状態には顕著な差があり、E~H の 4 人それぞれの 4 種類の動作に対する状況は以下のように異なる。

- E: 「歩行」に杖が必要、「階段昇り」、「階段降り」の動作は負荷が大きいためできない
- F: 「歩行」は問題無いが、「階段昇り」、「階段降り」の動作は負荷が大きいためできない
- G: 4 種類の動作をゆっくり行う
- H: 4 種類の動作を問題無く活動的に行う

このことから 70 代の観測対象者 E と F からは「階段昇り」と「階段降り」の加速度データを取得していない。

本実験では、観測対象者の腰部にセンサノード (SunSPOT) を取り付け、「歩行」、「静止」、「階段昇り」、「階段降り」の 4 種類の動作を行った際の 3 軸 (x, y, z) 加速度データを取得する。事前に 8 人の観測対象者から取得した加速度データから、2.5 節で述べた手法により特徴量を抽出し、訓練データを作成する。

実験 1 では、サンプリング周波数を 10Hz に固定して加速度データを取得した場合と、中間ホストからの指示に基づきセンサノードがサンプリング周波数を変更する提案手法とを比較する。提案手法における各動作のサンプリング周波数の設定は、「歩行」と推定した場合は 5Hz、「階段昇り」もしくは「階段降り」と推定した場合は 10Hz、「静止」と推定した場合は 2Hz とした。

表 2 実験環境
Table 2 A Experiment environment

センサ (SunSPOT)	中間ホスト
180MHz 32bit ARM920T コア 512KB RAM/4MB フラッシュメモリ 2.4GHz IEEE 802.15.4 無線 3.7V 720mAh : リチウムイオンバッテリー	Microsoft Windows7 32bit Intel Core i5 4GB RAM

表 3 データ送信回数 (実験 1)
Table 3 Number of data transmission (Experiment 1)

	歩行	静止	階段昇り	階段降り	合計
サンプリング周波数が一定の場合 (回)	3552	224	992	1088	5920
サンプリング周波数の動的変更有り (回)	1664	84	1088	1280	4116

サンプリング周波数を固定した場合と、動的にセンサノードのサンプリング周波数を変更した場合について、以下の項目で比較を行う。

- センサノードからのデータ送信回数
- 実行動に対する動作推定の識別正解率

この実験結果から、提案手法により推定精度を大きく落とさずにネットワークのの負荷軽減が可能であるか検証する。

実験 2 では、ある観測対象者に対し、1) 観測対象者自身の加速度データから構築した動作識別のための基準を用いて動作推定を行う場合、2) 観測対象者と状況の似た他の観測対象者から構築した動作識別のための基準を用いて動作推定を行う場合、3) 観測対象者以外の不特定多数の観測対象者から構築した動作識別のための基準を用いて動作推定を行う場合、それぞれの識別正解率の比較を行う。この実験結果から、動作推定における SVM の個人適応への有用性を検証する。

3.2 実験 1

実験 1 では、サンプリング周波数を 10Hz に固定して加速度データを取得した場合と提案手法を、データ送信回数と識別正解率で比較した。それぞれ「歩行」約 350 秒間、「階段昇り」約 86 秒間、「階段降り」約 134 秒間、「静止」約 22 秒間の加速度データを用いた場合の結果である。表 3 にデータ送信回数の比較、表 4 に識別正解率の比較を示す。

表 3 から、サンプリング周波数を 10Hz に固定した場合に比べて提案手法ではデータ送信回数を全体で約 30.47 % 削減することができている。識別正解率に関しては、提案手法は

表 4 識別正解率 (実験 1)
Table 4 Discernment correct answer rate (Experiment 1)

	歩行	静止	階段昇り	階段降り
サンプリング周波数が一定の場合	90.83 %	100.0 %	77.78 %	85.71 %
サンプリング周波数の動的変更有り	84.4 %	100.0 %	77.78 %	85.71 %

「歩行」が約 6.43 ポイント低下している。これは、サンプリング周波数を 5Hz に設定したため 1 ウィンドウ内のデータサンプル数が減り、実行動が「歩行」のとき、「階段昇り」や「階段降り」と誤推定したためである。そのため、サンプリング周波数が一定の場合に比べ、動的にサンプリング周波数を変更した場合には「階段昇り」と「階段降り」のデータ送信回数が増加している。これについて、平均と標準偏差などの単純な特徴量だけでなく、他の特徴量も増やすことなどで改善できると考えられる。

以上から、提案手法により正解率を大きく落とさずに、センサノードからのデータ送信回数を削減し、ネットワーク負荷を軽減することが可能である。

3.3 実験 2

実験 2 では、まず観測対象者をグループ 1 から 3 に分け、事前に取得した加速度データから、それぞれ訓練データを作成し、識別のための基準を構築した。そして、これらの識別のための基準を用いた場合の、観測対象者 A の実行動に対する動作推定の正解率を比較した。各動作におけるサンプリング周波数の設定は、実験 1 の提案手法と同じとした。

- グループ 1: 20 代の観測対象者 A (観測対象者自身)
- グループ 2: A 以外の 20 代の観測対象者 B, C (観測対象者と状況の似た他の観測対象者)
- グループ 3: A 以外の全員の観測対象者 B~H (観測対象者以外の不特定多数の観測対象者)

表 5 に、グループ 1 から 3 のそれぞれから取得した加速度データを用いて構築した識別のための基準を用いて、観測対象者 A の動作推定を行ったときの識別正解率を示す。グループ 1 のデータから構築した推定基準を用いた場合、「歩行」と「階段昇り」では 80 % 以上、「静止」と「階段降り」では 100 % の識別正解率となっている。このことから、動作推定において識別のための基準を構築するには、観測対象者自身からのデータを用いる事が最も有効であると考えられる。しかし、事前に観測対象者自身から各動作のセンサデータを大量に取得する必要があるため、システム開発者と観測対象者の負担が増加する。

本研究では、推定のための基準の個人への適応性を考慮し、新たな観測対象者に対しての

表 5 識別正解率 (実験 2)

Table 5 Discernment correct answer rate (Experiment 2)

	歩行	静止	階段昇り	階段降り
グループ 1: 観測対象者 A 自身	82.14 %	100.0 %	81.82 %	100.0 %
グループ 2: A に近い 20 代の観測対象者 (B,C)	94.64 %	100.0 %	18.18 %	91.67 %
グループ 3: A 以外の観測対象者全員 (B から H)	85.71 %	100.0 %	9.09 %	100.0 %

推定精度を評価するため、グループ 2 とグループ 3 の比較を行う。グループ 3 のデータから構築した推定基準を用いた場合、「階段昇り」の識別正解率は 9.09 % である。グループ 2 のデータから構築した推定基準を用いた場合は、グループ 3 に比べ、実行動が「階段降り」の、正解率が 8.33 ポイント低下しているものの 91.67 % と比較的高い推定精度となっている。また、「歩行」の識別正解率は 8.93 ポイント向上しており、識別正解率は 94.64 % である。グループ 2 の「階段昇り」の識別正解率は 18.18 % であるが、グループ 3 のデータから構築した推定基準を用いた場合に比べ、識別正解率は 9.09 ポイント向上している。グループ 2 とグループ 3 を比較すると、両グループともに「階段昇り」の推定精度は低い結果であるが、グループ 2 では他の 3 種類の動作に対し 90 % 以上の識別正解率となっている。これは、観測対象者 A に状況に近い 20 代の観測対象者 (B,C) のデータを用いたためと考えられる。しかし、今回の実験では、グループ 2、グループ 3 の観測対象者の人数がそれぞれ、2 人と 7 人と少人数であり、データに偏りがあったため、「階段昇り」のときの結果が著しく低かったと考えられる。より多くの人からデータを収集し、年齢や性別など類似している者同士の加速度データで、推定のための基準を構築することで、推定精度が向上する可能性があると考えられる。以上の結果から、SVM を用いて構築した識別のための基準を使用することは個人に適応した動作推定に対して有効であることが確認された。

4. おわりに

本研究では、1) ネットワークの負荷軽減と、2) 個人に適応した動作推定の実現を目的とし、中間ホスト上でのセンサデータ解析・処理において、パターン認識手法の中でも高い汎化能力を持つ Support vector machine (SVM) を用いて動作推定を行うセンサシステムを提案した。そして、プロトタイプシステムを実装して実験した結果、動作推定の精度を大きく落とさず、ネットワーク負荷の軽減ができることが確認された。さらに、個人に適応した動作推定の実現について、SVM を用いて構築した識別のための基準を使用することは有効であることが確認された。

より多くの人からデータを収集し、年齢や性別など類似している者同士の加速度データで、推定のための基準を構築することで、推定精度が向上する可能性があると考えられる。現状では、実験における観測対象者の人数や、データ取得時間、試行回数が不十分である。各年代の観測対象者の人数を増やし、動作に対する加速度データの取得時間も増やして実験する必要がある。

謝辞 本研究は科研費 (22700079) の助成を受けたものである。

参 考 文 献

- 1) 富田哲郎, 今井信太郎, 猪股俊光, 新井義和: ネットワーク負荷を考慮したセンサデータ処理の一手法, 情報処理学会第 72 回全国大会講演論文集. pp.“3-287”-“3-288”, (2010)
- 2) 今井信太郎, 猪股俊光, 新井義和: 加速度センサを用いた動作推定のためのデータ処理手法の一検討, 第 19 回マルチメディア通信と分散処理ワークショップ論文集. pp. 140-146 (2011)
- 3) 蔡明銳, 今井信太郎, 猪股俊光, 新井義和: 環境の差異を考慮したセンサデータ処理手法の一検討, 情報処理学会研究報告. Vol.2010-DPS-145 No.33, pp.1-8 (2010)
- 4) C. Cortes and V. Vapnik: “Support-vector networks”, *Machine Learning*, 20, 3, pp.273-297 (1995).
- 5) Elisabetta Farella, Augusto Pieracci, Luca Benini, Andrea Acquaviva: “A Wireless Body Area Sensor Network for Posture Detection”, *ISCC*, pp.454-459, 11th IEEE Symposium on Computers and Communications (ISCC'06), (2006)
- 6) 品川佳満, 谷川智宏, 太田茂: 加速度センサを用いた人間の歩行・転倒の検出, *川崎医療福祉学会誌*. Vol.9, No.2 pp.243-250, (1999)
- 7) 田淵勝沼, 納谷太, 大村廉, 野間春生, 小暮潔, 岸野文郎: 加速度センサを用いた日常行動識別におけるデータ収集条件の識別性能への影響評価, *電子情報通信学会技術研究報告*. PRMU, Vol.106(73), pp.43-48, (2006)
- 8) 橋田尚幸, 大村廉, 今井倫太: 加速度センサを用いた日常行動識別における個人適応技術の識別精度への貢献, *電子情報通信学会技術研究報告*. USN, Vol.108(138), pp. 69-74, (2008)
- 9) 石山慎, 高橋修, 宮本衛一: 加速度センサを用いたオフィスでの行動推定, 情報処理学会第 70 回全国大会講演論文集. pp.“3-333”-“3-334” (2008)
- 10) 浅野翔, 伊藤真也, 竹内伸一, 田村哲嗣, 速水悟: 3 軸加速度センサを用いた隠れマルコフモデルによる人間の行動識別, *情報科学技術フォーラム講演論文集*. Vol.7(4), pp. 195-196, (2008)
- 11) 児玉賢治, 藤田直生, 柳沢豊, 塚本昌彦, 義久智樹: センサノードのための加速度データに基づくルール型動作制御方式, *情報処理学会論文誌*. Vol.49, No.11 pp.3732-3742,

(2008)

- 12) L.Bao and S.S Intille : “Activity Recognition from User-Annotated Acceleration Data”, A. Ferscha and F. Mattern (Eds.): PERVASIVE 2004, LNCS 3001, pp.1–17, (2004).
- 13) N.Ravi, N.Dandekar, P.Mysore, and M.L. Littman : “Activity recognition from accelerometer data”, American Association for Artificial Intelligence(www.aaai.org), 2005.
- 14) 前田英作 : 痛快!サポートベクトルマシン : 古くて新しいパターン認識手法, 情報処理 Vol.42, No.7, pp.676–683 (2001).
- 15) Thorsten Joachims : A WEB Page,Multi-Class Support Vector Machine(online), available from http://svmlight.joachims.org/svm_multiclass.html (accessed 2011-4-30).