

# 動作認識のための身体に分散配置した複数慣性センサの身体動作に基づく自己位置認識

## Self-Localization of Distributed Multi Inertial Measurement Units on Body Using Motion Data for Motion Recognition

精密工学専攻 01号 アオ チェン  
Chen Ao

### 1. はじめに

近年、AIの発展に伴い、動作認識はあらゆる分野で利用されている。知能化空間を始め、医療、セキュリティなど色々な場面で実用されている。動作認識は、主にビジョンと加速度センサの二つの手法に分けられている。カメラやセンサなどから人体を検出、そして入力データを取得、特徴量を抽出、そのもとで観測対象が行っている動作を判別する<sup>(1)</sup>。前者は、屋内にカメラを設置するなどの環境で識別を行う。後者は、ユーザにセンサを身につけさせる必要があるが、カメラなどの環境が不要のため、屋内に限らず認識でき、自由度が高く、計算コストも軽いというメリットがある。その他の動作認識やジェスチャー認識には筋電位センサを使用する研究も存在している<sup>(2)</sup>。

加速度センサによる動作認識の研究では、使用するセンサ数により、単一のセンサと複数のセンサを使う研究に分けられる。単一センサを使う研究は、スマートフォンやウェアラブルデバイスに内蔵された慣性センサを利用した研究が多い<sup>(3)</sup>。ユーザが持ち歩く端末に内蔵された加速度計とジャイロなどのセンサから運動データを得て、ユーザは現在どんな動作を行っているかを識別する。通常、ユーザのスマートフォンやウェアラブルデバイスの着用位置は一つに限られていない。例えば、歩行時ではポケットの中、電話するため頭部付近、あるいは地図を見るため手に把持されるなど様々なシーンがあり、違う位置により認識結果が大きく影響を受ける可能性があると考えられる<sup>(4)</sup>。複数のセンサを使う研究では、体にいくつかのセンサを取り付けるため、高い精度、かつより複雑の動作の認識により、エネルギー消費量を計算することが可能になるとわかった<sup>(5)</sup>。一方、各位置の運動特性に応じてテンプレートを設定したため、システムを利用するたび、ユーザが各センサの取り付け位置を手作業で設定する必要がある。これにより、インタラクションの効果を下げると同時に、ユーザに精神的な負担がかかる。

以上より、複数のセンサを使った動作認識システムのための、手作業で位置を設定しなくてもセンサの位置を自動的に認識できる手法が望ましいと考えられる。これらの要件を満たすため、本研究では、動作認識のための身体に分散配置した複数慣性センサの身体動作に基づく自己位置認識手法を提案した。本手法では、複数のセンサを身体に分散配置したことにより、センサの位置に左右されず、全身の動作、かつ複雑の動作の認識が可能になる。センサの自己位置認識より、ユーザはどのセンサをどの部位に付けるかを記憶する必要

がなく、無順序を気にせずつけるだけでシステムが各位置の動作の特徴により各センサの位置を認識し、行動認識を行う。

2章では、動作認識のためのデータ前処理と特徴量選択について述べる、3章では、その特徴量を用いた位置識別手法を述べる、4章では提案手法より位置認識の検証実験について述べる、5章で結論を述べる。

### 2. 自己位置認識システム

#### 2.1 システム概要

自己位置認識のプロセスは、学習と認識の二つのプロセスに分けられる。学習プロセスでは、ユーザはセンサを取り付け、動作して身体各位置のデータを取得する。そして取得したデータに基づいて分類器を学習させ、認識モデルを作成する。認識プロセスでは、同様にユーザの身体にセンサを取り付けて、各センサからの入力データを学習データとマッチングすることによりセンサの着用位置認識を行う。

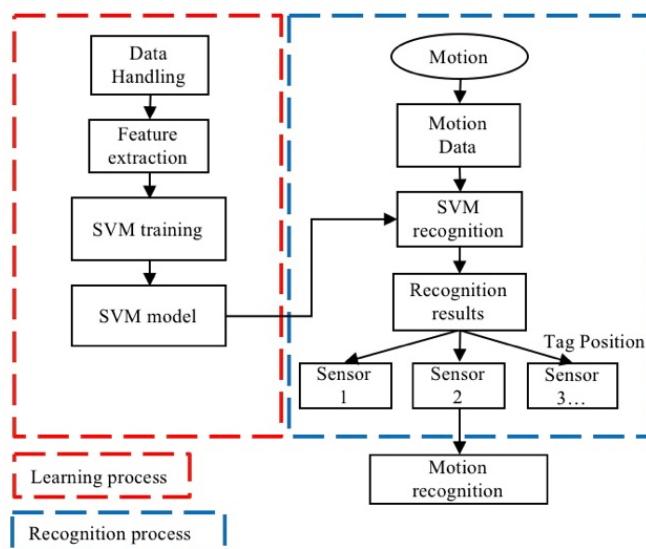


Fig. 1 Overview of the self-localization system

本手法では、Fig. 1で示すように、複数の3軸加速度センサを用いて、まず身体各位置の加速度データをセンシングする。また、前処理として、バターワースローパスフィルタに通し、ノイズを除去する。次に、各位置の時間領域と周波数領域の加速度特徴量を抽出する。その際、抽出された特徴量の次元が異なるため、正規化を行う。そして訓練したSVMによるセンサの位置認識を行う。

## 2.2 3軸加速度センサ

これまでの研究では主に慣性センサ (IMU) を使用している。慣性センサは、運動を司る加速度と角速度を検出する装置である。3軸加速度計とジャイロを内蔵し、これによって、3次元の加速度と角速度を計測できる。近年、MEMS技術の向上により、IMUセンサの小型化と軽量化が実現され、身体に複数のセンサを取り付けて日常生活を送ることが可能になり、センサ自体の値段も大幅に減少した。本研究には、ZMP Inc.の製品 9軸モーションセンサ IMU-Z2 を用いる。このモーションセンサの大きさは縦 36 mm、幅 52 mm、高さ 11mm で、3軸加速度、ジャイロ、地磁気センサを搭載し、加速度計では、各軸の加速度を最大 12bit の分解能で取得し、100Hz で送信する。センサと PC の間の通信方法には Bluetooth による無線通信を利用する。

## 2.3 センサの取り付け位置

センサの取り付け位置には、先行研究<sup>(6)</sup>において動作認識一般的に使われる身体の両側の上肢、手首、太ももなど Table.1 に示された合計 9 個の位置を選定した。これらの位置の加速度データを計測する。

Table 1, Used body positions

No.	Position
1	Left arm
2	Right arm
3	Left wrist
4	Right wrist
5	Waist
6	Left thigh
7	Right thigh
8	Left foot
9	Right foot

## 2.4 特徴量の選択

位置認識にはデータから特徴量を抽出する。そして抽出した特徴に基づく認識モデルを作成する。さらに、目的に応じて特徴量を選択する必要がある。

加速度センサから X, Y, Z 三軸方向の加速度値が得られる。各位置の加速度データは、それぞれの特徴を持つため、窓関数をかけることにより、各窓内の加速度データから特徴ベクトルを抽出する。本研究では、先行研究より一般的な時系列と周波数領域の特徴量を選択する。また、Lu らの研究<sup>(7)</sup>は、加速度波形のキーポイントでの傾きを特徴量として、良い認識結果が得られた。それより本研究では、加速度波形のカーブフィッティング曲線のキーポイント傾きを特徴量とする。これにより、求めた傾きから、異常値と極値の影響を排除できる一方、加速度変化の激しさも反映できる。Fig.2 で示すように、カーブフィッティングした曲線を求め、キーポイントでの傾き (0%, 20%, 40%, 60%, 80%, 100%) を特徴量として用いて、合計 7 つの特徴量を使用した。また、本研究では方向認識を目的に含めないこと、そして計算コストを削

減するため、X, Y, Z からの統合加速度を使用する。用いる特徴量を Table2 に示す。

Table 2, Selected Features

No.	Features	Description
1	Max.	Max(a <sub>i</sub> )
2	Min.	Min(a <sub>i</sub> )
3	Mean	$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i$
4	Std.	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2}$
5	Range	Max(a <sub>i</sub> ) - Min(a <sub>i</sub> )
6	PSD mean	$\mu_{amp} = \frac{1}{N} \sum_{i=1}^N C(i)$
7	Slope of Fitted Curve	See Fig.2

ここで、a は加速度値、i は窓の番号、 $\bar{X}$  はサンプリング平均値、N はサンプリング数、C(i) はスペクトル幅とする。




Fig. 2 Fitted Curve within one frame

## 3. 位置認識のための動作の学習と識別

前章で抽出した加速度の特徴量をもとに、サポートベクターマシン (SVM) を用いてセンサの位置認識を行う。

SVM は現在知られている手法の中で認識性能が最も優れた学習モデルの一つと考えられている<sup>(8)</sup>。Fig.3 のように特徴量を二つのクラスに分類することを想定し、学習データとして各クラスに入力、学習させる。ここで、この二つのクラスを境界になる超平面に分割することが可能と仮定し、超平面から最も近い点とのマージンが最大となる。そして入力データが入力される時、入力データが超平面の上下にある二つのクラスのどちらに所属するかにより分類する。

本研究では、推定に Lin らが開発したカーネル法を用い、LIBSVM<sup>(9)(10)</sup>を適用して実装する。LIBSVM では複数の 1 対 1 分類器を構成することにより多クラス分類を実現する。2 つの位置の学習データで二項分類器を訓練するため、N 個の位置に対して、合計 N(N-1)/2 個の二項分類器が必要である。そしてテストデータは分類器に入力され、Max-Wins 法により分類結果を出す。また、本研究では RBF カーネル関数を用いる。RBF カーネル関数では、許容程度を決めるコストパラメータ C と、決定境界の単純さを決めるパラメータ g があ

る. この二つパラメータは分類結果に大きく影響するため<sup>(11)</sup>, Fig.4 の手法に示すように, グリッドサーチでパラメータをある範囲に絞り, 学習モデルに代入して最適なパラメータを算出する.




Fig. 3 support vector machine principle

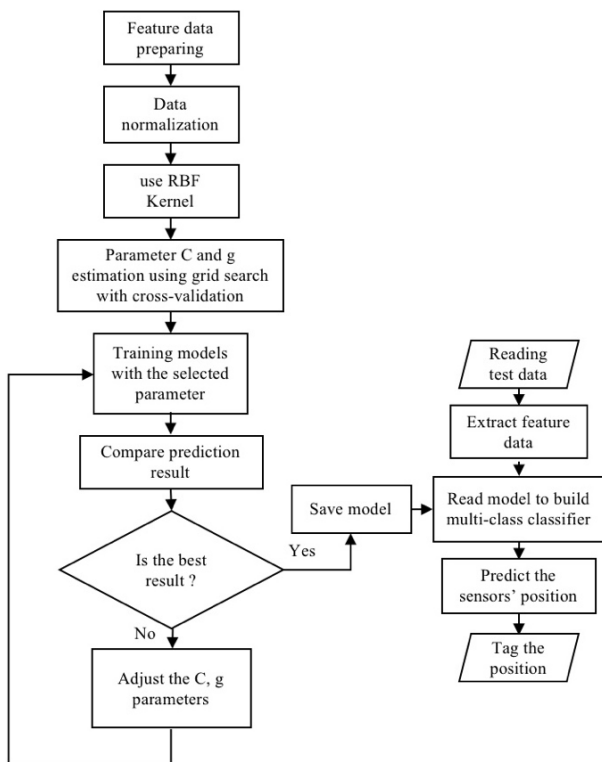


Fig. 4 Method for SVM prediction

#### 4. 検証実験

提案手法による位置認識の精度を検証するため検証実験を行なった. センサを着用する様子を Fig. 5 に示す.




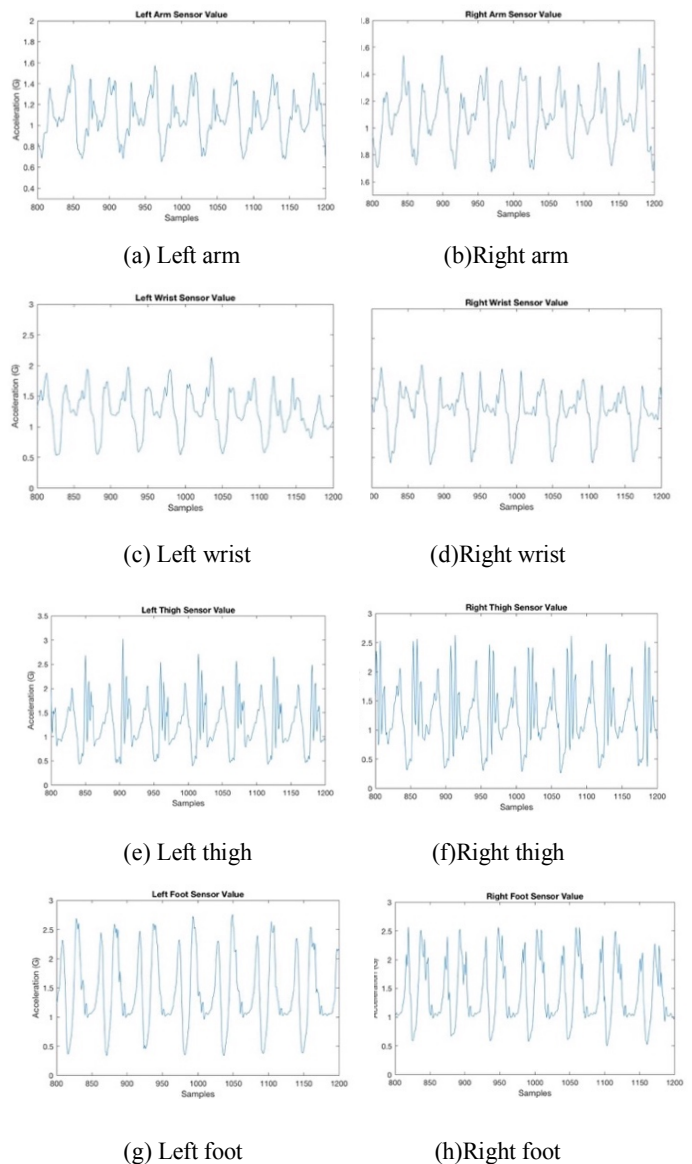
Fig. 5 Sensors placement for the experiment


#### 4.1 実験環境

今回の実験では, 加速度センサを身体 9 個の位置に着用した被験者 5 名の運動データを取得した. データは屋外の直線歩行, 長さは 10 分間とし, サンプル周波数は 100Hz, 切り出し幅が 512, ステップが 50%とする矩形窓をかけたものである. まず実際に身体に付けたセンサの位置に基づきラベルを付ける. そして K 分割交差検証により算出したモデルの精度を検証する. また学習された動作モデルを用いて各センサの位置認識を行う.

K 分割交差検証は, 入力データを K 個に分割し, 1 個がテストセットとし, 残り K-1 個をトレーニングセットとする. 得られた結果を平均化して認識率を求める. 今回はデータを 5 つに均等分割し, 5 分割交差検証を使用する.

また, 学習データの汎用性を検証するため, 5 人の中から 4 人分のデータをトレーニングセットとし, 残り 1 人のデータをテストセットとしてセンサ位置の認識を行なった. 被験者 1 人ずつテストしたため, 計 5 回分の検証を行なった.





(i) Waist

Fig. 6 Sensors' accelerated value of each position


## 4.2 実験結果

各位置から得られた加速度データを Fig.6 に示す. 5 分割交差検証では, 訓練したモデルが K 分割交差検証により 91.5%の平均精度が得られた. また, 各位置の認識結果を Table. 3 に示す. また新しいユーザに対する汎用性検証実験を Fig.7 に示す.

Table 3, Accuracy of the recognition of IMU position

Positions	Accuracy (%)
Left arm	91.3
Left wrist	89.1
Right arm	94.5
Right wrist	92.0
Waist	99.3
Left thigh	94.9
Left foot	92.1
Right thigh	95.0
Right foot	93.2

Fig. 7 Accuracy of the versatility experiment



## 4.3 考察

以上の結果より, SVM によるセンサ位置の識別率は 90% 以上で可能であることが分かった. 新しいユーザに学習データを適用した場合は認識精度がやや落ちたが, 今回は元の訓練データも少ないことから, 被験者数を増やすことにより精度の向上が期待される.

選択されたセンサ位置の中で, 一番認識しやすい位置は腰, 一番認識しにくい位置は手首と分かった. 手首の動作は敏捷であり他の位置の運動の影響を受けやすい, または無意識の動きによる影響があると考えられる.

## 5. おわりに

本稿では, 身体各位置の加速度特性により, 動作認識のためのセンサの自己位置認識手法を提案した. そして学習データの汎用性を確認する実験より, 本手法を適用して未学習である新しいユーザに対してもセンサ位置の認識が可能であることが分かった.

今後の展望として, 位置認識した結果に基づいて動作認識を行う. また慣性センサに内蔵されたジャイロを用い, 角速度を利用することにより, 精度の向上やユーザの向きも考えられる. その場合, 重力の影響を排除するため, 統合加速度を使わず3軸加速度データごとに訓練する必要があると考えられる. またセンサ認識段階の動作数を増やし, 歩行以外の動作でのセンサ位置の検出も考えられる.

## 参考文献

- (1) 松永武文, 尾下真樹, SVM を用いた動作認識の為の動作状態の自動推定, 情報処理学会研究報告グラフィクスと CAD (CG), (2008), pp.31-36.
- (2) Shibanoki, T. Sshima, K. Takaki, T. Tsuji, T. Otsuka, A. and Chin, T., A Class Selection Method Based on a Partial Kullback-Leibler Information Measure for Biological Signal Classification, System Integration (SII), (2010).
- (3) Kwapisz, R. J. Weiss, M. G. Moore, A. S., Activity Recognition Using Cell Phone Accelerometers, ACM SIGKDD Explorations Newsletter, 12-2 (2010), pp. 74-82.
- (4) Shi, Y. Yu, C. Shi, Y., On-Body Position Recognition Method for Mobile Devices Using Rotation Patterns, Journal of Software, 24-8, (2013), pp.1898-1908.
- (5) Altini, M. Penders, J. Vullers, R. Amft, O., Estimating Energy Expenditure Using Body-Worn, IEEE Biomed Health Inform, 19, (2015).
- (6) Atallah, L. Lo, B. King, R. and Yang, G., Sensor Positioning for Activity Recognition Using Wearable Accelerometers, IEEE Trans. Biomed. Circuits Syst., 5-4, (2011), pp. 320-329.
- (7) Lu, X. Wang, H. Wang, Y. Xu, X., Application Research on Acceleration Data Features in Human Behavior Recognition, Computer Engineering, 40-5, (2014).
- (8) 栗田多喜夫, サポートベクターマシン入門, (2002).
- (9) Hsu, C. Chang, C. and Lin, C., A Practical Guide to Support Vector Classification, (2016).
- (10) Hao, W. LI, C, Automatic real-time SVM-based ultrasonic rail flaw detection and classification system, Journal of Graduate School of the Chinese Academy of Sciences, 26-4, (2009).
- (11) LIN, S, LIU, Z, Parameter selection in SVM with RBF kernel function, Journal of Zhejiang University of Technology, 35-2, (2007).