

加速度センサを用いた動的窓幅による行動認識

西面 翼¹ 沼尾 雅之¹

概要：本稿では、従来の加速度センサにおける行動認識の問題点である一定窓幅での行動認識を解消するために行動の周期性、周期時間を用いることで動的に窓幅を変更する手法を提案した。従来手法では窓幅を減少させすぎると全体の分類率が下がることを予備実験で示した。本手法を用いて継続的行動 4 種類について必要最低限の窓幅で行動認識を行った結果、分類精度は向上しなかったものの窓幅の短縮と動的窓幅を可能にした。

1. はじめに

近年、コンピュータが進化し小型化、軽量化、高性能化したセンサ、スマートフォンが普及している。この携帯端末などを利用するユビキタスネットワーク環境の研究が盛んに行われている。ユビキタスネットワーク環境では実空間に存在するあらゆるものがネットワークで結ばれ、情報が流通するようになる。このようなネットワーク上にサービスを実現するためにはユーザの物理的な状況に応じて適切な情報を提供するコンテキストウェアという考え方が重要になる [1]。

コンテキストウェアの技術として、ユーザの行動を識別する行動認識手法がある。行動認識手法では、ユーザが身につけるセンサや環境に設置されたセンサから得られた情報を使い、行動・コンテキストを識別する。本研究では携帯端末を用いた行動認識について扱う。

現代のスマートフォンにはマイク、ジャイロセンサー、加速度センサなど複数のセンサが搭載されているが、加速度センサを用いたコンテキストウェアの研究が盛んに行われている。それらの研究のほとんどには基本的なフレームワークが存在し [2]、そのフレームワークで使用される窓幅は固定であった。

その一方で認識する行動毎に最適な窓幅が存在すると言われている [3]。そこで本研究では窓幅を動的に変更させる手法を提案し実験を行った。

2. 関連研究

2.1 基本的なフレームワーク

Bicocchi らは加速度情報を利用した行動認識研究には基

本的なフレームワークが存在することを指摘した [2]。基本的なフレームワークは次のようなものである。

- (1) 加速度センサをユーザの体に取り付ける。
- (2) 装着されたセンサから加速度データを集め、タグ付けを行う。
- (3) 加速度データから特徴量を算出する。
- (4) 収集したデータの半分を用いてパターン認識アルゴリズムを用いて学習を行う。
- (5) 収集したデータのもう半分を Cross Validation を行い分類する。
- (6) 分類率や Confusion Matrix を用いて評価を行う。

また 3. の特徴量算出は Section 2.2 で紹介した Bao らの示したフレーム解析手法が事実上の標準となっている。

- (1) 加速度データを窓幅 w 、ずらし幅 s で切り出しフレーム化する。
- (2) フレーム毎に特徴量 (平均、標準偏差、フーリエ係数) を算出する。

この手法はセンサの個数やセンサの装着場所を変えた場合でも上手く機能することが従来研究によって示されてきた。それらの研究を次に紹介する。

2.2 単一の加速度センサを用いた行動認識

竹内らは腰に装着した単一の加速度センサを用いて部屋で行う日常的な 6 種類の行動の識別を行っている [4]。一般的な特徴量である平均、分散などを使用せずに入力信号の低域周波数に着目した MFCC と重力加速度の角度情報を利用することで正解精度を約 80 % へ向上させた。また、加速度をフレーム化する際の窓幅の大きさを大きくしすぎると性能が低下することを指摘している。

Ravi らは、腰に装着した単一の加速度センサを用いて日常的な 8 種類の行動認識をする実験を行った [5]。特徴

¹ 電気通信大学大学院 理工学研究科 情報・通信工学専攻

量は、5.12 秒の窓幅から計算され、平均、標準偏差、軸相関が用いられている。学習アルゴリズムには 4 種類用いられ、SVM を用いた場合の認識精度が一番高くなり、73.3 %の精度で認識できることを示した。

2.3 複数の加速度センサを用いた行動認識

Bao らは、ユーザの体に 5 つの 2 軸加速度センサを固定させ、日常的な 20 種類の行動認識をする実験を行った [6]。20 種類と多くの動作数ながら、84 %の精度で認識できることを示した。この研究では加速度情報のフレーム解析に特徴量である平均、標準偏差、周波数領域エントロピーなどが使われた。以降の研究でこれらの手法は頻繁に用いられ行動認識の標準的手法となっている。

村尾らは体の 3 箇所に 3 軸加速度センサを取り付け 16 種類の行動認識をする実験を行った [7]。特徴量のデータ量削減に取り組み、平均値やフーリエ係数の代わりに加速度情報のピーク値を用いることで 95 %の正解率で識別している。

3. 分類精度と窓幅の予備実験

3.1 目的

章 2.1 のフレームワークでは窓幅があまりにも小さい場合、行動の識別ができないのは自明である。しかし各行動毎にどの程度の窓幅があれば認識が可能なのかということが論じられていない。

今回、歩行、走行、スキップ、静止という 4 つの行動について章 2.1 のフレームワークをもとに窓幅を変更しながら (1 秒から 0.05 秒まで) 行動認識を行うことで各行動についての分類率の変化を見て考察する。

3.2 実験環境

- データ
使用するデータは一人分の加速度データ (90 秒) を 2 つ用意した。行動の種類は歩行、走行、スキップ、静止という 4 つの行動である。
- 特徴量
3 軸それぞれの加速度データの平均、分散、最大値、最小値の計 12 次元で算出される。
- 分類器
分類器は学習データとして分類時と同じ窓幅で算出された特徴量で学習された SVM を用いた。

3.3 実験結果

それぞれの行動について横軸を窓幅 (100 で 1 秒)、縦軸を分類精度とした時のグラフを図 1 から図 4 で示す。それぞれの行動についての結果をまとめると、1 つ目に静止に関してはどれだけ窓を小さくしても認識率が高い (窓 0.05 秒で約 98 %の認識精度)。2 つ目にその他の行動に関して

はほぼ単調に減少しているのが見てとれる。

3.4 考察

まずはじめに、静止という行動はとても分散が低いことや平均値のぶれがとても少ないことなどからどのように窓を切っても認識精度が高くなるのだと予測できる。また、歩行、走行、スキップに関してはある値から単調に精度が減少しているように見える。そのある値とは、おそらく各行動の低周波数成分に關係しているのではないかと予測する。今回の各行動の低周波数成分について調べると、走行では 43Hz、スキップでは 93Hz、47Hz、歩行では 127Hz がピーク値となっていた。歩行、スキップに関してはそれらの値から減少率がやや高くなっていることが分かる。歩行に関しては 127 という値から単調減少しているように見えないがおそらく選択した行動に似た行動がないため窓幅が小さい場合でも認識率が良かったのではないかと考える。




図 1 走行における窓幅と認識精度の関係




図 2 歩行における窓幅と認識精度の関係




図 3 静止における窓幅と認識精度の関係




図 4 スキップにおける窓幅と認識精度の関係

4. 行動と窓幅

章 3 で得られた結果より、加速度データの低周波数成分が行動認識における必要十分な窓幅の長さに関係していることが分かる。これがどのように関係しているのかを考える前に行動の種類について考える必要がある。

4.1 行動の種類

行動の種類には大きく分けて 3 種類あると考えられる。具体的な行動の例を表 1 に示す。

- 瞬間的行動
この行動は短期間で終わる行動である。
- 継続的行動
この行動には大きく分けて 2 種類存在する。1 つは同じ動作を繰り返す行動、もう 1 つは同じ状態を維持する行動である。
- 複合的行動
この行動は瞬間的行動、継続的行動の複数からなる行動である。

4.2 必要十分な窓幅

それぞれの行動について従来のフレームワークで分類す

表 1 行動の種類と具体的行動

行動の種類	具体的行動
瞬間的行動	ドアを開ける、ロックする
継続的行動 (繰返し)	歩行、走行、スキップ
継続的行動 (維持)	立っている、座っている
複合的行動	食事をする、買い物をする

るのに必要十分な窓幅について考えてみる。

- 瞬間的行動
この行動は行動のはじめから行動の終わりまでデータが必要であると考えられる。
- 継続的行動
章 3 より同じ動作を繰り返す行動は、繰り返される動作を 1 回行うのにかかる時間 (後述の周期時間) 分以上が必要であることがわかっている。
また同じ状態を維持する行動は、サンプリングレート 100Hz で 0.05 秒でも高精度で分類できることがわかっている。よって必要十分な窓幅は数点で 0.05 秒以上あると良いと考えられる。
- 複合的行動
この行動を従来手法で認識するためにはとても長い窓幅を必要とする。しかし複数の行動が混ざっていることから考えても従来手法ではこの行動の認識には向いておらず、本研究では扱わない。

4.3 周期性のある行動

同じ行動をしているデータに対しある一定窓幅で分割されたそれぞれのデータの類似度が高くなる行動を周期性のある行動と呼ぶことにする。また、そのある一定窓幅の長さ (時間) を行動の周期時間と呼ぶことにする。

波形同士の類似度を見る方法として自己相関関数を用いてみる。実際に歩行データに自己相関関数を用いた場合、図 5 のようになる。縦軸が類似度、横軸がずらし幅 (100 で 1 秒) となっている。図 5 ではピーク値が 128,257 となっていることから、歩行の周期時間が 1.28 秒付近であることが分かる。

今回、動的に窓幅を変更するためにこの周期時間を使う。




図 5 自己相関関数による波形の類似度

5. 動的窓幅による行動認識

行動認識をするのに各行動に最適な窓幅が存在するといわれている [3]。しかし、従来のフレームワークでは窓幅が固定なので全ての行動が最適な窓幅となることがなかった。

5.1 提案手法

継続的行動について窓幅を動的に変更しながら行動認識を行う手法を提案する。その行動認識手法を以下に示す。1 から 4 までをループすることで分類を繰り返す。

(1) 加速度データの取得

通常のフレームワークではずらし幅 s だけデータを取得するが、本研究では前回認識した周期時間、又は一定時間分のデータを取得する。

(2) 周期時間の発見

現在時刻から過去数秒までのデータに周期性があるかどうかを自己相関関数や FFT を用いて調べる。周期性があった場合は周期時間を、周期性がなかった場合は一定時間を特徴量の窓幅、加速度データ取得量として認識を行う。

(3) 特徴量計算

現在時刻から 2. で得た周期時間分のデータを 1 つの窓幅として特徴量計算を行う。

(4) 分類器による分類

目的に応じた分類器を使う。学習は行動の周期時間毎の窓で区切られたデータを用いる。

5.2 実験

今回、従来手法と提案手法との精度の差と窓幅の差を検証する。今回周期時間の取得方法として、簡単な自己相関関数を用いた。また従来手法は Bicocchi らの提唱する基本的なフレームワークをもとに分類を行った。それぞれの実験環境は以下のようにした。データは章 3 で使われたものを使用した。

5.2.1 従来手法の実験環境

- 窓幅
窓幅は常に 2 秒固定とした。
- 特徴量
3 軸それぞれの加速度データの平均、分散、最大値、最小値の計 12 次元で算出される。
- 分類器
分類器は学習データとして 2 秒で算出された特徴量で学習された SVM を用いた。

5.2.2 提案手法の実験環境

- 特徴量の窓幅
自己相関関数より得られた周期時間を使用する。静止は周期性がないので静止と分類出来た場合は窓幅を 0.5 秒とする。また、周期時間がない場合は 2 秒を窓

幅とする。また、

- 自己相関関数の窓幅
自己相関関数によりずらず波形の窓幅は周期時間以上でなければならない。そこで今回は一番周期時間の長い歩行よりも長い窓幅の 2 秒を使用した。
- 特徴量
3 軸それぞれの加速度データの平均、分散、最大値、最小値、周期時間の計 13 次元で算出される。
- 分類器
分類器は学習データとして各行動の周期時間で算出された特徴量で学習された SVM を用いた。

5.3 実験結果

従来手法と提案手法で得られた Confusion Matrix、精度比較や窓幅比較を表 2 から表 5 で示す。

表 2 従来手法と提案手法の窓幅比較

	従来手法	提案手法
jog	2.0 秒	0.43 秒
skip	2.0 秒	0.91 秒
walk	2.0 秒	1.28 秒
stay	2.0 秒	0.5 秒

表 3 従来手法の Confusion Matrix

	jog	skip	walk	stay	適合率
jog	14	3	0	0	82.3 %
skip	3	18	1	0	81.8 %
walk	1	2	26	0	89.6 %
stay	0	0	0	26	100 %

表 4 提案手法の Confusion Matrix

	jog	skip	walk	stay	適合率
jog	66	10	3	0	83.5 %
skip	13	72	2	0	82.7 %
walk	2	4	43	0	87.7 %
stay	0	0	1	103	99.0 %

表 5 従来手法と提案手法の精度比較

	従来手法	提案手法	精度差
jog	82.3 %	83.5 %	+1.2 %
skip	81.8 %	82.7 %	+0.9 %
walk	89.6 %	87.7 %	-1.9 %
stay	100 %	99.0 %	-1.0 %

5.4 まとめ

単純に窓幅を小さくしてしまうと全体の分類精度が悪くなってしまいます。そこで窓幅毎に必要な最低限だと思われる窓幅へ動的に変更することで、データを収集してから結果がでるまでの認識速度が向上した。しかし従来手法と提案手法に精度の差があまりなかった。これは提案手法において問題点があることが精度に影響しているからだと考えられる。その問題点の1つとして周期時間の誤認識にあると考えられる。周期時間を誤認識してしまうとかなり高い確率で分類を誤認識してしまうため、周期時間の取得をより正確にできれば精度向上に努められると考えられる。

6. 今後

精度向上のためにより良い周波数分析法を選ぶことがあげられる。また、周期時間や加速度の強弱には個人差、環境差があることがわかっているのでこれらを軽減する手法としてスケーリングを行うことを考えている。周期性のない行動については今回は実装できなかったが、行動の移り変わりが本研究ではわかるので、それを用いた動的な窓幅の提案をしたいと考えている。

参考文献

- [1] 角康之. 実世界インタラクションにおける状況認識の役割. システム/制御/情報: システム制御情報学会誌, Vol. 47, No. 4, pp. 179-184, 2003-04-15
- [2] N.Bicocchi, M.Mamei, and F.Zambonelli. Detecting activities from body-worn accelerometers via instance-based algorithms. *Pervasive and Mobile Computing*, Vol.6, No.4, pp.482-495(2010)
- [3] T.Huynh and B. Schiele. Analyzing features for activity recognition. In *Proceedings of the 2005 joint conference on Smart objects and ambient intelligence: innovative context-aware services: usage and technologies*, pp.159-163. ACM, 2005
- [4] 竹内伸一, 伊藤真也, 田村哲嗣, 速水悟. 加速度情報を用いた日常行動認識について (デモ展示・ポスター講演, ネットワークプロセッサ, 通信のための信号処理, 無線 lan/pan, 一般). 電子情報通信学会技術研究報告.CAS, 回路とシステム, Vol. 108, No. 453, pp. 229-234, 2009-02-23.
- [5] Nishkam Ravi and Nikhil Dandekar and Preetham Mysore and Michael L. Littman. Activity Recognition from Accelerometer Data. In *Proceedings of the National Conference on Artificial Intelligence*, Vol.20, p.1541(2005)
- [6] Ling Bao and Stephen S. Intille. Activity Recognition from User-Annotated Acceleration Data. *Pervasive Computing*, pp.1-17(2004)
- [7] 村尾和哉, Kristof Van Laerhoven, 寺田努, 西尾章治朗. センサのピーク値を用いた状況認識手法. 情報処理学会論文誌, Vol. 51, No. 3, pp. 1068-1077, 2010