

ウェアラブルデバイスにおけるデータ品質が 行動認識精度へ及ぼす影響

Miyazawa, Yuki / 宮澤, 勇貴

(出版者 / Publisher)

法政大学大学院情報科学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 情報科学研究科編

(巻 / Volume)

14

(開始ページ / Start Page)

1

(終了ページ / End Page)

6

(発行年 / Year)

2019-03-31

(URL)

<https://doi.org/10.15002/00021950>

ウェアラブルデバイスにおけるデータ品質が 行動認識精度へ及ぼす影響

The Impact of Wearable Data Quality on Activity Recognition Accuracy

宮澤勇貴

Yuki Miyazawa

法政大学院情報科学研究科情報科学専攻

E-mail: yuki.miyazawa.8f@stu.hosei.ac.jp

Abstract

This research is to examine the data quality from wearable devices and the possible impact on activity recognition accuracy. In our experiments, multiple wearables were wearied in different parts of a participant for capturing motion data in daily activities such as walking, jogging, stair climbing, stair descending, and sitting. The captured data has been brought about some quality problem when a wearable is misplaced in an improper position, and temporal problems in captured data from one and multiple devices. For a data stream from a single device, the time intervals between samples change greatly around a sampling frequency specified in a sensing program. When multiple devices are used, there exist temporal differences among multi data streams. After raw data pre-processing for certain data quality improvement by means of filtration, interpolation and normalization, we conduct a set of activity recognition with typical machine learning algorithms such as SVM, K-NN, and decision tree. The results have shown that the temporal deviations in sensed data affect the recognition accuracy. The position shift of a device can affect much on the recognition accuracy, but this affect may be mitigated when using multiple devices together for recognition. Furthermore, it is found that the proper selection of feature quantity can improve the recognition accuracy. Among the three methods, SVM doesn't show enough flexible for testing various data situations.

1. まえがき

近年センサの小型化により、スマートフォンやウェアラブルデバイスといった1日中身に着けることの出来るセンサ機器が増加している。これらの機器は加速度やジャイロなどのセンサデータを収集することが出来る。センサを身体に装着しユーザーの日々の行動を認識できれば健康管理やライフログの管理など多岐の分野にわたってサービスを提供できる。行動認識技術の応用範囲は広く、現在までに様々な研究が行われている。

行動認識は身体の様々な場所にスマートフォンやウエ

アラブルデバイスを装着することでユーザーの行動を高精度で認識できる。しかし、複数のデバイスを使用することで生じる問題も存在する。その中の1つが各デバイスのシステム時間のずれやセンサデータの更新頻度の違いによってデータの品質が落ちてしまうことである。また、ウェアラブルデバイスなどのセンサ機器は想定されている正しい装着位置が存在する。多くの行動認識の研究では実験環境が高度に管理されているため常に正しい位置にデバイスが装着されている。しかし日常生活の環境下でデバイスを身に着ける場合、常に正しい位置にデバイスが装着されている保証はない。位置がずれることによりデータが変化する恐れがある。

上述のように、行動認識において様々な要因から、デバイスから取得したデータの品質が低下してしまう可能性がある。そこで、本研究ではウェアラブルデバイスにおけるデータ品質が行動認識精度に及ぼす影響について精査することが目的である。

本論文の構成は以下の通りである。2章で行動認識の関連研究を紹介する。3章で本研究の概要を説明する。4章では行動データ取得実験について述べる。5章では4章で取得した行動データから、データ品質にどのような問題があるか述べる。6章では、5章で述べたデータ品質を改善する処理について述べる。7章は特徴量の抽出について述べる。8章では、行動認識実験で用いる機械学習について説明する。9章では有効な特徴量を選択する方法について述べる。10章では、行動認識実験を行いデータ品質が認識精度に及ぼす影響について考察する。11章では、本研究のまとめと今後の課題について述べる。

2. 関連研究

本章では行動認識の関連研究について述べる。ウェアラブルデバイス等のセンサ機器を用いた行動認識の研究はこれまでに数多く行われている。

S. Leeらの研究[1]では、スマートフォンの3軸加速度センサを利用して、歩く、走る、静止の3つの行動認識を行っている。スマートフォンの位置を固定せずに加速度データの収集を行ったが、識別器がランダムフォレストの場合に89.10%、CNN(Convolutional Neural Network)の場合に92.71%と高い認識精度が報告されている。I. Clelandらの研究[2]では、加速度センサを胸部、手首、腰、

臀部、大腿部、足首の 6 カ所に装着して、歩く、ランニング、座っている、横になっている、立っている、階段上り、階段下りといった 7 つの行動認識を行っている。サポートベクターマシーン (以下 SVM), 決定木, K 近傍法 (以下 K-NN), ニューラルネットワーク, ナイーブベイズの 5 つの識別器を用いている。実験の結果から、認識精度が最も高い識別器は SVM であることが分かった。また、上記の行動を認識するのに最適な加速度センサの装着箇所は臀部であり、加速度センサの装着箇所を増やすことで認識精度が向上すると報告されている。

上記のように行動認識の研究では身体の様々な場所にスマートフォン等のセンサ機器を装着することでユーザーの行動を高精度で認識することが可能となっている。

しかし、寺田[3]によると行動認識技術はユーザーに高度で多岐にわたるサービスが提供できる一方、課題が山積みであると述べている。行動認識技術の課題を解決しようと試みている研究も存在する。A. Henpraserttae らの研究[4]では、スマートフォンを用いて、行動認識におけるデバイスの位置と方向に関する問題を調査している。シャツのポケットとズボンのポケット、ウエストベルトの 3 か所でデバイスを 16 の方向に装着して横になる、座る、立つ、歩く、ランニング、ジャンプの 6 つの行動の実験を行った。結果からデバイスの最適な配置はウエストベルトであることが分かった。デバイスの向きはデバイスの座標系を推定し、加速度データを変換することで認識精度が向上することが報告されている。米澤の研究[5]では、日常生活の環境下でも問題なく稼働する行動認識の為に、デバイスの位置ずれの検出を行っている。腕輪型のウェアラブルデバイスである Myo を用いて、被験者 20 名の歩行データを使用し、約 72.9% の識別率でデバイスの正誤位置判定が行えることが分かった。また走行データのような加速度が強く変動する運動の場合、約 97.0% という高い精度での識別が行えることも判明した。

上記で紹介した研究は、行動認識技術におけるデバイスの装着位置やずれによる認識精度の問題に関する解決を試みている研究である。しかし、行動認識技術に関する問題点は他にも存在する。本研究では、デバイスから取得したデータの品質に着目し、データ品質の問題が行動認識の認識精度にどのような影響を与えているか精査する。

3. 研究概要

本章では、本研究の概要について述べる。本研究の全体的な流れは図 1 に示す通りである。まず、データ品質の精査を行うために、複数のデバイスを使って実際の行動データの取得実験を行う。それぞれの行動に対して加速度データを取得する。次に、データ取得実験によって得られたデータの品質について精査する。その後、問題のあるデータに対してデータ品質を改善する処理を加え、処理を加える前と後の特徴量を抽出する。これらの特徴量を使用し機械学習による行動認識実験を行う。本研究では、機械学習として SVM, 決定木, K-NN を用いる。これらの機械学習が算出した値からデータ品質が行動認識の認識精度にどの程度影響を与えているか考察する。

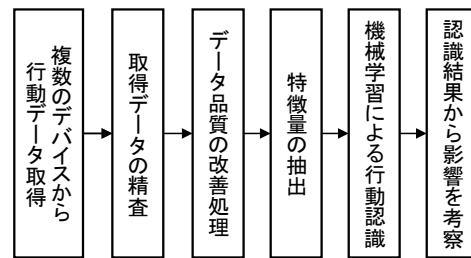


図 1 研究の流れ

4. 行動データ取得実験

本章では、行動データ取得実験について述べる。本研究の目的であるウェアラブルデバイスにおけるデータ品質が行動認識精度に及ぼす影響について精査するために行動データ取得実験を行った。行動データとしてスマートフォンとスマートウォッチの加速度を取得した。21~25 歳の学生 10 名の被験者に協力してもらい、5 種類の行動を行ってもらった。行動は「歩く」、「ジョギング」、「階段上る」、「階段下る」、「座る」の 5 種類である。日常的によく行われている行動としてこの 5 種類に決定した。実験の様子を図 2 に示す。




図 2 実験の様子

左から歩く、ジョギング、座る、階段上る、階段下る

加速度データの取得には AndroidOS 搭載のスマートフォンである ASUS Zenfone Go と、スマートウォッチである LG G Watch Urbane 2 を用いた。2 つのデバイスを図 3 に、装着位置を表 1 に示す。加速度データのサンプリングレートは、LG G Watch Urbane 2 で取得可能な間隔の最短である 10ms とした。Zenfone Go で取得可能な間隔の最短である 20ms とした。



図 3 ASUS Zenfone Go と LG G Watch Urbane 2

表 1 デバイスと装着位置

デバイス	装着箇所
ASUS Zenfone Go	腰, 右上腕, 右前腕, 左大腿, 左下腿
LG G Watch Urbane 2	右手首, 左足首

5. デバイスのデータ品質

本章では 4 章で取得した行動データの品質について考察する。単体デバイスにおける行動データの品質と複数デバイスにおける行動データの品質に分けて述べる。

本研究では主にデバイスから取得したデータの時間的な品質とデバイスの位置的なデータの品質に着目する。本研究における良いデータ品質とは、装着位置が推奨される位置に固定され、複数デバイスのデータ取得のタイミングが揃っており、センサの取得間隔が一定であることとする。

5.1. 単体デバイスのデータ品質

本節では 4 章で取得した行動データのうち、単体デバイスにおけるデータ品質について述べる。初めに時間的なデータ品質について述べる。行動認識における単体デバイスのセンサデータは等間隔の時間で取得できることが望ましい。センサデータの取得間隔が異なると 1 つの特徴量を算出する際のデータ数が異なる。これにより、各特徴量にデータ数の偏りが起き、認識率に影響を及ぼす可能性がある。実際に歩行時のデータ取得の際にある被験者の腰に装着したスマートフォンと足首に装着したスマートウォッチの加速度データの取得間隔を調べた。その結果を表 2、表 3 にまとめる。4 章の加速度データのサンプリングレートはスマートフォンが 20ms、スマートウォッチは 10ms に設定している。しかし、表 2 と表 3 を見ると全てのデータが等間隔で取得できていない。プログラムでサンプリングレートを設定しても実際にデータを取得すると等間隔に取れていないことが分かる。

表 2 スマートフォンのデータ取得間隔

Time Interval	Occurrence	Ratio
4~16 ms	109	0.80%
17~19 ms	2529	18.73%
20 ms	6543	48.47%
21~22 ms	4094	30.33%
23~24 ms	178	1.32%
24~40 ms	47	0.35%

表 3 スマートウォッチのデータ取得間隔

Time Interval	Occurrence	Ratio
1~5 ms	47	0.16%
5~9 ms	2015	7.27%
10 ms	19749	71.16%
11~12 ms	5520	19.90%
12~20 ms	157	0.56%
21~83 ms	263	0.95%

次に位置的なデータ品質について述べる。行動認識においてセンサ機器の装着位置は高度に管理されている。しかし、日常生活ではセンサ機器が常に同じ位置に存在している保証はない。デバイスの装着位置が異なること

により、行動認識の精度に影響を及ぼす可能性がある。しかし、デバイスの細かいずれを管理するのは難しいため、本研究では部位レベルでずれの検証を行う。図 4 に手首、前腕、上腕における歩行時の X 軸の加速度データの一部を示す。図 4 を見ると、部位単位のずれでデータが大きく変化していることが分かる。このような問題点が認識精度に影響を及ぼす可能性がある。




図 4 歩行時における X 軸の加速度データ

5.2. 複数デバイスのデータ品質

本節では 4 章で取得した行動データのうち、複数デバイスにおけるデータ品質について述べる。初めに時間的なデータ品質について述べる。複数のデバイスから取得した行動データには時間的な問題が 2 点存在する。1 つ目は複数デバイス間のシステム時間のずれである。4 章で取得した行動データは加速度データと同時にタイムスタンプを記録している。このタイムスタンプを基にして、複数デバイスの行動データの統合を行う。しかし、デバイスごとの端末時刻がずれていることにより同じ時刻を示したタイムスタンプであっても実際の加速度データを取得したタイミングが異なる。実際に 4 章で使用した 7 つのデバイスを後述する NTP サーバーと通信したところ、正しい時刻と 10ms 程度から 2000ms 程度ずれていることが確認できた。2 つ目はデバイスやセンサごとの取得間隔の違いである。例えば、Android スマートフォンから取得する加速度データの取得間隔は最速で 20ms であるが GPS のセンサデータの取得間隔は 1s である。また、同じ加速度データの取得でも 4 章での行動データ取得実験のようにスマートフォンとスマートウォッチのサンプリングレートは異なる。これらの取得間隔の違いにより特徴量を抽出する際のデータ数に偏りが生じてしまう。このような問題点が認識率に影響を及ぼす可能性がある。

次に位置的なデータの品質について述べる。複数デバイスを使用した場合には 5.1 節で述べた以外の問題も考慮する必要がある。例えば 2 つのデバイスを使用していた時に、1 つのデバイスの装着位置が正しく、もう 1 つの装着位置がずれている場合である。このような場合は、1 つのデバイスに位置的な問題があり認識精度を低下させていても、複数デバイスを使用することで認識精度の改善が見込める可能性がある。

6. データ品質改善の処理

本章では 5 章で述べた単体デバイスにおける取得間隔のずれと、複数デバイスにおける取得間隔の違いとシステム時間のずれの改善処理について述べる。

6.1. 線形補間

本節では単体デバイスにおける取得間隔のずれと複数デバイスにおける加速度データの取得間隔の違いの改善処理について述べる。設定通りの間隔でデータを取得できない点やサンプリングレートの違いにより、時間的なずれが発生する。これらの時間的なずれを無くすために行動データに対して線形多項式を用いた手法である線形補間という処理を行う。線形補間とは、与えられた2点のデータに対して、2点の間にある値を1次関数で近似して算出する方法である。2点のデータ (x_0, y_0) , (x_1, y_1) が与えられたとき、 x_0 と x_1 の間に存在する任意の時間 x における加速度データ y の値を式(1)によって算出する。

$$y = y_0 + (y_1 - y_0) \frac{x - x_0}{x_1 - x_0} \quad (1)$$

加速度データを算出する際は算出したい時刻に対して直前と直後の加速度データを用いて処理を行う。算出した時刻に加速度データが存在した場合は上記の処理を行わず、その時刻の加速度データをそのまま利用する。

6.2. NTP サーバーとの通信

本節では、複数デバイスにおけるシステム時間のずれの改善処理について述べる。5.2節で述べたようにデバイスごとのシステム時間は正確になっていないため、同じタイミングで取得した2つの加速度データでもタイムスタンプにずれが生じてしまう。このずれを解消するために複数デバイス間で時間の同期を行う。時間の同期にはNTP(Network Time Protocol)サーバーを用いる。本研究では、個人利用が可能である独立行政法人情報通信研究機構(NICT)[6]のNTPサーバーを利用する。4章の行動データ取得実験で各行動を行う前に各デバイスのAndroidアプリケーション内でNTPサーバーと通信し、複数のデバイスで時間の同期を行う。

7. 特徴量の抽出

本章では機械学習による行動認識実験で使用する特徴量の抽出について述べる。特徴量を抽出するまでに2つの処理を行う。

初めに4章で取得した行動データの前後部分のカット処理を行う。行動データ取得実験の仕様上、行動開始前と行動終了直後に各行動ではないデータを取得している。よって、不要な部分を削除するために各行動データの前後部分のカット処理を行う。

行動データの前後のカット処理を終えた後に、特徴量の算出を行う。本研究では各装着箇所デバイスにおける加速度データのX, Y, Z軸の平均値と分散値を特徴量とする。加速度データの平均値と分散値は基本的特徴量の1つであり、平均値は各軸方向の動作の速さを分散値は各軸方向の動作の大きさを示す指標である。1つのデバイスあたり3軸の平均と分散で6個の特徴量を抽出する。よって単体デバイスで行動認識実験を行う時には6個の特徴量となり、2つのデバイスで行動認識実験を行う時には12個の特徴量となる。また各特徴量のウィンドウサイズは1s、オーバーラップは0.5sとした。ウィンドウサイズは特徴量を抽出する単位時間であり、オーバー

ラップは一定区間データが重なることを許容する時間である。抽出した特徴量は機械学習の学習用とテスト用に分ける。特徴量の割合は学習用が8割、テスト用が2割とする。

8. 使用する機械学習

本章では行動認識実験で使用する機械学習について述べる。行動認識実験はデータ数が多く、自分で閾値を決めて各行動に分類することは難しい。そこで、行動認識実験に機械学習を用いる。本研究では3つの機械学習を使用し認識精度を算出する。1つ目は関連研究において認識性能が優れているとされるSVMである。SVM[7]はクラスを分類する際にマージンを最大化するようにして境界面を計算する。学習データの中で最も他クラスに近い位置にあるデータを基準にしてユークリッド距離が最も大きくなるように境界面を計算しクラス分けを行う。2つ目はK-NNである。K-NN[8]は学習データをベクトル空間上にプロットしておき、テストデータが入力されたらそのデータから距離が近い順に任意の k 個の学習データを取得して多数決でテストデータが属するクラスを推定するアルゴリズムである。3つ目は決定木である。決定木[9]は目的変数と説明変数の関係を木構造として表現することで分類を行うアルゴリズムである。本研究では3つの機械学習をScikit-learnというPythonのライブラリを用いて実装する。

9. 特徴量の選択

本章では10章の機械学習による行動認識実験の際に行う特徴量の選択について述べる。7章で抽出した全ての特徴量が機械学習の分類に有効であるとは限らない。そこで、本研究ではRFE(Recursive Feature Elimination)を利用して特徴量の選択を行う。RFE[10]とは全ての特徴量を含んだモデルから指定した数になるまで再帰的にモデルを再構築しながら重要度の最も低い特徴量を削除する手法である。RFEを利用するためには特徴量の重要度を算出できる識別器を利用する必要がある。特徴量の重要度の算出にはランダムフォレストを使用する。本研究では特徴量の選択する数を単体のデバイスの場合だと1~6個、複数のデバイスの場合だと1~12個とする。各個数においてRFEを用いて特徴量の選択を行う。選択された各個数の特徴量で11章の機械学習による行動認識を行い、1番認識率が高かったものを認識精度とする。

10. 機械学習による行動認識実験

本章では、機械学習による行動認識実験について述べる。データ品質が行動認識精度にどのような影響を与えているか精査するために行動認識実験を行う。3つの機械学習により算出した値からデータ品質が行動認識の精度にどの程度影響を与えるか考察する。

10.1. 更新頻度のずれによる認識精度の比較

本節では単体デバイスにおけるセンサデータの更新頻度のずれが認識精度に及ぼす影響について述べる。更新

頻度のずれを無くすために 6.1 節で述べた線形補間の処理を行っている。よって更新頻度のずれにおける認識精度の比較実験では更新頻度のずれを無くした線形補間後のデータでモデルを作成し、線形補間前と後のデータをテストデータとして入力して認識精度の比較を行う。また、使用デバイスは腰のスマートフォンとした。

表 4 にセンサデータの更新頻度のずれによる認識精度の比較結果を示す。線形補間前と後で使用された特徴量に変化はなかった。表 4 を見ると 3 つの識別器すべてにおいて 1%以下の誤差しか現れなかった。線形補間によりデータが変化していることを加味して考えてもほぼ影響はないと言える。これは更新頻度による数ミリ秒のずれではデータ数の偏りがほとんど無かったためだと考えられる。

表 4 更新頻度のずれによる認識精度の比較結果

線形補間	認識精度(%)		
	SVM	K-NN	決定木
前	88.9	90.2	87.9
後	89.6	91.2	88.0

10.2. 更新頻度の違いによる認識精度の比較

本節では複数デバイスにおけるセンサデータの更新頻度の違いが認識精度に及ぼす影響について述べる。本研究では右手首に装着したスマートウォッチと腰に装着したスマートフォンを用いて実験を行う。更新頻度の違いを解消するために 6.1 節に述べた線形補間を行っている。よって更新頻度の違いを無くした線形補間後のデータでモデルを作成し、線形補間前と後のデータをテストデータとして入力して認識精度の比較を行う。

表 5 にセンサデータの更新頻度の違いによる認識精度の比較結果を示す。線形補間前と後で使用された特徴量に変化が見られなかった。表 5 を見ると 3 つの識別器すべてにおいて 1%以下の誤差しか現れなかった。線形補間によりデータが変化していることを加味して考えてもほぼ影響はないと言える。これは更新頻度の違いによってデータの個数が変化しても、単位時間で区切って算出される平均や分散といった基本的特徴量では、データ数がある程度確保されていれば算出される値に大きな変化がなかったためだと考えられる。

表 5 更新頻度の違いによる認識精度の比較結果

線形補間	認識精度(%)		
	SVM	K-NN	決定木
前	92.4	93.8	89.4
後	93.3	94.2	89.4

10.3. システム時間のずれによる認識精度の比較

本節では複数デバイスにおけるシステム時間のずれが認識精度に及ぼす影響について述べる。4 章の行動データ取得実験では各行動データの取得時に各デバイスで NTP サーバーと通信を行い、システム時間の補正を行っ

ている。よって、比較実験では修正したタイムスタンプの行動データと修正したタイムスタンプを意図的にずらした行動データで認識精度の比較を行う。比較実験では NTP サーバーと通信を行ったデータでモデルを作成し、NTP サーバーと通信を行ったデータと意図的にシステム時間をずらしたデータをテストデータとして入力して認識精度の比較を行う。また、使用デバイスは腰のスマートフォンと手首のスマートウォッチとした。

表 6 にシステム時間のずれによる認識精度の比較結果を示す。使用された特徴量に SVM と K-NN で変化が見られた。しかし、通信ありで使用された特徴量で通信なしの結果を見るとそれぞれ 90.1%、91.8%となっていたため、特徴量の選択では認識率に大きな違いは見られなかった。

表 6 を見ると全ての識別器において約 2%の違いが見られた。単体デバイスにおける更新頻度のずれや複数デバイスにおける更新頻度の違いと比べると認識精度に影響が出ている。システム時間のずれはタイムスタンプを補正しているだけなので線形補間を行った後のように加速度データに対する補正は行っていない。以上のことを加味して考えても認識精度に影響が出ていると言える。今回抽出した特徴量のウィンドウサイズが 1 秒だったため、10~2000ms のずれでも特徴量に変化し、認識精度に影響が出たと考える。

表 6 システム時間のずれによる認識精度の比較結果

NTP サーバー	認識精度(%)		
	SVM	K-NN	決定木
通信なし	90.5	92.0	88.4
通信あり	92.8	93.8	90.2

10.4. 単体デバイスにおける装着位置のずれによる認識精度の比較

本節では単体デバイスにおける位置的なデータ品質が認識精度に及ぼす影響について述べる。デバイスの装着位置がずれてしまった時の認識精度の比較を行うために右手首のデバイスでモデルを作成し、右手首、右前腕、右上腕のデータをテストデータとして入力して認識精度の比較を行う。

表 7 に単体デバイスにおける位置ずれによる認識精度の比較結果を示す。表 7 を見るとどの識別器においても部位が離れるほど認識精度が低下していることが分かる。また認識精度は 20%以上低下しているため、部位レベルで装着位置をずらすことは認識精度に大きな影響をもたらすことが分かった。また全ての識別器において、右手首で使用された特徴量と右前腕と右上腕で使用された特徴量は異なっている。右手首で使用された特徴量と同じ 6 種類で右前腕の認識結果を比較すると、SVM で 20.0%、K-NN で 47.3%、決定木で 53.4%と低下していた。特に SVM においては全てのテストデータが「ジョギング」に分類されていた。今回の実験では部位レベルで装着位置をずらしているため、テストデータである特徴量データの入力ベクトルが大きく変化してしまい全ての行動のテストデータが「ジョギング」の識別面の中に入ってしまった。

ったためだと考えられる。位置ずれにおいて特徴量の選択を行わずに行動を認識するとさらに認識精度が下がってしまうことが分かった。

表7 単体デバイスの位置ずれによる比較結果

装着位置	認識精度(%)		
	SVM	K-NN	決定木
右手首	84.8	87.1	83.0
右前腕	62.4	61.7	63.4
右上腕	59.1	58.5	62.1

10.5. 複数デバイスにおける装着位置のずれによる認識精度の比較

本節では複数デバイスにおける位置的なデータ品質が認識精度に及ぼす影響について述べる。複数デバイスにおける位置がずれた時の認識精度の比較を行うために右手首と左足首のデバイスでモデルを作成する。その後、右手首と左足首、片方のデバイスだけずらした右前腕と左足首、両方のデバイスをずらした右前腕と左下腿のデータをテストデータとして入力し、認識精度を比較する。

表8に複数デバイスにおける位置ずれによる認識精度の比較結果を示す。表8を見ると両方のデバイスを部位レベルでずらすと認識精度が大きく低下しているが、片方のデバイスのみがずれた場合は認識精度の低下が小さくなっていることが分かる。デバイスの装着位置が部位レベルでずれていても複数デバイスを利用することで、認識精度の低下を緩和できることが示された。また、2つのデバイスを両方もずらした右前腕と左下腿の結果を見るとK-NNと決定木は60%程度の結果を保っているが、SVMは20%と著しく低い。これは10.4節で述べた理由と同じと考える。SVMはモデルに近いデータを用いることで高い結果を得ることができる。しかしモデルから大きく変化したデータで行動認識を行うときにはSVMよりもK-NNや決定木を用いた方が良いということが分かった。また使用された特徴量は異なった。10.4節と同様に装着位置のずれにおいて特徴量の選択は認識精度の向上につながっていることが分かった。

表8 2つのデバイスの位置ずれによる比較結果

装着位置	認識精度(%)		
	SVM	K-NN	決定木
右手首+左足首	84.5	90.6	90.2
右前腕+左足首	82.7	81.5	80.2
右前腕+左下腿	20.0	59.9	61.3

11. まとめと今後の課題

本研究では時間的なデータと位置的なデータの品質に着目し、行動認識精度に及ぼす影響を精査した。結果から時間的なデータ品質ではシステム時間のずれが認識精度に影響があることが分かった。また位置的なデータ品質では部位レベルで装着位置をずらすことは認識精度に

大きな影響をもたらすが、複数デバイスを利用することで認識精度の低下を緩和できることが分かった。さらに特徴量の選択を行うことが認識精度の向上につながっていることが示された。今回使用した3つの手法の内、SVMはモデルから大きく変化したデータでテストするときには適さないことも分かった。

今後の課題として以下の3つが挙げられる。1つ目は位置的なデータ品質の追加検証である。今回は部位レベルでのずれでしか検証を行わなかった。しかし日常生活でデバイスを使用すると考えたとき、部位レベルよりも細かいずれが発生するときの方が多い。より細かいずれで検証する必要がある。2つ目は被験者数の増加である。今回は10名でデータ取得実験を行ったが十分な数であるとは言えない。汎用性を出すためにも被験者数の増加が必要である。3つ目はデバイスやセンサの種類増加である。本研究ではスマートフォンとスマートウォッチの加速度データのみを用いて行動認識の比較実験を行った。しかし、行動認識ではジャイロデータなどを使用している研究も存在する。デバイスやセンサの種類を増加することで新たに発生するデータの問題もあると考える。

文献

- [1] S. M. Lee, S. M. Yoon, H. Cho, "Human Activity Recognition from Accelerometer Data Using Convolutional Neural Network", The IEEE International Conference on Big Data and Smart Computing (BigComp), pp.131-134, 2017.
- [2] I. Cleland, B. Kikhia, C. Nugent, A. Boytsov, J. Hallberg, K. Synnes, S. McClean, D. Finlay, "Optimal Placement of Accelerometers for the Detection of Everyday Activities", Sensors, vol.13, pp.9183-9200, 2013.
- [3] 寺田努, "ウェアラブルセンサを用いた行動認識技術の現状と課題", コンピュータソフトウェア, vol.28, No.2, pp.43-54, 2011.
- [4] A. Henpraserttae, S. Thiemjarus, S. Marukatat, "Accurate Activity Recognition using a Mobile Phone Regardless of Device Orientation and Location", The IEEE International Conference on Body Sensor Networks (BSN), pp.41-46, 2011.
- [5] 米澤直樹, "ウェアラブルデバイスの装着位置のズレによるデータの変化に関する研究", 法政大学卒業論文, 2018.
- [6] NICT公開NTPサービス, <http://jty.nict.go.jp/tsp/PubNtp/index.html> (2019年1月19日参照)
- [7] サポートベクターマシン (SVM), <http://www.sist.ac.jp/~kanakubo/research/neuro/supportvectormachine.html> (2019年1月19日参照)
- [8] 機械学習_k近傍法_理論編 | DevelopersIO, https://dev.classmethod.jp/machine-learning/2017ad_20171218_knn/ (2019年1月19日参照)
- [9] 決定木分析_理論編 | DevelopersIO, https://dev.classmethod.jp/machine-learning/2017ad_20171211_dt-2/ (2019年1月19日参照)
- [10] sklearn.feature_selection.RFE — scikit-learn 0.20.2 documentation, https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.RFE.html (2019年1月19日参照)