

## 複数のウェアラブルデバイスから得られる慣性データとコンテキストデータを用いた行動認識

Nakano, Kensuke / 中野, 賢亮

---

(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)

15

(開始ページ / Start Page)

1

(終了ページ / End Page)

6

(発行年 / Year)

2020-03-24

(URL)

<https://doi.org/10.15002/00022728>

# 複数のウェアラブルデバイスから得られる慣性データと コンテキストデータを用いた行動認識

## Human Activity Recognition Utilizing Inertial and Contextual Data from Multiple Wearable Devices

中野 賢亮

Kensuke Nakano

法政大学大学院情報科学研究科情報科学専攻

E-mail: kensuke.nakano.7j@stu.hosei.ac.jp

### Abstract

*This research has been aimed at human activity recognition (HAR) using both inertial data and context data from multiple wearables. Ten participants are recruited to conduct twelve daily activities such as walking, stepping stairs, typing, and writing, during which each participant wears multiple devices that are placed different parts in its body. The inertial data is captured from accelerometers and gyroscopes in the seven devices. The context data is special information that represents the state and environment situation to the user who conducts the twelve activities. The context data used in this study includes the WiFi access points' IDs the wearable devices connected to, the atmospheric pressure levels when moving, the total changes in inertial data, and the devices' positions in a body. The key in this research is how to organize the context information in some knowledge rules, which are then applied to divide activities into groups and detect a concrete activity together with machine learning algorithms such as SVM and k-NN. Both the probability distribution and the knowledge-based threshold are adopted in using the context. As a result, the recognition accuracy is 33% higher than that when only using inertial data, and 17% higher than that when using context data as feature together with inertial data features.*

### 1. まえがき

近年、センサの小型化が進み、デバイスにセンサを組み込んだウェアラブルデバイスが高性能になってきている。高性能化に伴い、普及率も上昇している。現在ウェアラブルデバイスのようなセンサが組み込まれたデバイスを使用したアプリケーションも多く作成されており、研究も活発に行われている。その1つに行動認識という分野がある。行動認識の研究で挙げられる問題の1つに認識する行動が多くなる程、認識精度が低下する問題がある。理由として人が日常生活で行う行動は多岐に渡り、「歩く」や「階段昇降」といった類似した行動も多くあるため認識精度の低下に繋がると考えられる。認識精度を向上させる取り組みに過去の研究では複数のウェアラ

ブルデバイスを用いて行動認識を行うことでもあった。しかし、上記のような類似した行動の認識には依然として向上の余地がある。そこで慣性データのみでなくユーザの位置や生体データ、高度、速度や運動量といった状況や状態、環境を表すコンテキストデータを使用することでも認識精度の向上に繋がると示されている。しかし、コンテキストデータをどのように使用することで認識精度に影響を及ぼすか検証している研究は少ない。

本研究では慣性データのみで認識を行うのではなく、コンテキストデータを複数の使用方法で認識を行いその認識精度がどのように変化するか検証しその結果から考察を行う。身体の7か所にウェアラブルデバイスを装着し、日常生活で頻繁に行われている歩行や階段昇降、スロープの昇降、筆記、タイピングといった12種類の行動を被験者10人に行ってもらい行動時のデータを取得する。その後機械学習を使用して慣性データのみで認識を行った結果とコンテキストデータを使用して認識を行った結果を比較し考察を行う。

本論分の構成は以下の通りである。第2章では行動認識の関連研究を紹介する。第3章ではデータ取得実験について述べる。第4章では行動認識の一般的手法と本研究の手法。第5章では特徴量として全て機械学習で使った場合について。第6章ではコンテキストデータを機械学習の前に使用した行動認識実験について述べる。第7章ではコンテキストデータを機械学習の後で使用した行動認識実験について述べる。第8章ではコンテキストデータを機械学習の前後で使用した行動認識実験について述べる。第9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

本章ではコンテキストデータを使用した行動認識の関連研究について述べる。L. Fiorini ら[1]の研究や A. Reiss らの研究[2]らの研究、A. Baura らの研究[3]では主に特徴量としてコンテキストデータを使用した。慣性データと同じようにウィンドウサイズごとに平均や分散、位置を算出し慣性データと一緒に機械学習へ入力し行動認識を行う。認識結果としては、それぞれ加速度データやジャイロデータのみで行動認識を行うよりも高い認識精度となった。また、D. Riboni らの研究[4]や G. Civitarese らの

研究[5]では気圧や場所、気象情報、道路の状況などをコンテキストデータとして使用している。コンテキストデータの使用方法は機械学習から出力される各アクティビティの確率分布に対しコンテキストデータを用いた推論から適さない行動に関してアクティビティの確率を無くすといった方法を用いている。実験の結果どの研究もコンテキストデータを使用しない認識より 20%以上認識精度が上がっている。

上記で紹介した研究は認識精度の向上を目的としてコンテキストデータを使用した研究である。主にコンテキストデータを特徴量として扱う研究が多いが他にも機械学習から出力される行動の確率とコンテキストデータを比較行う研究も行われている。しかし、機械学習の後に比較を行う場合には機械学習で出力する行動の正答率がコンテキストデータを使用する時に影響を与えるのではないかと考える。そこで本研究ではコンテキストデータを機械学習の前後に使用することで機械学習での認識精度を向上と出力された行動と整合性の確認を行うことで最終的な認識精度の向上を図る。

### 3. データ取得実験

本章では行動認識実験で使用するデバイスや行動について述べる。10名の被験者に協力してもらい認識する行動は大学内での生活習慣改善のためのライフログを想定した12種類の行動データを取得した。デバイスの種類と装着位置を図1に、行動の種類とラベルを表1に示す。使用デバイスはスマートフォンのNexus 5、スマートウォッチはLG Watch Urbane2、マルチジェスチャーコントロールアームバンドのMyoを使用する。スマートフォンは左上腕、腰部、左足首、Myoは両前腕、スマートウォッチは両手首に装着した。データ取得実験は各行動データが1人あたり3分以上になるよう行った。行動は歩行系のG1と座位姿勢系のG2にグループを分ける。



図1 デバイスの種類と装着位置

取得したデータの種類のスマートフォンからは3軸の加速度、ジャイロデータ、気圧データ、WiFiのアクセスポイントのデータを取得した。スマートウォッチからは3軸加速度データ、3軸ジャイロデータ、心拍データを取得した。心拍データはデータの波形等を目視で確認したが行動ごとのパターンが見られなかったため使用しなかった。Myoからは3軸の加速度、ジャイロデータを取得した。データ取得の際にはNTPサーバを使用し、デバイス間のシステム時間のずれを無くす。データカットや線形補間を終えた後に特徴量を抽出する。特徴量は、機

械学習を行うデータの特徴量を定量的に表現した数値のことである。同種類のセンサデータであっても各デバイスの装着位置によって独立した特徴量として抽出する。3軸の加速度・ジャイロデータは各軸の平均と分散とする。特徴量を抽出する単位時間をウィンドウサイズといい、本研究では0.5s, 1s, 2sを使用する。特徴量を抽出する際に一定期間のデータが重なることを許容する時間をオーバーラップといい、本研究では各ウィンドウサイズの50%をオーバーラップとした。特徴量抽出と別にコンテキストデータを算出する。

コンテキストデータとは、ユーザの状態や状況、環境などを表すデータである。例えば、心拍数や位置、速さ、運動量などが挙げられる。本研究で使用するコンテキストデータはWiFiのアクセスポイント、気圧、各装着箇所の加速度とジャイロから算出した。また、デバイスの装着箇所も含めた。WiFiのアクセスポイントはウィンドウサイズごとに最も接続されていた接続先(SSID)とその接続強度を求めた。使用したSSIDの種類はネットワークの管理者が任意で指定できる無線ネットワークの識別名であるExtended Service Set Identifier(ESSID)を使用した。接続先の種類は研究室、学内、接続先無し(外)の3種類である。SSIDは接続先の種類によって数値化を行った。気圧データに関してはウィンドウサイズごとの平均、分散、増加量と行動内での増加量を求めた。3軸の加速度データと3軸のジャイロデータは各行動内でのウィンドウサイズごとに算出した大きさを総変化量とした。特徴量とコンテキストデータを表2に示す。

表1 行動とラベル

グループ	行動	ラベル	
G1 (歩行系)	歩行	Wa	0
	スロープを降りる	Dsl	1
	階段を降りる	Dst	2
	スロープを昇る	Usl	3
	階段を昇る	Ust	4
G2 (座位姿勢系)	飲む	Dr	5
	食べる	Ea	6
	マウス操作	Mo	7
	座る	Si	8
	スマートフォン操作	Sm	9
	タイピング	Ty	10
	筆記	Wr	11

表2 慣性データの特徴量とコンテキストデータ

慣性データ	加速度	平均(X,Y,Z) 分散(X,Y,Z)
	ジャイロ	平均(X,Y,Z) 分散(X,Y,Z)
コンテキストデータ	加速度	総変化量
	ジャイロ	総変化量
	気圧	増加量(Windowsize 毎, 行動毎)
	WiFi	SSID, RSSI
	デバイス	装着位置

#### 4. 行動認識の一般的手法と本研究の手法

本章では行動認識の一般的手法と本研究での手法について説明する。行動認識の一般的手法と本研究の手法をまとめた図を図2に示す。本研究では3種類の行動認識実験を行う。1つ目と2つ目は慣性データとコンテキストデータを特徴量として使用する場合である。1つ目は慣性データのみ使用し、2つ目ではコンテキストデータも慣性データと一緒に機械学習で使用し行動認識実験を行う。3つ目はコンテキストデータを機械学習の前後で用いる方法である。コンテキストデータをそのまま特徴量として扱うと類似した行動の特徴が掴みにくいと考えられる。そこで本研究では機械学習で直接使用せずにその前後でコンテキストデータの値からナレッジベースのルールを用いてより認識精度が向上するよう機械学習の前にはグループ分けを行い、機械学習から出力された各行動に割り振られる確率の操作を行う。

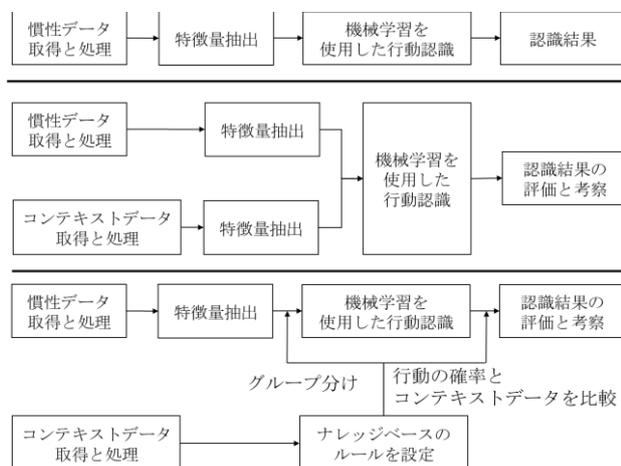


図2 行動認識の一般的手法(上, 中)と本研究の手法(下)

#### 5. 特徴量としてすべて機械学習で使った場合

本章では第6, 7, 8章で行うコンテキストデータを使用した行動認識実験での認識精度と比較を行う基準を設けるための事前実験に関して述べる。本研究では4種類の機械学習を使用する。Support Vector Machine(以下SVM), k近傍法(以下k-NN), 決定木(以下DT), ランダムフォレスト(以下RF)の4種類である。機械学習はライブラリとしてScikit-learnを使用する。機械学習の評価にはデータの偏りやばらつきなどの偶然による影響を受けにくく汎化性能が高い点でk=5のクロスバリデーションを行った。上記の手法でまず慣性データのみで機械学習による行動認識実験を行い基準を設ける。

##### 5.1. 慣性データのみで行った実験結果

本節では慣性データのみで機械学習を用いた行動認識実験の結果を述べる。使用した機械学習アルゴリズムはSVM, k-NN, DT, RFの4種類でウィンドウサイズは0.5s, 1s, 2sの3種類である。表3に機械学習アルゴリズム, ウィンドウサイズ, 標準化の有無の組み合わせ24通りの結果を示す。表3よりウィンドウサイズ2sで標準化

を行ったSVMとk-NNの認識精度が60%を超え高かったため以降ウィンドウサイズは2s, 標準化ありのSVMとk-NNを基準として同じ条件で行動認識実験を行う。

SVM, k-NNともにラベル0から4, 5から11の間で誤認識が多く, 逆にラベルの前半, 後半での誤認識が少ないことが分かった。これは, 行動時に歩行を含む行動か着座姿勢の行動かで大きく分けられることが認識の結果に表れたと考えられる。以降ラベル0から4の歩行系の行動群をG1, ラベル5から11までの座位姿勢の行動群をG2とする。表4に各機械学習でのG1とG2, 全体の認識率を示す。

表3 慣性データのみでの認識結果(標準化有|標準化無)

	SVM	k-NN	DT	RF
0.5s	51.2 23.6	56.8 32.7	43.1 33.0	44.2 30.8
1.0s	54.7 30.3	58.5 33.9	43.0 33.0	45.3 27.7
2.0s	62.5 32.8	62.4 33.3	46.5 35.3	51.6 28.8

表4 グループごとの認識結果

ML	G1	G2	全体
SVM	70.8	56.5	62.5
k-NN	66.2	59.8	62.4
DT	52.6	42.5	46.6
RF	60.2	45.7	51.6

##### 5.2. コンテキストデータの特徴量として扱う場合

本節ではコンテキストデータの特徴量と同じように機械学習で使った場合の結果について述べる。コンテキストデータの特徴量として扱った際のSVM, k-NNの結果を表5に示す。SVMは全体の認識精度は78.1%でG1の平均が98.1, G2の平均が63.7%となったG2は7%の上昇に対しG1は27%以上の上昇と大きく認識精度が向上している。k-NNも全体の認識精度は72.6%でG1の平均が94.4, G2の平均が57.0%となったG2は約3%の下降に対しG1は27%以上の上昇と大きく認識精度が向上している。G1の認識精度向上は気圧のコンテキストデータを用いた結果からであると考えられる。気圧の変化量はG2と歩行ではほとんど見られなく, 階段・スロープの昇りはマイナスとなり, 階段・スロープを降りるは増加量がプラスとなるため認識する際に大きく寄与したと考えられる。表5にコンテキストデータの特徴量として扱った場合の認識結果を示す。

表5 コンテキストデータの特徴量と扱った認識結果

ML	G1	G2	全体
SVM	98.1	63.7	78.1
k-NN	94.4	57.0	72.6
DT	91.8	58.6	72.4
RF	93.1	60.6	74.2

#### 6. コンテキストデータを先に使う場合

本章ではコンテキストデータを用いて機械学習を使用する前にG1とG2にグループ分けを行う方法で行った行動認識実験の結果について述べる。グループ分けを行う

際に使用したコンテキストデータはSSIDと左足首のジャイロの総変化量である。SSIDは接続先無し(外)または学内の場合にG1に振り分け、研究室に接続している場合にはG2に振り分けた。図3に振り分けで使用したコンテキストのルールを示す。SSIDの接続先によって被験者がどこにいるか分かり場所により行う行動が異なるため使用した。SSIDを使用してグループ分けを行った結果を表6に表す。表6よりG1の振り分け精度が低いことが分かる。これは研究室に接続した状態で歩行や階段昇降の実験をなつたため誤ってG2へ振り分けられたと考えられる。

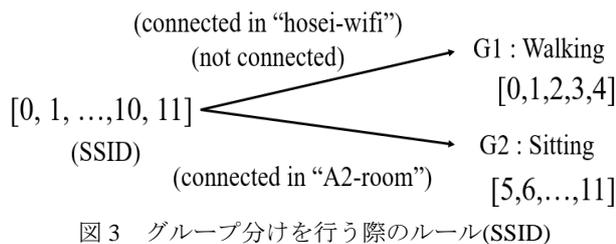


図3 グループ分けを行う際のルール(SSID)

次に左足首のジャイロの総変化量が10より大きい場合にG1へ振り分けそれ以外にG2に振り分けた。これは歩行系の行動群であるG1と座位姿勢系の行動群G2では足の動きが大きく異なると考えたため使用した。左足首のジャイロの大きさを使用してグループ分けを行う際のナレッジベースのルールを図4に結果を表6に表す。表6より全データを正しく振り分けすることができたことが分かる。座位姿勢の行動ではほとんど足を動かすことがないため高精度で振り分けることが出来たと考える。

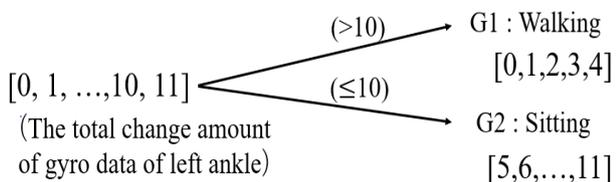


図4 グループ分けを行うルール(ジャイロの総変化量)

表6 コンテキストデータでグループ分けを行った結果

		G1	G2
SSID	G1	90.1	9.9
	G2	0.3	99.7
左足首	G1	100	0
	G2	0	100

表7に左足首でグループ分けを行った後の認識結果を示す。SVMでの認識結果はG1では平均72.4%, G2の平均は69.4, 全体は70.8, k-NNでの認識結果はG1では平均68.0%, G2の平均は68.5, 全体は68.3となった。G1の認識率はSVM, k-NNともに慣性データのみで認識を行った場合と比較して2%程度の向上になったがG2ではSVMでは12%以上k-NNでは8%以上と大きく向上したと言える。さらにコンテキストデータの特徴量として使用した場合よりもともに5%以上向上した。これは全体で認識を行うよりもG2の中で認識を行う方が単純に認識する

行動数が少なくなり似た行動であってもデータの特徴を掴みやすくなるため認識精度が向上したと考えられる。G1に関しては慣性データの特徴量だけでは認識する際に境界を引くのが難しかったためG1内で誤認識が多くなったと考えられる。

表7 先にグループ分けを行った場合の認識結果

	ML	G1	G2	全体
全位置	SVM	72.7	69.4	70.8
	k-NN	68.0	68.5	68.3
両腕・両手首	SVM	72.7	73.1	72.9
	k-NN	68.4	70.8	69.7

さらに先の認識ではG2の認識の際にデバイスの装着位置7箇所すべての特徴量を使用した。しかし座位姿勢での行動であるG2は左足首、腰のデータは両全腕と左上腕、両手首のデータほど重要では無いと考えられる。そこでG2の認識を左足首と腰から算出した特徴量以外の5か所の特徴量を位置ごとや組み合わせで行った。最も高い認識精度であったのは両手首と両前腕のデータを使用した場合であった。G2の認識を両手首と両前腕のデータを使用したSVM, k-NNでの実験結果を表7の下段(両腕・両手首)に示す。

G2の認識精度はSVMでは73.1%とk-NNでは70.8%と全位置のデータで認識を行った場合と比較して2, 3%の向上が見られた。結果からG2の認識の際に不要な腰と足首のデータを除いたことでG2の認識で重要な特徴を全てのデバイスのデータで認識した場合よりも得られたと考えられる。しかし食事、マウス操作が座る、スマートフォンなどに誤認識されている。これは座っている状態である点が誤認識を増やし、認識率が大きく上がらない原因と考えられる。

## 7. コンテキストデータを後に使う方法

本章ではコンテキストデータを機械学習後に使用方法での行動認識実験の結果について述べる。機械学習には各データがどの行動ラベルに振り分けられるかを表す確率を出力可能な種類がある。そこで本研究ではコンテキストデータでナレッジベースの閾値を設定し機械学習から出力された各行動の中でコンテキストデータとの整合性をとれる行動の確率を上げる補正をかけ、最も高い値の行動を最終出力とする。気圧データは第5.2節で述べたコンテキストデータの特徴量とした扱った結果からG1の認識精度を向上させるのに有効であると考えたため使用した。図5に設定した気圧データのコンテキストデータを使用したナレッジベースの閾値の図を示す。

まず、行動毎に気圧の増加量を算出し、0.83より大きい場合に「階段を降りる」、0.18より大きく0.83以下の場合に「スロープを降りる」、-0.24より大きく0.18以下の場合に「歩く」、-0.91より大きく-0.24以下の場合に「スロープを昇る」、-0.91以下の場合に「階段を昇る」の確率を上げた。気圧データを用いて機械学習後に行動とコンテキストデータとの比較を行い補正処理を行ったSVMとk-NNの認識結果を表8の上2段(気圧)に示す。

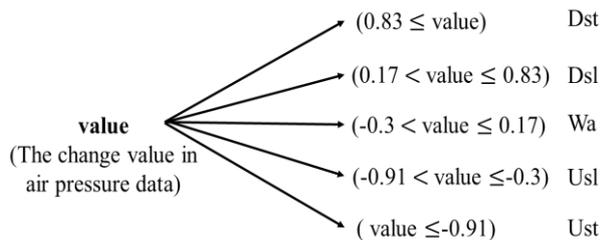


図5 気圧データを用いてナレッジベースで設けた閾値

SVM の G1 の平均は 100%, G2 の平均は 47.4% となり全体の平均は 69.4% であった。G2 の認識精度へ「歩行」に補正がかかり誤認識が多数あるが、G1 は補正の効果が如実に表れていることが分かる。k-NN も同様に G1 の認識精度が 92% と大きく向上した。スロープの高低差と階段の高低差との違いが大きく、歩行や G2 は同じ階での実験のため気圧の増減が少ないため、ナレッジベースの閾値を有効な値の設定が出来たと考える。しかし、コンテキストデータでの補正が G2 に対して有効に働いていないことから第 6 章で述べたグループ分けを行った後 G1 のみに気圧データのコンテキストデータによる補正を行うとより認識精度の向上が見込まれると考える。

次に両手首と上腕のジャイロデータをコンテキストデータとして扱う方法での行動認識実験の結果についての結果を述べる。気圧データを用いたナレッジベースのルールでは G1 に対して有効な閾値を発見したが G2 の認識精度の向上には繋がらなかったそのため G2 の認識精度の向上のために使用するデバイスの位置を考慮して、両手首と左上腕のジャイロデータをコンテキストデータとして使用する。行動時にどれほど各位置が回転していたかをウィンドウサイズごとに算出したものを合算した値で閾値を設定する。

例えばまず右手首の値が 18 以上である場合に「飲む」、「マウス操作」、「座る」が当てはまる。その中で左上腕の値が 15 以上である場合に「飲む」それ以外で再び右手首の値が 7.3 以上の場合に「マウス操作」が 7.3 未満の場合に「座る」と複数の条件を組み合わせ、コンテキストデータを使用したナレッジベースの閾値を作成する。

図 6 にジャイロデータを用いたナレッジベースの閾値の図を示し、SVM, k-NN の認識結果について表 8 の真ん中の 2 段(位置+ジャイロ)に示す。

SVM の G1 の平均は 65.0%, G2 の平均は 87.6% となり全体の平均は 78.2% であった。k-NN の G1 の平均は 65.2%, G2 の平均は 79.0% となり全体の平均は 73.3% であった。SVM, k-NN とともに G2 の認識精度は慣性データのみで認識を行った場合、特徴量として扱った場合よりも向上した。グループを分けず機械学習のモデルを作成した場合に類似した行動のクラスが近くに設定されるため細かい特徴までは考慮されずに認識を行い誤認識に繋がる。そこで両手首と上腕のジャイロデータから得たコンテキストデータを元にしたナレッジベースの閾値を設定することで細かい特徴を考慮することが出来たため認識精度の向上に繋がったと考える。しかし、「筆記」の取る値の範囲の多くが「飲む」と「スマートフォン操作」と重複

していた。そのため補正後であっても「筆記」が「飲む」と「スマートフォン操作」に多く誤認識している。この問題を解消するには他のコンテキストデータを使用する必要があると分かった。

次に G1 と G2 の両方に対して認識率が上がるようなナレッジベースの閾値を設定する。前述した気圧データは G1 に対して、左上腕、両手首のジャイロデータの総変化量は G2 に対して認識精度向上に有効であると分かった。しかし気圧データの増加量は G2 に悪い影響を与え、左上腕と両手首のジャイロデータの総変化量は G1 に悪い影響を与えたために認識精度がトレードオフの関係となった。そこで、G1 と G2 の認識精度を両方同時に向上させるために第 6 章でグループ分けを行う際に使用したコンテキストデータを用いたナレッジベースのルールを利用する。グループ分けのルールを追加することで、機械学習を使用した後に G1 と G2 のそれぞれに対してコンテキストデータを使用した補正処理を行う。SVM と k-NN の認識結果について表 8 の下 2 段(全て)に示す。

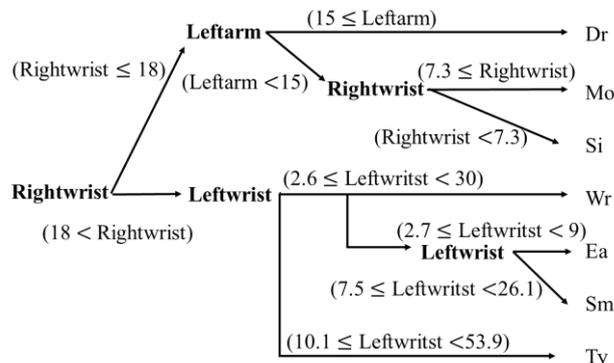


図6 ジャイロデータのナレッジベースで設けた閾値

SVM の G1 の平均は 100.0%, G2 の平均は 87.7% となり全体の平均は 92.8% であった。k-NN の G1 の平均は 92.6%, G2 の平均は 79.0% となり全体の平均は 84.7% であった。慣性データのみで認識を行った場合と比較して SVM の G1, G2 は 30% 近く認識精度が向上し、k-NN も G1 は 25% 以上、G2 も 20% 近く認識精度が向上した。コンテキストデータの特徴量として扱った場合と比較しても SVM と k-NN の全体の認識精度は 10% 以上の向上している。コンテキストデータによる補正をかける際にグループ分けのルールを使用し G1 と G2 を分けることで G1 と G2 にそれぞれ適した補正をかけることで互いの認識精度を低下させる影響を与えなかったためと考えられる。

表 8 コンテキストデータを後から使用した認識結果

コンテキスト	ML	G1	G2	全体
気圧	SVM	100.0	47.4	69.4
	k-NN	92.6	57.8	75.2
位置+ジャイロ	SVM	65.0	87.6	78.2
	k-NN	65.2	79.0	73.3
全て	SVM	100	87.7	92.8
	k-NN	92.6	79.0	84.7

## 8. コンテキストデータを前後に使う方法

本章ではコンテキストデータを機械学習を使用する前と後の両方で使用した行動認識実験の結果について述べる。第 7 章ではコンテキストデータを機械学習の後に使用することで全体の認識精度を上げた。しかし、機械学習の後にコンテキストを使用する場合に、機械学習自体の認識精度がコンテキストデータによる補正後の結果に影響を与える可能性がある。そこで本章では第 6 章で行った手法と同じく先に G1 と G2 のグループを分けた後に機械学習を使用する。G1 と G2 のそれぞれから出力された行動の振り分けられる確率に対して第 7 章で行ったコンテキストデータを用いたナレッジベースのルールと比較を行い整合性のある行動の確率に対して補正を行う。具体的にはまず、左足首のジャイロデータの総変化を用いて G1 と G2 を分け、G1 は全ての位置の慣性データを用いて認識を行い、G2 は両手首と両前腕の慣性データを用いて認識を行う。G1 の出力に対して気圧データの増加量を用いて補正を行い、G2 の出力に関しては両手首と上腕のジャイロデータの総変化量を用いて補正を行う。図 7 にはコンテキストデータを機械学習の前後で使用する際の流れの図を、表 9 に SVM と k-NN での機械学習の前後にコンテキストデータを使用した認識結果を示す。

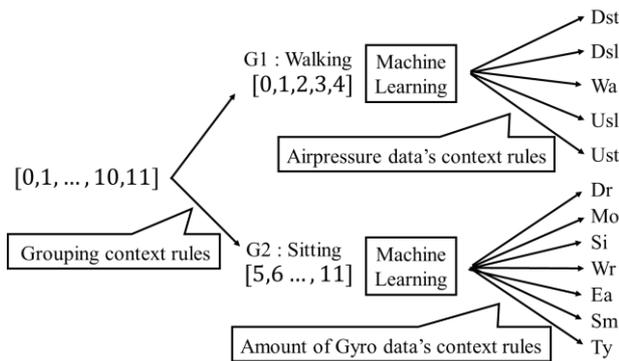


図 7 コンテキストデータを前後で使用する流れ

表 9 機械学習前後にコンテキストを使用した認識結果

ML	G1	G2	全体
SVM	100.0	92.8	95.8
k-NN	96.0	84.5	89.3

SVM の G1 の平均は 100.0%、G2 の平均は 92.8% となり全体の平均は 95.8% であった。k-NN の G1 の平均は 96.0%、G2 の平均は 84.5% となり全体の平均は 89.3% であった。SVM、k-NN とともに慣性データのみでの認識実験やコンテキストデータの特徴量として扱い認識実験を行った結果と比較して最高精度であった。

特に第 7 章で行った機械学習後に G1 と G2 のそれぞれに対して補正を行った結果と比較するとナレッジベースでの閾値は同じで行い G2 の認識精度が 5% 以上向上している。このことから機械学習の認識精度が機械学習後に行うコンテキストデータを用いた補正処理後の認識結果に影響があると考えられる。

## 9. まとめと今後の課題

本研究では慣性データである 3 軸加速度と 3 軸ジャイロの一般的な特徴量の平均と分散、ユーザの状況や状態、環境を表すコンテキストデータを WiFi のアクセスポイント、気圧データの増加量、行動毎のジャイロデータの総変化量も算出した。算出した慣性データの特徴量のみで機械学習による行動認識を行う場合とコンテキストデータの特徴量として扱い行動認識を行う場合、コンテキストデータを機械学習の前後で使用した場合で認識精度を比較し機械学習の前後で使用した場合が最も高い認識結果となった。結果から機械学習でのモデル作成前にグループ分けを行うことで各グループの認識精度が向上し、そこへ補正をかけることでより誤認識を減らすことができると分かった。また、補正をかける際にコンテキストデータからナレッジベースの閾値を設定することで機械学習では捉えきれないデータの特徴を捉えることができると考えられる。

今後の課題として以下の 3 点が挙げられる。1 つ目はコンテキストデータの追加である。本研究では気圧データの増加量やデバイスの位置などを使用した。しかし、「食事」や「スマートフォン操作」などナレッジベースの閾値を設定する際に値がとる範囲が重複する行動もあったため誤認識を減らすことが出来なかった。そこで「スマートフォンを使用していたか否か」等の情報も使うことでより誤認識を減らすことができると考えられる。2 つ目は被験者の追加である。今回は被験者を 10 人としたがそれでは汎用性のあるとは言えない。汎用性の向上のためにもより多くの被験者で実験を行う必要がある。3 つ目に特徴量の選択である。本研究では機械学習の実行時間短縮のために次元削減を PCA で行った。RFE などで特徴量の選択をすることで有効な特徴量がわかり、機械学習の認識精度も上がると考えられる。

## 文献

- [1] L. Fiorini, M. Boneccorsi, S. Betti, D. Esposito, F. Cacallo, "Combining Wearable Physiological and Inertial Sensors with Indoor User Localization Network to Enhance Activity Recognition", *Journal of Ambient Intelligence and Smart Environments*, Vol.10, No.4, pp. 345-357, August 2018.
- [2] A. Reiss, M. Weber, D. Stricker, "Exploring and Extending the Boundaries of Physical Activity Recognition", *The IEEE International Conference on System*, pp.46-50, 2011.
- [3] A. Barua, A. K. M. Masum, M. E. Hossain, E. H. Bahadur, M. S. Alam, "A study on Human Activity Recognition Using Gyroscope, Accelerometer, Temperature and Humidity data", *The IEEE International Conference on Electrical*, April 2019.
- [4] D. Riboni, C. Bettini, "COSAR: Hybrid Reasoning for Context-aware Activity Recognition", *Personal and Ubiquitous Computing*, pp.271-289, August 2010.
- [5] G. Civitarese, R. Presotto, C. Bettini, "Context-driven Activity and Incremental Activity Recognition", *Computer Vision and Pattern Recognition*, Cornell University, June 2019. (提出のみ)