

ウェアラブルセンサ装着位置/向きの違いにロバストな行動認識システムの実現に向けたデータ変換手法の検討

中村 優吾^{1,2,a)} 荒川 豊^{4,3} 安本 慶一¹

概要: 近年, IoT/ウェアラブルセンシング技術および人工知能技術の発展に伴い, 人々の身体に装着されたウェアラブルセンサを用いて, 対象者がどのような日常生活行動しているのかを高精度に推定することが可能となりつつある. しかしながら, 既存の行動認識モデルの多くは, ウェアラブルセンサ装着位置が学習フェーズで想定されている場所や向きと異なる場合には, 認識性能が劣化してしまうという問題を抱えている. 本論文では, この問題を解決するために, ウェアラブルデバイスから得られる加速度・ジャイロセンサデータの座標軸を回転し, 擬似的に異なるセンサ向きのセンサデータを生成するデータ変換手法に着目する. そして, 認識対象のセンサデータを適切に変換することで, 学習データのサンプルとセンサ装着位置/向きが違うセンサデータに対しても, 既存の機械学習手法に基づく行動認識モデルを活用しながら, 高精度に対象行動を認識する手法を提案する. また, 提案ワークフローの有効性を検証することを目的として, 複数の行動実施環境, 複数のセンサ装着位置, 複数のセンサ装着向きという条件に基づいて新たに構築された行動認識データセット (計 276.8 時間) を提示する. このデータセットを用いて, 提案手法の有効性を検証した結果, 適切なデータ変換手法を適用することで, センサ装着位置 (6 クラス) の認識精度 (F 値) 最大+31%改善し, 基本行動 (7 クラス) の認識精度 (F 値) を最大+28%改善出来ること確認した. また, 基本行動とながら行動を合わせた 17 クラス分類問題に関して, 認識精度 (F 値) を最大+25%を改善し, 3 つのセンサ装着位置を適切な組み合わせることで 83%の F 値で認識できることを示した.

Data Transformation for Improving the robustness of activity recognition against the difference of wearable sensors position and orientation

Yugo Nakamura^{1,2,a)} Yutaka Arakawa^{4,3} Keiichi Yasumoto¹

1. はじめに

近年, IoT/ウェアラブルセンシング技術および人工知能技術の発展に伴い, 人々の身体に装着されたウェアラブルセンサから得られる加速度・ジャイロセンサデータを用いて, 対象者がどのような日常生活行動しているのかを高精度に推定することが可能となりつつある. しかしながら, 既存の行動認識モデルの多くは, 認識性能が学習フェーズで使用されるデータセットに最適化されている一方, 日常生活のように制約条件のない状況で行動を認識する場合には, ウェアラブルセンサ装着位置や向きの違いに順応できず認識性能が劣化してしまうという問題を抱えている.

この問題の解決に向けて, Timo ら [1], [2] は, ウェアラブルセンサから得られるセンサデータを元に, 装着されている身体上の位置を常に推定しながら, 推定した位置に特化した推論モデルを適応的に選択することで認識精度を改善する手法を提案している. しかしながら, 身体上の位置が特定できる場合でも, センサを装着している角度や向きが学習データセットと異なる場合には認識精度が劣化するという問題を克服できていない.

本研究では, ウェアラブルデバイスから得られる加速度・ジャイロセンサデータに対して回転やノイズ付加といった一連の変換処理を加えることでデータ量を水増しするデータ変換/拡張手法 [3] に着目し, 認識対象のセンサデータに対して, 適応的にデータ変換処理を加えることによって, 既存の行動認識モデルを有効活用しながら, ウェアラブルセンサ装着向きの違いにロバストな行動認識システムが構築できるのではないかと考えている.

本論文では, 上記のモチベーションに基づいて, 適応的

¹ 奈良先端科学技術大学院大学

Nara Institute of Science and Technology

² 日本学術振興会特別研究員

JSPS Research Fellowships for Young Scientists

³ JST さきがけ JST PRESTO

⁴ 九州大学 Kyushu University

^{a)} nakamura.yugo.ns0@is.naist.jp

なデータ変換と多段階のセンサ装着位置および行動認識モデルに基づく、センサ装着位置と向きに違いにロバストな行動認識ワークフローを提案する。また、提案ワークフローの有効性を検証することを目的として新たに構築された行動認識データセットを提示する。このデータセットは、複数の行動実施環境、複数のセンサ装着位置、複数のセンサ装着向きを網羅した構成となっており、データ収集実験では、17人の実験協力者に、身体の6箇所に小型マルチセンサボード SenStick[4]を装着した状態で、7種類の基本的な日常生活行動とスマホ操作、PC作業、食事といった10種類のながら行動を実施してもらい、全体を合わせて計276.8時間（1デバイスあたり46.1時間）分のセンサデータセットを構築した。このデータセットを用いて、提案手法の有効性を検証した結果、適切なデータ変換手法を適用することで、センサ装着位置（6クラス）の認識精度（F値）最大+31%改善し、基本行動（7クラス）の認識精度（F値）を最大+28%改善出来ること確認した。また、基本行動とながら行動を合わせた17クラス分類問題に関して、認識精度（F値）を最大+25%を改善し、3つのセンサ装着位置を適切な組み合わせることで83%のF値で認識できることを示した。

以降の章構成は、以下の通りである。第2章では、提案手法に関連する既存研究を概説すると共に、本提案の位置付けを明らかにする。その後、第3章では、本論文で提示する新しい行動認識データセットの概要を示す。第4章では、本論文で対象とする行動認識の問題設定を記述する。第4章では、提案する行動認識ワークフローについて述べ、第5章で提案手法の有効性を示すために評価実験について述べる。最後に、第6章で本論文のまとめとする。

2. 関連研究

本章では、本研究の関連する既存研究として、ユビキタスコンピューティング分野で検討されてきたセンサ位置に着目した人間行動認識手法について述べる。また、各手法の検証に用いられたデータセットについて概説し、最後に、本研究の位置付けを明確にする。

ユビキタスコンピューティング分野では、スマートフォン・ウェアラブルデバイスの普及に伴い、これまで様々な研究グループによって、センサ装着位置に着目した行動認識技術の研究開発が行われてきた[1], [2], [5], [6], [7], [8], [9]。[5], [6]の研究では、スマートフォンが身体上のどこの部位に存在するかを高精度に認識するための手法の検証が進められてきた。[7], [8], [9]の研究では、センサ装着位置が行動認識精度に及ぼす影響を調査し、対象とする行動に応じて、最適なセンサ配置が異なることを明らかにした。我々のグループでも、既存の日常行動ではなく、身体を鍛えるための自重トレーニング行動を対象として、センサ装着位置と認識精度の関係性を明らかにした[10]。最近では、

[1], [2]の研究によって、スマートフォンだけでなく、様々なウェアラブルデバイスを想定し、従来より多くのセンサ装着配置に関して網羅的な調査が行われた。その結果、センサの装着位置を逐次推定して、センサ装着位置に特化した行動認識モデルで対象行動を分類するアプローチが、全てのセンサ装着位置からのセンサデータをまとめて学習するよりも有効であることを示した。

しかしながら、これらの研究では、同様の行動実施環境で、センサ装着向きが統一された共通のドメイン環境下で収集されたデータセットを用いて検証が行われている。そのため、テストデータのセンサ装着向きが学習データセットと異なる場合に、(1)センサ装着位置の認識、(2)ユーザ行動の認識それぞれにおいて、認識精度が劣化するという問題を克服できていない。また、既存の行動認識手法の検証に用いられるオープンデータセット[2], [11], [12], [13], [14], [15], [16]の多くは、対象行動が、歩く、立つ、座るといった基本的なユーザ行動のみを対象としているため、日常生活で発生する歩きながらスマホ操作、座りながらPC作業、座りながら物書きといったながら行動によって発生するノイズを考慮した検討が十分になされていない。


そこで本研究では、これらの課題を解決するために、(a)複数の行動実施環境、複数のセンサ装着位置、複数のセンサ装着向きを網羅した行動認識データセットを新たに構築する。そして、(b)ウェアラブルデバイスから得られる加速度・ジャイロセンサデータを水増し（拡張）する際に、使用するデータ変換手法[3]に着目し、認識対象のセンサデータに対して、適応的に座標軸の回転処理を適用し、擬似的に、学習データで想定されたセンサ装着向きと同様のセンサデータを生成することで、センサ装着位置および向きの違いにロバストな行動認識システムの実現を目指す。

3. SenStick データセット

本研究では、ウェアラブル装着位置や向きの違いにロバストな行動認識モデルの実現を目指している。この目的のために、我々は、超小型マルチセンサボード SenStickを用いて新たに実世界の行動データセットを構築した。

3.1 データセットの概要

本研究では、我々のグループが開発した SenStick[4] (図1左)を使用して、データ収集実験を実施した。SenStickは、8種類の代表的なMEMSセンサ（加速度、角速度、地磁気、温度、湿度、気圧、照度、紫外線）を超小型基板に搭載しており、最大100Hzでロギングが可能である超小型マルチセンサボードである。SenStickは、32MBのフラッシュメモリを搭載しており、収集したセンサデータを内部メモリにロギングすることが可能である。そのため、100Hzのような高サンプリングレートのセンサデータを欠損なくロギングすることが可能である。実験時における、データ収集



SenStick




図 1: SenStick とデータ収集アプリケーション

表 1: SenStick データセットの対象行動ラベル

基本行動：7 クラス分類問題	ながら行動：17 クラス分類問題
A1:横になる	A10:横になる A11:横になりながらスマホ
A2:座る	A20:座る A21:座りながらスマホ A22:座りながら食事 A23:座りながら PC 作業 A24:座りながらもの書き
A3:立つ	A30:立つ A31:立ちながらスマホ A32:立ちながら PC 作業
A4:歩く	A40:歩く A41:歩きながらスマホ
A5:階段登る	A50:階段登る A51:階段登りながらスマホ
A6:階段降りる	A60:階段降りる A61:階段降りながらスマホ
A7:走る	A70:走る

の開始・終了、ロギングされたセンサデータファイルの吸い出しといった操作は、図 1 右に示す専用のスマートフォンアプリケーションによって行われる。この際、SenStick とスマートフォンは、Bluetooth Low Energy (BLE) 通信を介して相互に接続する。本論文では、SenStick に搭載されているセンサの中で、既存の行動認識手法においてもっとも多く活用されている加速度とジャイロセンサに着目し、これら 2 つのセンサを使用した行動認識手法について検証を進める。

本データセットで対象となった行動ラベルを表 1 に示す。我々は、学内の日常生活で発生する行動を想定し、17 種類のラベル（日常行動：7 種類、ながら行動 10 種類）を選定した。従来の行動認識データセットで多く選定されている 7 種類（A1：横になる、A2：座る、A3：立つ、A4：歩く、A5：階段を登る、A6：階段を降りる、A7：走る）の日常行動に加えて、ながらスマホ、食事、PC 作業、もの書きといった、10 種類ながら行動ラベルを含んでいるのが特徴である。そのため、本データセットは、基本行動：7 クラ

表 2: 被験者データ

実験協力者	年齢	体重 (kg)	身長 (cm)	性別
A	25	62	174	Man
B	23	58	173	Man
C	23	68	174	Man
D	23	82	175	Man
E	23	66	177	Man
F	25	55	172	Man
G	23	62	177	Man
H	23	67	174	Man
I	24	59	172	Man
J	23	70	171	Man
K	24	58	163	Man
L	23	56	165	Man
M	22	55	157	Woman
N	26	49	162	Woman
O	23	82	174	Man
P	22	41	157	Woman
Q	23	52	167	Woman




図 2: センサ装着位置の概要




図 3: センサ装着向きが違う例

ス分類問題および、ながら行動：17 クラス分類問題として活用することが可能である。

実験協力者は、表 2 に示ように、男性 13 名、女性 4 名（年齢 23.4 ± 1.0 、身長 169.6 ± 6.3 、体重 61.2 ± 10.3 ）の計 17 名であった。実施する行動の順序は実験協力者に




図 4: センサ装着位置・向きが違う場合の歩行時の加速度波形

任せられ、各行動は、約 10 分間（階段の行動は 5 分程度）実施された。また、各行動に関して、指示はなく、どのように座るか、寝るか、どれくらいの速さで歩くか、などは、実験協力者の裁量に従って自由に行動してもらった。実験時、図 2 に示すように、(1) 胸部 (C : Chest), (2) 腰部 (W : Waist), (3) 右手首 (RW : Right Wrist), (4) 左手首 (LW : Left Wrist), (5) 右足首 (RA : Right Ankle), (6) 左足首 (LA : Left Ankle) の計 6 箇所に SenStick を装着し、1 サンプルレート 100Hz でそれぞれのセンサデータを同時にロギングした。これらのセンサ配置は、名札、ベルト、リストバンド、靴型のウェアラブルデバイスからのセンサデータの取得を想定した配置となっている。実験中、各実験協力者のセンサデータを収集することに加えて、すべての動作はビデオ上に録画された。各行動のラベリングは、そのビデオに基づいて手動で行なわれた。

本データセットを使用して、ウェアラブル装着位置の違いにロバストな行動認識モデルが実現可能か否かを検証するために、センサデータ収集シチュエーションをドメイン A とドメイン B に分けて、センサデータの収集実験を行った。ドメイン A では、大学構内で、各実験協力者に、計 17 種類の行動を実施してもらった。この時、SenStick の装着向きは、統一した状態でセンサデータの収集を行った。ドメイン B では、被験者 A に関して、大学構内とは別の環境下（自宅や屋外、街中、etc.）で、図 3 に示すように、センサ装着向きをドメイン A とは異なる配置で装着にし、計 17 種類の行動をもう一周実施してもらい、その際のセンサデータを収集した。日常生活環境では、図 3 のように、ウェアラブルセンサの装着向きが変動する可能性があるため、そのような違いをシミュレートする目的でこのような実験設定を採用した。実験を通して、ドメイン A のセンサデータ計 261.4 時間、ドメイン B のセンサデータ計 15.4 時間、全体を合わせて計 276.8 時間（1 デバイスあたり 46.1 時間）分のセンサデータを収集した。

以上より、本データセットでは、異なる行動実施環境、センサ装着位置、センサ装着向きのサンプルが含まれていることから、ウェアラブル装着位置の違いにロバストな行動認識モデルを検証するために適したデータセットである

本論文で対象とする問題

学習データとは異なる行動実施環境&センサ装着位置のサンプルが含まれるテストデータをいかに高精度に認識するか？




図 5: 対象問題の概要

と言える。実際、本データセットには、図 4 に示すように、同じ実施行動 (A4 : 歩く) にも関わらず、波形の異なるセンサデータが混在していることが確認できる。

4. 本論文で対象とする問題

本論文では、3 章で示した SenStick データセットを活用して、ウェアラブル装着位置の違いにロバストな行動認識モデルの検証を進める。本章では、本論文で対象とする問題設定について説明する。

4.1 問題設定

日常生活では、行動を実施する環境は多岐にわたり、センサの装着位置、向きに関しても、日々変わる可能性があることから、様々な波形のセンサデータ収集されることが想定される。例えば、単に座るといっても、作業椅子に座るのか、ソファに座るのか、また、階段の段差が異なれば、階段の昇降速度が代わり、同じ実施行動であっても、波形が異なる場合が発生する。このような場合でも、行動認識システムは、高精度にユーザの行動を認識することを求められる。一方、日常生活の全てを網羅した日常行動認識データセットの構築は、データ収集、ラベリングに多くの人的リソースを消費することから、非常に困難である。そのため、限られた状況下で収集された少量の学習データセットを駆使して、日常生活で得られる雑多なセンサデータを高精度に分類可能な行動認識モデルの構築が求められる。

本研究では、これらの状況を想定して、SenStick データ

学習フェーズ




図 6: センサ装着位置の違いにロバストな行動認識ワークフロー

セットを以下のように、学習データとテストデータに分類する。図 5 に、本論文で対象とする行動認識問題の概要を示す。本問題では、SenStick データセットの実験協力者 B～Q の計 16 名のセンサデータを学習データとする。そして、実験協力者 A のセンサデータをテストデータとする。学習データは、全てドメイン A から得られたセンサデータであり、同じ行動実施環境かつセンサ装着向きが統一されたサンプルである。一方、テストデータは、学習データと同じドメイン A からのデータと、異なる行動実施環境かつ異なるセンサ装着向きで収集したドメイン B のセンサデータが混在しており、より日常生活に近いデータ構成となっている。このとき、学習データから機械学習手法を用いて行動認識モデルを構築し、テストデータの行動ラベルを推定精度 (F 値) を最大化することを本問題の目的とする。本論文では、基本行動の 7 種類を対象とした: 7 クラス分類問題および、ながら行動 17 種類を対象とした: 17 クラス分類問題のそれぞれについて検証を進める。

表 3: 加速度・ジャイロセンサから取得した時間および周波数ドメインの信号

名前	種類 (T:Time, F:Freq.)
Body Acc	T, F
Gravity Acc	T
Body Acc Jerk	T, F
Body Angular Speed	T, F
Body Angular Acc	T
Body Acc Magnitude	T, F
Gravity Acc Mag	T
Body Acc Jerk Mag	T, F
Body Angular Speed Mag	T, F
Body Angular Acc Mag	T, F

5. センサ装着位置/向きの違いにロバストな行動認識システム

本章では、4 章で示した問題を解決するための行動認識システムを提案する。具体的には、以下の 3 つの違いが発生する状況下でも、それぞれの違いを吸収しながら、高精度にユーザの実施行動を認識するロバストな行動認識システムの構築を目指す。

- (1) センサ装着位置の違い
- (2) センサ装着向きの違い
- (3) 行動を実施する環境の違い

図 6 に、提案する行動認識ワークフローの全体構成を示す。本手法では、学習フェーズにおいて、様々なセンサ装着位置、装着向きに対応可能な、認識モデルを複数構築し、推論フェーズで、入力 of データに適した認識モデルを適応的に選択することで、センサ装着位置/向きにロバストな行動認識を実行することを狙いとする。以下では、それぞれの処理プロセスについて、説明する。

5.1 学習フェーズ

5.1.1 データ前処理

データ前処理プロセスでは、ウェアラブルセンサから取得される加速度 (Acc.XYZ), ジャイロ (Gyro.XYZ) 信号に対し、メディアンフィルタと 20Hz の 3 次バタワース・ローパスフィルタをかけてスパイクノイズなどのノイズ除去を行う。身体動作の 99 % が 15Hz 以下に含まれており、人間の行動を捕捉するのに十分であることから、20Hz のフィルタを選定している [17]。ノイズ除去された加速度信号 (Acc.XYZ) には重力および体動成分が混在しているため、0.3Hz のバタワース・ローパスフィルタをかけ、重力

成分 (GravityAcc.XYZ) と体動成分 (BodyAcc.XYZ) に分離させる。0.3Hz という値は、重力は低周波成分のみを有すると仮定されていることから決定された [11], [18]。この分離によって得られた重力成分は身体の姿勢判定などに有効的であり、体動成分は身体の動作や揺れなどを表すものとして考えられる。さらに、時間微分を計算することによって取得されるジャーク信号 (BodyAccJerk.XYZ) と 3 軸信号から式 1 を用いてユークリッド距離を算出することで取得される合成信号 (GravityAccMag, BodyAccMag, BodyAccJerkMag) を生成する。ジャイロ信号も同様に、体動成分の角速度 (BodyAngularSpeed-XYZ) に加えて、角加速度 (BodyAngularAcc-XYZ) および合成信号 (BodyAngularSpeedMag, BodyAngularAccMag) を生成する。次に、上記の波形の中から GravityAcc.XYZ, GravityAccMag, BodyAngularSpeed-XYZ を除く、7 つの波形に対して、高速フーリエ変換 (FFT) を適用し、周波数領域にマッピングした信号を生成する。結果として、このプロセスを通じて、表 3 に示す、時間ドメイン 10 個、周波数ドメイン 7 個の合計 17 種類の信号を抽出する。

$$Magnitude(Mag) = \sqrt{(x^2 + y^2 + z^2)} \quad (1)$$

5.1.2 特徴量抽出

特徴量抽出プロセスでは、前処理プロセスで得られた 17 個の信号を 1.56 秒のタイムウィンドウ幅 (128 サンプル)、50% のオーバーラップで分割する。そして、各ウィンドウから特徴量を抽出する。運動認識に関する先行研究 [19] によって述べられているように、1 秒以上のタイムウィンドウによって取り出されたデータには各運動の特徴を表すサンプルが十分に含まれていること、高い認識精度が得られていることからタイムウィンドウは 1.56 秒とする。1.56 秒のタイムウィンドウで区切られた信号から表 4 に示す、時間ドメイン特徴量 (Time domain features) と周波数ドメイン特徴量 (Frequency domain features) を算出する。これらの特徴量の選択する理由としては、主に慣性データを用いた日常行動認識に関する先行研究から有効性が示されているためである [11]。結果として、1.56 秒の各ウィンドウデータから、561 個の特徴量ベクトルを抽出する。抽出された特徴量はそれぞれ単位が異なるため、標準化を行う。そして、標準化された特徴量ベクトルの機械学習アルゴリズムに学習させて、行動認識モデルを生成する。

5.1.3 機械学習ベースの認識モデル構築

提案する行動認識ワークフローでは、センサ装着位置の違いを吸収するために、入力されたセンサデータからセンサ装着位置を認識した後に、センサ装着位置個別の行動認識モデルで対象行動を認識する 2 段階の認識ステップを採用する。センサ装着位置の違いを吸収するために、全ての装着位置を含んだ学習データを用いて対象行動の認識モデル




図 7: 加速度データに対する回転処理の適用例

ルを学習させるアプローチも考えられる。しかしながら、先行研究 [2] によって、前述のアプローチよりも、装着位置毎に個別の認識モデルを構築した方が、認識精度の良いモデルが構築できるという結果が得られているため、本アプローチを採用する。そのため、認識モデルの構築プロセスでは、(c) センサ装着位置を推定するためのモデルと (d) ユーザの行動を認識するモデルという 2 つのモデルを構築する。センサ装着位置を推定するためのモデルは、センサデータから SenStick データセットにある 6 つの装着位置 (胸部、腰部、右手首、左手首、右足首、左足首) を推定する位置認識モデルとなる。また、ユーザの行動を認識するモデルは、6 つの装着位置ごとに学習データを分割し、それぞれの部位に特化した行動認識モデルを学習させる。本プロセスでは、先行研究 [2] において有効性が示されている Random Forest (RF) を採用する。学習モデルの構築には、Python の機械学習ライブラリである scikit-learn[20] を用いており、分類木の本数を 100 に設定し、他のパラメータはデフォルトのものを使用する。

5.2 推論フェーズ

推論フェーズでは、学習フェーズで構築した複数の認識モデルを有効活用して、テストデータの認識を行う。前処理、特徴量抽出プロセスについては、前述の通りである。また、位置認識プロセスでは、学習フェーズで生成した装着位置認識モデルを使用して、入力のセンサデータがどの部位に装着されたセンサなのかを推定する。行動認識プロセスでは、位置認識プロセスで推定された装着位置情報に基づいて、その位置に特化した、行動認識モデルを選択し、対象となる行動の認識を行う。しかしながら、同じセンサ装着向きに統一されたドメイン特化な学習データを使用して、機械学習ベースの位置認識モデル、行動認識モデルを構築した場合、センサ装着向きが学習データと違う場合に認識精度が劣化してしまうという課題が残されている。そ

表 4: 特徴ベクトルを計算するための関数リスト

特徴量抽出関数	説明	数式	種類 (T:Time, F:Freq.)
mean (s)	Arithmetic mean	$\bar{s} = \frac{1}{N} \sum_{i=1}^N s_i$	T, F
std (s)	Standard deviation	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N \Gamma s_i - \bar{s} \Gamma^2}$	T, F
mad (s)	Median absolute deviation	$median_i \Gamma \mid s_i \Gamma median_j \Gamma s_j \Gamma \mid \Gamma$	T, F
max (s)	Largest values in array	$max_i \Gamma s_i \Gamma$	T, F
min (s)	Smallest value in array	$min_i \Gamma s_i \Gamma$	T, F
energy (s)	Average sum of the square	$\frac{1}{N} \sum_{i=1}^N s_i^2$	T, F
sma (s_1, s_2, s_3)	Signal magnitude area	$\frac{1}{3} \sum_{i=1}^3 \sum_{j=1}^N s_{i,j} $	T, F
entropy (s)	Signal Entropy	$\sum_{i=1}^N \Gamma c_i \log \Gamma c_i \Gamma, c_i = s_i / \sum_{j=1}^N s_j$	T, F
iqr (s)	Interquartile range	$Q3 \Gamma s \Gamma - Q1 \Gamma s \Gamma$	T, F
autorregresion (s)	4th order Burg Autoregression coefficients	$a = arburg \Gamma s, 4 \Gamma, a \in R^4$	T
correlation (s_1, s_2)	Pearson Correlation coefficient	$C_{1,2} / \sqrt{C_{1,1} C_{2,2}} \Gamma C = cov \Gamma s_1, s_2 \Gamma$	T
angle (s_1, s_2, s_3, v)	Angle between signal mean and vector	$\tan^{-1} \Gamma \parallel [\bar{s}_1, \bar{s}_2, \bar{s}_3] \times v \parallel, [\bar{s}_1, \bar{s}_2, \bar{s}_3] \cdot v \Gamma$	T
range (s)	Range of smallest value and Largest value	$max_i \Gamma s_i \Gamma - min_i \Gamma s_i \Gamma$	T
rms (s)	Root square means	$\sqrt{\frac{1}{N} \Gamma s_1^2 + s_2^2 + \dots + s_N^2 \Gamma}$	T
skewness (s)	Frequency signal Skewness	$E[\Gamma \frac{s-\bar{s}}{\sigma} \Gamma^3]$	F
kurtosis (s)	Frequency signal Kurtosis	$E[\Gamma s - \bar{s} \Gamma^4] / E[\Gamma s - \bar{s} \Gamma^2]^2$	F
maxFreqInd (s)	Largest frequency component	$argmax_i \Gamma s_i \Gamma$	F
meanFreq (s)	Frequency signal weighted average	$\sum_{i=1}^N \Gamma i s_i \Gamma / \sum_{j=1}^N s_j$	F
energyBand (s, a, b)	Spectral energy of a frequency band [a, b]	$\frac{1}{a-b+1} \sum_{i=a}^b s_i^2$	F

N : signal vector length, Q : Quartile, T : Time domain features, F : Frequency domain features.

ここで、本提案手法では、このようなドメイン特化の認識モデルを有効活用するための施策として、推論フェーズで適応的に、デバイスの向きに応じてセンサデータの座標軸を回転させるデータ変換プロセスを導入する。

5.2.1 デバイスの向きに応じたデータ変換処理

データ変換処理プロセスでは、推定対象の加速度・ジャイロデータからセンサデバイスの装着向きを算出し、その後、学習データのサンプルに含まれるセンサデバイス装着向きと同じになるように軸の回転処理を加える。これによって、センサ装着向きの違いを吸収する狙いがある。図 7 に、腕センサの装着向きの違いを吸収するために、回転処理を適用した加速度データの例を示す。左がセンサ装着向き A のセンサデータ、中央がセンサ装着向き B の加速度データ、右がセンサ装着向き A に合うように、センサ装着向き B の加速度データに対して Z 軸に対して 180 度の回転処理を加えた加速度データである。このように、入力となるセンサデータに対して適切な回転処理を適用することで、学習データ内に含まれるサンプルと同様の波形を擬似的に生成することが可能である。推論フェーズにデータ変換処理を適用する場合の利点として、データ拡張を行わずにドメイン特化で学習した機械学習ベースの行動認識モデルを有効活用できるという点があげられる。

6. 評価実験

本章では、5 章で示した提案手法の有効性を検証するために、3 章で示した SenStick データセットを用いた評価結果を示す。具体的には、次の 3 つの分類問題に対して、提案手法の有効性を検証し、それらの結果を考察する。

表 5: 全行動ラベルを対象としたセンサ装着位置認識の結果 (データ変換なし)

センサ装着位置	再現率	再現率	F 値
Chest	0.67	0.50	0.58
Waist	0.84	0.65	0.73
Left-wrist	0.58	0.46	0.51
Right-wrist	0.39	0.61	0.48
Left-ankle	0.38	0.48	0.42
Right-ankle	0.46	0.40	0.43
平均	0.55	0.52	0.52

表 6: 全行動ラベルを対象としたセンサ装着位置認識の結果 (データ変換あり)

センサ装着位置	再現率	再現率	F 値
Chest	0.95	0.93	0.94
Waist	0.85	0.83	0.84
Left-wrist	0.72	0.80	0.76
Right-wrist	0.73	0.81	0.76
Left-ankle	0.94	0.82	0.88
Right-ankle	0.83	0.79	0.81
平均	0.84	0.83	0.83

- (1) センサ装着位置認識 : 6 クラス分類問題
- (2) 基本行動認識 : 7 クラス分類問題
- (3) 基本&ながら行動認識 : 17 クラス分類問題

6.1 センサ装着位置認識 : 6 クラス分類問題

本節では、センサ装着位置認識の結果を示す。表 5, 表 6 に、それぞれ、データ変換処理を適用しない場合と、適




図 8: 全行動ラベルを対象としたセンサ装着位置認識の混合行列




図 9: 動的行動ラベル（歩く、階段登る/降りる、走る）のセンサ装着位置認識の混合行列

表 7: 動的行動ラベル（歩く、階段登る/降りる、走る）を対象としたセンサ装着位置認識の結果（データ変換なし）

センサ装着位置	再現率	再現率	F 値
Chest	0.72	0.51	0.60
Waist	0.99	0.86	0.92
Left-wrist	0.63	0.56	0.59
Right-wrist	0.44	0.59	0.50
Left-ankle	0.46	0.51	0.48
Right-ankle	0.49	0.51	0.50
平均	0.62	0.59	0.60

表 8: 動的行動ラベル（歩く、階段登る/降りる、走る）を対象としたセンサ装着位置認識の結果（データ変換あり）

センサ装着位置	再現率	再現率	F 値
Chest	1.00	1.00	1.00
Waist	1.00	1.00	1.00
Left-wrist	0.98	0.97	0.97
Right-wrist	0.97	0.98	0.97
Left-ankle	1.00	1.00	1.00
Right-ankle	1.00	1.00	1.00
平均	0.99	0.99	0.99

用した場合の全行動ラベルのセンサデータを対象としたセンサ装着位置認識の結果を示す。また、図 8 に、ドメイン A のテストデータ、ドメイン B のテストデータ、ドメイン B のテストデータにデータ変換処理を適用した場合、それぞれに関するセンサ装着位置認識の混合行列を示す。結果

表 9: センサ位置毎の基本行動（7 クラス）認識精度の比較

センサ装着位置	データ変換なしの結果（平均 F 値）	データ変換ありの結果（平均 F 値）
Chest	0.72	0.80
Waist	0.80	0.83
Left-wrist	0.54	0.75
Right-wrist	0.51	0.79
Left-ankle	0.62	0.79
Right-ankle	0.76	0.76

から、データ変換処理を適用しない場合のセンサ装着位置を平均 52%，データ変換処理を平均 83%，の F 値で認識できること示しており、データ変換処理を適用することでセンサ装着位置の認識精度を+31%改善できることを確認した。この結果から、センサの装着向きに応じて、適切なデータ変換処理を適用することで、異なる行動実施環境かつセンサ装着向きが異なる場合でも、ある 8 割程度でセンサ装着位置の認識が可能であると言える。

次に、表 7、表 8 に、データ変換処理を適用しない場合と、適用した場合の動的行動ラベル（歩く、階段登る/降りる、走る）のセンサデータを対象としたセンサ装着位置認識の結果を示す。また、図 9 に、各テストデータ毎のセンサ装着位置認識の混合行列を示す。結果は、データ変換処理を適用しない場合のセンサ装着位置を平均 60%，データ変換処理を平均 99%の F 値で認識できること示している。この結果より、歩く、階段登る/降りる、走るなど動的な行

動に関しては、ほぼ確実にセンサ装着位置を認識可能であると言える。そのため、ユーザのセンサ装着位置を正確に推定するためには、横になる、座る、立つのような静的行動から、動的行動に切り替わるタイミングをパターンマッチングなど機械学習を用いない手法により検出し、ユーザが動的行動の行なっている最中に、センサ装着位置を推定する手法が有効であると考えられる。

6.2 基本行動認識：7 クラス分類問題

本節では、基本行動認識（7 クラス分類問題）の結果を示す。表 9 に、センサ位置毎の基本行動（7 クラス）の認識結果を示す。結果は、腰部（Waist）のセンサが最も高精度に、基本行動 7 クラスを認識することが確認でき、データ変換処理を適用しない場合、平均 80%、データ変換処理を適用する場合、平均 83% の F 値で認識できること示している。また、胸部に関しても、比較的高い平均 83% の F 値で認識できることを示している。また、右手首（Right-wrist）に関しては、データ変換処理を適用しない場合、認識精度が平均 51% の F 値であるのに対し、データ変換処理を適用することで、平均 79% の F 値に改善（+28%）できることを示している。図 10、図 11 に、腰部と右手首のセンサ装着位置に関する、ドメイン A のテストデータ、ドメイン B のテストデータ、ドメイン B のテストデータにデータ変換処理を適用した場合、それぞれに関する基本行動認識の混合行列を示す。これらの結果から、身体の体幹に位置するセンサは、座る、歩く、走るなど基本的な日常行動の認識に有効であると考えられる。また、体幹に位置するセンサは、センサ装着向きが異なるドメイン B のテストデータでもある 7、8 割の精度で基本行動を認識できていることから、学習する際に、マグニチュードなど、センサ装着向きに依存しない合成信号の特徴量を重要視していると考えられる。両手首に位置するセンサは、他の装着位置と比べて認識精度が低いですが、これは、基本行動中のスマホ操作や PC 作業などのながら行動の多くが手を利用することから、これらの動作が基本行動を認識する上でのノイズとなり、認識精度が劣化していると考えられる。その一方で、両手のセンサは、ユーザのながら行動を認識するという用途では、有用なセンサと捉えることができると考える。次節で、基本行動に加えて、ながら行動の認識も考慮した行動認識結果を示す。

6.3 基本&ながら行動認識：17 クラス分類問題

本節では、基本行動およびながら行動認識（17 クラス分類問題）の結果を示す。表 10 に、センサ位置毎の基本行動およびながら行動（17 クラス）の認識結果を示す。結果から、前節の考察通り、右手首（Right-wrist）のセンサが最も高精度に、17 クラスを認識することが確認でき、データ変換処理を適用しない場合、平均 40%、データ変

換処理を適用する場合、平均 65% の F 値で認識できること示している（+25%改善）。また、図 12、図 13 に、右手首（Right-wrist）のセンサにおける、データ変換処理を適用しない場合、データ変換処理を適用する場合、それぞれの基本&ながら行動認識の混合行列を示す。図 13 の結果より、右手首（Right-wrist）のセンサのみでは、座りながらの PC 作業と立ちながらの PC 作業の誤認識や、立ちながらのスマホ操作と座りながらのスマホ操作、横になると横になりながらスマホ操作を誤認識していることが確認できる。これらの誤認識は、他の部位に位置するセンサを組み合わせることで、回避できるのではないかと考える。また、左手首より、右手首の方が認識精度が高い理由は、実験協力者の多数が右利きであり、データセットの中に、ながら行動を右手で実施するサンプルが多かったためだと考える。表 11 に、右手首のセンサとその他のセンサの組み合わせによる基本行動およびながら行動（17 クラス）の認識結果を示す。結果は、2 つセンサを利用する場合には、右手首（Right-wrist）と右足首（Right-ankle）の組み合わせが一番よく、平均 75% の F 値で 17 クラスを認識できることを示している。また、3 つセンサを利用する場合には、左右の手首（Right, Left-wrist）と左足首（Left-ankle）の組み合わせが最も高精度に、平均 83% の F 値で 17 クラスを認識できることを示している。図 14、図 15 に、右手首（Right-wrist）と右足首（Right-ankle）の組み合わせ、左右の手首（Right, Left-wrist）と左足首（Left-ankle）の組み合わせにおける 17 クラス認識の混合行列を示す。図 14 の結果から、右手首に加えて、左手首のセンサを活用することで、全体的に、17 クラスの分類精度が行動していることが確認できる。しかしながら、立ち座りながらスマホ操作や立ち座り PC 作業を誤認識していることが確認できる。図 15 では、3 つのセンサ組み合わせ（左右の手首と左足首）によって、ながらスマホ操作の誤認識を克服できていることが確認できる。しかし依然として、ながら PC 作業の認識には課題が残る結果となっている。今後は、一度に 17 クラスを分類するモデルを構築するのではなく、はじめに座っているなどの基本行動を分類した後、スマホ操作しているのか、PC 作業しているのか、食事しているのかを分類する多段構造の認識モデルを構築し、ながら行動の認識精度改善を試みる。

7. おわりに

本論文では、適応的なデータ変換と多段階のセンサ装着位置および行動認識モデルに基づく、センサ装着位置と向きに違いにロバストな行動認識ワークフローを提案した。また、提案ワークフローの有効性を検証することを目的として、複数の行動実施環境、複数のセンサ装着位置、複数のセンサ装着向きという条件に基づいて新たに構築された行動認識データセット（計 276.8 時間）を提示した。この




図 10: 腰センサを用いた基本行動（7 クラス）認識の混合行列




図 11: 右手首センサを用いた基本行動（7 クラス）認識の混合行列

表 10: センサ位置毎の基本&ながら行動 (17 クラス) 認識精度の比較

センサ装着位置	データ変換なしの結果 (平均 F 値)	データ変換ありの結果 (平均 F 値)
Chest (Ch)	0.37	0.40
Waist (Wa)	0.35	0.40
Left-wrist (Lw)	0.30	0.42
Right-wrist (Rw)	0.40	0.65
Left-ankle (La)	0.33	0.40
Right-ankle (Ra)	0.40	0.40

データセットを用いて、提案手法の有効性を検証した結果、適切なデータ変換手法を適用することで、センサ装着位置（6 クラス）の認識精度（F 値）最大+ 31%改善し、基本行動（7 クラス）の認識精度（F 値）を最大+ 28%改善出来ること確認した。また、基本行動とながら行動を合わせた 17 クラス分類問題に関して、認識精度（F 値）を最大+ 25%を改善し、3 つのセンサ装着位置を適切な組み合わせることで 83%の F 値で認識できることを示した。今後は、従来の機械学習ベースのアルゴリズムだけでなく、深層学習アルゴリズムを活用して、汎化性能の高い学習モデルの構築を検討する。また、本手法を日常行動認識だけでなく、体幹トレーニング [10] や剣道打突検出 [21] といった SenStick を活用したその他のプロジェクトに応用し、それぞれの認識性能改善を試みる。

謝辞 本研究は、JST ACT-I, さきがけ, JSPS 科研費




図 12: 右手首センサを用いたながら行動（17 クラス）認識の混合行列（データ変換なし）

(17J10021) の支援を受けて実施されたものである。

参考文献

- [1] Szttyler, T. and Stuckenschmidt, H.: On-body localization of wearable devices: An investigation of position-aware activity recognition, *2016 IEEE International Conference on Pervasive Computing and Communica-*




図 13: 右手首センサを用いたながら行動 (17 クラス) 認識の混合行列 (データ変換あり)




図 14: 右手首と右足首のセンサ組み合わせによる基本行動&ながら行動 (17 クラス) 認識の混合行列 (データ変換あり)

表 11: 右腕と他のセンサ組み合わせにおける基本&ながら行動 (17 クラス) 認識精度の比較

センサ装着位置 の組み合わせ	データ変換なしの 結果 (平均 F 値)	データ変換ありの 結果 (平均 F 値)
Rw & Ch	0.60	0.68
Rw & Wa	0.60	0.70
Rw & Lw	0.51	0.73
Rw & La	0.55	0.73
Rw & Ra	0.59	0.75
Rw & Ra & La	0.56	0.72
Rw & Ra & lw	0.67	0.81
Rw & Ra & wa	0.64	0.73
Rw & Ra & ch	0.62	0.73
Rw & La & Lw	0.64	0.83
Rw & La & wa	0.61	0.71
Rw & La & ch	0.62	0.74
Rw & Lw & wa	0.65	0.74
Rw & Lw & ch	0.67	0.76




図 15: 右手首, 左足首, 左手首のセンサ組み合わせによる基本行動&ながら行動 (17 クラス) 認識の混合行列 (データ変換あり)

- tions (PerCom), IEEE, pp. 1–9 (2016).
- [2] Szttyler, T., Stuckenschmidt, H. and Petrich, W.: Position-aware activity recognition with wearable devices, *Pervasive and mobile computing*, Vol. 38, pp. 281–295 (2017).
- [3] Um, T. T., Pfister, F. M. J., Pichler, D., Endo, S., Lang, M., Hirche, S., Fietzek, U. and Kulić, D.: Data augmentation of wearable sensor data for Parkinson’s disease monitoring using convolutional neural networks, *arXiv preprint arXiv:1706.00527* (2017).
- [4] Nakamura, Y., Arakawa, Y., Kanehira, T., Fujiwara, M. and Yasumoto, K.: Senstick: Comprehensive sensing platform with an ultra tiny all-in-one sensor board for iot research, *Journal of Sensors*, Vol. 2017 (2017).
- [5] Kunze, K., Lukowicz, P., Junker, H. and Tröster, G.:

- Where am i: Recognizing on-body positions of wearable sensors, *International Symposium on Location and Context-Awareness*, Springer, pp. 264–275 (2005).
- [6] Vahdatpour, A., Amini, N. and Sarrafzadeh, M.: On-body device localization for health and medical monitoring applications, *Pervasive Computing and Communications (PerCom), 2011 IEEE International Conference on*, IEEE, pp. 37–44 (2011).
- [7] Atallah, L., Lo, B., King, R. and Yang, G.-Z.: Sensor

- positioning for activity recognition using wearable accelerometers, *IEEE transactions on biomedical circuits and systems*, Vol. 5, No. 4, pp. 320–329 (2011).
- [8] Martín, H., Bernardos, A. M., Iglesias, J. and Casar, J. R.: Activity logging using lightweight classification techniques in mobile devices, *Personal and ubiquitous computing*, Vol. 17, No. 4, pp. 675–695 (2013).
 - [9] Coskun, D., Incel, O. D. and Ozgovde, A.: Phone position/placement detection using accelerometer: Impact on activity recognition, *2015 IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, IEEE, pp. 1–6 (2015).
 - [10] Takata, M., Fujimoto, M., Yasumoto, K., Nakamura, Y. and Arakawa, Y.: Investigating the Capitalize Effect of Sensor Position for Training Type Recognition in a Body Weight Training Support System, *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*, ACM, pp. 1404–1408 (2018).
 - [11] Anguita, D., Ghio, A., Oneto, L., Parra, X. and Reyes-Ortiz, J. L.: A public domain dataset for human activity recognition using smartphones., *ESANN* (2013).
 - [12] Reyes-Ortiz, J.-L., Oneto, L., Samà, A., Parra, X. and Anguita, D.: Transition-aware human activity recognition using smartphones, *Neurocomputing*, Vol. 171, pp. 754–767 (2016).
 - [13] Kwapisz, J. R., Weiss, G. M. and Moore, S. A.: Activity recognition using cell phone accelerometers, *ACM SigKDD Explorations Newsletter*, Vol. 12, No. 2, pp. 74–82 (2011).
 - [14] Kawaguchi, N., Ogawa, N., Iwasaki, Y., Kaji, K., Terada, T., Murao, K., Inoue, S., Kawahara, Y., Sumi, Y. and Nishio, N.: HASC Challenge: gathering large scale human activity corpus for the real-world activity understandings, *Proceedings of the 2nd augmented human international conference*, ACM, p. 27 (2011).
 - [15] Reiss, A. and Stricker, D.: Introducing a new benchmarked dataset for activity monitoring, *2012 16th International Symposium on Wearable Computers*, IEEE, pp. 108–109 (2012).
 - [16] Banos, O., Garcia, R., Holgado-Terriza, J. A., Damas, M., Pomares, H., Rojas, I., Saez, A. and Villalonga, C.: mHealthDroid: a novel framework for agile development of mobile health applications, *International workshop on ambient assisted living*, Springer, pp. 91–98 (2014).
 - [17] Karantonis, D. M., Narayanan, M. R., Mathie, M., Lovell, N. H. and Celler, B. G.: Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring, *IEEE transactions on information technology in biomedicine*, Vol. 10, No. 1, pp. 156–167 (2006).
 - [18] Mason, J., Kelley, C., Olaleye, B., Esterline, A. and Roy, K.: An Evaluation of User Movement Data, *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*, Springer, pp. 729–735 (2018).
 - [19] Maurer, U., Smailagic, A., Siewiorek, D. P. and Deisher, M.: Activity recognition and monitoring using multiple sensors on different body positions, *Wearable and Implantable Body Sensor Networks, 2006. BSN 2006. International Workshop on*, IEEE, pp. 4–pp (2006).
 - [20] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. et al.: Scikit-learn: Machine learning in Python, *Journal of machine learning research*, Vol. 12, No. Oct, pp. 2825–2830 (2011).
 - [21] Takata, M., Nakamura, Y., Torigoe, Y., Fujimoto, M., Arakawa, Y. and Yasumoto, K.: Strikes-Thrusts Activity Recognition Using Wrist Sensor Towards Pervasive Kendo Support System.