

体幹トレーニング支援に向けた ウェアラブルデバイスによる種目認識手法の提案

高田 将志^{1,a)} 中村 優吾^{1,2} 藤本 まなと¹ 荒川 豊^{1,3,b)} 安本 慶一^{1,c)}

概要: 近年, 健康志向ブームの到来により, 老化防止や運動不足解消に効果を発揮する体幹トレーニングの重要性が日々高まっている. 体幹トレーニングは個人でも行うことのできるエクササイズとして認識されており, 実用的かつ簡単なトレーニング手法である. 体幹トレーニングの効果を最大限に発揮するには, 正しい姿勢を保つことが極めて重要である. しかしながら, 個人で行う場合 (特に素人) は, トレーニング中の姿勢や正しい姿勢との違いを認識することは難しい. 本研究では, これらの問題の解決に向けた第一段階として, 体幹トレーニング支援に向けたウェアラブルデバイスを活用した種目認識手法を新たに提案する. トレーニング中の姿勢や正しい姿勢との違いを認識するには, トレーニング種目を正確に認識できる必要がある. 本稿では, 右手首, 左手首, ベルト位置に取り付けられたウェアラブルデバイスから得られる加速度, ジャイロデータのみを使って, 7種類 (計 10 パターン) の体幹トレーニング種目認識を行なった. 機械学習手法として, Random Forest (RF) を用い, Leave-one-person-out Cross-Validation により各種目の認識精度 (F 値) を評価した結果, F 値: 99.7%と高精度に認識することに成功した. さらに, 片方の手首およびベルト位置にデバイスを装着するだけでも F 値: 94.1%の精度で認識できることを確認した.

1. はじめに

近年, 我が国の高齢化率は著しく増加し続け, 65 歳以上の高齢者人口はおおよそ 3500 万人であり, 高齢化率で表すと 27.7%まで達している. 2050 年には 38.4%, すなわち 2.6 人に 1 人が老年人口となると推計されている [1], [2]. また, 要介護認定者は既に 640 万人を超えおり, 今後も高齢化が深刻化することが見込まれる [3]. 高齢化が深刻化すると, 経済成長の弱体化, 社会保障の負担増大など, 様々な問題が引き起こされる. それらの問題の解決策として, 高齢者になっても健康な体で自立した生活を続けられるように日頃から適度な運動やトレーニングを行うように促していく必要がある. 自立した生活を送ることのできる体力を身に付けければ, 健康寿命が延び, また介護の必要がなくなると共に, 労働力として社会貢献することに繋がる. したがって, 健康寿命を延伸させ, 要支援・要介護状態にならないための取組みを推進させることは非常に重要であるといえる.

このような背景の下, 「体幹」というキーワードに注目が集まっている. 体幹とは身体の四肢と頭部を除いた全重量の約 48%を占める非常に大きな部位で, 運動については四肢間の運動連結やバランスに関して重要な役割を果たしている. そのため, 体幹は動作の言わば要であり, 寝返り, 起き上がり, 座位, 立位, 移乗, 歩行動作などの全ての生活動作において最も重要な体の部位である. 体幹の筋力が低下すれば, 起き上がれなくなり, 体幹に異常運動を呈すれば, 座位などの姿勢保持が著しく困難になるなど, 体幹強度は身体の健康にとっても重要である. これらの理由から, 体幹筋の働きを重視したトレーニング方法をいち早くスポーツ選手が応用しており, その重要性が一般の人々にも浸透し始め注目されるようになってきている.

また, 保健, 医療, 福祉などの健康関連分野においても, 体幹の機能が見直されてきている [4], [5], [6]. 体幹トレーニングは, 一般的に個人でも行うことのできるエクササイズとして認識されており, 体幹筋を中心とした全身の筋肉を鍛えることができる実用的かつ簡単なトレーニング手法である. その効果を最大限に発揮するには, 正しい姿勢を保つことが極めて重要であり, トレーニング中の怪我防止にも繋がる. しかしながら, パーソナルトレーナーの指導下において行う場合の体幹トレーニングとは異なり, 個人 (特に素人) で行う体幹トレーニングは, トレーニング中の

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

a) takata.masashi.td7@is.naist.jp

b) ara@is.naist.jp

c) yasumoto@is.naist.jp

姿勢が正しいものかどうかを認識することやトレーニングの質（姿勢の正しさや時間の適正さなど）を評価することは難しい。

本研究では、これらの問題を解決するため、パーソナルトレーナーが介在しない状況でも、より効果的な個人トレーニングを支援する体幹トレーニング支援システムの実現を目指す。具体的には、(1) トレーニング中の姿勢からトレーニング種目を認識する機構、(2) トレーニング種目における理想的な姿勢との違いやどの程度その姿勢を保つことができたかなど、トレーニングの質を判定する機構、(3) 判定結果に基づいて、トレーニング中の姿勢改善や実施時間などのメニュー改善案をフィードバックする機構から構成されるインタラクティブシステムの実現を目指す。本稿では、体幹トレーニング支援システムの実現に向けた第一段階として、ウェアラブルデバイスによる代表的な7種類（計10パターン）の体幹トレーニング種目認識手法を新たに提案する。本稿の貢献は以下の通りである。

- 第一に、個人で行うトレーニングの質を定量的に評価すると共に、ユーザに対して適切なトレーニング指導を行う新たなインタラクティブシステムとして、体幹トレーニング支援システムの全体構想を明確化する。
- 第二に、安価かつ少数のウェアラブルデバイスによって、体幹トレーニング種目を認識する手法を提案する。具体的には、右手首、左手首、ベルト位置に取り付けられたウェアラブルデバイスから得られる加速度、ジャイロデータから特徴量を抽出し、機械学習を用いて基本的な7種類（計10パターン）の体幹トレーニング種目を高精度に認識できる手法を提案する。
- 第三に、提案手法の有効性を示すため、被験者14名による評価実験を行った。その結果、99.7%と高精度に識別することに成功した。さらに、片方の手首およびベルト位置にデバイスを装着するだけでも94.4%の精度で認識できることを確認した。

本稿の構成は以下の通りである。2章でウェアラブルデバイスを活用した運動支援に関する関連研究について述べる。3章で提案する体幹トレーニング支援システムの全体像について述べたのち、4章でウェアラブルデバイスによる種目認識手法を述べる。5章で評価実験について述べ、最後に6章で本稿の結論を述べる。

2. 関連研究

運動支援を目的とした関連研究には、1) 運動認識のみを行なった研究と、2) 運動認識を行い、さらにはその運動評価までを行なった研究の2つに分けられる。

2.1 運動認識

Terryらは腕装着型ウェアラブルデバイスから得られる加速度とジャイロデータをもとに、畳み込みニューラル

ネットワーク（CNN）によって50種目の筋肉トレーニングを92.1%の精度で認識し、また85.3%の精度で自動カウントに成功している[7]。Chenguangらはスマートウォッチベースの自動セグメンテーションを実行するトレーニングトラッキングシステムであるMiLiftを開発した[8]。これによりユーザーにトレーニング種目を選択させたり、トレーニングを開始/停止させたりすることによって生じる負担を防ぐことができる。しかし、フォームの指導やトレーニング評価までは行っていない。

2.2 運動認識と評価

DingらはFEMOと呼ばれるフリーウエイトトレーニングを対象としたモニタリングシステムを開発した[9]。これはパッシブ型RFIDタグをダンベルに取り付けて、発せられる信号変化から種目認識を行い、そして、信号の速さ、滑らかさ、強度、継続時間から運動の質を評価している。Zhouらはレッグマシントレーニングに焦点を当てて、その種目認識および評価を行なった[10]。圧力布センサをスポーツバンドで大腿部に装着し、皮膚とスポーツバンドとの間の面圧変化を利用して、トレーニング中の四頭筋の筋活動を監視した。その結果、4種目のトレーニングとその他ジム内での行動（歩く、マシン操作など）を含む5種類の行動識別を93.3%の精度で識別し、ウォームアップ中に生じる、筋肉の血流、酸素、代謝およびアドレナリンの増加を平均圧力の増減から評価している。ChenらはYogaSTと呼ばれるヨガに焦点を当てた、個人ヨガレッスンシステムを開発した[11]。これは2つのKinectを用いてヨガポーズ時の姿勢を認識し、視覚的フィードバックによる姿勢改善を促すことで効果的な個人ヨガレッスンを実施できる。

2.3 本研究の位置付け

上記で述べた関連研究[7]、[8]、[9]、[10]はあくまでトレーニング種目の認識および特別な専用デバイスを用いた評価のみに止まっており、先行研究[11]はKinectなどを用いる必要があるため、コストがかかる。本研究では、個人トレーニングの質の向上に向けて、簡易なデバイスを用いて種目認識だけではなく、姿勢改善フィードバックや推定された筋力や疲労度からユーザの体バランスの偏りや筋肉の弱点部位などを特定し、その部位を補うメニューを推薦できるような有効かつ効果的な個人向け体幹トレーニング支援システムの構築を目指す点で関連研究とは異なる。

3. 体幹トレーニング支援システムの全体構想

本稿では、人間の動きを一般的な方法で、事前定義された動作や機器に縛られることなく、定量的に評価できる体幹トレーニング支援システムを新たに提案する。図1に提案する体幹トレーニング支援システムの全体図を示す。提案システムは、最終目標である個人で行う体幹トレーニン

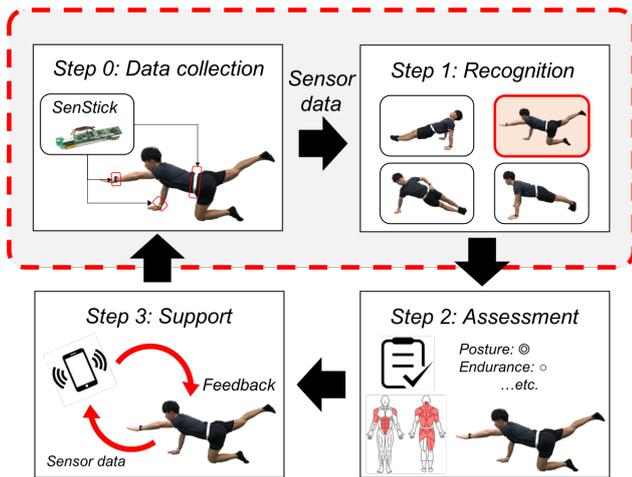


図 1: 体幹トレーニング支援システム

グ支援を実現するため、以下の4つの基本的なステップで構成される。

Step 0 : Data collection

身体に取り付けられた少数のウェアラブルデバイス内に搭載されたセンサ（加速度センサとジャイロセンサ）から体幹トレーニング中の姿勢情報を取得する。

Step 1 : Recognition

センサから得られるデータをもとに機械学習を用いて学習器を構築し、その学習器によって体幹トレーニング種目の自動認識を行う。

Step 2 : Assessment

認識された種目に対して、QoT(Quality of Training) 評価を行う。例えば、理想化された姿勢データセットからの逸脱をチェックする。または、センサデータから身体の震えを算出し、筋力や運動強度、そして疲労度などを推定・評価する。

Step 3 : Support

評価結果から個々に合った運動支援をデバイスを介して行い、人間のパーソナルトレーナーを人工知能的なエージェントに置き換える。例えば、姿勢の正誤判定結果から振動もしくは音声による姿勢改善フィードバックや、推定された筋力や疲労度からユーザの弱点を特定し、その部位を補うメニューを推薦する。

以上に述べた個人向け体幹トレーニング支援システムの実現に向けての第一段階として、本稿では Step 0 および Step 1 に焦点を当て、その提案手法および評価実験について述べる。

4. ウェアラブルデバイスによる体幹トレーニング種目認識手法

本章では、ウェアラブルデバイスによる体幹トレーニング種目認識手法の基本方針を述べると共に、体幹トレーニング種目や使用デバイス、装着位置の選定理由を記述し、サンプリング周波数や特徴抽出など体幹トレーニング種目

認識手法の詳細について記述する。

4.1 ウェアラブルデバイスによる体幹トレーニング種目認識手法の基本方針

体幹トレーニング種目を認識するには、トレーニング中の人間の動作を正確に認識する必要がある。これまで動作認識に利用可能な手法がいくつか提案されている。例えば、(1) 主に高速運動を伴うスポーツの動作計測への利用が試みられている光学式モーションキャプチャシステム [11] やデジタルビデオカメラを用いた DLT(Direct Linear Transformation Method) 法 [12], (2) 加速度センサやジャイロセンサなどの慣性センサをを身体部位に装着する方法がある。(1) は身体に何も装着する必要がなく計測を行える反面、システムが大規模かつ高コストになり、計測範囲も限定されるといった問題がある。一方、(2) は近年の MEMS (Micro Electro Mechanical Systems) 技術の発展に伴い、慣性センサの小型化、軽量化かつローコスト化が進み、今やスマートフォンやスマートウォッチなどのウェアラブルデバイスには標準搭載されているため、それらを用いれば簡易に動作計測が行えるといった利点を有する。そのため、本研究では、慣性センサを搭載したウェアラブルデバイスを用いて体幹トレーニング中の姿勢を計測し、得られる加速度やジャイロデータをもとに機械学習によって体幹トレーニング種目の認識を行う。

4.2 体幹トレーニング種目の選定

図 2 に、本研究において認識対象とする代表的な 7 種目 (計 10 パターン) の体幹トレーニングを示し、各種目に対応した筋肉への負荷部位も示す。0(P), 1(SAP), 8(HB) は主に腹筋群を鍛えられる種目であり、2(DR), 3(DL), 9(RP) は大臀筋や背筋などに効果的な種目であり、4(SPR), 5(SPL), 6(SASPR), 7(SASPL) は大腿四頭筋や三角筋に効果的な種目である [13], [14]。本研究において、これら 7 種目を選定する理由は、体幹トレーニングを始めたばかりの初心者から上級者までが一般的に行うトレーニング種目であり、また特定の筋肉に対する連続的な負荷を避け、過重負荷による怪我も防ぐことができる、非常に効果的な体幹トレーニングメニューであるためである。

4.3 使用センサデバイスと装着位置の選定

4.3.1 使用センサデバイス

体幹トレーニング種目を認識するためのセンサデバイスとして本研究では、筆者らが開発した SenStick[15] を使用する。SenStick は、8 種類の MEMS センサ (加速度、角速度、地磁気、温度、湿度、気圧、照度、紫外線) が搭載されており、最大 100Hz でロギングが可能である。そして、Bluetooth Low Energy (BLE) を介しデータを収集できる。本研究では、SenStick に搭載されている加速度とジャ

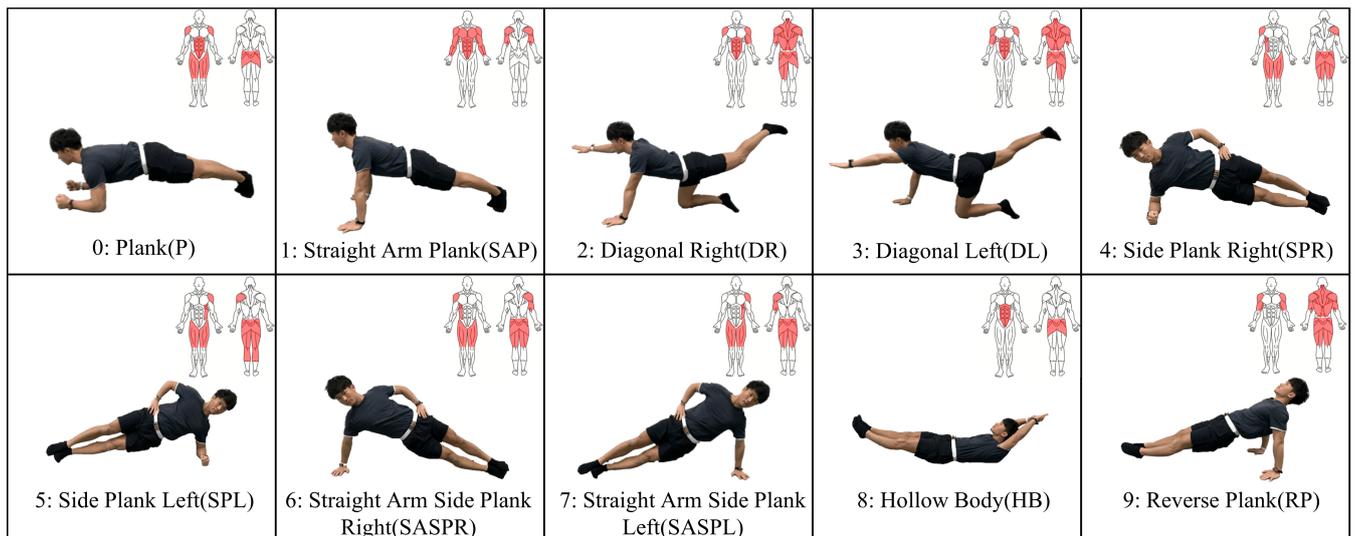


図 2: 体幹トレーニング種目

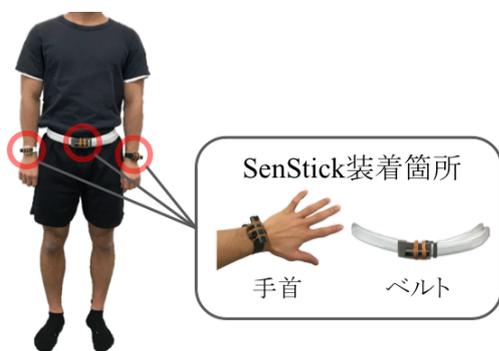


図 3: 装着の様子

イロセンサのみを使用して体幹トレーニング種目の認識を行うが、将来的には、温湿度センサ等の他のセンサから取得できるデータを組み合わせ、発汗量や体温の上昇による疲労度などの多次元コンテキスト情報も考慮したトレーニング評価を行う狙いがあることから、このようなマルチセンシングボードを採用している。

4.3.2 装着位置

体幹トレーニング中の姿勢を計測するにあたりセンサデバイスの装着位置が重要となる。近年、腕時計型やベルト型、眼鏡型など様々なウェアラブルデバイスが開発され一般的になってきている。本研究では、利用者の装着時の負担および運動への影響が少ないと考えられる手首と体幹トレーニング中の体幹部のブレを計測できると考えられるベルト位置に注目し、図3に示すように、SenStickを右手首(RW)、左手首(LW)、ベルト位置(B)の三箇所に装着して計測する。この方法により、種々の体幹トレーニング中における両手首および体幹(腰)の姿勢を反映できる。一例として、図4にSenStickによって計測されたDiagonal Right(DR)とSide Plank Left(SPL)における加速度波形を示す(上段: DR, 下段: SPL)。図4から加速度データ

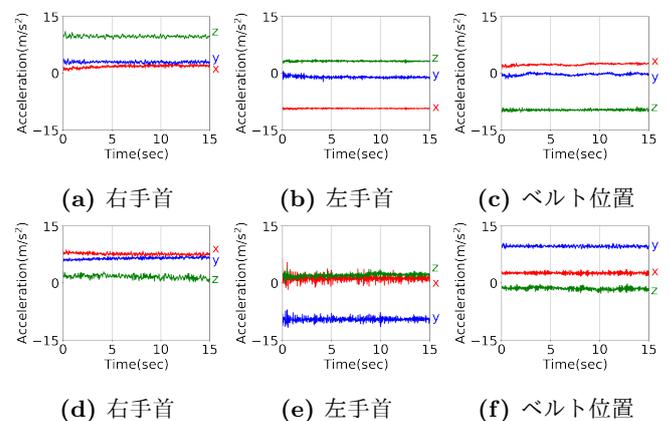


図 4: DR(上段), SPL(下段)における加速度波形(x, y, z軸はそれぞれ赤, 青, 緑で示す。以降、同様に使用する。)

は、体幹トレーニング時に生成されたほぼ一定の信号パターンを顕著に表しており、さらに異なるトレーニングでの姿勢変化も捉えられているため、体幹トレーニング種目をよりよく認識できることを示している。

4.4 体幹トレーニング種目認識に向けたデータ前処理

4.4.1 データ収集におけるサンプリングレート

本研究では、加速度およびジャイロデータから体幹トレーニング中の身体の震えも含めた生体情報を計測する必要がある。生体の振動には、電気的振動と機械的振動がある。電気的振動は脳波、筋電図、心電図などであり、機械的振動は震え(寒い部屋に居る場合や感情が高ぶった場合などに身体全体に起きる目に見える振動)、生理的振動(四肢および体幹に起きる目に見えない程度の小さい振動)、マイクロバイブレーション(瞼の上などから計測される皮膚表面上の目に見えない程度の振動)や筋音図(収縮時の筋肉における皮膚表面上の振動)など多く存在している。本研究が計測対象としている振動は身体の震え、つまり機械的振動で

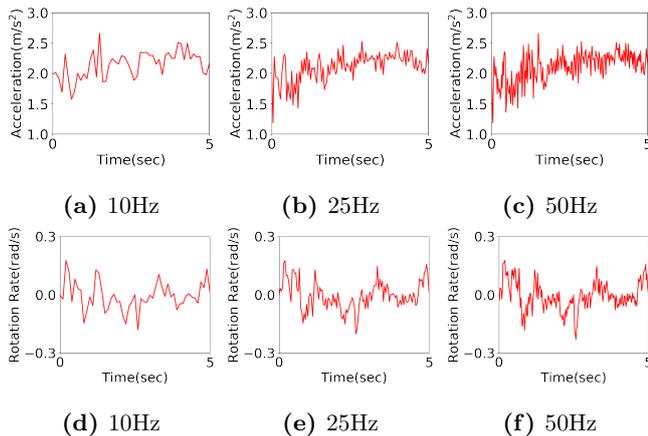


図 5: 各サンプリングレート時におけるベルト位置の x 軸加速度波形 (上段) とジャイロ波形 (下段)

あり, その主要周波数は 10Hz 前後とされている [16]. 標本化定理を考慮し, 体幹トレーニング時に発生した身体の震えを的確に捉えるには, およそ 20Hz 以上のサンプリングレートが必要である. そこで, 初めに 50Hz に設定し, 体幹トレーニング中の計測を行なったデータを 10, 25Hz にダウンサンプリングし, トレーニング中に発生する震えが的確に捉えられているかの確認を行なった. 図 5 に各サンプリングレート時におけるベルト位置の加速度波形とジャイロ波形を示す. 図 5(c), 5(f) から 50Hz の場合, 体幹トレーニング時に発生した身体の震えを顕著に表していると考えられる. これらを踏まえ, 加速度, ジャイロとも 50Hz で計測することとした.

4.4.2 特徴量抽出

SenStick からサンプリング周波数 50Hz で取得される加速度とジャイロデータに 1 秒のタイム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 [8], [17] によって述べられているように, 1 秒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と, 本研究ではリアルタイムの姿勢フィードバックも検討していることから, タイムウィンドウは 1 秒とする.

1 秒のタイムウィンドウで区切られた加速度, ジャイロデータから, 平均値, 最大値, 中央値, 最小値, 最大値と最小値の差, 合計値, 分散値の計 7 種類の特徴量を算出する. 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コンテキスト推定に関する先行研究から 7 種類の特徴量は有効性が示されているためである [18], [19].

4.4.3 機械学習手法

抽出された 7 種類の特徴量をもとに, 機械学習を用いた姿勢認識精度の評価を行う. 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] を用いる. scikit-learn は多数の機械学習アルゴリズムに基づく分類器を実装しており, 提案手法では, 代表的な機械

表 1: 被験者データ

Participant	Age	Weight(kg)	Height(cm)	Gender
A	23	70.00	172	Man
B	23	63.40	168	Man
C	23	73.70	170	Man
D	22	59.35	173	Man
E	23	58.20	172	Man
F	24	64.95	168	Man
G	24	54.25	172	Man
H	23	69.05	174	Man
I	30	67.85	171	Man
J	25	82.75	175	Man
K	24	88.00	182	Man
L	24	56.00	160	Man
M	26	60.25	173	Man
N	24	78.50	170	Man

学習アルゴリズムである, Random Forest(RF), Support Vector Machine(SVM), K-Nearest Neighbor(KNN), Convolutional Neural Network(CNN) の 4 つを用いる. そして, 標本から 1 つの事例を取り出して評価データとし, 残りを学習データとする. 全事例が 1 回は評価となるように検定を繰り返す Leave-one-person-out Cross-Validation により各種目の認識精度 (F 値) を評価する.

5. 評価実験

本章では, 右手首, 左手首, ベルト位置に装着された SenStick から収集される加速度とジャイロデータをもとに, 4 つの機械学習手法の性能比較および SenStick 装着位置別による種目認識の評価結果, トレーニング間の休憩中データも含む時系列データの適用について述べる.

5.1 機械学習手法および装着位置における認識精度の比較

本実験では, 各体幹トレーニング種目を行う前に写真による指導を受け, その後 15 秒の姿勢保持を各種目に対して 3 セット行う. 各セット間に 15 秒間の休憩を設けている. 被験者は 14 名とし (表 1), 全体として 6,300 秒の姿勢保持 (1 種目あたり 630 秒の姿勢保持) を記録している.

5.1.1 異なる機械学習手法による認識結果

表 2 に 4 つの異なる機械学習手法 (RF, SVM, KNN, CNN) での認識結果を示し, 図 6 に混同行列を示す. 最も認識精度が高いのは機械学習手法に Random Forest(RF) を用いた場合で F 値: 99.7% であり, 逆に最も認識精度が低かったのは機械学習手法に CNN を用いた場合で F 値: 99.2% である. Random Forest(RF) は多数の決定木を生成し, それら複数の決定木から多数決によって分類するアルゴリズムである. 決定木を弱学習機としているため, Random Forest(RF) はノイズに対して強いという特徴がある. よって, Random Forest(RF) を用いることで, 体幹

表 2: 4 つの学習器 (RF, SVM, kNN, CNN) での認識結果 (F 値)

Classifier	P	SAP	DR	DL	SPR	SPL	SASPR	SASPL	HB	RP	Average
RF	99.7%	99.8%	100%	99.7%	99.8%	99.4%	99.8%	99.2%	100%	100%	99.7%
SVM	97.7%	99.9%	99.8%	97.4%	99.9%	99.5%	99.9%	99.4%	100%	100%	99.4%
KNN	98.8%	99.9%	99.8%	98.6%	99.8%	99.6%	99.8%	99.5%	100%	100%	99.6%
CNN	97.1%	99.8%	100%	96.5%	99.8%	99.6%	99.6%	99.2%	99.9%	100%	99.2%

表 3: RF による SenStick 装着位置 (右手首 : RW, 左手首 : LW, ベルト位置 : B) 別での認識結果 (F 値)

Combination	P	SAP	DR	DL	SPR	SPL	SASPR	SASPL	HB	RP	Average
RW+LW+B	99.7%	99.8%	100%	99.7%	99.8%	99.4%	99.8%	99.2%	100%	100%	99.7%
RW+B	96.6%	79.7%	100%	74.5%	99.8%	88.9%	99.8%	88.4%	100%	100%	92.8%
LW+B	99.8%	83.2%	84.4%	99.8%	94.4%	99.4%	94.1%	99.3%	100%	100%	95.4%
RW+LW	99.8%	59.4%	99.9%	95.8%	96.2%	99.5%	92.7%	85.1%	99.9%	43.0%	87.1%
RW	68.7%	51.4%	99.8%	60.5%	68.7%	74.6%	69.9%	60.9%	99.8%	32.8%	68.7%
LW	79.1%	51.6%	55.1%	99.2%	80.2%	77.6%	73.2%	69.1%	99.8%	33.8%	71.9%
B	52.4%	49.7%	45.8%	26.9%	92.8%	88.1%	92.5%	87.2%	90.7%	90.5%	71.7%

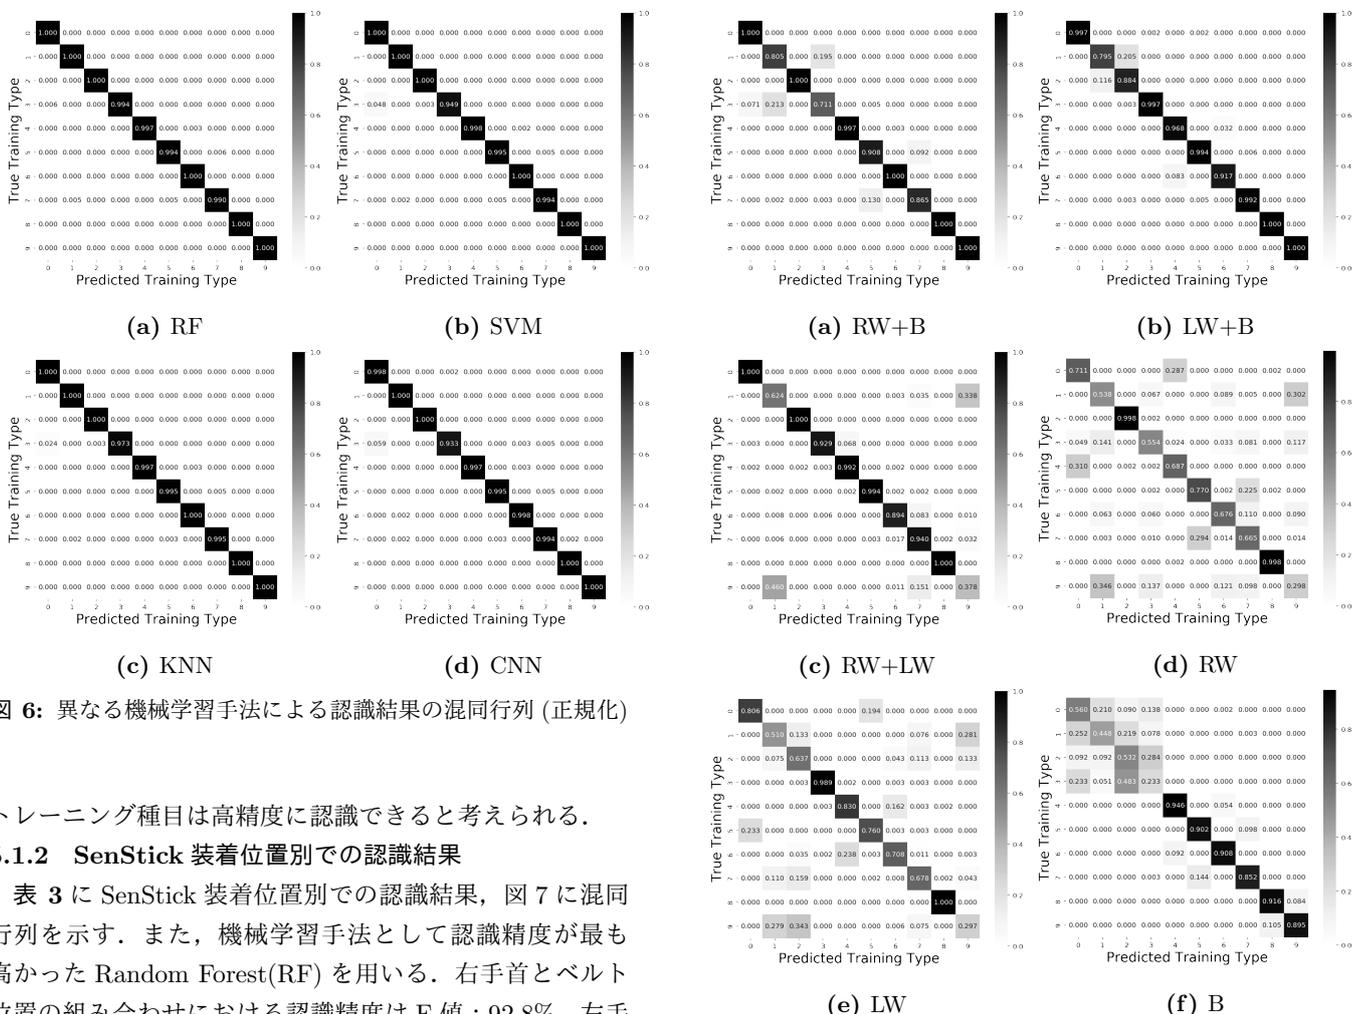


図 6: 異なる機械学習手法による認識結果の混同行列 (正規化)

トレーニング種目は高精度に認識できると考えられる。

5.1.2 SenStick 装着位置別での認識結果

表 3 に SenStick 装着位置別での認識結果, 図 7 に混同行列を示す. また, 機械学習手法として認識精度が最も高かった Random Forest(RF) を用いる. 右手首とベルト位置の組み合わせにおける認識精度は F 値 : 92.8%, 左手首とベルト位置の組み合わせにおける認識精度は F 値 : 95.4% である. よって今回の実験では, 片方の手首およびベルト位置にデバイスを装着するだけで F 値 : 94.1% の精度で認識できる. そのため, スマートフォンをベルト位置に, スマートウォッチを手首に装着すれば, 今回実施した体幹トレーニング種目を高精度に認識できることが示唆さ

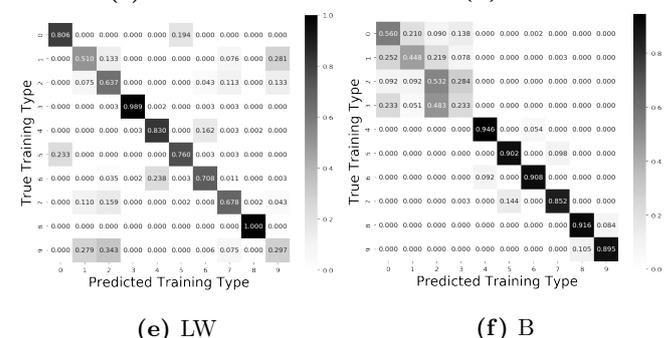


図 7: SenStick 装着位置別での認識結果の混同行列 (正規化)

れる. 次に, 左手首とベルト位置の組み合わせにおける種目別に認識精度を見ると, 1 (SAP), 2 (DR) の認識率が低いことがわかる. 理由として, これら 2 つの種目における手首の姿勢が酷似していたためと考えられる.

表 4: 時系列データを用いた認識結果 (F 値)

Classifier	P	SAP	DR	DL	SPR	SPL	SASPR	SASPL	HB	RP	No training	Average
RF	92.7%	95%	97.4%	100%	100%	90.9%	76.6%	75.5%	95.2%	86.4%	89.8%	90.3%

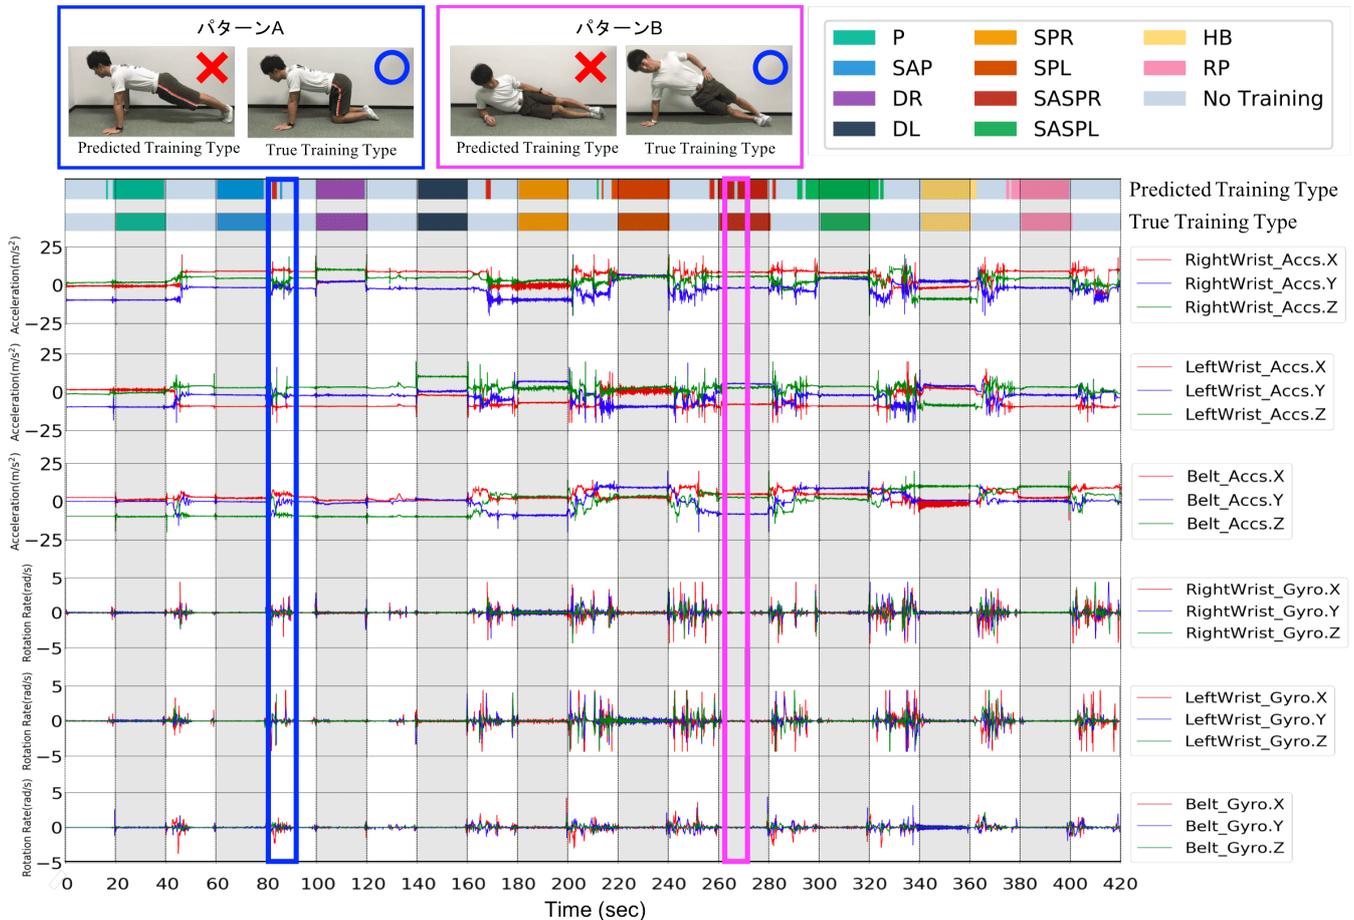


図 8: RF により予測されたトレーニングタイプとそれに対応した時系列波形

5.2 時系列データへの適用

本システムが実際の体幹トレーニングを行う流れにおいて実用性があるかどうかを評価するため、トレーニングの合間に休憩も挟んだ一連の行動下による評価実験を行う。被験者(年齢: 23 歳, 身長: 173cm, 体重: 70kg, 性別: 男性)は右手首, 左手首, ベルトに SenStick を装着し, 10 種の体幹トレーニング(図 2)をそれぞれ 20 秒間実施する。トレーニング間には, 20 秒間の休憩を設けることとする。

5.2.1 時系列データを用いた認識結果

5.1.1 項から認識精度が最も高かった Random Forest により構成された学習モデルを, 14 人の休憩時のデータ (No Training) も加えて再学習させ, 新たに作成した学習モデルを用いて評価を行う。表 4 にその認識結果を示す。認識結果は F 値: 90.3% であり, 休憩中のデータを学習させていない学習モデルによって求めた認識結果よりも低下することがわかる。図 8 は Random Forest (RF) に予測されたトレーニングタイプとそれに対応した時系列波形を示す。認識結果を見ると, 図 8 から以下に示す 2 つのパターン (A,

B) による誤認識があることがわかる。

パターン A: 休憩時を体幹トレーニング中と誤認識

パターン B: 体幹トレーニング中を休憩時と誤認識

図 9 は誤認識が発生した時刻におけるベルト位置の加速度波形を示す。図 9(a) はパターン A を表しており, 円で囲まれた波形を見るとトレーニング中から休憩に移る時に, 急激な加速度の変化が起こり, ピーク値を取っていることがわかる。よって, この急激な加速度の変化およびピーク値を検出すれば, パターン A による誤認識は改善できると考えられる。一方, 図 9(b) はパターン B を表しており, 円で囲まれた波形を見ると休憩からトレーニングに移る時に, 加速度の変化はある一定値に収束していることがわかる。よって, この加速度の収束を検出すれば, パターン B による誤認識は改善できると考えられる。また, このような誤認識を改善するには, LSTM (Long short-term memory) [21] のような時系列データのためのディープラーニング手法を用いることでトレーニング中か否かのセグメンテーション化もできる可能性があるため, 今後検討する。

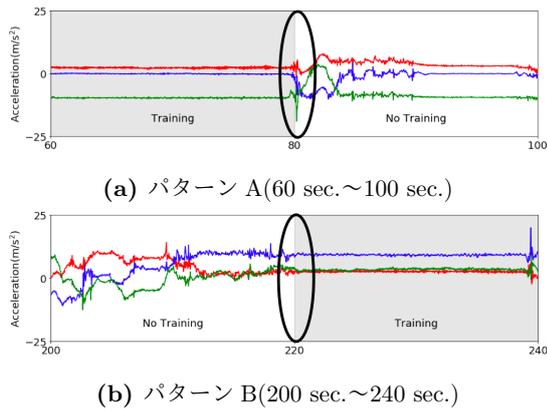


図 9: 誤認識が発生した時刻におけるベルト位置の加速度波形

6. まとめ

本稿では、パーソナルトレーナーが介入しない状況でも、より効果的な個人トレーニングが実施できるようにする体幹トレーニング支援システムの実現を目指し、第一段階として、体幹トレーニング支援に向けたウェアラブルデバイスによる種目認識手法を新たに提案した。提案手法の有効性を示すため、右手首、左手首、ベルト位置に取り付けられたウェアラブルデバイスから得られる加速度、ジャイロデータのみを使って、体幹トレーニングの種目認識を行なった。その結果、機械学習手法として Random Forest (RF) を用いた場合で F 値：99.7%と高精度に認識することに成功した。さらに、片方の手首およびベルト位置にデバイスを装着するだけでも F 値：94.1%の精度で認識できることを確認した。また時系列データへの適用では、休憩時を体幹トレーニング中と誤認識 (パターン A)、体幹トレーニング中を休憩時と誤認識 (パターン B) の2つのパターンによる誤認識があったことを確認した。

今後の展望として、(1) 装着部位として足首などを考慮した追加デバイスによる認識精度の向上、(2) トレーニング中か否かのセグメンテーション化の検討、(3) Step 2 および Step 3 の検討が挙げられる。

謝辞 本研究は、科学研究費補助金 26700007 および 15KK0011 の支援によって実施されている。

参考文献

[1] 総務省統計局：人口推計, <http://www.stat.go.jp/data/jinsui/pdf/201801.pdf> (2018).
 [2] 国立社会保障・人口問題研究所：人口問題研究資料第 336 号, http://www.ipss.go.jp/pp-zenkoku/j/zenkoku2017/pp29_ReportALL.pdf (2017).
 [3] 厚生労働省：介護保険事業報告書, <http://www.mhlw.go.jp/topics/kaigo/osirase/jigyom17/dl/1710a.pdf> (2017).
 [4] 藤本鎮也, 吉田一也, 佐藤慎一郎, 秋山純和：体幹と理学療法, 理学療法 - 臨床・研究・教育, Vol. 20, No. 1, pp. 7-14 (オンライン), DOI: 10.11350/ptcese.20.7 (2013).
 [5] Zimmerman, S., Greene, A., Sloane, P. D., Mitchell, M.,

Giuliani, C., Nyrop, K. and Walsh, E.: Preventing falls in assisted living: Results of a quality improvement pilot study, *Geriatric nursing*, Vol. 38, No. 3, pp. 185-191 (2017).
 [6] Suzuki, N. and Endo, S.: A quantitative study of trunk muscle strength and fatigability in the low-back-pain syndrome., *Spine*, Vol. 8, No. 1, pp. 69-74 (1983).
 [7] Um, T. T., Babakeshizadeh, V. and Kulic, D.: Exercise Motion Classification from Large-Scale Wearable Sensor Data Using Convolutional Neural Networks, *arXiv preprint arXiv:1610.07031* (2016).
 [8] Shen, C., Ho, B.-J. and Srivastava, M.: MiLift: Efficient Smartwatch-based Workout Tracking Using Automatic Segmentation, *IEEE Transactions on Mobile Computing* (2017).
 [9] Ding, H., Han, J., Shangguan, L., Xi, W., Jiang, Z., Yang, Z., Zhou, Z., Yang, P. and Zhao, J.: A Platform for Free-Weight Exercise Monitoring with Passive Tags, *IEEE Transactions on Mobile Computing*, Vol. 16, No. 12, pp. 3279-3293 (2017).
 [10] Zhou, B., Sundholm, M., Cheng, J., Cruz, H. and Lukowicz, P.: Never skip leg day: A novel wearable approach to monitoring gym leg exercises, *Pervasive Computing and Communications (PerCom), 2016 IEEE International Conference on*, IEEE, pp. 1-9 (2016).
 [11] Chen, H.-T., He, Y.-Z., Chou, C.-L., Lee, S.-Y., Lin, B.-S. P. and Yu, J.-Y.: Computer-assisted self-training system for sports exercise using kinects, *Multimedia and Expo Workshops (ICMEW), 2013 IEEE International Conference on*, IEEE, pp. 1-4 (2013).
 [12] 池上康男：DLT 法, *JJ Sport*, Vol. 10, No. 3, pp. 191-195 (1991).
 [13] Brumitt, J.: *Core assessment and training*, Human Kinetics (2010).
 [14] msn: ワークアウトとエクササイズを参照, Microsoft Network (オンライン), 入手先 (<https://www.msn.com/ja-jp/health/search/filter?gender=2>) (参照 2018-02-16).
 [15] 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).
 [16] 坂本和義, 清水豊, 水戸和幸, 高野倉雅人：生体のふるえと振動知覚メカニカルバイブレーションの機能評価, 初版. 東京都千代田区神田錦町, pp. 2-2 (2009).
 [17] 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).
 [18] Figo, D., Diniz, P. C., Ferreira, D. R. and Cardoso, J. M.: Preprocessing techniques for context recognition from accelerometer data, *Personal and Ubiquitous Computing*, Vol. 14, No. 7, pp. 645-662 (2010).
 [19] Pernek, I., Hummel, K. A. and Kokol, P.: Exercise repetition detection for resistance training based on smartphones, *Personal and ubiquitous computing*, Vol. 17, No. 4, pp. 771-782 (2013).
 [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] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural computation*, Vol. 9, No. 8, pp. 1735-1780 (1997).