

メニュー推薦に向けたセンサ取り付け位置に依存しない 自重トレーニング種目認識手法の提案

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

概要：老化防止や運動不足解消に効果を発揮する運動として，人工器具なしに個人でも比較的簡単に行うことのできるエクササイズである，自分の体重のみを負荷とした自重トレーニングが注目されている．自重トレーニングは特定の器具を用いるトレーニングと異なり，体勢を変えることで，さまざまな部位を鍛えることができ，そのトレーニング種目は50種類以上にもなる．そのため，その効果を最大限に発揮するには，パーソナルトレーナーによるトレーニング中の姿勢へのフィードバックやユーザに合ったメニュー推薦が重要となる．しかしながら，これまでの研究では，1日の運動量やユーザの運動強度などの個人特性，場所や時間といった環境を考慮した種目の推薦は行われていない．また，50種類の体勢に関して，ウェアラブルセンサの装着部位が与える影響の調査もなされていない．本研究では，これらの問題を解決するため，ウェアラブルコンピューティング環境下において，パーソナルトレーナーが介在しない状況でも，個人と環境に自己適応する自重トレーニングメニュー推奨システム (Ubi-Instructor) の実現を目指す．具体的には，Ubi-Instructor の実現に向けた第一段階として，ウェアラブルセンサによって普段の動きから歩行中のデータを抽出し，その歩行データから，ウェアラブルセンサの装着位置推定を行う．その提案手法の有効性を示すため，被験者10人による評価実験を行なった．機械学習手法として，Random Forest(RF)を用い，Leave-one-person-out Cross-Validationによりウェアラブルセンサの装着位置推定精度 (F 値) を評価した結果，F 値：90.0%と高精度に認識することに成功した．また1人の被験者から収集した自重トレーニングデータをもとに，50種類のトレーニング種目の識別器を作成し，トレーニングデータには用いていない別の1人の被験者を対象に，提案手法の有効性を確認した結果，提案手法を用いることで，鍛えたい部位とセンサの装着位置の両者を考慮して，ユーザの希望を叶えつつ，正確なトレーニング種目認識結果を記録できるシステムの実現可能性を示唆できた．

Position-independent Bodyweight Training Type Recognition for a Personalized Menu Recommendation

MASASHI TAKATA¹ YUGO NAKAMURA^{1,2} MANATO FUJIMOTO¹ YUTAKA ARAKAWA^{1,3}
KEIICHI YASUMOTO¹

1. はじめに

近年，我が国の運動不足は大変深刻化している．スポーツ庁による2万人を対象にした調査によると，「普段運動不足を感じるか?」という問いに対して，約7割の方が感じ

ると回答している [1]．また慢性的な運動不足は糖尿病や高血圧など，深刻な病気を引き起こす原因とされており，解決しなければならない大きな社会問題である．

そこで，我々は慢性的な運動不足問題を解決するための運動として，自分の体重のみを負荷とした自重トレーニングに注目している．自重トレーニングは，特別な人工器具なしに，自分の体重のみの負荷量で簡単に実践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 [2]．その効果を最大限に発揮するにはパーソ

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

ナルトレーナーによる、トレーニング中の姿勢へのフィードバックやユーザに合ったメニューの推薦、継続的な実施へのサポートが有効である。さらに、それらの継続的な運動は身心の健康維持・増進に繋がると広く認められ、慢性疾患、高血圧、糖尿病、アルツハイマー病などの生活習慣病を予防し、QoL(Quality of Service)向上に寄与する[3]。

現在では、モバイルデバイスの普及により多数のトレーニングアプリ(Freeletics Bodyweight[4]など)が提供され、これらのアプリケーションはアンケートベースによってカスタマイズされたトレーニングメニューを推薦し、エクササイズの詳細な説明を提供しているサービスも存在する。しかしながら、実際に1日の運動量やユーザの運動強度などの個人特性や場所・時間といった環境、ウェアラブルセンサの装着部位が与える影響などに適応した推薦は行っておらず、またトレーニング中のモニタリングや定性的評価などは提供していない。そのため、これらはモチベーション維持の低下やトレーニングの習慣化の欠落に繋がると考えられ、実行された運動が習慣化されずに短期間で終了してしまい、十分な効果を獲得できないといった問題が生じる可能性がある。したがって、個人でも質の高いトレーニングが実行でき、効果的なトレーニングの習慣化に向け、個人と環境に柔軟に自己適応し、よりユーザ目線でそれらを考慮可能なトレーニング支援システムが必要不可欠であると言える。

本研究では、これらの問題を解決するため、ウェアラブルコンピューティング環境下において、パーソナルトレーナーが介在しない状況でも、個人と環境に自己適応する自重トレーニングメニュー推奨システム、**Ubi-Instructor**の実現を目指す。具体的にはMAPE-Kモデル[5]に基づき、(1)ウェアラブルセンサによって普段の動きを監視(Monitor)する機構、(2)得られたセンサデータからウェアラブルセンサの装着位置および運動量を分析(Analyze)する機構、(3)特定された装着位置において、システム側が認識・評価できるトレーニングメニューをユーザの状態から計画(Plan)する機構、(4)ユーザに計画されたメニュー提示を実行(Execute)する機構、そして4つの機構を実行する際に必要な知識(Knowledge)から構成される。

本稿では、Ubi-Instructorの実現に向けた第一段階として、ウェアラブルセンサによって普段の動き(歩行や座位姿勢など)におけるセンサデータからコンテキスト推定をし、推定したコンテキスト情報とユーザの運動量からウェアラブルセンサの装着位置を推定する手法を新たに提案する。また、推薦対象の50種類(計61パターン)の自重トレーニングとウェアラブルセンサの装着位置との関係性を明確化する。本稿の貢献は以下の通りである。

- 第一に、ウェアラブルコンピューティング環境下において、パーソナルトレーナーが介在しない状況でも、個人と環境に自己適応する自重トレーニングメニュー

推奨システム(=Ubi-Instructor)の全体構想を明確化した。

- 第二に、普段の生活行動下から得られる時系列データから歩行動作を自動検出し、抽出された歩行データを元に、機械学習を用いてウェアラブルセンサの装着位置推定手法を提案した。
- 第三に、推薦する50種類(計61パターン)の自重トレーニングとウェアラブルセンサの装着位置との関係性を明確化し、位置推定に基づくトレーニング種目認識を提案した。

本稿の構成は以下の通りである。第2章では、トレーニングメニュー推薦支援に関する既存サービスおよびウェアラブルセンサを用いた運動支援に関する関連研究について述べる。第3章では、提案する自重トレーニングメニュー推奨システム(=Ubi-Instructor)の全体像について述べたのち、第4章でウェアラブルセンサの装着位置推定手法について述べ、第5章でその評価実験結果、および推薦する50種類(計61パターン)の自重トレーニングとウェアラブルセンサの装着位置との関係性について述べ、最後に第6章で本稿の結論および今後の課題を述べる。

2. 関連研究

本章では、トレーニングメニュー推薦支援に関する既存サービスおよびウェアラブルセンサを用いた運動支援に関する既存研究について述べる。

2.1 トレーニングメニュー推薦支援

現在オンライン上でパーソナルトレーナーの指導のもと、トレーニングが実行できるサービスが存在する[4], [6], [7]。これらの特徴として、まずStep1で年齢や性別、運動の状況などの基本情報やシェイプアップや筋肉アップなどの目的を入力する。Step2で専属のパーソナルトレーナーを選択する。Step3で重点部位やトレーニング可能時間・頻度、体力レベルなどのヒアリングを行い、その結果からユーザに最適なトレーニングメニューが推薦される。そしてStep4で推薦されたトレーニングを開始し、こなした分だけ手動で記録する。最後にStep5でトレーニングログを元にトレーナーがユーザに合ったメニューやアドバイスを提供する。これら全てのStepはスマートフォンアプリ上で実行できるため、好きな時間・好きな場所でPCやスマホを見ながら実行でき、仕事で忙しくてジムに行くことができないサラリーマンや主婦層向けのオンラインサービスである。しかし、運動の状況や体力レベルなどは主観的な入力によるもので、日常生活での行動、例えば1日どれくらい歩いたかやエレベーターを使わずに階段を使用した、またどれくらい座っていたかなどによって、その日の運動の状況を考慮したトレーニングメニューの推薦は行っていない。また、既存サービスは実行されたトレーニングが正




図 1: 自重トレーニングメニュー推薦システム

しい時間、フォームで行われているかまでは認識していないため、ただトレーニングメニューを推薦するだけで、トレーニング内容に対する専門的な指導は受けられない。さらに、前述のアプリケーションは、運動モニタリングの希薄な可能性しか提供せず、ユーザが運動を手動で開始/停止するか、運動タイプを選択するなど、ユーザに大きな負担がかかる。また実行されたトレーニングに関する定性的評価の可能性も提供しない。これはトレーニングの質の低下を招くとともに、継続性の欠落に陥り、途中でトレーニングをやめてしまうことに繋がる、さらには重大な傷害のような新たな問題を生じさせる。理由としては、トレーニングフォームの不当な伝達、ウォームアップの欠如である [8]。

2.2 ウェアラブルセンサを用いた運動支援

近年のウェアラブルコンピューティングの発展に伴い、ウェアラブル機器を用いてこれまでの運動をより効果的に行えるように支援する研究が多く行われている。Terry らは腕装着型ウェアラブルセンサ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 [9]。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 [10]。これによりユーザ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。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 [11]。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。

2.3 本研究の位置付け

上記で述べた関連研究 [9], [10], [11] はあくまでトレーニング種目の認識および特別な専用のウェアラブルセンサを用いた評価のみに止まっている。本研究では、個人トレーニングの質の向上と継続的な運動支援に向けて、年齢や性別、運動の状況などの個人情報とウェアラブルセンサの装着位置や居場所といったユーザの周りの環境に自己適応し、いつでもどこでも効果的なトレーニングが実行でき、そのトレーニングを認識し評価までを自動で行う Ubi-Instructor の構築を目指す点で既存研究とは異なる。

3. Ubi-Instructor

本章では個人と環境に自己適応する自重トレーニング推薦システムである Ubi-Instructor について説明する。近年のウェアラブルコンピューティングの発展により、腕時計型やメガネ型、ベルト型など、様々なウェアラブルセンサが登場してきている。そのため、ウェアラブルセンサ

を活用したトレーニングトラッキングシステムが開発され、ウェアラブルセンサから得られるセンサデータから実行したトレーニング種目を高精度に認識および評価できる [12], [13], [14].

ウェアラブルセンサは今後、様々な身体部位や人に着用されるものと考えられる。そこで、我々は個人の身長や体重、運動量、運動レベルなどの個人プロフィールへの適応と、ウェアラブルセンサの装着位置や場所といったユーザが置かれている環境への適応を可能とし、ユーザに最適な自重トレーニングメニューを推薦する自己適応型システムとして Ubi-Instructor を提案する。図 1 に提案する Ubi-Instructor の全体図を示す。このシステムによって、日常生活の中、例えば、昼休憩などの隙間時間などにおいて、最適な自重トレーニングメニューを組み込むことが可能となり、日々の運動不足解消に繋がると考えられる。さらに実行するトレーニングメニューを認識、評価し、そのフィードバックを行うことでトレーニング効果の向上とモチベーションの維持が期待できる。

3.1 全体概要

自己適応型システムは、実行時に起こる変化を検知し、要求を満たし続けるようシステムの構造・振る舞いを自身で変更するシステムである [15]。従って、自己適応型システムは、従来のアプリケーションロジックに加え、自己適応性のためのロジックを設計する必要がある。Ubi-Instructor は自己適応性ロジックをモデル化する手法として広く用いられている、Monitor-Analyze-Plan-Execute-Knowledge ループ (MAPE-K ループモデル) [5], [16] を採用する。

3.2 MAPE-K モデル

MAPE-K ループモデルは、Monitor, Analyze, Plan, Execute という 4 つのステップと、各ステップ実行に必要な知識を表す Knowledge で構成される [16]。各ステップの詳細は以下の通りである。

Step 1 : Monitor

Monitor 機構は、ウェアラブルセンサによって歩行や座位姿勢などの普段の動きを認識し、ユーザの状態を監視する機構である。

Step 2 : Analyze

Analyze 機構は、Monitor 機構で得られたセンサデータからその日、どれくらい歩いたか、どれくらい座っていたかなどのユーザ情報やウェアラブルセンサの装着位置および居場所など、ユーザが置かれている環境を分析する機構である。

Step 3 : Plan

Plan 機構は、Analyze 機構で分析されたユーザ個人とその環境にシステムが自己適応して、システムが自動で認識・評価できる自重トレーニングメニューを計画する機構

である。

Step 4 : Execute

Execute 機構は、ユーザに Plan 機構で計画された自重トレーニングメニューの提示を実行する機構である。

Knowledge

Knowledge は 4 つの機構を実行する際に必要な知識である。Ubi-Instructor において必要な Knowledge は (1) Monitor 機構で得られたセンサデータから歩行や座位姿勢といったユーザのコンテキストを推定し、かつその時のウェアラブルセンサの装着位置を推定するための知識、(2) Plan 機構で最適なトレーニングメニューを計画する際に必要となるトレーニング種目の知識である。例えば、手首とベルトにウェアラブルセンサを装着していた場合、ユーザに対して最適なトレーニングメニューであり、システムが自動でそれらのトレーニング種目を高精度に認識、評価ができるという事前知識が必要である。今回、図 2 に我々が提案する Ubi-Instructor において認識対象とした 50 種目 (計 61 パターン) の自重トレーニング種目を示し、各種目に対応した筋肉への負荷部位も示す。また、下線は左右のパターンがある種目、赤色は動きを伴うトレーニング、青色は静止姿勢を保つトレーニングを表す。本研究でこれら 50 種目を選定する理由は、自重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、非常に効果的な自重トレーニングメニューであるためである。

以上に述べた Ubi-Instructor の実現に向けての第一段階として、本稿では Step 1, Step 2 において、普段の動きからユーザが身につけているウェアラブルセンサの装着位置を推定する手法および Knowledge において、推定されたウェアラブルセンサの装着部位で高精度に認識できるトレーニング種目との関係に焦点を当て、その提案手法および評価実験について述べる。

4. ウェアラブルセンサの装着位置推定に基づくトレーニング種目選出/認識手法

図 3 に、提案手法であるウェアラブルセンサの装着位置推定に基づくトレーニング種目選出/認識手法の概要を示す。本手法では、(1) 対象ユーザが装着しているウェアラブルデバイスから収集される日常行動の時系列データから歩行動作を抽出し、(2) 抽出した歩行データからウェアラブルセンサの装着位置推定を行う。その後、(3) 推定されたウェアラブルセンサの位置とユーザの嗜好に応じたトレーニング種目の選出および推薦を行い、(4) 高精度なトレーニング種目認識および支援サービスをユーザに提供する。本章では、まず、(1)(2) に示したウェアラブルセンサの装着位置推定手法に関して詳述する。具体的には、



図 2: 自重トレーニング種目 (計 50 種類)

使用するウェアラブルセンサ，サンプリング周波数や特徴抽出などウェアラブルセンサの装着位置推定手法の詳細について記述する．その後，(3) (4) の実現に向けたデバイスの位置推定に基づくトレーニング種目選出/認識手法について記述する．

4.1 ウェアラブルセンサの装着位置推定の基本方針

ウェアラブルセンサの装着位置推定に関して，いくつかの関連研究がある．Vahdatpour らは頭部，胸部，上腕，前腕，腰部，大腿部，脛部の計 10 箇所にウェアラブルセンサを装着した状態で，歩行動作を含む大学内での日常行動を実行し，25 名の被験者から得られた 750 分の時系列データ

から歩行動作中のデータを抽出し，そのデータを基に，機械学習アルゴリズムとして Support Vector Machine (SVM) を用いた結果，84%の精度でウェアラブルセンサの装着位置を推定している [17]. Timo らは頭部，胸部，左上腕，左手首，腰部，前ポケット，左足首の計 7 箇所にウェアラブルセンサを装着した状態で，(1)Climb Up, (2)Climb Down, (3)Walk, (4)Run, (5)Jump, (6)Sit, (7)Stand, (8)Lie の 8 つの一般的な行動を実行し，15 名の被験者から得られた 1065 分の時系列データを基に，機械学習アルゴリズムとして Random Forest (RF) を用いた結果，84%の精度で 8 つの一般的な行動を推定することに成功し，ウェアラブルセンサの装着位置推定は 89%の精度で成功している [18].




図 3: ウェアラブルセンサの装着位置推定に基づくトレーニング種目選出/認識手法の概要




図 4: 装着の様子

本研究では、身体に取り付けられたウェアラブルセンサから得られる加速度、ジャイロデータを元に特徴量を抽出し、機械学習アルゴリズムとして関連研究で有効性が示されている Random Forest (RF) を用いて装着位置を推定する。

4.2 使用するウェアラブルセンサ

本研究では、装着位置を推定するウェアラブルセンサとして、著者らが開発した SenStick[19](図 4) を使用する。SenStick は、8 種類の MEMS センサ (加速度、ジャイロ、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 でロギングでき、Bluetooth Low Energy (BLE) を介しデータを収集できる。なお、SenStick を図 4 に示すように、(1) 頭部、(2) 胸部、(3) 左手首、(4) 右手首、(5) 腰部、(6) 前ポケット、(7) 後ろポケット、(8) 左足首、(9) 右足首の計 9 箇所 (可能な装着位置の全て) に取り付ける。本研究では、SenStick に搭載されている加速度センサ、ジャイロセンサのみを使用してウェアラブルセンサの装着位置推定を行う。

4.3 ウェアラブルセンサの装着位置推定に向けたデータ前処理

4.3.1 データ収集におけるサンプリングレートとタイムウィンドウ

本研究では、最終的にトレーニング種目の認識およびその評価までを行うことを目標としている。例えば、姿勢を一定時間静止するトレーニング時において発生する身体の震えなどを計測することで、その人の体幹力などを数値化することが挙げられる。これらを踏まえ、トレーニング中の細かな動きも正確に計測することが必要と考えるため、サンプリングレートは加速度、ジャイロとも 50Hz で計測することとする [14]。また、タイムウィンドウは慣性情報を用いて日常的な生活行動 (歩行や座位姿勢) のコンテキスト推定を行った先行研究 [18], [20] により有効性が示されていることから、1 秒と設定した。

4.3.2 特徴量抽出

ウェアラブルセンサの装着位置を推定するため、我々はユーザが特定のアクティビティを実行しているときの加速度、ジャイロデータを分析する。Welker らによる研究 [21] によると人々は平均的に、1 日あたり 8265 歩 (通常の日常活動のみを行う) とすることを示している。これは歩行動作であることを明確に示している (就寝や就寝などの非活動状態を除く)。したがって、歩行動作はウェアラブルセンサの装着位置推定のための特徴付ける動作として有効であると考えられる。しかし、身体上の加速度計の位置、配置、および向きは、事前に知られていない (および使用ごとに変わる可能性がある) ため、センサ上の身体運動パターンの投影は予測不可能である。したがって、得られる加速度データから式 1 を用いて合成加速度を算出し、正規化を行った。次に 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、合成加速度から、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[22].

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

4.3.3 機械学習手法

抽出された7種類の特徴量をもとに、機械学習を用いた歩行検出を行う。しかし、加速度、ジャイロ加速度計のすべての配置および位置に対して有効な歩行活動を検出するための一般的なモデルを定義することは不可能である。同じ理由から、活動検出の研究のすべては、加速度計の位置が既知であり、1つまたは数箇所限定されていると仮定している。本手法では、図3に示すように(1)時系列データ内に発生する歩行動作を教師なし学習手法によって検出し、(2)抽出した歩行データを元に再度機械学習を行うことで、ウェアラブルセンサの装着位置推定を行う。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[23]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、歩行検出、ウェアラブルセンサの装着位置推定とも、代表的な機械学習アルゴリズムである、Random Forest(RF)を用いる。評価方法として、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によりウェアラブルセンサの装着位置推定精度(F値)を評価する。

4.4 位置推定に基づくトレーニング種目選出/認識手法

本手法では、上述されたウェアラブルセンサの装着位置推定結果に基づいて、ユーザが鍛えたい部位をトレーニング可能かつ、ユーザが装着しているウェアラブルセンサの位置で認識が容易なトレーニングメニューを選出することによって、ユーザの要求を満たしつつも、質の高いトレーニング認識サービスの提供を行う。選出されたトレーニング種目の認識手法はウェアラブルセンサの装着位置推定と同様に各装着位置から得られる加速度、ジャイロデータ、合成加速度から、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。これらの特徴量を元に代表的な機械学習アルゴリズムである、Random Forest(RF)を用いる。トレーニング種目認識の評価に関しては、1人の被験者から作成された50種類(計61パターン)のトレーニング識別器を用いて、他の被験者が行ったトレーニングデータに対して認識を行う。次章では、本手法の妥当性を評価すべく、9カ所のウェアラブルセンサと50種類のトレーニング種目の相性を検証し、それぞれの認識精度を示す。

5. 評価実験

本章では、(1)頭部、(2)胸部、(3)左手首、(4)右手首、

表 1: 被験者データ

Participant	Age	Weight(kg)	Height(cm)	Gender
A	22	62.50	176	Man
B	25	72.40	183	Man
C	23	68.70	174	Man
D	22	78.35	176	Man
E	25	61.20	174	Man
F	24	62.95	173	Man
G	24	75.00	176	Man
H	23	68.05	174	Man
I	23	68.85	173	Man
J	25	45.00	160	Woman




図 5: 装着位置推定結果の混同行列 (被験者 C)

(5)腰部、(6)前ポケット、(7)後ろポケット、(8)左足首、(9)右足首の計9箇所に取り付けたSenStickから収集される加速度とジャイロデータをもとに、ウェアラブルセンサの装着位置推定結果および位置推定に基づくトレーニング認識について述べる。

5.1 実験内容

本実験では、図3において(1)歩行動作を検出するための学習モデルと(2)歩行中のデータからウェアラブルセンサがどこに装着されているかを推定する学習モデルが2つ必要である。そこで、図4に示すようにSenStickを身体に取り付けて、一般的な生活行動下におけるデータ収集実験を行った。具体的な行動として、(1)Climb Up、(2)Climb Down、(3)Walk、(4)Run、(5)Jump、(6)Sit、(7)Stand、(8)Lieの8種類を設定した。被験者10名(表1)による実験を行い、場所は大学構内とした。より現実的な条件、すなわち、被験者が行う各行動については、細かい指示はせず、どのくらい速く歩きたいか、どのように座りたいかなどは被験者に任せ、さらにスマートフォンの使用や、会話、飲食といっ

表 2: ウェアラブルセンサの装着位置推定結果 (F 値)

Participants	A	B	C	D	E	F	G	H	I	J	Average
Accuracy	94.6%	88.6%	97.1%	85.9%	91.7%	93.4%	87.9%	86.0%	98.2%	77.3%	90.0%

表 3: Glasses

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	JS	100	Leg	Dynamic
2	JJ	100	Arm	Dynamic
3	BJ	99.2	Hip	Dynamic
4	UD	95.9	Back	Static
5	CR	95.7	Leg	Dynamic
6	LT	95.2	Flank	Dynamic
7	GM	95.1	Back	Dynamic
8	CT	93.8	Flank	Dynamic
9	SPWHAL	92.7	Leg	Dynamic
10	SPWHAR	90.6	Leg	Dynamic

表 7: Belt

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	OHSAPR	100	Arm	Static
2	OHSAPL	100	Arm	Static
3	HB	100	Back	Static
4	SPL	100	Arm	Static
5	SASPL	100	Leg	Static
6	PJ	100	Arm	Dynamic
7	CFLRR	100	Leg	Dynamic
8	UD	100	Back	Static
9	SPWHAL	100	Arm	Static
10	OLSAPL	100	Leg	Static

表 4: Chest

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	HB	100	Abdominal	Static
2	UD	100	Back	Static
3	OHSAPR	99.2	Arm	Static
4	OHSAPL	99.2	Arm	Static
5	SPWHAR	99.2	Leg	Dynamic
6	RP	99.2	Back	Static
7	CD	97.6	Arm	Dynamic
8	PJ	97.6	Flank	Dynamic
9	JS	97.6	Leg	Dynamic
10	KT	97.6	Abdominal	Dynamic

表 8: Front Pocket

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	AC	100	Arm	Dynamic
2	OLRPL	100	Arm	Static
3	CD	100	Arm	Dynamic
4	SCS	100	Chest	Dynamic
5	SASPR	100	Flank	Static
6	SASPL	100	Flank	Static
7	DL	100	Back	Static
8	SAP	99.2	Chest	Static
9	CP	99.2	Abdominal	Static
10	HL	99.2	Hip	Static

表 5: Left Wrist

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	SCS	100	Chest	Dynamic
2	CD	99.2	Arm	Dynamic
3	GM	98.4	Back	Dynamic
4	JJ	98.3	Arm	Dynamic
5	SPWHAR	97.6	Leg	Dynamic
6	AC	96.8	Arm	Dynamic
7	JS	96.7	Leg	Dynamic
8	S	96.0	Back	Dynamic
9	OHSAPL	95.9	Arm	Static
10	MC	95.2	Abdominal	Dynamic

表 9: Back Pocket

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	JJ	100	Arm	Dynamic
2	HL	100	Hip	Static
3	OHSAPL	100	Arm	Static
4	CFLRL	100	Hip	Dynamic
5	UD	100	Back	Static
6	S	100	Back	Dynamic
7	SPL	99.2	Flank	Static
8	PJ	99.2	Abdominal	Dynamic
9	BS	98.3	Leg	Dynamic
10	BKL	97.6	Hip	Static

表 6: Right Wrist

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	OHSAPL	100	Arm	Static
2	CSAP	100	Chest	Static
3	SCS	100	Chest	Dynamic
4	RC	100	Abdominal	Static
5	JS	100	Leg	Dynamic
6	AC	99.2	Arm	Dynamic
7	HB	98.4	Abdominal	Static
8	JJ	98.3	Arm	Dynamic
9	LT	98.3	Flank	Dynamic
10	CT	97.6	Flank	Dynamic

表 10: Left Ankle

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	AC	100	Arm	Dynamic
2	PPU	100	Arm	Dynamic
3	OHSAPL	100	Arm	Static
4	PU	100	Chest	Dynamic
5	RC	100	Flank	Static
6	DR	100	Flank	Static
7	DL	100	Back	Static
8	BKR	99.2	Chest	Static
9	BKL	99.2	Abdominal	Static
10	CC	99.2	Hip	Static

た行動も伴う中でデータ収集を行った。しかし、各行動が実行される前後に数秒間アイドル状態になるように指示する。サンプリングレート 50Hz で得られた計 638 分の時系

列データから 1 秒のタイムウィンドウによって取り出し、7 種の特徴量を元に Random Forest(RF) を用いて、歩行検出のための学習モデルと歩行中のデバイスの装着位置を

表 11: Right Ankle

Ranking	Training Name	F1-score	Target Muscle	Training Type
1	HB	100	Abdominal	Static
2	SCS	100	Chest	Dynamic
3	SASPR	100	Flank	Static
4	BKR	100	Hip	Static
5	RP	100	Back	Static
6	SS	100	Back	Dynamic
7	UD	99.2	Back	Static
8	JJ	99.2	Arm	Dynamic
9	OHSAPR	99.2	Abdominal	Static
10	OLRPR	99.2	Abdominal	Static

推定するための学習モデルを生成する。

次に、位置推定に基づくトレーニング認識の実験も行う。具体的には、先ほどと同様に図 4 に示すように、SenStick を身体に取り付けた状態で、図 2 に示す 50 種類 (計 61 パターン) のトレーニング種目を被験者 1 名 (23 歳, 男性, 174cm, 66kg) が各トレーニング 20 秒を 3 セット行い、各セット間で Cross-Validation を適応させて、ウェアラブルセンサの装着位置と認識できるトレーニング種目との相性を確認する。次に、得られたセンサデータからトレーニング種目の識別器を作成する。この際、サンプリングレート、タイムウィンドウ、用いる特徴量は全て同じものとする。

5.2 ウェアラブルセンサの装着位置推定結果

5.1 節で Random Forest により構成された学習モデルの性能評価を行うため、Leave-one-person-out Cross-Validation により求めた。具体的には、10 人のうち一人をテストデータとし、他の 9 人で 2 つの学習モデルを作成する。その学習モデルを用いて、テストデータから (3)Walk の部分を抽出する。抽出された後、別の学習モデルによって、ウェアラブルセンサの装着位置推定を行う。最後に、全員がテストデータになるように振り分けられ、最終評価値としては、F 値の平均とする。

表 2 に各被験者それぞれがテストデータになった時の F 値とそれらの平均を表す。最大精度は被験者 C がテストデータの時に F 値 : 97.1%, 一方、最低精度は被験者 J で F 値 : 77.3% であった。この理由として、被験者 J は実験参加者のなかで、唯一の女性であり、体格の差によるものだと考えられる。また、図 5 に被験者 C がテストデータの時の混同行列を示す。比較的に高精度に装着位置を推定できていることがわかる。しかし、前ポケット (Front Pocket) と後ろポケット (Back Pocket) の精度が低い。この原因として、ポケット内で SenStick が動いてしまったためと考える。このような誤認識を改善するには、LSTM(Long short-term memory)[24] 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精度向上に繋がると考える。

5.3 位置推定に基づくトレーニング認識結果

表 3 から表 11 にウェアラブルセンサの装着位置と認識

できるトレーニング種目との関係を示す。F 値が最も高いトレーニング種目をランキング順に並べ、またそのトレーニング種目によって鍛えられる身体部位、動静的かの区別も表す。表からユーザにトレーニング種目を推薦する際、これらの Knowledge に基づき推薦することで、センサ取り付け位置に依存しないメニュー推薦が可能になると考えられる。

次に、今回の提案手法が有効かどうかを確認するため、1 人の被験者 (25 歳, 男性, 174cm, 62kg) を対象に、SenStick を右手首と前ポケット、右足首に取り付けた状態で、事前のアンケートによるユーザが希望する鍛えたい部位をターゲットにし、ランダムに推薦したトレーニングメニュー 10 種類と先ほどの装着部位に基づくトレーニング認識結果において、ユーザの希望に合う種目かつ高精度に認識できる種目を推薦したトレーニングメニュー 10 種類での認識比較実験を行った。

表 12, 表 13 にそれらの結果を示し、図 6 に混同行列を示す。ランダムで推薦したトレーニングメニューの認識精度は F 値 : 76.2%, 提案手法の方で推薦したトレーニングメニューの方の認識精度は F 値 : 94.6% で、提案手法の方が 18.4% となった。したがって、提案手法により、鍛えたい部位とセンサの装着位置の両者を考慮して、ユーザの希望を叶えつつ正確な認識結果を記録できるシステムの実現が可能であることが示唆された。さらに、提案手法を用いることで、その人に必要な種目の組み合わせに沿ったセンサの装着位置の推薦も可能である。

6. おわりに

本稿では、パーソナルトレーナーが介在しない状況でも、より質の高い個人トレーニングが実施できるようにする自重トレーニング支援システム (Ubi-Instructor) を提案した。第一段階として、一般的な生活行動である歩行中のデータからウェアラブルセンサの装着位置を推定し、推定された位置に応じた自重トレーニングメニューをユーザに推薦する手法を提案した。提案手法の有効性を示すため、(1) 頭部, (2) 胸部, (3) 左手首, (4) 右手首, (5) 腰部, (6) 前ポケット, (7) 後ろポケット, (8) 左足首, (9) 右足首の計 9 箇所にウェアラブルデバイスを取り付けた状態で、(1)Climb Up, (2)Climb Down, (3)Walk, (4)Run, (5)Jump, (6)Sit, (7)Stand, (8)Lie の 8 つの行動を実行し、得られた加速度、ジャイロの時系列データから初めに歩行検出を行う。そして抽出された歩行データを用いて、ウェアラブルセンサの装着位置推定を行った。その結果、機械学習手法として Random Forest(RF) を用いた場合、F 値 : 90.0% と高精度に認識できることを明らかにした。


また、ウェアラブルセンサの装着位置と 50 種類 (計 61 パターン) の自重トレーニングとの関係性について、被験者 1 人から収集したデータをもとに、表 3 ~ 表 11 に示す

表 12: ランダム選出によるトレーニング認識結果 (F 値)


Training Name	CPU	JJ	ETK	DR	DL	KT	JSU	SU	SPL	PU	Average
Accuracy	97.4%	33.3%	64.5%	57.1%	100%	95.2%	85.7%	46.5%	94.7%	87.0%	76.2%

表 13: 提案手法によるトレーニング認識結果 (F 値)

Training Name	SCS	CD	S	RC	AC	SS	SASPR	SASPL	CT	DL	Average
Accuracy	97.6%	81.6%	90.9%	100%	100%	88.9%	87.0%	100%	100%	100%	94.6%



(a) ランダムに選出



(b) 提案手法による選出

図 6: トレーニング認識結果の混同行列

ような関係性を確認した。全ての装着位置において、対応する筋肉部位、トレーニングタイプに関してほぼ網羅していることがわかる。さらに、提案手法が有効かどうかを確認するため、収集した自重トレーニングデータをもとに、トレーニング種目の識別器を作成し、1人の被験者を対象に、

SenStick を右手首と前ポケット、右足首に取り付けた状態で、事前のアンケートによるユーザが希望する鍛えたい部位をターゲットにし、ランダムに推薦したトレーニングメニュー 10 種類と先ほどの装着部位に基づくトレーニング認識結果において、ユーザの希望に合う種目かつ高精度に認識できる種目を推薦したトレーニングメニュー 10 種類での認識比較実験を行った。その結果、提案手法を用いることで、鍛えたい部位とセンサの装着位置の両者を考慮して、ユーザの希望を叶えつつ、正確な認識結果を記録できるシステムの実現が可能であることが示唆された。

今後の展望として、(1) 今回、自重トレーニングのデータセットとして 1 人分しか収集できなかったため、より汎用性のある識別器を作成させるため複数人によるデータ収集を行う (2) Step 3 および Step 4 の検討が挙げられる。

謝辞 本研究の一部は、JST さきがけ「行動認識と行動介入による情報駆動型社会システムの実証」(16817861) の支援により実施した。

参考文献

- [1] 総務省統計局：人口推計，http://www.mext.go.jp/prev_sports/comp/b.menu/other/_icsFiles/afieldfile/2017/02/15/1382031_001.pdf (2018).
- [2] Lauren, M.: *Fit ohne Gerte: Trainieren mit dem eigenen Krpergewicht*, Riva (2011).
- [3] Radak, Z., Hart, N., Sarga, L., Koltai, E., Atalay, M., Ohno, H. and Boldogh, I.: Exercise plays a preventive role against Alzheimer's disease, *Journal of Alzheimer's disease*, Vol. 20, No. 3, pp. 777–783 (2010).
- [4] Freeletics GmbH: Freeletics Bodyweight, <https://www.freeletics.com/ja>.
- [5] Kephart, J. O. and Chess, D. M.: The vision of autonomic computing, *Computer*, Vol. 36, No. 1, pp. 41–50 (2003).
- [6] Sony Network Communications Inc.: ソネットパーソナルトレーニング，<http://www.so-net.ne.jp/training/sonetore/>.
- [7] 株式会社ボディクエスト：bodyquest, <http://bodyquest.jp/>.
- [8] Jones, B. H., Bovee, M. W., Harris III, J. M. and Cowan, D. N.: Intrinsic risk factors for exercise-related injuries among male and female army trainees, *The American Journal of Sports Medicine*, Vol. 21, No. 5, pp. 705–710 (1993).
- [9] 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).

- [10] Shen, C., Ho, B.-J. and Srivastava, M.: MiLift: Efficient Smartwatch-based Workout Tracking Using Automatic Segmentation, *IEEE Transactions on Mobile Computing* (2017).
- [11] 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).
- [12] Vimo Labs Inc.: VimoFit, <http://www.vimofit.com/>.
- [13] Morris, D., Saponas, T. S., Guillory, A. and Kelner, I.: RecoFit: using a wearable sensor to find, recognize, and count repetitive exercises, *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, ACM, pp. 3225–3234 (2014).
- [14] 高田将志, 中村優吾, 藤本まなと, 荒川 豊, 安本慶一: 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, 177 回ヒューマンコンピュータインタラクション研究会, No. 20, pp. 1–8 (2018).
- [15] Krupitzer, C., Roth, F. M., VanSyckel, S., Schiele, G. and Becker, C.: A survey on engineering approaches for self-adaptive systems, *Pervasive and Mobile Computing*, Vol. 17, pp. 184–206 (2015).
- [16] 鄭 顕志, 清水 遼, 高橋竜一, 石川冬樹: 自己適応ソフトウェアのための自己適応性設計に関する研究動向, コンピュータソフトウェア, Vol. 31, No. 1, pp. 1.49–1.59 (2014).
- [17] 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).
- [18] Szttyler, T., Stuckenschmidt, H. and Petrich, W.: Position-aware activity recognition with wearable devices, *Pervasive and mobile computing*, Vol. 38, pp. 281–295 (2017).
- [19] 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).
- [20] Weiss, G. M. and Lockhart, J. W.: The impact of personalization on smartphone-based activity recognition, *AAAI Workshop on Activity Context Representation: Techniques and Languages*, pp. 98–104 (2012).
- [21] Welk, G. J., Differding, J. A., Thompson, R. W., Blair, S. N., Dziura, J. and Hart, P.: The utility of the Dig-walker step counter to assess daily physical activity patterns., *Medicine and science in sports and exercise*, Vol. 32, No. 9 Suppl, pp. S481–8 (2000).
- [22] 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).
- [23] 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).
- [24] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural computation*, Vol. 9, No. 8, pp. 1735–1780 (1997).