

懸垂マシンを用いた筋トレにおける デバイスフリー種目推定

難波 洸也¹ 中村 優吾¹ 荒川 豊¹

概要：

本論文では、家庭内での効果的な筋トレとして懸垂マシンに着目し、習慣化を促すための運動記録システムを提案する。提案システムは、懸垂マシン本体に加速度センサを内蔵し、その揺れ具合からトレーニング種目を自動判定する。今回、加速度センサを3箇所に着した懸垂マシンを開発し、8名の被験者に協力してもらい、評価実験を行った結果を報告する。評価実験では、各被験者にぶら下がり、懸垂、レッグレイズ、腕立て伏せの4種目を行ってもらい、その際に得られた時系列加速度データに機械学習を適用することで、種目判定モデルを構築する。その結果、上部に着した加速度センサによる判定精度が高いこと、機械学習アルゴリズムの中でも Logistic Regression が Leave One Person Out (LOPO) において、正解率：0.776、F 値：0.775 と高い精度となることを明らかにした。

1. 背景

近年では健康に関する意識や関心が高まってきている。また昨年のコロナウイルス感染症の拡大以降、家で過ごす時間が増えたこともあり、運動に気を遣う人も増えてきた。しかし、実際に運動を日々の生活に取り入れ習慣化している人は増えていない。また在宅ワークの普及により、会社に通勤することがなくなり体力の低下を感じている人も多い。運動を習慣化することの重要性は理解しているものの、行動に移せる人は実際には少ないことがわかる。

習慣化ができない理由は様々なことが考えられるが、その1つは変化を感じることができないからである。運動の場合には、大きく分けて3つの変化が存在する。1つ目は身体の見た目の変化、2つ目は身体の内部的変化（体重や筋肉量）、3つ目はトレーニングメニューの変化である。これら3種類の変化の中で最も難しいことは外見の変化である。外見の変化は、トレーニングだけではなく、食事など別の要因にも左右され時間が最もかかる変化である。一方、身体の内部的変化やトレーニングメニューの変化は外見の変化に比べると容易である。よって、体重や筋肉量、どのようなトレーニングをどれだけの回数こなしたかを記録し続ければ習慣化できる可能性が生まれる。しかし、毎日記録を取り続けることも意外と難しい。運動を習慣化するためには、トレーニング内容や体重などの記録を取り続けることも習慣化しなければいけなくなり、これらを続け

ることができずに運動を習慣化できない人も意外と多いように思われる。

1.1 本研究の対象とするトレーニング

本研究では、上記の問題に取り組むために一般化家庭内でできそうな運動を記録し、トレーニング内容を推定する手法を提案する。はじめにどのトレーニングを記録することが在宅ワークを求められ、運動不足になった人に必要であるか考える。最初に思いつくのは、本格的なトレーニングセットを導入し、全身をトレーニングすることである。しかし、金銭的にも面積的にも本格的なマシンを導入することは困難である。そうすると家庭内で行うことができる運動は大きく分けて2つの選択肢しか存在しない。1つ目は自分の体重を用いて行うトレーニング、2つ目は簡易器具を用いて行うトレーニングである。

1つ目の自重運動はコスト、トレーニングできる部位を考慮すると良い選択肢である。しかし、自重運動のほとんどは横たわった姿勢で行うため、器具を使わずとも面積は必要となる。また、自重運動は正しいフォームで行わないとトレーニングの効果を発揮することができないため効率も良くないといえる。さらに正しいフォームでトレーニングを行っていないと最悪の場合には怪我につながってしまう。これらのことを考慮すると、日々の生活に導入しやすいとは言えない。

2つ目の簡易器具を用いたトレーニングは用いる器具によって様々な方法が考えられる。器具の種類としては、バ

¹ 九州大学, Kyushu University

表 1 簡易器具の種類と特徴

簡易器具	コスト	面積	対象部位	効率	導入
バランスボール	低	小	腹, 脚	悪	簡単
ゴムバンド	低	小	背中, 脚	普	簡単
ローラー	低	小	胸, 腹	普	簡単
懸垂マシン	中	小	胸, 背中, 腹, 脚	良	簡単
ダンベル	中	小	腕	良	難しい
自転車	高	大	脚	普	難しい

ランスボール, ゴムバンド, ローラー, 懸垂マシン, ダンベル, 自転車がある. これらの中からコスト, 器具の設置面積, トレーニングできる部位と効率, 生活への導入のしやすさを考慮してコロナ禍でも健康的に家庭内で運動できるトレーニングを考える. バランスボールやゴムバンド, ローラーは低コストであり, 設置面積も小さく, 日々の生活に取り入れやすい. しかし, これらの器具は特定の部位に向けた簡易器具であるためトレーニングできる部位が少ない. ダンベルは使い方によって様々な部位をトレーニングすることができ, 効率も良い. しかし, コストが高いのと万が一床に落としてしまった時の修理費用は相当な金額になる. また, ダンベルの重量などを決めることは初心者には難しく, 日々の生活に導入しやすいとは言えない. 自転車はコストが高く, 設置面積も大きい. また, 脚は本格的に鍛えることができるかもしれないが, それ以外の部位をトレーニングすることは困難である. 最後に懸垂マシンは少しコストが高いが, 設置面積は垂直に立っているためそこまで大きくない. また, 1台で胸筋, 腹筋, 背筋そして脚までを効率よくトレーニングすることができる. さらに, 10秒ぶら下がるだけでも十分な効果があるため, 初心者でも扱いやすい器具と言える. 表1に, それぞれの器具と特徴についてまとめる. これらのことを考慮すると, 低コストで設置面積も少ないにもかかわらず, 全身トレーニングを効率よく行うことができるのは懸垂マシンであることがわかる. そこで本研究は, 懸垂マシンを用いた筋トレに焦点を当てる.

1.2 懸垂マシンにおけるの種目推定手法の検討

懸垂マシンを用いた筋トレを測定し推定する手法として, まず思いつく手法は, ウェアラブルデバイスを用いる方法である [1]. この方法は, Fitbit や Apple watch などのデバイスを手首につけ, そこから得た情報をもとにトレーニング種目の推定や繰り返し回数の推定・測定を行う. しかし, これらのデバイスを装着してトレーニングをすることは普段から運動をしていない人には煩わしいことであり, 何もつけずにトレーニングをできる方が良い. 次に考えられる方法としては, カメラを用い, 画像データからトレーニングの記録を行う方法である [2]. しかし, 画像を用いた手法は処理負荷が高く, 種目識別のためだけにパソコンを用意する必要がある. また, 懸垂マシンの全景を写すにはある

程度距離のあるところから撮影する必要もあり接地面積が狭いという特徴を台無しにしてしまう. また, 家庭によって設置箇所が異なるため, 光の強さや画角が変わり, 設置場所毎に学習し直さないといけない可能性ある. また, 別の方法として, WiFi の CSI(Channel State Information) を観測する手法があるが, 一般家庭の CSI の観測は不可能である上, 他の物体の動きにも左右されるため家庭内での利用は難しい.

そこで, 本研究では, 懸垂マシンにセンサを装着し, 器具の揺れ具合から, ユーザのトレーニング種別を識別する手法を提案する. 懸垂マシンに装着するセンサは, 小型の加速度センサであり, コストや接地面積の観点での影響は殆どなく, 懸垂マシンの追加オプションになりうると考えている. ユーザはこれまで通り懸垂マシンを利用するだけで, 運動記録が残るようになる.

今回, 研究室内にセンサを装着した懸垂マシンを設置し, 8名の被験者(21歳から23歳)による評価実験を行った. 被験者には, ぶら下がり, 懸垂, レッグレイズ, 腕立て伏せの4種目を行ってもらった. 加速度センサは, 適切な設置箇所の検討もおこなうため, 懸垂マシンの上部, 中部, 下部の3箇所に装着した. そして, 時系列センサデータに対して, 機械学習(Logistic Regression)を適用し, 筋トレ種目の推定モデルを構築した. 10分割交差検証(10 fold cross validation)を用いて被験者依存の推論モデルの精度を検証した結果, 正解率: 0.760, F 値: 0.760, Leave One Person Out (LOPO)を用いて被験者非依存の推論モデルの精度を検証した結果, 正解率: 0.776, F 値: 0.775で推定できることを確認した. 他の機械学習アルゴリズムでも同様に検証を行ったところ, 被験者依存の推論モデルは, ANN, LR, RF で 75 %以上の精度が確認できた. 被験者非依存の推論モデルは, ANN, LightGBM, LR, RF で 75 %以上の精度が確認できた. また, 加速度センサの設置箇所により異なる結果を得た. 機械学習(Logistic Regression)を適用し, 10分割交差検証(10 fold cross validation)を用いて検証を行なった結果, 上部に設置した場合, 正解率: 0.760, F 値: 0.760, 中部に設置した場合, 正解率: 0.659, F 値: 0.659, 下部に設置した場合, 正解率: 0.660, F 値: 0.662となった. これより上部に設置した場合が最も精度が高いことが確認できた.

2. 関連研究

本章では, 筋トレ種目の推定の関連研究について述べる. 筋トレの種目や場所, 用途などによって様々な手法が提案されており, これらの多くは (1) ウェアラブル端末を用いて, 人に身につけることによって測定し, 推定する手法, (2) カメラを用いて, 画像から推定を行う手法, (3) 電波(WiFi)を用いて, 測定し推定する手法の3つに分けることができる. 以下の節では, 各手法について述べる.

2.1 ウェアラブルベース

ウェアラブル端末を用いた手法は、現在最も広く研究されている。

Chang らは、フリーウェイトエクササイズの種類と繰り返しを回数測定するためのウェアラブルソリューションを提案した [1]。RecoFit [3] は腕装着型慣性センサーに基づくウェアラブルシステムでもあり、運動期間と非運動期間を区分することができ、様々な筋力トレーニング運動を検出することができる。高田らは、器具を使用しない自重トレーニングに着目し、ウェアラブルセンサ位置ごとに 10 種類の運動の認識精度を調査した [4]。これらウェアラブル端末ベースの手法は、詳細な情報を正確に集めることができる。しかし、トレーニングを行う際にはウェアラブル端末を身につける必要があり、日々のトレーニングを記録するものとしては使いづらい。また、日常的に運動をしていない人はアスリートとは異なり多くの情報を必要とせず、習慣化に必要な最低限の情報を必要としている。

2.2 カメラベース

カメラを用いた手法は、センサを身につけることなくトレーニングを行うことができるため、違和感なく計測することができる。また、khurana らは、単一のカメラを利用して、同時に運動している複数の人々を追跡し、トレーニングの種類と繰り返しを測定する手法を提案している [2]。一方、Velloso らは、ウェアラブルセンサと比較を行い、ビジョンベースの方法はプライバシーの問題と照明や見通し線などの外部要因の影響を受ける問題がある述べている [5]。今回の研究では、自宅を想定しており部屋の明るさは様々である。また、複数人が同時に筋トレを行うことは、1 台の懸垂マシンでは不可能である。

2.3 電波ベース

WiFi を用いた手法は、ウェアラブル端末のように身につけることが必要ないため、トレーニングをカメラベースと同じく違和感なく計測することができる。また、カメラのように画像を用いていないためプライバシーの問題もない。Xiao らは、WiFi-CSI (Channel State Information) 波形ベースの機能を利用して、4 つのエクササイズを区別する手法を提案している [6]。Guo らも同様に CSI 情報を利用して、自宅や職場環境内のトレーニングを分析する手法を提案している [7]。しかし、CSI を計測するためには特殊な装置が必要になり一般家庭の WiFi ルータを使用することはできない。また、WiFi は環境や時間によって通信に影響が出る可能性があり、正しく測定できない可能性がある。

3. 提案種目推定手法

本研究では、懸垂マシンを用いた筋トレ種目を推定する

ために、機械学習ベースのアプローチを採用する。以下では、推論モデルの構築プロセスについて述べる。

3.1 特徴量抽出

本研究では、加速度センサを用いた行動認識に関する先行研究 [8], [9], [10] に基づき、ウィンドウサイズと特徴量を選定した。まず、ウィンドウサイズは 1.24 秒を採用した。ウィンドウオーバーラップ率は、50%である。また、特徴量は、平均値、標準偏差、中央絶対偏差、最大値、最小値、二乗平均和、エントロピー、四分位範囲、4 次の Burg 自己回帰モデルの係数、最小値と最大値の範囲、二乗平均平方根、周波数信号の歪度、周波数信号の尖度、最大周波数成分、周波数信号の加重平均、周波数帯域のスペクトルエネルギー、パワースペクトル密度を採用した。

3.2 機械学習

機械学習フェーズでは、特徴量抽出された時系列信号を入力として、行動ラベルを出力する分類モデルを構築する。本研究では、予備実験として、代表的な 9 種類の機械学習アルゴリズム (Support Vector Machine (SVM), Artificial Neural Network (ANN), Random Forest (RF), Decision Tree (DT), LightGBM, Logistic Regression (LR), K-Nearest Neighbor (KNN), Naive Bayes (NB), Extra-Trees (ET)) の認識精度を比較した。



図 1 加速度センサを設置した懸垂マシン

4. 筋トレ種目推定の実験概要

本研究では、図 1 に示すように懸垂マシンの上部、中部、



図 2 懸垂マシンを用いて 4 種目の筋トレ




図 3 加速度センサのデータ

下部に加速度センサを設置し、データ収集実験を行った。被験者は 21 歳から 23 歳の男性 8 名で、トレーニング種目を合計 13 セット行った。1 セットの内容は、図 2 に示すように、ぶら下がり、懸垂、レッグレイズ、腕立て伏せの 4 種目である。ぶら下がり、懸垂、レッグレイズ、腕立て伏せは 5 回を 1 セットで行った。今回の実験の目的は 2 つ。1 つ目は、加速度センサーのみで筋トレ種目の推定を行うことができるのか。そして 2 つ目は、加速センサーをどこに設定した時に最も精度高く推定することができるのかである。

5. 結果と考察

計測の結果、加速度センサから図 3 に示すデータを得ることができた。このように、種目ごとに、異なる特性の波形が計測できていることが確認できる。これらのデータに対して特徴量抽出処理を適用し、9 種類の機械学習アルゴリズムを用いて、筋トレ種目の推定を行った。10 分割交差検証 (10-fold CV) を用いて被験者依存 (PD: Person Dependent) モデルの評価を行い、Leave-One-Person-Out 交差検証 (LO PO CV) を用いて被験者非依存 (PI: Person Independent) モデルの評価を行なった。表 2 と表 3 に結果を示す。

表 2 より、RF, ANN, LR を用いた被験者依存の推論モデルが 75 % 以上の正解率を達成していることが確認できる。一方、表 3 では、ANN, LightGBM, LR, RF を用いた被験者非依存の推論モデルが、75 % 以上の正解率を達成している。また、DT, KNN, LightGBM, LR, SVM を用いた被験者依存の推論モデルの正解率と被験者非依存の推

論モデルの正解率を比較すると、後者の方が正解率が高いことがわかる。この原因は、被験者あたりのデータ量が少なかったことが影響していると考えられる。特に、今回の実験で認識対象としている懸垂や腕立て伏せなど種目は、回数を重ねる毎に疲労が蓄積し、動作モーションが変わってしまうという性質がある。そのため、同じ被験者のデータのみで学習した被験者依存の推論モデルであっても誤分類が発生したと考えられる。今後は、各被験者ごとに十分な量のデータを収集し、より認識精度の高い推論モデルの構築を目指す。

次に、被験者非依存の推論モデルで最も良い精度を示した LR を用いて加速度センサをつける位置によってどれくらい精度が異なるの確認した。表 4 と表 5 に結果を示す。この結果から、加速度センサを懸垂マシンの上部に設置した方が正解率、適合率、再現率全てにおいて高いことがわかった。

今回抽出した特徴量に関して、LightGBM を用いて特徴量重要度を算出した。図 4 に、重要度が高かった上位 5 個の特徴量重要度を示す。結果から、加速度 X 軸の中周波数帯域におけるスペクトル・エネルギーや加速度 Z 軸の周波数成分の標準偏差といった特徴量が有効であることが確認できる。

表 2 10-fold CV による PD モデルの認識結果 (上部)

機械学習アルゴリズム	正解率	適合率	再現率	F 値
ANN	0.771	0.772	0.771	0.771
DT	0.680	0.678	0.680	0.678
ET	0.680	0.680	0.680	0.680
KNN	0.723	0.728	0.723	0.723
LightGBM	0.734	0.733	0.734	0.733
LR	0.760	0.761	0.760	0.760
NB	0.691	0.687	0.691	0.674
RF	0.773	0.771	0.773	0.771
SVM	0.743	0.757	0.743	0.739

表 3 LOPO CV による PI モデルの認識結果 (上部)

機械学習アルゴリズム	正解率	適合率	再現率	F 値
ANN	0.763	0.762	0.763	0.762
DT	0.682	0.684	0.682	0.683
ET	0.654	0.657	0.654	0.655
KNN	0.734	0.735	0.734	0.727
LightGBM	0.765	0.764	0.765	0.763
LR	0.776	0.775	0.776	0.775
NB	0.572	0.488	0.572	0.494
RF	0.756	0.756	0.756	0.755
SVM	0.748	0.747	0.748	0.745

表 4 10-fold CV による PD モデルの認識結果 (LR)

加速度の位置	正解率	適合率	再現率	F 値
上部	0.760	0.761	0.760	0.760
中央	0.659	0.665	0.659	0.659
下部	0.660	0.667	0.660	0.662

表 5 LOPO CV による PI モデルの認識結果 (LR)

加速度の位置	正解率	適合率	再現率	F 値
上部	0.776	0.775	0.776	0.775
中央	0.527	0.529	0.527	0.523
下部	0.603	0.605	0.603	0.599




図 4 上位 5 個の特徴量重要度

6. 結論

今回の実験から加速度センサのみで懸垂マシンを用いた筋トレ種目の推定は可能であることがわかった。さらに加速度センサの設置場所により推定精度が異なり、上部に設置した場合が最も高い精度を示した。しかし、データのサンプル数や、認識可能な種目数が少ないため、さらなるデータ収集が必要である。

これから本研究を運動の習慣化につなげるためには、大きく分けて 3 つのことをすべきと考えている。1 つ目は先に述べた通り、サンプルの数と種類を増やすことである。今回の実験では 21 歳から 23 歳の男性と限られた範囲からしかデータを得ることができなかった。そのため、女性のデータと幅広い世代のデータが必要がある。また、合計で 13 セットのサンプルしかなかったため、1 人あたりのデータを増やすことも必要である。2 つ目は、推定する項目を増やすことである。今回の実験では筋トレ種目の推定のみを行なったが、筋トレしている人の推定や繰り返し回数の推定などの情報も習慣化するためには重要である。また、トレーニング記録だけではなく、体重などの記録も身体内部の変化を実感するために重要である。そのため体重を取得する仕組みも必要である。3 つ目は、フィードバックの仕組み作りである。記録した結果をどのようにユーザに返すことが習慣化に繋がるのか検証を行う必要がある。これらについて研究を進めることで運動を習慣化できると考えられる。

謝辞 本研究の一部は、JSPS 科研費 JP18H03233 の支援のもと実施された。

参考文献

- [1] Keng-Hao Chang, Mike Y Chen, and John Canny. Tracking free-weight exercises. In *International Conference on Ubiquitous Computing*, pp. 19–37. Springer, 2007.
- [2] Rushil Khurana, Karan Ahuja, Zac Yu, Jennifer Mankoff, Chris Harrison, and Mayank Goel. Gymcam: Detecting, recognizing and tracking simultaneous exercises in unconstrained scenes. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 2, No. 4, pp. 1–17, 2018.
- [3] Dan Morris, T Scott Saponas, Andrew Guillory, and Ilya Kelner. Recofit: using a wearable sensor to find, recognize, and count repetitive exercises. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 3225–3234, 2014.
- [4] Masashi Takata, Manato Fujimoto, Keiichi Yasumoto, Yugo Nakamura, and Yutaka Arakawa. Investigating the capitalize effect of sensor position for training type recognition in a body weight training support system. In *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*, pp. 1404–1408. ACM, 2018.
- [5] Eduardo Velloso, Andreas Bulling, Hans Gellersen, Wallace Ugulino, and Hugo Fuks. Qualitative activity recognition of weight lifting exercises. In *Proceedings of the 4th Augmented Human International Conference*, pp. 116–123, 2013.
- [6] Fu Xiao, Jing Chen, Xiaohui Xie, Linqing Gui, Lijuan Sun, and Ruchuan Wang. Seare: A system for exercise activity recognition and quality evaluation based on green sensing. *IEEE Transactions on Emerging Topics in Computing*, Vol. 8, No. 3, pp. 752–761, 2018.
- [7] Xiaonan Guo, Jian Liu, Cong Shi, Hongbo Liu, Yingying Chen, and Mooi Choo Chuah. Device-free personalized fitness assistant using wifi. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 2, No. 4, pp. 1–23, 2018.
- [8] Yugo Nakamura, Yoshinori Umetsu, Jose Paolo Talusan, Keiichi Yasumoto, Wataru Sasaki, Masashi Takata, and Yutaka Arakawa. Multi-stage activity inference for locomotion and transportation analytics of mobile users. In *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*, pp. 1579–1588. ACM, 2018.
- [9] Yohei Torigoe, Yugo Nakamura, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Strike activity detection and recognition using inertial measurement unit towards kendo skill improvement support system. *Sensors and Materials*, Vol. 32, No. 2, pp. 651–673, 2020.
- [10] Yugo Nakamura, Yuki Matsuda, Yutaka Arakawa, and Keiichi Yasumoto. Waistbelt x: A belt-type wearable device with sensing and intervention toward health behavior change. *Sensors*, Vol. 19, No. 20, p. 4600, 2019.