

# IMUを用いたデバイスの装着位置に依存しない 身体運動認識手法の提案

石井 峻<sup>1</sup> 横窪 安奈<sup>1</sup> ロペズ ギョーム<sup>1</sup>

**概要:** 近年様々なウェアラブルデバイスが普及しているが, 身体的な運動を支援するシステムは既定のデバイスを使用したものが多く, デバイスおよび装着位置を問わずに使用できるシステムは少ない. また, 身体運動認識手法には機械学習を用いた手法が多いが, 身体的負荷の高い運動において十分な量のトレーニングデータを収集することは難しい. そこで本研究では, 事前に正しい動作を1回のみ必要とし, 様々なデバイスおよび装着位置で応用可能な正しい動作との相関を用いた身体運動認識手法を提案している. 4種類のデバイスおよび装着位置において5種類の運動を行い, 提案手法の有効性を検証するとともに, 機械学習による分類精度との比較を行った. その結果, 全てのデバイスおよび装着位置において機械学習と同程度の精度を達成し, 提案手法の有効性が確認できた. また, 提案手法を使用して, 操作ジェスチャーをカスタマイズ登録可能な仮想空間で行うドッジボール風ゲームを実装した.

## Physical Exercise Recognition Method Using IMU Robust to Positioning

SHUN ISHII<sup>1</sup> ANNA YOKOKUBO<sup>1</sup> GUILLAUME LOPEZ<sup>1</sup>

### 1. 研究背景

身体的な運動は心身の健康を増進させる効果がある一方, 継続して行うことは難しい. 厚生労働省による健康日本21の政策のひとつとして「国民の身体活動や運動についての意識や態度を向上させ, 身体活動量を増加させること」を目標としており, 多くの人が無理なく日常生活の中で運動を実施する方法の提供や環境をつくることが求められている [1].

近年では, 運動を継続するモチベーションを維持させるために, 身体運動を自動で認識するシステムを使用して自己の運動履歴を管理・共有したり, ゲームと連動させたりする取り組みがある. しかし, 既存の身体運動認識手法では, 行動範囲の限定されたカメラを使用したもの [2] や, 装着位置の決まった規定のウェアラブルデバイスを使用したもの [3] が多く, デバイスおよび装着位置を問わずに認識できる手法は少ない. また, 近年は機械学習を用いた認識手法が多く提案されているが, 身体的負荷の高い運動にお

いては大量のトレーニングデータを収集することは難しいため, 認識する運動の種類を増やすことが難しい. 一方, このような身体運動には正しいとされる動作があるため, 正しい動作との相関を利用することで認識が可能であると考えられる.

本研究では, 市販の様々なデバイスおよび装着位置から手軽に運動を認識できるようにすることを目的として, 正しい動作との類似度を用いた身体運動認識手法を提案し, その応用例を示す.

### 2. 関連研究

Danらは腕に装着した慣性センサによって繰り返し動作のある筋力トレーニングを認識するシステムである RecoFit を提案した [3]. 機械学習を用いた手法により, 運動中と運動中でない状態を95%の精度で判定し, 13種類の運動を96%の精度で認識した. 運動のカウントに関しても $\pm 1$ 回の回数を93%の精度で達成した一方, 専用のデバイスが必要となることや, カウントの開始までに5秒間かかることが課題として残る.

<sup>1</sup> 青山学院大学  
Aoyama Gakuin University

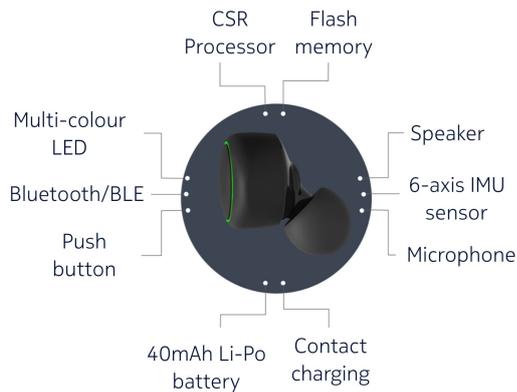


図 1 eSense の外観と搭載モジュール ([5] より引用)

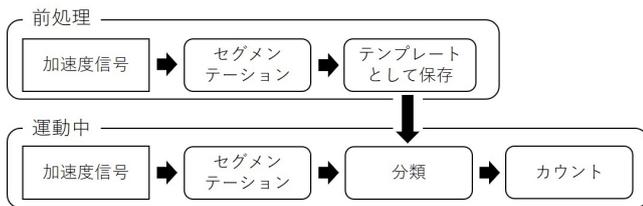


図 2 提案手法の概要

従来の行動認識に関する研究では、スマートフォンやスマートウォッチなど一般に普及したデバイスを用いた手法の提案が多かった一方、Kawsar らは近年急速に普及している左右独立型のフルワイヤレスイヤホンに IMU を搭載した、耳装着型のウェアラブルデバイス（イアラブルデバイス [4]）である eSense（図 1）を提案した [5]。

本研究では、提案手法を eSense によって取得したデータへも適用し、身体運動認識における有効性を検証する。

### 3. 加速度信号の類似度を用いた認識手法

本研究における提案手法の概要を図 2 に示す。慣性計測装置 (IMU) の搭載されたデバイスを体の任意の位置へ装着し、前処理として認識したい運動の正しい動作を各 1 回以上行う。得られた加速度信号を第 3.1 節に述べるセグメンテーションによって各 1 回の動作に切り取り、1 つの動作をテンプレートとして保存する。

運動中では、前処理と同様の手順によって、計測した加速度信号を 1 回ごとの動作に切り取るセグメンテーションを行う。その後、第 3.2 節に述べる分類手法によって複数のテンプレートとの類似度をリアルタイムで計算し、最も類似しているテンプレートの運動として認識しカウントする。この際、デバイスの装着位置は問わないが、前処理と運動中で同じ位置に装着する必要がある。

#### 3.1 セグメンテーション

提案手法において、連続した運動から計測された加速度信号を 1 回ごとの動作ごとに切り取る処理をセグメンテーションと呼ぶ。セグメンテーションの手法を図 3 に示す。

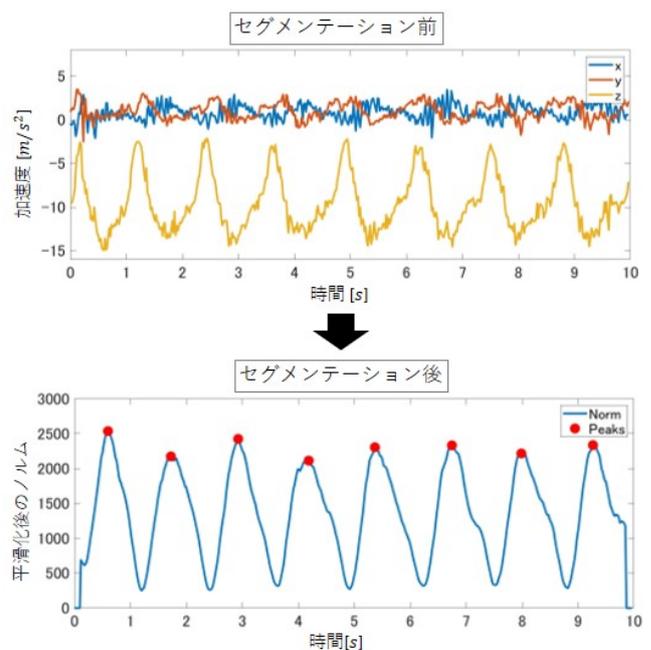


図 3 セグメンテーション時の加速度生データと処理後のデータ

セグメンテーションでは、まず取得した 3 軸加速度の生データのノルムを計算する。提案手法においてノルムは運動の強度を表し、3 軸加速度の値をそれぞれ  $x$ ,  $y$ ,  $z$  とすると以下の (1) 式によって与えられる。

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

ノルムを計算後、0.25 秒の移動窓を使用してノルムの時系列データを平滑化する（図 3「セグメンテーション後」青線）。平滑化したノルムに対してさらに 0.25 秒の移動窓を適用し、移動窓の中央の値が窓内の最大値であった場合に、その値をピーク値とする（図 3「セグメンテーション後」赤点）。ここで得られたピーク値のタイムスタンプによって加速度の生データを切り取り、1 回の動作とする。

#### 3.2 分類

第 1 章や第 2 章で述べたように、機械学習に必要な大量の運動のデータを収集することは身体的な負荷が高く、連続して行うと運動のフォームが乱れ正しいデータを取得することができない。また、機械学習によって作成されたモデルでは限定的な運動しか認識できず、後に各運動者が行いたい運動を認識の対象として追加することは難しい。そのため、本研究では事前に 1 回の動作のみを必要とするテンプレートとの相関を用いた分類手法を提案する。

提案手法における分類の手順を図 4 に示す。セグメンテーションによって 1 回の動作に切り取られた加速度信号と、事前に用意した各テンプレートの加速度信号から、Algorithm 1 に示す Dynamic Time Warping (DTW) によって類似度を計算する。多数の運動テンプレートのうち類似度が最も高いテンプレートの運動として分類しカウン

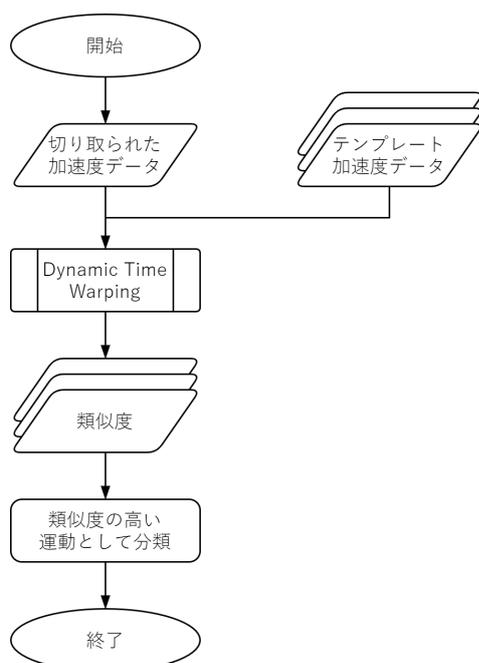


図 4 分類時のフローチャート

#### Algorithm 1 Dynamic Time Warping

Require:  $n > 0 \wedge m > 0$

$DTW \leftarrow \text{array}[0..n, 0..m]$

for  $i = 0 \dots n$  do

$DTW[i, 0] \leftarrow \text{infinity}$

end for

for  $j = 0 \dots m$  do

$DTW[0, j] \leftarrow \text{infinity}$

end for

$DTW[0, 0] \leftarrow 0$

for  $i = 0 \dots n$  do

for  $j = 0 \dots m$  do

$\text{cost} \leftarrow \|(s[i] - t[j])\|$

$DTW[i, j] \leftarrow \text{cost} + \min(DTW[i - 1, j], DTW[i, j - 1], DTW[i - 1, j - 1])$

end for

end for

return  $DTW[n, m]$

トするが、どのテンプレートとの類似度も閾値より低ければその他の動作として認識し、カウントしない。

## 4. 提案手法の検証

提案手法の有効性を検証するとともに、機械学習による分類との比較を行った。データは、週に1回以上の運動を行う大学生12名から取得した。

### 4.1 使用したデバイスと装着位置

データ収集に使用したデバイスとその装着位置を図5に示し、選定理由と今回使用したデバイスの詳細をそれぞれ以下に述べる。

#### ● 左手首 – スマートウォッチ

近年急速にスマートウォッチが普及しており、運動時



図 5 各デバイスの装着位置

に手首に装着して運動状態を記録する人が多い。今回はオペレーティングシステムに Wear OS by Google[6] を搭載したスマートウォッチである Polar M600[7] を使用した。

#### ● 胸の中心 – ウェアラブルセンサ

運動者の中には、運動に特化した専用のウェアラブルセンサを使用する人も多い。そのようなウェアラブルセンサは胸や背中に装着するタイプが多く、体の軸となる位置に装着することで高い精度で認識することができると考えられる。今回は直径 36.6mm の小型で安価なウェアラブルセンサである Movesense Sensor HR+[8] (Movesense) を胸の中心へ装着した。Movesense は計測したデータを Bluetooth 通信によってスマートフォンへ随時送信する。

#### ● 左上腕 – スマートフォン

スマートフォンは既に広く普及しており、上腕にバンドで装着して運動を行う人も多い。今回はオペレーティングシステムに Android[9] を用いた Google Pixel XL[10] を使用した。

#### ● 左耳 – イアラブルデバイス

近年、左右独立型のフルワイヤレスイヤホンが急速に普及し、日常生活や運動中に装着している人が多い。今回はイアラブルデバイスとして第2章で述べた eSense (図1) を使用した。

### 4.2 認識の対象とした運動

今回認識の対象とした運動は、ランニング、ウォーキング、腿上げジャンプ、腕立て伏せ、上体起こしの5種類である。これらの運動は、特別な器具が必要なく、一般の運動者が近所の公園で行うことができ、動作の習得が容易であるものを選択した。

表 1 セグメンテーションの再現率

		各運動					全運動
		ランニング	ウォーキング	腿上げジャンプ	腕立て伏せ	上体起こし	
装着位置	左耳	0.859	0.909	0.724	0.920	0.600	0.841
	胸の中心	0.970	0.961	0.965	0.943	0.537	0.914
	左上腕	0.972	0.977	0.951	0.936	0.517	0.918
	左手首	0.982	0.949	0.894	0.904	0.610	0.916

表 2 分類の F1 値 (標準偏差)

		各運動					全運動
		ランニング	ウォーキング	腿上げジャンプ	腕立て伏せ	上体起こし	
装着位置	左耳	0.757 (0.178)	0.803 (0.156)	0.696 (0.238)	0.700 (0.218)	0.880 (0.112)	0.784 (0.100)
	胸の中心	0.952 (0.111)	0.988 (0.035)	0.905 (0.196)	1.000 (0.001)	0.991 (0.006)	0.972 (0.044)
	左上腕	0.914 (0.039)	0.964 (0.021)	0.937 (0.090)	0.882 (0.100)	0.853 (0.185)	0.931 (0.031)
	左手首	0.809 (0.096)	0.878 (0.054)	0.778 (0.151)	0.745 (0.144)	0.915 (0.131)	0.835 (0.056)

### 4.3 認識精度と考察

#### 4.3.1 セグメンテーション

セグメンテーションの精度として、真値に対する予測値の再現率を表 1 に示す。各装着位置ごとの精度としては、左上腕が最も高かった。左手首、胸の中心でも高い精度が得られた一方、左耳のセグメンテーション精度は著しく低かった。左耳は他の装着位置と比較して、ランニングやウォーキング、腿上げジャンプのセグメンテーション精度が特に低かった。原因として、ランニングやウォーキング、腿上げジャンプには正しい顔の向きや頭の位置が無く、自由度が高かったためであると考えられる。

また、全ての装着位置において上体起こしのセグメンテーション精度が著しく低かった。これは、1 回の動作中に加速度のピークが複数回あったことが原因である。上体起こしでは、地面に近いときと上に起き上がったときで最も変化の大きい軸が変わるので、変化量の多い軸を特定することで改善できると考えられる。

#### 4.3.2 分類

分類精度の F1 値と標準偏差を表 2 に示す。各装着位置ごとの分類精度では、胸の中心が最も高かった。胸は運動をするときに軸となる胴体部分であるために、対象とする動きの影響を最も受け一方で、頭部や四肢と比較してノイズとなる動きが少なかったことが原因として考えられる。

また、左耳の分類精度が最も低く、上体起こしを除く 4 つの運動において最も精度が低かった。左耳の精度は顔の向きや頭の動きに依存するため、視線の影響を受ける。データ収集時には、運動者が周囲の状況を確認したり自身の運動姿勢を確認したりする状況が多くあった。運動者は運動中に様々な方向を見るために、左耳の精度が最も低くなったと考えられる。

表 3 提案手法と機械学習の F1 値

装着位置	提案手法	機械学習 1	機械学習 2
左耳	0.784	0.957	0.771
胸の中心	0.972	0.990	0.869
左上腕	0.931	0.952	0.835
左手首	0.835	0.944	0.795

さらに、機械学習に対する提案手法の優位性を示すために、分類精度の比較を行った (表 3)。機械学習モデルは線形サポートベクターマシンを用い、以下の 2 種類の交差検証を行った。

- 機械学習 1 では、1 人抜き交差検証を行った。
- 機械学習 2 では、1 人のデータをトレーニングデータ、その他のデータをテストデータとして交差検証を行った。

提案手法ではランダムに抽出した 1 人の行った 1 回の動作をテンプレートデータとして、全員のデータを分類して精度を算出する。提案手法と同じ条件での比較を行うために、機械学習 2 では 1 人のデータをトレーニングデータとし、その他のデータをテストデータとしている。

表 3 のとおり、1 人抜き交差検証を行った機械学習 1 で最も精度が高く、最も精度が低かったのは機械学習 2 であった。機械学習 1 では学習に複数人のデータを用いているため最も精度が高くなったと考えられる。提案手法と機械学習 2 では学習に 1 人のデータのみ用いており、全ての装着位置において提案手法の方が分類精度が高かったことから、機械学習に対する提案手法の優位性が示された。また、提案手法では事前に認識したい運動の動作を 1 回のみ必要とする点においても、機械学習に対して優位である。

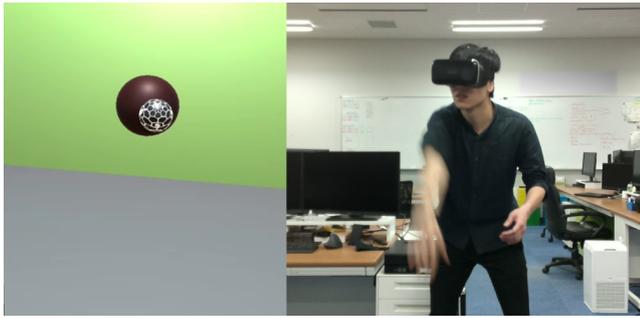


図 6 仮想空間で行うドッジボール風ゲーム

## 5. 結論

本研究では、加速度センサを用いて、正しい動作との類似度によって複数の運動を認識する手法を提案し、複数のデバイスおよび装着位置による検証や機械学習との比較を行った。左耳、胸の中心、左上腕、左手首の4箇所を検証を行った結果、セグメンテーションの再現率では胸の中心、左上腕、左手首においてそれぞれ91.4%、91.8%、91.6%を達成し、最も低かった左耳でも84.1%を達成した。分類精度に関しては、体の軸となる胸の中心で最も精度の高い97.2%を達成した。最も精度が低かったのは運動者の視線の影響を受けやすい左耳で、78.4%の精度であった。広く普及しているスマートフォンを左上腕に装着した場合は93.1%の分類精度を達成し、近年急速に普及しているスマートウォッチを装着した左手首では83.5%を達成した。機械学習との比較において、提案手法と同じく1人のデータのみをトレーニングデータとした場合は全ての運動において提案手法の方が精度が高かった。

## 6. 応用例と今後の展望

提案手法を使用して、仮想空間で行うドッジボール風ゲームを実装した(図6)。本ゲームでは加速度センサを搭載したデバイスを右手首に装着し、ターゲットから発射されるボールを弾きながらターゲットにボールを当てる。投球時は、事前に用意されている投球動作のテンプレートデータを用いて投球動作を認識し、視野の中央に向かってボールが発射される。ゲーム途中でボールを弾く動作を登録する場面があり、プレイヤーは任意の動作を1回行うだけでボールを弾くテンプレートデータが登録される。以降、同じ動作をすることによってボールを弾くことが可能となる。その際、プレイヤーが行った動作が投球動作か弾く動作かは、それぞれのテンプレートデータとの比較によって分類される。

今後はテンプレートの作成方法を改善することで提案手法の精度向上を目指す。また、テンプレートデータとの類似度を指標として、各運動の良し悪しを判定できるシステムの開発を目指す。

## 参考文献

- [1] 身体活動・運動 | 厚生労働省, 入手先 <<https://www.mhlw.go.jp/www1/topics/kenko21-11/b2.html>> (参照 2021-05-10).
- [2] David Antón, et al.: Exercise Recognition for Kinect-based Telerehabilitation, *Methods of Information in Medicine* 2015, 54(2), pp. 145–155.
- [3] Dan Morris, et al.: RecoFit: Using a Wearable Sensor to Find, Recognize, and Count Repetitive Exercises, *CHI '14*, pp. 3225–3234.
- [4] 谷口和弘 (2016)earable 世界初!イヤホン型ウェアブルコンピューター, 株式会社シーエムシー出版.
- [5] Fahim Kawsar, et al.: Earables for Personal-Scale Behavior Analytics, *IEEE Pervasive Computing*, Vol. 17, No. 3, pp. 83–89, 2018.
- [6] Wear OS by Google, 入手先 <<https://wearos.google.com>> (参照 2021-05-10).
- [7] Polar M600, 入手先 <<https://support.polar.com/ja/support/m600>> (参照 2021-05-10).
- [8] Movesense Sensor HR+, 入手先 <<https://www.movesense.com/product/movesense-sensor-hr>> (参照 2021-05-10).
- [9] Android, 入手先 <<https://www.android.com>> (参照 2021-05-10).
- [10] Google Pixel XL, 入手先 <<https://store.google.com/category/phones>> (参照 2021-05-10).