

## Hololens2 のマルチセンシング機能を利用した 機械学習に基づく身体動作解析

藤崎竜成<sup>†</sup> 森雅也<sup>†</sup> 野中尋史<sup>†</sup>  
長岡技術科学大学<sup>†</sup>

### 1. はじめに

製造業をはじめとするビジネスの現場において、作業者の作業動作を分析することは、作業効率改善や作業異常検知に貢献する。一般に、作業動作を高精度で認識するためには、様々な身体動作の特徴を捉える必要がある。既存研究では、身体に慣性センサーを装着することで、これを實現している[1][2][3]。しかし、慣性センサーでは指先の細かい動作や視線の動作情報を取得できない問題が挙げられる。

2019年にHololens2というMRデバイスがMicrosoft社から発表された。Hololens2は、アイトラッキングやハンドトラッキングなどのマルチセンサーを標準搭載している。そのため、指先などの細かい動作と視線の動作情報が取得可能である。これを活かし、手術シミュレーションを行う医療現場での活用や、倉庫内などの情報をあらかじめ共有することが可能な工場現場で活用されている。

そこで本研究は、Hololens2を用いて身体動作の特徴を捉えられるかを検証した。

### 2. 検証方法

本研究では、初めにHololens2でいくつかの動作を計測するためのアプリケーション開発を行う。次に、計測データから機械学習モデルを構築し、動作分類を行う。最後に、その分類精度から検証を行う。

#### 2.1 動作情報取得アプリケーション

Hololens2で動作を計測するために、ゲームエンジンのUnityとXRアプリケーション開発支援ライブラリのMixed Reality Toolkit (MRTK)を用いて、動作データをcsvで出力するアプリケーションの開発を行った。本アプリケーションの特徴は、1/60秒間隔で左右の手の中心と5本指の第一関節、また視線を含めた13箇所のx, y, z軸、計39個の座標データを取得することが可能な点である。

#### 2.2 特徴量エンジニアリング

x軸加速度, y軸加速度, z軸加速度, 合成加速度の4つを算出した。

座標データから速度データへの変換は式(1)より行い、速度データから加速度データへの変換は式(2)により行った。合成加速度の算出は式(3)により行った。ここで $v_{n+1}$ ,  $v_n$ は速度,  $x_{n+1}$ ,  $x_n$ は座標,  $a_n$ は加速度,  $t_{n+1}$ ,  $t_n$ は時間,  $n$ はn番目のデータ,  $x$ ,  $y$ ,  $z$ , はそれぞれ座標の成分,  $sacc$ は合成加速度を表す。

$$v_n = \frac{x_{n+1} - x_n}{t_{n+1} - t_n} \quad (1)$$

$$a_n = \frac{v_{n+1} - v_n}{t_{n+1} - t_n} \quad (2)$$

$$sacc = \sqrt{x^2 + y^2 + z^2} \quad (3)$$

特徴量の作成は、加速度データに対して窓幅とシフト幅を設定し、各窓で平均値, 分散値, 標準偏差, 尖度, 歪度, 最大値, 最小値を算出することで行った。今回のような時系列データの解析は、窓幅を設定して統計量を算出することで、データの特徴を把握しやすくなる利点がある。またシフト幅を指定することで、窓幅をとる際に起こる情報の欠落を軽減することが可能である。

最終的なデータ数と次元数を表1に示す。これらを用いてランダムフォレストで特徴量選択と動作分類を行う。

#### 2.3 実験条件

計測する動作は、Hololens2が手を認識できる範囲の動作である①静止状態, ②文字を書く, ③タイピングを行う, ④ルービックキューブを回す, ⑤折り紙を折るの5つとした。

被験者数は一人であり、計測時間は3分間で、各動作それぞれ約10000データ取得した。窓幅は300, シフト幅は30とした。また、合成加速度の分散値に関しては異常値が多かったため、今回の学習から除外した。

#### 2.4 ランダムフォレストによるモデル構築

動作分類のためのモデル構築は次の3つの手順で行った。

I. 2.2で述べたように、特徴量エンジニアリングを行う

- II. ランダムフォレストで特徴量選択を行う
- III. 選択された特徴量を入力とした、ランダムフォレストによる動作分類器を構築する

### 2.5 特徴量選択

作業の効率化や異常検知には、それらに關与する身体動作の特徴量を抽出する必要がある。そこで本研究では、特徴量選択手法としてランダムフォレストを採用した。理由は、予測精度が比較的高いことや、予測と同時に特徴量重要度を算出することができるためである。

特徴量選択は次の手順で行った。

- ① 全特徴量をランダムフォレストに入力し、各特徴量重要度を算出
- ② 重要度が 0.02 以上の特徴量を選択
- ③ 選択された特徴量を入力し、ランダムフォレストを学習させ分類精度を見る
- ④ 分類精度が向上するように特徴量を一つ削り学習させる
- ⑤ ④を繰り返す、精度が向上しなくなるまで行う

### 3. 結果と考察

加速度データから直接学習したモデル、加速度データから統計量を算出し、それらの特徴量として学習したモデル、特徴量選択した学習モデルの3つの結果をそれぞれ表2に示す。また、特徴量選択によって最終的に選ばれた15個の重要特徴量の部位、加速度、統計量、重要度を表3に示す。

表3の部位項目に着目すると、主に右手が重要な特徴という結果が確認された。今回の動作を考えると、折り紙を折る動作や文字を書く動作、ルービックキューブを回す動作などは基本的に利き手を動かし、非利き手は静止状態であることが多い。今回の被験者の利き手は右手であったため、分類に必要な重要特徴量が常に動かしていた右手に集中したと考えられる。

また、表3の統計量をみると、標準偏差や分散が今回の5つの動作分類の重要特徴量として、最も多く採用されていた。このことから、動作の緩急を動作分類する際に重要な特徴量として判断していることが確認された。

### 4. まとめと今後の課題

今回はHololens2を用いた身体動作解析を行い、新しい身体動作解析の可能性を示した。今回の実験では表3のような特徴量が選出され、それらは動作の特徴と一致していることが確認された。今後は、実践現場での身体動作解析が行えるように、時系列データに対する交差検証や被験者の人数の増加に取り組むとともに、複雑な動作分類を行っていく。

表 1: データ数と次元数

	データ数	次元数
学習データ	1280	351
テストデータ	280	351

表 2: 各モデルの学習結果

	Train(Accuracy)	Test(Accuracy)
加速度データモデル	0.524	0.542
特徴量作成後のモデル	0.888	0.832
特徴量選択後のモデル	0.860	0.853

表 3: 重要特徴量結果

部位	加速度	統計量	重要度
右手中心	y 軸加速度	標準偏差	0.0358
右手中心	合成加速度	標準偏差	0.0350
右手人差し指	y 軸加速度	標準偏差	0.0349
左手小指	z 軸加速度	分散	0.0294
右手小指	y 軸加速度	最小値	0.0288
左手親指	x 軸加速度	分散	0.0282
左手中指	z 軸加速度	分散	0.0274
右手中指	z 軸加速度	最大値	0.0263
左手小指	y 軸加速度	最大値	0.0245
右手中心	y 軸加速度	分散	0.0243
左手中指	y 軸加速度	標準偏差	0.0231
右手親指	合成加速度	最小値	0.0230
右手薬指	z 軸加速度	最小値	0.0224
右手小指	y 軸加速度	標準偏差	0.0223
右手中指	合成加速度	標準偏差	0.0218

### 参考文献

[1] Mori, M., Omac, Y., Akiduki, T., & Takahashi, H. (2019). Consideration of human motion's individual differences-based feature space evaluation function for anomaly detection. *International Journal of Innovative Computing, Information and Control*.

[2] W. Tao, M. C. Leu, Z. Yin, (2020). Multi-modal recognition of worker activity for human-centered intelligent manufacturing, *Engineering Applications of Artificial Intelligence*.

[3] M. Al-Amin, W. Tao, D. Doell, R. Lingard, Z. Yin, M. C. Leu, R. Qin, (2019). Action recognition in manufacturing assembly using multimodal sensor fusion. *ProcediaManufacturing*