

スマートウォッチのIMUに基づく握力推定手法の提案

本田 智大^{1,a)} 白根 薫² 志築 文太郎³

概要：

モバイルデバイスにおいて握力を推定するための試みは、スマートフォンもしくは外部の圧力センサを利用したものに限定されており、その他のアプローチを用いた研究は少ない。そこで、我々はスマートウォッチのIMUに基づいた握力推定手法を提案する。本稿ではスマートウォッチのIMUにて計測したデータから抽出される特徴量に基づいて機械学習による6種類の回帰モデルの構築を行った後、モデルの性能を比較および評価する。著者1名のデータを使った予備実験の結果、決定係数 (R^2) が 0.75、および平均絶対誤差 (MAE) が 1.69 という精度にて握力を推定できた。

1. はじめに

モバイルデバイスにおける握力推定は、ジェスチャ操作もしくはリハビリテーションへの活用という点にて需要がある。握力推定ではスマートフォンもしくは外部の圧力センサを用いる手法が試みられているが、その他のアプローチに注目した研究は少ない。一方で、ViBand [3] および Xu らの手法 [4] に代表されるように、スマートウォッチの慣性計測ユニット (IMU) により測定される手首周辺の微細な生体信号に基づいて、さまざまなハンドジェスチャを認識する手法が研究されている。しかし、これにより握力を推定する試みはまだない。

そこで本研究では、スマートウォッチのIMUに基づく握力推定手法を提案する。本手法では、人間がデジタル握力計を一定の力にて握っているときに腕から手首にかけて現れる振動をスマートウォッチのIMUにより測定する。その後、IMU データから抽出される時間領域特徴量および周波数領域特徴量を入力とする。また、IMU 測定時のデジタル握力計の表示値を目標値として回帰モデルを構築することによって握力を推定する。

2. 関連研究

スマートフォンを利用して握力を推定する研究が行われている。GripSense [1] では、スマートフォンのタッチスクリーン、IMU および振動モータを用いることにより、手の姿勢を推定および3段階の圧力を分類する。また、山本

ら [5] はスマートフォン上に安価かつ簡易な握力測定器具を追加することにより、スマートフォンのタッチ座標変化から握力を測定する。これらの関連研究に対して、スマートフォンのセンサによらない握力推定が可能であるかどうかについてはまだ不明である。

スマートウォッチのIMUに基づいて人間の手の動きを読み取ることにより、異なるハンドジェスチャおよび日常活動を認識する研究が行われている。Laput ら [2], [3] は、市販のスマートウォッチに内蔵されている加速度計のサンプリングレートを 4000 Hz に向上させることにより、フリック、クラップ、スクラッチ、タップなどのハンドジェスチャ、および、日常活動における手の動きを認識した。また、Xu ら [4] は、少量のデータから既存のジェスチャ認識モデルをカスタマイズすることによって新しいジェスチャを認識できるようにする手法を開発した。これらの関連研究より、我々はスマートウォッチのIMUによるユーザの手首周辺の動きの測定が握力推定にも応用できると考えた。

3. 手法

本手法の概要を図 1 に示す。本手法はスマートウォッチのIMUに基づき握力を推定する。すなわち、握力に応じて腕から手首にかけて現れる振動をスマートウォッチのIMUにより測定し、このIMU データから抽出される時間領域特徴量および周波数領域特徴量を機械学習モデルへ入力することにより握力を推定する。

4. 提案手法の予備調査

本手法の実現性を確かめるための予備実験を行った

¹ 筑波大学 情報メディア創成学類

² 筑波大学 情報理工学位プログラム

³ 筑波大学 システム情報系

a) thonda@iplab.cs.tsukuba.ac.jp

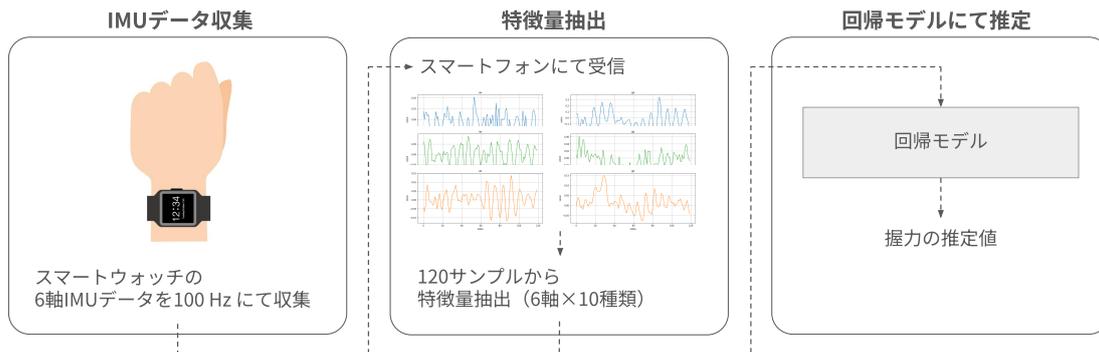


図 1 本手法の概要図.

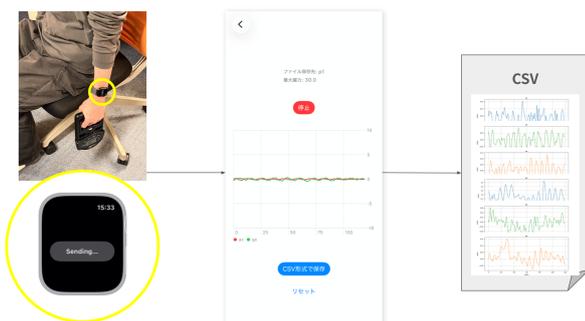


図 2 予備実験における IMU データの流れ.

(図 2). 予備実験では、スマートウォッチの IMU データの収集、データセットの作成、および機械学習モデルの構築を行った。

4.1 IMU データの収集

IMU データの収集には、スマートフォン (Apple iPhone 13) およびスマートフォンと Bluetooth によりペアリングされたスマートウォッチ (Apple Watch Series 9) を使用した。また、デジタル握力計として N-FORCE HG-251^{*1} を使用した。

IMU データは、スマートウォッチにおいて 100 Hz にて x, y, z 軸まわりの加速度および角速度が計測される。計測された 6 軸データはペアリングされたスマートフォンへ送信される。スマートフォンにて受信された IMU データは直近 120 サンプルが一時的に記録され、それより過去のデータは破棄される。この 120 サンプルを任意のタイミングにて 1 つの CSV ファイルとしてスマートフォン内に保存することができる。このとき、ラベルとしてデジタル握力計に表示される値を記録する。

以上により得られた CSV ファイル群を PC (Apple MacBook Pro M4 Pro) へ送信した後、PC において握力推定のためのデータセットの作成および機械学習モデルの構築を行う。

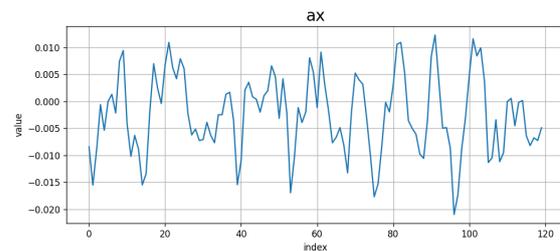


図 3 x 軸まわりの加速度データの例.

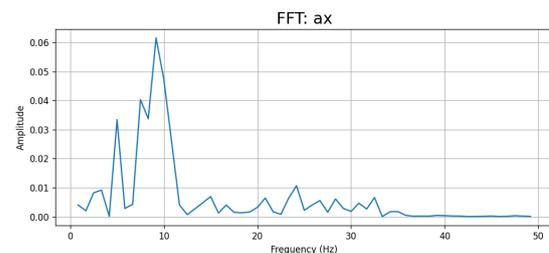


図 4 図 3 のデータに FFT を行った信号.

4.2 データセット作成

各 CSV ファイルには 6 軸の IMU データが 120 サンプル保存されている。例としてある CSV ファイルにおける x 軸まわりの加速度データをプロットしたものを図 3 に示す。

まず、モデル学習用のデータセットを作成するにあたり、それぞれの CSV ファイルから各軸についての時間領域特徴および周波数領域特徴を抽出した後、目標値をラベル付けする。具体的には、時間領域特徴には平均、標準偏差、振幅、二乗平均平方根およびピーク数を使用した。ピーク数は Python の scipy ライブラリに含まれる find_peaks 関数により検出されたピークの数である。また、周波数領域特徴には 10 Hz ごとのパワーバンドを使用した。パワーバンドは、図 4 に示されるように FFT により 0-50 Hz の範囲に変換された各軸のデータについて、0-10 Hz, 10-20 Hz のような 10 Hz の幅に含まれるパワーの総和である [6]。以上により、6 軸について 10 種類ずつ抽出した合計 60 種類の特徴量を入力として扱う。

^{*1} <https://www.n-force.co.jp/home-1>

4.3 機械学習モデルの構築

PC 上にて Python の scikit-learn ライブラリを用いて、6 種類の回帰モデルについてそれぞれ k-Fold 交差検証による機械学習を行う。回帰モデルには線形回帰、Ridge 回帰、Lasso 回帰、ElasticNet、RandomForest、およびサポートベクタ回帰 (SVR) の 6 種類を使用した。回帰モデルのハイパーパラメータには GridSearch によるパラメータチューニングを施すほか、SVR のカーネルには rbf を指定した。また、交差検証の分割数については $k=5$ とした。

各 Fold における機械学習の流れは次の通りである。まず、得られたデータセットを訓練データ 80% およびテストデータ 20% に分割する。次に平均 0、分散 1 に標準化した訓練データを用いて機械学習モデルの学習を行う。その後、得られたモデルおよびテストデータを用いて目標値の予測を行った後、決定係数 (R^2) および平均絶対値誤差 (MAE) を計算し保存する。

6 種類の回帰モデルそれぞれについて、その各 Fold にて計算された R^2 および MAE の平均を最終的な評価とするほか、目標値の予測値および真値をすべてプロットした散布図を描画することによってモデルの性能を比較する。

4.4 予備実験

本手法の精度を評価するための予備実験として、著者 1 名に対してデータ収集を行った後、得られた 46 個の IMU データに基づいて握力推定を行った。データ収集時、実験参加者は左腕にスマートウォッチを装着した状態にて、まっすぐ腕を下ろした状態にて椅子に座った後、手元のデジタル握力計を握った。このとき、ユーザは握り始めから握力を徐々に強めていき、ある一定の握力をなるべく維持するように指示された。目標値として得られた握力の範囲は 6.1–24.5 kg であった。

それぞれの回帰モデルによる機械学習を行った結果を図 5 に示す。各散布図は横軸が予測値、ならびに縦軸が真値 (単位: kg) である。また、タイトルには使用した回帰モデルの種類およびその評価値が記載されている。もっとも結果が優れているのは RandomForest による回帰であり、 R^2 および MAE とともに 6 種類の回帰モデルのうち最も良い数値を示している。

5. 考察・議論

予備実験の結果より、スマートウォッチの IMU に基づく握力推定の実現可能性が示唆された。特に今回は回帰モデルを用いた単純な推定を行ったが、図 5 に示されるように、予測値および真値の間には右上がりの線形関係が確認される。したがって、一定の誤差はあるものの握力を推定できていると考えられる。また、ニューラルネットワークもしくは深層学習を導入することにより推定精度のさらなる向上が期待される。

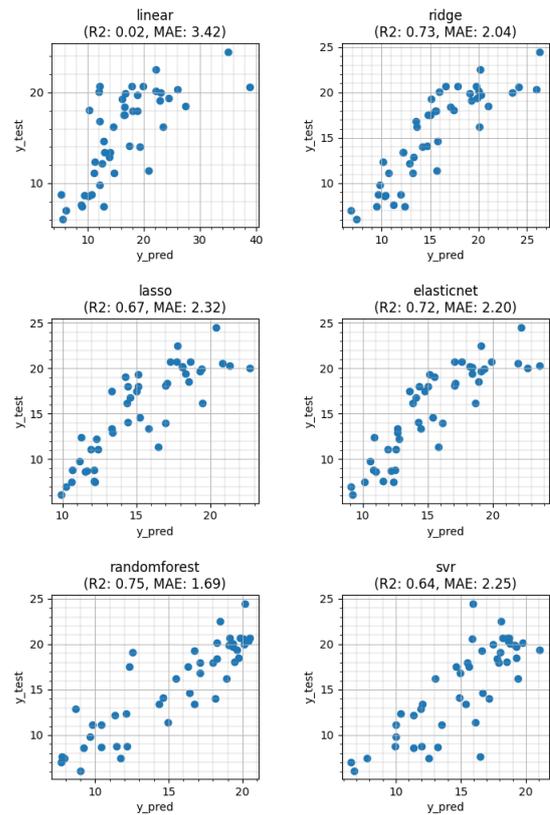


図 5 真値および 6 種類の回帰モデルによる予測値を示す散布図。

今後の展望としては、複数のユーザに対しても握力推定を行うことを目指すほか、リアルタイムにてユーザの握力を推定することによって、ジェスチャ認識によるデバイスの操作およびリハビリテーションへの応用を目指す。

一方、課題としては、デジタル握力計を使用したデータ収集方法がまだ確立しておらず、ある握力の表示値に対して IMU データが実際に示す値にどのようなばらつきが現れるのか不明な点が挙げられる。本手法にて使用したデジタル握力計はユーザの瞬間的な最大握力を計測することを目的に設計された一般的なものであり、ある一定区間の継続的な握力を推定することを目的とする本手法とは用途が異なっている。したがって、握力の真の値および表示値間の誤差を緩和するための本手法への改善が必要である。

また、異なるユーザに対して握力推定を行うためには本手法ではまだ不十分である。IMU データ収集においてユーザごとの体格、姿勢、および運動能力の違いなどから生じる IMU データの差異を吸収するために、少数サンプルによるキャリブレーション段階を設けることによって個人最適化を行うことが考えられる。また、ユーザによらない共通の機械学習モデルを利用できるように、モデル学習の手法についても改善を進める必要がある。

6. まとめ

本稿では、スマートフォンもしくは外部の圧力センサによらない握力推定を実現するため、スマートウォッチのIMUに基づく握力推定手法を提案した。我々は、ユーザがデジタル握力計をある一定の力にて握っているときのスマートウォッチのIMUデータを保存した後、時間領域特徴、周波数領域特徴および目標値からなるデータセットを作成した。著者1名から得られた46段階の握力に対応するIMUデータを用いて機械学習を行った結果、RandomForestによる回帰モデルにおいて、 R^2 が0.75、およびMAEが1.69という精度にて握力が推定できた。今後は複数のユーザに対しても同様の握力推定が行えるよう、さらなるデータ収集ならびに手法の改善を行うほか、リアルタイムでの握力推定の実現を目指す。

参考文献

- [1] Mayank Goel, Jacob Wobbrock, and Shwetak Patel. GripSense: using built-in sensors to detect hand posture and pressure on commodity mobile phones. In *Proceedings of the 25th Annual ACM Symposium on User Interface Software and Technology*, UIST '12, pp. 545–554, New York, NY, USA, 2012. Association for Computing Machinery.
- [2] Gierad Laput and Chris Harrison. Sensing Fine-Grained Hand Activity with Smartwatches. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, CHI '19, pp. 1–13, New York, NY, USA, 2019. Association for Computing Machinery.
- [3] Gierad Laput, Robert Xiao, and Chris Harrison. ViBand: High-Fidelity Bio-Acoustic Sensing Using Commodity Smartwatch Accelerometers. In *Proceedings of the 29th Annual Symposium on User Interface Software and Technology*, UIST '16, pp. 321–333, New York, NY, USA, 2016. Association for Computing Machinery.
- [4] Xuhai Xu, Jun Gong, Carolina Brum, Lilian Liang, Bongsoo Suh, Shivam Kumar Gupta, Yash Agarwal, Laurence Lindsey, Runchang Kang, Behrooz Shahsavari, Tu Nguyen, Heriberto Nieto, Scott E Hudson, Charlie Maalouf, Jax Seyed Mousavi, and Gierad Laput. Enabling Hand Gesture Customization on Wrist-Worn Devices. In *Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems*, CHI '22, pp. 1–19, New York, NY, USA, 2022. Association for Computing Machinery.
- [5] 山本さりい, 池松香, 加藤邦拓, 杉浦裕太. スマートフォンの座標変化による握力測定手法の提案. *インタラクション2023 論文集*, pp. 475–477, 2023.
- [6] 機械学習研究室, 日本大学生産工学部マネジメント工学科. PyLearnSIG03 - 周波数領域の特徴量. <http://int-info.com/PyLearn/PyLearnSIG03.html> [アクセス日: 2025年12月08日].