

筑波大学 情報学群 情報メディア創成学類

卒業研究論文

# スマートウォッチのIMUに基づく握力推定手法

本田 智大

指導教員 志築 文太郎, 川口 一画

2026年2月

## 概要

モバイルデバイスにおける握力推定では、スマートフォンを用いる手法、ならびに圧力センサもしくはRGBカメラなどの外部の計測機器を用いる既存手法がある。これに対して本手法は、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により計測し、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。実装されたシステムにより、本手法の実現可能性を確かめるための予備実験を行った。その結果、6種類の回帰モデルのうちRandomForestによる回帰が最も良い性能を示し、決定係数 ( $R^2$ ) が0.76、および絶対平均誤差 (MAE) が1.64であった。さらに、複数のユーザにも本手法が利用可能であるか調査するための評価実験を行った。その結果、 $R^2$  の平均値が0.66という精度にて握力が推定された。

# 目次

<b>第1章 序論</b>	<b>1</b>
1.1 モバイルデバイスにおける握力推定の課題	1
1.2 目的およびアプローチ	1
1.3 貢献	2
1.4 本論文の構成	2
<b>第2章 関連研究</b>	<b>3</b>
2.1 IMUに基づくジェスチャおよび日常活動の認識	3
2.2 モバイルデバイスによる握力推定	4
2.3 圧力による入力を用いたユーザインタフェース	4
<b>第3章 スマートウォッチのIMUに基づく握力推定手法</b>	<b>6</b>
3.1 本手法の設計	6
3.2 実装	6
3.2.1 実装環境	7
3.2.2 システム構成	8
3.2.3 IMU データ収集	10
3.2.4 機械学習	10
<b>第4章 予備実験</b>	<b>12</b>
4.1 IMU データの収集	12
4.2 機械学習モデルの構築	14
4.3 結果および考察	14
<b>第5章 複数ユーザに対する本手法の握力推定性能の評価実験</b>	<b>15</b>
5.1 IMU データ収集実験	15
5.1.1 参加者	15
5.1.2 実験手順	15
5.1.3 結果	16
5.2 機械学習モデルの構築	17
5.2.1 評価指標	17
5.2.2 結果および考察	17

<b>第 6 章</b>	<b>議論</b>	<b>23</b>
6.1	課題および改善点 . . . . .	23
6.1.1	データ収集における握力の測定方法 . . . . .	23
6.1.2	データ収集における IMU データの測定方法 . . . . .	23
6.1.3	IMU データのサンプル数および多様性 . . . . .	24
6.1.4	機械学習 . . . . .	24
6.1.5	リアルタイム推定 . . . . .	24
6.2	本研究の応用 . . . . .	25
<b>第 7 章</b>	<b>結論</b>	<b>26</b>
	謝辞	27
	参考文献	29
付録 A	機械学習モデルのハイパーパラメータ	33
付録 B	実験前アンケート	36
付録 C	評価実験手順書	38

# 目次

3.1	本手法の概要.	6
3.2	本手法の実装にて使用したデジタル握力計 (HG-251).	7
3.3	スマートウォッチ用アプリケーションの画面.	8
3.4	待機中のスマートフォン用アプリケーションの画面.	9
3.5	IMU データを受信中のスマートフォン用アプリケーションの画面.	9
3.6	x 軸まわりの加速度データの例.	10
3.7	図 3.6 に示した信号の周波数スペクトル.	11
4.1	データ収集の様子.	12
4.2	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.	13
5.1	Leave-one-participant-out 交差検証の結果.	18
5.2	参加者内の 4 分割交差検証の結果.	19
5.3	参加者内の leave-one-session-out 交差検証の結果.	20
5.4	セッション内の leave-one-out 交差検証の結果.	21
A.1	GridSearch におけるパラメータの候補を示すソースコード.	34
B.1	評価実験にて使用した実験前アンケート.	37
C.1	評価実験にて使用した実験手順書 (1/2).	39
C.2	評価実験にて使用した実験手順書 (2/2).	40

# 表目次

5.1	参加者1の握力値 (kg) の統計. . . . .	16
5.2	参加者2の握力値 (kg) の統計. . . . .	16
5.3	参加者3の握力値 (kg) の統計. . . . .	16
A.1	決定されたパラメータ. . . . .	35

# 第1章 序論

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ヘルスケアへの活用という点にて需要がある [AAMA22, AMA<sup>+</sup>18]. 例えば、スマートフォンのアプリケーション開発者は、スマートフォンを握ることにより「戻る」等の操作を行うことができるユーザインタフェースが実装できる [塚本 13]. また、動力計により計測される握力の強さは、その予測妥当性および単純性から、中年および高齢者にとって有用なバイタルサインとみなされる [Boh08]. 本論文においては、このような握力推定における課題に焦点を当てる. また、その課題を解決するための手法を示す.

本章では、モバイルデバイスにおける握力推定の課題、本研究の目的およびアプローチ、本研究の貢献、ならびに本論文の構成を示す.

## 1.1 モバイルデバイスにおける握力推定の課題

握力推定では、スマートフォンを用いる手法、ならびに圧力センサもしくはRGBカメラなどの外部の計測機器を用いる手法がある [FT17, GWP12, MFS21, 塚本 13, 山本 23] が、一般的に普及しているウェアラブルデバイスであるスマートウォッチに注目した研究は少ない. 一方で、Laput らの手法 [LXH16] および Xu らの手法 [XGB<sup>+</sup>22] 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) により計測される手首周辺の微細な動きに基づいて、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.

## 1.2 目的およびアプローチ

本研究の目的は、スマートウォッチの IMU に基づいた握力推定を行うことである.

これを実現するために、スマートウォッチに内蔵されている IMU データの収集および機械学習モデルの構築による握力推定手法を設計および実装した. 具体的には、スマートウォッチおよびペアリングされたスマートフォンを用いた IMU データ収集アプリケーションを実装した. さらに、デジタル握力計および IMU データ収集アプリケーションにより収集されたデータから、ラップトップ PC 上において特徴量抽出および機械学習モデルの構築を行うプログラムを作成した.

実装した握力推定手法を用いることにより、本手法による握力推定の実現可能性を調査するための予備実験、ならびに本手法の複数ユーザへの対応について調査する評価実験を実施

した.

### 1.3 貢献

本研究の貢献を以下に示す.

- スマートウォッチの IMU に基づく握力推定手法を設計および実装した.
- 握力推定を目的とする複数の回帰モデルの性能を比較した.
- 複数ユーザに対する本手法を用いた握力推定の精度を示した.
- 実験結果をもとに本手法の改善点を示した.

### 1.4 本論文の構成

本論文の構成を示す. 第 1 章では本研究の背景, 目的およびアプローチを示した. また, 本研究の貢献および本論文の構成を示した. 第 2 章では, 本研究の関連研究を述べ, 本研究の位置付けを示す. 第 3 章では, スマートウォッチの IMU に基づく握力推定手法の提案, および実装を示す. 第 4 章では, 本手法に対して行った予備実験の内容および実験結果を示す. 第 5 章では, 複数ユーザに対する本手法の実現可能性について調査した評価実験の内容および実験結果を示し, 得られた結果に対する考察を述べる. 第 6 章では, 本手法の改善および応用可能性に関する議論, ならびに本研究の今後を示す. 第 7 章では, 本研究の結論を述べる.

## 第2章 関連研究

本研究において示す手法は、スマートウォッチのIMUデータを用いた機械学習モデルを構築することにより、モバイルデバイスにおける握力推定を実現するものである。したがって、本章では機械学習を用いたIMUに基づくジェスチャおよび日常活動の認識に関する研究を述べると同時に、モバイルデバイスにおける握力推定手法に関する研究を述べ、本研究を位置付ける。さらに、本研究の応用先の例として、圧力入力をユーザインタフェースおよびヘルステックに活用した研究を述べる。

### 2.1 IMUに基づくジェスチャおよび日常活動の認識

IMUに基づいて人間の動きを読み取ることにより、さまざまな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 [LXH16, LH19] 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、ならびに日常活動における拍手、歯磨きなどの手の動きを認識する手法を実装した。Xuら [XGB<sup>+</sup>22] は、スマートウォッチのIMUに基づき事前に訓練されたジェスチャ認識モデルを少量のデータによってカスタマイズすることを可能にする手法を開発し、またそれによって動的に新しいジェスチャを認識できるモデルを訓練する手法を示した。Kunwarら [KBB<sup>+</sup>22] は、手首を左右に振ったり、傾けたりなどのさまざまなハンドジェスチャ、および身体の姿勢およびスマートウォッチの巻き付け具合によるユーザ変動を網羅したデータを収集し、また、省資源でも動作する高精度な畳み込みニューラルネットワーク (CNN) を設計することによって、スマートウォッチにおける堅牢かつ実用的なジェスチャ認識を実現した。Alteaimiら [AAMA22] は、手の向きおよび指の本数などにより示される静的なハンドジェスチャを高精度にて認識するために、複数の分類器を組み合わせて認識を行ったのち多数決法によって最終的な結果を出力するというアンサンブル学習手法を提案した。Laußら [LEP22] は、IMUに基づくハンドジェスチャ認識を低消費電力のマイクロコントローラ上に実装するために、長短期記憶ネットワークによる機械学習モデルを8 bit 整数データに量子化することにより、量子化前のモデルのジェスチャ認識の精度およびスループット時間を保った状態にてメモリ容量を削減する手法を提案した。Davidsonら [DVS<sup>+</sup>19] およびSharmaら [SDMP21] は、歩行分析における垂直地面反力 (vGRF) およびその他のパラメータを屋外環境にて推定するために、ウェアラブルINS/GPS記録計に基づく歩行特徴量抽出手法およびパラメータ推定手法を示した。

これらの研究より、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計測が握力

推定にも応用できると考えた。

## 2.2 モバイルデバイスによる握力推定

モバイルデバイスを利用し、握力を推定する研究が行われている。Goelら [GWP12] 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手法を提案した。塚本ら [塚本13] は、圧力計測が可能な触覚センサを用いることにより、スマートフォンの端末形状を変えずにユーザの把持特徴を検知できる端末の実装を示した。Funatoら [FT17] は、手首装着型デバイスおよび勾配ブースティング回帰木を用いることにより、アクティブ骨導音センシングに基づくリアルタイムの握力推定を行う手法を提案した。Matsumotoら [MFS21] は、単眼カメラおよびソフトテニスボールを用いて、ボールを握ったときの指関節の角度に基づいた回帰モデルの構築によりボールの空気圧および握力を推定する手法を提案した。山本ら [山本23] は、スマートフォン上に安価かつ簡易な握力計測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計測する手法を提案した。

これらの研究に対して、本研究はスマートウォッチのIMUに基づく握力推定の実現可能性、ならびにその性能について調査する。

## 2.3 圧力による入力を用いたユーザインタフェース

圧力による入力を用いたユーザインタフェースに関する研究が行われている。Stewartら [SRKE10] は、モバイルデバイスにおける圧力入力を用いたユーザインタフェースについて、センサから得られる圧力値を入力へ変換するときの伝達関数、およびデバイスに圧力を与える手の姿勢について、どれが最も優れた性能を持つか、ならびに圧力入力に伴う非視覚的フィードバックについて、ユーザスタディを実施することにより圧力入力の基礎的な特性を明らかにした。Arifら [AS13] は、スマートフォンにおいて2段階の圧力を検出したのち、テキスト入力において、誤った予測を圧力に基づき回避できるような入力手法を提案した。Arifら [AMS14] は、スマートフォンにおけるPINに圧力入力を加えた新しいユーザ認証技術を提案した。McLachlanら [MB15] は、タブレット端末のタッチスクリーンにおける両手入力手法として、非利き手による圧力入力および利き手によるピンチ、スワイプ、回転ジェスチャ入力を組み合わせた入力手法の精度を調査した。Hsiuら [HHC<sup>+</sup>16] は、スマートウォッチにおけるタッチキーボードの入力手法として、QWERTYキーボードの隣接する2つのキーを1つの領域に結合したキーに対して力入力によりいずれかの文字を選択する手法を提案した。Corstenら [CDVB17] は、横向きに把持したスマートフォンの背面(BoD)を使用した圧力入力手法のユーザ性能を調査したのち、BoD圧力入力の設計ガイドラインを示した。Adamsら [AMA<sup>+</sup>18] は、慢性疼痛の患者が痛みの強さを自己申告するための、圧力に基づく新しいタンジブルユーザインタフェースを設計、開発および評価した。Suzukiら [SSSO18] は、スマートフォンの片手操作において圧力感知に基づくズームアウトを行うインタフェースを実

装したのち、既存の地図アプリが備えるインタフェースを基準としてその性能を比較評価した。Wang ら [MGM<sup>+</sup>23] は、モバイルデバイス上にて圧力に基づくユーザインタフェースを設計するために、スマートフォンの画面のタッチ圧力に基づくターゲティングタスクを実施した。Kim ら [KKL24] は、圧力を検知可能な球形のタンジブルデバイスを製作したのち、仮想現実環境におけるメニュー選択ならびにオブジェクト操作、移動、およびテキスト入力タスクを圧力入力を用いて実行するアプリケーションを実装した。

これらの研究および本研究の間には圧力入力という共通点があるため、以上を参考にしながら、ターゲティングタスクによる本研究の握力推定を用いた入力性能の評価、ならびにテキスト入力、ジェスチャ入力などの状況において握力推定をユーザインタフェースへ応用することが考えられる。

## 第3章 スマートウォッチのIMUに基づく握力推定手法




図 3.1: 本手法の概要.

本システムの概要図を図 3.1 に示す. 本手法は, 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 により計測し, 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. 本章では, 本手法の設計および実装を示す.

### 3.1 本手法の設計

スマートウォッチの IMU に基づく握力推定を実現するため, スマートウォッチおよびスマートフォンから構成される IMU データ収集アプリケーションを実装したのち, ラップトップ PC において機械学習モデルの構築を行った.

### 3.2 実装

本節では, 本手法の実装に用いた実装環境, および実装の詳細を示す.



図 3.2: 本手法の実装にて使用したデジタル握力計 (HG-251).

### 3.2.1 実装環境

本手法の実装に使用したハードウェアを以下に示す。

- デジタル握力計：N-FORCE HG-251 (図 3.2)
- スマートウォッチ：Apple Watch Series 9 (41 mm モデル)
  - OS：watchOS 26.2
  - プロセッサ：Apple S9
  - ストレージ：64 GB
  - IMU センサ内蔵
- スマートフォン：Apple iPhone 13
  - OS：iOS 26.1
  - プロセッサ：Apple A15 Bionic
  - ストレージ：256 GB
- ラップトップ PC：MacBook Pro (14 インチ, 2024 年 11 月)
  - OS：macOS Sequoia 15.7.2


- プロセッサ：Apple M4 Pro
- ストレージ：512 GB

また、本手法の実装に使用したソフトウェアおよびプログラミング言語を以下に示す。

- ソフトウェア
  - XCode 26.1.1
  - Visual Studio Code 1.108.0
- プログラミング言語
  - Swift 6.2.1
  - Python 3.13.2
    - \* ライブラリ：scikit-learn 1.7.2, NumPy 2.2.3, Matplotlib 3.10.1, Pandas 2.3.2

### 3.2.2 システム構成

本システムは、スマートウォッチおよびスマートフォン上にて動作するアプリケーション（以下それぞれ、スマートウォッチ用アプリケーション、スマートフォン用アプリケーション）による IMU データ収集，ならびにラップトップ PC におけるデータセット作成および機械学習から構成される。



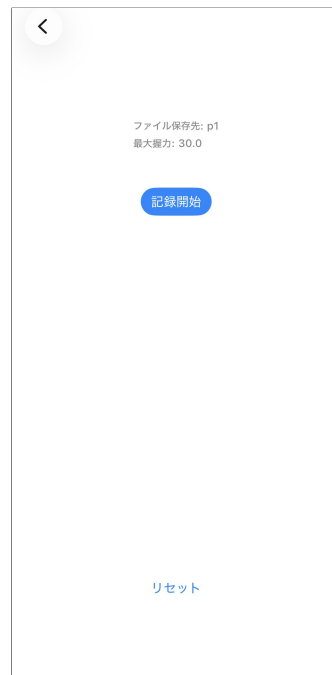
(a) 待機中の画面.

(b) IMU データを計測および送信中の画面.

図 3.3: スマートウォッチ用アプリケーションの画面.




(a) 初期画面.

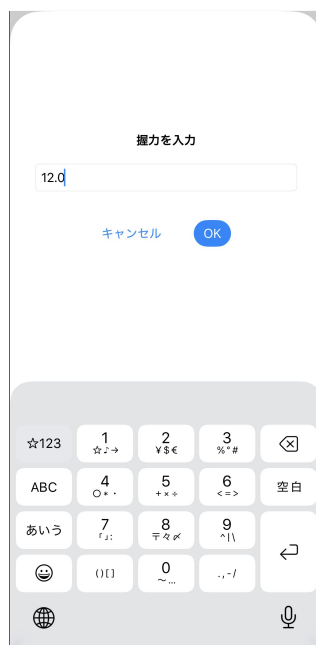


(b) IMU データを受信待機中の画面.


図 3.4: 待機中のスマートフォン用アプリケーションの画面.



(a) IMU データを受信中の画面.



(b) 握力記録用の画面.



(c) データ保存完了時の画面.

図 3.5: IMU データを受信中のスマートフォン用アプリケーションの画面.

### 3.2.3 IMU データ収集

**スマートウォッチ用アプリケーション** スマートウォッチ用アプリケーションの画面を図 3.3 に示す。操作者は画面中央のボタンによって待機状態（図 3.3a）および IMU 計測状態（図 3.3b）を切り替えることができる。本アプリケーションが IMU 計測状態のとき、加速度および角速度についてそれぞれ x, y, z 軸まわりの合計 6 軸のデータが 100 Hz のサンプリングレートにて計測される。システムの軽量化のため、計測された 6 軸 IMU データはスマートウォッチ用アプリケーション内のバッファへ一時保存されたのち、5 サンプルごとにまとめてスマートフォンへ送信される。

**スマートフォン用アプリケーション** スマートフォン用アプリケーションの画面を図 3.4 および図 3.5 に示す。操作者は、データの保存に必要な項目を初期画面（図 3.4a）にて入力したのち決定ボタンを押すことにより、アプリケーションが待機状態（図 3.4b）へ遷移する。この状態にて画面上部の記録開始ボタンを押すと、本アプリケーションはスマートウォッチ用アプリケーションから IMU データを受信する。データの受信状況は図 3.5a および図 3.5c に示される画面中央のグラフから確認される。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。操作者は、スマートウォッチの装着者が握力計測を行ったタイミングにて、この 120 サンプルを 1 つの CSV ファイルとしてスマートフォンのストレージに保存することにより IMU データを記録する。得られる CSV ファイルに対して、図 3.5b に示される画面にて、デジタル握力計に表示されている値を記録する。以上により保存される CSV ファイル群を任意の方法にてラップトップ PC に送信する。

### 3.2.4 機械学習

機械学習は、ラップトップ PC において Python によるデータセットの作成および機械学習モデルの構築により行われる。




図 3.6: x 軸まわりの加速度データの例。

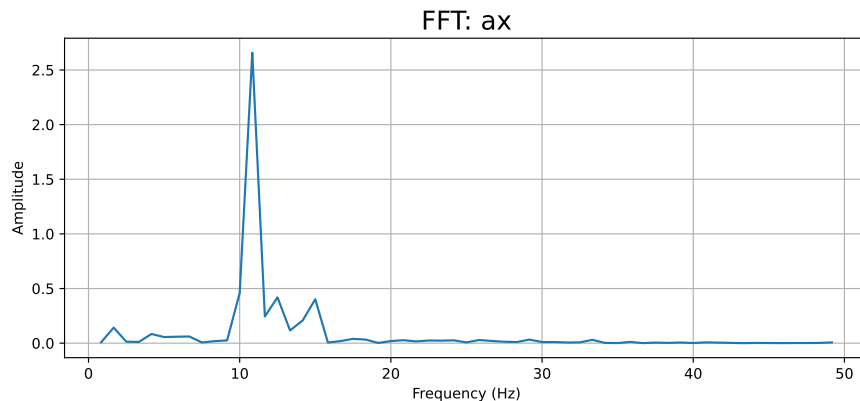


図 3.7: 図 3.6 に示した信号の周波数スペクトル.

**データセットの作成** 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 3.6 に示す。まず、この 6 軸 IMU データの各軸について、時間領域特徴および周波数領域特徴を抽出する。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の 5 種類を使用する。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する。パワーバンドは、図 3.7 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 [機械 18]。以上により、6 軸について 10 種類ずつ、合計 60 種類の特徴量を抽出したのち、ラベルとして握力値を付加することによりデータセットを作成する。

**機械学習モデルの構築** 機械学習モデルの構築の手順については以下の通りである。まず、得られたデータセットを訓練データおよびテストデータに分割する。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。

具体的なデータセットの分割方法および機械学習モデルの種類については、第 4 章および第 5 章にて述べる。

## 第4章 予備実験

本手法の実現可能性を確かめるための予備実験を行った。本実験では、実装したシステムを用いた著者自身の IMU データの収集および機械学習モデルの構築を行った。



図 4.1: データ収集の様子.

### 4.1 IMU データの収集

本実験における IMU データ収集方法について、まず、データ収集アプリケーションを稼働させた状態のスマートウォッチおよびスマートフォンを準備した。次に、図 4.1 に示されるように、椅子に座った状態かつスマートウォッチを装着した左腕を身体の側面にまっすぐ下ろした状態にて左手を用いてデジタル握力計を握った。握り方については、握り始めから徐々に握力を強めていった後、ある一定の握力まで達したらその握力を 2 秒程度維持するように握った。このときの IMU データおよびデジタル握力計の表示値をスマートフォンにて保存した。

著者自身による IMU データ収集の結果、46 個の IMU データおよび握力値が得られた。得られた握力値の統計は、最小値 6.1、最大値 24.5、平均値 15.302、標準偏差 4.972 (いずれも単位: kg) であった。

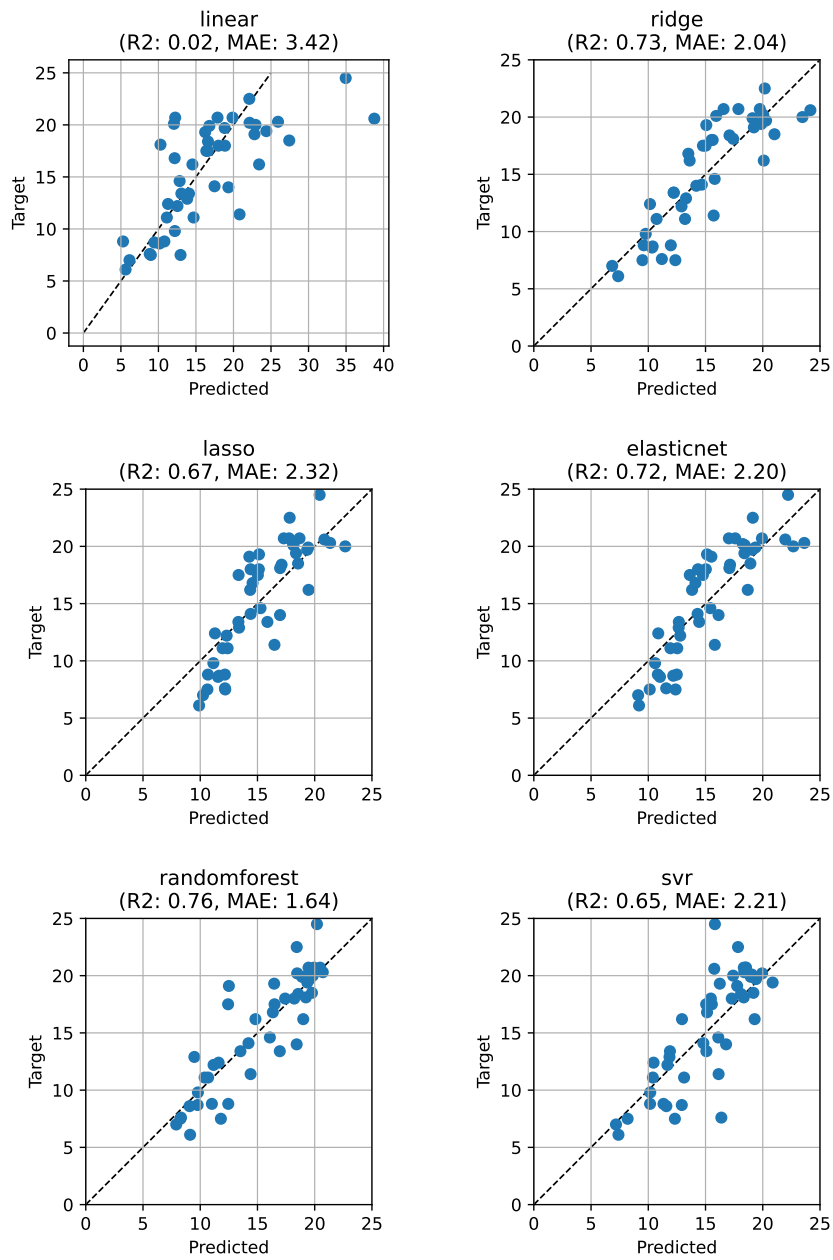


図 4.2: 真値および 6 種類の回帰モデルによる予測値を示す散布図。

## 4.2 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  $k$  分割交差検証による機械学習を行った。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、 $k$  分割交差検証の分割数については  $k=5$  とした。各分割において、データセットを訓練データ 80% およびテストデータ 20% に分割した。これを 5 回繰り返すことにより、全データが 1 回ずつテストデータとなるようにした。

5 回の交差検証それぞれにおいて計算された  $R^2$  および MAE の平均を、回帰モデルの評価とした。

## 4.3 結果および考察

それぞれの回帰モデルによる 5 分割交差検証を行った結果を図 4.2 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。散布図の青い点は回帰モデルの予測結果であり、黒い破線は  $y = x$  の理想線である。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示されている。

散布図を見ると、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。6 種類の回帰モデルのうちもっとも結果が優れているのは RandomForest による回帰であり、 $R^2$  が 0.76、および MAE が 1.64 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。

## 第5章 複数ユーザに対する本手法の握力推定性 能の評価実験

複数のユーザにも本手法が利用可能であるか調査するための評価実験を行った。本実験では、実装したシステムを用いた参加者3名によるIMUデータの収集および機械学習モデルの構築を行った。

### 5.1 IMU データ収集実験

#### 5.1.1 参加者

参加者は研究室内の大学生3名（全員男性，平均22歳）であった。スマートウォッチの利用状況について尋ねた結果，2名が「日常的に利用している」，1名が「利用したことがない」と回答した。

#### 5.1.2 実験手順

本実験を実施するために使用した手順書は付録Cに示す。

参加者は実験前アンケートに回答したのち，実験の目的および内容の説明を受けた。使用したアンケートを付録Bに示す。参加者のスマートウォッチ装着位置の手首周囲の長さおよび最大握力を計測したのち，実験タスクを実施した。

実験タスクにおいて，参加者は予備実験と同様に，椅子に座った状態かつスマートウォッチを装着した左腕を身体の側面にまっすぐ下ろした状態にて左手を用いてデジタル握力計を握る。本タスクは3つのセッションに分かれており，さらに各セッションは12回の試行から構成される。各試行について，まず参加者は握力のレベルを4段階（弱く，中程度，強く，とても強く）から1つ指示される。それに対して，参加者はその指示に応じた握力を2秒程度維持するようにデジタル握力計を握る。このときスマートウォッチにて計測されたIMUデータをスマートフォンにて保存する。また，デジタル握力計に表示された値をラベルとして記録する。各試行において指示される握力は，1つのセッションの全12回の試行においてそれぞれの段階が3回ずつ現れるようにランダムに決定される。セッション間においては最低1分間の休憩をとるとともに，過学習を防ぐためにスマートウォッチの再装着を行う。

注意として、計測された握力がおよそ 5kg 未満のとき、デジタル握力計の仕様上握力値が表示されないことがあった。この場合、参加者の疲労を防ぐため再測定は行わず、その試行における握力値を一律に 3.0kg として記録した。

### 5.1.3 結果

IMU データ収集実験により、3名の参加者から 1人当たり 36個、合計 108個の IMU データおよび握力値が得られた。各参加者の握力値の統計を以下に示す。

表 5.1: 参加者 1 の握力値 (kg) の統計.

セッション	最小	最大	平均	標準偏差
1	3.0	24.1	10.025	8.396
2	2.7	24.2	8.958	8.201
3	3.0	20.6	8.092	6.587
全体	2.7	24.2	9.025	7.588

表 5.2: 参加者 2 の握力値 (kg) の統計.

セッション	最小	最大	平均	標準偏差
1	3.0	18.1	10.108	5.022
2	7.0	19.5	13.267	4.316
3	7.2	23.1	13.375	4.759
全体	3.0	23.1	12.250	4.823

表 5.3: 参加者 3 の握力値 (kg) の統計.

セッション	最小	最大	平均	標準偏差
1	2.0	19.8	9.892	5.813
2	2.4	19.6	10.025	5.919
3	4.2	19.6	11.033	5.963
全体	2.0	19.8	10.317	5.751

## 5.2 機械学習モデルの構築

PC 上にて Python の scikit-learn ライブラリを用いた機械学習を行った。機械学習モデルについて、第 4 章にて示した予備実験の結果より、もっとも推定性能が良かった回帰モデルとして RandomForest を採用した。

### 5.2.1 評価指標


合計 108 個の IMU データ全体を用いた推定性能および参加者間の推定性能を調査するために、leave-one-participant-out 交差検証を行った。また、参加者内の推定性能を調査するために 4 分割交差検証を行った。各分割において、データセットを訓練データ 75% およびテストデータ 25% に分割した。さらに、参加者内の疲労もしくはスマートウォッチの再装着が推定性能に与える影響を調査するために、leave-one-session-out 交差検証を行った。最後に、少ないサンプル数による推定性能を調査するために、セッション内において leave-one-out 交差検証を行った。

### 5.2.2 結果および考察


交差検証の結果を図 5.1, 図 5.2, 図 5.3, および図 5.4 に示す。各散布図において、横軸は予測値、ならびに縦軸は真値 (単位: kg) を表す。

**Leave-One-Participant-Out 交差検証** 結果を図 5.1 に示す。 $R^2$  の平均値は 0.66 であった。複数の参加者にまたがるデータを用いた機械学習においてもある程度の推定性能を示したことから、本手法にて構築したモデルは一定の汎化性能を備えていると考えられる。また、各参加者について  $R^2$  はそれぞれ 0.74, 0.45, 0.80 であった。参加者 2 について他の 2 名よりも低い精度が出ていることから、学習に使用した特徴量には個人差が存在すると考えられる。参加者 2 の散布図を見ると、プロットされた点は理想線より右側に多く分布していることから、参加者 2 の握力が実際の値よりも高く推定される傾向にあることが分かる。ここで、表 5.2 に示される握力値を見ると、参加者 2 は参加者の中でもっとも握力値の平均が高い。したがって、モデルの構築には参加者個人の握力に由来する影響があると考えられる。


**参加者内の 4 分割交差検証** 結果を図 5.2 に示す。各参加者について、 $R^2$  はそれぞれ 0.90, 0.53, 0.83 であった。いずれも参加者間の交差検証を行ったときよりも性能に向上が見られることから、本手法の個人差の大きさ、ならびに個人最適化の有用性が示された。参加者 2 について、 $R^2$  は外れ値の影響を大きく受けたため低い値になっていると考えられる。また、参加者 1, 3 の  $R^2$  は第 4 章にて示した予備実験の交差検証にて示された値 (0.76) よりも高い値となっている。



(a) 参加者 1 のデータに対する推定性能.




(b) 参加者 2 のデータに対する推定性能.




(c) 参加者 3 のデータに対する推定性能.


図 5.1: Leave-one-participant-out 交差検証の結果.



(a) 参加者 1 のデータに対する推定性能.

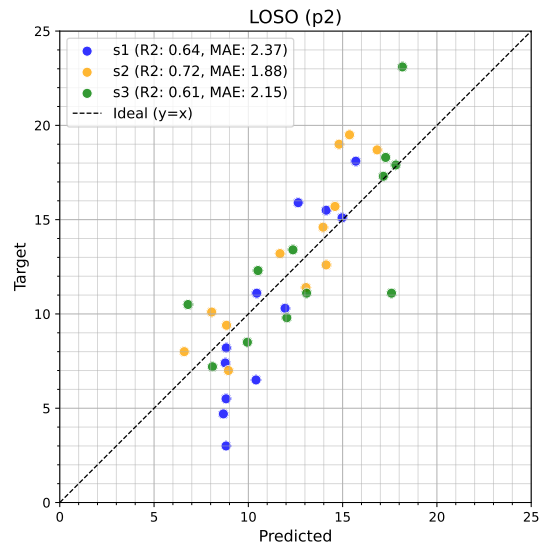



(b) 参加者 2 のデータに対する推定性能.

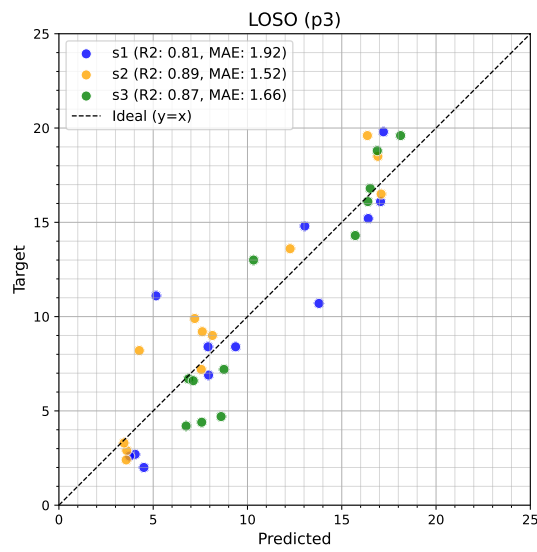


(c) 参加者 3 のデータに対する推定性能.

図 5.2: 参加者内の 4 分割交差検証の結果.

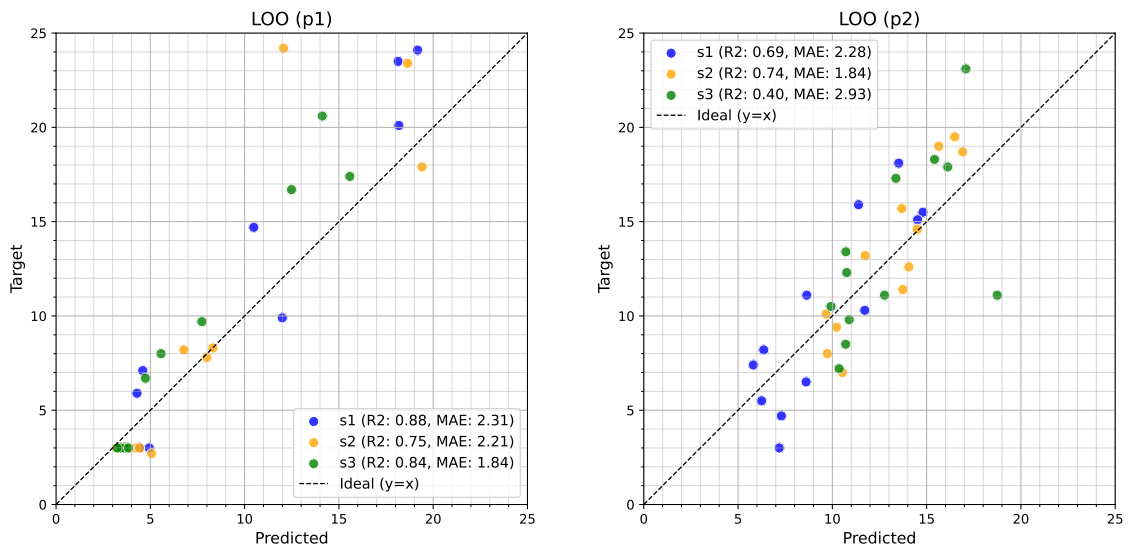


(a) 参加者 1 の各セッションのデータに対する推定性能. (b) 参加者 2 の各セッションのデータに対する推定性能.




(c) 参加者 3 の各セッションのデータに対する推定性能.

図 5.3: 参加者内の leave-one-session-out 交差検証の結果.



(a) 参加者 1 の各セッションのデータに対する推定性能. (b) 参加者 2 の各セッションのデータに対する推定性能.



(c) 参加者 3 の各セッションのデータに対する推定性能.

図 5.4: セッション内の leave-one-out 交差検証の結果.

**参加者内の Leave-One-Session-Out 交差検証** 結果を図 5.3 に示す。  $R^2$  は、参加者ごとにそれぞれ平均して 0.89, 0.66, 0.86 であった。 4 分割交差検証と比較して同等もしくは高い推定性能を持つことから、本手法にて構築したモデルは、参加者の疲労もしくはスマートウォッチの再装着を代表とするセッション間の変動に堅牢であると考えられる。

**セッション内の Leave-One-Out 交差検証** 結果を図 5.4 に示す。  $R^2$  は、参加者ごとにそれぞれ平均して 0.82, 0.61, 0.79 であった。 いずれの参加者についても 0.6 以上の  $R^2$  値をとっており、少ないサンプル数によるモデル構築においても一定の推定性能を持つことが示された。 参加者 2 のセッション 3 における推定性能がもっとも低くなっている点について、データ収集実験における疲労もしくは慣れの影響によって、一貫性のない不安定なデータが収集されたことが考えられる。 また、散布図にて見られる極端な外れ値 2 点がいずれもセッション 3 のものであることから、参加者 2 のデータを用いた機械学習モデルについては、本外れ値を除去することによる推定性能の改善が見込まれる。

## 第6章 議論

本章では、本手法における課題および改善案に関する議論，ならびに本研究の今後について述べる．また，本研究の応用について述べる．

### 6.1 課題および改善点

#### 6.1.1 データ収集における握力の測定方法

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である．本手法にて使用したデジタル握力計（図 3.2）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．加えて，デジタル握力計によるデータ収集時，およそ 5 kg に満たない弱い握力が計測されたときに測定結果としての握力値が表示されないことがあったため，本実験における安定した握力値の記録が困難であった．したがって，データ収集段階においてリアルタイムの握力測定およびデータ送信が可能な測定器具を利用することによる本手法への改善が考えられる．具体的には，握力の測定器具としてデジタル握力計でなくアナログ握力計を使用する方法，もしくは力覚センサによるセンシングにより握力の真値を収集する方法が考えられる，

#### 6.1.2 データ収集における IMU データの測定方法

本研究における IMU データの測定方法について，予備実験および評価実験のいずれもスマートウォッチを装着した左腕を身体の側面にまっすぐ下ろした状態にて左手を用いてデジタル握力計を握るようにユーザの姿勢を指示した．そのため，その他の姿勢においても本手法による握力推定が可能であるかどうか不明である．本手法をその他の姿勢へ拡張するために，姿勢に依らない IMU データを収集することが考えられる．また，これを実現するための手法として，データ測定時の手首および腕の向きに基づく IMU データの補正，および重力成分の除去が考えられる．

### 6.1.3 IMU データのサンプル数および多様性

本研究において収集した IMU データは、第 4 章の予備実験にて 46 個、また第 5 章の評価実験にて 108 個である。また、いずれも研究室内の大学生を対象にデータ収集を行った。そのため、本手法を実運用するのに十分な IMU データを得られなかったほか、実験参加者の年齢および性別に偏りが生じた。したがって、今後実験を行う場合、さまざまな属性の参加者に対して実験を行うことにより正確な実験結果が得られると考えられる。

### 6.1.4 機械学習

本研究では、第 4 章に示したように、6 種類の回帰モデルの単純な実装による握力推定を行った。また、第 5 章に示したように、RandomForest 回帰モデルを使用した複数の交差検証を行った。これに対する改善点として、ニューラルネットワークによる深層学習の導入により、推定性能の向上が期待される。

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。第 5 章に示した評価実験より、IMU データおよび抽出される特徴量には個人差があることが示唆された。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、握力推定を行う前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 [MSI24] が考えられる。

### 6.1.5 リアルタイム推定

本研究では、IMU データ収集アプリケーションおよび機械学習プログラムはそれぞれ独立した処理として実装されており、データ収集後にオフラインにて機械学習を行っている。しかし、本手法を用いた握力入力ユーザインタフェースによるデバイスの操作およびヘルスケアへの応用のためには、リアルタイムの握力推定が必要である。そのため、今後、本研究にて実装した IMU データ収集から握力推定までを統合したシステムを構築することにより、リアルタイムにてユーザの握力を推定することを目指す。

## 6.2 本研究の応用

本研究は、スマートウォッチのIMUに基づく握力推定手法の予備実験および評価実験を行うことに留まっており、本手法を用いたアプリケーションの実装は行っていない。本手法の応用先として、ユーザインタフェースおよびヘルスケアへの応用が考えられる。特に、ユーザインタフェースへの応用について、2.3節に示した通り、圧力入力を用いたユーザインタフェースに関する研究が多く行われている。これらの研究は、モバイルデバイスに対する圧力入力について、スクロール [SSSO18]、テキスト入力 [AS13, HHC<sup>+</sup>16, KKL24]、およびメニュー選択 [KKL24] など、多様な応用が可能であることを示している。また、本手法による握力推定は、操作対象となるモバイルデバイスに直接入力を行わなくても推定が可能であるという特徴がある。したがって、本手法をユーザインタフェースに応用する例として、握力の強さに応じたスクロール速度の制御、もしくは画面操作を伴わない入力手段としてバックグラウンドにおけるコマンド入力の提供などが考えられる。

今後、本手法を用いた応用アプリケーションを実装し、ユーザ実験を通じてそのユーザビリティを従来手法と比較評価する。

## 第7章 結論

本研究の目的は、スマートウォッチのIMUに基づく握力推定を行うことである。そのために、スマートウォッチのIMUデータを収集するアプリケーションを実装したのち、機械学習モデルによる握力の推定を行った。著者自身による予備実験の結果、46個のIMUデータを用いたRandomForest回帰モデルにおいて $R^2$ が0.76、およびMAEが1.64の推定性能が示された。また、参加者3名による研究室内実験の結果、合計108個のIMUデータに基づく握力推定により平均 $R^2$ が0.66（範囲：0.45–0.80）の推定性能が示された。今後、リアルタイムの握力推定の実装を進めるほか、データ収集および機械学習の改善による握力推定性能の向上に努める。

## 謝辞

本研究を進めるにあたり，志築文太郎先生，川口一画先生，高橋伸先生には多大なご意見とご指導を頂きました。心から感謝申し上げます。特に志築文太郎先生には，研究の進め方，および論文執筆の仕方をはじめとして，研究に関することを一からご指導頂きました。さらに，研究の相談および研究生活において，多くのご助言およびご指南を頂きました。ここに深く感謝の意を表します。

インタラクティブプログラミング研究室の同輩，先輩方には研究生活において大変お世話になりました。WAVE チームの皆様にはチームゼミにおけるご意見および論文の添削に加えて，研究生活に関しても多くのご助言を頂きました。心より感謝いたします。特に，白根薫氏には研究方針および論文執筆など本研究における重要な部分において多くのアドバイスを頂き大変お世話になりました。重ねて感謝申し上げます。COMMUNICATION チームの皆様にも，研究生活において多くのご意見とご支援を頂きました。また，評価実験に参加していただいた方々に深く感謝いたします。

最後に，学生生活においてお世話になった皆様，そして金銭的および精神的に私の学生生活を支えてくださった家族に深く感謝申し上げます。

# 著者論文リスト

## 本論文に関する論文

- 査読なし国内会議論文

1. 本田智大, 白根薫, 志築文太郎. スマートウォッチのIMUに基づく握力推定手法の提案. インタラクション 2026, 第30回一般社団法人情報処理学会シンポジウム, 2026年3月, 4 pages.

## その他の論文

- 査読付き国際会議論文

1. Kaoru Shirane, Riku Tsunoda, Hiroki Matsuda, Yuto Wada, Takumi Masuda, Tomohiro Honda, Kaori Ikematsu, and Buntarou Shizuki. Preliminary Study on the Effects of On-Screen Tactile Feedback on Virtual Joystick Interaction. In Proceedings of the 37th Australian Conference on Human-Computer Interaction (OzCHI '25). Association for Computing Machinery, New York, NY, USA, pp. 828–835.  
<https://dl.acm.org/doi/10.1145/3764687.3769934>

## 参考文献

- [AAMA22] Mohamed Tahar Ben Othman Amal Abdullah Mohammed Alteaimi. Robust Interactive Method for Hand Gestures Recognition Using Machine Learning. *Computers, Materials & Continua*, Vol. 72, No. 1, pp. 577–595, 2022.
- [AMA<sup>+</sup>18] Alexander T. Adams, Elizabeth L. Murnane, Phil Adams, Michael Elfenbein, Pamara F. Chang, Shruti Sannon, Geri Gay, and Tanzeem Choudhury. Keppi: A Tangible User Interface for Self-Reporting Pain. In *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems*, CHI '18, pp. 1–13, New York, NY, USA, 2018. Association for Computing Machinery.
- [AMS14] Ahmed Sabbir Arif, Ali Mazalek, and Wolfgang Stuerzlinger. The use of pseudo pressure in authenticating smartphone users. In *Proceedings of the 11th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, MOBIQUITOUS '14, pp. 151–160, Brussels, BEL, 2014. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering).
- [AS13] Ahmed Sabbir Arif and Wolfgang Stuerzlinger. Pseudo-pressure detection and its use in predictive text entry on touchscreens. In *Proceedings of the 25th Australian Computer-Human Interaction Conference: Augmentation, Application, Innovation, Collaboration*, OzCHI '13, pp. 383–392, New York, NY, USA, 2013. Association for Computing Machinery.
- [Boh08] Richard Bohannon. Hand-Grip Dynamometry Predicts Future Outcomes in Aging Adults. *Journal of geriatric physical therapy (2001)*, Vol. 31, pp. 3–10, 02 2008.
- [CDVB17] Christian Corsten, Bjoern Daehlmann, Simon Voelker, and Jan Borchers. BackXPress: Using Back-of-Device Finger Pressure to Augment Touchscreen Input on Smartphones. In *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, CHI '17, pp. 4654–4666, New York, NY, USA, 2017. Association for Computing Machinery.
- [DVS<sup>+</sup>19] Pavel Davidson, Heikki Virekunnas, Dharmendra Sharma, Robert Piché, and Neil Cronin. Continuous Analysis of Running Mechanics by Means of an Integrated INS/GPS Device. *Sensors*, Vol. 19, No. 6, pp. 1–20, 2019.

- [FT17] Nobuhiro Funato and Kentaro Takemura. Grip Force Estimation by Emitting Vibration. In *Adjunct Proceedings of the 30th Annual ACM Symposium on User Interface Software and Technology*, UIST '17 Adjunct, pp. 141–142, New York, NY, USA, 2017. Association for Computing Machinery.
- [GWP12] 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.
- [HHC<sup>+</sup>16] Min-Chieh Hsiu, Da-Yuan Huang, Chi An Chen, Yu-Chih Lin, Yi-ping Hung, De-Nian Yang, and Mike Chen. ForceBoard: using force as input technique on size-limited soft keyboard. In *Proceedings of the 18th International Conference on Human-Computer Interaction with Mobile Devices and Services Adjunct*, MobileHCI '16, pp. 599–604, New York, NY, USA, 2016. Association for Computing Machinery.
- [KBB<sup>+</sup>22] Utkarsh Kunwar, Sheetal Borar, Moritz Berghofer, Julia Kylmälä, Ilhan Aslan, Luis A. Leiva, and Antti Oulasvirta. Robust and Deployable Gesture Recognition for Smartwatches. In *Proceedings of the 27th International Conference on Intelligent User Interfaces*, IUI '22, pp. 277–291, New York, NY, USA, 2022. Association for Computing Machinery.
- [KKL24] Sunbum Kim, YoungIn Kim, and Geehyuk Lee. Pressure-Based Menu Selection on a Spherical Tangible Device. In *Extended Abstracts of the CHI Conference on Human Factors in Computing Systems*, CHI EA '24, pp. 1–6, New York, NY, USA, 2024. Association for Computing Machinery.
- [LEP22] Daniel Lauß, Florian Eibensteiner, and Phillip Petz. A Deep Learning based Hand Gesture Recognition on a Low-power Microcontroller using IMU Sensors. In *2022 21st IEEE International Conference on Machine Learning and Applications (ICMLA)*, pp. 733–736, 12 2022.
- [LH19] 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.
- [LXH16] 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.

- [MB15] Ross McLachlan and Stephen Brewster. Bimanual Input for Tablet Devices with Pressure and Multi-Touch Gestures. In *Proceedings of the 17th International Conference on Human-Computer Interaction with Mobile Devices and Services*, MobileHCI '15, pp. 547–556, New York, NY, USA, 2015. Association for Computing Machinery.
- [MFS21] Nagisa Matsumoto, Koji Fujita, and Yuta Sugiura. Estimation of grip strength using monocular camera for home-based hand rehabilitation. *SICE Journal of Control, Measurement, and System Integration*, Vol. 14, No. 1, pp. 1–11, 2021.
- [MGM<sup>+</sup>23] Wang Manying, Qin Guihe, Sun Minghui, Zhao Jian, and Qin Jun. An exploration of pressure input with bare finger for Mobile interaction in stationary and Mobile situations. *Multimedia Tools and Applications*, Vol. 82, No. 17, pp. 25711–25731, Jul 2023.
- [MSI24] Katsutoshi Masai, Maki Sugimoto, and Brian Iwana. Facial Gesture Classification with Few-shot Learning Using Limited Calibration Data from Photo-reflective Sensors on Smart Eyewear. In *Proceedings of the 23rd International Conference on Mobile and Ubiquitous Multimedia*, MUM '24, pp. 432–438, New York, NY, USA, 2024. Association for Computing Machinery.
- [SDMP21] Dharmendra Sharma, Pavel Davidson, Philipp Müller, and Robert Piché. Indirect Estimation of Vertical Ground Reaction Force from a Body-Mounted INS/GPS Using Machine Learning. *Sensors*, Vol. 21, No. 4, pp. 1–18, 2021.
- [SRKE10] Craig Stewart, Michael Rohs, Sven Kratz, and Georg Essl. Characteristics of pressure-based input for mobile devices. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI '10, pp. 801–810, New York, NY, USA, 2010. Association for Computing Machinery.
- [SSSO18] Kenji Suzuki, Ryuuki Sakamoto, Daisuke Sakamoto, and Tetsuo Ono. Pressure-sensitive zooming-out interfaces for one-handed mobile interaction. In *Proceedings of the 20th International Conference on Human-Computer Interaction with Mobile Devices and Services*, MobileHCI '18, pp. 1–8, New York, NY, USA, 2018. Association for Computing Machinery.
- [XGB<sup>+</sup>22] 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.

- [機械 18] 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, 2018. <http://int-info.com/PyLearn/PyLearnSIG03.html> [アクセス日: 2025年12月08日].
- [山本 23] 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.
- [塚本 13] 塚本晶克, 樋口雄太, 岡田隆. 把持特徴を利用したユーザインタフェースの開発 –Grip UI–. NTT ドコモ・テクニカル・ジャーナル, Vol. 21, No. 3, pp. 17–23, October 2013.

## 付録A 機械学習モデルのハイパーパラメータ

第4章に示す予備実験において、GridSearchによるハイパーパラメータの最適化を行った。候補となるパラメータを図A.1に示す。また、最適化により決定されたパラメータを表A.1に示す。

---

```
1 # GridSearch パラメータ設定
2 param_grids = {
3     "linear": {},
4     "ridge": {
5         "ridge__alpha": [0.01, 0.1, 1, 5, 10]
6     },
7     "lasso": {
8         "lasso__alpha": [0.01, 0.1, 1, 5, 10]
9     },
10    "elasticnet": {
11        "elasticnet__alpha": [0.01, 0.1, 1, 5],
12        "elasticnet__l1_ratio": [0, 0.01, 0.1, 0.3, 0.5, 0.9,
13            0.99, 1]
14    },
15    "rf": {
16        "rf__n_estimators": [30, 50, 100, 300],
17        "rf__max_depth": [None, 5, 10, 30],
18        "rf__min_samples_split": [2, 5]
19    },
20    "svr": {
21        "svr__C": [0.1, 1, 10],
22        "svr__epsilon": [0.01, 0.1, 0.5],
23        "svr__gamma": ["scale", "auto"]
24    }
25 }
```

---

図 A.1: GridSearch におけるパラメータの候補を示すソースコード.

表 A.1: 決定されたパラメータ.

回帰モデル	ハイパーパラメータ
Linear	—
Ridge	alpha=10
Lasso	alpha=1
ElasticNet	alpha=1, l1_ratio=0.5
RandomForest	max_depth=None, min_samples_split=2, n_estimators=300
SVR	C=10, epsilon=0.5, gamma='scale'

## 付録B 実験前アンケート

第5章にて述べた評価実験において使用した実験前アンケートを図B.1に示す。

## 実験前アンケート

thonda@iplab.cs.tsukuba.ac.jp [アカウントを切り替える](#) 

 共有なし

---

名前

回答を入力

---

性別

男性

女性

---

年齢

回答を入力

---

スマートウォッチの利用状況

日常的に利用している

過去に利用していたが、今はしていない

利用したことがない

---

送信 フォームをクリア

Google フォームでパスワードを送信しないでください。

このフォームは 筑波大学システム情報工学研究科コンピュータサイエンス専攻インタラクティブプログラミング研究室 内部で作成されました。 - [フォームのオーナーに問い合わせる](#)

このフォームが不審だと思われる場合 [報告](#)

図 B.1: 評価実験にて使用した実験前アンケート。

## 付録C 評価実験手順書

第5章にて述べた評価実験を実施するための手順書を図C.1および図C.2に示す。

## 実験実施要項

文責：本田 智大

1. 現在時刻を記録する。
2. 実験参加へのお礼をし，[\[実験前アンケート\]](#) に記入してもらう。
3. 実験内容および手順を説明する。
  - a. スマートウォッチの巻き方：  
左腕に装着。バンドが腕にピッタリつくように，かつキツすぎない程度に
  - b. 姿勢：座った状態，腕を身体の側面にまっすぐ下ろす
  - c. 握力計の握り方：  
だんだん握力を強めていき，ある握力に達したら2秒間それを維持  
(握力計には最大握力しか表示されないため)
  - d. 手順：
    - 合計3セッション行う。
    - 1つのセッションにつき12回ずつ握力計を握ってもらう。
    - 各試行について「〇〇くらいの力で握ってください」と指示を行うが，これは収集データの偏りを防ぐためのものであり正確な握力を指示するものではないので，握るときはなんとなくでOK。
4. スマートウォッチを一度実際に巻いてもらったのち，点検する。
5. スマートウォッチを外し，メジャーを用いてスマートウォッチ装着位置の手首周囲の長さを測定し，記録する。
6. 実験アプリケーションを説明する。
7. 現在時刻を記録する。

### \*\*セッション1

8. スマートウォッチを装着し，握力計を持った状態にて手順3.bの姿勢で座ってもらう。
9. 重力成分除去のため，静止状態のデータを計測しておく。
10. 握力の段階（弱，中，強，とても強）を1つ指示する。
11. データ保存および握力の表示値を記録する。
12. 9-10を12回（4段階×3回）繰り返す。
13. スマートウォッチを取り外してもらう。

図 C.1: 評価実験にて使用した実験手順書 (1/2).

14. セッション終了，最低1分間休憩を取る．（ラップとして現在時刻を記録する）

\*\*セッション2,3

15. スマートウォッチを再装着し，握力計を持った状態にて指定の姿勢で座ってもらう．

16. 10-14と同じ．（セッション終了ごとに現在時刻を記録する）

17. （任意）[\[実験後アンケート\]](#)を行う．

18. 実験終了，現在時刻を記録する．

図 C.2: 評価実験にて使用した実験手順書 (2/2).