

電力効率化を考慮した気圧センサによる階層移動認識の最適化手法

山本将史^{1,a)} 西尾信彦^{1,b)}

受付日 2025 年 7 月 25 日, 採録日 2025 年 7 月 25 日

概要: 本研究では, スマートフォンに内蔵された気圧センサを用いて, 水平歩行と階段の上り・下りといった階層移動を高精度かつ電力効率的に認識する手法を提案する. まず, GPS と気圧センサの実機での消費電力を測定した. 気圧センサはバックグラウンドでの 10 時間連続使用でわずか 5% のバッテリー消費に留まり, GPS と比較して省電力性に優れることが確認された. 次に, 気圧データから抽出した 7 種類の統計的特徴量をもとに機械学習モデルで分類を行い, サンプリング周波数・観測ウィンドウ長・端末の保持状態 (手持ち・ポケット) の影響を詳細に評価した. 実験の結果, 1Hz の取得周波数かつ 7 秒のウィンドウ長を用いることで, 保持状態が混在する条件下でも 90% 以上の分類精度を達成できることが明らかとなった. 本手法は, 気圧センサが屋内における三次元的な移動推定や人流センシングのトリガー検出として有用であり, ビッグデータ収集基盤としての応用が期待されることを示した. さらに, 気圧データに影響を与えるスマートフォンの保持状態についても詳細な分析を行い, とくに階段上り動作において最大 1.5hPa 程度のバイアスが生じうることを確認した. これにより, 保持状態の違いを明示的に考慮する設計や, 特徴量による頑健な補正処理の重要性が示唆された.

キーワード: センシング, 気圧センサ, 行動分類

Power-Efficient Optimization of Floor Transition Recognition Using a Barometric Sensor

Masafumi Yamamoto^{1,a)} Nobuhiko Nishio^{1,b)}

Received: July 25, 2025, Accepted: July 25, 2025

Abstract: This study proposes a power-efficient method for accurately recognizing floor transition behaviors—such as horizontal walking, stair ascent, and descent—using a barometric sensor embedded in smartphones. First, we measured the power consumption of GPS and the barometric sensor on an actual smartphone. The results showed that the barometric sensor consumed only about 5% of battery over 10 hours of continuous background operation, demonstrating superior energy efficiency compared to GPS. Next, we extracted seven statistical features from the barometric pressure data and used them to classify user behaviors with a machine learning model. We thoroughly evaluated the impact of sampling frequency, observation window length, and device holding state (handheld or in-pocket) on classification accuracy. Experimental results demonstrated that with a 1 Hz sampling rate and a 7-second window, the model achieved over 90% classification accuracy even under mixed holding conditions. These findings indicate that the proposed method is effective for indoor 3D localization and can serve as a low-power trigger mechanism for crowd sensing systems, with potential applications in large-scale data collection infrastructures. Furthermore, we conducted a detailed analysis of the effects of device holding state on pressure readings and confirmed that a bias of up to approximately 1.5 hPa may occur, particularly during stair ascent. This underscores the importance of designing systems that explicitly account for holding conditions and implement robust compensation through feature engineering.

Keywords: Sensing, Barometric Sensor, Activity Classification,

1 立命館大学情報理工学部

a) masafumi@ubi.ise.ritsumei.ac.jp

b) nishio@is.ritsumei.ac.jp

1. はじめに

近年、スマートフォンやウェアラブルデバイスに内蔵された各種センサを活用した人間の行動認識や位置推定技術の研究が急速に進展している。これらのモバイルデバイスは、加速度センサ、ジャイロスコプ、磁力計、GPS、気圧センサなど多様なセンサを搭載しており、ユーザの位置情報や移動経路、行動を連続的に取得・記録できる[1]。屋外ではGPSを用いた測位が一般的であるが、屋内環境においてはGPS信号の遮蔽や多重経路干渉の影響により、その測位精度が著しく低下する[2]。そのため、屋内における位置推定技術として、PDR(Pedestrian Dead Reckoning)や気圧センサを用いた高度推定が代替的手法として注目されている[3]。

PDRは、スマートフォンのIMU(慣性計測ユニット)を利用してステップ検出、歩幅推定、移動方向の推定を行う手法であり、ユーザの二次元的な位置変化を把握するのに有効である。しかし、PDR単体では階層情報、すなわち「何階にいるのか」といった垂直方向の位置情報を推定することは困難である[4]。この点において、スマートフォンにも搭載されている気圧センサは、比較的安定した解像度で高度変化を検出可能であり、特に階段やエレベータの利用などによる階層移動を捉える有効な手段として位置づけられている[5]。

一方、近年ではスマートフォンから得られる三次元位置情報(緯度・経度・気圧等)をビッグデータとして利活用しようとする動きも活発化している[6][7]。たとえば、商業施設における人流解析、災害発生時の避難行動の把握、マーケティング分析、都市設計や交通最適化など、多様な応用分野において活用可能性が広がっている。二次元位置情報にはGPSが広く活用されているが、GPSは垂直方向の測位精度が低く、とくに建物内や都市部のような環境では衛星信号の遮蔽や多重経路干渉により高度情報の取得が困難となる。そのため屋内での階層移動のような上下方向の移動を高頻度・高精度で検出する用途には不向きであり、別のセンサによる代替が必要となる。気圧センサは連続的なデータ取得が可能であり、気圧変動をもとにユーザの高度変化を検出できる。気圧センサをGPS起動のトリガーとして活用することで、精度と電力効率を両立させた三次元位置推定の実現を目指す。

このような設計において重要なのは、気圧センサのみでどのようなユーザ行動を識別可能かである。気圧値は環境要因、スマートフォンの保持状態による外乱や、センサの個体差が誤認識の原因となる[9],[10]。そのため、気圧データに含まれる時系列的な変化パターンを適切に抽出・特徴量化し、ユーザの動作状態(階段上り・下り・水平歩行など)との関係性を定量的に明らかにする必要がある。また、気圧センサの取得周波数や観測時間(ウィンドウサイズ)によっても分類精度や消費電力は変化すると考えられる。必要以上に高頻度な取得は消費電力の増加を招き、低頻度すぎる取得はトリガーの見逃しや誤認識を生む。したがって、「どの程度の周波数・観測秒数で、どのような特徴量を抽出すれば、ユーザの行動を確実に検出できるか」を明らかにすることが、トリガーベースのセンシング設計における鍵となる。

本研究では、気圧センサを用いて、ユーザが階層移動を伴う行動を行ったタイミングを高精度に検出し、それをGPS起動の契機とする省電力な三次元位置推定支援の実現を目的とする。そのために、スマートフォンから取得された気圧データに対して複数の統計的特徴量を抽出し、それを

用いた動作状態の認識を行う。また、保持状態やセンサ設定の違いによる分類性能への影響を分析し、より現実的な使用環境に適したセンシング設計の知見を提示する。

2. 関連研究

2.1 階層移動認識における気圧センサの活用

屋内におけるユーザの階層位置を認識するための手法として、気圧センサの活用が近年注目を集めている。PDRによって得られる水平方向の移動軌跡と異なり、垂直方向の高度変化を把握するには追加の情報が必要である。そのため、スマートフォンやウェアラブル端末に搭載された気圧センサが、階段やエレベータなどの上下移動を検出するセンサとして活用されている。

Huangら[11]は、気圧センサとIMUセンサを組み合わせることで、複雑な屋内環境においても頑健な階層推定が可能であることを示した。特に気圧データのノイズ除去やデバイス間の較正処理を行うことで、安定したフロア判定が可能であることを報告している。また、Monteiroら[12]はスマートフォン内蔵の気圧センサを用いて、階段昇降やエレベータの昇降を、垂直加速度や高度変化から推定した。加速度データと比較して気圧データはノイズが少なく、誤差の蓄積がほとんどなく、屋内でも安定的に動作状態を識別可能であるとの結論に達している。さらに、Zhaoら[13]は、Wi-Fi情報と気圧情報を統合した階層推定システムを構築し、実環境において3階建ての建物内の階層推定に成功している。

一方、Wangら[14]は、近年のスマートフォン搭載センサの進化を背景に、気圧センサと機械学習モデルを用いた階層認識技術の発展状況を概観し、ビルごとの気圧変動モデルや端末間の補正アルゴリズムの重要性を指摘している。

これらの先行研究は、気圧センサを用いた階層認識が、GPSやPDRなどの技術と補完的に連携しうること、またその軽量性や省電力性を活かしてスマートフォン単体で実行可能であることを示している。一方で、取得周波数・ウィンドウサイズ・ユーザの保持状態などが認識精度に与える影響については十分に議論されていない。本研究では、これらの変数が分類性能に及ぼす影響を詳細に検証することで、実環境に適したセンサ設計方針を提示することを目的とする。

2.2 センサ時系列における特徴量選定

センサデータに基づく人間の行動認識タスクにおいて、時系列から適切な特徴量を抽出し、それを入力として分類器に与えることは、システムの精度や汎用性を大きく左右する要素である。特にスマートフォンやウェアラブル端末に搭載されている加速度・ジャイロ・気圧センサなどの時系列信号から、移動状態や姿勢、環境変化を識別するためには、適切な特徴量の設計と選定が重要になる。

Kwapiszら[15]は、加速度センサの生データから平均加速度・標準偏差・平均絶対誤差・ピーク間隔などの基本統計量を用いることで、高精度な行動分類を実現できることを示した。Anguitaら[16]は、加速度・ジャイロデータに対し、時系列特徴に加えてFFT(Fast Fourier Transform)による周波数成分の特徴量も加味することで、複雑な活動認識精度をさらに向上させている。また、Thakurら[17]は、スマートフォンの加速度センサと角速度センサの特徴量抽出と選定を一体化した機械学習ベースのアプローチを提案し、Guided Regularized Random Forest (GRRF)を用いて高次元特徴空間から重要な特徴のみを選択することで、モデルの精度と解

釈性を両立している。これにより、全体の分類精度を保ちつつ、不必要な冗長特徴を削減することが可能となった。

気圧センサに着目した研究としては、Fetzer ら[18]が、気圧の標準偏差・傾きといった統計的特徴量が、階層移動（上下移動）の認識に有効であることを示しており、移動の有無や方向性の検出において顕著な効果を発揮することが報告されている。さらに、Choi ら[19]は、T-SNE や 主成分分析などの次元削減手法を活用し、時系列から抽出された特徴量の分布やクラスタリング傾向を可視化することで、分類可能性の検証と特徴量の選定評価に成功している。

本研究ではこれら先行事例を踏まえ、時系列の一次元気圧データから抽出される複数の統計的特徴量を用いて動作状態の分類実験を実施し、T-SNE を通じてその有効性を可視化・検証することで、階層移動動作の分類に適した特徴量の設計・選定方法を検討する。

3. バッテリー消費量の調査

スマートフォンに搭載された各種センサを活用した階層移動認識システムを設計する上で、各センサが消費するバッテリー量を把握することは極めて重要である。特に、リアルタイムでのセンシングや長時間のデータ収集を前提とした応用(例：人流解析や災害時モニタリング)においては、システムの電力効率が実用性を大きく左右する。本調査では、位置推定に用いられる代表的なセンサである GPS と気圧センサを比較し、それぞれのバッテリー消費量を定量的に評価することを目的とする。最初に GPS と気圧センサそれぞれの平均消費電力を調査し、その後バックグラウンドにおける実機のバッテリー消費量を調査した。調査には Android 15 搭載の Google Pixel 8 Pro を使用した。スマートフォン上に気圧データ、GPS データ収集アプリケーションをそれぞれ構築し、センサデータを測定して保存した。取得周波数はどちらのアプリケーションも 1Hz に設定した。

表 2 各センサの消費電力

センサ	平均消費電力 (mW)	累計消費量 (μ Ws)
気圧センサ 不使用	13.7	8,295,666
気圧センサ 使用	13.83	8,364,896
GPS 不使用	0.54	325,904
GPS 使用	5.2	3,144,830

3.1 平均消費電力

センサーの平均消費電力は Android Studio の Profile 機能を用いて測定した。アプリを 10 分間開いて、センサーを起動した場合と起動しなかった場合の消費電力の差を比較することで平均消費電力を求めた。調査結果を表 2 に示す。表 2 から気圧センサの 1 秒間の平均消費電力は約 0.13mW であることがわかった。この値は Vanini ら[20]の調査結果と一致した。また、GPS の 1 秒間の平均消費電力は約 4.6mW であることがわかった。よって GPS は気圧センサに比べておよそ 35 倍の電力を消費していることがわかる。特に、リアルタイムでの階層推定を継続的に行うようなユースケースでは、

気圧センサの活用がバッテリー寿命の観点から圧倒的に有利であると考えられる。

3.2 実機のバッテリー消費量

実機を用いた長時間測定の結果として気圧センサ、GPS をそれぞれバックグラウンド動作させた際のバッテリー残量変化を調査した。調査はバッテリー残量 93%の状態から開始し、バックグラウンドでそれぞれのアプリを 10 時間ずつ動作した。この間、他のアプリは起動せずに、画面は消灯していた。GPS を 1Hz で常時使用した結果、バッテリー残量が 93%から 75%に変化し、累計で 18%減少した。気圧センサを 1Hz で常時使用した結果、バッテリー残量が 93%から 88%に変化し、累計で 5%減少した。結果から、実用上も気圧センサの省電力性が極めて優れていることがわかった。

3.3 電力効率化の検討

スマートフォンに搭載された GPS は緯度・経度の推定には優れるものの、垂直方向の精度は低く、特に屋内や都市部では高度情報の取得が困難である。にもかかわらず、GPS が階層移動の推定にしばしば利用されるのは、屋外における高さ推定や位置補完の手段としての汎用性が高いためである。しかし、階層移動を高頻度かつ正確に検出するようなユースケースにおいては、GPS には精度・電力消費の両面で課題が残る。気圧センサと GPS の消費電力を実機上で比較した結果、気圧センサは GPS に比べて極めて電力効率が高く、端末のバッテリー消費を大幅に抑えられることが明らかとなった。具体的には、バックグラウンドで 10 時間連続センシングを行った場合、GPS の常時利用ではバッテリーが 18%減少したのに対し、気圧センサ単体ではわずか 5%の消費に留まった。この結果は、高頻度かつ長時間のセンシングを前提としたモバイルアプリケーションにおいて、気圧センサを中核とする設計が現実的かつ持続可能であることを示している。特に、スマートフォンやウェアラブルデバイスによる行動認識や人流モニタリングのように、連続的なバックグラウンドセンシングが求められる場面では、ユーザやシステムの長期運用の観点からも電力効率の最適化は重要な設計要件となる。階層移動の推定においては、気圧センサによって移動の兆候を検出し、必要な場面のみ GPS を補助的に動作させるといった構成を採用することで、電力効率と認識精度を両立できると考えられる。

4. システム設計

本章では、本研究における階層移動認識システムの設計方針について述べる。まず、実験に使用したハードウェアとデータの収集方法について述べる。次に、気圧データの取得に関して様々な条件下(取得秒数、取得周波数)で実施した予備実験の結果に基づき、適切な取得条件と特徴量選定について検討を行う。最後に保持状態による影響について述べる。

4.1 実験用ハードウェア構成

全ての実験において、Google Pixel 8 Pro(Android 15, API Level 34)を使用した。本端末には気圧センサが搭載されており、Android の標準センサ API を介して気圧データを高周波数で取得することが可能である。データ収集には Java を用いた自作の Android アプリケーションを使用した。




図1 周波数を変化させた際の T-SNE 分析の結果

4.2 データ収集方法

トレーニング用データの収集は、立命館大学 OIC キャンパス内の H 棟内で行なった。水平歩行、階段においての上下移動を含むセッションを繰り返し実施し、収集したデータに対して手動でラベル (suihei, stairup, stairdown) を付与した。

4.3 有効な特徴量の検討

階層移動に伴う気圧変化のパターンを定量的に捉えるため、各 5 秒セグメントから以下の 7 種類の統計的特徴量を抽出した。これらの特徴量はすべて 1 次元の気圧時系列に対して計算され、上昇、下降、水平歩行といった状態ごとの変化傾向を反映するよう設計した。

1.分散：気圧データのばらつきを示す指標であり、変動が大きい動作（例：階段移動）において高い値を示す。静止時水平歩行時には値が小さくなる傾向があるため、移動有無の判別に有効であると考えた。

2.傾き：時系列に対して線形近似を行った際の傾き係数であり、気圧の全体的な変化方向を表す。正の傾きは気圧値の上昇、負の傾きは気圧値の下降を意味する。

3.range(最大-最小)：セグメント内における気圧の最大値と最小値の差分を示す。急激な高度変化が起きた場合にこの値が大きくなるため、階段やエレベータ移動時の識別に有効であると考えた。

4.iqr(四分位範囲)：データの第 1 四分位点(Q1)から第 3 四分位点(Q3) までの範囲を示すロバストなばらつき指標であり、外れ値に影響されにくい。

5.尖度：時系列におけるピークの鋭さを示す指標。階層移動時に生じる急激な気圧変化の検出に有効であり、平坦な動作と鋭い移動動作の識別に用いる。

6. abs_mean_diff(差分の絶対値平均)：セグメント内の隣接する気圧値の差分の絶対値を平均した指標であり、気圧の微細な変化の総量を表す。静止状態と動作状態の変化検出に有効であると考えた。

7. Zero-crossings(ゼロ交差数)：時系列の一階差分が符号を変える (0 をまたぐ) 回数をカウントしたものであり、気圧変動のリズムや周期性の指標となる。小刻みな気圧変動が続く階段移動などで特徴的な値を示すと考えた。

これらの特徴量は、Zhao ら[5]や Liu ら[21]などの先行研究において有効性が示されている指標をベースに構成しており、気圧変動の「大きさ」「方向」「揺らぎ」など、階層移動に伴う動作特性を定量的に表現することを目的としている。Zhao らは、気圧センサを人間の行動認識に利用する際の可能性についてレビューしており、行動認識する上で、傾き、

標準偏差といった基本的な統計量が有効であると述べている。Liu らは、スマートフォン内蔵の気圧センサから抽出される平均値・分散・range・傾きといった統計的特徴量を、短時間と長時間の 2 種類のスライディングウィンドウから計算する手法を採用し、Random Forest 分類器を用いて階段およびエレベータ動作の識別精度を 95.05%まで高めた。本質的な特徴を選択し、精度とモデルの軽量性を両立させる重要性を強調している。これらの知見を踏まえ、本研究では、選定した 7 つの特徴量を用いて、どの特徴量が実際に階層移動の識別に有効かを視覚的に評価するため、T-SNE(t-Distributed Stochastic Neighbor Embedding) を用いた可視化分析を行った。T-SNE は、高次元の特徴空間を低次元(本研究では 2 次元)に変換する非線形手法であり、各特徴量が移動状態(上昇・下降・水平)をどの程度分離できるかを視覚的に評価する手段として有効である。

具体的には、各特徴量を個別に抽出した場合と、複数の特徴量を組み合わせた場合でそれぞれ T-SNE を実行し、クラスタの分離度を比較した。分析の結果、傾き、分散、Range、abs_mean_diffといった特徴量は、3 クラスの行動状態を明瞭に分離できる構造を形成しており、識別に特に有効であることが示された。

4.4 取得周波数と取得秒数

気圧センサからのデータ取得頻度(1Hz, 5Hz, 10Hz)および取得秒数(2 秒, 5 秒, 8 秒)を変化させ、それぞれの条件で得られた気圧時系列データから特徴量を抽出し、T-SNE を用いて高次元の特徴空間を 2 次元に可視化した。T-SNE 分析により、異なる移動状態(上昇・下降・水平歩行)が特徴空間上でどの程度分離されるかを確認することで、最適な取得設定を検討した。T-SNE の結果を図 1 に示す。図 1 から、2 秒のセグメントでは 1Hz, 5Hz の周波数においては 3 クラス(水平歩行、階段上り、階段下り)の特徴空間上での分離が不明瞭であり、分類に必要な情報が十分に捉えきれていないことが確認された。一方、10Hz の場合は他 2 つと比較してクラスタが分離していた。5 秒, 8 秒とセグメント長が伸びるにつれて各クラスのクラスタが明確に分離し、特に 8 秒以上の条件では、気圧変化の方向と変動幅に基づいて移動状態が安定して分類可能な構造が現れた。また、サンプリング周波数については、1Hz と 5Hz では大きな差はみられなかったが、10Hz では特徴空間がやや拡散する傾向が確認された。これは、高周波で取得された微細なノイズが特徴量に反映されやすくなり、クラスタ内部のばらつきを助長したためと考えられる。これらの結果から 1Hz でも 5 秒以上のセグメント長ならば分類可能であると考えられる。

4.5 保持状態による影響

気圧センサを用いた階層移動認識において、スマートフォンの保持状態が測定データに与える影響を評価することは極めて重要である。ユーザがスマートフォンを手持して操作している場合と、ポケットやバッグの中に入れている場合とでは、得られる気圧値が大きく異なる可能性があるため、本研究では保持状態ごとの気圧データの特性を調査した。また、この問題は大規模にユーザ端末から気圧データを収集する「モバイルセンシング型ビッグデータ」の利用においても影響を及ぼす可能性がある。収集されたデータがどのような状態(手持ち・ポケット・バッグ)で取得されたかは通常記録されないため、保持状態に起因する気圧の偏差やノイズが階層推定アルゴリズムに混入し、誤推定や統計的歪みを引き起こすリスクがある。したがって、モバイルセンシングのようにユーザの多様な使用状況を前提とするアプリケーションでは、保持状態の違いを明示的に考慮した設計、あるいはその影響を緩和する特徴量抽出や補正処理が不可欠である。本研究ではその一環として保持状態による影響が気圧値にどの程度影響を与えるか調査した。周波数を 1Hz にし、同一経路において端末を胸の位置に水平に固定、ポケットに入れた状態で、水平移動、階層移動を行い、取得された気圧値をグラフで表し比較した。

4.5.1 水平歩行

水平歩行時の結果を図 2 に示す。水平歩行のシナリオでは、最初手持ち状態から 30 秒ごとに端末の位置を手持ち固定、ポケットで切り替えて行った。ポケット状態と手持ち状態の間に 0.15~0.2 hPa 程度の気圧差が発生するケースが多く、ポケット状態の山では 0.6 hPa の差を示すケースも観測された。一部のセグメントでは両者が一致することもあったが、全体としては差が頻繁に確認された。T-SNE を用いた特徴量の可視化においては、手持ちとポケットのクラスが明確に分離される傾向が見られ、保持状態による系統的な差が特徴空間上でも顕在化していることが示された。

4.5.2 階段上り

階段上り時の結果を図 3 に示す。青色の線が手持ち状態、緑色の線がポケット状態を表す。階段を上るシナリオでは、手持ちとの平均気圧差がより顕著に現れ、差が大きいセグメントでは最大で 1.5 hPa 程度の気圧差が確認された。特に上昇時は気圧が上昇するため、密閉性の高いポケット環境では内部圧の変化が追従しにくく、値が不安定になる可能性が示唆された。T-SNE 分析においても、手持ちとポケットはほぼ完全に別クラスとして分離され、下りにおける保持状態の影響が非常に大きいことが確認された。

4.5.3 階段下り

階段下り時の結果を図 4 に示す。青色の線が手持ち状態、緑色の線がポケット状態を表す。階段を下るシナリオでは、気圧値が手持ち状態と一致するケースが多く、上りに比べて保持状態による影響が少ない傾向にあった。差が大きい場合でも 0.5 hPa 程度に留まっており、気圧値のばらつきが比較的少なかった。また、T-SNE の結果でも、手持ちとポケットのクラスが大きく重なり合っていることが確認され、両者の違いが識別困難であることが示された。




図 2 水平歩行時の気圧値の比較




図 3 階段上り時の気圧値の比較






図 4 階段下り時の気圧値の比較

4.5. 考察


以上の結果から、ポケットでの保持状態は移動方向(上り・下り)によって気圧データに与える影響が異なることが明らかとなった。特に階段上り時においては、密閉状態による気圧の変化や通気性の影響が顕著に現れることが考えられる。これに対し、下り動作では身体の動きや端末の姿勢が比較的一定であるため、影響が抑えられたと推察される。このような保持状態の違いを無視すると、階層推定における誤検出率の増加を招く可能性がある。そのため、今後の実装においては、保持状態を検出・推定する仕組みや、保持状態に依存しにくい頑健な特徴量設計が不可欠である。また、保持状態の違いは推定精度だけでなく、ビッグデータ活用時のセンサ設計方針にも影響を及ぼす重要な要素であると考えられる。



(a) 手持ち状態のみ



(b) 手持ち+ポケット(保持状態あり)



(c) 手持ち+ポケット(保持状態なし)

図5 ウィンドウサイズを変化させた際の F1 score の変化

表3 各状態の7秒の時の特徴量重要度

保持状態	傾き	分散	Range	Abs_mean_diff
手持ちのみ	0.5030	0.1637	0.1637	0.0872
手持ち, ポケット(保持状態ラベルあり)	0.2156	0.2121	0.2246	0.1720
手持ち, ポケット(保持状態ラベルなし)	0.2749	0.1982	0.1942	0.1545

5. 実験・評価

本章では気圧センサデータからの階層移動認識に対する機械学習モデルの評価実験について述べる. 分類対象は3種類の行動 (水平歩行, 階段上り, 階段下り) とし, 気圧センサから抽出された統計的特徴量(各データ数 200)を入力とする. 気圧データのサンプリング周波数は 1Hz とし, 取得されたデータはウィンドウサイズ 2 秒~9 秒までの範囲で変化させた. ウィンドウはスライディング幅 1 秒で区切り, 各セグメントから特徴量ベクトルを生成した. 分類モデルにはランダムフォレスト(Random Forest)を用い, 保持状態(手持ち/ポケット)の有無に応じて 2 種類の実験を実施した. モデルの性能評価には, F1 スコアを主要な指標として用いた. データセットは全体を学習データ 80%, テストデータ 20% に分割し, Stratified Shuffle Split によって各行動カテゴリの比率が維持されるよう設計した.

5.1 手持ち状態のみ

最初にスマートフォンを手持ち状態で取得したデータのみを用いて, 3 行動分類の精度を評価した. ウィンドウサイズを 2 秒から 9 秒まで変化させたところ, 6 秒まではウィンドウサイズの増加に伴い分類精度が大きく向上し, 最大で 95%以上の精度を達成した. 6 秒から 7 秒は精度が 0.2 上昇したが, 7 秒以降は精度の上昇が頭打ちとなり, 「7 秒」が分類精度とリアルタイム性のバランスにおいて最適と考えられる. 特徴量の重要度分析の結果を表 3 に示す. 手持ち状態のみの特徴量分析では, 傾きが最も高く(0.5030), 続いて分散(0.1637), Range(0.1637)が寄与していることが判明した. また, 全ての特徴量を使用した場合と比較して, 傾き・分散・Range の 3 種類のみでもほぼ同等の分類精度を得られた.

5.2 手持ち+ポケット

次に, スマートフォンの保持状態が混在したデータ(手持ち・ポケット)を用いて, 分類精度と特徴量の挙動がどのように変化するか検証した.

まず, 学習データに「手持ち」「ポケット」との保持状態のラベル情報を明示的に含めた条件で分類実験を行った.

手持ち状態のみを対象とした実験と比較して, 全体的な精度は低下する傾向が見られた. 手持ち状態のみではウィンドウサイズ 5 秒以上で精度が 90%を超えたが, 手持ち, ポケットでは, ウィンドウサイズ 7 秒かつ全 7 種の特徴量を用いた場合, 初めて 90%以上を達成した. このことから, 保持状態の違いによるノイズは存在するが, 7 秒以上のタイムウィンドウを用いることで, 安定した分類が可能であることが確認された. また, 全 7 種の特徴量を用いた場合, 特徴量の重要度分布が大きく変化することが確認された. 手持ちのみの条件では「傾き」が最重要であったのに対し, 手持ち, ポケットでは「分散」や「Range」の寄与が相対的に高まり, 気圧のばらつきや変化量が重要な識別指標となっていることが示唆された.

次に, 保持状態のラベル情報を学習には含めず, 分類器が保持状態を区別せずに学習・予測を行う条件での実験を実施した. この場合も, 手持ち状態のみの実験と比較して分類精度はやや低下したが, ウィンドウサイズ 7 秒以上の条件では精度 90%以上を維持できた. 全特徴量を用いず, 主要な 3 種類の特徴量(傾き, 分散, Range)のみに限定した場合でも, 精度は高い水準に保たれており, 特徴量選定の最適化による軽量モデル化の可能性も示された. この条件では, 傾きの重要度が高くなる傾向が確認され, 移動方向(上昇/下降)の明確な変化を捉えることが分類において有効であることが示された. 一方で, 分散や Range の重要度は, ラベルを含んだ場合よりもやや低下する傾向にあり, 分類器が保持状態による変動を十分に分離できないことも示唆された.

6. まとめと今後の課題

本研究では, スマートフォンに搭載された気圧センサを用いて, 屋内における階層移動を高精度かつ電力効率的に認識する手法の構築を目的とし, 実データに基づいた一連の実験と分析を行った. 具体的には, 気圧センサから得られ

る時系列データをもとに、7 種類の統計的特徴量を抽出し、それらを入力とした機械学習モデルにより、階段上り・階段下り・水平歩行の3つの行動を分類した。

実験の結果、実使用に近い条件である手持ち・ポケットを混在させた状態においても、ウィンドウ長7秒以上を確保すれば、保持状態による気圧のばらつきを考慮しながら同様の高精度を維持できることが確認された。また、実機による消費電力の測定により、GPSと比較して気圧センサは非常に低消費電力であることが明らかとなった。Google Pixel 8 Proを用いた10時間の連続測定実験では、GPSを1Hzで使用的場合にバッテリーが18%消費されたのに対し、気圧センサのみを使用した場合は5%の消費にとどまった。また、端末の保持状態によって同一の動作でも気圧に最大1.5 hPa程度のバイアスが生じることがあるため、これを補正しないまま活用することは、階層推定や行動推定において大きな誤差につながる危険性があると考えられる。

今後の課題としては、このような保持状態や外的環境(動作、保持状態、密閉度)など保持者の動きによる影響をリアルタイムで推定し、補正する技術の確立が挙げられる。また、多数のユーザ・多様な施設環境を対象とした大規模データセットによる検証が必要である。

参考文献

- [1] Giordano, S., & Puccinelli, D. (2015). When sensing goes pervasive. *Pervasive and Mobile Computing*, 17, 175-183.
- [2] Zhang, Z., He, S., Shu, Y., & Shi, Z. (2019). A self-evolving WiFi-based indoor navigation system using smartphones. *IEEE Transactions on Mobile Computing*, 19(8), 1760-1774.
- [3] Kuang, J., Niu, X., & Chen, X. (2018). Robust pedestrian dead reckoning based on MEMS-IMU for smartphones. *Sensors*, 18(5), 1391.
- [4] Geng, J., Xia, L., Xia, J., Li, Q., Zhu, H., & Cai, Y. (2021). Smartphone-based pedestrian dead reckoning for 3D indoor positioning. *Sensors*, 21(24), 8180.
- [5] Zhao, H., Cheng, W., Yang, N., Qiu, S., Wang, Z., & Wang, J. (2019). Smartphone-based 3D indoor pedestrian positioning through multi-modal data fusion. *Sensors*, 19(20), 4554.
- [6] Thums, M., Fernández-Gracia, J., Sequeira, A. M., Eguíluz, V. M., Duarte, C. M., & Meekan, M. G. (2018). How big data fast tracked human mobility research and the lessons for animal movement ecology. *Frontiers in Marine Science*, 5, 21.
- [7] Alam, S. S., Al-Qurishi, M., & Souissi, R. (2022). Estimating indoor crowd density and movement behavior using WiFi sensing. *Frontiers in the Internet of Things*, 1, 967034.
- [8] Almasri, A., El-Kour, T. Y., Silva, L., & Abdulfattah, Y. (2024). Evaluating the Energy Efficiency of Popular US Smartphone Health Care Apps: Comparative Analysis Study Toward Sustainable Health and Nutrition Apps Practices. *JMIR Human Factors*, 11, e58311.
- [9] Yi, C., Choi, W., Jeon, Y., & Liu, L. (2019). Pressure-pair-based floor localization system using barometric sensors on smartphones. *Sensors*, 19(16), 3622.
- [10] Manivannan, A., Chin, W. C. B., Barrat, A., & Bouffanais, R. (2020). On the challenges and potential of using barometric sensors to track human activity. *Sensors*, 20(23), 6786.
- [11] Huang, J., Luo, H., Shao, W., Zhao, F., & Yan, S. (2020). Accurate and robust floor positioning in complex indoor environments. *Sensors*, 20(9), 2698.
- [12] Monteiro, M., & Martí, A. C. (2016). Using smartphone pressure sensors to measure vertical velocities of elevators, stairways, and drones. *Physics Education*, 52(1), 015010.
- [13] Zhao, M., Qin, D., Guo, R., & Wang, X. (2020). Indoor floor localization based on multi-intelligent sensors. *ISPRS International Journal of Geo-Information*, 10(1), 6.
- [14] Wang, Q., Fu, M., Wang, J., Luo, H., Sun, L., Ma, Z., ... & Xia, M. (2023). Recent advances in floor positioning based on smartphone. *Measurement*, 214, 112813.
- [15] Kwapisz, J. R., Weiss, G. M., & Moore, S. A. (2011). Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2), 74-82.
- [16] Anguita, D., Ghio, A., Oneto, L., Parra, X., & Reyes-Ortiz, J. L. (2013, April). A public domain dataset for human activity recognition using smartphones. In *Esann* (Vol. 3, No. 1, pp. 3-4).
- [17] Thakur, D., & Biswas, S. (2022). An integration of feature extraction and guided regularized random forest feature selection for smartphone based human activity recognition. *Journal of Network and Computer Applications*, 204, 103417.
- [18] Fetzter, T., Ebner, F., Deinzer, F., & Grzegorzec, M. (2022). Using barometer for floor assignment within statistical indoor localization. *Sensors*, 23(1), 80.
- [19] Thakur, D., Guzzo, A., & Fortino, G. (2021, September). t-SNE and PCA in ensemble learning based human activity recognition with smartwatch. In *2021 IEEE 2nd International Conference on Human-Machine Systems (ICHMS)* (pp. 1-6). IEEE.
- [20] Vanini, S., Faraci, F., Ferrari, A., & Giordano, S. (2016). Using barometric pressure data to recognize vertical displacement activities on smartphones. *Computer Communications*, 87, 37-48.
- [21] Liu, M., Li, H., Wang, Y., Li, F., & Chen, X. (2018). Double-windows-based motion recognition in multi-floor buildings assisted by a built-in barometer. *Sensors*, 18(4), 1061.