

携帯機器の所持位置認識対象を逐次追加する機構の実利用を想定した 評価

齋藤 光明[†] 藤波 香織^{††}

[†] 東京農工大学大学院工学府情報工学専攻 東京都小金井市中町 2-2 4-1 6

^{††} 東京農工大学大学院工学研究院先端情報科学部門 東京都小金井市中町 2-2 4-1 6

E-mail: [†]perorokey@gmail.com, ^{††}fujinami@cc.tuat.ac.jp

あらまし 近年携帯機器の普及に伴い、使用者が持つ携帯機器に搭載された慣性センサを用いて、機械学習により機器の所持位置を認識する研究が盛んに行われている。従来の研究は予めデータ収集された既知位置のみを題材としたものが中心であり、特徴量選択や分類モデル考案が行われてきた。しかし現実には所持位置は様々であり、データ収集されていない未知位置に使用者が所持することもある。その場合その所持位置が認識の選択肢にないため、分類器は誤った認識を行うという問題が発生する。これを解決するには認識できる既知位置を逐次追加できるようにする必要がある。つまりどの既知位置にも分類し難い未知位置を発見し、それを既知位置に追加する。本研究では携帯機器の所持位置認識において、未知位置の発見と再学習を行う機能を持つシステムを提案し、実利用を想定した評価を行う。様々な行動と所持位置を含んだ実生活シナリオを考案し、シナリオに沿ってデータをシステムに与えることで評価を行った。評価結果、既知位置に多様な行動時のデータによるクラスが追加されることを許容する条件で、提案システムは実利用時に動作できるという知見を得た。

キーワード コンテキスト認識, 機械学習, 携帯機器位置特定, 拡張可能システム, クラスタリング

An evaluation on incremental addition of new portable device storing positions under realistic usage scenarios

Mitsuaki SAITO[†] and Kaori FUJINAMI^{††}

[†] Department of Computer and Information Sciences, Tokyo University of Agriculture and Technology
2-24-16 Naka-cho, Koganei, Tokyo, Japan

^{††} Department of Computer and Information Sciences, Tokyo University of Agriculture and Technology
2-24-16 Naka-cho, Koganei, Tokyo, Japan

E-mail: [†]perorokey@gmail.com, ^{††}fujinami@cc.tuat.ac.jp

Abstract With the spread of portable devices in recent years, work is being actively conducted to recognize the position of the device by machine learning using the inertial sensor mounted on the portable device owned by the user. Previous work has focused on only known positions for which data has been collected in advance, and features and classification models have been devised. However, in reality, the possession position varies, and the user may possess it in an unknown position where data is not collected. In that case, since the position is not a target for recognition, the problem that the classifier makes a wrong recognition occurs. To solve this, it is necessary to be able to add recognizable known positions one by one. In other words, it finds an unknown position that is difficult to classify into any known position, and adds it to the known position. This work proposes a system that has a function to detect and retrain unknown positions in the recognition of the position of portable devices, and evaluates it assuming actual use. The evaluation was performed by giving data to the system according to a real-life scenario that included various activities and possession positions. As a result of the evaluation, it was found that the proposed system can operate in actual use under the condition that a class based on various activities is added to the known position.

Key words context recognition, machine learning, on-body device localization, extensible systems, clustering

1. はじめに

近年携帯機器の普及に伴い、使用者が持つ携帯機器に搭載された慣性センサを用いて、機器の所持位置を認識する研究が盛んに行われている [1] [2] [3]。使用者が所持する位置に応じて慣性センサの値が変わることに着目し、機械学習技術を適用してその位置を認識する。携帯機器の所持位置認識は、使用者に携帯機器のより有益な使い方を提供するという点で有用性がある。例として所持位置に応じた適切な通知方法の自動選択 [4] や、所持位置を加味した環境パラメータ（温度や湿度）測定 [5] がある。

従来は予め認識対象の位置を固定したデータ収集や特微量選択、認識モデル考案などが行われてきた。現実には所持位置は多様であり [6]、学習を行っていない（認識機構が知らない）未知位置に使用者が所持することもあるが、その所持位置が認識の選択肢にないために認識機構は誤った認識を行うという問題が発生する。仮に想定する既知位置を最大限多くして解決を図るとしても、学習用データ収集の負担が増大する。

この解決策として未知位置を検出し、再学習することが考えられる。使用段階でどの既知位置にも分類し難い位置を検出した場合、それをいずれかの既知位置に分類するのではなく、まず未知位置と判定する。そしてその位置を利用者の介入を得てラベルを付加した上で再学習を行い、認識可能な位置を逐次追加することで解決する。本研究では新規性検出技術を用いた未知位置検出機能と、クラスタリング技術を用いた未知位置の認識対象への追加機能を持つ所持位置認識システムについて、実利用を想定した評価を行う。

本稿の構成を以下に述べる。まず 2. 章では本研究に関連のある先行研究を紹介し、本研究の位置づけを示す。3. 章では提案するシステムと、同システムにおける筆者の先行研究での成果を示す。4. 章ではシステムの実利用を想定した評価実験について、実験方法と実験結果、及び考察を示す。5. 章で結論を述べる。

2. 関連研究

2.1 携帯機器所持位置認識に関する研究

携帯機器の所持位置、もしくはウェアラブルセンサの装着位置を認識する研究例として、6 報の研究についてその認識位置をまとめたものを表 1 に示す。認識位置としてズボンポケットや胸ポケットといったポケット、バックパックやハンドバッグといった鞆、手持ちなどがある。ここで各研究において実験方法や認識位置数が異なるため、認識精度を一概に比較することはできない。しかしいずれの研究においても表に示している事前に想定した位置を認識することに重点を置いている。つまり各研究において想定されていない未知位置に使用者が所持することを考慮しておらず、その場合未知位置を既知位置の 1 つに誤認識するという課題が残っている。

2.2 慣性センサ値に機械学習技術を適用した研究

本研究では 2.1 節に示した課題を解消すべく、認識対象を逐次追加可能な携帯機器所持位置認識システムを提案する。提案

表 1 携帯機器又はウェアラブルセンサの所持位置認識研究

著者	認識位置
Fujinami ら [1]	首, 胸ポケット, ズボン前/後ポケット, ジャケットポケット, バックパック, ハンドバッグ, ショルダバッグ, 手持ち (通話, 閲覧, スウィング)
Shi ら [2]	胸ポケット, ズボン前/後ポケット, 手持ち
Bieshaar [3]	ジャケットポケット, ズボン前/後ポケット, バックパック
Fujinami [7]	首, 胸ポケット, ズボン前/後ポケット, ジャケットポケット, バックパック, ハンドバッグ, ショルダバッグ, メッセンジャバッグ
Alanezi ら [8]	ジャケットポケット, ズボン前/後ポケット, 机, 手持ち (通話, 閲覧, スウィング)
Sztylek ら [9]	頭, 胸, 腰, 上腕, 前腕, すね, もも

システムは機械学習技術を用いており、未知位置検出機能を新規性検出 [10]、認識対象への追加機能をクラスタリング [11] を用いて実現する。各技術の仕組みを簡単に述べた上で、慣性センサ値へ適用した研究例を示す。

新規性検出は N 種類のラベル 1~ラベル N を持つデータを訓練サンプルとして、新規性検出モデルを生成する。このモデルにテストサンプルを与えたとき、それが既知か未知か、すなわちラベル 1~ラベル N のいずれに属するか否かを判定する。新規性検出を慣性センサ値に適用した研究として、携帯機器の慣性センサによる使用者の行動を題材とし、未知行動の検出を行ったものがある [12] [13]。Yin ら [12] は歩行や走行など 5 行動を既知行動とし、それ以外のあらゆる行動を未知行動とした検証、Guo ら [13] は歩行や走行など 6 行動を扱い、この中で既知行動と未知行動の組み合わせを変化させた検証を行った。本研究は携帯機器の慣性センサを用いた新規性検出という点でこれら 2 研究と関連しているが、所持位置を題材としている。

クラスタリングはラベルの不明な複数のデータに対し、同一のラベルだと想定されるデータ同士をまとめ、クラスタを生成する。クラスタリングを慣性センサ値に適用する用途として、訓練サンプルのラベル付けにおける負担軽減がある [14] [15]。行動認識において認識モデルを生成する際、用いるすべての訓練サンプルにラベル付けを行っておく必要があるが、それを人間が手動で行うことは負担がかかる。そこでクラスタリングを訓練サンプルに適用し、同じクラスとなったサンプルを同一のラベルと見なすことで、ラベル付けの負担を大幅に減らすことができる。本研究の提案システムにおいてもこのような用途でクラスタリングを用いるが、始めに学習用データとして収集された訓練サンプルではなく、新規性検出で検出した未知位置のサンプルに適用する。

3. 認識対象の逐次追加が可能な所持位置認識システム

3.1 システム概要

図 1 に認識対象の逐次追加が可能な携帯機器所持位置認識システムの機能構成図を示す。本構成は Guo ら [13] の構成を参考にしており、新規性検出機能、所持位置認識機能、未知サン

プル退避機能、仮クラス抽出機能、仮クラスラベル付け機能の5つの機能から構成されている。仮クラス抽出機能は次元削減機能とクラスタリング機能の2つの小機能を持つ。

システムには予め N 個のラベルから成る既知クラスのサンプルが訓練データとして含まれている。また訓練データによる新規性検出モデル及び所持位置の認識モデルが予め構築されている。この訓練データは携帯機器及び所持位置認識システムの開発者などが募った、訓練データ収集用被験者により収集されていることを想定している。そのため携帯機器の使用者からのデータはシステムの使用初期には存在しない。

携帯機器の使用者がシステムを使用開始後、機器は常時センサ値を取得し、特徴量抽出によりテストデータ、つまり新たなサンプル（判定用特徴ベクトル）を発生させる。発生後随時それを新規性検出モデルに適用し、学習済みの既知クラスに属するか否かを判定する（A）。既知クラスに属すると判定されたサンプルを既知サンプル、既知クラスに属しないと判定されたサンプルを未知サンプルとする。既知サンプルと判定された場合、それを認識モデルに与えて学習済みの N 個のクラスのうちの1つに分類する（B）。一方未知サンプルと判定された場合には未知サンプルプールに退避する（C）。未知サンプルがある程度溜まったあと、 K 個の仮クラスをクラスタリングにより抽出する（D）。仮クラス抽出機能はクラスタリングの精度向上のために前処理として行う次元削減機能、仮クラスとしてクラスタを生成するクラスタリング機能の2つの小機能で構成される。その後抽出した仮クラスに対し使用者がラベル付けを行い、 M 個の新規クラスを生成する（E）。なお最終的には1つのクラスになる場合でも、クラスタリング段階では2つ以上の仮クラスに分割されている場合もあるため、 $M \leq K$ である。以後新規にラベル付けされたクラスのサンプルを訓練データとして、それまで既知であったクラスのデータとともに再学習することで、 $(N + M)$ 個のクラスが所持位置認識機能で認識できるようになる。同時に新たな訓練データによる新規性検出モデルを更新する。ここで仮クラスラベル付け機能は使用者の負担を考慮し、1日に何度も行うものではなく、お風呂上りや就寝前といった比較的自由に時間を取ることができる時間で、1日1回程度を想定している。




図1 提案する携帯機器所持位置認識システムの機能構成

3.2 研究成果

筆者の先行研究における成果を示す。新規性検出機能（A）はOCSVM(One Class Support Vector Machine) [16]、LOF(Local Outlier Factor) [17]、IF(Isolation Forest) [18] の一般的な3つの新規性検出手法を比較し、LOFが本機能に適していると結論付けた [19]。またアンサンブル型 Novelty Detection を提案し、既知と未知の判別性能を向上させた [20]。

未知サンプル退避機能（C）は次に実行する機能である仮クラス抽出機能に移行する基準について、未知サンプルプールに退避した未知サンプルの状態から決定する手法を提案した [21]。本手法の詳細は4.4節で述べる。

仮クラス抽出機能（D）の次元削減機能は主成分分析 [22] と t-SNE(T-distributed Stochastic Neighbor Embedding) [23]、加えて本機能を行わない条件の3条件を比較し、t-SNEが本機能に適していると結論付けた [24]。クラスタリング機能についてクラスタ数を使用者が指定する必要のない点や、クラスタ数を指定する必要のない他の手法と比べて計算量が小さい点からDBSCAN(Density-Based Spatial Clustering of Applications with Noise) [25] を採用し、主要パラメータ eps に適切な値を与えることで性能良く仮クラスを抽出できるという結果を得た [26]。さらに本パラメータを提案システムに含まれる訓練データを用いて算出する手法を提案した [21]。

4. 提案システムの実利用を想定した評価

4.1 概要

2.1節で示したような所持位置認識研究では、歩行や静止といった身体的に単純な行動時の認識について焦点を当てていることが多い。3.2節で示した研究成果も歩行時に収集された3つのデータセット [1] [7] [27] を用いることによる、歩行時に限定した実験から得られたものとなっている。つまり歩行時に収集された所持位置のデータを訓練データとして既知クラスを構成し、歩行時に収集された所持位置のデータをシステムのテストデータとして与えていた。しかし携帯機器の所持位置認識システムの実用化には、使用者が歩行以外の行動を取り、その時に発生したテストデータがシステムに与えられることも考慮する必要がある。そこで歩行以外の行動時のデータを与えることによるシステムの影響を調査することを本評価の目的とする。

本評価の実験では4.2節で示すデータセットを用いる。本データセットが含む7箇所のセンサ位置、23行動を用いて、歩行以外の行動を含み、かつ携帯機器の所持位置を変化させる生活シナリオを提案する。提案シナリオに沿って所持位置認識システムにデータを与え、システム内の機能を実行したときの性能を評価することで、目的を達成する。

ここで本稿では提案システムを構成する機能のうち、仮クラス抽出機能に焦点を当てる。システムに与えられたテストデータのすべてが新規性検出機能において未知と判定されたとして、仮クラス抽出機能にテストデータを与えて評価を行うこととする。

4.2 データセット

本評価では行動認識研究のために収集されたデータセット [28]

を使用する．行動認識とは所持位置認識と同様に，機械学習を用いて人物の行動を認識することである．本データセットは被験者が装着したウェアブルデバイスの加速度センサから収集されたデータである．被験者数 (H) や位置数 (P)，行動数 (B) などの詳細を表 2 に示す．図 2 に示すように胸，左右の上腕，左右の手首，左右の大腿前部の計 7 箇所に加速度センサを装着し，表 3 に示す 23 行動が収集された．なお同表中の WB はホワイトボードを意味する．また表 4 に示す携帯機器の所持位置認識でよく使われる 15 種類の計 59 次元の特徴量を用いてウィンドウサイズ ($wsize$) を 256，オーバーラップ ($olap$) を 50% としてサンプルを生成した．データ収集時のサンプリングレート (SR) は 50Hz であったため，1 サンプルあたりの実時間 (T_{Sample}) は 5.12 秒となる．

表 2 データセットの詳細	
項目	値
サンプリングレート (SR) [Hz]	50
被験者数 (H) [人]	14
位置数 (P) [箇所]	7
行動数 (B) [個]	23
特徴量 (F) [次元]	59
ウィンドウサイズ ($wsize$)	256
オーバーラップ ($olap$) [%]	50




図 2 データセットに含まれる位置

4.3 提案シナリオ

提案するシナリオについて示す．実世界において自然であり，また生活中に行動や携帯機器の所持位置を変化させる日常生活を題材としたシナリオを提案する．まず所持位置について，データセットには 7 箇所の位置が含まれているが，そのうち胸，右手首，右大腿前部の 3 箇所をシナリオに使用し，それぞれ胸ポケット，右手持ち，右ズボンポケットに見立て携帯機器の所持位置として扱うこととする．また行動について，データセットには 23 種類の行動が含まれるが，これらの行動の中からいくつかを用いて実生活で起こりうる自然なシナリオを提案することとする．

提案シナリオを表 5 に示す．本シナリオは社会人のオフィス

への通勤から帰宅までを題材としており，表の上行から下行にかけて時間が経過している．まずシナリオの 1 番から 6 番においてスーツジャケットを着ず，携帯機器をズボンポケットに所持して通勤する．次にシナリオの 7 番から 16 番がオフィスでの行動であり，7 番で PC 作業，11 番と 12 番で昼休憩，16 番で会議を行う．これらの合間には移動行動が入る．また移動行動中は携帯機器を手にも所持したり，会議時にはスーツジャケットを着て携帯機器を胸ポケットに所持したりするといった，所持位置の変化を起こしている．そしてシナリオの 16 番から 22 番においてスーツジャケットを着たまま帰宅する．本シナリオは歩く，自転車に乗る，階段を上る，読書，階段を下りる，パソコンを使う，座って食べる，座ってスマホを使う，ホワイトボード (WB) に書くの 9 行動を含んだ計 22 行動で構成される．そしてそれらの行動の中で状況に応じて，携帯機器の所持位置を変化させるシナリオとなっている．また短い距離を移動する行動，具体的には歩く，階段を上る，階段を下りるの 3 行動の 1 回あたりのサンプル数を 50 個，それ以外の行動の 1 回あたりのサンプル数を 200 個とする．このときシナリオ全体のサンプル数は計 2300 個となる．

4.2 節で示した特徴量を用いて，提案シナリオに沿ったデータが含まれるデータセットを 14 名の被験者単位に作成した．作成したデータセットをシナリオデータセット 1~14 と呼ぶこととする．同節で示したように 1 サンプルあたりの実時間 (T_{Sample}) は 5.12 秒であることから，提案シナリオにおける各行動の実時間は，短い距離を移動する 50 サンプルの行動が 4 分 16 秒 ($=5.12 \times 50$)，それ以外の 200 サンプルの行動が 17 分 4 秒 ($=5.12 \times 200$) となる．

表 3 データセットに含まれる行動

#	名前	#	名前	#	名前
1	歩く	9	立って食べる	17	パソコンを使う
2	走る	10	座って食べる	18	立ってスマホを使う
3	自転車に乗る	11	掃除機をかける	19	座ってスマホを使う
4	顔を洗う	12	階段を上る	20	読書
5	手を洗う	13	階段を下りる	21	WB を消す
6	歯を磨く	14	座って飲む	22	WB に書く
7	配膳	15	立って飲む	23	上着の着脱
8	コーヒーを淹れる	16	皿を洗う		

4.4 方 法

4.1 節で述べたように本評価は提案システムの仮クラス抽出機能に焦点を当てる．提案シナリオに沿って未知サンプルプールにサンプルを与えていき，溜まったサンプルに対して本機能を実行する．そして抽出された仮クラスに対して評価値を算出し，結果の良し悪しの評価を行う．

先行研究 [21] で提案した，未知サンプルプールのサンプルに対する仮クラス抽出結果採用手法を本評価の実験に取り入れる．実験方法を図 3 を参照して述べる．シナリオデータセット 1~14 のうち 1 つを用いる．未知サンプルプールにシナリオデータセットのサンプルをシナリオの順序通りに 1 つ追加する (A)．プールに溜められているサンプル数を S_{Pool} とする． S_{Pool} が

表 4 データセットの特徴量

#	名前	#	名前	#	名前
1	平均	6	第一四分位数	11	尖度
2	分散	7	中央値	12	二乗平均平方根
3	標準偏差	8	第三四分位数	13	相関係数
4	最大値	9	四分位範囲	14	エントロピー
5	最小値	10	歪度	15	エネルギー


表 5 提案シナリオ：P はポケットを意味する。

#	サンプル数 [個]	行動名	機器の 所持位置	状況
1	50	歩く	ズボン P	通勤 (家から駐輪場)
2	200	自転車に乗る	ズボン P	通勤 (駐輪場から駅)
3	50	階段を上る	ズボン P	通勤 (階段)
4	200	読書	ズボン P	通勤 (電車内)
5	50	階段を下りる	ズボン P	通勤 (階段)
6	50	歩く	ズボン P	通勤 (駅からオフィス)
7	200	PC を使う	ズボン P	デスクワーク
8	50	歩く	手持ち	移動 (以降昼休み)
9	50	階段を上る	手持ち	移動
10	50	歩く	手持ち	移動
11	200	座って食べる	ズボン P	昼食
12	200	座ってスマホ	手持ち	休憩
13	50	歩く	手持ち	移動
14	50	階段を下りる	手持ち	移動
15	50	歩く	手持ち	移動 (昼休み終了)
16	200	WB に書く	胸 P	会議
17	50	歩く	胸 P	帰宅 (オフィスから駅)
18	50	階段を上る	胸 P	帰宅 (階段)
19	200	読書	胸 P	帰宅 (電車内)
20	50	階段を下りる	胸 P	帰宅 (階段)
21	200	自転車に乗る	胸 P	帰宅 (駅から駐輪場)
22	50	歩く	胸 P	帰宅 (駐輪場から家)

閾値 S_{Cycle} 未満である限り、サンプルの追加を繰り返す (B)。 S_{Pool} が S_{Cycle} 以上であれば、プールに溜められている S_{Pool} 個のサンプルに対して仮クラス抽出機能を実行する (C)。このとき仮クラス抽出機能では次元削減機能に t-SNE を使い、先行研究 [21] で提案した eps 算出手法で事前に算出された eps を与えた DBSCAN をクラスタリング機能に用いる。仮クラス抽出機能で抽出された各仮クラスにおいて、構成するサンプル数を S_{Const} とする。 S_{Const} が閾値 $S_{Satisfy}$ 以上となった仮クラスを結果として採用する (D)。一方 S_{Const} が $S_{Satisfy}$ 未満の仮クラスを構成していたサンプルはプールに残留させる (E)。その後プールへのサンプルの追加を再開する。サンプルの追加をシナリオが終了するまで続行する。以上を 14 個のシナリオデータセットすべてに対して行う。

ここで本実験の中で用いる閾値である $S_{Satisfy}$ と S_{Cycle} について述べる。 $S_{Satisfy}$ は抽出された仮クラスを結果として採用するか否かの基準となる閾値であり、大きいほどより 1 つの仮クラスが採用されるのに必要となる構成サンプル数が多くなる。先行研究 [21] において $S_{Satisfy}$ はシステムの訓練データに

含まれる既知位置の 1 人・1 位置あたりのサンプル数 (S_{One}) を 3 で割った数が好適と分かった。4.2 節で示したようにウィンドウサイズを 256、オーバーラップを 50% としてサンプルを生成したところ、歩行時のサンプルの S_{One} はおよそ 288 となった。従って $S_{Satisfy}=95$ ($=288/3$) とする。また S_{Cycle} は仮クラス抽出機能を実行するか否かの基準となる閾値であり、大きいほどより多くのサンプルをプールに溜めてから本機能を実行する。本実験では S_{Cycle} として $S_{Satisfy}$ の 2 倍である 190 を与えることとする。

図 3 実験フロー：本図では $S_{Cycle}=6$, $S_{Satisfy}=3$ に指定

採用された仮クラス抽出結果に対して評価値を算出し結果を評価する。ここで本実験ではパターン 1 とパターン 2 の 2 パタンの正解ラベルを用いる。パターン 1 は行動と所持位置が共に同じであれば同一とする正解ラベルであり、逆に同じ所持位置でも別の行動時であれば別とする正解ラベルである。パターン 1 の正解ラベルは表 6 に示す 17 種類となる。パターン 2 は行動に関わらず、所持位置さえ同じであれば同一とする正解ラベルである。パターン 2 の正解ラベルは表 7 に示す 3 種類となる。各正解ラベルのシナリオに含まれるサンプル数を S_{Label} とする。本正解ラベルを採用された仮クラス抽出結果と比較することで評価値を算出する。

4.5 評価値

本評価ではシナリオに含まれる各正解ラベルによる仮クラスが抽出できたか否かについて、評価値 $Rate_{Extracted}$ を用いて評価する。ここでまず仮クラスのラベル付け方法について示す。抽出された仮クラスは、理想的には 1 つの正解ラベルのサン

表 6 パタン 1 の正解ラベルのラベル名とサンプル数

#	サンプル数 (S_{Label}) [個]	ラベル名
1	100	ズボンポケット-歩く
2	200	ズボンポケット-自転車に乗る
3	50	ズボンポケット-階段を上る
4	200	ズボンポケット-読書
5	50	ズボンポケット-階段を下りる
6	200	ズボンポケット-PC を使う
7	200	手持ち-歩く
8	50	手持ち-階段を上る
9	200	ズボンポケット-座って食べる
10	200	手持ち-座ってスマホ
11	50	手持ち-階段を下りる
12	200	胸ポケット-WB に書く
13	100	胸ポケット-歩く
14	50	胸ポケット-階段を上る
15	200	胸ポケット-読書
16	50	胸ポケット-階段を下りる
17	200	胸ポケット-自転車に乗る

表 7 パタン 2 の正解ラベルのラベル名とサンプル数

#	サンプル数 (S_{Label}) [個]	ラベル名
1	1000	ズボンポケット
2	500	手持ち
3	800	胸ポケット

ルのみで構成されることが望ましい。しかし実際には複数の正解ラベルのサンプルが混合して、1 つの仮クラスが抽出されることも想定される。そこで図 4 に示すように、各仮クラスが含む最も多いサンプルの正解ラベルをその仮クラスのラベルとして付けることとする。なお本図では例としてラベル名を三角や丸としているが、実際には表 6 及び表 7 に示すラベル名が付けられることになる。

次に評価値 $Rate_{Extracted}$ を定義する。 H 人の被験者による H 回ぶんの仮クラス抽出結果に対して、各正解ラベルについて 1 つ以上の仮クラスが抽出された回数を $H_{Extracted}$ とし、次式で示される $Rate_{Extracted}$ を定義する。

$$Rate_{Extracted} = \frac{H_{Extracted}}{H} \quad (1)$$

表 8 シナリオの正解ラベルと抽出された仮クラス数の 3 人の被験者の例

	抽出された 仮クラス数 (被験者 1) [個]	抽出された 仮クラス数 (被験者 2) [個]	抽出された 仮クラス数 (被験者 3) [個]
正解ラベル 1	3	1	0
正解ラベル 2	1	2	4
正解ラベル 3	0	0	0
正解ラベル 4	0	0	2

具体例を示して $Rate_{Extracted}$ の算出方法を述べる。表 8 は 4 つの正解ラベルを含むシナリオに対して実験を行ったときの、抽出された仮クラス数の 3 人の被験者の結果を示す。正解ラベル 1 は 3 人の被験者中 2 人の被験者において、1 つ以上の仮クラスが抽出されたため、 $Rate_{Extracted}=0.66$ ($=2/3$) となる。同様に正解ラベル 2、正解ラベル 3、正解ラベル 4 の $Rate_{Extracted}$ はそれぞれ 1.0 ($=3/3$), 0.0 ($=0/3$), 0.33 ($=1/3$) となる。本評価値は 0.0~1.0 の値を取り、高いほどその正解ラベルによる仮クラスが抽出されやすかったことを示す。なおこの例では被験者数は 3 人としたが、実際の評価の被験者数は 14 人であったため $H=14$ となる。




図 4 仮クラスのラベル付け方法

4.6 結 果

まずパタン 1 の 17 種類の正解ラベルそれぞれの $Rate_{Extracted}$ を棒グラフで示したものを図 5 に示す。表 6 に記載した各正解ラベルのサンプル数 (S_{Label}) が $S_{Satisfy}$ ($=95$) を超える正解ラベルを水色の棒グラフ、 $S_{Satisfy}$ 未満である正解ラベルを緑色の棒グラフとしている。本グラフより S_{Label} が $S_{Satisfy}$ を超える正解ラベルの $Rate_{Extracted}$ は、 S_{Label} が $S_{Satisfy}$ 未満の正解ラベルの $Rate_{Extracted}$ と比べて高くなる傾向にあることがわかる。 $S_{Satisfy}$ は仮クラス抽出機能で抽出した仮クラスを採用するのに必要な、構成するサンプル数 (S_{Const}) である。従って S_{Label} が $S_{Satisfy}$ を超える正解ラベルは、 $S_{Const} \geq S_{Satisfy}$ を満たす状態が発生しやすくなったため、 $Rate_{Extracted}$ が高くなったと考えられる。一方 S_{Label} が $S_{Satisfy}$ 未満の正解ラベルは、原理上その正解ラベルのサンプルだけで仮クラスを構成し $S_{Const} \geq S_{Satisfy}$ を満たすことはできない。従って S_{Label} が $S_{Satisfy}$ 未満の正解ラベルが仮クラスにラベル付けされるためには、仮クラスがその正解ラベルを含めて 2 つ以上のラベルのサンプルで構成され、かつそれらの構成するサンプルの中でその正解ラベルのサンプルがもっとも多く含まれる必要がある。従って S_{Label} が $S_{Satisfy}$ 未満の正解ラベルは、 S_{Label} が $S_{Satisfy}$ を超える正解ラベルと比べ、抽出された仮クラスにラベルが付きにくい。このことが S_{Label} が $S_{Satisfy}$ 未満の正解ラベルの $Rate_{Extracted}$ が低くなった原因だと考えられる。

次にパタン 2 の 3 種類の正解ラベルそれぞれの $Rate_{Extracted}$ を棒グラフで示したものを図 6 に示す。表 7 に記載されているようにパタン 2 の正解ラベルはいずれも S_{Label} が $S_{Satisfy}$ を超えるため、いずれも水色の棒グラフとなる。本グラフより $Rate_{Extracted}$ は 3 種類の正解ラベルすべてで 1.0 となったことが分かる。これは 14 人の被験者全員において、3 種類の正解

ラベルの仮クラスが抽出されたことを示している。パターン 2 の正解ラベルはシナリオ中の行動によらず位置のみを考慮するため、シナリオ中のある 1 行動時の仮クラスさえ抽出されれば、その位置の仮クラスが抽出されたと見なすため、 $Rate_{Extracted}$ を高くすることはパターン 1 と比べて非常に容易である。しかし実際にはパターン 1 の結果に示すように、シナリオに含まれるサンプル数が少ない行動時のサンプルはその仮クラスが抽出されにくかった。そのためそのような行動時のサンプルが、抽出された仮クラスにあまり含まれていないことに留意する必要がある。

4.7 考 察

本節では 4.6 節の結果を踏まえ、提案した携帯機器所持位置認識システムに歩行以外を含めた様々な行動時のデータが与えられることによるシステムの影響について考察する。本実験より S_{Label} が $S_{Satisfy}$ を超える正解ラベルの多くは、その仮クラスが抽出されることを確認できた。従って歩行以外の行動時のデータに対して仮クラス抽出機能を実行した場合でも、その行動時のデータが十分に未知サンプルプールに溜められていれば、行動 X 時の位置 Y という形で仮クラスを抽出できる見込みがあることが分かった。そして本実験では提案シナリオを 1 周、つまり 1 日ぶんだけサイクルさせたが、実際にはこのようなシナリオが繰り返されることとなる。つまり 1 周回ぶんのシ




図 5 パタン 1 の各正解ラベルの $Rate_{Extracted}$




図 6 パタン 2 の各正解ラベルの $Rate_{Extracted}$

ナリオではプール内のサンプルが足りず仮クラスが抽出されなかった正解ラベルも、シナリオを繰り返すことでプールにそのサンプルが溜まっていき、いずれその正解ラベルの仮クラスが抽出されることが想定される。従って提案した携帯機器所持位置認識システムは、既知クラスに歩行以外の行動時のデータが追加されることを許容すれば、歩行以外の行動時のデータが与えられても問題なく動作すると考えられる。

一方既知クラスに歩行以外の行動時のデータが追加されることを許容しない場合、発生したテストデータがそもそも歩行時のデータであるか否かを判別する機能がシステム内に必要となる。ここでその機能を提案システムに追加した一例を示す。図 7 に既知クラスに歩行以外の行動時のデータが追加されることを許容しない携帯機器所持位置認識システムの機能構成を示す。本システムは 3.1 節で示した提案システム (図 1) に歩行以外の行動検出機能 (F) を追加したものである。携帯機器の使用者がシステムを使用開始後は本機能は動作せず、歩行以外の行動時のテストデータは仮クラス抽出機能に与えられる。仮クラス抽出後のラベル付けにおいて、歩行以外の行動としてラベル付けされた仮クラスは既知クラスに追加されず、歩行以外の行動検出機能の訓練データとなる。本機能は本訓練データを用いた新規性検出を実行する機能であり、本機能で既知と判定されたテストデータは歩行以外の行動と見なされ棄却される。このような機能構成により、システムに歩行以外の行動時のデータを与えられた際、一度はそれが歩行以外の行動であることを使用者が付与する必要はあるものの、それ以降その行動がシステムに与えられた際にはそれを棄却することができる。

以上から既知クラスに歩行以外の行動時のデータが追加されることを許容することを想定した場合、及びそれを想定しない場合の双方において、提案した携帯機器所持位置認識システムは実利用時に発生する様々な行動時のデータが与えられることに対応できると考えられる。ただし後者においては対応できるように改良したシステム構成を提案したのみの段階であるため、提案システムを再現し性能を評価することが今後の課題となる。

5. おわりに

本研究では携帯機器の所持位置の認識対象を逐次追加する所持位置認識システムにおいて、未知位置を追加する機能である仮クラス抽出機能に焦点を当て、実利用を想定した評価を行った。様々な行動と所持位置を含んだ実生活シナリオを提案し、提案シナリオに沿ってサンプルを仮クラス抽出機能に与えたときの、シナリオに含まれる各正解ラベルの仮クラスの抽出されやすさを評価した。評価結果、シナリオに含まれるサンプルが十分数である正解ラベルは比較的正常に仮クラスを抽出できた。またシナリオに含まれるサンプルが十分数でない正解ラベルも、シナリオを繰り返すことで未知サンプルプールにサンプルが溜まっていき、いずれその仮クラスが抽出されると考察した。以上から既知クラスに歩行以外の行動時のデータが追加されることを許容する場合、行動 X 時の位置 Y という形でラベルを付けることにより、提案システムは様々な行動時のデータが与えられても動作するという知見を得た。歩行以外の行動時のデー




図 7 テストデータが歩行時のデータであるか否かを判別する機能を追加したシステムの機能構成

タへの対応は所持位置認識システムの実用化に対する課題の 1 つであり、その解消にあたっては本研究の大きな貢献点だと考えられる。今後の課題として既知クラスに歩行以外の行動時のデータが追加されることを許容しない場合における、テストデータが歩行時のデータであるか否かを判別する機能を追加した提案システムの再現と性能評価が挙げられる。

謝 辞

本研究は日本学術振興会 科学研究費補助金 (18H03228) の支援を受けた。

文 献

- [1] Kaori Fujinami, et al. Fine-grained Accelerometer-Based Smartphone Carrying States Recognition during Walking. *International Journal of Advanced Computer Science and Applications*, 8(8), 2017.
- [2] Yue Shi, et al. A Rotation Based Method for Detecting On-Body Positions of Mobile Devices. *UbiComp '11*, pp. 559–560, 2011.
- [3] Maarten Bieshaar. Where is my Device? - Detecting the Smart Device's Wearing Location in the Context of Active Safety for Vulnerable Road Users. *arXiv e-prints*, 2018.
- [4] Anja Exler, et al. Investigating the Perceptibility Different Notification Types on Smartphones Depending on the Smartphone Position. *UbiComp '17*, pp. 970–976, 2017.
- [5] Kaori Fujinami. Smartphone-based Environmental Sensing using Device Location as Metadata. *International Journal on Smart Sensing and Intelligent Systems*, 9(4), pp. 2257–2275, 2016.
- [6] F. Ichikawa, et al. Where's The Phone? A Study of Mobile Phone Location in Public Spaces. *2005 2nd Asia Pacific Conference on Mobile Technology, Applications and Systems*, pp. 1–8, 2005.
- [7] Kaori Fujinami. On-Body Smartphone Localization with an Accelerometer. *Information*, 7(2), 2016.
- [8] Khaled Alanezi and Shivakant Mishr. Design, Implementation and Evaluation of a Smartphone Position Discovery Service for Accurate Context Sensing. *Computers and Electrical Engineering*, 44, pp. 307–323, 2015.
- [9] Timo Sztyler and Heiner Stuckenschmidt. On-body Localization of Wearable Devices: An Investigation of Position-Aware Activity Recognition. *2016 IEEE International Conference on Pervasive Computing and Communications*, pp. 1–9, 2016.
- [10] D. Miljković. Review of Novelty Detection Methods. *The 33rd International Convention MIPRO*, pp. 593–598, 2010.
- [11] Marwan Hassani and Thomas Seidl. Using Internal Evaluation Measures to Validate the Quality of Diverse Stream Clustering Algorithms. *Vietnam Journal of Computer Science*, 4, pp. 171–183, 2017.
- [12] Jie Yin, Qiang Yang, and Jeffrey Junfeng Pan. Sensor-Based Abnormal Human-Activity Detection. *IEEE Transactions on Knowledge and Data Engineering*, 20(8), pp. 1082–1090, 2008.
- [13] Junqi Guo, et al. Smartphone-Based Patients' Activity Recognition by Using a Self-Learning Scheme for Medical Monitoring. *Journal of Medical Systems*, 40(6), pp. 1–14, 2016.
- [14] Dorra Trabelsi, et al. An Unsupervised Approach for Automatic Activity Recognition based on Hidden Markov Model Regression. *IEEE Transactions on Automation Science and Engineering*, 10(3), pp. 829–835, 2013.

- [15] Yongjin Kwon, et al. Unsupervised Learning for Human Activity Recognition Using Smartphone Sensors. *Expert Systems with Applications*, 41(14), pp. 6067–6074, 2014.
- [16] Bernhard Schölkopf, et al. Support Vector Method for Novelty Detection. *Proceedings of the 12th International Conference on Neural Information Processing Systems*, pp. 582–588, 1999.
- [17] Markus M. Breunig, et al. LOF: Identifying Density-Based Local Outliers. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, 29(2), pp. 93–104, 2000.
- [18] Fei Tony Liu, et al. Isolation Forest. *2008 Eighth IEEE International Conference on Data Mining*, pp. 413–422, 2008.
- [19] Mitsuaki Saito and Kaori Fujinami. Evaluation of Novelty Detection Methods in On-Body Smartphone Localization Problem. In *Proceedings of the 2019 IEEE 8th Global Conference on Consumer Electronics*, pp. 470–474, 2019.
- [20] Mitsuaki Saito and Kaori Fujinami. Unknown On-Body Device Position Detection Based on Ensemble Novelty Detection. *Sensors and Materials*, 32(1), pp. 27–40, 2020.
- [21] Mitsuaki Saito and Kaori Fujinami. New Position Candidate Identification via Clustering towards Extensible On-Body Smartphone Localization System. *Sensors*, 21(4), 2021.
- [22] Svante Wold, et al. Principal Component Analysis. *Chemometrics and Intelligent Laboratory Systems*, 2(1), pp. 37–52, 1987.
- [23] Laurens van der Maaten and Geoffrey Hinton. Visualizing Data Using t-SNE. *Journal of Machine Learning Research*, 9, pp. 2579–2605, 2008.
- [24] Mitsuaki Saito and Kaori Fujinami. New Class Candidate Generation applied to On-Body Smartphone Localization. In *International Conference on Activity and Behavior Computing*, 2020.
- [25] Martin Ester, et al. A Density-based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, pp. 226–231, 1996.
- [26] Mitsuaki Saito and Kaori Fujinami. Applicability of DBSCAN in Identifying the Candidates of New Positions in On-Body Smartphone Localization Problem. In *Proceedings of the 2020 IEEE 9th Global Conference on Consumer Electronics*, 2020.
- [27] Muhammad Shoaib, et al. Fusion of Smartphone Motion Sensors for Physical Activity Recognition. *Sensors*, 14(6), pp. 10146–10176, 2014.
- [28] 豊増聖実, 藤波香織. 要素行動の含有度合いを用いたゼロショット行動認識手法に関する研究. 第 82 回情報処理学会全国大会, 2020.