

携帯機器の所持場所認識対象の逐次追加のための新規検出の適用性検証

齋藤 光明* 豊増 聖実† 藤波 香織‡

* 東京農工大学 工学部 情報工学科 † 東京農工大学 大学院 工学府 情報工学専攻
‡ 東京農工大学 大学院 工学研究院 先端情報科学部門

1 はじめに

近年、ユーザ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場所を認識する研究が注目を集めている [1]。従来の研究は、予め学習した既知の場所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、現実には所持場所は様々であり、学習を行っていない未知の場所に使用者が所持することもある。その場合、その所持場所が認識の選択肢にないので、分類器は誤った認識を行うという問題が発生する。この解決策として、使用段階でどの既知の場所にも分類し難い未知の場所を発見し、再学習することが考えられる。本稿では、新規検出 (Novelty detection) 技術を用いた未知の場所の検出に焦点を当てて、各新規検出手法の適用性や個人差を検証する。

2 システム概要

図 1 にシステム図を示す。システムは Guo ら [2] の研究を参考に、携帯機器の所持場所認識を題材にしている点や、後に示す主成分分析による次元削減の影響を検証する点で異なっている。テストサンプル、つまり新たなサンプルが発生すると、それを訓練サンプル、つまり既知クラスのサンプルと比較し、既知クラスに属するかどうかを判定する (A)。既知サンプルと判定された場合、それを分類器に与え所持場所を認識する (B)。一方未知サンプルと判定された場合、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り次第、クラスタリングを通してクラスを抽出する (D)。抽出したクラスに対し使用者がラベル付けを行い、新規クラスとして追加する (E)。以後、追加された新規クラスが分類器で認識できるようになる。

3 新規検出手法の適用性検証

3.1 実験概要

携帯機器の所持場所認識における新規検出について、新規検出手法の適用性や、次元削減の影響の検証を目的とした、シミュレーション実験を行う。実験には、70 人の被験者による、11 クラスの携帯端末所持場所における歩行時加速度のデータセット [1] を用いた。特徴量は平均値、最大値など 8 の記述統計値による 30 次元である。新規検出手法として、scikit-learn ライブラリに実装されている One Class SVM (OCSVM)、Local Outlier Factor (LOF)、Isolation Forest (IForest) を用いた。ここで LOF と IForest は一般に、既知クラスはなく与えたテストサンプル内での外れたサンプルを検出する異常検出 (Anomaly detection) に主に用いられるが、新規検出にも適応可能である。また新規検出を行う前に、主成分分析を用いてサンプルを 3 次元に次元削減する

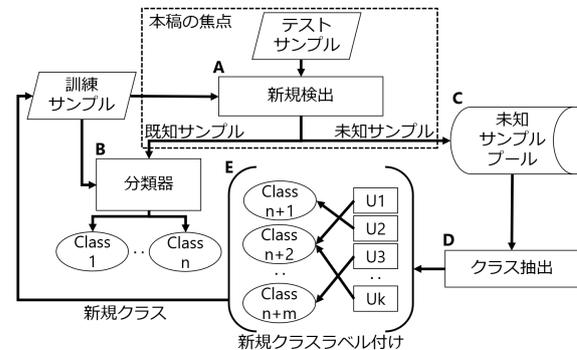


図 1: システム図

ことを考える。3つの新規検出手法に、主成分分析を行う場合と行わない場合を検証するため、実験条件は計 6 パタンとなる。

実験として理想環境下実験と現実環境下実験の 2 種類を行った。70 人の各被験者独立で判定を行うのが前者の実験である。このとき訓練サンプルには、テストサンプルに使う被験者と同一のものしか含まれない、つまり使用者のサンプルでその使用者のサンプルを判定するという状況になるため、判定状態として最も理想的なものとなる。検証方法として、10 分割交差検証を用いた。後者の実験は 1 人抜き検証であり、70 人の被験者のうち、1 人を除く 69 人の被験者のサンプルを訓練サンプルに使い、残り 1 人のサンプルをテストサンプルとして検証を行う。このとき訓練サンプルには、テストサンプルに使う被験者のものが含まれない、つまり事前に被験者から収集したサンプルで使用者のサンプルを判定するという状況になるため、判定状態として現実的なものとなる。

未知と判定することを陽性とする、混同行列は表 1 のようになる。本実験で評価する指標の精度として、以下の 3 式を採用する。それぞれ真陽性率、真陰性率、正規化を施した正解率を表し、真の未知サンプルを正しく判定した割合、真の既知サンプルを正しく判定した割合、この平均を意味する。

$$TruePositiveRate = \frac{TP}{TP + FN} \quad (1)$$

$$TrueNegativeRate = \frac{TN}{FP + TN} \quad (2)$$

$$NormalizedAccuracy = \frac{(1) 式 + (2) 式}{2} \quad (3)$$

表 1: 混同行列

		判定結果	
		未知	既知
実際の結果	未知	TP	FN
	既知	FP	TN

3.2 予備調査

予備調査として、携帯機器の所持場所に関する研究で扱われている所持場所を調査した。Ichikawa ら [3] の

A comparative study on novelty detection for discovering new on-body positions of portable devices

* Mitsuaki SAITO † Seiji TOYOMASU ‡ Kaori FUJINAMI

* , † , ‡ Department of Computer and Information Sciences, Tokyo University of Agriculture and Technology

研究をはじめ 10 件の研究を調査し、多く扱われていた 6 箇所（胸ポケット、手持ち、ジャケットポケット、ズボン前ポケット、ズボン後ポケット、リュックサック）を既知の場所に用いる。これら 6 箇所から考えられる既知の場所の組み合わせ数は、6 箇所から 1~6 箇所を選ぶ組み合わせ数の和となるので、63 通りある。既知の場所の組み合わせを変え、各条件、被験者ごとに指標精度の 63 通りの平均をまず算出する。その後その平均の 70 人分の平均と標準偏差を算出する。

3.3 実験結果

各実験結果を表 2 と表 3 に示す。平均が高いほど全体の結果が良く、標準偏差 (S.D) が小さいほど個人差が小さいことを表す。各指標精度で、平均が最高となった結果を網掛けしてある。

表 2: 理想環境下実験の結果

		次元削減なし		次元削減あり	
		平均	S.D	平均	S.D
OCSVM	TP-Rate	.999	.001	.988	.009
	TN-Rate	.715	.068	.608	.080
	N-Acc	.857	.034	.798	.041
LOF	TP-Rate	.983	.025	.893	.062
	TN-Rate	.945	.003	.944	.002
	N-Acc	.964	.012	.919	.031
IForest	TP-Rate	.928	.047	.797	.087
	TN-Rate	.878	.005	.880	.004
	N-Acc	.903	.022	.838	.042

表 3: 現実環境下実験の結果

		次元削減なし		次元削減あり	
		平均	S.D	平均	S.D
OCSVM	TP-Rate	.977	.018	.748	.048
	TN-Rate	.402	.149	.646	.100
	N-Acc	.689	.072	.697	.046
LOF	TP-Rate	.949	.022	.648	.057
	TN-Rate	.412	.118	.795	.085
	N-Acc	.680	.056	.721	.039
IForest	TP-Rate	.695	.063	.533	.072
	TN-Rate	.782	.125	.786	.129
	N-Acc	.739	.055	.660	.060

4 考察

4.1 効果的な判定条件の検証

未知サンプルと既知サンプルをどれだけ正確に判別できたかを表す、N-Acc で比較する。まず理想環境下では、現実環境下と比較すると平均は高く、とりわけどの条件も優れた結果を出していると考えられる。次元削減を行わない場合に平均が最も高かった手法は LOF であり、この条件下の結果、0.964 がシステムの上限值といえる。その標準偏差は 3 手法の中で最も小さく、また次元削減を行った場合、3 手法とも平均は低くなり標準偏差は大きくなるが、依然として LOF は平均が最も高く、標準偏差が最も小さい。従って、理想環境下では、LOF が最も正確かつ最も小さな個人差で既知と未知を判別できる手法といえる。

一方現実環境下では、次元削減を行わない場合 OCSVM と LOF では TP-Rate の平均は比較的高く、未知サンプルを未知と判定できている一方、TN-Rate の平均が低いことから、同時に既知サンプルも未知と誤判定してしまっている。IForest は未知サンプルと既知サンプルを同程度正しく判定しており、総合して N-Acc の平均は 3 手法の中で最も高い。ここで次元削減を行うと、

OCSVM と LOF では N-Acc の平均が高くなり、特に LOF は次元削減を行わない IForest 近くまでになる上に、標準偏差はそれを含めて最も小さくなっている。以上から、システム単体で見れば、IForest が最も正確に既知と未知を判別でき、また次元削減+LOF はそれに匹敵する精度で最も小さな個人差で行える。

4.2 システム全体を見通した考察

現実環境下においては、理想環境下と比較すると N-Acc の平均に大きく差があるため、システムの他の部分で補う必要がある。2 章で述べたように、未知と判定したサンプルは、クラス抽出後に使用者がラベル付けを行う。そのため真の既知サンプルを未知と誤判定することは、後の処理で使用者がテストサンプルにラベルを付け訓練サンプルに追加したり、もしくは訓練サンプルを棄却しテストサンプルのみに一新する（つまり理想環境下と同じ状態にする）ことで改善していくため、さほど問題ないと考えられる。一方、既知と判定したサンプルは、分類器で所持場所認識を行うため、真の未知サンプルを既知と誤判定することは問題となる。以上から、真の未知サンプルを既知と誤判定することを少なくすることが重要であり、それは TP-Rate が高いことを表す。従って、システム全体を見通したとき、TP-Rate の平均が高い手法が優れているといえる。それが比較的高い手法は次元削減を行わない OCSVM 及び LOF だが、一般に OCSVM はパラメータにより結果が著しく変化する。そのため、安定性の点から LOF が最も適用性があると本稿で結論付ける。

5 おわりに

本稿では携帯機器の所持場所認識における、新規検出の適用性を検証した。新規検出手法として OCSVM、LOF、IForest を用い、また主成分分析による次元削減を行った時の結果の変化を確認した。理想環境下では N-Acc の最高値が 0.964 であり、LOF が優れていた。現実環境下では新規検出単体で考えると IForest や LOF+次元削減が良好な結果となっている。一方システム全体を見通した場合、真の既知サンプルを未知と判定することはさほど問題ない。従って、TP-Rate が高い LOF が結果として良いことになる。これらの考察を踏まえて、TP-Rate を 1 に近い値に保ちつつ、TN-Rate をできる限り高くする方法を模索したり、本稿で用いたものと別のデータセットでの傾向を検証したりすることが、今後の課題となる。

謝辞

本研究は、日本学術振興会 科学研究費補助金 (18H03228) および平成 30 年度 (公財) 電気通信普及財団研究調査助成の支援を受けた。

参考文献

- [1] K.Fujinami, et al., Fine-grained Accelerometer-based Smartphone Carrying States Recognition during Walking, Int' J. Advanced Computer Science and Applications, 8(8), 2017.
- [2] J.Guo, et al., Smartphone-Based Patients' Activity Recognition by Using a Self-Learning Scheme for Medical Monitoring, J. Medical Systems, 40(6), 2016.
- [3] 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.