

アンサンブル型 Novelty Detection による 未知の携帯機器所持位置の検出

齋藤 光明^{1,a)} 藤波 香織^{2,b)}

概要：近年、携帯機器の普及に伴い、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である。しかし従来の研究では、判定できる位置は予め想定された既知位置に限られる。そのため、想定されていない位置で使用者が所持した際に、システムが対応できないという問題点がある。解決方法として、使用中に未知の所持位置を検出し、その位置を認識対象に逐次的に追加することが挙げられる。本研究では、新規性検出技術 (Novelty Detection) を用いて、与えられた位置が未知位置か否かを判定する「未知位置検出」に焦点を当てる。単一の検出技術を評価したうえで、RandomForest の原理に基づく新規性検出方法であるアンサンブル型の検出手法を提案する。3つのデータセットを用いた評価実験の結果、単一手法と比べて未知位置と既知位置をより正しく判別することができた。

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 [7][16][2]。携帯機器の所持位置認識は、使用者に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 [6] や、所持位置を加味した環境パラメータ（温度や湿度）測定 [9] がある。

従来は、予め認識対象の位置を事前に固定したデータ収集や特徴量選択、分類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 [11]、学習を行っていない（システムが知らない）位置（以下、「未知位置」とする）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分類器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。本稿では、新規性検出 (Novelty Detection) 技術 [13] を用いた未知位置の検出に焦点を当て、代表的な新規性検出手法の適用性や特徴を検証する。さらに、RandomForest の原理を参考とした新規性検出方法である、アンサンブル型 Novelty Detection を提案し、その有用性を示す。

本稿の構成について述べる。第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。第3章では想定するシステムの使い方と機能について示す。第4章ではシステムの基礎評価実験について示す。第5章では、複数の弱新規性検出器からなるアンサンブル型の検出手法を提案し評価実験を行う。第6章で今後の取り組みを述べ、結論を第7章にて述べる。

2. 関連研究

新規性検出とは、テストサンプルが訓練サンプルで形成されるクラス、つまり既知クラスに属するか否かを判定する技術のことである。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、属しないと判定されたサンプルを未知サンプルと呼び、以下の流れで行う。

- (1) 既知クラスモデル生成：訓練サンプルを与え、既知クラスモデルを生成する。
- (2) 未知サンプル検出：テストサンプルをモデル空間に投影し、既知サンプルまたは未知サンプルと判定する。

¹ 東京農工大学大学院 工学府 情報工学専攻
Department of Computer and Information Sciences, Tokyo
University of Agriculture and Technology

² 東京農工大学大学院 工学研究院 先端情報科学部門
Department of Computer and Information Sciences, Tokyo
University of Agriculture and Technology

a) perorokey@gmail.com

b) fujinami@cc.tuat.ac.jp

類似のアルゴリズムに異常検出 (Outlier Detection) があるが、異常検出は既知クラスは存在せず、与えたテストサンプル内で、クラスを形成していないと思われるサンプルを検出する。つまり、テストサンプルの比較対象となるサンプルが新規性検出では訓練サンプル、異常検出ではテストサンプル同士という点で異なる。本章では新規性技術を応用した研究について述べる。

まず携帯機器の慣性センサデータを扱った研究を示す。Yin ら [18] は携帯機器の慣性センサデータを用いて、使用者の行動を認識する行動認識を題材とし、新規性検出を用いて未知行動の検出を行った。この研究では歩行、走行など5つの行動を既知の行動とし、それ以外のあらゆる行動を未知の行動として評価を行った。ROC (Receiver Operating Characteristic) 曲線と AUC (Area Under Curve) 値を用いて検証を行い、AUC 値は最高で 0.985 まで達した。また Guo ら [10] も同じく携帯機器の慣性センサデータを用いた行動認識を題材とした新規性検出を行い、さらに未知行動として検出したサンプルを既知クラスに追加した上での再学習の検証を行っている。この研究では歩行、走行など6つの行動を扱い、この中で既知の行動と未知の行動の組み合わせを変えながら、評価を行なった。2クラス抜き検証で検証し、未知と既知の正解率は85%を超えた。また検出した未知の行動を新規クラスとし、それを既知クラスに追加した後の正解率は約84%となった。このように携帯機器のセンサデータを扱った新規性検出の研究は、行動認識を題材としたものは行われている。しかし携帯機器の所持位置を題材としたものは、筆者の知る限りは存在しない。そこで、本稿では携帯機器の所持位置を題材とした新規性検出について取り組み、また5章に示すアンサンプル型 Novelty Detection を適用して精度向上を図る。

Yin や Guo らの研究は、既存の新規性検出手法を扱い、その結果をもって未知と既知の判別結果としたものであったが、判別方法を新たに提案した研究を次に示す。新納ら [19] らは、文章中で使われ方が通常と異なる単語を検出する特異用例について、新規性検出を用いて検出を行った。この研究では2つ新規性検出手法を取り上げ、それらの結果の積を最終結果とする検出方法を検証している。その結果、新規性検出手法単体で用いたときよりも、提案した方法を用いたときのほうが、非特異用例と特異用例の認識の正解率は上昇した。また AlSuwaidi ら [1] は、新規性検出を用いて作物の異常画像の検出を行った。この研究では特徴量の異なる訓練サンプルを用いて複数回の検出を行い、多数決をとることで最終結果を決定する新規性検出方法である、アンサンプル型 Novelty Detection を提案している。単一の検出法とアンサンプル型の比較実験により、アンサ

ンプル型が正常画像と異常画像の識別正解率が上昇したとされている。このように、複数の新規性検出手法の検出を行ったり、訓練サンプルを変えたうえで複数回検出を行ったりして、その積や多数決をとることが有効だと示されている。本研究ではこのうち、AlSuwaidi ら [1] の研究と同様のアンサンプル型 Novelty Detection を携帯機器の所持位置に適用して検証する。その際、単なる多数決でない最終結果決定方法を新たに提案する。

3. 携帯機器の所持位置認識対象の逐次追加

本論文では、未知の所持位置を検出する手法を重点的に述べるが、まず利用イメージと全体の機能構成を説明する。

3.1 利用シナリオ

所持位置として考えられる位置は多いが、使用者ごとにみると、いくつかの決まった場所を状況（例：胸ポケットがない服を着ているのでズボンのポケットに入れる、等）に応じて使い分けられていると考えられる。認識可能な所持位置が多いということは、学習のためのデータ収集の負担が増大することを意味する。また、認識そのものも複雑化するため、精度向上が困難になる傾向がある。このため、初期状態で認識可能な位置を多くの人が利用することが想定されるごく一般的なものに限定し、その範囲での十分な認識精度を確保したものをリリースすることを想定する。一方で、新しいタイプの靴や服を使用・着用するようになるなど、ある時を境に未知位置が発生し、定常的に所持する位置が変化することがある。このように、既知位置ではないが継続的に出現する位置を「未知位置」と見なし、それを既知位置に追加するような利用を想定する。

3.2 処理フロー

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処理フローを示す。本構成は、Guo らの構成 [10] を参考にしており、5つの機能から構成されている。まずテストサンプル、つまり新たなサンプル（判定用特徴ベクトル）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で構築された既知位置モデルに適用し、学習済みの既知クラスに属するか否かを判定する (A)。既知サンプルと判定された場合、それを分類器に与えて学習済みの n 個のクラスのうちの一つに分類する (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ると、 k 個の仮クラスをクラスタリングにより抽出する (D)。そして、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二つ以上に

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データを訓練サンプルとして、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、以後 $n + m$ 個のクラスが分類器で認識できるようになる。同時に、新たな訓練サンプルによる既知位置モデルを更新する。本稿では、未知位置検出機能 (A) に焦点をあて、新規性検出手法の適用性を検証する。




図1 処理フロー

4. 未知位置検出手法の基礎評価

未知位置検出への新規性検出技術の適用性基礎評価について述べる。4.1節で述べるデータセットや評価指標は、第5章で述べるアンサンブル型の検出手法と共通である。

4.1 実験概要

4.1.1 データセット

本稿では3つの携帯機器所持位置認識研究 [7][8][17] のデータセットを使用する。いずれも歩行中の3軸加速度センサ値のデータである。各データセットで扱われた所持位置を表1に示す。データセットAは11箇所の所持位置における70人分のデータ（145,661サンプル）、同Bは9箇所の所持位置の20人分（34,962サンプル）、同Cは5箇所の所持位置10人分（22,450サンプル）で、それぞれ構成されている。各データセットは、加速度生データから平均値や最大値などの特徴量で構成されており、その次元数はそれぞれ、30次元、63次元、16次元となっている。

4.1.2 評価指標

未知位置検出の精度として、本稿では True-Positive Rate (TPR), True-Negative Rate (TNR), Normalized Accuracy (NA) の3つの精度を算出する。TPRは未知のテストサンプルのうち未知と判定した割合、TNRは既知のテストサンプルのうち既知と判定した割合である。またNAはTPRとTNRの平均であり、テストサンプルを総合的に正しく判定した程度を表す。NAは通常のAccuracyと比べ、既知のテストサンプル数と未知のテストサンプル数

表1 各データセットの所持位置

データセット	所持位置
A[7]	ジャケットポケット, ズボン前/後ポケット, 胸ポケット, 首提げ, リュックサック, ショルダーバッグ, ハンドバッグ, 手持ち, 閲覧中, 通話中
B[8]	ジャケットポケット, ズボン前/後ポケット, 胸ポケット, 首提げ, リュックサック, ショルダーバッグ, ハンドバッグ, メッセンジャーバッグ
C[17]	ズボン右/左ポケット, ベルト, 腕, 手首

に差があるときに有効な精度である。

既知位置の組み合わせを変えながら、未知位置検出のシミュレーションを行い、精度を算出する。データセットAでは、考えられる既知位置の組み合わせ数は $2046 (= \sum_{k=1}^{10} {}_{11}C_k)$ 通りとなるが、この全てを検証することは現実的でない。そこで、携帯機器の所持位置に関する研究で扱われている位置を、Ichikawa ら [11] の研究をはじめ10件ほど調査し、多く扱われていた6箇所（ジャケットポケット, ズボン前/後ポケット, 胸ポケット, リュックサック, 手持ち）からなる $63 (= \sum_{k=1}^6 {}_6C_k)$ 通りの組み合わせを検証する。1人抜き交差検証を行い、各既知位置の組み合わせでの被験者平均精度をまず算出する。その後63通りの既知位置の組み合わせの平均精度を算出し、検証結果の代表精度とする。

データセットBでは9箇所中5箇所（ジャケットポケット, ズボン前/後ポケット, 胸ポケット, リュックサック）を既知位置に用い、組み合わせ数を $31 (= \sum_{k=1}^5 {}_9C_k)$ 通りとして同様に行う。またデータセットCは、5箇所全てを既知位置に用い、組み合わせ数を $30 (= \sum_{k=1}^4 {}_5C_k)$ 通りとして同様に行う。

4.2 新規性検出手法比較実験

4.2.1 新規性検出手法の概要

本実験は既存の新規性検出手法を携帯機器の所持位置に適用し、各手法の特徴や適用性を検証することを目的とする。本稿で扱う新規性検出手法として3つ取り上げる。Domingues ら [5] は新規性検出手法及び異常検出手法を7つのカテゴリに分類している。カテゴリが異なり、かつよく用いられていると考えられる One Class SVM (以下 OCSVM) [14], Local Outlier Factor (以下 LOF) [4], Isolation Forest (以下 IForest) [12] の3手法を扱う。それぞれ、Domingues らの調査において領域に基づく手法、密度に基づく手法、分離に基づく手法に分類される。ここで LOF と IForest は一般に、異常検出に主に用いられる

が、新規性検出にも適用可能である。実験プログラムは Python 2.7.15 で開発し、上記 3 手法は scikit-learn 0.20.3 に搭載されているものを使用した。

4.2.2 新規性検出手法比較実験の結果と考察

実験結果を表 2 に示す。TPR, TNR, NA それぞれにおいて、最も高かった新規性検出手法の値に網掛けしてある。3 つのデータセット全てにおいて、TNR と NA は IForest が最も高くなった。また TPR は OCSVM が最も高く、次いで LOF が高くなった。ただし、データセット B の OCSVM は TPR が 1.000, TNR が 0.000 であり、これは全てのテストサンプルを未知と判定したことを示す。以上を踏まえ、各新規性検出手法の特徴を以下に述べる。

- OCSVM: TPR が高い傾向にあるが、データセットによって不安定な結果となる。
- LOF: TPR がいずれのデータセットでも高い傾向にある。
- IForest: TNR と NA がいずれのデータセットでも高い傾向にある。

表 2 データセット毎の新規性検出手法の性能

		A	B	C
OCSVM	TPR	0.977	1.000	0.895
	TNR	0.402	0.000	0.514
	NA	0.689	0.500	0.704
LOF	TPR	0.949	0.822	0.744
	TNR	0.412	0.445	0.626
	NA	0.680	0.634	0.685
IForest	TPR	0.695	0.755	0.737
	TNR	0.782	0.725	0.733
	NA	0.739	0.740	0.735

ここで、3.2 節で示したシステム全体を見直し、もっとも適用性のある新規性検出手法を考察する。未知と判定したテストサンプルは、仮クラス抽出後に使用者がラベル付けを行う (図 1 (E))。よって既知のテスト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棄却したり、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する選択肢がある。これは半教師付学習の一種である能動学習 [15] に通じる考え方である。よって、利用者の負担にならない量に抑えられれば誤判定は大きな問題にはならないと考えられる。一方、既知と判定したサンプルは、分類器で所持位置認識を行うため、未知のテストサンプルを既知と誤判定することは、誤った所持位置認識を行うことになるため、問題となる。また実際の利用シーンを考慮すると、時間的に連続したテストサンプルのうち多数が既知とされ、それらが同一の所持位置に認識された場合、未知とされた残りの少数のテストサンプルは、本来その所持位置

であったと推測できる。すなわち、全ての既知のテストサンプルが既知と判定されなかったとしても、既知と判定されたテストサンプルの所持位置認識の結果より、欠損した既知のテストサンプルの所持位置の推測は可能だと考えられる。以上から、TNR が高いことよりも TPR が高いことが重要だと考えられる。TPR が最も高い手法は OCSVM だが、データセットによっては全テストサンプルを未知と判定することや、一般にハイパーパラメータ調整が重要であることから不安定な面がある。そのため、3 つのデータセット全てで 2 番目に TPR が高い LOF が、安定性も踏まえて最も適用性があると結論付ける。

5. アンサンプル型 Novelty Detection

4 章で検証した新規性検出手法は、単体の検出器で既知か未知の判定を下す。近年、RandomForest[3] に代表される多数の弱識別器の結果を統合して利用するアンサンプル型分類 (回帰) が様々な領域で高い精度を達成している。新規性検出においても 2 章で述べたように、複数の検出器を用いることの有効性が示唆されている。本節では、携帯機器の新規所持位置検出問題への適用性を検証するとともに、パラメータ調整の手間を削減する手法を提案する。

5.1 概要

4.2.2 節では、システム全体を見通したときに有効な新規性検出手法は TPR が高い LOF と結論付けたが、一方で LOF は TNR が低かった。そこでまず、LOF においてアンサンプル型 Novelty Detection を適用し、TPR と TNR の平均である NA を上昇させることを目指す。そのうえで、TPR と TNR の変化を検証する。以降、特に断りがない場合はデータセット A について述べている。

本手法では訓練サンプルと特徴量にランダム性を導入する。なお、元の特徴量集合を F とする。まず訓練フェーズの処理を述べる。既知クラスのみで構成されたデータセットを復元抽出により S 個に分割するとともに F からサブセットの特徴量 F' を無作為に選択し、データセット' とする。各データセット' を訓練に用いて、未知サンプル判定モデルである弱検出器を S 個作成する。

次にテストフェーズの処理を述べる。図 2 に処理フロー示す。上記の方法で事前に作成された各弱検出器を用いて、テストサンプルに対して未知サンプル検出を行う (A)。このときテストサンプルの特徴量は、各データセット' でそれぞれ選択されたものを使用する。 S 個の弱検出器での結果を総合して、最終検出結果を決定する (B)。

ここで、 S 個の弱検出器の結果による、最終検出結果の決定方法を述べる。AlSuwaidi らは、最終結果の決定方法




図2 アンサンブル型 Novelty Detection の処理 (テストフェーズ)

として、複数の弱検出器の結果を利用した単純な多数決を用いている [1]。しかし、複数の弱検出器の結果から考えられる最終結果の決定方法は、単純な多数決だけではない。例えば、全弱検出器のうちである定数未満の弱検出器数で既知と判定したテストサンプルを未知、そうでないテストサンプルを既知と判定するという方法も考えられる。この数を L とし、判定閾値と呼ぶ。つまり、 S 個の弱検出器では L の取り方によって S 通りの検出結果が存在することになる。なお、 $L = S/2$ の時が多数決である。

5.2 アンサンブル方式の特性理解と適用性検証

以下では提案方式の特性を理解し、携帯機器の未知位置検出への適用性検証するための実験について述べる。なお、データセットや評価指標は 4.1 節と共通である。

5.2.1 判定閾値 (L) と NA の関係

scikit-learn における RandomForest 実装では、無作為抽出される特徴量数の既定値は元の特徴量数 ($|F|$) の平方根とされていることから、本実験でもこれを踏襲し、 $|F|=30$ であるデータセット A では 5 個を F' として選定して弱検出器で使用する。弱検出器の個数 (S) は 100 個とした。

既知位置の組み合わせを胸ポケット、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、手持ちの 6 箇所にしたときに、 L を変化させたときの NA の変化を図 3 に示す。 $L=66$ で、NA は最高値 0.870 をとり、これはアンサンブル型を用いなかったときの同既知位置の組み合わせでの結果 0.689 と比べ 0.181 上昇している。また、多数決 ($L=50$) での結果 0.786 と比べても 0.084 上昇している。したがって、適切な L を設定することにより NA は大きく上昇し、アンサンブル型の有効性を提示できた。以後、NA が最高値をとる L を L_{max} とする。

5.2.2 適切な判定閾値 (L_{max}) の見積もり手法

TPR, TNR, NA のいずれかを用いて、 L_{max} を見積もることを考える。このうち TPR と NA を用いる場合は、実環境でシステムを使用する時を想定すると、使用者に未知位置のテストサンプルを提供させることになり、本末転倒であり現実的でない。したがって、既知位置のサンプル




図3 NA の変化

で求められるよう、TNR を用いて L_{max} を見積もる方法を考案する。63 通りの既知位置の組み合わせの内、4 通りの組み合わせでの、 L を変化させたときの TNR の変化を図 4 に示す。このように TNR は単調減少していることが分かるが、これは L を大きくするほどテストサンプルが既知と判定されにくくなることを表す。

ここで、各グラフにおいて、 L_{max} における接線を引く。このとき、これら 4 通りの既知位置の組み合わせにおいて、接線の傾きはある程度一定になっていることがわかる。このことを確認するために L と TNR の関係を 3 次曲線に近似し、実際に計算で接線の傾きを求めた。求めた傾きを図中に示してある。このように近似曲線の接線の傾き (a) は、-0.010 程度で、おおよそ一定になっている。この図に載っていない残り 59 通りの既知位置の組み合わせのときも、同様の傾向が見られ、63 の接線の傾きの平均は -0.010 (標準偏差 0.002) となった。そこで次のような、 L_{max} の見積もり方法を提案する。

STEP1: TNR を L に関する 3 次曲線近似し、微分する。

STEP2: 微分係数を -0.010 とした 2 次方程式を解く。

STEP3: $(0, S)$ の範囲の解を四捨五入し、 L_{max} とする。




図4 4 通りの既知位置の組み合わせでの TNR の変化

考案した見積もり方法により算出された L を L_{est} とする。 L_{est} とそのときの NA などをもとめた表を 3 に示す。なお nonEns は、アンサンブル型ではなく単体の検出法を用いたケースである。また、NA(X) は条件 X にお

る NA を表す。表 2 段目と 3 段目より L_{est} は、 L_{max} と完全に一致してはいないものの、それに近い L が算出されていることが分かる。また表 4～6 段目から、 $NA(L_{est})$ は $NA(L_{max})$ と比べて減少しているもののその差は小さく、 $NA(nonEns)$ と比べると大きく上昇している。63 通りの既知位置の組み合わせでの平均を表 4 に示す。このように、 $NA(L_{est})$ の平均にも同様のことがいえ、考案した見積もり方法は多様な既知位置の組み合わせに適用できるといえる。

以上より既知位置のサンプルのみを用いて、多様な既知位置の組み合わせでも有効な L_{max} に近い L を求められ、アンサンブル型の効果を最大限に発揮して高い NA で未知位置検出を行うことができる。

表 3 考案した見積もり方法で求めた L と NA に関する実験結果

	組 (a)	組 (b)	組 (c)	組 (d)
L_{est}	49	45	63	62
$L_{est} - L_{max}$	+5	-4	-3	-4
$NA(L_{est})$	0.917	0.792	0.860	0.865
$NA(L_{est}) - NA(L_{max})$	-0.008	-0.001	-0.003	-0.005
$NA(L_{est}) - NA(nonEns)$	+0.286	+0.181	+0.157	+0.176

表 4 様々な条件下での NA の平均 (データセット A)

	nonEns	L_{est}	L_{max}
NA	0.680	0.833	0.839

5.2.3 弱検出器数 (S) の変化を考慮した L_{est} 見積もり

5.2.1 項及び 5.2.2 項では、弱検出器数 (S) を 100 個としたが、その個数を変えることを考える。図 3 の条件、つまり既知位置の組み合わせを胸ポケット、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、手持ちの 6 箇所に限定し、弱検出器数を 20 個と 50 個として、 L を変化させたときの NA 及び TNR の変化を図 5 に示す。図 3 のグラフと図 5 の 2 つのグラフの計 3 つのグラフの NA を比較すると、グラフの形状や、 L_{max} の位置は同程度のものになっている。また図 4 の組み合わせ (d) のグラフと図 5 の 2 つのグラフの計 3 つのグラフの TNR を比較すると、同様にグラフの形状は似ている。したがって弱検出器数を変えても、考案した見積もり方法により L_{max} に近い L を求めることができると考えられる。ただし横軸の最大値が異なるため、それを考慮する必要がある。具体的には、STEP2 において次のように、正規化を行う。
STEP2': 微分係数を $-0.010 \times (100/S)$ とした 2 次方程式を解く。

見積もった結果とそのときの NA などを表 5 にまとめる。このように、弱検出器数を変えても、 L_{max} に近い L_{est} が算出され、アンサンブル型を用いなかったときと比べ NA




図 5 弱検出器数を変えたときの NA と TNR (左: 20 個, 右: 50 個)

表 5 弱検出器数を変えたときの実験結果

	20 個	50 個	100 個
L_{est}	13	32	62
$L_{est} - L_{max}$	-1	-2	-4
$NA(L_{est})$	0.840	0.850	0.865
$NA(L_{est}) - NA(L_{max})$	-0.009	-0.007	-0.005
$NA(L_{est}) - NA(nonEns)$	+0.150	+0.160	+0.176

を大きく上昇させることができる。したがって STEP2' のような正規化を施すことで、弱検出器の数に依存せずに正確に L_{max} を見積もることができる。

なお、算出された NA の値は、弱検出器数を増やすほど上昇している。一方で、弱検出器数を増やすほどメモリや実行時間の観点では不利となる。したがって、弱検出器数は精度とメモリ・実行時間にトレードオフの関係があるため、精度の目標や、想定する実行環境のスペックで、適切な弱検出器数は変わるといえる。

5.2.4 LOF 単体の新規性判定パラメータ変更の影響

もともと LOF 単体では、各テストサンプルの既知と未知の判定はスコアを元に行われる。スコアが閾値より大きい小さいかで、既知か未知かを判定する。LOF のパラメータの 1 つである contamination (以下、 $cont$) は、その閾値を表し、大きいほどテストサンプルを未知と判定しやすくなる。これまでの検証では事前にパラメータ調整を行った結果にもとづき 0.05 としていたが、それを変えて検証した。図 3 の条件、つまり既知位置の組み合わせを胸ポケット、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、手持ちの 6 箇所に限定し、 $cont$ を 0.1 および 0.2 として L を変化させたときの NA 及び TNR の変化を図 6 に示す。弱検出器数は 100 個としている。図 3 のグラフと図 6 の 2 つのグラフの計 3 つのグラフの NA を比較すると、 L_{max} を頂点とした山ができていますが、 $cont$ が大きくなるにつれ、その山が左に移動している。また図 4 の組み合わせ (d) のグラフと図 6 の 2 つのグラフの計 3 つのグラフの TNR を比較すると、同様にグラフが左にスライドするような形状をしている。したがって TNR のグラフにおいて、 L_{max} における接線の傾きは、変化は小さいと考え、 $cont$ を変えても提案手法で精度良く L_{est} を求めることができると考えられる。

見積もった結果と、そのときの NA を表 6 にまとめる。このように、 $cont$ が 0.1 や 0.2 のときは、0.05 のときと比べ NA は低下している。これは TNR の形状が変わったのに伴い、傾きが少し変化したことが原因であると考えられる。しかし、アンサンブル型を用いなかったときと比較すれば NA は大きく上昇している。したがって $cont$ を変更しても、考案した見積もり方法が適用できるといえる。

ここで重要な点は、考案した見積もり方法にて用いる数値、つまり STEP2' における微分係数を変更せずに適用できるという点であり、パラメータ調整を必要としないことが示唆されたことになる。通常の新規性検出では、まずパラメータ調整を行い、それにより決定したパラメータで、新規性検出を行う。しかし、考案した見積もり方法を用いたアンサンブル型では、 L_{max} を見積もることがパラメータ調整に該当し、それは元のパラメータ値への依存が極めて低い。したがって、アンサンブル型は、解析的に L_{max} を求められるため、事前の慎重なパラメータ調整を必要とせずとも高い NA が得られる新規性検出方法といえる。




図 6 contamination を変えたときの NA と TNR

表 6 contamination を変えたときの実験結果

	0.05	0.1	0.2
L_{est}	62	45	25
$L_{est} - L_{max}$	-4	-8	-11
$NA(L_{est})$	0.865	0.840	0.769
$NA(L_{est}) - NA(L_{max})$	-0.005	-0.020	-0.079
$NA(L_{est}) - NA(nonEns)$	+0.176	+0.151	+0.080

5.2.5 他のデータセットへの適用

アンサンブル型検出法と L_{max} の見積もり手法のデータセット B および C への適用性を検証する。100 個の弱検出器に対して、63 次元であるデータセット B は 8 個、16 次元であるデータセット C は 4 個の特徴量をそれぞれ用いた。

まず各データセットについて、TNR のグラフにおける、 L_{max} での接線の傾きを求めた。その結果、データセット B における 31 通りの既知位置の組み合わせの平均の接線の傾きは -0.020 (標準偏差 0.004)、データセット C における 30 通りの既知位置の組み合わせの平均の接線の傾きは -0.008 (標準偏差 0.006) となった。この傾きを用いて、

それぞれの L_{max} を見積もった。このときの NA の平均を表 7 に示す。このように、データセット B, C においても提案手法の有効性を確認した。

表 7 異なるデータセットにおける新規性判定性能 (NA)

条件	データセット B			データセット C		
	nonEns	L_{est}	L_{max}	nonEns	L_{est}	L_{max}
NA	0.634	0.760	0.770	0.685	0.768	0.796

5.2.6 TPR および TNR への影響

5.1 節で述べたように、アンサンブル型は LOF において TNR が IForest と比べて大幅に低いことの改善が念頭にあり、TPR を考慮しつつ TNR を上昇させるためにそれらの平均である NA に着目していたが、最後に TPR と TNR について考察する。表 8 に、nonEns, L_{est} , L_{max} での TPR と TNR を示す。また、表 4 および表 7 で示した NA も合わせて示す。この表より、 L_{est} において、TPR は nonEns と比べ低下している。一方で、TNR は非常に大きく上昇しており、結果的に NA が大きく上昇した。4.2.2 項では、システム全体を見通したときに TPR が大きいことが重要であるとしたが、現状は TPR が低下する結果となった。データセット B と C に対して、IForest を単体で (nonEns で) 適用した時の TPR は、表 2 より 0.755 と 0.737 であるため、これらを超えることはできなかったが、データセット A の TPR および、全てのデータセットの TNR と NA は LOF のアンサンブル型の方が高い値を得た。もともと低い TPR をもつ IForest に本手法をそのまま適用した場合には、さらに TPR が下がることが予想されるため、現時点では提案手法が総合的に見ると最善の手法となっていると考える。今後は TPR を維持しつつ NA を上昇させる L を検証し、その見積もり方法を考案する。

6. 今後の取り組み

本稿ではシステムの未知位置検出 (図 1 (A)) に焦点を当てた。今後は上述の課題解決に加え、システムの他の部分の設計と検証を行い、システム全体として効率的かつ効果的に新規の所持場所を追加する仕組みを明らかにしていく。

1 つ目は、適切な仮クラス抽出タイミングの検証である (図 1 (C))。未知サンプルプールに蓄積されたサンプル数やサンプルの特徴を変え、次段に進む適切なタイミングを検証する。2 つ目は、仮クラス抽出手法の検証である (図 1 (D))。未知と判定された所持位置数は分からないためクラスタリングを行うが、その手法やクラス数を変えてより適切に仮クラスを生成できる方法を検証する。3 つ目は、適切なラベル付け方法の検証である (図 1 (E))。使用者が

表 8 異なるデータセットにおける評価結果のまとめ

	データセット A			データセット B			データセット C		
	nonEns	L_{est}	L_{max}	nonEns	L_{est}	L_{max}	nonEns	L_{est}	L_{max}
TPR	0.949	0.803	0.823	0.822	0.735	0.759	0.744	0.688	0.770
TNR	0.412	0.864	0.856	0.445	0.786	0.781	0.626	0.848	0.822
NA	0.680	0.833	0.839	0.634	0.760	0.770	0.685	0.768	0.796

ラベル付けを行う際に提示するサンプルの決定方法やその数が検証事項としてあり、使用者の負担を下げながらもラベリング性能を維持する。これらの機能を通して新規クラスが生成されるが、それを既知クラスに追加したときの、所持位置認識精度の変化も検証する (図 1 (B))。

7. おわりに

本稿では携帯機器の所持位置認識問題において、利用者の利用形態に合わせて認識対象 (所持位置) を逐次追加可能にすることを旨としたシステムを提案した。なかでも、前段に位置しており新たなサンプルが既に認識器が学習済みか否かを判定する「未知位置検出」機能を、機械学習の一技術である新規性検出 (Novelty Detection) 技術で実現するにあたっての適用性を検証した。OCSVM, LOF, IForest の 3 つの新規性検出手法を用い、3 つのデータセットで実験を行った。その結果、3 つのデータセットで TPR, TNR, NA それぞれに類似の傾向があり、TPR の高さや安定性の観点から総合的に判断すると LOF が本問題に適していることを確認した。

また、RandomForest の原理を参考にしたアンサンブル型 Novelty Detection を提案した。複数の弱検出器からの結果を統合する際に単純な多数決では不十分であることを示し、判定閾値 (L) を変化させて TNR を求めたときの任意の L での TNR の接線の傾きに注目して NA が最高となる L_{max} を解析的に見積もる手法を提案した。そして、弱検出器の数 (S) や LOF のハイパーパラメータ ($cont$)、複数のデータセットへの適用を通して頑健性を確認した。一方で、TPR がアンサンブル型を用いないときと比べて低下したため、今後は本来の高い TPR を維持しつつ NA (TNR) も向上させる手法を検討する。また、本稿ではシステムの一部分を扱ったため、他の部分の検討も進めていく。

謝辞

日本学術振興会 科学研究費補助金 (18H03228) および (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] A. AlSuwaidi, et al.. Feature-Ensemble-Based Novelty Detection for Analyzing Plant Hyperspectral Datasets.

IEEE J. Selected Topics in Applied Earth Observations and Remote Sensing, 11(4), pp. 1041–1055, 2018.

[2] M. 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.

[3] L. Breiman. Random forests. *Machine learning*, 45(1), pp. 5–32, 2001.

[4] M.M. Breunig, et al., LOF: Identifying Density-Based Local Outliers, *Proc. of ACM SIGMOD'00*, pp. 93–104.

[5] R. Domingues, et al. A Comparative Evaluation of Outlier Detection Algorithms: Experiments and Analyses. *Pattern Recognition*, Vol. 74, pp. 406–421, 2018.

[6] A. Exler, et al. Investigating the Perceptibility Different Notification Types on Smartphones Depending on the Smartphone Position. *Proc. of UbiComp '17*, pp. 970–976, 2017.

[7] K. Fujinami, et al. Fine-grained Accelerometer-Based Smartphone Carrying States Recognition during Walking. *Int'l J. Advanced Computer Science and Applications*, 8(8), 2017.

[8] K. Fujinami. On-Body Smartphone Localization with an Accelerometer. *Information*, 7(2), 2016.

[9] K. Fujinami, et al. Smartphone-based Environmental Sensing using Device Location as Metadata. *Int'l J. Smart Sensing and Intelligent Systems*, 9(4), 2016.

[10] J. Guo, et al. Smartphone-Based Patients' Activity Recognition by Using a Self-Learning Scheme for Medical Monitoring. *J. Med. Syst.*, 40(6), pp. 1–14, 2016.

[11] F. Ichikawa, et al. Where's The Phone? A Study of Mobile Phone Location in Public Spaces. *Proc. of the 2nd Asia Pacific Conference on Mobile Technology, Applications and Systems (APCC)*, pp. 1–8, 2005.

[12] F. T. Liu, et al., Isolation Forest, *Proc. of IEEE ICDM'08*, pp. 413–422.

[13] D. Miljković. Review of Novelty Detection Methods. *Proc. of the 33rd Int'l Convention MIPRO*, pp. 593–598, 2010.

[14] B. Schölkopf, et al., Support vector method for novelty detection, *Proc. of ICONIPS'99*, pp. 582–588.

[15] B. Settles. Active learning literature survey. *University of Wisconsin, Madison Technical report*, Vol. 52, No. 55-66, p. 11, 2010.

[16] Y. Shi, et al. A Rotation Based Method for Detecting On-Body Positions of Mobile Devices. *Proc. of UbiComp '11*, pp. 559–560. ACM, 2011.

[17] M. Shoaib, et al. Fusion of Smartphone Motion Sensors for Physical Activity Recognition. *Sensors*, 14(6), pp. 10146–10176, 2014.

[18] J. Yin, et al. Sensor-Based Abnormal Human-Activity Detection. *IEEE Trans. on Knowledge and Data Engineering*, 20(8), pp. 1082–1090, 2008.

[19] 新納, 他. LOF と One Class SVM を用いた特異用例の検出. 言語処理学会第 16 回年次大会発表論文集, 2010.