

# 利用者の積極的な関わりによる携帯機器の帯同場所認識機能の個人化

代表研究者 藤波香織 東京農工大学大学院 工学研究院 先端情報科学部門 教授

## 1 はじめに

近年、スマートフォンに限らず、熱中症警告器や活動量・消費カロリー計のような、通知や計測用の機器をズボンのポケットや鞆に入れたり、上腕や前腕に装着したりして帯同する機会が増えている。しかし、その帯同場所は様々な理由で一定ではなく、胸ポケットでは聞こえた着信音がズボンのポケットでは聞こえなかったり、ズボンのポケットでは正しい温度が測れなかったりするなど、機器が帯同場所に合った振る舞いととらないと狙った効果を発揮できなくなることがある。これに対して、歩行で生じる帯同場所特有の機器の動きを慣性センサで取得し、機械学習により構築した認識器で帯同場所(クラス)を判定するシステムは、行動認識の一対象として過去7, 8年で急速に注目されてきている[1, 3-6]。帯同場所判定の可能性が検証されてきた黎明期の従来は、帯同場所と行動(歩行や走行)を限定して利用者共通の認識器の構成法が研究されてきた。実用に際しては、多様な帯同場所や帯同時の行動をカバーすることと、同一クラス内での個人差の吸収が課題となっている。本研究ではこれらの課題に対して「認識器の逐次個人化」の面からアプローチし、その機構を明らかにすることを目的とする。

## 2 フレームワーク概要

本研究では、同一の帯同場所における動きや姿勢の個人差と帯同場所の個人差を利用中に逐次的に適応するための手法を対象とした。図1に本問題に対処するためのフレームワークを示す。大別して、1) 未知場所検出、2) 帯同場所判定、3) 逐次性能向上、4) 新帯同場所追加、5) ユーザ問い合わせ、の5つの主要機能で構成されている。なお、フレームワークはセンサ種別に依存するものではないが、帯同時にその帯同場所ごとに現れる動きや姿勢の特徴を捉えるのに適していることと、低消費電力性から本研究では加速度センサを使用する。

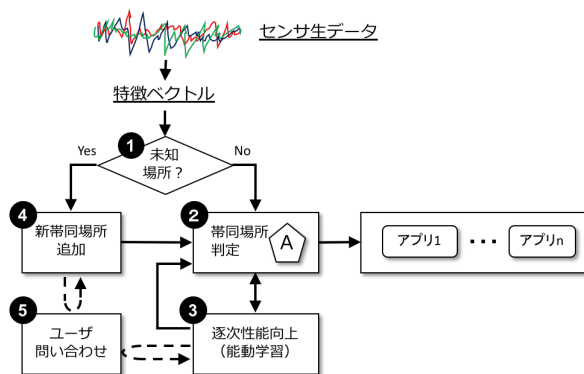


図1 携帯機器帯同場所認識器個人化フレームワーク

従来は、携帯機器搭載のセンサより取得した生データから帯同場所の特徴を表す多次元の特徴量(特徴ベクトル)が算出され、予め教師付学習により構築されている「②帯同場所判定機能」に入力されたのち、その出力である帯同場所情報がアプリケーションで使用されるという流れをとる[1, 3-6]。しかし、教師付学習では予め分類対象(クラス)は固定(既知)であるため、利用者固有の想定外の場所で帯同する場合には既知の場所のうちいずれかに分類せざるを得ず、その後のアプリケーションの挙動に影響を及ぼす。このため、既知でない(未知)ことを検出し、未知である場合にはそれを分類対象に追加するアプローチをとる。このとき必要となるのが、「①未知場所検出機能」と「④新帯同場所追加機能」である。

また、従来の分類器提供方法では、全ての利用者端末で共通的に使用することを前提としており、事前に個人差を吸収すべく十分多くの人からデータを収集するアプローチが取られてきたが、本研究では、能動学習[7]の枠組みを用いて利用開始後に利用者の協力を得て分類器を徐々にその利用者に適応させる個人化(パーソナライゼーション)アプローチを取る(③逐次性能向上機能)。この能動学習や前述の④新帯同場所追加においては利用者からの入力が必要となり、そのタイミングや問い合わせ内容、問い合わせ方法などに関する「⑤ユーザ問い合わせ機能」が存在する。以下では、①、③、④および⑤についての検討および実験結果を報告する。

### 3 新たな帯同場所の逐次的な追加と未知場所の検出

図 1 の①および④に関する取り組みについて述べる。

#### 3-1 概略

前述のように帯同場所判定機能は教師付学習により予め指定した種類の帯同場所（クラス）への分類ルールを学習により獲得して実現するため、想定外の場所で帯同が行われた場合には正しく判定ができない。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、未知位置を検出したうえで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。未知場所検出機能は、新規性検出 (Novelty Detection) 技術 (以下, ND 技術) として実現することとし、その適用方法を検討した。ND 技術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り、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) 既知モデル生成：訓練サンプルを与え、既知モデルを生成する。

(2) 未知サンプル検出：テストデータを既知モデル空間に投影し、既知または未知サンプルと判定する。

類似の技術に異常検出 (Outlier Detection) があるが、異常検出に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。

図 1 の①にて未知クラスと判定された場合の新帯同場所追加処理について説明する。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。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。そして、抽出した仮クラスに対し⑤のユーザ問い合わせ部の処理に従い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。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、 $n+m$  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モデルを更新する。

#### 3-2 ND 手法の適用性検証実験

未知位置検出への ND 技術の適用性や次元削減の影響の検証を目的とした、オフライン実験を行った。

##### (1) データセット

3つの携帯機器所持位置認識研究[1, 5, 9]で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。データセット A[5]は11箇所の所持位置（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）における70人分のデータ（145,661サンプル）、同 B[1]は9箇所の所持位置（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）の20人（34,962サンプル）、同 C[9]は5箇所の所持位置（ズボン左・右ポケット、ベルト、上腕、手首）10人分（22,450サンプル）で、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。

##### (2) 実験方法

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 らの研究[10]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  $31 (= \sum_{k=1}^5 {}_9C_k)$  通りとして同様に進行。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。

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に差があるときに有効な精度である。

### (3) 検証に用いる ND 手法

本稿で扱う 3 つの新規性検出手法を紹介する。Domingues ら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 [8]。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) [11], Local Outlier Factor (以下 LOF) [12], Isolation Forest (以下 IForest) [13] 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。

### 3-3 ND 手法の適用性検証結果と考察

実験結果を表 1 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する。データセットの全てにおいて、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。

ここで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。上述のように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ため、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後述の能動学習 [7] 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。その上で、TPR を 1 に近い値に保ちつつ、TNR をできる限り高くする方法を検討する必要がある。

今後は、3-1 節で述べた新規場所追加処理の残りの部分、すなわち未知場所候補の一時蓄積 (プーリング) 後にクラスタリングによる仮クラス抽出、利用者によるラベル付けを経て、未知クラス検出器と帯同場所判定器の再学習に至る処理の実現方法を考案する。これには、仮クラス抽出 (クラスタリング) を行う適切なタイミングやクラスタリング手法、利用者による効率的かつ効果的なラベル付け手法などが含まれる。

表 1 データセットごとの ND 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

## 4 帯同場所の逐次的性能向上手法

図 1 の③に関する取り組みについて述べる。

### 4-1 概略

逐次性能向上にあたっては、半教師付学習法の一つである能動学習 (Active Learning) を用いることで、利用者の協力を得ながらその人物からのデータを精度良く分類できる分類器に更新していく。また、能動学習を開始する時点の分類器である「核分類器」の提供方法について、全ユーザで共通の分類器を用いるのではなく、利用者と相性がよい分類器を選択することで収束を加速する手法を提案し、両者を比較する。図 2 に帯同場所の性能を逐次的に向上するための主要機能とその関係を示す。なお、②、③、⑤は図 1 に対応している。




図 2 核認識器選択にもとづく能動学習処理

図 2 に帯同場所の性能を逐次的に向上するための主要機能とその関係を示す。なお、②、③、⑤は図 1 に対応している。

#### (1) 能動学習手法

能動学習の基本的な考えは、「分類器が判定に自信がない場合には答えを知っている人間にラベルを付けてもらう」ということである。すなわち分類の境界を人間の協力を得て明確にすることである。ラベル付けを依頼する対象の決定法には、事例 (インスタンス) ごとに判定を行うインスタンスベースの方法と、一定数のインスタンスを保持した後に判定するプールベースの方法があるが、本研究では後者を用いる。また、不確実性を表す指標には様々なものが考案されているが、一般にドメイン依存である。本研究では 3 種類の代表的な指標 (Least Confident (LC, 式 (1)), Margin Sampling (MS, 式 (2)), Entropy (ENT, 式 (3))) を比較し、一定の精度に達する (収束する) までの問い合わせ回数を検証する。

以下の各式の左辺はプールされているインスタンス中のインデックス、すなわちラベル問い合わせ対象のデータを表す。そして、 $x, P_\theta, y_i$  はそれぞれ特徴ベクトル、分類モデル  $\theta$  における事後確率、 $i$  番目のクラスを表す。また、 $y_{1st}^{\wedge}$  と  $y_{2nd}^{\wedge}$  はそれぞれ事後確率が最大と 2 番目に最大となるクラスを表す。式 (1) は、分類時に選ばれるべきクラスの事後確率が最小となるインスタンスを問い合わせることを表しており、プールされているインスタンスの中で最も自信が低いものを指す。式 (2) は最大の事後確率と次点の事後確率の差が最小のもの、すなわち僅差で最大の事後確率を取るクラスが分類結果となるものを問い合わせ対象とするという考え方にもとづく。そして、(3) は事後確率分布を用いて計算されるエントロピーを表しており、どのクラスとも判断し難い曖昧な状態に選ばれやすいことを意味する。

$$x_{LC}^* = \arg \max_x (1 - P_\theta(y_{1st}^{\wedge}|x)) \quad \dots \dots \dots (1)$$

$$x_{MS}^* = \arg \min_x (P_\theta(y_{1st}^{\wedge}|x) - P_\theta(y_{2nd}^{\wedge}|x)) \quad \dots \dots (2)$$

$$x_{ENT}^* = \arg \max_x (-\sum_i P_\theta(y_i|x) \log P_\theta(y_i|x)) \quad \dots \dots (3)$$

#### (2) 相性にもとづく核分類器の選択

後の適応の核となる分類器 (核分類器) を当該利用者 (ターゲットユーザ) との相性にもとづき選定する。表 2 を用いてこの概念を説明する。この表の行は訓練済みの分類器を表し、列はターゲットユーザを表しており、値は精度 (F 値) を表している。例えば、ユーザ X のデータを分類器  $C_1$  により分類した結果の F 値は 0.9 であり、これは分類器  $C_1 \sim C_4$  を用いた中で最も高いことを表している。よって、分類器  $C_1$  はユーザ X との相性が最も良いと見なせる。

表 2 分類器と新規ユーザの相性の例

		訓練	
		ユーザ X	ユーザ Y
テスト	$C_1$	0.9	0.6
	$C_2$	0.7	0.8
	$C_3$	0.8	0.9
	$C_4$	0.5	0.7

同様に、ユーザ Y と最も相性が良い分類器は  $C_3$  になる。分類器  $C_k$  を用いたときの F 値を  $F_k$  とするとき、ユーザ  $u$  に対して選択される核分類器  $\theta_u$  は式 (4) で表される。

$$\theta_u = \arg \max_k F_k \quad \dots \dots (4)$$

## 4-2 評価実験

問い合わせインスタンス決定方法の特性理解と、相性にもとづく核分類器選択の有用性評価を目的としたオフライン実験を行った。

### (1) データセット

4-2 (1) の実験で用いたデータセット B (9 カ所) を用いた。ただし、1 名分 (ユーザ 20) は予備実験時にエラーとなったため除外した。

### (2) 実験方法：共通事項

問い合わせインスタンス決定方法の特性を理解するための実験と、相性にもとづく核分類器選択方法の有用性評価のための実験に共通する事項をまず述べる。一人抜き交差検証の手法で全 19 人のデータ提供者のうち 1 人をターゲットユーザと見なして、残りの 18 人それぞれから 18 個の核分類器を構築したうえで相性にもとづき選択し、能動学習を行うことを全ターゲットユーザ分繰り返した。図 3 に 1 人分の実験フローを示す。ユーザ X のデータから 20% 分を無作為抽出 (手順 1) した部分データから、さらに  $N_p$  個のインスタンスを無作為抽出し (手順 2)、これを 1 回分のプールされたデータとする。このプールデータに対して問い合わせ対象を決定する手法を適用する (手順 3)。問い合わせに対する反応は本来ユーザが行うが、オフライン実験においては事前に付与されているラベルをユーザが 100% 正しく回答したものとして扱い、当該データを加えて分類器を再学習する (手順 4)。その後、手順 1 で準備したデータを用いて分類器をテストして性能値 (F 値) を得る (手順 5)。手順 2 から 5 を、F 値が 0.999 に達するか部分データを使い切るまで繰り返す。これを 1 つの部分データに対して 10 回繰り返し、さらに 5 回分の部分データに対してこれまでの手続きを適用する。

本研究では所定の精度 (F 値,  $v_{finish}$ ) に達するまでの問い合わせ回数 ( $N_{query}$ ) を評価指標として用いる。能動学習では極力少ない問い合わせ回数で精度を向上させることが望ましいため、 $N_{query}$  が小さいほど良い。なお、 $v_{finish} = 0.95$  とする。横軸に問い合わせ回数、縦軸に F 値をとりプロットを行うことで、能動学習の

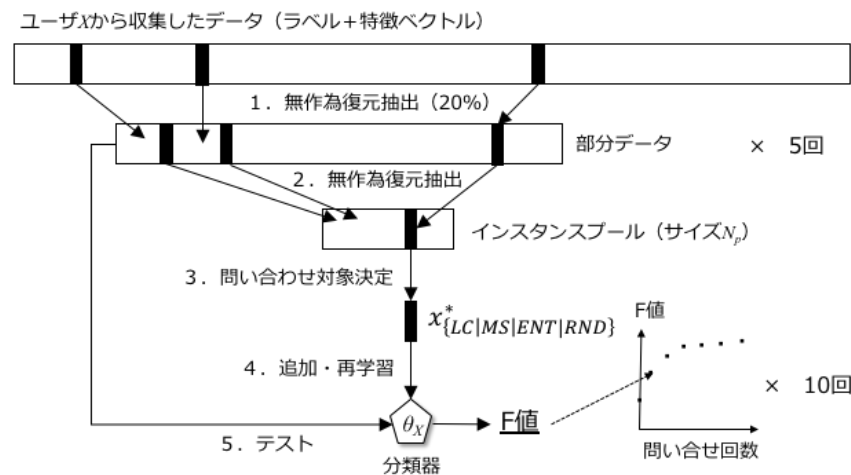


図 3 実験フロー

学習曲線を得ることができる。本研究では、1 つの部分データに対する 10 回分の学習過程を問い合わせ回数ごとに平均することで得る。この曲線に対して  $v_{finish}$  を連続して 3 回超えるまでの回数を  $N_{query}$  とする。そして部分データ 5 セット分の平均を後の評価で用いる。

また、ベースとなる分類器は RandomForest (弱分類器数=10) を用いた。機械学習ツールキット Weka に搭載の RandomForest 実装を用いた。この実装によれば、式 (1) ~ (3) に現れる事後確率 ( $P$ ) は、個々の弱分類器による分類を統合して相対度数分布化したものとなる。

### (3) 実験方法：問い合わせインスタンス決定方法の特性理解

本問題に適した問い合わせ対象の決定方法に対する理解を得るために、前述の LC, MS, ENT を上記の実験において用いた。さらにベースラインとしてランダム選択法 (RND) も用いた。

### (4) 実験方法：相性に基づく核分類器選択の有用性検証

19 人の全組み合わせを用いて 342 通り ( $=_{19} P_2$ ) の核分類器とテストユーザを作成し、上記の実験フロー

を適用した。一度も学習をしていない状態での F 値は 4-1 節 (2) の相性を表しており、相性値と  $N_{query}$  の関係を分析する。また、一人のテストユーザにつき 18 人分の相性計算が行われるが、その中で最も小さい  $N_{query}$  を  $\hat{N}_{query}$  とする。これは当該テストユーザに対する能動学習で可能な最小の問い合わせ回数とみなせ、 $N_{query} = \hat{N}_{query}$  となることが理想である。なお、問い合わせインスタンス決定方法は (3) で最も学習効率が良かった (平均の  $N_{query}$  が最も小さかった) 手法を用いた。

### 4-3 結果と考察

#### (1) 問い合わせインスタンス決定方法の特性

図 4 に問い合わせ回数と F 値の関係 (学習曲線) を示す。なお、この曲線は 18 人の 5 トライアルを平均したものである。F 値が 0.95 に達するまでの問い合わせ回数 ( $N_{query}$ ) に着目すると、LC, MAR, ENT, RND がそれぞれ 53.2 回, 46.8 回, 63.6 回, 124.4 回となった。式 (1) および (2) より、LC は 1 回ごとの判定に用いられる各クラスの事後確率の中で最大となる ( $P_{\theta}(y_{1st}^{\wedge}|x)$ ) クラス ( $y_{1st}^{\wedge}$ ) のみをみているのに対して、MAR は 1 番目  $P_{\theta}(y_{1st}^{\wedge}|x)$  と 2 番目  $P_{\theta}(y_{2nd}^{\wedge}|x)$  の差が最も小さく僅差で 1 番目のクラス ( $y_{1st}^{\wedge}$ ) が選ばれるようなインスタンスをみているため、曖昧なクラス間の境界を表しやすいことが MAR の優れる理由と考えられる。3 位となった ENT は各クラスをビンとする相対度数分布から計算されるエントロピーであり、RandomForest 中の弱分類器が分類対象のクラスにまんべんなく判定をする (1 つの正解クラス以外は誤分類) ほど高い値を取り、選択されやすくなる。つまり、LC は事後確率の上位 1 つ、MAR は上位 2 つのクラスに着目しているのに対して、ENT は全てのクラスを考慮している。ENT が振るわない理由は判定時の事後確率の分布を詳細に分析する必要があるが、全体を見るより「紛らわしい 2 つのクラス」に着目してその境界を明らかにするように利用者への問い合わせを行うのがよい、ということが示唆される。また RND の学習曲線から、単純に学習に用いるサンプル数が増えるだけでも精度は向上することがわかる。

#### (2) 相性に基づく核分類器選択の有用性

上記の実験結果より、最も学習効率が良かった MAR を用いて問い合わせインスタンスを決定した。相性値 (F 値) と  $N_{query}$  の関係を図 5 にプロットする。このプロットより計算される単相関係数は  $-0.531$  ( $N=342$ ) となり、無相関の仮説は棄却され、やや負の相関があるといえる。

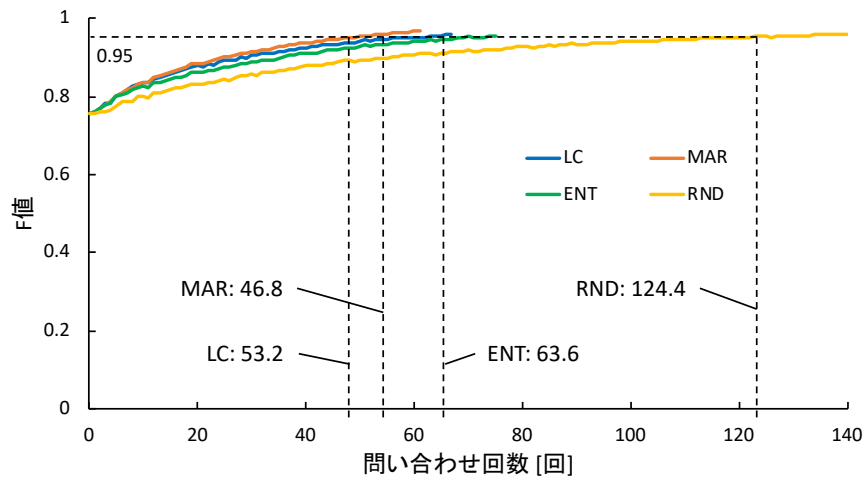


図 4 さまざまな問い合わせインスタンス決定方法に対する平均的な学習曲線

つぎに式 (4) にもとづき相性が良い (F 値が高い) 分類器を核分類器として用いた場合の問い合わせ回数  $N_{query}$  と理想値  $\hat{N}_{query}$  の 19 人分の平均値を求めたところ、それぞれ 31.7 回 (標準偏差 9.3) と 25.7 回 (同 6.6) となった。4-3 節 (1) で求めた MAR の  $N_{query}$  が 46.8 回であることから、相性が良い分類器を核として用いることで問い合わせ回数を 32.3% 削減でき (RND との比較では 74.5%)、利用者の負担を軽減できることが分かる。一方、理想値との差が 6.0 回あることから単純に F 値だけでは  $N_{query}$  を見積もれないことを示唆している。このことは前述の相関係数が -0.531 と相関がややあるにとどまっていることからもうかがえる。また本実験は、利用者が利用に先立ち全てのクラス (帯同場所) のデータを一定量提供することが前提となっているため、一部の場所から得たデータで最良の核分類器を選択する手法を今後開発する必要がある。




図 5 相性値と問い合わせ回数の関係




図 6 あるターゲットユーザの学習曲線と前後 2 回の問い合わせの差分

### (3) ユーザの積極的な関わりを促す要素の検討

上記の実験の結果より、MAR に相性にもとづく核分類器選択を組み合わせることで無作為のラベリングの時と比べると利用者の介入は 1/4 程度に抑えられるが、それでも数十 (30-40) 回のラベル付けが必要になる。このため、利用者が飽きずに継続するようなラベル付けへの参加動機付けが必要となる。研究室内でヒアリングした結果、残りの問い合わせ回数と達成感の提示が動機付けへの効果が期待できると考えた。

学習曲線はある程度学習が進んだ状態ではロジスティック曲線 (式 (5)) で近似可能なことを確認した。これにより、所望の精度に達するまでの残りの問い合わせ回数を見積もることができ、それを利用者に伝えることでラベル付けの動機付けに利用できる可能性がある。しかし、学習の初期段階では十分なサンプルが揃っておらずロジスティック曲線のパラメータ (式 (5) 中の  $b$  と  $c$ ) を精度良く推定することは難しい。

$$y = \frac{1.0}{1 + b \times e^{-cx}} \dots (5)$$

つぎに1回のラベル付けに対する達成感について考察する。図6に、あるターゲットユーザの1回分の学習曲線と問い合わせの前後でのF値の差分を示す。この図より、ラベル付けは必ずしも分類器精度の単調増加をもたらすのではなく、大きな増加の後に小さな増加（差分が正）や減少（差分が負）を繰り返しながら収束していくことが分かる。差分が負になることは精度が悪化したことを表すが、これは曖昧なインスタンスに正しいラベルが一つ付いたことで識別境界が大きく変化したために、前は正しく分類できていたサンプルが分類できなくなってしまうためと考えられる。ラベル付けのたびにその効果として差分を提示することは負であった場合に利用者のモチベーションを下げることに繋がりがねない。このため、利用者には大きな増加があったときだけ通知するようにするとともに、毎回通知をしないことを不審に思われない仕組みが必要である。

## 5 ユーザ問い合わせ機能

図1の⑤に関する取り組みについて述べる。

### 5-1 概略

これまで述べてきた新帯同場所追加機能や逐次性能向上機能は利用者からの入力により利用者の帯同状態に適合させる戦略を採っている。システムでラベル付けの必要性が生じたタイミングだけで利用者に問い合わせをすると、利用者に対応できない場合もあり問い合わせが無視され、ラベル付けのタイミングを逸することになる。このため、利用者に対応可能なタイミングを見計らうことがまず第1に必要なこととなる（図7⑤a）。これは「割り込み可能時推定 (interruption management)」と呼ばれる技術であり、現在様々な手法が研究されている[14]。

提案フレームワークでは、利用者に対応可能ではないと判断された場合には、問い合わせを一旦保留して対応可能になったときに実行することを想定する。このため、本来問い合わせがあったときに答えるはずであったラベル（帯同場所）を利用者が忘れていたり間違えたりする可能性がある。そこで、過去のラベルを正しく想起させるための問い合わせメッセージが必要になり、実験の結果、時間、場所、行動といった基本的なコンテキスト情報に加えて、本研究で扱うような習慣性のある行為に対しては、前日の同時刻の状態のように過去に付けられたラベルも提示することで、正しい想起が可能であることが分かった（図7⑤b）。

本研究では、問い合わせのタイミング (When) とメッセージ (What) ではなく、媒体 (How) に関して研究した（図7⑤c）。その際に、携帯機器以外にもPCやスマートウォッチなど情報通知を受け取れる機器を所有しているという前提を設ける。また、機器が受け取る通知は本研究で扱うラベル付け要求以外にも、業務の連絡や広告、友人知人との日常会話のようなものなど様々なものが含まれる。さらにメッセージの発信元もフレームワークだけでなく、様々な関係の強度を持った人が含まれる。このような一般的なメッセージ通知に対するデバイス選択のフレームワークを設計し評価を行った。

### 5-2 手法

図8に提案手法で用いるパラメータを図示する。本研究では、卓上作業中に通知を受け取るというシナリオでスマートウォッチ、PC、スマートフォンの3種の受信可能デバイスが存在していることを想定している。利用者と対象機器との距離と角度の2つを何らかの方法で取得する。周辺に他者がいる場合を考慮して各機器と他者の距離と角度も同様に求める。そして、利用者の各デバイスに対する即時応答可能性（通知が見えるため即時に対応できる状態を

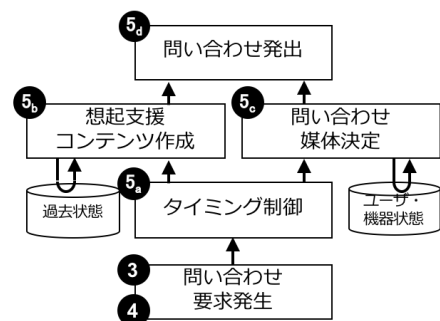


図7 ユーザ問い合わせ機能内部構成

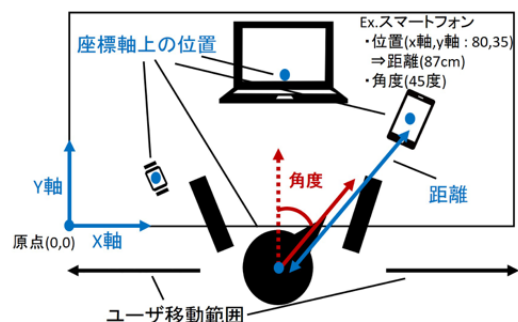


図8 提案手法で用いるパラメータ



1とし、通知に気付かない状態を5としその中間を含めた5段階)を顔中心からの距離と角度から決定する。これらの5つの情報を説明変数として、通知認識性( $c_1$ )、非集中阻害性( $c_2$ )、非プライバシー侵害性( $c_3$ )の3つの項目それぞれを目的変数とする回帰式を作成する。そして、式(6)に示すように、重み付け加算により総合評価点を決定し、全てのデバイスに対する総合評価点が催告のデバイスを通知先として選定する。なおウェイト( $w_1, w_2, w_3$ )は、通知の送信者と内容から判断される数値として、事前にアンケート調査により決定したが、実用上はアプリケーションのタイプやメッセージ内容のテキスト分析などにより自動的に決定する必要がある。また、式(6)に現れる通知の特性( $c_1, c_2, c_3$ )にはセンサやデータ処理の方法によらないため、適用可能な様々な手法を使用することが可能である。

$$S_{device} = w_1 \times c_1 + w_2 \times c_2 + w_3 \times c_3 \quad \dots (6)$$

### 5-3 実験

#### (1) 手法

上述のように通知の特性は計測手法やデータ処理と分離する構成を取っているため、本実験では確実に位置関係を取得可能となるよう、拡張現実感(AR)で使用する視覚マーカをデバイスや人物の頭部に装着した。13名の被験者を募り、一人あたり120件の様々なシチュエーションにおける通知を実際に体験し、その適切度を通知認識性、非集中阻害性、非プライバシー侵害性の3つの特性それぞれに7段階で回答した。各特性を予測する回帰モデルは線形回帰(Linear Regression (LReg))、最小二乗メジアン回帰(LMS)、SMO回帰(Sequential Minimum Optimizer (SMO))の3種類を用い、10分割交差検証により予測精度を比較した。

また、最も精度が良かった手法に関しては、実環境を用いて被験者の希望と回帰モデルにより予測されたデバイスの差異を集計した。被験者は上述のオフライン評価時に参加した者であるが、各自に用いられる回帰式は当該被験者を除いた者から収集したデータを元に構築している。各被験者は個人作業と共同作業を想定した各8つと7つのシチュエーションにおいて、毎回3つのデバイスに対する順位付けを行った。

#### (2) 結果

表3に10分割交差検証により求めた回帰モデルの評価結果をデバイスおよび評価特性ごとにまとめる。なお性能は平均平方2乗誤差(Root Mean Squared Error; RMSE)を用いており、小さいほど良い。この表より、線形回帰(LReg)がどのデバイスと通知特性の組み合わせにおいても誤差が最も小さくなった。

表3 デバイスおよび通知特性ごとの回帰モデル性能評価(RMSE)

通知デバイス 回帰モデル	スマートフォン			PC			スマートウォッチ		
	LReg	LMS	SMO	LReg	LMS	SMO	LReg	LMS	SMO
通知認識性	1.77	2.70	2.69	1.68	1.77	1.80	1.45	3.19	1.52
非集中阻害性	1.80	2.29	2.28	1.59	1.92	1.92	1.81	2.81	2.62
非プライバシー侵害性	2.01	2.35	2.08	1.57	1.62	1.63	2.30	2.40	2.45

つぎに実環境における実験結果についてまとめる。被験者が1位に順位付けしたデバイスとシステムが決定したデバイスとの一致度は、個人作業は60.0%、共同作業は44.3%となった。ランダム選択は33.3%となるため、提案手法により1.5~2倍程度はユーザが求めるデバイスに通知が行えていることになる。個人での作業中は、どのデバイスに来ても気付くことができるシチュエーションであるために全てのデバイスが同率1位であるとするような被験者が多かった半面、共同作業中はプライバシーの問題から順位を明確に設定している被験者が多かった。このため、個人作業を想定したシチュエーションにおいて一致度が高くなった可能性がある。デバイスへの順位付けの理由について聞き取ったところ、通知内容のプライバシー性を筆頭に、緊急性、作業中のデバイスであること、視界の範囲内であること、好み、と続いた。本研究の用途であるラベル付けに関しては、プライバシー性や緊急性はほとんど影響を与えないと考えられることから、応じやすさ(作業中のデバイスであることや視界に入っていること)が重要となると考えられる。

本実験は、スマートフォン、PC、スマートウォッチの3つを比較したが、それ以外にも第4のデバイスがある環境や、逆にスマートウォッチがない2台のみの環境にも適用可能である。通知の認識性や非集中阻害性、非プライバシー侵害性などの特性の算出方法も視覚マーカを用いずに屋外でも使用できる方法に置き換えることでより実用的になるが、前述のように情報とその取得手段は分離しているため対応は容易である。

## 6 おわりに

本研究では、スマートフォンを初めとした携帯機器の所持位置認識問題において、帯同者特有の帯同場所や方法に認識モデルを動的に適応させることを目的とした。その際に、自動適応ではなく利用者の積極的な関わりにより認識モデルを再学習するためのラベルを取得するアプローチを取った。積極的な関わりをもたらすためには極力少ない回数でできることが最低限必要であり、精度向上のための能動学習においては、核となる認識モデルを事前に当該利用者と最も相性が良いものを選び、ラベル問い合わせ選択に Margin Sampling 手法を用いることで、共通の分類器を用いて手当たり次第に利用者に問い合わせる手法と比べると約 75%の削減が可能であることを確認した。また、新規帯同場所の検出においては前段の処理において新規性検出 (Novelty Detection) の一手法である Local Outlier Factor (LoF) を用いることで、他の2手法と比べて総合的に良好な新規場所の検出が可能であることを確認した。そして、ラベルの問い合わせにおいては、多数の通知デバイスから最適なものを決定することに焦点を当て、用いるセンサやデータ処理手法と独立なフレームワークを考案した。今後は残った機能の検討・実装と全てを統合してスマートフォン上に実装した上での実機評価実験が必要である。

### 【参考文献】

1. K. Fujinami; "On-Body Smartphone Localization with an Accelerometer", Information, Vol. 7, No. 2, Article No. 21, 2016.
2. K. Fujinami; "Smartphone-based Environmental Sensing Using Device Location as Metadata", International Journal on Smart Sensing and Intelligent Systems, Vol. 9, No. 4, 2016.
3. A. Vahdatpour, et al.; "On-body device localization for health and medical monitoring applications", In Proceedings of PerCom'11, 2011, pp. 37-44.
4. A. Mannini, et al.; "Accelerometry-based recognition of the placement sites of a wearable sensor", Pervasive and Mobile Computing, Vol. 21, pp. 62-74, 2015.
5. K. Fujinami, et al.; "Fine-grained Accelerometer-based Smartphone Carrying States Recognition during Walking", International Journal of Advanced Computer Science and Applications, Vol. 8, No. 8, 2017.
6. K. Alanezi and S. Mishra; "Design, Implementation and Evaluation of a Smartphone Position Discovery Service for Accurate Context Sensing", Computers and Electrical Engineering, Vol. 44, pp. 307-323, 2015.
7. B. Settles; "Active Learning Literature Survey", University of Wisconsin-Madison, Tech. Rep., 2009.
8. R. Domingues, et al.; "A comparative evaluation of outlier detection algorithms: Experiments and analyses", Pattern Recognition, Vol. 74, pp. 406-421, 2018.
9. M. Shoaib, et al.; "Fusion of Smartphone Motion Sensors for Physical Activity Recognition", Sensors 2014, Vol. 14, pp. 10146-10176, 2014.
10. F. Ichikawa, et al.; "Where's The Phone? A Study of Mobile Phone Location in Public Spaces", In Proceedings of 2005 2<sup>nd</sup> Asia Pacific Conference on Mobile Technology, Applications and Systems, 2005, pp. 1-8.
11. B. Schölkopf, et al.; "Support vector method for novelty detection", In Proceedings of ICONIPS'99, 1999, pp. 582-588.
12. M. M. Breunig, et al.; "LOF: Identifying Density-Based Local Outliers", In Proceedings of ACM SIGMOD'00, 2000, pp. 93-104.
13. F. T. Liu, et al.; "Isolation Forest", in Proceedings of IEEE ICDM'08, 2008, pp. 413-422.
14. T. Okoshi et al.; "Reducing users' perceived mental effort due to interruptive notifications in multi-device mobile environments", In Proceedings of ACM UbiComp '15, 2015, pp. 475-486.

〈発表資料〉

題名	掲載誌・学会名等	発表年月
Extensible On-Body Smartphone Localization: A Project Overview and Preliminary Experiment	In Proc. of the 17 <sup>th</sup> IEEE International Conference on Pervasive Intelligence and Computing (PICom 2019)	2019年8月 (採録決定)
A Framework for Human-centric Personalization of Context Recognition Models on Mobile Devices	In Proc. of the 17 <sup>th</sup> IEEE International Conference on Pervasive Intelligence and Computing (PICom 2019)	2019年8月 (採録決定)
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	情報処理学会ユビキタスコンピューティングシステム研究会第62回発表会, 情報処理学会研究報告 Vol. 2019-UBI-62, No. 2.	2019年6月
Understanding Compatibility-based Classifier Personalization in Activity Recognition	In Proc. of the 1 <sup>st</sup> International Conference on Activity and Behavior Computing (ABC2019)	2019年6月
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	情報処理学会第81回全国大会	2019年3月
コンテキストおよびコンテンツウェアな情報通知先決定機構	電子情報通信学会ヒューマンプロープ研究会第20回研究会	2019年2月
Active Learning-based Classifier Personalization: A Case of On-body Device Localization	In Proc. of the 2017 IEEE 6th Global Conference on Consumer Electronics (GCCE2017)	2017年10月
Fine-grained Accelerometer-based Smartphone Carrying States Recognition during Walking	International Journal of Advanced Computer Science and Applications, Vol. 8, No. 8, pp. 447-456	2017年9月
Personalizing Context Recognition Model based on Active Learning: A Project Overview	The 2nd International Workshop on Smart Sensing System (IWSSS'17)	2017年8月