

アクティブ・パッシブセンシングを用いた学習環境への過剰適合を考慮した屋内位置セマンティクス推定手法

立川 雅也¹ 前川 卓也^{1,2,a)} 松下 康之¹

受付日 2016年12月10日, 採録日 2017年7月4日

概要: 近年スマートフォンを用いた屋内位置推定に関する研究が多く行われており, 推定される屋内位置情報のうち, 「会議室」や「食堂」といった屋内位置セマンティクス情報はライフログや高齢者の見守りなどの様々なアプリケーションのための重要な情報である. 一般的な屋内位置のセマンティクスを推定する手法では, 対象とする環境ごとに学習用のセンサデータを収集する必要があり導入コストが大きいという問題がある. そこで本論文では, 異なる環境において得られた学習データを利用することで, 対象とする環境において新たに学習データを収集する必要のない, 屋内位置のセマンティクスを推定する手法を提案する. 提案手法では, 一般的な屋内位置推定で利用されるパッシブセンシングに加えて音声のアクティブセンシングを組み合わせることで, 環境に依存しない特徴量を取得し, 他環境から得た学習データを用いて屋内位置セマンティクスを推定する. 提案手法では, 他環境の学習データに過剰適合しない分類器をランダムフォレスト分類器を基に構築する. 評価実験では複数の環境でセンサ情報の取得を行い, 提案手法の有効性を検証した.

キーワード: 屋内位置推定, パッシブセンシング, アクティブセンシング

Active/passive Sensing-based Indoor Location Semantics Estimation with Environment Independent Learning

MASAYA TACHIKAWA¹ TAKUYA MAEKAWA^{1,2,a)} YASUYUKI MATSUSHITA¹

Received: December 10, 2016, Accepted: July 4, 2017

Abstract: In this study, we present a method for estimating a user's indoor location without using training data collected by the user in his/her environment. Specifically, we attempt to predict the user's location semantics, i.e., location classes such as restroom and meeting room. While indoor location information can be used in many real-world services, e.g., context-aware systems, lifelogging, and monitoring the elderly, estimating the location information requires training data collected in an environment of interest. In this study, we combine passive sensing and active sound probing to capture and learn inherent sensor data features for each location class using labeled training data collected in other environments. In addition, this study modifies the random forest algorithm to effectively extract inherent sensor data features for each location class. Our evaluation showed that our method achieved about 85% accuracy without using training data collected in test environments.

Keywords: indoor positioning, passive sensing, active probing

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology,
Osaka University, Suita, Osaka 565-0871, Japan

² 国際電気通信基礎技術研究所
Advanced Telecommunications Research Institute International (ATR), Souraku-gun, Kyoto 619-0237, Japan

a) maekawa@ist.osaka-u.ac.jp

1. 序論

近年のセンサの小型化, 低価格化により日常を映像・音声・位置情報などのデジタルデータとして記録するライフログが注目されており, スマートフォンを用いたライフロ

グに関する研究が多く行われている [5]。ライフログにおける重要なコンテキスト情報の 1 つが屋内位置情報であり、一般的な屋内位置推定では位置座標を推定する手法がさかんに研究されているが [12], [19], ライフログなどへの応用を考えると、位置の意味情報 (セマンティクス) を取得することが重要である。本論文での意味情報とは、たとえば「トイレ」や「寝室」などの位置/場所のクラスを指し、本論文ではこれらの位置のクラスを「場所クラス」と定義する。しかし、屋内位置のセマンティクスを推定する手法の多くは、学習用のセンサデータを環境ごとに収集する必要があるため、導入コストが大きいという問題がある。

そこで本研究では、異なる環境において収集した情報を学習データとし推定の対象とする環境 (対象環境) に適用することで、対象環境において新たに学習データを収集する必要のない、情報収集コストを抑えた屋内位置セマンティクスの推定を行う。ここで本論文における環境とは、あるユーザが滞在する建物 (家, 研究棟, オフィスビルなど) のことを指し、環境内にトイレやエレベータなどの様々な場所が存在する。提案手法では、一般的な屋内位置推定で利用されるパッシブセンシングに加え、対象に対してセンサ側から何らかの働きかけを行い、その結果対象から得られる反応や応答をセンシングするアクティブセンシングをあわせて利用することで高精度な推定を目指す。このとき、Wi-Fi 電波情報と加速度データを用いてあらかじめユーザが停留している地点をクラスタリングしたあと、そのクラスタのセマンティクスの推定を行う。これにより、一度アクティブセンシングとパッシブセンシングを組み合わせるとセマンティクスを推定してしまえば、その後の同じ場所の推定は Wi-Fi 電波のみ、もしくは Wi-Fi センシングを含めたパッシブセンシングのみで実現可能となる。さらに提案手法では、他環境の学習データに過剰適合しない分類器をランダムフォレスト分類器を基に構築する。パッシブセンシングでは Wi-Fi 電波情報・加速度情報・磁気情報・気圧情報を取得し、アクティブセンシングではスマートフォンから音声を能動的に発生させて得られるインパルス応答を取得する。特に磁気情報、気圧情報およびインパルス応答から環境に非依存な特徴を学習する。以上をまとめると、提案手法ではユーザから得られた加速度データを用いてユーザが長期停留した期間を導出したあと、Wi-Fi データを用いてユーザが長期停留した地点を導出する。その後、磁気情報、気圧情報、インパルス応答を用いて「会議室」や「トイレ」などの停留地点のセマンティクスを推定する。停留地点の導出は主に Wi-Fi データのクラスタリング (グループ化) により行われ、導出された停留地点のセマンティクス推定には分類分析を用いる。

本論文では、まず屋内位置推定に関する関連研究を紹介したあと、提案する屋内位置セマンティクス推定手法について説明する。その後、評価実験により提案手法の有効性

を検証する。筆者らの知る限り、屋内生活環境における環境非依存のセマンティクス多クラス分類を実現する手法は提案手法以外にこれまでに研究されていない [18]。

2. 関連研究

2.1 Wi-Fi 電波を用いた一般的な屋内位置推定

屋内位置推定に関する研究は多く行われているが、その中でも多くの研究者が Wi-Fi のアクセスポイント (AP) を利用した屋内位置推定モデルの構築を試みている。Wi-Fi 電波を用いた一般的な屋内位置推定手法の中で最も実用的な手法の 1 つにフィンガープリンティングによる位置推定がある。フィンガープリンティングの学習フェーズではユーザの位置座標とともにユーザが持つスマートフォンなどによって観測される Wi-Fi 電波情報 (AP 固有の MAC アドレスと AP からの電波強度) を用いる。AP の組合せとそれらの電波強度が位置座標固有の電波情報 (フィンガープリント) となる。収集されたフィンガープリントは位置推定モデルを構築する学習データとして用いる [10], [12], [13]。

2.2 音声のアクティブセンシングを用いた屋内位置セマンティクス推定

音声情報のアクティブセンシングを用いた屋内位置セマンティクス推定手法として、環境音やインパルス応答を利用したものがある。環境音を利用した手法では、事前に部屋ごとの環境音の特徴を学習することで、建物内において部屋単位のセマンティクスの推定を行うが、環境音がほとんど存在しない場合は部屋ごとの特徴が得られず正しい分類が困難になるという問題がある [20]。インパルス応答を利用する手法では、屋内環境で得られたインパルス応答は室内音響を表現しているため [14]、事前に推定環境でインパルス応答を測定し、その特徴を学習させることによって部屋単位でのセマンティクスの推定を行う。この手法は、インパルス応答を測定するために測定者が持つ端末から音声を発生させ録音した音声情報を利用するアクティブセンシングを利用するため、環境にかかわらず屋内位置セマンティクスの推定が可能である。一方、推定環境ごとに事前学習をする必要があるため学習コストが大きい [17]。アクティブセンシングを用いてトイレのセマンティクスを環境非依存で推定する研究も行われているが [8]、本研究ではパッシブセンシングと組み合わせることで多クラス分類を実現する。

2.3 パッシブセンシングを用いた屋内位置セマンティクス推定

パッシブセンシングにより得られた音声情報のフィンガープリントは屋内位置セマンティクス推定に用いられることがある。Tarzia らは室内の環境音から音声のフィンガープリントを求めスマートフォンユーザのいる部屋を推

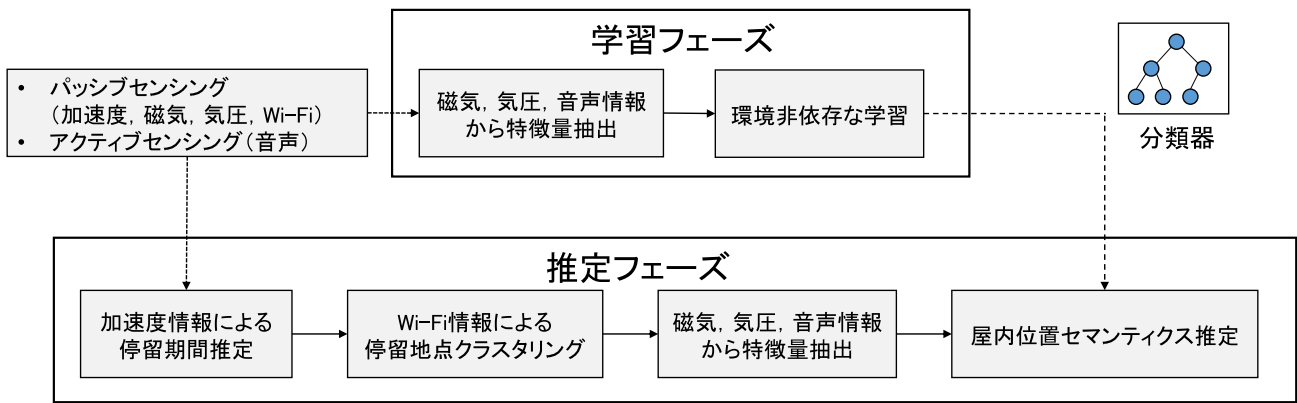


図 1 提案手法の概要

Fig. 1 Overview of proposed method.

定している [20]. また Azizyan らは音声情報に加え加速度, Wi-Fi 情報, 光情報, 画像から得られた特徴量からウォルマートやスターバックスといった店のラベルを推定している [2]. これらの手法は環境ごとに事前にデータを取得し学習を行う必要がある. またスマートフォンから磁気情報を取得し電化製品などの大きい磁気を示すような物体を通じてユーザの位置を推定する手法 [9], [21] や, 気圧情報を取得しユーザが位置する階数の推定や階段を昇る動作を特定するような手法 [1], [3] も研究されている. 上記のセンサに加えて照度センサ, カメラ, NFC reader などを利用してユーザの位置情報を求める手法 [15], [22], [23] もあるが, カメラを利用した手法にはプライバシーの問題がある. Bao らは部屋単位の屋内位置セマンティクスを滞在平均時間や滞在最大時間といった特徴を利用して推定する手法 [4] を提案しているが, 本論文では各場所クラスに特有の特徴量を収集し部屋単位の屋内位置セマンティクスを推定する手法を提案する.

3. 提案手法

3.1 提案手法の概要

提案手法の概要を図 1 に示す. 本研究ではユーザが日常生活で長期間停留する地点を対象とし, それらの屋内位置セマンティクスを推定する. 学習フェーズでは対象環境とは異なる環境において, パッシブセンシングとアクティブセンシングを利用し磁気情報・気圧情報・音声情報を収集し, それぞれ特徴量を抽出してセマンティクス分類器を学習する. 推定フェーズでは対象環境において磁気情報・気圧情報・音声情報に加え加速度情報・Wi-Fi 電波情報を収集し, 加速度情報を用いて停留期間を検出したあと, Wi-Fi 電波情報をクラスタリングすることで停留地点を導出する. ここで停留期間とはユーザが連続して長期停留した期間のことであり, その期間に収集された Wi-Fi データを用いて同じ地点で停留した期間をグループ化することによって, 停留地点を導出する. 観測される Wi-Fi アクセスポイントは環境ごとに異なるため, 対象環境ごとにクラスタリ

表 1 スマートフォンによるセンシング

Table 1 Sensing by smart phone.

センサ	サンプリング周波数	利用目的
加速度	30 Hz	停留期間推定
Wi-Fi	0.1 Hz	停留地点クラスタリング
磁気	30 Hz	位置セマンティクス推定
気圧	30 Hz	位置セマンティクス推定
マイク	44.1 kHz	位置セマンティクス推定

ングを行う必要がある. さらに, 各停留地点で収集した磁気情報・気圧情報・音声情報から学習フェーズと同様に特徴量を抽出しセマンティクス分類器を用いてセマンティクスを推定する. すなわち, ユーザが長期滞在する場所をクラスタリングにより分離したあと, そのセマンティクスを分類分析により推定する. 以降の節で学習フェーズと推定フェーズについて詳しく説明する.

3.2 学習フェーズ

本研究では, 環境から受動的に情報を取得するパッシブセンシングと, 環境に働きかけて情報を得るアクティブセンシングを組み合わせたセンシングを行う. 対象環境とは異なる環境の場所クラスが既知である地点においてパッシブセンシングによって磁気情報・気圧情報を, スマートフォンから音声を発生させ録音するアクティブセンシングによって音声情報を収集し, それぞれ特徴量を抽出, 結合した特徴ベクトルを用いて分類器を学習する. 本研究では分類器にランダムフォレストを基に構築した学習環境への過剰適合を考慮した分類器を用いる.

3.2.1 パッシブセンシングによる特徴抽出

パッシブセンシングにより取得した磁気情報・気圧情報は, それぞれ周辺の電子機器による磁気, エレベータや階段などの高度の変化する移動によって影響を受けると考えられるため, 時系列データに対してオーバラップ 50%, 窓幅 0.5 秒の時間窓で求めた移動分散を求め学習する. 図 2 と図 3 にエレベータとデスクで得られた磁気データの移




図2 エレベータでの磁気分散
Fig. 2 Variance of magnetic measurements in elevator.




図3 デスクでの磁気分散
Fig. 3 Variance of magnetic measurements at desk.




図4 スイープ信号波形
Fig. 4 Waveform of sweep.




図5 時間周波数表示
Fig. 5 Spectrogram of sweep.

動分散の推移を示す。エレベータではモータなどによる影響から磁気が大きく変化している。

3.2.2 アクティブセンシングによる特徴抽出

環境に依存しない普遍的な特徴量を得るため、スマートフォンから音声を発生させそのインパルス応答を測定する。インパルス応答は音響性質を表すものであり、特に同じマイク・スピーカを用いて様々な環境で測定すると環境ごとの室内音響が表現される。たとえばトイレ内の鏡や便器のように、同じ用途の部屋には共通するオブジェクトが存在することが多いため、室内音響を得ることでセマンティクスの推定に有用であると考えられる。インパルス応答はインパルス信号を発生させて得られるが、実世界において直接インパルス信号を発生させると、エネルギーが小さいため信号と雑音の比率であるSN比の小さいインパルス応答が得られてしまう。そのためインパルス信号を利用せずにインパルス応答を測定する手法として、ランダム信号を利用する手法 [6], [24] や時間とともに周波数に変化するサインスイープ信号を利用する手法 [16] などが提案されているが、本研究では SweptSine 法 [16] と呼ばれるサインスイープ信号とサインスイープ信号を時間反転させた信号で畳み込みを行うことによってインパルス応答を得る手法を用いる。本研究では、図4のような20 Hz から20 kHzまで周波数に変化する0.1秒間のスイープサイン波をスマートフォンから発生させ録音する。スマートフォンから信号を発生させるたびにその時刻を記録する。

周辺の人の声やドアの開閉音などの時間に周期的でないノイズの影響を軽減するため、スイープサイン波は0.3秒の間隔で連続再生し、録音された音声を再生したスイープサイン波の時間である0.1秒に連続再生の間隔の0.3秒を加えた合計0.4秒ごとに切り出し加算平均を行う。しかし、スマートフォンがOSに音声を発生するよう命令して




図6 同期処理なしで得られたインパルス応答
Fig. 6 Impulse response w/o synchronous averaging.




図7 同期処理ありで得られたインパルス応答
Fig. 7 Impulse response w/ synchronous averaging.

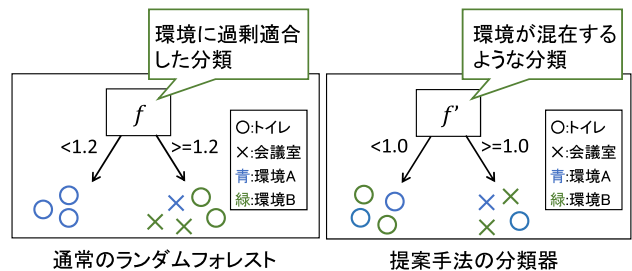


図8 提案する分岐関数を用いた分類
Fig. 8 Split using proposed split function.

から実際に音声が発生するまでに遅延が生じるため、単純に0.4秒ごとに切り出した受信信号を加算平均すると図6のような不正なインパルス応答が得られてしまう。そこで信号を発生させるときに記録した時刻から0.4秒ごとに単純に切り出した波形を時間軸で前後にスライドさせ1周期目の波形との差の絶対値を計算し、その値が最も小さくなる波形を加算平均に利用する同期処理を行うことによって正しいインパルス応答を測定する(図7)。その後、測定したインパルス応答から音声特徴量としてよく用いられるメル周波数ケプストラム係数(Mel Frequency Cepstral Coefficient: MFCC)による特徴抽出を行い学習する。本研究では、16のスイープ信号に同期加算を適用し得られたインパルス応答からMFCCを抽出する。

3.3 学習環境への過剰適合を考慮した学習

本研究では、ランダムフォレスト [7] を基に特定の学習環境への過剰適合をしないような分類器を構築する。ランダムフォレストにおける決定木学習では、データのクラスラベルを基に計算した情報エントロピーを $H(S)$ とすると式(1)、式(2)のように表されるクラスラベルのみを考慮したエントロピーの情報利得 $I(S)$ が最大となるように分岐条件 f を決定する。たとえば、図8の左図の通常のランダムフォレストの分岐条件の情報利得は1.2となっており、情報利得は大きい環境Aに過剰適合してしまい、学習環境と異なる環境のテストデータを与えられたときクラスラベルの分類が正しく行われぬ。

$$I(S) = H(S) - \sum_{i \in \{L,R\}} \frac{|S^i|}{|S|} H(S^i) \quad (1)$$

$$f = \arg \max I(S) \quad (2)$$

そこで提案手法では、データが得られた環境のラベルを基に計算した情報エントロピーを $H(E)$ とおくと式 (3) のように分岐関数 f' を決定することによって図 8 の右図のような多くの環境に共通する場所クラスのカテゴリを反映するモデルを作成する。

$$f' = \arg \max (I(S) - I(E)) \quad (3)$$

右図の提案手法の情報利得は左図の通常のランダムフォレストの情報利得より小さくなっているが、環境に過剰適合していない。環境ラベルから計算した情報利得 $I(E)$ は、分岐後に同じ環境ラベルを持つデータが多数存在していると大きくなるため、クラスラベルから計算した情報利得 $I(S)$ に $I(E)$ をペナルティとして与えることによって、同じ環境ラベルを持つデータが一方の分岐に偏らないようなクラス分類を行うことができる。

3.4 推定フェーズ

推定フェーズでは対象環境の様々な場所クラスにおいて、パッシブセンシングによって磁気情報・気圧情報・加速度情報・Wi-Fi 電波情報、アクティブセンシングによって音声情報（インパルス応答）を取得する。取得した加速度情報から長期停留期間を推定しその期間内に得られた Wi-Fi 電波情報から停留地点のクラスターリングを行う。また同時に取得した磁気情報・気圧情報・インパルス応答から学習フェーズと同様に特徴量を抽出し、学習フェーズによって作成された分類器を用いて各停留地点の位置セマンティクスの推定を行う。

3.4.1 長期停留期間の推定

取得した加速度情報を用いて長期停留期間を推定する。加速度の時系列データに対してオーバーラップ 75%、窓幅 2 秒の時間窓で移動分散を求め、事前に設定した閾値より分散が小さく、事前に設定した停留地点と見なす期間より長い期間を長期停留期間として推定する。閾値は実際に歩行と静止を繰り返したときの加速度の移動分散の値を考慮して定めた。また停留地点と見なす期間は、本研究で対象とした場所クラスのうち最も停留期間が短いと考えられるトイレのおおよその静止時間を基に 10 秒と設定した。

3.4.2 停留地点のクラスターリング

加速度情報によって推定された各長期停留期間ごとに、すべての長期停留期間で観測されたアクセスポイントについてそれぞれ得られた Wi-Fi 電波強度のベクトルを作成する。強度を取得できていない場合はその強度を形式的に -100dBm とする。各長期停留期間ごとに作成されたベクトルを用いて階層的クラスターリングを行う。階層的クラス

ターリングとはすべてのデータをそれぞれ 1 つのクラスターと設定しクラスター間距離が最も近いクラスターどうしを併合する処理をクラスター数が 1 になるまで繰り返す手法である。本研究では各クラスターを各長期停留期間で得られた Wi-Fi 電波強度のベクトルとし、クラスター間距離の計算はアクセスポイントごとに強度の差の絶対値を取る絶対平均誤差で求める。本研究では、閾値以下の距離を持つクラスターが見つからなくなるまでクラスターの併合を行う。閾値は事前実験の結果から定め、すべての環境で同一の閾値を使用した。

3.4.3 位置セマンティクス推定

加速度情報によって推定された各停留期間ごとに取得した磁気情報・気圧情報・インパルス応答から学習フェーズと同様に磁気情報・気圧情報からは移動分散、インパルス応答からは MFCC を特徴量として抽出する。このとき、インパルス応答は 16 周期の信号に対して同期加算を適用し求める。その後、学習環境への過剰適合を考慮した分類器を用いて位置セマンティクスの推定を行う。最後に同一停留地点に属する停留期間の位置セマンティクス推定結果を多数決することにより、停留地点のセマンティクス推定を行う。

4. 評価実験

提案手法の有効性を示すために、図 9 のようなデスク、エレベータ、食堂、休憩所（屋外喫煙所）、会議室、トイレの 6 つを場所クラスとする評価実験を行った。表 2 に示すような 4 つの異なる環境を実験環境として用いた。またセンサデータを取得するツールとしてスマートフォンを利



図 9 6 つの場所クラスの例

Fig. 9 Examples of 6 location classes.

表 2 実験環境の情報とそれぞれの場所クラスが位置する階
Table 2 Information about environments.

	環境 1	環境 2	環境 3	環境 4
建物	情報科学棟	情報科学棟	工学棟	理学棟
竣工年	2014	2015	1992	1996
デスクの階	2 階	7 階	7 階	3 階
トイレの階	2 階	6 階	1 階	3 階
会議室の階	3 階	6 階	1 階	3 階
食堂の階	2 階	2 階	1 階	1 階
休憩所の階	1 階	1 階	1 階	1 階

表 3 各場所クラスの実験時の周囲の状況
Table 3 Information about each location class.

場所クラス	周囲の状況
デスク	周囲に複数の研究者
トイレ	無人
会議室	無人, プロジェクター非起動
エレベータ	無人
休憩所	複数の通行人
食堂	昼食時, 大勢の客



図 10 測定姿勢

Fig. 10 Smart phone attachment.

用した。

4.1 データセット・評価手法

4つの異なる実験環境の各環境において、デスク、エレベータ、食堂、休憩スペース（屋外喫煙所）、会議室、トイレの6つの場所クラスをランダムに訪れ停留するセッションを合わせて10回ずつ行った。表2と表3に各実験環境の情報とそれぞれの場所が位置する階および各場所の実験時の周囲の状況を示す。各セッションでは図10のようにネクストラップに取り付けたスマートフォン（Nexus7P）を用いて、筆者らが開発したAndroid上で動作するソフトウェアを利用し音声・気圧・磁気・加速度・Wi-Fi電波のセンシングを継続的に行った。加速度、磁気、気圧のセンシングにはAndroid Sensor Frameworkを、Wi-Fi情報と音声のセンシングにはAndroidAPIのWiFiManagerとMediaRecorderをそれぞれ用いた。このように取得されたデータを用いて、ある環境で得られたデータをトレーニングデータ、他の環境で得られたデータをテストデータとして評価を行うLeave-One-Environment-Out交差検定を行った。

4.2 評価結果

提案手法の推定精度を図11と表4に示す。また、各環境ごとの推定精度を図12、図13、図14、図15と表5に示す。これらの結果から、どの環境においてもほぼ同程度の精度で位置のセマンティクスが推定されていることが分かる。また各場所クラスごとの精度を見ると、デスクの推定精度は他のクラスに比べて低いことが確認できる。この原因として、デスクへの推定に重要な特徴量が各環境ご



図 11 すべての環境下での混同行列

Fig. 11 Confusion matrix for all the environments.

表 4 すべての環境下での推定精度 [%]

Table 4 Classification accuracies for all the environments [%].

場所クラス	適合率	再現率	F 値
デスク	77.8	52.5	62.7
トイレ	72.9	83.3	77.8
会議室	73.5	87.8	80.0
エレベータ	94.1	84.2	88.9
休憩所	70.8	85.0	77.3
食堂	85.7	75.0	80.0

とに異なっており、各環境のデスクに共通する特徴量を取得できていなかったことがあげられる。しかし、トイレ・会議室・エレベータ・休憩所・食堂は非常に高い精度で推定することができており、全体としては高い精度での位置セマンティクスの推定が可能であることがいえる。

4.2.1 利用する特徴量による精度の変化

本研究では、分類に利用する特徴量として磁気分散、気圧分散、インパルス応答から抽出したMFCCを利用しているが、利用する特徴量の組合せによって精度がどのように変化するかを検証した結果を図19に示す。図中のMFCCはインパルス応答から抽出したMFCCを利用したものを示しており、磁気、気圧はそれぞれ磁気分散、気圧分散を利用したものを示している。この図19より、アクティブセンシングによって得られるインパルス応答のMFCCが他のパッシブセンシングで得られた磁気分散・気圧分散に比べ精度の向上に大きく寄与していることが分かる。また、1つのセンサからの特徴のみを利用したときの分類結果の混同行列を図16、図17、図18に示す。これらより、アクティブセンシングで測定したインパルス応答のMFCC特徴量は様々な場所クラスの推定に大きく貢献しており、気圧分散は高度に変化するエレベータの推定のための重要な特徴となっていることが確認できた。

4.2.2 スイープ信号の同期加算回数による精度の変化

3.2.2項のインパルス応答の測定の際、周期的でない雑音の除去のために複数の録音波形を同期加算する処理を行ったが、このとき同期させ加算する録音波形の数を変化させ




図 12 環境 1 の混同行列

Fig. 12 Confusion matrix of environment 1.




図 13 環境 2 の混同行列

Fig. 13 Confusion matrix of environment 2.




図 14 環境 3 の混同行列

Fig. 14 Confusion matrix of environment 3.




図 15 環境 4 の混同行列

Fig. 15 Confusion matrix of environment 4.




図 16 インパルス応答の MFCC のみを利用した混同行列

Fig. 16 Confusion matrix when only MFCC features of impulse response are used.



図 17 磁気分散のみを利用した混同行列

Fig. 17 Confusion matrix when only magnetic variance features are used.




図 18 気圧分散のみを利用した混同行列

Fig. 18 Confusion matrix when only barometric variance features are used.

表 5 各環境ごとの分類精度 [%]

Table 5 Classification accuracies for each environments [%].

環境	適合率	再現率	F 値
1	80.1	76.8	76.9
2	89.3	88.6	88.5
3	79.1	78.0	77.8
4	80.7	78.8	79.1




図 20 同期加算回数による精度の変化

Fig. 20 Transition of classification accuracies when the number of synchronous averaging is varied.




図 19 利用する特徴量の組合せごとの推定精度

Fig. 19 Classification accuracies when we use different combinations of features.

たときの精度の変化を図 20 に示す。これより、同期加算回数を多くすれば精度が向上していくことが分かるが、単調増加となっていないことも確認できる。原因として、複数のスイープ信号を再生し録音をしている期間に扉が閉まる音などの突発的な雑音が生じることにより加算回数を増やした方が大きな雑音が生じることがあることがあげられる。同期加算の回数をさらに多くすると、突発的な大きな雑音の影響が小さくなると予想されるが、同期加算の回数分だけスイープ信号を発信する必要があるため、情報収集コストが大きくなることが考えられる。

4.2.3 クラスタリングの結果

環境 1 における Wi-Fi 電波を用いた階層的クラスタリングにより得られたデンドログラムと各停留地点の正解ラベルの例を図 21 に示す。この図のように同じ場所クラスは近いクラスとして認識されており、閾値による分割を行うと正しくクラスタリングされた。また、環境 1 だけでなくすべての環境について正しく行われていることが確認された。

4.3 通常のランダムフォレスト分類器との精度の比較

3.4.3 項においてランダムフォレストを基に学習環境への過剰適合を考慮した分類器を提案したが、通常のランダムフォレストを利用したときの評価結果と提案手法の分類器を利用したときの評価結果を表 6 に示す。これら 2 つの分類器について、評価実験の 1 セッションごとに得られた F 値を用いて平均値の差で t 検定を用いたところ、両側 10%水準で有意差が認められた。提案手法の分岐閾数は、




図 21 環境 1 の Wi-Fi データから得られた
デンドログラム

Fig. 21 Dendrogram constructed using Wi-Fi data observed in environment 1.

表 6 ランダムフォレストと提案手法の分類器による評価結果 [%]
Table 6 Classification accuracies for the random forest and proposed method [%].

	適合率	再現率	F 値
通常のランダムフォレスト	76.8	73.0	75.4
提案手法の分類器	79.1	78.0	77.8

特定の環境に過剰適合することなく複数の環境に共通するクラス分類ルールを反映する決定木の分岐関数を作成するため、学習環境の総数が少ない場合や学習環境の中に他の環境と比べて得られる特徴量が大きく異なる環境が含まれるような場合に精度が大きく向上すると考えられる。

5. 結論

一般的な屋内位置セマンティクス推定手法では対象環境ごとに事前学習が必要であるという問題に対して、本研究ではアクティブセンシングとパッシブセンシングを組み合わせることにより場所の普遍的な特徴を取得し、対象環境ごとに事前学習を必要としない屋内位置セマンティクスを推定する手法を提案した。提案手法では、加速度より推定された各停留地点ごとに、アクティブ・パッシブセンシングにより取得した磁気分散・気圧分散・インパルス応答の MFCC の特徴量を利用し位置のセマンティクスを推定した。さらに特定の学習環境への過剰適合をしないような分類器をランダムフォレストを基に構築し用いた。提案手法の有効性を示すために、評価実験を行った。4つの異なる環境で6つの場所クラスをランダムに訪れ停留しながらセンシングを行い、提案手法を用いて位置セマンティクスの推定を行った提案手法の結果、高い精度で屋内位置のセマンティクスを推定することができ、提案手法の有効性を示すことができた。

今後の課題としては、分類精度の向上のため、さらに多くの環境における学習データの収集があげられる。また本実験では大学のキャンパス内でデータ収集を行ったが、た

例えばショッピングモールやホテルなどのまったく異なる環境では異なる場所クラスを追加した推定が必要となると考えられ、このような大きく異なる環境における実験も今後の重要な課題の1つである。さらに提案手法におけるクラスタリング手法で用いた閾値は事前検証から選択しており、環境が大きく異なるとその閾値も異なる可能性がある。クラス数数の自動決定はユビキタスコンピューティングの分野においてさかんに研究されている [11] 依然困難なタスクであり、今後解決すべき重要な課題の1つである。さらに本研究ではセンサデータを取得するツールとしてスマートフォンを利用したが、ネックストラップにスマートフォンを接続した携帯方法は一般的ではないため、スマートグラスやウェアラブルカメラなどのウェアラブルデバイス上でセンサデータ取得を行うことも今後の課題である。Google Glass のように頭部に設置されるデバイスや、Narrative Clip のように胸部に設置されるデバイスからは、本研究で収集したデータとほぼ同様のデータが得られると期待される。

謝辞 本研究の一部は、JST CREST JPMJCR15E2 および JSPS KAKENHI JP16H06539 の助成を受けて行われたものです。

参考文献

- [1] Asano, S., Wakuda, Y., Koshizuka, N. and Sakamura, K.: A robust pedestrian dead-reckoning positioning based on pedestrian behavior and sensor validity, *Position Location and Navigation Symposium (PLANS), 2012 IEEE/ION*, pp.328-333, IEEE (2012).
- [2] Azizyan, M., Constandache, I. and Roy Choudhury, R.: SurroundSense: Mobile phone localization via ambience fingerprinting, *Proc. 15th Annual International Conference on Mobile Computing and Networking*, pp.261-272, ACM (2009).
- [3] Banerjee, D., Agarwal, S.K. and Sharma, P.: Improving floor localization accuracy in 3D spaces using barometer, *Proc. 2015 ACM International Symposium on Wearable Computers*, pp.171-178, ACM (2015).
- [4] Bao, X., Liu, B., Tang, B., Hu, B., Kong, D. and Jin, H.: PinPlace: Associate semantic meanings with indoor locations without active fingerprinting, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.921-925, ACM (2015).
- [5] Blum, M., Pentland, A.S. and Tröster, G.: Insense: Interest-based life logging, *IEEE Multimedia*, Vol.13, No.4, pp.40-48 (2006).
- [6] Borish, J. and Angell, J.B.: An efficient algorithm for measuring the impulse response using pseudorandom noise, *Journal of the Audio Engineering Society*, Vol.31, No.7/8, pp.478-488 (1983).
- [7] Breiman, L.: Random forests, *Machine learning*, Vol.45, No.1, pp.5-32 (2001).
- [8] Fan, M., Adams, A.T. and Truong, K.N.: Public restroom detection on mobile phone via active probing, *Proc. 2014 ACM International Symposium on Wearable Computers*, pp.27-34 (2014).
- [9] Gozick, B., Subbu, K.P., Dantu, R. and Maeshiro,

- T.: Magnetic maps for indoor navigation, *IEEE Trans. Instrumentation and Measurement*, Vol.60, No.12, pp.3883–3891 (2011).
- [10] Gu, Y., Lo, A. and Niemegeers, I.: A survey of indoor positioning systems for wireless personal networks, *IEEE Communications Surveys & Tutorials*, Vol.11, No.1, pp.13–32 (2009).
- [11] Jiang, Y., Pan, X., Li, K., Lv, Q., Dick, R.P., Hannigan, M. and Shang, L.: ARIEL: Automatic wi-fi based room fingerprinting for indoor localization, *Proc. 2012 ACM Conference on Ubiquitous Computing (UbiComp '12)*, pp.441–450 (2012).
- [12] LaMarca, A., Chawathe, Y., Consolvo, S., Hightower, J., Smith, I., Scott, J., Sohn, T., Howard, J., Hughes, J., Potter, F. et al.: Place lab: Device positioning using radio beacons in the wild, *Pervasive 2005*, pp.116–133 (2005).
- [13] Liu, H., Darabi, H., Banerjee, P. and Liu, J.: Survey of wireless indoor positioning techniques and systems, *IEEE Trans. Systems, Man and Cybernetics, Part C: Applications and Reviews*, Vol.37, No.6, pp.1067–1080 (2007).
- [14] Oppenheim, A., Willsky, A.S. and Nawab, S.H.: *Signals and systems*, University of Michigan, Prentice Hall (1997).
- [15] Ozdenizci, B., Coskun, V. and Ok, K.: NFC internal: An indoor navigation system, *Sensors*, Vol.15, No.4, pp.7571–7595 (2015).
- [16] Paulo, J., Martins, C.R. and Bento Coelho, J.: Time Segmented Swept Sine Technique for Room Impulse Response Estimation, *Proc. ICSV*, Vol.12 (2005).
- [17] Rossi, M., Seiter, J., Amft, O., Buchmeier, S. and Tröster, G.: RoomSense: An indoor positioning system for smartphones using active sound probing, *Proc. 4th Augmented Human International Conference*, pp.89–95 (2013).
- [18] Tachikawa, M., Maekawa, T. and Matsushita, Y.: Predicting location semantics combining active and passive sensing with environment-independent classifier, *UbiComp 2016*, pp.220–231 (2016).
- [19] Taniuchi, D. and Maekawa, T.: Robust Wi-Fi based indoor positioning with ensemble learning, *IEEE 10th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob 2014)*, pp.592–597 (2014).
- [20] Tarzia, S.P., Dinda, P.A., Dick, R.P. and Memik, G.: Indoor Localization without Infrastructure using the Acoustic Background Spectrum, *Proc. 9th International Conference on Mobile Systems, Applications, and Services (MobiSys '11)* (2011).
- [21] Wang, H., Sen, S., Elgohary, A., Farid, M., Youssef, M. and Choudhury, R.R.: No need to war-drive: Unsupervised indoor localization, *Proc. 10th International Conference on Mobile Systems, Applications, and Services*, pp.197–210 (2012).
- [22] Xu, Q., Zheng, R. and Hranilovic, S.: Idyll: Indoor localization using inertial and light sensors on smartphones, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.307–318, ACM (2015).
- [23] Zhou, B., Lapedriza, A., Xiao, J., Torralba, A. and Oliva, A.: Learning deep features for scene recognition using places database, *Advances in Neural Information Processing Systems*, pp.487–495 (2014).
- [24] 伊達 玄: 数論の音響分野への応用, 日本音響学会誌,

Vol.42, No.11, pp.884–893 (1986).



立川 雅也 (学生会員)

平成 28 年大阪大学工学部電子情報工学科卒業, 同大学大学院情報科学研究科マルチメディア工学専攻博士前期課程入学. 機械学習に関する研究に従事.



前川 卓也 (正会員)

平成 15 年大阪大学工学部電子情報エネルギー工学科卒業. 平成 18 年同大学大学院情報科学研究科博士後期課程修了. 同年日本電信電話株式会社入社. 平成 24 年 4 月より大阪大学大学院情報科学研究科准教授. 平成 25 年 8~10 月スイス連邦工科大学ローザンヌ校招聘教授. 博士(情報科学). 本会平成 22 年度山下記念研究賞, 日本データベース学会平成 25 年度上林奨励賞等受賞. ACM, IEEE, 電気学会, 日本データベース学会各会員.



松下 康之

平成 10 年東京大学工学部卒業. 平成 15 年同大学大学院工学系研究科電子情報工学博士後期課程修了. 同年 Microsoft Corp. に入社し Microsoft Research Asia の Visual Computing Group に研究員として勤務. 平成 27 年 4 月より大阪大学情報科学研究科教授, 現在に至る. コンピュータビジョン・機械学習・最適化の研究に興味を持つ.