

研究論文

機械学習を用いたエリア検知技術導入支援システムの提案

肥田 一生^{1,a)} 陳 彬¹ 羽田 芳朗¹ 森 信一郎¹

受付日 2014年12月21日, 採録日 2015年5月21日

概要: 近年, あらゆる場所でサービスを楽しむことができるモビリティサービスが注目されている. なかでも, ユーザが居る場所に適したサービスを提供する LBS (Location-Based Service) が今後急速に市場を拡大すると予想されている. 屋内で利用される LBS は様々な装置を使用してデバイスが存在するエリアを検知する. 特に無線 LAN の RSSI (Received Signal Strength Indicator) を機械学習するエリア検知技術が検討されている. この技術は導入に際し新規に設備投資が不要でエリア検知成功率が電波環境の変動に影響されない. しかしこのエリア検知技術は導入の際に電波伝搬や機械学習の専門知識が必要で, このことが技術を広く普及させるうえで障壁になっていた. 筆者らはこうした専門知識を持たない作業者が RSSI を機械学習するエリア検知技術の導入を可能とする導入支援システムを開発した. このシステムは各エリアの RSSI データの相互相関を可視化して求めた RSSI データの類似度と RSSI データを使用して求めたエリア誤検知率の傾向が同様であることを確認することで, 電波伝搬の専門知識を持たない作業者がエリア検知成功率を見積ることを容易にする. また, RSSI データの類似度と利用可能なハードウェアの性能情報を使い, 機械学習の専門知識を持たない作業者が導入環境に適した機械学習法を選定することを容易にする. 本稿ではエリア検知技術の導入支援システムを提案し, その有効性を評価した結果を示す.

キーワード: エリア検知, 機械学習, 導入支援システム

Proposal of Installation Support System for Area Distinction Method Using Machine Learning

KAZUO HIDA^{1,a)} BIN CHEN¹ YOSHIRO HADA¹ SHINICHIRO MORI¹

Received: December 21, 2014, Accepted: May 21, 2015

Abstract: Nowadays, requirement of mobility services in anywhere have been increased to provide services us. For example, location-based service (LBS) is getting popular. Various kind of area distinction methods have been proposed to embody an indoor LBS. Especially, Wi-Fi based methods have advantages because any new devices for the LBS are not necessary and the area distinction accuracy is hardly affected by changes in the radio wave propagation environment. However, expert knowledge and skills of radio wave propagation and machine learning are necessary to install Wi-Fi based area distinction system. Therefore, the authors developed the installation support system for the Wi-Fi based area distinction system using similarity of radio wave propagation calculated by frequency distribution of RSSI correlation and area distinction accuracy with scanned RSSI samples. This system can be used easily by anyone include non-specialist because it has an ability to visualize the area distinction performance and select the machine learning engine suitable for the environment.

Keywords: area distinction, machine learning, installation support system

1. はじめに

近年, あらゆる場所で様々なサービスを楽しむことができるモビリティサービスが注目されている. モビリティサービスを実現するためには高機能なモバイルデバイスと無線通信イ

¹ 株式会社富士通研究所
Fujitsu Laboratories LTD., Kawasaki, Kanagawa 211-8588,
Japan

^{a)} hida.kazuo@jp.fujitsu.com

ンフラが必要だが、スマートフォンと無線 LAN が世界的に広く普及したことから [1], [2], モビリティサービスを実現するための条件が整ってきたと考えられる。

モビリティサービスのなかでもユーザが居る場所に適したサービスを提供する LBS (Location-Based Service) が今後急速に市場を拡大すると予想されている [3]. LBS の例として、近隣の観光スポット情報を通知するサービス [4], 博物館で眼前にある展示物を解説するサービス [5], SNS のチェックインサービスなどがある [6], [7].

屋外で利用される LBS の多くは GPS (Global Positioning System) [8] を使用してデバイスが存在するエリアを検知している。一方、屋内で利用される LBS は、無線 LAN, 赤外線ビーコン, IMES (Indoor Messaging System) など、様々な装置を使用してデバイスが存在するエリアを検知している [9], [10], [11]. しかし、これらのエリア検知技術は、いずれも専用の装置を新規にインフラに設置する必要があるため、技術導入に際しコスト面で障壁があった。そのためすでに世界的に広く普及している無線 LAN を使用するエリア検知技術が検討されている [12]. 無線 LAN を使用するエリア検知技術では既設の無線アクセスポイント (AP) を活用できるため、技術導入に際し新規の設備投資が不要となる。しかし、屋内環境では無線 LAN 電波の反射や減衰などの電波伝搬特性の変動によりエリア検知成功率が低下する問題が存在した。

そのためエリア検知成功率が無線 LAN 電波の伝搬特性の変動に影響されにくい、機械学習を使用した屋内エリア検知技術が検討されている [13], [14]. これらの技術では、機械学習を使用して複数の AP が送信した電波の受信信号強度指標 (Received Signal Strength Indicator; RSSI) をエリアごとに事前学習する。そしてユーザ端末で観測された RSSI データと事前学習した RSSI データを比較し、観測されたデータと最も類似している事前学習データを持つエリアをユーザ端末が存在するエリアと判定する。図 1 に機械学習を使用するエリア検知技術の基本原則を示す。図 1 では、ユーザ端末で観測された AP1 の RSSI が AP2 の RSSI よりも高い場合にエリア A, AP2 の RSSI が AP1




図 1 機械学習を使用するエリア検知技術の基本原則

Fig. 1 Basic principle of area distinction technology using machine learning.

の RSSI よりも高い場合にエリア B にユーザ端末が存在すると判定する。しかし、このエリア検知技術では、技術の導入と保守の際に電波伝搬や機械学習の専門知識が必要であり、このことが技術を広く普及させるうえで障壁になっていた。

筆者らは電波伝搬や機械学習の専門知識を持たない作業者が RSSI を機械学習するエリア検知技術の導入を可能とする、新しいエリア検知技術の導入支援システムを開発した。本稿 2 章では従来のエリア検知技術を導入する際の課題として、電波伝搬と機械学習の専門家が必要であることを述べる。3 章では電波伝搬と機械学習の専門家が不在であってもエリア検知技術の導入を可能にするエリア検知技術導入支援システムを提案する。そして 4 章で提案システムの有効性を評価する。

2. エリア検知技術を導入する際の課題

2.1 従来のエリア検知技術導入支援システム

Ekahau 社は、機械学習を使用するエリア検知技術である Ekahau RealTime Location System (Ekahau RTLS) [15] と、その導入支援システムである Ekahau Site Survey [16] を提供している。Ekahau Site Survey は、Ekahau RTLS の導入に際し、そのエリア検知成功率を保証する。Ekahau RTLS は、標準的な AP による既設の無線 LAN ネットワークを流用して構築することができるため、Ekahau RTLS を導入する際に新規の設備投資が不要である。Ekahau RTLS のエリア検知エンジンでは、被検知物である端末が受信した無線 LAN 電波の RSSI データを数学的な手法で処理することで端末が存在するエリアを平均検知精度 0.5~3m で算出する。なお、Ekahau 社は、フォーチュン 500 [17] にランクする多くの大企業をはじめ、製造業、小売業、医療、教育、重工業、政府機関、軍など広範囲な業種の顧客を持つ。特に、医療業界でのシェアが高く、世界で 300 カ所の病院が Ekahau RTLS を採用している [18].

Ekahau Site Survey は、無線 LAN 電波の RSSI を可視化することで Ekahau RTLS の導入を支援する。Ekahau Site Survey では、はじめに図 2 に示すように調査用の端末が受信した無線 LAN 電波の RSSI の強弱を色で表現し、それを地図上に重畳表示する。そして電波伝搬の専門家が




図 2 可視化された RSSI の例

Fig. 2 Example of visualized RSSI.

Ekahau RTLS によって可視化された RSSI データを分析してエリア検知成功率を推定する。すなわち、Ekahau RTLS を導入する際には、電波伝搬の専門家による RSSI データの分析が必要だった。

2.2 機械学習を使用するエリア検知技術

機械学習を使用するエリア検知技術では、使用するすべての AP の BSSID (Basic Service Set Identification), それらの AP が送信した電波の RSSI, および、それらの電波を事前に測定したエリア名から構成されるデータを学習データとして取得する。そして、ユーザ端末で取得された観測データ (AP の BSSID と RSSI) がどのエリアで取得された学習データと類似しているかを判定することでユーザ端末が存在するエリアを検知する。図 3 に、最近傍法、パターン認識法、ヒストグラム法のそれぞれの機械学習法によりエリアを検知する原理を示す。図 3 に示した図は、いずれも簡単のために 2 基の AP が送信した電波の RSSI を軸とした 2 次元ベクトル空間に、各エリアで測定された学習データの RSSI をプロットしたものである。実際に使用する AP の数は 2 基以上で、RSSI のベクトル空間は 3 次元以上となる。

図 3 左に示した最近傍法は、観測データ S とのユークリッド距離が最小となる学習データ S_1 を検索し、 S_1 を学習したエリアにユーザ端末が存在すると判定する [14]。図 3 中央のパターン認識法は、各エリアで測定された RSSI データ群の境界線を算出し、境界線で区切られたエリアに観測された RSSI データが存在するかを推定することでユーザ端末が存在するエリアを判定する [19]。図 3 右のヒストグラム法は、各エリアで測定された学習データの度数分布を確率分布に変換し、観測データが各エリアの学習データ群に属する尤度を算出して、最大尤度を持つ学習データ群を測定したエリアにユーザ端末が存在すると判定する [20]。

以上示したように機械学習法には様々な実現手法があるが、各手法には一長一短がある。そのため顧客の要求性能を満たすためには技術導入環境に最適な機械学習法を選定することが必要である。このことは、エリア検知技術を導

入する作業者は、各機械学習法の特徴を十分に把握し、技術導入環境に最適な機械学習法を選定する必要があることを意味する。

以上説明したように、従来は機械学習を使用するエリア検知技術を導入する際には電波伝搬と機械学習の専門家が必要だった。しかし、専門家を確保するためには高い人件費が必要になることから、エリア検知技術は特定の市場でしか導入ができず、コンシューマ市場での普及が困難だった。

3. エリア検知技術導入支援システムの提案

3.1 概要

そこで本稿では、電波伝搬や機械学習の専門家が不在であってもエリア検知技術を導入する前に技術導入環境のエリア検知成功率を推定し、最適な機械学習法の選定を可能にするエリア検知技術導入支援システムを提案する。

3.1.1 技術導入環境のエリア検知成功率の推定

技術を導入する環境におけるエリア検知成功率を事前に推定することにより、顧客にエリア検知技術を導入した際のエリア検知成功率の保証値を示すことができる。エリア検知成功率は電波環境の事前調査結果を使用して論理的に推定することが可能だが、電波環境の事前調査結果からエリア検知成功率を推定するには電波伝搬の専門知識が必要である。機械学習エンジンを使ってエリア検知成功率を実測し、その結果を保証値として提示することも可能だが、エリア検知成功率の実測値の信頼性を担保するためには統計的に十分な量のデータが必要になるため現実的ではない。

そこで提案方式では、エリア間の RSSI データの相互相関を可視化することでエリア検知成功率を推定する。エリア検知成功率がエリア間の RSSI データの相互相関に依存すると考えられるからである。機械学習によるエリア検知成功率は RSSI 学習データの質の影響を受ける。特に各エリアで取得した RSSI 学習データのそれぞれが固有の特徴を持つ場合は、各エリアの RSSI データの相互相関が低くなるため、高いエリア検知成功率が期待できる。そのため、各エリア間の RSSI データの相互相関を可視化することで、電波伝搬の専門知識を持たない作業者が論理的にエリア検知成功率を事前に推定することが可能になる。

また、実測したエリア検知成功率が論理的に推定したエリア検知成功率と同様の傾向を持つ場合に、実測したエリア検知成功率のデータ量が十分だと判断できると考えられる。そこで提案方式では、各エリアでエリア検知成功率を実測し、前述した RSSI データの相互相関値を使用したエリア検知成功率の推定結果と同様の傾向であることを確認する。そうすることで、容易にエリア検知成功率の推定が可能になる。

3.1.2 技術導入環境に最適な機械学習法の選定

技術導入環境に最適な機械学習法を選定することは顧客




図 3 機械学習法を使用してエリアを検知する原理

Fig. 3 Principle of area distinction by machine learning.

が要求するエリア検知成功率を満足するうえで重要である。機械学習法の、最近傍法、ヒストグラム法、パターン認識法のそれぞれは、エリア検知成功率と計算処理に固有の特徴がある。そのため各方式の特徴と技術の導入環境の特徴とを照合することで技術の導入環境に最適な機械学習法を選定できる。

最近傍法の計算量はエリア数の多少に影響されないため、計算量が少ない方式と考えられる。しかし最近傍法は少ない学習データを利用する単純な計算アルゴリズムを採用していることからエリア検知成功率は低い。そのため最近傍法は各エリアで取得した学習データの集合間のユークリッド距離が極端に離れている（たとえば、各エリアで固有のAPが検知できる）ような、正確なエリア検知が容易な環境に適した方式と考えられる。

パターン認識法は複雑な計算が必要なため、計算量が多い方式と考えられる。なかでもSVM (Support Vector Machine) は、その計算量がエリア数に応じて指数的に増大するが、高いエリア検知成功率が期待できる方式である。したがって、この手法は高性能なハードウェアを利用でき、各エリアの学習データの集合間のユークリッド距離が短い、正確なエリア検知が困難な環境に適した方式と考えられる。

ヒストグラム法の計算量はエリア数に応じて線型的に増加するため、その計算量は最近傍法より多く、パターン認識方法より少ないと考えられる。また、そのアルゴリズムは最近傍法より複雑だがパターン認識法ほど複雑ではないため、エリア検知成功率は最近傍法より高く、パターン認識法より低い。したがって、ヒストグラム法は正確なエリア検知が比較的容易な環境に適した方式と考えられる。

図4に各機械学習法の特徴を示す。図4に示すように、ヒストグラム法はエリア検知が比較的容易な環境に適している。パターン認識法はエリア検知が困難な環境で、デバイスのハードウェア性能が高い場合に適している。最近傍法はエリア検知が極端に容易な環境でデバイスのハードウェア性能が低い場合にのみ適している。この各機械学習

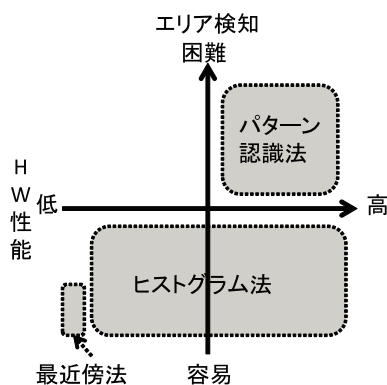


図4 機械学習法の特徴

Fig. 4 Feature map of machine learning methods.

法の特徴チャートを使用することで、機械学習の専門家でもなくても技術の導入環境に適した機械学習法を選定できるようになる。

3.2 エリア検知技術導入支援システム

本節では、筆者らが提案するエリア検知技術の導入支援システムの動作原理を示す。提案システムの作業フローを図5に示す。図5に示すように5つの作業フローを順次実行することで専門知識を持たない作業者でもエリア検知技術を導入できる。導入作業では、はじめに顧客からのヒアリングに基づき検知エリアと使用するAPを仮決定する。手順(i)の環境情報入力では、仮決定したエリア名とAPのBSSIDをシステムに入力する。手順(ii)のRSSIデータ取得では、各エリアのRSSIデータを取得する。手順(iii)のRSSIデータの可視化では、取得したRSSIデータを可視化し、エリア検知成功率を論理的に推定する。手順(iv)の機械学習法の選定では、手順(iii)で得られたエリア検知成功率に基づき、導入環境に適した機械学習法を選定する。この際に適した機械学習法が存在せず選定できない場合は、仮決定した検知エリアと使用するAPによって顧客が満足する要求性能を実現することが困難と判断し、顧客に仮決定したエリアまたは使用するAPの変更を提案する。提案内容に顧客が合意した場合、再度手順(i)から手順(iv)まで順次作業を実施する。そして手順(iv)で適した機械学習法が存在した場合、手順(v)の誤検知率の算出を実施する。手順(v)では手順(iv)で選定した機械学習法を使用してエリア誤検知率を算出し、手順(iii)の推定結果と同様の傾向であることを確認する。この際、同様の傾向が確認できなかった場合は、推定結果が誤りと判断し、手順(iv)、または手順(ii)を再度実施し導入作業を完了する。以下に手順(i)から(v)の詳細を記述する。

(i) 環境情報入力

本手順では、既存の環境によるエリア検知成功率を推定

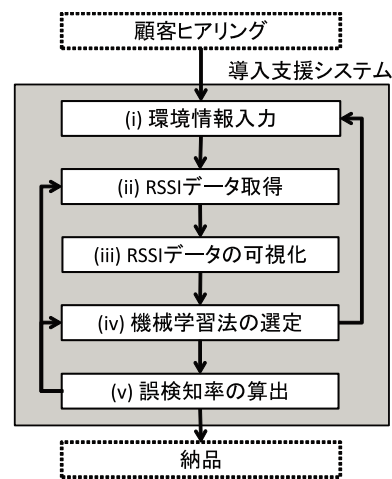


図5 提案システムの作業フロー

Fig. 5 Work flow of the proposed system.

するために既設の AP 情報 (BSSID) とエリア情報 (エリア名と面積) をシステムに入力する。

(ii) RSSI データ取得

本手順では、エリア検知成功率を推定するために必要な RSSI データ (BSSID, RSSI) を取得する。測定用端末を保持した作業者が、各エリア内を後述する規定時間以上、万遍なく歩行して RSSI データを取得する。RSSI データは取得したエリア名と関連付けて保存する。規定時間は手順 (i) で登録したエリアの面積から式 (1) を使用してあらかじめ算出しておく。

$$T = 6.18 \times S \times t \times \div n \tag{1}$$

式 (1) で、T は規定時間 (単位 s), S はエリア面積 (単位 m²), t はデータ取得周期 (単位 s), n は測定用端末の台数 (単位 台) である。定数は、作業者がエリア内のあらゆる位置で十分な量の RSSI データを取得するために予備実験により回帰的に求めた。

(iii) RSSI データの可視化

本手順では、手順 (i) で仮決定したエリア名と手順 (ii) で取得した RSSI データを使用して、各エリア間の RSSI データの相互相関を算出して可視表示する。自エリアの RSSI ベクトル (x_1, x_2, \dots, x_n) と、他エリアの RSSI ベクトル (y_1, y_2, \dots, y_n) の間の相互相関 R を、式 (2) を使用して算出する。

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \tag{2}$$

ここで $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ で、 x_i と y_i はそれぞれ RSSI データを n 基の既設 AP の RSSI を要素とした n 次元の RSSI ベクトルに変換して求める。

全エリアの RSSI ベクトルの R を総当たりで算出し、R の度数分布を作成する。そして作成された度数分布を、その形状に応じて図 6 に示す 5 種類に分類する。そしてその分類結果に応じて導入環境における RSSI データの類似度を定義する。類似度 1 は R が 0 付近に集中している場合に分類する。類似度 2 は R が 0 付近と 1 付近の両方に集中し、かつ 0 付近の度数が 1 付近の度数と比較して大きい場合に分類する。類似度 3 は R が 0 付近と 1 付近の両方に集中し、かつそれらの度数が同程度の場合に分類する。類似度 4 は R が 0 付近と 1 付近の両方に集中し、かつ 1 付近の度数が 0 付近の度数と比較して大きい場合に分類する。類似度 5 は R が 1 付近に集中している場合に分類する。




図 6 相互相関 R の度数分布と RSSI データの類似度

Fig. 6 Histogram of correlation R and its similarity indexes.

上述したように定義した類似度から導入環境のエリア検知成功率を推定する。類似度が 1 であれば RSSI データの相互相関が低いことからエリア検知成功率が高くなり、類似度が 5 であれば類似度 1 の場合とは逆にエリア検知成功率が低いと推定する。これは相互相関の平均値が 0.2 以下であれば 2 つのデータ間の相関が小さく、0.7 以上であれば相関が高いとする基準 [21] による。この基準によれば相互相関の平均が 0.2 以下の場合には類似度 1 と決定でき、0.7 以上の場合には類似度 5 と決定できる。そのため、エリア検知成功率は類似度 1 のときに高く、5 のときに低いと判断する。すべての組合せで類似度を判定することで、導入環境におけるエリア検知成功率を論理的に推定できる。

(iv) 機械学習法の選定

本手順では、利用可能なハードウェアの性能と RSSI データの類似度から導入環境に最適な機械学習法を選定する。利用可能なハードウェアの性能は顧客からヒアリングして取得したハードウェアのデータシートから得る。RSSI データの類似度は手順 (iii) で得る。

図 7 に機械学習法の選定法を示す。図 7 に示すように各エリアの RSSI データが類似しており、かつ利用可能なハードウェアの性能が高い場合はパターン認識法を選択する。RSSI データが類似していない場合はヒストグラム法を選択する。最近傍法は図 4 に示したように限定された状況でのみ有効なことから、本手順では選定候補から除外する。RSSI データが類似しており、かつ利用可能なハードウェアの性能が低い場合に適した機械学習法は存在しないことから、そのような条件の場合は使用するハードウェアを高性能なものに変更してパターン認識法を選定するか、RSSI データが相違するようにエリアを再定義してヒストグラム法を選定する。ここで、RSSI データは、手順 (iii) で得られた類似度が 1 であれば相違、5 であれば類似と分類する。ハードウェアの性能は、機械学習法が動作するために必要なメモリが 16 MB 以下であれば「低」、16 MB より大きければ「高」と分類する。これは Android アプリケーションが使用できるヒープサイズが 16 MB まで [22] とい

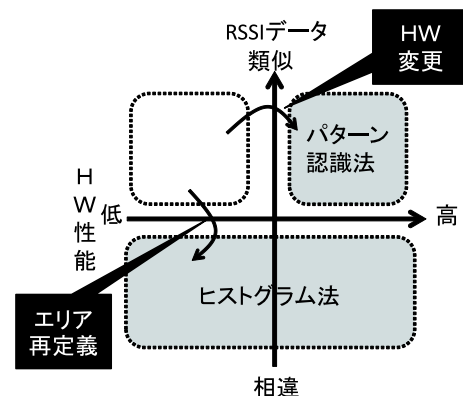


図 7 機械学習法の選定法

Fig. 7 Selection chart of suitable machine learning method.

う基準による。

(v) 誤検知率の算出

本手順では手順 (ii) で取得した RSSI データを使用して得たエリア誤検知率と、手順 (iii) で得た RSSI データの類似度の傾向が同様であることを確認することでエリア検知成功率を推定する。はじめに手順 (ii) で取得した RSSI データをエリアごとに学習データと観測データに分割する。そして、各エリアで学習データとして分割されたデータを統合して学習モデルを作成する。そのようにして作成された学習モデルとエリアごとの観測データを使用してエリアを検知し、他のエリアと間違えた確率と、他のエリアから間違えられた確率の平均値をエリア誤検知率として算出する。エリア誤検知率が低い場合、そのエリアでは検知結果を間違えにくいと考えられるため、エリア検知成功率が高いと推定する。ただし観測データの量が十分ではない可能性があるため、この結果だけでは推定結果の妥当性を判断できない。そこで、エリア誤検知率が高いエリアは類似度が高く、エリア誤検知率が低いエリアは類似度が低い傾向があることを確認することでエリア誤検知率を使用した推定結果が妥当であると判断する。このとき推定結果の傾向が異なっていた場合、機械学習法が正しく選定されていることを確認し、正しく選択されていなかった場合は正しい機械学習法を使用して再度エリア誤検知率を算出する。正しく選択されていた場合は RSSI データに不具合があると判断し、再度手順 (ii) に従い RSSI データを取得する。

4. 評価

4.1 基礎評価

提案方式の有効性を確認するために、エリア検知技術導入支援システムを実装し、図 5 に示した作業フローの各手順の有効性を個別に評価した。本評価で使用した環境を図 8 に示す。2つのフロアに設置されている 20 基の AP と 16 個のエリアを定義した。2つのフロアは階段でつながっている。RSSI データは、24,000 サンプル取得し、そのうちの約 20,000 サンプルを学習データ、約 4,000 サンプルを観測データとして使用した。




図 8 評価に使用した環境

Fig. 8 Evaluation environment.

(i) 環境情報入力手順の評価

AP 情報 (BSSID) とエリア情報 (エリア名と面積) を導入支援システムに入力する機能を評価する。評価実験では AP 情報とエリア情報を環境情報入力ツールによりシステムに入力し、導入支援システムがすべてのエリアの RSSI データの類似度とエリア誤検知率を正しく算出することを確認した。得られた各エリアの RSSI データの類似度を表 1 上に、エリア誤検知率を表 1 下にそれぞれ示す。同一エリアの類似度およびエリア誤検知率はエリア検知成功率の推定に使用しないため省略する。表 1 よりすべてのエリアの類似度とエリア誤検知率が算出されたことが分かった。この結果から本手順の有効性が確認できた。

(ii) RSSI データ測定手順の評価

エリア検知成功率を推定するうえで十分な量の RSSI データを取得する規定時間 T の算出機能を評価する。

規定時間 T の算出機能を評価するために、測定時間に対する RSSI データの度数分布形状の変化量を調査し、規定時間 T での度数分布形状の変化量の傾向を評価する。度数分布形状の変化量は、直前に作成した RSSI データの相対度数分布と最新の相対度数分布の差を積分して算出した。図 9 に測定時間と度数分布形状の変化量の関係を示す。測定時間が長くなると度数分布形状の変化量は小さくなり取

表 1 RSSI データの類似度とエリア誤検知率

Table 1 Similarity indexes (top) and area distinction error rates (bottom).

		RSSIデータの類似度															
		エリア名															
		A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
エリア名	A	-	1	2	2	1	1	1	1	1	1	2	1	1	1	1	1
	B	1	-	1	2	1	1	2	2	1	1	1	1	1	1	1	1
	C	2	1	-	1	1	1	1	1	1	1	4	1	1	1	1	1
	D	2	2	1	-	1	1	1	2	1	1	1	1	1	1	1	1
	E	1	1	1	1	-	1	1	1	1	2	1	1	1	1	1	1
	F	1	1	1	1	1	-	1	1	1	1	1	1	1	1	1	1
	G	1	2	1	1	1	1	-	2	1	1	1	1	1	1	1	1
	H	1	2	1	2	1	1	2	-	1	1	1	1	1	1	1	1
	I	1	1	1	1	1	1	1	1	-	3	1	1	1	1	1	1
	J	1	1	1	1	2	1	1	1	3	-	1	1	1	1	1	1
	K	2	1	4	1	1	1	1	1	1	-	1	1	1	1	1	1
	L	1	1	1	1	1	1	1	1	1	1	-	1	1	1	1	1
	M	1	1	1	1	1	1	1	1	1	1	1	-	1	1	1	1
	N	1	1	1	1	1	1	1	1	1	1	1	1	-	1	1	1
	O	1	1	1	1	1	1	1	1	1	1	1	1	1	-	1	1
	P	1	1	1	1	1	1	1	1	1	1	1	1	1	1	-	1

		エリア誤検知率 [%]																
		エリア名																
		A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	
エリア名	A	-	0	3.6	4.3	0	0	0	0	0	0	0.5	0	0	0	0	0	
	B	0	-	0	0	0	0	2.1	2.5	0	0	0	0	0	0	0	0	0
	C	3.6	0	-	0	0	0	0	0	0	0	0.7	0	0	0	0	0	0
	D	4.3	0	0	-	0	0	0	2.2	0	0	0	0	0	0	0	0	0
	E	0	0	0	0	-	0	0	0	0	0.2	0	0	0	0	0	0	0
	F	0	0	0	0	0	-	0	0	0	0	0	0	0	0	0	0	0
	G	0	2.1	0	0	0	0	-	0.4	0	0	0	0	0	0	0	0	0
	H	0	2.5	0	2.2	0	0	0.4	-	0	0	0	0	0	0	0	0	0
	I	0	0	0	0	0	0	0	0	-	2.8	0	0	0	0	0	0	0
	J	0	0	0	0	0.2	0	0	0	2.8	-	0	0	0	0	0	0	0
	K	0.5	0	0.7	0	0	0	0	0	0	0	-	0	0	0	0	0	0
	L	0	0	0	0	0	0	0	0	0	0	0	-	0	0	0	0	0
	M	0	0	0	0	0	0	0	0	0	0	0	0	-	0	0	0	0
	N	0	0	0	0	0	0	0	0	0	0	0	0	0	-	0	0	0
	O	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-	0	0
	P	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-	0




図 9 規定時間と度数分布形状の変化量の関係

Fig. 9 Measureing time v.s. change of RSSI frequency distribution shape.

束する。これはデータ量が増加するにつれて度数分布の形状が収束するためと考えられる。RSSI の類似度を判定してエリア検知成功率を推定するためには、各エリアの RSSI の特徴が RSSI データの度数分布に反映されている必要がある。測定時間が既定時間 T のときに度数分布形状の変化量が収束していることを確認することで、既定時間 T の算出機能を評価する。

図 9 の例では、おおむね測定時間が 100 (s) 以上の場合に度数分布形状の変化量が収束しており、式 (1) を使用して算出した規定時間 $T=150$ (s) が類似度を判定するうえで十分長かったことが分かる。この結果は、RSSI データ測定手順で算出した規定時間 T が類似度を判定するうえで十分なことを示しており、本手順の有効性が確認できた。

(iii) RSSI データの可視化手順の評価

RSSI データの類似度と実際に測定したエリア検知成功率の相互相関を評価する。RSSI データの類似度と実際に測定したエリア検知成功率の相互相関は -0.8 だった。相互相関が -0.7 以下であるため相関が高い [21] と判断できる。この結果は RSSI データを可視化することでエリア検知成功率を推定可能なことを意味しており、本手順の有効性が確認できた。

(iv) 機械学習法の選定手順の評価

図 7 に示した選定法を評価する。評価実験では図 4 に示す各機械学習法の特徴と図 7 の選定法のそれぞれが妥当なことを確認する。

はじめに機械学習法の特徴を確認する。本評価では最近傍法として Proximity [14]、パターン認識法として SVM [19]、ヒストグラム法としてノンパラメトリック法 [20] をそれぞれ使用して、各機械学習法のエリア検知成功率とハードウェア性能をオフラインで評価する。パターン認識法の処理フローを図 10 左に示す。パターン認識法では、観測データと学習モデルデータを読み込み、SVM を使用してエリア検知結果を算出する。学習モデルデータは事前に学習データを使用して作成してある。全観測データのエリア検知結果が出力されるまで繰り返し観測データを読み込

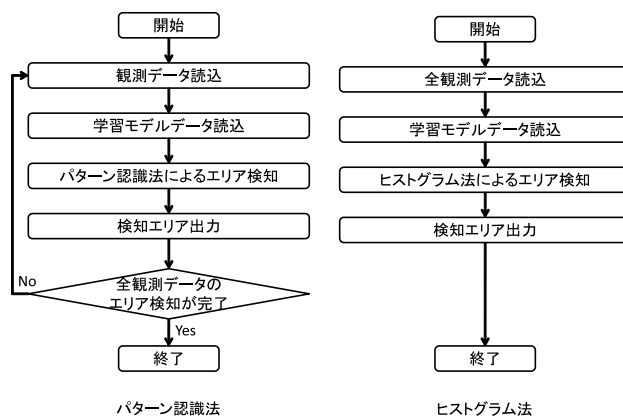


図 10 パターン認識法とヒストグラム法の処理フロー

Fig. 10 Process flow of pattern recognition method (left) and histogram method (right).




図 11 エリア数とエリア検知成功率の関係

Fig. 11 Number of area v.s. area distinction rate.

み、エリア検知結果を出力する。ヒストグラム法の処理フローを図 10 右に示す。ヒストグラム法では、すべての観測データとモデルデータを読み込み、ノンパラメトリック法を使用してエリア検知結果を算出する。モデルデータは事前に学習データを使用して作成してある。

まずエリア検知に成功した確率であるエリア検知成功率と、エリア数、AP 数、RSSI データの類似性のそれぞれの関係性を評価する。

第 1 にエリア数とエリア検知成功率の関係を評価する。エリア数が増加すると RSSI データの特徴が類似しているエリアが増加し評価対象になる可能性が高まることから、エリア検知成功率は減少すると考えられる。図 11 にエリア数とエリア検知成功率の関係を示す。この評価では、すべての AP と学習データを使用し、使用するエリアはランダムに選択した。エリア検知成功率エリア数が 16 の場合、パターン認識法、ヒストグラム法、最近傍法のエリア検知成功率はそれぞれ 0.98, 0.92, 0.79 だった。高いエリア検知成功率は 0.9 以上であること [23] に鑑み、パターン認識法とヒストグラム法はエリア検知成功率が高いと判断できる。また、各機械学習法のエリア検知成功率は、エリア数によらず、パターン認識法、ヒストグラム法、最近傍法の

順番で高いことが分かった。

第2に AP 数とエリア検知成功率の関係を評価する。図 12 に AP 数とエリア検知成功率の関係を示す。この評価では、すべてのエリアですべての学習データを使用し、AP はランダムに選択した。各機械学習法のエリア検知成功率は AP 数によらず、パターン認識法、ヒストグラム法、最近傍法の順番で高いことが分かった。図 11 と図 12 から各機械学習法のエリア検知成功率はエリア数や AP 数によらずパターン認識法、ヒストグラム法、最近傍法の順に高いことが分かった。

第3に RSSI データの類似性とエリア検知成功率の関係を評価する。各エリア間の RSSI データの類似性を各エリアの RSSI データの相互相関と定義し、パターン認識法とヒストグラム法に関して相互相関とエリア検知成功率の関係を評価した。最近傍法のエリア検知成功率は図 11 および図 12 から他の機械学習法と比較して大幅に低いと類推できることから、本評価ではパターン認識法とヒストグラム法のエリア検知成功率に絞って評価する。本評価はすべての AP と学習データを使用して実施した。

図 13 に各エリアの RSSI データの類似性とエリア検知成功率の関係を示す。各エリアの RSSI データの類似性が低い場合のパターン認識法とヒストグラム法のエリア検知成功率は、それぞれ 0.99, 0.96 であった。一方、類似性が高い場合のパターン認識法とヒストグラム法のエリア検知

成功率は、それぞれ 0.99, 0.85 であった。高いエリア検知成功率は 0.9 以上であること [23] に鑑み、RSSI データの類似性が低い環境ではヒストグラム法とパターン認識法のエリア検知成功率が高いが、RSSI データの類似性が高い環境ではヒストグラム法のエリア検知成功率が低いことが分かった。

次にハードウェア性能を評価する。評価指標はハードウェアの処理時間とメモリ使用量とする。最近傍法は、他の機械学習法と比較して処理時間とメモリ使用量が最も小さいと考えられることから、本評価ではパターン認識法とヒストグラム法のハードウェア性能に絞って評価する。

第1に処理時間を評価する。エリア数が増加するとユーザ端末が存在するエリアの探索回数が増加することから、各機械学習法の処理時間は増加すると考えられる。この評価ではすべての AP と学習データを使用し、エリアはランダムに選択した。処理時間は学習モデルデータを読み込んでからエリア検知結果を出力するまでの時間と定義した。図 14 にエリア数と処理時間の関係を示す。図 14 からエリア数が増加するとパターン認識法の処理時間も増加することが分かる。この理由はパターン認識法では組み合わせ探索アルゴリズムを使用してエリアを検知することから、エリア数の増加に伴い処理時間が指数関数的に増加したためと考えられる。一方でヒストグラム法の処理時間はエリア数が増加してもほとんど増加していない理由は、エリア数が増加しても尤度の計算量が線型的にしか増加しなかったためと考えられる。両方式の実装環境の違いによる影響を排除するため、エリア数の増加量と処理時間の変化量の関係を算出した。パターン認識法の処理時間の変化量は 71.9ms/エリア、ヒストグラム法は 0.2ms/エリアだった。この結果はヒストグラム法の処理時間の変化量がパターン認識法の 1/300 未満であることを意味する。以上の結果から、ヒストグラム法の計算処理量がパターン認識法の計算処理量と比較して大幅に少ないことが分かった。

第2にメモリ使用量を評価する。本評価ではパターン認識法とヒストグラム法の各機械学習法を実行した際のメモ




図 12 AP 数とエリア検知成功率の関係

Fig. 12 Number of AP v.s. area distinction rate.




図 13 RSSI データの類似性とエリア検知成功率の関係

Fig. 13 Similarity of RSSI v.s. area distinction rate.




図 14 エリア数と処理時間の関係

Fig. 14 Number of area v.s. processing time.

り使用量を測定した。測定に際してはすべての AP、学習データ、エリアを使用した。図 15 にメモリ使用量の測定結果を示す。パターン認識法では、約 2 秒周期でメモリ使用量が約 30 MB と約 0 MB の間で変化しているが、これはエリア推定する際に、1 エリア推定する度にメモリがリリースされているためである。したがって、パターン認識法のメモリ使用量は、図 15 のエリア推定中の 30 MB と考えるのが妥当である。一方、ヒストグラム法のメモリ使用量は約 3 MB であった。このことはヒストグラム法のメモリ使用量はパターン認識法の約 1/10 であることを意味する。以上の結果から、ヒストグラム法はパターン認識法と比較して少ないメモリ使用量でエリアを検知できることが分かった。

表 2 にこれまでの評価結果をまとめる。表 2 から、エリア検知成功率はパターン認識法とヒストグラム法が優れており、ハードウェア性能はヒストグラム法が優れていることが分かる。ただし、RSSI データが類似している環境ではヒストグラム法のエリア検知成功率が低下することからパターン認識法のほうが優れている。以上から、表 2 に示した結果は図 4 に示す特徴と同様であることが確認できた。

次に図 7 に示した機械学習法の選定法の妥当性を確認する。表 2 に示したようにパターン認識のエリア検知成功率は高いが、メモリ使用量は 16 MB 以上であり処理時間もヒストグラム法と比較して大幅に長い。そのため、パターン認識法はモバイル端末のようなハードウェアのリソースが限られているデバイスに適していないと考えられる。し




図 15 メモリ使用量の評価結果

Fig. 15 Memory usage of the area distinction methods.

表 2 評価結果のまとめ

Table 2 Summary of evaluations.

機械学習法	エリア検知成功率		ハードウェア性能	
	評価環境	RSSIが類似する環境	処理時間	メモリ使用量
パターン認識法	0.98 (最高)	0.99 (高い)	71.9[ms/area] (長い)	30MB (多い)
ヒストグラム法	0.92 (高い)	0.85 (低い)	0.2[ms/area] (短い)	3MB (少ない)
最近傍法	0.79 (低い)	評価せず (最低)	評価せず (最短)	評価せず (最少)

かし一方で、RSSI データが類似している環境でのエリア検知成功率は高い。すなわちパターン認識法は RSSI データが類似している環境に適しているといえる。以上の結果から、パターン認識法は RSSI データの類似性が高く、かつ高いハードウェアのリソースが利用可能なデバイスに適用する場合に適していることが分かった。

ヒストグラム法のエリア検知成功率はパターン認識法に次いで高い。そしてメモリ使用量も 16 MB 未満であり、処理時間もパターン認識法と比較して大幅に小さい。そのためヒストグラム法はモバイル端末での処理に適しているといえる。一方で、RSSI データの類似性が高い環境ではヒストグラム法のエリア検知成功率はパターン認識法と比較して低い。すなわちヒストグラム法は RSSI データの類似性が高い環境には適さないといえる。以上の結果から、ヒストグラム法は RSSI データの類似性が低い環境に適していることが分かった。このことは図 7 に示した機械学習法の選定法に合致している。以上から、図 7 に示した機械学習法の選定法を使用することで技術の導入環境に最適な機械学習法を選定可能なが分かり、機械学習法の選定手順の有効性が確認できた。

(v) 誤検知率の算出手順の評価

エリア誤検知率が実際のエリア検知成功率と同様の傾向であることを評価する。エリア誤検知率と実際のエリア検知成功率の相関が高ければ、エリア誤検知率を使用するエリア検知成功率の推定方法が妥当なことを示すことができる。本手順を評価するためにエリア誤検知率とエリア検知成功率の相互相関を算出した結果、 -0.78 だった。相関値が -0.7 以下であるため [21]、エリア誤検知率とエリア検知成功率の相関は高く、エリア誤検知率が実際のエリア検知成功率と同様の傾向を示すことが確認された。したがって誤検知率の算出手順の有効性が確認できた。

4.2 検証実験

本節では、提案する導入支援システムによって電波伝搬や機械学習法の専門知識を持たない作業者がエリア検知技術を導入できることを実験により検証する。図 16 に示すシステムを構築し、実際に顧客現場を想定した場所で検証実験を実施した。図 16 に示すように本検証実験で使用したシステムは 7 つのモジュールで構成されている。

図 17 に環境情報入力ツールの画面表示例を示す。このツールの画面では GUI を使用してエリア情報 (エリア名と面積) と AP 情報 (BSSID) を入力する。本ツールを使う際は、はじめに適用環境のレイアウト情報を画像ファイル形式で読み込み、画像のスケール情報を入力する。そして、GUI 上で AP とエリアをマウスで配置する。配置したエリアの大きさはアイコンをマウスで引き延ばすことで変更できる。エリアの面積は画像のスケール情報から自動的に算出される。エリア名はエリアアイコンを、AP の BSSID は

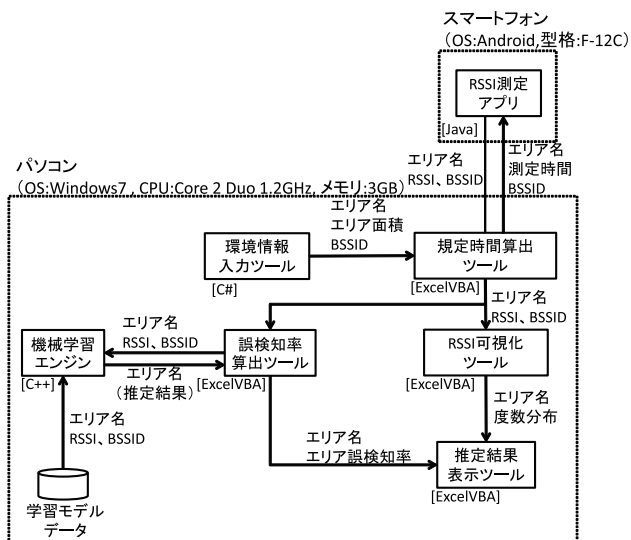


図 16 検証実験で使用したシステム構成

Fig. 16 Configuration of the evaluation system.



図 17 環境情報入力ツールの画面表示例

Fig. 17 An example of output screen of environmental data input tool.



図 18 RSSI 測定アプリの画面表示例

Fig. 18 An example of output screen of RSSI measurement tool.

AP アイコンを、それぞれダブルクリックすると入力可能になる。さらに AP の送信電力や設置高度、周波数、チャネルも AP アイコンをダブルクリックすることで入力や変更が可能になる。

図 18 に RSSI 測定アプリの画面表示例を示す。RSSI 測定アプリはスマートフォン上で動作するアプリケーションであり、タッチパネル操作が可能である。図 18 に示す画面のパラメータ欄にエリア名を入力しスタートボタンを押

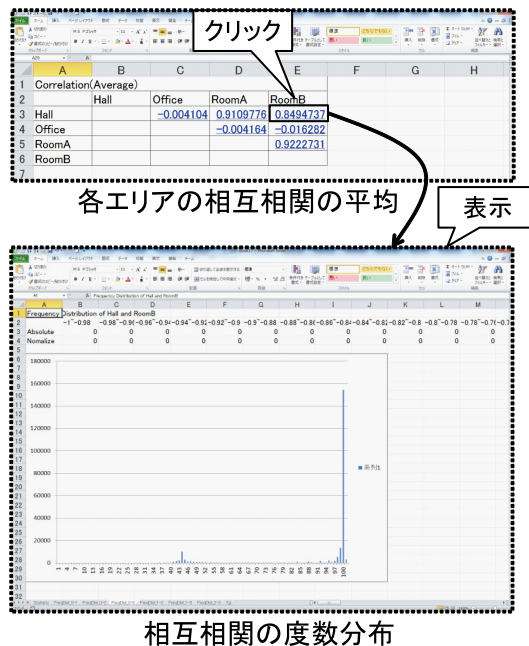


図 19 RSSI 可視化ツールの画面表示例

Fig. 19 An example of output screen of RSSI visualization tool.

すことで、端末で受信可能な無線 LAN 電波の記録を開始する。そして記録されたデータから BSSID と RSSI を抽出してエリアごとに RSSI データファイルとして保存する。

規定時間算出ツールは環境情報入力ツールで算出したエリア面積をもとに、式 (1) を使用して各エリアの RSSI データの規定時間を算出する。そして算出した規定時間と測定すべきエリア名を USB ケーブルを経由して RSSI 測定アプリに通知する。

RSSI 可視化ツールは RSSI 測定アプリが取得した RSSI データから各エリアの相互相関を算出し、エリアごとに相互相関の平均と度数分布グラフをファイル出力し保存する。保存されたファイルには図 19 に示すようにエリアごとの相互相関の平均が表にまとめられており、そこからエリア検知成功率の傾向を知ることができる。表の平均値をクリックすると相互相関の度数分布グラフが表示される。作業者はこのグラフの形状から RSSI データの類似度を分類し、導入環境に適した機械学習法を選定する際の判断材料として利用する。RSSI 可視化ツールは算出した相互相関の度数分布を推定結果表示ツールに通知する。

誤検知率算出ツールは RSSI 測定アプリが取得した RSSI データを一定の比率でランダムに学習データと環境評価用の観測データに分割し、機械学習エンジンへエリア名と共に通知する。機械学習エンジンは受け取ったデータをもとに検知したエリア名を誤検知率算出ツールに通知する。誤検知率算出ツールは受け取ったエリア名からエリア誤検知率を算出して推定結果表示ツールに通知する。

機械学習エンジンは誤検知率算出ツールから受け取った学習データと観測データを使用してエリアを検知する。ま

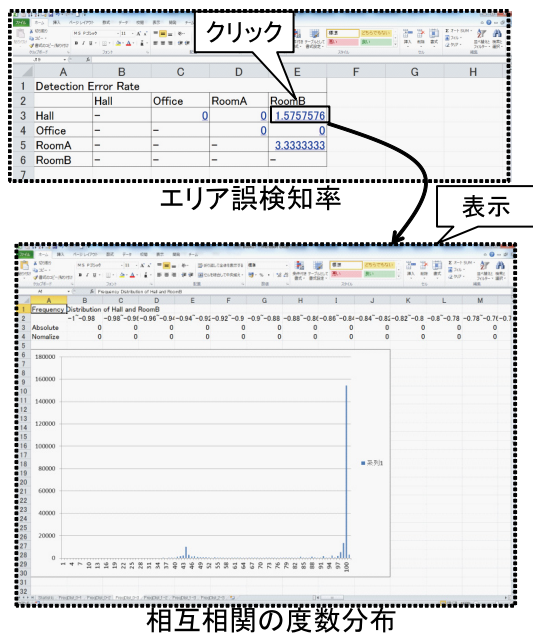


図 20 推定結果表示ツールの画面表示例

Fig. 20 An example of output screen of estimation result tool.




図 21 AP とエリアの配置
Fig. 21 Layout of APs and areas.

ず学習データを使用して学習モデルデータファイルを作成し、学習モデルデータと観測データを用いてエリアを検知する。そしてエリア検知結果を誤検知率算出ツールへ通知する。機械学習法としてパターン認識法の SVM とヒストグラム法のノンパラメトリック法を用意し、RSSI 可視化ツールの出力結果をもとに機械学習法を切り替える。

推定結果表示ツールは RSSI 可視化ツールから受け取った各エリアの相互相関の度数分布と、誤検知率算出ツールから受け取ったエリア誤検知率を結合してエクセル形式のファイルに出力し保存する。図 20 に示すようにエリア誤検知率は 1 つの表にまとめられており、表のエリア誤検知率をクリックすることで相互相関の度数分布グラフが表示される。クリックしたエリア誤検知率と表示された度数分布グラフの形状が同じ傾向であることを確認することで、エリア検知成功率を推定する。

オフィスの環境を想定して導入支援システムの検証実験を行った。図 21 に示すように同一フロアに設置されている 9 基の既設 AP を使用し、4 つのエリア (会議室 A, 会議室 B, 事務所, ホール) を定義した。AP 情報とエリア情報は環境情報入力ツールを使用して入力した。試験者は

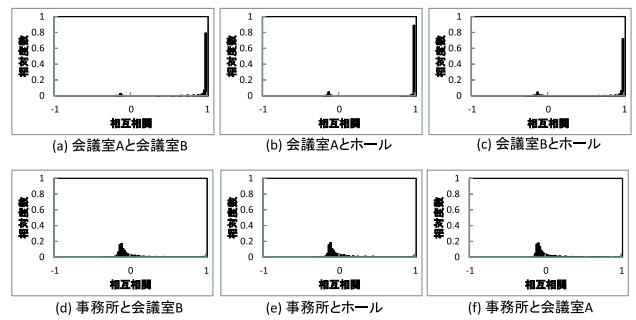


図 22 相互相関 R の度数分布

Fig. 22 Histogram of correlation R.

表 3 各エリアの類似度

Table 3 Similarity indexes of each area.

	会議室A	会議室B	ホール	事務所
会議室A	-	5	5	1
会議室B	-	-	5	1
ホール	-	-	-	1
事務所	-	-	-	-

(類似度)

RSSI 測定アプリをインストールした 2 台のスマートフォンを手に持ち、規定時間算出ツールが算出した規定時間だけ各エリア内を歩行して RSSI データを取得した。RSSI データの取得周期は 0.5 秒で、各エリアにおける規定時間は規定時間算出ツールが算出した結果にマージンを加えて 5 分とした。

図 22 に本検証実験で RSSI 可視化ツールが出力した RSSI データの相互相関 R の度数分布の例を示す。図 22 の (a), (b), (c) は相互相関が 1 の付近 (右端) に集中しており、図 22 の (d), (e), (f) は相互相関が 0 の付近 (中央) に集中していた。図 22 の結果を図 6 で示した分類法に従い分類した結果を表 3 に示す。図 22 の (a), (b), (c) の度数分布特性は類似度 5 に分類され、図 22 の (d), (e), (f) の度数分布特性は、類似度 1 に分類された。事務所エリアと他のすべてのエリアの度数分布特性は類似度 1 に分類されたことから、事務所エリアと他のすべてのエリアの RSSI データは相違している。そのため事務所エリアのエリア検知成功率は他のエリアと比較して高いと推定する。また、会議室 A エリア、会議室 B エリア、ホールエリアの類似度は互いに 5 なことから、上記 3 エリアの RSSI データは類似している。そのため上記 3 エリアのエリア検知成功率は低いと推定する。

表 3 に示した各エリアの類似度を使用して適用環境に適した機械学習法を選定する。表 3 の結果を図 7 に示した機械学習法の選定法に適用すると図 7 の第 1 象限および第 2 象限が選定される。この結果から、高性能ハードウェアが使用可能な場合は第 1 象限のパターン認識法を選定し、高性能なハードウェアを使用不可能な場合は第 2 象限のエリアを再定義の上、ヒストグラム法を選定することが望ましいことが分かる。本検証実験では高性能なハードウェア




図 23 エリア再定義後の相互相関 R の度数分布

Fig. 23 Histogram of correlation R after area redefinition.

を使用不可能な場合を想定しエリアの再定義を行う。

表 3 によれば、会議室 A エリア、会議室 B エリア、ホールエリアの RSSI データは互いに類似しているが、事務所エリアと他のエリアの RSSI データは類似していない。そのため事務所エリア以外の 3 エリアを統合して事務所外エリアと再定義し、事務所エリアと事務所外エリアとの間で再度エリア検知成功率を推定した。エリアを再定義した後の相互相関 R の度数分布を図 23 に示す。図 23 の結果は類似度 1 の度数分布 (RSSI データが類似していない) に分類されるため、エリア検知成功率が高いと推定する。この結果を図 7 に適用し、この環境に最適な機械学習法をヒストグラム法と決定する。さらに、類似度 1 であることから、エリア検知成功率が高いと論理的に推測できる。

次に全 RSSI データの 15% を観測データとして抽出し、この観測データを使用して事務所外エリアと事務所エリアのエリア誤検知率を算出した。その結果、エリア誤検知率は 0% だった。このことは RSSI データ可視化ツールと、誤検知率算出ツールのそれぞれが同様の同じ傾向を示したことを意味する。したがって、事務所と事務所外エリアにヒストグラム法を適用した場合のエリア検知成功率が高いことが実測結果により推測された。

事務所と事務所外エリアにヒストグラム法を適用した場合のエリア検知成功率は 0.985 だった。高精度なエリア検知成功率を 0.9 以上とする [23] ことに鑑み、提案システムを使用したエリア検知成功率の推定結果は妥当と考えられる。

また同じ環境で電波伝搬と機械学習の専門家 1 名がエリア検知成功率を推定した結果、今回提案した導入支援システムを使用した推定結果と一致することを確認した。以上の結果から、電波伝搬や機械学習の専門知識を持たない作業者が今回提案した導入支援システムを使用することでエリア検知技術を導入できることが確認された。

5. おわりに

本稿では、機械学習法を使用したエリア検知技術を市場に普及させるために、電波伝搬や機械学習の専門知識を持たない作業者がエリア検知技術を導入できる導入支援シ

テムを提案した。提案システムは 5 つの導入工程を順次実行することで、適用環境におけるエリア検知成功率を推定し、適用環境に適した機械学習法を選択することができる。すでに本システムはビジネスシーンでの活用実績があり、専門知識を持たない作業者がエリア検知技術の導入を実現している。

今後は提案技術のさらなる市場普及を目的として、機器の故障やレイアウト変更に起因する RSSI データの変化を電波伝搬の知識を持たない作業者が自律的に判断できる保守システムを検討する。また、無線 LAN を用いたエリア検知技術は屋外でも使用可能と考えられることから、屋内外シームレスエリア検知技術についても検討する。

参考文献

- [1] 総務省：情報通信白書平成 24 年版，総務省（オンライン），入手先 (<http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h24/index.html>)（参照 2015-07-16）。
- [2] 無線 LAN ビジネス研究会：無線 LAN ビジネス研究会報告書，総務省（オンライン），入手先 (<http://www.soumu.go.jp/main.content/000168906.pdf>)（参照 2015-07-16）。
- [3] Malm, A.: *Mobile Location-Based Services—8th Edition*, Berg Insight (2014).
- [4] 株式会社リクルートライフスタイル：ジオ系アプリ「RecoCheck」，株式会社リクルートライフスタイル（オンライン），入手先 (http://www.recruit-lifestyle.co.jp/news/2014/01/06/chikyuu_recocheck_20140107_1.pdf)（参照 2015-07-16）。
- [5] 東京国立博物館：アプリ「トーハクナビ」について，東京国立博物館（オンライン），入手先 (http://www.tnm.jp/modules/r_free_page/index.php?id=1467)（参照 2015-07-16）。
- [6] Wilson, M.W.: Location-based services, conspicuous mobility, and the location-aware future, *Geoforum*, Vol.43, No.6, pp.1266–1275 (2012).
- [7] Salt, S.: *Social Location Marketing: Outshining Your Competitors on Foursquare, Gowalla, Yelp & Other Location Sharing Sites*, Que Publishing (2011).
- [8] Reclus, F. and Drouard, K.: Geofencing for fleet & freight management, *9th International Conference on Intelligent Transport Systems Telecommunications (ITST)*, pp.353–356 (2009).
- [9] 財団法人ニューメディア開発協会：屋内測位普及発展に関する調査研究報告書，財団法人ニューメディア開発協会（オンライン），入手先 (<http://www.nmda.or.jp/keirin/h20houkoku/houkoku/h20okunai.pdf>)（参照 2015-07-16）。
- [10] HighTower, J. and Borriello, G.: Location System for Ubiquitous Computing, *IEEE Computer Society*, Vol.34, No.8, pp.57–66 (2001).
- [11] Dempster, A.: QZSS's Indoor Messaging System, GNSS Friend of Foe, *Inside GNSS* (2009).
- [12] Bahl, P. and Padmanabhan, V.: RADAR; An In0Building RF-Based User Location and Tracking System, *Proc. IEEE Infocom 2000*, pp.775–784 (2000).
- [13] Honkavirta, V. et al.: A comparative survey of WLAN location fingerprinting methods, *Proc. 6th Workshop on Positioning, Navigation and Communication 2009 (WPNC'09)*, pp.243–251 (2009).
- [14] Roos, T. et al.: A Probabilistic Approach to WLAN User Location Estimation, *International Journal of Wireless*

- Information Networks*, Vol.9, No.3, pp.155-167 (2002).
- [15] Ekahau: Real Time Location System (RTLS) RFID-over-WiFi Technology, Ekahau (online), available from <http://www.ekahau.com/real-time-location-system/technology> (accessed 2015-07-16).
 - [16] Ekahau: Wi-Fi site surveys, planning, WLAN troubleshooting software, Ekahau (online), available from <http://www.ekahau.com/wifidesign/ekahau-site-survey> (accessed 2015-07-16).
 - [17] Times: Fortune 500, Times (online), available from <http://fortune.com/fortune500/> (accessed 2015-07-16).
 - [18] 和田 恭: 米国における WiFi 位置情報ソリューションの動向, JETRO/IPA (オンライン), 入手先 <https://www.ipa.go.jp/files/000029440.pdf> (参照 2015-07-16).
 - [19] Hotta, S. et al.: A Robust Room-level Localization Method Based on Transition Probability for Indoor Environments, *Proc. 2012 International Conference on Indoor Positioning and Indoor Navigation 13-15th*, pp.1-8 (2012).
 - [20] Bin, C. et al.: Indoor Localization Based on Naive Bayes Method Using Wi-Fi RSSI, *The 14th SICE SYSTEM INTEGRATION DIVISION ANNUAL CONFERENCE* (2013).
 - [21] 有馬昌宏: 第 13 章 相関, 兵庫県立大学 (オンライン), 入手先 <http://www.ai.u-hyogo.ac.jp/~arima/lectures/JT-13.pdf> (参照 2015-07-16).
 - [22] 石原正樹ほか: 現場で使える [逆引き+実践] Android プログラミングテクニック, 1st edition, chapter 3, p.263, 技術評論社 (2012).
 - [23] 坂村 健: 高精度位置認識技術の研究開発, 総務省 (オンライン), 入手先 http://www.soumu.go.jp/main_content/000245415.pdf (参照 2015-07-16).



羽田 芳朗 (正会員)

1999 年電気通信大学大学院情報システム学研究科博士後期課程修了。同年同大学院助手。2006 年 (株) 富士通研究所入社。サービスロボットの研究, 屋内測位等の研究開発に従事。情報処理学会, 日本ロボット学会, 計測自動制御学会, 日本建築学会等の会員。博士 (工学)。




森 信一郎 (正会員)

1987 年関西大学工学部卒業。同年富士通 (株) 入社。2003 年 (株) 富士通研究所に異動。2011 年静岡大学大学院博士後期課程修了。半導体製造ロボットの開発, GPS 携帯端末関連の開発, 次世代携帯電話の開発, 仮想世界/オーギュメントドリアリティに関する研究を経て, 高精度測位技術の研究に従事。博士 (情報学)。



肥田 一生 (正会員)

2004 年静岡大学情報学部情報科学科卒業。2006 年同大学大学院修士課程修了。同年 (株) 富士通研究所入社。測位システムおよび実世界の設定運用環境に関する研究に従事。



陳 彬

2004 年電気通信大学博士後期課程修了。同年 (株) 富士通研究所入社。移動ロボットにおける実世界センシング・ナビゲーションシステムの研究開発に従事。日本ロボット学会会員。博士 (工学)。