

複数受信電波強度に基づく楕円周特徴量を用いた 機種依存性の低い高精度屋内測位

須ヶ崎 聖人^{1,a)} 下坂 正倫^{1,b)}

概要: 近年、モバイルデバイスの測位が、様々なユビキタス・コンピューティング、アプリケーションの基盤として重要となっている。屋外の測位では GPS が主流であるが屋内では精度が悪いため、RSSI を用いた屋内測位の研究が多く進められている。屋内測位の手法として、フィンガープリントを使用して屋内の位置を同定する手法が一般的である。しかし、多様なスマート端末が普及した現在、アンテナ特性が機種ごとに一定と仮定している既存の測位モデルでは精度が下がってしまう。そのため、屋内測位に対して機種依存性の低いモデルが求められ始めている。そこで本研究では、端末依存性の解消を目的として、楕円周特徴量という、複数のアクセスポイント (AP) から得る電波強度の差を用いることで、端末位置の候補を複数の楕円周上に絞り込むことができる特徴量表現を提案する。この特徴量は、2つの電波強度値を用いることで、電波方程式に現れる端末固有の物理特性値を消去する定式化を行い、既存の枠組みで問題となる、端末ごとのキャリブレーションが必要である問題を解決するものである。そしてこの特徴量は、2つの AP 間の楕円周上に位置を絞り込むことができる、少数の AP から絞り込みが可能なものであり、実環境データでの評価で既存の機種依存性の低い特徴量に比べて性能が高いことがわかった。また、2種の端末を用いた実験により、提案手法が単一の信号強度により作成される特徴量を用いた手法と比べ、端末依存性が低いことを確認した。

キーワード: Wi-Fi localization, Radio propagation, Machine learning, Feature design

1. 序論

1.1 本研究の背景

近年、モバイルデバイスの測位が、様々なユビキタス・コンピューティング、アプリケーションの基盤となる技術として重要となっている。これは、位置情報がユーザーの情報の中でも重要性の高いものであることに起因している。現在、屋外の測位としては GPS による測位が主流となっており、アプリケーションなどに頻繁に使用されている [1]。しかし、GPS のみでは高精度な屋内測位は不可能であり、そのため Wi-Fi や Bluetooth などの電波の受信強度を用いた測位に関して研究が進められている。

屋内測位の手法として、フィンガープリントを使用して屋内の位置を同定する手法が一般的である [2] [3] [4] [5]。しかしながら携帯端末の機種毎の受信特性 (アンテナ・チップ) の違いから、電波強度の分布は機種ごとに異なる点に注意すべきである。一方、フィンガープリントに基づく屋

内測位法の従来研究の多くでは、すべての端末で取得される電波強度が同一の分布に従うと仮定している [6]。これは、キャリブレーションで用いる端末と、実際にユーザーが使用する端末の電波受信特性が等しいという仮定と等価である。多様な端末が市場に出回っている現在において、すべての端末で電波特性が等価であるという上記の仮定は成り立たないため、屋内測位の高精度化の妨げとなっている。

機種毎の電波強度分布を推定するため、市場に出回っている端末それぞれに対してキャリブレーションデータを取得しそれぞれのモデルを作成するアプローチが考えられるが、多大な時間と人的コストを必要とする。このような多大なキャリブレーションコストは屋内測位の普及の妨げになる。転移学習により少数のラベル付きデータを活用した新しい電波環境への適応手法を新機種に適用 [7] することも考えられるが、キャリブレーションに必要なデータ量が減少することが期待されるものの、キャリブレーションが不可欠であることには変わりがなく、端末の機種依存性の根本的解消とは言い難い。そのため、転移が不要なモデルが必要となる。転移不要なモデルとして、複数の AP より

¹ 東京工業大学 情報理工学院 情報工学系
152-8552 東京都目黒区大岡山 2-12-1

^{a)} sugasaki@miubiq.cs.titech.ac.jp

^{b)} simosaka@miubiq.cs.titech.ac.jp

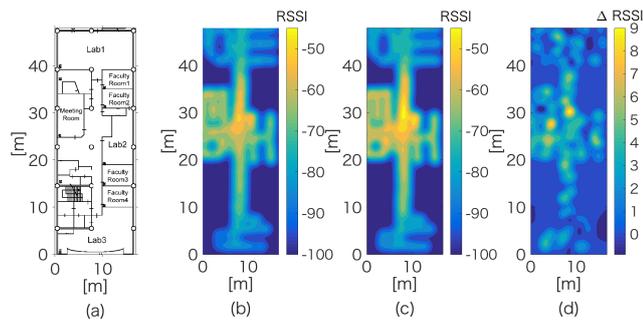


図1 1APに対する端末ごとのRSSI分布 (a)測位対象地図 (b)Nexus5に対するRSSI分布 (c)Nexus9に対するRSSI分布 (d)Nexus5とNexus9の取得信号の差分

得られるRSSIの大小関係から、APの距離の大小関係を空間の絞り込みに用いて測位を行うモデル [8] が提案されているが、大小関係に基づき端末位置の絞り込みをするため、少数のAPのみしか存在しない環境においては絞り込みの効果が小さく誤差が大きくなってしまふ。そこで、我々は端末依存性の観点における既存研究の問題点を指摘し、転移学習が不要となるような端末のアンテナ特性に対する依存性の低い特徴量表現による屋内測位法を提案する。

以上をまとめると、本研究の貢献は以下の2点にまとめられる。1つ目に電波の減衰伝搬の公式より導出された端末の機種依存性を棄却した表現による、測位を行う端末依存性の低い頑健なアルゴリズムを構築したことである。2つ目に絞り込み能力の高い特性を持つ、同一の特徴量を表現する空間を二次元平面上に写像することで楕円周上の点群を表す点群となる表現を使用することと、その表現に対しノイズに強いような非線形変換を行うことで作成される特徴量により、同一機種内での実験で、性能向上に貢献していることである。この特徴量表現については3章で詳述する。

関連研究

転移学習などによる取得時と測位時の電波強度分布の違いに注目する屋内測位の枠組みは、古くから研究されている [9]。これは、環境変化や時間変化により、RSSIの電波強度分布が変化することが知られているためである。現在、その状況に加え、端末が多機種登場したことにより、端末の機種依存性を無視することができなくなったため、RSSI取得環境の時間変化そのものよりも、端末間の転移を考慮することが重要である [10] [11] [12]。図1は端末ごとの電波強度分布をガウス過程 [13] を使用してモデリングし可視化したものである。これより、端末が異なる際、RSSIが最大10dB程度の差が生じることがわかる。このRSSIの端末間の差が測位時に大きな誤差の要因となる。

端末間の転移に注目した研究に、端末ごとのデータを使用して、端末ごとに固有のモデルを作成する枠組み [14] や多タスク学習を行う枠組み [15] があるが、端末の機種が多かつ刷新され続ける現在において、端末それぞれのデータを取得することが現実的ではない。そのため、転移学習

に基づく手法の適応が問題の性質上困難である。そのような端末ごとのデータ取得の難しさから、新たなデータを必要とせずあらゆる端末で使用することが可能な、機種依存性の解消を図ったモデルが必要となる。そこで、特徴量設計で端末間の機種依存性を棄却するような新しい枠組みが近年になって提案されている。

我々のモデルに最も近い手法として、Kjaergaardら [16] のモデルや、Zhengら [8] のモデルなどが存在する。Kjaergaardら [16] は端末で取得された2つのAPの比を特徴量として採用し、この対の信号強度の比をとることにより端末依存性の解決を目指している。しかし機種依存性に大きく影響する信号受信強度の最大値を特徴量作成に使用しており、機種依存性を完全にキャンセルできているとは言い難い。その理由を2.4.1で詳述する。Zhengら [8] は、取得された信号強度から複数のAP対に対してどれに近いのかを表現する2値の特徴量を採用し、機種依存性が小さくなるように学習している。この研究では差分表現での特徴量を使用しているが、どの程度近いのかという指標が入っておらず、少ないAPの場合、位置を断定することができない。そのため、位置の特定に2つだけでなく3つ以上のアクセスポイントによる絞り込みが必要になっている。しかし、考慮するAP対の数に対して指数のオーダーで特徴量が増加するため、特徴量圧縮が必須となり、その計算に対しても計算コストが膨大に掛かってしまう。その理由について2.4.2で詳述する。

また差分表現に注目したモデルとしてDongら [17] やFangら [18] の取り組みがあるが、このモデルでは差分表現について主成分分析などの線形変換を行ったものを特徴量として採用している。しかし線形変換のみで特徴量の設計を行っているため、単一RSSIを使用する手法と表現力が同等となってしまう機種依存性の解消に至らない。

提案手法では、機種依存性を棄却するような差分による楕円周上での特徴量表現を使用することによって、上記手法の絞り込み能力が弱いという問題点と、表現力不足のため計算量が膨大になってしまう問題点を解決している。また、ガウス場による非線形変換を介して特徴量設計を行うため、ノイズに対する感度の低い特徴量表現となっている。

2. 受信強度ベース測位における特徴量表現

受信強度が端末依存性を含んでいることを示し、既存の特徴量についてどのような問題があるのかを示す。

2.1 測位問題の定式化

測位のモデルとして、ガウス過程等によって信号強度の確率的な性質から信号強度を予測し測位を行う生成的なモデル [13] と、取得された教師付きデータから直接識別器を学習して測位を行う識別的なモデルがあげられる。また識

別的なモデルとして、特徴量から直接 $y \in \mathbb{R}^2$ への変換を行うような回帰ベースで測位を行う枠組み [15] と、特徴量から量子化された位置情報を推定する分類ベースで測位を行う枠組み [6] が挙げられる。本研究では識別モデルの分類ベースのものを想定し、特徴量表現について論ずる。

測位環境中に AP が d 個存在するとき、端末で取得される RSSI のベクトルを $\mathbf{x}^\top = (x_1, \dots, x_d)$ とする。ここで x_i が i 番目の AP の RSSI から取得される値とする。ただし i 番目の AP が観測されない場合、適当な定数 $V \in \mathbb{R}$ を用いて $x_i = V$ とする。本研究で構築する識別器 f は (1) で示される写像関数となる。

$$f(\mathbf{x}) : \mathbb{R}^d \rightarrow \mathcal{L} \quad (1)$$

ただし、 \mathcal{L} は $\mathcal{L} = \{l; g(y) = l, g : \mathbb{R}^2 \rightarrow \mathcal{L}\}$ となる量子化された位置ラベルであり、 $g(y)$ は実世界上の座標空間 \mathcal{Y} を位置ラベルである l に変換する量子化関数である。この関数 f を学習データ $\mathcal{D} = \{\mathbf{x}^{(k)}, y^{(k)}\}_{k=1}^n$ から推定する。そこで、識別器 f を (2) のように設計する。

$$f(\mathbf{x}) = \arg \max_l f_l(\mathbf{x}) \quad (2)$$

$$f_l(\mathbf{x}) = \boldsymbol{\theta}_l^\top \boldsymbol{\phi}(\mathbf{x}) \quad (3)$$

ただし、 $\boldsymbol{\phi}$ は特徴量である。本論文ではこの特徴量表現について既存の手法を 2 節、提案手法を 3 節にて述べる。この測位モデルのパラメータの学習として、次の最適化問題を考える。

$$\arg \min_{\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_L} \frac{1}{N} \sum_{k=1}^{|\mathcal{D}|} \Delta(g(y^{(k)}), f(\mathbf{x}^{(k)})) + \sum_{l \in \mathcal{L}} R(\boldsymbol{\theta}_l) \quad (4)$$

ここで、 Δ は距離の差分に対して定義されるコスト関数である。また $R(\boldsymbol{\theta}_l)$ は正則化項である。本研究では、学習アルゴリズムはコスト考慮型多クラス分類手法 [6] を使用する。また、特徴量の次元 d に対して、相対的にデータ数 n が小さくなるので、過学習を抑えるため $R(\boldsymbol{\theta}_l)$ として、L2 正則化項を導入する。今回の手法では、学習手法として確率的近接勾配法の一つである FOBOS アルゴリズム [19] を使用している。

2.2 電波強度方程式に基づく端末依存性

受信電波強度の端末依存性は、各端末のアンテナやハードウェアの特性が異なることに起因している。端末が i 番目の AP から受信する RSSI 強度 x_i は、(5) に示される電波強度方程式で示される。

$$x_i = z_{m,l_0} - 10\beta_i \log\left(\frac{l}{l_0}\right) + \psi \quad (5)$$

ここで、 z_{m,l_0} は機種 $m \in \mathcal{M}$ により決定する距離 l_0 での AP に対する絶対利得であり、 l は AP からの距離、 ψ は平均 0 のガウスノイズ、 β_i はパスロス指数である。(5) にお

ける、 z_{m,l_0} の項が機種別のアンテナやハードウェアの特性に依存しているために、受信電波強度に機種依存性が現れる。

2.3 単一 RSSI に基づく特徴量表現

取得された単一の RSSI に基づく特徴量表現について議論する。単一の RSSI から作成される特徴量表現として、RSSI について強度による閾値処理を行ってある一定以上の値であることを示す特徴量表現とするものや、ガウス場を使用して変換を行いある一定の強度の幅に存在することを示す特徴量表現にするものがある。ある閾値を超えたときに発火するバイナリ表現による j 番目の特徴量は (6) で示される。

$$\{\boldsymbol{\phi}(\mathbf{x})\}_j = \begin{cases} 1 & (sx_i \geq s\tau_j) \\ 0 & (sx_i < s\tau_j) \end{cases} \quad (6)$$

ここで、 τ_j は j 番目の特徴量に対する経験的に設定された閾値、 $s \in \{\pm 1\}$ である。2.2 で述べたように、端末によって受信強度の最大値も変化することにより多機種環境においては閾値を端末ごとに決定すべきであるため、この表現は端末依存性を棄却することはできない。

また、以下の (7) のような、ガウス場を使い RSSI に対して幅を持つことを許容した特徴量表現による位置測位も行われている。 j 番目の特徴量を次のように表現する。

$$\{\boldsymbol{\phi}(\mathbf{x})\}_j = \exp\left(-\frac{(x_i - \mu_j)^2}{2\sigma_j^2}\right) \quad (7)$$

ここで、 $\mu_j \in \mathbb{R}$ はガウス場の平均、 $\sigma_j > 0 \in \mathbb{R}$ は RSSI 値に対する尺度を示すハイパーパラメータである。しかし、端末によって受信強度の分布が変化することで、すべてのガウス場に対して特徴量の値にずれが生じてしまうため、 μ_j は端末依存のパラメータを設定すべきである。このように、単一 RSSI に基づく表現を使用すると、特徴量作成の際に必ず端末依存のパラメータを設定しなければならず、機種依存性の棄却は難しい。

2.4 複数の RSSI の組み合わせに基づく特徴量表現

端末で同時に取得された複数の RSSI に基づく特徴量表現について議論する。

2.4.1 2つの RSSI の比を使用する特徴量

2つの RSSI の比を使用した特徴量により端末依存性の棄却を目指している研究として、Kjaergaard ら [16] の手法がある。この手法では、(8) により、複数の RSSI を使用して 2つの RSSI の比を計算し、さらに端末ごとに取得される信号強度の最大値を使用して正規化を行うことで、端末依存な項の棄却を行っている。 k 番目の特徴量を次のように表現する。

$$\{\boldsymbol{\phi}(\mathbf{x})\}_k = \log\left(\frac{x_i}{x_j}\right) - \log\left(\frac{1}{\max x_m}\right) \quad (8)$$

表 1 AP 数に対するボロノイ領域面積の平均, 分散

AP 数	平均	最大値
25	100m ²	190.5m ²
50	50m ²	99.5m ²
10P	25m ²	64.9m ²

ここで $\max x_m$ は対象の機種 $m \in \mathcal{M}$ で取得された RSSI の最大値である. この表現は信号強度について対数関数を取ったものに対する差分を, さらに最大強度によって正規化したものとなっている. しかし, 信号強度がすでにデシベル値で表された対数関数の結果の値であり, また端末依存部が比となって残ってしまう表現のため機種依存性をキャンセルされない. さらに, 対象の端末の信号強度の最大値が既知である仮定のもとでのみ計算できる特徴量表現となっているため, 対象の端末についての情報がない状態で適応することができない.

2.4.2 2つの RSSI の大小関係に基づく特徴量

2つの RSSI 値の差分の正負により, 測位範囲を 2 等分する直線に対して左右どちらの AP に近いのかを表現する特徴量により端末依存性の棄却を図った研究として, Zheng ら [8] の手法がある. この手法では k 番目の特徴量を (9) で表現する.

$$\{\phi(\mathbf{x})\}_k = \delta \left(\sum_{(i,j)} c_{i,j}(x_i - x_j) + b > 0 \right) \quad (9)$$

この表現は測位範囲を二分する表現としての特性上, 図 2 のように, 原理的に曖昧性が大きくなる. そのため, 位置を絞り込むには大量の直線が必要となり, 精度に対して AP 数が大量に必要となる. ここで, 50m × 50m の空間にランダムに AP を設置したときに, その AP を 2 分割する直線での程度位置の絞り込みができるかを表すシミュレーション結果を図 3 に示す. これは, AP ごとの最も対象の AP に近くなる範囲であるボロノイ領域を 25AP, 50AP, 100AP の環境下で評価したものである. 表 1 のように, 誤差距離を 5m 程度に抑えるためには 100AP 程度必要となる.

これより 2 等分線によるどちらの AP に近いのかを表現した特徴量は, 位置の絞り込み能力が乏しいことがわかる.

そこで Zheng らは, 絞り込み能力の乏しい問題を解決するため High Order Pairwise 特徴量 [8] を提案している. これは, 2つの AP の対だけでなく, さらに複数の AP の対による表現を加えることで, バイナリ特徴量の表現力不足問題の解決を図っている. これにより, 次元が考慮するペアの数に対して指数のオーダーで特徴量が増えてしまうため, ボルツマンマシンにより非線形変換を行い特徴量を圧縮することで特徴量次元を減らしている [20]. しかし, 非線形変換の計算量も大きいため, 特徴量の計算に大きなコストがかかってしまう問題が残っている.

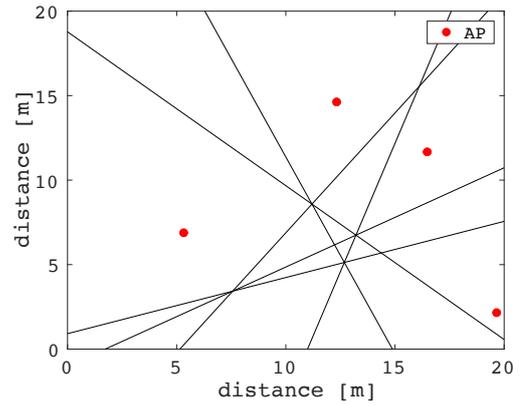


図 2 バイナリ表現の特徴量の概要図

3. 機種依存性の低い楕円周を表現する特徴量

信号強度の差分表現についてデバイスの依存性が少ないことを示す. 信号強度の差分は, 電波強度方程式 (5) より以下の (10) に示される.

$$\begin{aligned} \delta x_{i,j} &= x_i - x_j \\ &= -10\beta_i \log \left(\frac{l}{l_0} \right) + 10\beta_j \log \left(\frac{l}{l_0} \right) + \psi_i - \psi_j \end{aligned} \quad (10)$$

ここで β_i, β_j はアクセスポイント依存の信号強度を決めるパスロス指数であり, 対となる AP において同じ値を取ると仮定, つまり, $\beta_i = \beta_j = \beta_{i,j}$ とおくとすると, (11) となる.

$$\delta x_{i,j} = x_i - x_j = -10\beta_{i,j} \log \left(\frac{l_i}{l_j} \right) + \psi_i - \psi_j \quad (11)$$

また, ψ_i, ψ_j は取得環境や混雑度などによって変化するガウスノイズである. (10) より, 端末に依存する部分の項が引き算によりキャンセルされることで, RSSI の差分が端末依存性が少ない表現となっていることがわかる. この式の取る値は, 図 4 で示すような楕円周上で同じ値を取る表現となっている.

そのため, 少ない AP においても, 存在確率が高くなる範囲を円が重なる範囲に位置を絞り込むことができる. したがって, 信号強度の差分表現が位置の絞り込み能力が高い表現であることがわかる. この楕円周上を表現する値を使用し, 次のような端末の機種依存性の低い特徴量を提案する. 本研究ではこれを楕円周特徴量と呼ぶ.

$$\{\phi(\mathbf{x})\}_k = \exp \left(-\frac{(\delta x_{i,j} - \mu_k)^2}{2\sigma_k^2} \right) \quad (12)$$

ここで, $\mu_k \in \mathbb{R}$ はガウス場の平均, $\sigma_k > 0 \in \mathbb{R}$ は空間に対する尺度を示すハイパーパラメータであり交差検定により決定する. この特徴量は, (10) で導出した差分による表

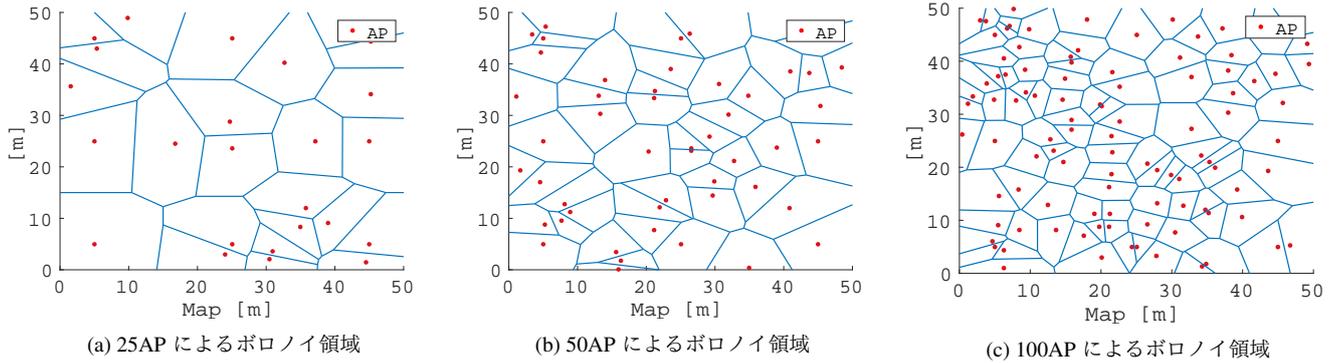


図3 バイナリ表現の特徴量のシミュレーション

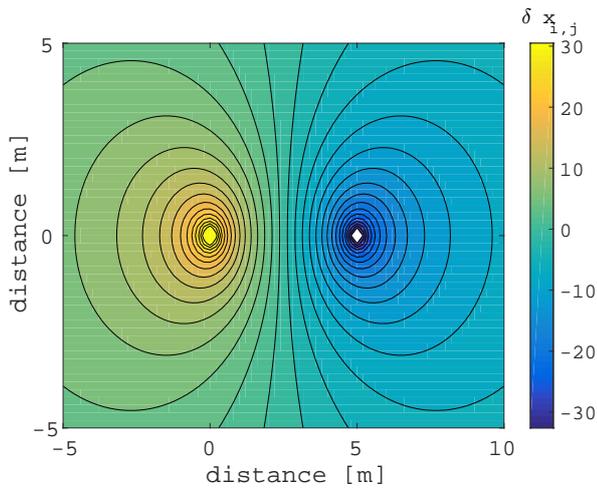


図4 電波強度の差分値の等高線図

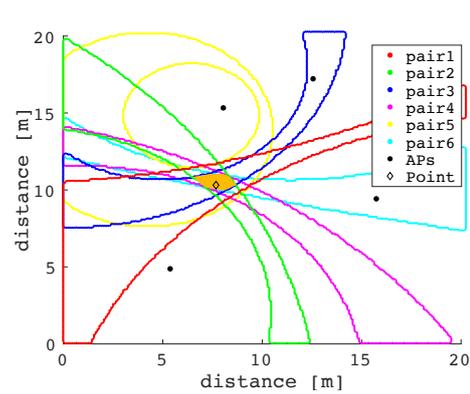


図5 差分表現における端末位置の絞り込み

現を、ガウス場による基底関数で変換することにより、差分値がある一定の幅内に収まることを表現する特徴量に変換する。この変換を行うことで特徴量が楕円周上に乗るものではなく、楕円周に対してある一定幅内に存在する事を表している。この幅を許容した表現により、RSSI 自体に乗るノイズと機種依存性に対してさらに感度が低くなる。

ランダムで4APを設置した際どの程度位置の絞り込みが行われるのかを図5に示す。この図は(10)によって計算したRSSI値が、ノイズとして ± 2 、つまり、5の幅を持ったとき、特徴量がどの程度絞り込みを行えるのかを示したものである。ここでAPは4つ設定しているため、差分表現は6種類作られる。ここで6種類の楕円表現が重なっている橙色の範囲が、差分表現によって絞り込まれた範囲である。この図より、 $5\text{m} \times 5\text{m}$ 以下の範囲に絞り込むことができていることがわかる。また、図6は、AP4つを設置し、ガウス場に30から-30まで5刻みの幅を持つ差分特徴量を設定したときに、特徴量の境界となる位置を表示したものである。これを、図3(c)と比較すると、最大となる領域の面積は、差分表現での特徴量はAPが4つのみであっても、およそ 31m^2 に絞り込むことができ、既存手法のAPのどちらに近いのかを使用する特徴量により絞り込まれた面積が100APで 64.9m^2 であるのに対し、少数のAPで位置

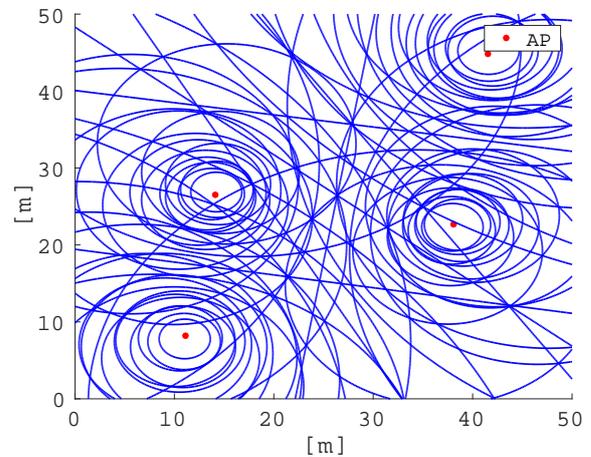


図6 30から-30まで5刻みの幅を持つ差分特徴量の絞り込み範囲

の絞り込みを行えることがわかる。このことから、差分表現が屋内測位において位置の同定力が高いことがわかる。

提案手法の特徴量であるが、この特徴量の次元が、単一のRSSIを使用して作成する特徴量と比べて増加することが問題となる。増加量は単一のRSSIの特徴量次元では d のオーダーであるが、提案手法である2APの対のRSSI値を使用する特徴量では $d^2/2$ のオーダーとなる。この特徴量のオーダーの増加に伴う学習コストの増大や過学習のリスクに関しては、注意が必要である。

観測されないAPに関しては、 $x_i = V$ と設定している

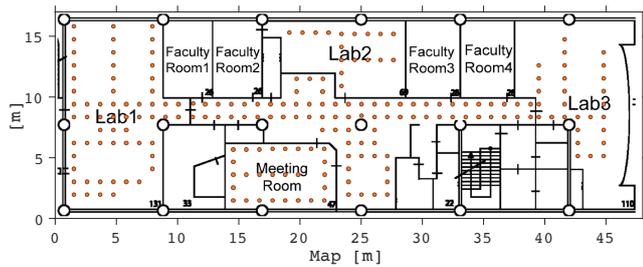


図7 実験フロア図

が、この観測されない AP に対して適当な V と (12) において適当なガウス場のパラメータを設定することによって、観測されない AP を含む AP 対を絞り込みに用いないような設定が可能である。これは、差分値が設定したガウス場に対して、すべて 0 を取るような大きな数 $\epsilon \in \mathbb{R}$ が存在するため、片方の AP が観測される際に、差分値が $|\delta x_{i,j}| = |(x_i - V)| > \epsilon$ となるような V を設定すると、ガウス場が発火しないような表現となり、絞り込みを行わない表現になるためである。また、対となる両方の AP が観測されない場合に差分値が 0 となるが、これは、差分値が平均 $\mu_k = 0$ 付近のガウス場に入り、AP が幅を持った同程度の距離にある事を示しているため、自然な表現となっている。これは、差分値が 2 つの AP の距離に応じて、同じ値を取りうる幅が広がるという特性を持つことにより導き出される。これにより、測定されない AP に対しても適切な扱いで絞り込みを行えることがわかる。

測位空間上で意味を持つ表現により測位を行う手法に RSSI の値から直接三角測量する方法が存在するが、三角測量法では (10) から直接距離空間に変換しているため、機種依存性が全く棄却できていない測位手法である。この表現では、三角測量法と異なり、機種依存性が棄却できる表現を使用して、測位空間上で楕円周上に存在するという意味を持つ表現に変換している。

また人体による電波吸収によって信号強度が弱くなる問題に対しては、ガウス場による非線形変換を行ったことにより、特徴量自体がある一定の幅を許容する表現であるため、感度が高くない。また測位において、マルチパス効果によって測位誤差が発生する問題に関しては、今回の手法では無視する。

4. 屋内測位評価実験

提案手法と既存手法の比較を行い、我々の手法が端末依存性の棄却について効果的であることを示す。

4.1 実験設定

実験は、図 7 のような、大学構内の鉄筋コンクリートによって建築されている 10 階建てビルの 4 階にある 1 フロアを使用した。17m × 47m からなるフロアであり、フロア

は 3 つの研究室、1 つの会議室、4 つの個室、1 本の廊下からなっている。この内、研究室 3 つ、会議室 1 つ、廊下を取得範囲とした。

データの取得は、このフロアに 1m × 1m のグリッド上かつ家具などが設置されていないデータ取得が可能な点を取得箇所とし、計 210 点と設定した。取得するデバイスとして、Nexus5、Nexus9 の 2 機種を用いて、設定取得範囲 1 点 1 回の取得を 10 セットを 1 日で行い、5 日間で取得を行った。それぞれの端末について計 5250 データ取得した。

各端末について、1 日分の半分である各点 5 回分のデータを学習に使用し、各点 5 回分のデータを検証用、他の各点 40 回分のデータをテスト用に使用した。

4.1.1 評価する屋内測位手法

比較する特徴量として、フィンガープリントをそのまま使用する方法として、ガウス場により取得された RSSI を非線形変換する特徴量による手法、ペアのどちらの AP に近いのかを示すバイナリを使用する手法、差分値をそのまま使用する手法を使用する。

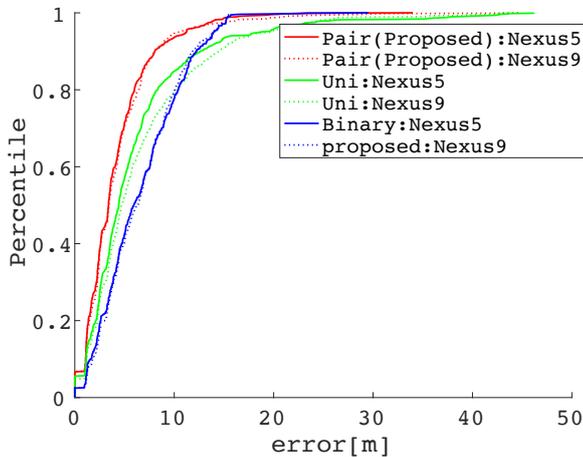
実験に用いる特徴量の設定であるが、各点 10 回分のデータを使用して交差検定した結果より、単体の RSSI とガウス場を使用する特徴量については、平均が $\mu \in \{-35, -45, -60, -80\}$ 、分散が $\sigma \in \{0.2, 1.0\}$ のそれぞれの対をハイパーパラメータを持つガウス場を使用した。また、提案手法である、差分表現に対してガウス場による変換を行う手法では、交差検定の結果、平均 μ を 30 から -30 まで 5 刻みに設定し、分散 $\sigma = 1.0$ のそれぞれのペアをハイパーパラメータを持つガウス場を使用した。

4.2 実験結果

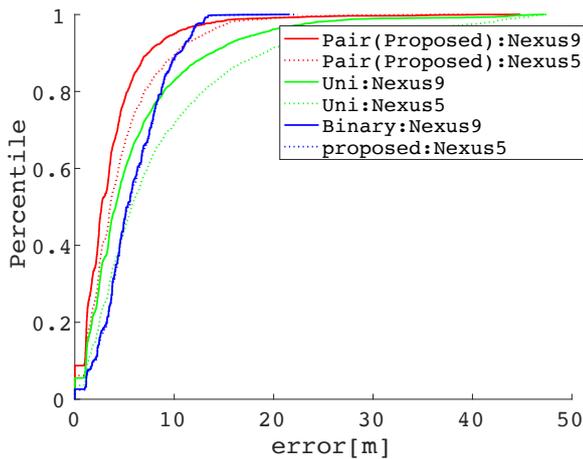
表 2 の Nexus5 を用いて取得されたデータによる学習の平均誤差 (a) より、学習した端末において屋内測位を実行する際、提案手法では 4.12m であり、既存手法の単一の RSSI を使用する手法が 6.15m、バイナリを使用する手法が 6.59m であることから、測位精度が高いことがわかる。これより、キャリブレーションを行った端末において屋内測位を行うような既存の枠組においても、精度が損なわれることがないだけでなく、精度が向上していることが示された。また、キャリブレーションを行った端末と異なる端末で屋内測位を行った際にも既存手法と比べ誤差が大きくなる範囲が少ないことが、図 8 の (a) の、学習端末と測位端末が同様の場合に対する楕円周特徴量の累積誤差曲線 (点線) と学習端末と測位端末が異なる場合に対する楕円周特徴量の累積誤差曲線 (実線) との重なりから明らかである。定量的には、平均誤差の悪化量は表 2(a) より、提案手法は 0.20m と、既存の単一 RSSI による手法は 0.53m に対し、62% 程度改善されている。バイナリの特徴量については、精度が悪化していないため、端末依存性が低いことがわか

表 2 平均誤差と平均誤差の悪化量

(a) 学習端末 : Nexus5				(b) 学習端末 : Nexus9			
feature	Nexus5	Nexus9	difference of error ave.	feature	Nexus9	Nexus5	difference of error ave.
Pair(proposed)	4.12 ± 3.49m	4.32 ± 4.14m	0.20m	Pair(Proposed)	3.70 ± 3.78m	4.71 ± 4.16m	1.01m
Uni	6.15 ± 6.56m	6.68 ± 6.39m	0.53m	Uni	6.06 ± 6.37m	8.54 ± 8.69m	2.52m
Binary	6.59 ± 4.12m	6.57 ± 3.86m	-0.02m	Binary	5.82 ± 3.18m	5.89 ± 3.19m	0.07m



(a)



(b)

図 8 CDF (a)Train by nexus5 (b)Train by nexus9

る。また、表 2 の Nexus9 によって取得されたデータによる学習の平均誤差 (b) では、各手法の累積誤差曲線は、図 8 の (b) のようになり、定量的には、提案手法は 1.01m と、既存の単一 RSSI による手法は 2.52m に対し、60% 程度改善されている。ここで、学習する端末を入れ替えた際に誤差の増加量が変化しているが、これは、学習端末のアンテナ感度の違いにより、発見できる AP の数が異なることにより発生していると考えられる。これより、AP 発見数に関する、機種依存性の解決が課題に挙げられる。これらの結果より、機種依存性が低い上に測位精度に関しても、既存の手法より良いことがわかった。

5. 結論

近年、ユビキタス・コンピューティングやアプリケーションにて需要が高まっている屋内測位において、現代の多様な端末の機種依存性により測位精度が低下してしまう問題に取り組んだ。そこで、転移学習が不要となるような端末のアンテナ特性に非依存な楕円周特徴量表現による屋内測位法を提案した。我々のモデルにより、端末の多様な機種を画一的に扱うことが可能となり、新たなキャリブレーションデータを必要とせずに新規端末に適用することが可能となった。さらに既存手法の特徴量表現と比べ、地図上での意味を持つ推定力が高い特徴量を使用することによって効率の良い絞り込みを行うことができた。

我々は、提案手法が 2 種類の機種から得られたデータを対象とした測位の評価により、端末の機種依存性の低い、精度の高い特徴量であることを確認した。将来課題として、AP 発見数に関する端末依存性を解決する手法の構築を行うこと、情報量の大きい AP を選択して特徴量として採用するような AP のスパース化を行うこと、特徴量次元をボルツマンマシンやオートエンコーダといった特徴量の圧縮によって減らすこと、またマルチパス効果による誤差の減少を可能とする学習手法の導入が挙げられる。

参考文献

- [1] Han, D. et al.: Building a practical Wi-Fi-based indoor navigation system, *IEEE Pervasive Computing*, Vol. 13, No. 2, pp. 72–79 (2014).
- [2] Bahl, P. and Padmanabhan, V. N.: RADAR: An in-building RF-based user location and tracking system, *Proc. of INFOCOM2000*, Vol. 2, pp. 775–784.
- [3] Liu, H. et al.: Survey of wireless indoor positioning techniques and systems, *IEEE Trans. on SMC(C)* 2007, Vol. 37, No. 6, pp. 1067–1080.
- [4] He, S. and Chan, S.-H. G.: Wi-Fi fingerprint-based indoor positioning: Recent advances and comparisons, *IEEE Communications Surveys & Tutorials* 2016, Vol. 18, No. 1, pp. 466–490.
- [5] Xiao, J. et al.: A Survey on Wireless Indoor Localization from the Device Perspective, *ACM Computing Surveys (CSUR)* 2016, Vol. 49, No. 2, p. 25.
- [6] Kawajiri, R. et al.: Frustratingly Simplified Deployment in WLAN Localization by Learning from Route Annotation, *Proc. of ACML2012*, pp. 191–204.
- [7] Daumé III, H.: Frustratingly easy domain adaptation, *arXiv preprint arXiv:0907.1815* (2009).
- [8] Zheng, V. W. et al.: Cold-Start Heterogeneous-Device Wireless Localization, *Proc. of AAAI2016*.

- [9] Chen, Y.-C. et al.: Sensor-assisted Wi-Fi Indoor Location System for Adapting to Environmental Dynamics, *Proc. of MSWiM2005*, pp. 118–125.
- [10] Kashima, H. et al.: A Semi-supervised Approach to Indoor Localization Estimation, *IEEE ICDM Data Mining Contest 2007*.
- [11] Hossain, A. M. et al.: SSD: A robust RF location fingerprint addressing mobile devices' heterogeneity, *IEEE Trans. on Mobile Computing 2013*, Vol. 12, No. 1, pp. 65–77.
- [12] Hoang, M. K. et al.: Aligning training models with smartphone properties in Wi-Fi fingerprinting based indoor localization, *Proc. of ICASSP2015* (2015).
- [13] Ferris, B. et al.: WiFi-SLAM Using Gaussian Process Latent Variable Models., *Proc. of IJCAI2007*, pp. 2480–2485.
- [14] Zhang, K. et al.: Covariate Shift in Hilbert Space: A Solution via Sorrogate Kernels, *Proc. of ICML2013*, pp. 388–395.
- [15] Zheng, V. W. et al.: Transferring Multi-device Localization Models Using Latent Multi-task Learning, *Proc. of AAAI2008*, pp. 1427–1432.
- [16] Kjærsgaard, M. B. and Munk, C. V.: Hyperbolic Location Fingerprinting: A Calibration-Free Solution for Handling Differences in Signal Strength (Concise Contribution), *Proc. of PerCom2008*, pp. 110–116.
- [17] Dong, F. et al.: A calibration-free localization solution for handling signal strength variance, *Mobile Entity Localization and Tracking in GPS-less Environments 2009*, pp. 79–90.
- [18] Fang, S.-H. and Wang, C.-H.: A Novel Fused Positioning Feature for Handling Heterogeneous Hardware Problem, *IEEE Trans. on Communications 2015*, Vol. 63, No. 7, pp. 2713–2723.
- [19] Duchi, J. and Singer, Y.: Efficient online and batch learning using forward backward splitting, *Journal of Machine Learning Research*, Vol. 10, pp. 2899–2934 (2009).
- [20] Hinton, G.: A practical guide to training restricted Boltzmann machines, *Momentum*, Vol. 9, No. 1, p. 926 (2010).