

Gaussian Process Particle Filter を用いた 無線 LAN 位置推定手法

伊藤誠悟†

無線 LAN 位置推定において精度の高い推定を行うためには、電波強度と対象環境内における位置を対応付けている電波地図を、正確に生成する必要がある。本論文では、無線 LAN 位置推定における電波地図の表現に Gaussian Process (GP) を用いる。GP により電波地図における電波強度平均に加え、分散（不確かさ）も表現できる。GP は分布に依存しないノンパラメトリックな表現モデルであるため、障害物などの影響により複雑に変化する実環境における電波強度を、事前サンプルデータに基づき柔軟に表現できる。本論文では、GP を Particle Filter に組み込んだ GP-Particle Filter と GP による電波地図を用いた、無線 LAN 位置推定手法を提案する。提案手法より、正確な電波地図に基づいた位置推定ができる。提案手法を実装し、実験環境において、約 3m 毎に事前サンプルデータを計測し、電波地図の生成と位置推定誤差の評価を実施した。その結果、対象実験環境全体の 3 分の 1 と少ない事前サンプルデータ計測の場合においても、位置推定結果の約 66% が 5m 以下の誤差であった。

WiFi Localization Method Using Gaussian Process Particle Filter

SEIGO ITO†

Localization of a device is highly active research area. It is important to make accurate signal strength maps of access points for localization. These maps correspond with signal strength from access points and position of environment. In this paper, we use Gaussian Process (GP) regression for a signal strength map of WiFi. GP can be used to show an uncertainty of maps and a mean of signal strength of maps. GP models are non-parametric regression; thereby GPs can approximate a signal strength map of WiFi accurately in complicated environments based on training data. We also implemented Gaussian-Process Particle Filter for localization of a device. In experiments, we demonstrate the superior result of our method.

†株式会社 豊田中央研究所
TOYOTA CENTRAL R&D LABS., INC.

1. はじめに

近年、端末の位置情報を得るために、GPS (Global Positioning System) が広く利用されている。しかし GPS 単独では、高層ビルの多い都市部や屋内環境では高い精度を得ることが難しく、他の手段を用いた位置推定手法との連携が求められている。他の手段として、無線を用いた位置推定手法に関する研究が数多くなされてきた。例えば、GSM (Global System for Mobile Communications) を用いた手法¹⁾²⁾、UWB (Ultra Wideband) を用いた手法³⁾⁴⁾、WiMAX (Worldwide Interoperability for Microwave Access) を用いた手法⁵⁾⁶⁾、Bluetooth を用いた手法⁷⁾⁸⁾、RFID (Radio Frequency Identification) を用いた手法⁹⁾¹⁰⁾、無線 LAN を用いた手法¹¹⁾¹²⁾¹³⁾¹⁴⁾¹⁵⁾¹⁶⁾¹⁷⁾¹⁸⁾¹⁹⁾²⁰⁾等がある。その中でも、無線 LAN は近年急速に普及し、屋内外の様々な環境でアクセスポイントが設置されている。これにより無線 LAN を用いた位置推定手法の実用性が高まっている¹¹⁾。

無線を用いた位置推定手法は大きく分けて Triangulation, Proximity, Scene Analysis, の 3 種類に分類できる²¹⁾。Triangulation とは、位置が既知である基準点から、無線の距離特性、方向、時間差などを考慮して位置推定を行う手法である。Proximity とは、対象がどの基準点の近くにいるかを推定する手法である。Scene Analysis とは、事前に対象環境において計測した事前サンプルデータに基づき位置推定する手法である。Scene Analysis では、事前サンプルデータ自身もしくは、事前サンプルデータから生成した電波地図 (図 1 実線) を参照して位置推定を行う。電波地図とは、対象環境内の位置と、アクセスポイントから得られる電波強度を対応付けている地図である。

Scene Analysis における大きな課題の 1 つとして、精度の高い位置推定に必要な正確な電波地図の生成がある。実環境では、壁などの障害物における反射等の影響で電波地図が複雑な形状となるため、簡単なモデルを用いた正確な電波地図の生成は難しい。他の課題として、電波地図のモデル化の際に事前サンプルデータの計測密度により、推定精度が変化するという課題¹⁹⁾がある。原因の 1 つとして、事前サンプルデータが存在しない位置での電波地図のモデル化が考えられる。例えば 図 1 に示す電波地図の例を考える。図 1 横軸はあるアクセスポイントからの距離、縦軸は電波強度である。アクセスポイントからの距離が 1, 2, 10m, の位置では多くの事前サンプルデータがあり (丸印)、8m の位置では少しの事前サンプルデータがある。4m~7m の位置では事前サンプルデータがない場合の電波地図である。事前サンプルデータがない位置では、例えば、逆距離加重法、スプライン補完 (図 1 実線)、Gaussian Mixture Model²⁰⁾等でモデル化し電波地図を構成する。従来、どの位置においても事前サンプルデータの有無に関係なく同一の重みで、図 1 実線の電波地図を用いて位置推定をしていた。しかし、事前サンプルデータが存在しない位置と存在する位置の重みを同一するのではなく、事前サンプルデータが密な位置では電波地図が確実であるとして位置推定し、疎な位置では不確実であるとして位置推定するべきであると考えられる。

上記課題に対して、本論文では電波地図の生成を Gaussian Process²²⁾により行う。Gaussian Process は、分布に依存しないノンパラメトリックな表現モデルであるため、障害物等の影響により複雑に変化する実環境での電波強度を、事前サンプルデータに基づき柔軟に表現できる。また、アクセスポイントの位置が既知である場合は、電波特性を考慮したモデルと、事前サンプルデータに基づいたモデルを連携させることも可能である。さらに、多変量モデルの平均と分散により電波地図 (図 2) を表現しているため、事前サンプルデータの密度を考慮した位置推定ができる。加えて、本論文では、Gaussian Process を Particle Filter²³⁾²⁴⁾へ組み込んだ Gaussian Process Particle Filter²⁵⁾を用いた位置推定手法を提案する。これにより、正確な電波地図に基づいた無線 LAN 位置推定を実現できる。

以下、2 節では Gaussian Process の概要について、3 節では Gaussian Process による電波地図の利点について述べる。4 節では Gaussian Process Particle Filter を用いた無線 LAN 位置推定手法について提案する。5 節においては実環境における評価実験と結果、6 節では無線 LAN を用いた位置推定手法の関連研究を示す。最後に 7 節で今後の課題を示しまとめる。




図 1 従来の電波地図例 (1 次元)
Fig. 1 Example of 1-D signal strength map

2. Gaussian Process

2.1 概要

本節では、Gaussian Process²²⁾ (以下 GP とする) の概要について述べる。GP では、事前サンプルデータの入出力から回帰関数のモデルを学習し、新たな入力を得られた場合の出力を予測する。図 2 に示す 1 次元の入出力の場合を例に説明する。図 2 は、図 1 と同様の事前サンプルデータを与えられた場合に GP で電波地図をモデル化した結果である。GP では、事前サンプルデータから破線のモデル (平均) を学習する。破線に示す非線形モデルだけならば、前節で述べた手法によりモデル化できる。GP が異なる点は、各位置における実線 (分散) のモデルも学習できる点にある。図 2 において、X が 1m~3m の値域では、事前サンプルデータが多いため、分散が小さい (不確かさが低い) と出力される一方で、4~7m の値域では、事前サンプルデータがないため、分散が大きい (不確かさが高い) として出力される。分散モデルにより、事前サンプルデータの計測密度に応じて、電波地図の不確かさを知ることができる。本論文では、2 つのモデルを電波地図 (平均)、電波地図 (分散) として位置推定する。




図 2 Gaussian Process による電波地図 (1 次元)
Fig. 2 Signal strength map of 1-D GP regression

2.2 GPによるモデル化

GPでは事前サンプルデータを基にモデルを表現する²⁵⁾。図2に示した、1次元の入出力を例に説明する。事前サンプルデータを D とする。 D は事前サンプルデータを計測した位置 x とその位置における電波強度 ss の組である。

$$D = \{(x_1, ss_1), (x_2, ss_2), \dots, (x_p, ss_p)\} \quad (1)$$

式(1)において、 p は事前サンプルデータ数である。この時、電波強度 ss は式(2)に従うと仮定する。式(2)において ε は平均0分散 σ_p^2 の加法的ガウスノイズである。

$$ss = f(x_i) + \varepsilon \quad (2)$$

事前サンプルデータ D と、ある入力 x_* において、GPでは出力 ss_* を以下の平均 GP_μ と分散 GP_Σ で定義する。

$$GP_\mu(x_*, D) = \mathbf{k}_*^T (K + \sigma_p^2 I)^{-1} ss \quad (3)$$

$$GP_\Sigma(x_*, D) = k(x_*, x_*) - \mathbf{k}_*^T (K + \sigma_p^2 I)^{-1} \mathbf{k}_* \quad (4)$$

式(3)(4)において、 k はカーネル関数、 \mathbf{k}_* は事前サンプルデータと、 x_* の共分散、 K は事前サンプルデータの共分散行列、 I は単位行列である。どのようなカーネル関数を選択するかについては利用場面次第である。以下に図2で用いているカーネル関数を示す。

$$k(x_a, x_b) = \sigma_f^2 e^{-\frac{1}{2l^2}|x_a - x_b|^2} \quad (5)$$

式(5)において、 σ_f は信号の分散、 l は長さ尺度である。 (σ_p, σ_f, l) はハイパーパラメータと呼ばれ別途最適化を行なう。上記事前サンプルデータは1次元の入出力例であるが、以降、本論文では2次元および3次元の電波地図を生成する。

3. GP電波地図

本節では実環境における具体例を用いて、GPによる電波地図の主な利点について述べる。

3.1 複雑な環境における電波地図

GPによる電波地図の一つ目の利点として、複雑な環境における電波地図を、事前サンプルデータに基づき柔軟に表現できる点がある。実環境は障害物等が存在しない自由空間ではなく、壁、柱、その他障害物が多数存在する。これらの影響により電波強度が各位置で複雑に変化するため、簡単なモデルで電波地図を正確に表現することは難しい。

例えば、図3に示す屋内環境を考える。図3はある建物の屋内地図であり、星印はアクセスポイントが設置されている位置、丸印は電波強度の事前サンプルデータの計測を行なった位置、黒線は壁や柱等を表す。図3に示す屋内環境における電波地図を作成する際に、例えば、LaMarca²⁶⁾らが用いたSeidelモデル²⁷⁾を用いた場合、電波地図は式(6)により表現できる。

$$\alpha = -32 - 25 \log_{10} r \quad (6)$$

式(6)において α は電波強度、 r はアクセスポイントからの距離である。式(6)を用いて、図3環境の電波地図を作成した結果を図4左に示す。加えて、図3の丸印の位置で計測した事前サンプルデータを用いて、GPにより生成した電波地図(平均)を図4右に示す。

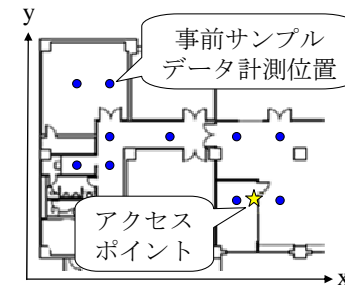


図3 屋内環境
Fig. 3 Indoor environment




図 4 電波地図 (2次元). 左: Seidel モデル, 右: Gaussian Process モデル.
Fig. 4 Signal strength map (2-D). (Left) Seidel Model, (Right) Gaussian Process Model.

図 4 左において, Seidel モデルによる電波地図では, アクセスポイントの位置から全ての方向へ電波強度が一様に低くなっている. しかし, 実際には障害物等の影響により, いくらかの位置では, 電波地図と異なる電波強度が観測される. このため, 図 4 左の電波地図を用いて位置推定を行った場合に, 高い推定精度を得ることは難しい. 一方, GP による電波地図 (平均) を図 4 右に示す. GP による電波地図では, 複雑な形状の電波強度を表現できている. GP による電波地図はノンパラメトリックな表現モデルであるため, 図 3 のような複雑な環境においても事前サンプルデータを基に柔軟に表現できる.

図 3 のような環境の電波地図を作成する既存技術として Gaussian Mixture Model (GMM) を用いた手法²⁰⁾がある. GMM では複数のガウス分布を混合係数に従い混合し電波地図を生成する. 藤田ら²⁰⁾が課題として指摘しているように, GMM による表現方法では, 表現できる形状の柔軟さがガウス分布の混合数により異なるため, 混合数をアクセスポイント毎に手動で設定する必要がある. 一方, GP による電波地図では, カーネル関数とハイパーパラメータにより環境全体のモデルを表現するため上記の課題はない.

3.2 事前サンプルデータ計測密度

GP による電波地図の 2 つ目の利点として, 電波強度の事前サンプルデータ密度を考慮できる点にある. これにより, 計測密度が疎な位置では電波地図が不確実として扱われ, 密な位置では確実な電波地図として扱うことが可能となる. 図 3 の環境における, GP による電波地図 (平均) を図 5 左に, 電波地図 (分散) を図 5 右に示す.

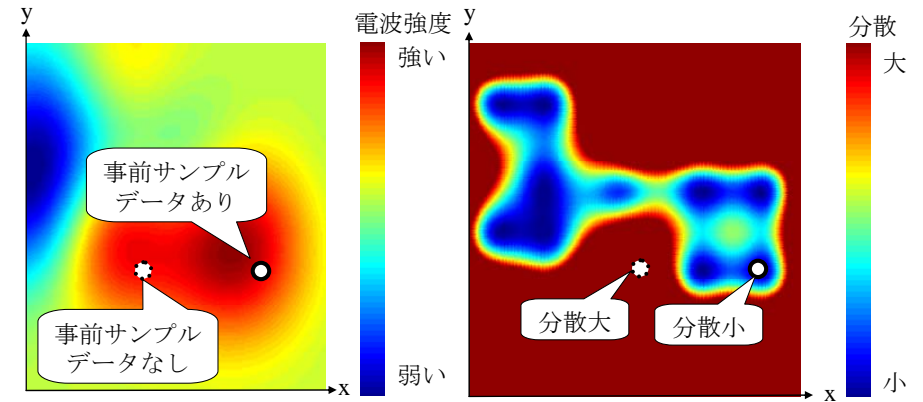


図 5 左: 電波地図 (平均), 右: 電波地図 (分散)
Fig. 5 (Left) Signal strength map, (Right) Variance map.

従来手法のように, 電波地図 (平均) のみの場合では, 事前サンプルデータがある位置 (図 5 左-丸印 (実線)) と事前サンプルデータがない位置 (図 5 左-丸印 (点線)) は, 電波強度が同じ場合は同一の重みとして扱われる. これに対し, GP による電波地図では図 5 右に示す電波地図 (分散) を併用する. 事前サンプルデータ計測をした位置付近は分散が小さく確実な電波地図として扱われ, 事前サンプルデータ計測をした位置から遠い箇所は, 分散が大きくなり不確実な電波地図として扱われる.

4. Gaussian Process Particle Filter 無線 LAN 位置推定

本節では 2 節および 3 節で説明した GP 電波地図と Gaussian Process Particle Filter を用いた位置推定手法を提案する.

4.1 全体構成

本論文における位置推定手法は, 電波地図学習段階 (4.2 節) および位置推定段階 (4.3 節) の 2 段階構成である (図 6).

電波地図学習段階では, 対象環境において事前サンプルデータの計測を行い, GP を用いてアクセスポイント毎の電波地図 (平均) および電波地図 (分散) を生成する (図 6- (1)). 基本的に電波地図学習段階は, 対象環境において一度実施する. 生成した電波地図は, 位置推定対象の各無線 LAN 端末に保持させる. 電波地図の更新については対象環境に変化が生じた場合等必要に応じて行う

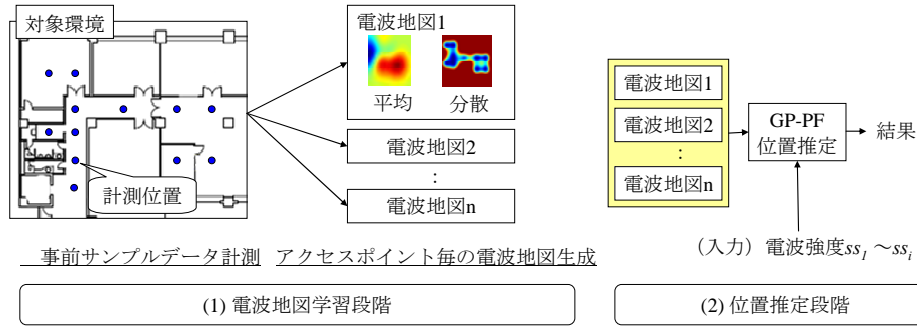


図 6 全体概要
Fig. 6 Overview of the method.

位置推定段階では、電波地図学習段階で生成した地図を保持し、ある位置においてアクセスポイントからの電波強度を計測する。その後、GP を Particle Filter²³⁾²⁴⁾に組み込んだ Gaussian Process Particle Filter²⁵⁾ (以下 GP-PF とする) により位置推定を行なう (図 6- (2))。Particle Filter はノンパラメトリックなベイズフィルタを実装した手法である。Particle Filter では、ある推定状態の事後確率を有限個の particle で表現する。

4.2 電波地図学習段階

電波地図学習段階では、各アクセスポイントの電波地図 D_o を 2 節で述べた手順に従い GP で生成する (式 (7) では $learnGP$ と略記)。事前電波地図学習における入力 X は推定対象の位置、出力 Y は各アクセスポイントからの電波強度 ss である。

$$D_o = learnGP(X_{train_input}, Y_{train_output}) \quad (7)$$

$$X_{train_input} = (x \ y \ z)^T \quad (8)$$

$$Y_{train_input} = (ss_{ap1} \ \dots \ ss_{ap_n}) \quad (9)$$

ap_n は対象環境におけるアクセスポイントの総数である。生成した具体的な電波地図は、5 節において図 8 図 10 で示す。アクセスポイント毎に電波地図 (平均) と電波地図 (分散) を生成するので、電波地図の総数は「(対象環境のアクセスポイント総数) \times 2」枚、保持することになる。

4.3 位置推定段階

本手法における位置推定段階は主に次の 3 段階からなる。

- GP 動作モデル D_u による particle の動作予測
- GP 電波地図 D_o による particle の重み計算
- 重みに応じた particle のリサンプリング

各変数の定義を示す。時刻 t における複数のアクセスポイントからの電波強度を SS_t とし、1 ステップ前の時刻 $t-1$ における particle を χ_{t-1} とする。各 particle は位置を要素に持つ。 n は電波強度を計測したアクセスポイントの数、 m は particle の数である。

$$SS_t := ss_{1,t}, ss_{2,t}, \dots, ss_{n,t} \quad (10)$$

$$\chi_{t-1} := x_{1,t-1}, x_{2,t-1}, \dots, x_{m,t-1} \quad (11)$$

$$x_{i,t-1} = (x_{i,t-1} \ y_{i,t-1} \ z_{i,t-1})^T \quad (i=1, \dots, m) \quad (12)$$

はじめに、時刻 $t-1$ におけるすべての particle に対して動作予測を行う (式(13))。 u_{t-1} は制御入力である。推定対象の速度や角速度が制御入力として得られる場合は与える。式(13)の右辺第 2 項は、動作モデル D_u に対して、入力 $[x_{i,t-1}, u_{t-1}]$ を与えた場合の GP の出力である。本論文では、ランダムウォークとするためランダムに与える。例えば、無線 LAN 端末を持っている人の位置推定をする際に、対象環境において人の動きに関する事前サンプルデータが得られる場合は、GP により動作モデル D_u を学習できる。また、移動ロボットなどに搭載されている無線 LAN 端末の位置推定を行う場合は、移動ロボットの動作モデル D_u を学習し位置推定の際に利用できる。

$$\hat{x}_{i,t} = x_{i,t-1} + GP([x_{i,t-1}, u_{t-1}], D_u) \quad (i=1, \dots, m) \quad (13)$$

動作予測を行った後、時刻 t において得られたアクセスポイントからの電波強度 SS_t を用いて、各 particle の重みを式(14)で計算する。式(14)が各 particle の位置において、あるアクセスポイントからの電波強度を観測した際の重みとなる。式(15)右辺の PDF とは、式(16)で表される。式 (16) は平均 M_μ 分散 V_Σ で表される多変量正規分布の SS における確率密度である。 k は変数の数である。このように電波地図の平均と分散を考慮して particle の重みを計算する。

$$w_{i,t} = \prod_{j=1}^n \bar{w}_{j,t} \quad (i=1, \dots, m \quad j=1, \dots, n) \quad (14)$$

$$\bar{w}_{j,t} = PDF(ss_{j,t}; GP_u(\hat{x}_{j,t}, D_{j,o}), GP_\Sigma(\hat{x}_{j,t}, D_{j,o})) \quad (15)$$

$$PDF(ss; M_u, V_\Sigma) := \frac{1}{(2\pi)^{k/2} |V_\Sigma|^{1/2}} e^{-\frac{1}{2}(ss-M_u)' V_\Sigma^{-1} (ss-M_u)} \quad (16)$$

動作予測した particle とその重みである式(17)に対し、重みに従って(18)で新たな particle をリサンプリング²⁴⁾する。

$$\hat{\chi}_t := (\hat{x}_{1,t}, w_{1,t}), (\hat{x}_{2,t}, w_{2,t}), \dots, (\hat{x}_{m,t}, w_{m,t}) \quad (17)$$

$$\text{resampling } x_{i,t} \text{ with probability } \propto w_{i,t} \quad (i=1, \dots, m) \quad (18)$$

$$\text{add } x_{i,t} \text{ to } \chi_k \quad (19)$$

本論文では(18)におけるリサンプリングの際に一定数の particle をランダムに環境内にリサンプリングするようにしている。これは、参考文献²⁴⁾において指摘されているように位置推定のロバスト性を高めるためである。式(19)の χ_k を時刻 t における位置推定結果とする。

5. 実験

本節では前節で述べた提案手法を実装し実験した結果 (5.2 節～5.6 節) を示す。

5.1 設定

図 7 に示す約 60×30m の屋内環境で電波地図の確認および提案手法の動作実験を実施した。電波地図学習フェーズは、図 7 の通路上の丸印の各箇所において 60 秒間実施した。観測されたアクセスポイントの総数は 58 個であった。このうち、-70dBm より弱い電波強度しか観測できなかったアクセスポイントは位置推定には利用しないため、25 個のアクセスポイントを電波地図の生成対象とした。すべての実験は Intel® XeonTM3.4GHz の PC 上で実施した。実験に用いた無線 LAN カードは Orinoco Gold PC Card Classic である。

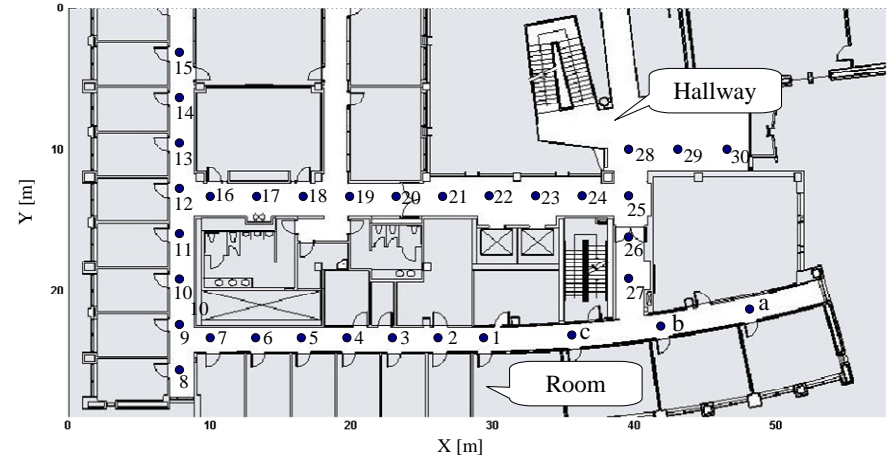


図 7 実験環境

Fig. 7 Experimental environment

5.2 電波地図 (平均)

電波地図 (平均) を作成した 25 個のアクセスポイントの中で、図 7 環境全体において、電波強度を観測できたあるアクセスポイントの電波地図 (平均) の結果を図 8 に示す。図 8 において、横軸および縦軸が位置、高さが電波強度を表す。環境全体において事前サンプルデータに基づいて複雑な形を表現できている。

電波地図 (平均) (図 8) と実際のそれぞれの位置において観測できる電波強度との関係を図 9 に示す。図 9 ではすべての位置の中より、いくつかの代表的な位置を抽出して表示している。図 9 において横軸は電波強度、縦軸は確率密度を表す。図 9 右上の位置は図 7 中の位置と対応している。実線がそれぞれの位置における、電波強度の確率密度を表し、破線が電波地図で表現している電波強度を表す。電波地図の表現方法によっては、事前サンプルデータから電波地図を生成しデータを抽象化した際に、実際の各位置における電波状況と異なる値を地図として出力してしまう手法もある。GP を用いた電波地図においては、図 9 で示すように、各位置において観測できる電波強度と、電波地図によって表現されている電波強度が大きく異なっていない。このため位置推定時の精度向上が期待できる。




図 8 あるアクセスポイントの電波地図 (平均)

Fig. 8 Mean of GP model for one access point




図 9 各位置での電波地図 (平均) の値 (破線), 同じ位置での観測データ (実線)

Fig. 9 Mean of GP map (dot), Real measurement (Solid)

5.3 電波地図 (分散)

図 8 に示した電波地図 (平均) と同じアクセスポイントの電波地図 (分散) を図 10 に示す. 図 10 において, 横軸および縦軸が位置, 高さが分散を表す. 対象環境では, 通路に沿って事前サンプルデータを取得しているため, 図 10 において, 通路付近は分散が小さい電波地図となっている. また, 図 7 における a から b を通り c までの地点も他の地点と比べて事前サンプルデータ取得間隔が長いため, その間の分散は, 他の通路の地点より大きくなっている (図 10 右). 加えて, サンプルデータを取得していない位置 (通路以外) においては分散が大きくなっており, 意図した通りに電波地図をモデル化できている.

図 7 環境の一部の範囲のみで, 電波強度を観測できたアクセスポイントの電波地図 (分散) を図 11 に示す. 横軸, 縦軸は位置を表す. 図 11 のアクセスポイントでは, 図 10 のアクセスポイントと異なり, 対象環境内の一部の通路 (図 11 中 R の範囲) では電波強度が観測できなかったため, その範囲では分散が大きい電波地図 (分散) となっている.

図 10 図 11 のどちらの電波地図 (分散) においても, 事前サンプルデータ計測位置から 5m 程離れただけで分散が大きくなっている. 事前サンプルデータ計測位置からの距離と分散の増加度合いについては, モデル化時のパラメータ設定で変更可能である. 図 10 図 11 のように, 数 m で分散が大きくなる設定ではなく, 事前サンプルデータ計測位置から遠い場合でも分散があまり大きくならない設定も可能である.




図 10 あるアクセスポイントの電波地図 (分散)

Fig. 10 Variance of GP model for one access point

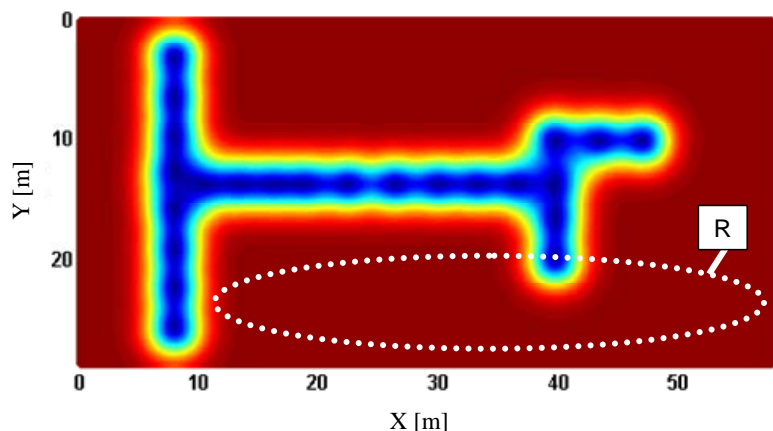


図 11 環境の一部で電波強度を観測したアクセスポイントの電波地図 (分散)
Fig. 11 Variance of GP model for partially observed access point

5.4 位置推定誤差

事前サンプルデータ計測地点の違いによる、位置推定結果を図 12 に示す。図 12 横軸は位置推定誤差、縦軸は累積確率である。図 12 の結果は、次の 3 種類の実験の結果である。

- **ALL**
番号 1~30 (図 7) の位置で事前サンプルデータを取得し電波地図を作成。
番号 1~30 の位置で位置推定を実施。各番号間は約 3m.
- **Half**
番号が偶数の位置で事前サンプルデータを取得し電波地図を作成。
番号が奇数の位置で位置推定を実施。
- **One Third**
番号が 3 の倍数の位置で事前サンプルデータを取得し電波地図を作成。
番号が 3 の倍数以外の位置で位置推定を実施。

事前学習地点が少なくなるにつれ推定誤差が大きくなっているが、図 7 における事前サンプルデータ計測地点全体の 3 分の 1 と少ない学習地点においても、全推定結果のうち 66% が 5m 以下の推定誤差であった。




図 12 GP-PF 位置推定誤差
Fig. 12 Error of GP-PF localization

5.5 実行時間

提案手法においては、実行時間は主に事前サンプルデータ数、particle 数、位置推定に利用するアクセスポイント数に影響を受ける。500 事前サンプルデータ, 200 particle, 最大 25 個のアクセスポイント (但しあるステップにおいて -70dBm 以下の観測は位置推定に利用しない) として設定し 100 ステップ位置推定した際、本手法 1 ステップあたりの平均実行時間は 0.32 秒であった。

5.6 位置推定結果例

最後に、実装した位置推定手法による結果の様子を図 13 に示す。図 13 上段に示す 4 階の Start の位置から、3 階の Goal の位置まで移動した際の結果 (図 13 下段) の例である。無線 LAN アクセスポイントは、屋内環境のいたるところに設置されているため、このように階を移動しても自己位置を見失わずに推定を続けることが可能である。



図 13 推定結果スクリーンショット
Fig. 13 Screen shot of WiFi localization

6. 関連研究

関連研究として次の論文を紹介する¹⁵⁾¹⁶⁾¹⁹⁾²⁰⁾。Bahl ら¹⁵⁾は、事前サンプルデータを決め細やかに収集し、観測した電波強度から最も近い事前サンプルデータの位置を、推定結果とする方法と、壁を考慮する Wall Attenuation Factor (WAF) というモデルを利用し推定する方法を提案している。桑原らは¹⁹⁾、電波地図において障害物の存在を予測し、予測に応じた電波減衰曲線を補完する方法を提案している。藤田ら²⁰⁾は、事前サンプルデータから Gaussian Mixture Model (GMM) により、複数の正規分布を混合して電波地図を生成している。上記 3 つの電波地図では本論文で扱っている事前サンプルデータの密度による電波地図の不確かさを考慮していない。Brian ら¹⁶⁾は、電波強度を GP でモデル化をして、無線 LAN 位置推定を実施しているが、GP による動作モデルの導入および、電波地図を Gaussian Process Particle Filter の枠組みに組み込まず本論文とは異なる。

7. まとめ

本報告では、電波地図を Gaussian Process で表現し、それらを Particle Filter に組み込んだ GP-PF による無線 LAN 位置推定手法について報告した。今後の展開として、電波地図の 3 次元化 (例: 図 14) による建物全体のモデル化および、他の屋内外位置推定システムとの連携を考えている。

残された主な課題として以下を挙げる。

- 事前サンプルデータの収集

提案手法では、事前サンプルデータを基に電波地図を作成するため、正確な事前サンプルデータの収集が課題となる。屋外では、無線 LAN 関連プロジェクト¹²⁾¹³⁾¹⁴⁾ や Google Street View²⁸⁾ で収集されているように、無線 LAN の事前サンプルデータは GPS の位置と対応付けて世界規模で広範囲に収集されている。しかし、走行しながらの収集であるため、位置との対応付けの精度が高くないと考えられる。加えて、参考文献²⁹⁾で指摘されているように、収集した事前サンプルデータは時間とともに陳腐化する。このため、SLAM (Simultaneous Localization and Mapping)²⁴⁾ 等により端末の位置推定をしながら電波地図を常に最新の状態に更新する必要がある。

- GP の計算量

大規模な事前サンプルデータを用いた場合、通常の GP では計算量が課題となる。このため、大規模な事前サンプルデータを扱う場合には Sparse GP³⁰⁾ 等を適用し計算量を削減する必要がある。




図 14 左: 建物外観, 右: 3D 電波地図 (平均) 断面図.
Fig. 14 Left – Overview of a building, Right – 3D signal strength map.

謝辞

本研究に際し、様々な議論およびアドバイスを頂いた University of Washington, Computer Science & Engineering 准教授 Dieter Fox 先生, Jonathan Ko 博士, Marc Deisenroth 博士に感謝いたします。

参考文献

- 1) Ahriz, I., Oussar, Y., Denby, B., and Dreyfus, G.: Full-Band GSM Fingerprints for Indoor Localization Using a Machine Learning Approach, *International Journal of Navigation and Observation* (2010).
- 2) Otsason, V., Varshavsky, A., LaMarca, A., et al. : Accurate GSM Indoor Localization, *Proc. UbiComp 2005*, pp.141-158 (2005).
- 3) Taok, A., Kandil, N., and Georges, S.: Fingerprinting Localization Using Ultra-Wideband and Neural Networks, *Journal of Communications*, Vol.4, No.4, pp.267-275, (2009).
- 4) Gezici, S., Zhi, T., Giannakis, G.B., et al.: Localization via ultra-wideband radios : a look at positioning aspects for future sensor networks, *IEEE Signal Processing Magazine*, Vol.22, No.4, pp.70-84 (2005).
- 5) Bshara, M., Orguner, U., Gustafsson, F., et al.: Fingerprinting Localization in Wireless Networks Based on Received-Signal-Strength Measurements: A Case Study on WiMAX Networks, *Proc. IEEE Transactions on Vehicular Technology*, Vol.59, No.1, pp.283-294 (2010).
- 6) Presad, R., Dixit, S., van Nee, R., et al.: Globalization of Mobile and Wireless Communications: Today and in 2020, Springer, pp.237-248 (2010).
- 7) Pei, L., Chen, R., Liu, J., et al. : Bluetooth RSSI Probability Distributions for Indoor Positioning, *Journal of Global Positioning System*, Vol.9, No.2, pp.122-130 (2010)
- 8) Hallberg, J., Nilsson, M., Synnes, K.: Positioning with Bluetooth, *Proc. ICT 2003*, Vol.2, pp.954-958 (2003).
- 9) Zhou, J., Shi, J.: RFID localization algorithms and applications – a review, *Journal of Intelligent Manufacturing*, Vol.20, No.6, pp.695-707 (2008).
- 10) Chon, H., Jun, S., Jung, H., et al. : Using RFID for accurate positioning, *Journal of Global Positioning Systems*, Vol.3, No.1-2, pp.32-39 (2004).
- 11) 伊藤誠悟, 吉田廣志, 河口信夫: 無線 LAN を用いた広域な位置情報システムに関する検討, *情報処理学会論文誌*, Vol.47, No.12, pp.1-13 (2006).
- 12) Locky.jp, <http://locky.jp/>
- 13) Place Engine, <http://www.placeengine.com/>
- 14) Place Lab, <http://www.placelab.org/>
- 15) Bahl, P. and Padmanabhan, V.N.: RADAR: An In-Building RF-based User Location and Tracking System, *Proc. Infocom 2000*, pp.775-784 (2000).
- 16) Ferris, B., Hahnel, D., and Fox, D.: Gaussian Processes for Signal Strength-Based Location Estimation, *Proc. RSS 2006* (2006).
- 17) 曆本純一, 味八木崇: When-becomes-Where: WiFi セルフロギングによる継続的位置履歴取得とその応用, *インタラクション 2007*, pp.223-230 (2007).
- 18) 藤田 迪, 佐々木 威, 河口 信夫: 地下鉄構内の制約条件を利用した無線 LAN 位置推定手法, *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*, No.66, pp.153-157 (2008).
- 19) 桑原 雅明, 石原 孝通, 西尾 信彦: 自律的トレーニングデータ収集による屋外位置情報システム, *情報処理学会論文誌*, Vol.50, No.4, pp.1238-1250 (2009).
- 20) 藤田迪, 梶克彦, 河口信夫: Gaussian Mixture Model を用いた無線 LAN 位置推定手法, *情報処理学会論文誌*, Vol.52, No.3, pp.1069-1081 (2011).
- 21) Liu, H., Darabi, H., Banerjee, P., et al.: Survey of Wireless Indoor Positioning Techniques and Systems, *Proc. IEEE Transactions on System Man and Cybernetics*, Vol.37, No.6, pp.1067-1080 (2007).
- 22) Rasmussen, C. E., and Williams, C.K.I.: *Gaussian Processes for Machine Learning*, The MIT Press (2006).
- 23) Metropolis, N., and Ulam, S.: The Monte Carlo method, *Journal of the American Statistical Association*, Vol.44, No.247, pp.335-341 (1949).
- 24) Thrun, S., Burgard, W., and Fox, D.: *Probabilistic ROBOTICS*, The MIT Press (2005).
- 25) Ko, J., and Fox, D.: GP-Bayes Filters: Bayesian Filtering Using Gaussian Process Prediction and Observation Models, *Autonomous Robots Journal*, Vol.27, No.1, pp.75-90 (2009).
- 26) LaMarca, A., Chawathe, Y., Consolvo, S., et al.: Place Lab: Device Positioning Using Radio Beacons in the Wild, *Proc. Pervasive 2005, Lecture Notes in Computer Science (LNCS) 3468*, pp.116-133 (2005).
- 27) Seidel, S., and Pappert, T.: 914MHz Path Loss Prediction Model for Indoor Wireless Communications in Multifloored Buildings, *Proc. IEEE Trans. Antennas and Propagation*, pp.207-217 (1992).
- 28) Vincent, L.: Taking online maps down to street level, *Proc. IEEE Computer*, Vol.40, No.12, pp.118-120 (2007).
- 29) 何 韜, 梶 克彦, 河口 信夫: 位置推定のための無線 LAN 観測データベースの健全性維持手法, *情報処理学会全国大会, 4W-2* (2011).
- 30) Snelson, E., Ghahramani, Z.: Sparse Gaussian Processes using Pseudo-inputs, *Advances in Neural Information Processing Systems*, pp.1257-1264, MIT press (2006).