

May 28, 2010

RT0908

Computer Science; Engineering Technology; Environmental Science 4 pages

Research Report

A FAST AND ACCURATE SEQUENTIAL LOCATION ESTIMATOR FOR WIRELESS DEVICES

Toshihiro Takahashi

IBM Research - Tokyo
IBM Japan, Ltd.
1623-14 Shimotsuruma, Yamato
Kanagawa 242-8502, Japan

Limited Distribution Notice

This report has been submitted for publication outside of IBM and will be probably copyrighted if accepted. It has been issued as a Research Report for early dissemination of its contents. In view of the expected transfer of copyright to an outside publisher, its distribution outside of IBM prior to publication should be limited to peer communications and specific requests. After outside publication, requests should be filled only by reprints or copies of the article legally obtained (for example, by payment of royalties).

受信信号強度を利用した高速かつ高精度な無線デバイス位置推定法

A FAST AND ACCURATE RSSI-BASED LOCATION ESTIMATOR

高橋 俊 博†

RFID や無線 LAN を利用した高速かつ高精度なデバイス位置推定は、様々な分野で重要な課題である。近年、特にロボティクスの分野で、デバイスの動きをモデル化し、推定エンジンに組み込むことで精度を向上させる、いくつかの研究がされている。これらは、詳細な生成モデルをつくり、事後分布を正確に近似しながら位置を推定・追跡するアプローチであり、計算量が多く、大量のデバイス位置のリアルタイム推定には不向きである。本論では、非線形回帰と拡張カルマンフィルタを組み合わせることで、様々な用途に耐えうる十分な精度と速度を両立した新規な手法を提案する。実験により、本手法と従来手法を精度と速度の両面から比較・考察し、有効性を示す。

1. はじめに

RFID や無線 LAN を利用したデバイス位置推定技術は、店舗内の顧客・従業員の動線解析、在庫管理、ロボットの制御といった多くの応用が考えられ、マーケティングやロボティクスをはじめとする様々な文脈で注目されている。応用を考えるうえで、アルゴリズムの位置推定精度と処理速度は重要な指標である。例えば、スーパーマーケットの店舗内の顧客の動線を解析し、マーケティングに利用する場合、顧客がどの商品棚の前を通ったかがわかる位置推定精度が必要である。また、工場内の在庫の位置を推定し作業員の補助に利用する場合、数百から数千個のデバイスの位置をリアルタイムに推定可能な処理速度が必要である。

1.1 RSSI・TOA の二つのアプローチ

位置推定法には、大きく二つの手法が提案されている。ひとつは、RSSI (Receive Signal Strength Indicator, 受信信号強度) 値を利用した手法である。^{1)~4)} 多くの RSSI 値を利用した手法では、RSSI 値から、デバイスとアクセスポイントの距離を割り出し、三角計量またはこれに類する手法で位置を推定する。一般に、RSSI 値と距離の関係は、機器に依存し、非線形である。事前に、教師データを用いて RSSI 値から位置を推定する学習器を構築、学習しておく必要がある。この手法の長短所を述べる。

- 長所
 - ハードウェアに特別な仕組みが必要ない
 - 信号の反射や回折に対してロバストである
- 短所
 - ノイズが大きく、精度が低い
 - 複雑なアルゴリズム、事前の学習が必要である

もうひとつは、TOA (Time of Arrival, 信号到着時間) を利用した手法である。アクセスポイント側に同期した時計を設置し、信号の送受信時の時刻差と信号の速度から距離を割り出し、位置を推定する。一般に、時刻差と距離の関係は線形である。また、デバイスとアクセスポイントの間に遮蔽物がないような環境では、ノイズが小さく、高い精度が得られる。この手法の長短所を述べる。

- 長所
 - 精度が高い
 - 事前の学習が必要ない
- 短所

- 特別なハードウェアが必要である
- 反射、回折に弱い

本論では、様々な遮蔽物がある室内での使用を前提とし、安価な装置で構築可能な前者のアプローチをとる。前者は、後者に対して、非線形な関係を学習する必要があり、より洗練されたアルゴリズムが必要である。また、ノイズが大きく精度が劣る。精度向上の工夫が重要である。

1.2 デバイスの動きをモデル化し、精度を向上させる研究

さらに最近の研究として、デバイスの動きモデル (遷移モデル) を構築し、確率的なフレームワークを用いて、前述の二つの手法に基づくモデル (観測モデル) と融合させたモデル (状態空間モデル) を構築することで位置推定精度を向上させる研究がされている。

Fox ら⁵⁾ は、この問題へのアプローチとして、いくつかの状態空間モデルを提案している。例えば、カルマンフィルタ⁶⁾、Multi-hypothesis Tracking (MHT)⁷⁾、Particle Filter⁸⁾などを提案している。同様の研究として、Kwok ら⁹⁾、Hightower ら¹⁰⁾がある。

カルマンフィルタと MHT は、観測モデル、遷移モデルともに線形モデル、または複数の線形モデルの混合モデルである。少ない計算量で学習・推定が可能であるが、これらのきつい仮定のため応用範囲が限定される。

Particle Filter は、遷移モデル、観測モデルともに非線形なモデルを仮定しており、応用範囲が広い。学習・推定時の計算量が多く、多数のデバイスの位置をリアルタイムに推定することは現実的でない。

本論では、拡張カルマンフィルタと親和性の高い非線形な観測モデルと線形な遷移モデルを設計し、拡張カルマンフィルタに組み込むことで、従来手法に比べて精度と処理速度を両立した位置推定アルゴリズムを構築する。

2. モデル化と学習・推定法

教師データとして座標と電波強度の組 $\{\chi_i, \omega_i\}_{i=1}^N$ を用い、時系列の電波強度 $\{z_t\}_{t=1}^M$ が与えられたとき、このデバイスの動いた軌跡 $\{\hat{x}_t\}_{t=1}^M$ を推定する。

2.1 逆観測モデル構築

逆観測モデルを構築する。逆観測モデルは、電波強度 z (ここでは時系列データでなくてもよい。単発の電波強度) が与えられたとき、教師データ (座標と電波強度の組) $\{\chi_i, \omega_i\}_{i=1}^N$ を用いて、推定座標 $\hat{x}^{(S)} = f(z)$ と座標の推定分散 $\hat{P}^{(S)} = P^{(S)}(z)$ が求まるようなモデルであれば、何でもよい。

逆観測モデルは、次のように書ける。

$$x = f(z) + v \quad (1)$$

† 日本 IBM 東京基礎研究所

Tokyo Research Laboratory, IBM Japan

ここで、 \boldsymbol{x} は真の座標、 \boldsymbol{v} はノイズ成分であり、平均 0、分散共分散行列 $\hat{P}^{(S)}$ の正規分布 $N(0, \hat{P}^{(S)})$ に従うとする。

$\hat{\boldsymbol{x}}^{(S)}$ や $\hat{P}^{(S)}$ の肩の (S) は、逆観測モデルによって推定された平均座標や分散共分散行列であることを表す。

2.1.1 逆観測モデルの例

逆観測モデルの例として、カーネル回帰法を挙げる。カーネル回帰法を用いて、教師データ（座標と電波強度の組） $\{\chi_i, \omega_i\}_{i=1}^N$ から、逆観測モデルによる推定座標 $\hat{\boldsymbol{x}}^{(S)} = f(\boldsymbol{z})$ と座標の推定分散 $\hat{P}^{(S)} = P^{(S)}(\boldsymbol{z})$ を求める。

電波強度 \boldsymbol{z} が与えられたとき、次式より逆観測モデルによる推定座標 $\hat{\boldsymbol{x}}^{(S)}$ と推定分散 $\hat{P}^{(S)}$ を求める。

$$\hat{\boldsymbol{x}}^{(S)} = f(\boldsymbol{z}) = \frac{\sum_i \left(\chi_i \times \exp\left(-\frac{\|\boldsymbol{z} - \boldsymbol{\omega}_i\|_{L_p}}{W}\right) \right)}{\sum_i \exp\left(-\frac{\|\boldsymbol{z} - \boldsymbol{\omega}_i\|_{L_p}}{W}\right)} \quad (2)$$

$$P^{(S)}(\boldsymbol{z}) = \frac{\sum_i \left(Z_i \times \exp\left(-\frac{\|\boldsymbol{z} - \boldsymbol{\omega}_i\|_{L_p}}{W}\right) \right)}{\sum_i \exp\left(-\frac{\|\boldsymbol{z} - \boldsymbol{\omega}_i\|_{L_p}}{W}\right)}$$

ここで、 $Z_i = (\chi_i - \hat{\boldsymbol{x}}^{(S)}) \times (\chi_i - \hat{\boldsymbol{x}}^{(S)})^T$ 、 $\|\bullet\|_{L_p}$ は L_p ノルムを表しており、 N 次元ベクトル $\boldsymbol{x} = \{x_1, x_2, \dots, x_N\}$ の L_p ノルムは、次式によって求まる。

$$\|\boldsymbol{x}\|_{L_p} = |x_1|^p + |x_2|^p + \dots + |x_N|^p \quad (3)$$

ノルムの係数 p は事前に適切な値を手動で設定しておく。また、 W はバンド幅をあらわしており、各サンプルの重みの減衰の仕方を調節するパラメータである。事前に適切な値を設定しておく。

2.2 遷移モデル構築

遷移モデルは、1 ステップ前の推定位置から、次のステップの位置を推定するためのモデルである。これは、時間発展するような線形モデルであれば、なんでもよい。

遷移モデルは、次のように書ける。

$$\boldsymbol{x}_t = T\boldsymbol{x}_{t-1} + \boldsymbol{w}_{t-1} \quad (4)$$

ここで、 \boldsymbol{x}_t は時刻 t の真の座標、 \boldsymbol{w}_t はノイズ成分で、平均 0、分散共分散行列 Q の正規分布 $N(0, Q)$ に従うとする。遷移行列 T と、 \boldsymbol{w}_t の分散共分散行列 Q は、事前に適切な値を手動で設定しておく。

すると、1 ステップ後の座標の推定平均は、1 ステップ前の推定平均値を使って、次式により求まる。

$$\hat{\boldsymbol{x}}_t^{(T)} = T\hat{\boldsymbol{x}}_{t-1} \quad (5)$$

また、推定された平均からのばらつき（分散共分散行列）は、1 ステップ前の分散共分散行列を使って、

$$\hat{P}_t^{(T)} = T\hat{P}_{t-1}T^T + Q \quad (6)$$

のように推定できる。

$\hat{\boldsymbol{x}}^{(T)}$ の肩の (T) は、遷移モデルによって推定された平均座標であることを表す。

2.2.1 遷移モデルの例 1

\boldsymbol{x} が 2 次元の座標で、あまり大きな移動をしないと分かっている（ランダムウォークするとしてしまって構わない）場合の例を述べる。

Q は、逆観測モデルによって推定される $\hat{P}^{(S)}$ と比べて小さく設定しておく。 T は、

$$T = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad (7)$$

と設定しておく。

2.2.2 遷移モデルの例 2

\boldsymbol{x} が 4 次元（2 次元の座標 + 2 次元の速度ベクトル）で、局的に等速直線運動のような動きをすると分かっている場合の例を述べる。このとき、逆観測モデルでも、2 次元の座標と 2 次元の速度の推定平均、推定分散共分散行列が求まらなければいけない。

例えば、デバイスが人間の徒歩の動きをしていて、0.3 秒間隔で電波強度を受信し座標を推定する場合は、 Q 、 T は、

$$Q = \begin{pmatrix} 0.3^2 & 0 & 0 & 0 \\ 0 & 0.3^2 & 0 & 0 \\ 0 & 0 & 0.5^2 & 0 \\ 0 & 0 & 0 & 0.5^2 \end{pmatrix} \quad (8)$$

$$T = \begin{pmatrix} 1 & 0 & 0.3 & 0 \\ 0 & 1 & 0 & 0.3 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (9)$$

のように設定しておく。単位はメートルとする。 Q の意味は、0.3 秒間の位置・速度の変化量の標準偏差が 0.3、0.5 であるというような意味である。（大雑把に言うと、0.3 秒間の間に位置が 30 センチずれ、速度が 50 センチ毎秒ずれることが、わりとよくある）

T は、0.3 秒間隔で推定しているため、一部要素が 0.3 となっている。 T に右から縦ベクトル $\{x_1, x_2, s_1, s_2\}^T$ を掛けると、次のステップでの座標 \boldsymbol{x} と速度 \boldsymbol{s} の平均が推定できる。

2.3 推定座標、分散の初期化

$\hat{\boldsymbol{x}}_0 = f(\boldsymbol{z}_1)$ 、 $\hat{P}_0 = P^{(S)}(\boldsymbol{z}_1)$ と初期化する。

2.4 推定

逐次的に、 $\hat{\boldsymbol{x}}_{t-1}$ 、 \hat{P}_{t-1} から、 $\hat{\boldsymbol{x}}_t$ 、 \hat{P}_t を推定していく。更新は、次のステップで行う。

まず、遷移モデルを用いて、 $\hat{\boldsymbol{x}}_t^{(S)}$ 、 $\hat{P}_t^{(S)}$ を推定する。

$$\hat{\boldsymbol{x}}_t^{(S)} = f(\boldsymbol{z}_t) \quad (10)$$

$$\hat{P}_t^{(S)} = P^{(S)}(\boldsymbol{z}_t) \quad (11)$$

次に、遷移モデルを用いて、 $\hat{\boldsymbol{x}}_t^{(T)}$ 、 $\hat{P}_t^{(T)}$ を推定する。

$$\hat{\boldsymbol{x}}_t^{(T)} = \hat{\boldsymbol{x}}_{t-1} \quad (12)$$

$$\hat{P}_t^{(T)} = T\hat{P}_{t-1}T^T + Q \quad (13)$$

ここで、ある比率 K_t で、推定値 $\hat{\boldsymbol{x}}_t^{(S)}$ と $\hat{\boldsymbol{x}}_t^{(T)}$ を混ぜたい。また、同じ比率で $\hat{P}_t^{(S)}$ と $\hat{P}_t^{(T)}$ も混ぜたい。この、混ぜる比率 K_t を次式により決定する。

$$K_t = (\hat{P}_t^{(T)} + \hat{P}_t^{(S)})^{-1}\hat{P}_t^{(T)} \quad (14)$$

K_t が求まったら、二つのモデルからの推定平均値、推定分散共分散行列を次式で混ぜる。

$$\hat{\boldsymbol{x}}_t = (I - K_t)\hat{\boldsymbol{x}}_t^{(T)} + K_t\hat{\boldsymbol{x}}_t^{(S)} \quad (15)$$

$$\hat{P}_t = (I - K_t)\hat{P}_t^{(T)}(I - K_t)^T + K_t\hat{P}_t^{(S)}K_t^T \quad (16)$$

上記の計算を、入力された電波強度の長さ $t = 1 \dots M$ だけ繰り返すことで、推定値 $\{\hat{\boldsymbol{x}}_t, \hat{P}_t\}_{t=1}^M$ を得る。

2.5 K_t の導出

ある混合比 K_t を用いて、

$$\hat{\mathbf{x}}_t = (I - K_t)\hat{\mathbf{x}}_t^{(T)} + K_t\hat{\mathbf{x}}_t^{(S)} \quad (17)$$

$$= (I - K_t)\hat{\mathbf{x}}_t^{(T)} + K_t(\mathbf{x}_t - \mathbf{v}_t) \quad (18)$$

と書ける。

真の推定値 \mathbf{x} との差の分散共分散行列は、

$$L(K_t) = \text{cov}[\mathbf{x} - \hat{\mathbf{x}}_t] \quad (19)$$

$$= \text{cov}[\mathbf{x} - (I - K_t)\hat{\mathbf{x}}_t^{(T)} - K_t(\mathbf{x}_t - \mathbf{v}_t)] \quad (20)$$

$$= \text{cov}[(I - K)(\mathbf{x}_t - \hat{\mathbf{x}}_t^{(T)}) + K_t\mathbf{v}_t] \quad (21)$$

$$= (I - K)\hat{P}_t^{(T)}(I - K)^T + K_t\hat{P}_t^{(S)}K_t^T \quad (22)$$

ここで、 $\text{cov}[\bullet]$ は、 \bullet の分散共分散行列を表す。

分散は $\text{trace}(L(K_t))$ のように計算できる。 trace は行列のトレースであり、対角成分の和である。この $\text{trace}(L(K_t))$ を最小化するために、 K_t で微分すると、

$$\frac{d}{dK_t}\text{trace}(L(K_t)) = -2(I - K_t)\hat{P}_t^{(T)} + 2K_t\hat{P}_t^{(S)} \quad (23)$$

のように書ける。式 (23) = 0 を計算すると

$$K_t = (\hat{P}_t^{(T)} + \hat{P}_t^{(S)})^{-1}\hat{P}_t^{(T)} \quad (24)$$

が求まる。

3. 実験

実データを用いて実験を行い、位置推定精度、処理速度の観点から、本手法と従来手法を比較する。

実データは、アクティブ型 RFID と 3 個のアクセスポイントを用い、12m × 6m 程度の広さの室内の 12m × 2.5m の領域で、約 0.5m 刻みの RSSI 値を収集した。室内には、ロッカーなどの遮蔽物があり、位置推定をするうえで実践的な環境と言える。RSSI 値のノイズが大きいため、各点で 2 回、5 回、10 回づつ計測し、その平均値に対して実験・考察を行った。教師データ数は 1260 点、テストデータ数は 168 点である。

以下の従来手法と比較を行う。

- k 近傍法 (kNN) (逆観測モデルのみ)
- カーネル回帰法 (KR) (逆観測モデルのみ)
- 局所重み付線形回帰法 (LWLR) (逆観測モデルのみ)
- パーティクルフィルタ + カーネル回帰法 (PKR)

比較手法における RSSI 値の距離尺度として、本手法で用いている距離尺度 $d(\alpha, \beta)$ を導入した。PKR の遷移モデルは、本手法と同じものを用いた。

すべての手法において、 d のパラメータであるバンド幅 w 、ノルム係数 p は、10-fold クロスバリデーションにより決定した。本手法、PKR の遷移モデルの分散 R は、手動で適切な値を設定した。PKR のパーティクル数は 1 万とした。

3.1 推定精度

図 1 に、各手法の平均推定誤差を示す。

多くの市場に普及している RSSI を利用した三角測量ベースの位置推定手法の平均誤差は、3m 以上である。本実験で比較対象とした kNN などの機械学習の手法を適用することで、数倍程度の精度向上が得られると考えられる。

2 点平均、5 点平均、10 点平均の違いに注目すると、すべての手法で平均点数が増えるほど平均推定誤差が減少している。複数の RSSI 値を平均化することで、ノイズを減少させ推定精度の向上が可能である。参考として、元データと 10 点で平均したデータでの RSSI 値と距離の関係を、図 2、3 に示す。

手法間の違いに注目すると、遷移モデルを取り入れた手法 (本手法、PKR) は、それ以外の手法にくらべて平均推定誤差が小さい。両者の差は、平均点数が小さいときほど顕著であ




図 1 平均誤差

表 1 処理時間

手法	処理時間 (ms)
本手法	431
PKR	33125
kNN	520
KR	656
LWLR	411

る。RSSI 値のノイズが大きいつきは、遷移モデルを導入することで、精度を向上することができると考えられる。

3.2 処理時間

表 1 に、各手法の処理時間を示す。使用したハードウェアは、ThinkPad T60 (CPU: Intel T2500 @ 2.00GHz、メモリ: 1.5GB) である。

PKR は、1 万個のパーティクルを使用して経路の事後分布を推定・追跡しているため、他の手法に比べ処理時間が長い。本手法は、拡張カルマンフィルタの枠組みを利用し、平均と分散だけを用いて、経路の事後分布を推定・追跡しているため、PKR に比べ処理が高速である。

本実験に用いたテストデータは 168 点である。PKR は、1 点あたり約 200ms の処理時間を要している。デバイスから毎秒 1 回づつ RSSI 値を受け取り推定処理を実行する場合、PKR は、最大 5 個のデバイスまでリアルタイムに処理できる。本手法は、理論上、約 400 個のデバイスまでリアルタイムに処理できる。




図 2 元データの RSSI 値と距離の関係

4. おわりに

拡張カルマンフィルタと親和性の高い非線形な観測モデルと線形な遷移モデルを設計し、拡張カルマンフィルタに組み込むことで、従来手法に比べて精度と処理速度を両立した位置推定手法を提案した。本手法が、従来手法に比べ十分な速度と精度

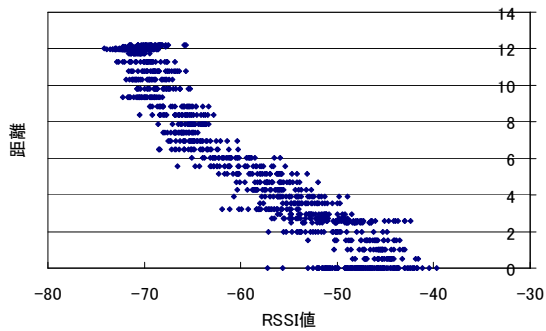


図 3 10 点平均データの RSSI 値と距離の関係

を両立しうることを実証した。

さらなる課題として、よりロバストな分布を使用した追跡・推定手法の研究(本手法では、カルマンフィルタ(正規分布)を使用した)より充実した実データでの検証などが考えられる。

謝 辞

有益な助言、実データの収集など、多大なご協力を頂きました、YSL の谷林真氏、ISE の角篤司氏、技術的なサポート・助言を頂きました、YSL の西野均氏、坂本史朗氏、TDC の福田薫氏、TRL の鹿島久嗣氏、田島玲氏に感謝します。ありがとうございました。

参 考 文 献

- 1) P. Bahland V. Padmanabhan, "RADAR: an in-building RF-based user location and tracking system." IEEE INFOCOM, Israel, March 2000.
- 2) T. Roos, P. Myllymaki, H. Tirri, P. Miskangas, and J. Sievanen, "A Probabilistic Approach to WLAN User Location Estimation." International Journal of Wireless Information Networks, Vol. 9, No. 3, July 2002.
- 3) M. Heidari and K. Pahlavan, "Performance Evaluation of Indoor Geolocation Systems Using PROPSimHardware and Ray Tracing Software." IWWAN '04, Oulu, Finland, May 2004.
- 4) A. Hatami, and Kaveh Pahlavan, "Comparative statistical analysis of indoor positioning using empirical data and indoor radio channel models." Consumer communications and networking conference, 2006.
- 5) Fox, D., Hightower, J., Liao, L., Schulz, D., Borriello, G. "Bayesian filtering for location estimation." IEEE Pervasive Computing 2 (2003) 24-33
- 6) B. D. O. Anderson and J. B. Moore, "Optimal Filtering." Prentice-Hall, 1979.
- 7) Y. Bar-Shalom and T. E. Fortmann, "Tracking and Data Association." Academic Press, 1988.
- 8) A Doucet, N de Freitas and N Gordon. "Sequential Monte Carlo Methods in Practice." Springer, 2001.
- 9) Kwok, C., Fox, D., Meil a, M. "Adaptive real-time particle filters for robot localization". In Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Volume 2. (2003) 2836-2841
- 10) J. Hightower and G. Borriello. "Particle filters for location estimation in ubiquitous computing: A case study." In Proceedings of International Conference on Ubiquitous Computing (UBICOMP), 2004.