

LSTMを用いた電波強度による複数ノードの相対位置推定

岩本 拓己¹ 重松 康祐¹

概要: 位置推定は、GNSS (Global Navigation Satellite System) を使うことが一般的であるが、衛星からの電波が届かない屋内などの環境では使うことができない。ノード間が互いに通信可能であれば、電波強度は距離に依存するため、ノードの相対位置を推定することができると考えられる。本研究では、パーティクルフィルタなどにより電波強度に含まれる誤差を抑え、LSTM (Long Short-Term Memory) を用いて相対位置の推定を行った。3つのノードによる実機実験を行った結果、GNSSと同程度以上の性能となることが確認できた。

キーワード: 電波強度, 相対位置推定, LSTM

Relative position estimation of multiple nodes by radio wave strength using LSTM

Abstract: GNSS (Global Navigation Satellite System) is commonly used for position estimation. A relative positions of multi nodes can be estimated when nodes establish communication with each other because a radio wave strength depends on a distance. In this study, we estimated relative positions using LSTM (Long Short-Term Memory) by suppressing an error contained in a radio wave strength with particle filters, etc. Experimental results with three nodes showed that a performance was equal to or better than GNSS.

Keywords: Radio Wave Strength, Relative Position Estimation, LSTM

1. はじめに

現在の位置推定はGNSSを利用することが一般的だが、衛星からの電波が届かない可能性のある屋内などでは使うことができない。電波強度は距離に依存し、ノード間の電波強度から距離を推定することができる。本研究では電波強度をもとに複数ノード間の相対位置を推定する手法を提案する。パーティクルフィルタとLSTMを併用することで、電波強度に生じる雑音を抑え、高精度に相対位置を推定することができる考えた。

自由空間で相対位置を推定する手法として、位置が既知な複数の固定ノードと、単一の移動ノード間の電波強度から移動ノードの位置を推定する手法が提案されている [1]。しかし、この手法ではすべてが移動ノードである場合に対しては適用できないため、本システムではその問題を解決する。

Svecko らは、電波の受信強度を重みとしたパーティクル

フィルタを用いる、位置推定法を提案した [2]。受信機は円形のボードに12本のアンテナを配置したものと、横に8本のアンテナを並べて配置したものを用意している。その2種類の受信機を用いて、自由空間と2波モデルのそれぞれで、受信機を比較した。結果、推定誤差は最大7.21mであった。本研究の中では、受信機は1つのアンテナを使い、パーティクルフィルタやLSTMを用いた場合との比較を行う。

GNSSのCEP (Circular Error Probability) は最大4m程度を想定する [3]。したがって、ノード間の距離の推定誤差は8mと考えられる。本システムは、GNSSが使えない環境下の代替手段として、これと同等の精度を目指す。

災害現場などでのロボットの自己位置推定としては、自己位置推定と周辺のマップ取得を同時に行うSLAM (Simultaneous Localization And Mapping) が導入されている。複数台ロボットのSLAMでは、類似の部分マップが存在する場合、互いの所有するマップを統合できる [4]。しかし、本来統合できる距離までロボット同士が近づいた

¹ 大分工業高等専門学校 情報工学科




図 1 システムの概要図

ときに、類似部分がない場合はマップを統合できない。そこで、ロボット間の相対位置情報が分かることで、統合することができると考えられる。

木村らは大型商業施設の屋内において、GNSS の代わりに無線電波通信機器の XBee と隠れマルコフモデルを使用して、電波強度から人の位置推定を行った。この研究では、場所をいくつかの領域に分けて推定した領域に人がいるかどうかを評価基準とし、正答率は 79.6% となった [5]。本システムは、相対位置推定を行うため、このような応用例に対しても有効だと考えられる。

2. 提案手法

2.1 システムの概要

図 1 にシステムの概要図を示す。ノードは通信のためのアンテナを持ち、通信時に電波強度を得る。この電波強度をパーティクルフィルタによって誤差を抑え、LSTM を通して相対位置に変換する。

2.2 電波強度と距離の関係

電波強度、RSSI (Receive Signal Strength Indication) とは受信電波の強さのことで、一般に距離が遠くなるほど弱まる。理想環境では λ を波長、 d を距離とすると (1) 式に示す自由空間伝搬損失に準じる。

$$L_{ideal}(d) = 20 \log_{10} \frac{4\pi d}{\lambda} \text{ [dBm]} \quad (1)$$

そのため、信号強度から距離を算出できるが、(2) 式に示す通り、現実の環境においては誤差や利得を含めた C を考慮する必要がある。 C は、事前のキャリブレーションによって推定する。

$$L_{real}(d) = 20 \log_{10} \frac{4\pi d}{\lambda} + C \text{ [dBm]} \quad (2)$$

また、自然・人工雑音による誤差も考慮する必要がある。その問題を解決するために、本研究ではパーティクルフィルタを用いる。

2.3 パーティクルフィルタ

パーティクルフィルタとは、時系列フィルタの一種で、

マルコフ決定過程のもとで、事前確率分布をモンテカルロ法によって近似し、事後分布を推定する手法である。特に、今回は観測不可能な状態である距離や位置 \mathbf{x}_t の確率分布を、観測値である電波強度 o_t から推定する。

本研究では以下のようにパーティクルフィルタを実装し使用する。

2.3.1 前提

$t \in \mathbb{N}$: 離散時間

o_t : 時刻 t における観測値

$pred_t$: 時刻 t における推定値

\mathbf{p}_i ($1 \leq i \leq N, i \in \mathbb{N}$) : パーティクル

2.3.2 アルゴリズム

パーティクルフィルタのアルゴリズムを、以下の 1 から 5 に示す。

- (1) \mathbf{p} を初期状態に設定する。
- (2) 3 から 5 を繰り返す。
- (3) \mathbf{p} にノイズを加えたものを $\tilde{\mathbf{p}}$ として、(3) 式から尤度を計算し、それを LH とする。

$$LH(\tilde{\mathbf{p}}, o_t) = \frac{1}{(\tilde{\mathbf{p}}_i - o_t)^2} \quad (3)$$

- (4) $\tilde{\mathbf{p}}$ から LH を重みとして N 回だけ、無作為に復元抽出したものを \mathbf{p} とする。
- (5) $\tilde{\mathbf{p}}$ から LH を重みとして、重み付き平均値を計算したものを $pred_i$ とする。

パーティクルフィルタでは、パーティクルと呼ばれるサンプルを有限個用意し、それらで分布を表現する。アルゴリズム (1) ではそれらを初期状態に設定することで、 $t = 0$ での分布を表現している。

アルゴリズム (3) では、各サンプルに対して時間 t が 1 だけ進んだ時の予測をし、どれだけ現時刻での観測に合っているかを尤度として計算している。アルゴリズム (4) はリサンプリングとよばれ、元のサンプル数と同じ数だけ、尤度が大きいものを積極的に集める。アルゴリズム (5) ではサンプルの値を尤度で重み付き平均をとって、それを推定結果とする [6]。

2.4 LSTM (Long Short-Term Memory)

機械学習において、前後のデータの関係を認識し学習する場合、RNN (Recurrent Neural Network) と呼ばれる人工回帰型ニューラルネットワークが使われることがある。しかし、RNN には勾配消失問題 [7] などの問題が知られている。この問題を解決するため、RNN をもとにした LSTM が Hochreiter らによって提唱された [8]。

本研究では、パーティクルフィルタによってノイズを抑制した電波強度を入力とし、ノードの相対位置もしくはノード間の距離を出力としたニューラルネットワークを用いる。その中のモデルの一つとして LSTM を使う。




図 2 Raspberry Pi 3B+




図 3 XBee ZB S2C

3. 実験と結果

3.1 実験機材

図 2 に示す Raspberry Pi 3B+ に、図 3 に示す XBee ZB S2C を装着し、これを 1 ノードとして通信を行う。XBee ZB S2C は、2.4GHz 帯を使用する無線モジュールである。

3.2 距離推定法の比較実験

以下に示す 4 手法で距離推定を行い、その誤差を比較する。入力には 3 ノード間の信号強度の時系列データが与えられるものとし、出力は 3 ノード間の距離とする。また、誤差の計算には 4 式を用いる。加えて、LSTM を含むニューラルネットワークの構成は図 4 に示すようにする。

- (2) 式の逆関数
逆関数を用いて、信号強度から距離に変換する。
- パーティクルフィルタ
逆関数で得た距離をパーティクルフィルタに入力し、距離を出力する。
- LSTM
逆関数で得た距離をニューラルネットワークに入力し、距離を出力する。
- パーティクルフィルタと LSTM
逆関数で得た距離をパーティクルフィルタに入力して、その結果をニューラルネットワークに入力し、距離を出力する。

表 1 に示すように、位置関係を変えた実験条件でデータを取得した。また、表 2 には表 1 で示したデータを組み合わせた、教師データとテストデータを示す。ただし、教師データは LSTM を含む手法でのみ使われる。

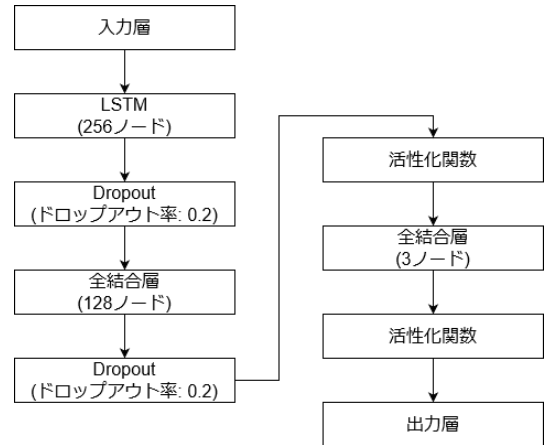


図 4 ニューラルネットワークの構成

表 1 実験条件

インデックス	AB 間の距離 [m]	AC 間の距離 [m]	BC 間の距離 [m]
1	10	10	14.14
2	20	20	28.28
3	30	30	42.43
4	40	40	56.57
5	50	50	70.71
6	10	10	18.48
7	20	20	36.96
8	30	30	55.43

表 2 学習データとテストデータ

実験	学習データ	テストデータ
1	1,2,4,5	3
2	6,8	7
3	1,2,4,5,6,8	3
4	1,2,4,5,6,8	7
5	1,2,4,5,6,7,8	3
6	1,2,3,4,5,6,8	7

$$MAE(true, pred) = \frac{1}{n} \sum_{i=1}^n |true_i - pred_i| \quad (4)$$

表 3 に、この実験の結果を示す。表からは、パーティクルフィルタと LSTM の組み合わせが、他の手法に比べて平均誤差が小さく、提案手法の有効性が確認された。また、LSTM が最も小さな平均誤差を示した。

3.3 相対位置推定法の比較実験

次に、以下に示す 2 手法で相対位置を推定する。入力は信号強度の時系列データ、出力は図 5 に示す p_1, p_2, p_3 の 3 つの値とする。また、教師データとテストデータは表 2 とする。

- LSTM
逆関数で得た距離をニューラルネットワークに入力し、相対位置を出力する。

表 3 距離の推定誤差

実験手法	実験 1 [m]	実験 2 [m]	実験 3 [m]	実験 4 [m]	実験 5 [m]	実験 6 [m]	平均 [m]
(2) 式の逆関数	13.97	6.42	13.97	6.42	13.97	6.42	10.20
パーティクルフィルタ	6.33	4.22	6.33	4.22	6.33	4.22	5.28
LSTM	4.16	5.73	4.80	10.24	4.80	10.91	6.78
パーティクルフィルタと LSTM	5.93	6.99	7.78	4.93	3.61	6.39	5.65

表 4 相対位置の推定誤差

実験手法	実験 1 [m]	実験 2 [m]	実験 3 [m]	実験 4 [m]	実験 5 [m]	実験 6 [m]	平均 [m]
LSTM	3.44	7.13	3.20	8.73	4.40	9.71	8.83
パーティクルフィルタと LSTM	5.96	4.45	4.35	9.02	2.30	7.13	6.46

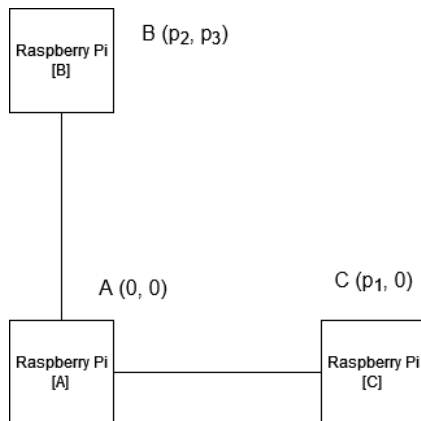


図 5 推定する値

● パーティクルフィルタと LSTM

逆関数で得た距離をパーティクルフィルタに入力して、その結果をニューラルネットワークに入力し、相対位置を出力する。

表 4 に、この実験の結果を示す。表からは、パーティクルフィルタと LSTM を用いた方が誤差が少ないことが読み取れる。また、推定誤差の平均が 6.46m と、目標にしていた GNSS の推定誤差に近い結果となった。

4. 今後の課題

今回の研究ではノードを固定している場合に限った実験であったため、移動ノードに対する評価をする必要がある。パーティクルフィルタの時間推移モデルには、正規分布を使ったため、これを対象の移動モデルに変えることで性能向上を図ることができると考える。

加えて、今回使用した無線モジュールは 100m ほどしか通信ができない。そのため、一般に 1km ほど通信可能な、920MHz 帯の無線モジュールを用いてより広い場所での実験を行うことができると考えられる。

5. 結論

本研究では電波強度から複数ノードの相対位置推定を行う中で、パーティクルフィルタや LSTM の有用性を検証した。

実験の結果、パーティクルフィルタと LSTM を組み合わせたモデルが最も推定誤差が小さくなった。また、相対位置推定における誤差平均は 6.46m であったため、目標であった GNSS の精度 8m と同程度以上の性能を示した。

参考文献

- [1] 中井若菜, 川濱悠, 勝間亮: 単位 RSSI 値の強弱の推定による位置推定精度の向上, 2017 年度情報処理学会関西支部 支部大会 (2017).
- [2] Janja Svecko, Marko Malajner, Dušan Gleich: *Distance estimation using RSSI and particle filter*, ISA Transactions (2014).
- [3] u-blox: *MAX-M10S Data sheet*, https://content.u-blox.com/sites/default/files/FILES/MAX-M10S_DataSheet_UBX-20035208.pdf, u-blox (2021).
- [4] Renaud Dubé et al.: *An online multi-robot SLAM system for 3D LiDARs*, 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (2017).
- [5] 木村 峻介, 松本 卓人, 浜中 雅俊, 李 昇姫: 迷子探しを目的とした屋内位置情報サービスの構築, 第 12 回情報科学技術フォーラム (2013).
- [6] Kitagawa, G.: *A Monte Carlo filtering and smoothing method for non-Gaussian nonlinear state space models*, Proceedings of the 2nd U.S.-Japan Joint Seminar on Statistical Time Series (1993).
- [7] Hochreiter, S.: *Untersuchungen zu dynamischen neuronalen Netzen*, Institut f. Informatik, Technische Univ. Munich (1991).
- [8] Sepp Hochreiter, Jürgen Schmidhuber: *Long short-term memory* Neural Computation 9(8) (1997).
- [9] Digi International Inc.: *XBee®/XBee-PRO S2C Zigbee® RF Module User Guide*, <https://www.digi.com/resources/documentation/digidocs/pdfs/90002002.pdf>, Digi (2022).