

ディープラーニングを用いたRSSIからの屋内位置推定

上原誠[†], 木村優志[‡], 小林秀幸^{*}[†]仙台高等専門学校, ^{*}Convergence Lab.

1. はじめに

人やモノの位置を推定し活用することは、人物の搜索や目的の場所への誘導をするうえで重要である。屋外での位置推定手法として、Global Positioning System(GPS)が普及している。しかし、屋内では人工衛星の電波を受信できないことから、GPSが利用できない。一方で、無線LANのアクセスポイントが普及したことにより、アクセスポイントを用いた様々な位置推定手法が研究されてきた^[1]。例えば、屋内位置推定手法として、端末が受信した電波の到来時刻や到来時間差を用いる方法が考えられている。しかし、屋内では、シャドウイングやマルチパスの影響を受けるため、正確な到来時刻、到来時刻差を得ることが難しい。より安価で簡易的な屋内位置推定手法として、フィンガープリント法がある。フィンガープリント法は、事前に場所ごとのWiFi受信信号強度(Received Signal Strength Indicator:RSSI)を収集するキャリブレーションを行い、データベースを作成する。位置推定時には、その場で各アクセスポイントからのRSSIを収集し、データベースの記録とマッチングすることで位置情報を推定する。しかし、RSSIを用いるフィンガープリント法は、収集端末の違いによるRSSIの差よりも、環境の変化によるRSSIの変動が推定に影響を与えることが分かっている^[2]。そのため、環境内の人やモノにより、データベース上のRSSI値とずれが生じると、それが位置推定精度の低下の原因となる。

本研究では、RSSI値の変動を考慮した屋内位置推定モデルの作成を目的とする。事前に収集したデータベースのRSSI値をディープラーニングで学習することにより、地点ごとの特徴を捉える屋内位置推定を目指す。

2. RSSIの基本原理

RSSIは無線端末などが受信した電波の強度を表す指標であり、理論値はフリスの伝達公式より、式1のように表せる。

Indoor Location Estimation from RSSI Using Deep Learning


[†]Makoto Uehara, Hideyuki Kobayashi, National Institute of Technology, Sendai College[‡]Masashi Kimura, Convergence Lab.

図1. ネットワーク構成

$$RSSI = P_t - 10 \log \left(\frac{4\pi d}{\lambda} \right)^2 + G_t + G_r \quad (1)$$

ここで、 P_t は無線LANアクセスポイントの送信電力[dBm]、 d は無線LANアクセスポイントから受信端末までの距離[m]、 λ は波長[m]、 G_t は送信アンテナ利得[dBi]、 G_r は受信アンテナ利得[dBi]を表している。

式1からRSSIは距離の二乗に反比例して減衰することがわかる。この特性は、データベースにおいても、それぞれの地点の固有の情報としてRSSI値に反映される。そのため、何らかの理由でRSSI値が変動し、位置的に近いデータから大きくずれていると、外れ値であることも分かる。このことから、それぞれの地点のRSSI値をディープラーニングで学習し、特徴を捉えることで位置推定ができるようになる。

3. 提案手法

ディープラーニングとは、パラメータで表現された関数モジュールを層状に積み重ねたネットワークを勾配降下法により最適化する手法である。各層の入力のアフィン変換を活性化関数によって非線形変換し、値の出力とする。これらを積み重ねて複雑な非線形変換を構成し、識別問題や回帰問題を解決する。

提案するディープラーニングモデルは、入出力層と、特徴を抽出する畳み込み層とプーリング層からなるCNN (Convolutional Neural Network) である。

ネットワーク構成を図1に示す。モデルは隠れ層2層のネットワークで、畳み込み層とプーリング層を交互に2回繰り返す。勾配降下法のアルゴリズムには AdamW^[3]を用いた。活性化関数には GeLU (Gaussian Error Linear Unit) を用いた。学習回数は、Early Stopping により決定した。これは、指定された試行回数だけ検証エラーが増加した場合学習を終了する手法である。ネットワークが学習データに過剰に適合して、過学習するためである。

3. 実験

フィンガープリント法と提案するディープラーニングモデルを用いて位置推定を行い、精度を比較した。フィンガープリント法では、データベースの20%をマッチングに用いる RSSI とし、残りの80%をあらかじめ収集した RSSI として利用した。フィンガープリント法のマッチングには最小二乗法を用いた。データベースの各 RSSI 値と、取得した RSSI 値の二乗誤差を計算し、誤差が最小になるインスタンスを求めた。求めたインスタンスが計測された座標 (x, y, z) を推定結果とした。ディープラーニングモデルとの比較を行うため、誤差を MAE (平均絶対誤差) で求めた。また、RSSI 値の変動による影響を確認するため、それぞれのモデルの R^2 (決定係数) を算出する。決定係数は、予測された値とデータベース上の実際の値の相関を示す指標である。決定係数が大きいほど、RSSI 値の特徴をより考慮して推定を行うモデルであるといえる。

従来の機械学習アルゴリズムと、提案するディープラーニングモデルを用いて位置推定を行い、精度を比較した。比較する機械学習アルゴリズムには、RandomForest と LightGBM を用いた。また、ディープラーニングモデルでは外れ値の影響を確認するため、目的関数として SmoothL1Loss と MSELoss を選択したモデルを作成しそれぞれの誤差を比較した。ディープラーニングモデルは PyTorch で実装した。

データは1540のインスタンスと65の属性(特徴量)からなる屋内位置データセット^[4]を用いた。入力する特徴量は35個に絞った。機器固有のIDや位置や部屋名を表す固有名詞等は位置推定への影響がほとんどないためである。出力は位置を表す3つの座標 (x, y, z) である。検証にはデータセットを学習、検証、テストの3つに分割するホールドアウト検証を、20%をテストデータ、残りを学習用データとして用いた。Early Stopping の際に用いるデータはハイパーパラメータの調整などに用いることから学習の終了に影響している。そのため、学習用データのうち20%を Early Stopping の際に用いる検証データとする。

表1. フィンガープリント法と各モデルの MAE と R^2

	フィンガー プリント法	機械学習アルゴリズム		ディープラーニングモデル	
		Random Forest	LightGBM	MSELoss	SL1Loss
MAE	1.64	2.51	2.53	1.54	1.38
R^2	0.89	0.91	0.92	0.93	0.94

フィンガープリント法、2つの機械学習モデル、目的関数が異なる2つのディープラーニングモデルの計5つのモデルの MAE と R^2 を表1に示す。フィンガープリント法や2つの機械学習アルゴリズムと比較して、ディープラーニングモデルの MAE が低く、 R^2 が高いことが分かる。これは、ディープラーニングモデルが地点ごとの RSSI の特徴を適切に捉えたからと考えられる。

また、フィンガープリント法は MAE はディープラーニングモデルに次いで高いが、 R^2 は全モデルの中で最も低い。このことから、フィンガープリント法は見かけ上 MAE は低くなるが、RSSI 値の分散が大きくなり、推定器として使用するのには課題がある。

目的関数に着目すると、MSELoss に比べて SmoothL1Loss の誤差が少ない。これは、SmoothL1Loss の外れ値に強い特性のためと考えられる。このことから、提案したディープラーニングモデルでは、データに外れ値が存在していた場合でも、その影響を小さく抑えられることが分かった。

実験から高い精度の位置推定モデルの実現が示された。

4. おわりに

本研究では、RSSI 値の変動を考慮した屋内位置推定モデルの作成を目的とし、ディープラーニングモデルを用いた屋内位置推定モデルを提案した。実験より、フィンガープリント法や従来の機械学習モデルより高い位置推定精度を示すことを確認した。

今後の予定として、アクセスポイントの数の変化がどの程度推定に影響するか確認を行う、また、データの収集時刻等、推定精度の向上を見込める新たな特徴量がないか、実際にフィンガープリントを収集して調査する。

【参考文献】

- [1] 伊藤 誠悟, 河川 信夫, “アクセスポイントの選択を考慮したベイズ推定による無線 LAN ハイブリッド位置推定手法とその応用,” 情報処理学会モバイルコンピューティングとユビキタス通信研究会, Vol.126, No.10, pp.1212-1220, 2005.
- [2] 岩館 武寛, 小林 秀幸, “複数端末におけるフィンガープリントの較正に関する研究,” 平成30年度仙台高等専門学校卒業研究論文, 2019.
- [3] Ilya Loshchilov and Frank Hutter, “Decoupled Weight Decay Regularization,” ICLR 2019 Conference, pp. 481-490, Pittsburgh, Pa, USA, September 2018.
- [4] Zsolt Tóth and Judit Tamá, “Miskolc IIS Hybrid IPS: Dataset for Hybrid Indoor Positioning,” 26st International Conference on Radioelektronika, pp.408-412, 2016.