

# 電波強度を用いた位置推定解析への LSTM の関係性

315501 Ashish Adhikari

## 1. はじめに

現在、ディープラーニング<sup>1)</sup>の応用される分野が多く存在する。様々なニューラルネットワークの構築が情報化社会の発展を遂行している。

これまで、電波強度による位置推定に対してディープラーニングの適用を試み、屋内では無線 LAN のアクセスポイントからの電波を利用した位置推定の研究を行った。RNN の一種である LSTM(Long Short-Term Memory)を使用した解析を行った結果、1m 間隔で80%以上の精度が得られた。本研究では、LSTM を使用し自己位置推定を考えた場合のデータと精度の関係性を実験的に明らかにした。<sup>5)</sup>

## 2. 実験環境およびデータ収集

図1は実験環境を示しており、図のように9つのアクセスポイント(AP1 から AP9)を配置した。アクセスポイントは、Buffalo AirStation Pro WAPM-APG300N を利用し、2.4GHz の電波を発信するように設定した。




図 1 実験環境および AP の配置

電波強度の測定には Apple MacBook Air を利用した。図1の左下を原点として、9つの AP からの電波強度 (RSSI 値) を 1m 間隔で順番に99地点のデータを測定した。AP から得られるデータには

(X,Y) 地点を設け各地点で 5 個ずつのデータを収集した。

これまでは測定した順番に並んだデータを利用して解析を行った。<sup>5)</sup> LSTM とは時系列データに有効な方法であるため、本研究では入力データとの関係性を評価するために表 1 のように収集データを AP1から AP9を元に X, Y 地点をランダム化したデータを準備し、オリジナルデータと別々に精度を測るために使用した。

表1:ランダム化データ

X	Y	AP1	AP2	AP3	...	AP8	AP9
9	6	-54	-46	-47	...	-45	-48
6	10	-51	-53	-42	...	-41	-36
...	...	...	...	...	...	...	...
8	7	-78	-54	-43	...	-31	-41
3	1	-41	-34	-43	...	-44	-55

## 3. データ解析

DL 解析ツールとしてワイカト大学によって開発された Java 系のデータマイニングツール Weka を使用している。解析は GPU 付 DL 専用パソコン (CPU Xeon E5-1620v4 4core/8thread 3.5GHz, メモリ 64GB, GPU : NVIDIA GeForce GTX 1080Ti 11GB, OS: ubuntu 16.04 LTS) で行った。

本研究の位置推定において、入力情報は、表 1と表2における AP1 から AP9 の値であり、出力は位置座標となる X と Y である。しかしながら、問題を簡単にするために、今回は、X と Y を別々に推定するように解析を行なった。

図 2 には、今回、解析を行なった基本的なディープラーニングのレイヤー構成を示した。データの入力に対し、GravesLSTM レイヤーを一層目とし、入力9に対し出力を27に設定した。Activation

Function を sigmoid と gate activation function を TanH にした. GravesLSTM によって解析された結果を 2 層目である Dense Layer に渡され, Dense Layer に出力を 27 と Activation Sigmoid を設定する. 最後に Output Layer が LossMCXENT と ActivationSoftmax を使って出力をする仕組みになっている. 最適化アルゴリズムは Stochastic Gradient Descent である.




図 2 DL のレイヤー構成

本研究では, 図2に示したレイヤー構成を基本とし, 様々なレイヤー構成を試し, ランダム化データとオリジナルデータでの精度を比較してみた.

#### 4. 実験結果

この実験には全てで4種類のニューラルネットワーク構成と2種類のデータを用いた. 構成1は図2の終わりに示されている Output Layer だけを使用し, 構成2として Dense Layer と Output Layer のみを設定している. 図2は構成3を示している. 構成4は, 図2の構成において, Dense Layer を Output Layer の前に追加した構成である.

ここで X と Y を出力とする場合の解析では, epochs 数として50と学習レートを 0.01 に設定した. Weight Initialization Method を XAVIER FAN IN 実験形式として, Cross-Validation の 10 folds を試した. これが本実験で精度が一番良かった組み合わせであり, 表3には, その時の精度を表している. 表3と表4ではそれぞれオリジナルとランダム化データの精度(%)を示す.

オリジナルデータを使用時(表3)の結果では一番精度が良かった構成は構成3であり, X も Y も 80%以上の精度を誇る. しかし, ランダム化されたデータの解析ではいい結果が得られなかった.

表 3:オリジナルデータ

No.	X(%)	Y(%)
1	32.52	31.21
2	61.26	57.27
3	81.96	81.16
4	70.00	69.59

表4:ランダム化データ

構成	X (%)	Y(%)
1	2.87	7.55
2	1.73	7.15
3	24.69	6.83
4	1.85	7.35

#### 5. おわりに

本研究を通していくつか無線 LAN の電波強度を利用した位置推定に対して, いくつかのニューラルネットワーク構成とデータを使って実験を行った. 解析データが異なれば結果も当然異なる. 今回の解析で LSTM を使用した時の結果が良かったためなぜ良かったのかを検討してみた. LSTM とは時系列データを処理するためのネットワーク層である. 位置推定のデータを取得するにも少しずつ移動しながらの取得になるので時系列データになる. 逆に, データをランダム化されたことによって時系列データではなくなった. 結果, 精度が大幅に下がってしまったのである.

#### 6. 参考文献

- 1) 書籍 ゼロから作る Deep Learning ② — 自然言語処理編 斎藤 康毅
- 2) 小野嵩晃, 平石広典, "電波強度と加速度センサーによるハイブリッドな位置推定方式", 情報処理学会第 75 回全国大会, Vol.3, pp.197-198, 2013.3.
- 3) こわかる LSTM ~ 最近の動向と共に  
<https://qiita.com/t.Signull/items/21b82be280b46f467d1b>
- 4) Understanding LSTM Networks  
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- 5) 平成 30 年度 前期 卒業研究発表会  
アブストラクト集創生工学科 情報システムデザイン学系 ページ 96-97