

機械学習を利用した BLE (Bluetooth Low Energy) の距離計測

高瀬一郎^{†1} 中谷多哉子^{†2}

概要: 在庫管理の場面で商品の位置を特定するのに電子タグなどを利用することで省力化、自動化が期待できるため企業での採用が増えている。いわゆる IOT の力を借りることで低予算で実現可能ではないかと考えた。商品に添付した BLE (Bluetooth Low Energy) タグが発する電波強度を利用して位置の特定をする場合に受信するセンサーの感度個体差を機械学習 (教師あり学習) を用いて是正した。

キーワード: 在庫管理, Bluetooth, 機械学習

Distance measurement of BLE (Bluetooth Low Energy) with machine learning

ICHIROH TAKASE^{†1} TAEKO NAKATANI^{†2}

Abstract: In order to save labor-cost electronic tags have been introduced. The tags specify the location of the goods by inventory control. The network of tags will construct IoT of goods in the inventory. The BLE (Bluetooth Low Energy) will open new world for detecting the position of each good in the inventory. However, there are still big problems to detect the position of goods by the radio strength from each BLE tag attached to goods. We tried to investigate the relationships between the strength of the electric wave from a tag and the real distance from the sensor to the tag by supervised mechanical learning.

Keywords: inventory control, Bluetooth, mechanical learning

1. はじめに

1.1 背景

在庫管理の場面で商品の位置や数量を特定するのに電子タグなどを利用することで省力化、自動化が期待できるため企業での採用が増えている。

特に大企業の場合は潤沢な資金をもとに専用の機材を用いて実現できるが、人手不足に陥りがちで本来一番必要とされる中小企業では中々実現できていないのが現状である。いわゆる IoT (Internet of Things: モノのインターネット) が普及することで安価な道具が増えてきたいま、その力を借りることで低予算で実現可能ではないかと考えた。

1.2 本論文の構成

本論文では第 2 章で研究のアプローチを示す。第 3 章で事前実験の概要を示す。第 4 章で実際の実験の内容を、第 5 章で実験の結果分析を述べる。おわりに今後の研究の方向性を述べる。

2. 研究のアプローチ

2.1 本研究の対象

本論文で在庫管理の省力化、自動化を低予算で実現するべくまずは単体のタグを使って距離測定が可能かを検証し、複数センサーを利用した位置特定の実現に向けた研究を進

めていく。

以下に必要な機材等について述べる。

2.2 Bluetooth タグ

位置特定のタグは Bluetooth のタグのうちバージョン 4.0 の BLE (Bluetooth Low Energy) を採用した。bluetooth は免許の必要がない 2.45GHz 帯を利用した単距離無線通信技術で IEEE 802.15.4 で標準化されている。その中の Bluetooth 4.0 はそれ以前のバージョンに比べて省電力化が進んでいる。BLE タグは HC-05 と呼ばれるトランシーバモジュールを利用した。図 1 に実際に利用したモジュールを示す。

在庫管理の場面では安価な RFID タグを利用^{†3}することが多い。RFID タグには大きく分けてアクティブタイプとパッシブタイプがある。アクティブタイプは自ら電波を発するもの、パッシブタイプはエネルギー源を持たず受信機が発する電波に反応するという違いがあるがいずれも専用の機材を必要とする。

Bluetooth は多くのスマートフォンや一部のパソコンに搭載されている機能で安易に利用が可能であることが採用に至った理由である。BLE タグは RFID のアクティブタイプ同様に自ら電波を発する機構ゆえ電源の寿命という問題やその心配がない RFID パッシブタイプよりも費用が掛かる

1 放送大学

2 放送大学

3 「RFID タグによる位置特定と歩行者ナビゲーションシステムの開発」内田 敬 など

という問題があるがそこは技術革新による長寿命化や流通量の拡大に伴う低価格化に期待したい。

トランシーバモジュールは本来電子部品として電化製品に組み込まれるものだが計測の邪魔となる装飾品がないというのが採用理由である。製造メーカーよりデータシートという形で詳細な仕様が公開されている。




図1 HC-05 Bluetooth Low Energy モジュール

2.3 センサーとして RaspberryPi を適用

BLE タグの電波を受信するセンサーとしてラズベリーパイ (RaspberryPi) を採用した。ラズベリーパイはラズベリー財団が開発したシングルボードコンピュータでコンピュータ教育の発展を目的として開発されたものであり、その高機能さを利用して各分野で利用されている⁴。ラズベリーパイはその大きさやバージョンにより数種類販売されている。本研究では必要機能である Bluetooth を搭載した安価な Zero W というモデルを採用した。実際に利用したラズベリーパイを図. 2 に示す。

USB での給電が可能な為スマートフォンで利用するモバイルバッテリーが利用可能である。OS (オペレーションシステム) はラズベリーパイ公式サイトで配布されている Raspbian を利用した。Raspbian は Linux のディストリビューション (使い易いように一纏めにした頒布形態) の一つである debian をベースとした OS である。動作プログラムは Raspbian に標準であり、且つ多彩な機械学習ライブラリを有する python 言語を利用した。




図2 RaspberryPi Zero W

2.4 機械学習の適用

機械学習は大きく「教師あり学習」、「教師なし学習」と「強化学習」の3種類がある。「教師あり学習」とは1つのデータとして特徴とラベル (正解) を結び付けたものを学習させ、そこから推測するものである。「教師なし学習」はラベルを持たず特徴だけを学習させてコンピュータが特徴を分類わけするものである。「強化学習」は人間が経験して学んで行くのと同様にコンピュータ自らが経験してその中から法則を導き出して行くものである。

今回は「教師あり学習」を採用した。タグの値とラベルとしてセンサーの位置を学習させて新たなデータがどこに分類されるかを判定させる事で利用できると判断した。

3. 事前実験

3.1 目的

位置を特定するにはタグが発する電波の強弱 (電波強度) を用いるが、電波強度がどれくらいのものか、実際に受信を行って確認する。スマートフォンなどの BLE タグからの電波強度を調べるアプリでは値が一定の数値を示しているのだが、そういう状況なのかも合わせて確認する。

3.2 方法

センサーを2台5mの間隔で配置し、1mごとに移動させたタグの電波がどのように変化するかを比較する。そのイメージを図3に示す。センサーAとセンサーBはそれぞれセンサーの配置場所、①~④はタグの配置場所を指す。センサーの間隔は5m、①~④の間隔はそれぞれ1mとした。センサーの個体差を比べるためにセンサーAとセンサーBの位置に配置するセンサーを入れ替えて合計8回の計測を行った。

4 Raspberry Pi を用いた野鳥観察システム (佐々木 征央 など)




図3 センサーとタグの配置

3.3 結果

測定結果を表1に示す。受信した値（RSSI値）はマイナス値で表される為、数値が大きい方が電波強度は低い（距離が遠いと推測できる）事に注意が必要である。

NOは実験の順序、距離は図3の①～④の場所に該当する。NO1～4 センサー1は図3のセンサーAの場所に、同じくセンサー2は図3のセンサーBの場所に該当する。NO5～8のセンサー2は図3のセンサーAの場所に、センサー1は同じくセンサーBの場所に該当する。

平均値/最大/最小はそれぞれ距離ごと、センサーごとの受信値の平均値/最大値/最小値を指す。

同じ距離でも最大値と最小値で最大1.58倍の乖離が見られた。また、同じ距離でもセンサーにより受信値が異なり距離による受信値を合算した場合は乖離はさらに大きくなった。表2に距離毎に受信値を合算した値を示す。距離毎の合算すると乖離の最大は1.74にまで膨らんだ。

表1 事前実験結果

NO	距離	センサー1				センサー2			
		平均	最小	最大	乖離率	平均	最小	最大	乖離率
1	①	-60.82	-73	-55	1.33	-76.45	-88	-70	1.26
2	②	-66.78	-80	-55	1.45	-79.17	-89	-70	1.27
3	③	-76.22	-87	-71	1.23	-74.71	-83	-69	1.20
4	④	-80.82	-99	-67	1.48	-66.05	-79	-60	1.32
NO	距離	センサー2				センサー1			
		平均	最小	最大	乖離率	平均	最小	最大	乖離率
5	①	-75.13	-85	-69	1.23	-61.78	-74	-55	1.35
6	②	-77.00	-86	-68	1.26	-70.30	-87	-55	1.58
7	③	-76.65	-87	-68	1.28	-75.58	-87	-62	1.40
8	④	-68.84	-84	-57	1.47	-80.70	-99	-69	1.43

表2 事前実験結果 距離合算

	平均	最小	最大	乖離率	平均	最小	最大	乖離率
①	-68.66	-85	-55	1.55	-67.40	-88	-55	1.60
②	-74.15	-86	-55	1.56	-73.26	-89	-55	1.62
③	-76.41	-87	-68	1.28	-75.19	-87	-62	1.40
④	-73.27	-99	-57	1.74	-67.40	-88	-55	1.60

3.4 本実験に向けて得られた知見

受信電波強度に1.5倍以上の幅があることが判明した。また、センサーによる個体差も想像以上に存在することが判明した。

4. 実験

4.1 問題点

事前実験で判明した受信強度の幅は特に屋内の場合は壁面

による電波の反射（電波は反射する事で弱くなるが全て消失する訳ではない）であると推測でき、考慮する必要がある。小規模の倉庫を想定しており数メートル程度の近距離にある商品の位置特定を目的とする為に反射による電波を簡単に無視することはできない。

BluetoothはWi-Fiや電子レンジなどに干渉されることが知られており留意する必要がある。

4.2 解決策（仮説）

反射による電波の乱れや他の機器による干渉により瞬間的な測定で位置を特定するのは非常に困難であるとの理解から、時間的に幅を持たせて受信した電波の情報を元に位置を特定することが可能ではないかと考えた。

具体的には事前に採取した大量のデータを教師データとして利用する機械学習（教師あり学習）を利用することで解決できると仮定した。

4.3 機械学習を採用した理由

統計的に考えて平均値、最頻値もしくは標準偏差を持って距離を推測することが可能ではないかとも考えられるが、受信電波強度に相当な幅があり反射による幅を差し引いたとしても一定の幅がある可能性が高い。幅のあるデータ群の出現確率を判断するには機械学習が最適との判断した。

4.4 目的

4.2. で示した仮説を実証する為に実験を行った。

4.5 方法

4.5.1 概略

自宅の部屋を倉庫にみたて位置を固定したBLEタグから発せられる電波を2.5mと5mの2か所で受信したものを学習データとして学習させ、時間を置いて同じ場所で再採取した別のデータを元に位置を推測させる。図4にタグとセンサーの配置を示す。太点線は部屋の壁面を、縦直線はそれぞれ2.5mと5mの距離を表す。なお測定場所の大きさからBLEタグと5mの測定時のセンサーの位置がそれぞれ壁際に配置せざるを得なかったことを明示しておく。




図4 タグとセンサーの配置図（イメージ）

4.5.2 測定距離の設定

2.5mと5mという距離は、想定する倉庫（おおよそ50坪）の中央に配置した場合にBLEタグとセンサーの最大距離を5mと仮定し、その半分の2.5mの2点でデータの違いを判別するという設定で決定した。

4.5.3 データ件数

データは BLE からの受信を 20 件ごとの束として推測させた。個別データではなく 20 件の束としたのは一定の目安として決定したもので結果により増減させる予定である。

4.5.4 動作プログラム

1 つのセンサーを移動させて測定する方式とした。センサーの個体差を不安視したためである。機械学習は多数の理論の中でナイーブベイズ定理分類器を利用した。

ナイーブベイズ定理分類器とは確率分類器である。

4.6 実施

収集したデータの件数を図 5 に示す。教師データをそれぞれ 19000 件以上、テストデータを 4000 件収集した。教師データとテストデータの収集には、連続して採取した場合、周辺環境が酷似してしまうと期待した成果があげられないとの視点から一定の時間をあけた。

	5m	2.5m
教師データ件数	19,940	19,120
テストデータ	4,000	4,000

図 5 収集データ件数

4.7 結果

4.7.1 機械学習による推測結果 5m

20 件の束の受信情報を使って 100 回の推測を行った。その結果を図 6 に示す。NO が試験番号、距離列と推測列が異なるもの（色付けした箇所）が誤推測で 2 件となった。

NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測
0	50	50	20	50	50	40	50	50	60	50	50	80	50	50						
1	50	50	21	50	50	41	50	50	61	50	50	81	50	50						
2	50	50	22	50	50	42	50	50	62	50	50	82	50	50						
3	50	50	23	50	50	43	50	50	63	50	50	83	50	50						
4	50	50	24	50	50	44	50	50	64	50	50	84	50	50						
5	50	50	25	50	50	45	50	50	65	50	50	85	50	50						
6	50	50	26	50	50	46	50	50	66	50	50	86	50	50						
7	50	50	27	50	50	47	50	50	67	50	50	87	50	50						
8	50	50	28	50	50	48	50	50	68	50	50	88	50	50						
9	50	50	29	50	50	49	50	50	69	50	50	89	50	50						
10	50	50	30	50	50	50	50	50	70	50	50	90	50	50						
11	50	50	31	50	50	51	50	50	71	50	50	91	50	50						
12	50	50	32	50	50	52	50	50	72	50	50	92	50	50						
13	50	50	33	50	50	53	50	50	73	50	50	93	50	50						
14	50	50	34	50	50	54	50	50	74	50	50	94	50	50						
15	50	50	35	50	50	55	50	50	75	50	50	95	50	50						
16	50	50	36	50	50	56	50	50	76	50	50	96	50	50						
17	50	50	37	50	50	57	50	50	77	50	50	97	50	50						
18	50	50	38	50	25	58	50	50	78	50	50	98	50	50						
19	50	50	39	50	50	59	50	50	79	50	50	99	50	50						

図 6 5m の推定結果

4.7.1 機械学習による推測 2.5m

5m と同様に 100 回の推測を行った結果、誤推測が 30 件となった。その結果を図 7 に示す。図 6 と同様に色付けした箇所が誤推測を表す。

NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測	NO	距離	推測
0	25	50	20	25	50	40	25	50	60	25	25	80	25	25						
1	25	25	21	25	50	41	25	25	61	25	50	81	25	25						
2	25	25	22	25	50	42	25	25	62	25	25	82	25	25						
3	25	25	23	25	50	43	25	50	63	25	25	83	25	25						
4	25	50	24	25	50	44	25	25	64	25	50	84	25	25						
5	25	25	25	25	25	45	25	25	65	25	25	85	25	25						
6	25	25	26	25	25	46	25	50	66	25	25	86	25	25						
7	25	25	27	25	50	47	25	25	67	25	50	87	25	50						
8	25	25	28	25	25	48	25	25	68	25	25	88	25	25						
9	25	50	29	25	25	49	25	25	69	25	25	89	25	25						
10	25	25	30	25	25	50	25	25	70	25	25	90	25	25						
11	25	50	31	25	25	51	25	25	71	25	50	91	25	50						
12	25	25	32	25	25	52	25	25	72	25	50	92	25	25						
13	25	50	33	25	25	53	25	25	73	25	25	93	25	25						
14	25	25	34	25	25	54	25	25	74	25	50	94	25	50						
15	25	25	35	25	25	55	25	25	75	25	25	95	25	25						
16	25	25	36	25	50	56	25	25	76	25	25	96	25	25						
17	25	25	37	25	25	57	25	50	77	25	25	97	25	25						
18	25	25	38	25	25	58	25	25	78	25	25	98	25	25						
19	25	25	39	25	25	59	25	25	79	25	25	99	25	25						

図 7 2.5m の推定結果

5. 分析

5.1.1 5m と 2.5m の推測分析

ほぼ正解であった 5m に対して 2.5m の場合は 3 割弱の誤推測という結果になった。

反射による誤推測であろうと推論できる。

5.1.2 教師データの数量分布

2.5m の誤推測の偏りの原因を調べるために教師データを集計したグラフを作成した。その内容を図 8 に示す。縦軸は合計件数、横軸は電波強度を表す

- ・右に行くほど電波強度が高い
- ・実線：2.5m の受信データ
- ・橙線：5m の受信データ

四角①：2.5m と 5m のデータが混在する部分

実線と点線が重なりながらも青線の方が全体的に右側（電波強度が高い＝近距離）にあることが読み取れる。

反射電波を受信したものと考えられる。

四角②：5m のデータが多く占める部分

四角③：2.5m のデータが多く占める部分

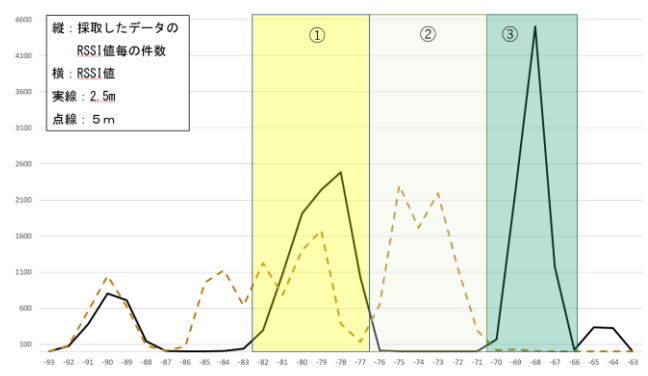


図 8 教師データの件数分布図

5.1.1 全体分析

2.5mm のデータは実際の場所③と反射によるもの①との 2 極化がはかられており、これが誤推測の原因ではないかと考えられる。逆に 5m は実際の場所②に比べて反射データの件数の分布①は多いが幅が広いために誤推測の確率が

下がり、正解が多かったと考えられる。

6. おわりに

本論文では BLE タグとラズベリーパイセンサーを利用して収集した電波情報を使って機械学習による距離計測の実験を行った。これによりデータ収集の手法や今後の問題点が明確となった。

以下に今後の展開について示す。

6.1 教師データのふるい落とし

グラフで見ると両距離ともに実際の場所と反射データの間に強度の谷が存在して見える。ここを境にして必要／不要のふるい落としが出来れば正解率が大幅に上がると考えられるのでその実現を目指す。

6.2 データ幅の検証

今回は 20 回の測定値を一つの束としたが、束の数を変更して機械学習させて適切な数を探る。

6.3 機械学習の理論の考察

確率論で推測できると考えてナイーブベイズ定理を採用したが、他の理論で実施できるか考察する。

参考文献

- [1] Song Chai, Renbo An and Zhengzhong Du
An Indoor Positioning Algorithm Using Bluetooth Low Energy RSSI
(参照 2017-10-22).
- [2] Zhu Jianyong ;Luo Haiyong ; Chen Zili ; Li Zhaohui
RSSI based Bluetooth low energy indoor positioning
(参照 2017-08-06).
- [3] Jea-Gu Lee¹, Byung-Kwan Kim¹, Sung-Bong Jang², Seung-Ho Yeon¹ and Young Woong Ko¹
Accuracy Enhancement of RSSI-based Distance Estimation by Applying Gaussian Filter
(参照 2017-08-06).
- [4] 杉野 恭兵 大園 忠親 新谷 虎松
複数の Bluetooth ビーコンに基づくデバイスフリーな屋内測位におけるキャリブレーションについて
(参照 2017-09-03).
- [5] 中島尚紀 湯素華 大岸智彦 小花貞夫
複数ウェアラブルデバイスの併用による BLE を用いた室内位置測位精度
(参照 2017-09-03).