

## BLE ビーコンの電波強度を用いた屋内測位のための機械学習モデルの提案

猪股 一步希<sup>†</sup> 堀川 三好<sup>‡</sup> 岡本 東<sup>‡</sup>岩手県立大学 ソフトウェア情報学部 ソフトウェア情報学科<sup>†‡</sup>

## 1. はじめに

近年、歩行者ナビゲーションや広告配信等、屋内測位を活用した様々なサービス導入が進んでいる。しかしながら、測位精度や導入コストに課題を残しており、新たな測位手法の開発が求められている。

本研究は、BLE ビーコン（以降、ビーコン）の電波強度を観測し、機械学習により近接判定を行う測位手法を提案する。本稿では、複数の機械学習モデルを取り上げ、近接判定の精度を比較検討する。また、比較検討した機械学習モデルの中で最も良い精度であった畳み込みニューラルネットワーク（以降、CNN）を用いたモデルをスマホアプリに実装し、動作検証した結果を報告する。

## 2. 関連研究

電波強度を用いる測位手法は、ナビゲーション等に用いられる座標測位型、在室判定等に用いられるエリア判定型および広告/クーポン配信等に用いられる近接検知型に大別できる。ビーコン測位は、近接検知型測位を得意としており、電波強度に閾値を設ける導入事例が多い。先行研究 [1] では、測位精度向上のため、複数ビーコンの電波強度を統計的検定により近接判定を行う手法を提案した。また、座標測位型として導入事例が多いフィンガープリント方式 [2] は、測位環境内の電波強度を事前計測（学習）し、観測した電波強度とマッチング（推定）する方式である。この方式は、高精度な測位が可能であるが学習には測位環境内の計測が必要となり、負荷低減が課題となる。

## 3. 近接判定手法

## 3.1 提案手法の概要

本稿では、近接検知型の機械学習を用いた測位手法を提案する。提案手法では、設置されているビーコンの電波強度を観測し「近接している」「接近している」「離脱している」「遠隔に




図1 距離と電波強度の関係




図2 観測された電波強度と正解ラベル

る」の4つの行動状態を機械学習により分類する。iBeacon では、Immediate/Near/Far/Unknown を距離として把握可能であるのに対し、所持者の行動把握を目的とした分類を目指す。すなわち、フィンガープリント方式における学習で機械学習モデルを生成し、推定を機械学習による分類を行う方式となる。

## 3.2 電波強度の特性

電波強度は、障害物のない自由空間において電波送信機と受信機間の距離に応じて送信機を中心とする球の表面積に反比例しながら値が減衰する。しかしながら、屋内環境における計測では、マルチパスフェージングやシャドウウィング等の変動要因により、図1のように実測値は変動する。そのため、これらの変動要因に対応できる測位手法を適用する必要がある。

## 3.3 データセット

機械学習モデルの検討を行うにあたり、データ収集を行う。自遊空間にビーコンを設置し、10m先からビーコンに接近後に近接する。その後、元の場所に戻る行動を6往復繰り返し、図2のような正解ラベルを持つデータを訓練用に2582件、検証用に2490件、テスト用に1587件取得した。収集データを訓練とテスト用に8:2の割合で分割する。ここで、汎用性のあるデータセットを作成するため、各行動状態において滞在、行動時間を変化させた。また、データのサンプリング長は（以降、窓長）は、3.5秒とした。

### 3.4 機械学習モデルの検討

まず, scikit-learn の all estimator 機能を用いて SVM, 決定木, 決定木を応用した複数モデル等の分類器から全探索を行った. その結果, 勾配ブースティング (HGB) が最も精度が高い結果となった. 併せて, 全結合ニューラルネットワーク (FNN), ディープラーニング (CNN), および Wave Net (WN) について比較検証を行う.

HGB: 決定木において勾配を考慮してグラフを更新するモデル.

FNN: 入力された値に重み行列を乗算し, バイアスペクトルを加算するモデル. 単純モデルでどのくらいの精度が出るか比較のため検討する.

CNN: 畳み込みノードを意味する Dilated Causal Convolution を考慮したモデルとする. 観測された電波強度から各ラベルの特徴が現れているため検討する.

WN: 電波強度のデータが音声データの波形と類似しているため検討する.

### 4. 機械学習モデルの比較検証

#### 4.1 実験方法

実験用ビーコンとして, 株式会社イーアールアイ製の BLU250H を用いる. また, 電波強度の計測用に Android アプリを制作した. 機械学習の構築は Jupyter Lab および Tensorflow を用いて行い, 精度評価は F 値 (適合率と再現率の調和平均) で行う.

#### 4.2 実験結果

各機械学習モデルの精度評価を表 1 に示す. CNN が最も高い結果であるため混合行列を図 3 に示す. 試作したモデルは 7 層構造である. 5×1 のフィ

表 1 学習モデルの精度比較 (F 値)

	HGB	FNN	CNN	WN
近接	0.82	0.88	0.93	0.88
遠隔	0.92	0.92	0.93	0.86
接近	0.88	0.87	0.85	0.81
離脱	0.80	0.84	0.88	0.80



図 3 CNN における混合行列




図 4 精鋭度検証における実験結果

ルタで畳み込みを行い, 64 枚の特長量マップを得る. この動作を 4 度繰り返しマックスプーリングによりサイズを小さくする. これを二層続きの全結合に渡してソフトマックス関数を用いた出力層で出力する.

### 5. 近接判定アプリによる精度検証

#### 5.1 実験目的および方法

学習モデルの比較検証において最も精度がよい CNN による学習モデルを適用した近接判定アプリを開発し, 実環境での近接判定が行えるかどうかを検証する. 学習済みの CNN モデルを Tensorflow Lite に変換し Pixel4 (Android) にて実験を行う. 実験条件は, 3.3 節に述べた環境と同様にする.

#### 5.2 実験結果

実験結果を図 4 に示す. 機械学習の分類処理においては, スマホの GPU を用いた場合は平均 4.66ms なのに対し, CPU を用いた場合は 11.17ms であった. また, 学習データ収集時と実験時で電波強度が大きく異なる事象が見られた際には, 近接検知がうまくできない場合も見られた. 今後, 電波強度を基準化する等の工夫も必要であるが, 全体での F 値は 0.89 と電波強度の変移から 4 つの状態推定が可能であることがわかった.

### 6. おわりに

本稿では, ビーコンの電波強度を観測し機械学習を用いて近接検知する手法を提案しアプリにて動作検証をした. この仕組みは, 近接判定の測位に限らず, センサを用いない電波強度の変移による行動分析への拡張も可能であると考えられる.

### 参考文献

- [1] D. Kudo, M. Horikawa etc.: "Indoor Positioning Method Using Proximity BLE Beacon", 17th APIEMS Conference, (2016)
- [2] 谷内大祐他: "位置フィンガープリントの自動更新を用いた電波環境変化に頑健な屋内位置推定手法", 情報処理学会論文誌, Vol. 55, No. 1, pp. 280-288, (2014)