

# 頑健な屋内位置推定のための時間的・空間的特徴を利用した Wi-Fi 受信信号のノイズ除去と欠損値補間に関する検討

村上 健太<sup>1</sup> 前川 卓也<sup>1</sup> 原 隆浩<sup>1</sup>

**概要:** 近年, Wi-Fi 受信信号情報を用いた携帯端末の屋内位置推定手法に関する研究が盛んに行われている。最も一般的な屋内位置推定手法は Wi-Fi フィンガープリンティングと呼ばれており, 環境内の各地点で長時間静止して Wi-Fi 受信信号を取得することで, 各地点における固有の Wi-Fi 受信信号情報を格納したラジオマップを作成する。そして, 未知の地点で取得された Wi-Fi 受信信号情報とラジオマップ内の各地点の Wi-Fi 受信信号情報を比較することで位置を推定する。しかし, 歩行中のある時点で取得されたノイズや欠損が多く含まれる Wi-Fi 受信信号を位置推定に用いると位置推定精度が大きく低下してしまう問題がある。そこで, 本研究では, ニューラルネットワークを用いて歩行中に取得された Wi-Fi 受信信号のノイズ除去と欠損値補間を行うことで, Wi-Fi フィンガープリンティングを用いた頑健な屋内位置推定を行う手法を提案する。ノイズ除去と欠損値補間を行うニューラルネットワークモデルは, 対象とは異なる環境で事前に学習したものを用いるため, 対象とする環境の学習データを取得する必要がない。評価実験では, 3つの環境で観測されたデータを用いて提案手法の有効性を確認した。

## 1. はじめに

近年, ネットワークアクセスを提供する Wi-Fi アクセスポイントは一般家庭, 駅, ショッピングモールなど, 多くの施設に普及している。また, スマートフォンなどの Wi-Fi 信号による無線通信が可能な端末も急速に普及しており, どこでも容易に Wi-Fi の無線通信サービスを利用できる環境になりつつある。それに伴い, Wi-Fi 受信信号情報を用いた屋内位置推定サービスに関する研究が数多く行われており, ショッピングモールや博物館などの屋内施設でのナビゲーションや, 子供, 高齢者の居場所を管理する見守りサービスなど, 様々なアプリケーションへの応用が期待されている [3], [9]。これらのアプリケーションの実現には, 数メートル以内の位置推定精度が必要となり, 屋内位置推定に関する研究の多くは, 位置推定精度の向上が課題となっている。

Wi-Fi 受信信号情報を用いた屋内位置推定の手法の1つに, Wi-Fi フィンガープリンティング [13], [14], [23], [24] がある。Wi-Fi フィンガープリンティングはオフラインフェーズとオンラインフェーズの2段階で行われる。オフラインフェーズでは, 位置推定を行う環境において, あらかじめ様々な場所で Wi-Fi 受信信号情報 (信号強度や Wi-Fi アクセスポイントの SSID など) を観測して記録し,

その環境のラジオマップを作成する。オンラインフェーズでは, 環境内の未知の場所で Wi-Fi 信号を観測し, 観測された信号情報とあらかじめ作成しておいたラジオマップの信号情報を照合し, Wi-Fi 信号を受信した位置を推定する。この手法は Wi-Fi 信号の伝播の特徴を確率分布や分類きを用いて容易にモデル化することができ, 比較的精度が高いことから多くの既存研究で用いられている。しかし, この手法を用いるにあたって問題となるのが Wi-Fi 信号の不安定性である。

Wi-Fi 信号はマルチパスやフェージングによる観測データの欠損や, その他の無線信号による干渉など, 環境による影響を受けやすく, このノイズが位置推定の精度に大きな影響を与える。そこで, 位置推定の精度を改善するために様々な手法が提案されてきた。多くの既存研究では, 各地点に長時間静止してデータを収集し, 収集したデータの平均値をとることによってノイズを除去している [13], [14]。しかし, ナビゲーションのようなアプリケーションへの応用を考えた場合, 1つの場所に長時間静止している状況ではなく, 歩行しながらの位置推定が必要となる。歩行中のある時点でのみ観測されたデータを用いて位置推定を行う際, 1つの地点で長時間静止して収集したデータのみで学習されたラジオマップを用いると, 精度の低下につながる。そこで, 本研究では歩行中に取得した Wi-Fi 信号情報を用いて, その場所に長時間静止して収集された平均化デー

<sup>1</sup> 大阪大学大学院情報科学研究科

タと同様のデータを推定する。これにより、長時間同じ場所に静止して収集したデータの平均値で作成されたラジオマップをそのまま歩行時のデータの推定に利用できる。提案手法では、歩行中のノイズや欠損を多く含んだ Wi-Fi データから、それらを含まない潜在的な特徴を学習することで、ノイズの除去および欠損値の補間を行う。

多くの既存研究では、Wi-Fi 受信信号強度の欠損値を最低値 (-100dBm) で補間している [2]。この手法では各観測地点における信号強度ベクトルのサイズを保持することはできるが、位置推定時の情報としては役に立たない。しかし、環境内の Wi-Fi アクセスポイント数が少ない状況では 1 つの値が位置推定の精度に大きな影響を与えることがある。そこで、本研究では取得した Wi-Fi 信号のノイズ除去と同時に欠損値を推定し、補間を行う。ノイズ除去と欠損値補間を実現するために、本研究では以下の 2 つの仮説に基づいて手法設計を行う。

- 位置推定を行う時刻  $t$  において、ある Wi-Fi アクセスポイントからの受信信号強度は、同じアクセスポイントからの時刻  $t$  以前の受信信号強度の推移の傾向に大きく関係があると考えられる。例えば、同じアクセスポイントからの受信信号強度が減少傾向にあれば、時刻  $t$  の信号強度は時刻  $t$  以前から減少するはずである。このように、以前の観測の結果は信号強度推定の手掛かりになる。
- 異なる場所に位置する Wi-Fi アクセスポイントからの Wi-Fi 受信信号強度には相関関係が存在する。例えば、近い位置に設置されている 2 つのアクセスポイントからの Wi-Fi 受信信号強度は同じような変化の傾向が見られるはずである。よって、アクセスポイント間の Wi-Fi 信号情報の相関関係から欠損値を補間し、大きなノイズを除去することが可能である。

提案手法では、上記の仮説をもとに教師あり学習のアプローチを用いて、歩行中に得られた Wi-Fi 信号強度のノイズ除去と欠損値補間を行い、得られたデータを用いて位置推定を行う。また、トレーニングデータとテストデータをそれぞれ異なる環境で取得して実験を行うことで、環境に依存しないノイズ除去システムを目指す。これによって、新しい環境ではラジオマップを作成するだけで頑健な位置推定が可能となる。

本稿の構成は以下の通りである。まず、2 節では Wi-Fi 受信信号情報を用いた屋内位置推定や、データのノイズ除去などに関する関連研究を紹介する。3 節では、歩行中に取得した Wi-Fi 受信信号情報のノイズ除去と欠損値補間や位置推定を行う提案手法について詳しく説明する。4 節では、提案手法の検証実験を行い、その結果について報告する。最後に、5 節で本研究のまとめを行う。

## 2. 関連研究

Wi-Fi アクセスポイントやスマートフォンなどの Wi-Fi 信号を受信可能なデバイスの普及により、Wi-Fi 受信信号情報を用いた屋内位置推定に関する多くの研究が行なわれている。特に Wi-Fi 信号のノイズに対する不安定性が位置推定精度を低下させる問題となっており、多くの研究の課題となっている。本研究でも、Wi-Fi 信号のノイズを除去することで頑健な屋内位置推定を目指すため、Wi-Fi 受信信号情報を用いた屋内位置推定や Wi-Fi 受信信号情報のノイズ除去に関する既存研究を紹介する。

### 2.1 Wi-Fi 受信信号情報を用いた屋内位置推定

Wi-Fi 受信信号情報を用いた屋内位置推定の手法としてはレンジベース方式 [8], [21] とレンジフリー方式 [12] がある。レンジベース方式では、位置の分かっている Wi-Fi アクセスポイントから受信した Wi-Fi 信号の到来時刻、到来時間差、受信信号強度からアクセスポイントと信号受信地点との距離を計算する。これを三箇所以上のアクセスポイントについて行うことによって、三角測量で位置を推定するという手法である。この方式では、取得した情報をそのまま計算に用いて位置推定を行うため、容易に実装することができる。しかし、ノイズやデバイス変化に対して信号の伝播は非常に不安定であるために、位置推定精度も不安定である。また、三辺測量を行うためには位置の分かっている Wi-Fi アクセスポイントを配置する必要があるため、追加のデバイスが必要となることも多い。一方、レンジフリー方式では Wi-Fi 信号の信号強度のみを用いるため、Wi-Fi アクセスポイントの位置情報は必要としない上、レンジベース方式による位置推定よりも一般的に精度が高いと言われている [2]。

レンジフリー方式で一般的に用いられている手法に RSSI フィンガープリンティング [13], [14], [23], [24] がある。RSSI フィンガープリンティングは、オフラインフェーズとオンラインフェーズの 2 段階に分けて行われる。オフラインフェーズでは、位置推定を行いたい環境において、Wi-Fi 受信信号情報（受信信号強度 (RSSI) や Wi-Fi アクセスポイントの SSID など）を測定し、各座標における固有の Wi-Fi 受信信号情報（フィンガープリント）として記録する。これを様々な場所で行うことで、その環境の Wi-Fi 信号の伝播情報を捉えたラジオマップを作成する。オンラインフェーズでは、未知の場所で観測された信号情報と、あらかじめオフラインフェーズで作成しておいたラジオマップにおける信号情報を照合し、最適な位置を推定する。本研究でも Wi-Fi フィンガープリンティングを用いた屋内位置推定を行う。

## 2.2 ノイズ除去手法

本研究では歩行中に取得した Wi-Fi 受信信号のノイズ除去と欠損値補間を行う。本節では、Wi-Fi 受信信号を用いた屋内位置推定の既存手法でも用いられているノイズ除去手法を紹介する。

### 2.2.1 Denoising Autoencoder (dA)

Autoencoder とは、入力データそのものを教師データとして教師あり学習を行う 3 層の Neural Network のことである。Autoencoder を用いて、データの次元を圧縮してから出力と入力を近づけるように復元することで、頑健なデータの特徴抽出を行う。Denoising Autoencoder (dA) [18] では、入力にノイズを付与し、出力を計算する。そして、誤差関数にノイズを付与する前の入力を用いることで、オリジナルデータを復元するように学習を行う。これによって、Autoencoder よりも頑健な特徴抽出が可能となり、未知のデータに対する汎化性能を高めることができる。

### 2.2.2 Stacked Denoising Autoencoder (SdA)

Stacked Denoising Autoencoder (SdA) [19], [22] は、Denoising Autoencoder を層ごとに学習し、多層に積み重ねて構築した Deep Neural Network の一つである。学習は Pre-training と呼ばれる教師なし学習と Fine-tuning と呼ばれる教師あり学習の 2 段階で行う。まず、SdA の各 dA の層の入力に近い dA から、中間層の出力を次の dA の入力として用いて Pre-training を行う。そして、全体を一つの dA とみなして Fine-tuning を行う。SdA は深い層ほどより抽象的な表現を獲得すると考えられているが、層数が増えるほど学習にかかる時間も増えるので、最適なパラメータを決定することが重要となる。

Abbas ら [2] は、Wi-Fi 受信信号強度のノイズに頑健な特徴抽出を行うために、Wi-Fi 信号のノイズが発生しやすい次の二つの状況を想定、ノイズを付与した SdA による特徴抽出を行っている。

- マルチパスやフェージングによる、ある Wi-Fi アクセスポイントからのデータの欠損を表現するために、一定の確率である要素が 0 になるようなバイナリベクトルを入力データに掛け合わせる。
- デバイスによって搭載されている Wi-Fi 受信チップが異なることによる Wi-Fi 受信信号強度の変化を表現するために、ガウシアンノイズを加える。

このように、実際に起こりうるノイズを人工的に作り出して、そのノイズを除去するような特徴抽出を学習させることで、実際のテストデータでノイズが発生しても精度が低下しない頑健な特徴抽出を行っている。本研究では、頑健な屋内位置推定を行うために、取得した RSSI からノイズを除去するような機械学習を行う。

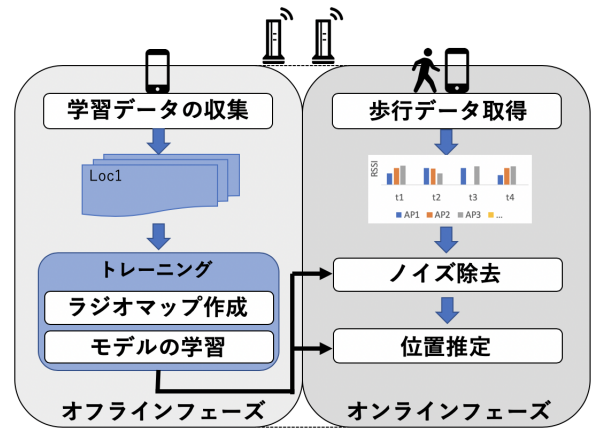


図 1: 提案手法の概要

## 3. 提案手法

### 3.1 提案手法の概要

提案手法の概要を図 1 に示す。本研究では、データの収集から位置推定までをオフラインフェーズとオンラインフェーズの二段階で行う。オフラインフェーズではラジオマップの作成と Wi-Fi 受信信号情報信号のノイズ除去と欠損値補間のための Neural Network モデルの学習を行う。オンラインフェーズでは位置推定を行う環境内で歩行しながら Wi-Fi 受信信号情報を収集し、オフラインフェーズで学習したモデルを用いてノイズ除去と欠損値補間を行ったデータを推定する。そして、推定したデータとラジオマップから位置推定を行う。オフラインフェーズの Neural Network モデルでは Wi-Fi 信号時間する二つのアイデアを用いた設計をおこなうため、この二つのアイデアが実際に利用できるかを事前に検証する。

### 3.2 事前検証

提案手法のモデルでは、Wi-Fi 受信信号情報に関する 2 つの特徴から欠損値補間とノイズ除去を行う。その特徴が実際に利用できるかどうか、事前検証を行った。図 2 に、歩行中に連続的に RSSI を取得し Wi-Fi アクセスポイントごとに RSSI の時系列データを可視化したものを示す。図 2 では、RSSI の変化の傾向をわかりやすくするために近似曲線を表示した。また、RSSI の欠損値は RSSI の最低値 (-100dBm) で補間した。

#### 3.2.1 時間的連続性の検証

歩行中に連続で取得された同じ Wi-Fi アクセスポイントからの RSSI は、同じアクセスポイントから受信した RSSI の変化の傾向に基づいて変化するはずである。例えば、アクセスポイントから遠ざかるように移動すると RSSI は減少し、アクセスポイントに近づくように移動すると RSSI は増加する。図 2 より、RSSI は変化の傾向を持っていることがわかる。したがって、提案手法では、RSSI のノイズ

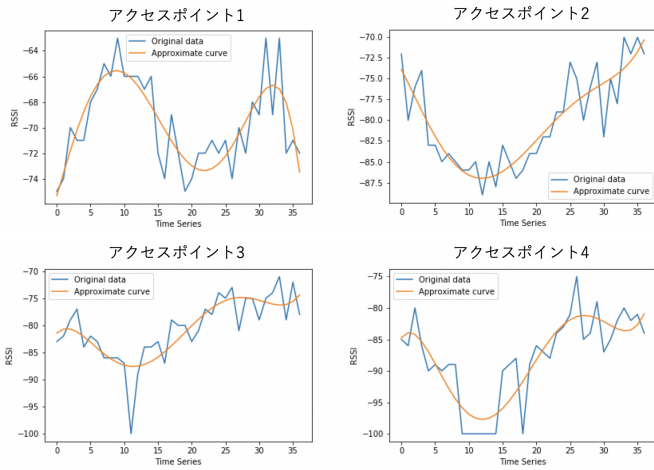


図 2: 4 つの AP から連続で観測された RSSI

除去と欠損値補間に、同じアクセスポイントからの RSSI 時系列データの変化の傾向を利用する。

### 3.2.2 AP 間の RSSI 変化の相関関係の検証

異なる場所に位置する Wi-Fi アクセスポイントからの RSSI には相関関係が存在する。例えば、近くに設置されている 2 つのアクセスポイントからの RSSI には同じような変化の傾向が見られるはずである。図 2 より、アクセスポイント 3 とアクセスポイント 4 の RSSI は同じような変化の傾向を持っていることが見て取れる。したがって、提案手法では、異なるアクセスポイントの RSSI の相関を求め、相関の高いアクセスポイントの RSSI を利用したノイズ除去と欠損値補間を行う。

## 3.3 オフラインフェーズ

### 3.3.1 ラジオマップの作成

位置推定を行いたい環境の Wi-Fi 信号の伝播の特徴を捉えるために、各地点における Wi-Fi 信号の特徴を記録したラジオマップを作成する。本研究では、Wi-Fi 受信信号情報として Wi-Fi 受信信号強度 (RSSI) と Wi-Fi アクセスポイントの BSSID を用いる。ラジオマップを作成するために、環境内の均等な地点で約 1 分間静止し、一定のサンプリングレートで Wi-Fi 受信信号情報を記録する。Wi-Fi 信号のノイズや欠損に対処するため、同じ地点で長時間静止して取得した多数のデータを正規分布としてモデル化する。すなわち、それぞれのアクセスポイントからの RSSI の平均と分散を求める。Wi-Fi アクセスポイントの BSSID, RSSI の平均値と分散を Wi-Fi 受信信号情報としてデータ取得地点の座標とともにラジオマップに記録する。

### 3.3.2 RSSI のノイズ除去と欠損値補間を行うモデルの設計と学習

不安定な Wi-Fi 信号の潜在的な特徴を捉えるために、3.2 節で検証を行った、Wi-Fi 信号の RSSI に関する二つの特




図 3: RSSI のノイズ除去/欠損値補間を行うモデル構造

徴に基づいたモデルの設計を行う。

- 歩行中に連続で取得された、ある Wi-Fi アクセスポイントからの時刻  $t$  の RSSI は、同じアクセスポイントから受信した時刻  $t$  以前の RSSI の変化の傾向に依存する。例えば、同じアクセスポイントからの時刻  $t$  以前の RSSI が減少傾向にあれば、時刻  $t$  の RSSI は以前の時刻から減少している可能性が高い。RSSI の変化パターンは歩行の方向とアクセスポイントの位置との関係によって様々なパターンが存在する。これらの RSSI の変化パターンの時間的な特徴をノイズの除去と欠損値の補間に利用するため、Long Short-Term Memory (LSTM) [15] を用いる。
- 異なる場所に位置するアクセスポイントからの RSSI には相関関係が存在する。例えば、近くに設置されている 2 つのアクセスポイントからの RSSI には同じような変化の傾向が見られるはずである。つまり、環境内の異なる複数のアクセスポイントにおける RSSI の相関関係から RSSI を補間可能である。このようなアクセスポイント間の RSSI の相関関係を利用するため、Matrix Factorization (MF) [7] を用いる。

図 3 に LSTM と MF の二つの手法を組み合わせた提案モデルの概要図を示す。モデルの入力は、歩行中に連続的に取得された複数のアクセスポイントからの RSSI を用いる。LSTM は中間層として用い、MF で補間したものと LSTM の中間層を FC 層で合成して各時刻、各アクセスポイントの RSSI を出力とする。提案モデルでは、歩行時のある時点で得られたデータをその地点で長時間静止した平均化データに近づけるような学習を行うことで、ノイズ除去と欠損値補間を行う。以下に提案手法で用いる LSTM と MF の構造、提案手法の学習方法の詳細を述べる。

### 3.3.3 LSTM を用いたノイズ除去と欠損値補間

歩行とアクセスポイントの位置の関係によって RSSI 時系列データに現れる変化のパターンを学習する。LSTM は時刻  $t$  と時刻  $t$  以前の時系列データから、時刻  $t$  の値のノイズ除去と欠損値補間を行う。LSTM の入力データには、アクセスポイントごとに、ノイズ除去と欠損値補間を行う時刻  $t$  のデータと、時刻  $t$  以前の連続する時系列データを用いる。また、同じ時刻に取得された相関の高いアクセスポイントの RSSI を同時に入力することで、他のアクセス




図 4: MF による欠損値補間

ポイントの RSSI 時系列データの変化パターンも利用する。ただし、LSTM は時間的な特徴を学習するため、過去の時系列データが多数欠損しているものは入力データから除く。ノイズ除去と欠損値補間を行う時刻  $t$  の各アクセスポイントの RSSI を LSTM の出力とし、FC 層へ入力する。

LSTM で相関の高いアクセスポイントの RSSI を同時に入力するため、事前にアクセスポイント間の RSSI の相関関係を求める。各アクセスポイントの RSSI の時系列データから、全てのアクセスポイントの組み合わせに関する相関行列を作成する。各アクセスポイントについて相関が上位のいくつかのアクセスポイントの RSSI を選択し、共に入力として用いる。

### 3.3.4 MF を用いた欠損値の補間

歩行中に取得した Wi-Fi 受信信号情報の欠損値補間を行うために MF を用いる。MF はランダムでない行列を分解、復元することで欠損値の補間が可能となる。本研究では、アクセスポイント間の空間的な配置による RSSI の相関関係を利用した欠損値の補間を行う。図 4 のように、取得データから行をアクセスポイント、列を時系列とした行列を作成する。アクセスポイント間の RSSI の相関関係を捉えた特徴の次元圧縮を行い、行列を復元することで、各時刻における RSSI の欠損値を補間する。MF では取得 RSSI の欠損値のみを補間し、欠損していなかった値は置き換えない。提案モデルでは、欠損値の補間を行った RSSI から、ノイズ除去と欠損値補間を行う時刻  $t$  の各アクセスポイントの RSSI を FC 層へ入力する。

### 3.3.5 提案モデルの学習方法

提案モデルの入力には歩行中に連続的に取得された RSSI を用いる。上記の通り、LSTM には注目するアクセスポイントとその相関の高いアクセスポイントに関する時刻  $t$  と、時刻  $t$  以前の連続するいくつかの時系列データを入力に、MF には取得 RSSI をそのまま入力に用いる。LSTM の入力には、欠損している RSSI については RSSI の最低値 (-100dBm) で補間する。また、アクセスポイントごとに RSSI のスケールが異なるため、学習データ全体の平均が 0、分散が 1 となるような標準化を行い、学習データの RSSI のスケールを統一する。モデルで推定を行う RSSI について、時刻  $t$  とそれ以前の RSSI が入力する時系列データの長さに対して欠損が多い場合には推定が困難であると考え、学習データから除く。

図 3 のように MF と LSTM のそれぞれの出力を FC 層

へ入力し、FC 層の出力によりノイズ除去と欠損値補間を行う時刻  $t$  の各アクセスポイントの RSSI を推定する。モデルの教師データとしては、時刻  $t$  のデータ取得位置で長時間静止し、取得されたデータを平均化した RSSI を用いる。損失関数には二乗平均平方根誤差 (RMSE) を、最適化手法には Adam Optimizer を用い、Adam Optimizer によって推定値と教師データの RMSE が小さくなるように繰り返し学習することで、推定値と教師データが近づくような学習を行う。これによって、歩行中に得られたデータから、その位置に長時間静止して平均化を行ったような値を推定するモデルの学習を目指す。

RSSI の時間変化の傾向や、AP の空間的な配置によって現れる相関関係は環境によらず、似たような傾向が現れるはずである。本研究では、ノイズ除去と欠損値補間を行いたい環境とは異なる複数の環境のデータを学習に用いることで、環境に依存しないモデルの獲得を目指す。このように、モデルを事前に学習しておくことで、実際に位置推定を行う環境では学習データの取得が必要なくなり、ラジオマップの作成のみで頑健な位置推定を行うことが可能となる。

## 3.4 オンラインフェーズ

オンラインフェーズでは、位置推定を行う環境内で歩行中に連続して観測された Wi-Fi 受信信号情報を用いる。歩行中の各時刻の Wi-Fi 受信信号情報に対して、オフラインフェーズで学習済みのモデルを用いてノイズ除去と欠損値補間を行った値を推定する。最後に、推定した Wi-Fi 信号情報とその環境のラジオマップを用いて位置推定を行う。

### 3.4.1 RSSI のノイズ除去と欠損値補間

オフラインフェーズで学習済みの提案モデルを用いたノイズ除去と欠損値補間を行う。LSTM の入力のため、取得データの各アクセスポイントに関して相関行列を作成する。そして、注目するアクセスポイントとその相関の高いアクセスポイントに関する時刻  $t$  と、時刻  $t$  以前の連続するいくつかの時系列データをモデルの入力とする。RSSI の欠損値に関しては、学習時と同様に最低値 (-100dBm) で補間を行う。また、RSSI のスケールを学習データと揃えるため、学習データの標準化の際に求めた平均と標準偏差を用いて標準化を行う。MF の入力には取得データをそのまま用いる。このような入力を行うことによって、各時刻の取得 RSSI のノイズ除去と欠損値補間を行う。

### 3.4.2 位置推定

ノイズ除去と欠損値補間を行なった Wi-Fi 受信信号情報とラジオマップの Wi-Fi 受信信号情報を比較し、その類似性からデータの取得位置を推定する。本研究では、Wi-Fi 受信信号情報からラジオマップの各トレーニングポイントに対する存在確率を求める。そして存在確率が上位のトレーニングポイントの座標の重み付き平均を求め、推定位置座標とする [23], [24]。

表 1: データ取得環境サイズと観測された AP 数

	環境サイズ		AP 数	
	縦 (m)	横 (m)	総数	欠損 80%以下
環境 1	11.84	27.50	245	39
環境 2	11.01	18.36	156	56
環境 3	14.85	16.34	242	45

表 2: 歩行中に取得した Wi-Fi 受信信号の数の

	TP 上	非 TP 上	総数
環境 1	127	171	298
環境 2	60	203	262
環境 3	309	201	510




図 5: 環境 1 のトレーニングポイント

$M$  個の Wi-Fi アクセスポイントから取得した RSSI ベクトルを  $x = (x_1, \dots, x_M)$  とする. ラジオマップの  $n$  番目のトレーニングポイントに対する, アクセスポイント  $i$  の RSSI の平均と分散をそれぞれ  $\mu_{i,n}$ ,  $\sigma_{i,n}^2$  とすると, アクセスポイント  $i$  に関するラジオマップの  $n$  番目のトレーニングポイントの分布確率は, 正規分布の確率密度関数より,

$$f_i(x_i, \mu_{i,n}, \sigma_{i,n}^2) = \frac{1}{\sqrt{2\pi\sigma_{i,n}^2}} \exp\left(-\frac{(x_i - \mu_{i,n})^2}{2\sigma_{i,n}^2}\right) \quad (1)$$

となる. 全てのアクセスポイントに関する分布確率の総和より, トレーニングポイント  $n$  に対する存在確率は,

$$f(x, n) = \sum_{i=1}^M f_i(x_i, \mu_{i,n}, \sigma_{i,n}^2) \quad (2)$$

と求めることができる. これをラジオマップの全てのトレーニングポイントに対して求める.  $n$  番目のトレーニングポイントの座標を  $l_n$  とすると, 存在確率が上位  $k$  個のトレーニングポイントの座標に関する重み付き平均は,

$$l = \sum_{n=1}^N f(x, n) l_n \quad (3)$$

となり, 求めた  $l$  を推定位置座標とする.

## 4. 評価実験

### 4.1 データセット

筆者の所属する大学内の 3 つの環境でデータセットの取得を行った. 各環境のマップを図 5 ~ 7 に示す. それぞれの環境サイズの情報は表 1 に示す. 本研究では, Wi-Fi アク




図 6: 環境 2 のトレーニングポイント

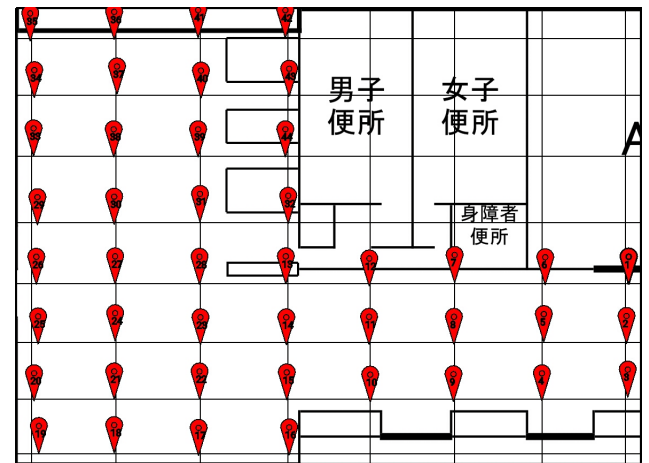


図 7: 環境 3 のトレーニングポイント

セスポイントは環境内に元々存在しているものを, Wi-Fi 信号情報の取得には Android スマートフォン (Google Nexus 6P) を用いた. Wi-Fi 受信信号情報としては, Wi-Fi 受信信号強度 (RSSI), Wi-Fi アクセスポイントの BSSID, タイムスタンプを取得した.

#### 4.1.1 長時間静止したデータの取得

ラジオマップを作成するため図 5 ~ 7 の赤いマーカの各トレーニングポイントで約 1 分間静止し, データの取得を行った. そして, 取得した RSSI の平均値と分散を求め, データ取得地点の座標と共に記録した. 環境 1 のトレーニングポイントにおいて, あるアクセスポイントからの RSSI の平均値を可視化したものを図 8 に示す.

図 8 より, アクセスポイントの配置によって, 信号強度が大きい位置があり, そこから離れるにつれて信号強度は減少している. 本研究では, このような各環境におけるアクセスポイントごとの Wi-Fi 信号の伝播傾向を利用した位置推定を行う.

#### 4.1.2 歩行中のデータの取得

3.3 節で述べたように, ノイズ除去と欠損値補間を行う提案モデルでは, 歩行中にデータを取得したある地点のデータを対象とし, その地点に長時間静止して取得したデータを平均化した値を教師データとして学習を行う. そこで,

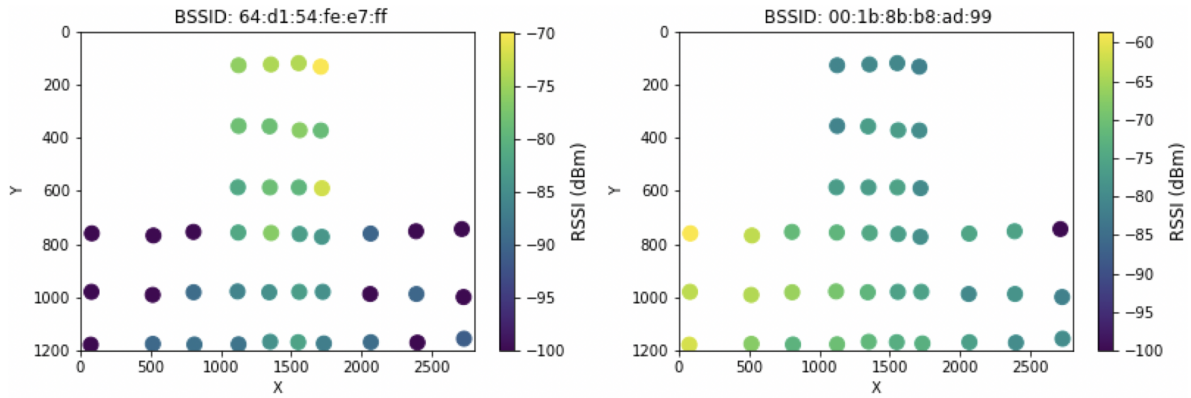


図 8: 環境 1 のあるアクセスポイントからの Wi-Fi 信号強度情報. 縦軸と横軸の単位は cm.

表 3: RSSI の推定誤差 (dBm)

	最低値	MF	LSTM	提案手法
環境 1	12.03	7.72	<b>6.50</b>	6.56
環境 2	7.71	6.69	6.31	<b>6.25</b>
環境 3	15.81	10.37	9.69	<b>9.58</b>
平均	11.85	8.26	7.50	<b>7.46</b>

表 4: 位置推定誤差 (cm)

	最低値	MF	LSTM	提案手法
環境 1	618.33	616.67	431.56	<b>401.30</b>
環境 2	<b>456.54</b>	523.53	486.60	479.67
環境 3	682.73	614.63	<b>501.67</b>	502.92
平均	585.87	584.94	473.28	<b>461.30</b>

歩行データを取得する際には 4.1.1 節で取得したトレーニングポイント上を通るようにランダムな歩行を行った。歩行中に観測された Wi-Fi 受信信号情報の内、トレーニングポイント (TP) 上で観測されたものの数は表 2 通りである。トレーニングポイント上を通過した時刻と、それ以前の時系列データを入力データとし、そのトレーニングポイントで長時間静止して観測した信号強度の平均値を教師データとした。

各環境で観測された Wi-Fi アクセスポイント数は表 1 の通りである。ただし、各環境で観測された全ての信号情報の内欠損 (未観測) の割合が 80% 以下のアクセスポイントのみ用いた。

## 4.2 評価方法

評価実験では、提案手法による RSSI のノイズ除去と欠損値補間の精度、ノイズ除去と欠損値補間を行ったデータを用いた位置推定精度の 2 つの項目で評価を行った。取得した 3 つの環境のデータの内、2 つの環境のデータで提案モデルの学習、1 つの環境のデータで精度に関する評価を行った。提案モデルの有効性を評価するために、ノイズ除去と欠損値補間に関して以下の比較手法を用意した。

- 最低値: 欠損値を RSSI の最低値 (-100dBm) で補間
- MF: 欠損値を MF 補間
- LSTM: LSTM による RSSI の推定

### 4.2.1 ノイズ除去と欠損値補間の精度

ノイズ除去と欠損値補間を行うモデルの RSSI の推定精度の評価には、モデルの学習データと同じ方法で取得したデータを用いた。すなわち、表 2 のトレーニングポイント

を通過していたデータを対象としたノイズ除去と欠損値補間を行った。歩行中に取得したデータの内、トレーニングポイント上を通過していた時刻を終点とし、それ以前の時刻を始点とする信号強度の時系列データを入力データとした。評価はモデルの出力とそのトレーニングポイントでの長時間平均化データとの誤差を用いて行った。評価指標には、誤差の絶対値の平均である平均絶対誤差 (MAE: Mean Absolute Error) を用いた。

### 4.2.2 位置推定精度

位置推定精度は、評価を行う環境の歩行中に取得した全データを用いて行った。提案手法によるノイズ除去と欠損値補間を行ったデータに対し、3.4 節で述べた位置推定手法を用いて位置推定を行った。推定した位置と、あらかじめ入力した正解座標との誤差で評価を行った。評価指標には、推定座標と正解座標とのユークリッド距離を用いた。

## 4.3 評価実験の結果

各環境ごとの評価実験を行った結果を表 3, 4 に示す。環境 1 の結果は環境 2 と環境 3 の学習データでモデルの学習を行い、環境 1 のデータで評価を行ったものである。表 3, 4 より、手法ごとの精度の平均値を比較すると、RSSI の推定誤差と位置推定誤差のどちらも提案手法が最も高い精度を達成していた。

RSSI の推定精度に関しては、表 3 より、元のデータの欠損値を RSSI の最低値で補間した手法と比較すると、全ての環境に関して RSSI は元のデータよりも平均化データに近い値を推定できていることがわかる。しかし、環境 1 に関しては、提案手法よりも LSTM のみを用いた方がわ




図 9: 環境 1 の位置推定結果の CDF

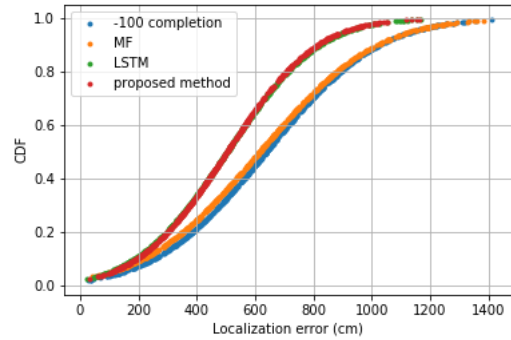


図 11: 環境 3 の位置推定結果の CDF




図 10: 環境 2 の位置推定結果の CDF

ずかに精度は高くなっていた。

各環境の累積分布確率 (CDF) を求めた結果を図 9 ~ 11 に示す。横軸が位置推定の誤差 (cm) で、縦軸が累積分布確率を表す。図 9, 11 より、環境 1 と環境 3 に関しては提案手法を用いた位置推定精度が元のデータの欠損値を最低値で補間したものよりも大幅に上昇していることがわかる。しかし、環境 2 に関しては表 4 より、提案手法は欠損値を小さい誤差で補間できているのに対し、図 10 から位置推定精度は最低値補間より低かった。環境 1 に関しては、LSTM のみを用いたものよりも提案手法の方が精度は高くなったが、環境 2, 3 では精度はほとんど変わらなかった。また表 3, 4 より、それぞれの環境において RSSI の推定精度と位置推定精度の最も精度の高かった手法が全て異なっていた。

#### 4.4 考察

ノイズ除去と欠損値補間を行う各手法における RSSI の推定結果を可視化し、評価結果の考察を行う。

各手法で出力された各地点の RSSI の推定値とその正解値及び、推定値と正解値の誤差を図 12 ~ 14 に示す。図 12 ~ 14 はそれぞれの環境について、適当な観測点を抜き出して作成した。左図が各手法で出力された RSSI で、横軸は推定対象のデータ、縦軸は各手法の出力 RSSI を表す。右図は左図の推定結果との誤差 (MAE) を表している。こ

こで、横軸のデータサンプルの並びには時系列的な関係性は存在しない。

環境 2 では提案手法が RSSI の最低値で補間した手法よりも位置推定精度が低かった。図 5 ~ 7 より、環境 1, 3 に比べて環境 2 は障害物が多く、歩行の軌跡が異なっていたことが原因として挙げられる。オフラインフェーズで学習していない RSSI の変化の特徴は捉えることができないため、環境に依存しないモデルを実現するには、様々な環境で様々な歩行軌跡で取得したデータを用いた学習を行う必要がある。

図 12 ~ 14 より、欠損値が多い場合でも、提案手法はある程度の精度で RSSI の補間ができていることがわかる。そのため、元のデータの欠損値を最低値で補間したものよりも多くのアクセスポイントに関する Wi-Fi 受信信号情報の特徴が利用可能となり、位置推定精度が向上したと考えられる。

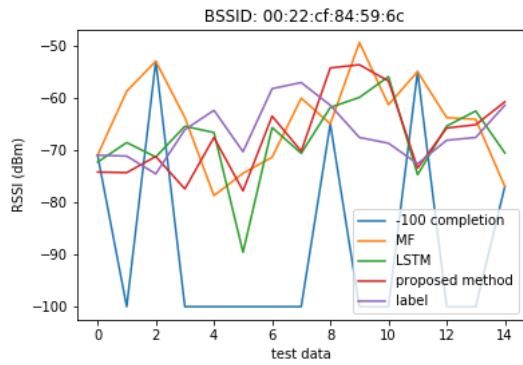
表 3, 4 より、MF のみで補間した場合の精度は他の手法と比較して低くなっている。また、提案手法と LSTM のみの結果がほとんど同じ精度になっていることから、MF が提案手法における RSSI の推定にはほとんど影響を与えていないことがわかる。この原因としては、MF の精度が低いため、図 3 の提案モデルの FC 層の入力における MF の重みが小さくなり、出力に与える影響が小さくなっているということが考えられる。

表 3, 4 より、RSSI の推定精度と位置推定精度が最も精度の高い手法は環境ごとに異なっていた。環境 1 と 3 では LSTM と提案手法の位置推定精度が最も高くなっていたが、表 3 に示す通り補間精度は大きく変わらない。環境 2 では最低値補間手法の位置推定精度が最も高くなっていたが、提案手法とは大きく変わらない。表 3 に示す通り、環境 2 では最低値補間手法と提案手法の精度の差は他の環境に比べて小さいため、提案手法における補間が位置推定精度に大きく寄与しなかったものとする。


## 5. おわりに

本研究では頑健な屋内位置推定を実現するために、機械






(a) RSSI 推定結果

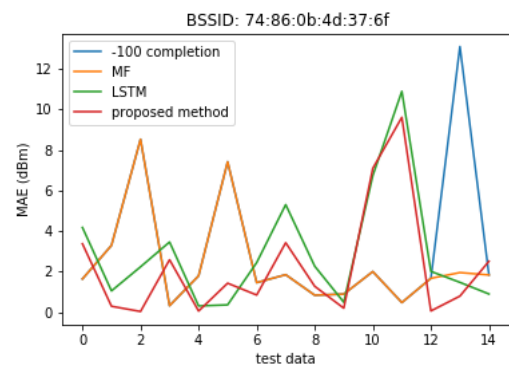


(b) の RSSI 推定誤差

図 12: 環境 1 の RSSI 推定結果とその誤差. 左図が各手法で出力された RSSI, 右図は左図の label データと各手法の RSSI との誤差の絶対値を表す. また, 横軸は推定対象のデータの観測点を表す.



(a) RSSI 推定結果



(b) RSSI 推定誤差

図 13: 環境 2 の RSSI 推定結果とその誤差. 左図が各手法で出力された RSSI, 右図は左図の label データと各手法の RSSI との誤差の絶対値を表す. また, 横軸は推定対象のデータの観測点を表す.


学習を用いて時間的・空間的特徴を利用した Wi-Fi 受信信号情報のノイズ除去と欠損値補間を行う手法を開発した. 評価実験から, 提案手法を用いることで, 最低値での単純な補間手法よりも高い精度での補間を達成し, 高精度な位置推定を行うことが可能であると確認できた. 一方で, 単純な補間手法よりも位置推定精度が低下してしまった環境も存在した. 原因として, 評価に用いた環境と学習に用いた環境の特徴が大きく異なっていたからであることが考えられる. 今後の研究課題として, 異なる様々な特徴をもった環境の学習データを用意することで, 環境に依存しないノイズ除去と欠損値補間を行うモデルを目指したい.

## 謝辞

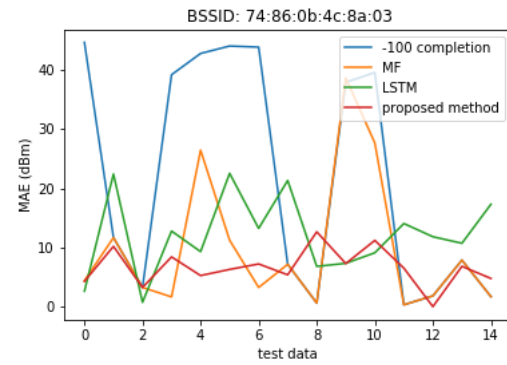
本研究の一部は JST CREST JPMJCR15E2, JSPS 科研費 JP16H06539, JP17H04679 の助成を受けて行われたものです.

## 参考文献

- [1] A.G. a and J. Schmidhuber, "Framewise phoneme classification with bidirectional LSTM and other neural network architectures," *Neural Networks*, vol.18, pp.602-610, 2005.
- [2] M. Abbas, M. Elhamshary, H. Rizk, M. Torki, M. Youssef, "Wideep: WiFi-based accurate and robust indoor localization system using deep learning," *ACM Computing Surveys*, vol.46, no.18833748, pp.2474-2503, Mar. 2019.
- [3] P. Davidson and R. Piché, "A survey of selected indoor positioning methods for smartphones," *IEEE Communications Surveys Tutorials*, vol.19, no.2, p.1347-1370, 2017.
- [4] J. Fan and J. Cheng, "Matrix completion by deep matrix factorization," *Neural Networks*, vol.98, pp.34-41, Feb. 2018.
- [5] A. Graves, N. Jaitly, and A.R. Mohamed, "Hybrid speech recognition with deep bidirectional LSTM," *Automatic Speech Recognition and Understanding*, pp.273-278, 2013.
- [6] K. Greff, R.K. Srivastava, J. Koutnik, B.R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," *IEEE Trans. Neural Networks and Learning Systems*, vol.28, no.10, pp.2222-2232, Oct. 2017.



(a) RSSI 推定結果



(b) RSSI 推定誤差

図 14: 環境 3 の RSSI 推定結果とその誤差. 左図が各手法で出力された RSSI, 右図は左図の label データと各手法の RSSI との誤差の絶対値を表す. また, 横軸は推定対象のデータの観測点を表す.

- [7] Y. Koren, R. Bell, and C. Volinsky, “Matrix factorization techniques for recommender systems,” *Computer*, vol.42, no.8, pp.30-37, Aug. 2009.
- [8] N. Lasla, M.F. Younis, A. Ouadjaout, and N. Badache, “An effective area-based localization algorithm for wireless networks,” *IEEE Trans. Computers*, vol.64, 2015.
- [9] D. Lymberopoulos and J. Liu, “The microsoft indoor localization competition: Experiences and lessons learned,” *IEEE International Conf. on Pervasive Computing and Communications (PerCom)*, vol.34, no.5, p.125–140, 2017.
- [10] E.A. Pnevmatikakis, Y.G. Daniel Soudry, R.Y. Darcy S. Peterka, and L. Paninski, “Simultaneous denoising, deconvolution, and demixing of calcium imaging data,” *Neuron*, vol.89, pp.285-299, Jan. 2016.
- [11] J.D.M. Rennie and N. Srebro, “Fast maximum margin matrix factorization for collaborative prediction,” *ICML 2005*, vol.22, pp.713-719, Aug. 2005.
- [12] J.P. Sheu, P.C. Chen, and C.S. Hsu, “A distributed localization scheme for wireless sensor networks with improved grid-scan and vector-based refinement,” *IEEE Trans. Mobile Computing*, vol.7, no.9, Sep. 2008.
- [13] Y. Shu, Y. Huang, J. Zhang, P. Coué, P. Cheng, J. Chen, and K.G. Shin, “Gradient-based fingerprinting for indoor localization and tracking,” *IEEE Trans. Industrial Electronics*, vol.63, no.46, Apr. 2016.
- [14] J. So, J.Y. Lee, C.H. Yoon, and H. Park, “An improved location estimation method for WiFi fingerprint-based indoor localization,” *International Journal of Software Engineering and Its Applications*, vol.7, no.3, May 2013.
- [15] M.F. Stollenga, W. Byeon, M. Liwicki, and J. Schmidhuber, “Parallel multidimensional LSTM, with application to fast biomedical volumetric image segmentation,” *NIPS 2015*, vol.28, 2015.
- [16] M. Sundermeyer, R. Schlüter, and H. Ney, “LSTM neural networks for language modeling,” *INTERSPEECH 2012*, vol.13, Sep. 2012.
- [17] I. Sutskever, O. Vinyals, and Q.V. Le, “Sequence to sequence learning with neural networks,” *NIPS 2014*, pp.3104–3112, 2014.
- [18] P. Vincent, H. Larochelle, Y. Bengio, and P.A. Manzagol, “Extracting and composing robust features with denoising autoencoders,” *ICML 2008*, vol.25, pp.1096-1103, July 2008.
- [19] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.A. Manzagol, “Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion,” *Journal of Machine Learning Research*, vol.11, Dec. 2011.
- [20] K.W. Wilson, B. Raj, P. Smaragdis, and A. Divakaran, “Speech denoising using nonnegative matrix factorization with priors,” *IEEE International Conf. on Acoustics, Speech and Signal Processing*, Mar. 2008.
- [21] 岡本英二, 堀場慎人, 中島啓太, “室内高精度位置推定によるスマートグリッド性能向上の研究,” 電気通信普及財団研究調査助成報告書, no.31, 2016.
- [22] 寺本隆磨, 長田茂美, “Stacked denoising autoencoder の汎化性能向上に関する一検討,” *IPSJ SIG Technical Report*, vol.CVIM-195, no.53, Jan. 2015.
- [23] 谷内大祐, 前川卓也, “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, Jan. 2014.
- [24] 谷内大祐, 前川卓也, 鈴木潤, 岸野泰恵, “Boostingを用いた環境変化に頑健な Wi-Fi 屋内位置推定の手法の提案,” *情報処理学会論文誌*, vol.UBI-40, no.5, Nov. 2013.