

Wi-Fi CSIの時系列情報を用いた少量学習データによる 屋内位置推定手法

村上 健太¹ Kumrai Teerawat¹ 前川 卓也¹ 原 隆浩¹ 尾原 和也² 岸野 泰恵² 村上 友規³
アベセカラ ヒランタ³

概要：近年、歩行中に観測された Wi-Fi 受信信号の時系列情報を用いた携帯端末の位置推定に関する研究が盛んに行われており、駅や空港などの屋内施設でのナビゲーションなどへの応用が期待されている。また、Wi-Fi 信号情報の中でも、チャンネル状態情報 (CSI: Channel State Information) は豊富な情報量を持ち、高精度な位置推定が可能であると言われている。Wi-Fi 受信信号の時系列情報を用いた歩行軌跡推定では、位置推定対象となるユーザが歩行する可能性のある全ての経路についてあらかじめ学習用の Wi-Fi 時系列データを収集する必要がある、広大な屋内施設では莫大な経路数が存在するため、全ての経路に対して学習データの収集を行うことは困難である。本研究では、少量の歩行パターンの CSI 時系列を学習データとして、未学習の歩行パターンに対しても位置推定可能な屋内位置推定モデルの作成を目指す。具体的には、近傍地点の Wi-Fi 信号の潜在表現は局所的に滑らかであるという仮定に基づき、Variational AutoEncoder (VAE) を用いて潜在空間のデータ分布に制約を持たせることで、学習していない座標で観測された CSI データの潜在表現を周辺座標のデータから補完的に獲得する。評価実験では、実環境での実験で未学習地点を含む歩行経路で得られた CSI 時系列を用いて提案手法の有効性を確認した。

キーワード：Wi-Fi 受信信号, チャンネル状態情報 (CSI), 屋内位置推定, Variational AutoEncoder (VAE)

1. 序論

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から駅、空港、ショッピングモールなどの多くの屋内施設に普及している。また、スマートフォンや IoT デバイスなどの Wi-Fi による無線通信が可能な端末の普及も進んでおり、誰がどこにいても容易に Wi-Fi の無線通信サービスを利用可能な環境になりつつある。それに伴い、Wi-Fi 受信信号情報を利用した屋内位置推定に関する研究が注目を集めており、ショッピングモールや駅、空港などの広い屋内施設でのナビゲーションや、子供、高齢者の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 [10], [13]。

近年、高速な無線通信を行うために、複数のアンテナペアを利用して分割したデータを同時に伝送する MIMO (Multiple Input Multiple Output) アンテナや、互いに干渉しない複数の伝送波 (サブキャリア) でデータを並列して送信する直行周波数分割多重方式 (OFDM: Orthogonal

Frequency Division Multiplexing) などの技術の普及が進んでいる。そこで、MIMO アンテナによる OFDM 方式 (MIMO-OFDM 方式) [2], [4] の Wi-Fi 通信を行う際に得られるチャンネル状態情報 (CSI: Channel State Information) が注目を集めている [14]。CSI は MIMO-OFDM 方式の通信において、各送受信アンテナペア、各サブキャリアの Wi-Fi 信号の伝搬経路の状態を複素数で表現したものである。CSI はサブキャリア毎の電波の伝搬損失や反射・回折などのマルチパスの影響による振幅 (amplitude), 位相 (phase) の変化を表し、豊富な情報量を含んでいる [11], [16]。

CSI を用いた位置推定に関する既存手法の多くはフィンガープリンティングベースの手法を用いている [8], [12], [15], [17]。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内の様々な場所で観測した Wi-Fi 信号情報とその観測地点の座標を記録し、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、環境内の未知の地点で観測された Wi-Fi 受信信号情報とオフラインフェーズで作成したラジオマップの信号情報を照合し、Wi-Fi 信号の観測地点を推定する。既存手法の多くが静止中に観測された CSI を用い

¹ 大阪大学大学院情報科学研究科

² NTT コミュニケーション科学基礎研究所

³ NTT アクセスサービスシステム研究所




図 1: CSI 時系列からの歩行軌跡推定




図 2: 未学習の歩行経路の推定

て位置推定を行なっているが、ナビゲーションなどへの応用を想定したときに、歩行中のある時点で得られた一時刻の CSI データは非常に不安定であり、既存手法での位置推定に用いると精度が低下する。

近年、このような問題に対応するため、Wi-Fi の時系列情報を用いた位置推定に関する研究が行われている [3], [5], [7]. Wi-Fi の時系列を用いた位置推定では、歩行中に得られた時間窓内の時系列の時間的な依存性を利用することで、単一時刻で得られた Wi-Fi 信号に比べて安定した位置推定が可能となる。この手法では図 1 のように Wi-Fi の時系列を入力とし、入力時系列に対応した歩行軌跡を推定するため、位置推定を行う環境において、歩行する可能性のある全ての経路をあらかじめ歩行して学習用の Wi-Fi 時系列データを収集する必要がある。これまでに、CSI の時系列情報を利用した歩行軌跡推定は行われていない。

しかし、屋内位置推定を応用する環境として想定されている、駅や空港などの広大な屋内施設では莫大な経路数が存在するため、それら全てに対して学習データの取得を行うのは困難である。また、図 2 のように、一つの十字路に対しても各方向からの歩行パターンを考えると計 12 パターンが存在しており、それら全てに対応する Wi-Fi 時系列を収集するには莫大なデータ収集コストが必要となる。本稿では、少量の歩行パターンの CSI 時系列を学習データとして、未学習の歩行パターンに対しても位置推定可能な屋内位置推定モデルの作成を目指す。例えば、図 2 のように、特定の経路を通らないデータのみで学習したモデルを用いた未学習地点の位置推定や、座標は学習しているが、歩行する順路が学習されていないような歩行軌跡に対しても位置推定可能なモデルの実現を目指す。




図 3: MIMO アンテナによる無線通信モデル. M_T と M_R はそれぞれ送信アンテナ、受信アンテナの数

学習データに含まれていない座標に対して位置推定を行うために、近傍地点の Wi-Fi 信号の潜在表現は局所的に滑らかであるという仮定を用いて、学習済みの周辺座標の情報を利用した潜在表現の獲得を行う。具体的には、Variational AutoEncoder (VAE) [1], [9] を用いて潜在空間のデータ分布に制約をもたせることで、学習していない座標で観測された CSI データの潜在表現を補完的に獲得する。また、VAE は入力データを再構成するように学習されるので、ユーザのアプリケーションの利用とともに大量に取得される座標ラベルが与えられていない CSI データを用いて VAE を学習することでより頑健な特徴抽出を行い、さらなるデータ収集コストの削減を行う。

本稿の貢献は以下の 3 つである。

- MIMO-OFDM 方式の通信で得られる Wi-Fi CSI の時系列情報を利用した初めての歩行軌跡の推定手法を実現した
- 潜在空間が滑らかであるという仮定を利用し、周辺座標の情報から未学習地点で得られた CSI に対して位置推定可能な特徴抽出を行うことで、少量の学習データでモデルの学習を行った
- 実環境での実験で高い位置推定精度が得られることを確認した

本稿の構成は以下の通りである。まず、2 節では CSI の性質や、Wi-Fi 信号情報を利用した屋内位置推定に関する研究を紹介する。3 節では、歩行中に観測された CSI 時系列に関する検証実験や、少量の学習データで位置推定を行うための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 節で本稿のまとめを行う。

2. 関連研究

本章では、屋内位置推定に用いる Wi-Fi 受信信号情報としてチャネル状態情報 (CSI: Channel State Information) と、CSI を利用した屋内位置推定手法について紹介する。

2.1 Channel State Information (CSI)

CSI は Wi-Fi 通信における物理層で抽出される送受信




図 4: CSI の時系列

機間の伝搬経路の情報を表す情報として知られている。MIMO-OFDM 方式の通信の概要を図 3 に示す。CSI は送信機から送信された電波が受信機に到達するまでに受ける伝搬損失や、壁や障害物への反射・回折などのマルチパスの影響による振幅 (amplitude)・位相 (phase) の変化を表し、この情報は MIMO アンテナの通信における各アンテナペア、OFDM 方式の通信における各サブキャリアについて得られる。

M_T 個の送信アンテナ, M_R 個の受信アンテナの組み合わせで得られる i 番目のサブキャリアの送信電波, 受信電波をそれぞれ $\mathbf{X}_i = [x_1, x_2, \dots, x_{M_T}]$, $\mathbf{Y}_i = [y_1, y_2, \dots, y_{M_R}]$ とすると, 観測される CSI (\mathbf{H}_i) は次式で表される。

$$\mathbf{Y}_i = \mathbf{H}_i \mathbf{X}_i + \mathbf{N}_i \quad (1)$$

ここで, \mathbf{N}_i は M_R 次元のノイズベクトルを表す。 h_{mn} を m 番目の受信アンテナと n 番目の送信アンテナ間の伝搬路における CSI の値とすると, h_{mn} は複素数であり, 次式で表される。

$$h_{mn} = |h_{mn}| e^{j\angle h_{mn}} \quad (2)$$

h_{mn} , $\angle h_{mn}$ はそれぞれ CSI の振幅と位相を表す。

サブキャリアの数を N_s とすると, Wi-Fi の 1 パケットにつき N_s 個の CSI 行列が得られ, それらをまとめて以下の式で表される。

$$\mathbf{H} = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_{N_s}] \quad (3)$$

つまり, 図 4 のように, パケット毎に CSI は $M_T \times M_R \times N_s$ 次元の複素数データとして得られる。連続して Wi-Fi 通信を行うことで, $M_T \times M_R \times N_s$ 次元の時系列データの CSI が得られる。

2.2 Wi-Fi 受信信号情報を用いた屋内位置推定

Wi-Fi 信号は伝搬中に減衰するため, 送信機と受信機間の距離によって受信信号の状態が変化する。また, 屋内環境には壁や障害物が存在し, それらに対する信号の反射や回折などによっても信号の減衰や位相の変化が発生する。

これらの原因で生じる Wi-Fi 信号の変化は屋内環境内の位置で固有と考えられるため, Wi-Fi 受信信号情報を分析することで位置推定が可能となる。

2.2.1 Wi-Fi フィンガープリンティング

Wi-Fi 受信信号情報を用いた屋内位置推定で最も一般的に用いられている手法に Wi-Fi フィンガープリンティングがある [8], [12], [15], [17]。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, 位置推定を行う環境において Wi-Fi 受信信号情報を観測し, その地点の座標とともに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。これを環境内の様々な場所で行うことで, 対象となる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, 未知の場所で観測された Wi-Fi 受信信号情報と, あらかじめオフラインフェーズで作成し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。

しかし, 歩行中に観測された Wi-Fi 信号はノイズや欠損が多く非常に不安定であるため, それを用いた位置推定の精度も低下する。そこで, 歩行中に観測された Wi-Fi 信号の時系列情報の時間的な関係性を用いた位置推定手法が研究されている。

2.2.2 Wi-Fi 時系列フィンガープリンティング

Wi-Fi 時系列フィンガープリンティングを用いた手法では, オフラインフェーズで位置推定対象となる環境内での歩行中に Wi-Fi 受信信号の時系列情報を収集し, 歩行軌跡の座標とともに記録することで, 時系列ラジオマップを作成する [6], [18], [19]。オンラインフェーズでは, 未知の経路の歩行中に特定の時間窓長で Wi-Fi 時系列情報を取得し, オフラインフェーズで作成した時系列ラジオマップから抽出可能な同サイズの時間窓の Wi-Fi 時系列情報と照合することで, 時間窓に対応する歩行軌跡を推定する。時系列情報を利用することで, 時間窓内の Wi-Fi 時系列の時間的な依存関係を利用可能となり, 単一時刻で得られた Wi-Fi 信号を用いるのと比較して突発的なノイズに頑健な位置推定が可能となる。

本稿では, 初めて CSI の時系列情報を利用した歩行軌跡推定を行う。しかし, 図 1 のように Wi-Fi 時系列情報から歩行軌跡を推定するためには, 位置推定対象となるユーザが歩行する可能性のある全ての経路について学習用の Wi-Fi 時系列データをあらかじめ収集する必要があり, 広大な屋内施設では莫大な経路数が存在するため, 全ての経路に対して学習データの収集を行うことは困難である。そこで, 本稿では学習済みの周辺座標の情報を利用することで, 未学習の歩行経路に対する位置推定を可能とするような歩行軌跡の推定を実現する。




図 5: 提案手法の概要




図 6: 実環境での歩行中に取得した CSI 時系列. 左図は元のデータで, 右図は移動平均フィルタ後のデータを表す.

3. 提案手法

提案手法の全体構造を図 5 に示す. 図 5 のように, 提案手法ではまず位置推定を行う環境内でのランダムな歩行中に CSI 時系列データの収集を行う. そして, 得られた CSI 時系列データに対してフィルタリングなどの前処理を行った後, 機械学習を用いて時系列から抽出された時間窓内のそれぞれの時刻のデータに対する位置推定を行う. CSI 時系列データから歩行軌跡の推定を行うための提案手法の詳細なアーキテクチャについて説明する.

3.1 CSI 時系列の前処理

本研究では, 位置推定を行う環境に IEEE802.11ac の無線通信機器を搭載した Wi-Fi アクセスポイント (送信アンテナ 2 本) を 1 つ設置し, モバイル端末 (受信アンテナ 2 本) で CSI データの取得を行う. 実環境での歩行中に観測された CSI phase の時系列を図 6 の左に示す. 図より, 実環境で観測された CSI 時系列はノイズが多く, 時間的な変化の傾向を目視で確認することは困難である. そこで, 時系列に対して移動平均フィルタを適用した結果を図 6 の右に示す. 移動平均フィルタによるノイズ除去を行うことで, 元のデータと比較して明確に時間的に連続的な変化が現れていることがわかる. 提案手法では, CSI 時系列に移動平均フィルタを適用したものを利用する.

また, 異なるサブキャリアについて得られた CSI 時系列について相関を可視化した結果, 図 7 のように高い相関をもつグループが観測された. 提案手法では, CSI 時系列の相関の高いサブキャリアについて平均をとることで次元を削減し, 不要な情報の削除による精度の向上や機械学習モデルの計算の高速化を行う.




図 7: サブキャリア間の相関. 相関の高いグループを長方形で包囲

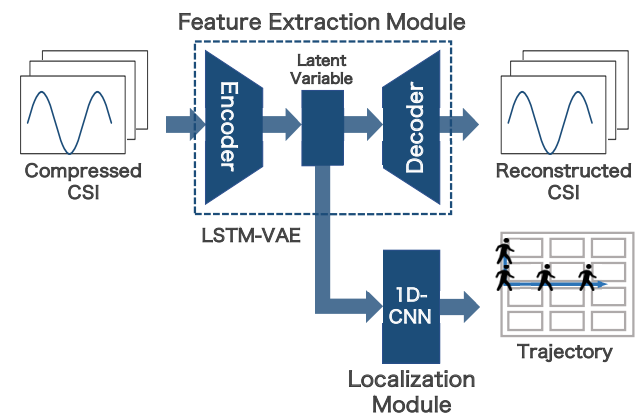


図 8: 提案手法のネットワーク

3.2 位置推定モデル

前処理後の CSI 時系列データに対して機械学習を用いて歩行軌跡推定を行う. 機械学習の入力としては, 特定の長さの時間窓内の CSI 時系列を利用し, 入力した時間窓に対応する歩行軌跡の座標を出力する. CSI 時系列を入力とした歩行軌跡推定モデルのネットワークを図 8 に示す. 提案モデルは CSI 時系列から潜在表現の獲得を行なう特徴抽出モジュールと潜在表現から歩行軌跡推定を行なう位置推定モジュールの 2 つに分かれている. 特徴抽出モジュールと位置推定モジュールを End-to-End で学習を行うことで, 特徴抽出モジュールで CSI 時系列から位置推定可能な潜在表現の抽出を行うと同時に, 抽出された潜在表現を利用して位置推定モジュールで歩行軌跡推定を行う.

3.2.1 特徴抽出モジュール

CSI 時系列から, 位置推定可能な特徴の抽出を行なう. 学習データに含まれていない座標の CSI データに対しても位置推定を可能とするために, VAE を用いて学習済みの周辺座標の情報を利用した潜在表現の獲得を行う. VAE では, 潜在空間のデータ分布が正規分布に近づくように学習

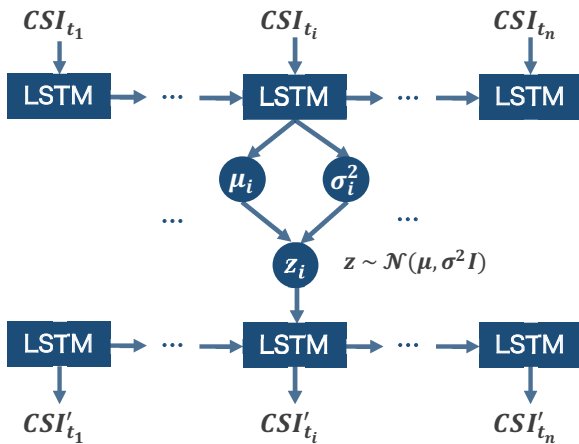


図 9: LSTM-VAE. 長さ n の CSI 時系列の入力 $CSI_{t_1} \sim CSI_{t_n}$ に対して, LSTM で時間的な依存関係を学習し, 各時刻の CSI の潜在空間の分布における平均 μ_i と分散 σ_i^2 を出力する. 各時刻の潜在空間の分布からランダムサンプリングされた潜在表現 z_i を用いて, LSTM で入力再構成を行う.

されるため, 潜在変数の分布に連続性が生じ, 類似した潜在変数からは類似したデータが生成されるようになる. つまり, VAE を用いることで学習データに含まれていない座標で観測された CSI に対しても, 学習済みの周辺座標の CSI との類似性から潜在表現の補完的な獲得が可能となる.

また, CSI 時系列の潜在空間の獲得に時間的な依存関係も利用するために, 図 9 に示すような LSTM-VAE を用いた CSI 時系列の特徴抽出を行う. LSTM-VAE は図 9 のように, 長さ n の CSI 時系列を入力とし, 時間的な依存関係を利用可能な LSTM を用いてそれぞれの時刻の潜在表現の獲得を行う. ここで, それぞれの時刻の潜在表現を確率分布の平均 μ と分散 σ^2 として推定することで, 潜在表現に正規分布に従う確率分布を仮定する. この平均と分散で表現される正規分布からランダムサンプリングを行なうことで, 入力した CSI 時系列の各時刻の潜在表現 z_i を取得する.

3.2.2 位置推定モジュール

図 8 に示すように, 位置推定モジュールでは特徴抽出モジュールで得られた潜在表現 z の時系列を利用して歩行軌跡の推定を行う. 本研究の実験環境では, あらかじめ定められた経路をランダムな経路で歩行している際に観測された CSI 時系列を利用した歩行軌跡推定を行う. 歩行のスムーズさを学習するため, 時系列モデルを用いた歩行軌跡推定を行うが, LSTM のような強い時間的依存性を学習するモデルを利用すると, 学習データに含まれていない座標の CSI データや, 同じ経路の逆向きの歩行などに対する位置推定が困難になると考えられる. そこで, 提案手法では 1D-CNN を用いることで弱い時間的依存性を学習し, 歩行軌跡推定結果をスムージングする.




図 10: 実験環境. 歩行経路はおおよそ横 12m×縦 6m. 青い矢印は学習データでは歩行しない (学習パターン 1), もしくは矢印の方向にのみ歩行を行った (学習パターン 2).

3.2.3 半教師あり学習

Wi-Fi CSI を利用した屋内位置推定の応用として想定されているナビゲーションなどのアプリケーションを実際にユーザが利用した際には大量の座標ラベルなし CSI データを収集することが可能となる. 特徴抽出モジュールで利用している LSTM-VAE は座標ラベルなしでも学習可能であり, モデル全体の座標ラベルありデータによる学習 (教師あり学習) と組み合わせて, 特徴抽出モジュールを座標ラベルなしデータで学習 (教師なし学習) することで半教師あり学習を行い, LSTM-VAE の潜在表現の学習性能を向上することで位置推定精度の向上を目指す.

具体的なモデルの学習は以下の手順で行なう.

- (1) 座標ラベルありデータでモデル全体を学習 (教師あり学習)
- (2) 座標ラベルなしデータで特徴抽出モジュールのみを学習 (教師なし学習)
- (3) 座標ラベルありデータでモデル全体を学習 (教師あり学習)

座標ラベルなしデータを利用したモデルの半教師あり学習を行なうことで, 大量の座標ラベルあり学習データの取得が困難であるような環境において, さらに少量の学習データでの頑健な屋内位置推定を実現する.

4. 評価実験

4.1 データセット

評価実験を行った環境を図 10 に示す. 評価実験では, 図の右下の位置に送信機を 1 つ設置し, 歩行者のアイコンの位置を始点として, 図 10 の赤線に示す経路に沿った完全にランダムな歩行中に CSI データの取得を行った. CSI データの収集の際には, スマートフォンの AR 機能を利用した現在地座標取得アプリケーションを用いて各時刻の CSI データ観測地点の座標取得を行った.

提案手法では, 少量の学習データでの位置推定を実現するため, 学習データに含まれていない経路や, 座標は学習データに含まれているが順路が異なる経路の歩行中に観

表 1: 学習・評価データセットの CSI 時系列サンプル数

	学習パターン 1	学習パターン 2	評価
時系列サンプル数	14215	18300	8912

測された CSI 時系列データに対する歩行軌跡推定を行う。これらの経路に対する歩行軌跡推定精度の評価を行うために、以下の 2 パターンの学習用データセットを用意した。

- 学習パターン 1: 図 10 の青い矢印の経路を通らない歩行中に取得された CSI 時系列データを学習に用いる
- 学習パターン 2: 図 10 の青い矢印の経路について、矢印の方向のみを含む歩行中に取得された CSI 時系列データを学習に用いる

評価実験では、学習パターン 1 の評価では青い矢印の経路を通るランダムな順路での歩行を、学習パターン 2 の評価では青い矢印の交差点に対して矢印の 2 パターン以外の順路での歩行を未学習経路として精度の評価を行った。

本研究の実験環境では、一時刻に観測される CSI は 4 アンテナペア、52 サブキャリアの複素数について実数、虚数の計 $4 \times 52 \times 2$ 次元の入力であり、それをサブキャリアの次元を 6 次元に削減を行った、 $4 \times 6 \times 2$ 次元のデータを提案モデルの入力に用いた。

評価実験では、CSI 時系列のサンプリング間隔は約 0.1 秒であり、長さ 50 の時間窓で切り取ることで CSI 時系列の作成を行った。つまり、約 5 秒間の歩行中に観測された CSI 時系列を 1 つのデータサンプルとして利用した。また、時間窓は 1 時刻ずつスライドしながら CSI 時系列を作成することで、一度の歩行データに対して大量の学習データを獲得した。

以上の方法でデータセットを作成した結果、学習パターン 1, 2 のデータセット、評価用のデータセットの CSI 時系列のサンプル数は表 1 のようになった。

4.2 評価方法

評価実験では、図 10 の環境内のランダムな歩行中に観測された CSI 時系列データに対する歩行軌跡推定精度に関する評価を行った。CSI 時系列を入力として推定された歩行軌跡の各座標に対してそれぞれ正解座標とのユークリッド距離を計算し、その平均値を歩行軌跡推定誤差とした。

パターン 1 とパターン 2 の学習データを利用して学習された歩行軌跡推定モデルについて、学習済み経路、未学習経路、全ての経路に対してそれぞれ歩行軌跡推定誤差を計算し、提案手法の評価を行う。評価を行う際には、全ての時系列に対して歩行軌跡の座標を推定した後、図 10 の青い経路に含まれている座標を未学習経路の、青い領域以外の座標を学習済み経路の位置推定誤差の計算に利用した。また、パターン 2 の学習データでは青い矢印の方向には歩行しているため、評価の際は青い領域の内、青い矢印の方向の歩行は学習済み経路の位置推定誤差の計算に利用し、

それ以外の順路での歩行を未学習経路に対する位置推定誤差の計算に利用した。

4.2.1 ベースライン手法との比較

提案手法の有効性を評価するために、提案手法のモデルを一部変更した 3 つのベースラインとなる比較手法を用意した。3 つの比較手法と提案手法のモデル構成を以下に示す。比較手法の名称については、+以前が特徴抽出モジュールを、+以降が位置推定モジュールを表している。

- LSTM: 特徴抽出は行わず、CSI 時系列を直接入力として LSTM で歩行軌跡を推定
- VAE + LSTM: VAE で CSI 時系列のそれぞれの時刻の CSI に対する特徴抽出を行い、得られた潜在表現の時系列を利用して LSTM で歩行軌跡を推定
- LSTM-VAE + FC: LSTM-VAE で CSI 時系列の時間的特徴を利用した特徴抽出を行い、時系列の各時刻について得られた潜在表現を利用して全結合層のみのニューラルネットワークで各時刻の座標を推定
- LSTM-VAE + 1D-CNN (提案手法): LSTM-VAE で CSI 時系列の時間的特徴を利用した特徴抽出を行い、得られた潜在表現の時系列を利用して 1D-CNN で歩行軌跡を推定

これらの手法について、学習パターン 1, 2 でそれぞれ位置推定精度を比較し、提案手法の評価を行う。

4.2.2 半教師あり学習

CSI 時系列情報を利用した屋内位置推定の応用先であるナビゲーションなどのアプリケーションを利用した際には座標ラベルなし CSI 時系列データが大量に取得される。提案手法では、座標ラベルありデータに加えて座標ラベルなしデータを利用する半教師あり学習を行い、さらに少量の座標ラベルあり学習データによる位置推定を目指す。半教師あり学習を行うために、パターン 2 の学習データを、座標ラベルありデータの割合を 100% から 20% まで 20% ずつ減らしながら、残りのデータを座標ラベルなしデータとして利用することで、学習に利用した。座標ラベルあり・なしデータを組み合わせた半教師あり学習を行ったモデルと、座標ありデータで教師あり学習のみ行ったモデルの位置推定精度を比較することで、予め取得が必要な座標ラベルあり学習データを減らしてもアプリケーションの利用とともに取得される座標ラベルなしデータを利用することで頑健な位置推定が可能であるか検証した。

4.3 評価実験の結果

4.3.1 ベースライン手法との比較

学習パターン 1 について、LSTM, VAE+LSTM, LSTM-VAE+FC, LSTM-VAE+1D-CNN (提案手法) の 4 つの手法でそれぞれ位置推定精度を行った結果を表 2 に示す。表 2 より、全ての経路に対する位置推定では提案手法が最も高精度であることがわかる。学習済み経路に対する位置推

表 2: 学習パターン 1 の位置推定誤差 (m) の比較

	全ての経路	未学習経路	学習済み経路
LSTM	2.019	2.186	1.982
VAE+LSTM	1.975	1.965	1.976
LSTM-VAE+FC	1.890	2.336	1.793
提案手法	1.817	2.097	1.756

表 3: 学習パターン 2 の位置推定誤差 (m) の比較

	全ての経路	未学習経路	学習済み経路
LSTM	1.758	1.802	1.751
VAE+LSTM	1.761	1.92	1.733
LSTM-VAE+FC	1.735	1.908	1.705
提案手法	1.659	1.664	1.658

定では、CSI 時系列をそのまま入力として利用するのではなく、VAE で獲得した潜在表現を用いることで精度が向上している。また、未学習経路については、位置推定に時系列モデルを利用することで精度が向上していることがわかる。

学習パターン 2 について、LSTM, VAE+LSTM, LSTM-VAE+FC, LSTM-VAE+1D-CNN (提案手法) の 4 つの手法でそれぞれ位置推定精度を行った結果を表 3 に示す。表 3 より、未学習経路、学習済み経路に対して共に提案手法が最も高精度である。特に、未学習経路に対する位置推定では提案手法は他の手法と比べて精度は大幅に向上していることがわかる。

学習パターン 1 と学習パターン 2 の結果を比較すると、学習パターン 2 の方が位置推定精度が高い。特に、学習パターン 1 では未学習経路の推定精度は学習済み経路の推定精度から低下していたが、学習パターン 2 では未学習経路も学習済み経路と同程度の精度での推定が可能となっている。

4.3.2 半教師あり学習の効果

パターン 2 の学習データを一定の割合で座標ラベルありデータと座標ラベルなしデータに分割し、座標ラベルありデータの割合を減らしながら半教師あり学習と教師あり学習をそれぞれ行ったときの位置推定精度を表 4 に示す。表のパーセンテージはパターン 2 の学習データの内、座標ラベルありデータとして利用する割合を示しており、その残りのデータを座標ラベルなしデータとして半教師あり学習に利用している。

表 4 より、半教師あり学習を行うことで教師なし学習のみを行った場合よりも高精度な位置推定が可能であることがわかる。学習済み経路よりも未学習経路に対しての精度の向上が大きく、未学習経路では、座標ラベルありデータの割合を 20% まで減らした際には 30% 以上の精度向上を達成している。

表 4: 半教師あり学習の位置推定誤差 (m) への影響。学習データの内、座標ラベルありとして用いたデータの割合を変化させて実験

		100%	80%	60%	40%	20%
全ての経路	半教師あり	1.649	1.65	1.724	1.745	1.778
	教師あり		1.675	1.741	1.77	1.851
未学習経路	半教師あり	1.585	1.832	1.869	1.767	1.659
	教師あり		1.873	1.762	1.812	2.186
学習済み経路	半教師あり	1.664	1.618	1.69	1.742	1.798
	教師あり		1.642	1.736	1.763	1.794

4.4 考察

学習パターン 1 と 2 では、VAE に基づく特徴抽出モジュールの利用によって全ての経路に対する位置推定精度が向上した。また、提案手法は LSTM-VAE+FC よりも高精度な位置推定が可能であることから、1 時刻の CSI から座標を推定するよりも、CSI 時系列による歩行軌跡推定を行うことで、位置推定精度が向上することが分かる。以上より、提案手法の有効性が確認できた。

学習パターン 1 の実験では、学習済み経路では比較手法より高精度となったが、未学習経路に対しては VAE+LSTM の方が高精度であった。これは、特徴抽出モジュールに時系列モデルを利用することで時間的な依存関係を考慮した潜在表現の獲得が可能となる一方、未学習経路の時系列に対しては時間的な依存関係を利用することで、潜在表現の獲得が困難になったからであると考えられる。しかし、学習パターン 2 の実験では、未学習経路に対しても提案手法は比較手法よりも精度は大幅に向上し、学習済み経路と同程度の精度での推定が可能となった。そのため、交差点に対して最小限の 2 パターンの歩行のみを加えることで提案モデルは学習可能であり、交差点に対するデータ収集コストを約 17% に低減可能である。

半教師あり学習を行うことで、座標ラベルなしデータを利用しない教師あり学習のみの場合と比較して精度は向上した。これは、CSI 時系列の特徴抽出が位置推定精度向上に関して大きな役割を担っており、座標ラベルなしデータで特徴抽出モジュールの特徴抽出性能が向上したからであると考えられる。

また、未学習経路に対して、半教師あり学習では教師あり学習のみの場合よりも大幅に精度が向上したが、今回の実験環境では全経路に対する未学習経路の割合が小さく、座標ラベルありデータと座標ラベルなしデータに分割を行った際に座標ラベルありデータに未学習経路のデータ量が少なく、教師なし学習を行った際に未学習経路に対する学習を行うことができたからであると考えられる。つまり、座標ラベルのある学習データ量が少ない経路が存在していても、その経路に関する座標ラベルのない学習データを利用して教師なし学習をおこなうことで、位置推定精度を向上できる。この結果より、半教師あり学習を行うこと

で、さらに少量の座標ラベルあり学習データでも頑健な位置推定が可能であると考えられる。

5. 結論

本研究では、Wi-Fi チャンネル状態情報 (CSI) の時系列を用いた少量の学習データによる頑健な屋内位置推定を実現するために、少量の歩行パターンの CSI 時系列を学習データとして、未学習の歩行パターンに対しても位置推定可能な屋内位置推定手法を開発した。提案手法では、近傍地点の Wi-Fi 信号の潜在表現は局所的に滑らかであるという仮定に基づき、Variational AutoEncoder (VAE) を用いて潜在空間のデータ分布に制約をもたせることで、学習していない座標で観測された CSI データの潜在表現を周辺座標のデータから補完的に獲得する。そして、得られた潜在表現の時系列から弱い時間的な依存性を学習する時系列モデルを利用した歩行軌跡推定を行うことで、歩行を再現するようなスムーズな座標の推定を実現した。また、屋内位置推定の応用先であるナビゲーションなどのアプリケーションの利用とともに座標ラベルなし CSI データが大量に取得されることに着目し、座標ラベルあり CSI データに加えて座標ラベルなし CSI データを用いる半教師あり学習を行った。

実環境での評価実験により、提案手法を用いることで、未学習の歩行パターンの CSI 時系列に対しても位置推定が可能となることを確認した。特に、十字路に対して最小限の 2 パターンの順路の歩行を学習するだけで、その他の未学習の順路での歩行に対しても学習済みの経路と同程度の精度での位置推定が可能となった。また、少量の座標ラベルありデータで教師あり学習のみを行った場合と比較して、座標ラベルなしデータを合わせて半教師あり学習を行うことで位置推定が向上することを確認した。

謝辞

本研究の一部は科研費 JP16H06539, JP17H04679, JP21H03428, 21H05299, JP21K19769 の支援によるものである。

参考文献

- [1] J. An and S. Cho, "Variational autoencoder based anomaly detection using reconstruction probability," Special Lecture on IEEE, vol.2, no.1, pp.1–18, 2015.
- [2] H. Bolcskei, "MIMO-OFDM wireless systems: basics, perspectives, and challenges," IEEE Wireless Communications, vol.13, no.4, pp.31–37, 2006.
- [3] Z. Chen, H. Zou, J. Yang, H. Jiang, and L. Xie, "WiFi fingerprinting indoor localization using local feature-based deep LSTM," IEEE Systems Journal, vol.14, no.2, pp.3001–3010, 2019.
- [4] L. Hanzo, J. Akhtman, Y. Akhtman, L. Wang, and M. Jiang, MIMO-OFDM for LTE, WiFi and WiMAX: Coherent versus non-coherent and cooperative turbo transceivers, John Wiley & Sons, 2011.

- [5] M.T. Hoang, B. Yuen, X. Dong, T. Lu, R. Westendorp, and K. Reddy, "Recurrent neural networks for accurate RSSI indoor localization," IEEE Internet of Things Journal, vol.6, no.6, pp.10639–10651, 2019.
- [6] W. Hu, Y. Wang, and L. Song, "Sequence-type fingerprinting for indoor localization," International Conference on Indoor Positioning and Indoor Navigation, Banff, Alberta, Canada, 2015.
- [7] M. Ibrahim, M. Torki, and M. Elnainay, "CNN based indoor localization using RSS time-series," IEEE Symposium on Computers and Communications, pp.01044–01049, 2018.
- [8] T. Koike-Akino, P. Wang, M. Pajovic, H. Sun, and P.V. Orlik, "Fingerprinting-based indoor localization with commercial MMWave WiFi: A deep learning approach," IEEE Access, vol.8, pp.84879–84892, 2020.
- [9] M.J. Kusner, B. Paige, and J.M. Hernández-Lobato, "Grammar variational autoencoder," International Conference on Machine Learning, pp.1945–1954, 2017.
- [10] D. Lymberopoulos and J. Liu, "The microsoft indoor localization competition: Experiences and lessons learned," IEEE Signal Processing Magazine, vol.34, no.5, pp.125–140, 2017.
- [11] Y. Ma, G. Zhou, and S. Wang, "WiFi sensing with channel state information: A survey," ACM Computing Surveys, vol.52, no.3, pp.1–36, 2019.
- [12] K.P. Nkabit and Y. Chen, "Application of solely self-attention mechanism in CSI-fingerprinting-based indoor localization," Neural Computing and Applications, pp.1–14, 2021.
- [13] D. Pavel and P. Robert, "A survey of selected indoor positioning methods for smartphones," IEEE Communications Surveys & Tutorials, vol.19, no.2, pp.1347–1370, 2016.
- [14] T.F. Sanam and H. Godrich, "An improved CSI based device free indoor localization using machine learning based classification approach," 26th European Signal Processing Conference, pp.2390–2394, 2018.
- [15] Y. Wang, C. Xiu, X. Zhang, and D. Yang, "WiFi indoor localization with CSI fingerprinting-based random forest," Sensors, vol.18, no.9, p.2869, 2018.
- [16] K. Wu, J. Xiao, Y. Yi, D. Chen, X. Luo, and L.M. Ni, "CSI-based indoor localization," IEEE Transactions on Parallel and Distributed Systems, vol.24, no.7, pp.1300–1309, 2012.
- [17] J. Xiao, Z. Zhou, Y. Yi, and L.M. Ni, "A survey on wireless indoor localization from the device perspective," ACM Computing Surveys, vol.49, no.2, pp.1–31, 2016.
- [18] X. Ye, Y. Wang, Y. Guo, W. Hu, and D. Li, "Accurate and efficient indoor location by dynamic warping in sequence-type radio-map," Proceedings of ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, vol.2, no.1, pp.1–22, 2018.
- [19] X. Ye, Y. Wang, W. Hu, L. Song, Z. Gu, and D. Li, "WarpMap: Accurate and efficient indoor location by dynamic warping in sequence-type radio-map," 13th Annual IEEE International Conference on Sensing, Communication, and Networking, pp.1–9, 2016.