

時間不変畳み込み層による不規則な CSI データを用いた Wi-Fi 屋内測位

Wi-Fi CSI Indoor Localization using Time Invariant Convolution Layers

屋間 彪吾[†] 井上 祐貴[†] 佐藤 拓杜[†] 大橋 洋輝[†]
Hyogo Hiruma Yuki Inoue Takuto Sato Hiroki Ohashi

1. はじめに

近年、ユーザの位置情報は様々なシステムにおいて、ユーザが取る行動の記録・解析・予測に用いられている。その為、今日では屋外測位における標準的な手法である GPS は多くの機器に搭載されている。

一方、GPS 電波が届かない屋内環境で測位を実現するには専用のセンサを設置する必要がありそのコストが課題となっている。例えば Bluetooth Low Energy (BLE) ビーコンの受信信号強度 (RSSI) を用いる手法では、測位する環境が広がるほど多数のセンサが必要になり、またその数に比例してメンテナンスコストが増加してしまう。

近年登場した Wi-Fi の Channel State Information (CSI) データを用いる手法[1]は、少ないセンサで障害物のある環境を広範囲にカバーできる強みが注目されている。特に Wi-Fi ルータは多くの施設で設置済みが多いため、コスト削減に効果的である。しかし、環境依存で変化する Wi-Fi 電波の特性上、既存手法では業務利用に耐える測位精度及び安定性の実現が困難であるという課題がある。

そこで本稿は、CSI データを用いた Wi-Fi 測位手法において精度低下の原因の 1 つを明らかにし、それを解消する方法として新しい深層学習モデルを提案する。

2. 従来の Wi-Fi 測位とその課題

Wi-Fi 測位に用いられる CSI データとは、通信時にデータを複数の周波数帯 (サブキャリア) に分割して送信する際の、サブキャリア毎の周波数応答の波形パターンである。この波形は送受信機 (例. Wi-Fi ルータとユーザの携帯端末) の位置関係や、その間の障害物の存在に依存して変化するため、地点ごとに固有な値を示すという特性がある。

[†]株式会社日立製作所 研究開発グループ 先端 AI ノバージョンセンタ 知能ビジョン研究部, Hitachi, Ltd.
Research & Development Group, Advanced Artificial Intelligence Center, Intelligent Vision Research Department

この特性を活かすことで、計測値からそのデータが計測されたであろう地点を推定することが可能である。例えば Fingerprinting 手法では、目的の環境内の各地点の波形データと座標のペア (=fingerprint) を入出力とした機械学習モデルを学習することで測位を実現する。

しかし、先行研究の Fingerprinting 手法[2][3]では電波の乱反射が発生しやすい環境 (例.金属板に囲まれた工事現場) において、精度が安定しないことが事前実験を通して確認された。理由は、同環境で計測される CSI データに、各地点で固有な波形が複数存在し、それらが時間的に不規則に切り替わりながら観測される性質 (時間的不規則性) を持つからである。これが既存の学習モデルが前提とするデータ性質と合致せず、精度低下の原因となっている。

例えば CSILoc[2]では単一時刻の波形データから予測するため、複数の固有波形を持つデータに対して予測が不安定になる。これは予測時に一部の固有波形しか入力されず、波形によって予測精度が変化するためである。故に安定化するためには複数時刻のデータを入力する必要がある。

ConFi[3]では複数時刻の波形データから成る時系列データを入力に用いている。しかし、時系列処理を行う畳み込み層 (Conv 層) の適用方法が時間的不規則性を持つデータに合わないため、予測精度が低い。ConFi では、隣り合う時刻のデータに連続的な規則性がある前提でモデル化しようとするが、不規則に切り替わる CSI データにはそれが無い。つまりそのようなデータを学習しようとしても、誤ったバイアスがモデルに内在しているため汎化損失が大きく、学習に失敗する可能性が高くなる。

以上より、CSI の時系列データを扱う場合、一定の時間窓内で各波形がどの程度の頻度で発生したかを示す「発生頻度的」な性質をモデル化するアプローチが有効である。本稿が提案する新しい深層学習モデルでは、上記性質を持つ時系列データに対して時間不変的に特徴量抽出を実現するネットワーク構造を導入した。

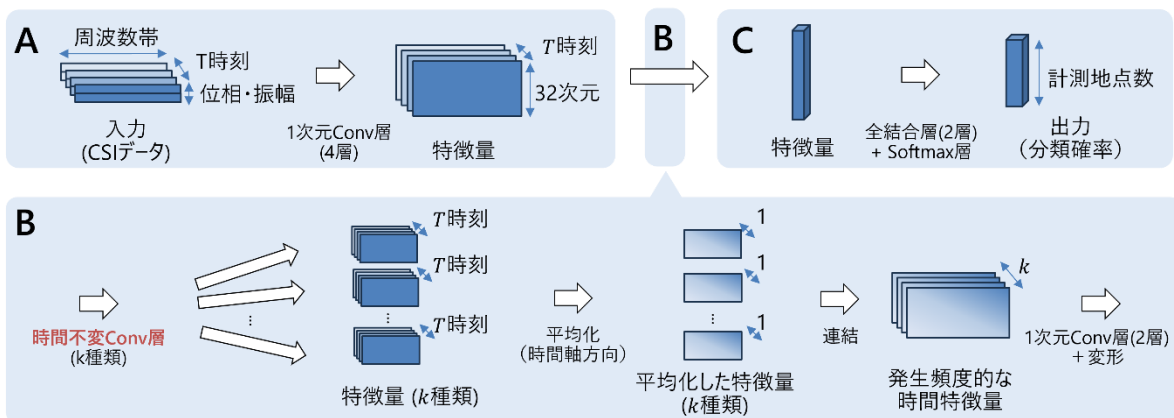


図 1: 提案手法のモデル構造

Conv層 = 畳み込み層

3. 提案手法

CSI の発生頻度的な特徴量化を得る方法として、図 1 A, B, C から構成される深層学習モデルを提案する。本提案モデルは CSILoc [2] のモデルを拡張し、時間不変的に特徴量抽出を行う「時間不変 Conv 層」を導入したものである。

図 1 A では、入力された CSI データ（振幅・位相の 2 チャンネルデータ）に 1 次元 Conv 層を 4 層適用し、32 チャンネルの特徴量に変換する。この処理を連続する T 時刻分の計測それぞれに適用して 1 つの特徴量にまとめる。

次に図 1 B では図 1 A の出力を受けて、時間不変 Conv 層を適用することで発生頻度的な特徴量を抽出する。時間不変 Conv 層は、通常の Conv 層と基本的な構成は同じだが、学習するフィルタの形状が異なる。入力時刻数を T 、フィルタのカーネルサイズを m 、出力のチャンネル数を k とした場合、通常の Conv 層は $R^{m \times m \times T}$ のフィルタを k 個学習するが、時間不変 Conv 層はチャンネル方向（今回は時間軸）に対して同一のフィルタを適用する為、 $R^{m \times m \times 1}$ の平面状のフィルタを k 個学習する。各フィルタが抽出した特徴量を時間軸方向に圧縮して用いることで、時間的な順序が無視され、発生頻度的に特化した特徴量抽出が可能になる。

最後に図 1 C では、前モジュールの出力をベクトル表現に変形した上で全結合層 2 つと Softmax 層により 1 次元ベクトルを出力する。このベクトルは分類確率を表現しており、学習データの計測地点数と同等の次元数を持つ。

学習時は、予測した分類確率と正解ラベルで Cross Entropy Loss を計算し、これを最小化するように学習する。

4. 評価

予測モデルの性能評価として、14m×22m の屋内建設現場でデータを収集し、測位精度を検証した。同現場は金属板が多く乱反射が発生しやすいため、全ての地点での計測に時間的不規則性が存在する環境である。比較評価には、従来手法として BLE ビーコンの RSSI 値から測位する手法と、CSI データを用いる既存手法として CSILoc[2] を使用した（図 1A と C から構成され、 $T=1$ ）。但し、公正な評価のために CSILoc は提案手法と同時刻分の入力に対して予測し、その平均精度によって評価した。

図 2 に現場の俯瞰図、センサ配置、及び学習/評価地点を示す。学習地点は計測可能区域を 2m 間隔で格子状に区切った配置とし、評価地点はそれらの中間とした。データ収集時は Wi-Fi ルータを 1 台設置し、学習データ、評価用データをそれぞれ 3000、300 時刻ずつ収集した。CSI データは有効な 56 チャンネルのデータを使用し、 $T=100$ とした。

ビーコン手法では、BLE ビーコンを環境内に平均 8m 間隔で設置した。これは、最少のセンサ数で、任意の地点で送受信機の間には障害物がない Line of Sight (LOS) が確保できる配置である。この手法では推定時は学習器を用いず、一定距離内にあると判定されたビーコンの座標の平均値を推定位置とする方式を用いた。

各測位手法で評価用データの予測を行った場合の予測誤差の分布を図 3 に示す。ビーコン手法は平均誤差が 3.65m であり、ビーコン同士の設置間隔である 8m の半分以下であるため、正しく各ビーコンがあるエリアを区別して認識できていることが分かる。一部予測誤差が極端に大きい外れ値が存在するが、それらは主に金属板周辺であり、乱反射により RSSI 値が乱れやすいエリアだった。

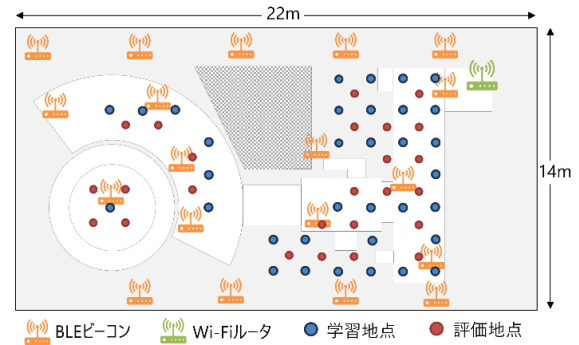


図 2: 実験環境におけるセンサ配置・計測地点
予測誤差の分布

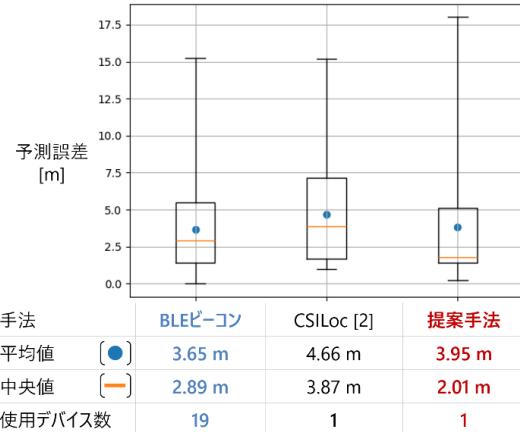


図 3: 各測位手法の予測誤差分布

一方 CSILoc は評価地点での平均予測誤差が 4.66m であり、ビーコン手法と比較して低い予測精度を示した。解析の結果、同一地点でも計測される波形によって精度が上下していることが判明した。これにより平均精度が低下しており、同モデルが CSI データの不規則な時間変化に対して脆弱であることが示された。

提案手法は、使用デバイス数を大幅に削減しつつも、従来のビーコン手法に近い予測性能を示した。特に中央値がビーコン手法と比較して低いことから、より安定して、高精度に予測できたデータが多かったことを示している。一方、一部の地点では極端に精度が低下する課題は残った。

5. おわりに

本稿では、Wi-Fi 測位技術において CSI の時系列データの特徴量化し、予測する手法を提案した。評価の結果、乱反射が多く測位が困難な環境において、1 台の Wi-Fi ルータで従来手法と同等の測位性能を得られることが示された。現在は特定の地点での精度低下の原因の特定と、全体の測位精度向上に向けて研究を進めている。

参考文献

- [1] K. Wu, et al. "CSI-Based Indoor Localization," in IEEE Transactions on Parallel and Distributed Systems, vol. 24, no. 7, pp. 1300-1309, July 2013
- [2] L. Wang and S. Pasricha, "A Framework for CSI-Based Indoor Localization with ID Convolutional Neural Networks," 2022 IEEE 12th International Conference on Indoor Positioning and Indoor Navigation (IPIN), Beijing, China, 2022
- [3] H. Chen, et al. "ConFi: Convolutional Neural Networks Based Indoor Wi-Fi Localization Using Channel State Information," in IEEE Access, vol. 5, pp. 18066-18074, 2017