

ニューラルネットワークによるWi-Fi受信電波強度を用いた 2地点間距離推定に関する検討

中谷 友哉^{1,a)} 前川 卓也^{1,b)} 白川 真澄^{1,c)} 原 隆浩^{1,d)}

概要：

近年、Wi-Fi電波情報を用いた屋内位置情報サービスに関する研究が数多く行われている。既存研究では、環境内に設置されたWi-Fiアクセスポイントからの受信電波強度を用いて位置を推定する方法が数多く研究されており、最も一般的な屋内位置推定手法であるWi-Fiフィンガープリンティングは、あらかじめ様々な場所で電波情報を収集しておく必要があり、そのコストは膨大である。一方本研究では、環境ごとの導入コストを必要とせずWi-Fi情報から提供可能なコンテキストとして、2地点間の物理的距離を、その2地点でスマートフォンなどにより観測されたWi-Fi受信電波情報を用いて推定する手法を提案する。このとき、提案手法では対象とする環境とは異なる環境で学習したニューラルネットワークを用いるため、対象とする環境における学習データを必要としない。2地点間の距離推定手法は、ナビゲーションや近接検知によるコミュニティ分析などのアプリケーションへの応用が期待される。評価実験では、5つの実環境において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、無線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、病院、駅などに広く普及している。さらに、スマートフォンなどの無線通信機能を搭載した端末の普及も進んでおり、どこにいてもWi-Fiによる通信サービスを利用できる環境が整いつつある。それに伴い、Wi-Fi電波情報を用いた屋内位置情報サービスに関する基礎的研究が数多く行われている。既存研究では、環境内に設置されたWi-Fiアクセスポイントからの受信電波強度を用いて位置を推定する方法が数多く研究されている。最も一般的な屋内位置推定手法として、Wi-Fiフィンガープリンティングがある。しかし、このようなフィンガープリントを用いた手法では、あらかじめ様々な場所で電波情報を収集しておく必要があり、そのコストは膨大である。また、ある環境で学習されたフィンガープリントを他の環境に適用することはできない。

このようにWi-Fiを用いた屋内位置推定手法は、端末の詳細なコンテキスト情報（位置座標）を提供できるが、その導入コストは大きい。一方本研究では、環境ごとの導入

コストを必要とせずWi-Fi情報から提供可能なコンテキスト情報を検討する。特に、本研究では、観測されたWi-Fi電波情報を用いて2地点間の物理的な距離を推定する手法を提案する。例えば、あるスマートフォンによって地点Aで信号強度ベクトル w_i が観測されたとし、またそのスマートフォンによって地点Bで信号強度ベクトル w_j が観測されたとする。このとき、 w_i と w_j を用いて地点AとBの間の物理的な距離を推定する。さらに本提案手法では、別の環境で観測されたトレーニングデータを用いて、2地点間の距離の推定を目指す。そのため、特定の環境に依存することなく2地点間の距離推定を行うことができる。

提案手法により推定された2地点間の距離を基に、以下のような実世界アプリケーションが実現できるようになると期待される。

- 屋内ナビゲーション：あるユーザの目的地におけるWi-Fi信号強度ベクトルとユーザの端末から得られたベクトルを基に、現在地から目的地までの距離を提示し、ナビゲーションに利用することができる。
- コミュニティの分析・検出：同一環境内にいる人々の端末を用いて人同士の距離を推定することによって、よく一緒に活動しているグループの検出などを行うことができる。
- 移動距離推定：GPSを使用できない屋内で移動距離を推定することができる。

¹ 大阪大学

Osaka University

a) nakatani.tomoya@ist.osaka-u.ac.jp

b) maekawa@ist.osaka-u.ac.jp

c) shirakawa.masumi@ist.osaka-u.ac.jp

d) hara@ist.osaka-u.ac.jp

筆者らの知る限り、Wi-Fi 信号強度ベクトルから物理的な距離を推定する研究はこれまでに行われていない。一方、大量に得られた Wi-Fi 信号強度ベクトルのクラスタリングを行う研究では、ベクトル間の距離（Wi-Fi 距離）をユークリッド距離や平均絶対誤差などによって定義している [4], [8], [10]。例えば、Tachikawa ら [10] は、観測された全ての AP からの受信電波強度を用いた平均絶対誤差により 2 つの Wi-Fi 信号ベクトル間の距離を計算している。この際、欠損値は Wi-Fi 信号強度の最小値である -100dBm に置き換えて計算している。しかしながら、どの既存の距離指標が物理的距離の推定に適切かどうかはこれまで検討されてこなかった。

そこで本研究では、機械学習を用いて、どの既存の距離指標もしくはそれらの組み合わせが物理的距離の推定に有効かをデータから学習するアプローチを取る。さらに深層学習を用いて、Wi-Fi 信号強度から直接的に物理的な距離の推定を行う。データから特徴を学習する深層学習を用いることにより、物理的距離の推定に有効なベクトル間の距離指標自体を学習することができる。最終的には、既存の距離指標およびデータから学習した距離指標を組み合わせて物理的距離の推定を行うニューラルネットワークを設計する。このとき、物理的距離を推定したい対象環境とは異なる環境で得られたデータを用いてニューラルネットワークの学習を行う。そのため提案手法では、対象環境において事前にデータを収集しておく必要はない。特に本研究では、1) 幾何学的な解析による検証、2) シミュレーションによる検証、3) 実験による検証、を基に学習器（ニューラルネットワーク）の設計を行う。これらの検証結果から設計した提案手法の特徴は主に以下の 3 点である。1) 距離推定に適した信号の選択的利用、2) 2.4GHz や 5GHz といった Wi-Fi 電波の周波数による伝搬特性の違いの考慮、3) 既存距離指標とデータから学習した特徴（距離指標）を組み合せた物理的距離の推定。

2. 関連研究

2.1 Wi-Fi 屋内位置推定

Wi-Fi を用いた屋内位置推定の一般的な手法として、Wi-Fi フィンガープリンティングがある [2], [6], [7]。Wi-Fi フィンガープリンティングは、訓練フェーズと推定フェーズから構成され、訓練フェーズでは既知の座標において Wi-Fi 電波情報（受信電波強度と Wi-Fi アクセスポイントの MAC アドレス）の観測し、フィンガープリントとして保存する。推定フェーズでは、未知の座標において観測された Wi-Fi 電波情報とフィンガープリントを比較することで、その電波情報に対応する位置を推定する。

一方本研究では、2 地点間の物理的距離の推定を提案している。この提案手法では、物理的距離を推定したい対象環境でトレーニングデータを集めめる必要はない。そこで、こ

こでは Wi-Fi 距離を利用する研究について主に紹介する。

Pulkkinen ら [9] は、半教師あり多様体学習により、不完全なラベルのフィンガープリントから密なラベルのフィンガープリントを作成している。筆者らは、2 つの Wi-Fi ベクトル間の距離計算をする際にユークリッド距離を用いている。

Tachikawa ら [10] は、2 つの Wi-Fi ベクトル間の平均絶対誤差（MAE）を用いて、対象環境で観測された Wi-Fi ベクトルをクラスタリングしている。信号強度ベクトル w_i と w_j 間の Wi-Fi 距離を計算すると仮定する。あるアクセスポイント（以下 AP） a_n が w_i のみに含まれていたとき、 w_j における a_n からの信号強度を最小値である -100dBm とみなす。このとき、 w_i と w_j 間の Wi-Fi 距離は以下によつて計算される。

$$d(w_i, w_j) = \frac{1}{|\mathcal{A}|} \sum_{a_n \in \mathcal{A}} |w_i(a_n) - w_j(a_n)|, \quad (1)$$

ただし、 \mathcal{A} は w_i または w_j に含まれる AP の集合を表し、 $w_i(a_n)$ は w_i に含まれる a_n からの信号強度を表す。

Maekawa ら [8] も 2 つの Wi-Fi ベクトル間の MAE を用いて、特定の場所へのユーザの再訪問を検知している。しかしながら、これらの研究では、観測された Wi-Fi ベクトルを用いた観測地点間の物理的距離の推定は行われていない。

2.2 無線信号を用いた距離推定

三角測量に基づく屋内位置推定手法は、Bluetooth ピーコンなどの信号送信機とスマートフォンなどの受信機間の物理的な推定距離を利用していている [12], [13]。また、Taniuchi ら [11] は、フィンガープリンティングによって推定された Wi-Fi 地点を補正するために Bluetooth ピーコンと受信機間の距離を推定している。Bluetooth 信号（や Wi-Fi 信号）は電磁波の一種であるため、従来の電磁波の減衰式を用いて Bluetooth 信号の減衰をモデル化することができる。理想空間において、電磁波のエネルギー損失は以下の公式によつて計算される。

$$A(d) = -20 \log \frac{4\pi d}{\lambda}, \quad (2)$$

ただし、 d は伝搬距離（メートル）を表し、 λ は電磁波の波長を表す。従って、 $\lambda = cf$ 、ただし、 c は光速を表し、 f は信号の周波数を表す。2.4GHz の Wi-Fi 信号や Bluetooth 信号の場合、 λ は 0.125 メートルとなる。上記の公式を基に、dBm 単位における受信信号強度 (RSSI) から伝搬距離を計算する以下の式が得られる。

$$w(a_n) = -40 - 20 \log d, \quad (3)$$

ただし、 $w_i(a_n)$ は、スマートフォンなどの信号受信機によって観測された AP a_n からの信号強度を表す。これらの研究は、信号送信機と受信機の間の物理的距離の推定を

表 1 物理的距離と既存距離尺度を基に計算した Wi-Fi 距離との線形回帰の R^2 値

	線形回帰の R^2 値
平均絶対誤差 (MAE)	0.32
平均二乗誤差 (MSE)	0.25
ユークリッド距離	0.20
ミンコフスキ距離	0.27
チェビシェフ距離	0.28
相関距離	0.14

行っている。一方本研究では、2つの受信機（スマートフォンなど）の間の物理的距離の推定を行う。

3. 距離推定のための検証

本研究では、信号の生データからニューラルネットワークによって学習された特徴に加え、既存距離尺度を用いて計算された Wi-Fi 距離を基に2地点間の物理的距離の推定を行う。本節では既存距離尺度とニューラルネットワークの入力に適した AP 信号の検証を行う。

3.1 既存距離尺度

教師あり・なし学習による屋内位置推定に関する先行研究では、既存距離尺度を用いて Wi-Fi 距離を計算している。そこで初めに物理的距離の推定に対する既存距離尺度の有効性について検証を行う。Google Galaxy Nexus を用いて大学のある建物内で既知の座標（51 地点）において Wi-Fi 信号情報の収集を行い、2 地点間の物理的な距離と2地点で収集された Wi-Fi 信号ベクトルから計算された Wi-Fi 距離との関係性を検証する。ここでは、 w_i と w_j 間の Wi-Fi 距離を以下の広く用いられている距離尺度によって計算する。

- 平均絶対誤差 (MAE): $\frac{1}{|\mathcal{A}|} \sum_{a_n \in \mathcal{A}} |w_i(a_n) - w_j(a_n)|$
- 平均二乗誤差 (MSE): $\frac{1}{|\mathcal{A}|} \sum_{a_n \in \mathcal{A}} (w_i(a_n) - w_j(a_n))^2$
- ユークリッド距離: $\sqrt{\sum_{a_n \in \mathcal{A}} (w_i(a_n) - w_j(a_n))^2}$
- ミンコフスキ距離: $\left(\sum_{a_n \in \mathcal{A}} |w_i(a_n) - w_j(a_n)|^p \right)^{\frac{1}{p}}$,
($p = 4$)
- チェビシェフ距離: $\max_{a_n \in \mathcal{A}} |w_i(a_n) - w_j(a_n)|$
- 相関距離: $1 - \frac{(w_i(a_n) - \bar{w}_i(a_n)) \cdot (w_j(a_n) - \bar{w}_j(a_n))}{\|w_i(a_n) - \bar{w}_i(a_n)\|_2 \|w_j(a_n) - \bar{w}_j(a_n)\|_2}$,
ただし、 $\bar{w}_i(a_n)$ は $w_i(a_n)$ の平均ベクトルを表す。

また、 \mathcal{A} は w_i かつ w_j に含まれる AP の集合を表す。

表 1 に実際の物理的距離と既存距離尺度を基に計算した Wi-Fi 距離との線形回帰の R^2 値（決定係数）を示す。ただし Wi-Fi 距離の計算には、2.4GHz の Wi-Fi 信号のみを用いて計算している。この理由は後述する。線形回帰の決定係数は MAE の場合が最も高く、ある程度物理的距離と相

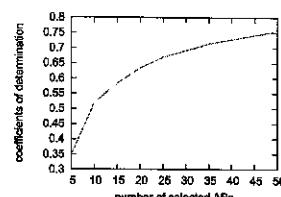


図 1 空間に AP 数が変化した場合の平均絶対誤差における R^2 値の変化

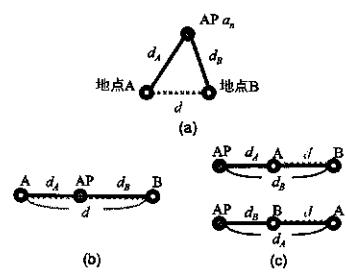


図 2 AP と AP からの信号が観測された地点との幾何的な関係

関があることがわかる。一方、広く用いられているユークリッド距離における決定係数は低かった。

3.2 用いる AP の数

AP は実環境において一様に分散していないため、観測される AP 数は場所によって異なる。ここでは、シミュレーションを用いて既存距離尺度の信頼性と距離計算に用いられる AP 数との関係性を検証する。このシミュレーションでは、障害物のない 100m × 100m の理想環境において 49 個の AP がランダムに配置され、AP の信号が式 3 に従って減衰すると想定する。この空間において、ランダムに選ばれた 100 地点で Wi-Fi 信号ベクトルを測定し、信号ベクトルの組間の MAE を計算する。その MAE と実際の物理的距離を基に線形回帰の決定係数である R^2 値を計算することができる。図 1 にシミュレーション空間内の AP 数が変化した場合の R^2 値の変化を示す。この結果から AP 数が少ない場合に R^2 値も小さいことがわかる。これは受信端末の周りにある AP 数が少ないと、計算された MAE の信頼性が低いことを示している。従って、Wi-Fi 距離をニューラルネットワークに入力する際に、計算した Wi-Fi 距離の信頼性を表す値（すなわち計算に用いた AP 数）も加えて入力することで、その距離の有用性を考慮した物理的距離推定が可能になると考える。

3.3 有用な AP

微弱な Wi-Fi 信号は不安定であるため、Wi-Fi 屋内位置推定に関する研究では、受信機の位置を推定するために強い Wi-Fi 信号のみを用いているものがある [3]。ここでは 2 地点間の距離推定における AP の有用性について検証を行う。ある対象環境内において AP (AP a_n) が存在し、図 2(a) のようにスマートフォンがその AP からの信号を 2 地点（地点 A と B）で受信すると仮定する。また、地点 A と B で観測された信号強度をそれぞれ $w_A(a_n)$, $w_B(a_n)$ とする。

本研究の目的は、図 2 の地点 A と B の間の距離 d を推定することである。 $w_A(a_n)$ または $w_B(a_n)$ から AP とある地点（地点 A と B）間の距離を推定できたとしても、地点

A と B の間の距離を一意に決めることは不可能である。しかしながら、AP と地点 A, B 間の距離から d の取りうる値の範囲を推定することは可能である。本研究の目的は小さな誤差で d を推定することであるため、取りうる値の範囲が小さい AP を使用したい。ここで図 2(b) は、 d の取りうる値が最大の場合を示している。このとき地点 A, AP, 地点 B がこの順で一直線上に並んでいるため、 d の取りうる最大値は以下の式で表される。

$$d_{max} = d_A + d_B, \quad (4)$$

ただし、 d_{max} は d の取りうる最大値を表し、 d_A は AP と地点 A の間の距離、 d_B は AP と地点 B の間の距離を表す。一方、図 2(c) は、 d の取りうる値が最小の場合を示している。 d の取りうる最小値は以下の式で表される。

$$d_{min} = \max(d_A, d_B) - \min(d_A, d_B), \quad (5)$$

ただし、 d_{min} は d の取りうる最小値を表す。式 4 と 5 から、 d の取りうる値の範囲すなわち $d_{max} - d_{min}$ は以下の式で表される。

$$d_{max} - d_{min} = 2 \min(d_A, d_B) \quad (6)$$

上述の通り、 d の取りうる値の範囲を小さくする AP すなわち $d_{max} - d_{min}$ を小さくする AP を利用したい。すなわち、 $\min(d_A, d_B)$ を小さくする AP を選択すればよい。式 2 から上記の選択基準は「 $\max(w_A(a_n), w_B(a_n))$ が大きい AP を選択する」という基準に解釈することができる。

本研究では、上記の幾何的な検証に基づく、「 $\max(w_A(a_n), w_B(a_n))$ が大きい AP を選択する」という基準に従って、ニューラルネットワークの入力に用いる AP を選択する。評価の節では、筆者らの AP 選択基準の有効性について検証する。

3.4 信号減衰特性

AP からの信号は AP からの距離だけでなく AP と受信端末の間の障害物によっても減衰する。物理的距離の推定において受信電波強度を利用する場合、障害物の影響のない信号を使うことが好ましい。これは、筆者らは機械学習ベースのアプローチを用いるため、距離推定を行いたい環境とトレーニングデータを収集する環境における障害物の密度が異なることが想定されるためである。ここでは 2.4GHz と 5GHz の Wi-Fi 信号に関する信号減衰特性を検証する。本研究では、広く用いられているデュアルバンド(2.4GHz と 5GHz 対応)AP に着目し、それらの信号特性の違いを利用して、AP と受信端末間の障害物の検出を行う。障害物の有無は、物理的距離の推定に有用な AP の発見に重要である。

図 3 は、AP とスマートフォン間に壁がある場合とない場合において、AP とスマートフォン間の距離を変化させ

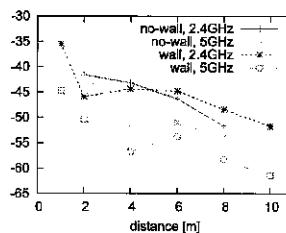


図 3 AP と受信端末間の距離が変化した場合のデュアルバンド AP からの 2.4GHz と 5GHz の信号強度の変化

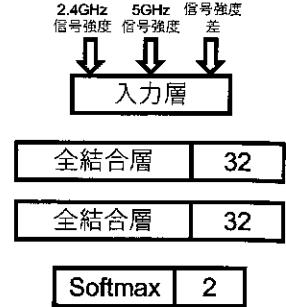


図 4 障害物の検出のためのニューラルネットワーク

表 2 壁検出のためのニューラルネットワークの分類結果

	precision	recall	f1-score
壁あり	0.98	1.00	0.99
壁なし	1.00	0.98	0.99
平均	0.99	0.99	0.99

た場合のデュアルバンド AP からの 2.4GHz と 5GHz の信号強度(約 80 スキャンの平均)の変化を示す。この結果から AP とスマートフォン間の距離を変化させた場合において、壁がない場合の方が 2.4GHz と 5GHz の信号強度の差が小さいことが分かる。

ここで、デュアルバンド AP と受信端末間の障害物(壁)を検出するニューラルネットワークについて検討する。この構造の検討は物理的距離の推定のためのニューラルネットワークを設計する上での参考になる。図 4 にその構造を示す。2.4GHz と 5GHz の信号強度および信号強度差を正規化後にニューラルネットワークに入力する。この単純なネットワークは、1 つの入力層、2 つの sigmoid 活性化関数を用いるノード数 16 の隠れ全結合層および壁ありなしの 2 値分類を行う softmax の出力層から構成される。

その構造の予備的な評価を行うために、スマートフォン(Google Galaxy Nexus)を用いて、3 つの異なる環境において壁あり・なしそれぞれの場合でデュアルバンド AP からの 2.4GHz と 5GHz 信号の観測を行った。

ネットワークを評価するために、leave-one-environment-out 交差検証を行う。この交差検証では、ある環境で収集されたデータをテストデータとして用い、残りの環境で収集されたデータをトレーニングデータとして用いる。表 2 は、分類結果を示しており、分類精度が非常に高いことがわかる。その結果から、単純なネットワークによってデュアルバンド AP からの信号を用いた障害物の検出が可能なことがわかる。

4. 距離推定手法

4.1 概要

図 5 に提案手法の概要を示す。提案手法では、異なる 2 地点(地点 A と B)で観測された 2 つの Wi-Fi ベクトル

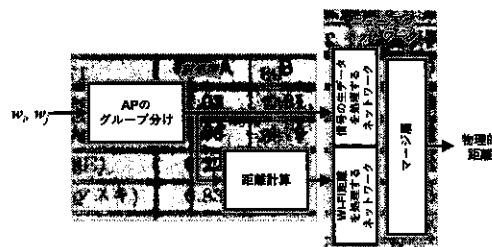


図 5 物理的距離推定のための提案手法概要

w_i と w_j が与えられると想定する。それぞれのベクトルは地点 A と B で観測された AP からの受信信号強度 (dBm) で構成される。また本研究では受信信号強度のばらつきによる影響を軽減するために同じ地点で複数回スキャンを行い、その平均を取った Wi-Fi ベクトルを w_i (w_j) として用いる。

本研究の目的は、Wi-Fi ベクトルを用いて 2 地点間の物理的な距離の推定を行うことである。本研究では、まず既存距離尺度を基に w_i と w_j 間の Wi-Fi 距離の計算を行う。検証実験に基づき Wi-Fi 距離の計算には観測された 2.4GHz の信号をすべて用いる。計算された Wi-Fi 距離と生の信号強度情報は正規化の後、物理的距離推定のためのニューラルネットワークに入力される。図 5 に示す通り、提案するネットワークは主に信号の生データを処理するネットワークと Wi-Fi 距離を処理するネットワークで構成される。Wi-Fi 距離のネットワークでは既存距離指標により計算された Wi-Fi 距離を組み合わせて有用な距離尺度を学習する。一方、信号の生データのネットワークでは、信号強度情報から直接物理的距離を推定するための特徴を学習する。

4.2 AP のグループ分け

Wi-Fi 距離を計算する前に観測された全 AP から以下の 2 つのグループを作成する。1) 2.4GHz の AP のグループ 2) 2.4GHz と 5GHz 両対応のデュアルバンド AP のグループ。デュアルバンド AP のグループは 2.4GHz の AP のグループの部分集合である。2.4GHz の AP のグループに属する AP からの信号を用いて Wi-Fi 距離の計算を行う。デュアルバンド AP のグループは、AP と受信端末間の障害物の検出に用いられる。本研究では、2.4GHz と 5GHz の BSSID の類似性からデュアルバンド AP を発見している。これは、BSSID の下 2 桁以外が一致する AP を同一の AP として扱っている。

4.3 Wi-Fi 距離計算

3.1 節では、様々な距離指標の有用性を検証した。また、2.4GHz の Wi-Fi 信号が物理的距離の推定に有用であることも明らかとなった。従って、2.4GHz 信号のみを用いて有用な Wi-Fi 距離を計算し、ニューラルネットの入力と

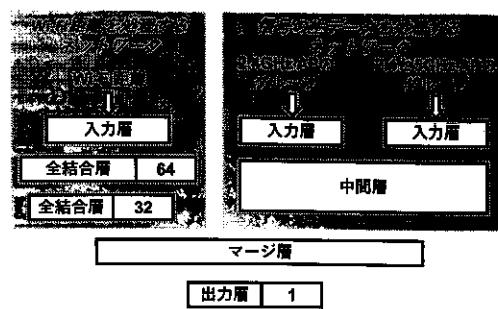


図 6 物理的距離推定のためのニューラルネットワークの構成

する。また、Wi-Fi 距離の計算に利用された AP の数が少ない場合、計算された距離の信頼性が低いことが明らかになった。そこで、計算した Wi-Fi 距離に加えて、Wi-Fi 距離を計算するのに用いた AP の数もネットワークに入力する。

4.4 ネットワーク構造

図 6 に物理的距離推定のためのニューラルネットワークの例を示す。ネットワークの入力は計算された Wi-Fi 距離と信号強度の生データである。これらの入力はそれぞれごとに用意された層に入力され、それらの出力はマージ層で結合される。出力層は最終的な物理的距離の推定結果を出力する。信号の生データを処理するネットワークの構成をいくつか用意し、評価の節でそれらを比較する。

4.4.1 Wi-Fi 距離を処理するネットワーク

MAE や MSE などの Wi-Fi 距離に加えて Wi-Fi 距離の計算に用いた AP 数を連結した入力ベクトルを構築する。Wi-Fi 距離の計算には観測された 2.4GHz の信号をすべて用いる。ネットワークは 2 層の全結合層からなり、それぞれの全結合層では活性化関数としてランプ関数（正規化線形関数）を用いる。

4.4.2 信号の生データを処理するネットワーク

3 節の検証結果を基に信号の生データを処理するネットワークを下記の通り 3 つ提案し、評価の節においてそれらを比較する。

- CnnRawD: 図 7 にその構造を示す。4.2 節で述べたように 2.4GHz と 5GHz の周波数を基に AP をグループ化する。2.4GHz の AP のグループにおいては 3.3 節で述べた AP 選択基準に従って k 個の AP を選択し、選択された AP の信号強度（選択基準を基に整列）からなる入力ベクトルを構築する。デュアルバンド AP のグループにおいては選択された各 AP の信号強度に加えて、2 地点（地点 A と B）それぞれにおける 2.4GHz と 5GHz の信号強度の差を入力層に入力する。2.4GHz とデュアルバンドのグループそれぞれごとに 1 層の畳み込み層からなるネットワークを用意し、それらの出力をマージ層で連結したあと、2 層の全結合

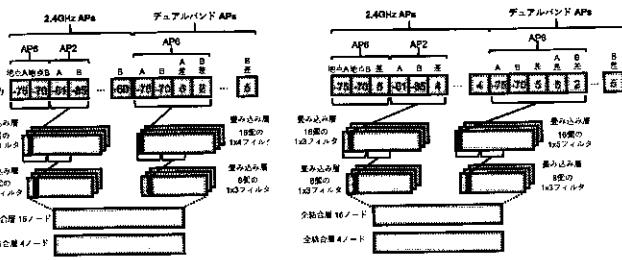


図 7 CnnRawD

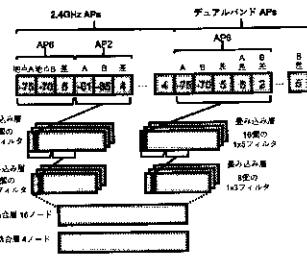


図 8 CnnRawDiffD

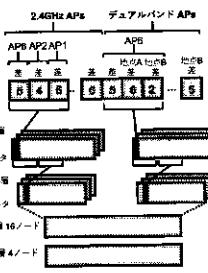


図 9 CnnDiffD

層で処理する。2.4GHz の AP のグループのための 1 層目の畳み込み層は、ストライド間隔が 2 の 1×2 のフィルタを 16 つ用いて特徴抽出を行う。またデュアルバンド AP のグループのための 1 層目の畳み込み層は、ストライド間隔が 4 の 1×4 のフィルタを 16 つ用いて特徴抽出を行う。

- CnnRawDiffD: 図 8 にその構造を示す。2.4GHz の AP のグループにおいては信号強度に加えて選択された各 AP の信号強度の絶対差を入力層に入力する。デュアルバンド AP のグループにおいては選択された各 AP の信号強度とそれらの絶対差に加えて、2 地点（地点 A と B）それぞれにおける 2.4GHz と 5GHz の信号強度の差を入力層に入力する。
- CnnDiffD: 図 9 にその構造を示す。2.4GHz の AP のグループにおいては選択された各 AP の信号強度の絶対差のみが入力層に入力される。デュアルバンド AP のグループにおいては選択された各 AP の信号強度の絶対差に加えて、2 地点（地点 A と B）それぞれにおける 2.4GHz と 5GHz の信号強度の差を入力層に入力する。

ここで、地点（A または B）で観測された AP の数が k よりも小さい場合は-100dBm で欠損値を補完する。

4.5 ネットワークの学習

正解距離と推定距離間の平均二乗誤差を最小化するよう、バックプロパゲーションを用いてネットワークの学習を行う。最適化アルゴリズムには学習率^{*1}を適応的に変化させることができ ADAM[5]を用いる。また、過学習を抑制するために dropout を利用する。dropout はトレーニング中にランダムに選んだノード（ニューロン）を無視して学習を進める正規化手法の一種である。

*1 学習率: ニューラルネットワークのパラメータを更新する割合を制御するパラメータ

表 3 実験環境の概要

環境	取得地点数	2.4GHzAP 数	デュアルバンド AP 数
A	54	98	17
B	26	57	13
C	51	88	17
D	53	38	5
E	54	31	2

環境	スキャンごとの 2.4GHzAP の平均数	スキャンごとの デュアルバンド AP の平均数
A	11.8	2.2
B	16.3	6.6
C	15.7	3.0
D	8.5	1.9
E	19.6	0

環境	最大距離 [m]	最小距離 [m]	平均距離 [m]
A	44.6	0.30	16.8
B	38.2	2.4	13.2
C	32.0	1.2	11.4
D	46.0	2.0	16.9
E	33.0	1.3	12.8

ニング中にランダムに選んだノード（ニューロン）を無視して学習を進める正規化手法の一種である。

5. 評価実験

5.1 データセット

本研究で用いる Wi-Fi データは筆者らの大学の 5 つの建物内で取得した。表 3 は、実験環境についてまとめたものである。「取得地点数」は各環境において Wi-Fi データの収集を行った地点の数を表す。「2.4GHz(デュアルバンド)AP 数」は各環境において収集した 2.4GHz(デュアルバンド)の AP の数を表す。「スキャンごとの 2.4GHz(デュアルバンド)AP の平均数」は各スキャンに含まれる 2.4GHz(デュアルバンド)AP の平均数を表す。「最大距離 (m)」は各環境における計測 2 地点間の最大距離を表す。「最小距離 (m)」は各環境における計測 2 地点間の最小距離を表す。「平均距離 (m)」は各環境における計測 2 地点間の平均距離を表す。

各環境の各地点において、Google Galaxy Nexus を用いて約 2Hz のサンプリングレートで 1 分間信号データを収集した。記録した 2 地点間の全ペアの座標を用いて 2 地点間の距離を計算し、それを正解データとして用いる。本研究では、両地点で観測される AP の数が 4 個未満の 2 地点の組は無視している。これは、三角測量に基づく Wi-Fi 位置推定手法においても少なくとも 3 つの AP を必要とするためである。

5.2 評価方法

「leave-one-environment-out」交差検証を用いて評価を行う。この交差検証では、1 環境で得られた信号データをテストデータとして、残りの環境で得られた信号データを学習データとして用いる。提案手法の有効性を検証するた

表 4 Naive と既存距離尺度を用いた手法の推定距離の誤差 (MAE)

	環境 A	B	C	D	E	平均
Naive	7.03	6.81	6.01	6.68	6.31	7.03
SVR(MAE)	6.06	4.79	5.16	5.43	4.72	5.23
SVR(MSE)	6.22	4.59	5.22	5.27	4.57	5.17
SVR(ミンコフスキ)	6.83	4.86	5.72	5.56	4.81	5.56
SVR(チェビシェフ)	6.80	4.95	5.64	5.63	4.87	5.58
DnnDist	5.67	4.53	4.34	5.30	4.37	4.84

めに以下の比較手法を用意する。

- Naive: 学習データの平均距離を用いて物理的距離を推定する手法。
- SVR (MAE): 観測された全 AP を用いて計算した w_i と w_j 間の MAE から物理的距離を推定するためにサポートベクトル回帰 (SVR)[1] を用いる手法。
- SVR (MSE): SVR の入力として w_i と w_j 間の MSE を利用する手法。
- SVR (ミンコフスキ): SVR の入力として w_i と w_j 間のミンコフスキ距離を利用する手法。
- SVR (チェビシェフ): SVR の入力として w_i と w_j 間のチェビシェフ距離を利用する手法。
- DnnDist: 図 6 の左上の Wi-Fi 距離を処理するネットワークと一致する手法。物理的距離推定を行うために 2 層目の全結合層の下に推定した物理的距離を出力する出力層を加える。本研究では、MSE, MAE と チェビシェフ距離を入力として用いる。
- 提案手法: 図 6 に示すネットワーク構造を利用する手法。このネットワークは既存距離尺度から計算された Wi-Fi 距離と信号強度の生データを組み合わせて入力として用いる。Wi-Fi 距離計算には MSE, MAE, チェビシェフ距離を用い、信号強度の生データの処理には 4.4.2 節で述べた CnnRawD, CnnRawDiffD, CnnDiffD をそれぞれ用いるものを用意する。

これらの手法の評価には推定距離と正解距離の平均絶対誤差 (メートル) を用いる。

5.3 評価結果

5.3.1 Naive と既存距離尺度を用いた手法

表 4 に Naive と既存距離尺度を用いた手法の推定距離の誤差 (平均絶対誤差) を示す。Naive の誤差のマクロ平均は 6.57m であった。一方、SVR(MAE) と SVR(MSE) における誤差が SVR の中で小さく、ほぼ同様の性能を達成していることがわかる。SVR(ミンコフスキ) と SVR(チェビシェフ) は、SVR(MAE) と SVR(MSE) と比べると全環境において劣っていることがわかる。MAE は Wi-Fi データのクラスタリングの研究において広く用いられており、この距離尺度が物理的な距離推定にも有用であることが確認された。

この結果では、環境 A と D における推定距離の誤差が

表 5 提案手法における推定距離の誤差 (MAE)

	環境 A	B	C	D	E	平均
CnnRawD	5.45	5.28	4.48	5.53	6.67	5.48
CnnRawDiffD	5.43	4.82	3.94	5.24	5.26	4.94
CnnDiffD	5.10	4.36	3.78	5.26	4.56	4.61

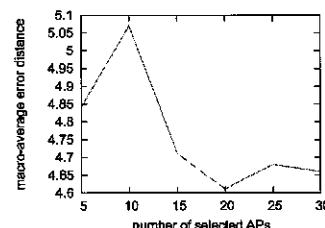


図 10 生データを処理するネットワークに用いる AP 数を変化させた場合の推定距離の誤差 (MAE) のマクロ平均

他の環境に比べて大きくなっている。これは、環境 A と D が他の環境よりも平均距離が長い (表 3 参照) ため、長距離における学習データ数が環境 A と D に含まれる長距離のデータ数に比べて不足してしまうからだと考えられる。

表 4 は DnnDist に関する推定距離の誤差も示している。DnnDist は SVR(MAE) と SVR(MSE) よりも誤差が小さく、SVR(MAE) と SVR(MSE) に比べて約 0.35m 小さい。

5.3.2 提案手法の結果

表 5 に提案手法の推定距離の誤差 (MAE) を示す。ここで、信号の生データを処理するネットワークではどの手法も AP 選択基準に従って選択された 20 個の AP を用いている。一方、Wi-Fi 距離を処理するネットワークではどの手法も Wi-Fi 距離の計算に観測された 2.4GHz の信号をすべて用いている。信号の生データを処理するネットワークで選択する AP の数と Wi-Fi 距離計算に用いる AP の数についての評価はそれぞれ 5.3.3 節と 5.3.4 節で行う。CnnRawD よりも CnnRawDiffD の方が誤差が小さく、CnnDiffD はさらに誤差が小さいことがわかる。これは物理的距離の推定には信号強度の差が有用であり、生の信号強度のデータから有用な距離指標を学習することが困難であったことを示している。

提案手法の結果と Naive や SVR の結果を比較すると、信号強度の差を入力とした提案手法はどの場合も Naive や SVR より距離の誤差が小さいことがわかる。提案手法で最もよい CnnDiffD を用いた手法では、SVR(MSE) や SVR(MAE) に比べて誤差が約 0.6m 小さくなっている。

5.3.3 生データを処理する AP 数

信号の生データを扱うネットワークでは AP 選択基準に従って k 個の AP を選択する。本節では、その選択する AP 数について検証を行う。

図 10 に AP 数を変化させた場合の推定距離の誤差 (MAE) のマクロ平均を示す。評価手法として信号の生データを処理するネットワークを CnnDiffD とする提案手法を用いた。表から選択する AP 数は少ない場合は誤差が大きくなるこ

表 6 WiFi 距離計算に用いる AP 数を変化させた場合の距離の誤差 (MAE) のマクロ平均の変化

	AP 数 5	10	15	20	全て
SVR(MAE)	5.26	5.26	5.24	5.23	5.23
SVR(MSE)	5.27	5.20	5.18	5.17	5.17
DnnDist	4.87	4.90	4.91	4.91	4.84
提案手法	4.80	4.73	4.67	4.66	4.61

表 7 提案 AP 選択基準による AP 選択とランダムな AP 選択の比較

	提案 AP 選択基準	ランダム
提案手法	4.61	4.87

とがわかる。AP 数が 20 の場合が最も誤差が小さく、それ以上は大きく変わらなかった。20 の場合が最も誤差が小さいのは、評価に用いた 5 つの環境において、スキャンごとの 2.4GHz の AP の平均数が最大がほぼ同数の数であるからだと考えられる(表 3 参照)。

5.3.4 距離計算に用いる AP 数

検証実験結果から WiFi 距離の計算には 2.4GHz の信号を全て用いている。本節では、WiFi 距離の計算に用いる AP 数について検証する。

表 6 に WiFi 距離計算に用いる AP 数を変化させた場合の距離の誤差 (MAE) のマクロ平均の変化を示す。評価手法として SVR(MAE), SVR(MSE), DnnDist と信号の生データを処理するネットワークを CnnDiffD とする提案手法を用いた。表から DnnDist 以外の手法で AP 数が増えるにつれて、誤差が減少している。一方で、DnnDist も AP 数 5 と 20 の場合でほとんど差はなく、AP 数が増えることによる精度の低下は起こらないことがわかる。観測された全 AP を用いた場合は全ての手法において最も誤差が小さく、観測された全 AP を用いることは有用であるとわかる。

5.3.5 AP 選択手法の効果

本節では、信号の生データを処理するネットワークで AP を選択する際に用いる提案 AP 選択基準について検証する。ここではランダムに AP を選ぶ場合を比較対象とする。

表 7 に提案 AP 選択基準による AP 選択とランダムな AP 選択の比較を示す。評価手法として信号の生データを処理するネットワークを CnnDiffD とする提案手法を用いて、推定距離の誤差 (MAE) のマクロ平均で比較を行った。提案 AP 選択基準に従っての AP 選択はランダムに選択する場合よりも誤差が小さく、提案 AP 選択基準の有効性が確認された。

6. おわりに

本研究では、機械学習を用いて WiFi の受信電波情報から測定された 2 地点間の物理的距離の推定を行う手法を開発した。今後は、再帰型ニューラルネットワーク (RNN)などを用いて入力できる AP 数が可変なネットワークを設

計して物理的距離推定精度の向上を目指す。

謝辞

本研究の一部は JSPS 科研費 JP16H06539 および JST CREST の助成を受けたものです。

参考文献

- [1] Debasish Basak, Srimanta Pal, and Dipak Chandra Patranabis. Support vector regression. *Neural Information Processing-Letters and Reviews*, 11(10):203–224, 2007.
- [2] Yanying Gu, Anthony Lo, and Ignas Niemegeers. A survey of indoor positioning systems for wireless personal networks. *IEEE Communications Surveys & Tutorials*, 11(1):13–32, 2009.
- [3] Taisei Hayashi, Daisuke Taniuchi, Joseph Korpela, and Takuya Maekawa. Spatio-temporal adaptive indoor positioning using an ensemble approach. *Pervasive and Mobile Computing (PMC)*, 2016.
- [4] Yifei Jiang, Xin Pan, Kun Li, Qin Lv, Robert P Dick, Michael Hannigan, and Li Shang. ARIEL: Automatic WiFi based room fingerprinting for indoor localization. In *Ubicomp 2012*, pages 441–450, 2012.
- [5] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [6] Anthony LaMarca, Yatin Chawathe, Sunny Consolvo, Jeffrey Hightower, Ian Smith, James Scott, Timothy Sohn, James Howard, Jeff Hughes, Fred Potter, et al. Place lab: Device positioning using radio beacons in the wild. In *Pervasive 2005*, pages 116–133, 2005.
- [7] Hui Liu, Houshang Darabi, Pat Banerjee, and Jing Liu. Survey of wireless indoor positioning techniques and systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 37(6):1067–1080, 2007.
- [8] Takuya Maekawa, Naomi Yamashita, and Yasushi Sakurai. How well can a user's location privacy preferences be determined without using gps location data? *IEEE Transactions on Emerging Topics in Computing*, 2014.
- [9] Teemu Pulkkinen, Teemu Roos, and Petri Myllymäki. Semi-supervised learning for WLAN positioning. In *ICANN 2011*, pages 355–362, 2011.
- [10] Masaya Tachikawa, Takuya Maekawa, and Yasuyuki Matsushita. Predicting location semantics combining active and passive sensing with environment-independent classifier. In *UbiComp 2016*, pages 220–231, 2016.
- [11] Daisuke Taniuchi, Xiaopeng Liu, Daisuke Nakai, and Takuya Maekawa. Spring model based collaborative indoor position estimation with neighbor mobile devices. *IEEE Journal of Selected Topics in Signal Processing*, 9(2):268–277, 2015.
- [12] Andreas Teuber, Bernd Eissfeller, and Thomas Pany. A two-stage fuzzy logic approach for wireless LAN indoor positioning. In *IEEE/ION Position Location Navigation Symposium*, volume 4, pages 730–738, 2006.
- [13] Junyang Zhou, KM-K Chu, and JK-Y Ng. Providing location services within a radio cellular network using ellipse propagation model. In *19th International Conference on Advanced Information Networking and Applications AINA 2005*, volume 1, pages 559–564, 2005.