

クラウドソーシングを活用した周波数データベースに関する研究

研究代表者

王 瀟岩

茨城大学 工学部 助教

1 まえがき

近年、無線機器の急激な増加によって、移動通信における周波数資源の不足が大きな問題となっている。現在の周波数割り当て方式では、プライマリシステムの通信を保護するため、周波数を排他的に利用する固定の割り当てとなっている。このような方式では時間・空間的に使用されない帯域が多数存在し、周波数利用効率の低下が生じてしまう。周波数の効率的な利用への有効的な手法として、動的な周波数共用 (Spectrum Sharing) 技術があり、その研究が進められている。周波数共用技術とは、プライマリシステムに干渉せずに、二次的に他の無線システム (セカンダリシステム) が同じ周波数を動的に利用するというものである。

周波数共用技術は米国ですでに実用化されている。2008年に米国でテレビ放送がアナログからデジタルへ移行し、それと同時に米国連邦通信委員会が未使用のテレビ放送の VHF/UHF 帯を開放したことで周波数共用技術が適用できるようになった。具体的には、セカンダリシステムは周波数共有の可否を電波環境データベースに問い合わせ、その地点で利用可能な周波数の情報を得る仕組みを使用する。データベースは伝搬モデルに基づいて推定された電波強度と、あらかじめ設定された閾値 (TV サービスについては -84dBm) とを比較することによって、周波数を二次的に利用可能かどうかを判断する。しかし、伝搬モデルに基づく電波強度の推定は、受信点周囲の構造物や地形の影響を考慮していないため、精度が低くなるという欠点が挙げられる [1]。

他の電波環境マッピング手法として、センサに基づくモニタリングによるものがある [2]。この手法では実環境の影響を考慮した推定が可能ではあるが、センサを大量に設置する必要があり、設置コストが高くなるのが課題となる。高精度かつコスト効率の良い電波環境マッピングをするため、クラウドソーシングに基づいた手法が近年提案された [3-7]。しかし、これらの既存の手法では推定誤差が大きいと、パフォーマンスの改善が必要となる。

そこで、本研究では機械学習とクラウドソーシングを組み合わせた電波環境マッピング手法を提案する。提案手法の概略を図 1 に示す。電波環境データベースはクラウドソーシングによりユーザーから異なる地点の受信電力の情報を収集し、これらのデータを用いて、推定点の電波強度をクリギング法で補間する。また、クリギングで補間する際、機械学習により測定点を分類し、推定点の伝搬特性と近い測定点を選択する。

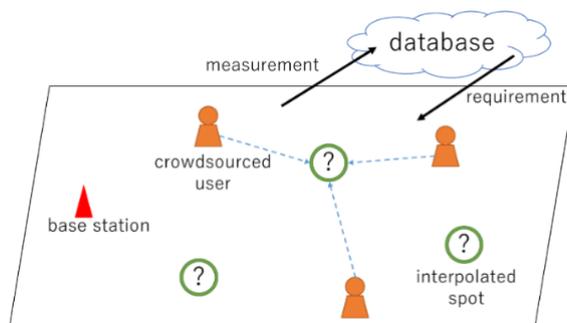


図 1 提案手法の概要

2 クリギング空間補間手法

本研究で用いている空間補間手法であるクリギングについて述べる。クリギングとは、周囲の計測値を加重して未計測の位置の値を予測するものである。2次元空間の点 (x_i, y_i) における値が $z_i = z(x_i, y_i)$ で表される。位置の集合 $\mathbf{N} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ が与えられたとすると、クリギングは重み付けされた既知値を用いて、次式から新しい位置の未知の値 \hat{z}_0 を予測することができる。

$$\hat{z}_0 = \sum_{i=1}^n \lambda_i z_i \quad (1)$$

ここで、 λ_i は正規化重み、つまり $\sum_{i=1}^n \lambda_i = 1$ である。最適な重み λ_i は、式(2)のように推定分散を最小となるように決定される。

$$\min_{\lambda_i} \text{Var}(\hat{z}_0 - z_0) \quad (2)$$

本研究では、通常クリギング(Ordinary Kriging : OK)とよばれる手法を用いた。OK では、次式のように z_i が定常性を満たしていると仮定する。

$$\begin{aligned} E[z_i] &= c \\ \text{Var}[z_i] &= \sigma^2 \end{aligned} \quad (3)$$

また、 $\phi_{(x_0, y_0)}(\mathbf{N})$ が式(2)における目的関数であるとする、 $\phi_{(x_0, y_0)}(\mathbf{N})$ は集合 \mathbf{N} の測定値を使用した地点 (x_0, y_0) の推定分散である。これを式(1)に代入することで次式が得られる。

$$\begin{aligned} \phi_{(x_0, y_0)}(\mathbf{N}) &= \text{Var} \left(\sum_{i=1}^n \lambda_i z_i - z_0 \right) \\ &= \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j C_{ij} - 2 \sum_{i=1}^n \lambda_i C_{i0} + C_{00} \end{aligned} \quad (4)$$

ここで、 $C_{ij} = \text{Cov}(z_i, z_j)$ 、 $\text{Cov}()$ は共分散関数を表す。

最小の $\phi_{(x_0, y_0)}(\mathbf{N})$ を見つけるために、セミバリオグラム γ_{ij} を用いる。 γ_{ij} は、2点間の値の差を距離の関数としてモデル化するものである。理論的にセミバリオグラムは次のように表される。

$$\gamma_{ij} = \frac{1}{2} E \left[(z_i - z_j)^2 \right] \quad (5)$$

式(3)のOK仮定に基づくと、 γ_{ij} は次のように表せる。

$$\gamma_{ij} = \sigma^2 - C_{ij} \quad (6)$$

式(6)を式(4)に代入すると、セミバリオグラム γ_{ij} を用いて $\phi_{(x_0, y_0)}(\mathbf{N})$ を以下の式で表すことができる。

$$\phi_{(x_0, y_0)}(\mathbf{N}) = 2 \sum_{i=1}^n \lambda_i \gamma_{i0} - \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j \gamma_{ij} - \gamma_{00} \quad (7)$$

ラグランジュ乗数法を使用することによって、以下の行列方程式の解より式(7)の最小値を求めることができる。

$$\begin{bmatrix} \gamma_{11} & \gamma_{12} & \cdots & \gamma_{1n} & 1 \\ \gamma_{21} & \gamma_{22} & \cdots & \gamma_{2n} & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \gamma_{n2} & \gamma_{n2} & \cdots & \gamma_{nn} & 1 \\ 1 & 1 & \cdots & 1 & 0 \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma_{10} \\ \gamma_{20} \\ \vdots \\ \gamma_{n0} \\ 1 \end{bmatrix} \quad (8)$$

ここで、 μ はラグランジュパラメータである。このように、セミバリオグラム γ_{ij} が分かれば、最適な重み λ_i を求めることができる。実際には、 γ_{ij} は測定値から推定され、指数モデルや球面モデルなどの経験的な曲線で適合される。最小化された $\phi_{(x_0, y_0)}(\mathbf{N})$ は、集合 \mathbf{N} における測定値を用いた未測定地点 (x_0, y_0) の推定の不確定性を表している。

3 提案手法

3.1 提案手法の概要

本研究では、推定点を補間する(クリギングを行う)前に、使用する測定値をあらかじめ機械学習技術を用いて選び出すようにした。提案手法の流れとしては、まず、OKの仮定を満たすために、伝搬損失のデータからシャドウイングによる減衰の部分を取り出す。次に、機械学習を用いて測定点を分類し、推定点と近いシャドウイング特性を持つと判定された測定値のみを推定に使うようにした。このようにクリギングに用いる測定点を選択することで、推定点の推定精度が向上できると考えられる。推定手法に関する流れを図2に示す。提案手法に関する箇所は赤い表示とした。

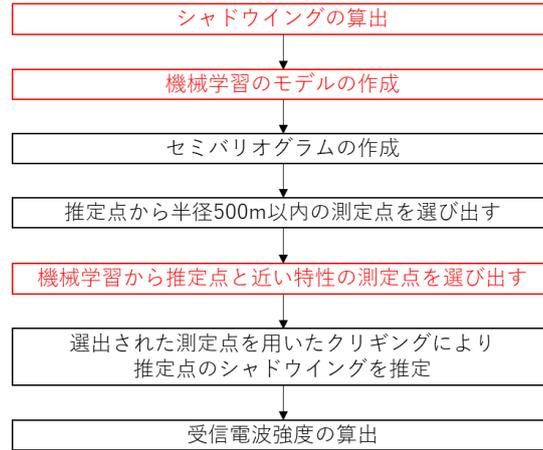


図 2 提案手法の流れ

3.2 シャドウイングによる減衰の算出

まず、伝搬損失 PL を以下の式で定義する。

$$PL = P_t - P_r \quad (9)$$

ここで、 P_t は送信電力、 P_r は受信電力を表す。本研究では、伝搬損失 PL を距離による減衰 $PL(d)$ と、シャドウイングによる減衰 $PL(s)$ に分けて考える。

$$PL = PL(d) + PL(s) \quad (10)$$

ここで、 $PL(d)$ は次式を用いて算出し、 $PL(s)$ がクリギングで推定する部分となる。

$$PL(d) = 10\bar{\alpha} \log_{10} d \quad (11)$$

ここで、 d は送受信点間の距離を表す。また $\bar{\alpha}$ は平均伝搬損失指数であり、式(12)(13)のように、各測定点の伝搬損失指数 α_i の平均をとることで求められる。

$$\alpha_i = \frac{P_t - P_{ri}}{10 \log_{10} d_i} \quad (12)$$

$$\bar{\alpha} = \frac{\sum_{i=1}^n \alpha_i}{n} \quad (13)$$

3.3 学習分類器の作成

本研究では、伝搬特性の分類のために2種類の機械学習メカニズムを用いた。

3.3.1 CNN

まず、一つ目の畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を用いる学習手法について述べる。CNNは、畳み込み層とプーリング層とよばれる2種類の層を、交互に積み重ねた構造を持つフィードフォワード型のニューラルネットワークである。ニューラルネットワークの大きな特徴として、学習データから認識に用いる特徴量を自動的に抽出できるという点がある。そのため、パターン認識に優れており、特にCNNは画像認識において高い性能が示されている[8]。本研究で使用するCNNの構造は、畳み込み層、プーリング層、畳み込み層、畳み込み層となっている。各畳み込み層の詳細としては、フィルタサイズはすべて5とし、フィルタの数は20, 40, 80と層ごとに変更した。

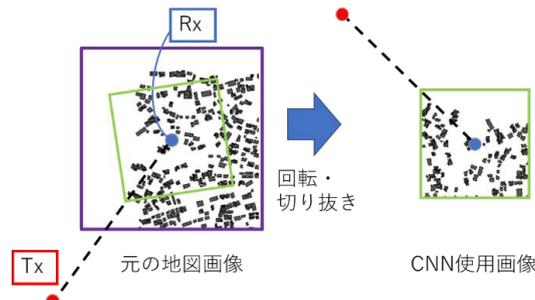


図 3 CNNの入力地図画像

CNN の入力には受信点周辺の地図画像を直接に用いた。地図画像の例を図 3 に示す。用いた画像は、送信点の方向が左上となるように回転させている。また、画像のサイズは縦 50 ピクセル、横 50 ピクセルで範囲 150m × 150m 相当となるように画像処理をした。また、二値画像とし建物がある地点が黒、それ以外が白となっている。

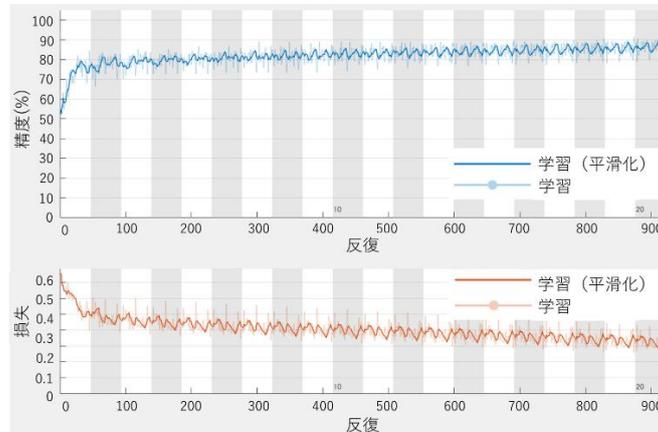


図 4 CNN 学習の収束特性

CNN 学習の収束特性を図 4 に示す。学習の回数が進むにつれて、精度が向上し、損失が減少していることがわかる。

3.3.2 決定木

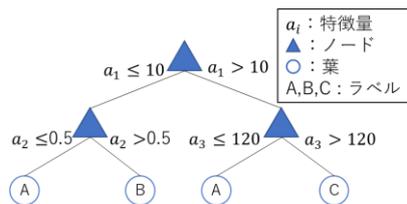


図 5 決定木の例

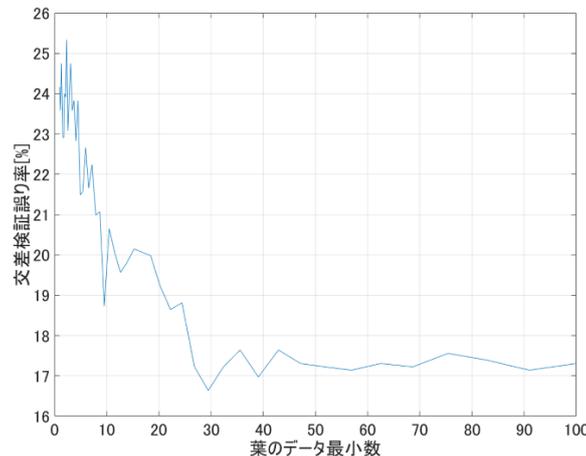


図 6 過学習の抑制

次に二つ目の決定木(Decision Tree)を用いる学習手法について述べる。決定木とは、木構造を用いて分類や回帰を行う機械学習の手法の一つである。決定木の例を図 5 に示す。決定木のデータ分岐部分をノード、最終的に分類されたデータが行き着く部分を葉とよぶ。決定木のノードの設定の仕方にはいくつかのアルゴリズムが存在するが、本研究では CART(Classification and Regression Tree)法とよばれるアルゴリズムを用いている。CART 法では過学習を抑制する必要があるため、葉に当てはまるデータ数が一定以上になるようにノードの数を減らす手法を用いている。葉のデータ最小数を増加させたときの交差検証の誤り率を求め、最も誤り率が小さくなるのが最適であるとした。この過学習抑制法で、最適な葉のデータ最小数を求めた

例を図 6 に示す。この場合は、葉のデータ最小数が 29 の時が最適であるとなっている。

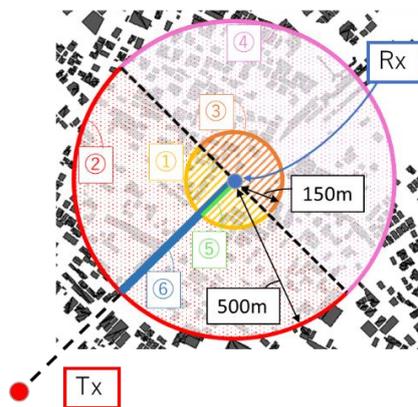


図 7 決定木の入力特徴量

決定木は CNN と異なり、学習に用いる特徴量を人工的に与える必要がある。本研究では電波伝搬の特徴から、送信点方向の半径 150m, 500m 以内の建物占有率 (①②)、送信点と反対方向の半径 150m, 500m 以内の建物占有率 (③④)、送信点方向の直線 150m, 500m 上の建物の割合 (⑤⑥) の 6 つの特徴量を設定した。特徴量を地図画像上で表したものを図 7 に示す。

3.3.3 ラベル付け

機械学習分類器には、データとラベルのペアが必要となる。上記の二つの学習手法には、3.2 章で求めたシャドウイングによる減衰に基づくラベルが付けられる。ラベルの付け方は 2 パターンを考慮した。一つ目は、シャドウイング減衰が中央値より大きい場合を”0”に、小さい場合を”1”にする、ラベル 2 種のパターンとした。二つ目は、一つ目のラベル分けをした上で、シャドウイングが中央値から中央絶対偏差の 3 倍以上離れている値 (外れ値) を”2”とする、ラベル 3 種のパターンとした。このラベル分けによって伝搬特性の分類を行う。

4. シミュレーション条件

本研究では、実環境に近い受信電波強度のデータを得るためにレイトレース法を用いた伝搬特性解析を行い、測定値を得た。レイトレースシミュレーションにはイメージング法によるレイトレースソフトウェア RapLab[9]を使用し、地図情報には茨城県日立市の 3D 建物データを用いた。シミュレーションのパラメータを表 1 に示す。また、設置した送受信点の位置を地図上に表したものを図 8 に示す。

表 1 シミュレーションパラメータ

Parameter	Value	Unit
Frequency	515	MHz
Transmission power	3	W
Transmission antenna height	100	m
Reception antenna height	1.5	m
Maximum number of reflections	3	
Maximum number of diffraction	2	
Maximum total number of reflections and diffractions	3	
Reception radius	150	m
Number of receiving points	11957	



図 8 送受信点位置

5. シミュレーション結果と考察

5.1 受信電力の分布

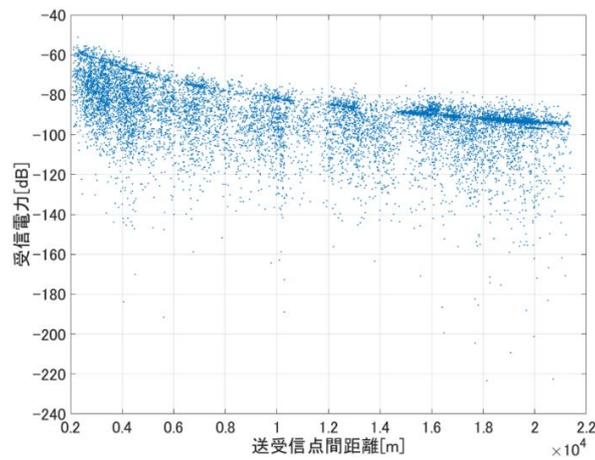


図 9 受信電力の分布

レイトレースシミュレーションによって求めた受信電力と送受信点間距離の相関図を図 9 に示す。図 9 のように、送受信点間の距離が同じであっても、受信電力の差が大きいため、推定点の近傍にある測定点を全て用いた補間では良い精度を得ることは困難であると考えられる。

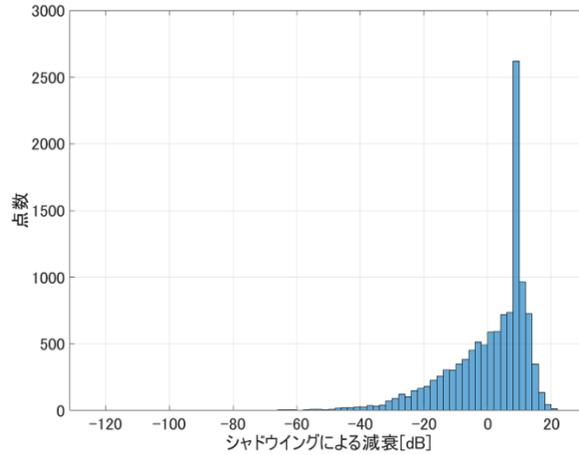


図 10 シャドウイングによる減衰のヒストグラム

次に、図 10 にシャドウイングによる減衰部分のヒストグラムを示す。図 10 からわかるように、シャドウイングによる減衰が非常に大きい点が存在するため、これらの点を用いてクリギングで推定すると精度が低下してしまうと考えられる。これらの結果から、クリギングに使用する点の選択で機械学習メカニズムを使用し、推定点の伝搬特性と近い測定点を選び抜くことが必要であるとわかった。

5.2 機械学習分類器の精度

次に、測定点から作成した CNN および決定木分類器を用いた、推定点のシャドウイング減衰特性の分類精度を調査した。シミュレーションを 10 回行った、分類精度の平均結果を図 11 に示す。それぞれの機械学習手法について、測定点の割合を変化させたときの推定点の分類正確率を求めた。また、2 パターンのラベルの付けかたそれぞれについて正確率を比較した。分類正確率とは、推定点の実際の受信電力の値によって付けられたラベルと、入力特徴量によって機械学習で推定され付けられたラベルが一致している確率を示す。どの手法でも、測定点が増加すると分類精度が上昇することが確認できた。また、分類のラベル数を 3 つに増やすと精度は 8%ほど低下していた。CNN と決定木を比較すると、ラベルの種類にかかわらず、決定木のほうが良い分類精度を持つことがわかった。

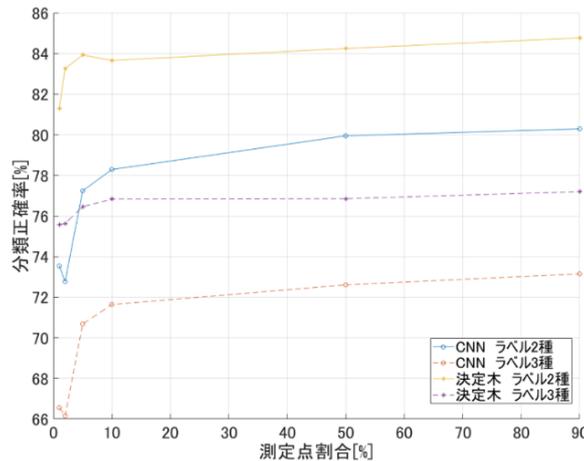


図 11 分類器の精度

5.3 受信電力推定精度の比較

最後に、測定点の割合を変化させたときの、推定点の受信電力の推定精度を評価した。測定点の割合は 10%, 50%, 90%とした。クリギングによる受信電力の推定精度を調査するために、推定値とシミュレーションによる実測値との差を推定誤差として評価に用いた。また、クリギングに機械学習を用いることの有効性を検証するため、機械学習を行わなかった手法、CNN を用いた手法、決定木を用いた手法を比較した。

まず、分類ラベルが 2 種類のパターンの推定誤差を、測定点割合ごとに箱ひげ図にしたものを図 12 に示す。箱内の赤線は中央値を示し、箱の大きさで四分位範囲を示している。推定誤差の外れ値は表示してい

ない。どの手法においても、測定点の割合が大きくなるほど、推定誤差の中央値や分散が小さくなる傾向があることを確認できた。機械学習を用いた二つの手法では推定誤差の中央値が小さくなっていることがわかる。しかし、分散を見ると CNN を用いた手法は機械学習を用いない場合よりも誤差のばらつきが大きくなってしまっていた。一方、決定木は分散も小さくなっており、決定木を用いた手法が最も良い性能を示している。次に、分類ラベルが 3 種類のパターンの推定誤差を図 13 に示す。おおまかな特性はラベルが 2 種類のパターンと同じであり、機械学習を用いると推定誤差が小さくなった。ただし、CNN はラベルを増やすことで分散が小さくなる傾向が見られた。

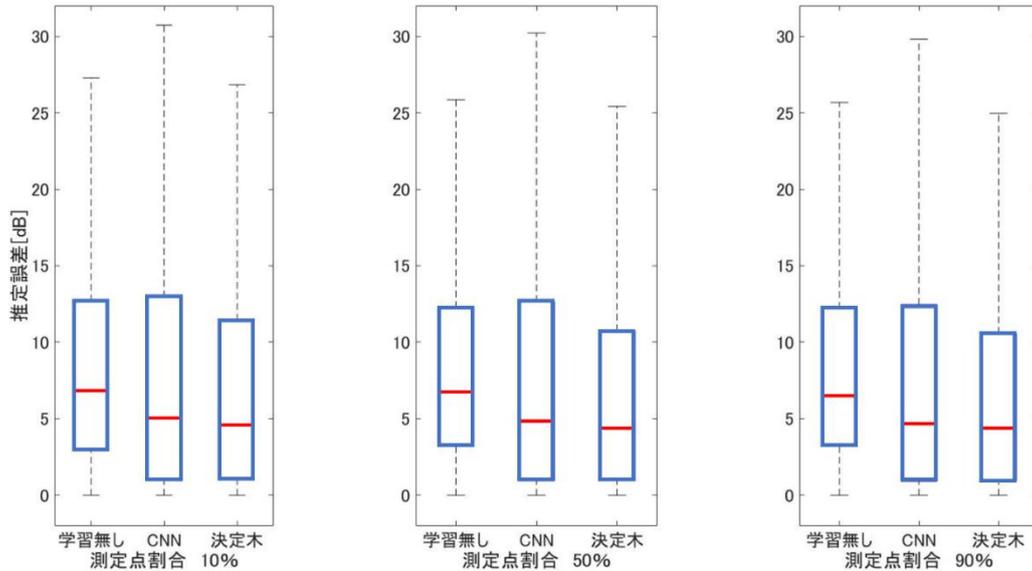


図 12 ラベル 2 種類の場合の推定誤差

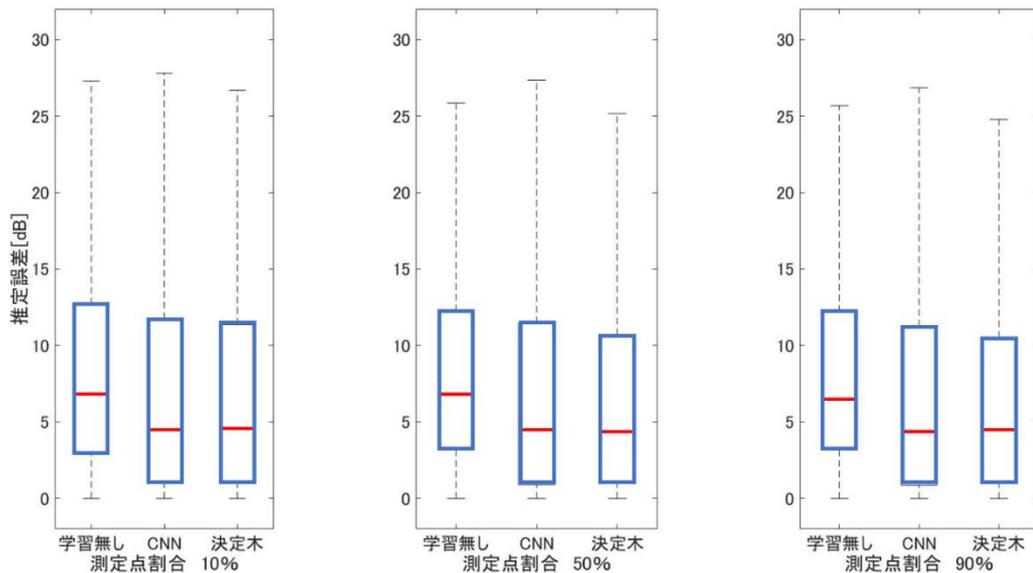


図 13 ラベル 3 種類の場合の推定誤差

6. まとめ

本研究では、機械学習を利用し、伝搬特性により測定点の分類を行った上で、推定点の電波強度を補間する電波環境マッピング法を提案した。シミュレーションの結果により、提案した機械学習を用いる手法が有効であることを示した。

【参考文献】

- [1] XuhangYing, Chang Wook Kum, Sumit Roy, “Revisiting TV Coverage Estimation with Measurement-based Statistical Interpolation”, 2015 7th International Conference on Communication Systems and Networks (COMSNETS), May 2015.
- [2] C. Phillips, M. Ton, D. Sicker, and D. Grunwald, “Practical radio environment mapping with geostatistics,” in Proc. of 2012 IEEE International Symposium on Dynamic Spectrum Access Networks, Oct 2012, pp. 422–433.
- [3] D. H. Shin, S. He, and J. Zhang, “Joint sensing task and subband allocation for large-scale spectrum profiling,” in Proc. of 2015 IEEE Conference on Computer Communications, April 2015, pp. 433–441.
- [4] X. Wang, M. Umehira, P. Li, Y. Gu and Y.Ji, “Fine-grained Incentive Mechanism for Sensing Augmented Spectrum Database”, in Proc. of 2017 IEEE Global Communications Conference, December 2017.
- [5] X. Wang, M. Umehira, P. Li, Y. Gu and Y. Ji, “Incentivizing Crowdsourcing for Exclusion Zone Refinement in Spectrum Sharing System”, in Proc. of Asia-Pacific Conference on Communications, December 2017.
- [6] S. Chaudhari et al, “Spatial Interpolation of Cyclostationary Test Statistics in Cognitive Radio Networks: Methods and Field Measurements”, in IEEE Transactions on Vehicular Technology, vol. 67, no. 2, pp. 1113-1129, Feb. 2018.
- [7] A. Chakraborty and S.R.Das, “Measurement-augmented spectrum databases for white space spectrum,” in Proc. of ACM CoNEXT, pp. 67-74, 2014.
- [8] 麻生英樹ほか(2015)『深層学習』近代科学社
- [9] 「電波伝搬解析ツール RapLab」 <<http://network.kke.co.jp/products/raplab/>>

〈発表資料〉

題名	掲載誌・学会名等	発表年月
Fine-grained Incentive Mechanism for Sensing Augmented Spectrum Database	IEEE Global Communications Conference	2017年12月4日
Incentivizing Crowdsourcing for Exclusion Zone Refinement in Spectrum Sharing System	Asia-Pacific Conference on Communications	2017年12月11日
Learning-based Radio Environment Mapping	International Workshop on Smart Wireless Communications	2018年10月30日
機械学習を用いた電波環境マッピング手法	電子情報通信学会スマート無線研究会	2019年3月6日