

## 機械学習を用いる無線リソース割り当て手法に関する一検討

相原 直紀<sup>†</sup> 安達 宏一<sup>†</sup> 田久 修<sup>††</sup> 太田 真衣<sup>†††</sup> 藤井 威生<sup>†</sup>

<sup>†</sup> 電気通信大学 先端ワイヤレス・コミュニケーション研究センター

〒 182-8585 東京都 調布市 調布ヶ丘 1-5-1

<sup>††</sup> 信州大学 電子情報システム工学科

〒 380-8553 長野県長野市若里 4-17-1

<sup>†††</sup> 福岡大学 電子情報工学科

〒 814-0180 福岡県福岡市城南区七隈 8-19-1

E-mail: <sup>†</sup>{aihara,adachi,fujii}@awcc.uec.ac.jp, <sup>††</sup>takyu@shinshu-u.ac.jp, <sup>†††</sup>maiohta@fukuoka-u.ac.jp

あらまし M2M 通信やモノのインターネット (IoT: Internet of Things) などの普及により無線ノードの高密度化が進んでいる。多数端末がランダムアクセスを用いて周波数を共用する環境で高信頼通信を実現するためには、端末間で生じる干渉を低減もしくは回避する必要がある。例えば、衝突回避機能付きキャリアセンス多元接続 (CSMA/CA: Carrier Sense Multiple Access/Collision Avoidance) をランダムアクセス方式として用いたときに、互いに送信を検知できない隠れ端末関係にある端末が存在した場合、パケットが衝突する。本稿では、パケット衝突により引き起こされるパケット配信率 (PDR: Packet Delivery Rate) の低減を回避するために機械学習を用いる検討を行う。検討システムでは、端末間のキャリアセンス可不可という不可視情報を端末の位置もしくは受信信号強度といった可視情報から機械学習を用いて推定する。機械学習により得られたキャリアセンスの可不可情報に基づいて直交する無線リソースを割り当てる。計算機シミュレーションにより提案法を用いることでランダムに無線リソースを割り当てた場合と比較して PDR を 15 % 改善できることを示す。

キーワード 周波数共用, 機械学習, 無線リソース割り当て

## A Study on Wireless Resource Allocation Using Machine Learning

Naoki AIHARA<sup>†</sup>, Koichi ADACHI<sup>†</sup>, Osamu TAKYU<sup>††</sup>, Mai OHTA<sup>†††</sup>, and Takeo FUJII<sup>†</sup>

<sup>†</sup> The University of Electro-Communications Advanced Wireless and Communication Research Center

1-5-1 Chofugaoka, Chofu-shi, Tokyo 182-8585

<sup>††</sup> Shinshu University dept.of Electrical and Computer Engineering

4-17-1, Wakasato, Nagano, 380-8553

<sup>†††</sup> Fukuoka University school of Electronics and Computer Science

8-19-1, Nanakuma, Jonan, Fukuoka 814-0180

E-mail: <sup>†</sup>{aihara,adachi,fujii}@awcc.uec.ac.jp, <sup>††</sup>takyu@shinshu-u.ac.jp, <sup>†††</sup>maiohta@fukuoka-u.ac.jp

**Abstract** Due to the wide spread of machine-to-machine (M2M) communications and Internet-of-things (IoT), more number of wireless nodes are density deployed. Under the dense deployment of wireless nodes, it is essential to manage the mutual interference among the wireless nodes. If carrier-sense multiple access/collision avoidance (CSMA/CA) is adopted as a random access scheme, some wireless nodes may not be able to carrier sense each other. The packet collision due to the hidden terminal problem may degrade the packet delivery rate (PDR). In this manuscript, we propose an orthogonal resource allocation scheme using machine learning. The information if the two wireless nodes are in the hidden terminal relationship is an unobservable information from network controller. By using the machine learning, the wireless controller estimates the unobservable information from the observable information such as the location of wireless nodes and the received signal strength. Then, based on the estimated information regarding the hidden terminal, orthogonal resources are allocated to the wireless nodes which are in the relationship of hidden terminal. The numerical evaluation elucidates that the proposed scheme can improve the PDR performance by 15% compared to the system without resource allocation.

**Key words** Frequency Sharing, Machine Learning, Wireless Resource Allocation

## 1. はじめに

近年、動画像伝送に代表されるマルチメディア通信やソーシャルネットワークサービス (SNS: Social Networking Service) の普及による通信の高速化への要求が高まっている。更に、IoT (Internet of Things) の普及に伴い、従来の H2H (Human-to-Human) 通信に加えて M2M (Machine-to-Machine) 通信が加速度的に増加している。M2M 通信の増加により、限られた無線周波数を多数の無線端末 (UE: User Equipment) が共用する環境が増加している。このような周波数共用環境下において優れた通信品質を達成するためには、無線伝搬路で生じる信号減衰に加えて UE 間で生じる相互干渉に対処しなければならない。そのためにスケジューリングや空間ビームフォーミング等が検討されているが、これらの技術は送受信機間のチャンネル状態等の明示的な情報通知が必須である。例えば、空間ビームフォーミングでは、送受信機間のチャンネルに整合した送信ビームを生成するために、受信機から送信機 (制御局) へチャンネル応答値もしくはビームインデックス等をフィードバックする必要がある。その情報通知により、貴重な無線周波数資源が逼迫されるという問題が存在する。

UE の周辺環境の情報を通知するオーバーヘッドを低減するために、機械学習を用いた無線資源割り当てが提案されている [1], [2]。機械学習を用いることにより、通信リソースの制御を行う制御局から直接観測することの出来ない“不可視情報”を制御局が直接観測することの出来る“可視情報”から推定する。これにより、不可視情報を制御局へと通知する必要がなくなるため、オーバーヘッドを削減することが可能となる。既存研究 [1], [2] では、基地局と端末間のチャンネル情報 (可視情報) から端末と他基地局間の観測できないチャンネル情報 (不可視情報) を推定することでオーバーヘッドを削減する方法が提案されている。

本研究では、ランダムアクセス方式の一つである CSMA/CA [4] に着目する。CSMA/CA では、各 UE が通信を行っている他 UE の有無をキャリアセンス (CS: Carrier Sense) により検出する。しかしながら、UE 間のチャンネルが障害物などの影響で落ち込んでいた場合にはキャリアセンスが正確に動作せず、通信中の他端末を検出できなくなるという“隠れ端末問題”が発生する。隠れ端末問題により、送信したパケットが衝突し、パケット損失が発生する。これにより周波数利用効率の劣化が生じる。互いにキャリアセンス不可能な UE に上位レイヤーで直交リソース (例えば時間スロット) を割り当てることで、パケット衝突を回避することが出来る。しかしながら、そのためには、制御局で不可視な端末間のキャリアセンス可否の情報が必要となる。そこで、本研究では、隠れ端末問題により引き起こされる周波数資源の利用効率低下を回避するために、機械学習を用いた無線リソースの割り当て方式を提案する。提案手法では、機械学習のひとつであるサポートベクターマシン (SVM: Support Vector Machine) [5] を用いることで UE 間のキャリアセンスの可否を推定する。学習段階において UE の位置に対しての UE 間のキャリアセンス状況を学習することで、それ以

降は UE からのフィードバックなしに UE に対して直交リソースを割り当てることができ、周波数利用効率を向上させることができる。

本論文は以下の構成になっている。第 2 章で既存研究について説明し、第 3 章で本研究で用いた既存技術について説明する。第 4 章で提案手法である SVM を用いた無線リソース割り当てについて説明する。第 5 章で計算機シミュレーションの結果について説明し、第 6 章で本論文のまとめを行う。

## 2. 既存研究

既存研究 [1], [2] では、チャンネルモデルとして GSCM (Geometric Stochastic Channel Model) [3] を想定している。このモデルでは、それぞれのチャンネル応答はそれぞれ全単射な写像として表されるため、観測可能なチャンネルから観測不可能なチャンネルへの対応関係を得ることができ、観測可能チャンネルから観測不可能チャンネルを推定することが可能になる。UE の位置を  $\mathbf{x}$ 、観測可能なチャンネル応答を  $\mathbf{h}_o$ 、観測不可能なチャンネル応答を  $\mathbf{h}_u$  と表記する。基地局の位置は常に固定であるためチャンネル応答は UE の位置  $\mathbf{x}$  によって一意に決定される。そのため、それぞれのチャンネル応答は次式のように表すことができる。

$$\begin{cases} \mathbf{h}_o = g_o(\mathbf{x}) \\ \mathbf{h}_u = g_u(\mathbf{x}) \end{cases} \quad (1)$$

ここで、 $g_o(\cdot)$  と  $g_u(\cdot)$  は全単射 (1 対 1 対応の写像) 関数である。これらの対応には一対一対の関係があるため逆関数が存在するので、 $\mathbf{x} = g_o^{-1}(\mathbf{h}_o)$  とすることで次式のように、観測可能チャンネルから観測不可能チャンネルを求めることが可能となる。

$$\mathbf{h}_u = g_u(g_o^{-1}(\mathbf{h}_o)) \quad (2)$$

機械学習ではこの対応関係を用いて、観測可能チャンネルから観測不可能チャンネルを推定する。

### 2.1 最適基地局の選択 [1]

文献 [1] では、マクロ基地局とスモール基地局が混在するヘテロジニアスネットワーク (Het Net: Heterogeneous Network) において、UE がデータの送受信を行うスモール基地局を選択するためにニューラルネットワーク (NN: Neural Network) を用いた検討が行われている。マクロ基地局が制御局として動作し、各端末が接続するスモール基地局を決定する。これによって、各端末と各スモール基地局間のチャンネル状態の推定を行う必要がなくなるため、接続先選択に必要なオーバーヘッドを低減できる。式 (2) において UE とマクロ基地局のチャンネル応答を  $\mathbf{h}_o$  とし、UE と第  $i$  スモール基地局のチャンネル応答を  $\mathbf{h}_{u,i}$  として定義する。これにより、UE と各スモール基地局との間のチャンネル状態を推定することなく割り当てが可能となる。計算機シミュレーションにより平均 74% の精度で最適なスモール基地局を割り当てることが出来ることが示されている。

### 2.2 最適ビームフォーミングの選択 [2]

文献 [2] では、無線リソースの割り当てを行う制御基地局と UE との通信を担当する通信基地局の混在するネットワー

クにおいて、超多数アンテナ素子 (Massive MIMO: Massive Multiple-Input Multiple-Output) によるビームフォーミング重み決定のために NN を用いた検討が行われている。通信基地局におけるビームフォーミング重みにはあらかじめ有限個の重みが用意されているものとする。式 (2) において UE と制御基地局のチャネル応答を  $\mathbf{h}_o$  とし、UE と通信基地局のチャネル応答を  $\mathbf{h}_{u,i}$  として定義する。また、これの次段に UE と通信基地局のチャネル応答から最適ビームフォーミング重みの学習を行う推定器を連結することで、観測可能な応答から最適ビームフォーミング重みの推定を行う。計算機シミュレーションにより、最大 99.74% の精度で最適なビームフォーミング重みを割り当てることができることが示されている。

### 3. 既存技術

#### 3.1 CSMA/CA 方式

複数の端末が同一のチャンネルにランダムアクセスする場合、送信パケットが互いに衝突する可能性がある。パケット衝突が発生した場合には、端末がパケットの再送を行わなくてはならないため、周波数利用効率が低下する問題がある。ランダムアクセス方式の一つである CSMA/CA では端末が CS を行うことでチャンネルの使用状況を判別し、自律分散的にチャンネルを共有することができる。しかしながら、この方式には遮蔽物等による CS 失敗に起因するパケット衝突が発生する“隠れ端末問題”と呼ばれるものが存在する。この場合はパケット衝突により干渉が発生し、パケット伝送に誤りが生じる可能性がある。この問題の一般的な対策として、RTS/CTS (Request To Send/Clear To Send) 方式がある。これは UE がパケット送信を行う際、アクセスポイント (AP: Access Point) が RTS と CTS という二つの制御信号を送信することで、隠れ端末問題を回避する手法である。しかしながら、この方式では送信にかかるオーバーヘッドが増大するという問題がある。

#### 3.2 SVM

SVM はデータの分類を行う教師あり学習の一つである。教師あり学習 (Supervised Learning) は与えられたデータから学習を行い、その結果から未知のデータの分類、推論および帰帰を行う。SVM では入力データである「特徴量」と出力データである「学習ラベル」の組を学習データとして定義する。なお、特徴量とは SVM への入力変数のことであり、学習ラベルは与えられた特徴量に対しての出力である。本研究の場合は特徴量として端末の位置情報や電力情報、学習ラベルに端末間の CS 可否を定義する。

この学習法では「マージン最大化」を基準にデータの分離平面を決定する。「マージン」とはある分離平面に対して一番近いデータ (サポートベクター) までの距離のことである。これを最大化することで、学習の汎化性能を向上させることができる。

### 4. 提案方式

#### 4.1 学習モデル

本論文では SVM へ入力する特徴量として 2 つの UE の位置情報もしくは受信信号強度 (RSSI: Received Signal Strength

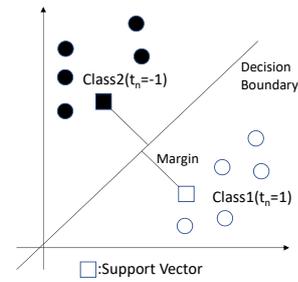


図 1 サポートベクターとマージン最大化

Indicator) を用いる。SVM のカーネル関数としては、線形カーネルとガウスカーネルを用いる。なお、線形カーネル  $k_{lnr}$  およびガウスカーネル  $k_{gs}$  は次式に示す通りである。

$$\begin{cases} k_{lnr}(\mathbf{x}_n, \mathbf{x}_m) = \mathbf{x}_n^T \mathbf{x}_m \\ k_{gs}(\mathbf{x}_n, \mathbf{x}_m) = \exp\left(-\frac{\|\mathbf{x}_n - \mathbf{x}_m\|^2}{2\sigma^2}\right) \end{cases} \quad (3)$$

ここで、 $\mathbf{x}_n$  を特徴量ベクトル (特徴量を列に並べたベクトル) とする。つまりカーネル関数は二つの特徴量ベクトルの組に対して作用することになる。SVM の出力となる学習ラベルには 2 つの UE 間のキャリアセンスの可否を用いた。学習段階においては 2 つの UE の組をランダムにシミュレーション領域内に配置し、その入力特徴量と学習ラベルを学習データとして収集する。その後推定段階では、 $J$  個の UE をランダムに配置し、得られた入力特徴量からそれぞれの UE 間でのキャリアセンス可否を SVM を用いて出力する。最終的な出力としては UE 間でのキャリアセンス可否を行列の形であらわした対称行列を出力する。

##### 4.1.1 複数 SVM の生成

本提案方式では、ランダムに配置された 2 つの UE の可視情報を用いて CS の可不可を推定する必要がある。UE1 が固定の場合、一つの SVM により十分な精度で推定が可能である。しかし、2 つの UE がランダムに配置される場合、SVM への入力が増しく変動し、推定精度が低くなる。そこで、図 2 に示すようにシミュレーションエリアを複数のグリッドに分割し、それぞれのグリッドにおいて異なる SVM を生成する。UE1 の位置もしくは RSSI によって使用する SVM を選択する方法を提案する。異なる特徴量を用いた場合のグリッド選択は以下のように決定する。

- 位置情報を特徴量とする場合: UE1 の二次元座標をそれぞれをグリッド幅で割り、その出力により所属グリッドのインデックスを決定する。
- 電力情報を特徴量とする場合: 以下の処理により所属インデックスを決定する。

- (1) 各 AP において、UE1 から AP までの電力と各グリッドアンカーノード (各グリッドの中心に配置された電力基準ノード) から AP までの電力の差を計算し、昇順にソート
- (2)  $i=1$  とする
- (3) AP は  $i$  番目に電力差が小さいグリッドに投票
- (4) 投票された数が一番多いグリッドを所属グリッドとする

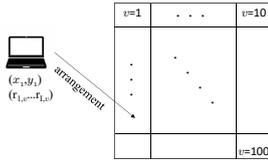


図2 SVMの分割と配置

(5) 投票数が最大のグリッドが複数ある場合は、 $i = i + 1$  としてただ一つ決定するまで投票を繰り返す

#### 4.2 無線リソース割り当てアルゴリズム

ここまでの説明で得られたCS状況の情報を用いて、APは各UEに対してそれぞれ上位レイヤーによって無線リソースを割り当てる。割り当てアルゴリズムを以下に示す。なお、割り当て可能なリソース数を  $K$  個とする。

- (1) 各UEに対して、CSできない他のUEの数をカウント
- (2) 1.の数をもとに降順にソート
- (3) 順に  $K - 1$  個の専用のリソースを割り当て
- (4)  $K$  番目以降のUEに対してはすべて同じリソースを割り当て

このような割り当てを行うことで、CS出来ないと推定されたUE、つまり衝突を起こしやすいUEに対して直交したリソースを割り当てることができる。 $K$  番目以降のUEは同じリソースを用いることになるが、これらは比較的互いにCSを成功しやすいため、CSMA/CAによるチャネル共用を利用して衝突を回避することができる。今回は割り当て方式として時分割多元接続 (TDMA: Time Division Multiple Access) を採用した。つまりUEはAPの指定した時間フレーム (例えば二つに分割する場合は奇数時間と偶数時間) にのみ送信を行う。

## 5. 数値結果

### 5.1 システムモデル

本論文では、シミュレーションエリア内にランダムに配置された  $J$  個のUEが固定配置された  $I$  個のAPに  $K$  個のTDMAリソースを用いてパケット送信を行う上りリンクを仮定する。通信路モデルとしては、伝搬距離に依存するパスロスと空間相関を持つウイングチャネル [6] に従うチャネルと RapLab [7] を用いたレイトレーシングモデルに従うチャネルの二つを仮定した。各UEはパケット生起率  $p_{\text{pkt}}=0.8$  でパケットを送信し、複数のUEが同時に同じ無線リソースを用いてAPへとパケットを送信した場合はAPにおいて衝突が発生する。APでは各UEから送信された信号の信号電力対干渉+雑音電力比 (SINR) を計算し、その値が閾値  $\Gamma$  を超えていれば復調されたものとする。なお、パケット伝送には適応変調を仮定し、各パケットの受信閾値は全BSに対する最大SNRによって変化し、PDRは次式で与えられる。

$$\text{PDR} = D/S \quad (4)$$

なお、 $D$  を各UEに対し最低一つのAPで復調できたパケット数、 $S$  を全UEが送信したパケット数とする。

### 5.1.1 空間相関を持つシャドウィングモデル

このモデルでは、基地局および端末での受信電力は次式で与えられる。

$$P_r = P_t - 10\alpha \log_{10} d - \beta - 10\gamma \log_{10} f - \eta \quad (5)$$

ここで、 $P_r$  を受信電力、 $P_t$  は送信電力、 $d$  は端末間距離 [m]、 $f$  は搬送波周波数 [GHz] である。また、 $\eta$  はそのグリッドにおける隣接グリッドと相関を持つ対数正規分布に従うシャドウィング減衰とする [6]。

### 5.1.2 レイトレーシングモデル

このモデルでは、送信局からのレイトレーシングにより受信波の電力、遅延、位相ずれを計算する。本論文で用いたレイトレーシングの障害物のレイアウトを図3に示す。なお、このモデルではレイトレーシングによりチャネルが決定されるため、任意の与えられた位置に対してのチャネルが決定できない。そのため、シミュレーションエリア内で1mごとに端末を配置し、配置したすべての端末において受信電力を決定する。その後、その中からランダムにデータを取り出し、SVMに入力した。今回のシミュレーションで用いた屋内モデルのレイアウトを図3に示す。

表1 シミュレーションパラメータ

UE数 $J$	3
直交リソース数 $K$	2
雑音電力密度	-174 [dBm/Hz]
帯域幅	10 [MHz]
キャリアセンス閾値	-82.0 [dBm]
AP数 $I$	1,2,3

表2 受信閾値

SNR	$\Gamma$ [dB]
$4 \leq \text{SNR} < 6$	4
$6 \leq \text{SNR} < 8$	6
$8 \leq \text{SNR} < 10$	8
$10 \leq \text{SNR} < 12$	10
$12 \leq \text{SNR} < 16$	12
$16 \leq \text{SNR} < 20$	16
$20 \leq \text{SNR} < 21$	20
$21 \leq \text{SNR}$	21

表3 チャネルモデルパラメータ (シャドウィング)

生成グリッド数	100
端末送信電力 $P_t$	10.0 [dBm]
搬送波周波数 $f$	2.4 [GHz]
シミュレーションエリア	100×100 [m <sup>2</sup> ]
伝搬損失距離係数 $\alpha$	3.5
伝搬損失周波数係数 $\gamma$	1.96
伝搬損失オフセット $\beta$	28.6
シャドウィング偏差	6.0 [dB]
シャドウィングエリアグリッド数	20×20
学習データ数	200,500,1000,5000,10000
テストデータ数	100000

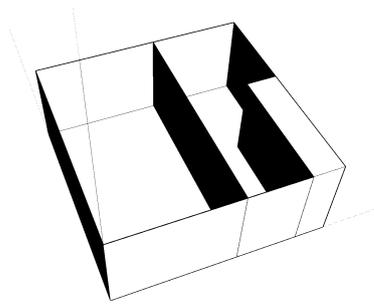


図3 レイトレーシングモデルでの障害物レイアウト

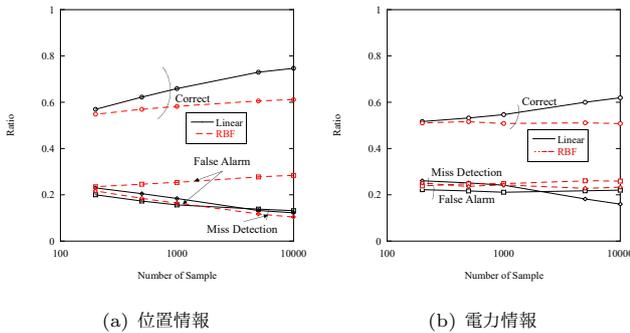


図4 CS 推定率

## 5.2 空間相関を持つシャドウィングモデルにおける評価

シャドウィングモデルにおいては、一方向のグリッド数は10、つまりシミュレーションエリア内に100個のSVMを作成してシミュレーションを行った。

### 5.2.1 CS 推定率の評価

図4に線形カーネル、ガウスクーネルの二つを用いた際のCS推定率、誤検知および検知漏れの割合を示す。これらの結果から、学習データを増加させることでCS推定率が向上していることが分かる。位置情報を特徴量として用いた場合には、学習データを10,000個とすることでおよそ80%の精度でCSの可否を推定できることがわかる。一方で、電力情報を用いた場合、推定精度は学習データ数の増加により向上するものの、位置情報を用いた場合より低い結果となった。この理由に関してはいくつかの理由が考えられる。

- 空間的に離散なシャドウィングチャンネルに対し、連続的な特徴量を用いるSVMを適用したため
- シャドウィングチャンネルによる電力変動による影響が、位置情報を用いる場合よりも強くなるため

### 5.2.2 PDR 特性

図5に位置情報、電力情報のそれぞれを用いて得られたCS可否の推定結果に基づいて無線リソース割り当てを行った

表4 チャンネルモデルパラメータ(レイトレーシングモデル)

生成グリッド数	1
基地局送信電力	10,0,-10,-20,-30[dBm]
搬送波周波数	5.0[GHz]
シミュレーションエリア	7×7[m <sup>2</sup> ]
学習データ数	177
テストデータ数	1593

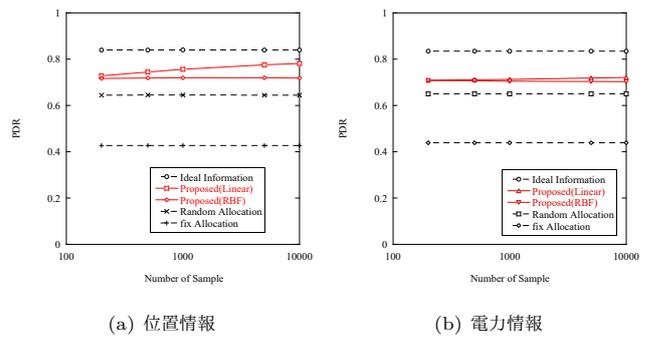


図5 PDR 特性

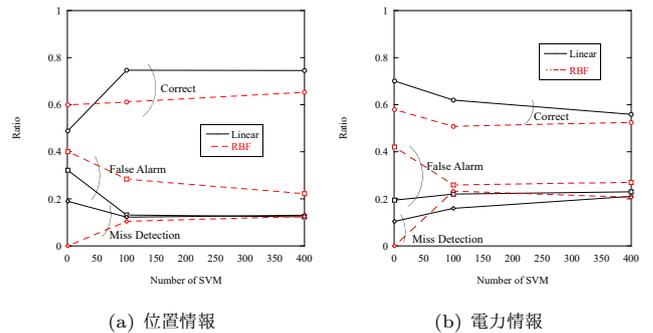


図6 グリッドサイズに対するCS 推定率

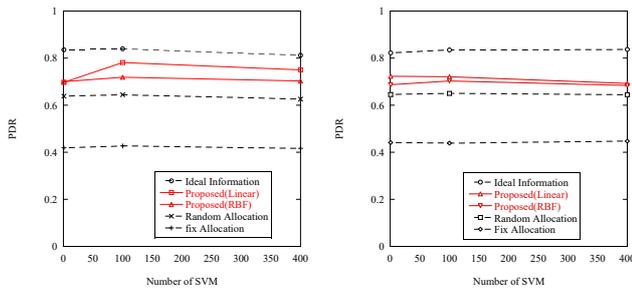
場合のPDRの特性を示す。これらの結果から、学習データの増加によりPDRを向上できることがわかる。学習データ数を10,000とすると、およそ80%のPDRを実現することができる。この時、不可視情報を用いないランダム割り当てを用いる場合と比較して約15%PDR特性を改善出来ており、理想的にCSの可否が推定出来た場合からの劣化は約6%である。電力情報を用いた際に特性が劣化するが、これは前節の推定精度の低さに起因するものだと考えられる。

### 5.3 グリッドサイズの影響

前節にて、学習データ数の増加に伴いPDR特性が向上することを示したが、これはSVMのグリッド幅によっても特性が変動する。UE1は指定されたグリッドの中ではランダムに配置されるため、それがSVMの入力に対して誤差として扱われてしまう。そのため、特性向上のためには可能な限り小さいグリッドサイズでSVMを作成することが必要になる。図6、図7にそれぞれ学習データサイズを10,000に固定し、SVM数を変化させた場合のCS特性およびPDR特性を示す。この結果より、先ほど説明したように、多くのSVMを作成する、つまりSVMグリッドサイズを小さくすることでCS推定精度が向上し、理想情報を得られた場合の特性に近づいていることがわかる。電力情報を用いた場合、グリッドサイズを小さくすることで特性が劣化しているが、これは前述のシャドウィングによるチャンネル変動の影響をグリッドに区切ることで抑制できなくなったためだと考えられる。

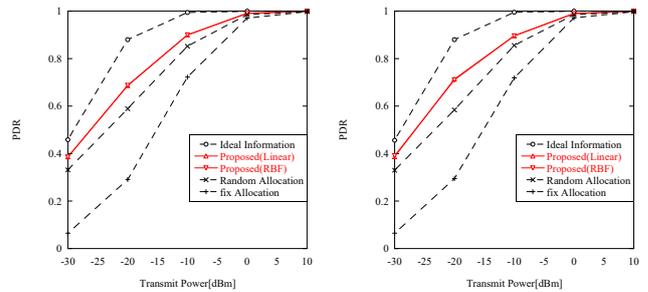
### 5.4 レイトレーシングモデル

以下ではレイトレーシングモデルでの評価を行った。なお、本節では送信電力を変化させた場合の特性について評価する。その理由として、シミュレーションエリアが小さいためPDR



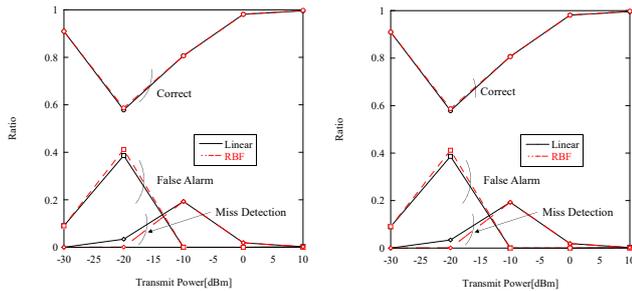
(a) 位置情報 (b) 電力情報

図7 グリッドサイズに対する PDR 特性



(a) 位置情報 (b) 電力情報

図9 PDR 特性



(a) 位置情報 (b) 電力情報

図8 CS 推定率

が学習データ数によらず 1 になるためである。

### 5.5 CS 推定率の評価

レイトレーシングモデルにおいて、SVM を用いた CS 推定率の評価を行った。図 8 に各入力特徴量を用いた CS 推定率を示す。これらを見てわかることとして、どちらのカーネル関数を用いても、一部の送信電力での設定を除いておよそ 80% ほどの CS 推定率を実現できていることがわかる。送信電力を  $-20$  [dBm] としたときに CS 推定率が大きく低下することの理由については、受信電力が全体的に CS 閾値に近づくため、CS の可否が位置により細かい変動をみせるためだと考えられる。送信電力を極端に低く、つまり  $-30$  [dBm] にすると、ほとんどの UE 同士で CS ができなくなるため、CS 推定率が向上したと考えられる。また、シャドウィングチャンネルでは、電力情報を用いた SVM の CS 推定率が低かったが、レイトレーシングモデルにおいては線形カーネルと同程度の推定性能を示している。これは、チャンネル相関が連続的に変化するため、電力情報によりチャンネル変動を十分に分類できるようになったためだと考えられる。

#### 5.5.1 PDR 特性

レイトレーシングモデルにおいて、位置情報を用いた PDR の評価を行った。その結果を図 9 に示す。これを見てわかることとして、位置情報、電力情報の両方を用いてランダム割り当てよりも高い PDR 特性を得られることがわかる。送信電力が  $-20$  [dBm] のとき、提案手法はランダム割り当てに比べおよそ 10% 程高い特性を得ることがわかる。シャドウィングチャンネルでは、電力情報を用いた際に良好な特性を得られなかったが、レイトレーシングモデルでは位置情報とほぼ同程度の特性を得られている。これはレイトレーシングモデルにおける電力情報を用いた CS 推定率がシャドウィングチャンネルに比べ向上して

いるため、適切な割り当てを行えるようになったためである。

## 6. おわりに

本稿では、CSMA/CA において隠れ端末の存在により生じる干渉回避のために機械学習を用いた無線リソース割り当てを提案し、計算機シミュレーションによる評価を行った。本手法は、SVM を用いて UE 間の CS 状況を推定することで、UE 間のパケット衝突を少ないオーバーヘッドかつ高い周波数利用効率を維持したまま回避することができるものである。シミュレーション結果から、提案手法はランダムな割り当て法と比較して最大 15% 程度 PDR を向上できることを示した。

今後の研究課題としては、電力情報を用いた場合の推定精度向上のための学習モデル設計や、実装時の学習データ収集の方法などがあげられる。

謝辞本研究開発は総務省 SCOPE (受付番号 175104004) の委託を受けて行われたものである。

## 文 献

- [1] J. Liu, R. Deng, S. Zhou, and Z. Niu, "Seeing the unobservable: channel learning for wireless communication networks", in *Proc. IEEE Global Commun. Conf.*, pp. 1-6, USA, Dec. 2015
- [2] S. Chen, Z. Jiang, J. Liu, R. Vannithamby, S. Zhou, and Z. Niu, "Remote channel inference for beamforming in ultradense hyper-cellular network", in *Proc. IEEE Global Commun. Conf.*, pp.1-6, Singapore, Dec. 2017
- [3] A. F. Molisch, "A generic model for MIMO wireless propagation channels in macro- and microcells", *IEEE Trans. on Signal Process.*, vol. 52, no. 1, pp. 61-71, Jan. 2004
- [4] 守倉 正博, 久保田 周治, "802.11 高速無線 LAN 教科書", インプレス R&D, 2010
- [5] C.M.Bishop, *Pattern Recognition and Machine Learning*, Springer, 2010
- [6] H. Claussen, "Efficient modelling of channel maps with correlated shadow fading in mobile radio systems", in *Proc. IEEE 16th Symp. on Personal, Indoor and Mobile Radio Commun.*, pp. 512-516, Germany, Sep. 2005
- [7] 構造計画研究所, "電波伝搬解析ツール RapLab", [Online]. Available: <http://network.kke.co.jp/products/raplab/> (2018/01/25 参照)