

スマートスペクトラムアクセスのための Duty Cycle の時系列モデル化

長 大樹[†] 梅林 健太[†] 成枝 秀介^{††} Miguel López-Benítez^{†††}

[†] 東京農工大学 大学院工学府 電気電子工学専攻 〒184-8588 東京都小金井市中町 2-24-16

^{††} 明石工業高等専門学校 電気情報工学科 〒674-8501 兵庫県明石市魚住町西岡 679-3

^{†††} Dept. of Elect. Eng. and Electron., University of Liverpool, Merseyside, L69 3GJ, UK

E-mail: †ume_k@cc.tuat.ac.jp

あらまし Primary User (PU) と Secondary User (SU) による周波数共有の実現には、PU の周波数利用を SU が適切に把握する必要がある。すなわち、PU の周波数利用に関する統計情報の活用が、効率的な周波数共有に対して有効であることがこれまでに報告されている。本報告では周波数利用統計情報として、時間軸方向に対する周波数利用率に相当する Duty Cycle (DC) に着目し、自己回帰 (AR: Auto-Regressive) モデル等を用いて時系列モデルの検討を行う。一般的な AR モデルはその統計情報の時間変動を考慮していない。さらに、実証実験により DC は比較的時間相関の高い状態と低い状態の二つに分類されることが確認されている。これらの事実を考慮した DC の新たなモデル化を本報告では提案する。具体的には、相関の高い状態 (S_1) と低い状態 (S_0) の分類を行い、時間と各状態に対する平均の DC の変動を考慮して時系列モデル化を行う。2.4 GHz 帯における周波数利用観測実験により本検討モデルを構築し検証を行った結果、従来のモデルに比べて高精度な予測が可能であることが明らかになった。

キーワード コグニティブ無線, ダイナミックスペクトラムアクセス, スマートスペクトラムアクセス, 周波数利用観測, 周波数利用率, 自己回帰モデル

A Study on Time Series Modeling of Duty Cycle for Smart Spectrum Access

Daiki CHO[†], Kenta UMEBAYASHI[†], Shusuke NARIEDA^{††}, and Miguel LÓPEZ-BENÍTEZ^{†††}

[†] Dept. of Elect. and Electron. Eng., Tokyo University of Agriculture and Technology,
2-24-16, Nakacho, Koganeishi, Tokyo, 184-8588, Japan

^{††} Dept. of Elect. and Comput. Eng., National Institute of Technology, Akashi College,
679-3, Nishioka, Uozumicho, Akashi, Hyogo, 674-8501, Japan

^{†††} Dept. of Elect. Eng. and Electron., University of Liverpool, Merseyside, L69 3GJ, UK

E-mail: †ume_k@cc.tuat.ac.jp

Abstract For an efficient spectrum sharing by primary user (PU) and secondary user (SU), SU needs to understand the spectrum usage by PU properly. Specifically, it has been reported that statistical information of spectrum usage by PU can enhance the efficiency of the spectrum sharing. In this paper, we focus on the duty cycle (DC) as statistical information of spectrum usage by PU, and we investigate a time-series modeling of DC, such as AR (Auto-Regressive) model. In a general AR model, the time fluctuation of statistics are not considered. In addition, the experimental results verifies that there are two types of periods: high correlation time period and low correlation time period. We propose a model in which the two types of periods and the time fluctuation of statistics. In the proposed time-series model, we employ detection method of the two states (high correlation state and low correlation state). Two different types of time-series models are used for the two sates. We show the validity of proposed model by experiment of spectrum measurement in 2.4 GHz band.

Key words Cognitive radio, dynamic spectrum access, smart spectrum access, spectrum measurement, duty cycle, auto-regressive model.

1. はじめに

近年、第5世代移動通信システム（5th Generation: 5G）やモノのインターネット（Internet of Things: IoT）などといった新たな無線通信技術の登場により、無線通信への需要は高まっている。一方で、固定的かつ排他的な周波数割り当てが原因で新規無線システムに対して割り当て可能な周波数帯域が不足するという、周波数逼迫問題が発生している。しかしながら、連邦通信委員会（Federal Communications Commission: FCC）の調査によると、何らかの無線システムに割り当て済みである周波数の利用率は、時間や場所によってはさほど高くなく、ホワイトスペースと呼ばれる未使用の周波数帯域が多数存在することが確認されている [1]。

そこで周波数資源の不足解消および効率的な利用を目的として、コグニティブ無線技術を用いた Dynamic Spectrum Access (DSA) が検討されている [2]~[5]。DSA は既存の一次利用者 (Primary User: PU) に割り当て済みでありながら時間的あるいは空間的に利用されていない周波数を、周波数が割り当てられていない新規の二次利用者 (Secondary User: SU) が二次利用するという、周波数共用技術である。DSA において、SU は PU の通信を阻害してはならないため、SU 周囲の PU の通信状況を適切に把握する必要がある。これにはスペクトルセンシングと呼ばれる信号検出技術などが用いられる [6]~[9]。これは瞬時の周波数利用の有無を検出することができる技術であり、これまでに電力検出 [10], [11] や特徴検出 [12], [13] に基づく手法などが検討されている。著者らもこれまでに、特徴検出に基づく低演算量かつ高精度なスペクトルセンシング法をいくつか検討してきた [14]~[17]。しかしながら周波数利用の時間変化が速い PU に対して SU が干渉を与えずにホワイトスペースを利用するためには、高速かつ高精度な手法が要求される。さらに SU が小型の無線端末である場合には低コスト/低演算量な実装が要求される。これら全ての要求を同時に満たすことは困難である。

このような課題を解決するアプローチとして、図 1 に示すような 2 階層型の Smart Spectrum Access (SSA) と呼ばれる、DSA をより高精度化した周波数共用技術が検討されている [18], [19]。SSA は PU の周波数利用に関する統計情報を活用し、PU と SU が周波数共用を行う。SSA の第 1 階層では PU と SU の周波数共用が行われ、第 2 階層では周波数利用観測システム (Spectrum Awareness System: SAS) が PU の周波数利用統計情報を取得し、その情報を SU に提供する。SAS による PU の周波数利用統計情報の取得および提供により、効率の良い周波数共用が実現できる。実際に、統計情報としてある期間中における PU 信号が存在する割合である Duty Cycle (DC) や、PU のトラフィックモデルとしてマルコフモデルを想定した際の状態遷移確率などを利用することで、スペクトルセンシングの性能向上が可能であることがこれまでに報告されている [20]~[22]。

本報告では、周波数利用統計情報の一つである DC のモデル化に着目する。DC は時間軸方向に対する周波数利用率に相当

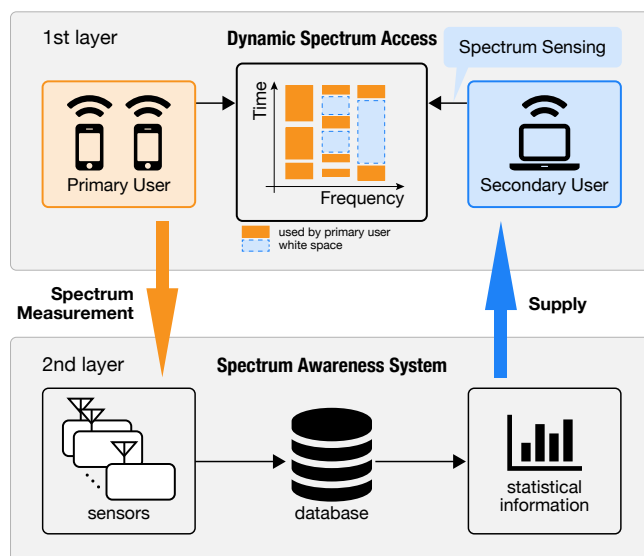


図 1 2 階層型 SSA の概念図

する。これまでに、周波数利用観測に基づいた DC のモデル化手法がいくつか検討されている [23]~[29]。例えば、文献 [25] では周波数利用の 1 日の傾向を示した時間軸に対する DC の決定論的モデルや、DC の確率論的振る舞いをベータ分布およびクマラスワミー分布で表現できることが示されている。また、文献 [26] ではベータ分布の定義域を $(0, 1)$ から $[0, 1]$ に拡張した修正ベータ分布を用いて、DC の確率論的振る舞いをより精度良く表現した。文献 [27], [28] では DC が 1 日を周期とする周期変動をもつことを利用し、季節自己回帰和分移動平均 (Seasonal Auto-Regressive Integrated Moving Average: SARIMA) モデルに基づく時系列モデルを構築した。さらに、文献 [29] では混合ベータ分布による DC の確率論的モデルおよび、それが時間によって決定論的に決まることに着目した決定論的-確率論的モデルを構築し、さらにモデルのパラメータ推定を効率よく行う手法についても検討されている。

DC は人々の活動と相関があることが確認されている [25]。例えば一般的に人々が活動的になる日中は DC が高くなり、反対に活動が休止する夜間は DC が低くなる、といったような特徴が見られる。そのため、DC には比較的時間相関が高い状態と低い状態の二つに分類されると考えられる。

そこで、本報告では DC の相関の有無を考慮したモデル化を検討する。具体的には、相関の高い状態と低い状態の分類を行い、時間と各状態に対する平均の DC の変動を考慮して、自己回帰 (Auto-Regressive: AR) モデル [30] による時系列モデル化を行う。2.4 GHz における周波数利用観測実験により本検討モデルの妥当性を示す。

2. 周波数利用観測諸元

本報告では Wireless Local Area Network (無線 LAN, 2,437 MHz 帯) における時間軸方向に対する周波数利用率に相当する短時間 DC の時系列モデル化について検討する。

モデル化対象である周波数帯を、東京農工大学小金井キャンパス 5 号館 408 号室に設置した周波数利用観測システムを用い

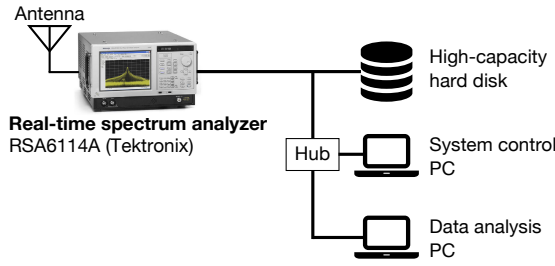


図 2 周波数利用観測システム

表 1 周波数利用観測諸元

観測場所	東京農工大学小金井キャンパス 5 号館 408 号室
観測日	2017/11/21, 22, 24, 27~30, 2017/12/1, 4~8, 12~14, 19~22, 26~29
観測中心周波数	2,437 MHz
観測帯域	1.25 MHz
連続観測期間	0.25 sec
観測周期	5 sec

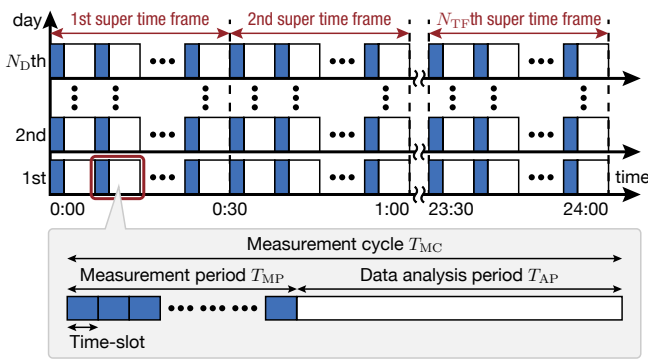


図 3 周波数利用観測の時間構成

て、周波数利用観測を行った。図 2 に本報告で用いる周波数利用観測システムを、表 1 に観測諸元を、図 3 に周波数利用観測の時間構成を、それぞれ示す。

DC の推定値に関する観測は観測周期 (Measurement cycle) T_{MC} ごとに行われる。 T_{MC} は観測期間 (Measurement period) T_{MP} とデータ解析期間 (Data analysis period) T_{AP} で構成される。すなわち $T_{MC} = T_{MP} + T_{AP}$ となる。まず T_{MP} に観測された I-Q サンプルングデータは、ネットワークを介して大容量ハードディスクに保存される。次にデータ解析用コンピュータにより、高速フーリエ変換 (Fast Fourier Transform: FFT) に基づく電力検出と後処理によって周波数利用の検出を行う。観測期間 T_{MP} は N_T 個のタイムスロットに分割され、各タイムスロットは Welch FFT を 1 回行う時間長に相当する。このとき、各タイムスロットに存在する周波数ビンの数を N_F とする。周波数利用の検出は、 $N_T \times N_F$ から成るタイルのパワースペクトル、電力検出、および誤警報除去 [31] を用いた信号領域推定 [32] に基づき行われる。ここで、タイルとは 1 タイムスロット-1 周波数ビンで構成される領域を指す [32]。これら処理によって得られる、 n_T 番目のタイムスロット・ n_F 番目の周波数ビンにおける、周波数利用検出結果は次式で定義される。電力検出の閾値は目標誤警報確率を 0.01 となるような基準で設定

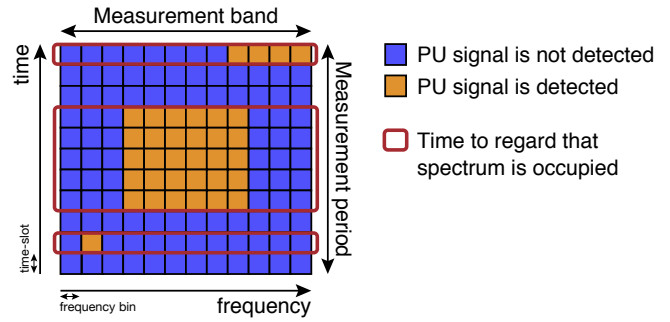


図 4 本報告における DC の計算方法

した。このときのノイズフロア推定法として MED-tED-mean 法 [33] を用いた。

$$D_{n_T, n_F} = \begin{cases} 1, & \text{PU signal is detected} \\ 0, & \text{PU signal is not detected} \end{cases} \quad (1)$$

ここで、観測日 d 日目における時刻 t の DC を $\Psi_d(t)$ と表記する。図 4 に、本報告で定義する DC の計算方法を示す。図 4 に示した周波数-時間の図は、文献 [32] および [31] の手法を用いて得られる $N_T \times N_F$ の周波数利用検出結果の例である。観測期間中の各タイムスロットにおいて、観測帯域のうち一箇所でも周波数利用が行われていると判定された場合、そのタイムスロットは周波数利用があるとみなす。観測期間中の周波数利用率を算出したものが DC の推定値となる。これらを数式で示すと、次式のとおり書ける。

$$\Psi_d(t) = \frac{1}{N_T} \sum_{n_T} \left(1 - \prod_{n_F \in W} (1 - D_{n_T, n_F}) \right) \quad (2)$$

ただし W は観測帯域。例えば図 4 に示した検出結果例の場合、観測期間中のタイムスロットの数が 11 であるのに対し、周波数が利用されているとみなされたタイムスロットの数は 7 であるため、DC は 7/11 であると推定される。

本報告では $T_{MP} = 0.25$ sec, $T_{MC} = 5$ sec と設定した。観測日数 N_D は 24 日間とし、表 1 に示した日程で周波数利用観測を行った。また、図 3 に示したように、得られた観測値を時間軸方向で複数のスーパータイムフレームに分割する。本報告では各スーパータイムフレームの長さを 30 分、1 日あたりのスーパータイムフレームの数 N_{TF} を 48 とする。

3. Duty Cycle のモデル化

3.1 概要

時刻 t に対する DC のモデルを以下の式で与える。

$$\hat{\Psi}_d(t) = \begin{cases} c_d(t), & S_d(t) = S_0 \\ c_d(t) + \sum_{i=1}^p \phi_i \Psi_d(t-i), & S_d(t) = S_1 \end{cases} \quad (3)$$

$c_d(t)$ はその時刻における DC の定数項を表し、平均値がこれに相当する。 ϕ_i は i 時点過去の観測値に対する AR モデルの係数、 p は AR モデルの次数に相当する。状態 S_0, S_1 は DC が

無相関、有相関である状態をそれぞれ表し、 $S_d(t)$ は観測日 d 日目の時刻 t における状態を表す。以下に、各モデルパラメータの推定法を示す。具体的には、3つのモデル化に着目する。最初の二つは式(3)に基づかず、一般的な時系列モデルであるARモデルとSARIMAモデルを用いたモデルである。すなわち、状態 $S_d(t)$ が常に S_1 であることを想定して各モデルのパラメータを設定している。もう一つのモデルは本報告の提案方式に相当し、状態 $S_d(t)$ を考慮してモデルパラメータの設定を行う。

3.2 状態判定・パラメータ推定

2階層型SSAにおけるSASでは、長期間の観測を行い、そこから適切なARパラメータを決定付けることができる。すなわち長期間の観測よりSASが $c_d(t)$ と ϕ_i を決定することを想定する。 $c_d(t)$ は、時刻 t における $\hat{\Psi}_d(t)$ の予測時に観測期間 T_M を設定し、次式のとおり算出する。

$$c_d(t) = \frac{1}{T_M} \sum_{t'=t-T_M+1}^t \Psi_d(t') \quad (4)$$

また長期間の観測では、観測時の状態の判定を行いながら観測を行う。 ϕ_i の推定方法は後述する。

次時点のDCの予測を行う場合は、DSAにおける端末やアクセスポイント自身が状態 S_d の判定を行い、SASより与えられた $c_d(t)$ と ϕ_i を用いて予測を行う。このとき端末やアクセスポイントは長期間の観測を行わず、状態の判定を十分に短い T_C (例: $T_C = 2$) により行うことを想定する。

3.3 状態 $S_d(t)$ の判定方法

長期間観測に基づくパラメータ推定や次時点の予測の際には状態 $S_d(t)$ の判定が必要となる。 $S_d(t)$ は、過去 T_C 時点における相関の値に応じて判定を行う。図5に、本報告における相関の計算方法を示す。ある時刻の相関は、その時刻の観測値および過去 $T_C - 1$ 個の観測値によって計算される。この長さ T_C のウィンドウを時間軸方向にシフトさせることにより、各時刻における相関を計算する。ここで d 番目の観測日、時刻 t における、ラグ k の自己相関 $\rho_{d,t}(k)$ を次式で定義する。

$$\begin{aligned} \rho_{d,t}(k) &= \frac{\mathbb{E}\left[\left\{\Psi_d(t) - \mathbb{E}[\Psi_d(t)]\right\}\left\{\Psi_d(t-k) - \mathbb{E}[\Psi_d(t-k)]\right\}\right]}{\mathbb{E}\left[\left\{\Psi_d(t) - \mathbb{E}[\Psi_d(t)]\right\}^2\right]} \\ &= \frac{\mathbb{E}\left[\left\{\Psi_d(t) - \mu_\Psi\right\}\left\{\Psi_d(t-k) - \mu_\Psi\right\}\right]}{\sigma_\Psi^2} \end{aligned} \quad (5)$$

ここで、 μ_Ψ と σ_Ψ^2 は $\Psi_d(t)$ の平均と分散を表している。相関の有無はラグ1の自己相関が0であるか否かによって判定する。ラグ1のみを考慮する件に対する妥当性は3.4で実証実験の結果より示す。

判定問題を以下のとおり定義する。

$$\begin{aligned} S_0 &: \rho_{d,t}(1) = 0 \\ S_1 &: \rho_{d,t}(1) \neq 0 \end{aligned} \quad (6)$$

ラグ1の自己相関の推定値 $\hat{\rho}_{d,t}(1)$ と閾値の大小を比較し判定する。SASが状態判定を行う際には、 μ_Ψ および σ_Ψ^2 はウィン




図5 本報告における相関の計算方法の概要図




図6 平均自己相関と偏自己相関。 $T_C = 60$ 。

ドウ内の観測値から計算する。一方で端末やアクセスポイントが、 $T_C = 2$ 程度の十分短い T_C により行う場合、 μ_Ψ および σ_Ψ^2 はSASによる長期間の観測により得られた各スーパータイムフレームごとのDCの平均および分散を用いる。閾値を η とすると次式のとおり判定を行う。

$$|\hat{\rho}_{d,t}(1)| \underset{S_0}{\overset{S_1}{\geq}} \eta \quad (7)$$

3.4 パラメータ次数 p およびパラメータ推定

$T_M = 60$ と設定し、SASが周波数利用観測をしたときの、 S_1 であると判定された時間における自己相関の平均値 $\bar{\rho}_{S_1}(k)$ および $\bar{\rho}_{S_1}(k)$ から導出された偏自己相関を図6に示す。ラグ k の偏自己相関は、次数が k であるARモデルの係数 ϕ_k と等価である値のことである。すなわち、偏自己相関がラグ $k+1$ 以降で0に近い値を取るような時系列に対しては $p \leq k$ となるような値を選択するべきであると言える。図6より、自己相関がラグの増加に伴いゆるやかに減衰し、偏自己相関がラグの増加に伴い急激に0に近づいていることがわかる。このような相関構造をもつ時系列のモデル化には、ARモデルが適していることが知られている[30]。さらに偏自己相関がラグ2以降で0に近い値を取っていることから、本報告ではARモデルのパラメータ次数 p を1とする。 ϕ_i は $\bar{\rho}_{S_1}(k)$ を用いてYule-Walker法[34]により推定する。結論として、 $p = 1$ のみを考慮することから ϕ_1 は以下のとおり与えられる。

$$\phi_1 = \bar{\rho}_{S_1}(1) \quad (8)$$

4. モデル評価

4.1 諸 元

2.4GHz 帯無線 LAN の実観測データを用いて、検討した DC のモデルを構築し評価を行う。さらに文献 [27], [28] で検討されている SARIMA モデルや状態 $S_d(t)$ が常に S_1 であることを想定している一般的な AR モデル [30] との比較も併せて行う。SAS が相関を計算するウィンドウの長さ T_C を 60、端末が相関を計算するウィンドウの長さ T_C を 2、AR モデルのパラメータ次数 p は先に述べたように 1、 $c_d(t)$ を計算するための観測期間 T_M を 2, 10 とした。さらに状態判定を行う際の閾値 η については、端末が判定する場合の閾値を $\eta = 4$ 、SAS が判定する場合の閾値を $\eta = 0.3244$ とそれぞれ設定した。

4.2 各モデルの誤差特性

まず、各モデルにおける 1 時点先予測値と観測値の誤差特性を示す。本報告では予測誤差として二乗平均平方根誤差 (Root Mean Square Error: RMSE) および平均二乗誤差 (Mean Square Error: MSE) を用いる。これらはそれぞれ次式で定義される。

$$\text{RMSE} = \sqrt{\mathbb{E} \left[(\hat{\Psi}_d(t) - \Psi_d(t))^2 \right]} \quad (9)$$

$$\text{MSE} = \mathbb{E} \left[(\hat{\Psi}_d(t) - \Psi_d(t))^2 \right] \quad (10)$$

図 7 に日付ごとの RMSE 特性を示す。横軸は観測日何日目であるかを示しており、例えば横軸の値が 1 は観測日 1 日目である 2017 年 11 月 21 日のことを指す。全ての観測日を通じて、 $T_M = 10$ としたときの検討モデルは他の手法に比べて誤差が小さいことがわかる。また、RMSE が低い 2017 年 11 月 27 日 (観測日 4 日目) や 2017 年 12 月 8 日 (観測日 13 日目) などはトラフィックが少なく、反対に RMSE が高い 2017 年 12 月 1 日 (観測日 8 日目) や 2017 年 12 月 13 日 (観測日 15 日目)、2017 年 12 月 26 日 (観測日 21 日目) などはトラフィックが多いことが確認された。また、図 8 に全観測値に関する RMSE を示す。図 8 より、 $T_M = 10$ としたときの検討モデルが最も優れた結果を示していることがわかる。一方で、 $T_M = 2$ としたときの検討モデルは従来の AR や SARIMA モデルとあまり差がないことがわかる。さらに、図 9 に DC 観測値の値に対する MSE 特性を示す。モデルを問わず、DC が高いところでの予測誤差が大きく、DC が低いところでの予測誤差が小さくなっていることがわかる。また、DC が低いところでは $T_M = 10$ としたときの検討モデルが、DC が高いところでは $T_M = 2$ としたときの検討モデルが、それぞれ最も MSE が小さくなっていることがわかる。ここで図 10 に DC 観測値の確率密度関数をそれぞれ示す。図 10 より、今回の周波数利用観測実験で取得した観測値は低い値を取ることが多いことがわかる。そのため $T_M = 2$ とした検討モデルの予測誤差が悪くなったと考えられる。一方で、DC が高くなる時間帯が多い状況下においては、 $T_M = 2$ とした検討モデルが有効であると考えられる。

4.3 各モデルの予測値の振る舞い

次に、各モデルにおける 1 時点先予測値の振る舞いについて

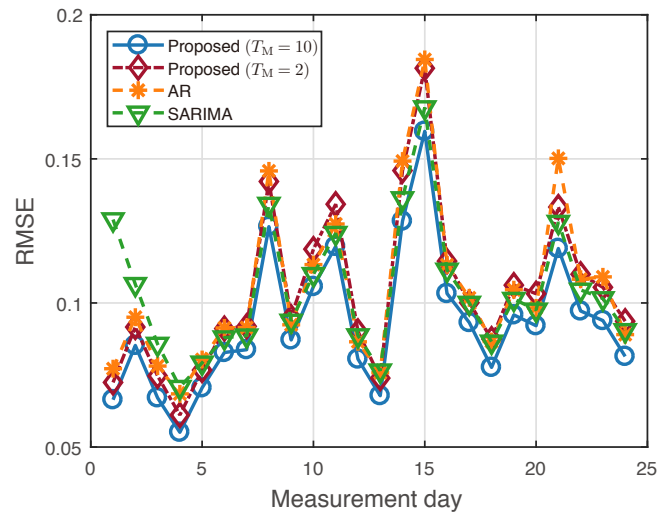


図 7 日付ごとの RMSE 特性

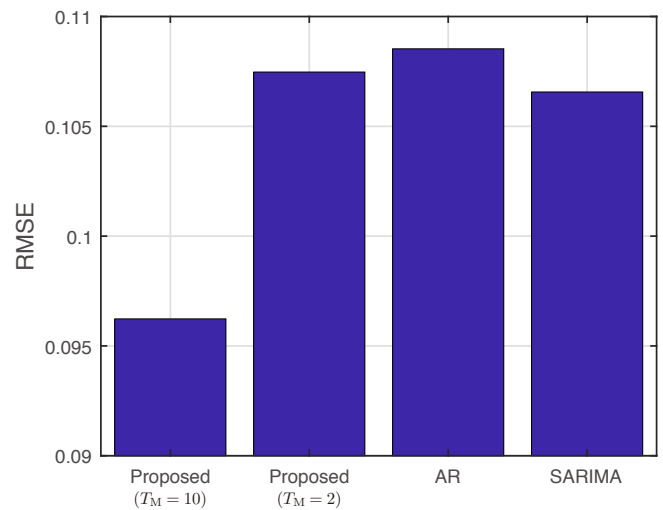


図 8 各手法の RMSE

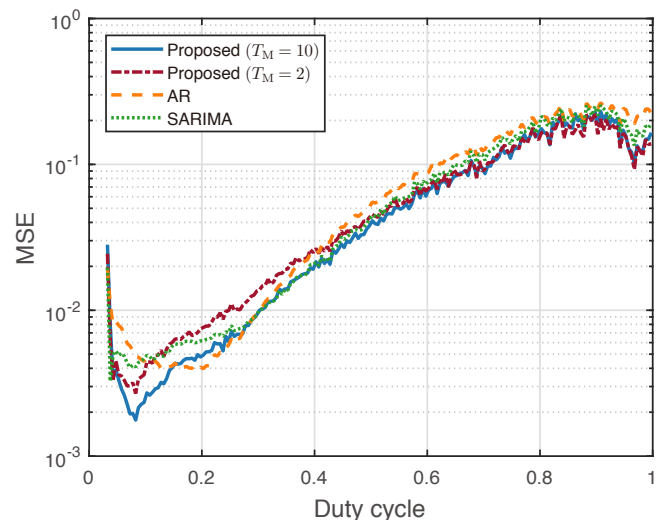


図 9 DC 観測値ごとの MSE 特性

検証する。図 11~13 に観測値と各モデルの 1 時点先予測値、および端末が行った状態判定結果を示す。図 11 はトラフィックが少ない時間帯、図 12 はトラフィックが多い時間帯のうち

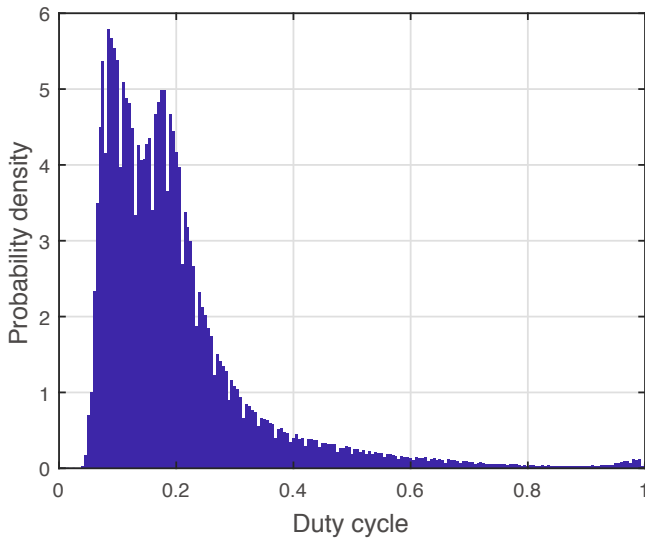


図 10 DC 観測値の確率密度関数

DC が高くなり始めた付近, 図 13 はある程度短い時間内にトラフィックが多くなる時間が複数存在する時間帯, をそれぞれ示している.

図 11 より, 従来の AR モデルや $T_M = 2$ とした検討モデルによる予測値は DC の変動に 1 時点遅れて追従する傾向にあることが分かる. よって, 1 時点だけトラフィックが急増した場合に次時点において AR モデルと $T_M = 2$ とした検討モデルは誤差が大きくなる傾向にある. さらに, AR モデルは DC の平均値が観測値より若干高い傾向にある. 一方で $T_M = 10$ とした検討モデルによる予測値はこのような DC に対して追従していないことがわかる. 図 12 では DC が高くなる瞬間の予測値および DC が高い状態の予測値に着目する. まず DC が高くなる瞬間を見ると, $T_M = 10$ とした検討モデルではやや遅れて予測値が高くなっている様子が見られる. それに対して $T_M = 2$ とした検討モデルでは瞬時に予測値が高くなっていることがわかる. また DC が高い状態が続いている時間を見ると, 従来の AR モデルや SARIMA モデルによる予測値は高い値にまで追従できていないことがわかる. 一方で検討モデルによる予測値は T_M の値に関わらず高い値に追従できている. 図 13 では DC が低くなる瞬間の予測値に着目する. 検討モデルによる予測値は T_M の値に関わらず, DC が低くなる瞬間に予測値も低くなっていることがわかる. また図 11~13 について状態判定結果を見ると, DC が高い時間帯では S_1 , DC が低い時間帯では S_0 と高精度に判別できている.

5. おわりに

本報告では PU の周波数利用統計情報である DC の時間帯による相関の有無に着目し, DC の時系列モデル化について検討した. 具体的には, 相関の高い状態と低い状態の分類を行い, 時間と各状態に対する平均の DC の変動を考慮して, AR モデルによる時系列モデル化を行った. 2.4GHz 帯無線 LAN の周波数利用観測実験により得られた実観測データを用いて本検討モデルを構築し検証を行った結果, 従来の AR モデルや

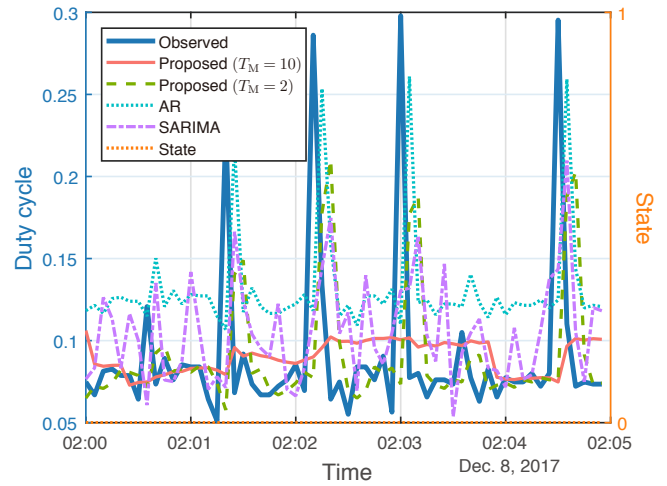


図 11 観測値と各モデルの 1 時点先予測および状態判定結果. トラフィックが少ない時間帯.

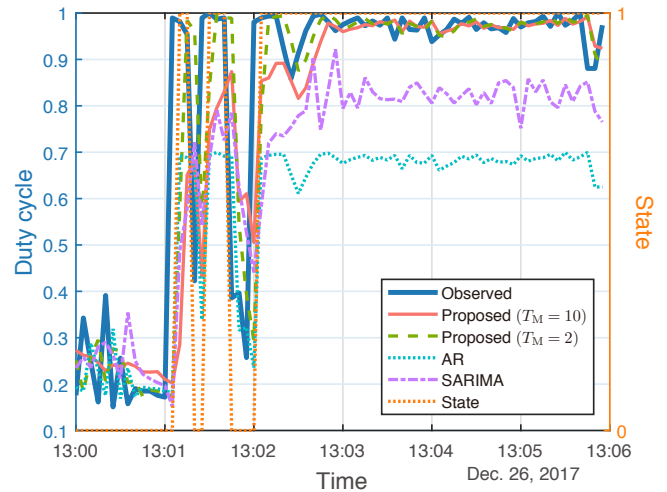


図 12 観測値と各モデルの 1 時点先予測および状態判定結果. トラフィックが多い時間帯のうち DC が高くなり始めた付近.

SARIMA モデルに比べて, 高精度な予測が可能であることが明らかになった.

文 献

- [1] FCC, "Spectrum policy task force," Federal Communications Commission, ET Docket No. 02-135, Nov. 2002. [Online]. Available: http://sites.nationalacademies.org/cs/groups/bpsite/documents/webpage/bpa_048826.pdf
- [2] S. Haykin, "Cognitive radio: brain-empowered wireless communications," *IEEE J. Sel. Areas in Commun.*, vol. 23, no. 2, pp. 201-220, Feb. 2005.
- [3] I. F. Akyildiz, W.-Y. Lee, M. C. Vuran, and S. Mohanty, "Next generation/dynamic spectrum access/cognitive radio wireless networks: A survey," *Computer Networks*, vol. 50, no. 13, pp. 2127-2159, Sept. 2006.
- [4] Q. Zhao and B. M. Sadler, "A survey of dynamic spectrum access," *IEEE Signal Process. Mag.*, vol. 24, no. 3, pp. 79-89, May 2007.
- [5] S. Bhattarai, J. M. J. Park, B. Gao, K. Bian, and W. Lehr, "An overview of dynamic spectrum sharing: Ongoing initiatives, challenges, and a roadmap for future research," *IEEE Trans. Cogn. Commun. Netw.*, vol. 2, no. 2, pp. 110-128, June 2016.
- [6] A. Ghasemi and E. S. Sousa, "Spectrum sensing in cogni-

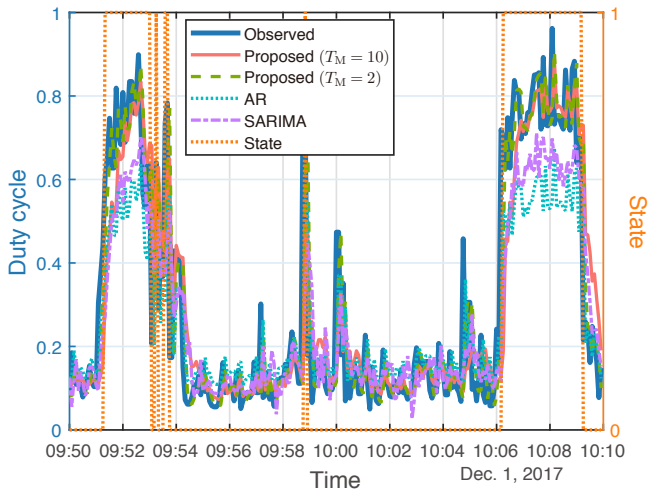


図 13 観測値と各モデルの 1 時点先予測値および状態判定結果。ある程度短い時間内にトラフィックが多くなる時間が複数存在する時間帯。

tive radio networks: Requirements, challenges and design trade-offs,” *IEEE Commun. Mag.*, vol. 46, no. 4, pp. 32–39, Apr. 2008.

- [7] S. Haykin, D. J. Thomson, and J. H. Reed, “Spectrum sensing for cognitive radio,” *Proc. IEEE*, vol. 97, no. 5, pp. 849–877, May 2009.
- [8] T. Yücek and H. Arslan, “A survey of spectrum sensing algorithms for cognitive radio applications,” *IEEE Commun. Surveys Tut.*, vol. 11, no. 1, pp. 116–130, 1st Quart. 2009.
- [9] H. Sun, A. Nallanathan, C. X. Wang, and Y. Chen, “Wideband spectrum sensing for cognitive radio networks: A survey,” *IEEE Wireless Commun.*, vol. 20, no. 2, pp. 74–81, Apr. 2013.
- [10] H. Urkowitz, “Energy detection of unknown deterministic signals,” *Proc. IEEE*, vol. 55, no. 4, pp. 523–531, Apr. 1967.
- [11] A. Mariani, A. Giorgetti, and M. Chiani, “Effects of noise power estimation on energy detection for cognitive radio applications,” *IEEE Trans. Commun.*, vol. 59, no. 12, pp. 3410–3420, Dec. 2011.
- [12] A. V. Dandawate and G. B. Giannakis, “Statistical tests for presence of cyclostationarity,” *IEEE Trans. Signal Process.*, vol. 42, no. 9, pp. 2355–2369, Sept. 1994.
- [13] K. Muraoka, M. Ariyoshi, and T. Fujii, “A robust spectrum sensing method based on maximum cyclic autocorrelation selection for dynamic spectrum access,” *IEICE Trans. Commun.*, vol. E92-B, no. 12, pp. 3635–3643, Dec. 2009.
- [14] D. Cho and S. Narieda, “Simple weighted diversity combining technique for cyclostationarity detection based spectrum sensing in cognitive radio networks,” *IEICE Trans. Commun.*, vol. E99-B, no. 10, pp. 2212–2220, Oct. 2016.
- [15] S. Narieda and D. Cho, “Improvement of false alarm probability in simple weighted diversity combining for cyclostationarity detection based spectrum sensing,” *IEICE Commun. Express*, vol. 6, no. 1, pp. 22–27, Jan. 2017.
- [16] D. Cho, S. Narieda, and K. Umabayashi, “Low computational complexity spectrum sensing based on cyclostationarity for multiple receive antennas,” *IEICE Commun. Express*, vol. 7, no. 2, pp. 54–59, Feb. 2018.
- [17] D. Cho, A. Kondo, S. Narieda, and K. Umabayashi, “CAF diversity combining for spectrum sensing by test statistics sharing with time-averaged weights,” in *Proc. IEEE 84th Veh. Technol. Conf. (VTC2016-Fall)*, Montréal, Canada, Sept. 2016, pp. 1–6.
- [18] K. Umabayashi, S. Tiuro, and J. J. Lehtomäki, “Develop-

ment of a measurement system for spectrum awareness,” in *Proc. 1st Int. Conf. on 5G for Ubiquitous Connectivity (IEEE 5GU)*, Levi, Finland, Nov. 2014, pp. 234–239.

- [19] H. Iwata, K. Umabayashi, J. J. Lehtomäki, M. López-Benítez, and S. Narieda, “Development of a smart spectrum access prototype,” in *Proc. 26th European Conf. Netw. and Commun. (EuCNC 2017)*, Oulu, Finland, June 2017, pp. 1–2.
- [20] N. Wang, Y. Gao, and X. Zhang, “Adaptive spectrum sensing algorithm under different primary user utilizations,” *IEEE Commun. Lett.*, vol. 17, no. 9, pp. 1838–1841, Sept. 2013.
- [21] T. Nguyen, B. L. Mark, and Y. Ephraim, “Spectrum sensing using a hidden bivariate Markov model,” *IEEE Trans. Wireless Commun.*, vol. 12, no. 9, pp. 4582–4591, Sept. 2013.
- [22] K. Umabayashi, K. Hayashi, and J. J. Lehtomäki, “Threshold-setting for spectrum sensing based on statistical information,” *IEEE Commun. Lett.*, vol. 21, no. 7, pp. 1585–1588, July 2017.
- [23] Y. Chen and H. S. Oh, “A survey of measurement-based spectrum occupancy modeling for cognitive radios,” *IEEE Commun. Surveys Tut.*, vol. 18, no. 1, pp. 848–859, 1st Quart. 2016.
- [24] G. Ding, Y. Jiao, J. Wang, Y. Zou, Q. Wu, Y. D. Yao, and L. Hanzo, “Spectrum inference in cognitive radio networks: Algorithms and applications,” *IEEE Commun. Surveys Tut.*, vol. PP, no. 99, pp. 1–1, 2017.
- [25] M. López-Benítez and F. Casadevall, “Empirical time-dimension model of spectrum use based on a discrete-time Markov chain with deterministic and stochastic duty cycle models,” *IEEE Trans. Veh. Technol.*, vol. 60, no. 6, pp. 2519–2533, July 2011.
- [26] M. Wellens and P. Mähönen, “Lessons learned from an extensive spectrum occupancy measurement campaign and a stochastic duty cycle model,” *Mobile Netw. and Appl.*, vol. 15, no. 3, pp. 461–474, June 2010.
- [27] Z. Wang and S. Salous, “Spectrum occupancy statistics and time series models for cognitive radio,” *J. Signal Process. Syst.*, vol. 62, no. 2, pp. 145–155, Feb. 2011.
- [28] M. G. Mostafa, E. Tsolaki, and H. Haralambous, “HF spectral occupancy time series models over the eastern mediterranean region,” *IEEE Trans. Electromagn. Compat.*, vol. 59, no. 1, pp. 240–248, Feb. 2017.
- [29] K. Umabayashi, M. Kobayashi, and M. López-Benítez, “Efficient time domain deterministic-stochastic model of spectrum usage,” *IEEE Trans. Wireless Commun.*, vol. PP, no. 99, pp. 1–1, 2017.
- [30] J. D. Hamilton, *Time series analysis*. Princeton, NJ: Princeton Univ. Press, 1994.
- [31] R. Mizuchi, K. Umabayashi, J. J. Lehtomäki, and M. López-Benítez, “A study on false alarm cancellation for spectrum usage measurements,” in *Proc. 2017 IEEE Wireless Commun. and Netw. Conf. Workshops (WCNCW)*, San Francisco, CA, Mar. 2017, pp. 1–6.
- [32] K. Umabayashi, K. Moriwaki, R. Mizuchi, H. Iwata, S. Tiuro, J. J. Lehtomäki, M. López-Benítez, and Y. Suzuki, “Simple primary user signal area estimation for spectrum measurement,” *IEICE Trans. Commun.*, vol. E99-B, no. 2, pp. 523–532, Feb. 2016.
- [33] R. Mizuchi, K. Umabayashi, M. López-Benítez, and S. Narieda, “A study on noise floor estimation method for wideband spectrum measurement,” in *Proc. IEICE Gen. Conf. ’17*, Nagoya, Mar. 2017, (in Japanese).
- [34] P. J. Brockwell and R. A. Davis, *Introduction to Time Series and Forecasting*, 3rd ed., ser. Springer Texts in Statistics. New York, USA: Springer, 2016.