

環境変動を柔軟に認知する脳の情報処理機構を用いた LoRaWANにおける無線チャネル割当制御

小南 大智[†] 長谷川洋平^{††} 野上 耕介^{††} 下西 英之^{††} 村田 正幸^{†††}

[†] 大阪大学 大学院経済学研究科 〒560-0043 大阪府豊中市待兼山町 1-7

^{††} NEC システムプラットフォーム研究所 〒211-8666 神奈川県川崎市中原区下沼部 1753

^{†††} 大阪大学 大学院情報科学研究科 〒565-0871 大阪府吹田市山田丘 1-5

E-mail: [†]d-kominami@econ.osaka-u.ac.jp, ^{††}(hasegawa@bk,k-nogami@bp,h-shimonishi@cd).jp.nec.com,
^{†††}murata@ist.osaka-u.ac.jp

あらまし Internet of Things (IoT) という単語が社会に広く知られつつあり、その要素技術の一つとして LPWA 技術が大きな注目を集めている。LoRa は LPWA 通信技術の一つであり、自営ネットワークの構築が可能であることから、今後、LoRa を用いたサービスが全体の管理者なく同一エリアに乱立することが予想される。その結果、設計時には意図していない通信干渉による LoRa の通信性能の低下が危惧される。本研究では、人の脳における情報処理をモデル化したベイジアンアトラクターモデルを応用することで、ベイズ更新による逐次推定によりネットワークの状態を推定し、推定結果に基づき無線チャネルを割り当てる手法を提案する。シミュレーション評価により、提案手法が自律的に特定の無線チャネルの混雑を避けるように無線チャネルの割当を行うことを示した。

キーワード ベイジアンアトラクターモデル、low power wide area (LPWA)、long range (LoRa)、ベイズ推定

Bayesian channel selection methods for LoRaWAN under unpredictable wireless channel fluctuations

Daichi KOMINAMI[†], Yohei HASEGAWA^{††}, Kosuke NOGAMI^{††}, Hideyuki SHIMONISHI^{††}, and
Masayuki MURATA^{†††}

[†] Graduate School of Economics, Osaka University

^{††} System Platform Research Labs, NEC Corporation

^{†††} Graduate School of Information Science and Technology, Osaka University

E-mail: [†]d-kominami@econ.osaka-u.ac.jp, ^{††}(hasegawa@bk,k-nogami@bp,h-shimonishi@cd).jp.nec.com,
^{†††}murata@ist.osaka-u.ac.jp

Abstract Internet of Things (IoT) become a common term used in society. LPWA technology is attracting attention as one of its elemental technologies. LoRa is one of LPWA communication technologies using unlicensed bands. Since it is possible to build a self-managed network with LoRa, many services using LoRa will be scattered in the same area without the entire administrator. As a result, communication performance of LoRa may be degraded due to unintended radio interferences. In this research, we propose a method for estimating the network state by successive estimation using Bayesian update and a wireless channel assignment method based on the estimation results. Through computer simulation, we show the network performance improvement with out proposal.

Key words Bayesian attractor model, low power wide area (LPWA), long range (LoRa), Bayesian inference

1. はじめに

低消費電力かつ広域通信を実現する LPWA (low power wide area) と呼ばれる通信技術が急速に普及している [1]。LPWA

普及の背景には、近年の IoT (Internet of things) の進展があり、LPWA を用いることで、より容易に、様々なユーザやデバイスからのデータを収集することが可能となる。LPWA の代表的な規格の一つである SIGFOX は 2019 年現在 65 カ国以

上へ展開し、もう一つの代表規格 LoRa (long range) については、2015 年に LoRa アライアンスが立ち上げられ、500 社以上が加盟しており、100 カ国以上で利用可能である。SIGFOX は各国に一社が Sigfox ネットワークオペレータとしてネットワークサービスを展開しており、ユーザは事業者が運営する公衆網を利用する必要がある。一方 LoRa では、LoRa アライアンスが規格化した製品を利用することで、ユーザは自由に自営ネットワークを構築することが可能である。

LPWA を用いることで、無線モジュールのみの消費電力を考慮するのであれば、市販の電池を用いる場合でも数年単位での通信機器の稼働が可能となる。通信距離に関しては、見通しの良い屋外であれば 10 km 程度離れた場所からでもデータをゲートウェイに届けることができる。LPWA に対応した通信モジュールをさまざまなモノと組み合わせることで、モノから得られる情報を容易に収集すること可能となる。低消費電力かつ広域通信を実現する個々の技術自体は、既存の技術をうまく組み合わせただけのものであるが、その応用性は非常に高く、LPWA は IoT を邁進する技術として期待されている。

現在の LPWA 機器による WAN (wide area network) では、ゲートウェイと端末子機からなるスター型ネットワークが構築される。すなわち端末とゲートウェイによる多対一の通信形態をとり、特に、端末からゲートウェイへのアップリンク通信が、IoT を想定する上では広く用いられると考えられ、トラフィックの大半を占めることとなる。この際、端末はデータの中継を行う必要がないため、自身が通信を行いたいタイミングでのみ無線モジュールを起動すればよく、それ以外の時間は無線モジュールをスリープさせておける。このような間欠型の通信によって、無線モジュールで発生する電力消費を大幅に削減している。また、LPWA は高いリンクバジェットを持つように設計されており、これが長距離通信を実現する理由の一つである。その要素技術としては、比較的低い周波数帯（日本国内では 920 MHz 帯等）を利用すること、冗長符号や干渉・ノイズに強い変調方式を用いること、受信感度の高いアンテナを利用すること、データレートを比較的低位設計していることが主である。特にデータレートに関して、数 100 bps～数 kbps と従来のモバイルネットワークと比較して低速である。

LPWA による通信では、データレートが低いためデータ伝送時間が長くなる。また、LoRa や SIGFOX では、MAC 層に ALOHA プロトコルを採用しており、端末数の増加とともにデータパケットの衝突増加が懸念される。信号の送信前に受信信号強度を調べることで、IEEE 802.11 で使用されるような搬送波検知による衝突回避 (CSMA/CA) が可能である。しかしながら、LPWA 端末のアンテナ受信感度は高く、IEEE 802.11 で使用される -80 dB 程度の CCA (Clear Channel Assessment) しきい値を用いると、しきい値よりも低い信号強度の電波であってもゲートウェイまで信号が到達し得る。結果的に ALOHA を利用している場合と同様に衝突が生じることが予想される。一方でしきい値を低くするほど、無線チャンネルをビジー状態と判断する確率が増加してしまう。

LoRa を使用する端末およびゲートウェイで構成される LoRaWAN においては、ユーザによる自営ネットワークの構築が可能であり、将来的に多数の自営ネットワークが同一エリアに混在する環境が考えられる。この際、端末数の増加やネットワークの混在によって干渉の影響が強まることとなる。干渉以外にも、同一の周波数帯を利用するシステムの敷設や、建造物などの障害物の発生といった様々な原因によって、端末とゲ

トウェイ間の通信品質は様々な時間スケールで変動する。LoRa では複数のデータレートおよび無線チャンネルを任意に利用可能であり、これらをゲートウェイが端末に割り当てることで、通信品質の変動に対応することができる。しかしながら、通信品質の変化に応じて適切なデータレートや無線チャンネルを決定するためには、ゲートウェイが通信品質の変化を捉え、変化に応じた制御を行う必要がある。

本稿では、LoRaWAN を対象に、ゲートウェイが自律的に通信品質の変化を把握し、端末に使用する無線チャンネルを割り当てる手法を提案する。ここで、無線通信品質は時間的・空間的に変動するが、各端末は必ずしも GPS を備えているとは限らず、また、常に利用可能な無線チャンネルの通信品質を観測しているとは限らない。さらに、情報収集に利用できる無線資源が限られており、推定を行うために十分な観測情報を収集することが困難と考えられる。

そこで我々は、不十分な情報しか利用できない際にも適切な推論を実施する、人間の脳の情報認知機構に着目した。人間の脳における情報認知が形成される過程においては、様々な感覚器からの入力情報を脳の中にある記憶と比較して意思決定を行う、トップダウン型の情報処理が存在することが知られている。この一連の情報処理がベイズ推論に基づく意思決定モデルにより説明可能であることが近年報告されている。文献 [2] で提案されたベイジアンアトラクターモデルでは、脳の意思決定状態を表す隠れ変数 (意思決定変数) を状態空間上で定義し、この変数が複数のアトラクターを持つダイナミクスに従うものとして定義している。また、意思決定変数の状態空間から特徴量空間に変換する非線形関数が定義され、各アトラクターに対応する特徴量は、前述の脳の中にある記憶に相当する。このとき、脳による情報処理プロセスは、観測 (知覚) した情報と意思決定変数のダイナミクスに基づき、意思決定変数をベイズフィルタによって更新し、更新後の意思決定変数とアトラクターとの距離がしきい値よりも短い際に意思決定を行う、というモデル化がなされている。

前述の通り、本稿では複数の LoRaWAN が同一のエリアに存在する状況を想定する。この際、ベイジアンアトラクターモデルにおける意思決定変数を、無線チャンネルにおける通信の混雑度合いに対応付ける。各アトラクターは異なる混雑度合いであることを表し、前述の非線形関数による変換により、各混雑度合いでの特徴量にマッピングされる。ベイジアンアトラクターモデルは、ゲートウェイ (あるいはその先のネットワークサーバ) 上で動作するため、特徴量はゲートウェイあるいは端末が観測可能な値である必要がある。ゲートウェイは端末との通信記録に基づき、定期的に特徴量を計算し、ベイジアンアトラクターモデルに入力する。そして、入力に応じて意思決定変数が更新される。これを、各無線チャンネルごとに行うことで、各無線チャンネルの混雑度合いの推定を行うことができる。ここで、ベイズ推定を用いて意思決定変数を更新するため、意思決定変数は事後確率分布として得られる。意思決定変数がそれぞれのアトラクターにどの程度近いのかを表す値、すなわち確信度を、事後確率分布に基づき定義する。すべての無線チャンネルにおいて確信度がしきい値を超えた際に、混雑度に対応する意思決定である無線チャンネル割り当て制御を行なうこととする。

混雑度合いを、仮想的な LPWA 端末が N 台存在する状態と定義すると、それぞれの無線チャンネルの混雑度合いとして、この仮想的な LPWA 端末の数が得られる。無線チャンネル割り当て制御ではこの端末数を各無線チャンネルで均等化するように行う。




図1 環境変動を認知し無線チャネル割当を行う自律的制御ループ

2. LoRa 通信モデル

本稿で想定する LoRaWAN の通信モデルを以下に説明する。LoRaWAN には三つの通信クラスがあり、現在用いられているユースケースのほとんどはクラス A と呼ばれるアップリンク通信が中心となるクラスである。クラス A では、それぞれの端末は任意のタイミングでデータをゲートウェイに送信することができる。送信データが生成されると、端末は 5 ms の間アンテナを受信モードにし、その間の信号強度がしきい値を超えない場合、データの送信を行う。しきい値を超えた場合には一度だけ再送を試みる。送信終了後には無線インタフェースをスリープさせる。一定時間 (RxDelay) スリープしたあとに無線インタフェースを起動し、ゲートウェイからの確認応答 (ACK) を受け取りデータの送信手順を終了する。一定時間 (ACK_TIMEOUT) 経過しても ACK が届かない場合には再送を試みる。再送の回数は一つのデータあたり NbTrans 回である。RxDelay および NbTrans の値は端末がネットワークに参加した際に登録される。ゲートウェイでは、データの受信終了後に RxDelay だけ待機してから ACK を送信する。ここで、LoRa 1.1 [3] では RxDelay の値が二つ用意され、端末側は無線インタフェースを二回起動する必要があるが、本稿では LoRa 1.0 と同様に RxDelay の値は一つのみと単純化する。

LoRa 端末は利用可能な無線チャネルの内一つを使用して通信を行う。LoRa 1.1 ではデータの再送時にチャネルホッピングを利用可能としているが、具体的な方法は定められていない。本稿では ACK に使用チャネル情報をピギーバックすることで、ゲートウェイは各端末に無線チャネルを割り当てることとする。

3. ベイジアンアトラクターモデル

ベイジアンアトラクターモデル (BaM) は脳による情報知覚と弁別および意思決定を、ベイズ推定の枠組みを用いてモデル化したものである。我々の研究グループでは、これまでに、光ネットワークにおける仮想ネットワーク再構成に BaM を用いることで、トラヒック状況に適した仮想ネットワークを構成できることを示した [4]。また、MPEG-DASH のレート制御に BaM を用いることで、利用可能帯域とユーザの好みに応じたレート選択が実現できることを示した [5]。

BaM は大きく三つの要素から構成される。すなわち、(1) 情報知覚、(2) 情報弁別、(3) 意思決定である。**情報知覚**：BaM は観測対象の情報の特徴量ベクトルで表現する。情報が観測されるごとに、この特徴量ベクトルが情報弁別の入力に用いられる。**情報弁別**：知覚した情報を過去の経験や記憶と照らし合わせ、いずれかと一致するかの判断を行う。過去の経験や記憶は所与の特徴量ベクトルで記述される。ここで、脳の内部状態を、 K 個のアトラクターを持つ非線形ダイナミクスを用いて表現し、それぞれのアトラクターに過去の経験や記憶を対応づけている。このダイナミクスと情報の知覚に基づき、脳の内部状

態がベイズ更新され、いずれかのアトラクターに向かう。**意思決定**：情報弁別において得られた脳の内部状態の確率密度分布に基づき、確信度と呼ばれる値を導出する。確信度がしきい値を超えた場合に、知覚した情報と、内部状態に対応する記憶がマッチしたものと判断する。

BaM においては、脳の内部状態を表す変数 (意思決定変数) が、既知のダイナミクスに従って更新される隠れ変数として定義される。意思決定変数 z (decision state) は、前述のダイナミクスにより状態空間上に存在するいずれかのアトラクターに近づく。BaM は、知覚した情報に基づいて z を推定する。ただし、 z は隠れ変数であるため、 z の推定にはベイズの定理が用いられる。

3.1 生成モデル

BaM では脳の意思決定状態を確率変数 z で表現し、 z は K 個のアトラクターを持つ非線形ダイナミクスにより更新される。ある初期状態が与えられると、ノイズがない限り、更新を繰り返すことで z はいずれかのアトラクターに引き込まれる。 z の更新則は以下のとおりである。

$$z_t = z_{t-\Delta} + \Delta g(z_{t-\Delta}) + \sqrt{\Delta} w_t \quad (1)$$

ここで、 z は $K \times 1$ のベクトルである。 Δ はダイナミクスの更新周期、 w_t は正規分布 \mathcal{N} に従う乱数である。 $w_t \sim \mathcal{N}(0, q^2/\Delta)$ であり、 q は生成モデルに含まれるプロセス誤差の大きさを表す。 g は winner-take-all network ダイナミクスであり、以下のように定義される。

$$g(z) = k(L\sigma(z) + b^{lin}(\phi - z)) \quad (2)$$

ここで、 k は更新のスケールを決定する定数である。また、 ϕ は $K \times 1$ の行列であり、すべての要素が同じ値 ϕ_g を持つ。 b^{lin} はベクトル z の自己要素への作用の大きさを表している。また、 $L = b^{lat}(I - \mathbf{1})$ であり、 I は単位行列を、 $\mathbf{1}$ は全要素が 1 の行列を表しており (いずれもサイズは $K \times K$)、 b^{lat} は他要素からの作用の大きさを表している。 σ はシグモイド関数であり z の各要素 z_i を、 $1/(1 + e^{-d(z_i - o)})$ によって $[0, 1]$ の範囲に変換する。 d は減衰特性を、 o は変曲点の位置を決定するパラメータである。ダイナミクス g を繰り返すことで、 z の K 個の要素のうち、一つだけが ϕ_g に、それ以外の要素は $-\phi_g$ に収束する。すなわち、 z のダイナミクスにおける K 個のアトラクターは、 i 番目要素のみが ϕ_g 、それ以外の要素は $-\phi_g$ である $K \times 1$ の行列にそれぞれ対応する ($i = 0, \dots, K - 1$)。

BaM では、 z_t のそれぞれのアトラクターに、過去の記憶や経験を表す特徴量ベクトルが対応付けられる。ある意思決定変数に対応した特徴量ベクトル x_t は以下で生成される。

$$x_t = M\sigma(z_t) + v_t \quad (3)$$

$M = [\mu_0 \mu_1 \dots \mu_{K-1}]$ は、特徴量ベクトルを列挙した特徴量行列である。 μ は $m \times 1$ のベクトルであり、 M は $m \times K$ の行列となる。また、 v_t は正規分布 \mathcal{N} に従う乱数である。ここで $v_t \sim \mathcal{N}(0, r^2)$ であり、 r は計測の不確かさを表す。

3.2 ベイズフィルタ

定義した内部モデルと知覚した情報に基づいて意思決定変数 z を推定する。 z は隠れ変数であり、またダイナミクスに従って時間的に更新されるため、逐次ベイジアンフィルタが推定に用いられる。文献 [2] ではベイジアンフィルタの一つである unscented カルマンフィルタ (UKF) を用いている。一般的なカルマンフィルタは、非線形ダイナミクスを扱う際には推定性

能が落ちることが知られている。UKF はカルマンフィルタの欠点を緩和した手法であり、標準偏差の推定値に基づいて計算されるシグマ点と呼ばれる少数個のサンプルと生成モデルを用いて確率分布を近似する。

UKF を用いることで時刻 t における z の事後確率分布 $P(z_t | \mathbf{x}_t)$ が得られ、各アトラクターの確率密度 $P(z_t = \phi_n | \mathbf{x}_t)$ を計算することができる。この確率密度の値を、[2] の著者らは確信度 (confidence) と呼んでいる。BaM における意思決定で、周辺尤度ではなく確信度を指標に用いるのは、アトラクター数が増えたときに周辺化に要する計算量が指数関数的に増加するためである。確信度がしきい値 λ よりも大きいとき、 ϕ_n を推定結果と判断する。ここで、 ϕ_n は $K \times 1$ の行列であり、本稿では、 n 番目の要素および、それ以外の要素をそれぞれ $\phi_g, -\phi_g$ としている ($n = 0, \dots, K-1$)。UKF を用いているため、確信度は多変量正規分布の密度関数で定義される。そのため、 z の次元数が大きいほど、また分散共分散行列の行列式の絶対値が大きいほど、その値は小さくなる。適切な λ の値については事前に十分検討しておく必要がある。

工学的な観点において BaM は、ノイズの含まれる観測源から観測した特徴量とあらかじめ記憶した特徴量の一致を判定するツールとみなすことができる。しかしながら、S. Bitzer らの提案したオリジナルの BaM を工学的に応用する際には解決すべき点がある。一般に、 z の次元が \mathbf{x} の次元よりも大きいとき、 \mathbf{x} による z の推定は劣決定問題であり、解が一意に定まらない。ここで、特徴量ベクトルの次元数を D_f とするとき、 D_f 個の要素それぞれについて、様々な値を記憶することが想定される。それぞれについて n 通りの値を記憶させるとき、アトラクターの数 (すなわち z の次元数) は n^{D_f} となる。多くの場合、 $n^{D_f} > D_f$ であり、劣決定問題となってしまう。BaM では z がアトラクターを持つ非線形ダイナミクスによって更新されるため、いずれ z がいずれかのアトラクターに収束することが期待できる。しかしながら、カルマンフィルタはモデル誤差の分散最小化を行うために、一度 z がアトラクター以外の位置に推定され、その際の推定分散値が小さい値を取るのであれば、アトラクター以外の均衡点で停留してしまう。アトラクター以外の均衡点では、確信度の値は低くなり、意思決定のしきい値を超えない可能性が生じる。

S. Bitzer らは脳の情報処理モデルとしての BaM の特性を検証しており、その際には z の次元が \mathbf{x} の次元よりも大きい状況や、列決定な推定となる状況は想定していない。我々は、ベイジックフィルタの一種であるパーティクルフィルタを用いることでこの問題を解決した。パーティクルフィルタはベイズ推定に基づく状態推定手法の一つである。状態推定に必要な確率分布を、数式ではなく多数の粒子 (パーティクル) 群の集合として表現し、状態空間上の重みつきパーティクルによって事後確率分布を近似する。パーティクルフィルタでは逐次的なモンテカルロシミュレーションを行い、尤度に基づく重みをパーティクルに与える。アトラクター以外の位置では値の低くなる尤度関数を定義することで、 z は前述の均衡点に留まるよりもアトラクターに向かう確率が高くなり、推定結果はアトラクターの近傍となることが期待できる。

BaM に適用するパーティクルフィルタのアルゴリズムは以下の通りである。ここで、全パーティクル p_i ($i = 0 \dots N_P - 1$) はあらかじめ初期化されているものとする。

- (1) 式 (1) に基づき p_i を更新する ($p_i \leftarrow p_i + \Delta g(p_i)$)。
- (2) パーティクルの重み $W_i = P(y | p^i)$ を計算する。尤度

関数 $P(y | p^i)$ には観測値 y の分布が既知であればそれを用いる。未知であるのであれば適切な分布で近似したものを用いる。

(3) \hat{z} を算出する。 \hat{z} は p_i の重み付き平均として与えられる。 $\hat{z} = \sum_{i=0}^{N_P-1} \mathcal{W}^{-1} W_i p_i + \mathbf{w}_t$ ここで、 $\mathcal{W} = \sum_{i=0}^{N_P-1} W_i$ である。

(4) p_i を SIR 法 [6] を用いてリサンプリングする。

一般にパーティクル数 N_P を増やすことで推定精度は向上するが、計算時間は N_P に比例して増加する。

4. 提案手法

ある事象 S が発生することで、無線通信品質を表現する特徴量が特定の値を出力するとき、BaM にこの特徴量を記憶することで、発生している事象が S であることを推定できる。ただし、BaM にあらかじめ記憶させた特徴量と同じ特徴量が観測されたとしても、発生した事象は必ずしも S であるとは限らないが、本稿では特徴量と事象の関係は一对一であることを前提にする。また、当然であるが、ある事象が発生する際の特徴量を、ネットワークを運用するよりも前に取得することは困難である。また、ネットワークの運用中に、事前に想定していなかった事象が発生する可能性も考えられる。このような状況に対しては、BaM にあらたな特徴量を記憶させる必要があるが、本稿ではこれらが既知であることとし、アトラクター数・特徴量の更新は本稿の対象外とする。

LoRaWAN は自営ネットワークの構築が可能であるため、同一エリアに複数のネットワークが混在し得る。そこで、1. で述べたように、無線チャネルごとの混雑度合いを BaM により推定する。2. で説明したように、端末が N_i 台存在する際の混雑度合いを表す特徴量 μ_i を BaM に記憶させる (i は記憶させる状態の数であり、アトラクター数と一致する)。特徴量として本稿では、データの到達率、データの復号成功率、ACK の受信率を用いる。一定周期ごとに一周期内のこれらの値を計算して BaM に入力する。データの到達率とは、ネットワークサーバが各端末のデータ送信スケジュールを既知であると仮定した上で、一周期中にネットワークサーバに実際に届き、かつ正常に復号されたデータ数を、想定される受信データ数で除算した値とする。データの復号率は、ゲートウェイがデータのみを受信すると仮定した上で、一周期中に受信した信号の内、復号に成功したものの割合である。ACK 受信率は端末によるデータ送信後に ACK が端末に返ってこなかった割合である。ACK 受信率についてはゲートウェイが直接観測できない値であるが、本稿では端末が送信データのヘッダに、直前のデータ送信に対して ACK が届いたかそうでないかを表す情報を載せることで近似的な値をゲートウェイが知ることができることとしている。

無線チャネルの割り当ては各無線チャネルの混雑度合いを等しくするように行う。これはランダム発生するデータ送信が互いに衝突しない確率が、混雑度合いの増加に対して指数関数的に減衰するためである。BaM による推定結果として得られた、無線チャネル c における端末数を $N_i(c)$ 、BaM の動作するネットワークで無線チャネル c を使用する端末の数を $N_{own}(c)$ 、利用可能な無線チャネルの数を N_c と表すとき、各無線チャネルに割り当てる端末の数 $N'_{own}(c)$ を以下のように決定する。

$$N'_{own}(c) = \frac{1}{N_c} \sum_c N_i(c) - \{N_i(c) - N_{own}(c)\} \quad (4)$$

端末の無線チャネル割当については、BaM で観測を行う無

表 1 BaM のパラメータ

Parameter	Value	description
q	0.35	dynamics uncertainty
r	σ	sensory uncertainty
b^{lat}	1.7	strength of the lateral inhibition
b^{lin}	$b^{lat}/20$	strength of a goal state attractor
Δ	0.004	time difference
k	100	scale of dynamics
g	10	distance factor between attractors
r	0.7	slope of sigmoid function
o	$g/2$	center of sigmoid function

線チャンネルすべてにおいて、確信度が一定のしきい値を超えた際に行う。また無線チャンネルは、すべての端末を対象に再割り当てを行うこととする。本手法では、再割り当てが行われていない端末を無作為な順で選択し、各無線チャンネルの割当数が N'_{own} となるまで割り当てていくこととする。端末への無線チャンネル割り当てを行った結果が通信に反映されるのは、各端末がチャンネル割当てが行われてから最初のデータ送信の後である。そのため、無線チャンネル割当てを行ってから一定時間は次の割当てを行わないこととする。また、制御対象のネットワークに属するノードが一台も存在しない無線チャンネルについては、BaM へ入力するための特徴量が得られない。未使用の無線チャンネルについては BaM 以外の方法で調べることが可能であるが、本稿では $N'_{own}(c)$ が N_{min} よりも小さい無線チャンネルについては、 $N'_{own} = N_{min}$ として、最低限の台数を割り当てることとする。その際は、その他の無線チャンネルで混雑度が均等になるようにする。

5. 評価結果

5.1 ベイズフィルタの比較

本節では BaM による認知精度を、パーティクルフィルタを用いた BaM (BaM-PF) を UKF を用いた BaM (BaM-UKF) と比較評価する。平均が μ_1, μ_2, μ_3 のいずれかであり、分散が σ^2 の正規分布に従う乱数を N_s 個生成し、特徴量の入力系列 $S = s_0, s_1, s_2, \dots, s_{N_s-1}$ として用いる。各タイムステップごとに各手法で得られる出力の精度を調査するために、この正規分布の平均が μ_1, μ_2, μ_3 のいずれであるのかを各手法で出力し、確信度の推移を調べる。各手法での出力の計算方法については以下の通りである。

a) BaM-UKF

アトラクター数を 3 に設定し、それぞれのアトラクターに μ_1, μ_2, μ_3 ($\mu_1 > \mu_2 > \mu_3$) を記憶させる。各タイムステップごとに入力を与え、確信度がしきい値を超えたアトラクターが存在すれば、そのアトラクターに記憶した値を出力する。確信度がしきい値を超えるアトラクターが複数存在する場合は、もっとも高い確信度が得られたアトラクターを選択する。BaM のパラメータは特に断らない限り、文献 [2] で用いられている値を使用する。表 1 にパラメータ一覧を示す。

k に関して、文献 [2] では 4 に設定されているが、意思決定変数の変化に非常に長い時間を要している。本評価では意思決定変数がよりアトラクターに近づきやすくなるように、100 と設定している。

b) BaM-PF

BaM-UKF と同様に出力を計算する。BaM-PF では表 1 のパラメータに加えて、パーティクル数と尤度関数を決める必

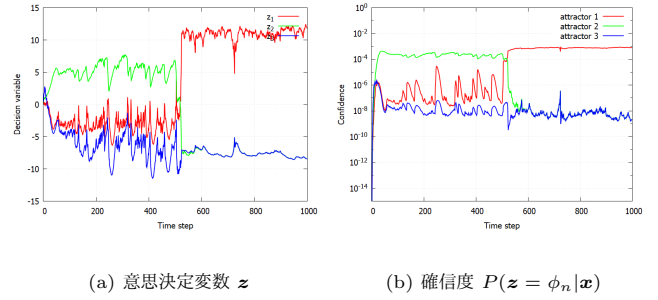


図 2 BaM-UKF

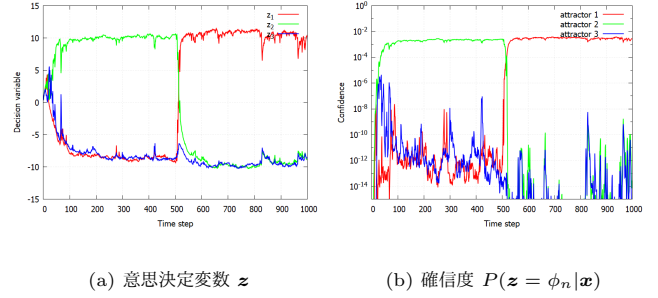


図 3 BaM-PF

要がある。本評価ではパーティクル数は 3,000、パーティクル p_i の尤度関数は平均が $[\mu_1 \mu_2 \mu_3]\sigma(\hat{z})$ 、分散 σ^2 の正規分布とする。

c) シミュレーション結果

$N_s = 1,000$ 、 $(\mu_1, \mu_2, \mu_3) = (1, 0, -1)$ と設定し、評価を行った。ここで、 s_0-s_{499} は、平均 0、分散 $\sigma^2 = 4$ の正規分布に従う乱数を生成し、 $s_{500}-s_{999}$ は平均 1、分散 $\sigma^2 = 4$ の正規分布に従う乱数を生成している。図 2 および図 3 に、BaM-UKF と BaM-PF の z と確信度の推移をそれぞれ示している。いずれもアトラクターの数は 3 つであり、意思決定変数を $z = [z_1 z_2 z_3]^T$ とするとき、3 つのアトラクター ϕ_1, ϕ_2, ϕ_3 はそれぞれ、 $[10 -10 -10]^T$ 、 $[-10 10 -10]^T$ 、 $[-10 -10 10]^T$ である。

BaM-UKF では、意思決定変数がアトラクターから離れた均衡点で留まっていることが分かる。一方で BaM-PF では BaM-UKF と比較して、意思決定変数がよりアトラクターに近い場所で留まっている。確信度は、意思決定変数がアトラクターに近づくほど高くなるため、観測値に最も近い値を記憶したアトラクターの確信度は BaM-PF の方が高く、観測値と離れた値を記憶したアトラクターの確信度は BaM-PF の方が低くなっている。BaM-UKF では、意思決定変数がアトラクターに近づくとは限らず、そのため確信度のしきい値を適切に設定することが困難となる。一方で BaM-PF では意思決定変数がアトラクターに近づいておりこのような問題は発生していない。

5.2 無線チャンネル割当

本節では、BaM-PF を用いて混雑度合いを推定して無線チャンネルの割当てを行い、確信度の推移を評価する。

a) シミュレーションモデル

$5 \times 5 \text{ km}^2$ のエリアに LPWA 端末 200 台とゲートウェイ 1 台を設置する。端末の x および y 座標は $[0 5] \text{ km}$ の範囲の一樣乱数に従い決定し、ゲートウェイは $(0, 0)$ に設置する。各

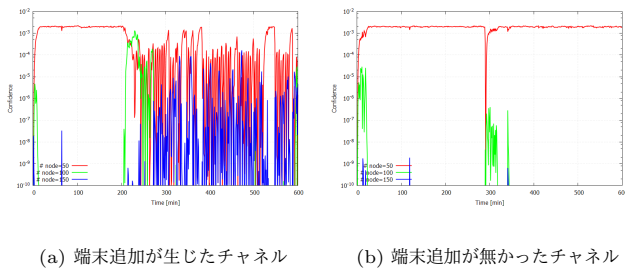


図 4 無線チャンネル割当時の確信度推移

端末は 300 秒ごとに 1 個、周期的にデータを生成する。生成するタイミングは端末間で非同期であり、また、連続的に衝突する状況を回避するため $-2.5 \sim 2.5$ s の一様乱数を加えている。端末の使用可能な無線チャンネル数は 4 とし、シミュレーション開始時には、それぞれの無線チャンネルを使用する端末数は 50 台に設定する。

データと ACK のフレームサイズはそれぞれ 50 byte, 10 byte とし、データレートは 1.5 kbps とする。端末及びゲートウェイは、データ・ACK 送信前に 5 ms のキャリアセンスを行う。CCA しきい値を -83 dB とし、同一チャンネルを利用している信号を検出したときは送信を中止する。端末はあるデータ送信において、キャリアセンスでのビジー状態検出あるいはゲートウェイから ACK が届かない場合に合計で一度だけデータを再送する。

信号伝搬は直接波のみを考慮し、フリスの伝達公式で与えられることとする。ここで、使用周波数を 920 MHz、減衰係数を 2.5、端末およびゲートウェイのアンテナ受信感度を -131 dB、送信電力を 13 dB、送受信アンテナのゲインを 5 dB としている。データおよび ACK は受信時の SNR に応じて復号エラーが確率的に発生することとし、簡易的なモデルとして、“0dB 以下: 100 %, 0-5 dB: 50 %, 5-10 dB : 10 %, 10-20 dB: 1%, 20 dB 以上: 0%” と設定した。

シミュレーション内で 12,000 秒が経過した時点で、特定の無線チャンネルにのみ LPWA 端末を 50 台追加で設置する。追加端末の設置座標は上記と同様にランダムに決定し、データの生成や通信方法も同様の動作とするが、追加端末に対してゲートウェイは ACK を返さない。

b) ベイジアンアトラクターモデルの設定

BaM-PF のパラメータは 5.1 と同様とする。混雑度合いとして、ある無線チャンネルを使用する端末数が 50, 100, 150 の場合の特徴量をあらかじめシミュレーションによって導出して、アトラクターに特徴量として記憶しておく。また、BaM-PF の尤度関数には、観測値の近似分布として多変量正規分布を用いる。この際の分散共分散行列についてもあらかじめシミュレーションによって導出しておく。特徴量の観測および BaM への入力シミュレーション中での 1 分周期で行う。確信度のしきい値に関しては、5.1 の結果より、 10^{-3} と設定した。また各無線チャンネルに割り当てる端末の最低台数 N_{min} を 10 と設定している。

c) シミュレーション結果

図 4 に端末が追加された無線チャンネルおよび追加されなかった無線チャンネルにおける確信度の推移を示す。端末の追加がなかった無線チャンネルでは、端末数が 50 程度の混雑度合いである確信度がほぼ全ての時刻で、他の混雑度合いに対応する確信

度よりも高い値を示している。シミュレーション開始から 300 分経過した付近で一時的に確信度が減少しているのは、偏った観測値が偶然繰り返し入力されたことが理由である。この際には、いずれの混雑度合いに対しても確信度がしきい値を超えておらず、誤ったチャンネル割当が行われることはなかった。端末の追加が生じた無線チャンネルでは、端末の追加が生じたシミュレーション時刻 200 分から 20 分が経過した時点で、端末数 100 台程度の混雑度合いが生じたと判断して、チャンネル割当が行われている。割当が行われた後は、50 台の端末が追加された無線チャンネルでは、制御対象のネットワークに所属する端末数が 12 台となる（その他の無線チャンネルでは 62 か 63 台）。そのため、BaM の一観測周期で得られる特徴量のばらつきが大きくなり、混雑度合いが 150 台と判断する確信度の値が比較的大きくなっている。しかしながら、端末数が 50 程度の混雑度合いであるとする確信度がほぼ全ての時刻で、他の混雑度合いに対応する確信度よりも高い値を示しており、この確信度のみがしきい値を超えている。

6. おわりに

本稿では、人の認知機構モデルであるベイジアンアトラクターモデル (BaM) を用いて、LoRaWAN における無線チャンネルの状態推定を行い、推定結果に基づき端末に適切な無線チャンネルを割り当てる手法を提案した。確信度に基づき制御を行う提案手法が、一時的な観測値の変動に大きな影響をうけることなく、適切なチャンネル割当を実現できることを示した。また、BaM を工学的に扱いやすくするための拡張を示した。具体的には、BaM で用いられているベイズフィルタを、unscented Kalman filter (UKF) からパーティクルフィルタに変更した。もともとの BaM は人の脳が環境を認知する仕組みをベイズ推定に基づく意思決定によりモデル化できることを示したものであり、BaM によって認知した情報に基づく自律的な制御ループを用いることで、変動する環境へ自律的に適応する制御機構が実現できると期待される。今後は評価の詳細化や他の手法との比較を行い、特に、通信性能の面での提案手法の利点を明確にする。

文 献

- [1] R.S. Sinha, Y. Wei, and S.-H. Hwang, “A survey on lpwa technology: Lora and nb-iot,” *Ict Express*, vol.3, no.1, pp.14–21, 2017.
- [2] S. Bitzer, J. Bruineberg, and S. J. Kiebel, “A bayesian attractor model for perceptual decision making,” *PLoS Computational Biology*, vol.11, no.8, p.e1004442, Aug. 2015.
- [3] LoRa Alliance, “LoRa Specification V1.1.1,” Oct. 2017.
- [4] T. Ohba, S. Arakawa, and M. Murata, “A bayesian-based virtual network reconfiguration in elastic optical path networks,” *IEICE technical report*, PN2016-33, vol.116, no.307, pp.45–50, Nov. 2016.
- [5] M. Iwamoto, T. Otoshi, D. Kominami, and M. Murata, “Rate adaptation with bayesian attractor model for mpeg-dash,” *Proceedings of IEEE Annual Computing and Communication Workshop and Conference (CCWC)*, pp.0859–0865, Jan. 2019.
- [6] A.F. Smith and A.E. Gelfand, “Bayesian statistics without tears: a sampling-resampling perspective,” *The American Statistician*, vol.46, no.2, pp.84–88, 1992.