

ベイジアンアトラクターモデルを用いた 動的な仮想ネットワークトポロジー構築

大歳 達也[†] 大下 裕一[†] 村田 正幸[†]

[†] 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: †{t-otoshi,y-ohsita,murata}@ist.osaka-u.ac.jp

あらまし 将来のIoTアプリケーション等、通信の多様化が予想される中で、ネットワーク仮想化技術を用いて各アプリケーションに合わせた柔軟なネットワーク構築が望まれている。しかし、広範囲に展開されたネットワーク上で絶えず変化する通信状況を正確に把握することは困難であり、従来検討されてきた正確なセンシング情報を前提としたネットワーク構築方法は限界を迎えつつある。従って、部分的な情報から状況を推定する等、各時点で取得できる不確実さを含んだ情報を用いたネットワーク構築が必要となる。本稿では、不確実なセンシング情報を扱いながら意思決定を行っている脳の情報処理機構に注目し、そのメカニズムをネットワーク構築に取り入れることで、このような不確実なセンシング情報を用いながらも状況に応じて適切に仮想ネットワークのトポロジーを変更する手法を提案している。具体的には、脳の意思決定をモデル化したベイジアンアトラクターモデル(BAttM)を基に、仮想ネットワークのトポロジー構築の問題をBAttMの意思決定と対応させて解くことにより、不確実なセンシング情報から、意思決定の状態を逐次的に更新し、十分に確信を得た上で適切なトポロジーへの変更を行う。また、逐次的な状態の更新に加えて、それまでに得られた情報から、どのような意思決定を行う方向に進んでいるのかを予測することで、意思決定にかかる時間を短縮する方法も提案した。そして、シミュレーション評価により、センシング情報が不確かであっても、それを用いることで適切なトポロジーへと素早く切り替えることができ、予測を用いることでさらにその移行期間を短くすることが可能であることを示した。

キーワード ベイジアンアトラクターモデル, 仮想ネットワーク, トポロジー設計

Reconstruction of Virtual Network by Bayesian Attractor Model

Tatsuya OTOSHI[†], Yuichi OHSITA[†], and Masayuki MURATA[†]

[†] Graduate School of Information Science and Technology, Osaka University 1-5 Yamadaoka, Suita, Osaka, 565-0871, Japan

E-mail: †{t-otoshi,y-ohsita,murata}@ist.osaka-u.ac.jp

Abstract Network Virtualization is expected to handle the various network traffic induced by such as IoT applications because a virtual network can be constructed adaptively to each type of applications. Since the traffic patterns changes with time, the virtual network should be reconstructed dynamically to accommodate increasing traffic and to release the unused resources. However, collecting the entire information of traffic is quite hard if the targeted application is deployed on a wide-range network. Thus, it is required to handle the uncertainty of information caused by the incompleteness of data and dynamics of changing traffic. In this paper, we propose applying the brain mechanism to the virtual network reconstruction, which deals with the uncertain information in decision making. Since the decision making in the brain is formulated as Bayesian Attractor Model(BAttM), we reformulate the virtual network reconstruction according to the BAttM to handle the uncertainty of sensing information. Moreover, we introduce the prediction of which decision is more likely selected in the future to decide the appropriate topology quickly. In the evaluation, we show that the proposal method quickly sets the appropriate topology even with using the uncertain sensing information. Additionally, we show that the prediction mechanism shortens the time required to decide the topology.

Key words Bayesian Attractor Model, Virtual Network, Topology Reconstruction

1. はじめに

IoT アプリケーション [1] の展開をはじめとして、将来の通信の多様化が予想される中で、ネットワーク仮想化技術 [2,3] を用いて、それぞれのアプリケーションに合わせた柔軟なネットワーク構築が望まれている。仮想ネットワークはそれぞれのアプリケーションで必要とする通信を収容できるように構築されるべきであるが、通信状況は時間と共に変化し得るため、固定の仮想ネットワークを構築すると、資源の不足あるいは過剰を生じる。そのため、定期的に通信状況のセンシングを行いつつ、動的に仮想ネットワークの構築、変更を行うことが必要である。

しかし、広範囲に展開される IoT で生じる通信等、大規模なネットワーク上での通信を詳細に把握することは困難であり、従来提案されているようなネットワーク全体のトラフィック情報を用いてネットワークを最適化する手法 [4] は適用できない。部分的なセンシング情報を用いて、全体の通信状況を推定する手法 [5] も考案されているものの、センシングの不完全さは推定誤差として現れるため、結局、取得できる情報には不確かさが含まれる。従って、不確実なセンシング情報に基づきながらも、適切な判断、意思決定を行うことが必要となる。

このような、不確実なセンシング情報に基づきながら意思決定を行っているシステムの身近な例として、脳の情報処理機構が挙げられる。脳では、不完全なセンシング情報から、あり得る状況を推定し、最終的な意思、行動決定までを行っている [6]。そこで、この脳の情報処理機構の動作を、ネットワーク構築に取り込むことができれば、完全な通信状況の把握ができない場合であっても、適切なネットワークを構築することが可能になると期待される。

脳の情報処理機構は未だ完全に解明されていないが、その振る舞いについて数理的なモデル化が進められつつある。そのような数理モデルの一つとして、ベイジアンアトラクターモデル (BAttM: Bayesian Attractor Model) [7] がある。BAttM は、脳が不確実なセンシング情報を受けて、状況を推定し、意思決定を行うまでの振る舞いをベイズの確率論を用いてモデル化したものである。BAttM では、確率的な意思決定の状態を内部状態として持っており、外部からのセンシング情報を用いて逐次的にその状態を更新する。そして、特定の選択肢について、十分に高い確率で確信を持った時点で、その選択を取るという意思決定を行う。

本稿では、仮想ネットワークのトポロジー構築を BAttM の意思決定モデルとしてモデル化することで、脳の情報処理機構を仮想ネットワーク制御へと応用する。すなわち、仮想ネットワークのトポロジー構築の問題を、不確実なトラフィック情報をセンシングし、状況に適したトポロジーを意思決定により選択するものとしてモデル化し、BAttM の枠組みで状態の更新、及び、意思決定を行う。これにより、各時刻では正確な情報が得られないとしても、逐次情報を更新し、適切なトポロジー制御を行うことができる期待される。

ただし、脳の情報処理機構とネットワーク制御では、その動作時間周期が異なるため、BAttM を応用する上ではそのギャップを解消することが必要である。BAttM では、ミリ秒オーダー

で情報のセンシングと状態の更新を同時に行うことを想定しているが、ネットワーク上のトラフィック観測では、典型的には秒または分オーダー等のより長い周期で観測が行われる。そのため、BAttM をそのままネットワーク制御に適用すると、意思決定の状態の更新周期も長くなり、トラフィックの状況が変わった場合に、それに合わせたトポロジーに変更するまでに要する時間が長くかかってしまう可能性がある。そこで、意思決定の状態については、観測によって更新するだけではなく、それが将来的にどのような判断に向かうのかを予測し、予測された状態に基いて判断を行うことで、素早く判断が切り替えられる仕組みを導入する。

本稿の以降の構成は次の通りである。2 章では、BAttM の状態更新及び意思決定について述べ、3 章では、仮想ネットワークのトポロジー構築の問題を BAttM として定式化し、逐次的な状態更新及び状態の推移を予測する方法について述べる。4 章では、BAttM を応用した仮想ネットワークトポロジー構築手法の評価を行い、5 章では、本稿のまとめと今後の課題について述べる。

2. ベイジアンアトラクターモデル (BAttM)

本章では、不確かなセンシング情報に基いて脳が行う意思決定をモデル化したベイジアンアトラクターモデル (BAttM) [7] の概要及び、その状態更新と意思決定について述べる。

2.1 概要

BAttM では意思決定の状態 z_t を内部状態として持っており、外部からの観測値 x_t を受けることで z_t を更新し、状況の判断を変えていく。そして、予め用意された S 個の選択肢に対応した状態値 ϕ_1, \dots, ϕ_S の中のいずれかに状態 z_t が到達した時、すなわち $z_t = \phi_i$ となった時に、 i 番目の選択肢を取るという意思決定を行う。

この時、状態の更新には、ベイズ推定の考え方が導入され、 z_t は一点として更新されるのではなく、観測値の不確かさ、及び、ダイナミクスの不確かさを反映した確率分布 $P(z_t)$ として更新される。また、 z_t の値は確率を伴って表現されているため、 $z_t = \phi_i$ の判定には、確率的な意思決定が導入される。以降では、状態の更新と意思決定の詳細について述べる。

2.2 状態の更新

状態の更新は、観測値 x_t から意思決定状態 z_t をベイズ推定によって事後分布 $P(z_t|x_t)$ を求めることで行われる。

x_t および z_t については、次のような生成モデルが仮定される。

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

$$x_t = M\sigma(z_t) + v_t \quad (2)$$

ここで、 f はホップフィールドネットワークのダイナミクスを表しており、 S 個の選択肢に対応した状態値 ϕ_1, \dots, ϕ_S を不動点 (アトラクター) として持つ。 M は各 i 番目の選択肢に対応した観測値 μ_i を並べた行列 $M = [\mu_1, \dots, \mu_S]$ であり、 σ は値域が 0 から 1 である多次元のシグモイド関数である。 w_t, v_t は、ノイズ項であり、それぞれ正規分布に従い $w_t \sim N(0, \frac{q}{\Delta t} I)$, $v_t \sim N(0, r^2 I)$ である。ただし、 q はダイナミクスの不確かさであり、 r は観測の不確かさである。

ベイズ推定により、上の生成モデルを逆方向に推定することで、観測情報 $\mathbf{x}_t \sim N(\boldsymbol{\mu}_i, s^2 I)$ から、決定状態 z_t を決める意思決定のモデルが得られる。(s は観測のノイズの大きさを表すが、 r との違いは、 s は実際の大きさ、 r は意思決定者が想定している大きさである。) 生成モデルは非線形状態空間モデルであり、厳密なベイズ推定は困難であるため、文献 [7] の筆者らは Unscented Kalman Filter(UKF) [8] を用いて近似計算を行っている。

2.3 意思決定

上述の状態推定によって得られるのは、点としての z_t ではなく、 z_t の事後確率 $P(z_t | \mathbf{x}_t)$ である。そのため、意思決定状態がどの選択肢 ϕ_i にあるかの判別は確率を伴って行われる。具体的には、しきい値 λ を導入し、 $z_t = \phi_i$ における確率密度が $P(z_t = \phi_i) > \lambda$ であるような選択肢 i を意思決定の結果として選択する。また、このような i が存在しない場合には、意思決定が終わっていない段階にあると判断される。

$P(z_t | \mathbf{x}_t)$ の計算は、UKF によって推定された期待値 $E[z_t]$ と、分散共分散行列 Σ_t を用いて、 $P(z_t | \mathbf{x}_t)$ が多変量正規分布 $N(E[z_t], \Sigma_t)$ である仮定して計算する。

3. BAttM を用いた仮想ネットワーク構築手法

上述の BAttM を応用することで、不確かな観測情報を基に、ネットワーク上のトラヒックの状況を素早く判断し、状況に合わせた仮想ネットワークトポロジーを設定する手法を実現する。

3.1 概要

本制御手法では、ネットワーク上に配置された観測器から順次情報を得て、トラヒックの状況を判断する。短周期の間に得られる観測情報は部分的な情報となり、トラヒック変動による不確かさに加えて、不完全な観測による不確かさが含まれる。これらの不確かさは、BAttM で扱っている dynamics uncertainty 及び sensory uncertainty に対応付けることができ、BAttM を応用することで、逐次的にネットワーク状態を判断し、制御を決定することが可能となると期待される。すなわち、順次得られる不確かなトラヒック情報を基に意思決定状態を更新し、意思決定状態の確信度によって設定すべき仮想ネットワークトポロジーを決定する。

しかし、意思決定状態に対して、十分な確信度を得るためには、情報の不確かさを補うに足るだけの十分な観測が必要となる。そのため、単純に BAttM を用いるだけでは、判断を決定するまでに時間を要し、制御が遅れる可能性が高い。そこで、現状の観測情報から、意思決定がどのような方向に進みそうであるかを予測し、その予測を用いて制御を決定する仕組みを導入する。すなわち、得られた観測情報から、BAttM の意思決定状態がどの選択肢に落ち着きそうであるのか、そして、その確信度はどの程度になりそうであるかを予測し、十分な確信度を持てるのであればその選択肢に向かってトポロジーの変更を始める。

以降では、仮想ネットワーク構築の問題を BAttM による意思決定としてモデル化する方法、及び、予測を取り入れた意思決定について述べる。

3.1.1 BAttM の仮想ネットワーク構築への応用

BAttM を仮想ネットワーク制御に応用するに当たって、(1)BAttM の観測値と意思決定状態を仮想ネットワーク上での観測値と制御に対応付ける、(2)アトラクターの構造(ホップフィールドダイナミクス)を決める、(3)観測値と制御の対応関係を観測行列に与えることが必要となる。

(1)の意思決定状態と、(2)に関しては、[9]で類似の問題が扱われており、それを利用できる。ただし、観測値と観測行列(観測式)については別途検討する必要がある。以降では、意思決定状態、観測値、ホップフィールドダイナミクス、観測式のそれぞれについての仮想ネットワーク制御との対応を述べる。

a) 意思決定状態

意思決定状態は、ホップフィールドネットワーク内の各ニューロンの状態値に相当し、トポロジー制御に応用する際には、状態値に対してネットワーク制御の制御変数を割り当てる必要がある。ここでは、[9]のように、仮想ネットワークのトポロジーを仮想リンクの接続関係で表し、各ノードペア i, j 間にリンクが存在するか否かを状態値 z_{ij} で表現する。すなわち、 $z_{ij} = 1$ なら i, j 間にリンクを張っており、 $z_{ij} \neq 1$ なら i, j 間にリンクを張っていないものとして、 $\mathbf{z} = (z_{12}, z_{13}, \dots)$ によって全ノード間のリンクの有無を表現する。

b) 観測値

BAttM において、観測値はホップフィールドダイナミクスに従った意思決定に対してフィードバックを与えるものとなる。すなわち、意思決定が間違っていれば正しい意思決定に誘導し、意思決定が正しければより高い確信を与えるように働く。このため、観測値に求められるのは、その観測値を得ることで、ある程度正しい意思決定が分かるような値であることである。

ネットワークの各地点間のフローのトラヒック量が与えられれば、そのフローを収容するようにトポロジーを決定することができるため、ここでは、観測値としてフローのトラヒック量を用いることとする。すなわち、 x_{ij} のノード i からノード j へ向かうフローのトラヒック量として、 $\mathbf{x} = (x_{12}, x_{13}, \dots)$ によって全ノード間のフローのトラヒック量を表現する。

c) ホップフィールドダイナミクス

ホップフィールドダイナミクス f は、各選択肢 i に対応した状態値 ϕ_i をアトラクターとして記憶するものであり、選択肢として用意するトポロジーに応じて適切に決定する必要がある。

S 個のトポロジーを意思決定状態 ϕ_1, \dots, ϕ_S で表し、これをアトラクターとして記憶するものとする。各意思決定状態のベクトルを列に並べた行列 $X = (\phi_1, \dots, \phi_S)$ を用いて、文献 [9]と同様に、ホップフィールドダイナミクスを次のように定める。

$$f(\mathbf{z}) = X X^+ \varsigma(\mathbf{z}) - \mathbf{z} \quad (3)$$

ここで、 X^+ は X の擬似逆行列であり、 ς は値域が -1 から 1 のシグモイド関数で、ベクトルに対しては、各要素にシグモイド関数を適用したベクトル値を返すものとする。値域が 0 から 1 のシグモイド関数 σ とは記号を分けて区別することとする。

d) 観測行列(観測式)

観測行列の働きは、観測値を得て現状の意思決定状態を正しい意思決定状態に向かって修正する時に、観測値に対応した正

解を与えるものである。元の BAttM では、一つのニューロンが一つの選択肢を表していたため、代表的な観測値 μ_i を対応するニューロン毎に並べた観測行列 M によって観測式を定義していた。今の場合、複数のニューロンの発火の組み合わせによって一つの選択肢を表しており、ニューロンと観測値がそのまま対応しているわけではないため、上の方法は使えず観測式を変更する必要がある。

理想的には、観測式は、観測値 x に対して適切なトポロジー z を返す関数 $c(x)$ の逆関数を用いて、 $x = c^{-1}(z)$ と表されることが望ましい。しかし、 c に逆関数が存在するとは限らず、また、 c は任意の観測値について最適解を返すものであるからそれ自体を求めることが困難である。

そこで、いくつかの代表的な観測値 $\mu^{(i)}$ についてのみ最適（あるいは準最適）なトポロジー $z = c(\mu^{(i)})$ を計算し、 c 及び c^{-1} を近似する方法が考えられる。すなわち、アトラクターに対応した観測値、すなわち、 $z^{(i)}$ が最適なトポロジーとなるようなトラヒック量のベクトル $\mu^{(i)}$ を求めて、各 $\mu^{(i)}$ について、 $\mu^{(i)} = h(z^{(i)})$ となるように関数 h を定める。このように定められる関数 h として、ここでは次のものを用いる。

$$h(z) = \sum_i \mu^{(i)} \delta_{z^{(i)}}(z) \quad (4)$$

$$\delta_{z^{(i)}}(z) = \prod_{j|z_j^{(i)}=1} \sigma(z_j) \prod_{j|z_j^{(i)}=0} (1 - \sigma(z_j)) \quad (5)$$

式中の $\delta_{z^{(i)}}(z)$ は、 $z = z^{(i)}$ となった場合にほぼ 1、それ以外はほぼ 0 の値をとり、 $z = z^{(i)}$ の時に総和の i 番目の $\mu^{(i)}$ のみが観測値として現れる式となっている。

代表値 $z^{(i)}$ の値は必ずしもアトラクター ϕ_i である必要はないが、ここでは、 $z^{(i)} = \phi_i$ として、アトラクターにおける観測値のみの対応を与えることとする。

3.1.2 予測を用いた意思決定

上述により、仮想ネットワーク構築の問題を BAttM としてモデル化したことにより、BAttM も同様の状態推定を行うことで、各時刻の不確かさを含んだトラヒックの観測値 \mathbf{x}_t から、その時点で適切なトポロジーの状態 \mathbf{z}_t の事後確率 $P(\mathbf{z}_t|\mathbf{x}_t)$ が求められる。しかし、トラヒックの観測値が得られる時間粒度は、脳がセンシング情報を受取る時間粒度よりも長い場合、観測値を受けたタイミングで更新された状態を用いるだけでは、状況の変化に対して判断が遅れる可能性がある。

そこで、現時点まで得られた観測から、将来的にどのトポロジーを設定することが適切であるかを予測して、その予測されたトポロジーを設定することで、判断の切り替えを早める仕組みを導入する。

意思決定状態は、式 (1) で示されるダイナミクスを持っており、観測値を伴わずとも状態値がアトラクターに向かって進むものとなっている。従って、式 (1) に従って、現時点の状態の分布 $P(\mathbf{z}_t|\mathbf{x}_t)$ から、 h ステップ先の将来の状態の分布 $P(\mathbf{z}_{t+h}|\mathbf{x}_t)$ を求めることができる。

このようにして、予測された状態値の分布を用いて、 $P(\mathbf{z}_{t+h} = \phi_i|\mathbf{x}_t) > \lambda$ なるトポロジー ϕ_i を構築することで、アトラクターに到達していない過渡期の段階で、到達すると予測されるアトラクターを設定可能となる。

4. シミュレーション評価

上述の BAttM を応用した仮想ネットワークトポロジー構築手法の有効性を確認するため、シミュレーションによる評価を行った。

4.1 シミュレーション環境

4 ノードの仮想ネットワークを構築する状況を与え、全 12 ノードペア間について、リンクを張るか張らないかを決定する。

a) トラヒック

トラヒックは一部のノードペア間で一定量を送出し、1000 タイムスロット経過後にトラヒックを送出するノードペアの集合を変更する。この時、トラヒックの変化に対して適切なトポロジーに移行できるか、移行にかかる時間はどの程度かに注目する。

リンク帯域を 1 とし、各フローが送出トラヒック量は 1/3 であるとする。また、観測されるフローのトラヒック量には正規分布に従った誤差が含まれ、その誤差の標準偏差は $s = 0.2$ である。

b) アトラクター

アトラクターはトラヒックの変化前、及び、変化後のそれぞれについて適切なトポロジーを用意しておく。具体的には、各トラヒックパターンについて、ランダムに複数のトポロジーを生成し、その中で最大リンク利用率と使用するリンク数の重み付け和を最小としたものをアトラクターとして用意した。この時のリンク数に対する重み w は、あり得る全てのリンクの数 $L = 12$ を用いて、 $w = 1/L$ である。

c) パラメータ

提案手法では、値域の異なる 2 つのシグモイド関数 σ, ς を用いるが、その具体的な関数としては、次の形のものを用いた。

$$\sigma(x) = \frac{1}{1 + \exp(-\alpha x)} \quad (6)$$

$$\varsigma(x) = \tanh(\beta x) \quad (7)$$

α, β はそれぞれシグモイド関数のカーブの急峻さを表すパラメータである。

そして、生成モデルに含まれる各パラメータの値は、 $q = 0.98, \alpha = 1, \beta = 3$ とし、 $r = s = 0.2$ とした。また、状態の更新には UKF を用いるものとし、初期状態は期待値が $E[\mathbf{z}_0] = 0$ で分散共分散行列が $\Sigma_0 = I$ であるとした。

4.2 比較対象

仮想ネットワークのトポロジーをネットワーク全体の正確なトラヒック情報を用いることなく動的に変更する手法として、文献 [9] のアトラクター選択によるトポロジー制御が挙げられる。

この手法では、本稿の手法と同様に、トポロジーの選択肢をアトラクターとして用意し、状態がどのアトラクターに落ち着くかによって構築するトポロジーを決定する。

提案手法との違いの一つは、観測情報の用い方であり、アトラクター選択では、アクティビティと呼ばれる状態の良さを判断するためにのみ観測情報が用いられるのに対して、提案手法では、観測情報からあるべき状態に移行するように状態の更新が行われる。この結果、提案手法はアトラクター選択と比べて

早く適切な状態に移行すると期待され、これを比較評価することで明らかにする。

アトラクター選択による手法では、次式に従ってトポロジーの状態 z を更新する。

$$\frac{dz}{dt} = af(z) + \eta \quad (8)$$

$$a = \frac{\gamma}{1 + \exp(\delta(u - \theta))} \quad (9)$$

a はアクティビティで最大リンク利用率 u が目標値 θ 以下であるときに 0.5~1 の値を取り、 θ を超えると 0 に近い値を取る。 f は BAttM と同様にホップフィールドダイナミクスを、 η は正規分布に従うノイズを表す。各パラメータの設定については、文献 [9] に習った。

4.3 結果

4.3.1 アトラクター選択との比較

図 1 に BAttM の結果を、図 2 にアトラクター選択の結果をそれぞれ示す。

図 1 では、各時刻で更新された意思決定状態 z の各要素について、その期待値と分散、また、各アトラクター ϕ_i における確信度 $P(z_t = \phi_i)$ を示している。グラフを見やすくするため、 z の値については、 ϕ_1 で張られるリンクに対応した z_{10} と、 ϕ_2 で張られるリンクに対応した z_{12} のみを示す。グラフより、期待値は、遷移時以外はアトラクター ϕ_1, ϕ_2 の付近に存在しており、分散については初期状態から数ステップ経過後に小さな値に落ち着いていることが分かる。

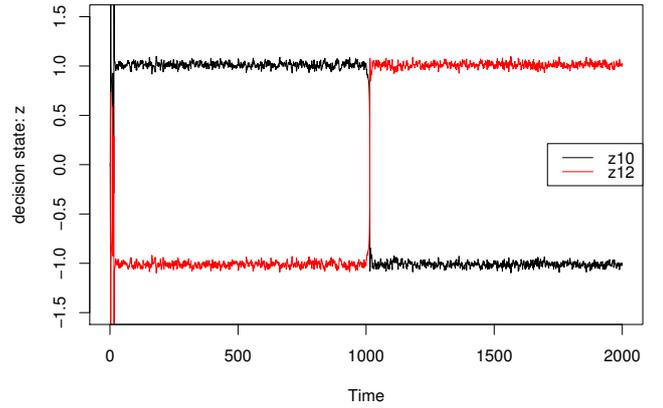
図 1 の確信度を見ると、BAttM ではタイムスロット 1000 でトラフィックが変化した後、20 スロットほどで、アトラクター ϕ_1 から ϕ_2 へ確信が移っていることが分かる。一方、図 2 では、1000 スロット以降でアクティビティの値が低い期間が 500 スロット以上続き、主にノイズ項によるトポロジーの探索が続けられていることが分かる。このように、BAttM はアトラクター選択に比べて正しいアトラクターへの移行が早いことが分かる。また、BAttM の意思決定の移行は、ホップフィールドのダイナミクスの予測を組み入れることで、さらに改善されると期待され、次節でそれを検証する。

4.3.2 予測を用いた場合の意思決定状態

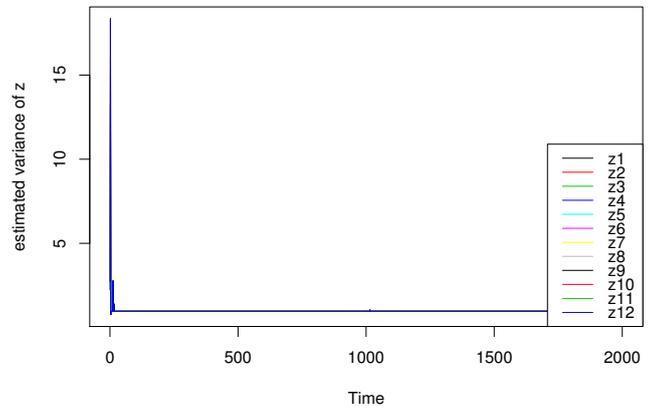
上述の BAttM の結果は、UKF により BAttM の現時点の意思決定状態を求めたものだが、UKF では数ステップ先の意思決定状態を予測することも可能である。このような予測を意思決定に取り入れることで、より素早く状況の切り替わりを判断できることをシミュレーションにより確認する。

図 3 では、 h ステップ先の予測を用いた BAttM と、予測を用いない BAttM の確信度を示している。例えば、タイムスロット 1000 における $h = 1$ の結果は、タイムスロット 1000 の時点で得られた観測値から、1 スロット先 (タイムスロット 1001) における意思決定状態の推移を予測した上で求められた確信度の大きさを表している。凡例で、 h の値を示しているものが、予測を用いた BAttM であり、 h の値を示していないものは予測を用いない BAttM を意味している。また、トラフィックが切り替わった後に注目しているため、タイムスロット 1000~1030 の期間だけを取り出して示している。

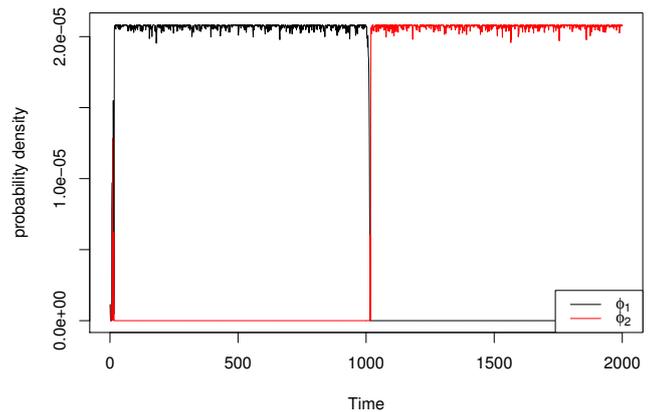
図より、予測を用いることで、予測を用いない場合に比べて



(a) 意思決定状態の期待値



(b) 意思決定状態の推定分散

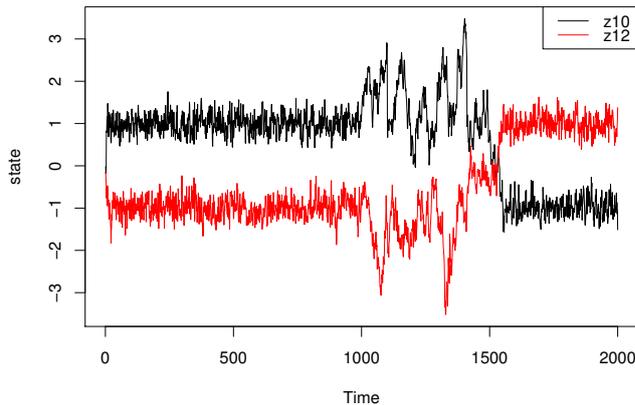


(c) 確信度: $P(z_t = \phi_i)$

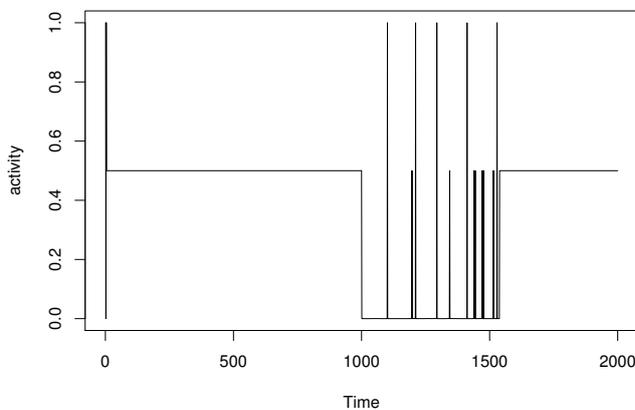
図 1 BAttM の結果

早くトラフィックが切り替わったと確信している状態に移行できていることが分かる。例えば確信度のしきい値を 1.5×10^{-5} とした場合、予測を用いなければトラフィックが切り替わったと判断できるのはタイムスロット 1018 であるが、予測を用いると、 $h = 1$ ではその 1 スロット前、 $h = 2, 3$ では 2 スロット前にトラフィックの切り替わりを判断できていることが分かる。

h が大きくなるにつれ、確信度の絶対値が下がっているが、



(a) 状態値



(b) アクティビティ

図2 アトラクター選択の結果

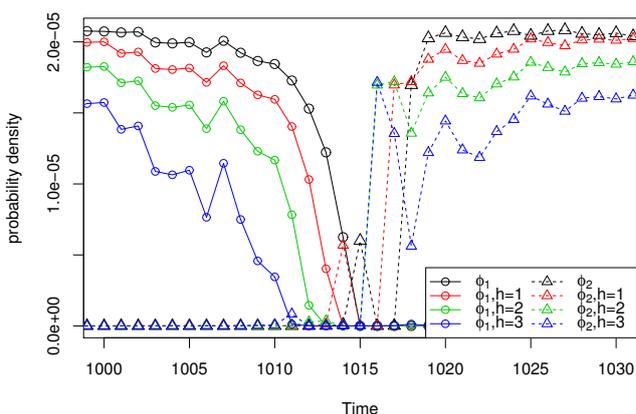


図3 予測を行った場合の確信度

これは先の予測ほど予測誤差が増大することが反映されたものである。従って、あまりに先の将来を考えても適切な制御ができないことが確信度を見ることで分かる。

5. まとめ

本稿では、ネットワーク全体の情報を取得することが困難である状況において、不確実な情報を用いながらも適切に仮想

ネットワークトポロジーを動的に変更する手法を提案した。提案手法では、脳の情報処理機構の数理モデル BAAttM を仮想ネットワークトポロジー構築の応用することで、不確実な情報を基に、状態を逐次的に推定し、適切な意思決定を行う仕組みを導入した。そして、確率的な状態の推定を伴わないアトラクター選択によるトポロジー構築と比較して、より短い時間で適切なトポロジーに移行することが可能であることを示した。また、各時点までに得られた観測値を用いて更新された状態のみを用いるのではなく、そこから将来的にどのトポロジーに向かって更新されていくかを予測し、予測された状態を用いて意思決定を行う手法も提案した。評価の結果、予測を用いた意思決定を行うことで、予測を用いない場合に比べて適切な状態への移行を早めることが可能であることを示した。

今後の課題としては、新たなトラヒックパターンが生じた場合等に、トポロジーの選択肢となるアトラクターを学習する方法を検討すること、適切なパラメータの条件を明らかにし、アトラクターの構造が変化させた場合に、それに合わせてパラメータを修正する方法を検討することが挙げられる。

謝辞 本研究成果の一部は、独立行政法人情報通信研究機構 (NICT) の委託研究「未来を創る新たなネットワーク基盤技術に関する研究開発」によるものである。また、本研究に関して活発な議論に加わって頂いた NTT ネットワーク基盤技術研究所 川原亮一氏、石橋圭介氏、辻野雅之氏、上山憲昭氏に深謝する。

文献

- [1] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari, and M. Ayyash, "Internet of things: A survey on enabling technologies, protocols, and applications," *IEEE Communications Survey & Tutorials*, vol. 17, no. 4, pp. 2347–2376, Forequarter 2015.
- [2] N. M. K. Chownhury and R. Boutaba, "A survey of network virtualization," *Computer Networks*, vol. 54, no. 5, Apr. 2010.
- [3] J. Carapinha and J. Jimenez, "Network virtualization: a view from the bottom," in *Proceedings of the 1st AMC workshop on Virtualized infrastructure systems and architectures*, Aug. 2009, pp. 73–80.
- [4] C. Graleigh, F. Tobagi, and C. Diot, "Provisioning IP backbone networks to support latency sensitive traffic," in *Proceedings of IEEE INFOCOM 2003*, Apr. 2003, pp. 375–385.
- [5] Y. Zhang, M. Roughan, W. Willinger, and L. Qiu, "Spatio-temporal compressive sensing and Internet traffic matrices," in *Proceedings of ACM SIGCOMM 2009*, Aug. 2009, pp. 267–278.
- [6] I. Vilares and K. Kording, "Bayesian models: the structure of the world, uncertainty, behavior, and the brain," *Annals of the New York Academy of Sciences*, vol. 1224, pp. 22–39, Apr. 2011.
- [7] 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.
- [8] S. J. Julier and J. K. Uhlmann, "A new extension of the kalman filter to nonlinear systems," in *Proceedings of SPIE3068, Signal Processing, Sensor Fusion, and Target Recognition VI*, Jul. 1997.
- [9] T. Ohba, S. Arakawa, Y. Koizumi, and M. Murata, "Scalable design method of attractors in noise-induced virtual network topology control," *IEEE/OSA Journal of Optical Communications and Networking*, vol. 7, no. 9, pp. 851–863, Sep. 2015.