

脳の情報処理機構にもとづく 実世界協調予測型ネットワーク資源制御の一考察

佐竹 幸大[†] 安 世民[†] 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: [†] {k-satake, s-an, y-ohsita, murata}@ist.osaka-u.ac.jp

あらまし Internet of Things(IoT)デバイスといった機器の登場とともに、ネットワークを介して提供されるサービスも多様化している。ネットワークには、各サービスが要求する品質を満たすように、各サービスのトラヒックを収容することが求められ、ネットワークスライシング技術の研究が進められている。ネットワークスライシング技術を用いることにより、ネットワークを仮想的に分割し、ネットワークスライスを構築することができる。スライス化されたネットワークでは、各ネットワークスライスへの資源割り当てが重要な課題となる。各ネットワークスライスが収容するトラヒックは、人の行動などの現実世界の状況の影響を受けて時々刻々変化するため、状況に合わせて資源不足をさけるように動的に資源割当制御を行うことが必要となる。動的な資源割当制御のためには、資源不足のリスクを把握する必要がある、資源不足のリスクの把握には、現在ネットワーク内を流れているトラヒック量のみではなく、現実世界の情報を用いることが有効であると考えられる。しかしながら、実世界情報を含む、観測情報と将来とのトラヒック量との関係は一般的にモデル化が困難であり、また、現実世界でセンシングされた情報を持ちいる場合、現実世界に配置された多種多様なセンサーのすべてから、短い周期で情報を収集することは困難であると考えられる。本稿では、そのように欠損をふくむ現実世界の情報をもとに資源不足のリスクを把握し、動的な資源割当を行う制御に、脳の情報処理機構にもとづく手法の適用を検討する。

キーワード ネットワークスライシング、資源割当、ベイジアンアトラクタモデル

Discussion on predictive network resource control incorporating real-world information inspired by human brain cognition process

Kodai SATAKE[†] Semin AN[†] Yuichi OHSITA[‡] and Masayuki MURATA[‡]

[†] Graduate School of Information Science and Technology, Osaka University

1-5, Yamadaoka, Suita, Osaka, 565-0871 Japan

E-mail: [†] {k-satake, s-an, y-ohsita, murata}@ist.osaka-u.ac.jp

Abstract Many kinds of service have been provided through networks as Internet of Things (IoT) devices become popular. Traffic from such services should be accommodated so as to satisfy the requirements which depend on services. One approach to accommodating traffic so as to satisfy the various requirements is to use the network slicing, which provides multiple network slices for the network services. Resources for each slice should be dynamically allocated so as to follow the traffic changes. Because the real-world condition has a large impact on traffic changes, real-world information is useful to predict future traffic. However, the relationship between real-world information and future traffic is difficult to model. In addition, it is difficult to collect all information censored in the real-world in a short time interval, and only a part of the information can be monitored. In this paper, we discuss the method to handle real-world information to predict future traffic and dynamically control the resources inspired by the human brain cognition process.

Keywords Network slicing, Resource management, Bayesian attractor model

1. はじめに

スマートフォンやタブレットといった高機能なモバイル端末の普及や Internet of Things(IoT)デバイスといった機器の登場とともに、ネットワークを介して提供されるサービスも多様化している。ネットワークには、各サービスが要求する品質を満たすように、各サービスのトラフィックを収容することが求められている。このような多種多様なサービスを収容する方法として、ネットワークスライシング技術の研究が進められている [1], [2]。ネットワークスライシング技術を用いることにより、ネットワークを仮想的に分割し、ネットワークスライスを構築することができる。このネットワークスライスを各サービスに対して構築することにより、各サービスに応じた仮想的なネットワークを柔軟に構成し、運用することが可能となる。

ここで、スライス化されたネットワークでは、各ネットワークスライスへの資源割り当てが重要な課題となる。各ネットワークスライスが収容するトラフィックは、人の行動などの現実世界の状況の影響を受ける。例えば、モバイルネットワークを対象とすると、人が密集するエリアでは輻輳発生リスクが増加するなど、人の行動の影響を受けることが考えられる。その結果、各スライスを流れるトラフィック量は時々刻々変化し、当初割り当てた資源では十分にトラフィックを収容することができなくなったネットワークスライスでは、必要な通信品質を維持することができなくなる。このような品質劣化を防ぐためには、資源不足が発生するリスクを把握し、資源不足が発生しないようにネットワークスライスに割り当てる資源を動的に変更することが求められる。資源不足のリスクを把握するためには、トラフィック量を予測することが重要であり、これまで過去に観測されたトラフィック量から将来のトラフィック量を予測する研究が進められてきた [3]-[9]。しかし、資源不足のリスクを把握するためには、現在ネットワーク内を流れているトラフィック量のみではなく、現実世界の情報を用いることが有効であると考えられる。しかしながら、実世界情報を含む、観測情報と将来とのトラフィック量との関係は一般的にモデル化が困難である。

さらに、現実世界でセンシングされた情報をもちいる場合、現実世界に配置された多種多様なセンサーのすべてから、短い周期で情報を収集することは困難であり、各時刻においては、観測する情報のうち、一部の情報しか得られない。また、情報が得られたとしても、その情報にはノイズが含まれている。

そのため、現実世界のセンシング情報を生かしながら、時々刻々変化するトラフィックに合わせてネットワークを制御するためには、このような各時刻に得られ

る情報が一部かつ不正確である場面に対応できる手法が必要となる。

曖昧かつ部分的な情報をもとに逐次判断を行っている代表的なものとして、人の脳が挙げられる。近年、脳が行う情報処理はベイズ確率モデルを用いて表すことができるとする Bayesian Brain 仮説が提唱されており [9]、それによると、脳は誤差を含んだ情報を抽象化した上で観測・取得し、取得・抽象化された情報をもとにモデルを構築し、構築されたモデルにもとづいて意思決定をしているとされる。これにより、脳は、得られる情報は不正確であり、状況を正確に把握できない場合であっても、即時に意思決定を行うことができるとともに、新たに得られた情報をもとに逐次、自身の認知の状態を更新することにより、状況判断の精度を向上できる。

脳が不確かなセンシング情報に基づいて意思決定を行う過程のモデルの一つに、Bayesian Attractor Model(BAM)がある [9]。BAM では、意思決定状態 z_t を内部の状態として持ち、外部から得られた観測値 x_t に基づいて z_t を更新する。BAM が行う状況判断は、意思決定状態 z_t によって決定される。事前に用意した S 個の選択肢に対応した状態値 ϕ_1, \dots, ϕ_i のいずれかに状態 z_t が到達した時、到達した状態に対応する選択肢が意思決定の結果となる。この時、状態更新にはベイズ推定の考え方が用いられており、 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、 z_t の値は確率を伴って表現されているため、 i 番目の選択肢に対応するかの判定は、対応するかしないの二値ではなく、得られた確率分布をもとに、 i 番目の選択肢である確信度、 $P(z_t = \phi_i)$ が得られ、 $P(z_t = \phi_i)$ をもととした意思決定が行われる。

我々は、BAM をネットワーク制御に適用することにより、曖昧かつ部分的な情報をもとにネットワーク制御を行う手法について検討を進めている。本稿では、仮想ネットワークスライスへの資源割当制御を対象として、BAM のネットワーク制御への適用方法について議論する。

2. 脳の情報処理機構

Bayesian Attractor Model(BAM) は、脳が不確かなセンシング情報に基づいて意思決定を行う過程をモデル化したものである。図 1 に脳の認知のモデルを示す。図 1 に示すように、本モデルでは、現実世界を観測し、抽象化することにより、特徴ベクトル x_t を得る。そして、特徴ベクトル x_t に基づいて z_t を更新する。BAM が行う状況判断は、意思決定状態 z_t によって決定される。事前に用意した S 個の選択肢(以後アトラクターとよ

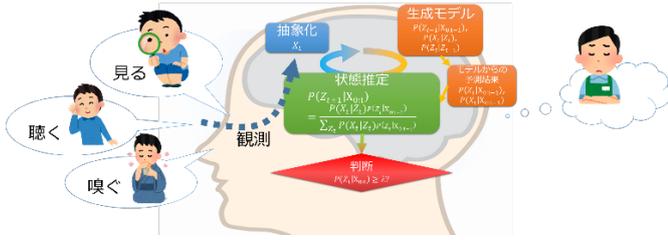


図 1 人の認知のモデル

ぶ)に対応した状態値 ϕ_1, \dots, ϕ_i 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 番目のアトラクターが意思決定の結果となる。

この時、状態更新にはベイズ推定の考え方が用いられており、 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。

2.1. 状態の更新

BAM では、以下のような意思決定状態 z_t 及び観測値 x_t の生成モデルを持つ。

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

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

ここで、 $f(z)$ はホップフィールドダイナミクス、 w_t 、 v_t はノイズ項である。

$M = [\mu_1, \dots, \mu_N]$ であり、 μ_i は、事前に用意された各アトラクターの状態値 ϕ_i に対応する観測値である。

ベイズ推定を用いて、上の生成モデルを逆推定することで、観測値 x_t から意思決定状態 z_t を更新することができる。ただし、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、近似計算により求める。

2.2. 意思決定

上述の状態推定によって得られる z_t は、一点としての z_t でなく、 z_t の事後確率 $P(z_t | x_t)$ 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。

3. 脳の情報処理機構にもとづく実世界協調予測型ネットワーク資源制御

3.1. ネットワーク資源制御

近年のネットワーク仮想化技術に進展により、単一の物理ネットワーク上を仮想的にスライス化し、仮想

ネットワークを各サービスの要求に応じて構築し、構築した仮想ネットワーク上にサービスを收容することが可能となっている。文献[2]に示されるように、モバイルネットワークにおいても様々な仮想化手法が存在し、周波数帯域を仮想的に分割する spectrum-level slicing や、ネットワークレベルで分割する network-level slicing 等が存在する。特に特に、network-level slicing では、RAN(Radio Access Network)における各種基地局等が利用する周波数帯域の一部および、該当 RAN と接続するバックボーン回線や、CN(Core Network)が利用する帯域幅の一部を、仮想的に分割することができる。これにより、単一のモバイルネットワークを用いて、要求が異なり、異なるポリシーで運用される複数のネットワークを構成することができる。

この環境下では、各仮想ネットワークに対して資源を割り当て、各仮想ネットワークでは、自身に対応するサービスの要求を考慮した自身のポリシーに基づき、割り当てられた資源をもとに経路制御やネットワーク機能の配置といった制御を行う。本稿では、このような仮想ネットワーク内の制御、仮想ネットワークへの資源割当制御について検討を行う。

各仮想ネットワークでは、対応するサービスの状態を把握し、当該サービスで收容する必要のある各地点におけるトラヒック量を予測し、予測を踏まえ、予測されたトラヒックを適切に收容するように制御を行う。本予測については、現実世界の情報が有用と考えられる。例えば、何かのイベント等により人が密集した地域からは、当該地域にいる人の持つスマートフォンからの多量の通信が発生するといったことが起こりえる。この場合、人の移動に関する情報を用いることにより、多量の通信が発生する予兆をとらえることができる。

しかしながら、実世界情報を含む、観測情報と将来とのトラヒック量との関係は一般的にモデル化が困難である。さらに、現実世界でセンシングされた情報をもちいる場合、現実世界に配置された多種多様なセンサーのすべてから、短い周期で情報を収集することは困難であり、各時刻においては、観測しうる情報のうち、一部の情報しか得られない。また、情報が得られたとしても、その情報にはノイズが含まれている。

本稿では、このような仮想ネットワークの制御、資源割当に脳の情報処理機構にもとづく制御の適用を検討する。

3.2. 脳の情報処理機構にもとづく制御

脳の認知のモデルでは、認知対象の候補を定め、逐次観測情報が得られる度に、観測情報を抽象化した特徴ベクトルを取得し、生成モデルをもとに認知の状態

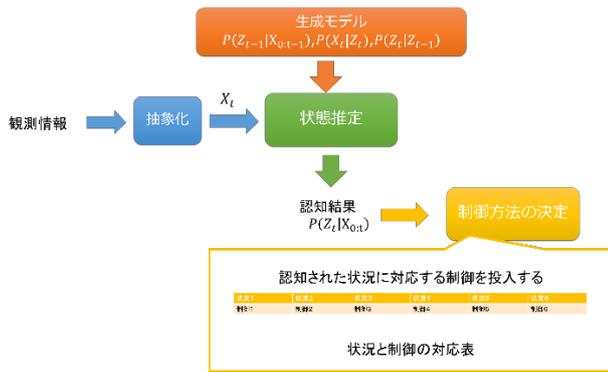


図 2 脳情報処理機構にもとづくネットワーク制御の概要

を更新、更新した認知状態をもとに行う制御を決定することを繰り返す。

以降、認知をもとにした制御の概要を述べたのちに、ネットワーク資源制御における認知対象の定め方、観測情報の抽象化の方法、生成モデルについて述べる。

3.2.1. 制御の概要

我々が検討を行っている環境下では、現実世界でセンシングされた情報やトラヒックの観測情報を蓄積しながら制御を行う。その結果、過去に蓄積された情報から、センシングされた情報やトラヒックの観測値と、その観測情報が得られて一定時間以内に発生するトラヒック量の対応がわかる。このトラヒック量の最大値は、観測情報が得られた時点で制御にとって、収容すべきトラヒック量であると考えられることができる。そこで、我々は、脳の情報処理機構をもとにした認知においては、将来のトラヒック量の予測量を認知の選択肢とし、その選択肢に対応する制御を別途保存しておき、新たな情報が得られるたびに、制御を行うことを考えている。

制御を行う際には、新たに得られた情報を抽象化した観測ベクトル x_t を生成、 x_t を入力として、過去に得られた情報をもとに定めた、いずれの選択肢に現在の状況が合致しているのかを認知する。BAM にもとづく認知では、 $P(z_t = \phi_i | x_t)$ という得られる。そして、 $P(z_t = \phi_i | x_t)$ がもっとも高い状態に対応する制御を行う。

3.2.2. 認知対象の選択肢と対応する制御の決定

脳の情報処理機構にもとづく予測型ネットワーク制御においては、近い将来どのようなトラヒックが発生する状況であるのかを認知する。そのため、認知の選択肢は、近い将来発生するトラヒック量をもとに決定する。ただし、現在の状況と将来のトラヒック量の関係は、一意に決まるものではなく、観測可能な現実世界の情報やトラヒック量が同一であっても、その後発生するトラヒック量は大きく異なることが考えられ

る。

この問題に対応するため、我々は、過去に蓄積された現実世界の観測情報・トラヒック量のうち、類似した状況となっている観測データを束ねたクラスタを構成し、各クラスタについて、将来収容が必要となる各地点からの流入・流出トラヒック量をラベルとして与えることを検討している。将来収容が必要となるトラヒック量は、各観測情報のデータについて、当該時刻以降、一定時間以内に発生した各地点からの流入・流出トラヒック量について最大値を求める。さらに、求めた各値について、クラスタ内の最大値を求め、この値を離散化したものを当該クラスタのラベルとする。このラベルに対応するトラヒック量は、当該クラスタに対応する状況後、一定時間以内に発生しうるトラヒック量の最大値であり、このトラヒックを収容するような制御を行うことにより、資源不足が発生することを防ぐことができる。

我々が検討している手法では、上述の手順で得られた各クラスタのラベルを選択肢とする。また、対応する制御については、当該ラベルに対応するトラヒック量を収容できるような経路や資源割当を、最適化問題や発見的な手法により事前に求めておき、その結果を各選択肢に対応する制御として保存し、制御に用いる。

3.2.3. 観測情報の抽象化

我々が検討している脳の情報処理機構にもとづく実世界協調予測型ネットワーク資源制御では、得られた観測情報を抽象化した観測ベクトル x_t を生成し、認知機構の入力として用いる。観測ベクトル x_t の生成方法は、得られた観測値をそのまま用いるといった方法や、機械学習を用いる方法など、任意の方法を用いることができるが、我々は k 近傍法にもとづく抽象化を行うことを検討している。

k 近傍法にもとづく抽象化では、認知の選択肢数を S とすると、次元数 S のベクトル $x_t = (x_{t,1}, x_{t,2}, \dots, x_{t,S})$ を以下の手順により生成する。まず、新たに得られた観測データと、これまでに経験・蓄積した対応するラベルを計算済みの観測データを比較し、新たに得られた観測データから最も近い過去の観測データを k 個選択する。そして、 $x_{t,i}$ を選択されたデータのうち、 i 番目のラベルに対応するデータの割合として定める。

これにより、各観測データが得られる度に、当該観測データが、どの選択肢に近いのかを示すベクトル x_t を得ることができる。

3.2.4. 生成モデル

我々は、文献[3]と同じ式(1)、式(2)で定める生成モデルを用いることを検討している。また、上述の抽象化により、 i 番目のアトラクターに対応する抽象化された特徴ベクトル x_t は、 i 番目の要素のみ 1、他の要素は

0としたものとなるので、 M は単位行列として設定する。

3.3. 情報の欠損への対応

現実世界でセンシングされた情報を持ちいる場合、現実世界に配置された多種多様なセンサーのすべてから、短い周期で情報を収集することは困難であり、各時刻においては、観測しうる情報のうち、一部の情報しか得られない。そのため、各時刻において、タイムリーな制御を行うためには、各時刻において、一部の情報しか得られないような場合においても、状況の認知を行うことが必要となる。

各時刻において、得られる情報が欠損しているという問題は、我々が検討している脳の情報処理機構にもとづく予測型ネットワーク制御においては、観測情報の抽象化により、対応することができる。具体的には、 k 近傍法による抽象化を行う際、各時刻において得られた情報のみを用いて、 k 個の類似データを取得する。これにより、得られる情報が欠損している場合であっても、いずれの選択肢の状況と類似しているのかを判断することができる。ただし、 k 近傍法による抽象化のみでは、情報が欠損していることにより、いずれの選択肢の状況と類似しているかの判断を誤る可能性がある。しかしながら、我々が検討をすすめている脳の情報処理機構にもとづく認知は、新たに観測された情報は、これまでの認知の状態を更新する情報として用いられるのみであるため、抽象化された情報が一時的に誤っていたとしても、その影響を大きく受けることはない。そのため、情報が欠損したとしても、その影響を大きく受けることなく、正しく状況を認知することが期待できる。

また、この方法は、新たに得られた観測値の欠損のみならず、蓄積された情報に含まれる観測値の欠損にも対応することができる。これは、蓄積された情報についても、現在得られた情報に含まれる情報がすべて揃っている情報のみを k 近傍法での探索の候補とすることにより行うことができる。

3.4. 資源割当制御の階層化

これまで、資源割当制御について、現実世界の情報をもとに、単一のコントローラによって状況を判断し、制御を行う場合について述べてきた。我々は、この判断を階層的に行うことについても、検討を進めている。

複数の仮想ネットワークを単一の物理ネットワークに構成している場合、ネットワーク全体の資源割当制御としては、各仮想ネットワークスライスに資源の割当を行い、各仮想ネットワークスライス内においては、割り当てられた資源を持ちいて、経路やネットワーク機能の配置といった制御を行うことが必要となる。

この場合、資源割当を行うコントローラと、各ネットワークスライス内の制御を行うコントローラを分けることも考えられる。

この場合、各スライス内において、当該スライスに関するトラフィック量や、当該スライスに対応するサービスから得られる現実世界の情報を用いて、トラフィック量を認知し、制御を行うことが考えられる。ただし、各スライス内で行う制御は、トラフィック量のみから定まるものではなく、認知された将来のトラフィック量と自身に割り当てられた資源量の組み合わせの上で、いずれの制御を行うのかを決定する。

資源配分の決定を行うコントローラでは、各スライスのコントローラで認知される情報を収集し、その情報を抽象化した上で、認知し、資源割り当てを決定する。これにより、資源配分の決定を行うコントローラでは、各スライスが認知に用いる現実世界の情報やトラフィック量といった情報を直接収集することなく、現在の状況を認知し、資源配分の決定を行うことができると考えられる。

4. 今後の展望

現在、我々は上述の脳の情報処理機構にもとづく実世界予測型資源割当制御について評価を進めている。評価においては、まず、実世界情報を用いることによる状況判断の精度の向上と、精度向上によるネットワーク制御の性能改善の確認を目指している。文献[10]において、実世界情報として人流の情報を用いることにより、40分先のトラフィック量の予測精度を向上させることができる可能性を示したが、今後、さらに評価をすすめ、実世界情報を用いることが効果的となる時間粒度、空間粒度などの環境を明らかにする予定である。

さらに、情報が欠損した場合についても評価を進め、脳の情報処理機構にもとづく制御が、どの程度の情報欠損であれば正しく認知、制御ができるのかについても明らかしたいと考えている。

また、資源割当制御の階層化についても評価を進めており、階層化した場合においても、正しく状況を認知した資源配分が可能であることを示す予定である。

謝辞

本研究成果の一部は、国立研究開発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」により得られたものである。

文献

[1] H. Zhang, N. Liu, X. Chu, K. Long, A. H. Aghvami,

- and V. C. M. Leung, "Network Slicing Based 5G and Future Mobile Networks: Mobility, Resource Management, and Challenges," *IEEE Communications Magazine*, vol. 55, no. 8, pp. 138–145, Aug. 2017.
- [2] C. Liang and F. R. Yu, "Wireless virtualization for next generation mobile cellular networks," *IEEE wireless communications*, vol. 22, no. 1, pp. 61–69, 2015.
- [3] L. Lu and C. Lianglun, "Network traffic prediction model based on optimizing SVM with improved cuckoo search algorithm," *Computer Applications and Software*, vol. 1, p. 033, 2015.
- [4] G. Rutka, "Neural network models for Internet traffic prediction," *Elektronika ir Elektrotechnika*, vol. 68, no. 4, pp. 55–58, 2015.
- [5] G. Rutka and G. Lauks, "Study on internet traffic prediction models," *Elektronika ir Elektrotechnika*, vol. 78, no. 6, pp. 47–50, 2015.
- [6] C. Daly, "Novel h. 265 video traffic prediction models using artificial neural networks," 2015.
- [7] W. Lu, "Parameters of Network Traffic Prediction Model Jointly Optimized by Genetic Algorithm," *JNW*, vol. 9, no. 3, pp. 695–702, 2014.
- [8] B. Zhou, D. He, Z. Sun, and W. H. Ng, "Network traffic modeling and prediction with ARIMA/GARCH," in *Proc. of HET-NETs Conference*, pp. 1–10, 2005.
- [9] S. Bitzer, J. Bruineberg, and S. J. Kiebel, "A Bayesian Attractor Model for Perceptual Decision Making," *PLOS Computational Biology*, vol. 11, no. 8, Aug. 2015.
- [10] 佐竹幸大, 大下裕一, 村田正幸, "人の脳情報処理プロセスに着想を得た動的な予測形トラフィックエンジニアリング手法," *電子情報通信学会技術研究報告 (IN2017-93)*, pp. 21-26, Mar. 2018.