

脳の情報処理基盤にもとづく交通状況認知と ネットワーク制御の連携方法に関する一検討

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: { y-ohsita, murata }@ist.osaka-u.ac.jp

あらまし これまで我々は、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手法として、脳の情報処理基盤にもとづいて状況を認知し、ネットワークを制御する手法の検討を行ってきた。一方で、我々は、脳の情報処理基盤にもとづく制御を、車両に対するサービス自体に用いることについても検討を行っている。本稿では、これまでの我々が独立に検討してきたネットワーク制御のための状況の認知と、交通情報を用いた交通状態の認知の連携の方法について、検討を行う。具体的には、お互いの認知状態を交換し、連携先の認知状態を取り入れることにより、自身の状態認知に生かす。これにより、自身のみでは認知に時間がかかるような状況においても、連携先において、状態の確信ができるのであれば、自身も素早く認知を行うことが可能となる。本稿では、シミュレーションにより、提案する連携することにより、単独で状況の認知を行っていた場合と比べ、早く状況の変化を認識できることを示す。

キーワード ネットワーク状況、コントローラ間連携、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

Yuichi OHSITA[†] and Masayuki MURATA[†]

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

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

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

Abstract We have proposed a method to allocate network resources using real-world information inspired by human brain cognition process. On the other hand, we have also applied the method inspired by human brain cognition process to handle the transportation traffic. In this paper, we discuss a method to cooperate them. In this method, the controllers send their cognitive status to each other, and update their status by using the cognitive status sent from the others. By this cooperation, the controller identifies the current status faster if another controller identifies the status fast. In this paper, we demonstrate the effectiveness of the proposed method by simulation.

Keywords Network status, Cooperation between controllers, 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。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、各車両からの情報収集や車両への情報提供を行うようなサービスを対象とすると、車両が密集するエリアでは輻輳発生リスクが増加する。すなわち、交通情報の把握と連携することにより、ネットワーク資源不足の予兆をとらえた制御を行うことが可能であると考えられる。

これまで我々は、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




図 1 人の認知のモデル

ネットワークを制御する手法の検討を行ってきた[3, 4]。

本検討では、現実世界の観測情報といった、各時刻で得られる情報としては不正確な情報をもとに逐次判断を行う必要がある。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。そこで、我々は、脳が不正確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である Bayesian Attractor Model(BAM) [5]にもとづいて、現実世界の観測情報を含め、ネットワーク制御に必要な状況を認知する手法を提案している。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。

我々のネットワーク制御において、事前に認知対象の選択肢、各選択肢に対応するネットワーク制御を事前に定めることにより、各時刻で得られた観測情報にもとづいた認知と、その認知結果に対応する制御を実現している。これまでに、我々は、特に車両向けのネットワークサービスに対応するネットワークスライスに焦点を当て、各交差点間の車両数といった情報や、それをもとにした渋滞の予測結果を取り入れることにより、ネットワークの資源不足のリスクを把握し、適切な資源割り当てができることを示してきた。

一方で、我々は、BAM にもとづく制御を、車両に対するサービス自体に用いることについても検討を行っている[6]。本検討では、各時刻に観測される交差点間の車両台数をもとに、BAM によって状況を判断することで、早期に渋滞の発生を予測し、渋滞発生リスクの

高い箇所を迂回させるような経路を提案する。

本稿では、これまでの我々が独立に検討してきたネットワーク制御のための状況の認知と、交通情報を用いた交通状態の認知の連携の方法について、検討を行う。具体的には、お互いの認知状態を交換し、連携先の認知状態を取り入れることにより、自身の状態認知に生かす。これにより、自身のみでは認知に時間がかかるような状況においても、連携先において、状態の確信ができるのであれば、自身も素早く認知を行うことが可能となる。

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、 $z_t =$

ϕ_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ネットワーク制御・交通状況認知間の連携

3.1. 脳の情報処理機構にもとづくネットワーク制御

我々が検討している脳の情報処理機構にもとづくネットワーク制御では、ネットワーク制御を行うネットワークコントローラを導入する。そして、ネットワークコントローラ内で、脳の情報処理機構にもとづいて、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。

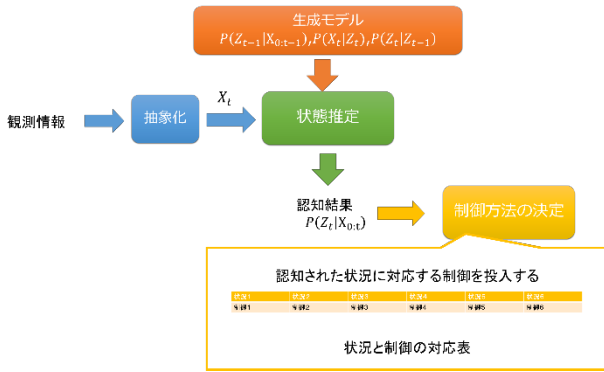


図 2 脳情報処理機構にもとづくネットワーク制御の概要

3.1.1. 観測情報の抽象化

本稿では、ネットワークコントローラはネットワーク内の各地点間を流れるトラフィック量といったネットワーク内で観測可能な情報を定期的に取得することを考える。時刻 t に取得された観測情報は、ベクトル o^{net}_t として表すことができる。脳の情報処理機構にもとづく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^{net}_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^{net}_t の生成方法は、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、本稿では、得られた情報を直接用いる。すなわち、 $x^{net}_t = o^{net}_t$ とした。

3.1.2. 状態の更新

本稿では、文献[3]と同じ式(1)、式(2)で定める生成モデルを用いて、状態の更新をする。すなわち、ベイズ推定を用いて、式(1)、(2)の生成モデルを逆推定することで、観測値 x^{net}_t から意思決定状態 z^{net}_t を更新する。

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、本稿では、粒子フィルタを用いた近似計算により求める。

3.1.3. 意思決定

上記の状態更新により、確信度 $P(z^{net}_t | x^{net}_{0:t})$ が得られる。ネットワークコントローラでは、各選択肢に対応するネットワーク制御手順や割り当て資源量をあらかじめ定めている。そのため、確信度が高い選択肢に対応する制御を行うことで、認知された状態に対応する制御を行う。

3.2. 脳の情報処理機構にもとづく交通状況認知

我々は、交通状況の認知に対しても、脳の情報処理機構にもとづく手法の適用を検討しており、これまで、混雑箇所の回避を行うような車両への経路提案への適用可能性について議論してきた。本稿では、交通状況の認知は、交通状況認知器において行われるものとする。

交通状況認知器で行われる、脳の情報処理機構にもとづく交通状況認知も、ネットワーク制御の場合と同様である。すなわち、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を更新、更新した認知状態をもとに対応する必要な処理（車両へのう回路の提案など）を行う。

3.2.1. 観測情報の抽象化

本稿では、交通状況認知器は各時刻において、各交差点間に滞在する車両数といった、交通状況に関する情報を定期的に取得する。時刻 t 取得された観測情報は、ベクトル $o^{traffic}_t$ として表すことができ、これを抽象化した $x^{traffic}_t$ を得る。ネットワーク制御と同様、様々な抽象化が考えられるが、本稿では、得られた情報を直接用いる。すなわち、 $x^{traffic}_t = o^{traffic}_t$ とした。

3.2.2. 状態の更新

ネットワーク制御と同様、ベイズ推定を用いて、式(1)、(2)の生成モデルを逆推定することで、観測値 $x^{traffic}_t$ から意思決定状態 $z^{traffic}_t$ を更新する。

3.2.3. 意思決定

上記の状態更新により、確信度 $P(z^{traffic}_t | x^{traffic}_{t:0})$ が得られる。交通状況認知器では、確信度の高い状態であると認知し、必要な交通に対する制御（車両へのう回路の提案など）を行う。

3.3. ネットワーク制御・交通状況認知間の連携

本稿では、上述のネットワークコントローラと交通状況認知器の間で、お互いの認知状態を交換することによる連携を考える。本節では、特にネットワークコ

ントローラ側において、交通状況認知器の認知状態を受け取り、自身の認知に反映させる手順について述べる。

まず、お互いの認知状態を交換し、自身の認知に反映させるためには、相手の認知状態が自身のどの認知状態に該当するのかの対応付けが必要となる。本稿では、事前に、この対応付けが定義されているものとする。以降、本対応付けを関数 $g()$ であらわす。

本連携のための手順を加えた、ネットワークコントローラの動作は以下に示す通りとなる。

1. ネットワーク内の観測情報の取得・抽象化
 2. ネットワークコントローラの認知状態の更新
 3. 交通状態認知器と認知状態を交換し、認知状態を更新する
 4. 認知状態をもとに判断をし、制御を行う
- 上記の手順のうち、1、2、4 は 3.1 で述べたネットワークコントローラが単独で状況認知、制御を行う場合と同じである。以降では、手順 3 の交通状態認知器との認知状態の交換と、交換した情報を用いた認知状態の更新について述べる。

各コントローラ・認知器では、自身の認知の結果、認知状態の確率分布を得る。以降、ネットワークコントローラが時刻 t に得た認知状態 Z_t^{net} の確率分布を $P(Z_t^{net})$ 、同様に交通状態認知器が得た認知状態 $Z_t^{traffic}$ の確率分布を $P(Z_t^{traffic})$ とする。本連携では、この確率分布自体を交換するものとする。すなわち、ネットワークコントローラからは $P(Z_t^{net})$ を交通状態認知器に送り、交通状態認知器からは、 $P(Z_t^{traffic})$ をネットワークコントローラに送る。

ネットワークコントローラでは、自身が認知した状態 $P(Z_t^{net})$ と、交通状態認知器から送られてきた $P(Z_t^{traffic})$ をもとに、最終的な時刻 t での状態認知結果 $P'(Z_t^{net})$ を定める。この際、自身の認知状態と連携先から送られてきた認知状態のうち、確信度が高い認知結果を重視することにより、早く状態の変化を認知できた認知器に追随することができる。本稿では、以下のように状態の更新を行った。

$$P'(Z_t^{net}) = (1 - \alpha)P'(Z_t^{net}) + \alpha P'(g(Z_t^{traffic}))$$

ただし、

$$\alpha = \frac{(1 - \beta) \max_i P(g(z_t^{traffic}) = \phi_i)}{\max_i P(z_t^{net} = \phi_i) + \max_i P(g(z_t^{traffic}) = \phi_i)}$$

ただし、 β は、自身の確信度に対する重みである。これより、より確信度の高い認知器を重視した認知状態の更新が可能となる。

また、上記のようにして得られた認知結果 $P'(Z_t^{net})$ を

保持し、ネットワークコントローラが新たな観測情報が取得された際には、 $P'(Z_t^{net})$ から状態の更新を行う。

本節では、ネットワークコントローラ側の制御について述べたが、交通状態認知器側でも同様の手順で、ネットワークコントローラ側から受け取った認知状態を自身の認知状態に反映することが可能となる。また、本節では、二つの認知器が認知状態を更新する度に、認知状態を交換し、自身の認知状態の更新に利用するものとして手順の説明を行ったが、必ずしも、毎回認知状態を交換する必要はない。その際、上記の手順 3 については、認知状態の交換が必要なタイミングで交換し、連携先から認知状態の通知が行われたタイミングで、自身の認知状態に反映させるのみでよく、各認知器を非同期で動作させることも可能である。

4. 動作検証

4.1. 評価環境

本評価では、車両が生成する通信を収容するネットワークスライスに焦点をあて、渋滞の発生、それによる特定エリアの通信量の増加といった状況をいかに早く認知できるかに焦点をあてて、ネットワークコントローラと交通状態認知器の連携について検証する。

本評価では、交通流は、図 3 に示す各交差点間の距離が 200m の 5×3 の格子状道路網を用いて、SUMO[7]を用いたシミュレーションにより生成した。交通流は、1 秒に 1 台、ランダムな始点・終点を指定した車両を追加することにより生成した。また、本評価においては、道路網の状況が急激に変化する状況として、事故等の発生により、車両の流れが悪くなった交差点を生成した。車両の流れが悪くなった交差点では、各方向の車両が通過できる時間帯を正常時の半分と設定することにより、交通状況の変化を生成した。本節では、交通状態の悪化により、徐々に車両が混雑する環境に焦点を当てて、評価を行う。

また、通信トラヒックは、各車両 1 台が生成するトラヒック量を平均 1Mbps、標準偏差 0.2 の正規乱数として生成した。本評価においては、図 3 の道路を 2×2 の 4 つのエリアに分割し、ネットワークコントローラ側では、各エリアについての流出入トラヒック量の合計が観測できるものとする。

また、本評価においては、ネットワークコントローラ、交通状態認知器のいずれにおいても、認知の候補は、混雑をしていない状況から、混雑状況を 4 段階に分割し、現在が、いずれの状況であるのかを認

知する。また、本評価では、 $\beta = 0.5$ とした。




図 3 格子状道路ネットワーク

4.2. 評価結果

図 4 に、ネットワークコントローラが、交通状況認知器と連携をした際の、ネットワークコントローラにおける状態認知結果を、図 5 にネットワークコントローラが単独で認知を行った結果を示す。本評価では、道路状況の悪化により、渋滞が発生し、徐々に車両が混雑、通信量も増加する。図 4、図 5 より、いずれの認知においても、その状況を把握することができおり、最初は混雑なしであったのが、混雑度小の状態、最後に混雑度大の状態へと認知状態が移行していることが分かる。ただし、連携をしなかった場合には、混雑なしという認知状態から混雑度小への認知が、56 タイムスロット以降となっているのに対し、連携をした場合は、6 タイムスロットで混雑度小であると認知ができている。また、混雑度大の認知も、連携をしなかった場合には、111 タイムスロット以降になって、混雑度大と認知されるようになるが、連携をした場合には、97 タイムスロットで混雑度大であると認知ができるようになっている。すなわち、交通状況認知器との連携により、早く混雑状態の認知を行うことができるようになった。これは、交通状況認知器では、各交差点間の車両台数というより細粒度な情報を得ることができ、その変化も通信量の変化と比べて、緩やかであり、交通状況認知器の方が、ネットワークコントローラよりも状態認知を行いやすいためである。その結果、交通状況認知器では、早めに状況の変化を認知することができ、連携を行うことにより、ネットワークコントローラ側でも、その状態変化に対応して、自身の認知状態を変えることができる。

このように、認知状態を介することにより、ネットワークコントローラ、交通状況認知器間で、それ以外の情報を介することなく、素早く状況の認知を行うことができることを示した。また、本評価のシナリオで

は、交通状況認知器の方が早く状況を認知できる場面での評価であったが、いずれの認知器が早く状況の変化を認知できるかは、観測情報の性質や状況に依存する。本連携では、一方的に片方の認知器の認知結果をもう一方の認知器で利用するものではなく、お互いの認知結果をもとに連携を行うものであるため、ネットワークコントローラ側で早く状況の変化を認知できる場合も、交通状況認知器側での状態変化の認知を早く行うことが可能となる。




図 4 確信度の変化（連携あり）




図 5 確信度の変化（ネットワーク）

5. まとめ

これまで我々は、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手法として、脳の情報処理基盤にもとづいて状況を認知し、ネットワークを制御する手法の検討を行ってきた。一方で、我々は、脳の情報処理基盤にもとづく制御を、車両に対するサービス自体に用いることについても検討を行っている。本稿では、これまでの我々が独立に検討してきたネットワーク制御のための状況の認知と、交通情報を用いた交通状態の認知の連携の方法について、検討を行った。具体的には、お互いの認知状態を交換し、連携先の認知

状態を取り入れることにより、自身の状態認知に生かす。これにより、自身のみでは認知に時間がかかるような状況においても、連携先において、状態の確信ができるのであれば、自身も素早く認知を行うことが可能となる。本稿では、シミュレーションにより、提案する連携することにより、単独で状況の認知を行っていた場合と比べ、早く状況の変化を認識できることを示した。ただし、本稿の評価シナリオでは、交通状況認知器の方が素早く状況の変化を認知できるシナリオのみでの検証であった。今後、コントローラ間の連携により、双方のコントローラの認知にとって有用であるような場面での検証を行う予定である。

謝辞

本研究成果の一部は、科研費 18H04096 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] S. An, Y. Ohsita, and M. Murata, "Evaluation of Network Resource Allocation Based on Monitored Traffic Condition inspired by Human Brain Cognition Process," in *Proceedings of International Conference on Emerging Technologies for Communications*, Dec. 2020.
- [4] K. Satake, Y. Ohsita, and M. Murata, "Predictive traffic engineering incorporating real-world information inspired by the cognitive process of the human brain," in *Proceedings of International Conference on ICT Convergence*, Oct. 2019.
- [5] 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.
- [6] Y. Ohsita, and M. Murata, "Route suggestion for vehicles inspired by the cognitive process of a human brain and its relation to predictive control of communication networks," in *Proceedings of International Conference on Emerging Technologies for Communications*, Dec. 2020.
- [7] D. Krajzewicz, "Traffic simulation with SUMO—simulation of urban mobility," *Fundamentals of traffic simulation*, Springer, 2010.