

# 人の脳情報処理プロセスに着想を得た実世界情報協調予測型トラフィック エンジニアリング手法

佐竹 幸大<sup>†</sup> 大下 裕一<sup>†</sup> 村田 正幸<sup>†</sup>

<sup>†</sup> 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,y-ohsita,murata}@ist.osaka-u.ac.jp

あらまし インターネットを流れるトラフィックは、量・時間変動ともに増大しており、時間変動の大きなトラフィックを効率的に収容する技術が求められている。変動するトラフィックを収容する手法として、将来のトラフィック量を予測し、予測に合わせてあらかじめ必要な資源を配分する予測型のトラフィックエンジニアリングが研究を進められている。予測型のトラフィックエンジニアリングにより適切な資源配分を行うためには、資源の再割り当てが必要なトラフィックの変化を正確に予測することが必要である。従来、このようなトラフィック量の予測は過去のトラフィックの時系列データをもとに行われてきた。しかしながら、トラフィック量は、人の行動など現実世界を反映したものであり、過去のトラフィック量の時系列データからのみでは、トラフィック変動を正確に予測することは困難である。本稿では、トラフィック量のみではなく現実世界でセンシングされた情報も用いることにより、将来のトラフィック量をより正確に予測し、資源割当制御を行う予測型ネットワーク制御手法について検討を行う。本予測型ネットワーク制御手法では、トラフィック量、現実世界の情報といった将来のトラフィック量との関係が曖昧な情報を得ながら、随時、資源割当の判断をする必要がある。本稿では、外界からの曖昧な情報を基に、随時、意思決定を行っている脳の情報処理過程をモデル化したベイジアンアトラクターモデル (BAM) を予測型ネットワーク制御における判断に適用する。本稿では、シミュレーションにより提案手法の評価を行う。その結果、提案手法により、将来のネットワークの状態を正確に判断でき、少ない資源割当で輻輳を回避することができることを示す。

キーワード トラフィックエンジニアリング、ネットワーク資源割当、実世界観測情報、脳情報処理機構

## Predictive traffic engineering incorporating real-world information inspired by human brain cognition process

Kodai SATAKE<sup>†</sup>, Yuichi OHSITA<sup>†</sup>, and Masayuki MURATA<sup>†</sup>

<sup>†</sup> Graduate School of Information Science and Technology, Osaka University 1-5 Yamadaoka, Suita, Osaka,  
565-0871, Japan

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

**Abstract** The amount of traffic through networks is increasing both in quantity and in fluctuation. One approach to accommodating such fluctuating traffic is to dynamically control resources in a network based on the predicted traffic. In this approach, the accuracy of the prediction is important. There are many methods to predict future traffic. Most of them predict the future traffic from the traffic rates of the previous time slots. However, it is difficult for these methods to predict future traffic accurately, because the traffic is affected by the human behavior, and the sign of the traffic change may not be included in the past traffic data. In this paper, we discuss the predictive traffic engineering methods using both of the monitored traffic data and real-world information. In this method, we need to decide the amount of resources based on the monitored traffic and real-world information, whose relation to the future traffic is unclear. In this paper, we apply a mechanism of human brain, which makes decisions from uncertain and incomplete information, to making decisions in the predicted traffic engineering. Through simulations, we demonstrate that our method avoid congestions without allocating a large amount of resources.

**Key words** Traffic Engineering, Resource Allocation, Real-World Information, Human Brain Cognition

## 1. ま え が き

インターネットに接続する機器の多様化や、インターネットを介したサービスの多様化が進むにつれ、インターネット上を流れるトラフィックは、量・時間変動ともに大きくなっている。ネットワーク事業者は、このような大きなトラフィック変動が生じる環境においても、輻輳が発生しないようにトラフィックを収容する必要がある。このような要求を満たす手法として、トラフィック変動に応じて動的に経路や資源割当等を変更する Traffic Engineering (TE) と呼ばれる技術が注目され、広く研究されてきた [1-4]。これらの手法では、ネットワーク内のトラフィック量を観測し、観測したトラフィック量を元にトラフィック量を予測し、予測したトラフィック量を収容できるようにネットワーク内の資源割当を動的に変更する。

従来の TE では、動的なネットワーク制御の際のトラフィック予測は、過去に観測されたトラフィックの時系列データをもとに定めた変動モデルを用いて行われてきた [5-10]。しかしながら、トラフィック量は、人の行動など現実世界を反映したものであり、過去のトラフィック量の時系列データからのみでは、トラフィック変動を正確に予測することは困難である。その結果、トラフィックの増大を予測できず、輻輳を防ぐことができない。

本稿では、トラフィック量のみではなく現実世界でセンシングされた情報も用いることにより、将来のトラフィック量をより正確に予測し、資源割当制御を行う予測型ネットワーク制御手法について検討を行う。本予測型ネットワーク制御手法では、トラフィック量、現実世界の情報といった将来のトラフィック量との関係が曖昧な情報を得ながら、随時、資源割当の判断をする必要がある。

本稿では、曖昧な情報を得ながら随時判断を行う手法を確立するにあたり、脳情報処理機構に着目した。脳の認知モデルの一つである Bayesian Attractor Model (BAM) [11] 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ことを繰り返すことにより認知を行う。

本稿では、BAM を予測型ネットワーク制御における状況の認知に適用する。本手法では、ネットワークにおいて、認知すべき状況と各状況において、将来必要となる資源量の対応関係をあらかじめ記憶しておく。また、認知対象となるネットワークの各状態を BAM に選択肢として埋め込み、各選択肢と対応する観測される情報との関係についても記憶する。そして、実際に制御する際には、観測情報をもとに意思決定の状態を更新し、各選択肢の確信度を得、確信度が高い選択肢に対応する将来必要となる資源量の割り当てを行う。これを繰り返すことにより、逐次、状況を判断し、必要な資源を割り当てることが可能となる。

## 2. Bayesian Attractor Model (BAM)

Bayesian Attractor Model (BAM) [11] 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。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 (以後アトラクターとよぶ) に対応した状態値  $\phi_1, \dots, \phi_i$  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、 $\mu_i$  は、事前に用意された各アトラクターの状態値  $\phi_i$  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、Unscented Kalman Filter (UKF) [12] を用いた近似計算を行う。

### 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  $\phi_i$  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  $\lambda$  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。 $P(z_t|x_t)$  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  $\Sigma_t$  を用いて、 $P(z_t|x_t)$  が多変量正規分布  $N(E[z_t], \Sigma_t)$  であると仮定して計算する。

## 3. 実世界情報協調予測型資源割当手法

### 3.1 概要

モバイルネットワークでは、モバイル端末を持つ多数のユーザからの通信を収容しており、各エリアから流入するトラフィックは、各ユーザが出すトラフィック量の変化、ユーザの移動の両方の影響を受ける。トラフィック量の変化の結果、処理する資源が不足したエリアでは、十分な品質での通信の収容が不可能となる。その一方、余剰な資源割当が行われたエリアが生じた際には、消費電力の増大や他のエリアに割当て可能な資源が不足する等の問題が発生する。そのため、各エリアの通信量に合わせた資源の割り当てを行うことが必要となる。

本稿では、上記のモバイルネットワークにおいて、各エリア

から流入するトラヒックの処理に割当てる資源を決定する処理を対象として、実世界情報協調予測型トラヒックエンジニアリング手法の検討を行う。上述のように、モバイルネットワークでは、トラヒック量は、各エリアのトラヒック量、各エリアにいるユーザの数に影響を受ける。また、各エリアのユーザ数を予測するには、周辺のエリアのユーザ数は重要な情報であり、周辺エリアのユーザ数が増大した場合、当該エリアのユーザ数も増大することが予想できる。そのため、本稿では、実世界情報協調予測型トラヒックエンジニアリング手法では、各エリアのトラヒック量に加えて、各エリアのユーザ数についての情報も入力として扱う。そして、それらの値を入力とし、将来の各エリアのトラヒック量を予測、予測結果をもとに資源の割り当てを行う。

以降、本節では、上記の実世界情報協調予測型トラヒックエンジニアリング手法で用いる脳情報処理機構にもとづくトラヒック予測手法、予測結果にもとづく資源割当方法について述べる。

### 3.2 脳情報処理機構にもとづくトラヒック予測

実世界情報協調予測型トラヒックエンジニアリング手法では、各エリアから流入するトラヒック量を実世界から取得される情報を用いて予測し、制御に用いる。以降、制御対象のエリアのうち、1つのエリアについて、将来のトラヒック量を予測する手法について述べる。

本稿では、現在までに得られている観測情報により認知可能なネットワークの状態を定義し、各状態について  $p$  タイムスロット先のトラヒック量を、過去の観測結果をもとに対応付けることにより、 $p$  タイムスロット先のトラヒック量の予測を、現在のネットワークの状態を認知する問題として扱う。そして、この認知に脳の認知のモデルの一つである Bayesian Attractor Model (BAM) [11] を適用する。BAM では、典型的な認知の状態をアトラクターとして持ち、各アトラクターに対応する観測値を覚えておく。そして、新たに観測値が得られるたびに、現在の認知の状態を更新することを繰り返す。

本稿では、BAM を上記の認知に用いるため、予測に用いる観測情報、観測情報を用いて認知する対象となるネットワークの状態、当該認知への BAM の適用方法について議論する。

#### 3.2.1 観測情報

本稿では、各エリアから流入するトラヒック量に加えて、各エリアのユーザ数についても観測情報として用いる。モバイルネットワークでは、トラヒック量は、各エリアのトラヒック量、各エリアにいるユーザの数に影響を受ける。また、各エリアのユーザ数を予測するには、周辺のエリアのユーザ数は重要な情報であり、周辺エリアのユーザ数が増大した場合、当該エリアのユーザ数も増大することが予想できる。そのため、予測対象エリアの情報に加えて、予測対象エリア周辺の観測値も用いる。また、ユーザ数、トラヒック量のいずれについても、現在の値のみではなく、ユーザ数、トラヒック量が増加傾向にあるか、減少傾向にあるかという点も、将来のトラヒック量の予測においては、重要な情報である。そのため、本稿では、予測対象地点から、 $m$  エリア分以内の距離にある各エリアにおける以下の

値を予測対象エリアの予測に用いる。

- 現在のトラヒック量
- $p$  タイムスロット前のトラヒック量と現在のトラヒック量との差分
- 現在のユーザ数
- $p$  タイムスロット前のユーザ数と現在のユーザ数との差分

#### 3.2.2 認知対象の状態

観測情報が類似しているネットワークの状態は、 $p$  タイムスロット先の予測対象エリアのトラヒック量も近くなると考えられる。そこで、本稿では、過去に得られた観測情報をもとに、観測情報を類似の観測情報をもつ事象をあつめた  $k$  個のクラス  $C_1, C_2, \dots, C_k$  に分割し、新たな観測値が得られた際には、今の状態が、いずれのクラスに属する状態であるのかを認知するものとした。これにより、現在の状態がクラス  $C_n$  であると認知した場合、過去に得られた観測情報をもとに、クラス  $C_n$  内に属する過去の各状態について  $p$  タイムスロット先のトラヒック量を調べ、その最大値を予測値とすることにより、 $p$  タイムスロット先の輻輳を防ぐために必要な資源量を得ることができる。本稿では、k-means 法を用い、観測情報をもとに  $k$  個の認知対象の状態を定義した。

#### 3.2.3 状態認知への BAM の適用

本稿では、 $K$  種類の状態認知を行うにあたり、BAM にもとづく認知器を  $K$  個準備し、各認知器において、当該認知器が対応する状態であるのか、それ以外の状態であるのかの 2 状態の判断を行う。以降、各認知器において、BAM における観測情報の与え方、BAM におけるアトラクターの定義、について説明する。

##### a) 観測情報の与え方

各認知器において、観測値は、現在の状態が各アトラクターのいずれであるかを判断するために用いられる。本稿では、現在の状態が各アトラクターのいずれであるかの判断が容易にできるように、以下のように加工した情報を BAM に与える。

$$\mathbf{x}_i = \sigma\left(\frac{a}{a+b}, \frac{b}{a+b}\right)$$

$$a = D(\mathbf{X}, \mathbf{M}_i)$$

$$b = \min(D(\mathbf{X}, \mathbf{M}_1), D(\mathbf{X}, \mathbf{M}_{i-1}), \dots, D(\mathbf{X}, \mathbf{M}_{i+1}), D(\mathbf{X}, \mathbf{M}_k)) \quad (3)$$

ただし、 $\mathbf{x}_i$  は、現在の認知の状態がクラス  $C_i (1 \leq i \leq k)$  に含まれるべき状態であるかを判断する認知を行う BAM に与える入力、 $\mathbf{X}$  は得られた観測値、 $D(\mathbf{y}_1, \mathbf{y}_2)$  はベクトル  $\mathbf{y}_1, \mathbf{y}_2$  間のユークリッド距離、 $\sigma$  はシグモイド関数を表している。また、 $\mathbf{y}_i$  は、 $i$  番目のクラス  $C_i$  に属する過去に得られた観測情報の平均値である。すなわち、 $\mathbf{x}_i$  は、クラス  $C_i$  に属する過去に得られた観測情報の平均に近ければ、0, 1、それ以外のクラスの観測情報の平均に近ければ 1, 0 となる。

##### b) アトラクターの定義

各認知器では、対象となる状態であるか否かを判断する。すなわち、現在の認知の状態がクラス  $C_i (1 \leq i \leq k)$  に含まれ

るべき状態であるかを判断する認知器では、現在の状態がクラスタ  $C_i (1 \leq i \leq k)$  に含まれるべき状態である  $z_{yes}$ 、それ以外の状態  $z_{no}$  の二つをアトラクターを持つ。そして、 $z_{yes}$  の場合、 $z_{no}$  の場合の観測値を以下のように定義する。

$$\begin{aligned} \mu_{yes} &= (0, 1) \\ \mu_{no} &= (1, 0) \end{aligned} \quad (4)$$

### 3.3 予測に基づいた資源割当

上述の手順により、 $k$  個のあらかじめ定義された各ネットワークの状態について、事後確率  $P(z_{yes}|x)$  (以降、確信度とよぶ) と、その状態における  $p$  タイムスロット先の必要資源量が求まる。本稿では、この確信度と  $p$  タイムスロット先の必要資源量をもとに資源割当を行う。BAM による認知の結果、ある特定の状態である確率が非常に高い場合は、一つの認知器のみ  $P(z_{yes}|x)$  が高い値となる。しかしながら、状況によっては、いずれの状態かの判断が難しく、複数の認知器の  $P(z_{yes}|x)$  が高い値となることもある。このような場合、輻輳を回避するためには、可能性のある状態のうち、もっとも予測値が高い状態に合わせて資源割当を行うことが有効であると考えられる。そこで、本稿では、 $P(z_{yes}|x)$  が閾値  $\lambda$  を超える全状態をしらべ、もっとも  $p$  タイムスロット先の必要資源量に合わせて、当該エリアの  $p$  タイムスロット先の資源割当を設定する。

## 4. 評価

本評価では、交通流情報を含む観測情報を用いることによる効果及び、脳情報処理プロセスに着想を得た制御方法を用いることの効果の評価をする。

### 4.1 評価手法

#### 4.1.1 評価環境

本評価のためには、人の移動と、それに伴う、各エリアから流入するトラフィック量のデータを用いる必要がある。しかしながら、人の移動とトラフィック量の両方を含む実測データは公開されていない。そこで本研究では、Open PFLOW [13] (東京大学 CSIS-JoRAS) と呼ばれる、擬似的に生成された GPS 軌跡データセットを用いて人の移動パターンを再現しつつ、人々が発生させるトラフィックについては、Synthetic Traffic Generator [14] で擬似生成されたものを用いる。

Open PFLOW では、首都圏における典型的な約 1 日分の人の移動パターンが再現されており、データセットは各人の時刻と GPS 座標の組が 5 秒間隔で記録されている。ただし、当該データセットに含まれる人数は、617040 人分であり、首都圏の全ユーザに相当する人流データは含まれていない。そこで、本研究では、Open PFLOW に含まれる各人流について、同一行動をとるユーザが複数人存在するものとして、各人流を定数倍した人数が同一の行動をしているものとして、人流データを構築した。さらに、各人流データにおける倍率をランダムに変更することにより、Open PFLOW の傾向に従いつつも、状況の異なる人流データを 2 種類生成して、一つを提案手法の認知対象の状況の定義・各状況に対応する予測トラフィック量の定義といった学習用のデータの生成に用い、残りの人流データを評価

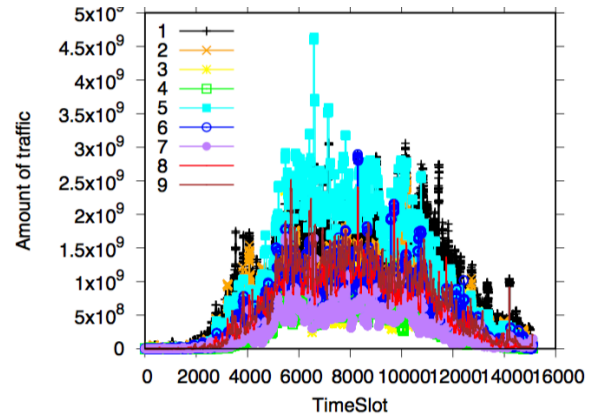


図 1: 予測対象地点及びその周辺のトラフィック量の時系列変化

用データの生成に用いた。

Synthetic Traffic Generator は  $x : 00 : 00$  から  $(x+1) : 00 : 00$  ( $0 \leq x \leq 23$ ) のトラフィック量、リクエスト数、リクエスト間のインターバル時間を、実計測データに基づいて再現したものである。ただし、本シミュレーターでは、各時台のリクエストは、 $x : 00 : 00$  直後に集中して生成されているが、現実的には、各ユーザのリクエストは、より様々な時間帯に発生する。そこで、本評価では、各ユーザのリクエストが発生する時刻を  $x : 00 : 00$  から  $(x+1) : 00 : 00$  の中で一様に分布するように、ずらす処理を行った。また、Synthetic Traffic Generator ではリクエストのみ発生させており、各リクエストによって生成されるトラフィック量について、より短い時間粒度でのトラフィック量のデータは含まれていない。本評価では、リクエストの開始から終了まで、一定レートでトラフィック量が送られているものとして、各ユーザのトラフィックを生成した。

本評価では、予測対象として、東京都千代田区周辺を緯度経度ともに 0.0036 (約 350m) 四方のエリアに区分した際の一つのエリアを選択し、当該エリアの必要資源量を制御した場合について評価を行った。該当エリア及びその周辺エリアにおけるトラフィック量の時系列変化を図 1 に、人数の時系列変化を図 2 に示す。それぞれ系列 1 が予測対象地点であり、その他は周辺 8 方位のエリアにおける時系列変化である。単位は bps である。

本評価においては、簡単のため、当該エリアから流入するトラフィックの処理に割当てられる資源は、16 Mbps 単位とした。また、必要資源を計算後、資源割当の処理に 40 分を要するとし、各時刻においては、40 分後のトラフィック量を予測した上で制御することとした。以降、すべての図において、1 タイムスロットは 5 秒間であり、3:00 24:00 までの時系列変化を示している。

#### 4.1.2 比較手法

本評価では、観測値として交通流情報を含む多種の情報を用いることによる効果及び、状態判断として脳情報処理プロセスに着想を得た方法を用いることの効果の評価をする。上述の効果の評価するため、本評価では、提案手法 (以降、BAM-based method with real-world information と表記する) を以下の手法の比較を行う。




図 2: 予測対象地点及びその周辺の人数の時系列変化

a) BAM-based method without real-world information

本手法では、観測情報として交通流情報を用いず、トラヒック量のみを用い、BAM モデルを用いて将来の予測対象エリアにおけるトラヒック量を予測、資源割当を行う。すなわち、本手法では、制御を行う際に、以下の情報を用いて予測を行う。

- 現在のトラヒック量
- $p$  タイムスロット前のトラヒック量と現在のトラヒック量との差分

本手法は、予測に用いる情報以外は、提案手法と同じであり、本手法との比較により、予測に交通流情報を用いる効果を確認する。

b) Prediction Based on Clustering Result (PBCR) With real-world information

本手法では、提案手法と同じ情報（トラヒック量、人流のデータの両方）を用いて将来の予測を行い、制御を行う。ただし、予測を行う際に、BAM による認知は行わず、各時刻で得られた観測値をもとに、認知対象の状況を定義する際に構築したクラスタのうち、最も近いクラスタと同じ状況であると判断し、予測を行う。本手法と比較することにより、BAM による認知を行うことの効果を確認することができる。

c) Prediction Based on Clustering Result (PBCR) Without real-world information

本手法では、観測値として交通流情報を用いず、かつ状態判断に BAM を用いない。この制御では、用いる観測情報としては上述の交通流情報を用いなかった場合と同様であり、状況判断の方法については、上述の BAM を用いなかった場合と同様である。

4.1.3 パラメータ設定

本評価では、予測に用いる情報に関するパラメータを  $m = 2$ 、 $p = 480$  と定めた。すなわち、予測対象地点より 2 エリア分以内 (約 700m) の距離にある各エリアの観測情報を用い、トラヒック量、エリア内人数の上昇率の計算は、40 分前の観測値との差分を用いて行った。

また、BAM のモデルで用いているパラメータは、sensory uncertainty を 0.42、dynamic uncertainty を 0.3、観測方程式及びホップフィールドダイナミクスにおけるシグモイド関数の

傾きを 2.0 としており、その他については文献に従う。

4.1.4 評価指標

本稿では、予測対象としているエリアに対する資源割当を各手法で行い、当該エリアの状況に注目して評価を行う。資源割当の際には、資源が不足して輻輳を発生させることを避ける必要がある。輻輳の発生を防ぐためには、予測により得られた将来必要となる資源量よりも多めの資源量を割り当てることにより、予測された以上のトラヒックが流入した場合であっても、輻輳を回避することができる。しかしながら、この方法で、 $\alpha$  を大きな値に設定すると、当該エリアに多量に資源を割り当てることとなり、他のエリアに割当てた資源を十分に確保できない、あるいは、より多くの機器を動作させることによる電力等のコストが問題となる。そのため、本評価では、対象エリアに対してシミュレーション開始から終了までの全時間帯において確保された資源量の合計、輻輳が発生した時間の長さの両面から手法の評価を行う。その際、上述の  $\alpha$  を変えながら各手法を動作させ、輻輳を発生させる時間を一定値以下に抑えるように  $\alpha$  を設定した際に、必要となる資源の合計を比較する。この値が小さいほど、少ない資源で輻輳を回避することができる手法であるといえる。

4.2 評価結果

図 3 に、シミュレーションによる評価結果を示す。図の横軸は資源不足による輻輳が発生したタイムスロット数を示し、縦軸は輻輳が発生したタイムスロットを横軸の値に抑えるように  $\alpha$  を設定した際に、当該エリアにシミュレーション開始から終了までの間に割当てた総資源を示す。また総資源量は、割当てた資源によりシミュレーション開始から終了までの間に中継可能な総トラヒック量 (Kbyte) を示している。

まず、BAM-based method with real-world information と BAM-based method without real-world information を比較すると、BAM-based method with real-world information の方が、輻輳が発生したタイムスロット数を基準値以下にするために必要な割当資源量が少ない。これは、人流に関する情報も用いることで、トラヒック量に関する情報のみでは区別できなかった状態の違いを捉えることができ、より正確な予測ができるようになってきているためである。図 1 と図 2 の系列 1 を比較するとわかるように、予測対象地点におけるトラヒック量の変動は、予測対象地点における人数の影響を受けており、ある時刻における人数は、当該時刻のトラヒック量の予測において有用な情報である、しかも、人数の変動はトラヒック量の変動と比較すると、時間変動に加わるノイズ成分が少なく、なめらかな変動をしている。そのため、現在のトラヒック量や増加率が似ていても、将来のトラヒック量は大きく異なることも多々あり、トラヒック量のみでは正確な予測ができないのに対して、各エリアの人数の情報を用いることにより、観測情報と将来のトラヒック量の状態をより正確に対応付けることができる。その結果、各エリアの人数の情報を用いることにより、予測精度が向上し、より少ない資源で輻輳を回避することが可能となったと考えられる。



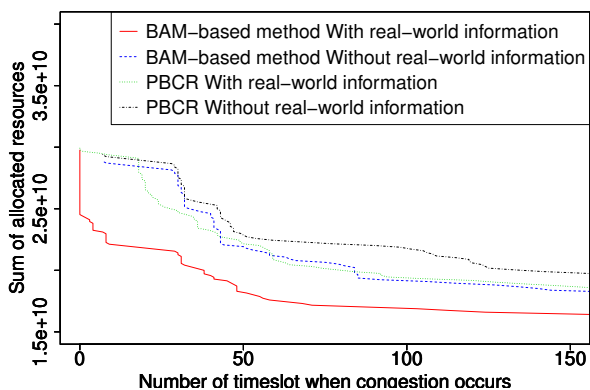


図 3: 輻輳発生時間を一定以下に抑えるために必要な割当資源量

次に、BAM-based method with real-world information と PBCR with real-world information を比較すると、BAM-based method with real-world information の方が、輻輳が発生したタイムスロット数が少ないことが分かる。これは、BAM-based method with real-world information が確信度をもとに制御をおこなっているためである。BAM-based method with real-world information では、確信度が閾値以上となった状況判断の選択肢が一つに絞られる状況においては、その認知に対応した予測結果に合わせた資源割当を行うが、確信度が閾値以上の選択肢が複数あり、いずれの状況かの判断が絞ることができない場合には、それらの確信度が閾値以上の選択肢のうち、もっとも資源を必要としている状況を基準とした制御を行う。これにより、状況判断が難しい場合にのみ、より多くの資源を割り当てることができ、輻輳を回避しつつ、割り当てが必要資源を抑えることができている。

## 5. まとめ

本稿では、トラフィック量のみではなく現実世界でセンシングされた情報も用いることにより、将来のトラフィック量をより正確に予測し、資源割当制御を行う予測型ネットワーク制御手法について検討を行った。本検討では、モバイルネットワークにおける各エリアから流入するトラフィックを収容するのに必要な資源を動的に割り当てる問題を対象とし、トラフィック量、各エリアの人数といった将来のトラフィック量との関係が曖昧な情報を得ながら、随時、将来必要となる資源量を予測し、資源割当の判断を脳の情報処理過程のモデルを用いて行う手法を提案した。そして、提案手法を、既存のシミュレーターを用いて交通流とトラフィック発生を再現し、シミュレーションにより評価した。評価の結果、交通流情報を用いることによる予測精度の向上が少ない資源での輻輳の回避を可能とすること、脳情報処理機構にもとづく予測型制御により、状況予測の確信度が得られ、複数の状況認知の選択肢がある場合には、資源量不足のリスクを避けるように資源割当の設定を行うことができ、輻輳回避に

必要な資源を削減できることが分かった。

今後の課題としては、各時刻で得られる観測情報が大きく欠損しているような状況や、予測粒度がより短い状況における性能評価が挙げられる。

## 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 石橋圭介氏に深謝する。

## 文 献

- [1] P. Kumar, Y. Yuan, C. Yu, N. Foster, R. Kleinberg, and R. Soulé, “Kulfi: Robust traffic engineering using semi-oblivious routing,” *arXiv preprint arXiv:1603.01203*, 2016.
- [2] M. Chiesa, G. Kindler, and M. Schapira, “Traffic engineering with equal-cost-multipath: An algorithmic perspective,” *IEEE/ACM Transactions on Networking*, 2016.
- [3] H. H. Liu, S. Kandula, R. Mahajan, M. Zhang, and D. Gelernter, “Traffic engineering with forward fault correction,” *ACM SIGCOMM Computer Communication Review*, vol. 44, no. 4, pp. 527–538, 2015.
- [4] I. F. Akyildiz, A. Lee, P. Wang, M. Luo, and W. Chou, “A roadmap for traffic engineering in SDN-OpenFlow networks,” *Computer Networks*, vol. 71, pp. 1–30, 2014.
- [5] L. Lu and C. Lianglun, “NETWORK TRAFFIC PREDICTION MODEL BASED ON OPTIMISING SVM WITH IMPROVED CUCKOO SEARCH ALGORITHM,” *Computer Applications and Software*, vol. 1, p. 033, 2015.
- [6] G. Rutka, “Neural network models for Internet traffic prediction,” *Elektronika ir Elektrotechnika*, vol. 68, no. 4, pp. 55–58, 2015.
- [7] G. Rutka and G. Lauks, “Study on internet traffic prediction models,” *Elektronika ir Elektrotechnika*, vol. 78, no. 6, pp. 47–50, 2015.
- [8] C. Daly, “Novel h. 265 video traffic prediction models using artificial neural networks,” 2015.
- [9] W. Lu, “Parameters of Network Traffic Prediction Model Jointly Optimized by Genetic Algorithm,” *JNW*, vol. 9, no. 3, pp. 695–702, 2014.
- [10] 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.
- [11] S. Bitzer, J. Bruineberg, and S. J. Kiebel, “A Bayesian Attractor Model for Perceptual Decision Making,” *PLoS Comput Biol*, vol. 11, no. 8, p. e1004442, 2015.
- [12] S. J. Julier and J. K. Uhlmann, “New extension of the kalman filter to nonlinear systems,” in *Signal processing, sensor fusion, and target recognition VI*, vol. 3068, pp. 182–194, International Society for Optics and Photonics, 1997.
- [13] T. Kashiyama, Y. Pang, and Y. Sekimoto, “Open pflow: Creation and evaluation of an open dataset for typical people mass movement in urban areas,” *Transportation Research Part C: Emerging Technologies*, vol. 85, pp. 249–267, 2017.
- [14] E. M. R. Oliveira, A. C. Viana, K. P. Naveen, and C. Sarraute, “Measurement-driven mobile data traffic modeling in a large metropolitan area,” in *Pervasive Computing and Communications (PerCom), 2015 IEEE International Conference on*, pp. 230–235, IEEE, 2015.