

# エラスティック光ネットワークにおける ベイズ推定にもとづく仮想ネットワーク再構成手法

大場斗士彦<sup>†</sup> 荒川 伸一<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: †{t-ohba,arakawa,murata}@ist.osaka-u.ac.jp

**あらまし** 仮想ネットワークを構築・再構成する手法の検討がなされてきているが、既存手法の多くは対地間トラフィックマトリクスの情報を用いて最適な仮想ネットワークを設計することを目指している。しかし、トラフィックが変動する状況において、対地間トラフィックマトリクスの情報を用いて最適な仮想ネットワークを構成するのは困難である。そこで本稿では、対地間トラフィックマトリクスの情報を用いない仮想ネットワーク再構成フレームワークを提案する。提案手法の基本的なアイデアは、特定のトラフィック状況に対して良好な性能を示す仮想ネットワークを複数記憶しておき、現在のトラフィック状況に適した仮想ネットワークを設定することである。提案手法は現在のトラフィック状況を同定するための方法としてベイズ推定を用いる。本稿では、トラフィック状況を表す情報として、対地間トラフィックマトリクスよりも容易に取得可能なエッジルーターにおけるトラフィック流出入量を用いる。さらに、同定したトラフィック状況に適した仮想ネットワークが現在のトラフィック状況に適さない場合に備え、ノイズを用いた仮想ネットワーク再構成手法を提案フレームワークに組み込む。評価の結果、提案手法は対地間トラフィックマトリクスよりも容易に取得可能なエッジルーターにおけるトラフィック流出入量を用いてトラフィック状況を同定可能であり、現在のトラフィック状況に適した仮想ネットワークを構成するまでの再構成の回数を削減可能であることがわかった。

**キーワード** エラスティック光ネットワーク、仮想ネットワーク再構成、ベイズ推定、ベイジアンアトラクターモデル

## A Bayesian-based Virtual Network Reconfiguration in Elastic Optical Path Networks

Toshihiko OHBA<sup>†</sup>, Shin'ichi ARAKAWA<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: †{t-ohba,arakawa,murata}@ist.osaka-u.ac.jp

**Abstract** A typical approach for constructing/reconfiguring a virtual network (VN) is to design an optimal topology and the amount of resources with a knowledge of the end-to-end traffic demand matrix. However, it is difficult to configure the optimal VN using the traffic demand matrix in a changing environment. In this paper, we develop a VN reconfiguration framework without using the traffic demand matrix. Our basic idea is to memorize a set of “good” VNs, each of which works well for a certain traffic situation, and then retrieve one of the VNs suitable for the current traffic situation. In order to identify the current traffic situation, we apply a concept of Bayesian inference. We use the amounts of outgoing/incoming traffic at edge routers as the traffic information, which are available more easily than the traffic demand matrix. Furthermore, for a case where the performance of the VN is not adequate even though the identification succeeds, we incorporate a noise-induced VN reconfiguration method with our framework. Evaluation results show that our method can identify the traffic situation using the amounts of outgoing/incoming traffic at edge routers, which are available more easily than the traffic demand matrix, and successfully decreases the number of VN reconfiguration to reach a VN suitable for the traffic situation.

**Key words** Elastic Optical Network, Virtual Network Reconfiguration, Bayesian Inference, Bayesian Attractor Model

## 1. はじめに

ネットワーク仮想化技術 [1] は、トラフィックを収容する柔軟なネットワーク基盤を実現する重要な概念の一つである。インターネットを利用する様々なデバイスやサービスの発展により、トラフィック量が増大・変動する傾向は今後も継続すると予想されている [2]。したがって、様々なユーザーの要求に対し、動的に資源（波長分割多重（WDM: Wavelength Division Multiplexing）技術を用いたネットワークにおける波長や、エラスティック光ネットワークにおける周波数スロット）を割り当てることで仮想ネットワークを提供し、またそれを再構成するアプローチが必須である。

これまでに検討されてきている仮想ネットワークを設定・再構成する手法には、対地間トラフィックマトリクス情報をもとに混合整数線形計画問題を解く、あるいはヒューリスティックアルゴリズムを用いることで最適な仮想トポロジー設計と資源（帯域幅）割り当てを目指すものが多い [3, 4]。しかし、対地間トラフィックマトリクスを直接取得するには、ネットワーク上を流れるパケットを解析し各地点宛でのトラフィック量をカウントする必要がある。したがって、対地間トラフィックマトリクスを取得するには長期的な観測と膨大な処理能力を要するため、トラフィック変動に追従して仮想ネットワークを再構成するのが困難である。そこで、対地間トラフィックマトリクスより容易に取得可能なリンク利用率の情報をもとに、対地間トラフィックマトリクスを推定する手法の検討がなされてきている [5, 6]。しかし、文献 [5] の手法は対地間トラフィック量が特定のトラフィックモデルに従うことを想定しており、また文献 [6] の手法は過去の対地間トラフィック量を学習させたニューラルネットワークをもとに推定を行うため、予期せぬトラフィック変動が生じた際の推定誤差が避けられないという欠点がある。推定に失敗すると、誤った対地間トラフィックマトリクス情報をもとに仮想ネットワークを構成することになるため、最適な仮想ネットワークを提供することができない。

そこで本稿では、対地間トラフィックマトリクス情報を用いない仮想ネットワーク再構成のフレームワークを提案する。本稿の基本的なアイデアは、人間の認知や意思決定に学ぶアプローチを採ることである。具体的には、特定のトラフィック状況に対して良好な性能を示す仮想ネットワークを複数記憶しておき、現在のトラフィック状況に適した仮想ネットワークを選択し、再構成するアプローチを採る。なお、トラフィック状況は対地間トラフィックマトリクスそのものである必要はなく、より容易に利用可能な情報を用いることが可能である。本稿ではエッジルーターにおけるトラフィック流出入量を用いる。

本稿で提案する仮想ネットワーク再構成手法を実現する上での課題は、(1) 動的にトラフィックが変動する環境において、容易に取得可能な情報からどのようにトラフィック状況を同定するか、(2) 同定したトラフィック状況に適した仮想ネットワークが良好な性能を示さない場合に、仮想ネットワークをどのように再構成するか、(3) トラフィック状況の同定に失敗した場合に、仮想ネットワークをどのように再構成するか、の3つである。課

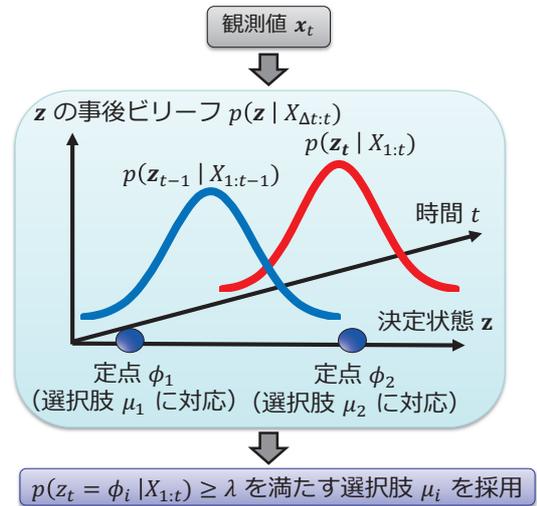


図1 ベイジアンアトラクターモデルの動作概要

題 (2) は、推定した対地間トラフィックマトリクスを用いるアプローチと共通の課題である。課題 (1) を解決するため、本稿ではベイズ推定 [7] の概念を適用する。ベイズ推定は、ベイズの定理にもとづき観測した情報からその原因事象の生起確率を推論する手法である。本稿の場合では、あらかじめ特定した複数のトラフィック状況が与えられた上で、トラフィック情報が観測される度に現在のトラフィック状況がそれらの状況に合致する確率を更新する。課題 (2)(3) に対しては、本稿ではアトラクター選択モデルにもとづく仮想ネットワーク再構成手法 [8] を提案するフレームワークに組み込む。文献 [8] の手法も同様に対地間トラフィックマトリクス情報を用いない手法であり、仮想ネットワーク上の通信品質（リンク利用率）のみを観測し、ノイズによって良好な仮想ネットワークを探索する特徴をもつ。しかし、本稿で提案するベイズ推定を用いたフレームワークは、文献 [8] の手法と比較して、仮想ネットワークの再構成の回数を削減可能であると考えられる。その理由は、文献 [8] の手法は本質的にノイズによって仮想ネットワークを随時再構成する手法であるのに対し、本稿で提案する手法は性能が悪化しない限り仮想ネットワークを再構成しないためである。

本稿の構成は以下の通りである。2. 章では、ベイズ推定の手法としてベイジアンアトラクターモデルについて述べ、これを応用した仮想ネットワーク再構成手法を 3. 章で提案する。4. 章では、文献 [8] の手法と比較したときの提案手法の有用性について述べ、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、ベイズ推定の手法として文献 [9] で提案されているベイジアンアトラクターモデル (BAttM) について簡単に述べる。

### 2.1 BAttM の概要

BAttM は、脳が外界からの感覚情報から抽出したエビデンスを蓄積し、それをもとに認知に関する意思決定をする振る舞いをモデル化したものである。BAttM は図 1 に示すように内

表 1 ベイジアンアトラクターモデルのパラメーター

パラメーター	説明
$s$ (noise level)	実際の観測値のノイズの大きさ
$q$ (dynamics uncertainty)	定点間の遷移のしやすさ
$r$ (sensory uncertainty)	想定される観測値のノイズの大きさ

部状態として決定状態  $\mathbf{z}$  をもつ。決定状態  $\mathbf{z}$  は、エビデンスが蓄積されるにつれて定点  $\phi^*$  に収束するアトラクターダイナミクスにしたがって値が変化する。BAttM は観測値の平均値に対応する選択肢を有しており、各選択肢  $\mu_i$  はそれぞれ対応する定点  $\phi_i$  に関連付けられる。時間  $t$  において、BAttM は決定状態  $\mathbf{z}_t$  の事後分布  $p(\mathbf{z}_t|\mathbf{X}_{1:t})$  を Unscented Kalman Filter (UKF) [10] を用いて推定する。ここで、 $\mathbf{X}_{1:t} = \{\mathbf{x}_1, \dots, \mathbf{x}_t\}$  は時間  $t$  までの観測値とする。正確には、時間  $t-1$  で得られた決定状態の事後分布  $p(\mathbf{z}_{t-1}|\mathbf{X}_{1:t-1})$  を事前分布とし、時間  $t$  の観測値  $\mathbf{x}_t$  を用いて逐次的に決定状態の事後分布  $p(\mathbf{z}_t|\mathbf{X}_{1:t})$  を推定する。したがって、観測値の情報は随時決定状態に反映されるため、観測値を保持する必要がないという利点がある。最後に、BAttM は  $p(\mathbf{z}_t = \phi_i|\mathbf{X}_{1:t}) \geq \lambda$  を満たす選択肢  $\mu_i$  を正しい選択肢として採用する。ここで、 $p(\mathbf{z}_t = \phi_i|\mathbf{X}_{1:t})$  は定点  $\phi_i$  に対する事後ビリーフ、すなわち選択肢  $\mu_i$  に対する意思決定の確信度 (confidence) を表す。

## 2.2 BAttM の生成モデル

BAttM における決定状態のダイナミクスと、UKF を適用する際に決定状態から次の時点の観測値を予測するためのモデルを詳細に説明する。BAttM は、ある時間ステップから次の時間ステップへの決定状態  $\mathbf{z}$  の変化を式 (1) のように定義する。

$$\mathbf{z}_t - \mathbf{z}_{t-\Delta t} = \Delta t \cdot f(\mathbf{z}_{t-\Delta t}) + \sqrt{\Delta t} \cdot \mathbf{w}_t \quad (1)$$

ここで、 $\mathbf{z}_t$  は時間  $t$  における決定状態、 $f(\mathbf{z})$  はアトラクターダイナミクス [11]、 $\mathbf{w}_t$  は正規分布  $N(\mathbf{0}, \mathbf{Q})$  にしたがうノイズとする。 $\mathbf{Q} = (q^2/\Delta t) \cdot \mathbf{I}$  は決定状態のダイナミクスにおけるノイズの分散共分散行列とし、 $q$  は“ダイナミクスの不確実性 (dynamics uncertainty)”を表す。

また、決定状態  $\mathbf{z}$  が与えられたとき、観測値に関する確率分布を式 (2) を用いて予測する。

$$\mathbf{x} = \mathbf{M} \cdot \sigma(\mathbf{z}) + \mathbf{v} \quad (2)$$

ここで、 $\mathbf{M} = [\mu_1, \dots, \mu_m]$  は意思決定における選択肢となる観測値の平均値から構成される。 $\sigma(\mathbf{z})$  は定点  $\phi_i$  をベクトル  $\sigma(\phi_i)$  にマッピングし、 $\mathbf{M} \cdot \sigma(\mathbf{z})$  が各定点  $\phi_i$  と選択肢  $\mu_i$  を関連付ける。また、 $\mathbf{v}$  は正規分布  $N(\mathbf{0}, \mathbf{R})$  にしたがうノイズとする。 $\mathbf{R} = r^2 \cdot \mathbf{I}$  は観測値のノイズの分散共分散行列とし、 $r$  は意思決定者 (脳) が想定する“観測値の不確実性 (sensory uncertainty)”である。それに対し、実際の観測値のノイズの大きさ (noise level) を  $s$  とする。BAttM におけるパラメーターを表 1 にまとめて示す。

## 3. ベイズ推定にもとづく仮想ネットワーク再構成手法

### 3.1 提案手法の概要

BAttM を仮想ネットワーク再構成フレームワークに適用する。提案するフレームワークでは、観測値  $\mathbf{X}_{1:t}$  のもとで現在のトラヒック状況があるトラヒック状況  $\mu_i$  に同定されたとき、仮想ネットワーク  $g_i$  を選択する。より正確には、選択肢  $\mu_i$  に対する意思決定の確信度 (confidence) が十分大きくなったとき、仮想ネットワークを  $g_i$  に再構成する。本稿では、観測値  $\mathbf{X}_{1:t}$  としてエッジルーターにおけるトラヒック流出入量を用いる。ここで、仮想ネットワーク  $g_i$  はトラヒック状況  $\mu_i$  に適したものになるようにあらかじめ用意したものである。

ただし、トラヒック状況の同定に成功した場合でも、仮想ネットワーク  $g_i$  が現在のトラヒック状況に適していない場合が考えられるため、BAttM を仮想ネットワーク再構成フレームワークに適用するだけでは不十分である。そこで、複数の制御フェーズを用意し、BAttM における confidence と仮想ネットワーク上の通信品質にもとづいて制御フェーズを切り替える。提案するフレームワークにおける制御フェーズを以下に示す。

- Phase 1: トラヒック状況を同定するまで待機

– トラヒック状況を同定する (confidence が大きい状態で安定する) まで仮想ネットワークの再構成を行わず待機する。トラヒック状況を同定すると Phase 2 へ遷移する。

- Phase 2: 同定したトラヒック状況もとづく仮想ネットワークの再構成

– 現在のトラヒック状況を  $\mu_i$  に同定したとき、仮想ネットワークをトラヒック状況  $\mu_i$  に適した  $g_i$  に再構成する (Phase 2-1)。仮想ネットワーク  $g_i$  が現在のトラヒック状況に適さない場合は、文献 [8] の手法を用いて良好な仮想ネットワークを探索する (Phase 2-2)。また、confidence が低下した場合は Phase 1 へ遷移する。

要約すると、提案するフレームワークはまず BAttM を用いてトラヒック状況を同定し (Phase 1)、同定が成功し次第仮想ネットワークをトラヒック状況に適している見込みのあるものに再構成する (Phase 2-1)。そして、仮想ネットワーク上の通信品質を観測し、必要に応じて仮想ネットワークを再構成する (Phase 2-2)。ただし、本稿ではトラヒック状況の同定に失敗する (confidence が小さい状態で安定する) 場合は検証の範囲外とする。しかし、ノイズにより良好な仮想ネットワークを探索する Phase 2-2 を適用するのみでも、トラヒック状況の同定に失敗する場合に対処可能であることが期待できる。

### 3.2 提案手法の制御アルゴリズム

#### 3.2.1 入力パラメーター

制御アルゴリズムの入力パラメーターとして、以下を用いる。

- 特定のトラヒック状況に適した仮想ネットワーク

エッジルーターにおけるトラヒック流出入量が  $\mu_i (1 \leq i \leq m : m$  は BAttM における選択肢数) であるときに良好な性能を示した仮想ネットワーク  $g_i (1 \leq i \leq m)$  を用意する。具体的な方法としては、

- 制御履歴から、エッジルーターにおけるトラフィック流出量が  $\mu_i$  であるときに良好な性能を示した仮想ネットワーク  $g_i$  を保持

- 日周期変動などから想定可能な  $m$  パターンの対地間トラフィック量を用いて  $m$  個の仮想ネットワークを算出などの方法が挙げられる。

b) トラフィック状況の同定に用いるパラメーター

BAttM によりトラフィック状況  $\mu_1, \dots, \mu_m$  を正しく同定できるパラメーター  $(r, q)$  の組をシミュレーションにより求める。

### 3.2.2 オンライン制御

本手法は、短周期でエッジルーターにおけるトラフィック流出量（および IP ネットワークにおけるリンク利用率）を観測し、BAttM における confidence と仮想ネットワーク上の通信品質にもとづいて遷移した制御フェーズにおける処理を実行する。運用開始時 ( $t = 0$ ) の制御フェーズは Phase 1 とする。以下では、時間  $t$  における処理を説明する。

a) Step 1: BAttM によるトラフィック状況の同定

エッジルーターにおけるトラフィックの流出入量を観測し、BAttM により現在のトラフィック状況が  $\mu_i$  のいずれと類似しているかを推定する。

Step 1-1 推定に用いるパラメーター  $r, q$  を設定する。具体的には、観測値  $\mathbf{X}_{1:t}$  から求めた標準偏差  $s_t$  を  $r$  とし、事前準備で求めた対となるパラメーターを  $q$  とする。観測値の標準偏差の計算には、 $\mathbf{x}_1, \dots, \mathbf{x}_{t-1}$  の値の保持が不要な Welford の方法 [12] を応用し、標準偏差の逐次更新を以下のように行う。ここで、 $\bar{x}_t$  は時間  $t$  までの観測値の平均値とする。

$$\bar{x}_t = \frac{1}{t} \{(t-1)\bar{x}_{t-1} + x_t\} \quad (3)$$

$$s_t^2 = \frac{1}{t} \{(t-1)s_{t-1}^2 + (x_t - \bar{x}_{t-1})(x_t - \bar{x}_t)\} \quad (4)$$

Step 1-2 BAttM により決定状態  $\mathbf{z}_t$  の事後分布を推定し、各定点  $\phi_i$  に対する事後確率  $p(\mathbf{z}_t = \phi_i | \mathbf{X}_{1:t}) (1 \leq i \leq m)$  を算出する。

Step 1-3 Step 1-2 で算出した事後確率から意思決定の確信度 (confidence) を算出する。ここでは、文献 [13] にしたがって、ある定点に対する事後確率が他の定点のものより一定値以上大きければ confidence が大きいものとする。したがって、式 (5) のように confidence を定義し、これが閾値  $\lambda$  以上であるとき現在のトラフィック状況が  $\mu_i$  である確信度が大きいとする。ただし、各定点  $\phi_k (1 \leq k \leq m)$  に対する事後確率の中で、定点  $\phi_i$  に対する事後確率が最も大きく、定点  $\phi_j$  に対する事後確率が 2 番目に大きいものとする。

$$\log_{10} \frac{p(\mathbf{z}_t = \phi_i | \mathbf{X}_{1:t})}{p(\mathbf{z}_t = \phi_j | \mathbf{X}_{1:t})} \geq \lambda \quad (5)$$

b) Step 2: 制御フェーズの遷移

算出した confidence および仮想ネットワーク上の通信品質にもとづいて制御フェーズを図 2 のように遷移させる。ここで、confidence が大で安定とは、confidence が  $c_{th}$  回連続で閾値  $\lambda$  以上となることを指す。

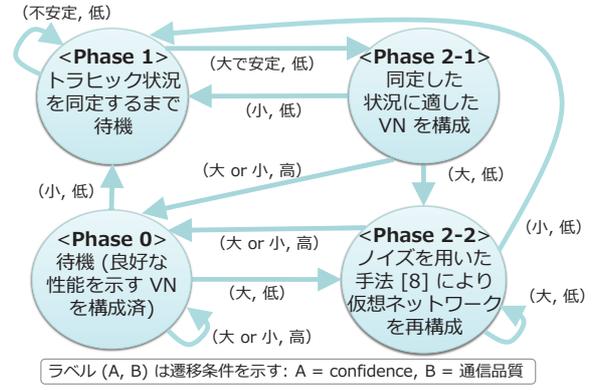


図 2 制御フェーズの状態遷移図 (提案手法)

c) Step 3: 遷移先フェーズの制御の実行

Step 2 で遷移した先の制御フェーズにおける処理を実行する。各フェーズの処理を以下に示す。

Phase 1 仮想ネットワークを再構成せず待機する。

Phase 2-1 仮想ネットワークを、同定したトラフィック状況に適したものに再構成する。具体的には、トラフィック状況が  $\mu_i$  である確信度が大きいとき、仮想ネットワークを式 (6) のように  $g_i$  に再構成し、物理ネットワークに投入する。ここで、仮想ネットワーク  $g_i$  に対応する状態変数の組を  $\mathbf{y}^{(i)} = (y_1^{(i)}, \dots, y_n^{(i)})$  とする。ただし、 $\mathbf{y} = (y_1, \dots, y_n)$  は仮想トポロジー（各対地間に光パスを設定するか否か）を決定する状態変数の組である。

$$\mathbf{y} = \mathbf{y}^{(i)} \quad (6)$$

Phase 2-2 文献 [8] の手法にしたがい仮想ネットワークを算出し、物理ネットワークに投入する。

Phase 0 構成した仮想ネットワークが良好な性能を示すため、仮想ネットワークを再構成せず待機する。

## 4. 評価

本稿で提案するエラスティック光ネットワーク上の仮想ネットワーク再構成手法の有用性を評価する。提案手法は、Phase 2-2 においてノイズを用いて仮想ネットワークを再構成する振る舞いを含んでいるため、文献 [8] の手法を比較手法とする。両手法は、対地間トラフィックマトリクスの情報を用いない手法である。

### 4.1 評価環境

#### 4.1.1 物理トポロジー

本評価では 24 ノードの USNET トポロジーをもつ物理ネットワークを対象とし、各ノード (BV WXC および IP ルーター) のポート (トランスポンダー) 数は等しく 10 とする。各ポートの帯域幅は 100Gbps であるとする。また、全ノードが外部とのトラフィック流入が発生するエッジルーターであるとする。

#### 4.1.2 周波数スロット割り当て

各光ファイバーの周波数域は 4.75THz、1 スロットあたりの周波数域は 12.5GHz とする。すなわち、各光ファイバーの周波数スロット数は 380 とする。また、1 スロットあたりの帯域幅は 10Gbps とする。周波数スロットの割り当てアルゴリズム

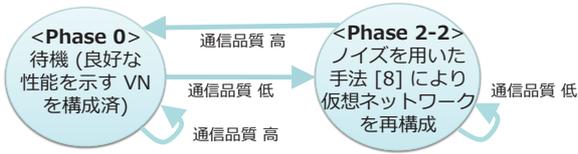


図3 制御フェーズの状態遷移図 (比較手法 [8])

は文献 [8] と同様のものを用いる。

#### 4.1.3 制御目標

制御目標は、仮想ネットワークの最大リンク利用率を閾値  $u_{maxth} = 0.5$  以下とすることとする。なお、IP ルータ間のトラフィックは仮想ネットワークをトポロジーとして最短経路制御にもとづいて転送されるものとしている。

#### 4.1.4 ベイジアンアトラクターモデル

対数正規分布にしたがう乱数から対地間トラフィック  $\mathbf{T}_i (1 \leq i \leq 5)$  を生成し、対地間トラフィック量が  $\mathbf{T}_i$  であるときのエッジルーターにおけるトラフィック流出量  $\mathbf{E}_i$  を  $\mu_i$  とする。想定するトラフィック状況  $\mu_1, \dots, \mu_5$  に対応する定点をそれぞれ  $(\phi_1, \dots, \phi_5)^T = 10 \cdot \mathbf{I}$  とする。式 (5) で定義する confidence が  $c_{th}=3$  回連続で閾値  $\lambda=10$  を上回ったとき、confidence が大きい状態で安定したと見做す。また、事前準備として、 $\mathbf{T}_i$  を収容可能な仮想ネットワーク  $g_i$  を準最適化アプローチにより算出する。具体的には、MSF (Most Subcarriers First) アルゴリズム [14] により仮想トポロジーを決定し、First-last Fit アルゴリズム [15] により各光パスに周波数スロットを割り当てる。

#### 4.1.5 対地間トラフィック量

対地間トラフィック量として、正規分布  $N(\mathbf{T}_1, \Sigma)$  にしたがう乱数を単位時間ごとに生成する。ここで、 $\mathbf{T}_i = (\bar{T}_{i,11}, \dots, \bar{T}_{i,sd}, \dots, \bar{T}_{i,NN})$  ( $N$  はノード数)、 $\Sigma = CV^2 \text{diag}(\bar{T}_{i,11}^2, \dots, \bar{T}_{i,NN}^2)$  である。CV は、トラフィック変動の度合いを示す変動係数 (coefficient of variation) を表す。ただし、単位時間ごとに観測するのはエッジルーターにおけるトラフィック流出量である。

#### 4.1.6 比較手法

比較手法は仮想ネットワーク上の通信品質にもとづいて制御フェーズを図3のように遷移させる。各フェーズで実行する処理は以下の通りである。

Phase 2-2 文献 [8] の手法にしたがい仮想ネットワークを算出し、物理ネットワークに投入する。

Phase 0 構成した仮想ネットワークが良好な性能を示すため、仮想ネットワークを再構成せず待機する。

#### 4.2 評価結果

まず、提案手法の振る舞いを図4に示す。図4は  $CV = 0.75$  のときの各手法の制御フェーズの推移を示しており、横軸は時間、縦軸はその時点における制御フェーズを示している。提案手法は、Time=4 まで Phase 1 でトラフィック状況を同定するまで待機しており、Time=5 で Phase 2-1 に遷移し、仮想ネットワークを最も見込みのあるものに再構成している。特筆すべき点は、提案手法は対地間トラフィックマトリクスよりも容易に取

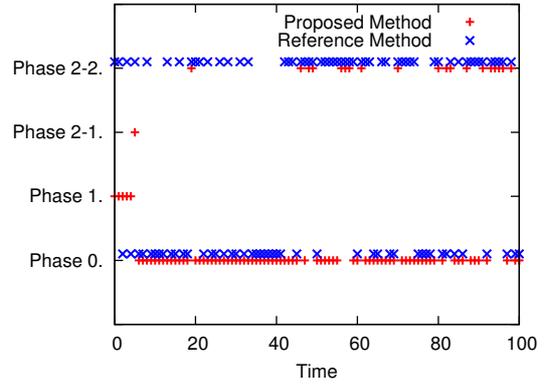


図4 制御フェーズの推移 ( $CV = 0.75$ )

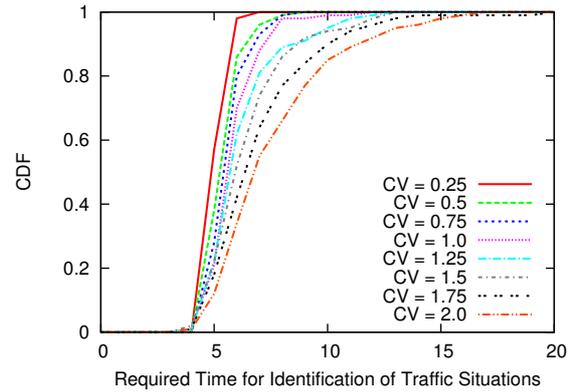


図5 トラフィック状況の同定に要する時間

得可能なエッジルーターにおけるトラフィック流出量を用いてトラフィック状況を同定できていることである。Time=6以降は、Phase 2-1 で構成した仮想ネットワークにより制御目標を達成しているため、Phase 0 にとどまっている。Time=20 など、トラフィック変動により制御フェーズが Phase 2-2 に遷移した場合でも、ノイズを用いた制御により迅速に Phase 0 に遷移していることがわかる。その理由は、仮想ネットワークは現在のトラフィック状況に最も適している見込みのあるものに再構成されているため、ノイズによる良好な仮想ネットワークの再構成が必要最小限で済むためである。一方、比較手法の制御フェーズは Phase 2-2、Phase 0 間の遷移を繰り返している。

以降では、トラフィック変動 ( $CV$ ) の大きさを変化させたときの提案手法の振る舞いを評価する。図5は、 $CV=0.25 \sim 2.0$  のそれぞれの場合について、トラフィック生成に用いるシードを変更して試行を 100 回行って得た、トラフィック状況の同定に要する時間の累積密度関数を示している。ここで、トラフィック状況の同定に要する時間とは、はじめて Phase 2-1 に遷移した時間とする。図5を見ると、 $CV$  が増加すると同定に要する時間も徐々に増加することがわかる。 $CV$  が 1.0 以下のときはおおむね 10 ステップ以下でトラフィック状況を同定でき、 $CV$  がそれ以上の場合でも最大で 20 ステップ程度でトラフィック状況を同定できることがわかる。

図6は、 $CV=0.25 \sim 2.0$  のそれぞれの場合について、Time=100 までの試行をトラフィック生成に用いるシードを

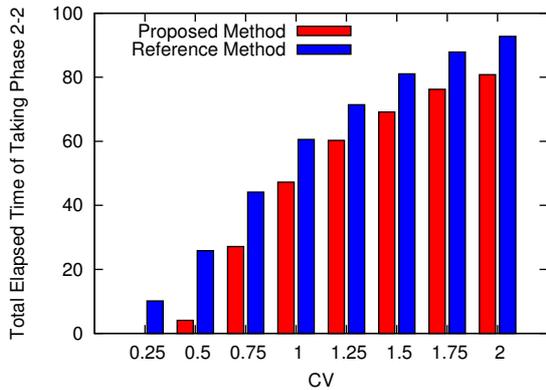


図 6 Phase 2-2 での滞り時間

変更して 100 回行って得た、Phase 2-2 での滞り時間の平均値を示している。図 6 を見ると、 $CV$  が小さいとき、提案手法は同定したトラフィック状況に適した仮想ネットワークでトラフィック変動にも対応できる場合が多いため Phase 2-2 での滞り時間が少ないが、 $CV$  が大きくなるにつれて Phase 2-2 の制御が必要になる割合が大きくなるのがわかる。ただし、提案手法は Phase 2-2 での滞り時間が比較手法の滞り時間より平均的に短く、仮想ネットワークを再構成する回数が少ないことがわかる。特に  $CV$  が 1.0 以下のとき、提案手法の仮想ネットワーク再構成回数の削減効果が大きいがわかる。したがって、提案手法は同定したトラフィック状況に適した仮想ネットワークを構成することで、トラフィック変動による性能劣化に伴う仮想ネットワーク再構成を抑制する特徴をもつといえる。

## 5. まとめと今後の課題

本稿では、対地間トラフィックマトリクスを用いない仮想ネットワーク再構成フレームワークとしてベイズ推定を用いたものを提案した。評価により、提案手法は対地間トラフィックマトリクスよりも容易に取得可能なエッジルーターにおけるトラフィック流出入量からトラフィック状況を同定し、それに適した仮想ネットワークを構成することで、トラフィック変動による性能劣化に伴う再構成を抑制する特徴をもつことを示した。

本稿では、トラフィック状況の同定に失敗する場合は検証の範囲外としたが、この場合に対処する方法として、未知のトラフィック状況を BAttM に学習させるアプローチが必要となる。今後の研究課題は、どのようなタイミングで、またどのような観点で未知のトラフィック状況を学習すべきかを検討することである。

### 謝辞

本研究の一部は、科学研究費補助金基盤研究 (A)15H01682 によるものである。ここに記して謝意を表す。

### 文献

- [1] N. M. K. Chowdhury and R. Boutaba, "Network virtualization: state of the art and research challenges," *IEEE Communications magazine*, vol. 47, pp. 20–26, July 2009.
- [2] Cisco, Visual Network Index, "Forecast and Methodology, 2015-2020," June 2016.
- [3] V. Gkamas, K. Christodoulopoulos, and E. Varvarigos, "A joint multi-layer planning algorithm for IP over flexible op-

tical networks," *IEEE/OSA Journal of Lightwave Technology*, vol. 33, pp. 2965–2977, July 2015.

- [4] Assis, KDR and Peng, S and Almeida, RC and Waldman, H and Hammad, A and Santos, AF and Simeonidou, D, "Network virtualization over elastic optical networks with different protection schemes," *IEEE/OSA Journal of Optical Communications and Networking*, vol. 8, pp. 272–281, Apr. 2016.
- [5] Y. Zhang, M. Roughan, N. Duffield, and A. Greenberg, "Fast accurate computation of large-scale ip traffic matrices from link loads," *ACM SIGMETRICS Performance Evaluation Review*, vol. 31, pp. 206–217, June 2003.
- [6] H. Zhou, L. Tan, Q. Zeng, and C. Wu, "Traffic matrix estimation: A neural network approach with extended input and expectation maximization iteration," *Journal of Network and Computer Applications*, vol. 60, pp. 220–232, Jan. 2016.
- [7] G. E. Box and G. C. Tiao, *Bayesian inference in statistical analysis*, vol. 40. John Wiley & Sons, 2011.
- [8] T. Ohba, S. Arakawa, and M. Murata, "Virtual network reconfiguration in elastic optical path networks for future bandwidth allocation," *IEEE/OSA Journal of Optical Communications and Networking*, vol. 8, pp. 633–644, Sept. 2016.
- [9] S. Bitzer, J. Bruineberg, and S. J. Kiebel, "A bayesian attractor model for perceptual decision making," *PLoS Computational Biology*, vol. 11, p. e1004442, Aug. 2015.
- [10] S. S. Haykin *et al.*, *Kalman filtering and neural networks*. Wiley Online Library, 2001.
- [11] J. J. Hopfield, "Neurons with graded response have collective computational properties like those of two-state neurons," *Proceedings of the national academy of sciences*, vol. 81, pp. 3088–3092, May 1984.
- [12] D. Knuth, *The art of computer programming, Volume 2, Seminumerical Algorithms*. Addison-Wesley, 1969.
- [13] S. Bitzer, H. Park, F. Blankenburg, and S. J. Kiebel, "Perceptual decision making: drift-diffusion model is equivalent to a bayesian model," *Frontiers in human neuroscience*, vol. 8, p. 102, Feb. 2014.
- [14] K. Christodoulopoulos, I. Tomkos, and E. Varvarigos, "Elastic bandwidth allocation in flexible OFDM-based optical networks," *Journal of Lightwave Technology*, vol. 29, pp. 1354–1366, Mar. 2011.
- [15] R. Wang and B. Mukherjee, "Spectrum management in heterogeneous bandwidth networks," in *Proceedings of IEEE GLOBECOM*, pp. 2907–2911, Dec. 2012.