

# ユーザ QoE 向上を目的とする脳内認知モデルを用いた 動画像ストリーミングのレート制御手法

小南 大智<sup>†</sup> 岩井 孝法<sup>††</sup> 下西 英之<sup>††</sup> 村田 正幸<sup>†††</sup>

<sup>†</sup> 大阪大学 大学院経済学研究科 〒 560-0043 大阪府豊中市待兼山町 1-7

<sup>††</sup> NEC システムプラットフォーム研究所 〒 211-8666 神奈川県川崎市中原区下沼部 1753

<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: <sup>†</sup>d-kominami@econ.osaka-u.ac.jp, <sup>††</sup>(t-iwai@hx, h-shimonishi@cd).jp.nec.com,

<sup>†††</sup>murata@ist.osaka-u.ac.jp

あらまし あらゆる情報を通信ネットワークを介して享受できる時代が近づく中、ユーザの求める様々な品質要求に対して、柔軟に対応できるネットワークの実現が望まれている。近年では、ユーザの体感品質 (QoE; quality of experience) を向上する技術が重要視されており、これまで、ユーザの QoE を推定し、その向上を目指す研究が行われてきた。QoE は人の主観にもとづく指標であり、時々刻々と変化するため、ユーザの QoE を真に向上するためには、時々刻々と変化するユーザの QoE を把握し、その向上のために適切な制御を行う必要がある。本稿では不確かな観測情報に基づく脳内の情報認知を模したベイジアンアトラクターモデルを QoE 推定に用いた。推定結果を動画像ストリーミングのレート制御に用いることで、ユーザ QoE の向上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、quality of experience、quality of service、MPEG DASH

## QoE enhancement for video streaming based on a human perceptual mechanism

Daichi KOMINAMI<sup>†</sup>, Takanori IWAI<sup>††</sup>, Hideyuki SHIMONISHI<sup>††</sup>, and Masayuki MURATA<sup>†††</sup>

<sup>†</sup> Graduate School of Economics, Osaka University

<sup>††</sup> System Platform Research Labs, NEC Corporation

<sup>†††</sup> Graduate School of Information Science and Technology, Osaka University

E-mail: <sup>†</sup>d-kominami@econ.osaka-u.ac.jp, <sup>††</sup>(t-iwai@hx, h-shimonishi@cd).jp.nec.com,

<sup>†††</sup>murata@ist.osaka-u.ac.jp

**Abstract** In the near future, we will be able to access to all sorts of information via information networks. Then, it is desired to realize a network control that can flexibly deal with various user requirements. Recently, quality of experience (QoE) for users is focused and various research has studied on the improvement of it. Since QoE is a subjective value, it changes from moment to moment. Therefore, in order to improve the QoE of users, it is essential to perform an appropriate control under uncertain user's QoE information. In this research, we use the Bayesian attractor model that simulates the information recognition based on uncertain observation in the human brain. We apply this model for estimating user QoE and the estimated QoE is used for a rate control of a video streaming application. We show that the proposed control method can choose an adequate video rate to improve user QoE under uncertain observation.

**Key words** Bayesian attractor model, quality of experience, quality of service, MPEG DASH

### 1. はじめに

現在では、ほぼ全ての人が通信端末を持ち歩き、日常的に

インターネット上の情報にアクセスをしている。人々はあらゆる情報を通信ネットワークを介して享受するようになっており、その結果特に、動画像トラフィックの量は急激な増加を

続けている。また、アプリケーションの多種多様化も顕著であり、ユーザやアプリケーション開発者の求める様々な品質要求に対して、柔軟に対応できるネットワークが望まれている。将来の通信ネットワークを支える技術として、software-defined networking (SDN) や network function virtualization (NFV) などの仮想化技術が着目され、この数年間で実用化が急速に進んでいる [1]。

ネットワーク事業者が通信サービスを提供する際には、ネットワークの通信品質、すなわち quality of service (QoS) を保証することが一つの目的となっていた。QoS の指標には、パケットロス率、遅延時間、スループット、ジッタなどが用いられる。仮想化技術によって、QoS 要件を満足するネットワーク構築が期待され、多くの場合は定期的にネットワークの QoS を計測し、個別のアプリケーションに対して一定の QoS を保証するように、仮想ネットワークの再構築を行うと考えられる。前述したトラフィックの増加とアプリケーションの多様化は、ネットワークを流れるトラフィックの激しい変動を引き起こし、結果として、QoS に大きな変動を与える要因となる。そのため QoS を計測する際には、変動によって生じる情報の不確実性を十分に考慮する必要がある。

近年では、ユーザの体感品質を表す指標である quality of experience (QoE) が QoS とともに着目されている [2, 3]。QoE はユーザ主観におけるサービスの快適さを表現する指標であり、ユーザ個々の QoE を向上する技術がより重要視されている。近年の研究では、計測可能な QoS の値に基づき QoE を推定する手法が様々に提案されている。しかしながら、あるアプリケーションの利用における QoE の要因は、サーバ、端末、ソフトウェア、ユーザの置かれているコンテキスト（ユーザ自身の習熟度、利用する場所や気候）などのネットワークの外側にも広がっており、ネットワーク管理者からは直接計測できないものが存在する。また、QoE 自体が人の主観に基づく指標であるため、それ自体が時々刻々と変化する。QoS のみでは正確に QoE を推定することは困難であるものの、QoS が QoE に与える影響は大きく、より正確な QoS の値を知ることは QoE の推定にとって重要である。

本研究では、時々刻々と変化するユーザの QoE に対応し、その向上を目的とするネットワーク制御技術の検討を行う。このような制御技術を実現する際に課題となるのは、(1) QoS の計測値における不確実性に対して適切な処理を行い、より正確な情報を取り出すこと、(2) 時々刻々と変化するユーザの QoE をできる限り正確に推定すること、(3) ネットワーク側で制御可能な範囲でユーザの QoE を最大化することである。本稿の内容は (1) および (3) の一部分の解決を対象としている。ここでの不確実性とは、QoS の真値に対して、その計測値が様々な誤差を含むことを意味する。白色誤差であれば、時間的な平均化処理によって真値の推定を行うことが可能であるが、分散が大きければある程度の計測期間が必要となる。また、バースト的に大きな誤差が発生する場合は平均化処理は大きく誤った推定値となる可能性がある。

不確かな情報に基づく意思決定のモデルとして、脳の情報認

知機構がある。本稿では、脳の情報認知機構モデルの一つである Bayesian attractor model (BAttM) [4] を用いることで、不確実性を伴う計測情報を適切に処理し、意思決定を行う制御手法を提案する。その対象として、近年普及の進んでいる、帯域適応レート制御方式を用いたビデオストリーミングを扱う。

BAttM は脳による情報知覚と弁別を、ベイズ推定の枠組みを用いてモデル化したものである。BAttM では、脳による弁別が事後確率密度関数を用いて表現されており、この密度関数が示す値の大きさを確信度 (confidence) と定義している。事後確率密度関数は情報の知覚によって更新され、同時に確信度も更新される。BAttM において、意思決定は確信度が一定の値を超えたときになされるものである。BAttM を用いたレート制御手法では、まず、ネットワークの QoS を繰り返し計測し、確信度が一定値以上となるような QoS の値を出力する。このようにして得られた QoS 値を用いるため、計測情報が不確実性を伴う場合でも、適切な判断を行うことが可能となる。図 1 に、提案する動画像レート制御制御手法の概要を示す（詳細は後述）。

本稿ではまず 2. で BAttM の概要を説明する。3. において、BAttM を用いた、ビデオストリーミングにおける帯域適応レート制御について述べる。4. では、計測情報が不確実な場合でも、提案手法が適切な判断を下せることを、計算機シミュレーションを用いて示す。最後に 5. で本稿のまとめを述べる。

## 2. Bayesian attractor model

前述の通り、Bayesian attractor model (BAttM) [4] は脳による情報知覚と弁別を、ベイズ推定の枠組みを用いてモデル化したものである。我々の研究グループでは、これまでに、光ネットワークにおける仮想ネットワーク再構成に BAttM を用いることで、トラフィック状況に適した仮想ネットワークを構成できることを示した [5]。BAttM は大きく三つの要素から構成される。すなわち、(1) 情報知覚のモデル化 (2) 情報弁別のモデル化、(3) 意思決定のモデル化である。以降でそれぞれについて説明する。

### a) 情報知覚モデル

情報知覚モデルにおいて、BAttM は観測対象の情報を一つの特徴量ベクトルの形式で記述する。情報の知覚は一定周期で行われ、各時点におけるこのベクトルが意思決定モデルでの入力となる。

### b) 情報弁別モデル

情報弁別モデルでは、知覚した情報を過去の経験や記憶と照らし合わせ弁別を行う。過去の経験や記憶は所与であり、入力と同じ次元の特徴量ベクトルの形で記述される。情報弁別モデルには  $K$  個のアトラクターを持つ非線形ダイナミクスを用いており、それぞれのアトラクターに過去の  $K$  個の記憶を対応づけている。弁別の機構を表現するために、現在の入力が過去の記憶のいずれに該当するのかを表現する意思決定状態を、このダイナミクスによって更新する。

### c) 意思決定モデル

意思決定モデルでは、知覚した情報による意思決定状態の更

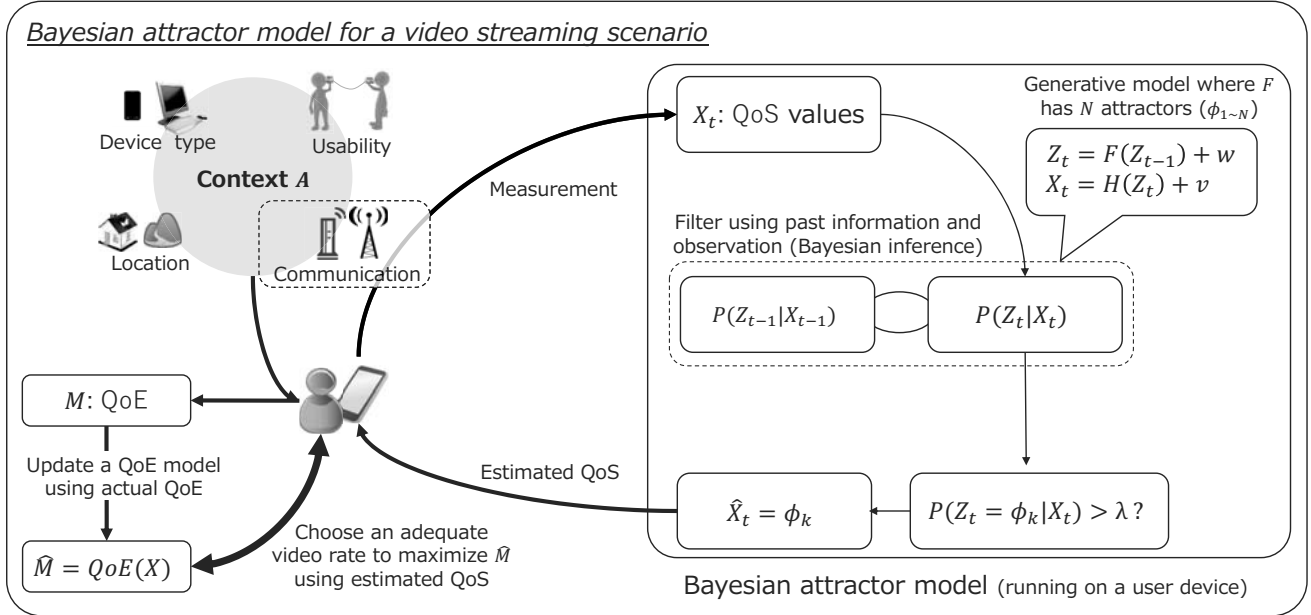


図1 BAttM を用いた動画レート制御

新をベイズ推定の枠組みでモデル化する。情報弁別モデルにおける意思決定状態がどの程度尤もらしいのかを推定し、その尤もらしさが閾値を超えた場合に、現在の意思決定状態が正しいものと決定する。意思決定状態の尤もらしさを定義するために、情報弁別モデルにおける意思決定状態を確率変数とみなし、その確率分布を用いる。情報知覚モデルによる観測値から、現在の意思決定状態を推定するために unscented Kalman filter (UKF) を用いている。

### 3. 提案手法

本節では、図1に示した BAttM を用いた動画レート制御について説明する。本稿では主に図1における Bayesian attractor model と書かれた枠の内側の処理を対象としている。また、本制御はユーザ端末上で動作するエージェントが自律的に行うことを想定している。

**3.1 不確実な QoS に対応する BAttM に基づく意思決定**  
前節で述べた BAttM を構成する三つのモデルに基づき、QoS を推定する手法を説明する。

#### a) 情報知覚モデル

動画ストリーミングアプリケーションの QoE に影響を与える QoS 指標として、スループット  $T$ 、遅延ジッタ  $J$ 、パケットロス率  $P$  を情報知覚の対象とし、これらを並べた特徴量ベクトル  $F$  を  $[T J P]^T$  と表す。

#### b) 情報弁別モデル

BAttM が用いている意思決定状態 ( $z$ ) の更新則は以下のとおりである。

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

$z$  は  $N \times 1$  のベクトルであり、行要素は後述の式 (2) における  $N$  個の安定点 ( $\phi_1 \dots \phi_N$ ) に対応する。 $\Delta t$  は更新周期、 $w_t$  は正規分布  $\mathcal{N}$  に従う乱数である。 $w_t \sim \mathcal{N}(0, q^2/\Delta t)$  であり、 $q$

は生成モデルに含まれるプロセス誤差の大きさを表す。この誤差により、意思決定状態が局所解に陥ることを避けている。 $g$  は winner-take-all network ダイナミクスであり、以下のように定義される。

$$g(z) = k(L\sigma(z) + b^{lin}(\phi - z)) \quad (2)$$

ここで、 $k$  は更新のスケールを決定する定数である。また、 $\phi$  は  $N \times 1$  の行列であり、すべての要素が同じ値  $\phi_g$  を持つ。 $b^{lin}$  はベクトル  $z$  における自己要素への作用の大きさを表している。また、 $L = b^{lat}(I - 1)$  であり、 $I$  は単位行列を、 $1$  は全要素が1の行列を表しているため (いずれもサイズは  $N \times N$ )、 $b^{lat}$  は他要素からの作用の大きさとなる。 $\sigma$  はシグモイド関数であり  $z$  の各要素  $z_i$  を、 $1/(1 + e^{-d(z_i - o)})$  に変換する。 $d$  は減衰特性を、 $o$  は変曲点の位置を決定するパラメータである。ダイナミクス  $g$  を繰り返すことで、 $z$  の  $N$  個の要素のうち、一つだけが  $\phi_g$  付近に収束する。それ以外の要素が収束する値はシグモイド関数のパラメータに依存し、本稿では  $d = 0.7$ 、 $o = \phi_g/2$  に設定しており、 $-\phi_g$  付近に収束する。

BAttM では、計測した情報は  $z_t$  のいずれかの安定点に対応して生成されていると仮定しており、各状態に対応した特徴量  $x_t$  は以下で生成される。

$$x_t = M\sigma(z_t) + v_t \quad (3)$$

$M = [F^0 F^1 \dots F^N]$  は、アトラクターに埋め込む特徴量ベクトルを列挙した特徴量行列である。また、 $v_t$  は正規分布  $\mathcal{N}$  に従う乱数である。ここで  $v_t \sim \mathcal{N}(0, r^2)$  であり、 $r$  は計測の不確かさを表す。BAttM を動画レート制御に用いる際には特徴量行列の設計が重要であり、詳細は次節において述べる。

#### c) 意思決定モデル

式 (3) では、脳内での意思決定状態  $z$  から  $x$  が得られる。逆に、計測した情報に対して、最小分散を与えるような  $z$  を決定

表 1 QoS クラスに基づく QoE 推定モデルの例

$\{T, J, P\}$	QoE
{good, good, good}	5
{good, good, bad}	4
{good, bad, good}	3
{good, bad, bad}	2
{bad, good, good}	3
{bad, good, bad}	2
{bad, bad, good}	1
{bad, bad, bad}	1

するために、文献 [4] では unscented Kalman filter (UKF) [6] を用いている。時系列データのフィルタリングに広く用いられるカルマンフィルタは、非線形ダイナミクスを扱う際には性能が落ちることが知られている。そのため UKF では一時点前の  $\mathbf{z}$  の事後確率分布からシグマ点と呼ばれる少数個のサンプルを抽出し、システムを表す非線形ダイナミクスでシグマ点を変換し、変換後のシグマ点の平均及び分散をもとに、近似的な事前確率分布を導出する。UKF を用いることで時刻  $t$  における  $\mathbf{z}$  の確率密度関数  $P(\mathbf{z}_t|\mathbf{x}_t)$  が得られ、各安定点の確率密度  $P(\mathbf{z}_t = \phi_n|\mathbf{x}_t)$  を確信度と呼ぶ。確信度が閾値  $\lambda$  よりも大きいとき、 $\mathbf{M}\sigma(\phi_n)$  を以降の QoE 推定に用いる。ここで、 $\phi_n$  は  $N \times 1$  の行列であり、本稿では、 $n$  番目の要素および、それ以外の要素をそれぞれ  $\phi_g, -\phi_g$  としている ( $n = 0, \dots, N$ )。確信度は多変量正規分布の密度関数であるため、 $\mathbf{z}$  のサイズが大きいほど、また分散共分散行列の行列式の絶対値が大きいほど、その値は小さくなる。

### 3.2 動画像レート制御

ここでは BAttM を動画像レート制御に対応付ける方法を説明する。まず BAttM により推定した QoS を QoE の推定に用いるためのモデルについて説明し、そのモデルを用いて QoE を最大化する動画像レートの制御を行う方法を説明する。

#### a) QoE モデル

QoE はアプリケーションシステムに対してユーザが感じる心理的な尺度である。その指標として広く用いられているものとして mean opinion score (MOS) があり、ほとんどの場合評価者が 5 段階の整数値で体感品質の良し悪しを評価し、その平均値として QoE を定量化する。既存研究の多くはシステム全体としての QoE 測定に着目したものであるが、Mitra らは、文献 [7] において、QoE の時間的な変化について着目すべきであると主張している。その根拠は、ユーザは通常、サービスやツールを繰り返し使うことでそれらに対する慣れや快適さを獲得していくものであり、単一の時間や場所における QoE の計測では不十分であることと主張している。我々も、QoE を維持あるいは向上することを目的としてネットワークの制御を行う際には、Mitra らの主張のように、QoE の時間的な変化に着目する必要があると考えている。

本稿で用いる QoE モデルは、QoS 値の組み合わせ  $F$  を入力として、まず  $F$  の要素である  $T, J, P$  をそれぞれいくつかのクラスに分類し、各要素が含まれるクラスの組み合わせに対応

したユーザ QoE の推定値を出力する。表 1 は  $T, J, P$  を良い (*good*) あるいは悪い (*bad*) の 2 クラスに分類した例である。*good* または *bad* への分類は、それぞれの代表値を定めることで行う。その代表値の組み合わせ  $F^n$  (ここでは三つの要素がそれぞれ二つの代表値を持つため総組み合わせ数は  $2^3$  となる) を列要素とした特徴量行列  $M = [F^0 F^1 \dots F^N]$  を BAttM に与える。これにより、3.1 での BAttM によって推定される QoS は表 1 のいずれかに該当することになる。なお、本稿では QoE モデルとして静的なものを想定しているが、前述の通り QoE については動的にモデルを更新する必要がある。図 1 では実際のユーザ QoE を用いたフィードバックを含めており、ユーザごとに個別にモデルを更新することで、ユーザ個々の QoE を満足することが可能となる。

#### b) QoE 最大化を目的とした動画像レート選択

本稿では対象アプリケーションとして、近年普及の進んでいるビデオストリーミングプロトコルである MPEG-DASH (MPEG dynamic adaptive streaming over HTTP) を想定している。MPEG-DASH は HTTP を用いたビデオストリーミングを規定しており、具体的には、メタデータを記述する MPD (media presentation description) ファイル仕様の規格と、動画伝送のための segment format というファイル仕様の規格で構成される。メタデータにはメディアサーバ上に存在するビデオの通信レートが複数記述されており、クライアントはいずれかの通信レートを指定してサーバに対する動画の要求を行うことができる。

QoS 値および QoE モデルが与えられた際に、選択される動画像レートがユーザ QoE の向上に最適なものとなるようにする。本稿ではクライアントが計測用のプローブパケットを定期的に送信することを想定している。クライアントが選択可能な動画像レートに相当する通信レートでプローブを送信することで QoS 値を取得する。QoS 値から設定可能な表 1 のクラスの組み合わせのうち、最も QoE が高いものを選択する。ただし、同じ QoE となる組み合わせについては、より通信レートの小さいものを選択することとする。QoE モデルの更新も含め、動画像レート制御の具体的な方法および実装については今後の課題としている。

## 4. 性能評価

BAttM による QoS 推定を計算機シミュレーションによって行い、その特性を明らかにする。本稿では BAttM を QoS の推定に用いており、QoE モデル、動画像レート選択基準は所与であると仮定している。本稿における BAttM では、QoS として計測する特徴量の数およびそれらのクラス数が増えると、アトラクターの数が爆発的に増加する。文献 [4] におけるアトラクター、特徴量の数はともに 2 であり、この違いが与える影響、特に、多数存在する安定点に対して、より少数の計測特徴量を用いて推定を行うことの影響を調査する。

### 4.1 シミュレーション設定

単一のユーザが操作するアプリケーションがネットワークを介して動画像ストリーミングサーバと通信する状況を想定する。






図2 計測値に対する UKF フィルタ出力



(a) 意思決定変数  $z$



(b) 確信度  $P(z_t = \phi_n | \mathbf{x}_t)$

図3 BAttM による意思決定のモデル化

ネットワーク QoS の計測は定期的に行われ、計測結果を入力として本提案手法が動作する。ここでは計測の周期を 1 タイムステップとし、スループット、遅延ジッタ、パケットロス率を計測する。遅延ジッタは、サーバからユーザへの片道遅延について一定期間計測した際の、最大値と最小値の差としている。

各特徴量のクラス分類に関して、それぞれを三つのクラスに分類している。その代表値として、スループット (10 Mbps, 5 Mbps, 1 Mbps)、ジッタ (200 ms, 500 ms, 1,000 ms)、パケットロス率 (0 %, 3 %, 5 %) を用いており、27 個の組み合わせをそれぞれアトラクターの安定点に設定した ( $N = 3^3$ )。意

思決定変数  $z$  の初期値はすべての要素を 0 とした。シミュレーションにおけるその他のパラメータとして、文献 [4] を参考に、 $\Delta t = 0.004$ 、 $k = 4$ 、 $\phi_g = 10$ 、 $b^{lat} = 1.7$ 、 $b^{lin} = b^{lat} / (2\phi_g)$ 、 $r = 1$  を用いている。また、UKF については文献 [6] で用いられているパラメータを利用している。

#### 4.2 シミュレーション結果

はじめに、提案手法が計測誤差および入力値の変化に適応できることを示す。シミュレーションにおいて、ステップ 0 から 2,000 までの計測値 (入力値) の平均値を  $(T, J, P) = (10 \text{ Mbps}, 500 \text{ ms}, 0 \%)$ 、2,001 から 4,000 まで (10 Mbps, 200 ms, 0 %) に設定した。これらは、あらかじめ設定した安定点のうちの一つに対応する性能であり、図 3 の pattern 4 および pattern 1 にそれぞれ相当する。見やすさのために 27 パターン中の 5 パターンだけを示しているが、意思決定変数、確信度のいずれも、増加しているパターン以外は同様の傾向を示している。ここでは、計測誤差として正規分布に従う誤差を想定しており、平均 0、標準偏差を (1 Mbps, 1 ms, 1 %) と設定して入力値を生成した。また、プロセス誤差の大きさ  $q$  は 0.01 に設定した。

シミュレーション結果が図 2 および図 3 である。図 2 では多くの時間領域で UKF が正常に動作していることがわかる。一方で、図 3 からは、初期時点およびステップ 2001 での入力値の切り替え時点から数ステップ後、複数の意思決定状態が混在し、いずれの安定点に対する確信度も低いことが分かる。この点は時間の経過とともに、正しい出力となっている。

提案手法では、ネットワークの QoS を計測し、BAttM を用いることで推定値を出力する。前述した、初期状態直後および入力パターンの切り替わり直後から、確信度がある程度高くなるまでの時間が長いことは、計測に要する時間が長くなること、さらにはネットワーク環境の変動に追従する能力が低いことを意味している。文献 [4] では、確信度の増加の速さと意思決定の正確さにはトレードオフの関係があると述べており、プロセス誤差  $q$  および計測誤差  $r$  を変更することによって、それらの優先度を決定できると述べられている。図 4 は  $q$  の値として 0.001, 0.005, 0.01, 0.05 のそれぞれに設定した際の確信度の推移を示している。 $q$  が 0.001 の際の確信度が他の結果と比べて低いのは、 $z$  の中で最も大きい要素が  $\phi_g$  よりも大きい値を返すためである (シグモイド関数のパラメータに依存する)。

表 2 提案手法の実行時計算時間 (4,000 タイムステップ)

$N$	2	4	8	12	18	27	36	48	64	80	100	125
計算時間 [s]	0.183	0.281	0.62	1.302	3.054	8.703	20.682	49.909	151.763	270.829	579.199	1320.42




図 4 確信度の増加速度と意思決定の正確さ

$q = 0.05$  と設定することで非常に素早い意思決定が行えることが示された一方で、 $q = 0.05$  の結果だけが、入力値に正しく対応する安定点についての確信度ではない (スペースの都合上、図は割愛する)。すなわち、誤った意思決定の結果となっており、 $q$  の設定は注意深く行う必要がある。また、実際の実行時間も重要な観点であり、 $N$  のサイズに対する実行時間を表 2 に示している。この結果は、Intel Core i7-5600U の 1 コアのみを利用した際の結果である。UKF の計算複雑度が  $N^3$  のオーダーであることが知られており、本提案手法の実行時間も  $N$  のサイズの影響を強く受けている。表 2 からは、 $N$  が 125 以下であれば、1 タイムステップに要する時間は 1 秒未満であり、1 秒程度の QoS 計測周期であれば本手法の適用が可能であるといえる。

最後に、状態数に対して少ない特徴量から状態推定を行うことで生じる本手法の問題点を示す。入力の平均値を、(10 Mbps, 200 ms, 0%) から (10 Mbps, 200 ms, 3%) に変えたときの意思決定状態の遷移を図 5 に示す。ラベルの pattern 1, 2, 3 はそれぞれ、(10 Mbps, 200 ms, 0%)、(10 Mbps, 200 ms, 3%)、(10 Mbps, 200 ms, 5%) に対応しており、ステップ 2,000 を境に、pattern 1 が最大の状態から、pattern 2 が最大の状態に遷移することが期待されるが、実際は pattern 1 と pattern 3 が同程度の値となる。これは、pattern 2 が、ほぼ同じ重みの pattern 1 と pattern 3 の線形結合で表現できることが理由である。BAttM がシグモイド関数を用いた非線形ダイナミクスを用いているため、 $q$  や  $r$  の適切な設定により、このような問題がある程度回避できることが分かっているが、提案手法が予期しない状態に収束する可能性を持っていることが明らかとなった。この点に関しては、複数の意思決定状態が混在しているときには一度意思決定状態をリセットする機構を用いることが有効であると考えている。

## 5. おわりに

本稿では、QoE という人間の認知に関わる指標の推定に、人




図 5 設計した安定点以外での収束

間の脳の認知モデルを適用した。脳の情報認知機構のモデルの一つである Bayesian attractor model を用いて推定した QoE に基づいた、動画ストリーミングにおける帯域適応レート制御機構を示した。適切なパラメータの設定下では、不確実性を含む観測情報に対しても正しい推定を行うことができることを示した一方で、提案手法が予期しない状態に陥る可能性もあることも示した。今後の課題として、安定的な推定結果を得るための機構の検討、EEG (Electroencephalogram) 計測結果を用いた、ユーザからの QoE フィードバックによる QoE モデルの更新、実機実装による動作実験がある。

## 文 献

- [1] R. Mijumbi, J. Serrat, J.-L. Gorricho, N. Bouten, F. De Turck, and R. Boutaba, "Network function virtualization: State-of-the-art and research challenges," *IEEE Communications Surveys & Tutorials*, vol.18, no.1, pp.236–262, 2016.
- [2] M. Seufert, S. Egger, M. Slanina, T. Zinner, T. Hobfeld, and P. Tran-Gia, "A survey on quality of experience of http adaptive streaming," *IEEE Communications Surveys & Tutorials*, vol.17, no.1, pp.469–492, 2015.
- [3] K. Mitra, A. Zaslavsky, and C. Åhlund, "Context-aware QoE modelling, measurement, and prediction in mobile computing systems," *IEEE Transactions on Mobile Computing*, vol.14, no.5, pp.920–936, 2015.
- [4] 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.
- [5] T. Ohba, S. Arakawa, and M. Murata, "A bayesian-based virtual network reconfiguration in elastic optical path networks," *IEICE technical report*, PN2016-33, vol.116, no.307, pp.45–50, Nov. 2016.
- [6] S. Haykin, ed., *Kalman filtering and neural networks*, Wiley Online Library, 2001.
- [7] K. Mitra, A. Zaslavsky, and C. Åhlund, "Dynamic bayesian networks for sequential quality of experience modelling and measurement," *Smart Spaces and Next Generation Wired/Wireless Networking*, pp.135–146, Springer, 2011.