

脳の情報処理機構にもとづく車両への経路提案手法

大下 裕一[†] 村田 正幸[†]

[†] 大阪大学 大学院情報科学研究科

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

あらまし 我々は、Bayesian Attractor Model とよばれる脳の認知プロセスのもでるにもとづき、不正確な情報をもとに現在の状況を認知する手法を提案している。。この手法では、認知対象の選択肢をアトラクタとして埋め込み、認知状態に対応する確率変数をベイズ推定により更新することを繰り返すことにより、現在の状況を認知する。これまで、我々は、この Bayesian Attractor Model にもとづく認知手法をネットワークの制御に適用してきた。本稿では、Bayesian Attractor Model にもとづく状況判断を、交通流制御に適用する。特に、リアルタイムに把握された情報に基づき、渋滞を避けるような経路を提案する機構に、Bayesian Attractor Model にもとづく手法を適用する。これにより、各時刻に得られる渋滞の予兆が不確かであっても、各時刻で渋滞が発生しそうな状況であるのかを判断し、判断結果にもとづいて渋滞を避ける経路の提案を行う。

キーワード 交通、車両経路、ネットワーク制御

Route Suggestion for Vehicles based on a Method inspired by Cognitive Model of Human Brain

Yuichi OHSITA[†] and Masayuki MURATA[†]

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

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

Abstract We have proposed a method to identify the current condition from noisy information based on the model of the cognitive process of a human brain, called the Bayesian Attractor Model. In this model, the cognitive options are embedded as attractors. Then, the brain assigns stochastic variables related to the options and recognizes which option is suitable by updating the variables by using the Bayesian inference. We have applied a method based on the Bayesian Attractor Model to the resource allocation within the communication network. In this paper, we apply the method to the control of transportation. Especially, we focus on the system to avoid congestion by suggesting routes. By applying our method based on the cognitive process of a human brain, the system can make decisions even if the information monitored at each time slot is uncertain. Then, based on the identified condition, the system suggests routes to avoid congestion.

Key words Transportation, Vehicle Route, Network Control

1. はじめに

情報技術の進展により、リアルタイムに道路や道路を走る自動車の状態を把握することが可能となってきた [1]。これらの情報をもとにすることにより、その時点の状況に応じて、交通流を制御し、渋滞を未然に防いだり、事故の防止を行うことが期待できる。

そのような高度な制御を実現するためには、各時刻に得られた情報をもとに状況を判断することが必要である。しかしながら、各時刻に得られた情報は、ノイズが含まれている情報であり、各時刻で得られた情報を用いて判断すると誤った判断をす

ることも考えられる。例えば、渋滞を未然に防ぐという応用を考える。この応用においては、各時刻の状況が、ある地点で発生する渋滞の予兆を含んでいるかを判断し、渋滞が発生しそうな道を選んだ道を提案する。従来から交通状況の予測手法は多数提案されている。それらの手法のアプローチの一つは、時系列モデルを構築する方法である [2]。しかしながら時系列モデルのみでは、日常的なトラフィック変動の予測はできるものの、予測には予測の誤差が含まれる。ある地点での渋滞発生の予兆としては、その地点が隣接する道における自動車数の増加が考えられる。しかしながら、自動車数の増加は、一時的であることもある。そのため、迂回が必要かの判断をするためには、こ




図1 Bayesian Attractor Model の概要

のようなノイズを含んだ予兆をもとに、各時刻の状況を判断することが必要となる。

我々は、これまでノイズを含んだ情報をつかう手法として、人の脳の認知のしくみにもとづく手法を提案してきた [3]。この手法は、脳の認知モデルの一つである Bayesian Attractor Model にもとづいている。Bayesian Attractor Model 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、これまで Bayesian Attractor Model にもとづく状況判断を、ネットワーク資源の割当制御に適用してきた。そして、Bayesian Attractor Model にもとづいた状況判断により、将来起こりうる資源不足のリスクを把握し、必要な資源割り当てを前もって行うという制御が可能であることを示してきた。

本稿では、Bayesian Attractor Model にもとづく状況判断を、交通流制御に適用する。特に、リアルタイムに把握された情報に基づき、渋滞を避けるような経路を提案する機構に、Bayesian Attractor Model にもとづく手法を適用する。これにより、各時刻に得られる渋滞の予兆が不確かであっても、各時刻で渋滞が発生しそうな状況であるのかを判断し、判断結果にもとづいて渋滞を避ける経路の提案を行う。

2. Bayesian Attractor Model

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 [4]。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 抽象化

本モデルでは、新たな観測が得られる度に、観測情報を抽象化する。抽象化された観測情報は以後、 X_t と表す。

2.2 認知状態の更新

Bayesian Attractor Model 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。

2.3 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 ではなく、 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. Bayesian Attractor Model にもとづく車両への経路提案

3.1 概要

本節では、自動車に対して、経路を提案することにより交通流を制御するというアプリケーションを想定する。本アプリケーションでは、自動車に経路を提案するコントローラを導入する。本コントローラは、定期的に各レーン上の車両台数といった情報を道路上のセンサやプローブカー等から収集する。そして、収集した情報をもとに、コントローラは、一定時間以内に混雑する可能性のある地点を予測する。もし、混雑する可能性のある地点が存在すれば、コントローラは、当該地点を迂回するような経路を車両に対して提案する。本システムにおいて、収集した現在の道路上の車両台数は、将来の混雑箇所を予測するのに有用な情報である。例えば、ある地点の車両台数が一定以上になった場合、近隣の別の地点における車両台数もその後増加する可能性が高く、将来の渋滞の予兆として考えることができる。しかしながら、各地点の車両台数は一時的に増加するということも多々ある。すなわち、各道路上で観測された車両台数は、将来起きうる渋滞のサインとしては、ノイズの大きな情報となる。そのため、Bayesian Attractor Model にもとづく制御を適用する。Bayesian Attractor Model にもとづく制御を適用することにより、各時刻に得られる情報にノイズが含まれていた場合であっても、得られた情報をもとにした認知状態の更新を逐次行うことにより、適切な認知を行う手法である。その

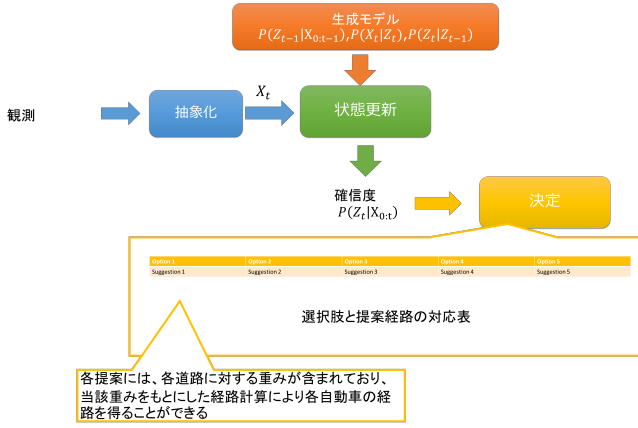


図2 Bayesian Attractor Model にもとづく経路提案の概要

ため、本手法を用いることにより、各道路上で観測された車両台数といった渋滞の予兆としては不正確な情報を用いた場合であっても、適切な認知が可能となる。

図2に、Bayesian Attractor Model にもとづく経路提案の概要を示す。Bayesian Attractor Model にもとづく経路提案手法では、まず、意思決定における選択肢を定める必要がある。本手法においては、以前に観測された観測値をもとに選択肢を定める。また、選択肢に加えて、各選択肢に対応する経路提案のための情報についても保存する。本手法では、経路提案のための情報として、各道路に対する重みを保持する。この重みを用い、最短経路問題を解くことにより、各車両は自身に適した経路を計算することができる。Bayesian Attractor Model にもとづく予測型経路提案手法は、以下のように動作する。コントローラは定期的に、交通情報し、それを抽象化し、 X_t を得る。を用いて認知状態 Z_t を更新する。そして、現在の確信度にもとづいて、提案する経路情報を決定する。

3.2 選択肢と選択肢に対応する経路の定め方

選択肢と各選択肢に対応する経路提案のための情報は以下のように定める。観測情報に含まれる時刻 t の集合を T^{monitor} とし、時刻 t における観測値ベクトルをとする。コントローラの認知対象の選択肢は、 O_t (ただし、 $t \in T^{\text{monitor}}$) をもとに以下のように定義する。まず、 O_t を最大値、最小値がそれぞれ 1、-1 になるように、以下のように正規化する。

$$\frac{2(o_{i,t} - \min_t o_{i,t})}{\max_t o_{i,t} - \min_t o_{i,t}} - 1 \quad (3)$$

ただし、 $o'_{i,t}$ は O_t を正規化したベクトル O'_t の i 番目の特徴量であり、 $o_{i,t}$ は O_t の i 番目の特徴量である。そして、 O'_t の集合を各クラスタに類似した観測が含まれるように、複数のクラスタに分割する。この各クラスタを各選択肢とする。つまり、コントローラは、現在の状況が属するクラスタを決定することにより、現在の状況を認知する。このクラスタの分割には、任意のクラスタリング手法を用いることができるが、本検証では、K-means++手法を用いた。その後、各選択肢に対して、経路提案のための情報を定める。本検証では、混雑する可能性のある箇所を迂回するような経路を提案する。そのような経路を提案するために、各コントローラは、各選択肢に対して、各道の重みの集合を経路提案のための情報として保持する。この重みを定める際には、混雑する可能性のある道については、大きな重

みを設定する。これにより、各車両は、混雑しそうな箇所を迂回した経路は最短経路問題を解くことにより求めることができる。本検証では、 j 番目の選択肢における、道に対する重みは以下のように定める。

$$W_{i,j} = \frac{L_i}{S_{i,j}^{\min}} \quad (4)$$

ただし、 L_i は道 i の長さ、 $S_{i,j}^{\min}$ は j 番目の選択肢に対応するクラスタに含まれる各データについて、道 i 上の車両の、その観測後 p 分間の平均速度を計算し、さらにその平均値である。これにより、混雑し、その観測後分間の平均速度が遅くなるような道に対して、混雑する可能性がある道としては、大きな重みを設定することが可能となる。

3.3 抽象化

コントローラは、新しい観測値 O_t が得られる度に、抽象化した行列 X_t を得る。本検証では、上述の正規化を行ったベクトルを観測値とする。すなわち $X_t = O'_t$ とする。

3.4 更新

コントローラは、 X_t が得られる度に、ベイズ推定により、Bayesian Attractor Model における生成モデルを逆推定することにより、認知状態 Z_t を更新する。

本稿では、文献 [4] と同じ生成モデルを用いる。すなわち、意思決定状態 Z_t と観測 X_t の生成モデルとして、以下のモデルを用いる。

$$Z_t - Z_{t-\Delta t} = \Delta t f(Z_{t-\Delta t}) + \sqrt{\Delta t} w_t \quad (5)$$

$$X_t = M\sigma(Z_t) + v_t, \quad (6)$$

ただし、 $f(z)$ はホップフィールドダイナミクスを表し、 w_t と v_t は、正規乱数、 $\sigma(x)$ はシグモイド関数である。また、 M の i 番目の要素は、 i 番目のクラスタの観測値の平均とする。

3.5 決定

上記の状態更新により、確信度 $P(Z_t|X_{t:0})$ が得られる。本稿では、経路提案の際には、各選択肢に対して、対応する各道に対する重みと確信度の組みが車両に提示されるものとする。車両は、確信度により重みづけられた確率で、経路を選択する。これにより、特定の状況の確信度が高い場合は、その状況に合わせた経路を選択し、同程度確信度が高い経路が複数存在する場合には、その確信度が高い状況の中からランダムに選択した経路を選ぶことができる。

4. 評価

4.1 評価環境

本評価では、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 を用いたシミュレーションを行った。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。

本評価においては、以下の比較により、Bayesian Attractor Model にもとづく経路提案の有効性を示す。




図3 格子状道路網

Bayesian Attractor Model にもとづく経路提案

上述の Bayesian Attractor Model にもとづく経路提案を行った場合。本評価においては、各道の車両台数を 30 秒に一回収集し、状況を認知、認知した状況に合わせて経路提案を行う。なお、Bayesian Attractor Model にもとづく経路提案を行うためには、事前に認知の選択肢を定める必要があるが、本検証では、事前に、正常時 10 回、途中から特定の交差点の流れが悪くなる場合 10 回の計 20 回、1 時間分のシミュレーション結果を選択肢を定める際の学習用データとして用いた

最近傍データを用いた経路提案

Bayesian Attractor Model にもとづく経路提案の有用性を示すために、全く同じ観測情報、学習結果を用い、各時刻において、学習した選択肢から最も近い選択肢を選ぶという手法を比較対象として用いた。本手法と Bayesian Attractor Model にもとづく経路提案の違いは、Bayesian Attractor Model にもとづく経路提案では、各時刻の観測値をもとに、認知状態を更新することを繰り返すことにより、現在の状況を認知して経路提案をするのに対して、本手法は、各時刻で観測された情報のみから状況判断をする。そのため、本手法と比較することにより、認知状態の更新を繰り返す、Bayesian Attractor Model にもとづく経路提案の有用性を示すことができる。

最短距離の経路を選択した場合

全車両が始点・終点間の最短距離となる経路を選択した場合。この結果との比較により、経路提案がなければ、混雑が発生することを確認できる。また、本評価においては、いずれの経路提案手法においても、経路提案に従う車両は半数のみであり、残りの車両は最短距離経路を選択するものとする。

4.2 結果

本評価では、交通状況の変化に対応して、提案する経路を変化させることができているかについて、まず、確認する。本評価では、認知対象の選択肢の数を 10 と指定して、選択肢と各選択肢に対応する経路を学習させた。その結果、8 個の選択肢については、混雑が発生せず、最短距離の経路を選択すればよい状況に対応し、残り 2 つの選択肢は、車両の流れが悪くなった交差点の周囲で混雑が発生し、当該交差点を迂回する経路を選択する状況に対応した。そこで、図 4 に、評価開始後 34 ステップ経過後に、特定の交差点の流れを悪化させた場合において、Bayesian Attractor Model にもとづく経路提案の場合について、混雑した状況に対応する 2 つの選択肢に対する確信度と、それ以外の選択肢に対する確信度の合計の時間変動について、確

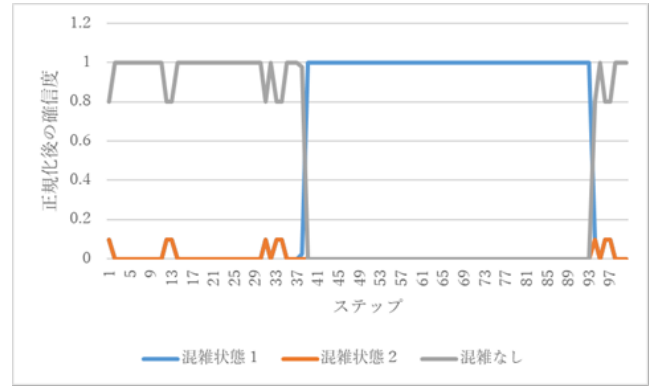


図4 Bayesian Attractor Model における確信度の時間変化

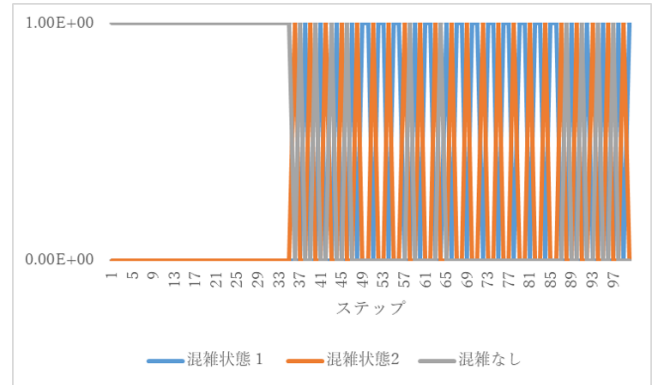


図5 最近傍データを用いた経路提案によって選択された状態

信度の合計が 1 となるように正規化して示す。同様に、最近傍データを用いた経路提案においても、各ステップにおいて選択された状態が 1 となる形で、各ステップにおいて選択された状態を図 5 に示す。これより、Bayesian Attractor Model にもとづく経路提案では、特定交差点の流れが悪くなってから 5 ステップで、その後発生する混雑の予兆をとらえ、混雑状態 1 の確信度が高くなり、それ以降、混雑状態 1 が選択され続ける。それに対して、最近傍データを用いた経路提案では、混雑状態が選択され続けることなく、交差点の流れが悪くなって以降も、混雑なしの状態も頻繁に選択され、選択される状態が安定しない。これは、観測される各道上の車両台数が時々刻々変化し、交差点の流れが悪くなり、その後、混雑が発生しそうな状態であっても、一時的に車両台数が減った際に、混雑が発生しない選択肢の観測値に近い観測値が得られ、混雑しない状況だと認識される。これらの結果より、各時刻において、観測される各道の車両台数は変動が大きく、観測情報をそのまま用いると、安定した状況判断を行うことは困難であるが、Bayesian Attractor Model にもとづく認知を行うことにより、そのような情報を用いた場合でも、混雑しそうな状態を安定して認知することが可能となる。

図 6 に、各手法で経路提案を行った場合に、直前 5 分間の平均速度が 1m/s 以下となった車両の台数の時間変化を示す。図 3-1-39 より、最短距離経路を選択し続けると、直前 5 分間の平均速度が 1m/s 以下となる低速な車両の台数は、時間経過とともに増え、流れが悪くなった交差点を起点とした渋滞が拡大することがわかる。それに対して、経路提案をすることにより、経路提案を受け入れる車両が半分であっても、低速な車両の台数




図6 各時刻における低速な車両数

表1 低速な車両が存在するタイムスロット数

	低速な車両が存在するタイムスロット数
Bayesian Attractor Model にもとづく経路提案	0
最近傍データにもとづく経路提案	21
最短距離	243

を大幅に減らすことができる。これは、車両の流れが悪くなった交差点を経由する車両が減ったことにより、当該交差点を経由する車両に対しても、交差点を通過するのにかかる時間が短くなるためである。また、Bayesian Attractor Model にもとづく経路提案は、低速な車両数は常に0であるのに対して、最近傍データにもとづく経路提案では、最大で、7台の車両の速度が1m/s以下となっている時間帯が存在する。これは、上述のように、最近傍データにもとづく経路提案では、交差点の流れが悪くなって以降であっても、混雑なしと認識されることが多々あり、当該交差点を経由する車両数を十分に削減できないことが原因である。

本評価では、上述のような、経路提案を含めたシミュレーションを、生成する交通流を変えて10回、各回1時間行った。そして、各タイムスロットにおいて、直前5分間の平均速度が1m/s以下の低速な車両の有無を調べた。表1に、全10回のシミュレーションのうち、低速な車両が存在したタイムスロット数を示す。表より、全10回のシミュレーションにおいて、最近傍データにもとづく経路提案においても、低速な車両が発生するタイムスロットが存在するにもかかわらず、Bayesian Attractor Model にもとづく経路提案では、一度も低速な車両が発生することはなかったことがわかる。すなわち、観測される情報の変動が大きい場合であっても、Bayesian Attractor Model による状態の認知により、変化に追随しつつ、安定した状況判断を行うことができ、混雑を解消することができている。

本検証では、経路提案のために得られる観測データとして、各道路上の車両数のみが得られるものとして、経路提案手法の有効性について検証した。混雑が発生しそうな状況なのか否かという、経路提案のために本来認知しなければならない状況の変化よりも、各道路上の車両数の変動は激しく、状況判断を行うには、ノイズの大きな情報となっているが、Bayesian Attractor Model にもとづく経路提案では、そのようなノイズの

大きな情報を入力とした場合でも、適切に状況を判断することができることを示している。本検証では、簡単のため、観測できる情報は各道路上の車両数のみとしたが、経路提案をするための観測情報としては、自動車の速度やコネクティッドカーから収集した情報など、他の情報も考えられる。そのような他の情報を用いた場合であっても、その観測情報の変化が激しい場合や観測情報にノイズが含まれる場合には、本検証と同様、Bayesian Attractor Model にもとづく認知が有効であり、Bayesian Attractor Model にもとづく認知によって、適切な状況判断が可能となると考えられる。

5. まとめ

本稿では、Bayesian Attractor Model にもとづく状況判断を、交通流制御に適用する。特に、リアルタイムに把握された情報に基づき、渋滞を避けるような経路を提案する機構に、Bayesian Attractor Model にもとづく手法を適用した。これにより、各時刻に得られる渋滞の予兆が不確かであっても、各時刻で渋滞が発生しそうな状況であるのかを判断し、判断結果にもとづいて渋滞を避ける経路の提案を行う。

本稿では、シミュレーションにより、提案手法による経路提案と、最近傍データを用いた経路提案を行った場合、常に最短移動距離の経路を選択した場合について比較を行った。その結果、提案手法で経路提案を行うことにより、混雑を解消するような経路が提案できていること、さらに、学習データ内から最近傍のデータと比較する手法と比べ、安定した判断を行うことができ、頻繁な提案経路の変更も防ぐことができることが分かった。

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] M. Mariem, and T. Taleb. "A Dynamic Map-based Framework for Real-Time Mapping of Vehicles and their Surroundings," in Proceedings of IEEE Wireless Communications and Networking Conference (WCNC), Apr. 2019.
- [2] N. Ranjan, S. Bhandari, H. P. Zhao, H. Kim, and P. Khan, "City-Wide Traffic Congestion Prediction Based on CNN, LSTM and Transpose CNN," IEEE Access, Vol. 8, Apr. 2020.
- [3] 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 ICTC, Oct. 2019.
- [4]] S. Bitzer, J. Bruineberg, and S. J. Kiebel, "A Bayesian Attractor Model for Perceptual Decision Making," PLoS Comput Biol, vol. 11, no. 8, 2015.
- [5] D. Arthur, and S. Vassilvitskii, "k-means++: The advantages of careful seeding," Technical Report, Stanford University, 2006.
- [6] D. Krajzewicz, "Traffic simulation with SUMO—simulation of urban mobility," Fundamentals of traffic simulation, Springer, 2010. .