

脳の認知機能モデルを用いた交通流センシング情報に基づく ネットワーク内資源配分制御の評価

安 世民[†] 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: †{s-an,y-ohsita,murata}@ist.osaka-u.ac.jp

あらまし 各サービスが要求する品質を満たすように、各サービスのトラフィックを収容することがネットワークには求められている。ネットワークが要求する品質はサービスにより多種多様であるため、サービスに合わせてネットワークをスライスに分割する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。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て時々刻々変化するため、状況に合わせて資源不足をさけるように動的に資源割当制御を行うことが必要となる。動的な資源割当制御のためには、資源不足のリスクを把握する必要がある。資源不足のリスクの把握には、現在ネットワーク内を流れているトラフィック量のみではなく、現実世界の情報を用いることが有効であると考えられる。ただし、現実世界と将来のトラフィック量との関係はモデル化が困難であり、各時刻に得られた情報のみからの判断では誤った判断をしてしまうことも考えられる。この問題に対して、我々は、脳情報処理機構にもとづいて、将来の資源不足のリスクを把握し、制御を行う手法について検討を行っている。本稿では、コネクティッドカー向けのネットワークスライスに対して、交通流情報を活用した脳情報処理機構にもとづくネットワーク資源制御を適用し、評価を行う。評価の結果、交通流情報を用いることが、コネクティッドカー向けのネットワークスライスへの配分資源制御において有効であることを示す。

キーワード ネットワークスライシング, 交通流センシング, Bayesian Attractor Model, 資源配分

Evaluation of Network Resource Allocation Based on Monitored Traffic Condition inspired by the Cognitive Process of the Human Brain

Semin AN[†], Yuichi OHSITA[†], and Masayuki MURATA[†]

[†] Graduate School of Information Science and Technology 1-5 Yamadaoka, Suita, Osaka, 565-0871 Japan

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

Abstract Many kinds of services have been provided through networks. Traffic from such services should be accommodated so as to satisfy the requirements which depend on services. One approach to accommodating traffic so as to satisfy the various requirements is to use the network slicing, which provides multiple network slices for the network services. Resources for each slice should be dynamically allocated so as to follow the traffic changes. Because the real-world condition has a large impact on traffic changes, real-world information is useful to predict future traffic. However, the relationship between real-world information and future traffic is difficult to model. Therefore, we have proposed a method to handle real-world information to predict future traffic and dynamically control the resources inspired by the human brain's cognition process. In this paper, we apply the method to the controller of network slices for the connected car. We demonstrate that the transportation traffic information is useful to the resource allocation in the network slice for the connected car.

Key words Network Slicing, Traffic Flow Sensing, Bayesian Attractor Model, Resource Management

1. ま え が き

ネットワークには、各サービスの要求する品質を満たすようにネットワーク資源を配分して、発生するトラヒックを収容することが求められる。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。このネットワークスライスを各サービスに対して構築することにより、各サービスに応じた仮想的なネットワークを柔軟に構成し、運用することが可能となる。

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。各スライスを流れるトラヒック量は時々刻々変化し、当初割り当てた資源では十分にトラヒックを収容することができなくなったネットワークスライスでは、必要な通信品質を維持することができなくなる。このような品質劣化を防ぐためには、資源不足が発生するリスクを把握し、資源不足が発生しないようにネットワークスライスに割り当てる資源を動的に変更することが求められる。資源不足のリスクを把握するためには、トラヒック量を予測することが重要であり、これまで過去に観測されたトラヒック量から将来のトラヒック量を予測する研究が進められてきた [3]~[9]。しかし、資源不足のリスクを把握するためには、現在ネットワーク内を流れているトラヒック量のみではなく、現実世界の情報を用いることが有効であると考えられる。しかしながら、実世界情報を含む、観測情報と将来とのトラヒック量との関係は一般的にモデル化が困難である。そのため、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ヒックに合わせてネットワークを制御するためには、このような各時刻に得られた情報による判断が不正確であることを考慮することが必要となる。

この問題に対して、我々は、脳情報処理機構にもとづくネットワーク制御手法を提案している [10]。この手法は、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のモデルの一つに、Bayesian Attractor Model (BAM) [9] にもとづいたものである。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 個の選択肢に対応した状態値 ϕ_1, \dots, ϕ_S 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、この BAM をネットワーク制御に適用することにより、曖昧かつ部分的な情報をもとにネットワーク制御を行う手法について検討を進めている。

本稿では、脳情報処理機構にもとづくネットワーク制御手法を、コネクティッドカー向けのネットワークスライスへの資源割当制御に適用する。コネクティッドカー向けのサービスを提供しているネットワークスライスでは、各エリアに存在する自動車の台数により、必要となる資源量は大きく異なる。自動車が多い時間帯は、多くのネットワーク資源を必要とし、自動車が少ない時間帯には必要とするネットワーク資源も少ない。しかしながら、自動車の場合、各自動車の移動速度が人の移動と比べ速いため状況の変化も激しい。特に事故などが発生した場合には、事故が原因とした渋滞が発生するなど、エリア内に滞在する自動車の台数が大きく変化する。コネクティッドカー向けのサービスを収容するネットワークスライスでは、このような急激な状況に変化に対しても、資源が不足することを防ぐことが必用となる。このような制御を行うにあたり、交通流情報は有用な情報となる。交通流情報を用いることにより、事故等により発生する渋滞を初期段階で認識し、その後の資源不足のリスクを把握し、早めにスライスの資源を増強することができると思われる。

以降、本稿では 2 節で脳情報処理機構のモデルである Bayesian Attractor Model について説明し、3 節で脳情報処理機構にもとづく交通流情報を利用したネットワーク資源割当手法について述べ、4 節で評価について述べる。最後に 5 節でまとめと今後の課題について述べる。

2. Bayesian Attractor Model (BAM)

Bayesian Attractor Model [9] は、脳の認知機能のモデルの一つであり、観測情報を入力とし、与えられた意思決定状態から一つを選ぶ意思決定モデルである。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 に基づいて意思決定状態 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呼ぶ) 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、 $z_t = \phi_i$ となったとき、 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、およ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。

z_t の更新は、生成モデルをもとに行われる。文献 [9] では、以下の式で生成モデルを構成している。

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

$$x_t = M\sigma(z_t) + v_t \quad (2)$$

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、近似計算を行う必要がある。論文 [9] の近似計算では Unscented Kalman Filter(UKF) [11] を用いているが、UKF は非線形性、非ガウス性が強く表れた観測情報を入力として与えた際に、正しく状態を推定できないことが多い [12]。そこで本稿では、UKF の代わりとして、非線形、非ガウス状態空間モデルを処理することが可能な Particle Filter(PF) を用いた近似計算を行う。

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。

我々は、Bayesian Attractor Model にもとづいた状況認知により、現実世界のセンシングデータ、トラヒック量の観測情報の両方を用いて、将来発生する資源不足のリスクを把握する手法に関する検討を進めている。文献 [10] では、Bayesian Attractor Model にもとづいた状況認知を、モバイルネットワークにおける特定のエリアから流入するトラヒック量が増加するリスクを事前に把握・資源割当制御へ適用した。本稿では、各時刻で観測可能な情報とその後発生する予測対象エリアのトラヒック量について事前に取得した情報をもとに、認知対象となる選択肢と、その選択肢に対応する将来の発生トラヒック量の対応をあらかじめつけておく。そして、実際に制御する際には、各時刻で取得できる観測情報をもとに、現在の状況がいずれの選択肢に合致しているのかを認知することにより、将来のトラヒック量増加のリスクを把握し、制御に用いる。これにより、各時刻において得られる観測情報と将来のトラヒック量との関係を正確にモデル化できない場合であっても、各時刻に観測された情報をもとに、逐次状態を判断し、制御に用いることができる。

3. 交通流センシングを用いた脳情報処理機構にもとづく資源配分手法

3.1 概要

本稿では、コネクティッドカー向けのネットワークスライス向けの資源配分手法について検討する。コネクティッドカー向けのネットワークスライスでは、各エリアにおいて必要とされるネットワーク資源は、各エリアに滞在する自動車の台数の影響を大きく受ける。自動車が多い時間帯は、多くのネットワーク資源を必要とし、自動車が少ない時間帯には必要とするネットワーク資源も少ない。しかしながら、自動車の場合、各自動車の移動速度が人の移動と比べ速いため状況の変化も激しい。特に事故などが発生した場合には、事故が原因とした渋滞が発生するなど、エリア内に滞在する自動車の台数が大きく変化する。トラヒックが変動すると、当初割り当てていた資源量では十分なサービス品質を維持できなくなる恐れがある。サービス品質の低下を回避するために大量の資源をあらかじめ配分しておくことも考える。しかし、この方法では、電力コストの増大

や他のエリアへ割り当て可能な資源が不足するなどの問題がある。そのため、大量の資源を割り当ててではなく、現在の状況に応じた資源を割り当てることが望ましい。

コネクティッドカー向けのネットワークスライス向けの資源配分においては、このような制御を行うにあたり、交通流情報は有用な情報となる。交通流情報を用いることにより、事故等により発生する渋滞を初期段階で認識し、その後の資源不足のリスクを把握し、早めにスライスの資源を增強することができると考えられる。そこで、本稿では、適切な配分資源を決定する際には、各エリアにおいて発生するトラヒック量や各エリアの車両台数のみならず、交通流センシング情報も観測情報として与える。以降、本手法で用いる交通流センシング情報、脳情報処理機構にもとづく状態認知の方法、および認知結果に基づく資源配分について述べる。

3.2 交通流センシング情報

コネクティッドカー向けのネットワークスライス向けの資源配分においては、交通流センシング情報は将来のトラヒック状況を予測するのに有用な情報となる。特に渋滞の初期段階を把握するのに有用な情報であれば、その後の渋滞と、それによるコネクティッドカーからのトラヒック量の増大を予測することができる。

本稿では、上述のような状況把握をすることができる情報として、主要幹線道路において、ある地点に滞在する自動車の台数を用いる。この自動車の台数が増加し始めると、当該地点において渋滞が始まったということを認識することができ、その後、当該道路で発生した渋滞が他の道にも波及することが予想できる。

3.3 脳の認知機能モデルによる状態認知

本稿では、観測情報を用いて状態認知を行い、将来のトラヒック量を予測する。本稿では、認知より以前に得られている観測情報により認知可能な状態を定義し、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、この状態認知に脳の認知機能モデル BAM を適用する。BAM では、典型的な認知状態をアトラクターとして保持し、各アトラクターに対応する観測値を学習させておく。そして、観測情報を取得する度に各アトラクターの状態を更新する。本節では、BAM を提案手法における状態認知に用いるため、認知に必要な観測情報および認知対象の状態、BAM の適用方法について述べる。

3.3.1 観測情報

今回は以下の3つの情報を観測情報として与える。

- 各エリアの発生トラヒック量
- 各エリアの車両台数
- センサを配置した各道路における車両台数

3.3.2 認知対象と観測情報の対応付け

本稿の制御では、各時刻において、現在から p タイムスロット先までに発生するトラヒック量のうち、もっとも大きな値を収容できるような資源を配分することを目標とする。これによ

り、資源割当の要求から実際に資源が割り当てられるまで p タイムスロットかかる場合であっても、事前に資源の割当を行うことができ、資源不足を解消することが可能となる。

ここで、観測情報が類似している状態は、 p タイムスロット後の発生トラフィック量が近い値になると考えられる。そこで本稿では、過去に得られた観測情報を基に、観測情報を類似の観測情報を持つ事象を集めた k 個のクラスタ 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、その時の状態が、いずれのクラスタのどれに属する状態なのかを認知することとした。これにより、現在の状態がクラスタ C_n と認知した場合は、過去に得られた観測情報を基に、クラスタ 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フィック量を調べ、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トラフィック損失を回避できるほどの資源量を得ることができる。

3.4 認知結果に基づく資源配分

本稿では、あらかじめ、各クラスタに対応する割り当てが必要な資源量を保持しておく。そして、認知の結果、最も高い事後確率 $P(z_t|x_t)$ となった状態をその時の認知結果とし、その状態に対応する資源を要求する。

4. 評価

4.1 評価手法

4.1.1 データ生成

本評価のためには、自動車の移動軌跡と、それに伴う各エリアにおける発生トラフィック量のデータを用いる必要がある。しかし、そのような交通流とトラフィック量の実測データは公開されていない。そこで本稿では、首都圏を中心に交通流を擬似的に生成したデータである、Open PFLOW [13] の情報を用いつつ、道路交通シミュレータである、SUMO(Simulation of Urban MObility) [14] を用いて、通常時、事故発生時の交通流を生成した。具体的には、OpenStreetMap を用いて実際の道路網情報を生成し、Open PFLOW に記載の各時刻の自動車の位置座標をもとに、観測エリアへの流入時刻、始点と終点を指定し、交通流を生成した。ただし、Open PFLOW の情報は、実際の交通流より少ないサンプリングされた情報である。そこで、本稿では、各始点・終点から流入する自動車数に倍数をかけた。また、この倍数を乱数として生成することにより、様々なパターンの交通流を生成した。本評価においては、事故が発生時について6パターン、事故が発生していない状況について5パターンのデータを取得した。

また、各自動車生成するトラフィック量は一定であるとした。本評価の具体的な評価データの生成環境を表1に載せる。こ

表1 評価環境

評価時間	平日の午前8時30分–午前9時30分
事故発生時刻	平日の午前9時00分
観測エリア	新宿大ガードを中心とする約5平方キロ(図1)
交通規制地点	青梅街道架道橋(新宿大ガード)

の環境下における各エリアの発生トラフィック量を図2、各エリ

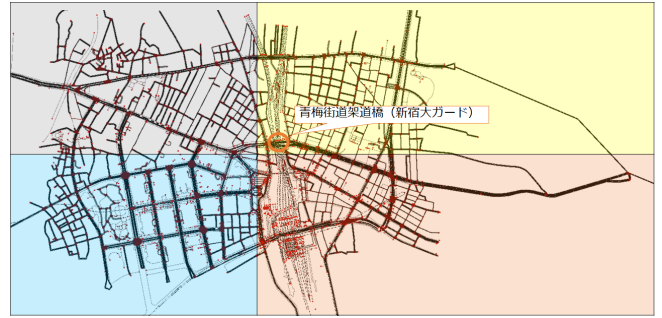


図1 観測エリア区分

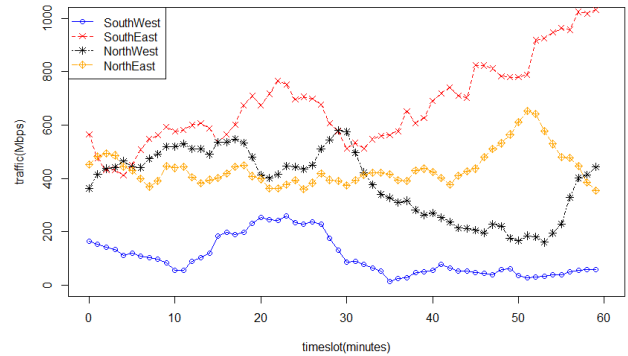


図2 各エリアの発生トラフィック量




図3 各エリアの車両台数

アの車両台数を図3に載せる。

4.1.2 パラメータ設定

本稿では、脳情報処理機構にもとづく状態認知を行っている。本評価においては、sensory uncertainty を 0.30、dynamic uncertainty を 0.20 に指定し、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、その他パラメータは [9] と同じ値に設定している。

4.1.3 比較対象

本稿では、コネクティッドカー向けのネットワークスライスへの資源配分を行う際の、状態認知における交通流センシング情報の効果を評価する。そのため本稿では、状況を認知し、必要資源量を予測する際に、交通流センシング情報を用いた場合 (With-Sensing information) と用いない場合 (Without-Sensing information) を比較する。いずれの手法においても、

我々が提案する脳情報処理機構にもとづくネットワーク制御を適用し、発生させたトラフィックパターンのうち、10パターンの情報を蓄積し、残りの1パターン（事故発生時）を用いて、評価を行った。

4.2 評価結果

資源配分の際には、資源不足によるトラフィック損失を回避するため、将来の発生トラフィック量を収容できる十分な資源を割り当てることが有効である。これにより、渋滞などによる突発的なトラフィック変動が発生した場合もトラフィック損失を回避できる。一方で、始めから大量の資源を配分しておくことでトラフィック損失の回避を図ることもできる。しかしこの方法は大量の資源確保にかかるコストが膨大になることや、資源は有限であるということから適切ではないと言える。本稿では、観測エリア内で発生したトラフィック量と、その時の配分資源量を比較し、常に配分資源量がトラフィック量を上回りつつ、かつ少ない配分資源量を達成できているかどうかを評価する。

シミュレーション結果を図4,5,6,7に載せる。図の横軸はタイムスロットを表しており、評価開始時刻（タイムスロット=0）は午前8:30である。図の縦軸はその時刻における配分資源量および発生トラフィック量を示しており、単位はMbpsである。

本稿で用いた手法は、いずれの手法も、類似の観測情報が得られる条件下のうち、 p タイムスロット先の必要資源が最も多かった場合を基準に資源の割当を行う。その結果、いずれの手法においても、資源不足を防いだ、安全側の資源割当を行うことができています。そのため、図において、With-Sensing information、Without-Sensing information のいずれの手法であっても、資源不足を発生させることはなく、十分な資源を割り当てることができています。

図より、With-Sensing information が、Without-Sensing information よりも少ない配分資源量でトラフィックを収容できていることが分かる。これは、With-Sensing information では、交通流センシング情報を用いることにより、渋滞の初期段階を把握することができ、その後 p タイムスロット以内に必要資源が増加するか否かを正しく判断することができるためである。これにより、交通流センシング情報を与えることで、将来の状態の認知精度が向上し、効率的な資源配分を達成できる。

5. ま と め

本稿では、コネクティッドカー向けのネットワークスライスに対して、交通流情報を活用した脳情報処理機構にもとづくネットワーク資源制御を適用し、評価を行った。評価の結果、交通流情報を用いることが、コネクティッドカー向けのネットワークスライスへの配分資源制御において有効であることを示した。今後は、各センサからの情報のうち一部が欠損するといった状況など、様々な状況を想定して評価を行う予定である。

謝辞

本研究の成果の一部は、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。

- [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] L. Lu and C. Lianglun, "Network traffic prediction model based on optimizing SVM with improved cuckoo search algorithm," *Computer Applications and Software*, vol. 1, p. 033, 2015.
- [4] G. Rutka, "Neural network models for Internet traffic prediction," *Elektronika ir Elektrotechnika*, vol. 68, no. 4, pp. 55–58, 2015.
- [5] G. Rutka and G. Lauks, "Study on internet traffic prediction models," *Elektronika ir Elektrotechnika*, vol. 78, no. 6, pp. 47–50, 2015.
- [6] C. Daly, "Novel h. 265 video traffic prediction models using artificial neural networks," 2015.
- [7] W. Lu, "Parameters of Network Traffic Prediction Model Jointly Optimized by Genetic Algorithm," *JNW*, vol. 9, no. 3, pp. 695–702, 2014.
- [8] 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.
- [9] 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
- [10] 佐竹幸大, 大下裕一, 村田正幸 "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" 電子情報通信学会 IN2017-93 pp. 21-26, 2018
- [11] 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
- [12] 矢野浩一 "粒子フィルタの基礎と応用：フィルタ・平滑化・パラメータ推定" 日本統計学会誌 vol.44 no.1 pp. 189-216, 2014
- [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] D. Krajzewicz, "Traffic Simulation with SUMO - Simulation of Urban Mobility" . In: *Fundamentals of Traffic Simulation International Series in Operations Research and Management Science*, Springer. Seiten 269-294, ISBN 978-1-4419-6141-9, ISSN 0884-8289, 2010
- [15] Jamal Jokar Arsanjani, Alexander Zipf, Peter Mooney, Marco Helbich, "An Introduction to OpenStreetMap in Geographic Information Science: Experiences, Research, and Applications" , ISSN 1863-2246, 2015




図 4 左上エリア




図 5 右上エリア




図 6 左下エリア

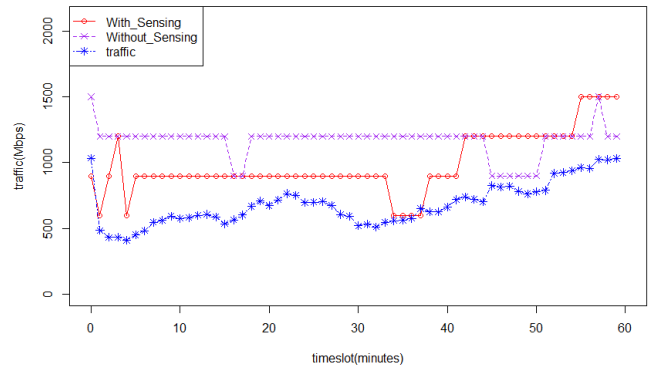


図 7 右下エリア