ドライバの行動決定モデルに基づく交通流シミュレーションに関する研究

非会員 佐川 大介* 非会員 佐川 雄二*
正 員 杉江 昇*

Traffic Flow Simulation Based on Driver's Model of Decision Making

Daisuke Sagawa*, Non-member, Yuji Sagawa*, Non-member, Noboru Sugie*, Member

In this paper, we introduce a new model for driver's route selection. In the model, a driver can decide a route before driving but may change it dynamically while driving. To decide the route before driving, the driver can use a Q-value map that is a result of reinforcement learning from the road information. Experience of driving the route and information offered from outside (e.g. via car navigation system) can make a driver change the route while driving. From the result of evaluation experiments with a traffic data of real world, the traffic flow simulator with the model works in more than 90% accuracy. To show how the model can process information from outside, we carry simple experiment in which a navigation system tells a driver the fastest route in the course of driving. The simulator produce some reasonable result.

キーワード: 高度交通システム(ITS), マルチエージェント, 経路誘導, 意思決定, 経路選択行動, 強化学習, 走行経験, 通過時間予測, 情報提供

Keywords: intelligent transport system(ITS), multi-agents, course inducement, decision making, routing action, reinforcement learning, running experience, travel time forecast, information offering

1. はじめに

近年, 高度交通システム(ITS)の発展とともに, ナビゲーションシステムの高度化が進んでいる。これによりさまざまな情報をドライバに与えることが可能になる。中でも注目されているのが, 適切な道路および交通情報を与えることにより, 慢性的な問題となっている交通渋滞を緩和できるのではないかという期待である。

情報提供により交通渋滞を緩和するには, どのような情報をどのタイミングで提供するかが重要であり, 今後様々な情報提供方法を検討する必要がある。しかし, その際問題となるのは, 提案された情報提供方法の評価を実際の道路を使って行うことが, 安全面や社会的容認可能性から困難である点である。

そこで, 現実の道路網における交通流を, 計算機上で正確にシミュレートできるシステムが望まれる。しかし, 上記のような目的に使用するには, 単に定常的な交通流をシ

ミュレートできるだけでは不十分である。それに加えて, ドライバが状況(外部からの情報も含む)に応じて経路を変更する点を考慮することで, シミュレーション結果が動的に変化する枠組みになっている必要がある。すなわち, ドライバの経路選択行動のモデルが, シミュレータに組み込まれている必要がある。

従来の研究には, 不確実性⁽¹⁾やニューラルネットワーク⁽²⁾を用いてシミュレーション結果が動的に変化するものが存在するが, この場合外部からの情報という要素を直接組み込むことはできず, 前述したような目的には使用できない。また, ドライバの意識調査結果から行動分析を行い, その結果を経路選択モデルに使用する研究⁽³⁾もあるが, 特定の道路網, ドライバ層などに依存してしまう可能性もある。

本論文では, ドライバが経路を, あらかじめ走行前に計画したものから, 走行時に動的に変更することのできるモデルを提案する。モデルは走行前にあらかじめ経路を決定する部分と, 走行時に経路を変更する部分からなる。走行前に決定する際の情報に, 経路に関する強化学習結果を用いることで, 選択をより現実のドライバに近いものにすると同時に, 走行時の動的な経路変更を容易にモデル化する

* 名城大学理工学部
〒468-8502 愛知県名古屋市中区塩釜口 1-501
Faculty of science and Technology, Meijo University
1-501 Shiogamaguchi, Tempaku-ku, Nagoya 468-8502

ことが可能である。また、走行時に経路を変更できる機能を利用して、過去の走行経験を経路選択に反映することができ、より現実のドライバに近い経路選択が可能である。また、外部からの情報提供の効果をこの機能を使って実現できる。

本モデルを組み込んだ交通流シミュレータを作成し、その有効性を検証する。

2. ドライバの経路選択行動モデル

経路選択行動とは、走行中経路が複数に分岐する場所に差し掛かったとき、どの経路を選択するかを決定する行動である。

経路選択行動は大きく 2 つの部分に分けることができる⁽⁴⁾。実際に走行する前に経路を決定しておく走行前経路選択と、実際に走行中に経路をそこから変更する走行中経路選択である。外部からの情報提供による渋滞のコントロールは、この走行中経路選択を適切にコントロールすることにより行うことができると考えられるため、本モデルでもこの 2 つの部分に分けて考える。

なお、モデルの前提として、走行対象となる道路網のすべての経路長は既知であるとする。ただし、道路の幅や曲がり具合は考慮しない。すなわち図 1 のような地図が入力として与えられるものとする。

〈2・1〉 走行前経路選択行動 走行前経路選択行動は、いわばドライバが地図を見て経路を決定する行動に相当し、静的に決まっているものではあるが、ドライバの出発地、目的地によって変わってくるので、必ずしも同じ分岐点ですべてのドライバが同じ選択をするわけではない。また、単に出発地から目的地までの経路長だけでなく、混雑しそうかどうかでもないかも重要な要因である。

本研究では、走行前経路選択行動に際して、仮想のドライバ（実際のドライバと区別するため、学習ドライバと呼

ぶこととする）による強化学習の一つである Q-学習⁽⁵⁾の結果を使用する。各学習ドライバは出発地と目的地を与えられ、道路網内を走行し、経路を学習し、Q 値マップを作成する。Q 値マップとは、図 2 のように道路網中の各分岐点から伸びるリンクそれぞれに対して Q 値と呼ばれる値が付与されたものである。Q 値は分岐点から伸びる各経路につけられ、その分岐点で当該経路を選択した際の値を表す。したがって、一般的には一経路に 2 つの値が付与されるが、図 2 の分岐点 6 から 7 に延びる経路のように一方通行の場合には、片方の値しか付与されない。

Q 値は Q-学習で一般的に用いられる状態 s 、行動 a の行動評価関数 $Q(s,a)$ に対応する。すなわち、出発地、目的地、今いる分岐点とそれまでの経路が状態に対応し、次に選択するリンクが行動に対応する。なお、図 2 は、図 1 の道路網において、出発地 1、目的地 13 のある学習ドライバが獲得した Q 値マップである。

なお、学習に際して各学習ドライバは単独で行動するわけではなく、他の学習ドライバ（目的地が同じものも異なるものもいる）が混在する状態で行動する。

学習の過程で、 $Q(s,a)$ は式(1)のように更新される。

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [r_t + \gamma \max_{a'} Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)] - (time + crowd) \dots\dots\dots (1)$$

ここで、学習係数 α は 0.1 から 1.0 までの値を 0.1 間隔でガウス分布を満たすように各学習ドライバに設定する。割引率 γ は 0.5 とした。報酬 r は学習ドライバが目的地に到達しなかったとき -1 を与える。このため、学習される Q 値は図 2 のように負の値となる。

通常の Q 値更新法と異なるのは、time と crowd を含む項

図 1 モデルに入力される道路網情報
Fig. 1. Road Network input to the model.

図 2 Q 値マップ
Fig. 2. Q-value map.

である。予想経路通過時間 $time$ は経路長を理想平均時速 60km/h で割ったもの、混雑度 $crowd$ は経路内に同時に存在する学習ドライバの数である。これは $time$ と異なる次元の数であるが、混雑の度合いによって生じる遅れ時間と解釈されたい。

走行前経路選択の際の情報を単に経路長だけとするならば学習は必要ない。しかし、地図を見て経路を決定する場合でも、混雑しそうかそうでないかなどは、ドライバによって判断が微妙に異なる。学習結果を使用すれば、学習ドライバごとに学習結果は異なる可能性があるため、上記のようなばらつきを実現できる。

また、学習の中でも強化学習を用いる主な理由は 2 つある。第 1 に、各分岐点から分かれる個々のリンクに Q 値を与えることができるので、後段の走行中経路選択行動が Q 値の変更という形でできるからである。第 2 に、前述したように単に全体の経路長が最小であれば良いというわけではないので、完全な解が与えられないので、教師なし学習が適していると判断したためである。

走行前経路選択において、各ドライバは自分と出発地、目的地が同じ学習ドライバが獲得した Q 値マップのうちのいずれかをランダムに選択し、それに基づいて経路を決定する。図 2 の Q 値マップ（出発地 1，目的地 13）を用いた場合は、可能な経路の Q 値の合計は表 1 のようになるので、走行前経路選択の結果は、 $1 \rightarrow 3 \rightarrow 4 \rightarrow 7 \rightarrow 10 \rightarrow 13$ となる。

〈2・2〉 走行中経路選択行動 走行前経路選択行動で選択された経路は、地図のみを見て決定するのに近いので、ドライバごとに多少のばらつきはあるものの、実際のドライバの経路選択行動からみると均一的である。実際のドライバは、様々な情報に基づいて、走行中に経路を動的に変更しているため、実際のドライバの経路選択行動は、よりばらつきが大きくなる。

本モデルでは、走行中経路選択行動を実現するには、走行前経路選択において選択した Q 値マップ中の Q 値を、走行中に動的に変更することによって実現できる。

ここでは、ドライバが経路を動的に変更する原因として、過去の走行経験と外部からの情報の 2 つを取り上げ、具体的な Q 値の変更法について説明する。

〈2・2・1〉 走行経験に基づく経路選択 走行前経路選択行動で選択された経路は、経路の予想通過時間と混雑度を反映したものであるが、実際の通過時間を反映したものではない。これはあくまで地図を見て決定するという状況に近づけるためである。しかし、実際にその経路を通った経験のあるドライバであれば、そのときにかかった時間は

経路選択を大きく左右する。

そこで、実際の走行中、各分岐点でドライバは以下のように過去の走行経験に基づいて、分岐するリンクの Q 値を更新する。その結果経路が走行前に選択したものと異なってくることもある。

1. 分岐点に到達
 2. 到達分岐点を含んだ走行経路の候補を求める
 3. 走行経路の候補に関する走行経験を探索する
 4. 経験がある場合、それをもとに予測通過時間を決定する
 5. 経験がない場合、見込み通過時間を求め、予測通過時間とする
 6. 求めた予測通過時間をもとに、それぞれの経路候補に対する選択確率を求める
 7. 求めた選択確率をもとに、 Q 値を更新する
- 以下、4以降の処理について述べる。

経験がある場合、かかった時間の平均値を求め、その値を中心とする範囲内から一つの値をランダムに抽出する。範囲は経験回数が多いほど狭くなるよう調節している。

経験がない場合、見込み通過時間を決定する。算出法は、現在のところ、シミュレーション時の走行モデルに依存している。詳細は〈3・2〉参照のこと。

算出された予測通過時間から Dial 配分法⁶⁾を用いて各経路の選択確率を求める。この値にその経路の予測信頼率をかけたものをその経路の新しい Q 値とする。予測信頼率は、予測時間 Te と実際の走行時間 Tr から式 (2) に基づいて決定する。

$$value = reward + (\alpha * Te / Tr) \dots\dots\dots (2)$$

ここで、 $reward$ は $Te > Tr$ の場合に 1、それ以外の場合に 0 をとる。また、 α はドライバ固有の学習率である。学習ドライバと同様に設定する。

〈2・2・2〉 外部からの情報に基づく経路選択 外部から情報を与える場合には、どのような情報をどのようなタイミングで与えるかを検討する必要がある。情報が有効に働き、渋滞を緩和できるためには、その問題を解決する必要があるが、本研究の目的は、その問題を解くこと自身ではなく、その問題を検討する上で有用な評価手段となりうるシミュレータを提供することであるので、ここでは、情報提供法の一例を取り上げ、本モデルに組み込む方法を解説し、5章でシミュレーション結果から、その情報提供が交通流に影響することを示す。

ここで取り上げる情報提供法は、ドライバが分岐点に達したときに、その時点で最も早く目的地に到達できる経路を直接指示するものである。このためには経路全体を観察することのできるフィールド観察器が必要である。フィールド観察器は各リンクを走行している車の平均速度を観測可能であるとする。

情報提供器は、その情報から、現在位置から目的地までの可能な経路の予想到達時間を算出し、その最も短いものを選択する。具体的な情報提供は、そのドライバが持って

表 1 Q 値マップを用いた走行前経路選択
Table 1. Route selection using Q -value map.

Route	Sum of Q value
$1 \rightarrow 3 \rightarrow 6 \rightarrow 9 \rightarrow 10 \rightarrow 13$	-7.0
$1 \rightarrow 3 \rightarrow 4 \rightarrow 7 \rightarrow 10 \rightarrow 13$	-6.8
$1 \rightarrow 3 \rightarrow 6 \rightarrow 7 \rightarrow 10 \rightarrow 13$	-7.3

いる Q 値マップの更新という形で行われる。ここでは、選択された経路に含まれるリンクの Q 値が最大値になるようにすればよい。

例えば、図 2 の分岐点 6 から分岐点 10 に向かう場合、分岐点 7 を経由する経路と、分岐点 9 を経由する経路の 2 通りがある。Q 値マップでは、分岐点 6 から分岐点 9 に向かう経路の Q 値が-1.4、分岐点 6 から分岐点 9 に向かう経路の Q 値が-1.2 であるので、通常は後者を選択する。

しかし、ある車両が分岐点 6 に到着した瞬間に、情報提供が予想到達時間を算出した結果、前者の経路のほうが速いと判断した場合には、経路 6 から経路 7 に向かう経路の Q 値を 0 に書き換える。これによりそのドライバはこちらの経路を選択することになる。

ただし、Q 値マップの書き換えは、当該ドライバの持っているマップに対してだけ行われ、他のドライバのマップに対しては行われない。他のドライバのマップは、そのドライバが分岐点に達したときに、その時点の状況に応じて、はじめて書き換えられる。また書き換えられた Q 値も、ドライバが経路を選択して分岐点を通過した後は、元の値に戻される。

3. 経路選択行動モデルの評価実験

本章では、前章で説明したモデルのうち、走行前経路選択行動と走行経験に基づく走行中経路選択行動の部分について、モデルの正当性を検証するために行った評価実験について述べる。

〈3・1〉 方針 モデルの正当性を証明するには、実際のドライバによる行動とモデルの動きが一致していることを示せばよい。しかし、交通流シミュレーションの目的からいえば、各ドライバの選択行動すべてが一致している必要はなく、それらの積み重ねとして現れる道路網内の交通流量が妥当な範囲で一致していれば良い。すなわち、ある時間内に各経路を通過した延べの車両台数が一致していればよい。そこで、実際の交通調査の結果（経路ごとの延べ通過台数）が存在する道路網をシミュレータ内に実現し、その上で本モデルを動かしたときに各リンクを走行したドライバの数と交通調査の結果を比較する。

〈3・2〉 走行モデル 走行中経路選択行動のシミュレーションを行うには、車両を道路網内で走行させなければならない。そのためのモデルを走行モデルといい、具体的には、ある瞬間の車両の置かれた状況から、その車両の速度あるいは加速度を決定するものである。

シミュレーションでは、各車両は走行モデルに従って走行し、分岐点に到達すると、経路選択モデルに従って経路を選択し、再び走行モデルに従って走行する。これを目的地に到達するまで繰り返す。

本シミュレータでは、自由走行モードと追従走行モードの 2 つのモードからなる走行モデルを採用している。モードの切り替えは、車間時間が 2 秒以上（車間距離が長い）ならば自由走行、それより短い場合は追従走行モードとな

る。追従走行モードでは、ドライバは前方の車両に追突しないような速度を決定しなければならない。車間時間 2 秒という値は、通常ドライバが安全に走行できる指標として一般的なものである⁽⁷⁾。

〈3・2・1〉 自由走行モード 自由走行モードでは、車両の速度は通過中のリンクの混雑度によって左右される。したがって、リンクを通行中の車両数をもとに、式 (3) のようにリンク内基準速度を求める。

$$V_s = \frac{\text{LinkLen}}{t_{a0}\{1 + \alpha(X_a/C_a)^\beta\}} \dots\dots\dots (3)$$

V_s : リンク内基準速度(km/h)

C_a : 最大リンク流入台数 (台/h)

t_{a0} : 該当リンクの理想通過時間(h)

α, β : 定数(2.62, 5.0)

X_a : リンク流入台数 (台/h)

LinkLen : リンク距離(km)

リンク内基準速度は、従来のネットワーク型の交通流シミュレーションにおけるリンクコスト関数⁽⁸⁾を用いる。なお、式中の定数 α 、 β の値は道路規格に応じたパラメータであり、日本の道路に適用する場合は、 $\alpha=2.62$ 、 $\beta=5.0$ が適当とされているので、本シミュレータでもこの値を用いる。

なお、リンク内基準速度は、リンクの見込み通過時間（〈2・2・1〉参照）を求めるときの基準としても使われる。ただし、この場合は X_a/C_a の項は不明なので、そのリンクの Q 値で代用する。すなわち、式 (4) のように求める。

$$T_k = t_{a0}\{1 + \alpha*(Q_{\text{link}})^\beta\} \dots\dots\dots (4)$$

T_k : 経路 k の予測所要時間、 t_{a0} : 基準速度での通過時間、 Q_{link} : 該当リンクの Q 値、 α, β : 定数(2.62, 5.0)

〈3・2・2〉 追従走行モード 追従走行モードでは、前方車両との車間距離を利用して、式 (5) を用いて、加速度を決定する。

$$\ddot{x}(t) = \frac{\lambda \times [\dot{x}_{n-1}(t) - \dot{x}_n(t)]}{[x_{n-1}(t) - x_n(t)]} \dots\dots\dots (5)$$

〈3・3〉 シミュレーション条件 シミュレーションに使用した道路網は、図 1 のものである。この道路網は現実存在する道路網に対応する。

発生させた車両の総数は、1,016 である。これは比較対象の交通調査の車両総数と同じになるようにした。また、車両の発生のタイミングは、車両発生間の時間がポアソン分布となるように調整した。

出発地はすべてのドライバについて 1 とした。目的地は 2, 5, 8, 11, 12, 13 であり、それぞれを目的地とした車両は 32, 152, 24, 49, 625, 134 である。なお、以下に示す結果は、10 回の走行経験を経た後のものである。

〈3・4〉 結果および考察 表 2 に車両の通過のあった全経路について、その経路を使用した車両数のシミュレーション結果と実際の交通量調査結果を示す。表中、P は走行全経路選択結果のみを用いた場合の結果を表し、P+A はさ

らに走行中経路選択行動シミュレーションを加えた場合の結果を表す。

なお、表中の一致度(agreement)は式(6)で計算した。

$$1 - \frac{\text{誤選択された数}}{\text{該当目的地に向かう車両数}} \times 100 \dots\dots\dots (6)$$

シミュレーション全体(表中 P+A)の結果と実際の結果(表中 real)を比較してみると、2つの経路でやや低い値を示しているものの、全体として良好な結果となっているといえる。

ちなみに、走行前経路選択結果のみを用いた場合(表中 P)と、走行前経路選択結果に経験に基づく経路変更を施した

もの(=シミュレーション全体)を比較してみると、後者のほうが実際の結果に近く、経験に基づく経路変更をモデルに組み込んだ効果が現れているといえる。

次に、経験による経路選択の学習の過程を図3に示す。図は走行経験が増えるに従って、総通過時間(各車両がゴールに到着するまでの時間の総和)がどのように変化したかを示している。図より経験を重ねるに従って、学習効果により総通過時間が減少していき、6回目あたりでほぼ収束していることがわかる。あらかじめ走行全経路選択において学習した結果から出発しているので、走行経験開始後の学習は速く収束するのだと思われる。

4. 外部からの情報提供による交通流変化のシミュレーション

前章では、本モデルの基礎となる部分の正当性を検証した。本モデルの特徴の一つは外部からの情報提供による交通流変化を比較的簡単にシミュレートできる点にあるので、その機能が正常に働くことを示す必要がある。しかし、外部から情報を与えた場合の交通流変化を実際の道路上で記録した実験結果は存在しない。そこで、本論文では、典型的な幾つかの情報提供を与えた場合の交通流の変化をシミュレータで発生させ、その結果に妥当な理由付けができることを示すことで、モデルの正当性ではなく、モデルの妥当性を検証することにする。

〈4・1〉 シミュレーション条件 使用した道路網、車両総数などは〈3・3〉節で説明したモデル評価実験で使したものと同じである。

情報提供法は、〈2・2・2〉節で説明した方法(その時点での最適経路を指示)を用いる。情報提供は分岐点3, 4, 6, 9, 10で行う。なお、情報を提供するドライバの割合を、0%(情報提供なし)から100%(全ドライバに情報を提供)まで10%間隔で変化させた。

〈4・2〉 結果および考察 図4に、情報を提供するドライバの割合を変化させたときの、総走行時間(全ドライバの走行時間の合計)の変化を示す。図より、情報を受け

表2 経路選択行動モデルの評価結果

Table 2. Result of evaluation of route selection model.

Route (distance)	Number of vehicles		
	Real	P (agreement(%))	P+A (agreement(%))
1→3→6→9 →12 (1020)	625	625 (100)	625 (100)
1→3→4→ 5(990)	152	152 (100)	152 (100)
1→3→6→9 →8 (1020)	24	24 (100)	24 (100)
1→3→2 (360)	31	32 (96.8)	32 (96.8)
1→3→6→9 →10→7→4 →3→2(2940)	1	0 (96.8)	0 (96.8)
1→3→6→9 →10→11 (1680)	20	42 (55.1)	24 (91.8)
1→3→4→7 →10→11 (1620)	29	7 (55.1)	25 (91.8)
1→3→6→9 →10→13 (1680)	15	105 (32.8)	62 (64.9)
1→3→4→7 →10→13 (1620)	118	25 (30.5)	71 (64.9)
1→3→6→7 →10→13 (1620)	1	4 (97.7)	1 (100)
average		— (76.5)	— (90.7)

図3 経験による経路選択の学習曲線
Fig. 3. Learning curve of route change.

図4 情報提供シミュレーション結果
Fig. 4. Result of information offering simulation.

るドライバの割合が 30%を超えたあたりから総走行時間が減少し始め、60%あたりではほぼ減少効果が落ち着いていることがわかる。情報を受けるドライバが少ないうちは、他の目的地を持つドライバが経路を変更して流れ込むことによって特定の経路が込み合うことがあるのに対し、情報を受けるドライバが増えることによってその効果が分散して薄れ、ある程度増えてくると頭打ちになるのだと考えることができる。

以上のように、一例ではあるが、外部からの情報提供を与えた場合の交通流の変化を本シミュレータが模倣することができることが確認された。

5. おわりに

本研究では、ドライバが経路を、あらかじめ走行前に計画したものから、走行時に動的に変更することのできるドライバの経路決定行動モデルを提案した。モデルは走行前にあらかじめ経路を決定する部分と、走行時に経路を変更する部分からなる。走行前に決定する際の情報に、経路に関する強化学習結果を用いることで、選択をより現実のドライバに近いものにすると同時に、走行時の動的な経路変更を容易にモデル化することが可能である。また、走行時に経路を変更できる機能を利用して、過去の走行経験を経路選択に反映することができ、より現実のドライバに近い経路選択が可能である。また、外部からの情報提供の効果をこの機能を使って実現できる。

本モデルを組み込んだ交通流シミュレータを作成し、以下の 2 点を確認した。

1. 現実の交通調査による交通流データが存在する道路網を、シミュレートした結果、本モデルがほぼ現実の交通流と一致している。
2. 外部からの情報提供のシミュレーションを行った結果、情報提供の方法を変化させると、シミュレーション結果が妥当に変化する。

今後の課題には以下のようなものがある。

- (1) 今回は道路の長さのみ考慮したが、現実には道路の幅や曲がり具合、交差点での角度などの要素も、ドライバが経路を選択する際に影響する。これらを考慮したモデルを作成する必要がある。
- (2) 本モデルでは、事前にはあるが、道路網を学習し、Q 値マップを学習ドライバごとに作成しなければならず、道路網が複雑になった場合に、問題である。広域道路網の場合は、細かい部分は 1 本の道路に近似するなどして、道路網自体を複雑にしない方法もあるが、根本的な改善が必要である。

- (3) 外部からの情報提供について、様々な方法をモデル上で構築し、この効果を検証する必要がある。

(平成 15 年 3 月 7 日受付, 平成 15 年 10 月 8 日再受付)

文 献

- (1) 森地 茂・兵頭哲朗・小川圭一:「情報提供システム評価のための交通行動分析手法に関する研究」, 交通工学, **30**, 3, pp.21-29 (1995-3)
- (2) 坪井兵太・秋山孝正:「ファジィ・ニューラルネットワークを用いた経路選択行動のモデル化」, 土木計画学研究・論文集, No.15, pp.509-516 (1998)
- (3) 溝上章志・柿本竜治・柴木雅也:「情報提供可での動学的経路選択行動に関する実験的分析」, 交通工学, **35**, 3, pp.9-19 (2000-3)
- (4) 羽藤英二・谷口正明・杉恵頼寧:「経路選択時の交通情報に対するドライバーの反応」, 交通工学, **30**, 1, pp.23-32 (1995-1)
- (5) 三上貞芳・皆川雅章(共訳):強化学習, pp.142-170, 森北出版 (2000)
- (6) 桑原雅夫:「やさしい交通シミュレーション -2.広域ネットワークシミュレーション-」, 交通工学, **32**, 5, pp.25-31 (1997-5)
- (7) 蓮花一己編:交通行動の社会心理学, pp.63-76, 北大路書房 (2000)
- (8) 交通ネットワークの均衡分析-最新の理論と解法-, pp.11-20, 土木学会 (2001)

佐 川 大 介

(非正員) 1978 年生。2001 年名城大学理工学部電気電子工学科卒業。現在, 同大学院理工学研究科電気電子工学専攻修士課程在学中。現在, 人間行動のモデル化に基づいた交通システムに関する研究に従事。

佐 川 雄 二

(非正員) 1963 年生。1987 年名大院情報工学専攻前期課程了。同年, (株)日立製作所入社。1992 年名大院情報工学専攻後期課程単位取得退学。同年同大助手, 同講師を経て, 2000 年名城大理工学部講師, 2003 年同助教授, 現在に至る。自然言語処理の研究に従事 (工学博士)。

杉 江 昇

(正員) 1932 年生。1957 年名古屋大学工学部電気学科卒業。同年通商産業省電子技術総合研究所入所。1970 年パイオニクス研究室長, 1978 年視覚情報研究室長。1979 年名古屋大学大学院工学研究科情報工学専攻教授, 1994 年名城大学理工学部電気電子工学科教授, 2000 年名城大学理工学部情報科学科教授, 現在に至る。パイオニクス, コンピュータビジョン, 自然言語などの研究に従事 (工学博士)。