マルチエージェントシミュレーションを用いた交通情報共有化の効果分析^{*1}

A study of the effect of traffic information sharing using multi-agent simulation

松下 歩^{*2}・菊池 輝^{*3}・北村 隆一^{*4}

By Ayumu Matsushita^{*2}, Akira Kikuchi^{*3} and Ryuichi Kitamura^{*4}

1. 研究の背景と目的

道路交通現象は個々人の意思決定の集合であり、各ドライバーの意思決定により、旅行時間といった交通状況が決定され、その交通状況が、他のドライバーの意思決定に影響を与えている。つまり、交通状況を介し、ドライバー間には相互作用が存在しているといえる。その相互作用が、交通状況の日々の不確実性を生み出し、道路交通を複雑なものとしている。近年交通施策の一つとして情報提供が盛んに行われているが、情報によって推奨された経路が混雑してしまい、道路交通システム全体の効率が下がるという情報提供による負の側面も存在する¹⁾²⁾。また、他者の選択行動を予測して、提供された情報とは異なる経路を選択するといった選択行動も考えられる。このようなことが存在するため、交通現象を把握するには、一人一人の意思決定行動を記述するだけではなく、相互影響下での意思決定行動を分析する必要があるといえる。

また、従来型の路側に設置された電光掲示板等による情報提供に加え、近年ではGPS (Global Positioning System) の精度の向上、カーナビゲーションやVICS (Vehicle Information and Communication System) サービスの普及、車載センサや通信デバイスの発展といった背景から、路車間通信システムのようなドライバーへの個別交通情報提供が実用化されつつある。それに伴い、複数の情報提供主体が存在する状況や、同じ情報提供主体のカーナビを持つ車両どうしで最新の経路情報を共有するという状況が実現されようとしている。

情報提供に関する研究としては、飯田ら^{3) 4)}の情報提供による経路選択行動変容に関する室内実験や、提供情報の利用者率と情報の依存率をパラメータとして変化させた数値実験があるが、行動主体を均一なものとして仮定しており、個々の異質性や相互作用は考慮されていない。また、吉井ら²⁾による、現在情報か予測情報かといった情報の質や精度が、情報利用率の変化に伴って、どのような影響をあたえるかに着目した数値実験があるが、不確実性下での人間行動の特性に関しては考慮されていない。

また、自律的に学習を行うエージェントが複数存在することによって異質性や相互作用を考慮するこ

とができるシミュレーションとしてマルチエージェントシミュレーションがあり、経路選択問題に関して、いくつかの研究が行われている。中山ら⁵⁾は経路選択と出発時刻選択を同時に行うとともに日々学習を行うエージェントによるシミュレーションを行っている。Wahle et al.⁶⁾は追従挙動及び経路選択を行うエージェントによって情報提供効果の研究を行っている。Klühl et al.⁷⁾はヒューリスティクスに基づく経路選択を行うエージェントを用いシミュレーションを行っている。

上記のマルチエージェントシミュレーションの既存研究では、情報の種類の違いや、異なった情報が混在することの影響についての分析は行われていない。近年実現されつつある個別交通情報のような情報提供による効果を把握するためには、相互作用や個々人の異質性を考慮した上で、情報の種類やその共有率が及ぼす影響についての研究が必要である。またエージェントがどのような選択を行っていくかに関わる重要な要素である戦略に関して既存研究では外生的に与えられたものとしているが、戦略というのも本来個人によって違い、内生的に決められるものであろう。

以上の背景から、本研究では、情報提供下において、複数の異質なドライバーが互いにどのように作用し、交通システム全体に対してどのように影響を及ぼしているのかを個々のドライバーが持つ戦略に基づき自律的に学習し、行動を決定するマルチエージェントシミュレーションを用いて分析する。なお、情報の共有とは、複数の情報提供主体により、異なる情報共有グループが複数存在する意味を含むものとする。

2. マルチエージェントモデル

ある環境をセンサである受容器 (detector) を用いて知覚 (percept) し、効果器 (effector) を通じて行動 (action) するエージェントが多数集まった集団をマルチエージェントと呼ぶ。エージェントの行動には相互作用が生じる⁸⁾。本研究では、経路選択行動時におけるドライバーをエージェントとして設定し、それぞれの選択によって実現された交通状況より、認知所要時間⁹⁾及び戦略を学習、更新していくものとする。

ここで、学習を「過去の経験を活かすことによって未来の行動の自己改善を行うこと」、戦略を「行動の決定指針・学習結果の利用指針」と定義する。具体的には「現実知覚した状態に近づけるように認知所要時間や戦略を改善していくこと」を学習、「選択決定のアルゴリズム」を戦略とする。

^{*1}キーワード：交通情報共有化、経路選択、エージェントシミュレーション

^{*2}学生員、京都大学大学院都市社会学専攻

(〒615-8540 京都市西京区京都大学桂C-1-2, TEL075-383-3242, FAX075-383-3241)

^{*3}正会員、工博、京都大学都市社会学専攻 助教

^{*4}正会員、Ph.D、京都大学都市社会学専攻 教授

3. シミュレーション概要

図-1のような1 OD 2 Linkの道路ネットワークを対象とし、図-2のようなドライバーエージェントモデルと、交通環境モデルから構成されるシミュレーションモデルを構築する。複数のドライバーエージェントが日々繰り返す経路選択行動を模擬するものとする。

図-1 1 OD 2 リンクの単純ネットワーク

図-2 シミュレーションモデル概要

図-3 エージェントのグループ

(1) ドライバーエージェントのグループ

各ドライバーエージェントは、情報獲得の有無によって、情報共有グループか自己学習グループのいずれかに属する(図-3)。各エージェントはグループごとに2つないし2つの戦略候補を所持し、各試行において、その中から1つを選択するものとする。

a) 自己学習グループ

このグループに属するドライバーエージェントは、交通情報が提供されず、自らの走行経験より得られる知識のみを用いて、認知所要時間の学習を行う。戦略については、確定的戦略と確率的戦略の2つを有する。(戦略の詳細に関しては後述)

b) 情報共有グループ

このグループに属するドライバーエージェントは、互いに所要時間に関する情報を共有する。そのため、非選択経路に関しても、グループ内の他エージェントがその経路を選択していれば、所要時間に関する情報を得ることができる。そのため、非選択経路に関しても学習が可能となる。

ここで、情報を提供する主体が2つ存在し、それぞれ以下のような異質の情報を提供することを想定する。

1) 単純情報グループ

この主体が提供する情報は、単純な両経路の実所要時間である。戦略については、自己学習グループと同様に、確定的戦略と確率的戦略の2つを有する。

2) 優秀情報グループ

この主体が提供する情報は、これまでに所要時間の短い経路を数多く選択したエージェントが内部状態として記憶している認知所要時間である。戦略については、このグループに所属するエージェントは同じ認知所要時間を記憶するため、確率的戦略のみとする。

情報共有グループに属するドライバーエージェントは、単純情報グループもしくは優秀情報グループのいずれかから情報が提供されるものとし、同時に複数の主体から情報を得ることはない。

(2) ドライバーエージェントモデル

各ドライバーエージェントが交通状況という環境を知覚し、内部状態として記憶する認知所要時間と戦略を学習することを表した「認知所要時間学習モデル」と「戦略学習モデル」及び、その二つの学習モデルに基づき行動決定を行う「経路選択モデル」の3つのモデルより構成される(図-4)。

図-4 モデル構成関係図

・ 認知所要時間学習モデル

本研究では、個々のドライバーエージェントは過去の走行経験より学習し、それぞれの経路に対して、実際の経路の実所要時間とは必ずしも一致しない、認知所要時間を保持していると仮定する。その更新

式はそれぞれのグループで異なり、次式のように表される。

(a)自己学習グループ
(選択経路)

$$Cogtime(t+1) = Cogtime(t) + \alpha \{Realtime(t) - Cogtime(t)\} \quad (1)$$

(非選択経路)

$$Cogtime(t+1) = Cogtime(t) \quad (2)$$

(b1)情報共有グループ (単純情報グループ)
(選択経路)

$$Cogtime(t+1) = Cogtime(t) + \alpha \{Realtime(t) - Cogtime(t)\} \quad (3)$$

(非選択経路)

$$Cogtime(t+1) = Cogtime(t) + \beta \{Realtime(t) - Cogtime(t)\} \quad (4)$$

(b2)情報提供グループ (優秀情報グループ)
(選択経路・非選択経路)

$$Cogtime(t+1) = Exellent_time(t) \quad (5)$$

ここで

$Cogtime(t)$: t 日の当該経路の認知所要時間

$Realtime(t)$: t 日の当該経路の実所要時間

$Exellent_time(t)$: t 日の最も累積利得が高いドライバーエージェントの当該経路の認知所要時間

α, β : パラメータ ($0 \leq \beta \leq \alpha \leq 1$)

なお、認知所要時間の学習において、提供される情報による影響よりも、自らの経路利用経験による影響の方が大きいと考え、パラメータに関する上記の不等号制約条件を設けた。

・戦略学習モデル

各ドライバーエージェントはそれぞれの戦略に戦略評価値を与え、その値の大きさに従って戦略を選択するものとする。戦略評価値は経験によって変化し、その変化による利用戦略の変遷はドライバーエージェントの学習過程を意味している。

(a)自己学習グループ

このグループのエージェントは非利用経路に関する情報を得ることができないため、自らの経験した経路の実所要時間を自らの認知所要時間と比較することによって、そのとき選択した戦略を評価するものとする。認知所要時間が実所要時間より大きければ正の評価値を与えるものとする。具体的には次式で表すものとする。

$$strategy_i(t+1) = strategy_i(t) + u \{score(t) - strategy_i(t)\} \quad (6)$$

$$score(t) = \gamma \{Cogtime(t) - Realtime(t)\} \quad (7)$$

ここで

$strategy_i(t)$: t 日における戦略 i の評価値

$Realtime(t)$: t 日の当該経路の実所要時間

$Cogtime(t)$: t 日の当該経路の認知所要時間

u, r : パラメータ ($0 \leq u, r \leq 1$)

(b1)情報共有グループ (単純情報グループ)

単純情報グループは、選択経路が、非選択経路よりも短い実所要時間であれば正の評価を行うものとする。具体的には次式のように表すものとする。

$$strategy_i(t+1) = strategy_i(t) + u \{score(t) - strategy_i(t)\} \quad (8)$$

$$score(t) = \gamma \{Realtime_NC(t) - Realtime(t)\} \quad (9)$$

ここで

$strategy_i(t)$: t 日における戦略 i の評価値

$Realtime(t)$: t 日の当該経路の実所要時間

$Realtime_NC(t)$: t 日の非選択経路の実所要時間

u, r : パラメータ ($0 \leq u, r \leq 1$)

(b2)情報提供グループ (優秀情報グループ)

優秀情報グループに関しては、戦略を一つしか持たないため、戦略評価値は与えない。

・経路選択モデル

各ドライバーエージェントは各経路の認知所要時間と、採用する戦略によって次のように行動する。

(i)確定的戦略

認知所要時間が短い方の経路を必ず選択する。

(ii)確率的戦略

認知所要時間をもとに、次式に従って、各経路の選択確率を算出し、モンテカルロシミュレーションにて選択する経路を決定する。

$$p_i = \frac{\exp \{-\theta \cdot Cogtime_i(t)\}}{\exp \{-\theta \cdot Cogtime_i(t)\} + \exp \{-\theta \cdot Cogtime_j(t)\}} \quad (10)$$

ここで、

p_i : 経路 i の選択確率

$Cogtime_i(t)$: t 日の経路 i の認知所要時間

θ : パラメータ

である。

(3)交通環境モデル

交通環境モデルは交通流モデルと交通情報計算モデルより構成される。

・交通流モデル

本研究では交通状況は、実旅行時間で表現し、ドライバーの経路選択のみによって形成されるものとす。実旅行時間と交通量の関係はBPR関数を用いて定式化する。

$$t^i = t_0^i \left\{ 1 + a \left(\frac{q^i}{C^i} \right)^b \right\} \quad (11)$$

ここで、

- t^i : 経路 i の実旅行時間
- t_0^i : 経路 i の自由旅行時間
- q^i : 経路 i の交通量
- C^i : 経路 i の交通容量
- a, b : パラメータ

・交通情報計算モデル

(b1) 単純情報グループ

単純情報グループは、同一グループに属する全ドライバーエージェントの選択結果を集計し、各ドライバーエージェントに、非選択経路の実所要時間を情報として提供する。

(b2) 優秀情報グループ

このグループに属する全ドライバーエージェントの、累積利得に関する情報をもとに、もっとも累積利得が高いエージェントの認知所要時間を情報として提供する。ここで利得とは、個々のエージェントの優劣を短時間経路選択数という観点から評価する指標である。利得は各エージェントに知覚されることはない。所要時間が少ない経路を選択した方が優秀であると考え、そのエージェントに正の利得を与えるものとする。なお、利得を累積所要時間などにより評価することも可能であるが、累積所要時間が短くなるよりも、安定的に短時間経路を利用することができたエージェントの方が優秀であるという視点に立ち、短時間経路選択数により評価することとした。つまり、偶発的に所要時間が非常に短い経路を利用することよりも、高い頻度で所要時間が短い経路を選択することを評価する。

具体的には、次式によって利得を定義する。

$$\text{payoff}(t) = \begin{cases} \omega, & \text{if } \text{Realtime}(t) < \text{Realtime_NC}(t) \\ 0, & \text{otherwise} \end{cases} \quad (12)$$

ここで、

$\text{payoff}(t)$: t 日におけるエージェント i の利得

$\text{Realtime}(t)$: t 日のエージェント i の選択経路の実所要時間

$\text{Realtime_NC}(t)$: t 日のエージェントの i の非選択経路の実所要時間

ω : パラメータ ($0 < \omega$)

である。
すなわち、

$$\max_i \left\{ \sum_i \text{payoff}_i(t) \right\} \quad (13)$$

となるドライバーエージェント i を検索し、そのエージェントが保有する認知所要時間を提供することになる。

4. 数値実験

前述のシミュレーションモデルを用いて、エージェント 400 人について繰り返し計算を行った。回数を重ねることに習慣的な行動へと収束し¹⁰⁾、内部状態の諸量の更新が行われにくくなることを表現するために、認知所要時間更新率 α 、 β 及び、戦略評価値更新率 u にはステップパラメータを導入した。 $\alpha = 1.0 / (\text{繰返し回数})$ 、 $\beta = 0.5 / (\text{繰返し回数})$ 、 $u = 1.0 / (\text{繰返し回数})^{1/2}$ とした¹¹⁾。交通環境モデルの交通流モデルにおけるパラメータは、 $a=2.0$ 、 $b=2.0$ 、自由旅行時間 t_0 および、交通容量 C は、経路の異質性を考え、経路 a は $t_0=20$ 、 $C=200$ 、経路 b は $t_0=10$ 、 $C=100$ とした¹¹⁾。また、経路選択の感度パラメータである θ は 0.5、戦略評価に加える得点に乘じる定数 γ の値は 0.5 と設定した¹¹⁾。どのグループが混在する時も 50 回以内でシステムが定常状態に安定したため、繰り返し計算の回数は 50 回とした。

また、全く走行経験を持たない初日の初期認知所要時間はそのシステムが等時間に均衡した際の時間を平均とする正規分布に従うように与えた。(分散 $\sigma = 10.0$)

以下、初めに各戦略利用割合に関する考察を行い、どのグループを同時に存在させるかといったグループの組み合わせを変え、それぞれにおける混在分析を行った。

(1) 各戦略利用割合に関する考察

表-1 は最終回 (50 回) の各戦略選択割合を、50 回繰り返し計算の乱数の種を変えて 6 回行った平均の結果である。確率的戦略を利用するエージェントの方が多かったことがわかる。これは本モデルの構成上、両経路の認知所要時間に差があった場合、認知所要時間が大きな経路を選択する確率が確率的戦略の方が高く、システム全体の様相を知覚しやすくなっているためであると考えられる。しかしながら、わざわざ認知所要時間が大きい経路を選択して見る必要がないことも往々にあり、必ずしも確率的戦略が賢い戦略とはいえない。その点から、この二つの戦略選択割合が僅差だったと考えられる。

表-1 最終回時戦略選択割合 (%)

確定的戦略	確率的戦略
47.45	52.55

(2) 自己学習グループと単純情報グループの混在

自己学習グループと単純情報グループのみを存在させ、その構成比率を変えて実験を行った。図-5 は、

最終回(50回)の全エージェントの所要時間の総和を総旅行時間とし、自己学習グループの割合と総旅行時間との関係を表したものであり、50回の繰り返し計算の乱数の種を変えて6回行った平均の結果である。図-5よりシステムをマクロな視点からみたとき、情報を提供される人数が一定比率を下回ると、その増加に伴い総旅行時間が大きく増加することがわかる。また、総旅行時間の観点に加え、表-2からわかるように、情報を持つ単純情報グループがある一定数以上存在する時、経路の所要時間も均等している。この時に最も社会的な時間損失が小さくなるように、システムが利用されているといえる。なおここでは各グループ50%ずつ混在している。次に各エージェントの認知所要時間というミクロな視点から考察を行うと、その分布図は図-6のようになる。それぞれ自己学習グループと単純情報グループが50%ずつ混在している時の初回と最終回における認知所要時間と50回で実際に実現した所要時間の分布である。自己学習グループは非利用経路に関する情報がなく認知所要時間が更新されないで認知所要時間が偏り(図-6右上)、エージェントの経路が変更されにくくなる。そのため、自己学習グループのみが存在する時は、経路の所要時間が近い値で収束することはない。また、初回はランダムに与えていた認知所要時間が経験を通しての学習の結果最終回には2つの固まりに収束している。自己学習グループ、単純情報グループともに、2つの固まりに収束しているが、自己学習グループより単純情報グループの方が同じグループ内での分散が小さくなっている。これは与えられた情報により、経路所要時間という環境をより現実近く認知できているということがわかる。

図-5 自己学習グループ割合と最終回総旅行時間の関係
(自己学習グループと単純情報グループ混在時)

表-2 最終回時経路所要時間(分)

	自己学習グループのみの時	単純情報グループ混在時
経路a所要時間	91.982	71.076
経路b所要時間	45.092	70.552

図-6 認知所要時間分布図
(初回と最終回)

次に、図-7に最終回における経路A利用人数を、図-8に最終回における経路A利用割合をそれぞれ示した。まず、図-7より、自己学習グループのみの時を除き、単純情報グループが存在している時は、経路Aの総利用人数に大きな変化は見られないことがわかる。しかし、図-7より、その利用割合は単純情報グループと自己学習グループで大きく違い、総じて、自己学習グループが主に経路Aを利用していることがわかる。これは、自己学習グループは両経路の経路所要時間に関する確かな認知を行っていないために、経路Bに比べ容量が大きく混雑を起しにくい経路Aを利用しやすくなっているためであると考えられる。単純情報グループは非選択経路の情報も得ているので、自己学習グループの認知所要時間の偏りによって混雑している経路Aを利用する確率が低くなる。それにより、見かけ上、単純情報グループは、自己学習グループによる経路利用の偏りを緩和するような作用があることが推察される。単純情報グループによる、上記のような偏りの緩和作用があるために、経路Aの総利用人数としては自己学習グループの割合が変化しても大きく変わらず、総旅行時間が小さくなるようにシステムが利用されていることがわかる。

図-7 最終回経路A利用人数

図-8 最終経路 A 利用割合

(3) 自己学習グループと優秀情報グループの混在

自己学習グループと優秀情報グループを同時に存在させ、その各グループの割合を変えることで、総旅行時間がどのように変わってくるかを調べた結果、図-9 のように自己学習グループが 100% の時、他の割合の時よりも大きく総旅行時間が増加していることがわかる。これより、優秀情報グループに関しても、総旅行時間短縮に寄与する効果があるということがわかった。しかし、図-5 の単純情報グループと自己学習グループが混在する時と比較すると、単純情報の時よりは効果が低いということがわかる。これは今回定義した優秀情報グループが、グループ内で最も累積利得の高いエージェントの各経路の認知所要時間をグループ内の全エージェントで共有したために、経路選択の多様性が失われてしまったことによるものと考えられる。

また、同じ理由から優秀情報グループ内のエージェントはほとんどが同じ経路選択を行ってしまうので、図-9 は図-5 と比べてグラフが単調になっていないことも伺える。

次に自己学習グループと優秀情報グループが 50% ずつ混在している時の最終回における優秀情報グループの認知所要時間と、50 回で実際に実現した所要時間の分布図を図-10 に示す。この図より、認知所要時間に関して、単純情報グループ内の分散も自己学習グループに比べると小さかったが、優秀グループはピンポイントに同じ情報が与えられるため、全員が同じ認知所要時間を持っているということが図-10 よりわかる。

図-9 自己学習グループ割合と最終回総旅行時間の関係
(自己学習グループと優秀情報グループ混在時)

図-10 認知所要時間分布
(初回と最終回)

次に、自己学習グループと優秀情報グループとの混在時における最終回の経路 A 選択人数および、経路 A 選択割合を算出した。(図-11, 12) これも単純情報グループとの混在の時と同様、自己学習グループは経路 B に比べ混雑を起こしにくい経路 A を利用しやすくなっていることがわかる。また、利用人数も情報を持つ優秀グループが混在しているときは概ね総旅行時間も同じであり、システムが安定しているといえる。

図-11 最終経路 A 利用人数

図-12 最終経路 A 利用割合

(4) 自己学習グループと単純情報グループと優秀情報グループ混在

最後に本研究での3グループ全てが混在するときの結果について考察する。今回は単純情報グループと優秀情報グループの人数は等しくした上で、自己学習グループの割合を10%ずつ変化させていき、総旅行時間との関係を調べた(図-13)。自己学習グループと単純情報グループと優秀情報グループ全てが混在するときも他の結果と同じく自己学習グループ割合が100%の時だけ他の割合の時と比べて大きく総旅行時間増加しており、やはり、情報を持つグループが加わるにより、総旅行時間が短縮される効果があるということがわかった。しかし、総旅行時間に関するグラフの比較より、その効果は優秀情報グループとの混在時より大きく、単純情報グループによる効果が主であると推察される。

なお、図-5, 9, 13 に共通して、自己学習グループが100%に到達する直前のあたりで、総旅行時間の飛躍的な増加が生じているが、これより、情報を持つグループが僅かでも存在することにより、総旅行時間を減少させる効果があるが、その後情報を持つグループが通増したからといって、線形的に総旅行時間が減少させることができるわけではないということが推察される。この総旅行時間の飛躍的な増加に各エージェントのミクロな相互作用がどのように関わっているのかに関しては今後の課題である。

図-13 自己学習グループ割合と最終回総旅行時間の関係
(自己学習グループ、単純情報グループ、優秀情報グループ混在時)

(自己学習グループ)

(単純情報グループ)

(優秀情報グループ) (実現時間分布)
図-14 認知所要時間分布
(初回と最終回)

5. おわりに

本研究では、交通現象における相互作用を考慮するために個々が自律的に学習を行うエージェントから構成されるマルチエージェントシミュレーションモデルを構築し、異なった情報・戦略を持ったエージェントを導入し、数値実験を行った。その結果、情報を持たないグループのみの時と比較して、情報を持つグループによってシステム全体を改善する効果を持つことが推察されることと、情報を持たないグループは容量が大きく混雑しにくい経路を利用しやすいということと、情報による時間改善効果はその共有人数によって変わり得るという結果が得られた。

また、今回行った3つのグループ混在のパターンの総旅行時間に関するグラフの比較より、単純情報の方が、優秀情報よりも総旅行時間を短縮させる効果があることがわかる。このことより、今回定義した優秀情報のような、全員が同じ判断基準として用いるような情報を与えるよりも単純情報のように、経験によって個人差が表れ、選択基準の多様性が失われない場合の方が交通システムとして、よりよい状態になることが示唆されている。これは、近年実現され始めている車車間通信を利用した個別情報提供は、全員に一律の情報が提供されるわけではなく、通信した車によって与えられる情報が異なることから、本研究での単純情報と同じように、総旅行時間を短縮など社会的損失を小さくする可能性があることを示唆している。

しかしながら、シミュレーション結果は仮想的な状況で実現されたものであり、パラメータの初期値は結果に大きな影響を与えるものである。特に今後はパラメータの妥当性に関する考察が課題としてあげられるほか、エージェントの行動様式の妥当性を検証する必要がある。

補注

[1] α, β に関しては実際の経験の方が与えられた情報よりも強く認知所要時間の更新に影響することを表す $0 \leq \beta \leq \alpha \leq 1$ という制約条件を満たす値を設定した。u に関しては戦略の多様性をみるために、認知所要時間の学習パラメータの α, β よりも小さい値に設定し、戦略の収束を遅らせた。θ に関しては、両経路が同質である条件下で、自己学習グルー

プのみを存在させ、 α を固定したもとして、両経路の所要時間が均等に収束するような値として0.5に設定し、 γ に関しては、制約条件を満たす値として0.5を設定した。

参考文献

- 1) Mahmassani, H. et al: System Performance and User Response under Real-time Information in a Congested Traffic Corridor. *Transportation Research* 25A(5), 293-307, 1991.
- 2) Yoshii, T. Akahane, H. and Kuwahara, M.: Impacts of the Accuracy of Traffic Information in Dynamic Route Guidance Systems, *Proceedings of The 3rd Annual World Congress on Intelligent Transport Systems*, 1996.
- 3) 飯田恭敬, 内田敬, 宇野伸宏: 交通情報の効果を考慮した経路選択行動の動的分析, *土木学会論文集* No. 470/IV-20, pp. 77-86, 1993.
- 4) 飯田恭敬, 宇野伸宏, 長谷川哲郎: 情報提供の分析のための経路選択シミュレーション, *土木系計画学研究・講演集* No. 15(1), pp. 67-74, 1992.
- 5) 中山晶一郎, 高山純一, 佐藤達夫, 北村隆一: 経路・出発時刻同時選択を考慮した適応的エージェントによる交通システムシミュレーション, *土木学会*

論文集 D, Vol. 63, No. 2, pp. 110-121, 2007.

- 6) Wahle, J., Bazzan, A., Klugl, F. and Schreckenberg, M.: The Impact of Real-time Information in a Two-route Scenario Using Agent-based Simulation, *Transportation Research*, Vol. 10C, pp. 399-417, 2002.
- 7) Klugl, F. and Bazzan, A.: Simulation of Adaptive Agents: Learning Heuristics for Route Choice in a Commuter Scenario, *Proceedings of the 1st. AAMAS (Autonomous Agents and Multiagent Systems)*, Bologna, pp. 217f, 2002.
- 8) Russell, S. J. and Norving, P.: *Artificial Intelligence: A Modern Approach*, Prentice-Hall International, 1995.
- 9) 牛若健吾, 菊池輝, 北村隆一: 所要時間の認知に基づくセーフティーマージンの要因分析, *土木計画学研究・論文集*, No. 3, pp. 569-574, 2005.
- 10) 中山晶一郎, 藤井聡, 北村隆一: ドライバーの学習過程を考慮した道路交通の動的解析-複雑系としての道路交通システム解析に向けて-, *土木計画学研究・論文集*, No. 16, pp. 753-761, 1999.
- 11) 中山晶一郎, 北村隆一: 帰納的推論に基づく経路選択行動と道路交通システムの動態に関する研究, *土木学会論文集*, No. 660/IV-49, pp. 53-63, 2000.

マルチエージェントシミュレーションを用いた交通情報共有化の効果分析*¹

松下 歩*²・菊池 輝*³・北村 隆一*⁴

本論文では、意思決定者間の相互作用を記述することができるマルチエージェントシミュレーションモデルを用いて、情報を共有することによって交通状況がどのように変わっていくのか、個人にとってどのような効果があるのかを分析した。情報の種類、有無によってエージェントのグループ化を行い、その存在割合を変化させた。

情報を持つグループの割合が増加するにつれ、システム全体として総旅行時間が小さくなるように利用が行われるようになること、逆にその割合が少ないほど個人としては、情報を持つことによる大きな時間短縮効果が得られるということが示された。

A study of the effect of traffic information sharing using multi-agent simulation

By Ayumu Matsushita*², Akira Kikuchi*³ and Ryuichi Kitamura*⁴

The impacts of sharing traffic information on network traffic are examined using multi-agent simulation which can describe interactions among decision makers. The agents are grouped according to whether they receive information and by the type of information they receive. The relative size of each group is changed in the simulation analysis.

It is shown that as the number of agents with information increases, network traffic improves. It is also shown that the travel time advantage enjoyed by agents with information increases as the fraction of agents with information decreases.