

マルチエージェントシステムを用いた異質ドライバー混在下の都市交通シミュレーション

名城大学大学院 学生員 ○魯 旭海
名城大学 正会員 松本 幸正

1. はじめに

交通シミュレーションを用いて、都市交通で起こり得る様々な現象に対しドライバーの行動を再現、分析することができる。その中で、交通工学でよく使われているマクロシミュレーションでは、システム全体を一つの系としてモデル化し、その挙動を統一させた行動規模として規定する。しかしながらこの手法では、交通混雑などの状況に異質なドライバーの影響を十分反映できないという問題点がある。マルチエージェントシミュレーション(MAS)では、異質なドライバーを個々にモデル化し、各ドライバーの経路選択行動を交通混雑の状況などへ反映することが容易となる。

そこで本研究では、異質なドライバーの経路選択行動を反映可能なモデルの開発を目指す。ドライバーの day-to-day の運転状況を MAS シミュレーションで再現し、交通混雑の学習がネットワーク交通流に与える影響をみる。

2. シミュレーションの概要

2.1 強化学習によるドライバーの経路選択

MAS を用いた交通シミュレーションは、速く目的地に到着するように、学習と経路選択を行うことを前提としているものが多い。本研究では、個々のドライバーの経路選択行動のモデル化を目指して、Q-learning におけるドライバーの学習過程を組み込んで経路選択行動を表現し、day-to-day の学習を重ねながら経路選択結果が収束していくと考える。Q 値の更新式は式(1)として表現する。

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [r_{t+1} + \gamma \max_a Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)] - \text{crowd} \quad (1)$$

ここで、各変数の意味は次の通りである。

s_t : エージェントの状態

a_t : 状態 s_t から s_{t+1} へ移動する時の行為

r_{t+1} : 状態 $t+1$ の時の報酬

α : ステップ t から $t+1$ までの変化値

γ : 報酬の割合率

crowd はリンク内の混雑度を表す指標であり、式(2)を用いる。

$$\text{crowd} = \theta \{1 + \alpha(L/C)^\beta\} \quad (2)$$

ここで、 α, β, θ : 係数、 L : リンク内の交通量、 C : 交通容量である。

また、初期値として、ドライバーの目的地を設定し、走行前に各経路の選択確率を設定する。そして、選択した経路を通過することで、その経路の走行経験が得られる。2 回目以降では、ドライバーの day-to-day の走行経験から学習することで、経路選択行動が変化していく過程を表現する。

2.2 シミュレーションの構築

本研究では、マルチエージェント交通シミュレーションツールキット MATSim を用いる。シミュレーションにおける運転行動に関連した行動決定を行う機能を実現するエージェントを設計した上で、Q-learning における混雑度を反映したドライバーの経路選択機能を動作可能とし、運転行動を表現可能なシミュレーションを構築する。

3. 実験の概要と結果

3.1 ネットワークとデータの概要




図 1 Sioux-Falls Network

キーワード: マルチエージェント, シミュレーション, 交通混雑

連絡先 〒468-8502 名古屋市天白区塩釜口 1-501 名城大学理工学研究科建設システム工学 TEL052-832-1151

図1は、本研究で用いた、交通量配分研究において検証に用いられる代表的なネットワーク Sioux-Falls network である。このネットワークは、ノード数が 24、リンク数が 76 であり、市街地における 2 車線、最高速度 50km/h の主要幹線道路網を想定した。今回、入力データに用いた OD 交通量は、仮想の日 OD 交通量として、1800 トリップを生成した。

エージェントについて、道路混雑度 *crowd* を考慮したエージェント CE と道路混雑度を考慮しない QE の 2 種類を用いる。シナリオの詳細を表1に示す。エージェントと同じ初期 Q 値を持ったエージェントのみを設定した上で、100 日のシミュレーションを行った。図2には実際のシミュレーションの様子を表す。

3.2 シミュレーションの結果

図3は、各シナリオにおける平均走行時間を示したものである。シミュレーションの最初では、各エージェントは初期 Q 値のみに基づいた最短経路を選択するため、エージェントの平均走行時間の偏りが小さいことがわかる。ドライバーの day-to-day の学習によって、差異が生じている。

シミュレーション日数が経過するにつれて、それぞれのシナリオの平均走行時間が一定の値の付近に収束していることがわかる。CE のみのシナリオにおいて、他のシナリオと比較して、平均走行時間がより少ないことがわかる。また、シナリオ2において、日数が長くなるにしたがって走行時間がシナリオ1に接近している。これは、2種のエージェントが混在し、互いに影響を発生することによって生じると考えられる。

図4には各シナリオにおける全車両の平均走行距離の変化を表す。図4より、どのシナリオにおいても、日数が長くなるほど、平均走行距離が短くなる傾向が見られる。また、道路混雑度を考慮したドライバーが多いほど、走行距離が短くなっていることがわかる。シミュレーション日数が80日を超えると、各シミュレーションにおける平均走行距離が収束していくことも確認できる。さらに、日数が長くなるほど、シナリオ1とシナリオ2の結果が近づいていくこともわかる。

このシミュレーションでは、ドライバーの割合のみを変化させ、各ドライバーの OD は変化しないため、平均走行距離と時間の結果から、道路状況を考慮した場合の方が、走行効率が高くなることといえる。これらから、混雑情報をドライバーに提供することにより、

表1 シナリオの詳細

	シナリオ1	シナリオ2	シナリオ3
エージェント構成	CE100%	CE50%, QE50%	QE100%




図2 シミュレーションの様子




図3 3つシナリオにおける平均走行時間




図4 3つシナリオにおける平均走行距離

交通混雑を緩和できる可能性があると考えられる。

4. おわりに

本研究では、交通混雑に着目し、マルチエージェントに基づく交通シミュレーションを構築し、仮想ネットワークに適用した。結果として、混雑度を反映したドライバーの day-to-day の経路選択行動を再現した。また、道路混雑度を考慮したドライバーが多くなるほど、走行効率が高くなることがわかった。

今後は、信号情報、または実データによるより詳細なシミュレーションを行う必要がある。