

交通渋滞抑制に向けた
協調型の自動運転に関する研究

2019年1月

千葉大学大学院工学研究科

建築・都市科学専攻 都市環境システムコース

石川 翔太

(千葉大学審査学位論文)

交通渋滞抑制に向けた
協調型の自動運転に関する研究

2019年1月

千葉大学大学院工学研究科

建築・都市科学専攻 都市環境システムコース

石川 翔太

論文要旨

自動運転車の普及や通信技術の発達に伴い、交通流の新しい制御方法が求められる中で、著者は交通渋滞の抑制に向けた協調型の自動運転に関する研究をおこなってきた。本論文はこれまでにこなった三つの研究をまとめ、高速道路で発生する交通渋滞の抑制に向けた路車間・車車間協調型の自動運転を提案する。一つ目の研究では Generalized Nagel-Schreckenberg(GNS) モデルを提案し、手動運転車および車車間通信機能を搭載した自動運転車による隊列走行をモデル化する。手動運転車のモデルでは現実のデータに現れる交通流の性質を再現でき、隊列走行のモデルでは車車間通信によって手動運転車のモデルよりも短い車間距離で制限速度を維持できることを確かめた。二つ目の研究では GNS を用いて自動運転車が普及する過程の交通流を解析し、車車間通信の性能と渋滞の抑制効果の関係を調べる。解析の結果から、自動運転車の通信性能が上がったとしても、普及過程では手動運転車の速度の揺らぎに起因する交通渋滞が抑制されないことを特定した。つまり、普及過程の渋滞を抑制するために制御が必要になることがわかった。既存研究では、自動運転車に、状況に応じた走行をさせる制御により渋滞を抑制する方法が提案されているが、その制御はシミュレーションを用いてアドホックに設計されている。しかし、道路構造などの多くの構成要素によって変化する交通状況のそれぞれに対して妥当な制御則を設計することは困難である。そこで、三つ目の研究では路車間・車車間通信を用いた協調型の制御則の設計方法の確立に向けて、強化学習による制御の学習法を提案する。提案手法ではシミュレーション環境の中で、自動運転車と相互作用しながら方策を学習できる。計算機実験の結果から、学習した制御には渋滞時に現れる車列の解消や、渋滞の抑制効果があることを確認し、交通流を最適な状態で維持できることを示した。本論文ではこれら三つの研究結果から、提案する協調型の自動運転によって渋滞が抑制できると結論する。

目次

第 1 章	序論	1
1.1	研究の背景	1
1.2	研究の目的	2
1.3	研究の方法	4
1.3.1	実験の方法	4
1.3.2	評価の方法	4
1.4	用語の定義	5
1.4.1	交通渋滞	5
1.4.2	自動運転	7
1.5	論文の構成	10
第 2 章	対象問題	12
2.1	交通流のモデル化：手動・自動運転車の挙動の再現	12
2.2	交通流の解析：交通流の基本図を用いた渋滞抑制効果の観察	13
2.3	交通流の最適化：メタ安定相の維持	14
第 3 章	関連研究	16
3.1	交通流のモデル化	16
3.1.1	モデルの分類	16
3.1.2	セルオートマトンモデルの発展形	17
3.2	交通流の解析	18
3.2.1	速度の揺らぎによる交通渋滞	18
3.2.2	自動運転車の普及する過程の交通渋滞	19
3.3	交通流の最適化	20
3.3.1	交通流の制御方法	20
3.3.2	状況に応じた自動運転車の制御	22
3.3.3	強化学習による交通流制御	23
第 4 章	車車間の協調：隊列走行のモデル化	25
4.1	序言	25
4.2	セルオートマトンモデル	25

4.2.1	記号の整理	25
4.2.2	Nagel-Schreckenberg モデル	26
4.2.3	Extended Nagel-Schreckenberg モデル	27
4.2.4	Anticipatory Drivers モデル	27
4.3	Generalized Nagel-Schreckenberg モデル	29
4.3.1	道路モデル	29
4.3.2	走行ルール	29
4.3.3	制限速度を維持するための車間距離の条件	31
4.4	計算機実験	32
4.4.1	実験設定	32
4.4.2	手動運転車モデルの交通流の基本図	33
4.4.3	隊列走行モデルの交通流の基本図	34
4.5	考察	38
4.5.1	交通流の基本図の再現	38
4.5.2	車車間通信による隊列走行の再現	41
4.5.3	交通渋滞の再現	42
4.6	結言	42
第 5 章	車車間の協調：交通流に与える影響の解析	45
5.1	序言	45
5.2	車車間通信が交通流に与える影響	45
5.2.1	隊列走行による渋滞の抑制	45
5.2.2	通信性能と渋滞抑制効果の関係	46
5.3	GNS モデルの拡張	48
5.3.1	拡張の方針	48
5.3.2	走行ルール	49
5.4	計算機実験	50
5.4.1	実験設定	50
5.4.2	自動運転車が普及する過程の交通流の基本図	50
5.5	考察	51
5.5.1	自動運転車が普及することによる交通流の変化	51
5.5.2	自動運転車の普及過程で求められる制御	51
5.6	結言	56
第 6 章	路車・車車間の協調：自動運転方策の学習法	57
6.1	序言	57
6.2	強化学習	57

6.2.1	マルコフ決定過程	57
6.2.2	Q-learning	59
6.3	自動運転方策の学習法	60
6.3.1	エージェント (Agent)	61
6.3.2	環境 (Environment)	61
6.4	計算機実験	62
6.4.1	交通流モデル	62
6.4.2	実験設定	63
6.4.3	実験結果	65
6.5	考察	68
6.5.1	学習の収束性について	68
6.5.2	渋滞抑制可能な方策を獲得できる理由	73
6.5.3	車車間通信が渋滞抑制効果に与える影響について	75
6.5.4	学習の失敗について	75
6.6	結言	77
第 7 章 結論		78
参考文献		81
謝辞		87
研究業績		88

第1章 序論

1.1 研究の背景

長年解決されていない交通渋滞問題は、解決に向けて様々な分野で盛んに研究がおこなわれている。交通渋滞が生活に及ぼす影響は多大かつ様々である。例えば、旅行時間や環境負荷の増大や、経済的な損失など [Wang 13] が挙げられる。日本においても例外ではなく、平成 24 年度のデータでは一人当たりの年間渋滞損失時間は約 40 時間で、乗車時間 (約 100 時間) の約 4 割りに相当する [国土交通省]。このような膨大な損失がある交通渋滞の抑制に向けた研究は、交通工学だけでなく、情報工学や物理学など様々な分野でも研究対象となっている。

交通渋滞の原因は、交通事故や道路工事による交通容量の減少、および車の速度の揺らぎによる車両密度の偏りに分けられる。交通容量とは道路がある単位時間内 (通常 1 時間) に通すことのできる最大車両数を示す [岩崎]。ある地点で道路工事や交通事故が起こると、幅員や車線数が一時的に減少し道路構造が変わるため、交通容量も同時に下がる。この時、その地点へ流入する車の台数が交通容量を上回った場合に渋滞が発生する。一方、車の速度の揺らぎとは、人が運転しているときに何らかの要因で速度が変化することであり、道路勾配の変化に人が気が付かないことや先行車に対する過剰反応や反応の遅れにより発生する [岩崎 12]。速度の揺らぎが発生した時、道路上の車両密度が偏り、密な部分を起点に渋滞が発生する。速度の揺らぎによる渋滞は、サグやトンネルなど、速度の揺らぎが発生しやすい箇所を除去することにより根本的に解決することができる。

しかし、道路構造を大きく変える、いわゆるハード的な対策は、様々な観点から困難といえる [Figueiredo 01]。まず、道路の新設および拡張する場所を確保することは、特に建造物が密集している都市部において不可能ともいえる。場所を確保したところで、道路工事には膨大な費用や資源が必要となる。さらに、道路構造を変えるほどの大規模な道路工事には時間がかかるため、工事中に交通需要が変わってしまうことも考えられる。

ハード的な対策が難しいことから、高度道路交通システム : Intelligent Transport System (ITS) に関係するソフトウェアを用いた対策が注目されている [Figueiredo 01]。ITS は IT (Information Technology) で高度化される人や物の移動システムと定義される [長谷 03]。例えば、路車間通信や車車間通信などを利用し、人の観測能力では取得できなかった情報をもとに、安全性や輸送効率を改善する取り組みがおこなわれている [福井 99]。渋滞の解消ができた事例としては ETC を用いた路車間通信による自動料金徴収などが有名である

[NEXCOc]. ソフトウェアを用いた対策は既存のインフラを活用することが多く、対策にかかる費用や資源を節約することもできる。また、路車間通信器などの設置工事にかかる時間は、道路構造を変えるような大規模な道路工事よりも短く、その時点の需要に合わせた対策が期待できる。

さらに、最近では速度や車間距離などが部分的に自動化された Adaptive Cruise Control (ACC)[Vahidi 03] や、Cooperative Adaptive Cruise Control (CACC)[Dey 16] を搭載した車が普及し、ソフトウェアで制御できる対象として着目されている。ACC や CACC は、Advanced Vehicle Control Systems (AVCS)[Sladover 95] や、Advanced Driver Assistance Systems (ADAS)[Brookhuis 01] に関連し、乗員の安全性や快適性を向上させる技術として開発されてきた。これらの技術は人と比較して精緻に車を制御できることから、速度の揺らぎを発生させずに走行することができる。さらに、人の反応速度よりも早く反応できるため、より短い車間距離で走行することができる。また、路車間通信や車車間通信から得られる、人では処理できない大量の情報も処理することができる。

こうした背景から、渋滞抑制に向けた自動運転車の制御法に関する研究がおこなわれるようになった[大前 14]。特に、車両密度の偏りに起因する渋滞に対しては、ACC や CACC などの自動運転車を状況に応じて制御する方法が注目されている[Kesting 08, Papacharalampous 15]。周囲の交通状況を観測および予測して、その状況に合わせて速度や車間距離を制御することにより、車両密度の偏りを修正し円滑な交通流を実現する。こうした制御による渋滞抑制効果は、自動運転車の普及過程においても一定の効果が得られることが、シミュレーション実験により確認されている。

しかし、複数の自動運転車および路車間通信を利用した協調的な制御については、まだ十分に議論されていない。一般的に、1 台の車を制御するよりも複数台の車を協調制御する方が、効率的に交通流を制御できる良い側面が期待できる。その反面、複数の意思決定主体が相互作用する複雑な環境において、交通ルールや人の特性などを考慮しながら、渋滞抑制に有効な協調制御を設計しなければならない。この制御の設計が非常に困難であることは容易に想像できるが、現時点においてハンドコードがいない協調的な制御の設計法については議論の余地が残されている。

1.2 研究の目的

著者は交通渋滞を解消し得る自動運転の実現という目的をもって研究してきた。本論文は関連する研究やこれまでの研究結果をまとめ、高速道路で発生する交通渋滞の抑制に向けた路車・車車間協調型の自動運転を提案する。

まずは本論文で想定する状況を図 1.1 を使って説明する。交通渋滞 (Traffic jam) が頻発する道路を本論文の対象とする。対象道路の上流 (Upstream) と下流 (Downstream) に 1 台ずつ路車間通信器 (Road-to-Vehicle communication) を設置する。対象道路では白色で示した

自動運転車 (Self-driving vehicle) と黒色で示した手動運転車 (Manually-driven vehicle) が混ざって走行する。なお、自動運転車は路車・車車間通信によって情報を得ることができる。

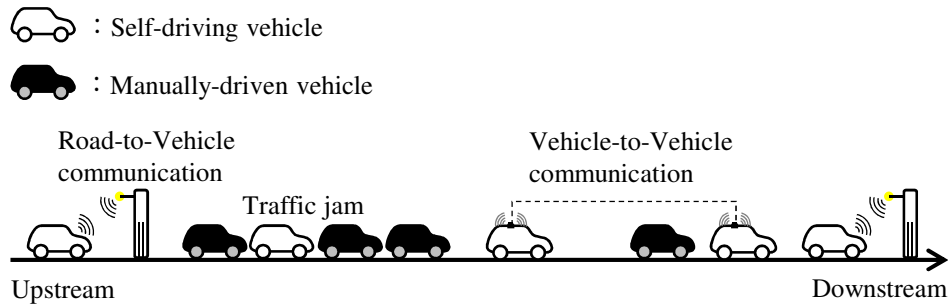


図 1.1: 本論文で想定する状況を表した図。白色で示した自動運転車 (Self-driving vehicle) と黒色で示した手動運転車 (Manually-driven vehicle) が、図の左側の上流 (Upstream) から右側の下流 (Downstream) へ走行する。上流と下流に 1 台ずつ路車間通信器 (Road-to-Vehicle communication) が設置されている。2 台の路車間通信器の間では交通渋滞 (Traffic jam) が発生する。自動運転車は車車間通信 (Vehicle-to-Vehicle communication) ができる場合がある。

この状況において、対象道路で発生する渋滞の抑制に向けた路車間・車車間協調型の自動運転を提案するために、著者は三つの研究をおこなった。

研究 1：交通流のモデル化

一つ目の研究では、手動運転車および車車間通信機能を搭載した自動運転車が走行する交通流をモデル化する。モデル化にはマイクロモデルの一つであるセルオートマトンモデルを用いる。個々の車の挙動をモデル化するマイクロモデルは、渋滞の原因となる速度の揺らぎを再現することができる。セルオートマトンモデルは、他のマイクロモデルと比較して柔軟にモデル化できる特徴を持つ。しかし、車車間通信機能を搭載した自動運転車は、セルオートマトンでモデル化されていない。そこで、新しいセルオートマトンモデルとして、パラメタによって手動運転車と自動運転車の両方をモデル化できる Generalized Nagel-Schreckenberg (GNS) を提案する。手動運転車のモデルでは現実のデータに表れる交通流の性質を再現し、自動運転車のモデルでは車車間通信を用いた隊列走行を再現することをそれぞれ目的とする。

研究 2：交通流の解析

二つ目の研究では、一つ目の研究で提案した GNS モデルを用いて、自動運転車が普及する過程の交通流を解析する。自動運転車が交通流に与える影響として、自動運転車を含む車群の安定性と交通流量の増加量を既存研究では評価している。しかし、自動運転車の通信性能に着目し、性能の向上に伴った渋滞の抑制効果について評価した研究は著者の知る限りない。そこで、自動運転車の通信性能や普及率と、渋滞の抑制効果の関係を明らかにして、渋滞が抑制できる場合とできない場合を特定することを目的とする。

研究 3 : 交通流の最適化

三つ目の研究では、二つ目の研究で解析した結果を踏まえて、自動運転車が普及してもなお発生する渋滞を抑制し交通流を最適化する。交通流を最適化する方法の中でも、自動運転車の速度や車間距離を制御する方法に着目する。既存研究は、シミュレーションを用いてアドホックに制御を設計しているが、道路構造などの多くの構成要素によって変化する交通状況のそれぞれに対して妥当な制御を設計することは困難である。さらに、路車間・車車間協調を考慮すると、従来の方法で制御則を設計することには限界がある。そこで、新しい制御則の設計方法の確立に向けて、路車・車車間協調型の自動運転方策を学習させることを目的とする。

1.3 研究の方法

1.3.1 実験の方法

図 1.2 が示すとおり、新しい交通流制御の手法が実社会に導入 (Implementation) されるまではシミュレーション実験 (Simulation)、試験場 (Test course) を用いた実機検証、社会実験 (Social) という段階を経る。シミュレーション実験では、対象の道路や車などをモデル化した後、計算機にモデルを実装することにより現実の交通流を再現し、その交通流を観察してデータを集める。どのような制御がどの程度の効果をもたらすかをシミュレーションにより予測できれば、最も有効な手段を短時間で経済的に選定することが可能となる [加藤 00]。試験場を用いた実機検証では、試験場関係者以外の安全が確保された状況で、シミュレーション環境と実環境との間での効果の違いを観察したり、実機を動かしたときの問題点などを検証する。社会実験では実際の道路の一部において限定した期間で新しい手法を導入し、有効性の検証や問題の把握をおこない、その手法を導入するのか最終的な判断を下すための材料を集める。これらの段階は、一方向に進むだけでなく、双方向に進んだり戻ったりしながら様々な形で実験を重ね、最終的な本格導入に至る。

本論文は最初の段階である交通流シミュレーションにより実験をおこなう。実車両を用いた試験は時間と費用の観点から繰り返し試行することは困難であるが、シミュレーション実験は低コストで試行を重ねることができるため、新しく提案する機能やアルゴリズムの検証に適している。当然のことながら、シミュレーション実験には現実社会との差異が必ずあるという欠点があるものの、様々な状況を想定した多くの実験ができる利点がある。この利点を活かし、なるべく多くの状況を想定して実験や考察を論じる。

1.3.2 評価の方法

交通流の評価には交通流の基本図を用いる。交通流の基本図は縦軸に交通流量 q (Traffic flow)、横軸に車両密度 ρ (Traffic density) を示し、交通流量 q は単位時間内に道路上の一地

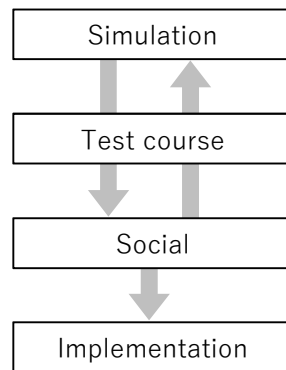


図 1.2: 新しい交通流の制御が実社会に導入されるまでの流れを表した図. シミュレーション実験 (Simulation), 試験場における実験 (Test course), 社会実験 (Social) を繰り返した後, 実社会に導入 (Implementation) される.

点を通過した車の台数, 車両密度 ρ は単位距離あたりに存在する自動車の台数を表す.

日本の高速道路における 1 カ月間の観測データ [Sugiyama 08] をプロットした交通流の基本図を図 1.3 に示す. 縦軸は交通流量として 5min あたりの交通流量, 横軸は車両密度として 1km あたりに存在する自動車の台数を示す. 基本図の中に自由走行相 (Free-flow phase), 渋滞相 (Jam phase), メタ安定相 (Meta-stable phase) の 3 つの相が観察できる. 自由走行相では車両密度の増加にしたがって交通流量も増加する関係が成り立ち, 車は制限速度で先行車を追従することができる. 渋滞相では逆に車両密度の増加にしたがって交通流量も減少する関係が成り立ち, 交通流に車列が表れる. 車がこの車列を通過するとき, 車は停止と発信を繰り返しながら走行するか, 低速度で走行する必要がある. 自由走行相と渋滞相の交点に対応する車両密度は臨界密度 (Critical density) と呼ばれる. 臨界密度を超えても車が制限速度で先行車を追従しているとき, 交通流はメタ安定相となる. これらの性質は, 日本の高速道路だけでなく, 世界各国の観測データでみられる共通の性質である [Sugiyama 08].

この基本図で交通流を評価する場合, 交通流量を最大化したときに交通流が最適となる. 特に, 車両密度が臨界密度よりも大きい場合, 同じ車両密度でも交通流量が大きいメタ安定相と小さい渋滞相の二つに分かれるため, メタ安定相を維持することが求められる. つまり, 基本図上で渋滞相のプロットを無くすことができれば, 交通流量の最大化を達成したことになる. そこで, 本論文は, 渋滞相やメタ安定相のプロットの有無で定性的な評価をおこなない, 交通流量で定量的な評価をおこなう.

1.4 用語の定義

1.4.1 交通渋滞

様々な定義がある「交通渋滞」という用語については, 著者と読者の考えに相違が生じやすいため, ここで本論文の定義を示す. 交通工学における定義は「交通容量上のボトルネック

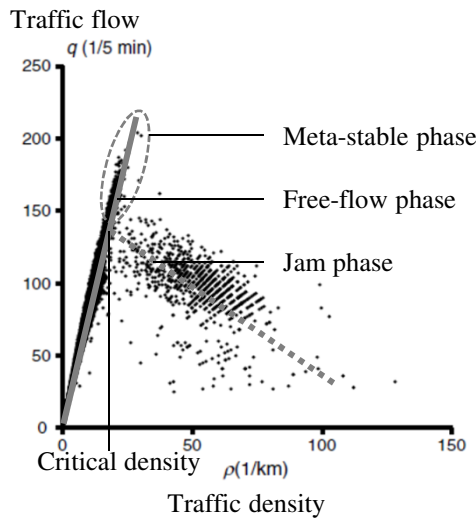


図 1.3: 日本の高速道路における 1 カ月間の観測データをプロットした交通流の基本図. 文献 [Sugiyama 08] から引用し, 自由走行相 (Free-flow phase), 渋滞相 (Jam phase), メタ安定相 (Meta-stable phase), 臨界密度 (Critical density) を加筆した.

クに, その地点の交通容量を超える交通需要が流入した時, ボトルネックを通過できずにここを先頭として上流に滞留した車両列の交通状態」である [越 正毅 98] ここで, ボトルネックとは道路の断面積がその道路の上下流に比べ相対的に狭くなっている箇所である [岩崎]. 実際の現場で用いられている例として, NEXCO 東日本, 中日本, 西日本が管理する高速道路における渋滞の定義は「時速 40km 以下で低速走行あるいは停止発進を繰り返す車列が, 1km 以上かつ 15 分以上継続した状態」である [NEXCOa]. 渋滞学では「交通流の基本図において車両密度が臨界密度よりも大きく, 渋滞相へ転移した状態」を渋滞と定義している [西成 06]. 本論文は交通流の基本図を用いて実験結果の評価をおこなうため, 渋滞学の定義を採用する.

表 1.1: 交通渋滞の原因と発生箇所により分類した表.

	一般道路	高速道路
突発渋滞・工事渋滞 (交通容量の低下)	交通事故・車両故障・道路工事	
交通集中渋滞 (車両密度の偏り)	交差点・入庫待ち	料金所・合流・サグ・トンネル出入口

交通渋滞の原因と発生箇所により分類した結果を表 1.1 にまとめる. 交通渋滞は交通容量の低下を招く突発渋滞・工事渋滞と, 車両密度の偏りを招く交通集中渋滞に分けられる [NEXCOb]. 突発渋滞では交通事故や車両故障など予期しない事象の出現によりボトルネックが形成され, 渋滞が発生する. 工事渋滞は道路工事の規制によりボトルネックが形成され, 渋滞が発生する. これは一般道路も高速道路も同様である. 一方, 交通集中渋滞は, 一般道路では交差点や入庫待ち, 高速道路では料金所, 合流, サグ, トンネル出入口で発生する.

図 1.4 によれば、渋滞の発生割合の 73%は交通集中となり、突発渋滞や工事渋滞よりも大きな割合を占める。さらに、交通集中渋滞のうち 66%はサグやトンネル出入り口などで発生している。




図 1.4: 高速道路における渋滞発生の原因と交通集中渋滞の発生個所の割合。文献 [NEXCOd] の情報をもとに作成。

本論文では、発生割合が一番高いサグやトンネル出入り口で発生する渋滞を対象とする。サグと呼ばれる、下り坂から上り坂に差しかかる凹部では、上り坂であることにドライバーが気づかないため、無意識に速度が低下してしまう [越 93]。また、トンネル出入り口では、明暗の差やトンネル内部の圧迫感により、ドライバーが減速してしまうことがある。これらの「速度の揺らぎ」を起因として、後続の車との車間距離が縮まり次々に後続の車が衝突回避のためのブレーキを踏むことになり、やがて渋滞が起こる。

図 1.5 の交通流の基本図を用いて、速度の揺らぎを起因とした渋滞がメタ安定相から渋滞相への相転移であることを説明する。車両密度が臨界密度よりも小さい交通流の場合 ($0 \leq \rho \leq \rho_1$)、速度の揺らぎが発生しても、その揺らぎは後続へ伝播されずに消えるため、自由走行相が維持される。一方、車両密度が臨界密度よりも大きく ($\rho_1 \leq \rho \leq \rho_2$)、かつメタ安定相の交通流の場合、速度の揺らぎは後続へ伝播し、渋滞相への相転移 (Traffic breakdown) が起こる。車が直前の先行車を追従している限り逆方向の相転移、つまり渋滞相からメタ安定相への転移は起こらない [Sugiyama 08]。この相転移の性質を踏まえると、速度の揺らぎを除去することができれば渋滞を抑制できると考えられる。

1.4.2 自動運転

ここでは本論文が用いる「自動運転」や「自動運転車」という用語を定義する。まずは、アメリカや日本が採用している定義として、運転自動化レベルについて説明する。次に、この定義のなかで用いられている「縦方向 (longitudinal) の制御」について説明する。そして、本論文が対象とする自動運転が縦方向の制御であることを述べる。

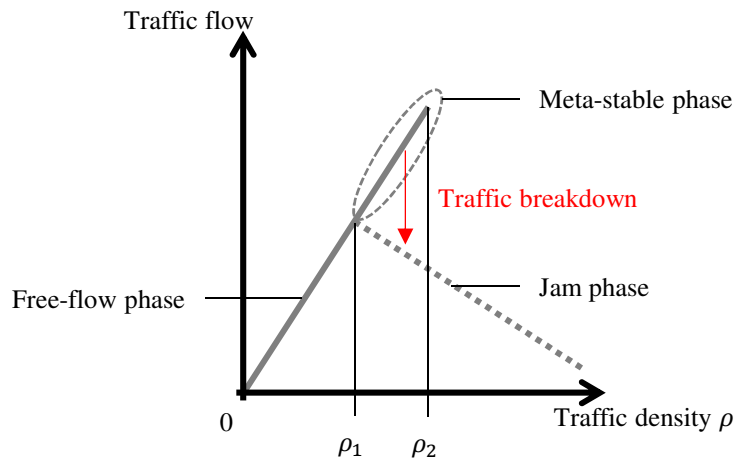


図 1.5: 交通流の基本図における速度の揺らぎに起因した渋滞をメタ安定相から渋滞相への相転移 (Traffic breakdown) であることを説明する図.

運転自動化レベル

運転自動化のレベルは議論が活発になった当初は「米運輸省道路交通安全局」(NHTSA) [Transportation] の定義が世界的によく採用されてきた. 2016年には「自動車技術会」(SAE) が示した定義を採用し始めたことから, このSAEの6段階の自動運転レベルの定義が主流になりつつある. 日本もこの定義を採用し始めており, 公益社団法人「自動車技術会」(JSAE) はSAEの定義を日本語参考訳した文書を公開している [公益社団法人]. 本論文もJSAEの文書を参考に自動運転について定義する. なお, 今後もこの定義が続くとは限らず, 改訂や再定義される可能性が残されていることに留意されたい.

表 1.2: 自動運転化レベルの概要. 文献 [公益社団法人] を参考に作成.

レベル	動的運転タスク		限定領域
	持続的な横・縦の車両運動制御	対象物・事象の検出及び応答	
0	運転者	運転者	適用外
1	運転者とシステム	運転者	限定的
2	システム	運転者	限定的
自動運転システム作動時は全ての動的運転タスクを実行			
3	システム	システム	限定的
4	システム	システム	限定的
5	システム	システム	限定なし

表 1.2 は自動運転化レベルの概要を表す. レベルごとに動的運転タスクを自動運転システムまたは運転者がおこなうのか, そのタスクを実行できる領域が限定されているかを示す. 以下, レベルごとに口語表現による定義を示す [公益社団法人].

レベル 0 運転自動化なし 運転者がすべての動的運転タスクを実行する. 運転者が予防安全

システムによって支援されている場合も含まれる。

レベル 1 運転支援 運転自動化システムが動的運転タスクの縦方向又は横方向のいずれかの車両運動制御のサブタスクを特定の限定領域において持続的に実行。ここでは縦方向と横方向の制御が同時におこなわれない。運転自動化システムが制御していない残りの動的運転タスクは運転者が実行する。

レベル 2 部分運転自動化 運転自動化システムが動的運転タスクの縦方向及び横方向の車両運動制御のサブタスクを特定の限定領域において持続的に実行する。運転者は動的運転タスクのサブタスクである対象物・事象の検知及び応答を完了し、システムを監督する。

レベル 3 条件付き運転自動化 運転自動化システムがすべての動的運転タスクを限定領域において持続的に実行する。作動継続が困難な場合への応答準備ができていない利用者は、他の車両のシステムにおける動的運転タスク実行システムに関連するシステム故障だけでなく、自動運転システムが出した介入の要求を受け容れ、適切に応答する。

レベル 4 高度運転自動化 運転自動化システムが全ての動的運転タスク及び作動継続が困難な場合への応答を限定領域において持続的に実行する。作動継続が困難な場合、利用者が介入の要求に応答することは期待されない。

レベル 5 完全運転自動化 運転自動化システムが全ての動的運転タスク及び作動継続が困難な場合への応答を持続的かつ無制限に実行する。作動継続が困難な場合、利用者が介入の要求に応答することは期待されない。

現在、レベル 2 までの自動運転システムが市場に普及している。この理由としては法規的な理由が挙げられる [小林 17]。例えば、日本は 1964 年に「道路交通に関する条約」(ジュネーブ交通条約) に加入している。2014 年 3 月、ジュネーブ交通条約は自動運転技術の発展を受け、レベル 2 までの自動運転を認めているが、レベル 3 以上の自動運転は認めていない。つまり、レベル 3 以上の自動運転の普及には、ジュネーブ交通条約の改正と、これを受けた国内法規の改正が必要になる。

本論文が対象とする自動運転車は、レベル 1 の運転支援やレベル 2 の部分自動運転化の機能、特に縦方向の車両運動制御が自動化された車を対象とする。レベル 1 では縦方向 (longitudinal) と横方向 (lateral) の制御は同時にはおこなわれないが、縦方向だけに焦点を当てれば対象の車になり得る。本論文では、縦方向の制御が自動化された車を「自動運転車」と呼ぶことにする。

縦方向の制御 (Longitudinal control)

車両運動制御の自動化には横と縦の二つの方向により分類できる。図 1.6 は車を上から見たときの横方向 (lateral) と縦方向 (longitudinal) を示す。横方向の車両運動制御は、横軸成分の動作からなる動的運転タスクである。例えば、車線の境界に対する車両位置の検知や、適切な左右方向の位置を維持するための操舵や差動ブレーキの入力の適用が含まれる。縦方

向の車両運動制御は、縦軸成分の動作からなる動的運動タスクである。例えば、設定速度の維持、並びに自車の経路上の先行車両の検知、先行車両との適切な車間距離の維持、及び車両速度又は車間距離を維持するための推進力又は制動力の入力が含まれる。先に述べたとおり、本論文は縦方向の制御が自動化された車を対象としている。




図 1.6: 車両運動制御の自動化の方向。横方向 (lateral) と縦方向 (longitudinal) の二つの方向に軸をとる。

持続的な縦方向の制御として、設定した車間距離の維持や速度の調整を自動化する機能として Adaptive Cruise Control(ACC)がある [Vahidi 03]。ACC は車にセンサやレーダを付けることにより直前の先行車との車間距離や相対速度を測り、先行車の状態に合わせた速度制御をおこなう。ACC 機能を搭載した車が市場に普及し始めた当初の主目的は、持続的なタスクから運転手を解放し、運転手の快適性を向上することであった [Vahidi 03]。最近では、運転手の安全運転支援 (Advanced Driver Assistance Systems: ADAS) やサグ渋滞の抑制など、安全性の向上や交通流量の増大が主目的となっている [大前 14]。この他にも、燃費の改善など様々なことを考慮しなければならないため、ACC により達成する目的は多目的となることが知られている [Li 11]。本論文は運転手の安全を最優先事項として、交通渋滞を抑制することを目的として ACC 機能に注目する。

近年では、短車間距離走行が空気抵抗の低減につながり、省燃費のニーズにこたえる機能として、Cooperative Adaptive Cruise Control(CACC)[Dey 16] も注目されている。ACC に車車間通信機能を搭載する CACC は、センサやレーダから得られる情報に加えて通信相手の情報も取得できるため、より精緻な制御が実現できる。特に、車車間通信を用いて極めて短い車間距離を自動制御により実現して走行する形態を ACC による走行と区別し、隊列走行 (Platooning) と呼ぶ [大前 14]。

以下、本論文では ACC 機能を搭載した自動運転車を ACC 車、CACC 機能を搭載した自動運転車を CACC 車と定義する。

1.5 論文の構成

本論文の構成を図 1.7 を用いて説明する。本論文は著者がこれまでおこなってきた交通流のモデル化、交通流の解析、交通流の最適化の三つの研究について記す。第 2 章では、三つ

の研究の対象問題を示す。続く第3章では、三つの研究の関連研究をまとめ、関連研究の課題を示す。第4章では、新しい交通流のモデルとして、車車間通信機能を搭載した自動運転車モデルを提案する。第5章では、第4章で提案したモデルを用いて、車車間通信機能を搭載した自動運転車が普及する過程の交通流を解析し、渋滞が抑制される状況とされない状況を特定する。第6章では、第5章で特定した抑制されない状況において、路車・車車間の協調型の自動運転方策を学習する方法を提案する。最後に、第7章では、第4章から第6章までの実験結果をまとめ、本論文の結論の述べる。

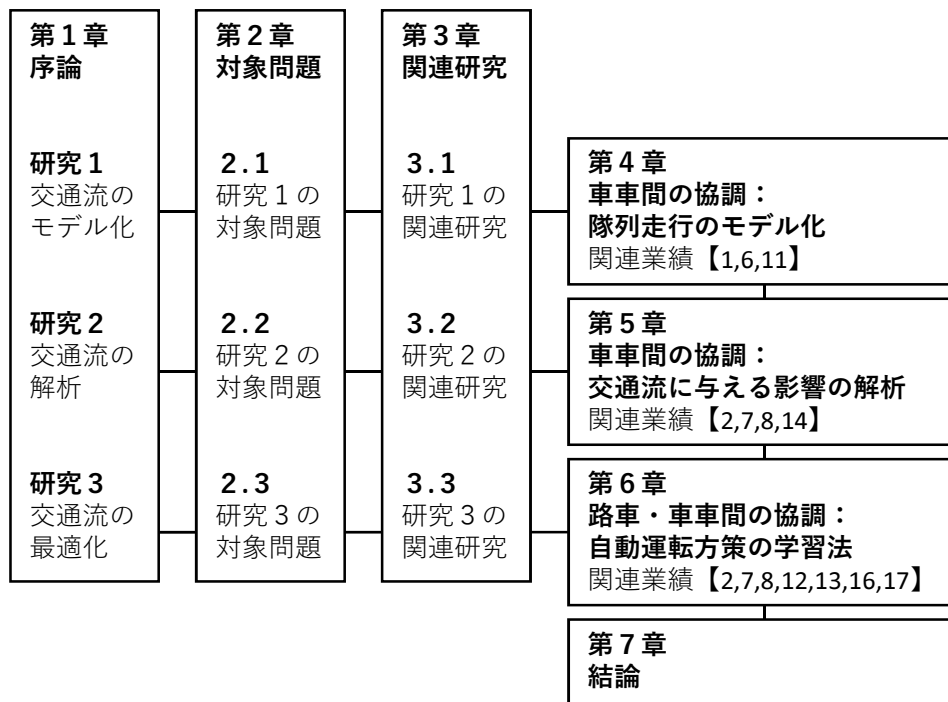


図 1.7: 本論文の構成

第2章 対象問題

2.1 交通流のモデル化：手動・自動運転車の挙動の再現

表 2.1 に手動運転車と自動運転車の特徴をまとめる。手動運転車の場合、運転者が直前の車の挙動予測をおこないながら運転する。そのため、人の心理や身体能力によって速度の揺らぎが発生する。自動運転車のうち、ACC 車はシステムが挙動予測をおこない、機械的に車間距離や速度を制御するため、速度の揺らぎを発生させずに走行する。この機能に加えて、CACC 車の場合、車車間の通信により 1 台以上の先行車の情報を獲得し、その情報を考慮しながら走行する。

表 2.1: 手動運転車と自動運転車 (ACC 車・CACC 車) の特徴。

		直前の車の挙動予測	速度の揺らぎ	車車間の通信
手動運転車		運転者	発生	-
自動運転車	ACC 車	システム	-	-
	CACC 車	システム	-	1 台以上と通信

表 2.1 の特徴を踏まえて、手動運転車のモデルは

- 自車の情報と直前の先行車の情報を入力する。
- 直前の先行車の情報から挙動を予測し、その予測を考慮しながら走行する。
- 速度の揺らぎによって速度が変化する場合がある。

の三つの要件を満たす必要があると考えている。

三つの要件を満たした手動運転車のモデルを動かして交通流をモデル化する。交通流のモデルから交通流の基本図を作成することができる。この基本図に、自由走行相、メタ安定相、渋滞相がすべて現れれば、再現性の高い交通流のモデルといえる。

また、自動運転車のうち ACC 車のモデルは

- 自車の情報と直前の先行車の情報を入力する。
- 直前の先行車の情報から挙動を予測し、その予測を考慮しながら走行する。

の二つを満たし、手動運転車から速度の揺らぎを排除した走行とする。

車車間通信を用いて隊列走行 (Platooning) をすることにより、手動運転車や ACC 車よりも短い車間距離で走行できる。CACC 車が隊列走行をおこなうとき、先頭車の速度や加減

速度が後続車に送信され、車間距離を一定にするため後続車の速度は常に先頭車と同じ速度になるよう制御される [須田 15]。これらの特徴を踏まえて、CACC 車のモデルは

- 自車の情報と通信した先行車の情報を入力する。
- 通信した先行車の情報から複数の先行車の挙動を予測し、その予測を考慮しながら走行する。
- n 台の隊列走行をおこなう場合、最後尾の車は n 台前の先頭車と通信する必要がある。
- 隊列走行することにより、手動運転車よりも短い車間距離で走行する。

の四つを満たす必要がある。

2.2 交通流の解析：交通流の基本図を用いた渋滞抑制効果の観察

車車間通信の導入前後や自動運転車の普及前後の交通流の基本図を比較して、渋滞の抑制効果について解析する。交通流の基本図に渋滞相があれば交通渋滞が発生したと判断し、渋滞相がなければ渋滞が抑制されたと判断する。

基本図に渋滞相が発生する二つの原因を図 2.1 を用いて説明する。

- Exceeding critical density 車両密度が増加し臨界密度を超えた場合、メタ安定相か渋滞相のどちらかが発生する。
- Traffic breakdown triggered by perturbation 交通流がメタ安定相にあるとき、速度の揺らぎ (perturbation) が起因となって渋滞相へ相転移する。

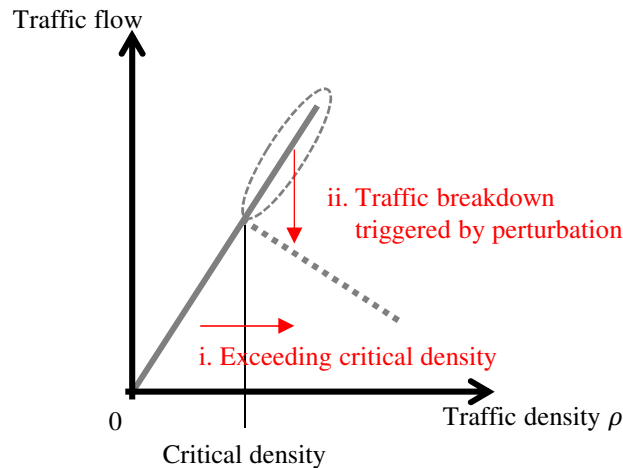


図 2.1: 交通流の基本図における渋滞相の発生原因. i. 車両密度が増加し臨界密度を超えた場合 (Exceeding critical density) と ii. 速度の揺らぎを起因としたメタ安定相から渋滞相への相転移 (Traffic breakdown triggered by perturbation) の二つを示す。

ここで、本論文が対象とする渋滞は ii の相転移である。i の影響を排除して、ii の影響に関して交通流の解析するために、車両密度を固定した環境で実験する。例えば、図 2.2 に示

す環状の道路では車両密度を固定することができる。本論文では、このような環状の道路を用いて実験することにより、iの影響を排除して、iiの相転移に関する交通流の解析をおこなう。




図 2.2: 車両密度を固定した環境の例.

2.3 交通流の最適化：メタ安定相の維持

図 2.3 に研究 3 で対象問題とする交通状況を示す。二つの路車間通信器が設置されている区間 L の対象道路において、白色で示した N 台の自動運転車と黒色で示した M 台の手動運転車が走行する。路車間通信器は隣を通過する車の台数と種類を計測する。二つの路車間通信器は計測した情報を共有することにより、区間の自動運転車の台数 N と手動運転車の台数 M がわかる。ここから、車両密度 $\rho = \frac{N+M}{L}$ と自動運転車普及率 $\mu = \frac{100N}{N+M} [\%]$ を計算する。上流の路車間通信器は車両密度 ρ と普及率 μ に対応する自動運転方策 $\pi_{\rho,\mu}$ を自動運転車に送信する。

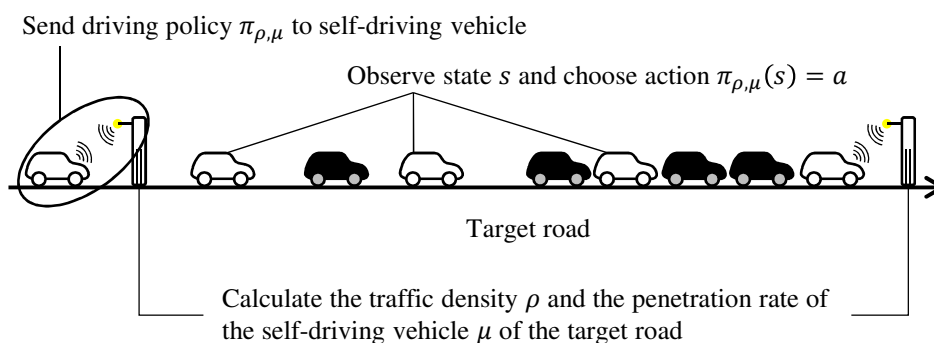


図 2.3: 対象問題とする交通状況。対象の道路区間内に存在する自動運転車の台数 $N = 4$ 、手動運転車の台数 $M = 4$ 。

研究 3 の対象問題は、対象道路内で発生する渋滞を抑制し、メタ安定相を維持することにより、交通流量を最大化する自動運転方策 $\pi_{\rho,\mu}$ を獲得することである。自動運転車は式 (2.1) の状態 s を観測し、自動運転方策をもとに式 (2.2) の行動を実行する。ここで状態 s の

各属性はそれぞれ、 ϕ^{vel} は速度、 ϕ^{gap} は車間距離、 ϕ^{rel} は相対速度、 $\phi^{\text{c-d}}$ は通信相手との通信距離、 $\phi^{\text{c-v}}$ は通信相手の速度、 $\phi^{\text{c-g}}$ は通信相手の車間距離である。

$$s = (\phi^{\text{vel}}, \phi^{\text{gap}}, \phi^{\text{rel}}, \phi^{\text{c-d}}, \phi^{\text{c-v}}, \phi^{\text{c-g}}) \quad (2.1)$$

$$a = \pi_{\rho, \mu}(s) \quad (2.2)$$

自動運転方策 $\pi_{\rho, \mu}$ は、渋滞の抑制制御が必要な時に送信される。この状況は、研究2の解析結果によって特定される。具体的には、自動運転車が普及しても交通流の基本図に渋滞相が現れる状況である。研究3で獲得した自動運転方策 $\pi_{\rho, \mu}$ を導入し、基本図の中から渋滞相がなくなれば、渋滞が抑制されたことになる。つまり、自動運転方策によって交通流が最適化されたことになる。

第3章 関連研究

3.1 交通流のモデル化

3.1.1 モデルの分類

交通流の基本図に表れる性質など、交通流が持つ性質をシミュレーションを用いて解析するために、交通流モデルの研究がおこなわれてきた。1950年代以来、提案された様々なモデルは表3.1のとおり分類される[杉山 03]。交通流モデルはマクロモデルとマイクロモデルに大別でき、さらにマクロモデルは気体モデル (Kinetic Gas Theory) と流体モデル (Fluid Dynamical Model)、マイクロモデルは追従モデル (Car Following Model) とセルオートマトンモデル (Cell Automaton Model) に分けられる。

表 3.1: 交通流モデルの分類表。文献 [杉山 03] を参考に作成。

	モデル名	時間	空間	速度
マクロモデル	気体 (Kinetic Gas Theory)	連続	連続	連続
	流体 (Fluid Dynamical Model)			
マイクロモデル	追従 (Car Following Model)	離散	離散	離散
	セルオートマトン (Cell Automaton Model)			

マクロモデルでは、個々の車の運動を考えずに、交通流を気体・流体の類推で考え、連続方程式や運動方程式で記述する。一方、マイクロモデルでは、交通流を個々の車の相互作用から創発される事象と考え、個々の車の挙動をルールとして記述する。マクロモデルでは、個々の車の挙動を考慮しないため、マイクロモデルと比較して計算コストが小さくなり、大規模な交通ネットワークを効率的にシミュレーションする時に用いられる。これに対して、個々の車を考慮するマイクロモデルは計算コストが大きくなるが、車ごとの特性や挙動を連立微分方程式や行動ルールとして記述できるため、渋滞発生過程の再現などに用いられる。

個々の車の速度の揺らぎに起因する交通渋滞問題を対象とする本論文ではマイクロモデルに焦点を当てる。追従モデルは「直前の先行車の挙動に応答して車を制御する」という仮定の下、1950年代から提案されてきた [Pipes 53, Chandler 58, Gazis 61]。その後提案された最適速度モデル (Optimal Velocity Model)[Bando 95] では、交通流の基本図に現れる性質を再現可能であることが示された [杉山 03]。

表 3.1 のとおり、追従モデルは時間・空間・速度をすべて連続で表現するのに対して、セルオートマトンモデルはすべて離散で表現する。セルオートマトンモデルは1980年代後半から

Rule-184[Wolfram 86] や一次元非対称単純排他仮定 (asymmetric simple exclusion process: ASEP)[Derrida 93] をはじめとして様々なモデルが提案されている。その中でも, Nagel らが提案した Nagel-Schreckenberg(NS) モデル [Nagel 92] は交通流の物理的研究が盛んになる契機を作り, 多くのモデル [Rickert 96, Emmerich 97, Barlovic 98, Knospe 99, Knospe 00, Knospe 02, Schneider 02, Daoudia 03, Jiang 05, Gao 07, 増淵 09, Ishikawa 15, 石川 16] の基礎となっている。

追従モデルと比較して, セルオートマトンモデルでは, 車の特性や運転手の特徴などの「直前の先行車の挙動」以外の影響を考慮した走行ルールを設定できる。例えば, サグやトンネル出入口で発生する速度の揺らぎは運転手の特徴による。また, 微分方程式によって記述する追従モデルよりも, 車間の相互作用の規則を記述するセルオートマトンモデルの方が簡単かつ柔軟なモデルである [加藤 00]。

本論文が対象とする車のモデル化は, 速度の揺らぎや車車間通信など「直前の先行車の挙動」以外の影響を考慮しなければならない。したがって, 本論文はセルオートマトンモデルで車をモデル化し議論を進める。

3.1.2 セルオートマトンモデルの発展形

セルオートマトンモデルは Nagel-Schreckenberg(NS) モデル [Nagel 92] を基礎として発展してきた。ここでは, 表 3.2 にまとめた NS モデルの発展形を紹介する。

表 3.2: NS 拡張系モデルの分類表。モデルの変更点, パラメタ増加数, n 台の先行車を観測可能であることを示す。

	NSsts+KWW [Gao 07]	MCD [Jiang 05]	PCA [Zamith 10]	ExNS [増淵 09]	AD [Schneider 02]	GNS [石川 16]
Accelerate	変更	変更	-	-	-	-
Maximize Velocity	-	変更	変更	変更	変更	変更
Decelerate	変更	変更	-	-	-	-
Move	-	-	-	-	-	-
パラメタ増加数	6	7	2	0	1	2
隊列走行	-	-	-	-	-	可能

NS モデルの走行ルールは **Accelerate**, **Maximize Velocity**, **Decelerate**, **Move** の四つで構成される。このうち, 関連研究では **Move** 以外の三つの走行ルールについて変更が加えられている。この変更に伴ってパラメタの数も増加している。最後の行には, 車車間通信による隊列走行をモデル化可能であるかどうかを示す。

NS with slow-to-start(NSsts) モデル [Barlovic 98] と Kerner-Klenov-Wolf(KKW) モデル [Kerner 04] を組み合わせた NSsts+KWW モデル [Gao 07] は, **Accelerate** と **Decelerate** に変更を加え, 加速度に関するノイズを導入した。Comfortable Driving(CD) モデル [Knospe 00] では, 各車に対してブレーキランプが点灯・消灯の状態を加え, 直前の先行車の

ブレーキランプに応じて速度を決める。さらに、Modified Comfortable Driving(MCD) モデル [Jiang 05] では、直前の先行車のブレーキランプを観測し始める距離に関するパラメータを導入している。CD モデルと MCD モデルでは、**Accelerate**, **Maximize Velocity**, **Decelerate** に変更を加えている。Zamith らは、「直前の先行車の正規分布に従う確率的な減速」を考慮して、**Maximize Velocity** を変更した PCA モデルを提案している。増渕らが提案した ExNS モデルは PCA と同じように「直前の先行車の予測速度」を考慮して **Maximize Velocity** を変更するモデルである。PCA と ExNS はどちらも「直前の先行車」の挙動を考慮して走行するモデルであるが、その先行車が **Decelerate** で減速するか否かを確率的に考慮するか (PCA), 決定的に考慮するか (ExNS) の違いがある。Anticipatory Drivers(AD) モデル [Schneider 02] は、ExNS を一般化したモデルである。

著者らは、確率的な減速は場所 (セル) に起因していると考え、AD モデルをマルチセグメント交通流に拡張した [Ishikawa 15]。AD モデルでは人間が複数台の先行車を観測しながら走行するが、人間の観測能力には限界があり現実的なモデルとはいえなかった。そこで、AD モデルに車車間通信に関するパラメータを導入し、車車間通信可能な自動運転車が隊列走行を行う GNS モデルを提案した [石川 16]。GNS モデルによってセルオートマトンモデルで初めて車車間通信による隊列走行がモデル化された。

3.2 交通流の解析

3.2.1 速度の揺らぎによる交通渋滞

本論文では、単車線道路の走行ルールである GNS モデルを用いて交通流の解析をおこなう。関連研究では NS モデルを基礎とした複数車線の走行ルールはいくつか提案されており [Rickert 96, Knospe 99, Knospe 02, Daoudia 03]、複数車線道路における解析も進められている。ここでは、車線変更によって生じる速度の揺らぎと、本論文が対象とする速度の揺らぎの違いを説明した後、単車線道路で実験を進める理由を述べる。

まずは、NS モデルを基礎とした複数車線の走行ルールについて説明する。単車線道路の走行ルールである NS モデルは、二車線道路の走行ルール [Rickert 96, Knospe 99, Knospe 02] や、三車線道路の走行ルール [Daoudia 03] に拡張されている。実際の高速道路では車の種類によって制限速度が異なることがある。この種類の違いを単車線道路のモデルで再現しようとしたとき、制限速度の遅い車を追従する車列が形成され、平均速度が遅い車の制限速度と一致してしまう [Rickert 96]。この問題に対処するために、NS モデルに車線変更ルールを導入し、制限速度の速い車が遅い車を追い越す現象を再現している。

複数車線道路モデルにおいて、車の追い越し、車線変更の禁止、ドライバの車線の好みが生渋滞の発生原因となる [Knospe 02]。これらはすべて、不適切なタイミングにおける車線変更が生渋滞を引き起こすことを示唆している。車線変更ルールには変更先の車線に存在する後続車両をどの程度考慮するかを定めるパラメータがあり、これが車線変更のタイミングに大

大きく影響する。変更先の後続車両を考慮しない場合、つまり、車線変更によって変更先の後続車両の速度を揺らがすような場合、車線変更が渋滞を引き起こす可能性が高くなることが知られている [Knospe 99]。こうした渋滞は三車線道路モデルにおいても確認されている [Daoudia 03]。

ここで、車線変更による渋滞について説明する。渋滞相になる原因としては、図 1.5 を用いて車両密度が臨界密度を超えた場合と、メタ安定相から渋滞相への相転移の場合の二つがあると述べた。車線変更にはどちらの場合にも当てはまる。車線変更がおこると、変更前の道路の密度が減り、変更先の道路の密度が増える。ここで、変更先の道路の密度が臨界密度を超えた場合、メタ安定相か渋滞相へ転移する。また、車線変更先の道路がメタ安定相だった場合、車線変更先の後続車両の速度を揺らがすような車線変更を行うと、メタ安定相から渋滞相への相転移が発生する可能性がある。

本論文が対象としているのは、メタ安定相から渋滞相への相転移を起こす速度の揺らぎであり、車線変更による相転移ではない。したがって、本論文は単車線道路モデルを用いて交通流の解析を進める。車線変更による速度の揺らぎの影響を排除して、手動運転車の速度の揺らぎによる影響だけに着目して交通流の解析をおこなうためである。また、長時間平均の交通流の基本図で交通流を解析する場合、車線数の違いは重要ではないためである。長時間平均の基本図では車線ごとの基本図のピークの高さが異なる程度であり、本質的には同じになるとされている [杉山 03]。

3.2.2 自動運転車の普及する過程の交通渋滞

手動運転車と異なる性能をもつ ACC 車や CACC 車は、車群安定性 (String stability) と交通流量の二つの性能で評価されている。車群安定性は、先行車の車間距離の変動を減衰するか、少なくとも増幅しないことを示す性質である [日高 13]。車群安定性が基準を満たさなければ先行車の挙動の変化である速度の揺らぎが後方に増幅されて伝播する。車群安定性が満たされている車で構成される車群であれば、速度の揺らぎに対しても速度低下は生じないため、揺らぎに起因した渋滞は発生しにくくなる。交通流量は、単位時間当たり通過した車の台数を表し、この値が大きいほど渋滞が抑制されたと評価できる。

車群安定性の評価

[日高 13] 三種類の ACC 車と手動運転車の車群安定性を評価した。車群安定性能が良い順番に並べると、フィードバックゲインが大きい ACC 車、人の特性に近い ACC 車、車間距離のフィードバックゲインが大きい ACC 車、手動運転車となる。

[山村 07] 自動運転車の普及過程における車群安定性を評価した。モデル予測制御により、先行車の車両挙動を考慮する制御を提案し、車群安定性が向上することを示した。

交通流量の評価

[日高 13] 車間時間 2.3 秒の ACC 車が 20% 普及することにより交通流量が増加することを確認した。

[Papacharalampous 15] ACC 車・CACC 車, および状況に応じて ACC 車を制御する Traffic State-Adaptive (TSA)-ACC の三種類について旅行時間を比較し, ACC 車, CACC 車, TSA-ACC 車の順に旅行時間が削減されることを示した。旅行時間が削減されれば単位時間あたりに通過する車の台数が増えるため, 交通流量も増加する。状況に応じた制御のなかでも特に旅行時間の削減に貢献するのは, 停止と発進を繰り返す渋滞の中を走行する状況とその車列から離れる状況において, 車間時間を短くして走行することであると示した。

本論文は交通流量で評価する。交通流の基本図としてプロットすることにより渋滞の発生有無を観察する。関連研究では, 車車間通信の性能と渋滞の抑制効果の関係性については言及していない。また, 本論文では車車間通信をパラメタにできる GNS モデルを用いることにより, この関係性について明らかにする。

3.3 交通流の最適化

3.3.1 交通流の制御方法

交通流の基本図上で, 交通渋滞の抑制を目的とした最適化を考える場合, 図 3.1 に示す制御方法が考えられる。

- (a) **メタ安定相の維持 (Maintaining meta-stable phase)** 車両密度が臨界密度よりも大きく交通流がメタ安定相の場合, 渋滞相への転移を防ぎメタ安定の交通流量を維持する。
- (b) **渋滞からの復帰 (Increasing queue discharge rate)** 車両密度が臨界密度よりも大きく交通流が渋滞相の場合, 渋滞相からメタ安定相へ復帰させ, 交通流量を増やす。
- (c) **臨界密度の増大 (Increasing the critical density)** 臨界密度を大きくすることにより, 自由走行相となる車両密度を大きくする。
- (d) **車両密度の調整 (Controlling traffic density)** 車両密度が臨界密度を超えないように, 道路上の車両密度を調整する。

(a), (b), (c), (d) の順に, 達成できる交通流量は大きくなる。

制御対象の道路は高速道路と一般道路がある。高速道路と一般道路の定義は国によって様々である。高速道路の一般的な特徴としては, 高速で走行, インターチェンジやジャンクションによる流入出, 直線が多い自動車専用道路であることなどが挙げられる。一方, 一般道路の特徴としては, 高速道路よりも低速で走行, 信号機のある交差点を通過, 急カーブを含み, 歩行者や自動車と共用の道路であることが挙げられる。一般道路では, 信号機の制御

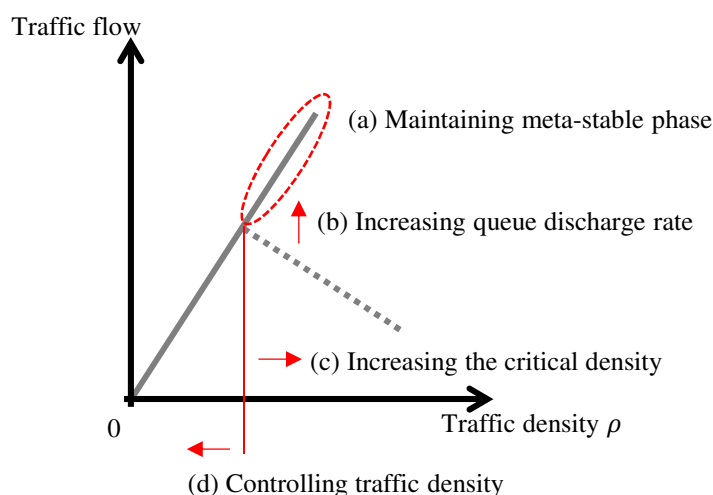


図 3.1: 交通流量を最大化する方法の分類.

[Khamis 14] やルート案内 [Zolfpour-Arokhlo 14] などの方法があるが、ここでは、本論文と同様に、高速道路で発生する交通渋滞を対象とした関連研究をまとめる。

表 3.3: 高速道路を対象とした交通流の制御方法の分類.

	強化学習を未使用	強化学習を使用
(a) メタ安定の維持	状況に応じた速度変更 [Kesting 08, Kesting 10] 車線変更規制 [Patire 11]	ランプメータの切り替え [Rezaee 12]
(b) 渋滞からの復帰	速度回復の情報提供 [Xing 07, Sato 09] 車間距離の情報提供 [Hatakenaka 06]	ペースカー [許 13]
(c) 臨界密度の増大	CACC の隊列走行 [Van Arem 06, Ploeg 11] CACC の制御 [Milanés 14]	ACC の制御 [Wang 15] CACC の制御 [Desjardins 11]
(d) 車両密度の調整	混雑料金 [赤松 88, 文世 93]	ルート案内 [Zolfpour-Arokhlo 14] 制限速度の変更 [Walraven 16]

(a) メタ安定相の維持 (Maintaining meta-stable phase) に向けた制御

メタ安定相を維持するためには、相転移の原因となる速度の揺らぎを発生させないことが重要となる。状況に応じた制御 [Kesting 08] では、自動運転車が、他の手動運転車が起こした揺らぎを軽減するために、揺らぎが発生する状況を特定し、各状況に応じて車間距離や速度を変更する。ランプメータの切り替え [Rezaee 12] では、合流時のタイミングによって速度の揺らぎが発生することに着目し、車の合流タイミングをランプメータで指示する。メタ安定相の交通流において車線変更も車線変更も速度の揺らぎの原因となるため、路車間通信器や電光掲示板などを通して、車線変更の抑制を促す。

(b) 渋滞からの復帰 (Increasing queue discharge rate) に向けた制御

渋滞から復帰するためには、道路上の停止と発進を繰り返す車列をなるべく早く解消する必要がある。車列を解消するためには、車列への流入率よりも、車列からの流出率を大きくする。速度回復の情報提供とは、車列から流出するときに強くアクセルを踏むことを促し、流出率を大きくする。ペースカーは、車列への流入率を小さくするために、車列の後方で速度を調整しながら走行する。このとき、ペースカーは追い越しできないものとする。

(c) 臨界密度の増大 (Increasing the critical density) に向けた制御

臨界密度を増大するには、短い車間距離で走行する必要がある。人間は状況を認知してから判断・操作に至るまでに一定の時間を要するため、今以上に車間距離を短くして走行することはほとんど不可能である。そこで、人に代わり、機械的な制御が可能な ACC 車や CACC 車によって短い車間距離の走行を実現する。ACC 車の場合、車両単体のセンサによる情報入力となるため、比較的長めの車間距離が必要になる。一方 CACC 車の場合、より短い車間距離、制御範囲 (加減速の大きさ) の拡大を実現し、臨界密度の増大や空気抵抗の低減に寄与することになる。

(d) 車両密度の調整 (Controlling traffic density) に向けた制御

車両密度が臨界密度よりも大きくならないように、高速道路に流入する車の台数を制御する。車両密度が臨界密度に近いほど、高速道路に流入する車に高い料金を請求する混雑料金 [赤松 88, 文世 93] や、臨界密度を超えないように他のルートに割り当てる制御 [Zolfpour-Arokhlo 14] がある。

本論文の対象問題では、道路の車両密度 ρ と普及率 μ に対応する自動運転方策 $\pi_{\rho,\mu}$ によって交通流を制御する。各車両密度に対して制御することから、図 3.1 の分類のうち (a) と (b) に相当する。

3.3.2 状況に応じた自動運転車の制御

交通流の制御に関する研究を制御する対象で分類すると、本論文は車の車間距離や加速度を制御する研究となる。状況に応じた速度変更により、交通流を制御できることが様々な論文で主張されている。例えば、一台の車に制御則を導入した場合、制御対象の車の前方で発生した速度の揺らぎを後続へ伝播させるのを防ぐために、減速度を小さくしたり車間距離を大きくしたりする [Kamal 14]。すべての車に制御則を導入した場合、道路上の車が同じ制御則にしたがって動き、車車間通信による混雑情報の共有による交通流制御や [Forster 12] や、隊列走行による交通流制御 [Ishikawa 15, 石川 16] の方法が提案されている。

表 3.4: 一部の車に渋滞低減に向けた制御則を導入した関連研究における制御対象と制御則の設計方法をまとめた表.

	[Knorr 12]	[Kesting 08]	[Forster 14] [Won 17]	[Papacharalampous 15]	[Ishikawa 18]
制御対象	車載システム	ACC	CACC	(TSA-)ACC&CACC	ACC&CACC
設計方法	ハンドコード	ハンドコード	ハンドコード	ハンドコード	強化学習

また、表 3.4 に示すとおり、一部の車に制御則を導入し、交通流を制御する研究もある。Knorr らは車車間通信を搭載した車が後方車に対して情報を発信する状況において、その情報から予測した交通状況をもとに、ドライバに車間距離を大きく維持するように警告する車載システムを提案している [Knorr 12]。Kesting らは走行しながら予測した交通状況に合わせて制御則を切り替える ACC 車を提案している [Kesting 08]。Forster らは車車間通信により得られた先行車情報をもとに、速度の揺らぎを後続に伝播するのを防ぐだけでなく、車両密度の偏りを均一に再配分する制御則を提案している [Forster 14]。Won らは車線情報を加えて車車間通信することにより、車線事に交通流を制御できるようにした [Won 17]。さらに、ファジーを用いた交通状況の特定法を提案し、交通流のダイナミクスの予測精度を上げている。Papacharalampous らは、ACC, Traffic State-Adaptive(TSA-ACC), CACC が 10% 普及した交通流についてそれぞれ解析し、どの制御則も交通流量を増加させることを確認している [Papacharalampous 15]。その中でも、予測した交通状況に応じて、追従するときの車間距離を変える TSA-ACC が一番交通流量を増加させることを明らかにしている。

表 3.4 の既存手法と本論文の提案手法との違いは、制御則の設計方法にある。既存研究についてはそれぞれの制御則の設計方法に言及しておらず、導入する交通流ごとにハンドコードが必要になる。速度の揺らぎや路車間・車車間協調を考慮しながら、多種多様な交通状況に合わせて制御則をハンドコードしなければならないため、シミュレーションを用いて設計者が試行錯誤する既存研究の方法は非常に困難だといえる。これに対して、強化学習を用いる本論文の提案手法は、設計者に代わって制御則を設計する方法となっている。

3.3.3 強化学習による交通流制御

強化学習を用いた交通流制御に関する研究についてまとめ、提案手法との違いについて説明する。表 3.5 は、関連研究を制御対象と学習手法で分類している。

Walraven らは、一定間隔に分割した道路区間を制御対象、それぞれの区間の制限速度を方策として Q-learning で学習させる方法を提案している [Walraven 16]。Rezaee らは高速道路の合流部のランプメータを制御対象として、これの切り替え制御を k nearest neighbors temporal difference(k NN-TD) で学習させ、従来制御よりも旅行時間を減らせることを示している [Rezaee 12]。Khamis らは信号機を制御対象として、多目的かつマルチエージェントの強化学習手法を提案している [Khamis 14]。Zolfpour-Arokhlo らは、車のナビゲーションを制御対象として、マルチエージェント強化学習によるルート計画システムを提案し、旅行

時間が削減されることを示している [Zolfpour-Arokhlo 14]. 本研究が車の速度を制御対象としているのに対して、これらの既存研究は車の速度以外を制御対象としている。

表 3.5: 強化学習による交通流制御の関連研究

	[Walraven 16]	[Rezaee 12]	[Khamis 14]	[Zolfpour-Arokhlo 14]	[許 13]	[Ishikawa 18]
制御対象	制限速度	ランプメータ	信号機	車のナビゲーション	ペースカー	複数の車
学習手法	RL	RL	MOMARL	MARL	RL	MARL

車の速度を制御対象としている研究として文献 [許 13] がある。この論文では交通流の中にペースカーを導入し、特定の速度で走行することにより、後続車両を渋滞相からメタ安定相へ復帰させる方法を提案している。ペースカーが走行する速度を Q-learning で学習させることにより、復帰制御が可能であることを示している。この論文はペースカー一台を制御対象としているが、本論文の提案手法では複数台の自動運転車を制御対象としている。また、図 3.1 の分類に従えば、本論文の提案手法では復帰制御だけでなく、メタ安定相の維持制御もおこなう点でペースカーとは異なる。

第4章 車車間の協調：隊列走行のモデル化

4.1 序言

手動運転車および車車間通信による隊列走行ができる自動運転車をモデル化する対象問題に対して、新しいセルオートマトンモデルを提案する。既存のセルオートマトンモデルでは、隊列走行の車モデルは無かったが、代表的なセルオートマトンモデルの一つである、Nagel-Schreckenberg(NS) モデルを一般化した Generalized Nagel-Schreckenberg(GNS) モデルを提案し、隊列走行する車をモデル化する。GNS モデルはパラメタによって手動運転車と自動運転車の二つの交通流を再現することができる。計算機実験では、二つの交通流の基本図をプロットする。手動運転車の基本図は、実際の観測データの基本図と比較することにより、基本図に現れる性質および、実データの再現性について考察する。隊列走行する車の基本図では、車車間通信することによって手動運転車よりも短い車間距離で走行できることを確かめる。

以下、4.2 節ではセルオートマトンモデルに用いる記号の整理と、NS モデルおよび GNS モデルに関連する NS モデルの発展形について説明する。4.3 節では、提案する GNS モデルについて説明し、車車間通信を用いた隊列走行に必要な車間距離の条件について示す。4.4 節では、計算機実験の設定と結果を示し、4.5 節で結果の考察をおこなう。最後に 4.6 節で本章をまとめと、次章への関連について説明する。

4.2 セルオートマトンモデル

4.2.1 記号の整理

図 4.1 にセルオートマトンモデルで用いる記号の定義を示す。時間・空間・速度を離散表現するセルオートマトンモデルでは、道路を一行に並べたセルで表す。各セルは「車が1台存在する」もしくは「車が存在しない」のいずれかの状態を取り、「車が2台以上存在する」という車の衝突に相当する状態は生じない。シミュレーション内の時刻 (time step) t において、車 i の直前の先行車を $i+1$ 、2 台前の先行車を $i+2$ のように、 n 台前の先行車を $i+n$ と表す。また、座標を $x_i(t)$ 、車 i と $i+1$ の車間距離を $g_i[\text{cell}]$ 、速度を $v_i(t)[\text{cell}/\text{time step}]$ と表す。




図 4.1: セルオートマトンモデルに用いる記号.

4.2.2 Nagel-Schreckenberg モデル

NS では前方のセルが空いていれば前に進み, 追い越しをせず, 前に車があれば減速して停止する, という単純な車の挙動をモデル化している. また, 時刻 t においてすべての車が同期的に走行ルールを適用するパラレルアップデートをおこなう. アルゴリズム 4.1 に NS モデルの車 i の走行ルールを記す. 時刻 t において, 座標 $x_i(t)$, 速度 $v_i(t)$, 車間距離 g_i を入力して走行ルールを実行し, 次時刻の座標 $x_i(t + 1)$ を出力する. 以下, 走行ルールの四つの構成要素 **Accelerate**, **Maximize Velocity**, **Decelerate**, **Move** を実行する順に説明する.

アルゴリズム 4.1: NS for vehicle i ($x_i(t), v_i(t), g_i$)
Accelerate
1: $v_i(t + 1) \leftarrow \min(v_i(t) + 1, v^{\text{limit}})$
Maximize Velocity
2: $v_i(t + 1) \leftarrow \min(v_i(t + 1), g_i)$
Decelerate
3: $v_i(t + 1) \leftarrow \max(v_i(t + 1) - 1, 0)$ probability p
Move
4: $x_i(t + 1) \leftarrow x_i(t) + v_i(t + 1)$

Accelerate

「車は 1[time step] に 1 ずつ加速できる」という制約の下, 車 i は制限速度 v^{limit} に達するまでは現時刻の速度 $v_i(t)$ に 1 を加算して加速する. 現時刻の速度 $v_i(t)$ が制限速度 v^{limit} に達していた場合は加速しない.

Maximize Velocity

直前の先行車と「衝突しない」および「追い越さない」という制約の下, 座標 $x_i(t)$, 速度 $v_i(t)$, 車間距離 g_i の情報を入力として, 次時刻の速度 $v_i(t + 1)$ を最大化する.

Decelerate

「後進しない (速度が負の値にならない)」という制約の下、次時刻の速度 $v_i(t+1)$ に 1 を減算して減速する。これは確率 $p = \{p | 0 \leq p \leq 1\}$ で実行される。

Move

次時刻の速度 $v_i(t+1)$ に基づいて、次時刻の座標 $x_i(t+1)$ を計算する。

5.3.2 項で述べたとおり、本論文が手動運転車のモデルに求める要件は以下の三つである。

- 自車の情報と直前の先行車の情報を入力する。
- 直前の先行車の情報から挙動を予測し、その予測を考慮しながら走行する。
- 速度の揺らぎによって速度が変化する場合がある。

Decelerate ルールによって速度の揺らぎがモデル化されているが、他の二つの要件が満たされていない。アルゴリズム 4.1 に示した走行ルールでは、車 i の走行は車 i の情報だけを入力としている。これでは、先行車 $i+1$ の予測できない。これに対して、次に紹介する Extended Nagel-Schreckenberg (ExNS) モデルでは、先行車 $i+1$ の速度 $v_{i+1}(t)$ と車間距離 g_{i+1} も入力し、直前の先行車の挙動を予測して走行することをモデル化している。二つのモデルの交通流の基本図を比較すると、NS モデルでは再現できないメタ安定相を、ExNS モデルでは再現できることがわかる [増淵 09]。

4.2.3 Extended Nagel-Schreckenberg モデル

ExNS モデル [増淵 09] では「車を運転するドライバーは直前の先行車情報 (速度 $v_{i+1}(t)$, 車間距離 g_{i+1}) も考慮しながら走行する」という立場をとる。これに伴ってアルゴリズム 4.1 の **Maximize Velocity** を変更する。

アルゴリズム 4.2 に ExNS モデルの車 i の走行ルールを記す。NS モデルと異なる箇所はアルゴリズム 2 行目と 3 行目である。2 行目では、「先行車 $i+1$ は必ず減速する」および「先行車 $i+1$ は後進しない」という制約の下、先行車 $i+1$ の予測速度 v_{i+1}^{pred} を求める。3 行目では、自車 i の車間距離 g_i と先行車の予測速度 v_{i+1}^{pred} から、次時刻の速度 $v_i(t+1)$ を最大化する。

ExNS モデルは本論文が手動運転車のモデルに求める三つの要件をすべて満たしている。したがって、本論文は ExNS モデルを手動運転車のモデルとして用いることにする。

4.2.4 Anticipatory Drivers モデル

Anticipatory Drivers (AD) モデル [Schneider 02] は ExNS モデルの予測の部分を一一般化し、 $n^{\text{pred}} > 0$ 台の先行車の挙動を予測しながら走行するモデルである。アルゴリズム 4.3 に AD モデルの車 i の走行ルールを記す。 $n^{\text{pred}} = 1$ のときは ExNS モデルと同じく先行車 $i+1$ の情報から予測速度 v_{i+1}^{pred} を求める。 $n^{\text{pred}} = 2$ のときは、まず先行車 $i+2$ の予測速度 v_{i+2}^{pred} を

アルゴリズム 4.2: ExNS for vehicle i ($x_i(t), v_i(t), g_i, v_{i+1}(t), g_{i+1}$)

Accelerate

1: $v_i(t+1) \leftarrow \min(v_i(t) + 1, v^{\text{limit}})$

Maximize Velocity

2: $v_{i+1}^{\text{pred}} \leftarrow \max(0, \min(v_{i+1}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$

3: $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$

Decelerate

4: $v_i(t+1) \leftarrow \max(0, v_i(t+1) - 1)$ probability p

Move

5: $x_i(t+1) \leftarrow x_i(t) + v_i(t+1)$

求め、次に予測速度 v_{i+2}^{pred} をもとに先行車 $i+1$ の予測速度 v_{i+1}^{pred} を求める。以降、 n^{pred} が増えれば、予測する先行車の台数も増える。

アルゴリズム 4.3: AD for vehicle i ($x_i(t), v_{i+j}(t), g_{i+j}, 0 \leq j \leq n^{\text{pred}}$)

Accelerate

1: $v_i(t+1) \leftarrow \min(v_i(t) + 1, v^{\text{limit}})$

Maximize Velocity

2: $n \leftarrow 1$

3: **while** $n \leq n^{\text{pred}} - 1$ **do**

4: $v_{i+n}^{\text{pred}} \leftarrow \min(v_{i+n}(t) + 1, v^{\text{limit}})$

5: $n \leftarrow n + 1$

6: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}(t), v^{\text{limit}} - 1, g_{i+n} - 1))$

7: **for** $n \leftarrow n - 1$ **to** 1 **do**

8: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}^{\text{pred}}, g_{i+n} + v_{i+n+1}^{\text{pred}}) - 1)$

9: $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$

Decelerate

10: $v_i(t+1) \leftarrow \max(0, v_i(t+1) - 1)$ probability p

Move

11: $x_i(t+1) \leftarrow x_i(t) + v_i(t+1)$

AD モデルでは、人が n^{pred} 台の先行車の挙動を予測することになる。しかし、直前の先行車 $i+1$ よりも前の先行車の挙動を予測することは困難だと考える。

4.3 Generalized Nagel-Schreckenberg モデル

4.3.1 道路モデル

Generalized Nagel-Schreckenberg(GNS) モデルは、セルごとに役割が異なるマルチセグメント交通流モデルである。ここまでに紹介したセルオートマトンモデルは、すべてのセルで同じ確率で **Decelerate** ルールを適用させてきた。しかし、サグやトンネル出入り口で速度の揺らぎが発生しやすいように、減速のしやすさは場所に関係するものと考えられる。そこで、著者らは AD モデルをマルチセグメント交通流モデルに拡張し、セルごとに異なる確率で **Decelerate** ルールを適用する提案をした [Ishikawa 15]。

具体的には、図 4.2 に示すとおり、長さ $L[\text{cell}]$ の道路区間の中に、長さ $l[\text{cell}]$ の速度の揺らぎが発生する区間 ($l \leq L$) を設ける。この区間は実際の道路におけるサグやトンネル出入り口に相当する。この区間で発生する速度 n 揺らぎをきっかけに、車両間隔の不均一化が起こるとメタ安定相から渋滞相への相転移がおこることが期待できる。




図 4.2: 長さ $L[\text{cell}]$ の道路区間にある **Decelerate** ルールが適用される区間 l の例。図では $L = 20\text{cell}$, $l = 5\text{cell}$ 。

4.3.2 走行ルール

Generalized Nagel-Schreckenberg(GNS) モデルは、車車間通信ができる自動運転車が複数台の先行車の挙動を予測できると考える。車車間通信によって挙動を予測できる先行車の台数を $n^{\text{com}}[\text{cell}]$ 、車車間通信ができる距離を $d^{\text{com}}[\text{cell}]$ とする。アルゴリズム 4.4 に GNS モデルの車 i の走行ルールを示す。 $n^{\text{com}} = 0$ の場合、GNS モデルのルールは ExNS モデルと同じになる。通信できる距離 $d^{\text{com}} = \infty$ のとき、GNS モデルと AD モデルの間には、 $n^{\text{com}} + 1 = n^{\text{pred}}$ の関係が成り立つ。

ExNS モデルと比較して、アルゴリズム 4.4 の GNS モデルは **Maximize Velocity** の部分が異なる。2 行目と 3 行目では、通信する先行車との距離 $d \leftarrow g_i + 1$ で、通信する先行車の台数 n を 1 で初期化する。4 行目では、通信する先行車との距離 d が通信できる距離 d^{com} 以内に存在し、かつ通信する先行車の台数 n が通信できる台数 n^{com} 以内であれば、5 から 7 行目を繰り返す。5 行目では、通信する先行車に ExNS ルールを適用するために、その先行車に **Accelerate** ルールを適用する。6 行目と 7 行目では、通信する先行車との距離 d と、通信する先行車の台数を、さらに 1 台前の先行車に更新する。8 行目では、 n 台前の先行車の予測速度 v_{i+n}^{pred} を ExNS モデルと同様に求める。9 行目と 10 行目では、通信した $n - 1$ 台

アルゴリズム 4.4: GNS for vehicle i ($x_i(t), v_{i+j}(t), g_{i+j}, 0 \leq j \leq n^{\text{com}} + 1$)

Accelerate

1: $v_i(t+1) \leftarrow \min(v_i(t) + 1, v^{\text{limit}})$

Maximize Velocity

2: $d \leftarrow g_i + 1$

3: $n \leftarrow 1$

4: **while** $d \leq d^{\text{com}}$ **and** $n \leq n^{\text{com}}$ **do**

5: $v_{i+n}^{\text{pred}} \leftarrow \min(v_{i+n}(t) + 1, v^{\text{limit}})$

6: $d \leftarrow d + g_{i+n} + 1$

7: $n \leftarrow n + 1$

8: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$

9: **for** $n \leftarrow n - 1$ **to** 1 **do**

10: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}^{\text{pred}}, g_{i+n} + v_{i+n+1}^{\text{pred}}) - 1)$

11: $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$

Decelerate

12: $v_i(t+1) \leftarrow \max(0, v_i(t+1) - 1)$ probability p in road section l

Move

13: $x_i(t+1) \leftarrow x_i(t) + v_i(t+1)$

の先行車に ExNS の **Maximize Velocity** ルールを再帰的に適用する。11 行目では、直前の先行車 $i+1$ の予測速度 v^{pred} をもとに、自車 i の次時刻 $t+1$ の速度 $v_i(t+1)$ を求める。

5.3.2 項では、車車間通信する自動運転車である CACC 車の要件は以下の四つである。

- 自車の情報と通信した先行車の情報を入力する。
- 通信した先行車の情報から複数の先行車の挙動を予測し、その予測を考慮しながら走行する。
- n 台の隊列走行をおこなう場合、最後尾の車は n 台前の先頭車と通信する必要がある。
- 隊列走行することにより、手動運転車よりも短い車間距離で走行する。

このうち、アルゴリズム 4.4 の GNS モデルは四つ目を除いて要件を満たしている。四つ目については続く 4.3.3 の車間距離の条件で満たしていることを確認する。

ここまでに紹介したセルオートマトンモデルについては、すべての車が同じ性能でなければならない。つまり、自動運転車の普及過程のような異なる性能の車が走行する状況は再現できない。例えば、GNS モデルの場合、通信台数 n^{com} と通信できる距離 d^{com} はすべての車で等しくなるため、手動運転車 ($n^{\text{com}} = 0, d^{\text{com}} = 0$) と、車車間通信ができる自動運転車 ($n^{\text{com}} > 0, d^{\text{com}} > 0$) が混在する状況は再現できない。異なる性能の車が混在する状況を再現するための GNS モデルは、自動運転車が普及する過程の交通流を解析する必要がある第 5 章で説明する。

4.3.3 制限速度を維持するための車間距離の条件

GNS モデルを隊列走行のモデルとして用いる理由を説明する．ここでは，GNS モデルが車車間通信をおこなうことにより，ExNS モデルよりも短い車間距離で走行できることを示す．

まず，ExNS モデルで制限速度 v^{limit} を維持するための車間距離の条件を確認する．前提条件として，すべての車が制限速度で走行し，かつ確率的減速は発生しないとする．アルゴリズム 4.2 の **Maximize Velocity** に着目する．3 行目では $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$ を計算し，次の時刻 $t+1$ において実現し得る最大の速度を計算している．ここで，先行車 $i+1$ の予測速度は 2 行目の $v_{i+1}^{\text{pred}} \leftarrow \max(0, \min(v_{i+1}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$ で求められる．前提条件により，先行車 $i+1$ も制限速度で走行していることを考慮すると，式 (4.1) を満たせば，車 i は次の時刻でも制限速度を維持できることになる．ここで，ExNS は先行車 $i+1$ が必ず減速すると考えるため，左辺第 2 項に -1 の減算がある．

$$g_i - 1 \geq v^{\text{limit}} - g_{i+1} \quad (4.1)$$

次に，通信できる台数 $n^{\text{com}} = 1$ ，通信距離 $d^{\text{com}} = \infty$ に設定したときの GNS モデルで制限速度 v^{limit} を維持するための車間距離の条件を確認する．前提条件は ExNS モデルと同様に，すべての車が制限速度で走行し，確率的減速は発生しないとする．ここでも，アルゴリズム 4.4 の **Maximize Velocity** に着目する．ExNS モデルと異なるところは二つある．一つ目は，通信する車に加速ルールを適用することである．通信台数 $n^{\text{com}} = 1$ の場合，先行車 $i+1$ の予測速度に $v_{i+1}^{\text{pred}} \leftarrow \min(v_{i+1}(t) + 1, v^{\text{limit}})$ を適用する．二つ目は，先行車 $i+1$ の予測速度を求めるときに，先行車 $i+2$ の予測速度 $v_{i+2}^{\text{pred}} \leftarrow \max(0, \min(v_{i+2}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$ を用いることである．この予測速度 v_{i+2}^{pred} を用いて，加速後の先行車 $i+1$ の予測速度を $v_{i+1}^{\text{pred}} \leftarrow \max(0, \min(v_{i+1}^{\text{pred}}, g_{i+1} + v_{i+2}^{\text{pred}}) - 1)$ として求める．こうして求められた先行車 $i+1$ と $i+2$ の予測速度を用いると，式 (4.2) の車間距離の条件が成り立つ．式 (4.1) と比較すると，先行車 $i+2$ の車間距離 g_{i+2} の大きさだけ制限速度を維持するための条件が緩和されている．

$$g_i - 1 \geq v^{\text{limit}} - (g_{i+1} + g_{i+2}) \quad (4.2)$$

式 (4.2) を一般化すると，式 (4.3) の車間距離の条件を導くことができる．通信できる台数 n^{com} が大きくなるほど，制限速度を維持するために必要な車間距離 g_i が小さくなる．そして，この性質は隊列走行の「車車間通信によって短い車間距離で走行可能になる性質」と同様であると考えられる．これによって，5.3.2 項にある CACC 車の四つの要件を満たすことになる．したがって本論文では通信できる台数 $n^{\text{com}} > 0$ の設定において，GNS モデルが CACC 車をモデル化していると考えられる．ただし，通信距離 d^{com} 内に先行車が存在し，すべての先行車が制限速度で走行しているとする．

$$g_i - 1 \geq v^{\text{limit}} - \sum_{n=0}^{n^{\text{com}}} g_{i+n+1} \quad (4.3)$$

4.4 計算機実験

4.4.1 実験設定

図 4.3 に示すような周期的境界条件の道路モデルを用いて交通流の基本図を作成する．セルオートマトンモデルの道路モデルは，開放境界条件と周期的境界条件の 2 種類がよく用いられる．開放境界条件では，車を道路に流入する判定と車を道路から流出させる判定が独立しているため，時刻 t の変化に伴う流入量の変化を再現できる．一方，周期的境界条件では，流入や流出がなく，円環の道路上にある車の台数が一定に保てるため，いかなる時刻 t においても車両密度 ρ は変化しない．周期的境界条件の道路を用いることにより，流入出による車両密度の変化の影響を排除し，速度の揺らぎの影響に着目できる．




図 4.3: セルオートマトンモデルにおける周期的境界条件の道路モデル．図は道路の長さ $L = 24\text{cell}$ ，確率的減速が適用される区間 $l = 4\text{cell}$ の道路を示す．

実験では，道路の長さ $L = 100\text{cell}$ ，制限速度 $v^{\text{limit}} = 5\text{cell/time step}$ の設定を用いる．道路の 1cell に最大 1 台の車が存在すること，および実際の車長 (軽自動車 3.4m，小型車 4.7m) を考慮して， 1cell を 10m に換算する．また， 1time step を 2s に換算すると，制限速度 $v^{\text{limit}} = 5$ は 90km/h となる．この値は日本の高速道路制限速度 (普通車・軽自動車が 100km/h，大型車が 80km/h) に相当する．

交通流量は長時間平均となるように 10000time step の平均値を求める．時刻 $t = 0$ から $t = 10000$ まで車を動かした間に，特定のセルを通過した車の台数を計測し，交通流量 $q[\text{volume}/5\text{min}]$ を求める．この計測を 1 試行として，各車両密度に対して 100 試行おこなう．実験結果の基本図には 100 試行のプロットする．

実験は手動運転車のモデル $n^{\text{com}} = 0$ と隊列走行のモデル $n^{\text{com}} > 0$ についてそれぞれおこなう．各モデルは表 4.1 に示す組合せの実験をおこなう．速度の揺らぎが無い $p = 0$ 場合では，ランダム・メタ安定・渋滞の三つの配置で実験する．ランダム配置では，ランダムに車を配置した後，走行ルール上起こり得ない配置を除くために 1000time step 動かして時刻 $t = 0$ とする．メタ安定相配置では，車を制限速度で均等な間隔で配置する．渋滞相配置では，停止している車を車間距離 $g = 0$ で配置する．速度の揺らぎがある場合では，速度の揺らぎ $p = 0.05, 0.1, 0.2, 0.25, 0.5, 0.75$ ，揺らぎ区間 $l = 5, 10, 25, 50, 100$ の実験をおこなう．

表 4.1: 速度の揺らぎ p , 揺らぎ区間 l , 配置 (ランダム・メタ安定・渋滞) の設定の組み合わせ.

速度の揺らぎ	揺らぎ区間	初期配置
$p = 0$	$l = 0$	ランダム・メタ安定・渋滞
$p = 0.05, 0.1, 0.2, 0.25, 0.5, 0.75$	$l = 5, 10, 25, 50, 100$	ランダム

4.4.2 手動運転車モデルの交通流の基本図

速度の揺らぎが無い場合

図 4.4 に減速確率 $p = 0$ の道路における, GNS の手動運転車モデル ($n^{\text{com}} = 0$) の交通流の基本図を示す. ランダム (random), メタ安定 (meta-stable), 渋滞 (jam) の配置の結果をプロットした. ランダム配置では, 車両密度 20volume/km を臨界密度として, 交通流の基本図に現れる三つの相 (自由走行相, メタ安定相, 渋滞相) をすべて再現できている. 一方, メタ安定配置では自由走行相とメタ安定相の二つ, 渋滞配置では自由走行相と渋滞相の二つの相しか再現できていない. つまり, 速度の揺らぎが無い場合, 初期配置によって再現できる相が決まり, 相転移も起こらないことが示された.

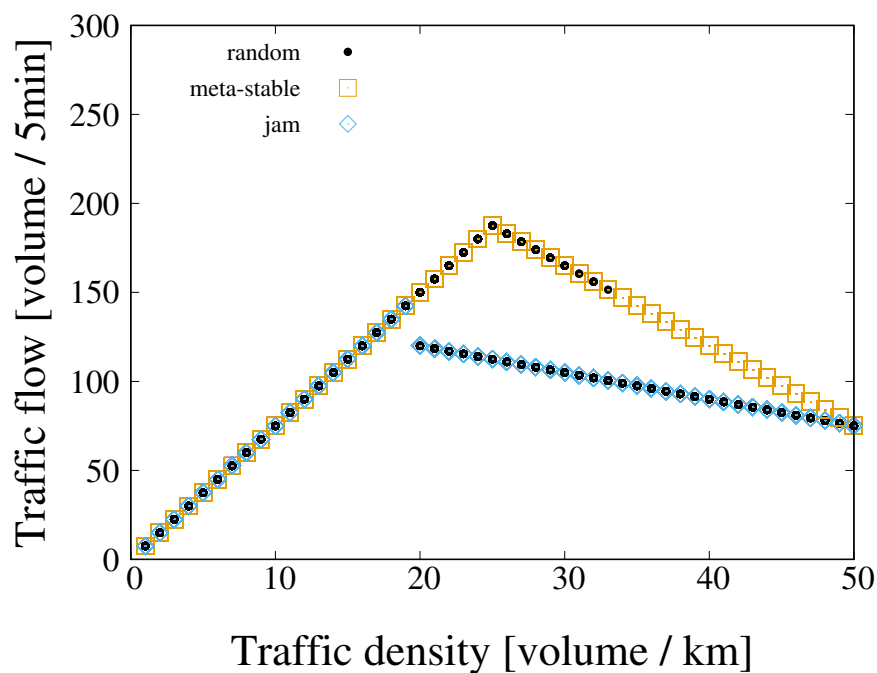


図 4.4: 速度の揺らぎが無い環境における, GNS の手動運転車モデル ($n^{\text{com}} = 0$) の交通流の基本図. ランダム (random), メタ安定 (meta-stable), 渋滞 (jam) の初期配置の結果を示す.

速度の揺らぎがある場合

図 4.5 から図 4.16 には、揺らぎ区間 $l = 5, 10, 20, 25, 50, 75$ の設定に対して、揺らぎ確率 $p = 0.05, 0.1, 0.2$ と $p = 0.25, 0.50, 0.75$ における手動運転車モデル ($n^{\text{com}} = 0$) の交通流の基本図を示す。揺らぎの区間 l が長くなるほど、また、揺らぎの確率 p が大きくなるほど、達成できる交通流量が小さくなる。揺らぎ区間 l が短く、かつ揺らぎの確率 p が小さい場合に、交通流の基本図に現れる三つの性質 (自由走行相, メタ安定相, 渋滞相) をすべて再現できているが、それ以外の場合ではメタ安定相は現れなくなる。

揺らぎの区間 l の長さによって、交通流の基本図の形も変化する。揺らぎ区間 l の長さが比較的長い $l = 50, 75$ では、車両密度の増加に伴い交通流量が徐々に下がる傾向がある。一方、揺らぎ区間 l の長さが比較的短い $l = 5, 10$ では、臨界密度を超えた後、交通流量は急激に減少する。例えば、図 4.8 の減速確率 $p = 0.75$ のプロットでは臨界密度 $\rho = 15$ 付近において、交通流量 $q = 100$ あたりの自由走行相から、交通流量 $q = 50$ 以下の渋滞相まで急激に減少している。

4.4.3 隊列走行モデルの交通流の基本図

速度の揺らぎが無い場合

図 4.17 から図 4.22 には、速度の揺らぎが無い環境における隊列走行のモデル $n^{\text{com}} > 0$ の交通流の基本図を示す。車車間通信できる距離 $d^{\text{com}} = L = 100\text{cell}$ として、必ず車車間通信ができる設定にしている。ランダム (random), メタ安定 (meta-stable), 渋滞 (jam) の配置の結果をプロットした。手動運転車のモデル $n^{\text{com}} = 0$ と同様に、ランダム配置では自由走行相, メタ安定相, 渋滞相の三つの相をすべて再現できているが、メタ安定配置や渋滞配置では二つの相しか再現できていない。

車車間通信ができる台数 n^{com} が大きくなるほど、高密度でもメタ安定相を発生させている。車車間通信ができる台数 $n^{\text{com}} = 1$ の図 4.17 では最高流量として、車両密度 $\rho = 25\text{volume/km}$ で交通流量 $q = 187.5\text{volume}/5\text{min}$ を達成している。一方、車車間通信ができる台数 $n^{\text{com}} = 6$ の図 4.22 では最高流量として、車両密度 $\rho = 40\text{volume/km}$ で交通流量 $q = 300\text{volume}/5\text{min}$ を達成している。

車車間通信できる台数 n^{com} が大きくなっても、渋滞相に陥ったときの交通流量には変化がみられなかった。

速度の揺らぎがある場合

図 4.23 から図 4.34 までには、車車間通信台数 $n^{\text{com}} = 2$ における交通流の基本図を示す。車車間通信ができるのは、速度の揺らぎを起こさない自動運転車としているが、ここでは、速度の揺らぎを発生させている。手動運転車の基本図と同様に、揺らぎの区間 l が長くなる

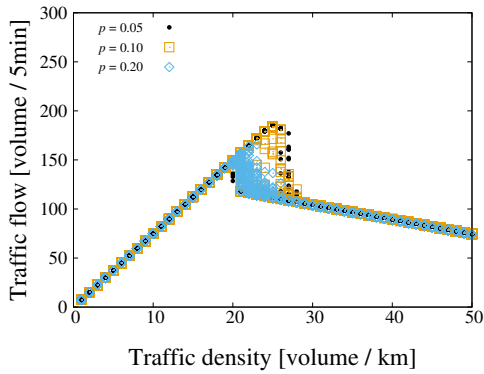


図 4.5: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 5$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.6: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 5$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.7: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 10$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.8: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 10$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.9: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 20$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.10: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 20$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.11: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 25$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.12: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 25$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.13: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 50$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.14: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 50$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.15: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 75$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.16: 手動運転車モデル ($n^{\text{com}} = 0$) の基本図. 揺らぎ区間 $l = 75$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.17: 速度の揺らぎが無い環境における, GNS の隊列走行モデル ($n^{\text{com}} = 1$) の交通流の基本図.

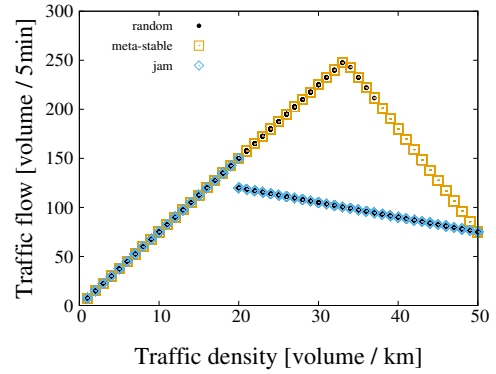


図 4.18: 速度の揺らぎが無い環境における, GNS の隊列走行モデル ($n^{\text{com}} = 2$) の交通流の基本図.

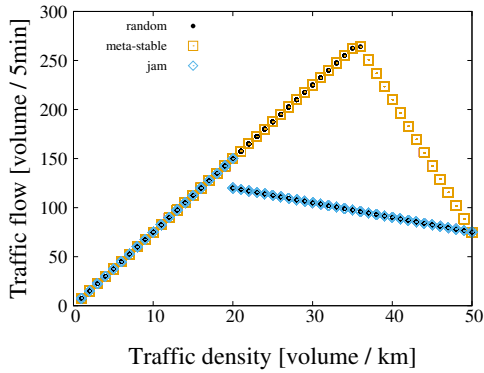


図 4.19: 速度の揺らぎが無い環境における, GNS の隊列走行モデル ($n^{\text{com}} = 3$) の交通流の基本図.

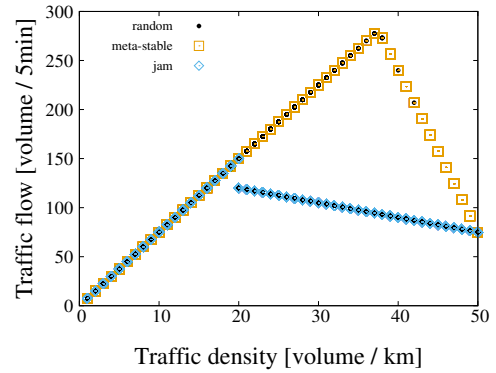


図 4.20: 速度の揺らぎが無い環境における, GNS の隊列走行モデル ($n^{\text{com}} = 4$) の交通流の基本図.




図 4.21: 速度の揺らぎが無い環境における, GNS の隊列走行モデル ($n^{\text{com}} = 5$) の交通流の基本図.




図 4.22: 速度の揺らぎが無い環境における, GNS の隊列走行モデル ($n^{\text{com}} = 6$) の交通流の基本図.

ほど、また揺らぎの確率 p が大きくなるほど達成できる交通流量は小さくなっている。また、揺らぎの区間 l が比較的短く、揺らぎの確率 p が比較的小さい場合に限り、メタ安定相が現れる。

図 4.5 から図 4.16 までの手動運転車の結果と比較して全体的に交通流量が大きくなっていることに加えて、揺らぎ区間 $l = 5, 10$ では臨界密度が大きくなっている。例えば、手動運転車のモデル $n^{\text{com}} = 0$ の図 4.8 と隊列走行のモデル $n^{\text{com}} = 2$ の図 4.26 を比べる。隊列走行の場合、車両密度 $\rho = 20$ が臨界密度となり、その密度まで自由走行相が維持されているが、手動運転車のモデルでは車両密度 $\rho = 15$ 付近が臨界密度となり、その密度から渋滞相へ転移している。

4.5 考察

4.5.1 交通流の基本図の再現

GNS の交通流の基本図を確認し、GNS の交通流の再現性について考察する。現実の交通データの交通流の基本図には自由走行相、渋滞相、メタ安定相の三つの相が現れる。これら三つの相が GNS の交通流の基本図に現れれば、GNS は現実の交通流を再現していると考えられる。図 4.4 から図 4.16 までに示した手動運転車モデル ($n^{\text{com}} = 0$) の交通流の基本図では、三つの相が確認できる。つまり、GNS モデルは手動運転車が走る現実の交通流を再現できているといえる。

メタ安定相を再現できない NS モデルに対して、GNS モデルの手動運転車 ($n^{\text{com}} = 0$)、すなわち ExNS モデルがメタ安定相を再現できる理由については文献 [増淵 09] が言及している。交通流がメタ安定相となるためには、道路上の車は制限速度を維持しなければならない。NS モデルのアルゴリズム 4.1 を確認すると、**Maximize Velocity** において、 $v_i(t+1) \leftarrow \min(v_i(t+1), g_i)$ となるので、制限速度を維持するためには $g_i \leq v^{\text{limit}}$ を満たさなければならない。この条件は車両密度だけに依存するため、車両密度が臨界密度を超えれば渋滞相へ必ず転移する。

これに対して、ExNS モデルのアルゴリズム 4.2 を確認すると、**Maximize Velocity** において $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$ となるので、先行車情報に応じて制限速度を維持できる。ここで、先行車情報は $v_{i+1}^{\text{pred}} \leftarrow \max(0, \min(v_{i+1}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$ である。メタ安定相で先行車 $i+1$ も制限速度で走行していると考えれば、式 (4.1) を満たせば、車 i は次の時刻でも制限速度を維持できることになる。この条件は先行車 $i+1$ と車間距離の両方に依存する。そのため、臨界密度を超える車両密度であっても、先行車 $i+1$ の車間距離に応じてメタ安定相を維持するか、渋滞相に転移するかが決まる。

図 4.35 に文献 [Sugiyama 08] の実データの基本図上に図 4.5 のプロットを重ねた図を示す。黒いひし形のプロットの上に、減速確率 $p = 0.05, 0.10, 0.2$ の三種類のプロットがある。自由走行相、メタ安定相、渋滞相すべてのプロットとほぼ一致していることがわかる。また、

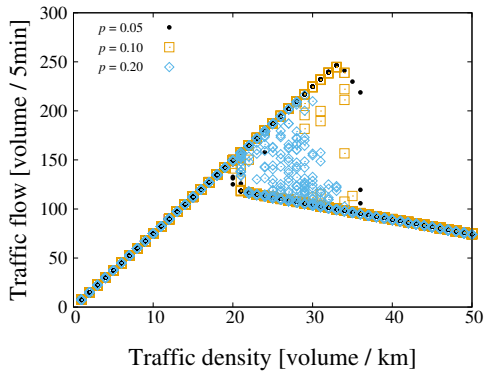


図 4.23: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 5$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.24: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 5$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$

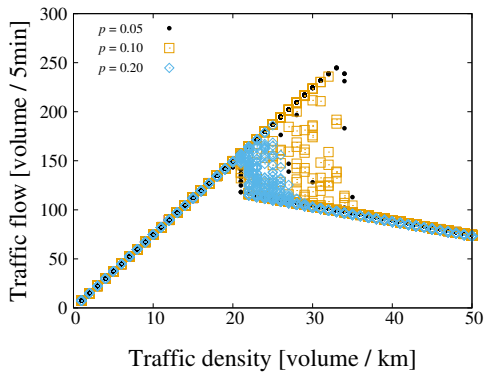


図 4.25: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 10$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.26: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 10$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.27: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 20$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.28: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 20$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$

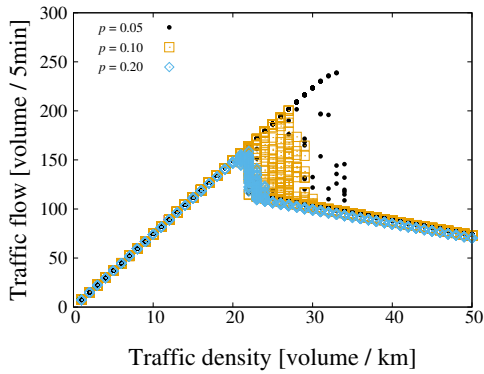


図 4.29: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 25$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.30: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 25$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.31: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 50$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.32: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 50$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$




図 4.33: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 75$, 揺らぎ確率 $p = 0.05, 0.1, 0.20$




図 4.34: 隊列走行モデル ($n^{\text{com}} = 2$) の基本図. 揺らぎ区間 $l = 75$, 揺らぎ確率 $p = 0.25, 0.5, 0.75$

車両密度 $\rho = 20$ 付近で渋滞相が現れていることから、臨海密度もほぼ一致しているといえる。GNS の手動運転車モデル ($n^{\text{com}} = 0$) の減速確率 p や減速する区間 l を調整することによって、実データの再現が可能であることを定性的に示した。




図 4.35: 文献 [Sugiyama 08] の実データの基本図上に図 4.5 のプロットを重ねた図。

4.5.2 車車間通信による隊列走行の再現

GNS モデル ($n^{\text{com}} > 0$) によって隊列走行がモデルかできていることを考察する。隊列走行ができれば、手動運転のときよりも短い車間距離で走行することになる。短い車間距離で走行できれば、到達可能な交通流量の大きさも大きくなる。速度の揺らぎや初期配置の影響を排除するために、速度の揺らぎが無い環境におけるメタ安定相の初期配置の結果を比較する。図 4.4 によれば、手動運転車の場合 ($n^{\text{com}} = 0$)、車両密度 $\rho = 25\text{volume/km}$ で最高流量 $q = 187.5\text{volume}/5\text{min}$ を達成している。一方、図 4.17 によれば、先行車 1 台と車車間通信する ($n^{\text{com}} = 1$) の場合、車両密度 $\rho = 30\text{volume/km}$ で最高流量 $q = 225\text{volume}/5\text{min}$ を達成している。つまり、GNS モデルの通信台数を $n^{\text{com}} > 0$ に設定することにより、手動運転車よりも短い車間距離で隊列走行する車をモデル化できる。

表 4.2 に、通信台数 n^{com} および、最高流量を達成したときの車両密度について記す。通信台数 n^{com} が大きくなるほど、達成した最高流量や車両密度も大きくなる。車車間通信によって獲得できる先行車情報が多くなるほど、短い車間距離で隊列走行し、高密度で高流量の交通流を実現できていることになる。

表 4.2: 速度の揺らぎが無い環境, メタ安定の初期配置における最高流量とそれを達成した車両密度

通信台数 n^{com}	0	1	2	3	4	5	6
最高流量 [volume/5min]	187.5	225	247.5	264	277.5	289.5	300
車両密度 ρ [volume/km]	25	30	33	36	37	39	40

4.5.3 交通渋滞の再現

GNS モデルではセル (場所) に起因して車が減速するマルチセグメント交通流を用いることによりサグやトンネル出入りで発生する渋滞を再現している. このような場所で発生する渋滞は自然渋滞と呼ばれる [西成 06]. 自然渋滞が発生した後に形成される車列の特徴については二つの文献 [越 86, Jiang 05] による道路の観察結果で確認できる.

一つ目は車列の先頭車両が速度の揺らぎが発生する箇所付近にとどまって安定する現象である [越 86]. 車列が形成した後, 車列の先頭車は何らかの理由で揺らぎが発生する区間内を揺らぎ無しで走行できたとしても, 区間の外に出ていなければ揺らぎが発生する可能性が残されているため, 車列全体が区間を通過できなくなる. もし車列の先頭車がある程度速度を持った状態で揺らぎが発生する区間に進入できたとしても, そこで発生する揺らぎで渋滞に至る. 二つ目は速度の揺らぎが上流へ伝播し, 車列の先頭車両が上流へ移動する現象である [Jiang 05].

二つの現象が GNS モデルで再現できることを, 図 4.5 の結果 ($\rho = 25, p = 0.2$) と図 4.6 の結果 ($\rho = 25, p = 0.75$) の時空間プロット図 4.36 と図 4.37 で確認する. 時空間プロットは横軸に車両密度, 縦軸に時刻を示し, 黒いプロットに車両が存在することを示す. 速度が遅いほど濃い色のプロットとなる. 横軸の右端 5cell は減速する区間 l を表している. 図 4.36 では車列の先頭車両が上流へ移動する渋滞を再現し, 図 4.37 では車列の先頭車両が揺らぎが発生する右端付近にとどまって安定する渋滞を再現している. この結果から, GNS の手動運転車モデル ($n^{\text{com}} = 0$) によって, 自然渋滞が発生した後に形成される二種類の車列の特徴を再現できることがわかった. つまり, GNS モデルは交通流の基本図で渋滞相を再現できるだけでなく, 渋滞時に発生する車列の再現もできることになる.

4.6 結言

Generalized Nagel-Schreckenberg(GNS) モデルを提案し, 手動運転車と, 車車間通信ができる自動運転車 (CACC 車) による隊列走行のモデル化をおこなった. 計算機実験では, 手動運転車のモデルと隊列走行のモデルの交通流の基本図をプロットした. 手動運転車のモデルは, 交通流の基本図に現れる自由走行相, メタ安定相, 渋滞相を再現できることに加え, 速度の揺らぎによる渋滞の発生も再現できることがわかった. また, 減速する区間および減速する確率を適切に設定することにより, 実際の観測データに近い交通流データを再現でき




図 4.36: 車両密度 $\rho = 25\text{volume/km}$ における減速する区間 $l = 5$, 減速確率 $p = 0.2$ の時空間プロット




図 4.37: 車両密度 $\rho = 25\text{volume/km}$ における減速する区間 $l = 5$, 減速確率 $p = 0.75$ の時空間プロット

ることを示した。隊列走行のモデルでは、車車間通信によって手動運転車よりも短い車間距離で走行できることを確認した。さらに、車車間通信台数を増やすほど、車間距離を短くできることを示した。これらの結果から、GNS モデルは手動運転車および CACC 車をモデル化できることを示した。

次の章では、このモデルを用いて車車間通信が交通流に与える影響や、自動運転車が普及する過程の交通流の解析をおこなう。

第5章 車車間の協調：交通流に与える影響の解析

5.1 序言

自動運転車が普及する過程の交通流を解析することを対象問題として、GNS モデルの一部を変更した GNS' を提案する。GNS' は異なる通信性能の車を同時に走行させることができるモデルであり、車車間通信ができる自動運転車 (CACC 車) の普及過程を再現することができる。この GNS' を用いて、車車間通信性能と渋滞の抑制効果や交通流量の関係について解析する。計算機実験では、車車間通信性能や自動運転車の普及率を変更し、様々な交通流の基本図をプロットする。プロットした基本図をもとに自動運転車の普及過程の交通流について解析する。

以下、5.2 節では普及過程を調べる前に、隊列走行による渋滞の抑制効果や、車車間通信性能と渋滞抑制効果の関係について述べる。5.3 節では、自動運転者が普及する過程を再現するための GNS' を提案する。5.4 節では、計算機実験の設定と結果を示し、5.5 節で結果を考察する。最後に、5.6 節では、本章のまとめと、次章への関連性について述べる。

5.2 車車間通信が交通流に与える影響

5.2.1 隊列走行による渋滞の抑制

車車間通信ができる自動運転車 (CACC 車) の普及過程を解析する前に、車車間通信の導入前後の渋滞の抑制効果について解析する。

まずは、メタ安定相から渋滞相への相転移の抑制効果に着目する。速度の揺らぎが無い環境における手動運転車の基本図の図 4.4 と、CACC 車 ($n^{\text{com}} = 2$) の基本図の図 4.18 を比較する。メタ安定配置で達成する最高流量には違いがあるが、メタ安定配置では自由走行相とメタ安定相、渋滞配置では自由走行相と渋滞相の二つの相しか現れない。つまり、隊列走行をしても、速度の揺らぎが無ければ相転移が起こらないことは変わっていない。

速度の揺らぎがある環境における手動運転車の基本図の図 4.5 と、CACC 車 ($n^{\text{com}} = 2$) の基本図の図 4.23 を比較する。ここでは車車間通信の導入前後を比較するために、CACC 車にも速度の揺らぎによる減速を加えていることを注意する。CACC 車の方が、メタ安定相のプロットは多くなるが、渋滞相のプロットは無くなっていない。これらの結果から、車

車間通信が導入されても、渋滞相への転移の原因は速度の揺らぎであり、その揺らぎを完全に抑制することはできないことがわかった。

次に、図 4.5 から図 4.16 の手動運転車の交通流の基本図、図 4.23 から図 4.34 の CACC 車 ($n^{\text{com}} = 2$) の隊列走行の交通流の基本図に着目する。ここでも車車間通信の導入前後を比較するために、CACC 車にも速度の揺らぎによる減速を加えていることを注意する。これらの結果を比較すると、減速する区間 $l = 5, 10$ の結果において特に変化がある。図 4.6 や図 4.8 に示す手動運転車の基本図では、減速確率 $p = 0.5, 0.75$ で車両密度が 20volume/km に達する前に渋滞相へ転移している。一方、図 4.24 や図 4.26 に示す CACC 車 ($n^{\text{com}} = 2$) の隊列走行の基本図では、車両密度が 20volume/km に達するまで渋滞相へ転移することはない。つまり、隊列走行をすることによって臨界密度は 20volume/km まで大きくなった。

このときの車の挙動を確認するために、車両密度 $\rho = 18\text{volume/km}$ 、減速確率 $p = 0.75$ 、減速する区間 $l = 10\text{cell}$ における手動運転車と CACC 車の時空間プロットをそれぞれ図 5.1 と図 5.2 に示す。時空間プロットの右端 10 セルが減速する区間 $l = 10\text{cell}$ を示す。図 5.1 の手動運転車の時空間プロットでは渋滞時に発生する車列が形成されている。一方、図 5.2 の手動運転車の時空間プロットでは車列は形成されておらず、右端 10cell で速度の揺らぎが発生しても、後続車両に伝播していないことがわかる。このことは、隊列走行によって車列を形成させずに渋滞を抑制し、自由走行相を実現していることを意味する。

5.2.2 通信性能と渋滞抑制効果の関係

図 5.2 で示した、車列の形成の抑制効果が表れる車車間通信能力を調べた。減速確率 $p = 0.75$ 、減速する区間 $l = 10$ の状況において、車車間通信台数 n^{com} と車車間通信距離 d^{com} を変化させたときの交通流量をプロットする。図 5.3 と図 5.4 は、横軸に車車間通信台数 n^{com} 、縦軸に交通流量を示した図である。図 5.4 の結果から、車車間通信距離 $d^{\text{com}} = 1$ から 6 までは d^{com} が長くなるほど交通流量が大きくなり、 $d^{\text{com}} = 6$ と 7 以上との間では交通流量に差がないことがわかった。図 5.5 と図 5.6 は、横軸に車車間通信距離 d^{com} 、横軸に交通流量を示した図である。両方の図から、 $n^{\text{com}} = 1$ で直前の先行車 1 台と車車間通信する場合よりも、 $n^{\text{com}} = 2$ で直前の先行車 2 台と通信する場合の方は交通流量が大きくなる。直前の先行車 2 台以上の先行車と通信する場合の間では、交通流量に差はなかった。つまり、通信台数や通信距離の大きさが一定以上であれば、渋滞抑制効果が表れることがわかった。

ここまで示したとおり GNS モデルを利用することにより、手動運転車のモデル化、隊列走行のモデル化、および車車間通信性能が交通流に与える影響の解析ができる。しかし、GNS モデルでは道路上のすべての車が同じ性能であることが前提であり、異なる性能の車の混在はモデル化できない。例えば、車車間通信ができる車とできない車(手動運転車)の混在をモデル化することができない。このままでは、車車間通信機能を搭載した自動運転車が普及する過程はモデル化できない。そこで、次の節では異なる性能の車の混在をモデル化するために GNS モデルの変更について説明する。

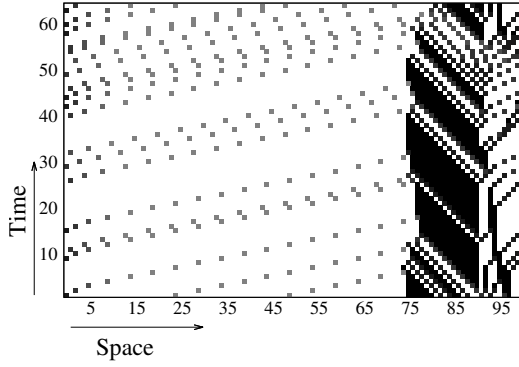


図 5.1: $n^{\text{com}} = 0$, $l = 10$, $p = 0.75$, $\rho = 18 \text{volume/km}$ の時空間プロット




図 5.2: $n^{\text{com}} = 2$, $l = 10$, $p = 0.75$, $\rho = 18 \text{volume/km}$ の時空間プロット




図 5.3: $l = 10$, $p = 0.75$, $\rho = 18 \text{volume/km}$ における車車間通信台数 n^{com} と交通流量 q の関係図. ($d^{\text{com}} = 25, 50, 75, 100$)

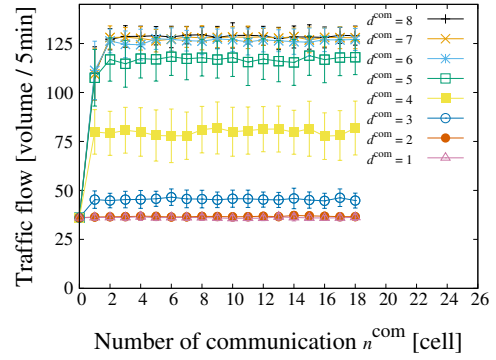


図 5.4: $l = 10$, $p = 0.75$, $\rho = 18 \text{volume/km}$ における車車間通信台数 n^{com} と交通流量 q の関係図. ($1 \leq d^{\text{com}} \leq 8$)




図 5.5: $l = 10$, $p = 0.75$, $\rho = 18 \text{volume/km}$ における車車間通信距離 d^{com} と交通流量 q の関係図. ($n^{\text{com}} = 1, 2, 3, 18$)




図 5.6: $l = 10$, $p = 0.75$, $\rho = 18 \text{volume/km}$ における車車間通信距離 d^{com} と交通流量 q の関係図. ($1 \leq n^{\text{com}} \leq 8$)

5.3 GNS モデルの拡張

5.3.1 拡張の方針

図 5.7 を用いて GNS モデルの車車間通信の概要と問題点を説明する。図 5.7 には、すべて同じ性能 (車車間通信できる台数 $n^{\text{com}} = 3$, 車車間通信できる距離 $d^{\text{com}} = 8$) の自動運転車が 4 台並ぶ。車 i の $d^{\text{com}} = 8\text{cell}$ 以内には、先行車 $i+1$ と $i+2$ が存在するため、予測速度 v_{i+1}^{pred} と v_{i+2}^{pred} を用いて走行することができる。先行車 $i+3$ については、 d^{com} 以内に存在しないため、予測速度 v_{i+3}^{pred} は計算できない。GNS モデルの問題点は、すべて同じ性能の車が道路上に存在する前提としていることである。つまり、車車間通信ができる車とできない車を混在させられない。これでは、車車間通信機能が搭載された自動運転車の普及過程の交通流のモデル化はできない。




図 5.7: GNS モデルの走行ルールにおける車車間通信の例。車車間通信できる台数 $n^{\text{com}} = 3$, 車車間通信できる距離 $d^{\text{com}} = 8$ の白色の自動運転車が走行する。

そこで、普及過程の交通流をモデル化できるように GNS モデルを拡張した GNS' を提案する。図 5.8 を用いて、GNS' の車車間通信の概要を説明する。図 5.8 には、黒色の手動運転車 $i+1$ と、白色の自動運転車 $i, i+2, i+3$ が並んでいる。車 i の $d_i^{\text{com}} = 8\text{cell}$ 以内には、手動運転車 $i+1$ と自動運転車 $i+2$ が存在する。今回、手動運転車には車車間通信機能を搭載しないため、手動運転車 $i+1$ とは通信できない。したがって、予測速度 v_{i+1}^{pred} を計算できない。そのため、車 i は実質 $n^{\text{com}} = 0$ で走行することになる。GNS' ではこのような通信台数の変化に対応した走行ルールを取り入れる。




図 5.8: GNS' の走行ルールにおける車車間通信の例。黒色の手動運転車および車車間通信できる台数 $n^{\text{com}} = 3$, 車車間通信できる距離 $d^{\text{com}} = 8$ の白色の自動運転車が走行する。

5.3.2 走行ルール

アルゴリズム 5.1 に GNS' の走行ルールを示す. GNS' では車ごとに車車間通信の性能を設定でき, 車 i の車車間通信できる台数を n_i^{com} , 車車間通信できる距離を d_i^{com} と設定する. 4 行目には, 車車間通信できる車なら予測速度を求められるように, 先行車の車車間通信台数 $n_{i+n}^{\text{com}} > 0$ という条件を加えた. さらに 12, 13 行目には, 車 i が手動運転車のときだけ確率的減速が適用される条件を加えた.

アルゴリズム 5.1: GNS' for vehicle i ($x_i(t), v_{i+j}(t), g_{i+j}, 0 \leq j \leq n_i^{\text{com}} + 1$)

Accelerate

1: $v_i(t+1) \leftarrow \min(v_i(t) + 1, v^{\text{limit}})$

Maximize Velocity

2: $d \leftarrow g_i + 1$

3: $n \leftarrow 1$

4: **while** $d \leq d_i^{\text{com}}$ **and** $n \leq n_i^{\text{com}}$ **and** $n_{i+n}^{\text{com}} > 0$ **do**

5: $v_{i+n}^{\text{pred}} \leftarrow \min(v_{i+n}(t) + 1, v^{\text{limit}})$

6: $d \leftarrow d + g_{i+n} + 1$

7: $n \leftarrow n + 1$

8: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$

9: **for** $n \leftarrow n - 1$ **to** 1 **do**

10: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}^{\text{pred}}, g_{i+n} + v_{i+n+1}^{\text{pred}}) - 1)$

11: $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$

Decelerate

12: **if** vehicle i is manually-driven vehicle

13: $v_i(t+1) \leftarrow \max(0, v_i(t+1) - 1)$ probability p in road section l

Move

14: $x_i(t+1) \leftarrow x_i(t) + v_i(t+1)$

GNS' で各車に設定したパラメタによって車の種類を区別する. 表 5.1 に車の種類ごとのパラメタを示す. パラメタには, 速度の揺らぎを起こす確率 p , 通信台数 n_i^{com} , 通信距離 d_i^{com} の三つがある. 速度の揺らぎが発生する区間 l において, 手動運転車は確率 p で GNS の **Decelerate** ルールを実行する. 一方, 自動運転車は **Decelerate** ルールを実行しない. 通信台数 n_i^{com} および通信距離 d_i^{com} は CACC 車に $[1, \infty)$ の範囲で設定する.

表 5.1: GNS' のパラメタによる手動運転車, 自動運転車 (ACC・CACC) の区別.

	手動運転車	自動運転車 (ACC)	自動運転車 (CACC)
減速確率 p	$[0, 1]$	-	-
通信台数 n_i^{com}	-	-	$[1, \infty)$
通信距離 d_i^{com}	-	-	$[1, \infty)$

では、ACC車の要件は以下の二つである。

- 自車の情報と直前の先行車の情報を入力する。
- 直前の先行車の情報から挙動を予測し、その予測を考慮しながら走行する。

これにしたがって、本論文はGNSの手動運転車モデル ($n^{\text{com}} = 0$) から確率的な減速を除き、ACC車のモデルとする。

5.4 計算機実験

5.4.1 実験設定

実験設定の大部分は4章の設定と同様とする。図4.3に示した周期的境界条件の道路を用いて長時間平均の交通流量を求め、交通流の基本図を作成する。手動運転車が減速する区間 $l = 5\text{cell}$ 、減速確率 $p = 0.2$ と設定する。これらの値は、図4.35をもとに、実データを再現するGNSの手動運転車モデル ($n^{\text{com}} = 0$) として定性的に決めた。CACC車の通信できる距離 d^{com} は20cellとした。

車はランダムに配置して実験する。不自然な配置を避けるために、道路に車をランダムに配置してから1000time step車を動かした後の時刻を $t = 0$ で走行することになる。その後、時刻 $t = 10000$ まで車を動かした間に、特定のセルを通過した車の台数を計測し、交通流量 $q[\text{volume}/5\text{ min}]$ を求める。この計測を1試行として、各車両密度に対して100試行おこなう。実験結果の基本図には100試行をプロットするか、100試行の平均値をプロットする。

5.4.2 自動運転車が普及する過程の交通流の基本図

図5.9から図5.18には普及率10%から100%の交通流の基本図を示す。CACC車と手動運転車の交通流量 (C+M)、ACC車と手動運転車の交通流量 (A+M)、手動運転車の交通流量 (M) の100試行のプロットを示す。例えば、自動運転車 (ACC車・CACC車) の普及率が50%であれば、残りの50%は手動運転車となる。なお、手動運転車の交通流量 (M) は普及率0%の交通流量であり、普及率100%では手動運転車は存在しない。

自動運転車の普及率が大きくなるにつれて、メタ安定相が表れる車両密度も大きくなっている。メタ安定相で達成する最高流量は、M、A+M、C+Mの順に大きくなっている。具体的に、図5.18では、手動運転車は車両密度 $\rho = 22\text{volume}/\text{km}$ で最高流量 $q = 164.01\text{volume}/5\text{min}$ 、ACC車は車両密度 $\rho = 25\text{volume}/\text{km}$ で最高流量 $q = 187.5\text{volume}/5\text{min}$ 、CACC車は車両密度 $\rho = 30\text{volume}/\text{km}$ で最高流量 $225\text{volume}/5\text{min}$ となっている。渋滞相の交通流量は、M、A+M、C+Mの間で変わらなかった。

A+MおよびC+Mは、同じ車両密度で渋滞相とメタ安定相の両方にプロットされている。普及率が小さいときは、メタ安定相と渋滞相の間にはプロットされているが、普及率が大き

くなるとメタ安定相か渋滞相のどちらかにプロットされるようになり、普及率 100%ではメタ安定相と渋滞相の間にプロットされなくなる。

図 5.19 から図 5.28 は自動運転車の通信台数 $1 \leq n^{\text{com}} \leq 5$ における、CACC 車普及過程の交通流の基本図である。図には 100 試行の平均値と標準偏差を示す。普及率が大きくなるほど交通流量が大きくなっていることが確認できる。しかし、通信台数 n^{com} が大きくなっても、交通流量に変化はない。つまり、自動運転車の普及過程において、車車間通信台数 n^{com} は交通流量には影響しないということになる。

5.5 考察

5.5.1 自動運転車が普及することによる交通流の変化

図 5.9 から図 5.18 までの結果より、ACC 車や CACC 車の普及率が大きくなるほど、メタ安定相が発生する車両密度が大きくなることがわかった。しかし、同じ車両密度でメタ安定相と同時に渋滞相も確認できることから、メタ安定相から渋滞相への転移を完全に防げるわけではない。これは、普及率 10%から、自動運転車が完全に普及した 100%まで同様に確認できる。また、図 5.19 から図 5.28 までの結果から、CACC 車の通信台数 n^{com} が増加したとしても、交通流量が増加していないことがわかった。つまり、車車間通信できる台数が増加したとしても、交通流には影響していない。

これらの結果から、自動運転車の普及による交通流の変化は限定的であるといえる。普及によってもたらされる変化は、高密度でメタ安定相が出現しやすくなること、それに伴って交通流量も増加することである。この変化は自動運転車の普及率が高くなるほど、大きくなる。しかし、ACC 車・CACC 車にかかわらず、渋滞相のプロットが存在することから、渋滞の抑制効果は見込めないことになる。

5.5.2 自動運転車の普及過程で求められる制御

自動運転車 (ACC 車・CACC 車) の普及過程の交通流を解析した結果、メタ安定相を維持する制御と渋滞相からメタ安定相への復帰制御が必要であると考えた。

メタ安定相を維持するには、手動運転車の速度の揺らぎが発生したときに、その揺らぎが後続車両に伝播させないための制御が必要になる。例えば、前方に手動運転車が走行している場合、車間距離を大きくすることによって揺らぎが後続に伝播するのを防ぐことができる [Kesting 08]。実験で用いた GNS' モデルでは、自動運転車に **Decelerate** ルールを適用しないため、衝突しない最大限の速度を維持することになる。ここで、自動運転車が状況に応じて **Decelerate** ルールを適用することによって、速度の揺らぎの伝播を防ぐ制御ができると考えられる。

渋滞相からメタ安定相へ復帰するためには、渋滞時に現れる車列を早期に解消する制御が必要になる。例えば、車列から抜け出すときに通常よりも加速度を大きくして、早く制限

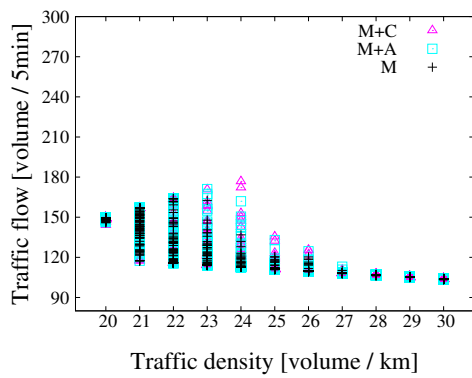


図 5.9: 自動運転方策を導入する前の自動運転車普及率 $\mu = 10\%$ の交通流の基本図




図 5.10: 自動運転方策を導入する前の自動運転車普及率 $\mu = 20\%$ の交通流の基本図




図 5.11: 自動運転方策を導入する前の自動運転車普及率 $\mu = 30\%$ の交通流の基本図




図 5.12: 自動運転方策を導入する前の自動運転車普及率 $\mu = 40\%$ の交通流の基本図




図 5.13: 自動運転方策を導入する前の自動運転車普及率 $\mu = 50\%$ の交通流の基本図




図 5.14: 自動運転方策を導入する前の自動運転車普及率 $\mu = 60\%$ の交通流の基本図




図 5.15: 自動運転方策を導入する前の自動運転車普及率 $\mu = 70\%$ の交通流の基本図




図 5.16: 自動運転方策を導入する前の自動運転車普及率 $\mu = 80\%$ の交通流の基本図




図 5.17: 自動運転方策を導入する前の自動運転車普及率 $\mu = 90\%$ の交通流の基本図




図 5.18: 自動運転方策を導入する前の自動運転車普及率 $\mu = 100\%$ の交通流の基本図




図 5.19: 自動運転方策を導入する前の自動運転車普及率 $\mu = 10\%$ の交通流の基本図




図 5.20: 自動運転方策を導入する前の自動運転車普及率 $\mu = 20\%$ の交通流の基本図

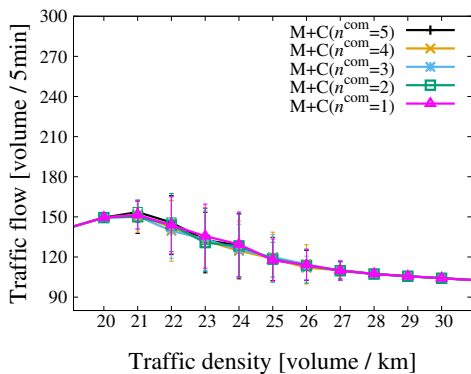


図 5.21: 自動運転方策を導入する前の自動運転車普及率 $\mu = 30\%$ の交通流の基本図




図 5.22: 自動運転方策を導入する前の自動運転車普及率 $\mu = 40\%$ の交通流の基本図




図 5.23: 自動運転方策を導入する前の自動運転車普及率 $\mu = 50\%$ の交通流の基本図




図 5.24: 自動運転方策を導入する前の自動運転車普及率 $\mu = 60\%$ の交通流の基本図




図 5.25: 自動運転方策を導入する前の自動運転車普及率 $\mu = 70\%$ の交通流の基本図




図 5.26: 自動運転方策を導入する前の自動運転車普及率 $\mu = 80\%$ の交通流の基本図




図 5.27: 自動運転方策を導入する前の自動運転車普及率 $\mu = 90\%$ の交通流の基本図




図 5.28: 自動運転方策を導入する前の自動運転車普及率 $\mu = 100\%$ の交通流の基本図

速度に到達したり，車列が長くなるのを防ぐために，低速度で走行して車列に到着するのを遅くする制御がある [Kesting 08]．GNS' モデルでは，**Accelerate** ルールの制約上，1time step に 1 ずつしか加速できない．一方，**Decelerate** ルールを適用することによって，制限速度よりも遅い速度で走行し，車列に到着する時間を遅らせることができる．

5.6 結言

GNS モデルやこれを拡張した GNS' モデルを用いて，車車間通信による隊列走行や自動運転車の普及が，交通流に与える影響を解析した．速度の揺らぎが発生する確率が比較的小さい場合，隊列走行することによって臨界密度を大きくできることを確認した．この効果は，一定以上の通信台数や通信距離であれば得られることも確認した．GNS' を用いた計算機実験では，ACC 車や CACC 車および，CACC 車の通信能力を向上させたときの，自動運転車 (ACC 車・CACC 車) 普及過程の基本図をプロットした．基本図では自動運転車が普及しても渋滞相のプロットが確認できたことから，渋滞相への転移の抑制，つまり渋滞抑制効果はないことがわかった．つまり，これから自動運転車が普及したとしても，速度の揺らぎを起因とした渋滞が抑制されることはないことになる．

次の章では，自動運転車が普及する過程で，自動運転車に状況に応じた制御をすることにより，渋滞を抑制することを目的とする．GNS' の **Decelerate** ルールの制御を，ハンドコードではなく，学習させるフレームワークを提案する．

第6章 路車・車車間の協調：自動運転方策の学習法

6.1 序言

自動運転車の普及過程において、速度の揺らぎによって発生する渋滞を抑制することを対象問題として、自動運転車の制御を獲得する方法を提案する。既存研究でも渋滞抑制に向けた制御を提案しているが、制御の設計方法については言及していない。これでは、導入する交通流ごとにシミュレーションを用いたアドホックな設計が必要になる。そこで、本章では強化学習を用いた自動運転車の制御（以下、自動運転方策と呼ぶ）の獲得法について提案する。計算機実験では、自動運転車の普及過程でかつ速度の揺らぎを起因とした交通渋滞が発生する状況において、自動運転方策の導入前後の交通流の基本図をプロットする。プロットした基本図を比較して自動運転方策の導入効果について確かめる。

以下、6.2節では提案手法の基礎となる強化学習について説明する。6.3節では、強化学習を用いた自動運転方策の学習フレームワークについて提案する。6.4節では、計算機実験の設定と結果を示し、6.5節で結果を考察する。最後に、6.6節では、本章のまとめと今後の課題を示す。

6.2 強化学習

強化学習は、環境とエージェントの相互作用の中でエージェントが方策を学習する枠組である。図 6.1 は強化学習におけるエージェント (Agent) と環境 (Environment) の相互作用の様子を表している。時刻 t において、エージェントは環境から状態 S_t と報酬 R_t を観測し、行動 A_t を実行する。時刻の変化 $t \leftarrow t + 1$ に基づいて、環境 S_{t+1} と報酬 R_{t+1} も変化する。

基本的に強化学習では環境にマルコフ決定過程を仮定し、その環境下でエージェントは方策を学習する。

6.2.1 マルコフ決定過程

マルコフ決定過程は $\langle S, A, P, R \rangle$ で定義される。 S は状態集合、 A は行動集合、 $P : S \times A \times S \rightarrow [0, 1]$ は遷移関数、 $R = (R(s_1), R(s_2), \dots, R(s_{|S|})) : S \rightarrow \mathbb{R}^{|S|}$ の R は報酬、 $R(s)$ は報酬関数である。ここで状態集合の要素は $\{s_i \in S | 0 \leq i \leq |S|\}$ 、行動集合の要素は $\{a_j \in A | 0 \leq j \leq |A|\}$ で示す。時刻 t において、状態 $S_t \in S$ で行動 $A_t \in A$ を取り、次の時




図 6.1: 強化学習におけるエージェント (Agent) と環境 (Environment) の相互作用を表した図. 文献 [Sutton 98] をもとに作成.

刻 $t+1$ で状態 $S_{t+1} \in \mathcal{S}$ に遷移する確率は遷移関数 P を用いて式 (6.1) のとおりに記述することができる. s が遷移前の状態, a が行動, s' が遷移後の状態を表す変数である.

$$P(s, a, s') = p(S_{t+1} = s' | S_t = s, A_t = a) \quad (6.1)$$

マルコフ決定過程における状態遷移は, 図 6.2 のような状態遷移図で表すことができる. 時刻 t において, 状態 $S_t = s_1$ にいるとき, 選択可能な行動は a_1 と a_2 の 2 通りある. 行動 a_1 を選択した場合, 状態遷移確率は $p(s_1, a_1, s_2) = 1.0$ となるので, 次の時刻 $t+1$ で状態 $S_{t+1} = s_2$ に遷移し, 報酬 $R(s_2) = 0.2$ を得る. 行動 a_2 を選択した場合, 状態遷移確率は $p(s_1, a_2, s_2) = 0.5, p(s_1, a_2, s_3) = 0.5$ となるので, 次の時刻の状態は $S_{t+1} = s_2$ か $S_{t+1} = s_3$ に遷移することになり, それに応じて獲得できる報酬は $R(s_2) = 0.2$ および $R(s_3) = 1$ に変わる.




図 6.2: マルコフ決定過程における状態遷移図. (状態 $s_1, s_2, s_3 \in \mathcal{S}$, 行動 $a_1, a_2 \in \mathcal{A}$, 状態遷移 $p(s_1, a_1, s_2) = 1.0, p(s_1, a_2, s_2) = 0.5, p(s_1, a_2, s_3) = 0.5$, 報酬 $R(s_2) = 0.2, R(s_3) = 1$)

図 6.2 の中で, 状態 s_1 で行動 a_2 を選択した方が, より多くの報酬を得られることになる. a_1 を選んだ場合, 獲得できる報酬の期待値は, $0.2 \times 1.0 = 0.2$ となる. 一方, a_2 を選んだ場合, 獲得できる報酬の期待値は, $0.2 \times 0.5 + 1 \times 0.5 = 0.6$ となる. この例に強化学習の枠組みを適用すれば, 状態 s_1 で行動 a_2 を選択するように学習することになる.

6.2.2 Q-learning

エージェントは、式 (6.2) の時刻 t における累積割引報酬 G_t の期待値を最大化する方策 $\pi = p(a|s) : \mathcal{S} \times \mathcal{A} \rightarrow [0, 1]$ の獲得を目的とする。

$$G_t = R(S_{t+1}) + \gamma R(S_{t+2}) + \gamma^2 R(S_{t+3}) + \gamma^3 R(S_{t+4}) + \dots = \sum_{k=0}^{\infty} \gamma^k R(S_{t+k+1}) \quad (6.2)$$

ここで、 γ は割引率であり、将来得られる報酬を割り引くために用いられる。

次に、強化学習において期待累積割引報酬 G_t から導かれる状態価値 $V^\pi(s)$ と行動価値 $Q^\pi(s)$ について説明する。式 (6.3) の状態価値は、特定の方策 π をもとに状態遷移したときの、状態 s における期待累積割引報酬となる。

$$V^\pi(s) = \mathbb{E}_\pi[G_t | S_t = s] \quad (6.3)$$

式 (6.4) の状態価値は、特定の方策 π をもとに状態遷移したときの、状態 s で行動 a の組み合わせにおける期待累積割引報酬となる。

$$Q^\pi(s, a) = \mathbb{E}_\pi[G_t | S_t = s, A_t = a] \quad (6.4)$$

ここで、式 (6.2) は再帰的な関係を用いると、式 (6.5) のとおりに表せる。この方程式はベルマン方程式と呼ばれる。

$$\begin{aligned} G_t &= R(S_{t+1}) + \gamma R(S_{t+2}) + \gamma^2 R(S_{t+3}) + \gamma^3 R(S_{t+4}) + \dots \\ &= R(S_{t+1}) + \gamma \{R(S_{t+2}) + \gamma R(S_{t+3}) + \gamma^2 R(S_{t+4}) + \dots\} \\ &= R(S_{t+1}) + \gamma G_{t+1} \end{aligned} \quad (6.5)$$

このベルマン方程式を用いることより、式 (6.3) の状態価値と式 (6.4) の行動価値はそれぞれ式 (6.6)、式 (6.7) のとおりに記述できる。

$$V^\pi(s) = \sum_{a \in \mathcal{A}} \pi(s, a) \sum_{s' \in \mathcal{S}} p(s, a, s') [R(s) + \gamma V^\pi(s')] \quad (6.6)$$

$$Q^\pi(s, a) = \sum_{s' \in \mathcal{S}} p(s, a, s') [R(s) + \gamma \sum_{a' \in \mathcal{A}} \pi(s', a') Q^\pi(s', a')] \quad (6.7)$$

エージェントが期待累積割引報酬を最大化する方策をもつとき、状態価値と行動価値はそれぞれ式 (6.8) と式 (6.9) を満たす。

$$V^{\pi^*}(s) = \max_{\pi} V^\pi(s) \quad (6.8)$$

$$Q^{\pi^*}(s, a) = \max_{\pi} Q^\pi(s, a) \quad (6.9)$$

式中の π^* は最適方策と呼ばれる。

さらに、最適方策 π^* における行動価値は式 (6.10) と表すことができる。

$$Q^{\pi^*}(s, a) = \mathbb{E}[R_{t+1} + \gamma V^{\pi^*}(S_{t+1}) | S_t = s, A_t = a, S_{t+1} = s'] \quad (6.10)$$

$V^{\pi^*}(s) = \max_{a \in \mathcal{A}} Q^{\pi^*}(s, a)$ であることに注意すると、式 (6.11) と表すことができる。

$$\begin{aligned} Q^{\pi^*}(s, a) &= \mathbb{E}[R_{t+1} + \gamma \max_{a' \in \mathcal{A}} Q^{\pi^*}(S_{t+1}, a') | S_t = s, A_t = a, S_{t+1} = s'] \\ &= \sum_{s' \in \mathcal{S}} p(s' | s, a) [R(s') + \gamma \max_{a' \in \mathcal{A}} Q^{\pi^*}(s', a')] \end{aligned} \quad (6.11)$$

エージェントが環境との相互作用の中で最適方策 π^* を獲得する方法として、数多のアルゴリズムが提案されている [Sutton 98]。本論文では、提案手法に用いた Q-learning [Watkins 89] について説明し、ある条件下で最適方策 π^* が確率 1 で獲得できることを示す。

Q-learning では、時刻 t においてエージェントが状態 S_t で行動 A_t を取り、環境から次時刻の状態 S_{t+1} と報酬 $R(S_{t+1})$ が返ってきたとき、式 (6.12) を用いて $Q(S_t, A_t)$ の値を更新する。ここで、 $Q(S_t, A_t)$ は時刻 t 時点での状態と行動の組合せの価値、 α はその価値の更新量を調整する学習率と呼ばれるパラメタである。このアルゴリズムの基本的なアイデアは、式 (6.11) で表される最適な行動価値関数に向けて、 $Q(S_t, A_t)$ を更新することである。

$$Q(S_t, A_t) \leftarrow Q(S_t, A_t) + \alpha [R(S_{t+1}) + \gamma \max_{a \in \mathcal{A}} Q(S_{t+1}, a) - Q(S_t, A_t)] \quad (6.12)$$

すべての状態 $s \in \mathcal{S}$ においてすべての行動 $a \in \mathcal{A}$ が選択される確率が 0 より大きいとき、学習率 α が式 (6.13) と式 (6.14) を満たせば、 $Q(S_t, A_t)$ の値は確率 1 で式 (6.11) に収束する。

$$\sum_{t=0}^{\infty} \alpha(t) \rightarrow \infty \quad (6.13)$$

$$\sum_{t=0}^{\infty} \alpha(t)^2 < \infty \quad (6.14)$$

最適な行動価値関数が求まると、式 (6.15) に示す最適方策 π^* を求めることができる。

$$\pi^*(s) = \operatorname{argmax}_{a \in \mathcal{A}} Q(s, a) \quad (6.15)$$

6.3 自動運転方策の学習法

図 6.3 に示す提案手法の枠組みを説明する。シミュレータ (Simulator) に環境 (Environment) とエージェント (Agent) を設置する。図 2.3 で説明した対象の道路を環境でモデル化し、エージェントはその環境と相互作用する中で自動運転方策 $\pi_{\rho, \mu}$ を学習する。相互作用はシミュレータの時刻変化 $t \leftarrow t + 1$ に 1 回おこなわれる。エージェントは環境に時刻 t の自動運転方策 $\pi_{t, \rho, \mu}$ を渡し、環境はエージェントに自動運転方策に従う車のデータを渡す。

以下、エージェントと環境について詳しく説明する。

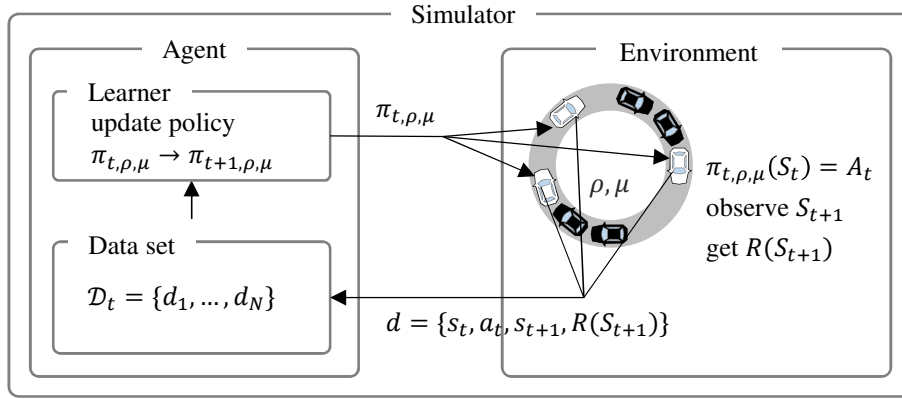


図 6.3: 環境と学習器の相互作用から自動運転方を学習する提案手法の枠組み.

6.3.1 エージェント (Agent)

エージェントは学習器 (Learner) とデータセット (Data set) で構成される。学習器はデータセット \mathcal{D}_t を用いて時刻の変化 $t \leftarrow t+1$ に伴い、自動運転方を $\pi_{t,\rho,\mu} \rightarrow \pi_{t+1,\rho,\mu}$ に更新する。データセット \mathcal{D}_t は時刻の変化 $t \leftarrow t+1$ に伴って得られた自動運転車のデータ $\equiv \{S_t, A_t, S_{t+1}, R(S_{t+1})\}$ の集合である。ここで、 S_t は時刻 t の状態、 A_t は時刻 t の行動、 S_{t+1} は時刻 $t+1$ の状態、 $R(S_{t+1})$ は状態 S_{t+1} の報酬である。

自動運転方はアルゴリズム 6.1 にしたがって更新する。 $Q_{t+1,\rho,\mu} \leftarrow Q_{t,\rho,\mu}$ により、時刻 t の Q を時刻 $t+1$ の Q に代入する。データセット \mathcal{D}_t の要素の数だけ Q の更新を繰り返す。 $Q_{t+1,\rho,\mu}(S_t, A_t) \leftarrow (1 - \alpha)Q_{t,\rho,\mu}(S_t, A_t) + \alpha(R(S_{t+1}) + \gamma \arg\max_{a'} Q_{t,\rho,\mu}(S_{t+1}, a'))$ の更新を繰り返す。ここで、学習率 $\alpha = \{\alpha | 0 \leq \alpha\}$ は行動価値の更新量を調節するパラメータである。

アルゴリズム 6.1: Update Q

Input $\mathcal{D}_t = \{d_n | n \in N\}, d_n = \{S_t, A_t, S_{t+1}, R(S_{t+1})\}$

1: $Q_{t+1,\rho,\mu} \leftarrow Q_{t,\rho,\mu}$

2: **for** $i \leftarrow 1$ to N **do**

3: Sample random data of $d_n = \{S_t, A_t, S_{t+1}, R(S_{t+1})\}$ from \mathcal{D}_t

4: $Q_{t+1,\rho,\mu}(S_t, A_t) \leftarrow (1 - \alpha)Q_{t,\rho,\mu}(S_t, A_t) + \alpha(R(S_{t+1}) + \gamma \arg\max_{a'} Q_{t,\rho,\mu}(S_{t+1}, a'))$

5: Discard data of d_n

6.3.2 環境 (Environment)

対象の道路を周期的境界条件でモデル化する。周期的境界条件の道路では道路上の車の総数が一定に保たれるため、車両密度 ρ と普及率 μ は固定される。これにより、エージェントは車両密度 ρ と普及率 μ ごとに自動運転方策 $\pi_{\rho,\mu}$ を学習できる。図 6.3 の中には、周期的

境界条件の道路上に白色の自動運転車 $N = 3$ と黒色の手動運転車 $M = 4$ が走っている様子
を示している。

自動運転方策 $\pi_{\rho,\mu}(s)$ は式 (6.16) に示すとおり、確率 $1 - \epsilon$ で状態 s における行動 a の
 $Q_{\rho,\mu}(s, a)$ の値が最大となる行動、確率 ϵ でランダムに選択された行動を出力する。ここで
探索率 $\epsilon = \{\epsilon | 0 \leq \epsilon \leq 1\}$ は様々な状態への遷移を促すために設定するパラメータである。

$$\pi_{\rho,\mu}(s) = \begin{cases} \operatorname{argmax}_a Q_{\rho,\mu}(s, a) & 1 - \epsilon \\ \text{random select } a & \epsilon \end{cases} \quad (6.16)$$

6.4 計算機実験

6.4.1 交通流モデル

GNS' によって交通流をモデル化する。アルゴリズム 6.2 に自動運転方策による減速ルー
ルを加えた GNS' のアルゴリズムを記す。アルゴリズム 5.1 に 15 行目を加えている。自動
運転方策を持つ自動運転車は、道路上のすべてのセルにおいて確率 p^{pol} で減速する。なお、
自動運転車が自動運転方策を持たない場合は、**Decelerate** ルールは実行しない。

アルゴリズム 6.2: GNS' with policy for vehicle i ($x_i(t), v_{i+j}(t), g_{i+j}, 0 \leq j \leq n_i^{\text{com}} + 1$)

Accelerate

1: $v_i(t+1) \leftarrow \min(v_i(t) + 1, v^{\text{limit}})$

Maximize Velocity

2: $d \leftarrow g_i + 1$

3: $n \leftarrow 1$

4: **while** $d \leq d_i^{\text{com}}$ **and** $n \leq n_i^{\text{com}}$ **and** $n_{i+n}^{\text{com}} > 0$ **do**

5: $v_{i+n}^{\text{pred}} \leftarrow \min(v_{i+n}(t) + 1, v^{\text{limit}})$

6: $d \leftarrow d + g_{i+n} + 1$

7: $n \leftarrow n + 1$

8: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}(t), v^{\text{limit}} - 1, g_{i+1} - 1))$

9: **for** $n \leftarrow n - 1$ **to** 1 **do**

10: $v_{i+n}^{\text{pred}} \leftarrow \max(0, \min(v_{i+n}^{\text{pred}}, g_{i+n} + v_{i+n+1}^{\text{pred}}) - 1)$

11: $v_i(t+1) \leftarrow \min(v_i(t+1), g_i + v_{i+1}^{\text{pred}})$

Decelerate

12: **if** vehicle i is manually-driven vehicle

13: $v_i(t+1) \leftarrow \max(0, v_i(t+1) - 1)$ with probability p in road section l

14: **else if** vehicle i is self-driving vehicle with policy $\pi_{\rho,\mu}$

15: $v_i(t+1) \leftarrow \max(0, v_i(t+1) - 1)$ with probability p^{pol}

Move

16: $x_i(t+1) \leftarrow x_i(t) + v_i(t+1)$

6.4.2 実験設定

提案手法の渋滞低減効果は、学習時と同様の周期的境界条件の道路で評価する。これまでの実験と同様に、道路区間への流入出が交通流量に与える影響を排除し、自動運転方策の渋滞低減効果に限定して評価できる。

すべての計算機実験に共通する設定を記す。

- 1time step = 2s
- 1cell = 10m
- 車長 = 5m
- 周期的境界条件の単車線道路
- 制限速度 $v^{\text{limit}} = 5\text{cell}/\text{time step}$
- 速度の揺らぎが発生する区間 $l = 5\text{cell}$
- 手動運転車の速度の揺らぎが発生する確率 $p = 0.2$
- CACC 車の通信距離 $d^{\text{com}} = 20\text{cell}$
- CACC 車の通信台数 $n^{\text{com}} = 1$

■ 学習の設定

提案する学習フレームワークにおける状態 s 、行動 a 、報酬関数 $R(s)$ について説明する。式 (2.1) の状態の属性は以下のとおりである。

- $\phi^{\text{vel}} = \{\text{slow, middle, fast}\}$
- $\phi^{\text{gap}} = \{\text{next, short, long, not in}\}$
- $\phi^{\text{rel}} = \{\text{depart, track, approach, not in}\}$
- $\phi^{\text{c-d}} = \{\text{near, far, disconnected}\}$
- $\phi^{\text{c-v}} = \{\text{slow, middle, fast, disconnected}\}$
- $\phi^{\text{c-g}} = \{\text{next, short, long, not in, disconnected}\}$

各属性の要素の値域は 6.1 に示すとおりである。図 6.4 に示すとおり、直前の先行車 $i+1$ との相対速度を v_i^{rel} 、車 i の通信相手を i 、通信相手との通信距離を d_i で表す。

行動 a は $p^{\text{pol}} = 0$ と $p^{\text{pol}} = 1$ とする。つまり、自動運転方策は状態 s において、GNS' の **Decelerate** ルールを確率 1 で適用するか否かを学習することになる。

学習時に用いる報酬関数 $R(s)$ は式 (6.17) にしたがって、負の報酬 $R(s) = -1$ (ペナルティ) もしくは報酬を与えない $R(s) = 0$ となる。

$$R(s) = \begin{cases} -1 & v_i(t) = 0 \text{ or } |v_i^{\text{rel}}(t)| > 1 \text{ or } g_i > 7 \\ 0 & \text{otherwise} \end{cases} \quad (6.17)$$

表 6.1: 状態 s の属性の要素の値域.

Element	Value range
slow	$0 \leq v_i(t) \leq 1$
middle	$1 < v_i(t) \leq 4$
fast	$4 < v_i(t) \leq v^{\text{limit}}$
next	$0 \leq g_i \leq 1$
short	$1 < g_i \leq 5$
long	$5 < g_i \leq 20$
not in	$20 < g_i$
depart	$v_i^{\text{rel}}(t) \leq -2$
track	$-2 < v_i^{\text{rel}}(t) \leq 1$
approach	$1 < v_i^{\text{rel}}(t)$
near	$0 \leq d_i \leq 6$
far	$6 < d_i \leq 20$
disconnected	$d_i^{\text{com}} < d_i$ or ACC 車

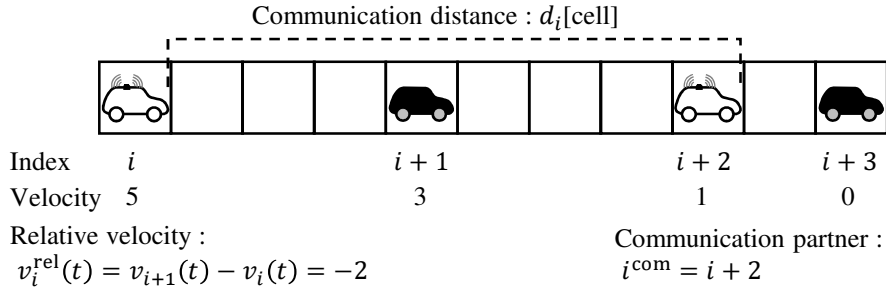


図 6.4: 相対速度 v_i^{rel} , 通信相手 i^{com} , 通信距離 d_i の説明.

ペナルティは以下の三つの場合に与えられる.

- $v_i(t) = 0$: 自動運転車が停止した場合. 渋滞時には停止と発進をくり返す車で構成される車列が現れる. この車列に加わり, 停止した場合にペナルティが与えられる.
- $|v_i^{\text{rel}}(t)| > 1$: 相対速度が 1cell/time step を超えた場合. GNS では交通流がメタ安定相にあるとき, 速度の揺らぎが後続車に影響しなければすべての車は「制限速度」または「制限速度-1」の速度を維持できるため相対速度の絶対値は 1[cell/time step] 以内に収まる. そこで, 前方で発生した速度の揺らぎに影響され, 相対速度の絶対値が 1[cell/time step] を超えたとき, 後続車に影響を及ぼすとしてペナルティを与える.
- $g_i > 7$: 車間距離が 7cell を上回った場合. 交通流量の増大にはなるべく小さい車間距離で走行することが望ましいため, 車間距離が 70[m] を超えた場合にペナルティを与える.

これら三つの条件を一つも満たさなかった場合は, 報酬 $R(s) = 0$ としてペナルティを与えないこととする. 以上の報酬の設定は, 渋滞を起こした場合, 渋滞の原因を発生させた場合, 交通流量の増大に対して効率的な車間距離を維持できなかった場合に対して与えられるペナ

ルティとして自然であると考えている。しかしながら、この報酬が最も適切であるという保証はない。

■ 実験の手順

実験は学習、評価の順におこなう。道路に車をランダムに配置してから 1000time step 車を動かした後を時刻 $t = 0$ とする。時刻 $t = 0$ から $t = 10000$ を 1episode とする。学習を 1000episode, 評価を 100episode おこなう。この 1100episode を 1 試行として、20 試行の平均値を実験結果とする。

探索率は 1episode から 500episode まで $\epsilon = 0.01$, 501episode から $\epsilon = 0$ とする。学習率は 1episode から 1000episode まで $\alpha = 0.01$, 1001episode から $\alpha = 0$ とする。割引率 $\gamma = 0.9$ とする。

6.4.3 実験結果

交通流の基本図

学習後の自動運転方策を導入した後の交通流の基本図から、提案手法の渋滞抑制効果について確認する。図 6.5 から図 6.14 までの図には、自動運転方策を与えた CACC 車と手動運転車の交通流 (CwP+M), 自動運転方策を与えた ACC 車と手動運転車の交通流 (AwP+M), C+M, A+M, M の 20 試行平均値と標準偏差をプロットしている。灰色の線は M の交通流におけるメタ安定相時の交通流量を表している。

まずは、CwP+M と C+M の交通流の基本図を比較する。CwP+M については、普及率 $\mu = 100\%$ を除いて、特定の車両密度まではメタ安定相に近い交通流量を実現できている。例えば、普及率 $\mu = 10\%$ では車両密度 $\rho = 21\text{volume/km}$ まで、普及率 $\mu = 60\%$ では車両密度 $\rho = 25\text{volume/km}$ までメタ安定相を維持できているといえる。一方、C+M については、車両密度 $\rho = 21\text{volume/km}$ 付近から、車両密度の増加に伴って交通流量が減少する結果が観察でき、メタ安定相を維持できていない。つまり、CACC 車に自動運転方策を導入すると、メタ安定相の維持効果による輸送効率の向上が実現できる。

次に AwP+M と A+M の交通流の基本図を比較する。AwP+M は、普及率 $\mu = 70\%$ まで車両密度 $\rho = 21\text{volume/km}$ においてメタ安定相の維持ができているが、それ以外の普及率や車両密度ではメタ安定相の維持ができていない。さらに、自動運転方策の導入前の A+M よりも交通流量が小さくなることが確認できる。A+M については C+M と同じく、車両密度 $\rho = 21\text{volume/km}$ 付近から、車両密度の増加に伴って交通流量の減少が確認できる。

普及率と交通流量の関係

図 6.15 から図 6.24 に示した結果から、各車両密度における自動運転車普及率と交通流量の関係を観察する。観察できる傾向として、特定の普及率までは、普及率が大きくなるほど




図 6.5: 自動運転方策導入前後の自動運転車普及率 $\mu = 10\%$ の交通流の基本図

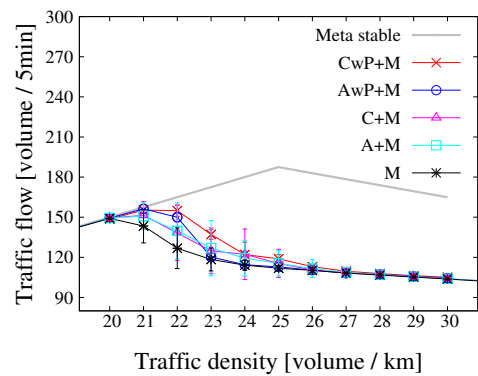


図 6.6: 自動運転方策導入前後の自動運転車普及率 $\mu = 20\%$ の交通流の基本図




図 6.7: 自動運転方策導入前後の自動運転車普及率 $\mu = 30\%$ の交通流の基本図

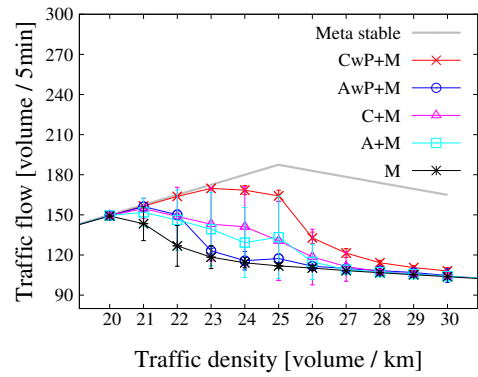


図 6.8: 自動運転方策導入前後の自動運転車普及率 $\mu = 40\%$ の交通流の基本図




図 6.9: 自動運転方策導入前後の自動運転車普及率 $\mu = 50\%$ の交通流の基本図




図 6.10: 自動運転方策導入前後の自動運転車普及率 $\mu = 60\%$ の交通流の基本図

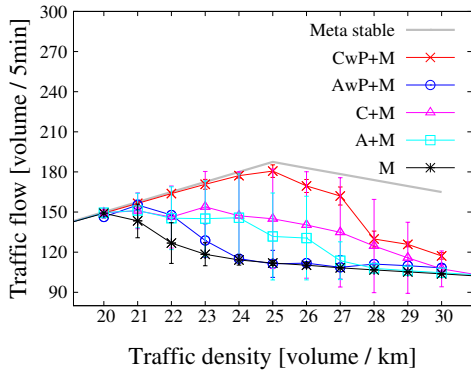


図 6.11: 自動運転方策導入前後の自動運転車普及率 $\mu = 70\%$ の交通流の基本図




図 6.12: 自動運転方策導入前後の自動運転車普及率 $\mu = 80\%$ の交通流の基本図




図 6.13: 自動運転方策導入前後の自動運転車普及率 $\mu = 90\%$ の交通流の基本図




図 6.14: 自動運転方策導入前後の自動運転車普及率 $\mu = 100\%$ の交通流の基本図

交通流量も大きくなり、メタ安定相を維持できるようになるが、特定の普及率を超えると、逆に交通流量が小さくなる。例えば、図 6.21 の車両密度 $\rho = 27\text{volume/km}$ の結果については、普及率 90%までは交通流量の増加効果が観察できたが、100%では交通流量が下がり、自動運転方策導入前の C+M と同等程度となる。AwP+M の結果より、ACC 車に自動運転方策を導入することによる交通流量の増加効果は、車両密度 $\rho = 21\text{volume/km}$ で観察できるものの、それ以外の車両密度では観察できず、自動運転方策導入前の交通流量よりも小さくなる結果となる。

学習曲線

提案手法のフレームワークによる学習が収束することを学習曲線を用いて確認する。学習曲線は、横軸にエピソード数、縦軸に交通流量を示す図であり、エピソード数が大きくなるにつれて交通流量の変化が小さくなれば学習が収束したことになる。

図 6.25 から図 6.27 は、車両密度 $\rho = 22\text{volume/km}$ 、普及率 $\mu = 30\%$ の時の学習曲線である。図には CwP+M と AwP+M の交通流量の 20 試行平均値とその標準偏差をプロットしている。CwP+M では 1episode から 10episode あたりまでに交通流量が収束し、探索率 ϵ や学習率 α の変動後も値が変わっていないことから、学習が収束していると判断できる。AwP+M では、1episode から 60episode にかけて交通流量が減少し、その後増加する傾向があるが、探索率 ϵ を 0.01 から 0 に変更する 501episode から交通流量が減少し、学習が収束した。

図 6.28 から図 6.30 は、車両密度 $\rho = 25\text{volume/km}$ 、普及率 $\mu = 30\%$ の時の学習曲線である。CwP+M では 1episode から 50episode あたりまでに交通流量が収束している。一方 AwP+M では、1episode から 10episode あたりまでに交通流量が収束するが、探索率 ϵ が 0.01 から 0 に変わる 501episode から標準偏差が大きくなる。

6.5 考察

6.5.1 学習の収束性について

図 6.25 から図 6.30 に示した学習曲線では、20 試行の学習結果が一定の値に収束していることを示した。これより、提案手法の学習フレームワークで一定の自動運転方策が得られることになる。しかし、20 試行平均の標準偏差は 0 に収束していない。例えば、図 6.30 の CwP+M の結果では、探索率や学習率が 0 になった 1001episode 以降も一定の標準偏差がある。

標準偏差が 0 に収束しない理由は、エピソードが変わるごとに自動車の配置が変更されるためであると考えられる。自動車の配置が変更されると、それまでに学習していた環境が変わることになる。環境が変われば、同じ状態でも異なる行動を学習しなければならない状況も現れる。特に学習率が 0 になった後は、方策が変更されることがないため、配置によって




図 6.15: 車両密度 $\rho = 21\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.16: 車両密度 $\rho = 22\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.17: 車両密度 $\rho = 23\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.18: 車両密度 $\rho = 24\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.19: 車両密度 $\rho = 25\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.20: 車両密度 $\rho = 26\text{volume/km}$ の自動運転車普及率と交通流量の関係図

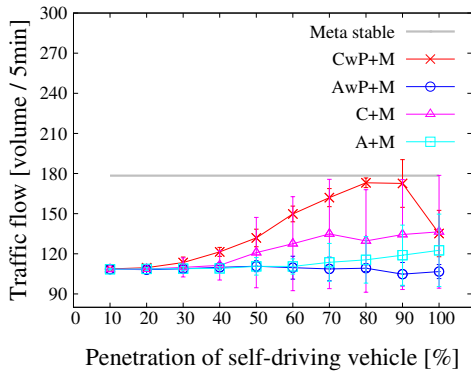


図 6.21: 車両密度 $\rho = 27\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.22: 車両密度 $\rho = 28\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.23: 車両密度 $\rho = 29\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.24: 車両密度 $\rho = 30\text{volume/km}$ の自動運転車普及率と交通流量の関係図




図 6.25: 車両密度 $\rho = 22\text{volume}/\text{km}$, 普及率 $\mu = 30\%$ における交通流量の 20 試行の平均値と標準偏差をプロット.




図 6.26: 車両密度 $\rho = 22\text{volume}/\text{km}$, 普及率 $\mu = 30\%$ における交通流量の 20 試行の平均値と標準偏差をプロット. 501episode から探索率 ϵ を 0.01 から 0 に変更.




図 6.27: 車両密度 $\rho = 22\text{volume}/\text{km}$, 普及率 $\mu = 30\%$ における交通流量の 20 試行の平均値と標準偏差をプロット. 1001episode から学習率 α を 0.01 から 0 に変更.




図 6.28: 車両密度 $\rho = 25\text{volume}/\text{km}$, 普及率 $\mu = 60\%$ における交通流量の 20 試行の平均値と標準偏差をプロット.




図 6.29: 車両密度 $\rho = 25\text{volume}/\text{km}$, 普及率 $\mu = 60\%$ における交通流量の 20 試行の平均値と標準偏差をプロット. 501episode から探索率 ϵ を 0.01 から 0 に変更.




図 6.30: 車両密度 $\rho = 25\text{volume}/\text{km}$, 普及率 $\mu = 60\%$ における交通流量の 20 試行の平均値と標準偏差をプロット. 1001episode から学習率 α を 0.01 から 0 に変更.

は渋滞が抑制できない状況も出てくると考えられる。配置の変更の影響を無くすためには、路車間通信器が車両密度 ρ と普及率 μ と同時に道路上の配置 *arrangement* を計測し、自動運転方策 $\pi_{\rho,\mu, arrangement}$ を送信する必要がある。

6.5.2 渋滞抑制可能な方策を獲得できる理由

強化学習を用いた提案手法の学習フレームワークにより、渋滞抑制できる自動運転方策が獲得できる理由を考察する。表 6.2 は車両密度 22volume/km かつ普及率 30%における、交通流量と 1time step あたりの停止 (stop) した車の平均台数を示す。括弧内の数字は 10 試行の標準偏差を表している。自動運転方策の導入により、交通流量が大きくなった AwP+M や CwP+M は、他の交通流と比較して 1[time step] あたりに停止する車の台数が小さくなることわかる。ここから、渋滞抑制できる二つの理由が考えられる。一つは渋滞時に現れる車列の形成を妨げたこと、もう一つは車列が形成された後に素早く車列を解消したことである。渋滞が発生すると、道路上に停止と発進を繰り返す車で構成される車列が現れる。式 (6.17) にしたがって、車列を通過する間に停止した回数だけペナルティを受け取ることになる。そこで、自動運転車が車列を形成させない、および車列が形成した後すぐに解消させる方策が学習される。結果的に、道路上に車列が存在する時間が減少し、道路上の車が停止することなく円滑に進めるようになり、交通流量が大きくなったと考えられる。

表 6.2: 車両密度 22[volume/km], 普及率 30[%] の交通流量と 1[time step] あたりの停止した車の平均台数。括弧内の数字は標準偏差を示す。

	Traffic flow [vehicles / 5min]	The number of stop [vehicles / time step]
M	126.8(15.2)	$9.9 \times 10^{-2} (4.1 \times 10^{-2})$
A+M	143.5(21.8)	$5.4 \times 10^{-2} (5.6 \times 10^{-2})$
C+M	143.8(21.3)	$5.4 \times 10^{-2} (5.6 \times 10^{-2})$
AwP+M	152.2(4.6)	$1.3 \times 10^{-5} (3.9 \times 10^{-6})$
CwP+M	162.3(7.1×10^{-1})	$2.0 \times 10^{-3} (6.8 \times 10^{-4})$

自動運転方策の導入前と後の車の動きを図 6.31 と図 6.32 に示した時空間プロットで確認する。時空間プロットの横軸は車の位置、縦軸は時間を表す。赤いプロットが自動運転車、黒いプロットが手動運転車を示し、速度が遅いほど色が濃くなる。方策の導入前は、図の色が濃い部分が示す停止と発進を繰り返す車列が進行方向とは逆向きに伝搬し、その車列が解消されることがないことがわかる。一方、方策の導入後は、時刻 (Time)200 前後において、車列が解消している動きが確認でき、それ以降、90 番目のセル付近で速度が遅くなる車が現れるが、車列は形成されていない。これらの結果より、自動運転方策を持つ自動運転車が車列を形成させないおよび車列を解消させる走行をすることがわかった。

ただし、今回の報酬が適切であるとは限らない。CACC 車に対して渋滞低減が可能な報




図 6.31: 普及率 $\mu = 30\%$, 車両密度 $\rho = 22\text{volume/km}$ における CACC 車に自動運転方策を導入する前の時空間プロット




図 6.32: 普及率 $\mu = 30\%$, 車両密度 $\rho = 22\text{volume/km}$ における CACC 車に自動運転方策を導入した後の時空間プロット

酬を設計できたが、ACC車に対しては不適切な報酬を設計した可能性も残されている。強化学習は、報酬をもとにした期待累積割引報酬を最大化する枠組みであって、解きたい問題に対して設定した報酬が適切かどうかは慎重に判断しなければならない。

6.5.3 車車間通信が渋滞抑制効果に与える影響について

自動運転方策を導入した後のACC車とCACC車の違いについて考察する。本論文で用いたGNSでは、CACC車は直前の先行車もCACC車であれば、情報共有することが可能なため、ACC車よりも小さい車間距離で走行できる。すなわち、制限速度内の走行において、車間距離の縮小が単位時間当たりには通過する台数(交通流量)の増加につながっている。

これに加えて、式(2.1)の状態 s の特徴 ϕ^{c-d} , ϕ^{c-v} , ϕ^{c-g} が異なる。表6.1の通り、ACC車のこれらの特徴は常にdisconnectedになる。一方、CACC車の場合、車車間通信できる距離 d_i^{com} 内に通信相手 i^{com} が存在する限り、特徴量 ϕ^{c-d} , ϕ^{c-v} , ϕ^{c-g} は通信相手の情報を持つ。図6.31からわかる通り、一般的に渋滞時に発生する車列は後続へ伝搬する性質を持つため、前方の通信相手の情報を通して渋滞の予測ができる。そして、提案手法がこの予測を考慮した協調的な自動運転方策を学習したため、CACC車に自動運転方策を導入した方が交通流量が大きくなったと考えられる。

図6.33と図6.34はそれぞれACC車とCACC車に自動運転方策を導入した時の時空間プロットである。車両密度は $\rho = 25 \text{ volume/km}$ 、自動運転車の普及率 $\mu = 60\%$ である。ACC車では車列を解消できていないが、CACC車では時刻250あたりで車列を解消しその後は車列が形成しない交通流を維持している。この結果より、ACC車では渋滞を解消・抑制できない状況においても、CACC車ではできることが確認できた。

今回設定した状態 s については、設計者の考えをもとに離散化している。ここでの考察で示した通り、観測する状態に応じて学習結果に影響が出る。しかしながら、強化学習では状態空間を設計する必要があるが、報酬の設計と同様に、設計した状態空間が解きたい問題に対して適切である保証はない。

6.5.4 学習の失敗について

ACC車が渋滞を解消・抑制できる方策の学習に失敗する理由について考察する。直前の先行車だけを観察するACC車の場合、その先行車より前方の状況を判断できない。この場合、前方が渋滞していても、車両間隔が均等な理想的な配列でも、同じ状態として観測し、自動運転方策から同じ行動が出力される。このような不完全知覚の状態において、異なる行動を学習する必要があるとき、常に好ましい行動を出力することは不可能である[荒井98]。実験の結果からわかるとおり、不完全知覚の状態異なる行動を学習する必要があったため、ACC車は学習に失敗したと考えられる。




図 6.33: 普及率 $\mu = 60\%$, 車両密度 $\rho = 25\%$ における ACC 車に自動運転方策を導入した後の時空間プロット




図 6.34: 普及率 $\mu = 60\%$, 車両密度 $\rho = 25\%$ における CACC 車に自動運転方策を導入した後の時空間プロット

この不完全知覚による学習の失敗を避けるためには、状態空間を適切に設計しなければならない。前節でも考察したとおり、強化学習では状態空間を事前に設計する必要があり、適切な状態設計は設計者に委ねられている。

6.6 結言

渋滞抑制に向けた自動運転車の制御則の設計方法が確立されていない問題に対して、自動運転方策の学習法を提案した。シミュレーションに設置した学習器が自動運転車と相互作用する枠組のなかで、学習器は自動運転方策を学習する。計算機実験により、提案手法の自動運転方策に渋滞抑制効果があることを確かめた。さらに、車車間通信が自動運転方策の渋滞抑制効果を高めることを明らかにした。以上のことから、計算機実験で用いた周期的境界条件の環境において、提案手法の自動運転方策に渋滞抑制効果があることを示した。

今後の課題は二つある。一つ目は開放境界条件の道路モデルで自動運転方策を評価することである。実際の道路では車の流入出により時々刻々と道路内の車両密度が変化する。こうした変化のある交通流において提案手法の自動運転方策に渋滞抑制効果があるのか確かめる。もう一つは、適切な状態空間や報酬関数を設計することである。考察で述べたとおり、所与の報酬や状態空間が対象の問題に対して適切である保証はない。ここにハンドコードによる試行錯誤が介入すれば、制御則を試行錯誤的に設計するときと同様の難しさに直面してしまう。

第7章 結論

これからの交通渋滞対策として、路車間の通信や車車間通信機能を備えた自動運転車が注目される中で、著者は「渋滞抑制に向けた協調型の自動運転」の実現に向けた研究をしてきた。本論文は対象問題を「交通流のモデル化」「交通流の解析」「交通流の最適化」の三つに分け、それぞれに対応する研究をまとめた。

交通流のモデル化

交通流制御の提案をする場合、交通流シミュレーションで有効性を確認してから、試験場、社会実験に至る。本論文では協調型の自動運転を新規提案するため、まずは交通流シミュレーションをおこなう必要がある。そこで、手動運転車や車車間通信機能を備えた自動運転車の挙動を再現し、交通流をモデル化することを対象の問題とした。既存の交通流モデル、特に柔軟に走行ルールを設計できるセルオートマトンモデルでは、自動運転車の隊列走行をモデル化できていなかった。

そこで、本論文は Generalized Nagel-Schreckenberg(GNS) モデルを提案し、通信に関するパラメタの違いで手動運転車と自動運転車 (ACC 車・CACC 車) の挙動を再現可能にした。GNS モデルは、手動運転車の挙動を再現した Extended Nagel-Schreckenberg(ExNS) モデルを一般化した走行ルールである。直前の先行車情報をもとに速度を決める ExNS の走行ルールを、 n 台の先行車情報をもとに速度を決めるように一般化し、車車間通信を使って隊列走行する挙動を再現できると考えた。

計算機実験では、手動運転車モデルや、自動運転車による隊列走行モデルの交通流の基本図を作成し、交通流モデルの再現性について考察した。実際の観測データをもとに作成された交通流の基本図に現れる、自由走行相、渋滞相、メタ安定相の三つの相を、手動運転車のモデルで再現できることが確認できた。また、隊列走行モデルでは、手動運転車よりも短い車間距離で走行する様子を再現できることが確認できた。これらの結果から、提案した GNS モデルによって、手動運転車および車車間通信機能を搭載した自動運転車の挙動を再現し、交通流をモデル化できることを明らかにした。

交通流の解析

交通渋滞の発生原因の一つである、手動運転車の速度の揺らぎは、機械的な制御の自動運転車には発生しない。こうした自動運転車が普及することによって交通流が変化していくこ

とが考えられ、将来の交通流の性質について議論する必要がある。本論文では、車車間通信を用いた隊列走行や、自動運転車が普及する過程の交通流を解析し、交通渋滞の発生有無や渋滞抑制効果を明らかにすることを対象問題とした。

しかし、一つ目の研究で提案した GNS モデルは同じ性能の車が同時に走行する交通流しかモデル化できず、車車間通信機能の搭載・非搭載などの異なる性能の車が同時に走行する交通流をモデル化できない。そこで、異なる性能の車の混在ができるように走行ルールを変更した GNS' を提案した。GNS' によれば、ACC 車や CACC 車が普及する過程の交通流をモデル化できる。

計算機実験では、速度の揺らぎを発生させる手動運転車と発生させない自動運転車である ACC 車や CACC 車が混在する普及過程では交通渋滞を抑制できないことがわかった。また、CACC 車が通信できる台数を多くしたところで、交通渋滞は抑制されず、交通流量を増大させる効果も小さいことを明らかにした。つまり、自動運転車の普及過程では、何かしらの制御を加えない限り、速度の揺らぎを起因とした交通渋滞を抑制できないことがわかった。さらに、一度渋滞した交通流をメタ安定相へ復帰させることもできないこともわかった。したがって、将来の交通流を最適化するためには、メタ安定相を維持する、またはメタ安定相への復帰ができる制御が必要になることを明らかにした。

交通流の最適化

自動運転車が普及する過程において、速度の揺らぎを起因とした交通渋滞を抑制するために、路車間通信や車車間通信を用いながら自動運転車を制御することを目的とした。路車間通信器が道路の車両密度や自動運転車の普及率を観測し、それに基づいた制御則を自動運転車に送信することによって、自動運転車を制御する。最近では自動運転車 (ACC 車・CACC 車) を状況に応じて制御することによって、交通流の最適化する試みは既存研究でも確認できる。しかし、既存研究ではシミュレーションを用いてアドホックに制御が設計されているため、道路構造などの多くの構成要素によって変化する交通状況のそれぞれに対して妥当な制御則を設計することは困難である。

そこで、制御則の設計方法の確立に向けて、強化学習を用いた自動運転車の制御 (自動運転方策) を学習する枠組を提案した。強化学習では、あらかじめ設計した報酬をもとに、エージェントがその報酬に基づいた方策を学習する。提案手法ではシミュレーション環境の中で、エージェントが自動運転車と相互作用しながら方策を学習できるので、一度報酬を設計できればアドホックな設計が不要となる。

計算機実験では、提案手法によって学習した自動運転方策の導入前後の交通流を比較した。自動運転方策を導入したときの交通流の基本図では、渋滞相への転移を抑制し、メタ安定相を維持できていることを確認した。これは、自動運転方策によって交通流を最適化できたことになる。また、車車間通信で前方の自動運転車の情報を取得することによって、渋滞抑制

効果が大きい自動運転方策を学習できることを明らかにした。

これら三つの研究から自動運転車の普及過程における，路車間・車車間協調型の自動運転により，速度の揺らぎを起因とした交通渋滞を抑制できることを明らかにした。後述する課題が残されているが，協調型の自動運転によって，近い将来，渋滞の無い交通流が実現可能であると結論する。

今後の課題は二つある。一つ目はより現実に近い交通流モデルで渋滞抑制効果を評価することである。交通流に関する実験はすべて周期的境界条件を用いたが，実際の道路では車の流入出により時々刻々と道路内の車両密度が変化する。また現実的な減速度の設定や天候による路面状況の変化など，より詳細にモデルしたシミュレータで実験をおこなう。二つ目は自動運転車の状態空間や強化学習に用いる報酬関数の設計を自動化することである。強化学習で得られる方策は，設計した報酬に対して最適な方策となるが，その方策が対象問題に対して最適である保証はない。また，あらかじめ設計した状態空間によって方策が変化することから，対象問題を解くために適切な状態空間を設計する必要もある。その問題を解決するために，Inverse Reinforcement Learning(IRL)[Russell 98, Ng 00, Abbeel 04, Ramachandran 07, Ziebart 08, Boularias 11, Choi 11, Choi 12] や Feature Construction for IRL[Levine 10, Choi 13] などの手法を用いて，報酬関数や状態空間の設計問題を解決する必要があると考えている。

参考文献

- [Abbeel 04] Abbeel, P. and Ng, A. Y.: Apprenticeship learning via inverse reinforcement learning, in *Proceedings of the twenty-first international conference on Machine learning*, p. 1ACM (2004)
- [Bando 95] Bando, M., Hasebe, K., Nakayama, A., Shibata, A., and Sugiyama, Y.: Dynamical model of traffic congestion and numerical simulation, *Physical review E*, Vol. 51, No. 2, p. 1035 (1995)
- [Barlovic 98] Barlovic, R., Santen, L., Schadschneider, A., and Schreckenberg, M.: Metastable states in cellular automata for traffic flow, *The European Physical Journal B-Condensed Matter and Complex Systems*, Vol. 5, No. 3, pp. 793–800 (1998)
- [Boularias 11] Boularias, A., Kober, J., and Peters, J.: Relative entropy inverse reinforcement learning, in *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, pp. 182–189 (2011)
- [Brookhuis 01] Brookhuis, K. A., De Waard, D., and Janssen, W. H.: Behavioural impacts of advanced driver assistance systems—an overview, *European Journal of Transport and Infrastructure Research*, Vol. 1, No. 3, pp. 245–253 (2001)
- [Chandler 58] Chandler, R. E., Herman, R., and Montroll, E. W.: Traffic dynamics: studies in car following, *Operations research*, Vol. 6, No. 2, pp. 165–184 (1958)
- [Choi 11] Choi, J. and Kim, K.-E.: Map inference for bayesian inverse reinforcement learning, in *Advances in Neural Information Processing Systems*, pp. 1989–1997 (2011)
- [Choi 12] Choi, J. and Kim, K.-E.: Nonparametric Bayesian inverse reinforcement learning for multiple reward functions, in *Advances in Neural Information Processing Systems*, pp. 305–313 (2012)
- [Choi 13] Choi, J. and Kim, K.-E.: Bayesian Nonparametric Feature Construction for Inverse Reinforcement Learning., in *IJCAI*, pp. 1287–1293 (2013)
- [Daoudia 03] Daoudia, A. K. and Moussa, N.: Numerical simulations of a three-lane traffic model using cellular automata, *Chinese journal of physics*, Vol. 41, No. 6, pp. 671–681 (2003)
- [Derrida 93] Derrida, B., Evans, M. R., Hakim, V., and Pasquier, V.: Exact solution of a 1D asymmetric exclusion model using a matrix formulation, *Journal of Physics A: Mathematical and General*, Vol. 26, No. 7, p. 1493 (1993)
- [Desjardins 11] Desjardins, C. and Chaib-Draa, B.: Cooperative adaptive cruise control: A reinforcement learning approach, *IEEE Transactions on intelligent transportation systems*, Vol. 12, No. 4, pp. 1248–1260 (2011)
- [Dey 16] Dey, K. C., Yan, L., Wang, X., Wang, Y., Shen, H., Chowdhury, M., Yu, L., Qiu, C., and Soundararaj, V.: A review of communication, driver characteristics, and controls aspects of cooperative adaptive cruise control (CACC), *IEEE Transactions on Intelligent Transportation Systems*, Vol. 17, No. 2, pp. 491–509 (2016)

- [Emmerich 97] Emmerich, H. and Rank, E.: An improved cellular automaton model for traffic flow simulation, *Physica A: Statistical Mechanics and its Applications*, Vol. 234, No. 3-4, pp. 676–686 (1997)
- [Figueiredo 01] Figueiredo, L., Jesus, I., Machado, J. T., Ferreira, J. R., and De Carvalho, J. M.: Towards the development of intelligent transportation systems, in *Intelligent Transportation Systems, 2001. Proceedings. 2001 IEEE*, pp. 1206–1211 (2001)
- [Forster 12] Forster, M., Frank, R., Gerla, M., and Engel, T.: Improving highway traffic through partial velocity synchronization, in *Global Communications Conference (GLOBECOM), 2012 IEEE*, pp. 5573–5578 (2012)
- [Forster 14] Forster, M., Frank, R., Gerla, M., and Engel, T.: A cooperative advanced driver assistance system to mitigate vehicular traffic shock waves, in *INFOCOM, 2014 Proceedings IEEE*, pp. 1968–1976 (2014)
- [Gao 07] Gao, K., Jiang, R., Hu, S.-X., Wang, B.-H., and Wu, Q.-S.: Cellular-automaton model with velocity adaptation in the framework of Kerner’s three-phase traffic theory, *Physical Review E*, Vol. 76, No. 2, p. 026105 (2007)
- [Gazis 61] Gazis, D. C., Herman, R., and Rothery, R. W.: Nonlinear follow-the-leader models of traffic flow, *Operations research*, Vol. 9, No. 4, pp. 545–567 (1961)
- [Hatakenaka 06] Hatakenaka, H., Hirasawa, T., Yamada, K., Yamada, H., Katayama, Y., and Maeda, M.: Development of AHS for traffic congestion in sag sections, in *13th World Congress on ITS* (2006)
- [Ishikawa 15] Ishikawa, S. and Arai, S.: Evaluating advantage of sharing information among vehicles toward avoiding phantom traffic jam, in *Proceedings of the 2015 Winter Simulation Conference*, pp. 300–311 (2015)
- [Ishikawa 18] Ishikawa, S. and Arai, S.: Learning Cooperative Policy among Self-Driving Vehicles for Relieving Traffic Jams, in *Proceedings of the 10th International Workshop on Agents in traffic and transportation* (2018)
- [Jiang 05] Jiang, R. and Wu, Q.: First order phase transition from free flow to synchronized flow in a cellular automata model, *The European Physical Journal B-Condensed Matter and Complex Systems*, Vol. 46, No. 4, pp. 581–584 (2005)
- [Kamal 14] Kamal, M. A. S., Imura, J.-i., Hayakawa, T., Ohata, A., and Aihara, K.: Smart driving of a vehicle using model predictive control for improving traffic flow, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, No. 2, pp. 878–888 (2014)
- [Kerner 04] Kerner, B. S.: Three-phase traffic theory and highway capacity, *Physica A: Statistical Mechanics and its Applications*, Vol. 333, pp. 379–440 (2004)
- [Kesting 08] Kesting, A., Treiber, M., Schönhof, M., and Helbing, D.: Adaptive cruise control design for active congestion avoidance, *Transportation Research Part C: Emerging Technologies*, Vol. 16, No. 6, pp. 668–683 (2008)
- [Kesting 10] Kesting, A., Treiber, M., and Helbing, D.: Enhanced intelligent driver model to access the impact of driving strategies on traffic capacity, *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, Vol. 368, No. 1928, pp. 4585–4605 (2010)

- [Khamis 14] Khamis, M. A. and Gomaa, W.: Adaptive multi-objective reinforcement learning with hybrid exploration for traffic signal control based on cooperative multi-agent framework, *Engineering Applications of Artificial Intelligence*, Vol. 29, pp. 134–151 (2014)
- [Knorr 12] Knorr, F., Baselt, D., Schreckenberg, M., and Mauve, M.: Reducing traffic jams via VANETs, *IEEE Transactions on Vehicular Technology*, Vol. 61, No. 8, pp. 3490–3498 (2012)
- [Knospe 99] Knospe, W., Santen, L., Schadschneider, A., and Schreckenberg, M.: Disorder effects in cellular automata for two-lane traffic, *Physica A: Statistical Mechanics and its Applications*, Vol. 265, No. 3-4, pp. 614–633 (1999)
- [Knospe 00] Knospe, W., Santen, L., Schadschneider, A., and Schreckenberg, M.: Towards a realistic microscopic description of highway traffic, *Journal of Physics A: Mathematical and general*, Vol. 33, No. 48, p. L477 (2000)
- [Knospe 02] Knospe, W., Santen, L., Schadschneider, A., and Schreckenberg, M.: A realistic two-lane traffic model for highway traffic, *Journal of Physics A: Mathematical and General*, Vol. 35, No. 15, p. 3369 (2002)
- [Levine 10] Levine, S., Popovic, Z., and Koltun, V.: Feature construction for inverse reinforcement learning, in *Advances in Neural Information Processing Systems*, pp. 1342–1350 (2010)
- [Li 11] Li, S., Li, K., Rajamani, R., and Wang, J.: Model predictive multi-objective vehicular adaptive cruise control, *IEEE Transactions on Control Systems Technology*, Vol. 19, No. 3, pp. 556–566 (2011)
- [Milanés 14] Milanés, V., Shladover, S. E., Spring, J., Nowakowski, C., Kawazoe, H., and Nakamura, M.: Cooperative Adaptive Cruise Control in Real Traffic Situations., *IEEE Trans. Intelligent Transportation Systems*, Vol. 15, No. 1, pp. 296–305 (2014)
- [Nagel 92] Nagel, K. and Schreckenberg, M.: A cellular automaton model for freeway traffic, *Journal de physique I*, Vol. 2, No. 12, pp. 2221–2229 (1992)
- [NEXCOa] NEXCO 中日本：渋滞の定義は？, <http://highwaypost.c-nexco.co.jp/faq/traffic/rule/345.html> : (Accessed on 2018.11.29)
- [NEXCOb] NEXCO 中日本：渋滞原因解説, https://www.w-nexco.co.jp/forecast/trafficjam_comment/index.html : (Accessed on 2018.12.19)
- [NEXCOc] NEXCO 東日本：ETC の仕組みについて, https://www.driveplaza.com/traffic/tolls_etc/etc_beginner/mechanism.html : (Accessed on 2018.10.10)
- [NEXCOd] NEXCO 東日本：コーポレートサイト渋滞の原因を分析し、渋滞解消・渋滞緩和を実施しています, <https://www.e-nexco.co.jp/activity/safety/detail.07.html> : (Accessed on 2018.8.23)
- [Ng 00] Ng, A. Y., Russell, S. J., et al.: Algorithms for inverse reinforcement learning., in *Icml*, pp. 663–670 (2000)
- [Papacharalampous 15] Papacharalampous, A. E., Wang, M., Knoop, V. L., Ros, B. G., Takahashi, T., Sakata, I., Arem, van B., and Hoogendoorn, S. P.: Mitigating congestion at sags with adaptive cruise control systems, in *Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on*, pp. 2451–2457 (2015)
- [Patire 11] Patire, A. D. and Cassidy, M. J.: Lane changing patterns of bane and benefit: Observations of an uphill expressway, *Transportation research part B: methodological*, Vol. 45, No. 4, pp. 656–666 (2011)

- [Pipes 53] Pipes, L. A.: An operational analysis of traffic dynamics, *Journal of applied physics*, Vol. 24, No. 3, pp. 274–281 (1953)
- [Ploeg 11] Ploeg, J., Scheepers, B. T., Van Nunen, E., Wouw, Van de N., and Nijmeijer, H.: Design and experimental evaluation of cooperative adaptive cruise control, in *Intelligent Transportation Systems (ITSC), 2011 14th International IEEE Conference on*, pp. 260–265 (2011)
- [Ramachandran 07] Ramachandran, D. and Amir, E.: Bayesian inverse reinforcement learning, *Urbana*, Vol. 51, No. 61801, pp. 1–4 (2007)
- [Rezaee 12] Rezaee, K., Abdulhai, B., and Abdelgawad, H.: Application of reinforcement learning with continuous state space to ramp metering in real-world conditions, in *Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference on*, pp. 1590–1595 (2012)
- [Rickert 96] Rickert, M., Nagel, K., Schreckenberg, M., and Latour, A.: Two lane traffic simulations using cellular automata, *Physica A: Statistical Mechanics and its Applications*, Vol. 231, No. 4, pp. 534–550 (1996)
- [Russell 98] Russell, S.: Learning agents for uncertain environments, in *Proceedings of the eleventh annual conference on Computational learning theory*, pp. 101–103 (1998)
- [Sato 09] Sato, H., Xing, J., Tanaka, S., and Watauchi, T.: An automatic traffic congestion mitigation system by providing real time information on head of queue, in *16th ITS World Congress and Exhibition on Intelligent Transport Systems and Services ITS America ERTICO ITS Japan* (2009)
- [Schneider 02] Schneider, J. and Ebersbach, A.: Anticipatory Drivers In The Nagel–Schreckenberg-Model, *International Journal of Modern Physics C*, Vol. 13, No. 01, pp. 107–113 (2002)
- [Sladover 95] Sladover, S.: Review of the state of development of advanced vehicle control systems, *Vehicle System Dynamics*, Vol. 24, No. 6-7, pp. 551–595 (1995)
- [Sugiyama 08] Sugiyama, Y., Fukui, M., Kikuchi, M., Hasebe, K., Nakayama, A., Nishinari, K., Tadaki, S.-i., and Yukawa, S.: Traffic jams without bottlenecks—experimental evidence for the physical mechanism of the formation of a jam, *New journal of physics*, Vol. 10, No. 3, p. 033001 (2008)
- [Sutton 98] Sutton, R. S. and Barto, A. G.: *Reinforcement learning: An introduction*, Vol. 1, MIT press Cambridge (1998)
- [Transportation] Transportation, of U. D.: National Highway Traffic Safety Administration, <https://www.nhtsa.gov/>: (Accessed on 2018.12.19)
- [Vahidi 03] Vahidi, A. and Eskandarian, A.: Research advances in intelligent collision avoidance and adaptive cruise control, *IEEE transactions on intelligent transportation systems*, Vol. 4, No. 3, pp. 143–153 (2003)
- [Van Arem 06] Van Arem, B., Van Driel, C. J., and Visser, R.: The impact of cooperative adaptive cruise control on traffic-flow characteristics, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 7, No. 4, pp. 429–436 (2006)
- [Walraven 16] Walraven, E., Spaan, M. T., and Bakker, B.: Traffic flow optimization: A reinforcement learning approach, *Engineering Applications of Artificial Intelligence*, Vol. 52, pp. 203–212 (2016)

- [Wang 13] Wang, Z., Lu, M., Yuan, X., Zhang, J., and Van De Wetering, H.: Visual traffic jam analysis based on trajectory data, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 19, No. 12, pp. 2159–2168 (2013)
- [Wang 15] Wang, B., Zhao, D., Li, C., and Dai, Y.: Design and implementation of an adaptive cruise control system based on supervised actor-critic learning, in *Information Science and Technology (ICIST), 2015 5th International Conference on*, pp. 243–248 (2015)
- [Watkins 89] Watkins, C. J. C. H.: *Learning from delayed rewards*, PhD thesis, King’s College, Cambridge (1989)
- [Wolfram 86] Wolfram, S.: *Theory and applications of cellular automata: including selected papers 1983-1986*, World scientific (1986)
- [Won 17] Won, M., Park, T., and Son, S. H.: Toward Mitigating Phantom Jam Using Vehicle-to-Vehicle Communication, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 18, No. 5, pp. 1313–1324 (2017)
- [Xing 07] Xing, J., Takahashi, H., and Takeuchi, T.: Increasing bottleneck capacity through provision of bottleneck location information, in *11th World Conference on Transport Research World Conference on Transport Research Society* (2007)
- [Zamith 10] Zamith, M., Leal-Toledo, R. C. P., Kischinhevsky, M., Clua, E., Brandão, D., Montenegro, A., and Lima, E. B.: A probabilistic cellular automata model for highway traffic simulation, *Procedia Computer Science*, Vol. 1, No. 1, pp. 337–345 (2010)
- [Ziebart 08] Ziebart, B. D., Maas, A. L., Bagnell, J. A., and Dey, A. K.: Maximum Entropy Inverse Reinforcement Learning., in *AAAI*, Vol. 8, pp. 1433–1438 (2008)
- [Zolfpour-Arokhlo 14] Zolfpour-Arokhlo, M., Selamat, A., Hashim, S. Z. M., and Afkhami, H.: Modeling of route planning system based on Q value-based dynamic programming with multi-agent reinforcement learning algorithms, *Engineering Applications of Artificial Intelligence*, Vol. 29, pp. 163–177 (2014)
- [越 正毅 98] 越 正毅 編著：交通工学通論，技術書院 (1998)
- [越 86] 越 正毅：高速道路のボトルネック容量，土木学会論文集，No. 371, pp. 1–7 (1986)
- [越 93] 越 正毅，桑原雅夫，赤羽弘和：高速道路のトンネル，サグにおける渋滞現象に関する研究，土木学会論文集，No. 458, pp. 65–71 (1993)
- [加藤 00] 加藤恭義 他：セルオートマトン法による道路交通シミュレーション (j 小特集j 高度道路交通システム (ITS) と AI)，人工知能学会誌，Vol. 15, No. 2, pp. 242–250 (2000)
- [岩崎] 岩崎征人：渋滞発生と伝播のメカニズム，https://www.jcca.or.jp/kaishi/268/268_toku1.pdf : (Accessed on 2018.12.17)
- [岩崎 12] 岩崎健，鈴木一史，坂井康一，金澤文彦：ACC 車両による高速道路サグ部における渋滞緩和効果，土木技術資料，Vol. 54, No. 5, pp. 30–33 (2012)
- [許 13] 許 海遲，荒井幸代：学習ペースカーによるメタ安定相への遷移の実現，電気学会論文誌 C (電子・情報・システム部門誌)，Vol. 133, No. 9, pp. 1709–1716 (2013)
- [公益社団法人] 公益社団法人 自動車技術会：自動車用運転自動化システムのレベル分類及び定義，<https://questant.jp/q/6KGL1WIR> : (Accessed on 2018.11.30)
- [荒井 98] 荒井幸代，宮崎和光，小林重信 他：マルチエージェント強化学習の方法論：Q-Learning と Profit Sharing による接近，人工知能学会誌，Vol. 13, No. 4, pp. 609–618 (1998)

- [国土交通省] 国土交通省 道路局：交通流対策について， http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/chikyu_kankyo/yakusoku_souan_wg/pdf/005_07_00.pdf：(Accessed on 2018.10.18)
- [山村 07] 山村吉典, 瀬戸陽治, 永井正夫：車車間通信を利用した車群安定 ACC の研究, 日本機械学会論文集 C 編, Vol. 73, No. 731, pp. 1917–1922 (2007)
- [小林 17] 小林正啓：自動運転車の実現に向けた法制度上の課題, 情報管理, Vol. 60, No. 4, pp. 240–250 (2017)
- [須田 15] 須田義大, 青木啓二：自動運転技術の開発動向と技術課題, 情報管理, Vol. 57, No. 11, pp. 809–817 (2015)
- [杉山 03] 杉山雄規：交通流の物理, 日本流体力学会誌 「ながれ」, Vol. 22, No. 2, pp. 95–108 (2003)
- [西成 06] 西成活裕：渋滞学, 2006, 日本物理學會誌, Vol. 64, No. 1, pp. 12–19 (2006)
- [石川 16] 石川翔太, 荒井幸代：先行車情報の共有が自然渋滞に与える影響の解析, 人工知能学会論文誌, Vol. 31, No. 2, pp. D–F32_1 (2016)
- [赤松 88] 赤松隆, 桑原雅夫：確率的利用者均衡条件下での最適混雑料金, 土木学会論文集, No. 389, pp. 121–129 (1988)
- [増淵 09] 増淵達也, 荒井幸代：前方情報を考慮した走行ルールによるメタ安定相の発生と特徴の解析, 電子情報通信学会論文誌 D, Vol. 92, No. 11, pp. 1935–1944 (2009)
- [大前 14] 大前 学：自動車の車間距離制御システムの研究動向 (2014)
- [長谷 03] 長谷川孝明 他：ITS とシステム創成に関する一考察, 情報処理学会研究報告高度交通システム (ITS), Vol. 2003, No. 25 (2002-ITS-012), pp. 13–17 (2003)
- [日高 13] 日高健, 北岡広宣, 北浜謙一, 志田充央, 藤本浩, 金須則之, 小池弘之, 江口純司, 加世山秀樹, 加藤哲也：ACC を活用した高速道路サグ部の交通流円滑化, 自動車技術会論文集, Vol. 44, No. 2, pp. 765–770 (2013)
- [福井 99] 福井良太郎：高度道路交通システム ITS 通信技術, 日本ロボット学会誌, Vol. 17, No. 3, pp. 334–338 (1999)
- [文世 93] 文世一：混雑料金と交通量配分, 土木計画学研究・論文集, Vol. 11, pp. 113–120 (1993)

謝辞

本論文をまとめるにあたり，終始あたたかくご指導ご鞭撻いただいた荒井幸代教授に心より感謝いたします。学部4年生から6年間，先生と研究できたことは，私にとって貴重な経験となりました。また，共に議論した研究室の先輩やメンバーの皆様に感謝いたします。皆様とともに過ごしたかけがえのない時間は，大変刺激的なものであり，自身の成長を促していました。最後に，私自身の意思をいつも尊重し，今までずっと支えてくださった家族に対しては，深い感謝の意を表して謝辞と致します。

研究業績

【学術雑誌に発表した論文】

1. (査読2名) 石川翔太, 荒井幸代: 先行車情報の共有が自然渋滞に与える影響-Nagel Schreckenberg Model の一般化, 人工知能学会論文誌, Vol.31, No.2, p.D-F32_1-8 (2016.2)
2. (査読2名) 石川翔太, 荒井幸代: 渋滞低減に向けた路車間・車車間協調を実現する自動運転方策の学習法, 人工知能学会論文誌, Vol.34, No.1, D-I55_1-9 (2019.1)

【学術雑誌または商業誌における総説や解説】

3. 荒井幸代, 石川翔太, 中田勇介, 北里勇樹: 逆強化学習における脱創発志向の潮流-試行錯誤～見まね～目的理解, 人工知能, Vol.33, No.2, pp.170-180 (2018.3)
4. 建築構造の技術革新と人工知能, 日本建築学会 建築構造と技術革新と人工知能 [若手奨励] 特別研究委員会 (2018.3)
5. 荒井幸代, 石川翔太, 野村俊太: インテリジェントモビリティへの期待とその技術, 計測と制御, Vol.57, No.7 (2018.7)

【国際会議における発表】

6. (口頭発表・査読5名) Ishikawa, S. and Arai, S.: Evaluating Advantage of Sharing Information among Vehicles toward Avoiding Phantom Traffic Jam, in *Proceeding of the 2015 Winter Simulation Conference*, pp.300-311 (2015.12 USA)
7. (口頭発表・ポスター・査読4名) Ishikawa, S. and Arai, S.: Cooperative Learning of a Driving Strategy to Suppress Phantom Traffic Jams, in *Agents (ICA), IEEE International Conference on*, pp.90-93 (2016.9 Japan)
8. (口頭発表・査読3名) Ishikawa, S. and Arai, S.: Learning Cooperative Policy among Self-Driving Vehicles for Relieving Traffic Jams, in *Proceedings of the 10th International Workshop on Agents in traffic and transportation* (2018.7 Sweden)

【国内学会・シンポジウムにおける発表】

9. (口頭発表・査読なし) 石川翔太, 荒井幸代: 利用者均衡をシステム最適へと促す混雑料金の設定, 第28回人工知能学会全国大会論文集, 1C4-OS-13a-5 (2014.4 愛媛)
10. (口頭発表・査読2名) 石川翔太, 荒井幸代: Traffic Breakdown 境界の検出による交通管理の効率化, Joint Agent Workshops & Symposium 2014 (2014.10 宮崎)
11. (口頭発表・査読なし) 石川翔太, 荒井幸代: 先行車情報を共有した走行ルールによる自然渋滞の抑制, 計測自動制御学会第42回知能システムシンポジウム (2015.3 兵庫)
12. (口頭発表・査読なし) 石川翔太, 荒井幸代: 車車間通信の局所的情報による運転戦略の学習, 第

- 29 回人工知能学会全国大会論文集, 1F4-OS-09-3 (2015.5 北海道)
13. (口頭発表・査読なし) 石川翔太, 荒井幸代: メタ安定相を生成する運転戦略の獲得法, 電子情報通信学会人工知能と知能処理研究会, Vol.115, No.97, pp.43-48 (2015.6 東京)
 14. (口頭発表・査読2名) 石川翔太, 荒井幸代: 車車間通信による自動運転車の混在が自然渋滞に与える影響-CACC 普及過程における搭載/非搭載の混合交通流の解析-, Joint Agent Workshops & Symposium 2015 (2015.9 金沢)
 15. (ポスター・査読なし) 山本雄介, 石川翔太, 荒井幸代: マイクログリッド内の需要家連携における電力融通間隔の影響, Joint Agent Workshops & Symposium 2015 (2015.9 金沢)
 16. (口頭発表・査読なし) 石川翔太, 荒井幸代: 自動運転車の協調型運転戦略の導入による渋滞抑制, 第 30 回人工知能学会全国大会論文集, 1H4-OS-05a-4in2 (2016.6 福岡)
 17. (口頭発表・査読なし) 石川翔太, 荒井幸代: CACC 車間の協調走行における通信障害の影響, 第 31 回人工知能学会全国大会論文集, 4I1-1 (2017.5 愛知)
 18. (ポスター・査読なし) 石川翔太, 荒井幸代: 熟練ドライバの運転を学習するための報酬と特徴ベクトルの同時推定法, Joint Agent Workshops & Symposium 2017 (2017.9 千葉)
 19. (ポスター・査読なし) 池永晶子, 石川翔太, 荒井幸代: 多目的計画における代替案選択行動に基づく各目的の選好度推定, Joint Agent Workshops & Symposium 2017 (2017.9 千葉)
 20. (口頭発表・査読なし) 北村清也, 石川翔太, 荒井幸代: 市街地の自動運転における環境情報のフィルタリング, 第 32 回人工知能学会全国大会論文集, 4D2-OS-18c-01 (2018.6 鹿児島)

【受賞歴】

21. 卒業論文「混雑時利用者均衡をシステム最適へと促す誘因の定量化法」, 奨励賞受賞, 千葉大学工学部都市環境システム学科 (2014.3)
22. 修士論文「渋滞緩和・抑制に向けた車車間通信による適応型速度制御モデル」, 優秀論文賞, 千葉大学大学院工学研究科建築・都市科学専攻 (2016.3)
23. 修士論文「渋滞緩和・抑制に向けた車車間通信による適応型速度制御モデル」, 工学研究科長賞, 千葉大学大学院工学研究科 (2016.3)
24. 熟練ドライバの運転を学習するための報酬と特徴ベクトルの同時推定法, 優秀ポスター発表賞, Joint Agent Workshops & Symposium 2017 (2017.9)

【研究資金・助成金獲得歴】

25. 平成 27 年度後期国際会議論文発表者助成, 20 万円, 公益財団法人 C&C 財団 (2015.12)
26. 平成 27 年度 AGSST 大学院生の研究論文発表支援プログラム, 5 万円, 千葉大学大学院工学研究科 (2016.2)
27. 平成 27 年度 AGSST 支援事業博士後期学生支援プログラム, 3 万円, 千葉大学大学院工学研究科 (2016.9)
28. 平成 28 年度 AGSST 支援事業博士後期学生支援プログラム, 7 万円, 千葉大学大学院工学研究科 (2017.3)
29. 平成 30 年度日本学術振興会特別研究員-DC2, 研究奨励費月額 20 万円・研究費 190 万円, 独立行政法人日本学術振興会 (2018.4~)
30. 2018 年度海外渡航旅費援助, 29 万円, 公益財団法人電気通信普及財団 (2018.6)

【その他】

31. 建築構造の技術革新と人工知能特別研究委員会, 委員, 日本建築学会 (2016.4~2018.3)
32. 平成 27 年度特に優れた業績による返還免除, 全額免除, 独立行政法人日本学生支援機構 (2016.5)
33. 平成 28 年度リサーチ・アシスタント業務「建築・都市環境のレジリエンスを支える人工知能」
(2016.9~2017.3)
34. 強化学習アーキテクチャ勉強会, 運営・幹事団, (2017.7~)
35. 千葉大学大学院工学研究科非常勤職員, 技術補佐員, (2017.8~2019.3 予定)
36. Joint Agent Workshops & Symposium 2017, 学生委員 (2017.9 千葉)
37. Joint Agent Workshops & Symposium 2018, 学生委員 (2018.9 広島)