

CACC 車間の協調走行における通信障害の影響

An Effect of Communication Error towards Cooperation of Vehicles Equipped with CACC

石川翔太 *¹ 荒井幸代 *¹
Ishikawa Shota Arai Sachiyo¹千葉大学 大学院工学研究科都市環境システムコース

Department of Urban Environmental Systems Course, Graduate School of Engineering, Chiba University.

We have found that a cooperation among the intelligent self-driving vehicles can control traffic flow for avoiding a phantom traffic jam. The cooperation needs the vehicular ad hoc networks in which individual vehicles communicate with each other. However, vehicles cannot always communicate due to vehicle movement. We therefore introduce a probabilistic communication error which disables a function of communication from the intelligent self-driving vehicles. We simulated a traffic flow where phantom traffic jam and communication error occurred to show an effect of communication error towards cooperation of vehicles equipped with CACC for avoiding a phantom traffic jam. We found communication error disturb the cooperation among the intelligent self-driving vehicles. We also found the intelligent self-driving vehicles learning with communication error were more cooperative than without communication error.

1. はじめに

自動運転への期待は衝突回避にとどまらず、車線変更さらには市街地での安全走行の実現へと広がりを見せている。著者らはこれまで、Cooperative Adaptive Cruise Control 機能を備えた自動運転車 (CACC 車) による協調走行の実現など、自然渋滞の抑制を目的とした運転方策の獲得法を示してきた。

協調走行には車間通信による先行車の状態観測が必要不可欠である。この通信には自動車だけで構成するアドホックネットワークの利用が考えられるが、高速に移動する自動車同士が常に安定して通信することは難しい。

そこで、本研究は通信障害の発生率が CACC 車間の協調走行に与える影響を計算機実験により明らかにする。具体的には、通信障害により通信相手が断続的に観測できない環境と、通信障害が無い環境で協調走行を学習した場合の交通流への影響を比較する。また、各場合での学習後における通信障害環境の変化が交通流に与える影響を観察する。

2. 問題設定

2.1 自動車モデル

自動車モデルに Generalized Nagel-Schreckenberg (以下, GNaSch と記す) モデルを用いる [Ishikawa 16]。GNaSch は個々の自動車が意思決定主体となるマイクロモデルであるため、各自動車に対して手動運転車と自動運転車を区別する設定や、確率的な減速による自然渋滞の再現ができる。表 1 に示す通り、減速確率 p 、通信台数 n^{com} 、通信距離 d^{com} により手動と自動を区別する。

2.2 協調走行の獲得方法

CACC 車間の協調走行を可能にする運転方策は強化学習を用いて獲得する [Sutton 00]。強化学習の枠組みにおいて、運転方策 $\pi(s)$ は CACC 車が観測した状態 s に対する行動 a の出力にあたる。本研究の状態 s の定義を図 1 に、状態 s の要素の設定を表 2 に示す。また、行動 a は GNaSch の減速ルー

表 1: GNaSch モデルの手動と自動 (CACC 車) の設定

	Deceleration prob.	Communication
Human driven vehicle	$p > 0$	$n^{\text{com}} = 0$ $d^{\text{com}} = 0$
Self-driving vehicle equipped with CACC	$p = 0$	$n^{\text{com}} > 0$ $d^{\text{com}} > 0$

State $s_t = \{v_i(t), g_i, v_i(t) - v_{i+1}(t), v_i^{\text{com}}(t), g_i^{\text{com}}, x_i^{\text{com}}(t) - x_i(t)\}$




図 1: CACC 車 i が time step t に観測する状態 s_t の定義 (各要素は 1[セル] ごとの離散値)。通信相手 i^{com} は通信距離 d^{com} 内に先行する一番近い CACC 車。

ルにおいて減速するかしないかの二つである。ここで、状態 s に対する行動 a の価値を $Q(s, a)$ と表す。運転方策 $\pi(s)$ による行動の選択確率は、行動価値 $Q(s, a)$ の大きさに比例するルーレット選択を用いる。time step の変化 $t \leftarrow t + 1$ において、行動価値 $Q(s, a)$ は任意に設定した報酬 r と式 (1) により更新する。式 (1) の学習率 α と割引率 γ はそれぞれ学習結果を反映する割合、将来の報酬を割引して反映する割合である。

報酬 r は自然渋滞の抑制工合を反映させた設計とする。自然渋滞は車間隔の不均一化により発生し、その発生後には停止した車の車群が交通流に現れる *¹。これを踏まえて、本研

*¹ 車間隔が均一な高密度交通流において、車が先行車との車間距離を過剰に大きくした時、車の前方の車間隔は粗に、後方の車間隔は密になる。車間隔が密な部分はさらに密になりながら上流方向へ拡大し、やがて前進するのに十分な車間距離がなくなると車が停止する。

表 2: 状態 s_i の要素における設定

Elements	Condition
g_i	“nothing ahead” $g_i > v^{\text{limit}} + 1$
$v_i(t) - v_{i+1}(t)$	do not change otherwise
g_i^{com}	“nothing ahead” $g_i^{\text{com}} > v^{\text{limit}} + 1$
	do not change otherwise
$v_i^{\text{com}}(t)$	“cannot connect” $x_i^{\text{com}}(t) - x_i(t) > d^{\text{com}}$
g_i^{com}	do not change otherwise
$x_i^{\text{com}}(t) - x_i(t)$	(prior to “nothing ahead”)

表 3: 実験の道路設定

Road length [cell]	$L = 100$
Perturbation area [cell]	$E = 10$
Speed limit [cell/time step]	$v^{\text{limit}} = 5$
Traffic density [volume/L]	25
Penetration rate [%]	20

究では式 (2) に示す通り、車間距離が一定数を超えた車、および停止した車に対して罰 r (負の報酬) を与える。

なお、複数の CACC 車がそれぞれ独立して運転方策を学習するため、協調走行の獲得法はマルチエージェント強化学習となる。

$$Q(s_t, a) \leftarrow (1-\alpha)Q(s_t, a) + \alpha(r + \gamma \arg\max_a Q(s_{t+1}, a)) \quad (1)$$

$$r = \begin{cases} -1 & v_i(t) = 0 \text{ or } g_i > v^{\text{limit}} \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

2.3 通信障害の設定

CACC 車 i が通信相手 i^{com} の状態を確率的に観測できなくなる事象を通信障害として設定する。通信障害が発生した場合、CACC 車の通信距離を $d^{\text{com}} = 0$ に変える。このとき、表 2 の条件により、状態 s_t の通信相手 i^{com} に関する要素 $v_i^{\text{com}}(t), g_i^{\text{com}}, x_i^{\text{com}}(t) - x_i(t)$ の値は “cannot connect” になる。

3. 計算機実験

3.1 実験設定

表 1 に示す自動車の設定を、手動運転の減速確率 $p = 0.05$ 、CACC 車の通信台数 $n^{\text{com}} = 1$ 、通信距離 $d^{\text{com}} = 20$ とした。実験の道路には周期的境界条件の 1 車線道路を用いて、表 3 が示す通りに設定した。道路に車をランダムに初期配置して 1000[time step] 動かした後の交通流を time step $t = 0$ として、 $t = 3000000$ まで実験を行った。この 1 試行のうち $2000001 \leq t \leq 3000000$ の交通流量を計測し、50 試行の平均値を結果とした。表 4 に示す 4 種類の環境において実験を行った。

3.2 実験結果および考察

図 2 の横軸と縦軸はそれぞれ通信障害発生率と交通流量を示す。

常に通信障害が無い NoError に比べて、通信障害がある AllTime の交通流量は減少し、通信障害によって通信相手を観測できない機会が増えるほど、協調走行が困難になることがわかる。

学習後に通信障害がある環境に対して、方策の学習中に通信障害がある環境 (AllTime) と無い環境 (Introduce) を比較すると、Introduce の交通流量の方が小さくなった。これは学

表 4: 学習中 (During learning) と学習後 (After learning) における通信障害の発生期間

	During learning $1 \leq t \leq 2000000$ ($\alpha = 0.01$)	After learning $2000001 \leq t \leq 3000000$ ($\alpha = 0$)
NoError	-	-
AllTime	error	error
Introduce	-	error
Eliminate	error	-

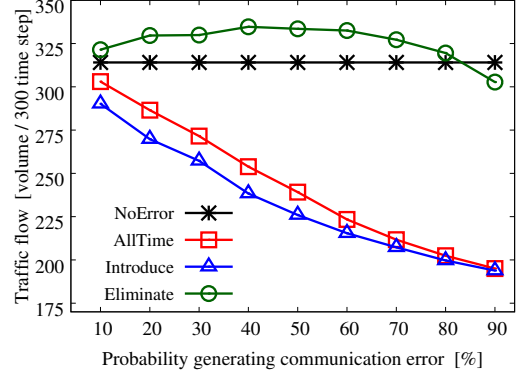


図 2: 通信障害発生率と交通流量の関係

習中に通信障害が無い Introduce では、通信障害でしか起こらない状態遷移に対する学習が不十分であることが原因と考えられる。

一方、学習後に通信障害が無い環境に対して、方策の学習中に通信障害がある環境 (Eliminate) と無い環境 (NoError) を比較すると、通信障害発生率 10% から 80% までの間は Eliminate の交通流量が大きくなった。この結果から、学習中、ある一定の確率により通信相手を観測しない方が学習性能を上げることがわかった。しかし、本研究の問題設定のようなマルチエージェント強化学習において、学習中に他エージェントを観測しないことが学習性能にどのように影響するか、一般的な関係性は著者らの知る限り無い。そのため、結果についてさらなる考察が必要である。

4. まとめと今後の課題

複数の CACC 車が協調走行する交通流に対して通信障害によって「通信相手を観測できない」場合の学習性能を考察した。計算機実験によれば通信障害の発生率が大きいほど、協調走行による効果が小さくなることがわかった。また、学習中に通信相手を確率的に観測しない方が協調走行による効果が大きくなる場合が確認できた。今後は、他エージェントの観測機会が学習性能に及ぼす影響について実験的に考察する。

参考文献

- [Ishikawa 16] 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)
- [Sutton 00] Sutton, R. S., and Barto, A. G.: 強化学習, 森北出版 (2000)