

# 道路交通での速度違反取り締まりにおける確率的な罰政策の効果

Effect of Probabilistic Penalty Policies on Speed Limit for Road Traffic

松井 宏樹\*<sup>1</sup>    和泉 潔\*<sup>2</sup>    野田 五十樹\*<sup>3</sup>  
Hiroki Matsui    Kiyoshi Izumi    Itsuki Noda

\*<sup>1</sup>株式会社シーエムディーラボ  
CMD Laboratory Inc.

\*<sup>2</sup>産業技術総合研究所デジタルヒューマン研究センター  
Digital Human Research Center, National Institute of Advanced Industrial Science and Technology

\*<sup>3</sup>産業技術総合研究所情報技術研究部門  
Information Technology Research Institute, National Institute of Advanced Industrial Science and Technology

We investigate the effect of probabilistic penalty policies on speed control for road traffic. We examined the rate of violators as the effect in some cases on condition that the expected value of penalty is constant using a multi-agent simulation approach. In this paper, we show that the probabilistic penalty policies are not effective in cases that the police is always in operation, however the policies are effective in cases that the operation of the police is dependent on the violation rate.

## 1. はじめに

日本での警察などによる様々な取り締まりは、対象をすべて検査し、違反者を漏らさず発見する方針が採られることが多い。鉄道の改札・検札では、ホームへの入場の際に駅員または自動改札機によって全員の乗車券が確認され、検札が行われる場合には全乗客に対して行われる。もし、不正乗車が行っていると運賃の2倍以内の増運賃を請求される[国土03, 第十九条]。一方、フランスでは入場・出場時の改札がない鉄道もあり、検札も常に行われるわけではない。しかし、万が一、不正乗車が発覚すると運賃の4倍以上の罰金など重い罰が課せられる。

日本での漏れなく確実な違反者の懲罰に対し、フランスの例は確率的ではあるが、より重い罰を課す政策といえる。本研究では、このような確率的な罰政策が違反者数の点でどのような効果があるかマルチエージェントシミュレーションを用いて評価する。

## 2. 問題設定

本研究では、違反者に対する罰の期待値が一定である前提の基で、以下の「道路交通の速度取り締まり」を模したシミュレーションにより確率的な罰政策の評価を行う。

### 2.1 概要

車両(エージェント)が次々に道路を通過する状況を考える(図1)。各エージェントは、道路を走行する際に予想される旅行時間(道路を走行することにかかる所要時間)に基づき「制限速度で走る」「速度違反して走る」を選択する。警察は走行している車両を監視し、設定された政策(罰を与える確率と罰の大きさ)に基づき速度違反したエージェントの取り締まりを行う。実験結果として、速度違反エージェントの割合で警察の政策を評価する。速度違反エージェントの割合がより小さい政策ほどよい政策とする。

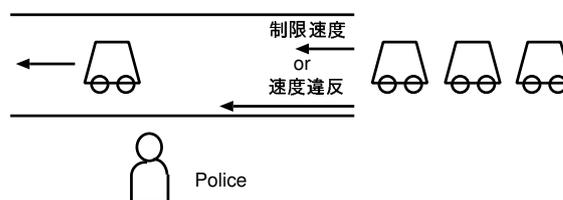


図1 道路交通の速度取り締まりシミュレーションのイメージ

本研究の設定に近い現実の状況としては、渋滞していない高速道路が挙げられる。走行車線と追越車線があり、どちらの車線(速度)で走るかを車両ドライバが選択する。

### 2.2 警察

警察は、出勤しているときに通過した車両エージェントが速度違反をしたら、政策に基づき罰  $b$  を確率  $p$  でエージェントに与える。政策( $b$ と $p$ の設定)は実験設定によるが、罰の期待値  $bp$  は本研究の前提に従い一定であるとする。また、政策は実験中変更しない。単純化のために罰  $b$  は、エージェントの旅行時間に追加されるものとした。

### 2.3 車両エージェント

車両エージェントには、道路を走行する際に行動(速度)  $s$  を「制限速度で走る」( $L$ )か「速度違反して走る」( $H$ )から選択できる。各エージェントは、2つの選択肢からより早く通過できると考えられる選択肢、つまり自身の評価旅行時間  $\tilde{T}_s$  がより短い方を  $\epsilon$ -greedy 選択で決定する。

また、各エージェントは通過後に実際にかかった旅行時間  $T_s$  選択した行動(速度)  $s$  の評価旅行時間  $\tilde{T}_s$  を以下の式で更新する。

$$\tilde{T}_s \leftarrow \alpha T_s + (1 - \alpha) \tilde{T}_s$$

ここで、 $\alpha$  は学習率である。

連絡先: 松井宏樹: matsui@cmdlab.co.jp  
和泉潔: kiyoshi@ni.aist.go.jp  
野田五十樹: I.Noda@aist.go.jp

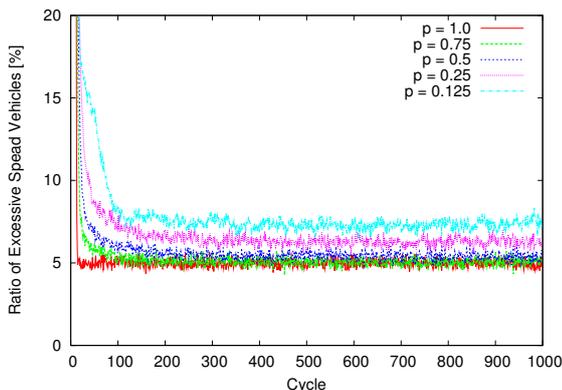


図2 警察が常に出勤している場合の違反者の割合 0~20%付近の拡大図

表1 警察が常に出勤している場合の速度違反の評価旅行時間

$p$	$Q_{\frac{1}{2}}(\tilde{T}_H)$	$\tilde{T}_H$	$\sigma_{\tilde{T}_H}$
1.0	4316.1	4315.1	3.8
0.75	4345.4	4328.4	272.9
0.5	4371.5	4390.3	435.5
0.25	4488.4	4596.0	707.4
0.125	4718.0	4935.5	1110.7

### 3. 実験

警察が常に出勤している場合と警察が違反者の割合によって出勤する場合、それぞれについて実験を行った。それぞれの結果について述べる。

#### 3.1 警察が常に出勤している場合

最初に、警察が常に出勤している設定で実験を行った。この設定では、速度違反を選択した場合に罰が得られる確率は他のエージェントの行動に依存しない。よって各エージェントは、他のエージェントの影響を受けず完全に独立に学習を行う。

理想的に十分学習が進むと、エージェントの各選択の評価旅行時間は

$$\begin{aligned} \tilde{T}_L &= t_L, \\ \tilde{T}_H &= t_H + bp. \end{aligned}$$

$t_L, t_H$  は制限速度、速度違反それぞれの設定旅行時間で前提から  $t_L > t_H$ 。

$(t_L - t_H) < bp$  を仮定すると\*1, 常に  $\tilde{T}_L < \tilde{T}_H$ 。したがってエージェントは、常に「制限速度」(L)を選択すると考えられる。

図2に実験結果を示す。設定は以下の通り。

- エージェント数: 100
- 制限速度選択時の旅行時間  $t_L$ : 3600
- 速度違反選択時の旅行時間  $t_H$ : 2160

\*1  $(t_L - t_H) \geq bp$  の場合は罰を課されても違反した方が有利になるので、ここではそのようなケースは考えない。

- 罰の期待値  $bp$ : 2160
- 学習率  $\alpha$ : 0.1
- ランダム選択確率  $\epsilon$ : 0.1

罰を与える確率  $p$  が 1 の場合は、ランダム選択を行うエージェント以外は全員制限速度を選択するため、違反者の割合は 5% に落ち着く。  $p$  が 1 未満になると徐々に均衡点での違反者の割合が大きくなり、本実験結果では  $p$  が 0.125 のとき違反者の割合も最大になる。

この現象を解析するために、実験最終ステップでのエージェントの速度違反選択時の評価旅行時間の中央値、平均値と標準偏差を表1に示す。 $p$  が 1 の場合は評価旅行時間はほぼ完全に収束しているが、  $p$  が小さくなるにつれてエージェントごとの評価旅行時間のばらつきが大きくなり  $\tilde{T}_L > \tilde{T}_H$  であるエージェントの割合が増えている。このため、  $p$  が小さくなるほど違反者の割合が大きくなる。

#### 3.2 警察が違反者の割合によって出勤する場合

次に、警察が違反者の割合によって出勤する場合の実験結果を示す。

前節では警察が常に出勤している設定で実験を行ったが、現実的には警察のリソースは有限であり違反者の多い、危険な道路で取り締まりを行うと考えられる。そこで、警察に以下のルールを追加する。

最近通過した  $n$  台の車両中、違反車両の割合が  $R$  以上のときに出勤。割合が  $R$  未満のときは出勤しない。

理想的に十分学習が進むと、警察を出勤させずにできるだけ違反すれば平均旅行時間を短くできるので、  $n$  の設定にかかわらず速度違反の選択確率は  $R$  に近づく。その際の、エージェントの評価旅行時間は、

$$\begin{aligned} \tilde{T}_L &> \tilde{T}_H \quad (T_H = t_H) \text{ の確率: } R, \\ \tilde{T}_L &< \tilde{T}_H \quad (T_H = t_H + bp) \text{ の確率: } 1 - R, \end{aligned}$$

となる。

図3, 4, 5に実験結果を示す。また、実験最終ステップのエージェントの速度違反に対する評価旅行時間を表2, 3, 4に示す。設定は以下の通り。下記の設定と学習率以外の設定は、前節の実験と同じである。

- 警察が監視する最近の車両数  $n$ : 20
- 警察が出勤する違反者の割合  $R$ : 0.5

罰を与える確率  $p$  と違反者の割合については学習率  $\alpha$  が 0.1 のように学習率が小さい設定で、罰を与える確率  $p$  が小さくなるほど、均衡点での違反者の割合が小さくなる傾向が見られた。しかし、学習率  $\alpha$  が 0.3 の設定では  $p$  が 0.25 で、学習率  $\alpha$  が 0.5 の設定では、  $p$  が 0.75 の場合に均衡点での違反者の割合が最小になり、  $p$  がそれ以上小さくなると逆に違反者の割合が大きくなった。

図6に、エージェントの学習率  $\alpha$  と罰を与える確率  $p$  の設定による違反者の割合の変化を示す。学習率  $\alpha$  が 0.3 未満の設定では、罰を与える確率  $p$  が小さくなるにつれて違反者の割合も減る傾向にあるが、  $\alpha$  が 0.3 以上になると徐々に  $p$  が小さくなるほど違反者の割合が増える傾向に変化していく。

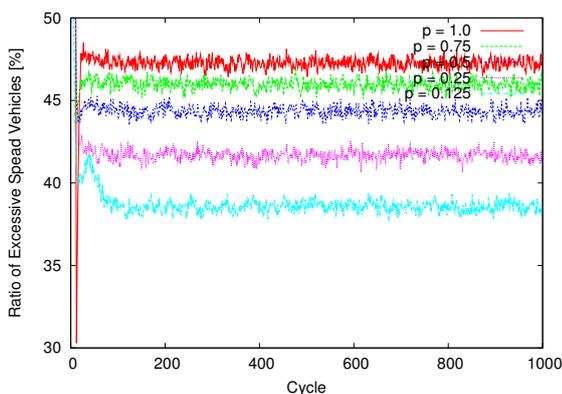


図 3 警察が違反者の割合によって出動する場合の違反者の割合 ( $\alpha = 0.1$ )  
30 ~ 50% 付近の拡大図

表 2 警察が違反者の割合によって出動する場合の速度違反の評価旅行時間 ( $\alpha = 0.1$ )

$p$	$Q_{\frac{1}{2}}(\tilde{T}_H)$	$\tilde{T}_H$	$\sigma_{\tilde{T}_H}$
1.0	3608.0	3449.0	318.7
0.75	3614.4	3428.4	405.8
0.5	3627.5	3412.1	520.2
0.25	3665.7	3421.0	715.0
0.125	3728.9	3481.0	931.9

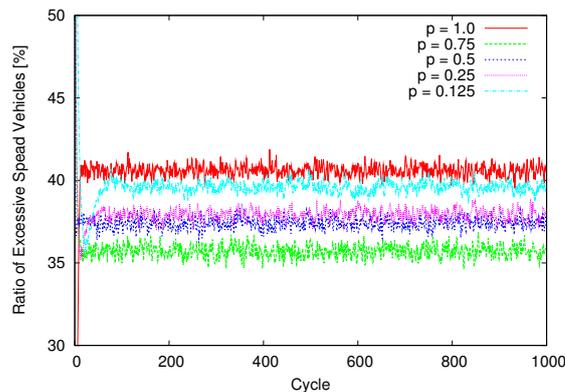


図 5 警察が違反者の割合によって出動する場合の違反者の割合 ( $\alpha = 0.5$ )  
30 ~ 50% 付近の拡大図

表 4 警察が違反者の割合によって出動する場合の速度違反の評価旅行時間 ( $\alpha = 0.5$ )

$p$	$Q_{\frac{1}{2}}(\tilde{T}_H)$	$\tilde{T}_H$	$\sigma_{\tilde{T}_H}$
1.0	3728.7	3367.9	690.0
0.75	3600.0	3241.3	732.3
0.5	4320.0	3674.7	1083.4
0.25	4320.0	4326.2	1860.4
0.125	4320.0	5396.1	3368.0

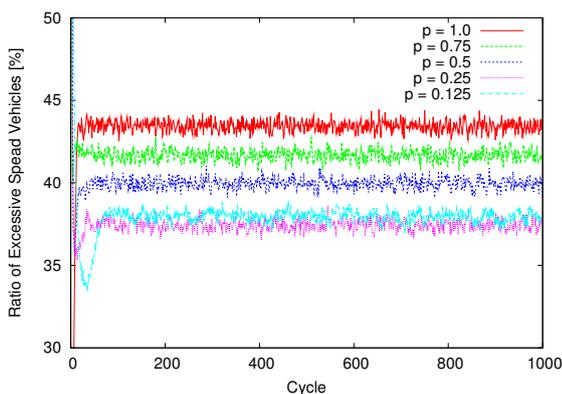


図 4 警察が違反者の割合によって出動する場合の違反者の割合 ( $\alpha = 0.3$ )  
30 ~ 50% 付近の拡大図

表 3 警察が違反者の割合によって出動する場合の速度違反の評価旅行時間 ( $\alpha = 0.3$ )

$p$	$Q_{\frac{1}{2}}(\tilde{T}_H)$	$\tilde{T}_H$	$\sigma_{\tilde{T}_H}$
1.0	3630.5	3374.6	541.1
0.75	3654.2	3378.1	660.9
0.5	3702.1	3450.9	822.1
0.25	3974.5	3717.4	1179.4
0.125	4009.9	4390.7	2015.6

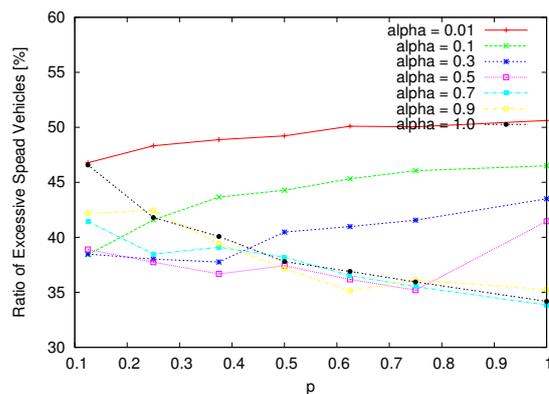


図 6 エージェントの学習率  $\alpha$  と罰の確率  $p$  による違反者の割合の変化

## 4. 議論

### 4.1 実験結果

常に警察が出動する設定では、罰を与える確率  $p$  が 1 未満で罰が確率的な場合に  $p$  が小さくなるほど罰を受けるエージェント数が減るので、常に罰を与える場合に比べて均衡点での違反者の割合が増えることになる。この結果は、 $\epsilon$  によって均衡点の割合が変化する以外は設定による大きな変化はないと考えられる。よって、このケースでは罰を与える確率を大きくした方が違反者の減少に効果が大いといえる。

一方、警察が違反者の割合によって出動する設定では、学習率によって結果に違いが見られた。学習率が小さい場合に

は、罰を与える確率  $p$  が小さいほど違反者の割合は小さくなった。これは、罰を受けたエージェントがその大きな罰の値  $b$  によって速度違反を行う場合の評価旅行時間  $\hat{T}_H$  を制限速度で走ることによる評価旅行時間  $\hat{T}_L$  よりも学習によって大きく設定し、その後、速度違反で罰を受けなくても学習率が小さいために  $\hat{T}_H > \hat{T}_L$  の順序が長く変化しないためだと考えられる。このようなエージェントが存在することで、全体の違反者の割合が減少する。

学習率が大きい場合も、罰を与える確率  $p$  がある程度までは同様の傾向を示す。しかし、ある程度  $p$  が小さくなると速度違反をしても罰を受けない回数が多くなり、罰をうけていない旅行時間  $t_H$  への評価旅行時間  $\hat{T}_H$  の修正が学習率の大きいため少ない回数で行われてしまう。このために  $p$  がかなり小さい場合には、違反者の割合は常に罰を与える場合と変わらないと考えられる。

よって、このようなケースでは罰を与える確率を小さく、罰の値を大きくした方が違反者の減少に効果が大きい傾向があるが、学習率や旅行時間に対する罰の期待値の大きさによってはかならずしもそうはならず、違反者の割合が最低になる確率を見極める必要がある。

#### 4.2 実験設定・有効性

本研究で行った実験設定は、非常に単純なものである。現実の道路交通では、交通量や赤信号などでの停止の有無など同じ速度でも状況により変化がある。また、一般的には速度の選択よりも経路の選択による旅行時間の変化の方が大きいであろう。しかし速度選択に関しては、事故などの危険性を考えない限りはより速い車速の方が旅行時間が短くなる傾向は変わらないと考えられるため、あまり経路選択の起こらない高速道路などであれば同様の現象が起こりうると考える。

また警察の設定に関しては、3.2 節では通行車両の状況を常に把握し、状況に応じて正確に対応する設定で行った。これは現実的には困難であり、例えば出動に関して時間遅れがあるなどが考えられる。この点については考慮する必要がある。

### 5. 関連研究

類似した問題としてエル・ファロールの酒場問題がある。より選択したエージェントが少ない選択肢を選んだエージェントの利得が大きいという点で同じであるが、本研究ではエージェントが同時に選択するのではなく順次選択し、直前のエージェントの選択の影響を受けるという点が異なる。エル・ファロールの酒場問題でのエージェントの振る舞いや系の挙動を調査した研究はある [Hercog 01] が、系自体を制御することに関する研究は見当たらない。

問題はある程度異なるが、社会に見られる現象を管理者の立場から何らかの介入や情報を流すことで管理者にとって望ましい状態にする研究は、最近多く行われている。資源共有問題での情報配信により系を均衡に導く研究 [Ohta 06] や、カーナビゲーションシステムにおいて一度目的地を集め計算して情報配信することで渋滞を解消する研究 [Yamashita 05] などがあ

### 6. おわりに

本研究では、道路交通の速度取り締まりを例に確率的に罰を与える政策をマルチエージェントシミュレーションを用いて評価した。その結果、常に警察が出動し罰を与えられる状態では、確率的ではなく常に罰を与える方が違反者の減少に効果が大き

いが、違反者の割合によって警察が出動する場合は、確率的に罰を与える方が違反者の減少に効果が大きいことがわかった。しかし、違反者の割合によって警察が出動する場合は罰の期待値やエージェントの学習率によって最適な罰を与える確率が変化する。これらの関係を解析することが今後の課題である。

### 参考文献

- [Hercog 01] Hercog, L. M. and Fogarty, T. C.: Social Simulation using a Multi-Agent Model Based on Classifier Systems: The Emergence of Vacillating Behaviour in "El Farol" Bar Problem, in *Fourth International Workshop on Learning Classifier Systems — IWLCS-2001*, pp. 362–366, San Francisco, California, USA (2001)
- [国土 03] 国土交通省：鉄道運輸規程 (2003), <http://law.e-gov.go.jp/htmldata/S17/S17F01301000003.html>
- [Ohta 06] Ohta, M. and Noda, I.: Reduction of Adverse Effect of Global-Information on Selfish Agents, in Antunes, L. and Takadama, K. eds., *Seventh International Workshop on Multi-Agent-Based Simulation (MABS)*, pp. 7–16, Hakodate (2006), AAMAS-2006
- [Yamashita 05] Yamashita, T., Izumi, K., Kurumatani, K., and Nakashima, ki H.: Smooth Traffic Flow with a Co-operative Car Navigation System, in *4rd International Joint Conference on Autonomous Agents and Multia gent Systems (AAMAS)*, pp. 478–485, Utrecht, Netherlands (2005)