

ドライバーの学習過程を考慮した経路選択モデルに関する研究

日本工営(株) 正会員 ○藤高 勝己
鳥取大学工学部 正会員 小林 潔司

1. はじめに

本研究では、不完備情報下におけるドライバーの合理的期待形成行動に着目した合理的期待均衡モデルを開発する。その際、経路選択を繰り返すドライバーの学習行動をベイズ学習過程として明示的に考慮する。さらに、数値実験よりベイズ学習を行うドライバーの合理的期待形成過程を分析する。

2. 合理的期待均衡¹⁾

(1) 経路情報の不完備性 ドライバー m が経路の走行条件の予測に用いる経路情報を ω_m とする。 ω_m を複数のドライバーが共有可能な共有情報 η と、他人にはその内容がわからない私的情報 ξ_m に区別する。ドライバーが利用する経路の走行条件が確定的に把握できない場合、経路情報は不完全であるといい、経路情報が不完全でありかつその一部が私的情報で構成されている場合、経路情報は不完備であるという。

(2) 合理的期待仮説 ドライバーは、不完備な経路情報の下で経路走行条件を主観的に予測する。彼は、日々の経路選択を通じて獲得した経路情報をもとに主観的期待を逐次更新する。このとき、ひとつの長期的な均衡状態として「ドライバーの主観的な期待が実際に実現する客観的な走行条件の変動と一致する」ような状態を考えることができる。すなわち、彼は経路走行条件に関して合理的期待(RE)を形成すると考える。REの下では、彼は主観的期待を修正する誘引を持たない。この均衡状態を合理的期待均衡(REE)と呼ぶ。

(3) 経路選択行動とREE ドライバー m が予測する経路 a の走行時間 τ_a の主観的期待を条件付き確率密度関数 $\pi_m^a(\tau_a | \omega_m)$ で表現する。 π_m^a の下で想定する期待効用を $V_m^a(\omega_m; \pi_m^a) = E_x[U(-\tau_a, \xi_m) | \omega_m]$ と定義する。 U は経路の効用水準を表す効用関数であり、 $E_x[\cdot | \omega_m]$ は π_m^a に関する期待値である。彼は期待効用を最大にする経路 $\gamma_m^*(\omega_m; \pi_m) = \arg \max_a E_x[U(-\tau_a, \xi_m) | \omega_m]$ を選択する。彼は日々の学習により主観的期待 π_m^a を更新する。すべてのドライバーが RE π^* を形成

したとすると、REの下での選択経路は $\gamma_m^*(\omega_m; \pi^*) = \arg \max_a E^*[U(-\tau_a, \xi_m) | \omega_m]$ となる。REEの均衡条件は、任意の ω_m に対して $E^*[U(-\tau_a, \xi_m) | \omega_m] = E^*[U\{-\tau_a(\gamma^*(\omega_m; \pi^*)), \xi_m\} | \omega_m]$ となる。 $E^*[\cdot | \omega_m]$ は客観的に実現する走行時間分布を用いて求めた期待効用である。全ての ω に対して上式を満たす π^* が存在する時、均衡解 $\{\pi^*, \gamma^*(\omega; \pi^*)\}$ をREEと呼ぶ。

3. ドライバーのベイズ学習過程モデル

(1) 経路選択行動の特定化 ドライバーが有する私的情報の独立性を仮定する。彼の期待効用を

$$V_{am}(\omega_m; \pi_m^a) = -\theta_{1,am}[\eta] - \frac{1}{2}\zeta\theta_{2,am}[\eta] + \xi_{am} \quad (1)$$

と定式化する。ここで、 $\theta_{1,am}[\eta], \theta_{2,am}[\eta]$ は経路 a の走行時間 τ_a の期待値と分散値に関する t 期の主観的期待 π_m^a の母数、 ζ はドライバーの絶対的危険回避度、 ξ_{am} は私的情報(確率変数)である。ドライバーは、式(1)を最大にする経路を選択する。以下では、ドライバーの期待形成に分析の焦点を絞るため、共有情報 η を明示的には取り扱わないこととする。

(2) 主観的期待のベイズ更新モデル ベイズ推定論を用いて主観的期待の更新モデルを定式化する。主観的期待と客観的走行時間は共に正規分布に従うと仮定する。経路 a の走行時間分布に関する t 期のドライバーの主観的期待を2つの母数 $\theta_{1,a}(t), \theta_{2,a}(t)$ (平均値 $\theta_{1,a}$, 分散 $\theta_{2,a}/2$) により表現する。彼は、 t 期までに経路 a を n_a 回利用し、各経路の走行時間 $\tau_a = \{\tau_{1a}, \tau_{2a}, \dots, \tau_{n_a a}\}$ を獲得したとする。以後 a を省略する。 t 期の主観的期待ベクトル $\pi^{(t)}$ の下で実現する客観的走行時間が $N(\theta_1, \theta_2/2)$ に従って分布し (θ_1, θ_2 : 未知)、ドライバーが t 期までに実現した各経路走行時間の標本が、 $N(\theta_1, \theta_2/2)$ からのランダム標本であると仮定すると、母数ベクトル $(\hat{\theta}_1, \hat{\theta}_2)$ の同時共役事前分布は正規・逆カイ2乗分布 $N - \chi^{-2}(\mu_0, \nu_0, \alpha_0, \beta_0)$ 、共役事後分布も $N - \chi^{-2}(\mu_1, \nu_1, \alpha_1, \beta_1)$ となる。事前分布と事後分布のパラメータの間には次式が成立する。

$$\mu_1 = \frac{\nu_0 \mu_0 + n \bar{\tau}}{\nu_0 + n}, \quad \nu_1 = \nu_0 + n$$

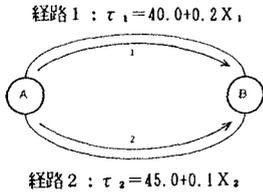


図-1 交通ネットワーク
(図中の式は走行時間関数を示す)

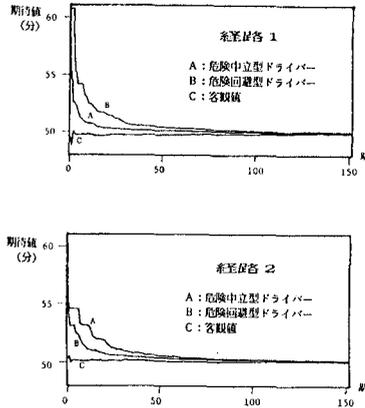


図-2 危険回避度がRE形成に及ぼす影響
(主観的期待値の変化)

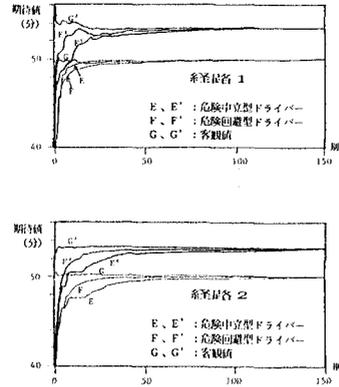


図-3 非合理的ドライバーが合理的ドライバーのRE形成に及ぼす影響
(図中の'は非合理的ドライバーの流入を考慮した場合を示す)

$\alpha_1 = \alpha_0 + \frac{n}{2}, \beta_1 = \beta_0 + s^2 + \frac{\nu_0 n}{\nu_0 + n}(\bar{\tau} - \mu_0)^2$
 $\bar{\tau} = 1/n \cdot \sum_{i=1}^n \tau_i, s^2 = \sum_{i=1}^n (\tau_i - \bar{\tau})^2$ である。各母数の期待値は $E(\hat{\theta}_1 | \tau) = \mu_1, E(\hat{\theta}_2 | \tau) = \beta_1/\alpha_1$ となる。
 (3) ベイズ学習過程モデルの定式化 ドライバー m が t 期に経路 a を選択したと考え、当該経路に関する主観的期待のベイズ学習過程モデルを導出する。 t 期にドライバーが過去の全ての情報を用いてベイズ推定した $t+1$ 期の主観的期待の母数推計式は

$$\theta_1(t+1) = \frac{\nu_0 \mu_0 + n^{(t)} \bar{\tau}_t}{\nu_0 + n^{(t)}} \quad (2)$$

$$\theta_2(t+1) = \frac{1}{\alpha_t} \left\{ \beta_0 + s_t^2 + \frac{\nu_0 n^{(t)}}{\nu_0 + n^{(t)}} (\bar{\tau}_t - \mu_0)^2 \right\} \quad (3)$$

となる。ここで、 $\alpha_t = \alpha_0 + n^{(t)}/2, n^{(t)}$ は t 期末までの当該経路の走行回数である。式(2)(3)を展開すると、ドライバーの主観的期待の母数更新式は

$$\theta_1(t+1) = \theta_1(t) + \frac{1}{\nu_0 + n^{(t)}} \cdot (\tau_t - \theta_1(t)) \quad (4)$$

$$\theta_2(t+1) = \theta_2(t) + \frac{1}{\alpha_t} \left\{ \frac{\nu_t - 1}{\nu_t} (\theta_1(t) - \tau_t)^2 - \frac{\theta_2(t)}{2} \right\} \quad (5)$$

となる。ここで、 $\nu_t = \nu_0 + n^{(t)}$ である。式(2)(3)において t が十分に大きくなれば、主観的期待は $\theta_1(t) \approx \bar{\tau}_t, \theta_2(t) \approx s_t^2/n^{(t)}$ と近似できる。 $\bar{\tau}_t$ と $s_t^2/n^{(t)}$ は標本平均と標本分散である。すなわち、経路選択を十分多く繰り返せば、走行時間の主観的期待値と分散は客観的に実現する標本平均と標本分散に漸近する。換言すれば、初期期待いかにかわからずドライバーの主観的期待は長期的にREに収束することとなる。

4. 数値計算事例

図-1 に示す交通ネットワークを用いてベイズ学習過程モデルの特性を分析する。ドライバーを危険中

立型 50 人 ($\zeta = 0.0$) と危険回避型 50 人 ($\zeta = 1.0$) に分類する。また、ドライバーの初期の主観的期待値を $N(50, 10)$ 、私的情報 $\xi_{a,m}$ は $N(0, 5)$ に従うと仮定した。

(a) 危険回避度の影響 図-2 に危険回避度が異なるドライバー群の中から任意に 1 名ずつ抽出したドライバーの主観的期待値と、実現する客観的期待値の時間的な変化を示す。経路 1 は危険中立型ドライバー、経路 2 は危険回避型ドライバーの主観的期待の方がREにより早く収束していることが理解できる。経路 2 は経路走行時間の分散が小さく、危険回避型ドライバーが利用する確率が高い。彼は、経路 1 よりも早く経路 2 のREを形成することができる。

(b) 非合理的ドライバーの影響 ドライバーの一部が合理的な学習を行わない非合理的ドライバーにより構成されていると考え、彼が合理的ドライバーのRE形成に及ぼす影響を分析する。各経路へ流入する合理的ドライバーの経路交通量が $N(25, 5)$ に従うとする。図-3 に合理的ドライバーの主観的期待の変化を示す。非合理的ドライバーの存在いかにかわからず、合理的ドライバーは各経路の走行時間の分布に関してREを形成することが理解できる。

5. おわりに

合理的なドライバーは、初期期待のいかにかわからず長期的な学習を行なうことによりREを形成することがわかった。今後の課題として、経路情報がRE形成に及ぼす影響を分析することが挙げられる。

参考文献 1) 小林潔司: 不完備情報下における交通均衡に関する研究, 土木計画学研究論文集, No. 8, pp. 81-88, 1990.