意思決定タイミングを内生化した動的な経路選択モデルの構築*

Dynamic Route Choice Model with Explicit Consideration of Decision Timing*

三輪富生**・倉内慎也***・森川高行****

By Tomio MIWA**・Shinya KURAUCHI***・Takayuki MORIKAWA****

１．はじめに

ロードプライシングや交通状態にあわせた応答型の信号制御など，特にIT技術を駆使した交通運用・管理施策が注目を浴びている．それに応じて，施策評価ツールも，静的配分のような代表的な交通状態の再現・予測を目指すものから脱却し，交通シミュレータのように交通需要の時間変動を捉えることが可能なものへと移行しつつある．

ここで，道路交通シミュレータや動的な配分モデルは，時間軸に沿って交通需要を出力できるという点で確かに動的なツールであるが，これはサブモデル自体が動的であるからではなく，静的なモデルを逐次的に適用することにより達成されている場合が多いことに注意が必要である．特に，道路交通シミュレータや配分モデルに組み込まれている経路選択モデルは，ロジットモデルなどの静的な離散選択モデルをベースとして，起点においてのみ実行したり，ノードに到達するごとに実行するものが主流である．このとき，ドライバーが経路選択の意思決定を行うタイミングについては，システムのアルゴリズムを特定する作業を通じて分析者が外生的に与えていることになる．一方，実際のドライバーの意思決定タイミングは任意であり，ここで分析者がおいた仮定の妥当性が問題になる．仮に，起点でのみ経路選択の意思決定が発生するとした場合，実際のドライバーは経路途中においても意思決定をするため，モデルから出力される経路の変更行動は過小に評価され，逆に，ノードに到達するたびにモデルが実行される場合には，経路変更回数を過大に評価するであろう．また，ロジットモデルのような離散選択モデルは，選択を行うことを前提としているが，そもそも意思決定を行うこと自体が保証されているわけではない．特にドライバーへの情報提供効果の分析においては，ドライバーがどのような時に問題を認識し，情報探索や意思決定を行うのかを解明することが決定的に重要となる．従って，経路選択モデルを改良するなどして，意思決定時点がモデルから内生的に特定されるよう，枠組みを拡張する必要があると言える．

経路選択モデルの推定に際しても，同様の注意が必要である．通常は，ODを結ぶ経路を選択肢として，調査により観測された走行軌跡に基づいてパラメータが同定されるが，そもそも観測された走行軌跡は経路途上での選択を含む一連の意思決定の結果として現れるものである．この場合，経路途中では意思決定は生じないという強い仮定をおいていることになるが，誤った意思決定時点の特定は，選択肢集合の特定の問題[1)]と同様に，パラメータ推定値に重大なバイアスが生ずるものと考えられる．

以上のような認識のもと，本研究では，観測される走行軌跡データと整合的な動的経路選択モデルを構築し，従来型の静的モデルとの差異を実証的に検証する．併せて，より一般的な経路選択モデルの構築を目指し，意思決定タイミングを内生化した動的な経路選択モデルの提案を行う．

２．プローブカーデータ

（１）データの概要

本研究では分析対象として中区役所交差点⇔JR名古屋駅桜通タクシーターミナルのトリップを扱う（図－１）．名古屋都市圏において，2002年1月～3月，2002年10月～2003年11月に渡る９ヶ月間に取得されたプローブカーデータより，各起終点付近に発着地を持ち，幹線道路のみを走行するトリップを抽

*キーワーズ：経路選択，プローブカー

**学生員，工修，名古屋大学大学院環境学研究科
（名古屋市千種区不老町，TEL:052-789-3729,
E-mail:miwa@trans.civil.Nagoya-u.ac.jp）
***正員，工修，名古屋大学大学院工学研究科
（名古屋市千種区不老町，TEL:052-789-3565,
E-mail:kurauchi@civil.Nagoya-u.ac.jp）
****正員，Ph.D，名古屋大学大学院環境学研究科
（名古屋市千種区不老町，TEL:052-789-3564,
E-mail:morikawa@civil.Nagoya-u.ac.jp）

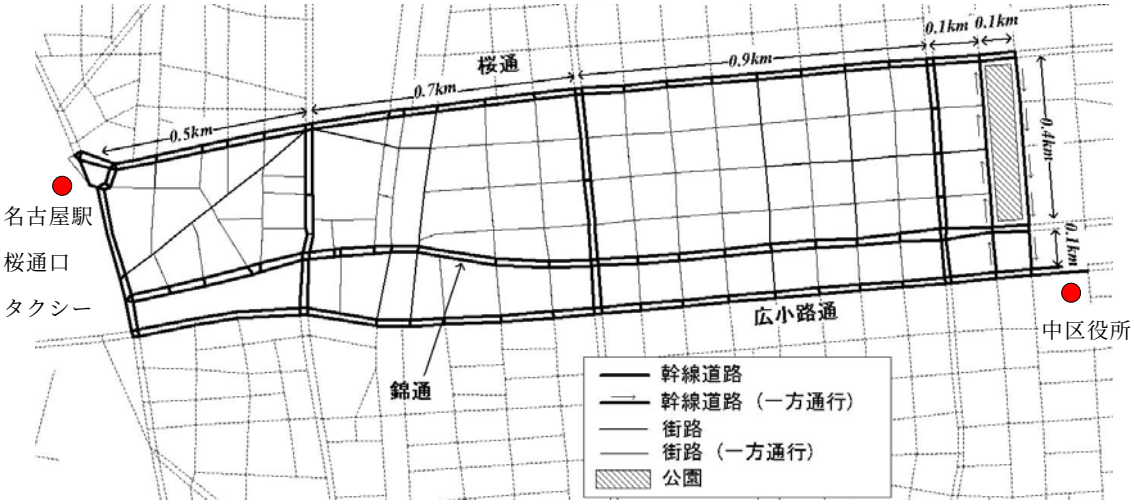

図－１　中区役所⇔JR名古屋駅桜通口タクシーターミナル間のネットワーク

出した．抽出されたトリップデータに関する基礎集計結果を表－１に示す．なお使用するプローブカーデータの概要については文献2)を参照されたい．

表－１　対象トリップデータの概要（平日）

	中区役所→名駅		名駅→中区役所	
経路数	13		14	
発生時刻	トリップ数	平均旅行時間（分）	トリップ数	平均旅行時間（分）
7:00～9:00	21	6.6	105	7.9
9:00～17:00	274	9.2	401	10.5
17:00～19:00	72	10.9	54	11.6
19:00～7:00	267	8.0	181	8.6
合計	634	8.8	741	9.8

（２）リンクコストテーブル

プローブカーデータは，ドライバーが実際に選択した経路やその運転挙動ついては正確に把握できるものの，同時刻において選択されなかった経路についての情報を直接把握することはできない．一方，経路選択行動を分析するためには，代替経路のサービスレベルを知る必要がある．そこで実験期間中に対象エリアを通過した全てのプローブカーデータのリンク通過旅行時間を5分間隔（1日を288区分）に集計することでリンクコストテーブルを作成した[3)]．リンクコストテーブルは平休日別，天候別（降水量1mm以上，未満）に作成されており，これを用いて選択肢集合に含まれる全経路の旅行時間を算出することで，経路選択モデルの分析が可能となる．

３．既存の経路選択モデルの検証

（１）静的モデル

従来，経路選択モデルにはロジットモデルが最も一般的に用いられてきた．非集計モデルや確率的均衡配分では，起点において終点までに走行する経路を一度に選択するような，選択行動を静的に扱うことでモデル化が図られてきた．この時，起点Oにおいて経路kを選択する確率 p_k^O は次式で表される．

$$P_k^O = \frac{\exp\left(V_k^O\right)}{\sum_{k' \in R^O} \exp\left(V_{k'}^O\right)} \qquad (1)$$

$$V_k^O = \sum_i \beta_i x_i^O \qquad (2)$$

ここに，V_k^O は起点Oにおける経路kの効用の確定項，xは説明変数，βは未知パラメータ，R^Oは起点Oにおおける利用可能経路集合，である．

前述のリンクコストテーブルは5分間隔であるため，各経路の所要時間も5分毎に異なった値となる．しかし，ドライバーが5分毎の交通状態の差異を識別しているとは考えにくい．そこで，リンクコストテーブルをピーク時間帯などの特定の時間間隔で再集計して計算される経路旅行時間を用いてモデルを推定し，その適合度を比較することで，ドライバーの経路旅行時間の認知に関して考察を行う．ここでは，A：ピーク・オフピークの時間間隔，B：1時間間隔，C：5分間隔，の3通りの経路旅行時間を作成し，それぞれ選択モデルの推定を行った．ここで，Aのピーク・オフピーク時間間隔とは，朝ピーク（7:00－9:00），昼オフピーク（9:00－17:00），夕ピーク（17:00－19:00），夜オフピーク（19:00－7:00）の4分類である．推定結果を表－２に示す．

結果より，Bのモデルが最も適合度が高く，ドライバーは1時間程度の時間間隔で交通状況を把握し

ていると推測される．著者らの名古屋空港→名古屋を対象とした同様の分析[3)]では，ドライバーは4時間帯程度の交通状況を認知していることを示しており，本研究で扱うような短いOD間では認知旅行時間の精度がより高くなるものと考えられる．

表－２　静的モデルの推定結果

説明変数	A	B	C
旅行時間（分）	-1.18 (-17.0)	-1.14 (-18.0)	-1.05 (-17.4)
右左折数	-1.30 (-36.0)	-1.31 (-37.2)	-1.32 (-37.3)
初期尤度	-3581.724		
最終尤度	-2509.210	-2497.399	-2514.573
ρ^2	0.299	0.302	0.297
AIC	2511.210	2499.399	2516.573

（）内はt値

（２）動的モデル

経路選択行動の代表的表現手法として，ノードに到着する毎にモデルを適用する方法が挙げられる．これは，ノード毎に意思決定が生ずると仮定したものである．しかし，1章で述べたように，観測される走行軌跡は一連の意思決定の結果であるため，前節のような静的モデルを適用することには不適切である．つまり，モデル推定に際しても，ノード毎に意思決定が生ずるような動的モデルを定式化する必要がある．

例として図－２のような簡単なネットワークにおいて，3本の経路が利用可能である（図中破線）ものとすると，経路選択に関する意思決定が発生しうるノードは2つ存在する．つまり起点に相当するノード，及び経路が分岐または交差するノードであり，その他の通過・合流ノードでは経路選択を行わないものと考える．

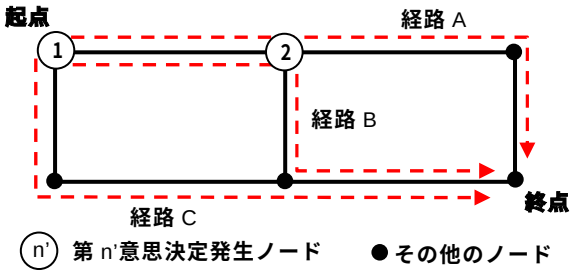

図－２　動的な経路選択の考え方

ここで，観測されたドライバーの選択経路が経路Bであった時，全ての意思決定ノードで選択を行うという仮定のもとで経路Bを選択する確率は次式のように表される．

$$P_B = p_A^1 \times p_B^2 + p_B^1 \times p_B^2 \qquad (3)$$

ここに，$p_k^{n'}$ は第n'意思決定ノードで経路kを選択する確率である．

これをより一般的に書き換えると，式（４），（５）のように表すことができる．

$$P_k = \sum_{\bar{k}^{1,2} \in R^1} p_{\bar{k}^{1,2}}^1 \left(\sum_{\bar{k}^{2,3} \in R^2} p_{\bar{k}^{2,3}}^2 \left(\cdots \sum_{\bar{k}^{n-1,n} \in R^{n-1}} p_{\bar{k}^{n-1,n}}^{n-1} \left(p_{\bar{k}^{n,dest}}^{n} \right) \right) \right) \qquad (4)$$

$$p_{\bar{k}^{n',n'+1}}^{n'} = \frac{\exp\left(V_{\bar{k}^{n',n'+1}}^{n'}\right)}{\sum_{\bar{k}^{n',n'+1} \in R^{n'}} \exp\left(V_{\bar{k}^{n',n'+1}}^{n'}\right)} \qquad (5)$$

ここに，$\bar{k}^{n',n'+1}$ は第n'意思決定ノードで選択可能な経路のうち，意思決定ノードn'～$n'+1$間で経路k（最終的に走行した経路）と重複する経路，$R^{n'}$は第n'意思決定ノードで利用可能な経路集合，$p_{\bar{k}}^{n'}$ は第n'意思決定ノードで経路$\bar{k}$を選択する確率である．

動的モデルでは，起点に近付くにつれ所要時間は短くなるため，意思決定ノードに応じて効用値が異なるが，同時に認知旅行時間が更新される可能性が高い．そこで，起点においては静的モデルで最も適合度の高かった1時間間隔の経路旅行時間を用い，トリップ途中では，D：1時間間隔で更新，E：5分間隔で更新，の2パターンの認知旅行時間の更新を想定してモデルを推定した（表－３）．

表－３　動的モデルの推定結果

説明変数	D	E
旅行時間（分）	-1.23 (-22.4)	-1.19 (-22.4)
右左折数	-1.37 (-33.5)	-1.37 (-33.5)
初期尤度	-3623.483	
最終尤度	-2839.898	-2848.244
ρ^2	0.216	0.213
AIC	2841.898	2850.244

（）内はt値

Dのデータを使用した場合のほうが適合度が高いことから，ドライバーはトリップを開始して現実の交通状況に直面しても，認知旅行時間はそれほど更新していないものと考えられる．また静的モデルと比較すると，動的モデルの方が適合度は低く，今回対象としたような短距離トリップでは，ドライバーはむしろ経路途中で意思決定を行わない傾向にあると言える．パラメータ推定値については，若干では

あるが，動的モデルの方が大きくなっている．これは，意思決定を行っていないにも関わらす動的モデルを適用したため，属性値に対する感度が過小に評価される一方で，動的モデルでは，終点に近付くほど選択肢数は少なくなるため，誤差項の分散が小さくなり，結果としてパラメータ値が大きくなったものと考えられる．

４．意思決定時点を内生化した選択モデル

現実の経路選択行動は，上述の静的モデルと動的モデルの中間であると考えられる．そこで本章では，意思決定が発生するか否かを内生化した経路選択モデルの構築を試みる．

トリップ中の意思決定は，それまでに経験した情報やネットワーク形状などにより説明されると考えられ，意思決定発生モデルは式（６）及び（７）のように二項ロジットモデルで表現できる．

$$q^{n'} = \frac{\exp\left(\lambda^{n'}\right)}{\exp\left(\overline{\lambda}^{n'}\right)+\exp\left(\lambda^{n'}\right)} \quad （６）$$

$$\lambda^{n'} = \sum_i \beta_i x_i^{n'} \quad （７）$$

ここに，$q^{n'}$は第n'意思決定ノードで意思決定が発生する確率，$\lambda^{n'}$は第n'意思決定ノードで意思決定を起こすか否かを規定する関数，$\overline{\lambda}^{n'}$は意思決定をするか否かを判定する閾値，$x^{n'}$は意思決定を起こすか否かをに影響を及ぼす要因，βは未知パラメータ，である．$x^{n'}$としては，例えば，当該トリップにおいて実際に経験したノードn'までの旅行時間と通常時の平均旅行時間との差などが考えられる．つまり，トリップ中での経験に起因して意思決定が発生するが，それが許容範囲内にあれば既に選択している経路をそのまま走行し，新たに経路選択に関する意思決定は行わないことを表現している．

上述の意思決定発生モデルを用いて，トリップ中の意思決定発生確率を考慮した動的な経路選択確率は，図－２の簡単なネットワークを例にすると，式（９）のように表される．

$$P_B = p_A^1 \times p_B^2 q^2 + p_B^1 \times \left(1-q^2\right) + p_B^1 \times p_B^2 q^2 \quad （８）$$

上式の第２項は起点において経路Bを選択し，その後意思決定を行わない確率を表し，その他の項は意思決定発生確率を考慮した動的な選択行動を表している．これをより一般的に書き換えると式（１０），（１１）のように表すことができる．

$$P_k = \sum_{\bar{k}^{1,2}\in R^1} p^1_{\bar{k}^{1,2}} \left(\sum_{\bar{k}^{2,3}\in R^2} \overline{p}^2_{\bar{k}^{2,3}} \left(\cdots \sum_{\bar{k}^{n-1,n}\in R^{n-1}} \overline{p}^{n-1}_{\bar{k}^{n-1,n}} \left(\overline{p}^{n}_{\bar{k}^{n,dest}} \right) \right) \right) \quad （１０）$$

$$\overline{p}^{n'}_{\bar{k}^{n',n'+1}} = q^{n'} \times p^{n'}_{\bar{k}_{n',n'+1}} + \delta_{\hat{k}^{n'}=\bar{k}_{n',n'+1}} \times \left(1-q^{n'}\right) \quad （１１）$$

ここに，$\hat{k}^{n'}$は意思決定ノードn'に到達した時点ですでに選択していた経路，$\delta_{\hat{k}^{n'}=\bar{k}^{n',n'+1}}$は$\hat{k}^{n'}$が意思決定ノード$n'$～$n'$+1において経路$k$と重複するとき1，そうでないとき0をとるダミー変数である．

上式を用いれば，プローブカーデータのような最終的な走行経路や走行中にドライバーが経験した情報から，より現実的な経路選択行動をモデル化することができる．推定されたモデルからは，ドライバーがどのような状況下で経路選択に関する意思決定を行っているか考察することも可能となる．

５．まとめ

本論文ではプローブカーデータを用いて，従来非集計分析や確率的均衡配分で用いられてきた静的な枠組み，および交通シミュレーションで取り扱われてきた，動的な枠組みについて分析を行った．この結果，現実のドライバーは出発前，出発後についても現在地点から目的地側の交通状況についての情報更新をそれほど行わないことが示された．また静的なモデル方がその適合度が高いことから，すべての意思決定ノードで意思決定を行っているとはいえないことを示した．そこで意思決定発生確率を内生化した経路選択モデルを提案した．提案したモデルをプローブカーデータから推定することで，より現実的な経路選択行動を表現しうる交通シミュレーションの開発が可能となると考えられる．

参考文献

1) Swait, J. and Ben-Akiva, M.: Analysis of the effects of captivity on travel time and cost elasticities, In Behavioral Research for Transport Policy, VNU Science Press, pp.119-134, 1986.
2) 三輪富生，境隆晃，森川高行：プローブカーデータを用いた経路特定手法と旅行時間推定に関する研究，第２回ITSシンポジウム2003 Proceedings，pp.277～282，2003.
3) 三輪富生，森川隆行：プローブカーデータを利用した経路選択行動に関するモデル分析，土木計画学研究・論文集，Vol.21，（印刷中）．