

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*

The Model Analysis on Route choice behavior based on Probe-Car Data*

三輪富生**・森川高行***

By Tomio MIWA**・Takayuki MORIKAWA***

1. はじめに

ドライバーの経路選択行動分析は、道路ネットワーク分析において重要な鍵となる作業であり、詳細な交通需要予測においては必要不可欠である。しかし従来の経路選択行動分析の基本的なアプローチは、アンケート形式により収集されたSPデータを用いて経路選択モデルを作成するか¹⁾、もしくは、あらかじめ仮定した経路選択モデルを組み込んだ交通量配分手法や交通シミュレーションの予測結果が、現実ネットワーク上で観測されたリンク交通量にどの程度近づいたかにより評価され²⁾、現実の経路選択行動を観測・分析する作業は行われてこなかった。これは、現実のドライバーが実際にしている経路選択行動を観測することは、極めて大きな費用と労力を要するためである。このため、選択実績や選択状況に関するデータも蓄積されておらず、詳細な経路選択行動や、さらにはこれまで使用してきた経路選択モデルを、観測データから検証した例はほとんどない。

そもそも経路選択行動は、他の交通行動とは大きく異なる特徴を有している。例えはあるOD間において膨大な数の利用可能な経路が存在し、ドライバーがそれらすべてを認知することが難しい点や、道路ネットワーク上の交通状況は時々刻々と変化しているため、出発時点で期待した旅行時間がトリップ中に大きく変わってしまう点などが挙げられる。このため、一度選択した経路上にあるドライバーが、交通状況の変化に応じて利用経路を変更することがしばしばあり、経路選択行動はより動的な枠組みで分析されるべきである。ここで述べる“動的”とは、出発地点での経路選択に加えて、トリップ中においても交通状況の変化に応じて選択経路を変更することを指す。静的な均衡配分のように、トリップ中の時間的変化を扱わない場合においても、現実に選択された経路のアウトプットは、上記のような選択行動の繰り返

*キーワード：経路選択、交通行動分析

**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:052-789-3730, E-mail: miwa@trans.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)

しの結果であり、リンク交通量が各ドライバーの経路選択・変更行動の集積である点を考えれば、このような意思決定構造を明らかにすることは大変重要であり、交通状況の解明につながるはずである。

このようなより現実的な経路選択行動の分析には、ドライバーが実際に選択した結果と合わせて、選択経路を決定する出発時点での交通状況や、選択された経路上を走行する間にドライバーが経験した交通状況についての情報も必要となる。プローブカーシステム（プローブビーカーとも呼ぶ）は、道路ネットワーク上を実際に走行する車両をセンサとして利用することで、走行速度などの交通情報を分析者に提供するシステムである。このシステムから得られる車両の走行軌跡は、現実の交通状況に対してドライバーが選択した経路を正確に分析者に伝えることができ、さらには蓄積したデータを分析することで、時々刻々と変化する周辺の交通状況についての情報を取得することも可能である。そこで本研究では、名古屋都市圏で収集されたプローブカーデータを用いて、実際の道路ネットワーク上においてドライバーが行っている選択行動について分析を行い、経路選択モデルに関する新たな知見を得ることを目的としている。

2. プローブカーデータの概要

(1) 実験の概要

本研究で使用するデータは、2002年1月28日～3月31日の2ヶ月間、名古屋都市圏において行われた「インターネットITSプロジェクト」（主体：経済産業省）の実証実験により取得されたデータである。この実験は名古屋都市圏において1,570台のタクシーをプローブカーとして行われた。データ送信はイベントスキャニングにより行われ、距離周期（300m）、車両発進、車両停止がそれぞれ約30%を構成している。またGPS車載機にはType1～3の3種類があり、Type1, 3 (915台) はGPS機能のみの簡単なモバイルサーバであるのに対して、Type2 (655台) にはカーナビゲーションシステムが装備されており、位置動態情報が精度良く取得できる。このため本研究では、Type2車載機から取得されたデータを分析に用いるものとする。収集データに関する詳細な集計結果については、著者らによりすでにまとめられている³⁾。

本研究のようにタクシーをプロープカーとするデータを用いる場合、乗客が乗車してから降車するまでのデータをトリップデータとして利用することができる。乗客を乗せたタクシーは、目的地に到着する時刻に敏感であることが報告されており⁴⁾、経路選択行動の分析を行うためのデータとしては適している。また著者らは、タクシーの経路選択に関する意思決定は基本的にはドライバーが行い、高速道路を利用するかどうかなど特別な意思決定のみ乗客が行うものと考える。

なお、タクシードライバーのような高頻度利用者の経路選択行動についての分析は、一般的利用者の行動へそのまま反映することは難しい。しかし、これまで得られなかった詳細な選択行動データを分析し、そこから得られる知見は一般的であるとみなせるものが多く、ここで行う分析は、今後の経路選択に関する研究に有用な知見を与えるものであると考える。

(2) データ整理

通常プロープカーデータの走行位置は座標として与えられ、交通データとして最も重要な情報である車両の走行路線については、車両位置座標や走行速度等を用いて道路ネットワーク上にマッチングする必要がある。本研究では、著者らが開発したシステムにより、プロープカーデータを(財)日本デジタル道路地図協会の基本道路網(以下DRMと呼ぶ)にマッチングを行っている⁵⁾。

本研究では、名古屋駅↔名古屋空港間のトリップを対象として分析を進める。このODペアは名古屋都市圏でタクシートリップの最も多いペアの一つであり、観測された経路の経路長は約10~15kmである。観測された経路についての基礎集計結果を表-1に示し、経路交通量図を図-1、2に示す。これらより、実際に利用された経路は非常に多岐にわたっており、特に名古屋駅周辺では、幹線道路以外の街路が頻繁に利用されていることが分かる。さらに名古屋空港→名古屋駅方向では、利用経路数に対して最大利用経路の利用トリップ数が相対的に少なく、利用経路の多様性が著しいことが分かる。

経路選択行動を分析するためには、選択された経路の情報以外にも、選択されなかった経路の情報が必要となる。そこで本研究では名古屋市周辺で発生したトリップをDRMにマッチングし、各リンク旅行時間を5分間隔の時刻ごとに集計することで、旅行時間テーブルとしてデータベース化している。旅行時間テーブルは、平休日別、天候別(降水量1mm以上と未満)に作成され、これを用いれば、あらゆる経路に対して任意の時刻に出発した場合の経路所要時間を算出することが可能となる。

表-1 実験期間中の対象トリップデータ

	名古屋駅→空港			空港→名古屋駅		
	平日	休日	計	平日	休日	計
トリップ数	330	229	559	722	481	1203
利用経路数	216	144	328	445	322	677
最大利用経路*	27	18	42	37	24	61

*最大利用経路：最も利用された経路のトリップ数

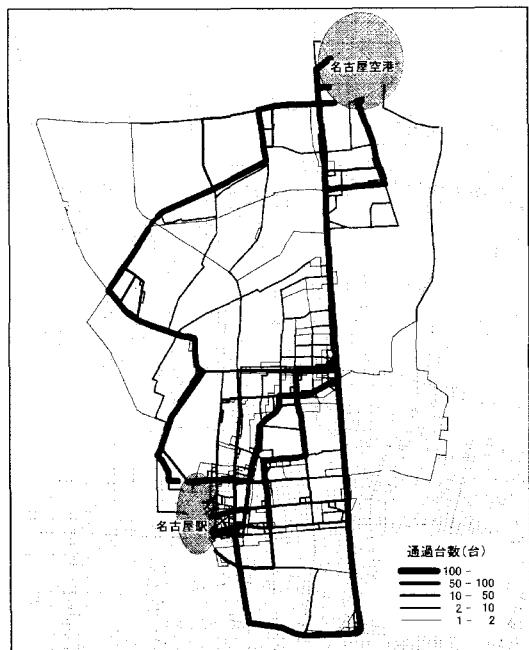


図-1 名古屋空港→名古屋駅の経路

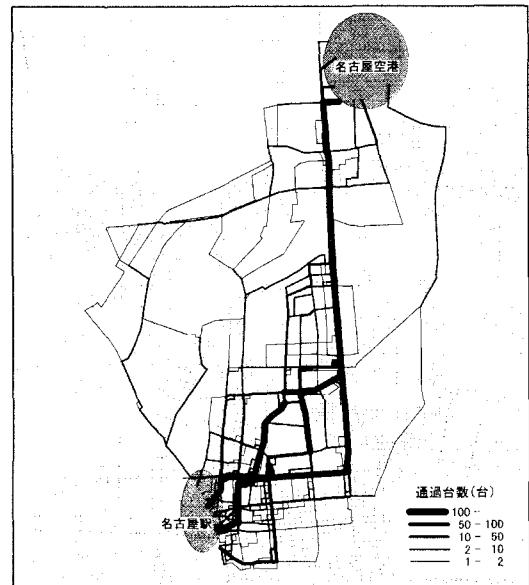


図-2 名古屋駅→名古屋空港の経路

3. 経路情報の認知に関する分析

ここでは、ドライバーが経路を選択する際に、各経路の属性をどのように認知しているかについて分析する。

表-2 所要時間情報の精度を変化させた場合のMNLモデルの推定結果

説明変数	A	B	C	D
旅行時間（分）	-0.0126 (-0.9)	-0.0155 (-1.1)	-0.0304 (-1.9)	-0.0315 (-2.0)
右折+U ターン数	-0.0808 (-1.8)	-0.0778 (-1.7)	-0.0662 (-1.4)	-0.0649 (-1.4)
高速道路定数項	0.386 (2.4)	0.386 (2.4)	0.416 (2.6)	0.415 (2.6)
初期尤度	-4705.759	-4705.759	-4705.759	-4705.759
最終尤度	-4662.467	-4662.257	-4661.052	-4660.885
修正 ρ^2	0.00856	0.00861	0.00886	0.00890
AIC	4665.467	4665.257	4664.052	4663.885

サンプル数：722 (t値)

経路選択における最も重要な属性は経路旅行時間であり、まず旅行時間データの精度を変化させることで、現実のドライバーがどのような情報を基にして選択行動を行っているかを分析する。次いで各経路の通過路線の構成や右折数など旅行時間以外の経路属性についても、それらが経路認知に与える影響について分析を行う。

(1) 経路旅行時間

現実のドライバーは経路を選択するに際して、その最も重要なサービスレベル変数である経路所要時間をどのように認知しているのだろうか。前述したように道路ネットワーク上の交通状況は時々刻々と変化しており、出発時点での交通状況がトリップ終了時点まで保たれることはほとんどない。ドライバーはこのような出発後の交通状況の変化を、出発前にある程度予測した上で選択を行っているのであろうか。そこで以下のような**A**～**D**の4つの旅行時間データを経路選択モデルに適用することで、ドライバーの情報認知について分析を行う。

- A.**交通状況把握は詳細であり、出発後の交通状況の変化も考慮している
- B.**交通状況把握は詳細であるが、出発後の交通状況の変化は考慮しない
- C.**交通状況の把握はせいぜいピーク・オフピーク時間帯程度しか認知していないが、出発後の時間帯の変化は考慮している
- D.**交通状況の把握はせいぜいピーク・オフピーク時間帯程度しか認知しておらず、出発後の時間帯の変化も考慮しない

ここで、**A**、**B**における詳細な交通状況とは、各ドライバーが利用可能経路集合に含まれる全経路上のすべてのリンクに対して、出発時刻におけるリンク旅行時間を把握していることを意味している。**C**、**D**で設定したピーク・オフピーク時間帯とは朝ピーク（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つの時間帯である。また**A**、**B**における交通状況の変化とは、終点に到着するまでに実際に要する旅行時間であり、トリップ中の交通状況の変化を意味する。**C**、**D**における時間帯の変化とは、出発時刻以降のピーク時間帯の変化である。

Aはドライバーの交通状況認知能力を非常に高いものであるとしており、**D**は低い能力しか持たないことを意味している。これら4つの経路旅行時間データは、それぞれ前述の旅行時間テーブルにより作成されている。

使用するモデルは、経路選択モデルとして最も一般的に用いられている多項ロジットモデル（MNLモデル）とし、推定には名古屋空港→名古屋駅方向のトリップデータのうち平日トリップ（722トリップ）を用いた。設定した利用可能経路集合は、実験期間中に同じOD間で観測されたすべての経路（677経路）とする。

推定結果を表-2に示す。この結果から、旅行時間に関する情報があいまいになるほど旅行時間パラメータの値が上昇しており、経路選択への影響が強くなっている。またモデル適合度についても、その値は非常に小さいものの、あいまいな**D**の旅行時間を用いた場合が最も高くなっている。したがって現実のドライバーは、ピーク・オフピーク時間帯程度の交通状況しか認知しておらず、さらに出発前においてトリップ開始後の交通状況の変化までは考慮していないことを示唆している。以上の結果では、推定結果間の差は非常に小さく、検定を行っても有意な差は見られない。しかしこれらの結果から、ドライバーの情報認知能力は、非常に低いものである可能性を示した。

(2) その他の経路属性

経路旅行時間以外の経路属性である、右折回数や通過路線もドライバーの経路認知に影響を与えていていると考えられる。つまり高速道路を主に通過する経路は、多くのドライバーに利用可能経路として認知されているが、右左折の多い経路や、生活道路を多く通過する経路についてはあまり認知されていないと考えられる。しかしプローブカーデータは、ドライバーが選択した経路や選択経路を走行中の交通状況については分析者に伝えることができても、出発時点においてドライバーが利用可能経路集合として認知していた経路についての情報を得ることができない。このためここでは、実験期間中に通過実績が得られた経路が利用可能な全経路集合とし、その中から2トリップ以上に利用された経路が、ドライバーに認知される経路とみなして経路認知モデルを作成する。つ

まり、どのような経路が認知されやすいかを分析するものである。このときモデル式は、2トリップ以上に利用された経路か否かの、2項ロジットモデルとして式(1)で表される。対象ODペアにおいて観測された全経路数は1005経路、その内2トリップ以上の利用実績が確認された経路は190経路である。推定結果を表-3に示す。

$$P_k = \frac{\exp(V_k)}{\exp(\lambda_{cong}) + \exp(V_k)} \quad (1.a)$$

$$V_k = \sum_i \beta_i x_i^k \quad (1.b)$$

ここに、 V_k は経路 k の認知効用の確定項、 β_i は未知パラメータ、 x_i^k は経路 k の i 番目説明変数、 λ_{cong} は認知されるための閾値である。つまり、認知効用が閾値を超える経路は認知されやすい経路であるとしている。

表-3 経路認知モデルの推定結果

説明変数	パラメータ
閾値 λ_{cong}	4.34 (4.0)
右折数 (回 / km)	-5.41 (-5.8)
高速利用距離 / 経路距離	4.88 (4.4)
国道利用距離 / 経路距離	4.45 (3.7)
主要道・県道利用距離 / 経路距離	4.59 (3.8)
初期尤度	-696.613
最終尤度	-435.513
修正 ρ^2	0.368
AIC	440.513

サンプル数 : 1005 (t値)

推定結果より、高速道路がもっとも認知されやすく、国道と主要道・県道は同程度に認知される傾向があり、右折・Uターンの数が増加するほど認知されにくくなる傾向があることが分かる。このよう旅行時間以外の経路属性によっても、ドライバーへの認知のされやすさは異なることが示された。

4. 経路選択モデルの適合度に関する分析

前章ではドライバーが経路選択を行うに際して、どのような情報をもとに選択行動を行っているかについて分析を行った。しかし、最も一般的に用いられているMNLモデルであるにも関わらず、その適合度は低く、実用に耐えうるものとは言い難い。これまでに経路選択モデルは数多く開発されており、すでにこれらを体系的にまとめた論文も発表されている^{6,7)}。開発された多くのモデルは、MNLモデルでは表現できない、いわゆる「赤バス・青バス」問題に代表される選択肢間の類似性の相違を表現するものである。しかしこれら多くの選択モデルが開発される中、本研究で分析対象としているような非常に大きな選択肢集合（677経路）に適用できるモデルはそ

れほど多くない。これまで開発された経路選択モデルの中でも、大きな選択肢集合に対して比較的容易に適用可能なもののとしては、Nested Logit (NL) モデル、C-Logit モデル、Path-Size Logit (PSL) モデルが挙げられる。ここではこれらのモデル用いて、そのモデル適合度から経路選択行動モデル化の可能性について分析を行う。

(1) Nested Logit Model

NLモデルは均衡配分モデルにおいて頻繁に用いられており、これを組み込んだ統合型均衡配分モデルもこれまでに多く開発されてきている⁸⁾。

ここで、ドライバーが利用経路を選択する際には、まず利用幹線道路を選択し、利用幹線に対するアクセス・イグレス経路は幹線ごとに独立した選択肢としてみなせると考えると、経路選択モデルは式(2)で表せる。これは、利用幹線道路が同一である経路間の類似性を考慮している。なお利用幹線道路とは、各経路での最も長い距離で利用された県道以上の路線とする。

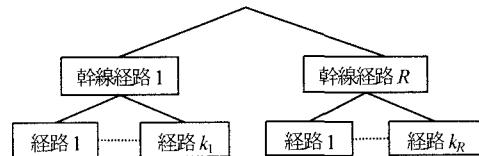


図-3 NLモデルの経路選択構造

幹線 n を選択するとき、経路 l を選択する確率は、

$$P^n(l) = \frac{\exp\left(\mu \sum_i \beta_i x_{l,i}''\right)}{\sum_{l' \in k_n} \exp\left(\mu \sum_i \beta_i x_{l',i}''\right)} \quad (2.a)$$

このとき幹線 n を選択する確率は

$$P(n) = \frac{\exp\{\theta S_n + \alpha\}}{\sum_{n' \in R} \exp\{\theta S_{n'} + \alpha\}} \quad (2.b)$$

$$S_n = \frac{1}{\mu} \ln \sum_{l' \in k_n} \exp\left(\mu \sum_i \beta_i x_{l',i}''\right) \quad (2.c)$$

ここに、 $x_{l',i}''$ は幹線 n を共有する経路 l' の i 番目説明変数、 μ 、 β_i 、 θ 、 α は未知パラメータ、 k_n は幹線道路 n を利用した場合の利用可能経路集合、 S_n は幹線 n を選択したときのログサム変数、 R は利用可能幹線道路集合である。

推定にはこれまでと同様に、名古屋空港→名古屋駅の平日トリップデータを用い、経路選択肢集合は観測された全経路とする。これら経路集合には、幹線経路数は11路線存在する。また経路旅行時間データは、MNLモデルを用いた分析における旅行時間 D と同様に、4時間帯、時間帯変化なしとした。表-4に推定結果を示す。

NLモデルの推定結果をMNLモデルの推定結果と比較

表-4 NLモデルの推定結果

説明変数	パラメータ
幹線選択	ログサム変数 0.939(19.8)
	高速道路定数項 0.617(7.6)
経路選択	旅行時間(分) -0.0319(-2.0)
	初期尤度 -5550.499
	最終尤度 -4661.000
	修正 ρ^2 0.160
	AIC 4664.001

サンプル数: 722 (t値)

する場合には、そのモデル構造の違いから、修正 ρ^2 値ではなくAIC (Akaike's Information Criteria) により比較されるべきである。それぞれのモデルのAICを比較すると、NLモデルの方がその値が大きく、モデル適合度が低いことが分かる。さらに、推定されたパラメータは適切な符号条件が得られているものの、幹線道路選択段階でのログサム変数のパラメータ値が1から十分に離れていない(帰無仮説 =1に対するt値が1.4であり、5%の有意水準で棄却できない)。これは図-3で仮定したネストの構造よりも、すべての経路が並列に並ぶ通常のMNLモデルで表現すべきであることを示唆しており、本研究で用いたデータでは、幹線道路を共有する複数経路間に観測されない類似性(誤差項の相関)はないことが分かる。

(2) C-Logit Model, Path-Size Logit Model

NLモデルの適用結果から、幹線道路を共有する経路間の相関を考慮することによる、モデル適合度の向上は見られず、むしろ各経路を並列に扱うMNLモデルで表現すべきであるといった結果が得られた。しかし実際に各経路間には共有区間が存在し、同じリンクを共有する経路間には何らかの類似性があると考えられる。MNLモデルのように、この相関を考慮しないモデルでは、共有リンクを多く含む経路の予測需要量を過大に推計してしまうといった問題が生じる。C-LogitモデルやPath-Size Logitモデルは、MNLと同様にすべての経路を並列に取り扱うことができる上、各経路に対して利用可能経路集合内の全ての経路との間の類似性を考慮することが可能である。

C-LogitモデルはCascettaらにより提案されたモデルである^{9,10)}。通常のMNLモデルと同様の構造を維持しているため適用し易く、各経路効用関数の確定項に式(3.c)で表されるCommonality Factorと呼ばれる変数 CF_k を組み込むことで、各経路間の類似性を表現している。モデル式を式(3)に示す。

$$P_k = \frac{\exp(V_k - CF_k)}{\sum_{k' \in K} \exp(V_{k'} - CF_{k'})} \quad (3.a)$$

$$V_k = \sum_i \beta_i x_{k,i} \quad (3.b)$$

$$CF_k = \beta_{cf} \ln \sum_{l=K} \left(\frac{L_{kl}}{\sqrt{L_k L_l}} \right)^{\gamma} \quad (3.c)$$

ここに、 V_k は経路 k の効用の確定項、 $x_{k,i}$ は経路 k の i 番目説明変数、 β_{cf} 、 γ は未知パラメータ、 L_{kl} は経路 k と経路 l 間の共有リンク長の合計であり、 L_k 、 L_l はそれぞれ経路 k と経路 l の経路長、 K は利用可能経路集合である。また CF_k は上式以外にも提案されている。

PSLモデルはBen-Akivaらにより提案されたモデルである^{11,12)}。モデルにはC-Logitモデルと同様に、式(4.b)で表される経路間のリンク共有の度合いを表現する修正項 PS_k が組み込まれる。モデル式を式(4)に示す。

$$P_k = \frac{\exp(V_k + \ln PS_k)}{\sum_{k' \in K} \exp(V_{k'} + \ln PS_{k'})} \quad (4.a)$$

$$PS_k = \sum_{a \in A_k} \left(\frac{l_a}{L_k} \right) \frac{1}{\sum_{k' \in K} \delta_{ak'} \frac{L_{k'}^*}{L_{k'}}} \quad (4.b)$$

ここに、 A_k は経路 k を構成するリンク集合、 l_a はリンク a のリンク長、 $\delta_{ak'}$ は経路 k' がリンク a を利用していれば 1、そうでなければ 0 のダミー変数、 L_k^* は最短経路長である。

ここで、それぞれのモデルに組み込まれる修正項について、簡単な比較を行う。図-4のような互いに重なり合う K 本の経路からなるネットワークを考える。

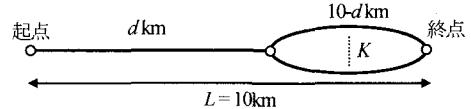


図-4 共有リンクを持つネットワーク

このとき、 CF_k 内の β_{cf} 、 γ の値を便宜的にそれぞれ1とすると、式(3.c)、式(4.b)は以下のように変形できる。

$$CF_k = \ln \left(1 + \frac{d(K-1)}{L} \right) \quad (5)$$

$$PS_k = \ln \left(1 - \frac{d(K-1)}{LK} \right) \quad (6)$$

ここで、式(5)、(6)の括弧内第2項は、 $K>1$ のときどちらも正であるから、 CF_k は正、 PS_k は負の値が算出される。しかしC-Logitモデルの効用関数では CF_k はマイナスの符号を持つので、結果的にどちらも共有リンク長 d や重複経路数 K が大きいほど、その経路の効用を下げる働きをする。図-5にそれぞれの修正値 ($-CF_k$ 、 PS_k の値) と共有リンク長の関係を示す。 $-CF_k$ と PS_k は凹凸関係が逆となっており、さらに $d=0$ または $d=L$ のときはどちらも同じ値となることが分かる。

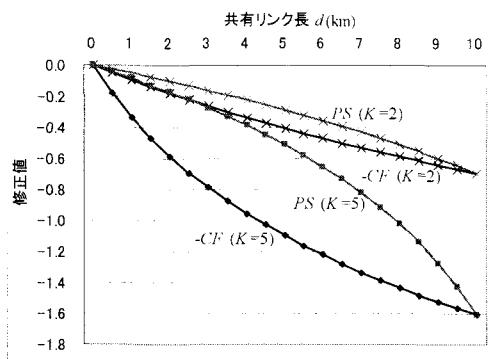


図-5 共有リンク長と補正値の関係

表-5にC-Logitモデルの推定結果を、表-6にPSLモデルの推定結果を示す。Cascettaらは γ の値が1か2程度であるとしており、同時推定された γ の値は妥当な値である。この推定結果から、C-LogitモデルのAICはMNLモデルのそれより低くなっているが、経路選択行動への適合度はMNLモデルよりも幾分高くなっている。したがって各経路間の共有区間の類似性を考慮することにより、モデル精度が向上することが示された。しかしモデルの適合度は依然としてかなり低い値である。またPSLモデルのAICは、推定されたいずれのモデルより高くなり、適合度が最も低くなっている。これは、PSLモデルではその補正項 PS_k にパラメータがつかず、モデルの自由度が低くなっているためであると考えられる。さらに、PSLモデル内の旅行時間パラメータ値は、いずれのモデルよりも高くなっている。C-Logitモデルの補正項 CF_k が0.3のパラメータを持つのに対して、PSLモデルの補正項のスケールが大きすぎるためにモデル適合度を下げていることも分かる。

(3) 分析のまとめ

ここまでMNLモデル、NLモデル、C-Logitモデル、PSLモデルについて分析を行った。しかしこれらのすべてのモデルにおいて、その適合度は非常に低く実用に耐えうるものとはいひ難い。ここまで示した選択モデルは、起点において終点までの詳細な経路を選択するものであり、言い換えれば、ドライバーはどんなにOD間距離が長くても、トリップ中に意思決定を行わないとしている。さらに本研究では、観測されたすべての経路を利用可能経路集合としており、ドライバーの経路選択行動は、起点において677本の経路から利用する1本の経路を選択する行動と捉えている。しかしドライバーが、そのような大規模な集合から経路選択行動を行っているとは考えにくい。実際にはさらに少ない認知経路集合からの選択であると考えられる。ドライバーがトリップ中において、新たに経路を認知／変更するような意思決定を起

表-5 C-Logitモデルの推定結果

説明変数	パラメータ
旅行時間(分)	-0.0332(-2.1)
高速道路定数項	0.652(7.9)
CF_k	β_d γ
	0.310(3.0) 2.13(3.6)
初期尤度	-4705.759
最終尤度	-4638.732
修正 ρ^2	0.0134
AIC	4642.732

サンプル数: 722 (t値)

表-6 PSLモデルの推定結果

説明変数	パラメータ
旅行時間(分)	-0.104(-7.8)
高速道路定数項	0.945(12.2)
初期尤度	-5031.170
最終尤度	-4900.084
修正 ρ^2	0.0257
AIC	4902.084

サンプル数: 722 (t値)

こしているとすれば、起点で認知する経路数が少なくても、利用実績経路数はそれより多くなると考えられる。そこで次節において、より現実的な動的認知／選択を考慮した経路選択行動のフレームワークについて考える。

5. より動的な経路選択行動への展開

(1) トリップ中の意思決定

通常、経路選択行動をモデル化する際には、出発地点において終点までの詳細な経路を、一度に決定すると捉えることがほとんどである。動的シミュレーションのようにトリップ中の意思決定を行う場合においても、出発地点では終点までの詳細な経路を選択し、トリップ中ににおいても出発地点での意思決定と同様の選択を、ノードに到着するたびに単純に繰り返すものである。しかし前述したように、道路ネットワーク上の交通状況は時々刻々と変化しており、ドライバーもこの交通状況の変化に応じて一度選択した経路を変更することが当然考えられる。それではどのような状況で、ドライバーは経路変更を行うのであろうか。著者らは、プローブカーデータを用いて、トリップ中の経路変更行動に関連した以下のようないくつかの分析を行っている⁴⁾。分析に用いられた対象エリアは名古屋駅→中区役所である。このODの大きな特徴として、各経路の大部分を構成する3本の幹線（桜通、錦通、広小路通）の混雑度合いが挙げられる。桜通は8車線であり比較的スムーズな走行が可能であるのに対して、広小路通は、沿線に商店やデパートが建ち並んでおり、駐車車両や歩行者が多いため、通過するためには何度も停止しなければならない。名古屋駅→中区役所のト

リップでは、トリップ開始時点において桜通に接続しており、中区役所→名古屋駅では広小路通りに接続している。それぞれを出発したトリップに対してどのような状況で桜通、広小路通りの利用を取りやめて右折行動を起こしているかを分析した。分析に用いたモデルを式(7)に示し、分析結果を表-7に示す。

$$P_{turn} = \frac{\exp(V_{turn})}{\exp(V_{turn}) + \exp(\lambda_{turn})} \quad (7)$$

ここに、 P_{turn} は右折行動を起こす確率、 V_{turn} は右折行動により得られる効用の確定項、 λ_{turn} は右折行動を起こすための効用の閾値である。

表-7 右折選択モデルの推定結果

説明変数	パラメータ
過去1.0kmに経験した最高速度(km/h)	-0.0461 (-2.8)
過去0.5kmに経験した停止回数(回)	0.295 (2.9)
幹線ダミー	2.73 (7.3)
起点からの走行距離 / OD間距離	4.53 (3.7)
閾値 λ_{turn}	4.00 (4.7)
初期尤度	-354.198
最終尤度	-137.712
修正 ρ^2	0.597
AIC	142.712

サンプル数: 511 (t値)

ここで幹線ダミーとは、目前の交差路線が幹線道路であれば1、そうでなければ0のダミー変数である。この結果から、ドライバーは過去1.0kmに経験した最高速度が高いほど、走行する幹線（桜通・広小路通り）から逸れにくく、過去0.5kmに経験した停止回数が多いほど、走行する幹線から逸れやすい。また交差する路線が、幹線である場合は右折しやすい傾向があるがわかる。このようなドライバーの経路変更行動については、幹線を走行する車両の細街路への迂回行動を取り扱った他の分析でも同様の結果を得ており¹³⁾、ドライバーはトリップ中であっても、直面した交通状況（混雑の度合いやネットワーク状況）によって意思決定行動を繰り返しながら終点に向かっていることが確認された。

(2) 動的な意思決定構造フレームの提案

ここまで分析結果を踏まえて、現実のドライバーが行う経路選択行動の枠組みについてそのフローを図-6に示す。この図では、ドライバーは出発前にはあいまいな経路情報しか認知しておらず、このあいまいな情報を用いて経路を選択する。さらにトリップを行っている際に、当初想定した旅行時間との乖離が確認された場合や、信号タイミングなどをトリガとして、経路変更に関する

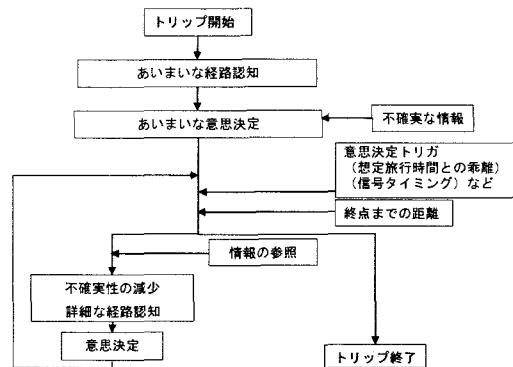


図-6 動的な経路選択行動のフロー

意思決定が行われる。この際の意思決定地点は、トリップ開始地点よりも終点に近くなっていることから、情報の不確実性は減少するであろうことが組み込まれている。このように意思決定トリガ→不確実性の減少→経路選択といった一連の行動を繰り返しながら終点に移動していくと考えることができる。

しかしここで注意が必要な点として、ドライバーの経路選択、変更行動は必ずしも最適な行動であるとは限らないという点である。例えば表-7の分析結果で示されるように、信号停止が増えると迂回経路を探索しだすなど、結果として合理的ではない意思決定も存在することに注意すべきである。

6. 結論と今後の展望

本研究では、プローブカーデータを利用して、ドライバーが実際に選択した経路についての情報、および周辺交通状況に関する情報を収集し、現実のドライバーが行っている経路選択行動に対して幾つかの経路選択モデルを適用することで、経路選択モデルに関する新たな知見を得た。実際に選択されている経路は、非常に多岐にわたっておりかなり多くの経路が存在することや、現実のドライバーの経路情報に関する認知能力は決して高いものであるとはいはず、かなりあいまいな情報を用いて選択行動を行っていることが示された。さらには、経路間の共有リンクを考慮することでその類似性を組み込んだ選択モデルは、これまで一般的に用いられてきたMNLモデルよりも適合度が高くなるものの、実用に耐えうるほどではなかった。現実のドライバーは、信号停止やネットワーク状況などの直面する交通状況に応じて、経路を変更していることを示す分析結果も示されていることから、より現実的な経路選択行動をモデル化するためには、より動的な経路認知／選択行動を対象とした枠組みを用いる必要があることが示された。

より現実的な意思決定過程をモデル化できれば、より

現実的な経路選択行動を再現しうる交通シミュレータ等を開発することが可能となる。しかし、プローブカーデータのみを用いて、ドライバーが起点において、またはトリップ中に認知している経路についての情報を取得することは難しい。したがって今後は、アンケート調査等を行うことも考慮に入れ、より動的な経路選択行動のモデル化に向けて、分析を行う予定である。

最後に、本研究を進めるにあたって貴重なデータを快く提供していただいた、インターネットITSプロジェクトグループの方々、慶應大学植原先生をはじめインターネットITSアプリケーション開発ツール検討委員会の方々から貴重なご意見を頂きました、深く感謝いたします。

参考文献

- 1) 例えば、Bekhor, S., Ben-Akiva, M. E. and Ramming, M. S.: Adaptation of Logit Kernel to Route Choice Situation, Transportation Research Board 81st Annual Meeting, CD-ROM, 2002
- 2) 例えば、桑原雅夫：交通量配分手法の実証的検討、交通工学, Vol.23, No.2, pp.17-25, 1989
- 3) 三輪富生、森川高行、岡田良之：プローブカーデータによるOD表の作成と経路選択行動の分析、第1回ITSシンポジウム2002 Proceedings, pp.591~596, 2002
- 4) Miwa, T. and Morikawa, T.: Analysis on Route Choice Behavior Based on Probe-Car Data, Proceedings of 10th World Congress on Intelligent Transport Systems, CD-ROM, 2003
- 5) 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
- 6) 羽藤英二：ネットワーク上の交通行動、土木計画学研究・論文集, Vol.19-1, pp.13~27, 2002
- 7) 兵藤哲朗、室町泰徳：個人選択行動モデルの最近の開発動向に関するレビュー、土木計画学研究・論文集, Vol.18, No.3, pp.517~522, 2001
- 8) 例えば、Fernandez, E. and Cea, J.D.: Network Equilibrium Models with Combined Modes, Transportation Science, Vol.28, No.3, pp.182-192, 1995
- 9) Cascetta, E.: Transportation Systems Engineering: Theory and Methods, Kluwer Academic Publishers, 2001
- 10) Cascetta, E. et al.: A Model of Route Perception in Urban Road Networks, Transportation Research Part B 36, pp.577~592, 2002
- 11) Ben-Akiva, M.E. and Lerman, S.R.: Discrete Choice Analysis, The MIT Press, Cambridge, Massachusetts, 1985
- 12) Ben-Akiva, M. and Bierlaire, M.: Discrete choice methods and their applications to short term travel decisions, Handbook of Transportation Science, Kluwer Academic Publishers, pp. 5~33, 1999
- 13) Kitamura, S. et al.: Descriptive Analysis of Detouring Traffic through Neighborhood Streets Using Probe Car Data, Proceedings of 10th World Congress on Intelligent Transport Systems, CD-ROM, 2003

プローブカーデータを利用したドライバーの経路選択行動に関するモデル分析*

三輪富生**・森川高行***

ドライバーの経路選択行動分析は、詳細な交通需要予測においては必要不可欠であり、プローブカーシステムから得られるデータは、ドライバーの経路選択行動の解明に向けて有用なデータである。本研究ではプローブカーデータを用いて、現実のドライバーが行っている経路選択行動が、どのような情報を基にして行われており、またどのような選択モデルがこの行動を表現し得るかについて分析した。この結果ドライバーはかなりあいまいな情報を基に選択経路を決定しており、この行動をモデル化するためには、近年開発されつつあるモデルの適用以外にも、トリップ中の経路変更行動を含むより動的な分析フレームが必要であることを示した。

The Model Analysis on Route choice behavior based on Probe-Car Data*

By Tomio MIWA**・Takayuki MORIKAWA***

Analysis on route choice behavior is the key to analyzing travel behavior and traffic demand on road networks. The data from the probe-car systems are very useful for making it clear. In this study we analyze the route choice behaviors, especially the accuracy of the travel time information drivers use for route choice and the fits of several route choice models. The result indicates that drivers use rather rough information on expected travel conditions for route choice, and that necessity of analysis on dynamic route choice behavior and framework of route choice process.