

## プローブカーデータを用いた動的な経路選択行動に関する基礎的分析\*

### Preliminary Analysis on Dynamic Route Choice Behavior Using Probe-Vehicle Data\*

三輪富生\*\*・森川高行\*\*\*・倉内慎也\*\*\*\*

By Tomio Miwa\*\*・Takayuki MORIKAWA\*\*\*・Shinya KURAUCHI\*\*\*\*

#### 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、IT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、施策評価ツールも均衡配分のような静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。

しかし、交通シミュレータや動的配分モデルは、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はあるが、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、これら動的なツー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、到着ノードごとや一定時間間隔に実行するものが主流である。ここで、ドライバーが経路選択に関する意思決定を行うタイミングは、需要予測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。

通常、経路選択モデルの作成段階では、ODを結ぶ経路を選択肢とし、観測された走行軌跡に基づいて全てのODで同一のパラメータが同定される。したがって、これまでに適用されてきた経路選択モデルは、距離の異なるODペアにおける、経路選択行動の変化を考慮するものではない。さらには、著者らはすでに、ドライバーはトリップ中に経験した交通状況や直面した道路ネットワーク条件により、経路選択に関する意思決定を発生させることを明らかにしている<sup>1),2)</sup>。すなわち、観測された

走行軌跡は、経路途上での経路選択行動を含む一連の意思決定の結果として捉えられるべきである。

また、経路途上での意思決定タイミングを分析者が外生的に与える場合は、現実とは異なる意思決定時点の特定により、選択肢集合の問題<sup>3)</sup>と同様にパラメータ推定値に重大なバイアスが生じると考えられる。さらには、今後実用が期待される動的経路誘導における、情報提供効果等の分析結果を誤らせることにもつながる。

そこで本研究では、このような経路選択モデル適用上の問題点を克服するための、基礎的な情報を提供することを目的とし、動的な経路選択行動のより適切なモデル化に向けた基礎的な分析を行う。

#### 2. プローブカーデータとリンクコストテーブル

##### (1) データの概要

本研究では、名古屋都市圏において1570台のタクシーをプローブカーとして、2002年1月～3月、2002年10月～2003年3月に渡る9ヶ月間に取得されたデータにより分析を行う。プローブカーからのデータ送信はイベントスキュー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、データに含まれる情報は、送信時刻、車両走行位置(緯度、経度)、走行速度、加速度、乗客の有無等である。

分析には、収集されたプローブカーデータから実車時(乗客が乗車してから降車するまで)のデータを抽出し、これをDRM基本道路網にマップマッチング処理したものをを用いる。プローブカーデータやマップマッチング処理についてのより詳細な情報は、文献<sup>4)</sup>を参照されたい。

##### (2) リンクコストテーブル

プローブカーデータからは、ドライバーが実際に選択した経路やその運転挙動に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得ることはできない。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、実験期間中に収集され、マップマッチング処理されたプローブカーデータについて、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

\*キーワード: 経路選択, 交通行動分析

\*\*正員, 博(工), 名古屋大学大学院環境学研究所  
(名古屋市中種区不老町, TEL052-789-3565,  
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所  
(名古屋市中種区不老町, TEL052-789-3564,  
E-mail: morikawa@nagoya-u.jp)

\*\*\*\*正員, 工修, 名古屋大学工学部  
(名古屋市中種区不老町, TEL052-789-3565,  
E-mail: kurauchi@civil.nagoya-u.ac.jp)

でリンクコストテーブルを作成した<sup>4)</sup>。リンクコストテーブルは平日日別、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。

また著者らはこれまでの研究において、このリンクコストテーブルの集計時間間隔を変化させ（図-1）、それにより作成される旅行時間情報により経路選択モデルを推定することで、ドライバーが経路選択を行うに際して認知する旅行時間に関して分析を行っている。この結果、名古屋空港→名古屋駅間（OD間距離：約14km）の比較的長いトリップでは、ドライバーはせいぜいピーク・オフピーク時間帯程度の違いしか認知しておらず、さらには出発後の交通状況の変化さえ考慮していない傾向があることを示している<sup>2)</sup>。

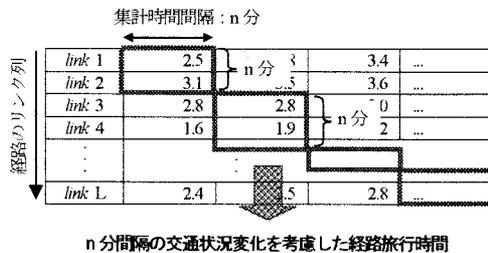


図-1 リンクコストテーブルによる旅行時間情報の作成

### 3. OD間距離による経路選択行動の変化

これまでの経路選択モデル適用場面では、OD間距離によらず同一のモデルを適用することが一般的である。例えば、均衡配分においては都市圏レベルや全国規模の道路ネットワークを対象としているにもかかわらず、全てのODペアに対して経路選択モデルのパラメータは同一である。そこでここでは、距離の異なる複数のODペアを対象として、OD間距離の変化に伴う経路選択行動の変化を分析する。

#### (1) OD間距離と経路選択行動の関係

ここでは、図-2に示す5つのODペアを対象とする。これらのODは、全て名古屋駅桜通口タクシーミナル前を終点に持つ。また、真の起点はトリップによってばらついているため、出発後300m以内に各起点側交差点を通過したデータを同一ODのトリップとする。

各ODペアでの利用可能経路集合は、各ODにおいて観測された全ての経路をそのまま用いず、ある程度集約した経路集合とする。これは、マップマッチングエラーやDRMデータの方向規制情報等のエラーにより、無意味に利用可能経路数が増加するのを防ぐためである。また、ドライバーの経路選択行動についての本質的な分析を行

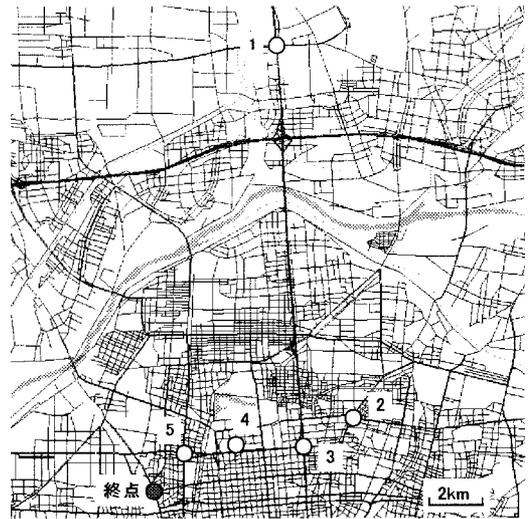


図-2 距離の異なるODペア

表-1 距離の異なるトリップの概要

OD No.	起点 (交差点名)	終点	抽出トリップ数	分析経路数	平均経路長(km)
1	豊場	名古屋駅	482	115	11.8
2	赤塚	桜通口	257	21	4.5
3	東片端	タクシー	316	25	3.3
4	県警本部西	ミナル	284	23	2.3
5	明道町		270	8	1.3

うためには、ある程度の分析経路の整理が必要と考えた。利用可能経路集合は、ODペアごとに2トリップ以上が通過したリンクを抽出し、このリンク上のみを通過して終点まで到達できる経路により構成される。またトリップについては、分析経路を90%以上通過するものとした。ODペアごとのトリップの概要を表-1に示す。

ここで、距離の異なるODペアには、OD間距離の変化以外にも経路数の変化やその他の空間的特性が同時に存在するため、これらを明示的に取り扱った分析が必要となる。しかし、ここでは基礎的な分析を目的とするため、空間的特性の中でも主にOD間距離に取り上げ、その他の空間的特性を代表できるものと捉えて分析を行う。

適用する経路選択モデルはMNLモデルを採用する。また、経路旅行時間は2時間間隔に交通状況の変化を考慮する。これは、ピーク・オフピーク時間帯（4区分）、2時間、1時間、30分、15分、5分間隔の6種類のリンクコストテーブルを作成した上で、出発後の交通状況変化ありとなしについて、それぞれのモデル適合度を分析した結果、モデル間に有意な差は見られず、また明確な傾向は見られなかったためである。ODペアごとの推定結果を表-2に示す。

推定結果より、OD間距離が短くなるほど旅行時間や右左折数のパラメータ値が上昇している。また、OD No.2から4において、OD間距離が短くなるほど国道比率

表 - 2 OD 間距離の異なる OD ペアの経路選択モデル

OD No.	1	2	3	4	5	6 <sup>1)</sup>
利用可能経路数	115	21	25	23	8	--
トリップ数	482	257	316	284	270	1609
平均経路長(km)	11.8	4.5	3.3	2.3	1.3	8.3
説明変数	パラメータ (t値)					
旅行時間 (分)	-0.236 (-8.5)	-0.438 (-2.8)	-0.616 (-3.8)	-1.39 (-9.2)	-2.04 (-10.6)	-0.342 (-16.0)
右左折数 (回)	-0.0771 (-2.9)	-0.185 (-2.7)	-1.31 (-14.0)	-1.17 (-14.6)	-1.68 (-15.4)	-0.391 (-18.1)
高速利用率 <sup>2)</sup>	3.01 (4.5)	--	--	--	--	5.46 (11.5)
国道利用率 <sup>2)</sup>	4.94 (6.5)	17.9 (6.8)	11.3 (6.9)	6.42 (5.5)	--	8.58 (19.0)
県道利用率 <sup>2)</sup>	1.72 (2.4)	15.2 (6.5)	11.2 (7.1)	2.43 (2.8)	--	6.26 (15.4)
初期尤度	-2287.057	-782.442	-1017.165	-890.480	-561.449	-5538.596
最終尤度	-2148.317	-619.278	-607.671	-546.763	-175.272	-4607.420
修正 $\rho^2$ 値	0.0585	0.203	0.399	0.382	0.684	0.167

<sup>1)</sup> 全てのデータをプールして推定した結果 <sup>2)</sup> 高速 (国道、県道) 比率: 高速 (国道、県道・主要道) 利用距離 / 経路距離

や県道比率のパラメータ値が減少しており、短距離トリップほど幹線道路利用の重要性が低下する傾向がみられる。ここで、OD No.1の推定結果は非常に適合度が低い。これは、利用可能経路数が115と大きいことや、経路間での重複区間の存在が原因であると考えられる。

表中のOD No.6は、5つのODペアをプールしたデータによる推定結果である。前述の通り、これまでの経路選択モデルにおけるパラメータは全てのODペアで同一であるとしている。したがって、従来の枠組みで経路選択モデルを適用する場合、ここで取り扱うエリアを対象とすればOD No.6の推定結果を用いることになる。しかし、旅行時間や右左折数のパラメータが示す明確な傾向は、これまでの経路選択モデルの適用方法に対する重要な示唆を与えている。

### (2) 対数を用いた経路選択モデル

OD間距離による経路選択行動の変化を表現するためには、説明変数に対数をとる方法が有効である。すなわち、旅行時間や費用に対して意思決定者がそれらの差を認知するための変化量は、それら属性の対数に比例して変化するという考えであり、ウェーバー・フェヒナーの法則としてよく知られている。

ウェーバーは、感覚の強さに変化を起こすために必要な最小の刺激強度差を $\Delta S$ 、もとの刺激の大きさを $S$ とすると、 $\Delta S / S$ が一定であることを示した。分析対象である経路選択行動において例を挙げると、10分の旅行時間が12分に変化した時に初めてその違いを認知した意思決定者は、20分の旅行時間が22分に変化してもその違いを認知せず、24分に変化してその違いを認知することになる (これらの設定値は説明のために便宜的に設定)。さらに、フェヒナーはこれを以下の式で表した<sup>5)</sup>。

$$E = k \log S + a \quad (1)$$

ここに、 $E$ は感覚量、 $S$ は刺激量、 $k$ 、 $a$ は定数である。

対象とする5つのODペアは、OD間距離が長くなれば

表 - 3 対数を用いた経路選択モデル

説明変数	パラメータ (t値)
log <sub>e</sub> 旅行時間 (分)	-15.1 (-20.9)
log <sub>e</sub> 右左折 (回)	-3.30 (-25.9)
高速比率	4.57 (9.5)
国道比率	6.51 (13.7)
県道比率	5.35 (12.4)
初期尤度	-5538.596
最終尤度	-4335.434
修正 $\rho^2$ 値	0.216

サンプル数: 1609

旅行時間や右左折数も大きくなるため、これら説明変数に対数をとることで、ドライバーの認知構造の変化を考慮することができる。旅行時間や費用の対数を説明変数とすることは、非集計モデル分析において頻繁に行われている<sup>6)</sup>。一般に、属性の対数を説明変数とする場合には自然対数を用いる場合が多いが、ここでは式 (1) に従って常用対数を用いる。常用対数を用いても底の変換により自然対数に変換することが可能であり、モデル適合度やその他のパラメータはどちらの場合も同一である。表 - 3に推定結果を示す。表 - 2における OD No.6と比較して、対数を用いた旅行時間や右左折数の値が上昇し、その説明力が上昇している。また、モデル適合度も大きく上昇しており、OD間距離が変化する場合においても経路選択行動をより適切に表現している。

### (3) スケールパラメータの構造化

対数を用いた説明変数を導入する以外にも、効用の誤差項がODペアごとに変化すると捉えることもできる。これは、目的地までの距離が短い場合は、交通状況や道路ネットワークに対するドライバーの認知度が高く、逆に距離が長い場合はその認知度が低くなると考えられるためである。さらには、OD間距離が長くなるに従って増加する観測された経路の集合が、ドライバーが認知する利用可能経路集合と異なるためとも考えられる。

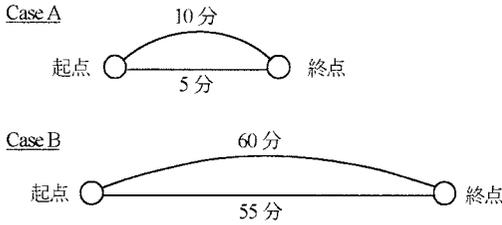


図 - 3 距離の異なるODペア

前者は、図 - 3に示すような距離の異なる2つのODペアにより説明できる。どちらのODペアにも2本の経路が存在し、その差はいずれも5分である。MNLモデルでは各経路の選択確率が効用差で決定されるため、全てのODペアで同一のパラメータを適用する従来の枠組みでは、どちらのケースにおいても短い経路の選択確率は同じである。すなわち、説明変数が旅行時間のみでありスケールパラメータが1であるとき、いずれのケースにおいても旅行時間の短い経路の選択確率は0.993となる。しかし一般的には、OD間距離の短いCase Aでは多くのドライバーが旅行時間の短い経路を選択しても、OD間距離の長いCase BではCase Aほど旅行時間の短い経路に選択が集中しないと考えられる。実際には、OD間距離が長くなれば、各経路の効用に対するドライバーの認知誤差が大きくなり、経路間の効用の差を正確には判断できなくなる。すなわち、OD間距離の増加とともに誤差項の分散が大きくなり、スケールパラメータが小さくなると考えられる。例えば、Case Bにおいてはスケールパラメータが0.1であるとすれば、旅行時間55分の経路の選択確率は0.622となる。

一方、後者は、実験期間中に観測された経路の集合を利用可能経路集合とすることによるものである。つまり、観測された経路集合に含まれる、旅行時間が十分に短い（または、右左折数が十分に少ない）経路をドライバーが利用可能経路として認知していないとき、導入した説明変数ではその選択構造を表現することができず、モデル内では誤差項として表現されてしまう。これは、Swait and Ben-Akivaにより分析された選択肢集合の特定の問題とも類似しており<sup>3)</sup>、ドライバーが認知する利用可能経路集合に関する詳細な分析を必要とする。しかし、本研究で使用するプローブカーデータからは、ドライバーの属性に関する情報が得られない。また、経路選択モデルを適用するために頻繁に用いられるDialのアルゴリズムは、OD間に存在する全ての経路を対象としている。したがって、経路選択モデルの適用場面を踏まえれば、観測されたすべての経路を利用可能経路とする分析から得られる知見は、十分有用であると考えられる。

そこで、5つのODペアをプールのデータにより、ODペアごとのスケールパラメータを推定した（表 - 4）。

表 - 4 距離の異なるODペアのスケールパラメータ

説明変数	パラメータ (t値)	
旅行時間 (分)	-1.52 (-14.2)	
右左折 (回)	-1.28 (-17.7)	
高速比率	4.61 (2.3)	
国道比率	5.61 (7.9)	
県道比率	5.03 (7.9)	
スケールパラメータ	OD No. 1	0.114 (8.3)
	OD No. 2	0.426 (11.2)
	OD No. 3	0.913 (14.7)
	OD No. 4	1 (-)
	OD No. 5	1.10 (13.8)
初期尤度	-5538.596	
最終尤度	-4184.558	
修正 $\rho^2$ 値	0.243	

サンプル数：1609

ここで、全てのODペアにおいてスケールパラメータを未知とすることはできないため、OD No. 4（平均経路長2.3）のスケールパラメータを1とした。

表 - 4に示された結果から、ODペアごとのスケールパラメータは、OD間距離の減少により単調に増加していることが分かる。しかし、実際に適用の対象となる全てのODごとにスケールパラメータを推定することは困難であるため、ODペアの属性によりスケールパラメータを構造化することが有効である。

MNLモデルにおける効用の誤差項はガンベル分布に従い、その分散は以下の式で表される。

$$\text{Var}(e_k^rs) = \frac{\pi^2}{6\mu_{rs}^2} \quad (2)$$

ここに、 $e_k^rs$  はODペアrs間の経路kを選択することで得られる効用の誤差項、 $\mu_{rs}$ はスケールパラメータである。

ここで、スケールパラメータ $\mu_{rs}$ が、OD間距離により式(3)のように、または利用可能経路数により式(4)のように構造化可能であるとする。

$$\mu_{rs} = \frac{\pi}{\sqrt{6}} D_{rs}^a \quad (3)$$

$$\mu_{rs} = \frac{\pi}{\sqrt{6}} R_{rs}^\gamma \quad (4)$$

ここに、 $D_{rs}$ はODペアrs間の距離(km)、 $R_{rs}$ はODペアrs間で観測された利用可能経路数(本)、 $a, \gamma$ は未知パラメータである。

上2式のように構造化されたスケールパラメータを用いて、再度5つのODペアをプールのデータにより、MNLモデルを推定した（表 - 5）。この結果から、構造化されたスケールパラメータを導入した2つのモデルは、構造化前のモデル（表 - 2のOD No.6）や、さらには旅行時間や右左折数に対数を用いたモデル（表 - 3）と比較してモデル適合度が向上している。したがって、OD間距離が増加するに従い、ドライバーの経路属性に対す

表 - 5 構造化スケールパラメータを用いた推定結果

説明変数	パラメータ (t値)	
	OD間距離	利用可能経路数
旅行時間 (分)	-1.85 (-13.5)	-6.16 (-8.2)
右左折回数 (回)	-1.79 (-16.8)	-5.46 (-9.0)
高速利用率	3.76 (2.0)	19.0 (2.9)
国道利用率	11.4 (9.9)	45.6 (8.5)
県道利用率	6.98 (6.8)	34.4 (7.7)
構造化パラメータ	$\alpha$	-0.951 (-25.1)
	$\gamma$	-0.734 (-23.3)
初期尤度	-5538.596	-5538.596
最終尤度	-4242.853	-4302.836
修正 $\rho^2$ 値	0.233	0.222

サンプル数: 1609

る認知誤差や、利用可能経路集合の不整合が大きくなり、スケールパラメータの構造化によりこれらの影響を表現可能であることが示された。ただし、ドライバーの認知誤差や利用可能経路集合の不整合は、経路選択モデル分析において同時に介在する問題であり、ここでの分析はどちらか一方を扱っているに過ぎない。これらを同時に扱ったモデルについても分析を試みたが、対象ODペア数が少なく、適切な推定結果を得ることができなかった。これら複数の空間的影響を同時に扱った分析については、今後の重要な課題の1つである。

なお、利用可能経路数よりも、OD間距離により構造化されたモデルの方がその適合度は高い。これは、表 - 4で示された各ODペアのスケールパラメータは、OD間距離の減少により単調に増加しているのに対して、観測された利用可能経路数はOD No.2~4の間でほとんど変化せず、特にOD No.2での利用可能経路数はOD No.3, 4より少ないためであると考えられる。また、利用可能経路集合により構造化されたモデルのパラメータが、OD間距離により構造化されたモデルより3~5倍のスケール値を持つのは、経路数がOD間距離よりも大きく、構造化後のスケールパラメータが小さくなるためである。

ここで、 $\alpha$ の値は-1から有意に離れていない(帰無仮説  $\alpha = -1$ に対するt値が1.3となり、5%の有意水準で棄却できない)。  $\alpha = -1$ であるとき、式 (3) は以下のように変形できる。

$$\sqrt{\frac{\pi^2}{6\mu_n}} = SD(\epsilon_k^n) = D_n \quad (5)$$

これは、誤差項の標準偏差がOD間距離により表現可能であることを意味する。参考として、図 - 4に構造化されたスケールパラメータと、表 - 4で推定されたODペアごとのスケールパラメータを示す。ただし、表 - 4で推定されたスケールパラメータは、OD間距離が約2kmのときに1と基準化しているため、図中に示す構造化後のスケールパラメータも、スケール軸方向にその値を修

正している。

ここで、経路選択モデルにおける説明変数に対数をとることは、経路選択モデルの再現性を大きく向上させる1つの方法ではあるが、交通量配分や交通シミュレータへの適用が困難となる場合があることに注意しなければならない。これは、経路選択モデルを容易に適用するために用いられるDialのアルゴリズムでは、経路効用がリンク効用の総和となることが前提とされているためである。一方、スケールパラメータを構造化する方法であれば、すべてのODペアの交通量をネットワーク上に同時に負荷することは困難となるものの、OD間距離によりODペアを幾つかのセグメントに分割すれば、Dialのアルゴリズムにより配分計算を行うことが可能である<sup>7)</sup>。このように、経路選択モデルの適用においても、スケールパラメータの構造化は有効な方法であるといえる。

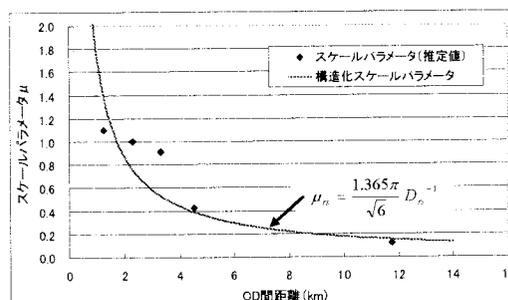


図 - 4 推定されたスケールパラメータと構造化後のスケールパラメータ

#### 4. トリップ中の経路選択行動

多くの動的交通量配分システムでは、トリップ中の意思決定タイミングは分析者が外生的に与えている。確かに、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、ドライバーも交通状況の変化に応じて一度選択した経路を変更する。しかし、実際に意思決定を行っていない状況下にもかかわらず経路選択モデルを適用すれば、再現されたドライバーの選択は、現実よりも交通状況認知能力の高い行動として再現されるであろう。

トリップ中の意思決定が発生するとすれば、その際の経路選択行動を表現するモデルパラメータはどのように変化するであろうか。そこで、図 - 2, 表 - 1で示したODペアのうち、豊場交差点から名古屋駅桜通口に向かうOD (OD No. 1) において、トリップ中に通過する幾つかの主要な交差点で意思決定が発生していると仮定して経路選択モデルを推定した。これは、交通シミュレータ等において、到着交差点ごとに経路選択を繰り返すと仮定していることを踏まえれば、妥当な仮定である。

モデルはこれまでと同様にMNLモデルとし、各経路

の旅行時間は2時間間隔に交通状況の変化を考慮すると  
している。各通過交差点の位置を図-5に、通過トリ  
ップの概要を表-6に示す。これらのデータを用いて、各  
交差点通過時のデータ、およびプールしたデータにより  
経路選択モデルを推定した。ここで、プールしたデータ  
には、同一トリップが複数の通過交差点で使用される可  
能性があるが、本研究では、同一トリップの連続する意  
思決定はそれぞれ独立であると仮定する。

推定結果を表-7に示す。ここで、表-4でスケールパ

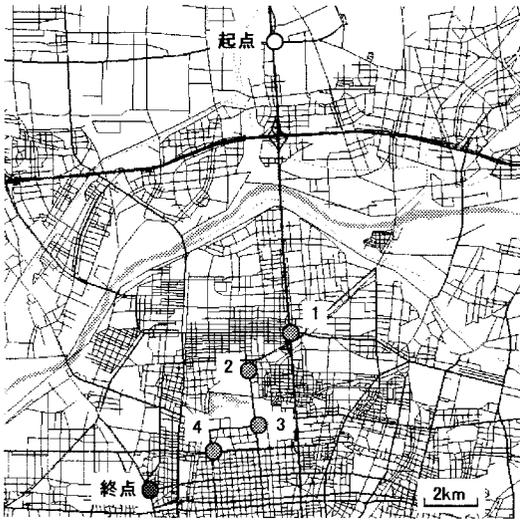


図-5 トリップ中の経路選択の分析対象交差点

表-6 通過交差点と通過トリップの概要

通過交差点 No.	起点交差点	通過交差点	終点	トリップ数	分析経路数	平均経路長 (km)
1	豊場	黒川	名古屋駅	197	70	5.5
2		城北橋	桜通口タ クシータ	173	61	4.1
3		市役所	ーミナル	95	24	3.2
4		新御園橋		83	22	1.9

ラメータを1としたOD間距離が約2kmであったことから、  
終点までの距離が同様な通過交差点No.4（御園橋交差  
点：終点までの距離1.9km）においてスケールパラメ  
ータを1とした。通過交差点ごとに推定されたスケールパ  
ラメータ（通過交差点No.6）より、トリップ中の走行位  
置が終点に近づくにつれスケールパラメータの値が大き  
くなっており、誤差項の分散が小さくなっている。

参考として、図-6に推定された通過交差点ごとのス  
ケールパラメータを、図-4に示された距離の異なるOD  
ごとのスケールパラメータや、構造化後のスケールパラ  
メータとともにプロットした。これにより、トリップ中  
の経路選択行動を表現するスケールパラメータの変化は、  
OD間距離の変化に伴うスケールパラメータの変化とほ  
ぼ同様であることが分かる。

しかし、表-7で示された各モデルは、いずれも適合  
度が非常に低い。同様のOD間距離、利用可能経路数で  
ある、表-2の OD No.3（利用可能経路数：25、OD間  
距離：3.3km）の修正 $p^2$ 値が0.399であるのに対して、通  
過交差点No.3（利用可能経路数：24、終点までの距離：  
3.2km）の修正 $p^2$ 値は0.0394と非常に小さい。これを説  
明する原因の一つとしては、対象とする通過交差点にお  
いて、必ずしもすべてのドライバーが意思決定を行って

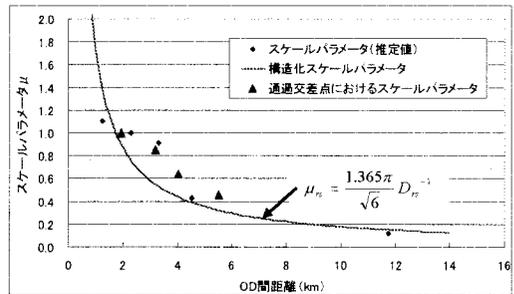


図-6 トリップ中の経路選択の分析対象交差点

表-7 トリップ中の経路選択行動モデル

通過交差点 No.	1	2	3	4	5 <sup>*1</sup>	6 <sup>*1</sup>
利用可能経路数	70	61	24	22	--	--
トリップ数	197	173	95	83	548	548
平均経路長(km)	5.5	4.1	3.2	1.9	4.1	4.1
説明変数	パラメータ (t値)					
旅行時間 (分)	-0.487 (-5.0)	-0.469 (-3.3)	-0.914 (-3.2)	-0.697 (-1.8)	-0.570 (-8.1)	-0.956 (-4.1)
右左折数 (回)	-0.156 (-4.0)	-0.271 (5.2)	-0.266 (-2.6)	-0.703 (-3.5)	-0.208 (-7.3)	-0.378 (-3.4)
国道利用率	0.916 (1.8)	2.02 (2.9)	6.90 (1.1)	-- --	1.10 (3.4)	1.86 (2.9)
県道利用率	0.431 (1.2)	-- --	3.51 (0.5)	1.21 (0.8)	0.227 (1.0)	0.306 (0.7)
スケールパ ラメータ	地点 No.1					0.458 (3.6)
	地点 No.2					0.637 (3.4)
	地点 No.3					0.856 (2.7)
	地点 No.4					1 (-)
初期尤度	-836.954	-711.181	-301.915	-256.557	-2106.605	-2106.605
最終尤度	-806.437	-678.963	-286.026	-235.565	-2021.134	-2016.043
修正 $p^2$ 値	0.0317	0.0397	0.0394	0.0623	0.0387	0.0397

\*1 全てのデータをプールして推定した結果

いるわけではないためであると考えられる。すなわち、ドライバーが走行を続ける経路が、対象とする通過交差点において最適でなければ、モデル適合度は低くなる。また、上表からは、旅行時間のパラメータがばらついてることが分かる。これは、各経路の旅行時間にそれほど差がないためや、旅行時間以外の変数の説明力が小さくなったためなどが考えられる。

いずれにしても、通過交差点以前の真の意思決定地点ではドライバーにとっては最適であった経路でも、トリップ中の交通状況の変化により最適ではなくなってしまうのは当然である。仮に、ドライバーが到着する交差点ごとに必ず意思決定を繰り返しているとすれば、さらに適合度が高くなるはずである。したがって、ドライバーは一度選択した経路をすぐには変更せずそのまま走りようとする、いわゆる“慣性”のような現象が起きていると考えられる。Mahmassaniらは通勤交通を対象として、ドライバーは旅行時間のより短い経路に関する情報を与えられても即座には経路を変更せず、走行中の経路を引き続き走行する傾向があるとしている<sup>3)9)</sup>。ここで示された結果は、運転経験の豊富なタクシードライバーでさえ、同様の傾向を持つことを示している。

## 5. 意思決定時点を内生化した経路選択モデル

ここでは、トリップ中の意思決定時点を内生化した経路選択モデルを開発、適用することで、トリップ中の意思決定の発生現象を考慮した経路選択行動のモデル化に対する新たな知見を得ることを目的とする。

図-7に示すような簡単なネットワークを考える。利用可能経路集合には後戻りが発生する経路は含まれないものとする。起終点間には図中に示す3本の経路が存在する。また、トリップ中の意思決定は、利用可能な経路が分岐または交差する交差点でのみ発生し、合流する交差点や単路部では発生しないと仮定する。このとき、経路選択に関する意思決定が発生しうる交差点（ノード）を“意思決定ノード”と呼び、図中に示すネットワーク上には、2つの意思決定ノードが存在する。ここで、ある経路上に意思決定ノードが*N*個存在するとき、起点から近い順に第*n*意思決定ノード（*n* = 1, ..., *N*）と呼

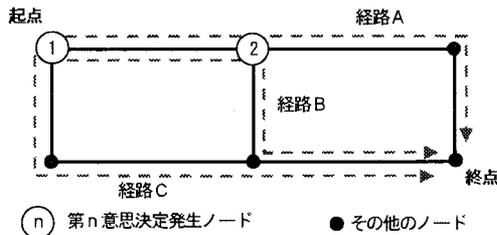


図-7 動的な経路選択の考え方

ぶ。例えば、図中の経路B上には意思決定ノードが2つ存在し、それぞれを第1意思決定ノード、第2意思決定ノードと呼ぶ。

また、トリップ中の経路選択に関する意思決定の発生確率が、意思決定ノードに到達するまでに経験した交通状況や、直面するネットワーク形状等により説明可能であるとき、意思決定発生モデルは以下のような二項ロジットモデルにより表現できる。

$$q^n = \frac{\exp(\lambda^n)}{\exp(\bar{\lambda}^n) + \exp(\lambda^n)} \quad (6.a)$$

$$\lambda^n = \sum_i \theta_i x_i^n \quad (6.b)$$

$$\bar{\lambda}^n = \alpha_0 + \alpha d_{rs}^n \quad (6.c)$$

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が発生するか否かを規定する関数、 $\bar{\lambda}^n$ は意思決定が発生するか否かを判定する閾値、 $x_i^n$ は意思決定が発生するか否かに影響を及ぼす要因、 $d_{rs}^n$ はトリップにおいてすでに走行した距離の割合、 $\theta_i$ 、 $\alpha_0$ 、 $\alpha$ は未知パラメータである。

このとき、図-7に示すネットワークにおける経路Bを選択する確率は、以下のように表される。

$$P_B = p_A^1 \times p_B^2 q^2 + p_B^1 \times (1 - q^2) + p_B^1 \times p_B^2 q^2 \quad (7)$$

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、 $(1 - q^n)$ は第*n*意思決定ノードにおいて意思決定が発生しない確率である。

これをより一般的に書き換えると式(8)のように表すことができる。

$$P_k = \sum_{\hat{k}^{1,2}} p_{\hat{k}^{1,2}}^1 \left( \sum_{\hat{k}^{2,3}} \bar{p}_{\hat{k}^{2,3}}^2 \left( \cdots \sum_{\hat{k}^{N-1,N}} \bar{p}_{\hat{k}^{N-1,N}}^{N-1} \left( \bar{p}_{\hat{k}^{N,End}}^N \right) \right) \right) \quad (8.a)$$

$$\bar{p}_{\hat{k}^{n,n+1}}^n = p_{\hat{k}^{n,n+1}}^n \times q^n + \delta_{\hat{k}^n = \hat{k}^{n,n+1}} \times (1 - q^n) \quad (8.b)$$

$$p_{\hat{k}^{n,n+1}}^n = \frac{\exp\left(f_{\hat{k}^{n,n+1}}^n\right)}{\sum_{k^{n+1} \in R^n} \exp\left(f_{k^{n+1}}^n\right)} \quad (8.c)$$

ここで、 $R^n$ は第*n*意思決定ノードで選択可能な経路集合、 $k^{n+1}$ は第*n*意思決定ノードで選択可能な経路、 $\hat{k}^{n,n+1}$ は第*n*意思決定ノードで選択可能な経路のうち、第*n*意思決定ノードと第*n*+1意思決定ノードの間で経路*k*（最終的に走行した経路）と重複する経路、 $\hat{k}^n$ は第*n*意思決定ノードに到達した時点ですでに選択していた経路、

$\delta_{\hat{k}^n = \hat{k}^{n,n+1}}$ は $\hat{k}^n$ が第*n*意思決定ノードと第*n*+1意思決定ノード間において経路*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。

このモデルにより、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、意思決定発生プロセスを考慮した、より現実的な経路選択行動のモデル化が可能となる。本研究では、上式で記述されるモデルを“意思決定時点内生化学モデル”と呼ぶ。

そこで、名古屋都心部の代表的な経路を対象として分析を行った。対象エリアは中区役所一名古屋駅桜通口タクシーターミナル間のODペアとし、対象トリップは中区役所前、名古屋駅前をともに通過したトリップとする。ただし、このODペア間にも多くの利用可能経路が存在するため、ここでは簡単のため方向別に代表的な3経路を利用可能経路集合として分析を進める。ここで、対象ODペア間で観測された経路数（往復合計）は133経路であり、全観測トリップ（通過トリップを含む）の46.6%が分析対象経路（6経路）を通過していた。対象経路を図-8に示し、対象トリップの概要を表-8に示す。

まず、開発したモデルとの比較を行うため、これまでに用いられてきた経路選択モデルを適用する。すなわち“起点において終点までの経路を一度に決定する”，または“到着するノードごとに意思決定を繰り返す”モデルであり、ここでは前者を“静的モデル”，後者を“動的モデル”と呼ぶ。静的モデルのモデル式は通常のMNLモデルであり、起点においてのみ適用される。動的モデルは、意思決定時点内生化学モデルにおける、トリップ中での意思決定発生確率を考慮しない以下の式で表せる。

$$P_k = \sum_{k^{1,2}} p_{k^{1,2}}^1 \left( \sum_{k^{2,3}} p_{k^{2,3}}^2 \left( \cdots \sum_{k^{n-1,n}} p_{k^{n-1,n}}^{n-1} \left( p_{k^{n,den}}^n \right) \right) \right) \quad (9)$$

各経路の旅行時間は、ピーク・オフピーク時間帯（4区分）、交通状況の変化なしとして作成した。静的モデ

表-8 通過交差点と通過トリップの概要

経路	名古屋駅→中区役所	中区役所→名古屋駅
A	103	1147
B	153	183
C	99	37
計	1367	355

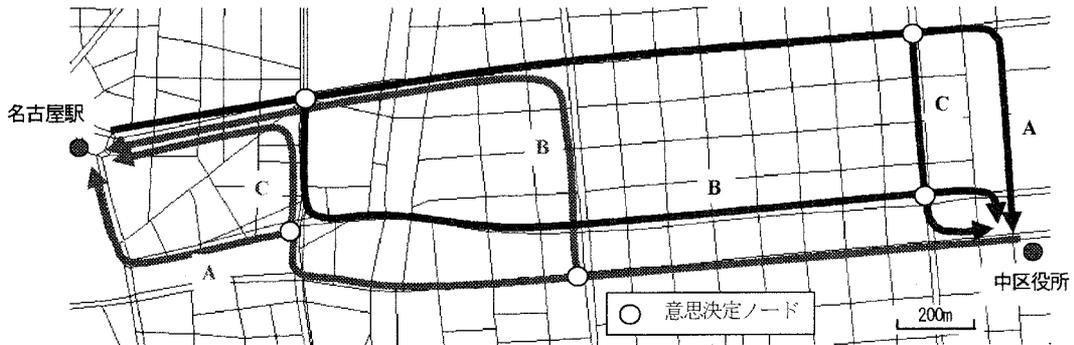


図-8 意思決定時点内生化学モデル適用ネットワーク

ルと動的モデルの推定結果を表-9に示し、意思決定時点内生化学モデルの推定結果を表-10に示す。

推定結果より、意思決定時点内生化学モデルのAICは静的モデルや動的モデルより大きく減少しており、適合度が大きく上昇している。したがって、トリップ中の意思決定時点を適切に考慮することで、現実の経路選択行動を精度よくモデル化できることが示された。

意思決定発生モデルにおけるパラメータの符合は全て正しく、また統計的に有意な値である。これにより、ドライバーが走行中に経験した停止回数や想定していたより遅い走行状況が意思決定を誘発し、終点までの距離が短い場合や走行中に経験した速度が高い状況では、意思決定が発生しにくいことが分かる。

また、起点における経路選択モデルの右左折数パラメータが有意に正となっている。この点についての理由の1つとして、ここでの分析で扱ったデータは必ずしも対象起終点付近に出发・到着地を持つトリップばかりではないことが考えられる。分析に使用した1722トリップの内69.0%にあたる1189トリップが、対象起終点の少なくともどちらか一方を通過するデータであった。このため、対象起点流入以前の真の意思決定地点においては、利用可能経路集合内における選択経路の右左折数が相対的に少なかったにもかかわらず、分析対象経路においては利用可能経路集合がドライバーの認知する経路集合とは異なっており、右左折数が相対的に多くなってしまった可能性も考えられる。

また、経路上での旅行時間パラメータの値は、対象起点でのパラメータ値よりも小さく、1値も小さくなっている。これまでの分析により、目的地までの距離が短くなれば誤差項の標準偏差が残り距離に比例して小さくなるため、パラメータのスケールは大きくなるはずである。したがって、仮に使用した旅行時間データがドライバーの認知する旅行時間と類似している場合は、トリップ中の意思決定に際しての旅行時間情報の重要性が低下していることを示唆する結果であり、ドライバーはトリップ中の意思決定には残り区間の旅行時間をそれほど重

表 - 9 静的モデルと動的モデルの推定結果

説明変数	静的モデル	動的モデル
旅行時間 (分)	-0.413 (-2.1)	-0.374 (-1.9)
右左折数 (回)	-1.18 (-23.8)	-1.13 (-23.9)
初期尤度	-1891.806	-2044.307
最終尤度	-1352.651	-1485.347
修正 $\rho^2$ 値	0.284	0.272
AIC	1354.651	1487.347

サンプル数：1722 (値)

表 - 10 意思決定時点内生モデルの推定結果

説明変数		パラメータ	
意思決定発生モデル	$\lambda^n$	定数項	2.46 (2.9)
		$D_{rs}$	6.51 (4.9)
	$\lambda^n$	意思決定ノードへの到着時刻の予測誤差 (分) *	4.53 (9.2)
		過去 500m での停止回数 (回)	1.78 (6.1)
		過去 1000m での最高速度 (km/h)	-0.091 (-5.3)
経路選択モデル (起点)	旅行時間 (分)	-2.27 (-5.2)	
	右左折数 (回)	1.93 (8.5)	
経路選択モデル (経路上)	旅行時間 (分)	-0.571 (-1.4)	
	右左折数 (回)	-2.38 (-20.5)	
	初期尤度	-1955.107	
	最終尤度	-1069.963	
	修正 $\rho^2$ 値	0.448	
	AIC	1078.963	

サンプル数：1722 (値)

\*意思決定ノードへの到着時刻予測誤差 =  
 意思決定ノード  $n$  への到着時刻  
 - 前回の意思決定地点でリンクコストテーブルに基づいて予測された意思決定ノード  $n$  への到着時刻

要視していないと解釈できる。一方で、仮に使用した旅行時間データがドライバーの認知する旅行時間情報と大きく異なっている場合は、使用した説明変数の精度が低く、その説明力が低いためであると解釈できる。

ここで示した分析では、その旅行時間情報をピーク・オフピーク時間帯、交通状況の変化なしとして経路旅行時間を算出しているが、実際にはトリップを開始して交通状況を経験することで、経路旅行時間に関する認知度が向上すると考えられる。開発した意思決定時点内生モデルは複雑な潜在クラス構造であり、高度に非線形であるため収束計算が難しい。本研究でも多くの条件設定に対して意思決定時点内生モデルを適用したが、収束解が得られることは非常に少なかった。このため、トリップ中のドライバーが認知する旅行時間情報については、本研究では十分に明らかにされておらず、今後の重要な課題の1つである。

## 6. まとめと今後の課題

本研究では、経路選択モデル適用上の問題点を克服するための、基礎的な情報を提供することを目的とし、動

的な経路選択行動のモデル化に向けた分析を行った。

この結果、終点までの距離の変化により、経路選択行動は変化することを明らかにした。すなわち、ドライバーの経路効用に対する認知はOD間距離により変化し、これは経路効用の誤差項の標準偏差がOD間距離に比例するとして表現できることを示した。また、トリップ中の経路選択行動においても同様の変化が存在することや、一旦選択した経路をそのまま走行しようとする、慣性のような現象が存在することを示した。さらに、トリップ中の意思決定発生を内生化した意思決定時点内生モデルを開発し適用することで、トリップ中の意思決定はドライバーが経験した交通状況により説明できることや、意思決定時点適切にモデルに組み込むことにより、現実的な枠組みを背景として大きく改善可能であることを示した。

本研究においては、OD間距離によるスケールパラメータの構造化を図ったが、Gliebeらは経路旅行時間によりスケールパラメータの構造化を図っている<sup>10)</sup>。経路旅行時間による構造化は、同じODペアの同じ経路に対しても、交通状況の違いにより認知誤差が変化することを表現することができ、交通状況の変化によるドライバーの経路選択行動の変化を表現可能であるため、より一般的な構造化手法であると考えられる。このような、より一般的な構造化手法については今後の課題として挙げられる。また、本研究では経路選択モデルにおけるスケールパラメータの構造化に着目しているが、トリップ中における意思決定発生モデルについても、終点までの距離による行動変化の分析が必要であり、この点についての十分な分析を行った後、再度意思決定時点内生モデルを適用する必要がある。

最後に、本研究では複雑な作業を避けるため、使用した経路選択モデルはすべてMNLモデルとしている。MNLモデルはDialのアルゴリズムにより、現在最も一般的に用いられており、ここで得られた知見は十分有用であると考えられる。しかし、これまでに多く指摘がなされているように、経路間には重複区間が多く、各経路を独立として扱うことは必ずしも適切ではない<sup>11)</sup>。さらには、Srinivasanらは、トリップ中の連続した経路選択行動間の相関を考慮している<sup>12)</sup>。このように、現実の経路選択行動を適切に表現しうるモデルにより分析を行う必要がある。

今後は、現実の経路選択行動や意思決定発生プロセスについてより詳細な分析を行った後、ドライバーの現実的な経路選択行動を組み込んだ動的な交通量配分システムを構築し、効果的な情報提供タイミングについて検討を行う予定である。

#### 参考文献

- 1) Miwa, T. and Morikawa, T.: Analysis on route choice behavior based on probe-car data, Proceedings of ITS world congress, CD-ROM., 2003.
- 2) 三輪富生, 森川高行: 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, pp.553-560, 2004.
- 3) 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.
- 4) 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.
- 5) Keats, J.A.: AN INTRODUCTION TO QUANTITATIVE PSYCHOLOGY, John Wiley & Sons Australasia Pty Ltd, 1971 [島津一夫, 石井巖 訳 (1973) 計量心理学, 基礎心理学4, 誠信書房] .
- 6) 例えば, Adler, T. and Ben-Akiva, M.: A theoretical and empirical model of trip chaining behavior, Transportation Research Part B, Vol. 13, pp.243-257, 1979.
- 7) 岡田良之, 三輪富生, 森川高行: 認知誤差を考慮したマルチクラス確率的利用者均衡配分モデルに関する研究, 第24回交通工学研究発表会論文報告集, pp.157-160, 2004.
- 8) Mahmassani, H.S. and D.G. Stephan. Experimental Investigation of Route and Departure Time Choice Dynamics of Urban Commuters, Transportation Research Record 1203, pp.69-84, 1988.
- 9) Mahmassani, H.S. and R. Jayakrishnan: System performance and user response under real-time information in a congested traffic corridor, Transportation Research Part A 25, No.5, pp.293-307, 1991.
- 10) Gliebe, J. P., Koppelman, F. S. and Ziliaskopoulos, A.: Route choice using a paired combinatorial logit model, Transportation Research Board 78th Annual Meeting, CD-ROM, 1999.
- 11) 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.
- 12) Srinivasan, K.K. and H.S. Mahmassani: Analyzing heterogeneity and unobserved structural effects in route-switching behavior under ATIS: a dynamic kernel logit formulation, Transportation Research Part B 37, pp.793-814, 2003.

---

### プローブカーデータを用いた動的な経路選択行動に関する基礎的分析\*

三輪富生\*\*・森川高行\*\*\*・倉内慎也\*\*\*\*

IT技術を駆使した交通運用・管理施策が注目を集めつつあり、交通シミュレータなど動的な需要予測ツールの役割は今後さらに高まると考えられる。しかし、これら動的な需要予測ツールは、ロジットモデルなどの静的な離散選択モデルを逐次的に適用することにより達成されている。そこで本研究では、このような経路選択モデル適用上の問題点を克服するために有用な情報を提供することを目的とし、より動的な経路選択行動のモデル化に向けた分析を行った。この結果、ドライバーの経路選択行動はトリップ距離とともに変化していることや、トリップ中の意思決定時点を適切にモデルに組み込むことで、より現実的な枠組みを背景として大きく改善可能であることを示した。

---

### Preliminary Analysis on Dynamic Route Choice Behavior Using Probe-Vehicle Data\*

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

Dynamic traffic assignment tools have been attracting increasing attention with the progress of traffic management policies based on information technology. These dynamic tools, however, just apply static route choice models either at only origin node or at every arrival node. This paper aims at providing some knowledge on drivers' dynamic route choice behaviors using probe-vehicle data. The results of analyses show that route choice behaviors relate to the distance from driver's position to the destination and that dynamic route choice behaviors are modeled better by considering decision process during trips.

---