

膨大な行動空間情報を基本にした経路列挙アルゴリズムの提案*

A suggestion of path enumeration algorithm based on massive behavioral space information*

山川佳洋***・羽藤英二**

By Yoshihiro YAMAKAWA***・Eiji HATO**

1. はじめに

経路選択モデルは現在、交通シミュレーションモデルに用いられるなど道路のネットワークの分析には欠かせないものである。しかしその適用可能性は十分に高いとは言えない。その原因は、経路選択モデルの構築において重要となる経路選択枝集合の生成方法にある。

Bovy (1990) ¹⁾は、道路ネットワーク上で経路選択をする際に段階的な選択枝集合の絞り込みが行われていると考える。Existing set (存在する経路) → Known set Available set (認知された経路集合) → Feasible set (ふさわしい経路集合) → Choice route (選択経路)と4つのプロセスを踏んで経路が絞り込まれ、決定されるというものである。実際の選択行動がこれほどのプロセスを踏んで経路の絞り込みが行われているかは議論の余地があるが、選択枝集合の生成過程を明示的に記述することは経路選択モデル構築において本質的に重要である。従来の経路選択モデルの構築においてはデータ収集に膨大な費用と労力がかかることからドライバーの走行経路の分析はあまり行われていない。選択枝集合生成方法として、Labeling Approach (Ben-Akiva, 1984) ²⁾、EBA手法(Tversky, 1972) ²⁾、K番目経路探索(眞浦ら, 1999) ³⁾などがあるが、どれもドライバーの位置情報データを用いたものでないため、選択枝集合に含まれる経路が実際の走行経路と必ずしも一致しない。

しかしGPS測位機器を用いた移動体の位置データを観測するプローブ技術の発達により、ドライバーに負担をかけずに、長期間の走行経路データを得ることが可能となった。それにより経路長、旅行時間をはじめとした経路データを算出し、個人の走行経路の分析が可能となった。そこで本研究では、データオリエンテッドな手法で実際の走行経路により近い経路選択枝集合の生成アルゴリズムを提案し、それを元に経路選択モデルを構築する。

*キーワード：経路選択、交通行動分析

***学生員、東京大学大学院工学系研究科

(東京都文京区本郷七丁目三番地一号、

Email yamakawa@bin.t.u-tokyo.ac.jp)

**正員、工博、東京大学大学院工学系研究科

2. 選択枝集合生成方法

本研究において2つの経路選択枝集合の生成方法を提案する。共に個人があるODトリップについて調査期間内に利用した複数(あるいは1つの)経路から成るネットワークを認知ネットワークと定義し、この認知ネットワークを用いる。1つ目の方法は、この認知ネットワークと最短経路探索を応用した経路列挙アルゴリズム、さらにEBA手法を用いて生成する方法である。この方法では従来のk番目経路探索に比べ計算コストを大幅に減らし、かつ空間的に広がりをもった経路を列挙することができる。2つ目は1つ目の方法と比較するため、認知ネットワークをそのまま用いたプローブパーソン(PP)データの実走行経路から生成する方法である。1つ目の方法に比べ、2つ目の方法のほうがより実際の選択枝集合を与えると考えられるが、2つ目の方法が走行データのある任意のOD間でしか選択枝集合を生成できないのに対して、1つ目の方法は任意のOD間で選択枝集合を生成できるという長所を持つ。以下に詳しく定義する。

(1) アルゴリズムを用いて生成する方法

a) 経路列挙アルゴリズム

選択枝集合を生成するにあたって、選択経路に対する代替経路を列挙するアルゴリズムを考案する。個人の経路選択行動は認知ネットワークに影響を受ける。したがって仮想の認知ネットワークをあらかじめ定義し、最短経路探索を応用したアルゴリズムで代替経路を列挙する。以下の4stepで示す。

Step1 あるOD間の経路選択における仮想認知ネットワークとしてOD間を結ぶ直線となす角 θ の4直線からなるひし形を考える。イメージを図1のStep1に示す。

Step2 ODノードを結ぶ直線の垂直二等分線でこのひし形内にある部分を考える。イメージを図1のStep2に示す。

Step3 この垂直二等分線を通るリンクを探索する。イメージを図1のStep3に示す。

Step4 最短経路探索を用いてOriginから通過リンクのupノード、downノードからDestinationまでの最短経路を求める。それらをつなぎ合わせたものを1つの代替経路として経路列挙を行う。イメージを図1のStep4に示す。

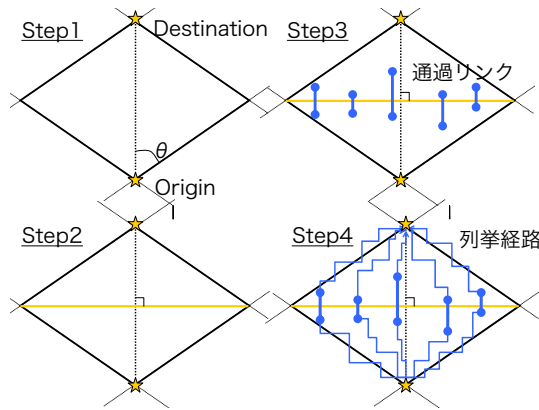


図1 経路列挙イメージ図

b) EBA手法を用いた選択枝集合生成アルゴリズム

アルゴリズムによって列挙された代替経路から選択枝集合を生成する。列挙された経路は互いに重複するリンクを持つため、似たような経路が選択枝集合に含まれないようにするために、重複率がある閾値を越えたものは、1つの経路としてまとめる必要がある。また個人ごとに選択枝数や最短経路に対する迂回率(最短経路長に対する選択経路長の比)の上限値、下限値などの経路選択特性が異なるため、これらを考慮した上で選択枝集合を生成する。これは経路の属性により、基準を満たさないものは削除していくEBA手法によるものである。以下の6Stepで示す。

Step1 選択枝集合生成アルゴリズムのパラメータとして迂回率の上限値、下限値、代替経路数、重複率を設定する。

Step2 代替経路の経路長について、迂回率が設定された上限値と下限値の間に入っていないものは代替経路から削除する。

Step3 代替経路の中で経路長が最短のものを選択枝集合に加える。

Step4 代替経路の中で、選択枝集合内の経路との重複率が設定よりも大きい経路は代替経路から削除する。

Step5 Step3、Step4を繰り返す。

Step6 列挙された代替経路がなくなるか選択枝集合に加わった代替経路数が設定値に達したら実走行経路を選択経路として選択枝集合に加えて終了する。

以上で生成された選択枝集合例を図2に示す。

(2) 実走行経路から生成する方法

ドライバーが実際に走行したあるOD間の経路に対してそれと同一ODの経路を代替経路として列挙する(認知ネットワーク)。そして経路重複率を基準として、あるODトリップ経路に対して、互いの経路重複率が90%を越えないような選択枝集合を生成する。例を図3に示す。




図2 アルゴリズムを用いた選択枝集合例

(探索角度 45°、迂回率上限 1.50、下限 1.00、代替経路 4、重複率 0.6)



図3 実走行経路を用いた選択枝集合

3. プロブパーソンデータを用いた経路選択モデル

(1) データ

本研究で用いたデータは松山プローブパーソン調査2004(MPP2004)のものである。MPP2004の調査概要として対象地域は松山都市圏(松山市(北条を含む)、伊予市、東温市(重信町、川内町) 砥部町、松前町の3市2町)、調査期間は2004年1月26日から2004年2月29日の35日間、調査対象時間は24時間、被験者は317名である。

(2) 選択経路分析

a) 基本特性

ドライバーの走行経路を分析することで経路列挙アルゴリズム、また選択枝集合生成アルゴリズムのパラメータを設定する。迂回率の上限値、下限値について、図4に最短経路長に対する選択経路の迂回率を示す。凡例はモニター番号を表す。これより従来の交通シミュレーションで用いられている経路選択モデルにおいて、経路選択の際には最短経路が選択されるという仮定には問題があることが分かる。迂回率は1.00から1.40の値をとっている。OD間距離が長く、最短経路長が長くなると最短経路が選択されることはほとんどないことが分かる。

次にモニターごとに異なるODトリップ数と各ODトリップに対する選択枝集合数を分析する。ここで選択枝集合とは、あるODについてモニターが調査期間内に走行した全経路から生成されており、互いの経路重複率が90%以上の経路は同一の経路と見なしている。図5に結果を示す。ODトリップ数はモニターごとにばらつきが見られる。選択枝集合数は4以下がほとんどである。




図 4 最短経路長に対する迂回率の関係




図 6 OD間直線距離と探索角度の関係




図 5 異なる OD トリップ内の選択肢集合数




図 7 アルゴリズムを用いた選択肢集合内の右左折数

b) 認知ネットワーク

経路列挙アルゴリズムのパラメータ θ は仮想認知ネットワークの広がりを表している。選択肢集合がより現実のものとなるためには仮想認知ネットワークと実走行データによる認知ネットワークの重複が高い必要がある。ここで認知ネットワークとは、個人のある OD トリップにおける選択経路、代替経路から成るものである。 θ を 10° から 5° 刻みで 70° まで変化させ、そのとき認知ネットワークに対する仮想認知ネットワークの重複をカバー率と定義し、ネットワークの重複するリンクの総リンク長をもとに求める。 θ を増やしていったときのカバー率がその OD トリップでのカバー率の最大値の 90% 以上となる角度をその OD トリップでの仮想認知ネットワーク探索角度とする。図 6 に OD 間直線距離と探索角度の関係を示す。OD 間直線距離が短いときは探索角度の取りうる値の範囲が大きくばらついている。OD 間直線距離が長くなるほど探索角度は小さくなる傾向がある。

(3) モデルのフレーム

経路選択モデルの構築において MNL (Multinomial Logit) モデルを用いる。MNL モデルにおける経路 n の選択確率 P_n は以下ようになる。

$$P_n = \frac{\exp(\mu V_n)}{\sum_{j \in C} \exp(\mu V_j)}$$

このとき、 V_n は経路 n の効用の確定項、 C は経路選択

肢集合、 μ はスケールパラメータである。なお意思決定者である個人を表す添え字は省略した。

(4) パラメータ推定結果

経路選択モデルの説明変数としては、PP データから得られる経路長、旅行時間、旅行時間標準偏差、幹線比率 (距離)、右左折数を用いた。幹線比率 (距離) とは経路長に対する、車線数が 2 以上のリンク長の総和の割合である。また旅行時間は出発時間によっても変動するし、たとえ毎日同じ時間に出発したとしても日によっても異なる。これに対して本研究では PP データの特徴である精度の高い時刻と位置のデータを用いる。時間帯別平均リンク通過速度を求め、それを元に時間帯別の旅行時間を算出し、説明変数として用いている。さらにこれを元に旅行時間偏差も計算している。なお個人モデルのため今回の推定は 1 人のモニターのデータを用いた。

a) アルゴリズムを用いた選択肢集合

図 7 から右左折数を説明変数と用いると結果にバイアスが生じてしまうので、今回用いる説明変数は経路長のみでアルゴリズムのパラメータを変化させたときの違いを表 1 に示す。モデル 1 では迂回率の下限が 1.00 のため選択肢集合内に最短経路が含まれる。選択肢集合内の経路の経路長が実選択経路の経路長より小さくなっているため経路長のパラメータの符号が正の値になり、直感と一致しない。モデル 2-4 では迂回率の下限を 1.10 とすることで選択肢集合内の経路長はより大きくなるためパラメータの符号が負となり、直感に一致するものとなる。探索角度、迂回率上限、重複率を大きくすることで経路長

表1 アルゴリズムを用いた選択肢集合

	モデル1		モデル2		モデル3		モデル4	
代替経路数	4		4		4		4	
探索角度(°)	30		30		40		45	
迂回率上限	1.00		1.10		1.10		1.10	
迂回率下限	1.30		1.40		1.40		1.50	
重複率(%)	50		50		50		60	
説明変数	推定値	t値	推定値	t値	推定値	t値	推定値	t値
経路長(km)	1.611	3.96**	-0.725	-1.19	-0.586	-0.94	-1.188	-2.01*
サンプル数	59		59		59		59	
初期尤度	-78.57		-62.99		-84.37		-90.76	
最終尤度	-69.89		-62.25		-83.91		-88.61	
尤度比	0.111		0.012		0.005		0.024	
修正済み尤度比	0.098		-0.004		-0.006		0.013	

** : 1%有意 * : 5%有意

表2 実走行経路を用いた選択肢集合

	モデル5		モデル6		モデル7		モデル8		モデル9		モデル10	
説明変数	推定値	t値	推定値	t値	推定値	t値	推定値	t値	推定値	t値	推定値	t値
経路長(km)	-1.593	-3.57**			-1.346	-2.78**					-1.001	-1.43
旅行時間(分)			-0.732	-3.70**			-0.484	-2.19*			1.667	0.68
幹線比率(%)							-4.291	-2.37*			-0.194	-1.33
右左折数(回)					-0.235	-3.57**	-0.402	-3.03**	-0.274	-4.46**	0.192	0.67
時間偏差(分)									-0.565	-4.19**	-0.597	-2.82**
サンプル数	53		53		53		53		53		53	
初期尤度	-83.50		-83.50		-83.50		-83.50		-83.50		-83.50	
最終尤度	-72.99		-68.83		-65.02		-63.54		-59.53		-58.30	
尤度比	0.126		0.176		0.221		0.239		0.287		0.302	
修正済み尤度比	0.114		0.164		0.197		0.203		0.263		0.242	

** : 1%有意 * : 5%有意

の値の幅が広い選択肢集合となるため適合度も高くなる。

b) 実走行経路を用いた選択肢集合

説明変数を変えパラメータ推定を繰り返し行い適合度が高かったものを表2に示す。モデル5、6を比較すると経路長よりも旅行時間の方が説明力が高いことが分かる。これよりPPデータから得られた出発時間帯を考慮した旅行時間の説明変数が有効であることが示せた。モデル7、8から経路長や旅行時間の変数と他の説明変数を組み合わせることで適合度は高くなる。全ての組み合わせの中でモデル9の右左折数と時間偏差を組み合わせたモデルが最も適合度が高かった。モデル10の結果とも合わせて考えると、これは単に旅行時間が短いよりも、旅行時間のばらつきが少ない方が好まれることを表している。

4. まとめ

本研究では、PP調査から得られるドライバーの位置データに基づいた経路選択肢集合の生成方法を考案し、経路選択モデルを構築した。経路列挙アルゴリズムを用いた生成方法では適合度は低かった個人ごとの選択経路の特性に沿ったパラメータチューニングを行うことでさらなるモデルの適合度の向上が望める。またこの生成方法では最終的な選択肢集合はアルゴリズムで生成された代替経路に実走行経路を外挿して生成される。よりコンピュータブルな選択肢集合生成アルゴリズムを構築する

には実走行経路をいかに列挙するかが課題である。また列挙された経路は選択経路に対して幹線比率が低く、右左折数が多い経路ばかりであった。このため説明変数にこれらの変数を含むとパラメータ推定結果にバイアスが生じてしまうため、EBAの閾値にこれらの変数を組み込んだり、ラベリング法を用いた経路を取り入れたりすることでパラメータ推定の精度が高くなると考えられる。次に実走行経路を用いた生成方法では適合度が高く、様々な説明変数を用いたモデルを構築することができた。時間偏差が経路選択に影響を与えていることは道路ネットワークを建設する際に考慮すべきこととなり得る。個人の超長期の交通データが得られれば、様々なODペアの選択肢集合も得られるため、交通シミュレーションにも適用可能な経路選択モデルが構築できるだろう。

参考文献

- 1) Bovy, S. and Stern, E. : Route Choice : Wayfinding in Transport Networks, Kluwer Academic Publishers, 1990
- 2) 北村隆一, 森川高行ら: 交通行動の分析とモデリング, 技報堂出版, 2002
- 3) 眞浦靖久, 朝倉康夫, 羽藤英二, 宗貞孝太郎: 経路選択肢集合生成アルゴリズムの提案と松山道路網での検証, 土木計画学研究・論文集, No22 (2), pp. 187-190, 1999

