

RPデータとSPデータの系列相関を考慮した 交通機関選択行動モデルの推定法

Combined Estimation Methods for Discrete Choice Model
from Serially Correlated RP and SP Data

森川高行*・山田菊子**

By Takayuki MORIKAWA and Kikuko YAMADA

Combined estimation methods from RP and SP data have three key features: i) identifying parameter for nonexisting service attributes; ii) gaining statistical efficiency; and iii) correcting SP biases. This paper develops the combined estimation methods by considering serial correlation of RP and SP data. Omitted latent preference for a specific alternative is taken account of as a random variable which is common among RP and multiple responses of SP data.

An empirical case study on mode choice analysis finds that serious biases in parameter estimates due to the omitted latent preference can be corrected by the proposed method.

1. 序論

交通需要予測のアプローチの一つとして発展してきた非集計行動モデルは、数々の事例に適用が進み、事例研究が発表されている。筆者らは実際の選好行動結果に基づくRPデータ(Revealed preference data)を、同一の個人から得られた仮想の状況における選択データであるSPデータ(Stated preference data)とともに用いることにより、大幅なサービス変更や全く新しい交通機関の供用などこれまでにないサービスの導入に際して有効であると考えた行動モデルを提案した^{1), 2), 3)}。

本稿ではこれまでに発表した手法を発展させ、RPデータSPデータの発生過程相互の関係を考慮したモデルを提案し、その有効性を示すことを目的とする。

2.でこれまでに提案したRPデータとSPデータを同時に用いる選択行動モデルの概要について、モデル

の特長を含めてまとめる。3.は、RPデータとSPデータの相互の関係について、それがRPモデルとSPモデルの系列相関であることを指摘したうえで、これを考慮した選択行動モデルの定式化、および未知パラメータの推定法を提案する。ケース・スタディとして、前出の文献³⁾と同じ都市間鉄道のサービス改善に関する調査によるデータを用い、既存の手法および本稿で提案する手法によるモデル推定を試みる。

2. RPデータとSPデータを用いる選択行動モデル

(1) モデルの特長

RPデータとSPデータを同時に用いる行動モデルの利点は以下の三点にまとめることができる。すなわち、

- i) RPデータだけでは同定できないパラメータ(現存しないサービスに関する選好情報など)を推定することができる。

* 正会員 Ph.D. 名古屋大学助教授 工学部土木工学教室
(〒464-01 名古屋市千種区不老町)

** 正会員 工修 (株)三菱総合研究所 社会システム第二部
(〒100 東京都千代田区大手町2-3-6 タイムライフビル)

- ii) より多くの情報をモデル推定に用いることによって統計的有効性を増すことができ、また属性間のトレード・オフを明確にすることができる。
- iii) S P データの持つバイアスを除去することができる。

である。

S P データに分類されるデータは、回答者に与える課題により選択データ (Choice data)、代替案について順位を付けさせる順位付けデータ (Rank data)、好みさの度合いを答えさせる評点データ (Rating data) など各種あるが、それぞれに対応した選択確率を定義することにより、すべての場合に本手法を適用することができる。

(2) モデルの定式化

ランダム効用理論に基づく離散型選択モデルを仮定し、それぞれのデータが発生する際の意思決定機構を別々に定式化することにより、それぞれのモデルの特長を生かすと同時に両データ相互の関係を表現するためである。

選択データの場合、得られるデータは代替案及び回答者の属性データと選択データである。

属性データ：

$$\text{RP data: } \{x_{in}^{\text{RP}}, w_{in}^{\text{RP}}\} \quad (1)$$

$$\text{SP data: } \{x_{in}^{\text{SP}}, z_{in}^{\text{SP}}\} \quad (2)$$

選択データ：

$$d_{in}^{\text{RP}}, d_{in}^{\text{SP}} = \begin{cases} 1: & \text{if alternative } i \text{ is chosen} \\ 0: & \text{otherwise} \end{cases} \quad (3)$$

ただし、

x_{in} ：RP, SP 両モデルに共通の係数を持つ属性ベクトル

w_{in} ：RP モデルに固有の係数を持つ属性ベクトル

z_{in} ：SP モデルに固有の係数を持つ属性ベクトル

である。

このように RP モデルと SP モデルの説明変数ベクトルを、両モデルに共通なサブベクトルと、それぞれに固有なサブベクトルに分離することにより、SP バイアスを除去することができる。例えば「過去の行動の正当化」や「政策操縦」のような SP バイアスは、SP モデル固有の定数項に吸収されるため、選択肢を

表すダミー変数をそれぞれ説明変数のモデルに固有なサブベクトル w_{in} , z_{in} として定式化し、需要予測においては RP モデルの推定値である定数項のみを利用することが考えられる。以上の説明変数を用いて RP モデル、SP モデルの効用関数を定義する。ただし以下、本稿では次のように変数を定義する。

u_{in} ：個人 n の代替案 i についての効用

ε_{in} ：誤差項

I_n ：個人 n の選択肢の数

N ：回答者数

$\alpha, \beta, \gamma, \mu$ ：未知パラメータ・ベクトル

RP モデル：

$$u_{in}^{\text{RP}} = \beta' x_{in}^{\text{RP}} + \alpha' w_{in}^{\text{RP}} + \varepsilon_{in}^{\text{RP}} \quad (4)$$

SP モデル：

$$u_{jn}^{\text{SP}} = \beta' x_{jn}^{\text{SP}} + \gamma' z_{jn}^{\text{SP}} + \varepsilon_{jn}^{\text{SP}} \quad (5)$$

RP データ、SP データそれぞれを用いて (4), (5) 式の未知パラメータをそれぞれ推定すると、効用関数の誤差項のばらつきの大きさに従ったスケールを持つ推定値が得られる。そこで両モデルのスケールを統一するためにスケール・パラメータ μ を導入する。両モデルの効用関数のスケールを同一にすることにより、需要予測の際にそれぞれの係数を両モデルで共有することができる。

スケール・パラメータはそれぞれのモデルの誤差項の分散の比で表現される。

$$\text{Var}(\varepsilon_{in}^{\text{RP}}) = \mu^2 \cdot \text{Var}(\varepsilon_{in}^{\text{SP}}) \quad (6)$$

このスケール・パラメータの推定値が 1 よりも大きければ SP データのランダムなノイズが RP データのそれよりも小さいことになる。

(3) パラメータの推定

未知パラメータは最尤推定法 (Maximum likelihood estimation) を用いて推定される。この方法は全サンプルについての実際の選択結果の同時生起確率である尤度関数を最大化するようなパラメータを最尤推定量とするものである。

各モデルの誤差項を独立であるとした仮定に基づき尤度関数を定義すれば、パラメータの推定はこの尤度関数、すなわち RP データ、SP データをプールしたうえでの同時生起確率を目的関数とする最大化問題に

帰着する。実際の推定計算においては対数尤度関数の最大化問題として、

$$\begin{aligned} & \max_{\alpha, \beta, \gamma, \mu} L(\alpha, \beta, \gamma, \mu) \\ &= \left\{ \sum_{n=1}^{N^{RP}} \sum_{i \in J_n^{RP}} d_{in}^{RP} \cdot \ln(P_n^{RP}(i)) \right\} \\ &+ \left\{ \sum_{n=1}^{N^{SP}} \sum_{i \in J_n^{SP}} d_{in}^{SP} \cdot \ln(P_n^{SP}(i)) \right\} \end{aligned} \quad (7)$$

この手法により求められるパラメータの推定量は、RPモデルとSPモデルの誤差項が独立な場合には一貫性および漸近の有効性を持ち、独立でない場合には一貫性を持つが、漸近の有効性を持たない推定量が得られる。

3. 系列相関を考慮したRP・SP混合推定モデル

(1) RPデータとSPデータの状態依存と系列相関

筆者らがこれまでに提案した混合推定法は2.に述べたように、RPデータ、SPデータのそれぞれについての発生過程をここにモデル化することにより、互いに補完しあう特長を取り込んだ。この手法ではさらに、両モデルのランダムネスが個人のすべての選択肢間で互いに独立で同一な分布をすると仮定した。

本節ではさらに正確なモデル化を行うに当たり、独立であると仮定した二つのデータの発生過程について考察を行う。

RPデータとSPデータを同時にモデル推定に用いる際に考慮しなければならない点は次の二点である。

- i) SPデータのRPデータへの状態依存
- ii) RPモデルとSPモデルの系列相関

状態依存は一般に"state dependence"とよばれ、SPデータの選択結果、すなわち分析者の設定する仮想の状況に対する選好がRPデータの選択結果である実際の行動結果に大きく影響を受けることを表す。

また系列相関(serial correlation)は個々に定義されるRPモデルとSPモデルのランダムネスが、独立でないことである。離散型選択モデルの効用関数の誤差項は、説明変数に含まれない、あるいは含めることのできない要因を吸収する^{4),5)}。説明変数に含まなかった要因

の代表的なものに潜在的な個人の嗜好がある。個人の嗜好は、潜在的であると同時に、定量化されないため説明変数に加えることが困難である。誤差項へのこの個人の嗜好の影響が大きい場合、RPモデル、SPモデルの誤差項は真にランダムなホワイト・ノイズに加え、この個人の嗜好の影響を共通に含むことになり、これまでに仮定した誤差項の独立性は保たれなくなる。これが系列相関である。

SPデータのRPデータへの状態依存は、SPモデルの説明変数の一つとしてRPデータの選択結果をダミー変数の慣性項として取り込むことにより解消される。この場合、誤差項の系列相関は考慮されないため、得られる未知パラメータの推定値は漸近的一貫性を持つが有効性を持たない。

疑似ダイナミック・モデルにおいて系列相関を考慮しない場合に、慣性項が「真の状態依存」と系列相関を「みせかけの状態依存」の両者を含む状況⁶⁾がこれに相当する。

また、状態依存と系列相関の両者をともに考慮しないモデルより推定されるモデルによる推定値にはバイアスが含まれ、需要予測の際に、誤った予測値を与えることになる。

状態依存はSPモデルの説明変数に慣性項を取り込むことにより、これまでに提案した手法により回避されるため、本章では誤差項の系列相関を明示的に取り込んだモデルの推定法を提案する。

(2) モデルの定式化

前述の誤差項の系列相関を考慮した離散型選択モデルを提案する。まず、RPデータとSPデータの発生過程はそれぞれに定義される。

RPモデル：

$$u_{in}^{RP} = \beta' x_{in}^{RP} + \alpha' w_{in}^{RP} + \omega_{in}^{RP} \quad (8)$$

SPモデル：

$$u_{in}^{SP} = \beta' x_{in}^{SP} + \gamma' z_{in}^{SP} + \omega_{in}^{SP} \quad (9)$$

ただし

$\omega_{in}^{RP}, \omega_{in}^{SP}$ ：個人 n のそれぞれのモデルにおける代替案 i についての誤差項

ここで誤差項に明示的に系列相関を取り込む。その方法として、パネル・アナリシスにおけるモデル⁸⁾と同様に、誤差項を各個人のそれぞれの代替案に共通な部分と真にランダムなホワイト・ノイズを表す部分の

二つに分離する。

$$\omega_{in}^{RP} = \lambda_{in} + \varepsilon_{in}^{RP} \quad (10)$$

$$\omega_{in}^{SP} = \theta_i \cdot \lambda_{in} + \varepsilon_{in}^{SP} \quad (11)$$

ここに、

λ_{in} : 個人 n の代替案 i に対して固有の誤差項

$\varepsilon_{in}^{RP}, \varepsilon_{in}^{SP}$: 個人 n のそれぞれのモデル、すべて

の代替案について真にランダムな誤差項

θ_i : 代替案 i に固有の未知パラメータ

である。以上の定式化によれば誤差項 λ は各個人について選択肢ごとに独立で同一の分布をし、各個人の選択肢に対する嗜好などの潜在的な説明変数の影響を表す。

新たにそれぞれのモデルについて、二つの誤差項を含む効用関数を定義できる。

R P モデル:

$$u_{in}^{RP} = \beta' x_{in}^{RP} + \alpha' w_{in}^{RP} + \lambda_{in} + \varepsilon_{in}^{RP} \quad (12)$$

S P モデル:

$$u_{in}^{SP} = \beta' x_{in}^{SP} + \gamma' z_{in}^{SP} + \theta_i \cdot \lambda_{in} + \varepsilon_{in}^{SP} \quad (13)$$

さらに前節と全く同様にスケール・パラメータ μ を導入して、効用関数のスケールを統一する。ここにスケール・パラメータ μ は

$$Var(\varepsilon_{in}^{RP}) = \mu^2 \cdot Var(\varepsilon_{in}^{SP}) \quad (14)$$

であり、効用関数の誤差項 ε は独立な確率分布を持つ。

誤差項のうち真のランダム・ノイズを表す ε の分布形を定義することにより、 λ が既知であるときの条件付選択確率が定義される。たとえば誤差項 ε が R P, S P モデルの間で独立で同一なガンベル分布であるとすればロジットタイプの選択確率となる。

したがって、ある個人が R P モデル, S P モデルでそれぞれ i, j という代替案を選択する同時選択確率は、 λ の分布形を与えることにより次のように与えられる。

$$\begin{aligned} & P_n \{d_n^{RP}(i) = 1, d_n^{SP}(j) = 1\} \\ &= \int \dots \int_{-\infty}^{+\infty} P_n^{RP}(i|\lambda) \cdot P_n^{SP}(j|\lambda) \cdot f(\lambda) d\lambda_{1n} \dots d\lambda_{ln} \end{aligned} \quad (15)$$

ここに、 $f(\lambda)$ は λ の確率密度関数である。

(3)パラメータの推定法

系列相関を明示的に考慮したモデルのパラメータ推定は、前節のモデルと同様に最尤推定法を用いて行なうことができる。対数尤度関数の最大化問題として表せば、

$$\begin{aligned} & \max_{\alpha, \beta, \gamma, \mu} L(\alpha, \beta, \gamma, \theta, \mu) \\ &= \sum_{n=1}^N \sum_{i \in I_n^{RP}} \sum_{j \in I_n^{SP}} [\{d_n^{RP}(i) \cdot d_n^{SP}(j)\} \cdot \ln \{P_n(d_n^{RP}(i) = 1, d_n^{SP}(j) = 1)\}] \end{aligned} \quad (16)$$

となる。誤差項の独立性が保たれているため、得られる最尤推定量は漸近的有効性と一致性を持つ。

以上が系列相関を考慮した R P・S P 混合推定モデルのフレーム・ワークである。

4. ケーススタディ

1) データの概要

ケーススタディに用いたデータは、前出の文献3)で使用了都市間高速交通機関選択に関する調査により得られたものである。

約500km離れた運行区間の代替交通機関は主に高速道路を利用する自家用車と近年運行を始めた高速乗合バスである。また1989年の実績によれば、3交通機関のシェアは鉄道、バス、自動車、それぞれに73.6%, 1.6%, 24.8%である。新型特急の導入による他交通機関からの転換需要の予測を目的とする今回の調査の場合、R P データでは高い快適性を持つ新型特急は所要時間でのみしか従来型特急と区別できない。これが S P データを調査に加える動機となったものである。

このような動機に基づきサンプルは選択肢別標本抽出により、調査実施日(1990年2月)に鉄道を含めた代替交通機関、高速バス、自家用車の利用者に質問票を配付し、後日郵送により回収した。

質問票は次の2部により構成される。

R P データ: 質問票を受け取った日の旅行に関する質問

S P データ: 鉄道利用者に対してはバスの、その他の交通機関の利用者に対しては鉄道のサービスの変更(新型特急の増便、所要時間の短縮、料金の引き下げ、バス停留所の

新設) に関して提示された仮想のシナリオ
の下での利用可能な交通機関の順位付け

S P データは、それぞれの交通機関ごとに共通で鉄道利用者に2間、それ以外の利用者に4間である。

有効な回答のなかから、次の条件を満たすサンプルを排除し、R P データ255、S P データ679を用いてモデルの推定を行なった。

- i) 利用可能な交通機関を一つしか持たないサンプル
(キャプティブ層)
- ii) 起点あるいは終点を北陸・京阪神地方以外に持つサンプル
- iii) 起点あるいは終点が同一地方内にあるサンプル

(2) R P モデルの推定

R P データのみを用いてモデルの推定を行なった。
効用関数の説明変数には

- i) 旅行時間(hr.)
- ii) ひとり当たり総旅行費用(1,000yen)
- iii) 業務目的旅行ダミー

を用いた。

パラメータの推定結果をTable 1の第一列に示す。すべてのパラメータが正しい符号のもとで有意な値をとった。本モデルでは旅行時間に関しては、業務目的を持つものしか考慮していない。これは、観光や帰省を旅行目的に持つものについては交通機関選択の場面において必ずしも所要時間の長短を考慮にいないか、あるいは費用のみを考慮しているため、あたかも「費用が安く、旅行時間の長い」交通時間を好むという結果になるためである。

(3) S P モデルの推定

S P データは順位付けデータであるが、選択肢のすべてにタイを許さず順位を付けたサンプルが少ないため、R P モデルと同様の変数を用いて多項ロジット・モデルの形式で表現する。ただし、2.に示した定式化により得られる最尤推定量はそれぞれ $\hat{\mu}_B$ 、 $\hat{\mu}_Y$ であり、S P モデル独自のスケールであることに注意が必要である。

効用関数にはS P 質問でシナリオ中に新型特急が増便されるものには1、そうでないときには0を取るダミー変数「新型特急増便ダミー」を加えたモデルを推定した。モデルの推定結果をTable 1の第2列に示す。

ここで注目すべきは新型特急増便ダミー変数にかかるパラメータの値が負値を取ったことである。現実の新型特急の集客力、S P データの回答を見ても、パラメータの値が負になることは明らかに矛盾である。

原因として、新型特急の増便を含むシナリオが設定されたのが高速バス、自家用車の利用者のみであったため、モデル全体としては「鉄道を好まない」ダミー変数、あるいは「高速バス、自家用車利用の慣性」ダミー変数として働き、鉄道の効用を低下させる方向に有効となったことが考えられる。これに加え、R P データの選択結果に対する状態依存を考慮していないため、前節に述べたような系列相関と状態依存の両者を考慮しないモデルとなりバイアスが生じたと考えられる。

これに対処する方法として、R P データの選択結果である慣性項(inertia dummy)を説明変数に用いたモデルを推定した。推定結果をTable 1の第3列に示す。慣性項も含め、すべてのパラメータが正しい符号を示した。自家用車の利用者にかかる慣性が、高速バス、鉄道利

Table 1
Estimation Results from Separate Data Sets
(t-statistics in parentheses)

	RP model	SP model without inertia dummy	SP model with inertia dummies
Rail constant	1.53 (4.2)	0.923 (5.1)	1.83 (7.6)
Bus constant	1.24 (4.7)	0.138 (0.9)	0.586 (2.0)
Business trip total travel time (hr.)	-0.553 (-1.5)	-0.117 (-0.8)	-0.0227 (-0.1)
Cost per person (1,000yen)	-0.354 (-3.8)	-0.344 (-7.6)	-0.216 (-4.4)
High-grade train dummy		-0.260 (-1.4)	0.768 (3.6)
Bus inertia dummy			1.53 (5.4)
Car inertia dummy			3.19 (10.7)
N	255	679	679
$\bar{p}^2$	0.194	0.0909	0.237

用者の慣性よりも大きな値として推定されるのは、自家用車の利用者が所要時間や、費用などを考慮せず、自家用車を利用していることを示していると考えられる現実に一致している。しかし、両モデルの誤差項の系列相関を考慮していないため、慣性項の推定値には状態依存だけでなく、系列相関の影響も含まれていることが予想されるが推定計算の簡便さから、実務上は有効なモデルであるといえる。

(4)系列相関を考慮しないRP・SPモデルの推定

先に推定したRPモデル、SPモデルの説明変数を用いて、RPモデルとSPモデルの混合推定を試みた。

このモデルは前節のRPデータとSPデータをプールしてパラメータの推定を行なう手法であり、両モデルの効用関数の誤差項が、回答者、選択肢、モデルのすべてについて独立であると仮定する。誤差項の分散の関係をスケール・パラメータとして式(14)で表すことにより、多項ロジット・モデルとして、選択確率を

$$P_n^{RP}(i) = \frac{\exp(\beta'x_{in}^{RP} + \alpha'w_{in}^{RP})}{\sum_{i \in J_n^{RP}} \exp(\beta'x_{in}^{RP} + \alpha'w_{in}^{RP})} \quad (18)$$

$$P_n^{SP}(j) = \frac{\exp\left\{\mu \cdot (\beta'x_{jn}^{SP} + \gamma'z_{jn}^{SP})\right\}}{\sum_{j \in J_n^{SP}} \exp\left\{\mu \cdot (\beta'x_{jn}^{SP} + \gamma'z_{jn}^{SP})\right\}} \quad (19)$$

と、表すことができる。すべてのデータの同時生起確率を最大化する最尤推定値が、未知パラメータの推定値である。推定結果をTable 2に示す。

Table 2の第一列は慣性項を含まないモデルの、第2列は含むモデルの推定結果である。SPデータをRPデータとともに用いることによって、新型特急ダミーは負の値をバイアスを解消できなかったことが分かる。これに対し、慣性項を説明変数に用いたモデルにおいてはすべてのパラメータがほぼ有意に正しい符号をとると推定された。また、スケール・パラメータは両モデルともに1より小さな値となり、SPモデルの誤差項はRPモデルのそれよりも大きな分散を持つと推定された。

(5)系列相関を考慮したRP・SPモデルの推定

3.に示した手法を用いてRPモデルとSPモデルの系列相関を考慮したモデルを推定した。

それぞれのモデルの効用関数を示す。誤差項は各個人のそれぞれの選択肢ごとに両モデルを通じて共通の

項 λ と、各個人、選択肢、モデルすべてについて独立な項 ε に分離されることにより、これまで問題となっていた系列相関を考慮している。

RPモデル：

$$u_{Rail,n}^{RP} = \beta'x_{Rail,n}^{RP} + \alpha'w_{Rail,n}^{RP} + \lambda_{Rail,n} + \varepsilon_{Rail,n}^{RP} \quad (20)$$

$$u_{Bus,n}^{RP} = \beta'x_{Bus,n}^{RP} + \alpha'w_{Bus,n}^{RP} + \lambda_{Bus,n} + \varepsilon_{Bus,n}^{RP} \quad (21)$$

$$u_{Car,n}^{RP} = \beta'x_{Car,n}^{RP} + \alpha'w_{Car,n}^{RP} + \varepsilon_{Car,n}^{RP} \quad (22)$$

SPモデル：

$$u_{Rail,n}^{SP} = \beta'x_{Rail,n}^{SP} + \gamma'z_{Rail,n}^{SP} + \theta_{Rail} \cdot \lambda_{Rail,n} + \varepsilon_{Rail,n}^{SP} \quad (23)$$

$$u_{Bus,n}^{SP} = \beta'x_{Bus,n}^{SP} + \gamma'z_{Bus,n}^{SP} + \theta_{Bus} \cdot \lambda_{Bus,n} + \varepsilon_{Bus,n}^{SP} \quad (24)$$

$$u_{Car,n}^{SP} = \beta'x_{Car,n}^{SP} + \gamma'z_{Car,n}^{SP} + \varepsilon_{Car,n}^{SP} \quad (25)$$

誤差項 λ が3つの代替案のうちの2つの効用関数にのみ含まれるのは、次に示す条件付き確率においてあたかも定数項のように働くため、3つ含んだ場合パラメータが一意に定まらないためである。

Table 2
Results of RP and SP Combined Estimation
with/without Inertia Dummies
(t-statistics in parentheses)

	without inertia dummy	with inertia dummies
Rail constant (RP)	1.72 (5.3)	1.67 (5.1)
Bus constant (RP)	1.27 (4.8)	1.26 (4.8)
Rail constant (SP)	1.00 (3.7)	3.37 (3.3)
Bus constant (SP)	0.147 (0.9)	1.17 (1.7)
Business trip total travel time (hr.)	-0.256 (-1.5)	-0.339 (-1.4)
Cost per person (1,000yen)	-0.389 (-4.4)	-0.383 (-4.4)
High-grade train dummy	-0.296 (-1.3)	1.49 (2.3)
Bus inertia dummy		2.87 (2.5)
Car inertia dummy		6.18 (2.8)
Scale parameter	0.859 (3.9)	0.518 (3.0)
N	934	934
p ²	0.119	0.226

ここで誤差項の分布形を以下のように定義する。すなわち、誤差項 ε についてはガンベル分布、 λ については標準正規分布である。

誤差項の分布形が与えられたもとで、選択確率を定義することができる。まず、誤差項 λ が既知であるという条件のもとでの各モデルの選択確率は、

$$P_n^{RP}(i|\lambda) = \frac{\exp(\beta'x_{in}^{RP} + \alpha'w_{in}^{RP} + \lambda_{in})}{\sum_{i' \in J_n^{RP}} \exp(\beta'x_{i'n}^{RP} + \alpha'w_{i'n}^{RP} + \lambda_{i'n})} \quad (25)$$

$$P_n^{SP}(i|\lambda) = \frac{\exp\{\mu \cdot (\beta'x_{in}^{SP} + \gamma'z_{in}^{SP} + \theta_i \cdot \lambda_{in})\}}{\sum_{i' \in J_n^{SP}} \exp\{\mu \cdot (\beta'x_{i'n}^{SP} + \gamma'z_{i'n}^{SP} + \theta_{i'} \cdot \lambda_{i'n})\}} \quad (26)$$

Table 3
Comparing Results of RP and SP Combined Estimations
(t-statistics in parentheses)

	model 0*	model 1**	model 2***
Rail constant (RP)	1.67 (5.1)	1.90 (3.8)	1.73 (5.1)
Bus constant (RP)	1.26 (4.8)	1.59 (4.3)	1.38 (4.0)
Rail constant (SP)	3.37 (3.3)	1.83 (1.53)	2.01 (3.4)
Bus constant (SP)	1.17 (1.7)	1.10 (1.1)	1.33 (2.1)
Business trip total travel time (hr.)	-0.339 (-1.4)	-0.225 (-0.4)	-0.508 (-1.5)
Cost per person (1000yen)	-0.383 (-4.4)	-0.371 (-3.4)	-0.417 (-4.8)
High-grade train dummy	1.49 (2.3)	0.796 (2.6)	1.23 (2.7)
Bus inertia dummy	2.87 (2.5)		0.0823 (0.2)
Car inertia dummy	6.18 (2.8)		3.46 (3.0)
θ -rail		2.41 (2.1)	2.08 (3.7)
θ -bus		2.56 (1.4)	1.48 (2.8)
Scale parameter	0.518 (3.0)	1.25 (3.1)	1.11 (3.3)
N	934	255	255
$\bar{p}^2$	0.226	0.240	0.265

* RP and SP mixed estimation not considering serial correlation

** RP and SP mixed estimation considering serial correlation without inertia dummies

*** RP and SP mixed estimation considering serial correlation, with inertia dummies

である。ここで、同時分布関数を用いることにより、RPモデルとSPモデルの同時選択確率を得る。

$$P_n\{d_n^{RP}(i)=1, d_n^{SP}(j)=1\} \\ = \int_{-\infty}^{+\infty} P_n^{RP}(i|\lambda_n) \cdot P_n^{SP}(j|\lambda_n) \cdot \Phi(\lambda_{Bus,n}) \cdot \Phi(\lambda_{Car,n}) d\lambda_{Bus,n} d\lambda_{Car,n} \quad (27)$$

ここに関数 $\phi(\lambda)$ は正規分布の密度関数である。

未知パラメータは最尤推定法により、すべての回答者の同時選択確率を最大化する値として求めることができる。推定計算には数値積分を要し、たとえばガウスの求積法などの手法を用いて行う。パラメータの推定結果をTable 3に示す。表中、第2列(model 1)は慣性項を含まないモデル、第3列(model 2)は含むモデルの推定結果である。比較のために前節の系列相関を考慮しないモデルの推定結果をmodel 0として第一列に示した。

系列相関を考慮した二つのモデルはともに、考慮しないモデルの推定結果に比べ、尤度比などから見ても適合度の高い推定結果を得た。またmodel 1より、RPモデルとSPモデルの系列相関を考慮することにより、慣性項を導入しなくても新型特急ダミーに現われたバイアスが解消されることが示された。

系列相関を考慮したモデルの説明変数に慣性項を加えたモデル(model 2)では、model 1に比較してさらに適合度も高く、またパラメータのt値も大きいモデルが推定されている。model 0と比較した場合、高速バス、自家用車利用者の慣性項がともに小さな値となり、真の意味での状態依存が表されたといえる。

以上の結果よりRP・SP混合推定ではSP質問に対する回答の持つRPデータへの依存性を表す状態依存と、両モデルの系列相関を考慮することが有効であることが明らかにされた。

5. 結論

(1) 研究の成果

本稿ではこれまでに提案したRPデータとSPデータを同時に用いる交通機関選択モデルをさらに発展させ、両者の補完的な特長を生かすとともに、状態依存だけでなく既存の方法では考慮できなかった系列相関を明示的に表現した考慮したRP・SP混合モデルの推定法を提案した。

提案した手法は、RPデータとSPデータをパネル・データとして捉えた手法であり、ダイナミック・モデリングにも適用が可能である。

事例研究の結果から、RPモデルとSPモデルの誤差項の系列相関の存在が確かめられ、また提案した手法によりより有効性の高いパラメータが推定されることが示された。加えて、状態依存のみを考慮したモデルによっても実用上は有効なモデルが導かれることが分かった。

(2) 今後の課題

まずパラメータ推定計算プログラムの改善が挙げられる。現在の計算プログラムではオーダード・モデルなどの種々のSPデータには対応しておらず、また、計算時間も長いので、モデルの実用化には改善が必要である。

また様々な条件下で得られたSPデータを用いて、事例研究を行ない、モデルの有効性を確認することが期待される。事後データによりモデルの推定結果の信頼性を確かめることも必要であろう。

さらに、パネルデータを用いるダイナミック・モデルへの手法の拡張も期待される。

参考文献

- 1) Ben-Akiva, M. and T. Morikawa: Estimation of Switching Models from Revealed Preferences and Stated Intentions, *Transportation Research-A*, Vol.24A, No.6, pp.485-495, 1990.
- 2) Ben-Akiva, M. and T. Morikawa: Estimation of Travel Demand Models from Multiple Data Sources, *Transportation and Traffic Theory*(M. Koshi, ed.), Elsevier, pp.461-467, 1990.
- 3) 森川高行, 山田菊子: SPデータとRPデータを用いた都市間鉄道のサービス改善に伴う需要予測法, 土木計画学研究・講演集, No.13, pp.659-666, 1990.
- 4) 太田勝敏: 非集計行動モデルの理論展開—ロジット・モデルを中心として—, 第15回土木計画学講習会テキスト—非集計行動モデルの理論と実際—, 土木学会土木計画学研究委員会編, 土木学会, pp.9-23, 1984.
- 5) Ben-Akiva, M. and S.R. Lerman: *Discrete Choice Analysis*, MIT Press, 1987.
- 6) Heckman, J.J.: Statistical Models for Discrete Panel Data, *Structural Analysis of Discrete Data with Econometric Applications*(Manski and McFadden eds.), MIT Press, pp.114-175, 1981.
- 7) Morikawa, T.: *Incorporating Stated Preference Data in Travel Demand Analysis*, Ph.D. Dissertation, Department of Civil Engineering, MIT, 1989.
- 8) Kitamura, R.: Panel Analysis in Transportation planning: An Overview, *Transportation Research-A*, Vol.24A, No.6, pp.401-415, 1990.