

S P データと R P 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

FORECASTING INTERCITY RAIL PASSENGERS
USING REVEALED PREFERENCE AND STATED PREFERENCE DATA

森川高行*・山田菊子**

By *Takayuki MORIKAWA and Kikuko YAMADA*

The aims of this paper are 1)to present a methodology for incorporating two different types of data, revealed preference (RP) and stated preference (SP) data in discrete choice models, 2)to apply the model to intercity mode choice analysis, and 3)to predict the aggregate numbers of passengers of alternative modes against changes in service levels.

A case study of intercity travel mode choice is emphasized. It demonstrated the practicality of the methodology by reproducing accurately observed aggregate data through two different aggregation methods and presenting a flexible and operative prediction method.

1. はじめに

交通施設のサービス・レベルの変更に伴う需要予測には、移転性が高く政策変数を取り込みやすい非集計行動モデルを用いることが多い。しかし大幅なサービスの変更やまったく新しい交通機関（長距離高速リニアモーターカーなど）の供用を含めて、これまでにないサービスの導入に対しては、過去の行動結果に基づく非集計データだけから信頼性の高い需要予測モデルを推定することは困難である。

このような場合、新しいサービスや交通機関の属性を言葉や絵で回答者に提示してそれに対する選好を尋ねるという調査手法がしばしば用いられる。このような「仮想の状況」における選好のデータを S P (Stated

Preference) データと呼び、これに対して実際の選好行動結果に基づくデータを R P (Revealed Preference) データと呼ぶ¹⁾。

S P データは、現存しないサービスに対する選好の情報を得られるという長所のほかに、一種の実験データであることから代替案の属性値を自由に設定できることや、選択肢集合を定めることができるなど選択モデル推定上多くの長所を持つ。しかし、市場における行動原理が必ずしも厳密に働かないために、S P データに現われた選好が実際の行動結果と一致しない場合があるなどデータの「信頼性」が問題となっている¹⁾。著者らは、S P と R P という二つの補完的な性質を持つデータをモデル推定に同時に用いることによって両者の長所を生かす方法論を提案している^{2), 3)}。この方法は、R P データの市場行動の反映、および S P データの属性間のトレード・オフの情報の豊富さと現存しないサービスに対する選好情報という長所の利用によ

* 正会員 Ph.D. 京都大学助手 工学部交通土木工学科教室
(〒606 京都市左京区吉田本町)

** 学生員 京都大学大学院 工学研究科応用システム科学専攻
(同上)

り、「パラメータ推定値の有効性の増大」、「SPデータのバイアスの修正」、「現存しないサービスに対する需要予測」という特長を持っている。

本研究の目的は、このRPデータとSPデータを同時に用いる手法によって推定された交通機関選択モデルを用いて、長距離鉄道のサービス改善に伴う需要予測手法を開発するものである。以下本論文で紹介する需要分析のポイントを列挙する。

a) 従来にないサービスの導入に伴う需要予測

本分析で扱うサービスの改善には、旅行時間の短縮や費用の削減に加え、「高快速性列車の導入」といった従来のRPデータだけを用いた需要分析では困難であったものが含まれている。

b) 都市間交通

本研究で対象とする都市間交通は2地方間を結ぶ非日常的な交通である。そのため、その発生は非常にまれであり、住民調査で推定に十分な数のサンプルを得ることは非効率的であるという特徴を持つ。

c) 交通機関の利用可能性の考慮

今回考慮した代替的な交通手段は、特急利用による鉄道と高速乗合バス、さらに高速自動車道による自家用車の3つであるが、公共交通機関である鉄道と高速バスは駅あるいは停留所の位置により、また自家用車は車あるいは運転免許の保有により、利用可能性が制限され、全回答者が同じ代替案集合を持つわけではない。

d) 集計予測OD表の作成

本分析の最終的な目的は、様々な政策変数を変化させたときの2地方間の県単位OD表を作成することである。

本論文の構成は以下の通りである。2.でSPデータとRPデータを同時に使用した非集計モデルの推定法を示す。3.では提案したモデルを都市間鉄道のサービス改善に関するアンケート調査データに適用し、通常のRPデータのみ、またSPデータのみを用いたモデルによる推定結果と比較、検討を行なう。4.では集計値算定の方法論と今回の分析の結果を紹介する。最後に5.において本研究で得られた知見をまとめ、今後に残された課題を提起する。

2. SPデータとRPデータを用いた

非集計モデルの推定法

前章に述べたように、RPデータとSPデータのそれぞれの性質を補完的に利用するために、本章では両者を同時に用いたモデルを定式化し、そのパラメータの推定方法を提案する。

(1) モデルの定式化

推定するモデルには、ランダム効用理論に基づく離散型選択モデル（ロジット・モデル、プロビット・モデルなど）を仮定し、RPデータとSPデータの発生過程をそれぞれ別のモデルで表現する。これはそれぞれのデータが発生する際の意思決定機構が異なる可能性に対処するためであるが、いくつかの属性間のトレード・オフ関係は共通と考えている。さらに両モデルの効用のランダム項のばらつきの大きさが同じであるという根拠はないため、2つのモデルのパラメータのスケールの違いを表す未知パラメータも含んでいる。

以下の定式化では添字のRP、SPがそれぞれの変数がRP、SPデータから得られるものであることを表す。

RPモデル：

$$u_{in}^{RP} = \beta' \mathbf{x}_{in}^{RP} + \alpha' \mathbf{w}_{in}^{RP} + \varepsilon_{in}^{RP} \\ = v_{in}^{RP} + \varepsilon_{in}^{RP}, i=1, \dots, I_n^{RP} \quad (1)$$

$$d_n^{RP}(i) = \begin{cases} 1: & \text{if alternative } i \text{ is chosen} \\ 0: & \text{otherwise} \end{cases} \quad (2)$$

SPモデル：

$$u_{in}^{SP} = \beta' \mathbf{x}_{in}^{SP} + \gamma' \mathbf{z}_{in}^{SP} + \varepsilon_{in}^{SP} \\ = v_{in}^{SP} + \varepsilon_{in}^{SP}, i=1, \dots, I_n^{SP} \quad (3)$$

$$d_n^{SP}(i) = \begin{cases} 1: & \text{if alternative } i \text{ is chosen} \\ 0: & \text{otherwise} \end{cases} \quad (4)$$

ランダム項の分散の関係：

$$\text{Var}(\varepsilon_{in}^{RP}) = \mu^2 \text{Var}(\varepsilon_{in}^{SP}) \quad \forall i, n \quad (5)$$

ここに、

u_{in} ：個人*n*の代替案*i*に対する総効用

v_{in} ：個人*n*の代替案*i*に対する効用の確定項

$d_n(i)$ ：個人*n*の代替案*i*の選択ダミー

\mathbf{x}_{in} , \mathbf{w}_{in} , \mathbf{z}_{in} ：個人*n*の代替案*i*に対する説明変数ベクトル

ε_{in} ：効用のランダム項

α , β , γ ：未知係数ベクトル

μ ：ランダム項の分散の違いを表すスケール・パラメータ

この定式化において、 \mathbf{x} はRPモデルとSPモデルで共通の係数ベクトル β を持つ説明変数ベクトルであり、 \mathbf{w}, \mathbf{z} はそれぞれRPモデル、SPモデルで異なる係数を持つ説明変数である。つまり、 $\gamma\mathbf{z}$ がSPバイアスおよびSPデータにしか含まれ得ない属性項（たとえば新しいサービスの影響）を表している。

RPモデルのランダム効用項に独立で同一なガンベル分布を仮定すると式(6)で選択確率を与えるロジット・モデルが得られる。

$$P_n^{RP}(i) = \frac{\exp(v_{in}^{RP})}{\sum_{j=1}^{I_n^{RP}} \exp(v_{jn}^{RP})} \quad (6)$$

同様に、SPモデルについても同様に式(7)のロジット・モデルが得られるが、式(5)に定義したスケール・パラメータ μ が効用関数にかけられている点に注意が必要である。

$$P_n^{SP}(i) = \frac{\exp(\mu \cdot v_{in}^{SP})}{\sum_{j=1}^{I_n^{SP}} \exp(\mu \cdot v_{jn}^{SP})} \quad (7)$$

(2) パラメータの推定

SPデータとRPデータを融合したデータを用いて最尤推定法により、未知パラメータ・ベクトル α, β, γ および、スケール・パラメータ μ を同時にまたは段階的に推定することができる。まず、以下に示す対数尤度関数を考える。

$$L^{RP}(\alpha, \beta) = \sum_{n=1}^{N^{RP}} \sum_{i=1}^{I_n^{RP}} d_n^{RP}(i) \cdot \log(P_n^{RP}(i)) \quad (8)$$

$$L^{SP}(\beta, \gamma, \mu) = \sum_{n=1}^{N^{SP}} \sum_{i=1}^{I_n^{SP}} d_n^{SP}(i) \cdot \log(P_n^{SP}(i)) \quad (9)$$

RPモデルとSPモデルの効用のランダム項が統計的に独立ならば

$$L^{RP+SP}(\alpha, \beta, \gamma, \mu) = L^{RP}(\alpha, \beta) + L^{SP}(\beta, \gamma, \mu) \quad (10)$$

で与えられる同時対数尤度関数を最大化することによって一致性と漸近的有効性を持つ最尤推定量を得ることができる。ランダム項に独立性が成り立たない場合でも一致性を持つ推定量を得ることができる⁴⁾が、この点に関しては5)で詳しく述べる。この同時対数尤度関数は μ の導入によりパラメータについて非線形であるため通常のロジット・モデルの推定パッケージを使用

することができない。段階推定法は、式(8)と(9)の尤度関数を段階的に最大化することによってパラメータの非線形性を避け、通常のパッケージの使用を可能にするものである。

段階推定法の手順はMorikawa(1989)⁵⁾に詳しい。

(3) モデルによる予測

前節で述べた方法でRP、SP両モデルの未知パラメータが推定されると、その推定値を用いて需要予測を行なう。その際使用すべきモデルは実際の選択行動を表す式(1)のRPモデルである。つまり期待効用の予測値は、

$$\hat{v}_{in}^{RP} = \hat{\beta}' \mathbf{x}_{in}^{RP} + \hat{\alpha}' \mathbf{w}_{in}^{RP} \quad (11)$$

で与えられる。

SPモデルに特有な説明変数ベクトル \mathbf{z} の中で、将来予測に必要な属性（たとえば、ある代替案にまったく新しいサービスを加える場合そのサービス・レベル）がある場合には、その属性の効用項をRPモデルの効用関数に加えて予測を行なう。すなわち、そのような属性ベクトルを \mathbf{z}_{in}^{SP} （ \mathbf{z}_{in}^{SP} は \mathbf{z}_{in}^{SP} のサブ・ベクトル）、それに対応する係数ベクトル推定値を $\hat{\gamma}$ （ $\hat{\gamma}$ は γ のサブ・ベクトル）とすると予測に用いる期待効用値は式(12)で与えられる。

$$\hat{v}_{in} = \hat{\beta}' \mathbf{x}_{in}^{RP} + \hat{\alpha}' \mathbf{w}_{in}^{RP} + \hat{\gamma}' \mathbf{z}_{in}^{SP} \quad (12)$$

ここで $\hat{\gamma}$ はスケール・パラメータ μ の導入によってRPモデルのスケールに変換されている。

3. 事例研究

—都市間交通機関選択モデルの推定

(1) 事例研究に用いたデータ

事例研究に用いたデータは、2地方を結ぶ特急列車にパノラマ・カーなどを含む高快適性列車を導入した場合の需要予測のために行なわれたアンケート調査により得られたものである。この2地方（以下A地方、B地方と呼ぶ）を結ぶ特急列車の代替的手段としては、高速バスおよび高速自動車道を利用した自家用車が考えられ、所要時間はそれぞれ、鉄道利用で2～3時間、バス・自家用車利用で4～5時間である。

当該交通機関の利用者に対して調査票を配布し、その場または郵送によって回収するという選択肢別無作為標本抽出(Choice Based Random Sampling)を採用した。これは、発生の少ない非日常的な都市間交通行動が対

象であるので、対象地域の住民を母集団とした無作為標本抽出では十分な有効回答数を得ることが困難であると考えられるためである。

(2) RP モデルの推定結果

まず、RPデータのみを用いたモデルを式(8)の対数尤度関数を最大化することによって推定した。モデル推定に用いた説明変数は以下の通りである。

- 1) 幹線交通時間：各幹線交通機関にかかる旅行時間。ただし、高速自動車道路利用の場合には出発地から目的地までにかかる時間。
- 2) 端末交通時間：旅行の出発地から幹線交通の始点まで（アクセス交通）、および幹線交通の終点から旅行の目的地まで（イグレス交通）にかかる時間の合計。
- 3) 総交通費用：幹線・端末交通にかかる費用の合計。
- 4) 旅行目的：業務旅行と観光・帰省目的の旅行には選択構造、時間価値などに差があることが考えられるため、モデル内では旅行時間および、旅行費用との相互作用項として用いた。

また選択肢別無作為標本抽出によるサンプルから推定されるロジット・モデルには、選択肢固有の定数項にそのサンプル比率に応じてバイアスが生じることが知られており、以下のように実際のマーケット・シェアを用いて選択肢の定数項を修正することが必要である⁶⁾。

$$\hat{\beta}_0^i = \hat{\beta}_0^i - \log \frac{H_i}{W_i} \quad (13)$$

ただし、

$\hat{\beta}_0^i$ ：修正された選択肢 i の定数項

$\hat{\beta}_0^i$ ：選択肢 i の定数項の最尤推定値

H_i ：推定に用いたサンプル中の選択肢 i のマーケット・シェア

W_i ：実際の選択肢 i のマーケット・シェア

である。

推定結果を表-1に示す。各パラメータは概ね妥当な値をとっていると考えられる。旅行時間に対して業務以外の旅行には有意な係数値が得られなかつたためにモデルには含まれていない。これは、業務以外の観光、帰省などの旅行では旅行時間は交通手段選択の際にあまり考慮されず、むしろ旅行費用が大きな影響を

与えることを示唆しており、直感的にも妥当と思われる。幹線旅行時間から計算される業務旅行の時間価値は、1時間当たり約千円になっており、妥当であると考えられる。

表-1 RP モデルの推定結果

変数	交通手段	鉄道	高速バス	自動車
定数項		1.66 (5.35)	-1.43 (-5.04)	
業務交通幹線時間 (時間)			-0.458 (-1.69)	
業務交通端末時間 (時間)		-0.973 (-1.83)		
総交通費用 (千円)			-0.402 (-5.47)	
業務ダミー・総交通費用 (千円)			0.102 (0.738)	
サンプル数= 255				
$L(0) = -191.35$		$L(\hat{\beta}) = -149.25$		
$\rho^2 = 0.220$		$\rho^2 = 0.251$		

ただし、

()内はt値

$L(0)$ ：係数値をすべて0としたときの対数尤度関数値

$L(\hat{\beta})$ ：係数が最尤推定値を取るときの対数尤度関数値

$$\rho^2 = 1 - \frac{L(\hat{\beta})}{L(0)}, \quad \bar{\rho}^2 = 1 - \frac{L(\hat{\beta}) - K}{L(0)} \quad (K : \text{推定する係数の数})$$

(3) SP モデルの推定結果

本調査ではSPデータとして交通機関のサービス・レベル（主に鉄道のサービス）を次のように変化させた10通りのシナリオを設定して最も好ましいと考える交通手段を回答させた。

【鉄道利用者を対象】

1) 現状と変化なし

2) 高速バスの発着駅が近くにできたとき

【高速バス利用者を対象】

3) 現状と変化なし

4) 鉄道の幹線旅行時間が2時間を切ったとき

5) 鉄道の特急の半分が高快速性列車になったとき

6) 鉄道の幹線旅行時間が2時間を切り、特急の半数が高快速性列車になったとき

【高速自動車道路利用者を対象】

7) 現状と変化なし

8) 鉄道の幹線旅行時間が1割短くなったとき

9) 鉄道の特急の半分が高快速性列車になったとき

10) 鉄道の幹線旅行時間が1割短くなり、特急の半分が高快速性列車になったとき

本事例研究では高速バスや自動車の利用者からの転換の意向を分析するために、高速バスと自動車の利用者に対するSPデータ（質問3～10）のみを使用してモデルの推定を試みた。式(9)の対数尤度関数を最大化して得られた推定結果を表-2に示す。ただしここで得られたパラメータはそれぞれ $\mu\beta$ 、 $\mu\gamma$ の推定値である。定数項については、RPデータから推定されたモデルとかなり異なった値を示しているが、これはSPデータに含まれるバイアスによるものであると考えられる。高快速性列車の導入によるサービス・レベルの改善についてのパラメータは、有意な正値をとった。また、このモデルにより計算される業務旅行の幹線交通の時間価値は2,000円程度である。

表-2 SPモデルの推定結果

変数	交通手段	鉄道	高速バス	自動車
定数項	-0.382 (-1.32)	-0.457 (-2.17)		
高快速性列車 ダミー	0.702 (3.14)			
業務交通幹線時間 (時間)		-0.370 (-0.556)		
業務交通端末時間 (時間)		0.232 (0.343)		
総交通費用 (千円)		-0.336 (-4.69)		
業務ダミー・総交通費用 (千円)		-0.551 (-1.20)		
サンプル数 = 434				
$L(0) = -332.26$		$L(\hat{\beta}) = -271.18$		
$\rho^2 = 0.184$		$\rho^2 = 0.205$		

(4) SPデータとRPデータを

同時に用いたモデルの推定結果

次にSPデータとRPデータを同時に用いたモデルの推定結果を表-3に示す。未知パラメータは同時推定法により推定した。また、本モデルではSPデータ、RPデータそれぞれについて、鉄道、高速バスの選択肢固有の定数項を設定した。これは将来予測に用いる際に、SPデータ特有のバイアスを表すと考えられるSPデータから推定された定数項を分離するためである。対数尤度関数は式(10)に定義されたものである。表-3よりSPデータの定数項には特有のバイアスが含まれていることが予想される。高快速性列車の増加に

関するパラメータはここでも有意な正値をとった。また、ランダム項のスケール・パラメータ μ は1.33となり、RPデータのランダム項の分散が、SPデータのそれより大きく、RPデータの方がランダム・ノイズが大きいことを示している。

表-3 RPモデルとSPモデルを
同時に推定した結果

変数	交通手段	鉄道	高速バス	自動車
定数項 (RPデータ)	1.40 (5.09)	-1.59 (-5.93)		
定数項 (SPデータ)	-0.182 (-0.797)	-0.324 (-1.88)		
高快速性列車 ダミー	0.520 (2.39)			
業務交通幹線時間 (時間)		-0.270 (-1.39)		
業務交通端末時間 (時間)		-0.143 (-0.516)		
総交通費用 (千円)		-0.294 (4.29)		
業務ダミー・総交通費用 (千円)		-0.187 (-1.58)		
スケール パラメータ		1.33 (3.55)		
サンプル数 = 689				
$L(0) = -524.61$		$L(\hat{\beta}) = -427.59$		
$\rho^2 = 0.185$		$\rho^2 = 0.204$		

4. 非集計モデルからの集計予測値推計

本章では、モデルの現況再現性の検証および、いくつかのシナリオに基づいた需要予測を行なうために、選択確率から予測集計値を求める手法について概説し、「総当たり法」と「代表的個人法」の2手法について分析を試みた結果をまとめると。

(1) 「総当たり法」による集計値の算定

まず式(12)により計算された各個人の各交通機関ごとの期待効用 \hat{v}_{in} を用いて個人ごとの選択確率が次のように求められる。

$$\hat{P}_n(i) = \frac{e^{\hat{v}_n(i)}}{\sum_{j=1}^{I_n} e^{\hat{v}_n(j)}}, \forall i, n \quad (14)$$

総当たり法では信頼性の高い集計値を得るためにサンプル数が多く必要であるため、県単位OD表ではなく2地方間の合計旅客数を予測した。またモデル推定に使われたサンプルがマーケット全体を十分よく表す

と仮定して、サンプル中のシェアをマーケット・シェアに用いた。

また、目的地や出発地の地理的条件などのために単一の選択肢しか持たない層であるキャブティップ層の存在を考慮する必要がある。ここでもサンプル中のキャブティップ層の比率が母集団のそれと等しいと仮定し、観測された代替案ごとの集計量をキャブティップ層とノン・キャブティップ層に分ける。ここで、代替案 i のキャブティップ層の集計値を $C(i)$ とする。

代替案 i の総予測需要量 $N(i)$ は、キャブティップ層の集計量 $C(i)$ と、ノン・キャブティップ層の集計量とそのシェア $S(i)$ を掛け合わせたものの和である。

$$\begin{aligned} N(i) &= C(i) + N \cdot S(i) \\ &= C(i) + N \cdot \sum_{j=1}^I W_j \frac{1}{N_{sj}} \sum_{n=1}^{N_{sj}} \hat{P}_{nj}(i) \\ &= C(i) + N \cdot \sum_{j=1}^I \frac{N_j}{N} \frac{1}{N_{sj}} \sum_{n=1}^{N_{sj}} \hat{P}_{nj}(i) \\ &= C(i) + \sum_{j=1}^I \frac{N_j}{N_{sj}} \sum_{n=1}^{N_{sj}} \hat{P}_{nj}(i) \\ &= C(i) + \sum_{j=1}^I E_j \sum_{n=1}^{N_{sj}} \hat{P}_{nj}(i), \quad i=1, \dots, I \quad (15) \end{aligned}$$

ただし、

N_{sj} : サンプル中の交通手段 j を選んだ人数

N_j : 選択肢 j の実績値

N : すべての選択肢について実績値の合計

W_j : 選択肢 j の実績シェア

$\hat{P}_{nj}(i)$: 選択肢 i を選んだ個人 n の想定したシナリオのもとでの選択肢 j の選択確率

また、

$$E_j = \frac{N_j}{N_{sj}} \quad (16)$$

は拡大係数で、各交通機関別の母集団内サンプル比率の逆数になっている。

このような集計法を用いて、鉄道の高快速性列車の導入を含むサービス・レベルの改善による需要の変化を予測する。

以下の4つのシナリオを説明変数の変化により表した。

シナリオ1 : 各交通機関とも現状のサービス・レベル。

シナリオ2 : 現在運行している従来型の特急の半数を高快速性列車を用いた新型特急に変更す

る。

シナリオ3 : 現在運行している特急の所要時間を約1割短縮する。

シナリオ4 : 特急の半数を新型にし、かつ所要時間も1割短縮する。

観測された需要実績値および各シナリオに対する需要予測の計算結果を表-4に示す。シナリオ1の結果から、予測値と実績値の誤差はそれぞれ鉄道のシェアで0.1%、高速バスで0.1%、高速自動車道で0.2%であり、選択肢固有の定数項に修正を加えたにもかかわらず本モデルの現況再現性は非常に高いことがわかる。これはRPデータとSPデータを結合した際に定数項をそれぞれのデータごとに推定し、予測にはRPデータの定数項を使うことによって総当たり法の場合の現況シェア完全再現性というロジット・モデルの望ましい性質を利用ることができたためである。高快速性列車による新型特急の導入が鉄道の需要増加を促す効果が大きいことがわかる。

表-4 需要実績値と総当たり法による需要予測

	鉄道	高速バス	自動車道
需要実績値	5,365,865 (73.6)	117,237 (1.6)	1,808,940 (24.8)
シナリオ1	5,357,431 (73.5)	113,046 (1.5)	1,821,565 (25.0)
シナリオ2	5,646,818 (77.4)	80,992 (1.1)	1,564,232 (21.5)
	△289,387 (△3.9)	▼32,054 (▼0.4)	▼257,333 (▼3.5)
シナリオ3	5,369,599 (73.7)	111,719 (1.5)	1,810,724 (24.8)
	△12,168 (△0.2)	▼1,327 (▼0.0)	▼10,841 (▼0.2)
シナリオ4	5,656,751 (77.6)	80,112 (1.1)	1,555,179 (21.3)
	△299,320 (△4.1)	▼32,934 (▼0.4)	▼266,386 (▼3.7)

ただし、需要実績値および各シナリオについて
予測利用人数（人／年）

予測シェア（%）

シナリオ2、3、4についてはさらに

シナリオ1からの増減値（△増、▼減）（人／年）

増減シェア（%）

(2) 「代表的個人法」による集計値の算定

代表的個人法はマーケット・セグメントごとに代表的であると思われるサンプルの説明変数値を設定し、その「代表的個人」の選択確率をそのセグメントのシェアとするものである。両地方間のそれぞれ3県（A地方についてはA1県、A2県、A3県、B地方についてはB1県、B2県、B3県）のODペア9種類をマーケット・セグメントとして、それぞれにサンプル中の説明変数の平均値をもって代表値とした代表的個人を設定し需要予測を試みた。

代表的個人法で問題となるのはマーケット・セグメント内で選択肢集合が不均一な場合である。都市間交通や観光行動などの非日常的な行動においては、個人ごとの選択肢集合には大きなばらつきがあると思われる。

本研究では、代替案の利用可能性を表すダミー変数のセグメントごとの平均値を用いて式(17)のように代表的個人の選択確率を計算することによって、この問題に対処した。

$$\bar{P}_k(i) = \frac{\delta_k(i) \cdot e^{\bar{v}_k(i)}}{\sum_{j \in C} \delta_k(j) \cdot e^{\bar{v}_k(j)}}, \quad i=1, \dots, I, \quad k=1, \dots, K \quad (17)$$

表-5 観測されたOD交通量

	A 1			A 2			A 3		
	鉄道	バス	自動車	鉄道	バス	自動車	鉄道	バス	自動車
B1	191,768 83.7%	0 0.0%	37,230 16.3%	414,524 83.4%	2,664 0.5%	79,570 16.0%	191,768 86.1%	1,332 0.6%	29,565 13.3%
B2	1,349,818 71.9%	0 0.0%	527,425 28.1%	1,265,649 66.7%	27,980 1.5%	604,805 31.9%	567,890 82.3%	13,320 1.9%	109,135 15.8%
B3	475,767 76.4%	0 0.0%	146,730 23.6%	621,082 68.5%	66,610 7.3%	218,635 24.1%	287,600 82.5%	5,329 1.5%	55,845 16.0%

表-6 代表的個人法による需要予測値

	A 1			A 2			A 3		
	鉄道	バス	自動車	鉄道	バス	自動車	鉄道	バス	自動車
B1	183,179 80.0%	0 0.0%	45,819 20.0%	408,038 82.1%	7,722 1.5%	81,498 16.4%	179,301 80.5%	1,348 0.6%	42,016 18.9%
B2	1,453,364 77.7%	0 0.0%	417,541 22.3%	1,366,426 72.0%	35,672 1.9%	496,336 26.1%	592,188 85.8%	11,131 1.6%	87,027 12.6%
B3	467,374 75.1%	0 0.0%	155,122 24.9%	659,621 72.7%	58,552 6.5%	188,154 20.8%	300,924 86.3%	6,383 1.8%	41,466 11.9%

ここに、

$\bar{P}_k(i)$ ：マーケット・セグメント k の代表的個人の選択肢 i の推定選択確率

$\bar{\delta}_k(i)$ ：マーケット・セグメント k の代表的個人の選択肢 i の利用可能性の平均値

$\bar{v}_k(i)$ ：マーケット・セグメント k の代表的個人の選択肢 i の推定確定効用値

である。

総当たり法の場合と同様にして、現況再現性を確かめるために政策変数の値を全く変化させずに需要予測を試みた結果が表-6である。表-5の観測されたOD交通量と比較すれば良好な現況再現性を示していることがわかる。次に「代表的個人法」の長所である説明変数の操作性の高さを利用して次の3ケースについて、説明変数を変化させて鉄道利用者の需要予測を行なった。

ケース1：高快適性列車を増便する

ケース2：鉄道の幹線所要時間を短縮する

ケース3：鉄道の幹線料金を減少させる

図-1～2は例としてOD交通量ではなく2地方間の総旅客数の変化を各ケースごとに表したものである。表-5に示した集計結果と同様に高快速性列車の増便がもっとも鉄道の利用を増加させ、ついで料金の低下が大きな影響を与えることがわかる。

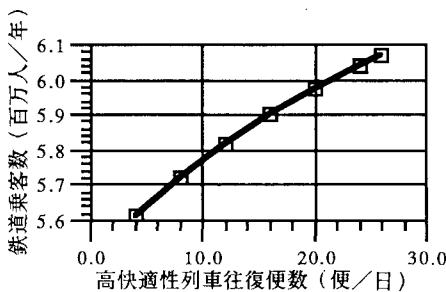


図-1 高快速性列車増便に伴う需要予測

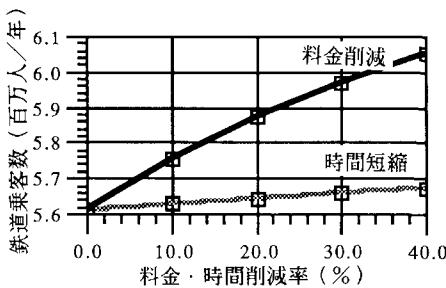


図-2 料金・時間の削減に伴う需要予測

5. 結論

(1) 本研究で得られた成果

本稿ではSPデータとRPデータという互いに補完的な性質を持つデータを同時に使用した交通機関選択モデルの推定法を提案した。事例研究においては「総当たり法」および「代表的個人法」の2つの集計手法を用いて、モデルの高い現況再現性および様々な政策変数の変更に対応できる柔軟性、というRPデータとSPデータの長所が生かされていることが示された。

(2) 今後の課題

今回のようにRP、SPデータの2つを同時に推定するモデルにおいて考慮しなければならない点は大きくまとめて次の3点である。まず両データのランダムネスの違いであり、本研究ではスケール・パラメータ μ

を導入することにより解決されたと考えられる。

次の点はSPデータに現われる選好がRPデータの行動結果に依存しているという両データの相関関係である。これは実際にとった行動を正当化しようとする「正当化バイアス」や余り深く考えずにSPデータの選好を回答してしまう「慣性」によるものである。

さらに、両モデルのランダム項はモデル定式化の際には独立であると仮定したが、実際には、

$$\varepsilon_{in}^{RP} = \varepsilon_n + \omega_{in}^{RP} \quad (18)$$

$$\varepsilon_{in}^{SP} = \varepsilon_n + \omega_{in}^{SP} \quad (19)$$

と言うように両者に共通の ε_n と独立の ω_{in} に分解され、独立でないことが考えられる。

これら2つの関係はそれぞれ、時系列データにおける“State Dependence”、“Serial Correlation”と相似のものである。2.(1)で述べたようにランダム項の独立性が保たれないSerial Correlationのみが存在するモデルについて推定された最尤推定量は一致性を持つが、State Dependenceと共に存在する場合にはバイアスが生じることが示されている⁴⁾。

この様な例はパネル・データ分析の際に指摘され、いくつかの方法が提案されている⁷⁾。本研究では今回取り扱わなかったこの2点の性質を踏まえたモデルの開発が今後の課題である。

参考文献

- 1) 森川高行：スティティッド・ブリファレンス・データの交通需要予測モデルへの適用に関する整理と展望、土木学会論文集、第413号、pp.9-18、1990年。
- 2) Ben-Akiva, M. and Morikawa, T.: Estimation of Switching Models from Revealed Preferences and Stated Intentions, Transportation Research B (Forthcoming), 1990.
- 3) Ben-Akiva, M. and Morikawa, T.: Estimation of Travel Demand Models from Multiple Data Sources, In Transportation and Traffic Theory, M. Koshi, ed., pp.461-476, 1990.
- 4) Amemiya, T.: Advanced Econometrics, Harvard University Press, 1985.
- 5) Morikawa, T.: Incorporating Stated Preference Data in Travel Demand Analysis, Ph.D. Dissertation, Department of Civil Engineering, MIT, 1989.
- 6) Ben-Akiva, M. and Lerman, S.R.: Discrete Choice Analysis, MIT Press, 1985.
- 7) Heckman, J.J.: Statistical Models For Discrete Panel Data, In Structural Analysis of Discrete Data with Econometric Applications, Manski, C.F. and McFadden, D., eds., MIT Press, pp.179-195, 1981.