

交通需要予測における調査頻度とサンプル数の トレードオフ： 3時点の繰り返し断面データを用いた基礎分析

三古 展弘¹

¹正会員 神戸大学大学院准教授 経営学研究科（〒657-8501 神戸市灘区六甲台町2-1）

E-mail: sanko@kobe-u.ac.jp

需要予測においては複数時点からデータが得られていても直近の1時点のデータのみを用いることが多い。本研究の問題意識は、複数時点のデータを用いるのであれば各時点のサンプル数を少なくしても、それよりも大きいサンプル数の直近の1時点のデータを用いるよりも優れた予測を行えるのではないかと、いうことである。筆者は既に2時点からデータが得られた場合の分析結果を報告しているが、本研究では3時点からデータが得られた場合について分析した。複数時点のデータを用いるモデルではパラメータが1人当たりGDP (Gross Domestic Product)の関数に従って変化することを仮定した。予測精度はブートストラップ法を用いることによって統計的に検定した。分析の結果、3時点から2500サンプルずつ合計7500サンプルを用いたモデルのほうが、1時点から10000サンプルを用いたモデルよりも統計的に有意に良い予測を行えることなどが示された。

Key Words : travel demand forecasting, temporal transferability, sample size, survey frequency, household travel survey, bootstrap

1. はじめに

交通手段選択や自動車保有などの交通行動を個人や世帯単位で分析するのに適した非集計モデルは需要予測に積極的に用いられている。需要予測モデルを断面データを用いて構築する場合、複数時点からデータが得られていても直近の1時点のデータのみを用いることが多く、貴重な過去のデータを無駄にしていた。

貴重な過去のデータも同時に用いることで、直近の1時点のデータのみを用いるよりも、予測精度が向上することが筆者¹⁾によって示されている。筆者¹⁾の方法では、複数時点のデータを同時に用い、パラメータを時間の関数で表現していた。この定式化は将来時点のパラメータを予測することが可能であるという特徴を持っている。その後、筆者²⁾は、パラメータを1人当たりGDP (Gross Domestic Product : 国内総生産) の関数で表現することも試み、1人当たりGDPの関数で表現するほうが時間の関数で表現するよりも予測精度において優れていることを示した。

パラメータをどのような変数（例えば、時間、1人当たりGDP）のどのような関数形（例えば、線形、2乗、平方根、対数、指数）で表現するかは重要な問題である。

交通手段選択モデルを例にとると、選択肢固有定数項と所要時間のパラメータが異なる変数の異なる関数形で表現されることも十分に考えられる。この問いに答えるためには、パラメータの時点変化がどのような要因で決まっているかを詳細に分析する必要がある。限られた時点の断面データを用いた分析ではこれを解明するには至っていないものの、Sanko³⁾の示す次の2つの理由により、総てのパラメータに1人当たりGDPの線形の関数を仮定することが現時点で最も妥当な方法と考える。理由の1つ目として、時間の関数についてはover-fittingの可能性があるため避けることが望ましい。理由の2つ目として、1人当たりGDP（線形、2乗、平方根）、女性の社会参加率（線形）、地下鉄路線長（線形）を比較したところ、結果に大きな差は無く、試みた中で最も理解が容易である1人当たりGDP（線形）の関数にするのが妥当と考える。

筆者の提案した方法はモデル更新手法の1つとして位置づけることが可能であり、パラメータを更新する関数を設けていることから、更新関数モデル(updating function model)と呼んでいる。更新関数モデルは、既存のモデル更新法である、transfer scaling, Bayesian updating, combind transfer estimation, joint context estimationと比べても統計的に

有意に良い予測精度を持つことがある。逆に、既存のモデル更新法が更新関数モデルよりも統計的に有意に良い予測を行えることはなかった⁴⁾。また、更新関数モデルと既存のモデル更新法のうち、更新関数モデルのみが直近の1時点のデータのみを用いるモデルよりも統計的に有意に良い予測精度を持つ場合があることを実証している⁵⁾。

以上の研究は、複数の時点のデータが与えられたときに、直近の1時点のデータのみを用いるか、複数時点のデータを用いるか、を問題としたものであった。しかし、複数時点からのデータ利用を前提とするなら、1時点あたりのサンプル数は少なくとも、それよりも大きい直近の1時点のデータによる予測と同等かそれよりも優れた予測を行える可能性があると考えられる。本研究の問題意識は、より多くの時点のデータを同時に用いることにより、各回の調査規模を削減できるのではないかと、ということである。このことは調査費用の削減と密接に関係している。直近の1時点のデータしか用いないのであれば、常に同規模の調査を継続して行う必要がある。しかし、各回の調査規模を小さくしても複数時点のデータを用いることで、直近の1時点のデータのみを用いるよりも予測精度が向上するのであれば、調査規模を削減することを正当化する理由となる。このことは、実務的にはパーソントリップ調査のような繰り返し断面調査のサンプル数の決定に貢献できると考える。

本研究のリサーチクエスチョンは以下に整理される。

リサーチクエスチョン：高頻度小規模調査と低頻度大規模調査の予測精度の比較

より多くの時点から n_s サンプルずつ得られたときのモデルと、より少ない時点から n_L サンプルずつ得られたときのモデルのどちらが統計的に有意に良い予測を行えるか。ただし、 n_s と n_L の関係は、 $n_s \leq n_L$ を考える。

このような問題意識に基づいた研究として、筆者⁶⁾はデータ収集時点として2時点を考えた分析を行った。直近の1時点のデータを用いるよりも、2時点のデータを用いることで各時点のサンプル数が1時点直近のサンプル数の10~80%しかなくても、同等の予測を行える場合があることを示した。

本研究の目的は、これを発展させ、複数時点として3時点を考慮した場合についても検討を行うことである。ここで示した問いに取り組むために、本研究では、中京都市圏で得られた1971, 1981, 1991, 2001年のパーソントリップ調査データを使用する。ここでは、1971, 1981, 1991年の3時点のデータをモデルの構築に用い、2001年

のデータを予測の検証のみに用いる。1時点のデータを用いるモデルでは1991年のデータを用いる（「1時点直近モデル」と表記）。2時点のデータを用いるモデルでは1971年と1991年のデータを用いる（「2時点更新関数モデル」と表記）。3時点のデータを用いるモデルでは1971, 1981, 1991年のデータを用いる（「3時点更新関数モデル」と表記）。このことから、低頻度大規模調査か、高頻度小規模調査か、という調査頻度とサンプル数のトレードオフを分析できると考える。なお、2時点更新関数モデルで1971年と1991年を選んだのは、3時点更新関数モデルと調査期間をそろえた場合における比較をすることを念頭に置いている。それぞれのモデルで、各時点から様々なサンプル数（100から10000の範囲の23通り）のデータをランダムに抽出する。統計的に意味のある知見を得るために、ブートストラップ法を用いる。パーソントリップ調査はこれまで同一の政府機関によって実施されており、調査方法が時点間で安定している。そのため、今回の分析でデータ収集年と各時点からのサンプル数以外の要因がコントロールされていると仮定することは妥当と考える。

本論文は以下のように構成される。2章ではデータを説明する。3章では方法論について説明する。4章ではパラメータ推定と統計的検定の結果を報告する。最後に、5章で結論を述べる。

2. データ

中京都市圏において1971, 1981, 1991, 2001年の4時点で作られた繰り返し断面データである、パーソントリップ調査データを用いる。モデルの構築には1971, 1981, 1991年のデータを用い、2001年のデータはモデルの予測精度の検証のみに用いる。本研究で分析の対象とするのは鉄道、バス、自動車の3選択肢からの通勤交通手段選択行動である。データの詳細についてはSanko⁷⁾を参照されたい。しかし、ここでは2点について再度強調しておく。1つ目に、通勤の費用については通勤手当が支給されることが多いため考慮しない。2つ目にモータリゼーションが急激に進んだことである。推定のためにデータを整理した後のサンプルを見ると1971, 1981, 1991, 2001年の交通手段のシェアは、鉄道：28%, 28%, 26%, 25%, バス：21%, 9%, 5%, 3%, 自動車：51%, 63%, 68%, 72%となっている。

3. 方法論

本研究の目的は、統計的な検定を用いて1時点直近モデル、2時点更新関数モデル、3時点更新関数モデルの予

測精度を比較することである。このような観点からの研究はこれまでにないので、本研究では分析を簡略化するため、多項ロジットモデルを採用する。しかし、ここで説明する方法論は、他のモデル構造の場合にも適用可能である。本章では、(1)節で多項ロジットモデルを説明し、(2)節で1時点直近モデルと更新関数モデルを説明する。(3)節では今回の分析におけるブートストラップ法の適用について説明し、(4)節ではブートストラップ法を利用したモデルの優劣の検定について説明する。なお、以下の説明で、3つのデータ収集時点を古い順に $t1$, $t2$, $t3$ と表記する。

(1) 多項ロジットモデル

ランダム効用理論に基づき、全効用を確定項と誤差項に分けて表現する。個人 p の選択肢 i に対する時点 t (ここでは $t1$, $t2$, $t3$ を区別しないで定式化する)における効用関数の確定項 V_{ip}^t を式(1)のように定式化する。

$$V_{ip}^t = \alpha_i^t + \sum_k \beta_{ik}^t x_{ikp}^t \quad (1)$$

ここに、 α_i^t は時点 t の選択肢 i の選択肢固有定数項、 x_{ikp}^t は時点 t の個人 p の選択肢 i に対する k 番目説明変数、 β_{ik}^t はそれに対応するパラメータである。なお、スケールパラメータは識別のため、1時点直近モデルでも更新関数モデルでも1に固定するので明示的に示していない。

誤差項に独立で同一なばらつきを持つガンベル分布を仮定すると、時点 t において個人 p が選択肢 i を選択する確率 P_{ip}^t は式(2)のロジット式で表現される。

$$P_{ip}^t = \frac{\exp(V_{ip}^t)}{\sum_j \exp(V_{jp}^t)} \quad (2)$$

このとき、対数尤度関数は式(3)で表現される。

$$L = \sum_t L^t = \sum_t \sum_p \sum_j y_{jp}^t \ln(P_{jp}^t) \quad (3)$$

ここに、 y_{jp}^t は時点 t で個人 p の選択結果が選択肢 j であったとき1、そうではないとき0となるダミー変数。パラメータは(3)式を最大化することによって推定される。

(2) 1時点直近モデルと更新関数モデル

a) 1時点直近モデル

上の(1)節で $t=t3$ を代入してモデルを推定する。なお、(3)式で最大化する対数尤度関数は、 $L = L^3$ である。モデルの予測精度は式(3)の2001年のデータへの対数尤度 L^{2001} で表現される。これは、推定されたパラメータ($\hat{\alpha}^{t3}$, $\hat{\beta}^{t3}$)、2001年の説明変数 \mathbf{x} と選択結果 \mathbf{y} を式(1)~(3)に代入することによって計算される。なお、 $\hat{\cdot}$ は推定値を意味

する。

b) 更新関数モデル

上の(1)節の式(1)において、 α_i^t と β_{ik}^t について、以下のように定式化する。

$$\alpha_i^t = \alpha_i + \alpha_{di} \text{gdp}^t \quad (4a)$$

$$\beta_{ik}^t = \beta_{ik} + \beta_{dik} \text{gdp}^t \quad (4b)$$

ここに、 α_i と β_{ik} は時点に関係ないベースのパラメータ(base parameters)、 α_{di} と β_{dik} は1人当たりGDPに伴って変化する部分を表現するパラメータ(historically changing parameters)である。また、 gdp^t は時点 t における、1人当たりGDP(constant 2005 price; units in 10 million JPY)である。

モデルの推定は、2時点更新関数モデルでは、(1)、(2)、(4)式で、 $t=t1, t3$ の場合について定式化し、(3)式の対数尤度関数 $L = L^1 + L^3$ を最大化する。3時点更新関数モデルでは、(1)、(2)、(4)式で、 $t=t1, t2, t3$ の場合について定式化し、(3)式の対数尤度関数 $L = L^1 + L^2 + L^3$ を最大化する。

モデルの予測精度については、2時点更新関数モデル、3時点更新関数モデルについて共通で、式(3)の2001年のデータへの対数尤度 L^{2001} で表現される。これは、推定されたパラメータ($\hat{\alpha}$, $\hat{\beta}$, $\hat{\alpha}_d$, $\hat{\beta}_d$)、2001年の1人当たりGDPである gdp^{2001} 、2001年の説明変数 \mathbf{x} と選択結果 \mathbf{y} を式(1)~(4)に代入することによって計算される。なお、1人当たりGDPについては線形で考えている。これは第1章で述べたように筆者³⁾が試みた1人当たりGDPの異なる関数形について結果に明確な違いが見られなかったためであり、最も単純な線形を採用した。

(3) ブートストラップ⁷⁾

まず、1971, 1981, 1991年のデータから通勤トリップをランダムに10000サンプルずつ抽出した。各年から同じサンプル数を抽出するのは、そこからブートストラップを行うことになる、サンプル数の違いが結果に与える影響を避けるためである。また、10000サンプルとしたのは、ブートストラップにおける計算時間を節約するためである。また、予測対象年の2001年からもランダムに10000サンプルを抽出して検証に用いる。

ここで、3つの変数 y , n , b を導入する。

- y はデータ収集年であり、以下の3時点を考える：1971, 1981, 1991
- n はサンプル数であり、以下の23通りを考える：100, 200, 300, 400, 500, 600, 700, 800, 900, 1000, 1500, 2000, 2500, 3000, 3500, 4000, 4500, 5000, 6000, 7000, 8000, 9000, 10000
- b はブートストラップの繰り返し回数であり200回繰り返す： $b=1, 2, \dots, 200$

まず、それぞれのデータ年 y (1971, 1981, 1991の3通り)においてサンプル数 n (100から10000の範囲の23通り)のデータを先に抽出した10000サンプルから200 ($b = 1, 2, \dots, 200$)回ランダムに復元抽出する。このとき、同じデータ年 y の b 回目の抽出において、 n が小さいサンプルは n が大きいサンプルの一部になるように抽出している。これによって y , n および b の組み合わせからなる $3 \times 23 \times 200 = 13800$ 通りのデータが生成された。

今回の分析で必要となる作業は次の通りである。

- 1時点直近モデルでは、 $y = 1991$ のデータを用いて、23の n に対してそれぞれ200回ずつ、つまり、 $23 \times 200 = 4600$ 回モデルを推定し、2001年の行動を予測する。
- 2時点更新関数モデルでは、 $y = 1971, 1991$ のデータを用いて、23の n に対してそれぞれ200回ずつ、つまり、 $23 \times 200 = 4600$ 回モデルを推定し、2001年の行動を予測する。
- 3時点更新関数モデルでは、 $y = 1971, 1981, 1991$ のデータを用いて、23の n に対してそれぞれ200回ずつ、つまり、 $23 \times 200 = 4600$ 回モデルを推定し、2001年の行動を予測する。

予測精度を2001年のデータへの対数尤度で表現する。

1991年のサンプル数 n による b 回目の抽出データにおいて、1時点直近モデルの予測精度を $L1(n, b)$ と表現する。1971, 1991年のサンプル数 n ずつ(合計 $2 \times n$ サンプル)による b 回目の抽出データにおいて、2時点更新関数モデルによる予測精度を $L2(n, b)$ と表現する。1971, 1981, 1991年のサンプル数 n ずつ(合計 $3 \times n$ サンプル)による b 回目の抽出データにおいて、3時点更新関数モデルによる予測精度を $L3(n, b)$ と表現する。

(4) 仮説検定

ここでは、1時点直近モデル、2時点更新関数モデル、3時点更新関数モデルの予測精度を統計的に検定する方法を説明する。検定は、これらの3つのモデルから2つを選ぶ組み合わせである、1時点直近モデルと2時点更新関数モデル、1時点直近モデルと3時点更新関数モデル、2時点更新関数モデルと3時点更新関数モデル、の3通りについて行う。いま、モデル g とモデル h による予測精度をそれぞれ Lg , Lh としたとき、 x_b を式(5)に示すように定義する。なお、 n_g と n_h はそれぞれモデル g と h で用いる1時点あたりのサンプル数である。ただし、 Lg と Lh は(3)節で示したように、 $L1$, $L2$, $L3$ のいずれかである。

$$x_b = Lg(n_g, b) - Lh(n_h, b) \quad (5)$$

なお、ここで総ての b ($= 1, 2, \dots, 200$)に対して良好な推定結果が得られるわけではない。特にサンプル数が小さ

い場合においてこのことは問題となる。そこで、式(5)の x_b は、 b 回目のランダム抽出のときに Lg と Lh の両方が計算されたときにのみ、定義されることとする。

x_b の意味するところは、この値が正であれば、モデル g のほうがモデル h よりも予測精度において優れているということである。

ここで、帰無仮説 H_0 と対立仮説 H_1 を下に示す。

$$H_0: x_b = 0$$

$$H_1: x_b \neq 0$$

ここで、次の z を定義する。

$$z = \frac{\bar{x}_b}{s(x_b)} \quad (6)$$

ここに、 \bar{x}_b と $s(x_b)$ はそれぞれ、 x_b の平均と標準偏差。ここで、 x_b が正規分布に従っていると仮定すると、 $z \geq 1.96$, または $z \leq -1.96$ のときにそれぞれモデル g のほうがモデル h よりも、モデル h のほうがモデル g よりも5%の有意水準で良い予測が行えることを示している。

4. 結果

ここでは、まず10000サンプルを使ったモデルの推定結果について示し、予測精度の差の統計的検定の結果を説明する。

(1) 推定結果

モデル化にあたって、男性ダミー(男性=1, 女性=0), 20歳以上ダミー(20歳以上=1, 19歳以下=0), 65歳以上ダミー(65歳以上=1, 64歳以下=0), 名古屋ダミー(名古屋市を出発地または到着地とする=1, そうではない=0)を定義した。モデルの変数の記述統計とその解釈はSanko¹⁾に示されている。

1991年の10000サンプルを用いて構築した1時点直近モデル(Sanko¹⁾の再掲), 1971年と1991年から10000サンプルずつの20000サンプルを用いて構築した2時点更新関数モデル(Sanko²⁾の再掲), 1971, 1981, 1991年から10000サンプルずつの30000サンプルを用いて構築した3時点更新関数モデル(Sanko³⁾の再掲)の推定結果を表-1に示す。本論文では以降もここでのモデル特定化を用いて分析を進める。なお、2章で述べたように費用の変数は含まれていないことに注意が必要である。2001年のデータに適用した予測精度(Log-likelihood on 2001 dataの行)は、高い順に3時点更新関数モデル, 2時点更新関数モデル, 1時点直近モデルの順になった。このことは、直近の時

表—1 モデルの推定結果

Variables	Most recent data model		Updating function models			
	1991		1971/1991		1971/1981/1991	
	Est.	t-stat.	Est.	t-stat.	Est.	t-stat.
<i>Base parameters (α_i, β_{ik})</i>						
Constant (B)	-0.638	-8.98	0.856	6.99	0.807	6.61
Constant (C)	0.301	1.96	-2.54	-9.35	-2.57	-9.61
Travel time [hr]	-1.59	-15.71	0.334	1.71	0.0094	0.04
Male dummy (R)	0.812	7.53	0.353	2.12	0.216	1.27
Male dummy (C)	1.78	17.30	2.15	13.15	2.03	12.29
20 years old or older dummy (C)	0.776	5.18	1.02	3.98	1.03	4.03
65 years old or older dummy (B)	1.33	5.59	2.47	5.18	1.96	4.34
Nagoya dummy (C)	-2.18	-37.81	-0.118	-1.11	-0.260	-2.44
<i>Historically changing parameters (α_{dt}, β_{dik})</i>						
Constant (B)	—	—	-4.22	-8.67	-4.36	-8.78
Constant (C)	—	—	8.02	7.53	8.21	7.62
Travel time [hr]	—	—	-5.44	-7.38	-5.21	-5.10
Male dummy (R)	—	—	1.29	1.85	2.02	2.80
Male dummy (C)	—	—	-1.04	-1.53	-0.223	-0.32
20 years old or older dummy (C)	—	—	-0.677	-0.66	-0.830	-0.80
65 years old or older dummy (B)	—	—	-3.24	-1.83	-1.64	-0.93
Nagoya dummy (C)	—	—	-5.82	-14.23	-5.68	-13.41
N		10000		20000		30000
L(β)		-5300.58		-13077.44		-19129.57
L(0)		-8398.85		-17347.11		-25940.98
Adj rho-squared		0.368		0.245		0.262
Log-likelihood on 2001 data		-4801.79		-4764.18		-4749.35

Note: (R), (B), and (C) notations refer to alternative-specific variables for rail, bus, and car, respectively. Variables without notations are generic. The most recent data model is a special case of the updating function models, where historically changing parameters are fixed to zeros.

点に加えて過去の時点のデータを用いるほうが良いことを示している。また、1971年と1991年の2時点を用いるよりも、1971、1981、1991年の3時点を用いるほうが良いことも示している。

参考までに、1971、1981、1991年のうちの1時点のデータを用いたモデルでは、1991年のデータを用いたモデルが最も予測精度が優れていた¹⁾。また、1971、1981、1991年のうちの2時点のデータを用いたモデルでは、1971/1991年のデータを用いたモデルが最も予測精度が優れていた⁶⁾。つまり、ここでは3時点更新関数モデルを、最も予測精度の優れている2時点更新関数モデルと最も予測精度の優れている1時点モデルと比較している。

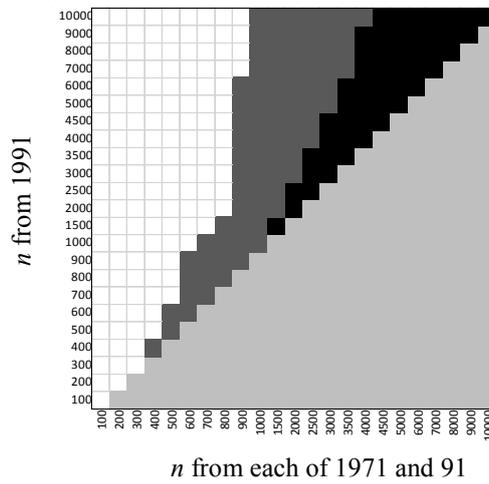
(2) 予測精度の差の検定

検定の結果を図—1に示す。図は3つのパネルから構成されており、高頻度小規模データと、低頻度大規模データを用いたモデルを比較している。具体的には、パネル(a)は2時点更新関数モデルと1時点直近モデル、パネル(b)は3時点更新関数モデルと1時点直近モデル、パネル(c)は3時点更新関数モデルと2時点更新関数モデル、を比較している。

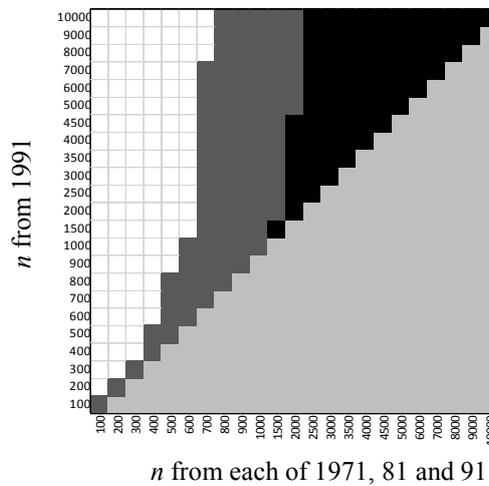
これらの検定には式(5)を用いているが、モデルgに相当するのが、高頻度小規模データを用いたモデルであり、モデルhに相当するのが、低頻度大規模データを用いたモデルである。つまり、式(5)はパネル(a)、(b)、(c)のそれぞれにおいて、 $L_2 - L_1$ 、 $L_3 - L_1$ 、 $L_3 - L_2$ のように表現される。

パネルの横軸には、高頻度小規模データを用いたモデルの各時点のサンプル数を示し、縦軸には、低頻度大規模データを用いたモデルの各時点のサンプル数を示している。なお、各パネルの右下の薄い灰色で塗りつぶしてある領域は、高頻度小規模データの各時点のサンプル数が、低頻度大規模データの各時点のサンプル数よりも大きく、本研究の設定と合致しないので、興味の対象外である。

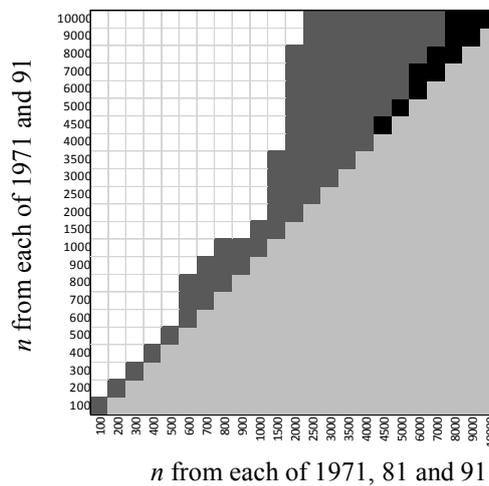
パネルの黒色で塗りつぶされている領域は $z \geq 1.96$ となり、高頻度小規模データを用いたモデルのほうが、低頻度大規模データを用いたモデルよりも5%の有意水準で良い予測を行えることを示している。また、濃い灰色で塗りつぶされている部分は $0 < z < 1.96$ となり、高頻度小規模データを用いたモデルのほうが、低頻度大規模データを用いたモデルよりも有意ではないものの良い予測を行えることを示している。



(a) 2 時点更新関数モデルと 1 時点直近モデル



(b) 3 時点更新関数モデルと 1 時点直近モデル



(c) 3 時点更新関数モデルと 2 時点更新関数モデル

注：横軸に示した、高頻度小規模データを用いたモデルのほうが、縦軸に示した低頻度大規模データを用いたモデルよりも良い場合に着色。黒は 5%有意、濃い灰色は 5%有意ではない。薄い灰色は、横軸に示したモデルのほうが時点あたりのサンプル数が大きく、今回の興味の対象外。

図一1 検定の結果

まず、3つのパネルのいずれにおいても、高頻度小規模データを用いたモデルのほうが、低頻度大規模データを用いたモデルよりも、有意に良い予測を行える場合がある。パネル(a)では1991年の10000サンプルよりも1971/1991年の4500サンプルずつのほうが有意に良い予測を行える。パネル(b)では1991年の10000サンプルよりも1971/1981/1991年の2500サンプルずつ、パネル(c)では1971/1991年の10000サンプルずつよりも1971/1981/1991年の8000サンプルずつという結果になった。低頻度大規模データを用いたモデルのサンプル数が10000以外の場合も含めると、パネル(a)では2時点から1500~4500サンプルずつ、パネル(b)では3時点から1500~2500サンプルずつ、パネル(c)では3時点から4500~8000サンプルずつあれば、低頻度大規模データを用いたモデルよりも統計的に有意に良い予測を行える。

次に、高頻度小規模データを用いたモデルのほうが、低頻度大規模データを用いたモデルよりも、有意ではないが良い予測を行える場合を検討する。パネル(a)では1991年の10000サンプルよりも1971/1991年の1000サンプルずつのほうが良い予測を行える。パネル(b)では1991年の10000サンプルよりも1971/1981/1991年の800サンプルずつ、パネル(c)では1971/1991年の10000サンプルずつよりも1971/1981/1991年の2500サンプルずつという結果になった。低頻度大規模データを用いたモデルのサンプル数が10000以外の場合も含めると、パネル(a)では2時点から400~1000サンプルずつ、パネル(b)では3時点から100~800サンプルずつ、パネル(c)では3時点から100~2500サンプルずつあれば、低頻度大規模データを用いたモデルよりも統計的に有意ではないものの良い予測を行える。

一方、低頻度大規模データを用いたモデルのほうが、高頻度小規模データを用いたモデルよりも統計的に有意に良い予測を行えることは、いかなるサンプル数の組み合わせにおいても存在しなかった。つまり、 $z \leq -1.96$ とはならなかった。これは、1991年の10000サンプルを用いたモデルが、1971/1991年の100サンプルずつの合計200サンプルを用いた更新関数モデルや、1971/1981/1991年の100サンプルずつの合計300サンプルを用いた更新関数モデルよりも有意に良い予測を行えないということである。また、1971/1991年の10000サンプルずつの合計20000サンプルを用いた更新関数モデルが、1971/1981/1991年の100サンプルずつの合計300サンプルを用いた更新関数モデルよりも有意に良い予測を行えないということである。

このことは、調査規模を大きく削減できる可能性を示唆している。統計的に有意に予測精度が改善されるという基準からは、1991年のサンプル数が10000の場合では、2時点のデータを用いることで調査規模を45%に削減可能であり、3時点のデータを用いることで調査規模を25%に削減可能である。また、1971年と1991年のサン

ル数がそれぞれ10000の場合では、3時点のデータを用いることで調査規模を80%に削減可能である。同様に、統計的に有意ではないものの予測精度が改善されるという基準からは、調査規模をそれぞれ、10%、8%、25%に削減可能である。もちろん、これは将来の1人当たりGDPの予測が正しいという条件付であるため、この不確実性に関する感度分析をSanko²⁾同様にを行う必要がある。

5. おわりに

本研究では、複数時点からデータが得られているが、直近の1時点のデータのみしか用いないという現在多くの場合で採用されているアプローチに対し、過去のデータも用いることで各時点のサンプル数を減らすことができるかを検討した。分析は、中京都市圏の交通手段選択行動を対象に行い、1991年のデータを用いた1時点直近モデル、1971年と1991年のデータを用いた2時点更新関数モデル、1971、1981、1991年のデータを用いた3時点更新関数モデルを構築し、2001年の予測精度を比較した。更新関数モデルでは、パラメータを1人当たりGDPの関数で表現した。高頻度小規模データを用いたモデルと、低頻度大規模データを用いたモデルの予測精度を比較した。

得られた知見を示す。

- 高頻度小規模データを用いたモデルのほうが、低頻度大規模データを用いたモデルよりも統計的に有意に良い予測を行える場合があることが示された。統計的に有意に良い予測が行えることを基準とするなら、1991年のサンプル数が10000の場合では、2時点のデータを用いることで調査規模を45%に削減可能であり、3時点のデータを用いることで調査規模を25%に削減可能な場合がある。また、1971年と1991年のサンプル数がそれぞれ10000の場合では、3時点のデータを用いることで調査規模を80%に削減可能な場合がある。
- 高頻度小規模データを用いたモデルのほうが、低頻度大規模データを用いたモデルよりも統計的に有意ではないものの良い予測を行える場合があることも示された。統計的に有意ではないものの予測精度が改善されることを基準とするなら、1991年のサンプル数が10000の場合では、2時点のデータを用いることで調査規模を10%に削減可能であり、3時点のデータを用いることで調査規模を8%に削減可能な場合がある。また、1971年と1991年のサンプル数がそれぞれ10000の場合では、3時点のデータを用いることで調査規模を25%に削減可能な場合がある。
- 低頻度大規模データを用いたモデルのほうが、高頻度

小規模データを用いたモデルよりも統計的に有意に良い予測を行えることは、いかなるサンプル数の組み合わせにおいても存在しなかった。

今後の課題は次の通りである。

- 今回の知見は、将来の1人当たりGDPに真値を与えた場合に得られたものである。実際には将来の1人当たりGDPの予測には不確実性が伴うことから、1人当たりGDPの予測に関する感度分析が必要である。
- 今回の知見を活かして、実際の調査費用のレベルで検討を行う。

このような研究により、効率的な調査設計を行うことができれば、費用や時間の制約が多い近年の交通調査において貢献が大きいと考える。

謝辞：本研究はJSPS科研費25380564, 16K03931の助成を受けている。データ使用に関して、中京都市圏総合都市交通計画協議会と名古屋大学森川研究室の支援を受けた。

参考文献

- 1) Sanko, N.: Travel demand forecasts improved by using cross-sectional data from multiple time points, *Transportation*, Vol. 41, No. 4, pp. 673–695, 2014.
- 2) Sanko, N.: Travel demand forecasts improved by using

cross-sectional data from multiple time points: enhancing their quality by linkage to gross domestic product, *Transportation*, Forthcoming.

- 3) Sanko, N.: Factors affecting temporal changes in mode choice model parameters, *Transportation Planning and Technology*, Vol. 39, No. 7, pp. 641–652, 2016.
- 4) Sanko, N.: Criteria for selecting model updating methods for better temporal transferability, *Compendium of Papers of the 95th Annual Meeting of the Transportation Research Board*, Washington D.C., U.S.A., Jan. 2016.
- 5) Sanko, N.: A novel model updating method: updating function model with gross domestic product per capita, *Compendium of Papers of the 96th Annual Meeting of the Transportation Research Board*, Washington D.C., U.S.A., Jan. 2017.
- 6) Sanko, N.: Comparing travel demand forecasts between models with larger data from single time point and models with smaller data from two time points, *paper presented at the Fifth International Choice Modelling Conference*, Cape Town, South Africa, Apr. 2017.
- 7) Efron, B. and Tibshirani, R.J.: An Introduction to the Bootstrap. Chapman & Hall, London, 1993.

(2017. 4. 28 受付)

TRADE-OFF BETWEEN SURVEY FREQUENCY AND SAMPLE SIZE FOR FORECASTING TRAVEL DEMAND: A PRELIMINARY STUDY USING CROSS- SECTIONAL DATA FROM THREE TIME POINTS

Nobuhiro SANKO