ダイナミックパークアンドライド施策における利用者の所要時間予測学習についての実験的検討

葛西　誠[1]・上杉　亮[2]・高沢 翔平[3]・寺部 慎太郎[4]・内山 久雄[5]

[1]正会員　東京理科大学理工学部土木工学科（〒278-8510 千葉県野田市山崎2641）
E-mail: kasai@rs.noda.ac.jp

[2]非会員　東日本高速道路株式会社東北支社 盛岡管理事務所（〒020-0841 岩手県盛岡市羽場11地割66）
[3]非会員　東京理科大学大学院 理工学研究科 土木工学専攻（〒278-8510 千葉県野田市山崎2641）
E-mail: j7610625@ed.noda.ac.jp

[4]正会員　東京理科大学理工学部土木工学科（〒278-8510 千葉県野田市山崎2641）
E-mail: terabe@rs.noda.ac.jp

[5]フェロー員　東京理科大学理工学部土木工学科（〒278-8510 千葉県野田市山崎2641）
E-mail: uchiyama@rs.noda.ac.jp

高速道路所要時間の増大時に高速道路から鉄道へ緊急避難するDynamic Park & Rideは，意識調査によれば利用者の受容度は高いものの普及には至っていない．相対的に高い信頼性を持つ鉄道への乗換えを利用者に経験させ学習させることが効果的と考えられるものの，所要時間信頼性に大きな差がある高速道路と鉄道との機関選択を対象とした所要時間学習過程は研究の蓄積がなく，効果の予測には至らない．本研究は室内において交通機関選択反復実験を行ない，所要時間予測の学習過程について実験的検討を行なうことを目的とする．複数の離散選択行動モデルを構築し比較検討したところ，直近過去に経験した所要時間は経路選択に有意な変数であることのみならず，影響力は小さいながら比較的過去の経験も有意な説明変数であることなど，いくつかの興味深い結果を得ている．

Key Words : *learning process, decision making, dynamic park and ride, TDM, travel time reliability*

1. はじめに

道路交通マネジメント(TDM)の一種として，高速道路と都市鉄道の連携による高速道路渋滞緩和策であるDynamic Park and Ride[1] (以下DP&R)が注目されてから久しい．”Dynamic”の含意は，時々刻々と変化する高速道路の所要時間に対応して，その瞬間の利用者の合理的な交通行動をとれるよう担保することにある．例えば，名古屋での施策想定例や東京首都圏縁辺部の柏DP&R構想[2]（**図-1**）にみるように，高速道路の所要時間が交通事故等の突発事象によって急激に増大するとき，並行する鉄道へ乗換えを可能にし，目的地までの定時性を確保する思想である．

この概念は比較的古くから提唱されているものの，本格導入にはまだ道半ばといったところであろう．この原因としていくつかの可能性が指摘できるが，1つには，旅客に，トリップ中の交通手段変更を求めるという全く新しい形態のマネジメント策であるから，施策供用初期段階における乗換抵抗が大きく，旅客に敬遠され普及に時間を要することが想定され，DP&R施策の利害関係者の合意を得ることが難しいことが挙げられよう．すなわち，DP&R普及促進策を立案する上で，利用者が正確なサービス水準を認知していく過程がどのようであるかを知っておく必要があることを意味する．

DP&R施策は一般に所要時間も大きくかつ所要時間信頼性の劣る高速道路から，所要時間も短くかつ所要時間信頼性の高い鉄道への乗換えを促すものであるから，利用者が合理的な判断をする限り，多くの利用を期待できよう．事実，過去の意識（Stated Preference）調査によれば，この種の施策に対する利用者の受容性は高いことが確認されている[2,3]が，これはいわば完全情報下での選択を聞いているにすぎない．したがって，施策供用初期の利用者が鉄道の所要時間信頼性の高さを実感していない段階での選択行動，および利用者が高速道路と鉄道のサ

ービスレベルを知っていく過程でどのような選択を行なうかは明らかではない．

本研究は，DP&Rを対象として，室内における交通機関選択行動反復実験を行なう．ここで得られたデータから，3種類の異なる統計手法によって学習効果を探る：1)横断面分析，2)直前の経験を反映させた縦断分析，3)直前のみならず比較的前の経験をも説明変数として導入した縦断分析，である．

2. 交通工学における学習過程の扱い

交通工学分野においては比較的古くから，経路選択または交通機関選択において学習過程が無視し得ないことが指摘されており，例えばHorowitz [4]がそれである．経路選択行動において学習過程に着目することの重要性を指摘する論文[5)-8)]は1990年代を中心に多くみられ，一定の成果を上げている．自動車交通において，利用経路の所要時間を事前には知らずとも複数回の利用によって所要時間を認知し，その後の経路選択に反映させていることが実験により示されている．さらには，利用しなかった経路の所要時間情報を利用者が提示されると学習が早くなる傾向なども指摘され，情報提供による混雑緩和の可能性を示唆するものであった．

一方で，人間の学習効果には負の側面があることも指摘されるようになる．利用者の選択が「誤った認知」に固定されてしまうことによる非効率性が存在すること[8)]は，学習によって必ずしも正確にサービスレベルを認知するとは限らないことを意味する．同時に，誤った認知を是正するための方策も，学習モデルにしたがって適切に検討されねばならないことが言及されている．いずれにしても，学習過程の重要さを裏付けるものである．

近年では，所要時間不確実性下での経路選択行動が焦点となっており，Ben-Elia & Shiftan[9)]の仕事がその代表例である．これは理論的検討の精緻さが特色となっており，完全情報下にない利用者の行動の扱いとして，期待効用理論，機械学習理論の適用可否を厳密に論じた上で，Mixed Logit Modelを基本とし学習効果について検討がなさている．しかし，学習過程そのものの構造については明確でない部分が残されている．例えばどの程度過去の経験まで影響するか，その重みはどの程度であるか等は様々考えられるものの言及されていない．さらには，必ずしも具体的な経路を想定した実験ではなく，DP&RのようなTDM施策に応用な可能な成果とは言い難い．

したがって，本研究は，実験設計に際し，所要時間の与え方を実際に想定されるDP&R施策を参考にすること，複数の学習過程を比較検討することで，DP&R促進施策の一助とすることを目指す．

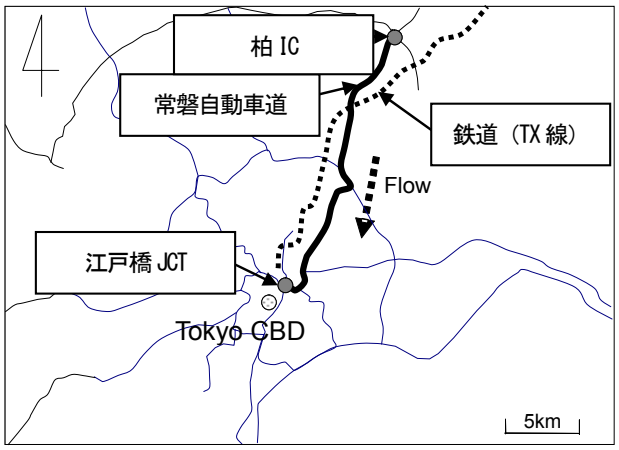

図-1　施策の想定例

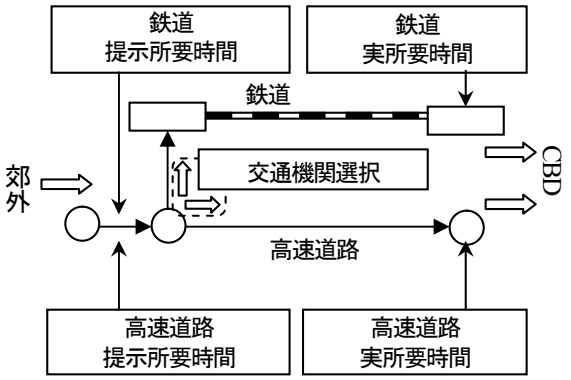

図-2　実験で提示する所要時間の種類

3. 反復交通機関選択実験

被験者の属性等詳細は割愛するが，解釈の上で重要と思われる情報を以下に示す．被験者は50名（男性：34名，女性：16名）の第1種普通運転免許保有者である．年齢層は10代から60代まで幅広いが，20代が27名と約半数を占める．運転頻度について月2～3回以上の被験者が26名おり，概ね日常的に自動車を利用する者が半数を占めていると言える．

(1) 室内実験の流れ

室内実験ではあるが，所要時間の設定は柏DP&Rを模擬する（図-2）．

被験者には茨城県南部から東京都区内秋葉原付近への移動を想定してもらう．出発時には自動車利用であり常磐自動車道から三郷JCTを経由し首都高速6号線にて目的地へ到達する予定とする．常磐自動車道柏IC手前を走行中に，1)首都高速道路へそのまま流入する場合（これを「高速利用」と呼ぶ），2)つくばエクスプレスに乗り換える場合（「鉄道利用」と呼ぶ）の所要時間，および費用（通行料金または運賃，駐車場料金等を含む）が被験者に提示される．この提示される所要時間は交通情報

表-1 被験者に提示するシナリオ

	シナリオ	提示所要時間[分]	実所要時間[min]	費用[yen]
高速道路	E1	30	実観測データ（車両感知器データに基づく値）	1,200
	E2	40		
		…		
	E11	120		
鉄道	R1	60	N(60,10)	1,650
	R2	65	N(70,10)	
		…	…	
	R5	80	N(80,10)	

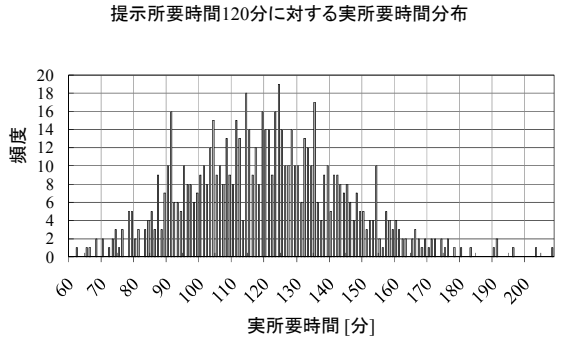

図-3 提示所要時間 120 分のときの実所要時間の分布

として情報板やラジオ等から提供されるものと同様に，車両感知器にて瞬間値に計測されるものとする．以降，これを「提示所要時間」呼ぶ．

被験者には，この提示所要時間を参考に，それぞれの選択肢について自らの予想する所要時間「予想所要時間」を回答してもらう．さらに，「高速利用」か「鉄道利用」かを回答してもらう．

選択後，被験者に到着時刻を知らせ，所要時間を被験者各自に計算させる．選択しなかった方の到着時刻についても提示し，事後的に見てどちらがより早く到着できたのかを知ることとなる．

一連の経路選択行動を各被験者に対して10回行なう．

⑵ 所要時間の与え方

一回の実験において，被験者には**表-1**に示すシナリオのうちいずれか1つをランダムに体験してもらう．高速道路の「提示所要時間」としては30分，40分，…，120分の11通り設定し，乱数に従っていずれかのシナリオを抽出する．鉄道の「提示所要時間」についても同様に60分，65分，…，80分の5通りのシナリオからランダムに抽出する．高速道路と鉄道の「提示所要時間」は独立とする．すなわち，1回の実験において被験者に提示される所要時間情報の組合せは11×5=55通り存在する．

選択の事前に提示される「提示所要時間」に対して，事後的に示される「実所要時間」は異なるものとする．高速道路に関しては，首都高速6号線三郷JCT～江戸橋JCTで2004年1年間に観測された車両感知器データを用い，「提示所要時間」としては，いわゆるいわゆる「瞬間値」を，「実所要時間」としては，「タイムスライス値」を対応させる．これは現状の所要時間提供方法を反映させた設定であり，高速道路流入前に運転者が知る所要時間，すなわち道路交通情報として入手できる所要時間は，あくまで瞬間的に計測された所要時間であり，実際に移動に要した時間は一般に異なる．これを模擬するものである．例えば，「提示所要時間」が120分であった場合の「実所要時間」の分布は**図-3**のように示される．

鉄道に関しては，「実所要時間」は「提示所要時間」を平均値，標準偏差を10分とする正規乱数を対応させる．

利用者は選択経路および選択しなかった経路の所要時間の両方を知ることができるとする．

整理すると，利用者は高速道路利用と鉄道利用の2種類の経路のそれぞれに対して，3種類の所要時間を持つことになる：1)経路選択の前に提示される「提示所要時間」，2)経路選択の前に，被験者が提示所要時間および以前の実験回の経験に基づいて予測する「予測所要時間」，3)経路選択の後に提示される「実所要時間」である．

4. 統計モデルによる学習効果の検証

過去の経験が現在の選択に影響を及ぼすか否か，3種の分析により統計的に検証する．1つは横断面分析，2つめとして，直近過去の経験を説明変数として導入する縦断分析，3つめとして，比較的過去の経験を考慮に入れた縦断分析，である．

これらはいわゆるランダム効用理論に基づく離散選択モデルを適用するが，3章の方法によって得られたデータを適用する方法の違いで3種類に分類されるのである．**図-4**はこれを図化したものである．

⑴ 横断面分析

実験回毎に，Logit型の離散選択モデルを適用し，パラメータおよび*t*値の時系列変化を見てみよう．説明変数として，「提示所要時間」「予測所要時間」「鉄道利用選択肢固有ダミー」とする．確定効用項および選択確率を書き下すと以下のようになる．

$$\begin{cases} V_{n1t} = apt_t Xpt_{n1t} + aet_t Xet_{n1t} + a_1, \\ V_{n2t} = apt_t Xpt_{n2t} + aet_t Xet_{n2t}, \end{cases} \quad (1)$$

$$p_{n1t} = 1/\{1-\exp(V_{n2t} - V_{n1t})\}, \quad (2)$$

表-2　変数表

鉄道選択	δ_{n1t}
高速道路選択	δ_{n2t}
鉄道提示所要時間	Xpt_{n1t}
高速道路提示所要時間	Xpt_{n2t}
鉄道予測所要時間	Xet_{n1t}
高速道路予測所要時間	Xet_{n2t}
鉄道実所要時間	Xat_{n1t}
高速道路実所要時間	Xat_{n2t}
鉄道における前回の予測所要時間と実所要時間の差	$Xdeat_{n1t-1} = Xat_{n1t-1} - Xet_{n1t-1}$
高速道路における前回の予測所要時間と実所要時間の差	$Xdeat_{n2t-1} = Xat_{n2t-1} - Xet_{n2t-1}$
鉄道における前回の提示所要時間と実所要時間の差	$Xdpat_{n1t-1} = Xa_{n1t-1} - Xp_{n1t-1}$
高速道路における前回の提示所要時間と実所要時間の差	$Xdpat_{n2t-1} = Xa_{n2t-1} - Xp_{n2t-1}$

本来は，母集団が異なるので，パラメータ推定を回数毎に分離した場合はパラメータ値と t 値等の統計量を比較することは統計的に意味のないことであるが，被験者に提示する所要時間生成基準が時間とともに変化しない（すなわち，同じ所要時間の集合から同一のルールにて発生させている）ため，比較が可能であるとして考察してみよう．

図-5 に t 値の時系列変化を示す．横軸が実験回を示し，縦軸が t 値である．第 1 回目選択では「提示所要時間」「予測所要時間」ともに同一の符号，ほぼ同様の有意水準であるが，第 3 回目以降「提示所要時間」の符号が逆転し，かつ 10%有意水準で帰無仮説 $H_0 : apt_t = 0$ を棄却できない．一方で「予測所要時間」は第 4 回目以降，10%有意水準を確保し，実験回を増すごとに増加傾向にある．符号条件も矛盾がない．

このことは被験者が経験を積むにつれて「提示所要時間」を重視しなくなっていくことを意味する．また予測所要時間が有意であるということは，何らかの手掛かりを元に被験者が所要時間の予測をしていること，予測値を重視するようになっていくことを意味する．繰り返し実験による学習効果が発現していることを暗示する．

⑵ 直近の経験を反映させた分析

学習効果をより明確にするため，前回の実験回の変量を採用した離散選択行動モデルを構築してみよう．

数回の試行錯誤により，現在の「提示所要時間」，現在の「予測所要時間」に加えて，「前回の『提示所要時間』」「前回の『実所要時間』」「前回の『予測所要時間』と『実所要時間』の差」を説明変数とし，全実験回のデータをプールしてパラメータ推定を行うと，解釈可

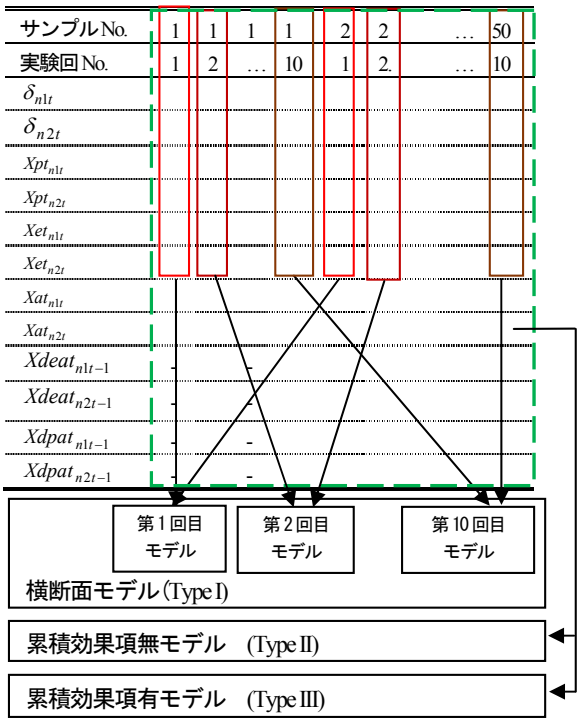

図-4　3 種類のモデリングとデータの用い方

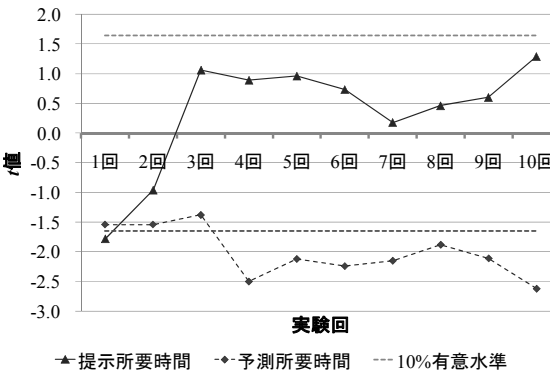

図-5　Type-I モデルにおける t 値の時系列変化

能なモデルとして**表-3**に示す結果が得られる．

なお確定効用項および選択確率項を書き下すと以下の通りとなる．

$$\begin{cases} V_{n1t} = aptXpt_{n1t} + aetXet_{n1t} \\ \qquad + apt_{-1}Xpt_{n1t-1} + aat_{-1}Xat_{n1t-1} \\ \qquad + adat_{-1}Xdeat_{n1t-1} + a_1, \\ V_{n2t} = aptXpt_{n2t} + aetXet_{n2t} \\ \qquad + apt_{-1}Xpt_{n2t-1} + aat_{-1}Xat_{n2t-1} \\ \qquad + adat_{-1}Xdeat_{n2t-1}, \end{cases} \tag{3}$$

$$p_{n1t} = 1/\{1 - \exp(V_{n2t} - V_{n1t})\}. \tag{4}$$

現在の「予測所要時間」は式(1)のTypeIのモデル同様有意な説明変数であるが，前回の実所要時間と予測所要時間との差もt値は10%水準を達成しないが比較的高い値

表-3　累積効果項無パラメータ推定結果(Type II)

説明変数	推定値	t値
$Xpt_{\cdot\cdot t}$：提供所要時間[分]	0.0253	1.56
$Xet_{\cdot\cdot t}$：予測所要時間[分]	-0.117	-7.18**
$Xpt_{\cdot\cdot t-1}$：前回の提供所要時間[分]	-0.0110	-0.694
$Xat_{\cdot\cdot t-1}$：前回の実所要時間[分]	0.0117	0.803
$Xdeat_{\cdot t-1}$：前回の実所要時間と予測所要時間との差[分]	-0.0149	-1.153
a_1：鉄道利用 選択肢固有ダミー	-2.144	-7.78**
的中率	0.907	
尤度比	0.668	
サンプル数	450	

* 5%有意

** 1%有意

を示しており，何らかの学習効果を示している可能性がある．

(3) 比較的過去の経験を反映させた縦断分析

直近過去の影響のみならず，比較的過去の経験も活用して選択していると仮定しよう．ただし，どの程度過去の経験がどの程度影響しているかは自明でない問題である．本研究では，この点を深く議論してみよう．

現在に比較的近い経験ほど大きな影響をおよぼしている，との考えは自然であろう．例えばBen-Elia & Shiftan[9]では，過去の「選択」の累積の調和平均をとって説明変数としている．過去になればなるほど現在への影響が小さくなる（すなわち減衰する）と考える．減衰型を満たす型として，他には指数減衰型があり得るであろう．

例えば，「予測所要時間と実所要時間との差の累積」は，調和平均型の場合，次のように与えられる：

$$Cdeat_{nit} = \sum_{k=2}^{t-1} \frac{Xdeat_{nik-1}}{t-k} \Bigg/ \sum_{k=2}^{t-1} \frac{1}{t-k}. \tag{5}$$

同様に指数減衰型は次のように与えることができる:

$$Cdeat_{nit} = \sum_{k=2}^{t-1} \exp\{-\alpha_2(t-k)\} Xdeat_{nik-1} \Bigg/ \sum_{k=2}^{t-1} \exp\{-\alpha_2(t-k)\}. \tag{6}$$

ある実験回の確定効用項は，当該選択肢の「提示所要時間」，および上述の「累積選択項」，「予測所要時間と実所要時間との差の累積」「提示所要時間と実所要時間と実所要時間との差の累積」および「鉄道選択肢固有ダミー」である．

$$V_{n1t} = aptXpt_{n1t} + accCc_{n1t} + acdeatCdea\,t_{n1t} + acdpatCdpa\,t_{n1t} + a_1, \tag{7}$$

$$V_{n2t} = aptXpt_{n2t} + accCc_{n2t} + acdeatCdea\,t_{n2t} + acdpatCdpa\,t_{n2t}. \tag{8}$$

$$p_{n1t} = 1/\{1-\exp(V_{n2t} - V_{n1t})\}. \tag{9}$$

累積項に調和平均型を採用したものををModel-H1，指数減衰項を用いたものをModel-E1およびModel-E2とする．Model-E1とModel-E2との違いは，指数減衰の減衰速さであり，相対的にModel-E1の方が減衰が遅く，比較的過去の影響を受けていると仮定する．具体にはModel-E1は $(\alpha_1,\alpha_2)=(0.01,0.01)$ ，Model-E2は $(\alpha_1,\alpha_2)=(0.05,0.1)$ と設定する．本来，これら α_1,α_2 も推定すべきパラメータではあるが，パイロットスタディとして固定し振る舞いを探ることとする．

表-4にパラメータ推定結果を示す．3種のモデルはそれぞれ尤度比が高く十分な説明力を有すると判断される．したがって本節で想定しているような減衰型の学習効果は一定程度実情を表現していると言えよう．

個々のモデルを比較すれば，Model-H1とModel-E2では尤度比およびAICに大差はなく，わずかにModel-H1が良い程度である．これに対してModel-E1は他2つに対して尤度比およびAICの観点からは比較的説明力が低い．これは極端に古い過去の影響はさほど受けないことを意味しているものと思われる．

次に説明変数に着目しよう．3種のモデルとも累積選択項はt値によれば高度に有意であり，符号も矛盾はない．これは，ある選択肢について，選択回数が多いほどその選択肢を選択する傾向にあることを意味する．Model-H1およびModel-E2においては，予測所要時間と実所要時間との差の累積はそれぞれ1%有意，5%有意であり，かつ符号条件も直観的考察と矛盾しない結果である．これは，予測所要時間が実所要時間よりも小さい交通機関を選好するようになることを意味している．一方で，提示所要時間と実所要時間の差の累積はModel-H1とModel-E2ともに5%有意であるものの符号が逆転している．そのまま解釈すれば，提示所要時間が実所要時間より長い交通機関を選好するようになることを意味し，直観に反する結果である．

現段階ではこれが何を意味するか理解することはなかなか困難であるが，次の可能性を指摘しておきたい．すなわち，Type-Iのモデルの知見と合わせて考察すれば，提示所要時間をさほど重視せず自身の予測所要時間を選択に際して重要視するようになるにつれて，「偽」の相関が選択結果と「提示所要時間と実所要時間との差の累積」との間に見られるようになった，との解釈である．

表-4　累積効果項有モデル(Type-III)のパラメータ推定結果

	Model-H1		Model-E1		Model-E2	
説明変数	推定値	*t*値	推定値	*t*値	推定値	*t*値
Xpt：提示所要時間[分]	-0.0927	-3.86**	-0.0995	-8.55**	-0.105	-4.14**
Cc：累積選択項	11.9	4.93**	4.14	7.44**	12.4	4.68**
Cdeat：予測所要時間と実所要時間との差の累積[分]	-0.111	-2.67**	-0.0238	-1.14	-0.103	-2.28*
Cdpat：提示所要時間と実所要時間との差の累積[分]	0.100	2.42*	0.0266	0.959	0.138	2.54*
a_1：鉄道選択肢固有ダミー	-0.280	-0.292	-1.44	-5.24**	-0.659	-1.40
的中率	0.982		0.913		0.980	
尤度比	0.922		0.701		0.912	
AIC	52.5		191		58.3	
サンプル数	450		450		450	

* 5%有意
** 1%有意

5. おわりに

本稿ではDP&R施策において利用者が高速道路と鉄道の所要時間を認知していく過程を，室内における繰り返し経路選択実験によって明らかにすることを試みた．得られた知見は下記のように要約できる：1)提示所要時間，すなわち，所要時間情報として現在提供されている所要時間瞬時値よりも利用者自身の予測する所要時間に重きを置いて経路選択を行なっていることが推認できる，2)直近過去の経験のみならず，比較的過去の経験も経路選択に際して有効であると推認できること，3)またその有効な変量とは，利用者自身が経路選択の前に予測した所要時間と事後的に経験した実所要時間の乖離であること，4)ただし，利用者自身が多く選択してきた経路を再び選択する傾向にあること，である．

上記のうち，4)のように既往の知見[9]と整合するものもあるが，3)のようにこれまで言及のなかった傾向も見受けられることは興味深く，選択行動における学習過程の研究の余地はまだ残されていることを示唆している．このような学習効果モデルを用いることで，DP&Rの普及のための情報提供方法を検討することができよう．例えば，現状では提供される所要時間は瞬間的に計測される値であるが，何らかの方法で予測された値を用いるべきであるのか，さらには意図的に長めの所要時間を提示することなど様々な方法が考えられる．

所要時間信頼性との関わりでは，次のことを述べたい．利用者の認知する不確実性は，本論文で扱ったような学習過程モデルに反映するとの考えである．所要時間変動の非定常性は以前より指摘されているが，非定常下での選択行動にこそ，利用者の覚える不確実性が現れるだろう．この選択行動は，利用者がそれまでに経験した手痛い失敗，すなわち経路選択に対する後悔によって左右されており，したがって学習過程を考慮した選択行動モデルによって利用者の知覚する所要時間信頼性を良く近似できるのではないかとの考えである．学習過程のモデリングが所要時間信頼性研究に寄与することを期待する．

参考文献

1) 中村英樹, 平松達仁, 内海泰輔: マイクロ交通流シミュレーションと手段選択モデルを用いたダイナミック・パーク・アンド・ライドの評価, 土木計画学研究・講演集, Vol.23, No.1, pp.587-590, 2000.
2) 内山久雄, 高橋浩一, 山下良久, 小長井教宏, 貞清一浩: 都市間高速道路と鉄道新線の連携による首都高速道路の混雑解消施策の可能性, 第 4 回 ITS シンポジウム 2005, pp.199-204, 2005.
3) 六反雅登, 松尾誠太郎, 葛西誠, 内山久雄, 寺部慎太郎, 貞清一浩: 都市間高速道路と鉄道新線の連携によるパーク＆ライドの実現可能性の検討, 第 6 回 ITS シンポジウム 2007, 6pages, 2007.
4) Horowitz, J. L. : The stability of stochastic equilibrium in a two-link transportation network, *Transportation Research Part B*, Vol.18, pp.13-28, 1984.
5) Iida, Y., Akiyama, T. and Uchida, T. : Experimental analysis of dynamic route choice behavior, *Transportation Research Part B*, Vol.26, pp. 17-32, 1992.
6) 飯田恭敬, 内田敬, 宇野伸宏: 交通情報の効果を考慮した経路選択行動の動的分析, 土木学会論文集 IV, No.470／IV-20, pp.77-86, 1993.
7) 中山晶一朗, 藤井聡, 北村隆一: ドライバーの学習を考慮した道路交通の動的解析:複雑系としての道路交通システム解析に向けて, 土木計画学研究・論文集, Vol.16, pp.753-761, 1999.
8) 藤井聡, 中山晶一朗, 北村隆一: 習慣解凍と交通政策: 道路交通シミュレーションによる考察, No.667／IV-50, pp.85-101, 2001.
9) Ben-Elia, E. and Shiftan, Y. : Which road do I take? A learning-based model of route-choice behavior with real-time, *Transportation Research Part A*, Vol.44, pp.249-264, 2010.