

貨物車走行経路の記述モデルにおける価値関数の適用に関する研究*

Applying Value Function to Descriptive Model for Route Choice of Freight Trucks *

小川翔吾**・安東直紀***・中村有克****・山田忠史*****・谷口栄一*****

By Shogo OGAWA**・Naoki ANDO***・

Yuki NAKAMURA***・Tadashi YAMADA****・Eiichi TANIGUCHI*****

1. はじめに

近年、都市部への人口集中や自家用車の普及、貨物車による輸送等、様々な要因により、都市部の道路ネットワークでは需要過多による慢性的な交通渋滞が発生しており、交通環境は良好とは言えない。そのため、道路交通における所要時間の不確実性は増大し、道路の利便性は低下してきている。また交通渋滞による温室効果ガスの発生は重大な問題となっており、経済活動だけでなく環境問題の観点からも、早急な解決策が望まれている。しかし、空間的・財政的制約により、新規道路の建設等のハード面の対策は早急に実行可能な対応策とはなり得ない。そこで交通需要の時間的・空間的分散を促すことを目的とした交通需要マネジメント(TDM: Transportation Demand Management)が注目を浴びている。具体的にはロードプライシングやパークアンドライドなどが挙げられる。TDMは道路利用者の利便性を一部制限するため、適切な施策の策定・評価が求められる。この施策の評価において、個人の行動に着目した非集計的アプローチによる経路の選択行動の分析は、施策が道路利用者にも与える影響を分析出来るため有効な手段¹⁾とされており、広く用いられている。しかし、従来の非集計的アプローチによる分析の多くは、期待効用理論に基づき、参照依存性や損失回避性、感応度逓減など現実の選択行動の特徴を考慮していないため、必ずしも十分なものとは言えない。

そこで本研究では、現実の個人の選択行動の特徴を考

*キーワード: 経路選択, プロスペクト理論,

ニューラルネットワーク

**学生員、学士(工)、京都大学大学院工学研究科

(京都市西京区京都大学桂C1、

TEL075-383-3231、FAX075-950-3800)

***正会員、博士(工学)、京都大学大学院工学研究科

(京都市西京区京都大学桂C1、

TEL075-383-2819、FAX075-383-2820)

****正会員、博士(工学)、京都大学大学院工学研究科

(京都市西京区京都大学桂C1、

TEL075-383-3231、FAX075-950-3800)

*****フェロー、工博、京都大学大学院工学研究科

(京都市西京区京都大学桂C1、

TEL075-383-3229、FAX075-950-3800)

慮したプロスペクト理論^{2),3)}を用いて経路の選択行動を分析することで、従来のモデルよりも説明力の高いモデルを構築することを目的とする。本研究で取り扱う交通行動は、他の行動に比べ時間制約が強く、ドライバーの属性による影響が小さいため、経路の選択において一貫性があると考えられる貨物車による配送とする。貨物車の配送は交通に与える影響も大きく、渋滞の一因と考えられているため、貨物車の走行経路選択行動を分析することは有意義であると考えられる。

また一方で、経路選択行動は人の思考の結果に依るもので、人の思考の複雑さを考えると数学的なモデル化は容易ではない。このようにメカニズムが複雑かつ入出力関係を支配する因果法則が不明という状況下において、ニューラルネットワークを用いた分析⁴⁾が有効的であるとされる。そこで本研究では、ニューラルネットワークを用いた学習による経路選択行動の分析を行い、プロスペクト理論を用いた場合との比較を行う。

2. プロスペクト理論における価値関数

従来、市場の投資行動や交通行動分野における経路選択行動などの不確実性状況下における意思決定は期待効用理論に従うという仮定の下で多くの研究が進められてきた。期待効用理論では各事象の期待効用は、効用関数で表される客観的な価値とその生起確率を掛け合わせた期待値で表され、期待効用は線形演算が可能とされる。期待効用理論は期待効用を最大化する意思決定のための規範的モデルとして広く用いられてきたが、Allaisの反例⁵⁾に見られるように期待効用理論では説明できない現象がいくつか存在することが知られている。

これに対しプロスペクト理論はKahneman and Tversky^{2),3)}により提案された、現実の意思決定を説明する理論の一つである。プロスペクト理論では、期待効用は価値関数とウェイト関数を掛け合わせたもので表され、記述モデルへの適用に適していると考えられる。




図-1 価値関数の概形

価値関数は、現実の選択行動の特徴を考慮し、期待効用理論では説明できない幾つかの事例に対しても理論的説明が可能である。具体的には、意思決定は選択肢の絶対的価値ではなく、個人の持っているある基準(参照点)に影響されるという参照依存性や、利得の大きさよりも損失の大きさに左右されるという損失回避性、参照点からの距離が大きくなるほど効用の変化が鈍くなる感応度逓減を考慮することにより、現実の意思決定をより精緻に表現することが可能である。価値関数の概形を図-1に示す。

3. プロスペクト理論に基づく本研究のモデル

従来、期待効用理論では、効用を式(1)に示す関数形により表してきた。⁶⁾

$$V_{in} = \sum_{k=1}^K \beta_k x_{ki} \quad (1)$$

ここに、

V_{in} : 個人 n の選択肢 i に対する効用

x_{ki} : 選択肢 i の説明変数 k

β_k : 説明変数 k の効用に対する重み

K : 考慮する説明変数の数

Kahneman and Tversky の提案する価値関数を基に、本研究では具体的に式(2)に示す関数形を用いる。¹⁾²⁾

$$u_{in} = \begin{cases} \sum_{k=1}^K \beta_k (x_{ki} - x_{k0})^{\alpha_k} & x_{ki} - x_{k0} \geq 0 \\ \sum_{k=1}^K \beta_k (-\lambda_k)(x_{ki} - x_{k0})^{\alpha_k} & x_{ki} - x_{k0} < 0 \end{cases} \quad (2)$$

ここに、

u_{in} : 個人 n の選択肢 i に対する効用

x_{ki} : 選択肢 i の説明変数 k

x_{k0} : 説明変数 k の基準点

α_k : 説明変数 k のリスクに対する反応を示すパラメータ

λ_k : 説明変数 k のリスクに対する損失回避係数

基準点 x_{k0} を用いることにより参照依存性、パラメータ λ_k により損失回避性、パラメータ α_k により感応度逓減を表現する。この関数形を用いることにより従来の手法よりも詳細に意思決定行動を記述できる経路選択モデルの構築が可能となると考えられる。

4. ニューラルネットワーク

ニューラルネットワークは脳内の神経細胞(ニューロン)を工学的にモデル化し、繋ぎ合わせネットワーク化した情報処理機構であり、教師信号を与えて学習することにより、望ましい入出力関係を表現するモデルである。本研究では、入力層と出力層の間に任意の個数の中間層を設け、誤差逆伝搬学習法を用いた階層型ニューラルネットワークを用いる。誤差逆伝搬学習法のアルゴリズムは以下の通りである。⁴⁾

- ① 学習に用いるデータ(入力層への入力データおよび出力層からの出力データと比較するための教師信号)を用意する。
- ② 入力層、中間層、出力層の順に、各ニューロンの出力値を計算する。
- ③ 教師信号と出力値の二乗誤差を計算する。
- ④ 教師信号と出力値の二乗誤差が減少するように、出力層から入力層へ向かって、各結合荷重を修正する。
- ⑤ 全ての入力データに対する二乗誤差が設定値以下になれば計算を終了し、そうでなければ②へ戻り、繰り返して計算する。

ここで m 層から構成される階層型ニューラルネットワークを考える(図-2)。入力データ X を提示した時の第 k 層($k=2,3,\dots,m$)の入出力関係は次式のように示される。

$$o_{X,j}^k = f(i_{X,j}^k) \quad (3)$$

$$i_{X,j}^k = \sum_{i=1}^{n_{k-1}} w_{i,j}^{k-1,k} o_{X,i}^{k-1} - \theta_j^k \quad (4)$$




図-2 m 層の階層型ニューラルネットワーク

ここに,

$o_{x,j}^k$: 入力データ X を提示した時の第 k 層の j 番目のニューロンの出力値

$i_{x,j}^k$: 入力データ X を提示した時の第 k 層の j 番目のニューロンの入力値

$w_{i,j}^{k-1,k}$: 第 $k-1$ 層の i 番目のニューロンと第 k 層の j 番目のニューロンとの結合荷重

f : 第 k 層の j 番目のニューロンの入出力関数

θ_j^k : 第 k 層の j 番目のニューロンのしきい値

n_k : 第 k 層のニューロンの数

ここで, 入出力関数 $f(x)$ は定数 ε を用いて次式のように表される関数を用いる.

$$f(x) = \frac{1}{1 + \exp(-\varepsilon x)} \quad (5)$$

また第 $k-1$ 層に常に出力値1をとる $(n_{k-1}+1)$ 番目のニューロンの存在を仮定して, このニューロンと第 k 層の j 番目のニューロンとの結合荷重を $w_{n_{k-1}+1,j}^{k-1,k} = -\theta_j^k$ と考えることにより式(4)は次式のように表すことができる.

$$i_{x,j}^k = \sum_{i=1}^{n_{k-1}+1} w_{i,j}^{k-1,k} o_{x,i}^{k-1} \quad (6)$$

ニューラルネットワークの評価関数として, 教師信号 $t_{x,i}^m$ と実際の出力値 $o_{x,i}^m$ の二乗誤差 E_x を考える.

$$E_x = \frac{1}{2} \sum_{i=1}^{n_m} (t_{x,i}^m - o_{x,i}^m)^2 \quad (7)$$

この評価関数値 E_x を小さくするように各結合荷重を変化させる. その修正量 $\Delta_x w_{i,j}^{k-1,k}$ は次式のように表される.

$$\Delta_x w_{i,j}^{k-1,k} \propto -\frac{\partial E_x}{\partial w_{i,j}^{k-1,k}} \quad (8)$$

式(8)は次式のように分解できる.

$$\frac{\partial E_x}{\partial w_{i,j}^{k-1,k}} = \frac{\partial E_x}{\partial i_{x,j}^k} \frac{\partial i_{x,j}^k}{\partial w_{i,j}^{k-1,k}} \quad (9)$$

式(9)の右辺の積の第1項を次式のように定義する.

$$\delta_{x,j}^k = -\frac{\partial E_x}{\partial i_{x,j}^k} \quad (10)$$

式(10)から式(9)は次式のように表すことができる.

$$\begin{aligned} -\frac{\partial E_x}{\partial w_{i,j}^{k-1,k}} &= \delta_{x,j}^k \frac{\partial}{\partial w_{i,j}^{k-1,k}} \sum_{l=1}^{n_{k-1}+1} w_{i,j}^{k-1,k} o_{x,l}^{k-1} \\ &= \delta_{x,j}^k o_{x,i}^{k-1} \end{aligned} \quad (11)$$

これらを用いて m 層の階層型ニューラルネットワークにおける各層間の結合荷重の変化規則は, 比例定数 η を用いて以下のように表せる.

$$\begin{aligned} \Delta_x w_{i,j}^{k-1,k} &= \eta \delta_{x,j}^k o_{x,i}^{k-1} \quad i = 1, 2, \dots, n_{k-1} + 1, \\ j &= 1, 2, \dots, n_k, \quad k = 2, 3, \dots, m \end{aligned} \quad (12)$$

$$\delta_{x,j}^m = \varepsilon (t_{x,j}^m - o_{x,j}^m) o_{x,j}^m (1 - o_{x,j}^m) \quad (13)$$

$$\begin{aligned} \delta_{x,j}^k &= \varepsilon o_{x,j}^k (1 - o_{x,j}^k) \sum_{l=1}^{n_{k+1}} (\delta_{x,l}^{k+1} w_{j,l}^{k,k+1}) \\ k &= 2, 3, \dots, m-1 \end{aligned} \quad (14)$$

式(12)より η が定数で, $o_{x,i}^{k-1}$ が既知の値であるため結合荷重の修正量 $\Delta_x w_{i,j}^{k-1,k}$ は, $\delta_{x,j}^k$ を計算することにより求められる. 式(13)に教師信号 $t_{x,j}^m$, 及び第 m 層の出力結果 $o_{x,j}^m$ を代入することにより, $\delta_{x,j}^m$ が求められ, 式(12)に代入することで第 $m-1$ 層と第 m 層との間の結合荷重の修正量 $\Delta_x w_{i,j}^{m-1,m}$ が求められる. さらに式(14)に $\delta_{x,l}^m$, 既知の $o_{x,j}^{m-1}$ 及び $w_{j,l}^{m-1,m}$ を用いて $\delta_{x,j}^{m-1}$ が求められ, 第 $m-2$ 層と第 $m-1$ 層との間の結合荷重の修正量 $\Delta_x w_{i,j}^{m-2,m-1}$ が求められる. 同様にして各層間の結合荷重が下流から上流へ順次修正される.

5. ケーススタディ

(1) 使用するデータ

本研究では, 大阪市中心部に仮想に設定した顧客間の配送に対し, 物流事業者の配送係の担当者に依頼し作成された走行経路を再現するモデルを構築することを目指し, 各モデルの未知パラメータを推定する. 本研究で用いる道路ネットワークを, 図-3 に示す. 使用する道路ネットワークは 225 ノード, 781 リンクにより構成される. なお図中の番号は, 出発地及び目的地になり得る顧客の番号である. また使用する所要時間情報は, VICS により提供された所要時間情報とした. 本研究で用いた物流事業者の配送係による選択経路は, 事前に図-3 の道路ネットワークを示し, 仮想的に設定した 24 対の OD に対する配送に対して, 担当者が自らの経験に基づき経路選択を行い作成したものである.




図-3 大阪市中心部の道路ネットワーク

(2) 価値関数を用いた場合

考慮する説明変数は経路長, 所要時間の平均及び標準偏差, 走行速度の平均及び標準偏差, リンク数, 左折回数, 右折回数の 8 種類とし, 順に $k=1, 2, \dots, 8$ とする. 価値関数として式(2)を用いる場合をケース A, 従来の効用関数である式(1)を用いた場合をケース B とする. ケース A, B において, パラメータ推定の際, モデル的的中率最大を目的関数とした. また, 従来の多項ロジット分析を行い, 最尤法によりパラメータ推定を行う場合をケース C とする. ケース A において推定されたパラメータの値は表-1 の通りである.

(3) ニューラルネットワークを用いた場合

ニューラルネットワークを用いた分析をケース D とする. ケース D において用いるニューラルネットワークは入力層(ニューロン 8 個), 中間層(ニューロン 8 個), 出力層(ニューロン 1 個)からなる全 3 層から構成される. 入力層には, 価値関数に用いるものと同じ 8 個の情報を用い, 出力層には配送係の選択した経路の出力結果が他の経路の出力結果

表-1 ケース A におけるパラメータ推定結果

パラメータ \ k	1	2	3	4	5	6	7	8
α_k	0.608	0.179	0.332	0.192	0.451	0.715	0.817	0.532
β_k	-23.404	3.741	5.522	-4.486	-14.363	-11.812	-21.349	-17.902
λ_k	9.993	29.330	7.013	5.864	4.462	2.896	0.02	6.462

表-2 学習により求められた w_1

$i \backslash j$	1	2	3	4	5	6	7	8
1	0.955798	0.734179	0.218023	0.722498	0.677284	0.222619	0.675683	0.688340
2	0.454939	0.602752	0.560480	0.207702	0.376587	0.883187	0.692076	0.083393
3	0.727136	0.462914	0.641107	0.545722	0.096238	0.956360	0.713817	0.929153
4	0.928428	0.827684	1.023809	0.854535	0.264980	0.962322	0.857650	0.971416
5	0.627082	0.581544	0.235488	0.844309	0.550757	0.287770	0.685148	0.168339
6	0.877261	0.786737	0.423382	0.084772	0.251114	0.081432	0.659936	0.460688
7	0.903014	0.601281	0.528432	0.278082	0.280101	0.209088	0.139460	0.661098
8	0.427504	0.346503	0.215000	0.801032	0.833838	0.418029	0.090056	0.492329

表-3 学習により求められた w_2

$i \backslash j$	1
1	-1.091340
2	-0.990941
3	-1.312875
4	-1.420550
5	-0.932958
6	-1.031288
7	-1.325129
8	-0.897681

よりも大きくなるように設定した. また, 定数 ε 及び η はそれぞれ $\varepsilon = 1.0$, $\eta = 0.1$ とした. ケース D において得られた結合荷重は表-2 および表-3 の通りである. ただし第 1 層と第 2 層, 第 2 層と第 3 層との間の結合荷重をそれぞれ w_1 , w_2 とする.

(4) 各ケースの比較

求められたパラメータを用いて各モデルの的中率を求めた. ここでの中率とは, 全 24 回の配送の内, 各モデルの推定する選択経路と実際に配送係が選択した経路が一致した割合を表す. 各モデルの的中率は表-4 の通りである. また各ケースにおいて求められたパラメータを用いて, 顧客 1-16 間の配送に関して各モデルによる経路の推定を行った. その結果を図-4 に示す.

表-4 各ケースにおける的中率

	ケースA	ケースB	ケースC	ケースD
的中率	0.583	0.542	0.375	0.375




図-4 各ケースで推定された経路

(5) 考察

ケース A と B は効用を表す関数形, ケース B と C はパラメータ推定の際の目的関数のみがそれぞれ異なっており, またケース D はニューラルネットワークを用いている. その結果, ケース A の的中率が最も高くなった. これは, 経路選択においても参照依存性・損失回避性・感応度逓減などの特徴があると考えられる. そのため, 従来用いられてきた多項ロジット分析やニューラルネットワークを用いた分析は, これらの性質を考慮しておらず, これらの性質を考慮可能なモデルの方が, 記述モデルとしてより有効である可能性が示された. また図4 に示す通り, 用いるモデルにより推定される経路が異なることから, 的中率の高いモデルを用いることで経路推定の精度を高めることが可能であると考えられる.

6. おわりに

本研究では, 経路選択においても参照依存性や損失回避性, 感応度逓減などの特徴があると考え, プロスペクト理論における価値関数を用いた経路選択モデルの提案を行った. また, 従来の多項ロジット分析やニューラルネットワークによる分析との比較を行った. その結果, 価値関数を用いることで, 従来から用いられてきた手法よりも高い確率で走行経路を推定しうる可能性を示した.

今後, 本研究で提案したモデルを用いて配送係が作成する都市内配送を推定し, 最適化モデルにより得られる都市内配送の配送コストを比較することで, 最適都市内配送の有効性を定量的に評価することが期待される.

参考文献

- 1) 交通工学研究会: やさしい非集計分析, 第1章, pp.1-16, 1993.
- 2) Kahneman, D. & Tversky, A.: Prospect theory: An analysis of decision under risk, *Econometrica*, Vol.47, pp.263-291, 1979.
- 3) Kahneman, D. & Tversky, A.: Choices, Values, and Frames, pp.1-65, 2000.
- 4) 森崎博亮, 谷口栄一, 山田忠史: 所要時間の変動を考慮した空港バスの経路決定支援システムに関する研究, 交通工学研究会論文報告集, Vol.26, 2006.
- 5) Allais, M.: Fondements d'une Theorie Positive des Chix Comportant un Rispue, *Econometrie*, Vol.15, pp.257-332, 1952.
- 6) 北村隆一, 森川高行: 交通行動の分析とモデリング, 第6章 pp.103-145, 2002.