

知識利用型の経路選択モデル化手法*

Modelling of Route Choice Behaviour using Knowledge Based Techniques

秋山 孝正*

By Takamasa Akiyama

There are advanced techniques using idea of Knowledge Base (KB) to describe human behaviour. Three methods such as production system (PS), fuzzy reasoning/logic (FL) and neural networks (NN) are applied to modelling of binary route choice. The basic concept of each method is mentioned. The advantages and disadvantages of them are discussed from the comparison with logit modelling as a standard method for solving the problem. The difference of KB approach from statistical one is considered. And also the relation among these techniques are summarized. Finally, a combined model between FL and NN can be proposed to develop these methods in terms of accurate estimation and precise description of human travel behaviour.

1. はじめに

交通機関選択や交通経路選択をモデル化する場合の方法として、いわゆる知識ベースを利用したモデリング方法が提案されている¹⁾。一般的にこれらの多くは、人間の獲得した知識から有効な情報を得て、モデル化を行おうとするものである。この点で統計的なデータ処理を基本とする関数モデルとは構造的あるいは機能的な相違があるといえる。

これまでも同様のモデリング手法が計算機工学の分野で多く用いられ、特に人間の非合理性あるいは人間判断の実際の意味に着目している。その意味では、統計的推計手法と目指すところが異なるため、従来法との優劣を議論することは重要な意味を持た

ない。しかしながら、モデリング概念、モデル化方法を明確にするために既存方法と比較し相違点を明らかにすることで、適用範囲を考察することは有意義である。つまり現実の多様な局面に対応するための経路選択現象の分析において、適用可能なモデリング手法の範囲を広げることにつながるからである。これは交通情報と運転者意識あるいは運転者の経路選択行動分析にも応用できる可能性がある。

本研究では、同種の問題に対する従来のモデリング方法の典型として、2項ロジットモデル(BL)を取り上げた。特に簡単な計算例を用いて、各モデル化手法の比較検討を行う。具体的なモデリング方法の相違と経路選択率の推計結果の比較を行うことで、各方法の特徴を具体的に整理できる。さらに各方法の相互関係の検討結果を踏まえて、それぞれの長所を生かした応用を検討し、この一例として、ファジィ推論とニューラルネットワークの結合型モデルについての検討結果を報告する。

*キーワード：ファジィ推論、ニューラルネットワーク、経路選択モデル

**正会員 工博 京都大学講師 工学部交通土木工学教室(〒606 京都市左京区吉田本町)
ダルムシュタット工科大学研究員(1993. 6. 現在)

2. モデル化手法の概要

(1) モデル化のための例題

ここでは、モデル化の各方法の比較を意図しており、簡単な例題を用いる。一般に経路選択の問題は、広範囲に定義することができる。道路網と鉄道システムとの分担、一般道路と高速道路など性質の異なる交通システム相互の経路選択の問題を考える。

図-1は最も簡単なO D間の経路構成を考えた2項選択の例題である。一般化するためには、各経路の具体的な評価要因の決定問題があるが、ここでは、時間費用その他が一般化された「交通費用」を考えることにする。




Fig. 1 Simple Example of Route Choice

このような前提のもとで最も簡単な交通経路／機関選択問題を考えることにする。すなわち典型的な2項型ロジットモデルの例題と考えることもできる。したがって、ここでは対象をドライバー（利用者）と考えた、個人レベルの交通行動表現がどのようにモデル化されるかが着目対象である。

表-1は、BLモデルを推計用サンプルの例を示したものである²⁾。これは本来、機関選択率推計の

Table 1 Example Data for Logit Model

No.	route	T ₁	T ₂	No.	route	T ₁	T ₂
1	2	52.9	4.4	12	1	18.5	84.0
2	2	4.1	28.5	13	1	82.0	38.0
3	1	4.1	86.9	14	2	8.6	1.6
4	2	56.2	31.6	15	1	22.5	74.1
5	2	51.8	20.2	16	1	51.4	83.8
6	1	0.2	91.2	17	2	81.0	19.2
7	1	27.6	79.7	18	1	51.0	85.0
8	2	89.9	2.2	19	1	62.2	90.1
9	2	41.5	24.5	20	2	95.1	22.2
10	2	95.0	43.5	21	1	41.6	91.5
11	2	99.1	8.4				

例題として示されているが、多数の要因を持つ経路間の選択を仮定しても一般性は失われない。

後述する各モデル作成において必要となるデータも同一の調査形式のものが利用できる。したがって、

具体的な交通行動のサンプリング方法に関する議論は行わない。つまり各モデルに対して、同一のデータが得られていることを前提としている。

(2) 従来型モデル

知識利用型のモデリングと統計的処理を基本とする従来型の方法は本質的に異なる。これらの優劣を問題とする必要はないが、モデリング上の相違を明確にするために、個人行動のモデル化の代表的方法として非集計モデルを取り上げ、算出手順・算出結果について比較検討する。

まず簡単で有効性の高い従来モデルとして、ロジットモデルを考える。ロジットモデルでは各経路の効用関数をつぎのように表現する。

$$V_{1n} = \theta_1 + \theta_2 x_{1n2} \dots\dots\dots (1)$$

$$V_{2n} = \theta_2 x_{2n2} \dots\dots\dots (2)$$

これらの効用関数から、ロジットモデルでは指数関数を含んだ形の関数で経路選択率が計算される。たとえば経路1の選択確率は以下のようなのである。

$$P_{1n} = 1/[1 + \exp\{-\{\theta_1 + \theta_2(x_{1n2} - x_{2n2})\}\}] \dots\dots (3)$$

このとき、統計的に関数型を決定するために通常最尤推定法を用いた推計が行われる。本例では、パラメータ値は $\theta_1 = -0.237$ 、 $\theta_2 = -0.053$ となる^{2), 3)}。この結果、各サンプルの経路選択確率の推計値が求められる。本例で適中率計算に用いられる $P_i \geq 0.5$ を経路1の選択基準とすれば、全体のうち、2サンプル(No. 2とNo. 13)が誤判別であることになる。したがって、適中率は $19/21 = 0.905$ であり、BLモデルとしても適合性の高い場合の例である。

また後述の他手法との比較のため、実績値（選択の有無 $R_i = 0$ or 1 , $i = 1 \sim n$ ）との整合性を示す指標として、以下のような指標を考える。

$$\varepsilon = \sum_i |R_i - P_i| \dots\dots\dots (4)$$

この誤差指標においては、各サンプルに対する推計誤差が最大1の大きさに累積される。BLモデルを用いて推計した結果（詳細は後述する）について ε を計算すると $\varepsilon = 5.452$ である。つまりこの結果を計量的に（経路選択交通量として）用いた場合には最大で、 $5.452/21 = 26\%$ 程度の誤差を生じる可能性

があること示している。

BL (あるいは多項ロジット) モデルは、統計的なデータ解析を基本としており、モデルの有意性について、以上の他にも多くの指標が存在することは周知のとおりである。したがって、モデルの有効性を統計的に検討できる点は大きな利点である。

これまでロジットモデルに関する推計方法、実用的検討など多数の議論が行われている。ここではBLモデルの修正を目的とはしないので、以下には議論に関連する『一般の特徴』をとりあげた。

- ・効用理論から関数型推計手順までモデル化における数学的議論が明確である。
- ・推計計算も数学的に定義でき比較的容易である。
- ・モデルの有意性を統計的指標で検討できる。
- ・個人の行動は経済原則に基づいており、個人が効用関数を持つと仮定されている。
- ・選択の相違 (誤差項) は確率的に生じる。
- ・モデル作成に多様性がなく、常に同一モデルが得られる。

3. 各モデルリング手法

知識ベース (Knowledge Base :KB) を利用したモデリングは、基本的にはAI手法 (人工知能、エキスパートシステム) 方法に基づくものである。しかしながら、現実の研究分野では人工知能、ファジィ工学、ニューラルネットワークなどの方法論がほぼ独立して提案されている。そこで本研究においてもこれらを3手法に分類して述べることにする。

(1) プロダクションシステムによるモデリング

一般にエキスパートシステムと称される方法は、専門家の知識を獲得・整理・保存し、さらにコンサルティングする機能を計算機上に実現するものと考えられる。ここでは、なかでも構造的にルールベースを利用するため、これをプロダクションシステム (Production System:PS) モデルと呼ぶことにする。

一般に交通行動を分析するための知識ベース作成には、付加的な情報に関する知識も重要となる。特に大がかりで複雑な知識ベースを作成するためには、意思決定構造を把握するような方法が必要である⁴⁾。

この場合には、経路選択に関する知識として、一般化費用に対する簡単な推論 (人間が日常的に用い

ているような判断) を用いた。すなわち経路1の選択に対して「交通費用 T_1 が他方の費用より小さければ、経路1を選択する」また「両費用が大きく違わなければ選択を決定的に行わない」などである。

プロダクションシステム (PS) としてのモデリング方法の手順を簡単に述べると以下のようなものである。

- ①基本的な人間の判断を定性的に整理する。
- ②入力・出力間の関係をルール形式で記述する。
- ③データとの整合性を考慮してルール群の構成を修正する。

この知識獲得の手順は数学的方法として構成できないので、BLモデルに比べて複雑であるが、通常のAI手法の各種方法を利用することもできる。

いま交通費用および経路1の選択率に対して、3種類の認識 (大・中・小) が考えられるとすると、これらの知識は、いずれもIF/THEN型のルール群で表現することができる。交通費用 (説明変数) のラベルを小文字、経路1の選択率 (被説明変数) のラベルを大文字で書くことにすれば、表-2のようなルール表を作成できる。

Table 2 Inference Table for PS Model

T_1	T_2	small	medium	large
small		①MEDIUM	②LARGE	③LARGE
medium		④SMALL	⑤MEDIUM	⑥LARGE
large		⑦SMALL	⑧SMALL	⑨MEDIUM

表中のラベル番号は各ルールに対応する。たとえば、ルール①は、

$$\begin{aligned} \text{IF } & T_1 \text{ is small \& } T_2 \text{ is small} \\ \text{THEN } & P_1 \text{ is MEDIUM} \dots\dots\dots (5) \end{aligned}$$

のように書くことができる。本例の場合は、合計9個のルール群で構成されている。通常の推論システムで用いられるルール論理は、このようにテーブル表示できる。これは各変数がクリスプ数 (ある範囲だけを示す値) であることに起因している。実際的には経路選択利用者を9個のカテゴリーに分類したと一致している。

モデルの推論結果として得られるラベル、SMALL, MEDIUM, LARGEは、経路選択率の値1.0, 0.5, 0.0に対応している。ここで結論のMEDIUM (表-2の網掛

け部分)は、選択確率が0.5 で未確定であることを示している。これらの具体的な計算結果の詳細は次項の方法(ファジィ推論)と比較して述べる。

ここで、経路選択結果の適合性だけを見るとこの計算例では、きわめて良好で誤判別は少ない。しかしすべての推論が2値論理(0か1か)で行われているため、常に推論がうまく構成できるとはかぎらない。この方法の特徴は以下のようなものである。

- ・人間の日常的な判断記述を基本として、モデル(推論ルール)を構成できる^[#]。
- ・通常のエキスパートシステムの推論機構その他の技法を用いることができる。
- ・ルール表現は言語表現に近くモデル構成が理解しやすい^[#]。
- ・2値論理を用いるので、経路選択率の表現ができない。
- ・変数・ルールの決定など試行錯誤が必要である。
- ・ルール数の増大により、推論内容が複雑になる可能性がある^[#]。

(ここで[#]印は一般的にも知られる特徴)

(2) ファジィ推論によるモデリング

知識ベース型モデルにおいて、ルール型記述が用いられている場合(Production Rules)には、言語変数による推論構成を用いることによって、ファジィ推論(Fuzzy Logic/Approximate Reasoning:FL)モデルを作成することができる¹⁾。

FLモデルの一般的な作成手順を簡単に示すと以下のようなものである⁵⁾。

- ①各言語変数(メンバーシップ関数)を定義する。
- ②推論の基本関係をルール表現する。
- ③推論方式(含意公式・結合方法など)を決定する。
- ④結論のファジィ数に関する非ファジィ化の方法を定義する。
- ⑤データとの整合性を考慮して、定義変数・ルール群構成・含意公式などを修正する。

基本的なモデリングの意味は、IF/THEN ルールを用いて利用者判断を記述するという点で前述のPSモデルと同一である。したがってモデリング手順もほぼ同様に行うことができる。

ファジィ推論では、人間の判断を特定の幅を持つ言語変数で表現している。PSモデルで用いた9個

のルール表現をそのまま用いることができる。相違点は、各ルール中の言語変数が、特定の幅と度合いを持つファジィ数であることから、図-2に示すように各変数の全体の判断に占める割合が大きくなる。




Fig. 2 Crisp Rules and Fuzzy Rules

この結果、通常のPSモデルですべての場合を尽くすには、多数のルールを必要とするが、FLモデルではルール数の簡略化が可能である。

例題では、ファジィ推論のなかで最も一般的なマムダニ推論法(max-min-gravity)を用いている。したがって、まずファジィ数A、Bを定義したとき、推論「IF x is A THEN y is B」を示すファジィ関係が2項関係として、

$$\mu_R(x,y) = \min\{\mu_A(x), \mu_B(y)\} \cdots \cdots \cdots (6)$$

で表現され、このときx=A' についての推論結果がつぎのように求められるものである。

$$\mu_{B'}(y) = \sup_y \min_x \{\mu_{A'}(x), \mu_R(x,y)\} \cdots \cdots \cdots (7)$$

この方法は、計算過程全体がmax, min演算で構成できるため、比較的簡単なプログラミングでモデル化できる。またファジィ推論の結果は、ファジィ数B'であるからこの点もPSモデルとは異なる。重心法・中心法などを用いた「非ファジィ化」手順をここに加えることによって、実用的な変数として算出結果を得ることができる。

本例では、データとの整合性を向上させるためのモデル構成の調整は特にせず、PSモデルのルール構成を用いて、必要な部分についてファジィ化したモデルを用いている。ファジィ推論が通常の推論を包含する特徴を利用したモデル化である。

表-3にPSモデルとFLモデルにおける推計結果が示されている。また比較のためBLモデルを用いた算出結果も併せて示している。

Table 3 Estimation of PS Model and FL Model

P_1	BL	PS	FL	P_1	BL	PS	FL
0	0.191	0	0.059	1	0.855	1	0.819
0	0.651	?	0.716	1	0.215	0	0.193
1	0.905	1	0.914	0	0.436	?	0.417
0	0.321	0	0.304	1	0.800	1	0.764
0	0.280	0	0.211	1	0.700	1	0.798
1	0.923	1	0.997	0	0.143	0	0.202
1	0.802	1	0.782	1	0.709	1	0.815
0	0.075	0	0.032	1	0.673	1	0.706
0	0.369	0	0.361	0	0.109	0	0.079
0	0.182	0	0.067	1	0.792	1	0.895
0	0.069	0	0.014				

すでに述べたように、PSモデルでは中間的な値を持たないため、選択結果として0、1、?（未決定）の3種類で表示されている。FLモデルでは、ファジィ推論の結果を重心法を用いて0～1の数値化（確率軸上の数値）として表現している。

この推計確率値をBLモデルの結果と比較すると、各サンプルに対して類似選択確率を与えていることがわかる。また誤差指標 ε を求めると、 $\varepsilon=4.754$ であり、BLモデルの結果に比べて実績判断により近い推計結果となっている。

さらにFLモデルは、上記に述べたように、ルール構成とそれに合わせたファジィ数の若干の変更で、モデルをより簡略化することができる。若干の試行錯誤の結果、さきの9個のルールの内、ルール⑨の結論はLARGEが妥当であることがわかった。このとき、ルール表が表-4のように変更できる。

Table 4 Modified Rules for FL Model

T_1	T_2	small	medium	large
small		①MEDIUM	②LARGE	
medium		④SMALL	⑤MEDIUM	⑩LARGE
large		⑦SMALL	⑧SMALL	

これは9個のルールのうち③、⑥、⑨が以下の新たなルール⑩：

IF T_1 is large THEN P_1 is LARGE(8)

に統合されたものである。したがって合計のルール数は7個に減少している。ここで入力変数の三角型ファジィ数を $N[p, q, r]=N$ [左スプレッド, 中央値,

右スプレッド] とする。いまルール変更に伴うキャリアブレーションとして N を変更する。たとえば、ここで $N[q-40, q, q+40]$ を用いると、 $\varepsilon=3.841$ となり推計精度の向上が見られる。

以上のような点から、特に関数型モデルに対するファジィ推論モデル（FLモデル）の特徴をつぎのようにまとめることができる。

- ・PSモデル同様、言語表現された人間の経路選択における経験的知識を利用できる。
- ・ファジィ数の利用により、ルールの簡略化、多様な推論形式の選択が可能である^[#]。
- ・論理構成を言語表現することで、比較的容易に非線形現象を記述することができる^[#]。
- ・ルール構成、変数設定などの決定方法に確定的なものが存在しない^[#]。
- ・PSモデル同様、有効なモデル作成には試行錯誤が必要となる。

（ここで[#]印は一般的にも知られる特徴）

(3) ニューラルネットワークによるモデリング

本研究に示した経路選択問題を経路選択の有無（0と1）についての「パターン決定問題」と考えると、ニューラルネットワーク（NN）モデルを用いることができる。この場合、以下の議論では階層型ニューラルネットワークを考えている。NNモデルの作成手順は、他モデルに比べて単純である⁶⁾。

- ①モデル構造を決定するため、ネットワークの要素（入出力変数、階層数、ノード数）を定義する。
- ②入力・出力パターンを教師データとして与える。
- ③出力パターンの誤差が最小になるような結合荷重を算出する。
- ④算出された荷重をネットワーク上に付加する。
- ⑤推計モデルでは上記荷重を固定し、新たな入力に対してネットワーク上の信号を順次計算する。

本例では、図-3に示すような入力層2・中間層2・出力層1の簡単なニューラルネットワークを用いた。もちろんNNモデルでは、さらに多層構造を持つ構成考えることができる。しかしながら、中間層を持つことで非線形構造を表現できるという意味では、この簡単な例による検討を行ってもモデルの一般性を失わない。多段階の意思決定を仮定できる場合には、多層構造も利用できる。




Fig. 3 Neural Network Model

このモデルでは入力層として、交通費用の実数値 T_1 、 T_2 を与え、出力層に経路 1 の選択率 P_1 を与えている。実際には NN 計算のため入力値は 0 ～ 1 の数値に線形変換されている。

また NN モデルの結合荷重の計算にあたっては、誤差伝播法（BP 法）のうち、繰り返し計算途上で、誤差修正の割合をモーメント係数を用いて変化させる修正モーメント法を用いた（ $\alpha=0.6$ 、 $\beta=0.3$ 、 $\Delta m=0.05$ ）⁶⁾。各ニューロンは通常の NN の方法にしたがって、指数関数を用いたシグモイド関数に基づいて発火する構造を持っている。

ここでは BP 法のプロセスにおいて、推計誤差 ε が 0.5 より小さくなった場合を収束基準とした。結果的に 416 回の繰り返し計算で、 $\varepsilon=0.497$ となった場合である。最終的な結合荷重の値は、図 - 3 のネットワーク上に併記している。この値が推計において保存され、NN モデルの各層の値を前向きに計算することで最終的な推計値が計算される。

表 - 5 に NN モデルを用いた推計結果を示す（この場合も BL モデルの結果を併記している）。

Table 5 Estimation Result of NN model

No.	P_1	Logit	Neuro	No.	P_1	Logit	Neuro
1	0	0.191	0.001	12	1	0.855	0.995
2	0	0.651	0.001	13	1	0.215	0.827
3	1	0.905	0.975	14	0	0.436	0.001
4	0	0.321	0.079	15	1	0.800	0.982
5	0	0.280	0.001	16	1	0.700	0.998
6	1	0.923	0.982	17	0	0.143	0.011
7	1	0.802	0.996	18	1	0.709	0.998
8	0	0.075	0.001	19	1	0.673	0.998
9	0	0.369	0.001	20	0	0.109	0.005
10	0	0.182	0.144	21	1	0.792	0.998
11	0	0.069	0.001				

各サンプルに対する推計結果を見ると、非常に実績パターンと類似した結果が得られている。これは、NN モデルの荷重決定が出力パターンの誤差最小を

前提としていることによる結果であるといえる。

特にこれまでの BL、PS、FL 各モデルのいずれにおいても誤判別であったサンプル No. 2、No. 13 に関しても実績判断と一致した判断結果を与えている。したがって実用的な推計精度を得るという意味では、NN モデルは通常極めて高精度な結果を与えることがわかる。

これらの考察から、NN モデル（階層型）の特徴を整理すると以下のようである。

- ・モデル化過程に誤差最小化の概念を持つので、計算手順は明確である^{〔#〕}。
- ・複雑な非線形関係をネットワーク表現を利用して実現しており、出力の適合性は極めて高い。
- ・パターン型変数、数値変数のいずれも適用可能である^{〔#〕}。（本例では数値変数である）
- ・この問題に対するネットワーク構造（層数、ノード数など）の特定の設定方法が存在しない。
- ・得られた結合荷重・ネットワーク構造の解釈が一般には困難である^{〔#〕}。

（ここで〔#〕印は一般的にも知られる特徴）

4. モデル相互の検討と結合モデルの提案

ここでは、各モデルの持つ特徴を比較・整理するとともに、具体的な応用として各特徴を生かした結合型モデルを提案する。

（1）各モデルの特徴と相互関係

これまでに、3 種類のモデリング手法について述べた。すでに見たように人間の知識をどのような形で蓄積・利用するかという点に方法の相違がある。各方法の特徴を実際のモデリングにおけるいくつかの視点から整理したものが表 - 6 である。

Table 6 Characteristics of the Models

項目	PS	FL	NN
知識保存形式	ルール	ルール	結合荷重
モデル変数	条件	言語	数値
モデル化原理	推論	推論	誤差最小
モデル多様性	多様	多様	画一的
モデル改良	ルールの変更	多数方法あり	学習データの追加

PS モデルと FL モデルはルール形式の表現を用いる点では類似するが、程度を持った言語表現を用

いる点では異なる。この言語変数の利用はモデルの多様性、改良の容易性を与えるものとなっている。ファジィ推論の算出方法の設定において、特別な場合には従来の推論と同じ結果が算出されることを考慮すると、FLモデルはPSモデルの一般化であるといえる。しかし、モデル化の最終目的が分類・確定的判断などである場合には、PSモデルによるほうが、推論ルール構成や推論演算が簡単になる場合もあると思われる。

さらにNNモデルは、パターン誤差最小原理に基づいて学習を行い、これを結合荷重として保存している。したがって、推計誤差を減少させるという意味では実用的な意味を持つ。しかし構成されたモデルの記述内容を解釈することは難しい。つまりNNモデルはパターン決定に対して高い再現性を持つが、論理的関係を明確にするには至らないことがわかる。

(2) 結合モデルの提案

ここでは、各モデルの特徴を考慮してファジィ推論モデル（FLモデル）の特徴である人間論理の直接的表現とNNモデルの誤差最小原理を組み合わせを提案する。その意味でファジィ・ニューラルネットワークモデルと呼ばれるものもある。図-7に本研究で提案する結合モデルの概要を示す。




Fig. 4 The Overview of the Combined Model

ここでは、基本的な論理をFLモデルのルールベースにより推論を行う。つまりモデルの最初の推論結果が通常ファジィ推論と同様、出力ファジィ数分布が求められる。この出力ファジィ数の実用的利用には、推計量としての非ファジィ化手順の定義が必要である（通常のFLモデルでは、重心法、中心法等）。この結合モデルでは以上の推論判断と実際の経路選択結果との整合性を持たせるためNNモデルを利用している。すなわち主要な推論をファジィ

推論で行うとともに、この結果を用いた妥当な意思決定結果としての合成数値の算出をNNによって行うことになる。つまり知識はFLモデルのルールベースとNNモデルの結合荷重に同時に保存されることになる。表-7に結合モデルによる各サンプルの推計結果を示している。

Table 7 Result of the Combined Model

No.	P ₁	FL	Concl.	No.	P ₁	FL	Concl.
1	0	S	0.002	12	1	L	0.999
2	0	ML	0.048	13	1	S	0.001 ←
3	1	ML	0.999	14	0	M	0.001
4	0	M	0.001	15	1	L	0.999
5	0	SM	0.001	16	1	ML	0.969
6	1	L	0.999	17	0	S	0.001
7	1	M	0.999	18	1	ML	0.990
8	0	S	0.012	19	1	ML	0.964
9	0	M	0.001	20	0	S	0.011
10	0	S	0.003	21	1	L	0.999
11	0	S	0.015				

本表では、結合モデルより算出されるファジィ推論の結果と最終的な選択率推計結果が示されている。ファジィ推論の結果は、S、M、L（小、中、大）あるいはこの組み合わせで示されている。経路選択の傾向を言語表現した結果であるともいえる。

また最終的な結果は、NNモデルの場合と同様な修正計算（修正モーメント法）を実行したものである。NNモデルの形状は、図中に示されているように、入力層3・中間層2・出力層1となり、前述のNNより若干大きい。したがって、十分な収束状況を得るための計算回数も増加する。この例では、800回の繰り返し計算の後、誤差変化がほぼなくなった結果を用いている。表-7において、サンプルNo. 13が誤判別になっている他は、実績値と異なる結果を与えるものはない。またFLモデルでML（確率が中か大：誤判別）と判断されたサンプルNo. 2は、NNモデルによって、選択確率が小さく推計されている。推計誤差 ϵ は、1.178であり、単純なNNモデルを用いた場合の誤差より大きくなるが、BLモデル、FLモデルに比べて良好である。

このような点から、ファジィ推論により基本判断を記述し、推論結果をNNで実用的推計値に修正するという目的が達成されている。

現実的な応用例を考えると、たとえば運転者に経

路情報が与えられる場合などに本モデルは有効である。つまり交通情報が利用者意識に与える定性的（全体的）な傾向を知るには、ファジィ推論の結果が有効である。また最終的な経路選択結果を正確に予測するためにはNNモデルの結果が有効であろう。

5. おわりに

本研究では経路選択問題を検討する場合の知識利用型の各種モデリング手法について比較検討を行った。各章では各モデルの構成法と算出結果の要点を述べた。特にロジットモデルに代表される非集計型モデルと比較を行うとともに、3種類の方法相互の関係とモデルの結合についても議論した。

経路選択など人間の意思決定過程を含むモデリングを考える場合、統計的に個人相互の判断の相違を考慮する方法が知られている。交通量推計問題など統計的な推計結果を得る場合には有効な方法である。

これに対して、知識ベースを用いた方法は、必ずしも合理的決定を行うとは限らない人間の意思決定過程を表現しようとしたものである。したがって各モデリングの方法は異なるが、その目指すところは類似している。個人行動の実際的記述に適した方法であるといえる。これらの方法の持つ特徴を整理・理解することで、交通行動分析の局面に応じた方法も有効に適用できることがわかる。

本研究で用いた少数サンプルは、本来非集計モデル推計用のものである²⁾。したがって、現実データ利用時に同様の結果が得られるとは限らない。しかし一般的に現実問題では、本例よりさらに非線形性の強いデータの解析が必要であろうから、ここに示した各方法の有用性は一層期待できるものである。

PSモデル・FLモデルの中心的概念である「推論」は言語表現での人間行動をモデル化であり、またNNモデル（神経回路網）は人間のパターン認識としてのモデル化である。たとえば、行動原理から実際の選択結果にいたる推論を表現するためにはFLモデルが有効である。一般的に推論がいくつかの段階に分かれる場合にも「多段推論プロセス」により同様のモデル化が可能である。一方、利用者行動パターンを同時に複数考慮する場合（多項選択のモデル化）には、NNモデルのパターン再現性が有効に機能するものと思われる。

また本研究では、ファジィ推論とニューラルネットワークの結合方法のひとつを述べた。しかしファジィニューラルネットワークモデルの構成方法には多くの方法が知られている。実際のモデル化においては、さらに構成方法について検討が必要である。

さらに、本研究で述べた人間の知識を利用したモデリングは、個人の意思決定における不確実な状況を表現する場合に有効であると思われる。しかし、個人相互の相違や経路選択交通量の集計化し、実際の交通問題に適用することを考えると、統計的手法との結合も考えることが必要である。

この点については、経路旅行時間の確率ファジィ数（Random Fuzzy Number）の取扱いも検討されており⁷⁾、推論システムとの結合も考えられる。

最後に本研究は、ロンドン大学交通研究所（University of London, CTS）およびダルムシュタット工科大学（Technische Hochschule Darmstadt）に滞在中に取りまとめたものである。執筆の機会を提供して頂いたR. E. Allsop教授、H. G. Retzko教授をはじめ両大学の諸兄に感謝の意を表します。

参 考 文 献

- 1) 秋山孝正：ファジィ理論の土木計画分野における適用に関する整理と展望，土木学会論文集，第395号/IV-9，pp. 23-32，1988.
- 2) 森杉壽芳：非集計モデルの推定と検定，土木計画学講習会テキスト15，pp. 25-66，土木学会，1984.
- 3) 秋山孝正・佐佐木綱：ファジィ推論と交通行動の記述，交通工学，Vol. 23，No. 3 pp. 21-27，1988.
- 4) 秋山孝正：阪神高速道路の交通制御エキスパートシステム，人工知能学会研究会資料集18，pp. 115-124，1991.
- 5) Akiyama, T. et al.: Traffic Diversion Model on Urban Expressway by Fuzzy Reasoning. The paper presented at the 5th World Conference of Transport Research, 1992, June.
- 6) 中野馨監修：入門と実習 ニューロコンピュータ，技術評論社，1989.
- 7) Akiyama, T. and Shao, C.: Motorist Behaviour on Motorways with Fuzzy Traffic Information, Proc. of the 5th IFSA World Congress, pp. 660-663，1993.