

# 交通行動記述のためのファジィ・ニューロモデル

## Fuzzy-Neural Network Models for Description of Travel Behaviour

坪井 兵太\* 秋山 孝正\*\*

By Hyoto TSUBOI and Takamasa AKIYAMA

### 1. はじめに

昨今、都市内道路網の管理において、交通情報の利用は重要な課題である。特に広域的な道路網に対する有効な経路情報提供は、情報サービス・交通円滑化などの点で重要である。

ここでは、交通情報による交通管理の基礎となる利用者行動分析を行うための方法論を検討する。従来の交通行動記述モデルでは、ロジットモデルなどの関数型選択モデルがあり、これは効用理論を前提とした統計的方法である<sup>1),2)</sup>。また一方で、計算機工学分野の考え方を用い、人間の知識に基づく主観的判断過程をモデル化しようとする方法として、ファジィ推論やニューラルネットワーク(NN)の利用が検討されている<sup>3),4)</sup>。ここで、ランダム性を基本としたモデルでは、将来予測時の不確定性を考慮できる点で有効であると思われる。一方、人間の認知のファジィ性を基本としたモデルは、人間の意思決定プロセスを言語的に表現することが可能となり、この意味で有効であると考えられる。これらは相対するモデル化手法ではなく、多様なモデル表現の可能性を示すものである。

またNNでは、誤差最小化原理に基づく学習過程によって高度なパラメータ調整が実現できる。ファジィ推論との両者の特徴を相互補完的に結合させたものがファジィ・ニューロ(FN)である。これらの組み合わせ形態から多数のモデルが提案されている。

本研究では、ロジットモデルによる交通機関分担推計に対応させ、これらの方法の適用性を検討する。すなわち、各種のFN方法の整理を行い、いくつか

の具体的方法を検討する。これらモデル化手法の推計結果を比較することで、各方法の標準的手順および各モデルの交通行動分析の適用性が検討できる。

### 2. 各種のモデリング方法

ここでは、ファジィ推論モデルとその実用的方法、さらにニューラルネットワークモデルを融合したファジィ・ニューロについて説明する。

#### (1) ファジィ推論モデル

##### (a) ファジィ推論モデルの方法

ファジィ推論の基本的概念は、「IF～THEN…」形式の推論モデルにファジィ変数(言語変数)を導入し、人間のあいまい性を持った推論を行うものである。この推論過程は以下のように定式化される。

$$\int \mu_B(y) / y = \int \sup \left[ \min \{ \mu_A(x), \mu_R(x, y) \} \right] / y \quad \dots \dots \dots (1)$$

$\mu_B(y)$  : ファジィ数Bのメンバシップ関数

$\mu_A(x)$  : ファジィ数Aのメンバシップ関数

$\mu_R(x, y)$  : ファジィ数A・Bから求まった関係Rのメンバシップ関数

ここで、 $\mu_R(x, y)$ はモデル作成時に設定するファジィ関係である。また、 $\mu_A(x)$ は新事実、 $\mu_B(y)$ は新事実から推論される帰結を示している。

ファジィ推論モデルの基本的な構築には、①各言語変数(メンバシップ関数)の決定、②推論の基本的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)の決定、④合成規則の決定、⑤最終的に算出される推論値のファジィ数に関する非ファジィ化(defuzzification)方法の決定という5点に集約できるとされる<sup>4)</sup>。

キーワード：交通行動分析、交通手段選択

\* 学生会員、岐阜大学大学院土木工学科専攻

\*\* 正会員、工博、岐阜大学工学部土木工学科

(〒501-11 岐阜市柳戸1-1)

TEL 058-293-2443 FAX 058-230-1528)

### (b) 簡略ファジィ推論モデル

つぎに実用的な推論方法として、簡略ファジィ推論モデルを説明する。これは、演算時間の容易性、モデル化の簡潔さと計算の高速化を目指している。この方法は、通常のファジィ推論の手順のうち、推論ルールの帰結部におけるファジィ数をクリスピ数(確定値)とする方法である。つまり、図1のように推論規則が与えられるとき、簡略ファジィ推論の演算手順は次のように表すことができる。

① 各規則の適合度  $h_i$  を  $\min$  計算を用いて求める。

$$h_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad \dots \dots \dots (2)$$

② 後件部の定数  $C_i$  を適合度  $h_i$  で荷重平均して推論結果  $Z^*$  を算出する。

$$Z^* = \sum_{i=1}^n \frac{h_i C_i}{h_i} \quad \dots \dots \dots (3)$$

すなわち、推論結果は、後件部の定数  $C_i$  を適合度  $h_i$  で荷重平均したものである。この簡略ファジィ推論を用いると、重心計算などの非ファジィ化手順が除かれるため全体の計算が簡単になる。

## (2) ファジィ・ニューロモデル

### (a) ファジィ・ニューロモデルの分類

ファジィ推論では、メンバシップ関数の設定やルール構成の調整方法が課題となっている。また、ニューラルネットワーク(NN)モデルでは、モデルに記述された意思決定の論理的構造を明確に示すことが難しい。これらの課題に対し、両者を相互的に補完させて問題解決を図ることのできるファジィ・ニューロモデルが提案されている。

このとき、基本とするモデルをファジィ推論とするか、NNとするかによって、組み合わせ形態が各種提案されている。特に両者の融合度という点から、11種類に分類した研究がある<sup>5),6)</sup>。この分類では、融合度の低い「ニューロ&ファジィ」(並列に各モデルを配置したもの)から融合度の高い「ニューロ化ファジィ」(一部をファジィ化したニューラルネットワ

Rule 1: IF x is A<sub>1</sub> and y is B<sub>1</sub> THEN z is C<sub>1</sub>

Rule 2: IF x is A<sub>2</sub> and y is B<sub>2</sub> THEN z is C<sub>2</sub>

Rule n: IF x is A<sub>n</sub> and y is B<sub>n</sub> THEN z is C<sub>n</sub>

i: ルール数 (i=1,2,...,n)  
A<sub>i</sub>, B<sub>i</sub>: ファジィ数 C<sub>i</sub>: クリスピ数

図1 簡略ファジィ推論モデルのルール構成

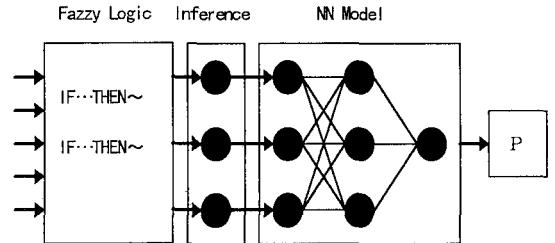


図2 ファジィーニューロモデルの概念図

ーク)まで、モデル構造的な相違が示されている。

本研究では、これらの中間的な位置にある「ファジィーニューロ」と、比較的融合度が高いとされている「ファジィ的ニューロ」について紹介する。

### (b) ファジィーニューロ

ここで、「ファジィーニューロ」モデルとは、ファジィ推論ルールを用いて推論を行い、その結果をニューラルネットワークを用いて処理するもので、直列型のファジィ・ニューロモデルである。

このタイプのモデルにも様々なものがある。本研究のモデルは、図2に示すように、既存研究で用いられたファジィ推論の出力をニューラルネットワークの入力とした構造モデルである<sup>6)</sup>。

すなわち、各要因から全体的な判断を行う部分がファジィ推論で記述され、ファジィ推論プロセスでいう非ファジィ化部分がNNモデルとなっている。このため、各推論判断が非線型的に統合され、最終的な確定値が定められる。

### (c) ファジィ的ニューロ

つぎに、「ファジィ的ニューロ」モデルとは、本質的にはNNモデルであるが、ファジィルール的構造を表現できるようなネットワークを構成している。つまり、ファジィ推論やファジィ制御における計算

過程の表現を、学習機能によって新たに提案するモデルである。したがって、NNは前件部メンバシップ関数とファジィルールを表現し、学習後の出力値は、ファジィ制御の推論値を表している。

具体的な「ファジィ的ニューロ」については様々な研究が行われており、多数のモデルが提案されている。ここでは、その中でも前件部メンバシップ関数にシグモイド関数を利用したモデルを紹介する<sup>7)</sup>。

ここで、前件部メンバシップ関数とは、推論ルールの前件部におけるファジィ言語変数を関数化したものである。

図3はモデル概念図であり、2入力1出力の場合のネットワーク構成例を示している。また、このモデルでは、図4に示すような3種類の前件部メンバシップ関数を、第[1]層から第[4]層で構成している。つまり、次式のようなシグモイド関数を用いた関数によって表現される。

$$A_{ij}(x_j) = \frac{1}{1 + \exp\{-w_b(x_j - w_a)\}} \quad \dots \dots (4)$$

$A_{ij}(x_j)$ :メンバシップ関数

すなわち、結合荷重  $w_a, w_b$  は、シグモイド関数の中心位置および傾きを定めるパラメータである。また、ネットワーク内の結合荷重  $w_a, w_b$  を各シグモイド関数ごとに値を設定すれば、前件部メンバシップ関数  $A_{1j}(x_j), A_{2j}(x_j), A_{3j}(x_j)$  を実現できる。

ただし、擬似台形型メンバシップ関数  $A_{2j}(x_j)$  については、[3]～[4]層間の結合荷重 1, -1 と [4] 層の  $\Sigma$  の記号を持つユニットから、符号の異なる2種類のシグモイド関数の和で構成される。また、図3のような入力  $x_1, x_2$  に対し、それぞれ3種類の前件部メンバシップ関数を持つこととなる。

ここで、各ルールでの前件部適合度  $\mu_i$  は、第[5]層で求まる。つまり、各ルールごとで、第[4]層の出力である前件部メンバシップ値を、次式のように積することで算出できる。

$$\mu_i = \prod_j A_{ij}(x_j) \quad \dots \dots (5)$$

$\mu_i$ :前件部適合度

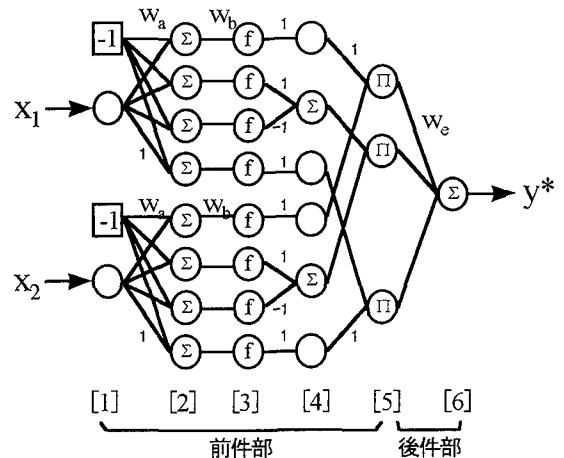


図3 ファジィ的ニューロモデルの概念図<sup>8)</sup>

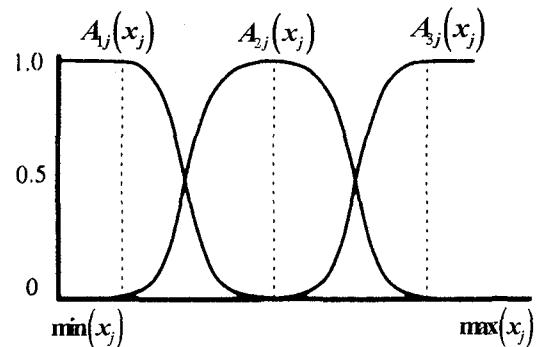


図4 シグモイド関数で表現されたメンバシップ関数

第[6]層において、第[5]層で求められた各ルールの前件部適合度と、結合荷重である後件部実数値  $w_e$  との荷重平均から、次式を用いて出力値つまり簡略ファジィ推論の推論値を推定している。

$$y^* = \frac{\sum_i \mu_i w_{ei}}{\sum_i \mu_i} \quad \dots \dots (6)$$

$w_{ei}$ :後件部実数値

本モデルでは、NNにおけるBP(バックプロパゲーション)法の学習によって結合荷重  $w_a, w_b, w_e$  が変化する。これによって、推論ルールの前件部メンバシップ関数の形状および後件部実数値が調整される。つまり、この「ファジィ的ニューロモデル」では、簡略ファジィ推論の実現を図っている。

### 3. 各種モデルの比較

ここでは、ファジィ・ニューロモデルの交通行動分析モデルとしての利用可能性について、各種モデルとの比較により検討を行う。

ここで、①ロジットモデル：BL、②ファジィ推論（マムダニ法）：FL、③簡略ファジィ推論：SFL、④ニューラルネットワーク：NN、⑤ファジィーニューロ：FN1、⑥ファジィ的ニューロ：FN2 の 6 種類のモデル作成を行い、それぞれの適用性を検討した。

#### （1）対象モデルの作成

ここでは、各種モデルの特徴が明確になるように、典型的なバスと自動車に対する二項型の交通手段選択問題をとりあげた。特にここでは、既存研究よりロジットモデル作成のためのサンプルデータを用いた<sup>9)</sup>。本例では、サンプル数が 30 個であり、説明要因は以下の 4 説明変数である。

- ① 乗車時間： $x_1$
- ② 乗車外時間/OD 距離： $x_2$   
乗車外時間（バス：バス待ち時間+徒歩時間、自動車：徒歩時間）
- ③ 費用： $x_3$
- ④ 専用自動車の有無： $x_4$   
(自分専用=1、家族と共有=0)

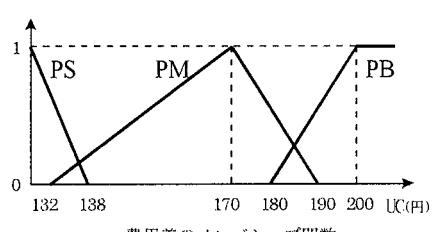
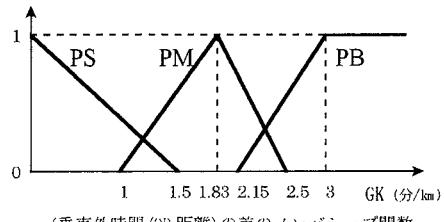
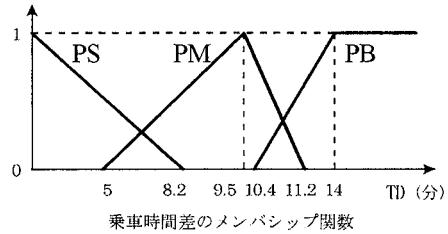
ここで、今回用いたデータは、乱数発生によりランダム性を持つサンプルが生成されている。したがって BL モデルによる適合率は  $r=0.76$  と高い。現実的なデータセットにおいてはランダムでないデータ群も観察されることがあると考えられ、その意味で BL モデルの適合性は低下する場合も想定される。本研究で用いた FL、NN モデルは必ずしもランダムデータを対象としておらず、このような場合においてもある程度の適合率を持つものと考えられる。

#### （2）既存手法によるモデル作成

既存モデルとして、簡単で有効性の高い従来型であるロジットモデル、人間の意思決定過程を記述できるファジィ推論モデルの 2 手法を考える。

R-1: IF  $x_1$  is PM and  $x_2$  is PB and  $x_3$  is PS THEN P is PVS  
 R-2: IF  $x_1$  is PM and  $x_2$  is PS THEN P is PVS  
 R-3: IF  $x_1$  is PB and  $x_2$  is PM THEN P is PSM  
 R-4: IF  $x_1$  is PM and  $x_2$  is PM and  $x_3$  is PM THEN P is PME  
 R-5: IF  $x_1$  is PM and  $x_2$  is PB and  $x_3$  is PB THEN P is PBG  
 R-6: IF  $x_1$  is PS and  $x_2$  is PS THEN P is PVB  
 R-7: IF  $x_1$  is PB and  $x_2$  is PS and  $x_3$  is PB THEN P is PVB  
 R-8: IF  $x_4$  is PB THEN P is PVS  
 PS: Positive Small PM: Positive Medium PB: Positive Big  
 PVS: Positive VERY SMALL=0 PSM: Positive SMALL=0.25  
 PME: Positive MEDIUM=0.5 PBG: Positive BIG=0.75  
 PVB: Positive VERY BIG=1 P: パス選択確率

図 5 SML モデルのルール構成



TD: 乗車時間差 GK: (乗車外時間/OD 距離)の差 UC: 費用差  
図 6 SML モデルの各説明変数メンバシップ関数

まず、ロジットモデルでは、各交通手段の効用関数から指數関数を用いた関数で交通手段選択確率が以下のように表現される。

$$V_{bus} = \theta_1 x_{1bus} + \theta_2 x_{2bus} + \theta_3 x_{3bus} \quad \dots \dots \dots (7)$$

$$V_{car} = \theta_1 x_{1car} + \theta_2 x_{2car} + \theta_3 x_{3car} + \theta_4 x_4 \quad \dots \dots \dots (8)$$

$$P_{bus} = \frac{\exp(V_{bus})}{\exp(V_{car}) + \exp(V_{bus})} \quad \dots \dots \dots (9)$$

$$P_{car} = 1 - P_{bus} \quad \dots\dots\dots(10)$$

$V_{bus}, V_{car}$  : バス、自動車の効用

$P_{bus}, P_{car}$  : バス、自動車の選択確率

$\theta_1, \theta_2, \theta_3, \theta_4$  : パラメータ

このとき、統計的に閾数型を決定するには、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、 $\theta_1 = -0.1072$ ,  $\theta_2 = -0.4168$ ,  $\theta_3 = -0.0128$ ,  $\theta_4 = 1.400$  となっている。この結果、各サンプルの選択確率の推計値が求められる。

またここでは、通常のファジィ推論・簡略ファジィ推論の具体的な作成手順は省略するが、いずれもルール数は同数で、ロジットモデル作成で用いられた説明変数によってファジィルールが構成される。また、推論ルールやメンバシップ関数のパラメータ値が試行錯誤によって決定される。図5、図6ではSMLモデルによるルール構成、各説明変数における前件部メンバシップ関数をそれぞれ示している。図5では前件部に対して3種類、後件部についても5種類の言語変数(ラベル)が設定されている。

### (3) ファジィ・ニューロモデル

(a) ファジィーニューロモデル：FN 1

つぎに、本研究でのファジィーニューロモデルを作成する上で、その概略を以下に示す。

- ①マムダニ法によるファジイ推論モデルのメンバシップ関数、ルール構成は前述で作成したものをそのまま用いる。
  - ②各ルールから、算出される後件部の3つの言語変数 SMALL, MEDIUM, LARGE の三角形の分布が min 計算によって切断される。
  - ③各ルールごとの SMALL, MEDIUM, LARGE に対応するファジイ出力の分布面積（推論結果メンバシップ関数）を、ラベルごとに総和する。
  - ④全てのサンプルについて③の計算を行う。
  - ⑤各データのラベルごとの分布面積を NN モデルの入力値として、最終的な出力結果を求める。

ここで、NNモデルのパラメータ決定において、推計誤差が 3.5 よりも小さくなった時、もしくは、繰り返し計算を 2000 回行った時を、収束判定基準と

R-1:IF  $x_1$  is PM and  $x_2$  is PB and  $x_3$  is PS THEN P is 0  
 R-2:IF  $x_1$  is PM and  $x_2$  is PS THEN P is 0.486  
 R-3:IF  $x_1$  is PB and  $x_2$  is PM THEN P is 0.475  
 R-4:IF  $x_1$  is PM and  $x_2$  is PM and  $x_3$  is PM THEN P is 0  
 R-5:IF  $x_1$  is PM and  $x_2$  is PB and  $x_3$  is PB THEN P is 0.566  
 R-6:IF  $x_1$  is PS and  $x_2$  is PS THEN P is 0.987  
 R-7:IF  $x_1$  is PB and  $x_2$  is PS and  $x_3$  is PB THEN P is 0.999  
 R-8:IF  $x_4$  is PB THEN P is 0.124

PS:Positive Small PM:Positive Medium PB:Positive Big

図7 FN2モデルのルール構成

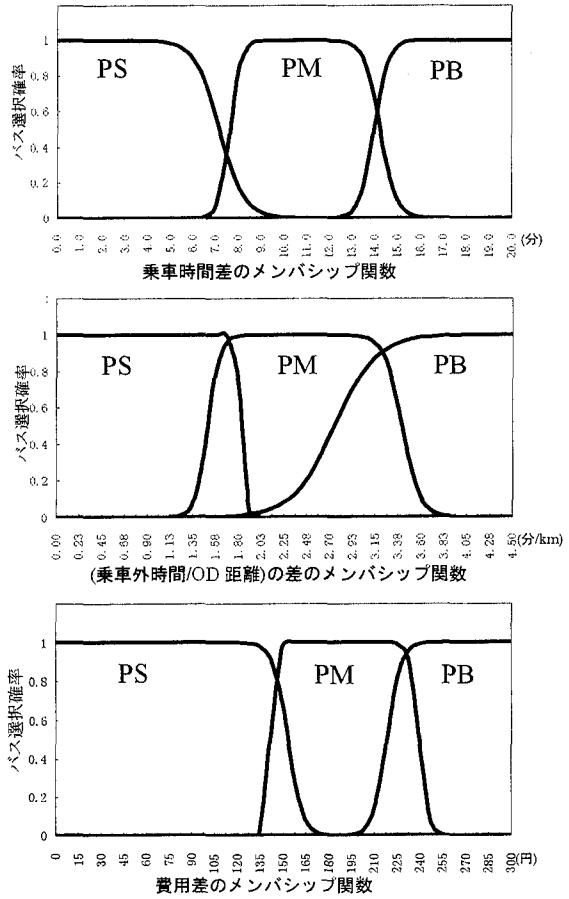


図8 FN2モデルの各説明変数メンバシップ関数

した。この結果、繰り返し回数が 1746 回のとき推計誤差が 3.5 以下となったので計算を終了した。

### (b) ファジィ的ニューロモデル：FN 2

ここでのモデルは、4入力1出力のネットワーク構造となっており、また、前件部のルール構成においては、SMLモデルと同一である。

表1 各モデルの特徴と推計結果

項目	BL	FL	SFL	NN	FN1	FN2
知識保存形式	推定係数	ルール	ルール	結合荷重	ルール・結合荷重	ルール・結合荷重
モデル変数	数値変数	言語変数	言語変数	数値変数	言語・数値変数	数値変数
モデル化原理	ランダム効用理論	推論	推論	誤差最小	推論・誤差最小	誤差最小
推論方式	マムダニ	簡略推論	マムダニ	簡略推論	マムダニ	簡略推論
パラメータ決定法	最尤推定	試行錯誤	試行錯誤	B P 法	試行錯誤・B P 法	B P 法
パラメータ数	4	18	18	19	33	32
推計誤差 $\epsilon$	9.4	7.027	6.920	2.08	3.489	8.169
判別指標 $\delta$	8.573	10.817	12.000	13.72	12.555	8.3423
適合率 $\gamma$	0.767	0.767	0.800	0.967	0.933	0.833

ここで、ファジィルール同定における学習では、結合荷重  $w_a, w_b, w_e$  の初期値を設定して計算を行う。つまり、結合荷重  $w_a, w_b$  は、学習データにおける入力値の最小値から最大値までを台集合として、この台集合上に前件部メンバシップ関数が等間隔に配置されるように初期設定する。また、後件部実数値ではバス選択確率を表しているので、各ルールにおける結合荷重  $w_e$  の値を 0.5 に初期設定する。

本モデルにおけるパラメータは、B P 法によって決定される。ここで、1000 回の繰り返し計算で得られた各パラメータ値から図 7、図 8 に示すルール構成と前件部メンバシップ関数の形状が決められる。

#### (4) 推計精度の検討指標

ここで、推計された交通手段選択モデルの適合性を検討するために、いくつかの指標を考える。

まず、通常の適合指標を考える。ここでは、 $P_{bus} > 0.5$  であればバスを選択すると考え、各サンプルの判別結果を求める。全サンプル中で正しく判別されたサンプル数の割合を適合率  $\gamma$  とする。また、各サンプルの実績選択結果 ( $R_i$ ) と推定結果の整合性を数値的に示す推計誤差を  $\epsilon$  とする。

さらに、推計された選択確率の分離状態を示す判別指標を  $\delta$  とする。これらの指標は、それぞれ次式のように定義できる。

$$\gamma = C / n \quad \dots\dots(10)$$

$$\epsilon = \sum_{i=1}^n |R_i - P_{bus_i}| \quad \dots\dots(11)$$

$$\delta = \sum_{i=1}^n |0.5 - P_{bus_i}| \quad \dots\dots(12)$$

C: 正判別のサンプル数 n: 全サンプル数(n=30)  
 $R_i$ : 実績選択結果  $P_{bus}$ : バス選択確率

#### (5) 計算結果の比較

ここでは、作成したモデルにより得られた推計結果に対する各指標から、各モデルの持つ特徴を比較する。また、モデリング手法には、知識をどのような形で蓄積・適用するかという点に相違がある。

このような各方法の特徴と推計精度を実際のモデリングの視点から整理したものが表 1 である。すなわち、この表では、モデル作成における原理や方法を整理し、モデルによって得られる推計結果に関する評価指標の値を示したものである。

この表より、ファジィ推論、NN モデルのいずれの方法においてもロジットモデルと比べて、良好な推計結果が得られていることがわかる。また、ファジィ推論（簡略ファジィ推論）に対して NN モデルの利用は、推計精度やパラメータ値の自動チューニングの点で改良となることが分かる。

なかでも、作成した「ファジィニューロ(FN1)」モデルは、基本的な推論部分として、マムダニ法 (FL) を用いており、モデル構造的な意味では推論プロセスを保持しながら、NN の結合によって推計精

度の向上していることが分かる( $\varepsilon = 7.027 \rightarrow 3.489$ ).

つぎにモデル作成上の問題点を比較検討する. ここで、表1のパラメータ数は、モデル構造の複雑さを示すひとつの指標と考えられる.

ロジットモデル(BL)は効用関数のパラメータ決定がモデル推定となる. したがって、説明要因に対応したパラメータ数を最尤推定法を用いた統計的推定が可能である. その意味で、モデル形式が比較的容易に規定できる. しかしながら、作成されるモデルは一意的である.

一方、ファジィ推論過程をもつモデル群(FL・SMLおよびFN)はメンバシップ関数のパラメータ決定が必要となる. この場合は、ある程度のモデル形状の変更が可能であり、モデルに頑健性を与えるものとなっている. また、近年ではGA(遺伝的アルゴリズム)を利用することで最適なパラメータ決定も可能である.

またNNのプロセスをもつモデル群(NN・FN)においては結合係数をパラメータとして決定する. したがって、決定すべきパラメータ数が最も多いが、モデル作成上はBP(誤差伝搬)法による決定法が確立しており、モデル同定は比較的容易である.

#### 4. おわりに

本研究では、交通行動記述モデルをファジィ推論およびニューラルネットワークにより作成する方法を示すとともに、FNモデルの適用性を検討した.

ファジィ推論(簡略ファジィ推論)モデルの構築にあたって、FNモデルを用いることにより、誤差最小化原理に基づく学習から、推計精度の向上が可能となった. また、パラメータ値の決定では、自動チューニングによる演算時間の短縮が図られた. これらの点でFNモデルの有効性を示すことができた.

今回の例題では、4説明変数、サンプル数30のデータを用いたが、統計的な関数型モデルであるロジットモデルは、比較的解釈の容易な挙動を示すことが分かる. また、モデル構造が推論ルールによって表現されるファジィ推論やファジィ・ニューラルネットワークの現状と展望、日本ファジィ学会誌、Vol.5, No.2, pp.178-190, 1993.

の推計精度を得ることができた. しかしながら、データ数の非常に少ない場合においては、推論ルールの表現の限界から、非現実的な挙動を示すことも観測されるので注意が必要である.

また、前述したようにランダム性を考慮したロジットモデルとファジィ性を基本とした本研究の各モデルは、相対的な意味を持つものではない. したがって、今後両者の利点を融合したハイブリッド型のモデルを作成することも可能である.

ここで、今回の研究成果を踏まえた今後の課題として以下の3点を挙げることができる.

- 1) 本研究の各方法は、多項選択問題にも適用可能である<sup>10), 11)</sup>. しかしながら、具体的なモデル化では、多項化に伴う構造的変更が必要となり、検討の余地がある.
- 2) ファジィ・ニューラルモデル(FN)には、すでにみたように、多数の形態があり、交通行動の現象記述的な意味からの整理が必要である.
- 3) ファジィ推論モデルの構築にはGA<sup>12)</sup>を用いる方法が知られている<sup>13)</sup>. 簡便なパラメータ推計方法の利用可能性が高く、この点の検討も必要である.

なお本研究は、文部省科学研究費補助金・基盤研究成果(C)(2)[課題番号:07650619]による研究成果の一部であることを付記します. また、数種のファジィ・ニューラルモデル開発等、本研究に多大な貢献を頂いた松浦貴宏氏に心から感謝の意を表します.

#### 【参考文献】

- 1) 原田昇、森川高行、屋井鉄雄: 交通行動分析の展開と課題、土木学会論文集、No.470/IV-20, pp.47-56, 1993.
- 2) 木村誠司、藤井聰、北村隆一: 選択構造の固有性を考慮した個人の交通機関および目的地選択モデルの構築、土木学会第50回年次学術講演会講演概要集第4部, pp.164-165, 1993.
- 3) 秋山孝正: ファジィ理論による経路選択行動のモデル化、第10回ファジィシステムシンポジウム講演論文集, pp.723-726, 1994.
- 4) 秋山孝正: 知識利用型の経路選択モデル化手法、土木計画学研究・論文集、No.11, pp.65-72, 1993.
- 5) 林勲、馬野元秀: ファジィ・ニューラルネットワークの現状と展望、日本ファジィ学会誌、Vol.5, No.2, pp.178-190, 1993.
- 6) 坂和正敏、馬野元秀、大里有生: ソフトコンピューテ

- イング用語集, 朝倉書店, 1996.
- 7) 秋山孝正: ファジィ理論を用いた道路交通流解析, 土木計画学研究・論文集, No. 11, pp. 13-28, 1993.
- 8) 堀川慎一, 古橋武, 内川嘉樹: ファジィニューラルネットワークの構成法と学習法, 日本ファジィ学会誌, Vol. 4, No. 5, pp. 906-928, 1992.
- 9) 浅野光行: やさしい非集計分析, 4. 非集計モデルの計算手順, 交通工学, No. 26, No. 5, pp. 37-41, 1991.
- 10) 松浦貴宏, 秋山孝正: ファジィ・ニューロモデルを用いた交通行動記述について, 第4回ファジィ土木応用シンポジウム講演論文集, pp. 39-46, 1997.
- 11) 秋山孝正, 坪井兵太, 松浦貴宏: ファジィ・ニューロモデルによる経路選択行動の分析, 第13回ファジィシステムシンポジウム講演論文集, pp. 219-220, 1997.
- 12) 伊庭斎志: 遺伝的アルゴリズムの基礎 -GAの謎を解く-, オーム社, 1994.
- 13) 秋山孝正, 安藤彰記: 遺伝的アルゴリズムを用いたファジィ推論による交通行動モデルの作成, 第2回ファジィ土木応用シンポジウム講演論文集, pp. 86-94, 1994.

---

### 交通行動記述のためのファジィ・ニューロモデル

坪井兵太 秋山孝正

交通行動記述モデルとして、効用理論を前提とした統計的方法であるロジットモデルなどの関数型モデルや、人間の知識に基づく主観的判断過程をモデル化するファジィ推論やNNモデルがある。

また近年では、ファジィ推論とNNの各々の特徴を相互補完的に結合させたファジィ・ニューラルネットワーク(FN)によるモデル化手法が各種提案され、多くの成果を挙げている。

本研究では、各種のFN方法の整理を行うとともに、ロジットモデル作成用データに対して、FNモデルを中心としたモデル化を行う。そして、各手法の推計結果を比較することで、標準的手順および各モデルの交通行動分析への適用性が検討できる。

---

### Fuzzy-Neural Network Models for Description of Travel Behaviour

Hyota TSUBOI and Takamasa AKIYAMA

Statics approaches based on random utility theory such as logit model have been used for description of travel behaviour. Fuzzy reasoning and neural network have been introduced as recent applicable techniques as well. Recently, many fuzzy neural network models to integrate their advantages have been proposed. And these models are reported to provide good performance in some fields.

In this study, models for the choice behaviour description with fuzzy neural networks are proposed. Moreover, some other models are applied to the same sample data prepared for establishment of logit model. The general step of model building can be mentioned and applicability of each model is discussed from the result of comparison.

---