

## 非線形効用関数を持つロジットモデル： ニューラルネットワークによる効用関数を例に\*

A Logit Model with Non-Linear Utility Functions: The Exemplum of Utility Functions consisting of Neural Networks

中山晶一朗\*\*・高山純一\*\*\*・山下裕一朗\*\*\*\*

by Shoichiro NAKAYAMA\*\*, Jun-ichi TAKAYAMA\*\*\*, Yuichiro YAMASHITA\*\*\*\*

### 1. はじめに

ロジットモデル<sup>1)2)</sup>が世に紹介されてから、四半世紀が過ぎたが、その間、交通行動分析の分野において、ロジットモデルは不動に地位を築いたと言える。これまでのロジットモデルは、線形な効用関数を持つものがほとんどであった。関数のうちでもっとも単純なものが線形関数であり、その取り扱い是非線形なものに比べて格段に容易である。また、効用関数を線形関数に限定すると、尤度関数の凸性が保障され、Newton-Raphson 法等により、パラメータを容易に求めることができる。このような理論上の利点により、これまでのロジットモデルでは、線形な効用関数を用いることがほとんどであった。しかし、線形効用関数を用いることができるのは、個々の説明変数が独立に、そして、その値に比例して効用に影響する場合に限定される。このような仮定が厳密に成立する現象はそれほど多くないと思われる。そのような仮定が成立せず、変数が複雑に作用する場合に、線形効用関数を適用すると、個々の変数がどのように作用するのかや変数間の関係が適切に捉えられないばかりでなく、誤った分析結果を導く恐れもある。このように考えると、非線形効用関数を持つロジットモデルを考えることの重要性を改めて認識することが出来る。

非線形な効用関数を持つロジットモデルを考える場合、尤度関数の凸性が保証されないため、パラメータをどのように推定すればよいのかが問題となる。そこで、本研究では、凸性が保証されない複雑な尤度関数を持つ場合のパラメータ推定法を提案する。

非線形関数は数限りなく存在するが、本研究では、非線形効用関数として、ニューラルネットワークによる関数を用いる。ニューラルネットワークはネットワークの形状により、様々な形状・特性の関数を作り出すことが出来るため、非常に便利である。

本研究では、まず、効用関数が非線形な場合のロジットモデルでのパラメータの推計方法を提案する。そして、非線形関数の一つであるニューラルネットワークを用いた効用関数を持つロジットモデルを構築する。さらに、道路合流部における車両走行データを用いて、構築したモデルの有効性等の検討を行う。その際、同じデータを通常の線形効用関数をもつロジットモデルにも適用し、本研究で構築したモデルとの比較検討を行う。

### 2. ニューラルネットワーク型効用関数

#### (1) ニューラルネットワークの特徴

ニューラルネットワーク (Neural Network) とは、人間の脳の構造を模擬して作られた情報処理機構である。人間の脳は、「ニューロン」と呼ばれる神経細胞の組み合わせた構造 (神経回路網) で構成される。そのニューラルネットワークモデルはパターン認識や制御、診断問題、予測・予知、最適化問題、信号処理など、非常に広い分野で実際に用いられ、交通工学の分野でも、いくつかの研究がある<sup>3)7)</sup>。

ニューラルネットワークは、ニューロン (ノード) を多数組み合わせ、ニューロン (ノード) 間の接続に重み (結合荷重) を付加することで情報処理を行う。ニューラルネットワークでは、通常、設定したモデルに入力データを与え、その出力結果と教師信号 (入力データに対して正解と考えられる値) とを比較し、その誤差をできるだけ小さくなるように重みを修正していく。

本研究では、ニューラルネットワークが①変数

\*キーワード：ニューラルネットワーク、ロジットモデル、非線形効用関数

\*\*正会員，博(工) 金沢大学工学部土木建設工学科  
金沢市小立野 2-40-20, TEL: 076-234-4614  
E-mail: snakayama@t.kanazawa-u.ac.jp

\*\*\*正会員，工博，金沢大学工学部土木建設工学科

\*\*\*\*学生員，金沢大学大学院自然科学研究科環境基盤基礎工学専攻

間の非線形な関係を考慮した解析が可能（各変数は独立であるとは限定しない）②汎化能力が高いこと（モデルに柔軟性があり，他の問題やモデルに適用しやすい），という特長に着目する。ただし，ニューラルネットワークはモデルの意味付けが難しい場合もあるという欠点があるが，これは，汎用性の裏返しでもあると考えられる。しかし，どのような現象であるのかが事前に良くわからない場合，機械的にニューラルネットワークの形状（ノード数など）を変化させるだけで，様々な形状・特性の効用関数をつくりだすことができることは，モデルを構築する際，非常に便利である。変数がそれほど多くない場合は，このようにして構築したニューラルネットワークモデルの特性を調べることは比較的容易である。

これまでにも線形でない効用関数を用いたロジットモデルの構築はなされてきている。経済学で用いられるCES関数等を用いたモデル<sup>8)</sup>，心理学で研究されている辞書編纂型など非補償型の意思決定を記述するモデル<sup>9)10)</sup>が提案されている。このような定式化は，事前に行動特性が分かっている場合やそれを限定できる場合であり，その特性に合わせた効用関数を用いることが可能であると同時に，そのような定式化が適切であると考えられる。このような場合にはニューラルネットワークを適用する必然性は少ないと思われる。逆に，事前に行動特性を予測することが難しい場合等に汎用性の高いニューラルネットワークを適用する意義が大きいと考えられる。

予測モデルを構築する場合，モデルの意味付けはそれほど重要ではないことが多く，ニューラルネットワークが有効なことが多いと思われる。線形効用関数の適用がどのような場合でも適切であるとは限らないのと同様，ニューラルネットワーク型非線効用関数もどのような場合でも適切ではなく，ニューラルネットワークの汎用性はあるが，意味付けが難しいという特性を考慮して，それを用いるのが適切かを検討する必要があると言える。

## （２）階層型ニューラルネットワークの概要

本研究では，階層型ニューラルネットワークを用いるが，階層型ニューラルネットワークとは，人間の神経細胞の人工的なモデルであるニューロン（ノード）が層状にグループ化され，信号がグループ間を特定の方向にのみ伝わる構造のネットワークである。一つのノードは多入力１出力であ




図1 3層型ニューラルネットワークの模式図

る（複数のノードに出力する場合は各ノードに同じ値を出力する）。階層型ニューラルネットワークは，入力層と出力層の間に中間層と呼ばれるいくつかの隠れ層をもつ多層構造をしているのが特徴である（図1参照）。

階層型ニューラルネットワークでは，入力層のノードは，ネットワークの外部からの入力信号を受け取り，出力層のノードは，ネットワークの外部に出力信号を送る。中間層のノードは，入力層（あるいは下位の中間層）のノードからの信号を受け取り，出力層（あるいは上位の中間層）に信号を送り出すことになる。このような階層構造のニューラルネットワークにおいては，入力信号として与えられた入力値は，順次前進しながら各層のノード（ニューロン）で処理され，最終的に出力層から，情報処理の結果としての出力値が外部に出力される。ここで，処理というのは，中間層及び出力層において，下位の層の各ノードから出された値の荷重和を出力関数により変換し，次の層へ出力することを言う。この時の荷重（重み）は上で述べたノード間の結合荷重である。出力関数としては，多くの場合，以下に示すシグモイド関数が用いられる。

$$f(X) = \frac{1}{1 + \exp(-X)} \quad (1)$$

ただし， $X$  は下位の層の各ノードから出された値の荷重和である。関数形から分かるように，シグモイド関数は0から1までの値をとる単調増加な関数である。

中間層の数や中間層のノードの数を多くすることにより，ネットワークの目的とする入出力関係の精度を上げることが出来る。その反面，パラメータの増加により，関数形が複雑になり，局所解

に落ち込みやすくなる。入出力間関係の観点からは、一般的には中間層は1層で十分であるとも言われている<sup>11)</sup>。よって、本研究においても設定する中間層は1層のみとする。

### (3) ニューラルネットワーク型効用関数の作成

ロジットモデルでは、ランダム効用理論に基づき、効用が最大となる選択肢が選ばれることになっている。効用  $U$  は、通常、確定効用  $V$  と確率項  $\zeta$  の和  $V + \zeta$  であり、確率項  $\zeta$  はガンベル分布に従っている。この時、選択肢  $i$  が選択される確率は、以下の式で表される。

$$P_i = \frac{\exp(V_i)}{\sum_i \exp(V_i)} \quad (2)$$

ただし、 $P_i$  は選択肢  $i$  が選択される確率、 $V_i$  は選択肢  $i$  の（確定）効用であり、ここでは、個人を意味する添え字  $k$  は省略されている。

従来までの多くのロジットモデルでは、既に述べたように（確定）効用を表すのに線形関数を用いていた。つまり、効用関数  $V_i$  は

$$V_i = \sum_{m=1}^M w_m x_{im} = w_1 x_{i1} + w_2 x_{i2} + \dots + w_M x_{iM} \quad (3)$$

である。ただし、 $x_{im}$  は選択肢  $i$  の  $m$  番目の説明変数である。

本研究では、効用関数を線形関数ではなく、ニューラルネットワークを用いた関数とする。以下に、ニューラルネットワークを組み込んだ効用関数を2種類提案する。

#### (a) ニューラルネットワーク型効用関数 I

入力層のノード数が  $M$ 、中間層のノード数が  $N$  のニューラルネットワークである効用関数を考える。ただし、中間層は1層である。効用関数であるため、このニューラルネットワークの出力は（確定）効用  $V$  であり、出力層のノードは一つになり、図1のような形状となる。ニューラルネットワーク型効用関数 I では、中間層のノードにおける出力関数にシグモイド関数を、出力層のノードにおける出力関数に線形関数を用いる。出力層でシグモイド関数を用いない理由は、出力層からの出力値は（確定）効用であり、出力層でシグモイド関数を用いると、効用が0から1の間に限定されるからである。

このようなニューラルネットワーク型効用関数 I は以下の式のように表現することができる。

$$V_i = \beta + \sum_{n=1}^N w_n \left[ \frac{1}{1 + \exp \left\{ - \left( \alpha_n + \sum_{m=1}^M w_{mn} x_{im} \right) \right\}} \right] \quad (4)$$

ただし、 $\alpha_n$  は各中間層の閾値（定数項）、 $\beta$  は出力層の閾値（定数項）である。 $w_n$  は  $n$  番目の中間層のノードと出力層のノードを結ぶパラメータ（結合荷重）、 $w_{mn}$  は  $m$  番目の入力層のノードと  $n$  番目の中間層のノードを結ぶパラメータである。

#### (b) ニューラルネットワーク型効用関数 II

中間層における出力関数にシグモイド関数を用い、出力層には変形したシグモイド関数を用いるニューラルネットワークを考える。ここで、変形したシグモイド関数とは、シグモイド関数の分子にパラメータ  $\gamma$  を追加した関数  $\gamma/[1 + \exp(-X)]$  である。パラメータ  $\gamma$  は、効用関数が0から1の値に限定されないことを目的として追加されている。この時の効用関数は次式のように表現することができる。

$$V_i = \frac{\gamma}{1 + \exp \left[ - \beta - \sum_{n=1}^N w_n \left[ \frac{1}{1 + \exp \left( - \alpha_n - \sum_{m=1}^M w_{mn} x_{im} \right) \right]} \right]} \quad (5)$$

### 3. パラメータ推定方法

ロジットモデルでは、以下に示す尤度関数が最大となるようにパラメータを推定する。

$$L = \prod_{k=1}^K \prod_{i=1}^I (P_i^k)^{\delta_i^k} \quad (6)$$

ここで、 $L$  は尤度関数、 $\delta_i^k$  は個人  $k$  が選択肢  $i$  を選択した場合は1をとり、選択しなかった場合は0をとる変数である。

既に述べたが、ニューラルネットワークを含め、非線形効用関数を持つロジットモデルでは、一般

に、尤度関数が凸関数であるとは限らず、通常パラメータを求めるために用いられる Newton 法などでは、局所解に陥り、適切に推定することができない。そこで、本研究では、焼きなまし法<sup>11)</sup>

(simulated annealing) を利用したパラメータ推定方法を提案する。

本研究でのパラメータ推定法は、基本的には、勾配 (gradient) に従って順次パラメータを更新していく勾配法に基づいている。つまり、現在のステップのパラメータに、勾配に基づいた修正量を加えながら、繰り返し修正 (更新) が行われる。この過程は次のような式で表すことができる。

$$w_{s+1} = w_s + \Delta w_s \quad (7)$$

ここで、 $w_s$  はステップが  $s$  回目でのパラメータであり、 $\Delta w_s$  が修正量である。本研究では、パラメータの修正量  $\Delta w$  を、次の式で順次決定していく。

$$\Delta w = \eta \frac{\partial L}{\partial w} + \varepsilon \quad (8)$$

ただし、 $\eta$  は正の定数、 $\varepsilon$  は (正規) 乱数であり、ここでは、ステップを意味する添え字  $s$  は省略している。修正量に乱数を加える理由は、パラメータを更新していく際に、局所解に陥ってもそこから脱出して、最適解に到達できるようにするためである。Newton-Raphson 法や通常の勾配法では、一度局所解に陥ってしまうと、そこから脱出することができない。しかし、上のように確率的なゆらぎを導入すると、たとえ局所解に陥ってもゆらぎのため、そこから脱出することが可能である。このような方法は焼きなまし法 (simulated annealing) と呼ばれている。

乱数  $\varepsilon$  は平均値 0、分散  $T(s)$  の正規乱数とする。本研究では、乱数の分散  $T(s)$  を式 (9) によって決める。ただし、 $s$  はパラメータの修正 (更新) のステップ回数である。

$$T(s) = \frac{(0.5)^2}{1+s} \quad (9)$$

これにより、パラメータの更新ステップ回数が増える毎に、乱数  $\varepsilon$  の分散  $T(s)$  は単調に減少、すなわち、確率的ゆらぎが徐々に小さくなり、最終的

には最適解で収束する。このような焼きなましを、十分に長い時間行うことにより、必ず最適解に到達出来ることが証明されている<sup>12)</sup>。

#### 4. 実測データの適用とモデルの比較

##### (1) 適用データの概要

適用するデータは交通事故多発地点 (合流部) における車両の避走挙動に関する調査結果である。調査方法および調査結果についての概要は次の通りである。

調査場所は、国道 1 号線下り奈良野町付近 (京都府) である。調査時間は、午前 7 時～午前 9 時・午後 14 時～午後 16 時の計 4 時間であり、サンプル数は 537 台である。

目的変数は、本線を走行する車両が避走するか、しないのか、という避走の有無である。避走とは、合流する車両が前方もしくは横並びに存在する際、本線走行車 (本線第一車線走行車) がそのまま同じ (第一) 車線を走り続けることなく、第二車線 (追越車線) に進路を変更する挙動のことである。説明変数については、避走行動の判断要因として特に重要と考えられる、「合流車と本線走行車との車尾時間 (間隔)」および「本線走行車の加速度」の 2 つを説明変数として採用する。なお、これら 2 つの変数は数値が大きく異なっているため、-1 から 1 までの値に収まるように、各説明変数データを正規化 (変換) し、モデル推定を行う。

##### (2) モデルの構築

モデル化に際し、個人  $k$  (車両  $k$ ) の効用関数 (効用差関数)  $V^k$  を、次式で示すような選択肢 1 (避走する) と選択肢 2 (避走しない) の効用差とする。

$$V^k = V_1^k - V_2^k \quad (10)$$

したがって、個人  $k$  の選択肢が 1 の場合 (避走する場合) の選択確率は次のようになる。

$$P_1^k = \frac{1}{1 + \exp[-V^k]} \quad (11)$$

また、個人  $k$  の選択肢が 2 の場合 (避走しない場合) の選択確率は次式となる。

$$P_2^* = \frac{1}{1 + \exp[V^*]} \quad (12)$$

比較するロジットモデルは以下の3種類である。

(a) 通常のロジットモデル

次式のような線形効用関数（効用差関数）をもつロジットモデルである。

$$V^k = w_1 x_1^k + w_2 x_2^k + c \quad (13)$$

ただし、 $V^k$  は個人  $k$  における選択肢 1 と選択肢 2 の効用差、 $x_1^k$  は個人  $k$  における合流車と本線走行車との車尾時間、 $x_2^k$  は個人  $k$  における本線走行車の加速度、 $w_1$  及び  $w_2$  はパラメータ、 $c$  は定数項である。

(b) ニューラルネットワーク型ロジットモデル I (以下、NN ロジット I)

次式のような、出力関数にシグモイド関数と線形関数を組み合わせた効用差関数（ニューラルネットワーク型効用関数 I）をもつロジットモデルである。

$$V^k = \beta + \sum_{n=1}^N \frac{w_n}{1 + \exp[-\alpha_n - w_{n1}x_1^k - w_{n2}x_2^k]} \quad (14)$$

ただし、 $w_{n1}$  は 1 番目の入力ノード（合流車と本線走行車との車尾時間）と  $n$  番目の中間層ノードを結ぶパラメータ、 $w_{n2}$  は 2 番目の入力ノード（本線走行車の加速度）と  $n$  番目の中間層ノードを結ぶパラメータ、 $w_n$  は  $n$  番目の中間層ノードと出力層ノードを結ぶパラメータ、 $\alpha_n$  は  $n$  番目の中間層の閾値（定数項）、 $\beta$  は出力層の閾値（定数項）である。図 2 は上の効用関数のネットワークである。




図 2 NN ロジット I の効用関数

(c) ニューラルネットワーク型ロジットモデル II (以下、NN ロジット II)

次式のような、出力関数にシグモイド関数と変形したシグモイド関数を組み合わせ、パラメータ  $\gamma$  を追加した効用関数（ニューラルネットワーク型効用関数 II）をもつロジットモデルである。

$$V_k = \frac{\gamma}{1 + \exp\left[-\beta - \sum_{n=1}^N \frac{w_n}{1 + \exp[-\alpha_n - w_{n1}x_{k1} - w_{n2}x_{k2}]}]\right]} \quad (15)$$

図 3 に式 (15) の効用関数のネットワークを図示する。




図 3 NN ロジット II の効用関数

(3) モデルの推定方法

NN ロジットモデルのパラメータ推定は、既に述べた焼きなまし法を利用した方法を用いている。式 (8) での  $\eta$  には 0.1 を用いた。多数の  $\eta$  を用いて、推定を行ったが、0.1 の場合が最も収束が早そうであることが分かったからである。しかし、これは今回のデータのための知見であり、どのような  $\eta$  を用いればよいのかは今後の研究課題であろう。

収束判定に関しては、今回、パラメータがより良いものに改善されなくなってから、つまり、対数尤度が変化しなくなってから、2000 ステップを経過した時点で、計算を終了した。どの時点で計算を終了するのかに関しても今後検討する必要があると考えられる。

(4) 分析結果

上で述べた 3 種類のモデルの分析結果を表 1 に示す。ここで、表 1 の「ノード数」とは、設定した中間層のノード数を表す。

表 1 の結果から、尤度比に関しては、中間層のノード数が 2 および 3 の場合の NN ロジットは、I および II の両方とも、通常のロジットモデルよりも大幅に良くなっていることが分かる。AIC に関しても、中間層のノード数が 2 および 3 の場合の NN ロジット I および II は、通常ロジットよりも

表1 分析結果

|              | ノード数 | 最終尤度   | 尤度比          | AIC          | 的中率 (%)      |
|--------------|------|--------|--------------|--------------|--------------|
| a)ロジットモデル    |      | -287.1 | 0.229        | 580.2        | 76.35        |
| b)NN ロジット I  | 1    | -283.2 | 0.239        | 576.4        | 76.35        |
|              | 2    | -249.4 | 0.330        | <u>516.8</u> | 78.21        |
|              | 3    | -246.8 | <u>0.337</u> | 519.7        | <u>78.40</u> |
| c)NN ロジット II | 1    | -284.7 | 0.235        | 581.5        | 76.35        |
|              | 2    | -249.2 | 0.330        | 518.4        | 76.35        |
|              | 3    | -247.1 | 0.336        | 522.2        | 76.35        |

大幅に値が減少しており、推定精度が良くなっていることが分かる。的中率については、際立った改善が見られなかったが、NN ロジット I の中間層のノード数が2と3の場合は、約2%ほど通常のロジットモデルよりも的中率が增加している。これらのモデルの中では、AICの結果から、中間層のノード数が2の場合のNN ロジット I が最も良いと考えられる。

以上のように、今回使用したデータに関しては、NN ロジット I 及びIIの両方が有効であり、ニューラルネットワークによる非線形効用関数を持つロジットモデルが有用であることが分かる。

### (5) 推定パラメータとモデル解釈

推定されたパラメータ値とその  $t$  値を図4、図5に示す。図4が通常ロジットの場合であり、図5が最も推定結果が良かった中間層のノード数が2のNN ロジット I である。紙面の都合上、他のNN ロジットに関しては省略する。

ほとんどのパラメータが有意であると推定されているが、有意でないと判断されるパラメータも存在しており、それらを除いたネットワークを再構築することにより、より推定効率の良いモデルを作成する余地もあると思われる。

上で推定した道路合流部における避走挙動の特性・性質を考察するために、避走確率  $P_i$  と各変数（合流車と本線車との車尾時間及び本線車の加速度）の関係について調べる。図6および図7は  $z$  軸に避走確率を、 $x$  軸に合流車と本線車との車尾時間を、 $y$  軸に本線車の加速度をとったグラフである。図6が通常のロジットモデルで推定した結果であり、図7が中間層のノード数が2の場合のNN ロジット I の結果である。

図6より、通常のロジットモデルでは、避走確




図4 通常ロジットモデルのパラメータ値




図5 NN ロジットモデルのパラメータ値

率は平面によって表現されることが分かる。一方、図7から、NN 型ロジットは、曲面で表現されている。このようにNN 型ロジットの方がより詳細な分析結果を出している。

図4のパラメータ値と図6から、車尾時間が小さい場合、つまり、合流車と本線車の距離が小さいと、衝突回避や円滑な走行を続けるなどの理由で、避走する確率が高くなることが分かる。このような特性は図7のNN ロジットからも読み取れる。ただし、図7の場合はその影響が必ずしも比例的（直線的）とはなっていない。

加速度に関しては、図4のパラメータ値から、通常ロジットの推定結果は、それほど影響は大きくないが、加速度が小さいほど、避走する確率が高くなる傾向がある。図6では、そのような傾向があまりみられないが、それは加速度に関するパラメータ値が0.05と低いためと考えられる。NN ロジットの図7では、加速度の避走への影響は、加速度が小さい場合と大きい場合とでは全く異なり、曲面が山型となっている。これは、加速度が小さい場合（減速の場合）、より減速する程、避走を行わず、合流車に道を譲ろうとしていると考えられ、加速度が大きい場合（加速する場合）、より加速する程、避走するのではなく、加速して合流車が合流車線にいる間に合流部を走り抜けようとしていると考えられる。このような加速度の避走行動への山型の影響は線形効用関数ではまったく記述できないものであり、ニューラルネットワークによる非線形効用関数によって記述できるもの




図6 通常ロジットモデルでの避走確率




図7 NN ロジットによる避走確率

である。また、図7から、車尾時間が小さい場合、加速度の避走割合への影響は山型というよりも台地型である一方、車尾時間が大きい場合は先の尖った山型である。このように一方の変数により他方の変数の作用が異なることも線形効用関数では記述できないものであり、非線形効用関数により捉えられるものである。尤度比およびAICが大幅に上昇したことも考え合わせると、以上の結果から、避走行動が非線形な現象であると考えられる。

ここで、実際の避走行動がどのようなになっているのかを概観するために、横軸に加速度を、(右側の)縦軸に避走確率(%)をとった図を作成する。これが図8である。なお、左側の縦軸は各カテゴリーのサンプル数である。図8により、図7のNNロジットの推定結果が実際の現象をより良く捉えていることが分かる。このような結果は、NN型非線形効用関数を持つロジットモデルの有効性を示すものと言える。

## 5. まとめ

線形効用関数をもつ従来のロジットモデルに対し、本研究では、ニューラルネットワーク理論を組み込んだ非線形効用関数を定式化し、新たなロジットモデルの構築を行うとともに、焼きなまし




図8 単純集計による実際の避走割合

法を応用した、非線形効用関数を持つロジットモデルでのパラメータ推定方法を提案した。そして、作成したモデルの検討のため、交通事故多発地点(合流部)における避走行動を取り上げ、本研究で構築したモデルの実用性を確認した。同じデータを通常の線形効用関数をもつロジットモデルにも適用し、本研究で構築したモデルとの比較を行った結果、ニューラルネットワーク型効用関数を持つロジットモデルの推定精度の上昇およびモデルの有効性が確認できた。

今後の課題として、本文中で述べた以外の新たなNN型効用関数を定義することにより、推定精度などの改善を目指すこと、また、本研究で適用したデータ以外の現象について、本研究で構築したニューラルネットワーク型非線形効用関数の適用性や有用性を検討することが挙げられる。本研究で提案した非線形効用関数のパラメータの推定方法はニューラルネットワーク型効用関数に限らず、あらゆる非線形効用関数のパラメータ推定に適用可能であり、ニューラルネットワーク型以外の非線形効用関数のパラメータ推定を行い、その有効性を検討することも今後の課題である。

## 参考文献

- 1) McFadden, D.: Conditional Logit Analysis of Quantitative Choice Behavior, in Frontiers in Econometrics, P. Zarembka, Ed., Academic Press, New York, pp. 105-142, 1974.
- 2) Ben-Akiva, M. and S. R. Lerman: Discrete Choice Analysis, MIT Press, Cambridge, MA, 1985.
- 3) Dougherty, M.: A Review of Neural Networks Applied to Transport, Transportation Research,

Vol. 3C, pp. 247-260, 1995.

- 4) Fagri, A. and J. Hua: Evaluation of Artificial Neural Network Applications in Transportation Engineering, Transportation Research Record, No. 1358, pp. 71-80, 1992.
- 5) Yang, H., R. Kitamura, P.P. Jovanis, K.M. Vaughn and M.A. Abdel-Aty: Exploration of Route Choice Behavior with Advanced Traveler Information Using Neural Network Concepts, Transportation, Vol. 20, pp. 199-223, 1993.
- 6) Shmueli, D., I. Salomon and D. Shefer: Neural Network Analysis of Travel Behavior: Evaluating Tools for Prediction, Transportation Research, Vol. 4C, pp. 151-166, 1996.
- 7) Hensher, D.A. and T.T. Ton: A Comparison of the Predictive Potential of Artificial Neural Networks and Nested Logit Models for Commuter Mode Choice, Transportation Research, Vol. 36E, pp. 155-172, 2000.
- 8) 森杉寿芳・岩瀬広：住宅立地行動の予測と住環境の便益評価の総合手法の提案，土木計画学論文集，Vol. 1, pp. 131-138, 1984.
- 9) Morichi et al.: Comparison of Various Utility Functions for Behavioral Travel Demand Model, Proceedings of the 3<sup>rd</sup> World Conference on Transport Research, pp. 159-173, 1983.
- 10) 倉内慎也，大橋聡子，森川高行：意思決定プロセスの異質性を考慮した潜在クラスモデルの推定特性に関する研究，土木学会第57回年次学術講演会講演概要集第4部，pp. 845-846, 2002.
- 11) 坂和正敏・田中雅博：ニューロコンピューティング入門，森北出版，東京，1997.
- 12) Geman, S. and D. Geman: Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-6, pp. 721-741, 1984.
- 13) 高山純一，中山晶一郎，宇野伸宏，飯田恭敬，玉元将裕，住友拓哉：一般道路合流部の交通錯綜における避走挙動解析，土木計画学論文集，Vol. 19, pp. 847-852, 2002.

---

## 非線形効用関数を持つロジットモデル：ニューラルネットワークによる効用関数を例に

中山晶一郎・高山純一・山下裕一郎

これまで多用されてきた線形効用関数をもつロジットモデルに対し，本研究では，ニューラルネットワーク理論を組み込んだ非線形効用関数を提案し，新たなロジットモデルの構築を行う。そして，作成したモデルの検討のため，道路合流部における避走行動を取り上げ，本研究で構築したモデルの実用性を確認した。同じデータを通常の線形効用関数をもつロジットモデルにも適用し，本研究で構築したモデルとの比較を行った結果，ニューラルネットワーク型効用関数を持つロジットモデルの推定精度の上昇およびモデルの有効性が確認できた。

---

## A Logit Model with Non-Linear Utility Functions: The Case of Neural Networks Utility Functions

Shoichiro NAKAYAMA, Jun-ichi TAKAYAMA, Yuichiro YAMASHITA

In most of logit models, linear utility functions have frequently been used. We propose a utility function with neural network, and make a logit model with it. We apply the model to the giveaway behavior at the merging point on the road, and examine the validity of the model. As a result, it is founded that the logit model with neural network utility function describes the giveaway behavior more elaborately than the conventional logit model and its goodness of fit is also better. Thus, we confirm that the logit model with neural network utility function is valid.

---