

# ニューラルネットワークによる交通手段選択モデル

島崎敏一\*・安田誠一\*\*

本論文は、交通手段選択モデルにニューラルネットワーク理論を応用したものである。実際の調査データによりモデルを構築し、モデルの特性を検討した。主な検討項目は、収束性、計算時間、非集計モデルとの比較を含めた手段選択の再現性、予測性などであり、モデルの主要要素である結合マトリックスなどの内容構造も解析した。その結果、ニューラルネットワーク理論によるモデルは、交通手段選択モデルに適用可能であることが判明した。

**Key Words** : neural network, modal choice

## 1. はじめに

最近、ひとの脳の働きをシミュレートするニューラルネットワークの応用が、各種の分野で試みられ、成功している。ニューラルネットワークの主要な応用分野は、形状認識、最適化などであるが、土木工学の分野においては島崎ら<sup>1)</sup>、土地利用については枝村ら<sup>2)</sup>、さらに交通工学、交通計画の分野においては赤松ら<sup>3)</sup>、土屋ら<sup>4)</sup>、中辻ら<sup>5)</sup>、秋山ら<sup>6)</sup>による研究などの応用が試みられ、その有用性が示唆されている。

交通需要予測に交通機関分担の段階で使用されて来た過去のモデルの基本的な方法論は、調査によって得られた変数から、1つの説明変数を構成し、それによって分担率などを求める関数を推定しようとするものである。使用される変数の数は、非集計モデルにおいては、集計モデルよりも多いとはいえ、多くの場合、10を越えることはないのがふつうである。このため、元のデータに含まれていた情報の多くが失われる可能性があり、また、変数の選択も、根拠が薄弱である場合もあった。ニューラルネットワークモデルの形状認識の機能を、交通手段選択に応用すれば、多くの変数を取り込むことができ、上記欠点を克服することができ、実用性の高いモデルを得られる可能性がある。また、人間が交通手段選択を実際に行なうにあたっては、非集計モデルにおけるような計算を実際に行なっているとは考えられず、ニューラルネットワークモデルにおける自己組織化の過程の方がより実際の思考過程に近いと考えられる。

本研究は、このような考察に基づき、交通手段選択モデルにニューラルネットワーク理論を応用する可能性を検討するものである。ニューラルネットワークモ

デルを、インドネシアなどにおける実測データにより構築し、収束性、所要計算時間、解の精度などについて検討する。また、その結果を、非集計モデルの結果と比較し、その実用性について検討する。さらに、モデルの主要構成要素である結合マトリックスなどの内部構造についても検討する。

## 2. ニューラルネットワークの概要

ニューラルネットワークによる情報処理とは何かという点については、その定義は、まだ、確定したものはない。概念的には、多くの比較的単純な情報処理要素が相互に結合して簡単な信号を交換するようなネットワーク状の機構により情報処理を行なうこと<sup>7)</sup>であるとされており、人の脳の情報処理を模擬したものである。

比較的単純な情報処理要素としては、いくつかのタイプが考えられているが、一般には、複数の入力に対して、その内部状態を変化させ、それに応じた1つの出力を出すようなものである。これは、人の脳では神経細胞(ニューロン)に相当するものであり、図-1のようにモデル化される。入力信号から、出力信号への内部変換の形式にも多くのものが検討されている。ニューラルネットワークは、フィードバック結合の有無で2つに大別されるが、フィードバックのあるものは主として最適化問題に利用される。

一方、ニューラルネットワークを形状認識あるいは学習に応用する場合には、フィードバックのないものが主として使われる。学習過程は、教師信号を利用したバックプロパゲーションによる、結合マトリックスの重みの改訂として表現される。ニューラルネットワークの各層内の入出力信号の関係を式(1)-(3)で表わせば、解析的には、この過程は、式(4)-(6)により表される。

\* 工博 東京大学助教授 工学部土木工学科 (〒113 東京都文京区本郷7-3-1) (前アジア工科大学助教授)

\*\* M.Eng. アジア工科大学大学院




図-1 ニューロンのモデル

$$u_i^n = \sum T_{ij}^{n,n-1} V_j^{n-1} \dots \dots \dots (1)$$

$$V_i^n(t) = g(u_i^n(t) - h_i^n) \dots \dots \dots (2)$$

ここで、 $u_i^n$  は、第  $n$  層の  $i$  番目のニューロンの内部状態、  
 $V_j^{n-1}$  は、第  $n-1$  層の  $j$  番目のニューロンの第  $n$  層の  $i$  番目のニューロンへの出力、  
 $T_{ij}^{n,n-1}$  は、第  $n$  層の  $i$  番目と第  $n-1$  層の  $j$  番目のニューロン間の結合状態を表現する重み、  
 $h_i^n$  は、第  $n$  層の  $i$  番目のニューロンの固有状態で、閾値とも呼ばれるもの、  
 $g$  は、シグモイド関数であり、次式のロジック型の関数などが使われる。

$$g(u) = \frac{1}{2} (1 + \tanh(\frac{u}{\theta})) \dots \dots \dots (3)$$

ここで、 $\theta$  は、統計力学とのアナロジーから温度と呼ばれるニューロンの感度を表すパラメータである。

$$\Delta T_{ij}^{n,n-1}(t) = e d_i^n V_j^{n-1} + a \Delta T_{ij}^{n,n-1}(t-1) \dots \dots \dots (4)$$

$$\Delta h_i^n(t) = e d_i^n + a \Delta h_i^n(t-1) \dots \dots \dots (5)$$

$$d_i^n = (s_i - V_i^n) g'(u_i^n) \dots \dots \dots (6)$$

ここで、 $\Delta T_{ij}^{n,n-1}(t)$  は、第  $n-1$  層と第  $n$  層間の結合マトリックスの修正項、  
 $s_i$  は、教師信号、  
 $d_i^n$  は、学習信号、  
 $V_j$  は、出力信号、  
 $h_i^n$  は、閾値の修正値、  
 $e$  は、学習速度を規定する学習定数、  
 $g'$  は、シグモイド関数の導関数、  
 $a$  は、収束過程における振動を防止するための安定化定数である。

したがって、ニューラルネットワークモデルによる

学習過程は、あるモデルの構造を設定したうえで、式(1)-(3)により入力信号に対する出力信号を計算し、その出力を実際にとるべき出力である学習信号と比較して、式(4)-(6)によって、結合マトリックスと閾値を修正するというプロセスになる。

### 3. 交通手段選択モデルの定式化

#### (1) モデル化にあたっての仮定

ニューラルネットワークモデルの構築にあたっては、隠れ層の数、各層におけるニューロンの数などの各種のパラメータが必要となるが、それらの決定の仕方には、まだ、一般的な方法論は提案されていない。したがって、これらのパラメータについては、いわば、試行錯誤で決める必要がある。

このため、ニューラルネットワークモデルによる交通手段選択モデルの定式化にあたっては、以下の仮定を用いた。

- (1) 基本的なニューラルネットワークの層数は、入・出力層を含めて3層を採用し、層数を増加させた場合のモデルの挙動を検討する。
- (2) 層間のニューロンはすべてが互いに結合している完全結合であるとする。
- (3) 入力層のニューロンの数は、次のように決める。入力変数が、性別などのように、名目尺度である場合には、各選択肢に対して1つのニューロンを対応させ、それぞれに該当するときに、1なる値をとるとする。入力変数が、数値変数である場合には、適当にカテゴリーに分け、各カテゴリーに対して1つのニューロンを対応させ、それぞれに該当するときに、1なる値をとるとする。これは、多くの場合、アンケート調査によって得られたデータはカテゴリー化されている場合が多いことを考慮したものである。
- (4) 隠れ層におけるニューロンの数は、入力層のニューロン数と同じ程度とし、これを増減させたときのモデルの挙動を検討する。
- (5) 出力層のニューロンの数は、選択可能な交通手段の数に等しいとし、それぞれの交通手段を選択したときに1なる値をとるものとする。
- (6) 結合マトリックスと閾値ベクトルの初期値は、乱数で与えるのが普通であるが、その大きさについては一般的な決定法はない。試行をした所、収束後の値の絶対値の平均値は0.7程度になったので、それより狭い範囲の初期値とするように-0.7と0.7の間の乱数で与える。

#### (2) モデルの定式化

以上の仮定のもとで、具体的なニューラルネットワークによる交通手段選択モデルの構築の手続きは、次の通りである。

- (1) 結合マトリックスと閾値の初期設定
- (2) 入力パターンの入力
- (3) 式(1)-(3)による出力の計算
- (4) 式(4)-(6)による結合マトリックスおよび閾値の修正
- (5) ステップ(2)-(4)をすべての入力パターンに対して繰り返す(これを1サイクルという)
- (6) ステップ(2)-(5)を同じ入力パターンセットに対して収束するまで繰り返す

#### 4. ニューラルネットワークモデルの適用

##### (1) ニューラルネットワークモデルの適用方法

上で述べたニューラルネットワークによる交通手段選択モデルの適用性を検討するために、調査原票が入手できたインドネシアのマナド市、中華人民共和国の上海市、台湾の台中市での実測データを使用する。

具体的な検討方法としては、ニューラルネットワークモデル自体の適用性の検討のために、学習過程におけるモデルの収束性、計算時間、交通手段選択結果の再現性と予測性を考える。収束性については、モデルの出力と教師信号の2乗誤差を指標として使用する。計算時間については、ニューラルネットワークモデルは計算量が大きく、従来のノイマン型の計算機を使用した場合には、時間がかかることが欠点であるとされていることから、検討の対象とする。ただし、並列処理型の計算機が利用できるようになれば、計算時間は問題とならないと考えられるので、一時的な問題である。再現性については、学習信号として使用したものと同じ教師データを与えたときの、モデルの出力と実際の選択結果を比較し、モデルの再現能力を検討するものである。また、モデルの予測性については、実測データの一部を教師データとして、学習させた後に、教師データ以外のデータをチェックデータとして入力してモデルの出力と実際の選択結果を比較するものである。

このような基本的なモデルの特性を検討した後に、同じ実測データによって構築した非集計交通手段選択モデルとの再現性の比較検討を行う。最後に、結合マトリックス、閾値ベクトルの構造について解析する。

##### (2) 使用データとモデルの構造

ニューラルネットワークモデルの適用にあたっては、収束性、学習用入力データの影響などについては、サンプル数が多く、データ抽出の自由度が高いインドネシアのマナド市、非集計モデルとの比較に関連した検討については非集計モデルの構築を行っている中国の上海市と台湾の台中市のデータを使用した。

基本的な特性の検討に使用したインドネシアのマナド市のデータは、1991年10月に調査<sup>8)</sup>されたも

のである。マナド市は、インドネシアの北スラウェシ州の州都であり、人口は1990年で32万人である。主要な交通手段は、徒歩、オートバイ、オプレットまたはマイクロレット(いずれも、軽4輪を改造したバスであり、ルートと停留所は固定している)、自家用車、その他である。データは、家庭訪問面接により、782家庭、2797人(うち男は1474人)についてのデータが得られた。機関分担率は、それぞれ、23、15、41、13、8%であった。調査項目は、性、年齢、職業、収入、私有交通手段、家族数のほかに、交通データとして、目的、出発地と目的地の施設、出発・到着時刻などである。なお、マナド市においては、オプレットのみが運賃が必要であるが、一律であるため、費用についての質問はしていない。

モデルの特性の比較に使用した上海市のデータは、1992年10月に調査<sup>9)</sup>されたものである。上海市は、中国最大の都市であり、人口は1200万人である。主要な交通手段は、公共バス、自転車、徒歩であり、調査によれば、それぞれ、56、33、11%の分担率であった。調査は、家庭訪問面接により行われ、515件のデータが得られた。調査項目は、性、年齢、収入、家族数、自転車の所有、バスの定期券の所有のほか、交通データとして、所要時間、待ち時間、アクセス時間、費用などである。

モデルの特性の比較に使用した台中市のデータは、1992年10月に調査<sup>10)</sup>されたものである。台中市は、台湾中部にある人口100万人の都市であり、主要な交通手段は、オートバイ、自家用車、バス、タクシーであり、調査によれば、それぞれ、57、30、8、3%の分担率であった。調査は、通勤交通を対象として行われ、事務所、工場などでの面接で、375件のデータが得られた。調査項目は、性、年齢、収入、自家用車の所有、オートバイの所有、自動車運転免許証の所有、オートバイ運転免許証の所有のほかに、交通データとして、トリップ距離、時間、待ち時間、アクセス時間、費用などである。

入力層、出力層のニューロンについては、前節の仮定で述べたように決定するが、たとえばマナド市のデータに対しては、入力層のニューロン数は52であり、内容は表-1のとおりである。出力層のニューロン数は5であり、徒歩、オートバイ、オプレット(またはマイクロレット)、自家用車、その他にそれぞれ対応している。上海については、ほぼ同様の内容で、入力層のニューロン数は37、出力層のニューロン数は3、台中については、それぞれ、127と4である。

##### (3) モデルの特性

###### a) 収束性

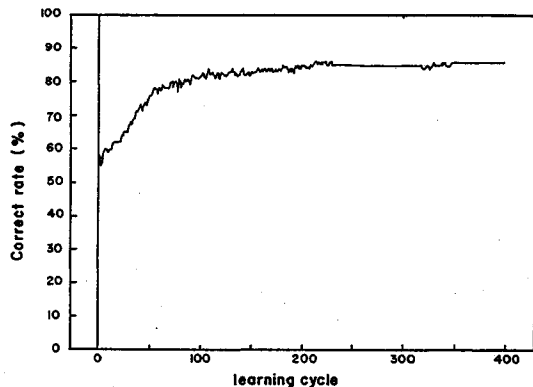
収束性については、マナド市のデータを使用し、モ

表一 1 ニューロンの割当 (マナド市の例)

項目	カテゴリー	ニューロン数
性別	男, 女	2
年齢	<20才, >20才	2
職業	主婦, 学生, 公務員, 民間企業, 商業, 退職者, その他	7
月収	<45万ルピア, >75万	3
私有交通機関	ない, 自転車, オートバイ, オートバイ2台以上, 自家用車	5
家族数	<3人, <5人, >5人	3
トリップ目的	帰宅, 通勤, 買い物, 通学, 業務, 私用, 娯楽, その他	8
出発施設	自宅, 事務所, 娯楽施設, 教育施設, 小売店, 銀行, レストラン, 宗教施設, その他	9
目的施設	出発施設と同じ	9
所要時間	<45分, <90分, <135分, >135分	4

表一 2 収束までのサイクル数 (マナド市データ)

N/L	3層	4層	5層
5	振動	振動	振動
10	振動	振動	振動
25	170	振動	振動
50	60	140	250
75	150	160	160
100	100	130	260
110	70	110	230
125	140	無学習	無学習
150	120	無学習	無学習
175	90	無学習	無学習
200	100	無学習	無学習
210	無学習	無学習	無学習
225	無学習	無学習	無学習
250	無学習	無学習	無学習
300	無学習	無学習	無学習



図一 2 収束の状況 (マナド市データ)

注] N/Lは, 隠れ層1層あたりのニューロン数  
無学習とは, 2乗誤差がまったく減少しないもの

表一 3 所要計算時間 (マナド市データ)

N/L	3層		4層		5層	
	連結数	t	連結数	t	連結数	t
5	285	13	310	18	335	23
10	570	14	670	19	770	25
25	1425	17	2050	25	2675	33
50	2850	22	5350	40	7850	58
75	4275	27	9900	61	15525	95
100	5700	33	15700	89	25700	145
110	6050	35	18370	102	3047	168
125	7125	38	-	-	-	-
150	8550	43	-	-	-	-
175	9725	49	-	-	-	-
200	11400	54	-	-	-	-

注] N/Lは, 隠れ層1層あたりのニューロン数  
時間は, 1サイクルあたりの秒数

デルの層数としては, 入力層と出力層を含めて3, 4, 5層, 隠れ層1つあたりのニューロン数については, 5-300個のケースについて検討を行った. その結果は, 表一2のとおりである. また, 1例として, 正答率で表現した収束の様子を, 層数3, 各隠れ層のニューロン数50の場合について, 図一2に示す. これから, 次のことがいえる.

- (1) 隠れ層の総ニューロン数が大きくなり, 200-300程度になると, 学習過程が進行しない.
- (2) 隠れ層の総ニューロン数が小さくなり, 100程度以下のときには, 振動現象を示し, 収束が不安定となる.
- (3) 隠れ層の総ニューロン数が, 100-200程度のときには, 隠れ層の数に関わらず, 収束する.
- (4) 収束までに要する学習サイクル数は, 層数が増えると増加する傾向があるが, ニューロン数は, 強い関係は持っていない.

b) 計算時間

本論文では, 使用したシステムは, ハードウェアが, NECのPC9801にNECインフォメーションテクノロジーのImPPボードを付加したもので, ソフトウェアは同社のNeuro 07であり, 単純バックプロパゲーション法

によっている. これによる計算時間を, 層数が3, 4, 5層, 隠れ層のニューロン数が5-200までについて, 計測したものが, 表一3である. ニューラルネットワークによる学習過程での主要な計算は, 式(1)と式(2)の出力の計算および式(4)と式(5)のバックプロパゲーションの計算である. これらの計算量は, ニューロン間の結合数に, ほぼ比例すると考えられる. 実際には, 結合数とサイクルあたりの計算時間は, 良い線形の関係を持っており, これらの層数別と全体についての相関計数は, 表一4に示すように0.97以上を示している.

総計算時間は, 400サイクルの学習をさせた場合に, 3層で各層5ニューロンのモデルで1時間24分, 5層で隠れ層各層110ニューロンで18時間42分となっている. 本論文で使用したボードでは,

表一 計算時間と結合数の単回帰分析

層数	定数項	結合数係数	R <sup>2</sup>	自由度
3層	11.33	0.00378	0.9997	9
4層	15.57	0.00466	0.9998	5
5層	20.53	0.00483	0.9995	5
全体	11.43	0.00496	0.9715	23

表一五 再現性、予測性への層数の影響（正答率，％）

共通因子	3層		4層		5層	
	R	P	R	P	R	P
50N/L	81.2	58.1	83.0	59.3	83.0	60.2
75N/L	81.0	57.8	83.4	60.3	82.9	60.9
100N/L	81.0	57.8	83.4	60.5	82.9	60.6
150N	82.5	59.0	84.0	60.3	83.0	60.2
5500C	81.0	57.8	83.0	59.3	83.0	59.4

注] Rは再現性, Pは予測性を示す.  
 N/Lは, 1層あたりニューロン数  
 Nは, 総ニューロン数  
 Cは, 結合数であるが, 概数であり, 3, 4, 5層について, それぞれ, 5700, 5350, 5480である.

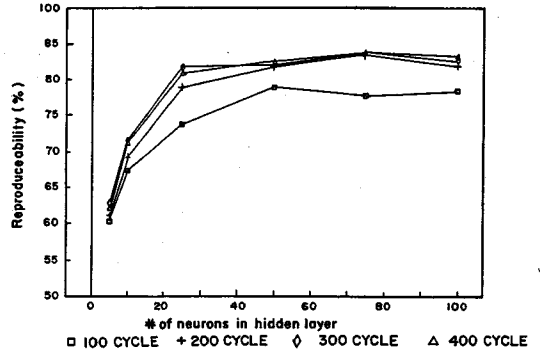
4つの並列計算ができるようになってきているが, 将来, より大規模な並列計算機が利用できれば, たとえば, 64並列計算ができる程度でも, 計算時間は最大のモデルに対しても約1時間となり, それほど非実用的ではないと考えられる.

c) 再現性と予測性


再現性と予測性の指標としては, 実際の交通手段の選択結果とモデルによる選択結果が一致した場合の全数に対する比である正答率を使用した. ここで, 再現性とは, モデル構築に使用したデータを, 入力したときの正答率である. 予測性とはモデル構築に使用していないデータに関するものである. 具体的には, インドネシアのマナド市のデータを使用し, いずれの場合も, 全データからランダムに1000データを抽出し入力データとして, モデル構築をおこなった後, 再現性については, その1000データについての正答率を求め, 予測性については, 抽出しなかった残りのデータを入力した場合についての正答率を求めたものである. 影響因子としては, 層数, ニューロン数, 学習サイクル数などを検討した. 検討したモデルの層数は3, 4, 5層であり, ニューロン数は層あたり5-200, 学習サイクル数は原則として400とした.

層数の影響に関しては, 1層あたりのニューロン数, 総ニューロン数, 結合数が同じ場合の影響を検討した. 表一五に示すように, 1層あたりのニューロン数, 総ニューロン数, 結合数が同じであれば, わずかに4層モデルの再現性, 予測性が高い傾向は見られるが, 大きな差は持たない.

隠れ層のニューロン数の, 再現性への影響については, 3, 4, 5層モデルについて, 5-100ニュー



図一三 ニューロン数の再現性への影響



図一四 学習サイクル数の再現性への影響

ロン/層について検討した. その結果の1例として, 4層モデルの場合を図一三に示す. これからわかるように, ニューロン数が増加すれば, 再現性も増加するが, 1層あたりのニューロン数がある限度以上であれば, 再現性はあまり増加しない. この限度の値は, 3, 4, 5層の各モデルについて, それぞれ, 50, 25, 25ニューロン/層程度である.

学習サイクル数の再現性, 予測性への影響については, 3層モデルで, 50ニューロン/層の場合について検討した. その結果は, 図一四に示すとおりである. これからわかるように, 1回目の学習サイクルで, 正答率は劇的に改善される. 最終的な正答率の値に対して, 再現性の場合には, 60%, 予測性の場合には94%が達成される. その後の改善は緩やかであり, 再現性の場合には100サイクル, 予測性の場合には

100サイクル以降はほとんど改善がみられない. さらに, 再現性の場合, 200サイクル以上では, 改善はまったく見られなかった.

以上のことから, ニューラルネットワーク理論による交通手段選択モデルについては, 3または4層モデ

表一六 学習用入力データの影響(上海市データ, 正答率, %)

学習データ	サイクル数	再現時データ			
		(a)	(b)	(c)	(d)
(a)	100	97	97	97	96
	200	98	98	98	96
(b)	100	96	98	99	96
	200	96	99	99	94
(c)	100	89	89	100	82
	200	89	89	100	82
(d)	100	87	90	90	96
	200	88	89	90	96

注] (a) 全データ (515件)  
 (b) ランダムな全データ (515件)  
 (c) ランダムに選択 (100件)

表一七 学習用入力データの影響(台中市データ, 正答率, %)

学習データ	サイクル数	再現時データ			
		(a)	(b)	(c)	(d)
(a)	100	99	99	100	100
	200	100	100	100	100
(b)	100	90	99	99	90
	200	91	100	99	92
(c)	100	70	70	100	76
	200	70	69	100	76
(d)	100	70	68	69	98
	200	70	68	69	98

注] (a), (b), (c), (d) は, 表-5に同じ

ルで, 隠れ層のニューロン数50以上, 学習サイクル数100以上とすれば, 再現性については, ほぼ, 90%程度の正答率を得られると推定される. しかし, 予測性については, 正答率はそれよりも低い可能性がある.

d) 学習用入力データの影響および非集計モデルとの比較

ニューラルネットワークモデルによる形状認識では, 学習用入力データの性質も, その結果に影響を持つといわれている. ここでは, 上海市と台中市のデータからいくつかのデータセットを作成し, それぞれのデータセットでモデルを構築し, 検討した. また, 併せて, 非集計モデルによる結果とも比較した.

上海市のデータは515件, 台中市のデータは375件の個人データからできているが, これらから, (a)元のデータ, (b)元のデータの順序をランダムにしたもの, (c)元のデータからランダムに100個選んだもの, (d)元のデータからランダムに50個選んだものという4つのデータセットを作成し, これを学習用入力データとしてモデルの構築を行った. 前節の結果を考慮し, 学習サイクル数は, 100と200とした. また, 隠れ層の層数は3層, 隠れ層のニューロンの数は, 上海市30と台中市50とした.

結果は, 表一六と表一七に示すとおりであるが, 表の中で(a), (b)については, 全データを使用しているので, 正答率は再現性だけを示しているのに対して, (c), (d)については, 1部のデータを使用してモデルの構築を行っているため, それ自身と同じでないデータセットの欄の正答率は, 予測性を示しているものと考えられる. これによれば, 再現性については, いずれも90%以上の正答率を示しているが, 予測性については, 上海市のデータについては80-90%, 台中市のデータについては70-75%程度の正答率である. この場合, 学習用の入力データが同じであれば, 再現用入力データに関わらず, 再現時の正答率はあま

表一八 非集計モデルの効用関数

上海市	バス	4.221 - 0.104 * バス所要時間 (-5.12) (-1.77)	-0.385 * バス待ち時間 (-5.98)
		-0.206 * アクセス時間 (-3.16)	-4.688 * バス運賃 (-2.83)
	自転車	-0.199 * 自転車所要時間 (-3.79)	+0.718 * 性別ダミー (-2.51)
	徒歩	3.238 - 0.221 * 徒歩所要時間 (3.70) (-5.05)	
台中市	バス	-2.6588 - 0.0374 * バス所要時間 (-5.99) (-2.37)	-0.0326 * バス運賃 (-3.59)
		-1.4427 - 0.0374 * 自家用車所要時間 (-2.981) (-2.37)	-0.0326 * 自家用車費用 (-3.59)
	オートバイ	+1.2259 * 性別ダミー (-3.79)	
	オートバイ	-0.0374 * オートバイ所要時間 (-2.37)	-0.0326 * オートバイ費用 (-3.59)
		-0.0497 * 年収(NT\$1000単位) (-4.30)	+0.9471 * トリップ距離ダミー (-2.85)

表一九 両モデルの再現性の比較

データ	ニューラルネットワーク	非集計モデル
上海市	97.7%	84.8%
台中市	100.0%	86.9%

り変わらず, 入力データが異なれば, 再現時データが同じでも, 正答率は異なることがわかる.

非集計モデルによる再現性については, ロジットモデル(表一八)による結果と比較したものが, 表一九である. これによれば, ニューラルネットワークモデルは, 非線型性が大きいとは言え, ほぼ100%と非集計モデルよりもかなり高い再現性を示しているといえる.

(4) 結合マトリックスの内部構造の検討

ニューラルネットワークモデルにおいては, 学習過程で入力されたデータの持っている情報は, すべて, 入力層と隠れ層, 隠れ層と隠れ層, 隠れ層と出力層の間の結合行列および, それぞれの閾値ベクトルによって表現されていることになる. そこで, ここでは, 主として結合マトリックスの構造を検討し, 学習入力データの情報がどのように表現されているかを検討する. 主たる検討の対象は, 結合マトリックスと閾値の分布, 隠れ層からの出力値の特性, 各入力変数の




図-5 結合マトリックスの値の分布




図-6 閾値ベクトルの値の分布

出力への影響であり、3層モデルで400サイクルの学習をさせた場合である。

まず、結合マトリックスと閾値ベクトルの値自体について検討する。マナド市のデータによって学習後の結合マトリックスと閾値ベクトルの値の分布を示したのが、図-5と図-6である。これによれば、閾値ベクトルについては、ほとんどが負の値をとり、-1から0.25の間に分布している。一方、結合マトリックスの値については、-1から+1までほぼ均等に分布している。ただし、いずれの場合も、隠れ層から出力層への値については、+1以上および-1以下の両極端に分かれる傾向がある。

次に、隠れ層から出力される値については、上海市のデータについて検討した。表-10は、学習用入力データとして前述の4種類を使用して作成したモデルに、同じデータを入力したときの、+0.1以上の値の出力を示したニューロンの数と出力値の全体の平均値を示したものである。これから分かるように、異なった学習信号によって構築されたモデルでは、同じ入力に対しても、ニューロンの個数も出力値も異なっているが、逆に、入力が変わっていても、同じ学習信号に

表-10 隠れ層からの出力の性質 (上海市データ)

学習データ	再現時データ			
	(a)	(b)	(c)	(d)
(a)	8.8 0.7	8.8 0.7	9.0 0.7	8.3 0.8
(b)	10.9 0.7	11.0 0.7	11.0 0.7	10.4 0.7
(c)	21.4 0.6	21.5 0.6	21.2 0.6	21.2 0.6
(d)	16.4 0.5	16.4 0.5	16.1 0.5	15.5 0.6

注] (a), (b), (c), (d) は、表-5と同じ  
上段は、+0.1以上の出力を持つニューロンの個数の平均値  
下段は、全ニューロンの出力の平均値

表-11 各入力の出力への影響 (上海市全データ, %)

入力変数	単一	除外
選択肢数	65	3.9
性別	56	3.9
年齢	35	4.3
収入	51	3.5
家族数	50	2.7
自転車所有	56	3.3
バス定期券所有	74	6.6

注] 単一とは、該当変数に関するデータだけをを入力した場合の正答率  
除外とは、該当変数以外に関するデータだけをを入力した場合の正答率の減少値

よって構築されたモデルではほぼ同様の値を示している。プラスの値を持つニューロンの数や出力値の平均だけではなく、各ニューロンからの出力値を詳細に検討しても、同じことが言える。

各入力変数の出力への影響に対しては、上海市の全データによって構築したモデルについて検討した結果が、表-11である。単一として示した欄の数値は、当該変数に対応するニューラルネットワークモデルの変数グループにのみ入力値を与え、他の変数にはすべて0を与えたときの正答率を示している。また、除外として示した欄の数値は、当該変数に対応するニューラルネットワークモデルの変数グループにはすべて0を与え、他の変数に対応する変数グループには実際の入力値を与えた場合の正答率のすべてに入力値を与えた場合の正答率の低下量を示したものである。これらは、いずれも、大きいほど、当該変数が最終出力に大きな影響を持っていることを示している。

これによれば、年齢に関する変数をのぞけば、いずれも1つの変数だけで、50%以上の再現率を示している。また、各変数に関する情報が欠けたときの、正答率の低下は、高々7%程度である。なお、年齢に関

する変数をのぞけば、単一と除外の示す値は、かなり高い相関を持っている( $R^2=0.82$ )。これらのことから推定されるのは、ニューラルネットワークモデルの場合には、各変数が、それぞれ出力に影響していると同時に、変数全体としても大きな影響を持っているということである。

## 5. 結論と今後の課題

以上、交通手段選択モデルへのニューラルネットワークモデルの適用の可能性について検討した。その結果、次の結論が得られた。

- (1) 計算所要時間などを考えれば、今でも適用は可能であるが、将来、並列処理型のコンピュータが利用できるようになれば、さらに、その適用性は高まる。
- (2) モデルの収束性については、モデルの層数、ニューロン数には、ある限界がある。今回の条件では、総ニューロン数が100-200程度の時には、層数に関わらず収束する。
- (3) モデルの再現性については、90%以上の正答率が期待でき、非集計モデルによるものよりも高い。また、モデルの構造の再現性への影響については、層あたりニューロン数は25-50程度以上であれば、モデルの層数はあまり影響を持たない。さらに、学習サイクル数の影響についても下限があり、それは100サイクル程度である。また、モデルの予測性については、少なくとも60%程度であり、その他の性質については、ほぼ、再現性の場合と同様である。
- (4) 異なった学習用入力データによる結合マトリックスの比較から考えると、構築されたニューラルネットワークモデルの結合マトリックスの構造は、データの入力順序など学習用入力データに大きく依存する。
- (5) 各入力変数の出力への影響については、当該変数単一でも50%以上の再現性を示し、そのデータを除外しても正答率の低下は7%ポイント程度である。その重要性の順序は、非集計モデルによるものとはほぼ一致する。

なお、今後の課題としては、適用例の数を増加し、ここで述べた結論を確認するとともに、特に、予測性についてその正答率を高める方法について検討する必要がある。

## 6. おわりに

ニューラルネットワークによる交通手段選択モデルの検討を行ったが、適用の可能性があることが判明した。具体的な例への適用に当たっては、Audie L.E. Rumayar (Sam Ratulangi Univ., マナド市, インドネシア), Li Gang (アジア工科大学), Ju Lai Shun (アジア工科大学)の各氏にデータの提供を受けたことを記して、深謝の意を表したい。

## 参考文献

- 1) Shimazaki, T., Sano, K. and Tuchiya, Y.: Resource Leveling in PERT by Neural Network, *Application of Artificial Intelligence in Engineering IV*, Ed. G. Rzevski and R.A. Adey, Computational Mechanics Publications, Great Britain, pp.487-498, 1991.
- 2) 枝村俊郎・川井隆司: ニューラルネットワークによるミクロ土地利用モデルの開発, 第27回都市計画学会学術研究論文集, No. 27, pp.175-180, 1992.
- 3) Akamatu, T., Tsuchiya, Y. and Shimazaki, T.: Parallel Distributed Processing on Neural Network for Some Transportation Equilibrium Assignment Problems, *Proc. of the 11th International Symposium on Transportation and Traffic Theory*, pp.307-323, 1990.
- 4) 土屋雄二・島崎敏一: 都市交通計画モデルへのニューラルネットワーク理論の応用について, 土木学会第44回年次学術講演会講演集第4部, pp.500-501, 1989.
- 5) 中辻隆・加来照俊: ニューラルネットワークモデルの交通工学への適用について, 土木計画学研究・講演集, No.12, pp.297-304, 1989.
- 6) 秋山孝正・楊海・高橋寛: ニューラルネットワークを用いた交通行動パターン分析, 交通工学, Vol.28, No.1, pp.25-33, 1993.
- 7) 麻生英樹: ニューラルネットワーク情報処理, 産業図書, p.4, 1988.
- 8) Rumayar, A.L.E.: Analysis of Travel Behavior in Manado, Indonesia, *Aisian Institute of Technology Thesis* No. GT-91/37, 1992.
- 9) Li Gang: Analysis of Transportation Behavior in Shanghai, China, *Aisian Institute of Technology Thesis*, No. GT-92/39, 1993.
- 10) Ju Lai Shun: Analysis of Modal Split Behavior in Taichung, Taiwan, *Aisian Institute of Technology Thesis*, No. GT-92/31, 1993.

(1993.6.3受付)

## MODAL CHOICE MODEL USING NEURAL NETWORKS

Toshikazu SHIMAZAKI and Seichi YASUDA

Modal choice models are constructed using neural networks based on the real survey data taken in Indonesia, China and Taiwan. Model performances are discussed in terms of convergence, computation time, reproducibility and predictability compared with disaggregated model. Internal structures of connection matrix are also analyzed. As a result, the applicability of the neural networks is identified.