

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

Application of Neural Network Models
to Traffic Engineering Problems

中辻 隆*
加来 照俊**

by Takashi Nakatsuji*
Terutoshi Kaku**

This paper is mainly concerned with the applications of neural-network models to some traffic problems. First self-organizing principle, which is the basic principle of neural computers, was discussed in brief. Next, using the back-propagation method, which is a representative neural network model, the problem of the on-line prediction of traffic variables was analyzed. It was found that prediction error by the this model was fairly small, compared to some kind of stochastic prediction models. Finally, using Hopfield model, which is another neural network model, formulations for a minimum cost flow problem were performed. It was shown that this model could give good approximated solutions.

1. まえがき

近年、脳の持つ優れた情報処理能力を人工的に実現しようとする「ニューラルコンピュータ」が、デバイス技術の発展や生体系の情報処理理論の進歩により第6世代コンピュータとして注目されている。ニューラルコンピュータがハード的に実用化されるまでには未だかなりの時間を要すると思われるが、その基本的な概念である各種のニューラルネットワークモデルに関しては、それらが持つ非線形ダイナミック特性、並列分散処理アーキテクチャー、あるいは自己組織化能力が、パターン認識や運動制御、あるいはある種の最適化問題に対して極めて有効であることが報告されてきている。数理計画の分野に

おいてもニューラルネットワークモデルが、巡回セールスマント問題に代表される極値探索問題に対して極めて有用であることが示されている。

本研究は、ニューラルネットワークモデルの交通工学における適用性を検討するために、交通変量のオンライン予測と交通配分問題に対してそれらの適用を試みたものである。まず最初に、ニューラルネットワークモデルが自己組織化能力によって特徴付けられることを考慮し、2つの自己組織化原理について言及する。次に、ニューラルネットワークモデルの代表的手法である逆伝搬法とホップフィールドモデルの学習メカニズムについて簡単に紹介する。さらに前者を交通変量のオンライン予測へ、後者を最も簡単な交通配分問題である費用最小流問題へ適用し、その定式化と解析結果について報告する。

* 正会員 工修 北大講師 工学部土木工学科

**正会員 工博 北大教授 同上

(〒060 札幌市北区北13条西08丁目)

2. 自己組織化原理

1) 自己組織化

人間の脳の持つ優れた特徴は、外界や環境からの作用を学習し、その情報を記憶、自己組織化していく能力にある。自己組織化とは、「過去の経験と環境の変化に応じて、それ自体で組織し、従って行動様式（入出力関係）を変化させていく能力」¹⁾と定義されているが、ニューラルネットワークモデルにおいては、その並列処理能力と並んでこの自己組織化能力が大きな特徴となっている。ここでは自己組織化の原理について簡単に概説する。

Fig. 1 は、Rosenblattによって提案された単純パーセプトロンモデルである。S層からの入力信号がA層を経由してR層から出力される。出力値と既知の教師信号 d との差（学習信号）を用いて層間の結合を変化させ望ましい入出力システムを形成しようとする過程が自己組織化である。

自己組織化原理はモデルの構造に関する事前情報の設定の有無によって2つに分類できる。1つが主に時系列解析の分野で発展してきたGMDH法であり、他方がここで取り上げるニューラルネットワークモデルである。

2) GMDH法^{2)~3)}

定式化が困難な構造を持つ非線形システムに対して、システムの入出力の間に多項式の関係を仮定することによって問題の解決を計ることが出来る場合がある。Ivakhnenkoによって提案されたGMDH法（Group Method of Data Handling）は、Fig. 2に示すような多層構造を仮定し、各層において入出力関係を以下のような線形多項式

$$y = A + Bx_1 + Cx_2 + Dx_1^2 + Ex_1x_2 + Fx_1x_3 \quad (1)$$

で表現した部分多項式を構成するとともに、自己選択によって次の層への入力変数を選択する。この過程を多層にわたって繰り返すことによって最終的に完全表現式を得ようとするものである。すなわち、入力と出力の定式化を決定論的に行なうのではなく、Fig. 1 に示したパーセプトロン型の多層構造によるモデル化を行い、既知出力値との適合性から各層の

結合（多項式係数）を変化させる（自己組織化）とともに、合目的な変数の選択を幾層（幾世代）にわたって行なう（品種改良）。モデル構造や変数の組合せを当初の目的にあうよう適切に選択していくことから、GMDH法は発見的自己組織化法（Heuristic Self-Organization）とも呼ばれている。わが国においても河川流量や大気汚染濃度等の予測、制御、構造同定に応用されてきている。変数の予備選択、正則化、部分表現構造モデル、部分表現選択、あるいは停止則にどのような規範を採択するかによって基本、修正、改良、あるいは一般化等の多様なアルゴリズムが存在する。

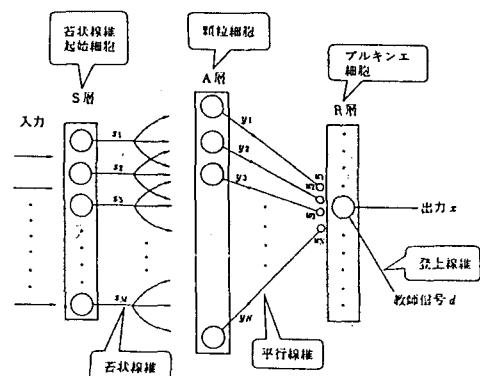


Fig. 1 自己組織化原理（単純パーセプトロンモデル）¹⁾

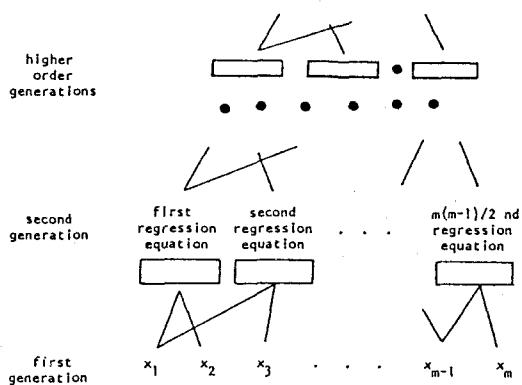


Fig. 2 GMDH法の基本算法²⁾

2) ニューラルネットワークモデル⁽⁴⁾⁻⁽⁷⁾

脳の神経細胞(ニューロン)は、0、1による刺激-興奮機構をもつ多入力1出力の情報処理素子として表現される(Fig. 3)。入力信号 V_j が i 番目のニューロンに与える影響をシナプス荷重 T_{ij} という。時間的に離散的なシステムにおいて、 i 番目ニューロンへの入力信号 x_i とその出力信号 V_i は

$$x_i = \sum_{j=1} T_{ij} V_j + I_i \quad (2)$$

$$V_i = f(x_i / \mu_0) \quad (3)$$

と与えられる。 I_i は外部から i 番目のニューロンに作用する刺激の総和である。また、関数 f は指数関数や正接関数などで表現されるシグモイド形の単調増加関数であり、刺激(入力)に対するニューロンの興奮(出力)を規定するものである。すなわち、ここでは、モデル構造に関する一切の事前情報はなく、入出力結果のみからその構造が学習される。

ニューラルネットワークモデルは、Fig. 4に示すように、各ニューロンの結合方法によって階層的(Perceptron型)ネットワークと、相互結合ネットワーク(Hopfield型)に分類される。以下に、これらの学習メカニズムを簡単に紹介する。

3. 学習メカニズム

1) 逆伝播法(Back-Propagation)

階層的ネットワークの代表的な学習法に逆伝播法がある⁽⁸⁾。逆伝播法の基本的な考え方を4層の階層モデルを例として説明する(Fig. 5)。A層が入力層、B、C層が中間層、およびD層が出力層である。ここで、学習に関係するのはB、C、D層の3層で、A層は入力された信号をB層に伝える役目だけを担うと仮定する。

各層間のシナプス荷重の大きさが与えられると、入力層へ入力された信号は、式(2)(3)に基づき、中間層から出力層へと順次伝達される。一般的に中間層の数、あるいはニューロンの大きさは任意であり、経験的に定められる。出力層の結果は既知の教師信号と比較され、誤差の度合に応じて各層間のシナプス荷重の大きさが補正される。いま、出力層の i 番

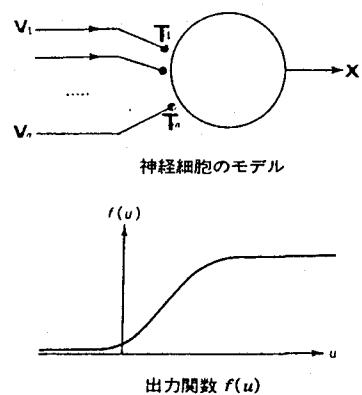


Fig. 3 神経細胞の入力-出力モデル

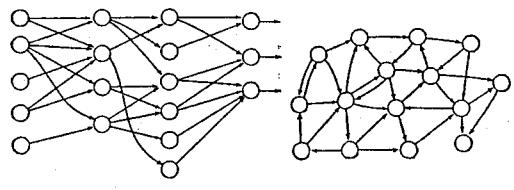
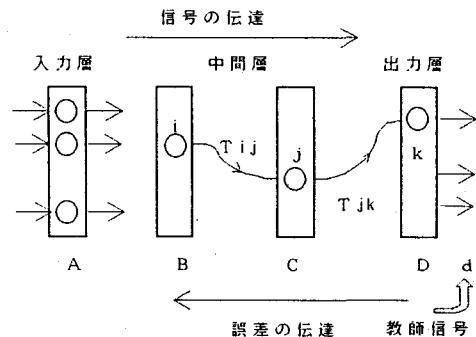
Fig. 4 ニューラルネットワークモデル⁽⁸⁾

Fig. 5 逆伝播法の学習メカニズム

目のニューロンの出力信号を y_i 、それに対応する教師信号を d_i とするとき、逆伝播法による学習は、誤差の自乗和

$$E = (1/2) \sum_i (d_i - y_i)^2 \quad (4)$$

を極小化しようとすることによって実現される。いま、式(3)のシグモイド関数 f が次式で定義され、

$$f = 1 / [1 + \exp(-x)] \quad (5)$$

B C 間、C D 間のシナプス荷重が T_{ij} 、 T_{jk} と与えられる時、それらの変化量 dT_{ij} 、 dT_{jk} は

$$\begin{aligned} dT_{jk} &= (d_k - y_k) y_k (1 - y_k) y_j \\ dT_{ij} &= \sum_k (d_k - y_k) y_k (1 - y_k) T_{jk} \\ &\quad * y_i y_j (1 - y_j) \end{aligned} \quad (6)$$

として求めることができる。実際の計算においては演算の収束をはやめるために

$$\begin{aligned} \Delta T(n) &= \varepsilon dT(n) + \alpha \Delta T(n-1) \\ T(n+1) &= T(n) + \Delta T(n) \end{aligned} \quad (7)$$

としている。ここで ε は学習定数と言われる十分小さな正の値であり、 α は安定化定数と言われる 0 から 1 の間の値である。

2) ホップフィールドモデル

各ニューロンが相互に結合されたネットワークに關し、Hopfield⁹⁾⁻¹¹⁾ らは、シナプス荷重が対称性 ($T_{ij} = T_{ji}$) をもち、かつ各ニューロンが非同期的に状態を変えるならば、以下の式で定義されるエネルギー関数が

$$E = -(1/2) \sum_{i,j} T_{ij} V_i V_j - \sum_i I_i V_i \quad (8)$$

常に減少するよう各ニューロンの状態が自発的に変化していくことを示した。これを、「エネルギー最小化原理」という。

この原理を利用することによって、ある種の最適化問題の近似解を比較的短時間で求めることができる^{11) 14)}。しかしながら、各ニューロンが非同期に状態を変化させるために、ある初期状態から出発したネットワークは、状態変化を繰り返すうちに、ある安定な平衡状態に到達したり、周期的な状態変化に落ち込むなど、いわゆるローカルミニマムに収束してしまう可能性がある。すなわち、状態変数の初期値と目的関数の重み係数によって近似解が影響を受けることになる。特に、試行錯誤的に与えられる重み係数の決定はニューラルネットワークモデルにおける解決すべき重要問題である。

ローカルミニマムを避けて真の最適解を得るために、C.E. Hinton⁽¹²⁾ らは、ニューロンの出力を確率的なものにした Boltzmann Machine を提案している。また、式(2) のニューロンの出力にノイズ項を導入したガウシアンマシンも提案されている。⁽¹³⁾

4. 適用例

1) 交通変量の短期予測

一般的にある地点における交通状態は、その地点の過去の値と相関を有するばかりではなく、上・下流地点とも相関を示す。このような状況における予測問題においては、例えば多変数自己回帰法などの統計的解析手法が用いられるが、予測結果が 1 ステップ遅れたり、あるいは地点数（変数）が多くなるにつれて、長時間の相関係数演算に陥るなどの欠点がある。ここでは、都市内街路で計測された車両感知器データを用いて交通状態のオンライン予測を GMDH 法とニューラルネットワークモデルの逆伝播法により行い自己組織化原理の特徴を示す。

Fig. 6 に示した車両感知器計測地点列において、地点 0 の交通量の予測を行なうものとする。各地点においては、5 分間隔で交通量、時間占有率、および地点平均速度の計測が行なわれている。

Table 1 に、GMDH 法によって地点 0 における交通量 y の予測に当り、自己の過去値（1 ステップ前の値）を含め、他地点の交通量、占有率、地点速度データを候補として、1 日の各時間帯ごとに、第 1 層の変数選択において交通量 y と最も相関ありとされた変数組を示した。各時間帯において、交通量 y に最も影響を与える変数が異なっていることがわかる。ここでのデータは、幹線上のものであるので、観測地点近傍の上下流地点との相関が高いにもかかわらず、相関の高い変数の組合せにはばらつきが見られている。より大規模な都市内街路のネットワークにおいては、さらにこのばらつきの傾向は顕著になると予想される。すなわち、固定化された変数による予測を行なうよりも自己組織化的に変数選択を行なうことが好ましいことを意味している。なお、GMDH 法では前日のデータを用いてモデルの同定

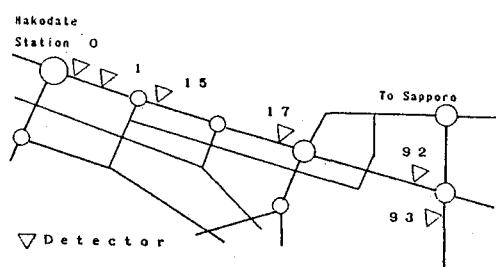


Fig. 6 車両感知器配置（函館）

を行っているが、奇数番目データをモデルのパラメータを決めるトレーニングデータ、偶数番目をモデルの妥当性を評価するチェックングデータとする基本GMDH法を用いて演算を行なった。

地点0の時刻 t_k における交通量の予測を行なうにあたり、ニューラルネットワークモデルはFig.5に示した4層構造とともに、 t_{k-1} までの自地点、および他地点の交通量、占有率を入力信号として用いた。予測後、時刻 t_k の計測値を教師信号として誤差の逆伝搬を行いオンライン予測を行なう。

Fig.7は、逆伝播法によって昼間12時間における予測した例を示す。また、変動が急変する時間帯(11時-13時)における予測を多変数ARモデルとGMDH法で行った結果も併せて示している。Table 2は、3つの手法による予測誤差の比較を表している。多変数ARモデルによる予測が1ステップ遅れていたり、あるいはGMDH法による予測が変動の急変に対する追従性が劣るのに対してニューラルモデルが極めて優れた結果を与えていている。

Table 2 予測誤差の比較
(函館: 地点0, 交通量11:00-13:00)

解析手法	予測誤差
多変数自己回帰法	24.7
基本GMDH法	16.4
逆伝播法	1.7

Table 1 GMDH法における変数選択の変動例(函館'86.8)

1日の時間帯	第1層で選択された変数
6-9	x1, x2
9-12	x2, x14
13-16	x8, x14
16-19	x1, x13

x1	地点0 交通量過去値
x2	0 占有率 "
x8	15 占有率 "
x13	92 交通量 "
x14	92 占有率 "

(過去値: 1ステップ前の値)

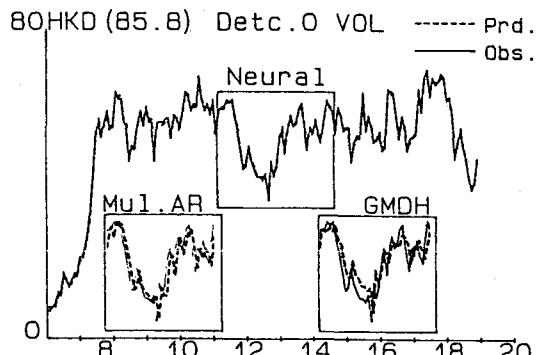


Fig. 7 交通量予測の比較(地点0、交通量)

2) 最小費用流問題

始端ノード*i*、終端ノード*j*から成るリンクにおける流量を x_{ij} 、その容量を a_{ij} 、そして単位流量当たりの費用を c_{ij} とする。ノード1からノードNへの総流量 q が与えられている時に、ネットワーク全体の総費用

$$Z = \sum_{(i,j)} c_{ij} x_{ij} \quad (9)$$

を最小にする流量を求めるのが、最小費用流問題である。制約条件は、各ノードにおいて

$$\begin{aligned} \sum x_{ij} - \sum x_{ji} &= \begin{cases} q & (i=1) \\ 0 & (i=2, 3, \dots, n-1) \\ -q & (i=n) \end{cases} \\ \text{out}_i - \text{in}_i &= \begin{cases} q & (i=1) \\ 0 & (i=2, 3, \dots, n-1) \\ -q & (i=n) \end{cases} \end{aligned} \quad (10)$$

$$0 \leq x_{ij} \leq a_{ij}$$

この問題は、Hopfield¹¹⁾らによる巡回セールスマント問題、あるいはTakeda¹⁴⁾らによる Hitchcock問題同様に目的関数が状態変数 V_i の2次形式で表現される組合せ最適化問題の1つであるので、上記

問題同様にニューラルネットワークモデルによる定式化が可能である。

各リンクにおける（流量／容量）比 ρ_{ij} をニューロンによって表わすことを考える。この値は当然のことながら 0 から 1 までの実数であるので、ニューロンを組み合わせて実数表現する必要がある。ここでは、Group-and-Weight Scheme⁽¹⁵⁾ によってその実現を計った。

Fig. 8 に示すように、1 つの実数を表わすのに M 衍をもって行なうものとし、かつ各衍は R 個のニューロンから構成されると仮定する。先に述べたように対象とする実数は 1 以下の正数であるので、m 番目の衍は $(R+1)^{-m}$ の位を表わすものとすると、対容量比 ρ_{ij} は以下のように表現される。

$$\rho_{ij} = \sum_{m=1}^M (R+1)^{-m} \sum_{r=1}^R V_{ijmr} = \sum_{m=1}^M \sum_{r=1}^R b_m V_{ijmr} \quad (11)$$

すなわち、ノード i とノード j は $R \times M$ 個のニューロンで結合されていることになる。大きな R の値を用いるとニューロンの総数が増加するので、解を得るまでの演算時間が大きくなるが、逆に R を小さくし過ぎると、演算時間的には有利であるが高次の位に対応するニューロンの変化に対して敏感過ぎる欠点がある。特に $R=1$ のときには、2 のべき乗表現 (Binary Scheme) となるが、 2^{-1} 、あるいは 2^{-2} に対応するニューロンの状態によって ρ_{ij} の値も大きく変動することになる。

容量比が求められると流量は次式で与えられる。

$$x_{ij} = a_{ij} \rho_{ij} = \sum_{m=1}^M \sum_{r=1}^R a_{ij} b_m V_{ijmr} \quad (12)$$

また、ノード i における流入量、流出量はそれぞれ

$$\sum_{j=1}^{N-1} \zeta_{ji} x_{ji} = \sum_{j=1}^{N-1} \sum_{m=1}^M \sum_{r=1}^R \zeta_{ji} a_{ij} b_m V_{ijmr} \quad (13)$$

$$\sum_{j=2}^N \zeta_{ij} x_{ij} = \sum_{j=2}^N \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} a_{ij} b_m V_{ijmr}$$

と表現される。ここで ζ_{ij} はノード i からノード j へのリンクが存在する時 1、存在しない時 0 の値をとるものとする。また、総費用は次式で表わされる。

$$Z = \sum_{i=1}^{N-1} \sum_{j=2}^N \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} c_{ija} a_{ij} b_m V_{ijmr} \quad (14)$$

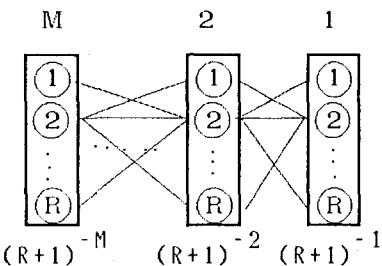


Fig. 8 ニューロンによる実数値の表現モデル
目的関数は、

$$\begin{aligned} \phi = & - (A/2) \left[\sum_{i=1}^{N-1} \sum_{j=2}^N \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} (1 - 2V_{ijmr})^2 \right] \\ & + (B/2) \left[q - \sum_{i=2}^N \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} a_{ij} b_m V_{ijmr} \right]^2 \\ & + (C/2) \left[q - \sum_{j=1}^{N-1} \sum_{m=1}^M \sum_{r=1}^R \zeta_{ji} a_{ji} b_m V_{jimr} \right]^2 \\ & + (D/2) \sum_{i=2}^{N-1} \left[\sum_{j=1}^{N-1} \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} a_{ij} b_m V_{ijmr} \right. \\ & \quad \left. - \sum_{j=2}^N \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} a_{ij} b_m V_{ijmr} \right]^2 \\ & + (E/2) \left[\sum_{i=1}^{N-1} \sum_{j=2}^N \sum_{m=1}^M \sum_{r=1}^R \zeta_{ij} c_{ija} a_{ij} b_m V_{ijmr} \right]^2 \end{aligned} \quad (15)$$

ここで、第 1 項はニューロンの 0 か 1 の 2 値のいずれか一方を取るようにするためのものであり、第 2 項、第 3 項、および第 4 項はそれぞれ入口ノード 1、出口ノード N、および通過ノード ($i = 2, 3, \dots, N-1$) における制約条件に対応し、最終項は費用最小条件を実現するためのものである。また、各項の係数 A, B, C, D, E は各条件の重みを表わす正の定数である。エネルギー関数との対応から

$$\begin{aligned} T_{ijmr} t'_{jmr} = & 4 A \delta_{ij} \delta_{jj'} \delta_{mm'} \delta_{rr'} \\ & - B a_{ija} t'_{j'b'mb'm} \delta_{ii'} \delta_{j'j} \\ & - C a_{ija} t'_{j'b'mb'm} \delta_{jN} \delta_{j'N} \\ & - D a_{ija} t'_{j'b'mb'm} [\delta_{ii'} (1 - \delta_{ii'}) \\ & \quad + \delta_{jj'} (1 - \delta_{jN}) - \delta_{ij'} - \delta_{i'j}] \\ & - E c_{ija} t'_{j'b'mb'm} \end{aligned} \quad (16)$$

ここで、 δ_{ij} はデルタ関数である。

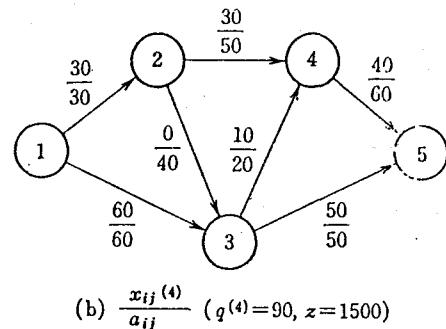
Fig. 9 は、例題としてとりあげたネットワークである¹⁶⁾。Table 3 に各リンクの容量 a_{ij} と単位流量当りの費用 c_{ij} を示す。Fig. 9 内のネットワーク中に示された数字は各リンクの容量（下段）とノード 1 からノード 5 へ $q = 90$ の流量が与えられた時の解析解（上段）を表わしている。なお、解析解はプライマル・デュアル法¹⁷⁾を用いて求めた。この問題をホップフィールド法でモデル化し、解析解と比較した結果を Fig. 10 に示す。ただし、実数表現のために 4 衍 ($M = 4$) の 4 進数 ($R = 3$) のニューロンを構成した。また、目的関数の重み係数は $A = 30$, $B = 1000$, $C = 1000$, $D = 100$, $E = 0.1$ とするとともに、ニューロンの初期値としては一様に 0.5 を与えた。ここでは、エネルギー関数の変動状態から、6 回目の繰り返し回数をもって収束したと判断したが、2 回目においても既にかなりの精度が得られていることがわかる。ここで結果は近似値としては十分な精度と判断されるが、入口ノードや出口ノードに比べ通過ノードでの精度が低下しているのが見られるが、重み係数の決定に改良の余地が残されていると言える。

5. あとがき

ニューラルネットワークモデルの交通工学への適用を目的として代表的なモデルの応用を試みた。交通变量のオンライン予測を逆伝播法を用いて行なった結果、初期値から最初の解を得るまでに多少の演算時間を要するが、従来の代表的統計解析モデルである多変数自己回帰モデルや逆伝播法と同じく自己組織化原理に基づく GMDH 法と比べて優れた予測精度が得られた。また、最も簡単な交通配分問題である最小費用流量問題に対しても、ホップフィールドモデルによる定式化を行なうとともに解析例を示した。しかしながら、実際の交通配分問題においては、費用（通過時間、遅れ）は交通量の状況によって変化し、目的関数が非線形となるので単純にホップフィールド型のモデルを適用することは出来ない。ローカルミニマムや重み係数の規範などとともに今後の課題として残されている。

Table 3 費用最小流問題^{16) 17)}

リンク	ノード	容量	費用
1	1-2	30	3
2	1-3	60	9
3	2-3	40	5
4	2-4	50	7
5	3-4	20	8
6	3-5	50	6
7	4-5	60	7



$$(b) \frac{x_{ij}^{(4)}}{a_{ij}} \quad (q^{(4)}=90, z=1500)$$

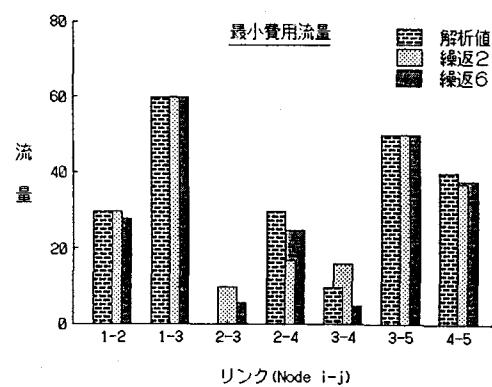
Fig. 9 費用最小流問題ネットワーク¹⁶⁾

Fig. 10 費用最小流問題の解析解との比較

参考文献

- 1)木村：「自己組織構成論」、共立出版、1973
- 2)Farlow:「SELF-ORGANIZING METHODS IN MODELING」MARCEL DEKKER, 1984
- 3)池田: GMDH の基礎と応用、システムと制御, Vol. 23 No12-Vol. 24 No. 7, 1980-1981
- 4)甘利: ニューロコンピューティングの数学的基礎、ヨハニクローク、No. 24、pp2-14、1988
- 5)甘利: 「神経回路網モデルとコネクションズム」、東京大学出版会、1989
- 6)麻生: 「ニューラルネットワーク情報処理」、産業図書、1988
- 7)合原: 「ニューラルコンピュータ」、東京電機大出版、1988
- 8)D.E. Rumelhart et al.: "Learning internal representations by error propagation, in Parallel distributed Processing Vol. 1, MIT Press, 1986
- 9)J. J. Hopfield: "Neural networks and physical systems with emergent collective computational abilities", Proc. Natl. Acad. Sci. USA 79, pp2554-2558, 1982
- 10)J. J. Hopfield: "Neurons with graded response have collective computational properties like those of two-state neurons", Proc. Natl. Acad. Sci. USA 81, pp3088-3092, 1984
- 11)J. J. Hopfield et al.: "Neural Computation of Decisions in Optimization Problems", Biol. Cybern., 52, pp141-152, 1985
- 12)Hinton, C. E.: "Learning and Relating in Boltzmann Machines", in Parallel Distributed Processing Vol. 1, MIT Press, 1986
- 13)宮沢: 実践! ニューラルネット、ASCII, Vol. 12, #10-Vol. 13, #4, 1988.10-1989.4
- 14)武田: 神経回路網と組合せ最適化問題、数理科学、NO. 289、pp14-22、1987. 7
- 15)M. Takeda et al.: "Neural networks for computation: number representations and programming complexity", Applied Optics, Vol. 25, No. 18, pp3033-3046, 1986
- 16)伊理: 「ネットワーク理論」、日科技連、1976
- 17)吉林: 「ネットワーク計画法」、培風館、1984