

IV—8

第4世代の交通マネジメントシステムに関する基礎的研究
(ニューラルネットワークモデルによる交通制御問題への適用)

北海道大学工学部 学生員 小林 秀 晃
学生員 熊 谷 洋
正 員 中 辻 隆
正 員 加 来 照 俊

1 まえがき

脳の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」の最大の特徴は、経験による学習能力と並行処理能力を持つことである。ニューラルコンピュータが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、数多くの工学問題に応用できることが認められている。実際、巡回セールスマン問題やヒッチコック問題などの組み合わせ最適化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、都市の動的交通マネジメントシステムに係わる問題、特に最適交通制御問題に対してニューラルネットワークモデルの適用を試みたものである。次に、ニューラルネットワークモデルとそ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。また、ローカルミニマム(局所最小値)を避ける方法として、コーシーマシンの逆伝搬法を組み合わせたステップワイズ法を提案する。さらにステップワイズ法を最適交通制御問題へ適用し、その定式化と解析結果について報告する。

2 動的交通マネジメントシステムとニューラルネットワークモデル

今日、多くの大都市が直面している慢性的な交通の過飽和状態に対応するため、交通状態の変動に素早く対応できるような、新世代の交通マネジメントシステムの実現が望まれている。図1に示した交通マネジメントシステムの概要は次の通りである。車両感知器からのデータに基づき、交通状態を判断し、交通変量を予測して、飽和交通流を他の経路に配分し、同時に、交通流を最適化するように制御変数を調整する。このようなシステムは、自己組織化原理¹⁾に基づく動的交通マネジメントシステムと呼ばれている。そこで、自己組織化能力を持つニューラルネットワークモデルを、このマネジメントシステムに適用することを提案するものである。




図1 動的交通マネジメントシステム

一方、最適制御問題において取扱いの難しい問題として、いわゆる”ローカルミニマム問題”がある。世界的に有名な最適交通制御プログラムであるTRANSYTに採用された山登り法においても、求められた信号パ

ラメータが最適であるという保証はない。しかし、ニューラルネットワークモデルのいくつかの手法は、確率的方法によりローカルミニマムを避けることができるので、この問題に対処できるのである。

また、大規模な交通ネットワークでの最適制御を考えた場合、膨大な計算時間が問題となる。これに対処するために、Singh らが階層制御法を提案したが²⁾、この方法は数学的な知識が必要であり、やや難解である。ニューラルコンピュータがハード的に実現したならば、その並行処理能力によって大規模なネットワークでも十分に適応できる能力を持つのである。

以上のような点から、ニューラルネットワークモデルは動的交通マネジメントシステムに適用され、その発展に大いに貢献するであろうと思われる。

3 ニューラルネットワークモデル³⁾⁻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。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 W_{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 とその出力信号は

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

$$V_i = f(x_i / \mu_0) \quad (2)$$

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型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。これが、ニューラルネットワークモデルの大きな特徴である自己組織化能力である。

ニューラルネットワークモデルは、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。ここでは、前者の階層的ネットワークの学習メカニズムを簡単に紹介する。

3.1 階層的ネットワーク

図2は、後に最適制御問題に使用する階層的ネットワークの、基本的な構造を示している。ここでは、入力層、二つの中間層、出力層を持つ4層のネットワークを用いる。入力層は入力された信号を次の層に伝える役目だけを担う。この階層的ネットワークの学習に用いられるのが逆伝搬法(Back-Propagation)である。

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(1)(2)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、誤差の度合い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、逆伝搬法による学習は、誤差の自乗和

$$E = (1/2) \sum (d_i - y_i)^2 \quad (3)$$




図2 階層的ネットワークモデル

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、

$$f = 1 / \{ 1 + \exp(-x) \} \quad (4)$$

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

$$\begin{aligned} \delta W_{jk} &= (d_k - y_k) y_k (1 - y_k) y_j \\ \delta W_{ij} &= \sum (d_k - y_k) y_k (1 - y_k) W_{jk} y_i y_j (1 - y_j) \end{aligned} \quad (5)$$

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早めるために

$$\begin{aligned} \Delta W(n) &= \varepsilon \delta(n) + \alpha \Delta W(n-1) \\ W(n+1) &= W(n) + \Delta W(n) \end{aligned} \quad (6)$$

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。

3. 2 コーシーマシン⁵⁾

ローカルミニマムへの収束は、ニューラルネットワークモデルにおいて大きな問題である。これを避けるために、ニューロンの出力を確率的なものにしたボルツマンマシンやガウシアンマシン⁵⁾等の方法が提案されている。

Szu は、グローバルミニマム（最適極小値）に収束する確率的方法、コーシーマシンを開発した。コーシーマシンは、微小なランダムノイズを発生させることによってシナプス荷重を調整する。目的関数が減少したときにはノイズによって荷重を変化させ、それ以外の場合には荷重の大きさを前値に戻し、その繰り返しによって目的関数を減少させていく方法である。

Wasserman は、コーシーマシンと逆伝搬法を組み合わせた方法を提案した。それによると「シナプス荷重の値を、逆伝搬法により求められた結果と、コーシーマシンによるランダムステップによる結果との和になるように調整すれば、どちらか一方の方法だけを用了場合よりも、速く、確実にグローバルミニマムに収束するシステムを形成することができる」⁵⁾のである。

ここでは、Wasserman の方法を参考に別の方法を提案する。最初に、ローカルミニマムへの収束を避けるためにコーシーマシンによってシナプス荷重を調整し、その後、逆伝搬法を適用する。この学習アルゴリズムをここではステップワイズ法と名付ける。

4 最適交通制御

4. 1 動的方程式

ここでは、ニューラルネットワークモデルの最適交通制御問題への適用を紹介し、ステップワイズ法がローカルミニマムから逃れてグローバルミニマムを得るのに効果的であることを示す。ここでは、1 交差点における制御問題に限って、その原理を論ずる。

流入リンク数が n で、 p 現示制御の行われている交差点を仮定し、状態変数としてリンク 1 における待行列長さを y_1 、制御変数として、サイクル長に対する現示 i の実青時間の比を u_i とする。各サイクルにおいて各パラメータは平均値をとるものとする、この交差点の状態方程式は次のように与えられる。

$$y(k+1) = y(k) + B u(k) + q(k) \quad (k=0, 1, \dots, N-1) \quad (7)$$

B は流入リンクの飽和交通流率で表された重みマトリックス、 $q(k)$ は流入率を、また、 N は最適化シミュレーションの計算周期を表す。状態変数、制御変数ともに、次のような拘束条件を受ける。

$$\begin{aligned} 0 &\leq y(k) \leq Y_{\max} \\ U_{\min} &\leq u(k) \leq U_{\max} \quad (k=0, 1, \dots, N-1) \\ u_1(k) + u_2(k) + \dots + u_p(k) + 1 &= 1 \end{aligned} \quad (8)$$

1 s はサイクル長に対する損失率である。

最適制御の規準には様々なものがあるが、ここでは待ち行列長さに関する規準を採用する。時間の経過とともに制御変数が最適化され、その結果、次の目的関数が最小化されるのである。

$$J = \sum_{k=1}^N \sum_{i=1}^p y_i^2 k \tag{9}$$

4. 2 学習プロセスと最適化プロセス⁸⁾⁻¹⁰⁾

図3に示すように、4層からなるニューラルネットワークと制御対象のダイナミクスの内部モデルを考える。ニューラルネットワークでは、A層に制御変数の時系列データを入力し、D層からは待ち行列長の時系列データを出力する。内部モデルでは、動的方程式によって計算された行列長の実際の出力を生成する。

このニューラルネットワークモデルの動作は、学習プロセスと最適化プロセスの2段階に分けられる。学習プロセスでは、D層が出力した行列長と内部モデルが出力した行列長とが一致するようにシナプス荷重が調整される。これは、確率的方法を導入せずに、逆伝搬法のみによって行われる。初期にランダム設定された制御変数で数回学習を繰り返すことによって、制御対象順システムの内部モデルが形成される。




図3 最適制御問題におけるニューラルネットワーク

一方、最適化プロセスでは、拘束条件の下で目的関数を最小化するために、制御変数の調整をステップワイズ法で繰り返し行う。制御変数を適当に調整した後、コーシーアルゴリズムにより、目的関数が減少した時のみ、微小なランダムノイズを加え調整を続ける。次に、逆伝搬法により制御変数を調整する。誤差信号の大きさは、目的関数を $u_i(k)$ について微分した次の式で表される。

$$\delta u_i = \sum_k y_i^2 k (1 - y_k) \sum_j W_{ij} W_{jk} y_j (1 - y_j) \tag{10}$$

4. 3 解析結果

ここでは、Singh らが提案した階層制御法²⁾によって得られた解析解と比較検討を行う。例として、流入リンク数が5で、3現示制御の交差点(図4)を用いる。表1は飽和交通流率、流入率、許容最大行列長、




図4 交差点例(Junction 225 in the West London Area)

リンク	1	2	3	4	5
飽和交通流率	90	60	60	100	50
流入量	21.8	20.1	11.6	21.3	8.5
最大行列長	500	30	30	100	100
初期行列長	100	25	25	80	80

表1 最適交通制御問題¹⁾




図5 目的関数の最適値への収束




図6 制御変数と待ち行列

そして、初期行列長を示している。制御変数はすべて、0.2から0.7の間の値をとるものとする。

前述のように、学習プロセスにおけるシナプス荷重の調整は逆伝搬法で行われるが、適確に荷重を調整するために、各初期変数について数十回の学習が必要となる。初期値を二、三回変えながら、シナプス荷重の妥当性を判断する。

図5はステップワイズ法を用いた場合と、逆伝搬法だけを用いた場合、そして解析解とを比較したものである。ここで、x軸は繰り返し回数を、y軸には目的関数の値をとる。逆伝搬法だけはローカルミニマムに収束し、しかも繰り返し回数が大きくなってしまいうのに対し、ステップワイズ法はグローバルミニマムへの収束に成功している。ここで、ステップワイズ法によって計算された最適解の値は、解析解よりも減少した。これは、解析法との目的関数の違いによるものである。即ち、解析法では(9)式の付加項として、制御変数が予め予定していた“望ましい値”に近くなるように目的関数を設定しているのである。図6は、制御変数列と、それに対応する各リンクの待ち行列長を示しているが、ニューラルネットワークによる結果は、解析解とほぼ一致していることがわかる。

5 あとがき

ニューラルネットワークモデルを1交差点の最適交通制御問題に適用し、以下のような成果を得た。

- 1) 階層的ニューラルネットワークモデルにより定式化が可能である。
- 2) 学習プロセスでは逆伝搬法により数回学習を繰り返すことによって、シナプス結合が決定できる。
- 3) 最適化プロセスでは、逆伝搬法だけを適用した場合はローカルミニマムに収束してしまったのに対し、ステップワイズ法は急速に真の最適解への収束に成功した。

今後の課題として、ニューラルネットワークの、多数の交差点からなる実際の交通ネットワークへの適用を検討してみると、基本的には1交差点のモデルを組み合わせることによって、交通ネットワークのニューラルモデルを構築できると思われる。しかし、重要な問題が数多く残されており、その一つとして交差点間の流入・流出を規定する、走行車両の拡散現象のモデル化があげられる。しかし、入出力結果のみからモデル構造を学習していく階層的ニューラルネットワークモデルは、拡散係数などの既知のパラメータを必要としないので、この問題を解決できると思われる。

動的交通マネジメントシステムのうち、ここでは最適交通制御問題に、自己組織化能力をもつニューラルネットワークモデルの適用を試みた。しかしながら、大規模な交通ネットワークへの適合性や、脳の情報処理を高速で実現するエミュレーションマシンの開発など、システムの実現には検討すべき点も多い。現在のデジタルコンピュータでは、ニューラルネットワークモデルの計算時間はかなり長く、大規模なネットワークに適用すると膨大な計算時間を要するであろう。だが、近い将来、ニューラルコンピュータは、その並行処理能力によって、大規模ネットワークを処理することが可能になるであろう。

参考文献

- 1) OECD: "Dynamic Traffic Management in Urban and Suburban Road System" Road Transportation Research, 1987
- 2) M.G. Singh and H. Tamura: "Modelling and hierarchical optimization for oversaturated urban road traffic networks" Int. Journ Control Vol. 20 No. 6 pp913-934, 1974
- 3) 麻生: 「ニューラルネットワーク情報処理」 産業図書、1988
- 4) 合原: 「ニューラルコンピュータ」 東京電機大出版、1988
- 5) P.D. Wasserman: "Neural Computing" Van Nostrand Reinhold, 1989
- 6) 宮沢: 実践! ニューラルネット、ASCII Vol. 12 #10-Vol. 13 #4, 1988. 10-1989. 4
- 7) 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
- 8) 宇野: 運動軌道の生成と学習システム、コンピュータロ-ル No. 24 pp29-37, 1988
- 9) 川人、宇野、鈴木: 随意運動制御における適応と学習Ⅱ、日本ロボット学会誌 6巻3号 pp50-58, 1988
- 10) 前田、川人、宇野、鈴木: ヒトの上肢多関節運動を学習・生成する多層神経回路モデル、信学技法 MBE87-133 pp233-240, 1988