

自己組織化原理に基づく交通制御手法に関する研究 (その2)

—マルチ入力型ニューラルネットワークモデルの開発—

Self-Organizing Approach to Traffic Control Problems
Using Neural Network Models (Part 2)

中 辻 隆*
加 来 照 俊**

by Takashi Nakatsuji
Terutoshi Kaku

This paper is mainly concerned with improving the neural network, which was proposed in the previously presented Part 1 of this paper, for realizing a self organizing traffic control system. First, to deal with the rapid increase of synaptic weights of neural networks for roads that consist of several intersections, a multiple split model, in which only neurons that were related to an intersection were connected to each other, was proposed. This multiple split model improved not only the computation time but also the estimation precision for untrained patterns. Next, to deal with the optimization of offsets and the variation of traffic situations, a complicated neural network, which has three input sources, one for splits, one for offsets and the other for inflow traffic volumes, was proposed. This model was classified into four types by how the neural networks for those input sources were connected.

1. まえがき

人間の脳の機能を模擬したニューラルネットワークモデルは、その単純な構造にも拘らず、過去の経験や周囲の環境に自律的に対応出来ること、アナログ値やファジイ値を取り扱うことが出来ること、あるいはニューロコンピュータがハード的に実現した場合には大規模場な並列処理が可能となることなど多くの優れた特性を有している。そのため、パターン認識、画像処理、組み合わせ最適化問題、あるいはシステム制御など多くの分野にその応用が試みられている。交通マネジメントシステムもニューロネットワークモデルがその機能を発揮する分野である。特に、自己組織化能力を有する交通制御システムは都市部における交通問題の解決に大いに寄与するものと期待されている。

筆者らは、ニューラルネットワークモデルのもつこのような特性に注目して、自己組織化原理に基づく交通制御システムの開発に従事している⁽¹⁾⁽²⁾⁽³⁾。これまで、信号現示のスプリット長を入力し、待ち行列長やP I (Performance Index) などの目的変量を出力する多層階層型のモデルを提案し、学習過程と最適化過程に分離することによって最適スプリットが推定出来ることを明らかにしている。さらに、学習や最適化の方法にいくつかの提案を行うとともに2、3の道路網への適用を行ってきている。しかしながら、特にシナプス荷重の学習において、改良すべき問題点がいくつか残されている。第1に、従来のモデルにおいては、すべてのスプリット長を入力層に入力し、すべての目的変量を出力層から出力するために、交差点の数が増えるにつれニューロンの結合数が大きく増加し演算時間の増大をもたらした。次に、シナプス荷重の学習においては定常性を仮定していたため、交通状況が変化した場合にはシ

キーワード: 交通制御、ニューラルネットワーク

* 正会員 工修 北大講師 工学部土木工学科

** 同上 工博 北大教授 同上
(〒060 札幌市北区北13条西08丁目)

ナプス荷重を再調整する必要があった。リアルタイム処理を行うためには、広範な交通状態に対して予めシナプス荷重の調整を行っておく必要がある。最後に、従来のモデルにおいては、最適化の対象はスプリットのみでありオフセット等の制御パラメータは、既知であると仮定されていた。特にオフセットの最適化は交通制御システムの実用化においては不可欠なものである。

ここでは、第1に交差点数の増加によるニューロンの結合数の増大に対処するために、各交差点に関係したニューロンだけを結合するようにした。すなわち、従来のスプリット最適化モデルを各交差点毎に設定するようモデルの拡張を行った。これによって演算時間のみならず計算に要するメモリ量も大きく減少させることが出来る。ここでは、これを多重スプリットモデルと呼ぶ。次に、オフセットの最適化と交通状況の変動に同時に対処するために、スプリット、オフセット、および流入交通量の3つの入力信号に関する入力源を有するニューラルネットワークモデルを作成した。それぞれの入力信号の結合方法によって4つのタイプを想定し、未学習データに対する推定精度、および演算時間の面からそれぞれの比較を行った。このモデルをマルチ入力モデルと呼ぶ。さらに、これらの解析を通して効率的な学習方法についても検討を行った。

2. 交通流モデルと学習過程

2.1 交通流モデル

ここでは、制御パラメータとしては、スプリットとオフセットのみを扱い、サイクル長や現示構成については既知であると仮定する。また、最適化のための目的変数としては、遅れ時間と停止回数の加重線形和として表されるPI (Performance Index) を用いるものとする。すなわち、交通状態としては定常であり過飽和状態にはならないものと仮定する。これは、ニューラルネットワークモデル自体に起因するものではなく、PI中の遅れ時間の推定においてTRANSYT^{(4) (5)}中で定義されている算定式を用いていることによる。過飽和状態に適用出来る算定式や実測値を導入することによって、過飽和状態にも対処できる。

2.2 教師信号

ここで用いるニューラルネットワークモデルは、多層階層型を基本構造としており、シナプス荷重の同定に教師信号を必要とする。すなわち、制御変数を入力した時に正しく目的変数を推定出来るよう、事前に既知の出力信号(教師信号)を与えてシナプス荷重の調整を行う必要がある^{(1) (2) (3)}。一般的に教師信号は、交通流シミュレーションモデルを用いて解析的に与えるか、あるいは現場における観測値を用いて実験的に与えるかする。自己組織化能力を有する交通制御システムの実現には後者の方法が望ましいが、ここでは、マクロな交通流モデルを用いて解析的に与えるものとする。すなわち、スプリットやオフセットの制御変数や流入交通量をマクロ交通流モデルに与えて求めた目的変数PIを教師信号とする。マクロ交通流モデルとPIの算定法については、TRANSYT User's Manual^{(4) (5)}に詳しい。

2.3 初期学習

ここでは、シナプス荷重の調整法とその評価法について簡単に紹介する。ランダムに発生させた入力変数を用いて、数十ないし数百組の教師信号を事前に準備する。次に逆伝搬法⁽⁶⁾によりシナプス荷重の調整を行う。これらの入力変数と教師信号の組み合わせを学習パターンと呼ぶ。シナプス荷重の調整においては、ニューラルネットワークによる出力信号と交通流モデルによる教師信号との差が十分小さくなるまで逆伝搬演算を繰り返す。1つの教師信号に対するシナプス荷重の調整は、他の教師信号に対するシナプス荷重の劣化をもたらすので、全ての教師信号に対して二乗平均(RMS)誤差がある閾値以下となるまで学習を繰り返す。これを初期学習という。学習を完了したニューラルネットワークの推定能力を調べるために、新たにランダムに発生させた入力変数を交通流モデルに与えて別途目的変数を準備する。これをチェック信号と呼ぶ。また、入力変数とこのチェック信号の組み合わせを未学習パターンという。ここでは、チェック信号とニューラルネットワークモデルによる出力信号とのRMS誤差をもって評価指標とした。なお、未学習パターンとしては100組のデータを用意した。

3. ニューラルネットワーク

3.1 単一スプリットモデル

Fig.-1に、先に提案したニューラルネットワークモデルを示す。このモデルでは、スプリットのみを制御対象としオフセットは既知と仮定している。入力層(B)、中間層(C)、および出力層(D)から構成されている。場合によっては中間層は2層以上となる。入力層にはサイクル長で正規化された各現示のスプリット長 u を与える。最終層では各交差点の流入リンクにおける目的変量 y 、本解析ではPI値、を出力する。すなわち、入力層におけるニューロン数は、全スプリット数となり、出力層におけるそれは、全流入リンク数に対応する。これを単一スプリットモデルと呼ぶ。Fig.-1中に示すダイナミックモデルが教師信号 z を生成する。このモデルにおいては、スプリットの他に入口リンクにおける流入交通量 q (既知)も与えて教師信号の算定を行う。なお通常、サイクル長は1-2分であるのに対し、車両感知器による交通量の計測は5分毎に行われているを考慮して、流入交通量は数サイクル間一定であると仮定する。すなわち、出力層は数サイクル間総計のPI値を出力するものとする。

3.2 多重スプリットモデル

従来の単一スプリットモデルを多交差点に適用する時、すべての交差点のスプリット値を入力層に、すべての目的変量を出力層に割り当てていたため、交差点数が増加するにつれてシナプス荷重の数が著しく増加した。演算時間も大幅に増大をするとともに推定精度も低下した。一般的に、PI等の目的変量は、流入リンクにおける交通量が推定出来れば良く、上流交差点におけるスプリット値そのものは必要としない。そこで、ある交差点に関するニューロンのみを結合するようにした。すなわち、単一スプリットモデルを各交差点毎に設置した。これを多重スプリットモデルと呼ぶ。FIG.-2にその概念図を示す。ニューロネットワークに関わる演算が各交差点ごとに行われるので演算時間の減少を計ることが出来る。上流交差点のスプリット値が下流リンクに及ぼす影響は、教師信号を通して行われる。すなわち、図中のダイナミックモデルには、各交差点におけるスプリット値と入口リンクにおける流入交通量




Fig.-1 単一スプリットモデル

Multiple Split Model




Fig.-2 多重スプリットモデル




Fig.-3 2交差点への多重スプリットモデルの適用

が入力される。さらに、内部リンクにおける流入交通量もシミュレーションに基づき用意に推定されるので各流入リンクにおけるPIを算定することができる。この値を、各交差点ごとの出力層に教師信号として与えることによって、間接的ではあるが各交差点間の相互作用を考慮した形でのシナプス荷重の調整を行うことができる。なお、この多重スプリットモデルにおいても、流入交通量とオフセットは既知であるとともに不変であると仮定している。

単一スプリットモデルとの比較を通して、多重スプリットモデルの優位性を明らかにする。Fig.-3に示す2交差点を解析例とした。交差点形状の概略と信号現示の構成は図に示す通りである。交差点1は8つの流入部を有し、3現示によって運用されている。他方交差点2は6つの流入部と3つの現示を有している。図中の現示構成の下にある数値は、学習に用いるスプリット値の範囲を示している。なお、リンク長や平均走行速度、流入交通量、あるいは飽和交通流率等についてはTRANSYT USER'S MANUAL⁽⁶⁾に詳しい。本解析においては、2つの中間層を有するニューロネットワーク構造とした。すなわち、単一スプリットモデルにおいては、6-6-14-14とし、多重スプリットモデルにおいては、交差点1に対しては3-3-8-8、交差点2に対しては3-3-6-6のシステム構成とした。なお、数字は各層におけるニューロン数を表している。

Fig.-4は、学習パターン数を30から300と変化した時の100組の未学習パターンに対する評価結果を示している。ただし、各学習パターンの数を増加させるとき、既存の学習パターンに変化はないものとした。例えば、最初の20パターンは、すべてのケースにおいて共通である。また、実際の学習に当たっては、両モデルがともにすべての学習パターンに対して2%以下のRMS誤差となるまで同じ回数逆伝搬演算を繰り返した。図中において、棒グラフが両モデルに対する平均のRMS誤差を示し、折れ線グラフが単一スプリットモデルに対する多重スプリットモデルの演算時間の比を示している。全てのケースにおいて、多重スプリットモデルが小さなRMS値をとるとともに、演算時間についてもおよそ35ないし40%減少している。

Fig.-5は、多重スプリットモデルにおいて、収束条件をRMS値で2%以下とした時の、学習パターン数と演算効率の関係を表している。棒グラフが収束するまでの繰り返し回数を、折れ線グラフがパターン数30のケースに対する演算時間の比率を表している。パターン数50のケースを除き、収束回数が大きく減少している。パターン数が10倍にまで増加しているにも拘らず、演算時間が、高々1.6倍の増加率となっている。このことは、初期学習においては、数多くの学習パターンを用いて学習を行うことが効率的であることを表している。




Fig.-4 単一モデルと多重モデルの比較




Fig.-5 学習パターン数と多重モデルの演算効率

3.3 マルチ入力モデル

オフセットの最適化と交通状況の変動に同時に対応するため、3つの入力源を有するニューラルネットワークの提案を行う。3つの情報源とは、1つがスプリットであり、1つがオフセットであり、他の1つが入口リンクにおける流入交通量である。先の多重スプリットモデルを基本構造としてオフセットと流入交通量に対するニューロネットワークをそれぞれこの基本ネットワークに結合させた。Fig.-6にマルチ入力モデルの概念図を示す。このモデルにおいては、単純のため各ネットワークは、中間層1つを有する3層構造とする。オフセットに対するネットワークにおいて、入力層のニューロン値は各交差点におけるオフセットを表すので、ニューロン数は全交差点数となる。ただし、基準交差点に対応するニューロンは常に0となるようにする。流入交通量に対するネットワークにおいては、入力層の各ニューロンは、各入口リンクにおける流入交通量を表す。内部に駐車場等の発生源を含む中間リンクも入力対象とする。

スプリット、オフセット、および流入交通量の3つのネットワークの結合方法によって4つのタイプに分類する。タイプⅠとⅡにおいては、オフセットと流入交通量に対するネットワークがシステム全体に1つずつ準備されているのに対し、タイプⅢとⅣにおいては、各交差点毎にそれらが準備されている。




Fig.-6 マルチ入力モデルの基本概念

さらに、タイプⅠとⅢにおいては、3つの入力信号が最終の出力層で合流するのに対し、タイプⅡとⅣでは、中間層で合流するものとする（Fig.-7参照）。

多重スプリットの節で用いた2交差点問題を例として、これらのネットワークモデルの特性を調べた。Fig.-7に、4つのモデルに対するネットワーク構成を示した。円内の数字が各層におけるニューロン数を表している。ここでは、Fig.-3に示した交差点図において、103、104、201、および202といった中間リンクもその内部に交通発生源を有しているものと仮定し、これらのリンクも入口リンクとして取り扱った。そのため、流入交通流に対するネットワークの入力層のニューロン数は14となる。

マルチ入力モデルにおいては、先の多重スプリットモデルと異なり、初期学習における事前情報としてはスプリットの他にオフセットと流入交通量も必要とされる。これらは、その範囲を設定してランダムに与えられる。ここでは、スプリットに関してはFig.-3中の値をその範囲とし、オフセットに関しては、0秒からサイクル長（120秒）を範囲とした。Table-1に流入交通量の変動範囲を示す。なお、表中において、中間リンクにおける値は、内部発生源からの発生量のみを表し、上流リンクからの流入交通量は含まれない。




Fig.-7 2交差点問題におけるマルチ入力モデル

4種類のマルチ入力モデルに対して、学習パターン数を30から300に変化させてシナプス荷重の調整を行った。その後、各々のケースについて100組の未学習パターンに対して目的変量P Iの推定誤差(RMS値)を求めた。その結果をFig.-8に示す。学習段階における収束判定のための閾値は3%とした。タイプIIとタイプIVにおいては、学習パターン数が少ないときには比較的大きな誤差となるが、学習パターンが増加するにつれて小さな値となっている。パターン数300においては、タイプIとIIIが約2.0%であるのに対し、タイプIIとIVにおいてはともに約1.7%になっている。Fig.-9は、タイプIIとIVに関して、収束までの繰り返し回数(棒グラフ)とタイプIIに対するIVの演算時間の比を示したものである。演算時間では2、3のケースで逆転現象が見られるが繰り返し回数においては、タイプIIよりタイプIVの方が優れている。Fig.-9には示していないが、タイプIとIIIにおいては、繰り返し回数および演算時間ともにタイプIIやIVより大きく上回った。このように推定精度並びに演算効率において、タイプIIやIVがタイプIやIIIより優れていたのは、各入力信号の結合方法の違いによる。タイプIIやIVにおいては、各信号が中間層で結合されているために、中間層と最終層の間のシナプス荷重の調整量が共通となり各経路間の調整が矛盾なく行われたものと思われる。

マルチ入力モデルにおいては、そのシナプス荷重の調整に数多くの学習パターンと数多くの繰り返し演算を必要とする。目的変量の推定精度に影響を与えない範囲で演算効率を高める方法を確立する必要がある。これまでの筆者らの経験から、用意した学習パターンの最後数パターンの収束に演算時間のかかなりの部分がとられる。Fig.-10は、これまでと同じく2交差点(Fig.-3)を例として、学習パターンのいくつかのパターンに対して収束条件(出力信号と教師信号のRMS誤差が3%以内)を満足しないことを認めたときに、未学習パターンに対する推定精度(棒グラフ)と収束に要する演算時間(折れ線グラフ)がどのように変化するかを示したものである。演算時間については、全ての学習パターンに対して収束条件を満足させた時に対する比率で表して

Table-1 流入交通量の変動範囲(2交差点)

Link	Inflows (veh/h)		Link	Inflows (veh/h)	
	Min.	Max.		Min.	Max.
101	750	1000	201	60	150
102	30	60	202	0	30
103	100	250	203	600	900
104	0	30	204	60	120
105	450	750	205	60	120
106	30	90			
107	300	600	207	90	150
108	60	150			




Fig.-8 マルチ入力モデル (I-IV) の推定精度




Fig.-9 マルチ入力モデル (II, IV) の演算効率

いる。ここでは、300組の学習パターンのうち1ないし7組のパターンが3%の閾値を超えることを認めた。ただし、すべてに対し3.3%は超えないものとした。なお、図中には2、ないし4組に関する結果が欠落しているが、同じ繰り返し回数で同時に2組が収束したことによる。すべての学習パターンに対して収束を求めた時に推定誤差のRMS値が1.74%、他方1組に対して収束条件を免除した場合には、1.93%、7組の時には2.03%となりその差は小さい。演算時間に関しては、完全学習（すべてのパターンが収束条件を満足）に比し50から60%の割合であった。この例では最後の1パターンの収束に全体の約40%の時間を要していた。Fig.-5の結果と併せると、初期学習においては、収束条件を満足しない若干のパターンの存在を許しながら、パターン数を増やすことが効率的であると言える。

最後に、タイプⅡのマルチ入力モデルを4交差点問題に適用した。交差点形状と現示構成をFig.-11に示す。各交差点6ないし8、全部で28の流入リンクから構成されている。図に示すように、各交差点は3ないし4の現示で運用されている。2交差点問題同様、すべての中間リンクはその内部に独自の発生源を有していると仮定する。以上のことから、各入力層におけるニューロン数は、スプリットネットワークで3ないし4、オフセットネットワークでは4、流入交通量ネットワークでは28となる。学習パターンの範囲に関しては、スプリットについてはFig.-11に、入口リンクの流入交通量についてはTable-2にその変動範囲を示した。オフセットについては、0から80秒（サイクル長）の範囲とした。リンク長、走行速度、あるいは飽和交通流率等の詳細な入力値に関してはTRANSYT User's Manual⁽⁶⁾に詳しい。初期学習においては、収束条件を3%としたが、学習パターンのうち1%以内のパターンがその閾値を超えることを許容した。




Fig.-10 未収束学習パターンと学習能力




Fig.-11 4交差点へのマルチ入力モデルの適用

Table-2 流入交通量の変動範囲（4交差点）

Link	Inflows (veh/h)		Link	Inflows (veh/h)		Link	Inflows (veh/h)		Link	Inflows (veh/h)	
	Min.	Max.		Min.	Max.		Min.	Max.		Min.	Max.
101	450	900	201	45	90	301	180	360	401	0	45
102	0	45	202	0	45	302	0	45	402	0	45
103	45	135	203	-90	90	303	135	315	403	540	810
104	0	45	204	0	45	304	0	45	404	45	90
105	450	675	205	45	90	305	450	675	405	45	90
106	0	90				306	45	90			
107	180	270	207	90	135	307	450	675	407	180	360
108	45	90				308	45	90			

Fig.-12 は、500 パターンの学習データを用いてシナプス荷重の調整を行った後に、100 パターンの未学習データを与えて、各交差点毎に平均推定誤差 (RMS 値) の分布を求めたものである。RMS 誤差が学習時の 3 % を超えるものが、交差点 1 では、100 例中わずか 7 例、交差点 4 では 3 例と入口交差点において非常に優れた推定結果を与えている。他方、交差点 2 ではその割合が 38、交差点 4 では 19 と入口交差点では推定精度の低下が見られる。これは、上流リンクからの流入交通量がスプリットの変化に対応して大きく変動するためと考えられる。しかしながら、交差点 2 においても、RMS 値が 5 % を超えるものがわずか 7 例であること、あるいは最大の RMS 値が 8 % 強であることは、交通流モデル自体の表現能力に限界があることを考慮するならば、まずまずの結果であるといえる。

4. あとがき

先に提案した交通制御のためのニューラルネットワークモデルの拡張を行った。まず、対象とする交差点規模の拡大によるシナプス荷重の増大に対処するために、各交差点毎にネットワークを構成した多重スプリットモデルを作成し、従来の単一スプリットモデルに比し、未学習データに対する推定精度、および初期学習における演算効率に優れていることを明らかにした。さらに、交差点間のオフセットと交通状況の変動に対処するために、スプリット、オフセット、および流入交通量の 3 つの入力源を有するマルチ入力ネットワークを作成した。ネットワークの構成方法の異なる 4 つのモデルに関して比較を行い、推定精度および演算効率の面から、各交差点毎のスプリットネットワークにオフセットと流入交通量のネットワークがともに中間層で結合されているモデルが好ましいとされた。また、初期学習においては、若干のパターンが収束限界を満足しないことを認めながら出来る限り数多くの学習パターンを用いて学習する方が効率的であることが確認された。今後さらに、大規模システムへの適用を可能にするために、ネットワーク構成、あるいは学習パターンの選択など多くの課題に対処していく必要がある。




Fig.-12 未学習データに対する RMS 誤差分布 (4 交差点)

参考文献

- 1) T. Nakatsuji and T. Kaku. Development of A Self-Organizing Traffic Control System Using Neural Network Models, Transp. Res. Record (to be published), TRB
- 2) T. Nakatsuji and T. Kaku. Application of Neural Network Models to Traffic Engineering Problems, Proc. 11th Intern. Symp. on Transp. and Traf. Theory, 1990, Yokohama, pp. 291-306.
- 3) 中辻他：自己組織化原理に基づく交通制御手法に関する研究、土木計画学研究・講演集、No.13, 1990, PP.213-220
- 4) R. A. Vincent, A. I. Mitchell and D. I. Robertson: User's Guide to TRANSYT version 8, Transp. Road Res. Lab. Report 888, 1980
- 5) TRANSYT-7F SELF-STUDY Guide, FHWA, U.S. Dept. Transportation, 1986
- 6) D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Learning internal representations by error propagation, in Parallel Distributed Processing, Vol.1, MIT Press, 1986
- 7) P. D. Wasserman: Neural Computing. Van Nostrand Reinhold, 1989