

## IV-2

### ニューラルネットワークモデルの交通制御問題への適用（その3）

北海道大学大学院 学生員 関 俊一  
北海道大学工学部 正 員 中辻 隆  
同 上 正 員 加来 照俊

#### 1.はじめに

人間の脳の情報処理能力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、過去の経験のみから自律的に学習を行うことができるため、非線形、非定常、非論理的構造の表現能力に優れている。また、アナログ値やファジィ値を取り扱うことも可能であり、将来ニユ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。交通マネジメントシステムもニューラル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持つこのような特性に注目し、自己組織化原理に基づく交通制御システムの開発を目指している。これまで、信号現示のスプリット長を入力して、待ち行列長やPI (Performance Index) 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を分離することによって最適スプリットが推定できることを明らかにしている。しかしながら、特にシナップス荷重の学習において、改良すべきいくつかの問題点がある。第一に、膨大な演算時間があげられる。交差点数が増加するにつれ、ますます演算時間が増大することが予想されるため、演算時間短縮の効果的手法を見いださなければならない。次に、交通状況が変化した場合に、リアルタイムに処理するためには広範な交通状況に対して予めシナッ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、最適化の対象をスプリットのみと

しており、オフセットなどの他の制御パラメータは対象としていなかった。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であるため、これを可能としなければならない。

今回の研究においては、これらの問題点を克服するために、これまでのスプリットだけの入力に加え、オフセット、流入交通量を入力するマルチ入力型ニューラルネットワークモデルを提案し、その目的変量の推定能力、スプリット、オフセットの最適化結果について報告する。

#### 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は既知であると仮定する。また、最適化の目的変量としては、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ならないものと仮定する。これは、PI中の遅れ時間の推定においてTRANSYT 中で定義されている算定式を用いることによる。過飽和状態に適用できる算定式や実測値を導入することにより、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、多層階層型で、シナップス荷重の同定に教師信号を必要とするモデルである。つまり、制御変量を入力し

たときに正しい目的変量を推定するように、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。今回は、教師信号として、マクロ交通流モデルを用いて解析的に与えてやるものとする。すなわち、スプリットやオフセットの制御変量や流入交通量をマクロ交通流モデルに、與えることによって求めた目的変量 PI を教師信号とした。

マクロ交通流モデルと PI の算定式については、TRANSYT User's Manual に詳しい。

## 2. 3 初期学習

ここでは、シナプス荷重の調整法について簡単に説明する。ランダムに発生させた入力変量を用いて、数百、数千組の教師信号を事前に用意する。次に逆伝搬法によりシナプスの調整を行う。これらの初期学習時に用いる、入力信号と教師信号の組み合わせを学習パターンと呼ぶ。シナプスの調整においては、ニューラルネットワークモデルによる出力信号と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。ひとつの教師信号について、シナプス荷重の調整を行うと、他の教師信号に対するシナプス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。学習の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量を交通流モデルに与えて、別途目的変量を用意する。この信号は、チェック信号と呼ぶ。また、この組み合わせを、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の RMS 誤差を評価指標とした。

## 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、同時に応答するために、3つの入力源を有するニューラルネットワークモデルの提案を行う。3つの入力源とは、スプリット、オフセット、入口リンクにおける流入交通量である。

図-1 にマルチ入力モデルの概念図を示す。入力層、中間層、出力層の3層構造を例に説明する。ま

ず、各交差点ごとに、スプリットに対するネットワークを用意する。これに、オフセットと流入交通量のネットワークを結合させる。スプリットのネットワークについては、入力層に現示数に対応するニューロンを用意し、各現示のスプリット値をサイクル長で正規化した値を入力する。オフセットのネットワークについては、基準交差点に対するオフセット値をサイクル長で正規化した値を入力する。この入力層には、当該交差点に隣接する交差点の数だけ、あるいは場合によっては全交差点に対応する数のニューロンを準備する。流入交差点に対する交差点には、入口リンクにおける流入交通量が入力される。但し、内部リンクであっても、その内部に交通の発生、吸収源を持つ場合には、それらも入口リンクとして扱う。流入交通量はその最大値のラウンド値によって正規化される。出力層のニューロンは、各交差点のリンク数に対応した数を用意する。中間層のニューロンの数は、任意に設定する。

こういったネットワークに学習パターンを与えて、初期学習を行い、スプリット、オフセット、流入交通量を与えると即座に目的変量であるPIを出力するネットワークを構築する。

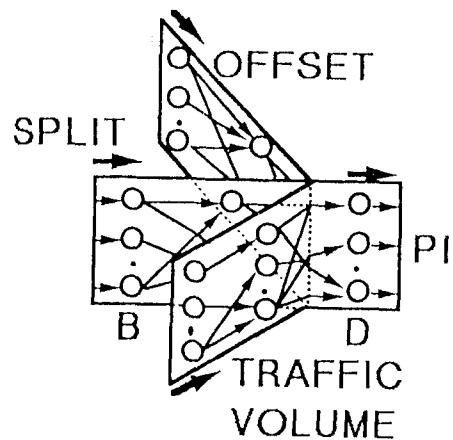


図-1 マルチ入力モデルの基本概念

#### 4. 最適化過程

制御変量（スプリット、オフセット）の数は、多交差点になるにつれますます増えるために、最適解を求めるのは、非常に難解となる。

ここでは、初期学習の終了したネットワークを用いて、コーディーマシンとフィードバック法を組み合わせたステップワイズ法によって、スプリットとオフセットの最適化を行う。

コーディーマシンは、微小なランダムノイズを発生させることによって入力信号を調整し、確率的にグローバルミニマム（最適極小値）に収束させようとするものである。図-2を用いて説明すると、まず、制御変量をランダムに初期設定すると、学習の完了したネットワークを用いることで即座に目的変量の値が決定する。（A点）ここから、制御変量にランダムなノイズを加えて目的変量の値を求め（B点）、目的変量の値がA点に比べ小さければ、次にその点から、ランダムノイズを加えて目的変量値を求める。ノイズの振れ幅をはじめに大きく取り、徐々に狭めていくことで、確率的にローカルミニマムへの収束を防ぎグローバルミニマム（局所極小値）へと導く方法である。これを、数回繰り返した後に、微調整として、逆伝搬法を応用したフィードバック法を用いて、C点から、D点へと収束させるものである。

#### 5. 多交差点への適用

##### 5. 1 学習過程

これまでの研究で、マルチ入力モデルのネットワークの構成は、図-3に示した各交差点ごとに、3つの入力源の入力層から、ひとつの中間層に結合させるものが、最も精度的に優れるといった結果を得た。他に考えた構成には、各交差点ごとに3つの入力層を持ち、それぞれに中間層を持たせるもの、スプリットだけは、各交差点ごとに入力層を持ち、他の二つの入力源については、道路ネットワークでひとつの入力層を用意しているものなどがある。詳細については、省略する。以下は図-3のネットワークにより行った。

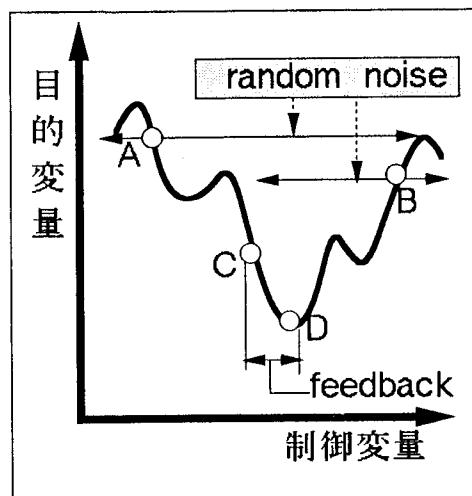


図-2 ステップワイズ法

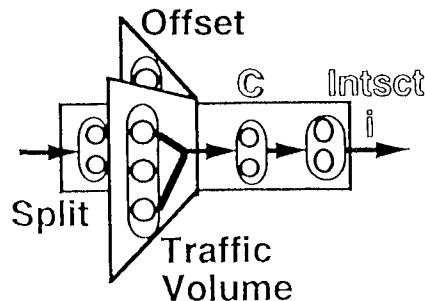


図-3 マルチ入力モデルのネットワーク構成

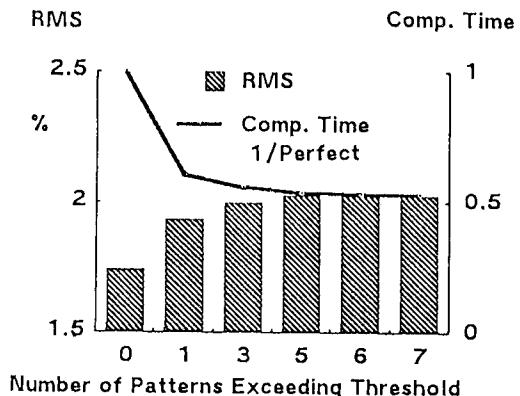


図-4

収束条件緩和の推定精度と演算時間に与える影響

一般的にマルチ入力モデルはシナプス荷重の結合数が多いために、数多くの学習パターンを必要とし、同時に学習に要する時間が膨大になる。演算時間の短縮を計るために、目的変量の推定精度にあまり影響を与えない程度に演算効率を高める必要がある。これまでの経験によると、例えば、数百の学習パターンを与えて学習を行うと、残りの数パターンの収束に演算時間の大半を取られる場合が多い。図-4は、2交差点の例を用いて、300組の学習パターンのうち、収束が遅い最後の数パターンに対して収束条件を緩和したときに、未学習パターンに対する推定誤差と収束に要する演算時間がどのように変化するかを示したものである。ここでは、出力信号と教師信号のRMS誤差が3%以内となることを基本収束条件としたが、残りのいくつかの学習パターンに対しては3.3%までのRMS誤差を許容した。具体的には、1から7組のパターンに対し収束条件の緩和を試みた。なお図-4において、横軸が収束条件の緩和された学習パターン数を表しているが、同時に収束してしまったときがあったために、2と4の時の結果が得られなかった。縦軸がRMS誤差（棒グラフ）と演算時間（折れ線）を表している。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したときの値に対する比率で表している。完全学習（全てのパターンが収束条件を満足）時のRMS誤差が1.74%、1組の緩和の時は1.93%、3組の時が2.00%、7組の時が2.03%とその差は非常に小さい。演算時間に関しても、完全学習のそれの約50%から60%の割合となった。すなわち、この例では最後の1パターンの収束に全体の約四割の時間を要していることが分かる。以上の結果から、マルチ入力モデルの初期学習において、収束条件を満足しない若干のパターンの存在を許容するものとする。具体的には、学習パターンの総数の1%以内の数の学習パターンの収束条件の緩和を許容することとした。

次に、4交差点の例を用いて、その学習精度について検証する。図-5に、3現示8リンク、3現示6リンク、4現示8リンク、3現示6リンクの4つの交差点と、各現示の構成を示す。学習パターンについては、スプリット、オフセット、流入交通量を

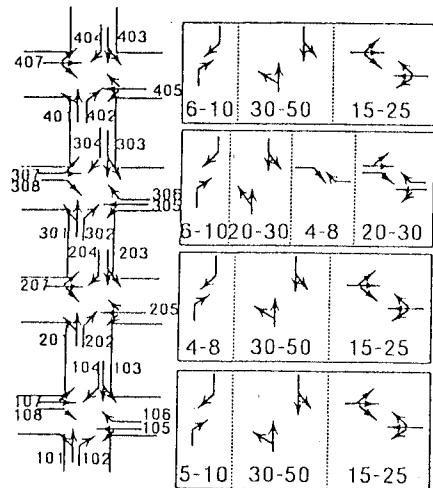


図-5 交差点形状と現示構成

表-1 交差点のリンク諸元

link No.	link length (m)	average speed (km/h)	saturation flow rate (veh/h)	inflow rate (veh/h)	
				min	max
101	120	55	3400	450	900
102	120	55	1600	0	45
103	230	55	3400	45	135
104	230	55	1600	0	45
105	120	55	3400	450	675
106	120	55	950	0	90
107	120	55	3400	180	270
108	120	55	750	45	90
201	230	55	3400	45	90
202	230	55	1600	0	45
203	230	55	3400	-90	90
204	230	55	1600	0	45
205	120	55	700	45	90
207	120	55	660	90	135
301	230	55	3400	180	270
302	230	55	1600	0	45
303	230	55	3400	135	315
304	230	55	1600	0	45
305	120	55	3400	450	675
306	120	55	1600	45	90
307	120	55	3400	450	675
308	120	55	1600	45	90
401	230	55	3400	0	45
402	230	55	1600	0	45
403	120	55	3400	540	810
404	120	55	1600	45	90
405	120	55	1760	45	90
407	120	55	1840	180	270

ランダムに与えている。スプリットの範囲は、図-5に現示構成と共に示している。オフセットについては0秒からサイクル長(80秒)の間の任意の値とした。各リンクにおける流入交通量の範囲については、リンク長、走行速度、及び飽和交通流率と共に表-1に示した。

図-6にはニューラルネットワークの構成と各層のニューロン数を示した。このネットワークに100組の学習パターンを与えて基本収束条件を3%として初期学習を行った。シナプスの調整の完了したネットワークに、100組の未学習パターンを与えて、各交差点ごとに平均推定誤差(RMS値)の分布を求めたのを、図-7に示した。

RMS誤差が学習時の条件である3%を越えるものが、交差点1では、100例中わずか1例、交差点4では2例と非常に優れた推定結果を与えている。他方、交差点2ではその数が9例、交差点3では29例と中間交差点で推定誤差が大きくなっている。これは、中間交差点における交通量が、上流交差点のスプリット値の変化に大きく依存するためと考えられる。しかし、交差点3においても、RMS値が5%を越えるものがわずか5例であり、最大のもので

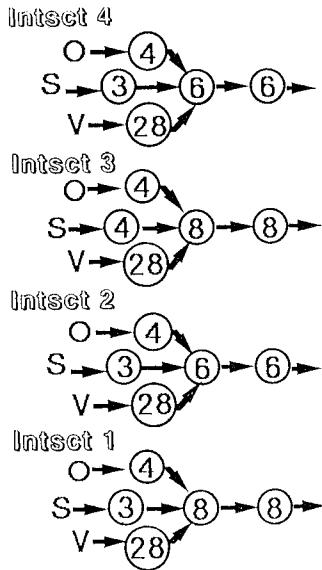


図-6 ネットワーク構成と各層のニューロン

も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、妥当な結果であるといえる。

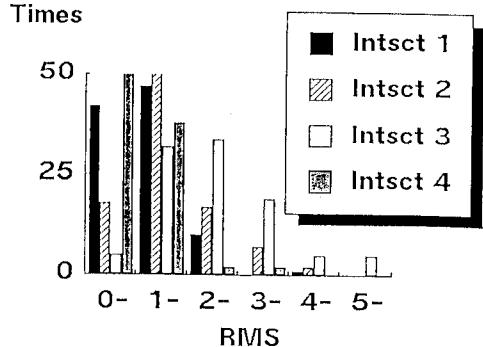


図-7 未学習パターンに対する  
RMS誤差の分布

表-2 最適制御パラメータの推定結果

	case 1	case 2	case 3	case 4	case 5	transyt
交差点	split 1	8	8	7	8	7
	2	40	39	41	38	40
	3	20	21	20	22	21
1	offset	0	0	0	0	0
	PI *1	17	16.7	17.7	16.7	16.8
	PI *2	17	16.2	18.3	16.8	16.7
交差点	split 1	8	7	8	7	6
	2	42	41	42	41	42
	3	18	20	18	20	20
2	offset	46	53	40	49	48
	PI *1	9	9.2	8.8	9.2	9
	PI *2	9.4	10.3	9.3	9.5	9.7
交差点	split 1	10	10	10	10	8
	2	30	28	30	29	30
	3	4	5	4	5	6
3	4	20.00	21	20	20	20
	offset	20	36	10	24	58
	PI *1	28	28.4	28	28	28.5
交差点	PI *2	31.4	31.7	31.3	31.9	31
	split 1	6	6	6	7	6
	2	38	40	41	38	41
4	3	24	22	21	23	21
	offset	40	58	25	41	46
	PI *1	10.7	10.7	10.7	10.9	10.6
	PI *2	11.1	10.6	11.4	11.5	10.7
						13

## 5. 2 最適化過程

初期学習で調整されたネットワークを用いて、任意に与えた交通状況について最適制御変量の推定を試みた。各交差点におけるスプリットとオフセットをランダムに初期設定した後、ステップワイズ法によって最適なスプリットとオフセットを推定した。初期乱数の値を5回変えて最適化を行った。その結果を表-2に示す。また各流入リンクにおけるPI値についても、マルチモデルによる出力値( $PI^{*1}$ )の他に、状態方程式に基づく解析値( $PI^{*2}$ )、さらにTRANSYT/7Fによる解析値も示している。スプリットとオフセットの初期値を全くランダムに初期設定しているにもかかわらず、スプリットに関しては、いずれのケースもほぼ類似した解に収束している。しかし、オフセットに関しては、各交差点とも初期値によらず類似した値となっているが、TRANSYT解とは異なった値となっている。これは、オフセットが、元来その目的関数に対して多峰性を示し、多くの値に対して極小値を持ち、しかもその目的関数の値は相互の差が小さい等の理由によるものと考えられる。

## 6. あとがき

今回は、これまでのスプリットに加えてオフセットの最適化を行うとともに、交通状況の変動に対しても事前に学習できるようモデルの拡張を行った。また、課題とされる演算時間の短縮について、ニューラルネットワークモデルの収束の特徴を検証し、収束条件をほんの少し緩和するといった、単純ではあるが、有効な手段の提案を行った。

学習の面では、今後さらに、大規模交差点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等の課題に対処しなければならない。一方、最適化手法についてもより有効な手法を見いだす必要がある。

## 参考文献

- 1)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（その2）、土木計画学研究・講演集、No.14, 1991, PP. 425-432
- 2)TRANSYT-7F SELF-STUDY Guide, FHWA, U.S. Dept. Transportation, 1986
- 3)P.D.Wasserman : Neural Computing. Van Nostrand Reinhold, 1989
- 4)T.Nakatsuji and T.Kaku : Application of Neural Network Model to Traffic Engineering Problems, Proc. 11th International Symposium on Transportation and Traffic Theory, Yokohama, 1990, pp291-306