

IV-23

自己組織化原理による都市内街路の交通状態の推定について

北大工学部 ○正員 中辻 隆
北大工学部 正員 加来 照俊

1. はじめに

近年、脳の持つ優れた情報処理能力にヒントを得て、その人工的実現を目指す「ニューラルコンピュータ（Neural Computer）」¹⁾が、VLSI等デバイス技術の発展や生体系の情報処理理論の向上にあいまって、いろいろな分野において実際的な研究が始まられている。脳の持つ情報処理能力は、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よって特徴づけられる。脳の基本素子であるニューロン（Neuron：神経細胞）と都市内街路交差点とは、ともにネットワークにおける情報の結節点であるという共通性を有していることから、脳の情報処理手法を街路交通の制御手法に応用することによって、交通流の人工知能的制御が可能になると期待される。ここでは、都市内街路における交通状態の予測と制御に関し、自己組織化原理とニューラルネットワークモデルによる定式化を試みる。

2. 自己組織化法



自己組織とは、「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」²⁾と定義されている。自己組織化の原理に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) GMDH法

定式化が困難な複雑な構造を持つ非線形システムに対して予測などを行なう場合、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。Ivakhnenkoによって提案されたGMDH（Group Method of Data Handling）は、図1に示すような、脳の自己組織化能力の基本的なモデルであるRosenblattのパーセプトロン形の多層構造を仮定し、各層において入出力関係を以下のような線形多項式

$$y = A + Bx_i + Cx_i^2 + Dx_i^3 + Ex_i^4 + Fx_i^5 \quad (1)$$

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してゆき、最終的に完全表現式を得るものである。それ故、発見的自己組織化法（Heuristic Self-Organization）と呼ばれている。図2にGMDH法の基本構成を示す。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発見的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種なアルゴリズムが存在する⁴⁾。

図1 自己組織化のためのパーセプトロンモデル¹⁾図2 GMDH法の基本算法³⁾

2) ニューラルネットワークモデル

自己組織化のもう1つの方法は、モデルの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モデル構造が学習されていく場合である。通常の神経回路モデルにおいては、0、1による刺激一興奮機構により各層間の情報伝達が行なわれるとともに、各層の連結を関係付けるシナップス荷重の大きさは、初期にランダム設定された後、バックプロパゲーション法等による学習を通して習得され、自己組織化される。これは、ニューラルコンピュータにおける自己組織化であり、パターン認識、動体制御などの問題に応用されている。図3にニューラルネットワークモデルの基本的概念図を示す。

3. 交通状態の予測

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予測を行なうことによって、GMDH法における自己組織化原理の概要を示す。

一般的に、ある1地点における交通状態は、自身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時系列解析手法が用いられるが、予測結果はどうしても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。

図4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。表1は、地点0における交通量yの予測に当り、自己の過去値 x_1 を含め、全地点の交通量、占有率、および地点速度のすべてを候補として、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ものである。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閉ループ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。




図3 ニューラルネットワークモデル




図4 車両感知器配置（函館）

表1 GMDH法における変数選択例
(函館: 地点0の交通量予測)

I日の時間帯	第1層で選択された変数
6- 9	x_1, x_2
9-12	x_2, x_{14}
13-16	x_8, x_{14}
16-19	x_1, x_{13}

備考

- x_1 地点0 交通量過去値
- x_2 0 占有率
- x_8 15 占有率
- x_{13} 92 交通量
- x_{14} 92 占有率

図5と図6は、それぞれGMDH法と自己回帰法による予測結果を示す。GMDH法では前日のデータを用いてモデルの同定を行っているが、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した。2つの結果を比較すると自己回帰モデルの方が追従性が良いように見えるが、これは単に1ステップ遅れで追従していることによる。GMDH法では、後半部で多少の偏差が見られるが、比較的良い結果を与えていた。この間の予測誤差は、自己回帰法が24.7、GMDH法が16.4と、変数選択の効果が見られている。

4. 最適交通制御

都市内街路における交通制御は、最適化が最も難しい制御問題の1つである。特に、過飽和状態における制御問題は、極めて重要である。ここでは、図7に示す単独交差点を例とし、過飽和状態における渋滞解消を基本的な目的として、ニューラルネットワークモデルによる定式化を試みる。各流入部での流入交通量と飽和交通流率をそれぞれ Q_i, S_i とする。また、現示は最も単純な2現示方式とし、各現示の青時間 G_j 、サイクル長 C 、ロスタイム L とする。各流入部における行列長 y_i を状態変数とし、現示1における流出率 r を制御変数とすると以下のように定式化することができる。

<ダイナミックシステム>

$$\begin{aligned}\dot{y}_1 &= D_1 - r \\ \dot{y}_2 &= D_2 - S_2 (1 - L/C) + r * S_2 / S_1 \\ \dot{y}_3 &= D_3 - r * S_3 / S_1\end{aligned}\quad (2)$$

$$\dot{y}_4 = D_4 - S_4 (1 - L/C) + r * S_4 / S_1$$

ここで、 $r = S_1 * G_1 / C$

<評価基準(1例: 行列待時間最小)>

$$J = \int_0^T y^T e^{-dt} dt \quad (3)$$

<拘束条件>

$$0 < r_{min} < r < r_{max} \quad (4)$$

$$y(T) = 0$$

この問題においては、全流入路の行列長を同時に解消することは一般的に不可能であり、式(4)の条件が各現示の飽和度を与える流入路(支配流入路)を対象とする時にPontryaginの最大原理を用いて解析的に解くことができる。⁵⁾




図5 基本GMDH法に交通量予測(函館'85.8)
(実線: 実測、破線: 予測)




図6 遂次自己回帰法に交通量予測(函館'85.8)
(実線: 実測、破線: 予測)




図7 交通制御交差点例

ニューロネットワークによるモデル化を図8に示す。文献6)に倣いA層からD層までの4層構成とする。各流入部における流入交通量を入力とし、行列長を出力する。所用時間Tで行列の解消を計るとして、この間の変動をサンプリング間隔 $\delta t = T/N$ で離散化し、1つ1つのニューロンが各時刻における状態を表わすものとする。すなわち各層はN個のニューロンから成っているものとする。図8に見るよう、このモデルの動作は学習モードと制御モードから構成される。学習モードでは、仮定された制御変量 r に対して、各流入交通量 Q_i によって生じる実際の行列長 θ_i とD層が出力する行列長 y_i が一致するようにするシナプス荷重（各層の連結を関係付ける重み係数）の大きさの調整を行なう。すなわちBCとCD間のシナプス荷重を w_{ij} 、 w_{jk} と定義する時、その変化量 $d w_{ij}$ 、 $d w_{jk}$ は逆伝播法により

$$d w_{jk} = (\theta_k - y_k) y_k (1 - y_k) y_j$$

$$d w_{ij} = \sum_k (\theta_k - y_k) y_k (1 - y_k) w_{jk} y_i y_j (1 - y_j) \quad (5)$$

のように求めることができる。

他方、制御モードは、学習モードによって十分な学習がなされた後、支配流入路における行列長が時刻Tにおいて解消されるよう制御変数 r が調整される。この時も逆伝播法が利用され、その変化量 $d r$ がB層にフィードバックされる。図9に流入路1, 2における行列長の時間変化を示す。

5. あとがき

人工知能の実現で最も重要な自己組織化の概念について交通現象への適用を検討した。入出力関係を予め多項式で規定するGMDH法は相関特性が複雑である都市内街路網における交通変量の予測や同定に適していると思われる。しかしながら、変数選択の規範性など検討すべき点も多い。ニューロネットワークモデルの交通制御問題への定式化を試みた。ここで取り上げた例題は、交差点形状としては最も単純なものであるが、これを組合せることによって実際の街路網をモデル化することも可能であると思われる。また、近年のデバイス技術の発展はハード的にモデル化することも可能にしてきている。今後さらに、ニューロコンピュータが得意とするパターン認識を応用した交通状態の識別などの解析を行う。

参考文献

- 1)合原: ニューラルコンピュータ、東京電機大出版、1988
- 2)木村: 自己組織構成論、共立出版、1973
- 3)Farlow: SELF-ORGANIZING METHODS IN MODELING, MARCEL DEKKER, 1984
- 4)池田: GMDHの基礎と応用 - , システムと制御, Vol.23 No.12-Vol.24 No.7, 1980-1981
- 5)Gazis: The oversaturated intersection, Proc. 2nd Intern. Symp. Traffic Theory, 1963, pp.221-237
- 6)宇野: 運動軌道の生成と学習システム、コンピュータール、Vol.24, pp.29-37, 1988




図8 交通制御のための
ニューラルネットワークモデル




図9 行列長の時間変化
(L1, L2: 流入路1, 2)