

IV-350

ニューラルネットワークモデルを用いた交通変量の特性関数表現

北海道大学 学生員 ○田中 満
北海道大学 正 員 中辻 隆
北海道大学 正 員 加来 照俊

1. はじめに

密度—速度（K—V）、密度—交通流率（K—Q）、あるいは交通流率—速度（Q—V）といった交通変量間の関係を関数的に表現する試みは、1930年代のGreenshield¹⁾による研究を発端として、莫大な数の研究が行われてきている。この交通変量間の関数的表現は、線形式はもとより、対数、あるいは指数など多くの解析的な回帰分析手法が用いられてきている。しかしながら交通変量間の著しい非線形性、あるいは不連続性によって必ずしも客観的・普遍的な関係を構築するのに成功していない。そこで本研究は、ニューラルネットワークモデルが有する特色に注目して、交通変量間のマクロ表現にこれらのモデルを用いて表現・比較するものである。

2. 交通変量のマクロ表現法

2. 1 非線形回帰モデル

交通変量の関数表現には、数多くのものがあるが本研究では式（1）に示すような、追従理論に由来する密度—速度関係を基本として用いた関数と比較した。

$$v = v_f \left[1 - \left(k / k_j \right)^m \right]^{\frac{1}{1-m}} \quad (1)$$

ここで $0 \leq m < 1$ 、 $1 > 0$ である。また v_f は自由速度であり、 k_j は渋滞密度である。

2. 2 ニューラルネットワークモデル

観測データのセットだけを与えて、それらの間の入出力関係を自律的に構築するために多層階層型のモデルを導入した。さらに、解析においては観測データが狭い範囲に集中しデータが粗密でばらつきがでてデータの取捨選択が必要となること、あるいは未知のパラメーターの数に比べ観測データ数が多いために、演算時間を要したり、相関係数が低くなったりすることがある。本研究は集中しているデータを集約化するために1次元のKohonen Feature Map (KFM)²⁾の適用を試みた。

1) 多層階層型モデル

多層階層型のニューラルネットワークモデルをFig 1に示す。このモデルは入力層、中間層、および出力層の3層から構成されている。各層のニューロンは相互に結合されており、その重み（シナプス荷重）を外部環境に合わせて変化させ




Fig 1 多層階層ニューラルネットワークモデル

ることにより学習を行うことができる。本研究においては、Fig 1に示すような逆伝搬（BP）法³⁾により学習させた。本研究では、K—Vであれば入力信号をK、教師信号をVとした。

2) Kohonen Feature Map (KFM)

KFMは教師信号なしに自律的に観測データをクラス分けする能力を有している。Fig 2に示すように、KFMは入力層と競合層の2層で構成されている。このモデルは入力層に入力ベクトルが入力されると、競合層のニューロンが競合し、勝利ニューロンが決定する。その勝利ニューロンの近傍のニューロンのみが結合荷重を入力ベクトルへ近づくように修正する。最終的にこの操作をすべての入力ベクトルに対して繰り返せば、入力ベクトルの集約化がなされる。

Fig 2 Kohonen Feature Map

3. 解析結果

3. 1 観測データと解析方法

ここで用いたデータはすべて首都高速横羽線に設置された車両感知器によって計測（1990年10月29日）されたものであり、目視による判断から自然渋滞が発生する前後2時間のデータを選択した。なお、密度Kに関しては、密度と占有率の線形性から、 $k / k_j = Oc / Oc_{max}$ を仮定し密度の代わりに占有率を用いた。

実際の解析方法として次の3種類の方法で比較した。

- 1) 非線形解析モデル（Fig 3）
- 2) BP法による多層階層モデル（Fig 4）
- 3) KFM法とBP法の組み合わせモデル（Fig 5）

なお、3)の方法は120組の観測データをKFM法によって20組のデータに変換した後BP法によってモデル化したものである。

3. 2 解析結果

Fig 3～Fig 5は同じ観測データに対して各モデルを適用させたものであり、Fig 5においてはKFMによって変換されたデータを線で結んで表した。ニューラルネットワークモデルは、算術関数による回帰では解析が不可能もしくは解析に非常に時間を要するような非線形もうまく表現できている。ここで、適合度の比較の指標として重相関係数を用いた。結果は、非線形解析が0.92、BP法が0.97、(KFM+BP法)が0.97となった。重相関係数上でも明らかにニューラルネットワークモデルの方が優れていることが分かる。その他のK-V曲線の適用例は、重相関係数のみTable. 1に示した。どの適用例もニューラルネットワークモデルの方が優れている。ここではあまり紹介しないが、K-Q、Q-Vに対しても同じ様な結果が得られた。参考までにK-Q曲線の方法3)による適用例をFig 6に示す。

Table. 1 Oc-V曲線適用例の重相関係数による比較

感知器番号	81-1009	81-1011	81-1103	81-1203
非線形回帰	0.94	0.87	0.91	0.87
KFM+BP法	0.97	0.94	0.95	0.97

4. まとめ

本研究では、非線形現象に対するニューラルネットワークモデルの表現能力に注目して、交通変量を表現することを試み、その結果を重相関係数で従来の回帰分析によるものと比較することにより次のような結果を得た。

- 1) 非線形解析より相関係数の高い回帰曲線を得ることができる。
- 2) 曲線形状に突起のある非線形な特性曲線をうまく表現することができる。
- 3) 微係数が不連続な形状となる場合にも事前の領域分けなしに適用可能である。

最後になりましたが、データの提供に便宜をお図り下さった首都高速道路公団の各位に深く感謝いたします。

参考文献

- 1) A.D. May: Traffic Flow Fundamentals, Prentice Hall, 1990
- 2) J. Dayhoff: Neural Network Architectures, Van Nostrand Reinhold, 1990
- 3) P. Wasserman: Neural Computing, Van Nostrand Reinhold, 1989




Fig 3 Oc-V曲線 非線形回帰
(10/29: 81-1203)




Fig 4 Oc-V曲線 BP
(10/29: 81-1203)




Fig 5 Oc-V曲線 KFM+BP
(10/29: 81-1203)




Fig 6 Oc-Q曲線 KFM+BP
(10/29: 81-1203)