

ニューラルネットワークによる交通現象解析

岐阜大学工学部 秋山孝正

1. はじめに

交通工学 (Traffic Engineering) の分野は、交通流理論を中心とした道路網交通流の解析を中心に発展してきた。この意味では、道路交通工学と称するほうが適当である。しかしながら都市交通の現状を見ればわかるように、道路交通に限らず交通全般を対象とした研究が必要となっている。したがって、現在の「交通工学」と称する研究分野はTransport Engineering とされる分野に近い概念である。

したがって、時代の要請とともに学問内容が広範囲となってきたといえる。特に交通現象を解析する場合にも、交通渋滞現象などの微視的時間変動をとともなう交通現象を分析しようとする立場と交通計画的に長期的な交通需要予測のための1日単位の交通現象を取り扱う立場が存在する。交通流理論にもとづくシミュレーションモデルなどは前者の典型であり、都市道路網を対象とした交通量配分などは後者の典型であろう。

現在のこうした交通工学において、計算機工学の方法を利用した研究も行われている。特にエキスパートシステム、ファジィ理論、ニューラルネットワーク、遺伝的アルゴリズムなどがその主要な応用技術である。ここではニューラルネットワーク (NN) を交通現象解析に用いた2つの例を紹介する。

2. オンラインOD交通量推計モデル

2.1 OD交通量の推計

単一交差点あるいは都市高速道路の部分区間という小規模の交通施設を考える。

対象とする交通施設はM個の流入部とN個の流出部を持つとする。対象時間をK個の時間帯に離散化して、各々の時間帯をkで区別し、その長さをT (例えば5分間) とする。また交通施設の各流入・流出部あるいは起点 (Origin)・終点 (Destination) における時間帯別交通量が車両検知器等によって自動的に計測されるとする。通過交通流の挙動を記述するために、次の記号と変数を導入する^{[1],[2]}。

$q_m(k)$: 流入部mにおける時間帯kでの流入交通量

$y_n(k)$: 流出部nにおける時間帯kでの流出交通量

$f_{mn}(k)$: 時間帯kでの流入部mから流出部nへの交通量 (時間帯別OD交通量)

$b_{mn}(k)$: 次式の関係を満足するスプリットパラメータ

$$f_{mn}(k) = q_m(k)b_{mn}(k) \quad m=1, \dots, M, n=1, \dots, N \quad \dots\dots\dots (1)$$

スプリットパラメータ $b_{mn}(k)$ は以下の条件を満たさなければいけない。

$$\sum_{n=1}^N b_{mn}(k) = 1.0 \quad m=1, 2, \dots, M \quad \dots\dots\dots (2)$$

$$b_{mn}(k) \geq 0 \quad m=1, 2, \dots, M, n=1, 2, \dots, N \quad \dots\dots\dots (3)$$

$$b_{mn}(k) = 0 \quad (m, n) \in \Omega \quad \dots\dots\dots (4)$$

制約条件 (2) は式 (1) の定義より明かであり、式 (3) はフローの非負条件である。制約条件 (4) は交通施設のいくつかの起終点間にはフローは存在しないことを表し、 Ω はその起終点ペアの集合である。例えば交差

点ではUターンは一般には禁止されている。

起終点間走行時間が時間帯長に対して無視できれば、次のフローの保存条件が得られる。

$$y_n(k) = \sum_{m=1}^M q_m(k) b_{mn}(k) + \zeta_n(k) \quad n=1, 2, \dots, N \quad \dots\dots\dots (5)$$

ここで $\zeta_n(k)$ は走行時間遅れおよび交通量の計測誤差等による観測雑音を表す「ランダム項」である。交差点では交通需要を考慮した交通制御を効率的に行うため、進行方向別交通フロー $f_{mn}(k)$ あるいは同等に直進右左折率 $(b_{mn}(k))$ が必要である。また高速道路では、 $b_{mn}(k)$ は最適ランプ流入制御を行うための流入ランプの影響係数に対応する。

ここで流入・流出部の通過交通流 $q_m(k)$ 、 $y_n(k)$ は車両検知器等により自動計測できるがOD交通流 $f_{mn}(k)$ は計測できない。そこで時系列観測データ $q_m(k)$ 、 $y_n(k)$ から式(2)～(5)の関係を満たすOD交通量 $f_{mn}(k)$ の推計が重要な研究課題である^[3]。

交通流を動的確率過程と考え交通量観測データを有限個の時間帯別交通量と考える。流出交通量と流入交通量の間時間・空間的な変化の応答関係から、起終点間の交通需要に関する情報を検出できる。つまり既存OD交通量等の先験情報を付加せずに交通量の時系列観測データからOD交通量の推計を行うための十分な情報が得られることになる。

しかし起終点別交通流 $f_{mn}(k)$ を推計する場合、フロー保存条件が式(2)右辺のように定数(1.0)とならず動的推計が難しくなる。また更新アルゴリズムの安定性、学習パラメータの設定にも影響されるため、通常 $f_{mn}(k)$ の代わりにスプリットパラメータ $b_{mn}(k)$ を推計対象としている。

この考えに基づいた交通量の時系列観測データからOD交通量を求める手法が提案されている。多くは次式のように流出交通量の観測値と予測値の(加重)残差二乗平方和の最小化からOD分布交通量を求めるものである。

$$\begin{aligned} \text{Min } E(b_{mn}) = & \sum_{k=1}^K \sum_{n=1}^N \frac{1}{\lambda_n(k)} \{y_n(k) \\ & - \sum_{m=1}^M q_m(k) b_{mn}(k)\}^2 \quad \dots\dots\dots (6) \end{aligned}$$

ここで $\lambda_n(k)$ ($0 < \lambda_n(k) \leq 1$)は加重パラメータであり、 $\lambda_n(k)=1$ ならば、式(6)は通常残差二乗誤差となる。式(6)の誤差関数を最小化するように最急降下法あるいはNewton法を用いて $b_{mn}(k)$ を目的関数の降下方向に沿って変化させる必要がある。

パラメータ $b_{mn}(k)$ は0～1間の値を取る相対量で、この値を更新するためのアルゴリズムでは交通量の実際予測誤差の代わりに、予測比率誤差等を用いることが合理的である。このような立場からニューラルネットワーク(NN)の誤差逆伝搬学習アルゴリズムを本推計問題に適用することを試みる。

2.2 誤差逆伝搬学習アルゴリズム

誤差逆伝搬学習法(BP法)は階層ニューラルネットワークの各層間の結合係数を逐次修正して、出力信号と教師信号との残差二乗誤差を最小にするものである^{[4],[5]}。

この方法では単調増加で0から1までの連続した値を取るロジスティック関数により出力信号の正規化を行う。学習アルゴリズムは前章の観測交通量の時系列データからOD交通量の逐次更新法に多くの類似点を持ち、OD交通量のオンライン推計に容易に利用できる。

図-1に示す通常の4枝交差点を例にとって、誤差逆伝搬学習アルゴリズムの推計問題への適用を考える。

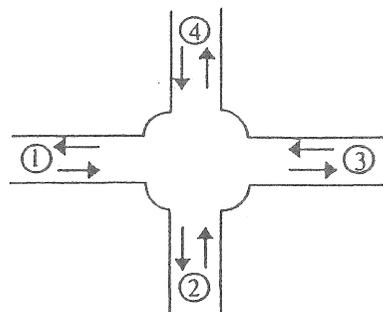


図-1 通常の四枝交差点

この交差点は図-2のように等価的表現ができる。交差点をこのように表現することにより、簡単な2層NNとして取り扱うことができる。このNNの入力層と出力層は各々4個のユニットを持ち交差点の入出力部に対応する。つまり $q_m(k)$ は入力層の m 番目のユニッ

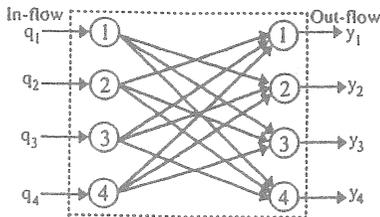


図-2 交差点のネットワーク表現

トへの入力、 $b_{mn}(k)$ は入力層の m 番目ユニットから出力層の n 番目のユニットへの結合係数である。

BP法を交通量のオンライン推計に適用するため入力層の各信号の正規化は行わない。入力層の入力値と出力値は交差点の各流入部のフロー観測値に等しく、ユニット間の結合係数はスプリットパラメータに対応する。いま出力層における n 番目ユニットへの入力の総和を $u_n(k)$ とすると次式で与えられる。

$$u_n(k) = \sum_{m=1}^M b_{mn}(k) q_m(k) \quad n=1, 2, \dots, N$$

..... (7)

次に各時間帯の流出交通量が近似的に正規分布すると考える。そこで観測値と予測値の比較のために、次式のように流出交通量の分布を標準正規分布に変換する。

$$x_n(k) = (u_n(k) - h_n) / w_n \quad n=1, 2, \dots, N$$

..... (8)

ここで h_n 、 w_n は観測交通量から決めるパラメータで各流出部における時間帯 k に関する交通量観測データの平均値と標準偏差である。

次に出力層のニューロンは図-3に示す多入力-1出力の非線形素子モデルを使用し、 n 番目のユニットからの出力 $o_n(k)$ は次式で与えられる。

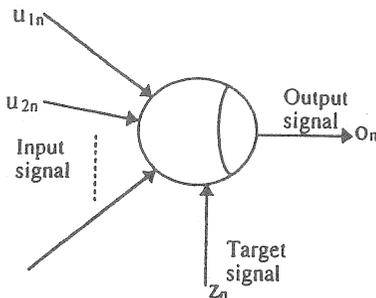


図-3 基本ニューロンモデル

$$o_n(k) = f(x_n(k)) \quad \dots\dots\dots (9)$$

ここで f は単調増加で、 $0 \sim 1$ 間の値を取る連続な出力関数であり、ユニット n の出力を $[0,1]$ の間に正規化させる役割を果たすものである。本研究では、ロジスティック関数($f(x)=1/(1+\exp(-x))$)を採用する。

出力層における n 番目のユニットの教師信号 $z_n(k)$ として、流出部の交通量観測データ $y_n(k)$ を式(8)と(9)によって変換して与える。したがって、誤差関数は次のように定義される。

$$E = \frac{1}{2} \sum_{k=1}^K \sum_{n=1}^N \{o_n(k) - z_n(k)\}^2 \quad \dots\dots\dots (10)$$

この誤差を最小にするには、誤差関数の減少する方向に、各結合係数 b_{mn} (便利のため、添字 k を省略する)を修正する必要がある。すなわち、通常の方法によく用いられる最急降下法等に基づいて各結合係数を $\partial E / \partial b_{mn}$ に比例した量だけ更新していけばよい。ここで ϵ は $0 \sim 1$ 間の値を取る学習定数である(例えば、 $\epsilon=0.25$)。

これより逐次更新式が得られるが、ここでは振動を抑え学習を早めるために、前回の修正量も考慮に入れる。すなわち、

$$\bar{b}_{mn}(k+1) = \bar{b}_{mn}(k) + \Delta b_{mn}(k) + \alpha \Delta b_{mn}(k-1) \quad \dots\dots\dots (11)$$

ここで α は $0 \sim 1$ 間の値を取る安定化係数をである。

2.3 制約条件の取扱い

前述の誤差伝搬法に基づくOD交通量のオンライン推計方法では式(2)~(4)の制約条件が考慮されない。そこで制約条件の取扱いについて述べる。

式(4)を満たすのは容易であり、対応する結合係数(スプリットパラメータ)を繰り返し学習過程でゼロとおけば良い。式(3)はフローパターンの時間変動が小さく、また学習アルゴリズムが収束すれば、スプリットパラメータの推定値が徐々に真実値に収束し、負の値になる可能性は小さい。仮にパラメー

タが負になっても、その時点で零あるいは微小な正数に修正すれば問題は生じない。

さらに式(2)を満足させるために各ステップでスプリットパラメータ(結合係数)の更新を行った後に以下の修正(正規化)を行う。

$$\bar{b}_{mn}(k) = \frac{\bar{b}_{mn}(k)}{\sum_{n=1}^N \bar{b}_{mn}(k)} \dots\dots\dots (12)$$

2.4 数値計算例

図-1に示す四枝交差点を対象として数値シミュレーションを行う。まず入力データを作成するために、直進右左折率 b_{mn} の真実値を定数とし、式(2)~(4)で示す制約条件を満たすように次のものと仮定する^[2]。

| | | | |
|------|------|------|------|
| 0.00 | 0.15 | 0.80 | 0.05 |
| 0.05 | 0.00 | 0.80 | 0.15 |
| 0.30 | 0.20 | 0.00 | 0.05 |
| 0.15 | 0.70 | 0.15 | 0.00 |

観測期間を100個の時間帯とし、各流入部における流入フロー $q_m(k)$ を各々

平均=(55,40,45,50)

標準偏差=(15,10,12,14)

の正規分布に従う100個のランダム整数として与える。方向別交通フロー $f_{mn}(k)$ は与えられた $q_m(k)$ と $b_{mn}(k)$ を用いて式(1)のように計算し、流出部ごとに集計化すると各流出部の流出フローが得られる。さらに計算された流出フローに観測誤差等を反映したランダム攪乱 $\zeta_n(k)$ (式(5)を参照)を加え流出フローの観測値 $y_n(k)$ とする。

以上のように直進右左折率 $b_{mn}(k)$ が定数である場合のシミュレーションデータを作成した。さらにフローが時間変動する場合についてもシミュレートを行うため、直進右左折率に適当なランダム変動と傾向変動成分を加え制約条件(2)~(4)を満たすように修正して時間変動を有する直進右左折率を作成した。また同様な手順で各流入部・流出部における時間帯別フローの観測データを作成した。

以上の2組のデータを用いて直進右左折率が定数である場合の2ケースについて、さきのオンライン推計手法を適用した。

スプリットパラメータの初期値を
0.00 0.40 0.40 0.20

| | | | |
|------|------|------|------|
| 0.30 | 0.00 | 0.30 | 0.40 |
| 0.40 | 0.30 | 0.00 | 0.30 |
| 0.30 | 0.40 | 0.30 | 0.00 |

とし学習パラメータ ϵ , α は数回の試行錯誤の結果、

$\epsilon = 0.88$, $\alpha = 0.40$

とした。

図-4に直進右左折率が時間的に変動しない場合の推計値 (b_{12} , b_{13}) を表す。それぞれ式(25)で修正された結果である。修正量は、パラメータが真実値に収束するにつれて徐々に減少する。しかしパラメータの修正量は“正”と“負”の両方の値を取り互いに相殺されるため、その総和(全修正量)を用いて議論することは難しい。そこで推計誤差について検討する。図-5は交差点全推計パラメータの相対RMS誤差(RMSE%)の学習による時間的変化を表している。これらの結果から分かるように、50回の観測更新を行った後にスプリットパラメータの推計値は真実値の近傍に到達している。

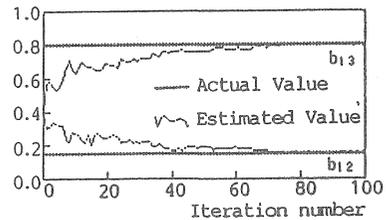


図-4 直進右左折率の推計結果(時間的に変動しない場合)

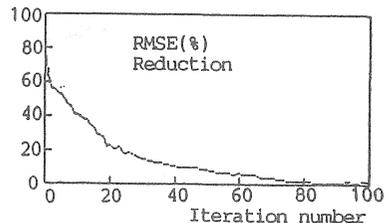


図-5 推計誤差の時間変化(時間的に変動しない場合)

また図-6は直進右左折率が時間的に移動する場合の推計結果 (b_{12} , b_{13}) を示している(この2つのパラメータの真実値はそれぞれ定数0.20, 0.80に、平均0,標準偏差0.03のランダム変動, また0.00(k=0)→±0.20(k=50)→0.00(k=100)の(線形的)傾向変動成分を加えたものである)。図-7は対応する推計誤差

の時間的な変化を表している。これより、誤差逆伝搬学習則による推計アルゴリズムはフローパターンの時間変動に十分追従でき、かつ高い安定性を維持していることが分かる。

この研究では、交通制御・交通情報提供を行うためのOD交通量のオンライン推計法を提案した。この方法は高速道路流入・流出交通量からランプ間交通量をオンライン推計にも利用できる。そこで阪神高速道路の実際観測データについても適用し、OD交通量推計の更新が頻繁に必要なオンライン交通管理に適用できることが確認している。

3. 交通渋滞量の予測モデル

3.1 都市高速道路の交通渋滞

つぎにNNモデルによる都市高速道路の交通渋滞量の予測方法を考える。通常渋滞シミュレーションモデルでは時間変化を考慮した交通現象解析と予測が可能であり、その計算結果は交通制御方法を考える上での基礎的資料となっている。しかし長期的な道路網計画のための平均的な渋滞状況把握や1日単位の交通状態評価が必要となる場合には、簡便な方法での交通渋滞量の推定が必要である。この推計には、特に交通渋滞と交通状態との非線形関係が記述できる方法が望まれる。そこでNNモデルの非線形性の利用を考えた。

3.2 交通渋滞量の定義

つぎに交通渋滞量を規定する数量を考える。ここで渋滞発生時刻 t_s から解消時刻 t_e までの渋滞継続時間 T (h)と渋滞の最大の延伸距離として最大渋滞長 (L) を用いる。これらの数量は日常的に計測・記録され本線上の交通渋滞状況を知る基本的指標となっている。一日全体の交通渋滞の影響範囲として、空間的变化(渋滞延伸距離)と時間的变化(継続時間)を考慮して両者の積で渋滞量を定義する。

$$S = TL \text{ (km} \cdot \text{h/day)} \dots\dots\dots (12)$$

交通渋滞が連続変化をする場合、この指標は時間-距離図の領域面積 S_A に比例する量となる。時間変化を二次曲線と考えると、両者の関係は二次関数の積分値として領域を算

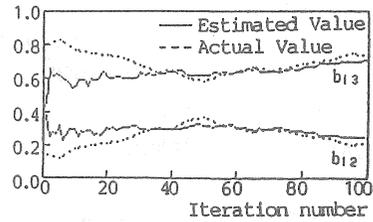


図-6 直進右左折率の推計結果 (時間的に変動する場合)

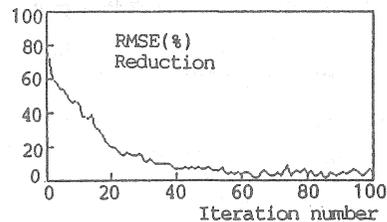


図-7 推計誤差の時間変化 (時間的に変動する場合)

出でき、つぎの関係が容易にわかる⁶⁾。

$$S_A = 2/3 S = 2/3 T L \dots\dots\dots (13)$$

渋滞影響領域の表現として渋滞量を考えると発生・終了時間の変動や一時的非渋滞の発生などの場合にも1日渋滞総量は変化が少なく平均的な交通渋滞程度を表現できる。

3.3 ニューラルネットワークによる推定

交通渋滞量に対してニューラルネットワーク(NN)を用いた推定を行う。ここでもNNモデルのBP法によりモデルを決定する。この結合係数 W_{ji} の修正計算に関して、いくつかの方法が知られている。たとえば逐次修正法の他に高速化に有効とされるモーメント法がある。この場合、前回 $(t-1)$ の修正量を $\Delta W(t-1)$ 、今回 (t) の修正量を $\Delta W(t)$ 、誤差からの修正量を d 、モーメント係数を m とするとき、修正は次式のように行われる。

$$\Delta W(t) = d + m \cdot \Delta W(t-1)$$

モデルよりわかるように、NNモデルでは入力・出力の関係からネットワーク形状のみ規定し、荷重決定により自己組織化を行う。

つまり因果関係が複雑であり、単純な形のモデル規定が困難な場合を想定している。これよりNNモデルによる推定はつぎの利点を持つ。①入出力の関係(教師信号)との推定誤差の最小化を目指す適合性の高いモデルが構築できる。②中間層を持ち非線形関係を容易に表現することができる。

3.4 渋滞量推定モデル

ニューラルネットワーク (NN) を用いた交通渋滞量 (高速道路の隘路区間から発生する渋滞量) の推定を考える。

入力層に相当する説明変数として、隘路区間交通量 (veh/day)、大型車交通量 (veh/day)、合流比率 (%) の3要因を用いる。各数量は、いずれも高速道路上の交通状態変化を表す基本的数量で通常時系列的に収集可能である。ここでは平日の日単位の集計結果を月単位で平均して用いる^{[7],[8]}。

具体的なネットワークとしては、図-8に示す入力層3個、中間層4個、出力層1個の構造を用いることにした。

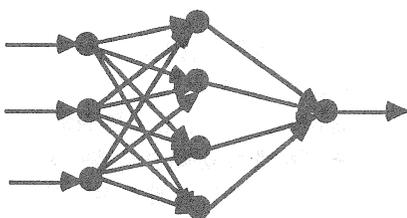


図-8 渋滞量推定のNNモデル構成

計算においては、入力層ニューロンに付加される実数値 (隘路区交通量の計測量) を0~1の区間値に変換している。

3.5 モデル構造の同定

NNモデルの構造は教師データのパターンから各ニューロン相互の結合荷重を決定することにより同定される。対象区間として阪神高速道路空港線上り塚本合流部を先頭とするの自然渋滞を取り上げた。当該区間に対応する教師データは、1986年1月~1988年12月の各月の平均渋滞量で計36データである^[9]。

まず結合係数の修正計算方法を比較するため、この教師データを用いて2種類のBP法で計算を実行した。図-9は逐次修正法とモーメント法による収束計算実行時の標準誤差の変化を示す。ここでは両方法とも収束状況の変化がなくなる修正計算1000回の場合までの標準誤差の比較を行っている。

逐次修正法における誤差変化には、なめら

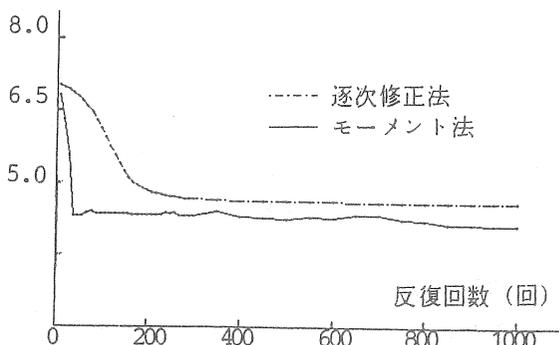


図-9 NNモデルにおける誤差変化

かな単調減少傾向が見られるが、解の収束は遅い。計算回数1000回の場合においても、パターン誤差 E_p は4.85である。修正回数が300回程度以上の部分では、ほとんど誤差の変化がなく、ローカルミニマムに陥っている可能性も考えられる。これに対してモーメント法は、修正40回程度の初期段階で急速に誤差が減少しており、全体的にも逐次計算法に比べて良好な収束性を示している。

3.6 モデル構造と現況再現結果

学習結果はモーメント法による修正計算を10,000回まで続けた結果を用いている。本研究では比較のため、渋滞量を被説明変数とした重回帰分析も行っている。

NNモデルの結合荷重に関する解釈は、モデル構成上難しいが、入力層からの結合係数値の大小 (レンジ) から見ると、渋滞量に対する説明程度は、大型車交通量の影響が比較的大きいことがわかる。

また交通量と合流比率では情報伝達の傾向 (荷重の符号) が逆である部分が多く、渋滞量の増減に対する影響も傾向として逆方向と推測される。

つぎに教師データに対する再現性を検討した。この算出結果を表-1に示す。重回帰分析と同等の推計精度がNNモデルの場合、約1000回の修正計算で達成されている。また修正計算を継続して行った場合 (10000回の算出結果を表示)、いずれの指標を見ても重回帰分析の場合より良好な推定結果が得られてい

表-1 現況再現精度の比較

| 項目 | 残差 2 乗和 | 不偏分散 | 標準誤差 | 相関係数 |
|-----------|---------|---------|-------|-------|
| 重回帰分析 | 2166.89 | 67.72 | 8.23 | 0.816 |
| NN モデル | n=1000 | 2284.98 | 71.41 | 0.806 |
| | n=10000 | 1361.18 | 42.54 | 0.889 |

る（標準誤差：6.52(veh・h/day)）。

誤差の漸近的減少が可能となるのは、重回帰分析では先験的に線形構造を規定したモデル化に対してNNモデルでは現実パターンからの学習を経て構造を決定する過程を取ることによる。さらに重回帰分析モデルとNNモデルにおける各サンプルの再現程度を見るため実績値と推計値の関係を図-10に示す。全体的に見れば、重回帰モデルの推計結果のほうが偏差が大きく、若干過大評価の傾向が見られる。これに対してNNモデルでは、各サンプルとの誤差が最小化され、過大過小のいずれにも偏らない（相関係数：0.889）良好な推計状態である。

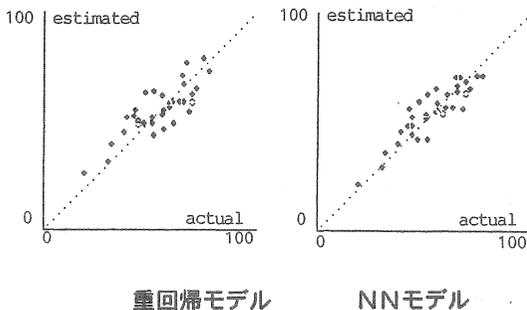


図-10 現況再現結果

3.7 交通量と渋滞量の関係

ここでNNモデルの利用可能性を検討するため、各渋滞地点の交通状況の変化が渋滞量に与える具体的な影響程度を考える。

特定路線に関して交通条件と渋滞程度の間を知ることは、いくつかの現実的問題にも関連する。たとえば、①大規模な事故・工事などによって継続的な交通容量の低下が発生するとき、②新規の交通規制・交通制御が導入され、関連路線間で交通流動の変化が生じるときなどがこれに相当する。

ここで求めたNNモデルにおいては交通条件の変化は説明変数として取り上げた変数値の変化として記述でき、これらの変数が渋滞量に与える影響程度を算出することができる。ここではモデル化に際して用いた変数の中から合流比率と交通量を取り上げる。

図-11は合流比率ごとに交通量との関係をNNモデルにより算出したものである。ここで両変数値については実績値を参照して起こりうる範囲を設定した。

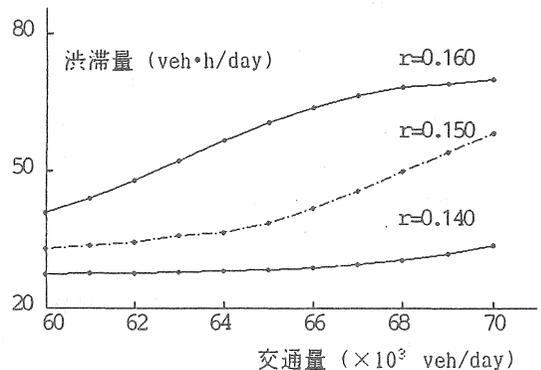


図-11 交通渋滞量と各要因の関係

この結果より、いくつかの点を観察することができる。

- ①交通量の増加と交通渋滞量の関係は線形ではなく非線形的な単調増加として現れる。
- ②合流比率の値によって、交通量-渋滞量関係は変化形状が異なる（ $r=0.14$, $r=0.15$ では下に凸、 $r=0.16$ では上に凸）。
- ③交通量が同一であるとき合流比率の変化が与える影響は、交通量が大きき場合に著しい。

以上の点から、合流比率および交通量の影響を考慮した渋滞量変化の状況が把握できた。

このように各種交通条件の変化の影響はNNモデルでは、新規パターンに対する出力算定と解釈される。本例に見るように要因間に存在する多様な非線形的な関係を内在的に表現できる点は、線形モデルにないNNモデルの長所であるといえる。

この研究は、従来の統計的処理方法である線形重回帰分析に対して、簡便な非線形推定法としてNNモデルを用いたものである^[10]。

4. おわりに

本研究では、交通工学における計算機工学手法の応用について、ニューラルネットワークを用いた研究例を紹介した。計算機工学の手法のなかでも NNモデルは、非線形計算手法としての有効性を持っており、本研究では交通工学の分析に対して従来法を効率的に改良する方法として位置づけている。

しかしながら、これまでに用いられている各種の計算機工学手法のなかでは、NNモデルはファジィ理論や遺伝的アルゴリズムに比べて計算指向性の強いモデルであるといえる。すなわち、問題設定が比較的単純であるため、工学的応用範囲は広いが、理念的なモデル拡張が難しいということである。この意味では、本研究で示した微視的な近似方法として交通流解析を行う場合には、NNモデルの応用性は高いといえる。しかしながら、経路選択や交通量配分などのマクロ的な人間行動を基本においた、いわゆる交通行動分析においては、適用方法が難しい局面がある^[11]。

すでにファジィ理論や遺伝的アルゴリズムを交通工学分野に応用した研究例は多数存在する。特にファジィ推論を交通行動現象に応用した研究については、基本的なモデル化手順が体系的に研究されており、すでにNNと結合したハイブリッド型のモデル化が検討されている^{[12]-[14]}。またこのとき、パラメータ推計法のひとつとして、遺伝的アルゴリズムを利用した研究も行われている。

したがって、交通工学の対象分野の広がりに対応して、利用されるべき分析技法にも多様性が必要であることがわかる。

そして、各方法の有機的關係を考慮するとこれらの研究は、NNモデルを用いた交通現象解析においても人間工学的な意味を付加する意味で重要であると思われる。

なお本研究で紹介した研究例はそれぞれ、筆者の京都大学工学部勤務時に京都大学から学位を授与された邵春福氏（現システム科学研究所研究員）と楊海氏（現香港科学技術大学講師）との共同研究の成果である。

- [1] Hai Yang, Takamasa Akiyama and Tsuna Sasaki : A Neural Network Approach to the Identification of Real Time Origin-Destination Flows From Traffic Counts, Artificial Intelligence Applications in Transportation Engineering, pp.253-269, 1992.
- [2] 楊海・秋山孝正・佐佐木綱：時系列観測交通量を用いたODフローのオンライン推計法，交通工学，Vol.27，No.1，pp.33-41，1992.
- [3] 楊海・飯田恭敬・佐佐木綱：観測リンク交通量を用いた時間OD交通量動的推定法，土木計画学研究・講演集，No.13，pp.599-606，1990.
- [4] 菊池豊彦：入門ニューロコンピュータ，オーム社，1990.
- [5] 中野警監修，飯沼一元編：ニューロンネットワーク，桐谷滋著：入門と実習ニューロコンピュータ，技術評論社，1989.
- [6] 秋山孝正・邵春福：ニューラルネットワークによる交通渋滞量推定について，土木計画学研究・講演集，No.14，pp.417-424，1991.
- [7] 邵春福・秋山孝正・佐佐木綱：ニューラルネットワークによる都市高速道路の交通渋滞量推定，土木学会第46回年次学術講演概要集，1991
- [8] 阪神高速道路公団・（社）交通工学研究会：阪神高速道路の交通渋滞対策に関する調査研究報告書，平成2年3月
- [9] 阪神高速道路公団：阪神高速道路のしごと，1989，1990
- [10] 邵春福：都市交通管理計画におけるファジィ理論の応用に関する研究，京都大学学位論文，1991.
- [11] 秋山孝正・楊海・高橋寛：ニューラルネットワークを用いた交通行動パターン分析，交通工学，Vol.28，No.1，pp.25-33，1992.
- [12] 秋山孝正・邵春福：ファジィ推論の交通行動分析への応用，ファジィ土木応用研究会講演論文集，Vol.1，pp.67-78，1993.
- [13] 秋山孝正：ファジィ理論を用いた道路交通流解析，土木計画学研究・論文集，No.11，pp.13-28，1993.
- [14] 秋山孝正：知識利用型の経路選択モデル化手法，土木計画学研究・論文集，No.11，pp.65-72，1993.