

都市高速道路における多種データを用いたランプ間動的 OD 交通量の簡易予測

名城大学 学生員 松葉一弘
 名城大学 正会員 松本幸正
 (財)名古屋高速道路協会 杉原良紀

1. はじめに

都市高速道路におけるランプ間動的 OD 交通量の短期予測は、渋滞予測や所要時間予測に必要なデータであるとともに、シミュレーションを用いた交通運用ツールへのインプットとしても不可欠である。一方、AVI や光ビーコンといった交通観測機器の拡充により、比較的容易に過去の動的 OD 交通量の観測は可能となってきている。

そこで本研究では、高度交通運用に必要なランプ間動的 OD 交通量の予測モデルとして、AVI データや車両感知器データを用いたニューラルネットワークモデルを提案し、モデルの適応性を名古屋高速道路の楠料金所～大高出口間の観測データを用いて検証する。

2. ニューラルネットワークモデルの構造

本研究におけるニューラルネットワークモデルの構造は、入力層 28 ユニット、中間層 15 ユニット、出力層 1 ユニットの階層型ニューラルネットワークモデルである。入力層には、図-1 に示すように観測データを用いて 5 分間隔で集計した流出入交通量とランプ間の主要な 4 箇所交通量、速度、オキュパンシーを現在から 5 分前までと 5 分前から 10 分前までの過去 2 インターバルのデータを与えた。出力層からは 5 分後の流入ベース OD 交通量の予測値が得られる。

ユニット間の結合の重みの学習には 30 分間のラグを持たせ、現在の 30 分前から 3 時間 30 分前までの 3 時間分のデータと 24 時間前から 27 時間前までの 3 時間分のデータを用いることにした。これより学習データは常に更新され、それと同時に結合の重みも更新されることから、OD 交通量の日変動と時間変動を包含した的確な予測ができると思われる。学習に 30 分間のラグを持たせたのは、流入ベースの OD 交通量を得るために、時間インターバルに流入したすべての車両が流出するまでの時間を必要とするためである。結合の重みの更新にはモーメント法を用い、最大学習回数は 5000 回とした。そして、教師データと出力値の誤差が最小となった時のユニット間の結合の重みを用い

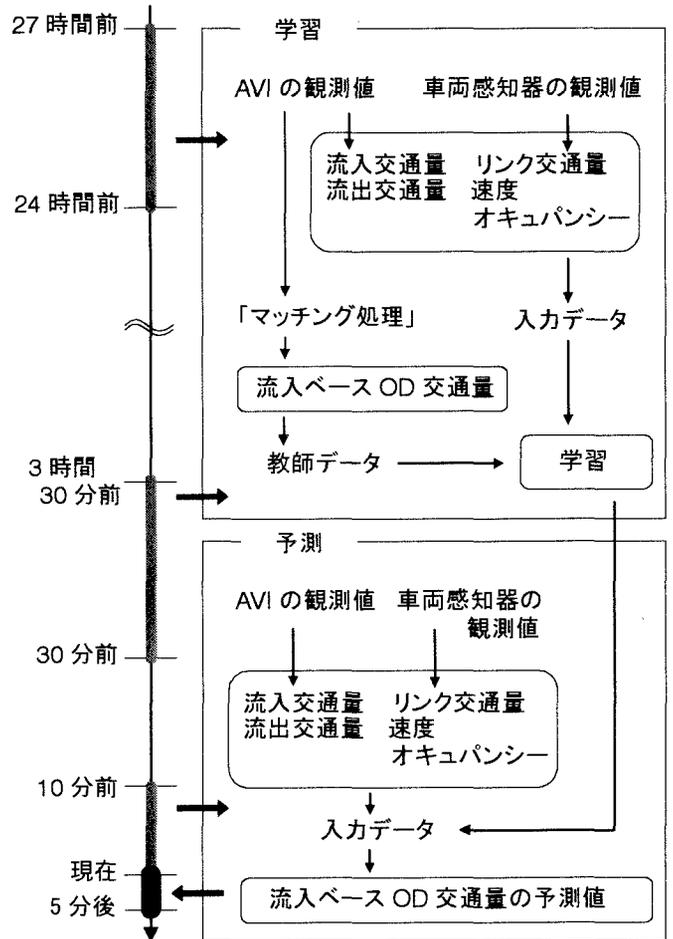


図-1 ニューラルネットワークモデルのフロー

て、ランプ間動的 OD 交通量の予測を行った。

3. ニューラルネットワークモデルの適応性の検証

ニューラルネットワークモデルの適応性を検証するため、平成 13 年 10 月 22 日(月)から 26 日(金)までの名古屋高速道路の楠料金所～大高出口間の AVI と車両感知器の観測データを用いて OD 交通量の予測値と実測値を比較する。また、ここではニューラルネットワークモデルの予測値と実測値および式(1)に示すような単純な AR モデルによる予測値を用いて検証する。

$$Q_{ij}(t+1) = \alpha_0 + \alpha_1 Q_{ij}(t-6) + \alpha_2 Q_{ij}(t-7) \dots (1)$$

$Q_{ij}(t)$ はオンランプ i とオフランプ j 間の OD 交通量、 α は自己回帰係数、 t は時間インターバルである。

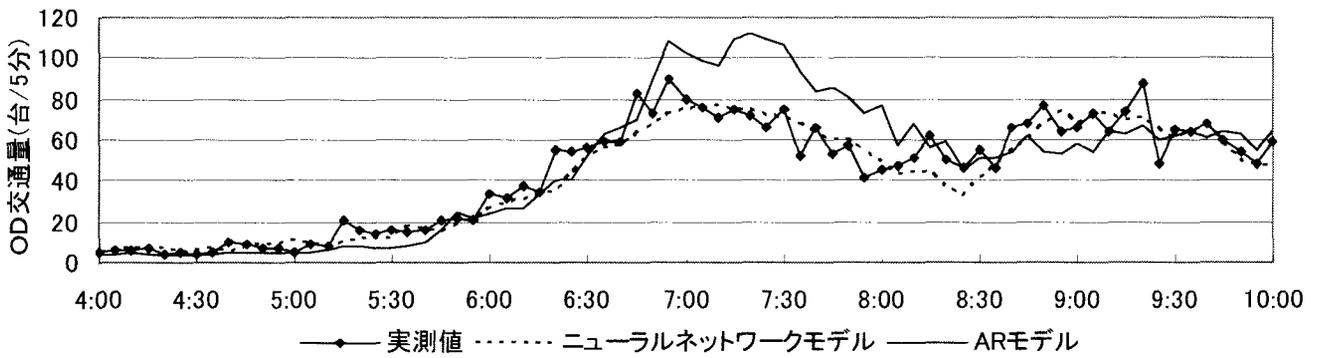


図-2 流入ベース OD 交通量の予測結果(10/26, 楠料金所-大高出口間)

AR モデルに 6 および 7 インターバル前のデータを用いたのは、ニューラルネットワークモデルの場合と同様に流入ベースの OD 交通量を得るために必要なタイムラグを考慮したためである。また自己回帰係数の算出は、ニューラルネットワークモデルの学習に用いたデータと同様のデータを用いて行った。

図-2 に 26 日(金)午前 4 時から 10 時の OD 交通量の実測値と予測値を示す。ニューラルネットワークモデルによる予測値は、比較的高い精度で得られていることがわかる。特に朝のピーク時において、AR モデルによる予測値は実測値に対して遅れた変動を示すが、ニューラルネットワークモデルは若干の遅れはあるものの、比較的良好に追従できていることがわかる。

表-1 に OD 交通量の予測を行った 24 日から 26 日の 4 日分の予測値と観測値を用いて算出したニューラルネットワークモデル、AR モデル、実測値の 24 時間ラグをとった時の RMS 誤差と相関係数を示す。なお 23 日に事故が発生したために 23 日と 23 日のデータを予測に用いる 24 日の予測精度は低い値を示している。ここでは 25 日と 26 日の RMS 誤差および相関係数について述べる。ニューラルネットワークモデルの RMS 誤差は他のモデルと比べると、どの時間帯も同等もしくは小さくなっていることがわかる。さらに、相関係数も若干ではあるが他のモデルよりも高い値を示している。このことから、ニューラルネットワークモデルは他のモデルよりも高い予測精度を持っていることが明らかになった。

4. おわりに

本研究では、高度交通運用に必要なランプ間動的 OD 交通量の予測モデルとして、AVI データや車両感知器データを用いたニューラルネットワークモデルを提案した。モデルの適応性を名古屋高速道路の観測デ

表-1 RMS 誤差と相関係数

日	時間帯	RMSE		
		ニューラルネットワーク	AR	24時間ラグ
23日	0~6	4.484	4.356	3.695
	6~12	20.017	23.197	19.558
	12~18	16.852	12.165	16.846
	18~24	11.150	6.862	11.977
	相関係数	0.588	0.667	0.699
24日	0~6	3.306	3.686	3.629
	6~12	24.737	18.845	23.367
	12~18	9.228	7.290	10.894
	18~24	5.716	7.552	6.764
	相関係数	0.752	0.850	0.764
25日	0~6	4.004	4.591	5.794
	6~12	13.000	24.274	16.414
	12~18	8.513	9.787	10.165
	18~24	5.715	8.102	7.402
	相関係数	0.923	0.860	0.888
26日	0~6	3.017	3.682	3.636
	6~12	9.184	15.953	10.915
	12~18	9.117	7.344	10.593
	18~24	5.649	7.242	8.012
	相関係数	0.947	0.912	0.921
RMSE(4日分)		11.528	11.972	11.865
相関係数(4日分)		0.826	0.841	0.824

ータを用いて検証した結果、事故時についてはよい結果を得ることはできなかったが、平常時については他のモデルと比べ高い予測精度を得ることができた。特に、他のモデルが OD 交通量の急激な変動に対して、遅れた反応を示すのに対してニューラルネットワークモデルは追従性が優れていることが明らかになった。

今後の課題は、さらなるデータを用いてモデルの適応性の検討を進めるとともに、モデルから得られる OD 交通量の予測値を用いて、AVI 未設置区間における OD 交通量の予測手法を検討する必要がある。