

上・下流の交通量および速度を考慮した 9 Q-3 ニューラルネットワークによる交通量予測

加藤誠巳 青山ゆき
(上智大学理工学部)

1. まえがき

首都圏道路網の交通状況は、年々悪化の一途をたどっている。しかし、未来の道路状況を事前の交通流データより予測しうるならば、迂回路をドライバに指示したり、最適信号制御を行ったりすることにより、渋滞を回避することが可能となる。また、目的地までの旅行時間を予めドライバに知らせることも出来る。

従来、予測の手法として、(1)多項式の当てはめ、(2)上流の交通量からの推定(上流で測った交通量が走行時間だけ遅れて現れる考え方)、(3)交通現象の周期性の利用(曜日や時刻の関数として、過去のデータから統計的に求めておく方式)等、様々な方式が提案されてきた^[1]。

本稿では、時間的、空間的な種々の予測因子を統合した処理及び統計的な処理を行うことが出来ると考えられるニューラルネットワークを用いて、道路に設置されている車両感知器より得られる交通量及び速度データをもとに、未来的な交通量を予測する手法を述べる。

2. 使用データ

今回は交通流データとして、次のように収集された交通量及び速度を用いた。ここで言う交通量及び速度は、観測点 x_0 での単位時間当たりの車両通過台数、 x_0 を通過する各車両の時間的平均速度である。

収集期間：平成3年8月1日～平成3年11月30日
収集時間：午前5時～午後8時の5分毎のデータ

収集場所：東京の郊外から都心部へ向う上り放射道路

感知器数：34(感知器番号Q0(下流)～Q33(上流))

但し、交差する主要幹線の感知器を除くと27

また各データは、ランダムなリップルや信号機による変動を取り除くため、指数平滑(平滑指数0.5、平滑回数2回)を行った。

さらに感知器毎の交通量の平均値には、その地点の道路状況の差による影響のために偏りがある。この偏りを取り除くため、各データをその感知器毎の交通量の平均値を用いて正規化した。

3. 交通量の伝搬

ネットワークが空間的予測因子を捉えるためには、交通を流れ(波動)として見なし、予測地点の上・下流からの交通量の伝搬を考慮する必要がある。

交通の流れを圧縮性流体と考えて、流体力学的手法によつ

Road Traffic Prediction by Neural Networks
with the up and down-stream Traffic
and Velocity Information as their inputs
Masami KATO, Yuki AOYAMA
Sophia University

て考察する研究は以前から行われている。ここで、交通量を q 、速度を v 、密度を k で表す。微小道路区間での流入出交通量の差は、微小時間での密度の変化率に等しいから、連続の式

$$\frac{\partial k}{\partial t} + \frac{\partial q}{\partial x} = 0 \quad (1)$$

が成立する。一般に速度 v は、密度 k の減少関数である。また、 $q = k \cdot v$ であるので、交通量 q は密度 k の関数と考えられるから、式(1)は

$$\frac{\partial k}{\partial t} + \frac{dq}{dk} \cdot \frac{\partial k}{\partial x} = 0 \quad (2)$$

と表される。式(2)は状態量 k の波動方程式であり、波動の伝搬速度 u は

$$u = \frac{dq}{dk} \quad (3)$$

となる。

密度 k 、速度 v 、および交通量 q の関係を図1に示す。密度 k と交通量 q のグラフ上で原点と結ぶ直線の勾配は速度 v を表し、接線の勾配が波動伝搬速度 u を表すことになる。よって、交通量 q を最大にする密度 k_m よりも密度が小さい領域、すなわち速度が v_m より大きい領域では、波動伝搬速度 u は正であり、波動は車両の進行方向に伝搬する。また、 k_m より密度が大きい領域、すなわち速度が v_m より小さい領域では u は負であり、波動は後方に伝搬することがわかる。

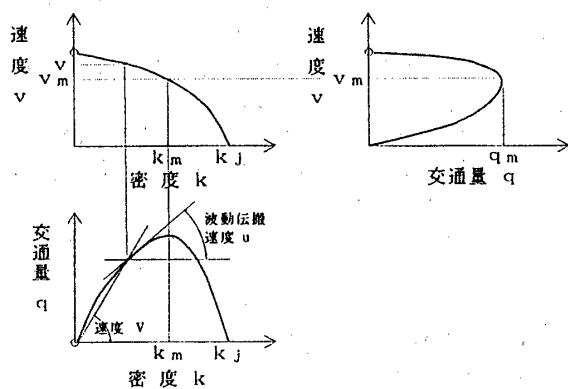


図1 交通量・速度・密度関係図

図2に、速度別に感知器Q17(予測対象地点)の現時点での交通量の変化量 dQ_{17} の、他の感知器 i の5分前の交通量の変化量 dQ_i に対する1次相関係数を求めたものを示す。図には速度が v_m ($v_m = 27.2 \text{ km}$: この値は、実際のデータの交通量と速度の回帰2次曲線を求めるこにより、算出した。) 以下であるとき(10～15km)、及び v_m 以上であるとき(45～50km)の例が示してある。これにより、確かに速度が v_m より大きい場合には、波動は車両の進行方向に、小さい場合には後方に伝搬していることが確認できる。

そこで、ネットワークへの入力として、予測時の速度に応じて、予測地点に影響を与えると思われる上・下流地点のデータを用いることとした。

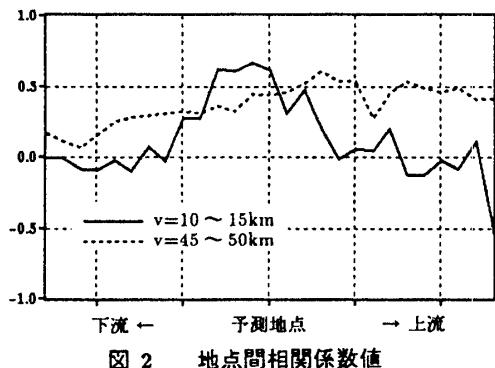


図 2 地点間相関係数値

4. ネットワークの構成

ネットワークとして、単なるフィードフォワード型のネットワークを用いてデータ間の写像を学習するだけでは、長期的な予測を行なう場合重要な時間相関が無視され、時系列である交通量の特徴が捉え難いと考えられる^[2]。そこで、今回、すべての出力を数ステップ（1ステップ=5分）前のデータと関連させるよう、ネットワークに出力層から入力層へのフィードバックを加えた^{[3][4]}。

このとき、予測値に対応するニューロンの出力値と実際の値（教師データ）との差を入力とするニューロンを入力層に付加する。これにより、このフィードバックは学習が進むと徐々に消滅する（学習が十分であれば、ニューロンの出力値と教師データの差はほぼ0となることが保証される）。学習過程では時系列としての特質を利用し、全データが利用できない予測過程ではフィードバックがカットされることになる。

従って時間相関を考慮し、さらに前述のように空間的予測因子が捉えられるよう、図3ようにネットワークを構成し、5分後から1時間後までの交通量を予測する学習を行った。但し、 $Q_i[k]$ 、 $S_i[k]$ は感知器 i （予測地点は17）の第 k ステップ時刻における交通量および速度を表し、時刻 $k-n$ は第 k ステップ時刻の n ステップ前を表す。また $\bar{Q}_{17}[k+i]$ は $Q_{17}[k+i]$ の予測値を表すものとする。

- 入力層のニューロン数：32 + 12 (12は付加した
入力ニューロン数)
- 中間層のニューロン数：10
- 出力層のニューロン数：12
- 入力データ
 - ： $Q_{17}[k] \sim Q_{17}[k-5]$, $S_{17}[k] \sim S_{17}[k-5]$,
 - $Q_i[k] \sim Q_i[k-2]$, $dQ_i[k]$ (i :速度に応じた上下流地点)
- 付加した入力データ
 - ： $Q_{17}[k+1] - \bar{Q}_{17}[k+1] \sim Q_{17}[k+12] - \bar{Q}_{17}[k+12]$
- 教師データ
 - ： $Q_{17}[k+1] \sim Q_{17}[k+12]$

5. 予測実験

上述のネットワークを用いて、午前7時30分～午前9時のデータで学習を行った。図4は、学習後のネットワーク

で8時以前のデータより、8～9時の予測を行ったものである。学習は8～10月のデータをクローズデータ、11月をオープンデータとしている。予測値が実際のデータ（測定値）の±5[台/5分]以内であれば予測出来たと見なし、予測を行ったデータ数に対する百分率で表すと、オープンデータで86%の予測精度が得られた。

6. 結び

本稿では、(1)ネットワークへの上・下流地点の入力データとして、予測時の速度に応じて変化する予測地点に影響を与える地点のデータ用い、(2)出力層から入力層へのフィードバックを持つニューラルネットワークを用いて交通量を予測することを提案し、1時間後まである程度予測することが出来ることを示した。最後に、有益な御討論を戴いた本学マルチメディア・ラボの諸氏に謝意を表する。

参考文献

1. 中原、保原：“トラフィック制御”，コロナ社, p.503 (1975).
2. 加藤、青山、井上：“ニューラルネットワークを用いた交通量予測”，情報処理学会第44回（平成4年前期）全国大会, 4U-5 (1992).
3. 安達、合原：“ニューラルネットワークと予測”，オペレーションズ・リサーチ, Vol.37, No.7, pp.336-341 (1989).
4. 松葉：“バックプロパゲーションによる特徴抽出”，数理科学, No.338, pp.31-37 (1991).

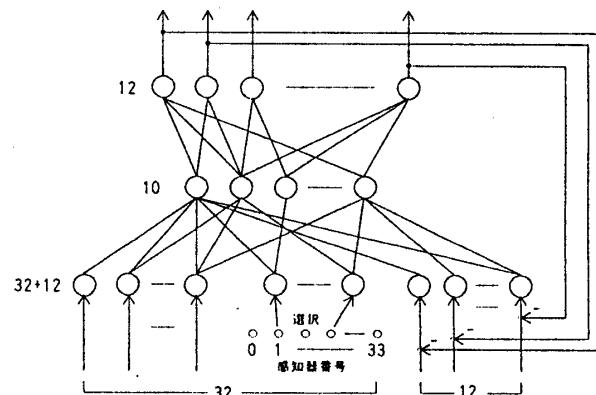


図3 ネットワークの構成

[台/5分]

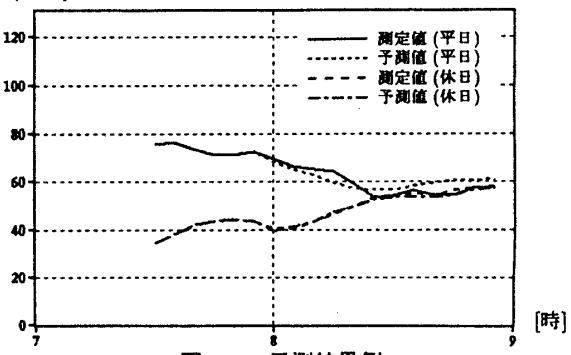


図4 予測結果例