

IV-246

一般街路のリンク交通量の短期予測

山口大学大学院 学生会員 山崎 徹也

山口大学工学部 正 会 員 久井 守

1. はじめに

本研究は、一般街路上の車両感知器から得られた交通量データを用いて、そのリンクの交通量の短期予測を行ったものである。予測手法として、ニューラルネットワークとカルマンフィルターを用い、それらの予測結果を比較した。本研究は、リアルタイム予測を目指している。交通量の短期予測を精度よく行うことは、交通制御、交通情報の提供および経路誘導システムの運用において有用である。

2. 予測対象

リンク交通量の予測対象として、福岡市の国道202号上り方向の1リンクをとり、そのリンクの車両感知器による観測交通量を用いた。観測日は、平成7年1月24日(火)～1月26日(木)および1月31日(火)、2月1日(水)、2日(木)の2週それぞれ3日分である。ただし、観測交通量は1時間レートに換算した5分間交通量である。これらのデータは、指数平滑化されたものである。また、第1週の1月24日～26日の3日間の平均をとり、さらにそれを11項の移動平均したものを統計交通量 $\bar{x}(t)$ として予測に用いる。

3. 予測手法

まず、ニューラルネットワークによる交通量予測について述べる。本研究で用いるニューラルネットワークは、図1に示すように3層からなる階層型ニューラルネットワークである。中間層は1層とし、そのユニット数は任意とする。図中のIはバイアス入力を表し、中間層と出力層のユニットに刺激を与える役目をもつものである。予測交通量 $\hat{x}(t+k)$ は、図2のように現時点 t の交通量 $x(t)$ 、同時刻の統計交通量 $\bar{x}(t)$ および予測時点 $t+k$ の統計交通量 $\bar{x}(t+k)$ を入力パターンとして、ニューラルネットワークの出力として求める。ただし、入力データおよび教師データとして用いる各交通量は、定数で割って0から1の範囲となるよう標準化した。結合荷重の調整には誤差逆伝播法を用いた。新しい観測交通量が得られるたびごとに、それを学習パターンにとり込んで荷重調整を行うようにした。

ニューラルネットワークを用いて実際に交通量予測を行うにあたって、以下の計算条件について検討し望ましい値を求めた。

①荷重調整に用いる学習パターンの組数

②平滑化係数 α と学習速度係数 η ③温度定数 t_n

④ネットワークの中間層のユニット数

⑤計算時間を考慮した学習回数

次に、カルマンフィルターによる交通量予測について述べる。カルマンフィルターの詳細な理論についてはここでは触れないが、本研究では k 時点先の交通量を予測する式を式(1)で与え、パラメータ a_1 、 a_2 および a_3 は、仮想的なシステム方程式を $a(t) = a(t-1) + e(t-1)$ と考慮して、カルマンフィルターで同定する。

$$x(t+k) = a_1(t)x(t) + a_2(t)\bar{x}(t) + a_3(t)\bar{x}(t+k) \quad \cdots(1)$$




図1 階層型ニューラルネットワーク




図2 入力に用いるデータ

また、入力変数を追加して予測を行った。具体的には、式(1)で用いた入力変数の他に、現時点より1時点前の交通量 $x(t-1)$ 、その同時刻の統計交通量 $\bar{x}(t-1)$ および予測時点より1時点前の統計交通量 $\bar{x}(t+k-1)$ などを入力変数に追加して予測精度を調べた。

4. 予測結果

それぞれの予測手法を用いて、2月1日(水)の30分先の交通量予測を行った。その結果を図3および図4に示す。ニューラルネットワークによる予測では、さまざまな計算条件で予測を行い、予測誤差を小さくする条件として、学習パターン=72組、平滑化係数 $\alpha=0.02$ 、学習速度係数 $\eta=0.99$ 、温度定数 $t_n=1.0$ 、中間層のユニット数=2、学習回数=5000回を求めた。図3はこの条件による予測結果を示している。学習パターンの組数は多いほど予測誤差が小さくなる傾向があり、また、低い平滑化係数と高い学習速度係数を用いるのがよいことがわかった。カルマンフィルタによる予測では、予測式の入力変数を変えて予測を行ったが、その結果、式(1)に入力変数を追加しても予測精度は改善できなかった。したがって、ここでは式(1)を用いた予測結果を図4に示している。それぞれの手法の予測誤差は表1に示す。

予測対象日の2月1日(水)は大雪のために九州自動車道が通行止めになるなどの影響もあって、その交通量は統計交通量とは異なる変動を示した。そのことを考えると、本研究で用いた各予測手法はある程度特異な交通状況にも対応できると思われる。また、交通量の予測結果をみると2つの予測手法で特徴的な点が挙げられる。ニューラルネットワークによる予測は比較的滑らかな変動を示している部分が多いのに対して、カルマンフィルタによる予測は小刻みな増減変動を示している。これは、用いたデータが5分間という短時間交通量の影響ではないかと考えられる。表1からみて、ニューラルネットワークよりカルマンフィルタの方が予測誤差が小さい。しかし、朝のピーク時の誤差は大きい。また、いずれの方法も8時から12時前後までの間の予測精度をもう少し改善することが望まれる。

5. おわりに

今後の課題としては、さらに予測精度を改善し、さまざまな交通状況に適用可能な予測モデルにすることである。また、用いるデータを10分間または15分間交通量に加工して予測し、精度を調べることが必要である。

本研究で用いた感知器データは、福岡県警からご提供いただいた。ここに記して謝意を表する次第である。

参考文献

- 1) P.C.Vythoulkas: Alternative Approaches to Short Term Traffic Forecasting for Use in Driver Information Systems, Transportation and Traffic Theory, pp.485~506, 1993年
- 2) 奥谷巖: カルマン・フィルタ理論を用いた道路交通状態の推定と予測, 土木学会論文報告集, 第289号, pp.131~144, 1979年9月




図3 ニューラルネットワークによる30分先予測




図4 カルマンフィルタによる30分先予測

表1 予測誤差

予測手法	単純平均誤差率	RMS誤差
ニューラルネットワーク	0.214	114
カルマンフィルタ	0.159	109