

高速道路サグ部における渋滞予測モデルの構築*

Prediction Model of Speed at Sag Section on Tohoku Expressway*

堀井雅史**・戎屋隆***

By Masafumi HORII**・Takashi EBISUYA***

1. はじめに

高速道路において、行楽シーズンになると毎年サグ部、トンネル部がボトルネックとなり、交通渋滞が発生している。これに対して日本道路公団は、車線増強などの措置をとるとともに、過去のデータをもとに渋滞予測を行い、事前に予測結果の公表を行い、交通需要の分散化を図っている。この予測データは利用者の交通行動の変更を促すという点においては非常に有用であると考えられるが、ある地点において、渋滞開始を正確に予測するためには別のモデルを用意しなければならない。もし、事前に的確な渋滞予測が可能となれば、運転者への正確な情報提供など適切な交通管理施策をとることが可能となり、渋滞の開始を少しでも遅らせることができるであろう。さらには、今後迎えるであろうITS社会において、正確な渋滞予測は重要な課題であると考えられる。

ボトルネック部での渋滞は、最大の捌け台数が出現した後、急激に速度が低下し、渋滞が発生する。したがって、いくつかの交通流要因の変動パターンが重なり合って渋滞が発生すると考えられる。そこで本研究では、サグ部での交通渋滞を対象に、パターン分類などに有効な手法であるニューラルネットワークを用いて速度の予測モデルを構築し、渋滞を予測できるシステムの確立を目指すものである。

*キーワード：渋滞予測，サグ部，ニューラルネットワーク

**正員，工博，日本大学工学部土木工学科

(福島県郡山市田村町徳定字中河原1，
TEL024-956-8711，FAX024-956-8711)

***日本道路公団東北支社保全部交通技術課

(宮城県仙台市青葉区中央3丁目2-1，
TEL022-217-1836，FAX022-711-6397)

2. 既往の研究と本研究の研究手法

(1) 既往の研究例

高速道路のサグ部での交通渋滞に関しては多くの研究例^{1),2)}が発表され、その現象が説明されている。それらによると渋滞の発生は以下のように説明される。交通量が増加してくると、追い越しのため追い越し車線を走行していた車が走行車線に戻らず走行し、追い越し車線の利用率が高くなる。追い越し車線の利用率が高い状態で、その中の比較的速度の遅い車が先頭となり、車群が形成される。この車群がサグにさしかかると、先頭車は勾配の変化に気づかないため、速度が低下する。後続車は、前車との車間距離が縮まるため減速を余儀なくされ、これが時間的遅れを伴って、後方に伝播し、増幅されるために車群最後尾では低速での走行となり、それらに後続の車群が到達すると巨大な車群となって、走行車線をも巻き込みながら渋滞流と変わる。すなわち、過度の追い越し車線への交通の集中が大きな要因であると考えられる。

一方、渋滞検出に関しては、オンラインでの検出精度の向上を目指していくつかの研究^{3),4)}がなされており、閾値速度の設定方法が示されている。これらはいずれも事前の渋滞予測を扱ったものではない。また、米川ら⁵⁾は渋滞予測のために必要となる交通容量の算定方法の構築を行っているが、渋滞予測には言及していない。以上のことから渋滞予測を扱った研究例は見あたらないと思われる。

(2) 研究方法

本研究では、高速道路のサグ部での渋滞予測を行うためにニューラルネットワークを用いる。ニューラルネットワークはパターン分類や非線形な関係を再現するのに威力を発揮する。ここで用いるニュー

ラルネットワークは、階層型ネットワークで、学習には少ない学習回数で収束が可能な拡張カルマンフィルタによるニューラルネットワーク^{6),7)}を用いる。

いま、図-1に示すような3層からなる階層型ニューラルネットワークを考える。入力層、中間層、出力層のユニット数をそれぞれ I, J, K とする。中間層、出力層に入出力関数を用いることにすれば、中間層第 j ユニット($j=1,2,\dots,J$)、出力層第 k ユニット($k=1,2,\dots,K$)での出力 o_j, y_k はそれぞれ次式のようになる。

$$o_j = f(u_j) = f\left(\sum_{i=1}^I w_{ji}^l x_i\right) \quad (1)$$

$$y_k = f(z_k) = f\left(\sum_{j=1}^J w_{kj}^u o_j\right) \quad (2)$$

ここで、

- u_j : 中間層第 j ユニットへの入力値
- z_k : 出力層第 k ユニットへの入力値
- w_{ji}^l : 入力層 i ユニットと中間層 j ユニット間のリンク結合加重
- w_{kj}^u : 中間層 j ユニットと出力層 k ユニット間のリンク結合加重
- x_i : 入力層 i ユニットへの入力データ

である。

入出力関数には次式のシグモイド関数を用いる。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

学習は、教師信号ベクトルを y_{dk} とすると次式の出力層における誤差の2乗和の1/2が最小化されるように行う。

$$E = \frac{1}{2} \sum_{k=1}^K (y_k - y_{dk})^2 \quad (4)$$

通常はBP法を用いるが、長時間の学習を要するなどの欠点があるため、ここでは、拡張カルマンフィルタを用いて、ニューラルネットワークの学習を非線形システムの状態推定問題として取り扱う⁸⁾。

3. 分析対象地点およびデータ

分析対象地点は、図-2に示すように東北自動車道




図-1 ニューラルネットワークモデル




図-2 調査地点

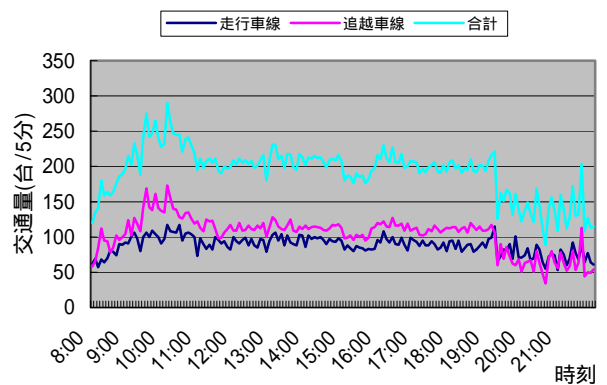


図-3 交通量の推移(1998.5.4, 249.3kp)




図-4 速度の推移(1998.5.4, 249.3kp)

上り線福島トンネル手前のサグ部付近(250kp付近)であり、この地点は行楽シーズンになると毎年渋滞が発生し、この渋滞解消が大きな課題であった。そこで抜本的解決策として付加車線の設置計画が策定された。本研究で用いるデータは、このための検討会用に測定されたものである。

使用したデータは1998年5月4日，8月15日，1999年5月4日に測定された5分間の交通量，速度，占有率，車頭時間，車線利用率である．図-3，図-4に1998年5月4日のボトルネック付近(249.3kp)の交通量，速度の時系列的変動を示す．これによると，10時過ぎに最大捌け台数280台/5分が観測された後，走行車線，追い越し車線とも速度が急激に低下し，渋滞になり，その後交通量，速度とも安定した状態で推移し，19時過ぎに速度が上昇して渋滞が解消している．この地点はサグ底部直近下流部に位置しているため，サグによる渋滞と考えられる⁹⁾．

4．渋滞予測モデルの構築

(1) モデルの構造

本研究で用いるニューラルネットワークモデルは3層構造とし，入力値に観測された交通流特性値，出力値に5分後のこの地点の速度とした．すなわち，現時点までのデータで5分後の速度を予測することになる．ただし，1.でも述べているように，渋滞開始の急激な速度低下は，交通流特性値の時系列的変動パターンが重なり合っ，実現されると仮定し，入力値には各特性値の時系列値(たとえば占有率について3単位分とは，現在の値，5分前の値，10分前の値を意味する)を入力する．中間層のユニット数は3~8程度とし，計算値と実測値との相関係数を勘案して，モデル構造を決定した．なお，学習期間は1998年5月4日の8:20から21:40とし，この学習済みのモデルに1998年8月15日，1999年5月4日のデータを入力して，予測を試みた．

(2) 速度予測モデル

速度予測に当たっては，図-4でもわかるように走行車線と追い越し車線で速度推移パターンが若干異なるため，別個に分析を試みた．入力変数は，車線別に相関関係を考慮しつつ，各変数の入力単位数を変化させ，中間ユニット数を変えて相関係数を算出した．その一例として図-5に追い越し車線についての学習結果を示す．この場合，入力変数は占有率，車線利用率をそれぞれ3単位ずつ合計6ユニットとし，中間ユニット数3の結果である．これによると，学習時には速度の変動をかなり正確に追従しており，




図-5 追い越し車線学習結果(占有率，車線利用率各3単位，1998.5.4， $r=0.9731$)




図-6 追い越し車線の予測結果(占有率，車線利用率各3単位，1998.8.15， $r=0.8137$)




図-7 追い越し車線予測結果(占有率，車線利用率各3単位，1999.5.4， $r=0.9367$)

相関係数にも見られるように，実測値を高い精度で再現できることがわかった．

つぎに，得られた各車線ごとの学習モデルに未学習データを入力し，速度の予測を試みた．追い越し車線についての計算例を図-6，7に示す．これによると，1999年5月4日のデータはかなりの精度で速度変動を再現していることが示されたが，1998年8月15日に関しては，後半部の速度変動にはあまり追従できないようである．この原因としては，データのばらつきが予測結果に反映される，学習していないデータパターン，学習データ範囲外のデータの入力などが考えられる．これについてはさらなる検討が必要である．

(3) 渋滞予測

ここでは、以上までで得られた速度の予測結果を用いて、閾値速度を基準に分類し、その的中率を用いて5分後の渋滞予測が可能であるか否かの検討を行う。ここで閾値をどのように設定するかであるが、本研究では赤羽ら⁴⁾の設定方法を用いて算定した。その結果、走行車線で55km/h、追い越し車線で59km/hとなる。しかしながら、閾値周辺のデータが少ないため、これについては検討が必要である。

表-1に走行車線における渋滞予測結果を示す。これによると、8月に若干精度の低下が見られるが、かなりの精度で予測可能である。同様に表-2に追い越し車線に関する予測結果を示した。8月の予測精度は73%程度であり、今後検討する必要があるが、5月に関しては高い精度を有していることを確認した。

5. まとめ

本研究は、高速道路のサグ部における渋滞予測モデルの構築を試みたものである。以下に得られた成果をまとめて示す。

- 1) 高速道路の速度予測にニューラルネットワークが適用可能であることを示した。
- 2) ニューラルネットワークを用いた5分後の速度予測モデルは学習時、予測時においてもある程度の精度で速度を再現していることを確認した。
- 3) 本モデルによる渋滞予測が可能であることを示した。

今後の課題としては以下のことがあげられる。まず、データのばらつきを抑えるために平滑化したデータに対する予測モデルの構築が必要であろう。さらに、今回は5分後を予測できるか否かの検討であったが、10分後の速度が予測可能かどうかを検討し、両者の予測結果から確度の高い予測モデルの構築が重要であると考えられる。

最後に、本研究で用いたデータは、「東北自動車道福島地区付加車線に関する検討委員会」で調査されたものであり、データの提供をしていただいた日本道路公団東北支社、並びに福島管理事務所に深く

表-1 走行車線における渋滞予測結果

予測結果	1998.8.15			1999.5.4		
	予測値		的中率	予測値		的中率
	非渋滞	渋滞		非渋滞	渋滞	
実測値	6	0	1.000	25	5	0.833
	19	154	0.890	1	118	0.992
的中率	0.240	1.000	0.894	0.962	0.959	0.960

表-2 追い越し車線における渋滞予測結果

予測結果	1998.8.15			1999.5.4		
	予測値		的中率	予測値		的中率
	非渋滞	渋滞		非渋滞	渋滞	
実測値	13	0	1.000	27	3	0.900
	48	118	0.711	1	118	0.992
的中率	0.213	1.000	0.732	0.964	0.975	0.973

感謝いたします。

参考文献

- 1) 越正毅・桑原雅夫・赤羽弘和: 高速道路のトンネル、サグ部における渋滞現象に関する研究, 土木学会論文集, No.458/V-18, pp.65-71, 1993.
- 2) 栗原光二・日置洋平: 高速道路ボトルネックの交通容量改善策, 土木計画学研究・論文集, No.12, pp.731-738, 1995.
- 3) 岩崎正人・越正毅・大蔵泉: 高速道路における渋滞検出精度の改善に関する研究, 土木学会論文報告集, No.330, pp.121-127, 1983.
- 4) 赤羽弘和・越正毅: 渋滞検出閾値のオンライン設定法, 土木学会第42回年次学術講演会概要集, pp.70-71, 1987.
- 5) 米川英雄・飯田克弘・森康男: 高速道路の渋滞中交通容量に影響を及ぼす要因の車線間相違に関する研究, 交通工学, Vol.36, No.2, p p. 53-63, 2000.
- 6) 村瀬治比古・小山修平・石田良平: パソコンによるカルマン・ニューロコンピューティング, 森北出版, 1994.
- 7) 片山徹: 応用カルマンフィルタ, 朝倉出版, 1983.
- 8) 堀井雅史・福田正: 舗装路面凍結予測システムの開発, 土木学会論文集, No.669/V-50, pp. 243-251, 2001.
- 9) 松本晃一・古川健・山岸将人・加藤真司: 3 Line Sensorによる交通流解析手法に関する研究, 交通工学, Vol.35, No.3, pp.20-27, 2000.