

## 事故検知におけるニューロモデルの頑健性について

信州大学工学部 学生員○藤田 浩一  
信州大学工学部 正会員 奥谷 巍

### 1. はじめに

1963年にわが国初の高速道路である名神高速道路が一部開通して以来、高速道路網は着々と整備・拡張され続けている。しかし、高速道路のように一方通行かつ迂回路のない道路においては、一度事故が発生すると交通流の乱れによって深刻な渋滞が発生し、高速道路としての機能が果たせなくなる。事故渋滞の解消には、事故発生を迅速かつ正確に検知し、素早く事故車を取り除くことが要求される。

従来より事故検知には、道路上に設置された交通感知器より得られるデータを用いているが、それらのデータには誤差が含まれており、従って事故の誤検知を招きしかねない。本研究ではこうした視座に立脚し、先に提案した事故検知方法<sup>1)</sup>の改善を図るとともに、誤差を有するデータにも影響を受けないニューロモデルを提案して、シミュレーションデータにより実証的な検討を行おうとするものである。

### 2. 検知モデルの構成

一般に、高速道路上の事故検知方法は、図1に示したような道路区間の上下流端に交通感知器を設置し、そこから得られる交通情報（交通量・オキュパシ・速度）をもとに、対象区間内の事故の有無を判定する方法をとる。

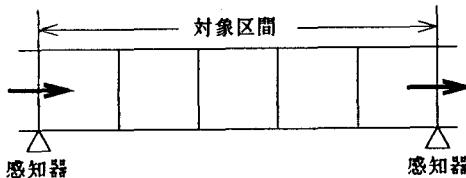


図1 対象道路区間

本研究でも、こうした方法論をベースとし、以下に示すような2つの事故検知モデルを提案する。

(1)モデル1：検知モデルとしては、通常の3層ニューラルネットワーク（以下、NNと略記）を考える。入力は対象区間の上下流端における交通情報の計測値であるから、先述したようにその種類が3個あるので、入力層のニューロン数は2~6となる。また、出力は事故の有無を判定するのみであるから、

出力層のニューロン数は1となる。当該NNでは、時々刻々と変化する交通状況を踏まえて事故検知を遂行することが要請されることから、その入出力関係は時刻tを陽的に含むダイナミックな関係式となる。

(2)モデル2：第2番目のモデルとしては、あいまい情報にも影響を受けないように、NNモデルにファジイ理論を取り入れたニューロ・ファジイ（以下NFと略記）モデルを考える。このモデルはモデル1における出力を0(t)とした時、それをファジイ推論における入力として利用することにより事故検知を行おうとするものである。

### 3. シミュレーションによる検討

交通事故に関する実際のデータ入手することは困難なので、DYNEMO<sup>2)</sup>と呼ばれるシミュレーションモデルを利用して学習実験を行った。シミュレーション時間は20分で単位時間は10秒とする。また対象とする道路区間は5000mの距離を有する3車線の高速道路を考え、それを図1に示したように1~5のサブ区間に分割する。1車線当たりの交通容量は平常時は1800(台/h)とし、事故時については2車線閉塞事故を想定してその値を600(台/h)とする。シミュレーションは、3車線合計の交通量が1800、2700、3600、4500、5400(台/h)の5種類、事故発生地点が上流から1、4番目のサブ区間の2種類、事故発生時間が300、400、500(s)の3種類、合計 $5 \times 2 \times 3 = 30$ ケースについて実行した。

モデル1において、30ケース全てについて学習を行い予備的テストを実行した結果、3車線の交通量が4000(台/h)以上の場合、推定精度が悪いことが分かった。従って、NNを4000台以上（以下、交通需要大の場合という）と4000台未満（以下、交通需要中以下の場合という）との2つに分け、各々についてNNを完成することとした。

完成したNNについて記述しておくと、シグモイド関数の $\phi$ の値は1.0、中間ニューロン数は交通需要大の場合5個、交通需要中以下の場合は20個で

あった。入力情報については、交通需要大の場合は、交通量と速度データの組み合わせが最もよく、交通需要中以下の場合は、オキュパンシと速度データの組み合わせが最適であった。しかしながら、交通需要レベルによって入力情報の組み合わせを変えることは、時々刻々と変化する交通流にオンラインで対処しなければならないという現実を鑑みると、決して好ましいことではない。さらに、交通需要大の場合、上述の交通量・速度データの最適な組み合わせとオキュパンシ・速度データの組み合わせとの差は、優位なものではなかった。こうしたことから、入力情報としては交通需要レベルにかかわらず、オキュパンシと速度データの組み合わせを用いることとする。

モデル2については、まず、30ケース全てについて各交通量ごとの事故前後それぞれの場合に対して、モデル1からの出力の平均を取り、その値を中心とした三角型メンバーシップ関数を設定する。三角形の底辺については、試行錯誤の結果、事故後の平均値を基準とした場合、事故前はその0.1倍、事故後は0.2倍の大きさが最適な値であることが判明した。また、事故発生と見なすファジィ推論ルールにおける後部の閾値も、試行錯誤の結果、表1のような値として設定された。

表1 NFモデルのずれに関する閾値

	0%	10%	20%	30%
交通需要大	0.51	0.51	0.60	0.78
交通需要中以下	0.51	0.53	0.55	0.57

表2 ずれ 10%時のテスト結果

Q t. J	2				3			
	250	350	450	550	250	350	450	550
5400	280(0.158)	390(0.183)	480(0.158)	580(0.158)	350(0.289)	430(0.258)	540(0.274)	630(0.258)
	270(0.129)	360(0.091)	470(0.129)	560(0.091)	330(0.258)	420(0.242)	520(0.242)	620(0.242)
	280(0.158)	390(0.183)	500(0.204)	610(0.224)	610(0.548)	550(0.408)	640(0.398)	790(0.447)
4000	280(0.158)	390(0.183)	490(0.183)	580(0.158)	380(0.329)	470(0.316)	590(0.342)	670(0.316)
	270(0.129)	370(0.129)	460(0.091)	560(0.091)	350(0.289)	440(0.284)	570(0.316)	660(0.303)
	340(0.274)	390(0.183)	520(0.242)	600(0.204)	500(0.456)	590(0.447)	760(0.508)	820(0.474)
3000	280(0.158)	380(0.158)	480(0.158)	580(0.158)	340(0.274)	480(0.329)	530(0.258)	640(0.274)
	260(0.091)	370(0.129)	460(0.091)	560(0.091)	330(0.258)	450(0.289)	560(0.303)	620(0.242)
	280(0.158)	410(0.224)	480(0.158)	660(0.303)	170(-----)	530(0.387)	170(-----)	700(0.354)
1800	280(0.158)	380(0.158)	480(0.158)	580(0.158)	1170(0.876)	870(0.658)	970(0.658)	1000(0.612)
	270(0.129)	370(0.129)	460(0.091)	570(0.129)	-----	680(0.524)	740(0.492)	770(0.428)
	440(0.398)	460(0.303)	630(0.387)	610(0.224)	400(0.354)	490(0.342)	170(-----)	710(0.365)

注1) Q: 交通需要(台/時間)、t.: 事故発生時間、J: 事故発生区間

注2) 各欄の上段の括弧外の数値はNN法による事故発生時刻推定値、括弧内の数値はRMSEを表す。中段はNF法、下段はGLR法によるもの。

注3) -----は誤検知のため数値を略したもの。

なお、対象区間の上下流端において計測される交通変量xのずれについては次式によって与えた。

$$\tilde{x} = x(1 + \varepsilon \cdot R) \quad (1)$$

ここに、 $\varepsilon$ : ずれの大きさ、R: [-1, 1]の一様乱数

#### 4. 有効性のテスト

NNモデルとNFモデルの有効性について、従来の方法である一般化尤度比検定法（以下、GLR法と略記）と比較において調べる。テストケースとしてのシミュレーションは、3車線合計の交通量が1800、2300、3000、4000、5000、5400(台/h)の6種類、事故発生地点が上流から2、3番目のサブ区間の2種類事故発生時間を250、350、450、550(s)の4種類、合計 $6 \times 2 \times 4 = 48$ パターンについて実行した。ずれ10%時のテスト結果の一部を表2に示す。

表2より、全体的にニューラルモデルを用いた場合のほうが、GLR法より正確な推定を行っていることが分かる。また、NFモデルにファジィ推論を取り入れたNFモデルの方が、区間2で10~30(s)、区間3における交通需要大の場合で10~50(s)早く検知できることが分かる。しかし、交通需要中以下の場合はNFモデルよりむしろ、NNモデルの方が良い推定を行っている。

#### 5. あとがき

NFモデルの各種パラメータの改善により精度向上が期待できる。

#### 参考文献

1) 奥谷・藤田: ニューラルネットワークによる自動的事故発見手法について、土木学会 中部支部 講演概要集, pp. 409~410, (1992)

2) T. Schwerdtfeger:DYNEMO, Intl. Symp. on Trans. and Traffic Th. 1984