

行政院國家科學委員會專題研究計畫成果報告

模糊類神經網路影像偵測器與交通事件即時偵測系統之研發(2/2)

Development of Fuzzy Neural Network Color Image Vehicular Detectors and Instantaneous Incident Detection Systems (2/2)

計畫編號：NSC 90-2211-E-009-058

執行期限：90年08月01日至91年07月31日

主持人：藍武王教授

交通大學交通運輸研究所

共同主持人：無

計畫參與人員：黃業傑、郭怡雯

交通大學交通運輸研究所

一、摘要

本研究發展一模糊類神經網路事件偵測演算法，用以偵測道路之非重現性擁塞。先在高速公路上產生一真實的交通事件，再同步觀測事件點上下游之車流變化情形，作為模擬軟體 Paramics 之校估基礎，俾進一步模擬在上下游偵測器相距一公里之情況下，事件發生於高速公路不同車道（內側、中間、外側）、不同地點（距上游偵測器 250、500、750 公尺）及不同嚴重度（阻塞一、二個車道）各種情境組合之偵測績效。本演算法經網路訓練與驗證後，再以離線測試上述各種不同情境，結果發現平均偵測正確率高達 90%，平均誤報率低於 0.05%，平均所需偵測時間約為 78 秒；另由統計檢定知，當事件點愈靠近上下游兩偵測器時偵測正確率愈高；在兩車道狀況下事件阻塞內車道之偵測正確率高於阻塞外車道，三車道狀況下阻塞兩車道之偵測正確率又高於阻塞一車道。

關鍵詞：事件偵測演算法、模糊類神經網路、車流模擬

Abstract

This research develops a fuzzy neural network (FNN) incident detection algorithm to detect non-recurring roadway congestions. A real incident case is generated on the freeway mainline and the variations of flow, density and speed at the adjacent upstream and downstream detectors are concurrently observed, which are used to calibrate the traffic simulation package -- Paramics. In the circumstance of vehicular detectors spaced

out at one-kilometer apart, we simulate and evaluate the incident detection performance under various scenarios combination of incident taking place in different lanes (inner, middle, and outer), at different locations (250, 500, 750 meters from the upstream detector), and with different severity (one or two lanes blockage). After trained and validated, this FNN incident detection algorithm is tested off-line under the above-mentioned various scenarios combination. The results show that average detection accuracy rate can reach as high as 90%, with average false alarm rate lower than 0.05% and average detection time of 78 seconds. In addition, statistic tests conclude that detection accuracy rate becomes higher as the incident occurrence spot gets closer to either the upstream or downstream detector. Moreover, inner-lane blockage has higher detection accuracy rate than outer-lane blockage in the two-lane mainline; while for the three-lane mainline, two-lane blockage yields higher accuracy rate than single-lane blockage.

Keywords: incident detection algorithm, fuzzy neural network, traffic simulation

二、緣由與目的

交通擁塞可分為重現性擁塞(recurring congestion)及非重現性擁塞(non-recurring congestion)。前者為交通需求過度集中或道路幾何瓶頸等因素所致，其發生時間、地點多可預知；後者受事件(Incident)影響，如交通事故、天候情況等，其發生時

間、地點多不可預知，因此過去之研究均針對非重現性擁塞研擬事件偵測方法。惟發展至今仍面臨許多瓶頸：如(1)事件偵測多僅偵測事件發生與否，未能偵得正確位置與嚴重程度。(2) 偵測演算法不具移轉性，參數須重新校估與驗證。(3) 績效常取決於門檻值之設定 (Stephanedes, *et al.*, 1992)、車流狀況 (中高流量有較佳之績效)、相鄰兩偵測器之距離等。(4)難以取得實際資料，多藉模擬方式驗證績效 (Levin and Krause, 1979)。

近年來，事件偵測演算法有逐漸以人工智慧為發展趨勢，如專家系統 (Lin and Chang, 1998)、類神經網路 (Ritchie and Cheu, 1993)、基因演算法 (Srinivasan *et al.*, 2000) 等。其中類神經網路經適當學習訓練即具極高之辨識力，且可結合模糊推論，提高容錯能力。由於參數均由訓練獲得，模式具較佳移轉性，適用於各種車流狀況。

因此，本研究發展一模糊類神經網路事件偵測演算法，用以偵測道路之非重現性擁塞。在高速公路上產生一真實的交通事件，觀測事件點上下游之車流變化情形，用以校估 Paramics 車流模擬軟體，再進一步模擬在上下游偵測器相距一公里之情況下，事件發生於高速公路不同車道、地點及嚴重度各種情境組合之偵測績效。

三、模糊類神經網路事件偵測演算法

本研究發展之模糊類神經網路事件偵測演算法，其網路分四層 (如圖 1)，運算與訓練方式簡述如下：

1. 運算方式

第一層：輸入層。輸入車流參數流量、速率與密度。透過車道偵測器，流量為各車道流量總和，速率與密度為各車道之平均值，加權值 w_i 固定為 1，輸出值 o_i 與輸入值 u_i 表為：

$$o_i = f(u_i) = u_i \quad i=1\sim 12$$

$$o_i = x_i \cdot w_i = x_i = u_i$$

第二層：模糊隸屬層。計算偵測器目前與前一單位時間，以及上下游偵測器同一時間車流參數差值之隸屬度。 a_j 、 b_j 為梯形函數參數，加權值 w_{ij} 固定為 1，輸出值 o_j

與輸入值 u_j 表為：

(1) 上/下游偵測器歷史資料比較

$$o_j = f_j(u_j) = \sim_j(x_{ij}) = \begin{cases} 0 & \text{for } x_{ij} \leq a_j \\ \frac{x_{ij} - a_j}{b_j - a_j} & \text{for } a_j < x_{ij} \leq b_j \\ 1 & \text{for } x_{ij} > b_j \end{cases}$$

其中 $x_{ij} = |o_i - o_{i+3}|$ ， $(i=1\sim 3, j=1\sim 3)$ 以及 $(i=7\sim 9, j=7\sim 9)$ 且 $i=j$

(2) 上下游間偵測資料之比較

$$o_j = f_j(u_j) = \sim_j(x_{ij}) = \begin{cases} 0 & \text{for } x_{ij} \leq a_j \\ \frac{x_{ij} - a_j}{b_j - a_j} & \text{for } a_j < x_{ij} \leq b_j \\ 1 & \text{for } x_{ij} > b_j \end{cases}$$

其中 $x_{ij} = |o_i - o_{i+9}|$ ， $(i=1\sim 3, j=4\sim 6)$ 且 $j=i+3$

第三層：推論層。主要分為三類：(1)若上游速率、流量及密度與前一單位時間皆具明顯差異，則推論有事件發生；(2)若上下游速率、流量及密度 (下游車流狀況為上游之時間延遲 δ) 皆具明顯差異，則推論有事件發生；(3)若下游速率、流量及密度與前一單位時間皆具明顯差異，則推論有事件發生。本層之輸出值 o_k 與輸入值 u_k 表為：

$$o_k = f(u_k) = (w_{jk} \cdot x_{jk}) * (w_{(j+1)k} \cdot x_{(j+1)k}) * (w_{(j+2)k} \cdot x_{(j+2)k})$$

($j=1, k=1$) 與 ($j=4, k=2$) 與 ($j=7, k=3$)
第四層：輸出層。以重心法將模糊值轉為明確值 (0 表無事件發生，1 表有事件發生)。輸出值 o_m 與輸入值 u_m 表為：

$$o_m = f(u_m) = \sum_{k=1}^3 w_{km} \cdot x_{km}$$

2. 訓練方式

採最陡坡降法 (Gradient Steepest Descent Method)，訓練步驟如下：

(1) 設定參數起始值

包含加權值、梯形隸屬函數參數、慣性項 (Momentum Term, \hat{a})，以及學習速率 (Learning Rate, \hat{c})。

(2) 輸入一筆訓練範例，計算網路輸出值

(3) 計算第四層之誤差量 (\hat{a}_m^4)

$$u_m^4 = a_m^4 - o_m^4$$

(4) 更新第三層與第四層加權值 (w_{km})

$$w_{km}(t+1) = w_{km}(t) + \gamma \cdot u_m^4 \cdot x_{km} + r \cdot [w_{km}(t) - w_{km}(t-1)]$$

(5) 計算第三層與第二層誤差量 (\hat{a}_k^3 、 \hat{a}_j^2)

$$u_k^3 = u_m^4 \cdot w_{km}(t+1)$$

$$u_j^2 = u_k^3 \cdot w_{jk} \cdot x_{jk}$$

(6)調整第二層參數(a_j 、 b_j)

$$a_j(t+1) = a_j(t) + y \cdot u_j^2 \cdot x_k \cdot \frac{x_j - b_j(t)}{[b_j(t) - a_j(t)]^2}$$

$$+ r \cdot [a_j(t) - a_j(t-1)]$$

$$b_j(t+1) = b_j(t) + y \cdot u_j^2 \cdot x_k \cdot \frac{a_j(t) - x_j}{[b_j(t) - a_j(t)]^2}$$

$$+ r \cdot [b_j(t) - b_j(t-1)]$$

(7)重複(2)至(6)，直至所有樣本輸入完畢

(8)計算總誤差函數值(TE)

$$TE_i = \frac{1}{2} \sum_{t=1}^N [d_m(t) - o_m(t)]^2$$

(9)檢驗誤差函數是否收斂

當某訓練回合之TE值與前一回合相差小於 ε 時，亦即 $|TE_i - TE_{i-1}| \leq \nu$ 則停止；否則，回至(2)。

四、實證分析

本研究在中山高速公路上產生一真實的交通事件，蒐集事件前、中、後之車流參數，並以此為基礎，利用 Paramics 產生網路訓練與驗證樣本。實驗路段為中山高速公路北向雙車道 21.3 至 18.4 公里，其間無匝道，事故產生在北向 19.3 公里處，時間為下午 4 點 10 分至 55 分，其中，4 點 25 分至 40 分為事件發生時段，以兩輛車分別阻斷外側車道及路肩，僅剩內側車道通行。利用高速公路西側 21.3 及 18.4 公里之攝影機分別拍攝事件前 15 分鐘、事件中 15 分鐘及事件後 15 分鐘之車流影像，作為模擬軟體 Paramics 之校估基礎，其車流參數與檢定結果詳如表 1。檢定結果顯示，在 5% 顯著水準下，事件前、中、後之大部分車流參數，實驗值與模擬值並無顯著差異 ($p > 0.05$)，故可用 Paramics 模擬各種情境組合之事件。

利用校估後之 Paramics 模擬在上下游偵測器相距一公里之情況下，事件發生於高速公路不同車道(內側、中間、外側)、不同地點(距上游偵測器 250、500、750 公尺)及不同嚴重度(阻塞一、二個車道)各種情境組合之偵測績效，結果詳表 2。

表 1 Paramics 模擬校估檢定結果

資料	事件前 15 分鐘			事件中 15 分鐘			事件後 15 分鐘		
	平均速率(公里/小時)	平均流量(輛/小時)	平均密度(輛/公里)	平均速率(公里/小時)	平均流量(輛/小時)	平均密度(輛/公里)	平均速率(公里/小時)	平均流量(輛/小時)	平均密度(輛/公里)
實驗觀測結果	80.47	1,652	20.54	62.27	1,328	21.43	68.23	1,636	23.95

五、結論與建議

本演算法經網路訓練與驗證後，再以離線測試上述各種不同情境，結果發現平均偵測正確率高達 90%，平均誤報率低於 0.05%，平均所需偵測時間約為 78 秒；另由統計檢定知，當事件點愈靠近上下游兩偵測器時偵測正確率愈高；在兩車道狀況下事件阻塞內車道之偵測正確率高於阻塞外車道(如圖 2)，三車道狀況下阻塞兩車道之偵測正確率又高於阻塞一車道(如圖 3)。後續研究可進一步變化不同情境設計或改變 FNN 架構，以探討本演算法偵測事件之能力。

六、主要參考文獻

- [1] Levin, M. and Krause, G. M., "Incident detection algorithms, Part 1: off-line evaluation; Part 2: on-line evaluation," *Transportation Research Record* 722, pp. 49-64, 1979.
- [2] Lin, C. K. and Chang, G. L., "Development of a fuzzy-expert system for incident detection and classification," *Mathematical and Computer Modeling*, Vol. 27, No. 9-11, pp. 9-25, 1998.
- [3] Ritchie, S. G. and Cheu, R. L., "Simulation of freeway incident detection using artificial neural networks," *Transportation Research Part C*, Vol. 1, pp. 203-217, 1993.
- [4] Srinivasan, D., Cheu, R. L., Poh, Y. P., Ng, A. K. C., "Development of an intelligent technique for traffic network incident detection," *Engineering Applications of Artificial Intelligence*, Vol. 13, pp. 311-322, 2000.
- [5] Stephanedes, Y. J., Chassiakos, A. P. and Michalopoulos, P. G., "Comparative performance evaluation of incident detection algorithms," *Transportation Research Record* 1360, pp. 50-57, 1992.

電腦模擬結果	83.70	1,572	18.68	64.98	1,366	21.02	72.16	1,509	20.81
t-values	1.31	-4.74	-1.58	1.69	-0.22	0.14	1.78	-4.62	-2.63
p-values	0.20	0.01	0.19	0.10	0.96	0.89	0.09	0.00	0.03

H_0 : 實驗之平均值=模擬之平均值。

表 2 不同事件發生位置實驗設計組合之離線測試結果

括號內數字為標準差

事件發生位置實驗設計組合	偵測正確率 (DR)	誤報率 (FAR)	偵測時間 (TTD)
兩車道之內側車道 距上游偵測器 250 公尺處	93.19% (0.03999)	0.0958%(0.00007741)	74 秒 (3.6556)
兩車道之內側車道 距上游偵測器 500 公尺處	87.90% (0.02867)	0.0628%(0.00007625)	89 秒 (4.5762)
兩車道之內側車道 距上游偵測器 750 公尺處	89.31% (0.03495)	0.0089%(0.00007288)	71 秒 (5.8212)
兩車道之外側車道 距上游偵測器 250 公尺處	88.25% (0.03721)	0.0337%(0.00008328)	83 秒 (6.4183)
兩車道之外側車道 距上游偵測器 500 公尺處	82.62% (0.02968)	0.0437%(0.00007258)	95 秒 (8.1292)
兩車道之外側車道 距上游偵測器 750 公尺處	91.35% (0.03725)	0.0380%(0.00006758)	76 秒 (4.2318)
三車道之內側車道 距上游偵測器 250 公尺處	87.38% (0.03611)	0.0082%(0.00006921)	82 秒 (5.2719)
三車道之內側車道 距上游偵測器 500 公尺處	81.06% (0.04210)	0.0697%(0.00007590)	97 秒 (5.8705)
三車道之內側車道 距上游偵測器 750 公尺處	89.93% (0.03518)	0.0582%(0.00006741)	84 秒 (5.6475)
三車道之內側與中間車道 距上游偵測器 250 公尺處	97.23% (0.02217)	0.0963%(0.00006741)	56 秒 (2.8733)
三車道之內側與中間車道 距上游偵測器 500 公尺處	92.59% (0.02592)	0.0101%(0.00008063)	62 秒 (3.2388)
三車道之內側與中間車道 距上游偵測器 750 公尺處	96.84% (0.02387)	0.0222%(0.00007812)	49 秒 (2.2971)
三車道之中間車道 距上游偵測器 250 公尺處	82.59% (0.03720)	0.0048%(0.00006937)	79 秒 (4.3561)
三車道之中間車道 距上游偵測器 500 公尺處	80.28% (0.03208)	0.0624%(0.00007205)	93 秒 (4.4819)
三車道之中間車道 距上游偵測器 750 公尺處	86.47% (0.03376)	0.0574%(0.00008111)	86 秒 (3.9337)
三車道之中間與外側車道 距上游偵測器 250 公尺處	95.56% (0.02102)	0.0103%(0.00008230)	53 秒 (2.2028)
三車道之中間與外側車道 距上游偵測器 500 公尺處	93.02% (0.02561)	0.0257%(0.00007206)	67 秒 (3.3128)
三車道之中間與外側車道 距上游偵測器 750 公尺處	95.00% (0.02378)	0.0405%(0.00007057)	52 秒 (2.3967)
三車道之外側車道 距上游偵測器 250 公尺處	91.23% (0.02762)	0.0816%(0.00007632)	93 秒 (4.8209)
三車道之外側車道 距上游偵測器 500 公尺處	83.75% (0.03889)	0.0885%(0.00008589)	102 秒 (6.950)
三車道之外側車道 距上游偵測器 750 公尺處	93.86% (0.03128)	0.0716%(0.00007194)	91 秒 (6.1938)

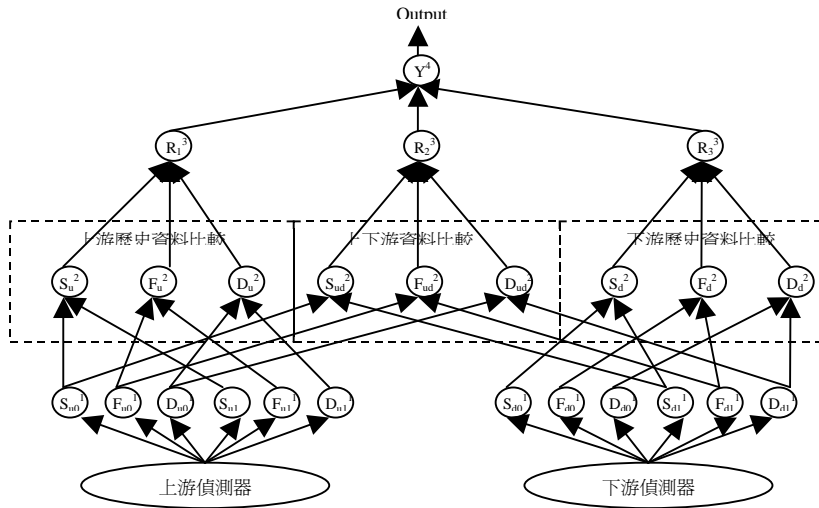


圖 1 模糊類神經網路事件偵測架構




圖 2 兩車道之事件偵測正確率與事件發生位置關係圖




圖 3 三車道之事件偵測正確率與事件發生位置關係圖