

以共用臨域類神經網路架構土石流預警系統之研究

曾國源^[1] 張斐章^[2]

摘 要 近年來類神經網路被廣泛應用於各種工程及科學領域，對於影像辨識、預測等皆有許多成功的案例，本研究主要以曾多次發生土石流災害之陳有蘭溪集水區為研究區域，蒐集土石流發生之相關資料，架構一類神經網路作為土石流預警系統之用，並評判其準確度及實用的效果性。

共用臨域(Shared Near Neighbors)為一種非監督式學習方法，適用於一般具有非球狀群集特性的資料作具有特殊意義的分割，即利用其分類之特點，以土石流災害之水文與地文條件進行發生機制判釋，藉以對未來可能發生之情況做分類模擬；本研究為改善共用臨域分類之推判效果，也研議將共用臨域的分類結果架構一層神經網路，使之成為共用臨域類神經網路(Shared Near Neighbors Network, SNN)，而網路連結的權重則利用監督式的學習方式，提升網路的預判效果，研究中發現共用臨域類神經網路對土石流之預警具有良好的功效。

關鍵詞：土石流預警系統、共用臨域類神經網路、非監督式學習。

The Shared Near Neighbors Neural Network of Constructing the Debris Flow Warning System

Kuo-Yuan Tseng^[1] Fi-John Chang^[2]

ABSTRACT The main purpose of this study is to propose an artificial neural network for constructing a debris flow warning system. The Chen-Eu-Lan creek, which is located in the center of Taiwan, was chosen as the study watershed. The creek is one of the most well-known debris flow areas where several serious debris flows have been reported in the last few years. The hydrological and geological data, which might cause debris flow, are collected and analyzed first. Then, the shared near neighbors neural network (SNN) is presented to construct the debris flow warning system for the watershed.

SNN is an unsupervised learning method, which has the advantages in dealing with the non-globular cluster and computational elegance. By using SNN, the collected hydro-geological data sets can easily and meaningfully be clustered into several categories. These categories can then be identified as “occur” or “non-occur” the debris flow. To improve the effectiveness of debris flow warning system, a neural network framework is designed to connect all the clusters produced by SNN, and the connected weights of the network are adjusted through a supervised learning method. This framework is used to investigate its applicability and practicability for

-
- [1] 國立台灣大學生物環境系統工程學系研究助理
Research Assistant, Department of Bioenvironmental Systems Engineering, National Taiwan University, Taipei, Taiwan, R.O.C.
- [2] 國立台灣大學生物環境系統工程學系教授(通訊作者)
Professor, Department of Bioenvironmental Systems Engineering, National Taiwan University, Taipei, Taiwan, R.O.C.
(Corresponding Author)
E-mail: changfj@ntu.edu.tw



debris flow. The results demonstrate that the proposed SNN neural network is an applicable and effective tool for debris flow warning system.

Key Words: debris flow warning system, shared near neighbors neural network, unsupervised learning.

一、前言

臺灣位處於歐亞板塊與菲律賓板塊交界之處，由板塊的推擠隆升而成，也因此使臺灣的地形陡峻而河短流急，又其位於環太平洋之地震帶，地震頻仍，加以颱風季節豪雨不斷，山崩、地滑及土石流等自然災害應運而生，隨著平地資源的日益短缺，人們便積極的往山坡地進行大規模的開發建設與經營，然而少數人為不當開發作用，造成大地環境更形惡化，諸如崩塌、山洪爆發、土石流等災害層出不窮，其中又以土石流災害最為嚴重，多次造成居民生命及財產的損失，而陳有蘭溪地處台灣中部之中高海拔山區，由於水文及地文環境特殊，在降雨量特大、集中及山區地質條件破碎的情況下，每逢颱風、豪雨季節常造成嚴重之土石流災害。如民國七十八年九月的莎拉颱風、翌年六月的歐菲莉颱風及九月的黛特颱風，造成四十餘人被活埋的不幸慘劇；民國 83 年 7 月間的耐特颱風於花蓮地區再度發生土石流災害；民國 85 年 8 月的賀伯颱風造成之全台各地重大土石流災害更引起全國的注意；而民國 90 年 7 月的桃芝颱風亦使全台發生多處大小不等土石流災情，所以，如何對土石流災害進行防治與研究，實為一件刻不容緩的事。

土石流為發生於山區並含有大量泥砂、石塊，受重力作用下，而產生向下滑動之流動體，造成土石流災害之主要因子為水文與地文條件，然因其牽涉的範圍甚廣，包括水文學、氣象學、測量學、地形學與地質學等，並包含大量的空間與時間的變異性及非線性因子，一般傳統模式並無法有效的予以分析，因此，本研究即收集土石流災害即將發生前之各種可能達到之現象，嘗試利用類神經網路架構土石流預警系統，期盼以類神經網路處理訊號之高度平行性與自我組織、學習能力，針對土石流機制之影響因子與因時因地而有所不同的特性進行研究、分析，並希望能透過土石流災害發生前之各種資料的蒐集，建立一土石流預警的類神經網路架構，研判土石流發生的機制，模擬推估土石流發生的時機，從而進一步了解類神經網路於土石流預警的合理性及適切性，以作為日後研究及實際操作執行之參考依據。

二、文獻回顧

土石流係指土、砂、石礫、岩層或岩塊等土體與水混合而成之流體，其運動特性不同於土體的崩塌運動也不同於河道水流的輸砂現象，而是介於兩者之間，所以在發生時往往因為其流速快、具突發性、衝擊力強及破壞性大而造成許多嚴重災情。關乎土石流之研究甚多，其中包含災害調查及各案研究，發生原因及機制的探討、流動特性、堆積型態、防治技術等；亦有許多是利用數值地形模型，擬判、分析可能影響土石流成因之地形資訊，進而對土石流機制亦或是發生情形做探討。

江永哲、林啓源（1991）分析曾經發於台灣的七場土石流與降雨間的關係，發現在台灣造成土石流的累積降雨量，至少大於 150mm，而最大一小時的降雨強度至少大於 40mm/hr，降雨延時全部在 12 小時以上，且發生土石流多在整場暴雨的後半期。

謝正倫等（1995）利用多變量分析(Multivariate analysis)中之二群體區別函數(Two-group discrimination function)的方法繪製土石流之臨界降雨線，以期能對土石流預警基準的劃定有一較佳之依據。

范正成等（1996）以土石流發生溪流的集水區內土壤力學性質、地文因子及水文條件，利用 Kruskal-Wallis 檢定法檢定各因子，比較各因子在曾經發生土石流區域與未發生土石流區域間是否有顯著的差異存在。並假設土石流發生的臨界降雨線為 $y=ax+b$ 的函數形式，其中 a、b 值為決定臨界降雨線座落位置的兩個待定係數，經過複迴歸分析後，建立以危險因子為自變數的 a、b 值迴歸關係式。

詹錢登等（1999）以機率觀點探討山坡地水文特性及地文特性與土石流發生條件之關聯性，根據水文及地文參數之不確定性，分別以一階二級動差法及蒙地卡羅模擬法，分析不同土石流發生機率下之土石流發生條件。其模擬結果類似實驗室或現場實驗所得的結果，雖然計算量龐大且複雜，但可得到結果之理想真實性。

林昭遠（2000）以衛星影像常化差異植生指數(Normalized Difference Vegetation Index, NDVI)



之變化做檢測，利用影像相減法計算前後兩期影像 NDVI 之差值，再經由群集分析(cluster analysis)找出 NDVI 明顯降低之類群；該類群係指原先植被生育良好，颱風過後被嚴重破壞之處，為地表受創區位指標。而經由多變量統計分析結果顯示集水區地形資訊對交點發生土石流規模分類之準確度可達 90%。

張守陽等（2005）藉由「機械視覺」(Machine Vision)原理，分別針對不同土石流之流動現象，研擬不同土石流情境之影像處理法則，以「移動之物體辨識」、「土石流波前判釋」、「現場溪床之特定物判釋」及「土石流與洪水紋理判釋」等四種影像處理方法，進行室內之土石流模擬實驗及實際影像分析，具有良好之檢定結果，可以提供建立土石流判識監測系統之參考。

近年來國內外對於類神經網路應用於不同領域之相關研究也如火如荼的展開，如：影像辨識、預測、文字辨識、天氣預測、雷達偵測、影像識別..等。

黃源義（1992）曾以自組性演算法(Group Method of Data Handling, GMDH)應用於降雨—逕流之模式，其方法為將 Ivakhnenko 提出的 GMDH 法改以逐步迴歸的方式修正輸出單元。

張斐章、李心平（1995）曾應用模糊理論與類神經網路於土石流預警系統，其主要以類神經網路為主軸，輔以模糊理論的概念，藉降雨量多寡及研究地區地形對土石流發生的影響，判斷是否達土石流之警戒標準。由結果可以看出，以模糊控制配合類神經網路為基礎的土石流預警判定有相當好的表現。

孫建平（1996）將倒傳遞類神經網路應用於暴雨事件的推估，其網路架構為 MLP(Multilayer Perceptorn) 型態，利用 EBP(Error Back Propagation)學習演算法做為神經網路的主軸，其結果發現對於暴雨事件於逕流量的推估上有不錯的表現。

張東炯（2000）以倒傳遞類神經網路針對過去調查所得資料，進行土石流發生情況之研究。其結果與調查所得比較後發現，類神經網路架構具穩定性，且在訓練學習過程所得成功率平均高達 91.073%，而在測試驗證過程，整體成功率約為 76.5%。

邱曉萍（2002）曾利用共用臨域類神經網路進行降雨逕流之推求，其模式架構上先以共用臨域方法進行資料之分類，而後半階段則以迴歸分析建構輸入—輸出資料間的相對應關係，在與倒傳遞類神經網路的效能比較上，證實其準確度較高之外，該模式執行所

需之 CPU 時間亦較倒傳遞類神經網路所需之時間來的少，即有較高的模式執行效率。

三、理論概述

由於電腦技術的日新月異，計算速度不斷的提昇，過去許多需要繁複計算的理論已不再是遙不可及，使得近代科學技術的發展，已不再是僅止於簡單的物理模式或方程式推算，人們開始透過模仿生物學習的方法，獲取新科學技術概念例如基因演算法、蟻行演算法及學習蝙蝠飛行的判斷行為...等；同樣地，模仿生物神經網路學習的人工神經網路(Artificial Neural Network, ANN)，也是在瞭解生物神經網路的結構、機制和功能的基礎上，學習和實現人們所需要的智慧。類神經網路可簡單定義為一種計算系統，它使用大量簡單的相連人工神經元來模仿生物神經網路的能力。人工神經元是生物神經元的簡單模擬，可從外界環境或其它神經元取得資訊，並以簡單的運算程序後輸出其結果到外界或其它神經元。

一般類神經網路為三層結構(如圖 1)，包含輸入層、隱藏層及輸出層。其中輸入層用以表現輸入變數，其單元數目依問題的型式而定；隱藏層有可能有數層，用以表現輸入處理單元間之交互影響，其單元數目需以試驗的方式決定其最佳數目；輸出層用以表現輸出變數。神經網路的基本原理為網路中靠相關權重連結各層間之單元，各輸入單元輸入值經由加權累加後到達隱藏層，並透過轉換函數可得一值，同理再傳至輸出層。




圖 1 一般前向式類神經網路架構圖

Fig.1 Forward neural network structure

本研究中，我們架設以共用臨域為概念的類神經網路，即共用臨域類神經網路(SNN)，此網路架構可分為兩部分，前半段先以共用臨域分類方法將土石流發生的資料做分類，而後半段則利用監督式學習方法針對分類出的結果與實際資料做比對，並進而決定其分類的結果所佔之權重比，使具不同權重之分類群集具有一定的指標性意義。

1. 共用臨域

分類之目的在於將各個個體具有之相似因素歸於一類，使不同群體間因為其




圖 2 球狀群集
Fig.2 Lump clusters




圖 3 非球狀群集
Fig.3 Non-lump clusters

相異處而代表不同意義，而此相異之處的辨別可以讓我們對於群體代表的意義做適當的解釋，因此針對不同之問題亦發展出不同之分類法。然而一般的分類方法通常只具有處理如圖 2 之球狀群集能力，對於如圖 3 之非球狀群集則通常無法達到令人滿意之結果。

共用臨域演算法則為先給予一對特定參數值 K (鄰近資料點個數) 與 KT (兩兩資料點比較之重覆資料點個數)，經由各資料點對其最短距離之點的搜尋，決定各資料點之相鄰 K 個資料點，之後再兩兩比較各資料點之 K 個資料點是否有一定之相似度(即其重覆點之個數是否大於等於設定之 KT 值)，若是，則可將之定義為屬於同一群集之個體。其相關決定法則如下：

(1) K 值(最短距離法)的搜尋：

K 值表示資料點所搜尋之鄰近資料點個數，而點與點之間的距離可以用許多種方法表示，在這裡使用最普遍的歐式距離(其為 Minkowski 距離的二次動差)

Minkowski 距離之方程式表示法如下：

$$d_{ij}(M) = \left\{ \sum_{k=1}^p |x_{ik} - x_{jk}|^m \right\}^{1/m}$$

$i, j = 1, 2, \dots, n$

其中 $d_{ij}(M)$ 為 i 與 j 兩個資料點間的 Minkowski 距離， p 為維度， m 為任一設定之係數， $m=2$ 時即為歐式距離。

在鄰近點的選取方面，以距離為主要的考量依據，若是點與點之距離皆不相同時，則選取之點個數即為 K ，反之，則可能有選取之點個數大於 K 的情形出現。而若以半徑觀點視之，則可簡單的說，所包含之 K 個鄰近點中，最遠點的距離即為此群集之半徑，即表示， K 值愈大，半徑愈大。

(2) 相似度的比較：

選取要比較的兩個點必須互相落於彼此的半徑之內，也就是兩兩比較的資料點必須存在彼此資料點所包括之 K 個鄰近點內，之後再判斷除了要比較的資料點之外，其所包括的 $K-1$ (點與點之距離皆不相同) 個資料點，其重覆出現的資料點個數是否有大於 KT 值，若是，則將之分為同類。

持續上述兩步驟直至資料完全比對，則分類即可宣告完成。圖 4 則為對圖 3 之非球狀群集分

類所得之結果，由圖形中可以看出當調整參數值（ K 與 KT ）為 $K=22$ 與 $KT=6$ 時，我們可以輕易地將原來的同心圓圖形分為三類。另外，我們以共用臨域分類方法對蝴蝶圖形做分類，如圖 5 為自行繪製的蝴蝶圖形，在圖形中我們可以很明顯的看到一隻蝴蝶是由鬚鬚、身體及翅膀等不同的構造所組成，由此圖形直觀上我們可以將之看成為具有六個不同分佈之聚類，同樣地，我們也可利用不同的 K 與 KT 值設定上，將其分類為六個聚類（如圖 6 所示，其 $K=5$ ， $KT=1$ ）。

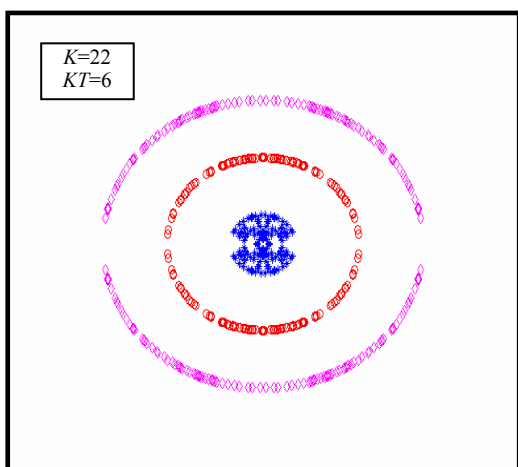


圖 4 對圖 3 進行分類的結果
Fig.4 Clustering result of fig.3

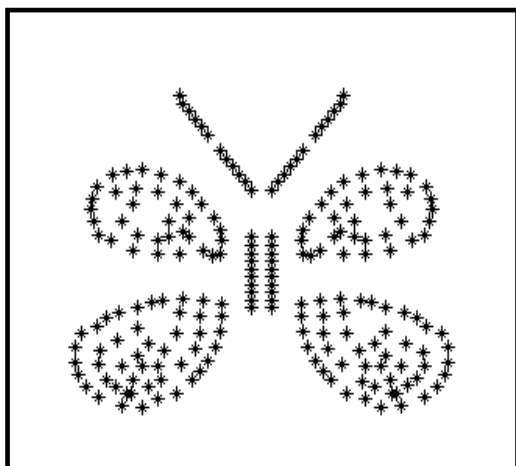


圖 5 蝴蝶圖形
Fig.5 Butterfly shape data set




圖 6 分為六個聚類之蝴蝶圖形
Fig.6 6 Clusters for butterfly shape data set

2. 監督式學習法則

經由以上之共用臨域演算法分類後，可以得到某些具特殊意義的類群，首先由這些群類中計算出每個聚類之中心點 $w^j(j=1...n; n$ 為分類群數)，並給定每個群類一 q^j 值($j=1...n; n$ 為分類群數；其中， q^j 為 0~1 的隨機值)，即輸出權重值，接著進行權重調整， $q_{new}^j = q_{old}^j + \beta[y(t) - q_{old}^j]$ 改變原分類的輸出權值為，其中 β 為學習速率， $0 < \beta < 1$ ，其值固定不變； $y(t)$ 為訓練範例的輸出值。由於此部份學習演算需有輸入及輸出資料的訓練範例，因此可稱為監督式學習。將上述的學習法則歸納可以為下列步驟：

$$1. D(w^j, x(t)) = \min_{j=1 \dots n} D(w^j, x(t))$$

$$2. \text{IF } D(w^j, x(t)) \leq \Delta$$

$$\text{THEN } q_{new}^j = q_{old}^j + \beta[y(t) - q_{old}^j]$$

$$\text{ELSE } q_{new}^j = q_{old}^j$$

其中：

$D(w^j, x(t))$ 表示第 j 個規則單元的中心點 w^j 與輸入值 $x(t)$ 的距離。

Δ 為在三角形從屬函數的模糊運算中，與中心點 w^j 的寬度值。

上述網路的學習演算可架構出網路模式，以進行預測函數或實際系統的工作。在學習運算中， Δ 值可以由試誤法找出，在本研究裡是先找出群類間之最大 Δ 值，再經由不斷地修正，直到其所得之誤差為最小為止。

在網路預測階段則包含兩個部份，第一步驟是形



式套配，第二步驟是權重均分，運用了模糊控制的觀念進行預測，其演算步驟如下：

步驟一：

輸入 $x(t)$ 與第 j 個聚類的套配情況以套配指數 $S^j \in [0,1]$ 表示：

$$s^j = S[x(t), (w^j, \Delta^j)]$$

其中， (w^j, Δ) 代表第 j 個聚類，其中心權重點為 w^j ，間隔寬度為 Δ 。 S 稱為套配量測或相似度量測，可以任何的形式表現，此處以下式及圖 7 表示：

$$s^j = 1 - D^j[x(t), (w^j, \Delta)]$$

其中， $D^j \in [0,1]$ 表示輸入 $x(t)$ 與規則單元 (w^j, Δ) 的相對距離：

$$D^j = \begin{cases} \frac{d^j}{\Delta} & \text{if } d^j \leq \Delta \\ 1 & \text{otherwise} \end{cases}$$




圖 7 以三角形函數作為從屬函數的套配指數 S^j

Fig.7 Suit index S^j of triangle function shape membership

其中， d^j 是 $x(t)$ 與第 j 個聚類中心權重點 w^j 的距離：

$$d^j = \left[\sum_{i=1}^n (w_i^j - x_i)^2 \right]^{\frac{1}{2}}$$

假設其輸入值為 n 個維度。

上述的計算中，若輸入值與第 j 個聚類的中心向量的距離大於 Δ ，則 $S^j=0$ ，表示第 j 個聚類對於該輸入值的影響權重等於 0。

步驟二：

預測值 $\hat{Y}(t)$ 以權重均分的方式計算，依照未知預測值佔各個從屬函數權重的百分比，乘以該從屬函數

的權重累加之後，再求其平均值以得出該預測值。在此網路模式中，預測值 $\hat{Y}(t)$ 的計算方式如下式所示：

$$\hat{Y}(t) = \frac{\sum_{j=1}^N s^j q^j}{\sum_{j=1}^N s^j}$$

其中， q^j 為規則單元的輸出權重值。

$\hat{Y}(t)$ 為輸入值 $x(t)$ 時的預測值。

模式建構完成之後，所有相關之參數將固定不變，其驗證階段則將新的資料與訓練階段所得到之每群的中心點間，求算新的資料於每個群集中心點的距離，依模式預測階段之方法進行演算，最後便可預測出輸入資料所相對映之結果。

3. 以簡例對 SNN 類神經網路架構測試

在此先隨機產生一 450 筆的資料，其為一 $z = \cos(x) - 0.3 * \sin(y)$ 的函數分佈，其中， x 、 y 分別為 0~1 的隨機變數值，而 z 則為此一函數的相對映輸出值，並將這 450 筆資料分為三組，分別用以充做訓練、驗證及測試階段之資料，其資料的筆數分配為 300、100 及 50，而網路的架構上則為一雙輸入一單輸出之 SNN 共用臨域類神經網路，以 x 、 y 為其輸入值， z 則為其輸出值，其結果如下：




圖 8 訓練階段

Fig.8 Training stage




圖 9 驗證階段

Fig.9 Validation stage






圖 10 測試階段

Fig.10 Testing stage

首先在 SNN 的分類階段，為了不讓資料的群數過大而產生過度描述的情況，選取的群數設定為資料組數的 1/10 較為適宜，則經由不同的 K 與 KT 值所得的結果，配合模式的架構並相對於驗證組所得出的結果，本研究中選取當 $K=10$ 、 $KT=6$ 所分出之 32 個聚類為分類之結果，而經由多次的測試，選定 Δ 值為 0.33，則以上即為模式測試之相關參數的設定。

依照相同的參數設定分別進行驗證與測試，可以得到不錯的結果，而由圖 8 至圖 10 看來，雖然沒有每個點都抓得到，但就整個趨勢看來，其結果尚屬不錯，若要得到更好的結果可能要再對參數進行不同的設定，然而此一簡例主要是為測試模式架構的可行性及適切性，則由此簡例函數的執行可以知道此一模式架構應屬一可行的方法。

四、研究區域與資料匯整

1. 研究區域

本研究以南投縣的陳有蘭溪流域為主要的研究區域，其地理位置於台灣中央，縣內山多平原少，山地約佔 80%，陳有蘭溪為濁水溪的主要支流之一，發源於玉山北峰八通關，其集水區東以邵大山與邵大溪為界，西以阿里山與清水溪及曾文溪為鄰，南至玉山、鹿林山與高屏溪，匯集玉山以北的阿里山山脈東坡與邵大山脈西坡的水，由南向北流，並於龍神橋處注入濁水溪主流，全長約 42.4 公里，流域面積 449.67 平方公里，平均坡度約 1/20，河道深狹，水流湍急，屬急流河川。

陳有蘭溪地勢南高北低，東高西低。由發源地高 2900 公尺，至最低點與濁水溪合流處的高度 310 公尺計算，平均河床坡度高達 6.1%，坡度陡峭，其值約為濁水溪流域的 3.7 倍。流域內平均高度為 1540 公

尺，其中低於 500 公尺僅佔少數，主要為為河道的氾濫平原；500~1000 公尺約佔 1/5，主要為沖積扇及低位階地；1000~1500 及 1500~2000 公尺的高度所佔面積最大，約為一半左右，主要分佈於東側及南側坡地，亦即是玉山北麓、邵大山及對關山的西坡；3000 公尺以上的面積佔 1/10，分佈於玉山北麓(如圖 11)。

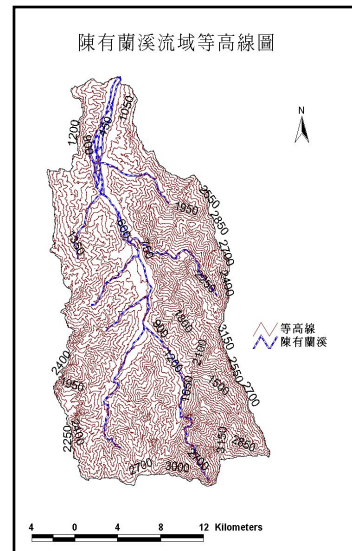


圖 11 陳有蘭溪流域等高線圖

Fig.11 Chen-Eu-Lan creek watershed contour map

2. 資料蒐集與分析

本研究所蒐集之災害資料為陳有蘭溪流域在民國七十年到八十七間所發生的土石流災情，蒐集的資料分為地文因子及水文因子兩部份，在地文因子方面利用數值地形模型(Digital Terrain Model, DEM)資料配合二萬五千分之一之地形圖，以地理資訊系統(Geographic Information Systems, GIS)和集水區資訊系統(WinGrid)進行地文因子的相關分析與擷取，而水文因子方面則是利用集水區鄰近雨量站之時雨量與土石流發生地點的距離相關遠近進行分析。

(1) 土石流災害發生紀錄

在土石流災害之記錄方面，本研究針對過去歷史資料、相關文獻所記載之土石流發生災害做調查，其結果經整理後如表 1 所示；由過去的資料蒐集可以看到，造成土石流災害的颱風場次多集中於民國八十年之後，推測其原因應是由於近幾年由平地往山坡地的開發增加，居住人口也隨

之聚集，另一方面，近幾年的颱風行為較為詭異，暴雨往往來得快而且急，造成全台各地之土石流災情嚴重，也使得土石流災害較受人重視，以致於近幾年之土石流災情較為人們注意而有記載。

表 1 土石流災害發生紀錄

Table 1 Historical debris flow record

地點	發生時間	降雨事件
南投豐丘	1985.8.23.19 時	尼爾森颱風
南投豐丘	1985.8.22.9 時	韋恩颱風
南投豐丘	1996.7.31.11 時	賀伯颱風
南投香蕉橋	1996.8.1.1 時	賀伯颱風
南投新興橋	1996.8.1.1 時	賀伯颱風
南投 95.5K	1996.8.1.1~2 時	賀伯颱風
南投新安橋	1996.8.1.2~3 時	賀伯颱風
南投新山橋	1996.8.1.2~3 時	賀伯颱風
南投郡平橋	1996.8.1.2~3 時	賀伯颱風
南投郡坑橋	1996.8.1.2~3 時	賀伯颱風
南投上安橋	1996.8.1.2~3 時	賀伯颱風
南投東埔一號橋	1996.8.1.2~3 時	韋恩颱風
南投豐丘	1998.6.9.18 時	暴雨

(2) 水文因子之分析與擷取

由於雨量的分佈在時間及空間上有極大的不確定性，不同的地點因為其距離遠近的關係其降雨量必定不同，再加上蒐集到的資料量過於繁複，因此，對於各個土石流發生溪流樣本處之雨量資料推估，除了要考量距離空間上的差異之外，如何減少雨量資料處理的困難度也是必須考慮的，所以在本研究中採用距離平方反比法，希望能藉由對降雨量在空間上分佈的差異進行簡化的假設，以利模式的建構，距離平方反比法就是利用鄰近距離資料點的平方值來決定相關加權值，距離越近者，權重值即越大。其計算方式如下：首先假設平面上有一欲推估之點 $X_0(x_0, y_0)$ ，以及 n 個觀測點 $X_i(x_i, y_i)(n=1 \sim i)$ ，計算欲推估之點 X_0 與 n 個觀測點之距離 d_{oi} ，則得到 i 個觀測距離，分別求取其平方值做反比，即可得到 i 個觀測距離之平方反比值，將各個值除以其總和則可得到不同距離之相對權重值 λ_i ，最

後累計其不同權重之觀測點雨量觀測值 $Z(X_i)$ ，即可得所欲推估之發生點的雨量推估值。其相關方程式如下：

$$\text{距離計算公式： } d_{oi} = \sqrt{(x_0 - x_i)^2 + (y_0 - y_i)^2}$$

$$\text{平方反比值計算： } f(d_{oi}) = \frac{1}{d_{oi}^2}$$

$$\text{不同距離之權重值推估： } \lambda_i = \frac{f(d_{oi})}{\sum_{j=1}^n f(d_{oj})}$$

$$\text{點 } X_0 \text{ 之推估值： } \hat{Z}(X_0) = \sum_{i=1}^n \lambda_i Z(X_i)$$

其中， $Z(X_i)$ ：為觀測點 (x_i, y_i) 之測量值

λ_i ：為觀測點 (x_i, y_i) 之權重係數

在有效降雨延時與有效累積雨量方面，土石流的發生在降雨量方面有一定的特性，為了減少資料的龐雜且易於使用，在降雨雨場方面在此略做篩減；其中，以一場集中降雨在其前 24 小時內累積降雨量達 10mm 之時間點，稱之降雨開始時間，其後 24 小時內累積降雨量未達 10mm 之時間點，稱之降雨結束時間，而有效降雨延時(HR)的定義為將降雨開始時間至任意時間稱之。有效累積雨量則以任意時間之時雨量(d_0)，加上其前各時雨量(d_i)乘以一衰減係數(α)後累加而得，可以下式表示：

$$ER = \sum_{i=0}^p \alpha^i d_i$$

p ：降雨開始時間

其中衰減係數之決定為： $\alpha = \sqrt{K}$

K 值的決定依據 Fedora and Beschta(1989)有關臨前降水指數模擬暴雨逕流之研究，指出每二小時的洪水消退係數與集水區面積的關係如下：

$$K = 0.881 + 0.00793 \times \ln(A)$$

A 為集水區面積(公頃)

(3) 地文因子之分析與擷取

在地文因子的擷取與分析方面，由於每個土石流發生地點並不相同，而不同的地點其地理概況即不一樣，前人的研究也指出，對於土石流的發生除了水文因子之外，尚有如：集水區面積、河川主流長度、集水區坡度...等各項不同的地文因子所影響，因此，本研究利用 GIS 軟體進行地文因子的蒐集與分析，在處理過程上先於陳有蘭溪流域上選取、描繪過去所記載曾經發生與未發生過之十六個次集水區，其中發生過土石流災情之集水區，共計有新安橋、新山橋、郡平橋、郡坑橋、上安橋、新中橫公路 95.5K 處、豐丘、東埔一號橋、香蕉橋及新興橋等十處，而未發生過



土石流災情之集水區六處，其地點為壽山橋、郡安橋、筆石橋、庫坑橋、望鄉橋及東埔二號橋，其相關之位置可由圖 12 所示，將選取之資料範圍與 40X40 網格大小之數值地形模型進行切割比對。

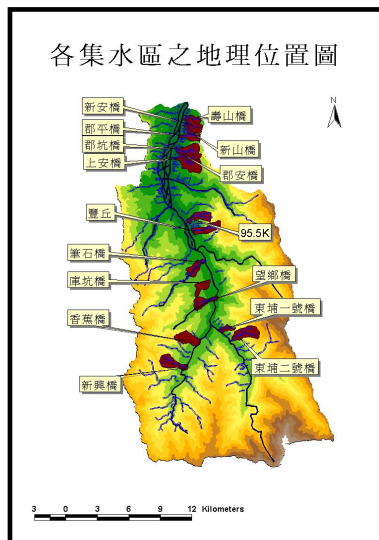


圖 12 各集水區之地理位置分佈圖

Fig.12 Subwatersheds of Chen-Eu-Lan creek

(4) 集水區資訊系統(WinGrid)

集水區可簡單定義為地面上以分水嶺為界之區域或河川某一地點地表水匯集之地形單元，以往集水區邊界之劃定皆是由專業人員依地形圖之等高線劃定，其結果常繫於個人主觀判定，無法依循客觀之標準獲得大家共識，不僅缺乏一致性及可重複性，整個處理過程相當繁瑣費時，本研究利用集水區資訊系統配合 GIS 所處理過之資料進行各項地文因子的分析與擷取，經由集水區資訊系統的集水區特性分析功能，對於切割之集水區進行分析，可以得到所需之地文因子，如：集水區面積、河川主流長度、集水區坡度及形狀因子...等特徵，其相關因子由於彼此間存在極大相似性，因此在整理後挑選如表 2 所示之地文因子進行模式之分析。

五、結果與討論

由於土石流的發生情況會隨著各區域的降雨條件與地文概況之不同而有所差異，而前人之研究通常將

降雨因素與地文條件對土石流之發生情形分別討論，因此本研究嘗試利用土石流發生時之臨前地文及水文因子，配合類神經網路之強大記憶及學習能力，期能對於土石流的預警做一適切之描述，而國內投入土石流防災的工作並不甚長，對於土石流發生的主要機制也都還在摸索之中，且土石流發生總是來得急而且快，其破壞力更是讓事後的研究工作無從下手，因此，如何在土石流的預警工作上有一定成效就顯得格外重要。

表 2 各個集水區之地文因子

Table 2 Subwatershed land parameters

	集水區面積 (km ²)	河川主流長度 (km)	集水區坡度(度)	形狀因子
新山橋	0.54	0.67	24.7	1.21
新安橋	1.39	1.5	21.3	0.61
郡平橋	0.88	1.26	23.3	0.55
郡坑橋	1.73	1.46	18.8	0.81
95.5K	1.64	2.03	24.7	0.4
上安橋	2.47	2.68	17.2	0.34
豐丘	1.88	1.7	27.9	0.65
香蕉橋	2.2	2.1	22.3	0.5
新興橋	2.18	2.79	23.3	0.28
郡安橋	1.07	2.38	20.3	0.19
壽山橋	0.64	0.82	21.3	0.95
筆石橋	1.44	1.59	11.3	0.57
庫坑橋	1.24	0.87	11.9	1.64
望鄉橋	1.59	1.99	12.9	0.4
東埔一號橋	0.65	0.96	23.3	0.71
東埔二號橋	2.54	2.52	26.6	0.4

過去的文獻及前人研究都曾指出，造成土石流發生原因除了水文因子之外，地文因子也是必須要考慮的因素之一，因此本研究利用陳有蘭溪流域的數值高程地形圖，由地形圖上不同的子集水區，配合地理資訊系統(GIS)及集水區資訊系統(WINGRID)軟體進行切割與分析，藉此蒐集到各個子集水區之一些地文因子概況，而分析得到之因子有：集水區面積、集水區周長、河川主流長度、平均高程、集水區坡度、形狀因子...等，希望能藉由此地文因子的不同，使模式架構愈趨完善，藉此對土石流之發生情況更更佳之描述。



本共用臨域類神經網路模式架構如圖 13 所示，前半段為一分類型之共用臨域網路，希望藉由輸入項所存在之特定關係做一有效的分類，而後半段採監督式之學習方法，利用發生與否當為輸出項之期望值，並藉由訓練階段不斷的比對、修改其權重，使輸入項之各筆資料能有適當之歸屬並定義之，在輸入因子方面利用有效降雨延時、有效累積雨量、集水區面積、河川主流長度、集水區坡度及形狀因子等六項，經由不同的輸入項進行試誤法，測試不同之網路模式架構，從而決定一最適之共用臨域類神經網路模式架構。

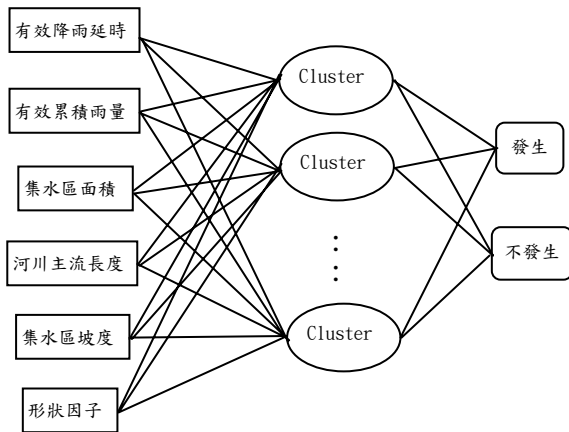


圖 13 共用臨域類神經網路架構圖

Fig.13 SNN structure

表 3 則為不同輸入因子之模式架構的測試結果，輸入資料為民國七十年到民國八十七年的雨場及蒐集分析到的地文因子資料，共計有新安橋、新山橋、郡平橋、郡坑橋、上安橋、新中橫公路 95.5K 處、豐丘、東埔一號橋、香蕉橋及新興橋、壽山橋、郡安橋、筆石橋、庫坑橋、望鄉橋及東埔二號橋十六個集水區，每個子集水區約有六十場左右的雨場，共計有 1038 筆，在資料的分割上則分為訓練階段的 620 筆，而剩下的 418 筆做為測試之用，其中，土石流發生之雨場資料共計有 26 筆，有 19 筆放置於訓練階段，測試階段則為剩餘之七筆。

在模式的架構上，由於對土石流發生的機制一直到現在為止尚沒有很明確的準則可循，前人研究與相關文獻也都僅指出與水文、地文因子有極高的相關性，鮮少有明確的定性、定量描述，而類神經網路的應用雖然可以彌補對於土石流機制無法完全掌握的缺

憾，然而在輸入項方面，也只能利用試誤法決定，本研究就蒐集的六個有關土石流發生之影響因子，即有效降雨延時(T)、有效累積雨量(R)、集水區面積(A)、河川主流長度(L)、集水區坡度(S)及形狀因子(F)進行試誤分析，共用臨域類神經網路在架構上由於牽涉到權重觀念，因此對於土石流之發生群集並無一絕對關係，而是視其相關之權重大小而決定之。

經由不同之輸入項及不同之 K 與 KT 值所設定之分類結果，如表 3 所列，就不同的輸入因子所執行的結果可以看到，其分類群聚大約是 100~140 類為最佳，這應該與資料筆數及資料形態有關，不同的資料所具有之特性會導致分類結果的歧異，另外，在發生點之判釋上，我們發現聚類分析不管在訓練或測試階段其皆有良好的表現，原因應是由於聚類所牽涉之範圍廣佈所致，這點由其誤判點數也相對的提高可以看出，因此，在聚類分析與 SNN 類神經網路模式的比較上可以明顯看出，雖然聚類分析在土石流發生資料的判釋上有良好表現，然其過高的誤判點數(約為 SNN 模式的二倍)，易使預警系統之效能降低，而在四種不同輸入項的比較上，本研究發現以四個輸入因子(T、R、S、A)與以五個輸入因子(T、R、S、A、L)之執行結果上，在發生點之判釋上皆具有較佳之表現，而在這二個模式的比較上可以發現，以四個輸入因子(T、R、S、A)之結果其分類群數較五個輸入因子(T、R、S、A、L)之分類群數為多，此一情況雖然能使其模式之誤判率降低，但另一方面來說，亦可能產生過度描述的現象，即較多的分類群數雖然可以降低驗證階段的誤判率，但在實際測試上卻不見得有比較好的執行效益，此一情形我們可以由測試階段的結果得到，因此本研究認為以有效降雨延時、有效累積雨量、集水區面積、河川主流長度、集水區坡度等五個輸入項為輸入因子之結果最能適切描述本研究之土石流發生情況，分類設定上則以 $K=5$ 、 $KT=2$ ，共可分為 112 類為最佳，在訓練階段的 620 筆資料中，有 15 筆為誤判，其誤判率為 2.4%，而測試階段的 418 筆資料，誤判的筆數僅為十筆，發生點的判釋上，七筆中有五筆被判釋而得(如表 3)，而發生與未發生土石流情況之判別情形就分類混淆表看來也有相當高的正確率(如表 4 及表 5)。

六、結 論

在共用臨域分類方法使用上，雖然用來控制其分類性質的 K 與 KT 兩參數並沒有特定方法可以決定，



表 3 不同輸入因子之結果比較表

Table 3 Comparison of different input combination

輸入因子	K(KT)	分類群數	Cluster & SNN	Training Set			Testing Set		
				誤判點 總點數	誤判率	發生點之 判釋	誤判點 總點數	誤判率	發生點 之判釋
三個輸入因子 (T、R、S)	5(2)	132	Cluster	36/620	5.8%	19/19	21/418	5%	4/7
			SNN	16/620	2.6%	12/19	10/418	2.4%	3/7
四個輸入因子 (T、R、S、A)	7(4)	139	Cluster	32/620	5.2%	19/19	21/418	5%	6/7
			SNN	14/620	2.3%	13/19	11/418	2.6%	4/7
五個輸入因子 (T、R、S、A、L)	5(2)	112	Cluster	29/620	4.7%	19/19	16/418	3.8%	6/7
			SNN	15/620	2.4%	13/19	10/418	2.4%	5/7
六個輸入因子(T、 R、S、A、L、F)	5(2)	107	Cluster	32/620	5.2%	19/19	16/418	3.8%	6/7
			SNN	16/620	2.6%	12/19	9/418	2.2%	5/7

表 4 五輸入項 SNN(訓練階段)之分類混淆表

Table 4 Clustering mix up table of 5 input SNN (training stage)

		土石流發生情況之 分類結果		正確率
		未發生	發生	
實際土石流 發生情況	未發生	592	9	98.5%
	發生	6	13	68.4%
總體正確率=97.6%				

表 5 五輸入項 SNN(測試階段)之分類混淆表

Table 5 Clustering mix up table of 5 input SNN (testing stage)

		土石流發生情況之 分類結果		正確率
		未發生	發生	
實際土石流 發生情況	未發生	403	8	98.1%
	發生	2	5	71.4%
總體正確率=97.6%				

必須經由選擇不同之組合重複進行分類測試，然因演算過程具有不需要大量之記憶體且執行速度快的優點，所以在模式分類運算效率上有不錯表現。

本研究以監督式學習法則對共用臨域分類方法分類之結果架設一層神經網路，並以有效降雨延時、有

效累積雨量、集水區坡度、河川主流長度、集水區面積做分析研究，在結果裡指出，以所架設之共用臨域類神經網路(SNN)除在未發生土石流雨場有不錯表現外，在發生土石流的雨場測試上亦可達到 71.4%之預警效果。

發生土石流災害的資料蒐集不易與資料的適確性有待商榷是研究土石流的最大難題，故對於本研究以共用臨域類神經網路架構土石流預警系統上，在模式的輸入項及模式的架構具有一定的影響程度，未來若能取得更長及更準確的資料，將有助於提高模式的精確度。

誌 謝

本研究工作承蒙行政院農業委員會水土保持局計畫[SWCB-92-012-10]的經費補助，研究期間，承蒙台大生工系范正成教授提供寶貴資料與建議，特此一併致謝。

參考文獻

1. 江永哲、林啓源(1991)，「土石流發生雨量特性分析」，中華水土保持學報，22(2): 21-37。
2. 邱曉萍(2002)，「以共用臨域網路推求降雨-逕流模式」，碩士論文，國立台灣大學生物環境系統工程研究所，台北。
3. 林昭遠、林文賜(2001)，「集水區資訊系統(WINGRID)入門」，暉帥股份有限公司，台中。
4. 林昭遠(2000)，「集水區地形因子自動萃取之



- 研究-土石流危險溪流判釋之應用」，中華水土保持學報，31(1): 81~91。
5. 高子劍、范正成(2001)，「機率式土石流臨界降雨線之研究」，碩士論文，國立台灣大學農業工程研究所，台北。
 6. 陳文福(1997)，「陳有蘭溪集水區地形特性與土地利用之關係」，中華水土保持學報，29(2): 137~155。
 7. 陳振杰(1999)，「陳有蘭溪流域的土石流發生與降雨之研究」，碩士論文，國立台灣大學地理學研究所，台北。
 8. 游繁結、陳重光(1987)，「豐丘土石流災害之探討」，中華水土保持學報，18(1): 76~92。
 9. 張守陽、黃榮堂、李璟芳(2005)，「機械視覺應用於土石流監測系統之研究」，中華水土保持學報，36(1): 1~18。
 10. 張東炯(2000)，「類神經網路於土石流發生預測模式之研究」，台灣水利，48(2): 92~98。
 11. 張斐章、李心平(1995)，「智慧型控制理論應用於土石流預警系統之研究」，碩士論文，國立台灣大學農業工程研究所，台北。
 12. 張斐章、孫建平(1997)，「類神經網路及其應用於降雨—逕流過程之研究」，中國農工學報，43(1): 9~25。
 13. 張瑞津(1997)，「陳有蘭溪流域的地形環境與自然災害之關係」，中國地理學會會刊，25: 43~64。
 14. 詹錢登(2000)，「土石流概論」，科技圖書股份有限公司，台北。
 15. 詹錢登、陳晉琪(1999)，「土石流發生機率分析—以花蓮縣銅門村及東興部落為應用對象」，中華水土保持學報，30(1): 65~75。
 16. 蔡玉琴(1995)，「淡水河流域降雨於空分析及推估—地理資訊系統的應用」，碩士論文，國立台灣師範大學地理學研究所。
 17. 謝正倫、陸源忠、游保杉、陳禮仁(1995)，「土石流發生臨界降雨線設定方法之研究」，中華水土保持學報，26(3): 167~172。
 18. Chang, F. J., Hu H. F. and Chen Y. C. (2001), "Counter propagation fuzzy-neural network for streamflow reconstructing," *Hydrological Processes*, 15(2): 219-232.
 19. Chang, F. J. and Huang Y. Y. (1999), "A Self-organization Algorithm for Real-time Flood Forecast," *J. of Hydrology*, 169: 229-241.
 20. Dueker, K. J. (1979), "Land Resource information systems: a review of fifteen years experience," *GeoProcessing*, 1:105-128.
 21. Yu, F. C. (2002), "An Overview of Debris Flow in Taiwan," *First International Conference on Debris-Flow Disaster Mitigation Strategy*, pp.185-196.
 22. Jarvis, R. A. and Patrick E. A. (1973), "Clustering using a similarity measure based on shared near neighbors," *IEEE Trans. Comput.*, C(22): 1025-1034.

2005年7月22日 收稿

2005年10月17日 修正

2005年11月9日 接受

(本文開放討論至2007年3月31日)

