

## 巢狀超矩形學習模式於乾旱季節流量預測之應用

### An Application of the Nested Hyper-rectangle Learning Model for Stream Flow Forecast in Droughty Seasons

國立台灣大學農業工程學系教授兼水工所主任

張斐章

Chang, Fi-John

國立台灣大學農業工程學系專任研究助理

林惠芬

Lin, Hui-Fen

#### 摘要

本文主旨旨在探討「巢狀超矩形學習模式」於曾文溪流域乾旱時期之流量預測。研究的主要對象為曾文水庫下游之玉田水文站每年乾季之旬流量。

「巢狀超矩形學習模式」是「依範例學習模式」的一種，它模擬人類經由經驗的累積以推估或分類事物的思考方式。此模式最初將事件以點的方式貯存在歐氏 $n$ 維空間中，隨著學習樣本的增加，將「相配」的範例視為同一類，並以超矩形方式記憶。此模式利用「類似度計量」來量測新加入樣本與已存範例之類似度，並依相配與否，動態的調整「類似度計量」中的各組權重參數，故模式將隨著學習樣本的增加而更接近真實狀況，亦即模式具學習的能力。

本研究將「巢狀超矩形學習模式」應用於乾旱季節之流量預測。預測結果顯示此模式在乾旱季節流量預測之適用性。另外，本研究亦探討各種不同架構方式對模式預測能力的影響，其中「二次機會」達到節省記憶空間且不影響預測精確度的效果。

關鍵詞：巢狀超矩形學習模式，乾旱，流量預測，二次機會。

#### ABSTRACT

The main purpose of this study is to forecast the stream flow of Tsengwen river in droughty seasons by using the nested hyper-rectangles learning model(NHRL). The stream flow of Yu-Tien, a gauging station located on the downstream of Tsengwen reservoir, is used to investigate the statistical characteristics during the droughty seasons.

The NHRL algorithm simulates the way human learns by experiences for estimation and classification. The learning is accomplished by storing objects in Euclidean  $n$ -space,  $E^n$ , as points in the beginning. And the exemplars are generalized to hyper-rectangles, if the

examples "match" the exemplars. The hyper-rectangles may be nested inside one another to arbitrary depth. This model uses "Similarity Metric" to measure the similarity between the new example and exemplar, while the weight parameters in "Similarity Metric" are adjusted dynamically. That is the model has the ability of learning.

The NHRL model has been employed to forecast the stream flow. The forecasting results of the model show the fitness in stream flow forecasting. Several types of model's structures are further investigated in this study for understanding their influence in stream flow forecasting. 「The second chance」 does save the memory space and does not reduce the accuracy.

Keywords : NHRL, Drought, Stream flow forecasting, The second chance.

## 一、前 言

近年來，台灣地區對水資源之需求日益殷切，但由於降雨之時間和空間分佈極不均勻，可供開發之理想水庫壩址亦已相當有限，故提昇水資源管理之決策品質的需求將日趨重要。良好的決策需要足夠的資料及準確的推估未來可能發生的情況，唯乾旱、洪水係一自然現象，其嚴重性及持續性為一序率過程，即具有不確定性。如何根據目前所擁有的水文及用水資料，分析其特性，從而較精確的推估其預期之數值，值得深入探討研究。

目前農政單位對曾文－烏山頭水庫灌區的農業用水需要一套具精確度高且能為大家所接受的乾旱預測方式，以提高協調說服能力，使協調後不致因預估有極大出入，導致協調政策不易執行，使公信力遭到質疑。針對此一問題，本研究擬以巢狀超矩形學習模式深入探討。

## 二、乾旱定義

水文文獻中指出，要定義一個合適的、一般化的「乾旱事件」(drought event)是一件複雜而困難的工作【張斐章，陳永祥，1992】。乾旱在農業、經濟、水文各種不同領域，因需求的不同而異。在農業乾旱方面，係指某一時期，因雨水不足，土壤含水量無法充分供應作物之所需，而使作物無法正常生長。在氣象乾旱方面，乃指氣候異常，雨水失調之自然現象。乾旱亦因不同地區、不同的需求而有不同的定義，在台灣則以連續五十日不下雨為小旱，連續一百日不下雨為大旱。在水文乾旱方面，乃指地球表面水量供應匱乏，水庫蓄水量低於規線嚴重下限之下，於各種用水不能適時適量之供應，尤其在作物生長時期，雨水短缺，農民又無法引水灌溉，以滿足作物之需水量【徐享崑，1979；王如意，趙啓迪，1987】。

由於本研究主要目的是提供農政單位一種新的方式預測流量，而農業灌溉之缺水季節大多集中在1、2、3及12月間，再加上水庫平時操作大抵以旬為操作單位，故本研究選取每年1、2、3及12月的旬流量為探討對象。另外，再將乾旱定義中降雨量小於0.5公釐視為不降雨日之定義引入，以連續不降雨日數為一影響因子，加入模式的運作。

## 三、巢狀超矩形學習模式之架構介紹

### 重要特質

巢狀超矩形學習模式為「依範例學習模式」之一種，而依範例學習之理論簡稱為 EACH(Exemplar-Aided Constructor of Hyper-rectangles)。其基本假設為以相同領域中先前發生過的例子(example)為基礎，作為推估或分類之依據。經由學習例子的持續增加，最初係以點(point)貯存在歐氏n維空間( $E^n$ )中，而n代表在一個例子中變數(variables)或特徵(features)的數目，巢狀超矩形理論又將上述各點形成超矩形(hyper-rectangles)結構【Medin and Schaffer, 1978】，當例子的個數增多時，一些例外(exception)可能在超矩形中產生，即所謂的「洞」(hole)，這些洞裡面又可能有其他的洞，而形成了「巢狀」(nested)的超矩形結構【陳莉，張斐章，

1992】。所謂的超矩形(hyper-rectangle)則是二維以上之矩形形狀。

EACH主要的概念為新的樣本與先前發生過的例子做比較，至於如何決定那一個例子和新的樣本最為相似，則係利用「類似度計量」(similarity metric)，也稱為「距離計量」(distance metric)，因為它量測了各範例與新樣本間的距離【Salzberg, 1988】。EACH新樣本的推估或分類變數值與記憶中最接近的範例值設為相同，而所謂學習，則是系統經由預測而獲得一些回饋(feedback)之後，使系統能依最新的信息，作必要的修正或適度的改善，使其更能與實際狀況相吻合。

巢狀超矩形學習模式並非產生規則(rule)，亦非一般的決策樹(decision tree)，而係建立一個佈滿範例(exemplar)的記憶空間，其中有些為繁衍(generation)的超矩形，有些則為從系統經驗中取得的獨立樣本(example)，這種結構化的範例記憶(structured exemplar memory)是學習程序的主要輸出。因為巢狀超矩形為軸平行矩形(axis-parallel rectangle)，所以只需要記憶對角線上的兩點就可定義一個超矩形，其內部的一些模例點則可省略不記，這種資料結構可節省龐大的記憶空間。

#### 基本演算法

此學習模式演算法基本上可分為兩大部份，一為資料庫模式之建立、參數之演算，稱為學習階段；另一為純粹的預測或分類工作。整個演算法之架構、參數調整均在第一部份，待整個資料庫架構完成再進行最終之預測工作，故在第二個部份中整個架構、參數將不再調整。

#### 1. 資料庫之架構

資料庫之架構流程示如圖1(不包括※超矩形內架構函數步驟)。

以一簡單例子說明建立此一模式之步驟及方式，假設目標輸出值為Y，而影響Y之變數有兩個 $x_1, x_2$ ，即 $Y=f(x_1, x_2)$ 。另外以E(example)代表欲加入訓練之新樣本，H(exemplar)代表已儲存於資料庫的超矩形範例，可能為一已推展(generate)成形的超矩形範例，亦可能是一個點範例。本例中由於變數為 $x_1, x_2$ 二類，故所形成之形狀為二維之矩形。

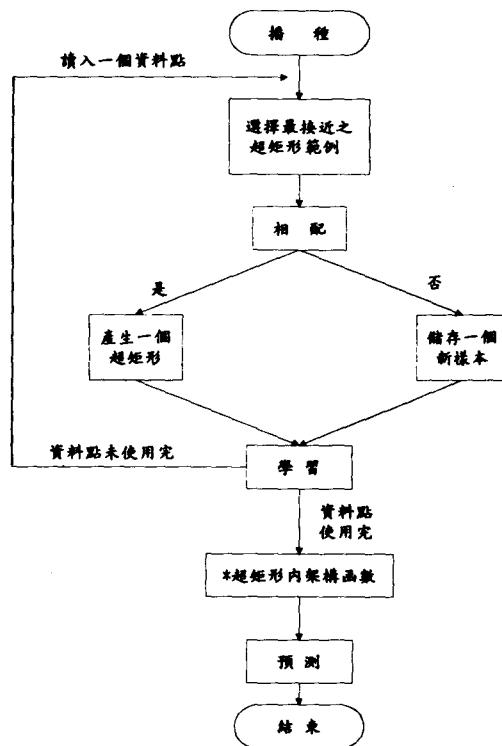


圖 1. NHRL 之流程

註：傳統NHRL不包括\*超矩形內架構函數步數

#### 步驟 1. 播種 (seeding)：

在一開始完全無範例可供學習的情況下，需隨機的選取幾個點來「播種」，播種個數無限制，但至少為一個。依此例子播種的每個點包括Y和相對的 $x_1, x_2$ 值。

#### 步驟 2. 選取最相似之超矩形範例 (H)：

此程序使用「類似度計量」來量測新的樣本(E)與一個範例(H)之間的距離(或類似度)。系統藉著量測兩個物體間的歐氏距離來計算E和H間「類似」的分數，其最簡單的方程式便是假設H為一點，距離即可由一般計算每一變數空間(variable space)在幾何上的距離，並考慮每一範例及變數向量之權重，其計算式如下：

$$D_{EH} = W_H \left[ \sum_{i=1}^n \left( \frac{E_i - H_i}{Max_i - Min_i} \right)^2 \right]^{0.5} \quad (1)$$

$D_{EH}$ ：新樣本E和超矩形範例H之類似度

$W_H$ ：超矩形H之權重

$W_i$ ：各個變數( $x_1, x_2$ )之權重

n：變數個數，本例中 n = 2

$Max_i$ ,  $Min_i$ : 各個變數之最大值、最小值

$E_i$ : 新樣本 E 中第  $i$  個影響變數之值

$H_i$ : 超矩形範例 H 中第  $i$  個影響變數之值

將新加入樣本 E 與資料庫中儲存之所有超矩形 H 比較後，選出  $D_{EH}$  值最小之超矩形 H。

### 步驟 3. 相配 (match) :

在步驟 2. 選擇最相似之超矩形 H 時只考慮變數  $(x_1, x_2)$  的類似度，而決定新加入樣本與超矩形是否相配則需考慮兩者之輸出值 (Y) 是否一致。

要決定新加入樣本 E 與選中之超矩形範例 H 是否相配，系統需設一「誤差容忍參數」 (error tolerance parameter, ET)。本研究誤差容忍參數 ET 採比例值，假如設定 ET 為 0.1，當一超矩形範例 H 的代表值 Y 為 5.0 時，則在範圍 [4.5, 5.5] 之間的任何數值均被視為「相配」 (match)。如新的樣本 E 之輸出值 Y 為 5.03，則此樣本 E 與該範例 H 相配，不必在記憶中貯存這一個新的點。

若 E 與 H 相配，則以 E 和 H 為對角線推展 (generate) 成一新的超矩形 H'，H' 只需記錄各個變數  $(x_1, x_2)$  之最大值、最小值，和原 H 中之輸出值 Y，即資料庫中屬於此超矩形範例最先被讀取到之 Y 值。原 E 與 H 將從記憶中消除，只留下新的 H'，而每個超矩形僅記錄一個目標值 Y，如此可節省記憶儲存空間。反之，若 E 與 H 不相配，則將 E 儲存為一新的點狀範例 H'。

### 步驟 4. 回饋 (feedback) :

經過了第 2 和第 3 步驟後可依其結果對整個架構作調整。而調整方式則是對「類似度計量」方程式中之兩組權重參數  $W_H$ ,  $W_i$  作調整。 $W_H$  為量度利用超矩形範例 H 並且相配 (match) 的機會，即選中某範例 H 的全部次數與能夠相配次數的比例。換言之， $W_H$  代表每一個範例有關「可靠性」的訊息，如一個超矩形 H 被選中很多次，可是卻經常無法相配的話，權重  $W_H$  將會變得非常大，如此 H 將趨於不被選為最相似超矩形，而漸漸被忽略。另外，如果 H 為一擾動 (noise) 點，則它將由於  $W_H$  的漸增亦被忽略，理論上  $W_H$  最小的值為 1 (即全部相配)。

另一組權重  $W_i$  代表第  $i$  個變數所佔的權重，權重之調整可反映出並非所有的變數對於分類、預

測的決定都具有相等重要的影響，應用依範例學習 EACH 演算法顯示若這些權重的修正很緩慢則系統較穩定且有較佳的表現，相反地，急速的調整將導致系統推估準確度的振動 (oscillations) 【Salzberg, 1991】。

上式程序於每次加入一個新的樣本點 E，即重覆步驟 2 到步驟 4，直到所有已知樣本點均被使用，才完成資料庫之架構。

### 2. 預測、分類工作

這個部份的情況是目標輸出值 Y 未知，欲利用與 Y 相關之變數  $(x_1, x_2)$  對 Y 值作分類或預測的工作。

此時，「類似度計量」公式中所有的權重參數  $W_H$ ,  $W_i$  均已固定，不再作調整。所以將欲推估點之相對變數值代入  $E_q(1)$  中，求出與資料庫中所有超矩形範例的  $D_{EH}$  值，並從中挑出  $D_{EH}$  值最小的超級形範例 H'，此一推估點的輸出值即為此超矩形 H' 的輸出值 Y'。

### 類似度計量 (similarity metric)

由於  $E_q(1)$  「類似度計量」為本演算法的決策中心，是以再對此計量方式作進一步之介紹。

#### 1. $W_H$

此權重參數說明了在每一個超矩形範例中有關「可靠性」的訊息。

$$W_H = \frac{\text{被選中為最類似超矩形範例的次數}}{\text{目標值 } Y \text{ 相配的次數}} \quad (2)$$

(2) 式表示若某一超矩形範例被選中為最類似的次數很多，但卻經常無法相配 (即作了錯誤的推估)，則將  $W_H$  調大，此範例將逐漸被忽略。換言之，若此超矩形範例被選中的次數幾乎等於相配次數 (即作了正確的推估)，則  $W_H$  將趨近於 1；另外，當分子、分母變大，即使有一、二個擾動點 (noise) 選中此超矩形範例，亦不會對  $W_H$  造成太大的影響，亦即此超矩形範例呈穩定狀態。

#### 2. $W_i$

權重參數  $W_i$  代表第  $i$  個參數所佔的權重。在本研究中，調整方式參式 SALZBERG(1991) 的方法，而為使其在應用時震盪不會太大，只在類似度大時調整  $W_i$ ，類似度小時則不加以調整，示如下式。

類似度大但 Y 值不相配

$$W_i = W_i(1 + Df)$$

類似度大且 Y 值相配

(3)

$$W_i = W_i(1 - Df)$$

Y 值相配與否與設定誤差容忍度 ET 有關；本研究探討  $ET = 0.2$  及  $0.4$  時對本例之影響。類似度大小評判標準設為下式：

$$CS_i = ET \times \bar{X}_i / 10 \quad (4)$$

ET：目標值相配與否之誤差容忍度。

$\bar{X}_i$ ：第  $i$  項影響因子之平均值。

3.d.

此值計算新的樣本點 E 與超矩形範例 H 第  $i$  個變數的歐氏幾何距離。

$$d_i = \begin{cases} E_i - H_{i(\text{upper})} & E_i \geq H_{i(\text{upper})} \\ H_{i(\text{lower})} - E_i & E_i \leq H_{i(\text{lower})} \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

$H_{i(\text{upper})}$ ：超矩形範例 H 中之最大值

$H_{i(\text{lower})}$ ：超矩形範例 H 中之最小值

以公式(5)計算所得之值即等於新的樣本點 E 與超矩形範例 H 最接近邊 (edge) 或角 (corner) 的垂直距離，若 E 點落 H 內，則距離視為 0。

如前所述，超矩形可能有重疊或相交的情形。若 E 落在重疊之超矩形中，或計算出之  $D_{EH}$  (類似度) 一樣時，本研究探兩種選取方式加以探討：(1) 選  $W_H$  較小之矩形，因其「可靠性」較高。(2) 選對角線較小之超矩形，因其含括之範圍較小，應較正確。以圖 2 為例，當變數有二個  $x_1, x_2$  時，以對角線較小之超矩形方式選取，則 A 點屬於超矩形 1；B 點屬於超矩形 2；C 點屬於超矩形 4；D 點屬於超矩形 4；E 點屬於超矩形 3。

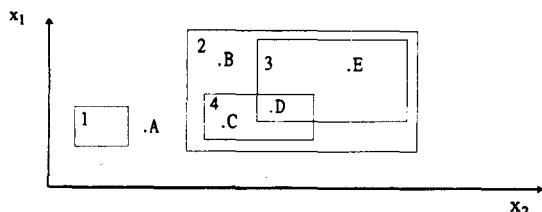


圖 2. 解說圖例

4.  $Max_i - Min_i$

Eq(1) 將  $d_i$  除以  $Max_i - Min_i$  是為使每一變數之差

異標準化在  $[0,1]$  區間內。在本研究中為了使架構穩定，在模式一開始時就先搜尋所有的資料點加以固定。

#### 第二機會 (The second chance)

在學習階段，當巢狀超矩形模式對其推估之結果與真實結果做比較以修正其參數值而獲致回饋的效果；即如果系統做了正確的推估，超矩形 H 就被認為包括新的點 E，此時可對各項參數做調整，使模式推估能力更強。如果系統做出錯誤的推估，Salzberg(1985, 1986, 1988)建議使用「第二機會」(the second chance) 經驗法則以避免產生過多不必要的記憶，即在產生一個新的範例之前，首先檢測記憶中的第二最佳「類似超矩形」，若第二類似超矩形與新加入樣本兩者之目標值(Y) 相配，則將其推展成一新的超矩形範例。若是第二最佳「類似」也做了錯誤的推估，那麼系統就將新的樣本 E 視為記憶中的一點，這個新的例子可能存在於範例 H 的內部，這種情形就好像在 H 中有一個例外(exception) 或「洞」(hole)，進而由點演變成一個矩形，最終構成一巢狀組織。

本研究將探討第二機會在預測時，是否達到節省記憶空間的目的，並探討是否會降低預測精確度。

#### 超矩形內架構函數

由前述知，一個新進樣本能否與其它超矩形範例相配取決於其目標值(Y) 是否夠接近，而是是否夠接近則由預先設定之誤差容忍度參數(error tolerance, ET) 決定，應用於連續數值的預測上時，發現若容忍誤差小則所形成之學習範例個數將增多，無法達到分類、節省記憶空間的目的；若將容忍誤差調大則所得結果可能不夠精確。

另外，由前述之理論知，在預測階段其預測值即是與最類的超矩形範例相同，無論在學習階段是否有類似情形發生過。以圖 3 為例，假設 1、2、3、4 四個矩形是在學習階段架構成的，推估時有一點 A 發生，由圖可看出 A 點與矩形 1 有很大的差異，但由於無其他更類似範例可供選擇，A 點將被歸類為矩形 1，即與矩形 1 具備相同的目標值(Y)。由此例子可看出，傳統的巢狀超矩形學習模式無法像其他以函數型態表示的方法一樣有向

外延伸的能力，因此對某些特殊事件將可能造成很大的誤差。

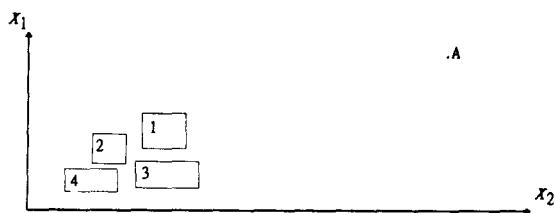


圖 3. 解說圖例

為解決不夠精確及無法向外延伸兩問題，試在每個超矩形內架構函數，亦即將「巢狀超矩形學習模式」視為分類的工具，而較細部數值的計算利用內部函數來執行，如此則可解決不夠精確

及無法向外延伸的問題，流程示於圖 1。

本研究中內部函數用最簡單的線性複迴歸(6)式表示，即利用所有選中且相配的點求算(6)式之係數。

$$Y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n \quad (6)$$

試用這個在內部迴歸函數的方法時曾懷疑如此則喪失巢狀超矩形學習模式不預設函數型態的優點，也就可能因為內部函數型態不符而造成推估錯誤的情形。但經實際應用及此模式的基本架構相信，經過巢狀超矩形學習模式仔細的分類後原本只用一個目標值代表該超矩形之輸出值，現改成以一條迴歸式表示尚屬合理。

#### 四、應用於曾文溪流域之乾旱預測

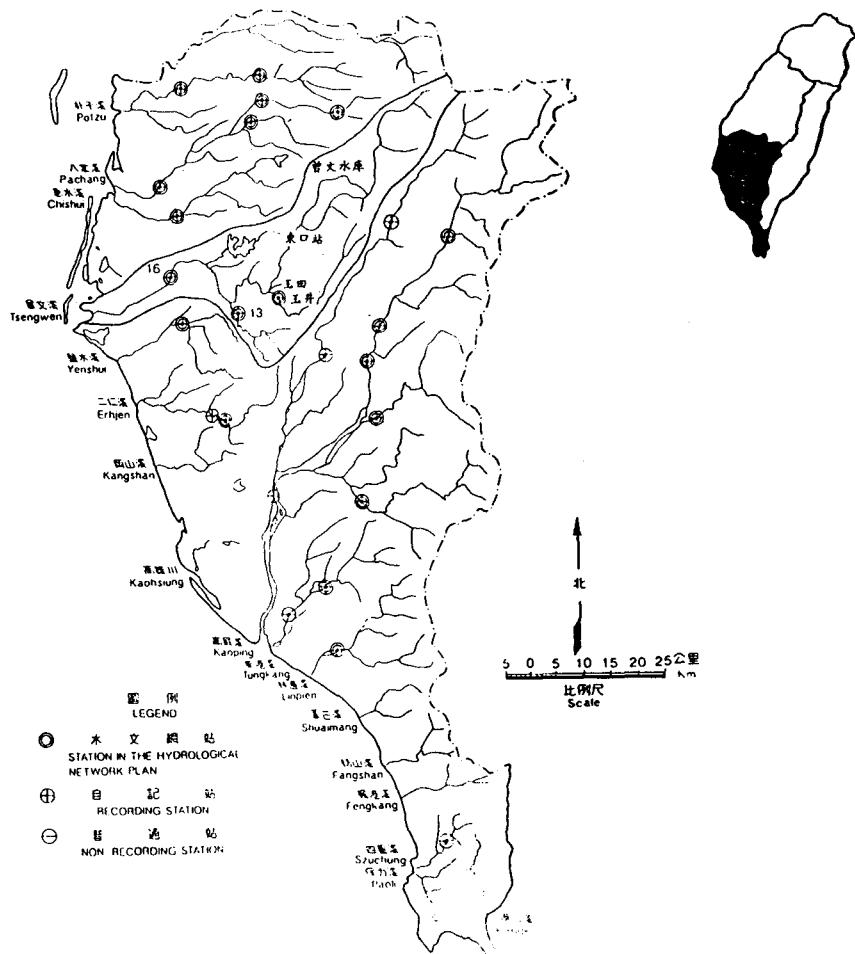


圖 4. 曾文溪流域測站位置圖

曾文溪發源於中央山脈南主峰之水山。主流全長 138.47 公里，流域面積 1177 平方公里，流域內現建有曾文、烏山頭及鏡面三座水庫。其中，曾文水庫集水面積 481 平方公里。本研究選取玉田水文站、玉井雨量站及曾文水庫入流量為研究對象。玉田及玉井基本資料示於表 1【農業工程研究中心，1993】。測站位置圖示於圖 4。

表 1. 選用測站之基本資料

站名	測站編號	東經 北緯	面積 標高	機器 儀器	計錄年限
玉田	H41005	120°27' 23°07'	160.53 40	水利局 自計	1959~迄今
玉井	R410012	120°27' 23°07'	54	臺轉 普通	1927~迄今

資料之選取使用 1959 ~ 1986 共 28 年，每年冬季（即 1 、 2 、 3 及 12 月份）之旬流量，共 335 旬為訓練模式之樣本，再利用訓練所得模式預測 1987 ~ 1990 每年冬季及 1991 年 1 、 2 、 3 月， 5 年間共 57 旬的流量。

### 流量預測

本應用實例利用巢狀超矩形學習模式預測玉田站流量，並以曾文水庫入流量及玉井雨量站為影響因子，探討不同因子之影響度；且探討不同模式架構對預測準確度的影響。

#### 1. 影響因子

為預測玉田站流量，我們利用不同的影響因子 (factor) 組合，希望找出對玉田流量預測影響較大之因子。影響因子組合示如表 2。表中連續不降雨日數指連續無間斷之不降雨天數，而當日降雨小於 0.5 公釐即視為不降雨日。

表 2. 影響因子組合類別

類別	影響因子
A	1. 玉田水文站前一旬流量
	2. 曾文水庫前一旬入流量
	3. 玉井雨量站前一旬雨量
	4. 連續不降雨日數
B	1. 玉田水文站前一旬流量
	2. 曾文水庫前一旬入流量
	3. 連續不降雨日數
C	1. 玉田水文站前一旬流量
	2. 連續不降雨日數

為比較各組合預測結果的優劣，以(7)式平均預測誤差為評判準則 (criteria)。分別將 A 、 B 、 C 三種組合以不同之容忍誤差 (error tolerance, ET) ，建立巢狀超矩形學習模式，並預測相同時期的流量，得結果如表 3 。

$$AE = \sum_{i=1}^m |\hat{Q}_i - Q_i| / m \quad (7)$$

m : 預測個數，本研究 m = 57

$\hat{Q}$  : 利用模式預測之流量值

Q : 實際記錄之流量值

表 3. 不同影響因子組合之平均預測誤差 單位： cms

影響因子 組合類別	容忍誤差	
	ET=0.2	ET=0.4
A	1.79	1.50
B	1.27	1.19
C	1.19	1.03

由表 3 可看出 C 組之預測結果最好，亦即玉田站本身前一句之流量及不降雨日數兩個影響因子，對玉田站的流量預測有較明顯的影響。曾文水庫入流量及玉井雨量資料則有擾亂此學習模式的效應。

#### 2. 第二機會 (the second chance)

Salzberg(1985,1986,1988) 建議使用「第二機會」 (the second chance) 經驗法則以避免產生過多不必要的記憶。本研究欲探討第二機會是否確實達到節省空間的目的，並瞭解是否會降低預測精確度。

在此，仍然使用 A 、 B 、 C 三種影響因子組合，在不同的誤差容忍度下，使用有二次機會和無二次機會兩種不同架構訓練樣本，並預測相同的資料。得結果如表 4 。

由表 4 可看出「第二機會」的確節省了儲存空間，預測誤差則互有消長，但無明顯的差別。

表 4. 有、無二次機會之不同架構下之預測誤差及儲存範例個數 單位： cms{ 個 }

影響因子 組合類別	容忍誤差 ET=0.2		容忍誤差 ET=0.4	
	有二次機會	無二次機會	有二次機會	無二次機會
A	1.79 (233)	1.69 (281)	1.50 (146)	1.53 (210)
B	1.27 (231)	1.35 (274)	1.19 (142)	1.29 (211)
C	1.19 (218)	0.84 (264)	1.03 (140)	1.44 (216)

註：表中數字無括弧者為預測誤差 AE, 有括弧者為儲存範例個數

### 3.類似度相同時之處置

實際應用巢狀超矩形學習模式時，發現當訓練樣本多或誤差容忍度大時，超矩形易於擴大，也就易於造成樣本點落在超矩形內部，即相似度 $D_{EH}$ 值等於0的情況。如前述，所謂「巢狀」即因超矩形會有重疊、交錯情況而得名，所以就可能有預測點同時落在數個超矩形內，或算出之相似度 $D_{EH}$ 值相同的情形發生，此時即需取捨與那個超矩形最為相似。

本研究比較以下兩種取捨方法：

(1)選擇可能較可靠，即 $W_H$ 值較小之範例。

(2)選擇超矩形範例對角線較小之範例，因其含括範圍較小，可能較為準確。

分別將預測結果示於表5，表5是採有二次機會之模式架構。由表可看出兩種選取方式的預測結果幾乎相同。

表 5. 類似度相同時不同取捨方式之預測誤差及儲存範例個數  
單位：cmns；{個}

影響因子組合類別	容忍誤差 ET=0.2		容忍誤差 ET=0.4	
	對角線小	$W_H$ 值小	對角線小	$W_H$ 值小
A	1.79 (233)	1.79 (233)	1.50 (146)	1.50 (145)
B	1.27 (231)	1.27 (231)	1.19 (142)	1.09 (142)
C	1.19 (218)	1.05 (194)	1.03 (140)	1.01 (140)

註：表中數字無括弧者為預測誤差AE，有括弧者表示存範例個數

## 五、結論與建議

將巢狀超矩形學習模式(NHRL)預測曾文一烏山頭灌區玉田水文站1987～1991年間之旬流量結果示於圖5。由圖5可看出此方法在低流量時有相當好的預測結果，也顯示了此方法於乾旱預測之適用性。以下為本模式在不同架構應用下所得結論：

### 1.影響因子

對於玉田站之流量預測，玉田本身前一旬流量及不降雨日數兩個因子有較佳的表現。至於曾文水庫入流量及玉井雨量站兩因子的加入反而降低了預測準確度。由此可看出NHRL雖然可利用權重參數 $W_i$ (3式)的調整減少無關變數的影響，但整個模式仍會受到干擾，故慎選影響因子仍是非常重

要的。

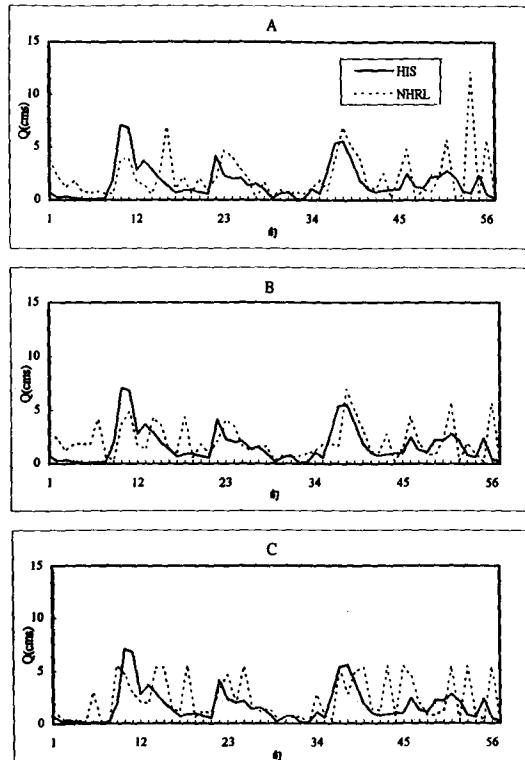


圖 5. ET = 0.4, 有二次機會及類似度相同時取對角線小範例下，用 A,B,C 三種不同影響因子組合之預測情形

### 2.第二機會

第二機會在流量預測上節省了大量儲存範例空間，而且不會影響預測的精確度，表此方式確有其應用的價值。

### 3.類似度相同時之處置

本研究對於類似度 $D_{EH}$ 值(1式)相同時，採取了選對角線小之超矩形及可靠度高 $W_H$ 小之超矩形兩種方法加以測試。此兩種方法之預測結果並無明顯的差別，表示此兩種取捨方法所架構之模式並無很大的不同。由此可得一結論，一般含括範圍小即對角線小之超矩形可靠度較高。

## 六、謝 誌

本研究承蒙行政院國家科學委員會工程技術發展處專案補助，計畫編號為 NSC83-0410-E-002-0

## 七、參考文獻

1. 王如意，趙啓迪，「台灣河川乾涸特性探討及模式建立之研究」，農委會 76 農建 -8.1- 林 -35 (3) 研究計畫，1987，11 月
2. 徐享昆，「台灣集水區乾旱週期及乾旱模式之研究」，台灣大學農業工程學研究所碩士論文，1979，6 月
3. 張斐章，陳永祥，「極端乾旱的統計分析－以高屏溪為例」，台灣水利，vol 39, no.3 pp33-44
4. 陳莉，張斐章，「巢狀超矩形學習模式於水資源系統之研究」，中國農業工程學報第 38 卷第三期，1992，9 月，pp.27-37
5. 王文清，林惠芬，張斐章，易任，「河川流量延伸方法之研究(一)---理論探討」，82 年度農業工程研討會論文集，pp.339-353
6. 林惠芬，王文清，張斐章，易任，「河川流量延伸方法之研究(二)---應用實例」，82 年度農業工程研討會論文集，pp.355-369
7. 林惠芬，「巢狀超矩形學習模式於河川流量推估之研究」，台灣大學農業工程學研究所碩士論文，1994，6 月
8. 水資會，「歷年來台灣乾旱研究」，1982,6 月
9. 財團法人農業工程研究中心，1993，「曾文水庫在緊急情況下運轉操作之探討研究，第三部份合理配水因應方案與應用歸線之分析」
10. Aha, D., and Kibler, D., 「Noise-Tolerant Instance-based learning algorithms」，Proceeding of the International Joint Conference on Artificial Intelligent, Mogn Kaufmann Publishers, 1989
11. Aha, D., 「Incremental, instance-based learning of independent and graded Concept descriptions」，Proceedings of the Sixth international workshop on Machine Learning, pp.387-391, 1989
12. Aha, D., Kibler, D., and Albert, M., 「Instance-based algorithms」，Machine Learning, 6, pp.37-36, 1991
13. Box, G. E. P. and G. M. Jenkins, 「Time Series analysis: Forecasting and Control」，Revised Ed., San Francisco, HoldenDay, 1976
14. Salas, J. D., Delleur, J. W., Yevjevich, V. and Lane, W. L., 「Applied Modeling of Hydrologic time series」
15. Kibler, D. and Aha, D., 「Learning representative exemplars of concepts; an initial case study」，Proceedings of the fourth International Workshop on Machine Learning, pp.24-30, 1987
16. McLeod, A. I. and K. W. Hipel, 「Simulation procedures for Box-Jenkins Models」，Water Resource. Res., 14(5), 969-975, 1978
17. Riggs, H. C., 「Low-flow investigations」，U. S. Geol. Surv. Tech. Water Resource. Invest., 4, 1972
18. Salzberg, S., 「Heuristic for introductory Learning」，Proceedings of IJCAI,85, Los Angeles, California, pp.603-610 1985
19. Salzberg, S., 「Exemplar-based Learning theory and implementation」 Technical Report TR-10-88, Center for Research in Computing Technology Harvard University, 1988
20. Salzberg, S., 「A Nearest Hyper-rectangle learning method」 Machine Learning, 6, PP. 251-276, 1991
21. Tao, P. O. and J. W. Delleur, 「Seasonal and nonseasonal ARMA models in hydrology」，J. Hydro. Div., ASCE, 102(HY10), 1541-1559, 1976
22. Medin, D. and Schaffer, M.. "Context Theory of Classification Learning",Psychological Review, 85(3), 1978

收稿日期：民國 86 年 3 月 20 日

接受日期：民國 86 年 7 月 9 日