

專 論

洪水水位之即時機率預報
—結合支撐向量機與模糊推理

**Real-time Probabilistic Flood Stage Forecasting
Using Support Vector Machines and Fuzzy Inference**

國立成功大學
水利及海洋工程學系
博士後研究員/兼任助理教授

陳 憲 宗

Shien-Tsung Chen

國立成功大學
水利及海洋工程學系
特聘教授/工學院副院長

游 保 杉*

Pao-Shan Yu

摘 要

本研究提出一套結合定值預報與誤差機率估算的方法，來實際進行洪水水位的即時機率預報。方法首先採用支撐向量機模式來建立定值水位預報模式，提供未來一至六小時的即時水位預報值，接著利用改良式模糊推理模式來推求預報誤差的機率分布函數，再結合定值水位預報值及預報誤差的機率分布函數，則可得到預報水位的機率分布函數。本機率預報方法以蘭陽溪的蘭陽大橋測站為案例，實際應用於未來一至六小時的即時洪水水位機率預報，經針對十二場驗證洪水事件的 95%信賴區間預報，以及針對預報水位超過警戒水位發生機率的探討，顯示本研究提出之機率預報方法具有良好的預報效能及實用性。

關鍵詞：洪水預報，機率預報，支撐向量機，模糊推理模式。

ABSTRACT

This study is to perform real-time probabilistic flood stage forecasting. The proposed method consists of a deterministic stage forecast derived from the support vector machines, and a probability distribution of forecast error based on the fuzzy inference model. The probabilistic flood stage forecasts can then be obtained by combining the deterministic stage forecasts with the error probability distributions. The proposed approach is applied to the Lang-Yang River in Taiwan pertaining to validation events of

*通訊作者，國立成功大學水利及海洋工程研究所教授，701 台南市東區大學路 1 號，yups@mail.ncku.edu.tw

six flash floods. The probability distributions of stage forecasts one to six hours ahead are made, and the predictive uncertainty information is presented and discussed in various aspects. Forecasting results examined by forecast hydrographs with a 95% confidence interval, and the percentages of data included in the confidence region, indicate the effectiveness of the proposed methodology.

Keywords: Flood forecasting, Probabilistic forecasting, Support vector regression, Fuzzy inference.

一、前言

1.1 研究背景與內容簡述

台灣每年夏秋期間，常遭遇颱風之降雨及暴雨侵襲，由於台灣地區之河川坡度陡峭，集水區對降雨—逕流過程的反應極為快速，急驟洪水(flash flood)常對於下游及低窪地區造成嚴重威脅。防洪預警系統為實用的非工程性洪災消滅措施之一，其核心模組為具有快速運算特性的水文水理預報模式，可在颱風及暴雨侵襲時，提前預報未來數小時的可能洪水量，以增加洪災應變時間，事先提供水庫防洪操作及下游低窪地區洪災預警之決策參考，可有效降低社會與民衆的生命財產損失。

洪水預報模式的預報對象常為洪水流量，再轉換為預報水位以提供決策者參考，而以洪水預報的觀點來說，採用洪水水位做為預報變量較流量更具實用性。在颱風及暴雨期間，實務單位採用河川水位做為預警之變量，而非流量，若能直接針對河川水位進行預報，則可免除流量與水位間的轉換手續及不確定性因素，因此本研究採用洪水水位做為預報變量。

洪水預報的型式可分為定率(deterministic)預報與機率(probabilistic)預報兩類；定率(定值)預報模式針對預報變量僅輸出單一定值的預報值，而機率預報模式則可針對預報變量輸出其機率分布函數(如圖 1)。目前洪水預報模式的相關研究多為定率性的預報模式，然而定值預報會傳達給決策者一種確定性的假象，可能因此導致較不適當的決策作為。基於工程實用之觀點，較為合適的做法是洪水預報模式除應提供定值預報

外，預報模式亦能提供機率預報值，並以合適的型式(例如：未來河川水位超越警戒水位之機率)傳達給決策者，讓使用者能將預報的風險納入決策或其他應用的考量，據以施行更合適的洪災防救措施。

機率預報必須要能夠考慮到預報模式的不確定性，即時預報模式的不確定性來源有許多，Krzysztofowicz (1999)指出即時預報模式的兩種不確定性來源為氣象(雨量)輸入及水文模式；而Todini (2004)則認為應該將雨量輸入的誤差區分為觀測誤差及預報誤差，因為觀測誤差之量度方法已經成熟可行，而預報誤差的評估仍然有待解決。然而無論誤差的來源如何考量，所有的誤差及不確定性將反應在模式的預報值上，亦即模式的預報誤差會包含所有的不確定性來源，因此本研究藉由分析定值水位預報的誤差序列數據來掌握模式預報的不確定性，據此估算預報誤差的機率分布。




圖 1 即時機率預報示意圖

本研究以蘭陽溪流域作為研究區域，採用支撐向量機來建立定率水位預報模式，即時預報未來一至六小時位於蘭陽大橋的定值洪水水位預報值，並採用 Chen & Yu (2007)提出的改良式模糊推理模式來建構預報誤差的機率分布函數，再結合定值水位預報值與預報誤差的機率分布，則可即時預報未來一至六小時的機率水位。

1.2 文獻回顧

1.2.1 機率預報

機率預報的方法有很多，本研究歸類下列四種較被廣為使用的方法：貝氏預報系統(Bayesian forecasting system)、卡門濾波(Kalman filter)、系集預報方法(ensemble method)及 generalized likelihood uncertainty estimation (GLUE)方法。

Krzysztofowicz 及其研究團隊採用貝氏預報系統進行一系列的機率預報研究，其代表性文章包括：Krzysztofowicz (1998, 1999, 2001, 2002)、Krzysztofowicz & Kelly (2000)以及 Krzysztofowicz & Maranzano (2004)等。卡門濾波亦為常用的流量機率預報的方法，相關研究有：Kitanidis & Bras (1980)、Szöllösi-Nagy & Mekis (1988)、Georgakakos & Smith (1990)、Lees *et al.* (1994)以及 Young (2002)等。系集預報方法是基於不確定性的架構原則，利用不同的模式或預報方法給予預報變量不同的可能預報值，做為不確定性的描述；使用系集預報方法來進行機率預報的相關研究有：Lardet & Obled (1994)、Koren *et al.* (1999)、Seo *et al.* (2000)、Georgakakos *et al.* (2004)、Gouweleeuw *et al.* (2005)等。Generalized likelihood uncertainty estimation (GLUE)方法為 Beven & Binley (1992)所提出，此方法認為不同的模式參數組合，可能會產生出同樣準確的預報值，因此可採用 Monte Carlo 模擬法隨機產生在合理範圍的參數值，利用此些參數進行大量預報值的計算，即可建立預報變量的不確定性；使用 GLUE 方法來進行水文機率預報的相關研究有：Freer *et al.* (1996)、Kuczera & Parent (1998)、Beven & Freer (2001)、Hossain & Anagnostou (2005)、Hunter *et al.* (2005)、Montanari (2005)、Pappenberger *et al.*

(2005)等。

1.2.2 支撐向量機

支撐向量機(support vector machines, SVMs)是由 Vapnik 及其共同研究者，基於統計學習理論(statistical learning theory)所提出的一類機器學習方法(Vapnik, 1995；1998)。支撐向量機起初應用於處理二元分類(binary classification)的問題上，後來漸漸應用於多類別分類，並延伸至迴歸問題。

支撐向量機於降雨-逕流模擬及洪水預報已有相關研究成果，例如：Sivapragasam *et al.* (2001)利用支撐向量機建立日雨量及日流量預報模式，進行前置時間一日的雨量及流量預報；Dibike *et al.* (2001)應用支撐向量機模擬降雨-逕流過程，並比較支撐向量機模式與類神經網路模式的預報結果，提出支撐向量機模式有優於類神經網路模式之處；Liong & Sivapragasam (2002)利用上游日水位資料做為支撐向量機的輸入變量，建立預報模式來預報下游水位；Choy & Chan (2003)利用支撐向量個數來決定幅狀基底函數類神經網路的架構，並用來模擬降雨-逕流的關係；Yu *et al.* (2004)結合支撐向量機模式與渾沌(Chaos)方法來預報日流量；Bray & Han (2004)應用支撐向量機預報逕流量，並著重於模式架構及參數選擇的探討；Sivapragasam & Liong (2005)將流量依大小分為三類，再分別建立 SVM 模式進行一日與三日之流量預報；張逸凡(2005)、Yu *et al.* (2006)及陳憲宗等人(2006)採用支撐向量機建立蘭陽溪水位預報模式，即時預報蘭陽大橋未來一至六小時的洪水水位。

1.2.3 模糊推理模式

模糊推理模式又稱為模糊規則模式，該模式主要為依據在規則庫中的模糊規則進行模糊推理，期能類比於專家的決策。模糊推理模式在水利工程領域已有廣泛的應用，在水文模擬與預報方面，模糊推理模式曾被應用於河川流量預報(See & Openshaw, 2000; Abrahart & See, 2002; Bazartseren *et al.*, 2003)、降雨-逕流模擬與預報(Hundecha *et al.*, 2001; Xiong *et al.*, 2001, Chang *et al.*, 2002)、河川流量資料補遺(Chang *et al.*,

2001)、季流量預報(Mahabir *et al.*, 2003)、洪水預報之即時更新(Yu & Chen, 2005)等。

二、模式理論

2.1 機率預報

本研究的機率預報方法為利用定值水位預報的誤差序列來估算預報值的不確定性，並建立預報誤差的機率分布，再結合定值水位預報值，即可得到水位預報值的機率分布；類似方法曾有 Montanari & Brath (2004)與 Tamea *et al.* (2005)採用過，理論方法詳述如下。

考慮 t 時刻有一水位觀測值 S_t ，此水位可表示成

$$S_t = \hat{S}_t + e_t \quad \dots\dots\dots(1)$$

其中， $\hat{S}_t$ 為水位預報模式 $f(\mathbf{X}_t)$ 輸出之定率水位預報值， e_t 為 t 時刻的預報誤差，此預報誤差之來源包含模式的不確定性 $f(\cdot)$ 及輸入資料向量 $\mathbf{X}_t$ 。

本機率預報方法的基本精神在於以單一的定率預報值 $\hat{S}_t$ 為基礎，加上許多估算的預報誤差值 e_t ，即可得到許多水位預報值。這些水位預報值與實際水位存在預報誤差 $e_t = S_t - \hat{S}_t$ ，假設觀測值 S_t 之不確定性極小，可予以忽略，則水位預報值之變異數將會與誤差之變異數相等，即預報誤差之不確定性將可用來代表水位預報值的不確定性。

$$\sigma^2[\hat{S}_t] = \sigma^2[e_t] \quad \dots\dots\dots(2)$$

此機率預報方法能考慮到預報模式的所有不確定性來源，其需以模式模擬階段的誤差做為資料庫，此資料庫可視為模式在某些輸入條件下的誤差樣本。在水位預報模式 $f(\cdot)$ 及輸入資料 $\mathbf{X}_t$ 的條件下，令預報誤差的機率分布函數為 Π_{error} ，則機率分布函數可表示成如下式之條件機率型式。

$$\Pi_{error} = P(e_t | f(\mathbf{X}_t)) \quad \dots\dots\dots(3)$$

當預報誤差的機率分布函數 Π_{error} 建立之後，水位預報值之機率分布可藉由結合定率水位預報值及誤差的機率分布而得，表示如(4)式。

$$\Pi_{stage} = \hat{S}_t + \Pi_{error} \quad \dots\dots\dots(4)$$

其中， Π_{stage} 代表水位的機率分布函數。當水位的機率分布函數建立後，預報水位超過某特定水位之超越機率亦可指定。在前置時間 l 小時的預報狀況下，其超越機率 $\Pi_{t+l}(h)$ 可表示為

$$\Pi_{t+l}(h) = P(H_{t+l} > h) \quad \dots\dots\dots(5)$$

其中， H_{t+l} 表示在 $t+l$ 時刻的水位變量， $P(H_{t+l} > h)$ 為水位 H_{t+l} 超過某特定水位 h 之機率。由於水位預報是在具備輸入變量 $\mathbf{X}_t$ 及預報模式 $f(\cdot)$ 的條件下推求得到，故可將(5)式表示成條件機率之型式。

$$\Pi_{t+l}(h) = P(H_{t+l} > h | f(\mathbf{X}_t)) \quad \dots\dots\dots(6)$$

在本研究中，預報模式 $f(\cdot)$ 本身及模式參數均為固定，也就是說在不同的時間點進行預報，每次均使用相同的模式架構，故上式之條件機率可視為僅為輸入變量 $\mathbf{X}_t$ 的條件機率。

$$\Pi_{t+l}(h) = P(H_{t+l} > h | \mathbf{X}_t) \quad \dots\dots\dots(7)$$

在機率分布函數 $\Pi_{t+l}(h)$ 建立後，針對某前置時間的特定預報值 $\hat{S}_{t+l}$ ，亦可指定出其超越機率。

$$\Pi_{t+l}(h) = P(\hat{S}_{t+l} > h | \mathbf{X}_t) \quad \dots\dots\dots(8)$$

2.2 支撐向量機

支撐向量機(Vapnik, 1995; 1998)為近年來資訊電子領域新興的機器學習方法，目前在許多領域已有蓬勃的發展與應用，支撐向量機依其應用方法可分為支撐向量分類(support vector classification, SVC)與支撐向量迴歸(support vector regression, SVR)二類，本研究採用支撐向量迴歸模式建立定值水位預報模式，故以下針對支撐向量迴歸之理論進行介紹。

假設一組訓練資料為 $[(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_l, y_l)]$ ，其中 $\mathbf{x}_i$ 為迴歸函數的輸入向量， y_i 為迴歸函數的輸出值，則可將支撐向量迴歸的函數表示為(9)式，其意義為將輸入向量 $\mathbf{x}$ 透過非線性函數 $\Phi(\mathbf{x})$ 的映射後，建立一最佳的迴歸函數來擬合輸入與輸出資料的特性，而此迴歸模式具有一誤差容忍區域。

$$f(\mathbf{x}) = \mathbf{w}^T \cdot \Phi(\mathbf{x}) + b \quad \dots\dots\dots (9)$$

式中， $\mathbf{w}$ 與 b 為迴歸模式的參數。關於誤差容忍

區域及誤差所產生的損失量(loss)，採用損失函數 L_ε (Vapnik's ε -insensitive loss function)來定義，如(10)式。

$$L_\varepsilon(y_i) = \begin{cases} 0 & \text{for } |y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b]| < \varepsilon \\ |y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b]| - \varepsilon, & \text{for } |y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b]| \geq \varepsilon \end{cases} \quad \dots\dots\dots (10)$$

由(10)式可知，若資料點落於容忍區間 ε 之內，即 $|y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b]| < \varepsilon$ ，則損失函數為零；而若資料點落於容忍區間 ε 之外，則有損失產生，損失函數值為 $|y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b]| - \varepsilon$ ；亦即只有當資料點落於容忍誤差範圍外才給予懲罰。因此，支撐向量迴歸相較於傳統的迴歸方法，主要差別在於支撐向量迴歸有誤差容忍範圍的機制，而傳統的迴歸方法則無；關於支撐向量迴歸的作用機制，可參考圖 2。

依據支撐向量機理論，支撐向量迴歸問題可以表示成數學規劃問題來求解：

$$\begin{aligned} \min_{\mathbf{w}, b, \xi, \xi^*} \quad & \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{subject to} \quad & y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b] \leq \varepsilon + \xi_i \quad \dots\dots (11) \\ & [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b] - y_i \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, l \end{aligned}$$

其中， ξ_i 與 ξ_i^* 為沉滯變數(slack variables)，分別代表資料點落於容忍區間上方及下方的誤差值(參考圖 2)，成本參數 C 為衡量此些誤差值之懲

罰權重。為方便求解上述問題，可引入 Lagrange 參數 α_i 與 α_i^* ，將上式轉換為 Lagrangian 問題，並再轉換成二次規劃(quadratic programming)問題來求解：

$$\begin{aligned} \max_{\alpha, \alpha^*} \quad & \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) \\ & - \frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \Phi(\mathbf{x}_i)^T \cdot \Phi(\mathbf{x}_j) \\ \text{subject to} \quad & \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \\ & 0 \leq \alpha_i \leq C \\ & 0 \leq \alpha_i^* \leq C, \quad i = 1, 2, \dots, l \end{aligned} \quad \dots\dots\dots (12)$$

求解二次規劃問題即可得 α_i 與 α_i^* ，再利用 Karush-Kuhn-Tucker conditions (Fletcher, 1987)，則可藉由 α_i 與 α_i^* 來求得 $\mathbf{w}$ 及 b ，如式(13)及式(14)。

$$\mathbf{w} = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \cdot \Phi(\mathbf{x}_i) \quad \dots\dots\dots (13)$$

$$\alpha_i (\mathbf{w} \cdot \Phi(\mathbf{x}_i) + b - y_i + \varepsilon + \xi_i) = 0 \quad \dots\dots\dots (14)$$

因此支撐向量迴歸模式可表示為

$$f(\mathbf{x}) = \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) \Phi(\mathbf{x}_i)^T \cdot \Phi(\mathbf{x}_j) + b \quad \dots\dots (15)$$

在(15)式中，每一組 $(\alpha_i - \alpha_i^*)$ 對應至某一筆訓練資料 $(\mathbf{x}_i, y_i)$ ，故 $(\alpha_i - \alpha_i^*)$ 為零所對應的資料點實際上並未參與迴歸模式的建立，非零的 $(\alpha_i - \alpha_i^*)$ 則表示該筆資料有用來參與建立迴歸函數，故稱其為「支撐向量」(support vector)。簡言之，支撐向量即是指這些用來支持(support)模




圖 2 支撐向量迴歸模式

式建立所使用的資料，此為「支撐向量機」名稱的由來。經由結果檢視可發現， $(\alpha_i - \alpha_i^*)$ 為零的資料點均落於誤差容忍區間內，而非零的 $(\alpha_i - \alpha_i^*)$ 所對應的資料點，則符合 $|y_i - [\mathbf{w}^T \cdot \Phi(\mathbf{x}_i) + b]| \geq \varepsilon$ 條件，故可參照圖 2 得知，支撐向量為落於誤差容忍區間的邊界上或外面的資料點。

如(12)式及(15)式所示，最後真正會影響支撐向量迴歸模式者為 $\Phi(\mathbf{x}_i)^T \cdot \Phi(\mathbf{x}_j)$ 的向量內積，而非個別的 $\Phi(\mathbf{x}_i)$ 或 $\Phi(\mathbf{x}_j)$ ，因此我們可以引入核函數(kernel function)的技巧來簡化問題，避免兩非線性函數內積運算可能導致的尺度問題(curse of dimensionality)，核函數 $K(\mathbf{x}_i, \mathbf{x}_j)$ 表示為

$$K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i)^T \cdot \Phi(\mathbf{x}_j) \dots\dots\dots (16)$$

若某函數滿足 Mercer's condition (Vapnik, 1999)，則此函數可用來當作核函數。本研究所採用之核函數為輻狀基底函數(radial basis function)，其具有一參數 γ 。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2\right) \dots\dots\dots (17)$$

最後可將支撐向量迴歸函數表示為

$$f(\mathbf{x}) = \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}_j) + b \dots\dots\dots (18)$$

影響支撐向量迴歸模式之參數為誤差容忍區間寬度 ε 、成本參數 C 及核函數之參數 γ ，上述三個參數值即為支撐向量迴歸模式的待定參數，本研究採用兩階段格網搜尋法(Hsu et al., 2003；陳憲宗等人，2006)來優選參數。

2.3 模糊推理模式

模糊推理模式為針對特定的知識領域建立模仿專家推理過程的系統，一般的做法是依據已知的模糊條件語句來進行推理。模糊推理模式的構成要件包含：模糊化介面、模糊規則庫、推理引擎、解模糊化介面等四項模組(如圖 3)，各部份說明簡述如下：




圖 3 模糊推理模式

2.3.1 模糊化模組

模糊推理所要求的輸入是模糊集合，由於在實際處理的問題中，模式的輸入變量值常是明確的數值(crisp value)而不是模糊集合，因此需要將確切的數字值轉換為模糊集合，此步驟稱為模糊化。模糊化需透過模糊隸屬函數的定義，一般來說，模糊隸屬函數的訂定常包含主觀的意識，使用者需針對問題選用或訂定合適的隸屬函數。

2.3.2 模糊規則庫

模糊規則庫中存放模糊控制規則(模糊條件語句)，規則一般可經由專家意見或使用者的經驗制訂，模糊規則亦可經由學習方法修改既有規則來重新佈置規則資料庫。模糊規則為利用「IF-THEN」陳述句來建立輸入變量與輸出變量之間的關係，「IF」所陳述的部分稱為前提(premise)，「THEN」所陳述的部分稱為結論(conclusion)，模糊規則的通式可以表示為

$$\begin{aligned} &\text{IF } (x_1 \text{ is } A_1) \text{ AND } (x_2 \text{ is } A_2) \dots \text{ AND } (x_m \text{ is } A_m) \\ &\text{THEN } (y_1 \text{ is } B_1) \text{ AND } (y_2 \text{ is } B_2) \dots \text{ AND } (y_n \text{ is } B_n) \\ &\dots\dots\dots (19) \end{aligned}$$

式中， $x_1, x_2, \dots, x_m$ 為輸入變量， $y_1, y_2, \dots, y_n$ 為輸出變量， $A_1, A_2, \dots, A_m$ 及 $B_1, B_2, \dots, B_n$ 為透過模糊隸屬函數定義之模糊集合。

模糊規則可分成語意式的條件規則及函數式的條件規則，語意式的規則例如「IF the rainfall is heavy, THEN the water level is high」，函數式的規則例如「IF the rainfall is 8.2 millimeters, THEN the water level is 2.4 meters」；若模糊規則的前提部分具備某隸屬度的符合程度時，則結論

部分亦具備此隸屬度的滿足程度。

2.3.3 模糊推理引擎

推理引擎為模糊推理過程的核心運行機制，其推理過程的步驟可分為模糊蘊涵(implication)及模糊合成(aggregation)兩部分(參考圖 4)，方法敘述如下。

(1) 模糊蘊涵

模糊蘊涵是針對某一模糊規則，以模糊數學計算各輸入變量所對應的隸屬度，得到單一個代表性隸屬度，此代表性隸屬度可稱為啟發強度(firing strength)，再依啟發強度來決定輸出變量的模糊子集合。常用的模糊蘊涵方法有 Mamdani 最小化運算規則及 Larsen 乘積運算規則(Lee, 1990)。以圖 4 為例，在第一個規則中，兩個輸入變量經模糊隸屬函數的比對後，分別得到隸屬度 μ_1 與 μ_2 ，運用 Mamdani 最小化運算，則得到代表性隸屬度 μ_1 ，依 μ_1 的強度來將輸出變量的模糊隸屬函數進行截短，則可得到圖 4 中第一個規則的輸出模糊子集。模糊蘊涵針對資料庫中的各個模糊規則均進行一次此運算步驟，如圖 4 中第二個規則亦有其相對應的輸出模糊子集。

(2) 模糊合成

模糊合成是將模糊蘊涵運算所得的所有輸出模糊子集整合成單一個模糊集合，模糊合成針對一個輸出變量進行一次運算。以圖 4 為例，利用模糊最大化運算(fuzzy maximum operation)結合二個規則所對應的模糊子集，可得到輸出變量的模糊合成集合。

2.3.4 解模糊化模組

經由模糊推理步驟所得到的輸出變量是以模糊集合的型式來表現，一般為能將模糊推理應用在實際問題上，需將此模糊集合利用解模糊化步驟推求輸出變量之明確值。解模糊化方法甚多，最常使用的為形心法(如圖 4)，即是求取模糊隸屬函數所包含面積的形心，再以形心位置所對應的明確值當做輸出變量。

$$y^* = \frac{\sum_{i=1}^n y_i \cdot \mu_i}{\sum_{i=1}^n \mu_i} \quad \dots\dots\dots (20)$$




圖 4 模糊推理運算機制－模糊蘊涵及模糊合成

其中， y^* 為解模糊化後之明確值， μ_i 為第 i 條規則中輸出變量 y_i 的代表性隸屬度(即啟發強度)，而 n 為模糊規則數目。

2.4 機率函數型式之解模糊化方法

由於模糊推理模式的明確輸出值為自模糊合成集合中解模糊化而得，此明確輸出值可視為模糊合成集合中所有輸出變量數據的代表值，解模糊化過程即是依照啟發強度的大小，從這些輸出變量數據中選出或計算出明確輸出值，如(20)式。因此，這些啟發強度可視為某輸出變量數值成為明確輸出值的發生可能性，由此觀點可利用模糊合成集合來建構輸出變量的機率分布函數。本研究採用 BADD 轉換法(basic defuzzification distributions transformation)，配合重點抽樣法(importance sampling)來建構水位誤差的機率分布函數，方法分別敘述如下。

2.4.1 BADD 轉換法

BADD 轉換法為 Filev & Yager (1991)所提出，本方法的基本觀念是在滿足 Klir's principle of uncertainty and information invariance (Klir, 1990) 的條件下，將模糊集合的可能性分布(possibility distribution) (Zadeh, 1978)轉換成機率分布。

設 y^* 為解模糊化後之明確值， n 為模糊規則數目，則解模糊化方法的通式可表示為




圖 5 模糊合成集合解模糊化成為機率函數示意圖

$$y^* = \sum_{i=1}^n y_i \cdot q_i \quad \dots\dots\dots(21)$$

其中 q_i 為第 i 條規則中的輸出變量 y_i 的權重，不同的解模糊化方法即是表示不同的 q_i 估算方式。例如以形心法來說， q_i 即為

$$q_i = \frac{\mu_i}{\sum_{i=1}^n \mu_i} \quad \dots\dots\dots(22)$$

如此，可知 q_i 具有下列二項機率分布的特性：

$$q_i \in [0, 1] \quad \dots\dots\dots(23)$$

$$\sum_{i=1}^n q_i = 1 \quad \dots\dots\dots(24)$$

由上述可知，解模糊化方法可視為先將模糊合成集合轉換成機率分布，再針對此機率分布求取期望值，此期望值即為欲求得之明確輸出值。Filev & Yager (1991)定義 BADD 轉換法並推導得到

$$q_i = \frac{\mu_i^\alpha}{\sum_{i=1}^n \mu_i^\alpha} \quad \dots\dots\dots(25)$$

其中， α 為模式參數，且 $\alpha \in [0, \infty]$ 。不同的解模糊化方法，可以(21)及(25)式來轉換表示，而若 $\alpha = 1$ ，則此即為形心法。

2.4.2 重點抽樣法

重點抽樣可根據某特定權重分布進行資料的隨機抽樣，其主要觀念在於某些資料可能較其他資料重要，則這些較重要的資料在抽樣過程中具有較大的機會被抽中。資料的重要性可由權重函數 $w(y)$ 來指定，如(26)式。




圖 6 蘭陽溪流域

$$\int w(y)dy = 1 \quad \dots\dots\dots(26)$$

本研究利用 BADD 轉換法所得到的機率分布函數是由模糊合成集合轉換而來，所以曲線可能較不平滑，本研究結合 BADD 轉換法與重點抽樣法，以得到的較平滑的機率分布函數。

由於各個輸出變量數值的啟動強度即代表該數據在模糊合成集合的權重，亦即表示其可能被選中出現在明確輸出值的可能性，因此本研究的權重函數為利用(22)式來定義，此即代表本研究之 BADD 轉換法中的參數 α 值為 1。圖 5 為本研究結合 BADD 轉換法與重點抽樣法，將模糊合成集合解模糊化成為機率函數之示意圖。

三、研究區域與水文資料概述

蘭陽溪流域(圖 6)位於台灣東北部，主流長度 73 公里，蘭陽溪於蘭陽大橋附近有支流羅東溪匯入，並於噶瑪蘭大橋附近匯合宜蘭河及冬山河，流域集水面積共 978 平方公里，計畫洪水量 8,500 秒立方公尺。

本研究以蘭陽溪下游的蘭陽大橋站為對象，即時預報蘭陽大橋一至六小時的機率水位，經蒐集現有水文測站資料及整體考量相關測站及水系位置，本研究選用的水位站為牛門及蘭陽大橋二站，雨量站為涵蓋兩水位站中間流域的雨

表 1 研究洪水事件

事件編號	發生日期	降雨類型	資料延時(hr)	牛門尖峰水位(m)	蘭陽大橋尖峰水位(m)	備註
1	1990/06/22	歐菲莉颱風	62	210.75	3.61	率定
2	1991/09/15	耐特颱風	111	212.78	3.54	率定
3	1996/07/30	賀伯颱風	63	212.52	5.47	率定
4	1996/10/09	暴雨	55	210.30	2.98	率定
5	1996/10/12	暴雨	49	210.60	3.07	率定
6	1997/08/28	安珀颱風	68	212.00	5.41	驗證
7	2000/06/12	暴雨	107	209.19	1.86	率定
8	2000/06/16	暴雨	133	209.39	2.30	率定
9	2000/07/08	啓德颱風	52	209.52	2.78	率定
10	2000/07/16	暴雨	23	208.99	1.77	率定
11	2000/07/18	暴雨	24	209.14	1.94	率定
12	2000/07/19	暴雨	34	209.13	1.97	率定
13	2000/08/01	暴雨	118	208.72	1.57	率定
14	2000/08/11	暴雨	73	208.85	1.64	率定
15	2001/05/11	西馬隆颱風	139	209.35	3.03	驗證
16	2001/05/27	暴雨	115	209.01	3.01	驗證
17	2001/06/07	暴雨	45	208.73	2.40	驗證
18	2003/06/06	南卡颱風	82	207.97	2.60	驗證
19	2003/06/16	蘇迪勒颱風	111	208.23	2.66	驗證
20	2004/06/30	敏督利颱風	178	209.35	2.87	驗證
21	2004/08/23	艾利颱風	67	211.47	5.75	驗證
22	2004/10/24	納坦颱風	48	211.08	5.97	驗證
23	2004/12/03	南瑪都颱風	74	210.56	5.63	驗證
24	2005/07/17	海棠颱風	149	210.87	7.24	驗證
25	2005/08/31	泰利颱風	74	211.54	6.70	驗證

量站共十站，並以徐昇網法估算兩水位站中間流域的平均雨量。研究事件的選取方面，本研究整理牛門及蘭陽大橋同時具有時水位之紀錄，並比對各雨量站具有較完整時雨量的期間，彙整出二十五場降雨事件供研究使用，年限自1990年至2005年(蒐集之洪水事件如表1所列)，其中十三場事件用來率定模式，其餘十二場則用來驗證；事件之編號依其發生日期之順序分別給予。

四、即時水位預報

4.1 定值水位預報模式

4.1.1 模式建構與參數率定

影響蘭陽大橋水位的因素，包含上游牛門站水位及牛門至蘭陽大橋間的雨量，且由於水位資料為一連續的時序列，故亦應考慮蘭陽大橋前時

刻水位的影響；由上述影響蘭陽大橋水位的因素來決定模式之輸入變量，則水位預報模式可表示如下：

$$S_L = f_{SVR}(S_L, R, S_N) \dots\dots\dots (27)$$

式中， f_{SVR} 代表支撐向量迴歸水位預報模式， S_L 為蘭陽大橋水位， R 為牛門至蘭陽大橋間之雨量， S_N 為牛門水位。

在確定模式變量後，接著需要決定各變量之階數，相較於一般支撐向量機模式常由試誤法決定模式變量的階數，本研究採用水文反應時間的觀念來決定變量階數(Yu *et al.*, 2006)。牛門水位變量 S_N 階數之決定，藉由相關係數法及特徵水位法來決定傳播時間，整體平均傳播時間為 3.32 小時，故取 S_N 之階數為 3；對於雨量變量 R 而言，

則求取降雨組體圖之重心與水位歷線之尖峰水位的時間差，用來代表蘭陽大橋水位 S_L 對於雨量 R 的反應時間，其平均稽延時間為 5.28 小時，故取 R 之階數為 5；對於輸入變量 S_L 而言，因其亦為輸出變量，不宜以上述反應時間之概念決定其變量階數，故本研究採自迴歸模式來決定變量 S_L 之階數，得到變量 S_L 其階數為 3。綜上所述，可將模式變量及其階數表示如(4-15)式。

$$S_L(t+1)=f_{SVR}[S_L(t+1-m_L), R(t+1-m_R), S_N(t+1-m_N)] \quad \dots\dots\dots(28)$$

式中 $m_L = 1, 2, 3$ ； $m_R = 1, 2, 3, 4, 5$ ， $m_N = 1, 2, 3$ ， t 代表時間。在目前 t 時刻，模式具有輸入變量之觀測值序列 $[S_L(t+1-m_L), R(t+1-m_R), S_N(t+1-m_N)]$ ，可用來預報 $t+1$ 時刻之輸出變量 $S_L(t+1)$ 。

支撐向量迴歸水位預報模式共有三參數需要決定，即成本參數 C 、誤差範圍 ε 與核函數參數 γ 。本研究採用 Hsu *et al.* (2003)建議的兩階段格網搜尋法來優選參數，即首先對三參數進行較粗略的搜尋，可得參數之較佳區域，再對此區域進行較細微的搜尋以得到最佳參數。本研究使用 *LIBSVM* (Chang & Lin, 2001)來進行參數率定與支撐向量迴歸模式的計算，而此模式建議將輸入資料標準化於 0 至 1 區間，因此本研究所輸入模式之水位及雨量資料，均先標準化成 0 至 1 的資料，再將模式輸出值換算成實際水位。模式率定時採用均方根誤差(RMSE)為目標函數，其最佳參數 $(C, \varepsilon, \gamma) = (26.9, 0.004, 0.105)$ ，均方根誤差為 0.035 公尺，而支撐向量個數約佔整體資料之 52.2%。

本研究將(28)式的支撐向量迴歸水位預報模式，以遞迴形式來建立可動態預報未來一至六小時的水位預報模式，如(29)式。

$$S_L(t+l)=f_{SVR}[S_L(t+l-m_L), R(t+l-m_R), S_N(t+l-m_N)] \quad \dots\dots\dots(29)$$

式中， $m_L = 1, 2, 3$ ； $m_R = 1, 2, 3, 4, 5$ ， $m_N = 1, 2, 3$ ，而 l 為預報前置時間(lead time)。在前置時間二小時以上的預報，需要用到輸入變量於未來時刻的數據作為模式輸入。蘭陽大橋未來時刻的水位可直接以水位模式的預報值遞迴帶入模式，雨量於

未來時刻的數值，本研究採用灰色雨量預報模式(陳憲宗，1998)來協助推求；而牛鬥站水位，本研究採取 Naïve 預報方法，其為一簡單但具指標性之預報方法；Naïve 模式直接以目前觀測值當作未來時刻之預報值，即前置時間 l 小時的預報值等於現在時刻的觀測值。

4.1.2 定值水位預報結果

為驗證模式之即時水位預報效能，針對十二場驗證事件分別採用支撐向量迴歸水位預報模式進行前置時間一至六小時的水位預報，部分場次之歷線如圖 7 與圖 8 所示；預報結果之均方根誤差(RMSE)及基準效率係數(CE_b) (Seibert, 2001)列於表 2， CE_b 之估算方法如下式：

$$CE_b = 1 - \frac{\sum_{t=1}^n (S_t - \hat{S}_t)^2}{\sum_{t=1}^n (S_t - \hat{S}'_t)^2} \quad \dots\dots\dots(30)$$

其中， S_t 為 t 時刻實測水位， $\hat{S}_t$ 為 t 時刻預報水位， $\hat{S}'_t$ 為參考基準模式之預測水位，本研究採用 Naïve 預報模式，故 CE_b 為本預報模式與 Naïve 模式預報效能之評比， CE_b 為正值表示本模式預報效能優於 Naïve 模式；若為零，表示本模式與 Naïve 模式相當；倘若為負值，則表示本模式預報效能較 Naïve 模式差。

由圖 7 與圖 8 之預報水位歷線可知，一至三小時的預報水位歷線與觀測水位歷線極為符合，而在較長前置時間的預報(如圖 8 的五、六小時)，則有較大的偏差，但整體而言，預報水位與實測水位的變化趨勢相當一致。就評鑑指標 RMSE 而言，模式於較短前置時間(一至三小時)的預報相當良好，整體的預報誤差小於 20 公分，在較長前置時間(四至六小時)的預報，整體誤差也小於 40 公分，顯示此定值水位預報模式的良好能力。就 CE_b 來看，本模式明顯優於 Naïve 預報方法，其中模式在前置時間三小時左右預報能力優於 Naïve 預報的程度，高於較短及較長前置時間的預報能力，但差異不並顯著。另外，可由預報結果得知，在較短前置時間(一至三小時)之預報，尖峰水位僅存在些微相位移(phase lag)之




圖 7 定值水位預報歷線及殘差圖(事件 15)




圖 8 定值水位預報歷線及殘差圖(事件 18)

表 2 定值水位預報結果

前置時間(hr)	RMSE (m)	CE _b
1	0.10	0.14
2	0.15	0.46
3	0.19	0.55
4	0.26	0.50
5	0.33	0.46
6	0.39	0.41

現象；而在六小時的預報，尖峰水位的平均相位移僅為三小時，明顯優於一般預報模式。整體而言，綜合預報歷線圖形與評鑑指標來看，支撐向量迴歸水位預報模式具有良好的即時水位預報能力。

4.2 機率水位預報模式

4.2.1 預報誤差之機率分布估算

機率水位預報模式之建立，以定值水位預報的結果為基礎，應用模糊推理方法來推求誤差之機率分布函數。關於模糊推理所採用的輸入及輸出資料，乃針對標準化的資料予以進行；資料庫中模糊規則的訂定，則依據定值水位預報模式針對率定事件的預報結果(標準化後之資料)來建立。首先，需定義輸入變量的模糊隸屬函數，本研究採用高斯函數型式的隸屬函數：

$$\mu(x) = \exp\left(\frac{-(x-m)^2}{2\sigma^2}\right) \dots\dots\dots(31)$$

其中， σ 為高斯函數的形狀參數，代表函數的展開幅度大小； m 為歷史資料庫中的變量數據，此隸屬函數即是定義輸入變量 x 與 m 的相似程度，此相似程度可藉由兩數據的距離 $(x-m)$ 來判定。若 x 很靠近 m 時，隸屬度 $\mu(x)$ 將接近 1.0；若 x 遠離 m 時，隸屬度 $\mu(x)$ 將以指數速率消減至 0。選用高斯函數做為模糊隸屬函數的優點為：高斯函數較常用的三角形隸屬函數具有較佳的數據區別特性。高斯函數的參數 σ 之選定，本研究根據變量數據的統計特性，直接採用標準化後資料的標準偏差來定義，可得參數 $S_N(t)$ 、 $S_L(t)$ 與 $R(t)$ 的隸屬函數參數分別為 0.20、0.16 與 0.13。

接著需要陳述模糊規則。由第 2.1 節的機率預報方法可知，預報誤差的發生是基於模式及其輸入值的條件，因此預報誤差的機率為模式及其輸入變量的條件機率，由於模式為單一模式且預報過程中並未有更新，因此模糊推理模式的輸入變量僅需考慮水位預報模式的輸入向量，即 $S_L(t)$ 、 $S_L(t-1)$ 、 $S_L(t-2)$ 、 $R(t)$ 、 $R(t-1)$ 、 $R(t-2)$ 、 $R(t-3)$ 、 $R(t-4)$ 、 $S_N(t)$ 、 $S_N(t-1)$ 與 $S_N(t-2)$ 。然而若在模糊規則的前提部分考慮過多的變量，則可能造成規則比對上的困難，相似的資料型態無法合理的選出，因此本研究簡化模糊規則的前提部分，僅採用最接近的三個輸入變量 $S_L(t)$ 、 $R(t)$ 與 $S_N(t)$ 來建立模糊規則。而輸出變量的選定，依研究目的則為一至六小時預報的誤差，故模糊規則可陳述為

$$\begin{aligned} &\text{IF } (S_L(t) \text{ is } F_{SL}) \text{ AND } (R(t) \text{ is } F_R) \text{ AND} \\ &(S_N(t) \text{ is } F_{SN}) \\ &\text{THEN } (e(t+1) \text{ is } F_{E1}) \text{ AND } (e(t+2) \text{ is } F_{E2}) \\ &\text{AND } (e(t+3) \text{ is } F_{E3}) \text{ AND } (e(t+4) \text{ is } F_{E4}) \\ &\text{AND } (e(t+5) \text{ is } F_{E5}) \text{ AND } (e(t+6) \text{ is } F_{E6}) \\ &\dots\dots\dots(32) \end{aligned}$$

其中， F_{SL} 、 F_R 與 F_{SN} 分別代表變量 $S_L(t)$ 、 $R(t)$ 與 $S_N(t)$ 的數據資料透過隸屬函數所定義的模糊集合； $e(t+1)$ 、 $e(t+2)$ 、 $e(t+3)$ 、 $e(t+4)$ 、 $e(t+5)$ 與 $e(t+6)$ 分別為一至六小時的預報誤差； F_{E1} 、 F_{E2} 、 F_{E3} 、 F_{E4} 、 F_{E5} 與 F_{E6} 則為經由模擬誤差透過隸屬函數所定義的模糊集合。

本研究直接以水位預報模式模擬期間的資料做為羅列數值式模糊規則的依據，而未採用語意式模糊規則，此方式可避免模糊語意變量定義的困擾，並可減少模糊推論過程的主觀性。

當 t 時刻的水位及雨量變量 $S_L(t)$ 、 $R(t)$ 與 $S_N(t)$ 已知時，預報誤差 $e(t+1)$ 、 $e(t+2)$ 、 $e(t+3)$ 、 $e(t+4)$ 、 $e(t+5)$ 與 $e(t+6)$ 可由模糊蘊涵及模糊合成的過程來推求。模糊蘊涵首先針對三個輸入變量的資料與規則庫的模糊規則進行一一比對，針對某個規則可得到三個隸屬度 (μ_1, μ_2, μ_3) ，則針對此規則的啟動強度為 $\mu = \min(\mu_1, \mu_2, \mu_3)$ ；接著以模糊聯集運算將每個規則的輸出變量值及啟動強度組合成為模糊合成集合。




圖 9 預報水位之機率分布

接下來引入解模糊化方法，本研究以 BADD 轉換法將模糊合成集合解模糊化為機率分布函數，再以重點抽樣法針對模糊合成集合的可能性分布函數(possibility distribution)進行重複取樣，每個輸出變量抽樣個數為 10,000 筆，然後再以 Weibull-Gumbel 點繪公式指定其超越機率，則可得到每個時間點各預報誤差 $e(t+1)$ 、 $e(t+2)$ 、 $e(t+3)$ 、 $e(t+4)$ 、 $e(t+5)$ 與 $e(t+6)$ 的機率。

4.2.2 機率預報結果與實案討論

接著將此機率預報方法實際應用於十二場驗證洪水事件，進行前置時間一至六小時的逐時刻機率水位預報。在每個時間點，機率預報模式可指定未來一至六小時各可能發生水位的超越機率值；以第 22 場次於第 30 小時的預報為例，將這些水位預報值及其超越機率值繪於圖 9，則可得到預報水位的機率分布函數曲線。由圖 9 中一至六小時的預報水位機率分布可知，隨著預報時間的加長，可能發生的水位範圍也加大，此機率分布可指定未來某洪水水位值的超越機率，以蘭陽大橋的三級警戒水位(5.8 公尺)為例，在一小時的預報結果中，水位會超過 5.8 公尺的機率為 0.0%，而在六小時的預報結果中，水位會超過 5.8




圖 10 水位機率預報結果

公尺的機率為 33.8%，此些資訊可構成未來水位會超越某警戒水位的時間機率分布，例如超越蘭陽大橋三級警戒水位的時間機率分布為[0.00%, 0.00%, 0.52%, 5.64%, 11.19%, 33.84%]。

圖 10 係與圖 9 相同案例之水位機率預報結果，在圖 10 中的灰色區域代表預報水位的 95% 信賴區間，實心黑點與中空三角形分別代表實際




圖 11 預報誤差的 95%信賴區間

水位值及定率預報水位值。由圖上可看出，定率水位預報值並未能完美符合實測水位值，然而 95%信賴區間的預報水位可合理涵蓋實測水位值。在圖 10 中，實測水位在前置時間四小時超越三級警戒水位(5.8 公尺)，但定率水位預報值在前置時間六小時才超越三級警戒水位；而機率預報則可以估算未來每個時刻超越三級警戒水位的機率，例如在前置時間四小時超越三級警戒水位之機率為 5.64%，雖然此非為準確之機率預報值，但機率預報仍可提醒使用者未來洪水有可能會超過警戒水位。倘使決策者僅依據定率水位預報的結果來協助決策，則可能會因為定率水位預報值的低估而未採取應變措施或採取較不合宜的措施；然若決策者能參考機率預報的結果，因為已將風險因素納入考慮，則決策者會因此實施較合適的應變措施。

關於一至六小時預報誤差的機率分布函數，可針對十二場驗證洪水事件依照時間逐一推求，如此可以比較實際誤差與預報的誤差，圖 11 為預報誤差的 95%信賴區間，由圖上可知此信賴區間能涵蓋大多數的實際誤差值，且信賴區間的範圍隨著前置時間的延長而加大，此現象顯示本

機率預報模式所建立的誤差機率分布具有實用性與合理性。

圖 12 與圖 13 分別繪出二場驗證事件的機率預報水位歷線圖，同樣以 95%信賴區間來展示。關於較短前置時間的機率預報，信賴區間範圍較小且其邊界較平順，亦能合理涵蓋實測水位歷線，顯示其具有良好的應用價值；而關於較長前置時間的機率預報，某些場次信賴區間的邊界顯得有些震盪，且在退水段有較大的信賴區間範圍。此原因推測為：因為在降雨停止時的退水段，雨量多數為零，所以實際參與模糊推論的變量只有上、下游水位，在僅兩個變量的情況下，模糊推論模式較無法明確比對出資料庫中相似的數據型態，以至於有更大的不確定性及信賴區間範圍。

另外，由圖 11 至圖 13 可看出，定率水位預報值並未落於機率預報的信賴區間中心位置，由本機率預報方法可知，定率預報值非為所有機率預報值的中位數或平均值，故本研究亦針對定率預報值估算其超越機率，圖 14 顯示某洪水(事件 23)定率預報值之超越機率，整體來說，此超越機率曲線呈現震盪的變化情形，且前置時間較長的




圖 12 即時機率水位預報歷線圖(事件 15)




圖 13 即時機率水位預報歷線圖(事件 18)




圖 14 定率預報值之超越機率(事件 23)

預報，大多數超越機率值有小於 50% 的情形。圖 11 至圖 13 亦指出機率預報值可能並非符合高斯分布，本研究隨機選取部份機率分布進行檢驗，結果發現整體水位機率預報資料呈現對稱現象且具高峰度值，並有些微正偏態，但所有受檢驗的機率分布均不符合高斯分布。

另一個檢驗機率預報結果的方式為計算正確落於信賴區間內的資料數目，圖 15 呈現不同百分比信賴區間所包含的資料數目比例。如果預報的機率分布可以合理地掌握系統的不確定性，則信賴區間的百分比將會和落於此區間資料數目的百分比一致，由圖 15 看來，正確落於信賴區間的資料數目約略等於期望的個數，顯示機率預報的可信度。圖 15 亦顯示在各種不同前置時間的預報，其數據曲線的型態頗為相似，表示在較長前置時間的機率預報能力並未低於較短前置時間的預報，證實本研究提出的機率預報方法在較長前置時間的預報效能。

五、結 論

機率預報能指明預報值的不確定性程度，讓決策者將風險納入考慮，並據以採取合宜的緊急




圖 15 不同百分比信賴區間所包含的資料數目比例

反應措施，較定率預報值具有更大的決策效益。

本研究以支撐向量迴歸水位預報模式的預報歷線與觀測水位歷線極為一致，且在長前置時間(六小時)的預報，整體均方根誤差(RMSE)也小於 40 公分，顯示此定值水位預報模式的良好能力；此定率預報結果接著做為機率預報的基礎。

機率預報所採用的模式為模糊推理模式，本

研究利用 BADD 轉換法改良模糊推理的輸出模糊集合，使其轉換為機率分布函數。本計畫針對牽定事件及其預報誤差來建立數據資料庫，並應用改良型模糊推理模式配合重點抽樣法，可於各預報時間即時預測未來一至六小時的水位機率分布函數。此機率預報方法經實際應用於蘭陽大橋一至六小時的機率水位預報，並探討水位歷線的 95%預報信賴區間及針對警戒水位的預報情況，結果顯示本機率預報模式具有良好的預報效能及實用性。

機率預報能提供更豐富的預報水情資訊，讓使用者能考慮風險因素，執行更合宜的決策及應變措施，然而機率預報方法在水文預報領域尚未有廣泛的發展與應用，本研究成功應用模糊推理模式來發展水位機率預報方法，未來建議可嘗試其他理論方法，持續推展水文機率預報，期能提供實務機關更實用準確的預報資訊。

謝 誌

本計畫承蒙行政院國家科學委員會永續發展研究推動委員會提供研究經費(計畫編號: NSC 94-2625-Z-006-001)，及水利署第一河川局提供研究資料，謹致謝忱。

參考文獻

1. 陳憲宗，1998，「灰色預測在逕流預報之應用」，國立成功大學水利及海洋工程研究所碩士論文。
2. 陳憲宗、張逸凡、謝章廷、游保杉，2006，「支撐向量機制：洪水水位預報模式」，台灣水利，第 54 卷，第 2 期，第 50-61 頁。
3. 張逸凡，2005，「支撐向量機在即時河川水位預報之應用」，國立成功大學水利及海洋工程研究所碩士論文。
4. Abrahart R.J. & See, L. (2002) Multi-model data fusion for river flow forecasting: an evaluation of six alternative methods based on two contrasting catchments. *Hydrology and Earth System Sciences*, 6(4), 655-670.
5. Bazartseren, B., Hildebrandt, G. & Holz, K.-P. (2003) Short-term water level prediction using neural networks and neuro-fuzzy approach. *Neurocomputing*, 55, 439-450.
6. Beven, K.J. & Binley, A. (1992) The future of distributed models: Model calibration and uncertainty prediction. *Hydrological Processes*, 6, 279-298.
7. Beven, K. & Freer, J. (2001) Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the GLUE methodology. *Journal of Hydrology*, 249, 11-29.
8. Bray, M. & Han, D. (2004) Identification of support vector machines for runoff modeling. *Journal of Hydroinformatics*, 6(4), 265-280.
9. Chang, F.-J., Chen, Y.-C. & Liang, J.-M. (2002) Fuzzy clustering neural network as flood forecasting model. *Nordic Hydrology*, 33(4), 275-290.
10. Chau, K. (2004) River stage forecasting with particle swarm optimization. *Lecture Notes in Computer Science*, 3029, 1166-1173.
11. Chang, F.-J., Hu, H.-F. & Chen, Y.-C. (2001) Counterpropagation fuzzy-neural network for streamflow reconstruction. *Hydrological Processes*, 15(2), 219-232.
12. Chen, S.-T. & Yu, P.-S. (2007) Real-time probabilistic forecasting of flood stages. *Journal of Hydrology*, 340 (1-2), 63-77.
13. Choy, K.Y. & Chan, C.W. (2003) Modelling of river discharges and rainfall using radial basis function networks based on support vector regression. *International Journal of Systems Science*, 34(14-15), 763-773.
14. Dibike, Y.B., Velickov, S., Solomatine, D. & Abbott, M.B. (2001) Model induction with support vector machines: Introduction and applications. *Journal of Computing in Civil Engineering*, 15(3), 208-216.
15. Filev, D. & Yager, R.R. (1991) A generalized defuzzification method via BAD distributions.

- International Journal of Intelligent Systems*, 6, 687-697.
15. Freer, J., Beven, K.J. & Ambroise, B. (1996) Bayesian estimation of uncertainty in runoff prediction and the value of data: An application of the GLUE approach. *Water Resources Research*, 32(7), 2161-2173.
 16. Georgakakos, K.P., Seo, D.-J., Gupta, H., Schaake, J. & Butts, M.B. (2004) Towards the characterization of streamflow simulation uncertainty through multimodel ensembles. *Journal of Hydrology*, 298, 222-241.
 17. Georgakakos, K.P. & Smith, G.F. (1990) On improved hydrologic forecasting — results from a WMO real-time forecasting experiment. *Journal of Hydrology*, 114, 17-45.
 18. Gouweleeuw, B.T., Thielen, J., Franchello, G., De Roo, A.P.J. & Buizza, R. (2005) Flood forecasting using medium-range probabilistic weather prediction. *Hydrology and Earth System Sciences*, 9(4), 365-380.
 19. Hossain, F. & Anagnostou, E.N. (2005) Assessment of a Probabilistic Scheme for Flood Prediction. *Journal of Hydrologic Engineering*, 10(2), 141-150.
 20. Hsu, C.-W., Chang, C.-C. & Lin, C.-J. (2003) A practical guide to support vector classification. Available at: <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>
 21. Hundecha, Y., Bárdossy, A. & Theisen, H.W. (2001) Development of a fuzzy logic-based rainfall-runoff model. *Hydrological Sciences Journal*, 46(3), 363-376.
 22. Hunter, N.M., Bates, P.D., Horritt, M.S., de Roo, A.P.J. & Werner, M.G.F. (2005) Utility of different data types for calibrating flood inundation models within a GLUE framework. *Hydrology and Earth System Sciences*, 9(4), 412-430.
 23. Kitanidis, P.K. & Bras, R.L. (1980) Real-time forecasting with a conceptual hydrologic model: 1. Analysis of uncertainty. *Water Resources Research*, 16(6), 1025-1033.
 24. Klir, G.J. (1990) A principle of uncertainty and information invariance. *International Journal of General Systems*, 17, 249-275.
 25. Koren, V.I., Finnerty, B.D., Schaake, J.C., Smith, M.B., Seo, D.-J. & Duan, Q.-Y. (1999) Scale dependencies of hydrologic models to spatial variability of precipitation. *Journal of Hydrology*, 217, 285-302.
 26. Krzysztofowicz, R. (1998) Probabilistic hydro-meteorological forecasts: Toward a new era in operational forecasting. *Bulletin of the American Meteorological Society*, 79(2), 243-251.
 27. Krzysztofowicz, R. (1999) Bayesian theory of probabilistic forecasting via deterministic hydrologic model. *Water Resources Research*, 35(9), 2739-2750.
 28. Krzysztofowicz, R. (2001) Integrator of uncertainties for probabilistic river stage forecasting: Precipitation-dependent model. *Journal of Hydrology*, 249, 69-85.
 29. Krzysztofowicz, R. (2002) Bayesian system for probabilistic river stage forecasting. *Journal of Hydrology*, 268, 16-40.
 30. Krzysztofowicz, R. & Kelly, K.S. (2000) Hydrologic uncertainty processor for probabilistic river stage forecasting. *Water Resources Research*, 36(11), 3265-3277.
 31. Krzysztofowicz, R. & Maranzano, C.J. (2004) Bayesian system for probabilistic stage transition forecasting. *Journal of Hydrology*, 299, 15-44.
 32. Kuczera, G. & Parent, E. (1998) Monte Carlo assessment of parameter uncertainty in conceptual catchment models: The Metropolis algorithm. *Journal of Hydrology*, 211, 69-85.
 33. Lardet, P. & Obled, C. (1994) Real-time flood forecasting using a stochastic rainfall generator. *Journal of Hydrology*, 162, 391-408.
 34. Lee, C.C. (1990) Fuzzy logic in control systems: Fuzzy logic controller, Part II. *IEEE Transactions*

- on *Systems, Man, and Cybernetics*, 20(2), 419-435.
35. Lees, M., Young, P., Ferguson, S., Beven, K. & Burns, J. (1994) An adaptive flood warning scheme for the River Nith at Dumfries. In: *River Flood Hydraulics* (ed. by W.R. White & J. Watts) (Proceedings of the Second International Conference on River Flood Hydraulics, March 1994, York, U.K.), 65-75, John Wiley & Sons, Chichester, West Sussex, U.K.
 36. Liong, S.-Y. & Sivapragasam, C. (2002) Flood stage forecasting with support vector machines. *Journal of the American Water Resources Association*, 38(1), 173-196.
 37. Mahabir, C., Hicks, F.E., Fayek, A.R. (2003) Application of fuzzy logic to forecast seasonal runoff. *Hydrological Processes*, 17, 3749-3762.
 38. Montanari, A. (2005) Large sample behaviors of the generalized likelihood uncertainty estimation (GLUE) in assessing the uncertainty of rainfall-runoff simulations. *Water Resources Research*, 41(8), W08406.
 39. Montanari, A. & Brath, A. (2004) A stochastic approach for assessing the uncertainty of rainfall-runoff simulations. *Water Resources Research*, 40(1), W01106.
 40. appenberger, F., Beven, K.J., Hunter, N.M., Bates, P.D., Gouweleeuw, B.T., Thielen, J. & de Roo, A.P.J. (2005) Cascading model uncertainty from medium range weather forecasts (10 days) through a rainfall-runoff model to flood inundation predictions within the European Flood Forecasting System (EFFS). *Hydrology and Earth System Sciences*, 9(4), 381-393.
 41. See, L. & Openshaw, S. (2000) A hybrid multi-model approach to river level forecasting. *Hydrological Sciences Journal*, 45(4), 523-536.
 42. Seibert, J. (2001) On the need for benchmarks in hydrological modelling. *Hydrological Processes*, 15, 1063-1064.
 43. Seo, D.-J., Perica, S., Welles, E. & Schaake, J.C. (2000) Simulation of precipitation fields from probabilistic quantitative precipitation forecast. *Journal of Hydrology*, 239, 203-229.
 44. Sivapragasam, C. & Liong, S.-Y. (2005) Flow categorization model for improving forecasting. *Nordic Hydrology*, 36(1), 37-48.
 45. Sivapragasam, C., Liong, S.-Y. & Pasha, M.F.K. (2001) Rainfall and runoff forecasting with SSA-SVM approach. *Journal of Hydroinformatics*, 3(3), 141-152.
 46. Szöllösi-Nagy, A. & Mekis, E. (1988) Comparative analysis of three recursive real-time river flow forecasting models: deterministic, stochastic, and couple deterministic-stochastic. *Stochastic Hydrology and Hydraulics*, 2, 17-33.
 47. Tamea, S., Laio, F. & Ridolfi, L. (2005) Probabilistic nonlinear prediction of river flows. *Water Resources Research*, 41(9), W09421.
 48. Todini, E. (2004) Role and treatment of uncertainty in real-time flood forecasting. *Hydrological Processes*, 18, 2743-2746.
 49. Vapnik, V.N. (1995) *The Nature of Statistical Learning Theory*. Springer-Verlag, New York.
 50. Vapnik, V.N. (1998) *Statistical Learning Theory*, Wiley, New York.
 51. Vapnik, V.N. (1999) An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5), 988-999.
 52. Xiong, L., Shamseldin, A.Y. & O'Connor, K.M. (2001) A non-linear combination of the forecasts of rainfall-runoff models by the first-order Takagi-Sugeno fuzzy system. *Journal of Hydrology*, 245, 196-217.
 53. Young, P.C. (2002) Advances in real-time flood forecasting. Philosophical Transactions of the Royal Society of London Series A – Mathematical Physical and Engineering Sciences, 360, 1433-1450.
 54. Yu, P.-S. & Chen, S.-T. (2005) Updating real-time flood forecasting using a fuzzy rule-based model. *Hydrological Sciences Journal*, 50(2), 265-278.

55. Yu, P.-S., Chen, S.-T. & Chang, I.-F. (2006) Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328(3-4), 704-716.
56. Yu, X., Liong, S.-Y. & Babovic, V. (2004) EC-SVM approach for real-time hydrologic forecasting. *Journal of Hydroinformatics*, 6(3), 209-223.
57. Zadeh, L.A. (1978) Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems*, 1, 3-28.
- 收稿日期：民國 96 年 6 月 4 日
修正日期：民國 96 年 8 月 24 日
接受日期：民國 96 年 8 月 28 日