

颱風期間即時淹水地圖預報之研究

Effective Real-Time Forecasting of Inundation Maps During Typhoons

國立臺灣大學
土木工程學系
博士班研究生

王志煌*

Jhih-Huang Wang

國立臺灣大學
土木工程學系
博士

鍾秉宸

Bing-Chen Zhong

國立臺灣大學
土木工程學系
特聘教授

林國峰

Gwo-Fong Lin

摘要

颱風期間之降雨常造成淹水災害而導致人命及經濟財產的損失，對於淹水預警及減災上，有效及準確的淹水預報是必須的。本研究提出一有效即時淹水預報模式產生未來 1 到 3 小時之淹水地圖，提出之模式分為三個階段：決定預報淹水點、點預報及空間延展。首先，選擇 7-11 便利商店位置作為預報淹水點，再對於各淹水預報點分別以支援向量機(support vector machine, SVM)建置點預報模式產生預報淹水度，另外，本研究也比較以 SVM 與倒傳遞類神經網路(back-propagation neural network, BPN)為基礎的淹水預報模式之預報表現能力。最後依據點預報模式之預報淹水深度及地理資訊，並以 SVM 建置空間預報模式。本研究以嘉義市作為 FLO-2D 之淹水模擬，並證明提出之模式能有效改善預報的能力。結果顯示在預報未來 1 至 3 小時淹水深度之 RMSE 及 CC 值表現上，SVM 有 54%到 100%的淹水點預報表現優於 BPN，且提出模式淹水模式有 76%到 100%的淹水點預報表現優於 SVM。表示所提出之淹水預報模式可有效改善預報的能力。此外，提出淹水預報模式可準確提供未來 1 到 3 小時之淹水地圖。總結而言，本研究提出之模式對於淹水預警及減災方面有相當大的幫助。

關鍵詞：淹水預報，淹水地圖，支援向量機，倒傳遞類神經網路。

ABSTRACT

The inundation resulting from typhoon rainfall frequently causes loss of life and serious economic damage. Efficient and accurate forecasts of inundation depth are necessary for inundation warning and mitigation. In this study, an effective real-time

*通訊作者，國立臺灣土木工程學系博士班研究生，10617 台北市中正區羅斯福路 4 段 1 號，f02521311@ntu.edu.tw

forecasting approach is proposed to yield 1- to 3-h lead-time inundation maps during typhoon periods. The proposed model is composed of three steps: determination of inundation points, point forecasting and spatial expansion. First, 7-Eleven stores are determined as inundation points for the point forecasting. Second, the support vector machine (SVM) is used as the computational method to develop a point forecasting model to yield inundation forecasts for each inundation point. In addition, the SVM-based model is compared with an existing model based on the back-propagation network (BPN) to show the improvement in point forecasting performance. Third, based on the forecasted depths and the geographic information, the point forecasts are expanded to the spatial forecasts using the proposed spatial expansion model. An application to Chiayi City is conducted to demonstrate the superiority of the proposed model. The results show that the percentage of the number of inundation points for which the SVM-based model performs better than the BPN-based model is from 50 % to 100% for 1- to 3-h lead-time forecasting. The percentage of the number of inundation points for which proposed model performs better than SVM-based mode is from 76 % to 100% for 1- to 3-h lead-time forecasting. The proposed model effectively improves the forecasting performance. Moreover, the proposed model can provide accurate inundation maps for 1- to 3-h lead times. In conclusion, the proposed forecasting model is expected to be useful to support inundation warning and mitigation.

Keywords: Inundation forecasting, Inundation map, Support vector machine, Back-propagation network.

一、前 言

全球發生熱帶氣旋頻率最高的區域為西北太平洋地區。臺灣地理位置位於西北太平洋颱風活動路徑上，根據中央氣象局的統計，平均一年當中約 3 至 4 個颱風會侵襲臺灣地區，是影響臺灣最嚴重的天然災害之一。颱風所挾帶的豪雨是台灣非常重要的水資源，但過度集中且強勁的降雨亦會颱風所挾帶的豪雨會導致洪水災害、土石流、邊坡滑動和淹水災害等嚴重的問題。其中淹水是影響範圍最廣的災害之一，不但威脅到人命安全，另外也會造成龐大的經濟損失，為了降低災害發生，防災相關單位積極的研發預警系統。水利署及國家災害防救科技中心 (National Science and Technology Center for Disaster Reduction, NCDR) 分別在 2007 年及 2011 年開始繪製台灣地區淹水潛勢圖，其淹水潛勢係以模擬

重現期距及 24 小時累積雨量(300 mm、450 mm 及 600 mm)，並考慮降雨的時空分布特性、水庫與防洪設施正常操作、堤防無溢堤及未考慮下游潮位情況下，各地區發生最大淹水深度之淹水潛勢圖。淹水潛勢圖的優點為在颱風侵襲之前可作為淹水災害防範之重要參考。依據高淹水潛勢地區加強整備，期降低災害衝擊與損失；缺點為在颱風侵襲時無法提供即時預報淹水地圖資訊，因此，若能提供準確的淹水預報，讓防災單位得到有效的預警資訊，即可增加相關單位疏散人民及反應的時間。

淹水相關的議題已被廣泛的討論，Fewtrell *et al.* (2008)發表利用模式評估和模擬洪水在都市地區的淹水情況；Paiva *et al.* (2011)在水文及流體動力學模式計算出河川流動情形，結合地理資訊系統，可得出現實淹水結果的地圖。近年來，淹水模擬模式的發展一直受到廣泛的討論與重

視，且有許多相關的文獻發表(Hunter *et al.*, 2007; Mason *et al.*, 2009; Bates *et al.*, 2010)。在淹水模擬常被使用的淹水模式有很多種，例如，Cunge *et al.* (1980)所提出的核胞淹水模式，由洪水平原的空間與地文特性，簡化為蓄水元素組成的核胞系統，並考慮一維理想渠道及水工結構物的水力理論；賴進松等(2001)提出以二維零慣性淹水模式模擬基隆河流域淹水情況；SOBEK 為荷蘭 WL|Delft Hydraulics 公司所研發的二維淹水模式，此模式可應用模擬河川、集水區及都市淹水情況；FLO-2D 為 O'Brien (1993)所提出中央有限差分法(central finite difference scheme)的二維淹水模式，並將此模式用於美國 1983 年 Rudd Creek mudflow 淹水事件進行驗證，評估結果為模擬的淹水範圍與觀測的淹水範圍呈現吻合的情況。淹水模式的重點在於根據物理條件及特性，以模擬淹水歷程。近幾年，FLO-2D 已被許多淹水模擬研究廣泛用運(Supharatid *et al.*, 2006; GEI 2013; Haltas *et al.*, 2013; Haltas *et al.*, 2016; Dimitriadis *et al.*, 2016; 張學聖等, 2013; 林永峻等, 2014)，且被美國聯邦急難管理署(Federal Emergency Management Agency, FEMA)認可之模式，其優點為以連續方程式和動力波方程式，並以中央有限差分方法進行洪水演算，模擬流體流動速度及深度，另外，此模式套裝軟體可藉由電腦輔助繪製模擬後的淹水地圖，因此，本研究將以 FLO-2D 進行模擬颱風事件之淹水情況作為淹水資料。

然而，雖然目前的淹水模擬技術已經非常成熟，但由於淹水模擬需考慮不同降雨型態、地形資訊及各種邊界條件等等，使淹水模式需要大量計算與模擬時間。因此於實際提供即時淹水資訊給防災單位進行決策上，預報技術將是一項困難的挑戰。從淹水預報的研究文獻可發現，淹水預報主要模式的演算法，幾乎都以最常見的類神經網路(artificial neural networks, ANN)來建置淹水預報模式(Chang *et al.*, 2010; Pan *et al.*, 2011; Shen and Chang, 2013; Lin *et al.*, 2013b; Chang *et al.*, 2014)。Chang *et al.* (2010)使用不同重現期距下的降雨資料，利用物理淹水模式進行模擬，得

到淹水潛勢圖資料。將淹水資料依照地文及淹水特性以 K-means 進行分類，分類的中心點是為控制點，接著在控制點以 BPN 建置淹水預報模式，預報未來 1 小時淹水深度，最後分別使用線性回歸模式及 multi-grid BPN，推估至整個區域。在許多水文預報問題中，類神經網路由於具備運算快速、不需假設及處理高度非線性問題的能力，因此是被廣泛使用的工具，像 Lin and Wu (2009)應用 ANN 進行颱風時期降雨預報。國內外利用類神經網路於河川流量預報的相關研究目前亦相當多，如：降雨逕流預報(Lin and Chen, 2004)、洪水預報(Chang and Chang, 2009)、尖峰流量預報(Chidthong *et al.*, 2009)等。

新型類神經網路－支援向量機(support vector machine, SVM)在許多水文問題上已取得不錯的成果(Yu *et al.*, 2006; Yu and Liong, 2007)。Lin *et al.* (2009a, 2009b)針對雨量及流量預報的研究中，以支援向量機與傳統上最常用的倒傳遞類神經網路(back-propagation network, BPN)做比較，應用支援向量機其優點有三點。第一，在模式表現上準確度較高；第二，支援向量機權重及架構的決定保證為全域最佳解並且為唯一解，因此支援向量機可以獲得更為可靠的結果，顯示強健性(robustness)較高；第三，支援向量機模式訓練速度快，效率高。而結果顯示支援向量機相較於倒傳遞類神經網路更為準確、強健且迅速。在淹水預報的研究文獻中，Lin *et al.* (2013)使用前期雨量及淹水深度資料，將淹水資料與地文特性以 K-means 進行分類，接著以 SVM 為基礎建立淹水預報模式。然而，沒有文獻比較以 BPN 及 SVM 為基礎建立淹水預報模式的表現，因此，本研究將以 BPN 及 SVM 為基礎建立淹水預報模式做比較，且提出以支援向量機為基礎的新型淹水預報模式，以提供防災單位更快速且可靠的防災資訊。

二、研究方法

2.1 支援向量機

在機器學習方法中，支援向量機(Support Vector Machine, SVM)是一種監督式學習的方

法，由 Vapnik 在 1990 年代早期發展出 SVM 來解決統計分類的問題，更在 1995 年將應用範圍擴展到回歸分析的問題上。支援向量機主要有兩個的特點，第一，SVM 使用結構化風險最小誤差法(Structural Risk Minimization, SRM)，不僅可以降低目標誤差函數，同時也考慮了網路結構複雜度，使模式能達到一定的準確度，又不至於使架構太大而增加運算時間。第二，SVM 模式的結構和模式的權重被轉換成一個二次規劃問題，可以採用標準演算法快速求解。支援向量機進幾年來廣泛的應用在各種不同的領域中，在處理分類及預測方面的問題都獲得相當不錯的成果。於此僅簡單介紹研究中所使用的支援向量回歸法(Support Vector Regression, SVR)，其詳細的數學原理可以在許多參考書目中找到(Vapnik, 1995; Cristianini and Shaw-Taylor, 2000)。

SVR 的目標為找出一個非線性函數，產生在容許誤差範圍 ε 內，最近似目標輸出值 y 之網路輸出值 \hat{y} 。考慮 N_d 筆訓練資料 $[(x_1, y_1), (x_2, y_2), \dots, (x_{N_d}, y_{N_d})]$ 。首先，將輸入向量 x 經由非線性函數(nonlinear mapping function) $\phi(x)$ 轉換至高維度空間，因此經由輸入向量 x 產生輸出向量 \hat{y} 的回歸方程式可表示如下：

$$\hat{y} = f(x) = \mathbf{w}^T \phi(x) + b \dots\dots\dots(1)$$

再者，基於結構風險最小化原理，推估回歸函數的權重 \mathbf{W} 及偏權值 b ，目標函數如下式：

$$R = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^{N_d} L_\varepsilon(\hat{y}_i) \dots\dots\dots(2)$$

其中， L_ε 為 Vapnik 所定義的誤差函數， C 為懲罰係數：

$$L_\varepsilon(\hat{y}) = \begin{cases} |y - f(x)|_\varepsilon & \\ 0 & \text{for } |y - f(x)| < \varepsilon \dots\dots(3) \\ |y - f(x)| - \varepsilon & \text{for } |y - f(x)| \geq \varepsilon \end{cases}$$

方程式(2)中的第一項和第二項分別代表複雜度和經驗誤差，值越大表式架構越複雜誤差越

大。一般來說，兩者為相反的目標，在大部分情形下，模式複雜度越高其經驗誤差會越小，但是當模式複雜度變高，訓練模式所需花費的時間將會拉長，且容易發生過度訓練(over fitting)的情形；反之，模式複雜度越低，描述現象的能力越低，較不易表現出原本數據特性，經驗誤差會越大。所以架構的複雜度和經驗誤差間之平衡，取決於使用者自行定義的參數 C ， C 值越大代表經驗誤差對目標函數的影響越大，反之則越小。

Vapnik (1995)將 SVR 問題轉換成下列的最佳化問題：

Minimize

$$R(\mathbf{w}, b, \xi, \xi') = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^{N_d} (\xi_i + \xi'_i)$$

subject to

$$y_i - \hat{y}_i = y_i - (\mathbf{w}^T \phi(x_i) + b) \leq \varepsilon + \xi_i \dots\dots\dots(4)$$

$$\hat{y}_i - y_i = (\mathbf{w}^T \phi(x_i) + b) - y_i \leq \varepsilon + \xi'_i$$

$$\xi_i \geq 0$$

$$\xi'_i \geq 0$$

$$i = 1, 2, \dots, l$$

上式中， ξ 和 ξ' 稱為鬆弛變數(slack variables)，兩者分別代表資料點落在容忍誤差範圍外的誤差值，用以說明部分離群的訓練資料。

將(4)式之最佳化問題，導入 Lagrange multipliers 以 Lagrangian 求解：

$$\begin{aligned} L(\mathbf{w}, b, \xi, \xi', \alpha, \alpha', \eta, \eta') & \\ = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \left[\sum_{i=1}^{N_d} (\xi_i + \xi'_i) \right] & \\ - \sum_{i=1}^{N_d} \alpha_i [\varepsilon + \xi_i - y_i + \mathbf{w}^T \phi(x_i) + b] & \\ - \sum_{i=1}^{N_d} \alpha'_i [\varepsilon + \xi'_i + y_i - \mathbf{w}^T \phi(x_i) - b] - \sum_{i=1}^{N_d} (\eta_i \xi_i + \eta'_i \xi'_i) & \\ \dots\dots\dots(5) & \end{aligned}$$

其中， α 和 α' 為對偶的 Lagrange 係數。對 $\max_{\alpha, \alpha', \eta, \eta'} \min_{\mathbf{w}, b, \xi, \xi'} L(\mathbf{w}, b, \xi, \xi', \alpha, \alpha', \eta, \eta')$ 求解得

$$\left\{ \begin{array}{l} \frac{\partial L}{\partial w} = 0 \rightarrow w - \sum_{i=1}^{N_d} (\alpha_i - \alpha'_i) \varphi(x_i) = 0 \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^{N_d} (\alpha_i - \alpha'_i) = 0 \\ \frac{\partial L}{\partial \xi_i} = 0 \rightarrow C - \alpha_i - \eta_i = 0 \\ \frac{\partial L}{\partial \xi'_i} = 0 \rightarrow C - \alpha'_i - \eta'_i = 0 \end{array} \right. \dots(6)$$

$$\alpha_i, \alpha'_i, \eta_i, \eta'_i \geq 0, i = 1, 2, \dots, N_d$$

將(6)式代入(5)式，先轉換成一對偶問題(dual problem)，接著對主要變數微分後，可整理改寫如下：

Maximize

$$\sum_{i=1}^{N_d} y_i (\alpha_i - \alpha'_i) - \varepsilon \sum_{i=1}^{N_d} (\alpha_i + \alpha'_i) - \frac{1}{2} \sum_{i=1}^{N_d} \sum_{j=1}^{N_d} (\alpha_i - \alpha'_i) (\alpha_j - \alpha'_j) \varphi(x_i)^T \varphi(x_j)$$

subject to

$$\sum_{i=1}^{N_d} (\alpha_i - \alpha'_i) = 0$$

$$0 \leq \alpha_i \leq C$$

$$0 \leq \alpha'_i \leq C$$

$$i = 1, 2, \dots, N_d$$

.....(7)

上式為二次規劃問題，求解即可得 α_i 和 α'_i ，每組 α_i 和 α'_i 對應一筆訓練資料，非零的 $(\alpha_i - \alpha'_i)$ 表示該筆資料用於建立目標函數，稱之為支援向量(support vector)，而為零的 $(\alpha_i - \alpha'_i)$ 則視為多餘可刪除；換言之，支援向量也就是指這些用來協助定義目標函數之資料。一般而言， ε 愈大支援向量就愈少，對解來說，每個支援向量相對重要性就愈高，因此只要使用訓練資料中一個小的子集合即可表示解，在運算上具有相當大的優勢。另外，值得注意的地方是此最佳化問題的解，由於目標函數為一個凸面(convex)方程式，因此保證是唯一解且為全域最佳解。

其中，最佳的 Lagrange 係數 α^* 可利用標準二次規劃演算法求得，回歸函數可以改寫成：

$$f(x) = \sum_{i=1}^{N_d} \alpha_i^* K(x, x_i) + b \dots\dots\dots(8)$$

上式中 $K(x, x_i)$ 為核函數(kernel function)，定義為

$$K(x, x_i) = \phi(x_i)^T \phi(x) \dots\dots\dots(9)$$

使用核函數好處是能處理任何維度的特徵空間，而不必實際進行計算。本研究使用的核函數類型為輻狀基底函數(Radial Basis Function)，參數為 γ ：

$$K(x, x_i) = \exp(-\gamma|x_i - x|^2) \dots\dots\dots(10)$$

最後的回歸公式為

$$f(x) = \sum_{k=1}^{N_{SV}} \alpha_k K(x, x_k) + b \dots\dots\dots(11)$$

其中， x_k 為第 k 個支援向量； N_{SV} 為支援向量的個數。應用 SVM 時需要設定的參數有兩個，分別為懲罰係數 C 和容許誤差 ε ，本研究分別訂為1和0.01。其中，將懲罰係數設定為1表示使用者視架構的複雜度和經驗誤差兩者同等重要。

2.2 倒傳遞類神經網路

倒傳遞類神經網路(back-propagation neural network, BPN)係由 Rumelhart *et al.* (1986)所提出，BPN 是目前 ANN 中應用最普遍的演算法。基本架構以多層層感知機(multilayer perceptron)，一般使用誤差倒傳遞演算法(error back propagation)，故又稱為 BP (back propagation)演算法。BPN 為監督式多層前饋式網路架構，其基本架構為輸入層(input layer)、隱藏層(hidden layer)與輸出層(output layer)。

BPN 學習過程，可分為前饋及倒傳遞兩階段。在前饋階段，輸入向量由輸入層進入，以前饋方式經由隱藏層傳導至輸出層，並計算出網路輸出值，神經元間連結的權重在此階段是固定的；在倒傳遞階段，是以目標輸出值減去網路輸出值以得到誤差信號，然後將此誤差信號倒傳遞回網路中，神經元間連結的權重則藉此修正，其基本原理為利用最陡坡降法，逐次地調整神經元間的連結權重，使誤差函數最小化。而隱藏層中神經元個數的決定，是採用網路增長法，逐步增加神經元個數，並從中選擇結果最佳者。

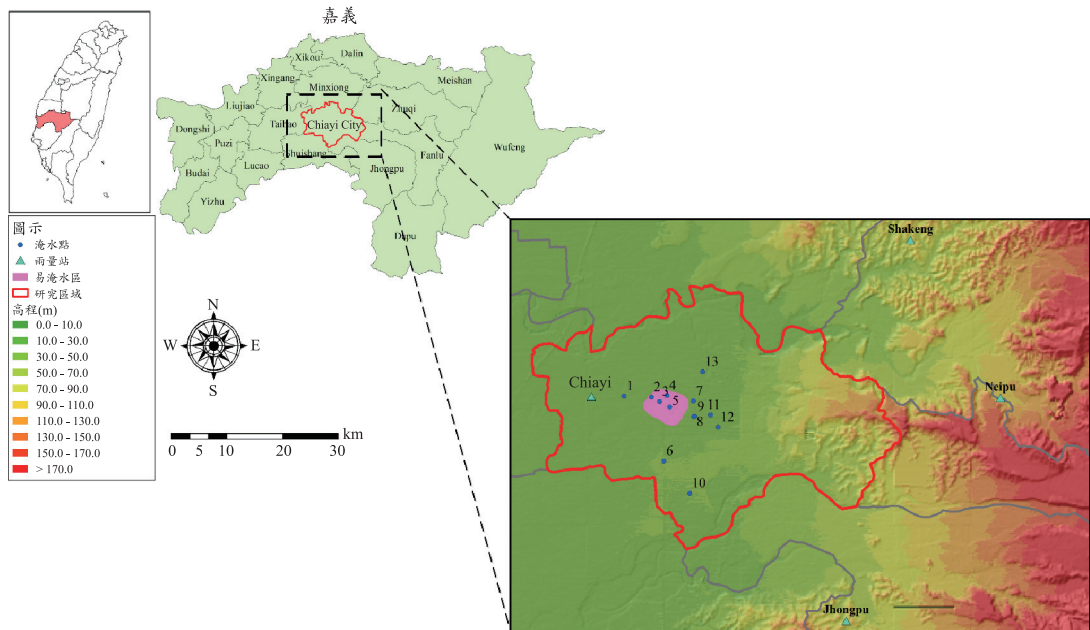


圖 1 研究區域

三、模式建立與應用

3.1 研究區域與資料

本研究之研究區域選定為嘉義市，如圖 1。嘉義市位於台灣西南端，面積約 60 平方公里。全市人口將近 27 萬人。嘉義市北有朴子溪、南有八掌溪，研究區域地勢由東向西緩降，其地形較為平坦。屬於亞熱帶型氣候，年雨量約在 1800 毫米，雨季主要集中於 5 到 10 月之間，其佔全年雨量的 84%。在圖 1，也標示本研究所使用的 4 個雨量及 13 個淹水點位置，以及水利署所公布的嘉義市易淹水範圍(粉紅色區塊)，由於本研究區域為典型的夏雨冬乾的氣候，所以每當夏季颱風來襲時，容易造成淹水災害，使得面臨人民生命上的危害及經濟上的損失。因此，需要建立有效即時淹水預警系統。

本研究採用的雨量資料是由水利署及中央氣象局所蒐集到四個雨量站(內埔、嘉義、沙坑及中埔)的觀測資料。為減少輸入維度，本研究利用徐昇平均法將四個雨量站的資料轉換為面積雨量作為輸入項。而選用了 16 場颱風事件建立全

表 1 颱風事件資料

時間	颱風事件	24 小時最大累積雨量(mm)
1996/07/29	賀伯	347.7
1998/08/03	奧托	244.6
2000/07/10	碧利斯	208.5
2001/07/24	桃芝	287.8
2001/09/13	納莉	733.8
2004/06/27	敏督利	458.9
2005/07/16	海棠	267.7
2005/08/30	泰利	232.1
2006/07/12	碧利斯	205.9
2007/08/16	聖帕	157.9
2007/10/04	柯羅莎	252.2
2008/07/16	卡玫基	351.7
2008/07/26	鳳凰	216.0
2008/09/11	辛樂克	188.6
2008/09/23	薔蜜	263.8
2009/08/06	莫拉克	584.0

區域淹水預報模式，颱風事件相關資訊見表 1。每個颱風事件有 24 小時整個研究區域的淹水深度歷線。然而，由於颱風事件的歷史觀測淹水深度

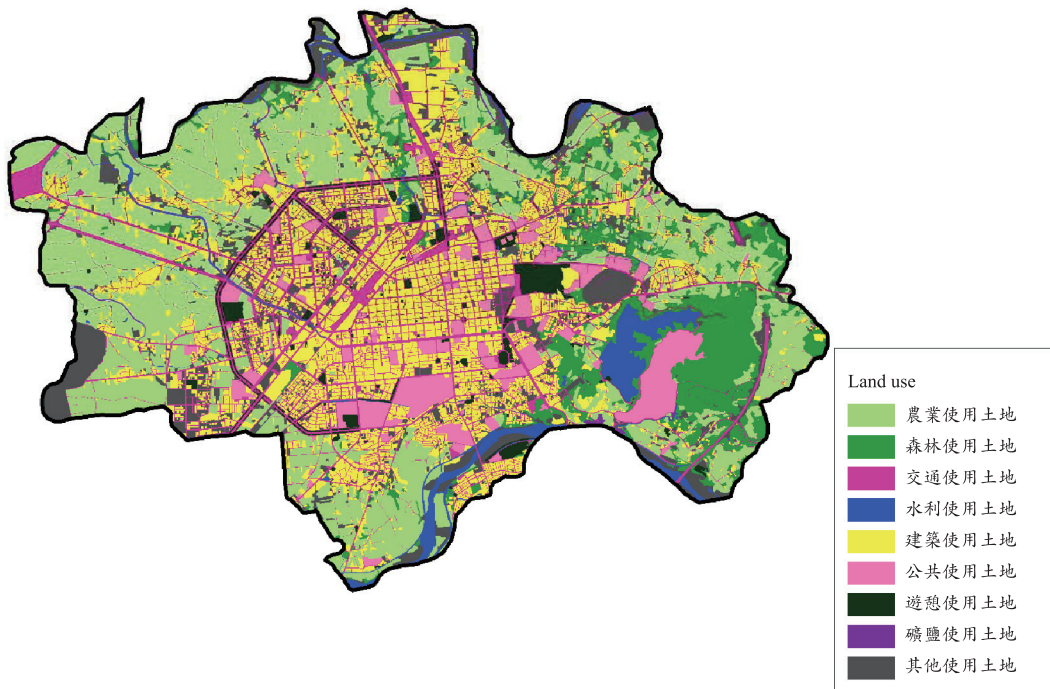


圖 2 嘉義土地使用分布圖

度非常少，甚至無觀測淹水資料，所以需要使用其他淹水資料來取代觀測淹水資料。因此，本研究採用的淹水資料為經 FLO-2D 模擬及驗證過後的颱風事件資料。

本研究以 FLO-2D 之二維地表漫地流方式進行淹水模擬，淹水模式之設定為以嘉義市為邊界，使用數值高程模型(Digital Elevation Model, DEM)資料，DEM 網格精度為 $80\text{ m} \times 80\text{ m}$ ，研究區域共有 10531 個網格的淹水資料。本研究使用的淹水深度資料共有 4,043,904 ($16 \times 24 \times 10,531$) 筆。每個網格點經由地理資訊系統(GIS)，將各網格所對應的經緯度座標及高程取出。另外，淹水模式還設置曼寧 n 值(Manning's n value)，以本研究區域土地使用情況對照 Chow (1959)所以提供的土地使用與曼寧 n 值之間關係表來設置曼寧 n 值。而本研究區域嘉義市之土地使用分佈圖，如圖 2 所示。此區域絕大部分的分佈為住宅、農業用地及森林三大部分，所以將淹水模式之曼寧 n 值設定為此三大部分，分別為住

宅為 0.012、農業用地為 0.035 及森林為 0.15。

本研究以 2008 年卡玫基颱風作為 FLO-2D 驗證，圖 3 為卡玫基颱風歷史觀測淹水紀錄及 FLO-2D 模擬之淹水情況，歷史觀測淹水面積為 NCDR 所提供，歷史觀測淹水點為水利署所提供。如圖 3 所示，FLO-2D 所模擬之淹水情況大致與歷史觀測淹水紀錄重疊。此外，更進一步以歷史觀測淹水深度與模擬淹水深度進行比較，在歷史淹水點之 a 點、b 點及 c 點的淹水深度範圍分別為 0.1 到 0.5 公尺、0.3 到 1.0 公尺及 0.3 到 1.0 公尺，而此三點在 FLO-2D 之淹水深度擬淹值為 0.6 公尺、1.15 公尺及 0.33 公尺。根據結果，FLO-2D 所模擬出來的淹水深度是合理的，所以本研究將以 FLO-2D 所模擬之淹水資料進一步發展淹水預報模式。

3.2 模式流程

本研究所提出一新型淹水預報模式架構流程，如圖 4 所示。由於代表性淹水點的決定是非




圖 3 卡孜基颱風歷史觀測淹水紀錄及 FLO-2D 模擬之淹水情況

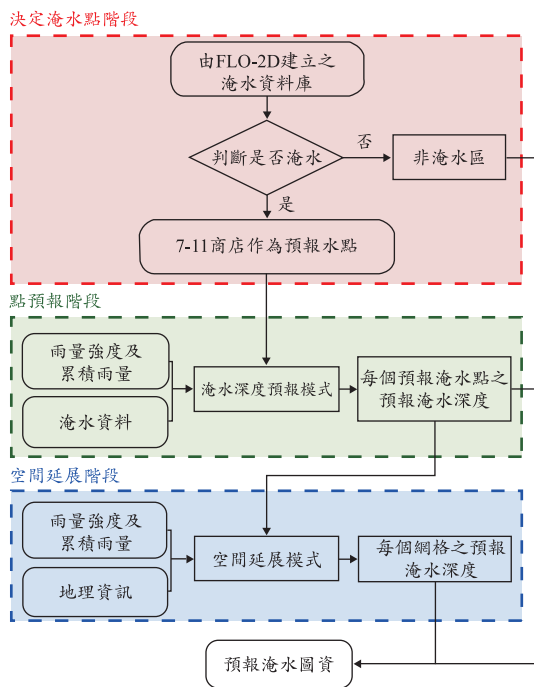


圖 4 本研究提出淹水模式之流程圖

水點應該設置在發生淹水頻率高的都市地區(Pan *et al.*, 2011)。然而，水利署自 2012 年起與 7-11 便利商店合作，以 7-11 便利商店為調查淹水點，當颱風豪雨來襲時，即由系統撥接室內電話，透過語音詢問各地積淹水深度。此外，7-11 便利商店幾乎位於人口密集的住宅區。雖然目前並無大量之淹水實際觀測資料可供模式建置，但根據上述原因，本研究將以 7-11 便利商店作為預報淹水點。

在模式應用上，支援向量機在水文研究方面之應用非常廣泛，在流量及雨量的預報上更是有相當的準確性，因此，在點預報階段，本研究利用支援向量機架構點預報模式。在提出之預報模式輸入項方面，為了提高預報的準確度，所以除了以前人研究常用的雨量及淹水深度外，本研究增加了累積雨量及預報的淹水深度作為提出模式的輸入項。接著，在空間推估方面，從文獻上可知，要得知各網格的預報時間之淹水深度，主要的輸入項為該網格當時刻的淹水深度來進行運算，這表示需建構所有網格的預報模式，雖然這種作法確實可以得到準確的預報淹水深度，但也代表往後若有真實颱風或暴雨來臨時，必須得

常重要的。在淹水緊急應變上，決策者常著重在易淹水區域且有人民居住的地方，所以代表性淹

先得知各網格的真實淹水深度後，才能夠進行預報。由於在真實情況下，無法得到各網格的真實淹水深度，所以此種方式不能使用在真實情況。為了得到在未來時間的各網之淹水深度，本研究提出使用支援向量機架構空間延展模式。在提出空間延展模式輸入項方面，使用了雨量、累積雨量、地理資訊(網格的經緯度及高程)，以及由點預報模式得到的預報淹水深度結果進行空間延展模式建置。最後，利用地理資訊系統進行視覺化，呈現預報淹水地圖。

3.2.1 點預報階段

本研究先以 BPN 及 SVM 建立淹水預報模式與提出之模式進行比較，兩模式稱為 BPN 及 SVM，其兩模式為輸入項為雨量及淹水深度資料，預報為未來 1 到 3 小時的淹水深度之淹水預

報。其以 BPN 及 SVM 建立淹水預報模式可表示如下：

$$\hat{D}_{IP, t+\Delta t} = f(R_t, R_{t-1}, \dots, R_{t-(L_R-1)}, D_{IP, t}, D_{IP, t-1}, \dots, D_{IP, t-(L_D-1)}) \quad \dots\dots\dots (12)$$

式中， t 為當前時間； Δt 為延時(1 到 3 小時)； R_t 為第 t 小時雨量； $D_{IP, t}$ 為淹水點在第 t 小時之淹水深度； $\hat{D}_{IP, t+\Delta t}$ 為淹水點預報 $t + \Delta t$ 小時之淹水深度； L_R 和 L_D 則表示雨量和淹水深度之稽延時間。

此外，本研究所提出的淹水預報模式，稱為 SVM_{proposed}，其輸入項為雨量、累積雨量、淹水深度資料及預報淹水深度，輸出項為預報為未來 1 到 3 小時的淹水深度。其 SVM_{proposed} 可表示如下：

$$\hat{D}_{IP, t+\Delta t} = \begin{cases} f(R_t, R_{t-1}, \dots, R_{t-(L_R-1)}, P_t, P_{t-1}, \dots, P_{t-(L_P-1)}, \dots, D_{IP, t}, D_{IP, t-1}, \dots, D_{IP, t-(L_D-1)}) & \text{for } \Delta t = 1 \\ f(R_t, R_{t-1}, \dots, R_{t-(L_R-1)}, P_t, P_{t-1}, \dots, P_{t-(L_P-1)}, \dots, D_{IP, t}, D_{IP, t-1}, \dots, D_{IP, t-(L_D-1)}, \hat{D}_{IP, t+1}, \dots, \hat{D}_{IP, t+\Delta t}) & \text{for } \Delta t > 1 \end{cases} \quad \dots\dots\dots (13)$$

式中， t 為當前時間； Δt 為延時(1 到 3 小時)； R_t 為第 t 小時雨量； P_t 為第 t 時累積雨量； $D_{IP, t}$ 為淹水點在第 t 小時之淹水深度； $\hat{D}_{IP, t+\Delta t}$ 為淹水點預報 $t + \Delta t$ 小時之淹水深度； L_R 、 L_P 和 L_D 則表示雨量、累積雨量和淹水深度之稽延時間。

對於淹水深度預測模式，適合的稽延時間輸入對模式建構是非常重要的工作。在本研究中，以相對百分誤差(relative percentage error, RPE)決定模式輸入項的稽延長度，其定義為：

$$RPE = \frac{E(L) - E(L+1)}{E(L)} \times 100 \quad \dots\dots\dots (14)$$

式中， $E(L)$ 和 $E(L+1)$ 分別為模式在 L 和 $L+1$ 延時之均方根誤差(root mean square error, RMSE)。由此過程取得適當的 L_R 、 L_P 和 L_D ，BPN、SVM 及 SVM_{proposed} 之輸入項，如表 2 所示。

3.2.2 空間延展階段

首先，假設有 n 個淹水點及 m 個網格(非淹水點)，計算每個淹水點($j=1, 2, \dots, n$)與其他網格($i=1, 2, \dots, m$)淹水深度之間效率係數(coefficient of efficiency, CE)，其中淹水點有 n 個。當 CE 值越接近於 1 時，表示淹水點與非淹水點網格之淹水深度越吻合。接著進行各網格分類，若第 i 個網格與每個淹水點之間計算出來的最大 CE 值為第 j 個淹水點，則把第 i 個網格分配於第 j 個淹水點作為空間延展推估，以此類推，會將各網格分為 n 類。由於本研究選了 13 個 7-11 便利商店作為淹水點，所以會將各網格分為 13 個類別。

接著，在每一類別，以雨量、累積雨量、地理資訊(網格的經緯度及高程)及該類淹水點所預報的淹水深度作為輸入項，建立以 SVM 為基礎的空間延展模式，最後，將每一類推估出來的預

表 2 點預報模式之輸入項

Lead time (h)	輸入項		
	SVM _{proposed}	SVM	BPN
1	$R(t), P(t), D_{IP}(t)$	$R(t), D_{IP}(t)$	$R(t), D_{IP}(t)$
2	$R(t), P(t), D_{IP}(t), \hat{D}_{IP}(t+1)$	$R(t), D_{IP}(t)$	$R(t), D_{IP}(t)$
3	$R(t), P(t), D_{IP}(t), \hat{D}_{IP}(t+1), \hat{D}_{IP}(t+2)$	$R(t), D_{IP}(t)$	$R(t), D_{IP}(t)$

報淹水地圖進行合併，得到此研究區域的預報淹水地圖。其空間延展模式可表示如下：

$$\hat{D}_{i, t+\Delta t} = f(X_i, Y_i, E_i, R_t, P_t, \hat{D}_{IP, t+\Delta t})$$

式中， $\hat{D}_{i, t+\Delta t}$ 為第 i 個網格在 $t + \Delta t$ 小時之預報淹水深度； X_i 和 Y_i 為第 i 個網格之經緯度座標； E_i 為第 i 個網格之高程； R_t 為第 t 小時雨量； P_t 為第 t 小時累積雨量。

3.3 交替驗證

傳統在建構模式時，通常採用將事件分成訓練、驗證、測試三群的方法，但是在如何分群的問題上，目前仍未有公認的規範。然而，即便使用相同的資料，也可能會因為分群的場次的不同，導致結果也因此有所不同。因此，本研究採用交替驗證(cross validation)的方式，避免傳統的分群方法而造成結果的不確定性。

以本研究為例，共 16 場颱風事件，每場事件輪流於每次運算中當作測試場次，每回運算皆有 15 場訓練場次，1 場測試場次，共進行 16 回運算，每回計算都有一次輸出結果，所以進行 16 回運算後，以平均所有測試場次預報結果的方式呈現模式表現。使用交替驗證的方式建模，不會有特定的場次作為測試資料，而且模式在每回運算中也可使用大量的訓練資料。

3.4 評鑑指標

為公正且客觀的評估全區域預報模式的表現，本研究採用均方根誤差(root mean square error, RMSE)及相關係數(correlation coefficient, CC)兩個指標，評估模式的預報誤差及相關性，分述如下：

均方根誤差 RMSE

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (D_t - \hat{D}_t)^2} \dots\dots\dots (15)$$

相關係數 CC

$$CC = \frac{\sum_{t=1}^n (D_t - \bar{D})(\hat{D}_t - \bar{\hat{D}})}{\sqrt{\sum_{t=1}^n (D_t - \bar{D})^2 \sum_{t=1}^n (\hat{D}_t - \bar{\hat{D}})^2}} \dots\dots (16)$$

式中， n 為颱風事件資料筆數， D_t 為第 t 小時之淹水深度， \hat{D}_t 為第 t 小時的模式預報淹水深度， \bar{D} 為淹水深度的平均值， $\bar{\hat{D}}$ 預報淹水深度的平均值。RMSE 為預報淹水深度與淹水深度間誤差之均方根，其值愈接近 0 代表預報值愈接近。CC 值為預報淹水深度與淹水深度間相關性，若 CC 值愈接近 1，則表示預測結果。

四、結果與討論

4.1 模式表現比較

4.1.1 BPN 與 SVM 之淹水預報模式比較

選擇合適的類神經網路是非常重要的，所以本小結將以 BPN 及 SVM 建立淹水預報模式，並比較兩者之淹水預報結果。表 3 為三個淹水預報模式(BPN、SVM 和 SVM_{proposed})在每個淹水點，預報未來 1 至 3 小時淹水深度之 RMSE 及 CC 值。BPN 及 SVM 在預報未來 1 至 3 小時淹水深度之 RMSE 表現上，在訓練階段有 SVM 有 54% 到 100%的淹水點之 RMSE 小於 BPN，而測試階段有 SVM 有 85%到 100%的淹水點之 RMSE 小於 BPN，不論於訓練或測試階段都顯示 SVM 預報準確度較優於 BPN。在預報未來 1 至 3 小時淹水深度之 CC 值表現上，在訓練階段有 SVM 有 85%到 100%的淹水點之 CC 值大於 BPN，而測試階段有 SVM 有 62%到 100%的淹水點之 CC 值大於 BPN，結果清楚表示 SVM 比 BPN 更能夠準確

表 3 預報點預報模式之 RMSE 與 CC 值

淹水點	Lead time (h)	RMSE (m)						CC					
		Training			Testing			Training			Testing		
		BPN	SVM	SVM _{proposed}	BPN	SVM	SVM _{proposed}	BPN	SVM	SVM _{proposed}	BPN	SVM	SVM _{proposed}
1	1	0.062	0.037	0.036	0.060	0.034	0.034	0.987	0.995	0.995	0.984	0.994	0.995
	2	0.092	0.074	0.072	0.087	0.067	0.067	0.968	0.980	0.980	0.962	0.975	0.976
	3	0.120	0.109	0.104	0.113	0.099	0.098	0.939	0.952	0.956	0.929	0.941	0.947
2	1	0.030	0.026	0.025	0.028	0.023	0.023	0.964	0.974	0.975	0.933	0.949	0.953
	2	0.045	0.043	0.040	0.040	0.038	0.036	0.913	0.922	0.934	0.845	0.862	0.885
	3	0.056	0.056	0.050	0.051	0.049	0.046	0.857	0.865	0.891	0.757	0.763	0.808
3	1	0.028	0.025	0.023	0.025	0.022	0.021	0.966	0.975	0.977	0.938	0.952	0.957
	2	0.043	0.043	0.039	0.038	0.038	0.034	0.914	0.920	0.935	0.848	0.862	0.896
	3	0.053	0.054	0.045	0.047	0.047	0.040	0.862	0.869	0.908	0.786	0.790	0.869
4	1	0.077	0.060	0.059	0.074	0.061	0.060	0.988	0.993	0.993	0.986	0.990	0.990
	2	0.126	0.120	0.105	0.121	0.114	0.100	0.966	0.970	0.977	0.957	0.962	0.971
	3	0.170	0.170	0.129	0.165	0.164	0.126	0.934	0.940	0.963	0.918	0.920	0.953
5	1	0.085	0.054	0.054	0.083	0.052	0.051	0.991	0.996	0.996	0.990	0.995	0.995
	2	0.133	0.126	0.101	0.131	0.122	0.099	0.976	0.980	0.986	0.971	0.974	0.982
	3	0.190	0.191	0.152	0.191	0.187	0.149	0.948	0.951	0.968	0.931	0.935	0.959
6	1	0.018	0.016	0.016	0.018	0.016	0.016	0.991	0.993	0.993	0.990	0.991	0.991
	2	0.031	0.030	0.030	0.030	0.029	0.029	0.972	0.973	0.974	0.968	0.967	0.968
	3	0.041	0.042	0.041	0.040	0.041	0.040	0.944	0.943	0.946	0.937	0.932	0.938
7	1	0.027	0.023	0.022	0.024	0.019	0.019	0.957	0.969	0.972	0.939	0.962	0.963
	2	0.040	0.040	0.036	0.035	0.032	0.031	0.892	0.905	0.917	0.856	0.884	0.887
	3	0.050	0.051	0.045	0.044	0.040	0.039	0.818	0.837	0.863	0.751	0.797	0.806
8	1	0.034	0.026	0.025	0.032	0.024	0.023	0.983	0.990	0.990	0.978	0.986	0.987
	2	0.050	0.048	0.044	0.046	0.043	0.040	0.960	0.966	0.971	0.950	0.954	0.962
	3	0.063	0.063	0.057	0.057	0.056	0.052	0.934	0.938	0.949	0.921	0.920	0.937
9	1	0.034	0.027	0.026	0.031	0.024	0.023	0.983	0.990	0.990	0.978	0.986	0.987
	2	0.051	0.049	0.044	0.046	0.043	0.041	0.960	0.966	0.971	0.950	0.954	0.962
	3	0.064	0.064	0.057	0.058	0.057	0.052	0.933	0.938	0.949	0.921	0.920	0.938
10	1	0.025	0.024	0.023	0.024	0.022	0.021	0.989	0.991	0.991	0.988	0.989	0.990
	2	0.043	0.042	0.041	0.041	0.042	0.040	0.967	0.967	0.969	0.960	0.958	0.961
	3	0.059	0.059	0.058	0.057	0.057	0.055	0.929	0.931	0.933	0.913	0.913	0.920
11	1	0.057	0.035	0.034	0.055	0.031	0.031	0.991	0.997	0.997	0.989	0.996	0.996
	2	0.083	0.071	0.070	0.078	0.064	0.064	0.978	0.985	0.985	0.976	0.983	0.983
	3	0.110	0.103	0.099	0.104	0.094	0.092	0.960	0.966	0.968	0.957	0.963	0.965
12	1	0.053	0.042	0.041	0.051	0.038	0.038	0.981	0.987	0.988	0.976	0.985	0.988
	2	0.089	0.082	0.079	0.085	0.076	0.075	0.937	0.948	0.952	0.915	0.927	0.940
	3	0.118	0.110	0.108	0.114	0.103	0.101	0.874	0.894	0.897	0.814	0.834	0.845
13	1	0.277	0.268	0.262	0.270	0.247	0.239	0.993	0.993	0.993	0.992	0.992	0.996
	2	0.377	0.399	0.371	0.373	0.395	0.361	0.986	0.984	0.986	0.984	0.981	0.984
	3	0.539	0.574	0.530	0.504	0.542	0.481	0.969	0.965	0.970	0.966	0.960	0.969




圖 5 SVMproposed 於所有 13 個淹水點(a)訓練之 RMSE 值平均改善幅度；(b)訓練之 CC 值平均改善幅度；(c)測試之 RMSE 值平均改善幅度；(d)測試之 CC 值平均改善幅度

預報未來淹水深度。

4.1.2 SVM 與 SVM_{proposed} 之淹水預報模式比較

由於為了證實本研究提出的淹水預報模式可提高預報能力，所以本章節將以本研究提出之模式(SVM_{proposed})及過去曾被使用的模式(SVM)進行比較。表 3 為 SVM_{proposed} 與 SVM 在每個淹水點預報未來 1 至 3 小時淹水深度之 RMSE 及 CC 值結果。由表 3 可知，由於隨著預報時間增長，輸入項與輸出項之間的相關性會隨之降低，各模式之表現能力也會隨之下降。雖然如此，但 SVM_{proposed} 的 RMSE 值比 SVM 的 RMSE 值明顯來得小，因此，SVM_{proposed} 相較於 SVM 在預報未來 1 至 3 小時都能得到較低的預報誤差。另外，在 CC 值表現上，雖然隨著預報時間的增加，各模式之 CC 值皆隨著減小的趨勢，但 SVM_{proposed} 的 CC 值比 SVM 的 CC 值來得高。在預報未來 1 小時中，兩模式表現皆不錯，訓練及測試階段的 CC 值，分別都有 0.97 和 0.95 以上，但到了預報未來 3 小時中，兩模式的差距則較為明顯，表示

SVM_{proposed} 在預報未來 3 小時較 SVM_{proposed} 更能抓到淹水深度的趨勢。

本章節除了呈現及討論 SVM_{proposed} 與 SVM 預報未來 1 至 3 小時之 RMSE 值及 CC 值表現外，並以 SVM 為基準，呈現 SVM_{proposed} 在所有 13 個淹水點的預報未來 1 至 3 小時之 RMSE 值及 CC 值平均改善幅度，如圖 5 所示。隨著預報時間的增加，SVM_{proposed} 之 RMSE 值及 CC 值改善幅度皆隨著提升。提出模式的 RMSE 值，訓練階段之改善幅度約從 2%到 9%左右，測試階段之改善幅度約從 2%到 8%左右。而在 CC 值，訓練階段之改善幅度為 0%到 2%左右，測試階段改善幅度為 0%到 2%左右。由此結果可知，本研究提出之模式(SVM_{proposed})可有效提升淹水預報的能力。

4.2 提出模式之點預報表現

上章節已透過評鑑指標評估 SVM_{proposed} 的預報準確度及相關性，本章節將以 2007 年柯羅莎

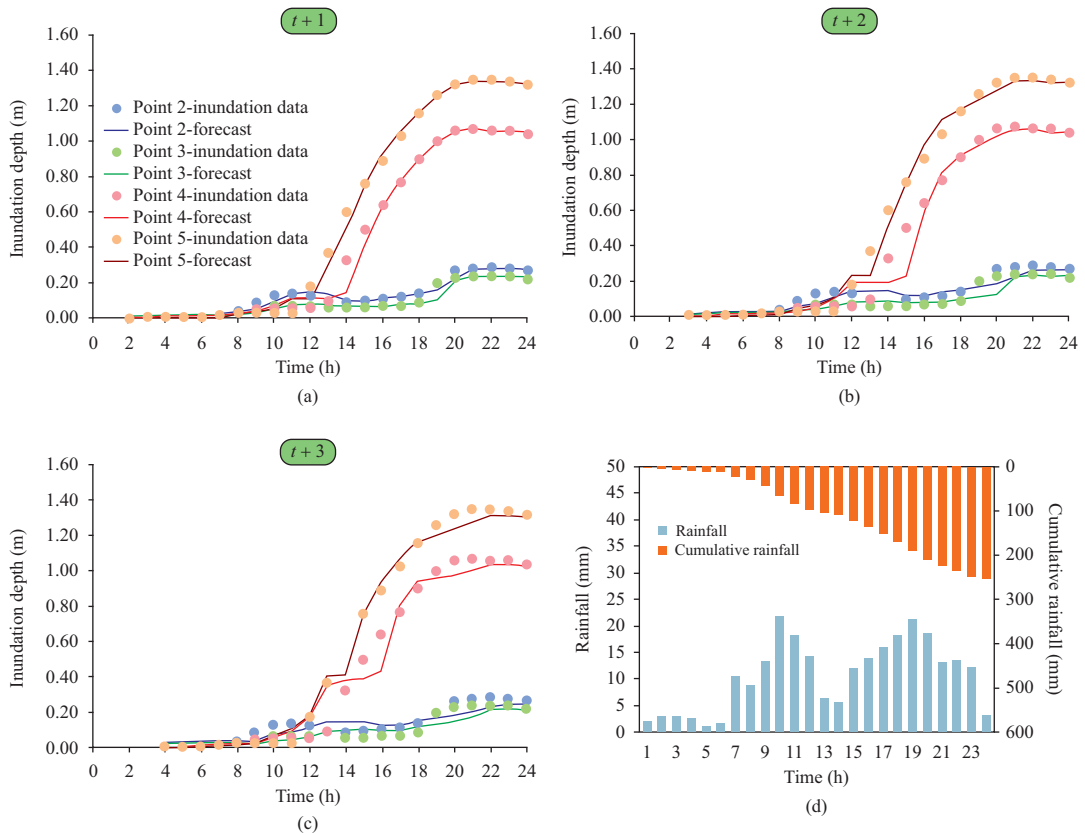


圖 6 SVM_{proposed} 於易淹水內點之(a)未來 1 小時淹水深度歷線；(b)未來 2 小時淹水深度歷線；(c)未來 3 小時淹水深度歷線；(d)柯羅莎颱風逐時雨量與累積雨量

颱風呈現預報淹水深度歷線之結果。圖 6 為 SVM_{proposed} 在易淹水區內淹水點的預報未來 1 到 3 小時淹水深度歷線結果。從圖 6(a)預報未來 1 小時淹水深度歷線圖可看出，在易淹水區內的四個淹水點，預報結果與淹水資料相當吻合，各個時間的淹水深度幾乎都能夠預報相當準確，且不論是淹水深度較淺的淹水點 2 及點 3，或是淹水深度較深的淹水點 4 及點 5，皆可準確得到預報淹水結果。而至於預報未來 2 到 3 小時的易淹水區內之淹水深度歷線圖，如圖 6(b)及(c)所示，其結果顯示提出模式之預報準確度高。整體來看，以上所呈現的預報結果，證實本研究提出的點預報模式(SVM_{proposed})有著良好的預報能力及準確度。

4.3 提出模式之預報淹水地圖之準確度評估

本章節將分析及討論提出模式的空間延展表現，以 2007 年柯羅莎颱風的 2007 年 10 月 6 日 08:00 PM 及 2007 年 10 月 7 日 08:00 AM 兩個時間點，比較空間延展之結果與淹水資料圖，如圖 7 所示。圖 7(a)為 2007 年 10 月 6 日 08:00 PM 的淹水資料，圖 7(b)為利用 07:00 PM 淹水資料預報 08:00 PM 的淹水結果，圖 7(c)為利用 06:00 PM 淹水資料預報 08:00 PM 的淹水結果，而圖 7(d)為利用 05:00 PM 淹水資料預報 08:00 PM 的淹水結果。由圖 7 可知，提出模式之預報淹水地圖結果與淹水資料非常相似，趨勢吻合。另外，2007 年 10 月 7 日 08:00 AM 淹水資料與預報結果也相當吻合。此結果明顯表示本研究提出的空間延展模式提供了合理的空間淹水預報。

除了淹水地圖結果展現，本研究加以討論預報未來 1 到 3 小時淹水圖的誤差分布。圖 8 為提

淹水資料

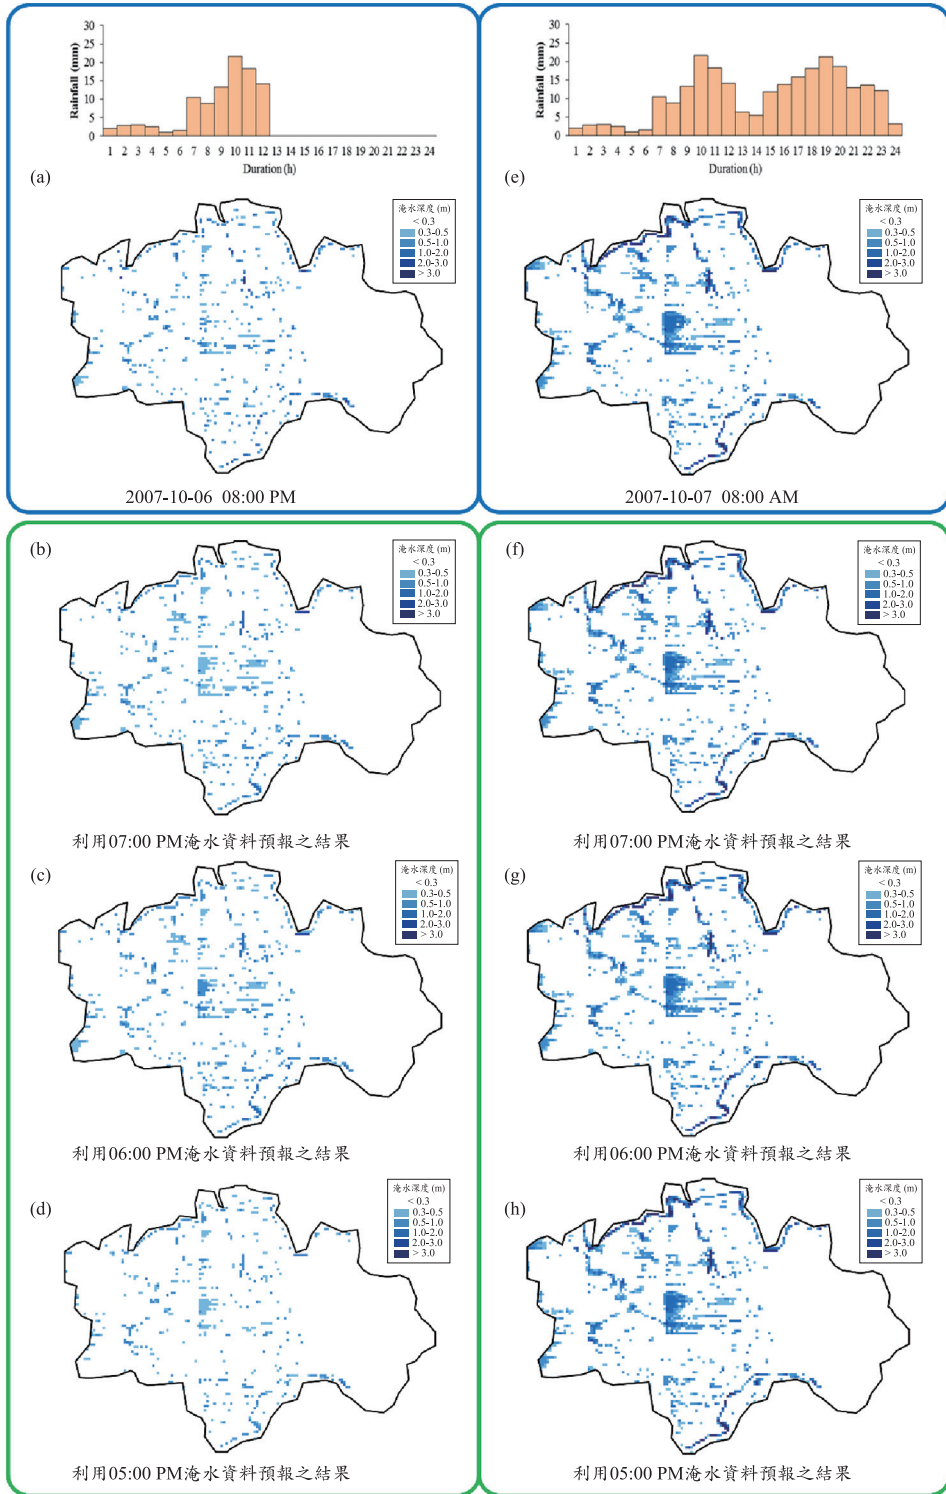


圖 7 柯羅莎颱風在 2007 年 10 月 6 日 08:00 PM 及 2007 年 10 月 6 日 08:00 PM 之淹水資料圖與預報淹水圖比較

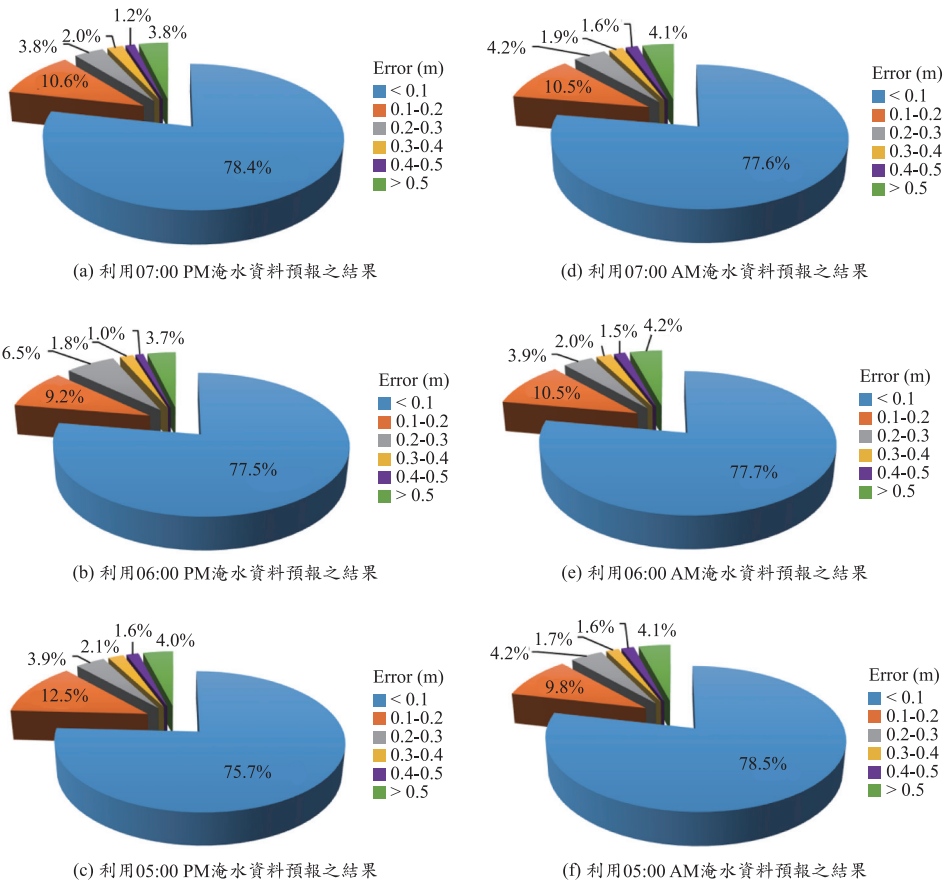


圖 8 柯羅莎颱風於 2007 年 10 月 6 日 08:00 PM 及 2007 年 10 月 6 日 08:00 PM 之預報未來 1 到 3 小時誤差分布圖

出的空間延展模式在 2007 年柯羅莎颱風於預報未來 1 到 3 小時誤差分布之圓餅圖。本研究係將 FLO-2D 所模擬納莉颱風(16 場事件中之最大淹水颱風場次)的最大淹水深度資料來判斷網格是否淹水，若最大淹水深度大於 0.3 公尺，則判定網格為有淹水；若最大淹水深度小於 0.3 公尺，則判定網格為非淹水，所有網格會分成淹水區(2094 個網格數)及非淹水區(8437 個網格數)，接著以淹水區之網格資料建立提出之淹水模式。值得一提的是，會以最大淹水颱風場次的最大淹水深度資料作為判斷是否淹水的原因，是因為若以其他場次(非最大淹水)來判斷是否淹水，則可能會造成某些網格實際上在最大淹水場次中有淹水，但卻被判斷為非淹水。因此，為了保守區分出淹水及非淹水區，本研究以最大淹水深度為基

礎，將小於 0.3 公尺之網格視為無淹水。然而，淹水區常導致人命及經濟財產的損失，故淹水區為本研究所關注的焦點，因此以有淹水區域之模式準確度作為評估。計算誤差分布方法為計算有淹水網格的預報誤差值，誤差區間以 0.1 公尺為基準，共分為六個區間，並計算各區間百分比。在計算各區間百分比時，各區間的分母都為有淹水的網格數(2094 個網格數)，分子為有淹水網格的預報誤差值落在各誤差區間之網格數，以誤差 0.1 公尺以下為例，預報誤差值小於 0.1 公尺的網格數除以有淹水的網格數(2094 個網格數)，得到誤差 0.1 公尺以下之區間百分比。另外，以圖 8(a)為例，圖中為圖 7(b)的預報值與圖 7(a)的淹水資料之差值，進而得到各區間百分比。其他圓餅圖亦以此方式得到誤差分布。透過誤差分布圖，可

以幫助讀者更清楚了解所有資料的誤差分布，而非僅針對整體平均結果進行探討。從圖 8 可看出，無論預報時間長短，有約 75.7%到 78.5%的資料誤差小於 0.1 公尺，而小於 0.3 公尺的資料更是佔了 88.6%到 93.3%之間，僅有約 3.7%到 4.2%的資料誤差超過了 0.5 公尺。由此結果可知，提出的淹水預報模式不僅在整體的評估指標上展現出非常理想的結果，針對所有資料誤差進行分析，亦顯示出所提出的淹水模式在空間淹水預報確實有相當高的準確度。

五、結論

本研究目的為發展在颱風間之有效即時淹水預警系統。因此，本研究提出一新型淹水預報模式。此模式包含了三個階段：決定預報淹水點、點預報及空間延展。第一階段，選擇 7-11 便利商店位置作為淹水預報點。第二階段，對於各淹水預報點分別以支援向量機建立點預報模式產生未來 1 到 3 小時之淹水深度。第三階段，依據點預報模式之預報淹水深度及地理資訊以 SVM 為基礎建立空間延展模式產生未來 1 到 3 小時之淹水地圖。

本研究於點預報淹水模式階段，建立三個淹水預報模式(BPN、SVM 和 SVM_{proposed})進行模式比較，並利用評鑑指標 RMSE 及 CC 值分別評估預報誤差及相關性。先以 BPN 和 SVM 進行比較，不論於訓練或測試階段，SVM 有 54%以上的淹水點之 RMSE 小於 BPN，且有 62%以上的淹水點之 CC 值大於 BPN，結果顯示 SVM 在大部分的淹水點皆有較準確的點預報結果。接著，再以提出模式之點預報與空間延展階段之結果，並利用評鑑指標 RMSE 及 CC 值進行評估模式表現。於點預報階段中，提出模式的 RMSE 值明顯比 SVM 的 RMSE 值來得小；而從相關性來看，提出模式之 CC 值比 SVM 的 CC 值來得高。隨著預報時間的增加，提出模式之 RMSE 值及 CC 值改善幅度皆隨著提升。除此之外，本研究更進一步以提出模式於空間延展中建置各時刻的預報淹水圖，並針對提出模式所估計之預報淹水圖進行誤差分析。結果清楚顯示所提出之淹水

預報模式在空間延展階段確實有不錯之準確度。由此研究結果，證實本研究所提出之模式能有效提升淹水預報的能力。對於防災單位來說，本研究提出的淹水預報模式應可提供相當即時的淹水預警資訊，並能作為防救災決策的參考依據。

參考文獻

1. Bates, P.D., Horritt, M.S., Fewtrell, T.J., "A simple inertial formulation of the shallow water equations for efficient two-dimensional flood inundation modelling," *Journal of Hydrology*, Vol. 387, Issues 1, pp. 33-45, 2010.
2. Chang, L.C., Shen, H.Y., Chang, F.J., "Regional flood inundation nowcast using hybrid SOM and dynamic neural networks," *Journal of Hydrology*, Vol. 519, pp. 476-489, 2014.
3. Chang, L.C., Shen, H.Y., Wang, Y.F., Huang, J.Y., Lin, Y.T., "Clustering-based hybrid inundation model for forecasting flood inundation depths," *Journal of Hydrology*, Vol. 385, Issues 1, pp. 257-268, 2010.
4. Chang, L.C., Chang, F.J., Wang, Y.P., "Auto-configuring radial basis function networks for chaotic time series and flood forecasting," *Hydrological Processes*, Vol. 23, Issues 17, pp. 2450-2459, 2009.
5. Chidthong, Y. C., Tanaka, H., Supharatid, S., "Developing a hybrid multi-model for peak flood forecasting," *Hydrological Processes*, Vol. 23, Issues 12, pp. 1725-1738, 2009.
6. Cunge, J.A., Holly, F. M., Verwey, A., "Practical aspects of computational river hydraulics," Pitman Publishing Ltd., London, 1980.
7. Dimitriadis, P., "Comparative evaluation of 1D and quasi-2D hydraulic models based on benchmark and real-world applications for uncertainty assessment in flood mapping," *Journal of Hydrology*, Vol. 534, pp. 478-492, 2016.
8. Ernst, J., Dewals, B.J., Detrembleur, S.,

- Archambeau, P., Erpicum, S., Piroton, M., "Micro-scale flood risk analysis based on detailed 2D hydraulic modelling and high resolution geographic data," *Natural Hazards*, Vol. 55, pp. 181-209, 2010.
9. Fewtrell, T. J., Bates, P. D., Horritt, M., and Hunter, N. M., "Evaluating the effect of scale in flood inundation modeling in urban environments," *Hydrological Processes*, Vol. 22, Issues 26, pp. 5107-5118, 2008.
 10. GEI Consultants Inc, "Hayden reservoir Dam and Davis No. 1 Dam breach inundation mapping report," Denver Co, USA, 2014.
 11. Haltas, I., "Two dimensional modeling and gis integrated mapping of the dam-break inundation, a case study: Lake Isabella Dam," In: *Proceedings of 6th international perspective on water resources & the environment*, Izmir, Turkey, 2013
 12. Haltas, I., "Two-dimensional numerical modeling of flood wave propagation in an urban area due to Urkmez dam-break, Izmir, Turkey," *Natural Hazards*, Vol. 81, Issues 3, pp. 2103-2119, 2016.
 13. Hunter, N.M., Bates, P.D., Horritt, M.S., Wilson, M.D., "Simple spatially distributed models for predicting flood inundation: a review," *Geomorphology*, Vol. 90, Issues 3-4, pp. 208-225, 2007.
 14. Lin, G. F., Chen, L. H., "A non-linear rainfall-runoff model using radial basis function network," *Journal of Hydrology*, Vol. 289, Issues 1-4, pp. 1-8, 2004.
 15. Lin, G.F., Chen, G.R., Huang, P.Y., Chou, Y.C., "Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warning periods," *Journal of Hydrology*, Vol. 372, Issues 1-4, pp. 17-29, 2009a.
 16. Lin, G.F., Chen, G.R., Wu, M.C., Chou, Y.C., "Effective forecasting of hourly typhoon rainfall using support vector machines," *Water Resources Research*, Vol. 45, W08440, 2009b.
 17. Lin, G. F., Wu, M. C., "A hybrid neural network model for typhoon-rainfall forecasting," *Journal of Hydrology*, Vol. 375, Issues 3-4, pp. 450-458, 2009.
 18. Lin, G.F., Chou, Y.C., Wu, M.C., "Typhoon flood forecasting using integrated two-stage support vector machine approach," *Journal of Hydrology*, Vol. 486, pp. 334-342, 2013a.
 19. Lin, G.F., Lin, H.Y., Chou, Y.C., "Development of a real-time regional-inundation forecasting model for the inundation warning system," *Journal of Hydroinformatics*, Vol. 15, Issues 4, pp. 1391-1407, 2013b.
 20. Lin, G.F., Jhong, B.C., Chang, C.C., "Development of an effective data-driven model for hourly typhoon rainfall forecasting," *Journal of Hydrology*, Vol. 495, pp. 52-63, 2013c.
 21. Mason, D.C., Bates, P.D., Dall' Amico, J.T., "Calibration of uncertain flood inundation models using remotely sensed water levels," *Journal of Hydrology*, Vol. 368, pp. 224-236, 2009.
 22. McCuen, R.H., Knight, Z., Cutter, A.G., "Evaluation of the Nash-Sutcliffe Efficiency Index," *Journal of Hydrologic Engineering*, Vol. 11, Issues 6, pp. 597-602, 2006.
 23. O'Brien, J. S., Julien, P. Y., Fullerton, W. T., "Two-dimension water flood and mudflow simulation," *Journal of Hydraulic Engineering* Vol. 119, Issues 2, pp. 244-261, 1993.
 24. Paiva, Rodrigo C.D., Collischonn, W., Tucci, Carlos E.M., "Large scale hydrologic and hydrodynamic modeling using limited data and a GIS based approach," *Journal of Hydrology*, Vol. 406, Issues 3-4, pp. 170-181, 2011.
 25. Pan, T.Y., Lai, J.S., Chang, T.J., Chang, H.K., Chang, K.C., Tan, Y.C., "Hybrid neural networks in rainfall-inundation forecasting based on a synthetic potential inundation database," *Natural Hazards and Earth System Sciences*, Vol. 11,

- Issues 3, pp. 771-787, 2011.
26. Shen, H.Y., Chang, L.C., "Online multistep-ahead inundation depth forecasts by recurrent NARX networks," *Hydrology and Earth System Sciences*, Vol. 17, Issues 3, pp. 935-945, 2013.
27. Supharatid, S., "The Hat Yai 2000 flood: the worst flood in Thai history," *Hydrological Processes*, Vol. 20, Issues 2, 307-318, 2006.
28. Vapnik, V., *The Nature of Statistical Learning Theory*, Springer, New York, 1995.
29. Vapnik, V., *Statistical Learning Theory*, Wiley, New York, 1998.
30. Yu, P.S., Chen, S.T., Chang, I.F., "Support vector regression for real-time flood stage forecasting", *Journal of Hydrology*, Vol. 328, Issues 3-4, pp. 704-716, 2006.
31. Yu, X.Y., Liang, S.Y., "Forecasting of hydrologic time series with ridge regression in feature space," *Journal of Hydrology*, Vol. 332, Issues 3-4, pp. 290-302, 2007.
32. 賴進松，張向寬，「防洪示範區淹水境況模擬與決策支援系統之研究（一）-子計畫八：基隆河流域颱風發生潰堤災害之情境模擬」，行政院國家科學委員會專題研究計畫，2001。
33. 張學聖，廖晉賢，「台南市土地使用計畫之水災風險分析」，*都市與計畫*，第四十卷，第一期，第 59-79 頁，2013。
34. 林永峻，張向寬，馬國宸，賴進松，張倉榮，吳祚任，鄧慰先，譚義績，「海嘯危險度地圖-以新北市金山與萬里區為例」，*農業工程學報*，第六十卷，第三期，第 42-54 頁，2014。

收稿日期：民國 105 年 5 月 29 日

修正日期：民國 105 年 8 月 4 日

接受日期：民國 105 年 8 月 8 日