

以類神經網路預測淡水河感潮河段水位

Water Stage Forecasting of the Tanshui River under Tidal Effects by Using Neural Network

國立台灣大學生物環境系統
工程學系教授

張斐章

Fi-John Chang

國立台灣大學生物環境系統
工程學系博士後研究

陳彥璋

Yen-Chang Chen

國立台灣大學生物環境系統
工程學系博士班研究生

梁晉銘

Jin-Ming Liang

摘 要

感潮河段內河川水位受潮汐及諸多水文因子影響，難以利用一般數學或物理模式對其水位進行預測。本研究藉由類神經網路之強大學習功能，以淡水河系感潮河段之水位資料建構台北橋站之水位預測模式，並用於預測未來一小時之水位。首先網路以團塊分類演算法預先將訓練範例依性質相近程度進行聚類，使歷史資料之規律性得到區隔並降低複雜度；其次，對非線性基底函數作簡易之線性組合運算，使重現機率較低之極端事件亦能得到適當的權重推論。

為求對模式建構成效作檢測，本研究取近年來淡水河感潮河段內多個水位站時序列為背景資料，經參數檢定、模式驗證與適用性測驗三階段之模式模擬預測，結果顯示模式能對水位漲落之趨勢掌握的相當良好，足見以類神經網路模式對感潮河段水位進行預報模式之建構具有實用之潛力。

關鍵詞：感潮，類神經網路，水位，團塊。

ABSTRACT

To forecast the water stage in open-channel under tidal effects is always a tough task. Even those sophisticatedly conceptual and mathematical models cannot do a good job. In this study we propose an artificial neural network model to forecast the one-hour-ahead water stage. One of the advantages of the artificial neural network is its powerful learning ability. During the training scheme, the training data with same similarities are clustered together at the beginning. Then the least squares method is used to estimate the weights of the model. Thus it can reduce the complexity of the system.

The water stage data of the Tanshui River under tidal effects are used to construct a

water stage forecasting model. The data is split into three independent subsets, namely, the training, validation, and testing subsets. The training subset is used for parameter estimation and model development. The validation subset is applied to choose the best model from the candidate ones. The testing subset is devoted to show the performance of the selected model. The results show that the artificial neural network model is a reliable and accurate tool for forecasting the water stage in an open-channel under tidal effects.

Keywords: Tidal effect, Artificial neural network, Water stage, Cluster.

一、前言

感潮河段流況複雜，其主要原因在於此類河川受河水與海水彼此交互過程之影響，也因此感潮河段不斷的在進行演化，並不時的改變其流況等特性以適應河川水流與氣候型態。其中週期約為半日之海水潮位變化，是造成一般情況時感潮河段水位具規律循環變化之主因（Kjerfve 1988）；此外河口流況之季節性變化則主要與鹽度有關，上游匯集之洪水帶來的效應則是造成水體垂直向層理之變化及水流規律性變化之破壞主因之一；於氣候因子中對感潮河段之影響主要為風效應，由於其所造成之風剪力將產生波浪，將使水流循環與海水及河水之混合過程發生改變；在水流循環與混合過程中，主要原因為僅有2%不同的河水與海水密度差，會產生水平方向之壓力梯度而影響水流，其中造成河水與海水密度不同的主要原因乃為溫度與鹽度，然而溫度之變化不如鹽度之變化大，故鹽度亦為感潮河段水流變化之主要因子之一（Dronkers and Leussen 1988）。綜觀上述成因可發現，感潮河段流況之物理過程相當不易掌握，其物理過程不但複雜且相互影響，且為形成水成岩（Sedimentological）、生物（Biological）及化學（Chemical）等過程之推動力（Dyer 2000），所以造成一般傳統方法難以準確預測感潮河段之流量或水位。

台灣地區位處亞熱帶，隸屬於海島型氣候區，夏秋之際常有颱風侵襲，年平均雨量可達兩千多公厘。因全島地形呈現東西窄而南北狹長狀，且多數主要河川均以中央山脈為分流點而東西向入海，所以颱風事件所挾帶之豐沛水氣每每

釀成豪雨，使上游集水區所匯集之湍急洪流於短促的數個小時之延時中，即能通過中下游地區向出海洋宣洩。颱風侵襲期間常有暴風伴隨，故當颱風路徑嚴重影響台灣時，其大氣壓差與風切剪力等作用將異常增強暴潮效應，致使河口之大量潮水上溯，使河川之水流難以順利排放入海。因此感潮河段內之河川水位於颱風期間，會受天文潮、颱風暴潮及上游洪流等眾多因子綜合效應之影響，使水位的漲落無論在規模或週期等水流特性，變得更加難以推估與預測。

由於台灣降雨量之分佈無論在時間或空間上常呈不均勻之狀態，再加上無充分的條件供逕流滯留，所以集水區之水資源涵養蓄存問題相當棘手；為求解決此一困境，淡水河流域上游集水區建有石門及翡翠水庫以為因應，以使豐枯期間的水資源盈虧得而相互調配。然而河川之天然水地文特性為其歷經長時期所保留下來的自然平衡，所以上游水庫或河道兩側之防洪結構物...等勢必對該平衡產生衝擊，尤其大台北地區在淡水河入海之前有基隆河、大漢溪、景美溪等支流蜿蜒於都會區之中，下游段沿岸雖有完備之監測及抽水設備與堤岸防護，但大台北區域內與水爭地之不當開發，將使突發性洪水事件的發生更加難以預料，令原有水工設計的可靠性勢必受到相當程度的影響，所以如何建構一便捷、有效且精確的感潮河段水位預測模式，使水位變化得到充分之掌握，以爭取充足之防災預警時效，使中下游臨岸居民的居家安全進一步受到保障，為本研究之目的。

本研究主要利用輻狀基底函數類神經網路模式，對感潮河段河川水位進行模擬。由於感潮

河段承受來自上游降雨匯集之逕流與下游潮汐上溯之多重影響，亦即基本上會存有高潮位時段加上洪水來臨則水位壅高與低潮位時段加非汛期流量則水位消退之因果關係，故適合以類神經網路模式來進行水位推估。於本研究中，輻狀基底函數類神經網路模式之分類階段將針對淡水河感潮河段內之相關水位站的時水位記錄進行特性分析，然後再利用線性迴歸推求第二階段之係數，所架構之淡水河感潮河段水位預測模式，可用於預測台北橋站未來一小時之水位。

二、文獻回顧

傳統上，感潮河段水位之推估常採定率方式來進行；藉由連續方程及運動方程等基本公式之推導，控制方程式即可演繹而出，而其相關之初始與邊界條件可藉由其他方法事先推求。早期對河口水力特性作有系統研究的首推 Pritchard (1952)，其發現海水與河水密度差所造成之密度流或重力環流，乃影響河口水力之重要因子；Hass (1977) 則建立潮汐變化與鹽度垂直分佈之關係；Stelling *et al.* (1986) 對水體內流速與水位變化進行研究，並應用淺水波方程式配合有限差分法建立水平二維模式於河口潮汐流及波浪之模擬。在國內許時雄 (1989) 曾利用變量流理論對淡水河河口至關渡感潮河段範圍內進行演算模式之建立，且為求檢討改進淡水河之洪水預報模式並擴大其演算之適用河段，以多種降雨逕流模式配合變量流模式及颱風降雨推估、河口潮位推估等方法分別組合出多種綜合模式對相同資料進行測試。此外，除上述變量流理論廣泛的對感潮段水位推估進行研究之外，國內亦有相當多的學者嘗試不同的學理與方法如小波 (wavelet) 理論、調和理論、線性時序理論，相繼投入於近河口之潮汐現象及感潮段水位之研究；柳文成等 (1998) 以調和分析對淡水河之水位站潮位進行探討，除提出分潮數愈多愈縮小殘差水位之結論亦歸結出較為重要之分潮類型；蔡瀚陸 (2000) 則結合調和分析、Navier-Stokes 方程式與颱風模式，對淡水河河口站颱風時期水位進行預測；王如意等 (1998) 則以小波復解析

方法進行理論解析並且實際應用於淡水河感潮河段水位-流量率定曲線修正；林淑真等 (1996) 以類比線性降雨-逕流模式之方式建構潮汐-逕流模式，並將兩者組合成自我聯合模式對彰濱工業區感潮河段之水位進行預報；顏沛華 (1996) 曾以自組非線性系統 GMDH 結合短期即時潮汐預報模式預測曾文溪感潮河段之水位。由於水位預報模式之建構可利用黑盒方式進行，不必對系統機制作過於嚴謹的探討及賦予過多之假設，且相關研究顯示普遍均能獲得不錯之結果，所以當分析之系統為感潮河段，則對水位之變化進行推估及預測時，僅需事先針對系統之輸出目標項與相關輸入因子作概略剖析，由此可知類神經網路模式亦為一深具潛力之工具。

類神經網路模式以模擬生物腦內神經細胞構造作為模式發展之主要依據，由於演算法、鏈結方式與神經元權重優選法等容易變更，故常推陳出新；McCulloch 與 Pitts 建立 M-P 數位化神經元架構進行研究並提出後 (1943)，此一概念即受到相當的重視，並廣受各領域之系統研究者所青睞。於水資源系統探究之研究中，近年來相關論述相繼發表；Hsu *et al.* (1995) 以三層前向式類神經網路對集水區流量序列進行推估；張斐章等 (1992) 及 Chang and Hwang (1999) 參考 Ivankhnenko (1971) 利用生物進化方式對模式神經元之組合作範束，且據以對集水區短延時降雨-逕流事件行自組性演算 (GMDH) 模式架構；此外，張斐章等 (1993) 亦曾利用此模式對長期之降雨-逕流歷程作深入之探討。陳昶憲等 (2000) 則透過倒傳遞網路對流域洪流進行研究，且取之與其他類神經網路於洪流量預測上作一比較；張斐章等 (1998) 除以倒傳遞網路對短延時降雨-逕流過程進行探討外，亦對降雨事件作進一步研究；此外 Chang and Chen (2001) 以反傳遞模糊類神經網路建構降雨-逕流模式，可相當準確預測颱風時期之逕流量。本研究所採用之類神經網路類型以改良型之輻狀基底函數類神經網路 (Radial Basis Function Neural Network, RBFNN) (張斐章等 2000, Chang *et al.* 2001) 為主要架構，目的在於用以預測淡水河感潮河段

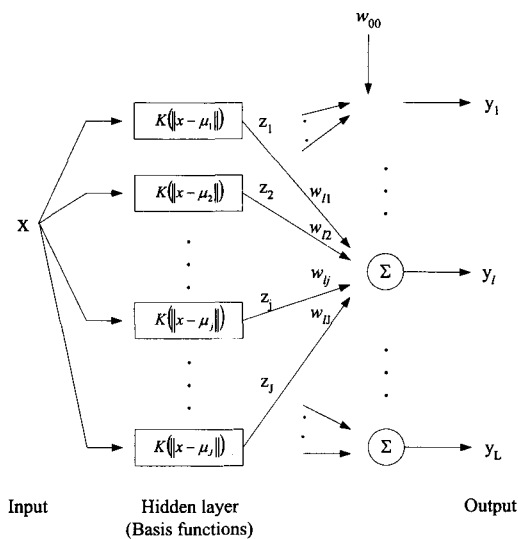


圖 1 網路架構

台北橋站未來一小時之水位。

三、RBFNN 架構與訓練

因傳統類神經網路對於隱藏層層數與內層所含之處理單元數並無適當原則可供參考，所以在不同系統進行參數及係數之推定以找尋最佳化類神經網路時，迭代式試誤方法往往使類神經網路模式的適用性大為降低。分析網路特性可知，一般類神經網路中之多層隱藏層結構所進行的工作，類似利用對多維空間進行切割並使資料進行聚類，所以近年來類神經網路的一般性結構建置原則轉變為模仿生物腦之邏輯判斷過程，且透過團塊演算及模糊理論等方法，類神經網路的結構特性趨向於完成分類與推理兩階段工作。

本研究所引用之 RBFNN 已廣泛應用於非線性系統，主要用以模擬大腦皮質層軸突的局部調整能力，因此具備相當良好的映射能力，近年來已推廣於推求水文歷程之降雨-逕流關係(張斐章等 2000)。由於具有大量減少學習所需之時間，並可應用於分類及非線性模式之建立等優點，故本研究以其為主要依據建立水位預測模式。RBFNN 之架構可簡單示意如圖 1，其具有輸入、輸出與隱藏三種層次，屬類神經網路中之前饋式

網路。於學習過程中採用混合式學習(前階段之訓練採用非監督式學習，後階段之訓練則為監督式學習)之訓練方式，因此 RBFNN 可被切割為兩階段，前階段由輸入層至隱藏層將輸入資料依其相似程度予以自動分類，並經由輻狀基底函數之非線性轉換將訊息傳至後階段，而後階段則將隱藏層輸出之值加權後得到網路之輸出值。因縮減隱藏層為單一層次並直接以團塊分類法則歸結出適於描述系統之處理單元(神經元或輻狀基底函數)，故得以排除前述隱藏層層數與處理單元個數難以客觀取得之難題。

第一階段訓練採用非監督式學習，所進行的分類工作，採用之聚類演算法需能減少參數設定且兼顧模式之準確性要求，故研究修改傳統 RBFNN，以模糊最小最大分類法(Fuzzy min-max clustering)(Simpson 1993)取代前段之演算法(張斐章等 2000)。為使相似之事件儘可能歸於同一團塊，模糊理論被引進以歸納水文事件之相似性。模糊最小最大分類法之優點為無須預先設定大量之參數，並可自動推求處理單元(神經元或輻狀基底函數)之總數 J 與每一個基底函數的中心 μ 及其數據散佈特性 σ 。其學習過程可概分為四個步驟：即 1. 起始狀態、2. 擴展、3. 重疊檢測及 4. 壓縮等四項(如圖 2 所示)。其中，起始狀態預設所有團塊均為有機會學習之未激化團塊。擴展步驟則檢驗新的訓練資料是否激化新團塊抑或對既有團塊進行擴展；若當團塊可供擴展則擴展團塊範圍容納新加入之訊息點，否則擴展無效需另行激化新團塊。最後當團塊數及其特性均呈穩定後，此分類階段之學習工作即告完成。因此 RBFNN 非監督式學習階段主要之工作為決定隱藏層之輻狀基底函數個數及其參數值。

當非監督式學習完成時，則啟動第二階段網路訓練即監督式學習，進行工作主要為決定隱藏層與輸出層間之權重係數，本研究採用之演算法為最小平方推估法，目的在找尋總誤差平方和最小的最適化網路架構。其中，所使用之輻狀基底函數、模糊理論與團塊演算相關方程式及最小平方推估方程式如附錄。

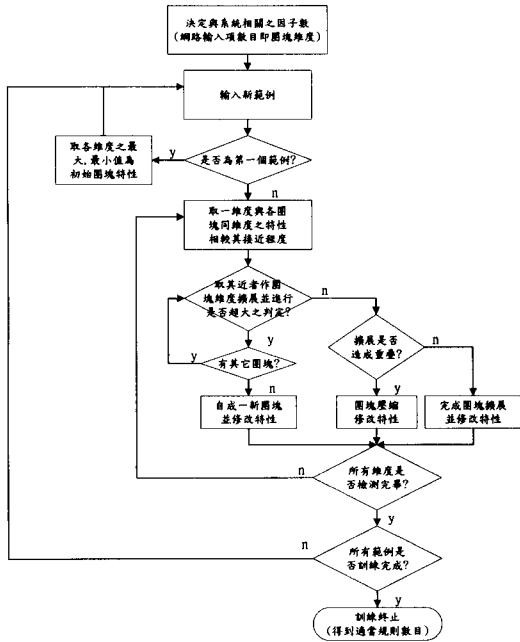


圖 2 圍塊分類流程

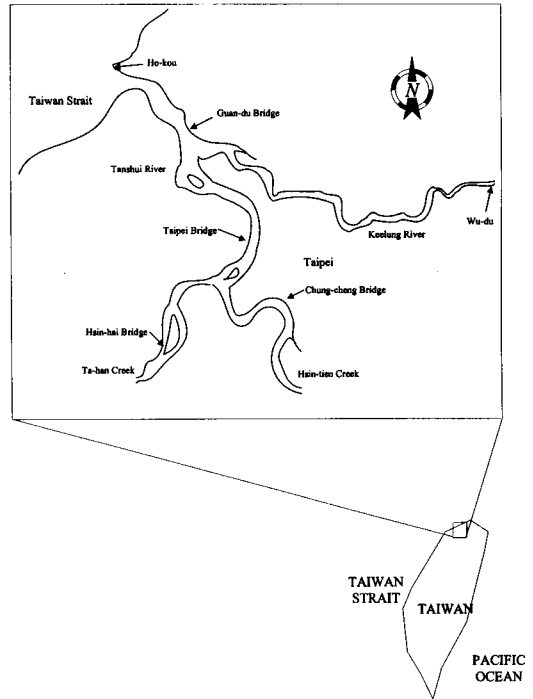


圖 3 研究區域位置

四、模式預測

當完成上述網路訓練後，模式所需輸入之唯一參數 θ 將被決定，RBFNN 中之輻狀基底函數個數與函數所需係數及隱藏層與輸出層間之係數將被自動調整到模式最佳化之狀態，因此在應用已架構完成之網路以預測水位時，則只需輸入網路所需之輸入資料，模式將自動對未來事件進行預測。

五、台北橋站水位預測

淡水河於台北附近匯聚大漢溪、新店溪及基隆河等三大支流，經狹隘之關渡溢口，於淡水附近注入台灣海峽，為台灣之第三大河流；其下游流經人口密集、地勢低窪之大台北地區，為保障人民生命及財產，政府已投入大量人力及物力完成大台北地區防洪計畫，但未來倘有天災如賀伯或象神颱風之事件時，其所造成之洪患仍有可能重創大台北地區，因此準確預測未來水位或流量以爭取預報時效，將成為淡水河系防洪之重要工作之一。由於淡水河系下游段的河道底床高程，

均低於海平面，平時受到天文潮之影響，其感潮河段之範圍可上溯至新店溪秀朗橋、大漢溪新海橋及基隆河汐止等地區，其影響之範圍如圖 3。故颱風時期感潮河段除受天文潮之影響外，亦受到颱風暴潮之影響，若天文潮及暴潮之影響在時間上一致，將產生相當嚴重之迴水影響，導致河水宣洩不及而造成重大災害。

為使台北橋站水位預測模式適切反映感潮河段之系統特性，RBFNN 於本研究所需之輸入資料為時間因子（陰曆之月、日與時資料）、及台北橋站本身及淡水河系鄰近測站之前三小時水位，輸出結果則為台北橋站未來一小時之水位預測。輸入資料中之時間因子可用以控制天文潮之特性；河口站之水位可用以控制颱風暴潮之效應；五堵站、中正橋站及新海橋站分別控制基隆河、新店溪及大漢溪等河川匯聚流量於淡水河之流量效應；土地公鼻站則控制海水漲落使流量回溯之效應，因此輸入層共有 21 個節點。本研究使用之資料由水利處第十河川局網站下載，因此只有 1996 年 7 月與 8 月之部分資料及 1997 年




圖 4 模式驗證之 RMSE 與隱藏層神經元數對 θ 之關係

1 月至 2000 年 12 月之資料可供使用，剔除不可用之資料後，尚有 22864 筆完整時水位資料。為建構完整之模式以準確預測台北橋站之時水位，所有可用之資料被分為三組（訓練組、驗證組及測試組），其中 1996 年 7 月至 1998 年 12 月之 13194 筆資料被用以訓練模式；1999 年 1 月至 12 月之 3399 筆資料用於決定最佳之模式；2000 年 1 月至 12 月之 6271 筆資料則用以測試模式之可靠性及準確性。

為求確立模式架構，透過不斷的改變分類演算之團塊擴展最大限度參數值 θ ，以訓練組之資料建構許多可能模式，再以驗證組之資料找尋可能之最佳模式，可得出如圖 4 所示驗證階段之 RMSE 與隱藏層神經元數對 θ 之趨勢關係。當 θ 為 0.175 時，模式之 RMSE 為最小，此時模式處於最佳化之狀態，其網路隱藏層具有 533 個輻狀基底函數（神經元）。圖 5 為當 θ 為 0.175 時模式於訓練階段之實測與預測水位之關係，其大部分之點皆落在 45 度線上，顯示模式於訓練階段可準確預測感潮河段之水位。圖 6 顯示訓練階段時期規模較大之水文事件，賀伯及瑞伯颱風之水位歷程圖。圓點為實測值而實線則為台北橋站未來一小時水位預測值，圖中包含水位於颱風時期前後受天文潮影響之變化及颱風期間受天文潮與暴潮影響之效應，當暴潮效應明顯較天文潮為大時，雖水位歷線將呈高度非規則性波動，但模式仍能準確掌握水位之變化。圖 7 與圖 8 分別為 $\theta=0.175$ 時模式於驗證與測試階段之實測與預測水位之關係，大部分之數據點均分佈於 45 度


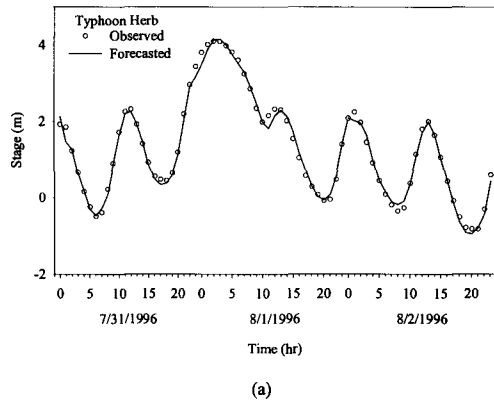
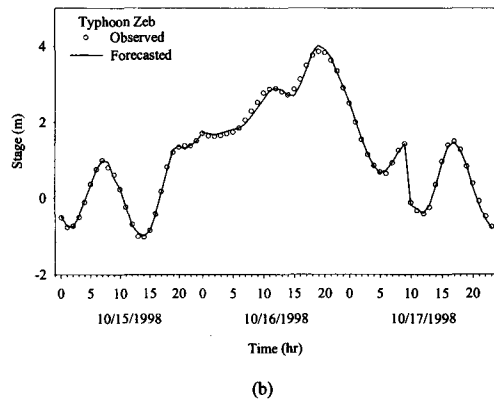


圖 5 模式訓練結果



(a)



(b)

圖 6 颱風時期之模式訓練結果：(a) 賀伯颱風 (b) 瑞伯颱風




圖 7 模式驗證結果




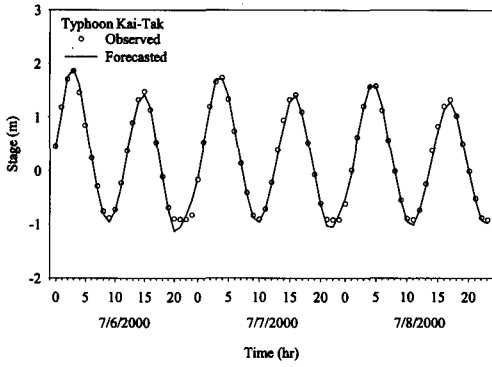
圖 8 模式預測結果

線上，僅有少數資料之預測具有較大偏估情形，其表示模式於驗證與測試階段仍能準確預測感潮河段之水位。為進一步了解模式於颱風時期對水位預測之能力，分別將中央氣象局所列於 2000 年對台灣有影響之颱風事件（啟德颱風、碧利斯颱風、巴比倫颱風、寶發颱風、雅吉颱風及象神颱風）的台北橋水位歷線繪於圖 9，其中最低水位時期常有定值水位記錄產生，主要肇因於實際水位已低於自計水位計之量測下限；而前 5 場事件的歷線特性顯示出期間雖有颱風生成，然其暴潮效應不若天文潮的影響為大，故台北橋之水位變化較具規律性，模式當然可準確預測感潮河段下一小時之水位。至於象神颱風侵台時期，因五堵站之水位計遭洪水淹沒，未能提供颱風末期之水位資料，因此模式也無法預測台北橋站於象神颱風末期之水位。此外，象神颱風水位預測之誤差較大，其乃肇因於高水位時期訓練資料之不足，若能收集更多之高水位資料以供網路訓練，將可改善此一現象。整體而言，類神經網路能對感潮河段水位作相當準確之預測。

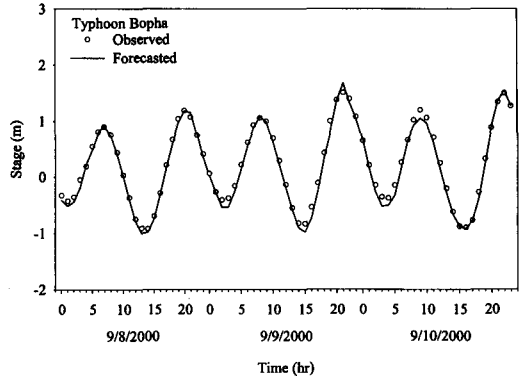
六、結 論

感潮河段水位受河川流量、天文潮及颱風暴潮等現象之影響，其變化複雜呈現高度非線性現

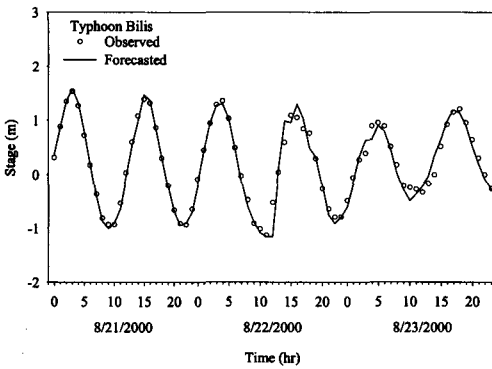
象，因此難以一般之傳統模式有效預測其變化。本文利用類神經網路中之 RBFNN 建構淡水河感潮河段台北橋站之水位預測模式，類神經網路可經由訓練過程自我學習，因此無需對系統之機制進行全盤之了解，而 RBFNN 之特性為可以一系列非線性輻狀基底函數之線性組合描述非線性之水文等現象，本研採用團塊法分類法以修改 RBFNN 前段之非監督式學習，由使用之團塊分類法直接取得網路架構隱藏層之處理單元數，所以省去傳統類神經網路對隱藏層層數及每層之單元數的迭代測試，因此可減少訓練時間及參數量之設定；此外利用簡單線性方式結合輻狀基底函數可降低模式之複雜度，亦使模式的運算趨於簡便。本模式最大優點之一為只需設定一個參數 θ ，而模式中各層所需之係數量則會自行決定，且這些係數亦會自動調整使模式達到最佳化之狀態。經由上述研究可知，類神經網路對於感潮河段水位漲落成因複雜的現象，雖未曾做出複雜的機制剖析，也不用受限於若干邊界或初始條件的設定，更無須預先對感潮河斷之水位進行分潮工作，僅需對系統之模擬標的（輸出項）挑選適當的對應輸入訊息，且經訓練階段學習歷史資料，由驗證階段挑選最佳之模式，即可經簡單運算後預測水位。本研究針對淡水河感潮河段所建



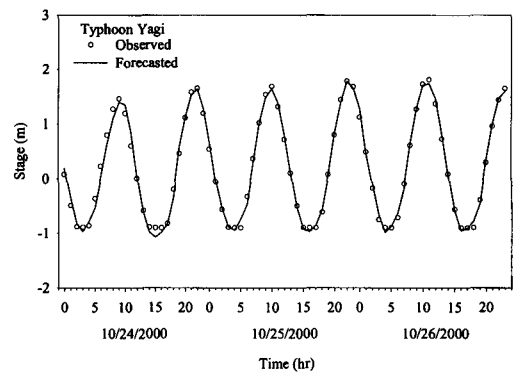
(a)



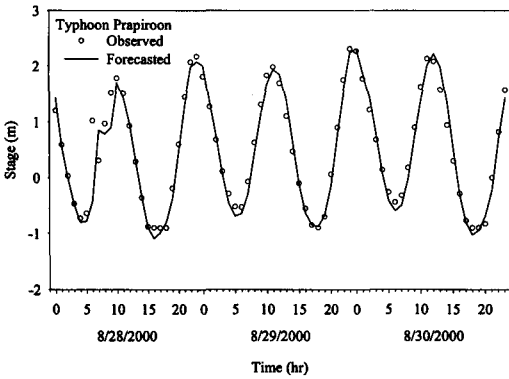
(d)



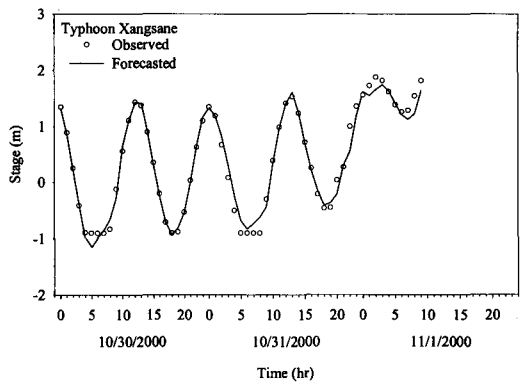
(b)



(e)



(c)



(f)

圖 9 颱風時期之模式預測結果: (a) 啟德颱風 (b) 碧利斯颱風 (c) 巴比侖颱風 (d) 寶發颱風 (e) 雅吉颱風 (f) 象神颱風

構之類神經網路水位預測模式，於 13194 個歷史資料只需用 533 個基底函數即可相當準確預測淡水河感潮河段台北橋站之下一小時水位，RBFNN

之訓練、驗證與測試結果均顯示類神經網路可應用於複雜之感潮河段水位預測。然本研究用於訓練階段之高水位時期的水位資料仍不足，若能收

集足夠之高水位時期水位資料以供網路訓練，將可再進一步改善模式預測之準確性及可靠性。

謝 誌

本研究蒙國科會計畫 NSC89-2313-B-002-239 之補助，謹此致謝。

參考文獻

- 張斐章、陳彥璋、梁晉銘、孫建平、黃源義 2000 “以輻狀基底函數網路建立降雨-逕流模式” 台灣水利，48(3):18-26。
- 梁晉銘、張斐章、陳彥璋 2000 “複合演算類神經-模糊推論模式應用於洪水預測” 中華水土保持學報，31(3):183-191。
- 陳昶憲、黃尹龍 2000 “倒傳遞與反傳遞類神經網路於洪流量預測之比較” 台灣水利，48(3):60-68。
- 蔡瀚陞 2000 淡水河口颱風暴潮水位之研究，國立臺灣大學土木工程學研究所碩士論文。
- 張斐章、孫建平 1998 “類神經網路及其應用於降雨-逕流過程之研究”，中國農業工程學報，44(1):34-49。
- 王如意、王志雄 1998 “小波複解析法之理論解析及其應用於淡水河感潮河段水位-流量率定曲線之修正” 台灣水利，46(4):1-21。
- 柳文成、許銘熙、郭義雄、郭振泰 1998 “感潮河川潮位調和分析之探討” 87 年度農業工程研討會論文集，149-155。
- 林淑真、李宗仰 1996 “自我聯合模式於感潮河段之水位預報” 土木水利，22(4):3-16。
- 顏沛華 1996 “曾文溪感潮河段水位自動化量測、預報及相關分析之研究(II)” 農業水利科技研究 85 年度計畫成果發表-河川治理及海岸保護技術研究論文集，1-20。
- 張斐章、黃源義、梁晉銘 1993 “模糊推論模式之建立及其應用於水文系統之研究”，中國農業工程學報，39(1)：71-83。
- 張斐章、黃源義 1992 “自組性演算法及其在降雨-逕流模式之應用”，國立臺灣大學農學院研究報告，32(4)：1-12。
- 許時雄 1989 淡水河預報模式之改進研究計劃
- (二) 行政院國家科學委員會防災科技研究報告 78-24 號，台灣省水利局第十工程處。
- Chang, F.-J. and Chen, Y.-C. 2001. “A counter-propagation fuzzy-neural network modeling approach to real time streamflow prediction.” *J. Hydrol.*, 245(1-4):153-164.
- Chang, F.-J., Liang, J.-M. and Chen, Y.-C. 2001. “Flood forecasting using radial basis function Neural Network.” Accepted by *IEEE Trans. Sys., Man and Cyber. Part C*.
- Chang, F.-J. and Hwang, Y.-Y. 1999. “A self-organization algorithm for real-time flood forecast.” *Hydrol. Process.*, 13:123-138.
- Dronkers, J., and Leussen, W. v. 1988. *Physical Processes in Estuaries*. Springer-Verlag, Berlin Heidelberg, Germany.
- Dyer, K. R. 2000. *Estuaries – A Physical Introduction*. Wiley, New York.
- Hass, L. W. 1977. “The effect of the neap-spring tidal cycle of the vertical salinity structure of the James, York, and Rappahannock Rivers, Virginia, USA” *Estuarine and Coastal Marine Science*, 5:485-496.
- Hsu, K. L., Gupta, H. V., and Sorooshian S. 1995. “Artificial neural network modeling of the rainfall-runoff process.” *Water Resour. Res.*, 31:2517-2530.
- Ivankhnenko, A. G. 1971. “Polynomial theory of complex system.” *IEEE Trans. Systems, Man, and Cybernetics*, SMC-1(4): 364~378.
- Kjerfve, B. 1988. *Hydrodynamics of estuaries – Volume I: Estuarine Physics*. CRC Press, Boca Raton, Florida.
- McCulloch, W. S., and Pitts, W. 1943. “A logical calculus of the ideas immanent in nervous activity.” *Bulletin of Mathematical Biophysics*, 5:115-133.
- Pritchard, D. W. 1952. “Estuarine hydrography.” in *Advances in Geophysics* Vol. 1, Academic Press

Inc., New York, 243-280.

Simpson, P. K. 1993. "Fuzzy min-max neural networks - part 2: Clustering." *IEEE Trans. Fuzzy Sys.*, 1(1): 32-45.

Stelling, G. S., Wiersma, A. K., and Willense, J. 1986. "Practical aspects of accurate tidal computation." *J. Hydr. Engrg.*, ASCE, 112(9).

收稿日期：民國 90 年 8 月 10 日

接受日期：民國 90 年 11 月 8 日

附 錄

本研究所使用之輻狀基底函數為 Gaussian 方程式，如下

$$z_j(x) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \dots\dots\dots(A1)$$

其中 x 為輸入向量； μ_j 為第 j 個基底函數中心； σ_j 為數據散佈特性； Z_j 為基底函數之輸出值。

新訓練資料與已存在團塊間之相似性，可藉由新資料點與每個團塊所對應之隸屬函數輸出值來推估得出；該隸屬函數可定義為一個二維函數 $H_j(x_h, V_j, U_j)$ ：

$$H_j(x_h, V_j, U_j) = \frac{1}{n} \sum_{i=1}^n [1 - f(x_{hi} - u_{ji}) - f(v_{ji} - x_{hi})] \dots\dots\dots(A2)$$

$$f(\tau, r) = \begin{cases} 1 & \tau > 1 \\ \tau \cdot \gamma & \text{if } 0 \leq \tau \leq 1 \\ 0 & \tau < 0 \end{cases} \dots\dots\dots(A3)$$

其中 $0 \leq H_j \leq 1$ ； v_{jn} 與 u_{jn} 分別為第 j 個團塊第 n 維度之最小與最大值。此一隸屬函數值大小可用來求出新訓練資料與既存團塊間之近似程度，而判斷出該點與哪一團塊先行擴展之順位。

權重 w 之調整，可藉由以誤差平方和 (Sum of squares error, SSE) 為目標函數進行，當 SSE 達到最小時，即可得最適參數 w 值。

$$SSE = \frac{1}{2} \sum_{j=1}^N \sum_{l=1}^L (y_{jl}^* - y_{jl})^2 \dots\dots\dots(A4)$$

式中之 y_{jl}^* 為輸出層第 l 個節點對第 j 個訓練範例之預測值， y_{jl} 為輸出層第 l 個節點對第 j 個訓練範例之觀測值， j 表範例數量之示標， N 為訓練範例量之總數， L 則為輸出層節點(處理單元)之總數。

而有關 (A4) 之估算，可藉由 (A5) 利用迴歸分析之最小平方方法推求得出

$$y = ZW + \epsilon \dots\dots\dots(A5)$$

其中， Z 、 w 、 ϵ 與 y 分別為基底函數輸出矩陣、待定參數向量、推估誤差向量及系統觀測值矩陣，所以待定參數向量 w 推估式可表如下式：

$$w = (ZZ^T)^{-1} Zy \dots\dots\dots(A6)$$

用以決定模式之 RMSE 如下式

$$RMSE = \sqrt{\frac{\sum (G_o - G_e)^2}{N}} \dots\dots\dots(A7)$$

其中 G_o 為水位觀測值； G_e 為水位推估值； N 表資料總數。