



# 結合類神經網路與小波分析 進行多源雨量融合及流量預測

江衍銘\* / 浙江大學水利工程學系水文與水資源研究工程所 副教授

李楠楠 / 浙江大學水利工程學系水文與水資源研究工程所 碩士

蔡可安 / 國立成功大學水利及海洋工程學系 碩士生

極端氣候導致自然災害頻傳，暴雨洪水成為了影響範圍最大、造成損失最嚴重的災害。降雨受到多種因素的影響，當我們使用單一的觀測方法對降雨進行解釋時，很難準確地對於該場暴雨進行描述，因此本研究通過融合不同的降雨資料對未來短時間內之流量對金華江流域進行預測，並考慮雨量序列複雜的時頻成分。本研究結合小波分析方法對兩種不同測量雨量（地面雨量計和 FY-2D 衛星反演雨量資料）的時頻特點進行組合與分析，結合神經網路的特性，提出三種不同的模型（「分解－單支重構－融合－預報－疊加」、「分解－融合－預報－疊加」與「分解－單支重構－融合－預報」模型）與僅通過簡單加權所產生的模型進行對比，最後根據金華江流域未來一小時流量預報結果對模型進行合理性及有效性的分析。結果顯示使用進行雨量融合的資料更能反映真實的降雨情況，根據權重可以判斷出不同雨量對融合雨量的影響，相較於未進行雨量融合的模型提高了準確度，且三個模型中「分解－單支重構－融合－預報－疊加」的表現最佳。

## 前言

洪水被視為常見且具有破壞性的災害之一，不僅影響的範圍廣大也時常造成嚴重的損失。近年來受到全球極端氣候的影響，全球各地皆飽受洪水災害的衝擊，根據 2019 年國家減災科學技術中心（National Science & Technology Center for Disaster Reduction, NCDR）<sup>[1]</sup> 的統計指出，當年全球的重大災害有將近五成成為洪水災害，這些事件造成了五千多人死亡。隨著全球暖化的影響，氣候變化加劇使得洪水強度增加，在經常受到梅雨與颱風侵襲的區域，容易產生降雨時空分佈不均，短時間的強降雨發生愈發頻繁，導致水災與旱災頻傳。

為了可以有效的降低暴雨對人們生活的影響，降雨資料的觀測與推估一直是水文研究領域的重要內容。提高洪水預報的準確性和時效性，讓我們可以更

精準的掌握洪水發生時的即時情況，因此，短期的洪水預報成為了水文領域關注的熱點。而產生預報的過程中，最重要的水文序列相關資料含有大量的非線性系統以及時空的變化，在複雜的資料下，模擬的結果無法得到很好的預測，因此如何讓資料可以有效運用是非常重要的。

過去傳統的洪水預測方法被認為效果不佳，2000 年由 Toth 等人 <sup>[2]</sup> 的研究指出在比較使用自回歸滑動平均模型（ARMA）、人工神經網路（ANN）以及 K-近鄰演算法（KNN）等三種時間序列分析技術的模型之後會發現，人工神經網路可以在短期的降雨預報中獲得較高的準確度。儘管使用 AN N 大量的數據作為模型的輸入，但它卻能夠有效地處理線性以及非線性的系統。

人工神經網路（ANN）在近幾年快速的發展且被廣泛應用在各個領域，例如語音辨識、醫學診斷及翻譯等。近幾年人工神經網路已經被證實可以成為一個有效的工具用來模擬複雜的水文系統，可以被用於流

\* 通訊作者，chiangym@zju.edu.cn

量模型、水質評估與懸浮顆粒預測等方向。人工神經網路利用可以自學的特性，在獲得大量數據資料的前提下能自動尋找到數據的特徵進而學習相關的資訊。然而，水文序列的非線性關係與時空的變化，有時會使模擬產生誤差。

小波轉換 (WT) 是一種有效的信號時頻分析工具，結合了傅立葉分析、數值分析等方法的優勢，可以被用來處理數據壓縮及信號分析。通過離散小波轉換可以對圖像及信號進行壓縮處理，使得壓縮過後的資料可以與原始資料有著相同的特徵。在訊號分析的方面，可以進行時頻分析、信號降噪及識別等；由於小波分析可以滿足信號時頻的局部化要求，使得信號通過小波分析後成為更加平順、頻率單一的序列。在實際情況中，可以將取得的離散時間序列使用離散小波轉換進行分解，得到較單一的時間序列，在通過疊加的方式重建出原始的訊號。

人工神經網路與小波分析在處理洪水預測時各有其優缺點，因此我們嘗試將人工神經網路與小波分析進行結合，擷取人工神經網路擅長學習以及小波分析可以使資料變得平順的優點，以取得更加準確的預測結果。2004 年吳東杰等人<sup>[3]</sup> 結合兩種方法來模擬地下水位，相較於過去傳統的人工神經網路模型有更準確的預測值。Adamowski 和 Chan<sup>[4]</sup> 在 2011 年時將離散小波轉換與人工類神經網路耦合，在對地下水位進行預測，他們發現耦合後的模型相比於傳統人工神經網路及自我迴歸整合移動平均線預測模型 (Autoregressive Integrated Moving Average model, ARIMA) 有更加良好的效能。

目前，降雨資料主要通過地面雨量站、雷達觀測與衛星觀測等三種方式，這三種方法在時間與空間上有著明顯的差異，地面雨量站最為直接，但受到雨量站位置影響能夠測量的區域固定；雷達與衛星測量屬於間接測量，主要通過大氣中與降雨相關的物理量來進行降雨的推測，而非直接降雨量的資料。我們利用將不同方法測得的資料進行整理和分析，結合小波分析與人工類神經網路進行洪水預測，並建構不同的組合的模式進行比較分析，對不同組合的模型進行效能評估，選出最優的模型架構；我們利用兩組不同的輸入數據 (地面觀測及衛星資料)，選擇包含更多有效雨量訊息的資料作為輸入值，並提供「分解－單支重構－融合－預報－疊加」、「分解－融合－預報－疊加」

與「分解－單支重構－融合－預報」三種結構的模型和直接將雨量進行加權融合的模型進行對比，由訓練結果選擇較優的模型。

本研究主要通過小波分析對不同方法測量的雨量資料 (地面雨量計與衛星反演雨量資料) 進行時頻分析擷取其特點並進行重組，相較於過去不考慮雨量資料中複雜的時頻成份以及不同的雨量之間的差異性，在經過小波分析後可以將不同雨量的時頻成份有效的融合，再使用小波類神經網路利用不同的架構模型對不同的雨量資料進行逕流分析的模擬進而產生洪水預報，最後根據預報的結果選擇結果較準確地進行權重融合，取得較有效的模型與雨量資料。

## 研究區域

金華江，又被稱之為婺江，位於中國浙江省金華市，由義烏江與武義江匯流而成，是省份境內的主要河流，也是錢塘江的重要支流。源頭位於磐安縣山環鄉嶺乾村的龍烏尖，流域面積約為 6781.6 平方公里，河川長度為 194.5 公里，平均流量為 153.4 立方公尺 / 每秒。上游主源為北江，位於山區，導致洪水發生頻繁，且常常伴隨土石流的發生，流入義烏境內後稱為義烏江，河道坡度趨於平緩。河川流域地貌屬於丘陵盆地，地勢南北高、中間低。

金華江流域位於北緯 28.5 ~ 29.5 度、東經 119.25 ~ 120.75 度之間，屬於四季分明的亞熱帶季風區，但受到盆地地形的影響，垂直高度落差較大，平均降雨量約為 1,500 mm。受到地形影響，迎風處的西南山區年平均降雨量可達 2,000 mm，反之，盆地底部區域與平原區域年降雨量僅有 1,300 mm 左右。除此之外，由於位於熱帶海洋氣團與極地大陸氣團的交界地帶，容易產生鋒面，導致春雨和梅雨的發生，使得降雨多集中在春夏兩季，造成頻繁的洪水災害。冬季在大陸冷氣團的影響下，形成高壓，導致降雨減少。

本研究採用的資料為金華江流域 2012 ~ 2014 年區域內流量站的監測數據，使用安文、佛堂、國湖與新建 4 個地面雨量站的測站資料 (圖 1)，以及來自 FY-2D 衛星的一小時降雨估計數據。

## 研究方法

### 小波分析 (Wavelet analysis)

小波分析是由傅立葉轉換發展而來的信號時頻工

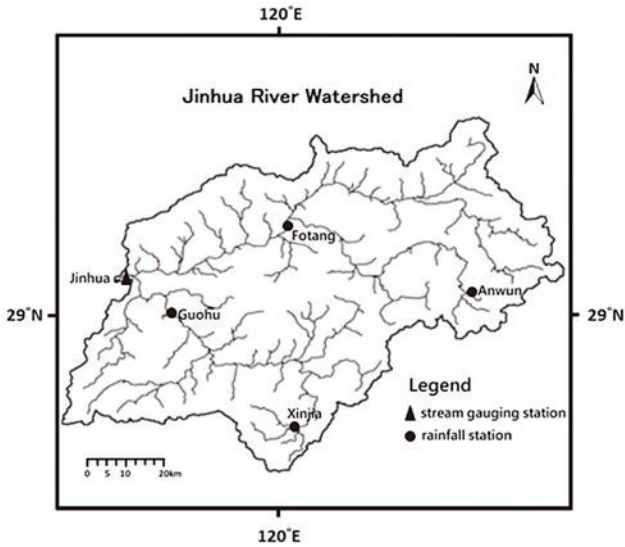


圖 1 金華江流域測站位置圖

具，但傅立葉轉換不能將時間和頻率訊息有效地結合起來，在傅立葉轉換之中資料從時域轉換到頻域，導致頻域中的時間訊息產生丟失。小波分析通過可被改變的時間和頻率窗口滿足時頻定位需求，從時頻分析的角度來看，雨量和徑流時間序列包含多種頻率成分，且具有各自的發展和演化過程。小波變換可以將非平穩的降雨和徑流時間序列分解為更加平滑和簡潔的序列。其次，小波分析的多分辨率分析特性有助於揭示隱藏在原始時間序列中的時頻特徵，因此，小波分析適合研究多時間尺度的非平穩降雨和徑流時間序列。近年來，小波分析發展迅速，應用廣泛，小波變換（WT）被認為能夠揭示其他時間序列分析技術可能遺漏的原始時間序列數據的各個方面，例如趨勢、故障點和不連續性。小波變換能將信號分解成低分辨率的信號。

### 人工神經網路 (Artificial Neural Networks, ANNs)

人工神經網路是藉由模仿人類神經元而形成的模型架構，最早相關資料為 1949 年提出的 Hebbian theory [5]，在 1958 年 Rosenblatt 架設了基礎的人工類神經模型，完成數學相關的建模 [6]，1989 年 LeCun 等人 [7]，成功將人工類神經網路應用在辨識手寫字體。

我們可以通過學習、儲存與記憶等方法，進行學習。人類神經元為大腦與外界交互的最基本單位，主要由樹突的部分作為接收訊息受器，神經的末梢通過與其他神經元突觸相連的方式傳遞訊息。人類大腦的運行就是透過這些神經元大規模的運作，才能快速處理各種訊息。

假設  $x_1, x_2, \dots, x_i, \dots, x_n$  為接收到來自其他神經元的信號，也就是該神經元的輸入， $w_{ji}$  為第  $i$  個與第  $j$  個神經元之間的權重， $b_j$  為第  $j$  個神經元的偏差值，將數值放入一個非線性轉換的函數，最後可以得到神經元的輸入總和  $s_j$ ，我們可以將  $s_j$  寫成以下形式：

$$s_j(t) = \sum_{i=1}^n w_{ji}x_i + b_j$$

將  $s_j$  通過激活函數  $f(s_j)$  後，可以得到該神經元的輸出  $y_j$ ：

$$y_j = f[s_j(t)]$$

### 倒傳遞神經網路

#### (Back Propagation Neural Network, BPNN)

倒傳遞神經網路 BNNN 屬於多層前饋式類神經網路，包含多個隱藏層，使用有監督的 BP 算法進行學習，其結構如圖 2。




圖 2 倒傳遞神經網路架構圖

BPNN 的各層神經元相互連接但同一層的神經元無法連接，多個隱藏層可以在輸入的樣本中找出更多有效訊息，建立更精準的模型。我們通過大量訓練來減少神經網路輸出 ( $y_k$ ) 與目標輸出 ( $d_k$ ) 之間的差距，將這個函數定義為 E：

$$E = \frac{1}{2} \sum_k (d_k - y_k)^2$$

BPNN 需要設計其網路結構以及參數率定，包含考慮使用多少層隱藏層、隱藏層內神經元個數及初始權重等，其中選擇神經元個數需要多次嘗試，過少會導致神經網路無法有效地描述問題，過多則會產生過度擬合問題的現象。

## 小波神經網路

2006年，Cannas 提出神經網路存在自身難以克服的局限性：如果不對輸入和輸出進行預處理的話，神經網路將無法對非平穩的資料進行有效分析。而小波變換被認為是能夠有效解決這個問題的一個強大工具，因為它可以同時在時域和頻域對信號進行分析，並通過小波變換將原序列有效分解為更平滑、單一的子序列，各子序列代表了原序列在不同時頻解析度上的有效組成成分。因此，近年來許多學者將傳統的非線性模型與小波變換耦合來提高模型性能。由於水文序列往往是非平穩序列，包含多種時頻成分，因此小波神經網路在水文領域的發展十分迅速，目前已有大量文獻提出多種耦合方法，並證明了小波變換與神經網路的結合對提高水文模型的性能大有裨益。

## 流量預測模型及評估指標

本文主要將由地面雨量計及衛星所估算的降雨量進行結合，通過小波分析取得較有效的雨量資料，並根據小波理論的特性，建立三種不同結構的模型框架，將取得的雨量融合資料輸入模型進行訓練並對逕流量進行預測，通過比較尋找最適合降雨-逕流預測模型，在本研究中資料時間尺度為小時（hourly）。

## 輸入變量選取

逕流量除了受降雨的影響外，與前幾時刻逕流也有十分密切的關係。為了確定輸入變數，我們首先對流量序列進行自相關分析，可以發現  $Q(t-1)$ 、 $Q(t-2)$ 、 $Q(t-3)$ 、 $Q(t-4)$ 、 $Q(t-5)$  與  $Q(t)$  密切相關，其自相關性可以達到 0.95 以上。因此，我們初步確定可能的輸入組合為表 1 中所示的 6 種情況。

為了確定最合理的輸入組合，我們建立一個簡單的 BP 神經網路，將上述 6 種輸入組合依次輸入，對未來一

小時流量進行預測。結果發現，模型 3、4、5、6 的預測結果差別很小，所以綜合模型表現和模型複雜程度，確定輸入組合為  $P(t-18)$ 、 $S(t-18)$ 、 $Q(t)$ 、 $Q(t-1)$ 、 $Q(t-2)$ 。

## 「分解—單支重構—融合—預報—疊加」模型（模型 A）

我們首先建立「分解—單支重構—融合—預報—疊加」模型，第一步先對收集到的地面雨量站資料使用 Daubechies Wavelet 函數（db）進行三次離散小波轉換，經過離散小波轉換後可以得到不同尺度上的小波函數序列包含一個趨勢子序列（GA3）以及三個細節子序列（GD3、GD2、GD1）。相同地，也利用 FY-2D 衛星反演資料得到趨勢子序列（SA3）以及三個細節子序列（SD3、SD2、SD1），以及由流量資料得到趨勢子序列（QA3）以及三個細節子序列（QD3、QD2、QD1）。取得各個子序列後，對這些子序列進行單支重構，將地面雨量站分解後的序列單支重構得到 GA3、GD3、GD2、GD1；FY-2D 衛星反演資料分解重構後得到 SA3、SD3、SD2、SD1；流量資料分解重構後得到 QA3、QD3、QD2、QD1。然後將地面雨量計的資料與 FY-2D 衛星雨量資料通過單支重構加權後求和並進行融合，假設當  $0 < v_1 < 1$ 、 $0 < v_2 < 1$  且  $v_1$ 、 $v_2$  分別表示地面雨量站與衛星反演數據的加權時，則該子序列的融合雨量（ $P_m$ ）可表示為  $P_m A3 = GA3 \times v_1 + SA3 \times v_2$ ，以此類推，可以由雨量觀測站與衛星觀測雨量的資料得到三組子序列的融合雨量，分別為  $P_m D3 = GD3 \times v_1 + SD3 \times v_2$ 、 $P_m D2 = GD2 \times v_1 + SD2 \times v_2$  和  $P_m D1 = GD1 \times v_1 + SD1 \times v_2$ 。將計算後的融合雨量作為模型的輸入，建立四個不同的 BP 神經模型，以不同尺度上預測未來  $n$  個小時流量分解序列作為模型輸出，透過訓練選擇出最佳權重組合，得到對應尺度上的未來  $n$  小時流量預報做為輸出結果  $Q'A3$ 、 $Q'D3$ 、 $Q'D2$  以及  $Q'D1$ 。將

表 1 模型可能的輸入組合

模型編號	輸入組合
1	*P(t-18)、S(t-18)、Q(t)
2	P(t-18)、S(t-18)、Q(t)、Q(t-1)
3	P(t-18)、S(t-18)、Q(t)、Q(t-1)、Q(t-2)
4	P(t-18)、S(t-18)、Q(t)、Q(t-1)、Q(t-2)、Q(t-3)
5	P(t-18)、S(t-18)、Q(t)、Q(t-1)、Q(t-2)、Q(t-3)、Q(t-4)
6	P(t-18)、S(t-18)、Q(t)、Q(t-1)、Q(t-2)、Q(t-3)、Q(t-4)、Q(t-5)

\*Q 代表流量，P 和 S 分代表地面雨量站雨量和衛星反演雨量

4 組輸出結果進行小波重構成為該 BP 神經模型的預報結果  $Q'$ ，最後，將 4 個模型所得到的流量預報結果進行疊加，即可獲得完整的流量預報結果  $Q'$  ( $Q' = Q'A3 + Q'D3 + Q'D2 + Q'D1$ )。流程圖如圖 3 所示。

### 「分解－融合－預報－疊加」模型（模型 B）

和「分解－單支重構－融合－預報－疊加」模型不同，第二種模型省去了單支重構得步驟，直接將對應尺度上的分解子序列利用加權的方式求和，做為融合雨量  $cP_m A3 = cGA3 \times v_1 + cSA3 \times v_2$ ,  $cP_m D3 = cGD3 \times v_1 + cSD3 \times v_2$ ,  $cP_m D2 = cGD2 \times v_1 + cSD2 \times v_2$  以及  $cP_m D1 = cGD1 \times v_1 + cSD1 \times v_1$ ，取得融合雨量後，與模型 A 相同，將融合雨量和流量作為模型的輸入，藉由 BP 神經模型進行訓練得到對應尺度上未來  $n$  小時逕流序列作為輸出，在訓練的過程中找出最佳權重組合，得到對應的預報結果  $cQ'A3$ ,  $cQ'D3$ ,  $cQ'D2$  和  $cQ'D1$ 。將 4 個模型所得到的流量預報結果進行疊加，即可獲得完整的流量預報結果  $Q'$  ( $Q' = cQ'A3 + cQ'D3 + cQ'D2 + cQ'D1$ )。流程圖如圖 4 所示。

### 「分解－單支重構－融合－預報」模型（模型 C）

「分解－單支重構－融合－預報」模型的方法與第一個「分解－單支重構－融合－預報－疊加」模型完全相同，差別在於當由 BP 神經模型進行訓練得到的對應尺度未來  $n$  小時逕流預報即為此模式的輸出，只需要單一個 BP 神經模型就可以進行，不需要用多個 BP 神經模型的輸出結果做疊加。流程圖如圖 5 所示。

### 評估指標

本文使用了以下四種指數作為評估指標，其中包含平均絕對誤差 (Mean Absolute Error, MAE)、相對平均誤差 (Relative Mean Error, RME)、均方根誤差 (Root-Mean-Square Error, RMSE) 和 Gbench 指數。平均絕對誤差 MAE 是將所有單次預測值與實際測量值之差的絕對值取平均，因為經過了絕對值所以誤差的正負不會抵銷，與平均誤差相比可以更好的反應預測誤差，MAE 可以被表示成以下方法：

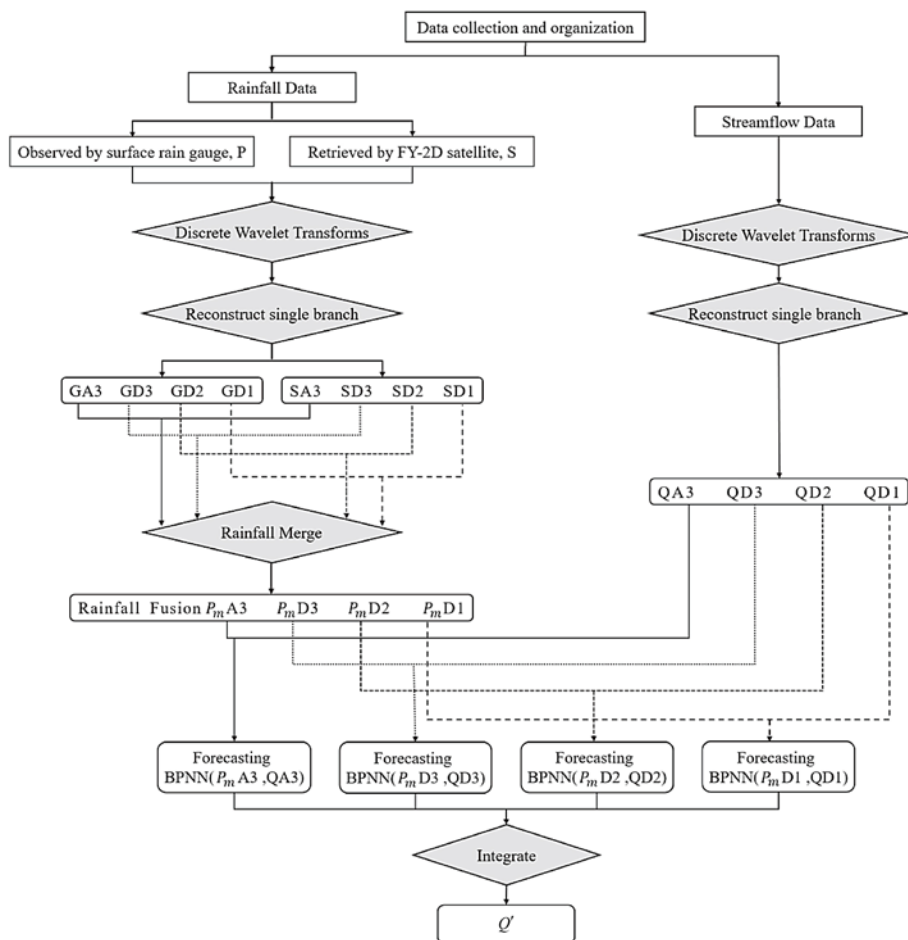


圖 3 「分解－單支重構－融合－預報－疊加」模型（模型 A）流程圖

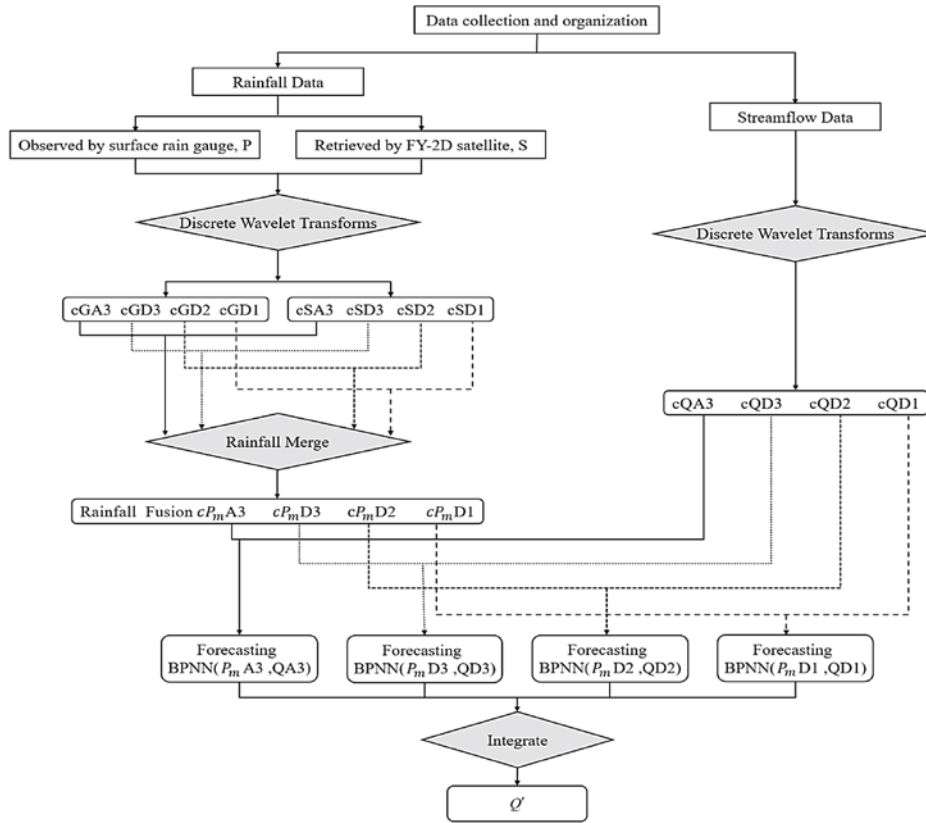


圖 4 「分解—融合—預報—疊加」模型（模型 B）流程圖

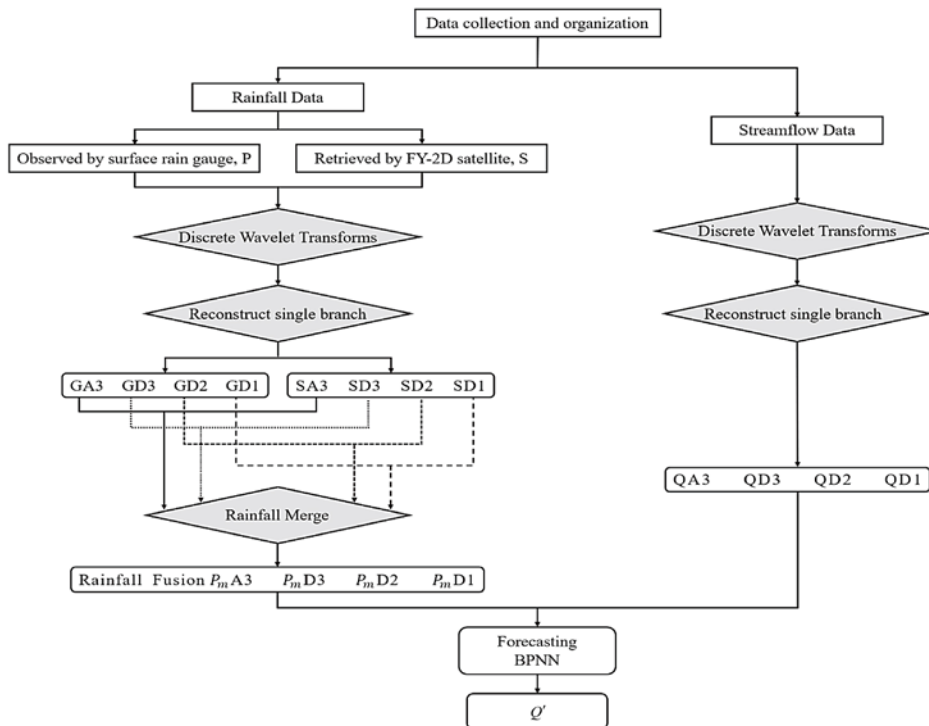


圖 5 「分解—單支重構—融合—預報」模型（模型 C）流程圖

$$MAE = \frac{1}{N} \sum_{t=1}^N |Q_{pre}(t) - Q_{obs}(t)|$$

其中  $N$  為數據組數， $Q_{obs}(t)$  和  $Q_{pre}(t)$  分別為在  $t$  時刻的

實際預測值和測量值，當 MAE 越小的時候表示該模型的精確度越高。

相對平均誤差 RME 為平均絕對誤差 MAE 與測量

平均值的比，一般來說 RME 比起 MAE 更能反應該預測的可信度，RME 越小表示模型的精確度越高。

$$RME = \frac{MAE}{\bar{Q}_{obs}} \times 100\%$$

$\bar{Q}_{obs}(t)$  為在  $t$  時刻內測量到逕流流量的平均值。

均方根誤差 RMSE 是預測值和觀測值差值平方與數據數量比值的平方根，它對於一次預測中極大或極小的誤差非常敏感，能夠反映出預測的精確度。

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N [Q_{pre}(t) - Q_{obs}(t)]^2}$$

其中， $N$  為數據數量， $Q_{obs}(t)$  和  $Q_{pre}(t)$  分別為  $t$  時刻的觀察流量與預測流量，RMSE 越小表示該模型的誤差越小。

我們用  $G_{bench}$  指數來評估模型在時間稽延方面的預報結果，其公式如下：

$$G_{bench} = 1 - \frac{\sum (Q_{obs}(t) - Q_{pre}(t))^2}{\sum (Q_{obs}(t) - Q_{bench})^2}$$

$N$  為數據數量， $Q_{obs}(t)$  和  $Q_{pre}(t)$  分別為  $t$  時刻的觀察流量與預測流量， $Q_{bench}$  為流量基礎序列，在本文中為  $Q_{obs}(t-1)$ 。 $G_{bench}$  指數變化區間為負無窮大到 1，越接近 1 時，準確度越高。

### 結果與討論

首先，我們對未進行融合雨量的模型做比較。由原始地面雨量站觀測的雨量資料 (P) 及前 3 小時的流量數據 (Q) 作為輸入的 BP 神經模型 BPNN-1 和由地面雨量站 (P) 結合 FY-2D 衛星測得雨量資料 (S)

及前 3 小時的流量數據 (Q) 作為輸入的 BP 神經模型 BPNN-2 進行比較。由兩組模型所產生的評估指標 RME、MAE 以及 RMSE 進行比較，可以推測出由兩項資料融合進行訓練的模型 BPNN-2 為較好的選擇，我們也可以推測是因為兩種數據裡包含了比一種數據更多的有效資料，如表 2。

根據我們所提出的三種方法「分解－單支重構－融合－預報－疊加」(模型 A)、「分解－融合－預報－疊加」(模型 B) 與「分解－單支重構－融合－預報」(模型 C) 建立三個不同的模型，將這三種模型與只使用簡單加權融合模型 (模型 D) 進行比較。我們分別將四種模型簡稱為模型 A、模型 B、模型 C 及模型 D，其中模型 A、B、C 分別為我們提出的三種架構模型，模型 D 為簡單加權模型。我們列出四種模型對未來 1 小時流量進行預報的結果 (表 3 及圖 6)，可以發現在三個指標上，四種融合模型皆優於 BPNN-1 與 BPNN-2，也可以發現將資料經過三種方法後當作模型的輸入相較單純將

表 2 未雨量融合模型 1h 流量預報結果對比

模型	BPNN-1	BPNN-2
模型輸入	P(t-18)、Q(t)、Q(t-1)、Q(t-2)	P(t-18)、S(t-18)、Q(t)、Q(t-1)、Q(t-2)
<b>Training</b>		
RME	6.39%	6.30%
MAE	38.46	37.95
RMSE	70.3	65.48
<b>Validation</b>		
RME	7.10%	6.31%
MAE	44.39	39.44
RMSE	74.46	66.04
<b>Testing</b>		
RME	10.06%	9.50%
MAE	55.63	52.53
RMSE	78.02	71.92

表 3 融合模型未來 1 小時流量預測結果對比

模型	分解－單支重構－融合－預報－疊加 (模型 A)	分解－融合－預報－疊加 (模型 B)	分解－單支重構－融合－預報 (模型 C)	簡單加權融合模型 (模型 D)
<b>Training</b>				
RME	0.99%	1.01%	3.79%	3.07%
MAE	6.01	16.11	22.81	18.48
RMSE	9.88	19.64	37.55	32.99
<b>Validation</b>				
RME	2.57%	4.57%	4.16%	5.96%
MAE	16.07	28.56	26.00	37.22
RMSE	22.08	37.44	39.11	61.76
<b>Testing</b>				
RME	5.50%	5.43%	6.34%	9.26%
MAE	31.81	30.04	35.08	45.70
RMSE	37.01	39.72	43.36	64.26

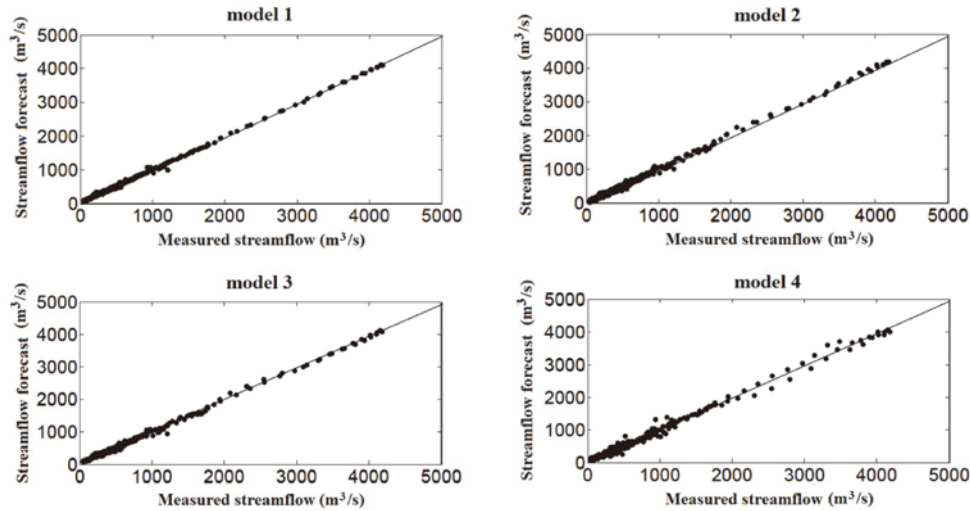


圖 6 融合模型的測試階段的未來 1h 流量預報散布圖

原始資料輸入模型，處理過的資料可以取得表現更好的預報，說明經過融合的雨量資料會比單一的雨量更能表現出真實的降雨情況。在訓練階段，模型 A、B 的結果優於另外兩個模型，但到了驗證階段，模型 A 表現的最優秀，而測試階段模型 A、B、C 明顯優於模型 D。

將預測結果使用散佈圖表示（圖 6），可以明顯發現模型 A、B、C 更加集中，而模型 D 的流量預測結果與實際流量的擬合度較差。模型 A 的點幾乎都落在 45 度理想線上，不同流量下也沒有落差特別明顯的區域；模型 B、C 大致趨勢也都落在 45 度理想線上，但當流量位於 2,000 ~ 3,000 立方公尺 / 每秒時，誤差明顯比較大，而模型 D 則在大於 2,000 立方公尺 / 每秒的區域皆有較大的誤差。因此，我們可以初步判斷經過小波分析的融合雨量相較於簡單加權的模型 D 有更好的表現，說明雨量融合可以使雨量資料變得更有效。

圖 7 是 4 個融合模型對測試階段的 5 次洪峰預報的相對誤差（單次洪峰流量預報值和實測值相對誤差）。

我們假設準確度超過 90% 以上為該預測資料合格的情況下，分析在測試階段的 5 筆洪峰流量資料（圖 7），模型 A 與模型 B 的合格率皆可以達到 80% 以上，而模型 D 只有 40%。此外，4 個模型對第 1、2、4 次洪峰的預報效果較好，而對第 3 次和第 5 次洪峰的預報效果較差，這 5 次洪峰的實測洪峰流量分別為 918 m<sup>3</sup>/s、1,160 m<sup>3</sup>/s、555 m<sup>3</sup>/s、4180 m<sup>3</sup>/s 和 511.5 m<sup>3</sup>/s，所以 4 個融合模型對高流量洪峰的預測效果比低流量洪峰的預測效果更好。

四種模型對於測試階段的五組數據產生的預報以及實際測量值的比較，可以看出預測結果整體趨勢與實際測量相同，但代表模型 D 在較大或較小的流量時，產生的誤差較其他三組模型大，也可以從圖中發現模型 B 在預測較小流量的時候產生的誤差較其他模型明顯，有可能是因為模型 B 在模型的架構上缺少了單支重構的部分直接進行了雨量融合與預測，使得資料在訓練時頻率混亂。

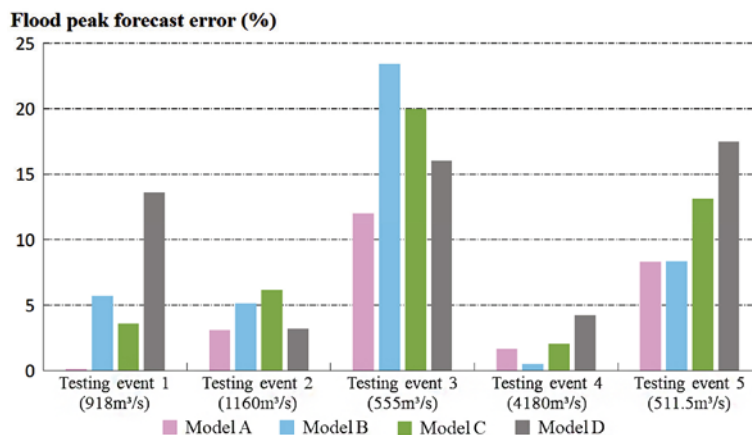


圖 7 各融合模型對測試階段的 5 次洪峰預報的相對誤差



表 4 我們列出平均相對偏差值與平均絕對偏差值在三個不同的訓練階段，平均絕對偏差值為該測量結果與實際測量結果差值得平均，平均相對偏差值測量結果與實際測量結果差值比例得平均，這兩項數據可以簡單地表示整個模型的效能，可以看出模型 a 在三個階段的表現都非常優秀，模型 B 的訓練階段與模型 A 效能差不多，但到了驗證與測試的時候模型 B 明顯較模型 A 差，而模型 D 呈現的效果為最差的。

表 4 各融合模型的洪峰流量預報效果

模型	模型 a	模型 b	模型 c	模型 d
<b>Training</b>				
洪峰相對平均偏差	0.37%	0.34%	2.68%	1.34%
洪峰平均絕對偏差	7.11	6.60	51.27	25.56
<b>Validation</b>				
洪峰相對平均偏差	1.07%	2.10%	3.34%	3.60%
洪峰平均絕對偏差	18.70	36.73	58.56	63.03
<b>Testing</b>				
洪峰相對平均偏差	3.01%	4.14%	5.01%	7.05%
洪峰平均絕對偏差	42.83	60.77	73.36	103.27

結合以上結果我們可以推論當我們要選定輸入的數據時，融合地面雨量站與衛星反演資料的 BPNN-2 會比單純只有地面雨量站數據的 BPNN-1 表現得更好，說明當有兩種雨量資料的時候，數據中含有更多的有效的雨量訊息，當使用 BPNN-2 的資料時，四種模型可以相對比使用 BPNN-1 時有更好的表現。建立的四種小波神經網路模型中，以模型 A 的效能最優，在全部的流量下皆有穩定的表現，模型 B 整體而言與模型 a 相差無幾，但模型 B 在較小的流量時容易產生較大的誤差，可能與在小波分解和重構的過程產生頻率的混淆有關，導致在低流量較不穩定，模型 C 為我們提出的三個模型中最差的，但依然優於模型 D。模型 D 為四個模型中預報效果最差的模型，預測的結果十分不穩定且誤差較其他三個模型大，也可以說明使用小波分析後所產生的模型較簡單加權後產生的模型更優。

### 結論

根據過去的資料我們可以發現，雖然過去的模型也有使用雨量融合的方法，但大多數皆是屬於直接對雨量進行融合，缺乏考慮到雨量資料本身的時間、頻率成分。本研究結合了小波分析對雨量的時間、頻率特點進行分析，使用分析後的資料結合類神經網路的

特性，提出了三種雨量融合的方法「分解－單支重構－融合－預報－疊加」、「分解－融合－預報－疊加」與「分解－單支重構－融合－預報」並將這三種模型與僅用地面觀測雨量推估 (BPNN-1)、單純輸入地面及衛星雨量 (未結合小波分析之 BPNN-2) 以及只通過簡單加權的模型進行比較。我們可以發現離散小波轉換可以有效地讓雨量序列變得頻率更加單一且平順，同時保有其特徵，也可以藉由分解出來的趨勢子序列分析原始數據中的主要趨勢。在輸入的部分，包含地面雨量站觀測值與 FY-2D 衛星反演資料的 BPNN-2 比起單純由地面雨量站進行計算的 BPNN-1 包含更多有效的雨量訊息，證實多種資料可以取得比單一雨量更加有效的輸入。比較的四種模型中，模型 A 的效能最出色且穩定，無論在任何流量的預測都比其他幾個模型更加穩定；模型 B 體來上來說較模型 A 遜色，但在高流量的區域表現出色；模型 C 相對模型 A 與 B，但依舊比模型 D 還要精準；模型 D 整體表現最差，不僅誤差大，穩定性也較低。

小波分析中如何選擇函數是十分重要也是最困難的一點，如何更加有效率地找到適合的小波函數是未來可以研究的方向。我們通過結合小波分析與類神經網路的特點來架構模型，但除此之外也許還有其他的組合方法可以得到更優秀的模型，也許使用更多方法獲取有效的資料也是未來可能考慮的方向。

### 參考文獻

1. National Science and technology Center for Disaster Reduction, NCDR, New Delhi, India, Mar. 2020.
2. E.Toth,A. Brath, and A. Montanari, (2000).“Comparisonofshort-termrainfall prediction models for real-time flood forecasting.” *J. Hydrol*, Vol. 239, Nos. 1-4, pp. 132-147.
3. 吳東杰、王金生、滕彥國 (2004)，小波分解與變換法預測地下水位動態 [J]，*水利學報*，(5)，39-45.
4. Adamowski, J. and Chan, H.F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *J. Hydrol.* **407** (1-4), 28-40.
5. R.G. MorrisandD. Hebb, *TheOrganizationofBehavior*. New York, NY, USA: Wiley, 1949.
6. F. Rosenblatt, (1958). “The perceptron: A probabilistic model for information storage and organization in the brain,” *Psychol. Rev.*, Vol. 65, No. 6, 386p.
7. Y. LeCun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, and L.D. Jackel, (1989). “Backpropagation applied to handwritten zip code recognition.” *Neural Comput*, Vol. 1, No. 4, pp. 541-551.