附件二

計畫編號：108 保發-10.1-保-01-06-001(19)

機器學習結合數值模式預報集水區土砂收支

Interdisciplinary application of machine-learning methods and numerical models to predict the sediment load in the watershed

（期末報告）

執 行 單 位：國立台灣大學

執 行 期 間：108 年 2 月 20 日至 108 年 12 月 31 日

計畫主持人 ：何昊哲 助理教授

行政院農業委員會水土保持局 編印

中華民國 108 年 11 月

（本報告書內容及建議純屬執行單位意見，僅供本局施政參考）

機器學習結合數值模式預報集水區土砂收支

摘要

台灣地理位置特殊，是複合型自然災害高危險區。過去集水區的土砂災害事都是以物理模式進行模擬各種情境，研析各種情境之模擬結果，僅能用於平日探討災害發生成因與減災之策略擬定，與實際災害發生成因、位置與規模仍有差距。土砂收支的預報模式，能有助於集水區的土砂管理，提早做出災害因應。本研究欲以機器學習結合數值模式的方法，提出一個透過前端的水文資料，預估流經一系列的防砂壩後的土砂流量。

機器學習具有模擬非線性系統、推估運算快速與持續學習之優勢，從最直接的降雨-逕流關係、水砂運移機制到複雜的集水區土石崩塌位置、規模等問題，皆可以機器學習進行分析、推估與預報。數值模式則是可提供不同情境的模擬結果，可根據需求調整不同參數產生許多的模擬資料。

本計畫以大漢溪流域為研究範圍，透過美國陸軍工兵團所發展之水文模式(HEC-HMS)進行流量模擬作為土砂模擬的輸入條件，並結合美國墾務局所發展之水理輸砂模式(SRH-2D)進行河道土砂運移模擬，產生模擬的大數據來提供機器學習足夠之學習資料量，希望透過 AI 為基礎的模式來描述集水區土砂生產、搬運流出、殘留淤積等各種複雜之物理過程，找到土砂收支與上游水文條件的關係式，用來準確推估土砂流量。

關鍵詞：機器學習、土砂收支、類神經網路、MUSLE、SRH2D

Interdisciplinary application of machine-learning methods and numerical models to predict the sediment load in the watershed

Abstract

There are about three to four typhoons hit Taiwan each year. The typhoon caused the huge increase of the discharge in the upstream catchment. It would also increase the sediment load flushed into the catchment. The estimation of sediment budget in the catchment area is very difficult. This study will conduct numerical models MUSLE and SRH2D to establish the numerical simulation for sediment estimation. With appropriate assumptions, we will build up the prediction model based on neural network (ANNs). This study propose the combination of machine learning and sediment numerical models to fulfill the sediment budget prediction. A reliable and efficient forecasting model can help the management unit to establish the early-warning system in the future.

Keywords: Machine-learning, Sediment budget, ANNs, MUSLE, SRH2D

目次

摘要 ..... **I**

Abstract ..... **III**

目次 ..... **IV**

表次 ..... **VI**

圖次 ..... **VIII**

第一章　緒論 **1**

1.1　計畫緣起 1

1.2　計畫目標 2

1.3 擬解決的問題 3

第二章　工作執行方法與步驟 **4**

2.1　文獻回顧 4

2.2　工作執行方法 6

2.3　工作執行步驟 7

第三章　工作進度與交付項目 **15**

3.　計畫甘特圖 15

3.1　基本資料蒐集 **16**

3.1.1 地形資料 16

3.1.2 水文資料 19

3.1.3 曼寧 n 值 25

3.1.4 上游入砂濃度設置 27

3.1.5 輸砂動床參數設置 28

3.2　水文分析 **30**

3.2.1　HEC-HMS 模式 30

3.3　河道輸砂分析 **43**

3.3.1 SRH-2D 模式 43
3.3.2 評估標準 50
3.3.3 水理參數率定 51
3.3.4 輸砂動床參數率定 56
3.4 設計暴雨分析 58
3.4.1 降雨分析 58
3.4.2 暴雨頻率分析 64
3.4.3 降雨強度公式 67
3.4.4 設計雨型 73
3.5 類神經網路 78
3.5.1 倒傳遞類神經網路(BPNN).....81
3.5.2 幅狀基底類神經網路(RBFNN) 90
3.5.3 長短時記憶網路類神經網路(LSTM).....96
3.6 預報模式建立 101
3.6.1 模擬結果比較 107
第四章 結論及預計可能遭遇之困難 114
4.1 結論.....114
4.2 預計可能遭遇之困難 116
參考文獻.....117

表次

表 3.1　進度甘梯圖 15
表 3.1.1 曼寧 N 值分佈 25
表 3.1.2 漫地流糙度係數 26
表 4.1.6 本研究採用之各種參數說明 29
表 3.2.1 表土質地分類 36
表 3.2.2 土地利用分類 37
表 3.2.3 HEC-HMS 初步模擬之採用參數表 38
表 3.2.4 各測站徐昇式分配權重 40
表 3.3.1 不同曼寧 N 值流量、水位均方根誤差比較表 54
表 3.4.1 霞雲站各延時之年最大暴雨量序列單位：MM 59
表 3.4.2 高義站各延時之年最大暴雨量序列單位：MM 59
表 3.4.3 嘎拉賀站各延時之年最大暴雨量序列單位：MM 60
表 3.4.4 玉峰站各延時之年最大暴雨量序列單位：MM 61
表 3.4.5 巴陵站各延時之年最大暴雨量序列單位：MM 61
表 3.4.6 白石站各延時之年最大暴雨量序列單位：MM 62
表 3.4.7 西丘斯山站各延時之年最大暴雨量序列單位：MM 63
表 3.4.8 選定之機率分布 65
表 3.4.9 霞雲站各延時雨量之機率分布套配 65
表 3.4.10 高義站各延時雨量之機率分布套配 65
表 3.4.11 嘎拉賀站各延時雨量之機率分布套配 65
表 3.4.12 玉峰站各延時雨量之機率分布套配 66
表 3.4.13 巴陵站各延時雨量之機率分布套配 66
表 3.4.14 白石站各延時雨量之機率分布套配 66
表 3.4.15 西丘斯山站各延時雨量之機率分布套配 66

表 3.4.16 霞雲站 HONOR 公式參數..... 72
表 3.4.16 高義站 HONOR 公式參數..... 72
表 3.4.17 嘎拉賀站 HONOR 公式參數..... 72
表 3.4.18 玉峰站 HONOR 公式參數..... 72
表 3.4.19 巴陵站 HONOR 公式參數..... 73
表 3.4.20 白石站 HONOR 公式參數..... 73
表 3.4.21 西丘斯山站 HONOR 公式參數..... 73
表 3.6.1 訓練、測試基本資料..... 102
表 3.6.2 情境一、二配置圖..... 106
表 3.6.3 各神經網路之配置情形..... 107
表 3.6.4 BPNN 神經元配置..... 107
表 3.6.5 RBFNN 神經元配置..... 107
表 3.6.6 LSTM 神經元配置..... 108
表 3.6.7 情境一不同流量組合下對於砂量預測的結果比較.....110
表 3.6.8 情境二不同流量、砂量組合下對於砂量預測的結果比較 110
表 3.6.9 不同時刻之預報結果.....111

圖次

圖 2.3.1 石門水庫集水區行政區位置.....7
圖 2.3.2 大漢溪各支流分布.....8
圖 2.3.3 石門水庫集水區內之雨量站與水文觀測站位置圖.....9
圖 2.3.4 預報模式建立的流程圖.....11
圖 2.3.5 柏拉圖最佳解示意圖 12
圖 2.3.6 BPN 架構圖..... 13
圖 2.3.7 SVM 架構圖..... 13
圖 3.1.1 本研究使用之初始地形（綠線為研究區域） 17
圖 3.1.2 大漢溪流域網格..... 18
圖 3.1.3 大漢溪邊界配置情形..... 20
圖 3.1.4 潭美颱風玉峰水文站流量歷線..... 21
圖 3.1.5 潭美颱風稜角水文站流量歷線..... 21
圖 3.1.6 潭美颱風雲霞水位站水位歷線..... 22
圖 3.1.7 菲特颱風玉峰流量站流量歷線..... 23
圖 3.1.8 菲特颱風稜角流量站流量歷線..... 23
圖 3.1.9 菲特颱風霞雲水位站水位歷線..... 24
圖 3.1.11 表面粒徑採樣點分布 26
圖 3.1.12 石門水庫集水區曼寧 N 值分布..... 27
圖 3.2.1 HEC-HMS 模式建置流程..... 32
圖 3.2.2 大漢溪流域 HEC-HMS 水文模式建置示意圖..... 33
圖 3.2.3 大漢溪土壤分布 36
圖 3.2.4 子集水區分區編號..... 38
圖 3.2.5 大漢溪流域徐昇網..... 39

圖 3.2.6 潭美颱風最佳化參數模擬結果 41
圖 3.2.7 潭美颱風事件 42
圖 3.3.1 活動層定義圖 47
圖 3.3.1 不同 N 值之水位、流量模擬結果比較 52
圖 3.3.2 N=0.03 潭美颱風水位、流量模擬結果比較 53
圖 3.3.2 N=0.03 之菲特颱風水位、流量模擬結果比較 55
圖 3.3.3 PARKER 公式不同調適長度 RMSE 值 57
圖 3.3.4 MPM 公式不同調適長度 RMSE 值 57
圖 3.4.1 霞雲站不同重現期之降雨強度延時頻率曲線 68
圖 3.4.2 高義站不同重現期之降雨強度延時頻率曲線 68
圖 3.4.3 嘎拉賀站不同重現期之降雨強度延時頻率曲線 69
圖 3.4.4 玉峰站不同重現期之降雨強度延時頻率曲線 69
圖 3.4.5 巴陵站不同重現期之降雨強度延時頻率曲線 70
圖 3.4.6 白石站不同重現期之降雨強度延時頻率曲線 70
圖 3.4.7 西丘斯山站不同重現期之降雨強度延時頻率曲線 71
圖 3.4.8 霞雲站 2 年重現期之降雨組體圖 75
圖 3.4.9 霞雲站 5 年重現期之降雨組體圖 75
圖 3.4.10 巴陵站 2 年重現期之降雨組體圖 76
圖 3.4.11 巴陵站 5 年重現期之降雨組體圖 76
圖 3.4.12 玉峰站 2 年重現期之降雨組體圖 76
圖 3.4.13 玉峰站 5 年重現期之降雨組體圖 76
圖 3.4.14 白石站 2 年重現期之降雨組體圖 76
圖 3.4.15 白石站 5 年重現期之降雨組體圖 76
圖 3.4.16 西丘斯山 2 年重現期之降雨組體圖 77
圖 3.4.17 西丘斯山 5 年重現期之降雨組體圖 77

圖 3.4.18 高義站 2 年重現期之降雨組體圖 77
圖 3.4.19 高義站 5 年重現期之降雨組體圖 77
圖 3.4.20 嘎拉賀站 2 年重現期之降雨組體圖 77
圖 3.4.21 嘎拉賀站 5 年重現期之降雨組體圖 77
圖 3.5.1 BP 神經網路結構 81
圖 3.5.2 活化函數形式 83
圖 3.5.3 神經網路運算流程 88
圖 3.5.4 饋式類神經網路架構 90
圖 3.5.5 輸入資料與網路連結的介面層 91
圖 3.5.6 非線性轉換至隱藏層的介面層 91
圖 3.5.7 將隱藏層的輸出進行線性組合的介面層 92
圖 3.5.8 高斯函數圖 93
圖 3.5.9 長短期記憶類神經網路之網路運行式意圖 97
圖 3.5.10 橫貫所有單元，帶著「記憶」的 CELL STATE 圖 98
圖 3.5.11 邏輯函數示意圖 98
圖 3.5.12 邏輯函數示意圖 99
圖 3.5.13 邏輯函數示意圖 99
圖 3.5.14 邏輯函數示意圖 100
圖 3.6.1 預報模式的流程圖 101
圖 3.6.1 流量歷線圖 103
圖 3.6.2 砂量歷線圖 103
圖 3.6.4 情境一(SET2)之 BPNN 相關係數圖 112
圖 3.6.5 情境二(SET4)之 RBFNN 之砂量歷線圖 112
圖 3.6.6 情境二(SET4)之 RBFNN 相關係數圖 113
圖 3.6.7 情境二(SET4)之 RBFNN 砂量歷線圖 113

第一章　緒論

1.1　計畫緣起

近年來由於氣候變遷的影響，極端天氣現象致使自然災害頻發，災害防治的相關議題更趨重要。台灣地理位置特殊，除位處颱風路徑上之外，更位於環太平洋地震帶，是複合型自然災害高危險區。要提升應變與救災之時效性，更須藉由新的科技或技術進一步地預知災害發生時間、位置與規模，可在災害發生前，先進行整備、擬定疏散或救災策略與行動，有效地降低生命財產損失，甚至可避免災害帶來的威脅。過去集水區的土砂災害在事先以物理模式進行模擬各種情境，研析各種情境之模擬結果，僅能用於平日探討災害發生成因與減災之策略擬定，與實際災害發生成因、位置與規模仍有差距。而現場量測，主要還是借重無人機、LiDAR、航照或是衛星影像在災害發生前後資料比對來進行研究，受限於災害發生時的資料取得困難，對於災害的預報還是有許多不足之處。用 AI 技術整合具有空間與時間分布之歷史觀測數據於防災科技中，研發特定災害預報模式，如河道水砂運移推估模式、集水區土石崩塌位置與範圍推估模式等，是現階段的研究熱點，不過 AI 對於資料量要求有一定的限制，目前我國在極端事件下的現場土砂資料還稍顯不足，需經過一段時間的儀器佈建才能確實利用觀測大數據研發土砂預報模式。

土砂收支的預報模式，能有助於集水區的土砂管理，提早做出災害因應。本計畫欲以機器學習結合數值模式的方法，提出一個透過前端的水文資料，預估流經一系列的防砂壩後的土砂流量。機器

學習具有模擬非線性系統、推估運算快速與持續學習之優勢，從最直接的降雨-逕流關係、水砂運移機制到複雜的集水區土石崩塌位置、規模等問題，皆可以機器學習進行分析、推估與預報。數值模式則是可提供不同情境的模擬結果，可根據需求調整不同參數產生許多的模擬資料。本研究利用數值模式產生模擬的大數據來提供機器學習足夠之學習資料量，冀望透過 AI 為基礎的模式來描述集水區土砂生產、搬運流出、殘留淤積等各種複雜之物理過程，找到土砂收支與上游水文條件的關係式，可以準確推估土砂流量。在面對未來氣候變遷可能造成之更大之災害，以 AI 模式進行情境推估，比起一般物理模式重新建模、調整參數等，更為快速與準確。

1.2 計畫目標

本計畫目標擬發展可靠的土砂收支預報模式將有助於集水區土砂管理、下游災害預警、水庫防洪防淤操作。本計畫致力於發展一套能有效預測自集水區源頭至下游水庫土砂運移型態的方法，透過機器學習法快速預測集水區土砂未來 1~6 小時的空間與時間變化關係。

將本研究前期以資料分析為主。完成資料分析後則可依序進行數值模式檢定驗證及機器學習訓練測試。最後發展出土砂收支預報模式，並用於颱風時期災害即時預警。下列四點為預期完成目標:

(1)監測資料蒐集;

(2)數值模式檢定及驗證;

(3)機器學習訓練及測試;

(4)土砂災害預警。

1.3 擬解決的問題

集水區於颱洪時期之土砂產量將嚴重影響下游河防安全，發展一套可靠的土砂收支預報模式可有效預警，並進一步減少災害發生。現行集水區的土砂災害可利用數值模式研析不同情境之災害尺度，但於颱洪時期之災害評估與實際發生狀況仍有差距，因此數值模式僅能用於探討災害可能成因及減災策略擬定。若以即時監測而言，目前集水區土砂產量於災害時期之測量精度仍有進步空間，多數研究於事後前往現場進行測量，透過沖蝕釘、空拍、LiDAR、航照或是衛星影像等資料進行災前及災後比對，但此時颱洪時期所夾帶之土砂量體已造成災害，對於防災預警並無實質幫助。由於極端事件下的現場資料量取得困難而導致觀測資料不足來建構以 AI 為基底的土砂收支模式，本計畫希冀結合現有觀測資料與數值模式成果來組成足夠的資料庫，了解集水區土砂於不同時間在空間中分布情形，並跨領域結合 AI 機器學習法，發展一套可靠的土砂收支預報模式。 此方法可有效降低依賴觀測資料可能產生之缺漏及誤差；利用具備物理機制之數值模式也可合理評估土砂運移型態；AI 技術則可利用監督學習概念分析數據，使本計畫擬發展之技術具備預測功能。

第二章　工作執行方法與步驟

2.1　文獻回顧

機器學習在預報的應用十分廣泛，其中相關的使用類神經網路為主的模式在泥砂預報的應用已經有些許的成果。ANNs 為可靠且有效率的預報模式，已經被廣泛地應用於各水文領域中(Fahimiet al., 2017)，包括水庫入流 (Lin et al., 2009；Chen and Chang, 2009；Jothiprakash and Magar, 2012)及泥砂濃度 (Heednacram and Samitalampa, 2014；Demirci et al., 2015；Rashidi et al., 2016)。本研究擬使用的 ANNs 為參數設定少、訓練時間短、加強峰值預報能力、預報準確度高及可視覺化的改良式。近年來為了提高預報準確度，提出了結合基因演算法 (Genetic algorithm, GA)與 ANNs (Kuo et al., 2006；Su et al., 2015； Cheng et al., 2015)方法，利用 GA 尋找最佳參數可有效提高預報表現，但在進行預報常會遇到要考慮多個評鑑指標的情形，為了於因子篩選時能同時考慮多個指標， 多目標基因演算法 (Multi-objective genetic algorithm, MOGAs)被提出並應用於許多水資源方面的研究，包括水資源系統 (Reed and Minsker, 2004；Louati, 2011)及水庫操作 (Reddy and Kumar, 2006)。由 Yapo et al. (1998)研究指出 MOGAs 為一個有效率搜尋最佳解之演算法，並由 Lin et al. (2013)提出結合 MOGAs 與支援向量機(Support vector machine, SVM)於雨量預報。雖然使用 MOGAs 於篩選模式最佳輸入因子能有效提高預報準確度，但隨著預報時間增加，預報的表現仍會愈來愈差。為了改善模式於長延時的表現，Lin et al. (2013)提出將前面時刻之預報值當作輸入項之模式於洪水預報，並顯示所

提出之模式能夠有效改善長延時預報之表現。

過去有相當多水理輸砂數值模式發展用以探討河道沖淤變化過程，早期多發展一維模式，常用於探討河道整體趨勢，優點為計算快速，缺點是斷面之沖淤為每一位置平均分配沖淤量，難比較高灘地與深槽間之差異。隨著運算科技進步，發展至可以求解複雜問題的二、三維模式。三維水理輸砂模式一般用於模擬水工構造物周邊地形，如橋墩前後沖刷、丁壩周圍水流等局小範圍區域探討，優點為能提供深度方向之分佈特性，然其模擬範圍受到運算資源限制且計算時間相對較長。本研究使用之二維模式雖然計算速度較沒有一維模式快速，卻可以針對平面流速分佈、彎道二次流、斷面水位變化進行模擬，比較能掌握水流的沖刷特性，因此常被用來探討水流橫向行為較為複雜的問題。二維模式應用水深平均淺水波方程式，須於寬深比較大之情況使用，且較難反應水深垂直方向之泥砂運動特性。三種不同維度之水理輸砂模式適用範圍皆不相同，本研究案例皆屬於河段區域不大且僅探討泥砂濃度與沖淤特性，故選擇二維模式之 SRH-2D 做為模擬之數值模式。此動床模式已有充足發展，並已經應用於國內(Lai and Wu, 2014;Wang et al.,2016; Lai and Wu, 2013; 黃麗文，2014)、國外(Moges, E. M., 2010; Greimann, B., 2008; Huang, J., & Russell, K. , 2014)許多案例。

2.2 工作執行方法

本研究使用類神經網路 (Artificial neural network, ANNs)為主的預測模型，測試模型使其成為可靠且高效的預報模式。由歷史文獻顯示，目前鮮少學者進行土砂在集水區的收支預報。該研究希冀提供一套合理的土砂收支預報模型，未來能夠利用該模型快速得出土砂在集水區的收支情況。

預報模式的建立擬分為三個階段來完成，第一階段數值模型的建立，由颱風事件下的集水區坡面降雨逕流模式獲得輸入之流量歷線，結合坡面土壤流失量(MUSLE)的推估，以及河道動床數值模式(SRH2D)演算結果，獲得集水區土砂生產量，河床堆積量及下游出口土砂流出量。第二階段機器學習的預報模式建立，以數場颱風的數值模擬結果作為參數輸入，結合多目標基因演算與類神經網路方法建立入砂量與土砂流出量的收支關係式，並以此為集水區土砂預報模式。其中使用改良式自組織線性輸出映射圖，並將其與倒傳遞類神經網路模式及支援向量機兩種常用之類神經網路比較，以尋找較佳之入流量預報模式。第三階段則為率定與驗證，利用本研究所產生的預報模式進行歷史事件的土砂收支預報，此預報結果將與實測資料做比對，並修正參數獲得最佳的土砂收支預報模式。最後未來可利用預報之結果，給予相關單位作為管理上重要的依據。

2.3 工作執行步驟

本研究將分三個步驟來完成預期之目標

1.選定研究區域並收集相關資料

2.建立預報模式

3.土砂預警機制的規劃

2.3.1 研究區域

本研究以大漢溪流域為示範區域，大漢溪位於石門水庫上游，集水區面積約 76430 公頃，東鄰新北市、宜蘭縣，南接台中縣，西南與苗栗縣相鄰，流域面積大多數位於桃園縣復興鄉與新竹縣尖石鄉，只有少部分面積位於其他周圍縣市或鄉鎮，與鄰近行政區關係如圖 1 所示。石門水庫原先之標的為灌溉與防洪目前則以調節供應公共給水為其主要功能。

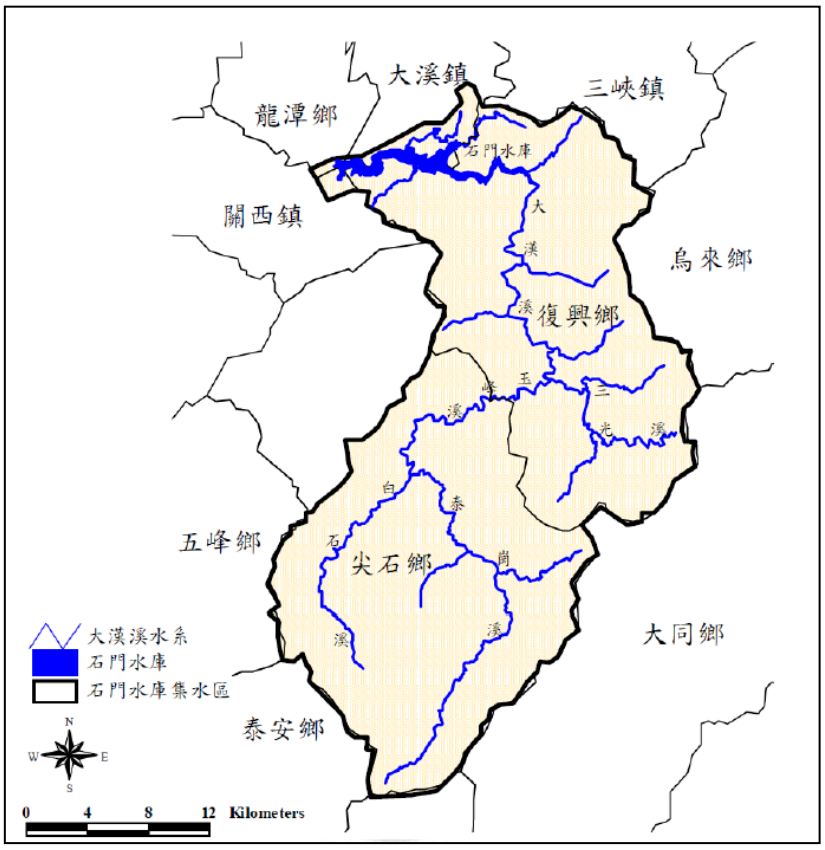


圖 2.3.1 石門水庫集水區行政區位置

集水區內之地形除西北邊違紀低緩之丘陵，大部分均為山岳，流域地勢大致由西南向東北逐漸遞減。依據水土保持技術規畫之坡度分類，坡度小於 30%之緩坡地約占集水區之 10.2%，坡度 30~55%之約占集水區之 29.3%，而集水區內多為坡度大於 55%，約占集水區之 60.5%(林昭遠，2004)。至於水系，皆發源自雪山山脈袋中，以大漢溪為主，由泰崗溪、白石溪、三光溪、拉拉溪、石磊溪、匹亞溪、雪霧鬧溪、大嵙崁溪、寶里苦溪、義興溪、抬耀溪、三民溪、高翹溪、以及南子溝溪等支流會合而成，流露呈不規則樹枝狀，總長約 352.63 公里。

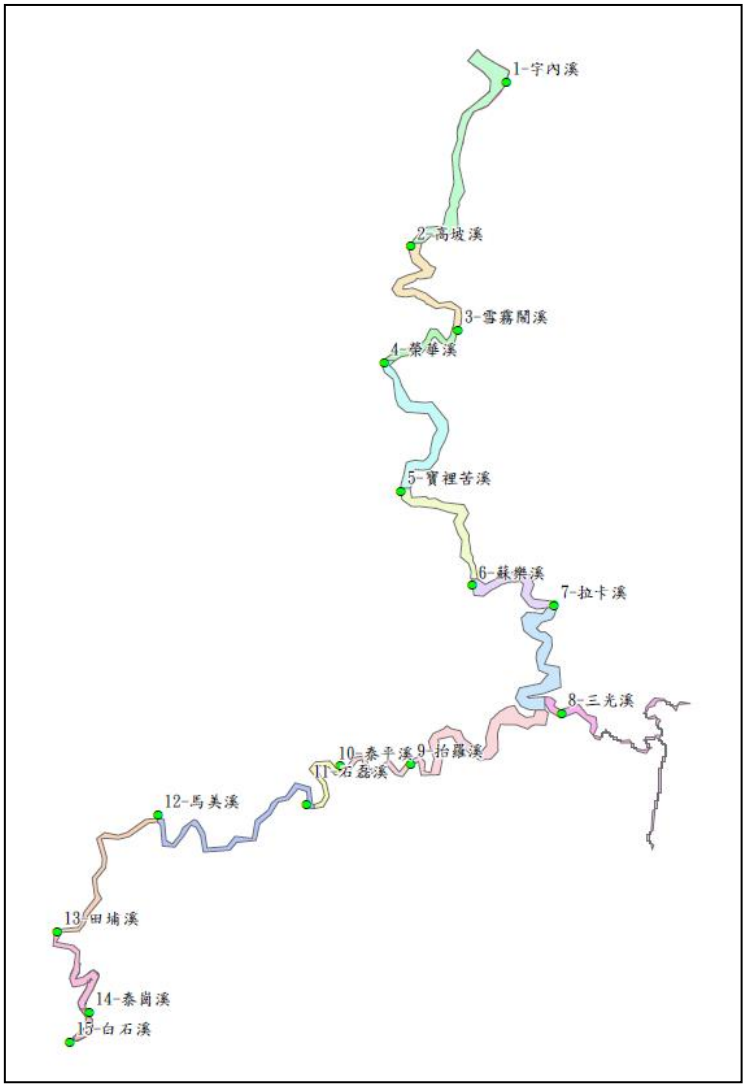
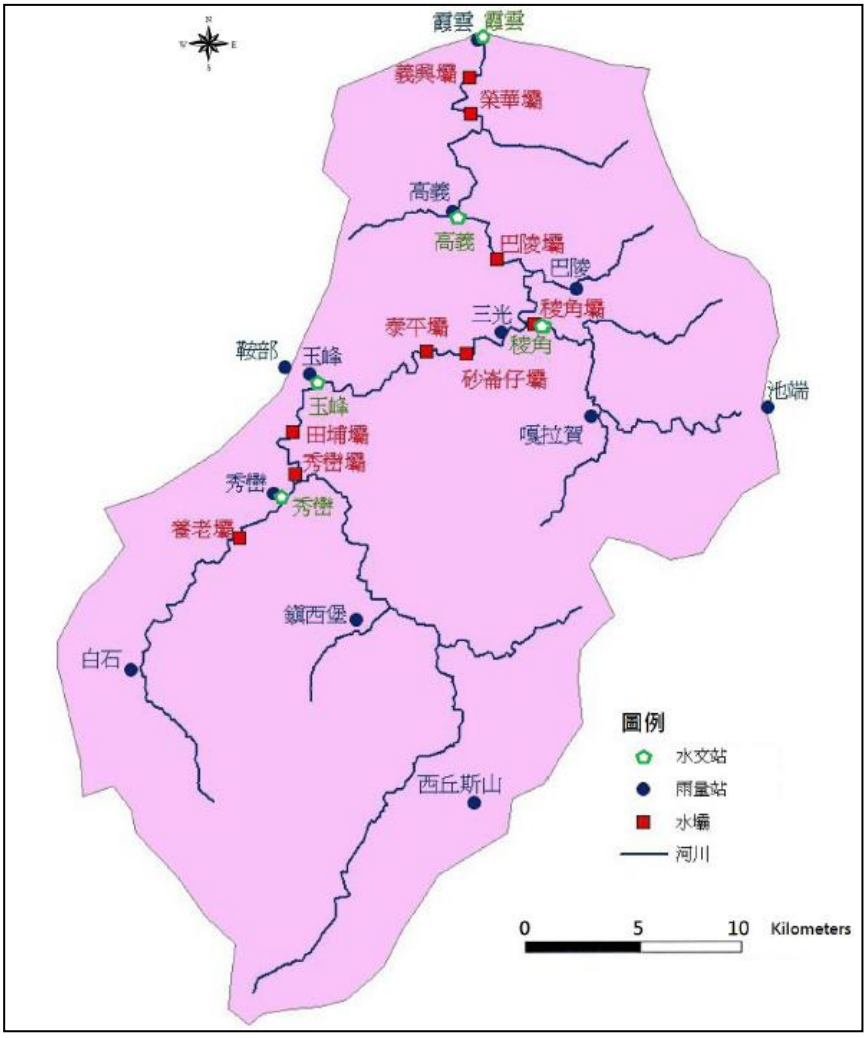


圖 2.3.2 大漢溪各支流分布

集水區內之氣象與水文觀測資料相當完備，有石門、霞雲、高義、巴陵、玉峰、嘎拉賀、池瑞、鎮西堡、白石、西丘斯山等雨量站，以及五個水位站，分別為霞雲、高義、玉峰、稜角、秀巒，個水位雨量站位置如圖 3 所示，集水區之平均降雨量約 2200~2800mm，多集中夏季，主要來源乃颱風、西南氣流帶來之雷陣雨、帶氣壓造成之豪雨。



資料來源:張明軒(2005)

圖 2.3.3 石門水庫集水區內之雨量站與水文觀測站位置圖

集水區內之地質構造複雜，有斷層、皺褶等各類型地質構造，露出之岩層大部分為沉積岩，岩石的節理、裂縫發達，經地殼變動、地形陡峻、雨水豐沛等條件，容易引發崩塌地發生。圍著集水區的土地開發利用，每逢雨季集水區內便遭受重大土砂災害，設置造成原水濁度過高而影響民生用水，以供水為主的石門水庫正面臨庫容減少的威脅。

2.3.2 預報模式的工作流程

工作流程圖將分為兩階段:第一階段維數值模式的建立，第二階段則為機器學習的預報模式建立，如圖 2.3.4 所示

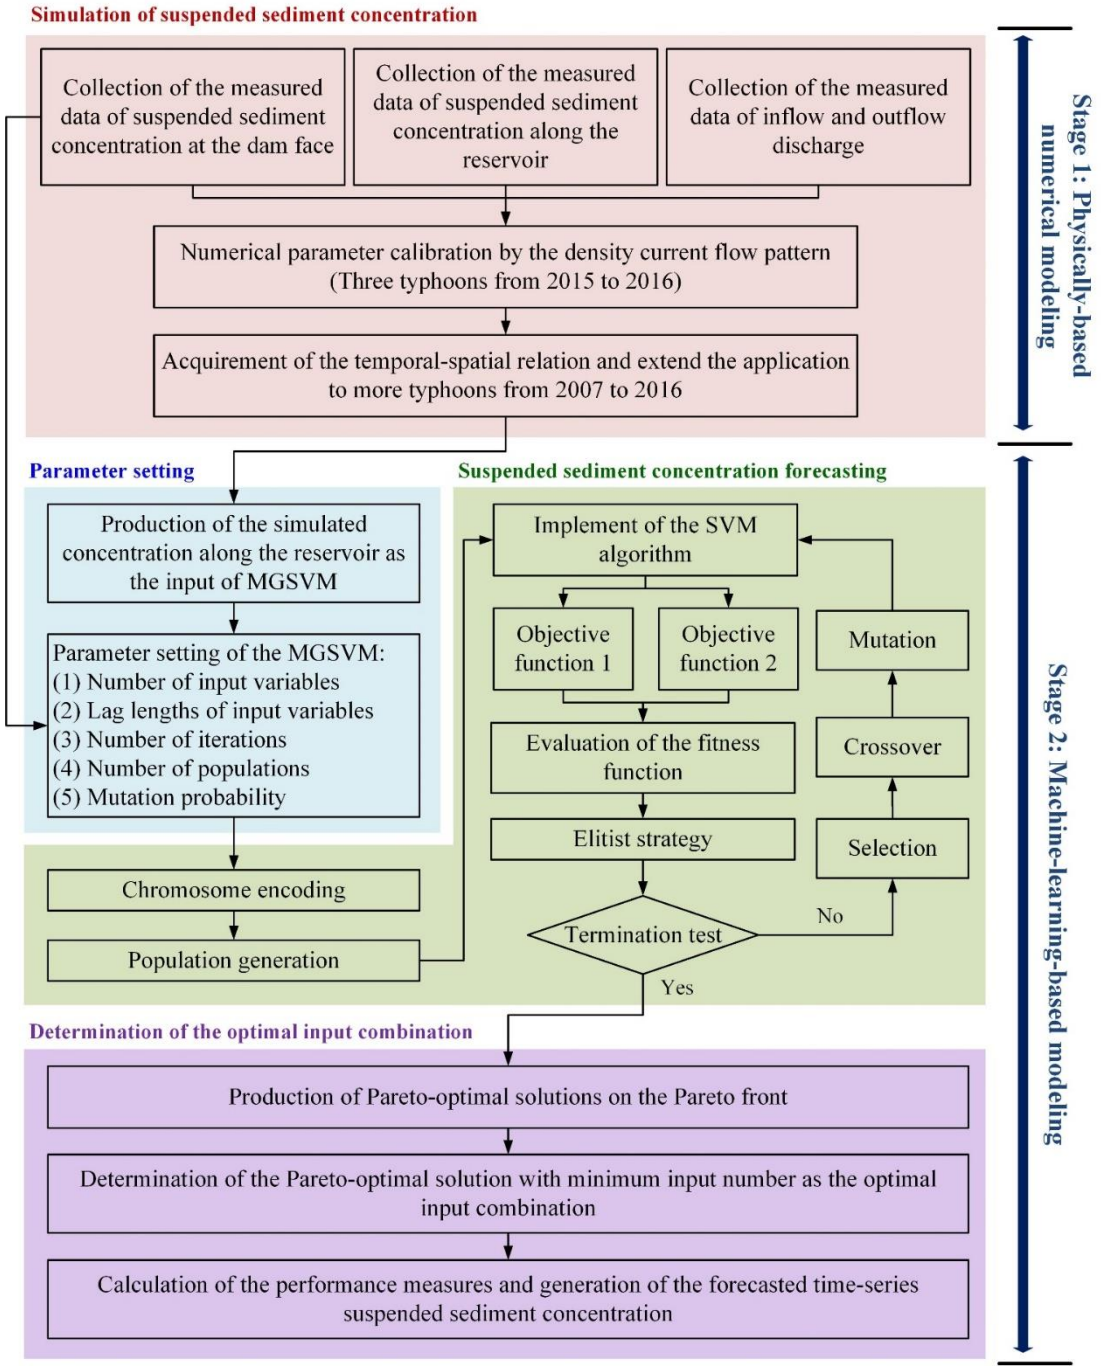


圖 2.3.4 預報模式建立的流程圖

- 多目標基因演算法：

該研究利用支配概念尋找柏拉圖最佳解 (Pareto-optimal solution)，相關概念如圖 5 所示。其中 score (A)、score (C)、score (D)、score (E)分別為 1、4、8、8，四者中以 D 和 E 兩組解之分數最高，可稱為柏拉圖最佳解。此概念可以在多項指標中比較個別優劣，適合解決多目標非線性問題。

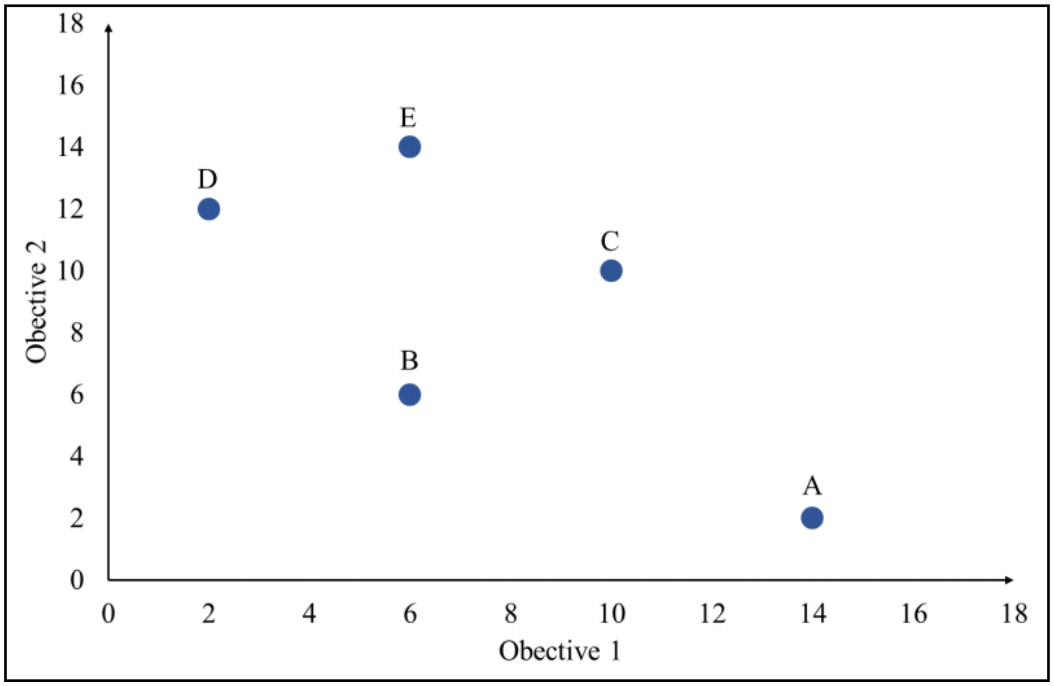


圖 2.3.5 柏拉圖最佳解示意圖

- 倒傳遞類神經網路：

倒傳遞類神經網路 (Back-propagation network, BPN)之基本架構為多層感知器 (Multi-layer perceptron)，其中包含一層輸入層 (Input layer)；一或多層隱藏層 (Hidden layer)；一層輸出層 (Output layer)，屬於監督式學習過程。一個三層之 BPN 基本架構如圖 6 所示。

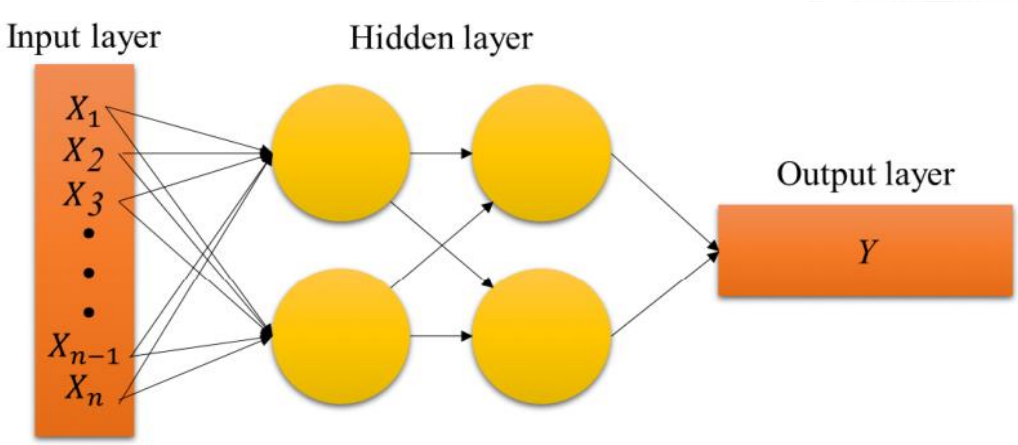


圖 2.3.6　BPN 架構圖

- 支援向量機：

SVM 是一種監督式機器學習法(Machine learning)，其主要特點可降低目標誤差函數，同時考慮網路結構複雜度，使模式達到一定的準確度，又可節省運算時間。圖 7 為 SVM 架構圖。

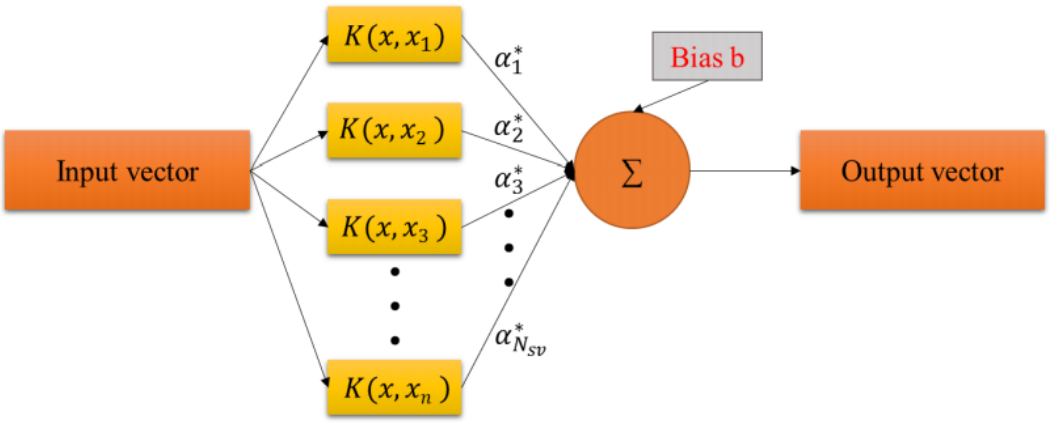


圖 2.3.7　SVM 架構圖

- 改良式自組織線性輸出映射圖：

ISOLO 為對於自組織線性輸出映射圖 (Selforganizing linear output map, SOLO)進行改進之預報模式。其原理可視為將一非線性之完整歷線，以自組織映射圖 (Self-organizing map, SOM) 拓樸，將該歷線切割成數條小線段，之後將每條線段視為線性歷線，最後將每條區分出來的線性歷線選取適當資料量進行線性回歸分析。由於 SOLO 在進行訓練過程中，採取線性回歸之方式進行分析，未妥善考慮到輸 入資料分布型態不同而造成回歸不理想之問題。尤其是訓練資料呈異分布 (Heteroscedastic)狀態時，原有之 SOLO 模式無法有效地解決，而 ISOLO 可以有效改進當資料呈現異分布所產生之問題。

2.3.3 土砂預警機制規劃

擬透過上述所建立的預報模式，提出颱風事件下土砂收支的預警系統規劃。

第三章　工作進度與交付項目

3. 計畫甘特圖

本計畫執行期間自 108 年 2 月至 12 月止，合計約 10 個月的時間，必須完成土砂收支預報模式的建立，相關執行進度如表 3-1 所示。表中，包括研究區域資料收集、數值模式的建立、預報模式的建立、報告書撰寫，期中需完成研究區域數值模擬成果以及土砂收支預報初步分析討論，而預報模式率定驗證則於期末階段完成。

重要工作項目	工作比重%	預定進度	108				備註
			2-3 月	4-6 月	7-9 月	10-12 月	
資料收集	10	工作量或內容	研究區域選定	水文水理資料收集			
		累計百分比	50	100	100	100	
數值模式的建立	30	工作量或內容	選定數值模式	網格建立	模擬結果		
		累計百分比	20	50	100	100	
預報模式的建立	30	工作量或內容	文獻收集	初步模式檢討	與數模成果結合		
		累計百分比	10	40	100	100	
預報模式率定驗證	10	工作量或內容		與實測成果比對	率定	驗證	
		累計百分比		50	80	100	
分析與討論	20	工作量或內容	分析與討論	分析與討論估	分析與討論	分析與討論	
		累計百分比	25	50	75	100	
累計總進度	百分比		30	60	85	100	

表 3.1　進度甘梯圖

3.1 基本資料蒐集

3.1.1 地形資料

作為模式之初始地形建置及模式率定驗證資料所用以使用 SRH-2D 模擬本研究河段之流場與輸砂情況，模式需大斷面測量資料作為地形資料，本研究採納之數值高程模型 (DEM)為內政部地政司(2004)「高精度及高解析度數值地形模型建置計畫」中產製的 5 公尺 DEM，然因航測無法有效反應河道水下地形，且拍攝年代相對模擬事件較久遠，河道地形可能已產生變化，因此其透過北水局提供之「102 年巴陵壩上下游河道淤積砂石下移測量作業」之河床測量資料，以 Spline with Barrier 法進行空間內插，整合(Mosaic)大斷面測量與數值高程模型，產置河道曲流地形之數值高程模型，並經由比對發現其改善原先之河道地形品質，為河床地形測量與數值高程模型的部分交界處有較明顯之高程差異，需特別注意。

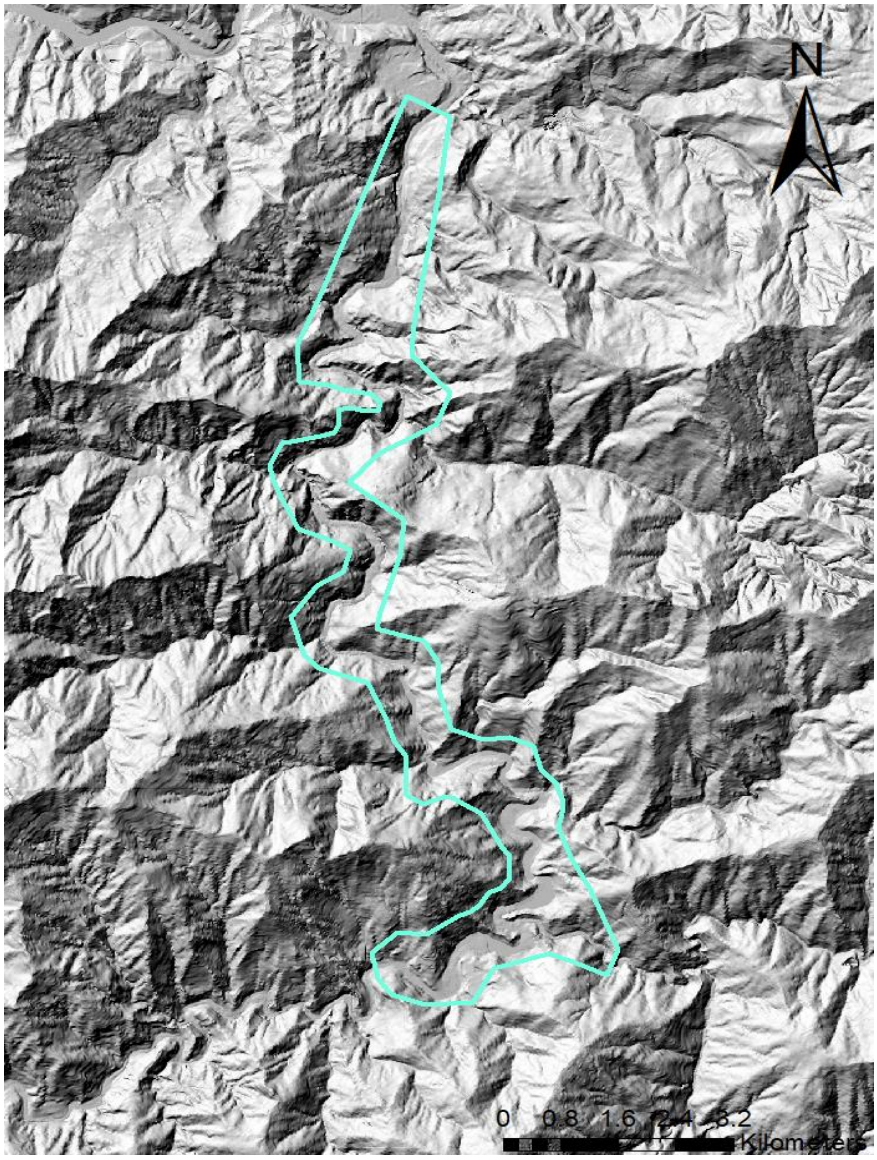


圖 3.1.1 本研究使用之初始地形（綠線為研究區域）

關於於渠道幾河特性，本案例使用 SMS 軟體進行網格編修，研究範圍為石門水庫上游五公里至巴陵壩，網格鋪設 22572 個三角形網格，選用全三角網格，以適應此區域複雜之地形與蜿蜒之河道，並在主河道處加密增加模擬之精確度，如圖 3.1.2。

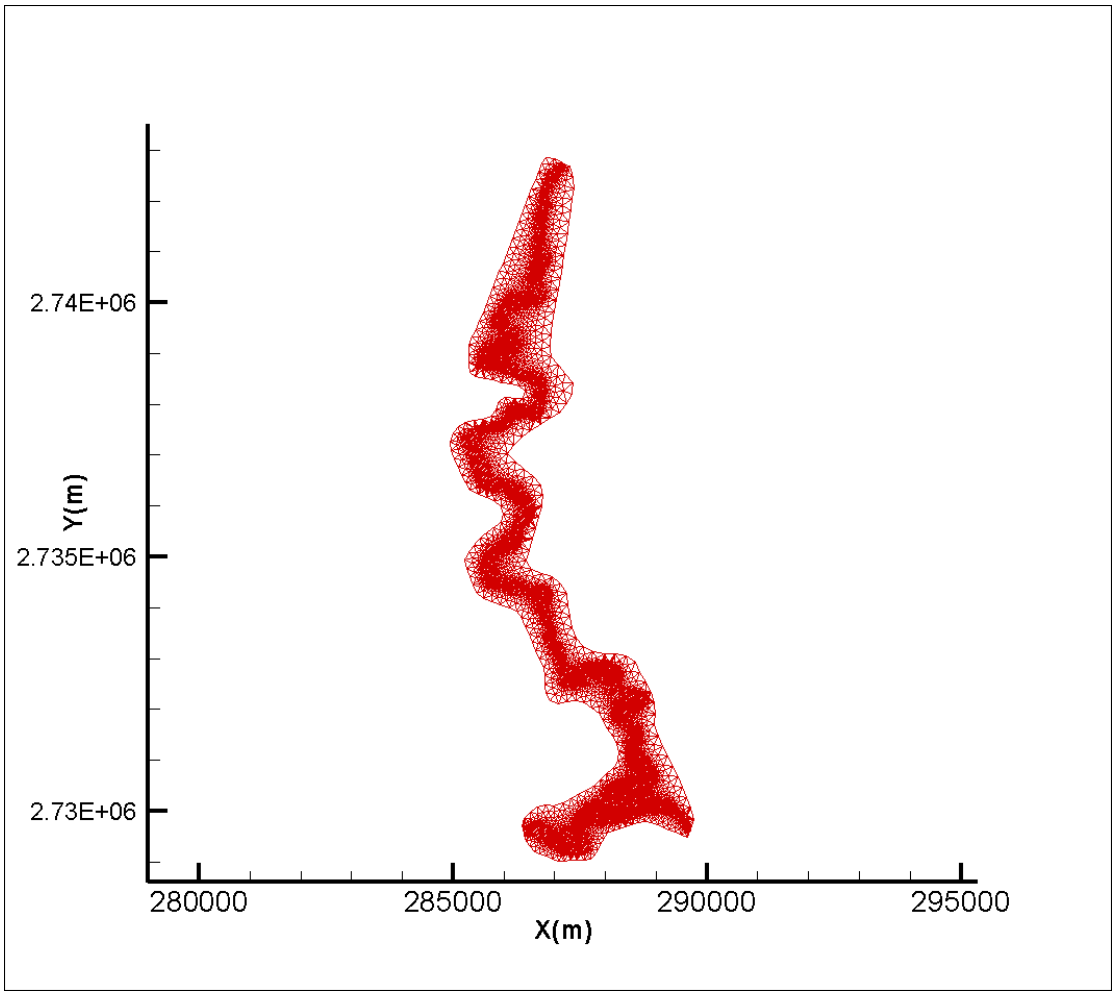


圖 3.1.2 大漢溪流域網格

3.1.2 水文資料

集水區內水系發源自雪山山脈中，以大漢溪為主流，研究區內現有 4 個水文觀測站，由上至下游分別為玉峰、稜角、高義、霞雲，在河川水文測站中，以霞雲水文站(1963 年~2013 年)及玉峰水文站(1957 年~2013 年)資料較為完整，關於研究區之選定因該區域具有以下優點故選擇之:

1. 水文觀測和地形測量資料充足: 自 52 年石門水庫開始運作，在集水區各處陸續設建置許多水文觀測站，水文觀測連續、穩定，加上 2009 年莫拉克颱風後泥砂問題受重視，修整泥砂測站，因此水利署北區水資源局開始進行完整地形測量，整體而言此區域觀測資料相當充足，足以提供水利和地形之研究。

2. 實際可得之資料以 2013 年各測站資料尤其輸砂濃度較為完整，考量到一般需較大之流量方能夠產生沖刷或造床運動，因此挑選較大流量之資料，然該年最大流量之蘇力颱風資料有所缺漏，故本研究以 2013 年該年次大流量之潭美颱風作為本研究率定之事件，潭美颱風在霞雲水文站測得之洪峰流量達 1800CMS，泥砂濃度達兩萬一千 PPM，且上下游各資料經自動監測與人工監測互相比對發現較其他事件可信度高

上游邊界流量資料採用經濟部水利署北區水資源局提供之玉峰流量站紀錄之時流量，採用民國 102 年 8 月 20 日 0 時至民國 102 年 8 月 23 日 14 時之時流量為模式率定時的上游邊界條件，另外在颱風事件前加入 24 小時民國 102 年 8 月 19 日 0 時至民國

102 年 8 月 20 日 0 時，先行模擬作為使模式穩定之緩衝時間，其中潭美颱風在玉峰站的尖峰流量為 1013 cms，側入流邊界為位於大漢溪支流三光溪之稜角站流量資料，時間亦為民國 102 年 8 月 20 日 0 時至民國 102 年 8 月 23 日 14 時之時流量，洪峰流量為 98.24 cms，為使 SRH-2D 能良好模擬土砂收支加入四個支流流量，由於沒有實測資料須由 HEC-HMS 模擬提供，邊界配置情形如圖 3.1.3。

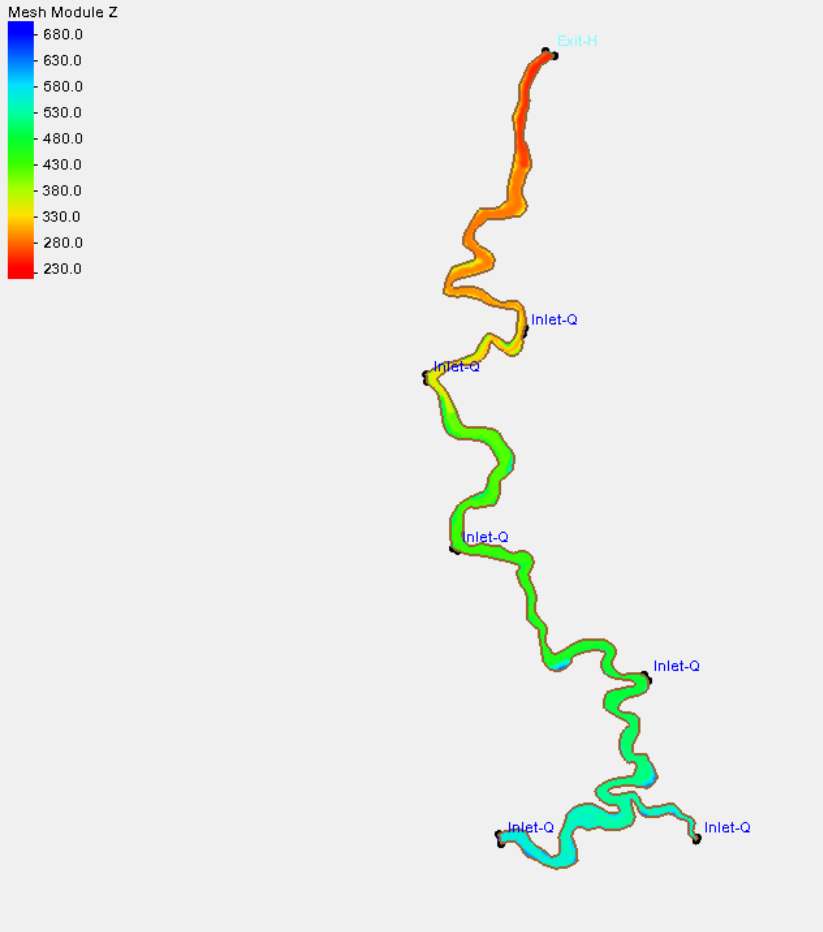


圖 3.1.3 大漢溪邊界配置情形

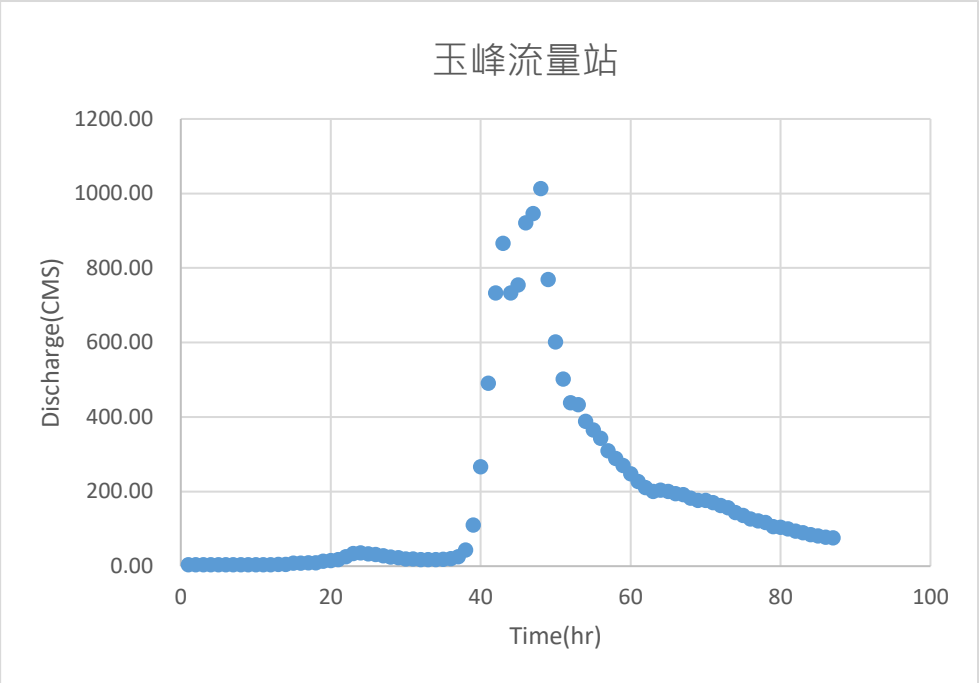


圖 3.1.4 潭美颱風玉峰水文站流量歷線

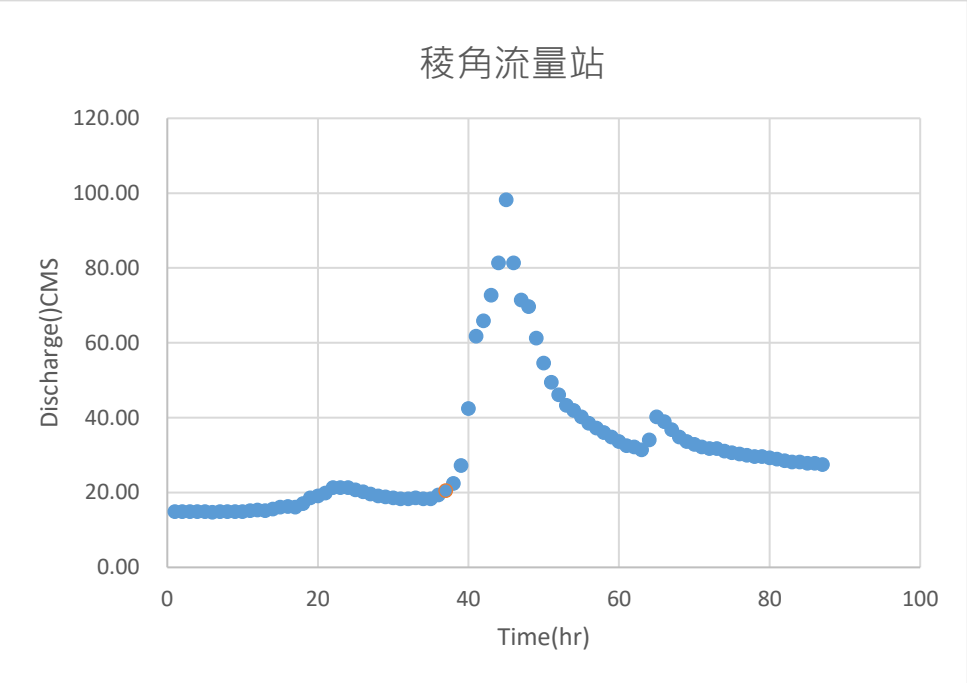


圖 3.1.5 潭美颱風稜角水文站流量歷線

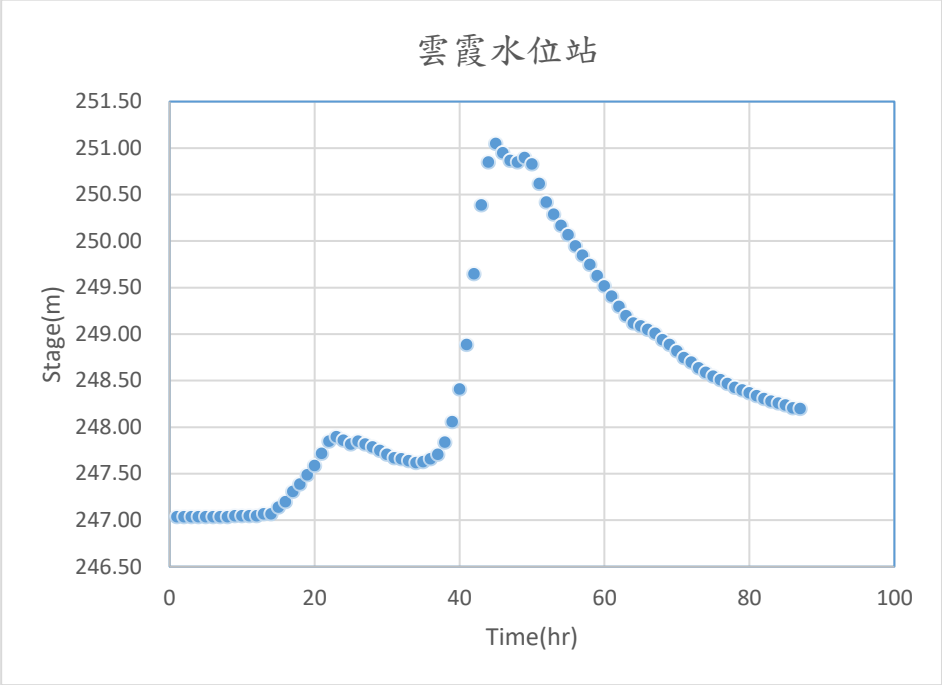


圖 3.1.6 潭美颱風雲霞水位站水位歷線

驗證階段使用同為民國 102 年菲特颱風 89 小時颱風資料，採用民國 102 年 10 月 5 日 0 時至民國 102 年 10 月 8 日 16 時之資料。另外在颱風事件前加入 24 小時與 102 年 10 月 4 日 0 時至民國 102 年 10 月 5 日 0 時模擬資料作為使模式穩定之緩衝時間，而此事件考量原因亦與上述相同，其擁有資料完整與與可信度高等優點。上下游邊界則分別給定玉峰水文站之流量歷線與霞雲水文站之水位歷線。

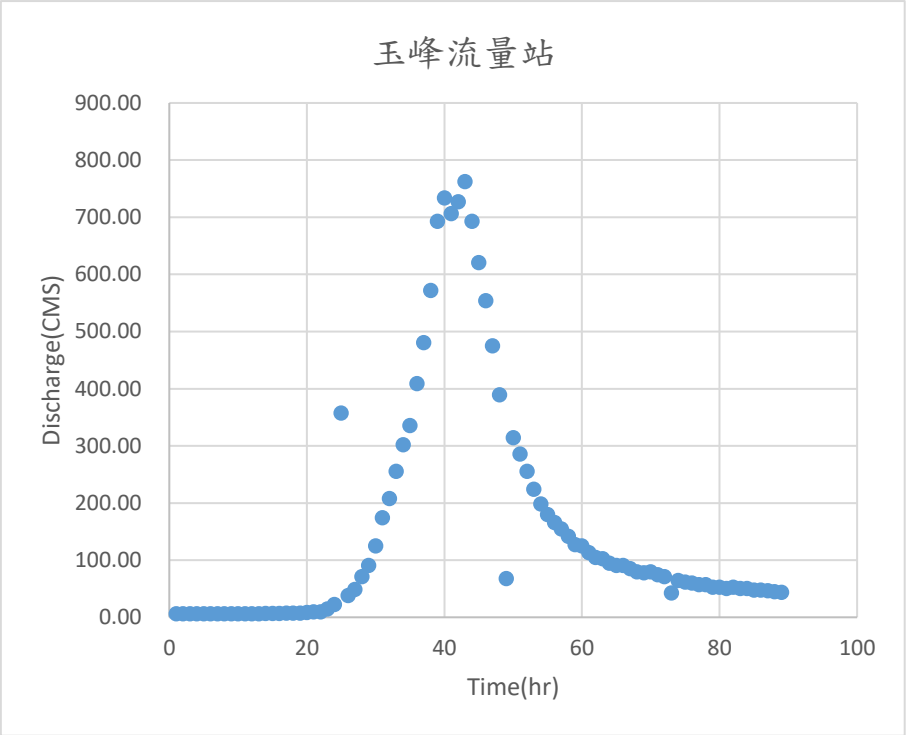


圖 3.1.7 菲特颱風玉峰流量站流量歷線

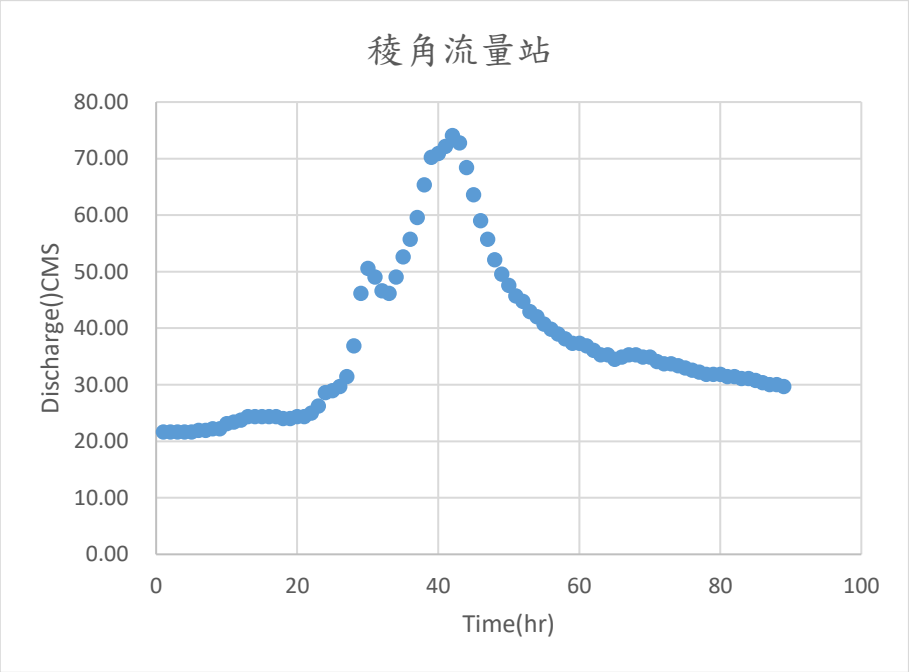


圖 3.1.8 菲特颱風稜角流量站流量歷線

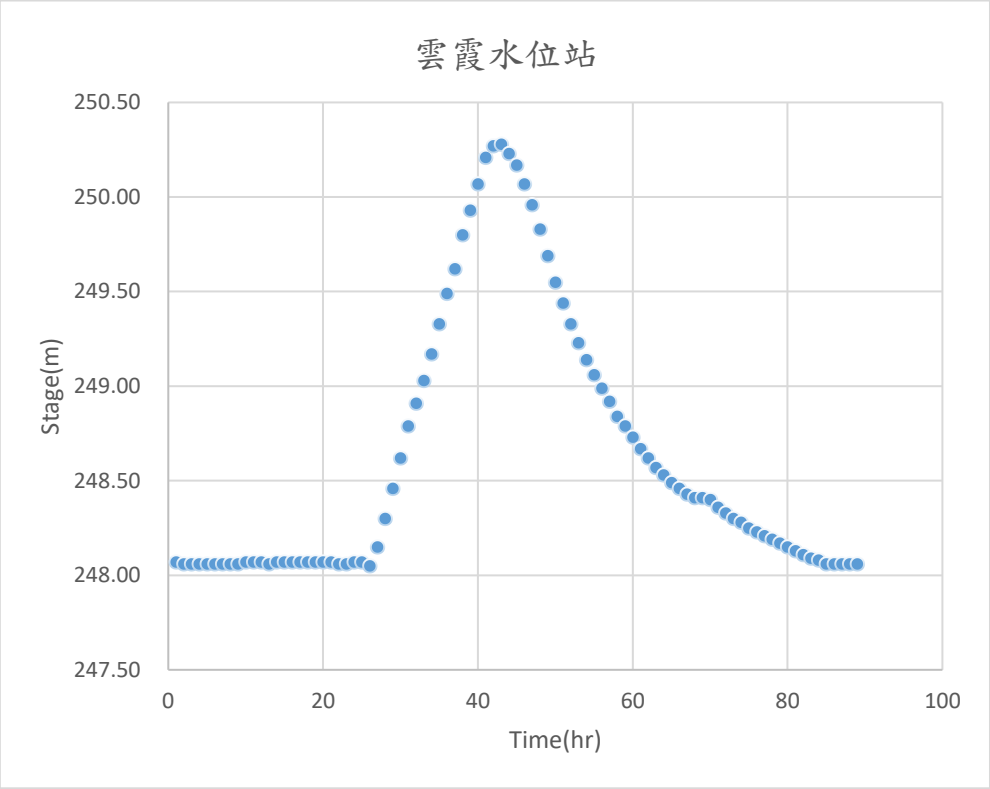


圖 3.1.9 菲特颱風霞雲水位站水位歷線

3.1.3 曼寧 n 值

曼寧 n 值為河川摩擦底床或岸壁造成能量損失的指標，本計畫參考水利規劃試驗所委託財團法人成大研究發展基金 會之「大漢溪上游河床變化調查及治理規劃」計畫的曼寧 n 值推求結果，詳表 3.1.1 和圖 3.1.11 所示;漫地流糙度係數則根據土地利用調查資料，由表 3.1.2 之建議值給定。石門水庫集水區曼寧 n 值分布如 3.1.12 所示。

表 3.1.1 曼寧 n 值分佈

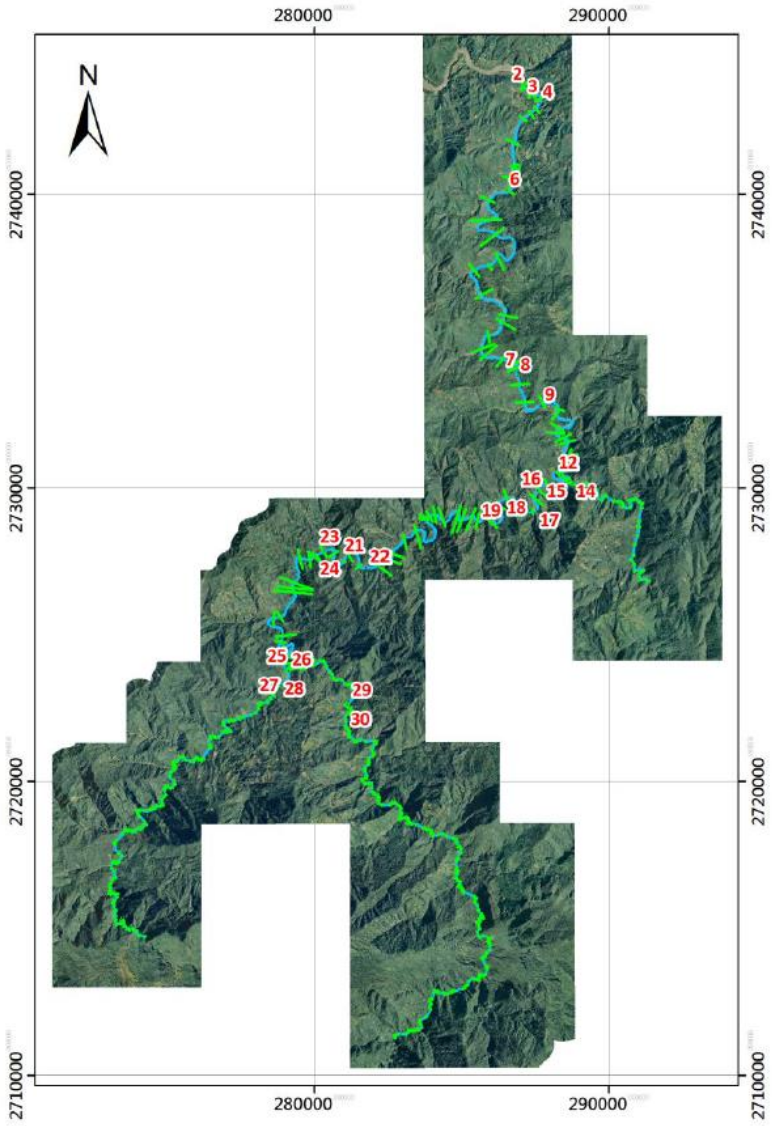
採樣點編號	曼寧 *n* 值推估公式					平均
	Einstein	Lane	Mayer&Peter	何貴氏	Strickler	
1	0.0216	0.0263	0.0242	0.0393	0.0257	0.0274
2	0.0231	0.0288	0.0289	0.0470	0.0287	0.0313
3	0.0228	0.0282	0.0274	0.0445	0.0280	0.0302
4	0.0297	0.0364	0.033	0.0537	0.0329	0.0372
5	0.0248	0.0301	0.0286	0.0465	0.0289	0.0318
6	0.0280	0.0343	0.0311	0.0506	0.0316	0.0351
7	0.0178	0.0239	0.0254	0.0413	0.0254	0.0268
8	0.0251	0.0300	0.0288	0.0467	0.0292	0.0320
9	0.0317	0.0384	0.0342	0.0556	0.0345	0.0389
10	0.0265	0.0331	0.0314	0.0511	0.0311	0.0346
11	0.0296	0.0358	0.0321	0.0521	0.0325	0.0364
12	0.0311	0.0378	0.0342	0.0556	0.0343	0.0386
13	0.0285	0.0348	0.0314	0.0511	0.0318	0.0355
14	0.023	0.0282	0.0272	0.0443	0.0276	0.0301
15	0.0274	0.0343	0.0318	0.0516	0.0316	0.0353
16	0.0282	0.0347	0.0315	0.0513	0.0317	0.0355
17	0.0259	0.0318	0.0297	0.0482	0.0305	0.0332
18	0.0283	0.0349	0.0317	0.0516	0.0318	0.0357
19	0.026	0.0328	0.0310	0.0503	0.0305	0.0341
20	0.0309	0.0371	0.0327	0.0532	0.0334	0.0375
21	0.026	0.032	0.0306	0.0497	0.0307	0.0338
22	0.0238	0.0299	0.0299	0.0485	0.0290	0.0322
23	0.0267	0.0332	0.0312	0.0507	0.0312	0.0346
24	0.0257	0.0322	0.0310	0.0503	0.0305	0.0339
25	0.0246	0.0298	0.0293	0.0477	0.0293	0.0321
26	0.0242	0.0290	0.0274	0.0446	0.0288	0.0308
27	0.0257	0.0310	0.0293	0.0477	0.0303	0.0328
28	0.0260	0.0328	0.0317	0.0516	0.0307	0.0346
29	0.0245	0.0299	0.0284	0.0462	0.0293	0.0317
30	0.0228	0.0278	0.0263	0.0427	0.0278	0.0295

資料來源：財團法人成大研究發展基金會(2007)，「大漢溪上游河床變化調查及治理規劃」

表 3.1.2 漫地流糙度係數

地表覆蓋	漫地流糙度係數
混凝土/瀝青 (水深大於 0.5 公分)	0.05～0.10
混凝土/瀝青 (水深小於 0.5 公分)	0.10～0.15
耕作地 (無殘株、有殘株)	0.10～0.40
短草地	0.20～0.30
草地	0.30～0.40
密集植生 (草地、灌木、森林)	0.40～0.80

資料來源：SCS (1985)



資料來源：財團法人成大研究發展基金會(2007)「大漢溪上游河床變化調查及治理規劃」

圖 3.1.11 表面粒徑採樣點分布

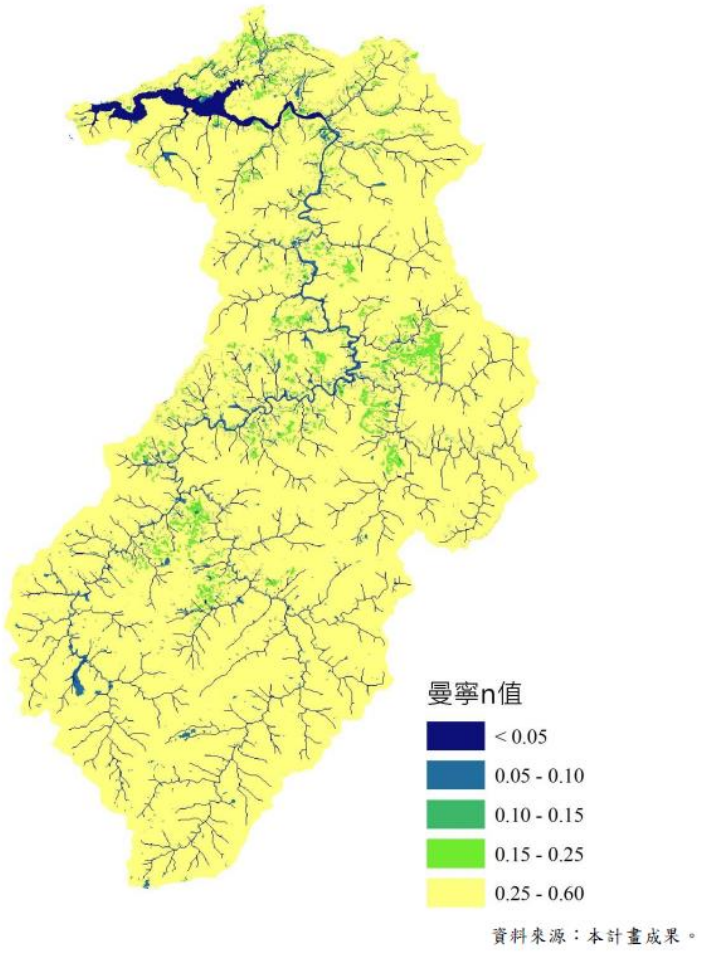


圖 3.1.12 石門水庫集水區曼寧 n 值分布

3.1.4 上游入砂濃度設置

在 SRH-2D 中有兩種可以作為計算入砂濃度的方式:流量-輸砂量率定曲線與輸砂公式(Sediment Capacity Euaqtion)，本案例採用內建之輸砂公式計算入砂濃度。根據粒徑資料判斷本研究河段為礫石河床，礫石河床主要為底床載為主，故選用 Parker(1990)與 MPM(2006)公式計算泥砂濃度的輸砂公式。

3.1.5 輸砂動床參數設置

本研究中率定的輸砂參數為粒徑閥值(Particle Diameter Threshold)、調適長度(Adaptation Length)、活動層厚度(Active Layer Thickness)，這些參數是影響輸砂模式較大的參數。以下就各參數選取之範圍與設計之考量如下。

粒徑閥值代表的意義是入流泥砂的主要粒徑與底床的粒徑分布，然而底床的粒徑分布已設定為實際採樣的粒徑分布，故在此僅代表模式之入流泥砂分佈。將以實際測量結果當作輸入參數，故不予以率定。

調適長度為相當重要的輸砂參數，其代表河床上平衡至非平衡過程中的特徵長度，亦即河床中單一顆粒被水流帶起後，並再度落下的影響距離。在應用上，調適長度目前並無公認的建議值，基本上會隨不同河道特性而改變。考量到此段河川為礫石河床，本案例根據 SRH-2D 之官方推薦，礫石河床之調適長度為河道平均度的一至五倍，本河段平均河寬約為 50 m，故本案例之調適長度設計為 50 m 至 250 m 之間每隔 10 m 設置一次。

活動層厚度為模式中計算底床能夠被沖刷的厚度或表層與子表層交換的厚度。本河段大部分區域D_{90}為 203.2 mm，根據官方建議當河段為礫石河川時，活動層厚度為 1 至 3 倍的D_{90}，但因為本次設置底床材質採用單一粒徑均勻分布沒有粒徑篩化的機制，基本上活動層以及底床分層都用不到，所以不需要率定。

表 4.1.5 初始輸砂參數範圍

參數	最小值	最大值	單位
Particle Diameter Threshold(小粒徑)	1	32	mm
Particle Diameter Threshold(中粒徑)	32	64	mm
Particle Diameter Threshold (大粒徑)	64	128	mm
Adaptation Length(調適長度)	50	250	m
Active Layer Thickness(活動層厚度)	203.2	609.4	mm

表 4.1.6 本研究採用之各種參數說明

模式參數	**研究設置參數**
模擬範圍	大漢溪石門水庫上游至巴陵壩
網格型態與數量	三角網格 (22572 elements 與 11400 nodes)
時間步幅	1 s
上游入砂濃度	採用輸砂公式 (Capacity)
曼寧 n 值	0.03
底床高程	2013 年 5m 數值高程資料
底床泥砂粒徑分布資料	2008 年交大防災中心採樣資料
泥砂種類	非凝聚性泥砂
泥砂粒徑種類(sediment size class)	非均勻砂(3 種)
河床層數量	1 層

活動層厚度(active layer thickness)	203.2 mm
泥砂運移公式 (sediment transport capacity equation)	Parker(1990)、Modified MPM(2006)
臨界 shield 參數	各輸砂公式預設值
調適長度(bedload adaptation length)	50 m-250 m (每隔十公尺)
懸浮質調適係數 (adaptation coefficients for suspended load)	預設值
紊流模式	標準 k-ε 雙方程紊流模式

3.2 水文分析

在進行土砂產生模式與河道輸砂數值模式演算前，需蒐集工作範圍內各流域之水文資料，方能進行相關案例之評估。本研究使用 HEC-HMS 來獲得颱風事件下的集水區坡面降雨逕流模式獲得輸入之流量歷線。

3.2.1 HEC-HMS 模式

HEC-HMS 已廣泛運用在烏溪、濁水溪、大安溪等水利署相關計畫，其皆有不錯的成果，有著其代表意義，因此本計畫採用 HEC-HMS 進行流量模擬。HEC-HMS 模式為美國陸軍工兵團發展之降雨逕流模式。降雨逕流模式是將雨水視為入流量，流入集水區後，經過蒸發散、入滲等作用後，計算出各位置的逕流量的值。HEC-

HMS 模式分成集水區模組(basin model)、氣象模組 (meteorologic model)與控制設定(control specification)等三個模組，只要完成這三個模組，就可計算出逕流量。HEC-GeoHMS 為輔助 HEC-HMS 模式之 ArcGIS 外掛模組，可以將地理數值高程 DEM 與河川圖層在 ArcGIS 中處理成諸多小型子集水區。而這些小子水區與彼此之間之相位連結的結果，可直接輸出成 HEC-HMS 模式之集水區模組(basin model)。HEC-HMS 模式建製流程如圖 3.2.1 所示。

1、HEC-HMS 模式建置本計畫使用地理資料系統軟體 ArcMap 將大漢溪數值地形進行分析，數值地形模型為 5m，應用美國陸軍工兵團所發展出 Hec-GeoHMS 模式加以分析大漢溪全流域子集水區眾多，為了節省建置模式時間及能有效反應流域水文現象，因此針對大漢溪流域分為 1 條主要河流、4 條次要河流。大漢溪流域分為 9 個子集水區。依照上述集水區及對應匯流點建置水文模式如圖 3.2.2 所示。

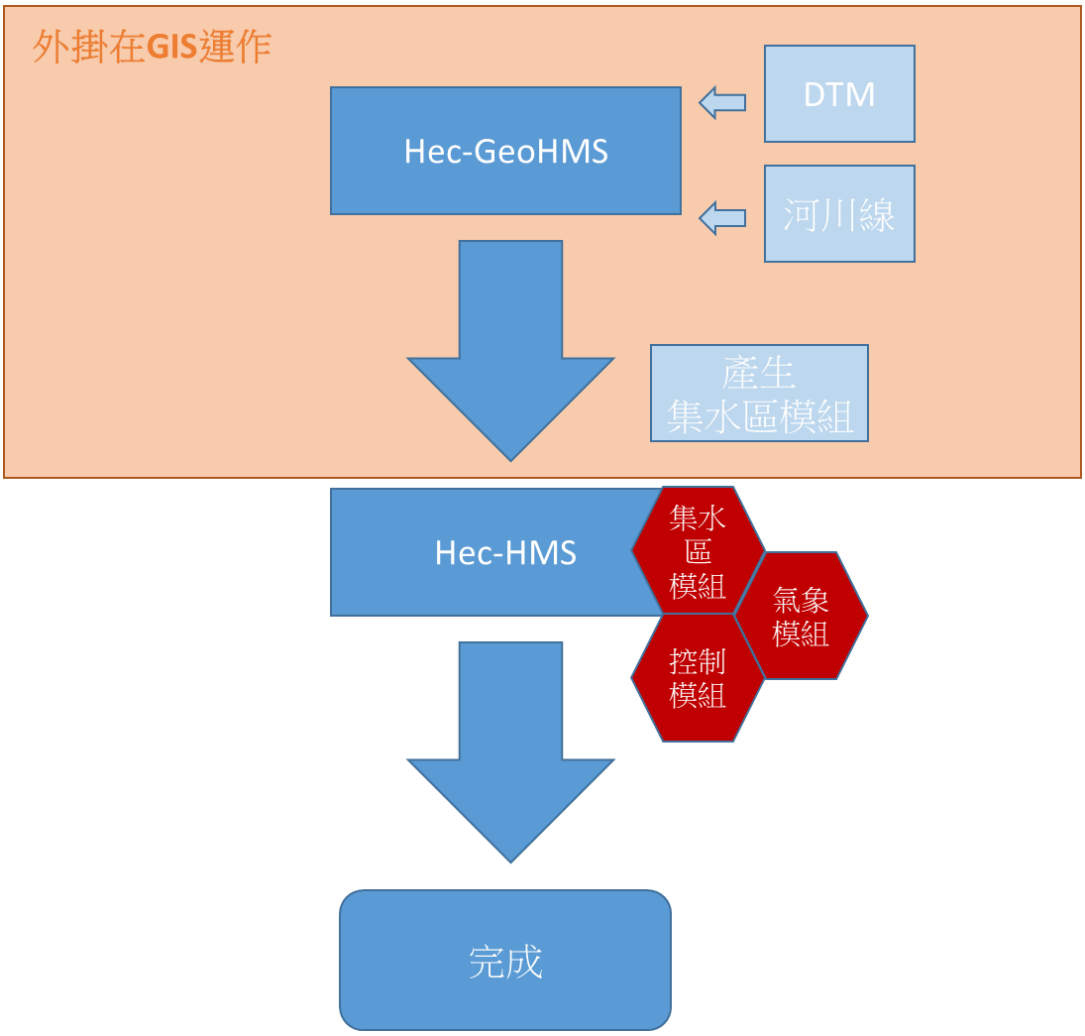


圖 3.2.1 HEC-HMS 模式建置流程

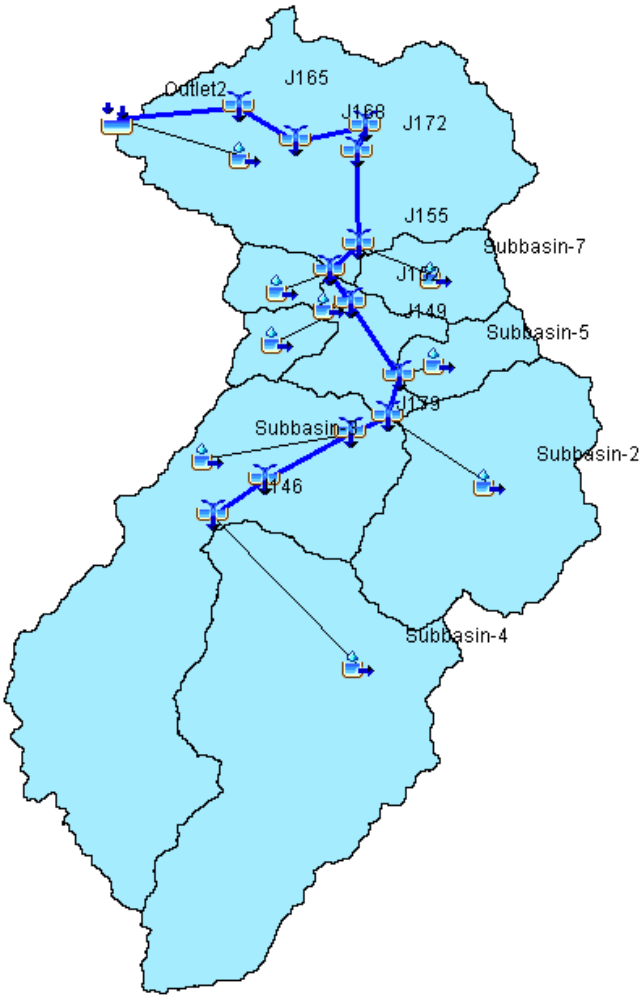


圖 3.2.2 大漢溪流域 HEC-HMS 水文模式建置示意圖

2、模式參數說明

茲將HEC-HMS所使用之模式參數進行說明。

(1)逕流曲線值(Runoff curve number, CN)

美國水土保持局之SCS逕流曲線法，估算降雨損失，其中CN值(逕流曲線係數)變化，正可反應出土地之開發程度。一般而言，CN值跟土地利用與土讓有關；CN值之參數範圍為1~100；CN值越大，表示開發程度越高。

表3-1為美國水土保持局所訂定CN類別參考表。

(2)延遲時間(Lag time)

參數為將雨量轉化成子集水區逕流量之用。

$$\text{Lag} = \frac{L^{0.8} \times (S+1)^{0.7}}{1900Y^{0.5}}$$

其中 Lag=延遲時間(hr) ; L=集水區逕流長度 ; Y=流域坡度(%);

$$S = \frac{1000}{CN} - 10$$

(3)基流量(Base flow)

河道中基本的流量。可能是由地下水、側向入流等等因素產生的。跟集水區面積與本身所在的地下水量有關。集水區越大基流量會越大。整體水量高估或低估時，可調整此值。

(4)馬斯金更法(Muskingum Method)

Muskingum 為一種洪水演算法，在模式中是計算節點與結點之間的量值，參數分別為:Muskingum K 和 Muskingum X。

k=蓄水常數，為加權蓄水量-流量關係圖斜率之倒數;

x= 每一已知河川斷面的加權因子，介於 0 至 0.5 間。

(5)SCS 三角形單位歷線法

降雨逕流推估主要採用 SCS 三角形單位歷線法，單位歷 線為在某一特定之延時內，對於時間、空間皆均勻降落於一集 水區之單位有效降雨所形成之直接逕流歷線，而 SCS 三角單位歷線法為美國水土保持局所發展。

3、大漢溪流域參數說明

在地表逕流模擬部份係採用 SCS Unit Hydrograph 加以模擬，其參數有遲滯時間(Lag Time)，其中逕流長度、 流域坡度及集水區面積藉由 ArcGis 計算出。集水區土壤入滲部分則採用 SCS Curve Number，其參數有入滲數 (Curve number)、地表覆蓋率(Impervious)等，入滲數值 CN 會採用參考 CN 值對照表進行率定驗證，如表 3.2.1 ，大漢溪土壤分佈經由 ARCGIS 圖層套疊如圖 3.2.3 可知表土質地屬於表 3.2.2 中 A、B 類，再經由衛星影像判視可知大漢溪流域大部分為森林用地，在本次模擬中為了符合實測值，此參數交叉率定以符合現況。在河川演算的部份則以 Muskingum 法加以分析，其參數有 Muskingum K 和 Muskingum X，採用參數值分別為 0.05 與 0.3。為方便呈現將集水區進行編號如圖 3.2.4，詳細參數詳見表 3.2.3。

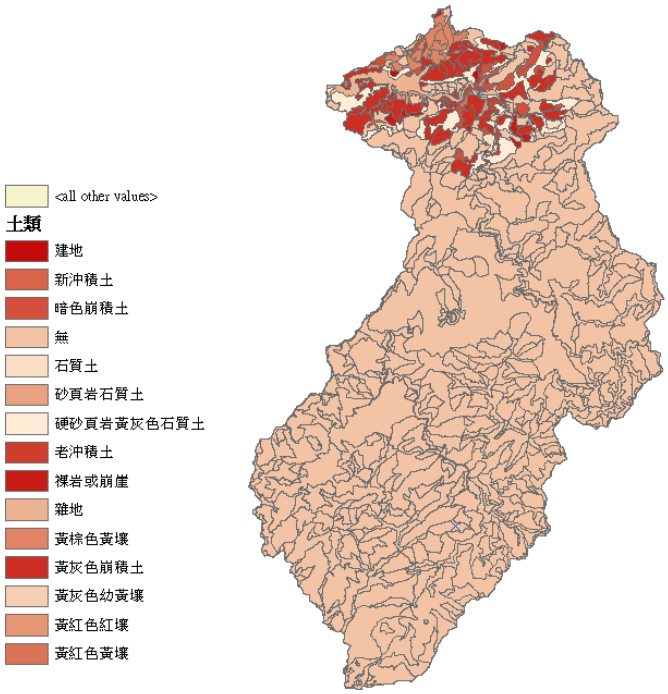


圖 3.2.3 大漢溪土壤分布

表 3.2.1 表土質地分類

分類代碼	表土質地分類	美國水土保持局分類
0	粗砂土、砂土	A
1	細砂土、壤質砂土、壤質粗砂土	
2	壤質細砂土、粗砂質壤土、砂質壤土、細砂質壤土	
3	極細砂土、壤質極細砂土、極細砂質壤土	B
4	坋質壤土、坋土	
5	壤土	
6	砂質黏壤土	
7	黏質壤土、坋質黏壤土	C
8	坋質壤土、砂質黏土	
9	黏土	

表 3.2.2 土地利用分類

SCS 分類	土地利用情形	土壤分類			
		A	B	C	D
	耕地：				
1	無保護措施	72	81	88	91
2	有保護措施	62	78	78	81
	牧草地或放牧地：				
3	不良情況	68	79	86	89
4	良好情況	39	61	74	80
5	草地：良好情況	30	58	71	78
	森林：				
6	稀疏、覆蓋少、無覆蓋物	45	66	77	83
7	良好覆蓋	25	55	70	77
	空地、林間空地、公園、高爾夫球場、墓地等：				
8	良好情況：草地覆蓋面積超過 75%	39	61	74	80
9	稍好情況：草地覆蓋面積 50~75%	49	69	79	84
10	商業區(85%面積不透水)	89	92	94	95
11	工業區(72%面積不透水)	81	88	91	93
	住宅：				
12	≦1/8 英畝 (65%)	77	85	90	92
13	1/4 英畝 (38%)	61	75	83	87
14	1/3 英畝 (30%)	57	72	81	86
15	1/2 英畝 (25%)	54	70	80	85
16	1 英畝 (20%)	51	68	79	84
17	鋪石(混凝土或柏油)、停車場、屋頂、道路等	98	98	98	98
18	街道	98	98	98	98
19	鋪石(混凝土或柏油)道路及雨水下水道	76	85	89	91
20	碎石道路及泥土道路	72	82	87	89
21	水體	98	98	98	98

資料來源：(USACE, 2000)。

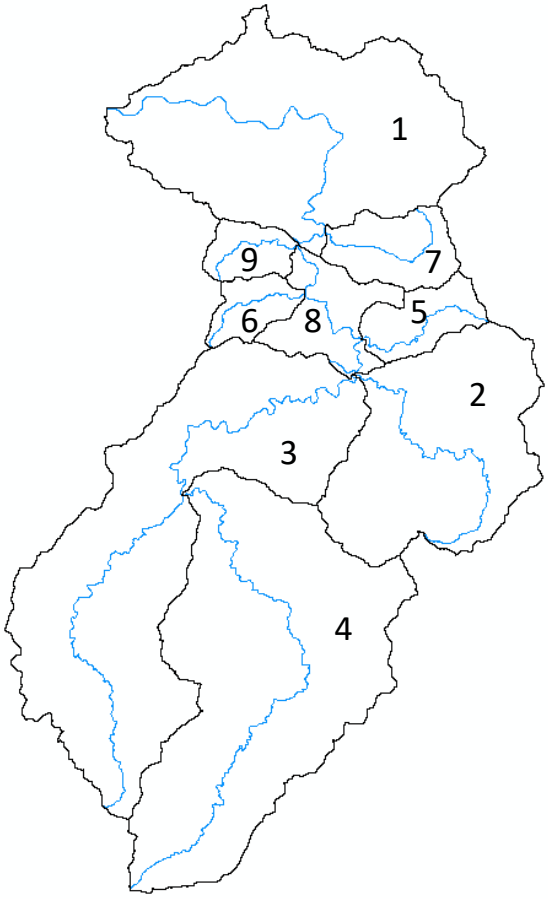


圖 3.2.4 子集水區分區編號

表 3.2.3 HEC-HMS 初步模擬之採用參數表

集水區	坡度	溪流長 (feet)	CN	S	延遲時間 (hr)	Ia
1	27.85018	91062.64	62	6.129032	3.65953572	31.13548
9	36.28659	24249.04	40	15	1.95890297	76.2
8	35.32219	45467.36	48	10.83333	2.65801466	55.03333
7	37.64474	33866	40	15	2.51240329	76.2
6	37.03783	26695.92	45	12.22222	1.83228336	62.08889
5	33.94556	35496.16	50	10	2.11336671	50.8
2	37.09994	76794.64	45	12.22222	4.26321913	62.08889
3	35.91438	164498.6	46	11.73913	7.76496982	59.63478
4	37.49599	131068.8	35	18.57143	8.55833401	94.34286

4、雨量資料分析

大漢溪流域內外有許多雨量站，颱風事件雨量資料有部分缺漏情況，因此為了資料的完整性與統一性，整理出大漢溪流域內外共 7 站進行權重分析。各雨量站在各集水區的權重關係並不相同，為求得各雨量站在各集水區之權重關係，本計畫採用徐昇氏法進行分析，利用 ArcMap 地理資訊系統內內建功能建置出各雨量站之徐昇氏站網，其權重分佈如圖 3.2.5 、表 3.2.3 所示。

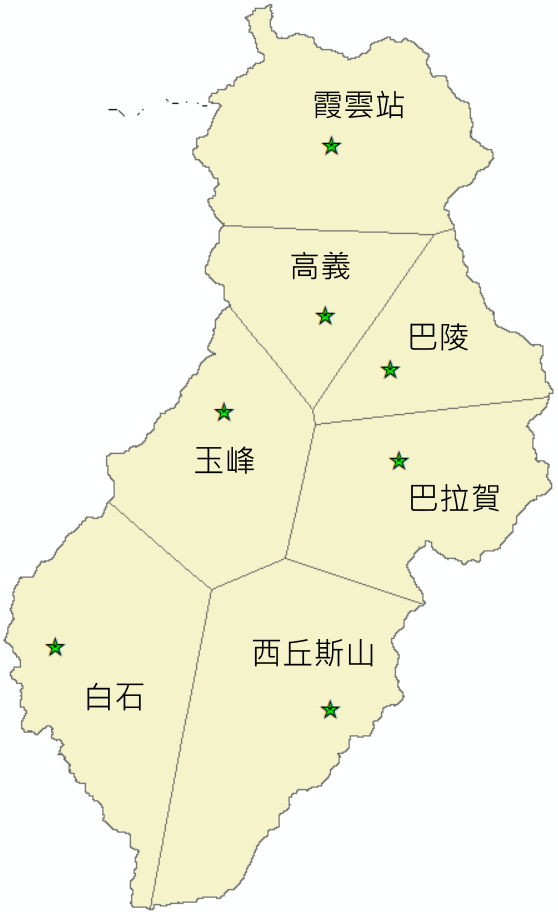


圖 3.2.5 大漢溪流域徐昇網

表 3.2.4 各測站徐昇式分配權重

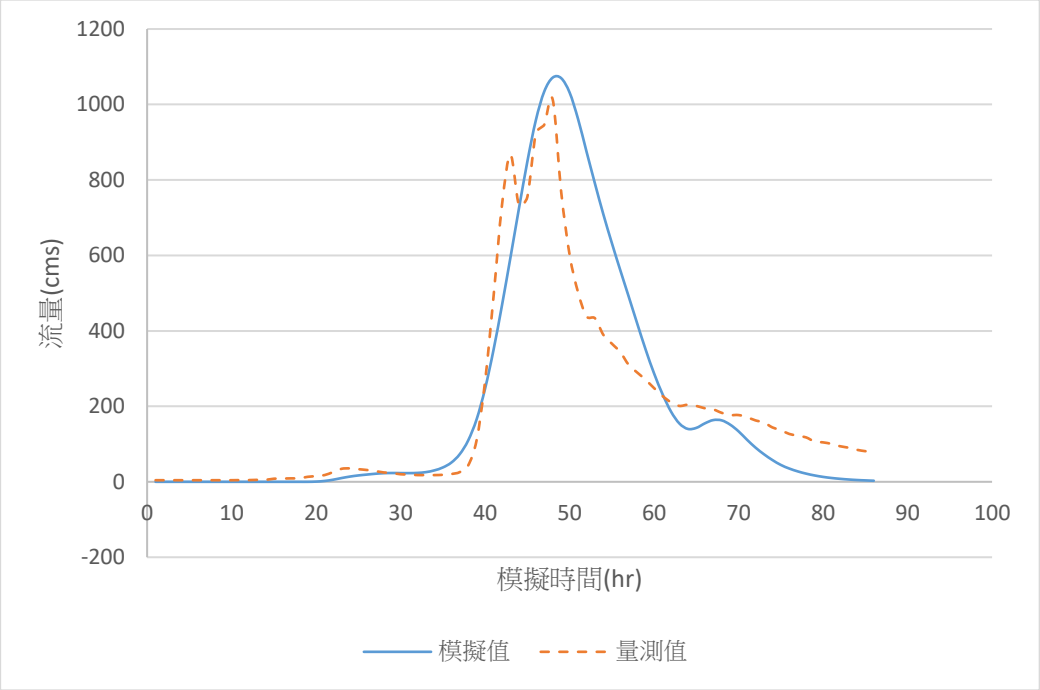
測站	面積（m^2）	百分比
雲霞	126697953	18
高義	63796811	9
巴陵	65756443	9
玉峰	95203209	13
嘎拉賀	100539828	14
白石	127520969	18
西丘斯山	143453987	20

5、模式率定驗證

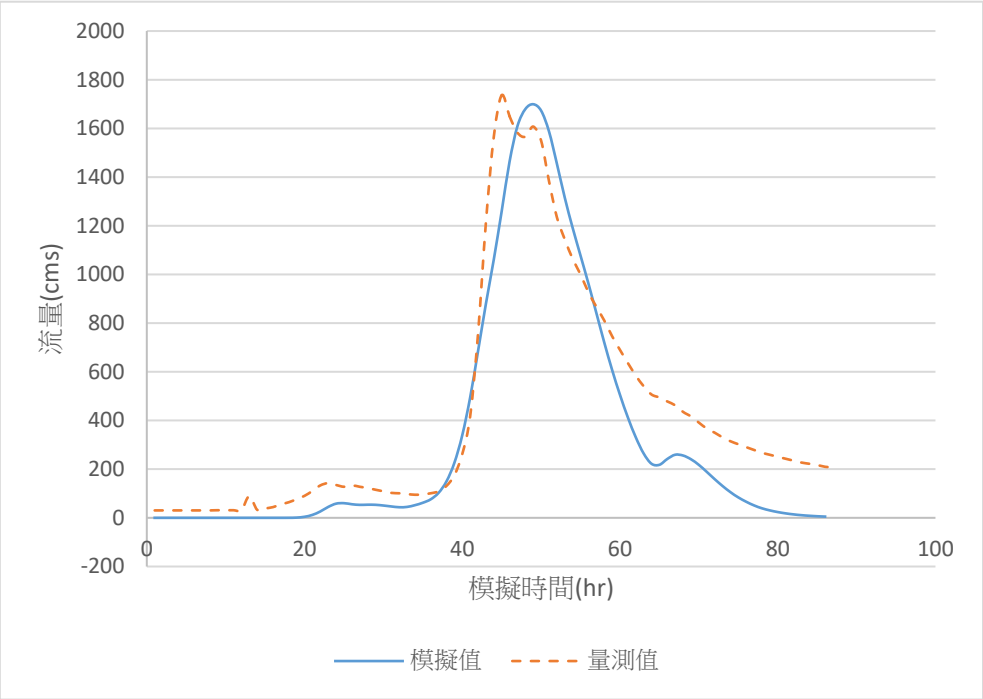
率定事件採用潭美颱風事件(模擬時間共 87 小時)，以大漢溪入流口玉峰流量站以及下游處霞雲站，進行模擬值與實測值比較，並修改參數 CN、Lag time、K、X，進行最佳化的配置，模擬結果如圖 3.2.6，玉峰站洪峰誤差為 5.7%，雲霞站洪峰誤差為 2.13%，皆由良好的改善，以此參數作為率定參數。

驗證事件為菲特颱風事件(模擬時間共 87 小時)，以大漢溪入流口玉峰流量站以及下游處霞雲站，進行模擬值與實測值比較，如圖 3.2.7 所示。玉峰站洪峰誤差為 6.75%，雲霞站洪峰誤差為 5%。

綜合以上率定驗證結果顯示其出流口平均誤差約為 3.5%，參數具有一定的可信度，之後以此參數進行流量資料的模擬。

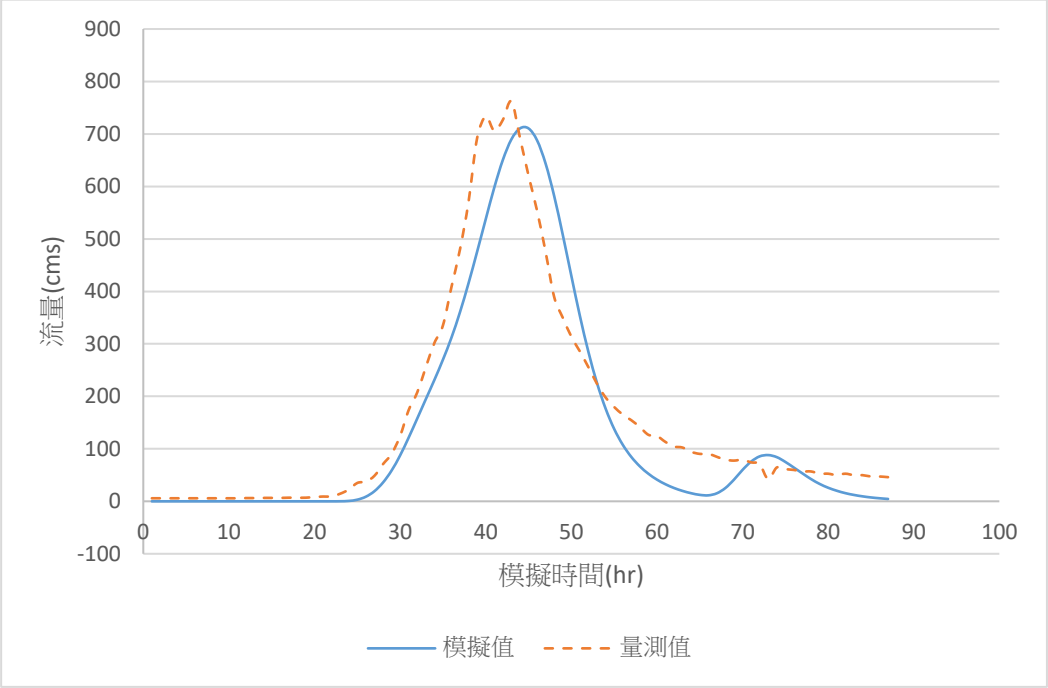


玉峰站流量模擬與實測值比較圖

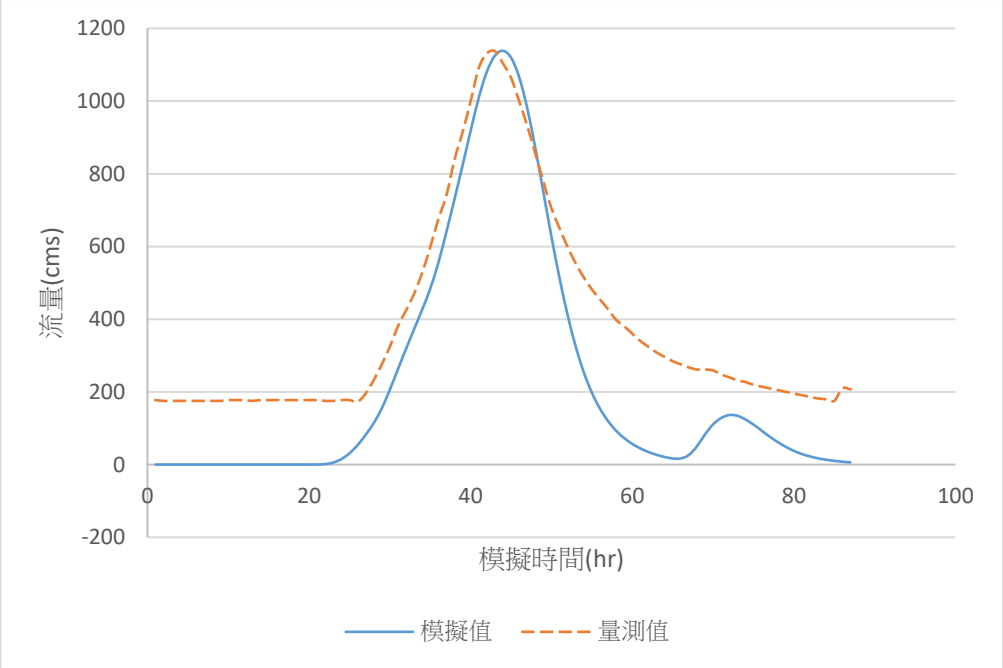


霞雲站流量模擬與實測值比較圖

圖 3.2.6 潭美颱風最佳化參數模擬結果



玉峰站流量模擬與實測值比較圖



霞雲站流量模擬與實測值比較圖

圖 3.2.7 潭美颱風事件

3.3 河道輸砂分析

本研究案例皆屬於河段區域不大且僅探討泥砂濃度與沖淤特性，故選擇二維模式之 SRH-2D 做為模擬之數值模式。

3.3.1 SRH-2D 模式

SRH-2D(全名 Sediment and River Hydraulic-Two Dimension model)由美國墾務局開發的二維水理輸砂數值模式，透過有限體積法求解二維淺水波方程式，亦稱水深平均聖凡南方程式(St.Venant equation)。此模式具有許多特點，其對於網格選擇較為彈性，可以使用結構化或非結構化網格或是混合網格，可以模擬所有流況之水流，如超臨界流、過渡流、亞臨界流，模式亦可以對多種物理量進行輸出，如水深、底床高程、水面高程、水深平均速度、D_{50}、輸砂濃度等。參數設定上提供較少參數可以調整，許多參數為預設值，使模式較為穩定且易於操作。針對本章節將針對 SRH-2D 之水理、輸砂控制方程式與本研究使用之輸砂經驗公式說明，並介紹模式中輸砂參數之物理意義。

1、 水理控制方程式

假設水深在於渠道中相對於寬度十分的淺，亦假設忽略垂直向的運動可以忽略，故本模式得以求解水深平均的二維方程式作為取代三維 Navier-Stokes 方程式。在二維中水平方向遠大於垂直向長度的，水流連續方程式與動量方程式為(Kron et al, 1990) :

$$\frac{\partial h}{\partial t}+\frac{\partial hU}{\partial x}+\frac{\partial hV}{\partial y}=0$$

$$\frac{\partial h\mathrm{U}}{\partial t}+\frac{\partial hU\mathrm{U}}{\partial x}+\frac{\partial hV\mathrm{U}}{\partial y}=\frac{\partial h\mathrm{T}_{xx}}{\partial x}+\frac{\partial hT_{xy}}{\partial y}-gh\frac{\partial z}{\partial x}-\frac{\tau_{bx}}{\rho}+D_{xx}+D_{xy}$$

$$\frac{\partial hV}{\partial t}+\frac{\partial hUV}{\partial x}+\frac{\partial hVV}{\partial y}=\frac{\partial h\mathrm{T}_{xy}}{\partial x}+\frac{\partial hT_{yy}}{\partial y}-gh\frac{\partial z}{\partial x}-\frac{\tau_{by}}{\rho}+D_{yx}+D_{yy}$$

以上公式中，t 為時間、x 與 y 分別是水平座標、h 是水深、U 與 V 為水深平均 x 與 y 軸之速度分量、g 為重力加速度、$\mathrm{T}_{xx},\mathrm{T}_{xy},\mathrm{T}_{yy}$ 為水深平均紊流應力、$D_{xx},D_{xy},D_{yx},D_{yy}$ 為由於水深平均產生的擴散項、$\mathrm{z}=\mathrm{z}_b+h$ 為水表面高程、z_b 底床高程、ρ 是水密度、τ_{bx},τ_{by} 為底床剪應力(摩擦)。底床剪應力可以使用下列曼寧粗糙度公式獲得:

$$(\tau_{bx},\tau_{by})=\rho U_*^2\frac{(\mathrm{U},\mathrm{V})}{\sqrt{\mathrm{U}^2+\mathrm{V}^2}}=\rho\mathrm{C}_f\sqrt{\mathrm{U}^2+\mathrm{V}^2}(\mathrm{U},\mathrm{V}),\ \ \mathrm{C}_f=gn^2/h^{1/3}$$

上式中，n 為曼寧粗糙係數。紊流應力基於以下 Boussinesq 方程式計算:

$$T_{xx}=2(\upsilon+\upsilon_t)\frac{\partial U}{\partial x}-\frac{2}{3}k$$

$$T_{yy}=2(\upsilon+\upsilon_t)\frac{\partial \mathrm{V}}{\partial y}-\frac{2}{3}k$$

$$T_{xy}=2(\upsilon+\upsilon_t)(\frac{\partial U}{\partial y}+\frac{\partial V}{\partial x})$$

其中υ為水的運動黏度、υ_t紊流渦流黏度(turbulent eddy viscosity)、k 為紊流動能。紊流渦流黏度則另外透過下述紊流模式計算。在 SRH-2D 中提供兩種常見的紊流模式供使用(Claps&Murrone,1994)，水深平均拋物線模式(parabolic model)與雙方程 k-ε 模式。在水深平均拋物線模式中，$\upsilon_t=C_tU_*h$ ，其中U_*為底床摩擦速度，模式常數C_t範圍介在 0.3 至 1.0 之間，在 SRH-2D 中預設值設定為 0.7。

以上控制方程式在 SRH-2D 中使用有限體積法(finite volume approach)離散化。透過隱式法對時間積分以達到模式的穩定與效

率，解答域(solution domain)包含了所有的非結構網格，並假設為任意多邊形網格且所有變數皆被儲存在多邊形的幾何中心。

2、 輸砂控制方程式

選擇 SRH-2D 之原因在於其可以進行動床模擬，關於輸砂模擬主要方程式在以下介紹。輸砂率主要來自底床材料性質、流況、上游輸砂量。在 SRH-2D 中，使用計算單層總載重的方式取代計算兩層的方式，即便其無法分辨懸浮載與底床載的運動行為差異，仍可以提升計算效率。總載重為懸浮載與底床載的加總，本模式採納計算總載重方式的原因為相同大小的顆粒在不同流況下可能產生不同種結果。對於單一的泥砂顆粒來說，會根據其粒徑大小、重量、流況決定為懸浮載或底床載。由於官方尚未發布 SRH-2D 第三版之說明手冊，因此以下泥砂傳輸理論的來源為(Mooges,2010)。SRH-2D 的泥砂傳輸使用了非平衡的概念假設，底床高程隨時間的變化率會與泥砂通量的發散量相等，底床的沉積物性質空間分布可以是均勻或非均勻且被劃分為多個沉積物類別(sediment size classes)，各個底床類別(k)必須滿足以下質量守恆方程式

$$\frac{\partial hC_k}{\partial t}+\frac{\partial hC_k}{\partial x}+\frac{\partial_t hC_k}{\partial y}=\frac{1}{L_k}(q_k^*-\sqrt{U^2+V^2}hC_k)$$

其中 h 為水深；t 為時間；C_k 為第 k 種沉積物類別按體積計的水深平均之泥砂濃度；U 與 V 分別為 x 與 y 軸水深平均之速度分量；L_k 為非平衡之調適長度(adaptation length) q_k^* 為第 k 種類別之平衡部分輸砂能力。不同的輸砂方程式對於 q_k^* 之計算方式亦不同。

本模式針對底床泥砂動力學和與底床材料荷載運輸的相互作用進行模擬。在現實中由於沖蝕與堆積，底床高程會隨時更動。底床高程

(Z_b)會透過下式計算，此方程式與式(2.4)等號右邊的項會做連結，並更新活動層的組成或厚度:

$$(1-p_b)(\frac{\partial z_b}{\partial t})_k = -\frac{1}{L_b}(q_k^* - \sqrt{U^2+V^2}hC_k)$$

式中 p_b 為底床材質的孔隙率。

在 SRH-2D 中，床被分為兩層以解釋床砂動力學:

1. 活動層(active layer) 底床的最頂層，上層底床層和床與床之間的交換沉積
2. 子表層(sub-surface layer) 提供泥砂供給活動層進行沖刷。

如圖 3.3.1 所示，活動層是底床與床載泥砂交換的頂層;基於子表面層的沉積物組成，可以將子表面層分成數層。當活動層遭受侵蝕，子表面層會提供泥砂供給給活動層，因此兩層的粒徑組成可能會隨著時間而改變。下式為活動層級配的方程式：

$$\frac{\partial \delta_a p_{ak}}{\partial t} = (\frac{\partial z_b}{\partial t}) + p_{ak}^{*}(\frac{\partial \delta_a}{\partial t} - \frac{\partial \delta_b}{\partial t})$$

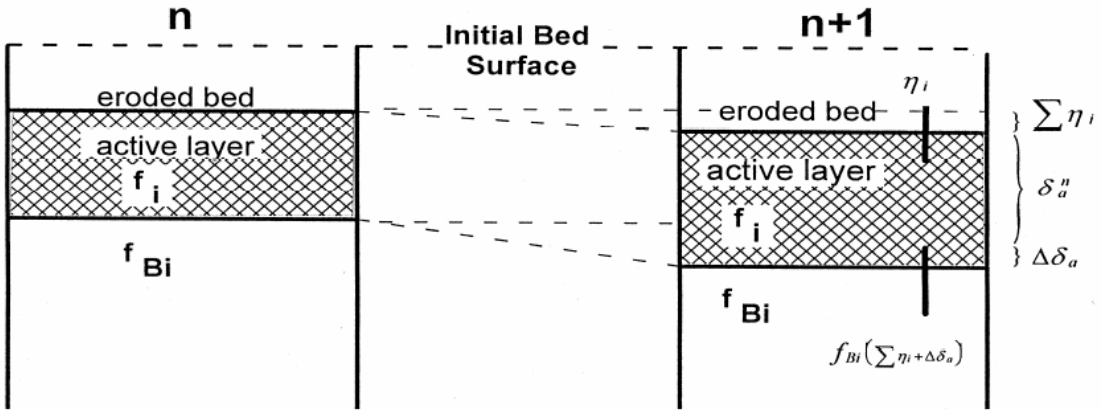
式中 δ_a 為活動層厚度；p_{ak} 為活動層泥砂粒徑的體積等級($\sum_k p_{ak} = 1$)。

$$p_{ak}^{*} = p_{ak} \qquad \text{if...}(\frac{\partial \delta_a}{\partial t} - \frac{\partial \delta_b}{\partial t}) < 0$$

pak *是泥砂粒徑級別 k 的下表面部分(sub-usrface fraction)。

$$\frac{\partial z_b}{\partial t} = \sum_k (\frac{\partial z_b}{\partial t})_k \qquad \text{if...}(\frac{\partial \delta_a}{\partial t} - \frac{\partial \delta_b}{\partial t}) > 0$$

輸砂率則會因活動層的粒徑組成改變而改變。



活動層定義圖(Reed 等，1998)

圖 3.3.1 活動層定義圖

在本研究中，使用 2 組輸砂公式進行參數率定，主要為計算底(bed load)為主，以下分別對不同輸砂公式(sediment transport capacity)之參數進行說明：

1. Muller-Peter-Meyer(1948)：

$$\gamma\left(\frac{K_s}{K_r}\right)^{3/2} RS = 0.047\left(\gamma_s - \gamma\right)d + 0.25\rho^{1/3}q_b^{2/3}$$

其中 $\left(\frac{K_s}{K_r}\right)^{3/2} = \frac{S_r}{S}$ ； $S = \frac{V^2}{K_S^2 R^{4/3}}$ ； $S_r = \frac{V^2}{K_r^2 R^{4/3}}$ ； $K_r = \frac{26}{d_{90}^{1/6}}$ and為 γ_s 水及泥砂的比重 (tons/m)；R為水力半徑(m)；S為能量坡降；d為中值粒徑(m)；ρ 為水的密度(ton-s/m)； q_b 為單位時間於單位寬度之底床載輸砂量(ton/s/m)； K_s 及 K_r 為底床載輸砂量參數。

2. Parker(1990)：

$$\frac{q_{bi}g\left(s-1\right)}{p_i\left(\tau_b/\rho\right)^{1.5}} = 11.93f\left(\phi_i\right)$$

其中 $\phi_i = \theta_i/\left(\xi_i\theta_c\right)$；$\phi_i = \tau_g/\left(\gamma\left(s-1\right)d_i\right)$ ；$\frac{U}{\sqrt{\tau_g/\rho}} = 2.5\ln\left(\frac{12.27R'}{k_s}\right)$ $\xi_i = \left(d_i/d_{50}\right)^{-\alpha}$；$q_s$ 為單位寬輸砂率；τ_b 為底床總應力；d_{50} 為中值粒徑；g為重力加速度；γ 為水的比重；s為相對泥砂密度 $\left(\rho_s/\rho\right)$；ϕ_i 為相對參考應力的應力尺度；θ_c 為參考Shields參數；θ_i 為第i級泥砂粒徑的Shields參數；τ_g 為顆粒剪應力；U 為橫剖面平均速度；R' 為顆粒剪應力造成的水力半徑 ($\tau_g = \gamma R'S_f$)； k_s 為顆粒粗糙度(k_s =2 d_{50})；ξ_i 為曝光因子；α 為固定值。

3、 紊流模式(turbulence model)

SRH-2D模式中有兩種紊流模式可選擇，分別為Parabolic eddy viscosity model與K-ε model。前者為常見之零方程閉合(zero-equation closure schemes)模式，後者為兩方程(two-equation)模式。由於紊流模式不需另外求解偏微分方程式，因此相對於K-ε model較具有計算效率。前者對於一般問題來說已足夠描述一般較大尺度之紊流流場問題，但若針對側向輸砂及水理流場之問題，則建議採用K-ε model計算。

4、 混合層厚度 (mixing layer thickness)

為了考慮河床質粒徑垂向分層之變化關係，在不可沖刷層上方之河床質通常會區分數層土層進行計算，最上層通常為懸浮載、推移載與河床質之交換區域，該層即可稱為混合層。混合層厚度與輸砂變化之時間尺度有關，對於較小時間尺度問題來說，如泥砂顆粒於沖刷坑之啟動沖刷過程，混合層厚度與泥砂粒徑大小有關，且相對較為敏感；對於較大時間尺度問題來說，如床形波長之形成過程，混合層厚度可為床形高度之尺度。Wu and Vieira (2002)曾建議混合層厚度約為砂丘高度之一半或兩倍河床質之d50。

5、 調適長度 L（adaptation length）

調適長度為河床上平衡至非平衡輸砂過程之特徵長度，L通常與案例之推移載輸砂過程相關，由推移載過程至形成床形(bed forms)之距離通常即為調適長度大小。若河床多由砂漣(sand ripples)所構成，L可為泥砂平均跳躍長度或砂漣長度；若河床多由砂丘(sand dunes)所構成，L可為5~10倍之水深；若河床多由交替砂洲(alternate bars)所構成，L可為交替砂洲長度或6.3倍之河道寬度；若研究河段為蜿蜒變遷型河道，L可為蜿蜒波長或12倍河道寬度；若調適長度小於網格大小，則可能

產生極大計算誤差。在天然河川之工程應用上，平均河寬為調適長度檢定之建議初始值。

3.3.2 評估標準

模式的表現與計算時間，必須有所權衡，快速運算往往造成正確率低，反之亦然。本研究中率定參數的選擇，使用均方根誤差(Root mean square error, RMSE)作為統計標準，續述如下:

1. 均方根誤差(Root mean square error, RMSE):

均方根誤差亦稱做標準誤差，是一種常用的測量數值之間差異的量度，其數值常為模型預測的量或是被觀察到的估計量。方均根偏移代表預測的值和觀察到的值之差的樣本標準差（sample standard deviation），當這些差值是以資料樣本來估計時，他們通常被稱為殘差；當這些差值不以樣本來計算時，通常被稱為預測誤差（prediction errors）。方均根偏移主要用來聚集預測裡誤差之大小，通常是在不同的時間下，以一個量值來表現其預測的能力。方均根偏移是一個準度的量度，但因其與數值範圍有關，因此被限制只能用來比較不同模型間某個特定變數的預知誤差，然其僅能顯示模式模擬值與觀測值之誤差大小，無法衡量模式優劣，故必須使用其他指標輔助分析。均方根誤差公式如下:

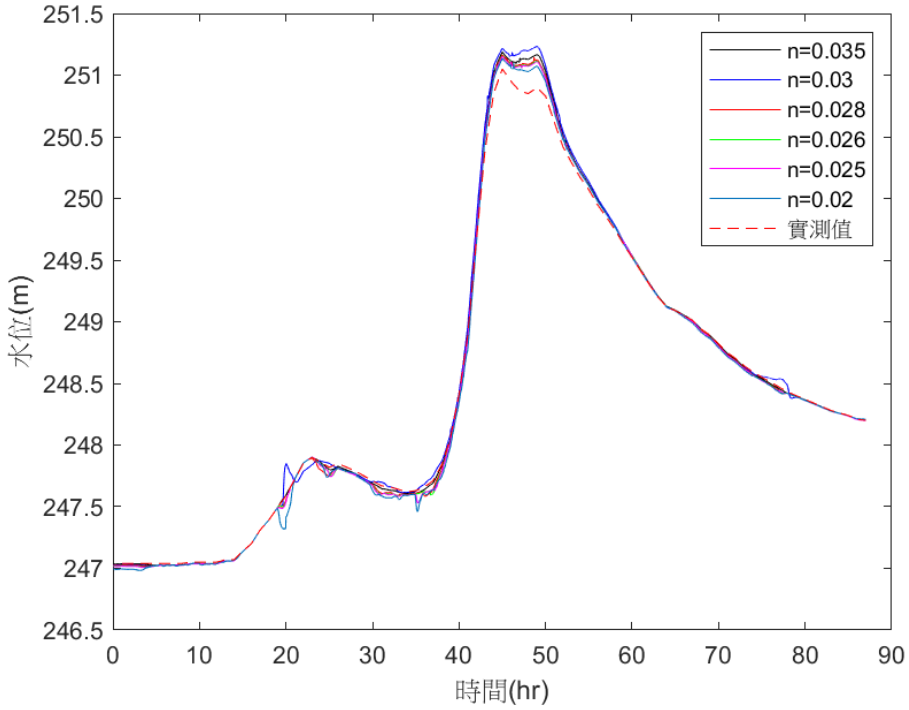
$$RMSE = \sqrt{\frac{\sum_{i=1}^{N} (\hat{Q}(i) - Q(i))^2}{N}}$$

3.3.3 水理參數率定

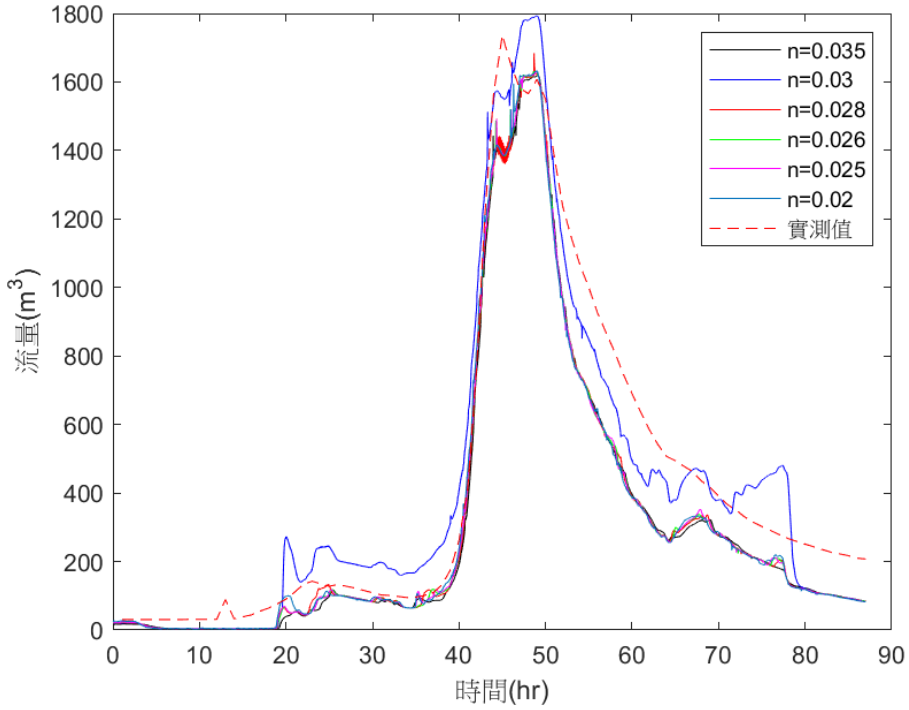
一般輸砂模擬需先完成水理率定，待水理模式率定完成，再調整輸砂參數，率定輸砂相關物理量，可使率定之參數較少、減少複雜度。在 SRH-2D 中，網格對於速度場的分布相當敏感；而水位高程則被推薦用來率定曼寧 n 值，曼寧 n 值亦為唯一需校正之水理參數(Lai 2009)，因此率定水理參數時，首先使用針
對網格大小進行率 定，與網格大小相關模式參數亦有時間步幅，確立網格後進行曼寧 n 值率定。

率定事件採用潭美颱風事件(模擬時間共 87 小時)，以下游處霞雲站，進行模擬值與實測值比較。本研究假設底床質分佈均勻，以均方根誤差(Root mean square error, RMSE)對曼寧 n 值進行檢定，取 n 為 0.35、0.3、0.28、0.26、0.25，水位、流量模擬結果如圖 3.3.1，均方根誤差比較如表 3.3.1。

因水位均方根誤差變化不大，以流量均方根誤差最小為最佳結果，此時時間步幅 1.5s、曼寧 n 值 0.03 時表現最佳，此時之水位、流量模擬結果如圖 3.3.2。

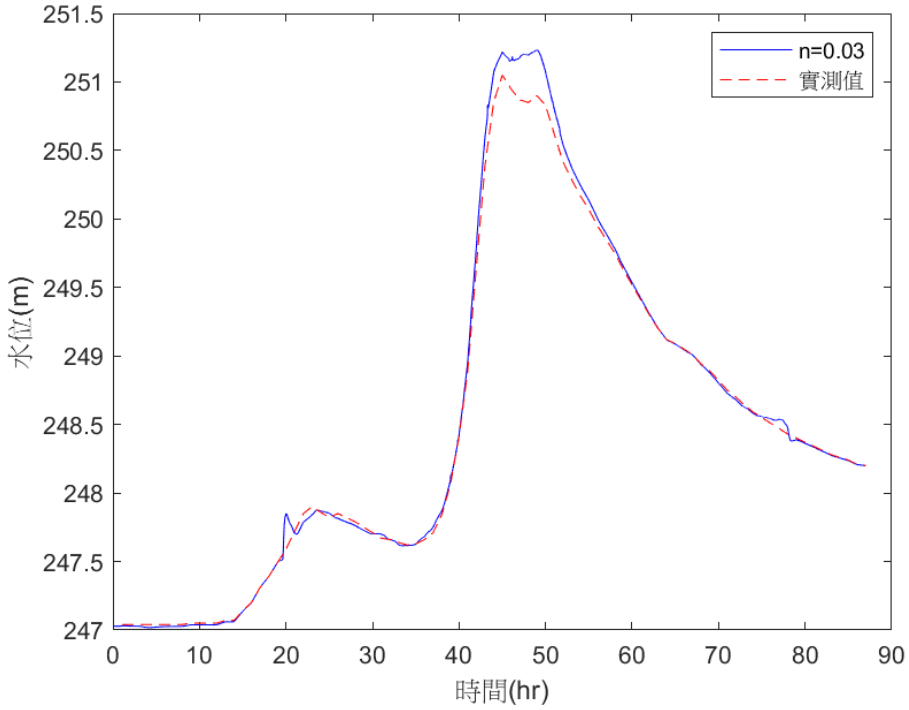


潭美颱風水位比較圖

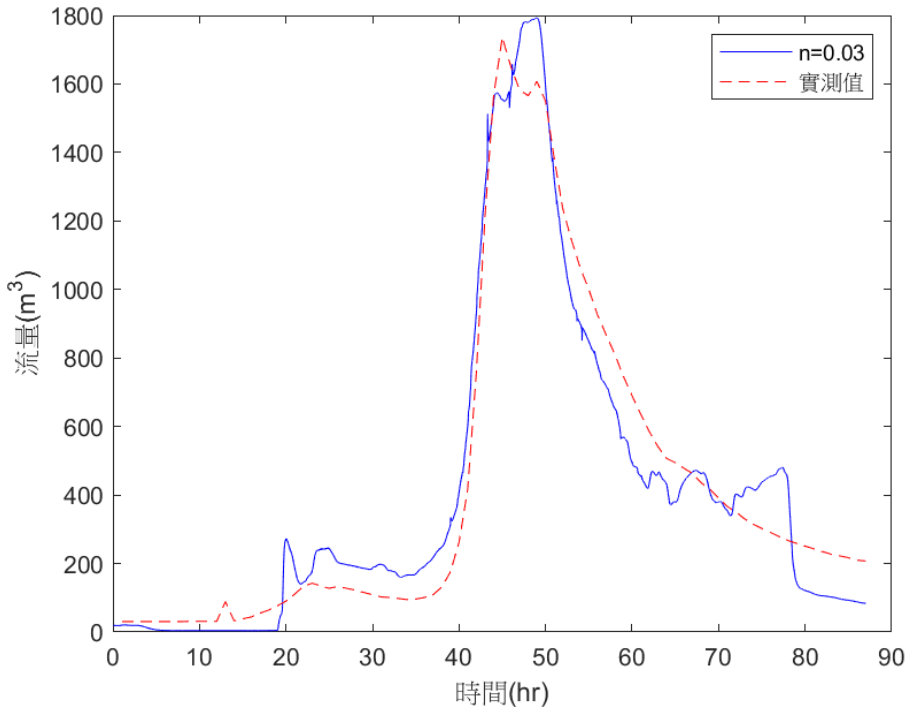


潭美颱風流量比較圖

圖 3.3.1 不同 n 值之水位、流量模擬結果比較



潭美颱風水位模擬與實測值比較圖



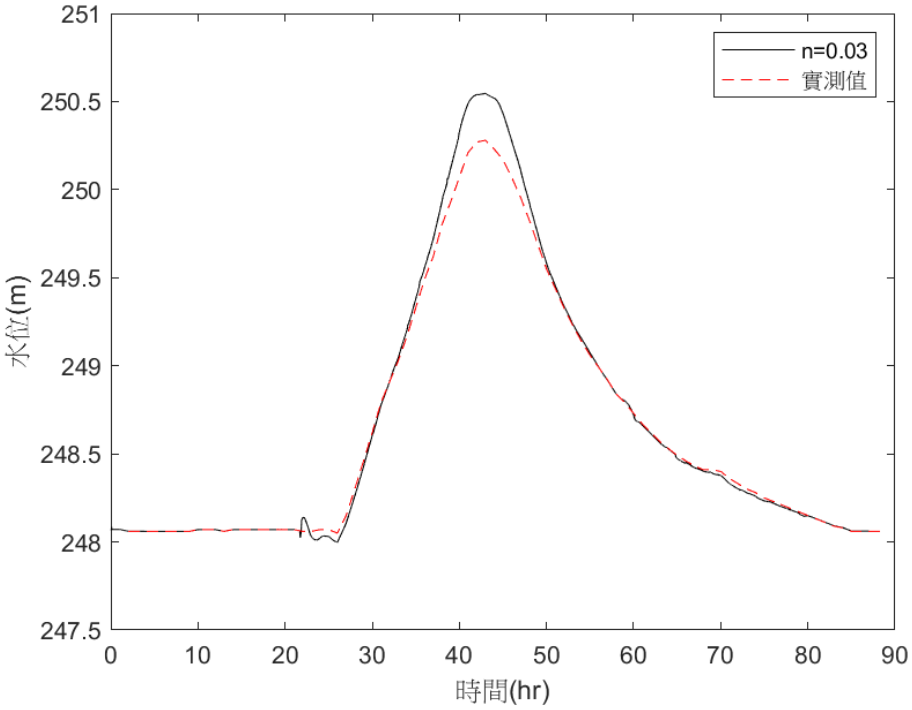
潭美颱風流量模擬與實測值比較圖

圖 3.3.2　n=0.03 潭美颱風水位、流量模擬結果比較

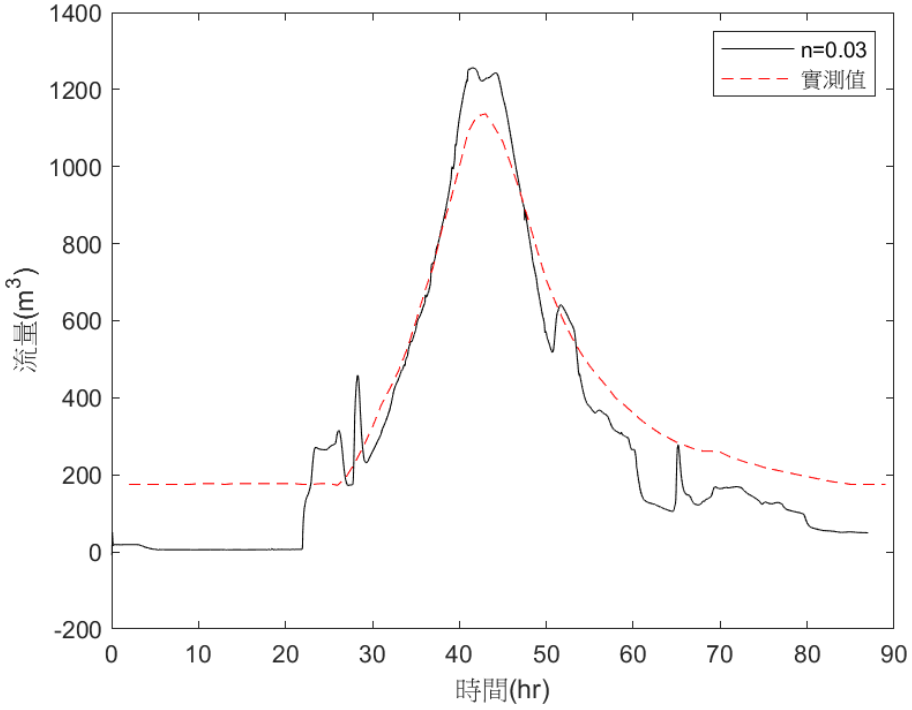
表 3.3.1 不同曼寧 n 值流量、水位均方根誤差比較表

曼寧 n 值	流量均方根誤差	水位均方根誤差
n=0.035	136	0.1
n=0.03	121	0.11
n=0.028	137	0.1
n=0.026	139	0.096
n=0.025	140	0.094
n=0.02	150	0.048

驗證事件為菲特颱風事件(模擬時間共 89 小時)，以下游處霞雲站進行模擬值與實測值比較，如圖 3.3.2 所示。此時水位方均根誤差為 0.11，流量方均根誤差為 116。



菲特颱風水位模擬與實測值比較圖



菲特颱風流量模擬與實測值比較圖

圖 3.3.2　n=0.03 之菲特颱風水位、流量模擬結果比較

3.3.4 輸砂動床參數率定

因為本次研究區域根據粒徑資料判斷本研究河段為礫石河床，礫石河床主要為底床載為主，故選用 Parker(1990)與 MPM(2006)公式計算泥砂濃度的輸砂公式。

由 3.3.3 章節水理律定率定結果選用 n=0.03，入砂濃度選用實測資料，進行動床模擬，改變不同的調適長度並與實測資料進行均方根誤差的比較，圖 3.3.3、3.3.4 為不同模式比較結果，可以知道 Parker 公式最小 RMSE 值為 34.75，此時的調適長度為 220 公尺; MPM 公式最小 RMSE 值為 34.94，此時的調適長度為 90 公尺。

最後選擇 RMSE 值較小的 Parker 公式，調適長度為 220 公尺作為率定參數，並進行菲特颱風的驗證，RMSE 值為 10.335。

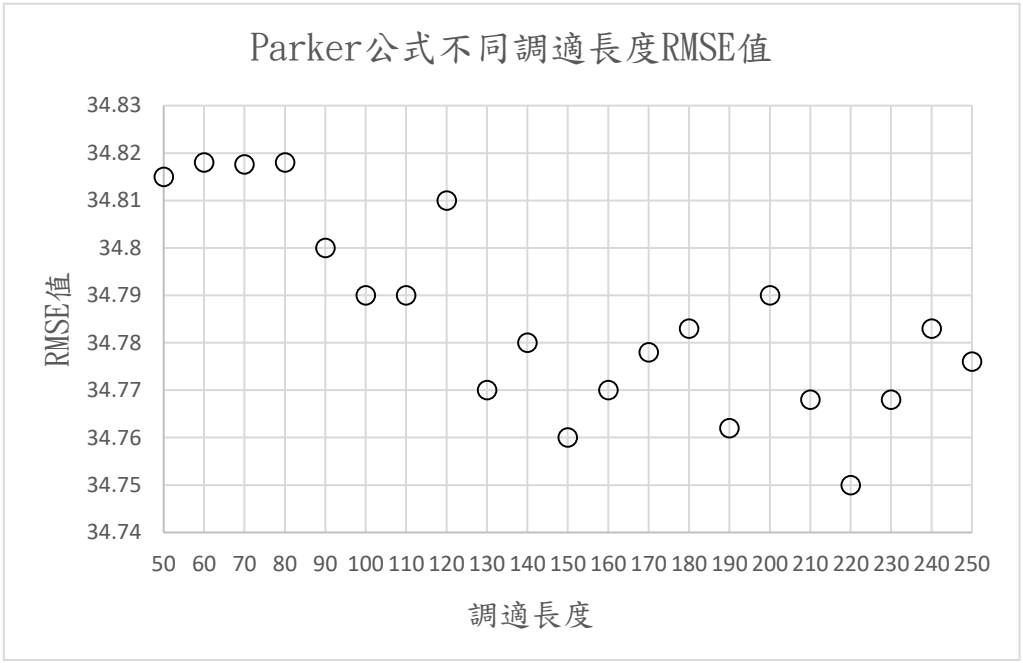


圖 3.3.3 Parker 公式不同調適長度 RMSE 值

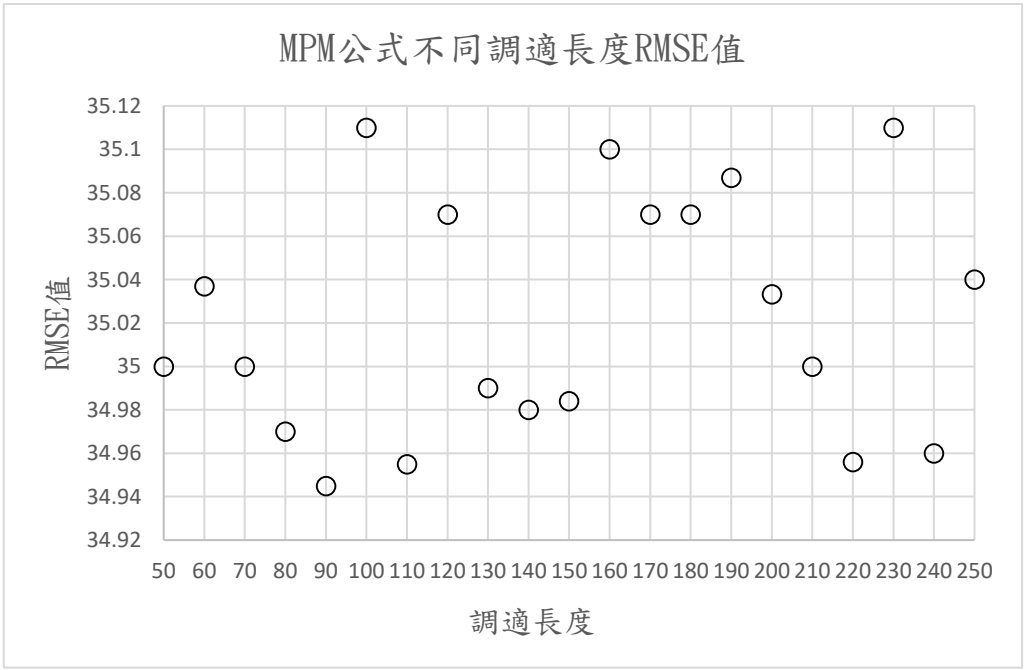


圖 3.3.4 MPM 公式不同調適長度 RMSE 值

3.4 設計暴雨分析

針對降雨量的取得一般採用當地雨量站長期觀測所得的雨量資料，藉由統計方式進行頻率分析，建置各種延時所對應的雨型公式。分別計算 5 年、10 年、20 年、50 年、100 年等重現期之一日暴雨量，再由雨型分佈求得各設計降雨組體圖，以作為 HEC-HMS 輸入雨量資料的依據。

3.4.1 降雨分析

針對集水區平均雨量資料，採年最大值選用法整理出霞雲、高義、巴陵、玉峰、嘎拉賀、白石、西丘斯山雨量站在不同延時之歷年最大降雨量延時，且採用 3、6、12、24、 48 小時，列表呈現，如表 3.4.1~7。

表 3.4.1 霞雲站各延時之年最大暴雨量序列單位：mm

霞雲站	3 小時	6 小時	12 小時	24 小時	48 小時
1998	142	243	366	531	623
1999	156	174	174	238	313
2000	93	152	274	405	433
2001	143	225	369	554	952
2002	108	140	247	333	363
2003	81	118	126	170	234
2004	138	264	429	632	898
2007	148	245	358	534	657
2008	71	131	132	160	190
2009	102	133	158	289	392
2011	92	134	193	238	318
2012	156	249	407	563	722
2013	130	216	305	371	372
2014	128	135	135	135	141
2015	149	232	303	414	429
2016	122	185	336	594	615
2017	93	168	236	251	335
2018	51	55	58	88	114

表 3.4.2 高義站各延時之年最大暴雨量序列單位：mm

高義站	3 小時	6 小時	12 小時	24 小時	48 小時
1998	171	284	388	555	640
1999	106	113	114	121	132
2000	99	137	236	341	361
2001	115	202	361	508	859
2002	108	197	330	500	536
2003	61	65	89	153	186
2004	192	361	623	894	1202
2007	132	253	451	719	865
2008	87	104	145	176	177
2009	96	118	165	314	481
2011	137	139	164	187	219

2012	138	252	427	596	801
2013	147	225	394	474	474
2014	78	94	117	135	184
2015	174	275	472	610	625
2016	159	283	404	496	511
2017	90	143	197	210	305
2018	50	50	51	76	100

表 3.4.3 嘎拉賀站各延時之年最大暴雨量序列單位：mm

嘎拉賀站	3 小時	6 小時	12 小時	24 小時	48 小時
1998	98	152	230	404	507
1999	68	69	69	94	131
2000	91	156	270	383	414
2001	123	219	330	455	767
2002	64	104	180	320	350
2003	40	64	89	128	147
2004	156	303	518	683	855
2007	99	184	278	466	533
2008	64	110	130	152	187
2009	107	111	179	257	398
2011	70	105	137	204	266
2012	88	169	277	413	555
2013	136	192	295	339	339
2014	84	126	183	325	336
2015	188	269	345	409	445
2016	142	216	327	685	398
2017	66	99	152	161	237
2018	24	27	36	66	94

表 3.4.4 玉峰站各延時之年最大暴雨量序列單位：mm

玉峰站	3 小時	6 小時	12 小時	24 小時	48 小時
1998	197	336	475	607	698
1999	58	68	68	82	100
2000	112	134	176	274	298
2001	163	269	403	521	793
2002	144	273	459	631	679
2003	51	58	103	170	203
2004	237	454	813	1175	1558
2007	140	232	384	604	702
2008	84	99	99	110	130
2009	94	119	146	265	391
2011	203	214	215	224	235
2012	106	169	220	346	494
2013	192	296	491	541	541
2014	89	129	185	285	291
2015	118	185	289	371	391
2016	120	213	287	357	366
2017	73	97	146	159	236
2018	35	42	50	92	122

表 3.4.5 巴陵站各延時之年最大暴雨量序列單位：mm

巴陵站	3 小時	6 小時	12 小時	24 小時	48 小時
1998	122	194	270	462	566
1999	78	95	97	98	111
2000	82	131	246	332	387
2001	83	142	215	304	551
2002	89	127	236	411	434
2003	50	66	92	147	160
2004	107	181	320	506	783
2007	136	233	398	676	813
2008	95	161	191	224	227
2009	106	129	219	342	533
2011	103	126	145	178	207

2012	125	234	381	558	792
2013	122	203	337	422	423
2014	42	58	72	74	76
2015	212	344	498	625	660
2016	154	296	469	583	605
2017	115	119	148	160	216
2018	24	29	37	72	94

表 3.4.6 白石站各延時之年最大暴雨量序列單位：mm

白石站	3 小時	6 小時	12 小時	24 小時	48 小時
1998	171	286	378	474	535
1999	46	59	69	121	155
2000	109	167	236	311	347
2001	124	215	295	414	705
2002	154	239	386	601	691
2003	55	100	108	155	165
2004	233	459	842	1263	1592
2007	130	210	362	514	580
2008	67	85	98	119	121
2009	75	91	149	272	405
2011	65	75	98	104	120
2012	114	214	326	493	627
2013	247	366	541	611	613
2014	74	74	102	149	156
2015	148	218	300	373	387
2016	131	218	363	424	432
2017	97	120	136	148	254
2018	26	43	55	102	150

表 3.4.7 西丘斯山站各延時之年最大暴雨量序列單位：mm

西丘斯山	3 小時	6 小時	12 小時	24 小時	48 小時
1998	93	163	269	423	509
1999	52	62	86	103	116
2000	109	187	297	395	442
2001	132	195	281	377	556
2002	92	130	209	341	362
2003	63	104	134	221	229
2004	102	192	326	485	653
2007	114	212	382	579	701
2008	80	150	212	252	280
2009	108	147	232	376	522
2011	67	119	200	291	388
2012	118	201	390	607	866
2013	96	150	246	298	305
2014	54	93	121	122	122
2015	149	266	440	541	584
2016	133	238	352	438	471
2017	115	174	231	290	384
2018	26	31	37	62	82

3.4.2 暴雨頻率分析

析方法何種較適用於本流域，茲採標準誤差（SE）予以檢定，當 SE 值愈小，則表示該法機率分布之理論值與實際觀測值密合度愈好，屬於較理想之機率分布，其暴雨量頻率分析值較為可信，茲將該項公式詳列如下：

誤差平方和: $$\mathrm{SEE}=\sum_{i=1}^{n}(X_i-R_i)^2$$

標準誤差: $$\mathrm{SE}=(\frac{SEE}{n-m})^{\frac{1}{2}}$$

韋伯(Weibull)法: $$\frac{N+1}{m}$$

式中： n為樣本數； i =1, 2, 3…n　排序

X_i為第 i 個由大至小排列之觀測雨量

R_i為第 i 個由大至小排列由韋伯法計算之累積機率

P_i 所對應之理論降雨量

m 為推估參數個數

選定之機率分布如表3.4.8，將最適機率分布及暴雨頻率分析成果，2 年、5 年、10 年、25 年、50 年、100 年及 200 年不同重現期之降雨量呈現如表3.4.9~15。

表 3.4.8 選定之機率分布

站名	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
霞雲站	對數皮爾遜Ⅲ	常態分佈	皮爾遜Ⅲ	對數皮爾遜Ⅲ	極端值Ⅰ
高義站	皮爾遜Ⅲ	對數皮爾遜Ⅲ	對數皮爾遜Ⅲ	極端值Ⅰ	極端值Ⅰ
嘎拉賀站	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ
玉峰站	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ	對數皮爾遜Ⅲ
巴陵站	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ	對數皮爾遜Ⅲ	對數皮爾遜Ⅲ
白石站	極端值Ⅰ	極端值Ⅰ	極端值Ⅰ	對數皮爾遜Ⅲ	對數皮爾遜Ⅲ
西丘斯山	皮爾遜Ⅲ	皮爾遜Ⅲ	皮爾遜Ⅲ	常態分佈	極端值Ⅰ

表 3.4.9 霞雲站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	117.1	177	259	348.2	414.4
5	142.7	226.3	349.3	512.3	678.7
10	153.3	251.8	394.9	596.7	853.8
25	162.2	278.9	431.6	679.3	1075
50	166.6	296.4	472	726.9	1239.1
100	169.8	312.2	498.4	764.9	1402
200	172	326.6	522.2	795.5	1564.4

表 3.4.10 高義站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	117.4	174.2	261.9	358	436
5	152	257.1	421.8	612.9	768.9
10	171	302.8	512.4	781.6	989.3
25	191.9	350.8	607.6	994.9	1267.8
50	205.7	380.5	666	1153	1474.5
100	218.4	405.8	715	1310	1679.5
200	230.2	427.6	756.4	1466.5	1883.9

表 3.4.11 嘎拉賀站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	88.79	138	206.2	303.8	356.4
5	133.9	216.5	334.9	499	579.6
10	163.8	268.4	420.1	628.3	727.4
25	201.5	334.1	527.7	791.6	914.1
50	229.5	382.8	607.6	912.8	1052.6
100	257.3	431.1	686.8	1033	1190.1
200	285	479.3	765.8	1152.9	1327.1

表 3.4.12 玉峰站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	114.7	172.2	249.7	339.1	359.4
5	176.6	290	461.2	631.1	660.6
10	217.5	368	601.2	824.4	907
25	269.2	466.6	778.1	1068.7	1270.1
50	307.6	539.7	909.4	1250	1577.6
100	345.7	612.2	1039.7	1429.9	1916.5
200	383.7	684.5	1169.5	1609.1	2289.1

表 3.4.13 巴陵站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	96.21	147.4	223	314.3	387.5
5	142.7	235.7	369.8	515.5	660.1
10	173.5	294.1	467	627.9	840.6
25	212.4	368	589.8	743.8	1068.7
50	241.3	422.7	680.9	813.2	1237.9
100	269.9	477.1	771.3	870.3	1405.9
200	298.5	531.3	861.4	917.3	1573.2

表 3.4.14 白石站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	105.9	163.5	239.8	280.8	338.7
5	171.4	285.4	456.4	531.7	640.8
10	214.8	366.1	599.7	749.9	904.1
25	269.6	468.1	780.9	1090.2	1315.4
50	310.3	543.8	915.2	1394.1	1683.3
100	350.6	618.9	1048.6	1743.9	2107.8
200	390.8	693.7	1181.5	2145.5	2595.9

表 3.4.15 西丘斯山站各延時雨量之機率分布套配

延時 / 迴歸年	各延時所選定之機率分布				
	3小時	6小時	12小時	24小時	48小時
2	98.28	161.3	250.9	344.5	389.6
5	122.3	207.8	339.5	477	619.6
10	132.9	229.5	383.6	546.3	771.9
25	142.9	250.7	429.1	620.1	964.4
50	148.7	263.4	457.5	667.8	1107.2
100	153.4	274.2	482.6	710.7	1248.9
200	157.5	283.6	505	750	1390.1

3.4.3 降雨強度公式

一、 降雨強度-延時-頻率曲線

降雨的特性可以降雨強度與降雨延時來表示，水資源規劃與設計時，除了需要考慮降雨強度與延時之間的關係外，還需要考慮某特定降雨強度與延時之降雨發生頻率。這種由降雨強度、延時與頻率三種變數所畫出的關係圖，稱為降雨強度-延時-頻率曲線，簡稱IDF 曲線。IDF 曲線通常以圖呈現，表示某一特殊發生機率情況下降雨強度與降雨延時之關係。

(一) IDF 曲線製作流程

1. 針對某延時降雨，整理歷年最大降雨資料，常用方法為年最大值序列法。
2. 進行暴雨頻率分析，決定最適合該延時降雨量的機率分布。
3. 利用機率分布推估不同重現期的降雨量，並將降雨量除以延時，得到降雨強度，得到該延時下不同重現期的降雨強度資料。
4. 針對其他延時，重複上述步驟，得到其他延時下不同重現期的降雨強度資料。
5. 針對各重現期下的延時與強度資料，分別建立降雨強度公式及得到IDF curves。

(二) 不同降雨強度延時曲線如下圖3.4.1~7。

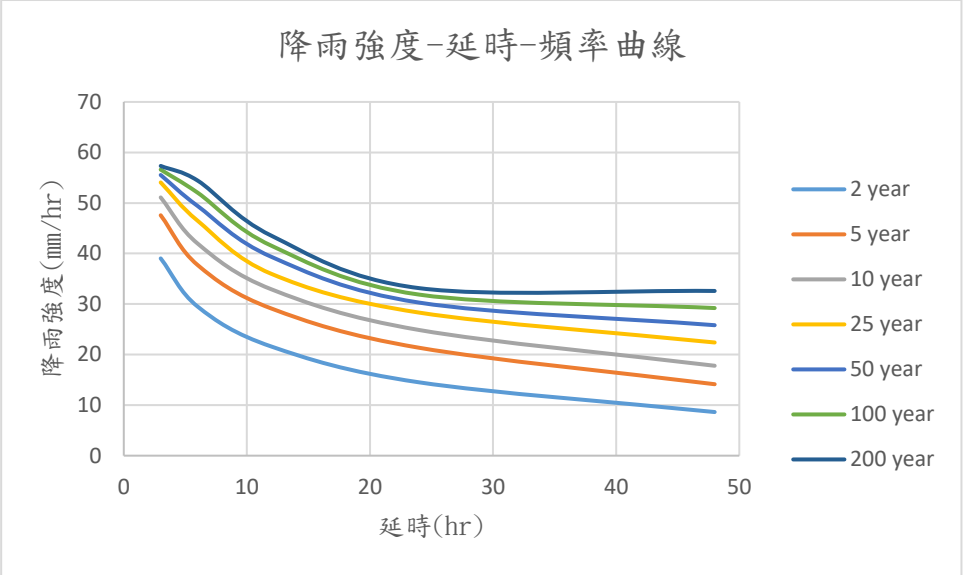


圖 3.4.1 霞雲站不同重現期之降雨強度延時頻率曲線

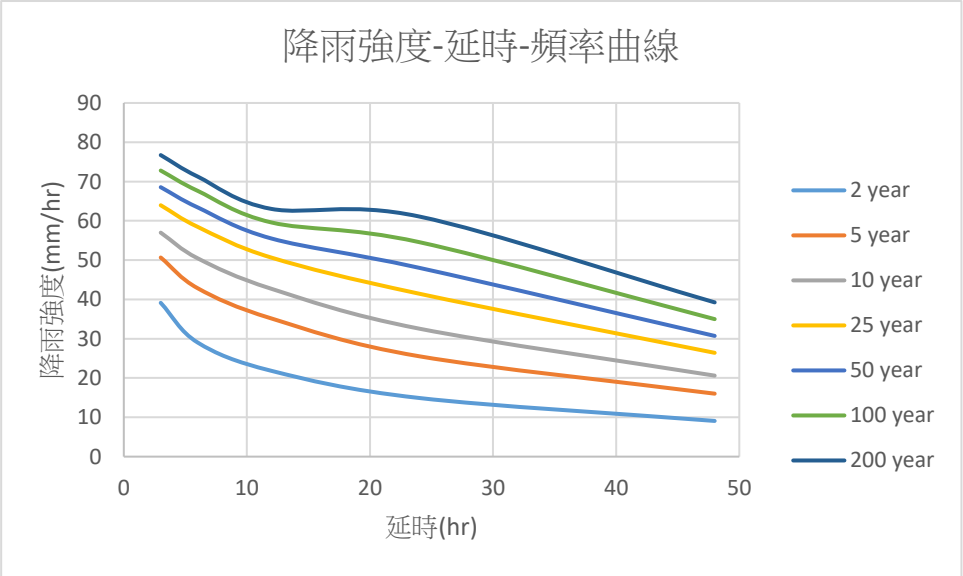


圖 3.4.2 高義站不同重現期之降雨強度延時頻率曲線

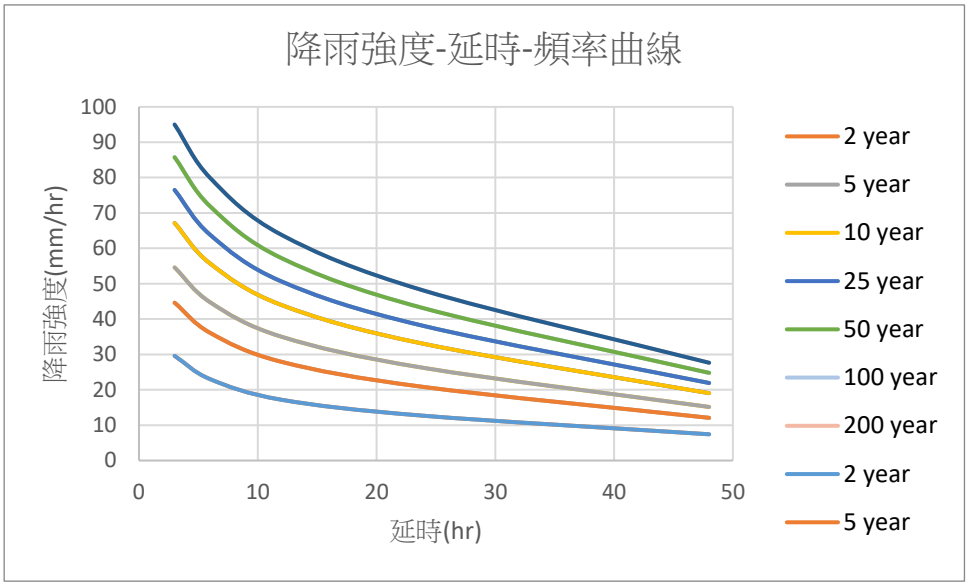


圖 3.4.3 嘎拉賀站不同重現期之降雨強度延時頻率曲線

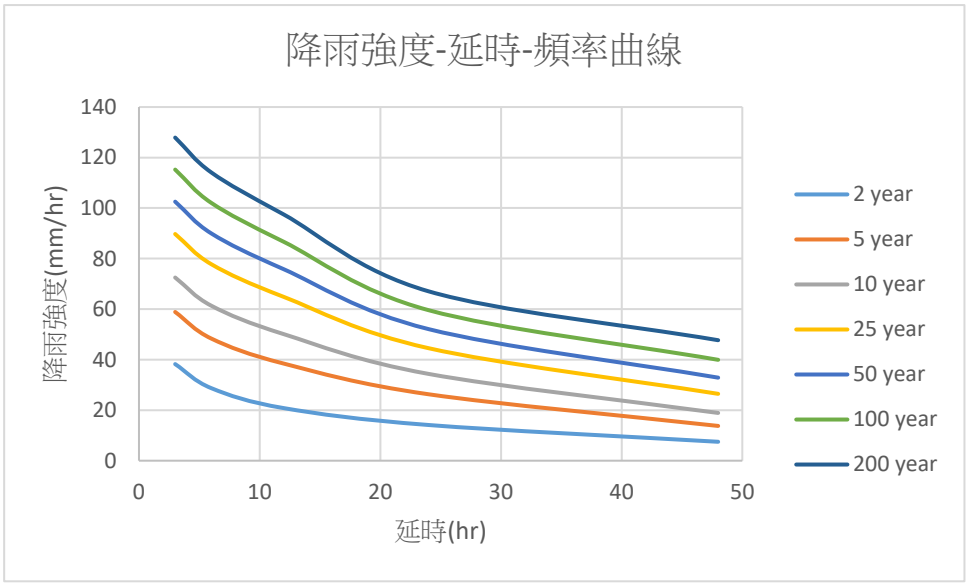


圖 3.4.4 玉峰站不同重現期之降雨強度延時頻率曲線

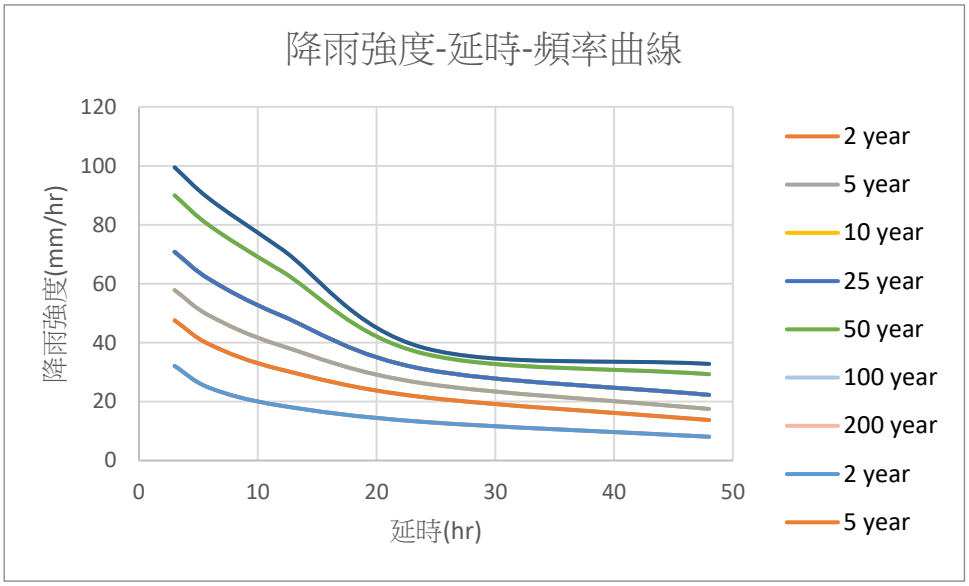


圖 3.4.5 巴陵站不同重現期之降雨強度延時頻率曲線

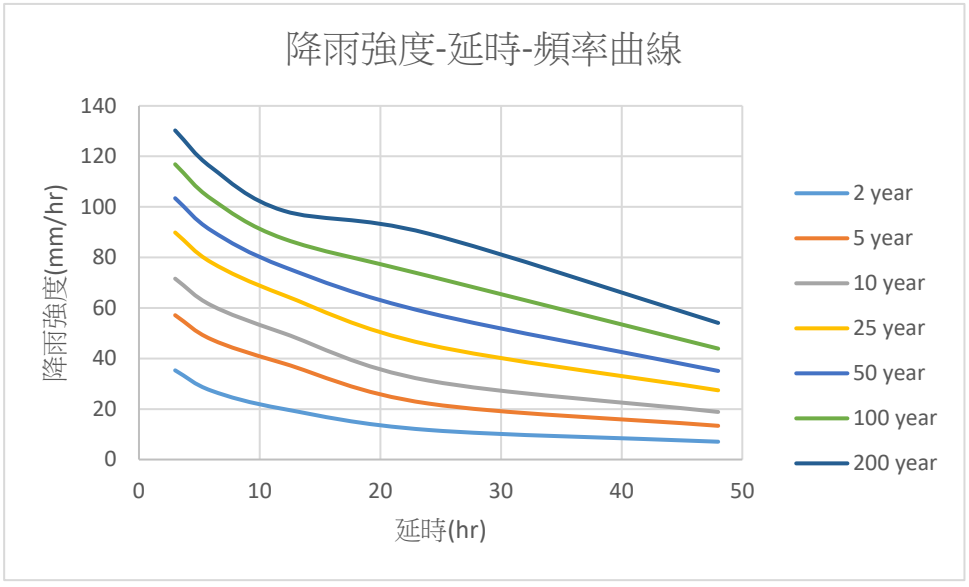


圖 3.4.6 白石站不同重現期之降雨強度延時頻率曲線

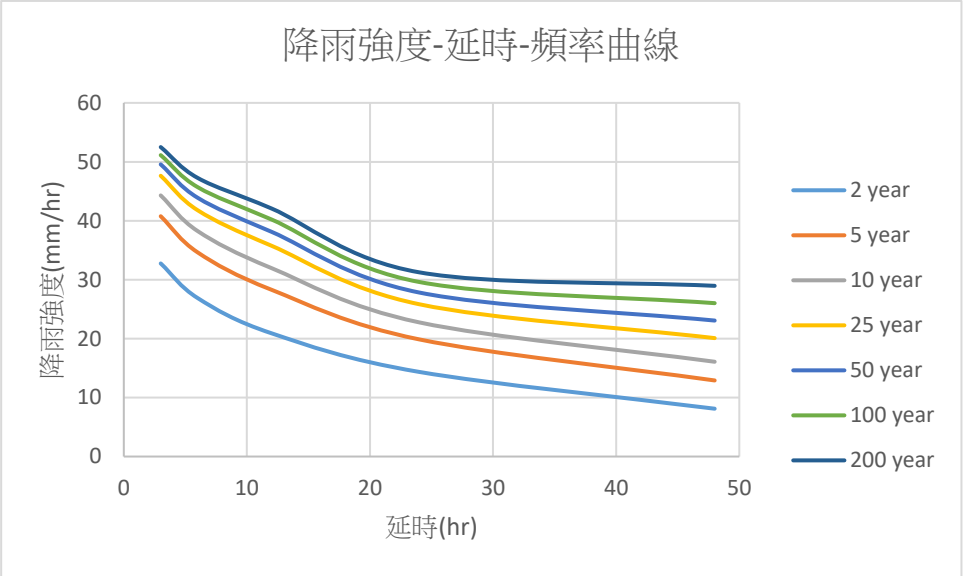


圖 3.4.7 西丘斯山站不同重現期之降雨強度延時頻率曲線

二、 降雨強度公式

(一) Horner公式

$$i = \frac{a}{(t_c + b)^c}$$

t_c是集流時間(min)；a、b、c 是係數

(二) Talbot公式

$$i = \frac{a}{t_c + d}$$

t_c是集流時間(min)；a、d 是係數

(三) Sherman公式

$$i = \frac{a}{(t_c)^n}$$

t_c是集流時間(min)；a、n 是係數

三、 降雨強度公式結果

根據歷年石門水庫上游集水區流量資料推算本次所用颱風事件大約為2年重現期距洪峰流量，且重現期越大以現有資料推估的精準度越差，所以本研究用honor降雨強度公式，計算霞雲站、高義站、嘎拉賀站、玉峰站、巴陵站、白石站、西丘斯山站，重現期為2、5年之極端事件 a、b、c 參數，如表 3.4.16~22 。

表 3.4.16 霞雲站 honor 公式參數

霞雲站			
重現年	a	b	c
2	2481.8	207.24	0.697
5	770.15	109.5254	0.49

表 3.4.16 高義站 honor 公式參數

高義站			
重現年	a	b	c
2	1410.7	145.12	0.62
5	3030.1	438.8	0.636

表 3.4.17 嘎拉賀站 honor 公式參數

嘎拉賀站			
重現年	a	b	c
2	802.15	145.62	0.57
5	1804.3	267.76	0.6

表 3.4.18 玉峰站 honor 公式參數

玉峰站			
重現年	a	b	c
2	2894.8	209.78	0.725
5	5265.5	364.82	0.712

表 3.4.19 巴陵站 honor 公式參數

巴陵站			
重現年	a	b	c
2	680	99.64	0.542
5	1878.4	276.63	0.6

表 3.4.20 白石站 honor 公式參數

白石站			
重現年	a	b	c
2	2688.6	198.63	0.728
5	6183.3	364.7	0.74

表 3.4.21 西丘斯山站 honor 公式參數

西丘斯山站			
重現年	a	b	c
2	1816.5	302.7	0.65
5	1240.1	287.3	0.55

3.4.4 設計雨型

一、雨型延時與單位時間之設計原則

(一) 雨型延時需與推求降雨強度之延時一致

(二) 雨型單位時間需與流量歷線單位時間一致

(三) 設計雨量之延時與單位時間須配合集水區之集流時間特性

(四) 依集流時間 Tc 選擇雨型單位時間 Tr

二、雨型常用方法

雨型設計常用方法有交替組體法、同位序平均法、實際暴雨雨型及序率、馬可夫雨型(來自水文設計應用手冊)

(一) 交替組體法，又稱交替區塊法或降雨強度法

(1) 降雨延時依照單位時間分成 n 個時段

(2) 由降雨強度公式分別計算延時為 ,2 ,3 …， 的降雨強度，再計算總降雨深度

(3) 推求個時刻增量所對應的降雨增量，以此增量作為各單位時間的降雨量

(4) 將最大降雨量置於延時 Tc 中間，接著將雨量由大至小交替置於最大降雨量之兩側，即形成延時 Tc 的設計雨型

(二) 同位序平均法

1. 求出多場具代表性降雨的各時段雨量百分比

2. 將各時段雨量百分比依大小順序重新排列

3. 計算相同級序的雨量百分比的平均

4. 將平均雨量百分比最大值置於延時中間，或考慮前進係數置於適當處

5. 將其餘平均雨量百分比，由大到小交替置於尖峰雨量之兩側

(三) 實際暴雨雨型

(四) 序率馬可夫雨型

依前述建立之 honor 降雨強度公式，以交替組體法建立設計雨型，霞雲站、高義站、嘎拉賀站、玉峰站、巴陵站、白石站、西丘斯山站，降雨延時分別為 24hr、48hr，重現期 2 年、5 年，總共 4 場事件之設計雨型，以建立後續機器學習的資料庫。

在此僅呈現降雨延時 48hr，重現期為 2 年、5 年之設計雨型示意，如下圖 3.4.8~3.4.21。

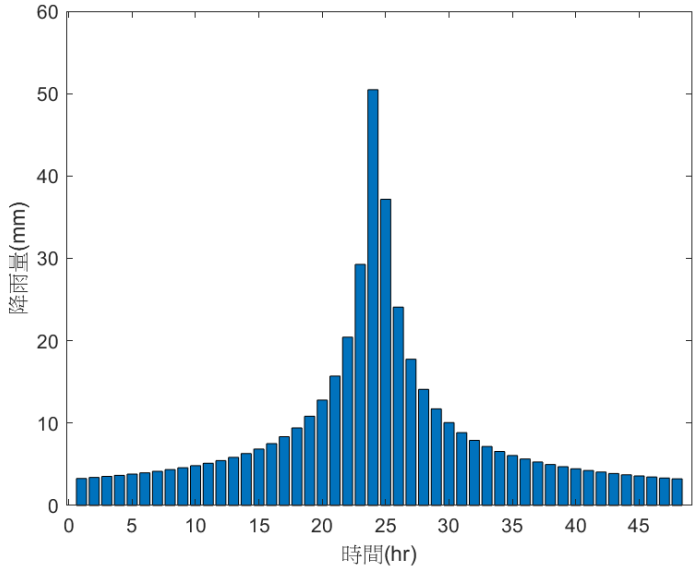


圖 3.4.8 霞雲站 2 年重現期之降雨組體圖

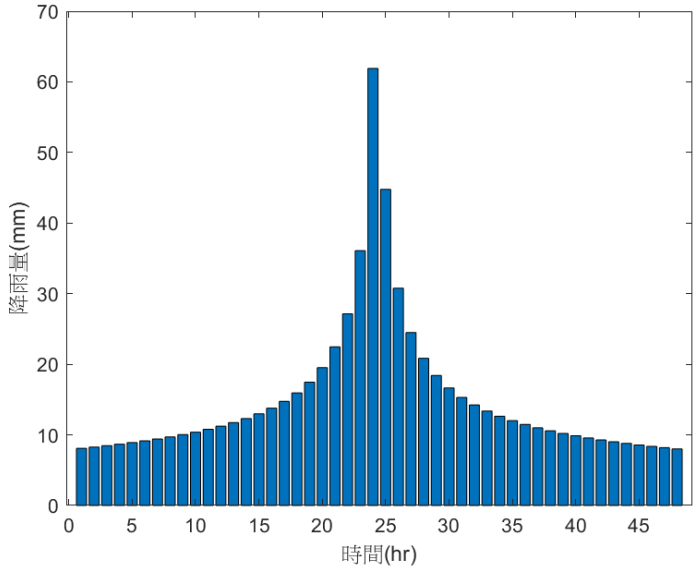


圖 3.4.9 霞雲站 5 年重現期之降雨組體圖

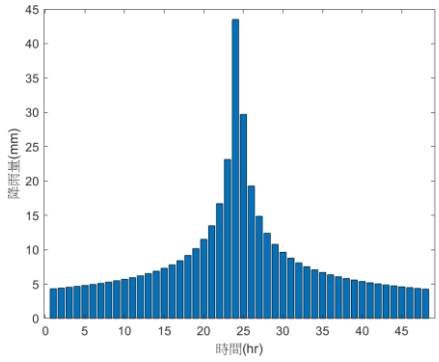


圖 3.4.10 巴陵站 2 年重現期之降雨組體圖

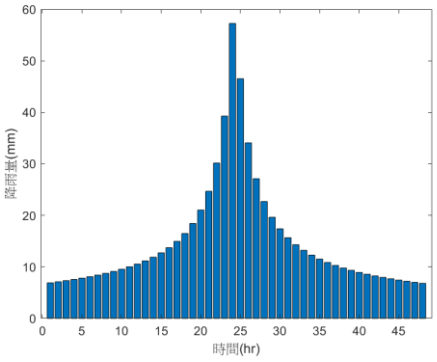


圖 3.4.11 巴陵站 5 年重現期之降雨組體圖

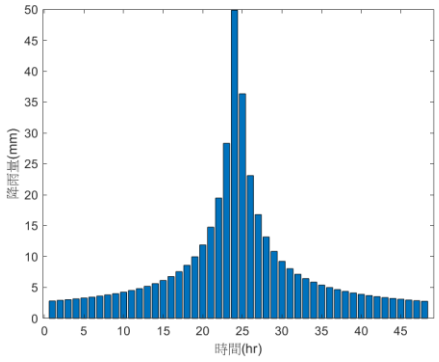


圖 3.4.12 玉峰站 2 年重現期之降雨組體圖

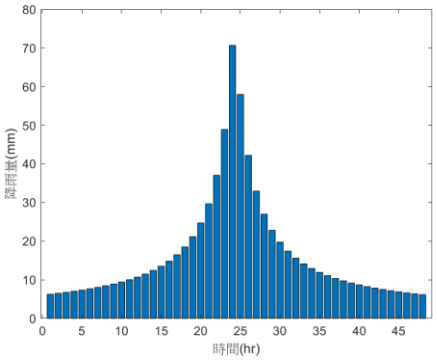


圖 3.4.13 玉峰站 5 年重現期之降雨組體圖

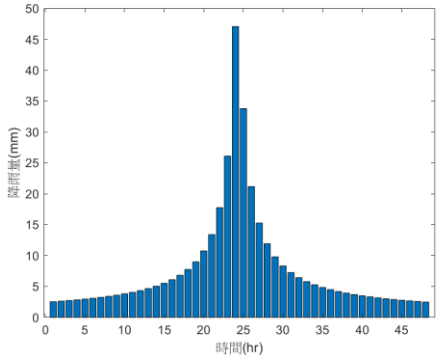


圖 3.4.14 白石站 2 年重現期之降雨組體圖

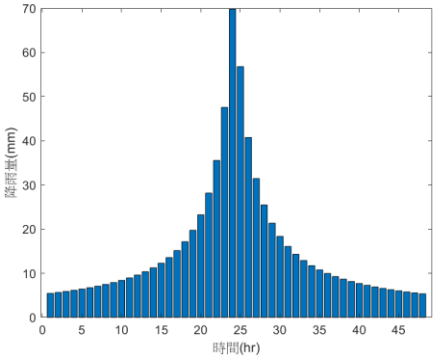


圖 3.4.15 白石站 5 年重現期之降雨組體圖

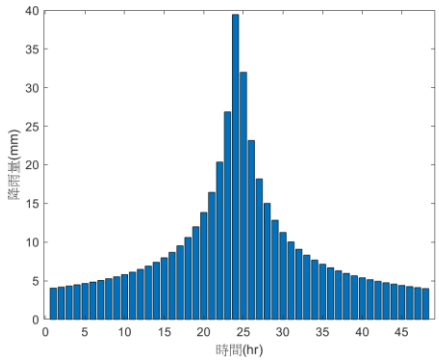


圖 3.4.16 西丘斯山 2 年重現期之降雨組體圖

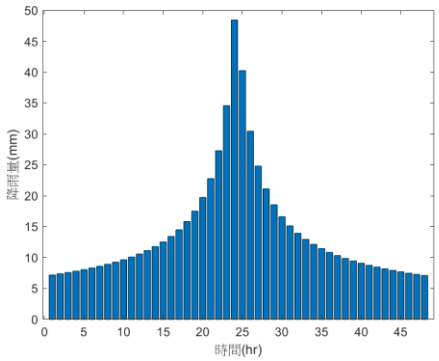


圖 3.4.17 西丘斯山 5 年重現期之降雨組體圖

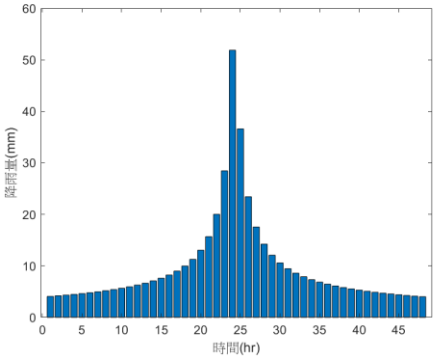


圖 3.4.18 高義站 2 年重現期之降雨組體圖

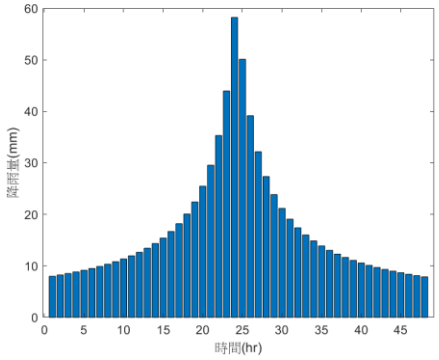


圖 3.4.19 高義站 5 年重現期之降雨組體圖

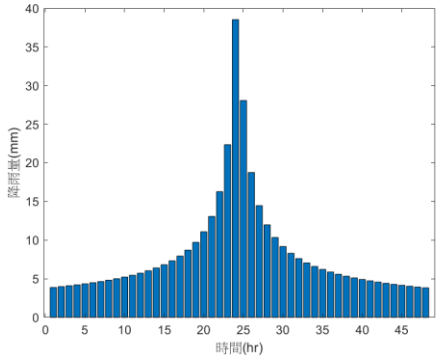


圖 3.4.20 嘎拉賀站 2 年重現期之降雨組體圖

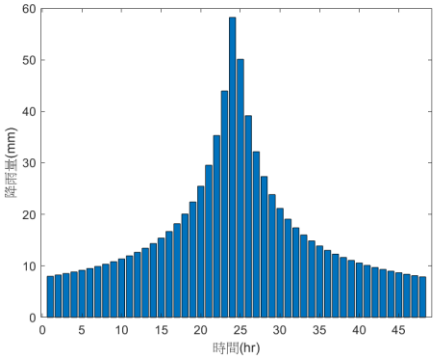


圖 3.4.21 嘎拉賀站 5 年重現期之降雨組體圖

3.5 類神經網路

神經網路是一種運算模型，由大量的節點（或稱神經元）之間相互聯接構成。每個節點代表一種特定的輸出函式，稱為激勵函式（activation function）。每兩個節點間的連線都代表一個對於通過該連線訊號的加權值，稱之為權重，這相當於人工神經網路的記憶。網路的輸出則依網路的連線方式，權重值和激勵函式的不同而不同。而網路自身通常都是對自然界某種演算法或者函式的逼近，也可能是對一種邏輯策略的表達。類神經網路具有以下特性:

1. 聯想速度快

類神經網路的訓練過程，需花較多時間調整神經元間的連結權重，但當權重值確定後，同樣輸入資料的輸出比對或資料預測的進行，其速度均較傳統模式快。

2. 網路架構容易維持

類神經網路之架構較為開放，其維護與升級的方式也相當簡單，只要加入新的資訊並調整網路架構，經重新訓練即 可符合新的需求。

3. 解決最佳化、非線性系統問題

當問題無法以一般演算法解決，或是需要相當的時間進行處理問題時，透過網路架構，只要決定輸入因子，再配合歷史資料，不需找出正確的數學模型，即可建構出輸入與輸出間的對應關係。

4. 具平行處理能力

類神經網路是以生物的樹狀神經網路所設計，仿照生物神經具平行處理的特性

5. 具容錯特性

因類神經網路的神經元，在網路的運作中是以平行且分散的方式來

解決問題，若輸入的資料有數據不完整或是有雜訊干擾，亦不會影響整體的網路運作，因為每一個神經元只會映射出其中一小部份特徵。其是因為輸入與輸出之間的映射關係，是由網路中各神經元的特徵集合一起，所表達出一個完整的輸入輸出模式。類神經網路模式可依照學習策略與網路系統架構來加以分類，下列將各別簡單介紹之。

1. 依學習策略分類

(1) 監督式學習網路（Supervised Learning Network）

監督式學習主要是利用學習範例對應於網路模式的輸入與輸出來調整網路修正傳遞權重的數值，藉由訓練過程中不停地調整網路連結的強弱來縮小目標輸出與網路輸出間差距，以達到分類預測效果。例如感知器網路、 倒傳遞類神經網路、機率神經網路。

(2) 非監督式學習網路（Unsupervised Learning Network）

非監督式學習不同於監督式學習在於沒有所謂的目標輸出，是自動導出分類規則而產生輸出值。例如自組織映射圖網路、自適應共振理論網路。

(3) 聯想式學習網路(Associate Learning Network)

聯想式學習網路是從完整的訓練樣本中得到一定的記憶規則，使其對於不完整或變形的新案例能夠自動聯想出其正確的狀態。例如霍普菲爾網路、雙向聯想記憶網路。

(4) 最適化應用網路(Optimization Application Network)

最佳化應用主要是用來求解組合最佳化問題，求得某問題或運算的一些設計變數，並且滿足其限制條件。例如霍普菲爾-坦克網路、退火神經網路。

2. 依網路系統架構分類

(1) 前饋式網路架構（Feedforward Network）

網路由輸入層、隱藏層、輸出層所構成，其中同一層中的每個神經元彼此間不相連，並且每一層只接受前一層的輸出值作為輸入值。例如：倒傳遞類神經網路、學習向量量化網路。

(2) 回饋式網路架構（Feedback Network）

網路由輸入層、隱藏層、輸出層所構成，回饋式網路至少會含有一回饋迴圈，其中可以僅包含一個神經元，然而此層的神經元會將輸出訊號經由迴圈傳給同一層或前一層迴圈所連結的神經元作為輸入訊號。

3.5.1 倒傳遞類神經網路(BPNN)

倒傳遞類神經網路全稱 Back Propagation Neural Network，導向傳播神經網路。屬於監督式類神經網路的一種。BP 神經網路就是在前饋型網路的結構上增加了後向傳播演算法（Back Propagation）。

前饋只是用於計算出網路的輸出，不對網路的引數進行調整。反向傳播是用於訓練時網路權值和閾值的調整，該過程是需要監督學習的。在你的網路沒有訓練好的時候，輸出肯定會有一個偏差，把偏差一級一級向前傳遞，逐層修正權重，這就是反饋。使得期望和輸出之間的誤差儘可能的減小。如下圖 3.5.1 所示。

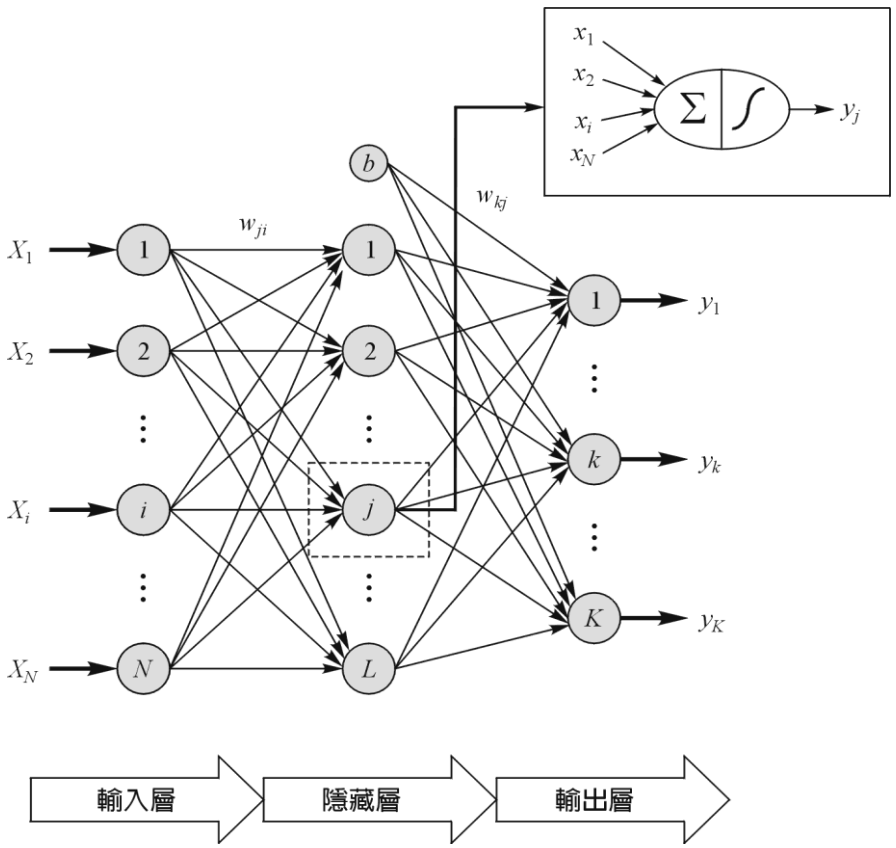


圖 3.5.1 BP 神經網路結構

(I) 網路架構

主要由輸入層、隱藏層及輸出層組成，輸入層用以表現網路的輸入變數，處理單元數目依據問題而定。隱藏層用以表現輸入單元間的交互影響，處理單元數目並無一定的標準，常須以試驗方式決定最佳數目。

(II) 隱藏層處理單元

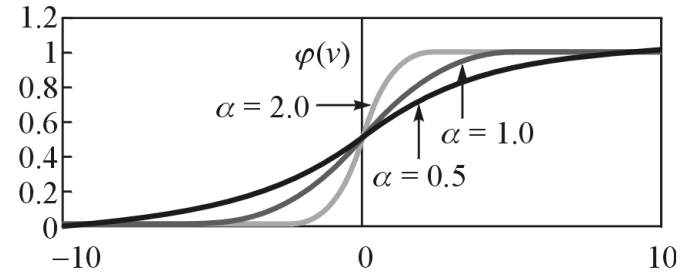
通常隱藏層處理單元之數目越多收斂越慢，但可以達到更小的誤差值。超過一定數目後，再增加隱藏層處理單元個數，對降低測試範例的誤差幾乎沒有幫助，只是增加執行的時間而已。爲平衡品質與成本，以取適當的數目為宜。

(III) 隱藏層層數

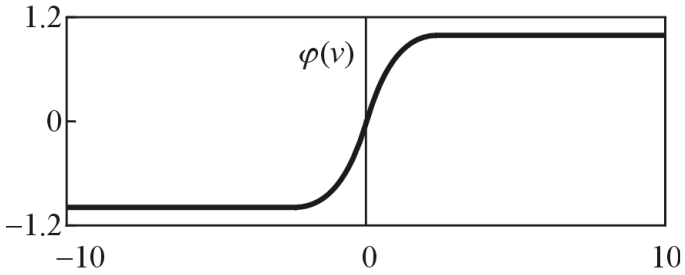
隱藏層的數目通常為一層到兩層有最好的收斂效果，太多層或太少層其收斂效果均差。

(IV) 活化函數

網路中各層間之神經元係靠相關權重來連結，輸入層中之輸入值傳至隱藏層後，經過連結加權及轉換函數（Transfer Function）轉換完成後，得一輸出值，再將此輸出值傳至輸出層，依其不同需求 而選擇適當的函數。本研究使用當前最多人研究使用的對數雙彎曲轉換函數，如下圖 3.5.2 所示。



(a) S 形函數 (α=0.5, 1 和 2)



(b) 雙曲線函數

圖 3.5.2 活化函數形式

(V) 活化函數

通常學習速率太大或太小對網路的收斂性質均不利。因為較大的學習速率有較大的網路加權值修正量，可較快逼近函數最小值，但過大的學習速率將導致網路加權值修正過量，造成數值振盪而難以達到收斂的目的。依據經驗取 0.001 到 0.01 間的值作為學習速率的值，大都可以得到良好的收斂性。但仍有一些問題的學習速率可能低到 0.001 以下或高到 1 以上。

(VI) 學習演算法

倒傳遞類神經網路其基本原理是利用最陡坡降法（The Gradient Steepest Descent Method）的觀念，將誤差值予以最小化，網路的學習過程即能量函數最小化之過程。此種演算法的疊代式如下:

在倒傳遞類神經網路（BPNN）中，第 n 層第 j 個神經元的輸入值為第 n - 1 層神經元輸出值的非線性函數：

疊代式如下:

(3.1) $$y_j^n = f(\sum_i w_{ji} y_i^{n-1} + b_j^n) = f(net_j^n)$$

(3.2) $$net_j^n = \sum_i w_{ji}^n y_i^{n-1} + b_j^n$$

誤差函數 E 定義:

其學習目的在降低網路輸出值與目標輸出值間的差距

$$E = (1/2)\sum_k (d_k - y_k)^2 \tag{3.3}$$

(1)每當輸入一筆訓練資料，網路就稍微調整加權值的大小：

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \tag{3.4}$$

✱ 學習速率 η 的大小決定了最陡坡降法修正的步幅

(2) $\frac{\partial E}{\partial W}$，可利用連鎖率求得

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}}$$

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial y_j^n}\frac{\partial y_j^n}{\partial w_{ji}} = \frac{\partial E}{\partial y_j^n}\frac{\partial y_j^n}{\partial net_j^n}\frac{\partial net_j^n}{\partial w_{ji}} \tag{3.5}$$

$$\frac{\partial y_j^n}{\partial net_j^n} = f'(net_j^n) \tag{3.6}$$

$$\frac{\partial net_j^n}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}}\left(\sum_i w_{ji} y_j^{n-1} + b_j^n\right) = y_i^{n-1} \tag{3.7}$$

$\frac{\partial E}{\partial y_j^n}$ = 第n層為最終層

第n層不是最終層

若第 n 層為最終層，即網路的輸出層，此時，$j=k$；將（3.3）式與 $j=k$ 代入得

$$\frac{\partial E}{\partial y_j^n}=\frac{\partial}{\partial y_j^n}\left[\frac{1}{2}\sum_k (d_k-y_k^n)^2\right]=-(d_j-y_j^n)=-e \tag{3.8}$$

若第 n 層不是最終層，也就是網路的隱藏層之一，可用連鎖律得

$$\frac{\partial E}{\partial y_j^n}=\sum_k\left(\frac{\partial E}{\partial net_k^{n+1}}\frac{\partial net_k^{n+1}}{\partial y_j^n}\right) \tag{3.9}$$

將（4.3）式代入可得

$$\frac{\partial net_k^{n+1}}{\partial y_j^n}=\frac{\partial}{\partial y_j^n}\left(\sum_i w_{ki}y_i^n+b_k\right)=w_{kj} \tag{3.10}$$

為簡明定義，令

$$\frac{\partial E}{\partial net_k^n}=-\delta_k^n \tag{3.11}$$

將（4.11）、（4.12）式代入（4.10）式可得：

$$\frac{\partial E}{\partial y_j^n}=-\sum_k(\delta_k^{n+1}w_{kj}) \tag{3.12}$$

總結:

(1) w_{ji}處於輸出層至隱藏層之間

$$\frac{\partial E}{\partial w_{ji}} = -(d_j - y_j^n) f'(net_j^n) y_i^{n-1} \tag{3.13}$$

將（3.7）、(3.11）式代入（3.5）式：

$$\frac{\partial E}{\partial w_{ji}} = -\delta_j^n y_i^{n-1} \tag{3.14}$$

比較（3.13）式與（3.14）式得

$$\delta_j^n = (d_j - y_j^n) f'(net_j^n) \tag{3.15}$$

(2) w_{ji}處於輸出層至隱藏層之間

$$\frac{\partial E}{\partial w_{ji}} = \left[-\sum_k \delta_k^{n+1} w_{kj} \right] f'(net_j^n) y_i^{n-1} \tag{3.16}$$

將（3.7）、(3.11）式代入（3.5）式：

$$\frac{\partial E}{\partial w_{ji}} = -\delta_j^n y_i^{n-1} \tag{3.17}$$

比較（3.16）式與（3.17）式得

$$\delta_j^n = \left[\sum_k \delta_k^{n+1} w_{kj} \right] f'(net_j^n) \tag{3.18}$$

因此不論w_{ij}處於隱藏層與隱藏層之間，或w_{ij}處於輸出層與隱藏層之間，均可寫成通式：

$$\frac{\partial E}{\partial w_{ji}} = -\delta_j^n y_i^{n-1} \qquad (3.19)$$

式中δ_j^n為將（3.19）式代入（3.4）式可得

$$\Delta w_{ji} = \eta \delta_j^n y_i^{n-1} \qquad (3.20)$$

此式即倒傳遞演算法之關鍵公式，每輸入一組訓練範例（也就是有輸入項與目標輸出值），各連結的權重即可依此方式，加以調整。

$$w_{ji}(p) = w_{ji}(p-1) + \Delta w_{ji} \qquad (3.21)$$

(VII) 神經網路運算流程

倒傳遞類神經網路模式之學習訓練為監督式學習網路，其學習流程可分為兩大階段：前饋階段與倒傳遞階段。以具有一層隱藏層之前饋式網路架構為例，其神經元間完全連結（即每個神經元與前一層各神經元間皆具有連結），外界輸入之訊號以前饋的方式由左至右傳遞，而由輸出端所產生之能量（誤差）函數，則是以倒傳遞的方式由右至左傳遞。運算流程如圖 3.5.3。

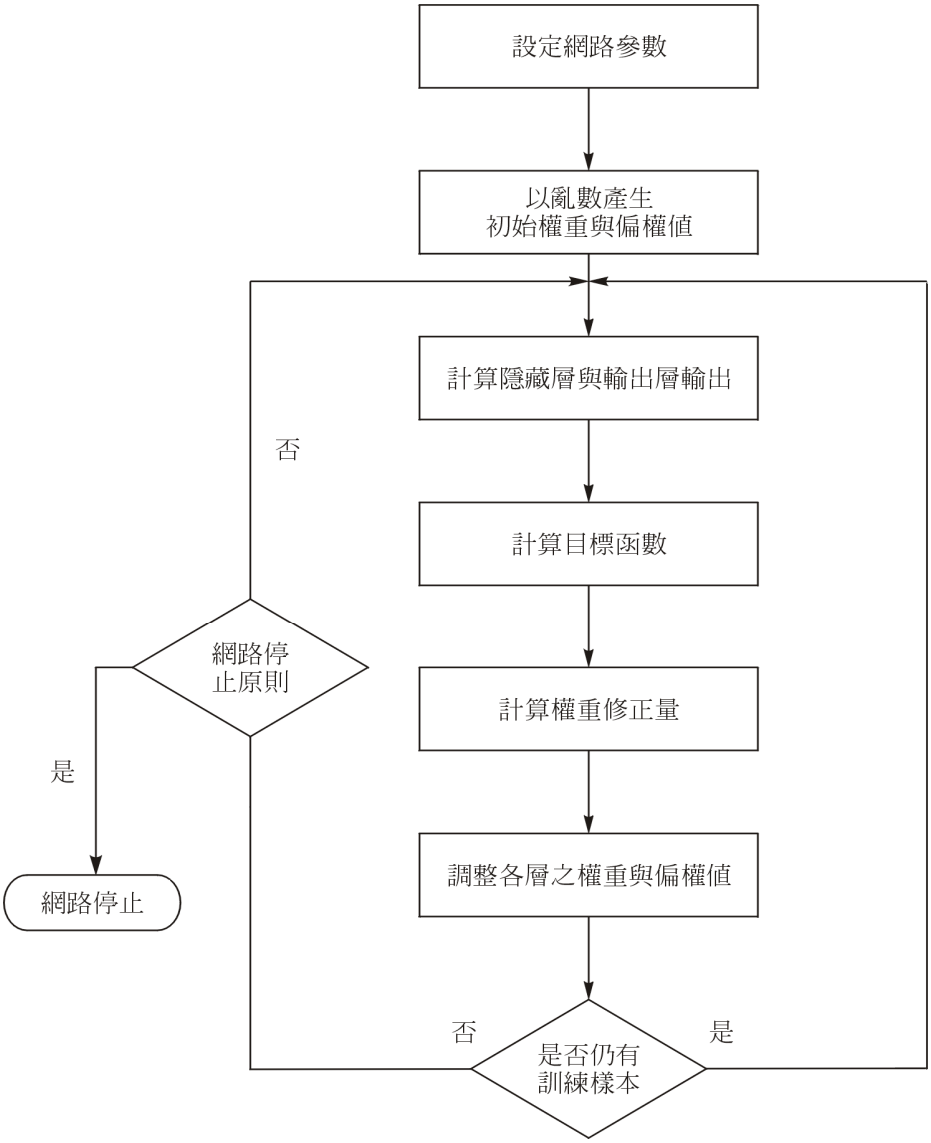


圖 3.5.3 神經網路運算流程

本研究使用本研究之到傳遞類神經網路，使用 Matlab 中 feedforwardnet 函式來建構，所需調整之參數，分別為容許誤差（GOAL）、隱藏層神經元數、學習速率採用建議值 0.005，詳細程式碼如下:

(1)設定網路為 BPNN 架構，

net=feedforwardnet(神經元數,'trainlm');

(2)套用資料範圍

net=configure(net,data_in,data_out);

data_in:輸入資料

data_out:輸出資料

(3)活化函數設定

net.layers{1}.transferFcn='tansig'

net.layers{2}.transferFcn='purelin'

tansig:S 型正切函數

purelin:純線性函數

(4)權重參數初始化方法

net.inputweights{1,1}.initFcn = 'rands';

net.biases{1,1}.initFcn = 'rands';

(5)設定訓練參數

net.trainParam.epochs = 50;

net.trainParam.goal = 0.005;

(6)執行網路訓練

net=train(net,data_in,data_out);

3.5.2 幅狀基底類神經網路(RBFNN)

或稱為半徑式類神經網路，為前饋式類神經網路以函數逼近的方式來建構網路，最早衍生於解決多變數的內插問題，後Powell(1987)加以發展，以不規則位置的資料點，求得相對應的輻狀基底函數，之後陸續有許多學者也提出類似理論，解決內插問題與近似的理論。

可視為在解決高維度空間的曲線調適問題，其學習過程即是在多維空間中找尋適切之曲面，而此曲面能利用統計原理經由訓練資料進行最佳的調適，以使訓練資料與曲面間之誤差達到最小。

(I) 網路架構

屬於基本的前饋式類神經網路，其架構包含了輸入層、單一隱藏層及輸出層。 將隱藏層的輸出值經加權傳至輸出層即可求得網路輸出值。

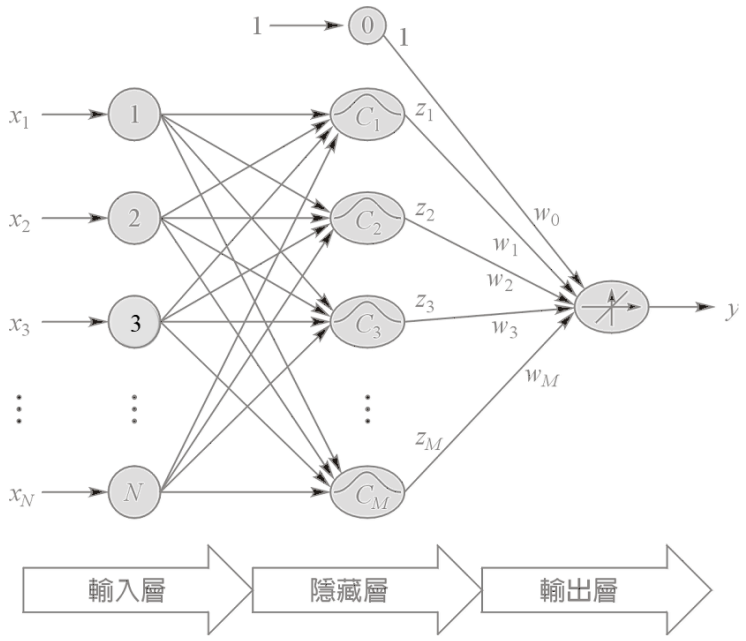


圖 3.5.4 饋式類神經網路架構

(II) 輸入層→輸入資料與網路連結的介面層，如下圖

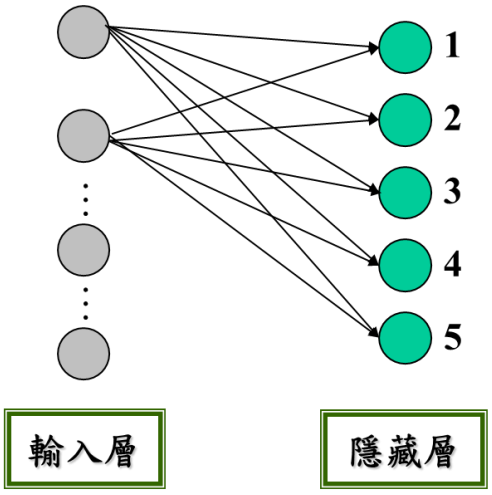


圖 3.5.5 輸入資料與網路連結的介面層

(III) 隱藏層→僅一層，將輸入經非線性轉換至隱藏層（將輸入空間進行非線性映射到隱藏空間）--分類，如下圖

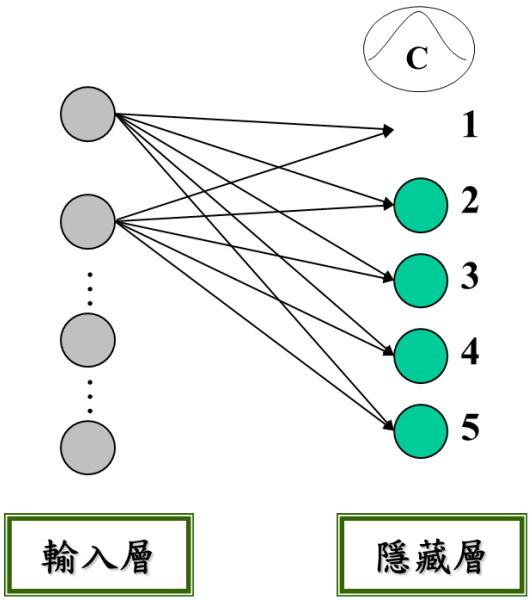


圖 3.5.6 非線性轉換至隱藏層的介面層

(IV) 輸出層→扮演著將隱藏層的輸出進行線性組合(或線性映射)獲得輸出值的角色，如下圖

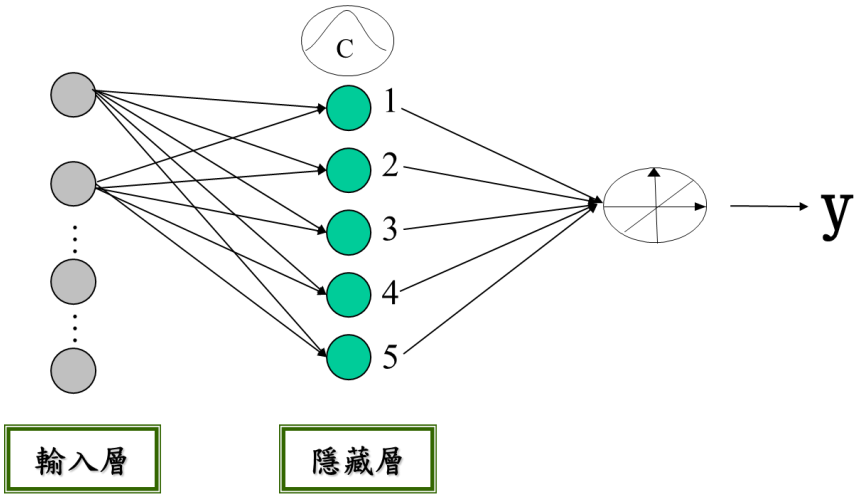


圖 3.5.7 將隱藏層的輸出進行線性組合的介面層

(V) 活化函數

當訓練範例資料輸入網路後，直接由輸入層將輸入向量傳給隱藏層中的每個輻狀基底函數，計算輸入向量與隱藏層各神經元中心點的距離後，經函數轉換獲得隱藏層各神經元的輸出。

$$z_j(x) = \emptyset\left(||x - c_i||\right) \qquad j = 1,2,\ldots.,M$$

$\phi(\cdot)$ 表輻狀基底函數

c_j 表隱藏層第 j 個神經元中心點

$\|x-c_j\|$ 表示x與c_j間之歐氏距離

將隱藏層的輸出值經加權傳至輸出層即可求得網路輸出值。

$$\mathrm{y} = \sum_{j=0}^{m} w_j . z_j(x)$$

y為輸出層的輸出值

w_j為隱藏層第 j 個神經元至輸出層的權重值

z_j為隱藏層第 j 個神經元的輸出值

$$\rightarrow \mathrm{y} = \sum_{j=1}^{M} w_j . \emptyset(|\left|x - c_j\right||) + w_0$$

本研究使用當前較多人使用的高斯函數，其形式如下

高斯函數:

$$\phi(\| x - c \|) = \exp\left(- \frac{\| x - c \|^2}{2\sigma^2} \right)$$

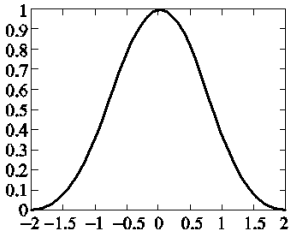


圖 3.5.8 高斯函數圖

(VI) 學習演算法

RBFNN 架構最重要的部分分別為(1)隱藏層神經元的個數(2)中心點的選取。其原因為隱藏神經元的個數代表了整個網路架構之複雜度，決定個數代表決定了整個網路架構，且中心點的位置對於網路訓練的收斂速度與穩定性有相當大之影響，選擇恰當的中心點位置能有效等減少中心點個數，等同於降低了網路的複雜度以至提升網路整體訓練收斂速度。 中心點的選取方法一般可概分為三類，(1) 隨機選取 (2) 聚類法 (3) 監督式選取法。

1. 隨機選取法Haykin 於 1999 年所提出RBF 中心點選取最簡單的方法就是從訓練範例資料點，隨機選取固定個數的中心。為了避免造成所有的輻狀基底函數過度陡峭或過度平緩，建議採用標準偏差值，即

$$\sigma = \frac{d_{max}}{\sqrt{M}}$$

式中 M 為中心點個數

d_{max} 為所有中心點間最大的距離值

其缺點有二:

(1)具備大量的訓練範例資料才能夠經由隨機選取，獲得具有代表性的中心點

(2)當輸入空間範圍很大的時候，選取的中心點也必須夠多才足具代表性。

2. 聚類法

此方法是將輸入資料的相似程度來進行分類，將資料相似度高的分為同一類，亦即當分為同一群集內的資料特性相似度高，不同群集間的資料特異性差異較大。此方法例如有 K-Means 聚類法、Fuzzy-C-Means 聚類法等。

3. 監督式選取法

本研究所使用的監督式選取法為 OLS，此方法選取中心點之概念為逐次由輸入資料中，一次挑選一個能讓輸出誤差最小者作為新加入的隱藏層中心點，當達到我們所設定誤差值時，就會停止增加隱藏層中心點個數。

本研究使用 MATLAB 之輻狀基底函數類神經網路（RBFNN）使用 Matlab 中 newrb 函式來建構，所需調整之參數有二，分別為容許誤差（GOAL）及中心點影響半徑（SPREAD）；遺傳演算法可同時使用多個搜尋點進行搜尋。利用此特性，從指定範圍隨機選取容許誤差(GOAL)與中心點影響半徑（SPREAD）組成一個初始族群，並開始進行最佳解的搜尋過程，最後對這個群體進行交配、複製、突變等運算過程，產生新一代的族群，進而完成參數的優選。

```
net = newrb(P,T,goal,spread,MN,DF)
```

其中：

P-Q 组输入向量组成的 RxQ 维矩阵

T-Q 组目標分類向量组成的 SxQ 维矩阵

goal-均方誤差,默認值為 0

spread-徑向基函数的擴展速度,默認值為 1

MN-神經元的最大数目,默認是 Q

DF-兩次顯示之间所添加的神经元数目,默認值為 25

net-返回值，一个徑向基網路

3.5.3 長短時記憶網路類神經網路(LSTM)

長短期記憶網路是一種特殊的 RNNs， 它能夠學習長期依賴。LSTM 由 Hochreiter&Schmidhuber(1997)引入，後來在很多人的努力下變得越來越精煉和流行。它們在大量的問題上有驚人的效果，現在被廣泛的使用。LSTM 在處理與預測時間序列相關的數據時，其預測出來的無論是誤差還是成果皆優於一般的遞歸類神經網路模型。起初，LSTM 被廣泛應用在機器人控制、文本識別及預測、語音識別、蛋白質同源檢測等領域但是近年來 由於演算法的進步以及電腦設備的快速成長，也將這此類神經網路大量的運用在預測股價以及許多衍生性金融商品如：期貨、選擇權甚至房價這些領域中。

LSTM 模型利用梯度下降法將訓練誤差不斷的傳回至神經元訓練並且讓誤差降至最低。在訓練的過程中，會依據在訓練期間所發現的錯誤，透過回傳的方式不斷修改每次的權重。

梯度下降法在類神經網路中主要的問題在 1991 年被第一次發現，就是誤差梯度隨著事件期間的拉長而消失。如果設置了長短記憶區塊，一旦訓練過程中發現誤差，誤差也會跟著訓練資料一起倒回計算，從輸出值影響每一階段的輸入值，直到這個數值被過濾掉。因此正常的倒傳遞類神經是一個有效訓練 LSTM 區塊記住長時間數值的方法。本研究式預測砂量，因為砂量具有時間序列的特性，因此想嘗試此網路看是否能達到良好的訓練效果。

因為此網路與傳統到傳遞神經網路相比，只是在 t 時間的輸出結果會被採用在 t+1 時刻，其餘相關輸入、輸出、活化函數、誤差修正的介紹在 BPNN 神經網路已經介紹過，在此只針對網路架構進行介紹。

(I) 網路架構

LSTM 創新的地方在於，他在神經單元中加入了遺忘，更新，以及輸出三個步驟，進而大幅提高了其在長期記憶的表現。這些步驟如同下圖 3.5.9 的紅色圓圈，他稱之為“閥(gate)”，透過數學函數來控制有多少的資料會被更新到單元狀態 (cell state) 中。單元狀態是最上方的水平線，連接所有的神經單元。

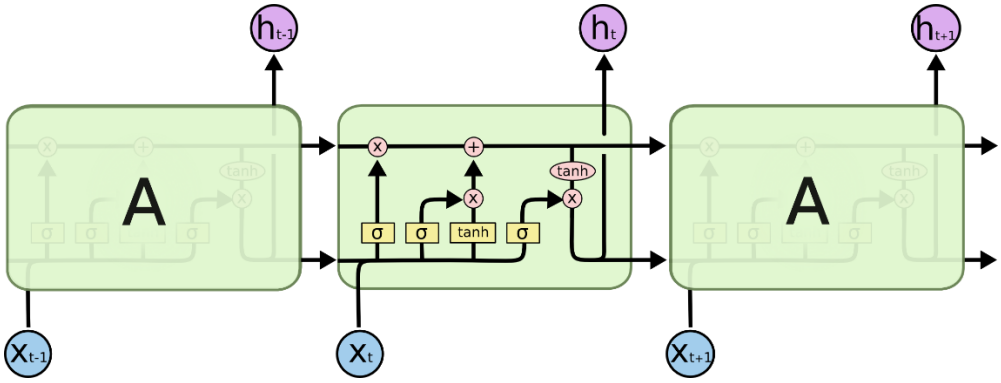


圖 3.5.9 長短期記憶類神經網路之網路運行式意圖

LSTMs 最為核心的一個概念：透過閘門來做控制。下圖 3.5.10 由左至右的水平線用來表示單元狀態 (cell state)，可以將它想像成是一個貫穿所有單元的一條道路，將資訊從一個單元帶到下一個單元 ，比如說前一個小時流量，前一個小時砂量的「記憶」，這個記憶是可以透過粉紅色的閘門 (gate) 做調控的。

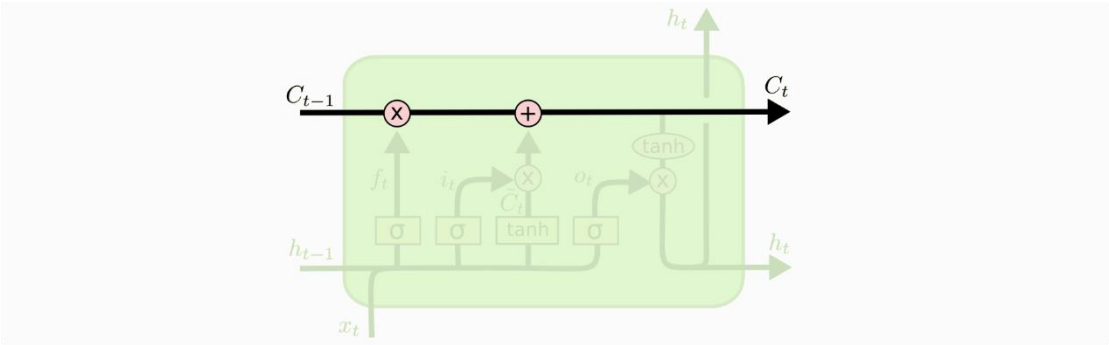
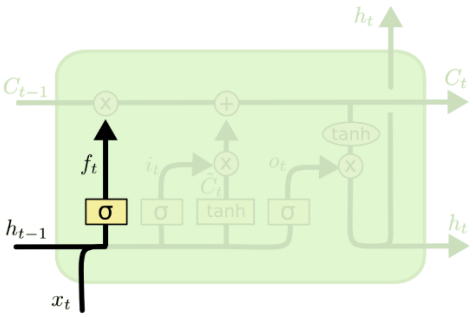


圖 3.5.10 橫貫所有單元，帶著「記憶」的 Cell state 圖

第一步是，決定哪些資訊要忘掉，透過下圖 3.5.11 這個黃色的邏輯函數我們可以決定從上一層的輸出帶進來的資訊，以及這一層新增加的資訊，有多少比例要被忘掉，不被帶進下一層。

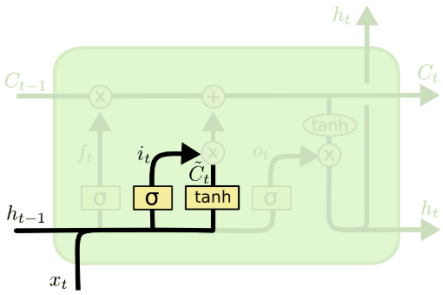


$$f_t = \sigma\left(W_f \cdot [h_{t-1}, x_t] \; + \; b_f\right)$$

圖 3.5.11 邏輯函數示意圖

下一步是將新帶進來的資料紀錄到主要的單元狀態中。這邊又分成兩步驟：決定什麼要被記錄下來，以及更新我們的主要單元。

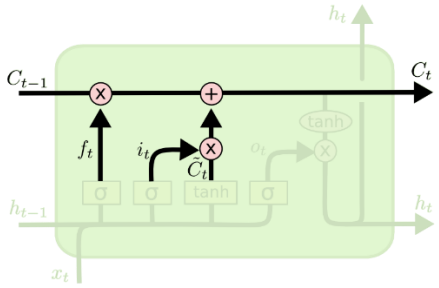
一樣地，透過下圖 3.5.12 的邏輯函數來決定有多少新的資訊要被記錄下來，然後用 tanh 激勵函數算出一個向量，決定有多少資訊 Ct 要用來更新主要單元。



$$i_t = \sigma\left(W_i \cdot [h_{t-1}, x_t] \; + \; b_i\right)$$
$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] \; + \; b_C)$$

圖 3.5.12 邏輯函數示意圖

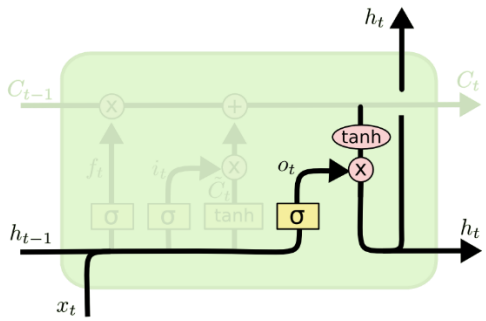
這個第二步驟用來解釋主要單元被更新，從下圖 3.5.13 數學公式可以看出，這邊也考慮了上一個遺忘步驟的結果 ft



$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

圖 3.5.13 邏輯函數示意圖

最後，我們決定有多少資訊要被輸出。從上一步驟的結果 Ct，再透過邏輯函數以及 tanh 的調控，來決定主要單元上要被輸出，如下圖 3.5.14。



$$o_t = \sigma\left(W_o\left[h_{t-1}, x_t\right] + b_o\right)$$
$$h_t = o_t * \tanh\left(C_t\right)$$

圖 3.5.14 邏輯函數示意圖

以上，就是標準的 LSTMs 在單元中每一步驟做的事情。透過這樣看似簡單的幾個步驟，已經在許多應用上都大幅改善 RNN 的效果。

本研究使用 MATLAB 之長短期記憶類神經使用 Matlab 中 lstmlayer 層來建構，以下為相關程式碼。

(1)設定輸入參數、輸出參數、隱藏層神經元數

```
numFeatures = 4;
numResponses = 1;
numHiddenUnits = 15;
```

(2)設定lstm網路

```
layers = [ ...
    sequenceInputLayer(numFeatures)
    lstmLayer(numHiddenUnits)
    fullyConnectedLayer(numResponses)
    regressionLayer];
```

(3)設定迭帶次數、學習效率、活化函數

```
options = trainingOptions('adam', ...
    'MaxEpochs',100, ...
    'GradientThreshold',1, ...
    'InitialLearnRate',0.005, ...
    'Plots','training-progress');
```

(4)進行網路訓練

```
net = trainNetwork(data_in_Norm(:,1:1186),data_real_out_Norm(:,1:1186),layers,options);
```

3.6 預報模式建立

潭美颱風經由年降雨資料頻率分析得知大約是 2 年重現期之暴雨事件，因此設計雨型部分在此選用 2、5 年重現期降雨，分別降雨時間為 24hr、48hr、72hr 的三場事件作為 HEC-HMS 的降雨資料，產製石門水庫的流量歷線，再將各入流點流量帶入 SRH-2D 模式進行輸砂動床模擬，以便產製不同重現期的輸砂量，作為機器學習的資料庫。

類神經網路的選擇，這次選用傳統的倒傳遞神經網路(BPNN)、幅狀基底類型神經網路(RBFNN)、以及加入時間遞迴項的神經網路(LSTM)來比較三種模式下神經網路的訓練情形，下圖為預報模式的流程圖。

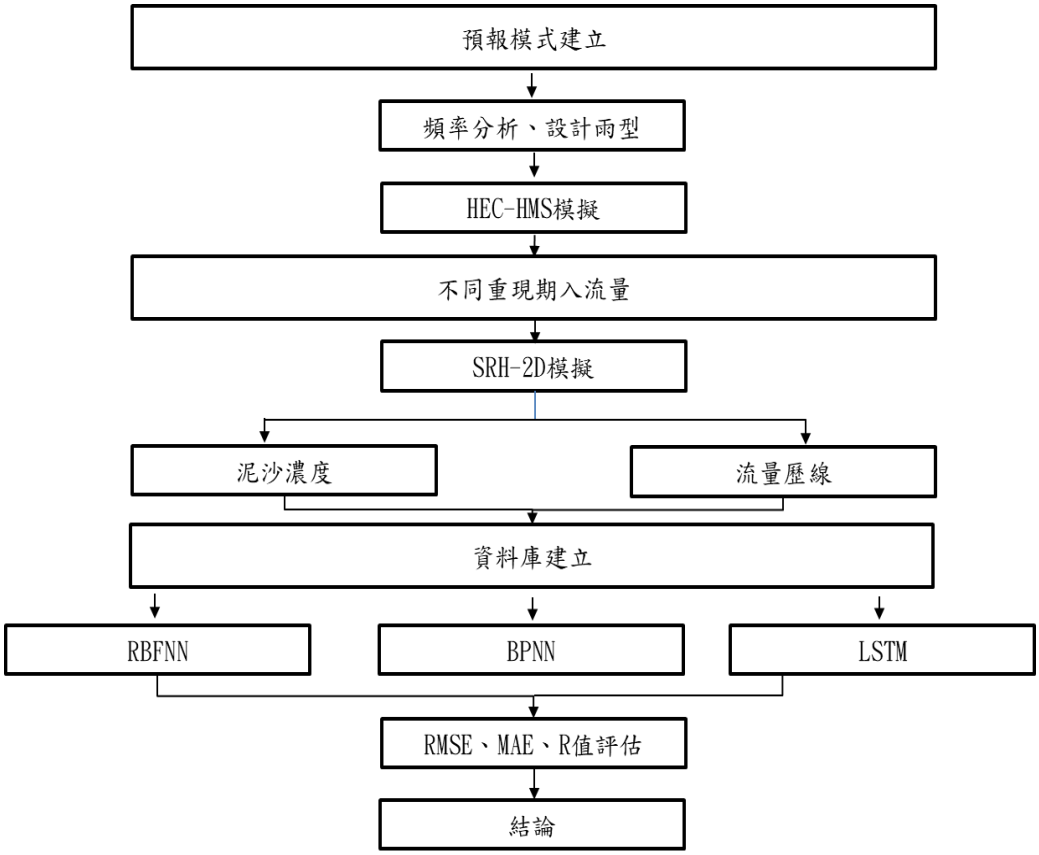


圖 3.6.1 預報模式的流程圖

I. 訓練資料選用與處理

一般需要將樣本分成獨立的三部分訓練集，驗證集和測試集。其中訓練集用來估計模型，驗證集用來確定網路結構或者控制模型複雜程度的引數，而測試集則檢驗最終選擇最優的模型的效能如何。一個典型的劃分是訓練集佔總樣本的 50%，而其它各佔 25%，三部分都是從樣本中隨機抽取。 由於本次模擬，樣本資料過少，因此只分成訓練和測試兩部分。

本次選用 2 年和 5 年重現期降雨，分別降雨時間為 24hr、48hr、72hr 三場事件加上菲特颱風、潭美颱風二場颱風事件之流量歷線以及對應的砂量作為神經網路的訓練資料，並以 2 年重現期 48hr 之事件進行神經網路的測試。如圖 3.6.1、3.6.2

表 3.6.1 為訓練資料及測試資料中最大值、最小值及平均值的基本資料。

表 3.6.1 訓練、測試基本資料

Data set	Data type	Maximum	Minimum	Average
Training	Flow(m^3/s)	3336.6	6.07	537.24
	Sediment(kg/s)	5398.2	0	500.6
Testing	Flow(m^3/s)	990.84	19.84	360
	Sediment(kg/s)	1371.3	0	283.2

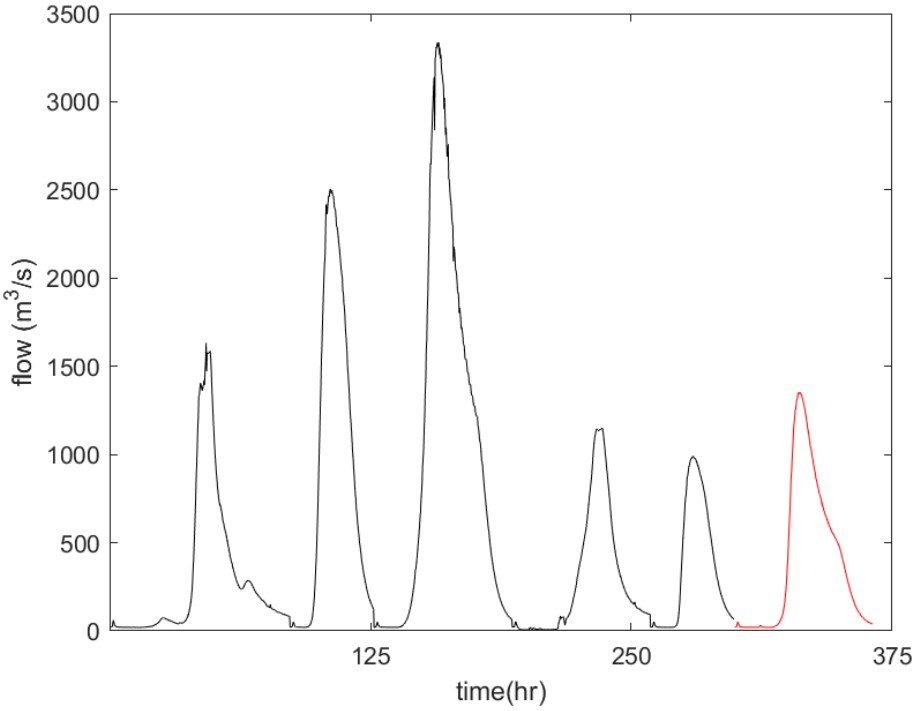


圖 3.6.1 流量歷線圖

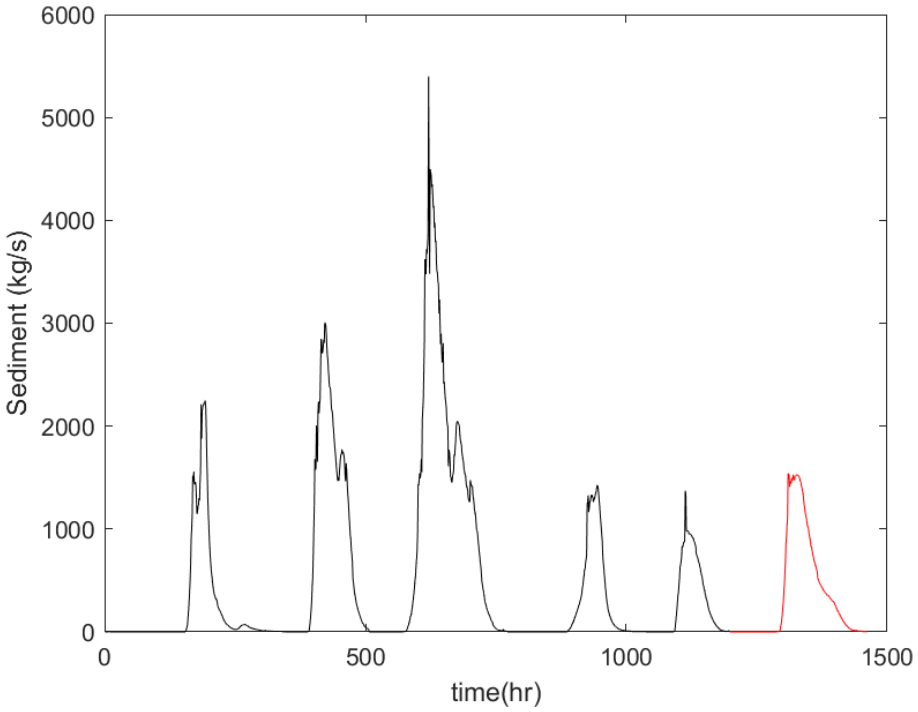


圖 3.6.2 砂量歷線圖

II. 資料正規化處理

為了使資料再訓練過程中能夠有效的達到收斂，而會有所謂的正規化的動作，將資料數值控制在 0~1 之內，也可以大幅降低訓練上的時間，在對網絡進行訓練和測試之後，通過使用相應的反正規化因子進行轉換來對輸出進行反正規化，以便以原始數據獲得輸出。以下為資料正規化的處理。

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

X:原始資料

III. 效能評估

本研究採用下列三種客觀的指標進行模式評鑑：

1. 相關係數（Correlation Coefficient，R）

$$\mathrm{R} = \frac{\sum(S_t - \overline{S_t})(\dot{S}_t - \ddot{S}_t))}{\sqrt{\sum(S_t - \overline{S_t})^2}\sqrt{\sum(\dot{S}_t - \ddot{S}_t)^2}}$$

式中，$\dot{S}_t$為模式預測之砂量(kg/s)

S_t為觀測之砂量(kg/s)

$\overline{S_t}$為觀測砂量之平均值(kg/s)

$\ddot{S}_t$為預測砂量之平均值(kg/s)

若 R 值愈趨進 1，則表示模擬結果與實際資料愈密合，即精確度愈高。

2. 均方根誤差(Root Mean Square Error，RMSE)

觀測值與真值偏差的平方和與觀測次數 m 比值的平方根，是用來衡量觀測值同真值之間的偏差。

$$\mathrm{RMSE} = \sqrt{\frac{1}{m}\sum(S_t - \dot{S}_t)^2}$$

式中，$\dot{S}_t$為模式預測之砂量(kg/s)

S_t為觀測之砂量(kg/s)

m 為資料總數

3. 平均絕對誤差(Mean Absolute Error，MAE)

是絕對誤差的平均值，能更好地反映預測值誤差的實際情況。

$$\mathrm{MAE} = \frac{1}{m}\sum|S_t - \dot{S}_t|$$

式中，$\dot{S}_t$為模式預測之砂量(kg/s)

S_t為觀測之砂量(kg/s)

m 為資料總數

IV. 模擬情境

本次研究想考慮不同輸入條件下的模擬情形，將分為兩種情境去進行模擬，情境一為僅考慮流量當輸入條件去預測砂量，分別有 set1(前一小時流量)、set2(前一小時流量和當前流量)、set3(前一小時流量和前二小時流量)、set3(當前流量、前一小時流量和前二小時流量); 情境二為考慮流量和砂量當輸入條件去預測砂量，分別有 set1(前一小時流量和前一小時砂量)、set2(前一小時流量、前二小時流量和前一小時砂量)、set3(前二小時流量、前一小時砂量和前二小時砂量)、set3(前一小時流量、前二小時流量、前一小時砂量和前二小時砂量)，輸出條件皆為

後一小時之砂量。下表 3.6.2 為情境一、二之配置。

表 3.6.2 情境一、二配置圖

	Set I	Set II	Set III	Set IV
Scenario No.1	Q_{t-1}	Q_{t-1}、Q_t	Q_{t-1}、Q_{t-2}	Q_{t-2}、Q_{t-1}、Q_t
Scenario No.2	Q_{t-1}、S_{t-1}	Q_{t-2}、Q_{t-1}、S_{t-1}	Q_{t-2}、S_{t-1}、S_{t-2}	Q_{t-2}、Q_{t-1}、S_{t-1}、S_{t-2}

V. BPNN、RBFNN、LSTM 神經網路配置

1. BPNN

輸入資料採用不同情境組合，神經元經由 5、10、15 分別測試，活化函數採用 S 形正切函數(tansig)、線性函數(purlin)搭配使用，學習速率越小可以使誤差更新越敏感，由於資料數不多每次更新都很重要在此採用 0.001，迭帶次數經由幾次模擬發現 10 次以內會達到誤差標準，在此設置為 50 使之達到最大迭帶。

2. RBFNN

輸入資料採用不同情境組合，中心點採用隨機產生，中心點數經由 5、10、15 分別測試，活化函數採用目前較多人使用的高斯函數，誤差傳播速率在此使用默認值 1。

3. LSTM

輸入資料採用不同情境組合，神經元經由 5、10、15 分別測試，迭帶次數經由幾次模擬發現 50~80 次左右會達到誤差穩定，在此設置為 100，活化函數採用默認 tanh 函數，學習速率越小可以使誤差更新越敏感，由於資料數不多每次更新都很重要在此採用 0.001。下表 3.6.3 為各神經網路之配置情形。

表 3.6.3 各神經網路之配置情形

	神經元	迭帶次數	學習速率	活化函數	傳播速率
BPNN	5、10、15	50	0.001	tansig、purlin	無
RBFNN	5、10、15	無	無	高斯函數	1
LSTM	5、10、15	100	0.001	tanh	無

3.6.1 模擬結果比較

1. 神經元數量選擇

   藉由固定訓練資料，改變不同神經元數量來看不同神經元數量下，模擬的準確性，來決定最佳神經元的配置情形，如下圖 3.6.3~3.6.5 可知，BPNN 神經網路的最佳神經元為 10; RBFNN 神經網路的最佳神經元為 10; LSTM 神經網路的最佳神經元為 15，神經元的數量多寡很重要因為神經元過少則無法適當描述，過多則會有過度地描述所謂過度擬和的問題。

表 3.6.4 BPNN 神經元配置

Input sets	BPNN		
神經元	RMSE	MAE	R
5	66.89	39.13	0.992
10	56.87	26	0.995
15	60	39	0.994

表 3.6.5 RBFNN 神經元配置

Input sets	RBFNN		
神經元	RMSE	MAE	R
5	63.8	36	0.994
10	52	24	0.995
15	52.4	24.3	0.995

表 3.6.6 LSTM 神經元配置

Input sets	LSTM		
神經元	RMSE	MAE	R
5	121	92	0.98
10	107	87	0.981
15	104	81	0.985

2. 情境模擬結果比較

情境一為探討不同流量組合下對於砂量預測的結果比較，結果如表 3.6.7，BPNN 與 RBFNN 的訓練結果差異不大，最好的預報組合皆為 Set2(當前流量、前一時刻流量)，至於 LSTM 在本次訓練組合中訓練不佳，最好的預報組合也是落在 Set2(當前流量、前一時刻流量)。

情境二為探討不同流量、砂量組合下對於砂量預測的結果比較，結果如表 3.6.8，可以發現此時 RBFNN 的結果都優於 BPNN 的訓練結果，且加入砂量訓練 RBFNN 的結果比未加入砂量有明顯的改善誤差，但對於 BPNN 而言加入砂量反而使得誤差增大了，在 LSTM 方面，加入砂量對於其預報的影響最大，RMSE、MAE 值都有明顯的下降，這可能是因為 LSTM 是會更新、學習前一時刻輸入資料的神經網路，所以前一時刻砂量會影響後一時刻的砂量

圖 3.6.3、3.6.4 為情境一 Set2 之 BPNN 及情境二 Set4 之 RBFNN 之相關係數圖，兩者皆呈現高度相關;圖 3.6.5、3.6.6 為情境一 Set2 之 BPNN 及情境二 Set4 之 RBFNN 之砂量時間曲線，可以看到在低流量的部分兩者皆有良好的擬合，但在高流量及尾水的部分，情境二 Set4 之 RBFNN 組合有更良好的擬合效果。

最後選用誤差最小的網路來進行不同時刻的砂量預測，分別是情境二中 set4 組合的 RBFNN 網路以及可以根據前一時刻輸入值進行更新的 LSTM 網路，來進行 T+1、T+2、T+3、T+4、T+5、T+6 時刻的砂量預測。下表 3.6.9 為不同時刻之預報結果，可以發現 RBFNN 網路雖然隨著預報時間的增加，誤差增大，但是在 T+4 小時以內誤差變化不大，T+5 小時以上誤差才有明顯的增加;LSTM 網路在 T+2 小時以內誤差變化不大，T+4 小時以上誤差則有明顯的增加。

表 3.6.7 情境一不同流量組合下對於砂量預測的結果比較

	RMSE值(kg/s)			MAE值(kg/s)			R值		
	BPNN	RBFNN	LSTM	BPNN	RBFNN	LSTM	BPNN	RBFNN	LSTM
set1	56.87	52	104	26	24	81	0.995	0.995	0.98
set2	40	44	91	23.4	23.6	66	0.996	0.996	0.982
set3	59	51.7	99	34	29	67	0.991	0.994	0.981
set4	48	56	90	32	33	68	0.992	0.993	0.98

表 3.6.8 情境二不同流量、砂量組合下對於砂量預測的結果比較

	RMSE值(kg/s)			MAE值(kg/s)			R值		
	BPNN	RBFNN	LSTM	BPNN	RBFNN	LSTM	BPNN	RBFNN	LSTM
set1	81	63	71	60	30.8	47	0.995	0.997	0.99
set2	78	48.3	59	37	24.5	31	0.996	0.998	0.993
set3	52	50	65	33	24	40	0.997	0.998	0.991
set4	53	40	58	33	19	30	0.997	0.998	0.994

表 3.6.9 不同時刻之預報結果

	RMSE值(kg/s)		MAE值(kg/s)		R值	
	RBFNN	LSTM	RBFNN	LSTM	RBFNN	LSTM
T+1	48.3	58	24.5	30	0.996	0.994
T+2	53.1	66.8	25	34	0.996	0.993
T+3	57.9	93.7	29.1	53.6	0.995	0.988
T+4	59.82	102.2	31.87	63	0.994	0.982
T+5	83.49	109.52	44.5	64	0.9882	0.98
T+6	85.4	150	47.85	83	0.9887	0.96

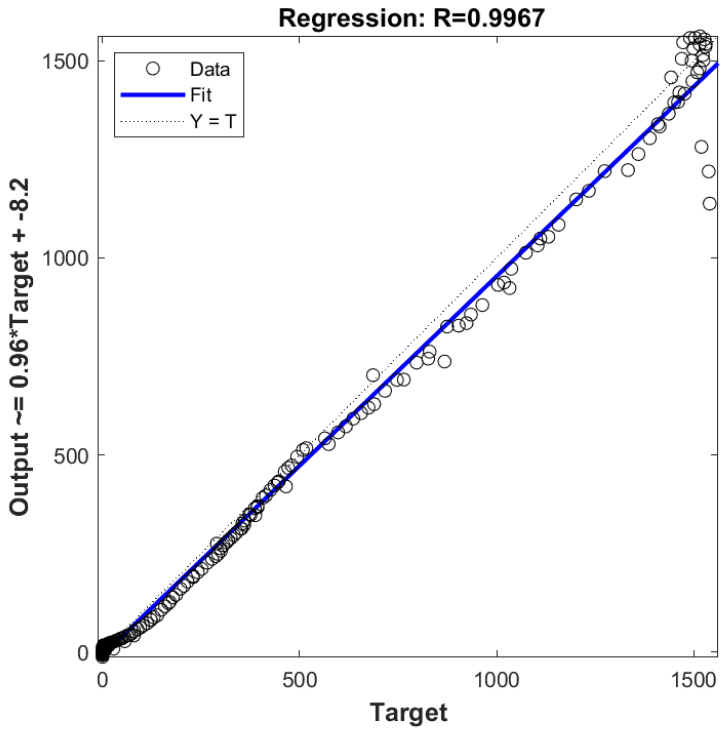


圖 3.6.4 情境一(Set2)之 BPNN 相關係數圖

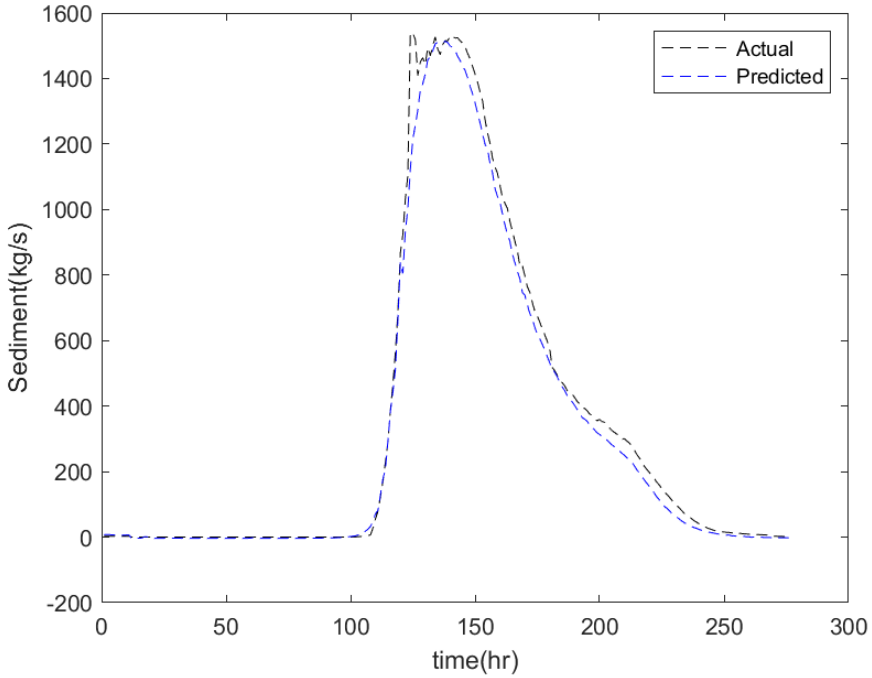


圖 3.6.5 情境二(Set4)之 RBFNN 之砂量歷線圖

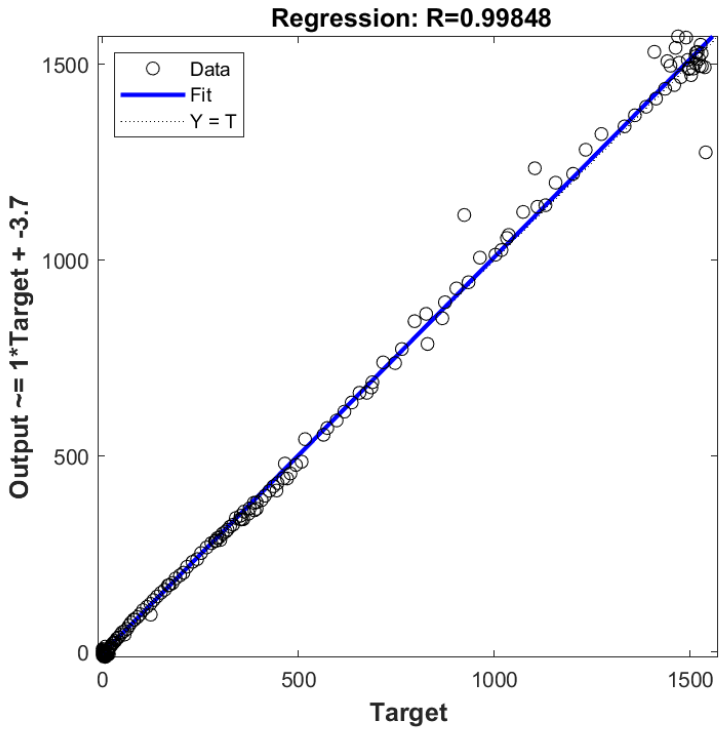


圖 3.6.6 情境二(Set4)之 RBFNN 相關係數圖

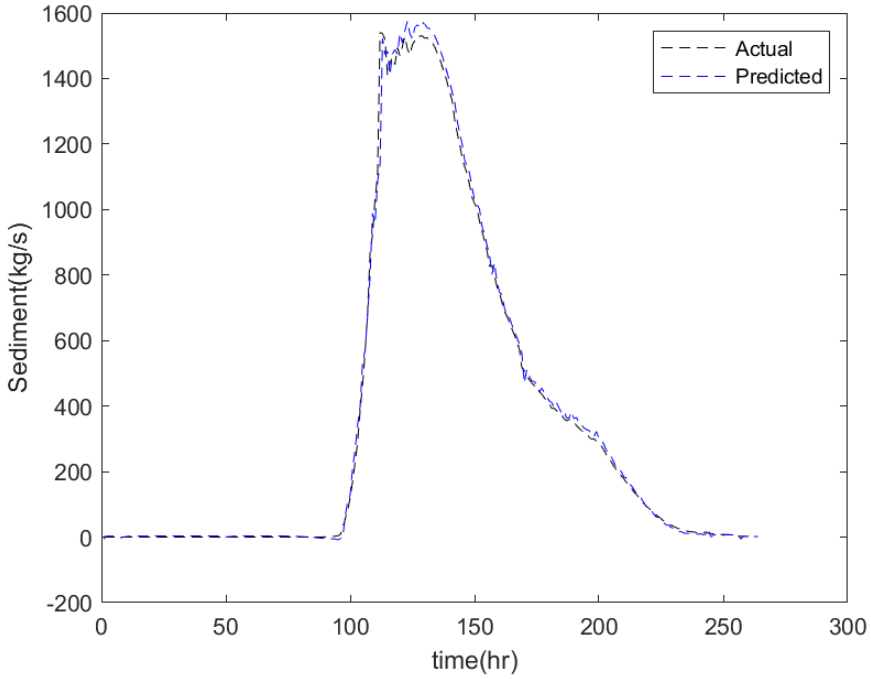


圖 3.6.7 情境二(Set4)之 RBFNN 砂量歷線圖

第四章　結論及預計可能遭遇之困難

4.1　結論

此研究提出一個集水區土砂收支預報，模式從一開始的雨量站資料蒐集、設計雨型，在用模式 HEC-HMS 進行集水區流量預測、放入輸砂模擬軟體 SRH-2D 產製輸砂量，最後再進行神經網路的預測，可提供水保局做為未來規劃的參考，其對於未來不同颱洪事件下可提供一定的科學依據。本研究以石門水庫為例，對石門水庫的上游砂量進行預報，最後以評鑑指標來表現。

最重要的，其能夠提高防砂治理效益，減少硬體投入資源浪費，對於集水區永續發展有正面助益。本研究成果歸納出以下結論:

1. 本研究以傳統頻率分析配合 HEC-HMS 產製集水區流量資料，並以民國 102 年潭美颱風及菲特颱風之實測資料進行模式參數的率定。
2. 選定民國 102 年潭美颱風及菲特颱風期間實測的水位、砂量、流量資料並加入利用 HEC-HMS 產生之支流資料進行 SRH2D 模式參數之檢定與驗證工作。
3. 待模式參數率定完成後，經由頻率分析、設計雨型，再利用 HEC-HMS 產生不同頻率年的設計暴雨量，最後用 SRH2D 模式產製輸砂量。

4. 根據集水區泥砂生產特性規劃類神經網路模式之網路架構，並利用所生產之大量人工資料加上原有之颱風資料進行類神經網路模式之學習訓練；模式學習訓練完成後並進行類神經網路模式之驗證。
5. 比較傳統神經網路 BPNN、RBFNN 與長短時記憶神經網路 LSTM 的訓練效果，以 RBFNN 神經網路有良好的訓練成果，可以得知雖然 LSTM 有記憶前一時刻的輸入結果加以進行修正，但在不同的訓練資料情況下，也不一定會有比較好的驗證效果。
6. 預測未來 1~6 小時之輸砂量，以 RBFNN 效果顯著，大概在前 3 小時誤差都沒有明顯變化。
7. 利用 SRH-2D 模式及類神經網路模式推估暴雨期間之產砂量都可獲得不錯的成果，但由於 SRH-2D 模式需要輸入眾多參數，且模擬時間較長，因此利用較為簡單及迅速之類神經網路模式，可以於颱風發生期間，迅速推求下游的砂量，以此來進行即時的人員避難，相關防護措施的建置，以減小颱風造成的損失。

4.2 預計可能遭遇之困難

台灣每年受到三至四場颱風侵襲，不過颱風時期現場量測資料量太少，量測的資料正確性也需要做進一步檢討，本研究依據現場資料進行數值模式的率定驗證後，再用該模式大量模擬不同颱洪事件的輸砂量進行機器學習，誤差的傳遞可能會造成本研究提出的預報模式產生一定的差異。

參考文獻

1. 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 Discussions, 6(4), 655-670.
2. Afan, H. A., El-Shafie, A., Yaseen, Z. M., Hameed, M. M., Mohtar, W. H. M. W., & Hussain, A. (2015). ANN based sediment prediction model utilizing different input scenarios. Water Resources Management, 29(4), 1231-1245.
3. Ajami, N. K., Duan, Q., & Sorooshian, S. (2007). An integrated hydrologic Bayesian multimodel combination framework: Confronting input, parameter, and model structural uncertainty in hydrologic prediction. Water Resources Research, 43(1).
4. Ajami, N. K., Duan, Q., Gao, X., & Sorooshian, S. (2006). Multimodel combination techniques for analysis of hydrological simulations: Application to distributed model intercomparison project results. Journal of Hydrometeorology, 7(4), 755-768.
5. Ajami, N. K., Duan, Q., Moradkhni, H., & Sorooshian, S. (2005). 1.3 RECURSIVE BAYESIAN MODEL COMBINATION FOR STREAMFLOW FORECASTING.
6. Alfieri, L., Burek, P., Dutra, E., Krzeminski, B., Muraro, D., Thielen, J., & Pappenberger, F. (2013). GloFAS-global ensemble streamflow forecasting and flood early warning. Hydrology and Earth System Sciences, 17(3), 1161.
7. Araghinejad, S., Azmi, M., & Kholghi, M. (2011). Application of

artificial neural network ensembles in probabilistic hydrological forecasting. Journal of Hydrology, 407(1-4), 94-104. Araghinejad, S., Azmi, M., and Kholghi, M., 2011.

8. Beck, M. B. (1987). Water quality modeling: a review of the analysis of uncertainty. Water Resources Research, 23(8), 1393-1442.
9. Beven, K., & Binley, A. (1992). The future of distributed models: model calibration and uncertainty prediction. Hydrological processes, 6(3), 279-298.
10. Bharti, B., Pandey, A., Tripathi, S. K., & Kumar, D. (2017). Modelling of runoff and sediment yield using ANN, LS-SVR, REPTree and M5 models. Hydrology Research, nh2017153.
11. Chiang, Y. M., Hao, R. N., Ho, H. C., Chang, T. J., & Xu, Y. P. (2017). Evaluating the contribution of multi-model combination to streamflow hindcasting by empirical and conceptual models. Hydrological Sciences Journal, 62(9), 1456-1468.
12. Chien, F. C. (2000). Precipitation parameterization in a simulated Mei-Yu front.
13. Coulibaly, P., & Baldwin, C. K. (2009). Dynamic neural networks for nonstationary hydrological time series modeling. In Practical Hydroinformatics (pp. 71-85). Springer Berlin Heidelberg.
14. Duan, Q., Ajami, N. K., Gao, X., & Sorooshian, S. (2007). Multi-model ensemble hydrologic prediction using Bayesian model averaging. Advances in Water Resources, 30(5), 1371-1386.
15. Evensen, G. (1992). Using the extended Kalman filter with a

multilayer quasi−geostrophic ocean model. Journal of Geophysical Research: Oceans, 97(C11), 17905-17924.

16. Fahimi, F., Yaseen, Z. M., & El-shafie, A. (2017). Application of soft computing based hybrid models in hydrological variables modeling: a comprehensive review. Theoretical and Applied Climatology, 128(3-4), 875-903.
17. 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(1-4), 222-241.
18. Greimann, B., Sheydayi, P., Vargas, S., Lai, Y., & Mefford, B. (2008). Developing Mitigation Plans for Matilija Dam Removal. In World Environmental and Water Resources Congress 2008: Ahupua'A (pp. 1-9).
19. Hoeting, J. A., Madigan, D., Raftery, A. E., & Volinsky, C. T. (1998, May). Bayesian model averaging. In Proceedings of the AAAI Workshop on Integrating Multiple Learned Models (Vol. 335, pp. 77-83).
20. Hoeting, J. A., Madigan, D., Raftery, A. E., & Volinsky, C. T. (1999). Bayesian model averaging: a tutorial. Statistical science, 382-401.
21. Huang, J., & Russell, K. (2014). Two-Dimensional Numerical Simulation of a Grand Canyon Sandbar during a High Flow Experiment. In World Environmental and Water Resources Congress 2014 (pp. 1183-1190).

22. Jeong, D. I., & Kim, Y. O. (2005). Rainfall‐runoff models using artificial neural networks for ensemble streamflow prediction. Hydrological processes, 19(19), 3819-3835.
23. Jiang, S. H. A. N. H. U., Ren, L. I. L. I. A. N. G., Yang, X. I. A. O. L. I., Ma, M. I. N. G. W. E. I., & Liu, Y. (2014). Multi-model ensemble hydrologic prediction and uncertainties analysis. Proceedings of the International Association of Hydrological Sciences, 364, 249-254.
24. Kitanidis, P. K., & Bras, R. L. (1980). Adaptive filtering through detection of isolated transient errors in rainfall‐runoff models. Water Resources Research, 16(4), 740-748.
25. Kitanidis, P. K., & Bras, R. L. (1980). Real‐time forecasting with a conceptual hydrologic model: 2. Applications and results. Water Resources Research, 16(6), 1034-1044.
26. Kuczera, G., & Parent, E. (1998). Monte Carlo assessment of parameter uncertainty in conceptual catchment models: the Metropolis algorithm. Journal of Hydrology, 211(1-4), 69-85.
27. Lai, Y. G., & Wu, K. (2013). Modeling of vertical and lateral erosion on the Chosui River, Taiwan. In World Environmental and Water Resources Congress 2013: Showcasing the Future (pp. 1747-1756).
28. Lai, Y. G., & Wu, K. (2014). Combined Vertical And Lateral Channel Evolution Numerical Modeling.
29. Leutbecher, M., & Palmer, T. N. (2008). Ensemble forecasting. Journal of Computational Physics, 227(7), 3515-3539.

30. Miller, R. N., Ghil, M., & Gauthiez, F. (1994). Advanced data assimilation in strongly nonlinear dynamical systems. Journal of the atmospheric sciences, 51(8), 1037-1056.
31. Moges, E. M. (2010). Evaluation of sediment transport equations and parameter sensitivity analysis using the SRH-2D Model (Doctoral dissertation, MS Thesis in Universität Stuttgart).
32. Montanari, A., & Brath, A. (2004). A stochastic approach for assessing the uncertainty of rainfall−runoff simulations. Water Resources Research, 40(1).
33. Moradkhani, H., Hsu, K. L., Gupta, H., & Sorooshian, S. (2005). Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter. Water resources research, 41(5).
34. Napolitano, G., Serinaldi, F., & See, L. (2011). Impact of EMD decomposition and random initialisation of weights in ANN hindcasting of daily stream flow series: an empirical examination. Journal of Hydrology, 406(3-4), 199-214.
35. Noori, N., & Kalin, L. (2016). Coupling SWAT and ANN models for enhanced daily streamflow prediction. Journal of Hydrology, 533, 141-151.
36. Ouarda, T. B. M. J., & Shu, C. (2009). Regional low−flow frequency analysis using single and ensemble artificial neural networks. Water resources research, 45(11).
37. Rajaee, T., Mirbagheri, S. A., Zounemat-Kermani, M., & Nourani, V. (2009). Daily suspended sediment concentration simulation using

ANN and neuro-fuzzy models. Science of the total environment, 407(17), 4916-4927.

38. Shamseldin, A. Y., O'Connor, K. M., & Liang, G. C. (1997). Methods for combining the outputs of different rainfall–runoff models. Journal of Hydrology, 197(1-4), 203-229.
39. Sharmaa, L. M. A., & Nottb, D. J. Efficient Bayesian Model Selection in Hydrological Modelling.
40. Shih, D. S., Chen, C. H., & Yeh, G. T. (2014). Improving our understanding of flood forecasting using earlier hydro-meteorological intelligence. Journal of hydrology, 512, 470-481.
41. Smith, C., Doherty, J., & Jin, Y. (2013, April). Recurrent neural network ensembles for convergence prediction in surrogate-assisted evolutionary optimization. In Computational Intelligence in Dynamic and Uncertain Environments (CIDUE), 2013 IEEE Symposium on (pp. 9-16). IEEE.
42. Thiboult, A., Anctil, F., & Boucher, M. A. (2016). Accounting for three sources of uncertainty in ensemble hydrological forecasting. Hydrology and Earth System Sciences, 20(5), 1809-1825.
43. Thiboult, A., Anctil, F., & Boucher, M. A. (2016). Accounting for three sources of uncertainty in ensemble hydrological forecasting. Hydrology and Earth System Sciences, 20(5), 1809-1825.
44. Tiwari, M. K., & Chatterjee, C. (2010). Uncertainty assessment and ensemble flood forecasting using bootstrap based artificial neural networks (BANNs). Journal of Hydrology, 382(1-4), 20-33.
45. Vrugt, J. A., Gupta, H. V., Bouten, W., & Sorooshian, S. (2003). A

Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. Water resources research, 39(8).

46. 經濟部水利署水文水資源資料管理供應系統

47. 陳鵬安，2017，機器學習法於水庫異重流到達時間及排砂效率預報之研究

48. 經濟部水利，2011，氣候變遷下水庫排砂對策研究總報告。

49. 經濟部水利署，2014，曾文永久河道放水道改建防淤設施工程射流閘門操作及維護手冊。