

國立臺灣師範大學科技與工程學院電機工程學系

博士論文

Department of Electrical Engineering

College of Technology and Engineering

National Taiwan Normal University

Doctoral Dissertation

適應不同氣候情境之流域多水庫多目標發電決策最佳  
化系統

Optimisation of Multi-Reservoir Multi-Objective Power  
Generation Decision Making System for Different  
Climatic Scenarios in River Basins



曹顥瀚

Hao-Han Tsao

指導教授：呂藝光 博士

Advisor: Yih-Guang Leu, Ph.D.

中華民國 114 年 1 月

January 2025

## 誌 謝

物換星移，轉眼間就步入畢業的時節，也代表我在國立臺灣師範大學博士的求學之路即將完結。回想起過往的求學之路中受到許多的幫助，在這邊至上我最誠摯的感謝。首先我要感謝我的指導教授呂藝光博士，在期刊投稿、資格考審查、計畫撰寫與論文種種的研究方向上給我無數的幫助與指導，不論是期刊撰寫的技巧亦或是待人處事的道理，都讓我受益良多。也讓我學習到再生能源在學術上面許多的應用方法與最佳化理論。讓我可以帶著這些經驗與知識步入人生中的下一個階段。最後感謝老師的指導與推薦，讓我可以將我的所學應用到我未來的工作場域當中。

再來要感謝我在職的主管周儷芬組長與同事哲宇、志榮的包容與支持，在求學的過程中對我的協助，不論是參訪大甲流域的每一個水庫與電廠亦或是在解決再生能源在實務上的實際應用所產生的種種問題以及電力公司在這些實務經驗上所面臨的挑戰，這些種種都是我的寶貴經驗。再來要謝謝曹朝陽主任對我的諄諄教誨，指導了我需量反應、輔助服務等眾多能源需求所面臨的挑戰，這些經驗都讓我對電網亦或是電力調度實務上的挑戰有著更進一步的了解。

最後我要感謝我的家人，在求學路上給我的支持與鼓勵，在需多刻苦的時分給了我支持與陪伴，讓我能夠堅持精進我的學業與研究。在最後至上我最誠摯的感謝。

曹顯瀚 謹誌於

中華民國一一四年一月

# 適應不同氣候情境之流域多水庫多目標發電 決策最佳化系統

學生：曹顥瀚

指導教授：呂藝光

國立臺灣師範大學電機工程學系博士班

## 摘 要

本文旨在開發一套流域多水庫多目標發電決策最佳化系統，以應對極端氣候下的挑戰。針對台灣大甲溪流域，該系統整合模糊類神經網路預測模型，來進行最上游德基水庫的入流量預測，並提出預測區間方法來量化預測的不確定性。藉由建立流域水庫間的逕流模型，來模擬水庫操作的耦合關係。此外，利用模糊邏輯與多準則決策方法，來動態調整決策權重，以及提出評估發電效率與排洪風險的指標，來設計多目標最佳化成本函數。最後，採用二階段逐小時多水庫最佳化架構，整合預測資訊與專家意見，來提升整體的水力發電調度效率、降低排洪風險，並在不同天氣事件中維持著不同的發電決策。

關鍵詞：多目標最佳化、入流量預測、多水庫發電決策、多準則決策

# Optimisation of Multi-Reservoir Multi-Objective Power Generation Decision Making System for Different Climatic Scenarios in River Basins

Student : Hao-Han Tsao

Advisor : Dr. Yih-Guang Leu

Department of Electrical Engineering  
National Taiwan Normal University

## ABSTRACT

This thesis develops an optimisation system for multi-reservoir, multi-objective power generation decision-making in river basins to address challenges posed by extreme weather. For Taiwan's Dajia river basin, the system integrates upstream inflow forecasting using a fuzzy neural network with meteorological and historical data, quantifies forecast uncertainty via prediction intervals, and models inter-reservoir runoff relationships to simulate operational coupling. In addition, the system uses fuzzy logic and Multi-Criteria Decision Making (MCDM) to dynamically adjust the decision weights, and proposes metrics for evaluating generation efficiency and flood risk to design the multi-objective optimized cost function. Finally, through a two-stage hourly multi-reservoir optimisation framework, the system integrates forecasts and expert opinions to enhance hydropower dispatch, reduce flood risk, and maintain generation during extreme weather.

Keywords: multi-objective optimisation, inflow forecasting, multi-reservoir power generation decision-making, multi-criteria decision-making (MCDM)

# 目 錄

誌 謝.....	i
中文摘要.....	ii
英文摘要.....	iii
目 錄.....	iv
圖 目 錄.....	vii
表 目 錄.....	xiii
第一章 緒論.....	1
1.1 研究背景與動機.....	1
1.2 研究目的.....	5
1.3 研究步驟.....	7
1.4 研究架構.....	9
第二章 文獻探討與回顧.....	10
2.1 水力預測背景回顧.....	10
2.2 氣象預報對水庫入流量預測之影響.....	13
2.3 預測誤差與各種不確定性對流域水庫最佳化帶來的挑戰.....	14
2.4 預測區間與信賴區間.....	15
2.5 流域水庫多目標最佳化問題.....	17
第三章 德基水庫入流量預測系統建置.....	22
3.1 簡介.....	22
3.2 台灣德基水庫介紹：.....	23
3.3 研究方法與預測機制.....	26
3.3.1 研究方法.....	26
3.3.2 三階段模糊神經網路預測機制.....	29
3.4 結果與討論.....	30

3.4.1	資料分析：水位、入流量與降雨量的關係 .....	30
3.4.2	水位容積曲線與電水比曲線近似方法實現 .....	33
3.4.3	集水區內水庫水位與氣象降雨資料的相關性分析 .....	35
3.4.4	實驗結果.....	36
3.4.5	討論.....	48
3.5	總結.....	49
第四章	預測區間系統建立.....	51
4.1	簡介與相關文獻回顧.....	51
4.2	基於重心的預測區間優化程序.....	53
4.2.1	基於重心的成本函數設計.....	58
4.2.2	啟發式演算法.....	58
4.2.3	研究架構.....	61
4.3	實驗結果與討論.....	62
4.3.1	類電磁模糊神經網路.....	63
4.3.2	細菌覓食模糊類神經網路.....	80
4.3.3	類電磁反向傳播神經網路.....	84
4.3.4	細菌覓食反向傳遞神經網路.....	88
4.3.5	反向傳播神經網路與模糊神經網路結果比較 .....	92
4.3.6	多步領前預測.....	93
4.4	結論.....	99
第五章	流域發電預測規劃系統建立.....	100
5.1	簡介.....	100
5.2	研究方法.....	104
5.2.1	EMOGA 模組 (ev-MOGA 多目標演算法) .....	107
5.2.2	CF 模組 (成本函數設計) .....	110

5.2.3 RM 模組 .....	115
5.2.4 FTOPSIS 模組 .....	118
5.2.5 EOG 模組 .....	124
5.2.6 CWG 模組 .....	127
5.2.7 方法整體流程.....	131
5.3 研究結果與討論.....	135
5.3.1 資料蒐集.....	136
5.3.2 RM 模組 .....	138
5.3.3 ev-MOGA .....	145
5.3.4 案例分析.....	146
5.4 結論.....	179
第六章 結論與未來展望.....	181
6.1 結論.....	181
6.2 未來展望.....	185
參考文獻.....	187
自 傳.....	198
學術成就.....	200

## 圖 目 錄

圖 1-1	德基水庫示意圖.....	2
圖 3-1	德基水庫及上游降雨觀測站的位置.....	25
圖 3-2	模糊類神經網路架構圖.....	28
圖 3-3	入流量、水位三階段預測架構.....	30
圖 3-4	德基水庫的水位變化與七個上游集水區雨量觀測站變化趨勢圖.....	31
圖 3-5	德基水庫集水區雨量觀測站加總與水位變化在不同延遲時間下的相關性趨勢圖.....	32
圖 3-6	德基水庫集水區氣象預報於雨量觀測站格點位置之雨量加總與水位變化在不同延遲時間下的相關性趨勢圖.....	33
圖 3-7	(a)水位容積曲線近似與(b)電廠電水比曲線近似.....	34
圖 3-8	德基水庫雨量觀測與預報誤差分析(a) RMSE 與(b) MAE.....	36
圖 3-9	水位預測結果 (a)訓練資料與(b)測試資料.....	37
圖 3-10	2013 年 8 月 21 號 0 點水位預測結果 (潭美颱風期間).....	39
圖 3-11	2013 年 8 月 21 號 0 點入流量預測結果 (潭美颱風期間).....	39
圖 3-12	2013 年 8 月 28 號 6 點水位預測結果 (康芮颱風期間).....	40
圖 3-13	2013 年 8 月 28 號 6 點入流量預測結果 (康芮颱風期間).....	40
圖 3-14	2013 年 9 月 22 號 2 點水位預測結果 (天兔颱風期間).....	41
圖 3-15	2013 年 9 月 22 號 2 點入流量預測結果 (天兔颱風期間).....	41
圖 3-16	2014 年 7 月 22 號 0 點水位預測結果 (麥德姆颱風期間).....	42
圖 3-17	2014 年 7 月 22 號 0 點入流量預測結果 (麥德姆颱風期間).....	42
圖 3-18	2012 年入流量預測誤差分析結果.....	44
圖 3-19	2013 年入流量預測誤差分析結果.....	44
圖 3-20	2012 年入流量預測誤差分析 (當觀測入流量大於 100CMS 時)....	45
圖 3-21	2013 年入流量預測誤差分析 (當觀測入流量大於 100CMS 時)....	45

圖 3-22	預測系統引入對水資源的影響（水位趨勢） .....	47
圖 3-23	預測系統引入對水資源的影響（發電趨勢） .....	47
圖 3-24	每小時預先滿載發電對排洪水資源損失影響（發電量計算） .....	47
圖 4-1	預測區間的上限與下限示意圖 .....	54
圖 4-2	預測區間方法整體架構 .....	61
圖 4-3	風力發電資料(a)風功率曲線 (b)風速趨勢圖 (c)相關係數 (d) 檢驗假設的 p 值趨勢 .....	62
圖 4-4	(a)模糊類神經網路歸屬函數 (b)類電磁網路的訓練收斂過程 .....	66
圖 4-5	類電磁模糊神經網路（傳統方法） (a)訓練資料與(b)測試資料 .....	67
圖 4-6	類電磁模糊神經網路(a)訓練資料與(b)測試資料（本文提出方法） ..	68
圖 4-7	類電磁模糊神經網路訓練結果（使用 $W_{PICP} = 2$ , $W_{MPIB} = 1$ , $W_{CC} = 0.005$ 作為參數）(a)訓練資料與(b)測試資料 .....	70
圖 4-8	類電磁模糊神經網路訓練結果（使用 $W_{PICP} = 6$ , $W_{MPIB} = 1$ , $W_{CC} = 0.005$ 作為參數）(a)訓練資料與(b)測試資料 .....	71
圖 4-9	類電磁類模糊神經網路訓練結果（使用 $W_{PICP} = 1$ , $W_{MPIB} = 1$ , $W_{CC} = 1$ 作為參數）(a)訓練資料與(b)測試資料 .....	73
圖 4-10	類電磁模糊神經網路訓練結果（使用 $W_{PICP} = 1$ , $W_{MPIB} = 1$ , $W_{CC} = 10$ 作為參數）(a)訓練資料與(b)測試資料 .....	74
圖 4-11	類電磁模糊神經網路訓練結果(使用 $W_{PICP} = 2$ , $W_{MPIB} = 4$ , $W_{CC} = 0.1$ 作為參數）(a)訓練資料與(b)測試資料 .....	76
圖 4-12	類電磁模糊神經網路訓練結果(使用 $W_{PICP} = 2$ , $W_{MPIB} = 3$ , $W_{CC} = 0.1$ 作為參數結果）(a)訓練資料與(b)測試資料 .....	77
圖 4-13	類電磁模糊神經網路於風力發電預測結果(a)訓練資料與(b)測試資料（使用傳統方法） .....	79

圖 4-14	類電磁模糊神經網路於風力發電預測結果(a)訓練資料與 (b)測試資料 (本文提出方法) .....	80
圖 4-15	細菌覓食模糊類神經網路訓練結果(a)訓練資料與(b)測試資料 (使用傳統方法) .....	82
圖 4-16	細菌覓食模糊類神經網路訓練結果(a)訓練資料與(b)測試資料 (本文提出方法) .....	83
圖 4-17	類電磁反向傳播神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用傳統方法) .....	86
圖 4-18	類電磁反向傳播神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用本文提出方法) .....	87
圖 4-19	細菌覓食反向傳遞神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用傳統方法) .....	90
圖 4-20	細菌覓食反向傳遞神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用本文提出方法) .....	91
圖 4-21	類電磁反向傳播神經網路於風速預測 WS (t+1)預測結果(a)訓練資料與(b)測試資料 .....	94
圖 4-22	類電磁反向傳播神經網路於風速預測 WS (t+2)預測結果(a)訓練資料與(b)測試資料 .....	95
圖 4-23	類電磁反向傳播神經網路於風速預測 WS (t+3)預測結果 (a)訓練資料與(b)測試資料 .....	96
圖 4-24	類電磁反向傳播神經網路於風速預測 WS (t+4)預測結果 (a)訓練資料與(b)測試資料 .....	97
圖 4-25	類電磁反向傳播神經網路於風速預測 WS (t+5)預測結果(a)訓練資料與(b)測試資料 .....	98
圖 4-26	不同領前預測步長對類電磁反向傳播神經網路之 MPIB 的影響 .....	99

圖 5-1	二階段流域多水庫發電決策最佳化整體系統架構圖 .....	104
圖 5-2	二階段逐小時多水庫多目標發電最佳化系統與模組架構圖 .....	107
圖 5-3	CF 模組運作流程圖 .....	113
圖 5-4	流域全水庫逕流模型架構圖 .....	116
圖 5-5	逕流模型類神經網路架構圖 .....	117
圖 5-6	FTOPSIS 模組系統架構圖 .....	120
圖 5-7	EOG 模組歸屬函數示意圖 .....	127
圖 5-8	本文提出方法整體虛擬碼 .....	131
圖 5-9	大甲溪流域圖 .....	136
圖 5-10	青山水庫逕流模型訓練結果 (訓練資料) .....	140
圖 5-11	青山水庫逕流模型訓練結果 (測試資料) .....	140
圖 5-12	谷關水庫逕流模型訓練結果 (訓練資料) .....	141
圖 5-13	谷關水庫逕流模型訓練結果 (測試資料) .....	141
圖 5-14	天輪水庫逕流模型訓練結果 (訓練資料) .....	142
圖 5-15	天輪水庫逕流模型訓練結果 (測試資料) .....	142
圖 5-16	馬鞍水庫逕流模型訓練結果 (訓練資料) .....	143
圖 5-17	馬鞍水庫逕流模型訓練結果 (測試資料) .....	143
圖 5-18	無雨情境：調度中心未來發電命令與最上游水庫入流量趨勢圖 ...	149
圖 5-19	無雨情境流域水庫水位趨勢圖 .....	150
圖 5-20	無雨情境：每一小時的 ev-MOGA 最佳解集合收斂過程 (a) 1 小時領前 (b) 24 小時領前 .....	151
圖 5-21	無雨情境下方法 1 與調度中心歷史逐小時用水量比較圖 .....	152
圖 5-22	無雨情境下方法 2 與調度中心歷史逐小時用水量比較圖 .....	152
圖 5-23	颱風情境：調度中心未來發電命令與最上游水庫入流量趨勢圖 ...	154
圖 5-24	流域水庫水位趨勢圖 .....	155

圖 5-25	颱風情境：每一小時的 ev-MOGA 最佳解集合收斂過程 (a) 1 小時領前與 (b) 24 小時領前 .....	156
圖 5-26	颱風情境下方法 1 與調度中心歷史逐小時用水量比較圖 .....	157
圖 5-27	颱風情境下方法 2 與調度中心歷史逐小時用水量比較圖 .....	158
圖 5-28	無雨情境下方法 1 (本文提出方法)、單目標最佳化 GA 與實際廠區歷史運行用水量比較圖 .....	160
圖 5-29	颱風情境下方法 1 (本文提出方法)、單目標最佳化 GA 與實際廠區歷史運行用水量比較圖 .....	160
圖 5-30	2016 年 9 月 1 號~9 月 20 號入流量趨勢圖 .....	161
圖 5-31	2016 年 9 月 1 號至 9 月 20 號日累積用水量對照表 .....	162
圖 5-32	本文提出方法與實際歷史廠區累計用水量於 2016 年 9 月 1 至 10 號與 11 至 20 號 .....	162
圖 5-33	2016 年 1 月份用水量比較 .....	164
圖 5-34	2016 年 2 月份用水量比較 .....	164
圖 5-35	2016 年 3 月份用水量比較 .....	165
圖 5-36	2016 年 4 月份用水量比較 .....	165
圖 5-37	2016 年 5 月份用水量比較 .....	166
圖 5-38	2016 年 6 月份用水量比較 .....	166
圖 5-39	2016 年 7 月份用水量比較 .....	167
圖 5-40	2016 年 8 月份用水量比較 .....	167
圖 5-41	2016 年 9 月份用水量比較 .....	168
圖 5-42	2016 年 10 月份用水量比較 .....	168
圖 5-43	2016 年 11 月份用水量比較 .....	169
圖 5-44	2016 年 12 月份用水量比較 .....	169
圖 5-45	2016 年季度用水量比較 .....	170

圖 5-46	2016 年年度用水量比較.....	170
圖 5-47	2016 年 1 月份各電廠發電佔比比較 .....	171
圖 5-48	2016 年 2 月份各電廠發電佔比比較 .....	171
圖 5-49	2016 年 3 月份各電廠發電佔比比較 .....	172
圖 5-50	2016 年 4 月份各電廠發電佔比比較 .....	172
圖 5-51	2016 年 5 月份各電廠發電佔比比較 .....	173
圖 5-52	2016 年 6 月份各電廠發電佔比比較 .....	173
圖 5-53	2016 年 7 月份各電廠發電佔比比較 .....	174
圖 5-54	2016 年 8 月份各電廠發電佔比比較 .....	174
圖 5-55	2016 年 9 月份各電廠發電佔比比較 .....	175
圖 5-56	2016 年 10 月份各電廠發電佔比比較.....	175
圖 5-57	2016 年 11 月份各電廠發電佔比比較.....	176
圖 5-58	2016 年 12 月份各電廠發電佔比比較.....	176
圖 5-59	2016 年春季各電廠發電佔比比較 .....	177
圖 5-60	2016 年夏季各電廠發電佔比比較 .....	177
圖 5-61	2016 年秋季各電廠發電佔比比較 .....	178
圖 5-62	2016 年冬季各電廠發電佔比比較 .....	178
圖 5-63	2016 年年度各電廠發電佔比比較 .....	179

## 表 目 錄

表 3-1	2013 年 4 月至 9 月 TAPEX 集水區氣象即時雨量預報資料與集水區雨量站資料相關係數 .....	33
表 3-2	預測誤差 MSE.....	37
表 3-3	2013 至 2014 年已登台的颱風列表 .....	38
表 4-1	類電磁類神經網路效能比較表 .....	69
表 4-2	不同 $W_{PICP}$ 權重設定對類電磁模糊類神經比較表 .....	69
表 4-3	不同 $W_{CC}$ 對預測區間的影響比較表 .....	72
表 4-4	$W_{MPIB}$ 權重對類電磁演算法比較表.....	75
表 4-5	類電磁模糊神經演算方法所提方法與傳統方法比較表.....	78
表 4-6	細菌覓食模糊類神經網路方法比較.....	84
表 4-7	類電磁反向傳播神經網路比較表.....	88
表 4-8	細菌覓食反向傳遞神經網路訓練與測試結果比較表.....	92
表 4-9	細菌覓食演算法於不同神經網路預測效能比較表.....	93
表 5-1	歸屬函數對應表 .....	121
表 5-2	CWG 模組的歸屬函數列表.....	130
表 5-3	排洪風險優先因子模糊規則庫 .....	130
表 5-4	發電效率優先因子模糊規則庫 .....	130
表 5-5	非最上游水庫之 NN 模型訓練相關參數表 .....	144
表 5-6	大甲溪流域非最上游水庫逕流模型預測誤差 (訓練資料) .....	144
表 5-7	大甲溪流域非最上游水庫逕流模型預測誤差 (測試資料) .....	145
表 5-8	EV-MOGA 使用參數表 .....	145
表 5-9	各種氣候情境下的預期決策方針.....	147
表 5-10	方法 1 與方法 2 比較表 .....	148
表 5-11	方法 1 與 GA 方法比較.....	159

表 5-12 GA 方法參數設定 ..... 159



# 第一章 緒論

## 1.1 研究背景與動機

水力發電作為一種可快速部署且潔淨的再生能源，目前已在許多國家廣泛應用。隨著全球再生能源比例的提升，這類能源的穩定性將對電網產生更大影響。一套快速反應的系統如儲能和水力發電，透過其快速的發電反應速度與儲存能力，可以對穩定電網提供重要支持。同時隨著極端天氣事件的頻率增加，尤其在降雨量大的地區和島嶼氣候中，強降雨的頻繁發生將導致發生排洪事件的風險顯著上升。若能提前採取預防措施進行發電，將大大降低排洪發生的可能性。但在實務的應用上，調度人員往往傾向於採取更為保守穩健的規劃策略。並且以流域而言，一套能滿足流域發電調度需求總量、同時優化發電效率並降低排洪風險的發電決策系統，將為調度人員提供更大的決策緩衝時間、增強經濟效益並減少因洪水造成的民生灌溉和水資源損失。當水庫排洪事件發生時，其下游的水庫往往是不能發電的。由於排洪產生的放水量巨大且快速的特性，排洪過程中的水勢湍急，導致輸入進下游的水庫時水中會夾帶大量泥沙，這些水資源如果進入水輪機將容易導致機組葉片受損。當排洪發生時下游的發電能力將同時受限，因此流域的水庫排洪事件往往是由上而下同時發生，並且這些決策將會對經濟產生巨大的損失。若是能夠設計一套系統對流域當中的水庫進行發電決策的分配彙總成流域內各電廠機組排程，相信將可以為調度人員提供一定的參考價值。同時該系統應當考量降雨密集的海島氣候特性，依照未來的天氣情境進行最佳化的發電決策規劃，這些規劃需隱含風險管控與發電效益兩項衝突的指標。因此這將會是一個複雜的時序、多目標問題，

並且隱含天氣、水庫入流量預測等等的不確定性，這也是本文要解決的問題。



圖 1-1 德基水庫示意圖

(資料來源：[1])

水庫除了發電作業之外，通常具備其他多重功能用途。並且在操作的過程中必須同時考慮穩定電網、防洪需求、經濟效益、民生用水或是政府的發電法規限制等多方面的因素。流域內的水庫系統屬於典型的多水庫操作問題 (multi-reservoir systems operation, MRSO)，需要以多層面進行分析和優化，具體論述如下：

決策層面：

從決策角度來看，水庫的發電調度必須遵守一系列運轉規則，例如最小民生用水排放量限制、發電水位的上下限、灌溉用水需求、排洪操作規範，以及政府制定的水庫運轉水位規線。同時每一時間點的發電調度還需滿足電網的即時需求。

模型建構層面：

在模型構建方面，流域水庫的最佳化是一個高度複雜的問題。除了必須滿足上述限制條件之外，在進行實際優化前，還需設計流域內水庫間的逕流模型，以捕捉各水庫操作決策在時間與空間上的耦合關係。

時間耦合：水庫操作是一個多階段決策問題，當前的操作決策將影響未來的可行性和效益。因此問題的複雜性會隨著規劃時間的延展而急劇增加。

空間耦合：多個水庫通過河道網路層層相連，流域內的每一座水庫的任何操作都有可能會對其他水庫產生影響，形成系統聯動效應。並且每一個流域的放水決策對下游水庫的影響還會因距離而產生時間延遲，這又更進一步的提升系統的複雜度。

除此之外，地表逕流的蒸發和滲透等損失也需要納入模型考量，進一步增加系統複雜度。同時水輪機組的特性使得水庫的發電效率取決於水位和水輪機組之間的位能差距（也稱作發電水頭）。較高的水位差可提供更高的位能，以較少的水量生產相同的動能推動水輪機。這些水位與用水量的關係通常以電水比形式描述並嵌入模型中。每階段的決策將影響水量的變化，這些用水決策透過逕流模型進行模擬推演過後，下游水庫的入流量將被預測出來，這些預測的入流量又會根據每一個水庫的水位容積曲線更新下一個時間步長的水位資訊，這些對水位產生的變化又將進一步影響後續的發電效率與發電決策。如此富含時間與空間相關性的問題將使得MRSO問題的複雜性與非線性程度極高。

氣象預測與風險管理：

在解決上述問題後，還需考慮未來降雨對流域水資源的影響，包括氣象降雨預測、雨量與水庫入流量的關係等議題。決策時需綜合考量這些預測結果的不確定性所帶來的排洪風險。例如若完全信任入流量預測，水庫可能以高水位運行以確保發電效率，但若預測不準確，則可能導致重大風險。以颱風帶來的極端降雨為例，若未能準確預測即將發生的洪水湧入，同時水庫又維持在較高水位的狀態，極有可能引發排洪操作。排洪不僅會對灌溉區和民生地區造成水資源災害，為保護水輪機組，下游水庫往往無法進行發電且需同步排洪，導致大量水資源的損失。

綜上所述，MRSO 問題涉及時間與空間的高度耦合，並需整合氣象預測與不確定性分析，才能實現安全高效的水庫調度與管理。

以流域多水庫多目標最佳化來說，目前有許多文獻將多水庫發電最佳化視為一個多目標決策問題，流域水庫發電需要考量許多因素，如經濟效益、政府法規、民生用水、灌溉用水與穩定電網等等。由於台灣的海島型氣候與颱風事件頻繁，雨量都集中在梅雨季與颱風季當中，這些事件容易導致水庫的排洪決策發生。因此排洪風險也是應當被考量的因素。而經濟效益則是大部分流域多水庫多目標最佳化領域文獻希望達成的問題。目前已有許多文獻在這部分進行研究與應用。目前大多數研究集中於多水庫的水力發電決策優化或水庫流量預測，然而大多數現有文獻採用的預測間隔過長，難以有效應對島嶼氣候中短期強降雨。例如在臺灣大甲溪流域中，僅 12 小時的強降雨即可觸發防洪排放決策，在此情況下以每日為決策區間為基礎的發電計劃可能不適合臺灣等氣候變化極端的島嶼氣候。同時當

流域中存在庫容量較小的水庫如調整池式水庫或是較小庫容量的水庫時，以天的決策也有機會導致溢流的產生，也可能限制住方法的搜尋空間。這將對方法找出最佳解產生一定程度的阻礙。此外若以防洪的觀點來看，大多數方法僅在模擬過程中當水位閾值等防洪風險約束被超過時才施加嚴格的懲罰，這在穩定的氣候特性下可以得到良好的發電效率。然而，當颱風等密集降雨事件發生時，這些方法反而容易導致排洪決策的發生，因為良好的發電效率往往伴隨著是較高的發電位能（水位），這將使得水位更接近庫容量上限，同時降低突發事件的應對能力。為應對這些問題，並適應島嶼氣候中強降雨和頻繁颱風的特性，有必要同時考量流域的發電效率和防洪風險。因此一個包含水庫入流預測與多目標優化的系統變得至關重要。



## 1.2 研究目的

為了要實現流域多水庫多目標發電最佳化預測系統，並且希望其能適應未來的極端天氣情境，本文擬定的研究內容希望實現下列目的之流域多水庫多目標發電最佳化決策系統：

1. 較短的發電排程區間：較短的發電排程區間理應可以提升發電決策的反應速度並且使得決策更容易考量庫容量較小的水庫快速變動的水位與庫容量，也更容易反應天氣預報與入流量預測的結果。
2. 天氣預報的整合能力：要針對短期降雨事件進行反應，勢必要引入未來的天氣資訊，因此降雨預報的引入是必要的。

3. 最上游水庫入流量預測引入：如前所述降雨預報將可以直接反應未來流域的集水區水量可能的變化，然而以實際使用的情境來看依舊不夠直觀。因此本文預期將流域集水區的降雨預報與降雨觀測整合成最上游水庫的入流量預測系統，這將更加的直觀反應未來入流量的變化。
4. 最上游水庫入流量預測區間方法引入：進一步解決預測系統帶來的不確定性，透過區間大小量化不確定性對系統產生的風險，以解決時間拉長後的風險控管能力。
5. 找出流域水庫間決策的對未來水資源影響的因果關係（逕流模型）：要實現流域多水庫多目標發電最佳化系統勢必要具備各種發電決策對於水庫水資源變化的情境模擬能力。因此，一套描述所有水庫歷史放水量與下游進水量（入流量）因果性的模型需要被建立。該模型針對不同集水區的獨立特性進行專門設計，結合類神經網路的高非線性映射能力和時間序列分析的動態特性，能更準確地捕捉逕流變化規律。與傳統逕流模型相比，該方法在考量多變環境因素和區域特性時，具有更強的適應性和預測準確度，有助於提升流域水庫入流量估算的可靠性與精確性。
6. 定義發電效率與排洪風險評價指標：最佳化問題往往建立在所有的指標（成本函數）優化上面，而當希望優化的指標超過一個的情況下，問題則會變成多目標最佳化問題，這些問題的指標需要被明確的定義出來，以本文為例，怎樣的發電決策會反應出好的發電效率與較低的排洪風險，這些指標需要被明確的進行量化。因此本文提出兩個關於發電效率（未來 12 小時用水量呈現）與排洪風險評價指標（以未來 12 小時後整體流域水位分布為基準）作為成本函數使用，用以量化兩相衝突的目標以作為最佳化方法的參考依據，各個成本函數的功能分別表述如下：

最大化發電效率（最小的流域用水量）：水庫應以高水位運行以提高發電效率、並且在排洪發生時給予懲罰。

最小化排洪風險：避免因瞬間強降雨導致水庫溢流或排洪，減少災害發生的可能性。傳統方法通常僅針對最大化發電量或最小化發電用水，未充分考慮未來降雨的不確定性。因此設計的關於排洪風險的成本函數需引入歷史降雨量資料與預報降雨資料，整合降雨趨勢和其可能帶來的風險，使模型更加穩健和實用。

7. 流域多水庫多目標發電決策最佳化方法引入：有了評價指標、逕流模型之後，一套考量多目標最佳化的方法需要被引入，該方法應該能涵蓋各個評價指標的多樣性，同時應該要有能因應未來天氣情境的選擇能力，因為情境的多樣性，這些評價指標應隨著未來的天氣不同而有著不同的重要程度，這意味著兩個評價指標的權重應當是可以動態調節的，這也將提升方法的複雜度。

### 1.3 研究步驟

基於上述的研究動機與研究目的，本文擬定整體研究的預估研究步驟，呈現如下：

1. 最上游水庫預測系統建置：利用預測系統的建置呈現考量上游集水區的降雨量與預報對相連水庫的影響。
2. 預測區間的方法設計：入流量預測區間系統可以提升預測資料帶來的不確定性，然而入流量的變動量在大部分的情境下並不够多變，較難

以呈現預測區間方法的效果。因此本文透過風力發電作為基礎，提出一套基於覆蓋機率與區間大小兩相衝突的函數的預測區間產出方法。該方法可以應用在各種不同的領域，也可以與本文提出的最佳化方法進行整合。

3. 逕流模型的建立：要建立最佳化方法的最大前提，就是要可以正確描述所有的輸入對於最佳化場域的影響，以本文來說也就是逕流模型(描述水資源的變化)以及成本函數(描述決策的優劣)，因此本文提出一套透過類神經網路描述出歷史下游水庫入流量與相連上游水庫出水量的關係，藉以找出流域當中相連水庫出水量與入流量的相關性，並更進一步實現下一小時個水庫的入流量預測。
4. 建立多目標最佳化的成本函數指標：設計出分別以排洪風險與發電效率的成本函數指標作為評斷決策好壞的準則，該準則應該考量所有發電決策對未來時間的影響。
5. 多目標最佳化方法建置與實現：找出適合此命題的多目標最佳化方法並進行實驗，本文透過台灣中部大甲溪流域作為實驗場域。

研究步驟 1 將透過第三章提出的論文進行呈現、研究步驟 2 將透過第四章提出的論文進行呈現、研究步驟 3~5 將在第五章提出的論文的內容進行呈現。最後，透過這些研究做為基礎，實現本文的流域多水庫多目標發電最佳化預測系統建置。

## 1.4 研究架構

本文分為六個章節，各章內容分述如下：

- 第一章 緒論：敘述本文之研究背景及動機、研究目的、研究步驟與研究架構。
- 第二章 文獻探討與回顧：探討過去相關領域之文獻，涵蓋流域水庫最佳化方法與其對最上游水庫入流流量預測、預測性能對決策系統的影響、大氣降雨預報之重要性等相關資訊。
- 第三章 德基水庫入流量預測系統建置：建立最上游水庫預測系統，分析最上游水庫集水區降雨測站資料與入流量的相關性，建立一套 48 小時入流量預測系統。
- 第四章 區間預測方法的建置：提出一套預測區間的產出方法，並透過不確定性變化程度更大的風力發電作為實驗場域，以驗證方法的可靠性。
- 第五章 流域多目標發電規劃系統建立：建立流域水庫發電最佳化系統，該系統須能適應如台灣的海島型極端氣候，所做出發電決策須考量風險管理與發電效益之間的即時權衡。最終產出未來 24 小時發電決策系統。
- 第六章 結論與未來展望：總結本文提出的方法，並且提出未來能夠修正改進的方向。

## 第二章 文獻探討與回顧

### 2.1 水力預測背景回顧

水力發電是一種潔淨且永續的能源，相較於太陽能和風能等其他再生能源有著更高穩定性，同時有著快速起停與儲能的特性，使得其相較於其他再生能源不需要考量發電的不確定性對電網的衝擊，伴隨而來的是需要考量儲水量對發電效率的影響以及旱災、雨季對儲水資源儲量的衝擊。若能提前掌握水位變化趨勢，將對發電調度優化及水庫防洪減災產生顯著助益。為了解決這些問題已有許多水力發電調度的相關研究。[2]以經濟角度分析亞馬遜周邊流域的水流量對水庫增設營收的影響；[3]探討水庫調節用水對農業灌溉與洪水調節的利弊；[4]基於(Global Change Assessment Model, GCAM)型研究電力行業構成與投資成本的後續影響；[5]設計模擬系統評估氣候變化對電力系統運行與區域相依性的影響，並強調氣候對水力發電的重要性；[6]以加州為例，研究氣候變化下水力發電對高風能與太陽能容量電網整合能力的影響，並強調綠能裝置容量增長對電力系統的衝擊及提升水力容量的重要性；[7]考慮長期集成降雨預報和單週降雨預報，以評估未來一個月的每日流入預報，並規劃每日排放，以維持乾旱條件下下游生活用水量。[8]比較逕流模型中使用類神經網路與概念模型進行實際的資料可靠度分析，並指出類神經網路是概念模型重要的替代方法；[9]使用集流量預測物理模型(Ensemble Streamflow Prediction, ESP)物理模型與抽樣隨機動態規劃(Sampling Stochastic Dynamic Programming, SSDP)結合進行流量預測，雖能產生準確結果，但因預測間隔較長，並不適用於颱風頻繁地海島型氣候的台灣；[10]建立考量流量預測與能源價格的決策支援系統

(decision support system, DSS) , 用於考量電價與放水時機的決策制定；[11]提出基於混合支援向量機 (support vector machine, SVM) 與類神經網路 (artificial neural networks, ANN) 的每月入流量預測方法；[12]整合五種氣象預報模型 (GFDL-ESM2M、HadGEM2-ES、IPSL-CM5A-LR、MIROC-ESM-CHEM、NorESM1-M), 構建可變入滲容量 (variable infiltration capacity, VIC) 逕流模型預測系統並應用於中國南流江流域；[13]以及設計考量太陽能與風能等再生能源系統狀況的水力發電調度系統。這些研究充分展現水力發電與再生能源整合的重要性，並突出預測技術在調度優化與風險管理中的關鍵作用。

然而水力發電廠的發電量受到天氣和季節性水量影響劇烈。在全球氣候變遷日益加劇的背景下，強烈颱風和密集降雨現象變得愈加頻繁，要兼顧高效發電、防洪以及民生供水的多目標需求已逐漸成為一項更加困難的挑戰。目前水力發電廠的操作人員主要依據經驗法則來制定發電運行策略。若能提供未來幾天的水庫水位預測資訊，將大幅提升操作人員對水庫的管理能力，以增加其決策的正確性。由於水力發電機組具有快速啟停的靈活特性，可根據負載的瞬時變化即時調整供電量，因此在確保電力供應穩定和維持電力品質方面始終發揮著不可或缺的重要作用。

如果能在事前掌握水庫入流變化的趨勢，將能大幅提升電力調度的最佳化並減少水庫排洪量。現有文獻多利用預測方法進行未來入流量資訊的獲取，而預測模型的選用在現有研究中主要分為兩大類型：統計模型和數學模型。數學模型側重於考量所有已知物理參數對結果的影響，雖然能提供高精度的結果，但需耗費大量計算成本，且需要完整的物理模型參數數據。以物理逕流模型[14][15]為例，透過考量蒸發散、滲透以及土壤儲存量

等多項參數的數學模型，最終能夠帶來良好的模擬結果。然而對於上游流域眾多的水庫而言，不論是降雨資訊亦或是河川支流模型的建構等，要取得這些資訊並不容易。另一方面，統計方法則是透過大量資料找出其輸入與輸出間的相關性，並利用各種統計方法來尋找最佳的預測結果。在統計模型的訓練階段的過程中計算成本相對較高，但實際運行時所需的計算量相對較少。近年來統計模型中的神經網路在系統辨識方面扮演重要角色，主要原因在神經網路的特性著重在找出輸入與輸出的對應關係，並透過誤差等方法作為依據進行訓練，使其能在不需使用數學轉換函數的情況下找出輸入與輸出之間的關係，以完成複雜的非線性映射、關聯性分析、資料分類及知識處理。[16]設計一種適用於非線性動態系統的自適應模糊類神經控制器方法，並透過模擬結果展示該方法的可行性。[17]將模糊神經網路 (Fuzzy-Neural Network, FNN) 應用於中國浙江地區的短期降雨量預測，結果顯示模糊神經網路在降雨量預測方面具有良好的表現。[18]討論使用神經網路預測水力發電量時，訓練方法所帶來的影響，並針對神經網路的整體訓練流程提出多項優化建議。[19]建立一套自適應模糊神經網路系統，用於預測義大利 Guardialfiera 水庫的週入流量與月入流量。[20]利用神經網路進行未來入流量預測，結果證實在不使用氣象資料的情況下，依然能達到一定程度有效的入流量預測。[21][22]中將考慮歷史時序的類神經網路模型應用於水位放水決策，並取得可接受的結果。[23]研究可用於優化水力發電預測的神經網路架構。[24]則利用類神經網路及迴歸方法預測集水區的降雨量；[25]透過降雨預測來推估橫向河川的入流量；[26]採用觀測數據、天氣預測以及氣候指數進行河川流量的預測。這些方法對於入流量及降雨預測皆具有良好成效，但都尚未考量實際發電情境以及水力發電系統於日常運轉中每小時變化的趨勢。

## 2.2 氣象預報對水庫入流量預測之影響

在水庫入流量預測當中，以有許多現有的文獻指出數值氣象預報能顯著提升預測的準確度。對於數值氣象預報而言，現有方法通常採用以網格為基礎的集合預報，文獻中也已經存在許多相關的應用與改進方式 [27][28][29][30][31][32][33][34]。[27]使用第五代賓州州立大學/NCAR 中尺度模式 (MM5) 來模擬颱風路徑。[28]提出氣象研究與預報 (WRF) 模式，用於更精確掌握台灣的天氣系統，並分析 20 年的歷史資料來比較 WRF 與 MM5 模式的成效，同時校正預測模式。[29]則提出一項可應用於降雨預測系統的定量降水預報技術。[30][31]採用數值動力模式來分析台灣的氣候情況，並考量德基水庫集水區的地形與水文特性；同時利用克利金 (Kriging) 法 [32][33] 的空間統計理論，將數值動力模式所產生的網格降雨預報資料縮放至特定區域。[34] 中則提出一種颱風定量降雨預報模式，並依據集合預報系統中的颱風路徑來定義平均用水量，以產出全台的定量降雨預報。近年來隨著數值模式的發展腳步加快，WRF 模式的應用也日趨普及，並逐漸取代 MM5 模式 [35][36]；目前僅在部分研究中仍使用 MM5 進行數值模擬與分析。WRF 模式的設計理念在於將學術研究成果與使用者對即時預報的需求相結合，並能同時模擬理想大氣及真實大氣的變化。[37] 指出數值預報對降雨預測具有顯著幫助。這些文獻指出數值氣象遇到的演進過程中，精準度與尺度逐漸縮小與進步，這些有效的氣象預測數據將可以透過統計模型的方法進行整合，得到更加可靠的預測產出結果。

隨著降雨預報精準度與可靠度的提升，將降雨預報數值納入入流預測模型將對預測準確度產生極大助益，尤其在四季天氣變化劇烈的台灣更是如此。由於台灣為海島型氣候，降雨主要來源包括夏季西南季風所帶來的地形雨、冬季東北季風、夏季雷陣雨、夏秋兩季的颱風雨，以及春夏之間

的鋒面氣旋雨。台灣氣候大多受雨季影響，水庫水位常在雨季期間顯著上升，因此降雨預測在河川流量預測中扮演關鍵角色。[38][39]也研究在河川流量預測中引入氣候資料的影響。其中[38]使用 Mann-Kendall 非參數檢定法對河川流量進行分析；而[39]透過實驗證實導入氣象預報網格點資料以預測集水區流量的可行性。

在水力發電預測領域目前已有諸多研究。[40]建立一套以 10 天為時間尺度的平均入流量長期預測系統，但此預測間隔在降雨變化劇烈的季節，無法提供即時性較高的預測結果，因而在短期電力調度上可能受限。[41]設計一種考量土壤滲透量的地表逕流模式，結果顯示適用於預測入流量。[42]則提出利用上游水庫即時預測下游水庫水位的方法。[43]對於台灣蘭陽溪的一小時流量預測，分析並比較神經網路在流量預測上的表現。[44]針對小型水力渦輪機設計一套發電預測系統，並使用非梯度下降的權衡演算法作為神經網路的訓練規則。[45]則採用啟發式演算法訓練模糊神經網路進行水力發電量預測。現階段這些演算法在降雨及入流量預測方面皆有不錯的成效；然而它們尚未同時考量當地水力發電廠的各種條件。對水力發電廠來說，更關注的是受發電排程、農業灌溉、民生用水及洪水等因素影響的未來水位變化。因此若能開發同時考量電廠運作需求的水庫水位預測系統，將有助於電廠的運轉與調度，甚或成為電廠能源管理系統的基礎。

## 2.3 預測誤差與各種不確定性對流域水庫最佳化帶來的挑戰

前面提及水力預測對整體調度與水資源管理的重要性。然而，在傳統防洪管理等應用當中，儘管大部分運轉單位都是透過歷史數十年河川地降雨數據集等資訊去對未來的降雨或是地表逕流進行對應的預測，然而近年

的研究[46]指出，在日本實務的歷史數據中表明，儘管使用 100 年以上的數據資料集，隨著極端氣候頻繁，近年來不斷發生超過歷史最大降雨量的事件，這也造成整體預測的不確定性上升，因為這些極端資料並未出現在訓練資料集當中。並且[47]指出當水力調度實際應用當中若是忽略不確定性帶來的影響的話，多水庫發電規劃的效能往往會導致高估或是低估的結果。在實務上的應用當中，超過 1 天的預測系統往往需要仰賴氣象降雨預報做為參考依據。許多文獻[48][49][50][51]指出目前大部分的系統皆可透過引入數值氣象預報與入流量預測模型進行整合。然而數值氣象預報在實務上存在著很大的不確定性，包含邊界和初始條件以及水文模型參數等等[49][50][51]，同時降雨預報作為水文相關的預測系統的輸入是所有資料的最主要不確定性來源[51][52]。要進行應用之前應提出一套方法去量化其不確定性等相關資訊，其中預測區間是一種可以量化預測不確定性的方法之一。

## 2.4 預測區間與信賴區間

與物理預測模型相比物聯網（Internet of Things, IoT）的發展使得資料驅動式預測模型的應用日益增加，例如風力發電量預測、水庫入流量預測等等。在蒐集到大量數據後，人工智慧能夠利用這些龐大的數據來建立資料驅動式預測模型，並據此預測未來的結果或狀態。透過這些預測結果或狀態，決策者或程式設計者便能進一步做出後續判斷或決策。然而在建構資料驅動式預測模型時，前述各種不確定性不可避免地會影響預測結果的準確度。為了因應這些不確定性，必須將其納入預測過程中，以增進資料驅動式預測模型輸出結果的可靠性與可信度[53][54]。一般而言信賴區間與預測區間是常用於量化與評估預測不確定性指標的方法。信賴區間用來描

述未知但固定之數值的不確定性；而預測區間用於預估未來數值的變動不確定性，因此預測區間的定義通常比信賴區間更廣 [54][55][56]。 [53][54][57][58] 指出，不確定性的預測方法包括機率預測法、集合預測法、模型誤差統計法以及智慧學習法（如神經網路、模糊神經網路與模糊理論）。對於機率預測法與集合預測法而言，需要事先掌握輸入與輸出之間的資料分布信息；至於模型誤差統計法，則需對資料做出特定假設，因此其預測準確度常受到假設合理性的限制。智慧學習方法因其非線性建模及強大的學習能力而備受重視 [54][59][60][61][62][63]，例如 Delta 法、貝氏方法以及預測區間成本法等。其中 Delta 法透過對資料驅動模型進行參數線性化來建構預測區間；貝氏方法則藉由計算成本函式的海森矩陣（Hessian Matrix）來構造預測區間。Bootstrap 法是統計或機器學習領域中常見且有效的估計方法，也能輕鬆應用於建構預測區間。上述 Delta 法、貝氏方法與 Bootstrap 法，都著重於透過最小化預測誤差來訓練資料驅動模型的參數以獲得預測區間；例如可使用平方誤差的成本函式求得預測區間。預測區間成本法 [54][63][64][65][66] 則將「覆蓋率（Coverage Probability）」與「預測區間範圍（Prediction Interval Bound）」兩個不同的衡量指標整合進單一指標中，以評估預測結果並應用於誤差最小化訓練。覆蓋率考量的是輸出資料點落在預測區間內的比例，而預測區間範圍則考慮預測區間本身的寬度。這兩種指標之間存在相互衝突：若要提高覆蓋率，預測區間必須拉得更寬，但如此一來預測區間過寬又不利於使用者決策；相對地，若要求縮小預測區間，覆蓋率便可能降低，容易導致使用者誤判。因此資料驅動式預測模型在「覆蓋率」與「預測區間範圍」之間必須進行權衡。預測區間成本法的主要目的是同時優化這兩個衡量指標。工程領域常使用各種啟發式演算法來解決此類權衡問題，例如遺傳演算法（Genetic Algorithm, GA）、粒子群演算法（Particle Swarm Optimization, PSO）、類電磁演算法

(Electromagnetism-Like Algorithm, ELA)、細菌覓食演算法 (Bacterial Foraging Algorithm, BFA) 以及蝙蝠演算法 (Bat Algorithm, BA)。儘管預測區間成本法能夠在覆蓋率與預測區間範圍之間取得較佳的平衡，但目前較少討論在資料驅動模型預測區間範圍之內，觀測特徵與輸出分布所造成的影響。如何有效整合這些影響因素並將其納入預測區間成本法，再進而建構預測區間，仍是一個值得深入探討的議題。

## 2.5 流域水庫多目標最佳化問題

許多文獻將流域多水庫發電規劃視為一個多目標決策問題，其受到即時電價、發電限制及政府法規等因素影響。每座水庫需遵守嚴格約束條件，包括水力發電比、水位及防洪管理等。此複雜性使得水庫管理成為一項優化問題，促使各種解決方案的發展。啟發式演算法，特別是遺傳演算法，已被廣泛應用於多水庫水力發電決策的優化[67][68][69]。此外現有許多啟發式演算法應用於流域多水庫調度的研究。例如，粒子群演算法[70][71][72][73]、螞蟻演算法 (Ant Colony Optimisation, ACO) [74]、模擬退火演算法 (Simulated Annealing, SA) [75][76]、蝙蝠演算法 [77]、螢火蟲演算法 (Firefly Algorithm, FA)[78]等，皆已被應用於多水庫水力發電優化，並取得可靠的結果。然而這些水庫優化方法通常忽略因強降雨引起的水量驟升，這在實際應用中特別是島嶼氣候或降雨集中的國家中可能帶來一定程度風險。為應對此類挑戰，必須同時考慮防洪與水力發電決策，進一步將多水庫優化問題轉化為權衡問題。此外獲取防洪相關因素需要進一步探索氣候及因決策引起的水庫水位變化。為更深入理解未來短期降雨導致的流量變化趨勢，[79]比較遞迴式神經網路 (Recurrent Neural Network, RNN)、長短期神經網路 (Long Short-Term Memory, LSTM) 與雙向長短記憶網路

Bi-LSTM (Bi-directional Long Short-Term Memory) 等模型在流量預測中的表現。[80]基於氣象降雨預測使用 LSTM 分析台灣石門水庫上游降雨與入流的關係。這些研究找出天氣情境與水庫入流量的關係，提出有效解決方案。目前大多數研究分別著重於多水庫水力發電決策的優化或水庫流量預測，但鮮有文獻同時探討水庫流量預測與多水庫水力發電決策優化的關係。[81]將 GFS 氣象預報模式與啟發式演算法結合，應用於美國俄勒岡州底特律與彭薩科拉大壩 1 至 16 天的發電計畫預測。然而，目前大多數文獻使用的預測區間過長，無法有效應對島嶼氣候中典型的短期強降雨。例如，在台灣的大甲溪，僅 12 小時的強降雨就可能觸發洪水排放決策。基於日常的發電規劃可能不適用於像台灣這樣的島嶼氣候。此外大多數方法僅在排洪風險約束條件（如水位閾值）被超過時施加嚴重懲罰，而非主動減少流域內的水量以應對即將來臨的降雨事件。為了解決這些問題並適應島嶼氣候中常見的強降雨和頻繁颱風，必須同時考慮流域發電效率和排洪風險。因此，一個結合水庫入流預測和多目標優化的系統變得至關重要。這也是本文第五章的研究動機。

在現有文獻中[82][83][84]，防洪風險管理通常透過動態調整洪水限制水位 (Flood Limited Water Level, FLWL) 來實現。[82]中透過考量入流不確定性，動態調整水庫的 FLWL，以在防洪調度與下游防洪安全之間取得更佳的平衡並提升效率。[83]針對多水庫串聯 (混合) 系統，將聯合營運策略與動態 FLWL 控制方法同時納入考量。[84]則提出一種可行的動態 FLWL 實施方案，整合即時資訊與預測技術，以動態調整水庫可用的防洪容量，並提升防洪調控的效率與效能。在定義約束條件後，根據受限制的水位範圍來決定最佳發電策略。然而，如何定義動態 FLWL 本身即是一大難題：降低 FLWL 雖可提升水庫防洪能力，卻會降低發電效率；反之將

FLWL 設得較高則會增加排洪風險。此外水庫優化運作往往需要多步驟的前瞻規劃，進一步加深 FLWL 的設定難度。為了因應上述問題，本文提出了一種可量化排洪風險的成本函式，以簡化訂定動態 FLWL 的複雜性。此成本函式與發電效率結合後，可產出柏拉圖最佳解 (Pareto-Optimal Solutions)，將問題轉化為一個多準則決策 (Multi-Criteria Decision-Making, MCDM) 問題。本文所提方法結合模糊邏輯、預測不確定性、入流預測與專家知識，能自動選擇最適合當前水庫狀態及未來預估入流的調度決策。該方法在高風險情境下可限制總體水位，並在正常運行情況下維持高效的發電水位，無需進行動態 FLWL 的調整。在解決多重目標問題時，如本文所示，流域的水力發電決策通常同時追求最高的發電效率 (維持高水位) 與最小化排洪風險 (維持低水位或考量未來入流)，這使得問題成為一個彼此衝突的多目標優化 (Multi-Objective Optimisation, MOO) 問題。為了處理此類問題，可選擇將成本函式加以整合[85]，或透過求解多目標函式的 Pareto 解集合。最終結果會產生一組解集合，用於覆蓋各種偏好情境；其中部分解可能偏向某一特定成本函式，亦可能在所有成本函式之間取得平衡。此解集合代表所有潛在決策的完整範圍，若解在不同區域皆有均勻的分佈，則能提供更大的彈性。在短期流域水力發電規劃中，發電效率與排洪風險兩者的重要性通常會根據未來氣候情境、流域水源可用情況，以及調度中心所下達的發電指令而變化。由於這些因素的動態性與複雜性，僅透過數值成本函式難以直接完整反映效率與排洪風險兩者的重要性；因此，需要更全面的作法，整合更多氣候資料與水庫資源資訊，以輔助決策制定。

在工程預測的應用中，某些情境下使用者可能偏好更保守的預測結果；而在另一些情況下，他們則可能更注重預測精準度。預測區間能在使用者

自訂的條件下，提供較為可靠的預測。然而，定義預測區間本身即相當困難。人們通常希望在提高覆蓋率的同時，盡可能縮小預測區間範圍，使此議題演變為一個需進行權衡的優化問題。[86]提出一種可靠的平衡方法，用於同時優化覆蓋率與預測區間邊界，並考量資料驅動式預測模型於預測區間範圍內的觀測特徵與輸出分佈所帶來的影響。此方法將觀測特徵與輸出分佈的結果整合至傳統預測區間成本方法，進而構建出更為可靠的預測區間，部分滿足調度人員的客製化需求。本文進一步將預測區間導入模糊邏輯，用以調整多水庫水力發電決策的保守程度。

當一個決策問題同時包含多個目標（或準則）時，即形成 MCDM 問題。MCDM 已在許多領域獲得應用。例如，[87]將模糊層級分析法（Fuzzy Analytic Hierarchy Process, FAHP）與模糊層級理想解相似度順序偏好法（Fuzzy Technique for Order Preference by Similarity to Ideal Solution, Fuzzy TOPSIS）與財務比率結合，提出一種新型的績效評估模型；[88]透過問卷調查與 Fuzzy TOPSIS 方法，評估巴西 BRT 系統服務，並為管理者提供改進建議；[89]則設計一個三階段的模糊框架，以 Fuzzy TOPSIS 來探討中國中小型供應鏈內部因素對產品完成時間的影響；此外，[90]採用畢達哥拉斯模糊集（Pythagorean Fuzzy Sets），在專家意見與權重未知的情況下提出永續合作夥伴之遴選方案。在 MCDM 問題中，通常不存在所謂「唯一的最佳解」，而是被一組非支配解（Non-Dominated Solutions）所取代。對於任何非支配解而言，若要在某一準則上取得更好的結果，往往需要犧牲至少另一準則的績效。MCDM 問題通常涉及多位決策者，分別針對每一可行方案的各項準則給予評分，並為每個準則賦予權重以表示其重要性。最終會透過決策方法綜合各準則與權重，得到「最適解」或「最偏好解」。由於 MCDM 方法能整合多位專家意見並動態調整準則權重，決策系統因此

能納入更廣泛的資訊，從而選擇最恰當的解決方案。

模糊集能透過語意概念有效處理單一實體概念內的不確定性，在控制系統與機器學習領域均有廣泛的應用。模糊控制始於 Zadeh 教授於 1965 年提出的模糊集理論[91]。以「人口」為例，傳統邏輯方法採用集合論來整合概念，假設陳述能以二元方式來描述；相較之下，模糊邏輯理論則會為各種語意概念建立一個範圍，使其能表現出逐漸平滑的意義梯度。這種方式可有效處理個體內部語意 (Intra-Personal) 不確定性的問題。本文在決策推理與權重分配中運用模糊邏輯理論。在水力發電效率與排洪風險這兩項因素中，它們的重要性會隨著未來天氣條件與水庫資源狀態的變動而有顯著差異。MCDM 方法特別適合納入「權重因子」的概念。因此，本文的第五章利用模糊邏輯將上游水庫入流預測引入決策過程，藉此動態調整這兩項因素的權重。



## 第三章 德基水庫入流量預測系統建置

本章節設計一套 48 小時入流量、水位預測方法，該方法使用水庫歷史入流量、集水區歷史時雨量與集水區降雨預報。資料時間區間選擇則透過找出集水區降雨量與入流量的時間與空間相關性分析後，選擇合理的歷史時間區間與入流量預報結果作為輸入，最終實現未來 48 小時最上游水庫入流量預測系統建置。

### 3.1 簡介

台灣的德基水庫全年提供水力發電、灌溉用水、民生用水以及防洪功能。近年來由於氣候變遷的影響，極端天氣事件下的防洪需求越來越頻繁。在台灣每年 5 月至 6 月的梅雨季節或 7 月至 9 月的颱風季，在此期間內往往在短時間內就能累積大量雨量；再加上台灣地形陡峭、河川流速快，使得降雨對水位的反應極為迅速。倘若沒有一套水庫水位預測系統，當颱風來襲時，隨著水位開始快速上漲而水力發電機組已全負載運轉時，可能依然無法因應瞬間暴增的入流量，進而導致多達數 GWh 的發電量損失。

為了提升水庫管理效率，本章節針對台灣的德基水庫提出一套利用模糊神經網路的水庫水位預測系統。該系統可進行 48 小時預測，整合數值氣象降雨預報特性，分析主要上游流域內降雨預報與實際降雨對入流量的相關性與延遲效果，並同時考量電廠區域內即時排洪以及發電及用水需求之間的互動關係。

此模糊神經網路採用三階段架構：

1. 第一階段（觀測資料前處理）：估算德基水庫的即時入流量，考慮水力發電機組的電水比（Power to Water Ratio）與排洪量，將現有數據透過神經網路轉換成出水量，並以水位的變化推估流量變化，最後透過這些流量變化以推估水庫的即時入流情況。
2. 第二階段（結合數值氣象預報與模糊神經網路的水庫入流量預測）：預測未來 48 小時的水庫入流量，綜合上游集水區實測降雨與數值預報降雨對未來入流的影響，以及目前的入流估算值，以取得 48 小時的入流預測結果。
3. 第三階段（透過入流量預測、排洪發電規劃，模擬出未來 48 小時水位預測系統）：輸出德基水庫水位。透過前述入流量預測與機組排程、排洪規劃，最終得到德基水庫的水位預測。

本章節的架構說明如下，第二節說明德基水庫的背景知識；第三節研究方法與預測機制；第四節詳細闡述資料分析、模擬結果及討論；第五節則給出最終研究總結。

## 3.2 台灣德基水庫介紹：

水庫水位變化主要受到集水區的降雨（影響河川入流量）、水力發電機組的發電量以及德基水庫的排洪量（水庫出水量）影響。本文設計一個 1 至 48 小時逐時水位預測系統，該系統基於德基水庫的相關水文觀測數據和氣象預測數據來進行預測。接下來將依序介紹以下內容：首先介紹德基水庫的背景；接著介紹德基水庫附近的降雨觀測站；最後解釋影響德基水

庫入流量的因素。

德基水庫位於台中市和平區，是大甲溪的最上游水庫。大甲溪源自中央山脈，全長 140 公里，從源頭到入海口，流域內雨量豐沛，並且上游河川眾多，同時集水區面積達 592 平方公里，是目前台灣水資源最豐富的河流。此外，大甲溪中上游的河床陡峭，德基水庫以下至石岡的距離約 702 公里，海拔高度落差達 1000 公尺，具有非常大水力發電潛能。

台灣擁有豐富的降雨量、陡峭的河流坡度和充沛的水資源。水力發電曾是第二次世界大戰後台灣發電的主要來源，隨著時代變遷，目前水力發電的數量已經減少至 11 座。台灣的理論水能資源包括 76 條河流，如淡水河；然而由於自然條件的限制，只有 30 條河流被選作技術可行的水能資源調查對象。評估結果顯示 76 條河流的理論水能儲量為 1173 萬度電，電能為 1027.3 億度電。相比之下 30 條主要河流的技術可行水能資源為 504 萬度電，電能為 201.5 億度電[92]。截至 2004 年底，台灣完成的傳統水力發電廠總裝置容量為 208.93 萬千瓦（2089.3MW），年發電量約為 4447.5 萬度電（4.44753 TWh）。大甲溪發電廠德基分廠位於德基大壩左岸，地下 210 公尺處，長 77 公尺，寬 33 公尺，高 17.5 公尺，配備有法蘭西斯水輪機。該廠設有 3 個發電機組，設計水頭為 143.1 公尺，最大水量為每秒 72.5 立方米（CMS），單機容量為 78,000 千瓦（78MW），3 台機組總容量為 234,000 千瓦（234MW），為台灣第二大水力發電廠，年平均發電能力為 3.7 億度電。德基水庫的主要設施包括大壩、排洪控制設備、排洪隧道、引水隧道、地下發電廠以及志樂溪引水隧道。大壩建於德基峽谷，海拔高度為大甲溪河床上方 1230 公尺，是一座雙曲薄拱大壩。德基水庫的入流量主要受到上游流域降雨、水庫的發電量和排洪量的影響。與上游流域相關的降雨觀測

站位置如圖 3-1 所示。每條上游河流的降雨量會通過上游河流的地形及河流與水庫之間的距離影響德基水庫的入流量。由於河流的流速，上游的降雨量會對水庫入流量產生時間延遲效應。為了確定降雨觀測值與水庫入流量變化之間的時間延遲，本文使用皮爾森積動差相關係數(Pearson Product-Moment Correlation)來找出最相關的延遲時間點。接下來將進行詳細說明。

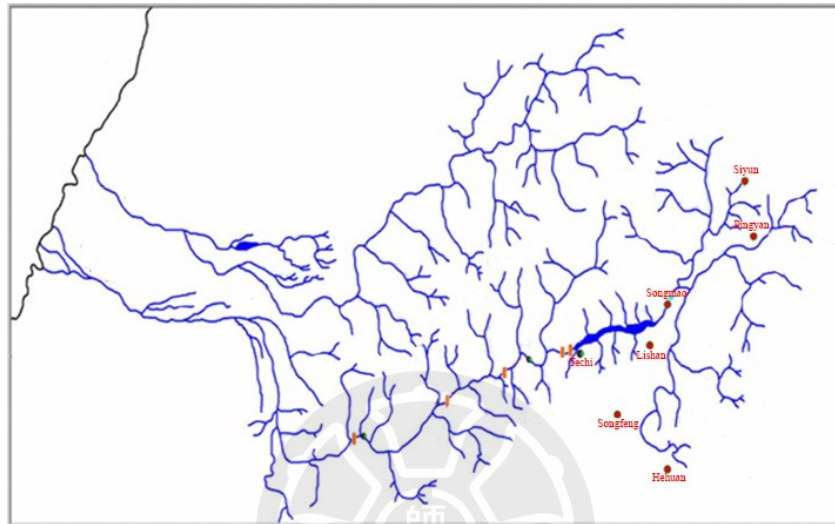


圖 3-1 德基水庫及上游降雨觀測站的位置  
(資料來源：[93])

德基水庫的入流量主要來自大甲溪，考慮到大甲溪流域在 4 月至 9 月期間的降雨量約占全年降雨量的 80%，而 10 月至翌年 3 月的乾季降雨量僅占約 20%。隨著全球氣候變遷的加劇，突如其來的暴雨變得更加頻繁。為了提高預測準確度，本文的預測系統考慮雨量水文資料與預報資料。水文資料包括德基水庫及其上游集水區的 7 個降雨觀測站(德基水庫、思源、平岩、松茂、梨山、松峰和合歡)，即時數據包括德基水庫 3 個水力發電機組的發電量和德基水庫的排洪資訊。降雨預報資料則使用台灣颱風與洪水研究中心提供的 1 至 78 小時逐小時降雨預報數據，來自德基水庫及其上游集水區的 7 個降雨觀測站。

### 3.3 研究方法與預測機制

近年來，類神經網路在智能預測模型的系統識別領域中扮演著非常重要的角色。類神經網路具有優異的學習能力，能夠輕鬆地找出系統輸入與輸出之間的關係，並建立實際系統的模型，如物理動態系統、非線性系統和數據驅動系統。類神經網路還具備並行計算能力，能提供快速的計算功能，並且可以即時完成多個模型的預測。

#### 3.3.1 研究方法

類神經網路是一種模擬大腦神經元結構的數學模型。類神經網路利用大量數據來獲得輸入和輸出數據之間的關係。在學習過程中我們不需要提供對應的數學函數。這一特徵非常適合應用於具有不同屬性變化的輸入的預測系統中。

在科學研究中，模糊理論提供一個邏輯系統來處理人類邏輯推理過程，並可用於設計智能系統來分析語義或描述性語言。模糊系統架構主要包括四個組成部分模糊化（Fuzzification）、模糊規則庫（Rule Base）、推論引擎（Inference Engine）以及解模糊化（Defuzzification）。模糊邏輯系統的應用包括控制系統、圖形識別、語音識別、診斷程序、時間序列預測、智能機器人、決策系統等領域。

模糊神經網路架構[16][94][95]，[16]介紹許多模糊類神經網路的架構與範例。[94]提出一種在非線性結構未知的情況下，針對非仿射非線性系統的基於觀測器的直接自適應模糊神經控制方案。在[95]中介紹多種模糊

神經網路的架構與應用範例。模糊神經網路是一種具有模糊架構的神經網路，容易模擬實際系統的輸入和輸出關係，從而建立實際系統的模型特徵，並且具有易於整合專家知識（模糊理論）和提高學習效率的特點。模糊邏輯系統的架構通常包括模糊化、模糊規則庫（IF-THEN 規則）、模糊推論引擎以及解模糊化等組成元件。模糊化負責將清晰的輸入轉換為對應的模糊值；解模糊化則將推論後的模糊集合轉換為具體的數值輸出。模糊推論引擎根據模糊的 IF-THEN 規則，將輸入語言變數對應至輸出語言變數，完成整體的模糊推理過程。假設一個模糊系統，其模糊的 IF-THEN 規則可表示如下：

$$R^{(i)} : \text{if } x_1 \text{ is } A_1^i \text{ and } \dots \text{ and } x_n \text{ is } A_n^i, \text{ then } y_1 \text{ is } B_1^i \text{ and } \dots \text{ and } y_m \text{ is } B_m^i \quad (3-1)$$

其中  $A_1^i, A_2^i, \dots, A_n^i$  和  $B_1^i, B_2^i, \dots, B_m^i$  是模糊集合， $x^T = [x_1, x_2, \dots, x_n] \in \mathfrak{R}^n$  是輸入向量， $y^T = [y_1, y_2, \dots, y_m] \in \mathfrak{R}^m$  是輸出向量。假設  $z$  為模糊的 IF-THEN 規則數量。通過使用乘積推理、重心法和單值模糊化，模糊邏輯系統的第  $k$  個輸出可以表示為式(3-2)與(3-3)：

$$y_k(\mathbf{x}) = \frac{\sum_{i=1}^z \bar{y}_k^i \left( \prod_{j=1}^n \mu_{A_j^i}(x_j) \right)}{\sum_{i=1}^z \left( \prod_{j=1}^n \mu_{A_j^i}(x_j) \right)} \quad (3-2)$$

$$= \theta_k^T \boldsymbol{\varphi}(\mathbf{x}) \quad (3-3)$$

其中  $\mu_{A_j^i}(x_j)$  為模糊變數  $x_j$  的歸屬函數， $\bar{y}_k^i$  是當  $\mu_{B^i}(\bar{y}_k^i) = 1$  時的一個點，

$\theta_k^T = [\bar{y}_k^1, \bar{y}_k^2, \dots, \bar{y}_k^z]$  為權重向量並且  $\phi^T = [\phi^1, \phi^2, \dots, \phi^z]$  為一個模糊向量，

$\phi^i$  被定義如式(3-4)：

$$\phi^i(\mathbf{x}) = \frac{\left( \prod_{j=1}^n \mu_{A_j^i}(x_j) \right)}{\sum_{i=1}^z \left( \prod_{j=1}^n \mu_{A_j^i}(x_j) \right)} \quad (3-4)$$

模糊邏輯系統式(3-3)可以通過神經網路來實現[16]。圖 3-2 顯示模糊神經網路的配置，該網絡有四層。第一層的節點代表輸入向量  $\mathbf{x}^T = [x_1, x_2, \dots, x_n]$ ，第二層的節點表示所有語言變數的歸屬函數值，第三層的節點是模糊基向量  $\phi$  的值。第三層和第四層之間是透過  $\phi^T = [\phi^1, \phi^2, \dots, \phi^z]$  進行完全連結，第四層的節點為輸出向量  $\mathbf{y}^T = [y_1, y_2, \dots, y_m]$ 。




圖 3-2 模糊類神經網路架構圖

因此，本文使用模糊神經網路架構，將氣象降雨數據、降雨觀測數據、水位和發電量整合，以預測水庫的入流量和水位，其中歸屬函數選擇為高

斯函數。

### 3.3.2 三階段模糊神經網路預測機制

傳統的預測機制通常只使用歷史數據來預測未來的數值。例如利用水位歷史數據、降雨觀測站數據、發電量和排洪量來預測德基水庫未來 1 至 48 小時的水位變化。然而隨著預測時間的延長，其預測精度會逐漸降低。如果能有效整合氣象降雨數據，長期預測的準確度將得到改善。此外過多的特徵輸入會增加神經網路的模型複雜性和學習難度。因此本文提出一種三階段模糊神經網路的預測機制，如圖 3-3 所示。該預測機制的模糊神經網路採用三階段架構。其中第一階段通過即時水位值、水力發電機組發電量和水庫排洪量作為輸入，生成水庫即時流量的估測。透過即時的廠區運轉用水、兩個時間區間的水位變化所推算的水量差異與當前的排洪量資訊進行彙總求出即時的入流量推估結果。其中，利用當前水位與電水比曲線可以得知當前發電量與入流量的關係，水量的差異可以透過兩個時間區間的水位差異與水位容積曲線推估而成，最後納入排洪排程的排水量，從而得出即時入流量（出水量）。有了即時入流的估測資訊後，在此基礎上，第二階段使用歷史集水區觀測降雨數據和氣象降雨數據，預測未來 48 小時的水庫入流量。最後第三階段則將推估的入流量與機組排程、排洪排程整合，從而轉換成 48 小時的水位預測結果。對於本文中的德基水庫，第二階段神經網路的輸入包括過去 9 小時入流量數據、7 個集水區降雨觀測站過去 6 小時的降雨數據，以及未來 3 小時的 7 個氣象降雨站的降雨數據。這些輸入考慮從德基流域到水庫的降雨延時效應。

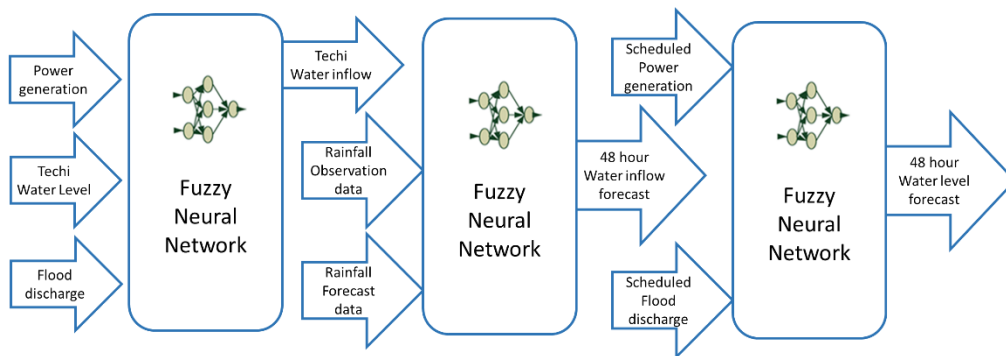


圖 3-3 入流量、水位三階段預測架構

### 3.4 結果與討論

本章節將會探討所有輸入資料的選用原因與最終的預測結果，其章節內容分別為資料分析、水位容積曲線與電水比曲線近似方法實現與集水區內水庫水位與實驗結果幾個章節。資料分析用以證實集水區降雨量與水位變化的相關性，為入流量的選用提供分析驗證。水位容積曲線與電水比曲線近似方法實現則透過實際場域使用的水位容積曲線、電水比曲線，這些曲線透過神經網路近似後呈現的曲線進行比較，最終呈現近似後的結果。集水區內水庫水位與氣象降雨資料的相關性分析章節則負責驗證實際收到的降雨量預報與水位變化的相關性，以驗證選用的輸入資料的有效程度。最後透過幾個於 2013 與 2014 年於中部大甲溪流域教具有代表性的颱風來進行入流量預測的驗證，以證明系統的有效性。

#### 3.4.1 資料分析：水位、入流量與降雨量的關係

為了找出集水區降雨觀測站與德基水庫水位之間的時間延遲，本文使用皮爾森積動差相關係數，如式(3-5)與(3-6)所示。

$$S_{xy} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{n-1} \quad (3-5)$$

$$r_{xy} = \frac{S_{xy}}{S_x S_y} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2} \sqrt{\sum(y_i - \bar{y})^2}} \quad (3-6)$$

其中  $S_{xy}$  表示  $x_i$  與  $y_i$  兩組輸入資料集的共變異數， $r_{xy}$  為兩個輸入資料集的相關係數，該係數用來描述兩個輸入之間的相關性。本文使用 2013 年 4 月到 9 月期間，7 個降雨觀測站的總降雨量與德基水庫水位觀測值如圖 3-4 所示。根據皮爾森積動差相關係數，計算得出不同延遲時間下，水位與 7 個降雨觀測站總降雨量之間的相關性，如圖 3-5 所示。從圖中可以看出，在約六小時的延遲時間下有著最高的相關係數。換句話說，當觀測降雨發生時，約需要六小時左右，7 個降雨觀測站的總降雨量才會對德基水庫的入流量產生最明顯的影響，這將作為輸入資料選用區間的參考依據。

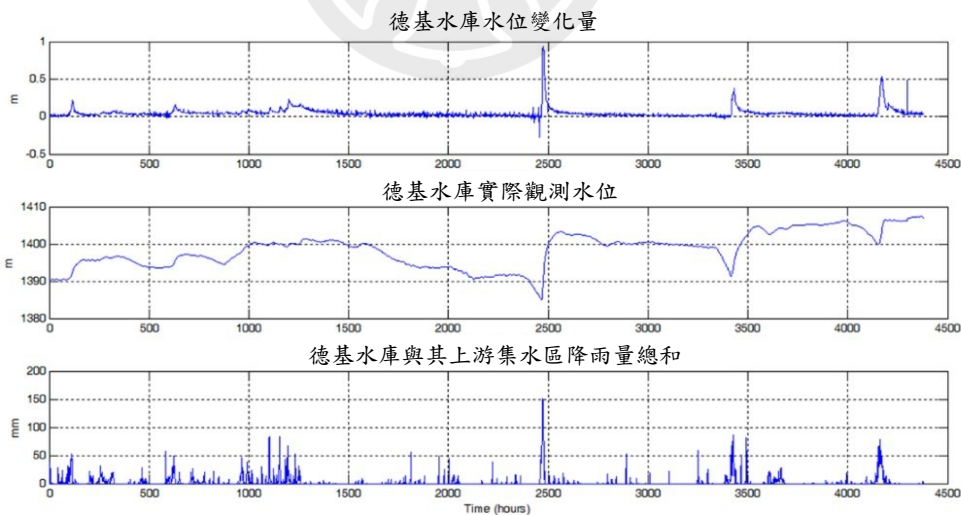


圖 3-4 德基水庫的水位變化與七個上游集水區雨量觀測站變化趨勢圖




圖 3-5 德基水庫集水區雨量觀測站加總與水位變化在不同延遲時間下的相關性趨勢圖

由圖 3-5 分析完雨量觀測站與水位變化的相關性後，由此可證降雨量的觀測結果與水位的變化量具有高度的相關性，為此，本文選用雨量資料作為預測模型的輸入，然而光使用觀測資料並無法反映出更長時間的未來資訊。為此，接下來將針對氣象預報格點資料進行可靠性的分析。因此分析 2013 年 4 月至 9 月現有格點雨量與實際雨量站的相關係數如表 3-1，從表中可看出每一個觀測站最高的相關係數約落在 0.4 左右，是可以接受的相關程度。最終透過德基水庫的變化量與氣象格點降雨預報加總於 2013 年之相關係數結果如圖 3-6 所示，從圖 3-6 可看出相關係數最高點的延遲時間依舊落在 6 小時左右，而峰值約落在 0.35 左右。

表 3-1 2013 年 4 月至 9 月 TAPEX 集水區氣象即時雨量預報資料與集水區雨量站資料相關係數

	德基	梨山	松茂	合歡山	松峰	思源	平岩山
武陵	0.230	0.266	0.244	0.213	0.264	0.263	0.269
合歡山站	0.394	0.358	0.397	0.412	0.398	0.195	0.327
梨山	0.401	0.368	0.403	0.450	0.422	0.408	0.400
大禹嶺	0.368	0.340	0.375	0.396	0.379	0.356	0.377
德基	0.458	0.415	0.437	0.465	0.449	0.315	0.418

德基水庫水位變化量與氣象預報雨量觀測站格點加總相關性分析

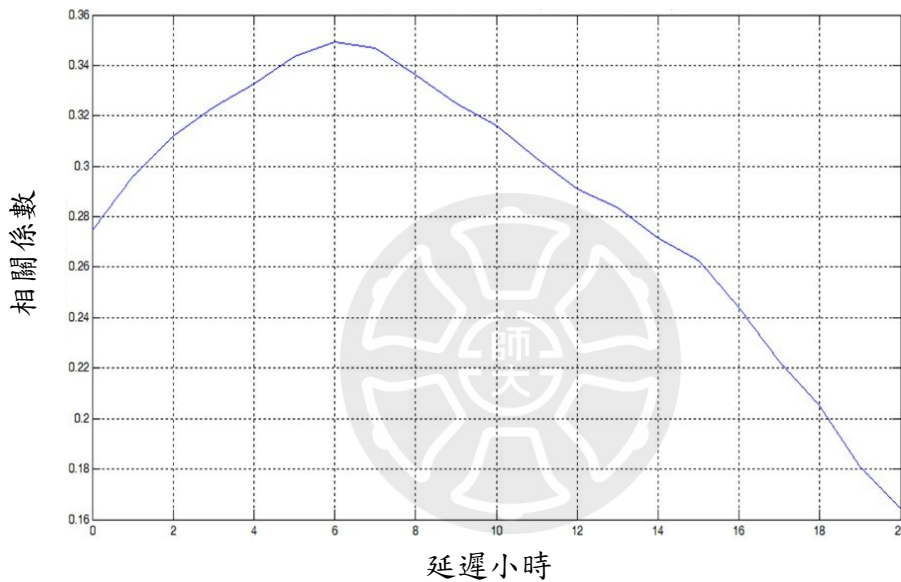


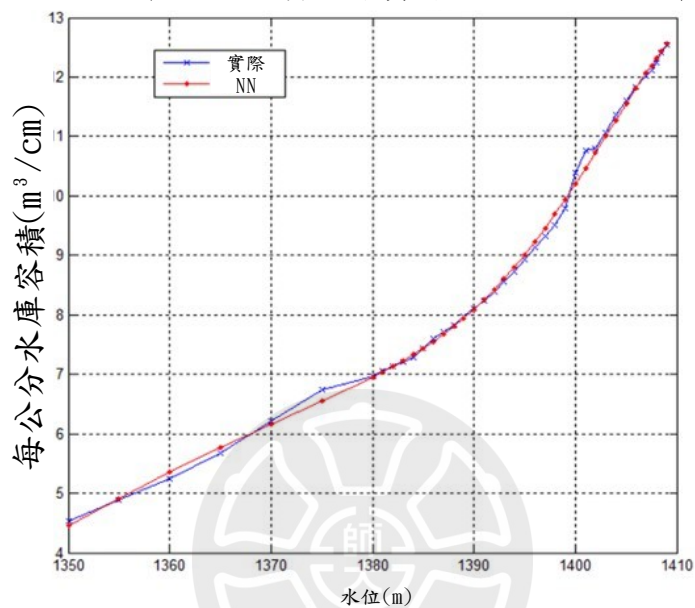
圖 3-6 德基水庫集水區氣象預報於雨量觀測站格點位置之雨量加總與水位變化在不同延遲時間下的相關性趨勢圖

### 3.4.2 水位容積曲線與電水比曲線近似方法實現

水庫的水位主要受水庫入流量、水力發電機組的用水量以及水庫的排水量影響。影響水位變化的因素已在前一節中介紹。其中水位容積曲線與電水比曲線可以透過神經網路進行訓練，其近似結果如圖 3-7 所示。發電


與排洪計劃是事先安排的，因此可以提前得知接下來兩天的排程。在了解水庫入流量與水位容積的關係以及電水比曲線後，就可以獲得水庫入流量、發電量與水位之間的關係。

德基水庫水位容積曲線實際與近似水位分布圖



(a)

德基水庫機組電水比實際與近似分布圖



(b)

圖 3-7 (a)水位容積曲線近似與(b)電廠電水比曲線近似

### 3.4.3 集水區內水庫水位與氣象降雨資料的相關性分析

許多研究都指出，再生能源的預測更容易受到天氣變化的影響 [7][96][97]。其中 [96] 中介紹台灣目前主要使用的 WRF 模式在降雨預測上的發展現況。[97] 則整合多種氣象資料，並能對瞬時入流量作出良好反應，突顯降雨預測對流量預測的重要性。而水庫的入流量受到降雨的影響，經過前述分析已知上游雨量測站的降雨資料與水庫入流量有高度相關性，若能將氣象降雨資料納入預測系統，將能顯著提升預測準確度。為了取得德基水庫集水區的氣象降雨資料，本文與 TTFRI 合作。自 2010 年起，TTFRI 中心便著手發展與執行台灣合作性降水集合預報實驗 (TAPEX) 的經驗。此外為了考量德基水庫集水區的地質與水文特性，TTFRI 中心利用空間統計理論中的克利金 (Kriging) 方法 [35][36]，將數值模式所產生的網格化降雨資料轉換為大甲溪流域七個雨量測站的氣象降雨資料。這 7 個氣象雨量站包含德基水庫、松茂、思源、梨山、松峰、合歡山及平岩山。TTFRI 所提供的氣象降雨資料每 6 小時更新一次，並可提供各雨量測站未來 1 小時至 78 小時的逐時累積降雨預報資料。

根據水庫集水區的氣象降雨預報數據和實際值，利用平均絕對誤差 (Mean Absolute Error, MAE) 和均方根誤差 (Root Mean Square Error, RMSE) 進行誤差分析，如式 (3-7) 和 (3-8) 所示，這些方法通常用於評估預測的準確性。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (3-7)$$

$$\text{RMSE} = \frac{1}{n} \sum_{i=1}^n \sqrt{(f_i - y_i)^2} \quad (3-8)$$

其中， $f_i$  與  $y_i$  分別表示第  $i$  筆數據的預測結果與實際值、 $n$  表示數據集的總數。

氣象降雨數據與德基降雨觀測站的誤差分析如圖 3-8 所示，其誤差也在一定可接受範圍內。此氣象降雨數據應能為長期預測水位提供重要的參考依據。

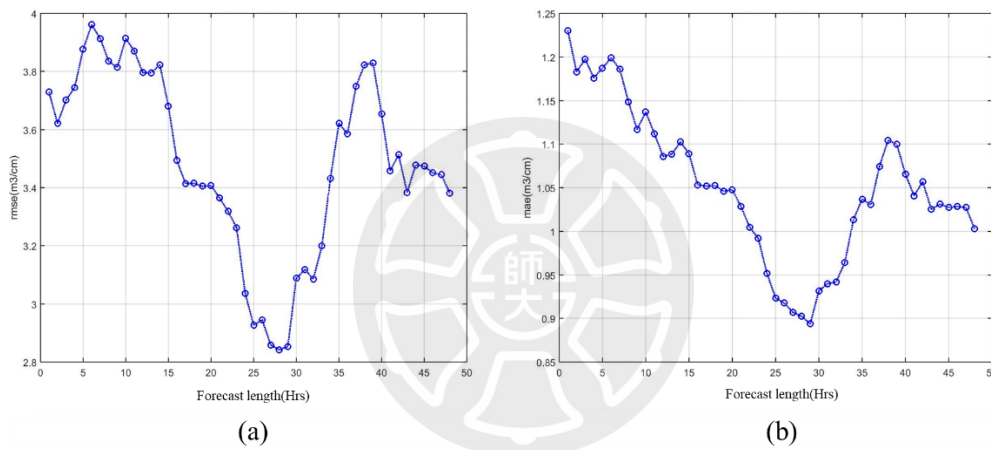


圖 3-8 德基水庫雨量觀測與預報誤差分析(a) RMSE 與(b) MAE

### 3.4.4 實驗結果

假設僅考慮德基水庫的歷史水位變化，並利用神經網路預測德基水庫 6 小時的水位變化。神經網路以 2012 年 1 月 1 日至 2013 年 6 月 30 日的德基水庫水位測量數據進行訓練，並使用 2013 年 10 月 1 日至 2013 年 12 月 30 日的德基水庫水位測量數據作為測試數據。該神經網路包含 5 個輸入層神經元、7 個隱藏層神經元以及 1 個輸出層神經元，輸入為 5 項（4 項歷史

水位數據與 1 項水位差值數據)，輸出為下一小時的預測水位值。訓練方法採用梯度下降演算法，訓練數據的學習結果及測試數據的預測結果如圖 3-9 所示。透過 MSE 計算方法如式(3-9)，其訓練結果的 MSE 為 0.0324，測試結果的 MSE 如表 3-2 所示。

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2 \quad (3-9)$$

表 3-2 預測誤差 MSE

Lead-Time (hour)	t + 1	t + 2	t + 3	t + 4	t + 5	t + 6
MSE	0.0437	0.0558	0.0825	0.1229	0.1724	0.2078

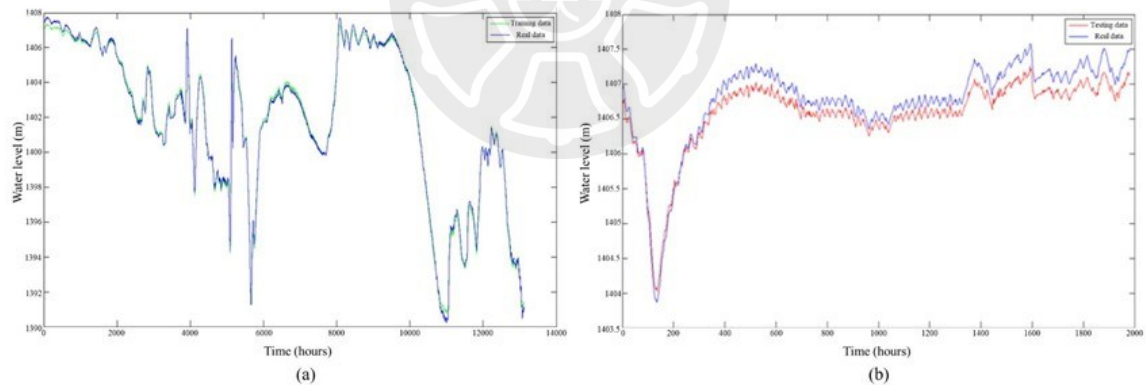


圖 3-9 水位預測結果 (a)訓練資料與(b)測試資料

本文以 MATLAB 作為開發平台，利用模糊神經網路開發一個可預測 48 小時水庫水位變化的系統。該系統的目的為預測未來逐小時入流量與水位變化的 48 小時趨勢，並於每小時更新預測結果。系統會自動每小時檢索水力發電機組的發電量、德基水庫水位、七個雨量觀測站的數據以及 TAPEX 氣象數據以進行水位預測。最後，為了驗證預測結果的有效性，本

文以 2013 年至 2014 年間台灣的颱風作為實驗測試數據。颱風數據來自台灣中央氣象局 (CWB) 的颱風資料庫[98]，如表 3-3 所示，包含過去颱風登陸時間及相關訊息。

對於表 3-3 中的潭美 (Trami)、康芮 (Kongrey)、天兔 (Usagi) 和麥德姆 (Matmo) 颱風，德基水庫的水位與入流預測結果分別如圖 3-10 至圖 3-17 所示。在圖 3-11 至 3-18 中，藍線表示觀測值，紅線表示預測值。從中可以看出預測值與實際未來值呈現出相似的趨勢。以驗證其預測結果的有效性。

表 3-3 2013 至 2014 年已登台的颱風列表

颱風名稱	登陸時間	颱風強度	最大風速 (m/s)
麥德姆	21 July至23 July 2014	中颱	38
哈吉貝	14 June至15 June 2014	輕颱	20
菲特	4 October至7 October 2013	中颱	38
天兔	19 September至 22 September 2013	強颱	55
康芮	27 August至27 August 2013	輕颱	25
潭美	20 August至22 August 2013	輕颱	30
西馬隆	17 July至18 July 2013	輕颱	18

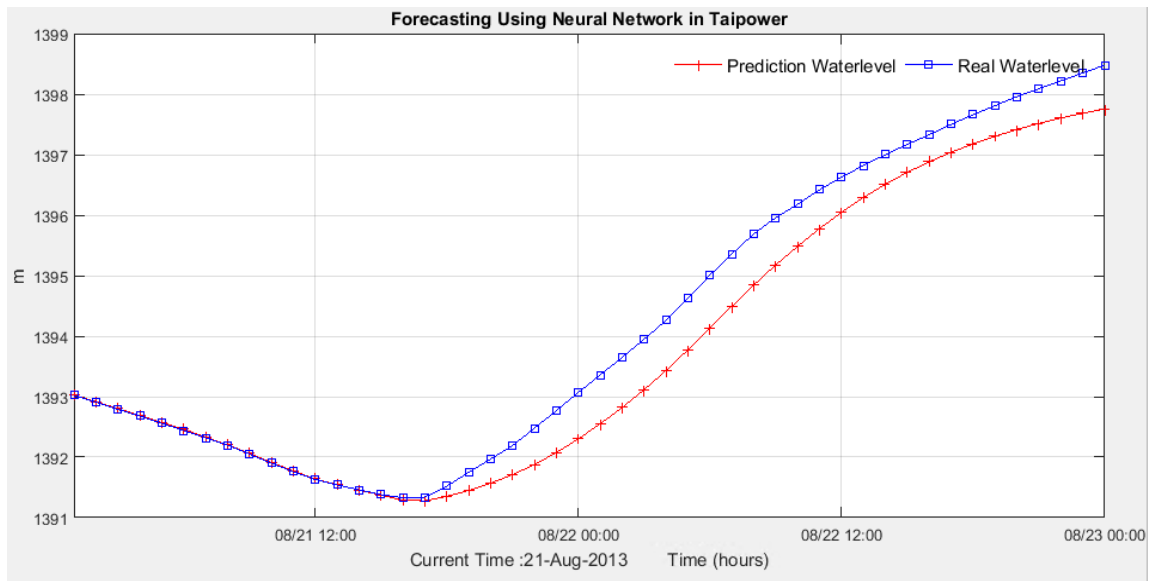


圖 3-10 2013 年 8 月 21 號 0 點水位預測結果 (潭美颱風期間)




圖 3-11 2013 年 8 月 21 號 0 點入流量預測結果 (潭美颱風期間)




圖 3-12 2013 年 8 月 28 號 6 點水位預測結果 (康芮颱風期間)

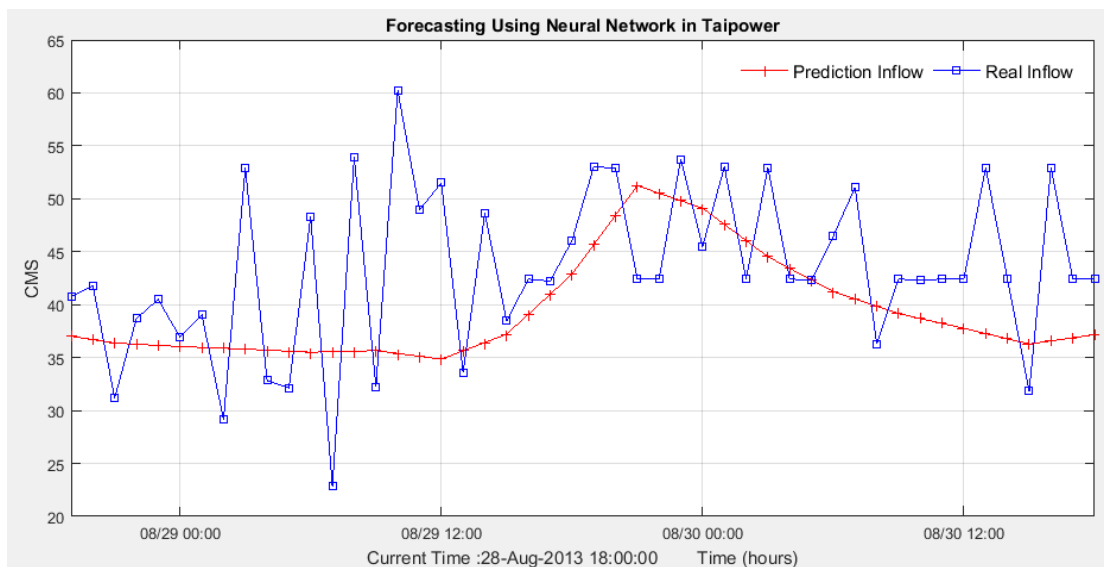


圖 3-13 2013 年 8 月 28 號 6 點入流量預測結果 (康芮颱風期間)

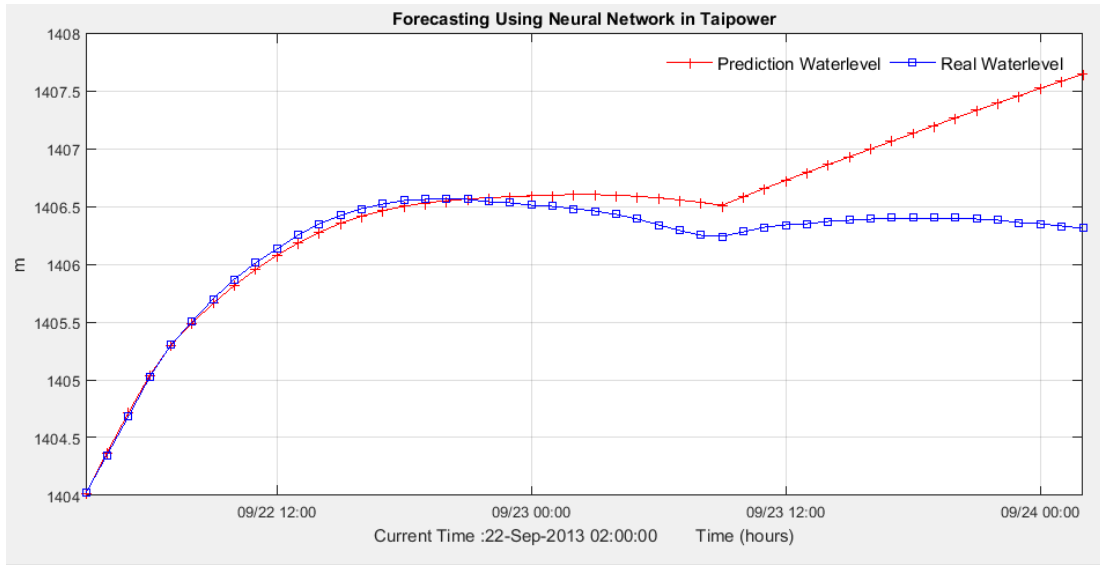


圖 3-14 2013 年 9 月 22 號 2 點水位預測結果 (天兔颱風期間)




圖 3-15 2013 年 9 月 22 號 2 點入流量預測結果 (天兔颱風期間)




圖 3-16 2014 年 7 月 22 號 0 點水位預測結果 (麥德姆颱風期間)




圖 3-17 2014 年 7 月 22 號 0 點入流量預測結果 (麥德姆颱風期間)

透過分析 2012 年和 2013 年德基水庫入流量的 48 小時預測結果之 MAE 如圖 3-18 和圖 3-19 所示，從圖中可以看出，隨著預測提前時間的增加，預測精度逐漸下降，且在降雨量突然變化時會出現較大的誤差。部分原因是氣象降雨數據的準確性影響，另一部分原因則是訓練數據中降雨驟變事件所佔比例較小，這會影響颱風登陸期間的預測準確性。

由於雨季期間水庫水位變化顯著，本文選擇水庫入流量大於 100CMS 的事件進行預測表現的準確性評估。2012 年與 2013 年的 RMSE 和 MAE 結果分別如圖 3-20 和圖 3-21 所示。圖 3-20 顯示，2012 年前 24 小時的 RMSE 值約為 160CMS；圖 3-21 顯示，2013 年前 24 小時的 RMSE 值約為 120CMS。

整體而言，設計的模糊神經網路模型能夠取得良好的水位預測結果。然而在颱風或暴雨期間，水庫入流量可能比平常高出數百倍，水庫水位可能上升數十公尺。此外在水位預測中，預測的水庫入流量誤差值會隨著 1 至 48 小時的預測累積，導致 48 小時後的預測水位誤差較大。

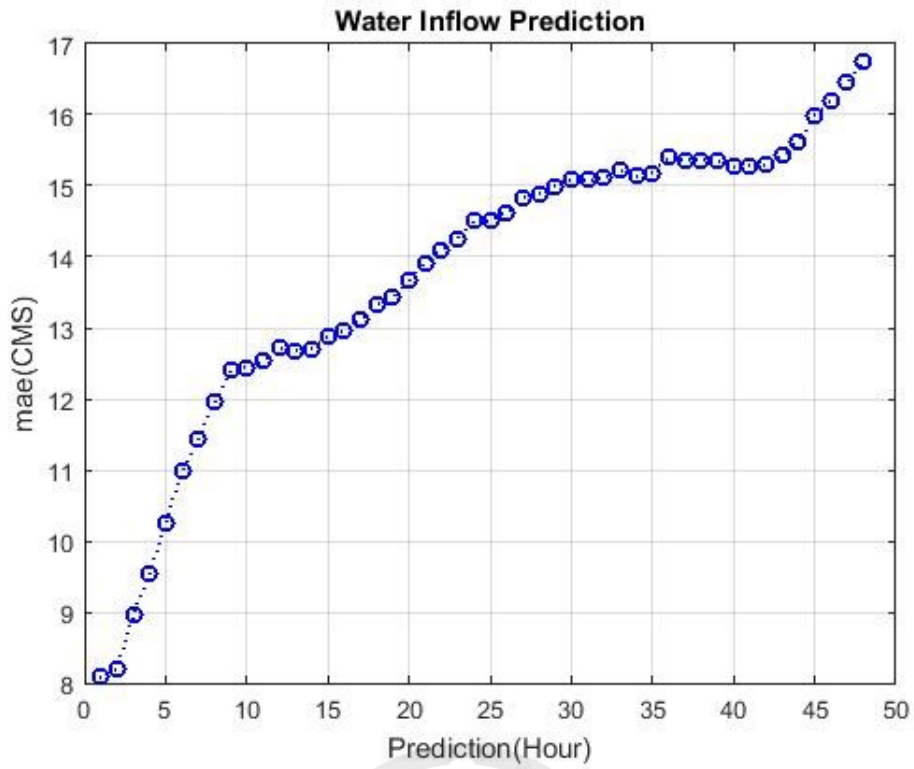


圖 3-18 2012 年入流量預測誤差分析結果




圖 3-19 2013 年入流量預測誤差分析結果

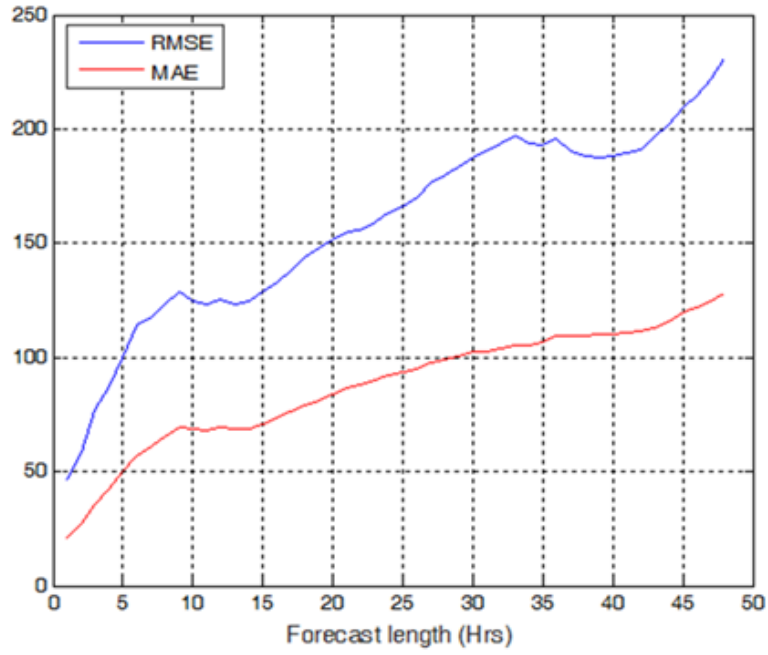


圖 3-20 2012 年入流量預測誤差分析 (當觀測入流量大於 100CMS 時)

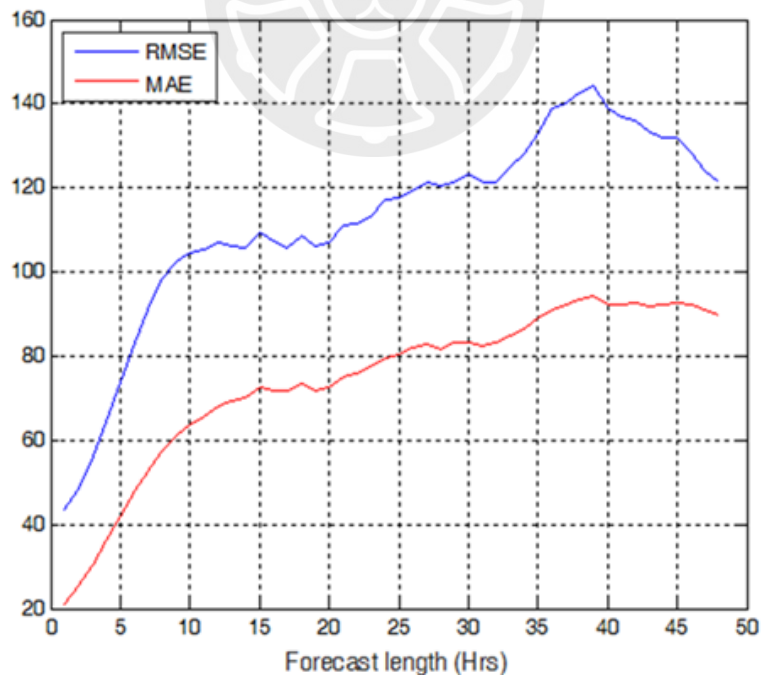


圖 3-21 2013 年入流量預測誤差分析 (當觀測入流量大於 100CMS 時)

為了說明水庫水位預測與水力發電之間的關係，本文以颱風麥德姆期間的模擬分析為例，假設在 2014 年 7 月 23 日颱風來襲時，初始水位為 1400 公尺，並評估水位預測系統對水力發電的影響。假設在無預測系統的情況下，調度員通常會在 2014 年 7 月 23 日凌晨 0 點水位出現大幅變化時才開始以滿載運行水力發電機組。而在有預測系統的情況下，調度員可於颱風前一日觀察到預測水位趨勢，並根據系統結果即時啟動水力發電機組以滿載運行。結果如圖 3-22 與圖 3-23 所示。如果調度員在颱風來襲時才啟動機組滿載運行，水庫水位將升至滿水位，必須進行排洪，這將導致大量的能源損失。若能提前 24 小時啟動滿載運行，則水庫可避免排洪。

接著本文詳細分析調度員在不同時間啟動水力發電運行時可能造成的發電損失。在 2014 年 7 月 22 日生成的預測結果顯示，水庫水位將在 33 小時內達到滿水位。在水庫初始水位較高且遭遇突發暴雨的情況下，調度員於不同時間點啟動機組滿載運行，分析水位變化。在此過程中，記錄水位達到最高點 1408 公尺時的排洪量，並根據電水比曲線計算水力機組的累計發電損失。結果如圖 3-25 所示，顯示若未提前 24 小時啟動滿載運行，將因排洪導致顯著的發電損失。從圖 3-24 可見，發電損失相當驚人，這也突顯出水位預測對調度員運行水力機組的重要性。




圖 3-22 預測系統引入對水資源的影響（水位趨勢）




圖 3-23 預測系統引入對水資源的影響（發電趨勢）




圖 3-24 每小時預先滿載發電對排洪水資源損失影響（發電量計算）

### 3.4.5 討論

降雨對集水區入流量的影響可以從物理逕流模型[14][15][41]和統計模型[17][25][45]中觀察到。集水區上游的降雨會導致德基水庫水位上升的事實已廣為人知。為了找出降雨對於德基水庫入流量影響的延遲時間，分析降雨觀測站與水庫水位的相關性。如圖 3-6 所示由觀測資料顯示出水庫入流量的最大相關性出現在 4 小時，而預測數據的顯著影響大約在 6 小時。此外圖 3-4 也反映降雨站對水位變化趨勢的影響。圖 3-6 顯示神經網路學習的水電比曲線與實際曲線相似，水位容量曲線也有良好的學習結果。

根據[17][18][20][25][26]的研究成果可知，降雨預測對於水庫水位及入流量具有關鍵作用。為了進一步探究此議題，本文分析預測降雨資料與實際水位變化間的相關性。而從圖 3-9 可以看出，雖然降雨預測的準確度在可接受範圍內，但仍存在進步空間。並且再進一步分析預報資料時，發現有時候預測數據並未反映出真實的降雨趨勢。

接著本文進行一個颱風案例研究。調度員通常依賴經驗來安排水力發電機組的運行。為了展現所提方法的有效性，我們模擬颱風麥德姆的入流情況，並結合水電比曲線將水力發電的用水量納入水庫中。此外為突顯排洪導致的巨大發電損失，我們假設颱風來臨前的初始水位為 1400 公尺，模擬如果調度員能提前啟動水力發電機組滿載運行，將大幅減少因排洪而造成的發電損失，一次颱風的發電損失可能高達 7GWh，這是相當可觀的能源損失。

最後考慮到台灣島嶼氣候的特性，降雨季節集中在 5 月至 9 月，期間水庫入流量經常發生劇烈變化。根據[2][3][5]可以了解極端降雨對水資源的影響。顯然直接使用 RMSE 和 MAE 來評估全年水庫入流量和水位並不客觀。因此本文選擇 2013 至 2014 年間的代表性颱風作為實驗數據，旨在探討水位預測系統在強降雨情況下能否即時反映未來水位趨勢。從圖 3-11 至圖 3-18 可看出，當發生極端降雨時，預測系統能夠良好地跟隨水位變化。此外，針對入流量超過 100 CMS 的特殊情況分析，如圖 3-11 和圖 3-22 所示，該預測系統在特殊案例和降雨事件中均能提供良好的預測結果。

### 3.5 總結

台灣擁有豐富的水資源，其中德基水庫是大甲溪流的最上游水庫。德基分廠的大甲溪發電廠的運行對於整個大甲溪流域的發電及下游供水至關重要，其重要性不言而喻。因此針對德基水庫，本文基於氣象降雨信息及集水區降雨觀測站的數據，結合水庫水位、排洪及發電等因素，開發一個模糊神經網路 48 小時預測系統，能夠預測水庫水位 1 至 48 小時內的每小時變化。

本文的主要目的是協助水力發電廠操作員利用水庫未來水位的動態信息，更有效率地調度水力發電機組，以增加發電量。如果將所提的水位預測系統整合至水力發電廠的能源管理系統，水力發電、灌溉用水、市政供水及防洪管理等目標可以更有效地達成，實現能源的最佳利用。在颱風來襲前，實際的水庫入流量分析也證明所提出的預測系統具有一定的前瞻性預測能力，能在近海颱風警報發布時，提前預測水庫入流及水位變化。因此，操作員可參考水庫水位動態變化的即時信息來進行管理。不僅能保

留庫容以應對洪水、削減洪峰、穩定供應各類下游用水需求，還可以調整水庫水位來提高發電量，增加發電收入。

模型訓練中最重要的部分是，訓練數據應涵蓋當地氣候特性的全範圍，特別是針對強降雨區域，這對於成功的水位預測系統能迅速應對劇烈水位變化至關重要。為了增強水位預測系統的有效性，除了擴大上游降雨觀測站的覆蓋範圍外，氣象數據的準確性也非常重要。由於大多數氣象數據來自鄰近城市地區的調校觀測，這往往因地形、氣候等多種因素，難以反映山區的準確降雨值。在這種情況下，若能利用上游流域的降雨觀測站對氣象數據進行校正，則可顯著提升水位預測的準確性。



## 第四章 預測區間系統建立

第三章解釋預測系統對水庫調度的重要性，以及天氣對水資源變化的不確定性。儘管預測系統在第三章的實驗結果中表現良好，但因為預測系統中存在許多的不確定性，例如觀測降雨的誤差不確定性、定量降雨預報於短時間的不確定性等等，而其中又以降雨預報的不確定性為最大，為了解決這些問題，量化這些不確定性使得系統可以將不確定性的概念引入，一個可靠的預測區間產出方法需要被建立出來。

由於預測資訊始終會存在一定程度的不確定性，然而這些不確定性在單一預測值的時候並無法得到準確地描述。也因此對應的系統若要使用該預測資料的時候並不容易引入其預測誤差帶來的不確定性。為了解決上述問題，本文提出一套基於覆蓋範圍、預測區間大小與輸出集中度為基礎的預測區間產出方法，並將其與不同的演算法進行搭配，以呈現出本文提出方法的有效性[99]。為了強調本文提出方法的有效性，本文以短時間變化劇烈的風力發電數據做為輸入，使得方法應對不確定性的能力得到更明確的呈現。

### 4.1 簡介與相關文獻回顧

2025 年，全球風力發電總裝置容量已超過 1136GW，預計 2026 至 2030 年每年將再增加 138GW、140GW、160GW、183GW、194GW[100]。風力發電通常是一種間歇性且具時間變化性的能源，無法提供穩定電源。若在

未預估可能發電量的情況下就直接將電力併入電網，容易導致電力系統不穩定，增加電力調度難度並提高運營投資與成本。透過進行風力發電量預測，能在一定程度上改善這些問題。一般而言，根據輸出的預測形式不同，風力發電量預測可分為單點預測[101][102]與區間預測[63][103][104][105]。在[101]中，研究者使用線上監控與資料採集系統（SCADA）及數值天氣預報（NWP）所產生的帶有不確定性的數據，提出一種基於第二型模糊神經網路（Type-2 Fuzzy Neural Network）與粒子群演算法的智慧風力發電量預測方法。[102]中則提出十二種不同的混合深度學習智慧聚類模型，用於風速與風力發電量的預測。[63][103]採用上下界估計法（Lower Upper Bound Estimation, LUBE）來預測風速。[104]提出一種混合方法，將單點預測與風力發電的機率性預測結合使用。[105]則提出一種加權方法，系統性地整合自回歸滑動平均模型（ARMA）、類神經網路及灰色預測模型（GM）的預測值，並以統計方法求得預測值附近的區間範圍。整體來看，單點預測雖具有一定程度的可靠性，但若考量風力發電在時間上的劇烈變化與不穩定性，僅依賴單點預測仍顯不足。除了風力發電本身的時間變動特性之外，影響單點預測準確度的因素還包括輸入資料的不確定性、模型本身的不確定性、參數設定的不確定性，以及來自人為與自然因素的不確定性[53][106]。因此為了同時兼顧這些不確定性，區間預測在風力發電與水庫入流量預測中顯得必不可少。

因此本文提出一種全新的預測區間建構方法，能同時考量多步預測需求，並避免受限於資料分佈、龐大運算或複雜運算的限制。為了驗證此方法的有效性，本文以使用具有劇烈變化的風力發電區間預測作為示範案例，由於並針對模型的輸出誤差特性進行分析。所提出的方法融合智慧型相關技術，例如神經網路與啟發式優化流程等，具體而言，本文針對資料驅動

式預測模型中的預測區間問題，開發智慧型預測區間技術，並進一步進行相關分析與評估。此外為了證明該方法的可行性與有效性，本文選用反向傳播神經網路（Back-Propagation Neural Network, BPNN）與模糊神經網路作為資料驅動式預測模型的架構，並透過類電磁演算法與細菌覓食演算法來優化模型。本文同時也提供一些比較結果，闡明所提方法的優點與潛在應用價值。

以下條列出本文的主要貢獻條列如下：

1. 與僅考慮覆蓋率與預測區間範圍折衷的預測區間相關文獻相比，本文提出一個同時納入「輸出集中度（Output Concentration）」、「覆蓋率（Coverage Probability）」及「預測區間範圍（Prediction Interval Bound）」三項指標的優化程序。
2. 本文選取金門風機數據作為預測模型的輸入資料，取樣時段為每年 10 月至 12 月，期間冬季季風風速變化劇烈。模擬結果顯示，相較於傳統成本函式，所提出的方法在維持相似覆蓋率的同時，能獲得更佳的預測區間範圍。

本章節的架構說明如下，第二節說明「基於集中度中心的預測區間」之優化程序；第三節詳細闡述資料分析、模擬結果及討論；第四節則給出最終研究總結。

## 4.2 基於重心的預測區間優化程序

預測區間的估計主要提供未來值的上限和下限，如圖 4-1 所示[53]。模型输出的上限預測區間與下限預測區間可能不相等，而上限與下限預測區

間值的總和即為預測區間。對於線性數據驅動模型[53]，假設輸出誤差均值為零、標準差為 $\sigma$ 的高斯分佈。為建立 $100(1-\alpha)$ 的預測限制，模型輸出的上限預測值 $y^U$ 和下限預測值 $y^L$ 分別如式(4-1)和(4-2)所示。

$$y^U = y + Z_{\alpha/2}\sigma \quad (4-1)$$

$$y^L = y - Z_{\alpha/2}\sigma \quad (4-2)$$

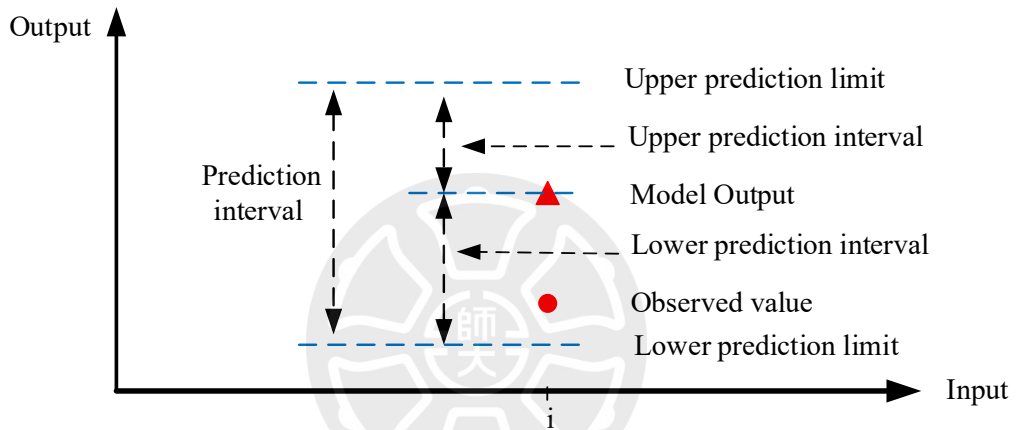


圖 4-1 預測區間的上限與下限示意圖

根據式(4-1)與(4-2)，由於上、下預測區間相等，因此標準差 $\sigma$ 等於均方誤差 (MSE)，通常稱為預測均方誤差[107]。然而事實上標準差 $\sigma$ 是未知的，必須從數據中估算。因此標準差被修正為式(4-3)。

$$\sigma_{est}^2 = \frac{\sum_{k=1}^n y_k - \hat{y}_k}{n - p} \quad (4-3)$$

當  $p$  為模型參數數量時若  $\sigma_{est}^2$  不是常數，則式(4-3)變得更加複雜[108]。因此計算該值實際上並不容易，特別是對於多變數或非線性模型。對於非線性數據驅動的預測模型[54][60][64]，其數學函數可表示為式 (4-4)：

$$y_i = f(X_i, \theta^*) + \xi_i, i = 1, 2, \dots, n \quad (4-4)$$

其中  $X_i$  是具有  $m$  維的輸入向量， $\theta^*$  是具有  $p$  維的最佳參數向量， $\xi_i$  被假設為獨立且同分佈的  $N(0, \sigma^2)$ 。假設  $y_i$  與  $\theta^*$  的估計值分別為  $\hat{y}_i$  與  $\hat{\theta}_i$ ，則忽略的高階項的泰勒展開式為式(4-5)至(4-7)：

$$\hat{y}_i = c_0 + c_1 \times (\theta - \theta^*), i = 1, 2, \dots, n \quad (4-5)$$

$$c_0 = f(X_i, \theta^*) \quad (4-6)$$

$$c_1 = \left[ \frac{\partial f(X_i, \theta^*)}{\partial \theta_1} \quad \frac{\partial f(X_i, \theta^*)}{\partial \theta_2} \quad \dots \quad \frac{\partial f(X_i, \theta^*)}{\partial \theta_p} \right] \quad (4-7)$$

將式(4-4)線性化後，可建立  $100(1-\alpha)\%$  的預測界限。模型輸出的上限與下限分別如式(4-8)與(4-9)所示：

$$y_i^U = \hat{y}_i + t_{n-p}^{1-\alpha} s \sqrt{1 + c_1 (CC')^{-1} c_1^T} \quad (4-8)$$

$$y_i^L = \hat{y}_i - t_{n-p}^{1-\alpha} s \sqrt{1 + c_1 (CC')^{-1} c_1^T} \quad (4-9)$$

其中  $s$  為標準差估計值， $t_{n-p}^{1-\alpha}$  為  $t$  分佈的值， $C$  為雅可比矩陣 (Jacobian Matrix) 的參數。從上述內容中可以看出，計算多變量或非線性模型的預測區間，除了需要考慮數據分佈約束之外，大量的計算與計算困難也成為一個問題。在[54][59][60][61][62][63]中，智慧學習模型（如類神經網路）因其非線性建模能力和強大的學習能力而備受推崇。如果智慧學習模型採用 Delta、貝葉斯等方法來建立預測模型，可以獲得具有最佳預測誤差的模型。然而對預測區間覆蓋概率 (PICP) 和預測區間邊界 (PIB) 的優化卻被忽略，PICP[53][54]表示如式(4-10)所示。

$$\text{PICP} = \sum_{k=1}^n \frac{m_k}{n} \quad (4-10)$$

其中

$$m_k = \begin{cases} 1 & \text{if } y_k^L \leq y_k \leq y_k^U \\ 0 & \text{otherwise} \end{cases} \quad (4-11)$$

並且  $n$  為資料總數，平均預測區間邊界 (MPIB) 表示為式(4-12)，或以標準化方式表示為式(4-13)[53][54]：

$$\text{MPIB} = \sum_{k=1}^n \frac{(y_k^U - y_k^L)}{n} \quad (4-12)$$

$$\text{NMPIB} = \sum_{k=1}^n \frac{(y_k^U - y_k^L)}{(n \times (y_{\max} - y_{\min}))} \quad (4-13)$$

其中  $y_{\max}$  和  $y_{\min}$  分別代表數據輸出的最大值和最小值。兩個衡量指標為 MPIB 和 PICP。PICP 考慮輸出點在預測區間內的比例，而 MPIB 考慮輸出點的範圍。如式(4-10)與(4-12)所示，這兩個指標相互矛盾。若 PICP 較高，則 MPIB 需更寬；但當 MPIB 較寬時，預測結果會使使用者的決策更為困難。因此確定預測區間的範圍成為一個權衡問題。預測區間成本方法的主要目的是優化 MPIB 和 PICP 兩個衡量指標。預測區間成本方法[54][103]通過式(4-14)中的目標函數與約束條件優化預測模型，以建立預測區間。

Objective function :

$$\begin{cases} \max \text{ PICP} \\ \min \text{ MPIB} \end{cases}$$

Constraint conditions :

$$\begin{cases} 0 \leq \text{PICP} \leq 1 \\ 0 \leq \text{MPIB} \end{cases}$$

(4-14)

雖然預測區間成本方法優化預測區間的 MPIB 和 PICP，但對數據驅動預測模型中觀測特性及輸出分佈在預測區間內的影響討論較少。因此，本文提出一種新成本函數，將輸出集中度、MPIB 和 PICP 納入考量。考慮輸出集中度的主要原因是，若能將觀測分佈納入成本函數以調整預測區間，應能獲得更優的預測區間。

### 4.2.1 基於重心的成本函數設計

首先，利用式(4-10)與(4-12)分別計算 PICP 和 MPIB 的值。接著在數據驅動預測模型的學習過程中，使用觀測輸出與預測區間中心點，計算觀測輸出集中值的中心與預測區間中心點之間的距離。最後將集中中心距離 (CC，定義在式(4-21)) 納入成本函數，並結合 CC、PICP 和 MPIB，形成基於集中中心距離的成本函數，用以評估數據驅動預測模型的學習效果。因此可形成優化問題如式(4-15)與(4-16)所示。

$$\begin{aligned} & \text{Objective function :} \\ & \{ \min J(\text{PICP}, \text{MPIB}, \text{CC}) \\ & \text{Constrant conditions :} \end{aligned} \tag{4-15}$$
$$\begin{cases} 0 \leq \text{PICP} \leq 1 \\ 0 \leq \text{MPIB} \end{cases}$$

$$J(\text{PICP}, \text{MPIB}, \text{CC}) = W_{\text{PICP}} \times e^{-\text{PICP}} + W_{\text{MPIB}} \times \text{MPIB} + W_{\text{CC}} \times \text{CC} \tag{4-16}$$

其中  $W_{\text{PICP}}$ 、 $W_{\text{MPIB}}$  和  $W_{\text{CC}}$  為權重。為了解決式(4-15)與(4-16)中的優化問題，本文採用類電磁機制和細菌覓食啟發式算法來優化權衡指標。

### 4.2.2 啟發式演算法

以下簡要說明類電磁演算法和細菌覓食演算法的主要原理。

類電磁演算法[109]主要由四個部分組成：初始化、局部搜索、總力計算和移動。這四個部分解釋如下。

步驟 1: 初始化隨機生成  $m$  組維度為  $n$  的粒子，然後計算每組粒子的目標

函數  $f(x)$ ，接著找到最佳粒子組將其定義為  $x^{best}$ 。

步驟 2: 局部搜索當前最佳粒子組附近的區域，嘗試找到更好的目標函數值以成為新的  $x^{best}$ 。假設搜索空間範圍為  $\mathbf{D} = [-d, d]$ ，其中  $d > 0$ ，則新的粒子組  $y^i$  如式(4-17)所示：

$$y^i = \begin{cases} x^i + \alpha\gamma^\beta(d - x^i), & \text{if } \varepsilon > 0.5 \\ x^i - \alpha\gamma^\beta(x^i + d), & \text{if } \varepsilon \leq 0.5 \end{cases} \quad (4-17)$$

其中  $\alpha$  為設計參數、 $\beta$  為常數、 $\gamma$  和  $\varepsilon$  是區間  $[0,1]$  的隨機值。如果新粒子組的目標函數值  $f(y^i)$  優於  $f(x^i)$ ，則接受新粒子組替換舊粒子組。如果經過多次迭代後仍無法找到更好的新粒子組，則終止搜索。可將  $\alpha$  設計為粒子收斂的函數以提高收斂效率。

步驟 3: 利用電磁理論的概念計算粒子組的帶電荷，最終所得合力計算如式(4-18)所示：

$$q^i = \exp \left( -n \frac{f(x^i) - f(x^{best})}{\sum_{k=1}^m (f(x^k) - f(x^{best}))} \right) \quad (4-18)$$

由式(4-18)可知，目標函數較佳者具有較高的帶電荷。粒子組之間的交互作用力，從而獲得粒子組合力，如式(4-19)所示：

$$F^i = \begin{cases} \sum_{j \neq i}^m (x^j - x^i) \frac{q^i q^j}{\|x^j - x^i\|^2} & \text{if } f(x^j) < f(x^i) \\ \sum_{j \neq i}^m (x^i - x^j) \frac{q^i q^j}{\|x^j - x^i\|^2} & \text{if } f(x^j) \geq f(x^i) \end{cases} \quad (4-19)$$

由式(4-19)可知目標函數數值較佳的粒子群會吸引目標函數數值較差的粒子群，而最佳目標函數粒子群  $x^{\text{best}}$  始終吸引所有其他粒子群。

步驟 4：移動基於合力的方向，其移動幅度為隨機值  $\rho > 0$  並限制在允許的搜索空間內。移動方法如式(4-20)所示：

$$x^i = x^i + \rho \frac{F^i}{\|F^i\|} \quad (4-20)$$

細菌覓食演算法模擬大腸桿菌通過游動和翻滾的運動。基本上細菌搜索演算法由四個主要結構組成，包括趨化、群集、繁殖以及消除-分散。以下是這些過程的簡要描述[110][111][112][113]。

步驟 1. 趨化：大腸桿菌有兩種生物運動方式。第一種是沿相同方向游動一段時間；第二種是隨機翻滾。此外大腸桿菌的運動可以在這兩種方式之間交替進行。

步驟 2. 群集：大腸桿菌在半固體的營養培養基中可以形成穩定的群體。當它們被置於含有單一營養化學誘因的半固體基質中時，通過誘導劑，細菌可以聚集成群，並以高細菌密度的形式群體移動。

步驟 3. 繁殖：每個健康的大腸桿菌可以在原地分裂成兩個，而不健康的細菌會死亡。

步驟 4. 消除-分散：環境中突然或漸進的變化（如溫度）會影響大腸桿菌的生存。因此一群大腸桿菌可能會被殺死或分散到另一個新位置。

### 4.2.3 研究架構

本文的整體設計架構如圖 4-2 所示。預測區間估計神經網路在每次學習過程中生成預測區間。根據預測區間可以計算集中中心距離(CC 距離)、PICP 和 MPIB，然後生成成本函數值。啟發式算法根據成本函數值調整神經網路的參數，以生成新的預測區間。經過多次上述學習過程後，可以生成一個優化的預測區間估計神經網路。

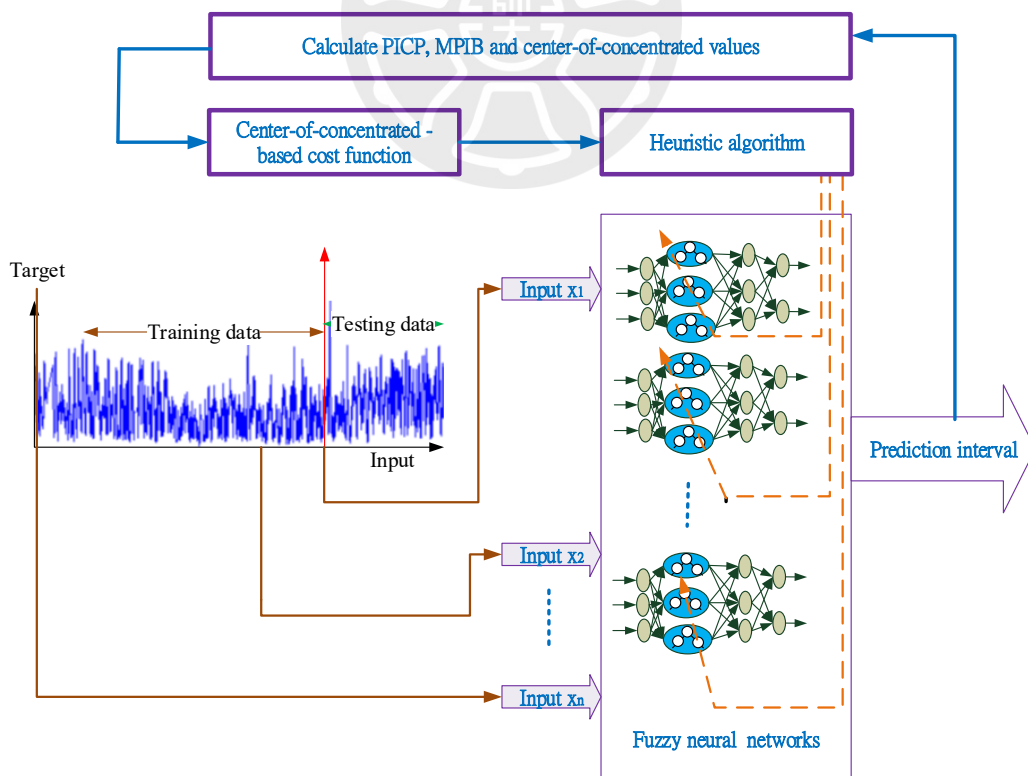


圖 4-2 預測區間方法整體架構

### 4.3 實驗結果與討論

本文選擇金門金沙風力發電站在 10 月至 12 月期間的風速和發電數據，共計 6000 筆數據，每 15 分鐘一次，該期間風速變化較大。金沙風力發電站安裝兩台 Vestas V80/2000 型風力發電機，額定容量為 2.0MW。風力發電數據，包括風速和功率曲線，見圖 4-3(a)與(b)。為了分析風力發電數據的相關係數和顯著性，使用 MATLAB 的 corrcoef 函數計算風速向量  $w(t)$  與  $w(t-k)$  之間的相關係數，結果見圖 4-3(c)與(d)。從圖 4-3(c)至(d)可以看出，檢驗假設無關聯的 p 值(顯著性水平為 0.05)直到  $k>150$  時才非常小。因此，當  $k<197$  時，風速向量  $w(t)$  與  $w(t-k)$  之間的相關性被認為是顯著的。此數據分析有助於發現基於數據的預測模型的特徵。基於數據的預測模型分別由模糊神經網路和反向傳播神經網路建模，並且它們的學習方法分別為類電磁算法和細菌覓食算法。因此，共有四種組合，包括類電磁模糊神經網路方法、細菌覓食模糊神經網路方法、類電磁反向傳播神經網路方法和細菌覓食神經網路方法。




圖 4-3 風力發電資料(a)風功率曲線 (b)風速趨勢圖 (c)相關係數 (d)

檢驗假設的 p 值趨勢

### 4.3.1 類電磁模糊神經網路

模糊神經網路的架構如[16]所示。該模糊神經網路有三個輸入和兩個輸出。三個輸入為時間點 t-1、t-2 和 t-3 的風力發電歷史數據，兩個輸出分別為時間點 t 的風力發電數據的上下預測限。每個輸入有三個歸屬函數，如圖 4-4(a)所示。模糊 IF-THEN 規則數量為 27，解模糊採用重心法。類電磁算法的參數設定為：粒子群數  $m=20$ ，維度  $n=54$ ，搜尋空間  $D=[-1,1]$ 。局部搜尋迭代次數為 5，風力數據已正規化，收斂準則設為 100 次迭代結果。式(4-15)與(4-16)中提出方法的權重設定為  $W_{PICP} = 10$ 、 $W_{MPIB} = 1$  與  $W_{CC} = 0.005$ ，而傳統方法不包含 CC 距離項。為了比較傳統方法，提出方法的集中中心距離（CC 距離）表示如式(4-21)所示：

$$CC = \frac{1}{n} \sum_{k=1}^n \frac{|c_k - y_k|}{(y_k^U - y_k^L)} \quad (4-21)$$

其中  $c_k$  為上下預測限的集中點中心。為了評估風速觀測數據集中於上下預測限中心附近的比例，定義集中度（Concentration Degree, CD），如式(4-22)所示。

$$CD = \frac{1}{n} \sum_{k=1}^n d_k \quad (4-22)$$

且

$$d_k = \begin{cases} 1 & \text{if } c_k - \alpha |y_k^U - y_k^L| \leq y_k \leq c_k + \alpha |y_k^U - y_k^L| \\ 0 & \text{otherwise} \end{cases} \quad (4-23)$$

參數  $\alpha$  是設定參數，用於評估數據集中於上下預測限中心的比例，此處設定  $\alpha = 0.2$ 。圖 4-4(b) 顯示類電磁模糊神經網路的學習曲線，總迭代次數為 100，其中藍色“+”符號和紅色實線分別代表本文所提方法與傳統方法。最終的模擬結果如圖 4-5 至 4-6 及表 4-1 所示。包括訓練資料的學習成果與測試資料的預測結果。紅色與綠色曲線分別代表預測區間的最大邊界與下邊界，而藍色“+”則表示觀測風速資料。由圖 4-5 至圖 4-6 可看出，不論是使用傳統方法或本文方法，類電磁模糊神經網路都能有效找出預測上下邊界。

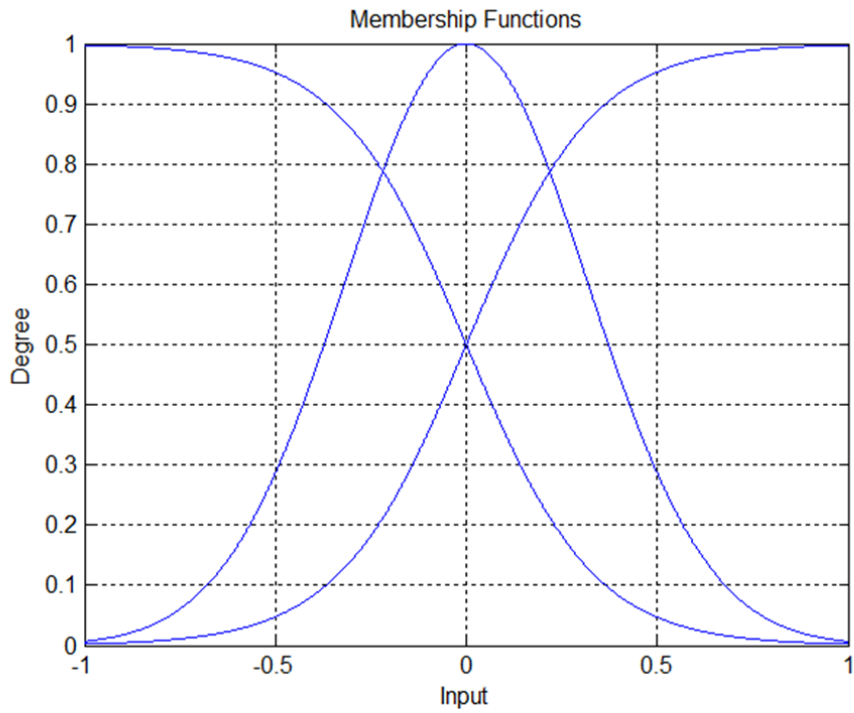
圖 4-5 顯示使用傳統方法的模擬結果，包括類電磁模糊神經網路的學習與測試結果。其中，紅色與綠色曲線分別代表上下預測限，藍色符號“+”表示風速觀測數據。同樣圖 4-6 呈現本文所提出方法的模擬結果，包括學習與測試過程。從圖 4-5 與圖 4-6 可以看出，無論是本文所提出的方法還是傳統方法，類電磁模糊神經網路都能有效找到上下預測限。

此外，從表 4-1 可看出，本文所提方法與傳統方法的權重皆設為  $W_{PICP} = 10$ 、 $W_{MPIB} = 1$ 、 $W_{CC} = 0.005$ 。在這些權重下，本文所提方法的訓練資料結果為：MPIB=4.77m/s，PICP=96.07%，CD=65.99%；測試資料結果為 MPIB=4.58m/s，PICP=92.00%，CD=59.13%。相較之下，傳統方法的訓練資料結果為 MPIB=4.87m/s，PICP=95.20%，CD=65.07%；測試資料結果為 MPIB=4.62m/s，PICP=90.88%，CD=57.63%。這表明本文所提方法在預測區間較小的同時具備更高覆蓋率。

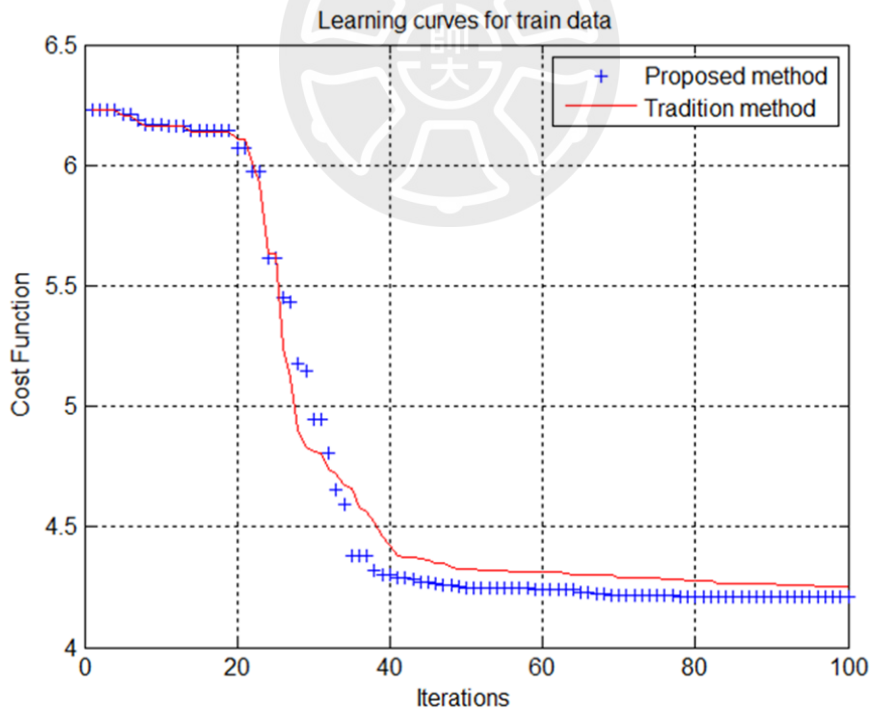
接下來分析不同權重設定對結果的影響，如圖 4-7、圖 4-8 及表 4-2 所示，當  $W_{MPIB} = 1$ 、 $W_{CC} = 0.005$  且兩種不同權重  $W_{PICP} = 2$  和  $W_{PICP} = 6$  時，可

以發現增加  $W_{PICP}$  權重會提高覆蓋概率，但預測區間會變大。



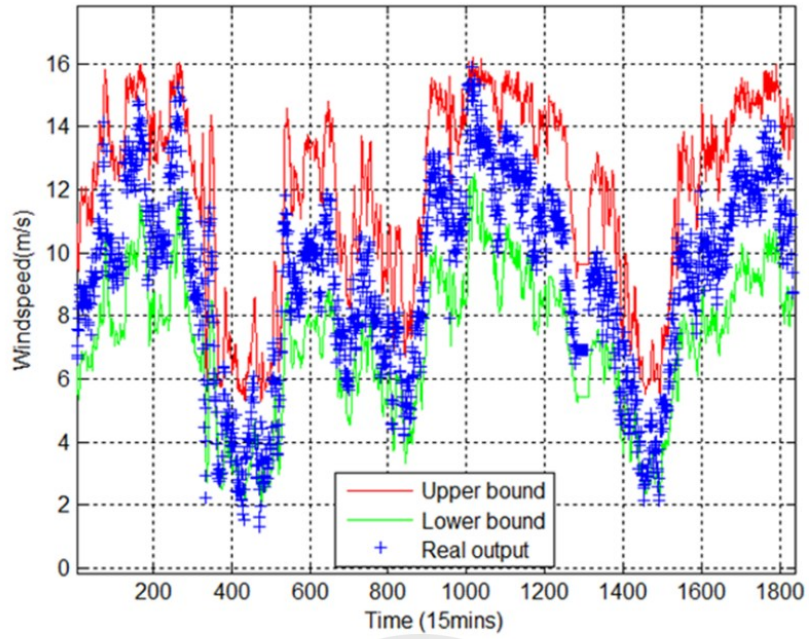


(a)

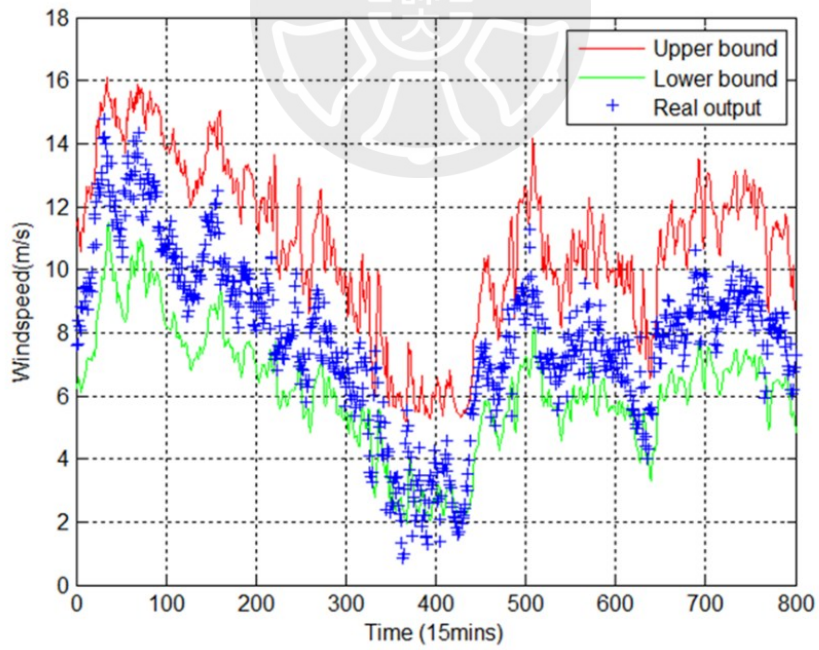


(b)

圖 4-4 (a)模糊類神經網路歸屬函數 (b)類電磁網路的訓練收斂過程




(a)




(b)

圖 4-5 類電磁模糊神經網路（傳統方法） (a)訓練資料與(b)測試資料



(a)



(b)


圖 4-6 類電磁模糊神經網路(a)訓練資料與(b)測試資料 (本文提出方法)

表 4-1 類電磁類神經網路效能比較表


Method	Training data			Testing data		
	MPIB	PICP	CD	MPIB	PICP	CD
Traditional Method	4.87 m/s	95.20%	65.07%	4.62 m/s	90.88%	57.63%
Proposed Method	4.77 m/s	96.07%	65.99%	4.58 m/s	92.00%	59.13%

表 4-2 不同  $W_{PICP}$  權重設定對類電磁模糊類神經比較表

Different weights		
$W_{PICP}$	$W_{MPIB}$	$W_{CC}$
2	1	0.005
6	1	0.005
Training data		
MPIB	PICP	CD
3.00 m/s	84.77%	47.71%
4.17 m/s	92.47%	57.70%
Testing data		
MPIB	PICP	CD
2.86 m/s	80.63%	44.75%
3.93 m/s	89.25%	54.13%




(a)




(b)

圖 4-7 類電磁模糊神經網路訓練結果 (使用  $W_{PICP} = 2$ ,  $W_{MPIB} = 1$ ,

$W_{CC} = 0.005$  作為參數) (a)訓練資料與(b)測試資料



(a)



(b)


圖 4-8 類電磁模糊神經網路訓練結果 (使用  $W_{PICP} = 6$ ,  $W_{MPIB} = 1$ ,

$W_{CC} = 0.005$  作為參數) (a)訓練資料與(b)測試資料


同樣，如圖 4-9、圖 4-10 及表 4-3 所示，當  $W_{MPIB} = 1$ 、 $W_{PICP} = 1$  且比較兩種不同權重  $W_{CC} = 1$  和  $W_{CC} = 10$  的差異時，可以看出增加  $W_{CC}$  權重會使集中度提高，但預測區間會隨之變大。

表 4-3 不同  $W_{CC}$  對預測區間的影響比較表

Different weights		
$W_{PICP}$	$W_{MPIB}$	$W_{CC}$
1	1	1
1	1	10
Training data		
MPIB	PICP	CD
3.50 m/s	89.57%	55.90%
7.36 m/s	95.91%	79.97%
Testing data		
MPIB	PICP	CD
3.61 m/s	87.63%	55.00%
6.83 m/s	92.75%	75.75%




(a)




(b)

圖 4-9 類電磁類模糊神經網路訓練結果 (使用  $W_{PICP} = 1, W_{MPIB} = 1,$

$W_{CC} = 1$  作為參數) (a)訓練資料與(b)測試資料



(a)



(b)


圖 4-10 類電磁模糊神經網路訓練結果 (使用  $W_{PICP} = 1$ ,  $W_{MPIB} = 1$ ,

$W_{CC} = 10$  作為參數) (a)訓練資料與(b)測試資料


此外，圖 4-11、圖 4-12 及表 4-4 顯示，當  $W_{PICP} = 2$ 、 $W_{CC} = 0.1$  且使用不同權重  $W_{MPIB}$  時，增加  $W_{MPIB}$  權重會使預測區間變小，但覆蓋概率降低。

表 4-4  $W_{MPIB}$  權重對類電磁演算法比較表

Different weights		
$W_{PICP}$	$W_{MPIB}$	$W_{CC}$
2	4	0.1
2	3	0.1
Training data		
MPIB	PICP	CD
1.54 m/s	59.44%	27.67%
1.76 m/s	65.56%	32.26%
Testing data		
MPIB	PICP	CD
1.53 m/s	57.13%	25.50%
1.76 m/s	62.88%	28.50%




(a)




(b)

圖 4-11 類電磁模糊神經網路訓練結果 (使用  $W_{PICP} = 2, W_{MPIB} = 4,$

$W_{CC} = 0.1$  作為參數) (a)訓練資料與(b)測試資料



(a)



(b)


圖 4-12 類電磁模糊神經網路訓練結果 (使用  $W_{PICP} = 2, W_{MPIB} = 3,$

$W_{CC} = 0.1$  作為參數結果) (a)訓練資料與(b)測試資料


前述的模糊神經網路主要是針對風速數據而設計。因此接下來我們將估計本文所提出方法與傳統方法對於風力發電數據的上下預測邊界情形。該模糊神經網路同樣具有三個輸入與兩個輸出。三個輸入特徵分別為風力發電歷史數據在 t-1、t-2 及 t-3 時間點的值，兩個輸出則分別為上預測邊界與下預測邊界。每個輸入皆對應三個歸屬函數，如圖 4-4(a)所示，本文使用重心法作為解模糊化方法。並且類電磁演算法的參數設定如下：粒子數  $m=20$ ，維度  $n=54$ ，搜尋空間範圍  $D=[-1, 1]$ ，局部搜尋的迭代次數為 5，並且所使用的風速數據已經進行正規化處理。使用傳統方法的模擬結果如圖 4-13 所示。顯示使用訓練數據的類電磁模糊神經網路的學習結果，以及測試數據的預測結果。紅色與綠色曲線分別代表上預測邊界與下預測邊界，藍色「+」符號表示風力發電觀測數據。從圖 4-13 與 3-14 可以看出，無論是使用本文所提出的方法還是傳統方法，類電磁模糊神經網路都能有效找出上下預測邊界。另外從表 4-5 中可以看出，當權重設定為  $W_{PICP} = 10$ 、 $W_{MPIB} = 1$ 、 $W_{CC} = 0.01$  時，所提方法的訓練資料結果為  $MPIB=1.87kW$ ， $PICP=97.00\%$ ， $CD = 39.9\%$ 、測試資料結果為  $MPIB = 1.96kW$ ， $PICP = 97.00\%$ ， $CD = 49.00\%$ 。與傳統方法的訓練資料  $MPIB = 2.18kW$ ， $PICP = 96.02\%$ ， $CD = 39.47\%$ ，測試資料  $MPIB = 2.00kW$ ， $PICP = 95.75\%$ ， $CD = 48.50\%$  相比，本文所提出的方法具有更高的覆蓋概率和更小的預測區間。

表 4-5 類電磁模糊神經演算方法所提方法與傳統方法比較表

Method	Training data			Testing data		
	MPIB	PICP	CD	MPIB	PICP	CD
Traditional Method	2.18 kW	96.02%	39.47%	2.00 kW	95.75%	48.50%
Proposed Method	1.87 kW	97.00%	39.9%	1.96 kW	97.00%	49.00%




(a)




(b)

圖 4-13 類電磁模糊神經網路於風力發電預測結果(a)訓練資料與(b)測試資料 (使用傳統方法)



(a)




(b)

圖 4-14 類電磁模糊神經網路於風力發電預測結果(a)訓練資料與 (b)測試資料 (本文提出方法)


### 4.3.2 細菌覓食模糊類神經網路

細菌覓食模糊類神經網路 (Bacterial Foraging Fuzzy Neural Network, BFFNN) 的結構與前述的類電磁模糊神經網路相同。細菌覓食算法的設計

參數如下：維度為 54，細菌數量為 20，化學趨性迭代次數為 5，消除-擴散次數為 5，繁殖次數為 5。收斂準則設為消除-擴散的迭代次數。權重設定為  $W_{PICP} = 10$ 、 $W_{MPIB} = 1$ 、 $W_{CC} = 0.01$ 。使用傳統方法的模擬結果如圖 4-15 至圖 4-16 所示。圖 4-15 為細菌覓食模糊神經網路使用訓練資料所產生的學習結果與測試資料預測結果。紅色與綠色曲線分別表示預測區間的上限與下限，藍色符號 + 表示風速觀測資料。同樣地，本文所提出方法的模擬結果如圖 4-16 所示。圖 4-16 分別為細菌覓食模糊神經網路的訓練結果與測試資料預測結果。紅色與綠色曲線分別代表預測區間的上限與下限，藍色符號 + 表示風速觀測資料。從圖 4-15 與圖 4-16 中可以看出，無論是本文所提出的方法或傳統方法，細菌覓食模糊神經網路皆能有效找出預測區間的上下邊界。並且透過表 4-6 所示，本文所提出的方法與傳統方法的權重分別設定為  $WPICP=10$ 、 $WMPIB=1$ 、 $WCC=0.005$ 。本文所提出方法下獲得的訓練資料結果為  $MPIB = 3.75 \text{ m/s}$ ， $PICP = 97.76\%$ 、 $CD = 71.62\%$ ；測試資料結果為  $MPIB = 3.84 \text{ m/s}$ ， $PICP = 98.00\%$ 、 $CD = 68.87\%$ 。相比之下，傳統方法下訓練資料結果為  $MPIB = 4.16 \text{ m/s}$ ， $PICP = 98.58\%$ 、 $CD = 73.80\%$ ；測試資料結果為  $MPIB = 4.34 \text{ m/s}$ ， $PICP = 98.38\%$ 、 $CD = 70.50\%$ 。雖然兩者皆可取得相近的涵蓋機率，但在預測區間方面，本文所提出的方法在測試資料中比傳統方法少 11.52%。其計算公式為： $(3.84 - 4.34) / 4.34 = -11.52\%$ 。




(a)



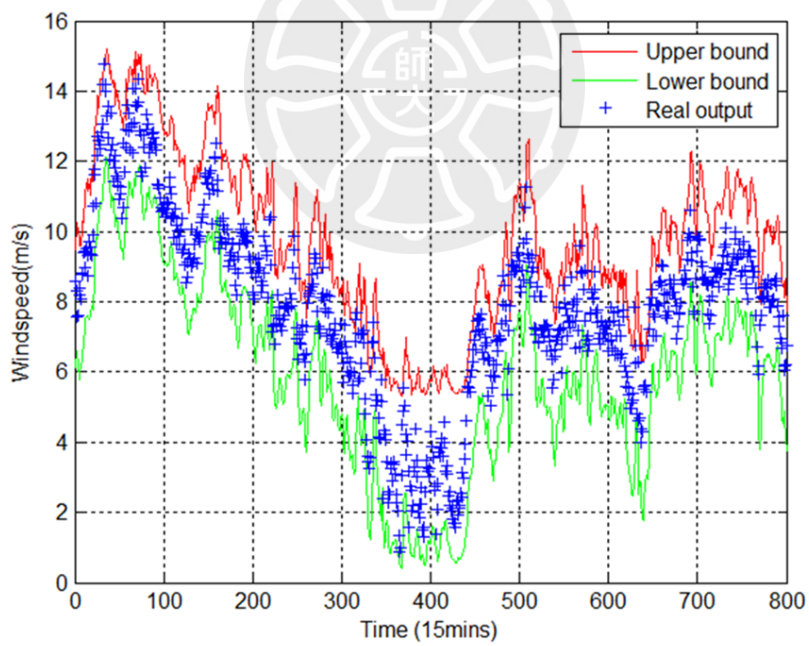
(b)

圖 4-15 細菌覓食模糊類神經網路訓練結果(a)訓練資料與(b)測試資料

(使用傳統方法)



(a)



(b)

圖 4-16 細菌覓食模糊類神經網路訓練結果(a)訓練資料與(b)測試資料

(本文提出方法)

表 4-6 細菌覓食模糊類神經網路方法比較

Method	Training data			Testing data		
	MPIB	PICP	CD	MPIB	PICP	CD
Traditional Method	4.16 m/s	98.58%	73.80%	4.34 m/s	98.38%	70.50%
Proposed Method	3.75 m/s	97.76%	71.62%	3.84 m/s	98.00%	68.87%


### 4.3.3 類電磁反向傳播神經網路

反向傳播神經網路的結構是一個三層神經網路，包括輸入層、隱藏層和輸出層。輸入層有三個輸入，隱藏層有 21 個神經元，輸出層有兩個輸出。三個輸入特徵是時間  $t-1$ 、 $t-2$  和  $t-3$  的歷史風速數據，兩個輸出是時間  $t$  的上下預測限。類電磁模擬算法的參數設為： $m=50$  組粒子，維度為  $n=126$ ，搜尋範圍  $D=[-1,1]$ ，局部搜尋的迭代次數為 5，風速數據已經進行歸一化，收斂準則設為 200 次迭代的結果。權重設定為  $W_{PICP} = 20$ 、 $W_{MPIB} = 1$  與  $W_{CC} = 1$ 。


使用傳統方法的模擬結果如圖 4-17 所示，圖 4-17 顯示反向傳播神經網路的學習和測試結果。同樣地使用所提出方法的模擬結果如圖 4-18 所示，圖 4-18 顯示反向傳播神經網路的學習和測試結果。從圖 4-17 和圖 4-18 可以看出，無論是所提出的方法還是傳統方法，反向傳播神經網路都能有效地找出上下預測限。此外從表 4-7 可以看出，在本文所提出的方法中，訓練資料的結果為： $MPIB = 3.73$  m/s， $PICP = 99.24\%$ 、 $CD = 78.77\%$ ；測試資料的結果為： $MPIB = 3.80$  m/s， $PICP = 98.88\%$ 、 $CD = 77.12\%$ 。相較之下，傳統方法的結果為：訓練資料  $MPIB = 4.19$  m/s， $PICP = 99.45\%$ 、 $CD = 79.91\%$ ；測試資料  $MPIB = 4.25$  m/s， $PICP = 98.75\%$ 、 $CD = 77.00\%$ 。

雖然兩種方法皆能達到相近的覆蓋機率，但在測試資料的預測區間方面，本文所提出的方法比傳統方法少 10.59%。其計算公式為： $(3.80 - 4.25) / 4.25 = -10.59\%$ 。






(a)




(b)

圖 4-17 類電磁反向傳播神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用傳統方法)



(a)



(b)

圖 4-18 類電磁反向傳播神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用本文提出方法)

表 4-7 類電磁反向傳播神經網路比較表

Method	Training data			Testing data		
	MPIB	PICP	CD	MPIB	PICP	CD
Traditional Method	4.19 m/s	99.45%	79.91%	4.25 m/s	98.75%	77.00%
Proposed Method	3.73 m/s	99.24%	78.77%	3.80 m/s	98.88%	77.12%

#### 4.3.4 細菌覓食反向傳遞神經網路


細菌覓食反向傳播神經網路 (Bacterial Foraging Back-Propagation Neural Network, BFBPNN) 的結構與前述的類電磁反向傳播神經網路相同。細菌覓食算法的參數維度為 126，細菌數量為 20，化學趨向的次數為 5，消除-擴散的次數為 5，繁殖的次數為 5。收斂準則設為消除-擴散的迭代次數。權重設為  $W_{PICP} = 20$ 、 $W_{MPIB} = 1$  和  $W_{CC} = 1$ 。

使用傳統方法的模擬結果如圖 4-19 所示，圖 4-19 顯示細菌覓食反向傳播神經網路的學習結果和測試結果。類似地，使用所提出方法的模擬結果如圖 4-20 所示，圖 4-20 顯示細菌覓食反向傳播神經網路的學習和測試結果。從圖 4-19 和圖 4-20 可以看出，無論是所提出的方法還是傳統方法，細菌覓食反向傳播神經網路都能有效地找出上下預測限。


此外從表 4-8 可以看出，傳統方法和所提出的方法在覆蓋概率上相似，但在預測區間方面，所提出的方法比傳統方法在測試結果中少 7.09%。細菌覓食反向傳播神經網路的結構與前述的類電磁反向傳播神經網路相

同。細菌覓食算法的參數維度為 126，細菌數量為 20，化學趨向的次數為 5，消除-擴散的次數為 5，繁殖的次數為 5。收斂準則設為消除-擴散的迭代次數。權重設為  $W_{PICP} = 20$ 、 $W_{MPIB} = 1$ ，和  $W_{CC} = 0.01$ 。使用傳統方法的模擬結果如圖 4-19 所示，圖 4-19 顯示細菌覓食反向傳播神經網路的學習結果和測試結果。同樣地，使用所提出方法的模擬結果如圖 4-20 所示，圖 4-20 顯示細菌覓食反向傳播神經網路的學習和測試結果。從圖 4-19 和圖 4-20 可以看出，無論是所提出的方法還是傳統方法，細菌覓食反向傳播神經網路都能有效地找出上下預測限。此外，從表 4-8 可以看出，傳統方法和所提出的方法在覆蓋概率上相似，但在預測區間方面，所提出的方法比傳統方法在測試結果中少 7.09%。






(a)




(b)

圖 4-19 細菌覓食反向傳遞神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用傳統方法)



(a)



(b)

圖 4-20 細菌覓食反向傳遞神經網路訓練與測試結果(a)訓練資料與(b)測試資料 (使用本文提出方法)

表 4-8 細菌覓食反向傳遞神經網路訓練與測試結果比較表

Method	Training data			Testing data		
	MPIB	PICP	CD	MPIB	PICP	CD
Traditional Method	4.28 m/s	99.56%	79.91%	4.23 m/s	98.50%	76.38%
Proposed Method	4.10 m/s	99.24%	82.81%	3.93 m/s	99.00%	77.25%

### 4.3.5 反向傳播神經網路與模糊神經網路結果比較


為了展示模型的不確定性，本文使用相同的細菌覓食算法參數訓練反向傳播神經網路和模糊神經網路模型。模糊神經網路和反向傳播神經網路的結構與前述的模糊神經網路和反向傳播神經網路相同。同樣地，細菌覓食算法的設置與上面描述的相同，唯一的不同是消除-擴散的次數。此外權重設為  $W_{PICP} = 20$ 、 $W_{MPIB} = 1$  和  $W_{CC} = 1$ 。和  $W_{CC} = 0.01$ 。這些不確定性對於 MPIB（平均預測區間）、PICP（覆蓋概率）和 CD（集中度）的影響，已經針對不同的學習參數調整過的模型架構進行討論。為了分析模型不確定性的相關係數和顯著性，使用 MATLAB 中的 `corrcoef` 函數計算相關係數和用於檢驗假設的 p 值（假設無關係）。模擬結果如表 4-9 所示。從表 4-9 可以看出，反向傳播神經網路的性能略優於模糊神經網路。這可能是由於網絡架構中的調整參數數量的差異，反向傳播神經網路有 126 個調整參數，而模糊神經網路只有 54 個調整參數。此外，由於細菌覓食算法中不同消除-擴散次數的 MPIB、PICP 和 CD 的 p 值大於顯著性水平 0.05，因此它們對於反向傳播神經網路和模糊神經網路來說不是顯著的相關性。

表 4-9 細菌覓食演算法於不同神經網路預測效能比較表


消除-擴散次數		5	10	20
細菌覓食 反向傳播類神經網路	MPIB (m/s)	3.93	3.886	3.44
	PICP	0.99	0.9862	0.9825
	CD	0.7725	0.7538	0.7500
	$R_{MPIB}, P_{MPIB}$	-0.9684, 0.1606		
	$R_{PICP}, P_{PICP}$	-0.9805, 0.1259		
	$R_{CD}, P_{CD}$	-0.8497, 0.3535		
細菌覓食模糊神經網路	MPIB (m/s)	5.84	4.225	3.626
	PICP	0.9850	0.9875	0.9813
	CD	0.4437	0.7113	0.7087
	$R_{MPIB}, P_{MPIB}$	-0.9008, 0.2859		
	$R_{PICP}, P_{PICP}$	-0.7346, 0.4748		
	$R_{CD}, P_{CD}$	0.7504, 0.4598		

#### 4.3.6 多步領前預測

最後，使用類電磁反向傳播神經網路解決多步預測問題。類電磁反向傳播神經網路的結構和參數設置與前述相同，權重設為  $W_{PICP} = 20$ 、 $W_{MPIB} = 1$  與  $W_{CC} = 0.01$ 。6 步預測的結果如圖 4-21 到圖 4-25 所示，6 步預測的 MPIB、PICP 和 CD 數據如表 4-10 所示。從表 4-10 可以看出，不同時間點的覆蓋概率相似，而隨著預測時間的增加，預測區間的值會變得更大。圖 4-26 顯示在不同預測時間點，預測區間的變化。從圖 4-27 可以看出，預測時間點越長，不確定性越大。




(a)




(b)

圖 4-21 類電磁反向傳播神經網路於風速預測 WS (t+1)預測結果(a)訓練資料與(b)測試資料




(a)




(b)

圖 4-22 類電磁反向傳播神經網路於風速預測 WS (t+2)預測結果(a)訓練資料與(b)測試資料




(a)




(b)

圖 4-23 類電磁反向傳播神經網路於風速預測 WS (t+3)預測結果 (a)訓練資料與(b)測試資料




(a)




(b)

圖 4-24 類電磁反向傳播神經網路於風速預測 WS (t+4)預測結果 (a)訓練資料與(b)測試資料



(a)



(b)

圖 4-25 類電磁反向傳播神經網路於風速預測 WS (t+5)預測結果(a)訓練資料與(b)測試資料




圖 4-26 不同領前預測步長對類電磁反向傳播神經網路之 MPIB 的影響

#### 4.4 結論

本文探討數據驅動預測模型的不確定性，並提出一種優化流程，考慮輸出集中度、覆蓋概率以及預測區間範圍。相比傳統方法，此優化流程為構建數據驅動預測模型的預測區間提供靈活設計。該流程結合神經網路、目標函數和啟發式演算法，應用於區間風電功率預測問題。此外，研究設計四種神經網路模型與啟發式算法的組合，用於金門金沙風力發電站的區間預測。模擬結果顯示本文所提方法可實現最佳的預測區間。最後，該方法也展示其在多步預測問題中的應用可行性。

## 第五章 流域發電預測規劃系統建立

第三章介紹於最上游水庫的入流量與水位預測方法、第四章提出一套量化預測不確定的預測區間產出方法後，透過這些方法作為基礎。本章節目的在提出一套流域多水庫多目標發電最佳化決策方法，該章節提出一套整合降雨預報、入流量預測與入流量預測區間等資訊，讓流域可以針對未來的天氣情境進行即時的風險評估，這將透過排洪風險因子與發電效率兩個目標函數為基礎進行實現。

### 5.1 簡介

水力發電作為一種可快速部署且清潔的再生能源，已被許多國家廣泛採用。然而，隨著極端天氣事件的頻率不斷增加，特別是在降雨量大的地區及島嶼氣候中，強降雨帶來的排洪風險顯著提升。儘管早期的預防措施可以大幅降低洪水發生的可能性，但調度人員往往傾向於採取較為保守的規劃策略。一個能在保證相同發電指令的同時，優化發電效率並降低排洪風險的系統，將能爭取更多緩衝時間為調度人員提供更大的決策彈性。這不僅能提升經濟效益，還能將洪水對民生和水資源的損失降到最低。此外，隨著全球再生能源占比的提升，其不穩定性對電網的影響將更加顯著。快速響應系統，如儲能與水力發電在穩定電網方面提供重要貢獻。為了最大化水資源利用、降低排洪風險並提升經濟效益，需要一套能適應短期颱風事件的流域發電決策系統。本章節提出一個針對上述挑戰的流域發電決策系統，透過兩種不同的指標（排洪風險）與流域用水量（隱含流域發電效

率意義) 作為成本函數，去量化實際應用上的風險因子與發電效率資訊。

之前於第二章文獻探討中提及，水庫入流量預測的重要性、氣象預報的不確定性以及明確量化的預測不確定性指標(如預測區間)皆應該納入流域多水庫發電最佳化系統當中進行考量，才能建構出真正實務上效果較好的系統。並且流域而為了避免 FLWL 對優化最佳解搜尋空間的限制。本文提出另外一種方式全面的考量短期排洪風險，不再侷限於僅針對發電所需的最高水位限制進行傳統調控，而是引入「考量未來的成本函式」的概念以量化排洪風險，並將問題轉化為一個多目標優化的課題。由於水力發電效率與排洪風險這兩個目標相互衝突，它們的重要性會因未來天氣情境而出現顯著差異。即使本文所提出的成本函式已納入短期未來條件，然而在實務上的應用當中，多目標最佳化方法往往是提出一組整合各種權衡意義的解集合，這些解集合在實務上的應用當中依然會造成決策者的決策困難，因為它不是作為單一的結果輸出，而是以一組解的方式呈現。因此本文進一步設計一個二階段逐小時多水庫多目標發電最佳化系統。本方法可以引入未來的水庫入流量預測與預測區間，並依照未來入流量預測情境對系統決策方針進行動態調節，在每一個小時的決策結果當中，排洪風險指標與流域用水量指標的重要程度都會依據其推演的未來一天入流量預測進行動態調節，這將使得方法能夠針對未來氣候情境進行靈活的決策制定。而這些富含權衡意義的決策機制皆可不依賴 FLWL 的制定實現。在第一階段中，系統採用 ev-MOGA 作為多目標最佳化基礎，在每一次迭代中針對未來 12 小時內需考量的用水需求及排洪風險，產生多樣化的候選解集合。這些候選解之後會被輸入至第二階段的決策系統，其中包含 Fuzzy TOPSIS 在內的多個模組。此決策系統會使用一種導入「水庫入流量預測區間」概念的專家意見生成方法，透過模糊邏輯綜合上游未來天氣情境與目前水庫

可用容量，從而動態設定各準則（成本函式）之權重。最終產出未來下一個領前小時的發電決策結果，最終經過 24 次迭代之後可以獲得未來 24 小時的發電決策結果。整體的目標是希望提升在極端降雨事件因應排洪風險能力的同時維持日常發電運行的效率。經過實驗結果顯示，本文提出方法可以在平日提供良好的發電效率並且可以在颱風情境下提供更良好排洪風險管控，本方法在大甲流域的應用成效得到驗證。

本章節的研究貢獻總結如下：

1. 提出一個能描述未來 12 小時決策對排洪風險影響的管理成本函式：

透過將此函式整合至決策機制中，能根據未來氣候情境動態調整整體水位，即使不調整洪水限制水位（FLWL），也能達到有效的防洪目標。

2. 提出一種基於預測區間的專家意見生成方法：

利用上下邊界與模糊歸屬函數的概念，同時提供樂觀與悲觀的專家評估意見。

3. 提出一種基於當前庫容與未來一天入流量預測的模糊邏輯方法：

用以決定風險管理的重要性（即權重機制），並說明如何將模糊決策應用於多水庫風險管理之中。

綜合而言，所提出的方法即使在不實際調整洪水限制水位（FLWL）的情況下，也能達到近似於動態調整 FLWL 的水位控制效果，展現其在氣候變化劇烈的台灣地區之優勢。即便是在颱風頻繁侵襲的 2016 年 9 月，本方法仍能維持令人滿意的發電效率。

本章節的架構說明如下，第二節介紹所提出的系統，包含系統中的各模組以及它們的運作機制，第三節呈現實際場域的模擬結果，包括模型訓

練成果、在真實颱風情境下的效能，以及整體流域用水量的累積情況，以驗證本系統在不同事件與綜合表現上的適用性，最後在第四節進行整體論文的總結。



## 5.2 研究方法

本文的研究架構呈現如圖 5-1 所示，要解決多目標流域水庫發電決策最佳化問題首先需要定義出希望優化的各項指標，以本文來說需要優化的指標的定義為發電效率與排洪風險指標。這兩項指標是完全衝突的，高發電效率意味著整體流域的平均水位會處較高的情形。而低排洪風險指標則會使流域水庫整體水位降低以應對未來可能的大量入流量。為此需要一套方法去找出多目標在不同決策下的輸出結果，這些結果包含各指標的極端解以及其權衡結果。這些解有著無法取代對方的特性。在產製這些多元的最佳解集合後。需要更進一步的未來資訊去評估當前情境下的最佳決策結果。以本文來說使用未來 48 小時的入流量預測做為基礎，並使用決策方法進行最終方案的選擇。決策方法非常適合來實現這部分的功能，決策方法有著高可解釋性、專家意見的整合能力等優點，因此第二部分將基於決策方法透過輸入的最佳解集合、引入的最上游水庫預測區間與所有方案模擬的水位趨勢等資訊進行多方面評估，最終選出最適合的決策結果。

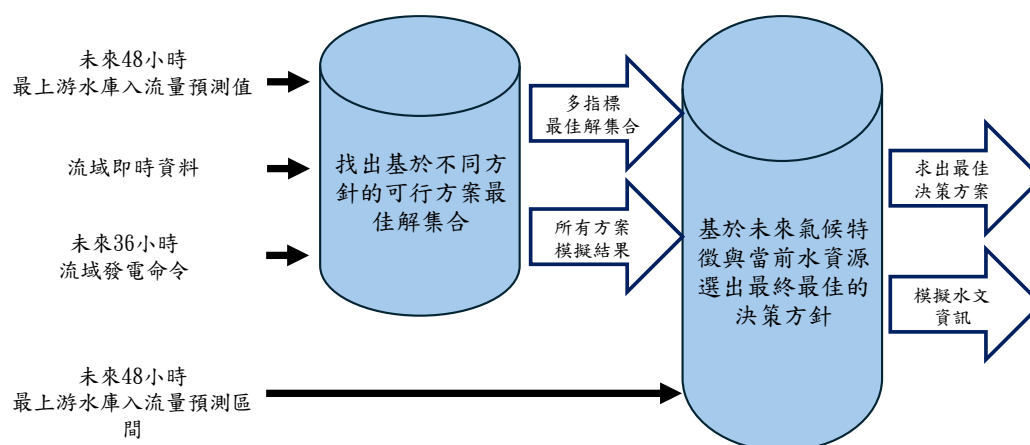


圖 5-1 二階段流域多水庫發電決策最佳化整體系統架構圖

前段說明了二階段方法使用的資料與其目的之後。接下來將具體說明

本文所提出的兩階段流域多水庫發電最佳化系統整體的詳細架構，其呈現如圖 5-2 所示。它被系統性地劃分為六個模組，包括 EMOGA 模組、RM 模組、CF 模組、FTOPSIS 模組、EOG 模組和 CWG 模組，其中 EMOGA、RM、CF、FTOPSIS、EOG 和 CWG 模組分別表示 ev-MOGA、逕流模型、成本函數、Fuzzy TOPSIS、專家意見生成和準則權重生成的功能。EMOGA 模組使用 ev-MOGA 作為多目標最佳化方法負責找出最佳解集合、RM 模組為逕流模型用來描述流域間水庫的水資源的轉移關係、CF 模組作為成本函數使用包含排洪風險與發電效率兩項指標，並且會與 RM 模組進行迭代推演模擬所有決策對未來的影響、FTOPSIS 模組則使用 Fuzzy TOPSIS 此經典的決策方法進行多目標的決策方法、EOG 模組則透過預測區間與解集合之間彼此不同的特性去生成兩個專家對所有解的意見結果包含所有方針的評價、CWG 模組則透過未來預測結果與當前水位資訊去調節所有方針於該時間情境下的重要程度。這些模組的組合最終實現流域多水庫多目標發電決策最佳化系統的建置。

本文採用兩階段系統，每個階段具有不同的目標。以下是每個階段的深入討論。

在第一階段，本文考慮兩個成本函數（流域用水量 and 排洪風險）生成多樣的候選解決方案，計算過程在 CF 模組內進行。在此模組內，成本函數與 RM 模組會進行迭代模擬，以評估所有輸入的決策對未來 12 小時水庫情境的影響。具體來說，RM 模組根據流域內每個水庫的歷史出水量數據，預測下游水庫下一小時的流入量；對於最上游水庫，則整合小時入流量預測作為輸入，從而確定所有水庫水資源的每小時變化。利用這些信息，成本函數計算其相應的數值。這些評估結果隨後進入 EMOGA 模組進行啟

發式運算，最終產生一組多樣化的解決方案。

在第二階段，系統使用 FTOPSIS 模組作為決策方法，並利用 CWG 模組和 EOG 模組生成所需的輸入數據以供決策模型使用。EOG 模組將上游水庫的流入預測上下限與每個候選解決方案的發電決策重新整合，並輸入 CF 模組，產生兩組不同的候選解方案。使用預測入流量預測範圍的上限所生成的解決方案反映對整體流域用水量的悲觀估計（較高的入流量），而使用下限的候選解方案則表示樂觀估計之整體流域用水量（即較低的入流量）。這種方法有效地納入與上游流入預測相關的不確定性。另一方面，FTOPSIS 模組所需的準則權重由 CWG 模組生成。CWG 模組利用模糊邏輯的可解釋性及其整合不同類型數據的能力，允許納入更長期的預測數據。使用次日的平均入流量預測和上游水庫的及時庫容量作為輸入，以導出兩個成本函數的權重，該權重用來表示當前情境（及時的庫容量與未來入流量預測）下兩個成本函數的重要程度。最後，FTOPSIS 模組利用這些參數和權重評估每個候選解決方案的量化值，並選擇最大值作為最佳解決方案。

在圖 5-1 與 5-2 中，本系統的輸入包含流域各水庫的即時水位、未來 48 小時上游水庫入流量預測及其預測區間，以及未來 36 小時的流域發電排程指令，而其輸出則為未來 24 小時的流域發電排程結果。

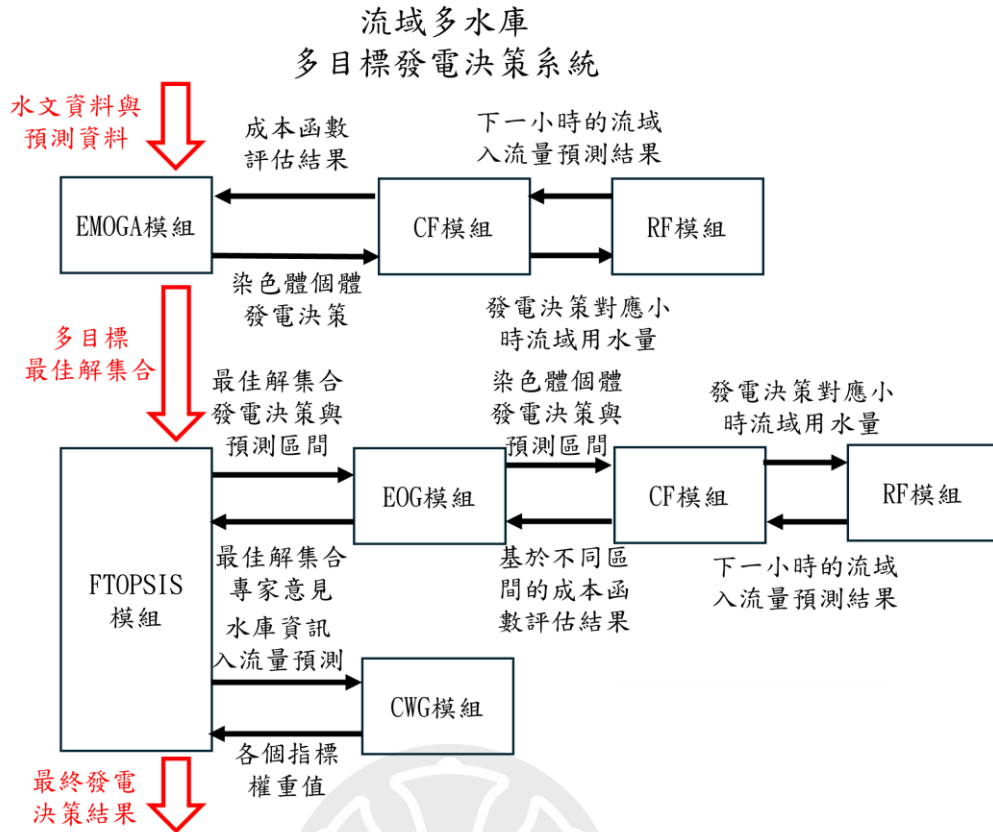


圖 5-2 二階段逐小時多水庫多目標發電最佳化系統與模組架構圖

### 5.2.1 EMOGA 模組 (ev-MOGA 多目標演算法)

在解決多目標問題之前，需要先對最佳化問題進行定義，多目標最佳化需要量化的數值定義，將每一個目標問題轉換成求最大值或是最小值的數值問題，而每一個解的最佳與最差的權衡則需要透過多目標問題進行解決。多目標最佳化方法的核心價值在於找出各個目標的最佳解與其權衡解的分布，作為一個集合產出，這些產出的集合的解有著不可取代性，這意味著此集合內的任意一個解皆無法全面優於集合內的其他解。產生這些包含權衡的解集合之後，才能夠提供後面決策方法做最佳的決策選擇依據。

為了定義問題的評估標準，本文提出兩個成本函數如式(5-6)和(5-9)分

別代表流域用水量和排洪風險。因為其包含兩個目標可見這是一個多目標優化問題。針對這類問題，可以採用多種方法，如 MOGA、MOPSO、MODE、MOSE、ev-MOEA 等。其中[89]中的 ev-MOGA 是一種基於  $\epsilon$ -支配概念的精英式 MOGA（多目標遺傳算法）。在 ev-MOGA 中，目標函數空間被劃分為若干個區域，形成以  $\epsilon$  為邊長的網格。 $\epsilon$ -支配的概念基於這樣的思想：區域內的特定解優於屬於該區域的其他解。與 ev-MOEA 算法相比，ev-MOGA 能動態調整 Pareto 前沿防止極端解的丟失，從而使後續決策模型擁有更廣泛的選擇範圍。同時，本文引入[89]的支配與  $\epsilon$ -支配的概念。

ev-MOGA 的運作流程如圖 5-2 所示。在 ev-MOGA 中每次計算成本函數時，會調用 CF 模組，並根據當前染色體輸出提供每個水庫的發電配比。這個配比將與每小時的發電命令相乘，以確保實際的發電總量輸出固定的前提下。然而由於每個水庫存在動態約束條件，例如可發電用水量（需要透過當前水位與可用水量進行計算）、排洪特殊情況（排洪發生時禁止發電）等資料，這些約束條件又會隨著過去的決策或是當前的狀態而有不一樣的變化，並且在大甲溪流域中存在許多小容量的水庫，這些水庫受到小時決策的影響甚大，這些都是需要考量的因素。這些計算出的發電量將會調整以符合這些約束條件。這一過程會在 CF 模組中詳細說明。CF 模組將會提供計劃中的水庫發電量給 RM 模組，RM 模組隨後會返回下一小時的流量預測和更新的水位信息。通過數次迭代之後，這一過程將產生 12 小時的發電規劃、用水量和最終的水位資訊。這些將用來評估兩個成本函數的評估值。最終 EMOGE 模組將獲得最佳的候選解集合，並將其傳送給 FTOPSIS 模組。

接下來我們針對 EMOGA 模組的多目標方法 ev-MOGA 進行說明，在

ev-MOGA 整體的操作流程中會使用到三個集合，分別是  $X_P^k$ 、 $X_A^k$  與  $X_G^k$ ，其中  $k$  表示 ev-MOGA 的第  $k$  次迭代結果。 $X_P^k$  為主要群集，包含所有演化過後的解、 $X_A^k$  表示第  $k$  次迭代產出的  $\varepsilon$ -Pareto 最佳解集合，並且該集合中的所有解不能被集合內的任何其他候選解所  $\varepsilon$ -支配。 $X_G^k$  則是透過  $X_P^k$  與  $X_A^k$  兩個集合進行隨機抽選交配與突變生成的變異染色體，這些染色體會被暫時存在  $X_G^k$  當中。

接下來為了減少記憶體和計算資源的消耗，ev-MOGA 提出一種透過  $Dbox_\rho$  的設定如式(5-1)，其中 ev-MOGA 將  $X_A^k$  的區間間隔依據每一個成本函數集合內每個維度之最大值與最小值劃分為  $Dbox_\rho$  個區塊，每一個區塊內只允許一組解存在。這樣可以有效減少由於過多密集聚集的解所導致的資源消耗。其相關描述對於集合  $X_A^k$  表示如式(5-1)至(5-3)。

$$\varepsilon_\rho = \left( \frac{F_\rho^{\max} - F_\rho^{\min}}{Dbox_\rho} \right) \quad (5-1)$$

$$F_\rho^{\max} = \max_{\rho \in \{1, \dots, c\}} (F_\rho(X_A^k)) \quad (5-2)$$

$$F_\rho^{\min} = \min_{\rho \in \{1, \dots, c\}} (F_\rho(X_A^k)) \quad (5-3)$$

其中  $Dbox_\rho$  可由使用者自定義，用來描述第  $\rho$  個成本函數空間，並將其劃分為若干個區塊。 $F_\rho^{\max}$  和  $F_\rho^{\min}$  分別表示集合  $X_A^k$  中第  $\rho$  個成本函數的最大和最小評估結果。 $\varepsilon_\rho$  表示為第  $\rho$  個成本函數的網格寬度，其寬度會依據  $X_A^k$  當代

的  $F_\rho^{\max}$  和  $F_\rho^{\min}$  而動態調整。接下來我們將集合  $X_A$  輸入到  $Fbox_\rho$  中來找出每一個解所落在的網格位置，如式(5-4) 所示。

$$Fbox_\rho(X_i) = \left\lceil \frac{F_\rho(X_i) - F_\rho^{\min}}{F_\rho^{\max} - F_\rho^{\min}} \cdot Dbox_\rho \right\rceil, X_i \in X_A^k \quad (5-4)$$

其中  $Fbox_\rho$  用來描述第  $\rho$  成本函數的評估結果落在哪一個區塊當中，並且  $Fbox_\rho(X_i) \in \{1, 2, \dots, Dbox_\rho\}$ 。透過  $Fbox$  的定義與  $\varepsilon$ -支配整合即可得到一個包含均勻分布的最佳解集合。為了簡化說明我們定義支配為符號  $\prec$ ，例如假設有兩組解  $X_i$  與  $X_j$ ，其中包含產出該解的所有必須輸入，以本文為例是所有水庫的發電配比，並且  $F(X_i)$  與  $F(X_j)$  表示這些輸入帶入成本函數後所產出的結果，成本函數包含多目標的結果，所以其呈現的會是一個多維度的空間，以本文為例為一個二維空間。那麼  $F(X_i) \prec F(X_j)$  則表示  $X_i$  支配  $X_j$  用來描述向量解  $X_i$  帶入所有成本函數所在的空間座標後可以支配向量解  $X_j$  所帶入的結果。當兩個解所在的位置落在同一個 Box 內時， $F(X_i)$  依舊可以支配  $F(X_j)$ 。

在 ev-MOGA 的運行過程中，使用三個集合，分別是  $X_P^k$ 、 $X_A^k$  與  $X_G^k$ ，這些集合的完整運作流程會展示於圖 5-8 的步驟 9 至 22 當中。

## 5.2.2 CF 模組（成本函數設計）

為了應對極端天氣條件帶來的排洪風險，整個流域的優化過程中不能

僅考慮最佳的發電效率（最低的流域用水量）。這是因為較高的發電效率往往伴隨著每個電廠的水頭（水位差）提高，這在瞬間大量的降雨導致的入流量持續增大的情境下，如颱風等，將會顯著增加產生排洪決策的風險。儘管在海島氣候當中，極端天氣實際發生的事件通常低於整一年期間中的10%以下；然而洪水事件和水資源浪費所帶來的大量經濟損失卻非常容易發生在此期間當中。並且這些事件帶來的經濟損失往往會比透過最佳化方法所節省的水資源還要多。儘管如此，在任何時間點都考量排洪風險也並不有利，如前面所述，較低的排洪風險所帶來的是發電效率的低下。要解決此相矛盾的決策指標是本文的研究目標。為此本節將對流域用水量（隱含發電效率與排洪決策）與排洪風險兩個指標進行明確的數值量化定義。本文提出兩個成本函數來評估有關流域用水量和排洪風險的所有決策，如式(5-6)和(5-9)所示。這些成本函數將用於 ev-MOGA 生成多樣化的候選解集，從而增強隨後決策系統中可供選擇的多樣性。另一方面，所有的發電決策通常只有在一段時間後才會對流域水庫水資源的變化產生顯著影響，並且由於流域中包含小水庫的情形，若是取用太長的時間間隔會限制整個最佳化方法的尋空間。為了解決這個問題，本文將上游水庫的流入預測與基於神經網路的徑流模組結合，模擬所有決策對下一小時水庫流入影響的變化。而成本函數實際會透過不斷迭代至 12 小時所呈現的流域水資源預測狀態去進行評估。關於逕流模型的設計方法與預測資料的整合，具體內容本文將在第 5.2.3 節中說明。成本函數利用接下來 12 小時的模擬結果作為評估的基礎。假設由 ev-MOGA 產生的其中一組解為  $g$ 。其中  $g$  是一個向量包含流域內所有水庫的發電分配比例。這些比例首先被正規化，使其總和等於 1，然後乘以流域排程發電指令  $P_c(s)$ ，以生成各水庫的發電分配指令。然而，這些發電分配指令尚未考慮實際情境約束條件，例如民生灌溉需求或發電水位限制。因此，這些發電分配指令根據發電約束條件進

行調整後可以得到  $P(s)$  如式(5-5)所示，其中  $P(s)$  代表在時間  $s$  流域內所有水庫的發電指令，包括未來 12 小時的逐小時結果。

$$P(s) = (P_1(s), \dots, P_n(s)), s \in \{1, \dots, 12\} \quad (5-5)$$

其中  $P_\Phi(s)$  表示第  $\Phi$  個水庫在時間  $s$  的模擬發電量，這些發電量將由 *ev-MOGA* 產生配比並與考量約束條件後進行調節。因此，每一個  $s$  時間點下的任一水庫模擬發電量  $P_\Phi(s)$  都會受到該時間點下的約束條件的下限和上限所限制，這些約束條件考量政府水位規線、民生灌溉、最大最小發電水位限制等等諸多條件。這部分將於 5.3.1 章節中進行說明，並且這些約束條件都會根據當前的水庫情境進行動態改變。本文使用到的成本函數如式(5-6)與(5-9)，其中  $WF$  表示流域用水成本函數， $FF$  表示流域排洪風險成本函數。

CF 模組的流程圖如圖 5-3 所示。最初，CF 模組從 *EMOGA* 或 *EOG* 模組接收每一個水庫的發電規劃配比向量解  $g$ 。接著計算發電比例和  $P_c(s)$ 。可獲得每個流域的目標分配發電指令  $P^*(s)$ 。然而  $P^*(s)$  不一定與實際的發電限制相符。CF 模組分析每個水庫的發電指令是否符合時間  $s$  的這些限制條件。如果任何限制條件未能符合，則該水庫多出或不足的發電量將在流域內的其他水庫之間平均重新分配。這種機制確保在所有情境下，流域內的發電指令均符合實際的發電限制。雖然最終還是有可能出現流域水庫無法完成來自調度中心的流域調度發電指令的情況，這將透過遲罰因子進行遲罰並且會在後續章節中進一步解釋。

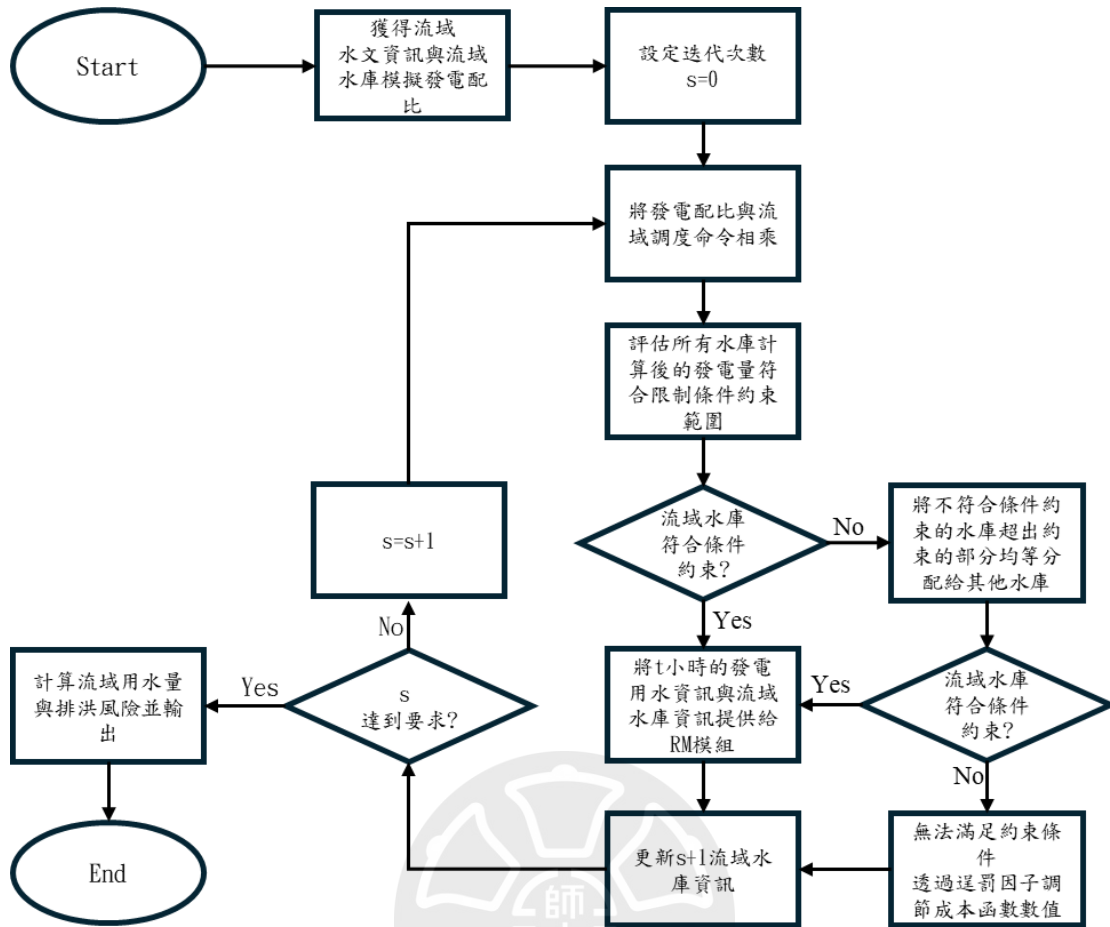


圖 5-3 CF 模組運作流程圖

流域用水成本函數  $WF$  定義為：

$$WF = \frac{\sum_{s=1}^{12} \sum_{\Phi=1}^n (\gamma \cdot W_{\Phi}(P_{\Phi}(s)) + \alpha \cdot fd_{\Phi}(s))}{12} \quad (5-6)$$

其中  $n$  表示流域中水庫的總數， $s$  表示第  $s$  小時的模擬結果。 $W_{\Phi}(P_{\Phi}(s))$  表示第  $\Phi$  個水庫在第  $s$  小時的發電用水量， $fd_{\Phi}(s)$  表示第  $\Phi$  個水庫在第  $s$  小時的排洪量， $\alpha$  是在洪水發生期間用於調整懲罰權重的權重調整參數。此外由於發電的限制，實際輸出可能無法與來自調度中心的流域調度發電指令相一致。為了確保這種差異不影響成本函數的評估標準，設計參數  $\gamma$  和  $\beta$

來解決此情況，如式(5-7)和(5-8)所示。

$$\beta = \frac{\sum_{s=1}^{12} P_c(s)}{\sum_{s=1}^{12} \sum_{\Phi=1}^n P_{\Phi}(s)} \quad (5-7)$$

$$\gamma = \begin{cases} \beta & ,if \beta = 1 \\ 1.5 \cdot \beta & ,if \beta \neq 1 \end{cases} \quad (5-8)$$

其中  $P_c(s)$  表示時間  $s$  來自調度中心的流域調度發電指令。式(5-7)用來解決當發電不匹配的時候造成成本函數失準的情形，而式(5-8)則發電不匹配的時候對函數施加懲罰。

第二個成本函數  $FF$  描述未來 12 小時內發電決策與排洪事件對流域排洪風險的影響，如式(5-9)所示。

$$FF = \sum_{\Phi=1}^n \frac{w_{\Phi} \cdot preC_{\Phi}}{C_{\Phi,MAX}} \quad (5-9)$$

其中  $preC_{\Phi}$  表示第  $\Phi$  個水庫在 12 小時後的模擬庫容量，如式(5-10)所示，並將與 RM 模組集成以得出結果。 $w_{\Phi}$  表示第  $\Phi$  個水庫的權重，可以由使用者自行設定，用來表示每一個水庫對流域的重要性。 $C_{\Phi,MAX}$  表示第  $\Phi$  個水庫的最大儲存庫容量。

$$preC_{\Phi} = C_{\Phi}(0) + \sum_{s=1}^{12} (preI_{\Phi}(s) - W_{\Phi}(P_{\Phi}(s)) - fd_{\Phi}(s)) \quad (5-10)$$

其中  $C_{\Phi}(0)$  表示第  $\Phi$  個水庫在初始時間的庫容量， $preI_{\Phi}(s)$  表示第  $\Phi$  個水庫在第  $s$  小時的預測入流量。如果該水庫是最上游的水庫，將使用預測的入流量。

有了式(5-6)與(5-9)兩個成本函數的定義結果，將可以量化所有決策對於未來 12 小時的影響，這將發電效率與風險參數進行明確的量化，讓整體方法可以有明確的優化目標。

### 5.2.3 RM 模組

由於水庫的決策需要一定時間才能比較明顯的反應出決策對於流域的影響好壞，並且流域間包含較小容量的水庫，因此本文以小時為單位進行時間取樣。並且為了描述各水庫的發電用水與排洪放水量決策對整個流域的影響，需要一個實用可靠的定量逕流模型來描述流域水庫之間水資源傳遞的過程，並識別水庫歷史放水量與下游水庫入流量之間的關係，以達到模擬所有決策對整體流域各水庫水資源入流量的影響。本文利用類神經網路來模擬地表逕流，其輸入數據為與目標水庫直接相連的上游水庫的歷史放水量（包括發電用水量和排洪水量）。若水庫為流域的最上游水庫，則採用預測數據取代。其整體流域水庫架構圖如圖 5-4 所示。所有的數據以逐小時平均 CMS 作為流量單位。輸出為所有水庫下一小時的預測入流量。神經網路模型的框架如圖 5-5 所示，而目標水庫所使用的輸入數據則在式(5-11)中說明。

$$uror_{\Phi}(t) = \begin{bmatrix} uro_1^{\Phi}(t-p) & uro_2^{\Phi}(t-p) & \cdots & uro_{hr_{\Phi}}^{\Phi}(t-p) \\ uro_1^{\Phi}(t-p+1) & uro_2^{\Phi}(t-p+1) & & uro_{hr_{\Phi}}^{\Phi}(t-p+1) \\ \vdots & & & \\ uro_1^{\Phi}(t) & uro_2^{\Phi}(t) & & uro_{hr_{\Phi}}^{\Phi}(t) \end{bmatrix} \quad (5-11)$$

其中  $uror_{\Phi}(t)$  表示第  $\Phi$  個水庫在時間  $t$  的放水量信息，並包括該水庫上游相鄰流域水庫的放水量資料。 $hr_{\Phi}$  表示第  $\Phi$  個水庫的上游水庫總數。 $uro_{hr_{\Phi}}^{\Phi}(t)$  表示第  $hr_{\Phi}$  個上游相鄰水庫在時間  $t$  的排洪資訊， $p$  表示所使用的歷史排水量的歷史時間。從圖 5-3 與式(5-11)中可以看出其輸入資料會因為上游水庫數量不同而有所改變，而其連結的所有上游水庫放水量都與其下游水庫入流量有著高度的相關性。

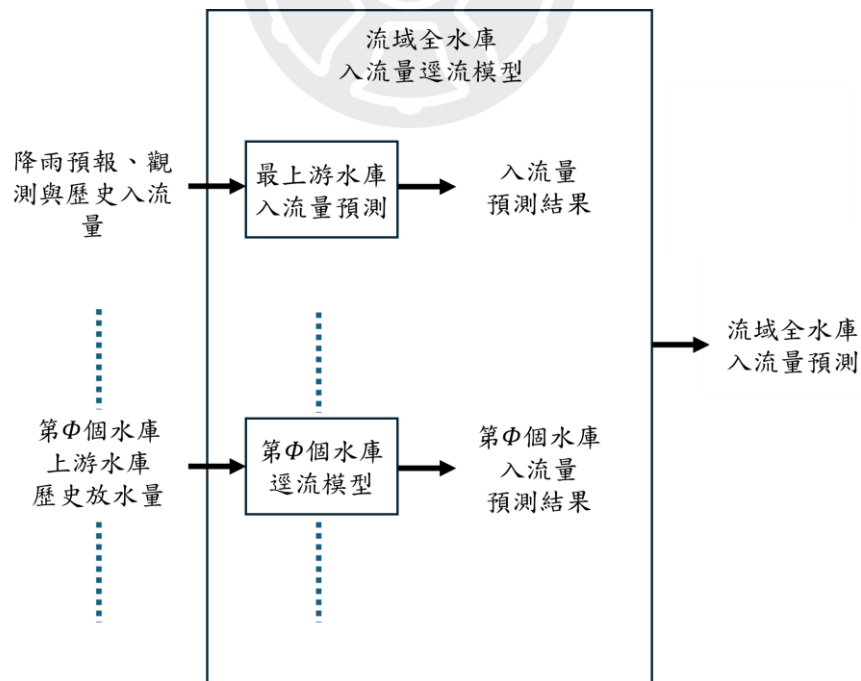


圖 5-4 流域全水庫逕流模型架構圖




圖 5-5 逕流模型類神經網路架構圖

接著，我們將所有來自  $uror_\Phi(t)$  的數據輸入神經網路後，將可以獲得針對每個水庫在未來一小時的流域入流量的預測徑流模型，並且最上游水庫將透過入流量預測整合進 RM 當中，整體流域的  $t+1$  入流量預測如式(5-12)所示。

$$RM = [preI_1(uror_1(t)) \quad \cdots \quad preI_n(uror_n(t))] \quad (5-12)$$

其中  $preI_\Phi(uror_\Phi(t))$  表示在時間  $t$  第  $\Phi$  個水庫下一小時的預測入流量。如果該水庫是流域中的最上游水庫，則使用每小時的入流預測數據代替神經網路。

有了逕流模型 RM 模組的設計，使得流域間水庫的水資源交換的時間與空間相關性得到具體的描述。這將使得 CF 模組可以明確推演出每一個決策對於未來的水資源的影響，也成為本文提出最佳化方法奠定基礎。

#### 5.2.4 FTOPSIS 模組

Fuzzy TOPSIS [104]用於解決涉及模糊不確定性的決策問題。該方法基於模糊集合理論和特徵向量分析，具有處理模糊性、多準則評估、提高可解釋性以及適用於非線性系統的優勢。目前它已被廣泛應用於供應商選擇、製造參數優化、產品評估及能源政策等多個領域。如前所述海島型氣候的極端特性需要針對不同天氣情境下採取截然不同的發電策略。舉例來說，在晴天時保持較高的流域水位有助於提高位能並提升發電效率，雖然會增加排洪風險，但考量天氣情境的狀況下這是最佳選擇。相反的在颱風或強降雨期間則應該優先適度的降低水位找出發電效率與風險的平衡。因此在不同的天氣情境下，這兩項指標的重要性會有顯著的變化。此外由於水庫入流量預測本質上具有不確定性，將預測區間納入系統可以使該方法更好地應對預測的不確定性。fuzzy TOPSIS 將兩個部分進行整合，其一為透過本文設計的 EOG 模組引入預測區間所產出的多位專家意見與本文設計的 CWG 模組整合未來入流量預測、當前水位等資訊去明確解釋未來兩個目標的權重分配。透過專家意見解釋每個解的方針與多目標權重分配的調節，最終實現符合氣候情境的最佳發電決策制定結果。

FTOPSIS 模組使用經典的模糊決策方法 fuzzy TOPSIS，此方法會依據彙整專家所提供的意見後，並評估每個指標的重要程度，將所有解的幾何距離與模糊邏輯進行整合，最終得到最佳決策結果。由於其意見整合的特性、模糊對於資料不確定性的有效性以及對於每一個指標可以明確調節權重等特色，使其非常適合整合預測區間等具有區段性的預測數據。其方法所需的專家意見與目標權重調節則由本文的 EOG 和 CWG 模組生成，整體數據流程如圖 5-6 所示。從圖 5-6 中可以看出 fuzzy TOPSIS 從 EOG 模組

獲取兩位專家的意見。這些專家意見是透過 EOG 模組接收最上游水庫的入流預測區間的上下限後產出，EOG 模組將這些預測區間重新引入 CF 模組，這些預測區間的最大值與最小值將會重新取代原本的最上游水庫入流量預測重新送入給 CF 模組進行評估。最終每一組解將得到兩個不同的評估結果，這些結果將被統整後產出悲觀和樂觀專家的意見，詳細過程會在章節 5.2.5 進行說明。CWG 模組使用模糊邏輯進行設計，透過模糊邏輯的可解釋性、資料的不確定性之適應能力與容易整合專家意見等特性。能夠整合多種類型的數據（如降雨預測、入流量預測等）。本文以最上游水庫的次日平均入流量和最上游水庫的即時庫容作為輸入，以生成每個目標成本函數的權重。這些權重反映當前情境下兩個成本函數的相對重要性。最後，FTOPSIS 模組將使用這些結果來確定最佳解。

Fuzzy TOPSIS 是一種整合模糊邏輯與多準則決策分析的數值排序方法，適用於處理不確定性的資訊。以下將介紹其基本的運作流程：首先先蒐集各方案（最佳解）對於個評估準則的模糊評分結果（專家意見），通常以三角模糊數表示。接著透過正規化處理與合併彙總後，在與每一個目標的權重數值相乘，產生加權模糊決策矩陣。有了此矩陣後，透過找出每一個方針的模糊正理想解（Fuzzy Positive Ideal Solution, FPIS）與模糊反理想解（Fuzzy Negative Ideal Solution, FNIS）後。計算所有方案與兩個理想解的相對距離。最終所有的方案都會得到一組相對接近度（Closeness Coefficient, CC）作為評估好話的量化指標，越接近 FPIS 同時越遠離 FNIS 者將會成為最佳解並擁有最高的 CC 量化數值。此方法能有效整合模糊資訊與多目標評估，常用於風險評估、資源分配與多準則決策等領域。

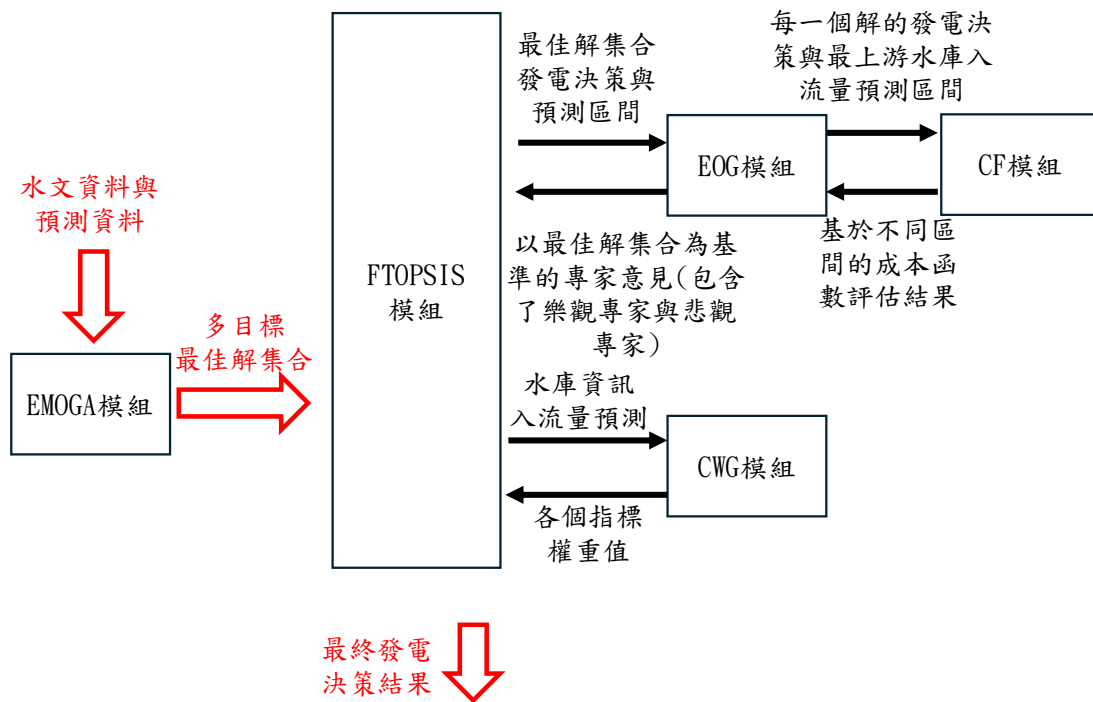


圖 5-6 FTOPSIS 模組系統架構圖

以下部分將介紹 FTOPSIS 模組，即 Fuzzy TOPSIS 方法。首先定義專家對所有方案的意見如式(5-13)所示：

$$J_e = \begin{matrix} A_1 \\ A_2 \\ \vdots \\ A_m \end{matrix} \begin{bmatrix} e r_{11} & e r_{12} & \cdots & e r_{1c} \\ e r_{21} & e r_{22} & \cdots & e r_{2c} \\ \vdots & \vdots & \cdots & \vdots \\ e r_{m1} & e r_{m2} & \cdots & e r_{mc} \end{bmatrix} \quad (5-13)$$

其中  $J_e$  表示第  $e$  位專家對所有備選方案的評估，在 Fuzzy TOPSIS 當中這將會是一個歸屬函數。而  $A_i$  表示第  $i$  個方案。 $e r_{ij}$  表示第  $e$  位專家對第  $i$  個方案中的第  $j$  個準則（成本函數評估）。所有可能的評估準則列於表 5-1 中。從表中可以看出，所有的意見都是以歸屬函數的方式呈現，並且歸屬函數使用三角模糊函數，其中  $e r_{ij} = (e a_{ij}, e b_{ij}, e c_{ij})$  表示語言變數的左極點、中間點和右極點，對應於第  $e$  位專家對第  $i$  個方案下的第  $j$  個準則（成本函數評

估)的評估。在本文中，這些歸屬函數都會透過 EOG 模組進行產生，這將會在後續的章節進行說明。並且 Criteria grad 將會作為 EOG 模組求出的專家意見索引結果。

表 5-1 歸屬函數對應表

Rank	Criteria grade	Membership function
Very low(VL)	1	(0, 0, 0.17)
Medium low(ML)	2	(0, 0.17, 0.33)
Low(L)	3	(0.17, 0.33, 0.5)
Medium(M)	4	(0.33, 0.5, 0.67)
High(H)	5	(0.5, 0.67, 0.83)
Medium high(MH)	6	(0.67, 0.83, 1)
Very high(VH)	7	(0.83, 1, 1)

這些專家意見將通過式(5-14)進行整合與正規化後，最終可以得到統整所有專家的專家意見矩陣，如式(5-15)所示。

$$x_{ij} = \left( \frac{a_j^-}{\max_e \{c_{ij}\}}, \frac{a_j^-}{\frac{1}{K} \sum_{e=1}^K b_{ij}}, \frac{a_j^-}{\min_e \{a_{ij}\}} \right) = (a_{ij}, b_{ij}, c_{ij}) \quad (5-14)$$

$$, a_j^- = \min_i \left\{ \min_e \{a_{ij}\} \right\}, i \in \{1, \dots, m\}, e \in \{1, \dots, K\}$$

$$R = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1c} \\ x_{21} & x_{22} & \cdots & x_{2c} \\ \vdots & \vdots & \cdots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mc} \end{bmatrix} \quad (5-15)$$

其中  $R$  表示經過正規化與匯總後的專家意見矩陣、 $K$  表示專家的總數，本文將  $K$  設定為 2，表示樂觀和悲觀專家的意見。在整合專家提供的語義意見後。 $x_{ij}$  表示語義變數於第  $i$  方案下的第  $j$  個準則意見結果為一三角模糊數。最後，整合所有專家意見和權重的矩陣被表示如式(5-16)。

$$V = \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1c} \\ v_{21} & v_{22} & & v_{2c} \\ \vdots & & \ddots & \\ v_{m1} & v_{m2} & & v_{mc} \end{bmatrix} \quad (5-16)$$

其中  $v_{ij} = (v_{ij1}, v_{ij2}, v_{ij3})$ ，並且  $v_{ij} = w_j \cdot x_{ij}$ ，同時  $w_j$  表示第  $j$  個準則下所代表的權重參數，該參數將通過 CWG 模組產生並且表示該天氣情境下每一個準則的重要程度。這些權重的產出過程將再在第 5.2.6 節中介紹。透過式(5-16)得到匯總意見的  $V$  矩陣後，接著需要找出所有方案中每個準則的最大值  $A^+$  和最小值  $A^-$ ，如式(5-17)和式(5-18)所述。

$$\begin{aligned} A^+ &= \{v_1^+, \dots, v_c^+\} \\ &= \left\{ \left( \max_{i \in \{1, \dots, m\}} (v_{ij3}^+) \right), j = 1, \dots, c \right\} \end{aligned} \quad (5-17)$$

$$\begin{aligned} A^- &= \{v_1^-, \dots, v_c^-\} \\ &= \left\{ \left( \min_{i \in \{1, \dots, m\}} (v_{ij1}^-) \right), j = 1, \dots, c \right\} \end{aligned} \quad (5-18)$$

其中  $A^+$  和  $A^-$  分別表示所有成本函數在  $m$  個備選方案中的正理想解和反理想解，用來描述此最佳解集合每一個目標的最佳與最差結果。由於這些數值都是由歸屬函數模糊數值進行表示。為了要描述兩組模糊數之間的距離計算方法，本文透過模糊距離函數  $d(x_1, x_2)$  進行兩個模糊數的距離計算，其方程式表示如式(5-19)所示。假設有兩個模糊數  $x_1 = (a_1, b_1, c_1)$  和  $x_2 = (a_2, b_2, c_2)$ ，其模糊距離可以透過式(5-19)計算求出。最後透過將所有方法與  $A^+$  和  $A^-$  理想解的進行模糊距離計算後如式(5-20)與(5-21)，最終可以得出所有方案與  $A^+$  的距離  $d_i^+$  以及與  $A^-$  的距離  $d_i^-$ 。

$$d(x_1, x_2) = \sqrt{\frac{1}{3} \left[ (a_1 - a_2)^2 + (b_1 - b_2)^2 + (c_1 - c_2)^2 \right]} \quad (5-19)$$

$$d_i^+ = \sum_{j=1}^c d(v_{ij}, v_j^+) \quad (5-20)$$

$$d_i^- = \sum_{j=1}^c d(v_{ij}, v_j^-) \quad (5-21)$$

其中  $d_i^+$  表示第  $i$  個方案與正理想解之間的距離， $d_i^-$  表示第  $i$  個方案與反理想解之間的距離，且  $i = 1, 2, \dots, m, c = 2$ 。

接下來，將計算第  $i$  個相對接近度  $CC_i$ ，如式(5-22)所示。

$$CC_i = \frac{d_i^-}{d_i^+ + d_i^-} \quad (5-22)$$

最終透過找出最大的  $CC_i$ ，即可找出最佳解集合內符合當前氣候情境的最

佳解。

### 5.2.5 EOG 模組

本節介紹專家意見生成系統。所有候選解的發電決策將重新輸入至 CF 模組，以計算成本函數。然而此情況的不同之處在於，最上游水庫的入流量預測結果將根據預測區間的最大值和最小值重新作為最上游的入流量結果輸入給成本函數。因此同一組解將生成兩組計算結果：一組代表使用預測區間最大值下的最上游水庫入流量下的成本函數值，這意味著流域有著更高的入流量與風險，另一組代表使用預測區間最小值下的最上游水庫入流量下的成本函數值，這意味著流域有著較低的入流量與風險。這兩組解集合將被整合後以計算其在每一個目標下的最大值和最小值。這些數據將作為動態調節用來產出專家意見語意指標的每一個歸屬函數的區間最大值與最小值。這些歸屬函數將依據最大與最小值進行等距離分隔成相對應的語意變數，其歸屬函數示意圖如圖 5-7 所示。最終每一個數值將輸入對應的歸屬函數後找出其的最大語義變數作為專家意見的語意輸出結果。通常來說，樂觀專家會對於所有方針提供傾向發電效率導向的專家意見。反之，悲觀專家則會對於所有方針提供傾向風險管控的專家意見。

由於 EOG 模組會在 ev-MOGA 找出候選解集合後才進行運算，因此假設由 ev-MOGA 產生的最佳解集合為  $X_A = \{g_1^A, \dots, g_m^A\}$ ，其中  $g_i^A$  表示  $X_A$  集合中第  $i$  個候選解。該函數利用最上游水庫入流量預測區間的最小值  $FL(g_i^A)$  和最大值  $FH(g_i^A)$ ，如式(5-23)和式(5-24)所示。

$$FL(g_i^A) = \{FL_1(g_i^A), FL_2(g_i^A)\} \quad (5-23)$$

$$FH(g_i^A) = \{FH_1(g_i^A), FH_2(g_i^A)\} \quad (5-24)$$

其中  $FL_1$  和  $FH_1$  分別表示基於最上游水庫入流量預測區間的最小值和最大值的流域用水成本函數，除了最上游水庫入流量預測使用不同的數據之外，其他計算邏輯都與式(5-6)相同。然而最上游水庫入流量的變化仍然會影響水位和發電效率，這種情況在天氣不穩定的時候會更加明顯。 $FL_2$  和  $FH_2$  分別表示與最上游水庫入流最小值和最大值相關的排洪風險因素。成本函數與式(5-9)相同。本文提出一套動態調節的歸屬函數用來產出專家的語意見，為了方便彙總本文以目標函數作為分類依據定義兩個集合以整合入流預測區間的最大值和最小值，其整合結果如式(5-25)所示，其流域水用量與排洪風險因子集合分別表示於式(5-26)和式(5-27)。同時每個成本函數的最大值和最小值分別定義為式(5-28)和式(5-29)。

$$FC(g_i^A) = \{FC_1(g_i^A), FC_2(g_i^A)\} \quad (5-25)$$

$$FC_1(g_i^A) = \{FL_1(g_i^A), FH_1(g_i^A)\} \quad (5-26)$$

$$FC_2(g_i^A) = \{FL_2(g_i^A), FH_2(g_i^A)\} \quad (5-27)$$

$$FC_j^{\max} = \max_{X_1 \in X_A} (FC_j(X_1)), j = 1, 2 \quad (5-28)$$

$$FC_j^{\min} = \min_{X_1 \in X_A} (FC_j(X_1)), j = 1, 2 \quad (5-29)$$

其中  $FC_j^{\max}$  和  $FC_j^{\min}$  分別表示第  $j$  個成本函數的最大值和最小值。接下來，如式(5-30)所示，定義歸屬函數的區間。歸屬函數如式(5-31)所示。

$$\text{delta}_j = \frac{(FC_j^{\max} - FC_j^{\min})}{6} \quad (5-30)$$

$$u_i^j = \begin{cases} (FC_j^{\min}, FC_j^{\min}, FC_j^{\min} + l \cdot \text{delta}_j) & , \text{if } l = 1 \\ (FC_j^{\min} + (l-2) \cdot \text{delta}_j, FC_j^{\min} + \\ (l-1) \cdot \text{delta}_j, FC_j^{\min} + l \cdot \text{delta}_j) & , \text{if } 1 < l < 7 \\ (FC_j^{\min} + (l-2) \cdot \text{delta}_j, FC_j^{\max}, FC_j^{\max}) & , \text{if } l = 7 \end{cases} \quad (5-31)$$

其中  $\text{delta}_j$  表示第  $j$  個成本函數的等距離間格，作為動態調整使用，其目的在於描述每個歸屬函數的區間間格。並且每個歸屬函數的左極點、中點和右極點可以如式(5-31)所示。基於式(5-32)，可以得出關於所有備選方案的樂觀和悲觀專家的意見。

$${}_e l_{ij}^* = \begin{cases} \arg \max_{l \in \{1, \dots, 7\}} (u_l^j (FH_j(g_i^A))) & , \text{if } e = 1 \\ \arg \max_{l \in \{1, \dots, 7\}} (u_l^j (FL_j(g_i^A))) & , \text{if } e = 2 \end{cases} \quad (5-32)$$

從式(5-32)可以看出， ${}_e l_{ij}^*$  是一個索引值會與表 5-1 的 Criteria Grade 進行對應，表示每個專家的語意意見與之相應的歸屬函數會被帶入  $J_e$  矩陣的  ${}_e r_{ij}$  當中，當所有的解集合都進行計算之後，最終所有的專家意見矩陣都將被計算出來。

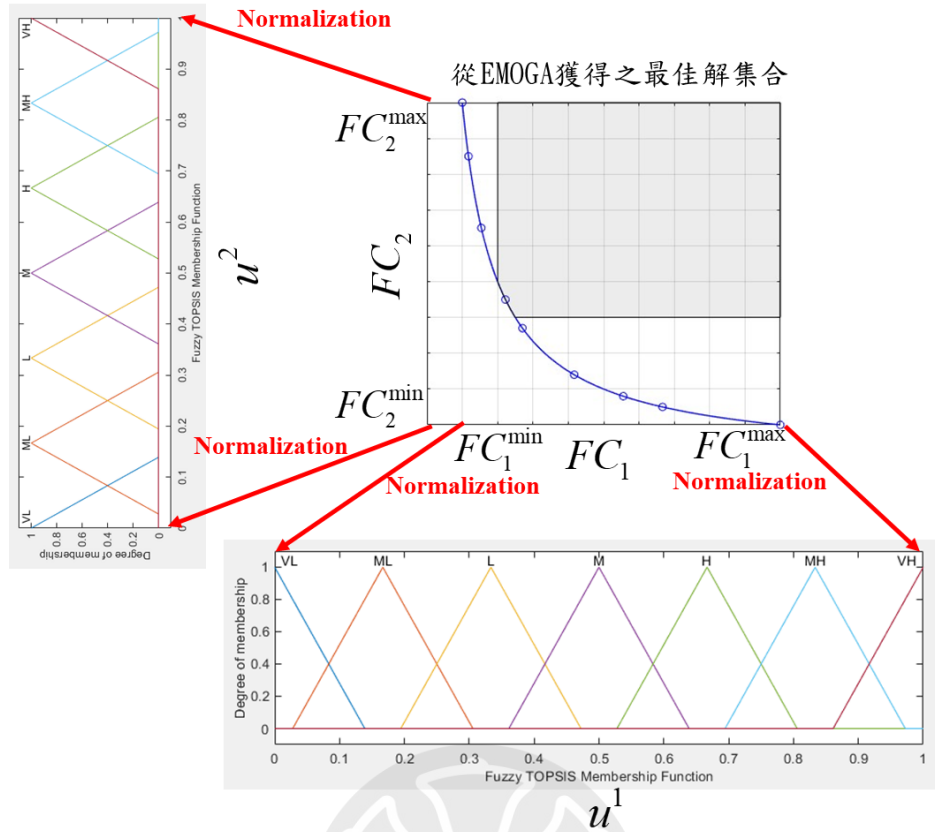


圖 5-7 EOG 模組歸屬函數示意圖

## 5.2.6 CWG 模組

模糊邏輯已廣泛應用於各個領域，而 Mamdani 方法是一種傳統的模糊推理系統。它利用模糊規則集和推理方法來處理模糊輸入並生成模糊輸出。Mamdani 方法在控制系統、模糊邏輯和模糊控制目前已經包含許多相關的應用實例，不論是自動化控制、自走車、避障系統中都有它的一席之地。在本文中，Mamdani 方法被用於 fuzzy TOPSIS 中的權重函數篩選。

本文使用最上游水庫的即時庫容量和未來 24 小時的平均入流量預測作為輸入數據，這是由於最上游水庫首當其衝會面對整個流域集水區經由降雨而產生的大量入流量，而最上游水庫的即時庫容量將直接反映其當前

時間狀態下對於水資源的容納能力、而最上游水庫未來 24 小時的平均入流量預測則反映未來集水區對於水庫所帶來的入流量表現，這兩個輸入應該可以在一定程度上代表整個系統的風險程度。而輸出的部分則代表所有成本函數的重要程度，以本文來說就是發電效率優先與排洪風險優先兩項指標在當前情境下的重要程度。因此本文也將簡要描述 Mamdani 的運作流程與本文使用的方法。

本文的規則庫當中每條模糊規則呈現如式(5-33)所示。

$$\begin{aligned} R^\Theta: & \text{ if } s_1 \text{ is } A_1^\Theta \text{ and } s_2 \text{ is } A_2^\Theta, \dots, s_b \text{ is } A_b^\Theta \\ & \text{ then } y_1 \text{ is } Y_1^\Theta \text{ and } y_2 \text{ is } Y_2^\Theta \quad \Theta = 1, \dots, n_r \end{aligned} \quad (5-33)$$

其中  $A_b^\Theta$  表示第  $\Theta$  條規則中第  $b$  個輸入的語義變數，為一個模糊集。 $A_b^\Theta(s_b)$  表示變數  $s_b$  對歸屬函數  $A_b^\Theta$  的歸屬度； $Y^\Theta$  表示輸出語義變數， $n_r$  表示規則總數， $b$  表示輸入變數的總數。每條規則的前件部如式(5-34)所示。

$$Y^\Theta(s_1, \dots, s_b) = u_{A_1^\Theta}(s_1) \wedge u_{A_2^\Theta}(s_2) \wedge \dots \wedge u_{A_b^\Theta}(s_b) \quad (5-34)$$

其中  $u_{A_b^\Theta}$  表示  $\Theta$ -th 規則下的第  $b$  個輸入的歸屬函數。於是第  $\Theta$ -th 規則下的推論結果表示如式(5-35)：

$$u_{Y_v^\Theta}^*(y_v) = Y^\Theta(s_1, \dots, s_b) \wedge u_{Y_v^\Theta}(y_v), v = 1, 2 \quad (5-35)$$

接著，透過式(5-35)整合出所有規則後求出式(5-36)。

$$u^*(y_v) = u_{Y_v^1}^*(y_v) \vee u_{Y_v^2}^*(y_v) \vee \dots \vee u_{Y_v^{n_r}}^*(y_v), v = 1, 2 \quad (5-36)$$

最終使用重心法計算每個結果的精確輸出值  $z_v$ ，呈現如式(5-37)所示，從而得出最終的權重結果。

$$z_v = \frac{\int y_v \cdot u^*(y_v) dy_v}{\int u^*(y_v) dy_v}, v = 1, 2 \quad (5-37)$$

在描述整體模糊邏輯的運作過程後，接下來開始介紹歸屬函數輸入與輸出變數。輸入和輸出的歸屬函數列於表 5-2 中。最上游水庫的即時庫容量是根據最上游水庫的可發電區間內的最低和最高水位所對應出的相對應庫容量結果。這些庫容量是透過水位-容積曲線轉換得到的。未來 24 小時平均入流量是基於流域最上游水庫的預測入流量彙總而成。規則庫根據專家經驗進行調整。並且兩個輸出權重的歸屬函數相同，排洪風險優先因子和發電效率優先因子的規則庫分別列於表 5-3 和表 5-4 中。這些歸屬函數和規則庫均是基於專家經驗生成的。



表 5-2 CWG 模組的歸屬函數列表

資料	歸屬函數總數	歸屬函數的取樣區間
		(最小值,最大值)
最上游水庫及時庫容量	3	$(9.53 \times 10^6 \text{m}^3, 1.89 \times 10^6 \text{m}^3)$
最上游水庫 未來一天的平均入流量預測	7	(0CMS,217.5CMS)
排洪風險優先因子	7	(0,1)
發電效率優先因子	7	(0,1)

表 5-3 排洪風險優先因子模糊規則庫

Avg inflow \ Reservoir capacity	VS	MS	S	M	L	ML	VL
L	VS	MS	S	M	M	L	L
M	VS	MS	ML	ML	VL	VL	VL
H	VS	S	L	ML	VL	VL	VL

表 5-4 發電效率優先因子模糊規則庫

Avg inflow \ Reservoir capacity	VS	MS	S	M	L	ML	VL
L	VL	VL	VL	VL	ML	L	L
M	VL	VL	ML	L	M	S	MS
H	VL	L	S	MS	MS	VS	VS

最終模糊權重會被求出帶入 fuzzy TOPSIS 的矩陣當中，作為描述當前情況兩個成本函數（準則）的重要程度。

## 5.2.7 方法整體流程

為了完整的呈現每一個模組之間的互動關係與運作邏輯，本章節將呈現完整的運作邏輯如圖 5-8 所示，其中主程式運作流程呈現於 1 至 8 行當中、EMOGA 模組呈現於 9 至 22 行當中，圖 5-8 中 CF()用來表示 CF 模組進行的成本函數的計算、FTOPSIS 模組呈現於 23 至 28 行當中，其中 EOG()表示 EOG 模組用來生成專家意見、CWG()表示 CWG 模組生成權重。

---

**Algorithm 1** Two-stage hourly multi-reservoir optimization system

---

```

1: function MAIN( )
2:   river_inf[0] ← obtain_river_inf(0)
3:   for lead_t = 0,1,... endtime do
4:     Best_A[lead_t] ← EMOGA(river_inf[lead_t])
5:     Best_solution[lead_t] ← FTOPSIS(Best_A,lead_t),
   river_inf[lead_t])
6:     river_inf[lead_t+1] ← UPDATE(Best_solution[lead_t],
   river_inf[lead_t])
7:   end for
8: end function
9: function EMOGA(river_inf)
10:  k ← 0
11:   $X_A^k \leftarrow \emptyset$ 
12:   $X_P^k \leftarrow \text{ini\_random}()$ 
13:  CF( $X_P^k$ , river_inf)
14:   $X_A^k \leftarrow \text{edsave\_ini}(X_P^k, X_A^k)$ 
15:  for k = 0,...,20 do
16:     $X_G^k \leftarrow \text{create\_}(X_P^k, X_A^k)$ 
17:    CF( $X_G^k$ , river_inf)
18:     $X_A^{k+1} \leftarrow \text{edsave}(X_G^k, X_A^k)$ 
19:     $X_P^{k+1} \leftarrow \text{dsave}(X_G^k, X_P^k)$ 
20:  end for
21:  return  $X_A^{k+1}$ 
22: end function
23: function FTOPSIS(Best_A, river_inf)
24:  opmastic_e, pesmistic_e ← EOG(Best_A, river_inf)
25:  cost_function_weight ← CWG(river_inf)
26:  Best_solution ← FuzzyTOPSIS(opmastic_e, pesmistic_e,
   cost_function_weight)
27:  return Best_solution
28: end function

```

---

圖 5-8 本文提出方法整體虛擬碼

第 1 行：主程式部份包含 1~7 行當中。

第 2 行：river\_inf[0] 將透過 obtain\_river\_inf 函數獲得初始的流域資訊，假

設在時間點 time\_ 下， river\_inf[time\_] 包含以下資料：

- time\_ 至 time\_+12 逐小時流域發電命令
- 所有流域水庫於 time\_ 下的即時或估測水位。
- time\_ 至 time\_+24 逐小時入流量預測值與預測區間。
- 所有非最上游水庫於 time\_ - p 至 time\_ 的歷史逐小時放水量結果  
p 代表模型選擇的歷史放水量時間點。

第 3 行：此步驟表示系統的總迭代領前步長（小時）。在這迭代過程中，每次迭代都會產生最佳解集合與最終的決策結果。其中 endtime 表示預測的領前時間，在本文中被設定為 24 小時。

第 4 行：將 river\_inf[time\_] 輸入 EMOGA 模組，模組將使用所需要的資料計算最佳  $\varepsilon$ -Pareto 候選解集合 Best\_A[time\_]，該部分在第 5.1.1 節中有詳細說明。

第 5 行：根據候選解集合 Best\_A[time\_]，輸入給 FTOPSIS 模組後即可找出最佳解 Best\_solution[time\_]，此解反應當前情境的水庫庫容量與入流量預測與預測區間結果。

第 6 行：最後利用 UPDATE 來更新整體流域的狀態、引入下一個時間步長的預測資料。具體來說 UPDATE 透過 Best\_solution[time\_] 這個最佳解作為該小時的發電決策並輸入給 RM 模組預測下一小時流域各水庫入流量後，透過水位容積曲線進行流域水庫的水位值更新，即可得到下一個時間步長的模擬水位結果。最後這些結果將被儲存在 river\_inf[time+1] 當中並準備進行下一個時間步長的迭代。

第 7 至 8 行：經過 24 次迭代後，得到未來一天每小時的流域發電命令最佳解。

第 9 行：EMOGA 模組的整體流程虛擬碼呈現在第 9 至第 22 步驟中。

第 10 至 12 行：在程式的初始執行中， $k$  作為迭代次數被設定為 0、 $X_A^k$  是一個空集合並且  $X_P^k$  透過 `ini_random` 進行隨機生成。

第 13 和 17 行：函數 `CF` 計算成本函數。它計算流域用水量因子和排洪風險因子的成本函數值，成本函數如式(5-6)、(5-9) 所示。這些成本函數透過發電命令跟 `RM` 模組合作推演出未來 12 小時的發電用水量、排洪用水量指標同時計算透過這些決策對未來 12 小時的排洪風險因子(透過流域各水庫庫容量)，該部分如第 5.2.2 節中的說明。

第 14 行：函數 `edsaveini`：透過找出  $X_P^k$  中所有的非支配解集合後，基於此解集合與式(5-1)將可以計算出 `box space` 後，透過此 `box` 與  $\varepsilon$ -支配的概念即可找出該集合內所有無法被  $\varepsilon$ -支配支配的解集合，並將其存入  $X_A^k$  當中。

第 16 行：函數 `create_` 表示對集合  $X_P^k$  和  $X_A^k$  進行交配和突變的過程，這遵循傳統的遺傳演算法。經過交配和突變操作後，所有變異的染色體最終將存儲在  $X_G^k$  集合中。

第 18 行：函數 `edsave` 將會透過  $X_A^k$  與  $X_G^k$  更新  $X_A^{k+1}$ ，首先假設從  $X_G^k$  集合中提取出來的元素為  $\omega^G$ ，並且另  $X_A^{k+1}$  相等於  $X_A^k$ 。 $X_G^k$  內的所有解將依序被取出與  $X_A^{k+1}$  比較與更新。首先  $\omega^G$  將會與  $X_A^{k+1}$  進行比較，以確保其符合  $X_A^{k+1}$  內所有元素不可  $\varepsilon$ -支配其他解的特性，在比

較的過程中可能會發生以下三種情形，以下將依序列舉而出，並說明對應的處理情況。

1.  $\omega^G$  被  $X_A^{k+1}$  集合內任一個以上的解  $\varepsilon$ -支配，那麼  $\omega^G$  將不會存入  $X_A^{k+1}$  當中。
2.  $\omega^G$  無法被  $X_A^{k+1}$  集合內任一個以上的解  $\varepsilon$ -支配，同時沒有任何一個成本函數帶入  $F_\rho(\omega^G)$  出來的結果不會大於  $F_\rho^{\max}$  或是小於  $F_\rho^{\min}$ ，那麼元素  $\omega^G$  將被存入集合  $X_A^{k+1}$  當中。
3.  $\omega^G$  無法被  $X_A^{k+1}$  集合內任一個以上的解  $\varepsilon$ -支配，同時有任何一個成本函數帶入  $F_\rho(\omega^G)$  出來的結果會大於  $F_\rho^{\max}$  或是小於  $F_\rho^{\min}$ ，那麼搜尋空間  $\varepsilon_\rho$  將被重新計算， $\omega^G$  將被暫時存入  $X_A^{k+1}$  當中，同時  $X_A^{k+1}$  會進行一次  $\varepsilon$ -支配計算確保所有的解符合新的 box space 的約束條件。

第 19 行：函數 `dsave` 用來更新母群  $X_p^{k+1}$ 、首先另  $X_p^{k+1}$  相等於  $X_p^k$ 。並且從

$X_p^{k+1}$  和  $X_G^k$  中隨機選擇相等數量的解，並表示為  $\omega^P$  與  $\omega^G$ ，若是  $\omega^G$  支配  $\omega^P$ ，則將  $\omega^G$  取代  $\omega^P$  更新至  $X_p^{k+1}$  當中，反之則淘汰  $\omega^G$ ，這些過程會包含  $X_G^k$  集合內所有的元素。

第 20 至 21 行：計算並獲得最佳候選解集合  $X_A^{k+1}$  提供給 FTOPSIS 模組使用。

第 23 行：FTOPSIS 模組的虛擬碼在第 23 至 28 行中進行描述。

第 24 行：函數 EOG 會從 river\_inf[time]提取所需的資料並生成樂觀和悲觀的專家意見存入 opmastic\_p 和 pesmastic\_p 當中。這部分在第 5.2.5 節中有詳細說明。

第 25 行：函數 CWG 會從 river\_inf[time]提取所需的資料並生成排洪風險優先因子和發電效率優先因子的成本函數權重存入便數 cost\_function\_weight 當中。這部分在第 5.2.6 節包含完整的說明。

第 26 行：最終 Fuzzy TOPSIS 將專家意見和成本函數權重進行整合，量化所有解與正理想解與反理想解的距離，並量化每一個解的優劣程度，從而找出最佳解。

第 27 行：返回最佳解。

### 5.3 研究結果與討論

本文選擇為台灣的大甲溪流域作為實驗場域，其流域內所有的水庫呈現如圖 5-9。大甲溪流域位於台灣中部，是台灣最重要的水資源之一，擁有豐富的自然景觀與水文資源。大甲溪是台灣第三長的河川，流經苗栗、台中與彰化等縣市，貫穿台灣中部地區。該地區水資源豐富，擁有多座重要水庫，包括德基水庫、青山水庫、谷關水庫、天輪水庫及馬鞍水庫。其水力發電機組的總裝置容量達到 1,136.8 MW，可以看出其強大的發電潛能。同時這些水庫不僅為農業、工業和民生用水提供重要支持，還對台灣的發電量做出顯著貢獻。由於台灣的氣候特徵有著降雨密集的特性，在颱風或梅雨季節經常發生瞬間且大量的強降雨，導致流域逕流量迅速增加，這些富含極端事件的特性也使得大甲溪流域成為理想的實驗場域。




圖 5-9 大甲溪流域圖

(資料來源：[93])

### 5.3.1 資料蒐集

為了要呈現更完整的資料使用情形，本節描述各模組中所使用到的數據，希望能讓讀者更完整的理解論文整體的資料流程。

EMOGA 模組：EMOGA 模組負責生成代表發電配比的染色體，以尋找最佳的候選解集合。此部分不使用其他數據。

CF 模組：CF 模組基於觀測資料如流域調度發電命令與流域水庫相關資訊與 RF 模組進行迭代，具體使用的資料呈現如下：

#### 1. 流域逐小時調度發電命令：

來自調度中心的流域調度發電命令表示流域內所有水庫的總發電目標，該目標會隨時間（逐小時）變化以滿足不同需求。

## 2. 流域水庫水文資訊：

RM 模組從 CF 模組接收最上游水庫入流量預測數據後回傳入流量結果。這些入流量將被轉換為容積，並與當前水庫庫容量進行相加。最終更新後的庫容量將代入水位-庫容曲線以更新下一個時間步長流域各水庫的預測水位值。

## 3. 動態發電限制：

- (1) 首先將最大和最小發電水位以及當前可用水位通過水位容積曲線轉換為想對應的容積上下限與即時庫容量（單位： $m^3$ ）。
- (2) 接著考慮民生與灌溉需求（CMS）、排洪約束條件（例如，上游水庫發生洪水時，下游水庫禁止發電）以及水庫水位規線（描述全年各時段的最低可發電水位）。
- (3) 再來考慮機組的最大用水能力，也就是滿載發電用水量。綜合這些因素後，可以確定每個水庫的水量限制，並通過電水比曲線（MW/CMS）計算發電限制的上下限。
- (4) 上述的水位容積曲線與電水比曲線都會受到不同的水位值而產生不同的用水效率，因此這是一組會不斷隨時間而即時改變的約束條件。

## RM 模組：

預測模型使用大甲溪流域水庫在 2014-2015 年的每小時入流量（CMS）和排洪量（CMS）數據進行訓練，並使用 2016 年的數據進行測試和驗證。目前最上游水庫的入流量使用觀測入流量作為預測輸入。

## FTOPSIS 模組：

作為決策系統使用，其內部不使用其他額外信息。

EOG 模組：

最上游水庫預測區間的最大值和最小值被用於 CF 模組的計算。預測區間結合觀測數據並加入 10% 的隨機誤差。

CWG 模組：

此系統使用水位容積曲線 ( $\text{m}/\text{m}^3$ ) 和即時水庫觀測水位 ( $\text{m}$ ) 計算最上游水庫的即時庫容 ( $\text{m}^3$ )，以及未來 24 小時最上游水庫平均入流預測 (CMS) 結果，目前使用的是歷史觀測的平均入流量作為輸入。

### 5.3.2 RM 模組

本節展示類神經網路模型在實際場域數據下的訓練參數與模型誤差。本文針對每個非流域最上游水庫需建立一個 ANN 模型進行對應的入流量預測。本文的實驗範圍包含大甲溪流域由上至下的五座水庫：德基、青山、谷關、天輪與馬鞍，這些水庫以串聯方式連結。因此本文需要建立四個下游水庫 NN 模型來進行入流預測以實現逕流模型的產出。訓練資料集使用 2012 年至 2015 年的逐小時平均小時入流量 (CMS) 數據，測試資料則選用 2016 年整年的數據。以平均絕對誤差 (Mean Absolute Error, MAE) 作為誤差評估指標。訓練參數與數據集數量詳見表 5-5，每一個水庫的訓練資料與測試資料趨勢則列於圖 5-10 至 5-17 當中。並且訓練資料與測試資料的 MAE 與 RMSE 誤差呈現於表 5-6 與表 5-7 當中。從訓練資料表 5-6 與測試資料表 5-7 中可見，儘管谷關水庫因其上游除青山水庫外還有志樂溪支流，因此導致其誤差略高，如果能有志樂溪上游雨量測站的觀測數據，應該能提升其準確度，除此之外其他四座水庫的入流誤差仍在可接受範圍

內。這些模型最終用於預測流域各水庫的入流量資訊，為發電決策模型提供建模依據。






圖 5-10 青山水庫逕流模型訓練結果（訓練資料）




圖 5-11 青山水庫逕流模型訓練結果（測試資料）




圖 5-12 谷關水庫逕流模型訓練結果 (訓練資料)




圖 5-13 谷關水庫逕流模型訓練結果 (測試資料)




圖 5-14 天輪水庫逕流模型訓練結果（訓練資料）




圖 5-15 天輪水庫逕流模型訓練結果（測試資料）




圖 5-16 馬鞍水庫逕流模型訓練結果（訓練資料）




圖 5-17 馬鞍水庫逕流模型訓練結果（測試資料）

表 5-5 非最上游水庫之 NN 模型訓練相關參數表

NN 參數	數值
訓練資料總數	17520
測試資料總數	8784
每個水庫的輸入數量	$hr_{\phi} \times (p+1)$
每個水庫的輸出數量	1
神經網路隱藏層架構	[20, 10]
正規化方法	L2
學習率 (Learning Rate)	0.01
學習衰退因子	0.98
轉移函數	Sigmoid
訓練方法	梯度下降法

表 5-6 大甲溪流域非最上游水庫逕流模型預測誤差 (訓練資料)

逕流模型水庫	MAE	RMSE
青山	0.45	1.49
谷關	8.04	11.19
天輪	3.36	6.65
馬鞍	1.84	3.05

表 5-7 大甲溪流域非最上游水庫逕流模型預測誤差（測試資料）

逕流模型水庫	MAE	RMSE
青山	5.54	7.54
谷關	9.98	15.4
天輪	4.04	6.55
馬鞍	6.36	7.56

### 5.3.3 ev-MOGA

本章節呈現 ev-MOGA 於本實驗所使用的相關參數，其參數列表如表 5-8 所示。從表 5-8 中可看出，初始主要母群設定為 200，這是希望能提升母群的多樣性。搜尋空間維度和成本函數的數量均設為 2。交配率和突變率分別設定為 0.4 和 0.1，迭代次數設定為 20。此外每個成本函數的 BOX 數設定為 200，以減少過於相似的結果，同時維持解集合內的多樣性。

表 5-8 ev-MOGA 使用參數表

參數	數值
初始 P 群集總數	200
搜尋維度	2
交配率	0.4
突變率	0.1
迭代次數	20
每個維度分割的 Box 數量	200

### 5.3.4 案例分析

為了驗證圖 5-1 與 5-2 所示的系統架構有效性，本文選擇台灣的大甲溪流域作為實驗地點。通過比較短期極端事件與長期用水情形做為兩項實驗來驗證所提方法之有效性。短期極端事件的設計是希望展示在無雨情境和颱風情境下，本文提出方法、對照方法與實際電廠歷史運行過程的發電效率與排洪風險比較，以說明本文提出方法在不同情境下的決策效果。同時為了展示所提方法的長期用水比較，本文接著比較 2016 年 9 月月初與月中（包含兩個颱風）的累積用水量與實際電廠的發電用水量。最後分析本文提出方法與實際廠區歷史資料於 2016 整年度、各季度與各月份的發電用水趨勢與流域各電廠的於發電總量的佔比，以評估整體方法在不同季節、月份與年度下的用水量差異與各電廠的發電佔比差異。同時為了盡量減少外部不確定如預測誤差對系統的影響，本文假設最上游水庫入流預測為理想情況，即預測入流值等於觀測值。預測區間基於觀測數據，使用 10% 的隨機誤差進行處理。此方法確保本文討論的實際效益主要集中於系統本身，呈現在理想情況下系統作出正確決策的能力。

#### 1. 特殊事件分析

由於台灣屬於氣候變化劇烈的海島型氣候，有著降雨集中的特性，並且全年的降雨集中在春雨季（3-4 月）、梅雨季（5-6 月）以及颱風季（7-9）月，其中梅雨季與颱風季時常在短時間就帶來大量的入流量，為此本文設計方法依照天氣情境不同應實現對應的決策方針，如表 5-9 所示，從表中可以看出在無雨的情境下，因為風險極低，系統應該著重在發電效率的最大化。而颱風情境則相反，系統應該最大程度的降低排洪風險。而在一

般降雨情境下，系統應該要具備應照情境動態調節的能力。本節的特殊事件分析則用以強調在無雨情境下與颱風情境下，本文所提出的方法的運作效能。

表 5-9 各種氣候情境下的預期決策方針

	無雨情境	降雨情境	颱風情境
預期決策方針	最大化 發電效率	根據未來資訊 動態調節	最大化 風險管控
流域用水量	主要優化目標	根據未來資訊 動態調節	次要優化目標
排洪風險	次要優化目標	根據未來資訊 動態調節	主要優化目標

本節分為兩部分。第一部分說明所提出的 CWG 模組在不同情境下對決策結果的影響，同時展示流域在各種條件下的水庫水位變化。第二部分則將結果與僅考慮發電效率作為目標的遺傳演算法進行比較，重點分析在不同情境下的發電決策所影響的流域用水量與排洪風險差異並且凸顯出多目標在多情境下的多元選擇能力。

為了強調圖 5-2 所示系統架構的有效性，本文提出兩種不同的方法針對短期事件進行分析，除了比較整體方法的運作性能之外更特別強調出 CWG 模組對多目標權重調節對整體決策產生的影響，兩個方法於每個步驟所使用的模組如表 5-10 所示，並與實際場域歷史用水量進行比較。從表 5-8 可以看出，兩種方法在決策系統中的權重參數雖然有所不同。方法 1（本文所提方法）使用 CWG 模組進行權重調整，該模組使系統能夠考慮

長期未來入流量資訊與並且會依據即時最上游水庫庫容量進行動態的權重調整，以增強所提權重參數在決策過程中的影響力。而方法 2 針對兩項指標完全使用相同權重，這意味著該決策方法在候選解的選擇上會完全基於權衡的角度進行最佳解的篩選。透過將這些方法與實際實驗場域進行比較可以展示所提 CF 模組結合 ev-MOGA 的最佳解搜索能力，同時呈現 Fuzzy TOPSIS、EOG 模組與所提 CWG 方法的權重調節能力對整體風險管控的影響。

表 5-10 方法 1 與方法 2 比較表

	方法 1	方法 2
多目標最佳解搜尋方法	ev-MOGA	ev-MOGA
成本函數設計	CF 模組	CF 模組
決策方法	Fuzzy TOPSIS	Fuzzy TOPSIS
Fuzzy TOPSIS 專家生成模組	EOG 模組	EOG 模組
Fuzzy TOPSIS 權重調節方法	CWG 模組	相同權重

無雨情境的的資料選用 2016 年 9 月 1 日凌晨 1 點。調度中心的流域發電命令和最上游水庫的入流量趨勢顯示如圖 5-18。可以看出其為典型的無雨情境，有著穩定的入流量。最終方法 1 的實際輸出水位如圖 5-19 所示。圖 5-18 展示所有決策對流域水庫水位的影響，圖中的紅色圓圈表示每小時由 EMOGA 模組生成的解集合對流域水庫的影響，藍色線則代表 FTOPSIS 模組選擇的最佳解對流域水庫的每小時影響。從圖 5-19 中可以明顯看出決策方法試圖將整體流域的平均水位拉高以提升整體的發電效率。並且候選

解集合能夠呈現多樣化的決策結果，這將提升後續決策過程中做出更多樣化決策的可能性。並且圖 5-20 說明在無雨情境下最佳候選解在不同迭代過程中的收斂過程。




圖 5-18 無雨情境：調度中心未來發電命令與最上游水庫入流量趨勢

圖

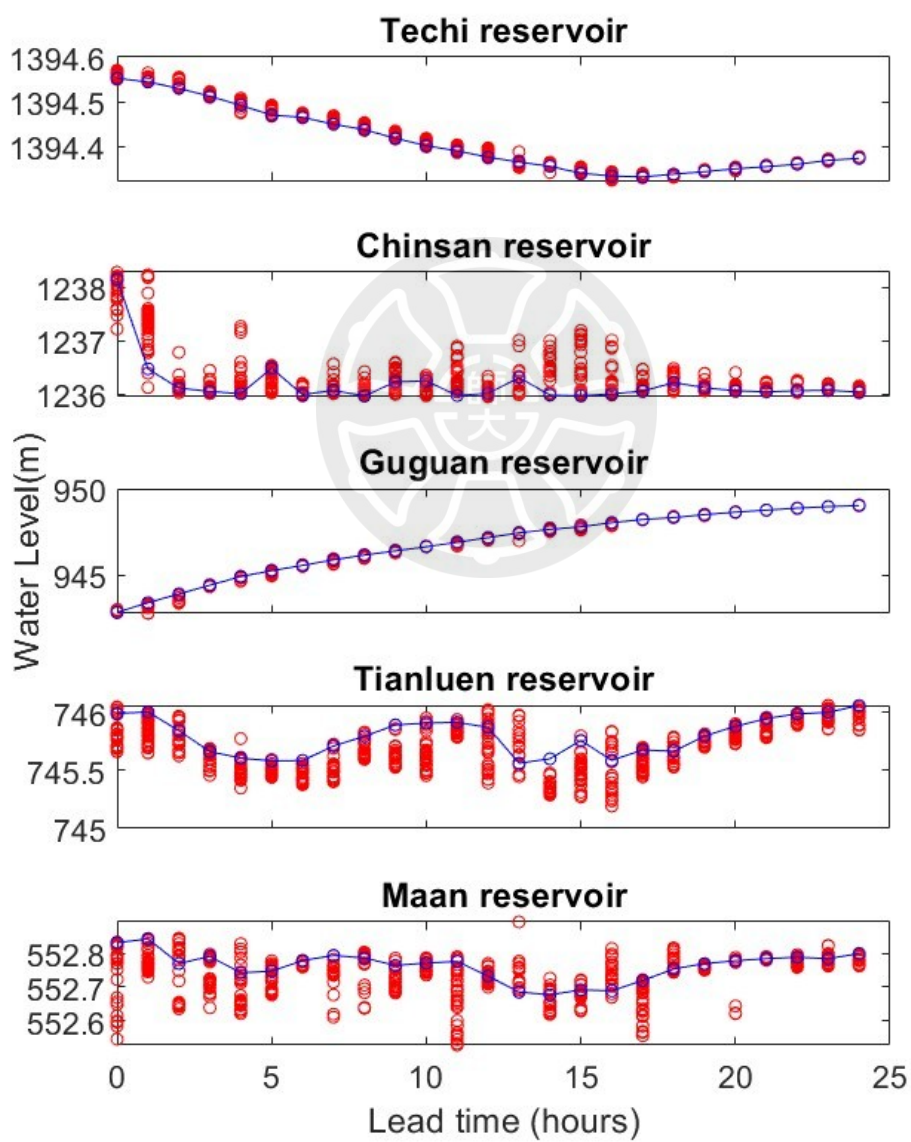

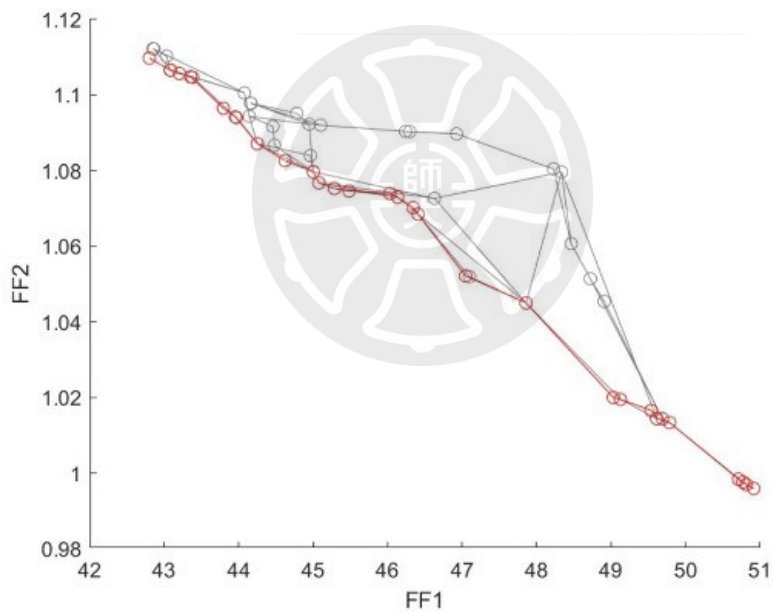


圖 5-19 無雨情境流域水庫水位趨勢圖



(a)



(b)

圖 5-20 無雨情境：每一小時的 ev-MOGA 最佳解集合收斂過程 (a) 1 小時領前 (b) 24 小時領前

接著我們將方法 1 與方法 2 與調度中心的實際發電用水量進行比較。所有發電用水量均根據流域各水庫的水位、發電量以及發電與水量比例曲線進行計算。最終結果如圖 5-21 和圖 5-22 所示。




圖 5-21 無雨情境下方法 1 與調度中心歷史逐小時用水量比較圖




圖 5-22 無雨情境下方法 2 與調度中心歷史逐小時用水量比較圖

圖 5-21 呈現方法 1 與實際調度中心歷史用水資料的每小時差異。從圖 5-21 可看出方法 1 強調在最大程度上的提升發電效率。與調度中心流域歷史用水量相比，整體用水量有著顯著的減少，這也意味著在非汛期期間本文提出的方法可以有效提升發電效率。方法 2 的用水比較如圖 5-22 所示。並且從圖 5-21 與圖 5-22 的對比中可以看出，由於方法 2 缺乏動態的決策權重調整機制，決策系統將傾向於在發電用水與排洪風險管理之間尋求權衡的結果，也可以看出儘管是基於權衡的方式進行發電決策，其用水量依舊優於調度中心的歷史用水量。相比之下方法 1 能夠根據未來的天氣情境進一步調整，確保在穩定無雨的情境下有效提升發電效率。引入 fuzzy TOPSIS 還能在一定程度上緩解過於極端的結果。

接下來介紹第二個情境涉及颱風來臨前的氣候情境，以 2016 年 9 月 13 日 15:00 的時間點為代表。調度中心針對未來 36 小時的流域調度發電指令和最上游水庫的入流趨勢分別如圖 5-23 所示。從圖中可看出，這是一個典型的強颱風案例，期間每小時入流量在最高點的時候有著近 400CMS 的入流量，已經遠超德基水庫的滿載發電用水量輸出，這時候應採取風險管控最大化的運行方針。最終實際運行結果與候選解集合如圖 5-24 所示，從圖中可看出本文提出方法嘗試降低整體水庫的平均水位，這是為了要降低整體流域的排洪風險。圖 5-25 展示颱風情境下最佳候選解在不同迭代過程中的收斂情況。可以觀察到即使在颱風情境下，系統仍然能提供多樣化的選擇，並且在保持固定發電命令的前提下盡量降低整體平均水位結果。




圖 5-23 颱風情境：調度中心未來發電命令與最上游水庫入流量趨勢

圖

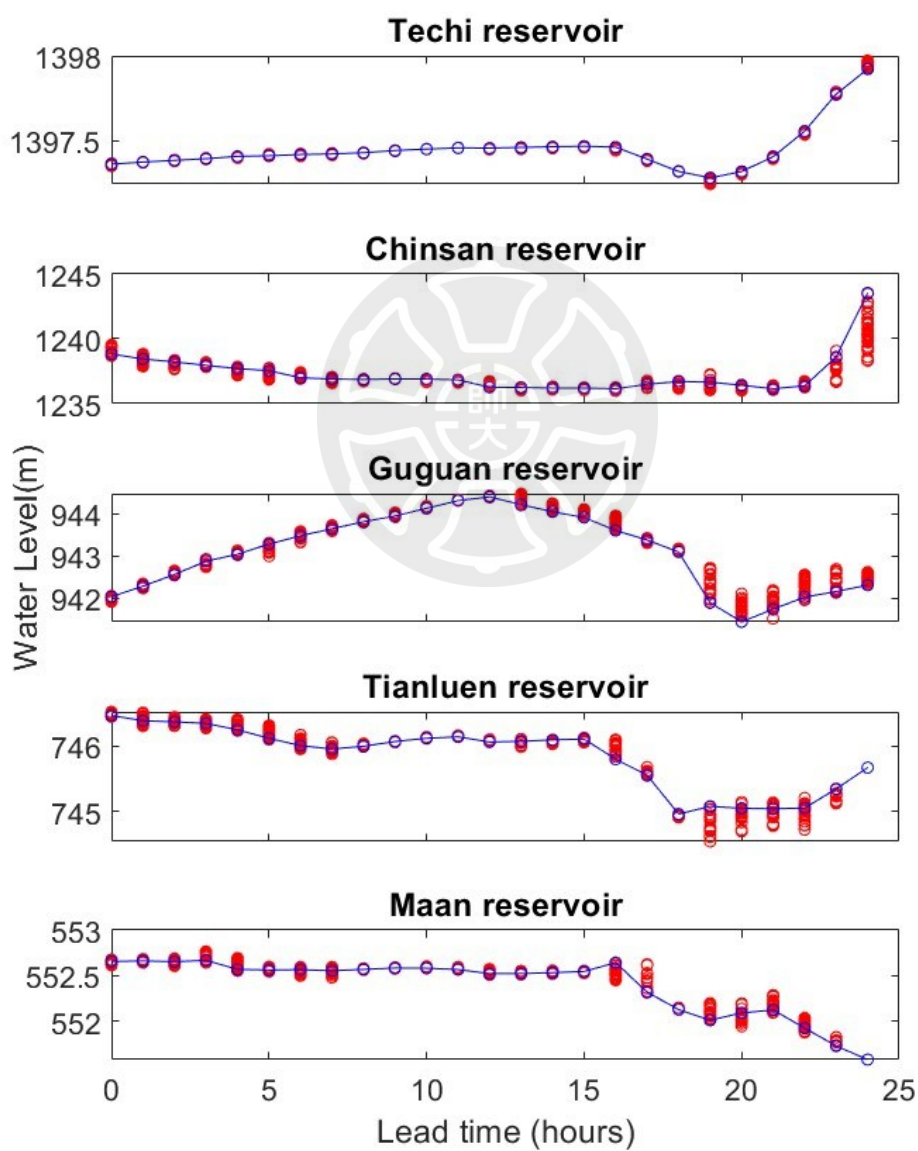




圖 5-24 流域水庫水位趨勢圖



(a)



(b)

圖 5-25 颱風情境：每一小時的 ev-MOGA 最佳解集合收斂過程 (a) 1 小時領前與 (b) 24 小時領前

方法 1、方法 2 與調度中心實際發電用水量的比較結果如圖 4-16 和圖 5-26 所示。從圖 5-27 可以看出，方法 1 導致發電用水量的增加。這是因為下游水庫應對即將到來的排洪風險進行預先排空，讓整體流域處於較

低的水位位能進行發電，這會導致發電用水量提高，在一定程度上降低排洪風險，雖然以此情境來看會對發電效率產生影響，但相較於洪水導致排洪決策對環境、民生灌溉與發電水量的浪費相比，其損失是可以接受的。從圖 5-26 中看出與實際場域歷史運行發電用水量相比，發電用水量有顯著增。同時在圖 5-26 中可以明顯看到，方法 2 的情境下，決策系統仍然專注於在發電用水量與排洪風險之間尋求最佳平衡。總體而言，可以觀察到所提方法生成足夠的候選解，以覆蓋多種情境選擇。在等距權重的決策系統下，產生平衡的最佳解，而權重調整方法則進一步優化不同情境下的發電策略。並且這些方法所搜尋出來的解不會因為追隨發電效率而忽略風險管理的重要性。同時所有運行機制流域內的水庫皆符合調度中心的流域調度發電指令總量要求的前提下進行運作。




圖 5-26 颱風情境下方法 1 與調度中心歷史逐小時用水量比較圖




圖 5-27 颱風情境下方法 2 與調度中心歷史逐小時用水量比較圖

## 2. 方法 1 與單目標方法用水量比較

對方法 1（本文提出的方法）與單目標 GA 方法（僅使用水力發電的用水成本函數進行優化）在無雨與颱風情境下進行比較。比較結果如表 5-11 所示，而單目標 GA 方法的參數列於表 5-12 中。無雨情境下的逐時累積用水量如圖 5-18 所示，颱風情境下的則如圖 5-19 所示。總體而言，圖 5-28 顯示，在無雨天氣條件下，提出的方法能實現與單目標 GA 方法相近的發電效率。相比之下，圖 5-29 顯示，在高風險的颱風情境下，提出的方法基於風險調整整體水位，並在較低水位下進行發電。此策略增加流域的用水量，使水庫能夠容納更多的颱風進水量。換句話說，在颱風情境下，提出的方法採用風險管理的理念，其決策趨向於降低流域水庫的水位，從而為水庫提供更多的緩衝時間，提升水庫容納更多進水量的機率。而單目標 GA 方法在沒有 FLWL 限制的情況下，仍持續以最大化發電效率為目

標，導致用水量上出現顯著差異。這進一步突顯提出的方法即使在沒有 FLWL 限制的情況下，仍具備優越的風險管理能力。

表 5-11 方法 1 與 GA 方法比較

	方法 1	單目標 GA
成本函數	<i>FF</i> 與 <i>WF</i>	<i>WF</i>
決策方法	fuzzy TOPSIS	-
Fuzzy TOPSIS 專家意見產生方法	EOG 模組	-
Fuzzy TOPSIS 權重參數產生方法	CWG 模組	-

表 5-12 GA 方法參數設定

參數	數值
母群大小	50
搜尋維度	1
編碼方式	雙精度
交配方式	單點交配
突變率	0.1
交配率	0.8
迭代次數	20




圖 5-28 無雨情境下方法 1 (本文提出方法)、單目標最佳化 GA 與實際廠區歷史運行用水量比較圖




圖 5-29 颱風情境下方法 1 (本文提出方法)、單目標最佳化 GA 與實際廠區歷史運行用水量比較圖

### 3. 流域發電用水量比較

在 2016 年 9 月，大甲溪流域在月初（1 日至 10 日）和月中（11 日至 20 日）期間出現顯著氣候差異。以最上游的德基水庫的每小時平均入流量為例，其趨勢如圖 5-30 所示，從德基水庫的入流量可以看到月初與月中有著相當大的流量差異。同時針對提出的方法和實際電廠運作的每日累積用水量如圖 5-31 所示。月初期間的氣候特徵穩定，而月中則因颱風莫蘭蒂（9 月 14 日登陸）和颱風馬勒卡（9 月 17 日登陸）的來臨造成大量降雨，在兩相對比之下，形成兩種截然不同的情境。為了分析這些變化，本文將 9 月分為月初和月中兩個時段，以比較用水趨勢。如圖 5-32 所示，提出的運作策略在月初展現卓越的發電效率。然而由於風險管理的考量，月中採取較保守的發電策略。總體而言，提出的模擬方法在 9 月初和月中期間節省約  $3.9 \times 10^6$  立方公尺的水，約佔該期間總用水量的 1.46%。如果這些節省的水以德基水庫單元的最大發電效率利用，將可產生約 1.44 GWh 的電能。




圖 5-30 2016 年 9 月 1 號~9 月 20 號入流量趨勢圖




圖 5-31 2016 年 9 月 1 號至 9 月 20 號日累積用水量對照表




圖 5-32 本文提出方法與實際歷史廠區累計用水量於 2016 年 9 月 1 至 10 號與 11 至 20 號

#### 4. 2016 年度用水量與發電趨勢比較

接下來本文針對 2016 年整年度的發電決策用水量進行分析，以分析其不同月份、季節與全年的用水量趨勢與流域各電廠的發電分布，以評估發電效率的緣由。2016 年的降雨主要集中在 6 月至 9 月之間，其中 9 月更是包含梅姬、莫蘭蒂颱風等強颱。2016 年逐日於方法 1 與歷史發電趨勢之用水量比較如圖 5-33 至圖 5-44 所示，從圖中可以看出除了包含強颱的九月份之外，本文提出方法在相同流域發電總量的情況下可以提供較少的流域用水量，2016 年各季度用水量呈現如圖 5-45，從圖中可看出，除了包含強颱的秋季情境下，方法會傾向使用更保守的發電決策，從而導致用水量的上升，這些決策變化在前述的章節中已有具體的呈現。除此之外，包含梅雨的夏季、春季與冬季皆有著較少的發電用水量。這也在一定程度上反應本文提出的流域多目標發電決策方法在不同時節的發電策略各電廠佔比分布。其流域之 2016 年各月份各電廠之發電分布如圖 5-47 至圖 5-58。其流域之 2016 年各季度各電廠之發電分布如圖 5-59 至圖 5-62，從圖中可看出除夏季當中本文提出方法在青山電廠上有著較高的發電比重之外，其他季節中則存在著近似的發電總量分布。最後從圖 5-63 顯示 2016 年整年度的流域之各電廠之發電分布圖，從圖 5-63 中可以看出，以年度總量的觀點來看，流域各電廠發電配比與實際電廠運行過程相似，並沒有明顯的差異，這意味著本文提出方法可以在最終與實際場域各個電廠當中使用相似的發電總量，同時降低用水的總量。這也意味著方法並沒有極端的偏向某些電水比較高的電廠的趨勢。




圖 5-33 2016 年 1 月份用水量比較




圖 5-34 2016 年 2 月份用水量比較




圖 5-35 2016 年 3 月份用水量比較




圖 5-36 2016 年 4 月份用水量比較




圖 5-37 2016 年 5 月份用水量比較




圖 5-38 2016 年 6 月份用水量比較




圖 5-39 2016 年 7 月份用水量比較




圖 5-40 2016 年 8 月份用水量比較




圖 5-41 2016 年 9 月份用水量比較




圖 5-42 2016 年 10 月份用水量比較




圖 5-43 2016 年 11 月份用水量比較




圖 5-44 2016 年 12 月份用水量比較




圖 5-45 2016 年季度用水量比較




圖 5-46 2016 年年度用水量比較




圖 5-47 2016 年 1 月份各電廠發電佔比比較




圖 5-48 2016 年 2 月份各電廠發電佔比比較




圖 5-49 2016 年 3 月份各電廠發電佔比比較




圖 5-50 2016 年 4 月份各電廠發電佔比比較




圖 5-51 2016 年 5 月份各電廠發電佔比比較




圖 5-52 2016 年 6 月份各電廠發電佔比比較




圖 5-53 2016 年 7 月份各電廠發電佔比比較




圖 5-54 2016 年 8 月份各電廠發電佔比比較




圖 5-55 2016 年 9 月份各電廠發電佔比比較




圖 5-56 2016 年 10 月份各電廠發電佔比比較




圖 5-57 2016 年 11 月份各電廠發電佔比比較




圖 5-58 2016 年 12 月份各電廠發電佔比比較




圖 5-59 2016 年春季各電廠發電佔比比較




圖 5-60 2016 年夏季各電廠發電佔比比較




圖 5-61 2016 年秋季各電廠發電佔比比較




圖 5-62 2016 年冬季各電廠發電佔比比較




圖 5-63 2016 年年度各電廠發電佔比比較

## 5.4 結論

本文提出一個兩階段的每小時多水庫優化系統。在第一階段，系統基於兩個參考標準生成一組非支配解，涵蓋決策的多樣性，且所提的成本函數能在更大程度上覆蓋未來的情境。在第二階段，所有候選解進行篩選，決策結合更長的預測期和預測區間，以應對天氣的不確定性。此外，模糊權重調整能夠在常規和極端情境下提升該方法的性能。

實驗結果表明，結合 ev-MOGA 的成本函數能夠有效突顯流域決策的多樣性。所提出的 fuzzy TOPSIS 與 EOG 模組融入預測區間的概念，能夠更廣泛地涵蓋預測不確定性，更好地反映未來的用水需求。最後，通過對

颱風頻繁的 2016 年 9 月用水量的比較，該方法在洪水控制管理的前提下提供更高效率的發電優化。而 2016 年全年運行結果證明該系統的整體發電效率與在不同季節特性下的用水趨勢，從實驗中可知，本文提出方法可以在颱風季節下提供風險管控的決策結果，並且在全年度的運行上保持整體較高的發電效率。總體而言，所提方法在應對未來水資源情境方面有著不錯的表現。



## 第六章 結論與未來展望

### 6.1 結論

本文提出一套以流域為單位的多水庫最佳化方法並呈現整體設計流程。首先，一套可靠且有效的發電規劃系統有一個比較明確的前提，就是整個流域的水資源的掌握能力，除了流域中水庫與水庫的水資源轉移相當重要之外，更重要的就是對於未來降雨、颱風、梅雨等事件的掌握能力，依照未來的降雨情境不同會直接影響到當前情境下的發電決策。因此建立一套可靠的最上游水庫入流量預測系統是必要的，本文的第三章節提出一種透過模糊類神經網路結合其上游集水區氣象降雨預報資料、歷史觀測降雨與德基水庫的歷史入流量後，實現未來 48 小時的入流量預測系統建置，這將錯綜複雜的預報結果具體轉換成明確的入流量預測結果，使得流域水庫最佳化系統可以以此入流量預測作為基礎，掌握未來水資源的變化情形。

然而在實務上的應用當中，對於入流量預測系統來說，氣象降雨預報對於未來 6 小時之後的準確度有著非常高度的相關性，若是預報資訊無法掌握正確的降雨事件將容易大幅度影響預測的準確度，這些誤差將會使得整體系統涵蓋較高的不確定性，同時這些不確定性會進一步的影響發電決策系統的可靠度。若是直接引入準確的預測結果的話並不容易量化其預測誤差所帶來的不確定性。因此，本文第四章節提出一套基於預測區間的產出方法，透過考量所預測出的預測區間結果於實際觀測量的覆蓋率與預測區間的上下限寬度作為兩相衝突的成本函數為基礎，透過類電磁演算法、

細菌覓食演算法結合類神經網路進行訓練，最終量化出預測結果的不確定性。這些不確定性將透過預測區間被突顯出來，使得最佳化系統可以進一步考量這些不確定性進行決策。

有了未來 48 小時的入流量預測結果與區間之後，我們可以在一定程度上掌握未來水資源的變化趨勢與其可能對流域帶來的衝擊。接著需要設計一套可以考量最上游水庫入流量預測值與預測區間的流域發電多目標最佳化系統。同時由於氣候變遷、極端氣候與海島型氣候等等，除了造成降雨預報的困難度上升之外，極端降雨對流域的衝擊也將變得更加明顯，在短時間上升的入流量將容易使得水庫面臨排洪決策，排洪決策除了會造成民生、農業灌溉等等的風險之外，也會造成非常大的水資源浪費，同時由於排洪水量會混合大量的泥沙，在水量進入下游水庫的時候除了會造成水庫泥沙堆積減少其庫容水量之外，在短時間該水庫也不能進行發電，因為混合大量泥沙的水庫發電容易造成機組的損害。因此一個水庫的排洪事件發生後，往往造成下游的所有水庫都會面臨排洪決策，並且在降雨事件結束前都無法終止排洪的決策，這帶來的水資源浪費是非常可觀的。並且調度中心在進行發電規劃的時候往往要考量許多因素，如水庫庫容量、季節與電網的供需平衡，這將會容易使得所有的決策缺乏即時性與較為保守。因此，本文的第五章以此些背景作為基礎，透過簡化調度中心的發電命令，讓整個發電規劃以流域作為單位而不是流域當中的所有水庫的具體發電量，該規劃整合風險管控與發電效率的概念進行多目標優化，同時達成民生用水、灌溉用水、政府制定政策等等的多目標需求。同時，其決策方法整合最上游水庫入流量預測與預測區間，透過這些入流量預測進行即時性的風險管控，這些風險管控的調節過程不會受到流域發電總量的影響，而

是根據預測結果進行動態的決策調節。所有的風險管控都透過模糊邏輯的特性、入流量預測結果、多元化的候選解集合與當前最上游水庫的水庫庫容量決定。相較於傳統方法是透過限制流域每一個水庫的運轉水位來進行風險管控，如汛期與非汛期，這些運轉水位的限制往往無法反映即時的环境情境，例如汛期的運轉水位限制直接限制最佳化方法的搜尋空間，如果限制水位制定的過於保守將會很大程度的降低整體流域的發電效率，同時汛期與非汛期的界定也無法保證，非汛期的期間就不會有極端降雨事件，同時汛期期間也不一定就會有極端降雨事件，這些運轉水位的設定本身就限制流域水庫的發電效率。為此，本文的第五章提出一套流域多水庫發電決策最佳化方法，該方法透過二階段的系統進行流域水庫的發電決策制定，第一階段透過設計的發電用水成本函數與排洪風險成本函數綜合考量未來一段時間的運轉指標，這些指標將透過多元的 pareto 近似曲線儲存起來，在第二階段的決策系統中透過未來預測結果與當前水庫的即時庫容量等資訊進行整合，以達成綜合風險管控的目的。從實驗結果中可以看出，本文提出方法可以在不限制 FLWL 的情況下自適應的調節風險管控能力，並且透過計算兩種情境頻繁發生的 2016 年 9 月 1 號至 20 號可以看出，所提的方法在總整體用水量上依舊優於歷史電廠的運轉方法。最終依照 2016 年各月份、季度與年度流域發電量差異最終所提方法提供靈活的風險管控機制、預測區間與預測數值的整合能力、可解釋性的決策系統，以及多元的方案產出方法，最終實現流域水庫的多目標最佳化系統建置。

總體而言，本文彙總出每一章節的貢獻如下：

第三章節的目的在於找出多水庫多目標最佳化的未來水資源情勢，具體貢獻如下：

1. 設計一套整合大氣數學模型預報資料與統計模型的未來 48 小時逐小時入流量預測模型。
2. 找出集水區降雨量觀測、預報與所預測之目標水庫歷史入流量的關聯性並得到可靠的結果。

第四章節的目的在於量化預測的不確定性，使得預測結果不是單一值而是透過區間呈現，其區間大小具體量化預測系統的不確定性：

1. 提出一套基於預測區間大小與預測結果覆蓋機率的預測區間產出方法，可以應用在各式領域，其方法具備高度的通用性。
2. 可自訂義的訓練方針，決策者可以決定預測區間的覆蓋率與預測區間的寬度兩者目標在於訓練過程中的重要性，以得到不同面向的預測區間。
3. 預測區間的大小反映所使用資料的可靠度與準確度，前面有敘述由於入流量預測系統高度依賴集水區降雨預報結果，然而降雨預報在數學模型當中也是屬於預測較為困難的類型，本文提出方法可以量化其在預測系統當中的表現，並以預測區間大小的方式呈現出來。

第五章節的目的在於解決高度複雜且涉略時間與空間相關性的流域多水庫決策問題，提出的方法目的在解決下列問題：

1. 降低預測不確定性對最佳化系統帶來的衝擊：大部分的流域最佳化系統會在條件約束制定完成後以最高效的方式去追求發電效率，雖然也會整合入流量預測結果，但大多是透過限制 FLWL 去進行風險管控，這些入流量的不確定性會使得決策者對於 FLWL 的制定更加保守，而本文提出方法可以整合預測區間使其涵蓋更進一步的預測不確定性。

2. 提出一套透過風險管控與發電效率的多目標方法解決實務上 FLWL 制定困難的問題：在實務應用上，大多方法考量風險管控的方式是透過對流域中每一個水庫進行最大運轉水位的約束，來達成降低流域水庫的風險（提供更多的庫容量面對洪水）。然而 FLWL 本身就非常難以制定，並且其作為最佳化方法的約束條件，需要在進行最佳化之前就先制定好，若是透過串接的方式進行訓練，將會大幅增加整體方法的運算成本，同時還需要考量汛期與非汛期等資訊，總體而言限制水庫最佳化方法的到全域最佳解的能力。

總體而言，本文提出方法改善預測的不確定性在流域多水庫上調度產生的困難，同時解決 FLWL 制定困難導致結果容易陷入區域最佳解的窘境，所提方法透過所設計得風險函數與發電效率進行多目標整合，最終實現在不限制流域水庫 FLWL 的前提下，達到有效的風險管控的目的，並且透過兩個極端且經典的情境來呈現該方法於無雨與極端降雨下的表現。從結果可看出，本文所提方法可以在經典情境下提出合理的制定策略，同時以長期的角度來看，依舊可以提供良好的經濟效益。

## 6.2 未來展望

雖然本文提出的方法解決許多流域水庫多目標最佳化上的問題，然而上述方法仍有部分問題尚待解決。除了需改善因模型複雜度所造成的運算效率不足外，也必須考量入流量預測的不確定性對系統可能產生的衝擊。同時，由於成本函數目前僅聚焦未來 12 小時的模擬情境，可能導致最佳

化方法偏向短期利益，進而在實際運行時增加陷入局部最佳解的風險。因此，針對本文提出幾項可能需要改進的方向與透過未來展望進行條列說明，方便後續研究或實際應用時進一步優化：

#### 1. 強化模型運算效率

(1) 評估並簡化現有多目標成本函數與複雜流域逕流模型之計算流程。

#### 2. 應對入流量預測不確定性

(1) 整合「動態調整防洪限制水位機制」並配合模糊 Q-Learning 或其他自適應學習方法，使系統能根據不同預測誤差情境自動調整決策。

#### 3. 延長成本函數時間長度以提升長期運轉的最佳化能力

(1) 將預測時間長度由原先的 48 小時進行延長，並將成本函數取樣時間由 12 小時延長，以更全面掌握未來可能發生的水文情境。

(2) 將流域多水庫決策系統的輸出時域進行延長。

#### 4. 綜合性評估與應用推廣

(1) 進行整合性評估，針對多水庫運轉的防洪、安全供水、發電等多目標需求，驗證各水庫在不同需求強度與氣候條件下的運作績效。

(2) 將研究成果推廣至其他不同特性之流域，多方面測試決策系統之通用性與適應性。

透過上述方向的持續改進與驗證，可進一步強化智慧型流域多水庫操控決策系統的實用性、準確度與穩健度，並為未來水資源綜合管理提供更加完善的解決方案。

## 參 考 文 獻

- [1] 交通部觀光局國家風景區網頁，<https://www.trimt-nsa.gov.tw/zh-tw/attraction/9/>。
- [2] C. A. B. Mendes, A. Beluco, and F. A. Canales, "Some important uncertainties related to climate change in projections for the Brazilian hydropower expansion in the Amazon," *Energy*, vol. 141, pp. 123-138, 2017.
- [3] T. Amjath-Babu *et al.*, "Integrated modelling of the impacts of hydropower projects on the water-food-energy nexus in a transboundary Himalayan river basin," *Applied energy*, vol. 239, pp. 494-503, 2019.
- [4] S. W. Turner, M. Hejazi, S. H. Kim, L. Clarke, and J. Edmonds, "Climate impacts on hydropower and consequences for global electricity supply investment needs," *Energy*, vol. 141, pp. 2081-2090, 2017.
- [5] N. Voisin *et al.*, "Impact of climate change on water availability and its propagation through the Western US power grid," *Applied Energy*, vol. 276, p. 115467, 2020.
- [6] B. Tarroja, K. Forrest, F. Chiang, A. AghaKouchak, and S. Samuelsen, "Implications of hydropower variability from climate change for a future, highly-renewable electric grid in California," *Applied energy*, vol. 237, pp. 353-366, 2019.
- [7] D. Nohara, T. Hori, and Y. Sato, "Real-time reservoir operation for drought management considering operational ensemble predictions of precipitation in Japan," in *Advances in Hydroinformatics: SimHydro 2017-Choosing The Right Model in Applied Hydraulics*, 2018: Springer, pp. 331-345.
- [8] A. Ghumman, Y. M. Ghazaw, A. Sohail, and K. Watanabe, "Runoff forecasting by artificial neural network and conventional model," *Alexandria Engineering Journal*, vol. 50, no. 4, pp. 345-350, 2011.
- [9] B. A. Faber and J. Stedinger, "Reservoir optimization using sampling SDP with ensemble streamflow prediction (ESP) forecasts," *Journal of Hydrology*, vol. 249, no. 1-4, pp. 113-133, 2001.
- [10] E. T. Alemu, R. N. Palmer, A. Polebitski, and B. Meaker, "Decision support system for optimizing reservoir operations using ensemble streamflow

- predictions," *Journal of Water Resources Planning and Management*, vol. 137, no. 1, pp. 72-82, 2011.
- [11] C.-T. Cheng, Z.-K. Feng, W.-J. Niu, and S.-L. Liao, "Heuristic methods for reservoir monthly inflow forecasting: A case study of Xinfengjiang Reservoir in Pearl River, China," *Water*, vol. 7, no. 8, pp. 4477-4495, 2015.
- [12] H. Wang *et al.*, "Assessment of the impact of climate change on hydropower potential in the Nanliujiang river basin of China," *Energy*, vol. 167, pp. 950-959, 2019.
- [13] A. Gupta, A. Kumar, and D. K. Khatod, "Optimized scheduling of hydropower with increase in solar and wind installations," *Energy*, vol. 183, pp. 716-732, 2019.
- [14] C. Llamosas and B. K. Sovacool, "The future of hydropower? A systematic review of the drivers, benefits and governance dynamics of transboundary dams," *Renewable and Sustainable Energy Reviews*, vol. 137, p. 110495, 2021.
- [15] C.-C. Kuo, T. Y. Gan, and P.-S. Yu, "Seasonal streamflow prediction by a combined climate-hydrologic system for river basins of Taiwan," *Journal of hydrology*, vol. 387, no. 3-4, pp. 292-303, 2010.
- [16] Y.-G. Leu, T.-T. Lee, and W.-Y. Wang, "Observer-based adaptive fuzzy-neural control for unknown nonlinear dynamical systems," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 29, no. 5, pp. 583-591, 1999.
- [17] W. Wang and X. Zhao, "A new model of fuzzy neural networks and its application," in *Fifth World Congress on Intelligent Control and Automation (IEEE Cat. No. 04EX788)*, 2004, vol. 3: IEEE, pp. 2022-2024.
- [18] H. R. Maier and G. C. Dandy, "Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications," *Environmental modelling & software*, vol. 15, no. 1, pp. 101-124, 2000.
- [19] L. F. Termite, F. Todisco, L. Vergni, and F. Mannocchi, "A neuro-fuzzy model to predict the inflow to the guardialfiera multipurpose dam (Southern Italy) at medium-long time scales," *Journal of Agricultural Engineering*, vol. 44, no. s2, 2013.
- [20] W. W. Ishak, K. R. K. Mahamud, and N. M. Norwawi, "Modelling reservoir water release decision using temporal data mining and neural network," *International Journal of Emerging Technology and Advanced Engineering*, vol. 2, no. 8, pp.

422-428, 2012.

- [21] N. A. Ashaary, W. H. Wan Ishak, and K. R. Ku-Mahamud, "Forecasting model for the change of reservoir water level stage based on temporal pattern of reservoir water level," 2015.
- [22] W. H. W. Ishak, K. R. Ku-Mahamud, and N. M. Norwawi, "Modelling of human expert decision making in reservoir operation," *Jurnal Teknologi (Sciences & Engineering)*, vol. 77, no. 22, 2015.
- [23] N. A. Ashaary, W. H. Wan Ishak, and K. R. Ku-Mahamud, "Neural network application in the change of reservoir water level stage forecasting," *Indian Journal of Science and Technology*, vol. 8, no. 13, pp. 1-6, 2015.
- [24] F. Mekanik, M. Imteaz, S. Gato-Trinidad, and A. Elmahdi, "Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes," *Journal of Hydrology*, vol. 503, pp. 11-21, 2013.
- [25] M. Akhtar, G. Corzo, S. Van Andel, and A. Jonoski, "River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information: case study of the Ganges river basin," *Hydrology and Earth System Sciences*, vol. 13, no. 9, pp. 1607-1618, 2009.
- [26] K. Rasouli, W. W. Hsieh, and A. J. Cannon, "Daily streamflow forecasting by machine learning methods with weather and climate inputs," *Journal of Hydrology*, vol. 414, pp. 284-293, 2012.
- [27] C. Lee, "The Analysis and Numerical Simulation of Typhoons Invading Taiwan from the South (I)," Research Report of the National Science Council: Taipei, Taiwan, 2005.
- [28] C. Lee, W. Fang, and L. Hwang, "The Development of Integrated Quantitative Precipitation Forecasting Technique for Typhoon," Research Report of Central Weather Bureau: Taipei, Taiwan, 2009.
- [29] Y. Chen, L. Chang, L. Hsiao, C. Chiang, C. Tsai, and C. Wang, "Quantitative precipitation forecasting technology in Taiwan," in *Proceedings of the 2012 Conference on Weather Analysis and Forecasting, Taipei, Taiwan*, 2012, pp. 17-20.
- [30] C. Chiang, Y. Chen, L. Hwang, M. Wu, L. Feng, and C. Lee, "Taiwan Quantitative Rainfall Prediction Experimental Platform (TAPEX) in the path and rainfall performance evaluation," in *Proceedings of the 2014 Conference on Weather*

*Analysis and Forecasting, Taipei, Taiwan, 2014, pp. 16-18.*

- [31] Y. Chen, "A Study of Typhoon Structure and Quantitative Precipitation Forecast by Using High Resolution Ensemble Models," Research Report of the National Science Council: Taipei, Taiwan, 2013.
- [32] C.-S. Lee *et al.*, "Assessment of sewer flooding model based on ensemble quantitative precipitation forecast," *Journal of hydrology*, vol. 506, pp. 101-113, 2013.
- [33] S.-C. Yang and T.-H. Yang, "Uncertainty Assessment: Reservoir Inflow Forecasting with Ensemble Precipitation Forecasts and HEC-HMS," *Advances in Meteorology*, vol. 2014, no. 1, p. 581756, 2014.
- [34] L. Chang, L. Hsiao, D. Chen, M. Yang, C. Tsai, and C. Wang, "Ensemble Forecast Experiment for Typhoon Quantitatively Precipitation in Taiwan," *Weather Forecast*, vol. 30, pp. 217-237, 2014.
- [35] R. L. Bras and I. Rodriguez-Iturbe, *Random functions and hydrology*. Courier Corporation, 1993..
- [36] D. R. Maidment, *Handbook of hydrology*. 1992.
- [37] J. Michalakes, J. Dudhia, D. Gill, J. Klemp, and W. Skamarock, "Design of a Next-Generation Regional Weather Research and Forecast Model. Mesoscale and Microscale Meteorological Division," *National Center for Atmospheric Research, Boulder, CO.* (<http://www.mcs.anl.gov/~michalak/ecmwf98/final.html>), 1998.
- [38] D. H. Burn, "Climatic influences on streamflow timing in the headwaters of the Mackenzie River Basin," *Journal of Hydrology*, vol. 352, no. 1-2, pp. 225-238, 2008.
- [39] A. J. Cannon and P. H. Whitfield, "Downscaling recent streamflow conditions in British Columbia, Canada using ensemble neural network models," *Journal of Hydrology*, vol. 259, no. 1-4, pp. 136-151, 2002.
- [40] T. C. Yang, P. S. Yu, and C. C. Chen, "Long-term runoff forecasting by combining hydrological models and meteorological records," *Hydrological Processes: An International Journal*, vol. 19, no. 10, pp. 1967-1981, 2005.
- [41] P.-S. Yu and T.-C. Yang, "Fuzzy multi-objective function for rainfall-runoff model calibration," *Journal of hydrology*, vol. 238, no. 1-2, pp. 1-14, 2000.
- [42] Y. Shang, Y. Xu, L. Shang, Q. Fan, Y. Wang, and Z. Liu, "A method of direct, real-time forecasting of downstream water levels via hydropower station

- reregulation: A case study from Gezhouba Hydropower Plant, China," *Journal of Hydrology*, vol. 573, pp. 895-907, 2019.
- [43] Y.-M. Chiang, L.-C. Chang, and F.-J. Chang, "Comparison of static-feedforward and dynamic-feedback neural networks for rainfall–runoff modeling," *Journal of hydrology*, vol. 290, no. 3-4, pp. 297-311, 2004.
- [44] A. T. Hammid, M. H. B. Sulaiman, and A. N. Abdalla, "Prediction of small hydropower plant power production in Himreen Lake dam (HLD) using artificial neural network," *Alexandria engineering journal*, vol. 57, no. 1, pp. 211-221, 2018.
- [45] M. Dehghani *et al.*, "Prediction of hydropower generation using grey wolf optimization adaptive neuro-fuzzy inference system," *Energies*, vol. 12, no. 2, p. 289, 2019.
- [46] J. Liu and D. Han, "On selection of the optimal data time interval for real-time hydrological forecasting," *Hydrology and Earth System Sciences*, vol. 17, no. 9, pp. 3639-3659, 2013.
- [47] X. Zhang, H. Wang, A. Peng, W. Wang, B. Li, and X. Huang, "Quantifying the uncertainties in data-driven models for reservoir inflow prediction," *Water Resources Management*, vol. 34, pp. 1479-1493, 2020.
- [48] S.-C. Yang and T.-H. Yang, "Uncertainty Assessment: Reservoir Inflow Forecasting with Ensemble Precipitation Forecasts and HEC-HMS," *Advances in Meteorology*, vol. 2014, no. 1, p. 581756, 2014.
- [49] Y. Liu and H. V. Gupta, "Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework," *Water resources research*, vol. 43, no. 7, 2007.
- [50] R. Hostache, P. Matgen, A. Montanari, M. Montanari, L. Hoffmann, and L. Pfister, "Propagation of uncertainties in coupled hydro-meteorological forecasting systems: A stochastic approach for the assessment of the total predictive uncertainty," *Atmospheric research*, vol. 100, no. 2-3, pp. 263-274, 2011.
- [51] M. Zappa, S. Jaun, U. Germann, A. Walser, and F. Fundel, "Superposition of three sources of uncertainties in operational flood forecasting chains," *Atmospheric Research*, vol. 100, no. 2-3, pp. 246-262, 2011.
- [52] M. Zappa, S. Jaun, U. Germann, A. Walser, and F. Fundel, "Superposition of three sources of uncertainties in operational flood forecasting chains," *Atmospheric*

*Research*, vol. 100, no. 2-3, pp. 246-262, 2011.

- [53] D. L. Shrestha and D. P. Solomatine, "Machine learning approaches for estimation of prediction interval for the model output," *Neural networks*, vol. 19, no. 2, pp. 225-235, 2006.
- [54] A. Khosravi, S. Nahavandi, D. Creighton, and A. F. Atiya, "Lower upper bound estimation method for construction of neural network-based prediction intervals," *IEEE transactions on neural networks*, vol. 22, no. 3, pp. 337-346, 2010.
- [55] N. Dewolf, B. D. Baets, and W. Waegeman, "Valid prediction intervals for regression problems," *Artificial Intelligence Review*, vol. 56, no. 1, pp. 577-613, 2023.
- [56] N. Meade and T. Islam, "Prediction intervals for growth curve forecasts," *Journal of Forecasting*, vol. 14, no. 5, pp. 413-430, 1995.
- [57] D. L. Harnett and J. L. Murphy, "Introductory statistical analysis," (*No Title*), 1975.
- [58] R. Krzysztofowicz, "The case for probabilistic forecasting in hydrology," *Journal of hydrology*, vol. 249, no. 1-4, pp. 2-9, 2001.
- [59] G. Chryssolouris, M. Lee, and A. Ramsey, "Confidence interval prediction for neural network models," *IEEE Transactions on neural networks*, vol. 7, no. 1, pp. 229-232, 1996.
- [60] J. G. Hwang and A. A. Ding, "Prediction intervals for artificial neural networks," *Journal of the American Statistical Association*, vol. 92, no. 438, pp. 748-757, 1997.
- [61] D. J. MacKay, "The evidence framework applied to classification networks," *Neural computation*, vol. 4, no. 5, pp. 720-736, 1992.
- [62] R. Dybowski and S. J. Roberts, "Confidence intervals and prediction intervals for feed-forward neural networks," Cambridge University Press, 2001.
- [63] F. Giordano, M. La Rocca, and C. Perna, "Forecasting nonlinear time series with neural network sieve bootstrap," *Computational Statistics & Data Analysis*, vol. 51, no. 8, pp. 3871-3884, 2007.
- [64] A. Khosravi, S. Nahavandi, and D. Creighton, "A prediction interval-based approach to determine optimal structures of neural network metamodels," *Expert systems with applications*, vol. 37, no. 3, pp. 2377-2387, 2010.
- [65] A. Khosravi, S. Nahavandi, and D. Creighton, "Quantifying uncertainties of

- neural network-based electricity price forecasts," *Applied energy*, vol. 112, pp. 120-129, 2013.
- [66] R. Li and Y. Jin, "A wind speed interval prediction system based on multi-objective optimization for machine learning method," *Applied energy*, vol. 228, pp. 2207-2220, 2018.
- [67] R. Oliveira and D. P. Loucks, "Operating rules for multireservoir systems," *Water resources research*, vol. 33, no. 4, pp. 839-852, 1997.
- [68] M. H. Louati, S. Benabdallah, F. Lebdi, and D. Milutin, "Application of a genetic algorithm for the optimization of a complex reservoir system in Tunisia," *Water resources management*, vol. 25, pp. 2387-2404, 2011.
- [69] C. G. Marcelino *et al.*, "An efficient multi-objective evolutionary approach for solving the operation of multi-reservoir system scheduling in hydro-power plants," *Expert Systems with Applications*, vol. 185, p. 115638, 2021.
- [70] R. Zhang, J. Zhou, S. Ouyang, X. Wang, and H. Zhang, "Optimal operation of multi-reservoir system by multi-elite guide particle swarm optimization," *International Journal of Electrical Power & Energy Systems*, vol. 48, pp. 58-68, 2013.
- [71] Y. H. Al-Aqeeli and O. M. Mahmood Agha, "Optimal operation of multi-reservoir system for hydropower production using particle swarm optimization algorithm," *Water Resources Management*, vol. 34, pp. 3099-3112, 2020.
- [72] A. Mahor and S. Rangnekar, "Short term generation scheduling of cascaded hydro electric system using novel self adaptive inertia weight PSO," *International Journal of Electrical Power & Energy Systems*, vol. 34, no. 1, pp. 1-9, 2012.
- [73] R.-M. Chen, "Particle swarm optimization with justification and designed mechanisms for resource-constrained project scheduling problem," *Expert Systems with Applications*, vol. 38, no. 6, pp. 7102-7111, 2011.
- [74] A. Afshar, F. Massoumi, A. Afshar, and M. A. Mariño, "State of the art review of ant colony optimization applications in water resource management," *Water resources management*, vol. 29, pp. 3891-3904, 2015.
- [75] M. Azizipour, A. Sattari, M. H. Afshar, E. Goharian, and S. S. Solis, "Optimal hydropower operation of multi-reservoir systems: Hybrid cellular automata-simulated annealing approach," *Journal of Hydroinformatics*, vol. 22, no. 5, pp. 1236-1257, 2020.

- [76] A. Kangrang, S. Compliew, and R. Hormwichian, "Optimal reservoir rule curves using simulated annealing," in *Proceedings of the Institution of Civil Engineers-Water Management*, 2011, vol. 164, no. 1: Thomas Telford Ltd, pp. 27-34.
- [77] O. Bozorg-Haddad, I. Karimirad, S. Seifollahi-Aghmiuni, and H. A. Loáiciga, "Development and application of the bat algorithm for optimizing the operation of reservoir systems," *Journal of Water Resources Planning and Management*, vol. 141, no. 8, p. 04014097, 2015.
- [78] I. Garousi-Nejad, O. Bozorg-Haddad, and H. A. Loáiciga, "Modified firefly algorithm for solving multireservoir operation in continuous and discrete domains," *Journal of Water Resources Planning and Management*, vol. 142, no. 9, p. 04016029, 2016.
- [79] H. Apaydin, H. Feizi, M. T. Sattari, M. S. Colak, S. Shamshirband, and K.-W. Chau, "Comparative analysis of recurrent neural network architectures for reservoir inflow forecasting," *Water*, vol. 12, no. 5, p. 1500, 2020.
- [80] I.-F. Kao, Y. Zhou, L.-C. Chang, and F.-J. Chang, "Exploring a Long Short-Term Memory based Encoder-Decoder framework for multi-step-ahead flood forecasting," *Journal of Hydrology*, vol. 583, p. 124631, 2020.
- [81] S. K. Ahmad and F. Hossain, "Maximizing energy production from hydropower dams using short-term weather forecasts," *Renewable Energy*, vol. 146, pp. 1560-1577, 2020.
- [82] X. Li, S. Guo, P. Liu, and G. Chen, "Dynamic control of flood limited water level for reservoir operation by considering inflow uncertainty," *Journal of hydrology*, vol. 391, no. 1-2, pp. 124-132, 2010.
- [83] Y. Zhou, S. Guo, P. Liu, and C. Xu, "Joint operation and dynamic control of flood limiting water levels for mixed cascade reservoir systems," *Journal of Hydrology*, vol. 519, pp. 248-257, 2014.
- [84] Y. Peng, X. Zhang, H. Zhou, and B. Wang, "A method for implementing the real-time dynamic control of flood-limited water level," *Environmental Earth Sciences*, vol. 76, pp. 1-8, 2017.
- [85] Ž. Zore, K. Zirngast, Z. N. Pintarič, and Z. Kravanja, "Stochastic multi-objective process optimization by using the composite objective function," in *Computer Aided Chemical Engineering*, vol. 40: Elsevier, 2017, pp. 601-606.
- [86] H.-H. Tsao, Y.-G. Leu, and L.-F. Chou, "A center-of-concentrated-based

- prediction interval for wind power forecasting," *Energy*, vol. 237, p. 121467, 2021.
- [87] M. Shaverdi, I. Ramezani, R. Tahmasebi, and A. A. A. Rostamy, "Combining fuzzy AHP and fuzzy TOPSIS with financial ratios to design a novel performance evaluation model," *International Journal of Fuzzy Systems*, vol. 18, pp. 248-262, 2016.
- [88] J. T. de Aquino, F. J. C. de Melo, T. d. B. Jeronimo, and D. D. de Medeiros, "Evaluation of quality in public transport services: the use of quality dimensions as an input for fuzzy TOPSIS," *International Journal of Fuzzy Systems*, vol. 21, pp. 176-193, 2019.
- [89] F. K. A. Alazemi, M. K. A. B. M. Ariffin, F. B. Mustapha, and E. E. B. Supeni, "A new fuzzy TOPSIS-based machine learning framework for minimizing completion time in supply chains," *International Journal of Fuzzy Systems*, vol. 24, no. 3, pp. 1669-1695, 2022.
- [90] P. Rani, A. R. Mishra, G. Rezaei, H. Liao, and A. Mardani, "Extended Pythagorean fuzzy TOPSIS method based on similarity measure for sustainable recycling partner selection," *International Journal of Fuzzy Systems*, vol. 22, pp. 735-747, 2020.
- [91] L. Zadeh, "Fuzzy sets," *Inform Control*, vol. 8, pp. 338-353, 1965.
- [92] Water Resources Agency, MOEA. Available online: [https://www.wra.gov.tw/News\\_Content.aspx?n=3254&s=19375](https://www.wra.gov.tw/News_Content.aspx?n=3254&s=19375) (accessed on 30 September 2020).
- [93] H.-H. Tsao, Y.-G. Leu, L.-F. Chou, and C.-Y. Tsao, "A method of multi-stage reservoir water level forecasting systems: A case study of Techí hydropower in Taiwan," *Energies*, vol. 14, no. 12, p. 3461, 2021.
- [94] Y.-G. Leu, W.-Y. Wang, and T.-T. Lee, "Observer-based direct adaptive fuzzy-neural control for nonaffine nonlinear systems," *IEEE Transactions on Neural networks*, vol. 16, no. 4, pp. 853-861, 2005.
- [95] L.-X. Wang, *Adaptive fuzzy systems and control: design and stability analysis*. Prentice-Hall, Inc., 1994.
- [96] J. Michalakes *et al.*, "Development of a next-generation regional weather research and forecast model," in *Developments in teracomputing*: World Scientific, 2001, pp. 269-276.
- [97] A. Falk, M. Butts, H. Madsen, and J. N. Hartnack, "Data assimilation to improve

- forecast quality of river basin models," in *Proceedings of the XVI International Conference on Computational Methods in Water Resource, Copenhagen, Denmark*, 2006, pp. 18-22.
- [98] Typhoon Database. Available online: <https://rdc28.cwb.gov.tw/> (accessed on 18 September 2020).
- [99] Yih-Guang Leu, Design of Center-of-gravity-based Intelligent Prediction Interval Models and its Applications, MOST Project Report, 2018.
- [100] GWEC. Wind industry installs record capacity in 2024 despite policy instability, Belgium, <https://www.gwec.net/gwec-news/wind-industry-installs-record-capacity-in-2024-despite-policy-instability>
- [101] A. Sharifian, M. J. Ghadi, S. Ghavidel, L. Li, and J. Zhang, "A new method based on Type-2 fuzzy neural network for accurate wind power forecasting under uncertain data," *Renewable energy*, vol. 120, pp. 220-230, 2018.
- [102] H. H. Aly, "A novel deep learning intelligent clustered hybrid models for wind speed and power forecasting," *Energy*, vol. 213, p. 118773, 2020.
- [103] H. Quan, D. Srinivasan, and A. Khosravi, "Short-term load and wind power forecasting using neural network-based prediction intervals," *IEEE transactions on neural networks and learning systems*, vol. 25, no. 2, pp. 303-315, 2013.
- [104] R. Tahmasebifar, M. P. Moghaddam, M. K. Sheikh-El-Eslami, and R. Kheirollahi, "A new hybrid model for point and probabilistic forecasting of wind power," *Energy*, vol. 211, p. 119016, 2020.
- [105] N. Korprasertsak and T. Leephakpreeda, "Robust short-term prediction of wind power generation under uncertainty via statistical interpretation of multiple forecasting models," *Energy*, vol. 180, pp. 387-397, 2019.
- [106] S. Maskey, V. Guinot, and R. K. Price, "Treatment of precipitation uncertainty in rainfall-runoff modelling: a fuzzy set approach," *Advances in water resources*, vol. 27, no. 9, pp. 889-898, 2004.
- [107] J. Tikka and J. Hollmén, "Sequential input selection algorithm for long-term prediction of time series," *Neurocomputing*, vol. 71, no. 13-15, pp. 2604-2615, 2008. Time-series forecasting
- [108] Wonnacott TH, Wonnacott RJ. Introductory statistics. New York: Wiley; 1996.
- [109] Ş. İ. Birbil and S.-C. Fang, "An electromagnetism-like mechanism for global optimization," *Journal of global optimization*, vol. 25, pp. 263-282, 2003.

- [110] S. Dasgupta, A. Biswas, S. Das, B. K. Panigrahi, and A. Abraham, "A micro-bacterial foraging algorithm for high-dimensional optimization," in *2009 IEEE Congress on Evolutionary Computation*, 2009: IEEE, pp. 785-792.
- [111] Albers B, Bray D, Lewis J, Raff M, Roberts K, Watson J. *Molecular Biology of the Cell*. New York: Garland Publishing Inc.; 1994.
- [112] W. Tang, Q. Wu, and J. R. Saunders, "A bacterial swarming algorithm for global optimization," in *2007 IEEE congress on evolutionary computation*, 2007: IEEE, pp. 1207-1212.
- [113] F. Torfi, R. Z. Farahani, and S. Rezapour, "Fuzzy AHP to determine the relative weights of evaluation criteria and Fuzzy TOPSIS to rank the alternatives," *Applied soft computing*, vol. 10, no. 2, pp. 520-528, 2010.



## 自 傳

我是曹顥瀚，來自於台北市。我喜歡吸收不同的知識。很幸運地在內湖高工求學階段中所選的科系與我的興趣相符。並且在高職階段我主動參加丙與乙級相關的證照考試並取得相關的證照，參加兩次作文比賽獲得第二名與嘉獎的獎項。於勤益科技大學的求學階段我得到 IC layout 的初步實作經驗並學習積體電路製程的整體流程與方向。碩士階段就讀國立臺灣師範大學工業教育學系電機電子組，研究重點為模糊控制、立體視覺與自走車避障技術。在此期間，我不僅建立單晶片實作經驗與控制系統的技術基礎，也養成解決跨領域應用問題的實務能力。藉由結合理論與實作，我初步認識到智慧化系統在工程領域中所能發揮的潛力，也促使我立志於更進一步的學術研究。並且在碩士就學階段中有幸加入台灣電力公司綜合研究所擔任研究助理，讓我累積許多再生能源相關的實務經驗。為了延續對人工智慧與工作所學內容地探究與熱情，我選擇繼續攻於博士並於求學過程中專注於人工智慧與最佳化方法應用到再生能源相關的研究，在博士生涯的中期階段我選擇投入於水資源領域的研究，聚焦於水庫入流量預測、預測區間方法（Prediction Interval Methods）與流域多水庫發電決策最佳化系統等主題。在這些研究內容中，我整合人工智慧、模糊邏輯、多目標演化演算法與多準則決策方法作為基礎，設計一套能因應不確定性與極端氣候條件的流域多水庫發電決策最佳化系統。本研究涵蓋結合氣象資料的短期水庫入流量預測技術、多目標最佳化方法、模糊決策模型與多水庫聯合調度策略，不僅具備理論深度，更強調實務應用的可行性與效益。並且在博士期間所做的研究成果已發表於 5 篇中英文期刊與 2 篇研討會中，並透過臺灣中部地區實際流域進行實際之案例分析。這段學術歷程讓我與實際廠區運轉人員接觸，經過討論與實驗，也讓我更加堅信，科學研究應以實際需求為導向，融合多元技術以達成永續發展的目標。未來，我將持續在人

工智慧領域上進行研究，期望以所學回饋社會，並在學術與工程實務間建立更緊密的連結。



## 學 術 成 就

日期	相關著作	標題
2020/01/25	台電工程月刊 857 期 (期刊)	定量降雨預報技術應用於德基水庫 集水區之適用性探討
2020/05/25	台電工程月刊 861 期 (期刊)	風機發電機故障預判模型之建立
2021/06/11	Energies, 14(12), 3461(期刊)	A Method of Multi-Stage Reservoir Water Level Forecasting Systems: A Case Study of Techí Hydropower in Taiwan
2021/12/15	Energy, Volume 237(期刊)	A center-of-concentrated-based prediction interval for wind power forecasting
2022/01/25	台電工程月刊 881 期 (期刊)	人工智慧應用於水庫水位預測與水 力發電領前模擬-以德基水庫為例
2023/08/22	The 20th World Congress of the International Fuzzy Systems Association(研討會)	Implementing Extreme Climate Reservoir Inflow Prediction based on Interval Type-2 Fuzzy Logic
2024/08/11	International Conference on Fuzzy Theory and Its Applications(研討會)	A Method for Hourly Load Forecasting Throughout the Day Using Fuzzy Neural Networks and Decaying Average

2025/04/02	International Journal of Fuzzy Systems(期刊)	Developing an Hourly Multi-reservoir Optimization System Adaptable to Extreme Weather Conditions Using Multi-objective Optimization, Fuzzy Logic, and Fuzzy TOPSIS

參加過的研究計畫：

2017：資料驅動之模糊類神經網路預測模型塑模與其應用(II)

2018：以重心為基礎之智慧型預測區間模型設計與其應用

2023：智慧型預測與最佳化策略應用於流域多水庫系統

