

中華民國一一三年二月・第五十一卷第一期

土木水利

The Magazine of The Chinese Institute of Civil and Hydraulic Engineering

February
2024



ISSN 0253-3804



NT\$350



Volume 51, No. 1

社團法人
中國土木水利工程學會 發行
CIVIL AND HYDRAULIC ENGINEERING

你的付出被看見
水利職人分享餐會

學會資訊看板

專 輯

永續水資源
之研究發展與應用

112 年
工程環境與美化獎

特別報導




亞新工程顧問股份有限公司
MOH AND ASSOCIATES, INC.

台北 | 台中 | 高雄 | 仰光 | 曼谷 | 新加坡 | 香港 | 澳門 | 北京



運輸工程 | 大地工程 | 數位工程 | 結構工程 | 環水工程 | 專案及施工管理 | 建築、都市計劃、景觀及室內設計 | 機電工程



Our World Our Work

亞新集團創業於 1975 年，多年來的經營發展，已逐漸成為亞洲地區居於領先地位的國際工程顧問公司。亞新集團主要是為東亞及東南亞地區政府及私人企業提供包括基礎建設、土地開發、建物結構、環境工程及資訊科技等綜合性國際化技術與管理的全方位專業服務。

目前，亞新集團有一千二百餘位具有不同專業領域的技術人員，分公司及關係企業依地理位置主要分布於大中華地區（台北、台中、高雄、香港、澳門、北京），東南亞地區（仰光、曼谷、新加坡），藉著從事專業活動的溝通與互動，將這些地區緊密的結合創造一個共同體，建構分享一個完整的專業服務網絡。



221411 新北市汐止區新台五路一段112號22樓（東方科學園區A棟）

Tel: (886-2) 2696-1555 Fax: (886-2) 2696-1166 Website: www.maaconsultants.com

E-mail: maagroup@maaconsultants.com



三貂嶺生態友善隧道 - THE DARKLINE 時空暗線

土木水利

社團法人中國土木工程學會會刊



發行人：高宗正

出版人：社團法人中國土木工程學會

主任委員：詹錢登（國立成功大學水利系特聘教授兼工學院院長、編輯出版委員會主任委員兼總編輯）

定價：每本新台幣350元、每年六期共新台幣1,800元（航郵另計）

繳費：郵政劃撥00030678號 社團法人中國土木工程學會

會址：10055台北市中正區仁愛路二段一號四樓

電話：(02) 2392-6325 傳真：(02) 2396-4260

網址：<http://www.ciche.org.tw>

電子郵件信箱：service@ciche.org.tw

美編印刷：中禾實業股份有限公司

地址：22161新北市汐止區中興路98號4樓之1

電話：(02) 2221-3160

社團法人中國土木工程學會第二十六屆理監事（依姓氏筆劃排序）

理事長：高宗正

常務理事：朱惕之 余信遠 廖學瑞 賴建信

理事：王宇睿 王昭烈 林子剛 林祐正 林聰利 胡宣德 高銘堂

張荻薇 莊均緯 許泰文 陳仲賢 曾榮川 黃一平 楊正君

楊偉甫 歐善惠 謝尚賢 謝震輝

常務監事：宋裕祺

監事：王藝峰 吳文隆 呂良正 沈景鵬 邱琳濱 賴建宏

先進工程

- 混凝土工程
- 鋼結構
- 運輸工程
- 鋪面工程
- 資訊工程
- 工程管理
- 非破壞檢測
- 先進工程

永續發展

- 永續發展
- 國土發展
- 水資源工程
- 大地工程
- 海洋工程
- 環境工程
- 景觀工程
- 綠營建工程
- 能源工程
- 天然災害防治工程
- 工程美化
- 營建材料再生利用

國際兩岸

- 國際活動及亞洲土木工程聯盟
- 兩岸活動
- 亞太工程師

教育學習

- 工程教育
- 終身學習
- 土木史
- 工程教育認證
- 大學教育
- 技專院校
- 學生活動

學會活動

- 學會選舉
- 學術活動
- 土水法規
- 介紹新會員
- 專業服務
- 學會評獎
- 學會財務
- 年會籌備
- 會務發展
- 會士審查
- 公共關係 [工程倫理]

出版活動

- 中國土木水利工程學刊
- 土木水利雙月刊

分會

- 土水學會
- 土水南部分會
- 土水部分會
- 土水東部分會

中國土木工程學會任務

1. 研究土木水利工程學術。
2. 提倡土木水利最新技術。
3. 促進土木水利工程建設。
4. 提供土木水利技術服務。
5. 出版土木水利工程書刊。
6. 培育土木水利技術人才。

土木水利雙月刊已列為技師執業執照換發辦法之國內外專業期刊，土木工程、水利工程、結構工程、大地工程、測量、環境工程、都市計畫、水土保持、應用地質及交通工程科技師適用。

中國土木工程學會和您一起成長！

中華郵政北台字第518號 執照登記為雜誌 行政院新聞局出版事業登記証 局版臺誌字第0248號

112年工程環境與美化獎特別報導

112年工程環境與美化獎首獎作品剪影	周南山
永續貢獻獎：臺北榮總重粒子癌症治療中心新建工程	3
景觀美化類首獎：三貂嶺生態友善隧道	6
環境生態類首獎：大湳森林公園	9

「永續水資源之研究發展與應用」專輯 (客座主編：蔡文柄助理教授、詹錢登特聘教授)

專輯序言：永續水資源之研究發展與應用	蔡文柄／詹錢登	13
淺談深度學習在水文領域之發展	何紹維／蔡可安／蔡文柄	14
氣候變遷資料偏差校正及水文頻率分析之探討	蘇元風／劉俊志／陳韻如	24
從參數校正到參數學習之探討—可學習物理意義之人工智慧技術	蔡文柄／蔡可安	29
結合類神經網路與小波分析進行多源雨量融合及流量預測	江衍銘／李楠楠／蔡可安	38
應用深度學習與遠端監視影像分析技術於防災	蘇元風	47
小水力發電之發展歷程、現況與推動建議	劉宏仁／林文勝／游景雲／陳谷汎	52
美濃溪上游段以自然為本在地滯洪解決淹水方案	邱昱嘉／游景雲／塗宗明／王澤琳／溫仲良	59
探討二重疏洪道之通洪能力改善策略	吳湘琪／陳怡如	66
共創科學-社會經濟路徑以邁向永續流域綜合管理造福社稷	張斐章／廖秀娟／黃誌川／江莉琦／許少瑜／鄭舒婷／石曜合／孫維	72

學會資訊看板

你的付出被看見 113年3月6日 水利署「水利職人交流分享餐會」報導	封底裡
------------------------------------	-----

廣告特搜

台灣世曦工程顧問股份有限公司 — 夢想和幸福 零距離的接軌	封底
亞新工程顧問股份有限公司 — Our World Our Work	封面裡
義力營造股份有限公司 — 義呈實諾 力呈卓越	37



112年工程環境與美化獎首獎作品剪影 (一)

永續貢獻獎： 臺北榮總重粒子癌症治療中心新建工程

周南山 / 國立臺灣大學土木工程學系 兼任教授、工程環境與美化委員會 主任委員

中國土木水利工程學會 112 年工程環境與美化獎報名作品共計 56 件，分為景觀美化和環境生態二類，參賽作品中佳作連連，筆者很榮幸擔任評審委員會主委，乃將永續貢獻獎、首獎得獎作品做一系列介紹。

首先介紹 112 年特別成立的永續貢獻獎作品。

本案由潤泰集團尹衍樑總裁個人捐獻，並由潤泰公司籌劃多年，精心打造成為世界第十四座重粒子加速治療中心。所有設施與工程建設均以永續營運為目標，並在十五個月完成施工和取得執照，以及早嘉惠癌症病患。為符合重粒子對癌症病灶精準照射治癌之需求，建築與醫療設備採零誤差設計、施工與安裝。

本案採用巨積混凝土和冰凍工法，建築外牆使用「樹影預鑄工法」，在堅硬的混凝土外牆上刻印出自然的樹影，讓建築整體多了一種生命的氣息，配合周遭環境呈現

樹影、劈裂紋與清水面的樣貌，讓整體建築外觀呈現「沉靜」的效果，以撫慰病患的心靈。目前甫完工使用，已幫助數百位患者痊癒，將成為廣大癌症患者之救星。本案乃基於人道關懷之建設，成就斐然，故本學會特頒此永續貢獻獎，以表彰其對工程、醫療及社會之重大貢獻。



永續貢獻獎－臺北榮民總醫院

臺北榮總重粒子癌症治療中心新建工程



臺灣第一座、全世界第14座
重粒子癌症治療中心



潤泰營造股份有限公司

莊傳業 執行副總
2023/10/3

112年工程
環境與美化獎

臺北榮總重粒子中心的
「傳世建築」

冰鎮+樹影預鑄工法 耐震、
抗輻射 美如日式庭園




臺灣第一座、全世界第14座 重粒子癌症治療中心

潤泰集團結合在日本具有多家粒子治療中心規劃經驗的日建設計公司，在臺北榮總西側院區打造出友善的環境及安全的空間，包括地下一層、地上四層的重粒子癌症治療中心，在嚴謹與效率的職人精神下整體工期在15個月完工。



潤泰營造股份有限公司



二.工程創意與美質

建築外觀 3D意象與完工照片



二.工程創意與美質

巨積混凝土冰鎮工法

本建築為重粒子醫療專用設備，皆為輻射屏蔽牆為配合各式管線貫穿樓板及牆面，考量輻射屏蔽牆厚度及材質；本工程輻射防護區屏蔽牆之最大混凝土厚度高達6m，故採用**巨積混凝土**。



巨積混凝土品質要求：

1. 強度達 280kgf/cm^2
2. 坍落度達 $50\pm 10\text{cm}$ ，且3~15秒內需達規定坍落度
3. 芯溫 $\leq 70^\circ\text{C}$ ，且芯表溫差 $\leq 20^\circ\text{C}$
4. 密度達 2350kg/cm^3 以上

配比中加入片冰及冰水 → 控制 芯溫 $\leq 70^\circ\text{C}$
使用保溫材料保溫 → 控制 芯表溫差 $\leq 20^\circ\text{C}$

12

三.符合與自然、人文藝術相結合之原則




外牆版的設計上，使用了「樹影預鑄工法」，在堅硬的混凝土外牆上刻印出自然的樹影，並且打造留白如日式庭園枯山水的前庭，讓建築整體兼具生命與靜謐之美。

三.符合與自然、人文藝術相結合之原則


預鑄外牆的工藝

- 榮總重粒子治療中心雖為醫療院所，但榮總醫療團隊希望在建築外觀的設計上，可以讓病患的感覺是自然、放鬆的一種情境。
- 潤泰團隊為達到榮總的期望，在外牆版的設計上使用了「樹影預鑄工法」；使用一種特殊的方法，在堅硬的混凝土外牆上刻印出自然的樹影，在樹影的搭配之下，讓建築整體多了一種生命的氣息。



23

三.符合與自然、人文藝術相結合之原則



控制室/準備室/治療室

26

三.符合與自然、人文藝術相結合之原則



榮總重粒子治療中心，採用是日立的儀器設備；在與日立配合的過程中，其中最為困難的是，環型軌道天車的放樣及預埋。
重粒子治療的方式，是將粒子加速至光速的百分之七十，再針對癌症病灶進行照射，而加速器就是整體的核心設備；為了將這些加速器設備，精準的定位在加速器室內，我們需要在該差不得超過2mm的狀態之下，將環型軌道天車預埋構件，事先埋設在尚未灌漿的混凝土內

三.符合與自然、人文藝術相結合之原則

榮總重粒子治療中心，採用是日立的儀器設備；在與日立配合的過程中，其中最為困難的是，環型軌道天車的放樣及預埋。
重粒子治療的方式，是將粒子加速至光速的百分之七十，再針對癌症病灶進行照射，而加速器就是整體的核心設備；為了將這些加速器設備，精準的定位在加速器室內，我們需要在該差不得超過2mm的狀態之下，將環型軌道天車預埋構件，事先埋設在尚未灌漿的混凝土內



日立的儀器設備設置完成

28

四.景觀綠美化及節能減碳成果



舊有原石融入
景觀意象永續生態

四.景觀綠美化及節能減碳成果

景觀植栽



景觀休憩區

36

六.結論

臺灣第一座、全世界第14座
重粒子癌症治療中心

潤泰集團結合在日本具有多家粒子治療中心規劃經驗的日建設計公司，在臺北榮總西側院區打造出友善的環境及安全的空間，包括地下一層、地上四層的重粒子癌症治療中心，在嚴謹與效率的職人精神下整體工期在15個月完工。



109/6/20

109/6/27

石來運轉
榮總重粒子癌症治療中心 觀禮
2020.06.27

46



112 年工程環境與美化獎首獎作品剪影 (二)

景觀美化類首獎：三貂嶺生態友善隧道

將歷經 30 年荒廢的舊宜蘭線鐵路三貂嶺隧道重新打開，以鋼筋作為鋪面與護欄，極具創意與特色。保留歷史歲月痕跡與原始的生態樣貌，創造出靜謐卻充滿生命力的隧道，讓遊客近距離欣賞自然生態及隧道歷史痕跡，是值得推崇的特殊景觀設計案。

本案獲得諸多國內外景觀大獎，亦是北台灣著名打卡景點。



首獎－三貂嶺生態友善隧道



本案於今年土木學會年會論壇中進行作品發表，頗受好評。



本案獲土木學會 112 年景觀美化獎首獎。圖為簡報封面及主辦、設計、監造、施工單位。



計畫緣起

隧道初評

✓民國101及107年兩次全線調查→進行初評

- ✓隧道內通風良好，無需安裝通風設備
- ✓隧道內土石堆積情形調查分布
- ✓隧道壁體初步全面檢視
- ✓排水溝洩水功能正常，可考量保留原始風貌
- ✓洞內生態豐富
- ✓結構功能尚在，設計階段進行補充調查、檢測及長期監測評估



重探百年隧道、初步評估再利用

令人驚訝的是隧道內通風良好，且生態豐富，包括蝙蝠長駐。



工程創意與美質

三貂嶺隧道東口 (0K+990) 至三瓜子隧道西口 (2K+975) 隧道段

營造隧道體驗美學

水鏡延伸，將山與藍天拉進隧道中，營造由暗轉亮、由窄變寬的對比，渲染出河谷乍現的壯闊之美。往天際延伸的鏡面水池帶將成為著名的地標打卡點。



隧道西洞口的鏡面水池是一奇觀



工程創意與美質

三瓜子隧道西口 (2K+975) 至端點 (3K+192) 隧道以西

本段為牽引道，將車道沿崖壁與既有動線銜接，步道隨崖壁地形及既有植栽調整，如同嵌入崖壁一般，降低對邊坡生態的干擾與破壞，使步道隱身於森林當中



引道建於懸崖側壁，不破壞邊坡。



自然、人文藝術結合

三瓜子隧道西口 (2K+975) 至端點 (3K+192) 西棧橋



用微型樁、RC地樑及三角托架，以輕巧結構降低對景觀的毀傷力，使結構能隱藏於環境中，維持環境自然度，避免大型開挖



用微型樁（岩釘）將三角托架植入岩盤中，並配以地樑及鋼筋步道，不破壞週遭環境，施工頗為困難。



自然、人文藝術結合



西棧橋



自行車道亦以防銹鋼筋為鋪面，設計獨特。



輪椅族亦可輕鬆體驗本隧道




隧道外的懸壁棧道亦由鋼筋做為步道

棧道的確是邊坡工程的高挑戰



蝠蝠倒立於隧道上端，也無懼人類。



隧道側壁的岩盤，碳酸碳結晶形成多彩的地質景觀。



隧道內的鋼筋步道與地燈

景觀組評審委員 (依筆劃序)

周南山 (召集人)：土木水利工程學會工程環境與美化委員會主委、
台大土木系兼任教授、前中興工程顧問公司總經理

何明錦：前內政部建築研究所所長、前中華大學建築與設計學院院長

汪荷清：前皓宇工程顧問公司總經理、前中華民國景觀學會理事長

曾富美：元皓景觀設計有限公司總監、中華民國景觀學會景觀師

陳明竺：前美國南卡州哈賓遜新市鎮總規劃師、前文化大學建築系系主任

鍾維力：前交通部鐵道局總工程司、前台北市捷運工程局聯合開發處處長



112年工程環境與美化獎首獎作品剪影 (三)

環境生態類首獎：大湫森林公園

大湫森林公園位於桃園市八德區，利用原有 16.6 公頃龐大的大湫營區創造出森林公園。

新建公園保留原有豐富植生環境，具備生態、教育、環境、滯洪、減碳、展演及休閒娛樂等多功能。工程採用減法與再利用、增進人與自然環境連結等原

則，將原本大湫軍事營區建置成為桃園都會中心的生態方舟，兼具都市中體驗自然生態以及市民間交流互動功能，是個具有永續發展的都會森林公園。此外，桃園市政府相關局處進駐公園，各本行政規畫創造各自的特色，公園特色將更加繽紛，價值因而提升。



首獎－大湫森林公園

111年度桃園市公園綠地景觀工程第1標(開口合約)之第1派「桃園市八德區大湫森林公園景觀工程第二期」

社團法人中國土木水利工程學會
112年「工程環境與美化獎」
【工程環境與生態類】

112年10月2日

主辦機關：桃園市政府工務局
Department of Public Works Bureau

設計/監造單位：工拓緯工程顧問有限公司

施工單位：友聯景觀工程有限公司

大湫森林公園榮獲土水學會 112 年環境生態類競賽首獎。
圖為主辦單位、設計、監造及施工單位。

工程概要 生態檢核 設計理念 工法特色 生態永續

恢復自然與人的連結

栽植蝴蝶食草植物
搭配昆蟲種類密源植物或
寄生植物，提升棲地功能

生態島
自然基底構築利植物生長

人為主要活動區
保持5公尺以上距離。

栽植高草類
提供棲地與緩衝人為干擾

緩和坡面
供水生動物攀爬

生態工法設計理念



滿佈誘蝶植物，與蝶共舞。



廣設草溝、碎石溝及透水鋪面，減少混凝土之使用。



循環經濟與植栽固碳



大滴森林公園的各項創新突破



循環經濟(回收再利用)

水與綠結合：

1. 百年大圳重生：利用閘門管制做為中央生態池及連通河道補水及洩洪之用。
2. 全區水循環河道，循環過濾徑流水，打造更多元生態環境。
3. 滯洪池：平時為動植物棲息之生態池，雨時為滯洪池，乾季時則可視情況利用園區內水井補水。



設計周詳的全區水循環系統

為了保留永續的生態，我們排除萬難，成功打造了桃園森呼吸基地，黃鸝鳥及各種生態物種的再度回歸證明我們做對了！

見水 森滴



完工後的大湫森林公園兼具生態、景觀、防洪、休閒、教育、展演等多功能，規模及效益不亞於台北大安森林公園。



參與現地評審的委員（左起）：
陳本康、吳宗信、周南山、張武訓、陳有祺



公園中的滯洪池（兼生態池與景觀池）



滯洪池另一角



造型特殊的竹製休息涼亭



公園內並設有民俗藝術村等多元化教育、休閒設施。



步道採用透水鋪面以增加蓄水空間



公園內遍佈草溝，以取代混凝土溝渠。



在森林公園中以步道穿越保護林區



綠蔭遍地的步道

環境生態類評審委員（依筆劃序）

周南山（召集人）：土木水利工程學會工程環境與美化委員會主委、台大土木系兼任教授、前中興工程顧問公司總經理

吳宗信：師大生命科學專業學院優聘教授、中華民國水資源環境教育學會理事長

吳淵洵：中華大學土木系兼任教授、前中華地工材料協會理事長

陳本康：台灣省水土保持技師公會理事兼臉書總編輯、前台灣省應用地質技師公會理事長、前康技技術顧問公司董事長

陳有祺：中華大學景觀系教授（前系主任）

張武訓：水利技師、前高鐵局副局長、台北市捷運局南工處處長



永續水資源 之研究發展與應用

專輯序言

北投草山水道「藍寶石泉」- 完工於1932年的臺北城自來水第二水源

專輯客座主編 蔡文柄／國立成功大學水利及海洋工程學系 助理教授
詹錢登／國立成功大學水利及海洋工程學系 特聘教授

隨著人口成長與經濟快速發展，人類對地球自然資源的需求越來越大，加上氣候變遷因素，明顯威脅人類未來的發展。聯合國「2030 永續發展目標」(Sustainable Development Goals, SDGs)，從2015年提出至今，已有上百個國家提出永續發展目標的相關計畫。就水資源而言，水資源的利用與管理越來越趨於永續經營之觀念，在人類使用及環境需求中尋求平衡，將永續與防災觀念融入水資源工程建設與經營管理之中。然而，水資源與周遭環境的關係，錯綜複雜，在既有的環境系統中建構合適的永續水資源管理策略及創新技術，有其必要性與挑戰性。近年來隨著電腦技術及人工智慧技術的快速發展，利用這些新穎技術於水資源永續經營管理是個新的研究發展趨勢。

通訊方式：蔡文柄助理教授 wptsai@gs.ncku.edu.tw
詹錢登特聘教授 cdjan@ncku.edu.tw

本專輯邀請專家學者撰寫九篇文章，介紹水文水資源與永續流域綜合管理最新研究發展及應用。第一篇文章介紹近年人工智慧的發展概況及介紹深度學習在水文領域的發展潛力。第二篇探討氣候變遷資料於水文應用之偏差校正方法。第三篇介紹新穎的深度學習參數學習框架，此框架可以有效學習物理模型之物理意義。第四篇介紹應用小波分析方法結合人工智慧，進行雨量時頻分析及流量預測。第五篇介紹遠端監視影像的發展及其在土木工程或防災領域之應用潛力。第六篇介紹小水力發電之發展歷程、現況與推動建議。第七篇以美濃溪上游淹水段為例，提出自然的解決方案，提高土地耐淹能力，達成韌性城市。第八篇探討大台北地區二重疏洪道通洪能力的改善策略，減輕與洪水相關的損失。第九篇則針對濁水溪流域，考量社會、經濟、自然環境等面向，綜合研究並提出永續流域整合管理之建議。期盼本專輯內容能夠提升讀者對於水利工程及永續水資源利用與管理有更多的認識。🇹🇼



淺談 深度學習 在 水文領域 之發展

何紹維*／國立成功大學水利及海洋工程學系 碩士生

蔡可安／國立成功大學水利及海洋工程學系 碩士生

蔡文柄／國立成功大學水利及海洋工程學系 助理教授

近年來，深度學習（Deep Learning, DL）在各個領域都取得了顯著進展，其多功能性改變了多個行業，同時在科學研究和模型建構方面呈現出新穎且獨特的潛力，儘管水文領域的發展逐漸趨於穩定，深度學習卻為該領域帶來了多項創新的可能性；本文認為，在水文領域中，深度學習可以開創全新的研究方向，在這個新途徑中，機器學習演算法首先預測與觀測數據一致的結果，接著使用可解釋性方法解析深度學習模型，以供科學家進一步評估；然而，深度學習在水文領域也面臨一些挑戰，包括數據限制、異質性和協同效益；同時，水文領域對深度學習應用的經驗相對不足，其進步需要科學家和相關群體的協同努力，結合基於過程的模型與深度學習模型有助於克服數據限制，而數據和基礎模型的開源則能提高整個領域的效率；此外，公開舉辦模型建置比賽也有助於推動水文數據科學教育的發展，需要眾人共同參與；總結來說，深度學習在水文領域中展現出豐富的潛力，同時也可能促使機器學習不斷取得進步。

前言

在過去的幾十年中，水文學領域已經經歷了多個機器學習（Machine Learning, ML）方法的發展，從正規化線性回歸方法^[1]到支持向量回歸方法^[2]，從遺傳演算法^[3]到人工神經網路（Artificial Neural Networks, ANNs）^[4-8]，再從決策樹到隨機森林^[9]，以及從高斯過程^[10]到幅狀基底函數網路^[11]；人工神經網路在水文領域有著廣泛的應用，包括地表逕流、地下水、水質、鹽度、降雨量估計和土壤參數化的模型^[12,13]；每種方法都為解決特定問題提供了有效的方案，然而，它們也各自存在一些限制。因此，隨著時間的推移，一些人可能對機器學習的發展感到失去興趣，同時另一些人可能對於新興名詞，如深度學習（Deep Learning, DL），是真正的技術進步還是只是炒作感到擔憂。

傳統上神經網路主要被用於模擬輸入與輸出之間的映射關係，其重點在於提高預測的準確性，然而就

神經網路在科學研究中的應用來說，最主要的問題來自於無法理解內容之黑匣子的特性，很難促進對於特定領域的理解，同時數據驅動的研究可能缺乏明確的假設，這與傳統的以假設驅動的科學方法產生了明顯的對比，因此深度學習方法內外都受到了要求解釋網路決策的巨大的壓力，像是歐洲數據隱私法規定（2018年1月），對演算法用戶具有重大影響的自動化個人決策必須提供「解釋權」，用戶可以要求演算法對其的決策做出解釋^[14]；深度學習研究的一些最新進展集中在如何解決這些問題上，值得注意的是，一個新的領域被稱為「AI neuroscience」，已經產生了有用的解釋技術來幫助科學家解釋深度學習模型（Shen, 2018^[15]）（後續將稱為 Shen18），解釋方法的主要種類包括：(1) 隱藏層的逆向工程，將深度網路的決策歸因於輸入特徵或輸入子集；(2) 將知識從深度網路轉移到可解釋的降階模型；(3) 網路運作的可視化；許多科學家還設計了對個案使用的特別方法，例如研究輸入和神經元運作之間的相關性^[15,16]。

* 通訊作者，N86111108@gs.ncku.edu.tw

近年來以深度學習與傳統假設相輔的研究方法正在成長，該方法一共需要三個要素：大量水文數據、強大的機器學習算法和從訓練完成的網路中提取可解釋性的研究方法（如資料可視化的技術）；這個新方法從擁有數據開始，使用深度學習產生假設，並使用具有可解釋性的方法，幫助我們理解水文系統的功能；深度學習（DL）是一個以大型人工神經網路為架構的一套工具，名稱中的「深度」是由於其具有多層的結構，而這有助於深度網路去呈現出數據中隱藏的抽象概念^[17]，在給定與真實值相關的輸入資料後，深度學習模型可以對該真實值的變化或分類做出預測，無論該值是連續資料或分類資料，例如對於基本的電腦辨識問題，深度學習可以去識別圖片中的主題或是對象^[18-20]，同時其也能運用在遙測圖像上^[21]；對於序列資料，深度學習可以掌握自然語言中的順序^[22,23]，甚至去預測出演員在影像下一幕的動作^[24]；深度學習還可以生成或是合成出帶有某些藝術風格的圖像^[25]，或是回答以自然語言表示的問題^[26,27]；在其具有深度的結構下，深度學習可以從大數據中自動找出數據間的關聯與特徵，而不需要以人工的方式去對特徵做標記；作為現代人工智慧的基礎，深度學習近年來取得了許多進步與成果，並解決了幾十年來人工智慧所遇到的阻礙^[28]。

雖然深度學習在許多領域中創造了亮眼的成績，並在部分領域中成為解決問題的首選方案，但目前為止在水文領域內對於深度學習的應用還十分有限^[15]，儘管有許多使用深度學習得到的成果^[29-34]，但大部分研究還尚未廣泛地採用這些新工具，在上述文章中展現了深度學習方法在水文科學領域中依然擁有許多機會，深度學習可以提供強大的預測能力並為科學研究提供額外的途徑；之後本文將探討在水文領域中使用深度學習和大數據將會遇到的各種挑戰，並研究如何強化應用於水文科學領域。

深度學習應用之介紹

隨著大量水文數據的累積，深度學習呈現出更廣泛的潛力與機會，這包括地表、地下、城市、基礎建設和生態系統的各種資料，在本文中，水文指的是完整的水循環，以及涉及生態系統和地球介質的相關過程，遙測所得的水文數據量也逐漸增加^[35]；舉例來說，衛星觀測的數據集包括降水量、地表土壤濕度^[36-38]、植

被狀態和指數^[39]、推斷的蒸發散量資料^[40]、地表水儲存^[41]、覆雪量^[42]，以及估算流量的研究^[43]等等。在數據整合方面，現今已有地質^[44]和土壤的數據集，其中包括了美國、歐洲、南美洲和亞洲部分地區的流量和地下水資料，還有全球一些大型河流^[45]、水化學、地下水樣本和其他生態地球科學數據集；水文科學促進大學聯盟（CUAHSI, the Consortium of Universities for the Advancement of Hydrologic Science, Inc.）運營了兩個水數據的發現和歸檔系統：時間序列的水文資料系統 Hydrologic Information System^[46]和包含所有水數據類型的 HydroShare^[47]。同時，水網路^[48]的概念已被提出並正在發展，以改善對這些新興數據集的取得難度。

此外，還有許多創新的資料收集方式正在發展，如立方衛星（CubeSats）、無人機、氣球、攝影測量傳感器或其他能獲取高精細度資料的感測技術^[49]；也有許多新方法提供許多以前未曾考慮到的測量形式和尺度，例如手機信號強度和手機拍攝的照片可用於監測降雨強度^[50]；紅外攝影圖像可以探測城市中複雜水流的水位資料^[51]；投放水中的物聯網（Internet of Things, IoT）傳感器可實時傳輸水中的狀態資料^[34]；這些新數據源覆蓋了自然和建築環境中難以想像的範圍和數量；然而每種新的測量方式都具有其獨特的優勢和特性，特別是在混合使用不同數據時，如何有效地利用這些資料是一項巨大的挑戰；相對而言，深度學習模型能夠在不需要大量專業知識人員的情況下構建，並迅速從這些數據中獲取有用的資訊和分析結果。

深度學習在各個科學領域中被廣泛地利用，而深度學習也為某些領域帶來實質性的轉變，從文獻檢索中就可以清楚地看到此現象的快速增長；水文領域不能再忽視深度學習在各個行業或科學領域帶來的革命性發展（Shen18）。各大科技公司都已迅速地採用深度學習驅動的人工智能並將其商業化^[52]，例如 Google 已將其研究重點從「移動裝置優先」改變為「人工智慧優先」^[53]，其普通用戶已可感受到這些投資的成果，像是機器翻譯或是語音助理，它們已可以像人類一樣交談^[26]；此外在 2012 年深度學習取得重大突破之後，人工智慧的專利在 2013 年到 2017 年間以 34% 的複合年增長率成長^[54]；同時在 Columbus^[54] 上報導，調查資料科學專業人士的回應中超過 65% 的人表示人工智慧是他們公司明年最重要的計畫。

從 2011 年以來，以深度學習為主題的投稿數量幾乎呈指數級增長，截至 2017 年複合增長率約為 100%（表 1）；深度學習在電腦科學（CS）中的占比從 2011 年的不到 1% 發展到 2017 年的 46%，這一變化表現了電腦科學中從傳統機器學習到深度學習的巨大變革，在其他領域雖相對緩慢，但也經歷了指數級增長，深度學習對機器學習的比率從 2011 年的 0% 成長至 2017 年的 33%；如 Shen18 所述，深度學習增強了物理數據的統計能力，實驗數據集中深度學習的使用者成長了 25% [55]，在生物學中深度學習已被用來預測基因序列中的潛在病理意義 [56]，當深度學習模型在預測高難度的特徵（例如來自分子組成所擁有的毒性）時，使用原始數據輸入的深度學習模型優於部分經由專家辨別的結果 [57]，深度學習正在各個領域取得許多進展。

ImageNetChallenge 是一種針對圖像分類和目標檢測的演算法競賽 [58]；每次的比賽主題都會有所變化，大賽管理組織提供了方便的資料存取方式，而其數據集共累積了約 1,400 萬張圖像和影像。2010 年的冠軍由大尺度的支持向量機（SVM）贏得。2012 年則是首次由深度卷積神經網路獲得冠軍 [59]。而這場勝利開始了深度學習的巨大成長，一直到 2017 年（最後一次比賽）為止，絕大多數的參賽者都是使用卷積神經網路參與比賽 [17]。

IJCNN 交通標識識別比賽是由 50,000 張圖像（48 像素 × 48 像素）組成，其見證了卷積神經網路的視覺識別能性能超過了人類能力的時刻 [60]，同時卷積神經網路在醫學圖像中識別癌症的表現也優於人類 [61]。

TIMIT 語音資料庫是一個保存了 630 名英語使用者錄音的數據集，長短期記憶模型（LSTM）的表現明顯優於隱藏式馬可夫模型（HMM）的結果，同樣地，利用長

短期記憶模型的方法在識別關鍵詞 [62]、字符識別、語言識別、文本轉合成語音、社會信號分類、機器翻譯和手寫中文識別方面都顯著優於其他所有統計方法。

基於長短期記憶模型的語音識別系統在 Switchboard 語音資料庫中的會話語音識別已達到了「人類的水準」[63]，其併行版本在 MR BrainS13 數據集上也獲得了著名的像素級大腦圖像分割結果 [64]。

在時間序列資料的預測競賽上，在長短期記憶模型出現之前的 2015 年，由模糊和指數的組合模型贏得冠軍，但長短期記憶模型馬上在 2016 年贏下了比賽 [65]；相較之下，深度學習在水文領域的應用就沒有如此亮眼，但也已展現出巨大的潛力，深度電腦視覺模型已可用於從衛星圖像中推估降水量，並且也表現出比以往神經網路更優越的性能 [66,67]，同時也有使用生成對抗網路（GAN）來模擬或生成地質圖像的研究 [68]；專注於時間序列之深度學習模型則被應用於衛星感測土壤溼度之未來推估 [29]，而該推估值相較以往的簡單模型更可靠，上述的深度學習模型也已成功創建了部分地區的區域降雨逕流模型 [69]；同時也有應用深度學習在小數據集的研究，像是預測城市環境中的水流量和水利基礎設施中的水流動 [34]；除了利用大數據，深度學習也能夠靠自己本身創建出原本難以收集的大數據集，例如利用深度學習可以通過跟蹤熱帶氣旋、大氣流動和天氣鋒面產生新的數據集 [70,71]；同時機器學習也被用於解決氣候建模中對流參數化的話題 [72]。

深度學習之技術發展

隨著軟、硬體技術的發展，深度學習的性能也越來越強大，深度學習具有下列幾項獨特的優勢：

- 1. 深度網路的架構具有反映極複雜之函數的能力；
- 2. 經過訓練後，隱藏層可以運行模組化的函數，這

表 1 從 Web of Science 搜尋得到的論文數量（來源：Shen et al. [73]）

year	DL-non-CS	DL-CS	ML-non-CS	ML-CS	DL/ML-CS	DL/ML-non-CS
2011	0	23	1068	1838	1 %	0 %
2012	15	25	1310	1899	1 %	1 %
2013	35	80	1677	2360	3 %	2 %
2014	84	238	2228	3050	8 %	4 %
2015	308	709	3074	4405	16 %	10 %
2016	841	1462	4414	5361	27 %	19 %
2017	2035	2723	6125	5860	46 %	33 %

* DL-CS 的結果是通過以下方式搜尋而得「“topic” (TS) = “deep learning”, “and”, “research area” (SU) = “computer science”」；ML-CS 的搜尋方式幾乎與 DL-CS 相同，僅有 “deep learning” 項改為 “machine learning”；DL-non-CS 的搜尋方式為「TS = “deep learning” not SU = “computer science” not SU = education」，其中教育因為與本文對深度學習的定義無關而被刪除。DL / ML-CS 是 DL-CS 和 ML-CS 的比值，而 DL / ML-non-CS 以同樣原理取得。

些函數可以在被稱為遷移學習的過程中遷移到其他任務，並拓展訓練數據的價值；

3. 隱藏層結構可以自動提取數據的特徵，大大地減少了標記特徵所需的人工、專業知識和試誤時間；
4. 與像是分類樹的早期模型相比，大多數深度網路都是可微分的，這代表我們可以計算輸出相對於輸入或是網路中參數的導數，這使得利用這些導數的高效訓練算法成為可能；此外，由於神經網路具有可微性，因此可以進行 DL 模型輸入參數的敏感度分析，這在水文領域是一件非常重要的事情。

深度學習中的隱藏層可以被視為深度網路自身構建的工作空間，這些隱藏層經過訓練後從數據中萃取出某些特徵，然後由下游層使用這些特徵來預測應變量，例如 Yosinski^[74] 表明了深度視覺識別網路中的一些隱藏層負責識別人類或是動物的面部的位置；Karpathy 等人^[75] 表明文本預測網路中的一些隱藏神經元發揮了長度計數器的作用，而另一些則負責追蹤資料文本是否在引號之中，這些功能並不是由網路設計者所賦予，而是經過訓練後網路自己形成的；早期的網路結構不是沒有所需的深度，就是沒有經過巧妙的設計，以至於無法有效地訓練隱藏層，關於更多細節請參閱 Shen^[15] 和 Schmidhuber^[17]。

鑑於深度網路可以在沒有人指導的情況下識別特徵，他們可以提取出設計者不知道或沒有特意要讓網路去操作的特徵；若是水文系統中還有我們人類尚未發現的潛在關係，那麼這一特性將為我們提供一個發現潛在知識的新方向；例如，模仿哺乳動物進行導航的模型經過訓練後，網路隱藏層中自動出現了網格狀的神經元反映結構，這結果提供了獲得諾貝爾獎的關於這些結構功能的神經科學理論大力的支持^[76]。

如果對深度網路進行適當的正規化（Regularization）（正規化技術減少了模型的複雜性，使其穩健性提升），並在兩階段方法中依照誤差來調整的話，增加模型規模的同時其穩健性也不會弱於簡單模型^[77]；常見的正規化技術包括 (1) 提前停止（early stopping），在單獨的驗證集上監控訓練進度，一旦驗證指標開始惡化就停止訓練，或是 (2) 新穎的正規化技術像是 dropout^[78]，深度學習架構同時解決了梯度消失等問題^[79]。而在科學家們開始使用圖形處理單元（GPU）進行處理之前，現在大型網路的訓練規模在以往的計算上是難以置信的，

在深度學習的架構仍然在不斷發展的同時，專門處理深度學習任務的專用集成電路也已然問世。

常見的深度學習架構包括用於圖像識別的卷積神經網路（CNN）^[59,80]、用於時間序列建模的長短期記憶（LSTM）^[81,82]、變分自編碼器（VAE）^[83] 以及用於識別模式和生成數據（通常是圖像，但也包括文本、聲音等其他數據）的深度信任網路（Shen18）。除了上述架構以外，也有一種新的生成模型被稱為生成對抗網路（Generative Adversarial Network, GAN），其已在各個領域中活躍發展。GANs 的特性是它們擁有零和博弈框架^[84]，框架內的「生成器」和「鑑別器」之間不斷競爭進而學習。與其他通用模型相比，GANs 在生成的模式中擁有更大的靈活性。GANs 的能力也在地球科學領域得到了認可，特別是在受物理學啟發的機器學習研究中，GANs 已被用於生成某些複雜的物理、環境或社會經濟系統^[68,85]。

雖然深度學習模型展現出許多優點，但它也需要大量的電腦/程式專業知識。其中超參數的調整例如網格大小、學習率、批次大小等，通常需要先驗經驗和反覆地試誤，例如在圖形處理單元上的計算，這也與典型的水文學家的教育背景有很大的不同；而關於深度學習為何在各領域都能有所發展的基本理論也還未得到成熟的發展（Shen18），一些人認為深度學習的能力主要來自於記憶，而另一些人認為深度學習優先學習簡單的模式^[86,87]，兩階段程序（訓練和測試）更有幫助^[77]，儘管有這些解釋，但在視覺深度學習中已有深度網路可能會被小規模的對抗性樣本所欺騙，輸入圖像內無法察覺的干擾有時會使預測發生巨大的變化，從而導致不正確的結果^[88,89]；水文領域的深度學習應用是否存在此類問題還有待觀察，若我們能夠再現對抗性樣本，並將其加入訓練數據集中，理論上能提高模型的穩健性^[90]。

在醫學圖像診斷中，一些研究人員使用逆向工程方法，來顯示出圖像上的哪個像素導致網路對其解剖分類做出決定^[91]，在最近的研究中，新的人工智慧網路不僅能對圖像進行分類，還能解釋其為何做出這個決策以及為何圖像是一個類別而非另一個類別（圖 1），研究者訓練了一個用於圖像的分類和解釋模型，其中紅字是解釋中的「類相關」屬性（不同類別間的區分屬性），分類網路提取出影響決策的視覺特徵（圖像上的某些區域），然後解釋網路將這些區域與字典中的區別詞連繫在一起形成解釋，解釋其分類的原因以及為何它不屬於




圖 1 用於圖像的分類和解釋模型（來源：Shen *et al.* [73]）

其他類別，受限於有限的監測數據，在水文問題上很難達成同樣的高辨識率，但將輸入數據中的特徵與一些描述性詞語連接是一個值得參考的想法^[92]；將此概念拓展到水文領域中的精度檢索問題上^[66,67]，我們可以讓深度學習告訴我們衛星雲圖上的哪些特徵有助於減少偏差。

近期於水文領域之發展

隨著具有解釋性的機器學習方法之發展，一種與傳統假設驅動的研究方法互補的嶄新研究方法產生，如圖 2 比較了兩種從數據中獲得知識的方式，傳統方法中科學家們編輯和解釋數據以形成假設，（建立模型）描述數據和假設，然後模型的結果符合或是否定假設的數據和反饋（黃色路徑）將允許科學家修改模型和迭代；在數據驅動的方法中科學家收集數據並定義深度學習的目標變量（綠色路徑），然後調用解釋方法來提取數據一致性與人類能夠理解的假設（黃色路




圖 2 比較兩種從數據中獲得知識的方式 (來源: Shen *et al.* [73])

徑)，其中必須有一個驗證假設的步驟，訓練中保留的數據將應用於驗證；數據驅動的研究過程可以分為四個步驟：(1) 通過機器學習演算法產生假設；(2) 使用與訓練集內不同的數據作驗證，評估機器學習生成之假設；(3) 使用解釋方法來提取一致的數據和人類可理解的假設^[93]；(4) 將保留的假設交給科學家進行分析和近一步的收集數據；之後上述步驟將反覆進行。

與傳統方法相比，數據驅動的方法能夠使我們更有效地探索更多假設，雖然機器學習算法並不能確定沒有人為偏見（因為輸入項是人為定義的，而一些超參數是由經驗作調整的），但在探索更多的假設時，至少會大大地降低人為偏見的風險；在此我們可以用一種基於分類和回歸樹（Classification And Regression Tree, CART）的數據驅動方法（Fang and Shen^[94]；Tsai *et al.*^[95]）作為例子，從研究地區的眾多地貌數據開始，包括地形、土壤類型或厚度等資料，我們可以使用對基於過程的水文物理模型產生之誤差進行建模，這將可以分離出更容易產生誤差的條件；這過程僅僅是讓模型從數據裡發掘並表現出來，並沒有執行人類先入為主的任何設定或假設，在過程中也必須注意數據驅動時的穩健性，需要保留各數據集並執行交叉驗證來確認結果的普遍性，在過程中所有的假設一開始都是同樣有可能的而不會提早被排除，深度學習的這個優點可以用一句話來形容，「演算法沒有自我（個性）」，即其

不會因為喜好或其他原因而忽略掉了任何假設；在實際應用上，這種方法將可以更有效地同時檢驗多個相互競爭的假設^[95]。

機器學習的方法使我們能夠在數據中發現到人類難以識別的聯繫或複雜的模式，藉著深度學習的強大性能，它可以更好地去擬合最佳可實現模型（Best Achievable Model, BAM）並以此來映射輸入與輸出之間的關係；Nearing 等人^[96]就利用了高斯過程回歸來近似 BAM，建構深度學習模型的簡單性使得它成為了各種新想法的理想試驗方法，現在已可以將深度網路的輸出可視化，以深入瞭解網路在輸入數據上進行的轉換過程^[97]，對於圖像識別任務，我們可以反轉深度學習模型以找出導致網路做出特定決策的輸入部分^[98]；還有一些方可以將循環網路的輸出可視化，例如顯示某些神經元被運作的條件^[99]，這些可視化的成果可以說明數據驅動的模型所識別出的資料間關係。

考慮到上述的潛力，數據驅動的方法在水文學領域中應有不少表現的機會，然而也並不是所有人都可以接受此種研究方法，在傳統方法中科學家們必須在建構模型前提出假設，而數據驅動的方法中，數據挖掘和知識發現的過程是在假設形成前的步驟，也就是在數據挖掘分析前並不會有假設生成（引用）；簡單來說，在研究的提議或初始階段時，並不能擁有一個可以清楚陳述的假設存在，當然可解釋性方法做為一個新的研究方法需要發展時間，近期已經取得初步的進展^[100,101]，近期的研究以探索可微分模型作為一種途徑，以消除地球科學系統中基於過程的模型和機器學習之間的障礙，並透過水文模型的例子展示其潛力；「可微」是指準確有效地計算模型變數或參數的梯度，從而能夠發現高維度未知關係，可微分模型涉及將物理知識連接到神經網路，從而突破了基於物理性機器學習的邊界；與純粹的資料驅動機器學習相比，它提供了更好的可解釋性、泛化性和外推能力，在需要更少訓練資料的情況下展現了類似的準確性；此外可微分模型的效能和效率隨著資料量的增加而很好地擴展，在資料稀缺的情況下，由於時間空間的物理限制，可微分模式在產生短期動態趨勢方面優於機器學習模型；可微分模型方法旨在使地球科學家能夠提出問題、測試假設並發現未被識別的物理關係。

深度學習在水文領域面臨的挑戰

在水文領域有一系列獨特的挑戰，而這同時也是

深度學習的表現機會，至今為止還有許多挑戰無法通過傳統方法有效地解決，接下來將介紹深度學習方法可能會面臨的一些挑戰。

水文學領域的觀測資料通常在區域和時間上都非常不平均，例如在美國的流量觀測數量相對密集，但世界上許多其他地區的流量數據卻十分稀少，甚至有些區域根本沒有觀測，而另一種困境則是無法對資料進行存取（資料不公開），導致部分區域缺乏深度學習算法的訓練資料；很少有水文模型擁有與其他人工智慧研究（如影像識別或自然語言處理）一樣多的數據，水文變量的遙測也具有侷限性，像是衛星影像具有的雲或是樹冠的遮蓋問題，衛星的軌道路徑也會導致觀測範圍與時間的密度問題，在不同地區研究此問題的大量研究可以被概括為「沒有資料的集水區推估」^[102]；上述資料缺乏的問題即是數據驅動的研究方法面臨的一大挑戰；同時全球尺度的氣候變遷及水文變化也使得水文學家現在需要預測超出以往觀測資料範圍的變化^[103]，世界上許多地區都觀測到更為頻繁的極端現象，而此種極端情況在未來將會更加頻繁地發生^[104]，數據驅動的方法將需要證明其可以在訓練數據集的範圍外應用時可以做出合理預測的能力。

此外，對於水循環過程的觀測資料往往集中在水循環系統的某一部份，很少有完整循環的資料，例如我們可以通過多次多顆的衛星觀測估算地表水儲存的總量^[105]或地表下 5 公分的地表土壤濕度，然而將水循環各個部分的觀測結果直接結合到水循環的整體中是相當困難的；深度學習在此方面的挑戰，主要為將不同的觀測結果與它們本身的時空不連續性結合起來，以幫助模型預測和驗證，並提供對於水循環整體的完整理解。

水文數據往往會伴隨著大量強烈異質性^[106]的背景變量，例如土地利用、氣候、地質或土壤特性的聯繫，在自然系統中異質性的尺度是一個複雜的問題^[107]，如水文模型中表示土壤水分和地質的微尺度非均勻特性，非常不容易藉由方程式描述，異質性的表現尺度會隨著水循環的環境和元素而變化^[108]；另外，我們知道環境特徵中具有異質性，這些特徵如土壤性質和水文地質，在不同現象中也許並沒有表現出許多差異，但此兩個特徵在控制水運動的過程中發揮重要的作用，深度學習方法將需要在不使模型參數空間和數據需求過度膨脹的情況下，需要充分地表示研究區域之異質性。

整體來說，水文問題很難融入標準網路結構（Shen18）所設計的問題模板，即純粹的影像識別、時間

序列的預測問題又或是兩者的混和，例如集水區的水文問題同時擁有在空間上不均勻，但在時間上的呈現靜態（地形和水文地質）或是動態（氣象因子）的屬性，而傳統的神經網路模型無法有效地表示此類的輸入維度。

由於深度學習方法需要大量的數據集，因此完整蒐集、正確處理和格式化的數據集也是個重大的挑戰，數據的彙編、預處理和格式化步驟往往會占用研究人員大量的時間，有許多圖像的處理任務並不是單個研究團體能夠負擔的；與人工智慧領域或化學領域的深度學習研究群體相比，水文領域的深度學習群體還沒有得到充分的協調與合作，這將導致大量工作重複且時間浪費的議題。

而生成對抗網路（GANs）之類的深度生成模型可以用於自然紋理的隨機生成，此種方法促進了地下水文學的進展，其中有效地模擬具有統計特性的地質結構，對於地下水模型的不確定性量化至關重要；然而在未來研究的各種方向中還需要更多的工作來達成下列事項：

- (1) 生成地質層中所觀察到完整範圍的複雜性結構；
- (2) 有效地處理大型三維空間資料；
- (3) 在模擬中考慮各種類型的直接數據（例如研究區域觀察到的地質條件或屬性平均值）與間接數據（例如在反向建模過程中使用的觀測水文變量）。

結論與建議

儘管深度學習依然存在許多挑戰，但在這裡 Shen 等人^[73]提出了一個通過深度學習推進水文科學的領域路線圖（圖3），圖3主要說明通過收集和彙編已有數據，結合新的數據源例如科學家們所收集的數據、遙測和模型數據集，深度學習可以用於預測現在難以觀察的數據，並且強調基於過程的模型和深度學習模型之間的建模競

賽，將建立一個重要的共享計算和分析的方式，與分享數據源一同支持廣泛的水文應用，並嘗試使用迭代方法從經過訓練的深度學習模型提取知識（橘色箭頭），而這些活動將加強水文領域中的學習教育計劃（紫色箭頭），這些模型比賽可能又會反饋回到教育活動之中。

正如在其它科學領域中的工作一樣，一個協調良好的領域在解決問題方面將會更有效率，像是 Montanari 等人^[109]所指出的：(1) 未來的科學必須建立在跨學科方法的基礎上；(2) 水文領域在未來十年的研究挑戰應該通過群體努力來解決；我們可以看到在這個路線圖中有幾個步驟是至關重要的：物理知識、基於過程的模型（Process-Based Model, PBM）和深度學習；使用深度學習來預測未知變量；公開透明的模式建置比賽；基礎模型和可視化元件；以及在各個階段引入數據驅動方法的教育計劃。

本文認為水文科學家應該考慮一種新的研究途徑與傳統的研究方法互補，其中深度學習驅動的數據挖掘可以用來產生假設、預測和見解，儘管黑盒的特性可能使人對其持保留意見，但最近在可解釋性方法和理解深度學習網路方面也取得了一些進展；水文領域中機器學習的黑盒特性或許是這個新興領域發展的困境，然而若因為這樣就拒絕此研究途徑，反而可能會危及其他透明演算法的發展，水文或其他領域的發展都表現出深度學習這項工具具有很大的發展性；唯數據的限制和模型的可變性等挑戰還是需要領域內研究者們一同努力；此外，本文也認為應建立開放式的水文模型競賽，並強調其模型表現和解釋性的能力，此種競賽將會非常有價值，包含演算法開發、模型評估和比較、可重複性測試、數據集彙編、資源共享和社群組織等領域內不同的面向都將匯聚到一起，並促進整個領域的成長。




圖3 深度學習驅動水文領域的發展圖（來源：Shen et al.^[73]）

參考文獻

- Tibshirani, R. (1994). Regression Shrinkage and Selection Via the Lasso, *J. R. Stat. Soc. Ser. B*, **58**, 267-288.
- Drucker, H., Burges, C.J.C., Kaufman, L., Smola, A., and Vapnik, V. (1996). Support vector regression machines, *Proc. 9th Int. Conf. Neural Inf. Process. Syst.*, 155-161, available at: <https://dl.acm.org/citation.cfm?id=2999003> (last access: 5 January 2018).
- Koza, J.R. (1992). Genetic Programming: on the Programming of Computers by Means of Natural Selection, MIT Press, Cambridge, MA, USA.
- Chang, L.-C., Shen, H.-Y., and Chang, F.-J. (2014). Regional flood inundation nowcast using hybrid SOM and dynamic neural networks, *J. Hydrol.*, **519**, 476-489, <https://doi.org/10.1016/J.JHYDROL.2014.07.036>.
- Chen, I.-T., Chang, L.-C., and Chang, F.-J. (2018). Exploring the spatiotemporal interrelation between groundwater and surface water by using the self-organizing maps, *J. Hydrol.*, **556**, 131-142, <https://doi.org/10.1016/J.JHYDROL.2017.10.015>.
- Hsu, Kuo-lin, Hoshin Vijai Gupta, and Soroosh Sorooshian. (1995). "Artificial neural network modeling of the rainfall-runoff process." *Water resources research*, **31**(10), 2517-2530.
- Hsu, Kou-lin, et al. (1997). "Precipitation estimation from remotely sensed information using artificial neural networks." *Journal of Applied Meteorology and Climatology*, **36**(9), 1176-1190.
- Hsu, Kuo-lin, et al. (2002). "Self-organizing linear output map (SOLO): An artificial neural network suitable for hydrologic modeling and analysis." *Water Resources Research*, **38**(12), 38-1.
- Ho, T.K. (1995). Random decision forests, in Proceedings of 3rd International Conference on Document Analysis and Recognition, *IEEE Comput. Soc. Press*, **1**, 278-282.
- Snelson, E. and Ghahramani, Z. (2006). Sparse Gaussian Processes using Pseudo-inputs, *Adv. Neural Inf. Process. Syst.*, **18**, 1257-1264.
- Moradkhani, H., Hsu, K., Gupta, H.V., and Sorooshian, S. (2004). Improved streamflow forecasting using self-organizing radial basis function artificial neural networks, *J. Hydrol.*, **295**, 246-262, <https://doi.org/10.1016/J.JHYDROL.2004.03.027>.
- Govindaraju, R.S. (2000). Artificial Neural Networks in Hydrology. II: Hydrologic Applications, *J. Hydrol. Eng.*, **5**, 124-137, [https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:2\(124\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:2(124)).
- Maier, Holger R., et al. (2010). "Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions." *Environmental modelling & software*, **25**(8), 891-909.
- Goodman, B. and Flaxman, S. (2016). European Union regulations on algorithmic decision-making and a "right to explanation." *arXiv:1606.08813*, available at: <http://arxiv.org/abs/1606.08813> (last access: 7 February 2018).
- Shen, C. (2018). A trans-disciplinary review of deep learning research and its relevance for water resources scientists, *Water Resour. Res.*, <https://doi.org/10.1029/2018WR022643>.
- Voosen, P. (2017). The AI detectives, *Science*, **80**, 357, <https://doi.org/10.1126/science.357.6346.22>.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview, *Neural Networks*, **61**, 85-117, <https://doi.org/10.1016/j.neunet.2014.09.003>.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., and Lew, M.S. (2016). Deep learning for visual understanding: A review, *Neurocomputing*, **187**, 27-48, <https://doi.org/10.1016/J.NEUCOM.2015.09.116>.
- He, Kaiming, et al. (2016). "Deep residual learning for image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Simonyan, Karen, and Andrew Zisserman. (2014). "Two-stream convolutional networks for action recognition in videos." *Advances in neural information processing systems*, **27**.
- Zhu, X.X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., and Fraundorfer, F. (2017). Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources, *IEEE Geosci. Remote Sens. Mag.*, **5**, 8-36, <https://doi.org/10.1109/MGRS.2017.2762307>.
- Baughman, Aaron K., et al. (2013). "Deepqa jeopardy! gamification: a machine-learning perspective." *IEEE transactions on computational intelligence and AI in games*, **6**(1), 55-66.
- Hirschberg, Julia, and Christopher D. Manning. (2015). "Advances in natural language processing." *Science*, **349**.6245 (2015), 261-266, <https://doi.org/10.1126/science.aaa8685>.
- Vondrick, C., Pirsiaavash, H., and Torralba, A. (2016). Anticipating Visual Representations from Unlabeled Video, CVPR 2016, available at: <http://arxiv.org/abs/1504.08023> (last access: 20 August 2018).
- Gatys, L.A., Ecker, A.S., and Bethge, M. (2016). Image Style Transfer Using Convolutional Neural Networks, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2414-2423.
- Leviathan, Y. and Matias, Y. (2018). Google Duplex: An AI System for Accomplishing Real-World Tasks Over the Phone, Google AI Blog, available at: <https://ai.googleblog.com/2018/05/duplex-ai-system-for-natural-conversation.html>, last access: 20 August 2018.
- Zen, Heiga, and Haşim Sak. (2015). "Unidirectional long short-term memory recurrent neural network with recurrent output layer for low-latency speech synthesis." *2015 IEEE International Conference*.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning, *Nature*, **521**, 436-444, <https://doi.org/10.1038/nature14539>.
- Fang, K., Shen, C., Kifer, D., and Yang, X. (2017). Prolongation of SMAP to Spatio-temporally Seamless Coverage of Continental US Using a Deep Learning Neural Network, *Geophys. Res. Lett.*, **44**, 11030-11039, <https://doi.org/10.1002/2017GL075619>.
- Laloy, Eric, et al. (2017). "Inversion using a new low-dimensional representation of complex binary geological media based on a deep neural network." *Advances in water resources*, **110**, 387-405.
- Laloy, E., Hérault, R., Jacques, D., and Linde, N. (2018). Training-Image Based Geostatistical Inversion Using a Spatial Generative Adversarial Neural Network, *Water Resour. Res.*, **54**, 381-406, <https://doi.org/10.1002/2017WR022148>.
- Tao, Yumeng, et al. (2016). "A deep neural network modeling framework to reduce bias in satellite precipitation products." *Journal of Hydrometeorology*, **17**(3), 931-945.
- Vandal, Thomas, et al. (2017). "DeepSD: Generating high resolution climate change projections through single image super-resolution." *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining*.
- Zhang, D., Lindholm, G., and Ratnaweera, H. (2018). Use long short-term memory to enhance Internet of Things for combined sewer overflow monitoring, *J. Hydrol.*, **556**, 409-418, <https://doi.org/10.1016/J.JHYDROL.2017.11.018>.
- Srinivasan, M. (2013). Hydrology from space: NASA's satellites supporting water resources applications, Water Forum III Droughts Other Extrem. Weather Events, available at: http://www.jsrg.utexas.edu/ciess/files/Srinivasanetl_TWF_Oct14_Final.pdf (last access: 12 July 2016).
- Entekhabi, D. (2010). The Soil Moisture Active Passive (SMAP) mission, *Proc. IEEE*, **98**, 704-716, <https://doi.org/10.1109/JPROC.2010.2043918>.
- Jackson, T., O'Neill, P., Njoku, E., Chan, S., Bindlish, R., Colliander, A., Chen, F., Burgin, M., Dunbar, S., Piepmeier, J., Cosh, M., Caldwell, T., Walker, J., Wu, X., Berg, A., Rowlandson, T., Pacheco, A., McNairn, H., Thibault, M., Martínez-Fernández, J., González-Zamora, Á., Seyfried10, M., Bosch, D., Starks, P., Goodrich, D., Prueger, J., Su, Z., van der Velde, R., Asanuma, J., Palecki, M., Small, E., Zreda, M., Calvet, J., Crow, W., Kerr, Y., Yueh, S., and Entekhabi, D. (2016). Soil Moisture Active Passive (SMAP) Project Calibration and Validation for the L2/3_SM_P Version 3 Data Products, SMAP Proj. JPL D-93720, available at: <https://nsidc.org/data/smap/technical-references> (last access: 27 July 2017).
- Mecklenburg, Susanne, et al. (2008). "The soil moisture and ocean salinity mission-An overview." *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*. Vol. 4. IEEE, 2008. <https://doi.org/10.1109/IGARSS.2008.4779878>.
- Knyazikhin, Y., Glassy, J., Privette, J.L., Tian, Y., Lotsch, A., Zhang, Y., Wang, Y., Morisette, J.T., P.Votava, Myneni, R.B., Nemani, R.R., and Running, S.W. (1999). MODIS Leaf Area Index (LAI) and Fraction of Photosynthetically Active Radiation Absorbed by Vegetation (FPAR) Product (MOD15) Algorithm Theoretical Basis Document, https://modis.gsfc.nasa.gov/data/atbd/atbd_mod15.pdf (last access: 8 October 2018).
- Mu, Q., Zhao, M., and Running, S.W. (2011). Improvements to a MODIS global terrestrial evapotranspiration algorithm, *Remote Sens. Environ.*, **115**, 1781-1800, <https://doi.org/10.1016/j.rse.2011.02.019>.

41. Wahr, J., Swenson, S., and Velicogna, I. (2006), Accuracy of GRACE mass estimates, *Geophys. Res. Lett.*, **33**, L06401, <https://doi.org/10.1029/2005GL025305>.
42. Hall, D.K., Riggs, G.A., and Salomonson, V.V. (2006). MODIS/Terra Snow Cover 5-Min L2 Swath 500 m, Version 5, Boulder, Colorado USA.
43. Pavelsky, T.M., Durand, M.T., Andreadis, K.M., Beighley, R.E., Paiva, R.C.D., Allen, G.H., and Miller, Z.F. (2014). Assessing the potential global extent of SWOT river discharge observations, *J. Hydrol.*, **519**, 1516-1525, <https://doi.org/10.1016/j.jhydrol.2014.08.044>.
44. Gleeson, T., Moosdorf, N., Hartmann, J., and van Beek, L.P.H. (2014). A glimpse beneath earth's surface: GLobal HYdrogeology MaPS (GLHYMPS) of permeability and porosity, *Geophys. Res. Lett.*, **41**, 3891-3898, <https://doi.org/10.1002/2014GL059856>.
45. GRDC (2017). River Discharge Data, Glob. Runoff Data Cent., available at: http://www.bafg.de/GRDC/EN/02_srvcs/21_tmsrs/riverdischarge_node.html, last access: 28 July 2017.
46. CUAHSI: HydroClient, available at: <https://data.cuahsi.org/>, last access: 19 August 2018c.
47. Horsburgh, J.S., Morsy, M.M., Castronova, A.M., Goodall, J.L., Gan, T., Yi, H., Stealey, M.J., and Tarboton, D.G. (2016). HydroShare: Sharing Diverse Environmental Data Types and Models as Social Objects with Application to the Hydrology Domain, *J. Am. Water Resour. As.*, **52**, 873-889, <https://doi.org/10.1111/1752-1688.12363>.
48. Aspen (2017). Internet of Water: Sharing and Integrating Water Data for Sustainability, A Rep. from Aspen Inst. Dialogue Ser. Water Data, available at: <https://www.aspeninstitute.org/publications/internet-of-water/> (last access: 27 August 2018).
49. McCabe, M.F., Rodell, M., Alsdorf, D.E., Miralles, D.G., Uijlenhoet, R., Wagner, W., Lucier, A., Houborg, R., Verhoest, N.E.C., Franz, T.E., Shi, J., Gao, H., and Wood, E.F. (2017). The future of Earth observation in hydrology, *Hydrol. Earth Syst. Sci.*, **21**, 3879-3914, <https://doi.org/10.5194/hess-21-3879-2017>.
50. Allamano, P., Croci, A., and Laio, F. (2015). Toward the camera rain gauge, *Water Resour. Res.*, **51**, 1744-1757, <https://doi.org/10.1002/2014WR016298>.
51. Hiroi, K. and Kawaguchi, N. (2016). FloodEye: Real-time flash flood prediction system for urban complex water flow, 2016 IEEE SENSORS, 1-3.
52. Evans, H., Gervet, E., Kuchembuck, R., and Hu, M. (2018). Will You Embrace AI Fast Enough? ATKearney Operations & Performance Transformation report, available at: <https://www.atkearney.com/operations-performance-transformation/article/a/will-you-embrace-ai-fast-enough>, last access 10 August 2018.
53. Dignan, L. (2018). Google Research becomes Google AI to reflect AI-first ambitions, *zdnet.com*, available at: <https://www.zdnet.com/article/google-research-becomes-google-ai-to-reflect-ai-first-ambitions/>, last access: 20 August 2018.
54. Columbus, L. (2018). Roundup of Machine Learning Forecasts and Market Estimates, 2018, *Forbes Contrib.*, available at: <https://www.forbes.com/sites/louiscolombus/2018/02/18/roundup-of-machine-learning-forecasts-and-market-estimates-2018/#7d3c5bd62225>, last access: 30 July 2018.
55. Baldi, P., Sadowski, P., and Whiteson, D. (2015). Enhanced Higgs Boson to $\tau^+\tau^-$ Search with Deep Learning, *Phys. Rev. Lett.*, **114**, 111801, <https://doi.org/10.1103/PhysRevLett.114.111801>.
56. Angermueller, C., Pärnamaa, T., Parts, L., and Stegle, O. (2016). Deep learning for computational biology, *Mol. Syst. Biol.*, **12**, 878, <https://doi.org/10.15252/MSB.20156651>.
57. Goh, G.B., Hodas, N.O., and Vishnu, A. (2017). Deep learning for computational chemistry, *J. Comput. Chem.*, **38**, 1291-1307, <https://doi.org/10.1002/jcc.24764>.
58. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., and Fei-Fei, L. (2014). ImageNet Large Scale Visual Recognition Challenge, arXiv: 1409.0575, available at: <http://arxiv.org/abs/1409.0575> (last access: 24 March 2018).
59. Krizhevsky, A., Sutskever, I., and Hinton, G.E. (2012). ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, **25**, 1097-1105, available at: <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural> (last access: 30 March 2018).
60. Stallkamp, J., Schlipsing, M., Salmen, J., and Igel, C. (2011). The German Traffic Sign Recognition Benchmark: A multi-class classification competition, *The 2011 International Joint Conference on Neural Networks*, 1453-1460.
61. Yu, K.-H., Zhang, C., Berry, G.J., Altman, R.B., Ré, C., Rubin, D.L., and Snyder, M. (2016). Predicting non-small cell lung cancer prognosis by fully automated microscopic pathology image features, *Nat. Commun.*, **7**, 12474, <https://doi.org/10.1038/ncomms12474>.
62. Indermuhle, E., Frinken, V., and Bunke, H. (2012). Mode Detection in Online Handwritten Documents Using BLSTM Neural Net works, *2012 International Conference on Frontiers in Handwriting Recognition*, 302-307, IEEE 2012.
63. Xiong, W., Droppo, J., Huang, X., Seide, F., Seltzer, M., Stolcke, A., Yu, D., and Zweig, G. (2016). Achieving Human Parity in Conversational Speech Recognition, Microsoft Res. Tech. Rep. MSR TR-2016-71. arXiv1610.05256, available at: <http://arxiv.org/abs/1610.05256> (last access: 24 March 2018).
64. Stollenga, M. F., Byeon, W., Liwicki, M., and Schmidhuber, J. (2015). Parallel multi-dimensional LSTM, with application to fast biomedical volumetric image segmentation, *Proc. 28th Int. Conf. Neural Inf. Process. Syst.*, **2**, 2998-3006.
65. CIF (2016). Results, Int. Time Ser. Forecast. Compet.-Comput. Intell. Forecast., available at: <http://irafr.osu.cz/cif/main.php?c=Static&page=results> (last access: 24 March 2018).
66. Tao, Y., Gao, X., Ihler, A., Sorooshian, S., Hsu, K., Tao, Y., Gao, X., Ihler, A., Sorooshian, S., and Hsu, K. (2017). Precipitation Identification with Bispectral Satellite Information Using Deep Learning Approaches, *J. Hydrometeorol.*, **18**, 1271-1283, <https://doi.org/10.1175/JHM-D-16-0176.1>.
67. Tao, Y., Hsu, K., Ihler, A., Gao, X., Sorooshian, S., Tao, Y., Hsu, K., Ihler, A., Gao, X., and Sorooshian, S. (2018). A Two-Stage Deep Neural Network Framework for Precipitation Estimation from Bispectral Satellite Information, *J. Hydrometeorol.*, **19**, 393-408, <https://doi.org/10.1175/JHM-D-17-0077.1>.
68. Laloy, Eric, et al. (2018). "Training-image based geostatistical inversion using a spatial generative adversarial neural network." *Water Resources Research*, **54**(1), 381-406.
69. Kratzert, F., Klotz, D., Brenner, C., Schulz, K., and Herrnegger, M. (2018). Rainfall-Runoff modelling using Long-Short-Term Memory (LSTM) networks, *Hydrol. Earth Syst. Sci. Discuss.*, <https://doi.org/10.5194/hess-2018-247>, in review.
70. Liu, Y., Racah, E., Prabhat, Correa, J., Khosrowshahi, A., Lavers, D., Kunkel, K., Wehner, M., and Collins, W. (2016). Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets, ACM SIGKDD 2016 Conference on Knowledge Discovery & Data Mining, available at: <http://arxiv.org/abs/1605.01156>, last access: 21 October 2016.
71. Matsuoka, D., Nakano, M., Sugiyama, D., and Uchida, S. (2017). Detecting Precursors of Tropical Cyclone using Deep Neural Net works, The 7th International Workshop on Climate Informatics, CI, 2017.
72. Gentine, P., Pritchard, M., Rasp, S., Reinaudi, G., and Yacalis, G. (2018). Could Machine Learning Break the Convection Parameterization Deadlock? *Geophys. Res. Lett.*, **45**, 5742-5751, <https://doi.org/10.1029/2018GL078202>.
73. Shen, Chaopeng, et al. (2018). "HESS Opinions: Incubating deep-learning-powered hydrologic science advances as a community." *Hydrology and Earth System Sciences*, **22**(11), 5639-5656.
74. Yosinski, J., Clune, J., Nguyen, A., Fuchs, T., and Lipson, H. (2015). Understanding Neural Networks Through Deep Visualization, in Deep Learning Workshop, 31st International Conference on Machine Learning, Lille, France, available at: <http://arxiv.org/abs/1506.06579> (last access: 19 November 2017).
75. Karpathy, A., Johnson, J., and Fei-Fei, L. (2015). Visualizing and Understanding Recurrent Networks, ICLR 2016 Workshop, available at: <http://arxiv.org/abs/1506.02078> (last access: 7 November 2016).
76. Banino, A., Barry, C., Uria, B., Blundell, C., Lillicrap, T., Mirowski, P., Pritzel, A., Chadwick, M.J., Degris, T., Modayil, J., Wayne, G., Soyer, H., Viola, F., Zhang, B., Goroshin, R., Rabinowitz, N., Pascanu, R., Beattie, C., Petersen, S., Sadik, A., Gaffney, S., King, H., Kavukcuoglu, K., Hassabis, D., Hadsell, R., and Kumaran, D. (2018). Vector-based navigation using gridlike representations in artificial agents, *Nature*, **557**, 429-433, <https://doi.org/10.1038/s41586-018-0102-6>.
77. Kawaguchi, K., Kaelbling, L.P., and Bengio, Y. (2017). Generalization

- in Deep Learning, arXiv:1710.05468, available at: <http://arxiv.org/abs/1710.05468> (last access: 12 March 2018).
78. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *J. Mach. Learn. Res.*, **15**, 1929-1958.
 79. Hochreiter, S. (1998). The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions, *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, **6**, 107-116, <https://doi.org/10.1142/S0218488598000094>.
 80. Ranzato, M., Poultney, C., Chopra, S., and LeCun, Y. (2016). Efficient learning of sparse representations with an energy-based model, *Proc. 19th Int. Conf. Neural Inf. Process. Syst.*, 1137-1144, available at: <https://dl.acm.org/citation.cfm?id=2976599> (last access: 30 March 2018).
 81. Greff, K., Srivastava, R.K., Koutník, J., Steunebrink, B.R., and Schmidhuber, J. (2015). LSTM: A Search Space Odyssey, available at: <http://arxiv.org/abs/1503.04069> (last access: 18 July 2016).
 82. Hochreiter, S. and Schmidhuber, J. (1997). Long Short Term Memory, *Neural Comput.*, **9**, 1735-1780, <https://doi.org/10.1162/neco.1997.9.8.1735>.
 83. Kingma, D.P. and Welling, M. (2013). Auto-Encoding Variational Bayes, in Proceedings of the 2014 International Conference on Learning Representations (ICLR), available at: <http://arxiv.org/abs/1312.6114> (last access: 24 March 2018).
 84. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., WardeFarley, D., Ozair, S., Courville, A., and Bengio, Y. (2014). Generative Adversarial Networks, in Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS'14), available at: <http://arxiv.org/abs/1406.2661> (last access: 25 February 2017).
 85. Albert, A., Strano, E., Kaur, J., and Gonzalez, M. (2018). Modeling urbanization patterns with generative adversarial networks, arXiv:1801.02710, available at: <http://arxiv.org/abs/1801.02710>, last access: 24 March.
 86. Arpit, D., Jastrzebski, S., Ballas, N., Krueger, D., Bengio, E., Kanwal, M.S., Maharaj, T., Fischer, A., Courville, A., Bengio, Y., and Lacoste-Julien, S. (2017). A Closer Look at Memorization in Deep Networks, in Proceedings of the 34th International Conference on Machine Learning, Sydney, Australia, PMLR 70, available at: <https://arxiv.org/abs/1706.05394>.
 87. Krueger, D., Ballas, N., Jastrzebski, S., Arpit, D., Kanwal, M. S., Maharaj, T., Bengio, E., Erraqui, A., Fischer, A., Lacoste-Julien, S., and Courville, A. (2017). Deep nets don't learn via memorization, ICLR 2017, available at: <https://openreview.net/pdf?id=rJv6ZgHYg>.
 88. Goodfellow, I., Shlens, J., and Szegedy, C. (2015). Explaining and Harnessing Adversarial Examples, International Conference on Learning Representations, available at: <http://arxiv.org/abs/1412.6572> (last access: 25 February 2017).
 89. Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., and Fergus, R. (2013). Intriguing properties of neural networks, available at: <http://arxiv.org/abs/1312.6199> (last access: 8 June 2016).
 90. Ororbia, A.G., Giles, C.L., and Kifer, D. (2016). Unifying Adversarial Training Algorithms with Flexible Deep Data Gradient Regularization, Neural Computation, MIT Press, available at: <http://arxiv.org/abs/1601.07213> (last access: 24 February 2017).
 91. Kumar, D. and Menkovski, V. (2016). Understanding Anatomy Classification Through Visualization, 30th NIPS Machine learning for Health Workshop, available at: <https://arxiv.org/abs/1611.06284> (last access: 24 November 2017).
 92. Hendricks, L. A., Akata, Z., Rohrbach, M., Donahue, J., Schiele, B., and Darrell, T. (2016). Generating Visual Explanations, in: Computer Vision – ECCV 2016, 3-19, available at: https://doi.org/10.1007/978-3-319-46493-0_1, Springer, Cham, Amsterdam, The Netherlands, 2016.
 93. Mount, N.J., Maier, H.R., Toth, E., Elshorbagy, A., Solomatine, D., Chang, F.-J., and Abrahart, R.J. (2016). Data-driven modelling approaches for socio-hydrology: opportunities and challenges within the Panta Rhei Science Plan, *Hydrol. Sci. J.*, **61**, 1-17, <https://doi.org/10.1080/02626667.2016.1159683>.
 94. Fang, K. and Shen, C. (2017). Full-flow-regime storage-streamflow correlation patterns provide insights into hydrologic functioning over the continental US, *Water Resour. Res.*, **53**, 8064-8083, <https://doi.org/10.1002/2016WR020283>.
 95. Tsai, Wen-Ping, et al. (2020). "Revealing causal controls of storage-streamflow relationships with a data-centric Bayesian framework combining machine learning and process-based modeling." *Frontiers in Water* 2 (2020), 583000.
 96. Nearing, G.S., Mocko, D.M., Peters-Lidard, C.D., Kumar, S.V., and Xia, Y. (2016). Benchmarking NLDAS-2 Soil Moisture and Evapo transpiration to Separate Uncertainty Contributions, *J. Hydrometeorol.*, **17**, 745-759, <https://doi.org/10.1175/JHM-D-15-0063.1>.
 97. Samek, W., Binder, A., Montavon, G., Lapuschkin, S., and Muller, K.-R. (2017). Evaluating the Visualization of What a Deep Neural Network Has Learned, *IEEE Trans. Neural Networks Learn. Syst.*, **28**, 2660-2673, <https://doi.org/10.1109/TNNLS.2016.2599820>.
 98. Mahendran, A. and Vedaldi, A. (2015). Understanding deep image representations by inverting them, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 5188-5196.
 99. Karpathy, A., Johnson, J., and Fei-Fei, L. (2015). Visualizing and Understanding Recurrent Networks, ICLR 2016 Workshop, available at: <http://arxiv.org/abs/1506.02078> (last access: 7 November 2016).
 100. Tsai, Wen-Ping, et al. (2021). "From calibration to parameter learning: Harnessing the scaling effects of big data in geoscientific modeling." *Nature communications*, **12**(1), 5988.
 101. Shen, C., Apppling, A.P., Gentile, P. et al. (2023). Differentiable modelling to unify machine learning and physical models for geosciences. *Nat Rev Earth Environ.*, **4**, 552-567 (2023). <https://doi.org/10.1038/s43017-023-00450-9>.
 102. Hrachowitz, M., Savenije, H.H.G., Blöschl, G., McDonnell, J.J., Sivapalan, M., Pomeroy, J.W., Arheimer, B., Blume, T., Clark, M.P., Ehret, U., Fenicia, F., Freer, J.E., Gelfan, A., Gupta, H.V., Hughes, D.A., Hut, R.W., Montanari, A., Pande, S., Tetzlaff, D., Troch, P.A., Uhlenbrook, S., Wagener, T., Winsemius, H.C., Woods, R.A., Zehe, E., and Cudennec, C. (2013). A decade of Predictions in Ungauged Basins (PUB)—A review, *Hydrol. Sci. J.*, **58**, 1198-1255, <https://doi.org/10.1080/02626667.2013.803183>.
 103. Wagener, T., Sivapalan, M., Troch, P.A., McGlynn, B.L., Harman, C.J., Gupta, H.V., Kumar, P., Rao, P.S.C., Basu, N.B., and Wilson, J.S. (2010). The future of hydrology: An evolving science for a changing world, *Water Resour. Res.*, **46**, 1-10, <https://doi.org/10.1029/2009WR008906>.
 104. Stocker, T.F., Qin, D., Plattner, G.-K., Alexander, L.V., Allen, S.K., Bindoff, N.L., Bréon, F.-M., Church, J.A., Cubasch, U., Emori, S., Forster, P., Friedlingstein, P., Gillett, N., Gregory, J.M., Hartmann, D.L., Jansen, E., Kirtman, B., Knutti, R., Kumar, K.K., Lemke, P., Marotzke, J., Masson-Delmotte, V., Meehl, G.A., Mokhov, I. I., Piao, S., Ramaswamy, V., Ran dall, D., Rhein, M., Rojas, M., Sabine, C., Shindell, D., Talley, L.D., Vaughan, D.G., and Xie, S.-P. (2013). Technical summary, Climate Change 2013, in: The Physical Science Basis, edited by: Stocker, T.F., Qin, D., Plattner, G.-K., Tignor, M., Allen, S.K., Boschung, J., Nauels, A., Xia, Y., Bex, V., and Midgley, P.M. Contrib. Work. Gr. I to Fifth Assess. Rep. Intergov. Panel Clim. Chang., available at: http://www.ipcc.ch/pdf/assessment-report/ar5/wg1/WG1AR5_TS_FINAL.pdf (last access: 8 October 2018).
 105. Wahr, First J. (2004). Time-variable results, Geophys. gravity Res. Lett., from GRACE: 31, L11501, <https://doi.org/10.1029/2004GL019779>.
 106. Blöschl, G. (2006). Hydrologic synthesis: Across processes, places, and scales, *Water Resour. Res.*, **42**, W03S02, <https://doi.org/10.1029/2005WR004319>.
 107. Archfield, S.A., Clark, M., Arheimer, B., Hay, L.E., McMillan, H., Kiang, J.E., Seibert, J., Hakala, K., Bock, A., Wagener, T., Farmer, W.H., Andréassian, V., Attinger, S., Viglione, A., Knight, R., Markstrom, S., and Over, T. (2015). Accelerating advances in continental domain hydrologic modeling, *Water Resour. Res.*, **51**, 10078-10091, <https://doi.org/10.1002/2015WR017498>.
 108. Ajami, H., Khan, U., Tuteja, N.K., and Sharma, A. (2016). Development of a computationally efficient semi-distributed hydrologic modeling application for soil moisture, lateral flow and runoff simulation, *Environ. Model. Softw.*, **85**, 319-331, <https://doi.org/10.1016/J.ENVSOFT.2016.09.002>.
 109. Montanari, Alberto, et al. (2013). "Panta Rhei—everything flows": change in hydrology and society—the IAHS scientific decade 2013-2022." *Hydrological Sciences Journal*, **58**(6), 1256-1275.



氣候變遷資料偏差校正及水文頻率分析之探討

蘇元風* / 國立臺灣海洋大學河海工程學系 助理教授

劉俊志 / 國家災害防救科技中心 博士

陳韻如 / 國家災害防救科技中心 博士

氣候變遷相關研究主要使用的動力降尺度資料與統計降尺度資料，都是基於數理與電腦工具模擬大氣與海洋的交互作用而產生降雨資料，然而這些大氣環流模式仍存在多種不確定性，例如：模式不確定性、資料不確定性、參數不確定性等等，因此氣候變遷資料是否能反映觀測資料的降雨特性，一直是水文學家在應用氣候變遷資料時非常想了解的問題。此時，氣候變遷資料的偏差校正（bias correction）便顯得相當重要，偏差校正的概念主要是透過統計方法，使氣候變遷資料與觀測資料具有相似的統計參數，例如：平均值、標準偏差、偏態係數等。過去已有許多研究使用經驗累積機率密度函數（Empirical Cumulative Density Function, ECDF）對應法，且得到不錯的成果。ECDF 對應法與水文頻率分析中的降雨量重現期的評估方式有其共通之處，本文將兩者一併探討其異同之處。

前言

近年來全球各地極端水文事件，例如：豪雨、乾旱等頻繁地發生，民眾普遍已認同氣候變遷正在發生當中，全球許多優秀的科學家，依循著聯合國政府間氣候變遷專業委員會（Intergovernmental Panel on Climate Change，簡稱 IPCC）所定義的不同暖化情境，分析氣候變遷對於水文圈的影響。基於不同的全球暖化情境，各國科學家以大氣環流模式（General Circulation Model, GCM）分析在此氣候情境下，大氣與海洋交互作用的改變，其中降雨量即為主要的觀測量之一。然而，由於大氣環流模式仍存在多種不確定性，例如：物理與數學機制是否能完整描述大氣與海洋交互作用－模式不確定性、觀測資料本身的誤差－資料不確定性、模式中需要的參數誤差－參數不確定性。有鑑於此，可以想見 GCM 的產出勢必包含著一定程度的誤差。

為了使用氣候變遷資料於水文相關研究上，已有許多研究提出偏差校正（Bias Correction, BC）的方法，將前述的 GCM 誤差進行校正，使得 GCM 資料更接近地面觀測資料的特性^[1-4]。蘇等人^[5]與 Su *et al.*^[6]使用經驗累積機率密度函數（Empirical Cumulative Density Function, ECDF）對應法，校正動力降尺度之颱風降雨量，且得到不錯的成果。當使用 ECDF 對應法時，事實上與水文上探討降雨量重現期的方式有其共通之處，本文將兩者一併探討其異同之處。

偏差校正－ECDF 對應法

以經驗累積機率密度函數（ECDF）對應法進行偏差校正時，其主要概念如下圖所示。圖 1 中可以看出氣象站觀測資料與統計降尺度之氣候變遷資料可以具有不同的樣本數，而兩者的 ECDF 也截然不同，而 ECDF 對應法的偏差校正做法，重點在於將氣候變遷資料（ X_p ）乘上一個比例（ratio, R ），使其接近觀測資料（ X_o ），而 R 的數值應隨著不同的 X_p 而異，換句話說，

* 通訊作者，yuanfongsu@mail.ntou.edu.tw

不同的 X_p 應找到其對應之 ECDF 值，再由 ECDF 值找到此 ECDF 所對應之觀測資料 X_o ，式 (1)。由圖 2 為偏差校正之示意圖，可發現經過 ECDF 對應法進行偏差校正後，兩組資料之 ECDF 將幾乎相同。

$$R = \frac{X_o}{X_p} \quad (1)$$

此方法已成功應用於動力降尺度資料，蘇等人^[5]使用 ECDF 對應法校正日本氣象廳氣象研究所與國科會臺灣氣候變遷推估資訊與調適知識平台計畫 (TCCIP) 產製之 Weather Research and Forecasting modeling system - Meteorological Research Institute (WRF-MRI) 動力降尺度資料，更多詳細之動力降尺度資料產製過程與內容請見「臺灣氣候變遷推估與資訊平台建置計畫 (1/3) 年度成果報告書」^[7]。在 WRF-MRI 動力降尺度資料中，包含多場模擬之颱風降雨事件，資料之時間尺度為時雨量，而經由 WRF-MRI 產製的資料中，對照測站觀測資料發現有低估降雨量的情形，因此透過 ECDF 對應法，找出 WRF-MRI 之校正因子 (R)，由圖 3 可發現校正因子

皆大於 1，故可減少前述低估降雨量的問題。經過偏差校正之後的 WRF-MRI 資料則更接近測站觀測資料，由圖 4 可看出校正後的數據較接近 1:1 等值線。校正結果從空間上看，可發現校正後的結果明顯大於校正前，整體數值分布較接近觀測的結果，而在空間分布特徵上 (圖 5)，可以發現偏差校正僅針對降雨量的數值進行校正，空間分布特性仍維持著 WRF-MRI 原始產製資料之空間分布特徵，由此可見，ECDF 對應法能保持原始資料產製之空間特性，調整數值使其統計特性與觀測值之統計特性相似，若要進一步改善空間分布特性，應從 WRF-MRI 的模式或是參數調整為出發點進行之。

水文頻率分析與 ECDF 對應法

水文頻率分析 (Frequency analysis, FA) 為常見的分析方式，是採用測站的時雨量資料，換算為連續 24 小時累積雨量，計算各年之最大連續 24 小時累積雨量，若有 N 年的紀錄，即有 N 筆年最大值序列，透過統計方法找出理論機率分布 (Theoretical




圖 1 ECDF 對應法於偏差校正之示意圖：(a) 氣象站觀測雨量；(b) 統計降尺度資料







圖 2 偏差校正示意圖：(a) 校正前兩組資料之 ECDF；(b) 校正後之 ECDF 分布圖應接近一致

圖 3 WRF-MRI 之校正因子^[5]圖 4 颱風事件總雨量經偏差校正前後之比較^[5]圖 5 觀測資料與偏差校正前後之總雨量分布圖^[5]

Distribution)。FA 與前述 ECDF 對應法都是以 ECDF 為分析的基礎，然而不同之處在於 FA 在 ECDF 上推估資料的理論機率分布，並以理論機率分布換算某水文量之超越機率 $P(x \geq x_T)$ 以及對應之重現期 (T)，如圖 6 及式 (2) 所示。

$$P(x \geq x_T) = \frac{1}{T} \quad (2)$$

當使用 TCCIP 的 AR6 統計降尺度氣候變遷資料於水文頻率分析時，同樣將需要面臨偏差校正的問題，然而使用 ECDF 對應法的概念，將可能同時完成偏差校正與頻率分析。舉例而言，若想分析氣候變遷下




圖 6 水文頻率分析示意圖

之日降雨在基期、近未來與世紀末，其重現期是否有明顯的改變？欲回答此問題，根據前面偏差校正的概念，一般作法是先將氣候變遷下的日雨量資料進行偏差校正，使其具備觀測資料之統計特性，由觀測資料與氣候變遷基期的資料所得之校正因子，套用在近未來與世紀末的資料中，再各自進行水文頻率分析。然而，若是將問題的視角轉由超越機率的角度出發，則此問題將可表示如下圖。分析流程請見圖 7 中的橘色路徑，首先左上方傳統的水文頻率分析過程先設定某水文量 (x_T)，例如：最大連續 24 小時累積雨量大於 650 毫米，找到其超越機率，再由此超越機率向右對應至氣候變遷下基期的 CDF 上，向下方找到對應之氣候變遷基期的門檻值，此門檻值所對應的是 AR6 統計降尺度模式之年最大日雨量值，在 AR6 統計降尺度日降雨資料中，其出現之超越機率與測站最大連續 24 小時累積雨量大於 650 毫米之超越機率相同。此門檻值即可回答一個問題：在傳統以測站方式所得的水文頻率分析中，最大連續 24 小時累積雨量大於 650 毫米的重現期對應到 AR6 統計降尺度日降雨資料時應該是多少雨量值。

在氣候變遷的研究中，水文學家往往希望得知：相對於過去或是現在，未來的降雨會如何改變？欲回答此問題，可由前述之門檻值找到對應於氣候變遷未來時期的超越機率，即可比較氣候變遷情境下，對應於觀測資料超過某水文量 (x_T) 之未來時期的超越機率，相較於相同基準下的基期，超越機率的數值是否有顯著的改變，透過公式 (2) 即可換算為重現期的改變。

值得一提的是觀測資料若採用時雨量資料換算之最大連續 24 小時累積雨量，與統計降尺度之日降雨量資料找出年最大日雨量，在此視為相同基準的變數，




圖 7 氣候變遷下日雨量之超越機率評估示意圖

進行累積機率分布（CDF）的對應。目前此方法已應用於 AR5 的統計降尺度日雨量的頻率分析，詳細內容請參閱童裕翔等人 [8]。

以前述之分析流程，選用 1995 年至 2014 年共 289 個雨量站資料，建立測站最大連續 24 小時雨量與 AR6 統計降尺度歷史期間之日雨量資料年最大值序列。雨量站分布與 AR6 統計降尺度網格位置如圖 8 所示。將某網格位置上兩者的年最大值序列繪製 ECDF 圖（圖 9），可以發現由於 AR6 統計降尺度共有 31 個模式產出歷史期間之日雨量資料，可以發現這些 AR6 統計降尺度日雨量之年最大值，均小於測站之最大連續 24 小時雨量年最大值，此現象符合我們對於最大連續 24 小時雨量與日雨量之關係。一般而言，最大連續 24 小時雨量會發生在暴雨尖峰的中心時段，而此時段絕大多數的情形不會發生在單一日曆天當中，非常有可能是跨越 2 個日曆天，如圖 10 所示。

將前述偏差校正方法應用於分析 AR6 統計降尺度日雨量資料，評估未來的四種氣候變遷情境下，超越機率的改變情形。AR6 的四種情境分別是 SSP126、SSP245、SSP370 與 SSP585，四種情境分別考量不同的碳排放情境與社會經濟發展情況，依序分為樂觀至悲觀的情境，以 SSP126 為最樂觀，反之 SSP585 為最悲觀，也就是碳排放量不減反增的情況，詳細之情境描述請見臺灣氣候變遷關鍵指標圖集—AR6 統計降尺度版 [9]。其




圖 8 測站所在網格（紅色十字）與 AR6 統計降尺度資料網格（藍點）之空間分布




圖 9 測站與 AR6 統計降尺度歷史期間年最大值 ECDF 圖




圖 10 最大連續 24 小時雨量與日雨量關係示意圖

分析結果以 ACCESS-CM2 模式為例（圖 11），可以看出近未來（2021 年～2040 年）之超越機率在四種情境下差異不大，但可以明顯看出若比較近未來與世紀末，SSP585 情境下的超越機率由近未來時期普遍小於 0.1，到了世紀末，則明顯增加至 0.3～0.5 之間，特別是在山區。換句話說，在近未來時期約每 10 年發生一次的事件，在世紀末約 2～3 年便會發生一次，由此可見其危害度增加的幅度相當顯著。

結論

本文由 ECDF 對應法進行氣候變遷資料的偏差校正談起，並探討 ECDF 對應法與水文頻率分析之異同之處。ECDF 對應法與水文頻率分析都是基於 ECDF 開始的分析，然而水文頻率分析在評估超越機率與重現期時，是基於理論機率分布計算之，與 ECDF 對應採用樣本計算有所不同。當使用氣候變遷資料於水文頻率分析時，可由超越機率的角度出發，找出對應於觀測資料超過某水文量（ x_T ）之超越機率，由此超越機率以 ECDF 對應法的概念，找出氣候變遷下基期的日雨量門檻值，再換算氣候變遷近未來的超越機率，即可比較氣候變遷情境下，對應於觀測資料超過某水文量（ x_T ）之未來時期的超越機率，相較於相同基準下的基期，超越機率的數值是否有顯著的改變。由結果顯示，以 ACCESS-CM2 模式為例，比較近未來與世紀末，SSP585 情境下的超越機率由近未來時期普遍小於 0.1，到了世紀末，則明顯增加至 0.3～0.5 之間，特別是在山區。換句話說，在近未來時期約每 10 年發生一次的事件，在世紀末約 2～3 年便會發生一次，由此可見其危害度增加的幅度相當顯著。使用頻率分析以及重現期的概念，提供的未來變化情況描述，可更直接讓一般民眾體會到未來改變率的感受，如同面對乾旱事件，民眾可明顯感受到過去平均每十年發生一次的乾旱，在最近十年中卻幾乎每年在抗旱。




圖 11 氣候變遷下不同情境於不同時期之超越機率圖，以 ACCESS-CM2 模式為例

參考文獻

- Piani, C., Haerter, J.O., and Coppola, E. (2010a). "Statistical bias correction for daily precipitation in regional climate models over Europe." *Theor. Appl. Climatol.*, **99**, 187-192.
- Piani, C., Weedon, G.P., Best, M., Gomes, S.M., Viterbo, P., Hagemann, S., and Haerter, J.O., (2010b). "Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models." *Journal of Hydrology*, **395**, 199-215.
- Haerter, J.O., Hagemann, S., Moseley, C., and Piani, C., (2011). "Climate model bias correction and the role of timescales." *Hydrol. Earth Syst. Sci.*, **15**, 1065-1079.
- Teutschbein, C. and Seibert, J., (2012). "Bias correction of region climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods." *Journal of Hydrology*, Vol. 456-457, pp. 12-29.
- 蘇元風、劉俊志、鄭兆尊、鬼頭昭雄（2014），以動力降尺度資料評估氣候變遷下颱風降雨事件特性變異，農業工程學報，第 60 卷第 4 期。
- Yuan-Fong Su, Chao-Tzuen Cheng, Jun-Jih Liou, Yung-Ming Chen, and Akio Kitoh (2016). Bias correction of MRI-WRF dynamic downscaling datasets, *TAO: Terrestrial, Atmospheric and Oceanic Sciences*, **27**(5), 649-657.
- 國科會（2010），「臺灣氣候變遷推估與資訊平台建置計畫（1/3）年度成果報告書」。
- 童裕翔、劉俊志、鄭兆尊、陳正達、連琮勛（2020），氣候變遷之日雨量以及時雨量頻率分析，國家災害防救科技中心技術報告。
- 國科會（2023），「臺灣氣候變遷關鍵指標圖集 -AR6 統計降尺度版」。



從參數校正到參數學習之探討 — 可學習物理意義之人工智慧技術

蔡文柄*／國立成功大學水利及海洋工程學系 助理教授

蔡可安／國立成功大學水利及海洋工程學系 碩士生

本文章著重於地球科學模型中的校正問題，許多地球科學模型（如水文或生態系統模型），高度依賴校正後的空間變化參數來進行模擬，模型經過良好的校正，可以通過物理模型將訊息從觀測值傳達到未觀測值，過去傳統的校正方法存在效率低和產生非唯一解的問題，本文章主要在介紹近期提出一種新型的可微分參數模型（differentiable Parameter Learning, dPL），該模型在學習全域解空間的輸入資料和模型參數方面表現出色；此外，dPL 亦呈現了過去未展示過的大數據效益，隨著輸入資料的增加，dPL 有更好的學習表現、能與空間物理特性呈現一致，且有著較好的模型通用性；此研究針對探討土壤濕度、蒸發散量及河川流量等水文系統重要變數進行探討，其中 dPL 在各變數的推估表現皆優於現有的方法，在全球河川流量模擬中，可微分參數學習框架只需要輸入原先 12.5% 的資料即可以達到相同的效果，顯示出其在水文系統模擬中的卓越性能，這一研究成果有望為地球科學模型的進一步發展提供新的方法和方向。

前言

近幾十年來，參數校正在地球科學領域被普遍視為一個必須的過程，多數的地球科學相關模型皆有著會受到這些不穩定參數的影響，許多研究機構致力於將參數校正的技術提升以及將其應用在地球科學的模型中，包含基因演算法^[1]及進化演算法（Shuffled Complex Evolution Algorithm, SCE-UA）等；大部分的降雨逕流模型^[2,3]及生態系統模型^[4]，皆含有需要被校正且無法觀測的參數。除此之外，這些參數對於空間或時間的變化非常敏感，通常需要不斷地重新調整校正後的參數，導致模型的訓練過程變得十分冗長；而當前的優選演算法需要通過多次的模型運作來對這些參數進行校正，十分耗費資源與時間；地球科學模型涉及多個領域，包含輻射傳導等非動力系統模型、動力系統模型，如模擬土壤濕度、蒸發散量、逕流及地下水的水文模型^[5]，模擬

植被生長及碳和養分循環的生態系統模型^[6]以及模擬農作物生長的農業模型，這些模型可以提供水資源管理、污染控制、森林及作物管理以及氣候變遷影響的相關資訊；因此，改進參數校正過程對於提高這些模型的精確性和實用性至關重要。

地球科學系統的資料往往具有空間特性，這種空間異同性為大數據學習提供了寶貴的訊息，進而提高模式系統的可靠性；而在傳統的模型中，校準過後的參數往往只有在單一空間（位置）具有參考價值，難以在其他區域被有效利用，意味著這些參數無法將在一個地方學到的信息應用於其他地區。又由於水文模型的站點分散，模型可能會過度依賴訓練數據、找到不具有物理特性的參數，導致可能獲得干擾訊息而非真實信號，使得參數有非唯一解的問題產生；如果使用逐點校準的方法會使得附近的區域產生不同的參數進行訓練，導致訓練結果的不連續^[7]；綜上所述，傳統的參數校準方法為大範圍地球科學研究中的瓶頸，尋

* 通訊作者，wptsai@gs.ncku.edu.tw

找更具彈性和全局性的參數校準方法是當前地球科學研究面臨的一個重要挑戰。

近幾年深度學習 (Deep Learning, DL), 一種具有多層架構的神經網路系統, 已經在學習數據與空間或時間相關性的領域展現出了卓越的潛力 [8,9]。在水文領域中, 長短期記憶模型 (Long Short-Term Memory, LSTM) 等深度學習的算法已經被成功應用, 研究成果顯示通過深度學習模型可以預測土壤濕度 [10,11]、水流溫度 [12] 及溶氧量 [13] 等, 然而這些只能用來預測具有足夠觀測數據的變量, 對於同樣重要但較難觀測的變量, 如蒸發散、地下水補注及碳的封存, 依然需要依賴手動校準的基於過程模型 (Process-Based Models, PBM); 儘管深度學習在水文領域取得了一定的成功, 但對於一些複雜的生態或水文過程, 特別是缺乏大規模觀測數據支持的情況下, 基於過程的模型仍然是不可或缺的; 因此, 深度學習和基於過程的模型的結合, 可能是未來解決難以觀測變量預測的有效途徑, 以實現對更全面地球科學問題的深入理解。

深度學習網路具有高效的訓練過程, 包含梯度下降與反向傳導, 對於大數據中的信息是很好的反向傳播; 儘管過去曾經試圖利用深度學習來解決整體的參數校準問題, 但結果顯示深度學習方法和物理模型無法有效的被整合 [14]; 更具體的來說, 反向傳播需要用到可微分計算, 需要分析與追蹤模型的輸出, 計算模型中的每一個步驟; 大部分的機器學習模型都可以進行自動微分, 自動追蹤所有梯度, 但傳統的開發環境並不支持這項技術, 需要大量的人工提供相關資料使其可以運行; 雖然在無法自動微分的情況下, 也可以運用有限差分法來對導數進行近似, 但對於大型的神經網路來說, 這個方法較難以處理且準確度較差; 因此, 深度學習在處理複雜且需要整合物理知識的地球科學模型方面, 仍然面臨著技術和方法上的挑戰。解決這些挑戰有望推動深度學習在地球科學中更廣泛的應用。

因此, 此研究提出一種創新的方法, 即利用深度學習神經網路的可微分參數學習框架 (differentiable Parameter Learning, dPL), 利用大數據在物理模型中發現數據的共同性與差異點, 並利用可微分計算, 使深度學習模型與地球科學的基礎模型緊密結合, 這一框架的目的是為模型的輸出提供更豐富的信息和解釋;

此框架分成兩種版本, g_A (無歷史觀測資料) 和 g_z (具歷史觀測資料), 如圖 1 所示; 這種結合深度學習和地球科學基礎模型的方法克服了傳統方法中的瓶頸, 提高參數校準的效率, 同時為模型的應用提供更全面、準確的結果; 這一新型框架也開啟地球科學模型研究的新篇章, 促進更廣泛、深入的理解和應用; 圖 1(a) 表示基於深度學習模型模擬 PBM 模型, 圖 1(b)、圖 1(c) 分別為 dPL 的 g_A 與 g_z 的架構。




圖 1 可微分參數學習框架

研究方法

可變滲透模型

(The Variable Infiltration Capacity, VIC)

可變滲透模型 (Variable Infiltration Capacity, VIC), 已經被廣泛應用在水文學領域, 通過模擬地表與大氣之間水和能量的交換, 為氣候、水資源 (包括洪水、乾旱和水力發電等) 以及農業等領域提供了關鍵的模擬; VIC 模型基於概念化的公式, 模擬蒸發散、逕流、基流以及土壤濕度等重要水文過程, 其輸入數據包含氣象數據、非氣象數據以及需要校正的靜態模型參數。

氣象數據是 VIC 模型的重要輸入，包括降雨量、氣溫、風速、大氣壓力、蒸氣壓以及長短波輻射的時間序列，這些數據在模擬過程中視為關鍵驅動因子，影響著模型對地表和大氣之間水文和能量交換的準確模擬，VIC 模型的應用範疇廣泛，對於理解和預測水文現象、水資源管理和氣候變化影響等方面提供了寶貴的資訊。

長短期記憶模型 (Long Short-Term Memory, LSTM)

長短期記憶模型為人工智慧深度學習的一種，主要被用於學習時間序列的數據，在水文模型中近年來得到廣泛應用，特別是對時間序列資料進行探討；與傳統的神經網路模型相比，LSTM 可以分成兩種狀態（cell state, hidden state）與三種閥門（input gate, forget gate, and output gate），能夠有效地處理序列數據，有效率的對長期記憶學習，同時透過遺忘閥門選擇需要被遺忘的信息。這樣的模型設計可以解決過去在機器學習演算，梯度經常隨著時間變化呈現指數的下降，導致最後因為變得太小而無法被有效的學習，即為過去被詬病經過學習，梯度會消失的問題。

水文物理模型的代理模型 (Surrogate Model)

LSTM 經過適當的訓練後，效能可以約等於 VIC 模型，且可以同時對梯度進行追蹤，因此本研究將水文模型（VIC）使用機器學習（LSTM）的方法進行訓練、建立代理模型，此方式可以改善當物理模型較複雜時無法直接編碼的問題。本研究通過多次的迭代訓練，使用從 NLDAS-2（North American Land Data Assimilation System phase-II）的氣象數據作為模型輸入，並將土壤濕度作為模型的輸出，建構一個 VIC 的代理模型，並在代理模型訓練完後，將歷史校準過的 VIC 參數放入代理模型進行模擬，用擾動這些參數來對代理模型進行重新訓練，進行擾動是為了可以更好的表現出最優的空間參數，重複此過程四次，使得經過訓練的代理模型與真實的 VIC 輸出，達到相關性約為 0.92；此研究並非使用 LSTM 來進行預測目標變數，而是利用它的演算機制來獲取物理模型所需要的參數。

參數估計網絡

此研究提出兩種版本的 dPL 模型架構（ g_A 和 g_z ）；

第一種（ g_A ）適用於沒有觀測的歷史資料（時間序列）當作輸入，僅用氣象資料及靜態屬性做為輸入；第二種（ g_z ）可以接受使用含歷史觀測資料的時間序列資料一併當作輸入。

整個網路利用梯度下降方式進行訓練，是一種一階最佳化的方法；為了允許梯度累積、高效的基於梯度最佳化，並且進一步減少計算成本，此研究將 PBM 應用在可微分學習框架，此研究分別測試了 g_A 和 g_z ；因為衛星地表土壤溼度資料（Soil Moisture Active Passive, SMAP）的觀測值頻率為不規則的 2 ~ 3 天，且模型的輸入無法接受資料空缺，因此，此研究也訓練一個高精確度的代理模型（LSTM），以彌補這些空白的資料。

與大多數深度學習模型一樣，dPL 的超參數也需要調整，此研究利用一年的資料調整模型超參數；對於不同的資料密度，分別使用不同大小的隱藏層神經元數量，更多詳細參數估計網路介紹請參見 Tsai *et al.* [15]。

傳統參數校正優化方式 (Shuffled Complex Evolution, SCE-UA)

為了比較 dPL 中的參數推估效能，此研究也使用 SCE-UA 作為參考方法，SCE-UA 的效果在過去 30 年，已經得到了肯定並且被廣泛應用；該算法根據目標函數對一個參數集合的群體進行排名，將這些參數集合劃分為被稱為複合體的多個子群體，在 SCE-UA 的一次迭代中，這些複合體將在若干競爭演化步驟中個別演化，嘗試進行反射、收縮和隨機試驗，然後在下次迭代之前進行洗牌並重新劃分為新的複合體。

SCE-UA 方法的有效性在許多領域都得到了肯定，它能夠在複雜的參數空間中搜索最佳解，並且已經成為參數校準的一個成熟且可靠的方法；因此，透過使用 SCE-UA 方法，我們可以對 dPL 的性能進行更全面的評估，了解其在水文模型參數估計方面的表現相對於傳統方法的優勢或局限。

地表土壤溼度數據

本研究使用 SMAP 的地表土壤濕度資料作為真實觀測資料，SMA 重複觀測同一地點的時間並不規律，可能是兩天或者三天，導致數據較不規則且有遺漏的資訊，因此此研究亦使用 LSTM 進行提前一天的土壤溼度預測，來彌補資料空白的區域；此方法可以通過氣象數據以及 SMAP 最新的資料集，進行即時的土壤

濕度預測且具有較低的模型誤差，可以彌補 SMAP 觀測與真實情況之間的差距，提供沒有缺漏的數據，供後續可微分學習框架使用。

衛星數據的蒸散量

中級解析度成像分光輻射度計 (Moderate-resolution Imaging Spectroradiometer, MODIS) 中的 MOD16A2 是一個基於 Penman-Monteith 方程式，以 500 公尺 × 500 公尺之分辨率的衛星合成蒸散量產品 (8 天一筆資料)，此研究中並未使用 MOD16A2 作為學習目標，這裡的目的是驗證哪種校準策略能更好地描述整體模型動態；由於 MOD16A2 的觀測與 SMAP 的觀測是完全獨立的，因此可以檢驗哪種校準策略具有更好的一致性。

流域流量測試

在先前的研究中，Mizukami 等人^[16]透過使用 Catchment Attributes and Meteorology for Large-Sample Studies (CAMELS) 資料^[17]，針對 531 個流域的多尺度參數區域化 (Multiscale Parameter Regionalization, MPR) 方案，對 VIC 模型進行了校準 (見圖 8(a) 中的流域位置)；他們將研究範圍限制在小於 2,000 平方公里的流域，並在相同的流域上進行訓練和測試，使實驗成為對模型在時間上泛化能力的測試。

全球無測站流域預測 (Prediction in Ungauged Basins, PUB) 測試

Beck^[18]提出了一個包含氣象因子、靜態屬性和全球 4,229 個源頭流域的日流量數據的全球尺度水文數據集，他們使用了一種最先進的區域化方案，用於在無測站流域中進行預測 (Prediction in Ungauged Basins, PUB)，在此區域化方案中，測試流域的數據未在訓練數據集中使用，從而測試方案在空間上的泛化能力；Beck 使用了 8 個屬性進行轉移函數，包括濕度、年均降水、年均潛在蒸發、年均正規化差異植被指數、開放水面的比例、坡度以及沙和粘土的百分比。他們使用了線性參數轉移函數從原始預測變數到一個簡單水文模型 (HBV) 的 12 個自由參數；總共 4,229 個流域被劃分為三個氣候組：(1) 熱帶、(2) 乾旱和溫帶、以及 (3) 寒冷和極地，為每個氣候組執行轉移函數的訓練，並在每個組內進行了交叉驗證；由於測試流域是隨機選擇的，因此總是會包含在訓練集中的鄰近流域；然而，訓練數據越稀疏，測試流

域平均距離訓練流域就越遠，因此，我們可以減少訓練流域的數量，以檢視對模型在空間上泛化能力的減弱影響，這部分工作的主要目的是比較 dPL 和 Beck^[18]的區域化方案，因此 dPL 保持盡可能相似的設置。

評估指標

本研究使用五種統計指標來衡量模型模擬的性能，其中包含偏差 (Bias)、相關性 (Corr)、無偏差均方根誤差 (ubRMSE, unbiased root-mean-square error)、納許效率係數 (NSE, Nash-Sutcliffe efficiency) 及 Kling-Gupta model efficiency coefficient (KGE)；偏差是模型結果和觀察結果之間的平均差異；相關性是評估模型是否正確模擬變動趨勢；ubRMSE 是計算過程中去除偏差後的 RMSE，用來衡量誤差的隨機成分；NSE 也考慮偏差，完美模型的 NSE 為 1，但較差模型的 NSE 可能為負值；KGE 則類似 NSE，越接近 1 表示模型表現越好。

$$\text{Bias} = \frac{\sum_{i=1}^n (y_i - y_i^*)}{n}$$

$$\text{ubRMSE} = \sqrt{\frac{\sum_{i=1}^n [(y_i - \bar{y}) - (y_i^* - \bar{y}^*)]^2}{n}}$$

$$\text{Corr} = \frac{\sum_{i=1}^n [(y_i - \bar{y}) - (y_i^* - \bar{y}^*)]}{\sqrt{\sum_{i=1}^n [(y_i - \bar{y})^2]} \sqrt{\sum_{i=1}^n [(y_i^* - \bar{y}^*)^2]}}$$

$$\text{NSE} = 1 - \frac{\sum_{i=1}^n (y_i^* - y_i)^2}{\sum_{i=1}^n (y_i^* - \bar{y}^*)^2}$$

$$\text{KGE} = 1 - \sqrt{(r-1)^2 + (\beta-1)^2 + (\gamma-1)^2}$$

$$\beta = \frac{\mu_s}{\mu_o} \quad \text{and} \quad \gamma = \frac{\sigma_s / \mu_s}{\sigma_o / \mu_o}$$

其中， y_i 代表模式輸出， y^* 代表觀測值， $\bar{y}$ 表示模式輸出平均值， $\bar{y}^*$ 表示觀測平均值；此外，KGE 中的 r 為模擬和觀測之間的相關係數， β 和 γ 分別為偏差和變異性比率， μ 和 σ 分別為逕流的平均值和標準差， s 和 o 分別代表模擬和觀測。

訓練資料選取

此研究訓練資料量之多寡 (採樣密度)，依次列為 s4 (最多訓練資料)、s8 及 s16，圖 2 以 s8 為例，s8 為在 8 × 8 的網格中 (綠色虛線)，取一個網格資料進行




圖 2 資料密度 s8 示意圖 (圖片來源: Tsai *et al.* [15])

訓練 (紅色圓圈), 圖中褐色三角形代表在進行空間測試時所選擇的測試站點。

結果與討論

地表土壤濕度 (SMAP)

根據土壤濕度 (SMAP) 的校正案例結果, 展示了在整個美國本土的土壤溼度模擬, dPL 可以提供與演算法 SCE-UA 相等或稍好的表現, 但 dPL 模式性能表現與訓練數據的數量有關, 如圖 3 所示, (a)、(c) 為僅用一年

資料訓練, (b)、(d) 為使用兩年資料進行訓練, Y 軸為模型評比指標 RMSE, X 軸為每個網格運算次數 (圖 3(a), 3(b)) 與計算時間 (圖 3(c), 3(d)), 實線代表 dPL 結果, 虛線則為 SCE-UA 之結果; 當僅用一年資料訓練且採樣密度最低 (s16), dPL 的性能較差 (高 RMSE); 而當用兩年訓練資料且資料採樣密度高 (s4) 時, 模式性能表現最好; 此結果表明隨著訓練資料量的增加, dPL 在每個網格的運算次數和計算時間都比 SCE-UA 更快地下降到可接受的範圍 ($RMSE < 0.05$)。

此研究亦指出兩個影響 dPL 效率的因素分別為採樣密度 (訓練資料量) 以及高效的圖形處理器 (Graphics Processing Unit, GPU) 運算; 大量的訓練資料, 使 dPL 能夠快速跨位學習, 減少運行次數及達到模型收斂, 而高效的 GPU 計算, 也是深度學習的成功關鍵; 雖然 SCE-UA 也可以做到相同的結果, 但很難達到 dPL 所具備的高水準並行效率和規模。

在時間測試上 (同一個訓練網格資料, 但以不同時間的資料做為測試), dPL 在整個美國本土區域的模式表現, 除了東北地區原始資料品質就有問題外, 中西部地區皆可達到相關性高於 0.7 (圖 4(a)), 且皆略優於 SCE-UA; 此外, dPL 在空間資訊上表現出具有更好的整合能力, 並且提供參數在空間上的一致性, 尤其在數據量增加時, 空間整合測試展示 dPL 指標從訓練




圖 3 RMSE 與訓練時間及資料量比較圖 (圖片來源: Tsai *et al.* [15])

集到訓練外的網格幾乎沒有明顯差異（圖 4(d) 之黃色虛線方框）；相比之下，SCE-UA 的 ubRMSE 對於相鄰網格有所增加且具有較大的差異，更明顯的是 dPL 相較 SCE-UA 有更小的偏差範圍；在空間整合測試中， g_z 略優於 g_A ，且均優於 SCE-UA，如圖 4(d)。

未校正變數推估 – 蒸散量

大多數地球科學模型對未觀測（未校正）的輸出變數，可以用作診斷或支持模式模擬的物理性敘述；如果經過土壤濕度為觀測值進行校準的參數，能夠提升未校準變數的模式表現，則可以認為這些校正後的參數更好地描述了潛在的物理過程，並且該模型以正確的物理意義獲得了良好的結果；圖 5 展示不同模型（VIC, SCE-UA 及 dPL g_A , g_z ）在 s8 的採樣密度下，對於蒸散量的預測結果與 MODIS 觀測值之比較，圖 5 顯示， g_z 和 SCE-UA 觀測到的蒸散量與模擬蒸散量之間的相關性中位數分別為 0.75 和 0.69，在 NSE 的方面， g_z 的模型為 0.55，而 SCE-UA 為 0.38；與輸入原始 NLDAS-2 資料的 VIC 模型輸出結果相比，SCE-UA 並無法有效提升模型的準確率，而使用此研究之參數學習框架（dPL）卻有明顯強健的模式表現。

推估的參數空間分佈明顯呈現 dPL 優於 SCE-UA（如圖 6）；如 dPL 評估之參數 INFILT（與入滲有關之參數），顯示出符合北美地區的乾溼分佈、空間地形分佈，且推估參數具有連續、空間代表性；而 SCE-UA 的結果呈現較無空間相關性，結果明顯受到隨機性




圖 4 土壤濕度模擬圖與評估指標（圖片來源：Tsai *et al.* [15]）




圖 5 蒸散量指標比較圖（圖片來源：Tsai *et al.* [15]）




圖 6 dPL 與 SCE-UA 生成參數空間對比
(圖片來源: Tsai *et al.* [15])

和參數非唯一性困擾的不連續參數，這解釋了為什麼 SCE-UA 在空間泛化（鄰近網格）和未校準變數測試中表現較差，需要逐點進行校正。

流量推估表現

在河川流量預測方面，與現有先前的多尺度參數區域化模式（MPR）相比，結果顯示 dPL 更具優勢；下圖 7 為使用 CAMELS 的水文資料集當作輸入的模擬結果，並用 dPL 來推估 VIC 水文模型的參數，測試不同時間段的流量推估結果。圖 7(a) 顯示使用 g_z 的 VIC 模型 NSE 中位數約為 0.44（紅色實線），而 MPR 方案的 NSE 中位數




圖 7 dPL、MPR (a) 與 Beck [18] 研究 (b) 之流量推估表現
(圖片來源: Tsai *et al.* [15])

為 0.32（綠色虛線），此結果挑戰了之前的論點，該實驗設置中的 0.32 接近 VIC 模型的性能上限，也說明區域化方案（MPR）並不是接近最優的方法，而 dPL 能提供更佳的參數推估結果；圖 7(b) 展示與 Beck 在 2020 年對全球無測站流域預測（PUB）之結果比較，由於 PUB 並無歷史觀測資料，因此 dPL 僅能使用 g_A 形式，圖中可以發現 Beck 2020 [18] 的 KGE 中位數約為 0.48（綠色虛線），使用與 Beck 相同設置的 8 個校正參數，dPL 的 KGE 中位數約為 0.56（藍色實線），模式表現優於 Beck 之結果，若進一步增加 dPL 校正參數至 27 個（紅色實線），KGE 中位數更可以接近 0.6；雖然使用越多校正後參數能增加模式表現，但在實際操作上仍要考慮到計算成本的問題。

圖 8(a) 為使用 dPL 之 g_A 模型針對美國地區（CAMELS 數據集），進行流量推估評比，不同顏色代表各區域的 NSE，越接近暖色系表示該區域模型準確率越高，圖 8(b) 則為 Beck 等人 [18] 在 2020 年使用全球水源流域資料庫的資料；整體而言，由圖可以發現應用 dPL 在區域尺度（北美地區）或是全球尺度下，對於河川流量的推估皆能有良好的模式表現。




圖 8 過去模型與現有模型比較圖

大數據效益

大數據效益問題從未在地球科學建置模型的背景下進行過討論，此研究亦用另一種方式總結結果，此研究隨著訓練數據量的增加，清楚地呈現大數據對於深度學習模型帶來的效益；如圖 9(a)，顯示隨著訓練資料增加（X 軸由左至右為 s16、s8、s4），模式整體的表現也隨之提升，以綠色實線為例（訓練結束時之 RMSE），s16




圖 9 dPL 的縮放曲線 (圖片來源: Tsai et al. [15])

時為 0.047，而 s4 則下降到 0.044，每個站點的平均計算量（計算成本）亦大幅下降（藍線 Y 軸），s16 要接近 900 次迭代才能達到低於門檻的 0.05，而 s4 僅需不到 50 次即可達到；成本的降低可以解釋為 dPL 藉由大數據訊息，提高了模式效益規模，其中增加的全域訓練成本改由各站點分擔；由圖 9(b) 可以發現藍色星星所延伸的虛線代表 Beck 等人 [18] 在 2020 年研究的模式表現結果（評估指標中位數），然而在此研究中，dPL 只需要使用不到 20% 的資料量訓練就可以達到一樣的效果，再次說明 dPL 能夠有效率地從有限的資料中，學到有用的訊息，提供模式有更佳的表现。

結論

此研究結果有幾個重要涵義：

1. 我們期望這些新穎的縮放曲線對其他地球科學領域也成立，這表明參數學習框架（dPL）的優勢主要來自利用大數據中發現的特徵共同性和差異性，沒有大數據這種優勢可能不存在，或者會大幅減小，這些曲線也表明對任何深度學習模型結果的解釋都必須以訓練資料量為基礎，例如，當少量的數據被應用在深度學習的情況下，結果的意義可能有限。
2. 參數學習框架（dPL）通過可微分計算將深度學習訓練機制與現有的地球科學模型（水文物理模型）結合後具有強大的優勢；這種整合涉及觀測變數的完整性，可藉由模擬歷史資料，來提供可解釋的敘述或診斷，例如氣候變化影響評估；另一方面，此研究的方法可以立即且有效的提高準確性，這裡提出的核心支持技術是通過使用可微分計算代理模型或在深度學習平台上重新實施進行微分計算，大部分現

代深度學習框架都支持這兩種選項，並且可以依據工作量做選擇；對於像 HBV 這種較簡單的水文模型（Hydrologiska Byråns Vattenbalansavdelning model），直接在深度學習上執行是最簡單且最準確的，但像是 VIC 這種較複雜的模型，代理模型可以成為他們與大數據學習的橋樑；根據這些整合，機器學習可以被用來提高我們對物理模式的理

3. 深度學習支持的 dPL 為地球科學系統及其他領域提供通用、合適且高效的解決方法；對此研究的三個例子（土壤濕度、蒸發散及河川流量），每個例子都有不同的配置，但都使用相同的 g_A 和 g_z 元素，此研究期望這些通用性繼續存在其他領域，因為本研究並沒有明確指定任何函數，這些參數是由深度學習演算法決定，並由模型本身適應新問題，顯示 dPL 比傳統方法更靈活，可以應對不同數據集和複雜問題。
4. 在地球科學的領域中，目前尚未有人提出類似 g_z 此種模型的結構，此結構嘗試藉由歷史觀測來推估模型參數；當具有良好品質的輸入資料時， g_z 與 g_A 並無法發現明顯的差別，也因此在預測土壤濕度的測試中 g_z 僅能表現出輕微的優勢，但在其它屬性資料有限的情況下， g_z 的表現會比 g_A 更有價值； g_z 在隱私方面也有具有一些優勢，例如在私人的區域上，基於各種不同的原因可能會導致資料不公開或無法共享，利用 g_z 使用私有資料作為輸入，因此可以允許使用無法選擇的資料做為參數，且一旦訓練完成，該模型即可被保存用於新的事件，不需要再重新架設模型，是過去傳統模型無法做到的；然而本研究仍表明 dPL 在僅有少數站點的時候，可能不會有明顯的優勢，且有可能會無法捕捉到潛在過程資訊。

參考文獻

- Maier, Holger R., *et al.* (2014). Evolutionary algorithms and other metaheuristics in water resources: Current status, research challenges and future directions. *Environmental Modelling & Software* 62.
- Moradkhani, H. and Sorooshian, S. (2008). Hydrological Modelling and the Water Cycle: Coupling the Atmospheric and Hydrological Models (eds. Sorooshian, S. *et al.*) 1-24.
- Paniconi, C. and Putti, M. (2015). Physically based modeling in catchment hydrology at 50: Survey and outlook. *Water Resour. Res.*, **51**, 7090-7129.
- Luo, Y. and Schuur, E.A.G. (2020). Model parameterization to represent processes at unresolved scales and changing properties of evolving systems. *Glob. Change Biol.*, **26**, 1109-1117.
- Ajami, N.K., Gupta, H., Wagener, T., and Sorooshian, S. (2004). Calibration of a semi- distributed hydrologic model for streamflow estimation along a river system. *J. Hydrol.*, **298**, 112-135.
- Post, H., Vrugt, J.A., Fox, A., Vereecken, H., and Franssen, H.-J. H. (2017). Estimation of Community Land Model parameters for an improved assessment of net carbon fluxes at European sites. *J. Geophys. Res. Biogeosci.*, **122**, 661-689.
- Yang, Y. *et al.* (2019). In quest of calibration density and consistency in hydrologic modeling: Distributed parameter calibration against streamflow characteristics. *Water Resour. Res.*, **55**, 7784-7803.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, **521**, 436-444.
- Schmidhuber, J. (2015). Deep learning in neural networks: an overview. *Neural Netw.*, **61**, 85-117.
- Fang, K., Shen, C., Kifer, D., and Yang, X. (2017). Prolongation of SMAP to spatiotemporally seamless coverage of continental U.S. using a deep learning neural network. *Geophys. Res. Lett.*, **44**, 11, 030-11, 039.
- Fang, K., Pan, M., and Shen, C. (2019). The value of SMAP for long-term soil moisture estimation with the help of deep learning. *IEEE Trans. Geosci. Remote Sens.*, **57**, 2221-2233.
- Rahmani, F. *et al.* (2021). Exploring the exceptional performance of a deep learning stream temperature model and the value of streamflow data. *Environ. Res. Lett.*, **16**, 024025.
- Zhi, W. *et al.* (2021). From hydrometeorology to river water quality: Can a deep learning model predict dissolved oxygen at the continental scale? *Environ. Sci. Technol.*, **55**, 2357-2368.
- Reichstein, M. *et al.* (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, **566**, 195-204.
- Tsai, W.P. *et al.* (2021). From calibration to parameter learning: harnessing the scaling effects of big data in geoscientific modeling. *Nat. Commun.*, **12**, 5988.
- Mizukami, N. *et al.* (2017). Towards seamless large-domain parameter estimation for hydrologic models. *Water Resour. Res.*, **53**, 8020-8040.
- Newman, A., K. Sampson, M.P. Clark, A. Bock, R.J. Viger, and D. Blodgett, (2014). A large-sample watershed-scale hydrometeorological dataset for the contiguous USA. Boulder, CO: UCAR/NCAR. <https://dx.doi.org/10.5065/D6MW2F4D>
- Beck, H.E. *et al.* (2020). Global fully distributed parameter regionalization based on observed streamflow from 4,229 headwater catchments. *J. Geophys. Res. Atmos.* 125, e2019JD031485. 

EARTHPOWER CONSTRUCTION CO., LTD

義力營造股份有限公司

卓越
誠信
安全
技術
品質

義呈實諾 力呈卓越

創立於民國八十三年・甲等綜合營造業

深耕台灣，致力鑽研土木、環境、建築、區段徵收、開發工程，秉持追求全員工安、品質提升的精神，在誠信踏實的經營態度之下，堅守營建道德崗位，各項工程實績屢獲優良工程金安獎、公共工程金質獎

土木工程

整地・道路・排水橋梁・隧道
護坡・植生景觀・管線工程

建築工程

辦公大樓・廠辦新建
特殊建築・集合住宅

環境工程

掩埋廢棄物分類清除・土壤污染改良
污水處理・復育工程・廢棄物分類機械製造

區段徵收

區段徵收工程
土地重劃・公設工程施工

開發工程

工業園區開發
社區開發・租售管理



優良廠商 / 優良營造業
金安獎、金質獎 雙獎特優

TEL: (04) 2435-0568
FAX: (04) 2435-0569

公司地址：
臺中市北屯區軍福11路553號1樓

郵箱: earth.powerld@msa.hinet.net
網址: www.earthpower.com.tw



結合類神經網路與小波分析 進行多源雨量融合及流量預測

江衍銘* / 浙江大學水利工程學系水文與水資源研究工程所 副教授

李楠楠 / 浙江大學水利工程學系水文與水資源研究工程所 碩士

蔡可安 / 國立成功大學水利及海洋工程學系 碩士生

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

前言

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

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

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

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

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

* 通訊作者，chiangym@zju.edu.cn

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

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

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

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

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

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

研究區域

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

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

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

研究方法

小波分析（Wavelet analysis）

小波分析是由傅立葉轉換發展而來的信號時頻工




圖 1 金華江流域測站位置圖

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

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

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

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

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

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

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

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

倒傳遞神經網路

(Back Propagation Neural Network, BPNN)

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




圖 2 倒傳遞神經網路架構圖

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

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

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

小波神經網路

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

流量預測模型及評估指標

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

輸入變量選取

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

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

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

「分解－單支重構－融合－預報－疊加」模型（模型 A）

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

表 1 模型可能的輸入組合

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

*Q 代表流量，P 和 S 分代表地面雨量站雨量和衛星反演雨量

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

「分解－融合－預報－疊加」模型（模型 B）

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

「分解－單支重構－融合－預報」模型（模型 C）

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

評估指標

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




圖 3 「分解－單支重構－融合－預報－疊加」模型（模型 A）流程圖




圖 4 「分解—融合—預報—疊加」模型（模型 B）流程圖




圖 5 「分解—單支重構—融合—預報」模型（模型 C）流程圖

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

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

實際預測值和測量值，當 MAE 越小的時候表示該模型的精確度越高。

相對平均誤差 RME 為平均絕對誤差 MAE 與測量

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

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

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

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

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

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

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

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

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

結果與討論

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

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

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

表 2 未雨量融合模型 1h 流量預報結果對比

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

表 3 融合模型未來 1 小時流量預測結果對比

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




圖 6 融合模型的測試階段的未來 1h 流量預報散布圖

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

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

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

我們假設準確度超過 90% 以上為該預測資料合格的情況下，分析在測試階段的 5 筆洪峰流量資料（圖 7），模型 A 與模型 B 的合格率皆可以達到 80% 以上，而模型 D 只有 40%。此外，4 個模型對第 1、2、4 次洪峰的預報效果較好，而對第 3 次和第 5 次洪峰的預報效果較差，這 5 次洪峰的實測洪峰流量分別為 918 m³/s、1,160 m³/s、555 m³/s、4180 m³/s 和 511.5 m³/s，所以 4 個融合模型對高流量洪峰的預測效果比低流量洪峰的預測效果更好。

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




圖 7 各融合模型對測試階段的 5 次洪峰預報的相對誤差

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

表 4 各融合模型的洪峰流量預報效果

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

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

結論

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

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

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

參考文獻

1. National Science and technology Center for Disaster Reduction, NCDR, New Delhi, India, Mar. 2020.

2. E.Toth,A. Brath, and A. Montanari, (2000).“Comparisonofshort-termrainfall prediction models for real-time flood forecasting.” *J. Hydrol*, Vol. 239, Nos. 1-4, pp. 132-147.

3. 吴东杰、王金生、滕彦国（2004），小波分解与变换法预测地下水位动态 [J]，水利学报，(5)，39-45.

4. Adamowski, J. and Chan, H.F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *J. Hydrol.* **407** (1-4), 28-40.

5. R.G. MorrisandD. Hebb, *TheOrganizationofBehavior*. NewYork, NY, USA: Wiley, 1949.

6. F. Rosenblatt, (1958). “The perceptron: A probabilistic model for information storage and organization in the brain,” *Psychol. Rev.*, Vol. 65, No. 6, 386p.

7. Y. LeCun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, and L.D. Jackel, (1989). “Backpropagation applied to handwrit- ten zip code recognition.” *Neural Comput*, Vol. 1, No. 4, pp. 541-551.



應用深度學習與遠端監視影像分析技術於防災

蘇元風* / 國立臺灣海洋大學河海工程學系 助理教授

深度學習在電腦視覺領域多年來已有非常快速的發展，例如：車牌辨識、人臉辨識等等，而在土木工程與防災領域的應用上仍有非常多的發展空間。在眾多影像分析的應用當中，CCTV（Closed-Circuit Television）的監視畫面分析是正逐漸受到重視的一環。由於 CCTV 畫面取得容易且數量眾多，因此如何自動由 CCTV 畫面中取得在防災領域中所關心的資訊，是各種應用之中最重要的問題。近年來快速成長的機器學習與深度學習技術，更是加速 CCTV 影像應用的重要功臣，本文介紹三個具有潛力的 CCTV 影像應用於防災領域之案例，盼能啟發更多在土木工程或防災領域之相關應用潛力。

前言

CCTV（Closed-Circuit Television）影像分析應用在土木工程與防災在近幾年中逐漸受到重視，其主要可歸功於電腦視覺（Computer vision）與深度學習（Deep learning）技術的快速發展，而在過去已被大量安裝的 CCTV 影像畫面，變成了最即時可快速派上用場的資料來源之一。由於深度學習工具已可免費取得，且在網路上可找到非常多教學資源，也有助於深度學習技術的發展。此外，開放資料政策下已有許多 CCTV 畫面可免費取得，在 CCTV 影像數量龐大的情形下，如何找到適當的議題，選擇適合的影像分析或深度學習工具，萃取出最合宜的資訊，是最主要的關鍵。

本文整理近年的三項防災領域的應用案例，一是以山區的 CCTV 畫面偵測山區河道洪水發生的時間點，爭取通知下游居民的警報時間；二是以深度學習中基礎的卷積神經網路，偵測 CCTV 畫面中是否發生淹水；最後則是使用預先訓練之模式，以物體偵測（object detection）方法識別 CCTV 畫面中是否出現人員，可應用於海岸或堤防邊在颱風期間觀浪民眾的偵測，即時發布通知並派遣人員前往勸離。

山區洪水發生偵測

山區洪水偵測方法（專利證號：發明第 I650529 號）^[1] 為國家災害防救科技中心所研發的第一項專利，其主要概念即利用現有的農業部農村發展與水土保持署的 CCTV 測站畫面，以基本影像分析方法偵測河道中水體的網格數量，當河道水體網格數量快速增加時，即可視為山區洪水正在發生，詳細分析方法請參見專利說明。由於山區 CCTV 測站到下游居民住所集中處仍有一段距離，提早由山區的 CCTV 影像發現洪水事件，可爭取數十分鐘的預先警報時間，相關單位可透過廣播系統通知在下游河道活動的人潮，盡早進行避難以遠離危險。

圖 1 為此方法之示意圖，而由本方法在影像中取得的資訊，經過比對鄰近的水位觀測站，由統計分析結果顯示其與水位資料有高度相關性，驗證 CCTV 畫面中的資訊正確性。

此方法之詳細過程如圖 2，首先將山區影像灰階化，灰階化後的影像可明顯看出山區的河水明顯較亮，河床背景則明顯較暗，本研究也將利用此觀察進行後續分析。為加速演算效率，本研究選擇一關注區域（Region of Interest, ROI），如圖 2 右上方較亮的區域，即為 ROI。此區域內的影像，採用非監督式分群方

* 通訊作者，yuanfongsu@mail.ntou.edu.tw




圖 1 山區洪水偵測方法示意流程圖

式，K-means 將像素 (pixel) 分為兩群，較亮的一群即為河水，較暗的即為河床。最後，為了得到一個適用於全天日照環境下的分群門檻值，我們蒐集了一天當中上午 6 點到下午 6 點共 600 張影像，均進行 ROI 內的 K-means 分群分析，得到兩群平均值的線如圖 2 左下圖所示，由圖 2 左下圖可看出除了早上 6 點到 6 點半之間，因太陽剛升起時光線不足的情況之外，大部分的時間兩群均可以單一門檻值區分得很清楚，因此可由此獲得適用於整個白天時段的單一門檻值，此門檻值即可有效的區分山區的河水與河床（如圖 1 左下圖所示）。

圖 1 右下圖則是將 ROI 中的河水像素個數除以

ROI 內總像素個數而得到的比值，此比值即可作為山區洪水偵測的主要資訊，當此比值快速上升時，即代表山區洪水開始侵襲 (onset)。由 CCTV 影像判斷水位快速上升的數據可與下游水位測站所測得之水位變化數據相比較以作為驗證。

在與水位資料比對時，採用了資料平移後計算相關係數的方法，發現當資料平移 30 分鐘後，與下游水位的相關性最高，由此可知當上游 CCTV 發現水位上升之後，經過 30 分鐘後，下游水位才開始有反應，因此相較於傳統水位觀測方法，CCTV 的方法有效的提早了 30 分鐘得知山區洪水即將來襲，因此有更多洪水預警時間，可提高防災之效率。




圖 2 CCTV 偵測山區洪水研究步驟示意圖

卷積神經網路應用於淹水事件偵測

卷積神經網路 (Convolutional Neural Network, CNN) 為基礎的深度學習網路，其概念最早由 Fukushima 於 1980 年提出^[2]，該文章中將神經網路分為 S-cell 與 C-cell，分別對應到卷積層 (convolution layer) 與池化層 (pooling layer)，而真正出現 CNN 一詞為 LeCun 等人於 1995 年的著作中^[3]所提出。CNN 基礎的概念如由圖 3 所示，其輸入為影像，CNN 中的卷積層主要目的為透過各式各樣的空間濾波 (filter) 與影像進行卷積操作，得到各種影像特徵資訊 (features)，這些特徵進一步透過池化層，減少影像大小並保留重要資訊，卷積層與池化層的操作可重複數次，萃取不同層級的影像特徵，這些特徵都將作為後方所接的全連結層神經網路系統的輸入，最後產出為單一數值，由此數值大小判斷畫面中是否出現淹水事件。在此應用之中，並不需要對影像進行標籤化 (label) 的動作，僅需挑選淹水與非淹水影像進行訓練，影像資料的前處理工作較少是其主要優點，然而缺點是未直接顯示 CNN 模式找到哪些影像特徵作為淹水的判斷，欲了解那些特徵是對淹水判斷有幫助的，必須仔細檢視 CNN 模式的權重與濾波器的等參數。

CNN 模式架構則如圖 3 所示，首先是 32 層的 Conv 層，用於萃取影像特徵，其後的 pooling 層則用於減少影像的大小以加速運算，其次再接 32 層的 Conv 層，萃取不同影像大小下的影像特徵，接著再一次縮小影像，再接上最後 64 層的 Conv 層，因為層層的擷取影像特徵，可掌握不同尺度的影像特徵。最後則是

以一個全連結層 (fully connected) 網路，判斷這些特徵是否能反映出積淹水特性。

CNN 模式建立的過程中，需要大量的積淹水影像作為訓練資料，然而要從歷史事件中找到 CCTV 影像中記錄淹水的畫面，是一件非常困難的任務，主要是因為過去 CCTV 的設置尚未普及在容易淹水的地區，其次則是 CCTV 畫面通常保留數天後即會銷毀，因此不易取得適當的訓練資料。為解決此問題，本研究蒐集各式新聞照片、現場人員回報影像、開放 CCTV 畫面等各種來源的積淹水影像，共蒐集了 318 張有積淹水以及沒有積淹水的影像作為訓練資料 (如圖 4)。訓練 CNN 模式時，本研究將所蒐集的 318 張影像，分為 80% 的影像進行訓練，20% 的影像則用於驗證 (Validation)。

CNN 模式的表現分析結果顯示，訓練的影像中約 99% 的影像均可分類正確，即可正確分辨 CCTV 畫面中是否發生積淹水，而測試影像則約有 87% 的影像可正確分類。由表 1 可看出在 128 張正常 (無積淹水) 的影像中，有兩張被分類為積淹水，屬於錯誤分類，而在 118 張積淹水影像則全數正確分類為積淹水。表 2 則為驗證影像所得結果，亦即使用訓練後的模式，稍微進行測試，結果發現測試資料仍有 87% 的比例是正確分類的，在 31 張正常影像中，有五張被錯誤分類為積淹水，在 31 張積淹水影像中，則有三張被錯誤分類為正常的影像，圖 5 為經 CNN 模式正確辨識為淹水之影像範例，圖片上方的數字為 CNN 模式之輸出值，該數據若小於門檻值，則判斷為淹水，反之則判斷為非淹水，在此範例中門檻值為 0.599，此門檻值取得方式




圖 3 卷積神經網路應用於 CCTV 畫面淹水偵測




圖 4 本研究蒐集之訓練影像範例

表 1 CNN 模式之訓練表現

訓練 正常		實際類別		使用者 精確度
		積淹水		
模式輸出類別	正常	126	0	100%
	積淹水	2	118	98%
生產者精確度		98%	100%	整體 精確度 99%

表 2 CNN 模式之驗證表現

驗證 正常		類別		使用者 精確度
		積淹水		
模式輸出類別	正常	26	3	90%
	積淹水	5	28	85%
生產者精確度		84%	90%	整體 精確度 87%




圖 5 經 CNN 模式正確辨識為淹水之影像範例

為透過 CNN 模式的驗證資料中可以将驗證資料區分得到最高精確度時所對應之門檻值。

此模式目前已在 2023 年的颱風事件中進行測試，測試結果顯示總體精度大致與模式建立過程的驗證精度相符，但是實際測試中也發現其他問題，例如：都市與山區道路淹水特性的差異、日間與夜間淹水特性的差異等情形，這些多樣的差異性，要在單一模式中偵測出來，需要更多的影像資料才能做到，甚至在未

來也將考慮採用多模式的方式偵測不同情況下的淹水情形，例如：先以一個模式偵測是否降雨，後續再接著另一個模式判斷降雨的畫面中是否發生淹水。

物件偵測於颱風時期海岸邊人員安全監測

使用深度學習於物件偵測（object detection）的發展十分迅速，例如：You Only Look Once（YOLO）^[4] 即為非常知名的物件偵測模式。物件偵測為分析影像中是否



圖 6 以 YOLOv5 偵測 CCTV 畫面中的人員，圖為海洋大學工學院後方海堤

出現某種物體或物件，例如：動物、茶杯、車輛等等，甚至可追蹤此物件的動向或是體態等，在許多領域都有非常大的應用潛力。在工程領域的應用上，交通部運輸研究所綜合 Faster R-CNN 與 YOLO 的技術，進行交通數據蒐集與分析^[5]，此外也使用同樣的技術於改善軌道扣件巡檢的效率^[6]。在防災領域，過去颱風時期海岸邊的觀浪人潮，往往是海岸防災重點工作，若此工作可透過 CCTV 影像與 YOLO 技術的結合，判斷 CCTV 畫面中在靠近海岸地區的人員，如圖 6 所示，即可透過自動化的分析方式，提出警示給相關單位，以進行勸離工作，將有助於相關單位之實務作業。

本應用案例為使用預訓練 (pre-trained) 深度學習網路模式的案例，該模式中本身即可偵測畫面中的人，而為了更符合本應用案例之使用，也可以針對人物的偵測進行研究區域影像的標籤化 (labelling)，將可更提高人物辨識的精確度，如圖 6 中 person 後方的數字即代表辨識的信心，經由影像的 labelling 與重新訓練模式，將可提高此信心值。此外，由於海堤若出現海浪拍打上岸時，觀浪危險性將大增，對此也可在標籤化時，將海浪拍打上海堤的畫面進行標籤化，並加以訓練模式後，可與人物偵測結果結合，若人物與海堤上的海浪這兩個特徵都出現時，發出更緊急的通知給岸巡人員，執行強制驅離作業，便可在海岸邊人員安全監測上提供不同程度之警報，以便權責機關執行相對應之作為。

結論

深度學習在資訊領域已有許多快速的發展，許多工具可應用於土木與防災領域，加上開源的資料、模

式與程式碼的取得也較以前容易。研究人員只需要了解不同的深度學習技術的概念，思考適當的應用命題，例如：港口設備物件偵測、車流統計、人流統計、結構安全檢測、動物行為偵測、物體瑕疵檢測^[7]等等，尚有許多應用的潛力。本文所描述的三種應用案例，例如：非監督式分類法應用於山區洪水發生偵測、卷積神經網路應用於淹水事件偵測、物件偵測於颱風時期海岸邊人員安全監測等應用，雖然只是簡單的應用，但卻可能提供重要且即時的防災資訊，希望透過本文能啟發更多深度學習在工程上之應用潛力，讓工程與防災工作能做到更細緻化、更有效率。

參考文獻

1. 國家災害防救科技中心，山區洪水偵測方法，專利證號：發明第 I650529 號。
2. Fukushima, K. (1980). Neocognition: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position, *Biological Cybernetics*, Vol. 36, pp. 193-202.
3. Yann LeCun, Yoshua Bengio, (1995). Convolutional Networks for Images, Speech, and Time Series, *The Handbook of Brain Theory and Neural Networks*, Vol. 3361, No. 10, pp. 1995.
4. Redmon, J., Divvala, S., Girshick, R., Farhadi, A., (2016). You Only Look Once: Unified, Real-Time Object Detection, arXiv.1506.02640
5. 林良泰、蘇昭銘、曾明德、劉霽、王晉元、吳沛儒、黃啟倡、郭松庭、莊智仁、倪文哲、卓奕志、陳怡君、沈志弘、呂宗翰、林孟潔、郭思漢、蕭昱書、白家綾、林冠融、張國彬、呂治國、康哲源、林彥宇、鍾俊魁、吳奇峰、吳東凌、樓軒宇 (2020)，應用人工智慧 (AI) 影像辨識技術進行交通數據蒐集與分析之研究，交通部運輸研究所合作研究計畫報告。
6. 謝禎罔、黃維信、謝尚琳、林雅雯、洪瑋宏、杜宇豪、賈漢文、徐倜雲 (2020)，軌道扣件巡檢系統建置 (2/2) — 扣件缺失辨識系統精進驗證，交通部運輸研究所合作研究計畫報告。
7. 交通部運輸研究所運輸工程組，影像辨識應用於橋梁檢測工作初探，交通部運輸研究所運輸研究專輯。



小水力發電之發展歷程、 現況與推動建議

劉宏仁*／國立臺灣大學水工試驗所 助理研究員

林文勝／國立臺灣大學水工試驗所 副研究員

游景雲／國立臺灣大學水工試驗所 主任、國立臺灣大學土木工程學系 教授

陳谷汎／水律能源股份有限公司 執行長

小水力發電或微水力發電是一種分散式的小型水力發電，可普遍簡易裝置於灌渠、溪流、水利設施（壩、堰、湖泊、蓄水池、尾水路）、旁通水路（bypass）等，適合做為農村、社區、山區、偏遠地區或者家庭、中小企業以及電力供給不穩定地區之供電來源。本研究透過文獻回顧，整理國內外小水力發電之發展歷程，發現「在地發電、在地使用」的小水力發電已成為國際再生能源發展的一個新趨勢。

台灣目前商轉中的小水力發電廠共有 30 座，裝置容量總計為 152.2 MW，近 10 年小水力發電廠的建廠數量明顯增加，顯示台灣對於再生能源的積極投入。本研究介紹最新的小水力發電廠，並就資源、技術、法規、產業、觀念、金融等六個面向，提出推動建議，期能突破發展初期的瓶頸段，順利推動小水力發電，成為國家邁向 2050 淨零排放的發展路徑，並進一步整合水資源與再生能源，帶動國家的永續發展。

關鍵詞：小水力發電、再生能源、淨零排放、永續發展

小水力發電

水力發電（Hydropower）乃運用水的勢能轉換成電能的發電方式，其原理主要是利用水位的高低落差（勢能）在重力作用下流動（動能），例如從河流或水庫等高水位處引水流動至低水位處，流動的水流即可推動水輪機使之旋轉（機械能），再帶動發電機發電（電能），提供可永續使用的綠色能源（Green Energy）。

依據「再生能源發展條例」（2023），其定義小水力發電（Small Hydropower，簡稱 SHP）係指「利用水道、圳路、管渠或其他水力用水以外用途之水利建造物之原有水量及落差，以直接設置或另設旁通水路設置之方式，轉換非抽蓄式水力為電能，且裝置容量未達二萬瓩（20,000 kW = 20 MW）之發電方式。」；而依據世界銀行與聯合國的標準，可再將裝置容量小於 100

kW 之機組細分微水力發電（Micro Hydropower）機組。

同時依據「開發行為應實施環境影響評估細目及範圍認定標準」，將小型水力發電排除在外，亦即小水力發電可免除環境影響評估。以此鼓勵及推廣再生能源利用，增進能源多元化，改善能源結構，降低溫室氣體排放，改善環境品質，帶動相關產業及增進國家永續發展。

具體而言，小水力發電或微水力發電是一種分散式的小型水力發電，可普遍簡易裝置於灌渠、溪流、水利設施（壩、堰、湖泊、蓄水池、尾水路）、旁通水路（bypass）等，適合做為農村、社區、山區、偏遠地區或者家庭、中小企業以及電力供給不穩定地區之供電來源。因具有建置成本低、廠房占地小、對生態環境影響小、運行維護成本小、可分散建置、輸電成本低、可不斷再生利用等優點，在地發電、在地使用的小水力發電已成為國際再生能源發展的一個新趨勢^[1]。

* 通訊作者，harrylittleprince@gmail.com

小（微）水力發電雖然有「小」或「微」的形容詞，但要設置小水力發電廠（如圖 1）仍然是不折不扣的工程，必須由具有水利及電機專業的工程師來規劃設計及監造完成。發電機組也是由專業工程師選定，後由設備廠製造完成並進行假組立，再運至工地安裝與試運轉。而不論是整體電廠的規劃設計監造或水輪機與發電機設備的製造、土木工程與輸配電工程等，都有完整且專業的規範需依循。完工後發電設施的操作及維護，也應由廠商提供專業的規範或手冊供維護管理人員遵循辦理^[2]。



圖 1 小水力發電廠實際案場 (stockport-hydro.co.uk)^[3]

國際小水力發電發展

小型水力發展甚早，早在 1882 年美國威斯康辛州狐狸河（Fox River）畔，世界第一座小水力發電廠即開始運作，供應發電廠、住家及附近建物所需電力。而後大型水力開發，因發電量上的差異，小水力發電廠漸被淘汰。時至今日，再生能源議題興起，小水力發電才又受到重視。以下回顧數篇重要的小水力發電論文，以呈現目前國際小水力發電的進展與成果：

- Anderson 等人^[4] 研究了水力發電的發展對美國中部的生態影響，主要即評估小型壩堰對魚類的影響。發現小水力發電廠因築壩引水使得河川流量減少約 10%。比較引水壩上游和下游的魚類群落組成，發現明顯不同，表示小水壩（< 15 m 高）阻礙了魚類的活動。
- Csiki and Rhoads^[5] 評估了壩堰對河川的影響，以及拆壩之後會產生的河川變化。河流受壩堰長期存在的影響，主要是上游沉積物堆積與下游河道侵蝕，可能會影響到河段流量，進而影響水力發電電量。
- Punys 等人^[6] 回顧並比較了用於小水力發電（SHP）電廠規劃和設計的軟體工具，將這些工具集成到地理信息系統（GIS）中，可以大幅提升對於發電潛能的

評估。目前加拿大、意大利、挪威、蘇格蘭和美國等國家，已經依此重新評估了水力發電的潛能容量。但，具體可靠與否，仍需進行現地勘查與測量。

- Kaunda 等人^[7] 對於水力發電技術進行回顧，並提出未來的挑戰。永續的水力發電是可能的，但需要適當的規劃和仔細的系統設計。能源規劃者、投資者和其他利益相關者需要掌握最新知識，才能做出明智的決策。隨著全球氣候變遷，水力發電的能力也會改變，伴隨開發的風險，需要設定好調適措施。
- Bracken 等人^[8] 鑒於過往圍繞小水力發電的研究方向，主要集中在發電技術方面，對社會組織和環境影響的理解有限。因此開始著重在社區居民和組織參與微水力發電的方式，同時以此作為未來促進英國可再生能源政策目標的一種手段。針對英國的微水力發電計畫進行研究，以英格蘭北部的兩個微水力發電計畫為例進行詳細評估，Settle 社區微水力發電（圖 2）與 Ruswarp 社區微水力發電，探討資源利用和競爭的過程，以確定社區在微水力發電計畫中的所需的專業知識和有爭議數據。該研究結果顯示，英國微水力發電的快速擴張，其所有權 / 控制權，有很大的比重是「基於社區」所發展出來的。
- McManamay 等人^[9] 開發了一個分類系統來組織美國水電大壩和發電廠的運行模式。其發現重要的是時間尺度，要採用比日還小的小時或分鐘尺度，才能進行良好的分類。這種標準化的分類有助於按類別進行水文模型、水庫作業、工程經濟性、環境影響和對應措施等之評估。
- Sood and Singal^[10] 針對水力電廠水理計算與機組設置之技術，做了一個整體回顧，以利於在氣候變遷下推動可再生能源的持續發展。研究總結三個關鍵步驟：




圖 2 英國 Settle 社區微水力發電
(www.sciencedirect.com/science/article/abs/pii/S0301421513013104)

現場特性資料蒐集、按特性選擇水力發電機組、安裝後對水流環境影響，並建議機組效率提高的同時，亦要考量環境影響，才能有最佳化的電廠建置。

- Ali 等人^[11]因大型水力電廠對環境的負面影響受到批評，所以研究小水力發電是否可以實現永續發展，其利用 GIS 結合 SWAT 水文模型對 U-Tapao 河進行了小水力理論潛能量評估。沿著 77.18 公里的 U-Tapao 河，小水力潛能量估計為 71.9 MW，可開發為生活在河邊的社區的可再生和可靠能源。
- 透明度市場研究公司^[12] (Transparency Market Research, TMR) 推算至 2023 年小水力發電將達 146.65 GW。近年來，中國、印度、日本、巴西、土耳其、奧地利、美國、英國等均投入於水力能源的開發，小水力發電在全球擁有巨大的市場潛力，需求量也持續增加中。其中中國和印度均制定了農村大規模電氣化計畫，以提升農村的經濟與產業發展，同樣地，未來小水力發電在菲律賓、馬來西亞、越南等東南亞國家，隨著經濟發展帶動水電的需求，小水力發電的發展前景亦十分樂觀。而在美國、加拿大與俄羅斯，這樣小型的再生能源系統可以應用於山區或偏遠地區，作為穩定供電來源，所以市場也正在擴大。歐洲各國在減緩氣候變遷的調適策略中，再生能源的開發是很重要的一環，加上社區自主意識的提升，以社區為主導的小水力發電正快速增加中。

國內小水力發電發展

本研究亦對國內小水力文獻進行回顧，列舉數篇重要論文及計畫，以呈現目前國內小水力發電的進展與成果：

- 黃育新^[13]分析了小水力發電廠進入到台電公司的配電系統後之系統衝擊，以台中某一小水力發電廠為分析對象，併入 11.4 kV 配電網路後，模擬結果顯示小水力發電機的併網容量對主變壓器一次側短路容量的比值與影響程度呈正比，不可過高；併網後饋線沿線電壓普遍上升可降低配電損失；台電規範同步發電機併網後最大併網容量限制以電壓變動率 5% 內為準，可再討論。
- 張登平^[14]針對花蓮農田水利的灌溉圳路進行小水力發電的開發經營可行性評估，於太平渠松浦跌水工具有 300 kW 的發電潛能，年發電量約 1,656,000 度，益本比大於一。惟推動上存在多個風險因子，包括：多角化經營法源、水權確定、渠道流量確定、營建物價變

化、環保議題、躉購電價及年限等，須待進一步討論。

- 河村禎彥^[15]評估於陽明山國家公園既有水系設立小水力發電，可供遊客中心、生態教育中心等有建築物之一至三成的用電量，形成山區供電網路之一環，增加供電彈性及穩定。
- 陳翰升^[16]應用地理資訊系統，結合 QGIS、HEC-HMS、HEC-RAS 評估集水區內小水力發電最佳場址，並利用 HSI 指標評估小水力對生態環境之影響。應用於南投北港溪流域的理想化評估結果顯示：最大潛能容量為 132.17 MW，已全部設置落差型小水力發電廠，電廠距離為 1,500 公尺以上為最佳。惟實務上仍有諸多困難，可行性需進一步檢視。
- 經濟部水利署^[17]對河川及供排水渠道發展小水力發電進行評估，提出 47 處河川小水力場址及 30 處灌渠小水力場址，而河川小水力機電設備費佔總成本之 11.1% ~ 36.5%，灌渠小水力機電設備費佔總成本之 27.8% ~ 79.1%，變動幅度極高，須個案進行檢視。而台灣國內目前小水力發電設備主要應用於河川與灌溉渠道之發電機組，以及工業循環系統之發電機組^[18]。
- 經濟部國營事業委員會^[19]於 2016 年委託中興工程顧問公司進行一個四年期的研究計畫，針對台灣北區、中區、南區，優選出 20 處小水力發電潛能場址，並進行發電機組可行性規劃，依一、二、三期順序，完成各期的小水力計畫可行性研究報告。該計畫研究利用現有水利設施，包括水庫堰壩、水力電廠、灌溉渠道等輸排水管道，由台電公司投資興建設置小水力發電機組的可行性，供台電公司據以整合後分區推動。
- 現階段，台灣商轉中的小水力發電廠共有 30 座，裝置容量總計為 152.2 MW，相關資料整理如表 1 所示。按電廠型式主要分為川流式、調整池式、水庫式三類，並以川流式為大宗。水輪機型式多樣化，有卡布蘭式、貫流式、法蘭西斯式、軸流式等，依電廠所在區域特性及施工廠商設計而有所不同。發電機組裝置容量介於 110 ~ 18,000 kW 間，裝置容量最大者為圓山機組、名間發電廠、桂山機組，已接近小水力的上限裝置容量 20 MW；裝置容量最小者為后里示範機組、軟橋機組，裝置容量小於 230 kW，所以即使都是小水力發電廠，規模可差異到 1,000 倍以上。從興建的過程來看，台灣的小水力主要是由台灣電力公司進行開發、設廠與維運，直到 1990 年以後才開始有民間企業投入小水力領域，只是裝置容量均較小，目前的小水力發電還是以台灣電力公司為主。不過可

表 1 國內商轉中小水力發電廠

電廠	區域	水源	興建年份	水輪機型式	裝置容量 (kW)	電廠型式	管理單位
粗坑機組	新北市新店區	新店溪	1907	豎軸卡布蘭式	5,000	川流式	台電公司
后里機組	台中市后里區	大安溪	1908	橫軸法蘭西斯式	940	川流式	台電公司
竹門機組	高雄市美濃區	荖濃溪	1908	橫軸卡布蘭式	2,670	川流式	台電公司
軟橋機組	新竹縣竹東鎮	上坪溪竹東圳	1919	貫流式	230	川流式	台電公司
北山機組	南投縣國姓鄉	南港溪	1919	橫軸法蘭西斯式	4,320	川流式	台電公司
六龜機組	高雄市六龜區	荖濃溪	1919	橫軸法蘭西斯式	4,500	川流式	台電公司
濁水機組	雲林縣林內鄉	濁水溪	1921	豎軸卡布蘭式	3,670	川流式	台電公司
社寮機組	台中市石岡區	大甲溪	1921	橫軸法蘭西斯式	945	川流式	台電公司
天埤機組	宜蘭縣三星鄉	蘭陽溪	1921	橫軸法蘭西斯式	8,375	川流式	台電公司
清水機組	花蓮縣秀林鄉	木瓜溪	1936	橫軸法蘭西斯式	6,000	川流式	台電公司
初英機組	花蓮縣吉安鄉	木瓜溪	1938	卡布蘭式	2,000	川流式	台電公司
溪口機組	花蓮縣壽豐鄉	壽豐溪	1938	橫軸法蘭西斯式	2,700	川流式	台電公司
桂山機組	新北市新店區	南勢溪	1939	豎軸法蘭西斯式	13,000	調整池式	台電公司
圓山機組	宜蘭縣三星鄉	蘭陽溪	1939	豎軸法蘭西斯式	18,000	川流式	台電公司
東興發電廠	台東縣卑南鄉	利嘉溪	1941	豎軸法蘭西斯式	800	川流式	台電公司
榕樹機組	花蓮縣秀林鄉	木瓜溪	1965	豎軸卡布蘭式	2,700	川流式	台電公司
水簾機組	花蓮縣秀林鄉	木瓜溪	1982	豎軸法蘭西斯式	9,500	川流式	台電公司
龍溪機組	花蓮縣秀林鄉	木瓜溪	1983	橫軸法蘭西斯式	4,700	川流式	台電公司
后里示範機組	台中市后里區	大安溪	1986	貫流式	110	川流式	台電公司
卑南上圳小型發電廠	台東縣卑南鄉	鹿野溪	1990	橫軸法蘭西斯式	2,200	川流式	聚電企業開發公司
水里機組	南投縣水里鄉	水里溪	1991	豎軸法蘭西斯式	12,750	川流式	台電公司
烏山頭水力發電廠	台南市官田區	官田溪	2000	豎軸卡布蘭式	8,750	水庫式	嘉南實業有限公司
名間水力發電廠	南投縣名間鄉	濁水溪	2004	豎軸卡布蘭式	16,700	川流式	名間水力公司
西口水力發電廠	台南市東山區	曾文溪	2004	豎軸法蘭西斯式	11,520	川流式	嘉南實業有限公司
八田水力發電廠	台南市官田區	官田溪	2012	豎軸軸流式	2,196	水庫式	嘉南實業有限公司
關山圳水力電廠	台東縣海端鄉	關山圳	2016	豎軸卡布蘭式	1,000	川流式	經一綠能公司
景山分廠	苗栗縣卓蘭鎮	景山溪	2017	豎軸法蘭西斯式	4,000	水庫式	台電公司
二水 N19 水力電廠	彰化縣二水鄉	濁水溪	2018	直立川渠式	480	川流式	經一綠能公司
湖山機組	雲林縣古坑鄉	清水溪	2019	橫軸法蘭西斯式	1,950	水庫式	台電公司
牡丹小型水力發電廠	屏東縣牡丹鄉	牡丹溪	2020	橫軸法蘭西斯式	490	水庫式	南區水資源局

以發現，因著重民間企業對小水力的投入，近 10 年小水力發電廠的建廠數量有明顯增加，也顯示了台灣對於再生能源的積極投入，除了太陽能光電、風力發電以外，小水力發電也成為了國家邁向 2050 淨零排放的發展路徑之一 [20]。

最新小水力發電廠

苗栗景山小水力發電廠

景山小水力發電廠（卓蘭發電廠景山分廠，圖 3）位於苗栗縣三義鄉鯉魚潭水庫之下，該發電廠由台電公司與經濟部中區水資源局共同建置，設計水頭高為 81.7 m、引水量為 5.5 cms。水源來自鯉魚潭水庫，由取水工引水後，經既有的壓力鋼管，引流至水庫下游的半地下式發電廠房。廠內裝設一部斯洛維尼亞製豎軸法蘭西斯式水輪機，搭配捷克製豎軸交流式同步發電機，裝置容量為 4 MW，進行發電。發電後尾水放流回鯉魚潭水庫下游，年發電量約 1,400 萬度，每年可減少約 7,200 公噸的二氧化碳排放量。

景山小水力發電廠採無人駐廠，由位於鯉魚潭水庫上游的卓蘭發電廠作為遠端控制中心。近年來，由於大型水力發電計畫受到普遍的反對，因此台電公司順應世界潮流推動小水力發電，利用既有水利設施興建小型水力發電廠，節省開發經費的同時，對於環境影響也降低。

南投東光社區公民電廠

南投東光社區的小水力發電廠開發（圖 4）可分為兩階段，第一階段為 2019 年水利署輔導社區參與微水力發電，第二階段為 2023 年能源局示範獎勵社區公開募集設置再生能源公民電廠。

第一階段：東光社區附近有台灣電力公司向天圳，其明渠長約 770 公尺，水理條件穩定。向天圳渠道終年流水不斷，只有在武界壩排洪及排洪門維修期不能使用，因此成為水源保育社區設置微水力發電廠的首選社區。

東光社區微水力發電廠係川流式設計，水輪機採用橫軸式水車，水車葉片係來自南投區處的回收電力電纜

鐵捲筒，下接浮台是利用武界壩的回收不鏽鋼浮筒。整體設計融入循環利用的理念，以廢棄的台電用品回收再利用，除了屬於綠能外，進一步發揚回收再生、循環利用的核心價值。發電機裝置容量為 1,000 W，發出來的綠電結合綠能公園作為公共設施照明、電動自行車與手機座充等，結合環境教育及社區漫遊，為地方觀光創造新話題。

第二階段：東光社區周圍環境水資源豐沛，經專業團隊公民決議後，確定於將公民電廠建置在東光溪上游三號攔砂壩位址處。東光溪源自水社大山，由南向北流，為整個東光村用水之命脈，早期東光溪產大量土砂，為了降低水的能量及土砂所造成的問題，於溪上建有若干座攔砂壩；近年土砂量已大為降低，攔砂壩多成為遊憩戲水之場所。



圖 3 景山小水力發電廠現場照片



圖 4 東光社區向天圳小水力現場照片




圖 5 東光社區小水力公民電廠設計

考量水源之穩定性、施工便利性、安全性、環境影響等事項，並確立水源管轄單位、地權、水工結構物管轄單位後，進行小水力公民電廠的設計如圖 5 所示。在最小開發影響下，利用既有的壩體於上方增設倒伏堰以抬高水深。再引流至旁邊的引水道，進入阿基米德水輪機，推動水輪機旋轉後帶動發電機發電。

根據東光溪監測流量分析結果，電廠設計流量為 2.55 CMS，有效水頭為 4.2 m，設置電站用阿基米德水輪機，裝置容量可達 73.47 kW，電廠發電計畫詳表 2 所列。目前已完成電廠規劃、工程初步設計、財務規劃、土地水權饋線確認、社區居民投資合作意向書造冊等工作，獲得能源局第一階段示範獎勵，正持續推動第二階段：於社區設置再生能源發電設備。

台灣小水力發電推動建議

小水力發電係目前台灣正積極發展的第三大再生能源，政府也透過修法推動小水力發電並拓展其適用之型式與範圍。然，時值小水力發電正要蓬勃發展之前，本研究就資源、技術、法規、產業、觀念、金融等，略述推動上的建議，期能突破發展初期的瓶頸段，順利國家的綠色能源發展。

資源：目標水資源與再生能源的永續發展

小水力發電最特別之處即在同時整合了水資源與再生能源，唯有好的水源，才能有穩定的電源，有了永續的水與電才能帶來永續的文明發展。文明的發展，

表 2 東光社區小水力公民電廠發電計畫

發電計畫	發電方式	在槽式
	有效水頭	4.2 m
	使用流量_常時	2.55 cms
	裝置容量_常時	73.47 kW
	年預估發電量	509,592 kWh
	總計投資金額	23,488,830 元
設備概要	沉砂池	無
	壓力管	無
	退水路	無
	發電站	融入環境式
	水輪機形式	阿基米德水輪機

將帶動技術與產能的提升，再次投入到水資源與再生能源的開發與管理，最佳化且永續地使用，如此形成一個自動的正向循環，終而達成永續發展的目標。所以，這個目標必須在小水力發電推動之初，第一個開宗明義地敘明，以為後續所有工作的指引。

技術：建立科學化的監測與量能計算

欲發展小水力發電的第一步，是對全台的河川（中央管、縣市管、野溪）流量進行定期監測，並建立資料庫系統，長期穩定的蒐集這些必要的基本資料。而後擴展為河川小水力管理系統，建立科學化的小水力發電潛能評估方法，具體掌握河川各個時間與空間區段的發電潛能量。最後，應用至圳路、水道、管渠、排水等，做到全流域（只要有水在流動的地方）小水力管理系統。有了這些量能，才會有後續的電廠產出。

法規：建立行政單一窗口

現階段台灣已經從法規層面明確規劃了小水力發電，作為「推廣再生能源利用，增進能源多元化，改善能源結構，降低溫室氣體排放，改善環境品質，帶動相關產業及增進國家永續發展」的一項重要工作。後續的配套法規與措施即該建立起來，並應比照先前推動太陽能的成功模式，設立行政單一窗口，透過一站式的行政服務，讓國家帶動的能源轉型，可以順利拉動民間的企業投入，蓬勃產業的發展。

產業：建立民間小水力發電廠

和其它的綠色能源一樣，其發展都不是由國家去建立多個小型的綠能電廠（台電的主要工作還是大型的電力開發以維持大電網的正常運作），而是仰賴民間企業的大量投入，形成一個健全的產業鏈，才會造成處處綠能、百花齊放，由民間形成的分散式的、小型的、可收益的綠能電網。所以在小水力發展之初，政府應大力獎勵並協助建立民間小水力發電廠，直到確認為發展上了軌道。

觀念：建立綠色能源轉型教育

現在的電廠，無論大小，很難是單一單位或企業說蓋就蓋好的，會關連到政府、企業與地方三者間的溝通與配合，再形成共識，而後轉變為觀念，一個綠色能源的觀念（這在歐洲國家以普遍內化為國民的基本素養）。所以要建立綠色能源轉型教育，透過教育系統，讓民眾改變過去全台一張網，停電罵台電、罵政府的觀念，而變成我們可以自主選擇使用綠色能源，還可以自主建立小型的綠色能源電廠，作為我們所要使用的電力來源。太陽能的发展已經產生了部分這樣的教育效益，小水力發電是可以全流域的開發，將更全面的推展能源轉型的教育。

金融：建立綠色金融體系

上述所有工作實際執行時，都需要資金，充足的資金。國家可以編列預算，民間則是需透過金融體系去投資，所以整體，從上到下，都應加速建立綠色金融體系。仿效德國，從法律、財政與金融上，對綠色能源直接支持，徹底落實能源轉型。德國從 2000 年的「再生能源法」至今，已經過了 23 年，綠色能源占比終於達到 50%。台灣，現在出發，可以在前人的經驗

與自身的特性下，找到合適自己的再生能源之路。小水力發電，即是國家邁向 2050 淨零排放的重要路徑，也是整合了水資源與再生能源，帶動國家朝向永續發展的重要策略。

參考文獻

1. World Small Hydropower Development Report (2019). United Nations Industrial Development Organization.
2. 劉宏仁、李方中（2019），國內外小水力電廠發展趨勢，台灣環境季刊，第 176 期，第 40-45 頁。
3. stockport-hydro.co.uk
4. Anderson, E.P., Freeman, M.C., and Pringle, C.M. (2006). Ecological consequences of hydropower development in Central America: impacts of small dams and water diversion on neotropical stream fish assemblages. *River research and applications*, 22(4), 397-411.
5. Csiki, S. and Rhoads, B.L. (2010). Hydraulic and geomorphological effects of run-of-river dams. *Progress in Physical Geography*, 34(6), 755-780.
6. Punys, P., Dumbrasukas, A., Kvaraciejus, A., and Vyciene, G. (2011). Tools for small hydropower plant resource planning and development: A review of technology and applications. *Energies*, 4(9), 1258-1277.
7. Kaunda, C.S., Kimambo, C.Z., and Nielsen, T.K. (2012). Hydropower in the context of sustainable energy supply: a review of technologies and challenges. *International Scholarly Research Notices*.
8. Bracken, L.J., Bulkeley, H.A., and Maynard, C.M. (2014). Micro-hydro power in the UK: The role of communities in an emerging energy resource. *Energy Policy*, 68, 92-101. doi:10.1016/j.enpol.2013.12.046
9. McManamay, R.A., Oigbokie, C.O., Kao, S.C., and Bevelhimer, M.S. (2016). Classification of US hydropower dams by their modes of operation. *River Research and Applications*, 32(7), 1450-1468.
10. Sood, M. and Singal, S.K. (2019). Development of hydrokinetic energy technology: A review. *International Journal of Energy Research*, 43(11), 5552-5571.
11. Ali, F., Srisuwan, C., Techato, K., Bennui, A., Suepa, T., and Niammuad, D. (2020). Theoretical hydrokinetic power potential assessment of the U-Tapao River Basin using GIS. *Energies*, 13(7).
12. www.transparencymarketresearch.com/small-hydropower-market.html
13. 黃育新（2009），小水力發電廠與配電系統互連之系統衝擊分析，國立臺灣科技大學電機工程系碩士論文。
14. 張登平（2011），花蓮農田水利會開發經營小水力發電之可行性研究—以太平渠松浦跌水工為例，國立屏東科技大學農企業管理系所碩士論文。
15. 河村禎彥（2019），探討小水力發電應用於建築之研究—以陽明山建築物為例，國立臺灣科技大學建築系碩士論文。
16. 陳翰升（2022），應用地理資訊系統評估集水區內小型水力發電最佳場，國立臺灣大學工程學研究所碩士論文。
17. 經濟部水利署（2008），河川及供排水渠道發展小水力發電潛能評估及可行性先期研究。
18. 經濟部水利署北區水資源局（2015），石門水庫及寶山第二水庫附屬設施小（微）水力發電潛能評估。
19. 經濟部國營事業委員會（2018），全台小水力發電計畫可行性研究。
20. 國家發展委員會（2022），臺灣 2050 淨零排放路徑及策略總說明。



美濃溪上游段以 **自然為本** **在地滯洪** 解決淹水方案

邱昱嘉*／國立臺灣海洋大學河海工程學系 助理教授

游景雲／國立臺灣大學水工試驗所 主任、國立臺灣大學土木工程學系 教授

塗宗明／國立臺灣海洋大學河海工程學系 研究助理

王澤琳／國立臺灣海洋大學河海工程學系 研究助理

溫仲良／美濃農村田野學會 執行理事

美濃地區於 107 年 8 月 22 日豪雨（0822 豪雨）時，美濃溪過路窩橋上游發生溢淹情形，造成美濃三洽水至廣興一帶，道路、農地及住戶之淹水災情。雖然美濃溪主流已依治理計畫完成工程，但下游河段兩岸堤防緊鄰民宅，要拓寬河道不易，工程方法有其極限，對於超過保護標準的颱風豪雨事件，仍有造成積淹水的風險。

面對極端氣候劇烈變化以及因應都市急遽發展，為維持水道治理之永續，且不只著眼以人為設施容納超額逕流量，將原本全部由水道承納的降雨逕流，調整為水道與土地共同來分擔，要求土地與建築物須共同分擔滯洪、蓄水責任，以提高土地整體耐淹能力，達成韌性國土的目標。符合以自然為本的解決方案（Nature Based Solution, NBS）精神，提出「在地滯洪」非工程策略理念，以高程管理及逕流分擔方法，就排水集水區附近之易淹水農田區，將可耐淹之農田區域劃入洪泛區，並適當利用田埂加高等方式，以源頭蓄留策略，允許雨水先暫留農田，避免太多雨水逕流快速集中於渠道，分擔逕流以減輕保全對象（村落）之淹水災害。

根據 112 年 07 月 25 日杜蘇芮颱風事件滯洪操作面積為 735,000 平方公尺，以現場量測平均積水深度 20 公分計算，其可暫存 147,000 立方公尺水量，削減流量約為 1.70 cms，美濃橋降低水位約為 0.11 m，顯示在地滯洪能達逕流分擔削減洪峰流量之功效。

關鍵詞：美濃地區、以自然為本的解決方案、在地滯洪

前言

受到都市化效應及氣候變遷的影響，造成地表逕流大量增加而現有的雨水下水道系統及河川常無法負荷超出設計標準的雨量，發生洪災的機率及程度加劇。然而，受限於工程經費、土地取得等問題，要藉由增擴建雨水下水道、區域排水、或河川通洪及加高堤防等防洪工程來改善淹水問題受到許多限制，鑑於

所有的水利設施及防洪工程建設，僅能提供一定程度的保護作用。因此，傳統的治水思維必須有所突破，如何從以往侷限於單一水道內之治水思維，透過流域概念，導入逕流分擔、風險評估及在地滯洪等策略，基於總合治水概念（integrated flood management）整體規劃流域防洪策略。

近年來以自然為本的解決方案（Nature-based Solution, NBS）廣為討論並應用於淹水改善^[1]，利用「土地規劃」與「工程設計」藉以削減暴雨逕流

* 通訊作者，yjchiu@mail.ntou.edu.tw

量。NBS 在 2008 年被國際自然保育聯盟（International Union for Conservation of Nature, IUCN）提出，主要是指在因應如氣候變遷、糧食安全、水安全、人民健康等社會挑戰的對策上，可使用較自然的方式達到永續利用並有效的災害風險管理，同時增進人類福祉與生物多樣性。IUCN 提出的 NBS 定義為「以保護、永續管理及復育自然的與被改造的生態系統之行動，可有效地及調適地因應社會挑戰，同時為人類福祉和生物多樣性帶來效益。」目前全球有許多 NBS 推行之案例，例如荷蘭因地形易淹水，因此從以往的填海造陸，至今試著與水共存，例如 Nijmegen 地區因鄰近 Waal river，時常受淹水困擾，因此將原本河道最窄處由 450 公尺擴大到 800 公尺，將堤防後移，使洪泛平原在洪水來臨時再次氾濫，降低人民的生命與財產損失^[2]。

台灣先前通過修正水利法部分條文，新增「逕流分擔與出流管制專章」，要求土地與建築開發者共同分擔滯洪、蓄水責任，以提高土地整體耐淹能力，目前整體概念已改進為以水系為單元進行綜合治水策略的易淹水地區水患治理模式。逕流分擔主要目的為避免現況之土地利用型態超過現有水利設施之負荷。概念上以逕流抑制、逕流分散、逕流暫存、低地與逕流積水共存之原則，以工程方法及非工程方法輔以避災措施等綜合運用達成。

在各項原則方法中，技術上或實務上較具挑戰性的為逕流暫存措施，其主要牽涉到兩個面向的問題，其一為其蓄流機制為何，其二為空間上之配置策略及對於水文時序特性影響。除都會區之外，非都會區有一定的操作使用性，因此「在地滯洪」也為近年來常討論的概念，以農地或其他空間作為分散式滯蓄洪或短期洪泛區的概念操作。過去國外均有類似案例，歐美有提出天然或農地滯洪的相關概念^[3-7]。相同的，其配置策略、規模大小與效果常為探討分析的重點。日本從 2007 年也開始透過各學術機構來推動各項相關的研究計畫，其成果指出透過水田、旱田排水缺口的修改將可強化原本水旱田的滯洪機能，大幅降低排水路尖峰流量，藉以明顯減少下游地區的淹水風險^[8]。

在臺灣，有時調度農業用水藉以供民生和工業用水之用，而農民也可能因應氣候的關係，調整原本的耕作型態。思考如何結合農業以發揮「在地滯洪」的機能，透過水文水理特性的瞭解，強化相關機制，尋找因地制宜的策略，故經濟部水利署從 99 年至今，嘗試透過推動逕流分擔及在地滯洪政策，希冀就源處理，提升下游防災韌性^[9-13]。因此擇定高雄市美濃區過路窩橋下游右岸約 3.96 公頃土地推動示範在地滯洪（如圖 1），分析淹水改善效益，同時促進在地農民共同參與，希冀未來於在地產業與減少水患威脅能共依存。



圖 1 在地滯洪示範區位置圖

推動地點背景資料彙整分析及評估

美濃溪流域近年受氣候變遷及都市土地高度發展，致使淹水事件頻傳，以 107 年 0822 豪雨為例，美濃溪於過路窩橋上游發生溢淹情形，造成美濃三洽水至廣興一帶淹水災情。主要淹水原因為連續三小時強降雨，瞬間強降雨超過區域排水路所能負荷範圍致使美濃湖排水局部溢淹，竹子門排水水位亦高漲，都市內水無法排出，造成局部道路地區及低窪地區積水，經統計美濃區淹水面積達 17.2 公頃、深度約 50 ~ 100 公分。雖然美濃溪治理工程已依 94 年公告之治理計畫辦理完成，但對於超過保護標準之颱風豪雨事件，仍會有溢淹風險，然而受限河道兩岸土地利用，難以河道拓寬等治理手段再增加河道通洪斷面。由前述淹水事件、成因可知美濃溪流域上游段多為易淹水區域，每當豪雨來臨時，不論參與在地滯洪與否，該區域具有高機率與高風險的淹水問題。因此若能透過獎勵方式讓原容易淹水之農地能兼顧原有的功能並附加滯洪操作，將過往快速排水轉變為蓄積洪水加以利用，更能賦予農地新價值與新思維。

統整農業政策規定可知其相關獎勵辦法取決於「種植農作物種類」而定，而在地滯洪獎勵辦法建立在蓄存「水體容量」與「水深高度」，無關農作物型態，因

此在政策上彼此獎勵辦法並不衝突，可與在地滯洪政策雙軌並行。

美濃區農作物豐富，但並非所有農作物皆適合推廣在地滯洪工作，因此須了解主力作物生長特性，逐一確認其位置及權屬，並繪製成圖，其篩選評估步驟為：(1) 農作物耐淹特性評估（見圖 2）；(2) 美濃溪流域上游農田易淹水區域共有 346 公頃，因此先以土地利用型態進行盤點（見圖 3）；(3) 由現有土地利用圖配合農作物資料篩選出耐淹作物位置（見圖 4）及 (4) 現場作物勘查了解實際作物種植種類用以佐證（見圖 5），即可選定優先推廣之實際區域。針對現階段美濃區農主力作物特性進行評估耐淹程度，其中以野蓮、水稻兩種作物耐淹程度最佳。

在地滯洪推動方法及優化

辦理座談會及資訊公開

參考經濟部水利署各河川分署在地諮詢小組設置及作業注意事項^[14]，需釐清在地滯洪之相關利害關係人，由各不同立場點論述各自關心與看法，以完整瞭解在地滯洪議題於執行上遇到的實際課題。圖 6 係在地滯洪應探討利害關係人，提供說明輪廓。整體而言，利害關係者可劃分為由上而下之政策決策或執行者，包含水



圖 2 高雄市美濃區主要作物耕作曆

資料來源：高雄市美濃區農會推廣部




圖 3 美濃溪上游流域推動在地滯洪農田範圍之土地利用圖



耐淹作物



汛期農地維護(休耕)作物

圖 5 現場作物盤點確認




圖 4 美濃溪上游流域推動在地滯洪農田範圍之耐淹作物初篩




圖 6 在地滯洪議題中利害關係人

藉由座談會形式，邀請當地民眾、利害關係者一同參與，以簡單明瞭的文字圖說方式，讓參與者瞭解實際淹水成因及說明在地滯洪政策，蒐集專業者及民眾對於在地滯洪政策推動、可改善的地方、防災補貼機制以及可行性，瞭解在地滯洪推動執行時可能面臨困難，並聚焦各利害關係人的共識。透過座談會建立跨領域溝通平台，為後續推動政策奠定基礎並讓資訊公開化（見圖 7）。

利署、第七河川分署及水利規劃分署，以及由下而上之受政策影響者，例如耕種農民、政策實施區域民眾及民間 NGO 團體等兩大類型。



(a) 說明會



(b) 意願調查



(c) 獎勵金發放



(d) 即時監測系統展示

圖 7 說明會、意願調查、獎勵金發放、與即時監測系統展示

研提整體改善方案

透過綜合水利單位、地方農政單位、中央農政單位、在地 NGO 團體多次與會，在地滯洪推動改善方案如下：

● 以貼近農民熟悉語言溝通在地滯洪政策

綜合水利單位、農政單位、NGO 團體、地方農民訪談會議，為能以貼近農民語言的宣傳方式來宣導，提高農民認同感，以農民熟悉的語言說明參與在地滯洪工作權益與義務並以「農地種水」為口號推動。

● 推廣目標

避免造成農民損失降低農民意願，以「一期水稻 + 二期養地蓄水 + 三期高經濟作物」或「水耕作物 - 野蓮」種植模式為推廣目標，以期順利推動。

● 滯水操作時間

滯水操作時間以汛期搭配農民休耕期間 5 月 1 日 ~ 9 月 30 日為主，其餘時間為整備和演練工作，如遇大雨則採自主性操作。

● 推廣期間田埂免費健檢及施作

依作業要點規定在地滯洪之相關滯洪及排水措施由實際耕作者辦理，並負擔相關費用，為求在地滯洪政策順利推動，因此推廣期間田埂（土埂）免費健檢及施作，提高農民參與意願。

後續「適用於美濃區」推行在地滯洪優化建議

● 田埂施作優化

田埂施作非一次作業即可造出堪用的滯水高度，且構築田埂需仰賴當地天氣條件方能施作，建議後續逐年田埂健檢、施作，並評估覆上防草黑布的可行性。

● 野蓮池溢流管、水稻田 PVC 管製作。

野蓮池蓄水以四吋或六吋 PVC 管增加蓄水高度；美濃區農地經重劃後皆以 PVC 管來作為出水孔，因此建議後續施作田埂時，若需額外建置出水孔，則統一以 PVC 管建置之。

● 路堤方案結合緩衝綠帶營造

為兼顧「治水」、「利水」、「親水」及「活水」之機

能，積極對水路空間多元化利用，提高在地文化與生活價值，建議路堤方案結合緩衝綠帶營造，以提供休憩且兼顧防洪治理所需水岸空間。

• 期程規劃

建議後續在地滯洪推動工項時程可依據美濃農民耕作圓環圖（見圖 8），配合農民耕作期程，符合農民平日作息習慣。於一月至三月進行用地協商及簽訂契約，四月進行田埂現勘功能健檢、修繕及施作，但四月份在水稻生長階段，需與農民協商，施作田埂容易導致小範圍農作物受損，須注意施作時的影響。五月汛期開始，進行滯水操作演練，讓農民熟悉滯水操作及拍照回傳機制。六月到九月，進入休耕轉作期間，農民需要配合預報進行滯水操作，並於降雨事件後進行田埂檢修及確認田菁存活率以發放備用田菁種子。經過實際滯水操作後，蒐集農民操作意見，進行滾動檢討。十月進入美濃區第三期作，颱風事件較少，適合再進行滯水操作演練，以增加未來農民操作熟悉度，並根據汛期農民操作情形，於十一月發放滯水獎勵金。因應隔年度持續推動，於 12 月進行總檢討，彙整推動遭遇困難並滾動調整推動對策。

在地滯洪示範區監測及成效分析

透過自記式水位計量測颱風期間之現地資料，時間間距 10 分鐘紀錄在地滯洪示範區之滯水歷程，且避免颱風期間淹水造成無法進入示範區域，故現況拍攝

採用 CCTV 即時影像監控如圖 8 所示，以掌握示範區域淹水深度及範圍，作為滯洪成效驗證。其中 A 點為記錄美濃溪水位，B 點為農田水稻區，C 點為野蓮區，D 點則為竹林區。

111 年 8 月 6 日盧碧颱風事件 48 小時最大降雨為 311 毫米，接近 2 年重現期距降雨（367 毫米）。滯洪歷程（現場照片）如圖 9 所示。農田區維持蓄滿狀態、水蓮池水位些微上升、竹林區則水位無明顯變化（仍維持蓄存部分水量）。依據現地情況可以得知農田區皆已蓄滿水位，而野蓮池、竹林區亦發揮蓄水功能，整體滯洪面積約為 39,661 平方公尺，若以現場量測平均積水深度 30 公分而言，其可暫存 11,898 立方公尺水量。經由現地觀測蓄滿時間約為 24 小時，因此削減流量約為 0.14 cms，此次降雨事件集中降雨量有達到短延時強降雨之大雨標準，搭配在地滯洪操作美濃溪主河道尚能負荷，未有淹水災情傳出。

112 年 7 月 25 日杜蘇芮颱風事件滯洪操作面積為 735,000 平方公尺，以現場量測平均積水深度 20 公分計算，其可暫存 147,000 立方公尺水量，削減流量約為 1.70 cms，美濃橋降低水位約為 0.11 m，顯示在地滯洪能達逕流分擔削減洪峰流量之功效。

結論與未來在地滯洪推動建議

依照水稻與滯水高度影響文獻顯示滯水高度對於水稻產量、品質皆有影響，為了解在地滯洪政策是否



圖 8 過路窩橋在地滯洪示範區壓力式水位計、CCTV 安裝位置



圖 9 111 年 08 月 06 日盧碧颱風事件－滯水歷程

影響水稻品質及產量，故必要進行農作物損害試驗，以了解田埂加高蓄水對於農作物損害程度，建議針對經濟部水利署暨所屬機關辦理在地滯洪獎勵及補償作業要點中滯水（田埂）高度 25 公分、50 公分及 75 公分，進行不同株高單一淹水、連續淹水及病菌擴散試驗，根據判釋水稻品質及產量，建置相關量化的科學數據提供日後水稻保險規劃參考依據。

美濃區在休耕期間（野蓮除外）推廣在地滯洪，雖然不會造成農作物損失，但可能會影響田菁存活率，導致後期驗收不通過情況發生，因此建議預備田菁種子提供補發，來維持田菁存活率。

考量每年度颱風事件無法預測是否侵襲台灣，為讓在地滯洪之滯水操作常規化，依據美濃區農耕習慣，建議每年 5 月（汛期前）、9 月（汛期後）擇期進行滯水操作演練，避免日後颱風豪雨因操作不熟悉導致無法發揮應有滯水功能。亦建議可辦理成果展示會，除宣傳滯洪成效，亦表揚相關人員，藉此提升農民長期參與意願及擴大民眾對此政策之認知與認同。

參考文獻

1. Chou, R.-J. (2016). Achieving Successful River Restoration in Dense Urban Areas: Lessons from Taiwan, *Sustainability*, **8**, 1159.
2. Siyu Yu, A. D. Brand, Philip Berke. (2020). Making Room for the River, Applying a Plan Integration for Resilience Scorecard to a Network of Plans in Nijmegen, The Netherlands. *Journal of the American Planning Association*, **86**(4).
3. Antolini, F., Tate, E., Dalzell, B., Young, N., Johnson, K., and Hawthorne, P.L. (2020). Flood Risk Reduction from Agricultural Best Management Practices. *JAWRA Journal of the American Water Resources Association*, **56**(1), 161-179.
4. Burek, P., Mubareka, S., Rojas, R., de Roo, A., Bianchi, A., Baranzelli, C., Lavalley, C., and Vandecasteele, I. (2012). Evaluation of effectiveness of natural water retention measures. *JRC Report*.
5. Collentine, D. and Futter, M.N. (2018). Realising the potential of natural water retention measures in catchment flood management: Trade offs and matching interests. *Journal of Flood Risk Management*, **11**(1), 76-84.
6. Löschner, L. (2019). Commentary: A Spatial Planning Perspective on Privately Funded Natural Water Retention Measures. In *Nature-Based Flood Risk Management on Private Land* (pp. 77-81). Springer, Cham.
7. Mubareka, S., Estreguil, C., Baranzelli, C., Gomes, C.R., Lavalley, C., and Hofer, B. (2013). A land-use-based modelling chain to assess the impacts of Natural Water Retention Measures on Europe's Green Infrastructure. *International Journal of Geographical Information Science*, **27**(9), 1740-1763.
8. 行政院國家科學委員會（2021），在地滯洪於台灣實行之初步可行性評估及實行策略探討計畫。
9. 經濟部水利署水利規劃分署（2021），有才寮排水在地滯洪擴大示範評估及實施方案。
10. 經濟部水利署水利規劃試驗所（2020），在地滯洪經濟效益分析。
11. 經濟部水利署水利規劃試驗所（2018），多功能滯洪空間運用與推動策略之研究。
12. 經濟部水利署第七河川分署（2020），高屏溪水系逕流分擔評估規劃（1/2）。
13. 經濟部水利署第七河川分署（2010），美濃地區設置滯洪池可行性評估。
14. 經濟部水利署各河川分署在地諮詢小組設置及作業注意事項。





探討 二重疏洪道之 通洪能力改善策略

吳湘琪* / 淡江大學水資源及環境工程學系 研究生
陳怡如 / 淡江大學水資源及環境工程學系 助理教授

疏洪道在城市防洪中具有分流洪水、減輕災害風險等重要功能。二重疏洪道位於臺灣北部，為大臺北地區關鍵的防洪設施，它能分流淡水河的洪水，減輕洪災風險。近年來，二重疏洪道內部增設許多人造設施供民眾使用，導致通洪量減少，並提高洪災風險。本文致力於為二重疏洪道研擬適當的改善策略，目標是透過清理疏洪道入口堰的淤積、改變疏洪道上游的植被，以及加深並擴寬中游的主渠道，提升整體的通洪能力，並減輕與洪水相關的損失。結果顯示，此策略能增加疏洪道的通洪量，並減緩流速，尤其在人造設施集中的區域，達到減少洪水淹沒範圍的效果。

關鍵詞：二重疏洪道、洪水管理、防洪策略

前言 緣起

疏洪道在洪水管理中扮演重要的角色，通常由一條或多條人工開鑿的渠道組成，這些渠道能夠快速且有效分散主河道部分的洪水，防止水流過多並積聚在上游地區，進而減少洪水的衝擊，主要用於保護社區、基礎設施和人民免受洪水威脅，對城市地區有重要的作用。臺灣的疏洪工程有二重疏洪道、員山子分洪道、曾文溪分洪道等，以上皆為臺灣在洪水管理方面的關鍵水利設施。透過疏洪道分流洪水，可以有效減少主河道的洪峰流量，防止水流超出河道容量，進而減少洪水對下游地區的影響。

然而，若疏洪道的狀況欠佳，會對河川和周邊地區造成莫大的影響，例如疏洪道底床淤積、堆積物阻塞、結構損壞等，這些不良狀況將加劇洪水風險以及對社區的威脅，因此定期維護、監測和修復是至關重要的工作，並確保疏洪道能正常運作，且有效地發揮作用。

在防洪工程規劃中，以底床疏濬和降挖為常見的增加斷面方法，不僅能增加流速和流量，並使洪水位降低，其優點亦包含降低堤防壓力及河道自然化。然而渠道因水流特性在凸岸和底床較高處易造成砂石淤積，必須定期進行疏濬或降挖工程，方能維持水體流動或可航性^[1]；近年臺灣有多項將防洪結合生態的水利工程，藉由疏濬營造自然感潮濕地，具備增加河川通洪能力和創造濕地棲地多樣性的效益，並將工程衝擊力轉換為復育能力^[2]。

二重疏洪道

二重疏洪道為一條位於臺灣北部的排洪道，自大漢溪、新店溪合流處為疏洪道入口，止於淡水河關渡一帶，其主要功能為分流淡水河洪水，減少淡水河在洪水來臨時所面臨的壓力，為臺灣北部重要的防洪工程。二重疏洪道近年在內部增設許多人工設施，其中占地最大的是「新北都會公園」，包含遊樂設施、步道、籃球場、停車場等，多集中於上游，平時作為民眾休憩、運動場所，在颱風或強降雨事件發生時，會將疏洪道封鎖並限制人員進出，啟動二重疏洪道的分洪功能，但依二

* 通訊作者，612480037@o365.tku.edu.tw

重疏洪道通洪能力重新檢討總報告^[3]指出，入口堰標高自 EL.3 m 淤積至 EL.4 m，洪水不易進入疏洪道進行分洪，導致分洪量下降，而面臨 200 年重現期的洪水事件時，通洪量只有 6,500 cms，遠不及原始設計通洪量 9,200 cms，兩者比較後約減少 30%，導致某些區域出水高不足及多處溢堤，對大臺北地區的防洪效果有相當大的影響，將造成多處淹水與災損。

根據敏感性分析的結果，有五種情境會引發淡水河洪水難以宣洩：(1) 二重疏洪道河床淤積 (2) 淡水河河床淤積 (3) 二重疏洪道或淡水河河床粗糙度增加 (4) 重現期 200 年洪水量增加 (5) 河口水面水位升高^[4]，欲解決上述問題可以利用疏濬和降低河床粗糙度等方式，降低粗糙度的方法包括改變植被類型、覆蓋率、密度、高度，並減少人造設施等因素。Shih and Chen 的研究指出二重疏洪道在完全清除植被的情況下，通洪量約可以增加 571 m³/s，且移除上游和中游的樹木會產生最顯著的效果^[5]。

本文依二重疏洪道目前面臨的問題設計改善計畫，並保留部分民眾活動空間，旨在建立一套兼顧防洪、減災、遊憩、提高疏洪道效能的方案，作為二重疏洪道或其他河川、渠道改善工程之參考案例。

研究方法

斷面資料

本研究使用之二重疏洪道斷面採淡水河（含大漢溪、疏洪道、三峽河、橫溪）大斷面測量計畫測量成果報告書^[6]，測量斷面位置圖見圖 1。二重疏洪道測量斷面自上游至下游依序為 F012、F011、F010、F009A、F009、F008A、F008、F007、F006、F005A、F005、F004、F003、F002、F001，共 15 個斷面，F011 為入口堰，F001 為出口閘門，斷面編號含 A 者表示橋梁，F009A 為重新橋，F008A 為中山橋，F005A 為中山高速公路橋，共 3 個橋樑斷面。

模式設置與驗證

本研究使用美國陸軍工程兵團所研發之 HEC-RAS 水理分析軟體，此軟體在國內經常用於分析河川、濕地的流況，包含水深、流速、洪氾區等，為確認本研究所建立之二重疏洪道模型具備高可信度，以二重疏洪道現地調查及數值水理模型建置工作^[7]使用的資料做為標準，如斷面位置、曼寧粗糙係數、邊界水位、




圖 1 二重疏洪道斷面圖

重現期 200 年的流量等，皆匯入 HEC-RAS 後將所得結果水位與上述報告書進行比較，各斷面水位比較結果見表 1，兩者誤差 1.20% 以下，準確率達 98.8% 以上。

表 1 各斷面水位誤差表

斷面編號	水規所模型水位 (m)	本研究建置模型水位 (m)	水位誤差百分比
F012	9.64	9.62	0.21%
F011	9.55	9.54	0.10%
F010	9.5	9.5	0.00%
F009A	9.14	9.21	0.77%
F009	8.83	8.89	0.68%
F008A	8.45	8.5	0.59%
F008	8.23	8.21	0.24%
F007	7.77	7.79	0.26%
F006	7.63	7.56	0.92%
F005A	7.68	7.62	0.78%
F005	7.6	7.53	0.92%
F004	7.48	7.39	1.20%
F003	7.4	7.34	0.81%
F002	7.37	7.31	0.81%
F001	7.2	7.2	0.00%

改善計畫

計畫簡述

本研究將二重疏洪道分為入口堰泥灘地、上游、中游三段分別進行改善計畫，入口堰泥灘地包含 F012、F011；上游段為入口堰至中山橋間，即斷面

F010 至 F008A；中游段為中山橋至永安大橋間，即斷面 F008 至 F005；下游為永安大橋至出口閘門間，即斷面 F004 至 F001，但因下游區域為四斑細蟥的棲息地，四斑細蟥被世界保育聯盟列為瀕危物種^[8]，故下游段不進行任何改善計畫。

入口堰清淤

二重疏洪道通洪能力重新檢討總報告^[3]、臺北防洪計畫（大漢溪、新店溪及二重疏洪道河段）清淤以維生態策略研擬^[8]及多項政府報告皆指出二重疏洪道入口堰因淤積使標高提升，進而影響分洪量，本研究將 F012、F011 之泥灘地清淤至原始標高 EL.3 m。

上游降低曼寧粗糙係數

二重疏洪道上游的新北大都會公園為最多人為建設之區域，河床表面粗糙度越大會導致洪水流速減緩、水位升高、洪氾區擴大，並造成損失及增加洪災風險，本研究考慮公園內遊樂設施多設置於疏洪道兩側，民眾活動較頻繁，並參考臺北防洪計畫（大漢溪、新店溪及二重疏洪道河段）清淤以維生態策略研擬^[8]中的開挖深槽方案範圍，左右岸堤前 80 m 之間區域（圖 2 中藍色區塊）做為本研究降低曼寧粗糙係數之區域，不僅保留兩側遊憩場所，亦能兼顧防洪效果。



圖 2 二重疏洪道上游改善範圍

圖片來源：經濟部水利署第十河川局，2018，臺北防洪計畫（大漢溪、新店溪及二重疏洪道河段）清淤以維生態策略研擬。

將上述區域中的人為設施（如：步道、移動式廁所、遊樂設施等）移除後種植矮短植物，可有效降低河床表面粗糙度，目前曼寧粗糙係數約為 0.027；平均植草高度 4 ~ 5cm 其對應之曼寧係數約為 0.017 ~ 0.019，平均植草高度 10 ~ 12 cm 其對應之曼寧係數約為 0.024 ~ 0.028^[9]，臺灣常見矮短植物之高度及曼寧粗糙係數見表 2，曼寧 n 值依不同植被高度參考上述報告進行線性插值法（Linear Interpolation）所得之，咸豐草為二重疏洪道常見的植物^[10]，故本研究以咸豐草做為改善區域的植被，曼寧粗糙係數約為 0.0202。

表 2 臺灣常見地被植物及曼寧 n 值

植物名稱	高度 (cm)	曼寧 n 值
臺灣天胡荽 (遍地錦)	3 ~ 5	0.0174
馬蹄金	5	0.0186
黃花酢漿草	1 ~ 7 (平均 4)	0.0174
咸豐草	4 ~ 8.5 (平均 6.25)	0.0202
蠅翼草	4 ~ 10 (平均 7)	0.0211
四瓣馬齒莧	5 ~ 10 (平均 7.5)	0.0217
假吐金菊	10	0.0248
伏生大戟	10	0.0248
雷公根	10 ~ 12	0.0260

河床降挖

二重疏洪道中游段橫斷面包含 F008、F007、F006、F005A、F005，共五個斷面，其中斷面 F005A 為橋梁，考慮此斷面有橋墩設置，開挖河床將影響橋樑安全性，故斷面 F005A 不進行降挖設計，其餘斷面依照既有渠道進行拓寬，或將數個小渠道合併為一條較大之渠道，亦將深度設定為原有渠道之最低高程，做為二重疏洪道中游改善計畫。斷面 F008 自測量定位點 176.31 公尺至 222.72 公尺及 321.03 公尺至 332.07 公尺處分別為寬度 46.41 公尺和 11.04 公尺之渠道，最低高程為 EL.-0.33 公尺，本降挖計畫將此斷面之兩條渠道合併，即始於距離 176.31 公尺，止於 332.07 公尺，計算後寬度為 155.76 公尺，亦將此範圍內高程統一降挖至 EL.-0.33 公尺，形成一條寬且深的渠道，可有效增加通水斷面積，降挖示意圖見圖 3。其餘 F007、F006、F005 斷面以 F008 斷面作為基準，向下游的方向規劃一條寬度 155.76 公尺，最低高程依各斷面既有深度，為 EL.-0.96 至 EL.-0.33 之渠道，此渠道之曼寧 n 值依原有主河道為設計，本中游改善計畫有效增加中游段之通水斷面積，進而使水位降低，增加通洪量。各斷面降挖起始點、終止點、寬度、深度見表 3。




圖 3 F008 斷面降挖示意圖

表 3 中游斷面降挖距離深度表

斷面編號	降挖起始點 (m)	降挖終止點 (m)	寬度 (m)	深度 (EL.m)
F008	176.31	332.07	155.76	-0.33
F007	185.21	335.62	155.76	-0.38
F006	102.8	258.56	155.76	-0.96
F005	191.25	388.03	155.76	-0.82

結果與討論

水位

透過上述入口堰、上游、中游改善計畫，並利用 HEC-RAS 模式進行模擬，二重疏洪道改善計畫前後水位變化結果如表 4 所示，水位於上游段下降最多（F010 至 F008A），入口堰次之（F012 至 F011），中游段最少（F008 至 F005）。其原因可能為上游改善後之曼寧粗糙係數（0.0202）較原始（0.027）差距大且範圍廣，而入口堰因位於大漢溪及新店溪合流處，又因洪水在此地區被分為疏洪道及淡水河兩方向，入口堰清淤後的水位降低程度雖比二重疏洪道上游少，但與未清淤前相比已有顯著的效果，另外二重疏洪道通洪能力重新檢討總報告^[3]也指出，依據敏感度分析，河道減糙及河床降挖可提高通洪量的效益均為上游 > 中游 > 下游，本研究因考慮生態，未對下游做任何改善計畫，故下游水位維持不變，而中游水位下降程度亦受影響。而透過圖 4 可更明顯看出水位差異，柱狀圖中的藍色與紅色分別代表各斷面在 200 年重現期情境下的原始水位和改善計畫後水位，在入口堰、上游有較明顯的差異，而中游以後兩者差異逐漸減少至下游無變化，折線圖則表示各斷面水位變化的數值，負值為水位降低程度，例如 F009A 斷面改善後水位比原始降低 0.61 m。

表 4 改善計畫前後水位表

斷面編號	原始水位 (m)	改善後水位 (m)	水位變化 (m)
F012	9.62	9.16	-0.46
F011	9.54	9.13	-0.41
F010	9.50	9.00	-0.5
F009A	9.21	8.60	-0.61
F009	8.89	8.31	-0.58
F008A	8.50	8.01	-0.49
F008	8.21	7.88	-0.33
F007	7.79	7.63	-0.16
F006	7.56	7.53	-0.03
*F005A	7.62	7.59	-0.03
F005	7.53	7.51	-0.02
*F004	7.39	7.39	0
*F003	7.34	7.34	0
*F002	7.31	7.31	0
*F001	7.20	7.20	0

* 表示未實施任何改善計畫




圖 4 改善計畫前後水位比較圖

流速與洪氾區域

在洪水災害的風險評估中，藉由分析流速和洪氾區域可以幫助劃定洪水影響的範圍，並預測可能的損害情況，以及規劃緊急應對措施。藉由改善計畫，對入口堰、上游、中游有不同影響，以下將逐一說明。

入口堰：將泥灘地高程降低後，能使洪水更容易進入疏洪道進行疏洪作業，而改善前後的洪氾面積比較如表 5 所示，F011 斷面增加 394.31 m²，表示未改善前因高程較高，使洪水容易被擋在疏洪道外，不利於進行疏洪作業，而改善後將改善此問題；而入口堰改善前後的流速見表 6，兩斷面的流速都顯示減緩，其原因是降低高程會使水流的能量減少，阻礙水流運動，導致流速減緩，但在流速慢與洪氾面積擴大的配合下，有助於分散洪水的壓力，並減少河道侵蝕。

表 5 入口堰改善計畫前後洪氾面積比較表

斷面	原始洪氾面積 (m ²)	改善後洪氾面積 (m ²)	洪氾面積比較 (m ²)
F012	4100.01	4157.5	+ 57.49
F011	3415.73	3810.04	+ 394.31

表 6 入口堰改善計畫前後流速比較表

斷面	原始流速 (m/s)	改善後流速 (m/s)	流速比較 (m/s)
F012	1.6	1.57	-0.03
F011	1.9	1.71	-0.19

上游：大範圍降低粗糙度後，上游改善前後的流速變化結果見表 7，各斷面流速都有提升的情況，流速上升表示洪水雖能較快速通過此區域，加速疏洪速度，但對於河床的冲刷力較大，而由表 8 洪氾面積比較表中可以得知洪氾面積有縮減的現象，表示改善計畫後洪水與河床直接接觸的範圍比原始少，縮減量約為 9% ~ 14%，洪水多集中於疏洪道中間，降低對左右岸的影響，而上游的左右岸為新北大都會公園最多設施處，二重疏洪道改善後能使公園被淹沒的面積減少，並降低設施的損失。

表 7 上游改善計畫前後流速比較表

斷面	原始流速 (m/s)	改善後流速 (m/s)	流速比較 (m/s)
F010	1.98	2.34	+ 0.36
F009A	2.73	3.5	+ 0.77
F009	2.72	3.38	+ 0.66
F008A	2.26	2.75	+ 0.49

表 8 上游改善計畫前後洪氾面積比較表

斷面	原始洪氾面積 (m ²)	改善後洪氾面積 (m ²)	洪氾面積比較 (m ²)
F010	3290.37	2986.38	-303.99
F009A	2383.15	2054.27	-328.88
F009	2390.38	2123.24	-267.14
F008A	2873.46	2565.6	-307.86

中游：進行河床降挖創建渠道後，拓寬了水流的通道，由表 9 的改善前後流速表中可見流速在各斷面都有減緩的現象，這有助於緩和上游流速加快的衝擊；而由表 10 改善前後洪氾面積的結果則發現，中游段因洪水容易積聚在開挖的渠道內，在此區停留的時間較長，使洪氾面積增加，然而中游較少人造設施，多為停車場、棒球場、高爾夫球練習場的平坦地帶，所以造成的損失較少，洪水事件後的修復工作也較容易。

表 9 中游改善計畫前後流速比較表

斷面	原始流速 (m/s)	改善後流速 (m/s)	流速比較 (m/s)
F008	3.98	3.15	-0.83
F007	3.59	3.02	-0.57
F006	3.14	2.64	-0.5
F005	2.27	2	-0.27

表 10 中游改善計畫前後洪氾面積比較表

斷面	原始洪氾面積 (m ²)	改善後洪氾面積 (m ²)	洪氾面積比較 (m ²)
F008	2525.77	2707.48	+ 181.71
F007	2562	2773.42	+ 211.42
F006	2887.34	3208.54	+ 321.2
F005	3955.11	4234.46	+ 279.35

結論與建議

透過對二重疏洪道設計改善計畫的研究結果，可以觀察到針對不同區段面臨的限制或問題，提供適當的解決方案，能夠帶來有效增加通洪量和減少洪災損失的效益。首先，在入口堰降低高程方面，其優點在於能夠更有效處理大量的洪水進入疏洪道，並藉由擴大洪氾面積，進而分散洪水壓力，同時降低土壤和河道的侵蝕。再者，上游降低曼寧粗糙係數方面，雖然此舉使上游流速略有提升，但同時也縮減了洪氾面積，且此段為水位降低較顯著的區域，這項調整對於改善附近地區的防洪效果有所幫助，並減少新北大都會公園內公共設施和基礎建設的損失。此外，中游降挖河床方面，雖然水位降低的幅度相對入口堰和上游較小，但有效增加洪水通過的斷面積，意味著在此區可以容納更多洪水，對增加二重疏洪道的通洪量有所裨益。

透過以上針對二重疏洪道設計的改善策略，將有效解決其通洪量下降之問題，進一步提升大臺北地區在面臨洪災時的應變能力，降低未來可能出現的災害風險；本改善計畫不僅彰顯二重疏洪道所扮演的關鍵作用，更突顯其在洪水管理中的重要性。

最後，根據前述的分析，建議未來的研究應進一步探討下游改善方案，並綜合考慮生態和防洪需求，提升二重疏洪道洪水管理的全面性和可持續性。在永續發展方面，建議在施作工程之前進行生態調查，並考慮生物棲地、環境、多樣性等因素後，對改善計畫範圍、內容做適當的調整；而在工程期間，應盡量減

少能源消耗，包括使用節能型機具、臨時管理站的電力使用太陽能或其他再生能源等方式；完工後應保持監測和定期維護，例如確保入口堰的高程維持在一定的範圍內、上游的植被和中游渠道保持完整，避免日後需要投入更大量的資源和能源進行修復，同時確保二重疏洪道維持一定標準的疏洪量，不僅增加二重疏洪道經過改善計畫後的疏洪能力，也提升整體的永續性。未來應以減少洪水損失為目標，持續進行更詳細的水文和水理分析，並考慮氣候變遷後的結果，與政府機構配合洪水預警系統及策略，如此可以提高二重疏洪道的效能，使其能更有效地應對大規模洪水事件，降低洪水衝擊，並維護大臺北地區的防洪安全，提升城市韌性。

參考文獻

1. Motiur Rahman and Md. Shahjahan Ali, (2022). "Morphological response of the Pussur River, Bangladesh to modern-day dredging: Implications for navigability." *Journal of Asian Earth Sciences: X*, Vol. 7, No. 1, 100088.
2. 陳健豐、楊連洲、曹榮顯、黃國文、施上粟、李偉哲（2022），

- 「防洪與生態雙贏的水利工程—大漢溪城林橋至鐵路橋右岸河道改善工程」，中國土木水利工程學會學刊，第 49 卷，第 2 期，第 32-38 頁。
3. 經濟部水利署第十河川局（2012），二重疏洪道通洪能力重新檢討總報告。
 4. Shih, SS., Yang, SC., and Ouyang, HT, (2014). "Anthropogenic effects and climate change threats on the flood diversion of Erchung Floodway in Tanshui River, northern Taiwan." *Nat Hazards*, Vol. 73, pp. 1733-1747.
 5. Shang-Shu Shih and Po-Chih Chen, (2021). "Identifying tree characteristics to determine the blocking effects of water conveyance for natural flood management in urban rivers." *Journal of Flood Risk Management*, Vol. 14, No. 4, e12742.
 6. 經濟部水利署第十河川局（2021），淡水河（含大漢溪、疏洪道、三峽河、橫溪）大斷面測量計畫測量成果報告書。
 7. 經濟部水利署水利規劃試驗所（2022），二重疏洪道現地調查及數值水理模型建置工作。
 8. 經濟部水利署第十河川局（2018），臺北防洪計畫（大漢溪、新店溪及二重疏洪道河段）清疏以維生態策略研擬。
 9. 行政院農業委員會水土保持局（2018），本土化不同草種與期齡及植生毯噴植應用於草溝曼寧粗糙係數與濾砂功能之研究—成果報告。
 10. 新北市政府臺大輔導顧問團（2020），全國水環境改善計—二重疏洪道出口堰親水環境再造計畫。



歡迎加入學會



www.ciche.org.tw
下載入會申請書

e-mail: service@ciche.org.tw

電話：(02) 2392-6325

傳真：(02) 2396-4260

土木水利 雙月刊

向您約稿

本刊出版有關土木水利工程之報導及論文，以知識性、報導性、及聯誼性為主要取向，為一綜合性刊物，內容分工程論著、技術報導、工程講座、特介、工程新知報導及其他各類報導性文章及專欄，歡迎賜稿，來稿請 email: service@ciche.org.tw 或寄 10055 台北市中正區仁愛路二段 1 號 4 樓，中國土木水利工程學會編輯出版委員會會刊編輯小組收，刊登後將贈送每位作者一本雜誌，不再另致稿酬；歡迎以英文撰寫之國內外工程報導之文章，相關注意事項如後：

- 工程新知及技術報導，行文宜簡潔。
- 技術研究為工程實務之研究心得，工程講座為對某一問題廣泛而深入之論述與探討。工程報導為新知介紹及國內外工程之報導。
- 本刊並歡迎對已刊登文章之討論及來函。
- 工程論著及技術研究類文章，由本刊委請專家 1 ~ 2 人審查，來文請寄電子檔案，照片解析度需 300dpi 以上。
- 文章應力求精簡，並附圖表照片，所有圖表及照片務求清晰，且應附簡短說明，並均請註明製圖者及攝影者，請勿任意由網站下載圖片，以釐清版權問題。



共創科學—社會經濟路徑以邁向 永續流域綜合管理造福社稷

張斐章*／國立臺灣大學生物環境系統工程學系 特聘教授

廖秀娟／國立臺灣大學生物環境系統工程學系 特聘教授

黃誌川／國立臺灣大學地理環境資源學系 教授

江莉琦／國立臺灣大學生物環境系統工程學系 副教授

許少瑜／國立臺灣大學生物環境系統工程學系 副教授

鄭舒婷／國立臺灣大學森林環境暨資源學系 副教授

石曜合／國立臺灣大學農業經濟學系 助理教授

孫維／國立臺灣大學生物環境系統工程學系 博士班研究生

本文藉由濁水溪做為研究流域，針對該流域之社會、經濟、自然等環境做綜合研究並提出整合管理之建議。研究內容主題包含應用機器學習對地下水位做短、中、長期之預測、灌溉方式對於地下水水位以及溫室氣體排放之影響、水質對新興藥品污染物生態毒性影響、濁水溪流域河川水之停留時間推估、地表水—土—地下水營養鹽之傳輸模擬、以系統動態評估水資源回復力以及湖山水庫對於水源供應、地層下陷、水質改善探討水資源保育之社會與經濟效益。藉由此綜合性探討，可以發現水資源管理除了水庫操作或是地下水抽水管理外，也需要結合水質、營養鹽、社會經濟等多面向共同研討。本文提供了各面向之研究成果，讓讀者可以更了解流域管理，並提供相關研究流程供管理者參考。

前言

近年來極端氣候事件的頻繁發生已經成為全球共同面臨的嚴重問題之一，不僅對水資源的永續性造成影響，也持續增加社會經濟成本。其中濁水溪流域地下水區被視為地下水蘊藏較豐富的區域之一，為台灣中部工業與農業區的重要補給水源，於社會活動中也多仰賴此資源，因此穩定的水資源供應對於農業與整體經濟的永續發展極為重要。本綜合研究深入探討濁水溪流域的水文循環、地下水與地表水的相互作用，除探討水文面向外，農業永續發展與社會經濟的影響、水質汙染等環境問題也是一大關注重點。透過結合機器學習、數值模

式、系統動力學等多種方法，達成探索預防、緩解、減輕水資源問題的潛在途徑目標，此將有助於提升此地區之韌性，同時實現永續發展目標。

地下水為水文循環中重要的部分，與地表水文密切相關，其中降雨補注與河川—地下水之相互作用為水文循環中重要的過程，本研究應用地表及地下水資料結合不同的機器學習方法以預測地下水短、中、長期之水位，以及為瞭解地下水與地表水相互作用對流域時間、空間的影響，使用地表地下水模型 SWAT-MODFLOW 考慮地表—地下相互作用並分析降雨入滲量，期能藉由預測及分析提升地下水資源管理。除使用機器學習與數值模型方法欲強化水資源管理外，透過了解河水在集水區內的移動軌跡，也可應用於水源與水質維護作業，同

* 通訊作者，changfj@ntu.edu.tw

位素分析技術與相關水文模式的發展有助於估計河水年齡 (transit time) 與流動地下水年齡 (residence time)，進而分析集水區河水之移動特性，而研究中則以近年發展之儲庫年紀選擇法 (Storage Selection functions, SAS) Botter *et al.* [1] 和 Rinaldo *et al.* [2] 探討濁水溪玉峰橋與內茅埔集水區河水年齡變化，為區域水資源管理基礎。

濁水河流域水質污染方面，本研究探討藥品和個人護理產品 (pharmaceuticals and personal care products, PPCPs) 生態毒性的影響。PPCPs 是新興污染物的一種，在世界各地與不同的環境介質中常被偵測到 [3,4]，其中對經基苯甲酸酯 (parabens) 為常用的防腐劑成分，在台灣近期相關研究顯示於不同水質環境及水中生物體中皆有檢測出 [5]，不僅會損害水質，還可能進入食物鏈，影響人類和環境生物的健康 [6]。因此本研究以濁水溪為研究區域，於不同水質條件下針對環境中最常見的 parabens 種類 methylparaben (MeP)，對秀麗隱桿線蟲 *Caenorhabditis elegans* (*C. elegans*) 的繁殖毒性進行探討，理解其對生態系統及人類健康的潛在影響。

農業永續發展方面，濁水河流域為臺灣重要農產品之主要產區之一，農業屬氣候敏感產業 [7]，然其秋冬季節少雨的特性，造成地表水的供應有明顯季節性。隨著農工業發展，水資源的需求持續增加，然而伴隨人類活動所造成的水質污染卻導致乾淨之水資源日益減少，使缺水及乾旱成為亟待解決的難題，研究中則透過乾旱指標與系統動態方法分析氣候變遷對於農業永續發展的影響。除須持續關注乾旱與缺水問題外，本研究針對水稻種植進行更進一步的探討，對於水稻種植而言，有效管理資源於產量、品質以及環境永續發展具有重要影響。在不斷變化的氣候和環境背景下，良好的灌溉策略已成為實現農業生產可持續性的關鍵要素之一，故本研究欲分析不同灌溉策略對地下水位和溫室氣體排放之影響。

除農業為高用水類別外，隨經濟日益發展之下，民生與工業用水需求也逐漸提升，增加區域內供水吃緊情形，為加強區域供水之穩定性，而建置湖山水庫，最終於民國 105 年起供應彰化與雲林地區之用水，為達成資源有效運用，各項公共投入皆應本於嚴謹之成本效益分析，研究中分析之目的即在於藉由估計湖山水庫完工後，對於該地區農業生產與農地價格之影響，評估湖山水庫為農業部門所帶來之經濟效益。

整體綜合研究中不僅關注水資源管理，更希望將科學、技術與經濟發展緊密結合，以應對氣候變遷與極端氣候事件帶來的多重挑戰，為地區的永續性及社會發展做出實質貢獻；而以下文章中分別根據水文循環、地下水、地表水、農業與經濟社會等多種面向進行探討。

創建新穎機器學習水文預測模式以促進地下水補注與水資源管理效益

本章節擬以歷年的地下水、流量、雨量等資料做短、中、長時間趨勢的分析，使用類神經網路為主的機器學習預測地下水，包含了使用混合模式預測短期水位 (日尺度)、最新穎的 Transformer 模式預測中期水位 (旬尺度) 以及結合物理模式預測長期地下水位 (月尺度)，以下將分三節進行討論。

短期地下水預測

卷積神經網路 (Convolution Neural Network, CNN) 是一種屬於深度學習的神經網路，過去被廣泛地應用在處理複雜的資料，例如圖片、演講或時間序列問題 [8,9]。卷積神經網路中最基礎的概念就是卷積 (Convolution)，CNN 藉由卷積過程擷取複雜資料中的特徵 (feature)，經由後續的邏輯處理層，便可以進行辨識及預測。CNN 的主要架構如圖 1。




圖 1 CNN 架構圖 (來源: Shreyak [10])

表 1 短期預測模式參數

模式	模式參數						
	Epochs	Hidden Layer	Kernel/Neuron	Learning rate	Batch size	Kernel size	Optimizer
CNN-BP	200	2* CNN Layer 1* FC Layer	25/25 15/15 50	0.001	8	2	Adam
BPNN	200	5* FC Layer	50/50/ 70/50/ 50	0.001	8	-	Adam

本研究建置之 CNN-BP 模式（架構如表 1），將輸入資料的時間維度特徵由 CNN 模式提取，再由 BPNN 模式進行地下水位的預測。本研究亦另建置一傳統 BPNN 神經網路模式，用同樣的資料輸入進行預測。本研究欲觀察深度學習的 CNN-BP 模式是否能在預測地下水位的時間序列資料上比傳統的類神經網路有更好的預測表現。

不論從整體的預測表現，或是從各測站的預測表現比較，CNN-BP 模式都是有效的區域地下水位預測模式，結果如表 2 所示，不但在所有階段都有較高的 R² 值（越高表示模式越擬合真實值）和較低的 RMSE 值（越低表示誤差越小），也能有效的減少預測時產生的時間延遲現象。儘管有些測站預測效果較差（R² < 0.90），整體 R² 達到 0.93 以上，RMSE 小於 2.64 公尺，說明 CNN-BP 模式是相當有效的區域地下水位預測模式。

表 2 地下水位預測平均 R2 表現

	預測時距	R ²		RMSE (m)	
		訓練	測試	訓練	測試
CNN-BP	T+1	0.98	0.98	0.183	0.156
	T+2	0.96	0.96	0.259	0.215
	T+3	0.94	0.94	0.319	0.264
BPNN	T+1	0.97	0.93	0.257	0.353
	T+2	0.95	0.93	0.331	0.402
	T+3	0.91	0.87	0.353	0.426
進步百分比	T+1	1.0%	5.4%	28.8%	55.8%
	T+2	1.1%	3.2%	21.8%	46.5%
	T+3	3.3%	8.0%	9.6%	38.0%

圖 2 為測試資料真實地下水位與 CNN-BP 模式預測地下水位的區域平均誤差圖。圖中藍色部分表示 CNN-BP 模式低估了地下水位，紅色表示模式高估地下水位。由圖可以看出，整體而言濁水溪沖積扇東部和北部的預測地下水位大多有低估的情形，而濁水溪沖積扇西部和南部的預測地下水位大多有高估的情形。地下水位低估的部分以古坑 (1)、烏塗 (1)、田中 (1) 測




圖 2 CNN-BP 模式預測誤差分布圖

站較為嚴重，而地下水位高估部分則是舊庄 (1)、海園 (1) 測站較為顯著。圖中除了上述提到的幾個區域外，大部分的誤差都在正負 15 公分之內，說明本研究之 CNN-BP 模式在預測區域地下水位上有相當的可信度。

中期地下水預測

目前機器學習隨著硬體的提升以及 GPU 的普及有了更迅速的發展，其中以深度學習在近期的研究更如雨後春筍般出現。而深度學習中，Transformer Neural Network (TNN) 的表現更為亮眼。TNN 擁有較高的彈性，因此包含了以往卷積神經網絡 (CNN) 以及長短期記憶神經網路 (LSTM, Long short-term memory) 的優點。

TNN 屬於一種 Sequence to Sequence (Seq2Seq) 的神經網路，因此輸入與輸出的長度不需要一樣，由神經網路自行決定，相關的應用如語音辨識或是翻譯

等。2017年由 Google Brain 的 Vaswani 等人^[11]發表了 Attention is All you Need，提出了 self-attention 為基底的 TNN，讓機器學習又更進一步。其中最主要的單元即為 Self-Attention。Self-Attention 會考慮所有的輸入向量，再放入全連結層，因此可以考慮所有的周圍資訊。

Self-Attention 其應用可以在影像上，將影像看為 vector set，每一個像素可看為 RGB 之三維向量^[12]。Self-Attention 與 CNN 的差異以及關聯性可以觀察，Self-Attention 看的是每一個像素與其他像素的關聯性，而 CNN 是僅考慮每一個 receptive field 內的資訊，因此 CNN 可以看成是簡化版或是特例的 Self-Attention。也可以說 Self-Attention 是 CNN 的複雜版本，相較之下 Self-Attention 較彈性，但也因此需要較多的資料才不會過度擬合。

在濁水溪下游扇尾區，我們關注八個距離工業區較近、人口較多的地下水位。我們在測試階段評估了 TNN 的性能，結果呈現在表 3 中。我們觀察到所有 TNN 預測未來 10 日的 R^2 值均超過 0.75，這表明預測數據與觀測數據之間存在著強烈的相關性。MAE (Mean Absolute Error) 值皆低於 1 公尺，顯示了預測的準確性。與 CNN 和 LSTM 模型相比，TNN 展現出卓越的預測性能。宜梧站在三個模型中表現最佳，測試階段的 R^2 值 TNN 為 0.93，CNN 模型為 0.93，LSTM 模型為 0.89。我們對宜梧站的時間序列預測進一步觀察，如圖 3(a) 所示。總體來說，三個模型都能夠捕捉到地下水位的趨勢。但表 3(b) 中呈現的 MAE 值進一步支持 TNN 的高準確性，因為它相較於 CNN 和 LSTM 模型具有更低的誤差。

在這三個模型中，TNN 在海園站預測較不理想， R^2 值為 0.73。然而，就 R^2 值而言，它仍優於 CNN 但略低於 LSTM 模型。進一步觀測該站的時間序列預測圖（圖 3(b)），我們觀察到雖然三個模型都能捕捉到趨勢，但 CNN 和 LSTM 模型明顯低估了地下水位。相比之下，TNN 在預測趨勢和峰值方面表現相對良好。

比較 CNN 和 LSTM 模型，我們發現 CNN 優於 LSTM。CNN 和 LSTM 在線西站預測最差， R^2 值分別為 0.74 和 0.44，而 TNN 在該站的表現相對良好， R^2 為 0.82。總體而言，由時間序列圖顯示，CNN 和 LSTM 在捕捉趨勢表現較差，而 TNN 不僅在趨勢預測上表現出色，而且在預測峰值方面也表現優異。


表 3 地下水測站 R^2 、MAE 表現圖

(a) 預測未來 10 日 R^2 之各測站表現


測站	Transformer		CNN		LSTM	
	Train	Test	Train	Test	Train	Test
宜梧	0.89	0.93	0.95	0.87	0.97	0.92
文昌	0.80	0.80	0.81	0.77	0.78	0.74
明德	0.92	0.75	0.95	0.75	0.93	0.72
洛津	0.89	0.80	0.93	0.79	0.88	0.66
海園	0.92	0.73	0.94	0.71	0.93	0.76
箔子	0.95	0.88	0.96	0.87	0.95	0.84
線西	0.76	0.82	0.76	0.74	0.63	0.44
豐榮	0.95	0.92	0.96	0.92	0.95	0.88

(b) 預測未來 10 日 MAE 之各測站表現

測站	Train	Test	Train	Test	Train	Test
宜梧	1.03	0.94	0.96	1.34	0.74	1.29
文昌	0.16	0.18	0.18	0.20	0.21	0.32
明德	0.32	0.90	0.30	0.90	0.42	0.96
洛津	0.18	0.17	0.14	0.23	0.20	0.37
海園	0.44	0.41	0.43	0.37	0.41	0.71
箔子	0.27	0.28	0.27	0.30	0.29	0.52
線西	0.15	0.15	0.17	0.36	0.22	0.35
豐榮	0.37	0.28	0.26	0.48	0.32	0.82



(a) 宜梧測站模式預測時間序列圖 (T+1)



(b) 海園測站模式預測時間序列圖 (T+1)

圖 3 模式預測時間序列圖 (T+1)




圖 4 地下水測站 R² 表現雷達圖（TNN、CNN、LSTM）

在測試階段預測 T + 1 之地下水位，整體而言 TNN 比 CNN 和 LSTM 表現更加穩定，尤其在預測峰值方面效果顯著。雷達圖（圖 4）顯示，在大多數站點上，TNN 優於 CNN 和 LSTM 模型。相較於 CNN 模型，TNN 在 R² 方面平均改善率為 3.75%，MAE 方面則為 21.15%；相較於 LSTM 模型，TNN 在 R² 方面改善率為 12.16%，MAE 方面則為 38.80%。表 3(a) 和 (b) 顯示

每個站點在 T + 1 時刻的 R² 和 MAE 表現之詳細數據。

長期地下水預測

圖 5 為 ConvAE-LSTM 的結構圖，其中有壓縮還原影像之 Autoencoder 以及 LSTM 兩個部分。以下分成：encoder、decoder 及 LSTM 三個階段簡單介紹，詳細說明請參閱 [13] 。




圖 5 ConvAE-LSTM 方法架構




圖 6 ConvAE 模組之推估表現：(a) 觀測影像；(b) 重構之影像

(1) Encoder 階段

歷史的觀測資料以及由 HBV (Hydrologiska Byråns Vattenbalansavdelning) 模式產生的模擬資料將會用 IDW (Inverse Distance Weight) 內插成區域影像圖，隨後輸入到後續的 CNN 以及 max pooling, 萃取特徵。Flatten layer 會將高維度的輸出資料整合成 1 維，隨後的 dense layer 將此階段輸出資料壓縮成只有 10×1 的大小。

(2) Decoder 階段

在 encoder 被壓縮的影像在此階段會被還原成一張圖的大小 (圖 6(a))。經過卷積層會將特徵進行還原，並通過 upsampling layer 將壓縮後的維度還原成圖片原有大小的維度 (圖 6(b))。值得一提的是 decoder 階段在訓練的時候才會進行，而本研究的重點是只截取壓縮後的 code 進行後續地下水位時間序列預測。

(3) LSTM 階段

此階段為模式的預測階段。輸入項分別為：(1) 影像壓縮後的特徵值 (image code value)、(2) 觀測井點資料。兩種資料分別輸入到各自的 LSTM 做訓練。圖 5 中 T-1 (前一個月) 及 T (當天) 為觀測資料，T + 1' (未來一個月) 至 T + 3' (未來三個月) 為 HBV 模擬資料。首先在 LSTM 層中將會學習資料潛在的時間連續特徵，隨後在 Concatenate layer 會將兩個單獨的 LSTM 萃取後的資訊進行結合。最後，整合後的資訊將會在 Dense 輸出層進行未來 3 個月的地下水水位的預測。

ConvAE-LSTM 模式相較一般神經網路有許多優勢，首先，在 ConvAE 中由於 Autoencoder 獨特的結構以及特性，它可以萃取二維空間影像之特徵，降低輸入的維度。隨後的 LSTM 可以學習資料之間時間維度上的關係，讓模式提升對於未來地下水水位的預測精

度。另外，兩者的結合讓深度學習模式有效避免了過度擬合的問題，因模式在 ConvAE 階段已有效的去除雜訊，故可以讓後續的 LSTM 階段進行更精準的預測。透過將壓縮後的影像資訊與觀測點位真實資料一併作為輸入資料，在 LSTM 階段可以結合兩種不同的資訊，藉此提升模式的預測精度。

表 4 為 ConvAE-LSTM 與 LSTM 模式於訓練及測試階段之預測表現。整體上來看，ConvAE-LSTM 的表現比 LSTM 更加理想，因為其預測的 RMSE 遠遠小於 LSTM，從 T + 1 至 T + 3 皆是如此。此外，比較訓練以及預測的結果發現，ConvAE-LSTM 在兩階段的表現比較一致，換句話說這代表誤差不會相差太大。反之，LSTM 在訓練階段的誤差卻遠小於測試階段。這個表現明了相比於 LSTM，ConvAE-LSTM 對於具有高不確定性之時間序列資料有著較強的通用性。

表 4 ConvAE-LSTM 與 LSTM 模式於訓練及測試階段之預測表現 (RMSE)

階段	時距	ConvAE-LSTM (m)	LSTM (m)
訓練	T + 1	0.60	2.56
	T + 2	1.04	3.43
	T + 3	1.39	3.44
測試	T+1	1.00	4.61
	T+2	1.49	8.15
	T+3	1.84	7.64

圖 7 為 ConvAE-LSTM 於濁水溪流域地下水水位預測在不同季節之 RMSE 表現，此結果為區域預測結果圖，分別表示了 2018 年冬天以及 2018 年夏天的預測誤差。可以很明顯地觀察到夏天相比於冬天的預測結果有較大的誤差。這是由於夏天颱風頻仍，造成水位變化較為劇烈，使模式預測的不確定性在夏天較大。除此之外，相比於濁水溪其它區域，西南部區域地下水之預測




圖 7 ConvAE-LSTM 於不同季節預測地下水之表現

誤差較大，其原因可能在於濁水溪西南部的土壤為保水較差的細砂，使地下水變化會較為劇烈。

灌溉方法對於地下水與溫室氣體排放的影響

本研究探討六種不同灌溉策略對於農業部桃園農業改良場（本文後續簡稱桃改場）的地下水水位及溫室氣體排放之可能影響。所採用的六種灌溉策略及其灌溉方式如下：桃改場慣行操作、控制灌溉（Controlled Irrigation, CI）、間歇灌溉（Intermittent Irrigation, II）、淺濕灌溉（Shallow-Wet Irrigation, SWI）、乾溼交替灌溉（Alternate Wetting and Drying, AWD）、水稻強化栽培體系（The System of Rice Intensification, SRI）^[14]。其中，桃改場慣行操作為傳統水稻淹水灌溉；CI 前期採淹水灌溉，後期採非湛水灌溉，屬於半乾式操作；II 在操作上與乾濕交替灌溉原理相似，為灌溉至一定深度待水分下降至 70% 飽和土壤含水量再行灌溉^[14]；SWI 為透過淺薄的灌溉水進行操作^[15]；AWD 即以乾濕交替的方式灌溉；SRI 採以大部分時間為非湛水灌溉但田間保持濕潤，直到開花後田間保持 1 至 3 公分湛水深，收穫前 25 天進行排水^[16,17]。六種灌溉策略請見圖 8。

根據 2021 年的桃改場水稻田灌溉資料與區域地下水位關係，所建立的地下水位變化推估如表 5。根據該表之規則，計算 2022 年 10 月 1 日至 12 月 31 日之地下水位高程資料與桃改場實際值比對，確認推估結果與實際值相近。因此，本研究以表 5 之規則推估各灌溉策略在 2022 年第二期作降雨與生長日期條件下之地下水變化（圖 9）。

在採用不同灌溉策略下，CI 及 SRI 二方法分別於營養生長期與生殖生長期間濕潤無湛水，致使滲漏量較低，地下水位有下降趨勢。桃改場慣行操作下收穫後之地下水位高程為 26.51 公尺處；CI 為 26.31 公尺；II 為 26.53 公尺；SWI 為 26.66 公尺；AWD 為 26.45




圖 8 各灌溉策略示意圖

表 5 桃改場地區之區域地下水位每日變化量規則表

發生條件	每日補注量 (mm/day)	每日排退量 (mm/day)
無灌溉 無降雨	0	-37 (初始) -17 (10 天後)
有灌溉	$\frac{\text{灌溉水提供之滲漏量}}{0.2}$	-20
有降雨	$\frac{\text{有效雨量}}{0.2}$	

公尺；SRI 為 25.77 公尺。SRI 灌溉策略與桃改場慣行操作相比，下降約 0.74 公尺，是唯一一個收穫後地下水位低於插秧時之策略。CI 則下降約 0.2 公尺；II 及 AWD 策略與慣行操作下之地下水位高度相似；而 SWI 則是些微上升。

溫室氣體排放量的推估是採用 2022 年第一期作的氣溫資料，在不考慮降雨及施肥情況下，透過 DSSAT 作物模式模擬各灌溉策略因不同湛水深及土壤含水量變化，發生脫硝作用造成之氧化亞氮排放量，模擬結果如圖 10。

結果發現，因脫硝作用造成之 N₂O 排放發生於田間由乾燥（好氧狀態）轉為湛水狀態（厭氧狀態）後，如桃改場慣行操作上曬田後灌水、間歇灌溉（II）與乾溼交替灌溉（AWD）由無湛水狀態再行灌溉，及 SRI 水稻生長前期皆無湛水，在生殖期起開始施行淹水





圖 9 各灌溉策略下推估之地下水位變化

圖 10 各灌溉策略之灌溉期間模擬 N_2O 排放量

灌溉時發生。其中，以 AWD 總排放量最高，其次為間歇灌溉 (II)。各灌溉策略中，因控制灌溉 (CI) 操作由初期的湛水灌溉至中後期的無湛水灌溉，土壤由厭氧轉為好氧狀態，恰好抑制脫硝作用的發生。而淺濕灌溉 (SWI) 在營養生長過程以乾濕交替原則進行灌溉，但因每次深度灌溉較低，土壤厭氧程度不足以發生脫硝作用而造成 N_2O 排放，因此主要 N_2O 排放僅發生於生殖期初期由排水操作轉為淹灌操作時。

綜合以上論述，可發現大部分灌溉策略的灌溉量都能維持地下水位高度，僅 SRI 灌溉策略，耕作期前地下水位有些微下降，要等到降雨後才会有顯著提升。而在各灌溉策略之田間湛水變化對於脫硝作用之影響可知，灌溉操作上若能盡量由湛水（厭氧）至濕潤無湛水（好氧）狀態，或執行乾濕交替操作時，盡可能降低淹水高度，能夠有效避免脫硝作用之 N_2O 排放，降低土壤 N 損失。

濁水溪水質對新興藥品污染物生態毒性影響探討

如前言所敘述，本研究以濁水溪流域為範例，探討水質條件對 parabens 生態毒性的影響。

濁水溪水質分析

濁水溪水樣的採樣點如圖 11 所示。研究採用感應耦合電漿光學發射光譜法 (inductively coupled plasma optima optical emission spectrometer, ICP-OES) 及離子層析 (ion chromatography, IC) 檢測水中的陽離子與陰離子含量，並使用總有機碳檢測儀分析水中的有機碳 (total organic compound, TOC) 與無機碳 (total inorganic compound, TIC) 含量。




圖 11 濁水溪採樣位置圖

C. elegans 繁殖毒性

研究針對 MeP 在不同濁水溪水質條件下，對 *C. elegans* 體內的卵數進行探討。試驗所用之培養液包含線蟲標準溶液（M9 buffer 及 K-medium）與濁水溪水樣（JS1-JS4）。

濁水溪水質檢測結果

水質檢測結果顯示，濁水溪水樣之離子濃度介 0.5 ~ 170 mg/L 之間，JS1 與 JS2 位於濁水溪上游支流，因此離子含量較 JS3 及 JS4 低。此外，JS3 之 COD 濃度較其他三者高，顯示此處可能有潛在的有機汙染源。JS4 位於濁水溪支流清水溪，靠近濁水溪主流中下游，推測可能因位於河流匯集處而使離子含量較多。

濁水溪水質對 parabens 繁殖毒性的影響

試驗所用之培養液包含線蟲標準溶液（M9 buffer 及 K-medium）與濁水溪水樣（JS1-JS4），當線蟲暴露在 100 mg/L 的 MeP 下，M9 buffer 和 K-medium 組別線蟲體內的卵數皆顯著下降（圖 12）。類似的結果也在斑馬魚的研究中發現，當暴露在 1 μ g/L 的 MeP 下，會造成斑馬魚配子數量的減少^[18]。此外，亦有研究發現 60 mg/L 的 MeP 會引起線蟲體內氧化壓力上升與干擾內分泌，進一步導致子代數減少^[19]。當線蟲培養在不同濁水溪水水質條件下，暴露 MeP 同樣會造成線蟲體內卵數顯著下降，且在不同水質條件下，其下降程度略有差異，以 JS4 下降程度最為明顯（圖 12）。綜上所述，MeP 已被證實對環境中的非目標生物具有繁殖毒性，相關分子機制也越來越明朗，惟目前較少研究探討水質與毒性之相關性，因此本研究利用主成分分析進一步討論。




圖 12 *C. elegans* 於不同水樣暴露 MeP 之繁殖毒性（體內卵數）。數據以 mean $\pm$ SEM 表示，統計利用 Student's *t*-test 分析，*** $p < 0.001$ 。

濁水溪水質參數與 parabens 繁殖毒性之主成分分析

研究利用 SPSS 進行主成分分析，將資料分群。水質與毒性資料轉換為相關性係數後，數值越接近 1 表示可靠度越高，數值小於 0.5 則不予參考，正值表示數據間為正相關，負值則表示數據間為負相關。圖 13 為 MeP 繁殖毒性及水質參數之主成分分析。第一主成分包含 Ca^{2+} 、TIC、TOC、 Cl^- 、 K^+ 及 NO_3^- ，第二主成分包含 Mg^{2+} 、 PO_4^{2-} 、 SO_4^{2-} 、 Na^+ ，表示此兩組水質參數可能源自於相異的兩大來源。第三主成分為 COD 與 MeP 之繁殖毒性數據，COD 為水樣中可化學氧化之有機物含量，可間接代表水中有機物含量，因此可推測水樣中有機物含量越高時，繁殖毒性也越強。此外，TOC 與 COD 未被分析為同一主成分，可能原因為兩種檢測方法中的水樣過濾與否有關，同時，COD 檢測也受水樣中 Cl^- 干擾而產生誤差。綜上所述，儘管環境樣品存在的不確定性高，研究結果仍可顯示主成分分析具有高度應用性。

近年新興汙染物在環境中的濃度及出現頻率日益提高，新興汙染物的研究已經成為全球重要的研究課題。然而大多數研究集中於檢測和監測新興汙染物，且新興汙染物對非目標生物的長期影響尚不清楚。此外，環境因子對於新興汙染物影響的相關研究仍缺乏，不同的水質條件可能藉由化學交互作用影響新興汙染物的活性、毒性及生物可用性等，仍需更深入地理解這些關聯以及其對生態系統和人類健康的潛在影響。本研究提供了一種可行的方法，分析不同水質條件對新興汙染物的影響。




圖 13 MeP 繁殖毒性及水質參數之主成分分析

應用儲庫年紀選擇法推估河水停留時間變化

研究中利用儲庫年紀選擇法，估算濁水溪玉峰橋與內茅埔集水區河水的年齡，進而分析河水之移動特性。由於 SAS 模式大多運用於小集水區（面積 $< 10 \text{ km}^2$ ），因此本研究首先評估該模式於較大流域如濁水溪玉峰橋集水區（ $1,517 \text{ km}^2$ ）之有效性，並進一步對內茅埔測站流域範圍內各子集水區（ $15 \sim 364 \text{ km}^2$ ，圖 15）進行評估。本研究首先使用中央氣象局觀測降雨資料與水利署流量資料，透過 SAS 模式計算日尺度河水年齡的變化。再以與資料相符時期採取之各流量測站雨水、河水樣本分析其 $\delta^{18}\text{O}$ 同位素濃度，用以驗證 SAS 模式所估算水年齡的適用性並以此提高對季節性變化的理解。雨水與河水 $\delta^{18}\text{O}$ 數值分別由 2014 年 ~ 2016 年（玉峰橋）與 2022 年（內茅埔）現地採取之水樣分析獲得，其中雨水 $\delta^{18}\text{O}$ 同位素值已根據海拔高度進行修正。由圖 14(a) 可知，玉峰橋集水區雨水 $\delta^{18}\text{O}$ 變動範圍較大（ $-24 \sim 1$ ），河水 $\delta^{18}\text{O}$ 則較為收斂（ $-14 \sim -8$ ），表示河水已經過長時間混合。模式預估值之 KGE 效率為 0.55，表明模擬可接受，但仍需進行修正。河水由 39% 的新水（水年齡 < 70 天）與 61% 的舊水組成（圖 14(b)），整體而言乾燥時以舊水的釋放為主，然而在前

期條件非常乾燥的大降雨事件中，可見新水大量釋出。地下水年齡（圖 14(c)）和河水年齡（圖 14(d)）的通過時間中位數差異約為 111 天，但河水之累積機率分佈較不平滑且不確定性亦較高，可能因為流路具有較高的變異性，須進一步考慮模式應用於較大集水區的時間或空間差異問題。內茅埔各子集水區模擬之 KGE 效率為 $0.51 \sim 0.68$ ，水年齡中位數由 130 天 ~ 1250 天不等，相較於玉峰橋而言整體偏高，可能因 2021 年 ~ 2022 年間無較大降雨事件，因此河水組成明顯以舊水為主有關。各集水區的新水比例（young water fraction）為 $10\% \sim 25\%$ （圖 15），除十八重溪橋集水區（W3）可能因坡度較高而加速新水的排出外，其餘上游集水區（W2、W4、W5）大致可見土壤滲透率或水力傳導度越高則新水比例較低趨勢，亦即高滲透性土壤易使雨水入滲，減少雨水短時間即進入河川中的比例，促使更多雨水進入地表下而隨時間緩慢釋放至河水中。

地表水－土－地下水之營養鹽傳輸模擬

在建置 SWAT-MODFLOW 部分是參考官方使用手冊，其研究流程圖以圖 16 表示模擬是以每日尺度進行，期間為 2000 ~ 2021 年，網格大小為 $1,000 \times 1,000$ 公尺。建置 SWAT 模式需要 DEM 資料、日尺度氣象資




圖 14 SAS 模式於玉峰橋測站成果。(a) 雨水與河水 $\delta^{18}\text{O}$ 變化圖，黑線為雨水，紅線為河水模擬值，橘色圓點為採集水樣之 $\delta^{18}\text{O}$ 分析值；(b) 測站觀測流量與模擬之新水比例；(c) 儲庫水年齡累積分布圖與中位數；(d) 河水年齡累積分布圖與中位數。




圖 15 研究集水區與內茅埔測站各子集水區水年齡分布圖（藍色區域為水年齡 70 天之新水佔比（young water fraction）。




圖 16 SWAT-MODFLOW 研究流程圖




圖 17 補注量與抽水計算流程圖

料、土壤分布圖、土地利用分布圖。建置 MODFLOW 需要地質參數、水文參數、河道參數、地下水位等等，當中 MODFLOW 中補注量與抽水量假設設定為表層是藉由地表補注或人為抽水進出網格，但在深層含水層僅能抽水不能補注的情境下設置，其計算流程如圖 17。

本研究建置濁水溪流域 SWAT 模式後，進行流量參數率定與驗證，率定測站共有三個，分為 STN1（玉峰橋）、STN2（延平橋）、STN3（溪州大橋）（圖 18），率定期為 2002 ~ 2011 年，2012 ~ 2020 為驗證期，其中莫拉克風災所帶來之強降雨（三日累積降雨量 2,747 mm）導致模式無法有效評估集水區流量，因此在率定期末考慮莫拉克風災所帶來之流量峰值。

率定與驗證結果如表 6 所示，根據 Moriasi *et al.* [20] 之水文模式表現評級，模式在濁水溪流域率定及驗證期皆為滿意的 ($R^2 = 0.62 \sim 0.84$, $NSE = 0.6 \sim 0.84$, $PBIAS = -22.9 \sim 20.9\%$)。

建置濁水溪沖積扇 MODFLOW 之補注量與抽水量，根據前人研究蒐集，江崇榮 [21] 使用地下水歷線分析法推估 1999 ~ 2001 年濁水溪沖積扇平均年補注量約為 15.33 億噸，年抽水量 13.32 億噸，中興工程公司 [22] 利用需求推估法求得年補注量約為 8.12 億噸，水利署地層下陷防治專案服務計畫 [23] 利用水電比推估年補注量 14.31 億噸，年抽水量 15.35 億噸。本研究目前初步計算 2000 ~ 2021 年地下水流數值模式之年補注平均為 11.22 億噸，年抽水量平均為 15.43 億噸。

以系統動態模型方法評估水資源回復力

近年來，全球自然災害及極端氣候事件頻繁發生，造成許多經濟及社會成本不斷增加 [24]。其中，乾旱為影響人數眾多的天然災害之一 [25,26]，常帶來龐大的經濟損失。為了解氣候變遷對濁水溪流域農業永續發展的影響，本研究搜集 1995 年至 2020 年歷史氣象觀




圖 18 濁水河流域測站及子集水區分布圖

表 6 流量率定驗證結果

測站	期間	R ²	NSE	PBIAS (%)	模擬值平均 (實測值平均)	模擬值標準差 (實測值標準差)
STN1	率定期	0.73	0.73	-0.8	109.38 (110.27)	214.53 (237.94)
	驗證期	0.62	0.60	20.9	93.99 (118.82)	168.42 (246.70)
STN2	率定期	0.84	0.84	-10.4	6.34 (5.74)	15.88 (18.23)
	驗證期	0.74	0.74	7.8	5.35 (5.81)	14.19 (16.14)
STN3	率定期	0.72	0.73	-20.6	163.17 (135.33)	340.00 (392.64)
	驗證期	0.77	0.76	-22.9	146.10 (118.92)	291.95 (307.78)

測資料，以 3 個月的累積降雨呈現短期與土壤濕度相關的氣象以及農業乾旱特性，輔以 12 個月的累積降雨呈現與地表水及地下水流量、水庫蓄水量等水文乾旱特徵，分析長期的乾旱特性^[27,28]，結果發現所有的歷史事件皆能擬合乾旱指標，但許多乾旱指標視為乾旱的時間點，卻沒有發生相關乾旱的記錄，推測可能的原因有二：一為歷史乾旱事件為全國尺度而非區域級尺度，因此在紀錄上恐有落差。另一可能原因為乾旱指標本身之計算限制。

接著，本研究以水資源之供應方式將農業分為引水灌溉之水稻系統以及非引水灌溉之龍眼產業，以系統動力模型方法分析不同氣候條件下水資源對於農作物產量與產值之調控機制與交互作用，並搜集台灣氣候變遷推估與資訊平台所模擬 2021 ~ 2100 年之氣候推估資料，模擬未來氣候變遷下農作物之產量與產值，再利用情境分析^[29] 探討氣候變遷對農家經濟可能產生的衝擊，並評估未來氣候變遷下農業之韌性。結果發現在多數狀況下，氣候因子與產量間多呈現非線性關係，氣溫為影響

農作物物候階段與產量之關鍵因子，雨量對農作物產量則未具有高度相關性^[30]。而在極端氣候下，各氣候因子對農作物產量有明顯的影響，無論在何種暖化情境下，農作物之產量皆會下降，暖化情形越為嚴重，產量減少情況也更為嚴重。

然而暖化造成之減產將使農產品價格上漲，本研究利用所推估之農產品價格計算農產銷售收入，輔以政府提撥之天災現金救助及銀行之存款利息，扣除各情境下之生產成本、日常生活開銷、生產資料通膨等支出，推估農業生產利潤。模擬結果發現於不同的氣候變遷情境下，農家經濟狀況將出現不同之結果，有利潤縮減或虧損的可能，亦有出現利潤增加的情況；顯示在不同氣候情境下對農家生計所產生之風險並不相同，並非產量減損越多收益就會越少^[31]。然而於 2050 年以前，無論哪種氣候情境，大部分農家多能維持盈利的狀態，因此政府機關仍有約三十年之時間提前擬定減緩 (mitigation) 或調適 (adaptation) 策略，以協助農業之永續經營，降低農戶面臨氣候風險時的

衝擊^[32,33]，例如：開發耐熱品系或因應高溫環境的田間管理模式等策略、提供低利貸款、開辦農業保險、輔導農民轉作、吸引青農回鄉等，以維持農業的永續經營與運作。

由水源供應、地層下陷、水質改善探討水資源保育之社會與經濟效益

濁水溪沖積扇長年以來皆是台灣重要的農業生產區域，然其秋冬季節少雨的特性，使得地表水的供應有明顯季節性。相較台灣其他地區，此區域長久以來許多經濟活動皆相對高度地仰賴地下水資源，而也因此有廣泛地層下陷與地下水污染之問題。區域內供水吃緊的狀況，更隨近年民生與工業用水需求的提升而更加劇。為加強該地區供水之穩定性，經濟部水利署於民國 84 年完成位於雲林縣湖山水庫工程計畫之可行性評估，並於民國 91 年動工，最終在民國 105 年開始供應彰化與雲林地區之用水，興建工程總經費逾新台幣兩百億元。湖山水庫有效容量為全台第九，達五千萬立方公尺。

為達成資源的有效運用，各項公共投入皆應本於嚴謹之成本效益分析。本分析之目的即在於藉由估計湖山水庫完工後，對於該地區農業生產與農地價格之影響，評估湖山水庫為農業部門所帶來之經濟效益。具體而言，本研究利用農業部農糧署提供之民國 98 年至 108 年間的鄉鎮市區稻作生產資料，以及內政部實價登錄系統提供之自民國 102 年起的不動產交易資料，結合雙重差分（difference-in-differences）架構之迴歸模型，估計在湖山水庫於民國 105 年開始供水後，雲林與彰化縣之水稻生產面積與產量以及兩縣灌溉區內農地交易價格之變化。

以科學實驗角度觀之，湖山水庫並非隨機介入因子，在估計其介入效果（treatment effect）之時，若單純比較湖山水庫供水前後，雲林與彰化地區稻作生產與農地價格相關數據之變化，自然存在遺漏變數等問題，例如農地價格極可能與台灣總體經濟情勢相關，而稻作產量也必然受到天氣與氣候因子之影響^[34]。因此，在研究方法上，為將台灣總體經濟與農業部門等因素納入考量，如圖 19 所示，我們利用雙重差分架構，將台中市、南投縣、嘉義縣市、台南市、高雄市與屏東縣



圖 19 雙重差分法之實驗組與準控制組

等，在地理位置與社經條件較相近之縣市作為控制組，以準實驗（quasi-experiment）方法，估計在湖山水庫供水後，相較於控制組縣市，實驗組之彰化與雲林縣在稻作生產與農地價格上的變化。迴歸模型亦加入年份與鄉鎮市區固定效果（fixed effects），分別控制會影響所有研究納入縣市且隨時間變化之共同因子，以及各鄉鎮市區之土壤品質與產業結構等與農地價格相關之固定特徵。另一方面，在分析對稻作生產影響的迴歸模型中，為考量天氣與氣候因子對於水稻種植面積產量之影響，我們參考 Lobell *et al.*^[35] 與 Schlenker and Roberts^[36] 等探討氣候因子對作物生產影響之文獻，納入臺灣歷史氣候重建資料^[37] 建構之各稻作期別 3°C 氣溫區間，以及氣壓、雨量、相對濕度、日照量與風速之線性和平方項[†]；我們亦加入稻作期別之固定效果以考量一期與二期稻作生產之差異。

實證結果顯示，民國 105 至 108 年間，相較於控制組之縣市，彰化與雲林縣內之平均水稻產量上升了 3.24%（P-value = 0.001），然而水稻種植面積並沒有顯著地增加（3.95%，P-value = 0.611）。若以彰化與雲林縣在湖山水庫供水前之民國 98 至 104 年期間，每公

[†] 氣候變數來源為我們設定一期稻作生產期為一至六月，二期作為七至十二月；氣溫區間（temperature bins）以各稻作期之氣溫介於一氣溫區間之天數計算。

頃平均水稻產量 6,465 公斤以及兩期稻作總收成面積 89,908 公頃計算，湖山水庫供水後，彰化與雲林縣平均每年增加共 131,872 公噸之稻穀總產量，若再依據民國 105 年公告之公糧收購價格與濕乾穀折換率計算，平均每年稻米產值增加約新台幣 3.38 億元。在農地價格方面，實證結果顯示，相較於控制組縣市，彰化與雲林縣內之農地交易價格在湖山水庫啟用供水後平均上升 13.47% ($P\text{-value} = 0.006$)。若僅以在民國 102 至 104 年間非重複交易之彰化與雲林縣內農地總成交價值計算，湖山水庫供水後，使農地總價值增加約新台幣 65.9 億元新台幣。為進一步觀察湖山水庫供水對於彰化與雲林縣內農地交易價格影響之逐年變化，我們在圖 20 呈現以雙重差分架構之事件分析法估計所得之結果。圖 20 顯示，農地價格上漲主要發生於事件後的前三年，及民國 105 至 108 年間；同時，圖形也呈現彰化與雲林縣內農地價格在湖山水庫完工供水的前三年間便有微幅增加的趨勢，顯示農地價格趨勢可能存在預期心理效果。




圖 20 湖山水庫對彰化與雲林縣農地價格之影響

綜合以上，在供水後四年的研究資料期間內，湖山水庫在農業部門內便創造近新台幣 80 億元的經濟效益。在效益估計上，本研究假設種植面積未因更穩定之供水而增加，公糧收購價格亦傾向低估稻米價值，農地價值的提升也僅納入曾於供水前三年間發生交易之約 13,000 筆土地，因此我們認為所得之經濟效益可被視為相當保守的估計值。此外，本研究仍未考慮許多湖山水庫可能帶來之效益，如減緩地層下陷、提升飲用水質，以及強化地區工業用水供給等，該些效益之評估仍有待未來研究的投入。

結語

本綜合研究對於濁水溪流域研究各種關於社會經濟及環境議題，包含 (1) 地下水位的預測，從短期（日地下水位）、中期（旬地下水位）到長期（月地下水位），將可根據不同的需求應用不同的機器學習模式。(2) 稻作對地下水位的影響以及溫室氣體的排放量，本研究也提供了數種不同的灌溉策略，提供碳排之計算與比較。(3) 針對濁水溪水質對藥品生態毒性之研究，提供了另一種方式來分析水質對於新興污染物之影響，進一步討論對人類健康可能的潛在問題。(4) 應用 SAS 模式計算河水的新舊水組成比例有利於水資源管理，也發現高滲透性的地質有助於雨水滲透進地下水，減少了雨水短時間即流入河流之比例，因此降低新水的比例。(5) 藉由 MODFLOW 模式來推估濁水溪流域年補注量提供相關單位多一種對於水資源管理的參考，研究也發現年補注仍小於年抽水量，此結果並不利於永續水資源發展，相關單位也應該採取對應措施。(6) 藉由系統動力模型及氣候變遷情境分析，可以概括得到 2050 年前，不同的情境下，大部分農民仍能維持營利，但後續的氣候變遷所造成的衝擊仍需要政府相關單位開發新的策略、技術等來因應，達到農業永續的目標。(7) 使用雙重差分架構分析湖山水庫興建之後，對於彰化、雲林地區的社會經濟效益影響研究，結果顯示有正面的成效，後續可進一步研究減緩地層下陷、提升水質效益等相關議題。

藉由本綜合研究對於濁水溪整體綜覽相關議題，包含了自然科學、社會經濟等各方面研究，期望能對於台灣水資源、永續發展提供一個研究藍圖，在未來氣候變遷的影響下，找出一個與環境、經濟、人文共好的解方。

參考資料

1. Botter, G., E. Bertuzzo, and A. Rinaldo (2011). Catchment residence and travel time distributions: The master equation, *Geophys. Res. Lett.*, 38, L11403, doi:10.1029/2011GL047666
2. Rinaldo, A., Benettin, P., Harman, C.J., Hrachowitz, M., McGuire, K.J., van der Velde, Y., Bertuzzo, E. and Botter, G. (2015). Storage selection functions: A coherent framework for quantifying how catchments store and release water and solutes. *Water Resources Research*, 51(6), 4840-4847. <https://doi.org/https://doi.org/10.1002/2015WR017273>
3. Ebele, A.J., Abdallah, M.A., and Harrad, S. (2017). Pharmaceuticals

- and personal care products (PPCPs) in the freshwater aquatic environment. *Emerg Contam*, **3**, 1e16.
4. Lai, W.W.P., Lin, Y.C., Wang, Y.H., Guo, Y.L., and Lin, A.Y.C. (2018). Occurrence of emerging contaminants in aquaculture waters: cross-contamination between aquaculture systems and surrounding waters. *Water, Air, & Soil Pollut*, **229**, 249.
5. Pai, C.W., Leong, D., Chen, C.Y., and Wang, G.S. (2020). Occurrences of pharmaceuticals and personal care products in the drinking water of Taiwan and their removal in conventional water treatment processes. *Chemosphere*, **256**, 127002.
6. Bayabil, H.K., Teshome, F.T., and Li, Y.C. (2022). Emerging contaminants in soil and water. *Front Environ Sci* **10**, 873499.
7. 盧虎生、姚銘輝、呂學榮、王淑音 (2017)，第六章 糧食生產和糧食安全，載於童慶斌編，臺灣氣候變遷科學報告 2017—衝擊與調適面向 (頁 335-372)，臺北市：國家災害防救科技中心。
8. LeCun, Y. and Bengio, Y. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, **3361**(10), 1995.
9. Kow, P.Y., Lee, M.H., Sun, W., Yao, M.H., and Chang, F.J. (2022). Integrate deep learning and physically-based models for multi-step-ahead microclimate forecasting. *Expert Systems with Applications*, **210**, 118481.
10. Shreyak. (2020). Becoming Human: Artificial Intelligence Magazine.
11. Vaswani, A., Shazeer, N.M., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is All you Need. NIPS.
12. Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., and Zagoruyko, S. (2020). End-to-End Object Detection with Transformers. ArXiv. /abs/2005.12872
13. Kao, I.F., Zhou, Y., Chang, L.C. and Chang, F.J. (2020). Exploring a Long Short-Term Memory based Encoder-Decoder framework for multi-step-ahead flood forecasting. *Journal of Hydrology*, **583**, pp.124631.
14. Zhuang, Y., L. Zhang, S. Li, H. Liu, L. Zhai, F. Zhou, Y. Ye, S. Ruan, and W. Wen (2019). Effects and potential of water-saving irrigation for rice production in China, *Agricultural Water Management*, **217**, 374-382. <https://doi.org/10.1016/j.agwat.2019.03.010>
15. Dong, B., Z. Mao, Y. Cui, Y. Luo, and Y. Li (2020). Controlled Irrigation for Paddy Rice in China, *Irrigation and Drainage*, **69**(S2), 61-74. <https://onlinelibrary.wiley.com/doi/10.1002/ird.2519>
16. Berkelaar, D. (2001). SRI, the system of rice intensification: less can be more, *ECHO Development Notes*, **10**(70), 1-7
17. Uphoff, N., I. Anas, O. Rupela, A. Thakur, and T. Thiagarajan (2009). Learning about positive plant-microbial interactions from the system of rice intensification (SRI), *Aspects of Applied Biology*, **98**, 29-54.
18. Thakkar, S., Seetharaman, B., and Ramasamy, V. (2022). Impact of chronic sub-lethal methylparaben exposure on cardiac hypoxia and alterations in neuroendocrine factors in zebrafish model. *Mol Biol Rep*, **49**, 331-340.
19. Nagar, Y., Thakur, R.S., Parveen, T., Patel, D.K., Ram, K.R., and Satish, A. (2020). Toxicity assessment of parabens in *Caenorhabditis elegans*. *Chemosphere*, **246**, 125730.
20. Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Haemel, R.D., and Veith, T.L. (2007). Model evaluation guidelines for systematic qualification of accuracy in watershed simulation. *Transaction of ASABE*, **50**, 282-290.
21. 江崇榮、黃智昭、陳瑞娥 (2006)，以地下水歷線分析法評估濁水溪沖積扇之地下水收支，經濟部中央地質調查所彙刊，第十九號，第 61-89 頁。
22. 中興工程顧問股份有限公司 (2007)，濁水溪沖積扇地面地下水聯合運用管理模式建立與機制評估，經濟部水利署中區水資源局委託計畫報告。
23. 經濟部水利署 (2017)，106 年度地層下陷防治專案服務計畫。
24. Wang, K. and Zhang, A. (2018). Climate change, natural disasters and adaptation investments: Inter-and intra-port competition and cooperation. *Transportation Research Part B: Methodological*, **117**, 158-189.
25. Wilhite, D.A. and Glantz, M.H. (1985). Understanding: the drought phenomenon: the role of definitions. *Water international*, **10**(3), 111-120.
26. Wilhite, D.A. (2000). Drought as a natural hazard: concepts and definitions. In: Wilhite, D.A. (Ed.), *Drought: A Global Assessment*, Vol. 1. Routledge, New York, pp. 1-18.
27. 李昱祺、王嘉琪、翁叔平、陳正達、鄭兆尊 (2019)，臺灣氣象乾旱特性未來趨勢推估 (Future Projections of Meteorological Drought Characteristics in Taiwan)，大氣科學，**47**(1)，66-93. <https://doi.org/10.3966/025400022019034701003>
28. Cavus, Y. and Aksoy, H. (2020). Critical drought severity/intensity-duration-frequency curves based on precipitation deficit. *Journal of Hydrology*, **584**(14), Article 124312. <https://doi.org/10.1016/j.jhydrol.2019.124312>.
29. Meinshausen, H. (2019). Implications of the Developed Scenarios for Climate Change. In Teske (Eds.), *Achieving the Paris Climate Agreement Goals* (pp. 459-469). Springer International Publishing AG.
30. Holzkämper, A., Calanca, P., and Fuhrer, J. (2012). Statistical crop models: predicting the effects of temperature and precipitation changes. *Climate research*, **51**(1), 11-21.
31. 陳世芳 (2019)，做好農作物生產成本收益分析：開源節流量入為出，臺中區農業專訊，**105**，7-10。
32. Kulshreshtha, S. and Wheaton, E. (2013). Climate change adaptation and food production in Canada: Some research challenges. *WIT Transactions on Ecology and the Environment*, **170**, 101-112.
33. Ho, S.-T., Ifft, J.E., Rickard, B.J., and Turvey, C.G. (2018). Alternative Strategies to Manage Weather Risk in Perennial Fruit Crop Production. *Agricultural and resource economics review*, **47**(3), 452-476.
34. Bishop, K.C., Kuminoff, N.V., Banzhaf, H.S., Boyle, K.J., von Gravenitz, K., Pope, J.C., and Timmins, C.D. (2020). Best practices for using hedonic property value models to measure willingness to pay for environmental quality. *Review of Environmental Economics and Policy*, **14**(2), 260-281.
35. Lobell, D.B., Roberts, M.J., Schlenker, W., Braun, N., Little, B.B., Rejesus, R.M., and Hammer, G.L. (2014). Greater sensitivity to drought accompanies maize yield increase in the US Midwest. *Science*, **344**(6183), 516-519.
36. Schlenker, W. and Roberts, M.J. (2009). Nonlinear temperature effects indicate severe damages to US crop yields under climate change. *Proceedings of the National Academy of Sciences*, **106**(37), 15594-15598.
37. 簡毓瑋、林士堯 (2023)，過去變遷測站資料說明文件 (1.4 版)，臺灣氣候變遷推估資訊與調適知識平台 (擷取日期：2023 年 8 月 7 日)：https://tccip.ncdr.nat.gov.tw/upload/data_profile/20210702170602.pdf 



茲附上廣告式樣一則
請按下列地位刊登於貴會出版之「土木水利」雙月刊

此致
社團法人中國土木工程學會

「土木水利」雙月刊
廣告價目表

(費率單位：新台幣元)

刊登位置	金額 (新台幣元)	敬請勾選
封面全頁 彩色	60,000	
內頁中間跨頁 彩色	80,000	
封底全頁 彩色	50,000	
封面裏／封底裏 全頁彩色	40,000	
內頁全頁 彩色 (直式)	30,000	
內頁半頁 彩色 (橫式)	15,000	
內頁 1/4 頁 彩色 (直式)	8,000	
折扣	3 期 9 折， 4 期以上 8.5 折	

刊登月份：

○ 51.2 ○ 51.3 ○ 51.4 ○ 51.5 ○ 51.6 ○ 52.1 共 次
(4月) (6月) (8月) (10月) (12月) (2月)

註：稿件請提供設計完稿之廣告稿；
相片、圖片等請提供清楚原件或電腦檔。

上項廣告費計新台幣 元整

隨單繳送請查收掣據
請於刊登後檢據洽收

機構名稱： (請蓋公司印)
商號

負責人：

地 址：

廣告聯絡人：

電 話：

廣告訂單聯絡：社團法人中國土木工程學會 電話：(02) 2392-6325 email: service@ciche.org.tw

98-04-43-04

郵政劃撥儲金存款單

收款帳號	0	0	0	3	0	6	7	8	金 額 新台幣 (小寫)	仟	萬	佰	萬	拾	萬	仟	佰	拾	元
------	---	---	---	---	---	---	---	---	--------------------	---	---	---	---	---	---	---	---	---	---

通訊欄 (限與本次存款有關事項)

繳納會費

- ☐ 常年會員年費 1,200 元
☐ 初級會員年費 300 元

訂閱土木水利雙月刊，一年六期

- ☐ 國內・個人會員 新台幣 300 元
☐ 國內・非會員及機關團體 新台幣 1,800 元
自第 卷第 期起， 年期雙月刊 份

訂閱中國土木工程學刊，一年八期

- ☐ 國內・個人會員 新台幣 1,600 元
☐ 國內・非會員及機關團體 新台幣 3,600 元
☐ 國外・個人 美金 80 元
☐ 國外・機關團體 美金 200 元
自第 卷第 期起 年期學刊 份

收款戶名	社團法人中國土木工程學會	
寄 款 人	主管：	
姓 名		
地 址	□□□—□□	
電 話	經辦局收款戳	

虛線內備供機器印錄用請勿填寫

- ◎ 寄款人請注意背面說明
◎ 本收據由電腦印錄請勿填寫

郵政劃撥儲金存款收據

收款帳號戶名	
存款金額	
電腦紀錄	
經辦局收款戳	

社團法人中國土木工程學會

信用卡繳納通知書

姓 名		款 別 註：入會時請先填入會申請書，傳真學會審查，我們會立即通知您，資格符合時請繳費， <u>入會費一人僅需繳交一次</u>	繳納會費 ☐ 常年會員年費 1,200 元 ☐ 初級會員年費 300 元
會員證號碼			訂閱土木水利雙月刊，一年六期 ☐ 國內・個人會員 新台幣 300 元 ☐ 國內・非會員及機關團體 新台幣 1,800 元 自第__卷第__期起，__年期雙月刊__份
身分證號碼			訂閱中國土木水利工程學刊，一年八期 ☐ 國內・個人會員 新台幣 1,600 元 ☐ 國內・非會員及機關團體 新台幣 3,600 元 ☐ 國外・個人 美金 80 元 ☐ 國外・機關團體 美金 200 元 自第__卷第__期起__年期學刊__份
卡 別 ☐ VISA ☐ MASTER CARD ☐ JCB			白天聯絡電話
信用卡卡號			通訊地址
信用卡末三碼			
信用卡有效期限 (月 / 年)			
信用卡簽名			
繳費金額			

回覆請利用傳真：(02) 2396-4260 或 email：service@ciche.org.tw

回覆後請務必電話：(02) 2392-6325 確認，謝謝！

郵政劃撥存款收據

注意事項

- 一、本收據請詳加核對並妥為保管，以便日後查考。
- 二、如欲查詢存款入帳詳情時，請檢附本收據及已填妥之查詢函向各連線郵局辦理。
- 三、本收據各項金額、數字係機器印製，如非機器列印或經塗改或無收款郵局收訖章者無效。

請 寄 款 人 注 意

- 一、帳號、戶名及寄款人姓名地址各欄請詳細填明，以免誤寄；抵付票據之存款，務請於交換前一天存入。
- 二、每筆存款至少須在新台幣十五元以上，且限填至元位為止。
- 三、倘金額塗改時請更換存款單重新填寫。
- 四、本存款單不得黏貼或附寄任何文件。
- 五、本存款金額業經電腦登帳後，不得申請撤回。
- 六、本存款單備供電腦影像處理，請以正楷工整書寫並請勿摺疊。帳戶如需自印存款單，各欄文字及規格必須與本單完全相符；如有不符，各局應婉請寄款人更換郵局印製之存款單填寫，以利處理。
- 七、本存款單帳號與金額欄請以阿拉伯數字書寫。
- 八、帳戶本人在「付款局」所在直轄市或縣(市)以外之行政區域存款，需由帳戶內扣收手續費。

交易代號：0501、0502現金存款 0503票據存款 2212劃撥票據託收

本聯由儲匯處存查 600,000 束 (100 張) 94.1.210 × 110mm (80g/m² 模) 保管五年 (拾大)

你的付出被看見

113年3月6日 水利署於台中金典酒店舉辦「水利職人交流分享餐會」

經濟部水利署於110年起辦理「全國水利工班職人大賞」評選活動，期透過競賽方式，鼓勵工程第一線工班人員，運用工法攝影及解說，展現施工技術、品質、技巧、創意，以提升水利工程品質、職人精神推廣與技術傳承，並建立優良認證機制，將得獎工班履歷建置於水利工程計畫透明網，以增加工作之媒合機會。

至112年度已完成3屆「全國水利工班職人大賞」活動，每年皆評選出石工、泥作、模板3類職人各1人，3年計9位職人，水利署為每位職人拍攝專屬影片，每位職人皆於拍攝訪談時侃侃而談其人生哲學，以及身為職人的工作態度，年輕職人更自學新科技、新工法結合於工作上，使工作起來事半功倍。

水利署特舉辦本次分享會，希冀將職人精神繼續推廣與技術傳承，公開分享並賦予職人至高的榮耀。

現場看板



氣勢恢弘

第1屆全國水利工班職人大賞

石工類：陳俊銘
模板類：王元賓
泥作類：侯振宏

第2屆全國水利工班職人大賞

石工類：陳進義
模板類：白桐輝
泥作類：郭瑞鴻

第3屆全國水利工班職人大賞

石工類：林哲偉
模板類：黎煥仁
泥作類：易廷敬



高宗正理事長參與盛會與有榮焉，鼓勵推廣職人教育。



宋裕祺前理事長感動職人精神，默默付出終受肯定。



泥作類人：易廷敬

行善積德，上天不會虧待你。



石工類人：林哲偉



石工類人：陳俊銘

人生的過程，就像疊石頭，基礎要夠紮實。
人必有所執，方能有所成。



賴建信署長勉勵所有水利工班職人



模板類人：白桐輝

盡力做到完美，盡力做到最好。



模板類人：黎煥仁

不要怕失敗，從錯誤中成長。



水利署表揚基層職人，促進一線工班專業技術與傳承，續寫職人精神！



水利署相關報導

夢想和幸福

零距離的接軌

技術必須經得起考驗，專業來自於永不妥協的堅持，
夢想的城堡、幸福的家園，就座落在不遠的前方，
台灣世曦和您一起攜手而行，用築夢的心、關懷的情，
戮力建設出每一項希望的工程。



Creativity · Excellence · Conservation · Integrity

CECI



台灣世曦
工程顧問股份有限公司

台北市11491內湖區陽光街323號

Tel: (02) 8797 3567 Fax: (02) 8797 3568

<http://www.ceci.com.tw> E-mail: pr@ceci.com.tw