

結合遷移學習和深度學習於水庫入流量預報之研究

Reservoir inflow forecasting by integrating transfer learning and deep learning

國立臺灣大學土木工程學系

碩士研究生

特聘教授

博後研究員

博士研究生

高家浩

林國峰

張明瑞

曾元福

Chia-Hao Kao

Gwo-Fong Lin

Ming-Jui Chang

Yuan-Fu Zeng

摘 要

台灣位於西太平洋颱風路徑要衝，夏秋兩季經常受到颱風侵襲，平均每年約遭受 3.3 個颱風侵襲，伴隨颱風而來的豐沛雨量，在集水區短時間產生大量逕流，增加管理機關操作的不確定性，並提高水庫防洪運轉策略研擬困難度。以深度學習建立入庫流量模式需要集水區相關資料，然而部分集水區資料相對稀少則無法有效地預測，可能的原因包含雨量站的資料缺失和歷史颱風事件的稀少，增加其預報的困難度。爰此，本研究是以臺灣數個水庫(石門水庫、翡翠水庫)作為研究區域，結合深度學習和遷移學習來進行入庫流量預報，以提升預報準確性。本研究提出之深度學習模式在適應足夠大的源域數據集後，將預訓練模型的權重重新用於資料稀少但有相似目標的數據集，以提高其他流域之模式表現，本研究探討目標域地理條件及水文條件與源域之相關性，並採用評鑑指標以評估模式表現。結果顯示，本研究所提出之入庫流量預報模式可有效解決目標區域資料稀少的問題，提升入庫流量預報之準確度，不同集流時間集水區則可透過遷移學習提升不同臨前時間輸入因子模型之準確性。可供未來水庫相關單位擬訂水庫操作策略之重要依據，作為水利防救災預警工作時之重要參考。

關鍵字：流量預報、水庫、深度學習、遷移學習、防洪運轉

Abstract

Taiwan is located on one of the main paths of northwestern Pacific typhoons. According to the Central Weather Bureau, on average, 3.3 typhoons per year had struck Taiwan. The heavy rainfall caused by typhoons often results in severe floods in the watershed. For flood warning system, an accurate forecast of reservoir inflow is necessary to reduce the difficulty of the operating strategy. Deep learning has demonstrated as an effective method to forecast reservoir inflow. However, forecasts in some reservoir watersheds are limited to the lack of observation data for typhoon events. Hence, a novel technique for forecasting of reservoir inflow is proposed in this study. Transfer Learning (TL) is used to improve the performance of reservoir

inflow forecasting in reservoir watershed with data-sparse through fine-tuning and parameter transferring. Several deep learning models are adopted to fit a sufficiently large source domain dataset and repurpose the learned weights to smaller datasets. The correlation between the geographical and hydrological conditions of the target domain for transfer learning and the source domain was discussed in this study. The proposed model is expected to provide more accurate forecasts of reservoir inflow for disaster prevention.

Keywords: reservoir, inflow forecasting, deep learning, transfer learning, operation of reservoir flood control

一、前言

台灣因受地形及降雨時空分布不均之影響，致使水資源捉襟見肘，雖位處於西太平洋颱風路徑要衝，平均每年約遭受 3.3 個颱風侵襲，且近年受氣候變遷加劇導致降雨延時短、強度高之趨勢，在降雨期間，水庫管理單位採高水位操作以確保台灣地區水庫蓄水量充足，導致水庫潰壩風險提升，易造成管理機關操作的不確定性，並提高水庫防洪運轉策略研擬困難度。

而過去對水庫入庫流量預報可分為兩種，分別是根據物理機制所建置之物理模式，以數學表達式來描述水文現象的物理過程；另一種是黑盒模式(又稱為機器學習法)，不同於物理模式需根據其物理性質輸入各個水文參數與邊界條件來建立模型，機器學習法透過演算法來解決各種非線性的問題，由模式透過巨量資料分析得出輸入資料間的關係與各屬性之間的關聯，近年來深度學習已被證明為可靠而且更為快速的方法，並廣泛應用於水文領域。

一般而言，深度學習網路在訓練時仰賴大量數據，當樣本數太少時常面臨過度擬合的情形。使模型在訓練資料上表現良好但在測試資料上預測不準確，而在水文領域研究中，常遇到資料不足的問題，其原因可能包含測站的資料缺失和建置數不足，在建立颱風入庫流量預報模式時，常因歷史颱風事件的稀少性增加預報上的難度，無法有效地預測。遷移學習 (Transfer Learning) 被認為可以解決資料不足的問題，主要將源領域已經訓練好的知識轉移到另一個目標領域，使得目標領域能夠有更好的表現，而當目標領域訓練資料與源領域有高度相關時，此方法可有效解決目標樣本不足的問題。考量水庫入流量為時間序列資料，在序列特性的神經網絡架構中是以遞迴神經網路最具代表性，遞迴神經網路對於序列數據的元素進行相同操作，網絡的輸出將取決於前一單元之計算，而後續衍生出長短期記憶模型 (Long short-term memory, LSTM) 及門閘遞迴單元(Gate Recurrent Unit, GRU)兩種模式，皆是利用開門的開關記憶資料加個敘述，因此本研究選用具有序列特性的三種深度學習模式作為主要水庫入流量預報之模式建模。

本研究以 4 種深度學習模式預報未來 1 至 6 小時之水庫入流量，並在石門水庫和翡翠水庫間進行遷移學習優化模型，模式之表現經過評鑑指標評估。本研究主要分為三個步驟：(1)比較不同深度學習模式表現(2)比較有遷移學習之深度學習模式和無遷移學習模型間差異(3)比較不同模型時間輸入項對於不同稽延時間之集水區影響。

二、研究區域與資料

本研究以石門水庫和翡翠水庫作為研究區域，兩水庫分述如下：

石門水庫為台灣第三大水庫，位於桃園市龍潭區大漢溪中游，集水區總面積達 763.4 平方公里，為台灣首座多目標水庫，兼具灌溉、給水、發電、調洪及休閒觀光等功能。本研究蒐集經濟部水利署管轄石門水庫集水區之八個雨量站，集水區內計八個雨量站分別為石門、霞雲、高義、巴陵、嘎拉賀、玉峰、白石、鎮西堡，並利用徐昇式多邊形法 (Thiessen's polygon method) 計算集水區內之平均雨量作為模型輸入，羅浮測站為石門水庫之入庫測站，利用庫區水位計量測之水位資料及量測之出流量搭配石門水庫之 H-A-V 曲線計算水庫入流量，以作為石門水庫入庫流量之輸入。

翡翠水庫位於台灣北部新店溪支流北勢溪上，集水區總面積 303 平方公里，為台灣第二大水庫，為台北地區重要水源，與石門水庫同為淡水河防洪系統重要一環，本研究蒐集台北翡翠水庫管理局之雨量與流量資料建構水庫入流量預報，六個雨量站分別為翡翠、十三股、九芎根、坪林、碧湖、太平，流量使用翡翠水位站量測之時入流量資料。

三、研究方法

3.1 深度神經網路

深度神經網路(DNN)為機器學習的一個分支，最早由 Hinton 等人提出「深度學習的概念」，深度神經網路具有輸入層、輸出層和多層隱藏層的神經網路，每一層包含活化函數，用來模擬生物神經元的門檻值，轉化輸入訊息疊加後的輸出值範圍，可將資訊提供給下一層用於預測工作，在非線性回歸問題上有優良表現。近年來由於資料量的增加以及圖形處理器技術的逐漸成熟，使需要大量資料訓練且耗時長時間的深度學習，逐漸成為人工智慧領域的主流。

3.2 遞迴神經網路

遞迴神經網路(Recurrent Neural Network, RNN)最早由 Elman 在 1990 年提出，通常含有一個或多個「回饋迴圈」，不同傳統的靜態前饋式的網路架構，允許神經元之間相互回饋，RNN 更接近生物神經系統，因回饋項提供記憶功能，動態類神經網路可模擬具有時變性的系統，為一種專門設計來解決時間相關問題的神經網路。然而 RNN 因為無法處理權重指數級爆炸或梯度消失問題，難以捕捉長期時間關聯，因此後續發展出的 LSTM 和 GRU 可有效解決梯度消失的問題。

3.3 長短期記憶網路架構

長短期記憶網路(LSTM)在 1997 年由 S. Hochreiter 等人發表，是一種特殊的 RNN，主要為了解決長序列訓練過程中的梯度消失和梯度爆炸問題。LSTM 引入了記憶細胞(memory cell) 以及閥 (gate) 的概念，將隱藏層中的神經元改成由一組遞迴連接的子網路組成為記憶細胞，LSTM 透過三個控制閥(輸入閥、遺忘閥、輸出閥) 組成來決定將什麼資料保存下來與捨棄遺忘，當將特徵輸入時，輸入閥會去控制是否將這次的值輸入；輸出閥控制是否將這次計算出來的值輸出到下一節點；遺忘閥對上一個節點傳進來的輸

入進行選擇性忘記。在 LSTM 神經網路的計算中往往會堆積 LSTM 的隱藏層來模擬較為複雜的水文時間序列資料。

3.4 門閘遞迴單元

門閘遞迴單元(GRU)在 2014 年由 Kyunghyun Cho 發表，GRU 相較於 LSTM 提高了執行速度與減少記憶體用量，其簡化了閘門的結構，GRU 只有兩個閘，分別為更新閘(reset gate)與重置閘(update gate)，更新閘控制該用多少比例的上一個 hidden state $h(t-1)$ 來和新讀入的 input $x(t)$ 計算下一個準 hidden state。重置閘調配準 hidden state 與上一個 hidden state $h(t-1)$ 的比例，來得到最終的 hidden state。GRU 同時也將細胞狀態(Cell State)和隱藏狀態(Hidden State)合併，參數較 LSTM 少更易於運算。

3.6 遷移學習

遷移學習最早在 1993 年被 Lorian Pratt 制定，並在 1997 年機器學習期刊發表討論。遷移學習(Transfer learning)從源領域抽取已經訓練好的知識、經驗，轉移到另一個目標領域(Target domain)，使目標領域能夠有更好表現。當源領域的訓練資料充足且有標記，但目標領域訓練資料稀少且與訓練資料有高度相關時，透過遷移學習，可解決樣本不足的問題。微調(fine-tuning)是遷移學習常用的方法，常被用於圖像分類任務中，其中一個方法為 Conservative Training，在新的模型加入一些正則化項，限制新模型與源模型盡量得到相同的輸出，可防止過擬合發生，如拿掉限制項可能發生災難性遺忘；另一種為 Layer Transfer，將源域訓練好的模型中的特定幾層萃取，在用目標域訓練其他幾層的參數，Layer Transfer 常應用於語音識別和圖片辨識問題。

四、模式建立

4.1 模式建置

本研究目的為建置最佳之水庫入庫流量預報模式，探討加入遷移學習對於深度學習模型之影響，分為無結合遷移學習之深度學習與有結合遷移學習之深度學習。前者首先進行研究區域資料之蒐集，輸入因子為時雨量和時流量，而後利用 Python 的 Keras 深度學習庫分別建立四種深度學習模型，並使用多步階預報建立未來 1~6 小時入流量，透過模型訓練和測試，由評鑑指標評估模式表現。有結合遷移學習之深度學習則是先在源域以源域資料訓練模型，再將模型參數權重轉移至目標域模型，再以目標域訓練資料進行訓練和測試，由評鑑指標評估模式表現(如圖 1 所示)。




圖 1、遷移學習流程圖

4.2 因子篩選

集水區之水文及地文條件會影響其水文模式輸入因子，以水庫入流量預報來說，須根據其集水區之集流時間設定雨量與流量臨前時間。在遷移學習中，當源域之集流時間與目標域之集流時間不相同時，需調整模型輸入因子的臨前時間。研究區域中石門水庫的集流時間大於翡翠水庫，因此本研究探討遷移學習下源域與目標域之集流時間不同對模式表現之影響，模式因子方面分別選擇臨前 2~7 小時之時雨量與時入流量作為模式輸入項，並由評鑑指標評估模式表現(如表 1 所示)。

入庫流量 預報模型	臨前時 間(小時)	輸入因子
DNN	2	$R(t+1), R(t_0), Q(t), Q(t-1)$
	3	$R(t+1), R(t_0), R(t-1), Q(t), Q(t-1), Q(t-2)$
LSTM	4	$R(t+1), R(t_0), R(t-1), R(t-2), Q(t), Q(t-1), Q(t-2), Q(t-3)$
	5	$R(t+1), R(t_0), R(t-1), R(t-2), R(t-3), Q(t), Q(t-1), Q(t-2), Q(t-3), Q(t-4)$
RNN	6	$R(t+1), R(t_0), R(t-1), R(t-2), R(t-3), R(t-4), Q(t), Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5)$

GRU	7	R(t+1),R(t0),R(t-1),R(t-2),R(t-3),R(t-4),R(t-5),Q(t)Q(t-1),Q(t-2),Q(t-3),Q(t-4),Q(t-5),Q(t-6)
	8	R(t+1),R(t0),R(t-1),R(t-2),R(t-3),R(t-4),R(t-5),R(t-6),Q(t),Q(t-1),Q(t-2),Q(t-3),Q(t-4),Q(t-5),Q(t-6),Q(t-7)

表 1、各模式不同臨前時間之輸入項。

五、結果與討論

5-1 遷移學習對於深度學習模型之影響

5-1-1 從石門水庫遷移到翡翠水庫

表 2 和表 3 呈現的石門水庫各模式有無結合遷移學習的各項評鑑指標，表 4 呈現加入遷移學習前後的改善幅度，由評鑑指標 RMSE 可得知 DNN 和 LSTM 整體進步幅度最大，在未來 T+6 小時預報中 RMSE 分別進步 8%和 14%，相較之下 RNN 和 GRU 則無明顯進步，而評鑑指標 CE 和 CC 指數約都在 0.8 以上。

從表 3 可觀察到遷移學習在短期預報中進度幅度不明顯，各項指標約進度 2%以內，但在長期預報(T+6)中有顯著進步，DNN 的評鑑指標 MAE 進步幅度高達 44%，顯示遷移學習結合深度學習可有效改善翡翠水庫長期預報。從圖 2 可觀察到 DNN 結合遷移學習於杜鵑颱風期間的未來 T+6 預報中，峰值較接近觀測值，且退水段相比無遷移學習模式較準確。

預報時間 (小時)	模式	RMSE	MAE	CE	CC
T+1	DNN	109.59	58.76	0.95	0.98
	LSTM	119.78	60.78	0.94	0.97
	RNN	135.97	62.78	0.92	0.96
	GRU	121.06	54.42	0.93	0.97
T+3	DNN	141.81	88.29	0.91	0.96
	LSTM	149.74	98.67	0.90	0.96
	RNN	179.26	103.31	0.86	0.93
	GRU	145.72	80.89	0.91	0.95
T+6	DNN	171.21	121.67	0.88	0.95
	LSTM	193.17	146.75	0.84	0.94
	RNN	215.47	137.62	0.81	0.90
	GRU	171.93	108.86	0.88	0.94

表 2、翡翠水庫深度學習模式之評鑑指標

預報時間 (小時)	模式	RMSE	MAE	CE	CC
T+1	DNN	108.88	46.49	0.95	0.97
	LSTM	118.31	58.99	0.94	0.97
	RNN	131.92	65.68	0.92	0.96
	GRU	120.81	53.62	0.93	0.97
T+3	DNN	135.52	58.11	0.92	0.96
	LSTM	148.14	90.89	0.90	0.95
	RNN	177.86	121.03	0.86	0.93
	GRU	146.14	80.38	0.91	0.95
T+6	DNN	146.97	67.69	0.91	0.96
	LSTM	177.63	121.86	0.87	0.93
	RNN	230.41	182.66	0.78	0.90
	GRU	173.57	109.91	0.87	0.93

表 3、翡翠水庫深度學習結合遷移學習模式之評鑑指標

預報時間 (小時)	模式	RMSE (%)	MAE	CE	CC
T+1	DNN	0.65%	20.89%	0.07%	-0.19%
	LSTM	1.23%	2.95%	0.17%	-0.08%
	RNN	2.98%	-4.61%	0.53%	0.32%
	GRU	0.21%	1.47%	0.03%	0.02%
T+3	DNN	4.44%	34.18%	0.85%	-0.32%
	LSTM	1.07%	7.88%	0.23%	-0.62%
	RNN	0.78%	-17.15%	0.26%	0.38%
	GRU	-0.29%	0.62%	-0.06%	-0.03%
T+6	DNN	14.16%	44.37%	3.7%	0.2%
	LSTM	8.04%	16.96%	2.9%	-0.5%
	RNN	-6.93%	-32.73%	-3.5%	-0.2%
	GRU	-0.95%	-0.96%	-0.3%	-0.1%

表 4、翡翠水庫深度學習結合遷移學習模式之評鑑指標改善幅度






圖 2、翡翠水庫於杜鵑颱風期間 DNN 模式 T+1、T+3、T+6 之歷線比較

5-1-2 從翡翠水庫遷移到石門水庫

表 5 和表 6 呈現的石門水庫各模式有無結合遷移學習的各項評鑑指標，表 7 呈現加入遷移學習前後的改善幅度，由評鑑指標 RMSE 可觀察到 DNN 進步最多，在未來 T+1、T+3、T+6 小時預報中 RMSE 分別進步 9%、14%和 22%。整體而言在石門水庫地區，遷移學習在 DNN、LSTM、RNN、GRU 模型中，評鑑指標 RMSE 平均進度幅度為 5.9%，顯示各模型不管是未來 T+1、T+3、T+6 小時預報中皆可得到改善。從圖 3 可觀察到石門水庫 GRU 模型於梅姬颱風期間 T+6 小時預報中，兩個模型在漲水段皆有高估情形，無法準確預測峰值到達時間，但結合遷移學習後模式之峰值較接近觀測值。

預報時間 (小時)	模式	RMSE	MAE	CE	CC
T+1	DNN	143.66	94.60	0.97	0.99
	LSTM	130.74	74.87	0.98	0.99
	RNN	141.18	82.27	0.97	0.99
	GRU	137.09	76.09	0.98	0.99
T+3	DNN	267.33	181.05	0.91	0.97
	LSTM	241.10	146.10	0.93	0.97
	RNN	319.95	194.06	0.87	0.94
	GRU	266.29	149.63	0.91	0.96
T+6	DNN	407.05	282.45	0.80	0.96
	LSTM	310.31	205.22	0.88	0.96
	RNN	426.08	301.88	0.78	0.90
	GRU	321.22	211.83	0.88	0.95



表 5、石門水庫深度學習模式之評鑑指標

預報時間 (小時)	模式	RMSE	MAE	CE	CC
T+1	DNN	130.76	79.94	0.98	0.99
	LSTM	128.87	76.62	0.98	0.99
	RNN	132.96	75.89	0.98	0.99
	GRU	125.58	70.03	0.98	0.99
T+3	DNN	229.72	145.17	0.93	0.97
	LSTM	239.37	155.38	0.93	0.96
	RNN	311.6	175.15	0.88	0.94
	GRU	254.97	145.19	0.92	0.96
T+6	DNN	317.27	215.39	0.88	0.95
	LSTM	301.51	217.88	0.89	0.95
	RNN	439.38	285.86	0.77	0.9
	GRU	312.35	208.44	0.88	0.95

表 6、石門水庫深度學習結合遷移學習模式之評鑑指標

預報時間 (小時)	模式	RMSE	MAE	CE	CC
T+1	DNN	8.98%	15.50%	0.46%	-0.01%
	LSTM	1.43%	-2.34%	0.06%	-0.05%
	RNN	5.83%	7.75%	0.30%	0.18%
	GRU	8.40%	7.97%	0.40%	0.15%
T+3	DNN	14.07%	19.82%	2.56%	-0.09%
	LSTM	0.72%	-6.35%	0.11%	-0.38%
	RNN	2.61%	9.74%	0.75%	0.70%
	GRU	4.25%	2.97%	0.81%	0.15%
T+6	DNN	22.06%	23.74%	9.74%	-0.22%
	LSTM	2.83%	-6.17%	0.73%	-0.75%
	RNN	-3.12%	5.31%	-1.77%	0.28%
	GRU	2.76%	1.60%	0.77%	-0.18%

表 7、石門水庫深度學習結合遷移學習模式之評鑑指標改善幅度






圖 3、石門水庫 GRU 模式於梅姬颱風期間 T+1、T+3、T+6 之歷線比較

5-2 水庫集水區集流時間對遷移學習之影響

本研究探討水庫集水區集流時間對遷移學習之影響，故挑選各水庫最佳入流量預報模式，分別挑選翡翠水庫的 DNN 模型及石門水庫 LSTM 模式建立未來 T+6 小時模式。表 8 和表 9 分別呈現石門水庫遷移到翡翠水庫和翡翠水庫遷移到石門水庫的結果，從表 10 和表 11 中可觀察到翡翠水庫在輸入因子臨前時間為 4 小時和 5 小時改善幅度較大，RMSE 進步幅度為 5%~14%。表中可觀察到石門水庫在輸入因子臨前時間為 2 小時和 3 小時改善幅度較大，MAE 約改善 5%~14%，從上述可知石門水庫遷移到翡翠水庫後，集流時間較短的翡翠水庫在輸入因子臨前時間較大時，準確度明顯較高；相反的翡翠水庫遷移到石門水庫後，集流時間較長的石門翡翠水庫在輸入因子臨前時間為 2~3 小時時，準確度獲得改善，可證明遷移學習在兩水庫中有發揮作用，集水區集流時間較長之模式可藉由遷移學習萃取知識改善輸入因子臨前時間較短之模式，集水區集流時間較短之模式則增強輸入因子臨前時間較長之模式。

DNN	無遷移學習				有遷移學習			
臨前時間(小時)	RMSE	MAE	CE	CC	RMSE	MAE	CE	CC
1	182.71	102.04	0.85	0.94	178.97	105.67	0.86	0.94
2	148.17	84.82	0.90	0.95	161.96	97.09	0.88	0.94
3	159.53	82.56	0.89	0.94	166.46	94.79	0.88	0.94
4	175.63	103.29	0.87	0.94	166.37	90.20	0.88	0.94
5	171.21	121.67	0.88	0.95	146.97	67.69	0.91	0.96
6	189.96	122.36	0.85	0.92	204.01	117.16	0.83	0.92
7	163.86	82.70	0.89	0.94	159.66	83.23	0.90	0.95

表 8、翡翠水庫於不同臨前時間輸入因子之未來 T+6 小時模式評鑑指標

LSTM	無遷移學習				有遷移學習			
臨前時間(小時)	RMSE	MAE	CE	CC	RMSE	MAE	CE	CC
1	345.22	201.98	0.85	0.92	368.28	234.11	0.83	0.92
2	330.91	227.36	0.86	0.95	291.47	172.74	0.89	0.95
3	328.55	220.27	0.87	0.95	278.06	169.83	0.90	0.95
4	312.39	206.26	0.88	0.95	368.33	279.88	0.84	0.95
5	310.31	205.22	0.88	0.96	301.51	217.88	0.89	0.95
6	327.51	233.79	0.87	0.95	290.06	202.80	0.90	0.96
7	370.15	270.09	0.84	0.95	342.56	233.08	0.86	0.95

表 9、石門水庫於不同臨前時間輸入因子之未來 T+6 小時模式評鑑指標

DNN	預報未來 T+6 小時			
臨前時間(小時)	RMSE	MAE	CE	CC
1	2.05%	-3.56%	0.72%	0.45%
2	-9.31%	-14.47%	-2.07%	-1.12%
3	-4.34%	-14.82%	-1.09%	-0.59%
4	5.27%	12.67%	1.58%	0.64%
5	14.16%	44.37%	3.71%	0.16%
6	-7.40%	4.25%	-2.67%	-0.69%
7	2.56%	-0.65%	0.62%	0.43%

表 10、翡翠水庫於不同臨前時間輸入因子之評鑑指標改善幅度

LSTM	預報未來 T+6 小時			
臨前時間(小時)	RMSE	MAE	CE	CC
1	-6.68%	-15.90%	-2.44%	-0.12%
2	11.92%	24.03%	3.54%	0.53%
3	15.37%	22.90%	4.35%	0.42%
4	-17.91%	-35.69%	-5.25%	-0.63%
5	2.83%	-6.17%	0.73%	-0.75%
6	11.44%	13.26%	3.14%	0.95%
7	7.45%	13.70%	2.73%	0.39%

表 11、石門水庫於不同臨前時間輸入因子之評鑑指標改善幅度

六、結論與建議

本研究提出結合遷移學習和深度學習以改善長期水庫入流量預報，並以石門水庫和翡翠水庫互相作為遷移學習之源域和目標域進行分析，以四種深度學習方法推估未來 1 至 6 小時之水庫入流量。依據本研究結果可以歸納成以下的結論：

- (1) 石門水庫遷移到翡翠水庫可有效改善翡翠水庫 DNN 和 LSTM 模式，在長延時預報中表現尤佳；翡翠水庫遷移到石門水庫可改善石門水庫 DNN、LSTM、RNN、GRU 模型中，並在 T+1、T+3、T+6 小時預報中皆可獲得改善。
- (2) 當集流時間較短的集水區模式其輸入因子臨前時間較長時，集流時間較長的集水區可以透過遷移學習有效改善；同樣集流時間較短的集水區可改善輸入因子臨前時間較短之長集流時間集水區，代表未來利用較少的輸入即可建立準確的預報
- (3) 本研究提出之方法可有效解決水庫入流量預報面臨颱風事件稀少的問題。
- (4) 本研究所提出之結合遷移學習和深度學習入庫流量預報模式，可供水庫相關單位擬訂水庫操作策略之重要依據
- (5) 由於水文資料的不易取得性，尚未加入其他水庫資料，未來希望加入石門和翡翠以外其他水庫進行分析，這也是本研究旨在解決之問題。

參考文獻

1. Hochreiter S., Schmidhuber J., (1997), "Long Short-Term Memory," *Neural Comput.* 9:1735–1780.
2. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y., (2014). "Learning phrase representations using RNN encoder-decoder for statistical machine translation," arXiv preprint arXiv:1406.1078.
3. Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory. *Neural Computation* 9, 1735–1780. doi:10.1162/neco.1997.9.8.1735
4. Oruche, R., Egede, L., Baker, T., & O'Donncha, F. (2021). Transfer learning to improve streamflow forecasts in data sparse regions. arXiv preprint arXiv:2112.03088.
5. Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks?. *Advances in neural information processing systems*, 27.
6. Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint arXiv:1412.3555.
7. 石廣琪. (2020). 混合式人工智慧於水庫入流量預報.
8. 殷仕明, 徐煒, 熊一橙, 田遠洋, 趙思琪, & 陳思. (2022). 基於遷移學習的長短時記憶神經網絡水文模型. *水力發電學報*, 41(6), 53-64
9. 張斐章、張麗秋, 2005, 「類神經網路」, 東華書局。