



# 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<sup>[1]</sup>及進化演算法（Shuffled Complex Evolution Algorithm, SCE-UA）等；大部分的降雨逕流模型<sup>[2,3]</sup>及生態系統模型<sup>[4]</sup>，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<sup>[5]</sup>，模擬

植被生長及碳和養分循環的生態系統模型<sup>[6]</sup>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<sup>[7]</sup>；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。

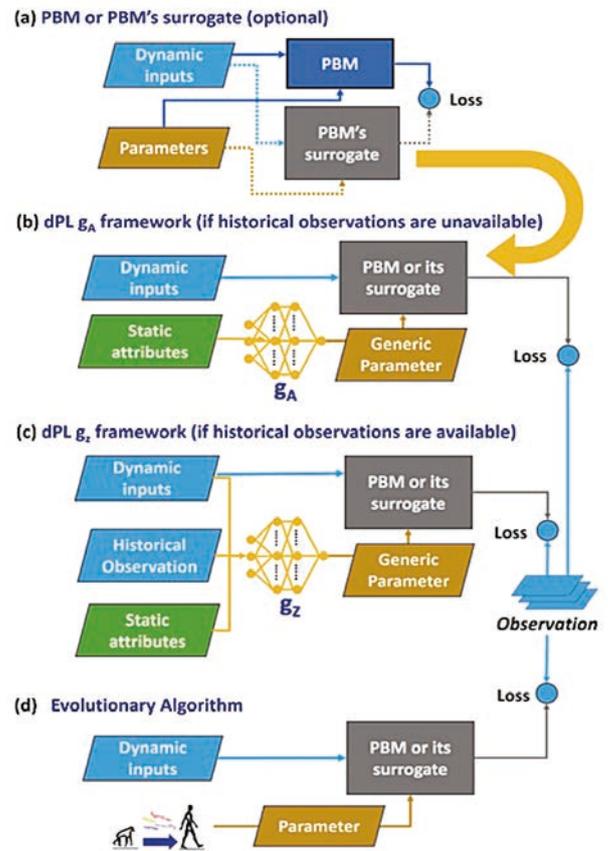


圖 1 可微分參數學習框架

## 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，然後在下一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， $\beta$  和  $\gamma$  分別為偏差和變異性比率， $\mu$  和  $\sigma$  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

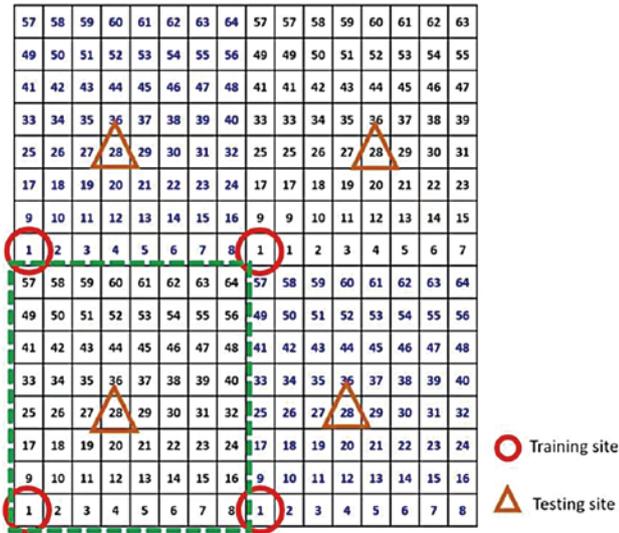


圖 2 資料密度 s8 示意圖 (圖片來源: Tsai *et al.* [15])

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

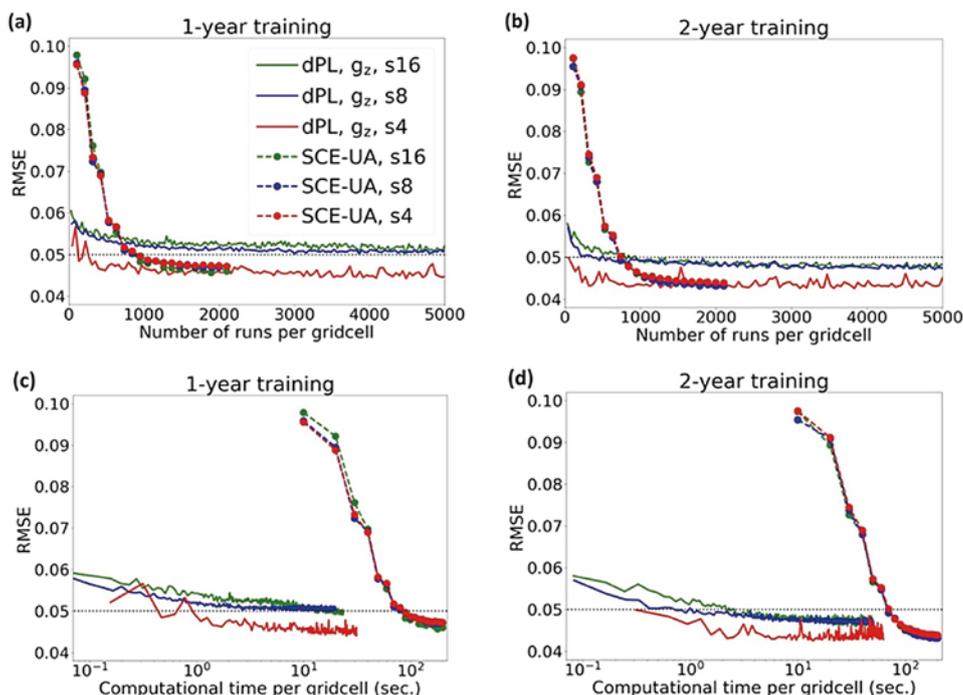


圖 3 RMSE 與訓練時間及資料量比較圖 (圖片來源: Tsai *et al.* [15])

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

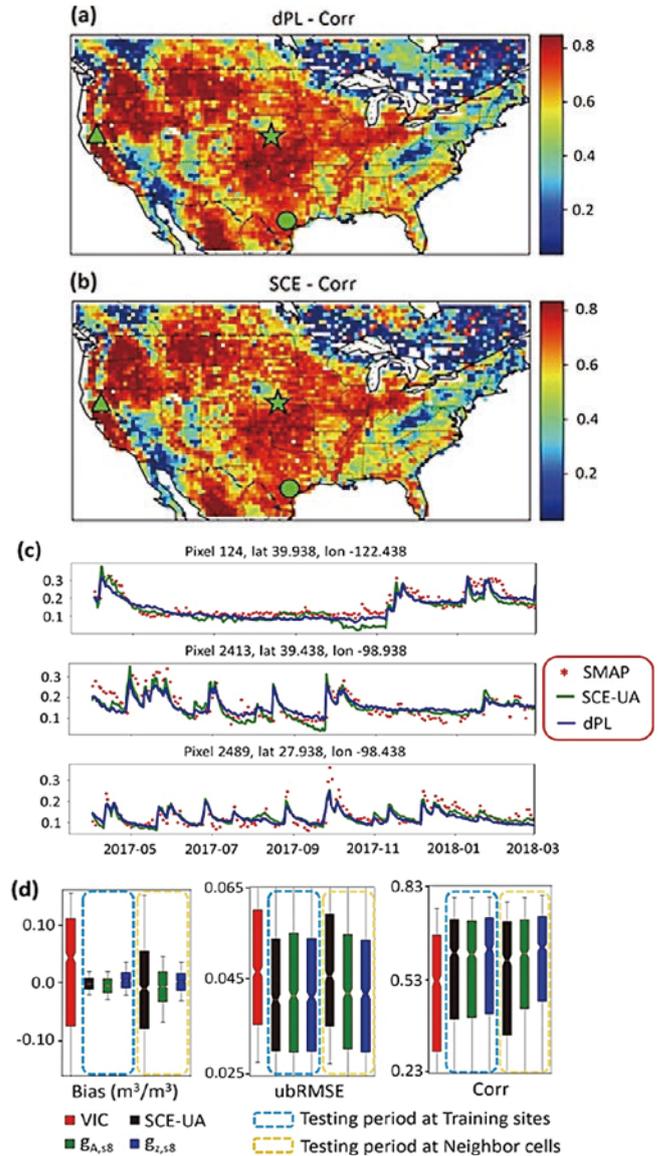


圖 4 土壤濕度模擬圖與評估指標（圖片來源：Tsai et al. [15]）

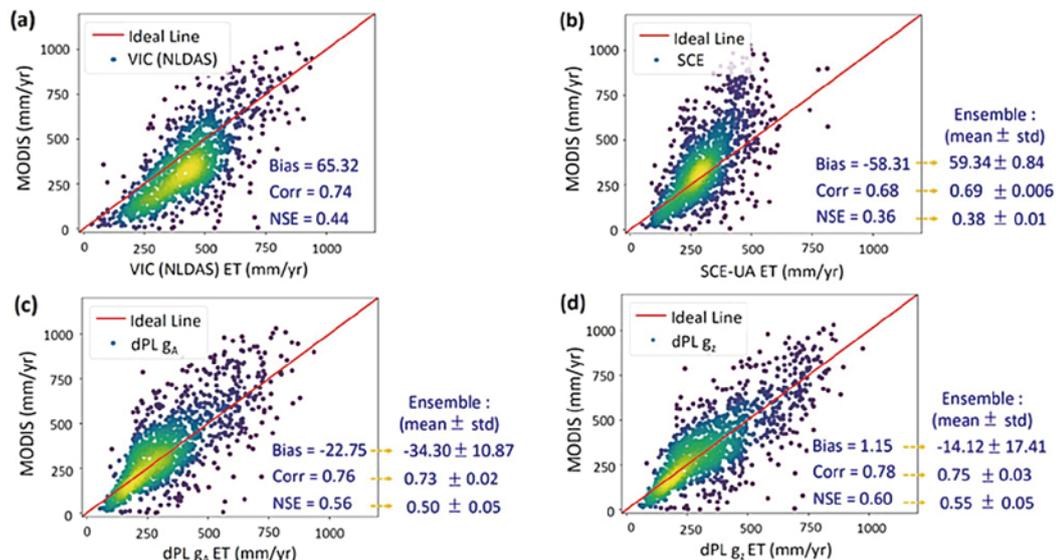


圖 5 蒸散量指標比較圖（圖片來源：Tsai et al. [15]）

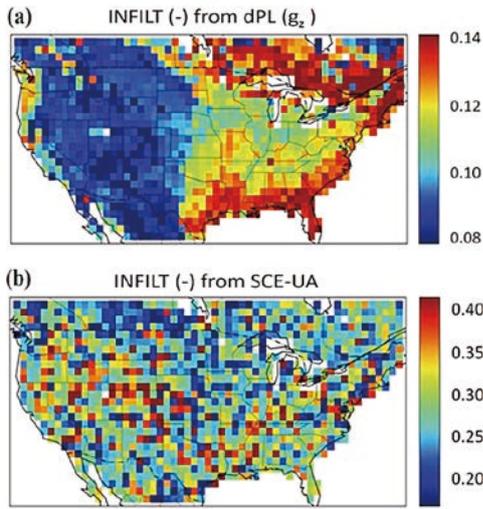


圖 6 dPL 與 SCE-UA 生成參數空間對比  
(圖片來源: Tsai et al. [15])

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

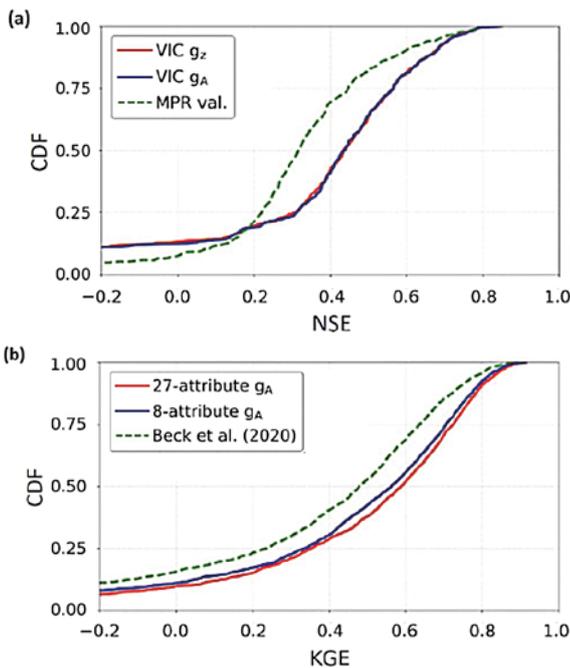


圖 7 dPL、MPR (a) 與 Beck [18] 研究 (b) 之流量推估表現  
(圖片來源: Tsai et al. [15])

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 能提供更好的參數推估結果；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。

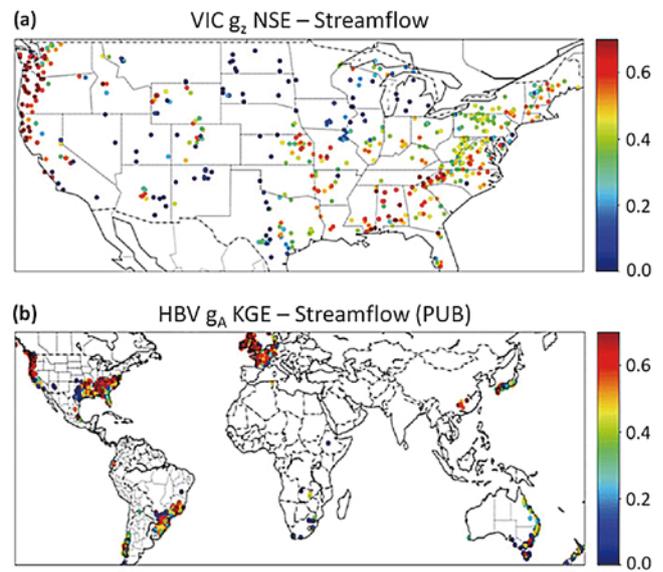


圖 8 過去模型與現有模型比較圖

### 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

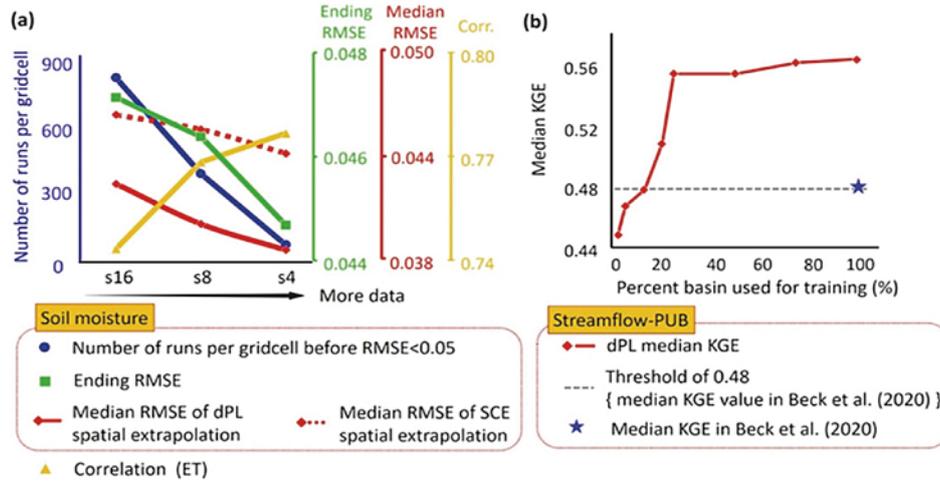


圖 9 dPL 的縮放曲線 (圖片來源: Tsai *et al.* [15])

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

1. 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.
2. 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.
3. Paniconi, C. and Putti, M. (2015). Physically based modeling in catchment hydrology at 50: Survey and outlook. *Water Resour. Res.* 51, 7090-7129.
4. 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.
5. 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.
6. 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.
7. 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.
8. LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444.
9. Schmidhuber, J. (2015). Deep learning in neural networks: an overview. *Neural Netw.* 61, 85-117.
10. 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.
11. 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.
12. 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.
13. 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.
14. Reichstein, M. et al. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566, 195-204.
15. 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.
16. Mizukami, N. et al. (2017). Towards seamless large-domain parameter estimation for hydrologic models. *Water Resour. Res.* 53, 8020-8040.
17. 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>
18. 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

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



卓越誠信  
安全技術  
品質

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