

台灣參考作物蒸發散量計算優選模式建立及氣候變遷衝擊下之未來變化趨勢預測

Establishment of An Optimal Model for Calculating the Reference Crop Evapotranspiration and prediction of the Change Trends Under the Impact of Climate Change in the Future in Taiwan

淡江大學水資源及環境工程學系
碩士班研究生

陳冠嘉
Guan-Jia Chen

助理教授

王聖璋
Sheng-Wei Wang

淡江大學水資源及環境工程學系
兼任助理教授

財團法人農業工程研究中心
研究員
陳豐文

Feng-Wen Chen

摘要

作物蒸發散亦稱為作物需水量(ET_{crop})，為政府推動農地重劃或擴大灌溉服務過程，掌握灌區需求水量之重要參數，其中參考作物蒸發散量(ET_0)為間接計算作物需水量(ET_{crop})的主要步驟；FAO56-Penman-Monteith(FAO56-PM)為聯合國糧食及農業組織(FAO)建議推估 ET_0 的方法之一，亦為國際間普遍使用，但該方法需要使用多項氣象參數，不易於實際廣泛應用；其次，考量氣候變遷對於氣候及水資源的衝擊，作物需水量於未來不同期間的變動牽動台灣整體水資源的供需調配，因此若能事前評估未來變動趨勢，有助於國家提前因應氣象及水情變動趨勢而擬定修正產業用水及區域水資源供需及調配政策。有鑒於此，本研究基於參考作物蒸發散量(ET_0)推估之快速性、廣泛性、準確性及因應氣候變遷的未來變動趨勢預測，建立一套參考作物蒸發散量(ET_0)優選模式，該模式由3種計算方式組成：(1).機器學習(MLP)、(2).Hargreaves and Samani(HS)經驗公式修正、(3).比較 HS、MLP 與 FAO 建議的參數替代方法；並以 RMSE 為優選評估指標；進一步透過機器學習的單參數方法，並優選3種適合台灣的 GCMs，套用 TCCIP 的未來溫度資料進行未來短中長期之4種情境條件下之變化趨勢推估。

本研究以柯本-蓋革(Köppen-Geiger)氣候分類法為基礎將台灣劃設為4個不同氣候區；選定嘉義、新竹、恆春及永康氣象測站為各氣候分區的代表測站，採用20年日資料(2004-2023年)進行評估，其中16年日資料建立模型，4年日資料進行驗證；研究成果顯示：(1).使用線性回歸方法(HS_adj2)修正 Hargreaves and Samani(HS)會優於使用乘上單一修正係數方法(HS_adj1)，並且 HS_adj2 方法與 HS_adj1 方法可以使 RMSE 值分別降低0~21.74%、0~12.35%；(2).交叉分析及驗證顯示推估 ET_0 其首要的氣象觀測參數為太陽輻射數據，而風速及濕度則較為次要；(3).優選模式部分則顯示當氣象觀測僅有溫度資料時， ET_0 的最佳推估方法為 MLP-a 模型，其次則是 HS_adj2 模型，而 HS 模型與

PM1 的模型性能排名則要視目標測站而定，但大多數情況下，PM1 模型會優於 HS 模型；(4).氣候變遷預測成果顯示各測站應用 3 種 GCMs 及 4 種模擬情境條件均有相同趨勢， ET_0 由短期(2021~2040)、中期(2041~2060)至中長期(2061~2080)呈現持續上升，並於中長期或長期(2081~2100)時達到高峰，凸顯氣候變遷對於台灣農業灌溉需求水量隨著時間推移產生高需求的趨勢，建議未來的水資源供需政策須提前調整因應。

關鍵詞：參考作物蒸發散量、氣候變遷、機器學習、優選模式、作物需水量

Abstract

Crop evapotranspiration, also known as crop water requirement (ET_{crop}), is a crucial parameter for the government's promotion of farmland reorganization or the expansion of irrigation services, helping to grasp the water demand in irrigation areas. The reference crop evapotranspiration (ET_0) is the primary step in indirectly calculating crop water requirements (ET_{crop}). The FAO56 Penman-Monteith method is one of the recommended methods by the Food and Agriculture Organization (FAO) for estimating ET_0 and is widely used internationally; however, this method requires multiple meteorological parameters, making it difficult to apply extensively in practice. Furthermore, considering the impact of climate change on climate and water resources, the fluctuations in crop water requirements over different future periods influence the overall supply and demand of water resources in Taiwan. Therefore, assessing future trends in advance can help the country prepare for changes in weather and water conditions and formulate policies for adjusting industrial water use and regional water resource allocation. In this context, this study aims to establish an optimal model for estimating reference crop evapotranspiration (ET_0) based on the rapidity, universality, accuracy, and trend prediction in response to climate change. The model consists of three calculation methods: (1) Machine Learning (MLP), (2) Hargreaves and Samani (HS) empirical formula adjustment, and (3) comparison of HS, MLP, and FAO-recommended parameter substitution methods. RMSE is used as the selection evaluation index. Additionally, through a single-parameter method in machine learning, three suitable GCMs for Taiwan (CanESM5, EC-Earth3, ACCESS-ESM1-5) are selected, and future temperature data from TCCIP is applied to estimate trend changes under four future scenarios.

This study classifies Taiwan into four different climate zones based on the Köppen-Geiger climate classification method and selects Chiayi, Hsinchu, Hengchun, and Yongkang weather stations as representatives for each climate zone. Twenty years of daily data (2004-2023) are used for evaluation, with 16 years for model establishment and four years for validation. The results show: (1) The linear regression method (HS_adj2) is superior to the single coefficient adjustment method (HS_adj1) in adjusting the Hargreaves and Samani (HS) model, with RMSE values reduced by 0~21.74% and 0~12.35%, respectively; (2) Cross-analysis and validation indicate that solar radiation data is the most important

meteorological parameter for estimating ET_0 , with wind speed and humidity being less significant; (3) The optimal model shows that when meteorological observations only include temperature data, the best estimation method for ET_0 is the MLP-a model, followed by the HS_adj2 model, while the performance ranking of the HS model and PM1 model depends on the target station, but in most cases, the PM1 model outperforms the HS model; (4) Climate change prediction results show that all stations applying the three GCMs and four simulation scenarios exhibit the same trend, indicating that ET_0 continuously rises from the short term (2021-2040) to the medium term (2041-2060) and to the mid-long term (2061-2080), reaching a peak in the mid-long term or long term (2081-2100). This underscores the increasing demand for agricultural irrigation water in Taiwan over time due to climate change, suggesting that future water resource supply and demand policies should be adjusted in advance to respond accordingly.

Keywords: Reference Evapotranspiration, Climate Change, Machine Learning, Optimal Model, Crop Water Requirement.

一、前言

隨著全球人口以及經濟的增長，人們對於糧食以及水資源的需求不斷增長，面對有限的水資源供應，水資源短缺的壓力將日益上升(Petropoulos *et al.*, 2018; Boretti & Rosa, 2019)，因此提高用水效率相當重要，考量推估參考蒸發散量(ET_0)是計算農業用水需求的主要步驟，準確估算參考蒸發散量(ET_0)有助於有效提升農業用水效率，對於農業永續水資源規劃十分重要(Gamal *et al.*, 2022; Wanniarachchi and Sarukkalige, 2022)。推估 ET_0 的方法分包含直接推估與間接推估，其中使用蒸滲儀直接測定現地 ET_0 最直接且精準，但須耗費較高的時間與經濟成本(Kumar *et al.*, 2011; Anapalli *et al.*, 2016)，因此較少被實際應用。聯合國糧食及農業組織(Food and Agriculture Organization of the United Nations, FAO)推薦的 FAO56_Penman-Monteith(FAO56-PM)方法則是最廣泛的 ET_0 間接推估方法，許多研究證實該方法在不同地區的可行性(Suleiman and Hoogenboom, 2007; 甘俊二等, 1996)，然而 FAO56-PM 方法需要使用較多的氣象參數，例如氣溫、風速、空氣濕度、太陽輻射等，實際應用時，常因此受限，台灣現有的自動雨量站及自動氣象站也並未完整觀測 FAO56-PM 方法所需的氣象參數，因此評估出合適的替代方法相當重要，藉以利用較少量的氣象參數求得準確的 ET_0 ，進而廣泛應用在台灣各區域。

面對缺乏某項氣象觀測參數時，Allen *et al.* (1998)提出建議的參數替代方法，當缺少濕度、輻射、風速數據時，可透過替代方法求得濕度、輻射、風速資料，應用 FAO56-PM 方法推估 ET_0 ；過去的研究也開發諸多以少量氣象參數推估 ET_0 的經驗公式，許多研究顯示 Hargreaves and Samani(HS)公式具有不錯的性能(Almorox *et al.*, 2015)，並且該方法僅需使用溫度及地外輻射數據，地外輻射可由日期和測站緯度計算，因此所需的觀測參數僅有溫度數據，針對 HS 方法進行本地校準後能獲得更精準的推估值，成為該地區可行的 ET_0 推估方法(Trajkovic, 2007)；近年來，運用機器學習方法解決問題為一種新趨勢，機器學習的技術已廣泛應用於水文研究(Patil and Deka, 2016; Zounemat-Kermani *et al.*,

2021), 許多研究皆表明機器學習方法比傳統經驗公式或物理模型具備更佳的性能(Luo *et al.*, 2022; Mosaffa *et al.*, 2022), 機器學習模型可以自行決定輸入參數, 相對於傳統方法能夠較靈活運用, 使其透過少量參數對模型進行訓練, 取得精準估計(Chen *et al.*, 2020; Kim *et al.*, 2022), Kumar *et al.* (2011)指出已有許多研究證實透過機器學習模型推估 ET₀ 的可行性, 而 Multilayer Perceptron(MLP)模型在水文研究中是最為常見的人工神經網路(ANN) (Kumar *et al.*, 2011)。本研究以柯本-蓋革(Köppen-Geiger)氣候分類方法為基礎進行分區, 以探討不同區域的推估結果, 本研究主要目的為下列 2 項: 1.在缺少不同氣象觀測參數的情況下建立優選模式, 評估 Allen *et al.* (1998)所建議的參數替代方法、Hargreaves and Samani(HS)經驗公式及 MLP 模型在不同輸入參數情況下的推估結果及性能差異, 並找出對於推估 ET₀ 較為重要的氣象觀測參數。2.評估 3 種基於溫度的 ET₀ 推估模型(HS、MLP 以及 FAO56-PM 替代方法), 篩選最佳的 ET₀ 推估方法, 套用臺灣氣候變遷推估資訊與調適知識平台計畫(TCCIP)所提供的未來溫度推估資料, 推估不同測站在不同氣候變遷情境下(SSP1-2.6、SSP2-4.5、SSP3-7.0、SSP5-8.5)的未來 ET₀。

二、研究方法

2.1 FAO56-Penman-Monteith(FAO56-PM)方法及參數替代方法

FAO56-Penman-Monteith (FAO56-PM)的基本假設是作物高度為 0.12 公尺(m)、表面電阻率(Surface Resistance)為 70(S/m)、反照率(Albedo)為 0.23、生長活躍並且澆水充足的大面積綠草的蒸發散量, FAO56-PM 改善了先前 FAO Penman 方法的缺點, FAO56-PM 方法所求得之 ET₀ 更符合全球的作物用水數據; FAO56-PM 公式如下(Allen *et al.*, 1998):

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (1)$$

式中: ET₀ 為參考作物蒸發散量(mm/day); Δ 為飽和蒸氣壓曲線斜率(kPa/°C); R_n 為作物表面的淨輻射量(MJ/m²day); G 為土壤熱通量(MJ/m²day); T 為離地面高度 2m 之平均氣溫(°C); γ 為濕度常數(kPa/°C); u₂ 為離地面高度 2 m 之風速(m/s); e_s 為飽和蒸氣壓(kPa); e_a 為實際蒸氣壓(kPa)。

式(1)需要應用到許多參數, 各項參數的計算公式可參考 Allen *et al.* (1998), 運用 FAO56-PM 公式遭遇完全缺乏某項氣象觀測參數時, 例如該研究區域缺少濕度、輻射、風速數據時, Allen *et al.* (1998)提出建議的參數替代方法如下:

1.缺少濕度資料: 可透過平均露點溫度(T_{dew})接近於最低氣溫(T_{min})的假設, 計算實際蒸氣壓(e_a), 其替代公式如式(2):

$$e_a = e^0(T_{min}) = 0.611 \exp\left(\frac{17.27 T_{min}}{T_{min} + 237.3}\right) \quad (2)$$

式中: e_a 為實際蒸氣壓(kPa); e⁰(T_{min}) 為氣溫 T 的飽和蒸氣壓(kPa); T_{min} 為最低氣溫(°C)。

2.缺少太陽輻射資料: 每日最高氣溫與最低氣溫之差值與雲層的覆蓋程度具有相關性, 可作為地外輻射到達地球表面比例的指標, 因此可透過氣溫差推估太陽輻射量:

$$R_s = k_{RS} \sqrt{(T_{\max} - T_{\min})} R_a \quad (3)$$

式中： R_s 為太陽輻射(MJ/m²day)； T_{\max} 為最高氣溫(°C)； R_a 為地外輻射(MJ/m²day)； k_{RS} 為修正係數(°C^{-0.5})， k_{RS} 建議值(內陸為 0.16、沿海地區為 0.19)，本研究以試誤法找出不同測站最合適的 k_{RS} 數值。

3. 缺少風速資料：如果該區域缺少風速資料，可以假設離地面高度 2 m 之風速(u_2)等於 2 (m/s)，該值為全球 2,000 多個氣象站的風速平均值(Allen *et al.*, 1998)。

表 1 FAO56-PM 公式與替代方法

模型	參數 (濕度)	參數 (風速)	參數 (太陽輻射)
FAO56-PM	實際觀測數據	實際觀測數據	實際觀測數據
PM-1	使用公式(2)	使用風速定值 2m/s	使用公式(3)
PM-2	使用公式(2)	實際觀測數據	實際觀測數據
PM-3	實際觀測數據	使用風速定值 2m/s	實際觀測數據
PM-4	實際觀測數據	實際觀測數據	使用公式(3)

本研究評估 FAO56-PM 方法與其替代方法(PM-1、PM-2、PM-3 及 PM-4 等 4 種)，如表 1，其中 FAO56-PM 為使用完整觀測參數計算的方法，PM-1 則為濕度、風速及太陽輻射資料均透過替代方法估算的 FAO56-PM，PM-2 為濕度資料透過替代方法估算的 FAO56-PM，PM-3 為風速資料透過替代方法估算的 FAO56-PM，PM-4 為太陽輻射資料透過替代方法估算的 FAO56-PM。有鑑於 PM-1 方法僅須使用溫度資料推估，因此以 PM-1 模型與其他僅需要溫度參數的模型比較，選出推估未來 ET_o 的最佳模型。

2.2 Hargreaves and Samani(HS)公式及校準方法

Hargreaves and Samani (1985)提出基於溫度觀測值與地外輻射的 ET_o 推估方程式，如式(4)，惟 ET_o 與 R_a 的單位應相同，透過式(5)將 R_a (MJ/m²day)轉換為 R_a (mm/day)：

$$ET_o = 0.0023(T_{\text{mean}} + 17.8)(T_{\max} - T_{\min})^{0.5} R_a \quad (4)$$

$$R_a(\text{mm/day}) = \frac{R_a(\text{MJ/m}^2\text{day})}{2.45} \quad (5)$$

式中： ET_o 為參考作物蒸發散量(mm/day)； T_{mean} 為平均溫度(°C)； R_a 為地外輻射(mm/day)。2.45 為汽化潛熱(MJ/kg)。

由於 Hargreaves and Samani (HS)方法屬於經驗公式，需要進行本地校準才能獲得良好成果，因此本研究透過兩種不同的校準方法對 HS 公式進行校準及評估，兩種方法分別為 1. 乘上單一修正係數方法、2. 簡單線性回歸方法，其公式如式(6)~式(8)：

1. 乘上單一修正係數方法(HS_adj1)：

$$k = \frac{ET_o(\text{PM})_{\text{Mean}}}{ET_o(\text{HS})_{\text{Mean}}} \quad (6)$$

$$ET_o(\text{HS_adj1}) = k \times ET_o(\text{HS}) \quad (7)$$

式中： $ET_o(\text{HS_adj1})$ 為 HS 透過單一修正係數校準後的 ET_o ； k 為修正係數； $ET_o(\text{PM})_{\text{Mean}}$ 為 FAO56-PM 求得的 ET_o 平均值； $ET_o(\text{HS})_{\text{Mean}}$ 為原始 HS 公式求得的 ET_o 平均值。

2. 線性回歸方法(HS_adj2)：

$$ET_{o(HS_adj2)} = a + b \times ET_{o(HS)} \quad (8)$$

式中： $ET_{o(HS_adj2)}$ 為 HS 透過簡單線性回歸校準後的 ET_o ； a 與 b 為修正係數； $ET_{o(HS)}$ 為原始 HS 公式。

2.3 機器學習-MLP 模型

圖 1 是 MLP 模型的架構範例圖，MLP 模型是由輸入層、隱藏層以及輸出層所構成的，隱藏層可以是單層或是多層，在輸入層的部分我們可以選用不同的氣象觀測值作為輸入參數，透過公式(9)將輸入參數傳輸到第一層隱藏層去，再透過激活函數進行轉換並傳到下一層，圖中所使用的激活函數範例為 Sigmoid，最後將由公式(10)傳到輸出層，其中隱藏層的最佳層數與隱藏層的最佳神經元數量會隨著不同問題而有所變化(張斐章等，2014)，因此本研究採用網格搜索方法尋找最佳的超參數設定，總共將測試 3 種優化器(Optimizer)、3 種激活函數(Activation)、3 種批次(Batch Size)、3 種迭代次數(Epochs)以及 39 種隱藏層架構，優化器將測試 Adagrad、Adam、RMSprop，激活函數測試 hard sigmoid、sigmoid、tanh，批次測試 8、16、32，迭代次數測試 50、100、150，隱藏層則是分別測試 1 層、2 層、3 層，且隱藏層神經元數量則是 8、16、32 的排列組合，總共將搜索 3,159 種組合，最終為每個測站的不同模型找出最佳的超參數設定。

本研究針對不同目標測站以及不同輸入參數組合建立不同的最佳模型，並評估不同輸入參數組合的模型性能，以此找出較為重要的輸入參數，本研究茲將考量之模型參數組合區分成以下 4 種：最終各模型所使用之參數如表 2 所示。1.MLP-a：針對缺少濕度、風速、太陽輻射觀測資料的情況，對應到 PM-1。2.MLP-b：針對缺少濕度觀測資料的情況，對應到 PM-2。3.MLP-c：針對缺少風速觀測資料的情況，對應到 PM-3。4.MLP-d：針對缺少太陽輻射觀測資料的情況，對應到 PM-4。

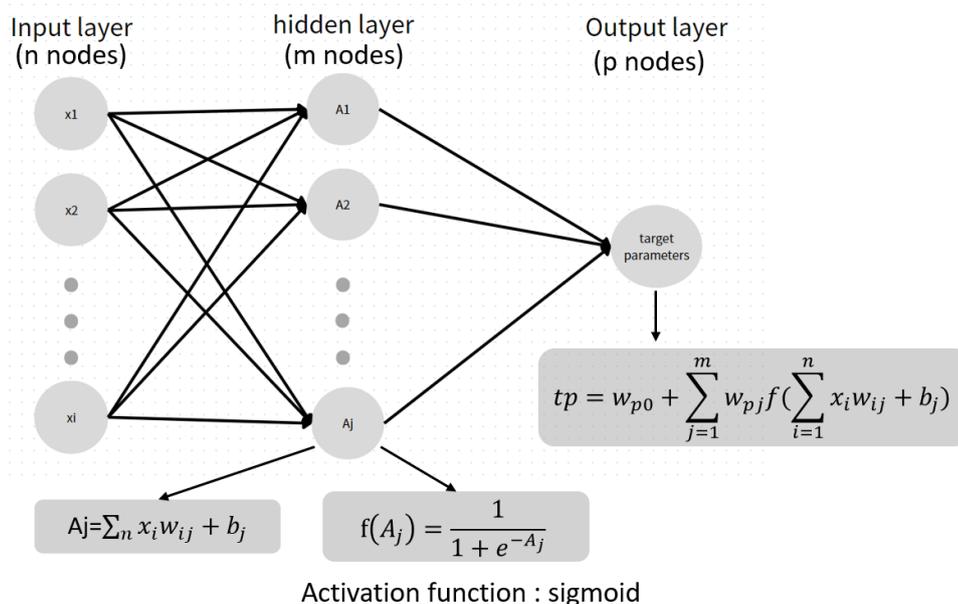


圖 1 MLP 模型架構圖

表 2 各模型對應之輸入參數

模型名稱	P	T _{max}	T _{min}	R _a	T _{dew}	u ₂	R _s
FAO56-PM	✓	✓	✓	✓	✓	✓	✓
PM-1	✓	✓	✓	✓			
PM-2	✓	✓	✓	✓		✓	✓
PM-3	✓	✓	✓	✓	✓		✓
PM-4	✓	✓	✓	✓	✓	✓	
HS		✓	✓	✓			
HS_adj1		✓	✓	✓			
HS_adj2		✓	✓	✓			
MLP-a		✓	✓	✓			
MLP-b		✓	✓	✓		✓	✓
MLP-c		✓	✓	✓	✓		✓
MLP-d		✓	✓	✓	✓	✓	

註 1：✓為該模型所需使用到的氣象觀測參數。

註 2：P 為平均氣壓(kPa)；T_{max}為最高氣溫(°C)；T_{min}為最低氣溫(°C)；T_{dew}為露點溫度(°C)；u₂為離地高度 2 m 的風速(m/s)；R_a為地外輻射(MJ/m²day)；R_s為太陽輻射(MJ/m²day)。

$$A_j = \sum_n x_i w_{ij} + b_j \quad (9)$$

$$tp = w_{p0} + \sum_{j=1}^m w_{pj} f\left(\sum_{i=1}^n x_i w_{ij} + b_j\right) \quad (10)$$

式中：n 為輸入層的參數個數，m 為隱藏層的神經元個數，p 為輸出層的神經元個數；A_j 為第 j 個隱藏神經元；x_i 為第 i 個輸入參數；w_{ij} 為第 i 個輸入參數與第 j 個隱藏神經元間的權重；b_j 為第 j 個隱藏神經元的偏權值；tp 為目標參數；w_{p0} 為偏權值；w_{pj} 為第 j 個隱藏神經元與第 p 個輸出神經元間的權重；f 函數為激活函數。

2.4 氣候變遷情境

IPCC(AR6)考量全球社會經濟發展，提出共享社會經濟路徑(Shared Socioeconomic Pathway, SSP)，不同 SSP 的主要差異來自對全球人口增長、受教育機會、城市化、經濟增長、資源可用性、技術發展和需求驅動因素的不同假設，區分為 SSP1~SSP5 等 5 種不同的社經發展情境(許晃雄等，2024)，本研究評估的未來溫室氣體排放情境如下：1.SSP1-2.6：低強迫路徑，溫室氣體(Greenhouse Gas, GHG)低排放量，升溫的程度於世紀末時控制在 2 °C 內；2.SSP2-4.5：中間路徑，GHG 中排放量，到世紀末時，升溫程度控制於 3 °C 內；3.SSP3-7.0：中高強迫路徑，GHG 高排放量，到世紀末時，升溫程度控制於 4 °C 內；4.SSP5-8.5：高強迫路徑，GHG 極高排放量，到世紀末時，升溫程度超過 4 °C。由於未來推估資料著重於模擬不同氣候變遷情境下的趨勢變化，因此本研究分析不同期間 ET_o 的變化趨勢，以 20 年為單位，將未來推估資料區分為 4 個時期進行分析，分別為短期(2021~2040)、中期(2041~2060)、中長期(2061~2080)及長期(2081~2100)。

2.5 交叉驗證方法

使用不同年份的資料對於 HS_adj1、HS_adj2 方法而言，會求得不同的修正係數，也無法確保該修正係數套用在其他年份的修正效果，對於 MLP 模型而言，選擇不同的訓練集跟測試集對於模型的性能表現會有所差異(Antonopoulos and Antonopoulos, 2017)，

因此本研究透過交叉驗證方法(k-fold)評估 HS_adj1、HS_adj2 方法及 MLP 模型的可行性，資料區分為訓練集跟測試集，訓練集用於求得修正係數以及對模型進行訓練；測試集則是套用訓練集求得的結果進行校準，最終評估測試集校準後的模型結果，透過交叉驗證方法能夠確保所有資料皆當過訓練集跟測試集，且能夠有效評估該方法的穩定性及可行性，本研究採用 5-fold 交叉驗證法，將完整資料集以年為單位拆分成 5 等分(組)，其中 4 組用於訓練，其餘 1 組用於測試，每次皆會使用不同的訓練和測試組別，重複試驗 5 次，HS_adj1 和 HS_adj2 方法採用按年份分組的交叉驗證方法，MLP 模型則會比較按照年份分組與隨機分組的交叉驗證結果，最終評估模型按照年份分組與隨機分組的結果是否有所差異。交叉驗證的分組，本研究的資料觀測期間為 2004~2023 年(共計 20 年)，隨機拆分的交叉驗證方法為以日為單位進行隨機拆分，而按年份分組的交叉驗證方法則是以年為單位進行隨機拆分，拆分為下列 5 個組別：第 1 組：2008、2009、2019、2023；第 2 組：2004、2015、2021、2022；第 3 組：2007、2011、2012、2018；第 4 組：2005、2006、2013、2014；第 5 組：2016、2017、2010、2020。

2.6 評估指標

本研究使用均方根誤差(Root Mean Squared Error, RMSE)及決定係數(Coefficient of Determination, R^2)評估模型的性能，其公式如式(11)及式(12)：

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (d_i - y_i)^2} \quad (11)$$

$$R^2 = \left[\frac{\sum_{i=1}^N (d_i - \bar{d})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (d_i - \bar{d})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \right]^2 \quad (12)$$

式中： N 為觀測值的數量； d_i 為推估值(mm/day)； y_i 為觀測值(FAO56-PM 推估值)(mm/day)； \bar{d} 為推估值平均(mm/day)； \bar{y} 為觀測值平均(mm/day)；RMSE數值越小代表模型的性能越高。

三、研究區域及氣象資料概述

本研究透過 Beck *et al.* (2023)製作的柯本-蓋革(Köppen-Geiger)氣候分類圖將臺灣測站進行分類，該分類方法是基於氣溫、降雨以及所處氣候帶將劃分不同的氣候類別，篩選出觀測期間長達 20 年以上且缺失數據較少的測站作為代表測站，最終決定選擇嘉義、永康、恆春、新竹測站分別做為 Cwa、Aw、Am、Cfa 氣候地區的代表測站，並選用鄰近的兩個測站作為補遺用測站，如圖 2。本研究所選用的資料年份為 2004~2023 年，在模型建立之前會先對氣象資料進行盤點檢查，並針對缺失的氣象數據進行資料補遺的前處理，確保研究數據的完整性，採用反距離權重法(IDW)進行補遺。

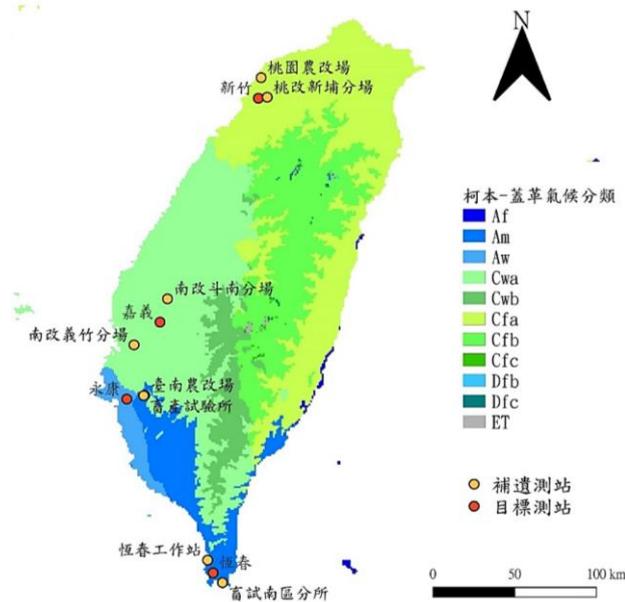


圖 2 目標測站與補遺測站位置

四、結果與討論

4.1 FAO56_Penman-Monteith 替代方法推估成果

各目標測站使用 4 種 FAO56-PM 替代方法的推估成果性能比較如表 3，結果顯示嘉義測站 PM-2 方法的 RMSE 值最小，僅 0.21 (mm/day)， R^2 高達 0.98，表示該測站即使缺少濕度資料，以 Allen *et al.* (1998) 推薦的溼度替代方法推估可獲得良好成果，具相對較低的誤差值，但 PM-2 方法在恆春測站的性能排名僅為第 3 順位，表示恆春測站使用溼度替代方法的成效不佳，可能原因為 PM-2 方法所應用的公式(2)中 T_{dew} 會接近於 T_{min} 的基本假設所致，從表 4 得知嘉義測站的 T_{dew} 歷年平均值相當接近於 T_{min} ，歷年平均值差異為 0.48 °C，而恆春測站中的 T_{dew} 歷年平均值則與 T_{min} 差異最大，歷年平均值差異為 2.52 °C，因此導致恆春測站使用溼度替代方法的成效不佳。

表 3 FAO56-PM 替代方法推估 ET_0 之均方根誤差及決定係數分析結果

測站	FAO56-PM 替代方法	ET_0 (mm/day)		測站	FAO56-PM 替代方法	ET_0 (mm/day)	
		RMSE	R^2			RMSE	R^2
嘉義	PM-1	0.72	0.72	恆春	PM-1	1.36	0.15
	PM-2	0.21	0.98		PM-2	0.92	0.69
	PM-3	0.30	0.97		PM-3	0.55	0.82
	PM-4	0.61	0.80		PM-4	0.71	0.65
新竹	PM-1	0.89	0.64	永康	PM-1	0.87	0.58
	PM-2	0.39	0.96		PM-2	0.42	0.95
	PM-3	0.34	0.97		PM-3	0.31	0.94
	PM-4	0.70	0.80		PM-4	0.67	0.74

此外，除了嘉義測站，PM-3 方法的 RMSE 值皆最小，嘉義測站 PM-3 方法的 RMSE 值也排名第 2 順位，其值為 0.30 (mm/day)，表示在所有目標測站中即使缺少風速資料，也可以透過 Allen *et al.* (1998) 所推薦的風速替代方法獲得良好推估成果。PM-4 方法的結果則普遍較差，除了恆春測站外，PM-4 方法皆排名第 3 順位，在恆春測站中也是排名第 2 順位，這表示太陽輻射數據並無法透過 Allen *et al.* (1998) 所推薦的替代方法良獲得

良好的成果，該項觀測參數對於推估 ET_0 而言可能較為重要。在所有測站中 PM-1 方法的 RMSE 值皆為最大，這是由於 PM-1 方法中的溼度、風速及太陽輻射數據皆是透過替代方法求得，因此所推估出的 ET_0 誤差較大。整體而言，對於 FAO56-PM 的替代方法，較為重要的氣象觀測參數為太陽輻射，其次為濕度數據，而風速觀測資料則較不重要，這與 Valle Júnior et al. (2021) 以及 Córdova et al. (2015) 的研究結果相同，此外，若該測站歷年的 T_{dew} 平均值接近於 T_{min} 平均值，就能夠透過 Allen et al. (1998) 所推薦的溼度替代方法很好地進行推估，反之則效果較差。

表 4 各測站 2004~2023 年 敘述性統計資料(補遺後)

測站別	氣象參數	有效筆數	缺失筆數	平均數	標準偏差	最小值	最大值
嘉義	最低氣溫(°C)	7,305	0	20.18	5.08	4.40	29.60
	露點溫度(°C)	7,305	0	19.70	4.89	1.50	27.40
新竹	最低氣溫(°C)	7,305	0	20.34	5.29	2.80	30.00
	露點溫度(°C)	7,305	0	18.50	5.24	0.70	26.90
恆春	最低氣溫(°C)	7,305	0	23.17	3.16	10.40	29.60
	露點溫度(°C)	7,305	0	20.65	4.27	6.90	28.20
永康	最低氣溫(°C)	7,305	0	21.28	4.97	5.30	29.80
	露點溫度(°C)	7,305	0	19.32	4.92	0.40	27.30

4.2 Hargreaves and Samani(HS)公式推估及修正成果

表 5 為各測站 HS 公式按年度別修正後的 RMSE，從中可以得知除永康測站外，其餘測站皆有所改善，並且 HS_adj2 的改善效果優於 HS_adj1，嘉義測站透過線性回歸方法修正後的 RMSE 從 0.81 降到 0.69(mm/day)；新竹測站透過線性回歸方法修正後的 RMSE 從 0.90 降到 0.88(mm/day)；恆春測站透過線性回歸方法修正後的 RMSE 從 1.38 降到 1.08(mm/day)，而永康測站並沒有改善，永康測站的 HS 公式相較於 FAO56-PM 方法並沒有明顯的高估或低估，因此透過本地校準方法所能夠改善的效果較為有限。

表 5 HS 公式修正後結果(按年度別修正)

測站		均方根誤差(RMSE)					平均
		交叉驗證-1	交叉驗證-2	交叉驗證-3	交叉驗證-4	交叉驗證-5	
嘉義	HS(原始)	0.80	0.75	0.79	0.72	0.89	0.81
	HS_adj1	0.75	0.68	0.67	0.69	0.75	0.71
	HS_adj2	0.73	0.65	0.66	0.67	0.75	0.69
新竹	HS(原始)	0.89	0.91	0.90	0.91	0.90	0.90
	HS_adj1	0.90	0.93	0.86	0.87	0.86	0.88
	HS_adj2	0.90	0.93	0.86	0.87	0.86	0.88
恆春	HS(原始)	1.33	1.38	1.41	1.35	1.44	1.38
	HS_adj1	1.30	1.22	1.32	1.27	1.35	1.29
	HS_adj2	1.07	1.05	1.12	1.03	1.14	1.08
永康	HS(原始)	0.79	0.86	0.84	0.80	0.77	0.81
	HS_adj1	0.79	0.86	0.84	0.80	0.77	0.81
	HS_adj2	0.79	0.86	0.85	0.80	0.77	0.81

註：本表為各方法與 FAO56-PM 方法比較後結果，HS_adj1 為透過乘上單一係數方法修正後結果，HS_adj2 為透過簡單線性回歸方法修正後結果。

4.3 機器學習(MLP)模式推估成果

透過網格搜索方法(GridSearchCV)尋找各個 MLP 模型的最佳超參數設定，結果顯示

各測站所有 MLP 模型最佳的優化器都是 Adam，且最佳激活函數大多為 tanh 或 sigmoid，最佳批次則較不固定，最佳隱藏層層數大多為 3 層，少數為 2 層，最佳迭代次數皆為 150 次。各測站不同 MLP 模型隨機分 5 組與按年份分 5 組的推估結果顯示隨機分 5 組與按年份分 5 組的交叉驗證平均 RMSE 都相當接近，兩種分組方式的平均 RMSE 差值皆小於 0.02 (mm/day)，表示模型即使進行隨機分組也能夠得到與按年份分組相似的結果，代表未來研究要進行交叉驗證分組時，並不一定需要按照年份進行分組，並且還發現同一種分組方式中的不同交叉驗證組別所求的 RMSE 數值也相差不遠，RMSE 值差異皆小於 0.15 (mm/day)，即使使用不同組別的訓練及驗證年份，MLP 模型也能夠穩定發揮，不會因使用不同的訓練及驗證組別而導致模型性能有極大差異，這可能是由於本研究所選用的訓練年份較長(16 年)，並且同一氣象觀測站的氣象參數並不會隨著時間推移而有較大變化，因此模型的訓練可以有相對穩定的結果。

4.4 參考作物蒸發散量(ET₀)優選模式分析成果及效能評估

圖 3~圖 6 為各測站各方法之綜合評估，圖中各模型尾端的數字代表交叉驗證的組別，舉例：MLP-a1 為 MLP-a 的第 1 組交叉驗證模型結果，HS_adj2-2 為 HS_adj2 的第 2 組交叉驗證模型結果。

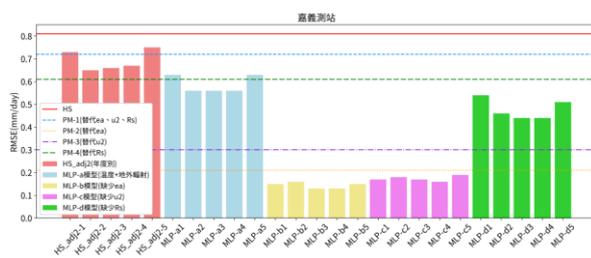


圖 3 嘉義測站各方法之效能評估

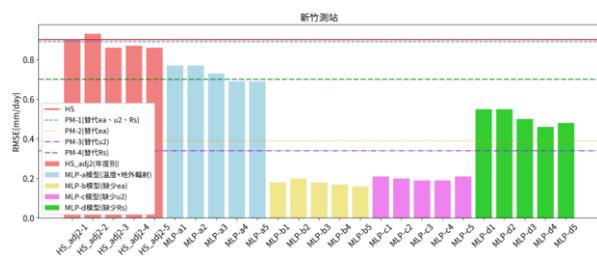


圖 4 新竹測站各方法之效能評估



圖 5 恆春測站各方法之效能評估

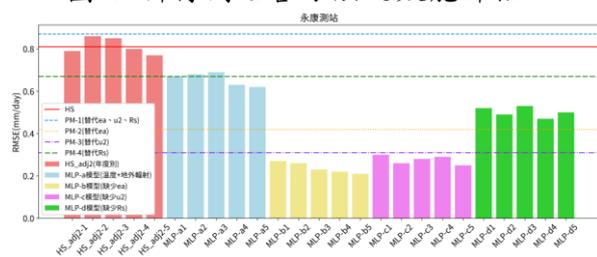


圖 6 永康測站各方法之效能評估

成果顯示所有測站的 MLP-a 模型均優於 PM-1 模型，MLP-b 模型均優於 PM-2 模型，MLP-c 模型均優於 PM-3 模型，MLP-d 模型均優於 PM-4 模型，亦即在缺失同樣的觀測參數情況下，MLP 模型的推估結果均優於 Allen *et al.* (1998) 所建議的替代方法。此外，我們可以發現各個測站透過 MLP 模型進行推估時，MLP-d 模型性能皆會低於 MLP-b 及 MLP-c 模型，而 MLP-b 與 MLP-c 模型的性能差異並不大，兩種模型彼此間的平均 RMSE 值差異均小於 0.04 (mm/day)，平均 RMSE 值皆不高於 0.3 (mm/day)，表示當測站缺少濕度或風速資料時，透過 MLP 模型可以求得良好的結果，然而，當測站缺少太陽輻射資料時，透過 MLP 模型所求得的 ET₀ 誤差則相對較大，表示對於 MLP 模型而言，推估 ET₀ 較為重要的氣象觀測參數為太陽輻射，而濕度與風速則較為次要。最終比較僅基於

溫度觀測資料的 ET_o 推估模型，結果顯示 MLP-a 模型的性能最佳，而嘉義、新竹及恆春測站的 HS_adj2 模型均優於 PM-1，且優於 HS 模型，永康測站則是 HS 模型與 HS_adj2 模型性能相近，且優於 PM-1 模型，整體而言，當氣象觀測參數僅有溫度資料時，最佳的 ET_o 推估模型為 MLP-a 模型，其次則是 HS_adj2 模型，而 HS 模型與 PM-1 的模型性能排名則要視目標測站而定，但大多數情況下，PM-1 模型優於 HS 模型，這與 Allen *et al.* (1998) 描述的結果一致，因此本研究擇定使用 MLP-a 模型推估未來的 ET_o ，不同測站選用該測站最佳的交叉驗證組別進行未來推估。

4.5 推估氣候變遷對參考作物蒸發散量(ET_o)之影響

本研究為了選出最合適的 GCM 模型，將評估各個 GCM 模型所推估之最高溫與最低溫資料(2015~2023 年)，使其與該測站點的實際觀測值進行比較，並透過均方根誤差 (RMSE) 進行評估，總共評估 21 個 GCM 模型，最終所選用的 GCM 模型為 CanESM5、EC-Earth3、ACCESS-ESM1-5，各測站所使用的 ET_o 推估模型及 ET_o 歷史平均值如表 6。

表 6 各測站所選用模型與網格

目標測站	ET_o (mm/day) 平均值(2004~2020)	使用模型	選用網格 經度 緯度	目標測站	ET_o (mm/day) 平均值(2004~2020)	使用模型	選用網格 經度 緯度
嘉義	3.43	MLP-a2	120.45 23.50	恆春	4.00	MLP-a2	120.75 22.00
新竹	3.06	MLP-a5	121.00 24.85	永康	3.72	MLP-a5	120.25 23.05

圖 7~圖 10 為各測站於不同情境下使用 3 種 GCM 模型所推估的未來 ET_o 變化量，該變化量為模型推估值減去歷史平均值(2004~2020)，從圖中可以發現不論是在哪種未來情境下或是在哪種 GCM 模型中，所推估出的未來 ET_o 相較於歷史平均值都會有所增加，該結果與 Kingston *et al.* (2009) 所發現的結果相似(對於未來升溫 2°C 的氣候情景下，在所有 GCM 模型和所有 PET 方法中所有緯度的 ET_o 都會增加)，並且在大部分的情況下， ET_o 會隨著時間推移逐漸上升，但某些情況下，中長期的 ET_o 會高於長期的 ET_o ，但可以確定的是不論是何種 GCM 模型或在何種模擬情境下， ET_o 從短期到中期再到中長期的這段期間會持續上升。

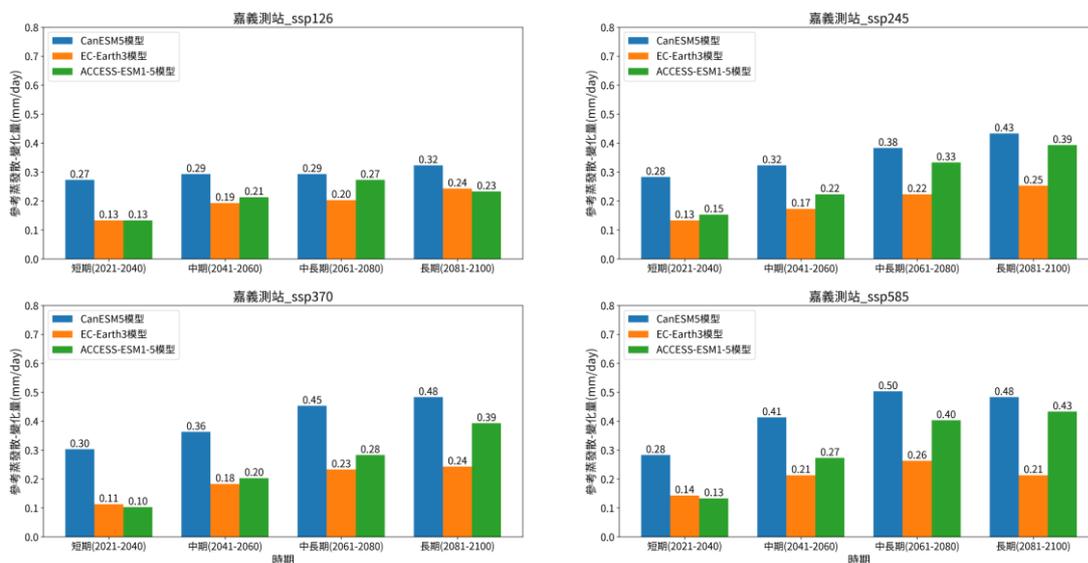


圖 7 嘉義測站_不同情境下 3 種 GCM 模型的 ET_o 變化量

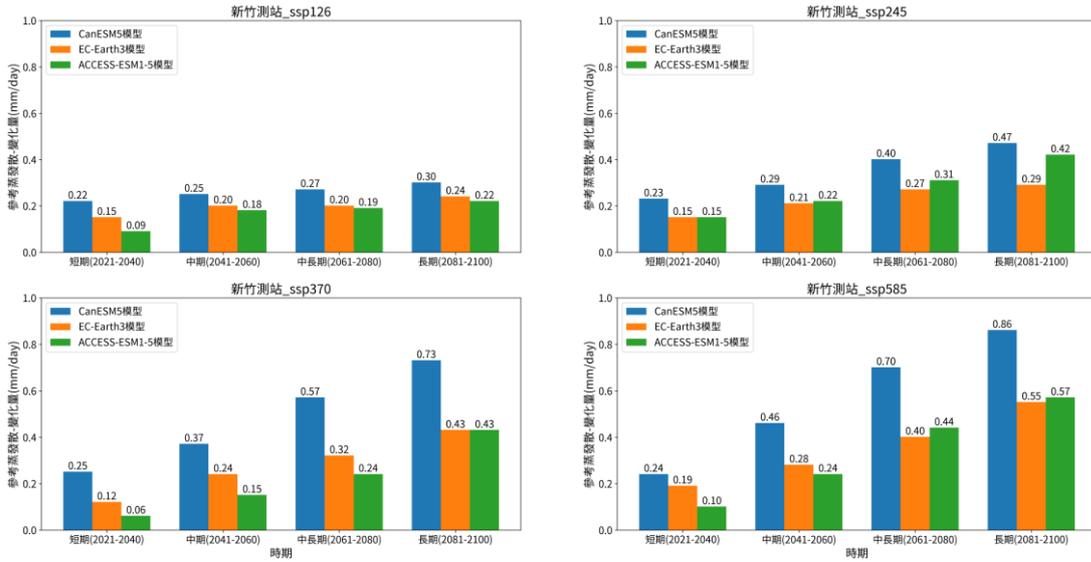


圖 8 新竹測站_不同情境下 3 種 GCM 模型的 ET₀ 變化量

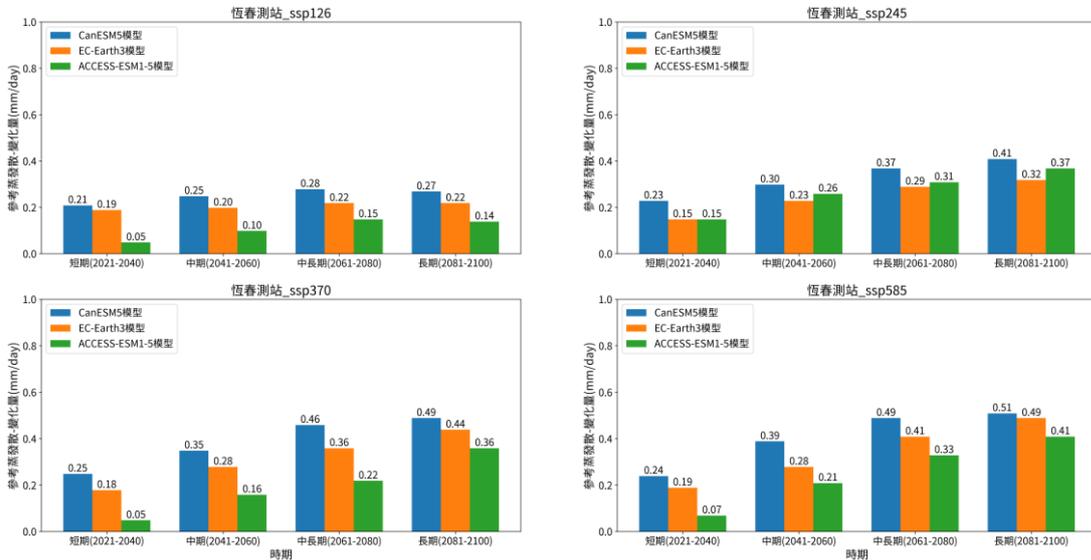


圖 9 恆春測站_不同情境下 3 種 GCM 模型的 ET₀ 變化量

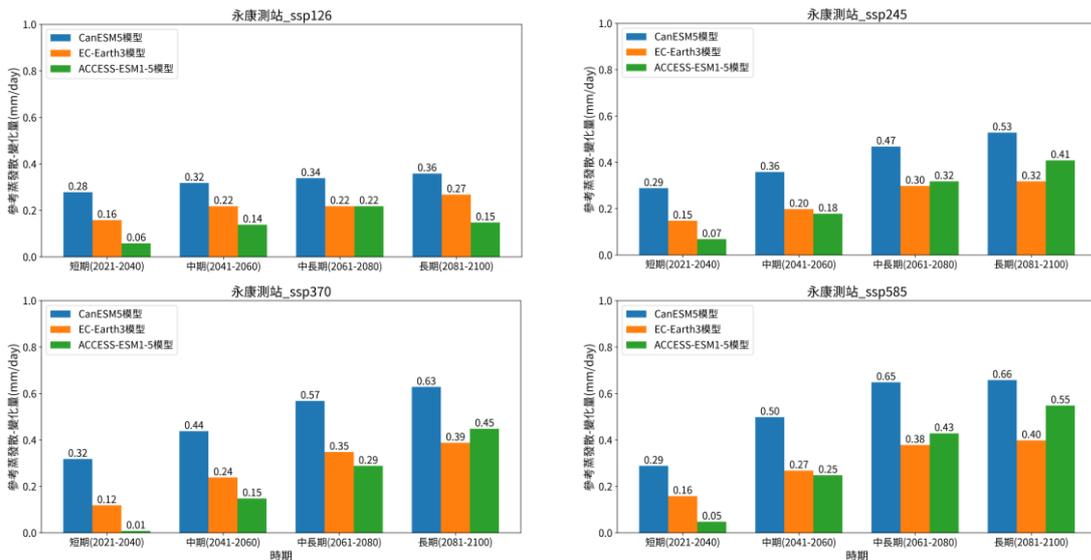


圖 10 永康測站_不同情境下 3 種 GCM 模型的 ET₀ 變化量

比較各測站成果，嘉義測站透過 CanESM5 模型於 ssp585 情境下所預測的中長期 ET₀ 會達到最高，相較於歷史平均值將增加 0.50 (mm/day)，上升了大約 14.7%；新竹測站透過 CanESM5 模型於 ssp585 情境下所預測的長期 ET₀ 會達到最高，相較於歷史平均值將增加 0.86 (mm/day)，上升了大約 28.2%；恆春測站透過 CanESM5 模型於 ssp585 情境下所預測的長期 ET₀ 會達到最高，相較於歷史平均值將增加 0.51 (mm/day)，上升了大約 12.7%；永康測站透過 CanESM5 模型於 ssp585 情境下所預測的長期 ET₀ 會達到最高，相較於歷史平均值將增加 0.66 (mm/day)，上升了大約 17.7%。此外可以發現在中期到長期的這段期間中，所有 GCM 模型於 ssp585 的模擬情境下 ET₀ 的上升幅度最大，並且於 ssp126 的模擬情境下 ET₀ 的上升幅度最小。

五、結論與建議

1. 本研究分析成果顯示透過 HS_adj1 方法跟 HS_adj2 方法都可以求得比原始 HS 方法更佳的結果，並且 HS_adj2 方法又會比 HS_adj1 方法結果更佳。此外，對於 ET₀ 的推估而言，其首要的氣象觀測參數為太陽輻射數據，風速及濕度則較為次要，因此本研究建議未來在設置氣象觀測站時，可以優先考量設置太陽輻射測量儀器。
3. 當氣象觀測參數僅有溫度資料時，相較於使用 Allen *et al.* (1998) 所推薦之替代方法以及 HS 經驗公式，透過 MLP 模型所求得之 ET₀ 均方根誤差最小。
4. 本研究顯示 3 種 GCMs 於所有模擬情境下，未來各階段的 ET₀ 皆呈現增加趨勢，從短期(2021~2040)到中期(2041~2060)再到中長期(2061~2080)的這段期間會持續上升，並於中長期或長期(2081~2100)時達到高峰，因此建議預先提前擬定好應對措施。

參考文獻

- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. Fao, Rome, 300(9), D05109.
- Almorox, J., Quej, V. H., & Martí, P. (2015). Global performance ranking of temperature-based approaches for evapotranspiration estimation considering Köppen climate classes. *Journal of Hydrology*, 528, 514-522.
- Anapalli, S. S., Ahuja, L. R., Gowda, P. H., Ma, L., Marek, G., Evett, S. R., & Howell, T. A. (2016). Simulation of crop evapotranspiration and crop coefficients with data in weighing lysimeters. *Agricultural Water Management*, 177, 274-283.
- Antonopoulos, V. Z., & Antonopoulos, A. V. (2017). Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. *Computers and Electronics in Agriculture*, 132, 86-96.
- Beck, H. E., McVicar, T. R., Vergopolan, N., Berg, A., Lutsko, N. J., Dufour, A., Zeng, Z., Jiang, X., van Dijk, A. I., & Miralles, D. G. (2023). High-resolution (1 km) Köppen-Geiger maps for 1901–2099 based on constrained CMIP6 projections. *Scientific data*, 10(1), 724.
- Boretti, A., & Rosa, L. (2019). Reassessing the projections of the world water development report. *NPJ Clean Water*, 2(1), 15.
- Córdova, M., Carrillo-Rojas, G., Crespo, P., Wilcox, B., & Célleri, R. (2015). Evaluation of the Penman-Monteith (FAO 56 PM) method for calculating reference evapotranspiration

- using limited data. *Mountain Research and Development*, 35(3), 230-239.
- Gamal, R., El-Shirbeny, M., Abou-Hadid, A., Swelam, A., El-Gindy, A.-G., Arafa, Y., & Nangia, V. (2022). Identification and quantification of actual evapotranspiration using integrated satellite data for sustainable water management in dry areas. *Agronomy*, 12(9), 2143.
- Hargreaves, G. H., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. *Applied engineering in agriculture*, 1(2), 96-99.
- Kim, S.-J., Bae, S.-J., & Jang, M.-W. (2022). Linear regression machine learning algorithms for estimating reference evapotranspiration using limited climate data. *Sustainability*, 14(18), 11674.
- Kingston, D. G., Todd, M. C., Taylor, R. G., Thompson, J. R., & Arnell, N. W. (2009). Uncertainty in the estimation of potential evapotranspiration under climate change. *Geophysical Research Letters*, 36(20).
- Kumar, M., Raghuvanshi, N., & Singh, R. (2011). Artificial neural networks approach in evapotranspiration modeling: a review. *Irrigation science*, 29, 11-25.
- Luo, J., Dou, X., & Ma, M. (2022). Evaluation of empirical and machine learning approaches for estimating monthly reference evapotranspiration with limited meteorological data in the Jialing River Basin, China. *International Journal of Environmental Research and Public Health*, 19(20), 13127.
- Mosaffa, H., Sadeghi, M., Mallakpour, I., Jahromi, M. N., & Pourghasemi, H. R. (2022). Application of machine learning algorithms in hydrology. In *Computers in earth and environmental sciences* (pp. 585-591). Elsevier.
- Patil, A. P., & Deka, P. C. (2016). An extreme learning machine approach for modeling evapotranspiration using extrinsic inputs. *Computers and Electronics in Agriculture*, 121, 385-392.
- Petropoulos, G. P., Srivastava, P. K., Piles, M., & Pearson, S. (2018). Earth observation-based operational estimation of soil moisture and evapotranspiration for agricultural crops in support of sustainable water management. *Sustainability*, 10(1), 181.
- Suleiman, A. A., & Hoogenboom, G. (2007). Comparison of Priestley-Taylor and FAO-56 Penman-Monteith for daily reference evapotranspiration estimation in Georgia. *Journal of Irrigation and Drainage Engineering*, 133(2), 175-182.
- Trajkovic, S. (2007). Hargreaves versus Penman-Monteith under humid conditions. *Journal of Irrigation and Drainage Engineering*, 133(1), 38-42.
- Valle Júnior, L. C. G. d., Vourlitis, G. L., Curado, L. F. A., Palácios, R. d. S., Nogueira, J. d. S., Lobo, F. d. A., Islam, A. R. M. T., & Rodrigues, T. R. (2021). Evaluation of FAO-56 procedures for estimating reference evapotranspiration using missing climatic data for a Brazilian tropical savanna. *Water*, 13(13), 1763.
- Wanniarachchi, S., & Sarukkalgige, R. (2022). A review on evapotranspiration estimation in agricultural water management: Past, present, and future. *Hydrology*, 9(7), 123.
- Zounemat-Kermani, M., Batelaan, O., Fadaee, M., & Hinkelmann, R. (2021). Ensemble machine learning paradigms in hydrology: A review. *Journal of Hydrology*, 598, 126266.
- 甘俊二、陳清田、陳焜耀，(1996)，台灣地區作物需水量推估模式之合適性研究，*農業工程學報*，42(2)。
- 許晃雄、王嘉琪、陳正達、李明旭、詹士樑，(2024)，*國家氣候變遷科學報告 2024：現象、衝擊與調適*，國家科學及技術委員會與環境部聯合出版。
- 張斐章、張麗秋，(2014)，*類神經網路導論：原理與應用*，滄海圖書資訊出版。