

計畫編號：：113 保發-5.1-保-01-06-001(15)

利用衛星與模式資料產製高解析度土壤含水量之研究

Development of High-Resolution Soil
Moisture through Satellite and Model Data
Merging and Downscaling
(成果報告)

執行單位：國立中興大學

執行期間：113 年 01 月 01 日至 113 年 12 月 31 日

計畫主持人：陳佳正 教授

農業部農村發展及水土保持署 編印

中華民國 113 年 11 月

(本報告書內容及建議純屬執行單位意見，僅供本局施政參考)



利用衛星與模式資料產製高解析度土壤含水量 之研究

摘要

土壤含水量對地表與大氣間的碳、水及熱循環具重要影響，因此獲取其準確之資料至關重要。目前土壤含水量主要資料來源包括地表測站、衛星遙測及模式模擬等，而以上來源由於各自觀測技術與演算方法不同，在產品之時空解析度、準確率及完整性等方面各有優劣。本研究以臺灣本島為研究區域，使用 Triple Collocation (TC)法將 Climate Change Initiative (CCI)、Soil Moisture Active Passive (SMAP)衛星資料及高解析土地資料同化系統(High-Resolution Land Data Assimilation System, HRLDAS)模式資料產品進行誤差分析與加權融合，並結合卷積長短期記憶網路(Convolutional Long Short-Term Memory Networks, ConvLSTM)，將融合之產品與土壤含水量相關之環境因子(如地形屬性、土地利用、土壤性質、地表反射率、溫度、日射量、降雨及植生指標等)作為 ConvLSTM 之輸入，進行降尺度分析，產製出最終之融合且降尺度產品。此外，本計畫亦利用 Weather Research and Forecasting Model-Hydrological modeling system (WRF-Hydro)模式模擬土壤含水量並進行各項參數初步校驗分析，以期未來產製全臺更精緻之土壤含水量產品。上述產品經過實際測站之觀測資料進行驗證，結果發現融合後產品與測站相關係數可達 0.76，且與各原始產品相比，可有效降低與測站資料之 Bias 與 Root Mean Square Error (RMSE)分別為 48.7~71.8%與 0.4~

20.6%，顯示 TC 方法可有效擷取各產品優勢，得到綜合表現最佳之資料。而融合與降尺度產品同樣為綜合表現最佳，其在維持與測站資料之高相關性(~ 0.76)同時，Bias、RMSE 及 unbiased RMSE (ubRMSE)三指標皆為各產品最佳，分別為 $-0.021 \text{ m}^3/\text{m}^3$ 、 $0.090 \text{ m}^3/\text{m}^3$ 及 $0.042 \text{ m}^3/\text{m}^3$ ，並可更好的反映土壤含水量之空間動態變化趨勢，彰顯其對於中小尺度之相關水文分析之應用價值。WRF-Hydro 模式參數校驗初步分析結果顯示，調校後之模式資料可顯著降低與測站之 Bias (80.5%)與 RMSE (61.0%)，並更可明顯展現出土壤含水量在極端豪雨事件之動態變化情形。本研究成果除能解決土壤含水量資料較為稀缺與解析度不足等問題外，未來可將結果應用於農業灌溉、洪旱災預警及集水區水源涵養能力評估等相關水文分析。

關鍵詞：土壤含水量、水文模式、資料融合、深度學習、降尺度分析



Development of High-Resolution Soil Moisture through Satellite and Model Data Merging and Downscaling

Abstract

Soil moisture (SM) is a crucial component of the hydroclimate system, yet obtaining an accurate estimate of SM at a high spatiotemporal resolution is still challenging. Three primary sources of SM data, namely satellite sensors, land surface models, and in-situ measurements, exhibit their strengths and weaknesses in accuracy and spatiotemporal coverage. This study employs the Triple Collocation (TC) method to merge SM data from the Climate Change Initiative (CCI), Soil Moisture Active Passive (SMAP), and the High-Resolution Land Data Assimilation System (HRLDAS) products in Taiwan. Based on the TC method, random error analysis is performed to calculate the weight of each SM product, which is used to produce a multi-source, weighted average SM dataset. Afterwards, a deep learning method referred to as Convolutional Long Short-Term Memory Networks (ConvLSTM) is used to downscale the merged SM product, with the use of SM-related environmental factors (e.g., topographic attributes, soil properties, land use, surface reflectance, temperature, solar radiation, precipitation, and vegetation indices) as input variables. In order to produce a better SM product for Taiwan, the Weather Research and Forecasting Model-

Hydrological modeling system (WRF-Hydro) is adopted, and preliminary calibration analysis is conducted for the simulation of SM. All the original, by-products (merged or downscaled), and final (merged and downscaled) products are validated against in-situ measurements. The validation results show that the merged product achieves a high correlation coefficient (0.76) with gauge data and effectively reduces the Bias and Root Mean Square Error (RMSE) by 48.7~71.8% and 0.4~20.6%, respectively, indicating the effectiveness of the TC method. The merged and downscaled (M&D) product exhibits even a more comprehensive performance. While maintaining a high correlation (0.76) with gauge data, the M&D SM produces the best Bias (-0.021 m³/m³), RMSE (0.090 m³/m³), and unbiased RMSE (ubRMSE, 0.042 m³/m³) among all products. The M&D product can better reflect the spatiotemporal trends of SM, suggesting its usefulness for fine-scale hydrological analyses. Preliminary analysis of WRF-Hydro demonstrates that the calibrated model data significantly reduces the Bias and RMSE by 80.5% and 61.0%, respectively; the calibrated model data also show better SM variations during extreme rainfall events. The developed high-resolution SM product is expected to facilitate various applications, including agricultural irrigation, flood and drought management, and assessment of watershed water conservation capacity.

Keywords : Soil moisture, Hydrologic model, Data merging, Deep learning, Downscaling

目次

摘要.....	I
Abstract.....	III
目次.....	V
表次.....	IX
圖次.....	X
第一章 前言	1-1
第一節 計畫緣起與目的	1-1
一、計畫緣起	1-1
二、計畫目的	1-4
第二節 計畫目標	1-4
一、全程目標	1-4
二、本年度目標	1-5
第二章 文獻回顧	2-1
第一節 衛星遙測技術於土壤含水量推估	2-1
第二節 水文模式(WRF-Hydro)	2-5
第三節 高解析度土地資料同化系統(HRLDAS)	2-7
第四節 多源土壤含水量資料融合應用方法	2-12
第五節 深度學習於土壤含水量之降尺度應用	2-14
第三章 研究區域與資料	3-1
第一節 研究區域	3-1
第二節 土壤含水量資料	3-1
一、CCI 產品	3-1
二、SMAP 產品	3-3

三、HRLDAS 產品	3-5
四、地表土壤含水量測站資料	3-9
第三節 土壤含水量相關環境因子資料	3-11
一、地形屬性資料	3-11
二、土地利用 資料	3-12
三、Land GIS 資料	3-14
四、MODIS 表面反射率資料	3-15
五、HRLDAS 模式輸出資料	3-16
六、Taiwan Climate Change Projection Information and Adaptation Knowledge Platform (TCCIP) 資料	3-16
七、Taiwan ReAnalysis Downscaling data (TReAD) 資料	3-20
八、土壤質地分類資料	3-20
第四節 最新取得資料	3-23
一、水利數值地形模型	3-23
二、最新臺中市土地利用 資料	3-26
第四章 研究方法	4-1
第一節 計畫研究架構說明	4-1
第二節 多源土壤含水量融合與降尺度研究流程說明	4-1
第三節 資料前處理	4-3
一、網格重採樣	4-3
二、偏差校正	4-4
第四節 TC 資料融合方法	4-6
一、隨機誤差分析	4-6
二、最佳權重分析	4-8

第五節	基於深度學習之空間降尺度	4-10
一、	空間降尺度流程	4-10
二、	深度學習方法之應用框架	4-11
三、	ConvLSTM 模型介紹	4-14
第六節	基於統計之時間降尺度	4-16
第七節	評估指標	4-17
第八節	WRF-Hydro 模式	4-18
一、	模式介紹	4-18
二、	ArcGIS 預處理	4-21
三、	模式設定	4-22
四、	參數調校	4-23
第五章	分析結果	5-1
第一節	土壤含水量產品偏差校正結果	5-1
第二節	TC 誤差分析結果	5-1
第三節	0.25° 土壤含水量產品準確性分析結果	5-4
第四節	前期降水指數(API)分析結果	5-8
第五節	ConvLSTM 模型驗證結果	5-11
一、	CCI 產品之模型驗證成果	5-11
二、	SMAP 產品之模型驗證成果	5-13
三、	Merged & Downscaled 產品之模型驗證成果	5-15
第六節	3 km 土壤含水量產品準確性分析結果	5-17
第七節	土壤含水量產品於颱風豪雨事件之評估結果	5-21
第八節	WRF-Hydro 土壤含水量模擬之參數校驗結果	5-25
第六章	結論與建議	6-1

第一節 研究結論	6-1
第二節 研究建議	6-3
參考文獻.....	參-1
附錄.....	附錄-1



表次

表 3-1 本研究採用測站站點之經緯度與資料採用期間.....	3-11
表 3-2 臺灣本島土地利用概況及其對應曼寧粗糙係數.....	3-14
表 3-3 MOD09GA 產品之各波段與其所對應之波長表.....	3-16
表 3-4 臺灣地區土壤種類與其對應之 K_s	3-22
表 4-1 各土壤參數調校倍數.....	4-24
表 5-1 0.25°解析度之三產品與測站 Bias 之 Median 與 Average	5-1
表 5-2 0.25°解析度之四產品與測站之統計分析結果	5-5
表 5-3 土壤含水量之動態、靜態因子分類表.....	5-11
表 5-4 3 km 解析度之四產品與測站之統計分析結果	5-17
表 5-5 模式校正前後模擬之土壤含水量與測站之分析結果.....	5-30



圖次

圖 3-1 CCI 產品於臺灣本島之資料涵蓋範圍.....	3-3
圖 3-2 SMAP 產品於臺灣本島之資料涵蓋範圍	3-5
圖 3-3 HRLDAS 模式資料之模擬流程	3-8
圖 3-4 HRLDAS 產品於臺灣本島之資料涵蓋範圍	3-9
圖 3-5 土壤含水量地表測站分布圖	3-10
圖 3-6 地形屬性圖	3-12
圖 3-7 臺灣本島於 2015 年之土地利用分類圖	3-13
圖 3-8 土壤性質圖	3-15
圖 3-9 更新後之臺灣土壤分類圖	3-22
圖 3-10 水利數值地形資料測製流程圖	3-24
圖 3-11 桃園市與淡水河流域範圍之 HyDEM 圖	3-25
圖 3-12 桃園市與淡水河流域範圍之 HyDEM 與 DEM 差異圖	3-25
圖 3-13 臺中市 2015 土地利用分類(第一級)	3-27
圖 3-14 臺中市 2023 土地利用分類(第一級)	3-27
圖 4-1 本計畫之多源土壤含水量融合與時空降尺度研究流程圖	4-2
圖 4-2 各產品重採樣後網格區域	4-4
圖 4-3 土壤含水量產品之 CDF matching 偏差校正示意圖	4-5
圖 4-4 本研究之土壤含水量產品降尺度流程	4-11
圖 4-5 ConvLSTM 模型運算之單元結構圖	4-14
圖 4-6 ConvLSTM 資料輸入維度轉換示意圖	4-16
圖 4-7 本研究之土壤含水量時間降尺度流程	4-17
圖 4-8 WRF-Hydro 物理參數和相關輸出概念圖	4-20
圖 4-9 模式地形流向概念圖	4-20

圖 4-10 模式渠道設定示意圖	4-21
圖 4-11 ArcGIS 預處理流程	4-22
圖 4-12 本計畫之 WRF-Hydro 參數調校流程	4-24
圖 5-1 三產品之 COV 空間分布圖	5-3
圖 5-2 三產品與未知真值之 REV 空間分布圖	5-3
圖 5-3 三產品於融合時所佔之權重空間分布圖	5-3
圖 5-4 各 0.25°產品與測站評估成果之盒狀圖	5-5
圖 5-5 各 0.25°解析度之各產品與測站資料之時間序列圖	5-7
圖 5-6 0.25°之各網格計算 API 所使用之 K 值、考慮天數與 λ 值..	5-9
圖 5-7 0.25°之降雨量、Yeo-Johnson 轉換前後之 API 分別與 Merged SM 之相關係數	5-9
圖 5-8 3 km 之各網格計算 API 所使用 K 值、考慮天數與 λ 值...	5-10
圖 5-9 Yeo-Johnson 轉換後之 API 與 HRLDAS SM 相關係數	5-10
圖 5-10 CCI 產品於模型驗證階段之預測值與實際值散佈圖	5-12
圖 5-11 CCI 產品驗證階段各環境因子之特徵貢獻度	5-13
圖 5-12 SMAP 產品於-模型驗證階段之預測值與實際值散佈圖 ...	5-14
圖 5-13 SMAP 產品驗證階段各環境因子之特徵貢獻度	5-15
圖 5-14 Merged 產品於模型驗證階段之預測值與實際值散佈圖 ..	5-16
圖 5-15 Merged 產品驗證階段各環境因子之特徵貢獻度	5-16
圖 5-16 各 0.25°產品與測站評估成果之盒狀圖	5-18
圖 5-17 各 0.25°解析度之各產品與測站資料之時間序列圖	5-20
圖 5-18 兩產品於 2018 年 0823 熱帶低壓水災事件之空間分布圖： (a)NCDR 觀測雨量；(b)Merged SM；(c)M&D SM	5-22
圖 5-19 兩產品於 2019 年 0517-0520 豪雨事件之空間分布圖： (a)NCDR 觀測雨量；(b)Merged SM；(c)M&D SM	5-23

圖 5-20 兩產品於 2021 年盧碧及 0806 豪雨事件之空間分布圖： (a)NCDR 觀測雨量；(b)Merged SM；(c)M&D SM	5-24
圖 5-21 上安測站各參數敏感度分析之時間序列圖	5-26
圖 5-22 上安測站各參數敏感度分析之時間序列圖	5-27
圖 5-23 上安測站各參數敏感度分析之時間序列圖	5-28
圖 5-24 上安測站各參數敏感度分析之時間序列圖	5-29
圖 5-25 上安測站最佳參數倍數組合之時間序列圖	5-30



第一章 前言

第一節 計畫緣起與目的

一、計畫緣起

土壤含水量(Soil Moisture, SM)對地表與大氣間之能量循環、通量變化有著重要影響，因此已被廣泛認為是水文氣候系統重要變量之一(Peng et al., 2017; Long et al., 2019)。再者，隨著現今氣候變遷愈加嚴重，發生極端水文氣象災害如與降雨有關之山崩、乾旱以及淹水等事件頻率也愈加頻繁，且上述災害皆與 SM 息息相關。因此獲取準確、即時及覆蓋率高之 SM 資料顯得格外重要，其不僅可為農業灌溉和水資源管理提供許多重要資訊，亦可作為洪旱災害監測之重要依據(Dobriyal et al., 2012)。

然而土壤含水量觀測不易，目前主要資料來源為地表測站、衛星遙測及模式模擬等，然上述來源產品由於各自觀測技術和計算方法等不同，在時空完整性、準確性及解析度上均各有其優缺點。如地表測站雖然可獲取單一點位長時間之連續觀測資料，但無法提供同一時刻之大範圍資料；此一局限性在臺灣尤為顯著，乃因目前臺灣本島之 SM 地表測站點數與雨量站相比較為稀缺，且分布多集中在山區。而基於衛星遙測之 SM，如美國國家航空暨太空總署(National Aeronautics and Space Administration, NASA)部署之 Soil Moisture Active Passive (SMAP)任務，可提供近全球尺度之大範圍觀測，但受限於衛星重訪頻率、所搭載感測器解析度、雲層與地表植被遮蔽等因素，只能提供時空解析度與完整性較為粗略之資料。相較之下，目前已廣泛應用於氣候監測、區域水循環等領域之 Weather

Research and Forecasting Model-Hydrological modeling system (WRF-Hydro)與高解析度土地資料同化系統(High Resolution Land Data Assimilation System, HRLDAS)之模式資料具有更精細之時空解析度，且可展現更細緻之時序變化趨勢，使其在進行中小尺度之水文分析更具應用性。但此類模式資料之準確度往往取決於其模式之各參數設定、初始化狀態、輸入之驅動資料與其使用之土壤含水量物理擴散過程方程式等眾多不確定性之影響(Lee et al., 2022; Ming et al., 2022)。基於上述產品不同特性，若能對衛星和模式等多源產品進行融合將有助於減少資料之不確定性，從而提供更加準確之 SM 資料(Gruber et al., 2017)。

現今已開發出多種資料融合方法，如常用於融合觀測和模式土壤含水量資料之全球土地資料同化系統(Global Land Data Assimilation System, GLDAS)，但此缺點在於若缺乏對其系統不確定性來源之正確理解，可能會限制其應用，且資料融合過程不僅複雜，還需耗費許多運算資源(Zhang et al., 2021)。與 GLDAS 不同，另一種基於統計之資料融合之 Triple Collocation (TC)方法由於其計算快速、運算成本低與不需仰賴其他輔助環境資料等優勢，使其被廣泛應用於多源土壤含水量產品之融合。TC 主要為評估三組獨立之資料產品與未知真值間之誤差，透過分析產品間之共變異數及每產品自身之變異數，從而推估出各產品與真值間之隨機誤差變異數，並可進一步根據此隨機誤差變異數進行加權融合產製出一隨機誤差變異數最小之產品(Stoffelen et al., 1998)。TC 方法目前已廣泛應用於多源土壤含水量之融合，如歐洲太空總署(European Space Agency, ESA)之氣候變遷倡議計畫(Climate Change Initiative, CCI)所提供之土

壤含水量資料即有使用 TC 方法來對多個衛星觀測資料進行融合產製而成；Ming et al. (2022)也利用 TC 方法將 Global dataset for the land component of the fifth generation of European Reanalysis (ERA5-Land)再分析資料、GLDAS-Noah 模式與 SMAP 衛星資料融合。

另一方面，中小尺度之山崩、土石流災害監測、洪旱災及水文氣象分析往往需要高解析度之 SM 資料，然基於衛星或模式等產品因其解析度不足與偏差過高等因素，使其在實際應用上受到諸多限制，因此針對各種 SM 產品，目前也已發展出數種降尺度方法 (Sabaghy et al., 2018)，其中基於機器學習(Machine Learning, ML)與深度學習(Deep Learning, DL)之方法因在模型配置上具有高度靈活性，且能夠高效、準確的處理大資料和擬合複雜之非線性問題，在此方面研究中受到了最多關注(Ali et al., 2015)。而在實際應用上，Ming et al. (2022)透過長短期記憶網路(Long Short Term Memory Network, LSTM)模型對多個 SM 產品進行降尺度，其成果顯示 LSTM 模型能在提升 SM 產品解析度之同時保有可靠準確度。而相較於 LSTM，卷積長短期記憶網路(Convolutional LSTM, ConvLSTM)則是在 LSTM 基礎上進一步結合卷積神經網路(Convolutional Neural Networks, CNN)之空間特徵擷取能力，使其可同時處理時間與空間序列資料，對於預測土壤含水量此等具高度時空相關性之水文變量而言，此特點顯得尤其重要。

綜上所述，本研究欲結合 TC 方法與 ConvLSTM 模型之架構，以臺灣本島為研究區域，對 CCI、SMAP 與 HRLDAS 等產品進行融合與降尺度分析，並對 WRF-Hydro 模式進行土壤含水量模擬的參數

校驗分析，希冀透過此研究探討衛星與模式等資料在臺灣之特性與差異，並提供更具綜合性之產品，為相關水文分析增添參考依據。

二、計畫目的

本計畫目的為使用 TC 方法融合 CCI、SMAP 與 HRLDAS 等產品，產製綜合不同來源產品優勢之資料，並透過統計評估指標探討分析各原始產品與融合後產品之差異，以評估 TC 方法在臺灣地區的適用性及其在提升資料準確度方面的有效性，並且進一步將各 SM 產品與其相關之輔助環境因子輸入至 ConvLSTM 進行降尺度分析，提升各產品之時空解析度，以展現土壤含水量在時空上更細緻之變化，並同時針對 WRF-Hydro 模式進行土壤含水量模擬時之各項參數校驗分析，以提升模式於土壤含水量模擬之準確度，從而增強上述產品對中小尺度水文分析的應用潛力，並探討其是否可作為無測站區域的參考依據，增加臺灣在土壤含水量資料方面的多樣性。

第二節 計畫目標

一、全程目標

- (1)開發土壤含水量時空降尺度程式與資料融合程式與分析流程架構。
- (2)進行 HRLDAS 土壤含水量準確性分析與空間降尺度分析，以產製空間解析度 3 公里以下，時間解析度 1 小時之臺灣本島土壤含水量網格資料。
- (3)進行衛星土壤含水量(如 SMAP、ESA CCI 等)準確性分析與時空降尺度分析，以產製空間解析度 3 公里以下，時間解析度 1 小時之臺灣本島含水量網格資料。

(4)進行 WRF-Hydro 模式調校(包含取得 HyDEM、臺灣地區土壤資料、最新土地利用資料等並進行預處理)，以產製空間解析度 3 公里以下，時間解析度 1 小時之臺灣本島含水量網格資料。

(5)進行衛星與模式土壤含水量產品融合，以產製空間解析度 3 公里以下，時間解析度 1 小時之臺灣本島融合含水量網格資料。

二、本年度目標

(1)達成「全程目標」項目(1)。

(2)達成「全程目標」項目(2)。

(3)達成「全程目標」項目(3)。

(4)針對「全程目標」項目(4)，完成中部地區(苗栗、臺中、彰化、雲林與南投)之測試。

(5)針對「全程目標」項目(5)，完成中部地區(苗栗、臺中、彰化、雲林與南投)之測試。





第二章 文獻回顧

第一節 衛星遙測技術於土壤含水量推估

獲取土壤含水量觀測資料傳統上仰賴地表測站直接測量，此觀測方法雖最為準確，但不僅耗時耗力、易受極端天氣影響，且測站點位常有過於稀缺且分布不均之狀況。再者，土壤含水量於空間上之異質性極高，以上因素導致基於測站之觀測資料無法完全反映土壤含水量於空間上之變異模式(Tong et al., 2020)。隨著近數十年科技進步，使用衛星遙測(Remote Sensing)進行大尺度土壤含水量觀測已逐漸成為趨勢，基於微波(Microwave)、可見光(Optical)與熱紅外線(Thermal Infrared)之感測器皆已成功應用於全球表層土壤含水量檢索(Peng & Loew, 2017)，其中基於微波波段之遙測由於波長較長(約 1 cm 至 1 m)使其穿透能力較強，受大氣雲層散射與地表植被干擾較小、對土壤介電係數(Soil Dielectric Constant)敏感及不受太陽光照影響，可進行日夜不間斷連續觀測等眾多優勢，使其在此方面受到最多重視(Barrett et al., 2009)。衛星遙測依據其所接收之電磁波訊號源差異，分為主動式遙測(Active Remote Sensing)與被動式遙測(Passive Remote Sensing)兩類。前者是透過主動發射電磁波並接收其被地表或大氣反射、折射或散射後之訊號並加以分析；後者則是直接接收並測量地表、大氣產生之自然輻射，常用來測量地表成分、溫度、表面特性等，其工作頻段根據目標物質之物理特性決定(賴郡曄、林遠見，2022)。

根據 Karthikeyan et al. (2017)所述，微波遙測推估土壤含水量之原理源自於土壤介電係數(作為土壤含水量之間接測量值)，會影響

土壤表面在微波頻率下之發射率(Emissivity)和反散射(Backscattering)特性，因此主動(雷達)和被動(輻射計)感測器可以透過測量土壤表面之亮度溫度與反散射值來推估土壤含水量，微波遙測對土壤表層(約1~5 cm)尤為敏感，其穿透深度與其波長成正比，通常為波長十分之一到一半，而土壤越濕潤，其微波發射率降低，導致輻射計測量到的亮度溫度越低；同時在雷達觀測中，越濕潤之土壤其微波反散射能力越強，其反射回雷達之信號強度亦會增加，從而使雷達影像上之反射亮度越高，反之亦然，而 L 波段(0.5-1.5 GHz)、C 波段(4-8 GHz)與 X 波段(8-12 GHz)等對土壤含水量較敏感，其中 L 波段被視為是最適合測量土壤含水量之微波波段(Kerr et al., 2010)，因為其相較其他波段可更有效穿透至更深之土壤(約 5 cm)。

利用被動式微波遙測推估土壤含水量這項技術最早可追溯到上世紀 70 年代，微波輻射計透過測量土壤表面之熱輻射，並將其轉化為亮度溫度(Brightness Temperature, TB)之形式，進而推估土壤含水量大小，而根據 Karthikeyan et al. (2017)，TB 正比於土壤物理溫度(Soil physical temperature, T_s)，而此比例係數為土壤表面之微波發射率(ε)，如式 2-1 所表示。

$$T_B = \varepsilon \times T_s \quad (2-1)$$

式中 ε 受土壤含水量強烈影響，當土壤含水量增加， ε 則會降低，進一步使 TB 降低，此即為被動式微波遙測推估土壤含水量之原理。

另一方面，由於地表自然輻射之能量在對土壤含水量敏感之微波段非常微弱，因此基於測量 TB 之被動式微波遙測需要更大的覆蓋面積才可測量到足夠的輻射量，使其空間解析度往往過於粗略(約數十公里不等)，如目前最新發射之兩顆專用於土壤含水量觀測衛

星，分別為 ESA 於 2009 年發射之 Soil Moisture and Ocean Salinity (SMOS) 與 NASA 之 SMAP 所搭載之被動輻射計，分別可提供 25 km 和 36 km 解析度，時間解析度約 2~3 天之表層土壤含水量資料。

與被動式遙測相同，主動式遙測一樣可追溯到上世紀 70 年代，主動式微波感測器可分為成像(Imaging)與非成像(Non-imaging)感測器兩類，其中雷達是最廣泛被應用之成像感測器，而合成孔徑雷達(Synthetic Aperture Radar, SAR)則是基於雷達技術上，專為遙測應用而設計的高階成像感測器，目前已成功應用於土壤含水量觀測之 SAR 包括 ENVISAT、TerraSAR-X、Sentinel-1 及 SMAP 其所搭載之主動感測器；另一方面，散射計(Scatterometer)與高度計(Altimeter)則屬於非成像感測器，前者主要用途為風速與土壤含水量觀測，後者則主要用於地表高程測量，目前已成功應用於土壤含水量觀測之散射儀包含 QuikSCAT、ERS Scatterometer 及 ASCAT 等(Karthikeyan et al., 2017)。

如上述之各種主動微波感測器，可透過主動向地表發射微波，並測量地表反射回來之微波，因此不同於被動輻射計，其可提供數十公尺等級之高空間解析度資料(Walker et al., 2004)。其中發射與反射微波之間能量差異，被稱為反散射係數(σ^0)，通常以分貝(Decibels, dB)表示(Mo et al., 1984)，此係數代表入射波能量與平均反射回來能量之比例，並且還需要考慮如土壤之物理和電性質、地表粗糙度、植被覆蓋、感測器之波長(Wavelength)、偏振(Polarisation)與入射角(Incidence Angle)等眾多因素之影響，因此解析來自土壤表面反射之微波，並判斷其中哪部分真正源自土壤含水量顯得極為複雜，而根據 Schmugge et al. (2002)研究表示，植被覆蓋率是影響反散

射係數最為關鍵之因素之一，首先，植被不僅會吸收自土壤表面反射之微波，也會吸收部分直接入射其上之微波，植被所吸收的輻射量主要與其含水量有關；其散射程度則取決於植被之幾何形態。植被對於散射之影響與所發射微波波長成反比，而波長較長之 L 波段被植被影響程度相較其他波段較小，因此被視為是最適合進行土壤含水量觀測之波段(Van de Griend & Wigneron, 2004)。

另一方面，地表粗糙度同樣對反散射係數有顯著影響，其可視為是相對衛星測量基準面，地表高程之變化，目前主要計算方法是透過分析觀察到的高度變化，從而計算出土壤表面之平均平方根高度、相關長度及自相關函數等統計參數，這些參數隨後作為其反散射模型輸入(Snapir et al., 2014)，地表粗糙度影響反散射係數的原因為在高空間解析度下，地表之微觀結構能夠改變入射微波之散射方向和強度，具體而言，當入射波遇到粗糙表面時，將會以多種不同角度散射，進而增強多方向反射與散射能量，如 Ulaby & Batlivala (1976)發現，當感測器入射角度大於 10° 時，反射回來之能量會隨著地表粗糙度增加而增加。同時，由於上述植被與地表粗糙度等自然因素無法人為控制，因此許多研究更傾向於如何更好的調校感測器參數於土壤含水量檢測，如 Holah et al. (2005)分析 Advanced SAR (ASAR)資料對水平偏振(Horizontal transmit, Horizontal receive, HH)、交叉偏振(Horizontal transmit, Vertical receive, HV)與垂直偏振(Vertical transmit, Vertical receive, VV)等多種偏振形式與多個入射角對觀測之影響，發現 HH 偏振與 HV 偏振對土壤含水量變化最為敏感；中低角度之入射角(20° 至 37°)對土壤含水量估算最為理想，此發現與 Li

et al. (2004)研究結果相符，後者指出入射角度過大對土壤含水量之敏感度會降低，進而出現較大之觀測誤差。綜上所述，文獻中之普遍共識為使用低入射角、較長的波長、使用 HH 或 HV 偏振形式等參數配置對於主動微波感測器推估土壤含水量是較佳的(Barrett et al., 2009)。

第二節 水文模式(WRF-Hydro)

WRF-Hydro 為 Weather Research & Forecasting Model (WRF)模式中預設水文模組之擴展版本，屬於多參數分散式類型之物理性水文模式，提供準確之土壤含水量、漫地流、地下水、和河流演算模擬資訊，可應用於區域水文氣象評估、洪災預報、水資源管理及地表大氣耦合研究。WRF-Hydro 可與地球系統模式進行耦合，也可獨立作為傳統水文模式運行，目前已在全球多項研究中應用。通過與 WRF 模型的雙向耦合，WRF-Hydro 可更具物理性地模擬大氣與陸地間的水文收支變化。WRF-Hydro 在土壤含水量方面之相關研究包括 Rummler et al. (2019)將 WRF 與 WRF-Hydro 耦合模式應用於位在德國南巴伐利亞地區和東阿爾卑斯山，研究發現降雨模擬受 WRF-Hydro 耦合模式增加了土壤含水量反饋影響，比 WRF 模擬表現來的較為突出。Wehbe et al. (2019)使用 WRF 及 WRF-Hydro 耦合模式評估調查 2016 年 3 月影響阿拉伯聯合酋長國極端天氣事件，結果顯示與 WRF 相比，WRF-Hydro 耦合模式對於降雨預報的 Root Mean Square Error (RMSE)和 relative bias (rBIAS)分別減少了 24%及 13%；且與 Advanced Microwave Scanning Radiometer 2 (AMSR2)得出的土壤含水量估計值相比，WRF-Hydro 耦合模式能夠在整個研究域中合

理地模擬土壤含水量之空間分佈。Galanaki et al. (2021)使用 WRF-Hydro 耦合模式於希臘阿提卡地區進行洪水預報，以及研究陸地-大氣間交互作用對降雨預報的影響，其研究透過調校 RETDEPRTFAC、REFKDT、MannN、OVROUGHRTAC 等參數改善流量估計值，在調校後所有事件流量模擬值與觀測值相關係數皆高於 0.7，這對於理解研究區域模擬洪災機制至關重要。

而國內研究有林梓舜(2014)使用 WRF-Hydro 耦合模式探討地表水文過程及土壤含水量及大氣模擬影響，並以全球地表同化系統 (Global Land Data Assimilation System, GLDAS)的土壤含水量及土壤溫度來取代原先初始場的資料做為初始值，試圖改善模式土壤初始化、土壤型態及次網格解析度的物理水文過程，針對 2013 年 8 月 29 號至 9 月 11 號的個案進行討論。其結果顯示，GLDAS 相較模式預設初始場資料，提供了與實際觀測較為吻合之土壤含水量。另外，在 WRF-Hydro 耦合模式條件下，由於側向水流動，土壤含水量在山區減少，平地有所增加，進而改善逕流過程。從上述研究中可以發現 WRF-Hydro 可合理地模擬土壤含水量分佈，除了改善土壤層側向水流動外，更可在耦合條件下更好地描繪陸地與大氣之間的水文循環。

第三節 高解析度土地資料同化系統(HRLDAS)

由美國國家大氣研究中心(National Center for Atmospheric Research, NCAR)開發之高解析度土地資料同化系統(HRLDAS)為一被廣泛使用之陸面模式(Land Surface Model, LSM)之離線驅動系統，其核心基於 Noah 陸面模式(Noah LSM)。HRLDAS 開發目的旨在解決數值天氣預報(Numerical weather prediction, NWP)中因土地參數，如植被、土壤含水量及土壤溫度等資料因解析度與準確性不足，而導致預報結果精度不足問題，其中高解析度土壤含水量資料稀缺問題尤為嚴重。根據 Trier et al. (2004)研究結果顯示，土壤含水量初始化精確度對於模擬對流啟動的位置和面積極為重要。當使用高解析度之土壤含水量資料進行初始化時，可以更精確模擬對流啟動的時間和位置；反之，使用較低解析度之土壤含水量資料時，即便對流層之乾線(Dry line)結構和變化之模擬結果與高解析度情況相似，但對流啟動位置之預測卻顯得不夠精確。這種差異主要源於不同解析度之土壤含水量初始化導致地表可感熱與潛熱通量在局部分布之差異，進而影響對流層下層之熱力學結構。因此可顯示高解析度之土壤含水量資料對於提高天氣模式中對流發展之預測精度至關重要。然而，目前尚無區域性至全球範圍之連續高空間解析度水分資料，並且土壤含水量在空間上之異質性極高，常在小範圍內就有著高度差異，而現有之土壤含水量資料解析度過於粗略，使得 WRF 等高解析度之 NWP 模式難以準確掌握並模擬這些細節，進而影響模式對天氣系統之預測效果。對此，為解決上述 NWP 中土地參數初始化問題，Chen et al. (2007)提出結合資料同化技術、衛星遙測和 LSM 之方法，透過將觀測雨量、衛星遙測之地表土壤資訊及氣象資料驅

動非耦合之 LSM，使模型中的土壤含水量變化能夠受到觀測強迫條件約束，進而提升 LSM 模擬土壤含水量之準確性。為此，美國國家海洋暨大氣總署(National Oceanic and Atmospheric Administration, NOAA)、NASA、Princeton University、the University of Washington 等多機構共同開發了北美土地資料同化系統(North American land data assimilation system, NLDAS)，NLDAS 使用小時時間解析度之觀測強迫資料作為輸入，具有 0.125° 之空間解析度，並由四個 LSM 所構成，包括 Noah LSM、Mosaic LSM、Variable Infiltration Capacity Model (VIC)及 Sacramento Soil Moisture Accounting Model (SAC-SMA)等，儘管如此，NLDAS 可能還不是高解析度之 WRF 土地參數初始化精確度不佳問題之最佳解決方案，這是由於高解析度之 WRF 應用通常使用 2 至 4 km 之解析度，因此 NLDAS 之 0.125° 解析度在此情況下仍顯不足，儘管 WRF-Noah 與 NLDAS-Noah 系統都採用了相同之 Noah LSM 為基礎，但由於 NLDAS 與 WRF 之解析度不相同，導致使用 NLDAS 所提供之土壤含水量資料來初始化 WRF 可能會引發問題，這主要是因為這兩系統在地形、土地利用及土壤質地方面之解析度不匹配，從而可能導致兩系統計算出之土壤含水量有所不同。為此 NCAR 進一步開發了 HRLDAS 以解決這些問題並滿足 WRF 所需之精確土地參數初始化需求，本質上，HRLDAS 以非耦合形式運行於與 WRF 相同之網格上，使得 WRF 和 HRLDAS 可以在不需進行空間插值之情況下，共享相同解析度之土地利用、土壤質地、高程及植被屬性等各項土地參數。因此，HRLDAS 所模擬之土壤條件可以直接用於 WRF 系統中。

國內外有許多評估 HRLDAS 之表現並探討其在 NWP 應用之相關研究，如 Zhao et al. (2022)於 2019 至 2021 年在美國內布拉斯加州 (Nebraska)產製解析度為 500 公尺；小時之 HRLDAS 土壤含水量資料，並透過將 HRLDAS 其與 AmeriFlux network、U.S. Climate Reference Network (USCRN)及 Soil Climate Analysis Network (SCAN)等地表測站資料進行比較，發現 HRLDAS 在各土層之模擬資料與測站資料表現出良好之準確度，其中 HRLDAS 的 5 公分、25 公分、70 公分與 150 公分等四土層與測站資料之 Root Mean Square Error (RMSE)分別為 0.06、0.07、0.14 和 0.07 m^3/m^3 ，顯示 HRLDAS 能夠有效掌握土壤含水量之變化；但另一方面，由於 HRLDAS 模式是基於大氣驅動與能量平衡，並未考慮到人為灌溉活動，因此在乾旱時期(如 2020 年)之模擬會出現較大誤差，於是此研究透過引用當地灌溉資料校正 HRLDAS，結果顯示其 2020 年之 5 cm、25 cm、70 cm 各土層 RMSE 相較於未引用灌溉資料時分別下降約 25%、29%與 13%，顯示出未來 HRLDAS 在灌溉管理方面之進展和應用潛力。

Zhong et al. (2020)使用 Rapid-Refresh Multiscale Analysis and Prediction System-Short Term (RMAPS-ST)探討土壤含水量初始化精確度對中國北方冬季近地表 2 公尺氣溫預測之影響。RMAPS-ST 為基於 WRF 的區域型數值天氣預報系統，以 3 km 解析度運行。其研究使用與其模式相同解析度之 HRLDAS 土壤含水量資料替代模式原始使用之歐洲中期天氣預報中心(European Centre for Medium-Range Weather Forecasts, ECMWF)提供之 0.25° 解析度資料作為其模式之土壤含水量初始場，其研究發現使用 HRLDAS 提供之土壤含水量初始化能顯著改善區域平均之 2 公尺最高溫和最低溫之預測準確率，其

中 2 公尺最高溫之 Bias 與 RMSE 降低 83%與 27%；2 公尺最低溫之 Bias 與 RMSE 降低 44%與 30%，顯示 HRLDAS 提供之之土壤含水量初始化對於提升 NWP 預測準確性之重要性。

而近年來已有多項研究顯示 LSM 對於各項大氣與近地表參數尤為敏感(Maity et al., 2017; Nayak et al., 2018)，但 LSM 對各大氣驅動參數敏感性尚未得到系統性之分析，因此，為探究各近地表參數對於地表與大氣間交互作用之影響，Nayak et al., (2022)於 2011 至 2013 年在印度特別針對 HRLDAS 進行一系列大氣驅動資料如近地表 2 公尺溫度、比濕度、短波輻射、長波輻射、降雨量與近地表 10 公尺風速等之敏感性分析，此研究亦關注不同氣候區域，包括乾燥(土壤含水量約 $0.1\sim0.2\text{ m}^3/\text{m}^3$)和濕潤(土壤含水量約 $0.2\sim0.3\text{ m}^3/\text{m}^3$)地區之反應，並針對季節變化進行分析，以詳細了解各大氣參數在調控地表能量平衡與水平衡方面之重要性。其研究顯示 HRLDAS 土壤含水量對長波輻射最為敏感，在所有研究區域中，增減 20%長波輻射均會導致約 8%之年均表層土壤含水量變化，而土壤含水量對於風速最不敏感，無論風速如何變化，對於其造成之變化均小於 1%。另一方面，在乾燥地區之土壤含水量與降雨量呈顯著正相關，當降雨量增加 20%時，可使土壤含水量增加約 7%；但在潮濕地區，相同之降雨量增量只會使土壤含水量增加約 3%，顯示乾燥地區之土壤含水量對降雨更為敏感，其研究推測是因潮濕地區之土壤含水量已接近飽和狀態，導致額外之降雨轉化為地表逕流，而不是顯著增加土壤含水量。此外，大部分區域之土壤含水量對各參數之敏感性會隨著季節變化，如 3 至 8 月對降雨和長波輻射之敏感度最高，而對 2 公尺溫度和風速最低；到了 10 至 12 月則轉為對比濕度和長波輻射

最敏感，對風速最不敏感。綜上所述，此研究有效分析了 HRLDAS 在不同參數條件下模擬之結果，並顯示不同季節和氣候型態之土壤含水量對各參數之敏感程度，為未來相關應用提供許多重要之參考依據。

而國內相關研究也有洪于瑀等(2014)評估臺灣 HRLDAS 在土壤溫度和土壤含水量之表現，且為了解不同來源雨量資料對模擬之影響，此研究亦對並對其使用之大氣驅動降雨量資料如 Climate Prediction Center Morphing Method (CMORPH)與 Quantitative Precipitation Estimation and Segregation Using Multiple Sensor (QPESUMS)進行敏感性分析。透過將 HRLDAS 與 NCEP Global Forecast System (GFS)、中央氣象署之未經土地資料同化之 WRF 模式與地表測站等多個土壤含水量資料相互比較，首先對於模式準確度方面，研究透過與測站實際觀測資料比較後顯示，HRLDAS 之土壤溫度與測站資料相當接近，由此可知其土壤分析場之穩定。而對於其土壤含水量分析場之定性分析和雨量資料之敏感性，透過與 NCEP GFS 相比，發現用 QPESUMS 降雨資料之 HRLDAS 土壤含水量變化與觀測雨量更相關，且由於其時間解析度更高，因此也可觀察到更細緻之時序變化；相較於依賴模式預報雨量之 WRF 也是如此，也是 HRLDAS 表現出與觀測雨量更佳之相關性，其中使用 CMORPH 雨量要較使用 QPESUMS 略為遜色。而對於雨量資料之敏感性分析，透過將 QPESUMS 取代 CMORPH 資料，發現使用 WRF 模式預報誤差對 HRLDAS 之影響極小，而使用 QPESUMS 則對土壤含水量分析產生顯著影響，另一方面，以臺灣地區之資料品質與解析度而言，QPESUMS 均要比 CMORPH 更佳，因此結論建議將

QPESUMS 作為臺灣 HRLDAS 之驅動資料。綜上所述，此研究為臺灣高解析度土壤含水量模擬奠定了良好基礎。

第四節 多源土壤含水量資料融合應用方法

正如前文所述，各衛星與模式等來源之土壤含水量產品在時空解析度、準確性與完整性均各有優劣，為取得在各方面綜合表現更佳之土壤含水量資料，本研究欲融合多種土壤含水量產品，擷取各產品之優點，針對臺灣地區產製出綜合化之土壤含水量產品，而關於此方面之研究，目前已有許多相關文獻對 DL、統計學習方法應用於多源資料融合進行了探討和分析，因此本章節將回顧前人對多源土壤含水量產品融合之案例。如 Xie et al. (2022)彙整了 2011 至 2018 年間全球之 SMOS、FenYun-3B (FY3-B)、Advanced Scatterometer (ASCAT)、SMAP 與 CCI 等眾多衛星產品，透過 TC 分析各產品之隨機誤差變異數，並按照此隨機誤差變異數使用 The linear weight fusion (LWF)方法進行加權融合，產製出全球範圍之日尺度土壤含水量產品(Global daily-scale soil moisture fusion dataset, GDSMFD)，並將融合前後產品與國際土壤含水量網路(International Soil Moisture Network, ISMN)於世界各地之地表測站資料進行評估，結果顯示，融合後產品在保持與測站資料良好相關性(約 0.6)之同時，在平均絕對誤差(Mean Absolute Error, MAE)、RMSE、Bias 等指標之平均值分別相較於原始單一產品，最多也降低了 17%、17%與 89%。另一方面，在平均每日全球資料覆蓋率(Global Coverage Fraction, GCF)方面，GDSMFD 也可提升約 1.1 至 3.2 倍不等。研究結果顯示，TC 方法對於多源資料融合不僅能有效降低誤差，提升產品的準確性，並

且採用多個衛星產品後，也顯著增加了資料的覆蓋範圍，使得所融合產品之可應用性更為廣泛。

此外對於融合不同衛星產品以提升資料品質之相關研究，也有 Cui et al. (2020)以中國青藏高原之 Naqu 與 Maqu 為研究區域，提出兩階段式之資料融合框架，以提升 Essential Climate Variable Soil Moisture dataset(ECV SM)資料品質，此框架首先透過將 ECV SM 與 Feng-Yun-3B(FY-3B)等之土壤含水量資料與 Moderate-resolution Imaging Spectroradiometer (MODIS)之各項輔助環境因子如 Normalized Difference Vegetation Index (NDVI)、Land surface temperature (LST)與 Digital Elevation Model (DEM)等一同放入 General Regression Neural Network (GRNN)深度學習模型進行擬合，以提升 ECV SM 與 FY-3B 資料之時間覆蓋率與準確度，接著再將兩產品進行等權重融合，產製出一品質提升後之 ECV SM 土壤含水量產品。經過分析顯示，提升後之 ECV SM 於研究區域之時間覆蓋率有顯著提升，從 30.84%提升至 78.12%，與此同時透過各產品與當地 2 種測站網路之平均評估結果，也可發現品質提升後之 ECV SM 在 Naqu 與 Maqu 地區，相關係數分別提升了 6%和 49%，顯示融合後產品對於掌握土壤含水量於時間上之變化趨勢更佳，且 unbiased RMSE (ubRMSE)也有所下降，說明融合不同產品對於準確率方面也可有所提升。以上結果顯示透過整合不同衛星資料與其相關環境因子，可以顯著增強土壤含水量資料之整體品質與應用價值。

而對於衛星與模式等不同資料類型之土壤含水量融合研究，也有 Ming et al. (2022)以中國雲南省為研究區域，對 GLDAS-Noah、ERA5-Land 等模式資料與 SMAP 衛星資料，透過相同之 TC 方法進

行融合，並也以測站之觀測資料進行驗證，與測站評估結果顯示，融合後產品展現出與測站最高之相關性(約 0.84)與最低之無偏均方根誤差(ubRMSE) ($0.039 \text{ m}^3/\text{m}^3$)，而 ERA5-Land, GLDAS, SMAP 與融合後產品等與測站之 Bias 中位數分別為-0.086、-0.014、0.038 及-0.017 m^3/m^3 ，由以上資料可得知，融合後產品之 Bias 雖略遜於 GLDAS，但也顯示基於 TC 方法產製之融合產品未必會展現出最低之 Bias，其研究推測可能是由於資料來源其中之一(ERA5-Land)的 Bias 相對較大，使融合後產品受到一定程度之限制，但總體而言，基於 TC 方法之融合後產品依舊為綜合表現最佳。

第五節 深度學習於土壤含水量之降尺度應用

基於衛星之土壤含水量產品如 CCI 與 SMAP 等，都已被研究證實可提供全球範圍之高準確率土壤含水量資料，但礙於其較粗略之空間解析度(約數十公里)，導致其適用性僅限於全球(Global)或區域性(Regional)之相關應用，但對於流域或集水區之中小尺度之山崩、土石流監測、洪患、旱災、農業等相關水文氣象分析所需之數百公尺至數公里之高解析度資料，其應用性必然受到許多限制(Dorigo et al., 2017; Senanayake et al., 2021)。因此為提高衛星產品在此方面之可應用性，許多研究以透過引入相關輔助環境因子，發展出各種基於統計、物理與水文等模型之空間降尺度方法(Sabaghy et al., 2018)，在這其中基於 ML 與 DL 之方法由於具有出色之模型建置靈活性、高準確性，且能夠有效擬合土壤含水量與相關環境因子間複雜之非線性關係，在此方面研究中受到了最多關注，並展現出巨大潛力(Ali et al., 2015)。在世界各地，也已有實際研究案例證實此方法

對於空間降尺度之優異成效，如 Abbaszadeh et al., (2019)針對美國大陸 SMAP 資料解析度不佳之窘境，提出了一種基於隨機森林 (Random Forest, RF)模型之空間降尺度方法，此研究首先根據過往文獻鑑定了包括降雨量、LST、NDVI、土壤性質與地形屬性等多種影響土壤含水量空間變異性之關鍵因子，並利用 2015 年收集之 SMAP 土壤含水量與上述相關環境因子資料輸入至 RF 進行擬合，將 SMAP 資料解析度自 36 km 提升至 1 km。透過與 ISMN 測站資料驗證顯示，降尺度後產品相較原始產品能更精確反映土壤含水量在空間上之細微變化，且在空間解析度顯著提升之同時，也保持了良好之準確性。其與測站之 ubRMSE 表現為 $0.029 \text{ m}^3/\text{m}^3$ ，已滿足 SMAP 任務官方對精度之要求($0.04 \text{ m}^3/\text{m}^3$)，此結果不僅大幅增強了資料之應用性。也凸顯了機器學習方法在空間降尺度方面之優異成效。

而近年來隨著人工智慧(Artificial Intelligence, AI)演算法進步，DL 在探索目標資料與多個特徵間更深層之非線性關係之成效已被證明優於如 RF、支援向量機(Support Vector Machine, SVM)等較淺層網路架構之 ML 模型(Zhao et al., 2022)，目前也有許多將 DL 方法應用於土壤含水量之空間降尺度，如 Xu et al. (2022)同樣為提高 SMAP 產品之空間解析度，以美國大陸為研究區域，使用結合 Generalized Linear Model (GLM)與 Deep Neural Network (DNN)之 Wide & Deep Learning (WDL)模型用於 SMAP 之空間降尺度，此研究同樣發揮了 DL 分析大資料之強大優勢，篩選了從 2015 年到 2017 年間眾多被廣泛認為與土壤含水量具相關性之特徵因子，如降雨量、LST、表面反射率、NDVI、土壤性質與地形屬性，作為 WDL 模型之輸入，

而除了上述常用之相關因子外，此研究亦探討了將土地利用與氣候類型作為相關因子引入，是否能進一步提升深度學習在預測土壤含水量精度上之潛力。在模型預測精度比較結果顯示，引入土地利用與氣候類型可提升模型之預測精度約 10%，顯示這兩個因子對於土壤含水量之空間分布有顯著影響。此外這兩個因子在模型模擬土壤含水量變化時提供了更多有效資訊，有助於模型更精確地掌握土壤含水量動態變化；而透過與全美 ISMN 共 211 個測站資料驗證之結果顯示，基於 WDL 方法產製之降尺度後產品具有良好之準確率，其與測站之平均 ubRMSE 為 $0.041 \text{ m}^3/\text{m}^3$ ，同樣滿足 SMAP 任務對於精度之要求，此外在土壤含水量空間變化模式分析結果也可看出降尺度後產品不僅保留了原始產品整體變化之趨勢，還提供了更細緻且可用之土壤含水量資料。

儘管已有許多研究應用 ML 或 DL 方法之土壤含水量之空間降尺度，如 RF、SVM 與 DNN 等，但這些方法本質上都是基於分析單一網格自變數與應變數間關係，並未充分考慮網格間之空間關聯性，這點在現有降尺度方法中較少被討論到，對於土壤含水量此種在變化上具高度空間相關性之物理變量，進一步考慮鄰近網格間之關聯可能有助於對於提升模型預測之準確性。而 CNN 有別於傳統 DL 模型，其透過特有之卷積層結構可有效擷取空間上之局部特徵，使其特別擅長分析具有明顯空間結構具相關性之資料，因此 Xu et al. (2021) 為探討 CNN 在土壤含水量空間降尺度之應用潛力，於 2018 年將美國奧克拉荷馬州(Oklahoma)之 SMAP 之 9 km 土壤含水量與 MODIS 之反射率和 LST 作為輔助因子使用 CNN 進行空間降尺度。為詳細探討 CNN 之性能，此研究產製了解析度分別為 3 km 與

1 km 之降尺度產品，並將 CNN 之結果與 RF、SVM 比較。透過與當地 108 個地表測站之詳細評估，3 km 降尺度產品與測站平均之 CC、RMSE 及 ubRMSE 等指標表現雖說均略微降低，但依舊可保持與原始 SMAP 產品相當之水準；而當解析度提升至 1 km 時，與測站資料之各項指標下降幅度則較為明顯，其中 CC、RMSE 及 ubRMSE 分別較原始 9 km 產品下降了 1.88%、0.05% 及 0.23%，但相較於 RF 與 SVM，各項指標仍為 CNN 表現最佳。以上結果顯示考慮到空間變化之 CNN 在空間降尺度表現上優於傳統 ML 模型；另一方面，隨著資料解析度提升同時，模型需要處理空間上更為複雜細部結構，導致誤差也隨之增加。但就整體而言，CNN 之表現仍然表明其在空間降尺度應用中之潛力。且也突顯其相對 ML 方法在處理此類空間資料時之優勢。

除空間上之相依性，掌握土壤含水量在時間上之趨勢同樣重要，這是因為土壤含水量變化不僅在空間上具有相關性，其在時間上之動態也與相關環境因素高度相關，而在眾多 DL 方法中，LSTM 由於其在處理時間序列資料方面，具有能夠擷取資料長期依賴性和記憶過去長期資訊之能力，已被廣泛應用於相關之水文分析，如 Ming et al. (2022) 便結合了 TC 方法和 LSTM，以 TC 方法融合 SMAP、GLDAS-Noah 及 ERA5-Land 等土壤含水量產品，並透過 LSTM 將以上土壤含水量資料與 NDVI、LST、地表反射率、高程及土壤性質等多種環境因子擬合，進行空間降尺度，使各產品之空間解析度自 36 km 提升至 1 km，而透過與測站資料比較之中位數可發現，所有降尺度後產品之準確率同樣會隨著解析度提升而略微下降，其中各降尺度產品在 CC 下降約 0.005 至 0.116，ubRMSE 則是

增加了約 0.001 至 $0.008 \text{ m}^3/\text{m}^3$ 不等。儘管存在輕微之精度下降，但此研究成果依舊顯示 LSTM 在空間降尺度分析上之可行性。總結而言，基於 LSTM 產製之降尺度產品仍可有效截取土壤含水量在空間上之動態變化，從而提供更詳細之土壤含水量空間資訊。而有別於 CNN 與 LSTM 只能單獨處理資料在空間或時間上之關係，由 Shi et al. (2015) 所開發之 ConvLSTM 則結合了 CNN 與 LSTM，使其可有效分析如降雨、土壤含水量此等在時間與空間上同時具有高度相關性之水文變量。而在土壤含水量相關研究案例中，有 ElSaadani et al. (2021) 為解決衛星觀測間隙所造成資料空缺，使用 ConvLSTM 預測無衛星資料時土壤含水量變化，而為探討 ConvLSTM 在此方面之效能，此研究以美國路易斯安那州(Louisiana)為研究區域，結合 2017 年之 National Water Model (NWM)、High-Resolution Rapid Refresh (HRRR)、Multi-Radar/Multi-Sensor radar (MRMS) 及 National Land Cover Dataset (NLCD) 來源之之土壤含水量、長短波輻射、地表與地下逕流、降雨量及土地利用等資料，並將上述資料輸入模型進行擬合，且同時也將 ConvLSTM 與 CNN 進行比較。透過與 NWM 土壤含水量之評估結果，在所有研究區域之平均值中，ConvLSTM 結果與 NWM 土壤含水量之 CC 達到 0.9，且 RMSE 也表現良好，僅有 2.5%，顯示 ConvLSTM 在預測土壤含水量方面的高度準確性，並且這兩項指標結果都要優於 CNN，說明引入時間特徵分析能力之 ConvLSTM 在土壤含水量預測之效能更為更佳。

第三章 研究區域與資料

第一節 研究區域

本研究以臺灣本島為研究區域，其位於東亞與太平洋的交界處，氣候可由北回歸線南北作為劃分為熱帶季風氣候與副熱帶季風氣候，並且地形高程、坡度變化極大，山地面積約佔全臺面積七成。全島最顯著之地形特徵為從北到南縱貫全島之中央山脈，其高海拔導致臺灣東西兩側氣候差異顯著，複雜的地形與氣候條件使得降雨時空分布極度不均，導致洪水、乾旱好發，進而影響農業灌溉，並且在颱風、豪雨來襲時，山區還易因強降雨引發表層土壤山崩、土石流等災害，而上述現象均與土壤含水量變化息息相關，然現今臺灣此方面資訊仍較不完善，地表測站數量也較為稀缺，且分布不均。因此在此背景下，本研究欲透過多源土壤含水量融合與降尺度，期望提供更準確與高覆蓋率之土壤含水量資料，以利後續進行相關水文研究及應用。

第二節 土壤含水量資料

一、CCI產品

本研究採用 ESA 在其 CCI 計畫於 2022 年推出之全球衛星觀測土壤含水量產品 v07.1 版。CCI 計畫之成立主要是為了解決單一衛星感測器在長期土壤含水量監測方面之不足，特別是無法滿足相關水文氣象研究對於時空連續之土壤含水量資料需求(Dorigo et al., 2017)。為此，ESA CCI 計畫綜合了來自主動(AMI-WS ERS1/2; ASCAT-A; ASCAT-B; ASCAT-C)與被動(SMMR; SSM/I; TMI;

AMSR-E; WindSat; SMOS; FY-3B; FY-3C; FY-3D; AMSR2; GPM; SMAP)感測器之衛星土壤含水量資料。透過將上述資料進行偏差校正和資料融合產製出綜合主動與被動衛星之長期土壤含水量觀測資料，首先將所有衛星之時空解析度統一成相同之 0.25° 與每日一筆 (0:00 UTC)，對於主動感測器融合階段，ASCAT-B 先以 ASCAT-A & C 為基準進行偏差校正，並將三產品進行融合產製出 ASCAT A/B/C 產品，而 AMI-WS ERS1/2 產品則又以 ASCAT A/B/C 為基準進行偏差校正，校正後之 AMI-WS ERS1/2 與 ASCAT A/B/C 使用 TC 方法再次進行誤差分析與融合，產製涵蓋 1991/8/5 至 2021/12/31 之 Active product。在被動感測器方面，SMMR、SSM/I、TMI、WindSat、SMOS 及 AMSR2 等產品均以 AMSR-E 為基準進行校正，而 SMAP、GPM、FY-3B、FY-3C、FY-3D 等產品則是以校正後之 AMSR2 為基準進行校正，而以上校正後之 SMMR、SSM/I、TMI、WindSat、SMOS、AMSR2、SMAP、GPM、FY-3B、FY-3C 及 FY-3D 等產品使用 TC 方法進行誤差分析，並融合產製涵蓋 1978/11/01 至 2021/12/31 之 Passive product。而 Active 與 Passive product，最後再次使用 TC 方法融合，產製綜合主動與被動感測器優勢、時空覆蓋率更高，且更加準確之 Combined product，其涵蓋期間為 1978/11/01 至 2021/12/31，空間覆蓋率為全球。綜上所述，本研究選取 Combined product 進行數分析，其資料自 2018 至 2021 年在本研究區域之資料涵蓋範圍如圖 3-1 所示。




圖 3-1 CCI 產品於臺灣本島之資料涵蓋範圍

二、SMAP 產品

SMAP 為 NASA 最新發射之衛星，其目的為透過 L 波段 (1.4GHz) 頻率之結合主動雷達與被動輻射計以 9 km 之解析度觀測全球之土壤含水量，以提供天氣與氣候預報模式重要參數值，並可作為洪水與乾旱預警之用途，而 SMAP 已於 2015/3/31 開始提供全球範圍之土壤含水量資料，但由於其主動雷達於 2015/7 發生故障，目

前僅剩被動輻射計繼續以 36 km 解析度進行土壤含水量觀測。

SMAP 按照不同資料處理過程，提供了多種不同等級之產品，分別為 Level 1 (L1):原始 SMAP 儀器觀測資料；Level 2 (L2)為基於掃描 (Swath Based)之衛星反衍地表資料；Level 3 (L3)為每日複合(Daily Composite)之衛星反衍地表資料；Level 4 (L4)為將 SMAP 衛星資料與地表模式同化後產出之更高解析度之資料。本研究所使用之產品為 SMAP 的 L4 土壤含水量資料，產品名稱為「L4 Global 3-hourly 9-km Surface and Root Zone Soil Moisture (SPL4SMGP) V007 版」。

該產品是通過將 SMAP 的 Level 1C 之 36 公里解析度輻射計亮度溫度(L1 Radiometer Brightness Temperature, L1C_TB)資料，透過集成式卡爾曼濾波器(Ensemble Kalman Filter, EnKF)同化到 Catchment LSM (CLSM)陸面模式來產製而成，且此 L1C_TB 資料是每 3 小時為間隔與 CLSM 進行同化。CLSM 之大氣驅動資料來自 global Goddard Earth Observing System (GEOS)之分析資料，而降雨資料則採用每日、0.5°解析度、基於測站校正產製而成之 Climate Prediction Center Unified (CPCU)產品。SPL4SMGP 產品為時空解析度為 3 小時；9 公里之網格化資料，主要提供表層(距地表 0~5 公分)與根區(距地表 0~100 公分)之土壤含水量及其他地表分析場之環境變量資料，其空間覆蓋範圍為全球地表，經度範圍從 180°W 至 180°E，緯度範圍從 85.044°N 至 85.044°S，但不包括內陸水域和永凍區域(Permanently frozen areas)，資料涵蓋期間則為 2015/3/31 至今，資料延遲(Latency)為 7 天。另一方面，由於 SPL4SMGP 資料透過 CLSM 進行資料同化，與傳統衛星資料相比，其不受重訪頻率和雜訊干擾等限制，因此資料能夠完整且無遺漏覆蓋所有地區。本研究主要採用此產品之

表層之土壤含水量進行資料融合與降尺度分析，其資料自 2018 至 2021 年在本研究區域之資料涵蓋範圍如圖 3-2 所示。




圖 3-2 SMAP 產品於臺灣本島之資料涵蓋範圍

三、HRLDAS 產品

HRLDAS 是以 Noah LSM 為核心之土壤資料同化系統。Noah LSM 將土層分為四層，分別為地下 5 公分、25 公分、70 公分與 150 公分。除土壤含水量及溫度之物理擴散模式外，亦也有涵蓋植被模

式，可處理植物葉面攔截水與蒸散作用之過程。而 HRLDAS 模式之預報輸出變量包括地表溫度、每層土壤含水量和土壤溫度、雪深、雪量及冠層含水率(洪于琄等，2014)。HRLDAS 提供之資料範圍為臺灣本島，時空解析度分別為小時；3 km，本研究主要使用地下 5 公分之表層土壤含水量資料。

HRLDAS 所使用之陸面模式、植被覆蓋率、土質資料、網格設定及地表反射率等參數與行政院交通部中央氣象署(Central Weather Administration, CWA)之作業模式 WRF 皆相同，HRLDAS 系統所需之近地表大氣驅動資料包含溫度、濕度、風速、壓力、輻射通量和降雨等，其中地表氣壓、近地表溫度、近地表相對濕度、近地表風、地表長波和短波輻射通量使用 WRF 模式每一預報之 7-12 時之輸出資料，而降雨資料則是使用 QPESUMS 之雷達估計降水產品(洪于琄等，2014)。陸面模式在水平空間上具有高度之異質性，即相鄰網格點位之土地利用型態、地表覆蓋物和土壤質地可能有許多差異，而各種土地利用型態、地表覆蓋物及土壤質地均影響土壤之物理過程和地表-大氣交互作用。HRLDAS 藉由近地表大氣驅動資料，透過土壤模式物理過程，將這些大氣觀測資訊經長時間積分後同化至深層土壤，進而調整土壤溫度與土壤含水量，經一定時間之模式起轉(Spin Up)後，HRLDAS 即可得到與大氣強迫作用平衡之土壤含水量與土壤溫度，此為 HRLDAS 土壤分析場，也可作為模式積分之初始場。執行 HRLDAS 時除需輸入 WRF 模式之 Annual maximum in vegetation fraction (GVFMAX)、Annual minimum in Vegetation fraction (GVFMIN)、Canopy water (CANWAT)及 Vegetation fraction (VEGFRA)等植被資訊(Geogrid data)和初始土壤狀態(Soil Initial

Conditions, Soil IC)即初始之 Soil temperature (STEMP)、Skin temperature (SKINTEMP)及 Soil moisture (SMOIS)等，還需近地表大氣驅動資料，如降水、雪及區域模式大氣資料包含 2 公尺溫度(T2m)和濕度(Q2m)、10 公尺風場(U10m、V10m)、地表氣壓(PSFC)、短波輻射(SWDOWN)及長波輻射(LWDOWN)。經過整合以上資料，即可產生 HRLDAS 輸入場(LDASIN)，再經 Noah 陸面模式進行預報，即可得下一小時之土壤預報場(LDASOUT)(洪于珺等，2014)。

HRLDAS 執行之流程如圖 3-3 所示。模式於 2016 年完成 Spin Up，並於 2017 年上線提供土壤分析場資料，而 HRLDAS 於 2018 年至 2021 年在本研究區域之點位涵蓋範圍如圖 3-4 所示。






圖 3-3 HRLDAS 模式資料之模擬流程(參考並改繪自洪于琚等，2014)




圖 3-4 HRLDAS 產品於臺灣本島之資料涵蓋範圍

四、地表土壤含水量測站資料

除上述土壤含水量產品外，本研究亦根據各產品所採用之資料年限蒐集 2018 至 2021 年無缺漏之行政院農業部農村發展及水土保持署之神木(Shenmu)、南豐(Nanfung)、華山(Huashan)、坪頂(Pingding)、上安(Shangan)、九份二山(Jiufenershan)、來義(Laiyi)、羌黃坑(Qianghuangkeng)；國立中央大學水文與海洋科學研究所李明

旭教授研究團隊於桃園中央大學(NCU)、南投蓮華池(Lienhuachih)及國立中興大學土木工程學系陳榮松教授研究團隊於臺中東勢(Dongshi-1、Dongshi-2)、苗栗卓蘭(Zhuolan)等共 13 測站無缺漏之資料作為成果驗證依據，測站點位分布圖與採用時段分別如圖 3-5 與表 3-1 所示。




圖 3-5 土壤含水量地表測站分布圖

表 3-1 本研究採用測站站點之經緯度與資料採用期間

Gauge	Lon	Lat	Time
Laiyi	120.6761	22.5260	2018/1/1~2021/8/7
Qianghuangkeng	120.5368	23.0720	2018/1/1~2019/5/31
Shenmu	120.8567	23.5279	2019/8/14~2021/12/31
Huashan	120.6078	23.5935	2019/1/1~2021/12/31
Shangan	120.8765	23.7253	2019/1/1~2021/12/31
Pingding	120.6391	23.7539	2019/1/1~2021/12/31
Lienhuachih	120.8940	23.9310	2018/1/1~2021/12/31
Jiufenershan	120.8540	23.9498	2019/1/1~2020/5/10
Nanfung	121.0886	24.0174	2019/1/1~2021/12/31
Dongshi-1	120.8334	24.2321	2019/12/20~2020/12/31
Dongshi-2	120.8336	24.2265	2019/3/12~2021/10/11
Zhuolan	120.8247	24.3127	2020/5/26~2021/12/31
NCU	121.1850	24.9680	2018/1/1~2021/12/31

第三節 土壤含水量相關環境因子資料

一、地形屬性資料

本研究所使用之地形屬性資料包括高程(Elevation)與坡度(Slope)，其中 DEM 為內政部國土測繪中心(National Land Surveying and Mapping Center, NLSC)公布之 20 公尺解析度資料，臺灣本島高程分布為-33 至 3947 公尺，如圖 3-6(a)所示；而坡度是透過國土測

繪中心之 DEM 資料利用 ArcGIS 之 Slope 工具計算得出，臺灣本島坡度分布約為 0 至 85%，如圖 3-6(b)所示。

此外，WRF-Hydro 模式建置所需之 DEM 資料則使用 Shuttle Radar Topography Mission (SRTM)衛星量測之 Hydrological data and maps based on SHuttle Elevation Derivatives at multiple Scales (HydroSHEDS)資料，其解析度為 3 弧秒(約 90 公尺)，高程精度為 1 公尺。




圖 3-6 地形屬性圖(a)高程；(b)坡度

二、土地利用資料

本研究之土地利用資料是採用 NLSC 公布之 2015 年土地利用資料。此資料產製方式是透過使用高解析遙測影像，再配合地籍圖與臺灣通用電子地圖等參考圖資及部分外業調查資料，所合理規劃得出之土地利用分類，而 NLSC 將臺灣本島之土地利用型態分為十類，包括都市和建地、旱田、水田、草地、荒地、墓地、林地、水

體、濕地及裸露地十種類型，如圖 3-7 所示；而各土地利用類型對應之曼寧粗糙係數則如表 3-2 所示。




圖 3-7 臺灣本島於 2015 年之土地利用分類圖

表 3-2 臺灣本島土地利用概況及其對應曼寧粗糙係數

土地利用分類	曼寧粗糙係數
建地(Urban)	0.15
旱田(Dryland)	0.035
水田(Irrigated Cropland)	0.035
草地(Grassland)	0.035
荒地(Shrubland)	0.1
墓地(Mixed Shrubland)	0.03
林地(Mixed Forest)	0.16
水體(Water Bodies)	0.015
濕地(Wetland)	0.07
裸露地(Barren)	0.025

三、Land GIS 資料

不同之土壤性質會均會影響水分之滲透性，進一步改變土壤含水量之空間分布(Xu et al., 2022)，因此本研究採用與土壤含水量具相關性之土壤性質資料，包括黏土含量(Clay content)、土壤酸鹼值(Soil pH)、土壤有機碳含量(Soil organic content)，以上資料均來自 Land GIS 系統(<https://openeohub.org/contribute-training-data-openlandmap>)，此系統資料是透過彙整 1950 至 2017 年全球之地表土壤觀測資料並結合多種 ML 演算法所產製得出，並分為 0、10、30、60、100 及 200 cm 六層，本研究選取 10 cm 之土層資料，其解析度為 250 公尺，臺灣本島之黏土含量、土壤酸鹼值及土壤有機碳含量如圖 3-8 所示。




圖 3-8 土壤性質圖：(a)黏土含量；(b)土壤酸鹼值；(c)有機碳含量

四、MODIS表面反射率資料

MODIS 之各表面反射率與其衍生之地表植生指標產品由於被證實與土壤含水量具高度相關性，因此已被廣泛應用於土壤含水量降尺度之相關研究(Wei et al., 2019; Xu et al., 2022)。本研究根據文獻彙整了 MODIS 之地表反射率產品(MOD09GA)，此產品同樣可在可在 NASA 地球觀測資料搜索平台(<https://search.earthdata.nasa.gov/search>)下載取得，此產品提供日尺度之從可見光至近紅外外光波段之地表反射率資料，解析度為 500 公尺，並分為 Band1~Band7 等七個波段，其對應之波長如表 3-3 所示，本研究主要選用 Band4 與 Band7 資料，其分別對應綠光與短波紅外光(Shortwave Infrared, SWIR)。

表 3-3 MOD09GA 產品之各波段與其所對應之波長表

Band	Wavelength
Band1	620-670 nm
Band2	841-876 nm
Band3	459-479 nm
Band4	545-565 nm
Band5	1230-1250 nm
Band6	1628-1652 nm
Band7	2105-2155 nm

除上述 Band4 與 Band7 資料外，本研究亦根據此產品之 Band1 與 Band2 資料計算出 NDVI，Band1 與 Band2 分別對應紅光(Red)與近紅外光(near-infrared, NIR)，計算方程式如式 3-1 所示。

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \quad (3-1)$$

式中 R_{NIR} 與 R_{RED} 分別代表紅光與近紅外光反射率。

五、HRLDAS 模式輸出資料

本研究除使用氣象署 HRLDAS 模式之土壤含水量資料外，亦也有使用其模式輸出之土壤溫度(ST)與地表溫度(LST)，而 ST 與 LST 資料之產製流程、時空解析度、資料涵蓋範圍等也均與第 3.2.3 節之敘述相同。

六、Taiwan Climate Change Projection Information and Adaptation Knowledge Platform (TCCIP) 資料

(一) TCCIP 降雨資料

本研究所使用之降雨(Precipitation)資料為國科會政策推動之 TCCIP 之網格化降雨日資料，透過收集彙整來自交通部中央氣象署、行政院環保署、經濟部水利署、林業試驗所及行政院農業委員會農試所等多個單位之地表測站資料，並將基於測站之單點資料進行網格化為網格資料，以此建立長期與高解析度之歷史網格化觀測雨量資料。而根據其資料生產履歷，此降雨資料產製流程大致可分為五步驟，首先將所彙整之全臺各單位測站資料轉換成隱藏高斯 (Latent Gaussian variable, LGV) 變數，接著取得每月份最佳化統計模型與參數，再來下一步驟則是將 LGV 轉換之測站降雨資料進行資料補遺，再用 Empirical Orthogonal Function, (EOF) 將資料拆分為時間和空間，並分析所得到之特徵向量，在保留 99.5% 的變異量後，利用 Natural Neighbor Interpolation (NNI) 對其與 EOF 裡減掉之平均值進行網格化，下一步則是使用 EOF 分析得到之主分量再相乘回其所相對應之相應模組(mode)之網格化特徵向量值累計加總，並再加上每個網格之平均值，取得標準化之網格化降雨資料，並將後者再代回首步驟所分析得出之每月份最佳化統計參數、模型，進而反演得出降雨量估計數值，即可在最終產出解析度為 0.01° 之日降雨資料，本研究使用之降雨資料為 0.01° 解析度之網格化資料。

而在獲取了此高解析度之降雨資料後，本研究下一步目的為使用此降雨資料計算前期降水指數(Antecedent Precipitation Index, API)，API 透過將特定區域過去一段時間的降雨量進行加權和，以量化此段時間之降雨對當前土壤含水量變化之影響(Ali et al., 2010)，且目前此方面之相關研究也有 Schoener & Stone (2020) 在美國新墨西哥州中部結合雷達降雨產品與 API 推估網格化土壤含水量資料，且

結果也證實 API 與土壤含水量具有一定程度之相關性。而 API 計算方程式如式 3-2 所示。

$$API = \sum_{t=-1}^{-i} P_t K^{-t} \quad (3-2)$$

式中 i 為所考慮之先前天數，通常設為 10 至 60 天(Zhao et al., 2019)； K 為衰減常數(decay constant)，通常設為 0.80~0.98(Li et al., 2021)； P_t 為第 t 天之降雨量。而另一方面，由於此基於降雨資料計算得出之 API 可能不完全符合常態分佈，可能會影響後續深度學習模型訓練速度與成效，因此本研究進一步將 API 進行 Yeo-Johnson power 轉換，使其資料分布更加接近常態分佈(Zhang & Ye, 2021)，Yeo-Johnson power 轉換方程式如式 3-3 所示。

$$API^{(\lambda)} = \begin{cases} \frac{[(API_i + 1)^\lambda - 1]}{\lambda}, & \text{if } \lambda \neq 0 \\ \ln(API_i + 1), & \text{if } \lambda = 0 \end{cases} \quad (3-3)$$

式中 λ 為轉換參數，是透過 Maximum likelihood method 分析得出； API_i 為第 i 天之 API； $API^{(\lambda)}$ 為經過 Yeo-Johnson power 轉換後之 API。

(二)TCCIP 平均溫資料

本研究所採用之每日近地表 2 公尺平均溫(Daily average temperature, temp)資料同樣來自 TCCIP 根據測站之點資料所面化而成之網格化資料，而其資料產製流程根據其資料生產履歷，首先在測站溫度之資料面化成網格資料前，需要對資料進行許多預處理步驟，包含測站資料之篩選與查核，確認測站三組最低溫、最高溫及平均溫等有記錄到資料，才可以作為可參考之測站，以估計每網格

之溫度資料，若有缺少上述任何一種資料即當作不可使用，且也不額外對測站資料進行資料補遺，而另一方面，因每個目標網格點與所參考之測站間有高程差，需要考慮此高程差導致之溫度差異，因此此在資料進行網格化前還須將測站溫度修正。依據所有測站在所有日期，取每日包含前後各 15 日，共 31 日之溫度資料的氣候平均值，利用溫度氣候值與測站高程進行迴歸分析，計算每日之溫度遞減率經驗值，即上述三組不同之溫度資料，在所有日期中，皆會有其所對應之溫度遞減率經驗值，且此方法適用於全部測站。最後依據每網格點與其對應之測站之高程差，下一步為資料進行網格化：以資料補遺之方法作為基礎，將網格點當作缺值，並使用該網格點附近之參考測站(權重最大之五測站)之溫度資料，推估出該網格上的溫度值，並代入溫度遞減率公式進行測站溫度修正，最後產製輸出為 0.01° 解析度的網格日資料，本研究即使用 0.01° 解析度之平均溫度資料。



七、Taiwan ReAnalysis Downscaling data (TReAD) 資料

TReAD 資料為 TCCIP 使用 WRF 模式，針對臺灣地區，將 ECMWF 產製之 ERA5 再分析資料進行動力降尺度，所產製之一組長時、高解析度之歷史氣候資料。其中資料來源包括 ERA5、美國地質調查局(U.S. Geological Survey)與美國國家地理空間情報局(National Geospatial-Intelligence Agency)所研發之全球高解析度地形高度資料(global multi-resolution terrain elevation data)及中研院環境變遷研究中心之土地利用資料。而其資料產製流程根據其資料產製流程，TReAD 所模擬之流程會配合 ERA5 資料之間隔，每隔 6 時啟動一組模擬，並且將再分析資料和區域模式之模擬結果利用 blending 方法進行混合，以結合再分析場之大尺度特徵，並保留區域模式所解析出之小尺度成果，最後再將 blending 後的結果作為下次模擬之初始場。另一方面，由於模式在模擬初期未達平衡狀態，使模擬初期的結果受到雜訊之干擾，進而導致結果不佳，因此為減緩模擬初期之雜訊與未達平衡之問題，TReAD 會將每次模擬之前 6 時作為 Spin up 時間，即只採第 7 至 12 時之輸出結果，再將每次模擬之 7 至 12 時串接成時間上連續之資料，而 TReAD 之輸出資料有 2 km 與 0.05° 之日射量、降雨量、最高溫、最低溫、平均溫、平均風速、地表氣壓及相對溼度，本研究使用其中 2 km 之日射量(SR)。

八、土壤質地分類資料

除上述 Land GIS 之黏土含量、土壤酸鹼值及土壤有機碳含量資料外，本研究亦有使用 WRF 模式中之土壤質地資料，而 WRF 模式預設之土壤質地主要是由 U.S. Department of Agriculture (USDA)針對

北美開發之 30-s State Soil Geographic (STATSGO) 資料庫，而在美國以外地區，土壤質地資料則是使用聯合國糧食及農業組織(Food and Agriculture Organization of the United Nation, FAO)之 16 類土壤質地資料，此種土壤分類方法或許無法詳細反映美國以外地區之土壤型態(Gao et al., 2008)。因此本研究參考 Lin and Cheng (2016)針對臺灣地區更新土壤種類之資料，其更新後資料是由行政院農業委員會根據 USDA Soil Survey Geographic Database (SSURGO)之標準進行現地調查所彙整而成，資料解析度為 0.00833° ，更新後之臺灣土壤分類如圖 3-9 所示，根據 FAO 之分類資料，臺灣主要之土壤類型為 clay loam、sandy clay loam 及 loamy and clay，並且不同土壤之分佈過於均勻，無法合理反映臺灣真實之土壤狀態、土壤物理和水力性質(Lin and Cheng, 2016)，而經過更新，本研究將臺灣土壤分為 Sand、Loamy sand、Sandy loam、Silt loam、Loam、Sandy clay loam、Silty clay loam 及 Silty clay 等八類，而本研究主要使用更新後之土壤種類之 K_s 資料，而各不同土壤與其對應之 K_s 如表 3-4 所示。




圖 3-9 更新後之臺灣土壤分類圖

表 3-4 臺灣地區土壤種類與其對應之 K_s (Lin and Cheng, 2016)

Data	K_s (10^{-6})
Sand	22.6
Loamy sand	18.4
Sandy loam	8.45
Silt loam	2.03
Loam	3.79
Sandy clay loam	7.71
Silty clay loam	1.46
Silty clay	1.25

第四節 最新取得資料

一、水利數值地形模型(Hydraulic Digital Elevation Model, HyDEM)

HyDEM 為水利規劃分署自 107 年起與內政部跨政府部會合作所產製，旨在提升二維淹水模式與各種水利相關應用之地文資料品質，透過訂出水利數值地形資料集(Hydrologic Topography Dataset, HTD)的整體概念，並訂定「水利數值地形資料測製及檢核技術指引」，作為後續產製適合淹水模式之地文資料之依據。水利數值地形資料集包含水利數值地形分類點雲、三維水利圖徵及水利數值地形模型等 3 種成果，其中水利數值地形分類點雲係將內政部空載光達點雲資料針對溝渠兩側立面堤防及寬度小於 1 公尺之防洪牆、胸牆或護欄等人工水利構造物重新分類至地面點；並由分類後之點雲資料數化產製三維水利圖徵，三維水利圖徵包含建物區塊、溢堤線、水域區塊、海陸線、海堤線等 5 種類別；再利用分類後點雲資料與溢堤線、海陸線、海堤線內插而得 1 公尺網格之水利數值地形模型，其相關測製流程則如圖 3-10 所示。截至目前為止，本研究所取得之 HyDEM 資料範圍為桃園市及淡水河流域部分，如圖 3-11 所示，而為更精確了解 HyDEM 與 DEM 之間的差異，本研究將兩者高程值進行差值計算，生成如圖 3-12 所示的高程差異圖，結果顯示高程差約介於 0.6 至 3.5 公尺之間，主要集中於淡水河主河道與其周圍。本研究後續將嘗試取得更多區域之 HyDEM 資料，分析其對於土壤含水量模擬(如利用 WRF-Hydro)之影響。



圖 3-10 水利數值地形資料測製流程圖(資料來源：內政部國土測繪中心，<https://www.nlsc.gov.tw/cp.aspx?n=13855>)




圖 3-11 桃園市與淡水河流域範圍之 HyDEM 圖




圖 3-12 桃園市與淡水河流域範圍之 HyDEM 與 DEM 差異圖

二、最新臺中市土地利用資料

除 3.3.2 節所述之 2015 年土地利用資料外，目前本研究亦與 NLSC 申購臺中市最新(2023 年)之土地利用資料，未來本研究預計持續取得全臺更多區域最新之土地利用資料，並透過土地利用變化來更好探討不同土地利用形式對於土壤含水量之潛在影響。而此資料產製方式同樣是透過使用高解析遙測影像，再配合地籍圖與臺灣通用電子地圖等參考圖資及部分外業調查資料，所合理規劃得出之土地利用分類，而因應國土計畫法（104 年 12 月完成立法）明定國土利用現況調查工作係屬國土計畫主管機關主管事項，且該法第 19 條明定國土利用現況調查辦法，由中央主管機關定之，爰內政部國土管理署(以下簡稱國土署)據以研訂「國土利用現況調查辦法」，同時檢討原有「土地利用分類系統表」，納入辦法並更名為「土地利用分級分類系統表（陸域部分）」，該辦法業經內政部 108 年 2 月 21 日通過，並由國土測繪中心據以持續辦理國土利用現況調查成果更新維護作業，其中第一級共分為 9 大類，第二級就第一級之劃分再細分 48 類、第三級則就第二級之架構再分為水田等 93 類。本研究取得之 2015 與 2023 年臺中市土地利用分類(第一級)分別如圖 3-13 與圖 3-14 所示。




圖 3-13 臺中市 2015 土地利用分類(第一級)




圖 3-14 臺中市 2023 土地利用分類(第一級)



第四章 研究方法

第一節 計畫研究架構說明

本研究本期主要著重於多源土壤含水量產品之融合與降尺度分析，將於本章第二至七節介紹多源土壤含水量產品之融合與降尺度分析之研究方法，以及用以進行結果驗證之統計評估指標。另外為後續利用 WRF-Hydro 模式進行土壤含水量模擬與資料產製，第八節介紹 WRF-Hydro 模式之參數調校與土壤含水量模擬流程。

第二節 多源土壤含水量融合與降尺度研究流程說明

本研究結合 TC 方法與 ConvLSTM 模型架構以進行多源資料融合與降尺度，研究流程如圖 4-1 所示。此架構主要有以下步驟，首先透過 TC 方法分析，獲得 CCI、SMAP 及 HRLDAS 產品隨機誤差變異數。再利用最小平方法確定各產品融合時之最佳權重，並根據此權重進行加權融合，產出融合後產品(Merged SM)。接著將此 Merged SM 與如前述所示之輔助環境因子輸入 ConvLSTM 進行訓練，待模型訓練完畢，即可將精細解析度(3 km)的環境因子資料輸入模型，預測相同空間尺度之土壤含水量(Merged and Downscaled SM, M&D SM)，並將此產品與測站資料進行結果驗證，以達到資料融合與空間降尺度之目的，接續利用 HRLDAS 之小時 SM 產品計算出資料在小時尺度之相依性，再透過統計方法對 M&D SM 進行時間降尺度，以產製出臺灣本島之 3 km 與 hourly 之高解析度土壤含水量產品。




圖 4-1 本計畫之多源土壤含水量融合與時空降尺度研究流程圖

第三節 資料前處理

一、網格重採樣

由於各產品之時空解析度不盡相同，因此在進行各項分析如融合與空間降尺度前，須將所有產品之時空解析度統一重採樣成相同尺度，而為對應各原始產品中最粗略解析度之 CCI 產品(0.25° ；日)，本研究將其餘產品之時間解析度統一平均成日資料，並按照 CCI 產品之網格解析度便後續進行 TC 資料融合。此外，由於 CCI 產品網格並未完全涵蓋臺灣本島(如圖 3-1)，本研究根據其網格經緯度間距向外擴展，直至涵蓋此區域(如圖 4-2(a))，因此所有產品均按此區域之網格分布進行空間重採樣；且各環境因子除統一重採樣至上述解析度外，也另外重採樣至本研究降尺度目標之 3 km，而各 3 km 產品重採樣後所範圍如圖 4-2(b)所示。而在空間重採樣方法中，除降雨資料採用線性插值法外，其餘所有資料均使用最鄰近插值法進行空間重採樣(Xu et al., 2022)。






圖 4-2 各產品重採樣後網格區域 (a) 0.25° ; (b) 3 km

二、偏差校正

由於各土壤含水量產品各自之觀測、演算方式不同，會存在一定程度之系統偏差，所以在進行資料融合前需消除各產品之偏差，而基於 Cumulative distribution function matching (CDF matching) 之偏差校正方法已被廣泛應用於消除各種土壤含水量資料之偏差 (Drusch et al., 2005; Gao et al., 2019; Xu et al., 2022)，而本研究使用已廣泛應用於統計與氣候學之基於「Quantile Mapping」之 CDF matching 方法，其概念在於通過匹配目標資料與待校正資料的 CDF，以達成偏差校正。此方法首先根據目標資料與待校正資料各自之 CDF 分別計算所有資料所對應之分位數。接著將待校正資料在其 CDF 中的分位數，映射到目標資料的 CDF 上，以此對待校正資料進行轉換，使其資料分布與目標資料的一致，從而達到校正偏差之目的，示意圖如圖 4-3 所示。




圖 4-3 土壤含水量產品之 CDF matching 偏差校正示意圖

而為更進一步掌握土壤含水量變化之趨勢，在對各產品進行上述偏差校正前，本研究以 HRLDAS 資料為基準，使用隨機森林模型對 CCI 和 SMAP 等土壤含水量產品進行迴歸，以擬合 CCI 和 SMAP 的資料變化趨勢。此原因在於 HRLDAS 之大氣驅動資料來自臺灣本地的實際觀測數據，使其可更準確反映臺灣之地表-大氣交互作用趨勢。且其資料對於土壤含水量在時間上之趨勢變化掌握性也已在洪于琚等(2014)之研究中得到驗證。

第四節 TC 資料融合方法

TC 方法旨在無法得知真值的情況下，仍可透過分析三個觀測產品(在本研究即為 CCI、SMAP 及 HRLDAS 等產品)推估各自相對於未知真值之隨機誤差變異數(Random Error Variance, REV)。此方法的核心在於即使真值資料未知，但通過分析來自三產品間之統計關係(如變異數、共變異數等)依然能有效揭示各產品之誤差特性(即 REV)。另一方面，在分析得出各產品之 REV 後，即可進一步結合最佳化方法，以最小化 REV 為目標，對三產品進行加權融合，而為了求取在此目標下，產品於融合之權重配置，本研究參考過往文獻並應用了在此方面研究已有被成功實踐之最小平方法(Least squares method; Ming et al., 2022; Xie et al., 2022)，以最小化 REV 為目標，計算得出在此加權融合過程中，各產品各自所占之最佳權重。通過此種加權融合方法，即可產製一 REV 最小化之融合後產品。本節將詳細敘述 TC 方法與基於最小平方法之權重分析原理與方程式。

一、隨機誤差分析

TC 方法的核心假設包括：各產品相對於未知真值之誤差均為線性、誤差的平均值為零，及各產品的誤差之間相互獨立，基於上述前提，即可根據各產品之變異數(Variance)與產品間之共變異數(Covariance)推求各產品與未知真值之 REV，首先其誤差方程式可以由式 4-1 表示。

$$\begin{cases} SM_x = \alpha_x + \beta_x T + \varepsilon_x \\ SM_y = \alpha_y + \beta_y T + \varepsilon_y \\ SM_z = \alpha_z + \beta_z T + \varepsilon_z \end{cases} \quad (4-1)$$

式中 $SM_i (i \in x, y, z)$ 分別代表 CCI、SMAP 與 HRLDAS 等土壤含水量產品； T 為未知真值； α 與 β 分別為產品與真值之系統偏差與比例偏差； ε 為產品與真值之隨機誤差(Random error)。且由於 TC 方法假設各產品之誤差平均值為零，且彼此獨立，因此產品間之 Covariance 可表示如式 4-2 所示。

$$C_{ij} = COV (SM_i, SM_j) = \begin{cases} \beta_i \beta_j \sigma_T^2, & \text{for } i \neq j \\ \beta_i^2 \sigma_T^2 + \sigma_{\varepsilon_i}^2, & \text{for } i = j \end{cases} \quad (4-2)$$

式中 $i, j \in (x, y, z)$ 分別代表 CCI、SMAP 與 HRLDAS 等土壤含水量產品， $C_{ij} = COV (SM_i, SM_j)$ 表示各產品間之 Covariance，其中當 $i = j$ 時，可得各產品自身之 Variance；當 $i \neq j$ 時，則可得任意兩不同產品之 Covariance， σ_T^2 為真值之變異數， $\sigma_{\varepsilon_i}^2$ 為各產品之 REV，而在此情況下，一共會有 7 個未知數(β_x 、 β_y 、 β_z 、 σ_T 、 $\sigma_{\varepsilon_x}^2$ 、 $\sigma_{\varepsilon_y}^2$ 、 $\sigma_{\varepsilon_z}^2$)，但只有 6 個方程式(C_{xx} 、 C_{yy} 、 C_{zz} 、 C_{xy} 、 C_{xz} 、 C_{yz})，無法求得唯一解，因此為解決此問題，本研究參考 Xie et al. (2022)之做法，透過引入一個新變數 θ ，並令 $\theta = \beta_i \sigma_T$ ，即可將式 4-2 轉化為如 4-3 所示之方程式。

$$C_{ij} = COV (SM_i, SM_j) = \begin{cases} \theta_i \theta_j, & \text{for } i \neq j \\ \theta_i^2 + \sigma_{\varepsilon_i}^2, & \text{for } i = j \end{cases} \quad (4-3)$$

式中 $i, j \in (x, y, z)$ 同樣代表 CCI、SMAP 與 HRLDAS 等土壤含水量產品，此時即可將未知數數量減少至 6 個(θ_x 、 θ_y 、 θ_z 、 $\sigma_{\varepsilon_x}^2$ 、 $\sigma_{\varepsilon_y}^2$ 、 $\sigma_{\varepsilon_z}^2$)。

$\sigma_{\varepsilon_z}^2$)，且對應至六個方程式(C_{xx} 、 C_{yy} 、 C_{zz} 、 C_{xy} 、 C_{xz} 、 C_{yz})，此時即可透過對式 4-3 成對進行解聯立方程式求得各產品之 REV 唯一解，如式 4-4 所示。

$$\begin{aligned}\sigma_{\varepsilon_x}^2 &= C_{xx} - \frac{C_{xz}C_{xy}}{C_{yz}} \\ \sigma_{\varepsilon_y}^2 &= C_{yy} - \frac{C_{xy}C_{yz}}{C_{xz}} \\ \sigma_{\varepsilon_z}^2 &= C_{zz} - \frac{C_{xz}C_{yz}}{C_{xy}}\end{aligned}\quad (4-4)$$

式中 x 、 y 、 z 分別為 CCI、SMAP 及 HRLDAS 產品， C_{xx} 、 C_{yy} 、 C_{zz} 分別為 CCI、SMAP 及 HRLDAS 產品之變異數； $\sigma_{\varepsilon_x}^2$ 、 $\sigma_{\varepsilon_y}^2$ 、 $\sigma_{\varepsilon_z}^2$ 分別為 CCI、SMAP 及 HRLDAS 產品之 REV。

二、最佳權重分析

本研究的目的是根據已獲得的各產品 REV，進一步產製一最小化 REV 之融合後產品。為此，本研究對各產品進行加權融合，過程如式 4-5 所示。

$$SM_{merged} = W_x SM_x + W_y SM_y + W_z SM_z \quad (4-5)$$

式中 SM_{merged} 為融合後產品； SM_x 、 SM_y 、 SM_z 分別為 CCI、SMAP 及 HRLDAS 產品； W_x 、 W_y 、 W_z 分別為 CCI、SMAP 及 HRLDAS 產品之權重，且為確保融合後結果無偏差，各產品權重總和須為 1

(Ming et al., 2022)，式中 SM_{merged} 為融合後產品； x 、 y 、 z 分別為 CCI、SMAP 及 HRLDAS 產品；而為確保融合後產品之

REV(σ_{merged}^2)最小，本研究將 σ_{merged}^2 表示為如式 4-6 所示之方程

式，即 σ_{merged}^2 為各產品 REV 乘上各權重之加權平方和。

$$\sigma_{merged}^2 = W_x^2 \sigma_{\varepsilon_x}^2 + W_y^2 \sigma_{\varepsilon_y}^2 + W_z^2 \sigma_{\varepsilon_z}^2 \quad (4-6)$$

而由於權重總和須為 1，因此式 4-6 可以轉化為如式 4-7 所示之方程式。

$$\sigma_{merged}^2 = W_x^2 \sigma_{\varepsilon_x}^2 + (1 - W_x - W_z)^2 \sigma_{\varepsilon_y}^2 + W_z^2 \sigma_{\varepsilon_z}^2 \quad (4-7)$$

由於本研究目標為最小化 σ_{merged}^2 ，因此本研究令式 4-6 對 W_x 和 W_z 偏微分為零(即 $\frac{\partial \sigma_{merged}^2}{\partial W_x} = 0$, $\frac{\partial \sigma_{merged}^2}{\partial W_z} = 0$)，即可求取在此目標下，如式 4-8 至 4-10 所示之各產品最佳權重配置。

$$W_x = \frac{\sigma_{\varepsilon_y}^2 + \sigma_{\varepsilon_z}^2}{\sigma_{\varepsilon_x}^2 \sigma_{\varepsilon_y}^2 + \sigma_{\varepsilon_x}^2 \sigma_{\varepsilon_z}^2 + \sigma_{\varepsilon_y}^2 \sigma_{\varepsilon_z}^2} \quad (4-8)$$

$$W_y = \frac{\sigma_{\varepsilon_x}^2 + \sigma_{\varepsilon_z}^2}{\sigma_{\varepsilon_x}^2 \sigma_{\varepsilon_y}^2 + \sigma_{\varepsilon_x}^2 \sigma_{\varepsilon_z}^2 + \sigma_{\varepsilon_y}^2 \sigma_{\varepsilon_z}^2} \quad (4-9)$$

$$W_z = \frac{\sigma_{\varepsilon_x}^2 + \sigma_{\varepsilon_y}^2}{\sigma_{\varepsilon_x}^2 \sigma_{\varepsilon_y}^2 + \sigma_{\varepsilon_x}^2 \sigma_{\varepsilon_z}^2 + \sigma_{\varepsilon_y}^2 \sigma_{\varepsilon_z}^2} \quad (4-10)$$

式中 x 、 y 、 z 分別為 CCI、SMAP 及 HRLDAS 產品； W_x 、 W_y 、 W_z 分別為 CCI、SMAP 及 HRLDAS 產品之權重； $\sigma_{\varepsilon_x}^2$ 、 $\sigma_{\varepsilon_y}^2$ 、 $\sigma_{\varepsilon_z}^2$ 為各產品之 REV。

第五節 基於深度學習之空間降尺度

一、空間降尺度流程

本研究欲進行空間降尺度之土壤含水量產品根據前段所述之各產品解析度之不同，共包含 0.25° 之 CCI SM 與 Merged SM，以及 9 km 之 SMAP SM 等產品，上述產品之降尺度目標皆為 3 km。本研究基於 ConvLSTM 之空間降尺度流程首先係將資料區分為訓練(2018 至 2020 年)與驗證(2021 年)兩階段，於模型訓練階段，首先將與 0.25° 之 CCI、Merged SM、9 km 之 SMAP 產品資料以及對應各產品解析度與資料範圍之相關環境因子資料用做模型訓練輸入(Training dataset)，透過模型學習擬合環境因子與各土壤含水量產品(label)間之非線性關係，而 2021 年之 0.25° CCI 與 Merged SM，以及 9 km 之 SMAP 等產品與環境因子資料則用作模型驗證(Validation dataset)，不參與模型訓練，此目的在於透過獨立於訓練階段之新資料評估模型對新情況之適應能力，即防止模型過擬合(Overfitting)於訓練資料，而喪失其在實際預測精細尺度資料時之泛化性。待模型訓練完畢，即可輸入 2018 至 2021 年之 3 km 解析度之環境因子資料至 ConvLSTM 模型中，以預測 2018 至 2021 年 3 km 之高解析度土壤含水量資料。而本研究針對 CCI SM、SMAP SM 及 Merged SM 進行空間降尺度所產製之降尺度產品分別稱為 Downscaled CCI SM、Downscaled SMAP SM 及 M&D SM，並且上述所有產品及 HRLDAS SM 均會以地表測站資料為依據，進行最終成果之評比，而本研究之空間降尺度流程如圖 4-4 所示。




圖 4-4 本研究之土壤含水量產品降尺度流程

二、深度學習方法之應用框架

本研究使用 Python 3.10 於 Spyder 整合開發環境中進行土壤含水量產品資料之空間降尺度程式編譯與分析。研究中使用之 DL 模型為在 Tensorflow 與 Keras 框架下執行之 ConvLSTM，此外，本研究亦使用 Scikit-learn (Sklern) 套件進行資料之前處理。而本研究所使用之各套件版本使用的套件版本分別為 Tensorflow 2.11.0、Keras

2.11.0 及 Sklearn 1.4.0。此小節將簡述 Tensorflow、Keras 及 Sklearn 之理論與發展過程。。

(一)Tensorflow

Google Brain 團隊在 2015 年開發了 TensorFlow，這是一個支援多種程式語言之開源 DL 平台，包括 Python、C++、R、Swift 及 JavaScript。TensorFlow 不僅適用於多種 DL 演算法，還已在多家知名企業如 Google、YouTube、Paypal、Intel 和 Twitter 中得到應用。同時此平台擁有良好的系統兼容性，可以在 Windows、Linux 和 Raspberry Pi 等多種作業系統運行，並支援包括 CPU、GPU 和 TPU 在內的多種運算架構，以進一步提升其運算效率。此外，TensorFlow 已將多種 ML 與 DL 模型模組化，包括 CNN、LSTM、Sequential Models 及本研究所使用之 ConvLSTM，使其能勝任從圖像識別到自然語言分析等多種不同應用。不僅如此，TensorFlow 此種模組化設計也支援各種自定義函數，允許使用者根據自身特定需要對模型進行更詳細的調整。TensorFlow 之開源設定與對可模型調整之靈活性使其成為當前極具影響力之 DL 框架之一。

(二)Keras

Keras 是一個由 François Chollet 使用 Python 所開發之開源神經網路模組，並提供了高階的神經網路 Application Programming Interface，其可以多種平台上作為後端運行，包括 TensorFlow、由加拿大蒙特婁大學的 MILA 實驗室開發之 Theano 及由微軟研究院開發之 CNTK，而其中 TensorFlow 是 Keras 之預設後端。Keras 常被用來處理 DL 模型之各種模組化，包括層、目標、啟動函數、最佳化

函數等一系列參數設定，令使用者在處理資料時可更有效率，此外對於各種 ML 與 DL 模型之輸入層、隱藏層和輸出層等架構，Keras 也已經預先定義完畢，讓使用者更加易於設計自身所需模型，無需過多關注模型深層之各種超參數，能夠迅速地進行分析。此外 Keras 同樣支援在 CPU 和 GPU 等不同運算架構上進行轉換，而 Keras 之工作模式分為以線性方式堆疊層進行設計之序列式模型和將不同的結構組合成通用模型之功能式模型。

(三)Sklearn

Sklearn 是一個以 Python 為基礎的開源 ML 函式平台，其為利用了 NumPy、SciPy 和 Matplotlib 等 Python 之資料科學平台所實現高效之演算法應用，並涵蓋許多主流之 ML、DL 演算法。Sklearn 提供了包括分類(Classification)和迴歸(Regression)之監督式學習演算法，及如分群(Clustering)之非監督式學習演算法，而在資料前處理(Preprocessing)方面，其也提供降維(Dimensionality Reduction)、及各種正規化(Normalization)與標準化(Standardization)函式功能，另外在模型選擇與評估(Model Selection and Evaluation)方面，其也提供交叉驗證(Cross-validation)、超參數調整及各種評估指標之量化等功能，以上功能共同構成了其之核心部分。綜上所述，Sklearn 之各種功能和工具讓使用者對於各式 ML 和 DL 建模之過程有更全面的掌握。從資料前處理開始，到模型的訓練、參數調整、模型之評估與選擇，其都能提供相應支援，讓使用者可以更專注於探討欲解決之問題，並且當使用者遇到相關問題時，Sklearn 還擁有許多豐富的社群資源與許多公開之應用經驗分享，令使用者可更容易取得相應解決方案。

三、ConvLSTM模型介紹

ConvLSTM 由 Shi et al. (2015)開發，是一種專為處理時空序列資料設計之遞歸神經網路(Recurrent Neural Network, RNN)變體。相較於傳統 LSTM 只使用全連接層來處理時間序列資料，完全無考慮到資料在空間上之特性，ConvLSTM 將傳統 LSTM 的全連接操作替換為卷積操作，使其能夠有效地處理並分析具有空間結構的資料，其模型運算之單元結構如圖 4-5 所示。




圖 4-5 ConvLSTM 模型運算之單元結構圖

在 ConvLSTM 中，輸入門、遺忘門及輸出門之運算從全連接變為卷積運算，這種變更讓模型之資料輸入維度從 2D image 擴展至 3D tensor，使其可更精確擷取資料於空間上之特徵，此外，ConvLSTM 之輸入門、遺忘門、輸出門及細胞狀態之更新等各運算結構都結合了 Hadamard 乘積進行對應元素間之相乘，以控制資訊之流通。在遺忘門中，Hadamard 乘積決定哪些舊細胞狀態之資訊需要被保留；在輸入門中，Hadamard 乘積用於將新資訊融入當前之細胞

狀態；而輸出門則利用 Hadamard 乘積來確定從細胞狀態到隱藏狀態之資訊流量。細胞狀態之更新則是融合遺忘門和輸入門的結果，進一步強化了模型對資料之時間序列和空間特徵擷取能力，使其能夠有效分析與處理如降雨、土壤含水量此等同時具有時空相關性之水文變量。

而 ConvLSTM 之輸入門、遺忘門、輸出門、細胞狀態與隱藏狀態更新等各運算結構之方程式分別如式 4-11 至式 4-15 所示。

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \quad (4-11)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \quad (4-12)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (4-13)$$

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o) \quad (4-14)$$

$$H_t = o_t \circ \tanh(C_t) \quad (4-15)$$

式中 i_t 、 f_t 、 C_t 、 o_t 與 H_t 分別為第 t 時刻之輸入門(Input gate)狀態向量、遺忘門(Forget gate)狀態向量、細胞狀態(Cell state)、輸出門(Onput gate)之狀態向量與隱藏狀態(Hidden state)； X_t 為第 t 時刻之輸入； H_t 為第 t 時刻之輸出； W 為權重； b 為偏差值； σ 為 Sigmoid function，用於將計算出之狀態向量值域壓縮在 0 到 1 間； $\tanh$ 為 Hyperbolic Tangent Activation Function，用於將計算出之狀態向量值域壓縮在 -1 到 1 間；“*”表示卷積運算；“ $\circ$ ”表示 Hadamard 乘積。

而 ConvLSTM 於資料輸入維度轉換之示意圖則如圖 4-6 所示，其概念為將二維圖像(rows and columns)增加一個維度，從而形成三維張量。




圖 4-6 ConvLSTM 資料輸入維度轉換示意圖(Shi et al., 2015)

ConvLSTM 通過分析輸入資料以及其在空間上之鄰近網格之過去狀態，來決定網格中某個單元的未來狀態(Shi et al., 2015)。此種轉換使得模型能夠在每個時步(timesteps)擷取資料中更多之空間特徵，從而有效進行時空資料分析。

第六節 基於統計之時間降尺度

本研究進一步產製小時尺度之 M&D SM 產品，目前採用之方法為基於 HRLDAS 小時資料變化率之時間降尺度流程。由於 HRLDAS 與 M&D SM 的網格相互對應，因此可以逐網格進行處理。首先，對每個網格之 HRLDAS 小時 SM 資料進行平均，生成 HRLDAS 的日平均 SM 資料。接著將每網格之 HRLDAS 小時 SM 值除以該網格的日平均值，從而計算出每小時的資料變化率(Variation Ratio)。在獲得這些變化率後，再將每個網格之日尺度 M&D SM 產品乘以對應的每小時變化率，即可得到小時尺度的 M&D SM 產品，而詳細流程如圖 4-7 所示。




圖 4-7 本研究之土壤含水量時間降尺度流程

第七節 評估指標

為對研究成果進行全面性之評估，本研究以表 3-1 所述之 13 地表測站於 2018 至 2021 年間無缺失之觀測資料作為依據，對所有土壤含水量產品進行結果驗證，而本研究所使用之評估指標分

別為 CC、Bias、RMSE 及 ubRMSE，其方程式分別如式 4-16 至式 4-19 所示。

$$CC = \frac{cov(x, x')}{\sigma_x \sigma_{x'}} \quad (4-16)$$

$$Bias = \frac{1}{n} \sum_{i=1}^n (x - x') \quad (4-17)$$

$$RMSE = \sqrt{\sum_{i=1}^n (x - x')^2 / n} \quad (4-18)$$

$$ubRMSE = \sqrt{\sum_{i=1}^n [(x - \bar{x}) - (x' - \bar{x}')^2] / n} \quad (4-19)$$

式中 x 為測站資料； x' 為各產品資料； σ_x 與 $\sigma_{x'}$ 為測站與各產品資料之標準差； $cov(x, x')$ 為測站與各產品資料之共變異數； $\bar{x}$ 與 $\bar{x}'$ 為測站資料平均值與各產品資料平均值； n 為資料總筆數。

第八節 WRF-Hydro 模式

一、模式介紹

WRF-Hydro 模式是由 NCAR 所開發之 WRF 模式於「水文模擬」的擴展加強版本，為多參數分散式類型之物理性水文模式，WRF-Hydro 旨在連接大氣層和陸地水文學的多尺度過程，改善 WRF-Noah 模式與相關應用中對陸面模擬之地表、地下和河道水之與空間再分配(spatial redistribution)有關的陸地水循環，可應用於區域水文氣象評估、水資源管理及陸面-大氣耦合等相關研究 (Skamarock et al., 2008)。其既可用於非耦合(獨立或離線)模式，也可

用於大氣模式(如 WRF)和其他地球系統建模架構的耦合模式，提供有關漫地流、地下水、以及河流空間再分佈後更準確的資訊，增強水文模式與大氣模式的耦合(Gochis et al., 2020; Skamarock et al., 2008)。

WRF-Hydro 開發至今之主要元件包括陸地(漫地流)水理演算、飽和地下水流演算、一維渠道演算、水庫/湖泊佈線模塊及簡單的經驗基流演算模型，如圖 4-8 所示。WRF-Hydro 在漫地流演算應用完全不穩定顯式有限差分的擴散波方程式，該方程式為 St. Venant 連續方程的簡化和淺水波的動量，擴散波公式優於典型的運動波公式，可用於計算迴水影響並考慮逆坡上的流量，其概念如圖 4-9 所示。而在渠道網格演算方面，考量隨地形向下分佈之渠道網格中水流的分佈式演算，使用由一階 Newton-Raphson 求解積分所得之顯式、一維、可變時間步長之擴散波公式，可變的時間步長乃為避免求解過程之數值離散和不穩定性。另外假設渠道為梯形橫截面，需要兩個附加參數，分別為渠道底部寬度和邊坡項，模式設定之渠道示意圖為圖 4-10 所示。

除上述物理過程外，為更加描述陸氣通量交換等之物理特性，WRF/WRF-Hydro 有再與 Noah LSM 耦合，在獨立運行 WRF-Hydro 模式需給定其大氣驅動資料，亦需透過 ArcGIS 預處理工具，由給定的數值高程資料(DEM)處理得到模式需要之相關地理文件(如子集水區和渠道網格)，以利模式針對陸地、渠道、地下水、漫地流演能更具有合理模擬結果。




圖 4-8 WRF-Hydro 物理參數和相關輸出概念圖

(取自 Gochis et al., 2020)




圖 4-9 模式地形流向概念圖(取自 Gochis et al., 2013)




圖 4-10 模式渠道設定示意圖(取自 Gochis et al., 2013)

二、ArcGIS預處理

在 WRF-Hydro 模式中，ArcGIS 預處理工具負責建立運行所需的空間地理資訊資料(如地形和土地利用)，使模式能夠合理模擬土壤含水量、地表漫地流、地下水流以及河道演算等各項物理過程。此過程首先須建立演算網格，WRF-Hydro 演算會在 LSM 網格之子網格上執行，儘管 WRF-Hydro 演算功能通常在比 LSM 有更精細的網格，但其演算網格仍需與 WRF 網格相同，且完全嵌套在 LSM 網格內(Sampson and Gochis, 2020)，此外，此預處理過程亦會用到 WRF 預處理系統生成之 GEOGRID 文件所提供之地表參數資料。而在重新嵌套因子(regridding/nesting factor)設定方面，本研究將水平解析度設為 2 km，並考量模擬所需之計算時間，將重新嵌套因子設定為 20，以獲得解析度為 100 m ($=2000/20$) 之水理演算網格，而其單元數量設置為 200，使用較小的閾值以增加渠道網格的排水密度，預處理流程如圖 4-11 所示。預處理完過程會生成四個 netCDF 格式文

件提供 WRF-Hydro 邊界條件，分別為描述二維演算網格文件 (Fullodom_hires.nc)、一維地下水盆地參數文件 (GWBUCKPARAM.nc)、二維地下水盆地文件 (GWBASIN.nc) 及 LDAS 網格空間資料文件 (GEOGRID_LDASOUT_Spatial_Metadata.nc)。




圖 4-11 ArcGIS 預處理流程(取自紀旻宏，2022)

三、模式設定

本計畫使用之 WRF-Hydro 模式版本為 V5.1.1，模擬範圍為臺灣本島，並選擇離線模式進行模擬。運行模式前先對 WRF-Hydro 模式預設之預處理資料(如土地利用與土壤質地)替換為臺灣實際觀測資料，並透過 ArcGIS 預處理工具，提供相關更符合臺灣實際情況之地理文件，以利模式模擬出更準確之土壤含水量資料，而模式所需之降雨驅動資料則使用臺灣 QPESUMS 降雨資料。本研究選用研究資料距今最近之盧碧颱風事件時段(2021/8/6~2021/8/8)進行模擬。模

擬結果前 10 小時將作為模式起轉(spin up)時間，測試土壤參數敏感度階段採用起轉時間後 48 小時之結果，調校土壤參數階段採用起轉時間後 72 小時之結果。研究結果以上安(Shangan)土壤含水量測站資料作為驗證對象。

四、參數調校

在 WRF-Hydro 模式中可對多種參數進行調校，包含 Noah LSM 中的全域參數(GENPARM.TBL)、土壤參數(SOILPARM.TBL)、土地覆蓋參數(MPTABLE.TBL)；地形演算參數(Hydro.TBL 及 hydro2dtbl.nc)；渠道演算參數(CHANPARM.TBL 及 Route_Link.nc)；地下水參數(GWBASINS.nc 及 GWBCKPARM.nc)；和湖泊/水庫參數(LAKEPARM.nc)。本計畫根據 Hogue et al. (2006)研究成果，優先選擇分析 SOILPARM.TBL，並對其內部之土壤保水曲線之斜率(BB)、土壤飽和水力傳導度(SATDK)、土壤飽和含水量(MAXSMC)、土壤飽和水分擴散率(SATDW)、土壤飽和基質勢能(SATPSI)、土壤乾燥含水量(DRYSMC)、田間容水量(REFSMC)及凋萎點(WLTSMC)等參數進行敏感度分析，而後調校 BB、MAXSMC 及 SATDK 等較為敏感的參數，模式詳細之參數調校流程如圖 4-12 所示。而各項參數值調校範圍同樣依據 Hogue et al. (2006)研究結果，調校倍數如表 4-1 所示，總計模擬 125 種參數組合。此方法有助於在模擬強烈降雨事件下，使模式可更準確反映實際水文過程，從而提高土壤含水量模擬之準確性。




圖 4-12 本計畫之 WRF-Hydro 參數調校流程

表 4-1 各土壤參數調校倍數

Parameters	調校倍數
BB	1.1、1.2、1.3、1.4、1.5
MAXSMC	1.1、1.2、1.3、1.4、1.5
SATDK	1.5、2.0、2.5、3.0、3.5

第五章 分析結果

第一節 土壤含水量產品偏差校正結果

為對 CCI、SMAP 及 HRLDAS 等產品進行偏差校正以利後續進行資料融合，本研究首先對各 0.25° 解析度之三產品與測站進行 Bias 分析，而為使偏差校正結果與實際觀測值更為符合，本研究挑選了資料品質較佳且資料觀測年份超過兩年之較齊全測站(上安、來義、神木、南豐、坪頂、氣象坪、蓮華池)來作為驗證依據，而 0.25° 解析度各產品與上述測站 Bias 之中位數(Median)與平均值(Average)如表 5-1 所示。由可看到三產品中 SMAP 與測站資料 Bias 之 Median 與 Average 皆為最小。因此本研究選擇 SMAP 作為偏差校正之依據。

表 5-1 0.25° 解析度之三產品與測站 Bias 之 Median 與 Average

Bias	CCI	SMAP	HRLDAS
Median	0.027	0.009	-0.014
Average	0.012	0.001	-0.025

第二節 TC 誤差分析結果

在此小節分析中，主要針對 CCI、SMAP 及 HRLDAS 等三產品進行 TC 方法之各項分析，並以如圖 5-1 至圖 5-3 展示了各產品間之共變異數(Covariance, COV)、與未知真值之 REV 以及各產品於最終進行加權融合時所佔之權重空間分布。首先自圖 5-1 可發現，三產品間之共變異數在空間變化趨勢上大致相同，這是由於在對各產品進行 CDF matching 偏差校正以及將 HRLDAS 作為依據，對 CCI 與

SMAP 進行隨機森林迴歸等兩前處理步驟後，會使得各產品本身之變異數以及資料離散程度趨於相似，進一步使產品間 COV 展現出類似之趨勢。而在具體之地理分布上，臺灣西南部、東部及北部，三產品之間 COV 普遍較高，越往西北方向則呈現下降之趨勢，顯示三產品之土壤含水量在上述區域有較高之相關性，即三產品之土壤含水量資料在臺灣西南部、東部及北部之變化趨勢相較其他區域要更有一致性。而推求出各產品之變異數與共變異數後，即可進一步求得如圖 5-2 所示，各產品與真值之 REV 中，並且由圖 5-2 可看出 HRLDAS 於大部分區域明顯要較其他兩產品要低許多，顯示 HRLDAS 之資料變化更為穩定，推測造成此現象是因為 HRLDAS 模式在運行時引入了許多大氣驅動資料，考慮了更多地表特性與更多與土壤含水量相關之氣候變量，而 CCI 和 SMAP 因基於衛星遙測，受到各種大氣干擾與植被複雜度因素，使其所反演出之土壤含水量資料品質較 HRLDAS 不佳。綜上所述，本研究根據前段所述之式 4-8 至式 4-10，即可估算出如圖 5-3 所示，各產品於融合之權重分布，其中 HRLDAS 權重在所有區域同樣最高，其在所有網格之平均值為 0.837；SMAP 次之，其在所有網格之平均值為 0.089，CCI 則為最低，其在所有網格之平均值為 0.074。




圖 5-1 三產品之 COV 空間分布圖




圖 5-2 三產品與未知真值之 REV 空間分布圖




圖 5-3 三產品於融合時所佔之權重空間分布圖

第三節 0.25°土壤含水量產品準確性分析結果


為對 0.25°之融合後產品(Merged SM)進行驗證，本研究透過將 CCI、SMAP 及 HRLDAS 等三原始產品與 Merged SM 與全臺 13 個測站進行統計分析，與測站之分析結果如表 5-2 與圖 5-4 所示。

由表 5-2 與圖 5-4 可發現，Merged SM 在與測站評比之各項指標綜合表現最佳，其中與測站 CC 之 Median 中，Merged SM 雖較 HRLDAS 略為降低約 1.93%，但相比於 CCI 與 SMAP，Merged SM 則分別提升了 46.5%與 39.7%；且 Merged SM 與測站之 Bias 與 RMSE 均為所有產品中表現最佳，其中 Merged SM 與測站 Bias 之 Median 分別較 CCI、SMAP 及 HRLDAS 要降低了 48.7%、44.1%及 71.7%，RMSE 則是分別降低了 20.6%、0.30%及 5.32%，；但 Merged SM 與測站之 ubRMSE 表現則分別遜色於 CCI 與 HRLDAS 約 6.91%與 21.1%，但較 SMAP 仍降低了約 12.5%。綜上所述，就結果而言 Merged SM 雖在 ubRMSE 表現較為遜色，但仍要優於 SMAP 產品，而在 CC 方面，Merged SM 也有著與原始產品中表現最佳之 HRLDAS 近乎持平之良好表現(~ 0.76)，且 Bias 與 RMSE 兩誤差指標更為所有產品中最佳，表示本研究基於 TC 資料融合方法產製之 Merged SM 可有效擷取各來源產品之優勢，獲取更具綜合性之土壤含水量產品。


表 5-2 0.25°解析度之四產品與測站之統計分析結果

Median	CCI	SMAP	HRLDAS	Merged
CC	0.519	0.545	0.776	0.761
Bias	-0.019	-0.018	-0.035	-0.010
RMSE	0.119	0.095	0.100	0.095
ubRMSE	0.050	0.062	0.044	0.054


(a) CC



(b) Bias



(c) RMSE



(d) ubRMSE




圖 5-4 各 0.25°產品與測站評估成果之盒狀圖

而在各產品與測站資料的時間序列比較中，也可看出其趨勢和差異。各產品在與測站的時間序列比較如圖 5-5 所示，此處本研究舉上安、南豐及坪頂測站為例，圖中黃線、藍線、綠線、紅線和黑


線分別代表 CCI SM、SMAP SM、HRLDAS SM、Merged SM 及測站資料，降雨量則以深藍色直條表示。

以上安測站為例，HRLDAS SM 和 Merged SM 的變化趨勢更為接近測站資料。整體來看，CCI SM 波動較平穩，較難反映實際觀測之土壤含水量變化而 SMAP 產品在降雨過後的退水曲線與測站觀測結果較不相符，HRLDAS SM 趨勢較接近測站資料，Merged SM 則綜合各產品優勢，表現出最佳的一致性。

而在南豐測站，CCI SM 資料波動同樣較小且與降雨峰值較不對應；SMAP SM、HRLDAS SM 及 Merged SM 則呈現出較大之數值變化範圍，在趨勢較接近測站資料。其中 Merged SM 更能有效反映強降雨對土壤含水量於時序變化上的影響。

在坪頂測站的情況也類似，CCI SM 波動較平穩，SMAP SM 資料偏差較小，但同樣展現出與測站觀測差距較大之退水歷線。相反，HRLDAS SM 雖有一定偏差，但其變化趨勢和退水歷線與測站資料更一致，而 Merged SM 則展現出最小的偏差和最高的一致性。

整體而言，各產品在與各測站資料的比較上均表現出類似特性。CCI SM 在所有測站中都顯示出相對平穩的數值波動；SMAP SM 則與測站資料偏差較小，但在強降雨後的退水歷線與測站觀測、降雨峰值較不相符；HRLDAS SM 則是在資料之時序變化趨勢上與測站最接近，但其也有著與測站觀測值較大之偏差。而本研究通過 TC 方法產製之 Merged SM 相較各原始產品，能夠更好地反映土壤含水量在時序上之變化趨勢。

圖 5-5 各 0.25° 解析度之各產品與測站資料之時間序列圖

(a)上安測站；(b)南豐測站；(c)坪頂測站

第四節 前期降水指數(API)分析結果

本小節將敘述本研究所使用的相關環境因子 API 的計算結果。本研究中，將 0.25° 解析度的 TCCIP 日雨量代入式 3-2。在此公式中，衰減常數 K 設置範圍為 0.80 至 0.98，間隔為 0.01；考慮的前期天數區間設置為 1 至 30 日，間隔為 1 日。以上各網格之 K 值與前期天數設置是根據與 Merged SM 計算所得的相關係數最高值決定。在計算得出各網格 API 後，本研究將 API 根據式 3-3，使用 Python 之 sklearn 套件進行 Yeo-Johnson 轉換。此套件會根據 Maximum likelihood method 自動計算每個網格最適配之 λ 值。而各網格所使用之 K 值、考慮天數與 λ 值如圖 5-6 所示，其中各網格計算所使用之 K 值範圍為 0.80 至 0.98，各網格計算使用天數範圍為 16 至 30 日，各網格計算使用之 λ 值範圍為 -0.282 至 0.209；原始降雨量、Yeo-Johnson 轉換前後之 API 分別與 Merged SM 之相關係數空間分布圖則如圖 5-7 所示，其中降雨量與 Merged SM 平均相關係數為 0.41；Yeo-Johnson 轉換前之 API 與 Merged SM 平均相關係數為 0.68，Yeo-Johnson 轉換後之 API 與 Merged SM 平均相關係數為 0.78，就平均而言，Yeo-Johnson 轉換後之 API 與 Merged SM 之相關係數相較原始降雨量資料與原始 API 值分別要提升了約 0.27 與 0.10，因此本研究在這三者中選用 Yeo-Johnson 轉換後之 API 作為後續放入 ConvLSTM 模型於 0.25° 訓練時之因子。此外，鑒於 HRLDAS 產品與測站觀測資料之間的平均相關性最高，因此在 3 km 解析度 API 的計算中，其 K 值、前期天數與 λ 值設置依據調整為與 3 km HRLDAS SM 計算所得的最高相關係數決定，圖 5-8 展示了 3 km 各網格所使用之 K 值、考慮天數與 λ 值，其中各網格計算所使用之 K

值範圍為 0.80 至 0.95，各網格計算使用天數範圍為 1 至 30 日，各網格計算使用之 λ 值範圍為 -0.709 至 0.220；3 km 之 API 與 HRLDAS SM 之相關係數則如圖 5-9 所示，所有網格相關係數平均值高達 0.83。




圖 5-6 0.25° 之各網格計算 API 所使用之 K 值、考慮天數與 λ 值




圖 5-7 0.25° 之降雨量、Yeo-Johnson 轉換前後之 API 分別與 Merged SM 之相關係數




圖 5-8 3 km 之各網格計算 API 所使用 K 值、考慮天數與 λ 值




圖 5-9 Yeo-Johnson 轉換後之 API 與 HRLDAS SM 相關係數

第五節 ConvLSTM 模型驗證結果

本研究係將衛星土壤含水量產品(即 0.25° 之 CCI SM、Merged SM 及 9 km 之 SMAP SM)進行降尺度至 3 km，而為確保模型可以用於預測精細尺度之土壤含水量資料，因此需先對 ConvLSTM 模型進行驗證，本研究以各產品於 2018 至 2020 年資料作為模型訓練資料，並以 2021 年資料作為模型驗證資料。本節將說明 CCI SM、SMAP SM 及 Merged SM 分別於 ConvLSTM 之驗證成果。且為更好說明各環境因子對於土壤含水量之影響程度，本研究將因子分為會隨時間變化之動態環境因子與不隨時間變化之靜態分類因子，如表 5-3 所示。

表 5-3 土壤含水量之動態、靜態因子分類表

動態因子	靜態分類因子
API、Band 4、Band 7、LST、NDVI、ST、Temperature	Elevation、Slope、Landuse、Manning's n value、Soil pH、Clay content、Soil organic content、 K_s

一、CCI產品之模型驗證成果

圖 5-10 與圖 5-11 分別為 CCI 產品於 ConvLSTM 模型在 2021 年驗證階段之預測值與產品實際值散布圖，以及 CCI 產品於 ConvLSTM 模型在 2021 年驗證階段之特徵貢獻度。

首先圖 5-10 之橫軸代表 CCI 產品於 2021 年之實際土壤含水量值，縱軸則代表模型所預測的土壤含水量值。從圖中可以看出，模

型預測值與實際值之間有著良好之相關性(~ 0.77)，且在 Bias 與 RMSE 方面也有著一定的準確性，此成果顯示 ConvLSTM 在擬合 CCI 產品與眾多環境因子具有良好成效。而在各因子之特徵貢獻度方面，也可由圖 5-11 中看出基於降雨量資料產製之前期降水指數(API)之貢獻度明顯高於其於所有因子許多，顯示降雨是驅動土壤含水量變化最為重要之因素，而其餘主要貢獻因子為 soil clay、ph 及 slope 等不隨時間變化之「靜態、分類型」因子之原因，在於 CCI 產品與土壤含水量實際變化較不吻合、資料之「隨機性」較高，且資料隨時間變異程度較低，從而導致其他「動態」因子貢獻度相對下降。




圖 5-10 CCI 產品於模型驗證階段之預測值與實際值散佈圖




圖 5-11 CCI 產品驗證階段各環境因子之特徵貢獻度

二、SMAP 產品之模型驗證成果

圖 5-12 與圖 5-13 同樣為 SMAP 產品於 ConvLSTM 模型在 2021 年驗證階段之預測值與產品實際值散布圖，以及 SMAP 產品於 ConvLSTM 模型在 2021 年驗證階段之特徵貢獻度。

首先，圖 5-12 之橫軸同樣代表 SMAP 產品於 2021 年之實際土壤含水量值，縱軸則為模型所預測的土壤含水量值。從此圖中可以看出，相比於 CCI 產品，ConvLSTM 模型對於 SMAP 產品之預測值與實際值之間有著更為優異之相關性(~ 0.85)，並且在 Bias 與 RMSE 方面同樣也有著不俗之準確性，此驗證成果再次顯示 ConvLSTM 對於擬合土壤含水量產品與眾多環境因子具有一定之成效。而對於 SMAP 產品，各因子的特徵貢獻度同樣以前期降水指數(API)為最高。然而與 CCI 產品不同的是，其餘主要貢獻因子如 Band 4(綠光)

和 Band 7(短波紅外光)，皆與土壤含水量有較直接的關聯。如綠光的反射率受植被狀態影響，當土壤含水量較高時，植被生長旺盛，葉綠素含量增加，反射更多綠光；反之，當土壤含水量較低時，反射綠光減少。而短波紅外光對水分吸收非常敏感，濕潤的土壤吸收更多短波紅外光，導致反射率降低，乾燥土壤則反之。因此，資料品質更佳且更能反映土壤含水量變化的 SMAP 產品，其 Band 4 與 Band 7 的貢獻度也相對較高。




圖 5-12 SMAP 產品於模型驗證階段之預測值與實際值散佈圖




圖 5-13 SMAP 產品驗證階段各環境因子之特徵貢獻度

三、Merged & Downscaled 產品之模型驗證成果

圖 5-14 與圖 5-15 為 Merged 產品於 ConvLSTM 模型在 2021 年驗證階段之預測值與產品實際值散佈圖，及 Merged 產品於 ConvLSTM 模型在 2021 年驗證階段之特徵貢獻度。

圖 5-14 之橫軸為 Merged 產品於 2021 年之實際土壤含水量值，縱軸則為模型預測值。相比 CCI 與 SMAP 產品，模型預測值與實際值間有著最佳之相關性(~ 0.92)，且從資料分布也可看出模型對於 Merged 產品也有更佳的預測能力，其迴歸斜率來到最佳之 0.77，說明資料品質對於模型在擬合時的重要性。在各因子貢獻度分析中，Merged SM 產品同樣以 API 的貢獻度最高，且相比 CCI 和 SMAP 產品，API 的貢獻度更為顯著(~ 0.6)。顯示降雨作為主要驅動因子，對土壤含水量變化的影響極為明顯，使得其他動態因子對於捕捉土

壤含水量變化的影響力相對降低，而其餘主要貢獻因子如 soil clay、ph 及 slope 等則反映出不同土壤特性在空間異質性方面的重要性。




圖 5-14 Merged 產品於模型驗證階段之預測值與實際值散佈圖




圖 5-15 Merged 產品驗證階段各環境因子之特徵貢獻度

第六節 3 km 土壤含水量產品準確性分析結果

由表 5-4 與圖 5-16 同樣可發現，在 3 km 各產品之表現趨勢大致和 0.25° 相同，並且 M&D SM 同樣在與測站資料之綜合評估結果表現最佳，其在 Bias、RMSE 及 ubRMSE 等三指標表現更是所有產品中最佳，其相較 Downscaled CCI、Downscaled SMAP 及 HRLDAS 等產品，Bias 分別降低 43.7%、67.5%及 68.4%；RMSE 分別降低 25.4%、1.4%及 21.5%；ubRMSE 分別降低 13.4%、11.2%及 15.4%；而在 CC 方面，雖較 HRLDAS 略為下降 6.61%，但相較 Downscaled CCI、Downscaled SMAP 仍有所提升 17.5%與 4.99%。整體而言，Merged & Downscaled SM 在 CC 表現略微遜色，但仍可維持與測站資料之高相關性(~ 0.76)，且也在其他三項各項指標表現最佳，表示相比單一來源之產品，本研究產製之 M&D SM 為綜合表現最佳之土壤含水量資料。

表 5-4 3 km 解析度之四產品與測站之統計分析結果

Median	Downscaled CCI SM	Downscaled SMAP SM	HRLDAS SM	M&D SM
CC	0.647	0.724	0.814	0.760
Bias	0.037	-0.064	-0.066	-0.021
RMSE	0.121	0.091	0.115	0.090
ubRMSE	0.049	0.047	0.050	0.042




圖 5-16 各 0.25° 產品與測站評估成果之盒狀圖

此外，為對各土壤含水量產品進行更全面之分析，本研究也分別挑選臺灣北、中、南部測站(此處舉中央大學、上安及來義測站為例)，繪製各 3 km 產品與測站資料之時間序列，如圖 5-17 所示，圖中黃線、藍線、綠線、紅線和黑線分別代表 Downscaled CCI SM、Downscaled SMAP SM、HRLDAS SM、M&D SM 及測站資料，降雨量則以深藍色直條表示。

由圖 5-17 可看出，各 3 km 產品均表現出與 0.25° 解析度類似之資料特性，同樣要以 Downscaled CCI SM 之資料值域波動相對平

穩，相比之下，Downscaled SMAP SM、HRLDAS SM 及 M&D SM 則呈現較大之波動幅度，更能反映土壤含水量隨時間的變化趨勢，且各降尺度產品引入前期降水指數(API)作為深度學習輸入因子，使資料的峰值與退水歷線更能對應雨量峰值。本研究產製的 M&D SM 在臺灣北、中、南部區域表現出與測站資料的高相關性，且相對其他產品，其偏差值更小。綜上所述，3 km 解析度的各產品在資料特性上與 0.25°解析度有相當程度的相似性，但對雨量變化更為靈敏，且能保持與測站資料的高相關性，顯示降尺度後的產品，在空間解析度提升之同時，在時間動態變化上亦也有優異表現。







圖 5-17 各 0.25° 解析度之各產品與測站資料之時間序列圖

(a) 中央大學測站；(b) 上安測站；(c) 來義測站


第七節 土壤含水量產品於颱風豪雨事件之評估結果

為對本研究產製之兩綜合性產品(即 0.25° 之 Merged SM 與 3 km 之 M&D SM)在時空變化上之表現進行評比，本研究挑選了 3 場研究期間內對於所挑選之大部分測站所在地(即臺灣中西部)影響較劇烈之颱風豪雨事件，分別為 2018 年 0823 熱帶低壓水災事件、2019 年 0517-0520 豪雨事件及 2021 年盧碧颱風事件，而三場颱風豪雨事件之擷取時段分別為 2018 年 8/22~8/24、2019 年 5/16~5/18 及 2021/8/5~8/7，其中觀測雨量資料來源為國家災害防救科技中心(National Science & Technology Center for Disaster Reduction, NCDR)之日累積雨量圖。圖 5-18 中展示了 2018 年 0823 熱帶低壓水災事件的影響，Merged SM 呈現之空間分布較為粗糙，但仍可展現與觀測雨量之對應性；而 M&D SM 則在臺灣中南部之高降雨區域，展現更精細的空間變化，尤其臺灣中部和南部高降雨區域，土壤含水量的增加更加明顯，顯示其能更可有效反映因降雨引起的土壤含水量變化。而於圖 5-19 中之 2019 年 0517-0520 豪雨事件期間，M&D SM 同樣能捕捉到更小尺度的土壤含水量變化，如在 2019/5/17 桃園、新竹一帶與 2019/5/18 中部山區，其高土壤含水量分布區域與當地局部強降雨區域更加吻合。而在最後圖 5-20 所展示的 2021 年盧碧颱風事件期間，M&D SM 同樣展示出更為精細且與降雨量更為吻合之土壤含水量空間分布。如 2021/8/5 在南部區域和 2021/8/6 在中南部沿海區域等降雨集中的區域，M&D SM 更能看出細緻之土壤含水量分布情況。綜上所述，兩產品均可有效反映強降雨事件所引起之土壤含水量變化，相較之下，M&D SM 在解析度上更具優勢。使其在更小尺度之相關分析更具應用性。

(a) Precipitation



(b) Merged SM



(c) Merged & Downscaled SM




圖 5-18 兩產品於 2018 年 0823 熱帶低壓水災事件之空間分布圖：

(a)NCDR 觀測雨量；(b)Merged SM；(c)M&D SM





(a) Precipitation**(b) Merged SM****(c) Merged & Downscaled SM**


圖 5-19 兩產品於 2019 年 0517-0520 豪雨事件之空間分布圖：

(a)NCDR 觀測雨量；(b)Merged SM；(c)M&D SM

(a) Precipitation



(b) Merged SM



(c) Merged & Downscaled SM





圖 5-20 兩產品於 2021 年盧碧及 0806 豪雨事件之空間分布圖：

(a)NCDR 觀測雨量；(b)Merged SM；(c)M&D SM

第八節 WRF-Hydro 土壤含水量模擬之參數校驗結果

本計畫首先對 SOILPARM.TBL 內參數如 BB、SATDK、SATDW、SATPSI、DRYSMC、MAXSMC、REFSMC 及 WLTS MC 進行敏感度分析，而上述參數之敏感性分析如圖 5-21 至圖 5-24 所示，由圖中可看出土壤含水量對 BB、SATDK 及 MAXSMC 三參數較為敏感，因此本研究優先選擇此三參數進行調校。根據與上安測站資料之評估結果，本研究最佳之模式參數調校組合為相較模式預設 1.5 倍之 BB、3.5 倍之 SATDK 及 1.5 倍之 MAXSMC。各參數調校前後，模式模擬之土壤含水量資料與上安測站之時間序列圖如圖 5-25 所示，Bias 與 RMSE 差異比較則如表 5-5 所示。結果顯示本研究調校後之 WRF-Hydro 模式土壤含水量相較調校前，可顯著降低與測站之 Bias 與 RMSE 分別為 80.5%與 61.0%，且由與測站之時間序列圖來看，其更可展現土壤含水量在強降雨事件之時序變化。此結果顯示模式經調校後所模擬之土壤含水量資料對極端降雨事件之響應更加靈敏，能準確掌握土壤含水量在降雨前後之變化過程。

(a) BB



(b) SATDK





圖 5-21 上安測站各參數敏感度分析之時間序列圖

(a) BB ; (b) SATDK

(a) SATDW



(b) SATPSI





圖 5-22 上安測站各參數敏感度分析之時間序列圖

(a) SATDW ; (b) SATPSI

(a) DRYSMC



(b) MAXSMC




圖 5-23 上安測站各參數敏感度分析之時間序列圖

(a) DRYSMC ; (b) MAXSMC



(a) REFSMC**(b) WLTS MC**

圖 5-24 上安測站各參數敏感度分析之時間序列圖

(a) REFSMC ; (b) WLTS MC




圖 5-25 上安測站最佳參數倍數組合之時間序列圖

表 5-5 模式校正前後模擬之土壤含水量與測站之分析結果

Gauge	Bias		RMSE	
	Original	Calibrated	Original	Calibrated
Shangan	-0.220	-0.043	0.223	0.087

第六章 結論與建議

第一節 研究結論

為產製臺灣地區高時空解析度網格話土壤含水量資料，本研究採用 TC 方法對 CCI、SMAP 及 HRLDAS 等土壤含水量產品進行誤差分析與多源資料融合，並結合 ConvLSTM 與統計方法對各產品進行時空降尺度分析。此外，本研究也針對 WRF-Hydro 模式進行初步土壤含水量模擬之參數調校。經由上述多面向分析後，本研究得出以下幾點結論：

1. 本研究通過 TC 方法產製之融合後產品(Merged SM)整體表現相較各原始產品更具綜合性。其與測站 CC 中位數較 CCI 和 SMAP 分別提高 46.5%和 39.7%，且其在 Bias 和 RMSE 方面表現最佳，相較各原始產品分別可降低 48.7~71.8%與 0.4~20.6%。而在 ubRMSE 方面較 SMAP 降低 12.5%，綜上所述，本研究基於 TC 方法的融合資料可有效擷取各產品優點，獲取更準確之土壤含水量資料。
2. ConvLSTM 模型在擬合 CCI、SMAP 及 Merged SM 各土壤含水量產品與眾多環境因子的關係時，基於降雨資料產製之前期降水指數(API)在各產品驗證階段的貢獻度最高，顯示降雨量是控制土壤含水量變化之最關鍵因素。
3. 本研究產製之 Merged and Downscaled SM 在四組 3 km 產品，同樣展現出綜合表現最佳之評估結果，其在維持與測站資料之高相關性(~0.76)同時，Bias、RMSE 及 ubRMSE 等指標上表現均

為最佳，其中 Bias、RMSE 及 ubRMSE 分別可降低 Downscaled CCI、Downscaled SMAP 及 HRLDAS 約 43.7~68.4%、1.4~21.5%及 11.2~15.4%，顯示經由 TC 方法與 ConvLSTM 之資料融合與降尺度架構可得到綜合表現最佳之土壤含水量資料。

4. Merged SM 與 Merged and Downscaled SM 均能有效反映颱風或豪雨等強降雨事件所引起的土壤含水量空間分布變化，但相較之下，後者在解析度和細節上更具優勢。因此在小範圍之強降雨和複雜地形的相關分析中，Merged and Downscaled SM 更具優勢，可提供更具應用性的土壤含水量資料。
5. 本研究初步調校後之 WRF-Hydro 模式土壤含水量相較調校前，可顯著降低與測站之 Bias 與 RMSE 分別為 80.5%與 61.0%，且更可展現土壤含水量在時間上之變化，對於極端降雨事件之響應也更加靈敏，彰顯其在區域相關水文分析之應用價值。



第二節 研究建議

1. 本研究使用之衛星產品之一 CCI 因其資料產製流程複雜因素，導致其資料更新較為不及時，每年僅提供一次更新，因此若欲取得更為即時之土壤含水量資料以進行後續之融合分析，可嘗試使用如 ASCAT、CYGNSS 等資料延遲更短之衛星產品，然此些產品於臺灣地區表現狀況仍須評估。
2. 深度學習方法日新月異，未來可利用更新穎之深度學習模型如 Trajectory Gated Recurrent Unit (TrajGRU)、U-Net 及遷移式學習等方法，或針對 ConvLSTM 進行超參數調校，以進一步提升深度學習對於土壤含水量預測之準確性。
3. 本研究之空間降尺度目標為 3 km，若欲進行更小尺度(如農業灌溉、局部坡地崩塌等)之水文分析，可在效能與時間允許情況下，收集相對應解析度之環境因子資料並將其輸入模型，以產製更高解析度的土壤含水量資料，從而應用於相關分析。
4. 本研究於 WRF-Hydro 模式之土壤含水量模擬中，目前僅針對模式內部的土壤參數進行調校，未來可進一步調校模式內部其餘參數，並採用更新的土地利用、土壤質地等地表資料作為模式，更進一步提升土壤含水量模擬的準確性，還可鍊接如 TCCIP 針對臺灣地區產製之 AR6 暖化情境與氣候統計降尺度資料氣候變遷推估資料，更深入探討未來氣候變遷對於土壤含水量變化趨勢之潛在影響。
5. 本研究所使用之衛星、模式及融合且降尺度之土壤含水量資料

未來除可應用於農業灌溉、局部坡地崩塌等議題外，亦可用於集水區水源涵養能力評估、估算土壤雨量指數等更具體之水土保持相關分析。



參考文獻

1. 林秉毅，林士堯（2021），臺灣歷史氣候重建資料生產履歷(1.0版)。[擷取日期：2023/9/19]，取自臺灣氣候變遷推估資訊與調適知識平台：
https://tccip.ncdr.nat.gov.tw/upload/data_profile/20210702170602.pdf
2. 林梓舜（2014），地表水文循環過程與大氣耦合作用對土壤濕度以及氣象模擬的影響，中央大學大氣物理研究所學位論文。
3. 洪于琄、洪景山、蔡佳伶（2014），高解析土壤資料同化系統之效能評估。《大氣科學》，42(1)，29-47。
4. 紀旻宏（2022），耦合氣象水文和水理模式於即時洪災預報，國立中興大學土木工程學系所碩士論文。
5. 楊承道，林士堯（2021），網格化觀測雨量日資料生產履歷(4.0版)。[擷取日期：2022/12/29]，取自臺灣氣候變遷推估資訊與調適知識平台：
https://tccip.ncdr.nat.gov.tw/upload/data_profile/20200117105621.pdf
6. 楊承道，林士堯（2021），網格化觀測溫度資料生產履歷(4.0版)。[擷取日期：2022/12/29]，取自臺灣氣候變遷推估資訊與調適知識平台：
https://tccip.ncdr.nat.gov.tw/upload/data_profile/20200117105621.pdf
7. 賴郡曄、林遠見（2022），GNSS-R 遙測技術的工程應用。《土木水利》，49(1)，21-26。
8. Abbaszadeh, P., Moradkhani, H., & Zhan, X. (2019). Downscaling

- SMAP Radiometer Soil Moisture Over the CONUS Using an Ensemble Learning Method. *Water Resources Research*, 55(1), 324-344.
9. Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., & Notarnicola, C. (2015). Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data. *Remote Sensing*, 7(12), 16398-16421.
10. Ali, S., Ghosh, N. C., & Singh, R. (2010). Rainfall–runoff simulation using a normalized antecedent precipitation index. *Hydrological Sciences Journal*, 55(2), 266-274.
11. Barrett, B., Dwyer, E., & Whelan, P. (2009). Soil Moisture Retrieval from Active Spaceborne Microwave Observations: An Evaluation of Current Techniques. *Remote Sensing*, 1(3), 210-242.
12. Blanken, P. D., Basara, J. B., Oncley, S. P., Horst, T. W., Niyogi, D., Tewari, M., Roberts, R., Alfieri, J. G., Trier, S. B., LeMone, M. A., Manning, K. W., & Chen, F. (2007). Description and Evaluation of the Characteristics of the NCAR High-Resolution Land Data Assimilation System. *Journal of Applied Meteorology and Climatology*, 46(6), 694-713.
13. Cheng, F.-Y., & Lin, T.-S. (2016). Impact of Soil Moisture Initialization and Soil Texture on Simulated Land–Atmosphere Interaction in Taiwan. *Journal of Hydrometeorology*, 17(5), 1337-

- 1355.
14. Cui, Y., Yang, X., Chen, X., Fan, W., Zeng, C., Xiong, W., & Hong, Y. (2020). A two-step fusion framework for quality improvement of a remotely sensed soil moisture product: A case study for the ECV product over the Tibetan Plateau. *Journal of Hydrology*, 587, 124993.
 15. Dobriyal, P., Qureshi, A., Badola, R., & Hussain, S. A. (2012). A review of the methods available for estimating soil moisture and its implications for water resource management. *Journal of Hydrology*, 458-459, 110-117.
 16. Dorigo, W., Wagner, W., Albergel, C., Albrecht, F., Balsamo, G., Brocca, L., ... & Lecomte, P. (2017). ESA CCI Soil Moisture for improved Earth system understanding: State-of-the art and future directions. *Remote Sensing of Environment*, 203, 185-215.
 17. Drusch, M., Wood, E. F., & Gao, H. (2005). Observation operators for the direct assimilation of TRMM microwave imager retrieved soil moisture. *Geophysical Research Letters*, 32(15), L15403.
 18. ElSaadani, M., Habib, E., Abdelhameed, A. M., & Bayoumi, M. (2021). Assessment of a Spatiotemporal Deep Learning Approach for Soil Moisture Prediction and Filling the Gaps in Between Soil Moisture Observations. *Frontiers in Artificial Intelligence*, 4, 636234.

19. Entekhabi, D., Yueh, S., O'Neill, P. E., Kellogg, K. H., Allen, A., Bindlish, R., ... & West, R. (2014). SMAP handbook—soil moisture active passive: Mapping soil moisture and freeze/thaw from space.
20. Galanaki, E., K. Lagouvardos, V. Kotroni, T. Giannaros and C. Giannaros. (2021). Implementation of WRF-Hydro at two drainage basins in the region of Attica, Greece, for operational flood forecasting. *Natural Hazards and Earth System Sciences*, 21(7), 1983-2000.
21. Gao, X., Zhao, X., Brocca, L., Pan, D., & Wu, P. (2018). Testing of observation operators designed to estimate profile soil moisture from surface measurements. *Hydrological Processes*, 33(4), 575-584.
22. Gochis, D.J., M. Barlage, R. Cabell, M. Casali, A. Dugger, K. FitzGerald, M. McAllister, J. McCreight, A. RafieeiNasab, L. Read, K. Sampson, D. Yates, Y. Zhang, “The WRF-Hydro® modeling system technical description version 5.1.1,” NCAR Technical Note, pp.107, 2020.
23. Gochis, D. J., Yu, W., & Yates, D., “The WRF-Hydro model technical description and user’s guide, version 1.0,” NCAR Technical Document. National Center for Atmospheric Research, Boulder, CO, USA, 2013.
24. Gruber, A., Dorigo, W. A., Crow, W., & Wagner, W. (2017). Triple Collocation-Based Merging of Satellite Soil Moisture Retrievals. *IEEE Transactions on Geoscience and Remote Sensing*, 55(12), 6780-6792.

25. Hogue, T. S., Bastidas, L. A., Gupta, H. V., & Sorooshian, S. (2006). Evaluating model performance and parameter behavior for varying levels of land surface model complexity. *Water resources research*, 42(8), W08430.
26. Holah, N., Baghdadi, N., Zribi, M., Bruand, A., & King, C. (2005). Potential of ASAR/ENVISAT for the characterization of soil surface parameters over bare agricultural fields. *Remote Sensing of Environment*, 96(1), 78-86.
27. Karthikeyan, L., Pan, M., Wanders, N., Kumar, D. N., & Wood, E. F. (2017). Four decades of microwave satellite soil moisture observations: Part 1. A review of retrieval algorithms. *Advances in Water Resources*, 109, 106-120.
28. Kerr, Y. H., Waldteufel, P., Richaume, P., Wigneron, J. P., Ferrazzoli, P., Mahmoodi, A., Al Bitar, A., Cabot, F., Gruhier, C., Juglea, S. E., Leroux, D., Mialon, A., & Delwart, S. (2012). The SMOS Soil Moisture Retrieval Algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1384-1403.
29. Kerr, Y. H., Waldteufel, P., Wigneron, J.-P., Delwart, S., Cabot, F., Boutin, J., Escorihuela, M.-J., Font, J., Reul, N., Gruhier, C., Juglea, S. E., Drinkwater, M. R., Hahne, A., Martín-Neira, M., & Mecklenburg, S. (2010). The SMOS Mission: New Tool for Monitoring Key Elements of the Global Water Cycle. *Proceedings of the IEEE*, 98(5), 666-687.

30. Lee, J., Park, S., Im, J., Yoo, C., & Seo, E. (2022). Improved soil moisture estimation: Synergistic use of satellite observations and land surface models over CONUS based on machine learning. *Journal of Hydrology*, 609, 127749.
31. Li, X., Wei, Y., & Li, F. (2021). Optimality of antecedent precipitation index and its application. *Journal of Hydrology*, 595, 126027.
32. Li, Z., Ren, X., Li, X., & Wang, L. (2004). Soil moisture measurement and retrieval using Envisat ASAR imagery. *2004 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 3539-3542.
33. Long, D., Bai, L., Yan, L., Zhang, C., Yang, W., Lei, H., Quan, J., Meng, X., & Shi, C. (2019). Generation of spatially complete and daily continuous surface soil moisture of high spatial resolution. *Remote Sensing of Environment*, 233, 111364.
34. Maity, S., Satyanarayana, A. N. V., Mandal, M., & Nayak, S. (2017). Performance evaluation of land surface models and cumulus convection schemes in the simulation of Indian summer monsoon using a regional climate model. *Atmospheric Research*, 197, 21-41.
35. Ming, W., Ji, X., Zhang, M., Li, Y., Liu, C., Wang, Y., & Li, J. (2022). A Hybrid Triple Collocation-Deep Learning Approach for Improving Soil Moisture Estimation from Satellite and Model-Based

- Data. *Remote Sensing*, 14(7), 1744.
36. Mo, T., Schmugge, T. J., & Jackson, T. J. (1984). Calculations of radar backscattering coefficient of vegetation-covered soils. *Remote Sensing of Environment*, 15(2), 119-133.
37. Nayak, H. P., Nayak, S., Maity, S., Patra, N., Singh, K. S., & Dutta, S. (2022). Sensitivity of Land Surface Processes and Its Variation during Contrasting Seasons over India. *Atmosphere*, 13(9), 1382.
38. Nayak, S., Mandal, M., & Maity, S. (2018). RegCM4 simulation with AVHRR land use data towards temperature and precipitation climatology over Indian region. *Atmospheric Research*, 214, 163-173.
39. Peng, J., & Loew, A. (2017). Recent Advances in Soil Moisture Estimation from Remote Sensing. *Water*, 9(7), 530.
40. Peng, J., Loew, A., Merlin, O., & Verhoest, N. E. C. (2017). A review of spatial downscaling of satellite remotely sensed soil moisture. *Reviews of Geophysics*, 55(2), 341-366.
41. Reichle, R.H., G. De Lannoy, R.D. Koster, W.T. Crow, J.S. Kimball, Q. Liu, and M. Bechtold. (2022). *SMAP L4 Global 3-hourly 9 km EASE-Grid Surface and Root Zone Soil Moisture Geophysical Data, Version 7*. Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center.
42. Roger, J. C., Vermote, E. F., & Ray, J. P. (2015). MODIS Surface

Reflectance User's Guide: Collection 6. MODIS Land Surface
Reflectance Science Computing Facility.

43. Rummeler, T., J. Arnault, D. Gochis and H. Kunstmann. (2019). Role of lateral terrestrial water flow on the regional water cycle in a complex terrain region: Investigation with a fully coupled model system. *Journal of Geophysical Research: Atmospheres*, 124(2), 507-529.
44. Sabaghy, S., Walker, J. P., Renzullo, L. J., & Jackson, T. J. (2018). Spatially enhanced passive microwave derived soil moisture: Capabilities and opportunities. *Remote Sensing of Environment*, 209, 551-580.
45. Scanlon, T., Pasik, A., Dorigo, W., de Jeu, R. A. M., Hahn, S., van der Schalie, R., Wagner, W., Kidd, R., Gruber, A., Moesinger, L., Preimesberger, W., van der Vliet, M., & Stradiotti, P. (2022). ESA Climate Change Initiative Plus - Soil Moisture Algorithm Theoretical Baseline Document (ATBD) Supporting Product Version 07.1.
46. Schmugge, T. J., Kustas, W. P., Ritchie, J. C., Jackson, T. J., & Rango, A. (2002). Remote sensing in hydrology. *Advances in Water Resources*, 25(8-12), 1367-1385.
47. Schoener, G., & Stone, M. C. (2020). Monitoring soil moisture at the catchment scale – A novel approach combining antecedent precipitation index and radar-derived rainfall data. *Journal of Hydrology*, 589, 125155.

48. Senanayake, I. P., Yeo, I. Y., Willgoose, G. R., & Hancock, G. R. (2021). Disaggregating satellite soil moisture products based on soil thermal inertia: A comparison of a downscaling model built at two spatial scales. *Journal of Hydrology*, 594, 125894.
49. Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., & Woo, W.-c. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
50. Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D. M., Wang, W., and Powers, J. G., “A description of the Advanced Research WRF version 3,” NCAR Technical note-475+ STR, 2008.
51. Snapir, B., Hobbs, S., & Waine, T. W. (2014). Roughness measurements over an agricultural soil surface with Structure from Motion. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 210-223.
52. Stoffelen, A. (1998). Toward the true near-surface wind speed: Error modeling and calibration using triple collocation. *Journal of Geophysical Research: Oceans*, 103(C4), 7755-7766.
53. Trier, S. B., Chen, F., & Manning, K. W. (2004). A study of convection initiation in a mesoscale model using high-resolution land surface initial conditions. *Monthly weather review*, 132(12), 2954-2976.

54. Ulaby, F. T., & Batlivala, P. P. (1976). Optimum radar parameters for mapping soil moisture. *IEEE Transactions on Geoscience Electronics*, 14(2), 81-93.
55. Van de Griend, A. A., & Wigneron, J. P. (2004). On the measurement of microwave vegetation properties: some guidelines for a protocol. *IEEE Transactions on Geoscience and Remote Sensing*, 42(10), 2277-2289.
56. Van der Schalie, R., Preimesberger, W., Pasik, A., Scanlon, T., & Kidd, R. (2022). ESA Climate Change Initiative Plus Soil Moisture Product User Guide (PUG) Supporting Product Version v07.1.
57. Walker, J. P., Houser, P. R., & Willgoose, G. R. (2004). Active microwave remote sensing for soil moisture measurement: a field evaluation using ERS-2. *Hydrological Processes*, 18(11), 1975-1997.
58. Wehbe, Y., M. Temimi, M. Weston, N. Chaouch, O. Branch, T. Schwitalla, V. Wulfmeyer, X. Zhan, J. Liu and A. Al Mandous. (2019). Analysis of an extreme weather event in a hyper-arid region using WRF-Hydro coupling, station, and satellite data. *Natural Hazards and Earth System Sciences*, 19(6), 1129-1149.
59. Xie, Q., Jia, L., Menenti, M., & Hu, G. (2022). Global soil moisture data fusion by Triple Collocation Analysis from 2011 to 2018. *Scientific Data*, 9(1), 687.
60. Xu, M., Yao, N., Yang, H., Xu, J., Hu, A., Gustavo Goncalves de

- Goncalves, L., & Liu, G. (2022). Downscaling SMAP soil moisture using a wide & deep learning method over the Continental United States. *Journal of Hydrology*, 609, 127784.
61. Xu, W., Zhang, Z., Long, Z., & Qin, Q. (2021). Downscaling SMAP Soil Moisture Products With Convolutional Neural Network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 4051-4062.
62. Xu, Z., Man, X., Duan, L., & Cai, T. (2022). Improved subsurface soil moisture prediction from surface soil moisture through the integration of the (de)coupling effect. *Journal of Hydrology*, 608, 127634.
63. Zhang, D., & Zhou, G. (2016). Estimation of Soil Moisture from Optical and Thermal Remote Sensing: A Review. *Sensors*, 16(8), 1308.
64. Zhang, N., Quiring, S. M., & Ford, T. W. (2021). Blending Noah, SMOS and In-Situ Soil Moisture Using Multiple Weighting and Sampling Schemes. *Journal of Hydrometeorology*, 22(7), 1835-1854.
65. Zhang, Y., & Ye, A. (2021). Machine learning for precipitation forecasts post-processing — Multi-model comparison and experimental investigation. *Journal of Hydrometeorology*, 22(11), 3065-3085.
66. Zhao, B., Dai, Q., Han, D., Dai, H., Mao, J., Zhuo, L., & Rong, G.

- (2019). Estimation of soil moisture using modified antecedent precipitation index with application in landslide predictions. *Landslides*, 16(12), 2381-2393.
67. Zhao, H., Di, L., Sun, Z., Yu, E., Zhang, C., & Lin, L. (2022). Validation and Calibration of HRLDAS Soil Moisture Products in Nebraska. *2022 10th International Conference on Agro-geoinformatics (Agro-Geoinformatics)*, 1-4.
68. Zhao, H., Li, J., Yuan, Q., Lin, L., Yue, L., & Xu, H. (2022). Downscaling of soil moisture products using deep learning: Comparison and analysis on Tibetan Plateau. *Journal of Hydrology*, 607, 127570.
69. Zhong, J.-Q., Lu, B., Wang, W., Huang, C.-C., & Yang, Y. (2020). Impact of Soil Moisture on Winter 2-m Temperature Forecasts in Northern China. *Journal of Hydrometeorology*, 21(4), 597-614.

附錄

附錄一、期初審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
業務單位(組、中心、小組)審查意見：		
一、	因不同土壤含水量產品資料之時空解析度並不一致，各類輔助環境因子之時空解析度也不盡相同，計畫中並無說明如何解決所使用資料時空解析度不一致之問題。	本研究會先利用內差方法將不同土壤含水量產品統一至相同空間解析度(25 公里)進行融合，而各類輔助環境因子亦會產製出兩種空間解析度(25 與 3 公里)分別於 ConvLSTM 訓練與降尺度階段使用。時間尺度方面會先以日尺度進行融合與空間降尺度，爾後再利用產品時間分佈相依性產出小時尺度產品。已於計畫內容稍作補充，另將於計畫報告書中詳述。
二、	此研究工項目標為產製解析度3公里之每小時土壤含水量資料，請補充說明與HRLDAS資料異同處為何？	本年度預期產製之土壤含水量資料(融合且降尺度)將結合「衛星」與「模式」兩種不同資料特性與其優勢，如衛星資料可迅速獲得大範圍且精確的表層土壤含水量推估，而模式資料可提供更精細的時空解析度與時序變化趨勢等，與僅為模式種類之 HRLDAS 資料有所不同。已於計畫內容稍作補充，另將於計畫報告書中詳述。
三、	此研究模式以3公里空間解析度作為分析網格，是否會因解析度不足，而對資料品質造成影響。	模式部分(WRF-Hydro)實際進行水理演算時之解析度可達 100 公尺(或更細，基於 DEM 解析度；詳見附檔第 3 節所述)。而最終土壤含水量產品為與衛

項次	審查意見	回覆辦理情形
		星資料進行融合，並且考量各類輔助環境因子之最適解析度，會將模式資料空間解析度提升至3公里，此乃受限於目前相關科學研究之進展。
四、	HRLDAS 及 WRF-Hydro 模式之產品均為公里解析度，所使用之 DEM 資料是否採 20DEM(開放資料)即已足夠？	目前開放資料(如 20 公尺 DEM、HydroSHEDS 等)的確已可作為初步建模測試用，亦為本研究初步規劃。未來若能取得更精細、準確之 DEM (如 HyDEM)，可再用於檢視更符合水理演算需求之 DEM 可否加強土壤含水量之模擬。
五、	如何驗證最後成果之精度及可用性？	如附檔所述，本研究會利用多方蒐集之測站資料進行成果準確性驗證，評估指標將包含相關係數、偏差值、均方根誤差及無偏差均方根誤差等。在準確度得以滿足的情況下，未來考量將成果鏈接於水文氣象模式、災害模式(如崩塌數值模式)及農業作業模式，以評估本研究產製之土壤含水量產品之可應用性。
六、	建議可使用降雨致災案例進行驗證與分析。	遵照辦理。將於計畫報告書中呈現於降雨致災案例時之驗證與分析。
二、有關計畫書格式及經費審查部分：		
一、	本計畫請以補助經費 675 仟元調整編列。	遵照辦理。
二、	本年度執行期限請修正為自 113 年 2 月 7 日至 113 年 12 月 31 日。(10.8 個月)。薪俸、保險、退休離職儲金、主持人費、兼任研究助理，請以計畫執行期	遵照辦理。

項次	審查意見	回覆辦理情形
	限 10.8 個月內編列。年終獎金亦配合計畫期程。	
有關計畫書格式及經費審查部分：		
一、	本年度執行期限請修正為自 113 年 2 月 7 日至 113 年 12 月 31 日。(10.9 個月)。薪俸、保險、退休離職儲金、主持人費、兼任研究助理，請以計畫執行期限 10.9 個月內編列。年終獎金亦配合計畫期程。	遵照辦理。
二、	請重新更正為 10.9 個月經費編列，造成不便，請見諒。	遵照辦理。
主計室審查意見：		
一、	薪俸請量化須列學歷、年資，保險請量化。	皆已修正。
二、	按日按件計資酬金請量化。	已修正。
三、	雜支請量化。	已修正。
四、	附表一請修正，須與預算明細表金額相符。	已修正。
五、	餘同減災監測組意見。	遵照辦理。

附錄二、期中審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一、	期中報告已針對解析度 0.05° 之兩降尺度衛星產品進行驗證、也將 HRLDAS 產品之 3 km 解析度生尺度至 0.05° 之 Upscaled HRLDAS 進行比較，可證明本研究基於 ConvLSTM 之降尺度模式對應土壤含水量於時間上之動態變化趨勢有掌握，已達期中階段進度。	感謝委員意見。
二、	CCI/SMAP 產品於預測值較低有高估，預測值高時則有低估現象，如圖 5-3、5-5 所示，請說明造成此現象之原因，並提出改善作法。	感謝委員意見，關於預測值高（低）估現象主要與以下兩點有關：1. 與本研究用以訓練 ConvLSTM 模式之損失函數為 Mean Square Error (MSE) 有關。為最小化模式預測值與 CCI/SMAP 產品實際值之 MSE，模型訓練可能傾向於「平均結果最佳」而犧牲較極端情況，因而導致結果預測值向中間(平均)值靠攏，出現對低值高估、高值低估的現象。2. 與原始產品資料樣本數、數值離散程度、品質等皆有關。而在本研究透過 TC 方法產製之 Merged SM 透過擷取各產品優勢、資料品質提升的情況下，已有效改善預測值高(低)估現象，如期末報告書 5-16 之圖 5-14 所示。
三、	CCI/SMAP 各環境因子之特徵貢獻度(圖 5-4、5-6)除 api 皆為最大貢獻因子外、其餘主要貢獻因子差異頗大，請探討其背後物理意義。	根據本研究對 CCI 與 SMAP 之分析成果（如期末報告書 5-5 之表 5-2），SMAP 產品與測站資料的 CC、Bias 及 RMSE 表現皆較 CCI 產品為優，顯示其更接近臺灣地區

		土壤含水量實際之時空變化；相較而言 CCI 產品的變化趨勢較為平滑，較無法反映臺灣土壤含水量實際變化。兩產品除 api 因子的貢獻度皆為最高外，其餘主要貢獻因子（如 SMAP 為 Band 4 和 Band 7，CCI 為 soil clay、ph 及 slope）差異頗大之原因歸納如後：Band 4（綠光）和 Band 7（短波紅外光）與土壤含水量較有直接關聯；綠光之反射率受植被狀態影響，當土壤含水量高時，植被生長旺盛，葉綠素含量高，反射更多綠光，反之亦然；而短波紅外光則對水分吸收非常敏感，濕潤土壤會吸收更多短波紅外光，使反射率降低，而乾燥土壤則相反。因此資料品質更佳且更能反映土壤含水量變化的 SMAP 產品，其 Band 4 與 Band 7 之貢獻度也較高。相對而言，CCI 產品由於與土壤含水量實際變化較不吻合，「隨機性」較高，且資料隨時間變異程度較低，使 Band 4 與 Band 7 此種「動態」因子之貢獻度下降，而 soil clay、ph 及 slope 等不隨時間變化之「靜態、分類型」因子之貢獻度則有所提高。而以上有關各產品之因子貢獻度差異探討已於期末報告書 5-11 至 5-16 內文部分補充。
四、	是否考量到其他外部環境因素(如土地利用變化、氣候變遷等)對土壤含水量之潛在影響?	感謝委員意見。首先關於土地利用變化方面，目前本研究已陸續向內政部國土測繪中心申購最新 2023 年之土地利用分類資料(如期末報告書 3-27 之圖 3-14)，預期未來可將目前使用(2015 年)與最新之土地利用資料作為深度學習與

		水文模式之輸入，以探討土地利用變化對土壤含水量資料之影響程度。而在氣候變遷的考量上，本計畫本期主要以衛星觀測資料為基礎，聚焦於現今氣候條件下的土壤含水量變化；而未來將持續對 WRF-Hydro 模式調校，並將 TCCIP 針對臺灣地區產製之 AR6 暖化情境與氣候統計降尺度資料鏈接於 WRF-Hydro，透過把未來各種不同之溫室氣體排放、全球暖化情境推估資料驅動 WRF-Hydro，模擬未來土壤含水量在不同情境下可能的趨勢變化，進而得以與現今狀況進行比較，評估氣候變遷之潛在影響。
五、	結論部分，建議提出未來的研究方向和改進建議，例如如何進一步提高模型的準確性？	感謝委員意見，遵照辦理。
六、	4-7 的對 W_x 和 W_z 偏微分為零部分，為何有 W_1 和 W_2 兩個代數出現？	感謝委員指正，此處撰寫錯誤已於期末報告中修正。
七、	4-13 倒數三行文字部分敘述問題？請修正	感謝委員指正，此處撰寫錯誤已於期末報告中修正。
八、	報告書封面及內文等請依本署最新範本格式撰寫，相關範本檔案請至本署電子圖書管理中心下載。 (https://elibrary.ardswc.gov.tw/)	遵照辦理。

附錄三、期末審查會議紀錄暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一、	不同模式所產製的解析度有無差異？解析度可達多少？未來能透過何種方式提高解析度？	由氣象署 HRLDAS 模式產製資料之解析度為 3 公里（如報告書 3-6 頁所述），而本計畫利用之 WRF-Hydro 可依不同模式設定調整產製資料之解析度，目前設定為 2 公里（如報告書 4-21 頁）。而產製資料之解析度會與模式所使用之數值高程（DEM）、土壤質地等資料解析度和精確度直接相關，因此，欲提高產製資料之解析度還需先確認模式所使用相關資料之精確度方可確保產製出之高解析度土壤含水量具有合理、準確性。本計畫規劃於下一期利用 WRF-Hydro 進一步將產製資料之解析度提高至「2 公里以下」。
二、	ConvLSTM 學習的 label 為現地測量之時序土壤濕度嗎？土壤濕度的對應深度為何？	ConvLSTM 於訓練階段之輸入、輸出分別為於原始解析度之各環境因子 vs. 各土壤含水量產品資料（如報告書 4-10 頁與圖 4-4），後者即為學習的 label；而在模型訓練完畢後可輸入高解析度之各環境因子以達到土壤含水量降尺度預測。目前模型對應深度為地下 5 公分之表層土壤含水量，惟此方法論並不僅限於表層土壤。
三、	土壤含水計量測範圍不大，如何增加精度？	感謝委員意見。土壤含水計量測範圍的確有其限制，而量測精度也的確會影響本研究於計算驗證評估指標結果。然而如何增加土壤含水計量範圍與精度並非本計畫

		本期所專注之面向；未來或可再利用新興儀器方法於已建立測站位址瞭解量測範圍與精度以及其與衛星和模式土壤含水量產品資料範圍之差異。
四、	建議加強說明後續應用與衛星資料和土壤含水量之間的關係。	感謝委員意見。本研究所使用之衛星、模式及融合且降尺度之土壤含水量資料未來除可應用於農業灌溉、局部坡地崩塌等議題外，亦可用於集水區水源涵養能力評估、估算土壤雨量指數等更具體之水土保持相關分析。以上此點已補充於第六章第二節處。此外，本計畫預計於第二期完整呈現應用層面之成果。
五、	是否有考量不同表面材質的影響？	本研究利用 ConvLSTM 進行土壤含水量降尺度所使用之各種土壤含水量相關環境因子有包含「土地利用」（第三章第三節），即有反映不同表面材質的影響。
六、	目前的模擬成果較無法反應上安雨量站的急降雨資料，可能的原因為何？	感謝委員意見。由圖 5-5 確實指出衛星（CCI 和 SMAP）與模式（HRLDAS）及融合之產品於上安測站無法反應急降雨造成觀測土壤含水量急升之現象，導致明顯偏差的結果。然本研究後續使用之 WRF-Hydro 經參數初步調校後已能於上安測站反映其土壤含水量之變化（如圖 5-25），因此可推測 HRLDAS 之參數可能還未調校至最佳而導致模擬有所偏差。