



國立中央大學

大氣科學學系

碩士論文

使用深度學習於複雜地形雙偏極化雷達定量
降水估計之垂直修正

Radar Quantitative Precipitation Estimation Over Complex
Terrain using a Deep Learning Approach

研究生：葉祐銓

指導教授：張偉裕 博士

中華民國一一五年六月

國立中央大學圖書館學位論文授權書

National Central University Library Authorization for Thesis/ Dissertation

填單日期(Application Date): 115 / 08 / 14

The latest version since Feb. 2026

授權人姓名 Applicant Name	葉祐銘	學號 Student Number	113621002
系所名稱 Departments	大氣科學系暨大氣物理研究所	學位類別 Graduate Degree	碩士
論文名稱 Thesis/Dissertation Title	使用深度學習於複雜地形變偏極化雷達定量降水估計之垂直修正		

學位論文網路公開授權

Authorization for Internet Access of Thesis/ Dissertation

我同意於 115 年 8 月 14 日起，將本學位論文之全文電子檔公開於網路。

I agree to make the full-text electronic version of my thesis/dissertation publicly available online on 2026 (year) 8 (month) 14 (day).

1. 依著作權法規定，授權國立中央大學、台灣聯合大學系統與國家圖書館，無償、不限期間與次數重製本論文，並得以非營利用途之利用，其包括得將本論文之電子檔收錄於數位資料庫，並透過網際網路於上列日期公開，以供為非營利目的之檢索、閱覽、下載及/或列印。
2. 本授權書所定授權，均為非專屬授權之約定，本人仍得自行或授權任何第三人利用本著作。
1. In accordance with the Copyright Act, I hereby authorize National Central University, the University System of Taiwan, and the National Central Library to reproduce my thesis/dissertation free of charge and without limitation as to duration or frequency, for non-commercial purposes. This includes incorporating the electronic version of my thesis/dissertation into digital databases and making it publicly accessible via the Internet on the selected date indicated above, for non-commercial searching, viewing, downloading, and/or printing.
2. The rights granted under this agreement are non-exclusive, and I retain the right to use the work myself or to authorize any third party to use it.

存放於本校之學位論文紙本延後公開申請 (紙本立即公開免填此欄)

Application for Delayed Disclosure of Hard Copy Thesis/Dissertation

本人撰寫學位論文紙本，將延後至____年____月____日公開。

原因：☐ 涉及機密。 ☐ 涉及專利申請。 ☐ 依法不得提供

The print version of my thesis/dissertation will be released on ____ (year) ____ (month) ____ (day).

Reason: ☐ Involves confidential information☐ Involves patent matters☐ Not permitted to be made available by law

※繳交教務處註冊組之紙本論文(送繳國家圖書館)若不立即公開，請加填「國家圖書館學位論文延後公開申請書」

※Please note that you should submit a printed thesis/dissertation to the National Central Library (NCL) through the NCU Academic Affairs Office. If you wish to delay its public release at the NCL, please also complete and submit the "Application for Embargo of Thesis/Dissertation."

研究生簽名：葉祐銘

Signature of the Applicant

指導教授簽名：張偉銘

Signature of the Advisor

國立中央大學碩士班研究生
論文指導教授推薦書



大氣科學學系大氣物理碩士班 學系/研究所 葉祐銓 研究生
所提之論文 使用深度學習於複雜地形雙偏極化雷達定量降水估
計之垂直修正 Radar Quantitative Precipitation Estimation Over
Complex Terrain using a Deep Learning Approach

係由本人指導撰述，同意提付審查。

指導教授 張傳銘 (簽章)
115 年 06 月 26 日



國立中央大學碩士班研究生
論文口試委員審定書

大氣科學學系大氣物理碩士班 學系/研究所 葉祐銓 研究生
所提之論文 使用深度學習於複雜地形雙偏極化雷達定量降水估
計之垂直修正 Radar Quantitative Precipitation Estimation Over
Complex Terrain using a Deep Learning Approach

經由委員會審議，認定符合碩士資格標準。

學位考試委員會召集人

委

員

林品芳

廖宇慶

陳如瑜

張偉銘

中 華 民 國 115 年 7 月 27 日



摘要

傳統的雙偏極化雷達定量降水估計(Radar Quantitative Precipitation Estimation, RQPE)通常依賴基於區域統計的雨滴粒徑分布(Raindrop Size Distribution, RSD)所定義的多項式降雨估計式。然而因為雨滴粒徑分布(RSD)在時間與空間上的變化，使得這些多項式為高度非線性。此外，在複雜地形上，雷達定量降雨(RQPE)會受到部分波束遮擋以及因波束本身與地表的高度差，出現雲微物理變化造成估計降雨的誤差，因此對雷達定量降雨(RQPE)在垂直方向上進行修正對於真實估計地表降水來說至關重要。其中為解決雷達定量降水估計(RQPE)固有的複雜性與非線性問題，本研究使用深度學習(Deep Learning, DL)方法對雙偏極化雷達參數測量值(DPMs, i.e., Z_{HH} , Z_{DR} , K_{DP})與降雨率(R)之間的關係建立模型，以取代傳統的冪律多項式。另外為了進一步解決地形帶來的挑戰，本研究開發垂直修正模型(TopoCorr-Net)結合多層的雙偏參數空間分布透過卷積神經擷取降水的垂直變化趨勢，得到降雨估計在高低層之間的變量。從梅雨個案的應用結果分析顯示，基於雷達觀測資料訓練的垂直修正模型(TopoCorr-Net)能夠有效捕捉估計降雨的垂直變化，並提升地表附近降雨率的估計精度。



Abstract

Traditional radar quantitative precipitation estimation (RQPE) based on dual-polarization radar usually relies on power-law rainfall relations derived from regional raindrop size distribution (RSD) statistics. However, because RSD varies with time and location, these relations are highly nonlinear. In complex terrain, RQPE is further affected by partial beam blockage and vertical differences between radar observations and surface rainfall, leading to additional estimation errors. Therefore, correcting the vertical structure of rainfall is important for improving surface rainfall estimation. To address these issues, this study applies a deep learning (DL) approach to model the relationships among dual-polarization radar measurements, including reflectivity (ZH), differential reflectivity (ZDR), specific differential phase (KDP), and rainfall rate (R), thereby replacing traditional power-law equations.

In addition, a vertical correction model, TopoCorr-Net, is developed to reduce terrain-related errors. The model combines multi-level radar parameter fields and utilizes convolutional neural networks to learn the vertical variation of precipitation and estimate rainfall differences between observation heights. Results from Mei-Yu rainfall events show that TopoCorr-Net can effectively capture vertical variations in rainfall and improve rainfall estimates near the surface. These results demonstrate the potential of combining deep learning and vertical correction techniques to enhance RQPE performance in complex terrain regions.




誌謝

暖暮蟬鳴，這才意識到炎熱炙夏再一次的走到我身旁，偶然瞥見辦公桌上螢幕的日期，頓感碩士生活倏忽即逝，兩年的時間有研究上的頻頻卡關卻又在某個瞬間找到解方，有每一個午後與實驗室成員們嘻笑閒聊的吵鬧時光，也有每一次出觀測時感受逐年增加的排班工時與彷彿出任務般的堅守自己的輪班崗位，雷達實驗室從來不是一個單純家與辦公室兩點一線的空白時光。想到兩年前，研究所考試放榜後，確定錄取這個熟悉的大氣科學系僅有一半的喜悅，另一半是對研究方向的迷茫無措，非常感謝我的指導教授張偉裕老師就算我在大學階段並沒有修任何專題課，實作能力接近零的情況下，仍然願意收我進入實驗室，並且耐心地坐下來與我初步探尋研究方向，這兩年的時間裡老師總是能階段性的給我新的研究進展目標，讓我的研究成果從些許的雛型一路到接近完整，老師總說：「適當的壓力可以讓我們變成鑽石。」雖然身邊的同學告訴我們鑽石完全可以人工製造，但不管是如何變成鑽石的，我們都可以發出耀眼的光芒。此外，也感謝廖宇慶老師與鍾高陞老師在無數個實驗室會議給予我們的建議與如何做個好的簡報。也非常謝謝我的口試委員廖宇慶老師、林品芳博士、陳如瑜老師給予我非常多寶貴的建議與改進方向，得以讓這個研究更加豐富。

兩年的時光在雷達實驗室受到許多人的幫助與鼓勵，感謝鎧蒂與小那學姐，幫我們處理許多行政事務，讓我們不管是出差還是實驗都沒有後顧之憂。也感謝 Haidy 與如瑜學姐在不同時期給予我在雷達資料處理與 QPE 細節上的協助與建議。感謝實驗室的助理們的照顧，特別是大柯學姐、伯謙學長與詠霖學長在每次實驗都能把人員與流程安排到位，以及昭昭署長兩次研討會在我們不知道吃甚麼的時候，替我們出謀劃策。感謝孟杰、覃哥、皓宇學長偶爾會一邊忙碌手頭的工作一邊聆聽我對研究的抱怨。

感謝同屆的同學們與我一起在大物所成長，大家幾乎都是在這個食物荒漠中央大學待滿六年的老人了，尤其是同為雷達實驗室的同學們 May、芳、文瑞、偷米、語萱、翊翊、采琳，碩二搬上 825 後總是要三不五時跑到其中一間稽查有沒有人偷偷摸魚，為




了怕有人偷卷而偶爾干擾對方，或是一群人擠在同一間分享八卦。而澎湖與福岡的研討會除了幫彼此紀錄海報或是上台報告的專業瞬間，研討會外的出遊也是會讓我偶爾想回憶起的歡樂時光。謝謝你們，在研究生活的路上有你們的陪伴，我感到非常幸運也相當珍惜這段時光。

除此之外，感謝最辛苦的媽媽和我所有的家人們肯定我攻讀碩士，雖然偶爾還是會問我是不是要當氣象主播，但每當我研究不順時回家一趟，感受家裡最溫暖的氣氛以及超大分貝的講話聊天，很吵鬧很溫暖，也讓我意識到我永遠有最好的家人們消化任何焦慮與不安。最後，謝謝真的第一線面對研究的我自己，這兩年真切地了解到達克效應(D-K Effect)，從剛開始規畫研究階段爬至愚昧山峰，隨後多巴胺消逝墜入絕望之谷也還是不斷調適心態與維持健康的自己，不管遇到什麼事一路撐到口試結束。就算真的變成鑽石也不能停下，還需要經歷打磨拋光，我想，從碩士生活學到的一切會變成養分使我持續往前。




目錄

摘要.....	i
Abstract	ii
誌謝.....	iii
目錄.....	v
表目錄.....	vii
圖目錄.....	viii
1 第一章 緒論.....	1
1.1 前言.....	1
1.2 文獻回顧.....	1
1.3 研究方向.....	4
2 第二章 資料與方法.....	5
2.1 雷達資料來源與處理.....	5
2.1.1 模擬雷達參數.....	5
2.1.2 五分山 S 波段雷達.....	5
2.1.3 雷達資料處理.....	6
2.2 多項式擬合.....	8
2.2.1 QPE 關係式係數集	8
2.2.2 複合型降雨估計式.....	9
2.3 深度神經網路.....	10
2.3.1 模型結構.....	10
2.3.2 訓練資料前處理.....	12
2.3.3 資料切分	13
2.3.4 模擬誤差測試.....	14
2.4 垂直修正模型.....	15
2.4.1 模型結構.....	16
2.4.2 模型預處理.....	19
3 第三章 深度學習定量降雨估計結果.....	21
3.1 個案概述.....	21
3.2 不同仰角估計效果.....	21
3.2.1 仰角分析：20170602 個案	22
3.2.2 仰角分析：20190517、20190520 個案	23



3.3 小時與累積雨量圖分析	24
3.3.1 小時累積雨量	24
3.3.2 長時間累積雨量	26
3.4 誤差空間分布	29
4 第四章 垂直修正模型結果	30
4.1 降雨修正後比較	30
4.2 空間誤差分布	32
4.3 多仰角分析	34
4.3.1 不同高度差修正	34
4.3.2 最低有效估計	37
4.4 真實地形	38
4.4.1 高仰角差修正核心	39
4.4.2 低仰角差修正核心	40
5 第五章 結論與未來展望	42
5.1 結論	42
5.2 未來展望	43
6 參考文獻	45
附表	48
附圖	52
附錄	108
附錄 A1. MLP 深度學習降雨估計模型	108
附錄 A2. TopoCorr-Net 降雨估計垂直修正模型	110




表目錄

表 2.1 模擬觀測誤差各參數誤差範圍。	48
表 2.2 PLF 與 MLP 兩方法在各參數組合為輸入，分別測試由 n0 至 n3 等級模擬觀測誤差之方均根誤差(RMSE)評估指之。	48
表 4.1 多仰角降雨估計垂直修正，個案 20170602。	49
表 4.2 多仰角降雨估計垂直修正，個案 20190517。	49
表 4.3 多仰角降雨估計垂直修正，個案 20190520。	50
表 4.4 多仰角降雨估計垂直修正至真實地形，個案 20170602。	50
表 4.5 多仰角降雨估計垂直修正至真實地形，個案 20190517。	51
表 4.6 多仰角降雨估計垂直修正至真實地形，個案 20190520。	51
表 A1.1 MLP 模型層數結構、激活函數與防過擬合機制。	108
表 A1.2 MLP 降雨估計模型超參數設定。	109
表 A2.1 垂直修正模型特徵提取結構與尺寸。	110
表 A2.2 垂直修正模型迴歸區塊全連接層。	110
表 A2.3 垂直修正模型超參數設定。	111




圖目錄


圖 2.1 誤差容忍度測試，分別測試 n0(無模擬誤差)至 n3(1.5STD)誤差等級，輸入參數分別為 Z ， K_{DP} ， Z ， Z_{DR} ， K_{DP} ， Z_{DR} ， Z ， Z_{DR} ， K_{DP} 。	52
圖 3.1 使用 PLF 以及 MLP 方法降雨估計於 20170602 梅雨個案與 Rain Gauge 觀測比較之(a)0.5°，(b)1.5°及(c)2.4°散佈圖。	53
圖 3.2 使用 PLF 以及 MLP 方法降雨估計於 20190517 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°散佈圖。	54
圖 3.3 使用 PLF 以及 MLP 方法降雨估計於 20190520 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°散佈圖。	56
圖 3.4 個案 20170602 之1.5°仰角一小時累積雨量分布圖，分別使用 PLF 方法與 MLP 方法於(a)060120，(b)060121，(c)060203 及(d)060204 UTC。	58
圖 3.5 個案 20190517 與 20190520 之1.3°仰角一小時累積雨量分布圖，分別使用 PLF 方法與 MLP 方法於(a)2019051705，(b)2019051706，(c)2019052002 及(d)2019052003 UTC。	59
圖 3.6 個案 20170602 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)1.5°及(c)2.4°。	61
圖 3.7 個案 20190517 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。	64
圖 3.8 個案 20190520 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。	69
圖 3.9 北臺灣地面自動雨量站位置於 20170602 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)1.5°及(c)2.4°。	74



- 圖 3.10 北臺灣地面自動雨量站位置於 20190517 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及 (e)2.4°。.....76
- 圖 3.11 北臺灣地面自動雨量站位置於 20190520 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及 (e)2.4°。.....79
- 圖 4.1 經過移除 PBB 影響範圍後五分山雷達之 100 公里觀測半徑內最低有效資料高度，包含0.5°、0.9°、1.3°、1.8°以及2.4°觀測仰角。.....82
- 圖 4.2 五分山雷達觀測方位角216°之最低仰角0.5°有效觀測距離(無 PBB 影響)，其中紅色實線為有效觀測，灰色虛線為受遮擋波束。.....82
- 圖 4.3 方位角216°之波束傳遞與地形垂直剖面圖，(a)為 2019 掃描策略調整前之2.4°以下仰角波束傳遞，(b) 為 2019 掃描策略調整後之2.4°以下仰角波束傳遞。.....83
- 圖 4.4 20170602 個案在 060202UTC 至 060205UTC 分別使用(a)PLF、(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.5°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。.....84
- 圖 4.5 20170602 個案三方法降雨估計散佈圖，(a)2.4°之 PLF，(b)2.4°之 MLP 及(c)經過垂直修正(2.4°修正至 1.5°)。.....86
- 圖 4.6 20190517 個案在 051705UTC 至 051706UTC 分別使用(a)PLF，(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.3°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。.....87
- 圖 4.7 20190517 個案三方法降雨估計散佈圖，(a)2.4°之 PLF，(b)2.4°之 MLP 及(c)經過垂直修正(2.4°修正至 1.3°)。.....88



- 圖 4.8 20190520 個案在 051705UTC 至 051706UTC 分別使用(a)PLF，(b)MLP 以及(c)經過垂直修正(2.4° 修正至 1.3°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。.....89
- 圖 4.9 20190520 個案三方法降雨估計散佈圖，(a) 2.4° 之 PLF，(b) 2.4° 之 MLP 及(c)經過垂直修正(2.4° 修正至 1.3°)。.....91
- 圖 4.10 比較 20170602 個案 2.4° 仰角修正前後之 RRMSE(左上)、NMB(左下)、大間距累積雨量(右上)、小間距累積雨量(右下)。(a)為修正前 MLP，(b)經過垂直修正(2.4° 修正至 1.5°)。.....92
- 圖 4.11 比較 20190517 個案 2.4° 仰角修正前後之 RRMSE(左上)、NMB(左下)、大間距累積雨量(右上)、小間距累積雨量(右下)。(a)為修正前 MLP，(b)經過垂直修正(2.4° 修正至 1.3°)。.....93
- 圖 4.12 比較 20190520 個案 2.4° 仰角修正前後之 RRMSE(左上)、NMB(左下)、大間距累積雨量(右上)、小間距累積雨量(右下)。(a)為修正前 MLP，(b)經過垂直修正(2.4° 修正至 1.3°)。.....94
- 圖 4.13 個案 20170602 估計降雨散佈圖，(a)為欲修正之目標仰角 1.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.5°)(右)，(b)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。.....95
- 圖 4.14 個案 20190517 估計降雨散佈圖，(a)為欲修正之目標仰角 1.8° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.8°)(右)，(b)為欲修正之目標仰角 1.3° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.3°)(右)，(c)為欲修正之目標仰角 0.9° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.9°)(右)，(d)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。.....96



- 圖 4.15 個案 20190520 估計降雨散佈圖，(a)為欲修正之目標仰角 1.8° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.8°)(右)，(b)為欲修正之目標仰角 1.3° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.3°)(右)，(c)為欲修正之目標仰角 0.9° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.9°)(右)，(d)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)°.....98
- 圖 4.16 個案 20170602 最低有效降雨估計事件累積雨量。左為垂直修正前之 MLP 方法，右為垂直修正後。.....100
- 圖 4.17 個案 20170602 最低有效降雨估計之修正前後小時降雨強度評估指標，上為 RRMSE，下為 NMB°.....100
- 圖 4.18 個案 20190517 最低有效降雨估計事件累積雨量。左為垂直修正前之 MLP 方法，右為垂直修正後。.....101
- 圖 4.19 個案 20190517 最低有效降雨估計之修正前後小時降雨強度評估指標，上為 RRMSE，下為 NMB°.....101
- 圖 4.20 個案 20190520 最低有效降雨估計事件累積雨量。左為垂直修正前之 MLP 方法，右為垂直修正後。.....102
- 圖 4.21 個案 20190520 最低有效降雨估計之修正前後小時降雨強度評估指標，上為 RRMSE，下為 NMB°.....102
- 圖 4.22 由 20170602 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及(右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.5° 修正至地表，(c)為 0.5° 修正至地表。.....103
- 圖 4.23 由 20190517 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及(右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.8° 修正至地表，(c)為 1.3°



修正至地表，(d)為 0.9° 修正至地表，(e)為 0.5° 修正至地表。.....	104
圖 4.24 由 20190520 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及 (右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.8° 修正至地表，(c)為 1.3° 修正至地表，(d)為 0.9° 修正至地表，(e)為 0.5° 修正至地表。.....	106
圖 A1.1 深度學習降雨估計模型 MLP 結構示意圖。.....	109
圖 A2.1 降雨垂直修正模型 TopoCorr-Net 模型結構示意圖。.....	111



第一章 緒論


1.1 前言

降水對於整個生態、文明發展、城市設計、人文社會具有舉足輕重的影響力，然而致災性的強降雨會引起洪水與土石流等天災，尤其是在人口稠密的都市地區，降水造成的洪流更是容易造成人類生命以及財產的巨大損失。

北臺灣地區山地與丘陵地形廣布，地形起伏複雜，天氣系統容易與地形交互作用，使得降水型態在不同季節與天氣條件下呈現高度變化性。例如在夏季旺盛對流的影響下，水氣在短時間內因強烈的上升運動與凝結過程迅速發展成對流胞，其形成與增強往往僅需數十分鐘(Markowski, P., & Richardson, Y. 2010)。此類快速演變的降水系統，使得僅依賴地面雨量觀測難以全面掌握降水的空間結構與演變過程。使用氣象雷達可以更精準地捕捉降雨過程中水滴在空間上的變化，雷達的高時空解析度特性可以輔助缺乏觀測資料的地區，掌握動態的天氣資訊。此外在近年台灣的雷達觀測網大部分已完成由傳統單極化雷達升級至雙偏極化雷達，其中雙偏極化雷達更是能直接觀測到的差異反射率(Differential reflectivity, Z_{DR})使得觀測內容更為豐富，對於降水強度以及雨滴粒徑變化也更有把握。另一方面，歷年針對北臺灣使用雷達進行定量降水估計(Radar Quantitative Precipitation Estimation, RQPE)由於前人們的不斷發展，雷達資料品質處理方面極大的完善雜訊的處理、系統性誤差移除、能量衰減的修正等(紀 2005；Loh et al. (2022))，以及擬合與校驗降雨估計式所需的雨滴粒徑分布(Raindrop Size Distribution, RSD)資料反演(Chang et al. 2009；盧 2018)，接著後續在雷達定量降水估計的應用上(周 2015；陳 2016)很大程度的降低誤差。

1.2 文獻回顧


氣象雷達與地面雨量計是觀測降雨事件最直接的兩項觀測儀器。氣象雷達負責提供高空間與時間解析度之大面積連續觀測資料(Doviak and Zrníc, 1993)，傳統雷達 QPE 多



以雷達反射率因子(Reflectivity, Z)與降雨率(Rain rate, R)之經驗幂律式關係為基礎。然而此關係式本質上依賴雨滴粒徑分布(Raindrop Size Distribution, RSD)之統計特性，本身會受到季節環境與降雨微物理過程影響，其在對流降雨與層狀降雨之間，雨滴數量濃度與粒徑分布差異顯著，即使具有相同反射率，也可能對應不同降雨率(Bringi and Chandrasekar, 2001)。不過隨著雙偏極化雷達(dual-polarimetric radar)技術發展，雷達定量降水估計開始納入更多雙偏極化參數，例如差異反射率(Z_{DR})、比差異相位差(K_{DP})與相關係數(RH)等，以獲取降水粒子之形狀、大小、液態含水量與相態資訊(Ryzhkov and Zrníc, 1995)。其中， Z_{DR} 能反映雨滴扁平程度與相對粒徑大小，而 K_{DP} 則與液態水含量及強降雨具有高度相關性，因此多參數降雨估計式如 $R(Z, Z_{DR})$ 與 $R(K_{DP}, Z_{DR})$ 被廣泛應用於提升QPE 準確度(Bringi and Chandrasekar, 2001；Ryzhkov et al., 2005)。

儘管雙偏極化參數能提供更多降雨微物理資訊，但相關降雨估計式本質上仍建立於RSD 統計特性與經驗迴歸關係。許多研究指出，RSD 具有顯著之時間與空間變異性，因此利用特定地區或特定降雨事件建立之降雨估計式，往往僅適用於相近氣候區域與特定降雨型態(Tokay and Short, 1996；Cao et al., 2008)。此外， K_{DP} 雖於強降雨事件中具良好估計能力，但於弱降雨情況下容易受到相位擾動與觀測雜訊影響，導致估計結果不穩定(Ryzhkov et al., 2005)。另一方面，傳統雷達降雨估計式多採用固定係數形式描述雷達參數與降雨率之間的關係。然而，實際降雨微物理過程具有高度非線性特徵，包含雨滴碰撞合併、蒸發、融化與粒徑演變等複雜過程，使雷達參數與降雨率之間單純固定型態之幂次關係更難以掌握以及描述上述微物理過程。因此，固定係數之經驗式可能無法有效反映不同降雨系統中雷達特徵隨時間與空間之變化趨勢，進而限制其於複雜降雨環境下之估計能力。

另一方面，在複雜地形影響下，雷達定量降水估計常常面臨多種觀測限制與誤差來源。其中地形遮蔽為影響雷達觀測品質的重要因素之一，當雷達波束傳播路徑受到山脈阻擋時容易產生部分波束遮擋(Partial Beam Blockage, PBB)甚至完全遮蔽的情形，導致雷達接收能量減弱，使觀測之雷達反射率與雙偏參數產生低估或缺值情形(Borga et al.,



2002)。在臺灣複雜地形環境下，實務上常需使用較高仰角之雷達資料以避開地形遮蔽區域。然而，當使用較高仰角資料進行降雨估計時，雷達波束高度亦會隨距離快速增加，使雷達實際觀測位置偏離近地面降雨層。由於降水系統於垂直方向上本身具有顯著微物理變化，導致不同高度間之雷達參數與降雨率可能存在系統性差異(Vignal et al., 2000；Fabry, 2015)。因此，高仰角 QPE 結果往往更接近高空降水特徵，而非實際地面降雨情況，容易產生系統性誤差與垂直結構誤差(Chang et al. 2016)。

由於深度學習(Deep Learning, DL)技術快速發展，資料驅動(Data-driven)方法逐漸被應用於中大尺度的氣候或天氣系統領域。深度學習模型具備優秀的非線性映射關係(Nonlinear fitting capability)，能夠自動學習輸入資料與預測目標之間複雜的非線性關係，且不需事先假設特定函數形式。此外，深度學習模型亦具備特徵提取(feature extracting)能力，特別是卷積神經網路(Convolutional Neural Network, CNN)可從影像或空間分布資料中學習局部結構與空間特徵，因此已廣泛應用於圖像辨識(image recognition)、影像分類(image classification)與非線性回歸等領域(LeCun et al. 2015)。

近年來一些研究將深度學習實際應用到雷達定量降水估計，例如利用深度學習進行強降雨事件 QPE(Zhang et al., 2021)，結果顯示深度學習模型於強降雨事件中具有較佳的估計能力；Huangfu et al. (2023)則進一步利用多組雙偏極化雷達建立深度學習 QPE 模型，改善傳統單一 Z-R 關係式於不同降雨型態下之限制。亦有使用最低兩層仰角的雙偏極化雷達參數資料，配合高解析度之地面雨量計網格，使用卷積神經網路(CNN)模型大幅改善佛羅里達強降雨事件在使用多項式降雨估計式出現的低估情形(Li et al. 2023)；另外，Li et al. (2024)亦指出隨著雷達觀測距離增加，雷達波束寬度放大會導致遠距離區域之空間解析度下降，同時高仰角觀測亦會使雷達量測位置逐漸偏離地面降雨層，進而增加降雨估計誤差。為改善上述問題，該研究提出之 StarNet 深度學習架構，利用多層仰角之三維雙偏極化雷達資料作為輸入，並加入真實物理高度資訊與時間參數。該研究結果顯示，多仰角雷達特徵可有效改善遠距離區域降雨事件之降雨估計能力，並降低傳統單一仰角雷達定量降水估計因垂直降水變化所造成之誤差。



1.3 研究方向

由於雷達觀測資料與地表降雨率之間的映射關係本質上具有高度非線性，且存在明顯的空間與時間尺度差異，傳統以固定冪律形式建立之雷達降雨估計方法在不同降雨型態下往往難以維持穩定表現。相較之下，深度學習方法無須事先假設特定的物理冪律關係，能透過大量觀測資料自動學習雷達參數與地表降雨率之間的隱含映射關係，並有效捕捉不同降雨強度與降雨結構下的非線性特徵，從而提升降雨估計之準確度與穩定性(Li et al. 2023)。

此外，深度學習的方法不需要額外透過地區性雨滴粒徑分布資料校驗模型，可降低因 RSD 資料點空間分布過低導致降水冪律式在物理意義上無法代表雷達觀測範圍內的所有地區，並進一步提升模型於強降雨事件的估計準確性。因此，本研究將以深度學習架構為基礎，結合北臺灣 S 波段雙偏極化雷達觀測資料，開發一套適用於區域尺度的雷達定量降水估計方法。在完成基於深度學習之定量降水估計模型建立後，本研究進一步利用不同仰角之雙偏極化雷達資料進行降雨估計，產生多層仰角之估計降雨率場設計垂直修正模型(Vertical Correction Model)，使模型學習高層至低層之雷達特徵變化所對應的降雨修正量，考慮複雜地形下的波束遮擋問題，改進使用高仰角資料的系統性誤差，期望能改善傳統冪律關係式於實務應用上的限制。



第二章 資料與方法

本篇研究前半部分為使模型學習降雨率與雙偏極化雷達參數之間的非線性關係，藉由雨滴譜儀長期統計資料反演相關偏極化雷達參數。由於此雷達參數係透過演算法模擬產生，因此降雨率與雷達參數之間具有高度相關性，且資料中不包含觀測誤差與系統性誤差。

2.1 雷達資料來源與處理


2.1.1 模擬雷達參數

為提供深度學習模型之大量訓練資料，尋找雙偏極化雷達參數與降雨率的非線性關係，本研究使用之地面觀測資料包含設置於國立中央大學之 1 分鐘解析度撞擊式雨滴譜儀(Joss-Waldvogel Disdrometer, JWD)，並統計分析 2005 年至 2015 年共計十年之降雨觀測紀錄。

為將雨滴譜儀所量測之雨滴粒徑分布資料轉換為對應雷達觀測雙偏參數，本研究採用 T-matrix 電磁散射理論(Waterman, 1971)進行雷達參數數值模擬。在 T-matrix 模擬設定上，假設模擬之雷達波長位於 S 波段(波長 10.8 cm)，以符合北臺灣五分山雷達(RCWF)實際運作波段。且模擬過程中假設環境溫度為 20°C，雨滴軸比(短軸與長軸之比)則依據 Brandes et al (2002) 所提出之經驗關係式，隨雨滴粒徑變化而調整。透過上述假設套用於每一時間解析度為 1 分鐘之雨滴粒徑分布資料，可反演對應之相關雷達參數。所模擬之雷達參數與同時間尺度之雨量計資料進行配對後，建立具物理一致性之雷達參數-降雨率資料集，作為後續深度學習模型訓練與分析之輸入特徵。

2.1.2 五分山 S 波段雷達

五分山 S 波段雷達 RCWF(WuFenshan, WSR-88D NEXRAD S-band dual-pol radar)於 2014 年完成雙偏極化更新，其所提供之可用雷達參數包含雷達反射率(DZ, Reflectivity)、



徑向速度(VR, Radial Velocity)、頻譜寬(SW, Spectrum Width)、差異反射率(DR, Differential Reflectivity)、相關係數(RH, Correlation Coefficient)、差異相位差(PH, Differential Phase)，能為北臺灣的天氣系統帶來更多可用的高時間解析度分析。RCWF 雷達的波長特性(10.7 cm)相較於其他短波長氣象雷達不易受到電磁波衰減效應影響，有效觀測距離來的更遠且擁有相對穩定的訊號接收能力。再者，RCWF 所在的位置位於臺北盆地東北方，海拔約 766 m 之五分山上，由於雷達架設高度較高，因此即使使用低仰角掃描，其雷達波束仍能有效跨越部分地形遮蔽區域，相較於低海拔雷達較不易受到地形阻擋效應影響，能提升北臺灣複雜地形區域之降水觀測涵蓋範圍與觀測穩定性。RCWF 的掃描策略在 2019 年 4 月 19 後有所更新，掃描仰角高度由每個循環 9 個增加至 15 個，尤其是低仰角部分新增更多仰角數，有助於降雨個案分析上的使用，每個循環體積掃描時間在 6 分鐘內完成。

本研究著重於北臺灣強降雨事件的定量降水估計改善分析，北臺灣降雨事件可分為五種降雨型態，春季中尺度系統降水、梅雨、夏季午後熱對流、颱風與東北季風鋒面降雨，其中梅雨個案降雨強度分布廣且持續時間長，容易形成致災性降水，因此由 2017 年至 2019 年間挑選三個梅雨個案進行實際案例應用與分析。

2.1.3 雷達資料處理

使用氣象署(Central Weather Administration, CWA)提供之 RCWF 原始資料雖已有初步資料品質處理，但作為雷達定量降水估計所用仍需進行更進一步的雷達資料處理流程，詳細處理流程如下：

1) 過濾非氣象訊號及雜訊

首先使用相關係數(ρ_{hv})進行初步氣象訊號過濾，由於梅雨個案處於五至六月且大部分中低空為純液態降水，因此通常降水粒子具有較高的相關係數，將 ρ_{hv} 小於 0.85 的資料濾除。隨後沿著波束計算每五個資料點的標準差，當出現異常高值實則中心之資料點予以濾除，以減少雙偏極化參數(Φ_{DP}, Z_{DR})在觀測時出現過多雜訊的區域，門檻設定上

為 Φ_{DP} 標準差 10° 以及 Z_{DR} 標準差 0.8 dB，分別將大於此門檻的兩變數資料予以濾除。

此外位於雷達中心周圍的資料點容易接收到來自附近地形、建築、海面或地表的非氣象回波，造成反射率異常值或是雙偏極化參數 Z_{DR} 、 Φ_{DP} 的不穩定，將統一移除雷達中心半徑 3.5 km 內所有資料點，以利後續得到更準確的 Φ_{DP} 初始值或防止近雷達處有錯誤的 Φ_{DP} 去折疊(unfolding)判斷。

2) 部分波束遮擋與融化層(Melting Layer, ML)問題

因地形導致的部分波束遮擋(PBB)資料，會造成低估的能量參數影響降雨估計表現，因此需使用 4/3 地球半徑的假設求得波束高度，若波束上的資料高度低於地形高度則此後的資料點將被濾除(陳 2016)。並且移除高度 5.5 km 以上的所有資料，避免因具有冰、水混相的粒子對回波或是降雨估計的影響。

3) 相位參數處理

首先對相位參數 Φ_{DP} 進行去摺疊(unfolding)，並減去由雷達體積掃描所計算之平均初始相位差(Φ_0)，作為沿波束初始相位差從 0° 開始的增量，後續沿用 Φ_{DP} 。

4) K_{DP} 計算

比差異相位差(K_{DP})為水平與垂直偏極化電磁波在傳播過程中的相位差變化率，因雨滴的形狀通常為扁球形(Oblate)造成水平電磁波在穿越時的路徑較垂直電磁波長，故水平電磁波在相位延遲上較大，促使 K_{DP} 在物理意義上與液態水含量以及大雨滴濃度高度相關。

先將已減去 Φ_0 之 Φ_{DP} 沿著波束進行 17 點平滑以降低 Φ_{DP} 雜訊造成的影響，再將此代入(XX 式)之沿其傳遞路徑(R)前後共 5 點使用中心差分法計算 K_{DP} 的值。

$$K_{DP} = \frac{1}{2} \frac{\partial \Phi_{DP}}{\partial r} \quad (2.1)$$

分母 r 為徑向資料間的距離； Φ_{DP} 為差異相位差的觀測增量；故 K_{DP} 表示由徑向梯度



計算的比差異相位差參數，單位為 $^{\circ}/km$ 。

5) XY 直角網格內插

原始雷達觀測資料係採用極座標（Polar Coordinate）形式儲存，其空間解析度會隨著觀測距離增加而逐漸下降，使遠距離觀測之雷達資料於水平方向具有較粗糙之空間分布。因此，為利於後續降雨分析、資料比對與深度學習模型輸入，本研究將原始極座標雷達資料內插至固定仰角之 XY 直角網格系統。

傳統雷達資料處理多將資料內插至三維卡氏座標（CAPPI）架構，以建立固定水平與垂直解析度之體積資料。然而，本研究所使用之內插方法為 FIXPPI（Interpolate PPI to XY），其於水平方向採用固定網格之二維直角坐標系統，而垂直方向則仍保留原始雷達仰角資訊進行表示，因此不同仰角之資料仍對應不同之觀測高度。透過此方法，可在維持雷達原始仰角觀測特性的同時，建立固定水平解析度之雷達分析資料。

內插後的雷達資料水平解析度上為 $0.5\text{ km} \times 0.5\text{ km}$ ，一個仰角掃描的雷達半徑 100 km 內將有 401×401 個資料點。相較於傳統將雷達資料內插至三維卡氏座標之方式，FIXPPI 方法可保留各仰角掃描之原始觀測特性，避免因垂直高度層重建而額外引入不確定性。此處理方式亦有助於後續分析不同仰角資料之降雨估計差異，並作為垂直修正模型之輸入資料來源。


2.2 多項式擬合

2.2.1 QPE 關係式係數集

多項式降雨關係式可由 T-matrix 設定環境溫度、電磁波波長、雨滴粒徑軸比等資訊後，模擬出非球型顆粒之對應雷達參數求得。通常降雨關係式為相關雙偏極化雷達參數組合之冪律式：

$$R(Z) = aZ^b \quad (2.2)$$

$$R(K_{DP}) = aK_{DP}^b \quad (2.3)$$



$$R(Z, Z_{DR}) = aZ^b Z_{DR}^c \quad (2.4)$$

$$R(K_{DP}, Z_{DR}) = aK_{DP}^b Z_{DR}^c \quad (2.5)$$

早期使用最小平方差回歸法(Least Square Regression, LSR)回歸降雨關係式時，因降雨事件的強度偏態導致小雨個案有相對較大的權重，而大雨區回歸表現較差，經常出現低估的情形。後續使用 Levenberg-Marquardt (LM)演算法(Levenberg 1944)，以迭代的方式計算非線性最小化(局部)的數值解，求得 $R(Z)$ 、 $R(K_{DP})$ 、 $R(Z, Z_{DR})$ 及 $R(K_{DP}, Z_{DR})$ 四種降雨關係式(陳 2016; Chen et al. 2019)，後續更依照台灣降水系統的特性(Chen and Chen 2003)依月份分類，五個主要降雨型態如春季(Spring, 3-4 月)、梅雨(Mei-Yu, 5-6 月)、颱風(Typhoon, 依實際個案)、對流(convection, 7-9 月)、冬季(Winter, 10-2 月)，5 組降雨型態關係式以及另外 1 組為不分季節共計 6 組關係式。本研究基於相似條件設定選用不分季節之降雨估計式係數組。

$$R(Z) = 0.0279Z^{0.6619} \quad (2.6)$$

$$R(K_{DP}) = 47.5998K_{DP}^{0.7605} \quad (2.7)$$

$$R(Z, Z_{DR}) = 0.0046Z^{0.8492}Z_{DR}^{-0.6193} \quad (2.8)$$

$$R(K_{DP}, Z_{DR}) = 64.8411K_{DP}^{0.988}Z_{DR}^{-0.6921} \quad (2.9)$$

各參數單位分別為 $Z_h(mm^6m^{-3})$ ， $Z_{DR}(dB)$ ， $K_{DP}(^{\circ}/km)$ ， $R(mm/hr)$ 。此係數集將主要用於誤差測試以及深度學習降雨估計模型初步結果對照。

2.2.2 複合型降雨估計式

由於本研究之深度學習模型輸入參數最多三個雙偏極化雷達參數，主要採用 Z 、 Z_{DR} 、 K_{DP} 作為輸入特徵進行降雨估計。再者，考量 K_{DP} 於弱降雨情況下容易受到相位擾動與雜訊影響，導致估計結果不穩定，因此在傳統多項式擬合(PLF)方法中，本研究主要採用 $R(K_{DP}, Z_{DR})/R(Z)$ 複合式(hybrid)降雨估計策略。

在複合式降雨估計策略中使用 $R(Z)$ 估計式彌補 K_{DP} 參數在小雨時的低準確度。詳細



使用門檻為當觀測資料同時滿足 Z 大於 35dBZ 及 K_{DP} 大於 $0.5^{\circ}/km$ 的條件時，使用 $R(K_{DP}, Z_{DR})$ 估計式，其餘條件則使用 $R(Z)$ 估計式。

2.3 深度神經網路

2.3.1 模型結構

本研究採用的深度學習模型為多層感知器(Multi-Layer Perceptron, MLP)架構，以下稱為 MLP_QPE，藉由其出色的擬合能力，用以建立雙偏雷達參數與地表降雨率之非線性關係。模型輸入層包含三個節點，分別對應雷達反射率(Z)、差異反射率(Z_{DR})以及比差異相位差(K_{DP})。詳細模型超參數列表與結構示意圖於附錄 A1。

1) 層數結構

在整體模型架構上，由於多層感知器(MLP)主要可分為輸入層(Input Layer)、隱藏層(Hidden Layer)及輸出層(Output Layer)。此定量降水估計模型之隱藏層由多個全連接層(Fully Connected Layer)所組成其隱藏層神經元數量依序設計為 128、128、64、32 個神經元，最後輸出單一降雨率估計值。輸入參數會先與權重(Weight)進行線性組合後傳入激活函數(Activation Function)，以學習資料中的非線性特徵(Haykin, S. 2009)；而在模型訓練過程中，則透過背向傳播(Backpropagation)根據預測誤差持續更新權重，使模型逐步最佳化降雨率與雷達參數之間的關係。另外，為提升模型訓練穩定性與非線性特徵學習能力，本研究於各主要隱藏層後加入批次正規化(Batch Normalization)與隨機丟棄(Dropout)機制。其中批次正規化可降低不同批次(Batch)資料分布差異對模型訓練之影響(Ioffe, S. & Szegedy, C. 2015)，而隨機丟棄則可降低模型過度擬合(Overfitting)的問題，並有助於提升模型泛化能力(Srivastava et al. 2014)。此外，本研究於模型後段加入殘差連接(Residual Connection)設計，將原始輸入特徵透過跳過連接(Skip Connect)映射至隱藏層輸出後進行相加，以改善深層網路於訓練過程中的梯度傳遞能力，額外提升模型對原始雷達特徵的保留能力。



2) 激活函數(Activation Function)與最佳化方法(Optimizer)

激活函數為深度學習模型中重要的非線性轉換機制，其主要目的在於使神經網路具備學習複雜非線性關係之能力。若模型僅由線性運算所組成，即使增加多層神經網路，其整體輸出仍僅視為線性轉換，將無法有效描述真實世界中高度非線性之資料特徵。因此，激活函數透過對每個神經元輸出進行非線性映射，使模型能夠學習輸入資料與預測目標之間複雜的非線性關係。

以全連接神經網路為例，每個神經元會先對輸入資料與權重進行線性組合：

$$z = \sum_{i=1}^n w_i x_i + b \quad (2.10)$$

其中 x_i 為輸入特徵、 w_i 為權重、 b 為偏差項。接著再透過激活函數 $f(z)$ 將其轉換為非線性輸出：

$$a = f(z) \quad (2.11)$$

將此輸出結果作為下一層神經元之輸入，本研究採用 Gaussian Error Linear Unit (GeLU) 作為模型之激活函數，其數學形式可表示為：

$$\text{GeLU}(x) = x \cdot \Phi(x) \quad (2.12)$$

其中 $\Phi(x)$ 為標準常態分布之累積分布函數(Cumulative Distribution Function, CDF)。實務上常使用其近似式：

$$\text{GeLU}(x) \approx 0.5x(1 + \tanh(\sqrt{\frac{2}{\pi}}(x + 0.044715x^3))) \quad (2.13)$$

而相較於傳統 ReLU 函數：

$$\text{ReLU}(x) = \max(0, x) \quad (2.14)$$

GeLU 屬於平滑型激活函數，其對於負值輸入不會直接截斷為零，而是保留部分負值的資訊，因此在背向傳播的過程中仍能維持非零梯度，有助於降低梯度消失(Vanishing Gradient)的問題提升模型訓練穩定性。對於本研究降雨估計問題而言，GeLU 能較有效地保留弱降雨與細微雷達特徵變化資訊。

在模型訓練過程中，本研究採用 Adam (Adaptive Moment Estimation) 作為最佳化方法。Adam 最佳化器結合 Momentum 與自適應學習率 (Adaptive Learning Rate) 之概念，可根據模型訓練過程中的梯度變化，自動調整不同權重參數之更新幅度，以提升模型收斂效率與訓練穩定性。其權重更新方式可表示為：

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.15)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.16)$$

其中 g_t 為當前梯度， m_t 與 v_t 分別代表梯度平均值與梯度平方平均值， β_1 為控制過去梯度影響程度， β_2 為控制過去梯度平方影響程度。上述之一階與二階動量估計分別用於控制梯度更新之方向與大小。最後模型權重更新為：

$$w_t = w_{t-1} - \alpha \frac{m_t}{\sqrt{v_t + \epsilon}} \quad (2.17)$$

其中 w_t 為模型權重， α 為學習率 (Learning Rate)， ϵ 為避免分母為零之微小常數。


3) 損失函數 (Loss Function) 與早停機制 (Early Stopping)

損失函數主要用於衡量模型預測結果與真實觀測值之間的差異，並作為模型訓練過程中權重更新之依據。模型會透過最佳化方法持續降低損失函數值，使預測結果逐漸接近真實資料。在本研究中因應降雨型態的分布與其偏態，採用加權均方誤差 (Weighted Mean Squared Error, Weighted MSE) 針對強降雨樣本給予較高權重，以避免資料集中且強降雨樣本少所造成之不平衡問題。當樣本降雨率超過 20、45 及 65 mm/hr 時，模型將分別提高其損失函數權重，使模型能更有效掌握強降雨特徵。

另外，在訓練過程中亦採用早停機制監控驗證集誤差，當模型訓練時連續於多個訓練輪次 (Epoch) 未出現改善時即停止訓練，以避免模型產生過度擬合併提升訓練效率。

2.3.2 訓練資料前處理

本研究因使用之雷達雙偏參數包含不同量級與單位，為避免不同參數因數值範圍差異過大而影響模型訓練，本研究亦對輸入之雷達雙偏參數進行資料標準化



(Standardization)處理，使各參數轉換為具有相近分布尺度之資料。透過標準化處理，可避免特定變數於訓練過程中主導權重更新，提升模型梯度更新之穩定性與收斂效率，並有助於模型學習不同雷達參數數值組合與降雨率之關係，進而提升整體預測表現。

此外，由於降雨率資料在自然界中通常呈現高度右偏且具長尾分布特性，強降雨樣本相對稀少，若直接以原始降雨率作為深度學習模型之預測目標，容易使模型訓練過程受到極端值主導，進而影響整體模型的學習穩定性與後續泛化的表現。因此，本研究於模型訓練前，先對降雨率資料進行對數轉換處理，以降低資料分布偏態並壓縮極端降雨的影響。在模型訓練與損失函數計算過程中，均以對數轉換後之降雨率作為預測目標；後續於模型推論階段，則將模型輸出結果透過反對數轉換還原為實際降雨率，以進行後續結果分析與比較。透過此方法，可緩解降雨資料分布不均帶來的影響，並提升模型對不同降雨強度之預測穩定性。

2.3.3 資料切分

本研究中雷達反射率(Z)、差異反射率(Z_{DR})以及比差異相位差(K_{DP})由上述所及來自於雨滴粒徑分布之數值模擬，每 6 分鐘為一次掃描單位。將雷達資料與降雨率資料整合，統計自 2005 年至 2015 年降雨事件總計 30,126 筆樣本(圖 X)。

在深度學習中，若僅使用單一資料集進行模型參數更新與效能評估，容易導致模型對訓練資料產生過擬合，使其在未曾見過的資料上回歸性能顯著下降。為確保模型具有良好的泛化能力，並能客觀評估於未知樣本上的預測表現，本研究將資料集隨機切分為訓練集 (Training Set)、驗證集 (Validation Set) 與獨立測試集 (Independent Test Set)，其比例分別為 70%、20%與 10%。其中，訓練集主要用於模型權重參數之學習與更新；驗證集則用於監控模型訓練過程與調整超參數(Hyperparameters)設定，以避免模型發生過度擬合問題；而獨立測試集並不參與模型訓練與參數調整，僅作為最終模型效能評估，與套用至真實個案前之初步定量降水估計效能檢視，驗證模型對未知資料之特徵適應能力與實際應用表現。




2.3.4 模擬誤差測試

深度學習定量降水估計模型(MLP)之訓練資料採統計雨滴粒徑分布資料之模擬雙偏極化雷達參數，故其環境不包含任何真實個案觀測時可能出現之觀測誤差或系統性偏差。考慮真實個案間，在實際應用至真實個案前，為測試不同參數組合(Z)、(K_{DP})、(Z, Z_{DR})、(K_{DP}, Z_{DR})、(Z, Z_{DR}, K_{DP})之估計效益以及對於可能的真實個案之觀測誤差容忍度，其中，使用(Z, Z_{DR}, K_{DP})參數組合測試之 PLF 方法，將使用複合型降雨估計式。以下測試將使用提供 MLP 模型之訓練資料 10%(未使用於訓練以及驗證階段)約 3000 筆資料，藉由在輸入之雷達參數中額外加入四種等級的模擬觀測誤差，檢驗 MLP 模型與傳統多項式降雨估計式(PLF)在遇到可能的觀測誤差或系統性誤差時，還有多少估計降雨之性能。

具體之模擬誤差幅度數值(表 2.1)，於剩餘之 10%總樣本中，計算每個雙偏雷達參數之標準差，並於每個參數中額外加入 $\pm 0\%$ 、 $\pm 50\%$ 、 $\pm 100\%$ 以及 $\pm 150\%$ 範圍之標準差(Standard Deviation, STD)大小，並將此含有誤差之資料集分別用於傳統幂律式(PLF)以及深度學習降雨模型(MLP)，以不同程度之加入誤差模擬真實個案中的觀測誤差。

統整 PLF 與 MLP 兩方法在各參數組合為輸入，分別測試由 n_0 至 n_3 等級模擬觀測誤差之方均根誤差(RMSE)評估指標(表 2.2)。首先由單一輸入參數雷達反射率 Z 測試，在未加入任何觀測誤差之資料集(n_0)測試結果可看到兩種方法有較接近的 RMSE，且 PLF 之 RMSE 稍好於 MLP 模型(圖 2.1)。隨著誤差等級增加，兩方法之 RMSE 皆有上升的趨勢，當誤差等級大於 n_2 後，PLF 之 RMSE 開始略大於 MLP 方法，於誤差等級 n_3 兩者之 RMSE 分別為 7.01 mm/hr (PLF)以及 5.26 mm/hr (MLP)。接著使用單一輸入參數比差異相位差 K_{DP} 測試，在未加入任何觀測誤差之資料集(n_0)中兩方法之 RMSE 也相當接近，但當誤差等級增加至 n_2 後，PLF 之 RMSE 開始因其降雨估計式的特性，估計結果大幅受到所加入的模擬觀測誤差影響，與 MLP 模型估計結果之 RMSE 拉開差距。到了最高的誤差等級 n_3 ，PLF 估計結果之 RMSE 高達 17.4 mm/hr，而 MLP 模型之 RMSE 也有 7.21 mm/hr。在使用(Z, Z_{DR})和(K_{DP}, Z_{DR})的輸入參數組合誤差測試中，PLF 在無加入模擬誤差之資料集(n_0)估計降雨初始 RMSE 相比 MLP 模型高，隨著誤差等級增加兩方法



RMSE 差距越來越大，尤其使用(Z, Z_{DR})輸入組合之 PLF 估計結果 RMSE 高達 26.5 mm/hr，相較之下 MLP 大約為 11.6 mm/hr。最後是使用三參數輸入(Z, Z_{DR}, K_{DP})模擬誤差測試，由於 PLF 方法根據參數數值門檻分別使用 $R(K_{DP}, Z_{DR})/R(Z)$ ，會有條件的區分大雨或小雨所使用之降雨估計式。無加入誤差之資料集(n0)測試中，PLF 之 RMSE 為 2.41 mm/hr，而 MLP 模型之 RMSE 達到全參數組合最佳 1.06 mm/hr，隨著誤差等級增加兩方法之 RMSE 皆有上升趨勢但 PLF 會較為顯著。

整體而言，各種降雨估計雙偏參數組合之 RMSE 皆有上升趨勢，說明輸入之雙偏雷達參數誤差會直接影響降雨估計結果之穩定性，無論是傳統幂律估計式(PLF)或深度學習模型(MLP)。其中，PLF 方法在高模擬誤差(n3)條件下誤差增加幅度最為明顯，尤其涉及 Z_{DR} 以及 K_{DP} 兩參數之估計式中更容易受到觀測誤差影響。例如在 n3 誤差等級下，單變數 $R(K_{DP})$ PLF 之 RMSE 已上升至 17.4 mm/hr，而雙參數 $R(K_{DP}, Z_{DR})$ 亦達 19.7 mm/hr，顯示傳統固定係數之幂律關係式在高誤差環境下容易產生不穩定估計結果。相較之下，MLP 之降雨估計模型在個誤差等級下皆展現較佳之誤差容忍能力。特別是在多參數輸入情況下，MLP 可透過非線性特徵學習，自動調整不同雷達參數之權重關係，降低單一參數受誤差干擾所造成之影響。其中以三參數輸入(Z, Z_{DR}, K_{DP})之 MLP 結果表現最佳，在所有誤差等級下皆維持最低 RMSE，尤其在最高誤差等級 n3 條件下，其 RMSE 仍僅為 3.46 mm/hr，明顯低於 PLF 方法之 13.1，顯示深度學習模型對於觀測誤差具有較高穩定性與適應能力。

2.4 垂直修正模型

為改善複雜地形下高仰角雷達觀測所造成之降雨估計偏差，本研究開發一套基於卷積神經網路之垂直修正模型——TopoCorr-Net。此模型主要目的在於學習不同雷達高度層之降雨垂直變化，使高仰角雷達估計能修正至較低高度之降雨分布，以降低因波束高度增加與地形遮擋所造成之系統性誤差。

第二部份將使用多仰角的雙偏極化雷達參數以及 MLP 模型在不同仰角的網格點將與率，切分原始解析度 $0.5km \times 0.5km$ 的網格點雙偏參數至若干小區域，透過垂直修正



模型(TopoCorr-Net)的卷積神經網路提取上層降雨特徵，計算指定高度間的雷達估計降雨高度變量。

2.4.1 模型結構

垂直修正模型 TopoCorr-Net 模型之整體架構如圖 X 所示，模型主要將由兩部分輸入所組成，分別為雙偏極化雷達參數與降雨空間特徵(X_1)與物理高度資訊相關特徵輸入(X_2)，並透過卷積神經網路(CNN)與多層感知器結構(MLP)進行特徵融合與殘差學習。詳細模型超參數列表與結構示意圖於附錄 A2。

1) 雷達空間特徵輸入(Spatial Radar Features)

模型第一部分輸入為：

$$X_1 = [Z, Z_{DR}, K_{DP}, R]_{upper} \quad (2.18)$$

其中包含高層仰角之雷達反射率(Z)、差異反射率(Z_{DR})、比差異相位差(K_{DP})以及 MLP 模型估計降雨率(R)。為保留對流胞局部空間結構資訊，本研究並非使用單一網格點，而是以 9×9 patch 作為輸入，因此輸入張量(Tensor)尺寸為 $4 \times 9 \times 9$ 。透過此方式，模型可同時學習降雨系統之局部空間分布特徵，例如對流邊界、強回波核心或弱回波區域降雨梯度變化。

在特徵提取部分，採用多層 3×3 卷積層(Convolution Layer)進行空間特徵提取。卷積層能有效提取局部鄰近區域之空間相關性，並降低單點雷達參數擾動對模型造成之影響。卷積特徵經過平均池化層(2D Average Pooling Layer)與全連接層(Fully Connected Layer)後，轉換為高維空間特徵向量。

2) 物理高度特徵輸入(Height and Location Features)與特徵融合(Feature Fusion)

除雙偏雷達參數外，此研究亦考量實際波束高度與仰角間高度差對降雨估計之影響，因此加入第二區輸入：

$$X_2 = [HH, \Delta H, DS]_{upper} \quad (2.19)$$



其中 HH 變數為上層波束高度， ΔH 為上層與下層波束高度差，DS 為雷達至觀測點距離。此部分特徵主要反映雷達波束隨距離增加之高度變化，以及不同仰角間之垂直結構差異。由於此類特徵屬於非空間性之物理資訊，因此採用單一格點線性層搭配 GeLU 激活函數進行非線性映射。

完成前兩部分之特徵提取後，模型將 CNN 所提取之雷達空間特徵與物理高度特徵進行串接(Concatenate)：

$$F = [F_{radar}, F_{height}] \quad (2.20)$$

為後續多層感知器與殘差學習同時整合雷達局部空間降雨結構、地形高度資訊以及雷達觀測幾何特性，使模型能學習不同高度層之降雨變化關係。

3) 殘差學習(Residual MLP Head)

在後續垂直降雨修正變量輸出的部分，採用 Residual MLP Head 進行最終修正量預測。模型包含兩層全連接層：

$$FC1 \rightarrow LeakyReLU \quad (2.21)$$

$$FC2 \rightarrow LeakyReLU \quad (2.22)$$

並加入 Shortcut Connection 形成之殘差結構(Residual Connection)：

$$Y = F(x) + x \quad (2.23)$$

此設計可降低深層網路訓練時梯度消失的問題，同時使模型更容易學習關於垂直方向間降雨「修正量(Correciton)」而非直接重新建構完整降雨率。故本研究之模型輸出將定義為：

$$Y = \Delta R \quad (2.24)$$

其中將模型輸出 ΔR 定義為：

$$\Delta R = \ln(R_{upper}) - \ln(R_{lower}) \quad (2.25)$$



表示高層與低層降雨率之對數差值，最後得到：

$$R_{correct} = R_{upper} \cdot e^{-\Delta R} \quad (2.26)$$

得到修正後之降雨率。此處採用對數空間進行修正之原因，在於降雨率分布具有高度偏弱降水與長尾特性，透過對數轉換可降低極端值影響，使模型更容易習得不同降雨強度間之相對變化。

4) 模型訓練與最佳化(Optimizer)設定

垂直修正模型 TopoCorr-Net 模型訓練採用 AdamW 作為最佳化方法。AdamW 為基礎 Adam(Adaptive Moment Estimation)演算法中加入權重衰減(Weight Decay)之改良版本，可避免傳統 Adam 於正規化(Normalization)過程中產生權重更新耦合問題，提升模型泛化能力。模型具體參數更新方式如下：

$$w_{t+1} = w_t - \alpha \frac{m_t}{\sqrt{v_t + \epsilon}} - \alpha \lambda w_t \quad (2.27)$$

其中 α 為學習率、 m_t 為一階動量估計、 v_t 為二階動量估計、 λ 為權重衰減係數。此外，本研究於訓練初期採用 Warm-up learning rate 策略，使學習率由較小值逐步增加，可避免模型於初始階段因梯度震盪造成訓練不穩定。在 Warm-up 完成後，則進一步採用餘弦退火(Cosine Annealing)調整學習率：

$$\alpha_t = \alpha_{min} + \frac{1}{2}(\alpha_{max} - \alpha_{min})(1 + \cos \frac{T_{cur}}{T_{max}}\pi) \quad (2.28)$$

其中 α_{max} 為初始學習率、 α_{min} 為最低學習率、 T_{cur} 為目前訓練步數、 T_{max} 為總訓練步數。此方法可使學習率於訓練後期平滑下降，提升模型收斂穩定性並降低過擬合風險。整體來說，TopoCorr-Net 可透過結合上層雷達與降雨空間特徵以及物理高度資訊與殘差式深度學習架構，習得不同仰角間之降雨垂直變化關係，並期望改善複雜地形下高仰角雷達定量降水估計之系統性偏差。



2.4.2 模型預處理


為使垂直修正模型所輸入之資料品質完整，於模型訓練前，針對輸入之雙偏極化雷達參數以及降雨率網格點 patch 資料進行前處理。由於在實際雷達觀測中，有些網格點位置雖存在降雨現象，但仍可能因地形效應、資料品質不佳等因素導致雷達資料在某些點上缺值，因此網格點中無資料位置有時不一定代表雷達實際接收到為 0dBZ 之回波大小，而可能代表該位置缺乏有效觀測資料。若直接將此類缺值視為無降雨訊號，可能造成模型對降雨空間結構產生錯誤學習。

將用於模型輸入資料以中心網格點為核心之 9×9 patch，首先逐一檢查 81 個資料點數值有效性。若 patch 中心點為缺值(NaN)，則直接捨棄該 patch，原因在於中心點為模型最終欲修正之目標位置，若中心位置本身不存在有效觀測資訊，則該樣本無法提供欲修正目標之物理高度資訊(輸入層 X_2)。對於除中心外 patch 內部其他缺值點，則進一步針對缺值進行補值處理。若缺值位置並非於 patch 邊界，將利用其周圍八個鄰近格點之有效值進行平均補值，計算方式如下：

$$X_{fill} = \frac{1}{N} \sum_{i=1}^N X_i, N \geq 3 \quad (2.29)$$

其中 X_i 為周圍有效點之數值， N 為有效鄰近格點數。為避免補值結果受到過少資料影響，此步驟限制周圍八個格點中至少需有三個以上有效點，才允許進行缺值補值；若周圍有效點數不足，則保留原始缺值狀態。透過此方法可在保留局部降雨空間結構資訊情況下，減少因雷達觀測缺值造成的空間不連續問題，同時降低因大缺值直接捨棄資料而造成的樣本數不足情形。

在完成缺值處理後，本研究進一步於模型輸入前加入局部平滑(Local Smoothing)。由於雷達觀測資料或 MLP 估計降雨網格資料可能包含小尺度擾動或局部極值訊號，因此在輸入模型前利用 3×3 卷積核(Convolution Kernel)對 patch 內資料進行初步空間平滑處理。其目的在於減弱局部高頻訊號，同時呈現局部降雨空間連續性。卷積過程表示為以下：


$$Z(i, j) = \sum_{m=-1}^1 \sum_{n=-1}^1 K(m, n) \cdot X(i + m, j + n) \quad (2.30)$$

其中 X 為原始輸入 patch、 K 為 3×3 卷積核、 Z 為平滑後輸出結果。透過此平滑化處理，模型能更穩定地輸入局部空間降雨分布特徵，降低單一格點異常值對模型造成之影響，並提升後續卷積神經網路對降雨空間型態之辨識能力。整體而言，此處資料前處理流程主要包含「缺值檢查」、「局部補值」以及「空間平滑」，提升輸入雷達之 patch 資料品質。



第三章 深度學習定量降雨估計結果


經過前述深度學習定量降雨估計模型(MLP)的建置與訓練後，本章將進一步使用北臺灣梅雨期間之真實降水個案，分析此深度學習模型於實際雙偏極化雷達觀測資料中的降雨估計表現，包含個案之降雨概況、不同仰角下降雨估計效果、誤差空間分布，並額外與多項式冪律降雨估計方法(PLF)進行比較。

3.1 個案概述

用於分析之梅雨降水個案分別為 20170602、20190517 以及 20190520 共三個案。20170602 個案主要由 2017 年 6 月 1 日深夜到 6 月 3 日主要降水時間大約為 27 小時，其累積降雨範圍廣泛，主要強降雨區集中在北臺灣西北海岸沿陽明山方向至臺北盆地東北側區域，部分區域累積雨量超過 500 mm 且地面自動雨量站紀錄之最大小時累積雨量可達 112 mm/hr。此外，由於降雨持續時間較長且範圍較廣，此個案同時包含層狀降水與強對流降水特徵，對定量降雨估計模型而言具有挑戰性。第二個個案為 2019 年 5 月 17 日局部強對流降水事件，相較前一個案此事件降雨範圍較小，但局部降雨強度依然相當顯著。強降雨區域主要集中於臺灣西北側海岸，局部累積雨量超過 150 mm，降雨系統呈現較窄且集中的對流雨帶結構，此類降水具有短時間強降雨以及高空間變異性的特徵，且主要對流區域距離所使用之五分山雷達(RCWF)較遠，因此容易造成雷達降雨估計上的局部誤差或雷達資料點過高所產生之垂直結構誤差問題。第三個個案為 2019 年 5 月 20 日強對流降水事件，降雨系統主要位於北臺灣西北側海岸以及部分臺北盆地、林口臺地區域。局部累積降雨超過 150 mm，且部分高累積降雨區位於接近五分山西北側地形遮蔽區域，對雷達低仰角觀測造成一定程度之限制。

3.2 不同仰角估計效果

為探討不同雷達仰角資料之使用影響定量降水估計效果，本節將分別分析 MLP 模型以及多項式冪律估計式(PLF)於不同仰角下降雨估計性能，包含低仰角至高仰角結果



差異。此外，由於雷達波束高度會隨著觀測距離增加而逐漸上升，因此不同仰角所觀測之降水粒子高度與地表實際降雨之間存在明顯差異，進而影響降雨估計結果，特別是在北臺灣複雜地形下，低仰角觀測雖較接近地表降雨，但容易受到地形遮蔽與部分波束遮蔽(PBB)影響；相對地，高仰角資料可避免地形遮蔽問題，但觀測高度篇稿容易受到降水垂直結構變化影響。

3.2.1 仰角分析：20170602 個案

於 20170602 梅雨個案中，不同仰角下雷達降雨估計散佈圖比較(圖 3.1)，包含 0.5° 、 1.5° 及 2.4° 仰角，並比較多項式冪律降雨估計式(PLF)與深度學習降雨估計模型(MLP)之結果。散佈圖中以雨量站 1 小時累積雨量為橫軸，雷達估計降雨為縱軸，虛線為理想一比一分布。

以結果來說，隨著雷達仰角增加，PLF 與 MLP 兩中方法之降雨估計誤差皆有增加之趨勢。於最低之仰角 0.5° 時，由於雷達資料高度較接近地表降雨層，因此兩種降水估計方法皆能獲得相對較佳之估計效果，而相較於 PLF 表現 MLP 模型在弱降雨至中等降雨區間具有更集中之一比一分布，RRMSE 由 PLF 之 0.3138 下降至 0.2961，相關係數亦由 0.9222 提升至 0.9435。當仰角提升至 1.5° 時，PLF 方法之發散現象開始明顯增加，尤其在中強降水區間可觀察到低估的情形出現，其 NMB 達到-0.1084，表示整體降雨估計具有系統性低估，固定係數之降雨估計式(PLF)在提高仰角資料後，較難有效反映實際地表降雨。相較之下，MLP 降雨估計模型仍維持較穩定一比一分布，於強降雨事件下雨地面觀測具有較好的一致性。當仰角進一步提升至 2.4° 時，由於雷達波束高度明顯抬升，雷達觀測與地表降雨之垂直差異更加明顯，因此兩種方法皆出現較明顯之估計誤差。其中 PLF 方法於強降雨區域之低估現象更加明顯，分布情形更為發散，而雖然使用 MLP 模型同樣受到高仰角觀測資料影響，但其偏差量較 PLF 來的低且強降雨區雖同樣出現低估情形但分布更為集中。



3.2.2 仰角分析：20190517、20190520 個案

由於後二個個案五分山雷達(RCWF)於 2019 年 4 月進行掃描策略調整，故於先前仰角 0.5° 至 2.4° 所包含仰角數有新增以及調整，後續個案之雷達仰角有 0.5° 、 0.9° 、 1.3° 、 1.8° 以及 2.4° 共五個，可進一步分析更多不同仰角下的降雨估計特性以及變化趨勢。

於 20190517 個案中(圖 3.2)，可觀察隨著雷達仰角由 0.5° 逐漸提升至 2.4° ，兩方法之散佈圖分布皆逐漸發散與低估，資料點逐漸遠離一比一理想參考線。此現象均反映出雷達觀測高度增加後，雷達參數在不同層高度之間具有垂直結構上的差異，造成上下層估計降雨之情形逐漸相左。於 0.5° 仰角時，兩種方法分布情形大約一致，RRMSE 都在 0.45 上下，NMB 顯示的估計偏差均為所有仰角最低，但此個案兩方法皆無法掌握中強降雨的精準估計(>20 mm/hr)。隨著仰角增加至 1.3° 後，PLF 方法於中強降雨(>20 mm/hr)的分布開始出現較程度的發散，估計值逐漸遠離參考線附近。當仰角進一步提高至 1.8° 與 2.4° ，PLF 之 RRMSE 上升至 0.65 左右而 MLP 也有 0.56，但兩者的 NMB 估計偏差指標沒有明顯的正成長或負成長，且由散佈圖分布也可發現，在 15 mm/hr 強度以上的估計大部分會出現負偏差但 15 mm/hr 強度以下則出現高估現象的正偏差，此情形可由估計指標的 RRMSE 逐漸上升和 NMB 無明顯成長顯示，兩方法皆有相似的分布變化，表示此個案在兩種方法的估計上較難藉由提高仰角比較兩者性能差距。

相較於 20190517 個案，20190520 之降雨事件則位於北臺灣西北沿海至臺北盆地區域，呈現不同的降雨特性。整體而言兩方法在估計降雨事件從低仰角至高仰角雖同樣有負偏差的趨勢，但整體分布較前一個案來的集中。於 0.5° 及 0.9° 仰角時，由於主要降雨區域位於陽明山靠海岸側，此區雷達參數受限於地形影響缺乏資料，但從兩方法的散佈圖來看整體估計效果皆比 20190517 個案來的更為精準且集中(圖 3.3)，PLF 之 RRMSE 約為 0.34 而 MLP 之 RRMSE 約為 0.3，但 NMB 指標兩方法皆有 -0.1 的負偏差情形，於中強降雨強度區域。到了 1.8° 與 2.4° 仰角後，NMB 指標在兩方法皆有明顯往負偏差成長的趨勢，且 MLP 之 NMB 負偏差較 PLF 方法來的多，但由於觀察圖 X 分布可推測雖然 MLP 之 NMB 偏差較多，但於弱降水區估計較 PLF 來的好，故在 2.4° 仰角下 MLP 之



RRMSE 仍可相對 PLF 來的低。


綜合此二個案(20190517、20190520)結果可發現，降雨估計誤差普遍呈現增加趨勢，此現象與觀測高度造成之垂直降水結構差異有關，不管是由於仰角增加或是由於降雨區域距離雷達較遠的波束上升情形。相較於 PLF 方法，MLP 之降雨估計雖然在仰角上升時同樣出現低估的情形，但整體分布皆能較 PLF 方法來的集中，尤其在中強降雨事件下，估計情形會來的穩定。

3.3 小時與累積雨量圖分析

本節將三個案之雨量網格點資料分為 1 小時累積雨量以及事件總累積雨量場，以分析梅雨事件強對流降水之演變與 MLP、PLF 方法估計降雨之效益。此外，由於比較降雨估計效果時通常需使用越低仰角資料越能減少因資料點高度引起的誤差，但若僅使用最低仰角資料可能導致部分區域雨量場受限於地形遮擋而無觀測資料，因此本研究選用 1.5° 仰角之估計雨量場作為主要分析對象，以兼顧地表降雨代表性與雷達觀測完整性，降低低仰角地形遮擋對降雨分析之影響。

3.3.1 小時累積雨量

使用 20170602 梅雨事件主要降水持續 27 小時個案，分析強對流降雨在不同發展階段、地形影響與不同降雨區域特性，於此個案中數個代表性時段之一小時累積雨量場進行比較。圖 3.4 顯示 MLP 與 PLF 方法於 1.5° 仰角下之降雨量估計結果，其中圓點代表地面雨量站位置，而圓點內顏色則表示實際觀測之累積雨量強度。首先，於 0601 20UTC 與 21UTC 兩連續時段中，可觀察到對流系統核心仍位於西北海岸外海附近，對流邊緣已開始登陸海岸至陽明山西側，由圖可發現，MLP 對於對流前緣區域之降雨強度分布較為完整，能維持較連續之高降雨帶結構，且於西北海岸至山區迎風面附近，也可觀察到較明顯之強降雨核心分布。相較之下 PLF 方法於相同區域之降雨估計較為不連續，且部分強降雨區域之估計強度亦較低，導致降雨帶前緣空間分布差距較大。在地形後方區域亦可觀察到兩者差異，PLF 方法於雷達西北側山區後方之降雨分布呈現明顯低估現象，



而 MLP 仍能維持較完整之降雨空間結構，且位於山區附近之降雨強度與測站分布較為一致。當對流系統持續向東南方向移動後，0602 03UTC 與 04UTC 時段中，對流核心已逐漸進入臺北盆地內部，此階段強降雨帶主要集中於盆地北側至西側區域。於此階段中，兩方法有較相似的強降雨核心分布，由地面雨量站觀測可發現，臺北盆地內部多處測站皆出現 65 mm 以上的累積降水，而兩種方法於主要對流核心位置皆能呈現相對應之強降雨估計結果。然而，PLF 方法於局部強降雨核心區域仍可觀察到較明顯之降雨強度衰減，部分強降雨帶之空間延伸亦較短；相較之下，MLP 於強降雨核心周圍維持較完整之強降雨分布，使整體雨帶結構較接近測站觀測之空間型態。此外，MLP 於對流尾端與周圍降雨梯度變化區域之降雨分布亦較為平滑，顯示其對對流系統空間連續性具有較佳描述能力。綜上所述，在此個案中當對流系統尚未完全進入北臺灣時，由於處於地形後以及降雨結構快速變化影響，PLF 方法較易出現局部低估與降雨帶數值忽大忽小現象；而當對流核心完全進入臺北盆地後，兩種方法皆能掌握主要降雨區域，但 MLP 於強降雨核心強度與空間連續性上仍呈現較穩定之估計結果。

由於 20190517 與 20190520 兩個案之主要降雨持續時間相對較短，且強對流降雨區域移動速度快，因此本節僅挑選降雨涵蓋陸地範圍最大且降水系統最完整之一段連續時間進行分析。20190517 個案中(圖 3.5)，主要降雨區域位於西北海域沿岸以及近岸約 20 公里範圍，於 0517 05UTC 時，兩方法皆能掌握主要降雨區域，並反映對流系統向東延伸之降雨結構。然而，兩方法在強降雨極值區域與真實觀測降雨皆有落差，低估約 10~15 mm。隨後 0517 06UTC 時，雨帶逐漸移動至相對內陸區域，整體降雨強度明顯減弱，此時兩方法之降雨分布差異相較前一時段減少，皆能反映主要雨帶實際位置。然而，可發現 MLP 於部分弱降雨區域仍存在較零散之局部高值分布，顯示模型對局部雷達參數特徵變化較為敏感；而 PLF 方法則呈現較平滑之雨帶結構，但部分測站附近降雨強度仍有低估情形。此個案由於降雨持續時間較短且降雨範圍有限，兩方法在空間雨量場之差異並不如長生命週期對流個案明顯。

20190520 個案中(圖 3.6)，對流系統的空間尺度與降雨強度均高於 20190517 個案。



0520 02 UTC 時，北臺灣北側海面存在對流降雨帶，並向臺北盆地方向延伸。兩種方法皆呈現北海岸附近的降雨核心，其中 MLP 的高降雨量較集中，PLF 則於對流尾端呈現範圍較廣的中低降雨量，使兩者在降雨核心外圍的分布有所差異。部分山區附近，MLP 所呈現之雨帶延伸方向亦與測站觀測分布較為一致。至 0520 03 UTC，對流系統逐漸向南移入臺北盆地及西側山區，降雨強度的空間梯度隨之增加，兩種方法的降雨場亦受到地形影響而產生局部變化。MLP 於部分山區出現局部高值，部分位置存在高估；PLF 雖較少出現此類高值，但對部分測站所觀測到的較高降雨量反應較弱。當降雨系統逐漸減弱時，兩種方法皆出現部分區域估計降雨範圍大於測站觀測分布的情形，顯示在對流消散階段，雷達降雨估計仍可能受到殘留回波及降雨垂直結構變化的影響。

3.3.2 長時間累積雨量

再來由三事件的總降雨量累積圖分析兩方法在不同仰角下的估計降雨效益與觀測雨量校驗。圖 3.6 至圖 3.8 分別為 20170602、20190517 以及 20190520 梅雨個案於不同仰角下之事件總累積雨量分布，其中上排為 MLP 結果而下排為 PLF 結果，並分別以大間距(Big range)與小間距(Small range)色階呈現事件降雨空間分布特徵。

1) 20170602 事件累積降雨

由橫向比較(MLP 與 PLF)可發現(圖 3.6)，兩方法大致上皆呈現正確的主要降雨核心位於臺北盆地北側至北海岸山區附近之特徵，並呈現由西北側海面延伸至陸地之帶狀降雨結構。於大間距色階下，在 0.5° 與 1.5° 可觀察到 MLP 於北海岸山區附近呈現出較完整之高累積降雨核心區域，其空間分布與測站有較相似的分布情形；而 PLF 方法於部分區域則呈現較大範圍的中高累積降雨帶，整體降雨梯度相對平滑。於小間距色階下，上述差異則更加明顯。MLP 在北臺灣陸地區域可呈現較細緻之降雨分布變化，尤其臺北盆地周圍與地形迎風面附近，可發現到較明顯之局部高值延伸。然而，亦可發現 MLP 於部分區域出現局部降雨估計高值偏強情形，使局部累積雨量分布較集中。相對地，PLF 方法之累積雨量分布雖較為平滑，但部分測站附近之高累積降雨區域則有較明顯低估現象，




且局部強降雨中心之空間結構較不明顯。

此外，由垂直方向比較(不同仰角)可進一步分析，隨著仰角增加，累積雨量場之降雨範圍與強度皆有明顯減弱。於 0.5° 仰角時，由於雷達資料較接近地表，因此兩方法能呈現相似之北臺灣強降雨結構，且於高累積降雨區域與測站觀測之對應性較佳。然而， 0.5° 仰角易受到部分地形遮蔽影響，在雷達西南側與陽明山山區後方可觀察到較明顯之缺乏資料扇形區域。當仰角提升至 1.5° 後，雖部分地形遮蔽現象減少，但由於觀測資料高度增加，北海岸強降雨區域累積雨量開始下降，且降雨範圍略有縮小。此時 MLP 仍維持相對完整之降雨核心結構，而 PLF 方法的降雨核心則有較明顯之弱化與擴散情形。到了 2.4° 後，雷達資料高度進一步上升，降雨系統高層與地表降雨之垂直差異更加明顯，因此兩種方法皆呈現累積雨量大幅下降與降雨範圍持續縮小之現象。尤其於北臺灣陸地區域，可觀察到高累積雨量核心區域與 1.5° 相差 50~100 mm，凸顯高仰角觀測資料容易使 MLP 以及 PLF 方法低估地表強降雨。而在 2.4° 小間距比較方面，MLP 於雷達西南側山區之累積降雨(約 120~200 mm)相較 PLF 方法(60~140 mm)更接近該區域測站累積雨量(200~280 mm)。

此個案兩方法皆能反映梅雨鋒面降雨代之主要空間分布，但兩者於強降雨核心之空間結構與降雨梯度呈現上仍有明顯差異。MLP 對局部強降雨與地形相關降雨結構較為敏感，能保留空間變化上的細節；而 PLF 方法則呈現出較為平滑且平均之降雨場特性。隨著仰角增加所造成之降雨低估與空間結構弱化現象，亦顯示高仰角觀測下仍存在明顯之垂直降雨結構誤差。

2) 20190517 事件累積降雨

由低仰角累積雨量場(圖 3.7)橫向比較(MLP 與 PLF)，兩方法皆呈現出降雨核心位於北臺灣西南方向海面之特徵，並沿西南-東北方向延伸至北臺灣沿岸地區之降雨結構。由大間距色階累積雨量場可發現，兩方法之高累積降雨核心位置與降雨範圍差異相當有限，整體雨帶結構相似。於小間距色階下，可觀察北臺灣陸地區域之中低降雨分布，兩方法



皆出現越靠近內陸而越容易出現 20~40 mm 的低估現象。

由垂直方向比較(不同仰角)進一步分析，當仰角提高至 0.9° 與 1.3° 時，兩方法之主要降雨核心仍維持於西北側海面，但陸地區域降雨範圍已開始慢慢縮小。到 1.8° 與 2.4° 仰角時，此現象更加明顯，強降雨核心幾乎侷限於西北側海面，陸地區域累積降雨原先低仰角 200~320 mm 銳減至 60~180 mm，部分於低仰角可觀察到之雨帶亦逐漸消失。由於本個案之降雨系統高度較低且生命週期較短，因此高仰角觀測對近地表降雨之代表性下降更加明顯。尤其於 2.4° 仰角下，兩種方法皆呈現出降雨範圍快速縮減之現象。

3) 20190520 事件累積降雨

首先由低仰角之水平比較進行分析(圖 3.8)。在 0.5° 以及 0.9° 主要降雨區域嚴重受到雷達西北側山區迎風面地形遮蔽影響，無法呈現完整降雨核心結構。而由大間距色階下可發現在總降雨量 150 mm 以下區域 MLP 方法的延伸性相對較好，PLF 的降雨強度梯度下降快速。從小間距色階可以更好的發現此現象，MLP 於臺北盆地北側與西北海岸區域附近維持較完整之中高降雨帶，部分測站高降雨區域附近亦具有較連續之降雨結構；相較之下 PLF 於陸地區域雨帶分布較不連續，局部高值與低值交錯情形較明顯。此外，兩種方法皆可觀察到北側強降雨核心向東南方向快速衰減之特徵，顯示本次事件降雨主要仍集中於北部沿岸與外海區域。

當仰角上升至 1.3° 與 1.8° 後，主要降雨核心逐漸向北側收縮集中，陸地區域降雨範圍開始縮小。由圖 3.8.c 與圖 3.8.d 中可觀察到，臺北東南方向之降雨逐漸減弱，而北海岸附近仍有較高累積降雨。此時兩種方法在降雨核心位置上仍相當一致，但 PLF 於低降雨區域之分布較不均勻，部分區域呈現較零碎之弱降雨分布；MLP 則呈現較平滑之降雨場，但在部分邊界區域亦可觀察到降雨強度略為擴散之情形。到了 2.4° 後，整體降雨範圍再次縮減，此時兩種方法均顯示高仰角觀測下之降雨場較偏向高空降水結構，臺北盆地內部之降雨訊號明顯減弱，整體降雨區域逐漸內縮至降水核心(北海岸外海)，而 MLP 之雨量分布較 PLF 來的平滑。整體而言，20190520 個案之主要差異並非降雨核心位置，



而是兩種方法對低降雨背景場與局部空間連續性之表現不同。MLP 於多數仰角下呈現較平滑且連續之降雨分布，而 PLF 則較容易出現局部零散高值與弱降雨分布擾動。

3.4 誤差空間分布

在三個案的誤差空間分布中，本研究以選定範圍內的自動雨量站觀測為真實值，並在降雨估計網格中找到最靠近自動雨量站的網格點，計算該點的個案 RRMSE 與 NMB，並分析 2.4° 以下所有仰角的誤差空間分布變化(圖 3.9 至圖 3.11)。

以梅雨強對流降雨個案來說，PLF 方法與 MLP 深度學習估計之降雨沒有特別顯著的落差，以 20170602 與 20190520 個案來看，兩個案因為降雨分布與系統移動方向皆相似，在誤差空間分布表現上也有相似的結果。從各仰角的 RRMSE 在測站位置的呈現來說，低仰角兩方法的誤差分布主要受到資料點與雷達距離的影響，當所在的網格離雷達中心較遠時，普遍上 RRMSE 會相較距離雷達較近的網格點來的大，而 MLP 方法的 RRMSE 在低仰角大部分的測站位置皆可維持 RRMSE 小於 0.4 以下的表現。在 20190517 個案中降雨位置主要集中在距離雷達較遠的西南方沿岸以及外海，可以發現在 1.3° 以下的 RRMSE 與 NMB 誤差分布在降雨較大的桃園沿岸兩方法有比較明顯的差距，尤其越靠近降雨核心 MLP 方法的 RRMSE 與 PLF 的差距會來的更大。

兩方法比較明顯的差異會出現在高仰角的降雨估計中，當使用的仰角上升至 1.8° 以及 2.4° 後，PLF 方法於三個個案皆開始出現較多高 RRMSE 測站，且高誤差測站主要分布於距離雷達較遠或鄰近主要降雨區域的位置；相較之下，MLP 方法雖然誤差亦隨仰角增加而上升，但高誤差測站數量明顯較少，大部分測站仍維持較低之 RRMSE。而 NMB 的高仰角降雨估計誤差分布，兩方法高仰角估計容易出現局部較大的正偏差或負偏差，尤其是山區或山區附近的位置。


第四章 垂直修正模型結果



由於對流降水在垂直結構上變化快速，且上下層結構差異大，導致使用不同仰角觀測同一對流胞會有不同的雙偏參數分布及強度，再者，雨滴落下的過程涉及諸多雲微物理過程，在傳統幕律式定量降水估計中尋求使用最靠近地面之有效參數來代入方程式，因此若有地形阻擋導致須使用較高仰角來補足受干擾地區之降水估計，勢必會影響降水估計的準確性。圖 4.1 五分山雷達掃描半徑 100 公里內的最低有效資料高度分布，主要在西南方向受到雪山山脈與部分中央山脈地形影響，其中由方位角 216° 之地形剖面圖中(圖 4.2)，經過雪山群峰方向可發現地形高度隨距離快速增加，超過 50 公里外的地區僅剩 1.5° 以上仰角觀測能涵蓋後續地區。其次是在西北側會受到陽明山群峰影響，抬升最低有效觀測高度，且西北側沿海位於山後地區也被迫須使用高仰角觀測資料，由圖 4.3 可得知不同仰角之波束高度差異亦會隨距離增加而逐漸擴大。在近雷達區域，各仰角間之高度差相對有限；然而於遠距離區域，高仰角與低仰角之間的觀測高度差可達數公里以上。此結果說明雷達於遠距離觀測時，不同仰角所觀測之降水結構可能具有顯著垂直差異，因此容易造成高仰角降雨估計與地表實際降雨之間產生偏差，且由於五分山雷達固有的高度，觀測高度影響實際地表降雨率的程度會來的更大。

4.1 降雨修正後比較

圖 4.4 為 20170602 個案在 060202UTC 至 060205UTC 分別使用 PLF、MLP 以及經過垂直修正(2.4° 修正至 1.5°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。在第一小時未修正前的兩方法大部分能與測站的降雨級距相符，少部分位於降雨強度 50 至 70 mm/hr 的測站位置會出現些許低估的情況，經過修正後原觀測降雨級距於 110 至 120 mm/hr 的周遭降雨分布整體上升，且於降雨核心區域強度擴大，90 mm/hr 以上區域相較於修正前有向外擴散的情形。到了第二個小時強降雨面積重建的情形更為明顯，陽明山至八里一帶 90 mm/hr 區域擴大並一路往西延伸。而修正效果最好的為 04 UTC，在修正前 PLF 以及 MLP 的降雨結果與實際觀測紀錄之降雨量差距在 20 至 40 mm，經過



垂直修正整體強降雨至弱降雨的分布與變化更為平滑，且強降雨核心的誤差也較修正前來的更小。此外，由圖 4.5 之三方法散佈圖結果也可發現，在未經修正前，PLF 以及 MLP 方法在降雨強度 15 mm/hr 以上開始有明顯的低估情形，而 60 mm/hr 以上強度 MLP 的低估狀況更為嚴重，此二方法之結果顯示單純使用高仰角觀測進行降水估計仍會受到資料高度與垂直降水結構差異影響。而經過修正後，散佈點整體更接近一比一參考線，特別是在中強降雨率區間，原先偏低之估計值明顯向上修正。評估指標亦顯示修正後 RRMSE 由 MLP 之 0.4446 降低至 0.2686，NMB 由 -0.1728 改善至 0.0773，原始高仰角估計降雨之負偏差大幅減少。不過，修正後部分弱至中降雨強度樣本出現些許高估之情形。

20190517 梅雨個案則是整體雨帶較弱，圖 4.6 顯示此個案在 051705 至 06 UTC 分別使用 PLF、MLP 以及經過垂直修正(2.4° 修正至 1.3°)的累積雨量分布圖。在 05 UTC 中，降雨強度大多集中在 8 至 32 mm/hr 之間，在雷達西南方沿海有少數測站紀錄該小時降雨量達 60 至 72 mm 但 PLF 及 MLP 估計之降雨量僅 24 至 32 mm，且在上方之估計雨帶有與周圍差異較大的小範圍不連續極值(64 至 72 mm)出現，該地區的觀測降水為 24 至 32 mm 區間。經過修正後整體降雨強度變化幅度較為平滑，結構更為完整，但雷達西南方接近沿海之少數測站極值範圍未獲得明顯的改善，依然維持與修正前類似的降雨強度，而在 06 UTC 時間之降雨分布圖可發現，相較於修正前，修正後可更容易地觀察到降雨強度由 48 往下遞減至 16 mm 的梯度範圍。由 20190517 個案 2.4° 仰角之一小時累積雨量散佈圖(圖 4.7)可進一步觀察垂直修正前後之差異。整體而言，此個案降雨強度較 20170602 弱，測站雨量多集中於 0 至 30 mm/hr 區間，因此散佈點主要聚集於弱至中等降雨範圍。未經修正前之 PLF 與 MLP 散佈圖結果，資料點於弱雨強度區域具有較大離散情形，當降雨強度增加至 20 至 40 mm/hr 後，可觀察到部分估計值逐漸低於測站觀測值。此外，散佈點之垂直離散度較大，表示不同測站間估計穩定性仍存在一定差異。其 RRMSE 為 0.6630，相關係數為 0.7379，顯示高仰角資料下兩方法對降雨變化之掌握能力較有限。垂直修正後的散佈圖，強降雨區的低估現象雖有獲得改善，然而，修正後之

NMB 為-0.0653，相較 MLP 原始結果略呈現低估，表示垂直修正雖改善整體散佈結構與誤差，但部分區域降雨強度仍存在輕微低估情形。整體而言，此個案中垂直修正主要改善了中等降雨區間之估計一致性，使高仰角觀測結果更接近低仰角降雨特徵。

圖 4.8 為 20190520 梅雨個案在 052000 至 03 UTC 分別使用 PLF、MLP 以及經過垂直修正(2.4° 修正至 1.3°)的累積雨量分布圖。在此四個連續小時之降雨量分布圖中，主要的修正為將雨帶中由降雨極值的範圍往外擴散，重建較為有序的降雨梯度變化，使得整體雨帶數值更為平滑且減少雨量場的波動。在 01 UTC 的累積雨量圖分布來說，在修正前雷達西北山區的迎風面降雨區地面雨量站觀測到降雨強度 64 至 72 mm 範圍，但 PLF 的降雨估計在其周圍大約僅有 40 至 50 mm，MLP 方法中雖然再往外海一些區域範圍內有零星區域達到更強的累積降水，但此雨帶之強降雨核心數值分布不均。而經過修正後該區域測站觀測累積雨量與修正後估計降雨分布有所匹配。另外，在 02 UTC 的累積雨量圖中，未經修正的 PLF 降雨估計在 64 mm 以上的區域較為西側且後側強降雨範圍較為零散，而 MLP 之 64 mm 以上強降雨帶雖略有延伸至東側一些，但位於雷達西北山區的測站周圍之估計降雨量仍未達觀測之降雨強度區間，修正後(2.4° 修正至 1.3°)的降雨分布圖可以發現，除了既有的強降雨區降雨強度有所增強外，該雨帶一併將降雨核心延伸至山區範圍，且北海岸之降雨強度也成功接近該區域測站所觀測之累積雨量。圖 4.9 則為 20190520 梅雨個案之 PLF、MLP 以及 2.4° 修正至 1.3° 降雨估計散佈圖。PLF 與 MLP 顯示其降雨估計普遍於降雨強度 20 mm/hr 以上開始出現明顯低估，低估幅度隨著降雨強度上升而有所增加，出現 NMB 約為-0.15 以上之負偏差，而修正後個案降雨率散佈圖主要改進中強降雨強度的低估情形，並成功將負偏差縮小至 NMB 為-0.057，且進一步提升估計準確性，其 RRMSE 由修正前 0.4178 改善至 0.2311，相關係數提升至 0.9571，代表垂直修正有效補償了高仰角觀測下之降雨低估問題。

4.2 空間誤差分布

使用高仰角資料進行定量降水估計時不論是使用傳統冪律式(PLF)或是深度學習模型(MLP)，主要會出現明顯相對於使用低仰角之低估情形為距離雷達較遠或是地形後方



區域。藉由分析測站附近之降雨估計情形，比較使用垂直修正模型前後的評估指標差異，在所使用之三個梅雨個案中，為考量強降雨所造成之低估影響程度，以下降雨估計評估空間分析僅採納觀測降雨大於每小時 5 mm 以上之樣本，分別使用 RRMSE 以及 NMB 來觀察誤差之空間分布。

使用仰角 2.4° 之 20170602 個案由事件累積雨量分布圖與測站觀測比較(圖 4.10)可發現，臺北盆地延伸至南方山脈方向有較明顯之低估情形，普遍測站可觀測 220 至 280 mm 累積雨量，而未經修正前之降雨估計(MLP)僅呈現 120 至 200 mm 累積雨量，由 NMB 空間分布亦可觀察到整體降雨估計與測站觀測間為負偏差，數值約為-0.2 至-0.6。經過垂直修正後，此個案整體降雨空間分布並未改變主要降雨核心位置，但可明顯觀察到中高雨量區域出現增強現象，北海岸至雷達北方海面累積降雨 400 mm 以上區域之面積擴大，往東西方向擴張；另外，臺北盆地西側、雷達西南方區域一路延伸至雪山山脈一帶亦有明顯增強雨量之情形，使估計降雨分布更接近地表雨量站所觀測之累積降雨。原始 MLP 之 RRMSE 分布雖大多落於較低誤差範圍，但北海岸山區、西側山區以及部分背風側地區仍存在較高誤差側站。由修正結果可發現，多數測站之 RRMSE 顏色轉為較低值區間，估計誤差普遍下降，尤其於雷達西北方山區一帶。而修正後 NMB 分布多數測站逐漸接近零值，尤其北部山區與西南側山區更為明顯。

圖 4.11 比較 20190517 個案於 2.4° 仰角 MLP 估計之事件總累積雨量場與經垂直修正(2.4° 至 1.3°)之結果，並搭配測站位置 RRMSE 及 NMB 空間分布進行分析。由原始 MLP 累積雨量場可發現，100 mm 以上累積雨量區域約出現 40 至 100 mm 的估計與觀測差距，而雖然林口台地與臺北盆地一帶並非主要降雨核心區域，但該區之 RRMSE 與 NMB 數值較大，呈現相對較大的誤差。修正後整體累積雨量分布差異不大，僅北海岸附近及盆地西側部分區域出現累積雨量提升現象，從測站 RRMSE 空間分布來看，修正前後多數測站未有明顯改善，修正幅度不如前一個案來的明顯，由 NMB 空間分布來看，在累積降雨 50 mm 以上之範圍數值顯示原始之負偏差有獲得些許改善，尤其在雷達中心西南方一帶與臺北盆地一帶則無明顯變化甚至出現負偏差惡化情形。在此個案中，垂直修正



模型之主要增益在於區域細部雨量調整，在維持原有降雨結構以外，增強部分中高雨量區域並降低該區域之負偏差。

圖 4.12 則是比較 20190520 個案於 2.4° 仰角 MLP 估計之事件總累積雨量場與經垂直修正(2.4° 至 1.3°)之結果。在原始 MLP 累積雨量分布圖中，主要的低估情形發生在雷達西北方山區西側與南側，南側的模型累積雨量與觀測差距約為 40 至 50 mm，而西側之累積雨量差距則較大，約為 60 至 70 mm，該區域之初始 NMB 數值呈現-0.3 至-0.4。在此問題方面，垂直修正給予部分區域將累積降雨量差異縮小但並未完全解決西側與南側之低估情形，而此個案主要將部分臺北盆地西南方周圍之 RRMSE 修正至小於 0.2。在強降雨核心此修正模型將累積降雨 150 mm 以上區域向外擴散，整體而言以 2.4° 至 1.3° 之結果來看模型改善幅度輕微。

垂直修正模型在將初始 2.4° MLP 模型估計結果修正至 1.5° 或是 1.3° 仰角的修正表現，對於持續時間較長且降雨範圍較廣之梅雨鋒面系統，其改善幅度最為顯著；而對於局地短時強降雨事件，雖然雨量場修正前後變化有限，但仍可降低 RRMSE 並提升相關性。尤其在 20190520 個案中，在修正後 RRMSE 空間分布呈現垂直修正模型對於輕微至中度低估區域具有良好修正能力，而對於受到地形遮蔽或其他誤差來源影響之嚴重低估區域，改善幅度相對有限。

4.3 多仰角分析

由高仰角 2.4° 修正至 1.5° 或 1.3° 的結果可以得知將降雨估計結果往下層修正確實能改善原始高仰角的誤差，不管是 RRMSE 或是正負偏差的空間分布均能有一定程度的改進，而在三個案中高仰角 2.4° 至最低觀測仰角 0.5° 間仍有多個仰角觀測資料，故此小節將著重分析 2.4° 仰角降水估計修正至多個仰角的不同高度差修正。

4.3.1 不同高度差修正

1) 20170602 個案




由於五分山雷達掃描策略改動於 2019 年 4 月份，20170602 梅雨個案 2.4° 以下的掃描策略僅包含 1.5° 以及 0.5° ，故表 4.1 整理了未進行垂直修正之 PLF 與 MLP 三仰角之降雨估計評估指標，包含相對方均根誤差(RRMSE)、標準化平均偏差(NMB)與相關係數(CC)，以及高仰角 2.4° 分別修正至 1.5° 以及 0.5° 之三項評估指標。在未經垂直修正前的三仰角誤差表現來看，高仰角的誤差 RRMSE 大約會介於 0.4 至 0.45 之間，而 MLP 方法中的 1.5° RRMSE 數值則是降低至 0.2765。經過垂直修正後的誤差評估表現，首先由 2.4° 修正至 1.5° 的結果來看，可以發現其 RRMSE 數值為 0.2686，相比於原始之 2.4° PLF 與 MLP 方法來說，改善幅度相當明顯，且在負偏差的改進方面由-0.18 修正至 0.0773 也側面說明了此個案垂直修正模型的修正方向。而將 2.4° 修正至 1.5° 以及 2.4° 修正至 0.5° 的結果與原始 MLP 方法的 1.5° 以及 0.5° 比較來看，數值方面 RRMSE 甚至能與修正目標仰角支原始降雨估計表現相當。由圖 4.13 的散佈圖來看， 2.4° 修正至 1.5° 與 MLP 初始 1.5° 皆呈現均勻分布在一比一參考線相當靠近的兩側，除了 2.4° 修正至 1.5° 在降雨強度接近零的樣本有些許高估的情形外，均無明顯的偏差；而 2.4° 修正至 0.5° 與 MLP 初始 0.5° 估計結果則是在修正後的散佈圖可觀察到弱降水的高估狀況，MLP 初始 0.5° 則是在 60 mm/hr 以上的強降水樣本有輕微的負偏差出現，相比之下 2.4° 修正至 0.5° 在該強度的樣本表現雖無更為靠近參考線，但整體來說樣本正偏差與負偏差分布平均，這或許是 RRMSE 數值上 2.4° 修正至 0.5° 可以下降至 0.2590 而 MLP 初始 0.5° 仍有 0.2961 的差異所在。

在此個案的多仰角高度差修正來說，不論是將 2.4° 修正至 1.5° 或是 2.4° 修正至 0.5° ，相對於原始使用 2.4° 資料進行降水估計的 PLF 或是 MLP 來說皆有明顯的修正幅度，且將修正結果與修正目標仰角的降水估計來比較，也可以發現評估指標呈現表現相當甚至也有輕微的性能提升。

2) 20190517 個案

在此個案中，由表 4.2 可看到 MLP 方法之 RRMSE 由 0.5° 的 0.4588 上升至 2.4° 的 0.5871，而 PLF 方法之 RRMSE 由 0.5° 的 0.4840 上升至 2.4° 的 0.6630，可知此個案使用低仰角觀測資料進行降雨估計初始就容易有較高之誤差，且由於 NMB 數值無明顯正負




偏差，可說明該個案整體呈現不同強度的高估低估分布平均，相關係數僅 0.8，故一旦使用更高仰角來估計降雨則誤差即快速上升。多仰角高度差修正將初始 2.4° 降雨估計分別修正至 1.8° 、 1.3° 、 0.9° 以及 0.5° 的高度，在修正到最小高度差 1.8° 時，相較於初始 2.4° 的 RRMSE 將近 0.6，修正後之相對方均根誤差隨即下降至 0.4817，除了 NMB 無明顯變化以外，相關係數更是由 0.7884 上升至 0.8473，觀察 2.4° 修正至 1.8° 之降雨估計樣本散佈圖更是可以發現(圖 4.14)，經過垂直修正後的降雨估計，首先於原始降雨率 $< 5 \text{ mm/hr}$ 的高估情形更為分散在一比一參考線的兩側，而 15 mm/hr 降雨強度以上的低估情形也開始有較為明顯的改善。隨著修正目標仰角逐漸下降， 2.4° 修正後的 RRMSE 也逐步由 0.4817(2.4° 修正至 1.8°)下降至 0.4211(2.4° 修正至 0.5°)，而從其中的下降程度也可以發現修正目標仰角低於 1.3° 以後，RRMSE 的改善程度逐漸收斂。此外，將修正後的結果與修正目標仰角的初始降雨估計來比較，修正後的 2.4° 降雨估計表現均能相比初始兩方法的降雨估計，不論是 RRMSE、NMB 或是相關係數等評估指標來的好，且由修正後的降雨估計散佈圖來看，樣本的分布也隨著修正目標仰角下降而慢慢往參考線集中，相關係數最好的項目為 2.4° 修正至 0.5° 達到將近 0.87。

此梅雨個案之強降水由雷達西南方向外海由西南往東北方向往內陸移動並逐漸減弱降雨強度，初始之 2.4° 散佈圖強降雨低估來自於仍處於西南方外海至陸地沿岸的測站樣本，此區域已位於雷達觀測範圍半徑 60 公里以外，高仰角資料高度上升快，此區域修正屬於增強高層降雨結構，促使高仰角資料的降雨估計可以更接近低層降水的強度。

3) 20190520 個案

在 20190520 個案中(表 4.3)，初始 MLP 方法降雨估計 2.4° 仰角之 RRMSE 為 0.4178，NMB 為-0.1757，相關係數 0.9284，顯示此個案於未經垂直修正下的高仰角資料估計表現雖具有良好的相關性，但整體仍存在明顯負偏差，表示高仰角估計對實際降雨有低估現象。此外，相較於 PLF 方法，MLP 已能降低部分誤差，但由 2.4° 初始散佈圖可見(圖 4.15)，當樣本降雨強度超過 20 mm/hr 時，估計值仍多落於參考線下方，顯示出高仰角資料對強降雨的低估問題。經過仰角間垂直修正後，整體而言評估指標呈現明顯改善。




其中，將 2.4° 修正至 1.8° 時，RRMSE 數值由 0.4178 大幅下降至 0.2173，NMB 由 -0.1757 改善至 -0.0167，相關係數亦略有提升，為此梅雨個案多仰角修正中最好的修正目標仰角結果。由 2.4° 修正至 1.8° 的散佈圖可觀察到，降雨估計樣本明顯往參考線集中，特別是先前大於 20 mm/hr 明顯低估的中強降雨區間，原先偏低之估計值被有效向上增強。然而當修正目標仰角進一步降低至 1.3° 以下，RRMSE 數值反而由修正至 1.8° 的 0.2173 逐漸增加至 0.2311(1.3°)、0.2611(0.9°)以及 0.2754(0.5°)，相關係數亦逐漸降低。此結果顯示，對於 20190520 梅雨個案而言，修正至更低仰角並未持續帶來更好的表現，反而使估計誤差略為增加，由散佈圖可見，修正目標高度越低時，樣本雖仍大致維持於參考線附近，但中高降雨區間之離散程度逐漸增加，部分強降雨樣本仍出現低估或發散分布。從 NMB 隨修正目標仰角變化來看， 2.4° 修正至 1.8° 時初始降雨估計所包含的負偏差幾乎被修正至接近零，代表此高度差修正最能補償此個案之系統性低估。然而，修正至 1.3° 與 0.9° 時，NMB 分別為 -0.0570 與 -0.0893，負偏差又略微增加；而修正至 0.5° 時雖 NMB 回升至 -0.0516，但整體 RRMSE 與相關係數並未優於 1.8° 修正結果。

此梅雨個案之強降雨核心主要集中於北臺灣北側至北海岸附近，降雨區域較局部且強度落差明顯。初始 MLP 之 2.4° 高仰角估計之低估，在經過 2.4° 至 1.8° 之垂直修正效益良好，使中強降雨樣本估計接近測站觀測。相較之下，當修正目標高度更低時，模型須修正之垂直差異增大，降雨微物理過程與局地降雨結構變化可能更為細緻且複雜，難以同時兼顧更大的高度差修正。因此，20190520 個案顯示，對於局部性較強且降雨核心明顯之事件，適度高度差修正即可達到最佳效果，過度向低仰角修正未必能進一步提升估計表現。

4.3.2 最低有效估計

考量實際雷達定量降水估計作業中，不同方位角因地形遮擋程度不同，各位置可使用之最低有效觀測仰角(Lowest Effective Elevation)亦不盡相同。因此，實務上通常依據各網格點所對應之最低有效觀測仰角，選用適當之雷達觀測資料，並整合形成最低有效仰角之降雨估計場。本小節將初始使用 MLP 模型之最低有效降雨估計，以及將使用 0.5°




以外之其他高仰角資料往下一個仰角修正後之最低有效降雨估計，透過地面雨量站之 RRMSE、NMB 評估指標，以及事件總累積雨量場之空間分布，比較兩種方法於實際應用上的估計效益。

由三個個案之最低有效仰角降雨估計事件累積雨量圖(圖 4.16、圖 4.18、圖 4.20)可觀察到，經垂直修正後之最低有效降雨估計大致維持原始 MLP 之降雨分布，部分降雨區域經垂直修正後，其累積降雨量更接近地面雨量站之觀測結果。例如 20170602 與 20190520 梅雨個案中，北臺灣主要降雨帶以及迎風面降雨區之累積雨量均有所增加，改善原先偏低估之情形。此外，由於最低有效降雨估計係依各網格位置選用不同仰角資料，因此在不同最低有效仰角交界附近，常因不同觀測高度之降雨結構存在差異，使原始降雨場容易出現局部降雨量突變或分布不連續的情形。而經過垂直修正後的最低有效觀測降雨估計尤其在 20170602 個案更為明顯，各仰角間之降雨估計具有較一致的垂直結構，使不同仰角拼接後之降雨分布更加平滑，降低原始最低有效降雨估計於仰角交界處之不連續面。

在最低有效降雨估計修正前後之小時累積 RRMSE 與 NMB 方面(圖 4.17、圖 4.19、圖 4.21)，在經過垂直修正後，可以發現整體 RRMSE 與 NMB 皆能獲得改善，其中改善效果以中強降雨最為明顯。20170602 梅雨個案中，當小時累積降雨超過 20 mm 以上，各降雨強度區間 RRMSE 均明顯下降，且在此個案小時累積雨量越大獲得的改善幅度越顯著，高雨強區間甚至可降低至原始估計之一半左右；同時 NMB 亦由原先約-0.25 至-0.30 之系統性低估改善至更為接近 0。20190517 個案則與 20190520 有相似的變化趨勢，在小時累積降雨 30 mm 以上之中高降雨區間 RRMSE 才有更明顯的降低，NMB 亦由約-0.2 至-0.35 改善至接近零，僅於弱降雨強度區間數值存在波動甚至表現更差。

4.4 真實地形

垂直修正模型(TopoCorr-Net)在將高仰角雷達參數 9×9 的小面積網格配合由 MLP 產生的初始降雨估計，結合上層雷達資料的物理波束高度與雷達距離，輸出得到修正至下層仰角高度之垂直修正量，此仰角間修正得到一定幅度的改進。而考慮到五分山雷達




已位於海拔 750 公尺山頂，雷達波束的初始傳遞高度加上隨著傳遞距離而抬升的高度，勢必會帶給雷達定量降水估計額外的垂直結構差異，並產生較大的估計誤差。本研究額外嘗試將 2.4° 以下的所有仰角雷達資料，將模型設定中初始設定的目標仰角改為真實地形高度(圖 4.22 至圖 4.24)，透過垂直修正模型使雷達定量降水估計達到真實地表降水量。此外，由於不同仰角至地表之高度差異範圍並不一致，因此本研究分別採用兩種不同高度差修正核心進行測試。Kernel1 為設定高仰角差修正核心，其訓練樣本來自較大高度差之仰角組合，預期能學習較明顯之垂直降雨結構變化；Kernel2 則為設定短高度差修正核心，其訓練樣本來自相鄰仰角間較小高度差之修正關係，預期能描述較局部且細緻之垂直變化特徵。

4.4.1 高仰角差修正核心

高仰角差修正為使用 2.4° 之三雷達參數小範圍網格以及降雨率，結合雷達波束物理資訊，修正目標仰角為 0.5° ，為 2.4° 以下所含仰角之最大高度差。表 4.4 至表 4.6 分別為三個案 2.4° 以下所有仰角修正至真實地形高度之估計降雨率評估指標，包含 RRMSE、NMB 以及相關係數，其中 2.4° 至 0.5° 為高仰角差修正核心(Kernel1)。首先由 20170602 梅雨個案的套用情形來看，在使用 Kernel1 分別將 2.4° 、 1.5° 與 0.5° 之 MLP 初始估計降雨率修正至地表時，修正後之誤差 RRMSE 數值隨著欲修正仰角下降而增加，而 NMB 亦隨著誤差提升而逐漸增加正偏差幅度。在 2.4° 修正至地表降雨率的散佈圖中，大部分的樣本分布皆相當靠近參考線並均勻分布於兩側，而僅在 10 mm/hr 以下弱降雨樣本有輕微高估之情形；而在 0.5° 散佈圖可發現，雖然整體分布依然沒有明顯的偏差情形，但由於均勻分布於參考線兩側且相較高仰角修正結果更為發散，故誤差評估指標項 RRMSE 數值居高不下，也透露出相對更接近地表的低仰角估計降雨率在進行垂直修正上難以超越 MLP 原始估計結果。

到了 20190517 梅雨個案，可由降雨強度在散佈圖上的分布區分其所距離雷達距離，此個案強降雨普遍分布於距離雷達西南側 60 公里外的沿岸上方，而弱降水樣本則大致由西南至東北方向往臺北盆地延伸。若單看未修正前的各仰角 PLF 以及 MLP 所估計降




雨之 RRMSE 修正後明顯較佳，且各組結果之相關係數皆維持於 0.84 以上，顯示垂直修正模型仍能在原始估計降雨結構上有明顯修正效益。然而，相較於仰角間修正結果，修正至地表後之 NMB 普遍轉為正值，表示模型傾向增加降雨量並產生明顯高估現象。其中以 0.9° 修正至地表較佳，隨著初始仰角逐漸升高，修正所需之垂直高度差增加，模型所產生之修正降雨率過修而導致高估的情形擴散至大部分樣本。

在 20190520 個案中，個仰角修正至真實地表高度後之結果差異相當有限，RRMSE 普遍落在 0.26 至 0.28 之間，相關係數皆維持於 0.93 以上，而 NMB 在各仰角的結果也未出現明顯高估或低估偏向。但由散佈圖樣本可觀察，在弱降水 10 mm/hr 以下表現良好，幾乎分布於參考線兩側；但隨著降雨樣本逐漸增強，在散佈圖上的分布也逐漸發散，至 40 mm/hr 以上之較強降雨區間，雖然樣本數少但離散程度增加至最大。不過，在不同仰角之間， 0.5° 、 0.9° 、 1.3° 與 1.8° 修正結果的樣本分布相當接近，整體 RRMSE 數值也幾乎一致，代表此個案中由不同高度層推估至地表時，模型皆能維持類似的降雨強度排序與整體分布。

4.4.2 低仰角差修正核心

而 1.5° 至 0.5° 為低仰角差修正核心(Kernel2)，主要使用對象為 1.5° 以下之仰角降雨估計修正至真實地形高度。在 20170602 個案中，使用 Kernel2 將 1.5° 降雨估計修正至地表，結果顯示在 20 mm/hr 以上降雨強度的樣本偏向正偏差，導致 NMB 數值為 0.1896，而相對於修正前以及使用 Kernel1 所修正之 1.5° 降雨估計，在中強降雨區間分布較為發散，故 RRMSE 也接近 0.3 呈現負修正效益的情形。在此個案最低仰角 0.5° 修正結果亦呈現無明顯偏差但整體分布較分散，RRMSE 為 0.324。其餘兩個案在使用 Kernel2 修正至地表降雨率之結果整體而言最好的修正效益均出現在 0.5° 仰角，20190517 個案在 NMB 數值上最低仰角 0.5° 接近零，但當使用的仰角上升而過修導致的正偏差逐漸上升，在 1.3° 修正至地表之偏差達到 0.3195；而在 20190520 個案在使用 Kernel2 的修正情形整體與使用高仰角差修正核心 Kernel1 效果相差無幾，無論是比較 RRMSE 或是 NMB，修正效益在樣本降雨強度超過 30 mm/hr 後分布逐漸發散。



總結三個個案使用低仰角差核心修正至地表降雨率的結果，除了 20170602 個案外，在使用初始最低仰角修正結果均會比更上層的仰角來的好。本研究預期在使用此修正核心將降雨率修正至真實地形時，應用在中低仰角可能會因此核心學習來自中至低仰角較為細節之降水結構或強度變化，而最後在評估指標與散佈圖的表現來說，僅在使用 0.5° 的仰角修正至真實地形可以較同條件下使用 Kernell 結果來的好。

第五章 結論與未來展望



5.1 結論

本研究以北臺灣五分山 S 波段雙偏極化雷達，探討深度學習方法於雷達定降水估計 (RQPE) 以及降雨估計垂直修正之應用。首先利用 NCUJWD 十年雨滴粒徑分布資料透過 T-matrix 模擬對應雙偏極化雷達參數，建立 MLP 深度學習定量降水估計模型；其次則進一步設計垂直修正模型 TopoCorr-Net，使模型學習基於單一掃描時間下不同觀測高度間之降雨變化，改善高仰角雷達資料於複雜地形環境下所造成之垂直結構誤差。主要研究結果如下：

1. MLP 定量降水估計模型以雷達反射率(Z)、差異反射率(Z_{DR})與比差異相位差(K_{DP})作為輸入參數，利用多層感知器結構學習雷達參數與降雨率之間的非線性關係。模擬誤差測試結果顯示，MLP 模型於多種模擬觀測誤差等級環境下皆較傳統降雨率律式(PLF)具有更低之 RMSE，尤其於多參數輸入組合時表現最為穩定，揭示深度學習模型對雷達觀測誤差具有較佳容忍能力與適應狀況。

在實際梅雨個案分析中，MLP 模型於各仰角資料之降雨估計表現普遍優於 PLF 方法，在 RRMSE、NMB 及相關係數等評估指標上均有穩定改善。其中低仰角資料通常具有最佳估計降雨能力，而隨著觀測仰角上升，因雷達波束高度抬升導致估計誤差逐漸增加，但 MLP 模型仍能維持較傳統方法更加之降雨估計性能。

2. 為改善高仰角觀測所造成之垂直方向上降水估計誤差，本研究提出 TopoCorr-Net 垂直修正模型。模型利用多層 9×9 局部空間尺度之雙偏極化雷達參數與 MLP 初始降雨估計結果，結合雷達波束物理資訊例如雷達資料高度、仰角間資料高度差及觀測距離，學習不同高度層間之降雨變化量。

三梅雨個案分析結果可得知，TopoCorr-Net 能有效改善高仰角降雨估計之低估現象。




整體而言，較小高度差修正(如 2.4° 修正至 1.8° 或 1.5°)具有較穩定之改善效果，RRMSE顯著下降，NMB亦更接近零，相關係數同步提升。其中20170602長時間大範圍梅雨個案改善幅度最為明顯，顯示模型對於具有穩定垂直結構之降雨系統具有良好修正能力；而20190517及20190520局部對流個案亦能有效修正強降雨核心區域之低估現象，但隨修正高度差增加，其改善幅度逐漸趨於飽和。此外，空間分布分析顯示，修正效果主要集中於距離雷達較遠及受地形影響較明顯之區域。此結果說明TopoCorr-Net確實能學習高層至低層降雨結構之轉換關係，並有效降低因觀測高度增加所產生之系統性偏差。

3. 進一步將垂直修正模型延伸應用至真實地表高度修正，分別利用長高度差修正核心(Kernel1)與短高度差修正核心(Kernel2)探討不同訓練策略之效益。整體而言，當修正目標由低層仰角延伸至真實地表高度時，模型仍可維持一定程度之降雨估計能力，但改善幅度普遍低於仰角間修正結果。此結果顯示，真實地表與雷達觀測高度間之降雨微物理變化較為複雜，除垂直高度差外，亦可能受到地形抬升、局部對流發展、蒸發及降水粒子成長等因素影響，使模型較難僅透過有限高度資訊完整重建地表降雨結構。此外，比較兩種修正核心修正結果可發現，Kernel2(短高度差修正核心)在低仰角修正至地表時僅能維持初始估計降雨的穩定性，鮮有正效益之修正結果，而Kernel1(長高度差修正核心)則較能處理高仰角至地表之大高度差修正問題。結果證明利用深度學習方法直接建立雷達觀測高度與真實地表降雨間之轉換關係具有可行性，並不會造成較嚴重的錯誤修正方向。

5.2 未來展望

本研究有效地建立基於雙偏極化雷達參數之深度學習定量降水估計模型(MLP)以及垂直修正模型(TopoCorr-Net)，並驗證其於北臺灣梅雨強降雨事件中的應用潛力。然而仍有部分限制與值得進一步探討之方向。

首先，在定量降水估計模型方面，本研究之訓練資料主要來自雨滴粒徑分布反演資



料，實際個案分析則以梅雨期間之強降雨事件為主，因此模型對於梅雨鋒面系統與對流性降雨具有較佳之估計能力。然而臺灣降雨型態多元，包含颱風降雨、午後熱對流、春季鋒面降雨以及冬季東北季風降雨等不同天氣系統，各類降雨事件在雨滴粒徑分布、雙偏極化雷達參數特徵以及降雨垂直結構上皆具有明顯差異。未來可針對不同季節雨天系統態調整納入訓練之樣本分布與權重，提高模型於不同天氣系統下之泛化能力。此外，本研究目前採用單一 MLP 模型進行降雨估計，未來可進一步發展具有初期降雨型態辨識能力之架構，先利用三個雙偏極化雷達參數場之空間分布特徵判斷目前天氣系統或降雨型態，再依據辨識結果選擇最適合之降雨估計模型或參數配置。透過此方式，有機會建立適用於臺灣全年各類降雨事件之統一深度學習定量降水估計系統，降低單一模型於特定降雨型態下之限制。


在垂直修正模型方面，本研究所開發之 TopoCorr-Net 訓練資料主要來自梅雨個案不同仰角間之雷達參數場與初步降雨估計結果，因此模型所學習之垂直降雨變化仍以梅雨類型為主。實際上，不同天氣系統之垂直降雨結構具有明顯差異，例如颱風降雨通常具有較深厚且較均勻之降水結構，而午後熱對流發展時間短變化快速，常伴隨劇烈且局部化之垂直變化。因此未來可進一步擴充不同降雨事件與不同季節之訓練資料，使模型學習更多樣化之垂直降雨結構，提高其於不同天氣環境下之修正能力與穩定性。


最後，在修正至真實地表高度之研究方向，本研究結果呈現由雷達觀測高度直接修正至地表高度具有一定可行性，但其改善程度仍有限。原因在於現有的訓練資料中要使模型能學習正確的低仰角修正至地表的細節變化，參數的使用依然太少。未來可考慮額外設計專門針對地表降雨修正之深度學習架構，例如引入多仰角三維雷達資料、地形高度場、地理位置資訊以及更多時間序列特徵，或利用 U-Net、Transformer 等具備較強空間特徵提取能力之模型，以建立更完整之雷達至地表降雨映射關係，進一步降低低仰角觀測與真實地表降雨之間的估計誤差，提升複雜地形區域之雷達定量降水估計能力。



參考文獻

- 劉倩瑜，2023：「評估北台灣 S 波段雙偏極化雷達定量降水估計垂直修正之效益」。國立中央大學碩士論文，82 頁。
- 紀博庭，2005：「利用中央大學雙偏極化雷達資料反求雨滴粒徑分佈及降雨率方法的研究」。國立中央大學碩士論文，70 頁。
- 盧可昕，2018：「利用雙偏極化雷達及雨滴譜儀觀測資料分析 2008 年西南氣流期間強降雨事件的雲物理過程」。國立中央大學碩士論文，91 頁。
- 周仲島、鍾吉俊、修榮光，2015：S 波段雙偏極化雷達在梅雨季豪大雨天氣系統定量降雨估計之應用。 *大氣科學*, **43**, 91-113.
- 陳如瑜，2016：「S 與 C 波段雙偏極化雷達參數定量降雨估計之探討」。國立中央大學碩士論文，88 頁。
- 陳如瑜、張偉裕、陳台琦，2017：北台灣 S 與 C 波段雙偏極化雷達定量降雨估計之比較。 *大氣科學*, **45**, 57-81.
- Borga, M., Tonelli, F., Moore, R. J., & Andrieu, H, 2002: Long-term assessment of bias adjustment in radar rainfall estimation. *Water Resources Research*, **38**(11).
- Brandes, E. A., G. Zhang, and J. Vivekanandan, 2002: Experiments in Rainfall Estimation with a Polarimetric Radar in a Subtropical Environment. *Journal of Applied Meteorology*, **41**, 674-685.
- Bringi, V. N., & Chandrasekar, V. (2001). *Polarimetric Doppler Weather Radar: Principles and Applications*. Cambridge University Press.
- Cao, Q., G. Zhang, E. Brandes, T. Schuur, A. Ryzhkov, and K. Ikeda, 2008: Analysis of Video Disdrometer and Polarimetric Radar Data to Characterize Rain Microphysics in Oklahoma. *J. Appl. Meteor. Climatol.*, **47**, 2238–2255.
- Chang, W.-Y., T.-C. C. Wang, and P.-L. Lin, 2009: Characteristics of the Raindrop Size Distribution and Drop Shape Relation in Typhoon Systems in the Western Pacific from the 2D Video Disdrometer and NCU C-Band Polarimetric Radar. *Journal of Atmospheric and Oceanic Technology*, **26**, 1973-1993.

- 
- Chang, W.-Y., J. Vivekanandan, K. Ikeda, and P.-L. Lin, 2016: Quantitative Precipitation Estimation of the Epic 2013 Colorado Flood Event: Polarization Radar-Based Variational Scheme. *Journal of Applied Meteorology and Climatology*, **55**, 1477-1495.
- Chen, C., and Y. Chen, 2003: The Rainfall Characteristics of Taiwan. *Mon. Wea. Rev.*, **131**, 1323–1341.
- Doviak, R. J., & Zrnić, D. S. (1993). *Doppler Radar and Weather Observations* (2nd ed.). Academic Press.
- Fabry, F. (2015). *Radar Meteorology: Principles and Practice*. Cambridge University Press.
- Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson.
- Huangfu, J., Z. Q. Hu, J. F. Zheng, L. R. Wang, and Y. G. Zhu, 2024: Study on quantitative precipitation estimation by polarimetric radar using deep learning. *Adv. Atmos. Sci.*, **41**, 1147–1160.
- Ioffe, S., & Szegedy, C., 2015: Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, 448–456.
- LeCun, Y., Bengio, Y., & Hinton, G, 2015: Deep learning. *Nature*, **521**, 436–444.
- Levenberg, K. 1944: A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Mathematics*, **2**, 164–168.
- Loh, J. L., W. Y. Chang, H. W. Hsu, P. F. Lin, P. L. Chang, Y. L. Teng, and Y. C. Liou, 2022: Long-Term Assessment of the Reflectivity Biases and Wet-Radome Effect Using Collocated Operational S- and C-Band Dual-Polarization Radars. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-17.
- Markowski, P., & Richardson, Y. (2010). *Mesoscale Meteorology in Midlatitudes*. Wiley-Blackwell.
- Ryzhkov, A. V., & Zrnić, D. S, 1995: Comparison of Dual-Polarization Radar Estimators of Rain. *Journal of Atmospheric and Oceanic Technology*, **12**, 249–256.
- Ryzhkov, A. V., S. E. Giangrande, and T. J. Schuur, 2005: Rainfall Estimation with a Polarimetric Prototype of WSR-88D. *Journal of Applied Meteorology*, **44**, 502-515.

- 
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R., 2014: Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, **15**, 1929–1958.
- Tokay, A., and D. A. Short, 1996: Evidence from Tropical Raindrop Spectra of the Origin of Rain from Stratiform versus Convective Clouds. *J. Appl. Meteor. Climatol.*, **35**, 355–371.
- Vignal, B., G. Galli, J. Joss, and U. Germann, 2000: Three Methods to Determine Profiles of Reflectivity from Volumetric Radar Data to Correct Precipitation Estimates. *J. Appl. Meteor. Climatol.*, **39**, 1715–1726.
- W. Li, H. Chen and L. Han, 2023: Polarimetric Radar Quantitative Precipitation Estimation Using Deep Convolutional Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, vol. **61**, pp. 1-11.
- W. Li, H. Chen, L. Han and W. -C. Lee, 2024: StarNet: A Deep Learning Model for Enhancing Polarimetric Radar Quantitative Precipitation Estimation. *IEEE Transactions on Geoscience and Remote Sensing*, vol. **62**, pp. 1-13.
- Waterman, P. C., 1971: Symmetry, Unitarity, and Geometry in Electromagnetic Scattering. *Physical Review D*, **3**, 825-839.
- Zhang, Y., Bi, S., Liu, L., Chen, H., Zhang, Y., Shen, P., Yang, F., Wang, Y., Zhang, Y., & Yao, S, 2021: Deep Learning for Polarimetric Radar Quantitative Precipitation Estimation during Landfalling Typhoons in South China. *Remote Sensing*, **13**, 3157.



附表

表 2.1 模擬觀測誤差各參數誤差範圍。

Table of simulated error range

	n0	n1	n2	n3
Z	0	3.103	6.207	9.311
Z_{DR}	0	0.186	0.372	0.558
K_{DP}	0	0.08	0.161	0.246

表 2.2 PLF 與 MLP 兩方法在各參數組合為輸入，分別測試由 n0 至 n3 等級模擬觀測誤差之方均根誤差(RMSE)評估指標。

Testing set error tolerance (RMSE) with simulated noise from n0 to n3

	n0		n1		n2		n3	
	PLF	MLP	PLF	MLP	PLF	MLP	PLF	MLP
Z	2.32	2.48	2.51	2.52	3.31	2.74	7.01	5.26
K_{DP}	2.18	2.20	3.89	2.46	6.45	2.74	17.4	7.21
Z, Z_{DR}	5.37	3.31	9.54	4.56	14.6	6.81	26.5	11.6
K_{DP}, Z_{DR}	4.15	2.97	7.12	3.52	10.4	4.78	19.7	8.19
Z, Z_{DR}, K_{DP}	2.41	1.06	2.57	1.62	3.36	2.26	13.1	3.46

表 4.1 多仰角降雨估計垂直修正，個案 20170602。

Table. Evaluate metrics in cases 20170602

elev		PLF	MLP	TopoCorr-Net	
RRMSE	2.4	0.4178	0.4446	0.2686	2.4_to_1.5
	1.5	0.3559	0.2765	0.2515	1.5_to_0.5
	0.5	0.3138	0.2664	0.2590	2.4_to_0.5
NMB	2.4	-0.1884	-0.1728	0.0773	2.4_to_1.5
	1.5	-0.1084	0.0576	0.1370	1.5_to_0.5
	0.5	-0.0102	-0.0065	0.0455	2.4_to_0.5
CC	2.4	0.9121	0.9414	0.9420	2.4_to_1.5
	1.5	0.9192	0.9455	0.9489	1.5_to_0.5
	0.5	0.9222	0.9435	0.9441	2.4_to_0.5

表 4.2 多仰角降雨估計垂直修正，個案 20190517。

Table. Evaluate metrics in cases 20190517

elev		PLF	MLP	TopoCorr-Net	
RRMSE	2.4	0.6630	0.5871	0.4083	
	1.8	0.6035	0.5469	0.4817	2.4_to_1.8
	1.3	0.5776	0.5397	0.4391	2.4_to_1.3
	0.9	0.5271	0.4978	0.4200	2.4_to_0.9
	0.5	0.4840	0.4588	0.4211	2.4_to_0.5
NMB	2.4	-0.0428	0.0341	0.3070	
	1.8	-0.0538	0.0740	-0.0979	2.4_to_1.8
	1.3	-0.0858	0.0292	-0.0653	2.4_to_1.3
	0.9	-0.0538	0.0446	-0.0351	2.4_to_0.9
	0.5	-0.0532	0.0056	-0.0253	2.4_to_0.5
CC	2.4	0.7379	0.7884	0.8551	
	1.8	0.7950	0.8041	0.8473	2.4_to_1.8
	1.3	0.7856	0.8056	0.8580	2.4_to_1.3
	0.9	0.8187	0.8268	0.8639	2.4_to_0.9
	0.5	0.8266	0.8444	0.8679	2.4_to_0.5




表 4.3 多仰角降雨估計垂直修正，個案 20190520。

Table. Evaluate metrics in cases 20190520

elev		PLF	MLP	TopoCorr-Net	
RRMSE	2.4	0.4799	0.4178	0.2786	
	1.8	0.4338	0.3648	0.2173	2.4_to_1.8
	1.3	0.4060	0.3527	0.2311	2.4_to_1.3
	0.9	0.3711	0.3315	0.2611	2.4_to_0.9
	0.5	0.3424	0.3074	0.2754	2.4_to_0.5
NMB	2.4	-0.1535	-0.1757	-0.0022	
	1.8	-0.1117	-0.1275	-0.0167	2.4_to_1.8
	1.3	-0.1484	-0.1407	-0.0570	2.4_to_1.3
	0.9	-0.1327	-0.1278	-0.0893	2.4_to_0.9
	0.5	-0.1198	-0.1009	-0.0516	2.4_to_0.5
CC	2.4	0.9069	0.9284	0.9298	
	1.8	0.9043	0.9308	0.9576	2.4_to_1.8
	1.3	0.9251	0.9419	0.9571	2.4_to_1.3
	0.9	0.9305	0.9391	0.9515	2.4_to_0.9
	0.5	0.9292	0.9407	0.9363	2.4_to_0.5

表 4.4 多仰角降雨估計垂直修正至真實地形，個案 20170602。

Table. Corrected to surface evaluate metrics in cases 20170602

elev		PLF	MLP	2.4_to_0.5	1.5_to_0.5
RRMSE	2.4	0.4178	0.4446	0.2499	
	1.5	0.3565	0.2765	0.2442	0.2968
	0.5	0.2759	0.2664	0.3454	0.3446
NMB	2.4	-0.1884	-0.1728	0.0687	
	1.5	-0.1771	0.0033	0.0906	0.1896
	0.5	-0.0743	-0.0763	0.1398	0.1302
CC	2.4	0.9121	0.9414	0.9484	
	1.5	0.9307	0.9441	0.9493	0.9319
	0.5	0.9383	0.9557	0.8956	0.8960

Correct to surface

表 4.5 多仰角降雨估計垂直修正至真實地形，個案 20190517。

Table. Corrected to surface evaluate metrics in cases 20190517

	elev	PLF	MLP	2.4_to_0.5	1.3_to_0.5
RRMSE	2.4	0.6630	0.5871	0.4083	
	1.8	0.6035	0.5469	0.4212	
	1.3	0.5776	0.5397	0.4079	0.4162
	0.9	0.5271	0.4978	0.3924	0.4080
	0.5	0.4840	0.4588	0.4149	0.4062
NMB	2.4	-0.0428	0.0341	0.3070	
	1.8	-0.0538	0.0740	0.3235	
	1.3	-0.0858	0.0292	0.2290	0.3195
	0.9	-0.0538	0.0446	0.2174	0.3437
	0.5	-0.0532	0.0056	-0.0321	0.0268
CC	2.4	0.7379	0.7884	0.8551	
	1.8	0.7950	0.8041	0.8425	
	1.3	0.7856	0.8056	0.8538	0.8538
	0.9	0.8187	0.8268	0.8655	0.8652
	0.5	0.8266	0.8444	0.8612	0.8606

Correct to surface

表 4.6 多仰角降雨估計垂直修正至真實地形，個案 20190520。

Table. Corrected to surface evaluate metrics in cases 20190520

	elev	PLF	MLP	2.4_to_0.5	1.3_to_0.5
RRMSE	2.4	0.4799	0.4178	0.2786	
	1.8	0.4338	0.3648	0.2632	
	1.3	0.4060	0.3527	0.2664	0.2664
	0.9	0.3711	0.3315	0.2677	0.2782
	0.5	0.3424	0.3074	0.2760	0.2628
NMB	2.4	-0.1535	-0.1757	-0.0022	
	1.8	-0.1117	-0.1275	0.0271	
	1.3	-0.1484	-0.1407	0.0166	0.0166
	0.9	-0.1327	-0.1278	0.0340	0.0877
	0.5	-0.1198	-0.1009	0.0381	0.0925
CC	2.4	0.9069	0.9284	0.9298	
	1.8	0.9043	0.9308	0.9368	
	1.3	0.9251	0.9419	0.9358	0.9358
	0.9	0.9305	0.9391	0.9342	0.9281
	0.5	0.9292	0.9407	0.9303	0.9379

Correct to surface



附圖




圖 2.1 誤差容忍度測試，分別測試 n0(無模擬誤差)至 n3(1.5STD)誤差等級，輸入參數分別為 Z ， K_{DP} ， Z, Z_{DR} ， K_{DP}, Z_{DR} ， Z, Z_{DR}, K_{DP} 。




圖 3.1 使用 PLF 以及 MLP 方法降雨估計於 20170602 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5°，(b)1.5°及(c)2.4°散佈圖。





圖 3.2 使用 PLF 以及 MLP 方法降雨估計於 20190517 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5°, (b)0.9°, (c)1.3°, (d)1.8°及(e)2.4°散佈圖。



續圖 3.2 使用 PLF 以及 MLP 方法降雨估計於 20190517 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5° , (b) 0.9° , (c) 1.3° , (d) 1.8° 及 (e) 2.4° 散佈圖。





圖 3.3 使用 PLF 以及 MLP 方法降雨估計於 20190520 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5°, (b)0.9°, (c)1.3°, (d)1.8°及(e)2.4°散佈圖。



續圖 3.3 使用 PLF 以及 MLP 方法降雨估計於 20190520 梅雨個案與 Rain Gauge 觀測比較之(a) 0.5° , (b) 0.9° , (c) 1.3° , (d) 1.8° 及(e) 2.4° 散佈圖。





圖 3.4 個案 20170602 之 1.5° 仰角一小時累積雨量分布圖，分別使用 PLF 方法與 MLP 方法於(a)060120，(b)060121，(c)060203 及(d)060204 UTC。



續圖 3.4 個案 20170602 之 1.5° 仰角一小時累積雨量分布圖，分別使用 PLF 方法與 MLP 方法於(a)060120，(b)060121，(c)060203 及(d)060204 UTC。





圖 3.5 個案 20190517 與 20190520 之 1.3° 仰角一小時累積雨量分布圖，分別使用 PLF 方法與 MLP 方法於(a)2019051705，(b)2019051706，(c)2019052002 及(d)2019052003 UTC。



續圖 3.5 個案 20190517 與 20190520 之 1.3° 仰角一小時累積雨量分布圖，分別使用 PLF 方法與 MLP 方法於(a)2019051705，(b)2019051706，(c)2019052002 及(d)2019052003 UTC。






圖 3.6 個案 20170602 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)1.5°及(c)2.4°。



續圖 3.6 個案 20170602 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)1.5°及(c)2.4°。



續圖 3.6 個案 20170602 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)1.5°及(c)2.4°。







圖 3.7 個案 20190517 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。




續圖 3.7 個案 20190517 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.7 個案 20190517 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.7 個案 20190517 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.7 個案 20190517 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。







圖 3.8 個案 20190520 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。




續圖 3.8 個案 20190520 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.8 個案 20190520 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.8 個案 20190520 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.8 個案 20190520 之事件累積估計降水分布圖，分別使用 PLF 方法與 MLP 方法之大間距與小間距色階，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。





圖 3.9 北臺灣地面自動雨量站位置 20170602 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)1.5°及(c)2.4°。



續圖 3.9 北臺灣地面自動雨量站位置 20170602 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)1.5°及(c)2.4°。






圖 3.10 北臺灣地面自動雨量站位置 20190517 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°



續圖 3.10 北臺灣地面自動雨量站位置 20190517 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°



續圖 3.10 北臺灣地面自動雨量站位置 20190517 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。






圖 3.11 北臺灣地面自動雨量站位置 20190520 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.11 北臺灣地面自動雨量站位置 20190520 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。



續圖 3.11 北臺灣地面自動雨量站位置 20190520 個案降雨估計，分別使用 PLF 方法與 MLP 方法之 RRMSE、NMB 誤差空間分布，(a)0.5°，(b)0.9°，(c)1.3°，(d)1.8°及(e)2.4°。




圖 4.1 經過移除 PBB 影響範圍後五分山雷達之 100 公里觀測半徑內最低有效資料高度，包含 0.5° 、 0.9° 、 1.3° 、 1.8° 以及 2.4° 觀測仰角。




圖 4.2 五分山雷達觀測方位角 216° 之最低仰角 0.5° 有效觀測距離(無 PBB 影響)，其中紅色實線為有效觀測，灰色虛線為受遮擋波束。




圖 4.3 方位角 216° 之波束傳遞與地形垂直剖面圖，圖中實線為實際可觀測波束，虛線則為受 $PBB > 0$ 閾值濾除範圍，(a)為 2019 掃描策略調整前之 2.4° 以下仰角波束傳遞，(b) 為 2019 掃描策略調整後之 2.4° 以下仰角波束傳遞。





圖 4.4 20170602 個案在 060202UTC 至 060205UTC 分別使用(a)PLF、(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.5°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。



續圖 4.4 20170602 個案在 060202UTC 至 060205UTC 分別使用(a)PLF、(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.5°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。




圖 4.5 20170602 個案三方法降雨估計散佈圖，(a)2.4°之 PLF，(b)2.4°之 MLP 及(c)經過垂直修正(2.4°修正至 1.5°)。




圖 4.6 20190517 個案在 051705UTC 至 051706UTC 分別使用(a)PLF，(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.3°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。




圖 4.7 20190517 個案三方法降雨估計散佈圖，(a)2.4°之 PLF，(b)2.4°之 MLP 及(c)經過垂直修正(2.4°修正至 1.3°)。





圖 4.8 20190520 個案在 051705UTC 至 051706UTC 分別使用(a)PLF，(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.3°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。



續圖 4.8 20190520 個案在 051705UTC 至 051706UTC 分別使用(a)PLF，(b)MLP 以及(c)經過垂直修正(2.4°修正至 1.3°)的累積雨量分布圖，圖中圓點顏色為測站實際觀測降雨量。




圖 4.9 20190520 個案三方法降雨估計散佈圖，(a)2.4°之 PLF，(b)2.4°之 MLP 及(c)經過垂直修正(2.4°修正至 1.3°)。




圖 4.10 比較 20170602 個案 2.4° 仰角修正前後之 RRMSE(左上)、NMB(左下)、大間距累積雨量(右上)、小間距累積雨量(右下)。(a)為修正前 MLP，(b)經過垂直修正(2.4°修正至 1.5°)




圖 4.11 比較 20190517 個案 2.4° 仰角修正前後之 RRMSE(左上)、NMB(左下)、大間距累積雨量(右上)、小間距累積雨量(右下)。(a)為修正前 MLP，(b)經過垂直修正(2.4°修正至 1.3°)




圖 4.12 比較 20190520 個案 2.4° 仰角修正前後之 RRMSE(左上)、NMB(左下)、大間距累積雨量(右上)、小間距累積雨量(右下)。(a)為修正前 MLP，(b)經過垂直修正(2.4°修正至 1.3°)




圖 4.13 20170602 估計降雨散佈圖，(a)為欲修正之目標仰角 1.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.5°)(右)，(b)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。





圖 4.14 20190517 估計降雨散佈圖，(a)為欲修正之目標仰角 1.8° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.8°)(右)，(b)為欲修正之目標仰角 1.3° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.3°)(右)，(c)為欲修正之目標仰角 0.9° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.9°)(右)，(d)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。



續圖 4.14 20190517 估計降雨散佈圖，(a)為欲修正之目標仰角 1.8° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.8°)(右)，(b)為欲修正之目標仰角 1.3° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.3°)(右)，(c)為欲修正之目標仰角 0.9° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.9°)(右)，(d)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。





圖 4.15 20190520 估計降雨散佈圖，(a)為欲修正之目標仰角 1.8° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.8°)(右)，(b)為欲修正之目標仰角 1.3° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.3°)(右)，(c)為欲修正之目標仰角 0.9° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.9°)(右)，(d)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。



續圖 4.15 20190520 估計降雨散佈圖，(a)為欲修正之目標仰角 1.8° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.8°)(右)，(b)為欲修正之目標仰角 1.3° MLP 方法(左)與經過垂直修正(2.4° 修正至 1.3°)(右)，(c)為欲修正之目標仰角 0.9° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.9°)(右)，(d)為欲修正之目標仰角 0.5° MLP 方法(左)與經過垂直修正(2.4° 修正至 0.5°)(右)。




圖 4.16 個案 20170602 最低有效降雨估計事件累積雨量。左為垂直修正前之 MLP 方法，右為垂直修正後。




圖 4.17 個案 20170602 最低有效降雨估計之修正前後小時降雨強度評估指標，上為 RRMSE，下為 NMB。




圖 4.18 個案 20190517 最低有效降雨估計事件累積雨量。左為垂直修正前之 MLP 方法，右為垂直修正後。




圖 4.19 個案 20190517 最低有效降雨估計之修正前後小時降雨強度評估指標，上為 RRMSE，下為 NMB。




圖 4.20 個案 20190520 最低有效降雨估計事件累積雨量。左為垂直修正前之 MLP 方法，右為垂直修正後。




圖 4.21 個案 20190520 最低有效降雨估計之修正前後小時降雨強度評估指標，上為 RRMSE，下為 NMB。




圖 4.22 由 20170602 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及 (右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.5° 修正至地表，(c)為 0.5° 修正至地表。






圖 4.23 由 20190517 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及 (右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.8° 修正至地表，(c)為 1.3° 修正至地表，(d)為 0.9° 修正至地表，(e)為 0.5° 修正至地表。

(d)

Corrected QPE & Rain Gauge elev0.9_to_surface(high_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3




Corrected QPE & Rain Gauge elev0.9_to_surface(low_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3




(e)

Corrected QPE & Rain Gauge elev0.5_to_surface(high_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3



Corrected QPE & Rain Gauge elev0.5_to_surface(low_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3



續圖 4.23 由 20190517 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及(右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.8° 修正至地表，(c)為 1.3° 修正至地表，(d)為 0.9° 修正至地表，(e)為 0.5° 修正至地表。






圖 4.24 由 20190520 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及(右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.8° 修正至地表，(c)為 1.3° 修正至地表，(d)為 0.9° 修正至地表，(e)為 0.5° 修正至地表。

(d)

Corrected QPE & Rain Gauge elev0.9_to_surface(high_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3




Corrected QPE & Rain Gauge elev0.9_to_surface(low_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3




(e)

Corrected QPE & Rain Gauge elev0.5_to_surface(high_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3



Corrected QPE & Rain Gauge elev0.5_to_surface(low_version) (Accumulation)
Accumulation=1 hr || n_scans_min=3



續圖 4.24 由 20190520 個案觀測仰角垂直修正至真實地形分別使用(左)Kernel1 以及(右)Kernel2 降雨估計散佈圖，(a)為 2.4° 修正至地表，(b)為 1.8° 修正至地表，(c)為 1.3° 修正至地表，(d)為 0.9° 修正至地表，(e)為 0.5° 修正至地表。



附錄

附錄 A1. MLP 深度學習降雨估計模型

本研究於前三層隱藏層加入批次正規化 (Batch Normalization) 與 Dropout 機制，其中 Dropout 率設定為 0.2，以降低過度擬合並提升模型訓練穩定性。所有隱藏層皆使用 Gaussian Error Linear Unit (GELU) 作為激活函數，以提升模型對高度非線性降雨關係之學習能力。考量輸入雷達參數仍保有部分線性資訊，本研究另外建立由輸入層直接連接至第五層之 Shortcut (Residual Connection)，將原始輸入特徵投影至 32 維後與第五層輸出相加，再經由 GELU 函數後輸出至最終預測層。此設計可保留原始雷達資訊，同時降低深層網路於訓練過程中的資訊衰減問題，提升模型收斂速度與整體估計表現。

表 A1.1 MLP 模型層數結構、激活函數與防過擬合機制。

Layer	Structure	Output Dimension
Input	Z_{HH}, Z_{DR}, K_{DP}	3
FC1	Linear + BatchNorm + GeLU + Dropout	128
FC2	Linear + BatchNorm + GeLU + Dropout	128
FC3	Linear + BatchNorm + GeLU + Dropout	64
FC4	Linear + GeLU	32
FC5	Linear	32
Shortcut	Linear(3 $\rightarrow$ 32)	32
Residual	Since FC5 + Shortcut	32
Activation	GeLU	32
Output	Linear	1



表 A1.2 降雨模型超參數設定。

Hyperparameters	Value
Loss function	Weighted MSE
Optimizer	Adam
Learning rate	5×10^{-4}
Batch size	128
Epochs	100
Early stopping	20 epochs
Dropout	0.3
Residual connection	Input→FC5




圖 A1.1 深度學習降雨估計模型 MLP 結構示意圖。



附錄 A2. TopoCorr-Net 降雨估計垂直修正模型

TopoCorr-Net 為本研究提出之垂直修正模型，主要由 CNN 與全連接神經網路所組成。模型以 9×9 局部雷達參數場及初始 MLP_QPE 降雨估計為主要輸入，搭配波束高度、雷達距離及中心點雷達參數等輔助資訊，學習不同高度間之降雨結構變化。透過卷積網路擷取空間特徵，並結合殘差學習與全連接網路建立高低層降雨之非線性映射關係，最終輸出目標高度之降雨修正量，以改善高仰角觀測造成之垂直結構誤差。

表 A2.1 垂直修正模型特徵提取結構與尺寸。

Layer	Structure	Output
Input	$9 \times 9 \times 4$	$9 \times 9 \times 4$
Fixed mean layer	3×3	$9 \times 9 \times 4$
Conv1	32 filters, 3×3	$7 \times 7 \times 32$
LayerNorm		
Conv2	32 filters, 3×3	$5 \times 5 \times 32$
LayerNorm		
Adaptive AvgPool	2×2	$2 \times 2 \times 32$
Flatten		128

表 A2.2 垂直修正模型迴歸區塊全連接層。

Layer	Neurons
FC1	256
FC2	128
FC3	32
Output	1




表 A2.3 垂直修正模型超參數設定。

Hyperparameters	Value
Patch size	9×9
Input channels	4
Meta features	6
CNN filters	32
Convolution kernel	3×3
Normalization	GroupNorm(CNN)、LayerNorm(FC)
Activation	CNN : GeLU ; FC : LeakyReLU
Adaptive pooling	2×2
Residual connection	$256 \rightarrow 128 \rightarrow 32$
Loss function	Masked MSE
Optimizer	AdamW
Learning rate	2×10^{-4}
Batch size	32
Epoch	60
Early stopping	10 epochs




圖 A2.1 降雨垂直修正模型 TopoCorr-Net 模型結構示意圖。