

國立臺灣大學理學院大氣科學系  
碩士論文



Department of Atmospheric Sciences

College of Science

National Taiwan University

Master's Thesis

使用統計模型探討阿里山茶區夜間成霧原因  
Investigating Nighttime Fog Formation Mechanisms in the  
Alishan Tea-Growing Region Using Statistical Models

黃子強

Tzu-Chiang Huang

指導教授：羅敏輝博士

Advisor: Min-Hui Lo, Ph.D.

中華民國 115 年 04 月

April 2026



## 謝辭

讀了一個加長版的碩士，讓台北模擬器.exe 的遊戲時長來到了七年，一句曲折離奇不足以形容這段經歷，各種機緣巧合也讓我明白完成學業並非單憑自身努力可以達成的事。因此，謹以此文紀念家人、師長的各種幫助。

爸爸媽媽在成長過程中提供的資源之豐富，即使拿我所觀察到下一個世代的標準來看也都算十分充足；爺爺奶奶跟外婆在我每次回去時都讓我飽食終日，真的是字面上的意思，每一餐都很飽；姑姑跟舅舅也都很愛跟我聊天，常常聊很久的時間（褒義）。

還有教過我的老師們，其中天文所王為豪老師提出鹿林天文台夜間霧的預測需求，是啟發我做山區霧的最初原因。也特別感謝耐心帶過我三年的 Mog 老師，除了熱力學的知識外，在研究或生涯發展上都給了很好的建議，只是當時可能還聽不懂，但後來其實是可以慢慢體會的。

最後感謝敏輝老師這三個學期的鼓勵，沒有想過可以在一年內就從零開始到可以寫論文的程度，在遇到挫折時先安慰我又鼓勵我去跑步（雖然我論文寫完才開始被學弟抓去跑步），工作狀態跟生活型態在這段時間以來都有明顯的改善。而且我平常講話或寫字的風格就是這樣，在寫論文的時候被說了不只一次文字過度口語化，雖然老師超忙但他看我的論文看得真的很仔細，也陪我慢慢把各種細節修正成現在的成果。在跟他的討論中，我被鼓勵更加直接地講出我對科學問題的懷疑跟猜測，這是在碩一時還學不會的，也是到這個時候才逐漸學會怎麼讀一篇論文（在各種翻譯軟體的輔助下確實加速很多，或許這也是原因之一）。總之當時如果沒進這間實驗室的話，應該會直接去當兵，讀碩班真的是很大程度改變了人生軌跡，各種意義上來說都是這樣。

以上這些都是我平常不會當面說的話，趁著論文謝辭一輩子就一次（沒有意外的話啦）的機會把它們寫出來，祝各位研究順利、身體健康。



## 中文摘要


台灣中海拔山區常受到霧影響並降低能見度，造成交通上的風險，並改變輻射條件與微氣候，進而影響山區農業。本研究以嘉義縣竹崎鄉石園（SY）測站為主要研究站點，並以南投縣溪頭（XT）通量塔為參考站點，探討阿里山周遭茶區的夜間霧頻率為何會明顯高於相近海拔高度的溪頭測站。本研究以每小時通過 QC 之樣本中有霧樣本所占比例定義起霧頻率，兩站霧頻率皆在當地時間約 17 時達到峰值，石園的霧頻率約可達 0.2，溪頭則約為 0.15。相較之下，夜間霧頻率出現很明顯的差異，石園的霧頻率在 20 時由 0.16 逐漸降至凌晨 02 時的 0.08，而溪頭在 20 時後不久即降至 0.05 以下，使得夜間的霧頻率出現三至五倍的差異，兩站霧頻率比值（SY/XT）通常超過 3，並在 22–00 時可達 4.8 以上。

我們建立機器學習模型，用於石園的起霧偵測（t0h）與一小時預報（t1h），以 Logistic Regression 作為基準模型，並以基於決策樹的統計模型（Random Forest 與 LightGBM）作為主要分析重點。SHapley Additive exPlanations 特徵重要性診斷（SHAP）提供具有物理可解釋性的線索，用以說明氣溫、混合比、風速、氣壓等氣象條件如何共同影響霧的發生。

為了解釋其環境控制因子，我們根據模型的 SHAP 分析，挑選較為重要的變數，並檢視其二維霧頻率分布。首先，分析溫度與混合比對霧頻率的關係，結果顯示接近飽和的溫、濕條件可視為成霧的必要條件。其次，在接近飽和的前提下分析平行坡向風速與降溫趨勢對霧頻率的關係，發現上坡風在夜間扮演成霧的關鍵角色。石園夜間（20–02 時）有霧時的平行坡向風速逐小時中位數約為 0.8 至 1.0  $\text{m s}^{-1}$ ，無霧時約為 -0.3 至 -0.6  $\text{m s}^{-1}$ ，其中正值定義為上坡風，負值代表下坡風，故此結果支持夜間上坡風的重要性。溪頭夜間有霧時平行坡向風速的中位數介於 -0.2 至 0.2  $\text{m s}^{-1}$ ，而無霧時約為 -0.7 至 -0.6  $\text{m s}^{-1}$ ，與溪頭在 20 時後幾乎缺乏上坡風的現象一致。綜合而言，本研究使用機器學習對霧的存在進行偵測與預報，並指出上坡風對阿里山茶區夜間霧頻率有明顯關聯，季節性的背景風向差異亦可能影響石園夜間風場型態，但其具體作用機制仍待後續研究釐清。

關鍵字：山區霧、夜間霧、局地環流、機器學習、決策樹、SHAP 分析


## 英文摘要



Fog frequently affects the mid-elevation mountainous regions of Taiwan, reducing visibility, increasing traffic hazards, and altering radiation conditions and microclimates, thereby influencing mountain agriculture. This study focuses on the Shiyuan (SY) station in Zhuqi Township, Chiayi County, as the primary study site, with the Xitou (XT) flux tower in Nantou County as a reference site, to investigate why nighttime fog frequency in the tea-growing region surrounding Alishan is markedly higher at SY than at XT, despite their similar elevations. Fog frequency is defined here as the proportion of foggy samples among all quality-controlled samples within each hour. At both sites, fog frequency reaches its peak at approximately 17:00 local time, with values of about 0.20 at SY and 0.15 at XT. In contrast, nighttime fog frequency differs substantially between the two sites. At SY, fog frequency gradually decreases from 0.16 at 20:00 to 0.08 at 02:00, whereas at XT it drops below 0.05 soon after 20:00. As a result, nighttime fog frequency differs by a factor of three to five between the two sites, with the fog frequency ratio (SY/XT) generally exceeding 3 and reaching above 4.8 during 22:00–00:00.

Machine learning models were developed for fog detection at the current hour ( $t_0h$ ) and one-hour-ahead prediction ( $t_1h$ ) at SY. Logistic Regression was used as the baseline model, while decision tree-based statistical models, including Random Forest and LightGBM, served as the main focus of the analysis. SHapley Additive exPlanations (SHAP)-based feature importance diagnostics provide physically interpretable insights into how meteorological conditions, including air temperature, mixing ratio, wind speed, and pressure, jointly influence fog occurrence.

To identify the environmental controls of fog formation, we selected the more important variables based on the SHAP analysis and examined their two-dimensional fog frequency



distributions. First, the relationship between temperature, mixing ratio, and fog frequency indicates that near-saturated thermodynamic conditions can be regarded as a necessary condition for fog formation. Second, under near-saturated conditions, the relationship between slope-parallel wind speed, cooling tendency, and fog frequency shows that upslope flow plays a key role in nighttime fog formation. During nighttime (20:00–02:00) foggy conditions at SY, the hourly median slope-parallel wind speed is approximately 0.8 to 1.0 m s<sup>-1</sup>, whereas under non-foggy conditions it ranges from about -0.3 to -0.6 m s<sup>-1</sup>. Positive values are defined as upslope flow, and negative values indicate downslope flow, supporting the importance of nighttime upslope flow. At XT, the median slope-parallel wind speed during nighttime foggy conditions ranges from -0.2 to 0.2 m s<sup>-1</sup>, while under non-foggy conditions it is about -0.7 to -0.6 m s<sup>-1</sup>, consistent with the near absence of upslope flow after 20:00 at XT. Overall, this study applies machine learning to detect and predict fog occurrence and further indicates that upslope flow is strongly associated with nighttime fog frequency in the Alishan tea-growing region. Seasonal differences in background wind direction may also influence the nighttime wind characteristics at SY, although the underlying mechanism remains to be clarified in future work.

Keywords: montane fog, nighttime fog, local circulation, machine learning, decision trees, SHAP analysis

# 目次



|                                           |     |
|-------------------------------------------|-----|
| 謝辭.....                                   | i   |
| 中文摘要.....                                 | ii  |
| 英文摘要.....                                 | iii |
| 目次.....                                   | v   |
| 圖次.....                                   | vi  |
| 第一章、緒論.....                               | 1   |
| 第二章、研究方法.....                             | 4   |
| 2.1 測站資料與資料前處理 .....                      | 4   |
| 2.1.1 測站位置、地面觀測資料與時間基準 .....              | 4   |
| 2.1.2 地形資料與坡向設定、風向投影及上坡風速之定義 .....        | 4   |
| 2.1.3 霧事件定義與起霧頻率 (fog frequency) 計算 ..... | 5   |
| 2.1.4 資料品質控制 (QC) 與樣本數概況.....             | 5   |
| 2.2 機器學習霧偵測與預報方法 .....                    | 6   |
| 2.2.1 研究架構與資料使用範圍 .....                   | 6   |
| 2.2.2 特徵建構 .....                          | 6   |
| 2.2.3 模型訓練資料建構與驗證 .....                   | 7   |
| 2.2.4 評估指標與 SHAP 特徵重要性分析方法 .....          | 7   |
| 2.3 ERA5 再分析資料 .....                      | 8   |
| 第三章、時段定義與機器學習模型結果討論.....                  | 9   |
| 3.1 起霧頻率之日變化與時段劃分 .....                   | 9   |
| 3.2 模型表現概述 .....                          | 9   |
| 3.2.1 即時偵測 (t0h) 結果 .....                 | 9   |
| 3.2.2 一小時後預測 (t1h) 結果 .....               | 10  |
| 3.2.3 t0h 與 t1h 的差異 .....                 | 10  |
| 3.3 特徵重要性 (SHAP) .....                    | 10  |
| 第四章、成霧環境條件之統計分析.....                      | 11  |
| 4.1 成霧環境條件之 2D 起霧頻率 .....                 | 11  |
| 4.2 霧與非霧條件下的上坡風日變化比較 .....                | 11  |
| 4.3 夜間上坡風比例之站點差異：小提琴圖驗證 .....             | 12  |
| 4.4 綜觀環境與夜間上坡風之關聯 .....                   | 12  |
| 第五章、討論.....                               | 14  |
| 第六章、結論.....                               | 15  |
| 參考文獻.....                                 | 16  |
| 圖表.....                                   | 18  |
| 補充資料.....                                 | 36  |

## 圖次



|                                                           |    |
|-----------------------------------------------------------|----|
| 圖 2-1. 研究區域與測站位置示意圖 .....                                 | 18 |
| 圖 2-2. 石園測站各小時觀測樣本數統計 .....                               | 19 |
| 圖 3-1. 石園與溪頭之起霧頻率逐小時日變化 .....                             | 19 |
| 圖 3-2. 當地時間 12-17 時偵測 (t0h) 各模型分類表現比較 .....               | 20 |
| 圖 3-3. 當地時間 12-17 時一小時後預測 (t1h) 各模型分類表現比較 .....           | 21 |
| 圖 3-4. 當地時間 12-17 時偵測與一小時後預測之獨立測試集 F1 分數對照圖 .....         | 21 |
| 圖 3-5. 當地時間 20-02 時偵測 (t0h) 各模型分類表現比較 .....               | 22 |
| 圖 3-6. 當地時間 20-02 時一小時後預測 (t1h) 各模型分類表現比較 .....           | 22 |
| 圖 3-7. 當地時間 20-02 時偵測與一小時後預測之獨立測試集 F1 分數對照圖 .....         | 23 |
| 圖 3-8. 兩個時段情境下隨機森林與 LightGBM 之偵測 (t0h) SHAP 特徵重要度比較 ..... | 24 |
| 圖 3-9. 石園氣溫與混合比之逐小時平均日變化 .....                            | 25 |
| 圖 4-1. 石園當地時間 12-17 時之二維起霧頻率分布圖 .....                     | 26 |
| 圖 4-2. 石園當地時間 20-02 時之二維起霧頻率分布圖 .....                     | 27 |
| 圖 4-3. 石園當地時間 12-17 時之二維起霧頻率分布圖 .....                     | 28 |
| 圖 4-4. 石園當地時間 20-02 時之二維起霧頻率分布圖 .....                     | 29 |
| 圖 4-5. 石園有霧與無霧條件下之上坡風速逐小時中位數日變化 .....                     | 29 |
| 圖 4-6. 溪頭有霧與無霧條件下之上坡風速逐小時中位數日變化 .....                     | 30 |
| 圖 4-7. 當地時間 20-02 時石園與溪頭之上坡風速逐兩小時分布比較 .....               | 31 |
| 圖 4-8. 冬季上坡日之 ERA5 再分析 850 hPa 風場合成圖 .....                | 32 |
| 圖 4-9. 冬季下坡日之 ERA5 再分析 850 hPa 風場合成圖 .....                | 33 |
| 圖 4-10. 夏季上坡日之 ERA5 再分析 850 hPa 風場合成圖 .....               | 34 |
| 圖 4-11. 夏季下坡日之 ERA5 再分析 850 hPa 風場合成圖 .....               | 35 |
| 圖 S1. 當地時間 12-17 時偵測 (t0h) LR 之 SHAP 特徵重要度 .....          | 36 |
| 圖 S2. 當地時間 20-02 時偵測 (t0h) LR 之 SHAP 特徵重要度 .....          | 37 |



## 第一章、緒論

臺灣中海拔山區常受雲霧影響 (Schulz et al., 2017)。霧不僅會降低能見度，增加山區道路行車與交通安全風險，亦會改變近地表輻射收支與微氣候條件，進而影響茶園等山區農業環境之日照、溫度與濕度條件。

在臺灣山區雲霧研究脈絡下，前人已指出不同地區、海拔與時段之霧具有明顯異質性。Li et al. (2022) 以臺灣東北部棲蘭山區為例，結合不同海拔高度之地面氣象觀測、縮時影像與 Himawari-8 輻射資料，利用機器學習方法量化日間霧之時空分布，指出霧在中海拔、午後與冷季較常發生。Chen et al. (2024) 則進一步利用 Himawari-8 與深度學習方法估計霧頂高度，顯示山區霧頂邊界與地形高度具有一致性，反映地形對雲霧垂直結構的約束作用。不同山區（例如台灣北部的棲蘭山區與位於中部的溪頭地區等）可能呈現不同的起霧型態與控制因子，凸顯在地成霧機制研究的重要性。（賴彥任、羅明慧，2019）

近年來，地球同步衛星與機器學習方法亦逐漸被用於山區雲霧之區域尺度監測。Chong et al. (2024) 以臺灣東北部棲蘭山區為例，整合 Himawari-8 各波段訊號、太陽高度、植生指標與地形屬性，建立以隨機森林為核心之模型，以偵測日間霧與低層狀雲之時空變化。其結果顯示，此方法可描繪棲蘭山區日間霧與低層狀雲之時空分布，並指出日間霧與低層狀雲主要集中於中海拔地區，且秋冬中午至午後較為明顯。此研究說明地球同步衛星結合機器學習不僅可用於雲霧偵測，亦可作為量化山區雲霧時空特徵的重要工具。

雲霧林之微氣候亦與日尺度能量分配密切相關。Gu et al. (2021) 指出，在雲霧頻繁的山地雲霧林環境中，潛熱通量的日變化可能呈現明顯不對稱，且在日間較早時段即出現相對較高的值，抵銷部分近地面升溫並減少日溫差；而提供潛熱通量的水分來源與樹冠上可蒸發水滴有關（前一天自雲霧攔截或夜間凝結所補充）。午後雲霧可補充樹冠水分並維持樹冠濕潤，使隔日日間蒸發冷卻增強而提高再度達到飽和與起霧的機率，形成日循環尺度的水—能量回饋（Gu et al., 2021）。

另一方面，山區雲霧之好發海拔、地區與持續特性亦可能隨季節不同而有所差異。Ou et al. (2024) 指出，山區霧在不同季節呈現顯著的空間分布差異：夏季霧較傾向出現在較高海拔

且持續時間相對較短；冬季好發高度偏低，並可能受東北季風影響而在盛行風的迎風面呈現較長時間持續的特徵。此類結果顯示，雲霧的控制因子可能隨大尺度背景環境改變而有所差異（Ou et al., 2024）。



在應用面，霧的即時監測與短期預報（nowcasting）對山區道路風險管理與天文觀測作業安排具有實務價值。在缺乏直接雲霧觀測的情境下，衛星夜間霧偵測可作為可行方案（Ellrod, 1995）。近年亦有研究以地面氣象資料結合機器學習與統計方法進行霧之短期預報，顯示此類方法具有可行性（Colabone et al., 2015；Durán-Rosal et al., 2018；Vorndran et al., 2022；Bari et al., 2023；Schütz et al., 2024）。在臺灣山區，Chong et al. (2024) 亦已證明隨機森林結合 Himawari-8 與地形相關特徵，可有效描述山區日間霧與低層狀雲之空間分布，顯示機器學習方法在臺灣山區雲霧問題上亦具良好應用潛力。

儘管機器學習預報在不同地區的案例中已被證實具有潛力，霧預報仍面臨多重挑戰。例如，資料不平衡可能導致不同能見度區間的預測能力差異（Castillo-Botón et al., 2022），而模型亦可能僅擬合時間序列的持續性行為，使短期預報結果看似良好，但難以掌握霧的生成與消散時機（Vorndran et al., 2022）。為改善短期預報，Schütz et al. (2024) 指出透過時間濾波與趨勢特徵可提升分類式預報的表現；此外，Schütz et al. (2025) 亦評估測站、衛星及其融合資料在能見度預報中的貢獻，顯示整合不同來源資料具有應用潛力，惟能否取得充足之能見度觀測資料仍為主要限制。亦有研究以地面攝影影像輔助霧事件之即時判識，顯示影像資料可作為地面氣象觀測之輔助資訊來源（Bartok et al., 2022）。此外，Chong et al. (2024) 與 Li et al. (2022) 雖已分別展示臺灣山區雲霧之區域分布量化與日間霧偵測能力，但其研究重點仍較偏向日間霧之時空分布描繪，對於相近海拔站點之夜間起霧差異、局地環流角色，以及以地面站為主之短期預報與機制診斷，仍缺乏直接比較。

基於上述背景，本研究經初步分析後聚焦於臺灣中部山區兩個相近海拔但夜間起霧行為不同之站點：嘉義縣竹崎鄉石園（SY）與南投縣鹿谷鄉溪頭（XT）。本研究先比較兩站起霧頻率之日變化，以界定午後與夜間兩個主要分析時段；接著以石園為主要研究對象，建立霧之即時偵測（t0h）與一小時預報（t1h）模型，並結合特徵重要性分析與條件化統計，探討溫度、水氣與局地沿坡環流如何共同影響成霧。藉由與溪頭之對照，本研究進一步檢視：為何兩站在午後起霧頻率相近，但在夜間卻呈現顯著差異。



本研究之核心科學問題與研究目的如下：

(1) 為何同樣位於臺灣中部山區的石園與溪頭，在下午起霧頻率相近，卻在夜間出現顯著且可達數倍的差異？

(2) 溫度、水氣與局地環流等條件如何影響成霧，且這些條件扮演的角色在下午與夜間有何異同？



## 第二章、研究方法

### 2.1 測站資料與資料前處理

#### 2.1.1 測站位置、地面觀測資料與時間基準

本研究使用石園與溪頭之氣象與能見度觀測資料進行統計分析（圖 2-1）。石園站屬於嘉義縣竹崎鄉阿里山茶區，位處曾文溪北側山坡，站址座標為北緯 23.47577、東經 120.70360，海拔 1463m；溪頭通量塔位於南投縣鹿谷鄉，站址座標為北緯 23.66490、東經 120.79590，海拔 1250m。其中石園為主要研究對象，溪頭作為對照站，後續分析皆採臺灣當地時間（UTC+8）。石園為 5 分鐘之瞬時資料；溪頭為 30 分鐘之平均資料。本研究使用之石園站觀測資料涵蓋期間為 2022 年 1 月至 2024 年 10 月；溪頭通量塔之觀測資料期間則為 2009 年 10 月至 2018 年 1 月。儘管兩站資料之觀測時期未完全重疊，但考慮到兩站皆具備多年之長期觀測，足以反映兩地之氣候特徵，因此適合用於起霧頻率與日變化型態之氣候特徵比較。

儀器型號如下：

#### 1. 石園：

- (1). 能見度儀：IRS miniBVS
- (2). 風速計：METER ATMOS 22
- (3). 溫濕壓計：METER ATMOS 14
- (4). 雨量計：METER ECRN-100

#### 2. 溪頭：

- (1). 能見度儀：Campbell Scientific CS12
- (2). 風速計：Campbell Scientific CSAT3
- (3). 雨量計：Takeda TK-1。

#### 2.1.2 地形資料與坡向設定、風向投影及上坡風速之定義

本研究以空間解析度為 20 公尺之數值高程模型（DEM）計算石園站周遭半徑 500m 內之平均坡向，結果約為 201°（下坡方位角，順時針自北起算）。溪頭通量塔坡向採用賴與羅（2019）文中所述之北北西（取 337.5°）定義坡向平行／垂直風。

本研究以坡向  $\theta$  定義坡面下坡方向，風場以  $U$ （東向為正）與  $V$ （北向為正）表示，

並將其投影至坡面方向：平行坡向風速分量（下坡方向為正）為  $U_{\parallel} = U \cdot \sin\theta + V \cdot \cos\theta$ ；垂直坡向風速分量為  $U_{\perp} = U \cdot \cos\theta - V \cdot \sin\theta$ 。為便於物理解釋，本研究進一步將平行坡向風速分量之相反數定義為上坡風速，使正值代表上坡方向（上坡風），負值代表下坡方向（下坡風）；垂直坡向風速分量（ $U_{\perp}$ ）於圖中標記為 Slope-perpendicular wind。

### 2.1.3 霧事件定義與起霧頻率（fog frequency）計算

本研究以能見度（visibility）< 1000 公尺作為有霧事件之判定閾值，符合條件者標記為有霧（fog = 1），否則為無霧（fog = 0）。該小時之起霧頻率（fog frequency）即為：有霧觀測次數 / 當小時通過品管之觀測總次數。由樣本數統計可知（圖 2-2），本研究各時段之觀測資料密度均相當充足（各小時通過品管之有效觀測均達 8,000 筆以上），因此計算起霧頻率時，未額外設定最小有效樣本數門檻亦不影響其統計代表性。兩站之霧頻率比值（SY/XT）則分別由各站全期間資料計算每小時霧頻率後，再取其比值。值得注意的是，溪頭通量塔與石園測站之觀測時間解析度分別為 30 分鐘與 5 分鐘，本研究保留兩測站之原始觀測時間解析度，各自於對應之時段內依其原始筆數計算起霧頻率，再進行後續之逐時特徵比較。

### 2.1.4 資料品質控制（QC）與樣本數概況

本研究採用兩步驟 QC：首先針對必要欄位進行缺值剔除；其次排除降雨條件（若該筆 5 分鐘觀測樣本之降雨量 > 0 mm 即予以排除）與明顯異常值。研究期間通過初步資料品質控制之觀測資料共 210,935 筆，進一步排除降雨後移除了 9,023 筆（約 4.3%），剩餘 201,912 筆資料用於後續分析，此一步驟雖損失少部分伴隨降雨之霧事件，但能確保後續分析不受降雨干擾。

為排除儀器故障或雜訊所造成之不合理極端值，本研究設定以下資料品質控制（QC）條件：（i）氣溫  $\geq -10^{\circ}\text{C}$ ；（ii）混合比  $\geq 0 \text{ kg kg}^{-1}$ ；（iii）氣壓  $\geq 70 \text{ kPa}$ ；（iv）平行與垂直坡向風速分量之絕對值均  $\leq 10 \text{ m s}^{-1}$ ，設定上述條件與排除降雨之主要考量如下：

1. 排除降雨：主要為避免將「純粹因強降雨造成的低能見度」誤判為霧的可能，進而導致機器學習模型學習到錯誤的特徵關聯。儘管會損失部分伴隨降雨發生之真實霧事件樣本，但也因此確保了本研究之後續分析，避免降雨干擾造成之物理詮釋偏誤。
2. 氣溫  $\geq -10^{\circ}\text{C}$ ：台灣中海拔山區極難出現低於  $-10^{\circ}\text{C}$  之低溫，若觀測值低於此門檻，極可能是溫度感測器異常。
3. 混合比  $\geq 0 \text{ kg kg}^{-1}$ ：混合比在物理上不可能為負值，出現負值必然為儀器計算或觀

測失誤。

4. 氣壓  $\geq 70$  kPa：石園測站（海拔 1463 m）之平均氣壓約在 85 kPa 左右，若氣壓降至 70 kPa 以下，顯然違背當地正常氣壓範圍，屬儀器雜訊。
5. 風速絕對值  $\leq 10$  m s<sup>-1</sup>：在非颱風等劇烈天氣系統影響下，當地之局地沿坡風速極少超過 10 m s<sup>-1</sup>，此閾值可有效排除因劇烈天氣或風速計異常造成之雜訊。

混合比 (mixing ratio,  $w$ ) 由實際水汽壓  $e$  與氣壓  $p$  計算： $w = \varepsilon \cdot e / (p - e)$ ，其中  $\varepsilon = 0.622$  為乾空氣與水氣之氣體常數比值（無單位）。本研究採用逐筆（5 分鐘）判定霧事件，而非設定最短持續時間門檻，主要基於以下考量：山區霧之出現與消散較平地更為快速，且無法排除是否為層雲水平移入導致，強制設定持續時間門檻可能損失大量真實但短暫的霧事件，亦可能影響機器學習模型對成霧初始條件的學習能力。此外，本研究之分析目標為「霧與非霧之統計條件差異」，而非「霧事件的生命週期追蹤」，因此以逐筆判定更符合本研究的研究目的。

## 2.2 機器學習霧偵測與預報方法

本研究旨在建立起霧之即時偵測與預測模型。在模型架構設計上，本研究將起霧預測定義為二元分類問題，而非連續能見度數值的回歸預測。資料處理流程如下：首先收集測站氣象特徵與能見度觀測資料，經資料清洗與品質過濾後，以 1000m 為門檻標記起霧與否之類別標籤；隨後將資料集分割為訓練集與測試集，並輸入羅吉斯迴歸 (LR)、隨機森林 (RF) 與輕量梯度提升機 (LGBM) 等機器學習分類器進行模型訓練與效能評估。

### 2.2.1 研究架構與資料使用範圍

本研究以石園為主要研究對象，並以溪頭作為對照站進行統計比較與時段情境定義，而溪頭資料不參與任何機器學習模型訓練。本研究分別建立即時偵測模型（t0h，偵測當下是否起霧）與一小時後預測模型（t1h，預測一小時後是否起霧）。

### 2.2.2 特徵建構

本研究建構兩類特徵：一為五個即時觀測變數，包含氣溫、混合比、平行坡向風速分量（上坡風速）、垂直坡向風速分量及氣壓；二為上述各變數之一小時趨勢量，定義為  $\Delta X(t) = X(t) - X(t-1 \text{ h})$ ，共計十個特徵。本研究之模型是直接以石園 5 分鐘瞬時資料進行特徵建構與預測，上述之 1 小時趨勢與 1 小時預測目標（t1h），均為針對各 5 分鐘觀測資料，直接對應其 60 分鐘前與 60 分鐘後之原筆資料計算，未進行時間降採樣（resampling）。在將

特徵變數輸入機器學習模型前，考量各氣象變數之數值尺度差異甚大，為避免特徵尺度差異影響模型之收斂與權重評估，本研究對所有連續變數進行了標準化處理，先計算訓練集資料之平均值與標準差，再依此將訓練集與測試集之特徵轉換為平均值為 0、標準差為 1 之資料。針對特徵變數間可能存在的共線性問題，本研究考量相對濕度深受氣溫影響，而混合比主要取決於實際水氣壓與測站氣壓（同測站之氣壓相對恆定），因此採用混合比不僅能較高程度上代表絕對水氣含量，亦可避免與氣溫間的共線性。此外，本研究所採用的主要模型（隨機森林 RF 與輕量梯度提升機 LGBM）屬樹狀集成模型。此類模型在進行節點分裂時，會自動挑選當下資訊增益最大的特徵，對特徵間的多重共線性具有較高容忍度，故本研究保留上述變數，協助模型從不同維度的熱力特徵中學習成霧條件。

### 2.2.3 模型訓練資料建構與驗證

在完成特徵建構後，下午（12–17）情境之可用樣本為 48,628 筆（6,327 筆有霧，42,301 筆無霧），夜間（20–02）情境之可用樣本為 59,493 筆（7,019 筆有霧，52,474 筆無霧）。由於有霧事件相對少，為避免類別不平衡造成模型偏誤，本研究在各情境中，從有霧（fog = 1）與無霧（fog = 0）樣本各隨機抽取 5,000 筆資料，共 10,000 筆，並以此作為後續模型訓練與評估之主要設定。

在每個情境（下午、夜間）與每個預測目標（t0h、t1h）中，先完成類別平衡抽樣後，採 80/20 比例隨機切分為訓練集與測試集，切分時以分層抽樣（stratified sampling）保留正負樣本比例。於訓練集中進行十折交叉驗證以進行超參數搜尋與模型比較，並以交叉驗證平均 F1 與其標準差作為穩健性指標。為確保結果可重現性，所有隨機程序均設定固定隨機種子（random seed = 42）。

本研究採用三種常見分類模型：Logistic Regression（LR）、Random Forest（RF）與 LightGBM（LGBM）。LR 作為可簡易訓練之線性基準模型；RF 與 LGBM 則可捕捉非線性關係與特徵交互作用。每個模型皆於固定的超參數候選組合（各 12 組）中，以 10-fold 交叉驗證之平均 F1 分數作為挑選依據，選出分數最高者為最佳組合，再以訓練集重新訓練得到最終模型。

### 2.2.4 評估指標與 SHAP 特徵重要性分析方法

本研究以精確率（precision）、召回率（recall）與 F1 分數評估模型之二元分類表現，並以「有霧（fog = 1）」作為正類。令 TP、FP、FN 分別表示真正例、假正例與假負例，則  $\text{precision} = \text{TP}/(\text{TP}+\text{FP})$ ， $\text{recall} = \text{TP}/(\text{TP}+\text{FN})$ ， $\text{F1} = 2 \cdot \text{precision} \cdot \text{recall}/(\text{precision}+\text{recall})$ 。在起

霧預測之實務應用中，須考量不同類型預測錯誤的相對代價，而漏報（實際起霧但模型未預測）可能導致交通安全風險增加，其代價通常高於誤報（實際無霧但模型預測有霧）所帶來的不便。因此，在評估模型表現時，除了整體準確率與 F1 分數外，各模型皆有較高的召回率（Recall），以期盡可能減少漏報事件，提升預警系統的實用性。

採用 SHapley Additive exPlanations (SHAP) 量化各特徵對模型輸出的貢獻，作為特徵重要性排序與物理解釋之基礎。對樹模型（RF、LGBM）採用 SHAP 套件之樹模型解釋器（TreeExplainer），線性模型（LR）則採用線性解釋器（LinearExplainer）。特徵重要度以各特徵之平均絕對 SHAP 值  $\text{mean}(|\text{SHAP}|)$  衡量，並以長條圖呈現前七名重要特徵；同時以特徵值與 SHAP 值之 Spearman 相關係數判定方向，以紅色表示有霧機率隨該特徵增加而上升（正相關），黑色表示負相關。

### 2.3 ERA5 再分析資料

為了對應石園測站所在海拔高度（約 1463 m）之背景大氣環境，本研究使用 ECMWF ERA5 再分析資料之 850 hPa 每小時風場（ $u$ 、 $v$ ），水平解析度為  $0.25^\circ$ 。分析期間涵蓋 2022–2024 年之冬季（DJF=12–2 月）與夏季（JJA=6–8 月），研究區域聚焦於臺灣及其周邊（ $118\text{--}123^\circ\text{E}$ ， $21\text{--}26^\circ\text{N}$ ）。本研究雖聚焦於測站氣象條件對成霧的影響，但為了探討不同成霧事件所處的綜觀天氣型態背景，仍選用了 ERA5 再分析資料進行大尺度環流特徵分析。然而，由於 ERA5 資料的空間解析度在臺灣複雜地形下的應用存在一定限制，可能無法精準捕捉山區局地熱力與動力變化，因此，本研究中的 ERA5 資料主要作為辨識大尺度綜觀背景環境（如氣壓場配置與盛行風向）之輔助指標，而非用於直接推導局地起霧之微氣象機制。



### 第三章、時段定義與機器學習模型結果討論

#### 3.1 起霧頻率之日變化與時段劃分

圖 3-1 呈現溪頭與石園起霧頻率之日變化。為維持夜間時段之連續性，圖中時間軸設定為當地時間 06:00 至翌日 06:00。兩站的起霧頻率在傍晚約 17 時達到峰值；其中下午時段石園的起霧頻率最高可接近 0.2，而溪頭亦可接近 0.15，顯示兩站在午後皆有機會起霧，且起霧頻率相近。進入夜間(20 時至 02 時)後，溪頭的起霧頻率於 20 時已快速降至 0.05 以下；相對地，石園夜間起霧頻率約由 0.16 逐步降至 0.08，顯示石園在夜間仍維持相對較多的起霧事件。

圖中紅色虛線為兩站起霧頻率比值(SY/XT)。在午後(12 時至 17 時)比值多低於 1.5，表示兩站日間起霧頻率差異有限；但在夜間(20 時至 02 時)此比值皆高於 3，甚至在 22 時至 00 時可達 4.8 倍，反映石園夜間霧顯著多於溪頭。因此，本研究排除 18-19 的日夜轉換期，以避免混合不同環境控制條件，將 12 時至 17 時與 20 時至 02 時分別定義為兩個重點分析時段。

#### 3.2 模型表現概述

本章分別評估即時預測(t0h)與一小時後預測(t1h)在午後、夜間兩個情境下的 Logistic Regression (LR)、Random Forest (RF) 與 LightGBM (LGBM) 二元分類表現。模型表現以 F1 分數長條圖呈現：左側橘色長條為 10-fold 交叉驗證之 F1 分數平均(黑色短線範圍為平均值正負一倍標準差)，右側藍色長條為獨立測試集之 F1 分數。整體而言，樹模型(RF、LightGBM)普遍優於線性基準模型(LR)，且 LightGBM 表現最佳。結果顯示，模型在夜間情境的預測效能整體優於下午時段。推測這可能與夜間成霧條件有關：在夜間的偵測與預測時，除了環境是否接近飽和之外，上坡風的存在與否基本上主導了霧的生成。這種相對明確的動力與熱力條件，使得模型在夜間情境下相對較容易掌握起霧規律，因而展現出較高的可預測性。

##### 3.2.1 即時偵測(t0h)結果

下午時段(12-17 時)之偵測(t0h)測試集 F1 分數，LR 為 0.848、RF 為 0.856、LightGBM 為 0.882(圖 3-2)；夜間時段(20-02 時)之偵測(t0h)測試集 F1 分數，LR 為 0.883、RF 為 0.908、LightGBM 為 0.912(圖 3-5)。各模型之精確率與召回率亦詳見

圖 3-2 與圖 3-5。

### 3.2.2 一小時後預測 (t1h) 結果

下午時段 (12 - 17 時) 之預測 (t1h) 測試集 F1 分數, LR 為 0.7903、RF 為 0.7948、LightGBM 為 0.8074 (圖 3-3) ; 夜間時段 (20 - 02 時) 之預測 (t1h) 測試集 F1 分數, LR 為 0.8297、RF 為 0.8584、LightGBM 為 0.8600 (圖 3-6) 。各模型之精確率與召回率亦詳見圖 3-3 與圖 3-6。

### 3.2.3 t0h 與 t1h 的差異

相較於 t0h, 各情境與模型之 t1h F1 分數皆有所下降, 反映提前預測量增加所帶來的不確定性。此外, 20 - 02 情境在 t0h 與 t1h 之 F1 分數均高於 12 - 17 情境, 顯示不同時段情境之模型可預測性存在差異。t0h 與 t1h 之測試集 F1 分數對照圖, 見圖 3-4 (12-17) 與圖 3-7 (20-02) 。

## 3.3 特徵重要性 (SHAP)

圖 3-8 顯示, 在兩個情境下樹模型 (RF、LightGBM) 的 SHAP 特徵重要度中, 氣溫與混合比皆為穩定且排名靠前的關鍵特徵, 此結果符合一般認知中高相對濕度 (低溫、高混合比) 有利成霧之物理預期。此外, 午後 (12-17) 情境中, 氣溫的一小時趨勢與上坡風亦具有顯著重要度, 顯示午後起霧除了接近飽和外, 需搭配降溫與上坡風條件; 而夜間 (20-02) 情境中, 上坡風的重要性更為突出, 顯示夜間起霧對局地沿坡環流 (即上坡風) 之依賴程度更強。另外 LR 作為基線模型, 其 SHAP 特徵重要度結果置於補充資料 (圖 S1-S2) 供對照。基於上述結果, 本研究於第四章之 2D 霧頻率分析中, 選取「氣溫、混合比」與「氣溫趨勢、上坡風」作為兩組代表性的環境座標, 以檢視不同熱力與動力條件下的起霧頻率分布。

在下午時段 (12 - 17 時) 情境中, 混合比之一小時趨勢對起霧機率呈負向關聯。圖 3-9 顯示, 模型可能主要捕捉到由午後轉入傍晚時混合比下降較快的日循環訊號, 此一負向關聯並不代表混合比下降有助於起霧。而氣壓變數展現出一定的預測貢獻, 是由於本研究探討短延時之預測, 氣壓的變化主要反映的可能並非大尺度綜觀系統的移入, 而是大氣潮汐所主導的規律日變化, 模型可能透過捕捉此一日變化特徵, 作為輔助辨識特定時間點的指標。



## 第四章、成霧環境條件之統計分析

### 4.1 成霧環境條件之 2D 起霧頻率

本節以二維起霧頻率圖檢視成霧所需之環境條件。霧事件定義採能見度  $< 1000$  公尺，而二維網格分箱是依各圖之座標軸範圍將兩個變數各劃分為 40 個等距區間，形成  $40 \times 40$  個網格；每一網格之起霧頻率定義為該網格內有霧樣本數除以該網格內總樣本數。氣溫-混合比圖（圖 4-1、圖 4-2）之分母總樣本數取該網格內所有 QC 後樣本；氣溫趨勢-上坡風圖（圖 4-3、圖 4-4）則先以相對濕度  $RH > 99\%$  篩選，以在接近飽和之母體中檢視降溫趨勢與上坡風條件對起霧頻率之影響。

由圖 4-1 與圖 4-2 可觀察到，在未達近飽和之條件下之起霧頻率普遍偏低；相對地，較高起霧頻率主要分布於貼近飽和曲線之區域，顯示近飽和為成霧之必要條件。因此於氣溫趨勢-上坡風圖的分析中以  $RH > 99\%$  作為篩選條件，避免飽和與否主導統計結果，並聚焦於接近飽和時其他條件對成霧與否之影響（圖 4-3、圖 4-4）。

在午後（12-17）情境中，較高起霧頻率主要對應於降溫且伴隨上坡風之條件（第二象限）；夜間（20-02）情境之高值區域對降溫趨勢之依賴則較弱，並更集中於上坡風存在的條件，表示夜間起霧與上坡風存在與否之關聯較為重要。

綜合上述，氣溫-混合比圖指出近飽和為成霧之必要條件；在此基礎上，於接近飽和母體內（ $RH > 99\%$ ）檢視氣溫趨勢與上坡風，可見午後（12-17）高起霧頻率對應到降溫與上坡風並存之條件組合，而夜間（20-02）則以上坡風存在與否為最主要的判別依據。此觀察呼應了前章 SHAP 分析的結果：午後情境中降溫趨勢為重要程度高之特徵，而夜間情境中上坡風的重要性則顯著提升。此外，此處之二維起霧頻率圖進一步呈現了單變數 SHAP 分析較難直觀顯示利於成霧的變數組合（如降溫伴隨上坡風的組合條件）。然而，2D 起霧頻率屬條件化統計指標，其高值僅表示在特定條件組合下霧事件比例較高，未必可直接詮釋為觸發機制或因果關係。後續小節將透過霧／非霧分組的上坡風日變化與分布比較，進一步檢視上坡風訊號與夜間起霧頻率差異之關聯。

### 4.2 霧與非霧條件下的上坡風日變化比較

本節比較霧與非霧條件下之上坡風日變化（圖 4-5、圖 4-6）。由於午後（12-17）時兩者之上坡風分布差異相對小，以下以夜間（20-02）為主要討論時段。夜間石園站在有霧時的上坡風中位數約為  $0.8-1.0 \text{ m s}^{-1}$ ，而在無霧時中位數約為  $-0.3$  至  $-0.6 \text{ m s}^{-1}$ ，呈現明顯分

離；而溪頭夜間有霧時，上坡風中位數約為  $-0.2$  至  $0.2 \text{ m s}^{-1}$ ，無霧時中位數則約為  $-0.7$  至  $-0.6 \text{ m s}^{-1}$ 。整體而言，石園夜間起霧與否所產生的上坡風／山風條件之對比更為鮮明，而溪頭夜間多呈現弱上坡風或山風條件，與其夜間起霧頻率顯著偏低之特徵一致。

上述結果顯示，石園夜間霧事件多伴隨明顯上坡風，而無霧時則以山風為主，呈現動力條件上的顯著對比；相較之下，溪頭夜間即使在有霧條件下，風速亦多落於弱上坡風的範圍，顯示上坡風訊號較弱。此一對比提供了夜間上坡風為石園夜間霧偏多之重要線索的觀測支持。惟本節僅基於近地風場指標進行比較，仍需分析石園夜間是否有較多的上坡風發生。

#### 4.3 夜間上坡風比例之站點差異：小提琴圖驗證

為進一步驗證兩站在夜間之上坡風出現頻率存在差異，本研究以小提琴圖呈現每兩個小時上坡風的分布情形（圖 4-7），並以其內嵌之四分位線比較上坡風量值的分布情形。整體而言，溪頭的夜間風速分布呈現高度集中的單峰特徵，峰值偏向山風側（下坡風方向）；相對地，石園的分布不僅較寬廣且較多延伸至正值側（上坡風方向），部分時段甚至呈雙峰分布，顯示其夜間風場可能存在受到下坡風與上坡風兩種不同機制影響的情形。以第一四分位數為基準，石園於 20 時出現上坡風之樣本比例接近 50%，至 02 時仍高於 25%；反觀溪頭進入夜間後，上坡風比例急遽下降，20 時之後即罕有上坡風發生。上述分布差異與石園夜間起霧頻率較高之現象相呼應，顯示夜間上坡風出現頻率之差異，可能為兩站起霧頻率差異的重要原因。

此處所示之夜間上坡風分布差異，與第三章所呈現之夜間起霧頻率差距相互呼應：石園在夜間維持較高起霧頻率，且模型於夜間情境下亦將上坡風視為重要特徵之一，顯示模型所捕捉之統計訊號可被觀測資料支持。

#### 4.4 綜觀環境與夜間上坡風之關聯

為初步檢視綜觀環境與石園夜間上坡風之關聯，本研究以 2022–2024 年之冬季（DJF，12–2 月）與夏季（JJA，6–8 月）為分析期間。首先，計算每日 20:00–21:55 期間石園測站之上坡風風速平均值（具方向性），其中正值代表上坡（上坡風），負值代表下坡（山風）。接著於各季節內依其大小排序，取前 25% 作為上坡日、後 25% 作為下坡日，樣本數則分別為冬季的 46 天與夏季的 43 天。

接著取各上坡或下坡日於當地時間 21:00（LST）之 ERA5 再分析資料 850hPa 風場進行合成，圖中向量與流線為合成後之平均風場，著色為合成平均風速之大小  $|\bar{V}| = \sqrt{\bar{u}^2 + \bar{v}^2}$ 。圖 4-8 至圖 4-11 分別呈現 2022–2024 年的夏、冬季，上坡、下坡日 21:00 之 850 hPa 風

場合成結果。整體而言，夏季在上坡日的背景風向偏西南風，而下坡日則偏南風或東南風；冬季在上坡日背景風向偏北風，而下坡日背景風向則為偏東風。



## 第五章、討論

在石園夜間以下坡風較常發生，然而本研究發現夜間起霧事件中，多數伴隨著上坡風（偏南風）的特徵。此現象可能反映了大尺度背景風場受地形舉升、抑或是特定熱力條件下局部環流的異常發展。由於僅憑單一測站觀測資料無法完全釐清其三維熱力與動力結構，本研究暫時將此夜間上坡風視為水氣輸送與成霧的關鍵動力指標，其詳細物理機制仍有待未來高解析度數值模式或密集觀測網進一步驗證。

關於夜間上坡風在成霧過程中扮演的具體角色，觀測結果顯示，夜間下坡風存在時幾無霧的存在。相對於下坡風強烈的抑制作用，當夜間轉為上坡風，或是缺乏明顯下坡風發展時，局地水氣與熱力條件較易維持近飽和狀態，進而為成霧提供相對有利的環境。因此，本研究將上坡風視為夜間成霧的有利指標，並未斷定上坡風直接造成了雲霧推移或水氣平流。

ERA5 合成圖顯示，石園夜間上坡風／山風日對應之背景風向在夏、冬季皆不同：夏季上坡風日偏西南風、山風日偏南至東南風；冬季上坡風日偏北風、山風日偏東風（圖 4-8 至圖 4-11）。但僅憑本章之結果仍不足以對綜觀環境與夜間上坡風之關聯做出足夠可解釋性之結論，相關機制與更完整的診斷留待後續研究進一步釐清。

後續研究可依背景風場型態（如風向、風速及水氣輸送特徵）對 ERA5 再分析資料進行天氣分類，進一步比較各類背景下石園夜間起霧事件之熱力與動力環境差異，以釐清大尺度背景環境對夜間成霧之影響機制。此外，後續亦可納入更多測站與地形參數、延伸至更長預測提前量，以及結合衛星雲霧產品以提升空間泛用性。



## 第六章、結論

本研究排除 18–19 時的日夜轉換期，聚焦於午後與夜間兩個時段情境，主要結論如下：

(1) 兩站霧頻率日變化存在明顯差異，夜間石園起霧頻率顯著高於溪頭，兩站夜間差異幅度大於日間。

(2) 石園在夜間起霧時段較常出現上坡風訊號，而無霧時則以下坡風為主。由於下坡風極度不利於成霧，當夜間風場轉為上坡風或缺乏明顯下坡風時，局地環境相對有利於維持近飽和狀態，進而提升夜間成霧機率。


(3) 在兩個重點時段（12–17、20–02 時）中，以氣溫、混合比、平行坡向風速分量、垂直坡向風速分量及氣壓五項即時地面觀測變數及其一小時趨勢作為輸入特徵，訓練 LR、RF 與 LightGBM 三種統計模型，皆能提供穩健的霧偵測（t0h）與一小時後短期預報（t1h）；整體上 t0h 優於 t1h，且夜間時段情境較下午時段具有更高的可預測性。

(4) SHAP 分析顯示低溫、高混合比（即近飽和）的條件為起霧的先決條件；在午後情境中，除接近飽和外仍需搭配降溫趨勢與上坡風條件以提高起霧率；而在夜間情境中，上坡風訊號對於起霧判別更為關鍵。此結果支持解釋 SY 夜間霧顯著多於 XT 的重要線索，並可作為後續機制研究與預報模型設計之依據。



## 參考文獻

- Schulz, H. M., Li, C.-F., Thies, B., Chang, S.-C., & Bendix, J. (2017). Mapping the montane cloud forest of Taiwan using 12 year MODIS-derived ground fog frequency data. *PLoS ONE*, 12(2), e0172663. <https://doi.org/10.1371/journal.pone.0172663>
- Li, H. J., Lo, M. H., Juang, J. Y., Wang, J., & Huang, C. Y. (2022). Assessment of spatiotemporal dynamics of diurnal fog occurrence in subtropical montane cloud forests. *Agricultural and Forest Meteorology*, 317, 108899. <https://doi.org/10.1016/j.agrformet.2022.108899>
- Chen, P. J., Chen, W. T., Wu, C. M., Tsou, S. W., & Lo, M. H. (2024). Machine learning detection of fog top over eastern Taiwan mountains from Himawari-8 satellite true-color images. *Remote Sensing Applications: Society and Environment*, 34, 101203. <https://doi.org/10.1016/j.rsase.2024.101203>
- Chong, J. Y., Lo, M. H., & Huang, C. Y. (2024). Quantification of the spatiotemporal dynamics of diurnal fog and low stratus occurrence in subtropical montane cloud forests using Himawari-8 imagery and topographic attributes. *International Journal of Applied Earth Observation and Geoinformation*, 134, 104212. <https://doi.org/10.1016/j.jag.2024.104212>
- Gu, R. Y., Lo, M. H., Liao, C. Y., Jang, Y. S., Juang, J. Y., Huang, C. Y., ... & Chang, K. Y. (2021). Early peak of latent heat fluxes regulates diurnal temperature range in montane cloud forests. *Journal of Hydrometeorology*, 22(9), 2475-2487. <https://doi.org/10.1175/JHM-D-21-0005.1>
- Ou, T. Y., Lo, M. H., Jang, Y. S., & Gu, R. Y. (2024). A Novel Approach of Using High Spatiotemporal Geostationary Satellite to Explore the Characteristics of Near-surface Solar Energy Attenuation. Unpublished manuscript.
- Ellrod, G. P. (1995). Advances in the detection and analysis of fog at night using GOES multispectral infrared imagery. *Weather and Forecasting*, 10(3), 606–619. [https://doi.org/10.1175/1520-0434\(1995\)010<0606:AITDAA>2.0.CO;2](https://doi.org/10.1175/1520-0434(1995)010<0606:AITDAA>2.0.CO;2)



- Colabone, R. D. O., Ferrari, A. L., Vecchia, F. A. D. S., & Tech, A. R. B. (2015). Application of artificial neural networks for fog forecast. *Journal of Aerospace Technology and Management*, 7, 240-246. <https://doi.org/10.5028/jatm.v7i2.446>
- Durán-Rosal, A. M., Fernández, J. C., Casanova-Mateo, C., Sanz-Justo, J., Salcedo-Sanz, S., & Hervás-Martínez, C. (2018). Efficient fog prediction with multi-objective evolutionary neural networks. *Applied Soft Computing*, 70, 347-358. <https://doi.org/10.1016/j.asoc.2018.05.035>
- Vorndran, M., Schütz, A., Bendix, J., & Thies, B. (2022). Current training and validation weaknesses in classification-based radiation fog nowcast using machine learning algorithms. *Artificial Intelligence for the Earth Systems*, 1(2). <https://doi.org/10.1175/AIES-D-21-0006.1>
- Bari, D., Bergot, T., & Tardif, R. (2023). Fog decision support systems: A review of the current perspectives. *Atmosphere*, 14(8), 1314. <https://doi.org/10.3390/atmos14081314>
- Schütz, M., Schütz, A., Bendix, J., & Thies, B. (2024). Improving classification-based nowcasting of radiation fog with machine learning based on filtered and preprocessed temporal data. *Quarterly Journal of the Royal Meteorological Society*, 150(759), 577-596. <https://doi.org/10.1002/qj.4619>
- Castillo-Botón, C., Casillas-Pérez, D., Casanova-Mateo, C., Ghimire, S., Cerro-Prada, E., Gutierrez, P. A., et al. (2022). Machine learning regression and classification methods for fog events prediction. *Atmospheric Research*, 272, 106157. <https://doi.org/10.1016/j.atmosres.2022.106157>
- Schütz, M., Schütz, A., & Bendix, J. (2025). Evaluating station, satellite, & combined data for XGBoost-based visibility forecast. *Atmospheric Research*, 108395. <https://doi.org/10.1016/j.atmosres.2025.108395>
- Bartok, J., Šišán, P., Ivica, L., Bartoková, I., Malkin Ondík, I., & Gaál, L. (2022). Machine Learning-Based Fog Nowcasting for Aviation with the Aid of Camera Observations. *Atmosphere*, 13(10), 1684. <https://doi.org/10.3390/atmos13101684>
- 賴彥任、羅明慧. (2019). 溪頭地區太陽輻射量特性探討. 國立臺灣大學生物資源暨農學院實驗林研究報告, 33(3), 145-156. [https://doi.org/10.6542/EFNTU.201909\\_33\(3\).0001](https://doi.org/10.6542/EFNTU.201909_33(3).0001)

## 圖表




圖 2-1、研究區域與測站位置示意圖。淡藍色星號（★）標示石園（SY，23.476°N, 120.704°E，海拔約 1463 公尺）與溪頭（XT，23.665°N, 120.796°E，海拔約 1250 公尺）兩個觀測站之地理位置。兩站均位於臺灣中部山區，石園站鄰近阿里山茶區，位處曾文溪北側山坡；

溪頭通量塔位於南投縣鹿谷鄉。




圖 2-2、石園測站各小時觀測樣本數統計。上半圖為資料品質控制（QC）前總樣本（灰）、QC 後總樣本（淺藍）與無霧樣本（深藍）之筆數分佈；下半圖為有霧（能見度  $\leq 1000$  m）樣本之筆數分佈。




圖 3-1、石園（SY，藍色）與溪頭（XT，橘色）之起霧頻率（fog frequency）逐小時日變化（2022 - 2024 年 QC 後全年資料）。起霧頻率定義為每小時通過資料品質控制（QC）之樣本中，能見度（Visibility）< 1000 公尺之有霧樣本占比。橫軸為當地時間（LST，UTC+8），時序自 06:00 起至隔日 06:00 止，以保留完整夜間時段；紅色虛線為兩站起霧頻率比值（SY/XT，右側縱軸），比值越高代表兩站差異越大。粉紅色底色標示本研究兩個重點分析時段：下午（12 - 17 時）及夜間（20 - 02 時）。




圖 3-2、當地時間 12 - 17 時偵測（t0h）各模型分類表現比較。以「有霧（能見度 < 1000 公尺，fog = 1）」為正類，以「無霧（fog = 0）」為負類。橫軸為三種分類模型（LR：Logistic Regression；RF：Random Forest；LGBM：LightGBM），縱軸為各指標分數。橘黃色柱（Validation 10-fold）為十折交叉驗證之平均 F1 分數，黑色誤差線為  $\pm 1$  標準差；藍色柱（Testing F1）、橘色柱（Testing Acc）、綠色柱（Testing Prec）及紅色柱（Testing Recall）分別為獨立測試集之 F1 分數、正確率（Accuracy）、精確率（Precision）及召回率（Recall）。




圖 3-3、當地時間 12 - 17 時一小時後預測 (t1h) 各模型分類表現比較。圖例說明同圖 3-2。




圖 3-4、當地時間 12 - 17 時偵測 (t0h, 左側) 與一小時後預測 (t1h, 右側) 之獨立測試集

F1 分數對照圖。三種模型（LR、RF、LGBM）之 F1 分數以長條圖並排呈現，以便直接比較不同預測提前量對各模型表現之影響。




圖 3-5、當地時間 20 - 02 時偵測 (t0h) 各模型分類表現比較。圖例說明同圖 3-2。




圖 3-6、當地時間 20 - 02 時一小時後預測 (t1h) 各模型分類表現比較。圖例說明同圖 3-2。




圖 3-7、當地時間 20 - 02 時偵測 (t0h, 左側) 與一小時後預測 (t1h, 右側) 之獨立測試集 F1 分數對照圖。圖例說明同圖 3-4。




圖 3-8、兩個時段情境下隨機森林（RF，左欄）與 LightGBM（LGBM，右欄）之偵測（t0h）SHAP 特徵重要度比較。上方兩圖為當地時間 12 – 17 時，下方兩圖為當地時間 20 – 02 時。

縱軸為各模型前七名重要特徵（依重要度由大至小排列），橫軸為平均絕對 SHAP 值  $[\text{mean}(|\text{SHAP}|)]$ ，代表各特徵對模型輸出對數勝算之平均絕對貢獻量。紅色表示該特徵與有霧機率呈正相關，黑色表示負相關（依 Spearman 相關係數方向判定）。Upslope wind 正值代表上坡風，負值代表下坡風；帶「\_trend」後綴者表示一小時差分量  $X(t) - X(t-1 \text{ h})$ 。




圖 3-9、石園 (SY；2022–2024 年 QC 後全年資料) 氣溫 (Temperature, °C，左縱軸，藍色) 與混合比 (Mixing Ratio,  $\text{kg kg}^{-1}$ ，右縱軸，紅色) 之逐小時平均日變化。橫軸為當地時間 (LST, UTC+8)。




圖 4-1、石園 (SY) 當地時間 12–17 時 (2022–2024 年 QC 後資料) 以氣溫 (Temperature, °C) 為橫軸、混合比 (Mixing Ratio,  $\text{kg kg}^{-1}$ ) 為縱軸之二維起霧頻率分布圖。色塊表示各網格 (40×40 等距分箱) 內有霧樣本 (能見度 < 1000 公尺) 占該網格總樣本數之比例 (即起霧頻率, 色軸見右側色條) ; 黑色等值線標示各網格總樣本數; 淡藍色曲線 (Saturation) 為依石園站觀測期間平均氣壓所計算之飽和水氣混合比曲線。




圖 4-2、石園當地時間 20 - 02 時之二維起霧頻率分布圖，圖例說明同圖 4-1。




圖 4-3、石園（SY）當地時間 12 - 17 時（2022 - 2024 年；RH > 99% 子集）以一小時氣溫趨勢（ $^{\circ}\text{C}$ ）為橫軸、上坡風速（Upslope wind, 公尺/秒）為縱軸之二維起霧頻率分布圖。色塊與等值線定義同圖 4-1。縱軸正值代表上坡風，負值代表下坡風；橫軸負值表示過去一小時氣溫下降。




圖 4-4、石園當地時間 20 - 02 時之二維起霧頻率分布圖，圖例說明同圖 4-2。




圖 4-5、石園 (SY; 2022 - 2024 年 QC 後全年資料) 有霧 (藍色圓點, Fog: 能見度 < 1000

公尺) 與無霧 (橘色方點, No-fog) 條件下之上坡風速 (Upslope wind, 公尺/秒) 逐小時中位數日變化。陰影帶為 15 - 85 百分位區間; 正值代表上坡風, 負值代表下坡風。橫軸為當地時間 (LST, UTC+8), 时序自 06:00 起至隔日 06:00 止; 粉紅色底色標示重點分析時段: 12 - 17 時及 20 - 02 時。




圖 4-6、溪頭 (XT; 2022 - 2024 年 QC 後全年資料) 有霧與無霧條件下之上坡風速 (Upslope wind, 公尺/秒) 逐小時中位數日變化。圖例說明同圖 4-5。




圖 4-7、當地時間 20 - 02 時 (2022 - 2024 年 QC 後資料) 石園 (SY, 藍色) 與溪頭 (XT, 橘色) 之上坡風速 (Upslope wind, 公尺/秒) 逐兩小時分布比較。每個小提琴圖之外形反映核密度估計分布；內嵌四分位箱顯示中位數 (白點) 及第 25 - 75 百分位 (粗箱)；正值代表上坡風，負值代表下坡風。




圖 4-8、冬季（DJF：12–2 月；2022–2024 年）上坡日（當地時間 20–21 時石園上坡風速前 25%， $n=46$  天）之 ERA5 再分析 850 hPa 風場合成圖（合成時刻為當地時間 21:00）。色塊為合成平均風速大小  $|\bar{V}| = (\bar{u}^2 + \bar{v}^2)^{0.5}$ （公尺/秒，色條見右側），流線與箭頭顯示合成平均風向；淡藍色星號（★）標示石園（SY）與溪頭（XT）之地理位置。




圖 4-9、冬季下坡日之 ERA5 再分析 850 hPa 風場合成圖。圖例同圖 4-8。




圖 4-10、夏季 (JJA：6 - 8 月；2022 - 2024 年) 上坡日 (當地時間 20 - 21 時石園上坡風速前 25%， $n=43$  天) 之 ERA5 再分析 850 hPa 風場合成圖 (合成時刻為當地時間 21:00)。

圖例說明同圖 4-8。




圖 4-11、夏季下坡日之 ERA5 再分析 850 hPa 風場合成圖。圖例同圖 4-10。




圖 S1、當地時間 12 - 17 時偵測(t0h)基準線性模型(LR：Logistic Regression)之 SHAP 特徵重要度。縱軸為前七名重要特徵，橫軸為平均絕對 SHAP 值 [mean(|SHAP|)]；顏色定義同圖 3-8。




圖 S2、當地時間 20 - 02 時偵測(t0h)基準線性模型(LR：Logistic Regression)之 SHAP 特徵重要度。圖例說明同圖 S1。