


A foggy airport runway at night, illuminated by runway lights. A futuristic digital overlay is visible, featuring a glowing blue grid on the ground, a central data panel with various numbers and labels, and a bright blue horizontal line of light. The background is a thick layer of fog or mist.

探索濃霧：基於深度學習的機場輻射霧預測模型

以嘉義水上機場為例之時間序列分析 (RNN, LSTM, GRU)

報告時長：10-12 分鐘

致命的水平視障：無法防禦的瞬間盲區



1977 特內里費(Tenerife)空難

濃霧導致兩架即將起飛的波音747在跑道高速相撞，全球單一失事死傷最慘重的重大事件。

2010 斯摩倫斯克(Smolensk)空難

搭載波蘭總統的 Tu-154M 客機於俄羅斯摩倫斯克北機場，因大霧降落時墜毀。

核心痛點：濃霧會瞬間剝奪飛行員對跑道與地形的辨識能力。預防勝於臨場反應，精準預報是飛安最後防線。

研究對象與時空邊界



氣象報 (METAR) 資料範圍：2012/1/1 至 2025/1/31 整點鐘資料。

訓練集 (Training Set) :
2012 - 2023年

測試集 (Testing Set) :
2024年 - 2025年1月



註：原計畫逐日預測2026年第一季起霧機率，因未取得2025全年資料而調整預測標的。

目標場域：嘉義水上機場 (RCKU)

軍民合用，地勢低平且夜間輻射冷卻效應強，具備易產生輻射霧之完美條件。

運算環境與技術堆疊 (Tech Stack)

開發環境層

Jupyter Notebook

程式撰寫、運行與視覺化輸出的整合介面

軟體核心層

Python + PyTorch

基礎運行環境與深度學習模型建構框架

實體運算層

Genuine 15H-13-RNCQ 筆記型電腦

Intel i5 處理器 + NVIDIA RTX 4050

提供深度學習所需的 GPU 加速



標準化預測模型建構流程



Step 1: 資料前處理

清洗 METAR 缺失值、數值正規化

時間特徵週期性轉換 (sin/cos)，保留季節與日夜遞變規律



Step 2: 兩階段模型訓練

第一階段：特徵篩選 (Feature Selection)

第二階段：學習率策略優化 (Learning Rate Tuning)




Step 3: 模型驗證與評估

不只看準確率 (Accuracy) 與時間 (Time)

導入混淆矩陣 (Confusion Matrix) 與 Macro F1 指數


第一階段：數據篩選印證物理機制



AI 憑藉純數據學習，精準還原了自然物理法則。依據訓練準確率，為各模型選出 3 組最佳氣象因子組合（包含 QNH, RAM, RAT 等輔助因子），進入第二階段學習率測試。


第二階段：學習率策略設計 (Learning Rate Strategies)

固定學習率 (Fixed)




步伐一致，表現穩健，但容易在複雜資料中陷入局部最佳解。

階梯式衰退 (Step Decay)



由高至低呈階梯狀下降。初期步伐大以快速學習，後期步伐縮小以進行精細收斂。

階梯式熱身 (Warm Up)



初期步伐小以避免震盪，隨後放大步伐，防止模型過早陷入保守預測。

關鍵變數：調整學習率策略，將成為改變模型捕捉小概率事件（起霧）敏感度的核心鑰匙。

隱形陷阱：資料不平衡與 95% 的準確率幻覺



極端不平衡的樣本：嘉義機場一年起霧天數極少（常低於20天）。

準確率的謊言：如果模型偷懶，永遠只預測「不起霧」，它依然能輕鬆獲得 $>90\%$ 的整體準確率 (Accuracy)。但在飛安實務上，這毫無意義且極度危險！

評估指標升級：放棄單一準確率，導入混淆矩陣 (Confusion Matrix) 嚴格檢視漏報 (FN) 與誤報 (FP)，並加入 Macro F1 指數，真實反映對小概率事件的捕捉力。

LSTM 模型表現解析：困於多數偏好

整體表現

準確率：91% - 97%

運算時間：約 1200-1300 秒

(極高準確率主要得益於準確預測大量不起霧)

小概率捕捉力疲弱

在多數設定下，LSTM 的漏報數 (FN) 依然大於正確命中數 (TP)。模型因複雜的門控機制，容易將細微的起霧特徵視為雜訊過濾掉。

最佳配置

採用 [TTT, TTD, RAT] 搭配階梯式熱身，成功讓 TP(16) 大於 FN(10)，但整體 F1 指數仍偏低。

True Negative

False Positive

FN
(漏報)

TP
(命中)

GRU 模型表現解析：最高效的運算與極端的代價



整體表現

準確率：最高 (達 97%)

運算時間：約 1200 秒 (全場最短，效率極佳)

激進的防禦配置

採用 [TTT, TTD, RAM] 搭配階梯式熱身策略時，GRU 成功命中高達 20 次起霧 (TP，全場最佳之一)，漏報僅 6 次 (FN)。

誤報的代價

為了不漏報，該配置付出了高達 940 次誤報 (FP) 的代價。模型變得極度敏感，用海量的假警報換取飛安的絕對不漏報。

True Negative

940

FP (誤報)

FN
(6)

TP
(20)
命中

RNN 模型表現解析：落後架構的反常優勢

整體表現

準確率：最低 (76% - 92%)

運算時間：最長 (近 2000 秒)

缺乏過濾機制的意外收穫

RNN 因為沒有 LSTM/GRU 複雜的門控機制，反而不會輕易過濾掉細微的特徵（雜訊）。

小概率預測的突出

RNN 在絕大多數配置下，正確命中起霧 (TP) 的次數都高於漏報 (FN)。特別在階梯式熱身學習率下，展現了強大的特徵保留能力（儘管伴隨龐大誤報量）。



深度學習模型綜合比較矩陣

	LSTM	GRU	RNN
運算效率 (Time)	● 佳 (~1300s)	● 優 (~1200s)	○ 劣 (~2000s)
整體準確率	優 (>93%)	優 (>96%)	待加強 (~86%)
特徵過濾度	高 (易漏報)	高 (易漏報)	低 (保留雜訊)
捕捉起霧敏感度 (TP>FN)	弱 ↓	中 →	強 ↑

實務導入首選為 GRU (效率與準確率最佳) ;
但RNN提供了保留細微起霧特徵的關鍵演算法研究線索。

實證結論 I：AI 可行性與物理機制的完美驗證

技術流程全驗證


本研究完整建立從 METAR 資料清洗、時間序列轉換，到深度學習模型訓練與評估的標準化作業流，證明 AI 預測機場低能見度在技術上具備高度可行性。

數據證明物理

最令人振奮的是，三個模型在無人為干預下，自主篩選出「氣溫 (TTT)」與「露點 (TTD)」為預測起霧的核心因子，完美印證了氣象學中「輻射霧」的生成機制。AI 學會了自然法則。

實證結論 II：飛安視角下的模型取舍

高準確率
(預測不起霧)



飛航安全
(捕捉起霧)

準確率陷阱的破解

高準確率大多來自大量預測成功的不起霧。但在飛安實務中，漏報 (FN) 導致的潛在災難成本，遠遠高於航班延誤的誤報 (FP) 成本。

超參數的藝術

如何在固定學習率的穩健，與變動學習率（如階梯式熱身）的激發敏感度之間做取舍，是未來演算法調校的核心。必須學會接受一定程度的誤報，來換取極端氣象的成功捕捉。

未來展望與應用建議



邁向機率預報

放棄僵硬的二元分類（起霧/不起霧），比照降雨機率，針對機場發布「霧靄機率預報（Probability Forecast）」，提供航空公司更彈性的調度決策空間。

擴充特徵維度

納入「靄 (Mist)」將預測轉為三元分類以擴大樣本數，並整合雷達回波、衛星雲圖等多源資料，從根本解決樣本不平衡問題。

前瞻模型導入

未來應嘗試導入 Transformer 或注意力機制 (Attention Mechanism) 模型，進一步提升對長時間序列與空間氣象特徵的精準捕捉。