

中華民國第 65 屆中小學科學展覽會

作品說明書

高級中等學校組 地球與行星科學科

第三名

051906

雲屬判讀 Teachable Machine AI 模型

學校名稱： 新竹市私立曙光女子高級中學

作者： 高二 李宜家	指導老師： 周明麗
-------------------	------------------

關鍵詞： 雲屬判讀、圖像辨識、模型訓練

雲屬判讀 Teachable Machine AI 模型

摘要

無人氣象站的應用提升了大氣觀測的數據收集效率，雲屬自動判讀仍然是一項技術挑戰。本研究參考 WMO 國際雲圖鑑，進行雲屬影像的收集與分類，並利用 Teachable Machine 圖像辨識模型進行訓練，建立具備十種雲屬辨識能力的模型並探討學習率與訓練週期對模型判讀準確度的影響。實驗結果顯示，不同雲屬的分類準確度受雲屬特徵影響，層積雲與積雨雲因特徵變化較大，易產生混淆。經超參數調整發現，較低學習率有助於提升整體準確率，而訓練週期的增加或減少對準確率的影響則較不顯著。本研究證實機器學習技術在雲屬觀測上的可行性，未來可透過擴展資料集與優化模型，提高對不同天氣條件下雲屬變化的適應能力。

壹、前言

一、研究動機

近年來，大氣地面觀測已逐漸採用無人氣象站進行數據收集[1]，提升觀測效率。然而現階段唯一無法克服的就是雲的觀測，雲屬判讀與分類的自動化仍是一大挑戰[2]，主要原因在於雲的形態變化多樣[3]。在國際通用的十雲屬分類基礎上，每個雲屬還包含十個雲屬、十五種雲類、九種變型以及變化複雜的衍生雲和各雲屬間的轉化雲[4]，使得傳統的觀測工作高度依賴人工經驗判斷[5]，人工判斷的主觀心態可能會造成資料取得的標準有變動[13]。

從人工觀測轉向自動化觀測雲。各種傳感設備在雲的觀測中廣泛應用。然而這類儀器測量方法的缺點是觀測結果的分辨率低，且容易受到空氣雜質和濕度等因素的干擾，導致較大的觀測誤差[6]，為解決此問題，本研究希望結合人工智慧圖像辨識技術，透過 Teachable Machine 嘗試訓練一套能夠辨識具備判斷十雲屬的 AI 模型。此研究不僅有助於提高雲屬觀測的自動化程度，還能夠為大氣科學提供更精確的觀測數據支持。

二、文獻回顧

1、Teachable Machine 模型

隨著機器學習技術的普及，Teachable Machine 是一個基於網頁的互動介面，能無需編碼便可建立機器學習分類模型。其核心技術依賴於 TensorFlow.js 模型，使用戶僅需少量數據即可重新訓練基於預訓練模型的分類器，並快速實現分類任務。[7]

Teachable Machine 隱藏了模型訓練的複雜性。例如: MobileNet(輕量化深度學習

模型) 作為基礎模型，原本訓練於包含 1000 種類別的大型數據集，潛在特徵可以用於識別用戶自行定義的類別。這種方式不僅縮短了訓練時間，減少了數據需求，可以透過有限的資料進行模型訓練，降低了機器學習的應用門檻。[8]

2、雲的分類

雲的形成機制與其物理特性相關，依據其形成的雲粒相態可分為水雲、混合雲和冰晶三類。積狀雲常出現在不穩定的上升氣流中，呈現向上發展的特性。層狀雲則是在穩定的大氣條件下形成，以水平方向擴散。這些特性是雲的分類與觀測的基礎依據。[9, pp.58-60]

國際氣象組織（World Meteorological Organization 以下用 WMO 簡稱）採用十種雲屬作為標準分類，這些雲屬根據雲的外觀、結構以及形成高度進行劃分。以下為各類雲屬的主要辨識特徵：

(一) 卷雲（Cirrus, Ci）：

卷雲通常呈現白色、纖維狀或羽毛狀，位於高空(離地面約 5 到 13 公里)，特點是透光性強，可清晰觀察到太陽或月亮，並無降水現象，有五個雲類和四個變型。[9, pp.64-65]

(二) 卷積雲（Cirrocumulus, Cc）：

此類雲以小型圓斑狀分布，每個雲的個體較小，當從地面觀察，單個雲的大小在仰角 30 度以上時小於手指寬度，顏色多為白色且不帶陰影，有四個雲類和兩個變型。[9, pp.68-69]

(三) 卷層雲（Cirrostratus, Cs）：

具有薄薄的均勻雲層外觀，常出現日暈現象。當卷層雲覆蓋整個天空時，太陽和月亮可能仍隱約可見，有兩個雲類和兩個變型。[9, pp.72-73]

(四) 高積雲（Alto cumulus, Ac）：

高積雲呈白色或灰白色塊狀分布，雲塊多為圓形或層狀，大小介於卷積雲和層積雲之間，常見於穩定天氣條件下，有五個雲類和七個變型。[9, pp.74-76]

(五) 高層雲（Altostratus, As）：

高層雲為灰色或淡藍色的均勻雲層，通常覆蓋大部分天空，導致陽光變得模糊且無明顯陰影，有時會帶來小雨。高層雲中不會出現暈，沒有雲類，有五個變型。[9, pp.80-81]

(六) 層積雲（Stratocumulus, Sc）：

這類雲呈現較大塊且不規則的圓頂狀雲塊，分布於低層天空，顏色介於灰白色至深灰色，天氣穩定時常見單獨出現的層積雲，也會經由兩層雲轉化，積雲和積雨雲像水平擴散時也會形成，有五個雲類和七個變型。[9, pp.84-85]

(七) 層雲（Stratus, St）：

層雲較低且均勻的灰色雲層，覆蓋範圍廣泛，通常伴隨陰天，但不一定帶來降水與地面接觸時會形成霧，有兩個雲類和三個變型。[9, pp.90]

(八) 雨層雲 (Nimbostratus, Ns) :

雨層雲厚實且水平分布，多呈暗灰色，為持續性降水（如大雨或小雨）的主要來源，沒有雲類與變型。[9, pp.83-84]

(九) 積雲 (Cumulus, Cu) :

積雲具有明顯的圓頂狀結構，頂部可能呈羽毛狀，雲體輪廓分明，通常預示穩定的天氣條件，視雲的發展高度也可能帶來局部降水，有四個雲類和一個變型。[9, pp.93-94]

(十) 積雨雲 (Cumulonimbus, Cb) :

積雨雲為垂直發展雲，水平分布範圍可達 10 公里，高度可由接近地表發展至距離地面 2 公里，有兩個雲類。[9, pp.96-97]

3、雲屬判讀與氣象預報之關聯:

雲屬判讀在氣象預報中因為不同類型的雲層與大氣動力過程和天氣系統密切相關。透過對雲的形態、結構及發展趨勢的分析，可以推測大氣穩定度、降水可能性及即將發生的天氣變化。

高雲族(卷雲、卷積雲、卷層雲) 主要由冰晶組成，通常出現在對流層的上部，與大尺度天氣系統相關。例如，卷雲的出現通常被視為暖鋒靠近的先兆，當其演變為卷層雲時，可能預示降水即將發生。卷雲在高空噴流附近的分布也與風切有關，影響航空氣象預報[9, pp.66-68]。卷層雲則經常形成光暈現象，代表大氣中冰晶含量較高[9, pp.72-74]。卷積雲可能伴隨大氣波動形成波狀的雲層，可能反映高空氣流變化[9, pp.69-70]，並且在颱風外圍環境中可觀察到高雲族的雲屬。

中雲族(高層雲、高積雲、雨層雲)可能由水滴或冰晶混和組成，高積雲的出現通常受到大氣波動、風切、對流影響[9, pp.75] 高層雲在溫帶氣旋接近時會大範圍出現[9, pp.81]若覆蓋整個天空，通常導致長時間的陰雨天氣。雨層雲出現會引起降水[9, pp.83]。

低雲族(層積雲、層雲)主要分布於對流層下部，以水滴為主要成分，與局部天氣變化及降水過程密切相關。層積雲可能出現輕微小範圍降水，或是轉化為積雲、雨層雲等雲屬[9, pp.84]。層雲單獨出現通常不會產生降水，但在接近地面會產生霧[9, pp.90-91]。

積雲、積雨雲的出現通常表示大氣處於熱對流旺盛的環境，可能產生驟雨或是雷暴[9, pp.94-97]。

4、冷鋒鋒面與飆線系統

冷鋒（cold front）是當性質不同的氣團相遇時，在地面上形成的分界線之一，通常是較冷、密度較大的空氣團推較暖空氣區域所形成的鋒面系統。冷空氣密度較高，在鋒面處迫使暖空氣沿鋒面抬升，進而引發強烈的上升氣流，促成雲的生成與發展。冷鋒的通過常伴隨大量積雲或積雨雲的形成，並可能帶來劇烈天氣現象，如短時強降雨、雷暴或陣風。

當大氣條件具高度不穩定性時，冷鋒前緣或其附近可能形成組織化的對流系統。飗線（squall line）為呈線狀排列的積雨雲群，動速度快易引發短時間的強降雨、雷擊及強陣風。雖然其移動迅速，降雨持續時間短，但其瞬間雨強與風速常造成明顯影響。在垂直風切環境下，飗線可進一步組織化並在背後形成新的積雨雲，使降水區域擴大，甚至導致集中豪雨。[14]

三、研究目的

本研究透過機器學習技術，開發一套基於 Teachable Machine 的雲類觀測與分析系統，建立自動化的雲屬分類模型，以提升氣象觀測的效率與準確性。透過該系統，使用者可利用攝影設備即時拍攝天空影像，並經由模型判別雲層種類，進一步分析雲屬。

- 1、訓練能夠分別十雲屬的模型。
- 2、探討學習率和訓練週期對雲屬判讀模型的影響。
- 3、分析 AI 在判讀雲屬混淆的細節和可能原因。
- 4、探討雲屬判讀 AI 在觀測冷鋒鋒面飗線型降水帶的應用成效，分析其在中尺度系統觀測中的優勢與限制。

貳、研究設備與器材

一、個人電腦

- 1、裝置名稱: LAPTOP-VKSNTR02
- 2、處理器: AMD Ryzen 5 PRO 3500U w/ Radeon Vega Mobile Gfx2.10 GH
- 3、版本: Windows 10
- 4、記憶體: 8.00 GB

二、Teachable Machine

Teachable Machine 是 TensorFlow.js 模型支援所有執行 javascript 的環境，2017 推出。

三、攝影機

廠牌: Canon

型號: EOS800D

四、腳架: 固定拍攝仰角為 60

五、地面觀測站

地面觀測站為百葉箱內安裝自動氣象資料收集儀器，可收集溫度、氣壓、相對濕度等地面觀測數據，內建有電路板將儀器數據輸入記憶卡中，再由人工取出記憶卡讀取數據。供電來源主要為百葉箱外的太陽能板。




圖 1 儀器內部電路板與電池



圖 2 氣象儀器



圖 3 百葉箱外觀

參、 研究過程與方法

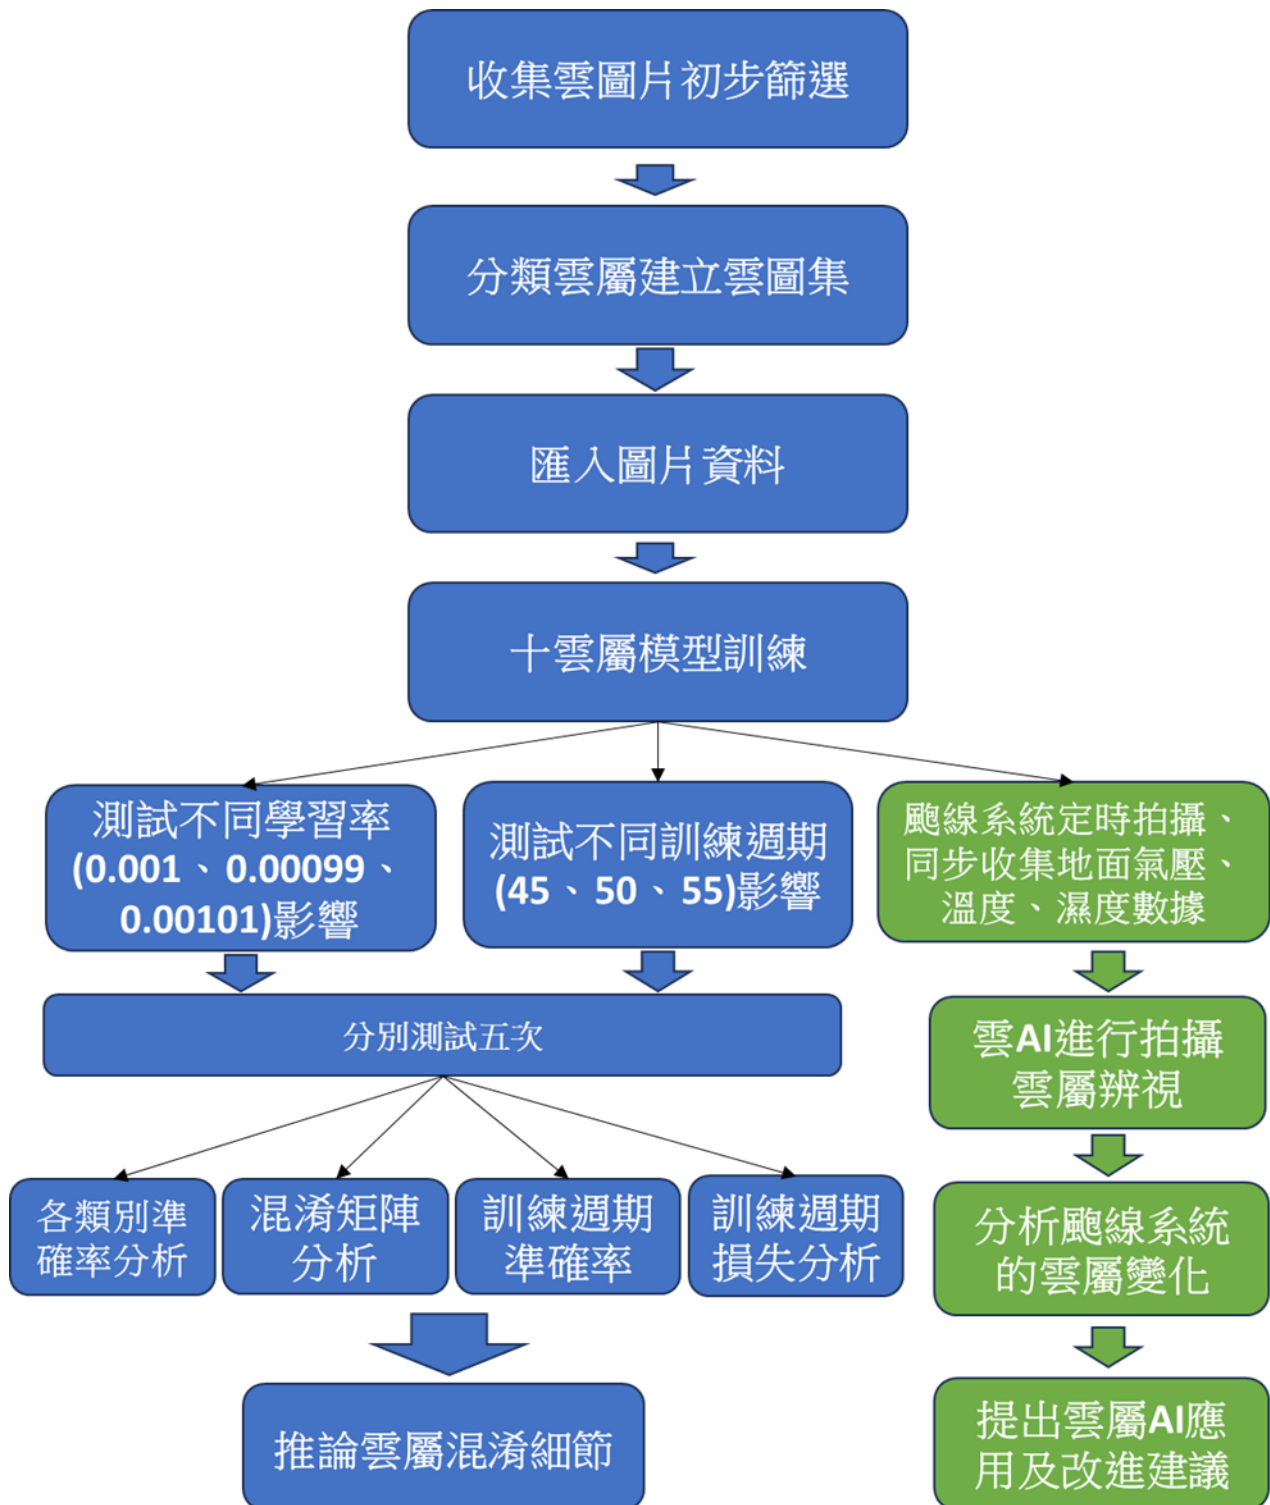


圖 4 本研究研究流程圖

一、 資料預備

本研究需收集大量雲圖片作為訓練依據，為了收集特徵明顯、標註雲屬的雲圖片作為本研究的數據，確保模型訓練過程使用有代表性的特徵，可以依照 WMO 國際雲圖鑑分類標準進行訓練前的資料分類。

1、雲圖片收集

(一)開放資料:本研究初步使用 WMO 國際雲圖鑑（International Cloud Atlas）作為訓練資料來源。然而，該資料庫中的雲圖片數量有限，各雲屬之間的資料量亦存在明顯落差。此外，部分圖片同時包含一種以上的雲屬或是影像模糊而無法清晰辨識雲型，容易造成模型混淆。因此，去除上述不符合條件的影像，保留具有清晰且單一雲屬特徵之圖片，每類雲屬篩選出 50 張作為初步資料。

考量到若每類資料量過少，可能於 AI 模型訓練過程中造成批次重複訓練的問題，本研究進一步引入由日本雲研究所的已標註雲圖片。該資料集依循 WMO 分類標準整理，並為每類雲屬補充 500 張清晰影像。最終每種雲屬共使用 550 張圖片，本研究雲屬判讀模型的訓練資料集為每個雲屬 550 張雲圖中隨機 500 張，測試集為剩餘 50 張。

(二)數據標註

WMO 的雲圖片已經對每一種雲屬進行標記，並記錄每張圖片中雲屬發生的情況。



圖 5 十雲屬拍攝範例

二、 測試數據與訓練參數

為了評估 AI 模型的分類能力，收集到的圖片再分類為數據分為以下三個部分：

- 1、訓練集：每一種雲屬分別使用 500 張圖片，用於 AI 模型訓練，讓 AI 學習雲屬特徵，調整模型權重。
- 2、測試集：用於最終模型評估，每個雲屬各 50 張測試模型在未見過數據上的表現，調整參數。

完成數據集的收集與劃分後，開始進行 AI 模型的訓練。本研究使用 Teachable Machine 作為基礎模型訓練工具，結合卷積神經網絡（convolutional neural network，縮寫：CNN）進行雲屬分類。

(一) 訓練超參數設定

為了提高模型的訓練效率與準確度，本研究調整模型的超參數，參考文獻中提到，超參數是在訓練機器學習模型之前，事先設定的參數，這些參數並非模型透過學習數據自動調整，而是根據使用者經驗來決定。不同的超參數設定會影響模型的訓練效果。本研究將調整學習率以及訓練週期，分析較佳的模型超參數設定。

表 1 本研究超參數設定

參數名稱	預設值	影響
輸入影像大小	224×224px	統一圖片尺寸
批量	16	平衡計算效能與訓練穩定性
訓練週期	50	訓練模型必須處理訓練資料的次數
學習率	0.001	控制模型學習的幅度大小

(二) 超參數的功能

1. 批量:單一訓練疊代中使用的一組樣本，即每一次進行訓練的圖片數量。假設全體資料為 80 張圖片，批量設為 16，則將分成 5 批次(80/16)進行資料處理，完成所有批次即為一個訓練週期，對模型訓練較無影響。
2. 訓練週期:當模型訓練的每個樣本都經過一次模型處理後即為一次訓練週期。
3. 學習率:測量模型的預測和實際輸出的錯誤，目的在於減少損失功能，提升準確度，此超參數會影響模型的學習速度和效果，如果學習率過大，權重更新幅度過大，可能導致模型不斷跳過最佳解，可能造成無法完全學習的問題。

題。學習率過小權重更新幅度過小，模型的學習速度會變慢，訓練時間延長，並且因為幅度小結果容易停留在局部最小值，難以找到最優解。學習率通常設為小的正數（例如 0.001、0.0001 等），這樣可以確保模型穩定地學習，不會因為步伐過大而錯過最佳解，或因為步伐過小而學習過慢，本研究初始設定模型學習率為 0.001，測試變因改變為較大者 0.00101，較小者為 0.00099。

三、 模型訓練

根據以上雲圖片資料篩選方法和訓練參數設定，實驗中利用 Teachable Machine 進行模型訓練，並進一步在 Tensorflow 調整學習率為 0.00101、0.001、0.00099，分析不同學習率造成的影響，提升模型準確度。

四、 結果分析

1、各類別準確率:

計算 AI 模型對不同雲屬的分類正確率，計算公式如下:[10]

$$\text{某類別準確率} = \frac{\text{正確分類為該類別的數量}}{\text{被模型分類為該類別總數量}}$$

2、混淆矩陣:

用來評估機器學習分類模型的工具，可以顯示模型的預測結果與真實情況之間的對應關係。能夠幫助了解模型在哪些類別表現良好、哪些類別有錯誤。

3、推論雲屬混淆細節:

透過記錄易混淆雲屬進行人工的雲種判讀，觀察測試集圖片細節與易產生混淆的結構與原因。

五、 冷鋒鋒面飈線系統通過期間雲屬判讀實驗

1、資料蒐集與分段:

本研究於 2025 年 5 月 24 日 早上 8:00-12:30，東經 120 度 56 分 54 秒 北緯 24 度 47 分 02 秒進行冷鋒鋒面飈線系統的拍攝，根據中央氣象署雷達回波以及校內地面觀測數據，將事件劃分為「飈線接近前」、「飈線通過中」、「飈線遠離後」三個階段。每階段定時拍攝具有代表性的雲屬照片，並記錄拍攝時間、地點及對應氣象觀測資料。

2、模型判讀

將上述實地拍攝之雲圖片輸入訓練完成的雲屬判讀 Teachable Machine 模型中，進行判讀。透過輸出預測雲屬類別來檢驗模型在實際應用中的可行性，並提出未來發展 AI 雲觀測之建議。

肆、研究結果

一、調整模型學習率為 0.00101、0.001、0.00099 統計各類別準確率、混淆矩陣、訓練週期準確率、訓練週期損失。

1、各模型準確率: 橫軸標題 acc1-acc5 為五次準確率測試

表 2 學習率 0.001 時各類別的準確率

雲屬	acc1	acc2	acc3	acc4	acc5	Average
卷雲	0.38	0.75	0.75	0.13	0.50	0.502
卷積雲	0.63	0.75	0.75	0.75	0.63	0.702
卷層雲	0.63	0.63	0.50	0.63	0.75	0.628
高積雲	0.75	0.50	0.50	0.63	0.50	0.576
高層雲	0.63	0.75	0.63	0.88	0.63	0.704
雨層雲	0.88	0.75	0.88	0.63	0.88	0.804
層積雲	0.38	0.25	0.50	0.38	0.38	0.378
層雲	0.38	0.38	0.38	0.75	0.38	0.454
積雲	0.50	0.50	0.75	0.50	0.25	0.500
積雨雲	0.63	0.50	0.38	0.50	0.63	0.528
總和	5.79	5.76	6.02	5.78	5.53	5.776




圖 6 學習率 0.001 時各類別的準確率比較圖

(一)學習率 0.001 的模型中，雨層雲 (0.804) 準確率最高，層積雲 (0.378) 和層雲 (0.454) 的準確率較低。

表 3 學習率 0.00101 時各類別的準確率

雲屬	acc1	acc2	acc3	acc4	acc5	Average
卷雲	0.38	0.25	0.50	0.50	0.50	0.426
卷積雲	0.88	0.63	0.75	0.88	0.75	0.778
卷層雲	0.75	0.38	0.75	0.63	0.50	0.602
高積雲	0.75	0.63	0.63	0.63	0.63	0.654
高層雲	0.75	1.00	1.00	0.63	0.75	0.826
雨層雲	0.88	0.88	0.5	0.10	0.88	0.648
層積雲	0.63	0.13	0.38	0.38	0.25	0.354
層雲	0.38	0.75	0.50	0.63	0.63	0.578
積雲	0.50	0.63	0.25	0.63	0.25	0.452
積雨雲	0.50	0.13	0.38	0.38	0.50	0.378
總和	6.40	5.41	5.64	5.39	5.64	5.696




圖 7 學習率 0.00101 時各類別的準確率比較圖

(二) 學習率 0.00101 的模型整體準確率較學習率 0.001 的結果在卷積雲、高積雲、高層雲、層雲等雲屬上有所提升，但部分雲屬的準確率下降，表現較不穩定。高層雲(0.826) 準確率最高，層積雲 (0.354) 和積雨雲(0.378) 的準確率較低。存在學習率過高，導致模型無法穩定收斂，出現過擬合或欠擬合的問題，影響整體準確率。

表 4 學習率 0.00099 時各類別的準確率

class	acc1	acc2	acc3	acc4	acc5	Average
卷雲	0.38	0.63	0.63	0.50	0.63	0.554
卷積雲	0.88	0.63	0.88	0.75	0.25	0.678
卷層雲	0.38	0.63	0.63	0.63	0.75	0.604
高積雲	0.50	0.75	0.63	0.75	0.38	0.602
高層雲	0.63	0.75	0.75	0.75	0.63	0.702
雨層雲	0.88	0.75	0.88	0.88	0.88	0.854
層積雲	0.25	0.63	0.38	0.50	0.13	0.378
層雲	0.75	0.50	0.63	0.75	0.38	0.602
積雲	0.50	0.25	0.63	0.25	0.50	0.426
積雨雲	0.25	0.25	0.50	0.63	0.38	0.402
總和	5.40	5.77	6.54	6.39	4.91	5.802




圖 8 學習率 0.00099 時各類別的準確率比較圖

(三) 學習率 0.00099 的模型整體表現較 0.001 穩定，準確率在學習率 0.00101 時波動較大，而 0.00099 的結果顯示準確率較為均衡，模型對不同類別的適應性更好。雨層雲(0.854) 準確率最高，層積雲(0.378)的準確率較低。學習率較低雖然會導致訓練速度變慢，但整體穩定性較高。

(四) 表 5 比較(一)的各學習率對模型訓練準確率的影響。

(五) 由(一)和(二)之準確率的比較，可歸納出較高學習率(0.00101)會導致模型波動較大，某些類別準確率雖然提高，但其他類別的分類效果下降，模型可能過擬合或欠擬合。適中學習率(0.001)讓模型有較均衡的學習效果，但部分類別的準確率仍然偏低，仍有進步空間。較低學習率(0.00099)提供最佳的穩定性，讓模型能穩定收斂，但可能影響學習效率，需要較長的訓練時間才能獲得最優結果。

表 5 模型學習率準確率比較表

學習率	最低準確率類別	最高準確率類別	平均準確率變化
0.001	層積雲(0.378)	雨層雲(0.826)	中等穩定，部分類別較低
0.00101	積雨雲(0.378)	高層雲(0.804)	波動較大，部分雲種準確率下降
0.00099	層積雲(0.378)	雨層雲(0.854)	整體最穩定，平均準確率最佳

(六)混淆矩陣分析，數值越大表示模型的預測較為準確。




圖 9 學習率0.001時各類別的混淆矩陣

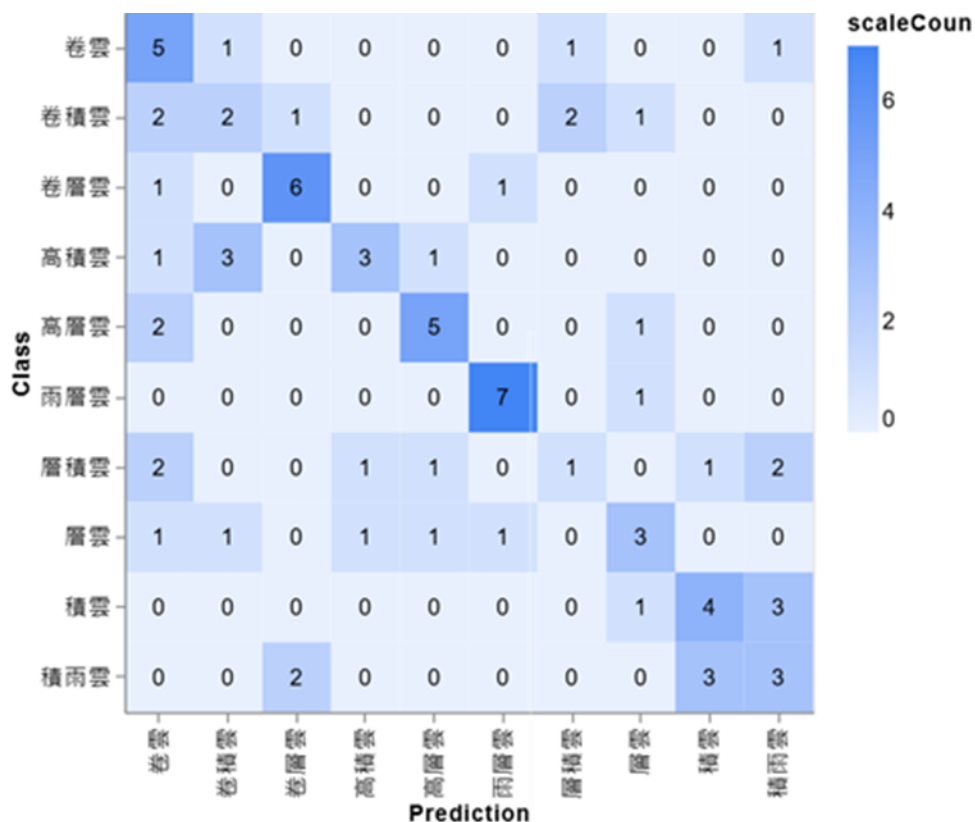


圖 10 學習率0.00101時各類別的混淆矩陣




圖 11 學習率 0.00099 時各類別的混淆矩陣

1. 由圖 9 到圖 11 分析不同學習率呈現的混淆矩陣，學習率在 0.00099 和 0.001 之間的表現較佳，能夠平衡模型的學習效果和分類準確率。學習率過高 (0.00101) 導致分類不穩定，學習率過低 (0.00099) 會降低整體準確率，但可減少錯誤分類的波動，適合本研究模型需要更穩定的學習。
2. 不同類別雲層分類難度不同，雨層雲、高層雲較容易分類，而層積雲、積雨雲較難區分。

二、調整模型週期為 50、55、45 統計各類別準確率、混淆矩陣、訓練週期準確率、訓練週期損失。

1、各模型準確率

表 6 訓練週期 50 時各類別的準確率

雲屬	acc1	acc2	acc3	acc4	acc5	Average
卷雲	0.38	0.75	0.75	0.13	0.50	0.502
卷積雲	0.63	0.75	0.75	0.75	0.63	0.702
卷層雲	0.63	0.63	0.50	0.63	0.75	0.628
高積雲	0.75	0.50	0.50	0.63	0.50	0.576
高層雲	0.63	0.75	0.63	0.88	0.63	0.704
雨層雲	0.88	0.75	0.88	0.63	0.88	0.804
層積雲	0.38	0.25	0.50	0.38	0.38	0.378
層雲	0.38	0.38	0.38	0.75	0.38	0.454
積雲	0.50	0.50	0.75	0.50	0.25	0.500
積雨雲	0.63	0.50	0.38	0.50	0.63	0.528
總和	5.79	5.76	6.02	5.78	5.53	5.776




圖 12 訓練週期 50 時各類別的準確率比較圖

表 7 訓練週期 55 時各類別的準確率

雲屬	acc1	acc2	acc3	acc4	acc5	Average
卷雲	0.63	0.25	0.63	0.50	0.63	0.528
卷積雲	0.63	0.88	0.88	0.75	0.10	0.648
卷層雲	0.75	0.63	0.50	0.63	0.88	0.678
高積雲	0.63	0.88	0.50	0.63	0.75	0.678
高層雲	0.63	0.50	0.63	1.00	0.38	0.628
雨層雲	0.88	1.00	0.88	0.88	0.50	0.828
層積雲	0.75	0.38	0.38	0.38	0.25	0.428
層雲	0.50	0.63	0.63	0.75	0.63	0.628
積雲	0.38	0.25	0.75	0.50	0.75	0.526
積雨雲	0.25	0.38	0.38	0.25	0.38	0.328
總和	6.03	5.78	6.16	6.27	5.25	5.898




圖 13 訓練週期 55 時各類別的準確率比較圖

表 8 訓練週期 45 時各類別的準確率

class	acc1	acc2	acc3	acc4	acc5	Average
卷雲	0.50	0.50	0.38	0.38	0.50	0.452
卷積雲	0.88	0.38	0.63	0.75	0.63	0.654
卷層雲	0.50	0.38	0.50	0.75	0.88	0.602
高積雲	0.63	0.75	0.38	0.75	0.75	0.652
高層雲	0.50	0.75	0.63	0.75	0.63	0.652
雨層雲	0.75	0.75	0.88	0.63	0.63	0.728
層積雲	0.88	0.25	0.63	0.50	0.13	0.478
層雲	0.50	0.63	0.50	0.88	0.50	0.602
積雲	0.38	0.38	0.75	0.50	0.38	0.478
積雨雲	0.50	0.25	0.25	0.25	0.38	0.326
總和	6.02	5.02	5.53	6.14	5.41	5.624




圖 14 訓練週期 45 時各類別的準確率比較圖

(一) 分析訓練週期對準確率的關係

1. 由表 6 到表 8 的準確率比較，45 增加到 50 週期，卷雲、卷積雲、卷層雲、高層雲，雨層雲、積雲、積雨雲共六種雲屬平均準確率有提升，代表模型仍在有效學習。
2. 50 增加到 55 週期，卷雲、卷層雲、高積雲，雨層雲、層積雲、層雲、積雲等

七種雲屬雖然平均準確率有提升，但部分雲類（如卷積雲和積雨雲）準確率下降，顯示這些類別開始受到過擬合影響。

3. 總準確率隨訓練週期增加而提升，顯示模型在學習過程中持續改善，但增長幅度在 50 週期後開始減緩。
4. 45 到 50 週期平均準確率提升最多增加 0.152， 50 到 55 週期增加 0.122，提升較少。
5. 部分雲類在 55 週期時平均準確率下降，似乎與過擬合或類別混淆有關。

(二)混淆矩陣




圖 15 週期 50 時各類別的混淆矩陣




圖 16 週期45時各類別的混淆矩陣




圖 17 週期55時各類別的混淆矩陣

1. 由圖 15 混淆矩陣分析，週期 50 的分類結果最為均衡，大部分雲種的分類誤差較少。

2. 由圖 16 混淆矩陣分析，週期 45 的分類錯誤較明顯，特別是在卷雲、積雲、層積雲等類別上錯誤率較高。
3. 由圖 17 混淆矩陣分析週期 55 總準確率最高，但部分雲種誤分類情況加重，例如：高層雲與高積雲的錯誤分類增加，可能是這兩類雲的影像特徵較相似，導致模型過擬合。




圖 18 各類別平均準確率在週期為 45、50、55 的比較圖

表 9 各雲屬的總準確率比較

雲屬	45 週期	50 週期 /0.001	55 週期	學習率 0.00099	學習率 0.00101	總和	排序
卷雲	0.452	0.502	0.528	0.554	0.426	2.462	7
卷積雲	0.654	0.702	0.648	0.678	0.778	3.46	3
卷層雲	0.602	0.628	0.678	0.604	0.602	3.114	5
高積雲	0.652	0.576	0.678	0.602	0.654	3.162	4
高層雲	0.652	0.704	0.628	0.702	0.826	3.512	2
雨層雲	0.728	0.804	0.828	0.854	0.648	3.862	1
層積雲	0.478	0.378	0.428	0.378	0.354	2.016	9
層雲	0.602	0.454	0.628	0.602	0.578	2.864	6
積雲	0.478	0.5	0.526	0.426	0.452	2.382	8
積雨雲	0.326	0.528	0.328	0.402	0.378	1.962	10

三、颱風個案雲屬分析

本實驗選取 2025 年 5 月 24 日冷鋒鋒面過境時，從 08:00 至 12:30 以 30 分鐘為間隔，於東經 120 度 56 分 54 秒 北緯 24 度 47 分 02 秒進行連續觀測與記錄颱風線降水系統，統整雷達回波圖、地面雲圖拍攝、拍攝地點之地面氣象站數據（氣溫、相對濕度、氣壓）與 AI 雲屬判讀結果。

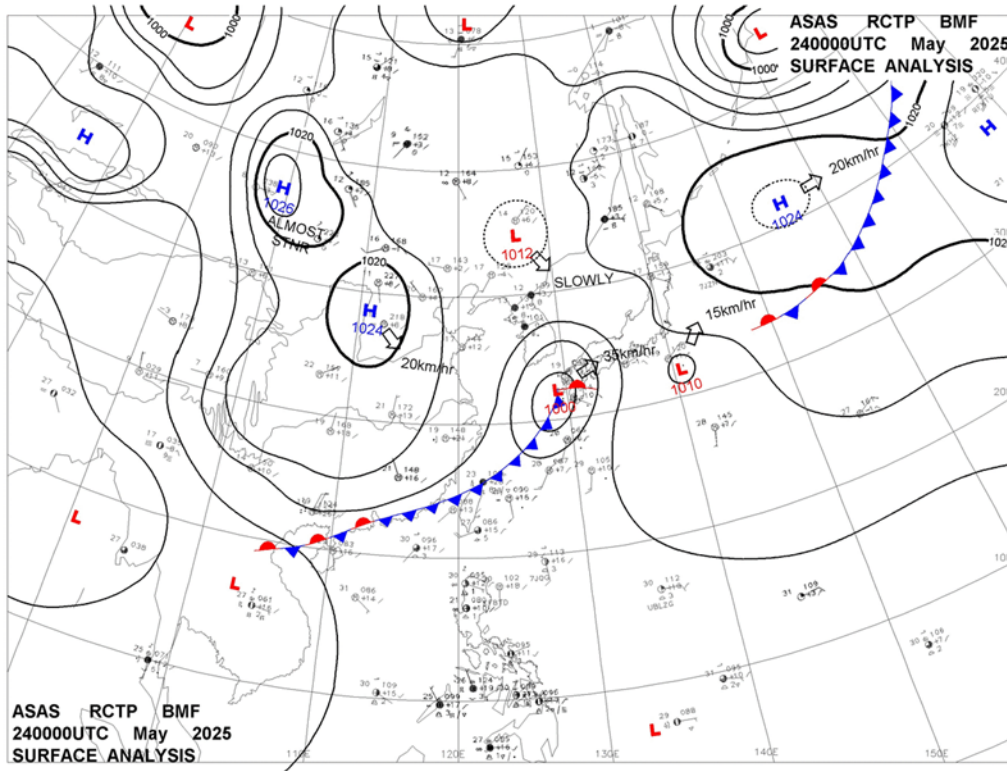
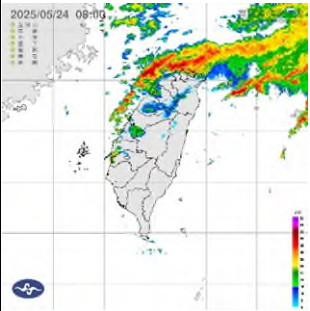

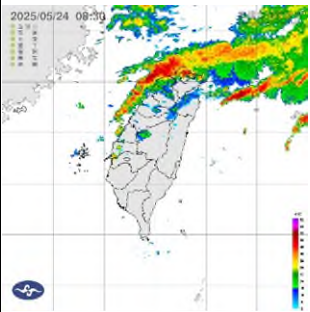

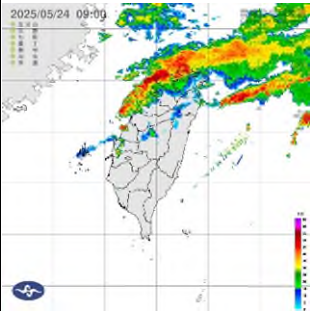

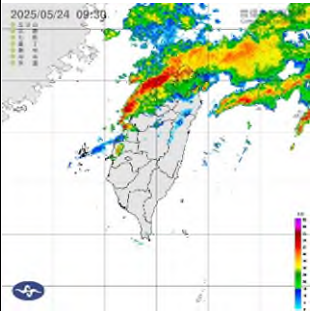

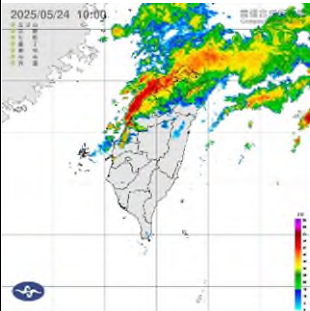

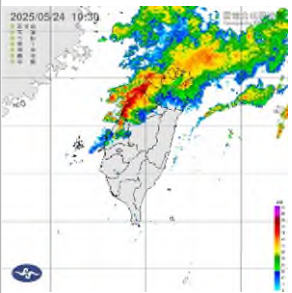
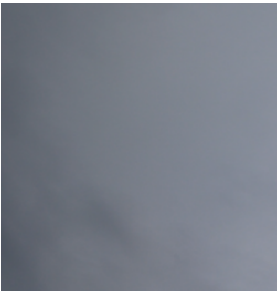
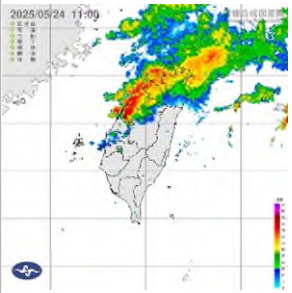

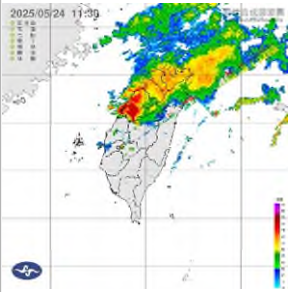

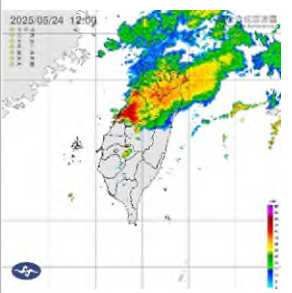

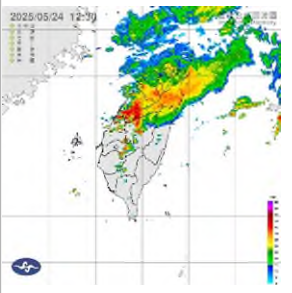



圖 19 中央氣象署發布 2025/5/24 地面天氣圖[15]

表 10 鋒面過境期間雲屬變化之時序地面觀測數據與 AI 判讀結果整理表[16]

時間	雷達回波圖	雲圖片	溫度 °C	相對溼度	氣壓 atm	AI 判讀結果
08:00			29.3	76.53	1006.40	層積雲: 61% 高層雲: 39%
08:30			29.26	76.24	1006.41	層雲: 80% 高層雲: 20%
09:00			29.25	76.69	1006.82	高層雲: 90% 高積雲: 10%
9:30			27.24	79.43	1008.22	高層雲: 77% 高積雲 23%
10:00			24.10	87.57	1008.75	高層雲: 100%

時間	雷達回波圖	雲圖片	溫度 °C	相對溼度	氣壓 atm	AI判讀結果
10:30			23.39	90.69	1009.47	雨層雲:100%
11:00			23.32	91.77	1009.43	雨層雲:100%
11:30			23.28	92.15	1009.35	雨層雲:100%
12:00			23.45	91.72	1009.28	雨層雲:100%
12:30			23.36	90.42	1009.29	雨層雲:100%

1、 飈線接近前:

由 08:00 到 09:30 之雷達回波圖可知，飈線處於接近台灣西北部和前緣通過階段。雲圖中雲底呈現厚實、混亂、雲底有陰影的層積雲特徵。氣壓略微下降，溫度仍處於高值（29.2–29.3°C），相對濕度略升。AI 判讀結果呈現出層積雲，顯示模型依據雲底特徵已能夠辨識對流性雲屬。

2、 飈線通過中

10:00 至 10:30 為主對流區通過階段，根據雷達回波顯示，觀測地點位於飈線所引發之強降水區內。雲圖顯示上空雲層密布，呈現深灰至黑色調，屬典型積雨雲近地層結構。此時段內地面氣象數據顯示氣溫驟降至約 24.1°C，相對濕度上升至 90% 以上，氣壓亦有明顯上升，顯示冷空氣隨飈線通過後入侵地面層。

在雲屬判讀方面，AI 於 10:00 時將雲屬辨識為「高層雲：100%」，而 10:30 時則判讀為「雨層雲：100%」。該結果顯示，在積雨雲水平發展區域內，若取樣圖像未能涵蓋雲頂或發現積雨雲垂直發展特徵，則雲屬判讀模型可能無法正確識別其為積雨雲底部。此外，積雨雲常伴隨多層次及多類型雲層分布，導致圖像中出現其他雲屬特徵進而引發模型誤判，此為目前 AI 模型在複雜對流系統中常見的挑戰。

3、 飈線遠離後

11:00 到 12:30 對流後區層狀雲發展，雷達顯示主對流區逐漸東移，西北部進入後部穩定降水區。雲圖呈現均勻灰色、水平分布。AI 判讀為「雨層雲：100%」，說明模型正確辨識了降水後區雲屬轉變。

伍、 討論

一、 模型學習率

在本實驗模型中，較高的學習率雖然能提升某些類別的準確率，但其波動較大，容易導致模型產生過擬合或欠擬合的問題。相較之下，較低的學習率雖然學習效率較低，需較長時間訓練才能收斂至最優結果，但能有效提升模型的穩定性。因此，對於雲屬判讀模型需要較低的學習率對整體準確率最佳。

二、 模型訓練週期

在模型訓練週期的比較中，週期 45 的泛化能力最佳，雖然測試準確率較低，但測試損失穩定，有助於降低過擬合的風險。週期 50 則能提升最高測試準確率，且過擬合程度仍在可接受範圍內，是較為平衡的選擇。相較之下，55 週期未能進一步提升測試準確率，且過擬合現象明顯，導致泛化能力最差。這與文獻中提到「增加訓練週期可提升預測結果」的結論有所不同。因此，在雲屬判讀模型中，較適合使用 50 週期作為模型訓練的超參數設定。

三、 不同雲屬的準確率差異

雲屬的平均準確率由高到低排序依序為：雨層雲、高層雲、卷積雲、高積雲、卷層雲、層雲、卷雲、積雲、層積雲、積雨雲。準確率最高的雨層雲和第二高的高層雲皆為水平擴散的層狀雲，兩雲數皆無雲類，較少外型變化。準確率最低的積雨雲因為分布範圍從地面附近到 2 公里高，可同時存在不同的構造(如:乳狀雲、弧狀雲、管狀雲等附屬雲)會因為附屬雲的差異導致準確率下降。層積雲準確率較其他雲屬低，推測其原因為層積雲型態多樣，層積雲的五個雲類皆和高積雲有所重疊，其形成的原因可由雨層雲、層雲、積雲、積雨雲轉化形成，因此層積雲出現時也時常伴隨其他雲屬，在僅使用圖像辨識的雲屬判讀模型存在準確率較低的問題。

表 11、雲屬準確率排序和雲分類數的比較表

class	準確率排序	雲類數量	變形數量	附屬雲數量	衍生雲數量	轉化雲數量
卷雲	7	5	4	2	4	2
卷積雲	3	4	2	3	2	4
卷層雲	5	2	2	0	2	4
高積雲	4	5	7	5	2	4
高層雲	2	0	5	4	2	2
雨層雲	1	0	0	3	2	3
層積雲	9	5	7	6	4	3
層雲	6	3	3	2	6	1
積雲	8	4	1	8	5	2
積雨雲	10	2	0	12	7	1

四、本研究為避免主觀判讀的誤差，測試集選取 WMO 國際雲圖鑑的清晰雲圖片，涵蓋十種雲屬，每種各 50 張。儘管測試集規模較小，但由於本研究採用 Teachable Machine 輕量化的 TensorFlow.js 模型，此數量仍足以進行有效的模型評估，並降低測試集對模型準確率影響的潛在疑慮。

五、本研究結果顯示，雲屬判讀 AI 模型在鋒面過境與颱風線型降水帶發展過程中，能辨識出與中尺度對流系統相關的雲層類型，如雨層雲與高層雲，具備辨識雲屬時空演變特徵的潛力。然而，由於颱風系統本身具有快速演變、積雨雲垂直發展之特性，AI 模型在單一時點與局部視角的輸入條件下，常因視角限制或雲底結構相似性，誤判積雨雲為其他層狀雲種，特別是在雲底灰暗、對比度不明顯的情況下較為明顯。

儘管如此，雲屬判讀 AI 仍具有實質應用價值。可有效提升人工觀測資料的取得效率，縮短資料整理與判讀時間。無人自動氣象站也能與雲觀測設備結合，進行自動化雲屬分類，有助於提升對中尺度對流系統發展階段的掌握與預測的速度。

六、2019 年 M. Jingyi 等人發表使用 Multi-CNN 來進行卷積神經網路多層次的特徵辨識，擷取特定雲屬特徵來進行雲的判讀再進行特徵間的融合來進行雲屬判讀 [12]，在當時這個前衛的想法與亮點也受到 IEEE 期刊的肯定，可見模型訓練擁有可能進行雲屬判讀的可能性。然而 2019 到 2025 年間的圖像辨識技術出現如 Teachable Machine 可透過少量數據便能進行圖像分析的輕量化模型，能夠突破需要多層次和多尺度的卷積特徵提取以及局部特徵的編碼和融合，輕量化的 Teachable Machine 發展讓圖像辨識的模型不再是如此高貴的研究設備，實現更多

生活化與教學實作[7]的可能，也許在今日我們未能見到雲屬圖像辨識在實際生活中的應用，但試著想像一下未來能夠用這項技術進行即時的雲屬判讀，不受地點和人物的影響，現行技術的衛星雲圖雖然能觀測雲的動向，但是局部範圍的精細程度依然有限，倘若能夠結合地面觀測的雲屬判讀，方能增加預報的精確度。

未來要能做到即時雲辨識的前提是對於雲屬資料的收集與雲屬判讀的基礎，必須建立完善的雲屬測試數據集，提升雲屬辨識的準確率。隨著人工智慧與氣象預測的結合更加緊密，雲屬判讀模型必然是一塊重要的基石。

陸、 結論

- 一、雲屬判讀模型需要較低學習率提升準確率但過低的學習率可能造成訓練時間增加。
- 二、最佳訓練週期為 50，大部分雲屬的分類誤差較少，且未進入過擬合階段。增加週期數對雲屬判讀模型而言不一定有助於準確率提升。
- 三、擁有較多雲類、附屬雲、衍生雲的雲屬準確率較低，容易和其他雲屬混淆，需要更多的資料進行模型訓練。
- 四、本研究證實雲屬判讀 AI 模型具備辨識鋒面與飆線相關雲型變化的潛力，若結合雷達回波與時序影像資料，有助於提升中尺度對流系統觀測與預報之效率與準確性。
- 五、雲屬判讀模型未來具備發展預報之潛能，需要更大量的雲屬測試數據集進行模型訓練並與氣象預報、圖像生成技術融合。

柒、 參考文獻資料

- [1] 中央氣象署產品說明文件 地面氣象觀測資料. (2023, October 15). 中央氣象署.
https://www.cwa.gov.tw/Data/data_catalog/2-1-1.pdf
- [2] Heinle, a., Macke, a., and Srivastav, a. (2010). Automatic Cloud Classification of Whole Sky Images, *Atmos. Meas. Tech.*, 3, (<https://doi.org/10.5194/amt-3-557->), 565.
- [3] Heinle, a., Macke, a., and Srivastav, a. (2010). Automatic Cloud Classification of Whole Sky Images, *Atmos. Meas. Tech.*, 3, (<https://doi.org/10.5194/amt-3-557->), 566 – 567.
- [4] 荒木健太郎. (2020). 愛上雲的技術-了解雲和天空的 25 個秘密，成為賞雲高手 (978-986-97921-6-5)pp.61-64
- [5] Yuan, Y., & Hu, X. (2015). Bag-of-Words and Object-Based Classification for Cloud Extraction From Satellite Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8, 4197-4205.
- [6] Irish, richard r.; barker, john l.; goward, samuel n.; arvidson, terry. (2006). Characterization of the Landsat-7 ETM+ Automated Cloud-Cover Assessment (ACCA) Algorithm. *Photogrammetric Engineering & Remote Sensing*, Number 10 / October(pp. 1179-1188(10)).
- [7] Carney, M., Webster, B., Alvarado, I., Phillips, K., Howell, N., Griffith, J., ... & Chen, A. (2020, April). Teachable machine: Approachable Web-based tool for exploring machine learning classification. In *Extended abstracts of the 2020 CHI conference on human factors in computing systems* (pp. 1-8).
- [8] Carney, M., Webster, B., Alvarado, I., Phillips, K., Howell, N., Griffith, J., ... & Chen, A. (2020, April). Teachable machine: Approachable Web-based tool for exploring machine learning classification. In *Extended abstracts of the 2020 CHI conference on human factors in computing systems* (pp. 1-8).
- [9] 荒木健太郎. (2020). 愛上雲的技術-了解雲和天空的 25 個秘密，成為賞雲高手 (978-986-97921-6-5)
- [10] Sunil gupta , kamal saluja , ankur goyal , amit vajpayee, vipin tiwari. (2022). Comparing the Performance of Machine Learning Algorithms Using Estimated Accuracy. *ScienceDirect*, 24(100432), pp.3 – 4.
- [11] Liu, L., Sun, X., Chen, F., Zhao, S., & Gao, T. (2011). Cloud Classification Based on Structure Features of Infrared Images. *Journal of Atmospheric and Oceanic Technology*, 28(3), 410-417.
<https://doi.org/10.1175/2010JTECHA1385.1>
- [12] M. Jingyi, T. Zhang, J. Guodong, Y. Wenjun and Y. Bin, "Notice of Violation of IEEE Publication Principles: Ground-Based Cloud Image Recognition System Based on Multi-CNN and

- Feature Screening and Fusion," in IEEE Access, vol. 8, pp. 173949-173960, 2020, doi: 10.1109/ACCESS.2020.3026364.
- [13] Robert R. hoffman, daphne S. ladue, H. michael mogil, paul J. roebber, J. gregory trafton. (2023). Minding the Weather: How Expert Forecasters Think (026254881X, 9780262548816th ed.). MIT Press.pp142.
- [14] Henson, Robert, Ahrens, c. Donald. (2008). Meteorology Today: An Introduction to Weather, Climate, and the Environment (0534397719, 9780534397715th ed.). Thomson/Brooks/Cole, 2003.p308
- [15] 中國文化大學大氣科學系天氣圖庫 (CCU/ATM/SSL Weather Charts Catalog)<https://asrad.pccu.edu.tw/catalog/> 2025/5/24 CWA 地面天氣圖
- [16] 中國文化大學大氣科學系天氣圖庫 (CCU/ATM/SSL Weather Charts Catalog)<https://asrad.pccu.edu.tw/catalog/> 2025/5/24 8:00-12:30 雷達回波圖

【評語】 051906

雲屬自動判讀仍然是一項技術挑戰。作者參考 WMO 國際雲圖鑑，進行雲屬影像的收集與分類，並利用 Teachable Machine 圖像辨識模型進行訓練，建立具備十種雲屬辨識能力的模型並探討學習率與訓練週期對模型判讀準確度的影響。實驗結果顯示，不同雲屬的分類準確度受雲屬特徵影響，層積雲與積雨雲因特徵變化較大，易產生混淆。經超參數調整發現，較低學習率有助於提升整體準確率，而訓練週期的增加或減少對準確率的影響則較不顯著。研究結果證實機器學習技術在雲屬觀測上的可行性，未來可透過擴展資料集與優化模型，提高對不同天氣條件下雲屬變化的適應能力。建議結合日本向日葵衛星（Himawari 8 和 Himawari 9 衛）16 個波段影像。這 16 個波段提供的資訊包含高品質的衛星雲圖（雲的光學厚度、種類、溫度和高度等物理參數）。也可以比較可見光與紅外線雲圖以確認雲的型態與特性。

作品海報

雲屬判讀 Teachable Machine AI模型

摘要

無人氣象站的應用提升了大氣觀測的數據收集效率，然而雲屬自動判讀仍是一項技術挑戰。本研究參考WMO國際雲圖鑑，進行雲屬影像的收集與分類，並利用 Teachable Machine 圖像辨識模型進行訓練，**創建具備十種雲屬辨識能力的AI模型**，並探討學習率與訓練週期對模型判讀準確度的影響。模型訓練結果顯示，不同雲屬的分類準確度受雲屬特徵差異影響[1]，經參數調整發現，較**低學習率**有助於**提升整體準確率**。將自行拍攝雲圖與地面觀測數據進行比對，結果顯示，雲屬判讀AI模型可補足地區性觀測的局限，具備作為**氣象觀測自動化輔助工具**的應用潛力。

研究目的

- 1. 訓練能夠分別十雲屬的模型。
- 2. 探討學習率和訓練週期對雲屬判讀模型的影響與判讀雲屬混淆的細節和可能原因。
- 3. 實測雲屬判讀AI觀測冷鋒鋒面飈線型降水帶的應用成效。
- 4. 探討雲屬判讀AI在天氣系統觀測的優勢與限制。

研究器材及流程

一、研究器材

- 1. 個人電腦 裝置名稱：LAPTOP-VKSNTR02，版本Windows 10
- 2. Teachable Machine
- 3. Canon EOS800D攝影機
- 4. 腳架:固定拍攝仰角為60度
- 5. 地面觀測站:百葉箱內安裝自動氣象資料收集儀器可收集溫度、氣壓、相對濕度等地面觀測數據。



圖1百葉箱


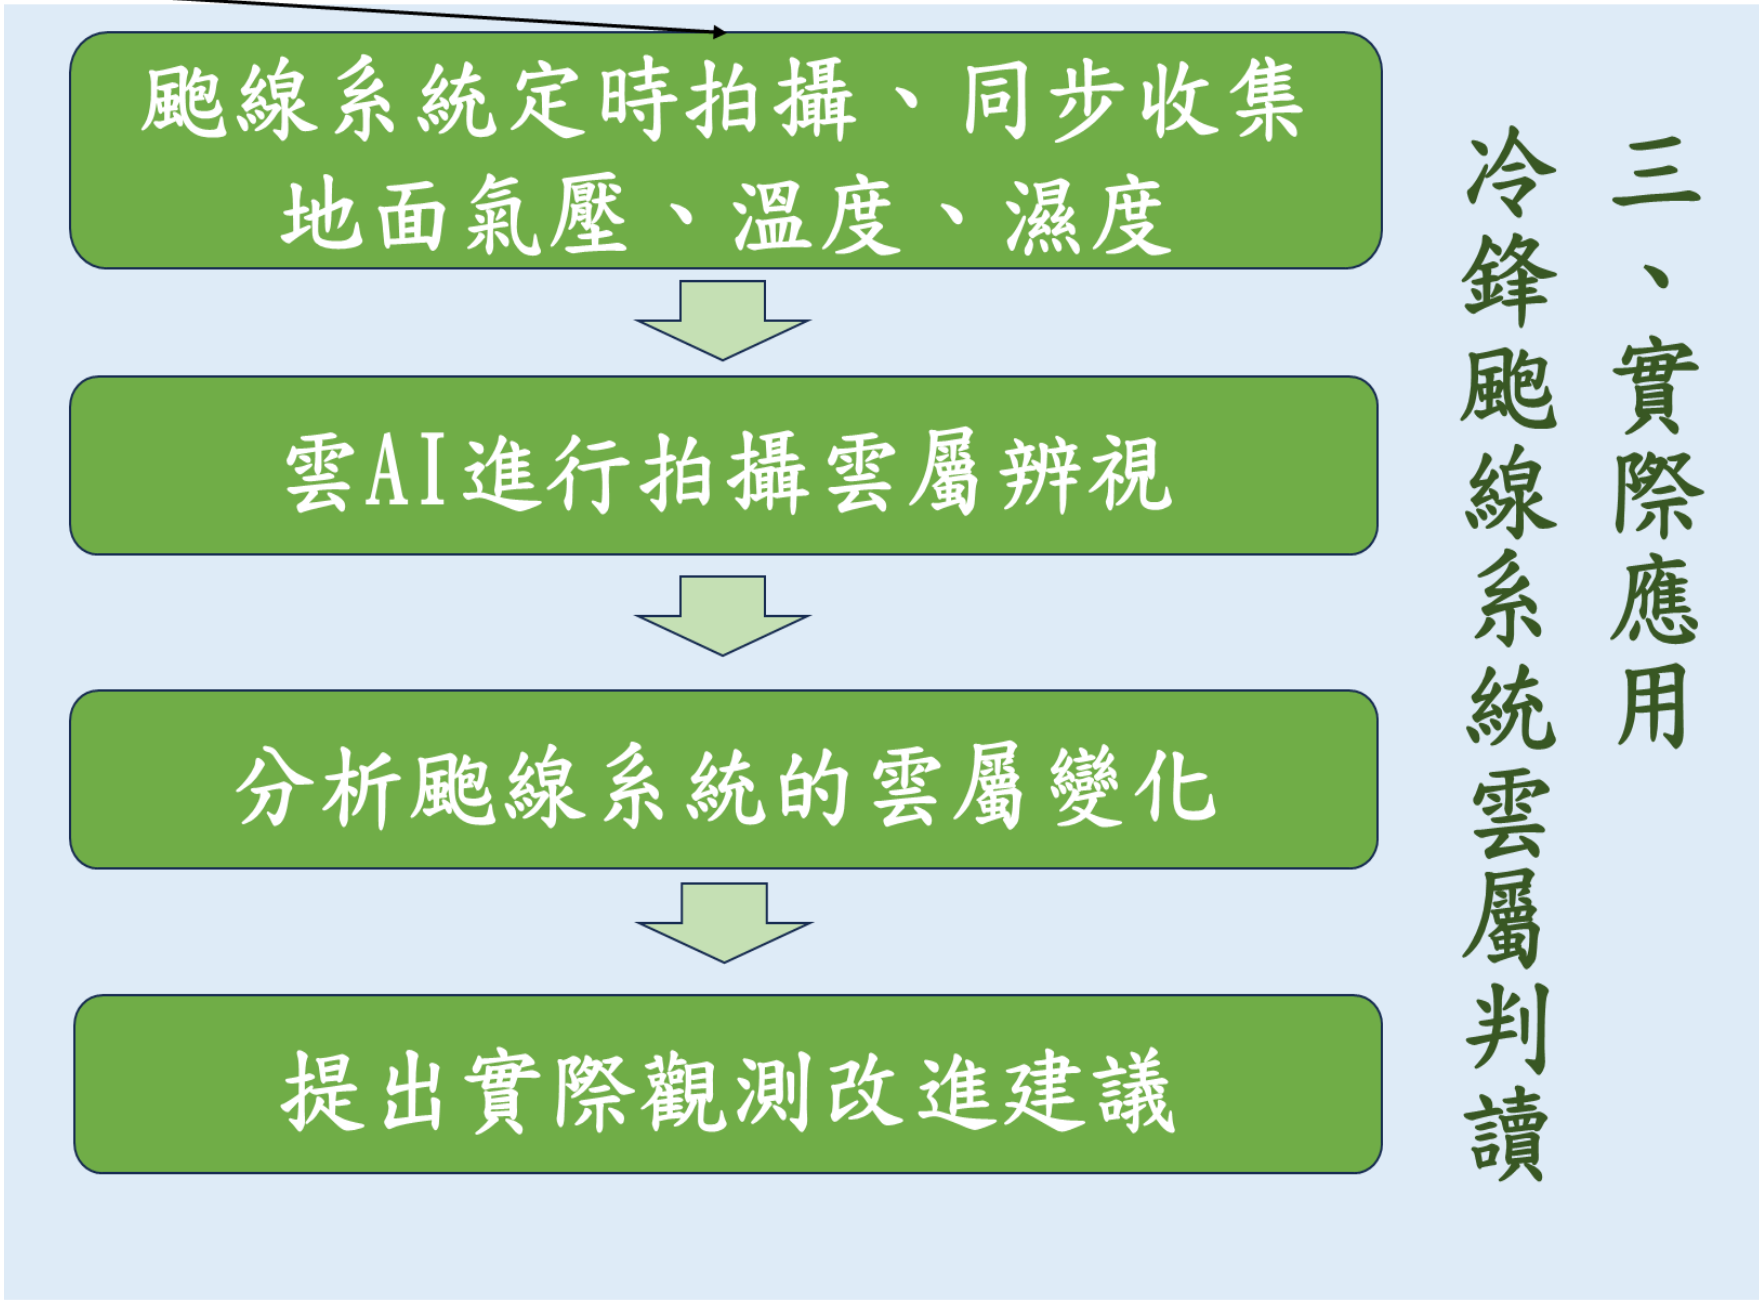
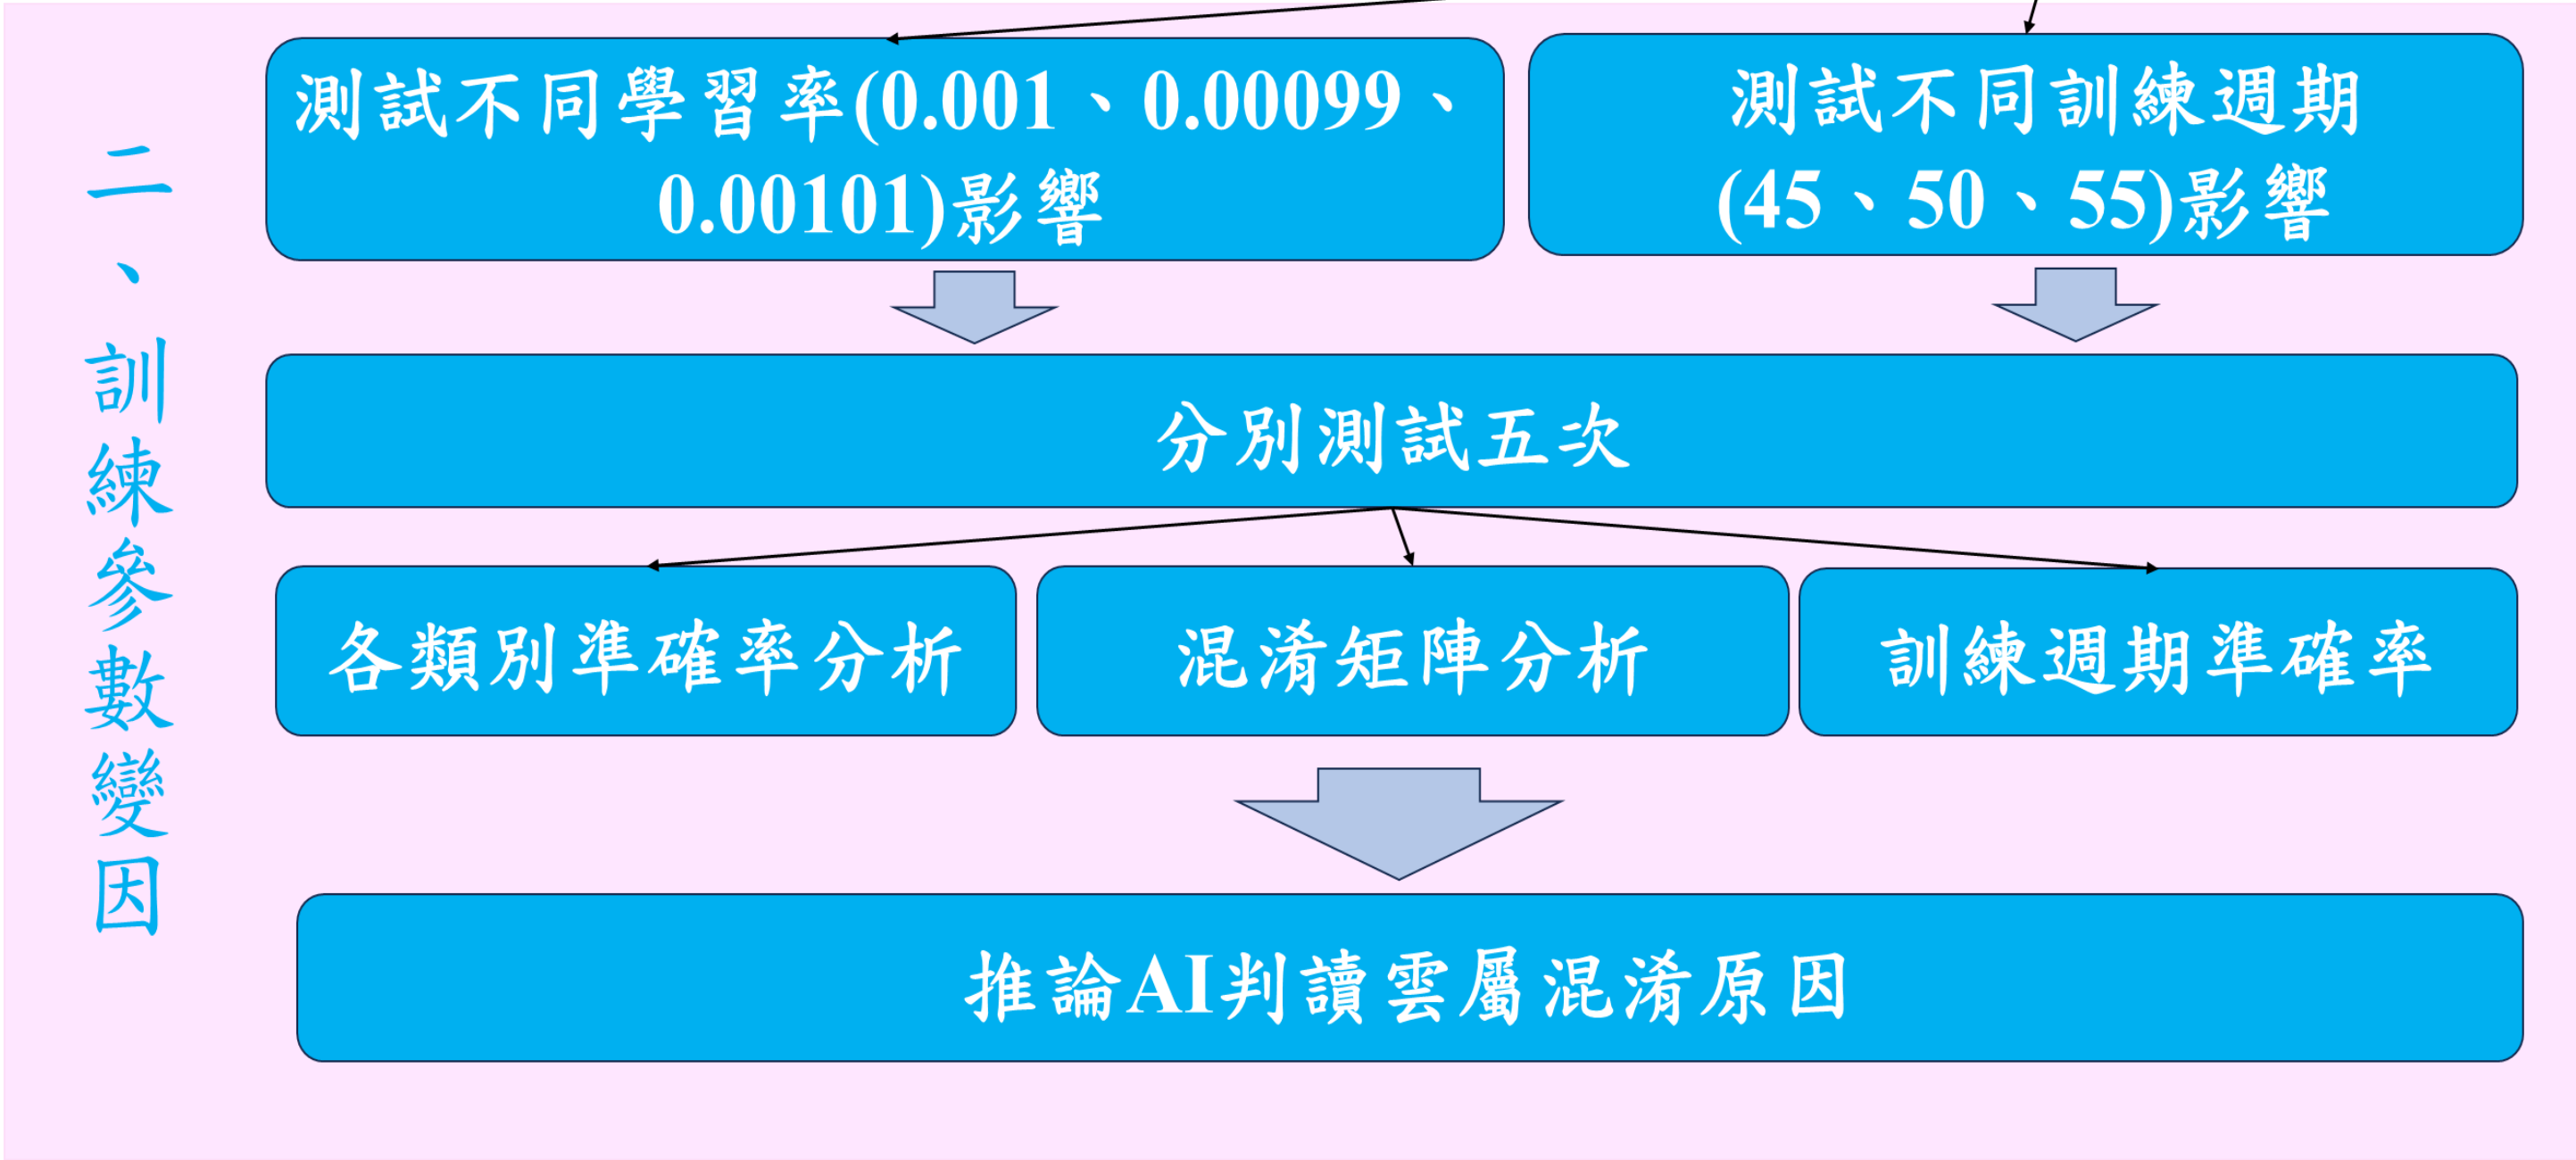
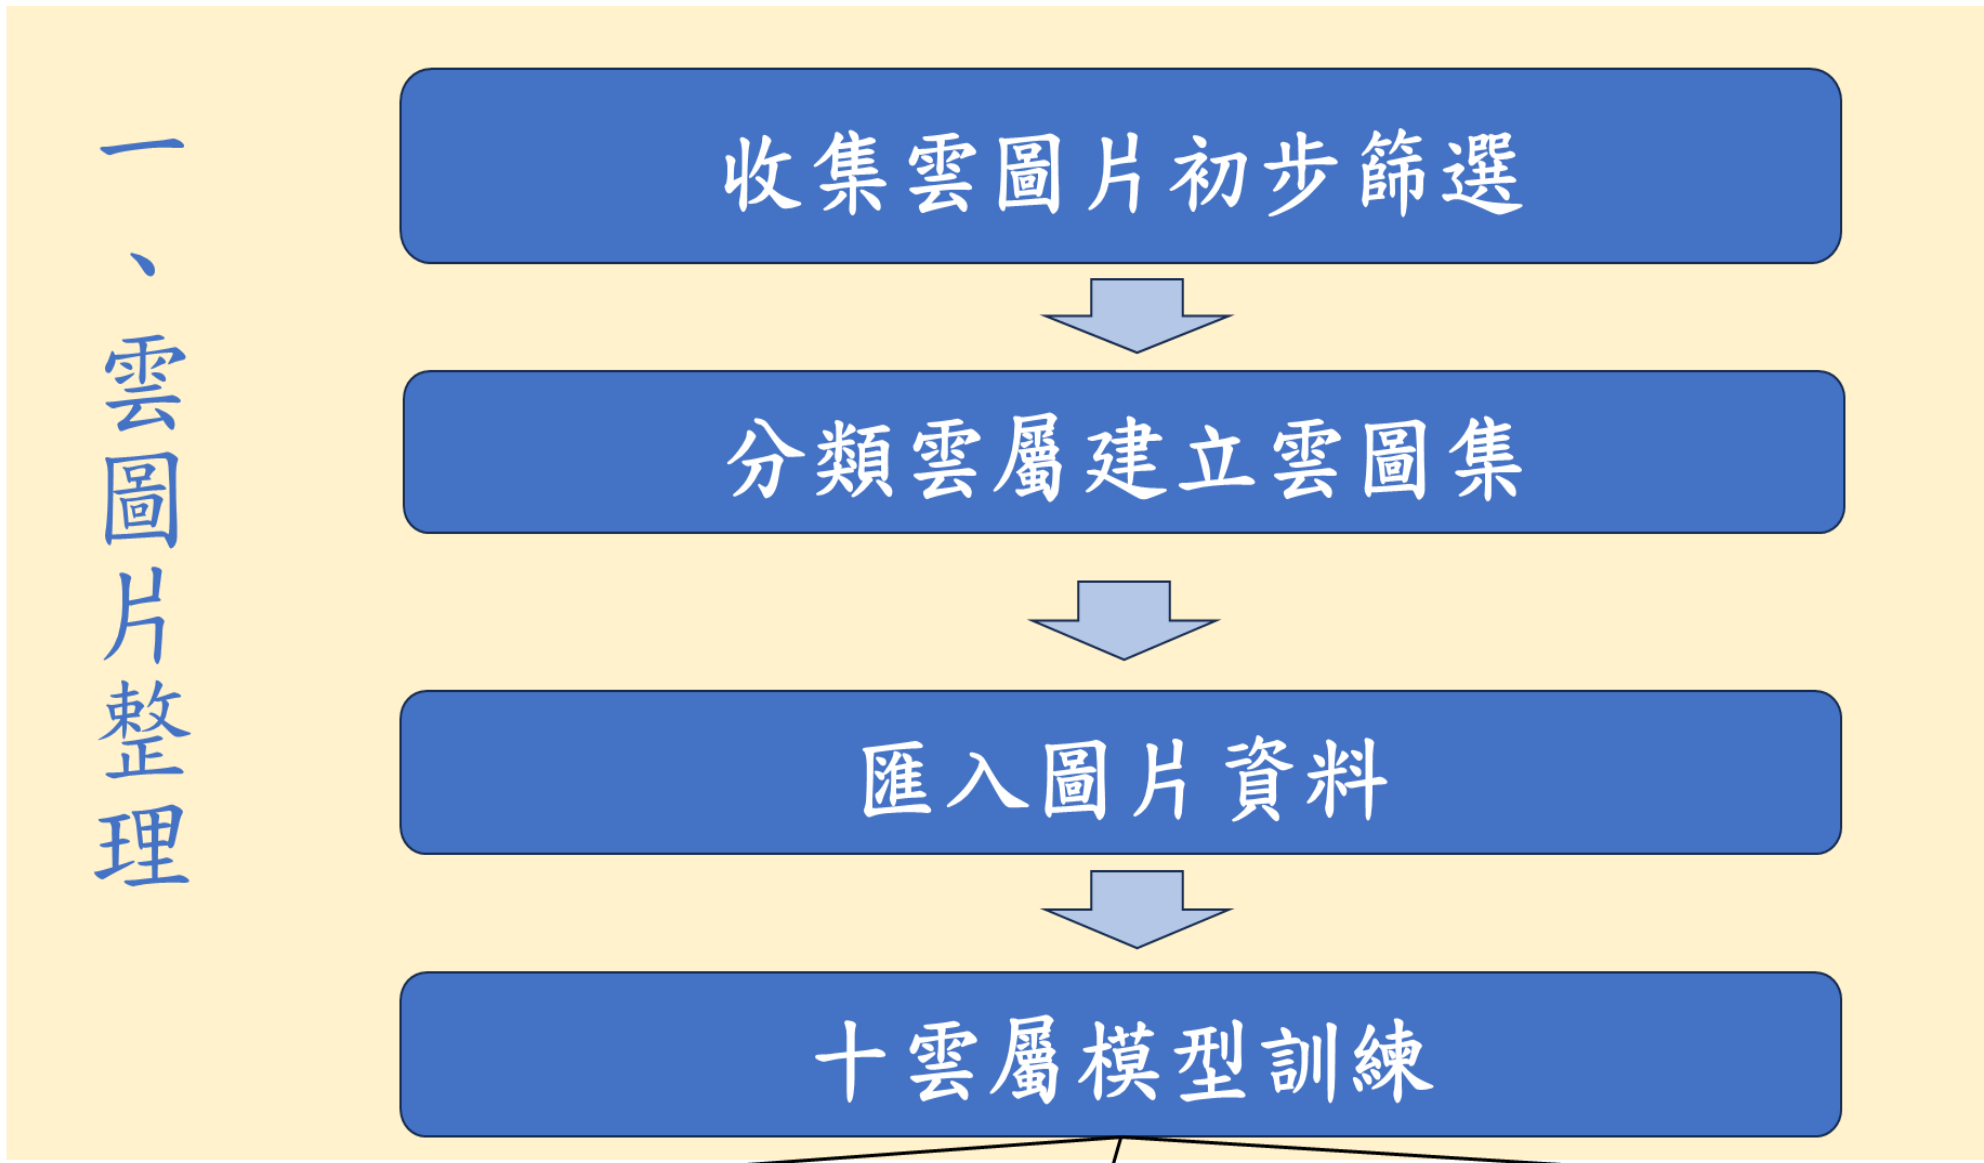


圖2儀器內部電路板與電池



圖3百葉箱內氣象儀器
(圖1-3圖片來源:自行拍攝)

二、研究流程圖



研究方法

一、雲圖片整理

- (一)開放資料:WMO國際雲圖鑑十雲屬
- (二)日本雲研究所的已標註雲圖片
- (三)每種雲屬使用 550 張圖片
訓練資料集500張、測試集50張

二、訓練參數變因

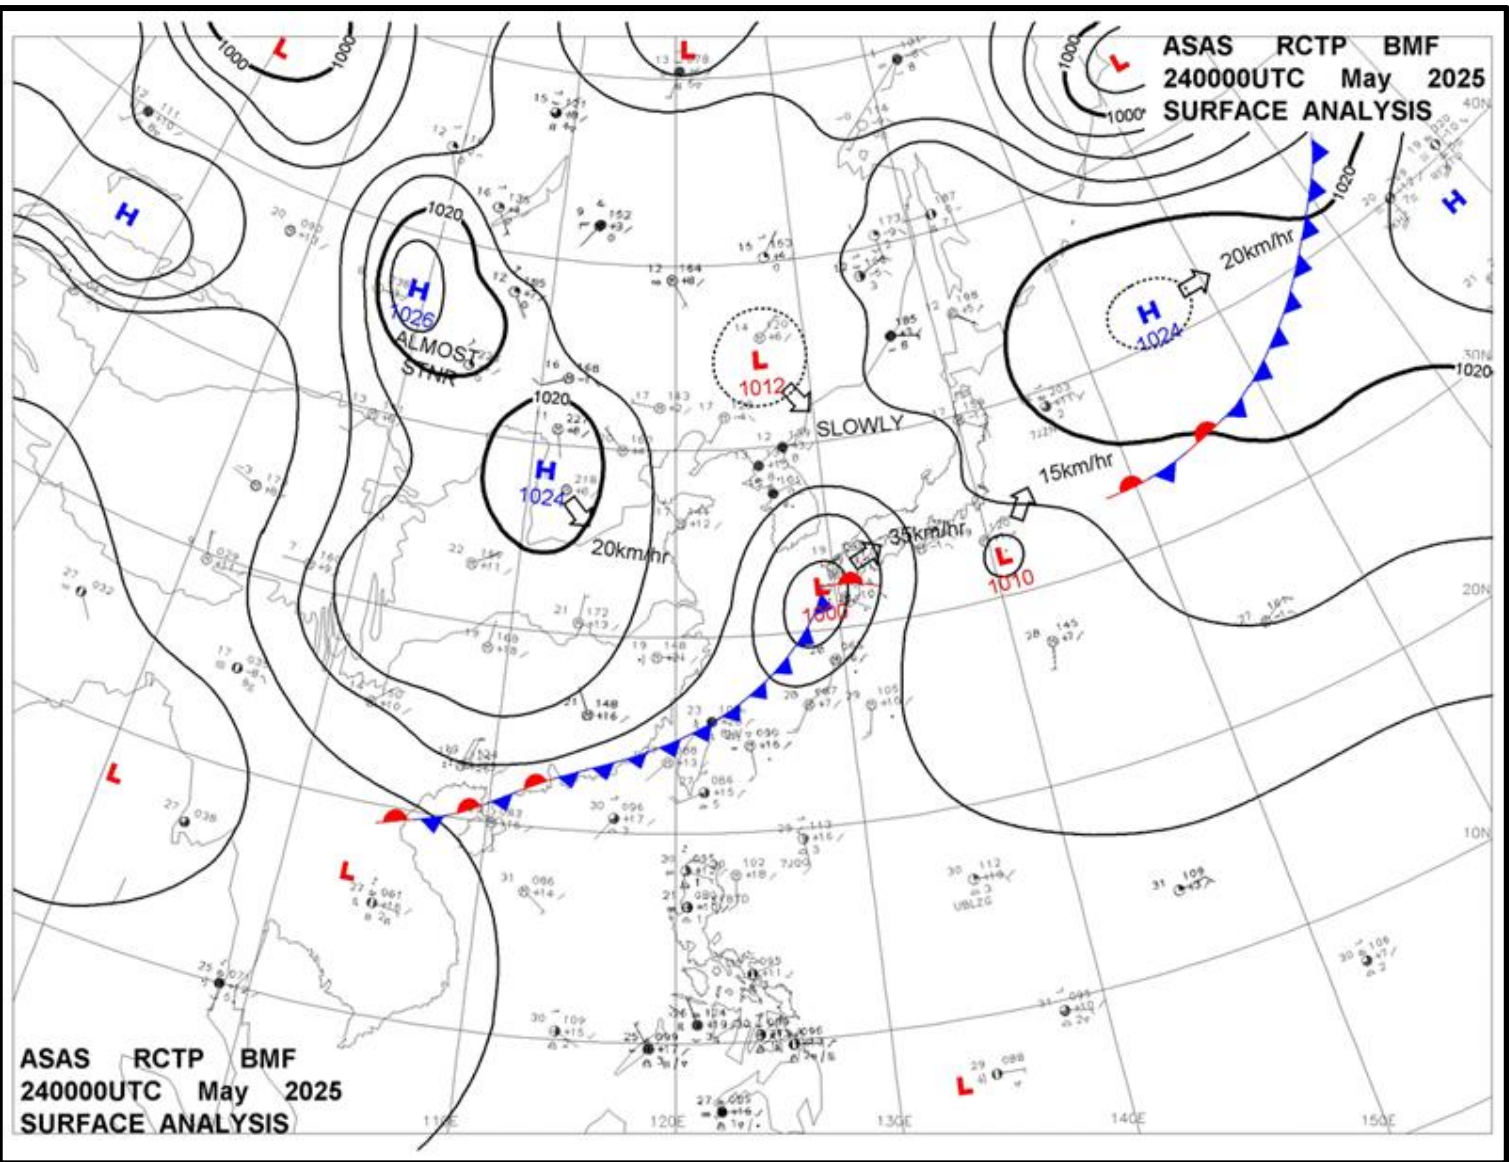
- (一)測試學習率
- (二)測試訓練週期



圖4十雲屬示意圖(圖片來源:WMO國際雲圖鑑)

三、實際應用:冷鋒颶線系統定時拍攝與AI雲屬判讀

1. 2025年5月24日冷鋒鋒面**颶線**系統過境08:00至12:30以**30分鐘**間隔
2. 統整**雷達回波圖**、地面連續**拍攝雲圖**、拍攝地點的**氣溫**、**相對濕度**、**氣壓**與**AI雲屬判讀**結果。



四、分析方法

(一) 各類別準確率

某類別準確率= $\frac{\text{正確分類該類別的數量}}{\text{被模型分類為該類別的數量}}$

(二)混淆矩陣:

橫軸為預測雲屬，縱軸為輸入測試的雲屬，兩軸對應到相同雲屬**顏色越深、數字越大**，表示**準確率越高**。

(三)應用AI進行分析颶線過境的雲屬變化，進行個案分析，並提出使用AI觀測的建議。

表1實驗模型參數設定

參數名稱	預設值	影響
輸入影像大小	224×224px	統一圖片尺寸
批量	16	每次輸入的圖片數量
訓練週期 Epochs	45、50、55	訓練模型必須處理訓練資料的次數
學習率	0.001 0.00101 0.00099	控制模型學習的幅度設為小的正數以確保模型穩定地學習

研究結果

一、測試模型準確率

(一)平均準確率比較圖

雨層雲準確率表現最佳
層積雲表現最差




圖6改變學習率各類別平均準確率(訓練週期50)




圖10改變訓練週期各類別平均準確率

(二)混淆矩陣

低學習率表現最穩定

訓練週期50為最佳，45、55分類錯誤增加




圖7學習率0.001




圖8學習率0.00099




圖9學習率0.00101




圖11訓練週期50




圖12訓練週期45




圖13訓練週期55

表2模型學習率準確率比較表

學習率	最低準確率類別	最高準確率類別	平均準確率變化
0.001	層積雲(0.378)	雨層雲(0.826)	中等穩定
0.00101	積雨雲(0.378)	高層雲(0.804)	波動較大，部分雲種準確率下降
0.00099	層積雲(0.378)	雨層雲(0.854)	整體最穩定，平均準確率最佳

二、冷鋒颶線系統定時拍攝與AI雲屬判讀

表3地面觀測數據、雲圖片、雷達回波圖、AI判讀結果比較表

時間	溫度 °C	相對溼度%	氣壓 hPa	雷達回波圖	雲圖片	AI判讀結果
08:30	29.26	76.24	1006.41		(a)	層雲: 80% 高層雲:20%
09:00	29.25	76.69	1006.82		(b)	高層雲:90% 高積雲:10%
09:30	27.24	79.43	1008.22		(c)	高層雲:77% 高積雲:23%
10:00	24.10	87.57	1008.75		(d)	高層雲:100%
10:30	23.39	90.69	1009.47		(e)	雨層雲:100%

(圖片來源:中央氣象署) (圖片來源:自行拍攝)

討論

一、模型訓練與準確率分析

(一)學習率對模型的影響

高學習率：部分類別準確率提高，但波動大，不適合雲屬判讀AI訓練。

低學習率：學習幅度小，可學習雲屬複雜的細節，提高整體模型穩定性。

(二)模型訓練週期 50 週期測試準確率最高，45、55 週期皆產生分類錯誤，準確率低 訓練週期大小與雲屬判讀模型訓練準確率較無關聯性

二、不同雲屬的準確率差異

(一)準確率較高的雲屬-雨層雲、高層雲：層狀雲，形態變化少，模型判讀較準確。

(二)準確率較低的雲屬-積雨雲：高度範圍廣，附屬雲變化多，影響準確率。[2]
-層積雲：型態多樣，與高積雲重疊，容易與其他雲屬混淆。

三、雲屬判讀AI應用-自行拍攝實測結果

案例一:單一雲屬高積雲



案例二:複合雲屬積雲、卷積雲



案例一判讀結果為高積雲100%
與拍攝結果相符
案例二的判讀結果積雲99%
沒有辨識出卷積雲，
因為卷積雲在圖中顏色較淡
模型存在忽略卷積雲的情況
(圖片來源:自行拍攝)

雲屬判讀AI已具備辨識單一雲屬的能力，持續增加樣本數可提高模型準確率，未來可以加入複合雲屬圖片進行訓練，增加模型對雲屬變化的適應。

四、雲屬判讀AI應用-冷鋒颶線判讀搭配地面觀測數據比對成果

由表3地面觀測數據、雲圖片、雷達回波圖、AI判讀結果比較表中可發現:

- 在08:30 至 09:30 之雷達回波圖中，**颶線處於接近台灣西北部和前緣通過階段**，而雲圖片中雲底呈現混亂、雲底有陰影的**層積雲**，氣壓略微下降，溫度仍處於高值（29.2–29.3℃），相對濕度略升。
- 10:00 至 10:30 **為主對流區通過階段**，根據雷達回波顯示，觀測地點位於颶線所引發之強降水區內。雲圖顯示上空雲層密布，呈現深灰色，屬典型**積雨雲近地層結構**。氣溫驟降至約 24.1℃，相對濕度上升至 90% 以上，氣壓亦有明顯上升，顯示冷空氣隨颶線通過後入侵地面層。
- 雲屬判讀AI 模型在08:30判讀結果為層雲: 80% 高層雲:20% ，與觀測結果相符，但在10:30判讀為雨層雲:100%，未判讀到積雨雲的部分。

五、雲屬混淆原因分析



在此討論表3中雲屬判讀AI之混淆情形:局部視角的拍攝角度下，因視角限制或雲底結構相似性，誤判積雨雲為其他層狀雲種。 現場雲圖搭配判讀AI 模型**能補充特定地點之即時天氣狀況**，**辨識鋒面颶線型降水帶發展過程中的雲層類型**，如雨層雲與高層雲，具備辨識雲屬時空演變特徵的潛力。

結論與未來展望

- 雲屬判讀模型需要**較低學習率**提升準確率，**最佳訓練週期為50**，增減訓練週期無益於雲屬判讀
- 擁有**較多雲類、附屬雲的雲屬準確率較低**，容易和其他雲屬混淆，需要更多的資料進行模型訓練。
- 雲屬判讀 AI 模型具備辨識天氣系統雲型變化的潛力，提供特定地點**即時觀測資料**，**補足區域性現場觀測資料**，有助於提升觀測與預報之效率。
- 本研究未來能**應用在觀測教學與自動氣象測站**進行無人雲屬觀測，降低民眾觀測門檻。

參考資料

[1]M. Jingyi, T. Zhang, J. Guodong, Y. Wenjun and Y. Bin, "Notice of Violation of IEEE Publication Principles: Ground-Based Cloud Image Recognition System Based on Multi-CNN and Feature Screening and Fusion," in IEEE Access, vol. 8, pp. 173949-173960, 2020, doi: 10.1109/ACCESS.2020.3026364.
[2]荒木健太郎. (2020). 愛上雲的技術-了解雲和天空的25個秘密成為賞雲高手 (978th-986th-97921st-6th-5th ed.).
[3]中國文化大學大氣科學系天氣圖庫 (CCU/ATM/SSL Weather Charts Catalog)<https://asrad.pccu.edu.tw/catalog/> 2025/5/24 CWA地面天氣圖 (詳細請見作品說明書)