

中華民國第 65 屆中小學科學展覽會

作品說明書

國中組 生活與應用科學科(一)

032822

危機蟲蟲—基於 Inception v3 的害蟲影像辨識
與數據優化研究

學校名稱：宜蘭縣立國華國民中學

作者： 國二 張旭 國二 黃釋駐 國二 簡頌叡	指導老師： 覺一容 李佳勳
--	-----------------------------

關鍵詞：害蟲辨識、InceptionV3 卷積神經網路、數據集優化

危機蟲蟲—基於 Inception v3 的害蟲影像辨識與數據優化研究

摘要

本研究針對農業害蟲辨識數據集的優化進行探討，旨在提高深度學習模型的辨識準確度。隨著科技進步，人工智慧在害蟲識別中愈發重要，但現有數據集面臨數據品質不良、樣本偏差和錯誤標註等問題，影響模型的可靠性。研究主要分為三個部分：首先分析現有數據集，探討樣本數對分類準確度的影響；其次優化數據集，通過刪除拼接和錯誤圖片、重複圖片等，提升數據質量；最後實際應用模型，開發一套害蟲辨識系統。實驗結果顯示，增加樣本數和改善數據質量顯著提升了模型的準確率，並且開發的介面可協助用戶即時識別害蟲。整體而言，本研究不僅提高了農作物的病蟲害防治效率，還為未來的害蟲識別技術提供了有價值的參考。

壹、研究動機

在農業與環境保護領域，準確識別害蟲對於病蟲害防治至關重要。隨著科技的發展，人工智慧與深度學習技術已被廣泛應用於害蟲辨識，期望能提高農作物的保護效率，減少農藥的使用，並降低對環境的影響。然而，現有的害蟲數據集仍有許多問題，如數據品質不良、樣本偏差、圖片標註錯誤，以及資料重複等問題，導致在實際應用中可能出現誤判或辨識失敗的情況，影響其可靠性與實用性，進而影響模型的訓練效果與最終準確度。

因此，本研究希望透過分析與優化害蟲數據集，找出影響辨識準確度的關鍵因素，並藉由針對數據集的整理與改進，提升深度學習模型的辨識能力。我們不僅關注數據本身的品質，還希望探討樣本數量、圖片分類標準及圖片處理方式對於模型準確度的影響。此外，除了優化數據集之外，本研究亦將進一步開發害蟲辨識系統，期望能設計出一個實用的人工智慧輔助工具，使農民、研究人員及環保單位能夠更快速、準確地識別害蟲，從而做出適當的防治決策。

貳、研究目的

研究一 -分析現有的數據集

實驗 1 數據集分類與資料分析

實驗 2 探討樣本數對害蟲物種分類準確度的影響

研究二 -優化害蟲數據集

實驗 3 刪除拼接圖片對模型準確度的影響

實驗 4 刪除錯誤圖片對模型準確度的影響

實驗 5 刪除無目標圖片對模型準確度的影響

實驗 6 幼蟲與成蟲分類對模型準確度的影響刪除重複圖片對模型準確度的影響

實驗 7 刪除重複圖片對模型準確度的影響

實驗 8 數據集擴增對模型準確度的影響

研究三 -模型之實際應用

實驗 9 使用 Grad-CAM 可解釋 AI 進行害蟲影像辨識可視化分析

實驗 10 開發害蟲辨識介面

實驗 11 自製捕蟲器以抓取害蟲

參、研究設備及器材

一、 分析軟體

設備名稱	設備規格說明	功能
電腦	具備上網功能	提供實驗進行各種軟體操作的
	具備螢幕、鍵盤、滑鼠的基本使用者介面	硬體平台
軟體	Python	運作程式碼
	Google Chrome	操作各種網路資源
	微軟 Office 2010	實驗報告產出
網站資源	Google Colab	運作程式碼
	ChatGpt	文本實驗討論的對話
	iNaturalist、Gbif	新增害蟲樣本
	Google 雲端硬碟	存放各種實驗資源

肆、研究過程與方法

一、研究架構

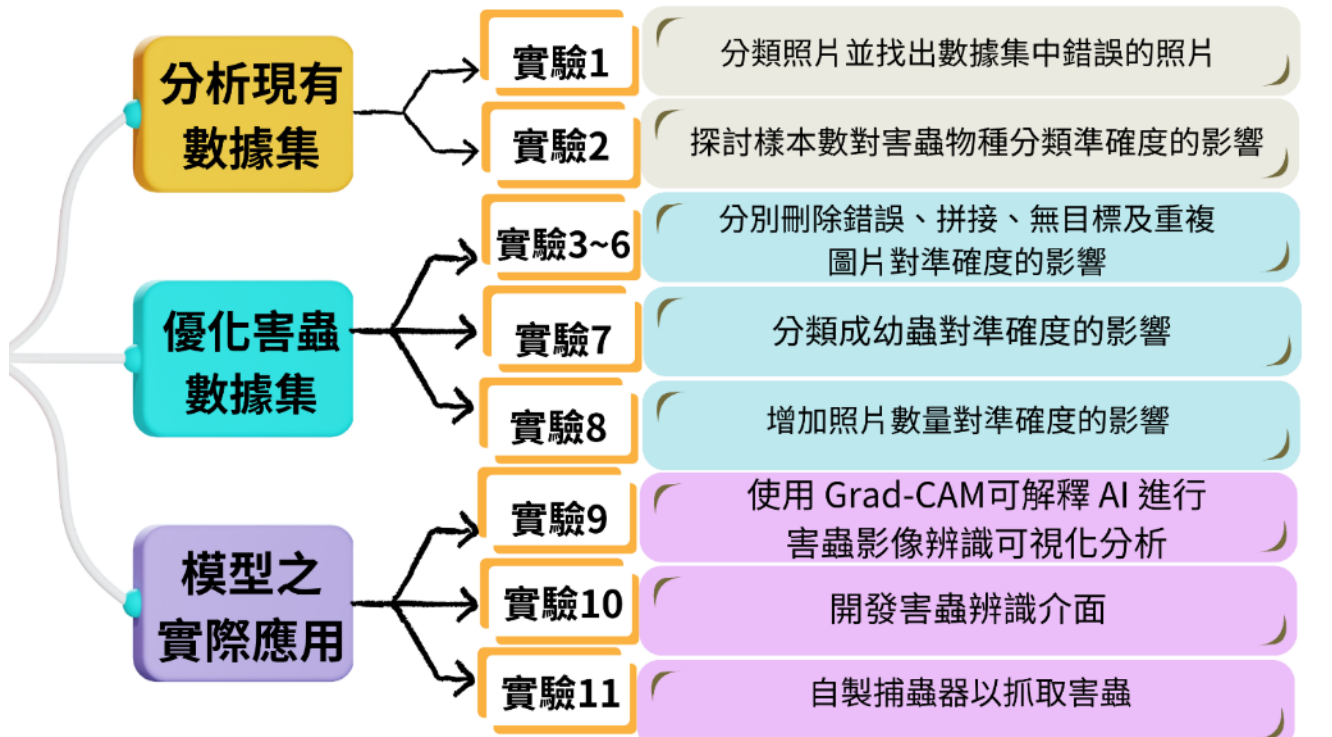


圖 4-1-1 研究架構圖

二、研究原理

(一) 深度學習

深度學習 (Deep Learning) 是一種機器學習的子領域，利用多層神經網路模仿人類大腦的結構和功能，處理複雜數據並解決高難度問題。其核心特點包括多層結構、自動特徵提取、端到端學習、大規模數據支持及強大的計算能力。深度學習模型通過層級結構逐步提取數據中的高層次特徵，實現更準確的預測和分類。相比於傳統機器學習方法，深度學習能自動從數據中學習特徵，尤其在處理非結構化數據如圖像、語音和文本時，表現出色。此外，深度學習對大規模數據適應性強，利用圖形處理單元 (GPU) 和專用硬件加速訓練過程。深度學習廣泛應用於圖像識別、語音識別、自然語言處理、自動駕駛及醫療診斷等領域，大大推動了科技進步和社會變革。

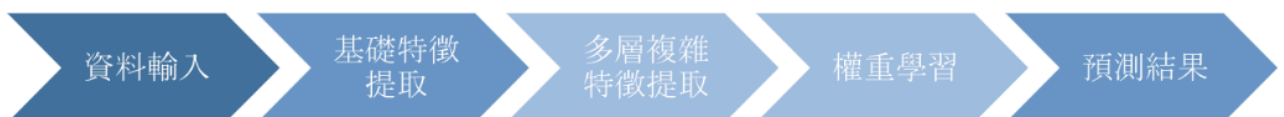


圖 4-2-1 深度學習流程圖

(二) InceptionV3

InceptionV3 是由 Google 開發的深度卷積神經網路 (CNN)，是 Inception 系列的第三個

版本，以高效的計算能力和出色的性能著稱，特別在圖像分類和物體檢測中表現優異。其核心特點包括使用 **Inception** 模塊，通過不同尺寸的卷積核（如 1×1 , 3×3 , 5×5 ）同時操作輸入數據，並將結果合併，這使網路能夠在不同感受野中學習特徵。此外，**InceptionV3** 採用卷積分解技術，將較大的卷積操作分解為更小的卷積，降低計算複雜度。通過批量標準化、輕量級卷積操作和輔助分類器等優化技術，**InceptionV3** 在減少模型參數和計算量的同時保持了高準確性。它廣泛應用於圖像分類、物體檢測和圖像生成等領域，其高效的特徵提取能力使其在多個圖像處理競賽中表現出色，並在自動駕駛、醫療影像分析和監控系統等工業應用中得到廣泛使用。




圖 4-2-2 InceptionV3 卷積神經網路架構(出處詳圖片來源 1)

(三) CNN

CNN（卷積神經網路，Convolutional Neural Network）是深度學習中專門用於圖像識別與處理的神經網路架構。主要由卷積層（Convolutional Layer）、池化層（Pooling Layer）和全連接層（Fully Connected Layer）組成。CNN 模仿人類視覺系統，透過卷積運算提取影像特徵，可以有效處理影像分類、物件偵測、語音識別等任務。

(四) Grad-CAM

Grad-CAM（Gradient-weighted Class Activation Mapping）是一種可解釋 AI（Explainable AI, XAI）技術，用來視覺化深度學習模型對分類結果的關注區域。它適用於 CNN 卷積神經網路，能幫助我們理解模型是基於哪些影像區域來做決策的。透過計算卷積層的梯度，來確定該層對最終分類結果的影響，然後將重要性權重應用到特徵圖上，產生一張熱力圖（heatmap），顯示模型關注的區域。

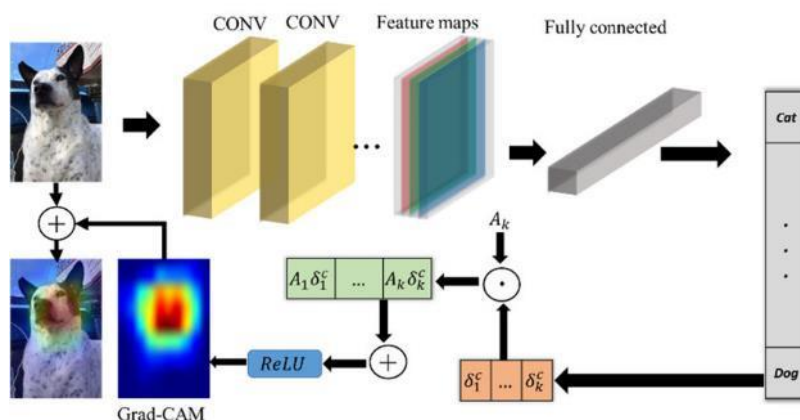


圖 4-2-3 Grad-CAM 技術(出處詳圖片來源 2)

三、名詞定義

(一) 混淆矩陣(Confusion Matrix)

用於評估分類模型(分類演算法)效果的一種矩陣表示方法,顯示出分類模型將樣本正確分類和錯誤分類的情況。

混淆矩陣		真實值	
		YES(1)	NO(0)
預測值	YES(1)	真陽性(True Positive, TP)	偽陽性(False Positive, FP)
	NO(0)	偽陰性(False Negative, FN)	真陰性(True Negative, TN)

(二) 正規化混淆矩陣(Normalized confusion matrix)

將混淆矩陣以百分比的形式呈現

(三) 精確率(Precision)

表示在所有預測陽性的樣本中真實正確的百分比，公式如下：

$$Precision = \frac{TP}{(TP + FP)}$$

(四) 召回率(Recall)

表示所有事實為陽性的樣本中預測正確的百分比，公式如下：

$$Recall = \frac{TP}{(TP + FN)}$$

(五) F1-score

為精準率及召回率的調和平均數(Harmonicmean)，可作為該二指標的綜合指標，能概略地評估模型的表現。F1 score 的數值介於 0 到 1，若該值越近於 1，代表模型有較佳的表現，反之越趨近於 0，則模型性能不理想。其公式如下：

$$F1\ score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

(六) 準確率(Accuracy)

分類正確的比例。其數學定義如下：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

(七) 損失值(Test Loss)

測試集上預測輸出與真實標籤之間的差異度量，採用交叉熵損失(Cross-Entropy Loss) 計算，其中 N ：樣本數、 C ：類別數、 y_{ic} ：第 i 個樣本的真实標籤、 p_{ic} ：模型對第 i 個樣本第 C 類別的預測概率。

$$Test\ Loss = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{ic} \log(p_{ic})$$

(八) 訓練集(Training Set)

模型訓練和學習的數據集，包含了標記有正確答案的數據。

(九) 驗證集(Validation Set)

用於調整模型參數和選擇最佳模型的一組數據。在模型訓練過程中，驗證集與訓練集分開使用，通常用於評估模型在訓練期間的表現以及防止過擬合。通過在每個訓練階段後評估模型在驗證集上的表現，可以調整超參數和其他設置。

(十) 測試集(Test dataset)

用於評估機器學習模型性能的一組數據。這些數據在訓練過程中不會被使用，因此可以用來測試模型在未見數據上的泛化能力。

(十一) 無目標圖片

圖片中沒有昆蟲的照片，範例如下：



圖 4-3-1.無目標圖片。A. 物種 01 稻縱卷葉螟的外觀型態。B.物種 01 資料夾中找到的無目標圖片

(十二) 錯誤圖片

圖片中標記的昆蟲和實際物種並不相符，範例如下：



圖 4-3-2.錯誤圖片及拼接到照片。A.物種 01 稻縱卷葉螟的外觀型態。B.物種 01 資料夾中找到的錯誤圖片，此物種非稻縱卷葉螟，而是白背飛虱。C.物種 01 資料夾中的拼接圖片，由多張影像拼貼而成，不符合實際場景。

(十三) 拼接圖片

圖片為多張影像拼接在一起，同時包含許多不同的蟲體，範例如圖 4-3-2C。

(十四) 害蟲數據集

經過查詢，IP102 是目前農業領域最大的開源害蟲識別數據集，專注於農作物病蟲害的視覺識別與檢測任務。因原資料集中部份類別所含影像過少、類別定義不清、涵蓋多種物種..，我們從中過濾後，篩選出 44 種定義明確的物種，挑選後的物種如下：

序號	中文名	學名	序號	中文名	學名
1	稻縱卷葉螟	<i>Chilo suppressalis</i>	46	苜蓿夜蛾	<i>Heliothis virescens</i>
2	稻螟蛉	<i>Naranga aeneas</i>	47	苜蓿盲蝽	<i>Adelphocoris lineolatus</i>
3	稻潛葉蛾	<i>Atherigona orientalis</i>	48	牧草盲蝽	<i>Lygus lineolaris</i>
4	水稻二化螟	<i>Chilo suppressalis</i>	54	牛角花齒薊馬	<i>Odontothrips loti</i>
5	水稻三化螟	<i>Tryporyza incertulas</i>	57	東方菜粉蝶	<i>Pieris canidia</i>
6	稻癭蚊	<i>Orseolia oryzae</i>	58	綠盲蝽	<i>Apolygus lucorum</i>

7	稻稈蠅	<i>Chlorops oryzae</i>	67	葡萄天蛾	<i>Ampelophaga rubiginosa</i>
8	褐稻虱	<i>Nilaparvata lugens</i>	68	斑衣蠟蟬	<i>Lycorma delicatula</i>
9	白背飛虱	<i>Sogatella furcifera</i>	72	溫室粉虱	<i>Trialeurodes vaporariorum</i>
10	灰飛虱	<i>Laodelphax striatellus</i>	74	柑橘鳳蝶	<i>Papilio xuthus</i>
11	稻水象甲	<i>Lissorhoptrus oryzophilus</i>	77	吹綿蚱	<i>Icerya purchasi</i>
12	稻葉蟬	<i>Nephotettix spp.</i>	78	矢尖蚱	<i>Unaspis yanonensis</i>
15	蟊蟥	<i>Heteronychus arator</i>	83	黑刺粉虱	<i>Aleurocanthus spiniferus</i>
17	金針蟲	<i>Elateridae</i>	85	芒果柑桔小實蠅	<i>Dacus dorsalis</i>
19	小地老虎	<i>Agrotis ipsilon</i>	87	斜紋夜蛾	<i>Prodenia litura</i>
20	大地老虎	<i>Agrotis infusa</i>	88	枯葉夜蛾	<i>Adris tyrannus</i>
21	黃地老虎	<i>Agrotis ypsilon</i>	89	柑桔潛葉蛾	<i>Phyllocnistis citrella</i> <i>Stainton</i>
23	玉米螟	<i>Ostrinia spp.</i>	93	茶黃薊馬	<i>Scirtothrips dorsalis</i> Hood
26	白星花金龜	<i>Potosia brevitarsis</i>	95	白翅蠟蟬	<i>Lawana imitata</i> Melichar
27	桃蛀螟	<i>Conogethes punctiferalis</i>	96	褐緣蛾蠟蟬	<i>Salurnis marginella</i> Guerr
28	麥長管蚜	<i>Sitobion avenae</i>	100	脊胸天牛	<i>Rhytidodera bowrinii</i>
40	甜菜夜蛾	<i>Spodoptera exigua</i>	101	芒果果肉象甲	<i>Sternonchetus frigidus</i>

四、實驗方法

(一)數據集整理與前處理

1. 人工分類與篩選 (實驗 1、3-5)

以電腦逐一檢視數據集所有害蟲圖片，上網查詢確認該物種外型特徵後，將圖片依照物種幼蟲、成蟲進行分類，並同時過濾出以下異常資料：無目標圖片、分類錯誤、拼接圖片，統計各類圖片比例，了解數據分佈狀況。整理後的資料另存為新目錄，作為後續實驗基礎。

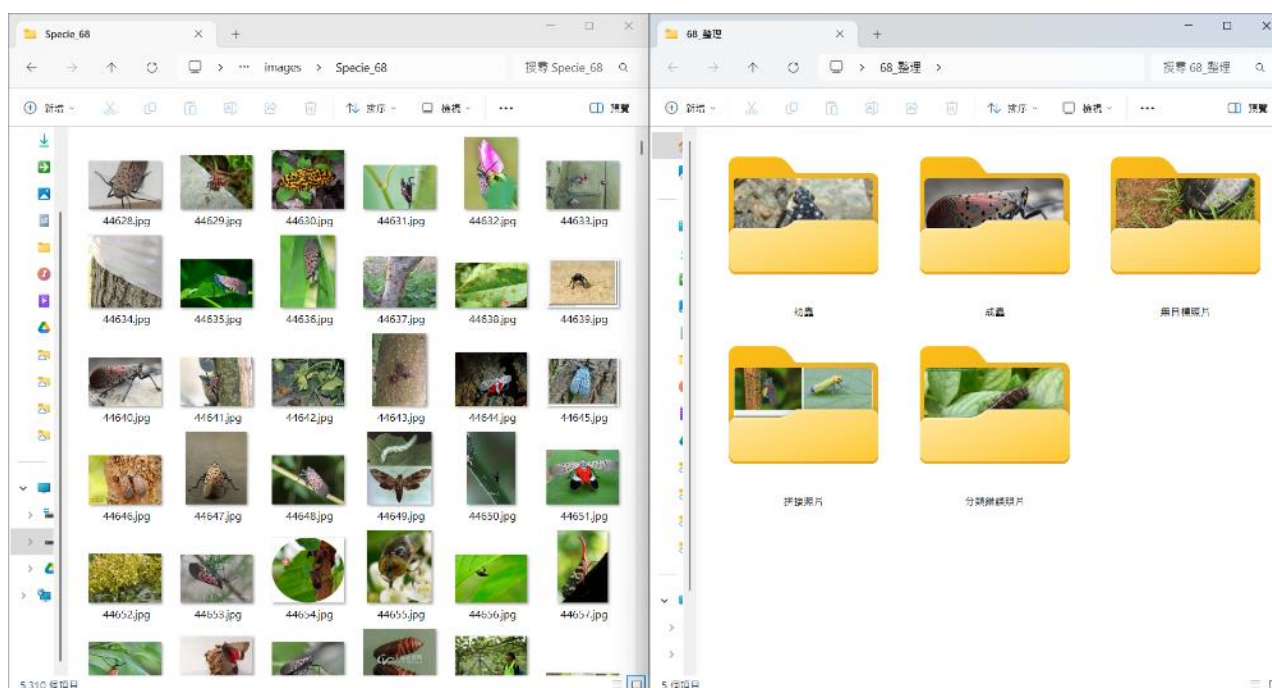









圖 4-4-1.人工篩選數據集的害蟲圖片。

2. 樣本控管與分類標註 (實驗 2)

選取七個樣本數超過 1000 張的物種，如圖所示，分別保留其樣本數為：100 張、500 張與 1000 張，以 Python 程式隨機抽取指定數量之樣本，比較不同樣本數對模型訓練結果的影響。

序號	1 稻縱卷葉螟 <i>Chilo suppressalis</i>	4 水稻二化螟 <i>Chilo suppressalis</i>	23 玉米螟 <i>Ostrinia spp</i>	40 甜菜夜蛾 <i>Spodoptera exigua</i>
圖片				
序號	46 苜蓿夜蛾 <i>Heliothis virescens</i>	68 斑衣蠅蟬 <i>Lycorma delicatula</i>	87 斜紋夜蛾 <i>Spodoptera exigua</i>	
圖片				

3. 刪除異常圖片處理 (實驗 3、4、5)

分別建立版本化資料集：

實驗 3：刪除拼接圖片、實驗 4：刪除分類錯誤的圖片、實驗 5：刪除無目標圖片

這些資料清理版本皆使用原始集為基礎，進行單一變因排除，以利比較實驗準確性差異。

4. 幼蟲與成蟲標註分類 (實驗 6)

依害蟲生命周期分為「成蟲」與「幼蟲」兩類。分別建立三種分類模式資料集：

成蟲資料集、幼蟲資料集、成蟲+幼蟲合併資料集

用以觀察不同影像分類模式對模型準確度之影響。

5. 圖片重複偵測與去除 (實驗 7)

感知哈希 (Perceptual Hashing, pHash) 是一種用於圖片相似性比較的技術，將圖片轉換成固定長度的二進位碼，使得相似的圖片會產生相似的哈希值 (pHash)。閾值 (Threshold) 則表示哈希值 (pHash) 差異的容忍程度，越小越嚴格，經測試後，我們將閾值定為 15，篩選出低於閾值 (過於相似) 的影像，統計重複數量並加以刪除，重組後進入下階段模型訓練。




圖 4-4-2. 感知哈希圖像相似度算法
(出處詳圖片來源 3)

6. 新增成蟲與幼蟲圖片 (實驗 8)

為提升模型對於特定物種的辨識能力，透過公開資料庫 GBIF 與 iNaturalist 搜集影像，針對 44 種常見害蟲物種進行資料擴增。經過人工審查與重複圖片過濾後，成功新增 8,002 張成蟲與幼蟲影像。並挑出 880 張當作測試集 (每物種 20 張，共 44 種)。以原訓練完成的 Inception v3 模型進行辨識測試，觀察擴增後資料對準確率的實際影響。

(二) InceptionV3 模型訓練與辨識流程 (實驗 2 ~ 8)

1. 資料切割與格式標準化

所有版本資料集皆統一以 8 : 1 : 1 比例切分為：訓練集 (training set)、驗證集 (validation set)、測試集 (testing set)，使用 Python 程式自動化完成切割與資料夾整理。完成後將資料夾壓縮上傳至 Google Drive。




圖 4-4-3.切割後的資料集格式

2. 模型訓練與評估

使用 Google Colab 執行 Inception v3 模型訓練。將訓練用圖片進行預處理 (如：標準化尺寸、正規化數值)。設定超參數 (如學習率、批次大小、訓練期數等)，啟動訓練。紀錄每次訓練的準確率 (Accuracy) 與損失值 (Loss)，以繪圖方式呈現學習曲線。使用測試集進行最終驗證，與不同資料集處理策略下的模型表現進行比較。

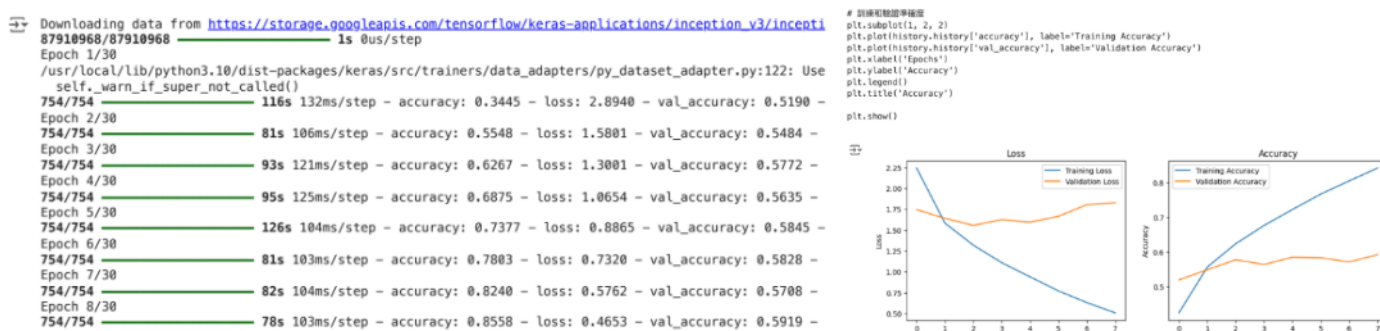


圖 4-4-4. Inception v3 模型訓練過程，並繪製損失和準確度圖，可視化訓練過程

(三) 延伸實驗與應用開發 (實驗 9、10、11)

1. 模型可視化與可解釋性分析 (實驗 9)

載入訓練完成且表現最佳的 Inception v3 模型與權重，從測試集中挑選數張正確分類與錯誤分類圖片。使用 Grad-CAM 方法計算模型在圖片中的關鍵區域，根據梯度生成熱力圖 (heatmap)，疊加在原始圖片上，並調整顏色與透明度，便於分析模型關注的區域。

2. 害蟲辨識介面開發 (實驗 10)

匯入已訓練好的成蟲/幼蟲模型，儲存模型完整架構與權重 (使用 .h5 或 .pt 格式)。

```
model_path = "/content/drive/MyDrive/生物組/03實驗數據分析/實驗7-分類成幼蟲對準確度的影響/inception_v3_model.h5"
image_size = (150, 150) # 你訓練時的圖片尺寸

# 加載模型
model = load_model(model_path)

# 測試模型是否成功載入
print("模型載入成功!")
```

編寫 Gradio 介面進行害蟲辨識的程式

```
def predict_pest(img):
    # 預處理圖片
    img = img.resize((224, 224)) # 轉換大小
    img_array = image.img_to_array(img) # 轉換為數組
    img_array = np.expand_dims(img_array, axis=0) # 增加 batch 維度
    img_array /= 255.0 # 標準化

    # 預測
    predictions = model.predict(img_array)[0] # 取得模型輸出
    top_5_indices = np.argsort(predictions)[-5:] # 取得前 5 項的索引
    top_5_scores = predictions[top_5_indices] # 取得前 5 項的機率

    # 轉換索引為名稱
    result_text = f"最有可能的害蟲: {pest_names[top_5_indices[0]]} ({top_5_scores[0]:.2%})\n\n"
    result_text += "其他可能的害蟲:\n"
    for i in range(1, 5):
        result_text += f"{i+1}. {pest_names[top_5_indices[i]]} ({top_5_scores[i]:.2%})\n"

    return result_text
```


建立索引編號對應實際害蟲名稱的字典，整合索引與物種名稱對應功能

```
pest_names = {
    0: '01_稻縱卷葉螟', 1: '02_稻螟蛉', 2: '03_稻潛葉蛾', 3: '04_水稻二化螟', 4: '05_水稻三化螟',
    5: '06_稻飛虱', 6: '07_稻稈蛾', 7: '08_褐稻虱', 8: '09_白背飛虱', 9: '100_脊胸天牛',
    10: '101_芒果果肉象甲', 11: '10_灰飛虱', 12: '11_稻水象甲', 13: '12_偽黑尾葉蟬', 14: '15_蟬蟬',
    15: '17_金針蟲', 16: '19_小地老虎', 17: '20_大地老虎', 18: '21_黃地老虎', 19: '23_玉米螟',
    20: '26_白星花金龜', 21: '27_桃蛀螟', 22: '28_麥長管蚜', 23: '40_甜菜夜蛾', 24: '46_苜蓿夜蛾',
    25: '47_苜蓿盲蝽', 26: '48_牧草盲蝽', 27: '54_牛角花齒齧馬', 28: '57_東方菜粉蝶', 29: '58_綠盲蝽',
    30: '67_葡萄天蛾', 31: '68_斑衣蠅蝶', 32: '72_溫室粉虱', 33: '74_柑橘鳳蝶', 34: '77_吹綿蚱',
    35: '78_矢尖蚱', 36: '83_黑刺粉虱', 37: '85_東方果實蠅', 38: '87_斜紋夜蛾', 39: '88_枯葉夜蛾',
    40: '89_柑桔潛葉蛾', 41: '93_茶黃薊馬', 42: '95_白翅蠅蝶', 43: '96_褐緣蠅蝶'
}
```

以 Gradio 建立使用者介面，讓使用者可即時上傳害蟲圖片進行分類辨識

```
# 建立 Gradio 介面
interface = gr.Interface(
    fn=predict_pest,
    inputs=gr.Image(type="pil"),
    outputs="text",
    title="害蟲識別系統",
    description="請上傳一張害蟲圖片，系統將會識別該圖片是否為害蟲並顯示可能類別。",
)

# 在 Colab 運行時需要加上 share=True
interface.launch(share=True)
```

3. 自製害蟲捕捉裝置 (實驗 11)

使用市售捕蟲器，外部安裝攝影鏡頭，將即時影像輸入至訓練模型，若偵測到內部有特定害蟲，以圖表紀錄數量，並且將類別與時間做成 CSV 檔，完成捕捉並記錄。

伍、研究結果與討論

實驗 1：數據集分類及資料分析




圖 5-1-1 數據集分類的比例

各物種資料的整體品質落差明顯，部分物種（如編號 15、17、74）具高比例的正确資料，然而也有數個物種中異常圖片的比例明顯偏高，甚至超過原始資料的一半，例如物種 12(錯誤 41.9%)、28(拼接(44.3%)、46(錯誤 59.7%)、100(錯誤 77.1%)。平均錯誤圖片 13.04%、拼接照片 5.69%、無目標 13.62%，正確比例為 67.65%，反映出這些物種的資料來源可能存在混雜問題，釐清了原始數據的品質分佈，也為後續實驗提供了明確依據。

實驗 2：探討樣本數對害蟲物種分類準確度的影響




圖 5-2-1. 不同樣本數資料集的準確率和損失值

將樣本數量設為 100、500、1000 後，準確率(accuracy)分別為 45.45%、53.43%、64.31%，可以發現樣本數越多，準確率呈現上升趨勢，而損失值則呈現下降趨勢，顯示其辨識效果有所提升。此結果也驗證了我們的原始假設：當電腦獲得較多的訓練樣本來學習時，模型能學習到更完整的特徵，學習成效相對有更好的表現，進而提高分類準確度並減少錯誤。因此，較多的樣本數更有利於強化害蟲物種辨識能力。

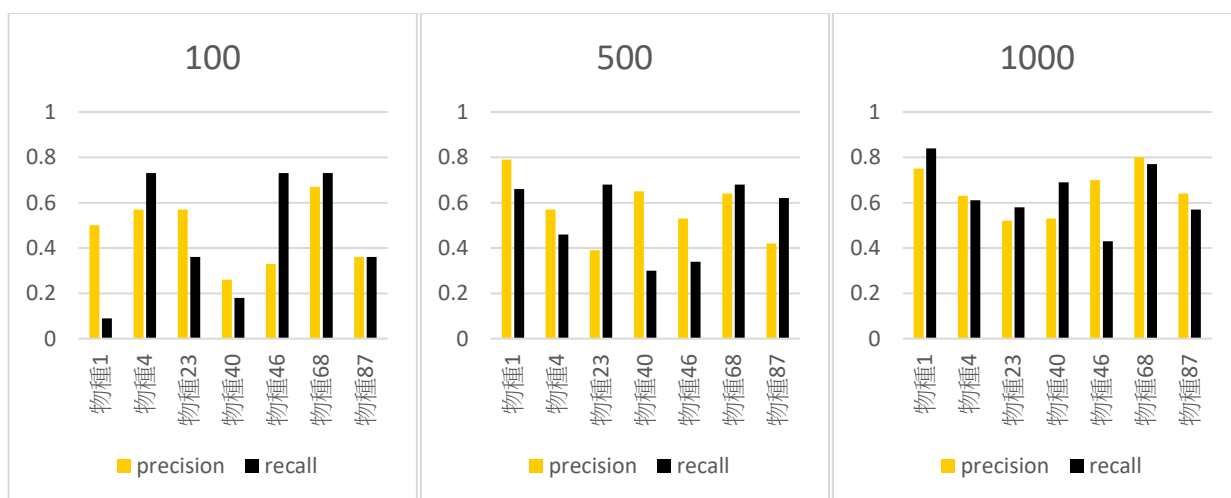


圖 5-2-2. 不同樣本數資料集的訓練結果。A. 100 張。B. 500 張。C. 1000 張

接著觀察各組的精確率與召回率，可以發現樣本數為 100 的精確率與召回率普遍都低於 40%、整體平均為 46%；將樣本數增加至 1000 後，精確率與召回率普遍都提升至高於 60%、整體平均也提升至 65%。此外，從數據分布的穩定性來看，隨著樣本數從 100 增加到 1000，各物種的精確率與召回率波動幅度明顯減少，顯示模型逐漸趨於穩定。不同物種的辨識效果亦有所不同，物種 23 玉米螟、40 甜菜夜蛾在低樣本數時召回率低，表示有很多正確的樣本未被識別，物種 40 甜菜夜蛾外形與

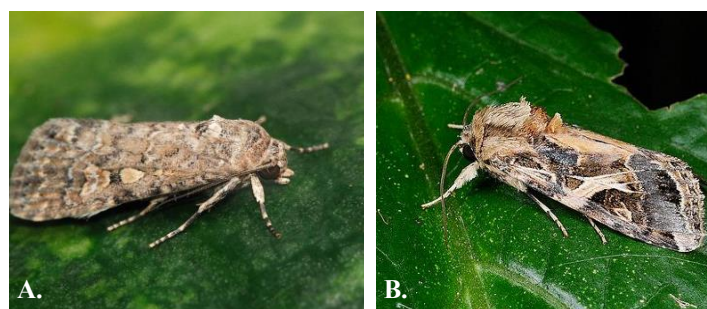


圖 5-2-3. 物種 40 甜菜夜蛾(A)與物種 87 斜紋夜蛾(B)

物種 87 斜紋夜蛾外形相似，經樣本數增加時改善幅度較大，顯示在足夠的訓練數據下，模型才可以更準確地學習其特徵。物種 68 斑衣蠟蟬則在低樣本數時已有不錯的表現，推測因為半翅目斑衣蠟蟬與其他 6 種鱗翅目害蟲外型差異較大，較不容易分類錯誤，這也反映出不同物種的識別難度不同。

實驗 3：刪除拼接圖片對模型準確度的影響




圖 5-3-1. 刪除拼接圖片的準確率和損失值

將「拼接照片」刪除後，準確率(accuracy)從 50.36%微幅上升到 53.05%，而損失值(loss value)從 1.8223 降至 1.7189，可發現此實驗將「拼接圖片」刪除，雖然能讓準確率提高，但上升幅度不大(因拼接照片僅占 5.7%)。




圖 5-3-2. 刪除拼接圖片的精確率和召回率

從精確率(precision)來看發現物種 57(東方菜粉蝶) 皆高於 80%(可能是特徵差異大)，而在精確率裡表現較差的有物種 9(白背飛虱)、12(稻葉蟬)、46(苜蓿夜蛾)、58(綠盲蝽)，這 3 種皆未達 30%，特徵可能重疊。接著換從召回率(Recall)來看，物種 1(稻縱卷葉螟)、15(蟬蟻)、57(東方菜粉蝶)、68(斑衣蠅蟬)、74(柑橘鳳蝶)、83(黑刺粉虱)、95(白翅蠅蟬)、100(脊胸天牛)皆高於 70%，表現較差的有物種 2(稻螟蛉)、3(稻潛葉蛾)、8(褐稻虱)、10(灰飛虱)、20(大地老虎)、28(麥長管蚜)、58(綠盲蝽)皆低於 20%，可能是因為特徵不足。

其中有一些精確率高但召回率低的物種例如:物種 3，表示模型對於該物種的預測非常「保守」，絕大多數物種 3 被歸類到其他物種，原因可能是因為物種 3(稻潛葉蛾)在訓練數據中比例非常低或用於區分物種 3 的特徵可能不足或不明顯，我們可以透過增加物種 3 的數據樣本、特徵改進和重新評估模型架構。像是物種 15(蟬蟻)召回率高精確率卻很低的種類，表示說這代表模型對該物種的判斷能力良好，但也容易將其他類別錯分至物種 15 原因可能:是物種 15 和其他物種的特徵可能高度重疊，導致模型難以準確區分，增加了假陽性數量。




圖 5-3-3 物種 3 稻潛葉蛾(A)與物種 1 稻縱卷葉螟(B)




圖 5-3-4. 刪除拼接圖片的混淆矩陣

此外，從混淆矩陣的結果來看，顏色越深代表該分類結果所佔的比率越高。可以觀察到，大多數的分類結果沿對角線排列，顯示多數物種被成功地分類為其正確的類別。然而，仍有部分物種容易被誤判為其他物種，例如：物種 88（枯葉夜蛾）常被誤分類為物種 68（斑衣蠟蟬）。經查閱圖片可知，兩者在顏色上具有高度相似性，可能導致模型混淆。此外，部分物種在數據集中所佔比例偏低，且特徵不夠明顯，可能也導致拼接圖片對分類結果的影響有限，進而使混淆矩陣與整體統計結果差異不大。



圖 5-3-5. 物種 88 枯葉夜蛾(A)與物種 68 斑衣蠟蟬

實驗 4：刪除錯誤圖片對模型準確度的影響




圖 5-4-1. 刪除錯誤圖片的準確率和損失值

透過上方的圖片可以發現，在原始的數據集中刪除「錯誤圖片」後，讓數據集分類更加明確，使辨識的正確率(accuracy)提高從原本的 50.36% 提升至 56.60% 且損失值(loss value)從 1.8223 降低至 1.6192，證明刪除錯誤圖片能夠提升辨識結果。




圖 5-4-2. 刪除錯誤圖片的精確率和召回率

分析精確率，可發現某些物種的精確率特別高如第 57(東方菜粉蝶)、74(柑橘蝶)、83(黑刺粉虱)、100(脊胸天牛)種皆有 80% 以上，觀察後發現物種 57(東方菜粉蝶)及 74(柑橘蝶)中的樣本都較其他物種清晰且單一不混雜，物種 83 及 100 則是昆蟲形體特殊且特徵較明顯；而在第 46(苜蓿夜蛾)、58(綠盲蝽)種的精確率較差皆低於 30%。而在召回率 (Recall) 方面，實驗 4 在部分分類處理中表現較差，且發現精確率高的物種如第 83(黑刺粉虱)、100(脊胸天牛)種召回率卻較低，可以解釋為由於模型的決策門檻 (Threshold) 設置較高，導致模型傾向於只標記那些模型高度確信的正例。另外第 68 種的召回率高於精確率，推測是因為樣本數量太多，約有 5300 多個樣本，多於平均的 780 個，導致許多其他的物種被錯分到此種內。




圖 5-4-3. 物種 57 東方粉菜蛾(A)與物種 74 柑橘蝶(B)




圖 5-4-4. 刪除錯誤圖片的混淆矩陣

若是從混淆矩陣的結果來看，顏色越深代表分類所佔的比率越高，可以發現結果是呈現對角線代表大部分的物種都有被分類到正確的物種，但是仍可以發現某些物種被分類到錯誤的物種的比例較高如：物種 1(稻縱卷葉螟) 被錯分到物種 12(稻葉蟬)、物種 95(白翅蠟

蟬)被錯分到物種 96(褐緣蛾蠟蟬)等，推測可能是因為兩種物種較為相似，導致電腦錯分了更多的圖片到相似的物種中。另外還可以發現有許多物種被錯分到物種 68(斑衣蠟蟬)，因為該物種的樣本數量特別多，資料分布不均，導致該物種辨識的學習效果較好，造成更容易將其他物種錯分到此類。

實驗 5：刪除無目標圖片對模型準確度的影響




圖 5-5-1. 刪除無目標圖片的準確率和損失值

透過上方的圖片可以發現，由於需刪除照片在數據集中的平均中大約為 15%，在原始的數據集中刪除「無目標圖片」後，讓數據集分類更加明確，使辨識的正確率(accuracy)提高從原本的 50.36%提升至 57.43%且損失值(loss value)從 1.8223 降低至 1.6087，證明刪除錯誤圖片能夠提升辨識結果。

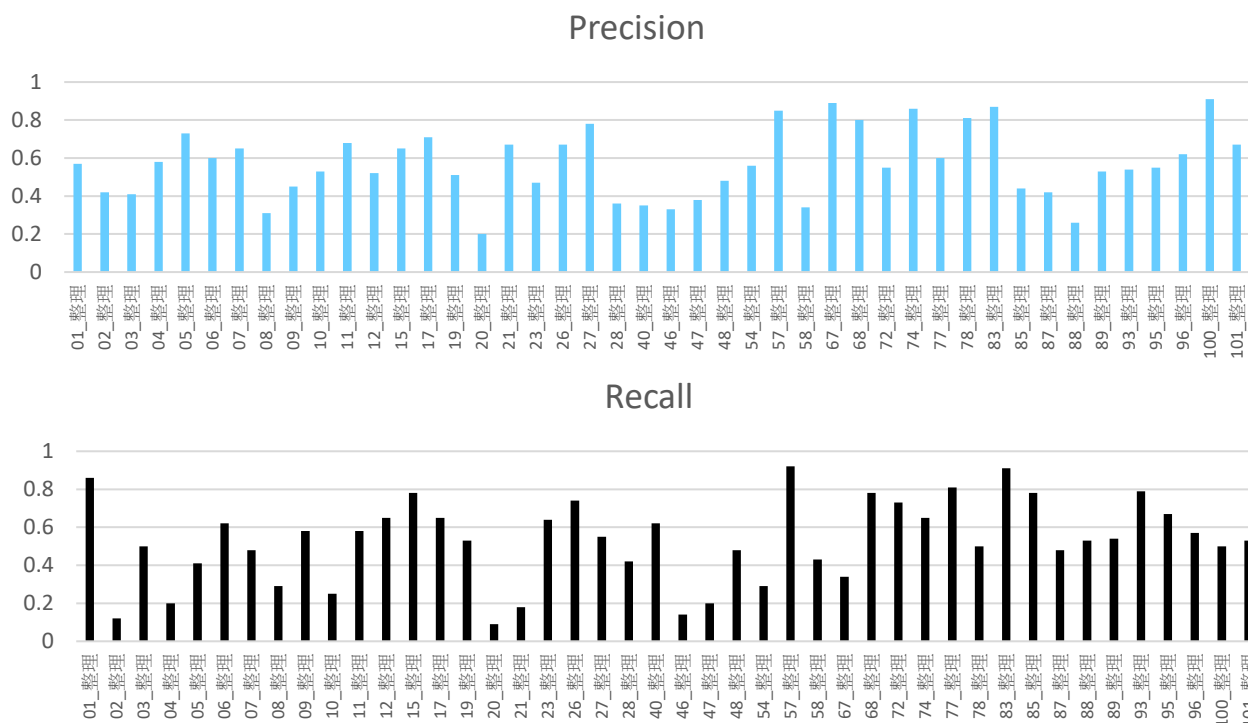


圖 5-5-2. 刪除無目標圖片的的精確率和召回率

從細部來分析精確率，可發現某些物種的精確率特別高如:第 57 東方菜粉蝶、67 葡萄天蛾、74 柑橘鳳蝶、83 黑刺粉虱、100 褐緣蛾蠟蟬，他們大多具有鮮豔的顏色或外觀。

而在 20 大地老虎、88 枯葉夜蛾兩者的體型相對較小，並兩者的體色都具有一定的保

護性，有助於隱藏或偽裝，精確率較差皆低於 30%。

在召回率（Recall）方面，實驗 5 在部分分類處理中表現較差，且發現精確率高的物種如第 2、20、21、46、47 種，召回率卻較低，可以解釋為由於模型的決策門檻（Threshold）設置較高，導致模型傾向於只標記那些模型高度確信的正例。第 57 種則是精確率高召回率也高代表該物種易於分類且不易把其他物種錯分到此物種內，利於辨識。




圖 5-5-3. 刪除無目標圖片的混淆矩陣

此外，從混淆矩陣的結果來看，圖中顏色越深代表該分類結果所佔的比率越高。觀察整體分佈可發現，分類結果大多集中於對角線上，顯示大部分物種能夠被正確分類。然而，仍有部分物種容易被誤判為其他類別。例如，物種 54（牛角花齒薊馬）經常被誤分類為物種 93（茶黃薊馬）。這兩種昆蟲在形態上具有高度相似性：牠們的體長皆約介於 5 至 12 毫米之間，屬於小型害蟲，外觀呈黃褐色或綠色，能在自然環境中有效偽裝。此外，兩者皆具透明翅膀，並帶有明顯的斑紋或條紋，這些相似的外觀特徵可能是導致模型分類混淆的主要原因。

實驗 6：幼蟲與成蟲分類對模型準確度的影響




圖 5-6-1. 分類成幼蟲模型的準確率和損失值

本研究進一步比較了幼蟲與成蟲分類模型的表現，模型的測試準確率依序為 64.42%、72.55%、63.62%，顯示成蟲的分類準確率最高且損失值最低，這可能是由於成蟲在形態上具有較為明顯的特徵差異，因此分類模型能夠更準確地進行辨識。相較之下，**幼蟲**的外觀相對類似，導致分類準確率較低，結果較不具辨識性。此外，當成蟲與幼蟲的數據合併進行分類時，準確率介於兩者之間，顯示該模型的整體分類能力受到兩類特徵影響。




圖 5-6-2. 分類成幼蟲模型的精確率

幼蟲分類的精確率整體偏低，主要原因是不同物種間幼蟲在外觀上變異較小，模型較容易誤將其他物種錯判為目標類別，造成 Precision 偏低。成蟲在形態、顏色、翅膀等外部特徵上具有較高辨識性，模型在面對成蟲影像時能更穩定地對應正確分類。成蟲與幼蟲合併訓練的精確率介於兩者之間，但略偏向成蟲表現。




圖 5-6-3. 分類成幼蟲模型的召回率

有些成蟲的召回率相比精確率差距較大，例如物種 20 大地老虎，我們發現物種 20 容易被搞混，而分至其他物種，導致其召回率偏低，但是成蟲的平均召回率仍然較數據集[幼蟲]、數據集[成蟲加幼蟲]高。接著是幼蟲，我們發現幼蟲的召回率為 0 的物種有許多都與精確率一樣，這代表如果這些精確、召回率為 0 的幼蟲是有被分類到的話、就代表這些幼蟲都被分到其他物種，且其他物種也會被分類進去，也表示了大多數的幼蟲都長得一樣。最後是成蟲加幼蟲，它的平均召回率是位於成蟲與幼蟲間，這可能是因為將成蟲的召回率較高，幼蟲則相反，而兩個數據及的平均召回率與成蟲加幼蟲的平均召回率差不多。

實驗 7：刪除重複圖片對模型準確度的影響




圖 5-7-1.物種 83 黑刺粉虱中部份的重複圖片




圖 5-7-2. 各類別重複圖片的比例

在成蟲和幼蟲總共 23,475 張照片中，有 8,584 張照片與同物種中至少一張照片相似，大約為 36.57%。其中物種 6 稻瘰蚊以及物種 83 黑刺粉虱比例皆高過於 50%。




圖 5-7-3. 刪除重複圖片的準確率和損失值

透過上方圖表可發現，實驗 7 的 Accuracy 從原本的 50.36%降低至 47.82%，Tess Loss 則升高至 1.9929，我們認為在原本對照組中，高比例的重複圖片恐造成資訊洩漏的問題，相同照片出現在訓練集和測試集，導致模型由於看過相同圖片而呈現出不實的高準確率。

為了驗證此一假設，我們進一步建立一組「全新測試集」作為模型效能的驗證依據。這

組測試集為外部額外蒐集的影像資料，兩組模型在訓練中皆未曾接觸過，能有效排除資料重複所造成的影響，真正評估模型在陌生資料上的表現。

測試結果顯示，原對照組模型在新測試集上的準確率為 48.3%，而刪除重複圖片後訓練的模型則提升至 54.66%。此結果明確驗證了我們的推論：原先較高的準確率部分來自於訓練與測試資料間的資訊重疊，並非模型對於未知資料的真實辨識能力。去除重複圖片不僅提升了模型的泛化能力，也讓模型表現更具代表性與可信度。




圖 5-7-4. 兩組模型對全新測試集的準確率




圖 5-7-5. 刪除重複照片的混淆矩陣

在實驗 3-5 中，物種 68(斑衣蠟蟬)因樣本數過多且包含大量重複圖片，導致其他物種經常被誤判為 68，清除重複圖片後，其誤分比例大幅下降，顯示資料清理成效顯著，提升整體辨識公平性。模型較容易誤判為物種 23(玉米螟)及物種 40(甜菜夜蛾)，兩者皆屬鱗翅目夜蛾科，幼蟲外觀相似（細長身形），且在資料中亦可能有類似背景或角度，使模型較難區分。

實驗 8：數據集擴增對模型準確度的影響

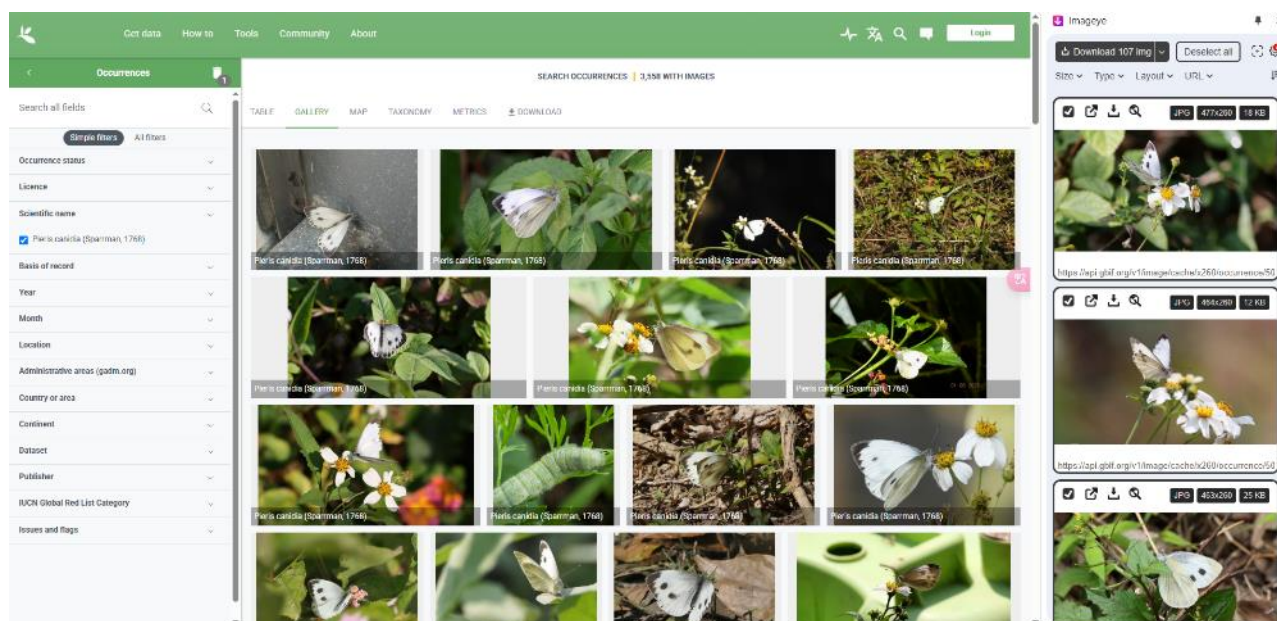


圖 5-8-1. 以物種 57 東方菜粉蝶為例，從公開資料庫 GBIF 搜尋影像，搭配 Image Downloader 批量下載

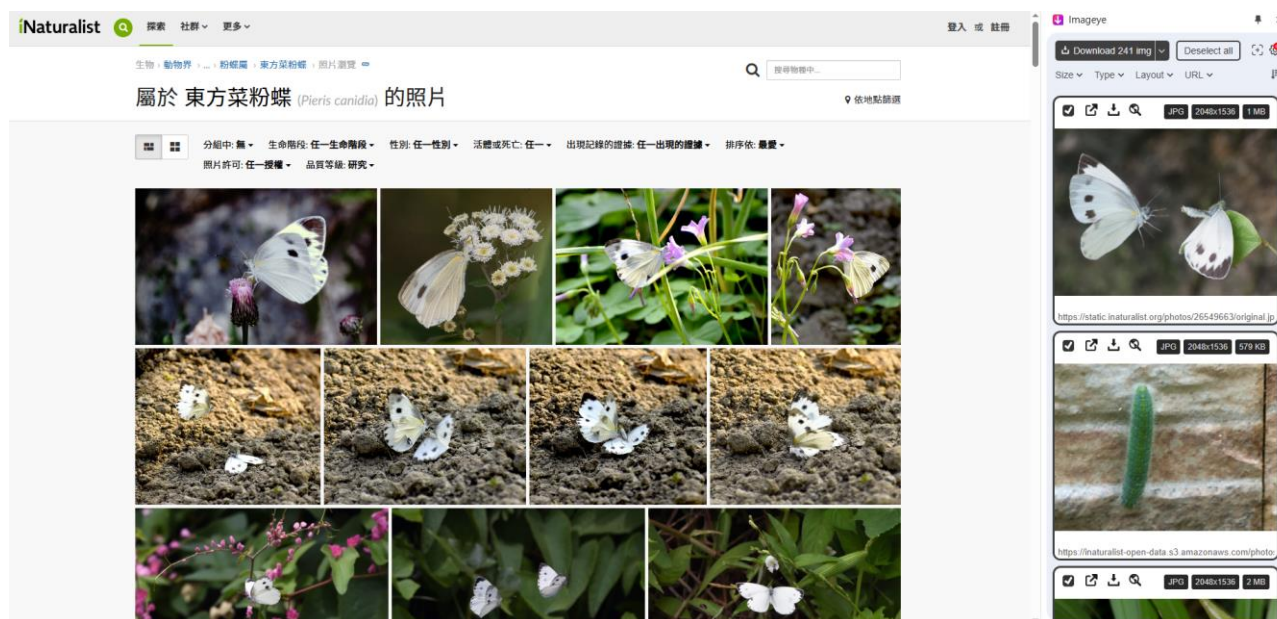


圖 5-8-2. 以物種 57 東方菜粉蝶為例，從公開資料庫 iNaturalist 搜尋影像，搭配 Image Downloader 批量下載




圖 5-8-3.原始照片與新增圖片所佔比例，數據集擴增後總樣本數為 24885 張




圖 5-8-4.新增圖片的準確率和損失值

當刪除重複照片後，我們新增成蟲與幼蟲的圖片，共增加 10094 張(從 GBIF、iNaturalist 找的)，發現準確率較之前新增前的照片來的高，而損失率也比新增圖片前的數據集來的低，這代表新增圖片後比原本的數據集還要更加準確。




圖 5-8-5.新增圖片的精確率

由這張圖來看，我們發現新增後的精確率幾乎全部都高於新增前的圖片，這代表新增後的圖片相較於新增前的圖片更不容易將錯誤圖片分進自己的物種裡，這也代表新增圖片後對訓練集更有幫助，而比原本精確率還要低的(物種 2、5、57、88)這四種的精確率降低可能是因為新增圖片不多且其他物種有錯誤圖片而導致的。




圖 5-8-6.新增圖片的精確率

接著觀察召回率的變化，可發現多數物種的召回率有明顯提升，顯示模型在辨識這些物種時，較能完整地將其正確分類為對應類別，較少將其錯誤地判斷為其他物種。

實驗 9：使用 Grad-CAM 可解釋 AI 進行害蟲影像辨識可視化分析

輸入影像	Grad-CAM 熱力圖	可視化結果分析
<p>物種 67 葡萄天蛾</p> <p>錯誤分類 ✗</p>		此照片的背景較為雜亂（落葉、泥土等），可能與其他昆蟲的背景相似，導致模型誤認。
<p>物種 67 葡萄天蛾</p> <p>成功分類 ✓</p>		當背景較為單純時，模型較能學習到昆蟲本身的形狀與特徵。
<p>物種 58 綠盲蝽</p> <p>錯誤分類 ✗</p>		紅、黃區域主要集中在背景花朵上，推測模型錯誤依賴背景來判斷導致錯誤。

物種 58
綠盲蝽

成功分類



模型聚焦在昆蟲本體，特別是頭部，專注於昆蟲的特徵來進行分類，而非背景資訊。

實驗 10：開發害蟲辨識介面

使用者在拍攝或上傳圖片後點擊提交，系統就會辨識出最有可能的害蟲名稱，及其他五種可能性較低的物種，如下方所示：

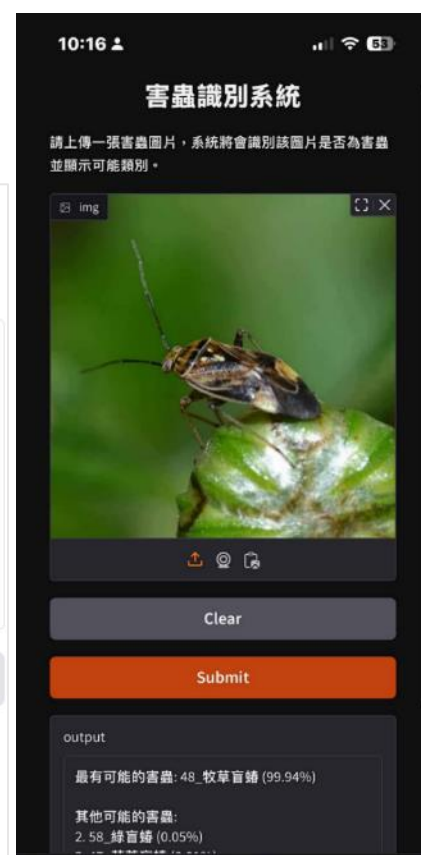
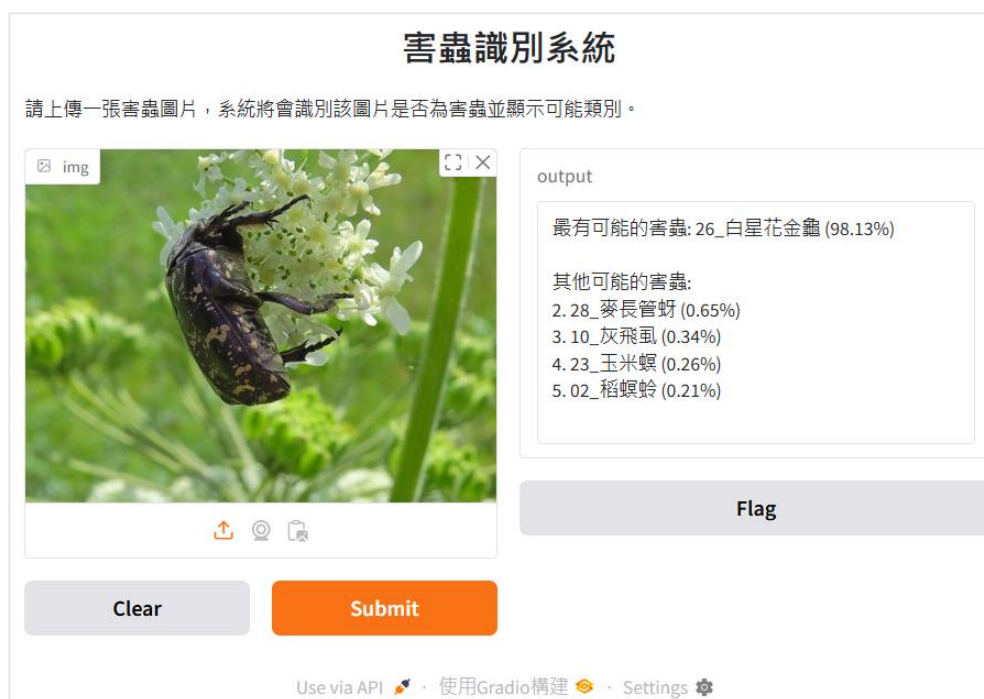


圖 5-10-1 電腦版(左)與手機版(右)的害蟲辨識介面

除了提供害蟲辨識結果，本系統亦整合「防治方法查詢」功能。當使用者確認系統辨識出的害蟲後，只需點擊「查詢防治方法」按鈕，系統便會根據該害蟲類別，自動顯示相對應的綜合防治建議。這些建議內容涵蓋生物防治、耕作管理、化學防治與環境調控等策略，針對每一種害蟲皆提供具體可行的田間管理措施。使用者無須額外查詢資料，即可快速掌握有效防

治對策，提升農業作業的效率與準確性，實現智慧農業的應用價值。

害蟲與防治查詢系統



圖 5-10-2 針對害蟲提供防治方法

實驗 11：自製捕蟲器以抓取害蟲




圖 5-11-1.鏡頭辨識以記錄害蟲

此捕蟲裝置的程式由 Python 撰寫，並使用 ESP32-CAM 進行辨識，10 秒偵測一次，當偵測到內部有害蟲時且準確率大於 0.7 時，會將記錄到的害蟲進行統計，並在完成後提供使用者長條圖及辨識出的物種清單。

陸、研究綜合討論

1. 為避免訓練與測試資料重疊導致的資訊洩漏，本研究額外建立一組全新測試集，並針對各模型進行泛化能力驗證，經過一系列的測試後，證實剔除拼接圖片、錯誤圖片、無目標照片、重複影像...等異常影像均能提升模型訓練準確度，其中又以重複影像的影像最大，拼接照片及無目標照片次之。原始數據集模型在未見過的全新測試集上的準確率僅為 48.30%，Test Loss 升高至 2.0060，驗證先前數據中重複圖片對模型產生過擬合的影響。而實驗 7（刪除重複圖片）在全新測試集上的表現提升至 54.66%，明顯優於對照組，顯示模型的泛化能力因資料清理而提升。資料擴增（實驗 8）在全新測試集上達到 85.11% 的準確率，顯示在資料經過妥善清理後，再透過擴增補足低樣本物種，能有效改善模型對於未見資料的辨識能力。

實驗名稱	操作方法	Accuracy	Test loss	全新測試集 Accuracy	全新測試集 Test Loss
原始數據集	-	50.36%	1.8223	48.30%	2.0060
實驗 3	刪除拼接圖片	51.85%	1.7698	51.02%	1.9565
實驗 4	刪除錯誤圖片	56.60%	1.6192	50.57%	1.9712
實驗 5	刪除無目標圖片	54.73%	1.6187	51.25%	1.9849
實驗 7	刪除重複圖片	50.03%	1.8898	54.66%	1.9651
實驗 8	數據集擴增	89.06%	0.5815	85.11%	1.8907

2. 我們花了非常多的時間進行照片的分類，預期進行修正之後對實驗結果會有大幅度的變化。做完實驗後，可以發現若單純刪除特定照片，對準確度提升沒有太大的幫助，如刪除無目標圖片後準確率僅上升 4.37。但如果將不符合標準的照片逐一刪除，只保留正確的成蟲及幼蟲，正確率會提升至 62.37，成長的幅度大約為 23%。
3. 在進行資料清理之後，我們進一步檢查了重複的照片，發現這之中竟然有 36% 的重複照片，這些照片有一樣的蟲體，只差在浮水印的不同。在做完測試之後，我們發現沒有資訊洩漏的問題只會些微降低正確率，比預期中的好很多。
4. 原始數據集的品質並不優良，因此我們希望能從特定網站中新增品質較為優良的物種樣本，藉此提高模型訓練表現，每個物種僅增加了約 200 張圖片後準確率就提升了 9%，可知這個方法能夠有效的優化模型辨識表現，未來可繼續擴增。
5. 發現某些物種不管在進行哪個實驗時辨識的結果都很理想，如物種 74 柑橘鳳蝶、83 黑

刺粉虱，觀察這些物種後，發現這些物種在資料集中的樣本都非常清晰，不利於模型學習的樣本較少，且物種本身都具有較明顯的特徵，因此能推測如果能將所有物種的樣本都提升到這樣的水準，就能大幅提升模型辨識的表現。



6. 圖中呈現為本研究中各分類物種在資料處理前後的樣本數變化情形，橫軸為物種分類編號，縱軸為對應樣本數。從圖中可見，**原始資料集（灰色長條）**存在明顯的樣本數不平衡問題，**部分物種如編號 68 樣本數有 5310 張**遠高於其他物種，而低樣本物種的資料量則相對稀少，如物種 54 卻只有 177 張，對模型訓練構成潛在偏誤風險。在進行資料清理（綠色長條）後，整體樣本數略有下降，顯示原始資料中包含許多拼接影像、分類錯誤、無目標或重複圖片，這些低品質資料若未排除，將會降低模型辨識效能。因此透過人工分類與程式輔助清洗，有效提升資料品質。接續透過資料擴增（黃色長條），從 GBIF 與 iNaturalist 等開放資源補充圖片，尤其針對樣本較少的物種進行補強。雖無法達成完全均衡，但整體樣本分佈已顯著改善，有助於模型訓練時提升各類別的辨識公平性與穩定性。




圖 6-1-1. 各分類物種在資料處理前後的樣本數變化情形

柒、研究結論

1. 本研究所使用的原始數據集整體品質參差不齊，平均異常影像比例高達 32.35%。部分物種資料中錯誤標記比例過高，顯示進行人工分類與品質篩選為必要前處理步驟。
2. 樣本數量對模型辨識能力具有顯著影響，較多樣本能提升模型對害蟲物種的辨識準確性與穩定性。
3. 移除拼接圖片後雖略有提升準確率，但幅度有限，主因為該類圖片僅占整體資料集的 5.7%。
4. 刪除錯誤圖片後，模型準確率由 50.36% 提升至 56.60%，損失值(Test Loss)由 1.8223 降至 1.6192，證實此清理步驟有助於提升模型表現。
5. 移除無目標圖片同樣有效提升模型效能，準確率由 50.36% 提升至 57.43%，損失值降至 1.6087，顯示減少干擾資訊可改善模型分類準確性。
6. 在 23,475 張成蟲與幼蟲影像中，約有 8,584 張與同類別圖片高度相似，重複率達 33%，顯示原始數據集中存在大量冗餘影像，有潛在模型過擬合問題。
7. 高比例重複圖片可能導致資訊洩漏問題，使訓練與測試集之間出現重疊，進而造成模型準確率的非真實性提升。
8. 成蟲與幼蟲合併訓練組的圖片數量相對較多，且已移除部分干擾圖像，因此整體模型辨識精確率相較其他組別更為穩定且優異。
9. 經資料清理與擴增處理後，模型在原始與全新測試集上皆顯著提升分類準確率，證實擴充數據集對改善模型表現具有正向效果。
10. 利用 Grad-CAM 可視化技術分析模型特徵提取重點，發現模型在辨識過程中多聚焦於害蟲主要形態區域，如身體輪廓位置，若模型錯誤聚焦於背景作物則易辨識錯誤。
11. 本研究成功建構可操作之害蟲辨識介面，使用者可透過拍照或上傳影像並點擊提交，即可快速獲得模型預測之害蟲名稱與辨識結果。

捌、參考資料

1. Liu, H., Chen, Y., Zhang, M., & Yang, H. (2019). A large-scale benchmark dataset for insect pest recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
2. Zhang, Y., Zhang, J., Liu, Y., & Wang, L. (2022). Crop pest recognition in real agricultural environment using convolutional neural networks by a parallel attention mechanism. *Frontiers in Plant Science*, 13.
3. Lin, C. H. (2021). 利用深度學習提升蔬菜蟲害辨識之研究 (Master's thesis). 臺灣博碩士論文知識加值系統.
4. Lee, L. (2020). Inception 系列—InceptionV2, InceptionV3. *Medium*. <https://reurl.cc/VY3qqb>
5. Lynn. (2016). 人工智慧的黃金年代：機器學習. *StockFeel*. <https://reurl.cc/qGm34D>
6. Lin, C. H. (2023). 機器學習任務分類、訓練測試集. *Medium*. <https://reurl.cc/6KyeYk>

圖片來源

1. 引自 Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the inception architecture for computer vision. arXiv. <https://doi.org/10.48550/arXiv.1512.00567>
2. 引自 Lin, C.-J., & Jhang, J.-Y. (2021). Bearing fault diagnosis using a Grad-CAM-based convolutional neuro-fuzzy network. *Mathematics*, 9(13), 1502. <https://doi.org/10.3390/math9131502>
3. 引自郭耀文.圖像相似度算法 (Google 以圖搜圖) 2：Hash Algorithm、Hamming distance 哈希演算法. *Medium*. <https://reurl.cc/YYWD5o>

【評語】 032822

系統性地處理影像辨識資料問題，說明資料清理對於影像辨識的重要，並成功提高辨識率，但是對於本研究布署之後的實際作用探討略嫌不足。建議未來研究可以強化在地化應用與實際系統的整合，實地分析害蟲影像，提升實務價值。

作品海報



危機蟲蟲



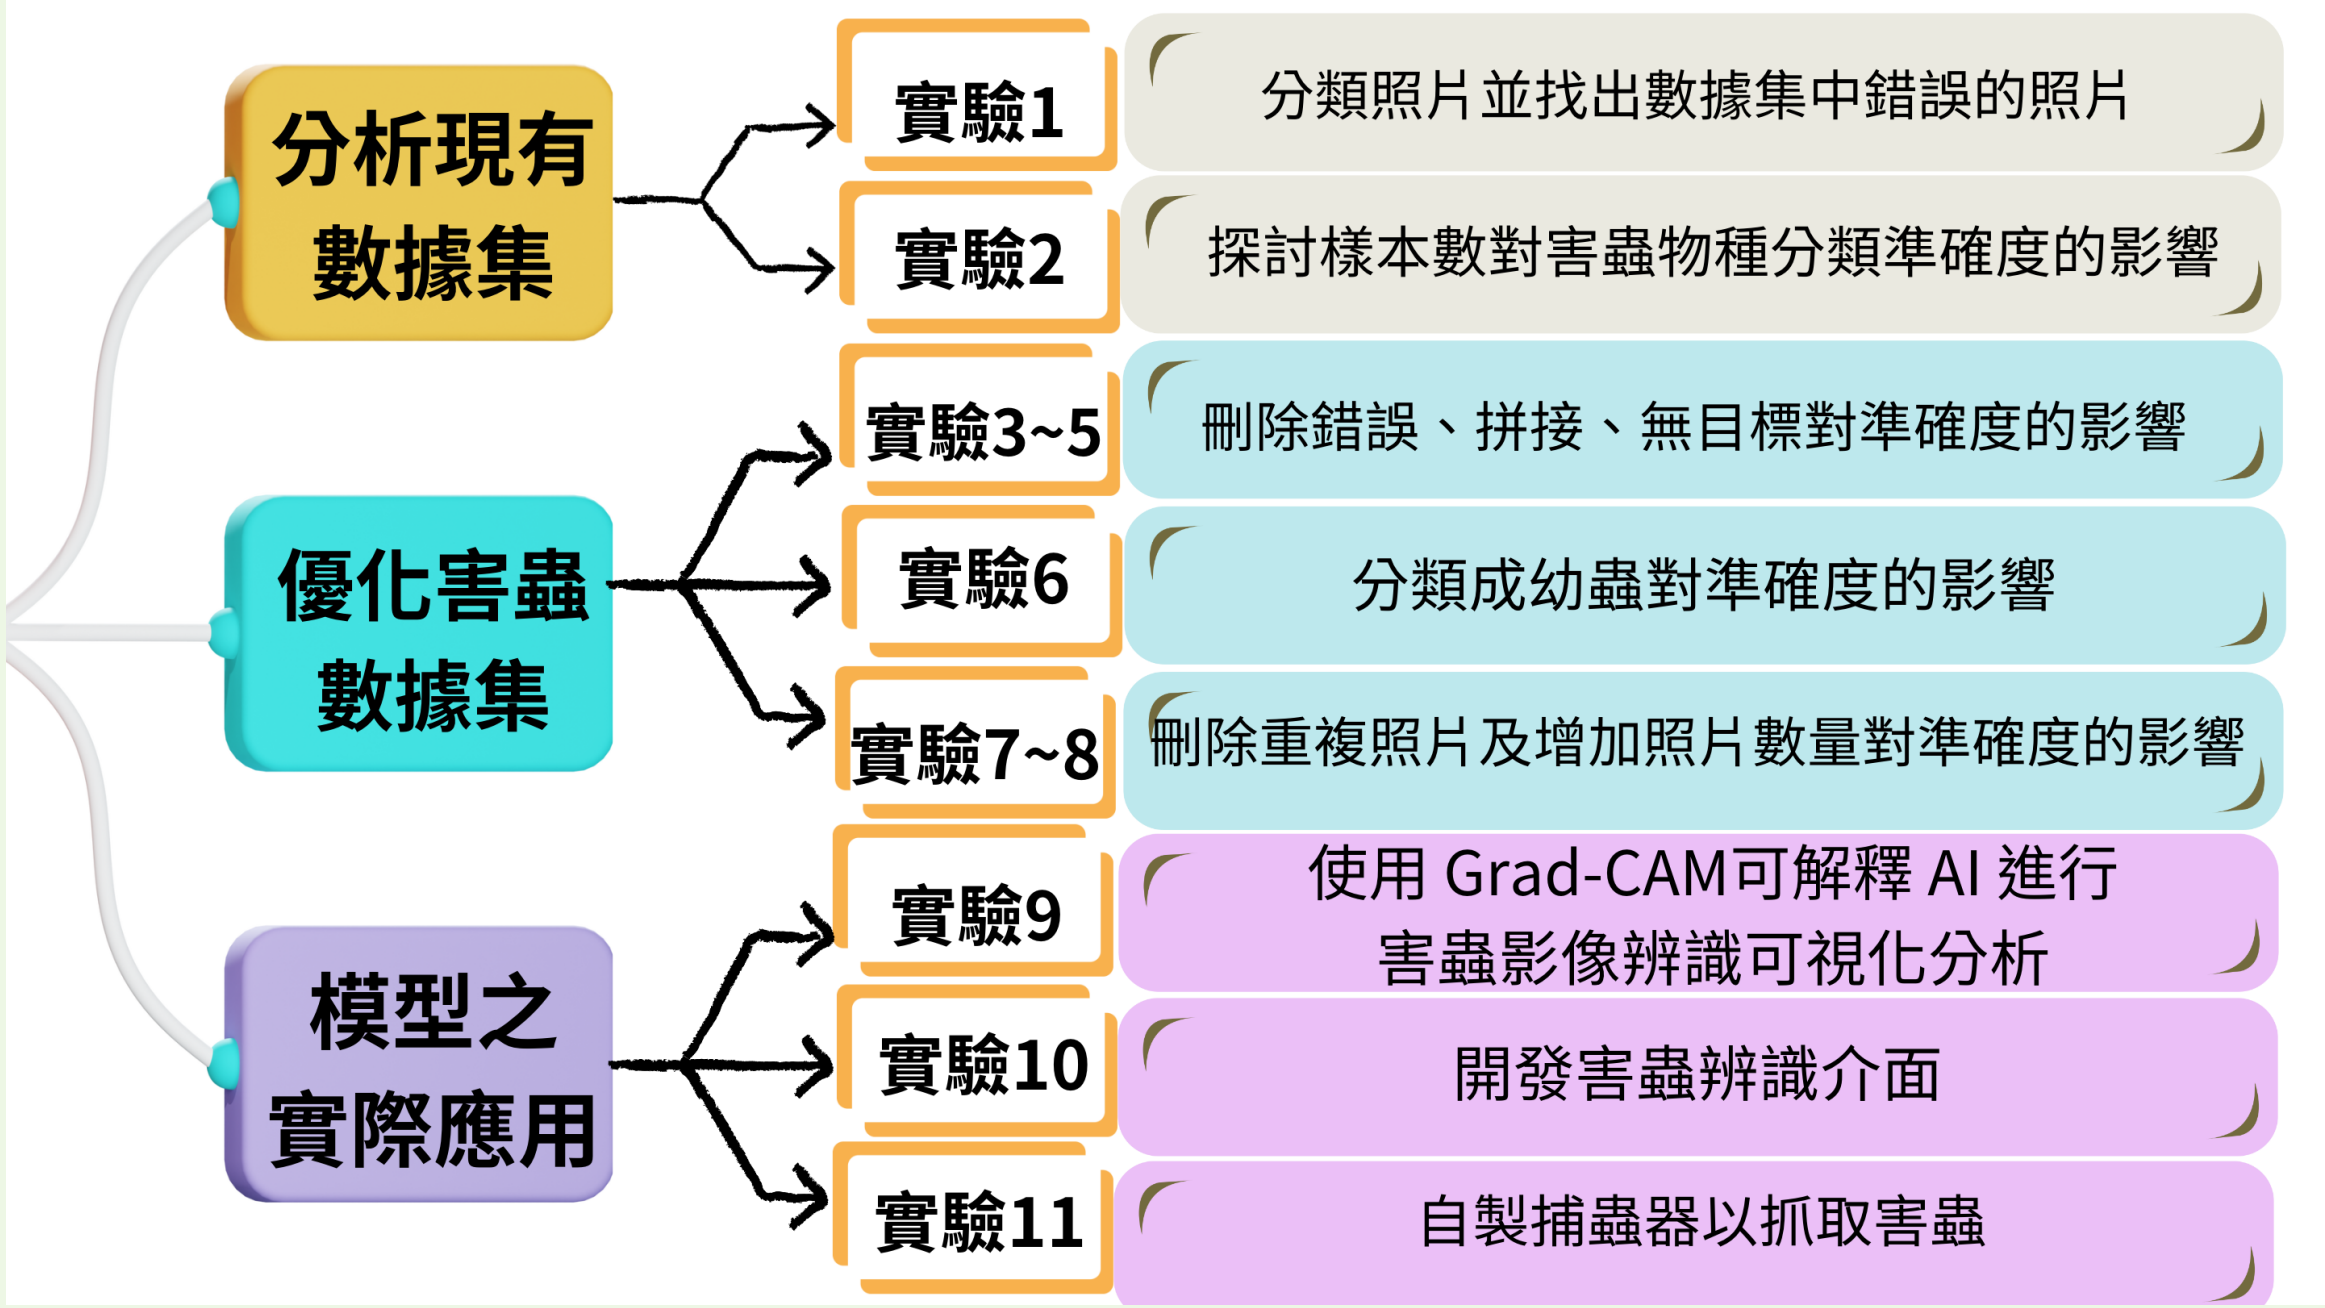
基於 Inception v3 的害蟲影像辨識與數據優化研究

摘要

本研究針對農業害蟲辨識數據集的優化進行探討，旨在提高深度學習模型的辨識準確度。隨著科技進步，人工智慧在害蟲識別中愈發重要，但現有數據集面臨數據品質不良、樣本偏差和錯誤標註等問題，影響模型的可靠性。研究主要分為三個部分：首先分析現有數據集，探討樣本數對分類準確度的影響;其次優化數據集，通過刪除拼接和錯誤圖片、重複圖片等，提升數據質量；最後實際應用模型，開發一套害蟲辨識系統。實驗結果顯示，增加樣本數和改善數據質量顯著提升了模型的準確率，並且開發的介面可協助用戶即時識別害蟲。整體而言，本研究不僅提高了農作物的病蟲害防治效率，還為未來的害蟲識別技術提供了有價值的參考。

研究過程與方法


研究架構



研究原理

(一) InceptionV3

由 Google 開發的深度卷積神經網路(CNN)，以高效的計算能力和出色的性能著稱，特別在圖像分類和物體檢測中表現優異。



圖片來源:https://reurl.cc/AMgn3e

名詞定義

正確圖片



物種01稻縱卷葉螟

(一)錯誤圖片

圖片標記物種和實際物種不相符



(一)錯誤圖片

(二)拼接圖片

圖片為多張影像拼接在一起，包含許多不同的蟲體



(二)拼接圖片

(三)無目標圖片


圖片中沒有昆蟲的照片



(三)無目標圖片

研究結果


實驗1：數據集分類及資料分析




各物種資料的整體品質落差明顯，部分物種(如編號 15、17、74)具高比例的正確資料，然而也有數個物種中異常圖片的比例明顯高，甚至超過原始資料的一半，例如物種12(錯誤 41.9%)、28(拼接44.3%)。平均錯誤圖片 13.04%、拼接照片 5.69%、無目標 13.62%，正確比例67.65%，反映出這些物種的資料來源可能存在混雜問題，釐清了原始數據的品質分佈，也為後續實驗提供了明確依據。

實驗2：探討樣本數對害蟲分類準確度的影響



發現樣本數越多，準確率呈現上升趨勢，而損失值則呈現下降趨勢，顯示其辨識效果有所提升



實驗3：刪除拼接圖片對模型準確度的影響




將「拼接照片」刪除後，準確率從50.36%微幅上升到53.05%，而損失值從1.8223降至1.7189，可發現將「拼接圖片」刪除，雖然能讓準確率提高，但上升幅度不大。




其中有一些精確率高但確率卻很低的種類，表示說召回率低的物種例如：物種這代表模型對該物種的判斷1(稻縱卷葉螟)召回率高精能力良好。

實驗4：刪除錯誤圖片對模型準確度的影響




透過上方的圖片可以發現，在原始的數據集中刪除「錯誤圖片」後，讓數據集分類更加明確，使辨識的準確率提高從原本的50.36%提升至56.60%且損失值從1.8223降低至1.6192，證明刪除錯誤圖片能夠提升辨識結果。




分析精確率，可發現某些物種的精確率特別高如第57(東方菜粉蝶)、74(柑橘蝶)、83(黑刺粉虱)、100(脊胸天牛)種皆有80%以上，觀察後發現物種57(東方菜粉蝶)及74(柑橘蝶)中的樣本都較其他物種清晰且單一不混雜，物種83及100則是昆蟲形體特殊且特徵較明顯。另外第68種的召回率高於精確率，推測是因為樣本數量太多，約有5300多個樣本，多於平均的780個，導致許多其他的物種被錯分到此種內。

實驗5：刪除無目標圖片對模型準確度的影響




透過上方的圖片可以發現，由於需刪除照片在數據集中的平均中大約為15%，在原始的數據集中刪除「無目標圖片」後，讓數據集分類更加明確，使辨識的準確率提高從原本的50.36%提升至57.43%且損失值從1.8223降低至1.6087，證明刪除錯誤圖片能夠提升辨識結果。






從細部來分析精確率，可發現某些物種的精確率特別高如：第57東方菜粉蝶、67葡萄天蛾、74柑橘鳳蝶、83黑刺粉虱、100褐緣蛾蠟蟬，他們大多具有鮮豔的顏色或外觀。在召回率方面，部分精確率高的物種，召回率卻較低，可以解釋為由於模型的決策門檻（Threshold）設置較高，導致模型傾向於只標記那些模型高度確信的正例。第57種則是精確率高召回率也高，代表該物種易於分類，且不易把其他物種錯分到此物種內，利於辨識。

實驗6：幼蟲與成蟲分類對模型準確度的影響




成蟲的分類準確率最高且損失值最低，這可能是由於成蟲在形態上具有較為明顯的特徵差異；幼蟲的外觀相對類似，導致分類準確率較低；結果較不具辨識性成蟲與幼蟲的數據合併進行分類時，準確率介於兩者之間




幼蟲分類的精確率整體偏低，主要原因是不同物種間幼蟲在外觀上變異較小，模型較容易誤將其他物種錯判為目標類別，造成準確率偏低。成蟲在形態、顏色、翅膀等外部特徵上具有較高辨識性，模型在面對成蟲影像時能更穩定地對應正確分類。成蟲與幼蟲合併訓練的精確率介於兩者之間，但略偏向成蟲表現。

實驗7：刪除重複圖片對模型準確度的影響



在成蟲和幼蟲總共23,475張照片中，有8,584張照片與同物種中至少一張照片相似，大約為36.57%。




透過上方圖表可發現，實驗6的準確率從原本的50.36%降低至47.82%，損失值則升高至1.9929，我們認為在原本對照組中高比例的重複圖片恐造成資訊洩漏的問題，相同照片出現在訓練集和測試集，導致模型由於看過相同圖片而呈現出不實的高準確率。

利用「全新測試集」測驗後，結果顯示去除重複圖片不僅提升了模型的泛化能力，也讓模型表現更具代表性與可信度。

實驗8：數據集擴增對模型準確度的影響

從GBIF、iNaturalist新增10094張照片，準確率由62.37%提高至89.06%，損失值也從1.3887降低至0.5815。



實驗10：開發害蟲辨識介面

利用GRADIO介面與訓練好的模型做結合，使用者在拍攝或上傳圖片後點擊提交，系統就會辨識出最有可能的害蟲名稱，及其他四種可能性較低的物種。



實驗9：使用 Grad-CAM 可解釋性 AI 進行害蟲影像辨識可視化分析

	輸入影像	Grad-CAM 熱力圖	可視化結果分析
物種67 葡萄天蛾 錯誤分類✗			此照片的背景較為雜亂（落葉、泥土等），可能與其他昆蟲的背景相似，導致模型誤認。
物種67 葡萄天蛾 成功分類✓			當背景較為單純時，模型較能學習到昆蟲本身的形狀與特徵。
物種58 綠盲蝽 錯誤分類✗			紅、黃區域主要集中在背景花朵上，推測模型錯誤依賴背景來判斷導致錯誤。
物種58 綠盲蝽 成功分類✓			模型聚焦在昆蟲本體，特別是頭部，專注於昆蟲的特徵來進行分類，而非背景資訊。

實驗11：自製捕蟲器以抓取害蟲



討論

- 本研究額外建立一組全新測試集，並針對各模型進行泛化能力驗證，經過一系列的測試後，證實剔除拼接圖片、錯誤圖片、無目標照片、重複影像...等異常影像均能提升模型訓練準確度。資料擴增（實驗8）在全新測試集上達到 85.11% 的準確率，顯示在資料經過妥善清理後，再透過擴增補足低樣本物種，能有效改善模型對於未見資料的辨識能力。
- 原始數據集的品質並不優良，因此我們希望能從特定網站中新增品質較為優良的物種樣本，藉此提高模型訓練表現。每個物種僅增加了約200張圖片後，準確率就提升了9%，可知這個方法能夠有效的優化模型辨識表現，未來可繼續擴增。
- 在進行資料清理之後，我們進一步檢查了重複的照片，發現這之中竟然有36%的重複照片，在做完測試之後，我們發現沒有資訊洩漏的問題只會些微降低正確率，比預期中的好很多。

研究結論與應用

- 本研究使用的原始數據集整體平均異常圖比例高達 32.35%，顯示分類與品質篩選為必要處理步驟。
- 樣本數量對模型辨識能力具有顯著影響，較多樣本能提升模型對害蟲物種的辨識準確性與穩定性。
- 移除拼接圖片後準確率提升不明顯，主因為該類圖片僅占整體資料集的 5.7%。
- 刪除錯誤圖片後，對於模型的準確率提升、損失值下降，都有幫助。證實此實驗有助於模型準確率。
- 移除無目標圖片同樣有效提升模型效能，準確率提升，損失值下降，顯示減少干擾資訊可改善模型分類準確性。
- 在 23,475 張成蟲與幼蟲影像中有許多圖片高度相似，重複率達 33%，顯示原始數據集中存在大量冗餘影像，有潛在模型過擬合、資訊洩漏等問題，進而造成模型準確率的非真實性提升。
- 成蟲與幼蟲合併訓練組的圖片數量相對較多，且已移除部分干擾圖像，因此整體模型辨識精確率相較其他組別更為穩定且優異。
- 經資料清理與擴增處理後，模型在原始與全新測試集上皆顯著提升分類準確率，證實擴充數據集對改善模型表現具有正向效果。
- 利用 Grad-CAM 可視化技術分析模型特徵提取重點，發現模型在辨識過程中多聚焦於害蟲主要形態區域，如身體輪廓位置，若模型錯誤聚焦於背景作物則易辨識錯誤。
- 本研究成功建構可操作之害蟲辨識介面，使用者可透過拍照或上傳影像並點擊提交，即可快速獲得模型預測之害蟲名稱與辨識結果。

參考文獻

- Liu, H., Chen, Y., Zhang, M., & Yang, H. (2019). A large-scale benchmark dataset for insect pest recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Zhang, Y., Zhang, J., Liu, Y., & Wang, L. (2022). Crop pest recognition in real agricultural environment using convolutional neural networks by a parallel attention mechanism. *Frontiers in Plant Science*, 13.
- Lin, C. H. (2021). 利用深度學習提升蔬菜蟲害辨識之研究 (Master's thesis). 臺灣博碩士論文知識加值系統.