

國立臺灣大學生物資源暨農學院生物機電工程學系

碩士論文

Department of Biomechatronics Engineering

College of Bioresources and Agriculture

National Taiwan University

Master Thesis



溫室微型害蟲辨識系統之優化與線上自主學習架構之
研究

Optimization and Development of an
Online Self-Learning Framework
for Greenhouse Insect Pest Classification System

陳璟寬

Ching-Kuang Chen

指導教授：林達德 博士

Advisor: Ta-Te Lin, Ph.D.

中華民國 112 年 07 月

July 2023

誌謝



回首碩士班兩年的生涯，最要感謝的是我的指導老師：林達德教授，從碩零開始，不論是在學術研究、待人處事方面或是未來的人生方向。感謝您不厭其煩的在每一次 meeting 中給予指導，感謝您在我研究迷失時指點我應該前往的方向。若沒有您，我也不可能會完成這本碩士論文，由衷的感謝。

接下來要感謝我的碩士班同學：少政和軍諺，從剛進實驗室的陌生到即將畢業的不捨，能與你們一起在碩士這條路上打拼，讓我在研究所的生活中增添了許多美好回憶。還有先行畢業的承穎，願你在天上也能好好的。

感謝害蟲計畫的夥伴：欣正學長、麟雅學姊還有乙澤學長，有你們的協助我才能順利完成實驗研究。特別感謝學弟喬尹，在每一次出差的準備與協助，準備成為害蟲計畫的扛霸子，願你堅強。也謝謝 BBLAB 405 的夥伴，Longmen、桂枝、敬恆、化達、浩平、晨宇以及易霖，大家互相幫助一起成長，祝福你們在未來的路上也能順利。

感謝我的家人：在天上的阿公炳煌，在我小時候告訴我要好好念書，也謝謝您對我從小的疼愛，同樣感謝在天上的外婆惠嬌，也請您持續守護著您最愛的我們。謝謝我的阿嬤靜子、父母紹釗、采宣和姑姑秀珍，您們從小拉拔我到大，無憂無慮的做我想做的事情，然後健康的成長。謝謝姐姐靖惠，在我上北部讀書時對我的照顧。謝謝在天上當天使的帥哥還有小可愛嚕咪在我回台中時給我的陪伴。最後謝謝女友心柔，一起在台大讀研究所並互相扶持陪伴，給予我往前進的力量。沒有家人的照顧與支持，我是沒有辦法堅持走到這的，在此獻上誠摯的感謝。

最後謝謝我的口試委員：謝廣文老師和陳世芳老師，不吝嗇地分享您們的專業知識和經驗，讓我受益良多，也讓我的論文能夠更加的完善。由衷的感謝這一路上所受到的幫助，要感謝的人太多了，族繁不及備載，那只好謝謝當初不放棄的自己，也願愛我的人及我所愛的人能平安健康。

摘要



在作物生長期間，蟲害被認為是對農業生產的最大威脅之一。它們危害農作物的生長，降低產量，對農業經濟收益造成嚴重損失。因此，有效管理蟲害的發生，對於農業從業者至關重要。若想要達到有效管理的目標，需要透過即時且準確的害蟲種類和數量數據，擬定正確的管理對策。本研究室先前已開發出一套基於物聯網技術的智慧型蟲害管理系統(intelligent integrated pest and disease management, I²PDM)，使用相機拍攝黏蟲紙，並利用深度學習辨識害蟲種類與數量。本研究目的為優化 I²PDM 系統中所使用的害蟲辨識模型，使其提供更準確的蟲害資訊，我們使用 SRGAN 影像增強模型，用於強化害蟲影像的視覺特徵。同時，將害蟲的尺寸納入分類模型中提供額外的資訊，以提高辨識的準確性。以影像增強、尺寸特徵與兩者結合的方法，提出三種新的模型架構，相比於原始的架構，經過優化後的模型分別能提升約 2.7%、2.3%與 4.4%的 F₁-score。此外，我們提出一套自動化線上自主學習架構，利用 I²PDM 系統數據流的優勢，持續收集更多的害蟲影像擴增訓練集，再利用新影像對基礎模型進行優化訓練，用以解決傳統資料收集與訓練模型所需的大量人力與時間。並且透過樣本清理演算法，搭配高斯混合模型對新進樣本進行篩選，確保新收集之樣本正確性，以及與正確樣本之間的特徵相似性，實現自動化樣本收集和模型再訓練的流程。測試結果顯示，在使用三年資料與四種不同基礎模型的情境下，其最終模型都能有效提升約 2.6% 到 5.8% 的水準。後續利用 MQTT、ZMQ 與 TCP 等網路傳輸協議，將線上自主學習架構實際部署到 I²PDM 系統中。經使用五個月的資料進行測試比較，與基礎模型相比可達 2.7% 的效能提升。除軟體優化外，本研究亦進行硬體升級，以使用 Arducam 64MP 替換原有的 Raspberry pi camera v2 相機模組，最終得到約 2 倍 DPI 的影像，取得更細微的害蟲特徵，測試結果顯示，使用新相機所訓練的分類模型相比使用原始相機，約有 4.4% 的 F₁-score 提升。

關鍵詞：病蟲害整合管理、影像增強、手工特徵、線上自主學習、害蟲分類模型

Abstract



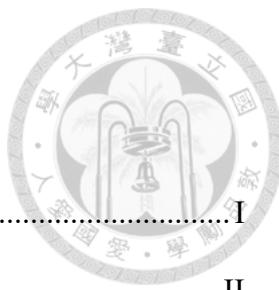
During crop growth, pests are considered one of the biggest threats to agricultural production. They damage crop growth, reduce yields, and cause significant economic losses to the agricultural industry. Therefore, effective management of pest occurrence is crucial for agricultural practitioners. To achieve effective management goals, accurate and real-time data on pest species and quantities are needed to formulate appropriate management strategies. Our research laboratory has previously developed an Intelligent Integrated Pest and Disease Management (I^2PDM) system, which utilizes cameras to capture images of sticky traps and employs deep learning to identify pest species and quantities. The objective of this study is to optimize the pest recognition model used in the I^2PDM system to provide more accurate pest information. We employ the SRGAN image enhancement model to enhance the visual features of pest images. Additionally, we incorporate the size of pests into the classification model to provide additional information for improved recognition accuracy. Three new model architectures are proposed using image enhancement, size features, and a combination of both, which achieve F_1 -score improvements of approximately 2.7%, 2.3%, and 4.4%, respectively, compared to the original architecture. Furthermore, we propose an automated online self-learning framework that leverages the data flow of the I^2PDM system to continuously collect more pest images for augmented training sets and optimize the base model through retraining with new images. This approach solves the challenges of traditional data collection and the significant manpower and time required for model training. By utilizing a sample cleaning algorithm with a Gaussian Mixture Model, the newly collected samples are filtered to ensure their correctness and feature similarity with correct samples. This automated process of sample collection and model retraining is achieved. With three years of data and four different base models, the final models show effective improvements ranging from approximately 2.6% to 5.8%. The online self-learning framework is deployed in the I^2PDM system using network transmission protocols such as MQTT, ZMQ, and TCP. Through a five-month data test, it shows a 2.7% performance improvement compared to the base models. In addition to software optimization, we also upgraded the hardware by replacing the original Raspberry Pi Camera V2 module with the Arducam 64MP camera module, resulting in images with approximately twice the DPI. This upgrade captures finer pest features. The test results indicate a 4.4%

improvement of the F₁-score when using the model trained with the new camera compared to the model trained with the original camera.

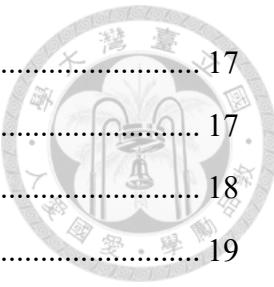
Keywords: integrated pest management, image enhancement, hand-crafted features, online learning, insect pest classification



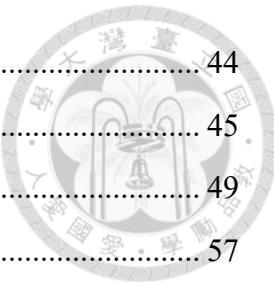
目錄



誌謝	I
摘要	II
Abstract.....	iii
圖目錄	viii
表目錄	xii
第一章 緒論	1
1.1 前言	1
1.2 研究目的	2
第二章 文獻探討	4
2.1 基於影像的昆蟲辨識方法	4
2.1.1 影像處理應用於昆蟲辨識	4
2.1.3 機器學習應用於昆蟲辨識	5
2.1.2 深度學習應用於昆蟲辨識	6
2.2 影像增強技術	8
2.2.1 深度學習應用於影像增強	8
2.2.2 影像增強模型應用於農業影像辨識	9
2.3 手工特徵 (Handcrafted Features)	10
2.3.1 結合手工特徵和深度學習之方法	10
2.3.2 手工特徵應用於深度學習模型	11
2.4 線上學習方法回顧	13
2.4.1 連續神經網路學習 (Continuous Neural Network Learning)	13
2.4.2 線上學習與其應用	13
第三章 研究方法	16
3.1 研究架構	16



3.2 害蟲分類模型之優化	17
3.2.1 原始害蟲分類模型	17
3.2.2 影像增強分類模型	18
3.2.3 手工特徵融合於害蟲分類模型	19
3.2.4 影像增強結合手工特徵分類模型	22
3.3 模型訓練與評估	22
3.3.1 起始模型建立	23
3.3.2 分類模型效能檢定	23
3.3.3 影像增強模型訓練與評估	25
3.4 線上自主學習框架	27
3.4.1 自動害蟲影像收集	28
3.4.2 害蟲樣本清理流程	29
3.4.3 模型再訓練與模型更新	30
3.5 實驗場域與害蟲影像資料集	31
3.5.1 害蟲標的	31
3.5.2 害蟲影像資料集	32
3.6 I ² PDM 相機模組升級	34
3.6.1 相機模組	34
3.6.2 原始相機與高解析度相機分類模型測試	34
第四章 結果與討論	35
4.1 影像增強模型訓練結果	35
4.1.1 初步實驗結果	35
4.1.2 影像增強方法	36
4.1.3 樣本數對於影像增強模型評估結果	38
4.2 深度學習模型訓練結果	40
4.2.1 原始模型訓練結果	40
4.2.2 影像增強分類模型訓練結果	41
4.2.3 手工特徵分類模型訓練結果	42
4.2.4 影像增強結合手工特徵分類模型訓練結果	43



4.3 線上自主學習	44
4.3.1 樣本清理參數選擇	45
4.3.2 線上自主學習迭代訓練結果	49
4.3.3 動態樣本測試結果	57
4.3.4 樣本清理演算法探討	62
4.4 線上自主學習部署於 I ² PDM 系統	66
4.4.1 基礎模型訓練結果	67
4.4.2 程式架構	67
4.4.3 實際部署運作結果	68
4.5 相機模組升級結果	72
4.5.1 實際拍攝結果與延長支架設計	72
4.5.2 分類模型測試結果	75
第五章 結論與建議	78
5.1 結論	78
5.2 建議	80
參考文獻	81

圖目錄



圖 2-1 手工特徵注入位置 (a)位置 1：Convolution、Residual 與 Dense 模塊；(b) 位 置 2：基於 CNN 的特徵的一維向量層；(c) 位置 3：內部全連接層；(d) 位置 4：最終的全連接層(Zhang and Zhang, 2021)。	12
圖 2-2 線上學習架構圖 (Hoi et al., 2021).....	14
圖 3-1 研究架構圖	16
圖 3-2 ResNet 所使用之 (a)殘差模塊；與 (b)模型結構圖(He et al., 2016).....	18
圖 3-3 昆蟲影像結合 SRGAN 之模型架構示意圖	19
圖 3-4 影像增強分類模型實際應用流程	19
圖 3-5 分類模型經常因為 (a)不同種類的害蟲仍存在型態相似的個體，而造成誤 判，即使我們發現到 (b)各類別間實際的害蟲尺寸具有明顯的差異.....	20
圖 3-6 尺寸特徵手工提取流程	21
圖 3-7 手工特徵分類模型流程圖	21
圖 3-8 影像增強結合手工特徵分類模型流程圖	22
圖 3-9 原始 128 x 128 像素之影像經由雙三次插值法下採樣為 32 x 32 像素之影 像，建立成對害蟲樣本數據集，用於 SRGAN 模型訓練使用	25
圖 3-10 線上自主學習流程圖	28
圖 3-11 本實驗室前期所發展之 (a)I ² PDM 無線取像裝置；與 (b) 其 YOLO 物件偵 測模型辨識結果	29
圖 3-12 樣本清理流程	30
圖 3-13 模型更新流程圖	31
圖 3-14 各種類害蟲典型的型態	32
圖 4-1 初步結果顯示因粉蟲的體色造成 SRGAN 增強效果較差，在其身體與背景 皆呈現不自然的黑色躁點	35
圖 4-2 修改後的影像增強分類模型流程圖，增加二分類模型區分粉蟲及其他類 別，以符合 SRGAN 之訓練類別	36



圖 4-3 影像增強結果：(a)原始影像；(c)以 32 x 32 像素為輸入；(e)以 128x128 像素作為輸入；與 (b)、(d)和(f)對應之 Sobel 濾波器處理後之結果，顯示出經過改良後的方法能得到更清晰的增強影像	37
圖 4-4 Tenengrade 影像清晰度計算結果 (a)全部五種類；(b)蠅；(c)蕈蠅；(e)蠻；(d)蕈蚋；與 (f)薊馬	38
圖 4-5 不同訓練樣本數對於影像增強後的測試結果，顯示當各類別樣本數超過 350 張後，對於增加影像增強的效果已經達到飽和	39
圖 4-6 不同訓練樣本的影像增強結果，顯示在訓練樣本數較少的影像中背景有較多雜訊，隨著樣本增加，雜訊逐漸減少	39
圖 4-7 原始模型測試結果	40
圖 4-8 影像增強分類模型測試結果	41
圖 4-9 尺寸特徵分類模型測試結果	42
圖 4-10 手工擷取尺寸特徵分布	43
圖 4-11 影像增強結合尺寸特徵分類模型測試結果	43
圖 4-12 PCA 維度與累積解釋方差比與輪廓係數的趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與(d) Model A4，顯示當降為四個維度時有最好的表現	45
圖 4-13 害蟲訓練集的對數機率分布圖與第十百分位數示意線：(a)蠅；(b)蕈蠅；(c)蠻；(d)蕈蚋；與 (e)薊馬	46
圖 4-14 不同閥值對於樣本數量和準確率趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4	47
圖 4-15 經正規化後不同閥值對於樣本數量和準確率趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4	47
圖 4-16 經微分後不同閥值對於樣本數量和準確率趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4	48
圖 4-17 不同閥值對於 Increasing rate 的趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4	48
圖 4-18 使用 Model A1 進行 (a)線上自主學習；與 (b)監督式線上學習之結果	50
圖 4-19 Model A1 經 (a)線上自主學習；與 (b)監督式學習的最終模型測試結果 ...	51



圖 4-20 使用 Model A2 進行 (a)線上自主學習；與 (b)監督式線上學習之結果.....	52
圖 4-21 Model A2 經 (a)線上自主學習；與 (b)監督式學習的最終模型測試結果... ..	53
圖 4-22 使用 Model A3 進行 (a)線上自主學習；與 (b)監督式線上學習之結果.....	54
圖 4-23 Model A3 經(a)線上自主學習；與(b)監督式學習的最終模型測試結果.....	55
圖 4-24 使用 Model A4 進行 (a)線上自主學習；與 (b)監督式線上學習之結果.....	56
圖 4-25 Model A4 經 (a)線上自主學習；與 (b)監督式學習的最終模型測試結果... ..	57
圖 4-26 Model A1 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠻；(e)	
蕈蚋；與 (f)薊馬	58
圖 4-27 Model A2 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠻；(e)	
蕈蚋；與 (f)薊馬	59
圖 4-28 Model A3 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠻；(e)	
蕈蚋；與 (f)薊馬	60
圖 4-29 Model A4 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠻；(e)	
蕈蚋；與 (f)薊馬	61
圖 4-30 經由樣本清理演算法所得到之樣本 (a)Precision；與 (b)Missing rate	63
圖 4-31 僅使用分類模型收集新樣本的準確率低於使用樣本清理演算法	63
圖 4-32 使用 Model A1 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平	
均；(b)蠅；(c)蕈蠅；(d)蠻；(e)蕈蚋；與 (f)薊馬	64
圖 4-33 使用 Model A2 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平	
均；(b)蠅；(c)蕈蠅；(d)蠻；(e)蕈蚋；與 (f)薊馬	64
圖 4-34 使用 Model A3 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平	
均；(b)蠅；(c)蕈蠅；(d)蠻；(e)蕈蚋；與 (f)薊馬	65
圖 4-35 使用 Model A4 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平	
均；(b)蠅；(c)蕈蠅；(d)蠻；(e)蕈蚋；與 (f)薊馬	65
圖 4-36 Model B 基礎模型測試結果.....	67
圖 4-37 線上自主學習實際部署架構圖	68
圖 4-38 線上自主學習演算法部署於 I ² PDM 系統迭代訓練結果：(a)七種類平均；	
(b)大蚊；(c)蠅；(d)蕈蠅；(e)蠻；(f)蚊；(g)蕈蚋；與(h)薊馬	70
圖 4-39 Model B 經過線上自主學習的最終模型測試結果	71



圖 4-40 Model B 之動態樣本測試結果	71
圖 4-41 使用不同相機拍攝之黏蟲紙影像，使用 (a)原始相機；與 (b)Arducam 64MP 相機的拍攝結果，經過相機更新後，在焦點附近可拍攝到更清楚的細節，而焦點外的昆蟲會呈現失焦的狀態	73
圖 4-42 相機工作距離示意圖：(a)原始的黏蟲紙支架工作距離約 10 cm；(b)安裝延長支架後將工作距離延長到 14cm	73
圖 4-43 使用相同相機在不同工作距離時所拍攝之黏蟲紙影像，當工作距離為 (a)10cm；與 (b) 14cm，延長工作距離可加大其清楚對焦的範圍	74
圖 4-44 使用原始相機 (a) (c)；與 Arducam 64MP 相機 (b) (d)在昆蟲身體細節上的表現，結果顯示更新相機能捕捉到昆蟲更細節的特徵	74
圖 4-45 不同相機拍攝之害蟲影像：(a)原始相機；(b)Arducam 64MP	75
圖 4-46 不同相機所拍攝之害蟲影像清晰度計算結果，顯示更新相機後能顯著提升影像清晰度	76
圖 4-47 Model C1 測試結果	76
圖 4-48 Model C2 測試結果	77

表目錄



表 3-1 ResNet-18 訓練參數	23
表 3-2 McNemar 統計列聯表	24
表 3-3 SRGAN 影像增強模型的訓練與測試資料集統計	33
表 3-4 害蟲分類模型的訓練、驗證和測試資料集數量統計	33
表 3-5 相機參數對照表	34
表 4-1 使用於線上自主學習的基礎模型代號與其架構	44
表 4-2 Model A1 動態樣本測試之配對 t 檢定統計結果	59
表 4-3 Model A2 動態樣本測試之配對 t 檢定統計結果	60
表 4-4 Model A3 動態樣本測試之配對 t 檢定統計結果	61
表 4-5 Model A4 動態樣本測試之配對 t 檢定統計結果	62
表 4-6 經由線上自主學習最終所收集之樣本數量與準確率	66
表 4-7 線上自主學習演算法部署於 I ² PDM 系統所收集之樣本數量和準確率	69
表 4-8 Model B 動態樣本測試之配對 t 檢定統計結果	72



第一章 緒論

1.1 前言

農業在人類歷史上扮演極其重要的角色，不僅為人類提供食物和糧食，並且是許多國家的重要經濟支柱，根據聯合國糧食及農業組織 (food and agriculture organization of the United Nations, FAO)統計，2022 年全球農業產值達到 3.6 兆美元，農業從業人數為 8.66 億，佔全球勞動力的 27%。隨著氣候變遷、人口增長與糧食危機，農業生產面臨的挑戰也越來越多。其中，蟲害被認為是對農業生產的最大威脅之一。因為它們會危害農作物的生長，降低產量，並且對經濟收益造成嚴重損失 (Thomas, 1999)。研究指出巴西農業面生產遭受害蟲和疾病的嚴重損失，其中以昆蟲害蟲的損失對主要作物生產的影響最為嚴重，並且估算這些損失對巴西經濟的影響。研究發現，害蟲平均每年造成巴西農業生產 7.7% 的損失，相當於減少約 2500 萬噸的食物、纖維和生物燃料的生產，而這些損失對經濟的總損失約為 177 億美元 (Oliveira et al., 2014)。因此，控制和防治蟲害是農業生產中的一個重要問題。有效的控制蟲害的發生頻率，可以減少作物產量的損失並提升收益 (Oerke, 2005)。

「病蟲害整合管理」(integrated pest management, IPM)是一個重要的概念。它指的是透過多種手段對蟲害進行控制和防治，包括監測、生物防治、化學防治等多種方法。與傳統僅使用大量農藥不同，IPM 的實施強調於對環境友好的管理方法，能夠有效地減少蟲害對作物的損害，同時提高作物的產量和品質 (Kogan, 1998)。隨著 IPM 概念的出現，也漸漸出現許多種實施 IPM 的方法 (Ehler, 2006)，其中最直接的方法就是監測作物中的蟲害發生情況，並給予相對應的管理對策，例如適量噴灑農藥、天敵防治 (Picanço et al., 2007)。傳統上，蟲害的檢測和防治主要依賴人工定時的巡檢，這種方式存在著時間和人力成本高昂的問題。為解決這些問題，近年開始導入物聯網系統，並整合環境感測器、相機、嵌入式系統、害蟲辨識等技術，提供農業從業人員即時的溫室環境資訊，逐漸實現溫室或蟲害管理的自動化和智慧化 (Aiello et al., 2018; Azfar et al., 2018; Espinoza et al., 2016)。

隨著人工智慧技術的不斷發展，深度學習技術作為其中的一種重要應用，逐漸受到各行各業的關注和探索。在這其中，深度學習技術在害蟲辨識方面的應用特別受到矚目。利用深度學習技術，機器能夠從大量的數據中學習和識別害蟲的特徵，準確地進行害蟲辨識，並且能夠及時地提供準確的資訊，讓農業從業人員能夠更加精準地判斷害蟲種類、數量和危害程度等關鍵因素 (Alves et al., 2020)。這些即時與正確的資訊能夠幫助農業從業人員制定更有效的管理策略，從而提高害蟲防治的效率和準確度，減少對作物的損害與農藥的施用，增加農作物的產量和品質。這對實現 IPM 策略的順利實行具有重要意義。

1.2 研究目的

本研究室已開發一套基於物聯網技術的智慧型蟲害管理系統 (I^2PDM)， I^2PDM 無線取像裝置利用相機拍攝黏蟲紙影像，並透過深度學習模型計算害蟲數量 (Rustia et al., 2020)。儘管這種方法在害蟲防治方面有著很高的應用價值，但根據我們系統實際運作的經驗中發現，環境或是生物的多樣性問題，例如雨天、灰塵、過曝或光線不足等，會影響影像品質，進而導致辨識模型的準確度下降。此外，同一種害蟲也會有個體差異，例如顏色、型態或尺寸等，也會影響辨識模型的準確度。因此，進一步優化深度學習模型以提高準確率，是我們需要處理的重要課題。否則，管理者將無法得到正確的資訊，也就無法做出符合當前環境需要的決策，例如農藥施用的多寡或天敵防治投放的時機，進而導致損失。因此本研究的主要目的是優化害蟲辨識模型的效能，以提高對農業生產的支援能力。為達到此目標，我們在軟體方面提出三種優化方法。

首先，根據以往的經驗，我們觀察到卷積神經網路 (convolutional neural network, CNN) 在辨識害蟲時，由於固定輸入尺寸的限制，往往會忽略害蟲的大小差異，進而導致模型的誤判。例如，不同種害蟲其形態差異相似，但大小相差很大，模型可能仍然會把它們誤判同一種害蟲。因此，我們提出加入手工提取的害蟲尺寸特徵，以解決卷積神經網路在做分類任務時，可能會忽略昆蟲大小的問題。這樣可以讓模型更加準確地區分不同大小的害蟲，提高辨識的精確度。其次，我們加入影像增強模型來解決可能因取像時的環境因素或其他原因導致的影像品質

損失。通過該模型，能夠增強影像品質，從而提高模型的準確度。最後，利用 I²PDM 資料流的特性提出一套自動化線上學習方法，可以自動收集新的害蟲影像，並結合害蟲樣本清理演算法來自動化清理資料集，過濾掉不適合的樣本，從而去監督式學習所需的標記影像時間與人力。在舊有的資料集中加入新進的資料集，不斷重新訓練分類模型，隨著時間的推移，模型不斷迭代和優化，能夠更加準確地辨識害蟲的種類和數量，從而更好地支援農業生產和管理。

除軟體改善外，我們還計畫在硬體方面進行升級，透過升級無線取像裝置內的相機模組。從硬體的改善中提升影像的解析度，使得害蟲的特徵在影像中更加清晰，有助於模型更準確地辨識害蟲，從而進一步提升 I²PDM 系統的可靠性和準確性。

本研究主要研究目標與細項條列如下：

1. 溫室微型害蟲辨識模型之優化

- 加入 SRGAN 模型增強影像品質
- 加入害蟲尺寸資訊作為手工特徵

2. 線上自主學習架構之研究

- 建立樣本清理演算法
- 自動化分類模型更新流程

第二章 文獻探討



2.1 基於影像的昆蟲辨識方法

隨著處理器、顯示卡與人工智慧 (artificial intelligence, AI)的快速進步，人類在機器視覺上的發展快速，並且被證實效能優於以往所開發的最先進技術 (Voulovodimos et al., 2018)，承襲這項技術的發展，不同的影像辨識模型也被應用在害蟲辨識上，本節將分三階段回顧：（1）傳統影像處理方法；（2）機器學習方法；與（3）深度學習方法。

2.1.1 影像處理應用於昆蟲辨識

影像處理是一門涉及多個領域的技術，它在電腦視覺、機器學習、圖形學以及許多其他領域中都有廣泛的應用。影像處理的主要目的是改善圖像品質，使其更適合進一步的分析，或是為從圖像中取得有用的訊息，從而幫助我們更好地理解並描述圖像中的物體或是場景 (Boyat and Joshi, 2015; Xie et al., 2018)。

Cho (2007)等人對於在溫室中選定的害蟲，如白蝶、蚜蟲和瓢蟲等，進行對收集自黃色黏蟲紙上的標本的自動識別，利用靜態色彩閾值方法進行影像分割。透過使用預設的閾值，去除黃色背景。利用物體分析技術，對圖像中的昆蟲進行檢測和分類，並基於它們的大小、顏色和形態特徵進行分類。在昆蟲辨識方面的影像處理應用中，影像的預處理是提高影像品質的重要步驟。透過轉換圖像到不同的顏色空間、去除噪聲或是歸一化等處理，我們可以改善圖像品質，讓其更適合進一步分析。Huddar (2012)等人研究葉片上粉蟲的識別。首先，他們將整張影像從 RGB 空間轉換成 YCbCr 空間，以節省存儲空間並提高運算速度。接著，利用分水嶺分割法 (watershed segmentation)將感興趣的區域 (region of interest, ROI)與葉子分離，再使用侵蝕法消除雜訊。最終，該方法在粉蟲數量檢測上達到約 0.96 的準確率。Wen (2012)等人在進行昆蟲影像分割之前，將圖像轉換為色調 (hue)、飽和度 (saturation)和 HSV 空間。這樣做的原因是色調分量對照明變化的敏感度較其他顏色空間中的元素低。透過將影像轉換為 HSV 顏色空間，研究人員可以降低

照明變化的影響，從而提高在不同照明條件下的準確性和可靠性。經過實驗闡明，該方法在這項任務中達到 0.86 的分類準確率。



2.1.3 機器學習應用於昆蟲辨識

然而，由於傳統的影像處理方法在解決複雜問題時存在局限性，因此近年來機器學習技術的發展引起研究人員的廣泛關注。通過使用影像前處理方法提取特徵並透過機器學習模型進行分類，相較於僅使用傳統的影像處理方法，機器學習能夠更好地處理昆蟲辨識中的複雜問題。

Liu (2016)等人採用 MSER (maximally stable extremal regions)方法濾掉背景中的小麥，使用方向梯度直方圖 (histogram of oriented gradient, HOG)提取圖像特徵並訓練支持向量機 (support vector machine, SVM)辨識蚜蟲，模型可達到 0.86 的辨識率。Espinoza 等人 (2016)則使用昆蟲的顏色特性建立辨識模型。先計算黏蟲紙影像的 RGB 直方圖，並將頻率大於 10000 的像素點視為背景。接著，該團隊將影像由 RGB 映射到 Lab 空間做圖像分割，再將 RGB 轉換為 HSV 空間進行影像增強並提取特徵，最後使用前饋神經網路 (feedforward neural network)進行分類，其辨識粉蟲與薊馬的準確率約為 0.96 和 0.92。Li 等人 (2017)嘗試使用多曲率直方圖與圖塊灰階共生矩陣描述蝴蝶翅膀的形狀與紋理，並設計基於給定權重的 K-鄰近演算法 (k nearest neighbors)的自動辨識方法。經測試，該方法可以在 750 張 50 種蝴蝶的數字圖像中達到 98%的準確率。Lu 等人 (2020)使用 GrabCut 影像分割法提取蝗蟲的身體各部位紋理、顏色和形態特徵，藉由異常值檢測與主成分分析 (principal component analysis, PCA)最終篩選出八個特徵，並以支持向量機為模型訓練出對於不同蟲齡具有適用性與準確性高的分類模型。除基於單一分類器的模型，Yao 等人(2014)提出融合多個分類模型的方法，應用於稻田中監測飛蟲。包含三層分類器應用於稻田中監測飛蟲，其模型架構包含哈爾特徵的自適應增強分類器、方向梯度直方圖特徵的支持向量機分類器與三個特徵的閥值篩選，辨識準確率可達 0.85。

通過前述文獻的研究，我們解到影像處理和機器學習技術已成功應用於昆蟲檢測和辨識。然而，傳統影像處理方法只能提取較簡單的特徵，對於更複雜的分類問題，例如更多類別的分類或特徵差異不明顯的昆蟲，其效能仍然受到限制。因此，為克服這個問題，需要更強大的特徵提取技術或更穩健的模型來提高分類的準確性和效率。

2.1.2 深度學習應用於昆蟲辨識

深度學習模型在近年來的發展中已經成為一種非常強大的工具，相對於傳統機器學習，深度學習模型的優勢在於它們可以自動從原始數據中學習特徵的表示，而不需要手動設計特徵提取器。這使得深度學習模型能夠更好地應對高維度、非線性的問題。此外，深度學習模型的層次結構使其能夠逐層進行特徵提取和分類。卷積神經網路是其中一種成功的架構，已被廣泛應用於機器視覺任務中，例如辨識、偵測和影像分割方面 (LeCun et al., 2015)。從 1998 年 LeNet (LeCun et al., 1998) 被提出以來，學者們一直致力於卷積神經網路的架構設計與優化，並提出許多經典的架構，例如，AlexNet 在 2012 年被提出，擁有八層深度，使用 ReLU 作為激活函數，使用 Dropout 進行過擬合控制，在 ImageNet 資料集上取得突破性的成果 (Krizhevsky et al., 2017)。VGGNet 使用較小的卷積核，連續使用多個卷積層和池化層構建更深的網路 (Simonyan and Zisserman, 2014)。InceptionNet 則是基於 Inception 模塊的卷積神經網絡，它使用多種不同尺度的卷積核和池化操作，以提高模型的性能和速度。此外，該模型架構也採用 Batch Normalization 進行加速和控制過擬合 (Ioffe and Szegedy, 2015)。ResNet 提出殘差函數，用於解決深度神經網路中的梯度消失和梯度爆炸問題，使得網路更深，並且訓練更穩定 (He et al., 2016)。MobileNet 輕量級的卷積神經網路，用於解決在移動設備上運行深度學習模型的問題。其特點是使用深度可分離卷積可以大大減少模型的參數量和計算量 (Howard et al., 2017)。EfficientNet 可以根據不同的計算資源和精度要求自動調整網路的深度、寬度和分辨率，以達到更好的平衡模型的精度和計算成本 (Tan and Le, 2019)。

在農業害蟲檢測方面，深度學習技術已經被廣泛應用，取得不錯的效果。例如，Tetila 等人(2020)使用多種模型架構，以訓練大豆害蟲模型為例，實驗結果表明相較於傳統的特徵提取和機器學習方法，深度學習在分類表現上更優秀，在這些模型中，ResNet-50 的準確率達到 0.93。為解決作物害蟲辨識的難題，Thenmozhi 等人(2019)提出一個高效的深度卷積神經網絡模型。該模型透過引入深度結構，自動進行特徵提取和高層次特徵學習，並使用數據擴增技術和預訓練模型進行模型微調，以避免過擬合的問題。實驗結果表明，所提出的模型在三個不同的公開數據集中均取得較高的分類準確率，優於常用的預訓練模型。除影像分類任務外，深度學習模型也被應用於物件偵測，Partel 等人(2019)使用 YOLOv1 (you only look once)與 YOLOv3 模型建立一套用於偵測樹林中亞洲柑橘木蝨的系統。Wang 等人(2020)建立共 24 種、25378 張田間害蟲的數據集 Pest24，測試不同的物件偵測模型，其中 YOLOv3 在 RCNN、faster RCNN、Cascade R-CNN 與 SSD 之中得到最好的表現。

為提高模型的性能和準確度，卷積神經網路通常需要大量的影像做訓練，但這需要耗費大量的時間與人力進行影像收集和標註。然而，遷移式學習的方法可以利用已經訓練好的模型權重，使模型訓練更快速收斂有效地節省訓練時間和資源成本 (Pan and Yang, 2010)。例如，Alves 等人(2020)使用 ImageNet 的模型權重做遷移式訓練，並且改善原始的 ResNet-34 模型，將其最後一層替換為 7 個附加層增加特徵數量，結果顯示該團隊所提出的方法在 6 種與 15 種昆蟲的分類任務上，其 0.98 的 F₁-score 相對於 AlexNet、RseNet-34 和 ResNet-50 有著更好的結果。

深度學習技術能夠自動從影像數據中提取複雜的特徵，解決機器學習使用較差的特徵可能會使模型表現不佳的困難。此外，深度學習模型的優化、預訓練和參數調整等技術進一步提高模型的穩定性和準確性，使得深度學習模型能夠處理更複雜和繁雜的分類任務，同時保證模型的良好性能。



2.2 影像增強技術

影像增強是一種技術，其目的是通過數學模型來估計圖像中的退化過程，例如椒鹽雜訊、運動模糊或相機失焦等，以補償或消除影像缺陷，從而提高影像質量 (Mohapatra et al., 2014)。然而，在真實的溫室環境中，每次拍攝無法保證都在最佳狀態下進行，這可能會對分類模型的準確性產生影響。因此，需要對影像進行修補，以降低取像因素對分類模型的影響。

2.2.1 深度學習應用於影像增強

在影像增強領域中，隨著深度學習技術的發展，出現許多新的模型。這些模型能夠更好地進行影像增強，並在許多應用中取得良好的結果。其中，生成器是指一種深度學習模型，能夠將低解析度影像映射到高解析度空間，生成經過加強的影像，也被稱為超解析度 (super-resolution) 影像。這種生成器的模型權重是由低解析度與高解析度的配對影像 (paired-images) 進行學習而成的。近年來，許多用於單張影像增強的方法都取得相當好的結果。

Dong 等人 (2015) 提出 SRCNN (super-resolution CNN) 這個基於卷積神經網路的超解析度模型，該模型使用補丁提取與描述來找到影像的特徵，然後透過非線性映射組合先前找到的影像特徵，最後再進行影像重建與上採樣。透過實驗結果顯示，該模型在當時的運算速度與增強品質上達到當時的最先進水準。為改進 SRCNN，Dong 等人於 (2016) 提出 FSRCNN (fast-SRCNN)。FSRCNN 的架構包括特徵擷取、降維、映射、擴張與反卷積層，相較於 SRCNN，FSRCNN 不需要先將低解析度的影像進行上採樣，並且降低卷積層的核的大小，這樣不僅保持模型的性能，同時也提高運算速度。此外，透過共享參數的模型設計，可以加快訓練不同上採樣因子模型時的速度。

Shi 等人 (2016) 提出 ESPCNN (efficient sub-pixel CNN)，該模型使用兩個卷積層與一個亞像素卷積層來處理低解析度圖像，並進行上採樣以產生高解析度影像的輸出。作者測試多個公開的數據集如: Set14、BSD300 和 SuperTexture 等，結果顯示 ESPCNN 不僅在運算速度上比當時最好的方法如 SRCNN 或 TNRD 更快，同

時也取得更低的峰值訊躁比 (peak signal-to-noise ratio, PSNR)。Ledig 等人 (2017) 結合亞像素卷積層與生成對抗網路 (generative adversarial network, GAN) 稱為 SRGAN (super-resolution using a generative adversarial network)，並提出全新的損失函數使模型訓練的結果能更接近真實的影像，使用平均意見分數 (mean-opinion-score, MOS) 作為評斷準則。實驗結果顯示，使用 SRGAN 生成器增強影像，可以取得比先前方法更好的影像品質。

2.2.2 影像增強模型應用於農業影像辨識

根據前一小節的文獻回顧，使用深度學習技術來提升影像品質的效果已經被證明比傳統影像處理方法更優秀。這項技術不僅適用於一般影像處理，而且在處理農業影像方面也能取得很好的成效。透過深度學習技術，可以修復影像品質並且強化分類模型的表現，尤其是在複雜的取像環境下，這種技術更能顯示其優勢。

Zhou 等人 (2019)，提出一種基於生成對抗網路的低解析度昆蟲影像增強分類架構稱為 LRIRNet，由分類器、基於 U-net 的生成器與基於 PatchGAN 的判別器 (discriminator) 組成，使用該團隊前期研究的線上昆蟲影像拍攝裝置取得的影像當作低解析度影像，並使用 iPhone 拍攝相同的照片視為高解析度影像，該架構有三個訓練步驟且一次只會更新一個模型的權重：（1）固定生成器的權重後將低階解析度影像輸入生成器進行增強後，將該影像與高解析度影像輸入判別器判斷與更新模型權重；（2）固定判別器與分類器的權重，將增強後的影像輸入判別器和分類器，根據結果更新生成器的權重；（3）固定生成器的權重後將增強的影像做分類器的更新重複以上三步驟直到模型收斂。實驗結果顯示，使用該架構對比僅使用低解析度影像模型提升 19% 的分類準確率。

Dai 等人 (2020) 提出一種融合 quadra-attention、residual 與 dense 的生成對抗網路用來恢復低分辨率的害蟲影像，稱為 PSRGAN，該團隊同時使用八種上採樣模型與八種分類模型在 Xie1 和 Xie2 的害蟲資料集上測試，實驗結果發現，對比其他著重於提高 PSNR 的上採樣方法如：SRDensNet 或 LapSRN 會使重建後的影像過於平滑，PSRGNA 可以在重建昆蟲的整理輪廓與身體細節方面有顯著的優勢，與原始分類模型相比，使用上採樣影像的模型可以提高約 4% 的準確率。

除昆蟲辨識外影像增強模型也被應用到植株病害的檢測，Maqsood 等人 (2021) 使用 SRGAN 提升小麥條繡病 (wheat stripe rust) 的準確率，分別使用原始影像訓練分類模型，再使用經過 SRGAN 對小麥葉子影像上採樣後的影像訓練模型。相較之下使用原始影像的分類模型準確率約為 75%，而經過 SRGAN 模型上採樣的模型，其準確率可以提高至 83%，而使用原始影像訓練模型準確率僅約為 75%。此外，該團隊還使用其他上採樣方法，如：EDSR 和 WDSR 進行測試，實驗結果顯示以 SRGAN 的效果最佳。

前述論文指出，將深度學習應用於影像增強上，可以使用影像增強模型修復因取像環境等因素而導致的影像品質損失，從而提高影像細節與品質，增強後的影像能提供分類模型更好的影像特徵，進而提升分類模型表現。預期將其應用在本研究的害蟲辨識上，將有相當大的可行性。

2.3 手工特徵 (Handcrafted Features)

在傳統機器學習方法中，需要透過人工提取特徵來表示資料，但是這種方法需要設計繁瑣的步驟，且可能無法充分挖掘資料的潛在特徵。相比之下，深度學習模型能夠從原始資料中學習到更加豐富和抽象的特徵，從而提高模型的準確度。但這並不表示人工設計的特徵就不管用，相反地這些特徵仍然可以適時提供補充資訊，從而提高深度學習模型的性能。因此，研究者開始探索如何將人工提取的特徵與深度學習模型相結合，以實現更好的影像分類性能。

2.3.1 結合手工特徵和深度學習之方法

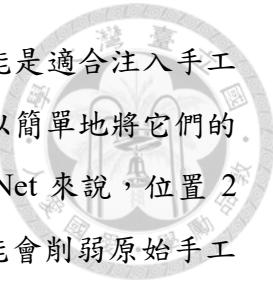
Lin (2020) 等人提出一種使用手工特徵和卷積神經網路特徵來識別肝臟影像的方法，並將隨機森林應用作為分類器。這些手工特徵包括高斯混合模型、歐拉特徵曲線和紋理分析，並比較不同訓練樣本下的表現。研究發現，在小樣本大小的情況下，使用手工特徵的方法優於卷積神經網絡。當訓練數據足夠時，卷積神經網路的表現會提高，但仍不及結合使用手工特徵和深度特徵的分類器。這些結果顯示，在數據量不足的情況下，使用結合手工特徵的方法相比於僅使用卷積神經網路更為可行，其可能原因是在深度學習初期，由於標註數據不足，手工設計特

徵成為一種有效的方法，利用提取具有代表性的特徵，讓模型能更高效地尋找規律和模式，從而提高模型性能。Khan (2020)等人提出一種人類行為辨識模型，使用方向梯度直方圖做為人工特徵，並同時利用卷積神經網路提取深度學習特徵，並將兩者結合，使用支持向量機作為分類器，在五個公開的基準數據集上測試，並對比多種不同的分類器，如 LSVM、CSVM、BTree 和 ESDA 等。結果表明，該作者提出的特徵融合的方法取得最優的表現。Rajan (2020)等人提出一種應用於手語字母識別的方法。作者利用基於膚色的 YCbCr 分割方法和局部二值模式提取手部的形狀和紋理特徵。然後使用同一組資料集對 VGG-19 模型進行微調訓練，獲得深度特徵後使用將手工特徵進行融合。最後使用 SVM 進行識別，相較於深度學習的 0.91，該作者提出的方法達到 0.98 的準確率。以上文獻表明，這種手工設計特徵與深度學習方法的結合，可以提高模型的準確率。

2.3.2 手工特徵應用於深度學習模型

除將手工特徵與深度學習模型特徵融合後再訓練分類模型外，另一些研究則探討將傳統的人工設計的特徵注入到 CNN 模型中的可能性。Zhou 等人 (2018)將手工特徵與卷積神經網絡結合起來進行分類，作者使用 CaffeNet 來提取用於圖像分類的 CNN 特徵。CaffeNet 是一個修改過的 AlexNet 模型，它包含三個卷積層、三個池化層和三個全連接層。最後一個池化層的輸出就是 CNN 特徵，並將手工特徵連接到 CNN 特徵的末端，作為全連接層的輸入。實驗結果表明，發現直接結合 CNN 特徵和手工特徵可以帶來一定的改善，這種方法在 Cifar10 數據集上的性能優於原始的 CaffeNet，達到 79.16% 的準確率。

Zhang (2021)等人提出一種新的框架，用於船舶分類的模型，將方向梯度直方圖、原始幾何特徵 (navie geometric features, NGFs)、局部雷達散射截面特徵 (local radar cross section features, LRCS)和主軸特徵 (principal axis features, PAFs)等一些手工特徵直接加入到 CNN 中。在該文獻中，作者探討將手工特徵注入到 CNN 模型的哪個部分可以獲得較好的效果，四個架構分別為: AlexNet、VGGNet、ResNet 與 DenseNet。根據圖 2-1 (a)，將一維傳統特徵直接注入到二維 Convolution、Residual 或 Dense blocks 中是不切實際的，因為不同傳統特徵的維度是不同的，無



法直接轉換成相同尺寸的二維特徵圖。圖 2-1 (b)中的位置 2 可能是適合注入手工特徵的位置，因為手工特徵和基於 CNN 的特徵都是一維的，可以簡單地將它們的向量特徵拼接起來實現特徵融合。然而，對於 AlexNet 和 VGGNet 來說，位置 2 後面還有另外兩個全連接層，這些全連接層的學習權重參數可能會削弱原始手工特徵的表示能力。因此，位置 3 (圖 2-1(c)) 的內部全連接層也不建議使用。最後，作者建議將手工特徵注入到終端的全連接層 (位置 4，圖 2-1(d))，這樣傳統特徵和 CNN 的抽象特徵可以直接參與最終的決策過程。這種方式有效地監督 CNN 提取船舶特徵的過程，同時保留傳統特徵的原始屬性和豐富的專家經驗。該研究測試不同的人工特徵，結果都顯示將傳統的人工設計的特徵注入到 CNN 模型中可以有效地提高分類準確率，並且最大準確率提高可達 6.75%。

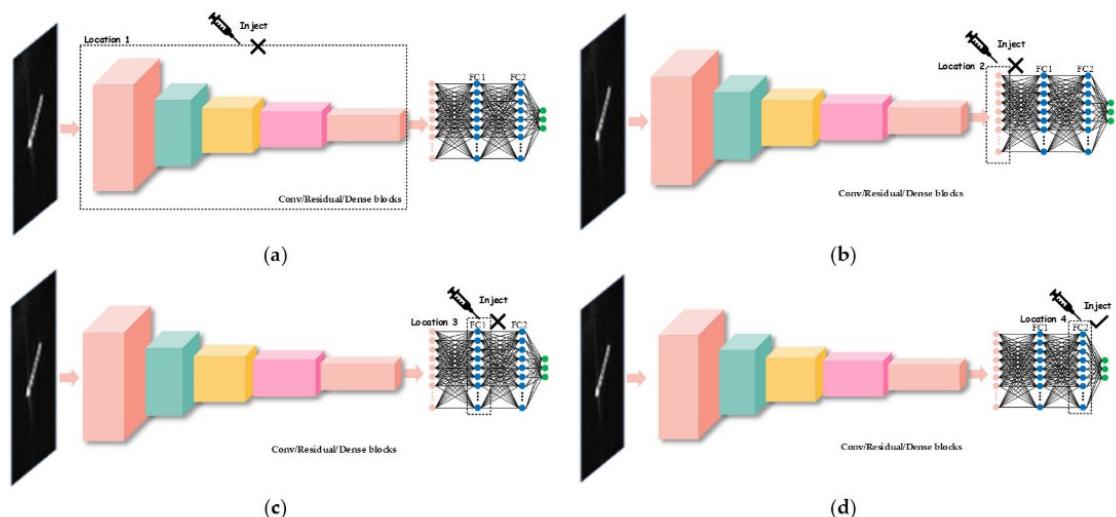


圖 2-1 手工特徵注入位置 (a)位置 1：Convolution、Residual 與 Dense 模塊；(b) 位置 2：基於 CNN 的特徵的一維向量層；(c) 位置 3：內部全連接層；(d) 位置 4：最終的全連接層 (Zhang and Zhang, 2021)。

以上提到的研究顯示，將手工提取的特徵加入到深度學習模型中能夠有效提高模型表現。這種特徵的加入可以提供額外的輔助資訊。因此，在本研究中，我們希望進一步探討將害蟲尺寸作為手工設計的特徵加入到深度學習模型中的可能性，以提高害蟲識別的準確率。



2.4 線上學習方法回顧

2.4.1 連續神經網路學習 (Continuous Neural Network Learning)

在深度學習模型中，要實現良好的泛化能力通常需要大量的標註數據，但由於標註數據的收集和標註過程十分繁瑣且耗時，收集足夠的數據往往是一個困難的問題。為解決這個問題，許多研究人員開始探索如何在使用較少標記數據的情況下訓練深度學習模型。其中，Bacucum (2017)等人提出名為連續神經網路學習 (continuous neural network learning, CNNL)的新型神經網路訓練數據流架構。其主要目標是減少訓練神經網路所需的已標註數據量。CNNL 使用少量手工標記數據來建立初始模型，並透過演算法將新進資料自動分類並不斷持續訓練，最終達到良好的模型效能。該研究表明，從僅有 150 個標記圖像的初始數據集開始迭代，MNIST 模型的準確率從 47% 提升到最終 85%，顯示出顯著的改進。Gjestang 等人 (Gjestang et al., 2021)提出一個類似的框架，稱師生 (teacher-student)框架用於對腸道內視鏡影像做疾病檢測，該框架包含三個主要的步驟：(1) 用已標註的數據訓練教師模型；(2) 使用教師模型對還沒經由人工標註的資料自動標註稱為做偽標註；(3) 用已標註與偽標註組合成一個更大的訓練集訓練學生模型，將學生模型視為教師並持續分類尚未標註的數據。重複以上三步驟的實驗結果發現，該團隊提出的方法可以在兩個腸道內視鏡影像資料集上獲得分別提升 3.2% 與 4.7% 的 F_1 -score。顯示該框架可以在不需要專家標記的情況下更好地利用醫院收集的數據，從而為自動疾病檢測的系統提供更優秀的模型。

2.4.2 線上學習與其應用

傳統的深度學習通常以批量學習 (batch learning)或離線學習方式運作，其中模型通常是通過某些學習算法從整個訓練數據集中一次性訓練好，然後在實地部署應用幾乎不進行任何更新。當面對新的訓練數據時，這種學習方法需要昂貴的重新訓練成本，因此在實際應用中的可擴展性較差。與 CNNL 的概念相似，利用基礎的模型對於新進的資料標記分類再訓練得到更好的模型，另外一種方法稱為

在線學習 (online learning)，是一種在深度學習模型的部署期間從連續數據流中進行學習的方法，應用於處理不斷新進的數據，並嘗試從每一個模型更新步驟中逐步學習並更新最佳的模型(Hoi et al., 2021)。線上學習可以分為三大類別（圖 2-2）：

(1) 線上監督學習 (online supervised learning)：在每一輪學習結束時會收到完整的反饋訊息，研究員可以根據收到的反饋資料進行實時的調整；(2) 有限反饋線上學習 (online learning with limited feedback)：在線上學習過程中，模型從環境中獲得部分反饋訊息，研究人員會在開發知識和探索未知之間取得平衡；(3) 線上非監督學習 (online unsupervised learning)：模型只接收新進的資料而沒有其他多餘的反饋資訊，包括線上分群或是線上異常檢測等任務上分群 (online clustering) 或是線上異常檢測 (online anomaly detection) 等任務。

Online Learning			
Statistical Learning Theory		Convex Optimization Theory	Game Theory
Online Learning with Full Feedback		Online Learning with Partial Feedback (Bandits)	
Online Supervised Learning		Stochastic Bandit	Adversarial Bandit
First-order Online Learning	Online Learning with Regularization	Stochastic Multi-armed Bandit	Adversarial Multi-armed Bandit
Second-order Online Learning	Online Learning with Kernels	Bayesian Bandit	Combinatorial Bandit
Prediction with Expert Advice	Online to Batch Conversion	Stochastic Contextual Bandit	Adversarial Contextual Bandit
Applied Online Learning		Online Active Learning	Online Semi-supervised Learning
Cost-Sensitive Online Learning	Online Collaborative Filtering	Selective Sampling	Online Manifold Regularization
Online Multi-task Learning	Online Learning to Rank	Active Learning with Expert Advice	Transductive Online Learning
Online Multi-view Learning	Distributed Online Learning	Online Unsupervised Learning (no feedback)	
Online Transfer Learning	Online Learning with Neural Networks	Online Clustering	Online Density Estimation
Online Metric Learning	Online Portfolio Selection	Online Dimension Reduction	Online Anomaly Detection

圖 2-2 線上學習架構圖 (Hoi et al., 2021)

在實際應用中，隨著監控系統收集更多數據，使用線上非監督式訓練技術可以將新收集的數據與舊數據集相結合，擴展當前模型的學習特徵。Wang (2019)等人，提出一種高效且無監督的臉部重識別系統 (face re-identification)，該系統可同時在人機交互中重新識別多個臉部。這個重識別系統使用深度卷積神經網絡來提取特徵，並使用線上聚類演算法來確定人臉的 ID。該系統在兩個數據集上進行測試，分別是 TERESA 機器人收集的 TERESA 影片數據集和 YouTube 藝人臉部數據集。實驗結果顯示，經過優化的技術組合在 TERESA 數據集上取得 93.55% 的整體準

確率，而在 YTF 數據集上達到 90.41% 的整體準確率。同樣地，Guérin (2018) 等人也使用線上非監督式訓練技術的概念為物體分類機器人進行訓練。當機器人遇到新物體時，它利用卷積神經網路提取物體特徵並進行聚類分析，將收集到的物體資訊用於訓練分類器模型。這使得機器人能夠在對要分類物件的知識有限的情況下進行分類。線上非監督式訓練技術意味著系統可以在不斷提高性能的同時，能夠有效地完成任務。隨著時間的推移，這種自我改進的能力能夠更好地適應不斷變化的環境和條件，提高其在各種應用場景中的實用性和可靠性。此外，這種持續優化的過程還有助於減少人工干預和調整的需求，從而降低系統維護成本，並提高效率。

本實驗室開發的智慧型蟲害管理系統定期收集黏蟲紙影像。該系統很適合導入線上學習的方法，因為隨著時間推移，黏蟲紙影像會不斷增加。若使用傳統批量學習方式，需要花費大量的人力與時間來處理大量數據，無法有效的更新模型。因此，採用線上非監督學習的方式，可以實現自動化實時處理新進數據的同時進行模型更新，從而提高模型的準確性。



第三章 研究方法

3.1 研究架構

本研究的目標是優化現有 I²PDM 系統的害蟲辨識演算法，以提升系統的性能和效能。研究架構如圖 3-1 所示，包括軟體和硬體兩個方面的改進。在軟體方面，採用影像增強技術並結合手工特徵，提升卷積神經網路模型的能力。透過影像增強模型的訓練和研究，增強輸入影像的品質並提高模型對害蟲的辨識能力。同時，擷取手工特徵並將其注入模型中，進一步增強辨識的準確性。其次，提出一套自動化線上學習的演算法，用於收集新的黏蟲紙影像並進行模型的訓練和更新。這套演算法能夠自動地收集新樣本，並通過樣本清理方法提高樣本的可用性。透過這套演算法，能夠持續地學習和優化模型，以應對不斷變化的害蟲情況。最後，在硬體方面，升級無線取像裝置內的 Pi Camera v2，使用更高解析度的相機模組，進一步提升害蟲辨識系統的效能和準確性。綜合而言，透過影像增強和手工特徵的結合，持續的自動化線上學習，以及硬體升級，提供更準確和可靠的害蟲辨識結果。

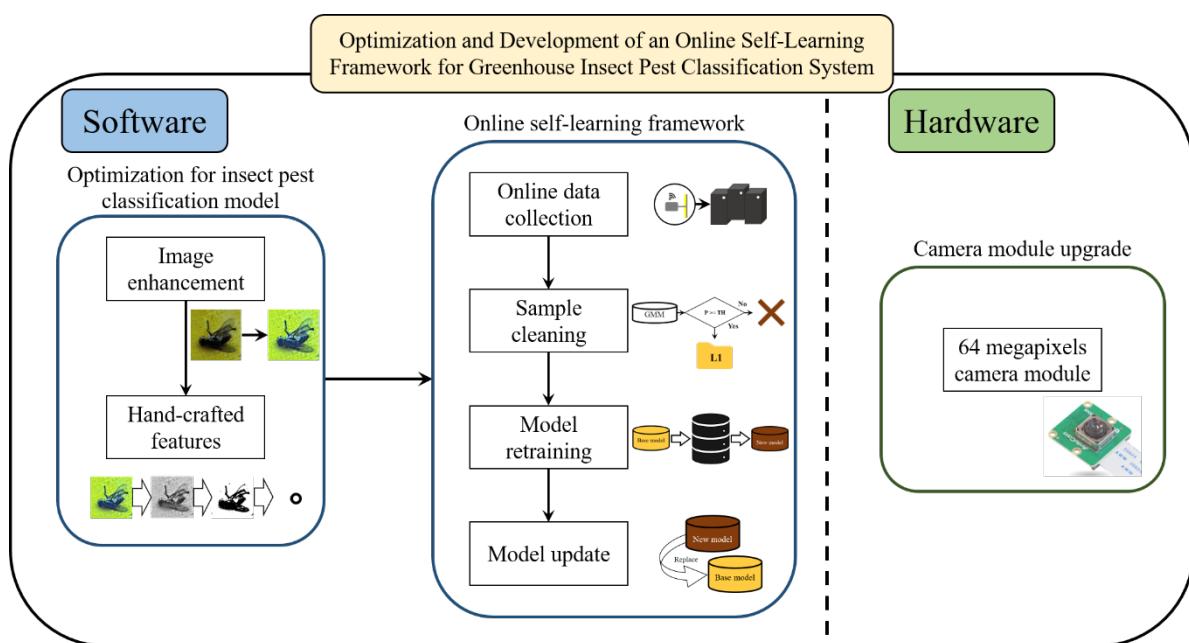


圖 3-1 研究架構圖



3.2 害蟲分類模型之優化

本章節將會介紹基礎的害蟲分類模型架構，以及兩種應用於優化基礎的害蟲分類模型的方法，分別是使用影像增強模型，與手工提取害蟲尺寸特徵 (size features)，以下將詳細說明。

3.2.1 原始害蟲分類模型

本研究使用 ResNet (He et al., 2016) 做為分類模型之架構，ResNet 的作者提出殘差模塊的概念（圖 3-1），利用快捷連接 (shortcut connections) 的方式，將前一層的輸出添加到後續堆疊層 (stacked layers) 中，透過殘差模塊的導入，模型能夠更容易地學習到輸入與輸出之間的殘差，使得深層網路的訓練更加順利。從而有效的解決模型加深時所產生的梯度消失問題 (vanishing gradient problem)。

進一步選擇 ResNet-18 作為具體的模型架構，ResNet-18 是 ResNet 系列中相對較輕量的模型，具有 18 個堆疊層，同時保留 ResNet 的核心特性。能在模型的準確性和計算效能之間取得平衡。ResNet-18 的結構包括輸入層、卷積層、殘差塊、全局平均池化層、全連接層和輸出層。輸入層接收圖像作為模型的輸入，隨後進行卷積操作，並使用步幅 (stride) 為 2 進行下採樣，從而減小圖像尺寸。接下來，輸出通過殘差塊的堆疊處理，每個殘差塊包含兩個卷積層。每個卷積層後面都接有批量正則化與 ReLU 激活函數，而跳躍連接使得殘差能夠被有效地傳播。最後，通過全局平均池化層將特徵圖轉換為固定大小的向量，再經過全連接層進行分類，最終輸出預測結果。

本研究參考目前 I²PDM 的架構，將害蟲影像縮放至 128 x 128 像素作為輸入，這樣做的目的是確保新模型的輸入與現有系統的相容性，可以直接將該模型應用於 I²PDM 系統中，而無需進行額外的調整。

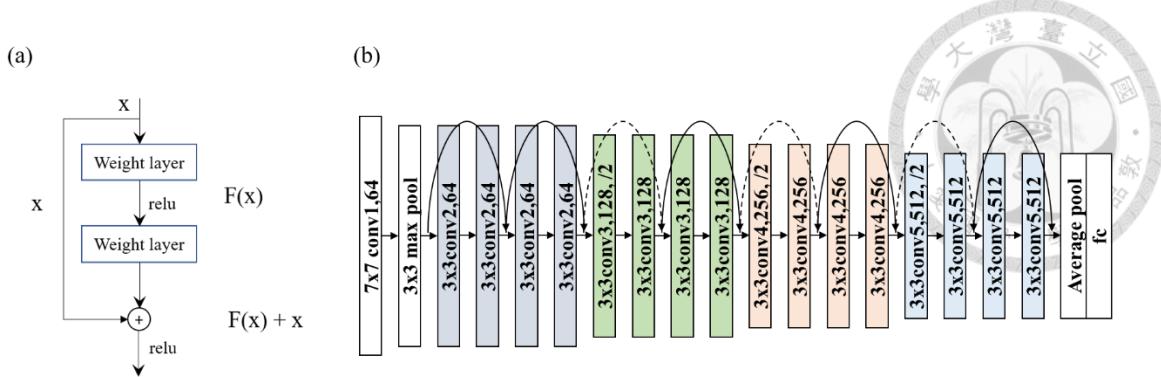


圖 3-2 ResNet 所使用之 (a)殘差模塊；與 (b)模型結構圖(He et al., 2016)

3.2.2 影像增強分類模型

我們選擇使用 SRGAN 作為影像增強模型，藉由 SRGAN 對影像的強化能力，進一步改善分類模型的性能。SRGAN 是一種基於生成對抗網絡的超解析度影像增強模型，旨在將低解析度的影像轉換為更清晰且更具細節的高品質影像 (Ledig et al., 2017)。

如圖 3-3 所示，SRGAN 由兩個主要組件組成，生成器 (generator, G)和判別器 (D)。生成器使用殘差模塊 (residual blocks)對低解析度影像進行特徵提取，並使用像素混合器 (pixel-shuffler)對低解析度的昆蟲圖像進行上採樣，以生成高解析度影像。判別器則由多個卷積層組成，用於區分輸入的超解析度影像和真實高解析度影像。在訓練 SRGAN 時，兩個模型同步進行訓練。生成器試圖生成逼真的高解析度影像，而判別器則用於區分生成的影像和真實高解析度影像。通過對抗性訓練，當生成器提高解析度的圖像未能成功欺騙判別器時，它被迫生成更逼真的昆蟲圖像。這個過程促使生成器逐漸提高其生成的影像品質，同時判別器也增強對於真實高解析度影像的鑑別能力。

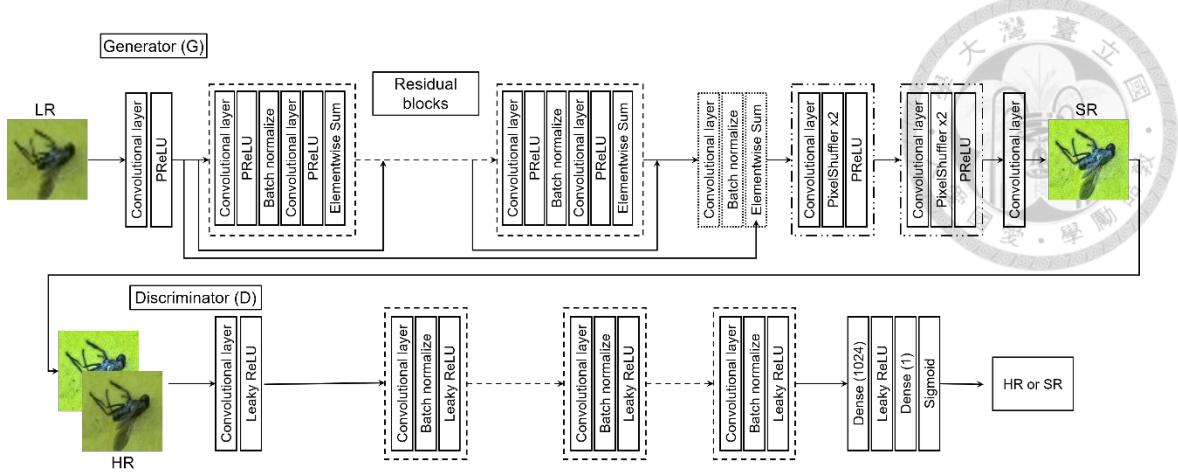


圖 3-3 昆蟲影像結合 SRGAN 之模型架構示意圖

在訓練分類模型時，先利用已經訓練完成的 SRGAN 對害蟲資料集進行影像增強，生成一組新的資料集。隨後，利用這些經過影像增強的害蟲影像來訓練分類模型。在實際應用中，新進的昆蟲影像首先經過 SRGAN 的影像增強處理，再利用先前訓練完成的分類模型對強化後的影像進行分類，將該方法通稱為影像增強分類模型，流程如圖 3-4 所示。

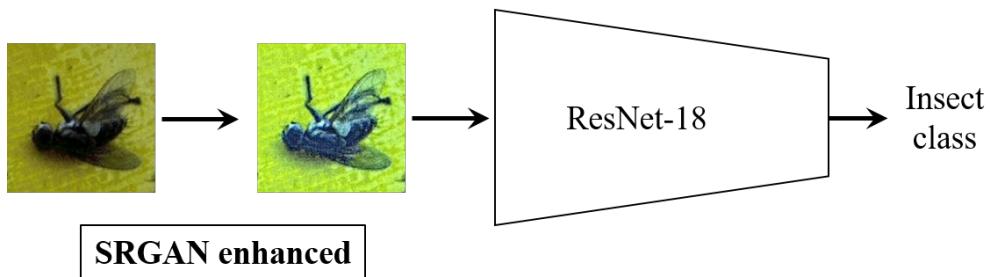


圖 3-4 影像增強分類模型實際應用流程

3.2.3 手工特徵融合於害蟲分類模型

根據以往 I²PDM 系統運作的經驗，卷積神經網路在辨識害蟲時，因為固定尺寸輸入的關係，對於昆蟲的尺寸較不敏感。這導致不同種害蟲的大小存在很大的差異，但在形態上相似的情況下，模型仍然會將它們誤判為同一種害蟲。舉例來說，如圖 3-5 所示，蠅 (fly)、蕈蠅 (gnat) 和蠓 (midge) 這三種害蟲都具有雙翅，儘管尺寸差異很大，但在某些角度上它們的形態相似，模型往往會辨識成蕈蠅。為



解決這個問題，我們決定將害蟲的大小作為一個額外的特徵加入模型中。這樣模型在辨識害蟲時可以考慮到它們的大小資訊，從而更好地區分不同種類的害蟲。

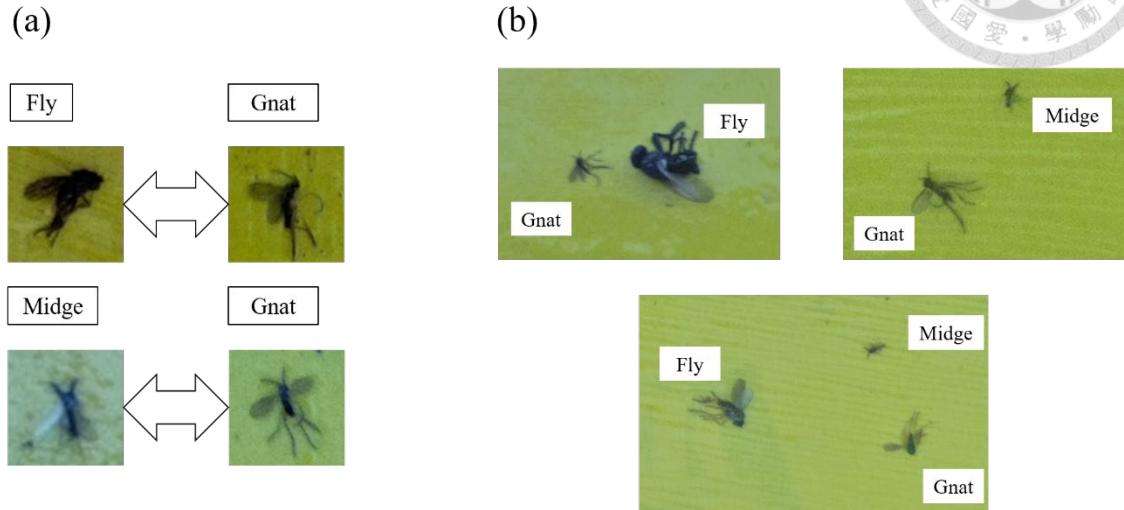


圖 3-5 分類模型經常因為 (a)不同種類的害蟲仍存在型態相似的個體，而造成誤判，即使我們發現到 (b)各類別間實際的害蟲尺寸具有明顯的差異

圖 3-6 為手工提取害蟲影像尺寸特徵的流程，首先基於式 3.1 將輸入的 RGB 影像轉為灰階影像，這個公式基於人眼對不同顏色的感知度，將每個像素的 RGB 值進行加權平均，並生成一個新的灰階值 (Y) (Bradski and Kaehler, 2000)。透過這種方式，從彩色影像中提取出灰階訊息。

接下來，我們使用 OTSU 演算法對灰階影像進行二值化，這是一種基於影像灰階直方圖的自動閾值選擇技術 (Otsu, 1979)，對於具有明顯對比度的影像，如黏蟲紙，其中背景顏色與昆蟲體色之間存在明顯差異，OTSU 方法能夠有效地將影像進行二值化。因此，我們可以將背景標記為白色，害蟲身體標記為黑色，從而清晰地區分出害蟲區域。最後，我們使用式 3.2 計算黑色像素的數量，並除以整張黏蟲紙的大小，得到該蟲在黏蟲紙上的比例，以獲得尺寸特徵。

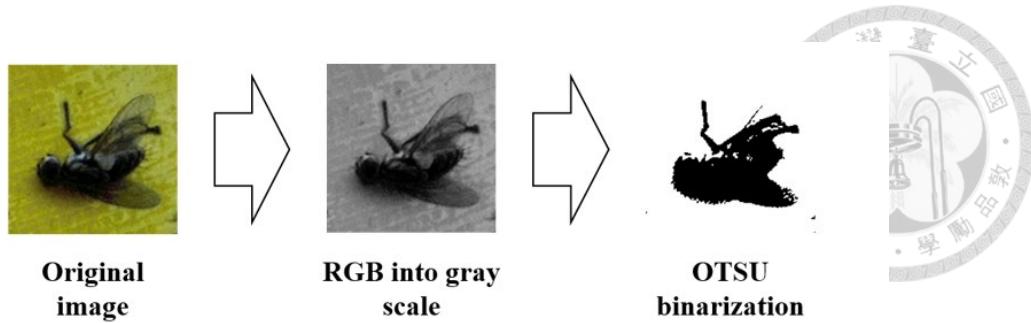


圖 3-6 尺寸特徵手工提取流程

$$Y = 0.299 * R + 0.587 * G + 0.114 * B \quad (3.1)$$

$$\text{size ratio} = \frac{(\text{number of black pixels})}{(3200 * 2400)} \quad (3.2)$$

同時，為避免尺寸特徵在高維度的特徵向量中被稀釋，我們在原始的 ResNet-18 模型的全連接層後增加一層額外的全連接層。這個額外的全連接層的目的是將原有輸入的 512 維特徵向量降低到 31 綴度。在這個全連接層中，將尺寸特徵注入，使得最終的特徵向量變成一組包含尺寸特徵的 32 綴度向量。

最終的手工特徵分類模型的流程如圖 3-7 所示，首先將原始未經縮放的害蟲影像進行尺寸特徵提取。然後，將這些影像縮放至 128×128 像素，以符合原始模型的輸入尺寸要求。最後將尺寸特徵組合成一組 32 綴度的特徵向量並進行分類。

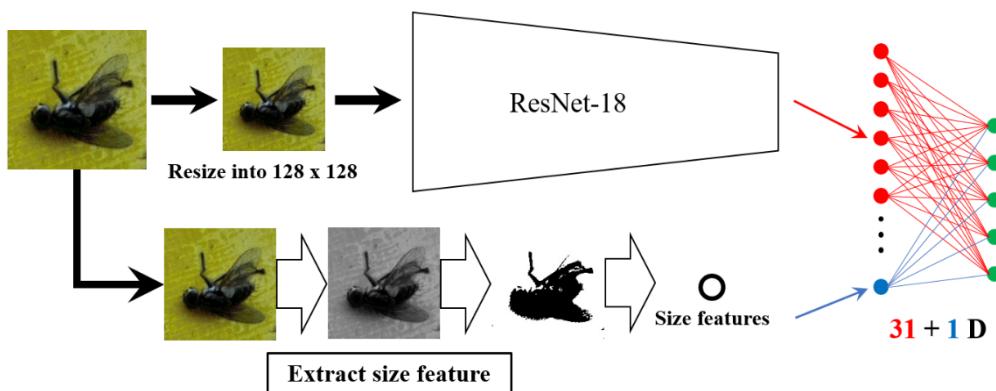


圖 3-7 手工特徵分類模型流程圖



3.2.4 影像增強結合手工特徵分類模型

除前面章節介紹的個別的優化方法外，我們也嘗試將兩種優化方法結合，形成第三種優化方法。整個流程如圖 3-8 所示，首先使用影像增強模型對害蟲影像進行強化，這可以提升影像的清晰度和細節，進一步改善害蟲的辨識效果。接下來，將經過影像增強處理的影像輸入到手工特徵分類模型中，進行尺寸特徵提取和分類。這樣的結合方法能夠充分利用影像增強的優勢和手工特徵的額外資訊，進一步提高分類模型的性能和準確度。

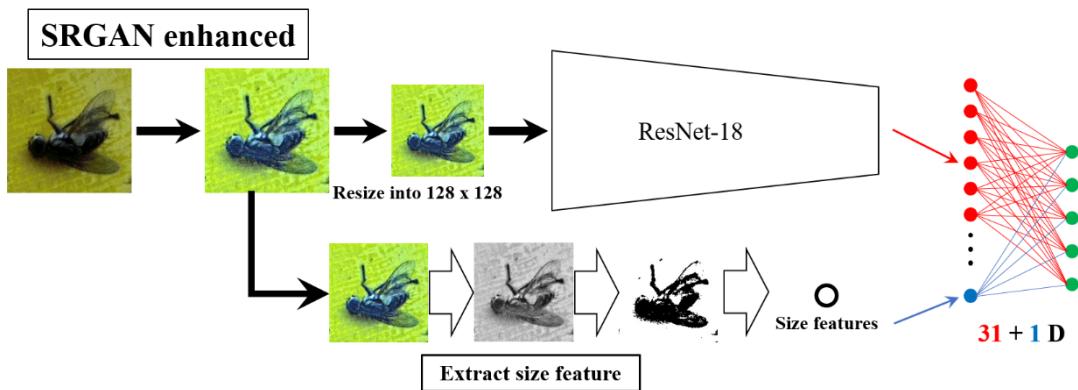


圖 3-8 影像增強結合手工特徵分類模型流程圖

3.3 模型訓練與評估

本研究使用 Python 3.8 語言進行程式撰寫，並利用各套件來協助工作：使用 torch 1.9.0 + cu10.2 與 torchvision 0.10.1 + cu10.2 作為深度學習模型框架與訓練，使用 opencv-python 4.5.3.56 進行影像的前處理與手工特徵擷取，利使用 Sklearn 0.24.2 進行模型準確度評估並使用 Matplotlib 3.5.2 與 seaborn 0.12.2 套件進行資料視覺化。在硬體配置方面，我們使用 Ubuntu 18.04 作業系統，搭配 Nvidia Titan RTX 24GB GPU 進行 SRGAN 模型的訓練。同時，我們使用 Windows 10 作業系統，配備 Nvidia RTX 2070 8GB GPU，用於建立和測試 CNN 模型。



3.3.1 起始模型建立

我們使用相同的參數進行四種起始模型的訓練包括原始模型、SRGAN 分類模型、手工特徵分類模型與影像增強結合手工特徵分類模型，使用的訓練參數條列於表 3-1，透過固定這些參數，可以盡可能確保在不同模型之間進行公平的比較。訓練完成的模型也將被用來做為下一階段的線上自主學習演算法使用。

表 3-1 ResNet-18 訓練參數

Hyperparameters	value
Input size	128
Batch size	16
Learning rate	0.001
Epochs	200
Loss function	categorical crossentropy
Optimizer	Adam

3.3.2 分類模型效能檢定

在模型訓練完成後，使用測試集對模型進行測試並計算其 F_1 -score，這是一種常用的分類性能指標，結合精確度 (precision)和召回率 (recall)，用於評估模型在分類任務中的能力。 F_1 -score 的計算公式如式 3-5，TP (true positive)代表真陽性，表示模型預測為真，且事實上也為真的樣本數量，FP (false positive)代表偽陽性，表示模型預測為真，但事實上不為真的樣本數量，FN (false negative)代表偽陰性，表示模型預測不為真，但事實上為真的樣本數量。 F_1 -score 介於 0 到 1，越接近 1 表示模型的分類性能越好。其綜合考慮精確度和召回率的指標，可以避免僅使用單一指標而忽略模型在不同類別的表現。在多類別分類模型，公式修正如式 3.6，將各類別的 F_1 -score 計算後再除以類別數量 N 得到 macro average F_1 -score。



$$Precision = \frac{TP}{TP + FP} \quad (3.3)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.4)$$

$$F_1 - score = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (3.5)$$

$$Macro F_1 - score = \frac{\sum_{n=1}^N F_1 - score_n}{N} \quad (3.6)$$

除計算 F_1 -score 外，也使用 McNemar 統計檢定的方式檢驗我們所提出的方法對原始的模型是否有顯著的效能提升 (Raschka, 2018; Wang et al., 2022)。該方法基於對比兩個分類器在相同樣本上的預測結果，建立一個 2 × 2 的交叉表格（表 3-2），其中包括以下四種組合：

- A：兩個分類器都正確預測的樣本數
- B：第一個分類器正確預測，但第二個分類器錯誤預測的樣本數
- C：第一個分類器錯誤預測，但第二個分類器正確預測的樣本數
- D：兩個分類器都錯誤預測的樣本數

表 3-2 McNemar 統計列聯表

		模型一正確	模型一錯誤
模型二正確	A	B	
模型二錯誤	C	D	

對於上述列聯表的結果，可以將其分為兩種配對情況：前後一致的配對 (A、D) 和前後不一致的配對 (B、C)。當原假設 H_0 成立（即兩個模型之間沒有顯著差異）時，預期 $A + B = A + C$ 或 $B + D = C + D$ ，也就是 $B = C$ 。因此，根據 H_0 成



立的假設， $B + C$ 應該均勻分配給 B 和 C 兩個欄位。為探討 B 和 C 兩個欄位的數量是否符合預期，可以使用卡方分配檢定。這種統計方法稱為 McNemar 檢定。在進行 McNemar 檢定時，計算經過連續性校正後的檢定統計量，其公式如下：

$$x_o^2 = \frac{(|B + C| - 1)^2}{(B + C)} \quad (3.7)$$

透過 McNemar 檢定比較模型之間的效能差異，並確定這種差異是否具有統計上的顯著性。

3.3.3 影像增強模型訓練與評估

在訓練 SRGAN 模型時，使用與原始論文相同的訓練參數，其中，上採樣因子 (upsample factor)被設定為四倍 (Ledig et al., 2017)，這表示會將輸入影像提升四倍解析度，因為模型的特性，需要使用成對樣本做訓練，目的是讓模型能夠學習從低解析度 (low resolution, LR) 影像生成對應的高解析度 (high resolution, HR) 影像。在建立害蟲影像成對樣本時使用雙三次插值法 (bicubic interpolation) 將 128×128 的害蟲影像下採樣為 32×32 的低解析度影像如圖 3-9 所示。



圖 3-9 原始 128×128 像素之影像經由雙三次插值法下採樣為 32×32 像素之影像，建立成對害蟲樣本數據集，用於 SRGAN 模型訓練使用

在訓練 SRGAN 分類模型前，需要先完成 SRGAN 模型的訓練，本研究使用結構相似度 (structural similarity, SSIM)、多尺度結構相似度 (multi-scale structural

similarity, MS-SIM)和特徵相似度 (feature similarity, FSIM)等指標，對原始影像與不同訓練樣本所得到的模型所增強的影像做比較，這些指標被用來探討在本研究中需要多少樣本才足夠訓練 SRGAN 模型 (Wang et al., 2004; Zhang et al., 2012)。透過比較不同訓練樣本數量所產生的增強影像與原始影像之間的相似度，評估模型的性能和增強效果。這些指標可以提供量化的度量，以解模型在不同訓練樣本數量下的表現。透過觀察這些指標的變化，得出訓練樣本數量對 SRGAN 模型的影響的關係。

結構相似度的公式如式 3.8 所示，它是基於兩張影像的像素值、平均值、變異數和共變異量來計算的。其中 x 和 y 分別表示兩張影像的像素值， $\mu_x\mu_y$ 表示兩張影像的平均值， $\sigma_x^2\sigma_y^2$ 表示兩張影像的變異數， σ_{xy} 表示兩張影像的共變異量， C_1C_2 為常數用以維持計算過程的穩定

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3.8)$$

如式 3.9 所示，多尺度結構相似度的是建立在結構相似度的基礎上，加入多尺度的分析，其中 M 為多尺度的數量， $SSIM(x_j, y_j)$ 為計算兩張影像在第 j 個尺度下的結構相似度。

$$MSSSIM(x, y) = \frac{1}{M} \sum_{j=1}^M SSIM(x_j, y_j) \quad (3.9)$$

式 3.10 為特徵相似性的公式，其中 x 和 y 表示兩個影像中的像素值， Ω 代表影像中的所有位置。 $S_L(x)$ 代表位置 x 處的局部結構相似度，而 $PC_m(x)$ 則表示位置 x 處的相位一致性值，計算兩個影像在所有位置 x 處的局部結構相似度與相位一致性值乘積之和，然後除以所有位置 x 處的相位一致性值的總和。這樣可以獲得兩個影像之間特徵相似度。

$$FSIM(x, y) = \frac{\sum_{x \in \Omega} S_L(x) \cdot PC_m(x)}{\sum_{x \in \Omega} PC_m(x)} \quad (3.10)$$

除使用上述指標評估不同訓練樣本對結果的影響外，還計算原始影像與經過 SRGAN 強化後影像之間的 Tenengrad 分數。Tenengrad 是一種用於計算影像梯度的方法，可量化影像中的邊緣強度和細節程度(Pech-Pacheco et al., 2000)，根據式 3.11，使用 Sobel 運算子 (G)來計算影像中每個像素的水平和垂直梯度，然後將其平方和加總以獲得最終的 Tenengrad 分數。透過比較原始影像和 SRGAN 強化後影像的 Tenengrad 分數，了解影像的邊緣強度和細節程度是否有改善。

$$T = \sum \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (3.11)$$

3.4 線上自主學習框架

在傳統的機器學習方法中，通常需要耗費大量時間和精力進行手動標記的訓練數據。然而，I²PDM 系統具有持續收集新的黏蟲紙樣本的能力。為充分利用系統數據流的優勢，我們提出一個自動化的在線學習框架，它可以自動收集新的數據集，並用這些數據重新訓練和更新模型，隨著時間的推移不斷提升模型的效能，而且無需額外的人力投入。如圖 3-10 所示，該框架主要分為四個部分：（1）線上樣本收集；（2）樣本清理；（3）模型再訓練；（4）模型更新。

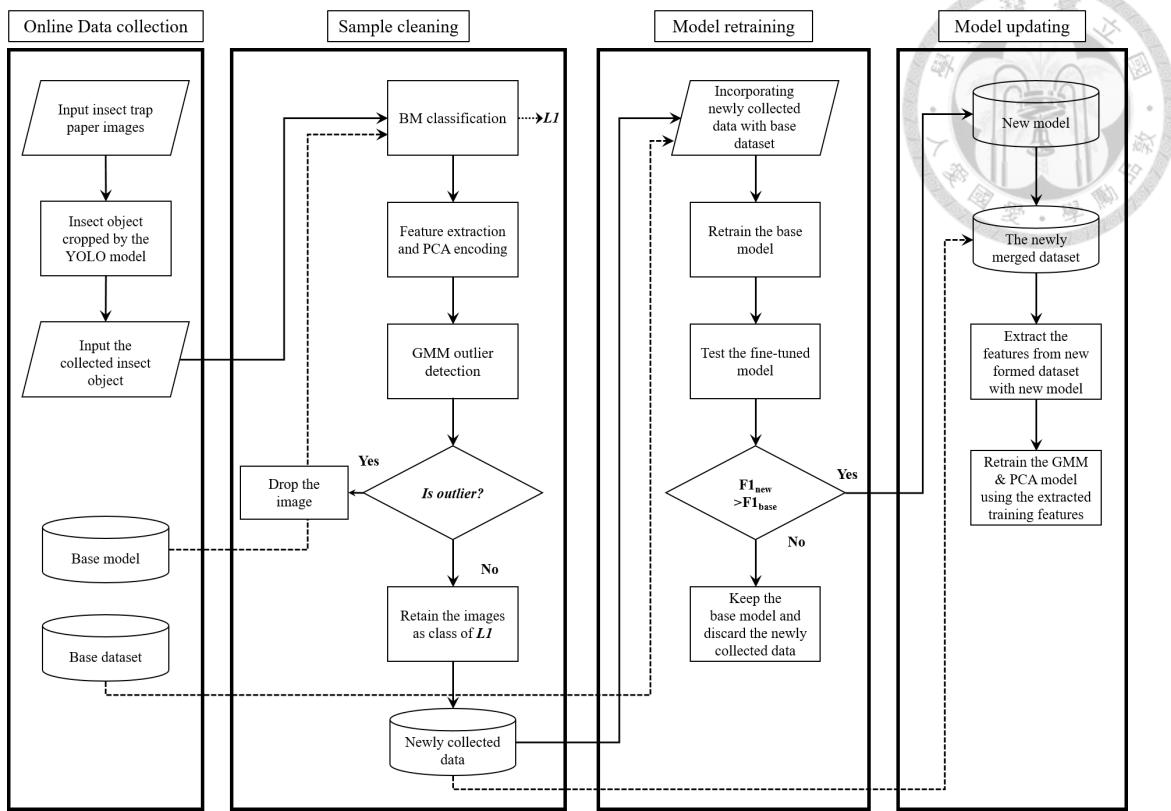


圖 3-10 線上自主學習流程圖

3.4.1 自動害蟲影像收集

I²PDM 無線取像裝置如圖 3-11 (a)，使用樹梅派 4B 做為裝置的核心，結合各項溫室環境感測器，並配備有 Raspberry pi camera v2 用來對安置在鋁製手臂上的黏蟲紙取像，藉由 Wi-Fi 將影像傳輸到實驗室伺服器分析。每天從早上六點到晚上七點之間，裝置每隔 10 分鐘取像一次。並會定期更換黏蟲紙，而在更換之前取得的最後一張影像被作為自動害蟲影像收集的資料集，因為更換前的最後一張影像會含有最多害蟲。然後，使用先前所訓練的 YOLOv3 tiny 物件偵測模型 (Rustia et al., 2020)，從 3200 x 2400 像素的黏蟲紙影像中擷取害蟲物件，這些被擷取的害蟲影像會在下一階段做進一步處理。

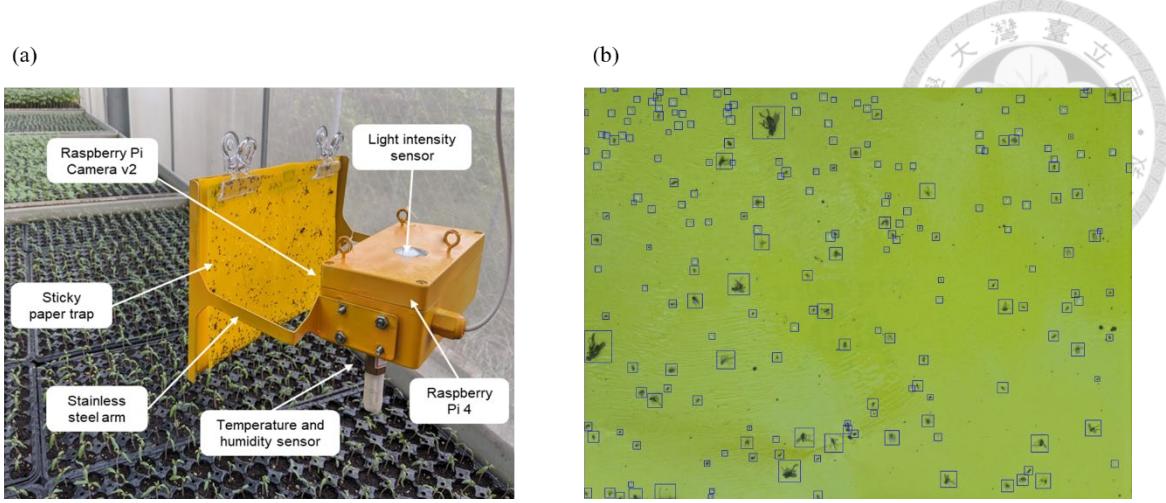


圖 3-11 本實驗室前期所發展之 (a)I²PDM 無線取像裝置；與 (b) 其 YOLO 物件偵測模型辨識結果

3.4.2 害蟲樣本清理流程

先前所得到的害蟲樣本會經過當前系統部署中，稱為基礎模型 (base model, BM)的分類器進行自動分類，以供後續模型再訓練使用。然而，除模型本身能力可能造成的錯誤分類外，實際情況中，黏蟲紙上可能會出現一些不屬於模型所分類類別的昆蟲。這些情況對模型來說可能是異常值 (outlier)，代表著訓練數據集中未出現的昆蟲物種。為提高線上學習過程中新收集害蟲樣本的分類準確性，我們提出一套樣本清理的演算法。

首先，我們使用基礎模型對訓練集進行特徵提取，並將基礎模型的最後一層輸出作為特徵，這組特徵稱為訓練特徵 (training features)。接著使用 PCA 對這些特徵進行降維，它可以在最小訊息損失的情況下對數據進行壓縮，從而減少計算資源並加快處理速度。接下來，使用高斯混合模型 (gaussian mixture model, GMM)對每個類別的訓練特徵進行訓練 (Reynolds, 2009)。並利用訓練過後的 GMM 對其對應的類別計算機率分布，由於高斯機率密度函數的值可能非常接近零，甚至可能下溢至零，因此常見的做法是對這些機率值取對數 (log-probabilities) (Domingues et al., 2018)。

最後，根據訓練數據中樣本的累積機率百分位數，計算篩選閾值。這個百分位數表示在訓練數據中有多少百分比的樣本小於或等於該值。在篩選過程中，新

進樣本會首先經過基礎模型分類，然後提取特徵並進行 PCA 降維。接下來，利用該樣本對應類別的 GMM 計算對數機率，如果機率值高於所設定的閾值，則保留該樣本；反之則捨棄，這表示該樣本可能會是異常值。透過這個方法確保盡可能收集到最適合的資料集，同時過濾掉異常值。樣本清理流程如圖 3-12 所示。

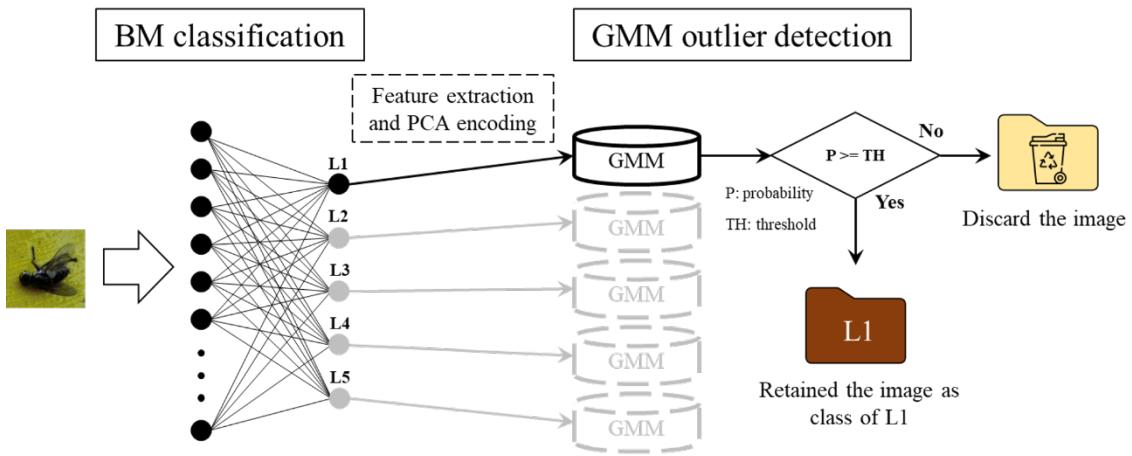


圖 3-12 樣本清理流程

其中有兩個參數需要事先決定，在樣本清理過程中，PCA 的降維維度使用累積解釋方差比 (cumulative explained variance ratio)和輪廓係數 (silhouette score) (Rousseeuw, 1987)來決定。累計解釋變異越高有助於保留約完整的原始數據資訊，而輪廓係數則評估各類別之間資料點的分散程度。考慮到這兩個因素可以確保 PCA 降維過程中的數據完整性和聚類的有效性。在 GMM 異常檢測中，閾值的選擇需要平衡正確率和樣本保留數量之間的關係。較寬鬆的閾值會降低正確率，而較嚴格的閾值則會導致較少的樣本被保留。因此，我們會透過計算不同閾值下的樣本數和準確率之間的關係，找到適當的閾值。確保在樣本清理過程中取得正確性和樣本保留量之間的良好平衡。

3.4.3 模型再訓練與模型更新

在樣本清理完成後，將現有的害蟲影像資料集與新收集的資料合併成一個更大的資料集。接著，使用微調訓練 (fine-tuning)對基礎模型進行模型再訓練。在這個步驟中，凍結 ResNet-18 模型的前三層參數，只訓練最後一層。微調的目的是通過調整神經網絡模型的部分權重，動態地學習新樣本的特徵。這個方法可以保

留從前幾層學習到的基本特徵，同時只學習新樣本在不同時間點上的更具體特徵 (Khalifa et al., 2020)，模型再訓練的參數設置與訓練起使模型相同，其中只有 epochs 減少為 30，因為模型已經具有一定的基礎特徵，所以在這階段不需要像起使模型一樣，需要較長的訓練週期。再訓練模型完成後，將使用與測試起始模型相同的測試集對其進行評估，並計算其 F_1 -score 稱為 F_1 -new，然後將 F_1 -new 與基礎模型的 F_1 -base 進行比較，當 F_1 -new 大於 F_1 -base 時，表示再訓練模型的表現優於基礎模型，並進行下一步的模型更新步驟；如果 F_1 -new 小於或等於 F_1 -base，表示再訓練的模型表現較差，這時會將這組新進的資料捨棄，不進行模型更新步驟。

模型更新的目的是將訓練好的模型與現有的模型替換，透過這個迭代過程以持續優化系統效能，流程如圖 3-13 所示，基礎模型會被替換為重新訓練後的模型，並保留先前新收集的害蟲影像，因為這表示新收集的影像對模型的優化是有貢獻的。同時，使用更新後的模型對新形成的資料集進行特徵提取。GMM 和 PCA 模型會根據提取的訓練特徵進行重新訓練，同時也會更新異常檢測的機率閾值。此外， F_1 -base 的值也會被替換為 F_1 -new，成為新的評估基準。在本研究中，線上自主學習週期的時間設定為一個月，這意味著整個學習過程每個月執行會一次，包括線上資料收集、樣本清理、模型再訓練和模型更新。

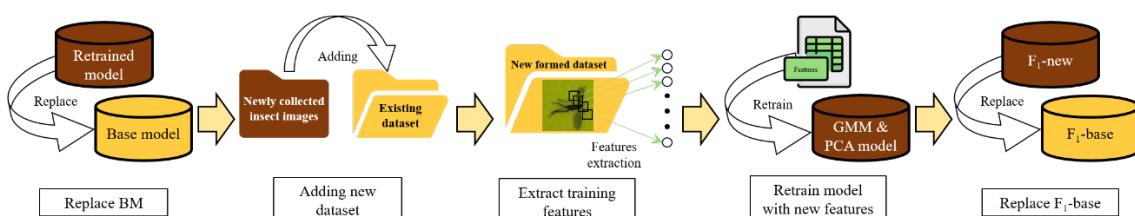


圖 3-13 模型更新流程圖

3.5 實驗場域與害蟲影像資料集

3.5.1 害蟲標的

本研究選定八種常見於黏蟲紙上的害蟲作為辨識目標，如圖 3-14，分別為：大蚊 (crane fly)、蠅 (fly)、蕈蠅 (gnat)、蠓 (midge)、蚊 (mosquito)、蕈蚋 (moth fly)、蘿馬 (thrips)與粉蠅 (whitefly)，大蚊和蕈蠅的幼蟲以植物根部為食，可能導致植物

根系受損；蠅和蠻的幼蟲在植物組織上產卵並以植物為食，可能造成植物組織的腐爛和破壞；蚊和蕈蚋的幼蟲以植物根部和有機物為食，可能導致根系受損和破壞；薊馬以植物的細胞汁液為食，可能造成植物組織的損害且常常攜帶與傳播病菌；粉蟲則以植物汁液為食，大量粉蟲會聚集在植物上，引起植物生長不良並傳播病毒。這些害蟲對農作物的危害可能導致植物生長受阻、產量減少，並使植物容易受到其他病害的感染。

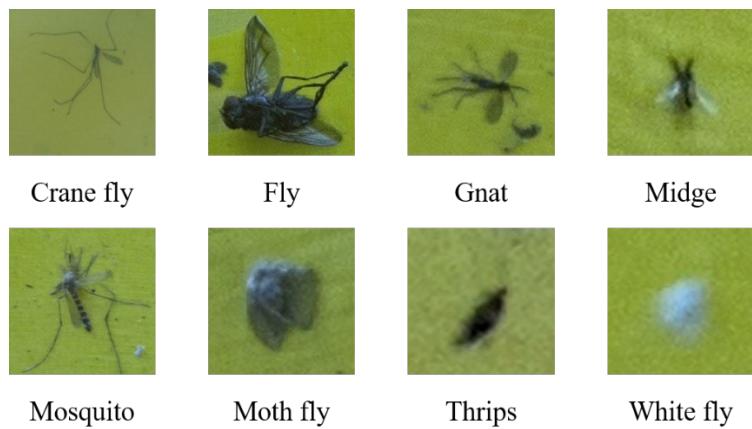


圖 3-14 各種類害蟲典型的型態

3.5.2 害蟲影像資料集

在資料集收集時，發現大蚊與蚊子類別的樣本數較少，所以只使用其餘六個類別進行方法的驗證。在實際部署於系統時，因累積較多樣本，才將大蚊與蚊子類別的資料加入，使用所有八種蟲類的資料。

本研究總共使用兩組不同的資料集：（1）SRGAN 成對害蟲樣本；（2）分類模型訓練用資料集。其中 SRGAN 成對樣本是從實驗室前期收集的資料中，隨機選取每個類別 450 張，大小為 128 x 128 的害蟲影像作為訓練集。同時，選取另外 150 張影像作為測試集，用以建立並比較不同訓練樣本數量對 SRGAN 模型的影響。訓練與樣本資料統計如表 3-3。

表 3-3 SRGAN 影像增強模型的訓練與測試資料集統計

Class	Training	Testing
Fly	450	150
Gnat	450	150
Midge	450	150
Moth fly	450	150
Thrips	450	150
Whitefly	450	150

第二組資料集用於訓練害蟲分類模型，因為先前的資料集已經被縮放至 128 x 128 的大小，無法應用於手工特徵的擷取，因此，重新收集一組包含原始尺寸資訊的資料集。其害蟲影像由位於雲林和嘉義兩個育苗場的 17 台 I²PDM 無線取像裝置中收集。這兩個場地被選擇是因為收集較長期的資料，具有較完整的時間序列資料，以利線上自主學習方法的測試。訓練害蟲分類模型使用 2018 年的資料，其中 80% 的資料用於訓練，另外 20% 的資料用於驗證。從 2019 年的資料中隨機選取各 150 張影像作為測試集。隨後，使用 2020 年、2021 年和 2022 年的資料進行線上自主學習的實驗。各類別數量的統計如表 3-4 所示，其中大蚊與蚊類的統計數量為截至 2022 年的累積數量。

表 3-4 害蟲分類模型的訓練、驗證和測試資料集數量統計

Class	Training sample number	Validation sample number	Testing sample number
*Crane fly	50	12	15
Fly	214	54	150
Gnat	1472	368	150
Midge	515	129	150
*Mosquito	106	26	32
Moth fly	565	141	150
Thrips	1107	278	150
Whitefly	1454	363	150



3.6 I²PDM 相機模組升級

3.6.1 相機模組

為選擇適合的相機模組進行升級，我們比較原始的 Raspberry Pi camera v2、Arducam 16MP 和 Arducam Hawk-eye 64MP 這三款相機的規格。根據表 3-5，選擇 Arducam Hawk-eye 64MP 相機作為升級的選項。Arducam Hawk-eye 64MP 相機具有更高的解析度和自動對焦模式，能夠提供更清晰的影像。當工作距離為 100 mm 時，原始的相機 DPI 約為 662，若使用 Arducam Hawk-eye 64MP 可得到約為 1641 DPI 的影像，有顯著的提升。而在相機尺寸方面，這三款相機的尺寸都相同且都採用 MIPI 接口，這使得可以輕鬆地將 Arducam Hawk-eye 64MP 相機升級到系統中，而無需進行內部配置的更改。

表 3-5 相機參數對照表

	Raspberry pi camera v2	Arducam 16MP	Arducam Hawk-eye 64MP
Resolution	3280 x 2464	4656 x 3496	9152 x 6944
Pixel Size	1.12 x 1.12 μm	1.22 x 1.22 μm	0.8 x 0.8 μm
FOV	62.2 (H) 48.8 (V)	67.5 (H) 53.3 (V)	71.9 (H) 57.1 (V)
Focus Mode	Manual	Manual / Auto	Manual / Auto
Board Size	25 x 24 mm	25 x 24 mm	25 x 24 mm
Focal length	3.04 mm	4.28 mm	5.1 mm
Price	1,146	982	1,965

3.6.2 原始相機與高解析度相機分類模型測試

為進一步評估更換相機對於分類模型實際應用的效果，我們使用 Raspberry pi camera v2 和 Arducam Hawk-eye 64MP 相機，對同一張黏蟲紙進行拍攝，使用 YOLO 模型擷取害蟲影像，手動分類形成兩組數據集，這兩組數據集中包含相同的昆蟲，但是由不同相機拍攝所得到的影像。在固定的光源底下取像，並使用相機預設的參數，不進行任何調整或是優化。確保在比較兩種相機效益時，所觀察到的差異主要來自於相機硬體本身的特性，而非人為的設定變動。

第四章 結果與討論



4.1 影像增強模型訓練結果

本章節將說明 SRGAN 模型的訓練結果與後續分類流程的改善，根據第 3.5.2 節的說明，因大蚊與蚊類的樣本較少，所以 SRGAN 模型僅使用其餘六種蟲類進行實驗和討論。

4.1.1 初步實驗結果

根據圖 4-1 的初步訓練結果顯示，粉蟲的身體和背景呈現出不自然的黑色，這可能是因為粉蟲的顏色與其他種類的蟲體色有所不同，在訓練過程中產生衝突。為解決這個問題，我們決定從訓練集中移除粉蟲，僅使用剩下的五種蟲類進行訓練，避免粉蟲的白色在訓練過程中對其他類別的產生影響。

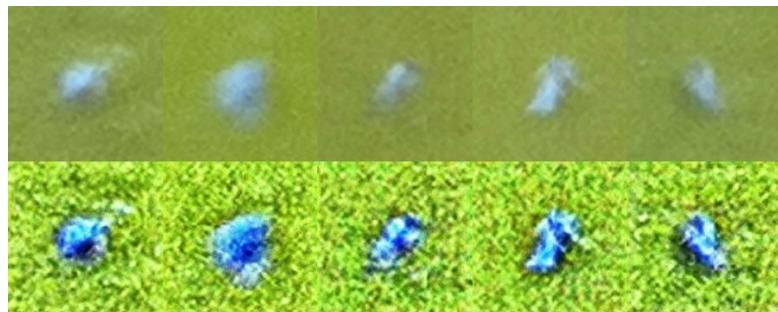


圖 4-1 初步結果顯示因粉蟲的體色造成 SRGAN 增強效果較差，在其身體與背景皆呈現不自然的黑色躁點

修正後用來訓練 SRGAN 的資料集只含有五個類別，但是這個框架被設計用於分六個類別，所以將分類流程做改善，圖 4-2 為經過改善後的影像增強分類模型流程。粉蟲在顏色上與其他物種的不同，讓模型能夠輕易區分粉蟲和其他物種。因此，在影像增強分類模型之前添加一個二分類模型，用於區分粉蟲和其他類別。如果輸入的影像被分類為粉蟲則不進行影像增強，被分為其他種類害蟲影像將進一步做影像增強，後再由分類模型得到最終分類結果，使用 ResNet-18 作為二分類模型架構進行訓練和測試，最終該模型得到約為 0.97 的 F₁-score。

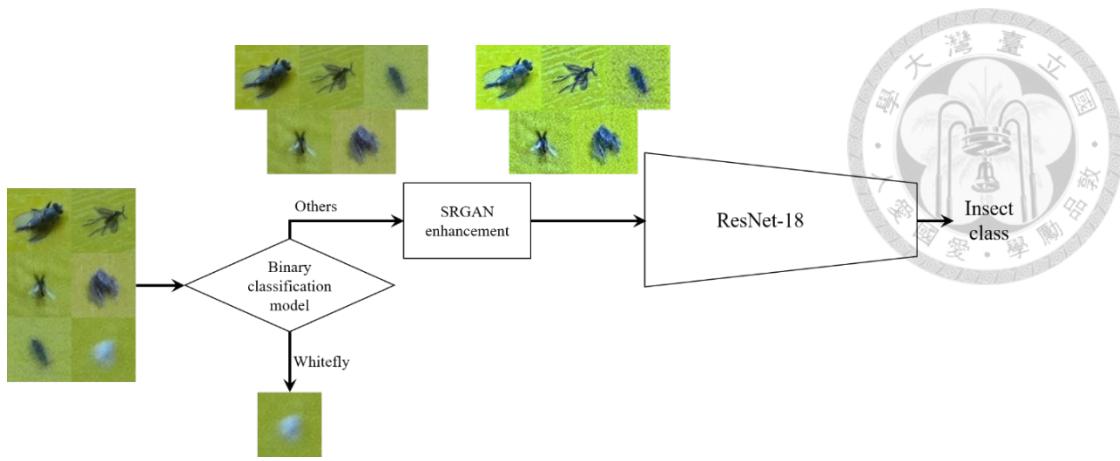


圖 4-2 修改後的影像增強分類模型流程圖，增加二分類模型區分粉蟲及其他類別，以符合 SRGAN 之訓練類別

4.1.2 影像增強方法

在圖 4-3 中，(a)為原始害蟲影像；(c)為經過 SRGAN 影像增強後之結果。原始 SRGAN 模型使用 32×32 像素的害蟲影像作為輸入，生成 128×128 像素為輸出。這樣的方法確實能提升蟲體與背景的亮度，但害蟲身體的細節與邊界卻顯得較模糊。推測是因為 32×32 的影像包含的原始資訊有限所導致。為改善此問題，我們嘗試將原始 128×128 影像直接使用 SRGAN 進行影像增強至 512×512 ，然後再將其縮放回 128×128 以符合分類模型的輸入要求。如圖 4-3 中的 (e)，改善後的方法能得到增強效果更好的影像，圖 4-3 中的 (b)、(d)和 (f)分別為經過 Sobel 濾波器處理後的影像結果。相較於原始的影像，經過 SRGAN 增強的影像在害蟲的身體輪廓和邊緣方面更加明顯。這表明 SRGAN 增強的影像能呈現出更清晰和更銳利的輪廓與邊緣，使得影像中的細節更加清晰可見。

圖 4-4 展示測試影像集的 Tenengrad 分數計算結果。結果顯示，經過 SRGAN 增強後的影像能得到更高的分數。以 32×32 作為輸入的方法在各類別的影像品質都有顯著的提升，進一步經統計檢定後，顯示皆具有統計上的顯著差異，這表示 SRGAN 對於客觀的影像品質提升有所幫助。而經過改良後的方法，在各類別也有所提升，尤其在蠅與蕈蠅上有更大幅度的清晰度提升。總體來說，SRGAN 模型在影像增強方面表現出色，但在輸入影像尺寸限制下，改良的方法可以更好地保留細節和邊界，提高影像品質和清晰度。

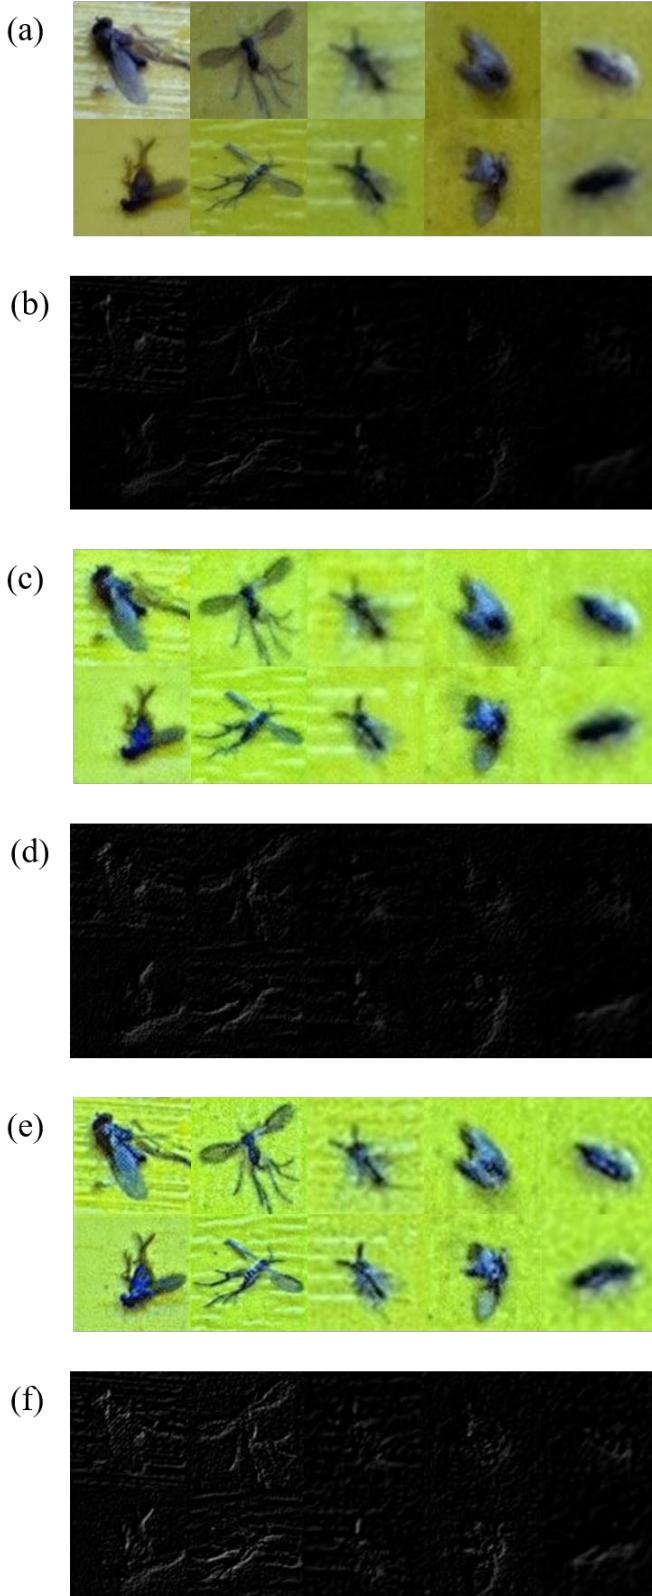


圖 4-3 影像增強結果：(a)原始影像；(c)以 32×32 像素為輸入；(e)以 128×128 像素作為輸入；與 (b)、(d)和(f)對應之 Sobel 濾波器處理後之結果，顯示出經過改良後的方法能得到更清晰的增強影像

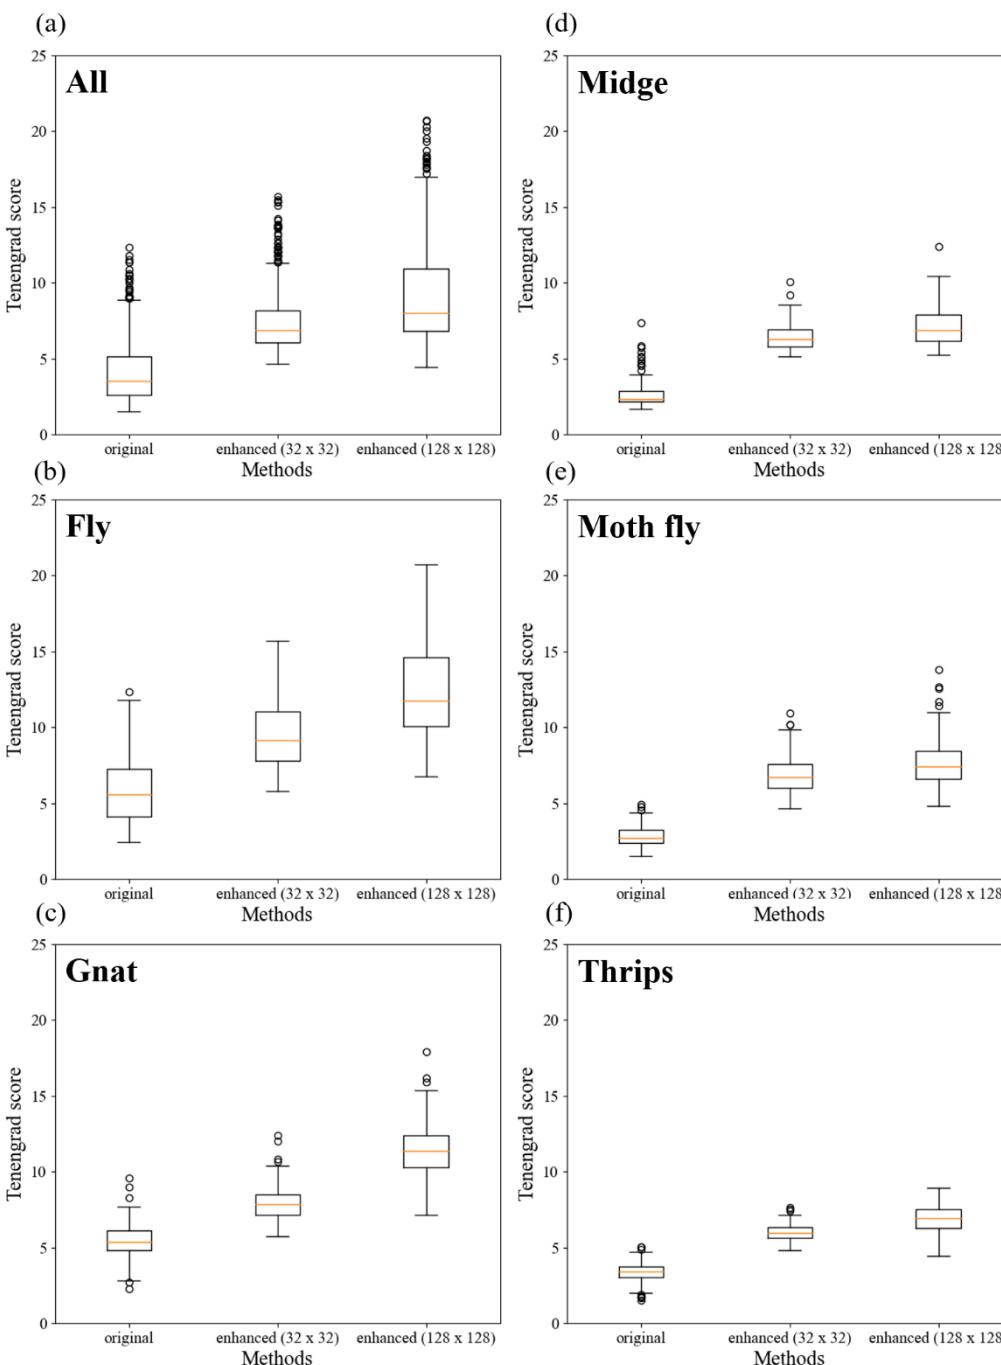


圖 4-4 Tenengrade 影像清晰度計算結果 (a)全部五種類；(b)蠅；(c)蕈蠅；(e)蠓；
 (d)蕈蚋；與 (f)薊馬

4.1.3 樣本數對於影像增強模型評估結果

在 SRGAN 模型訓練中，另外一個部份是探討訓練樣本數對於影像增強結果的影響，測試各種類 5、10、15、20、25、50、100、150、200、250、300、

350、400 與 450 張樣本並以 SSIM、MS-SSIM 與 FSIM 指標檢驗。根據圖 4-5 的結果，增加樣本數對於影像增強結果具有正向的影響。根據 SSIM、MS-SSIM 和 FSIM 指標的分數趨勢來看，隨著樣本數的增加，影像的品質逐漸提高。觀察到在大約 350 樣本後，影像增強的分數趨於穩定，並沒有明顯的進一步提升。這暗示著在樣本數超過 350 之後，增加樣本對於影像增強效果可能已經達到飽和。

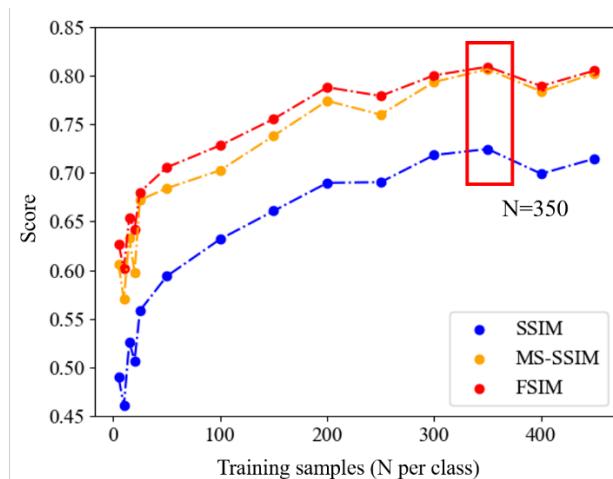


圖 4-5 不同訓練樣本數對於影像增強後的測試結果，顯示當各類別樣本數超過 350 張後，對於增加影像增強的效果已經達到飽和

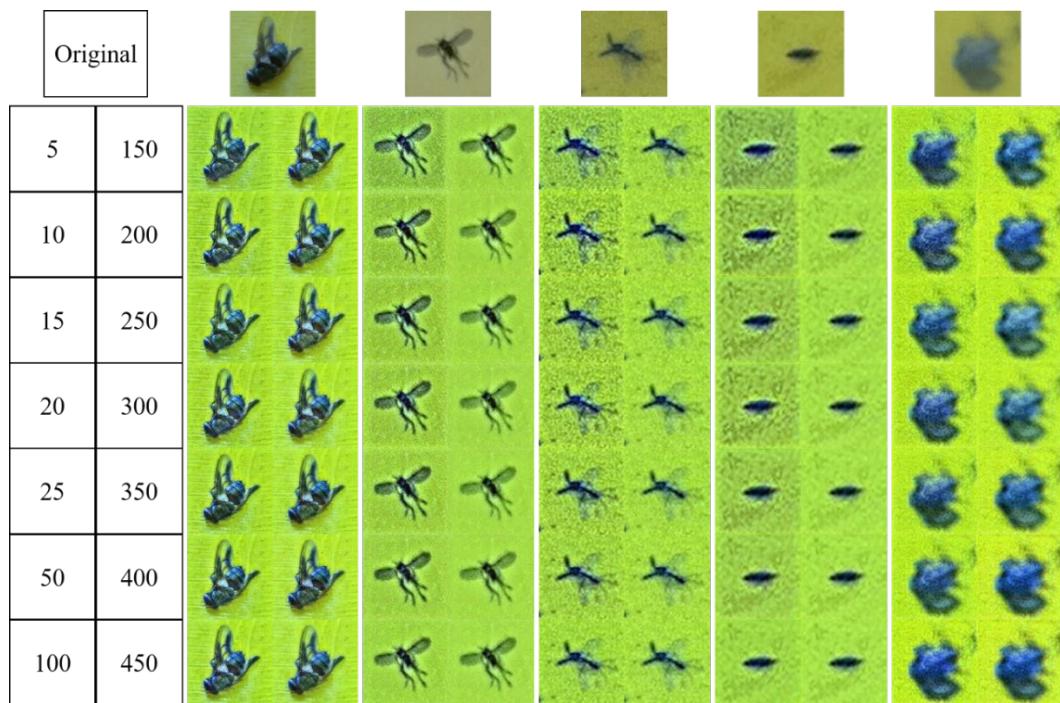


圖 4-6 不同訓練樣本的影像增強結果，顯示在訓練樣本數較少的影像中背景有較多雜訊，隨著樣本增加，雜訊逐漸減少

圖 4-6 為不同訓練樣本數的 SRGAN 影像增強結果。從圖中可以觀察到，當訓練樣本數較少時，背景中的雜訊較明顯，然而隨著訓練樣本數的增加，背景的雜訊逐漸減少。然而，當訓練樣本數超過 250 後，人眼難以察覺到進一步的改善。綜合以上測試結果，使用每個類別約 250 張樣本可以獲得良好的結果，而增加到 350 張時可以達到最佳效果。

4.2 深度學習模型訓練結果

根據 4.1.1 的內容，由於粉蟲體色對於 SRGAN 的影像增強有特殊的挑戰，分類流程被修改為先區分粉蟲與其他類別，然後再進行其他種類的分類。因此，這個章節的分類模型只會訓練並探討這五種類別：蠅、蕈蠅、蠓、蕈蚋與薊馬。

4.2.1 原始模型訓練結果

圖 4-7 為原始模型即使用 ResNet-18 架構於測試集上的測試結果，原始模型在蠓、蕈蚋和薊馬進行分類，其 F₁-score 分別約為 0.95、0.96 和 0.99。原始模型在蕈蠅上取得 100% 的高準確率；然而，有約 30% 的蠅和 9% 的蠓被錯誤歸類為蕈蠅，導致蕈蠅的 F₁-score 較低。這可能是因為蠅和蠓在翅膀或身體形態上的相似性造成的，這可能導致分類錯誤。此外，與其他類別相比，蠅的訓練數據較少也可能導致難以與蕈蠅區分。

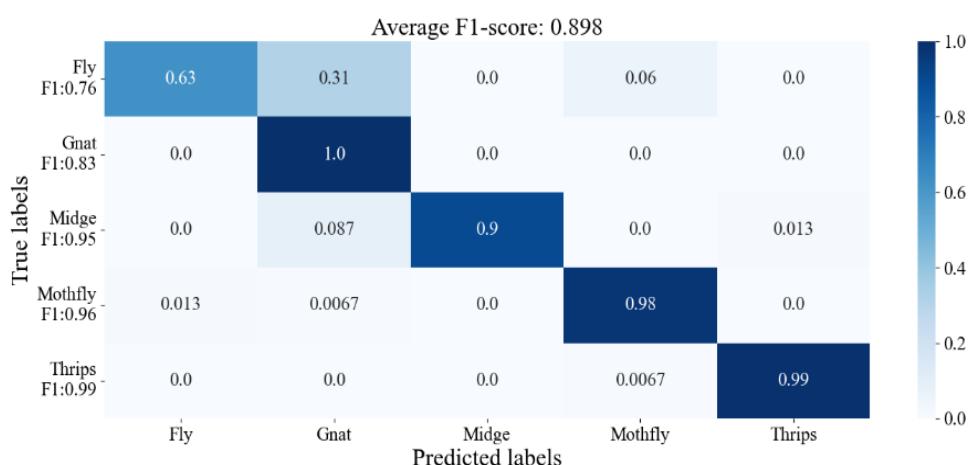


圖 4-7 原始模型測試結果



4.2.2 影像增強分類模型訓練結果

圖 4-8 為影像增強分類模型測試結果，根據混淆矩陣，該模型在蠅的準確率上提升約 9%；蠓類提升約 3%，在其餘基礎模型上表現已經很好的三種類別上較無發現顯著的提升。

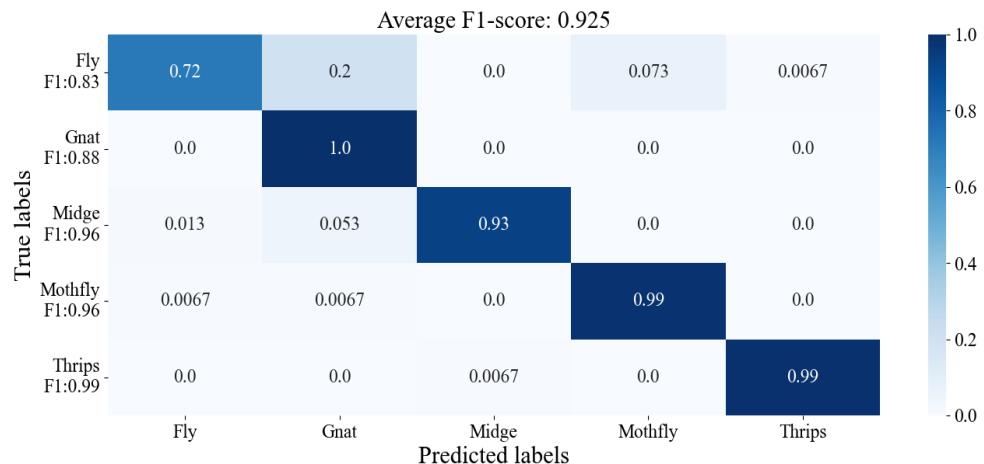


圖 4-8 影像增強分類模型測試結果

根據觀察結果，選定準確率提升差異最大的蠅和蠓兩個類別進行 McNemar 統計測試，並將顯著性水準(α)設定為 0.05，以確定這些差異是否超出隨機誤差的範圍，進一步確定是否存在統計學上的差異。經計算後顯示在蠅類中 P-value 為 0.02006，表示在統計學上具有顯著的差異，顯示影像增強分類模型在蠅類的效能上有明顯的提升。然而，在蠓類中的 P-value 為 0.26684 超過 0.05 的顯著性水準，這表示未能在統計學上確定存在顯著的差異。這結果表明，模型在蠓類的分類中的改善效果相對較小，並不是特別明顯。這個結果進一步證實我們提出的 SRGAN 影像增強方法對於提升分類器的效能具有有效性。



4.2.3 手工特徵分類模型訓練結果

圖 4-9 為尺寸特徵分類模型測試結果，該模型在蠅與蠓類的準確率都提升約 6%，剩餘類別較無顯著的提升。

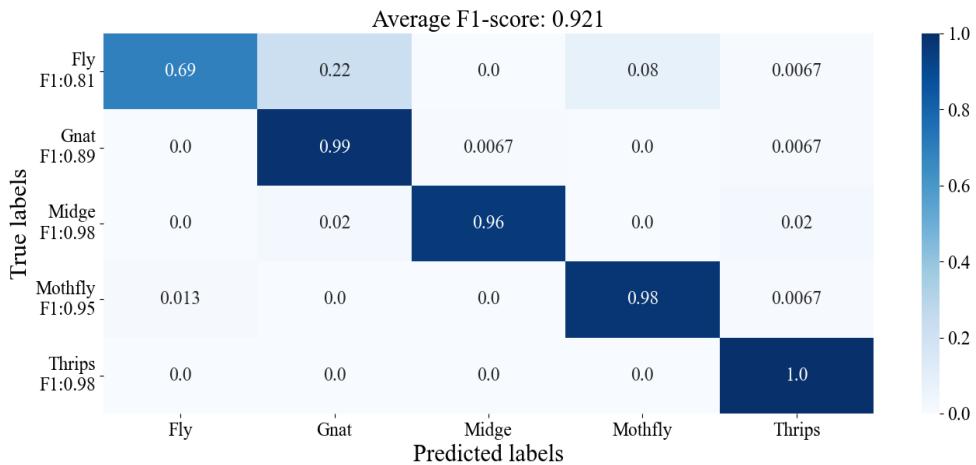


圖 4-9 尺寸特徵分類模型測試結果

在尺寸特徵分類模型也進行蠅和蠓兩個類別的 McNemar 統計測試，蠅類的 P-value 為 0.13249，顯示尺寸特徵分類模型在蠅類的分類效能提升上較無顯著差異，蠓類的 P-value 為 0.0224，顯示在蠓類的提升上是有顯著差異的。這些結果顯示，在不同的分類模型中，對於蠅和蠓兩個類別的改善效果可能有所不同。SRGAN 影像增強方法在蠅類的分類上表現較好，而尺寸特徵模型在蠓類的分類上取得顯著的提升。

進一步檢視被提取的尺寸特徵分布，可以觀察到蕈蠅和蠓類之間的尺寸特徵分布存在較大的差異。這表示蕈蠅和蠓類在尺寸上有明顯的差異，因此在模型中加入尺寸特徵能夠更好地區分這兩個類別。在蠅和蕈蠅之間，尺寸特徵的分布雖然也有差異，但部分尺寸仍然有重疊。這也解釋蕈蠅和蠅類在混淆矩陣和統計測試結果中仍然存在一定程度的混淆。在進行害蟲分類時，僅使用單一特徵可能無法完全解決所有類別之間的混淆問題，因此，在下一小節我們嘗試將兩種優化方法結合，形成第三種方法。

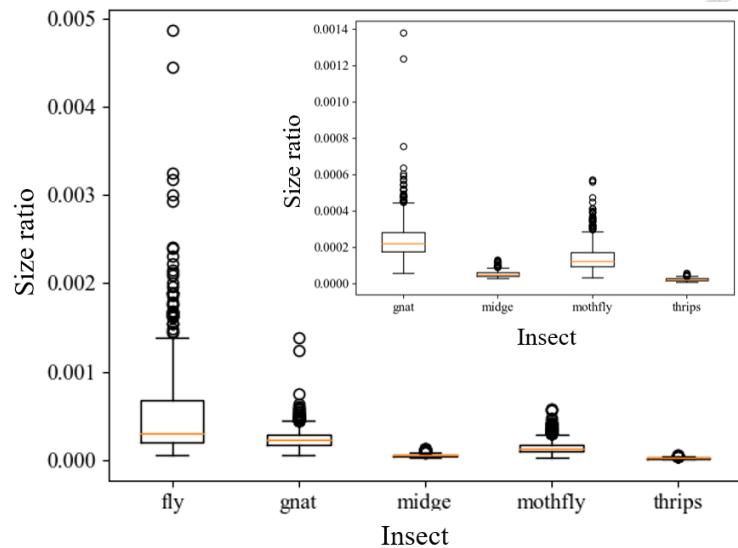


圖 4-10 手工擷取尺寸特徵分布

4.2.4 影像增強結合手工特徵分類模型訓練結果

根據 4-11 所示的測試結果，在蠅的分類，結合影像增強和手工特徵後取得約 18% 的提升，而在蠓類的分類中取得約 7% 的提升。這結果顯示，結合影像增強和手工特徵可以有效改善模型對於蠅和蠓類別的辨識能力。然而，這種結合的方法可能會導致在其他類別上的性能略有下降，例如在蕈蚋和薊馬的 F₁-score 下降約兩個百分點。這可能是由於在影像增強過程中或尺寸特徵中存在會令模型混淆的特徵所導致的。儘管犧牲某些類別的效能，在平均的 F₁-score 仍然有顯著的提升，從原始的 0.898 提升約四個百分點達到 0.942。

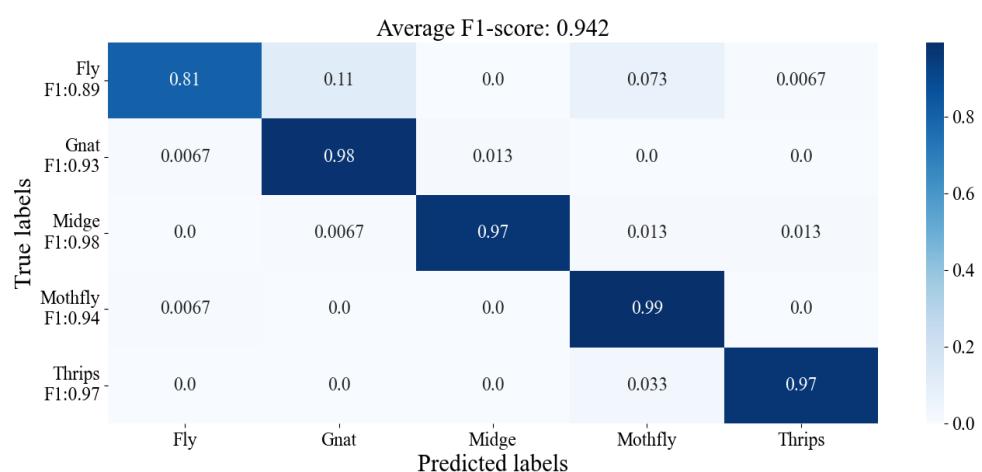


圖 4-11 影像增強結合尺寸特徵分類模型測試結果

McNemar 統計結果顯示蠅與蠓的 P-value 分別為 0.00004 與 0.000183，顯示結合兩種方法的模型在這兩類別的分類任務上取得顯著的提升。這些測試和統計結果表明，本研究所提出的模型優化方法確實能夠提升模型的效能。將這些方法應用於 I²PDM 系統中，能夠提供更準確的資訊，進一步改善害蟲辨識的準確性。

4.3 線上自主學習

本章節將探討自動化線上自主學習演算法的結果，包括演算法中參數的選擇、線上學習迭代訓練的結果與樣本清理演算法的探討，並且在每個月的黏蟲紙樣本中手動挑選測試樣本，進一步測試該演算法對於動態系統的效能改善。在這個章節，我們會使用 4.2 章節訓練的四種模型，做為線上學習的基礎模型，比較不同模型間的差異性，模型代號與其架構如表 4-1 說明。

表 4-1 使用於線上自主學習的基礎模型代號與其架構

Model	Model ID	Model architecture
Original model	Model A1	Original
Model with image enhancement	Model A2	Image enhanced
Model with size features	Model A3	Size feature
Model with image enhancement and size features	Model A4	Image enhanced with size feature



4.3.1 樣本清理參數選擇

在本研究中所提出的上自主學習架構，其中有兩個需要設定的參數，分別是 PCA 的降維維度和 GMM 樣本清理閾值的百分位數。在建立基礎模型後，從訓練集的害蟲影像中使用基礎模型提取訓練特徵，並利用這些訓練特徵來確定最佳的 PCA 降維維度。圖 4-12 顯示四種模型提取的特徵在不同維度下的 PCA 累積解釋方差比和輪廓係數的變化。結果顯示，隨著維度的增加，累積解釋方差比也增加。然而，輪廓係數並不一定隨著維度的增加而增加，實際上，在維度為四時達到峰值。這種現象可能是由於增加維度引入一些冗餘特徵或噪音，從而導致數據點之間的距離增大，聚類效果變差。此外，增加維度還可能導致特徵空間變得更加複雜，增加計算的成本。基於以上觀察和分析，最終決定將特徵的降維維度從設定降到四。這樣做有助於簡化特徵空間，提高聚類效果，同時減少冗餘特徵和雜訊的影響。

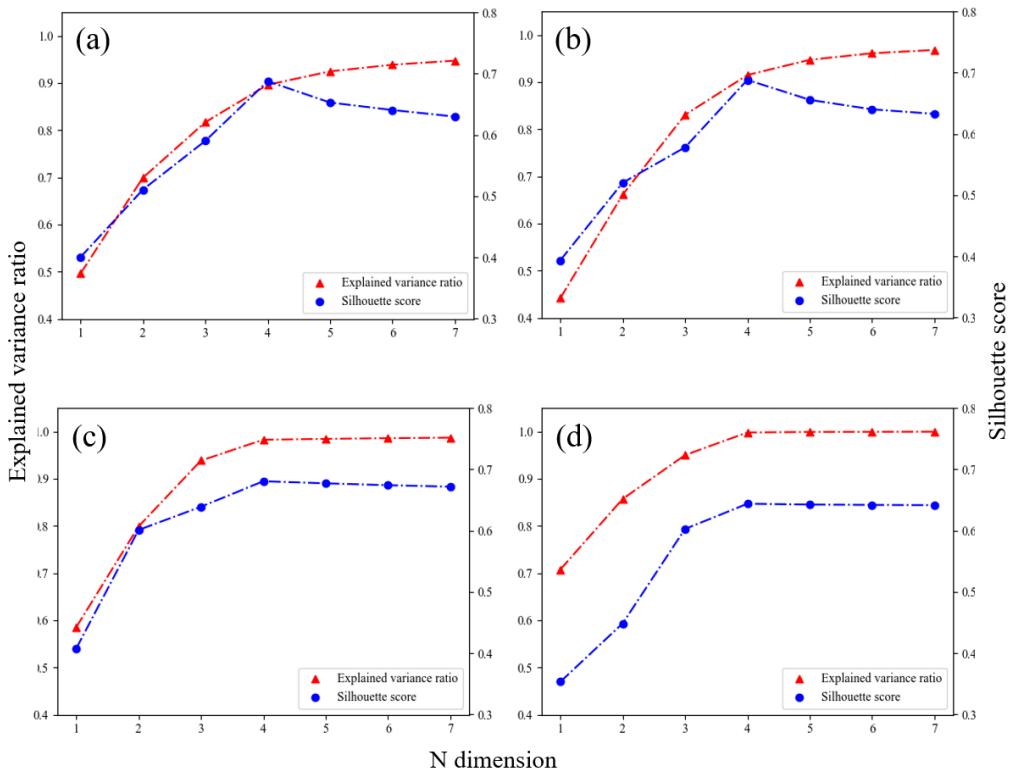


圖 4-12 PCA 維度與累積解釋方差比與輪廓係數的趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與(d) Model A4，顯示當降為四個維度時有最好的表現

在樣本清理閾值的選擇中，使用訓練好的 GMM 模型將訓練資料集的機率分佈繪製成直方圖，圖 4-13 呈現害蟲訓練集的對數機率分佈圖，其中的示意線表示第 10 百分位數。使用 2019 年的數據集進行閾值測試，僅做樣本篩選，不做模型再訓練或更新。同時測試不使用樣本篩選與設定閾值為第 5、10、20、30、40、50、60、70、80 和 90 百分位數。計算每個月樣本的平均數量和篩選後的樣本準確率，如圖 4-14 所示。為在樣本數量和準確率之間取得最佳平衡，進行以下步驟計算最佳權衡。首先對原始數據進行正規化（圖 4-15），然後進行微分（圖 4-16），最後使用式 4.1 計算在減少單位樣本數量的情況下準確率的增加量，透過這種方法，可以找到在樣本數量和準確率之間的最佳平衡點。

$$\text{Increasing rate} = \left| \frac{\text{Accuracy}}{\text{Counts}} \right| \quad (4.1)$$

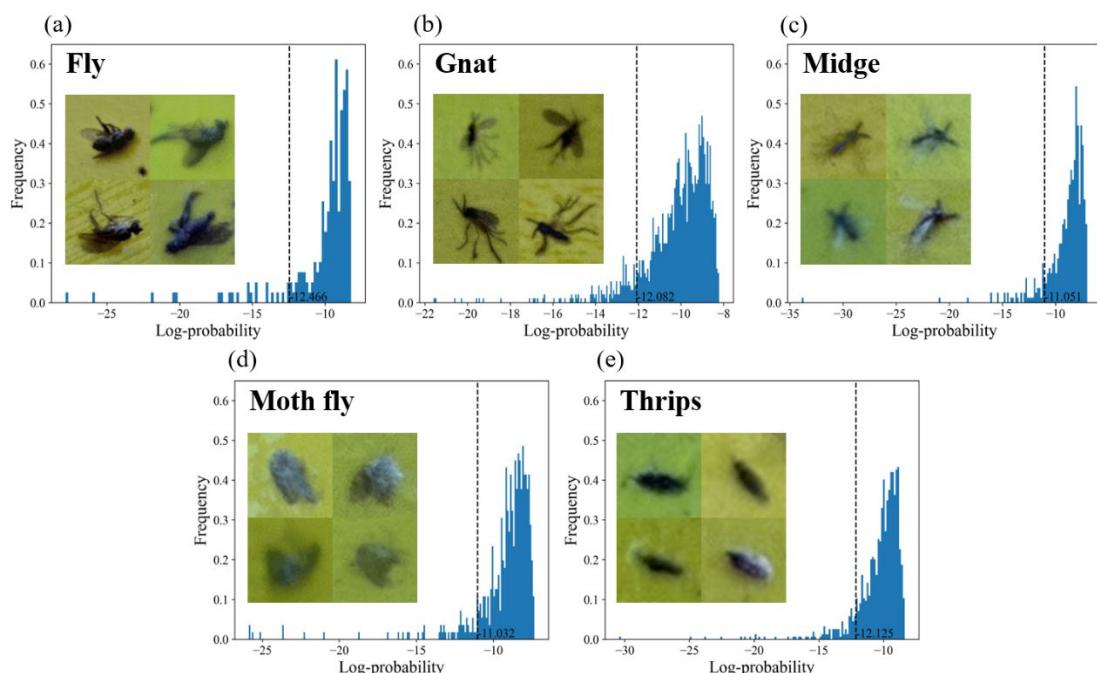


圖 4-13 害蟲訓練集的對數機率分布圖與第十百分位數示意線：(a)蠅；(b)蕈蚊；(c)蠻；(d)蕈蚋；與 (e)薊馬

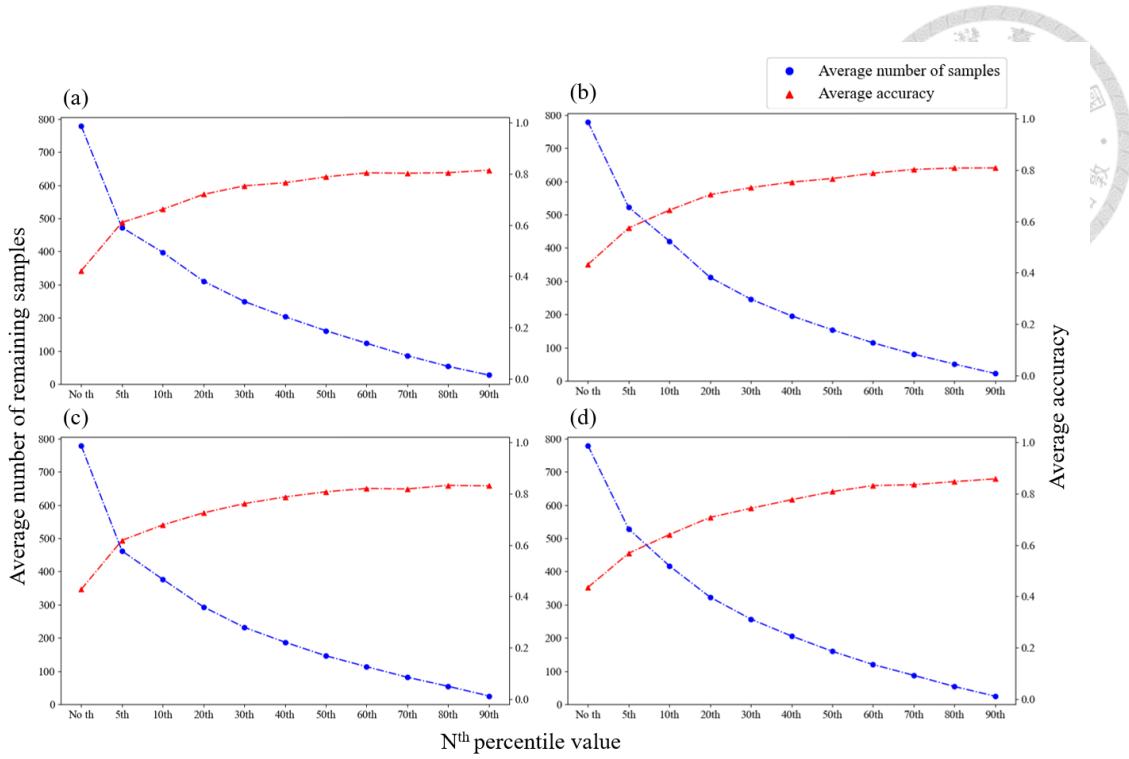


圖 4-14 不同閥值對於樣本數量和準確率趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4

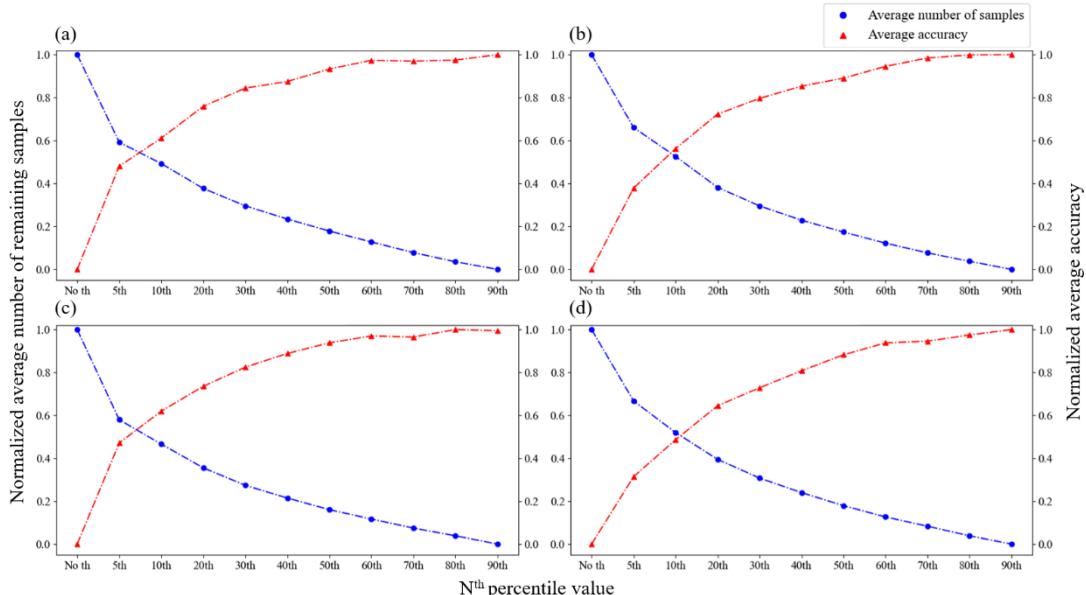


圖 4-15 經正規化後不同閥值對於樣本數量和準確率趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4

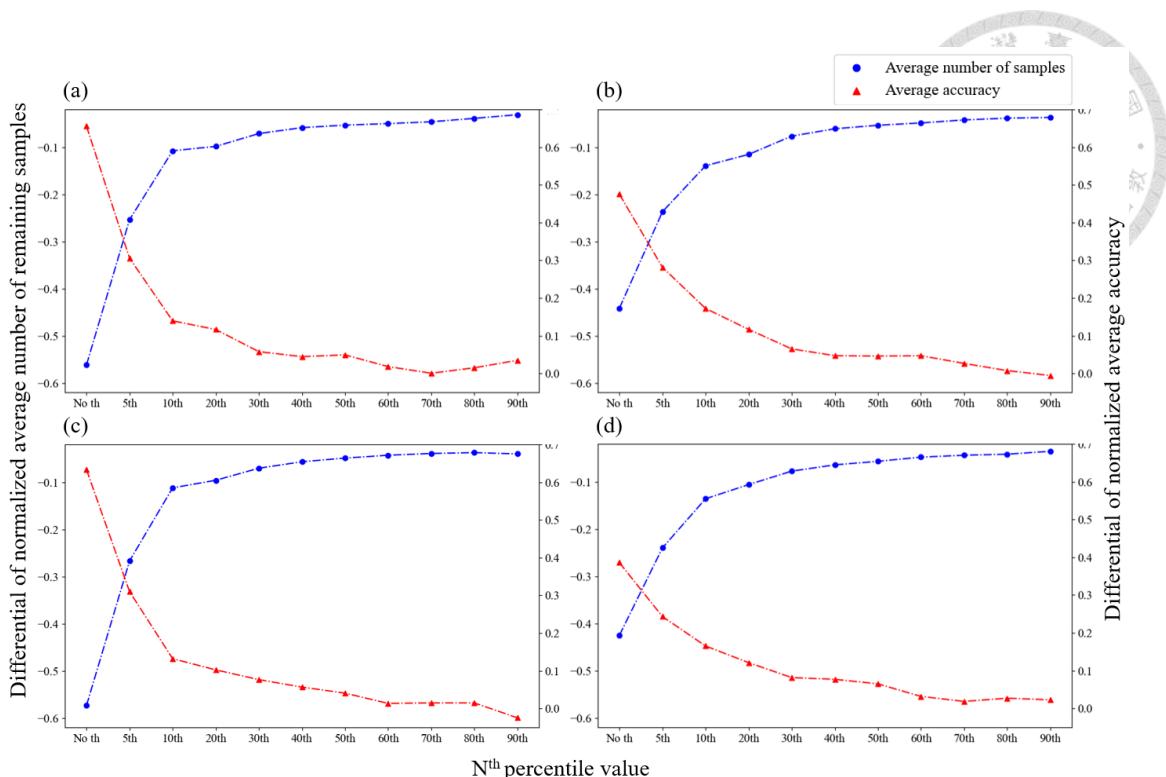


圖 4-16 經微分後不同閥值對於樣本數量和準確率趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4

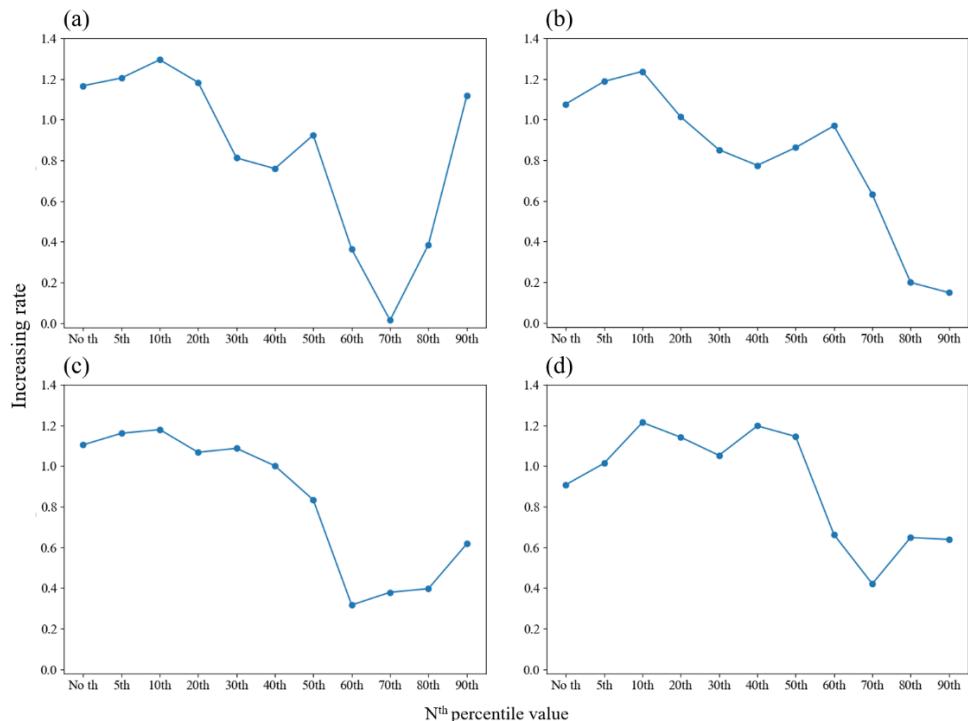


圖 4-17 不同閥值對於 Increasing rate 的趨勢圖：(a) Model A1；(b) Model A2；(c) Model A3；與 (d) Model A4

根據上述圖表的結果，可以得出以下結論。以原始模型為例，如果不使用 GMM 異常值檢測，平均準確度僅約為 0.4。然而，加入第五百分位數的閾值篩選後，準確度提高至約 0.61，同時平均樣本數量減少約 40%。進一步將閾值提高至第十百分位數時，準確度約為 0.67 左右，平均樣本數量減少約 15%至約 400 個。將閾值提高至第 20 百分位數時達到約 0.71 的準確度，但同時損失約 23%的樣本數量。儘管將閾值提高至第 90 百分位數可以達到約 0.8 的平均準確度，但平均樣本數量僅減少至約 30 個。根據式 4.2 的計算結果和上述圖表中四種模型的趨勢，都顯示選擇第十百分位數作為樣本清理的閾值能夠取得最佳的權衡。因此，在這四種模型的線上自主學習演算法中，選擇第十百分位數作為樣本清理的閾值。

4.3.2 線上自主學習迭代訓練結果

本研究的目的是提出一種自動化的方法，用於收集新進樣本並進行訓練，以進一步提升分類模型的效能。為比較所提出的方法是否能取代傳統的人工方法，在本小節中進行兩個實驗。第一個實驗根據第 3.4 章說明的線上自主學習演算法，並將 GMM 樣本清理的累積機率閾值設定為第十百分位數做測試，另一個實驗則使用監督式線上學習的方法，把 GMM 樣本清理演算法替換成由人工篩選的方式，再進行模型的訓練和更新。使用雲林和嘉義兩個育苗場的 17 台 I²PDM 無線取像裝置，從 2020 年 1 月到 2022 年 12 月所收集的黏蟲紙資料集進行演算法的測試。

圖 4-18 (a)顯示以 Model A1 作為基礎模型，在每個線上自主學習週期中的測試結果。對於一開始表現不佳的類別，如蠅和蕈蠅，隨著每個訓練週期中與新篩選樣本的結合訓練，分類模型在這兩個類別上的表現逐漸提升。然而，在剩下的三個初始表現較好的類別中，改善效果較不顯著，推測模型在這三個類別的性能上已達到飽和，新增訓練樣本和模型再訓練的效果有限，相較之下其他兩個類別的訓練靈活性較高，在使用線上自主學習方法時顯示出更顯著的性能改善。圖 4-18 (b)為使用監督式線上學習的測試結果，其各類別的趨勢與線上自主學習類似，在起使表現較好的類別有穩定成長的趨勢，而在剩下的類別呈現持平的狀態。

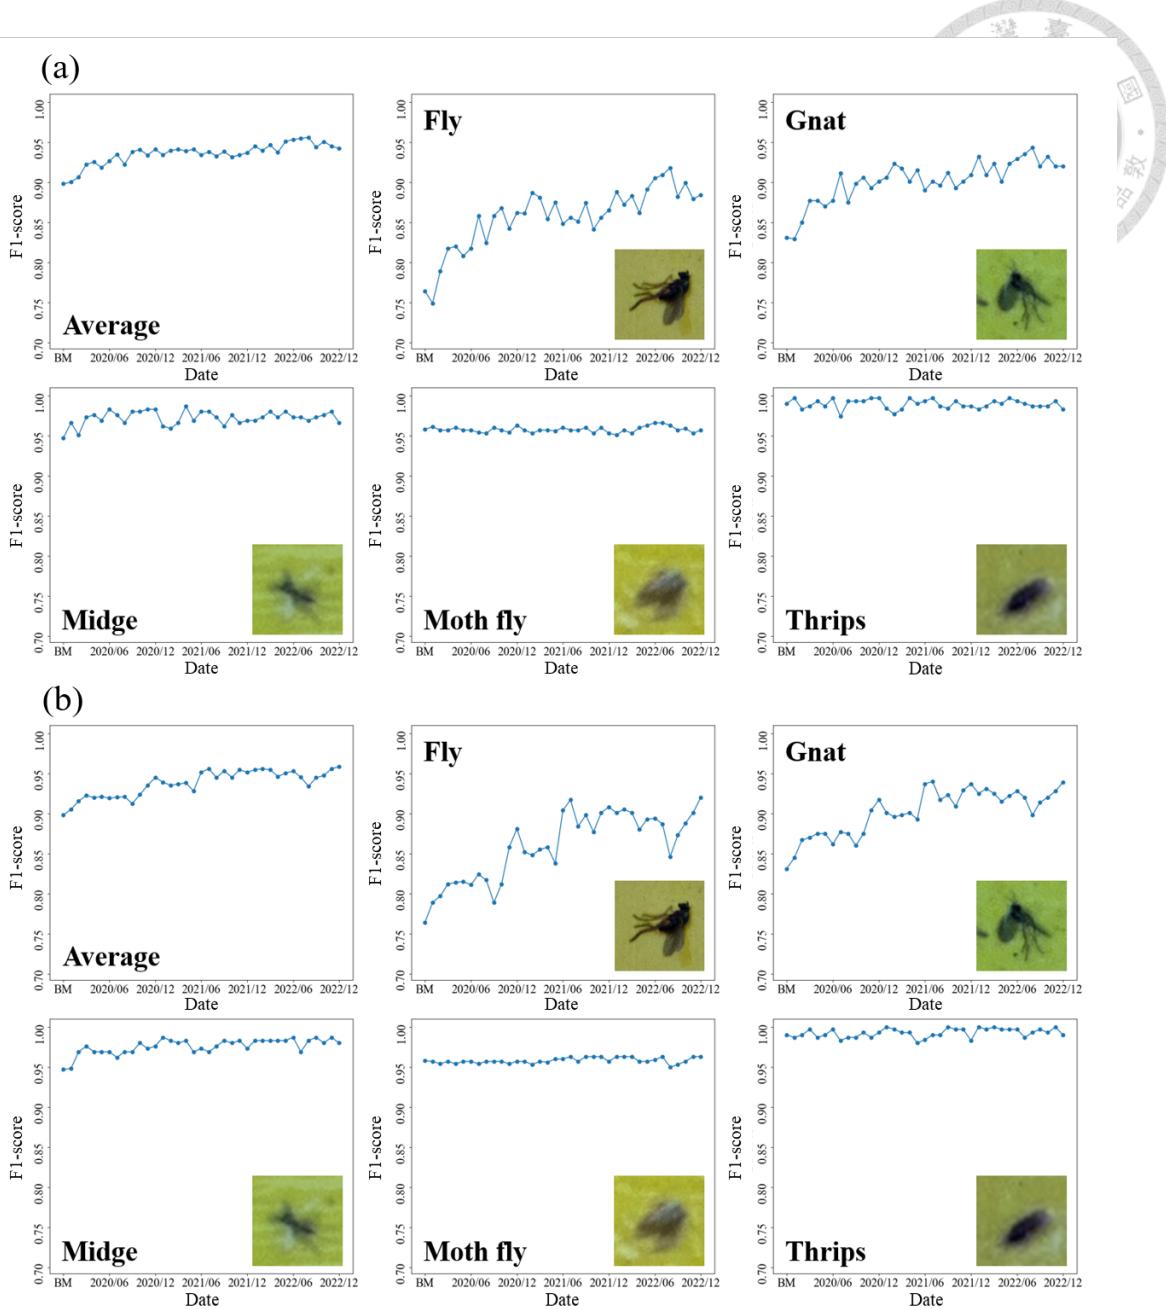


圖 4-18 使用 Model A1 進行 (a)線上自主學習；與 (b)監督式線上學習之結果

圖 4-19 為使用 Model A1 作為基礎模型，經過三年的迭代訓練所得到表現最好的模型，稱為最終模型的測試結果。使用線上自主學習方法的最終模型，其 F_1 -score 由 0.898 成長 5.8%，達到 0.956。而使用監督式學習的方式則是提升約 6.1%，達到 0.959 的 F_1 -score。兩種方法的結果相差不大，僅在蠛這個類別上存在約 1% 的 F_1 -score 差異。這些結果顯示，在進行模型訓練和更新時，線上自主學習方法能在無需人力介入的情況下達到與監督式學習方法同樣顯著的效能提升。

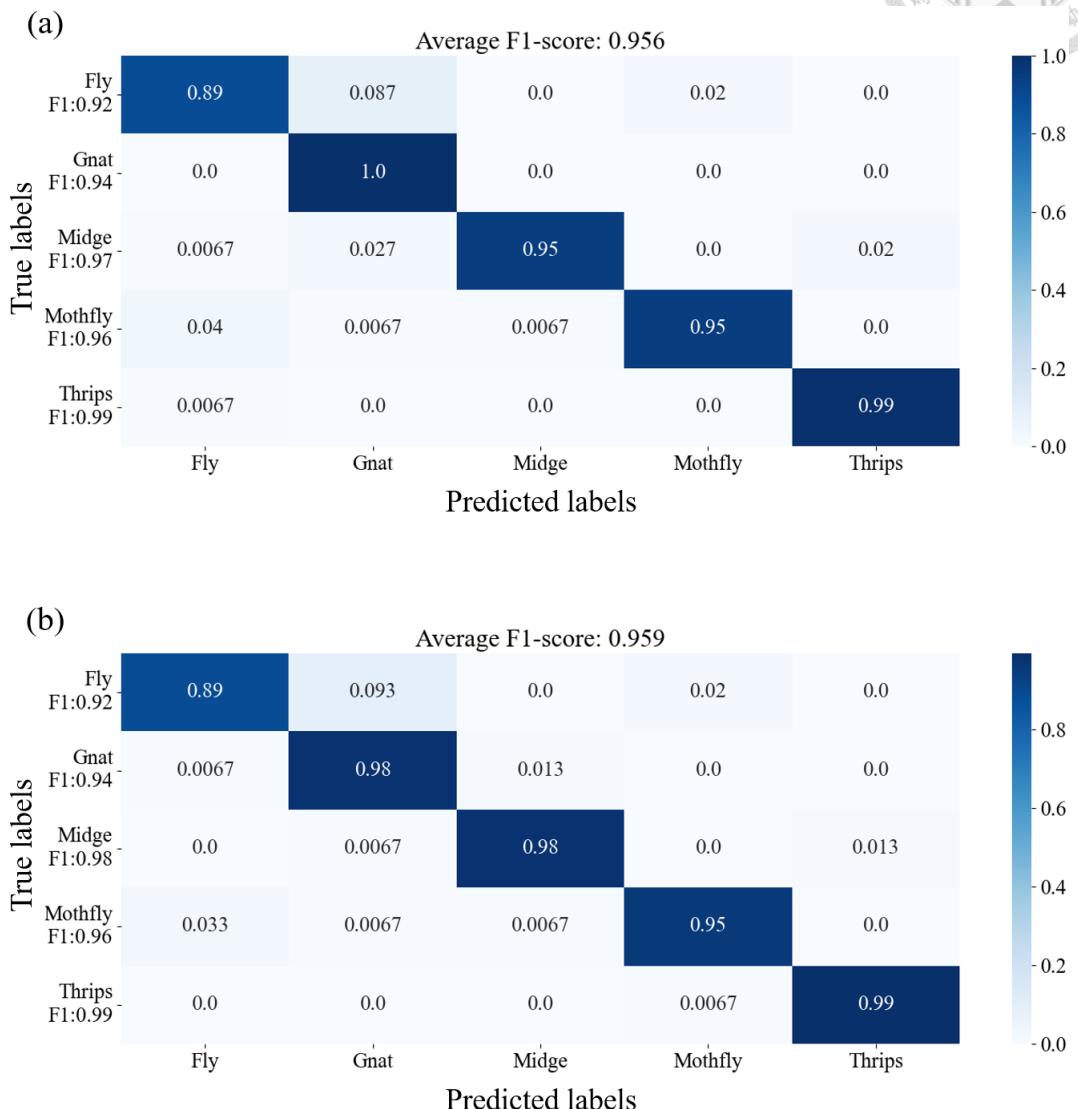


圖 4-19 Model A1 經 (a)線上自主學習；與 (b)監督式學習的最終模型測試結果

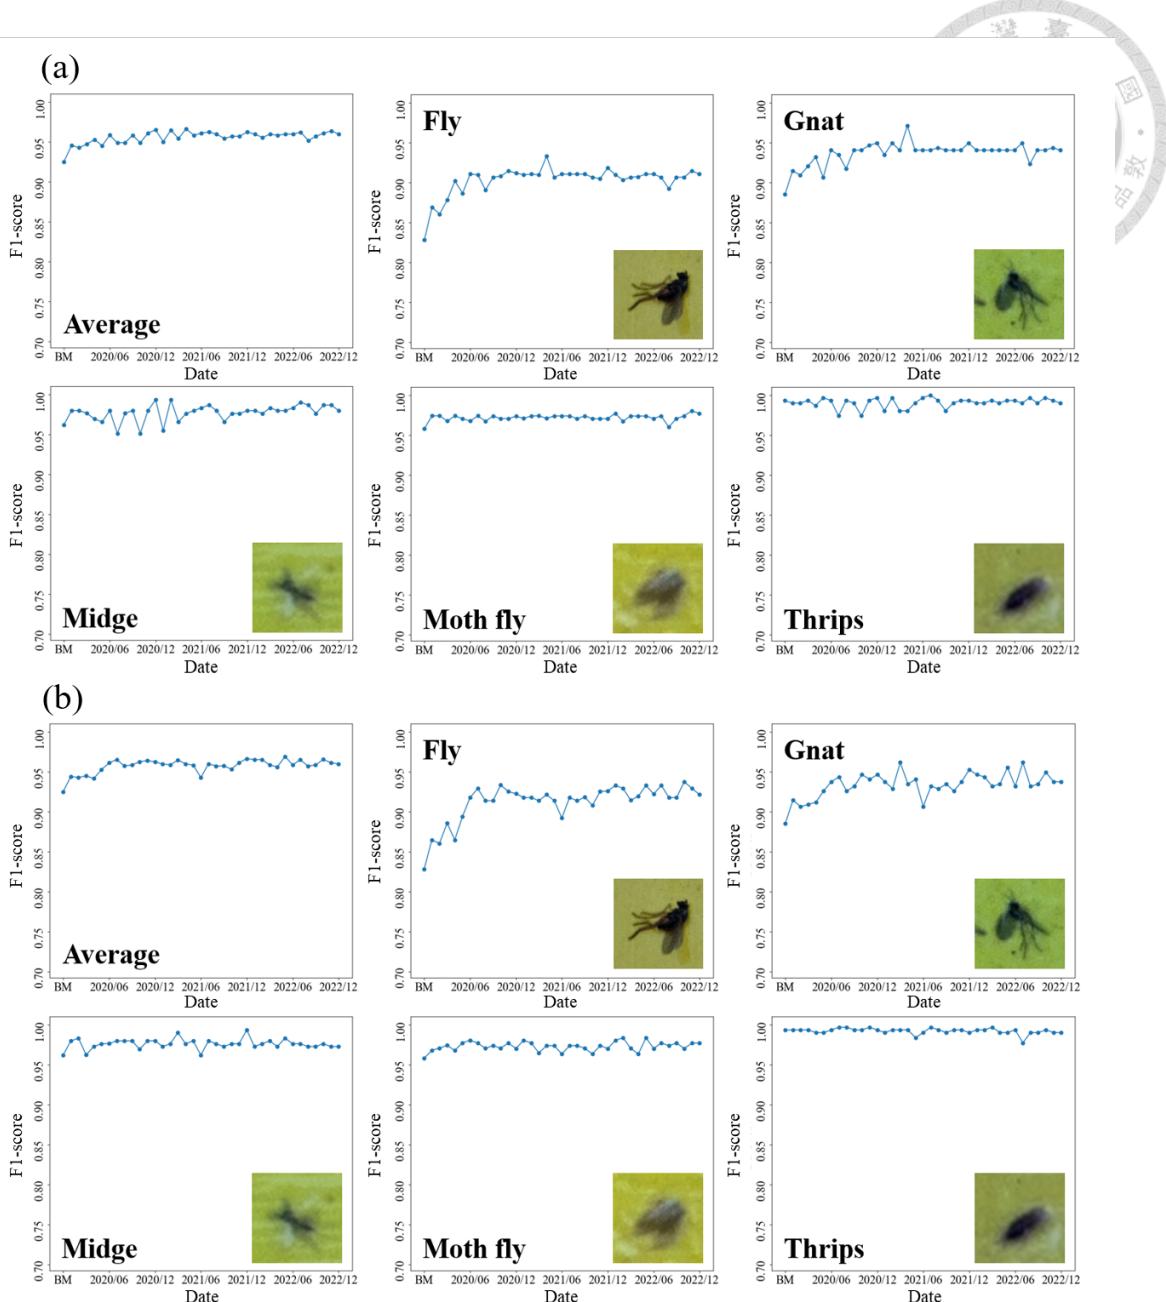


圖 4-20 使用 Model A2 進行 (a)線上自主學習；與 (b)監督式線上學習之結果

圖 4-20 為以 Model A2 作為基礎模型時的線上自主學習訓練結果。與圖 4-18 類似，在起始較不好的類別有較明顯的提升，而在相對優異的類別較無顯著差異。進一步觀察發現，不論是使用自主學習或是使用監督式學習，在前面七個月的提升較為明顯，之後則較無顯著的提升，推測該模型在經過前期的迭代訓練後，效能已經達到飽和的狀態，持續增加訓練樣本的效果已經不明顯。

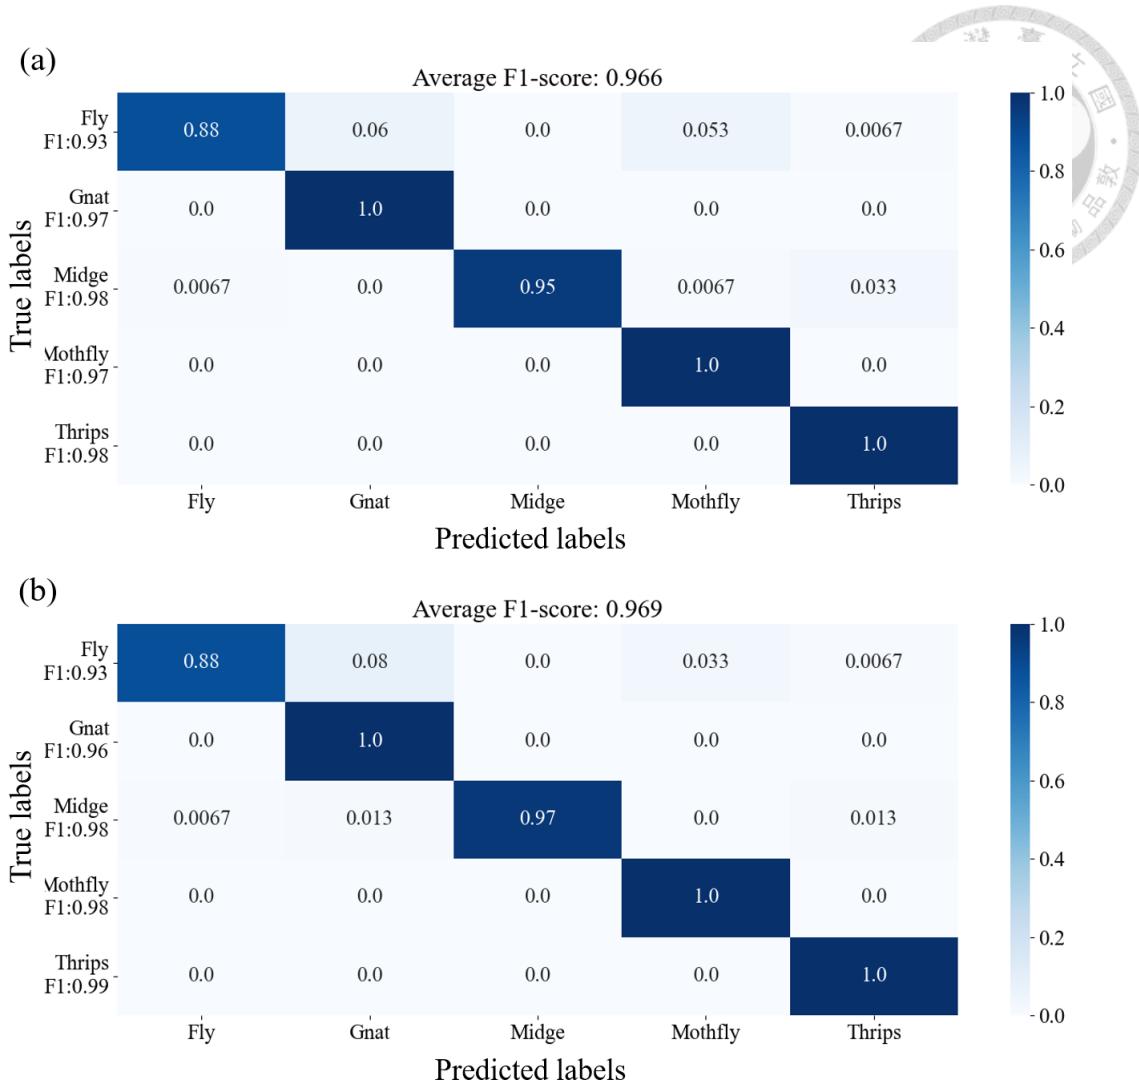


圖 4-21 Model A2 經 (a)線上自主學習；與 (b)監督式學習的最終模型測試結果

圖 4-21 為使用 Model A2 作為基礎模型，所得到的最終模型的測試結果。使用線上自主學習與監督式學習的方法， F_1 -score 分別由 0.925 成長到 0.956 與 0.959。在 Model A2 上，使用自動化與人工的方法效能也相差不大，僅在某些類別上有著約 1% 的 F_1 -score 差異。而相對於 Model A1 整體平均約 6% 的成長，在 Model A2 僅有約 3% 的成長。

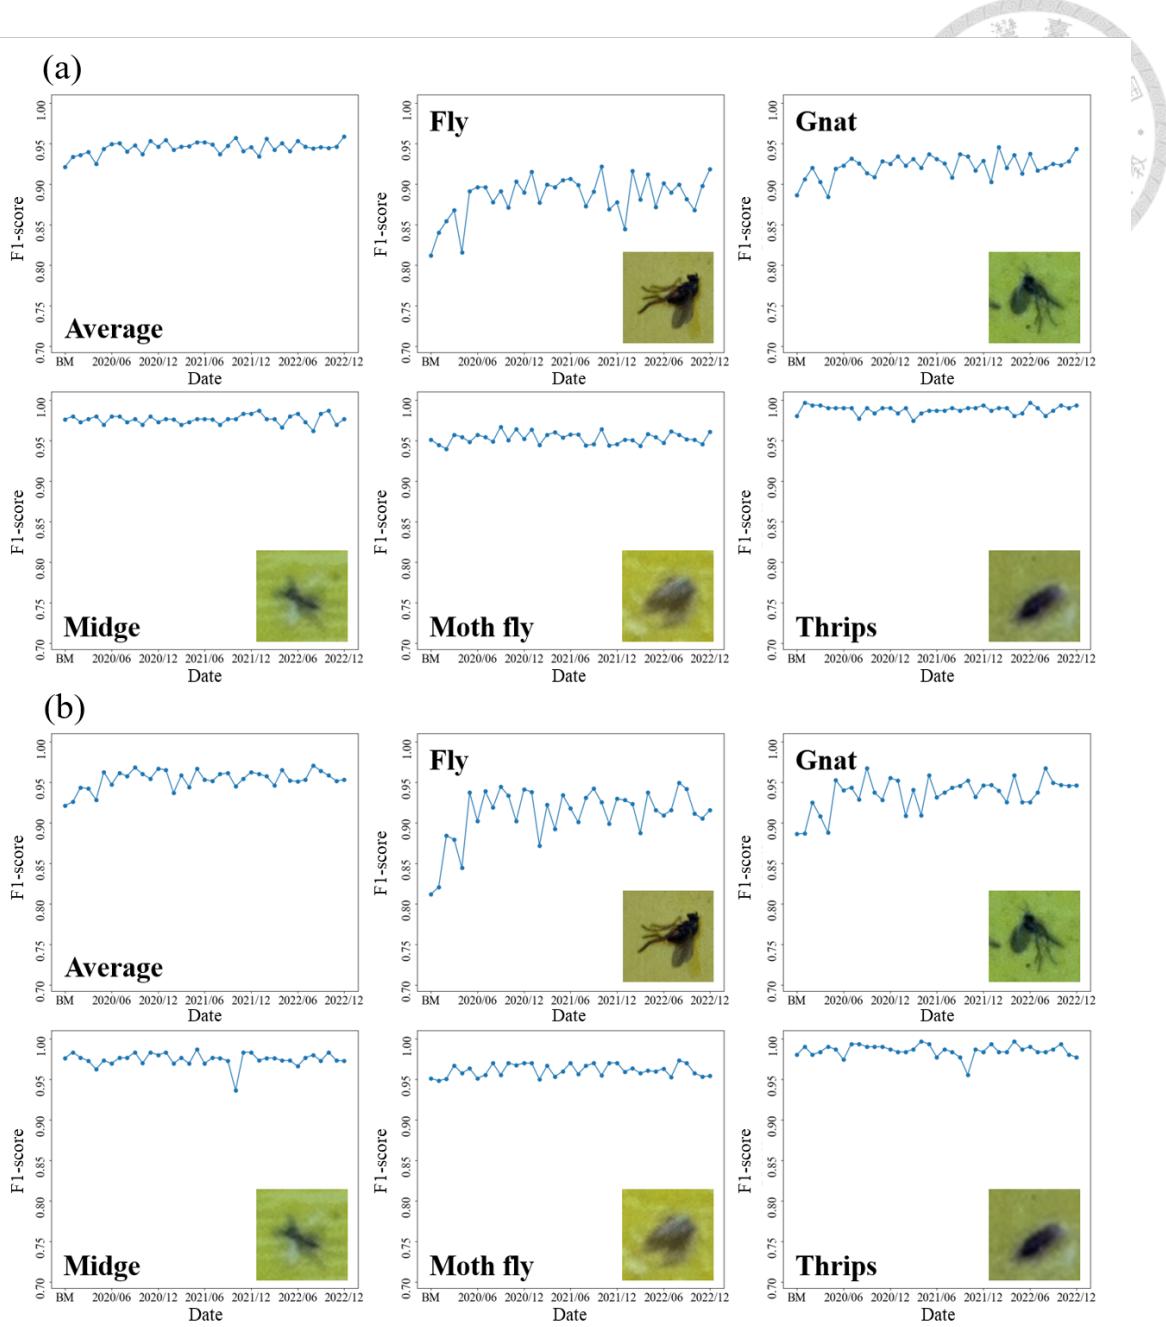


圖 4-22 使用 Model A3 進行 (a)線上自主學習；與 (b)監督式線上學習之結果

圖 4-22 為使用 Model A3 作為基礎模型時的訓練結果，其趨勢如同前面兩個模型的結果類似，在蠅與蕈蠅上有較明顯的提升。F1-score 在訓練前期的進步幅度較明顯，約經過七個月的迭代後，模型的測試結果呈現上下波動的狀態，而無明顯上升的趨勢。

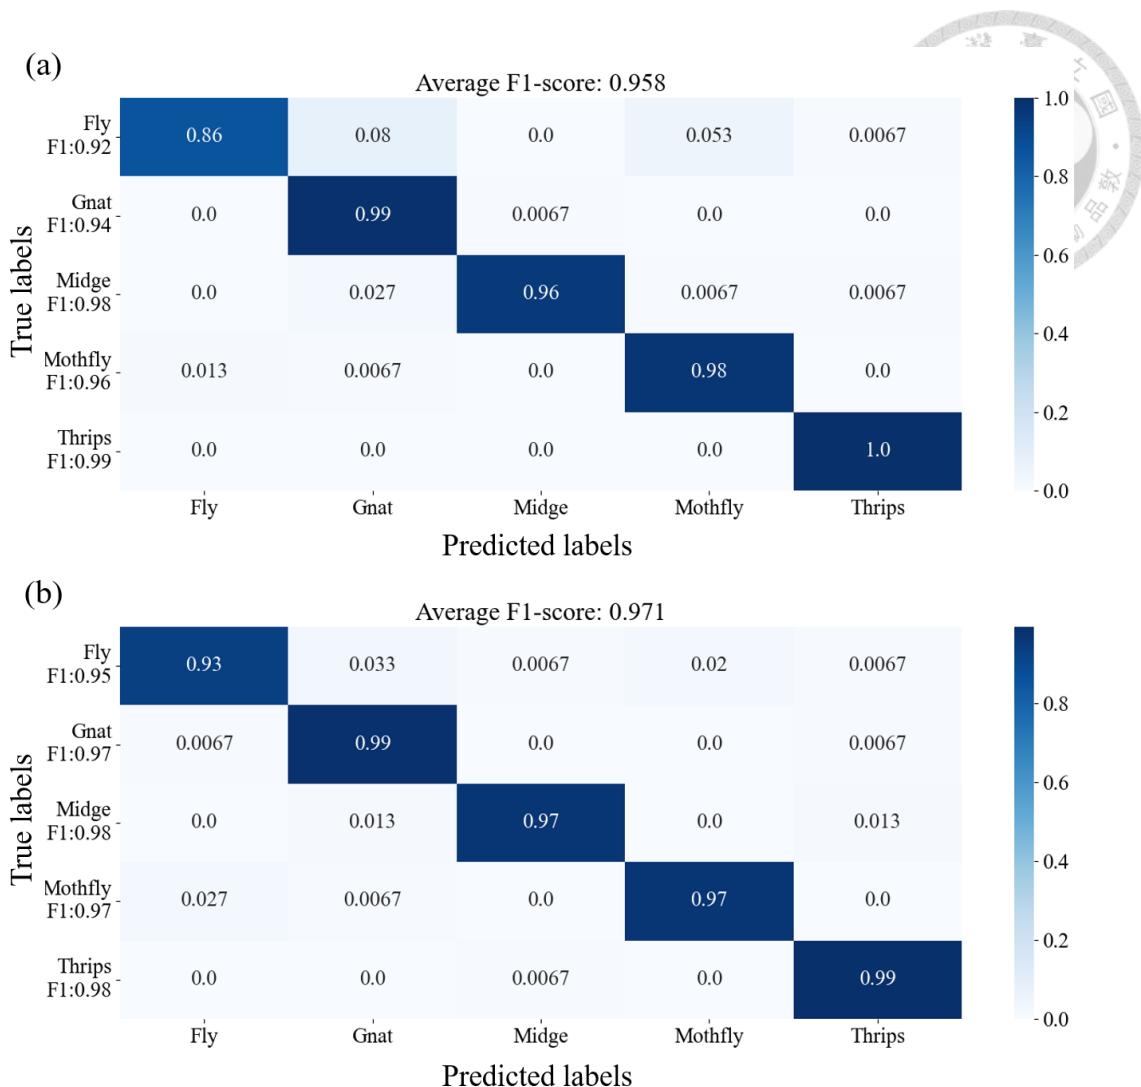


圖 4-23 Model A3 經(a)線上自主學習；與(b)監督式學習的最終模型測試結果

根據圖 4-23 顯示以 Model A3 作為基礎模型的最終模型的結果，使用線上自主學習和監督式學習兩種方法進行訓練，其 F₁-score 分別從 0.921 成長到 0.958 和 0.971，個別提升約 3.7% 和 5%。蠅和蕈蠅這兩類別的 F₁-score 相差約 3%，整體差異約為 1.3%。儘管在 Model A3 上使用自動化的方法與人工的方法，最終的模型效能上有些微的差異。以 Model A3 作為基礎模型時，透過自動化的方法還是能有效的提升其效能。

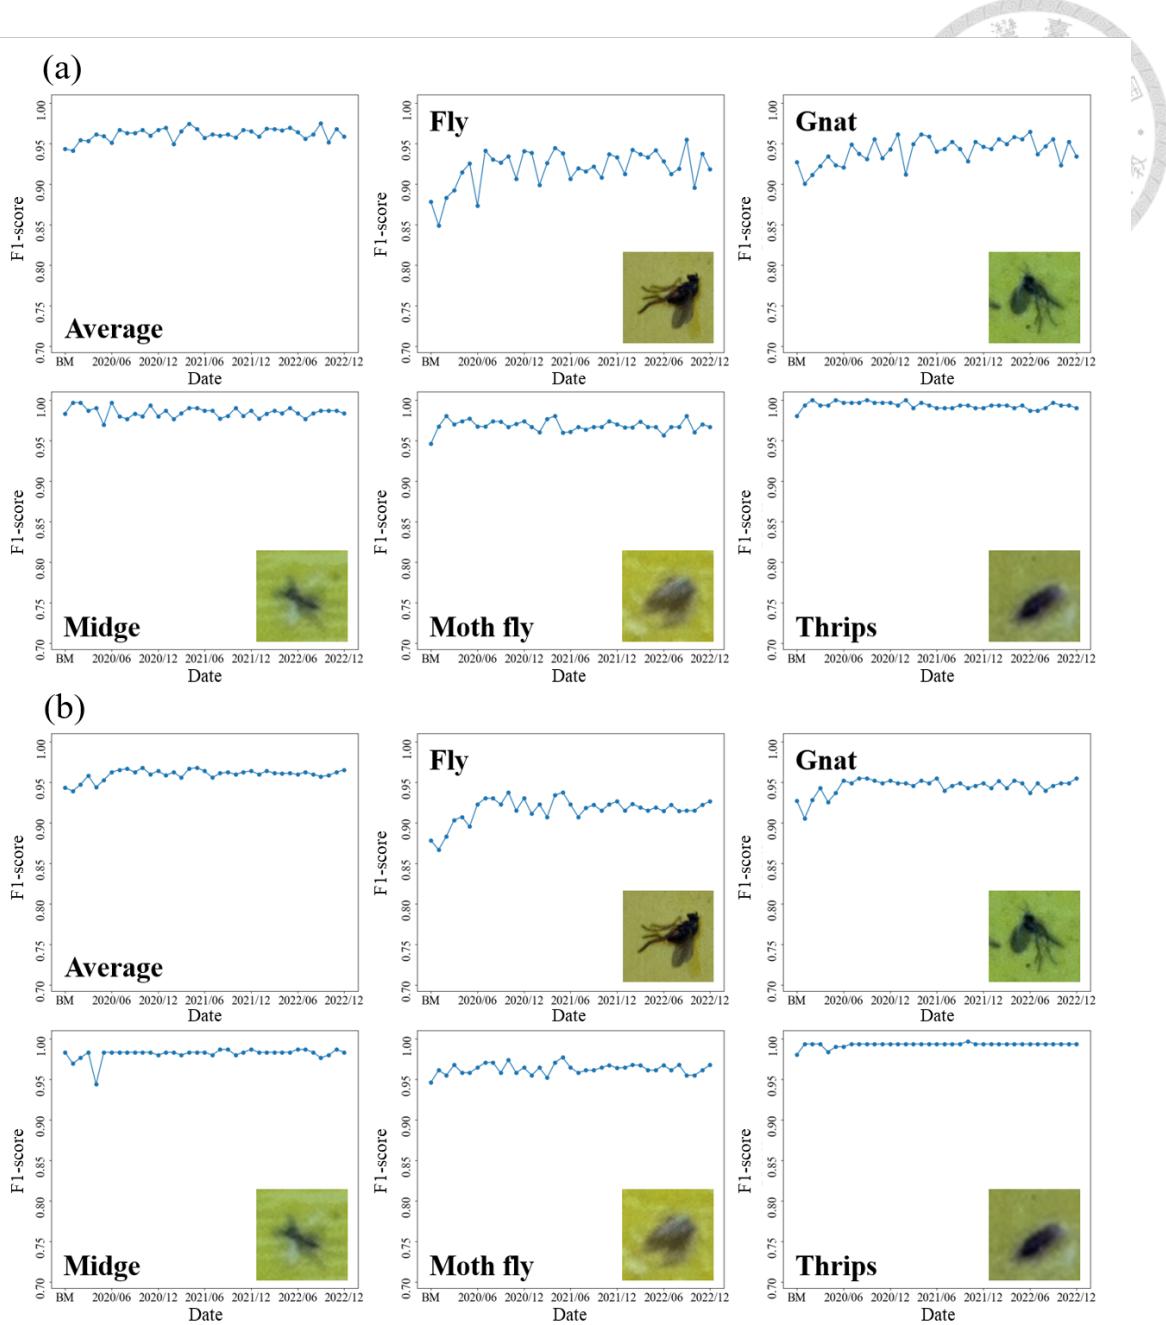


圖 4-24 使用 Model A4 進行 (a)線上自主學習；與 (b)監督式線上學習之結果

圖 4-24 為使用 Model A4 作為基礎模型時的訓練結果，蠅與蕈蠅的變化幅度較大，其餘三種類別皆維持其優異的表現。相對於其他三種模型的結果，其整體的提升幅度較小，自動與手工的方式分別僅提升約 2.3%與 3%。

圖 4-25 為 Model A4 的最終模型測試結果，自動化的方法能讓模型的 F1-score 提升到 0.968，而人工的方式提升到 0.975，各類別的效能相當，僅在某些類別有約 1%的差異。

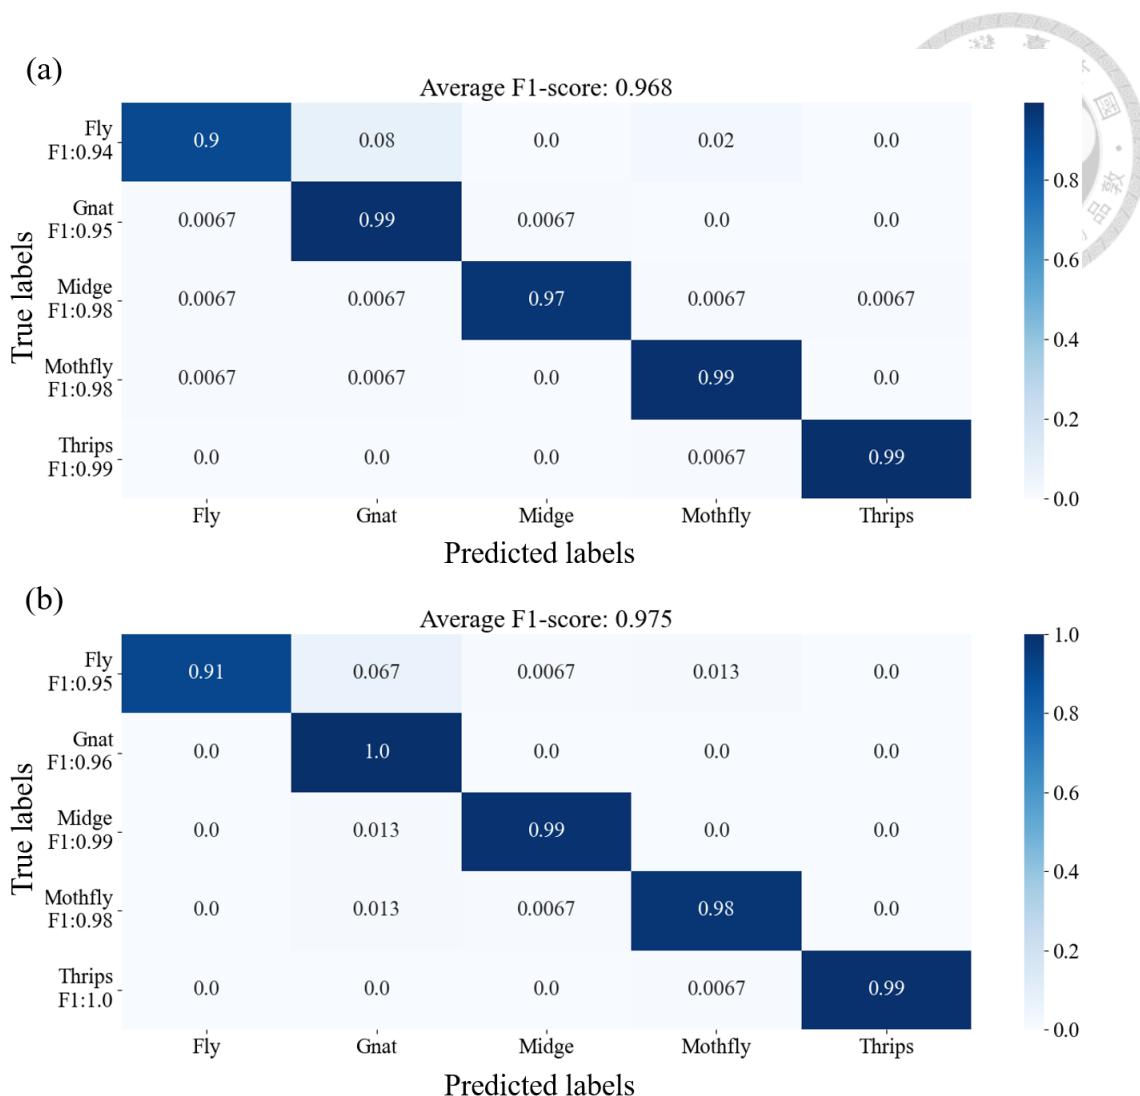


圖 4-25 Model A4 經 (a)線上自主學習；與 (b)監督式學習的最終模型測試結果

進一步觀察發現，在基礎模型表現較好的模型的成長效果相對較不明顯，而基礎模型表現較差的模型則有較大的成長幅度。這可能是因為基礎模型表現較好的模型，在性能上已接近上限，因此在再訓練過程中的改善效果有限。相反，基礎模型表現較差的模型具有更大的改善空間，因此在迭代訓練中呈現較明顯的成长效果。

4.3.3 動態樣本測試結果

為進一步評估線上自主學習演算法對辨識系統效能的改善，除使用 3.5.2 章節提到固的測試集進行模型測試外。我們另外將每個月從無線取像裝置收集的黏蟲紙進行手動的分類，形成新的動態測試數據集。這個新的測試數據集包含從 2020



年1月到2022年12月總共36組測試集。其目的為觀察模型在動態更新過程中對辨識結果的實際改善情況。並對各類別與平均的F₁-score進行配對t檢定(paired t-test)的統計分析，以比較基礎模型、線上自主學習和監督式學習在每個月手動測試結果之間是否存在顯著差異(Raschka, 2018)。

圖4-26為以Model A1做為基礎模型時的動態樣本測試結果。線上自主學習與監督式學習的結果相似，都在蠅與蕈蠅兩個類別上有相當顯著的提升，蠓與蕈蚋也有些微的提升，而薊馬在基礎模型的測試上F₁-score已經接近0.99，所以即使經過模型迭代也得不到太多的提升。

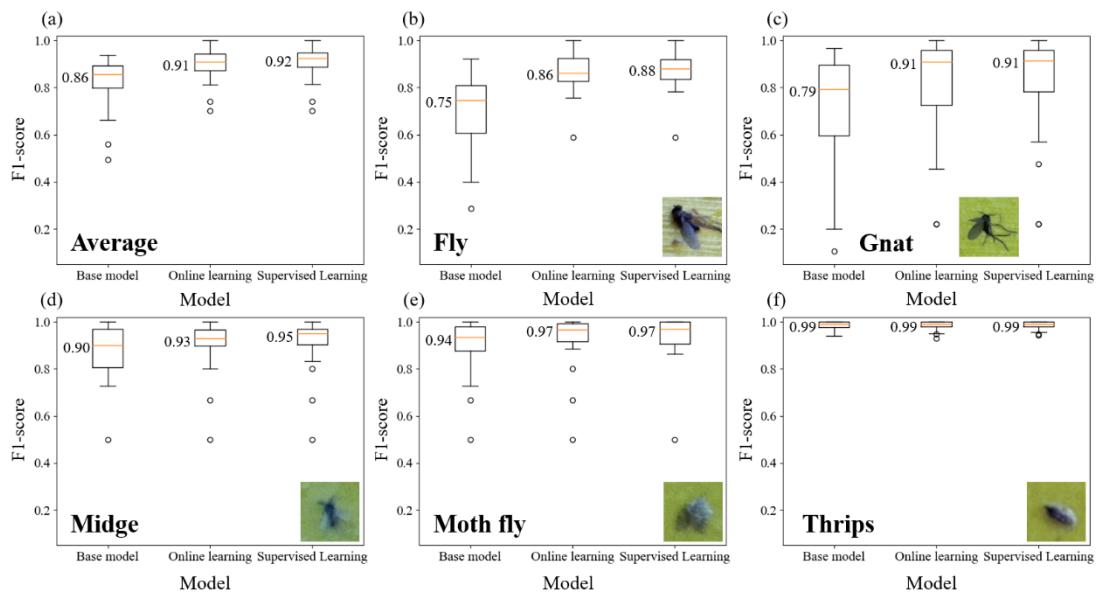


圖4-26 Model A1動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠓；(e)蕈蚋；與(f)薊馬

根據表4-2的結果，對於基礎模型、線上自主學習和監督式學習所進行的動態樣本測試的F₁-score，進行統計檢定。結果顯示，在平均F₁-score、蠅、蕈蠅以及先前測試集上進步較不明顯的蕈蚋方面，基礎模型與線上自主學習之間存在顯著差異，表明線上自主學習能夠明顯提升模型性能。此外，結果還顯示，在線上自主學習和監督式學習之間並沒有顯著差異。這進一步證實線上自主學習方法能夠有效提升基礎模型的性能，並且與傳統的手動訓練方法相比並無顯著差異，能夠以自動化的方式達到與手動訓練相當的效果。

表 4-2 Model A1 動態樣本測試之配對 t 檢定統計結果

Model	Average	Fly	Gnat	Midge	Moth fly	Thrips
Base model-						
Online learning	2.82×10^{-7}	5.61×10^{-9}	2.73×10^{-8}	0.113	0.012	0.538
Base model-						
Supervised learning	8.58×10^{-9}	2.58×10^{-9}	4.31×10^{-8}	0.102	0.013	0.178
Online learning-						
Supervised learning	0.082	0.262	0.408	0.468	0.448	0.711

圖 4-27 為以 Model A2 為基礎模型時的動態樣本測試結果。觀察結果顯示，線上自主學習和監督式學習在平均值、蠅和蕈蚊這些類別上的改善較為明顯，但在蠓和薊馬這兩個本來就表現較好的類別上改善程度較不明顯。此外，在蕈蚋這個類別上，監督式學習的表現稍微優於線上自主學習。

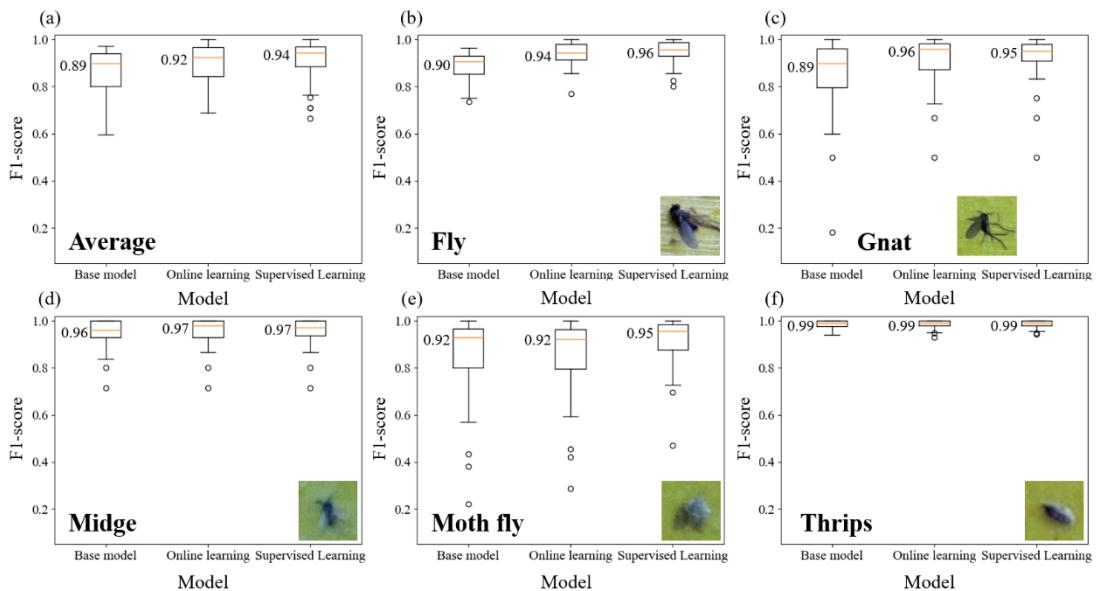


圖 4-27 Model A2 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蚊；(d)蠓；(e)蕈蚋；與 (f)薊馬

根據表 4-3 中的 Model A2 的統計結果顯示，在平均值、蠅、蕈蚊和薊馬這些類別上，經過線上自主學習的模型與基礎模型之間存在著顯著的差異。然而，除

蕈蚋這個類別外，線上自主學習和監督式學習之間的結果無顯著差異，表示線上自主學習的方法也在影像增強分類模型上得到與監督式學習匹敵的效能。

表 4-3 Model A2 動態樣本測試之配對 t 檢定統計結果

Model	Average	Fly	Gnat	Midge	Moth fly	Thrips
Base model- Online learning	0.003	3.32×10^{-5}	0.003	0.349	0.569	0.002
Base model- Supervised learning	3.14×10^{-5}	1.95×10^{-5}	4.78×10^{-5}	0.535	0.002	0.002
Online learning- Supervised learning	0.451	0.859	0.850	0.351	0.001	0.097

圖 4-27 為以 Model A3 為基礎模型時的動態樣本測試結果。線上自主學習和監督式學習在平均值、蠅、蕈蠅和蠓這些類別上的有明顯的進步。此外，監督式學習在平均值、蠅和蕈蠅上相比自主學習又有些微的提升，平均 F1-score 的中位數達到 0.96。

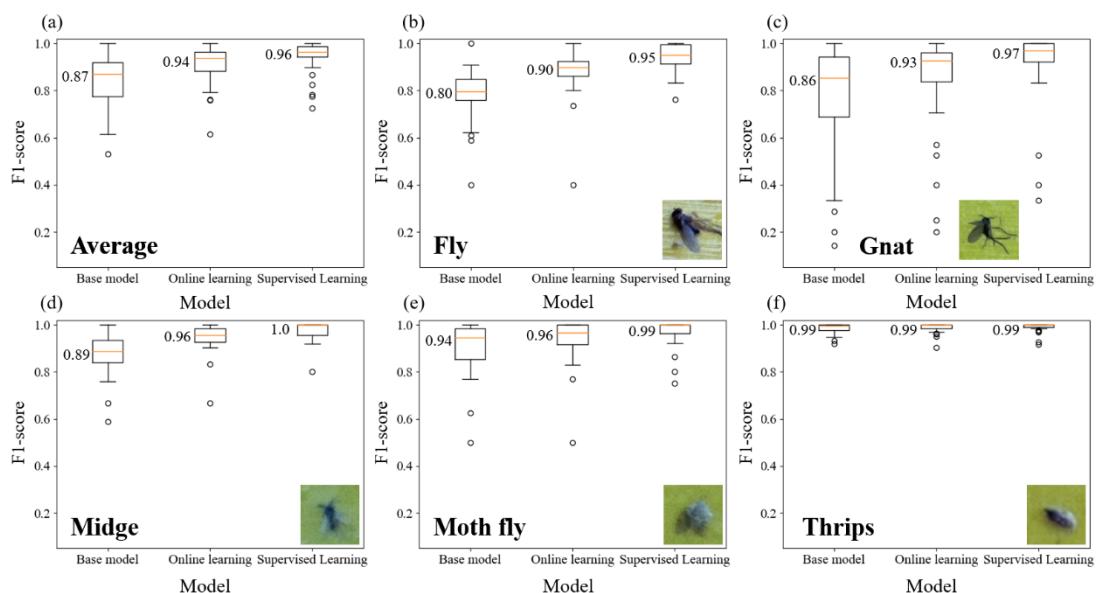


圖 4-28 Model A3 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠓；(e)蕈蚋；與 (f)薊馬

根據表 4-4，在平均值、蠅和蕈蚊這些類別上，線上自主學習和監督式學習之間的結果存在顯著差異，這意味著線上自主學習的方法在尺寸特徵分類模型上無法達到與監督式學習相同的性能。儘管如此，根據統計結果顯示，使用線上自主學習的方法仍然可以持續改進分類模型，使其優於基礎模型。

表 4-4 Model A3 動態樣本測試之配對 t 檢定統計結果

Model	Average	Fly	Gnat	Midge	Moth fly	Thrips
Base model- Online learning	6.87×10^{-7}	5.95×10^{-10}	2.42×10^{-7}	0.016	0.02	0.333
Base model- Supervised learning	1.91×10^{-8}	7.80×10^{-10}	5.23×10^{-6}	0.003	0.002	0.130
Online learning- Supervised learning	0.0002	0.001	0.003	0.136	0.087	0.442

圖 4-29 顯示以 Model A4 作為基礎模型時的動態樣本測試結果。在經過模型的迭代訓練後，整體的分類效能也有所提升。然而，相較於前三種模型，改善的幅度相對有限。如前面 4.3.2 所提到的，這可能是因為基礎模型已經具有良好的性能，限制其進一步改善的空間。

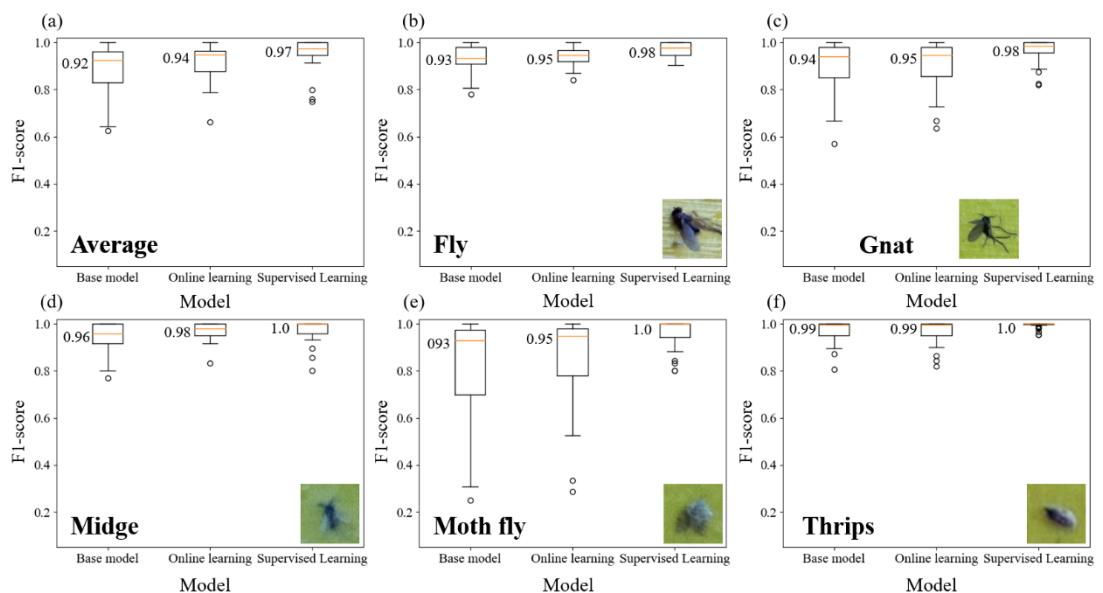


圖 4-29 Model A4 動態樣本測試結果：(a)五種類平均；(b)蠅；(c)蕈蚊；(d)蠻；(e)蕈蚋；與 (f)薊馬



根據表 4-5 的結果，在平均值、蠂和蕈蚋這些類別上，經過線上自主學習後，分類效果顯著提升。在蠅、蕈蠅和薊馬這三個類別上，線上自主學習和監督式學習之間存在顯著差異，但在平均值上則無顯著差異。這結果顯示自動化的方法，雖然在某類別上有差異，但是總體的效能上還是能追趕使用人工的方式，進一步證明線上自主學習的可行性。

表 4-5 Model A4 動態樣本測試之配對 t 檢定統計結果

Model	Average	Fly	Gnat	Midge	Moth fly	Thrips
Base model- Online learning	0.023	0.276	0.437	0.001	0.001	0.887
Base model- Supervised learning	0.009	0.0007	0.0002	0.3349	0.0004	0.001
Online learning- Supervised learning	0.055	0.0003	0.0008	0.423	0.002	0.002

4.3.4 樣本清理演算法探討

本章節將進一步分析經由樣本清理演算法的表現，首先定義以下兩種指標：

- Precision: 經由樣本清理後，所保留的資料中為正確樣本的比例
- Missing rate: 所有正確樣本中，被樣本清理演算法所丟棄樣本的比例

Precision 表示模型再訓練過程中，所使用的新進樣本中含有多少比例的正確樣本，而計算 Missing rate 可以了解在樣本篩選的過程中，是否同時犧牲掉大量的正確樣本。圖 4-30 顯示四種不同的模型在經過 4.3.2 的實驗後，所得到之 Precision 與 Missing rate，在 Precision 方面，四種模型在三年的資料中平均值分別約為 0.62、0.62、0.73 與 0.65，在 Missing rate 方面約為 0.20、0.19、0.32 與 0.28。Model A1 與 Model A2 所得到的結果相似，約 0.62 的準確率下犧牲約 0.2 的正確樣本。Model A3 雖然得到最高的準確率，但是另一方面犧牲約 0.32 的正確樣本，而 Model A4 得到次高 0.65 的準確率但也同時犧牲次高約 0.28 的正確樣本。根據這些結果，推



測因 Model A3 在樣本清理過程中篩掉較多的正確樣本，導致在訓練過程中相對於其他模型缺少一些有用的特徵。這也解釋在 4.3.3 的動態樣本測試中，Model A3 的自動化結果與手動方法之間存在較大差異的原因。同樣地，由於篩掉約 0.28 的正確樣本，Model A4 的統計結果顯示自動化的效能略微不如手動方法。

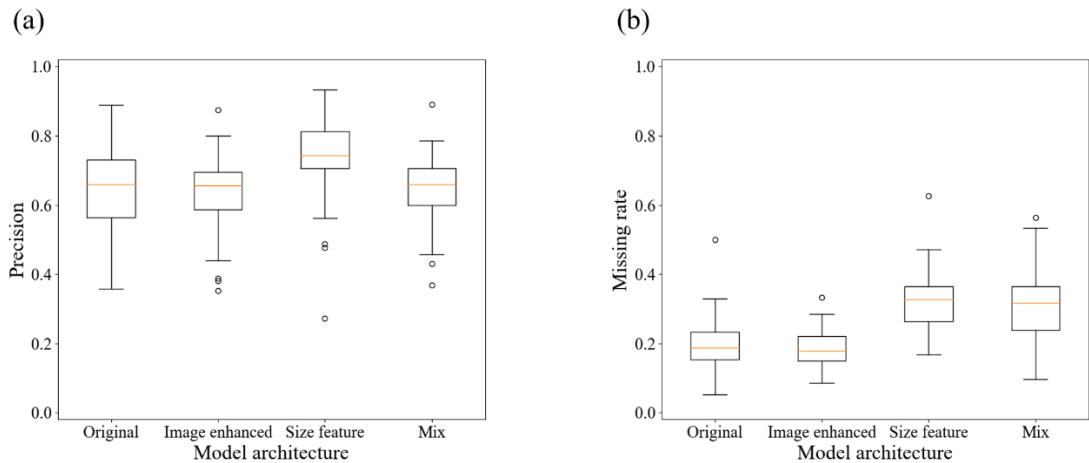


圖 4-30 經由樣本清理演算法所得到之樣本 (a)Precision；與 (b)Missing rate

為進一步證實樣本清理演算法在模型迭代訓練時的幫助，我們進行不使用樣本清理演算法，僅依靠分類模型做新進樣本的分類的線上自主學習測試。樣本準確率如圖 4-31 所示，相比使用樣本清理演算法可得到 0.6 以上的準確率，不使用樣本清理演算法的各模型平均準確率約只有 0.45。

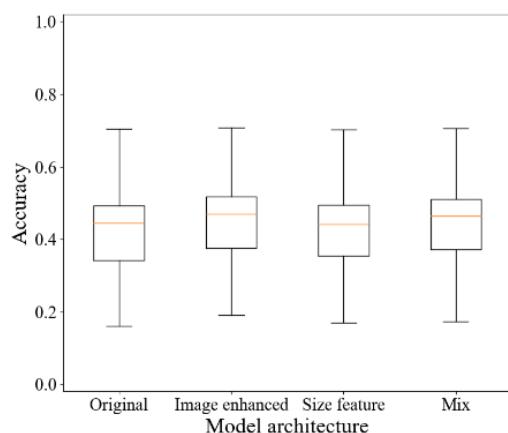


圖 4-31 僅使用分類模型收集新樣本的準確率低於使用樣本清理演算法

各模型的迭代訓練結果如圖 4-32、4-33、4-34 與 4-35。觀察發現，只透過基礎模型分類新進樣本，而不使用 GMM 進行樣本篩選，在線上自主學習過程中，並沒有辦法隨著時間的增加而提升模性效能，甚至會造成模型的效能下降，在四個模型的測試中都觀察到類似的結果，這進一步證實樣本清理演算法的效能。

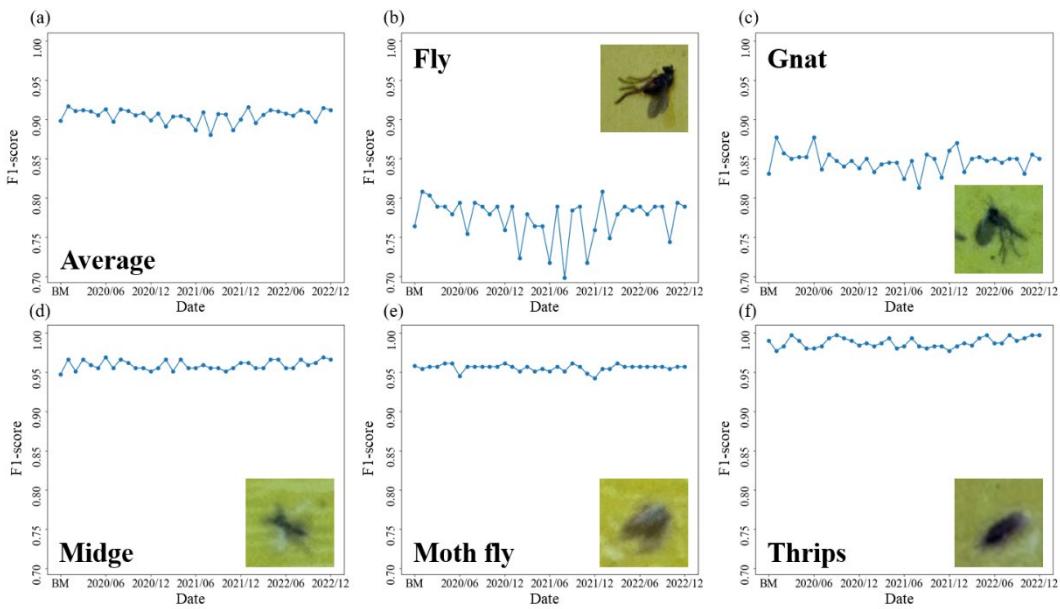


圖 4-32 使用 Model A1 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠓；(e)蕈蚋；與 (f)薊馬

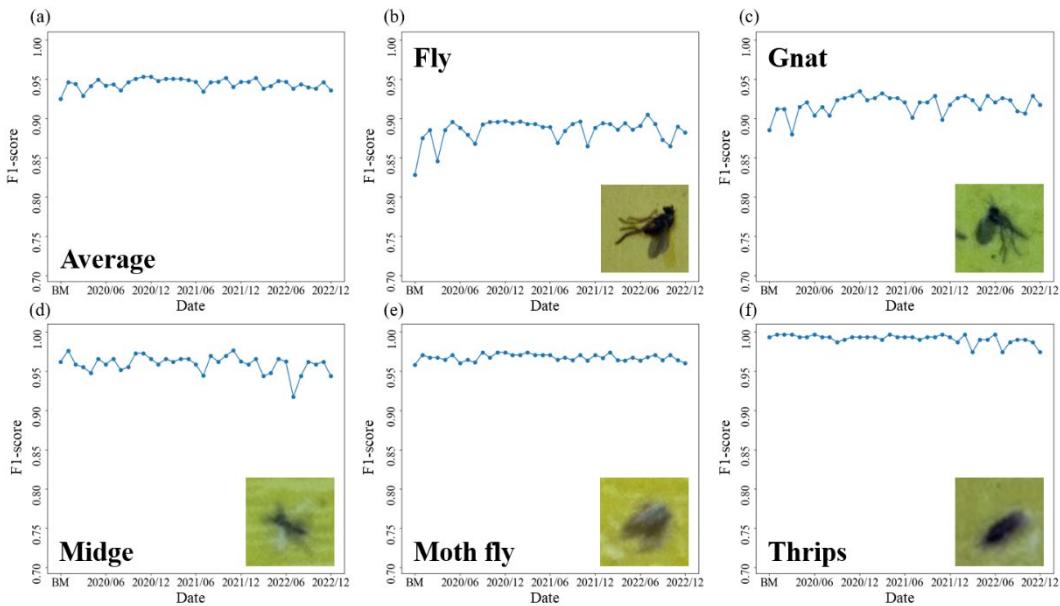


圖 4-33 使用 Model A2 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠓；(e)蕈蚋；與 (f)薊馬

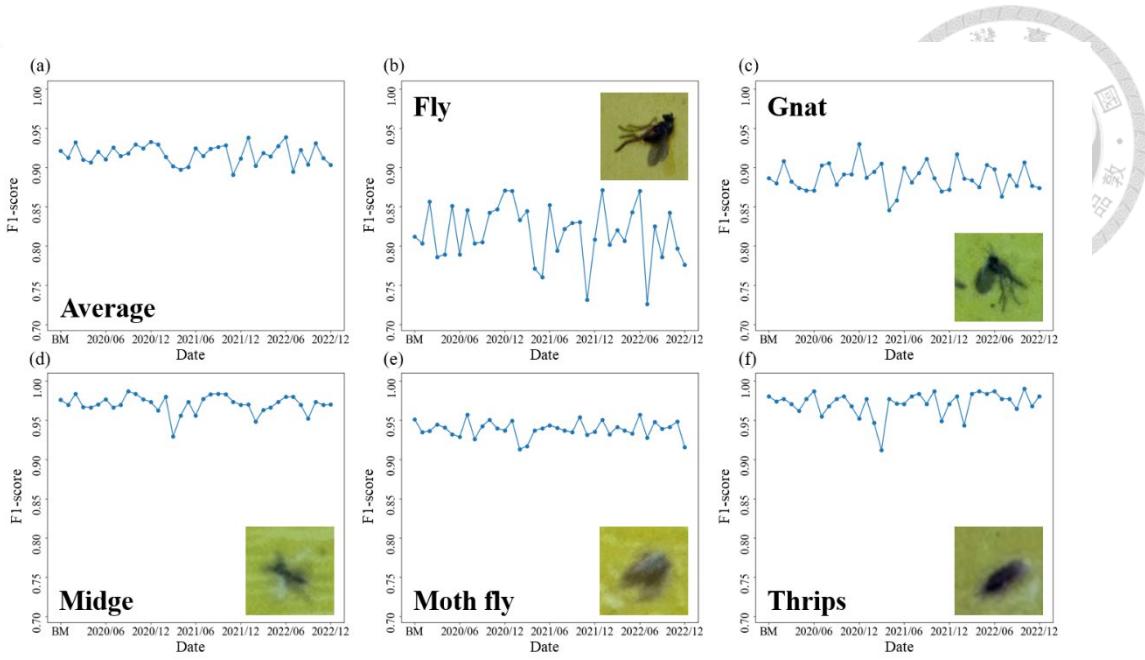


圖 4-34 使用 Model A3 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠓；(e)蕈蚋；與 (f)薊馬

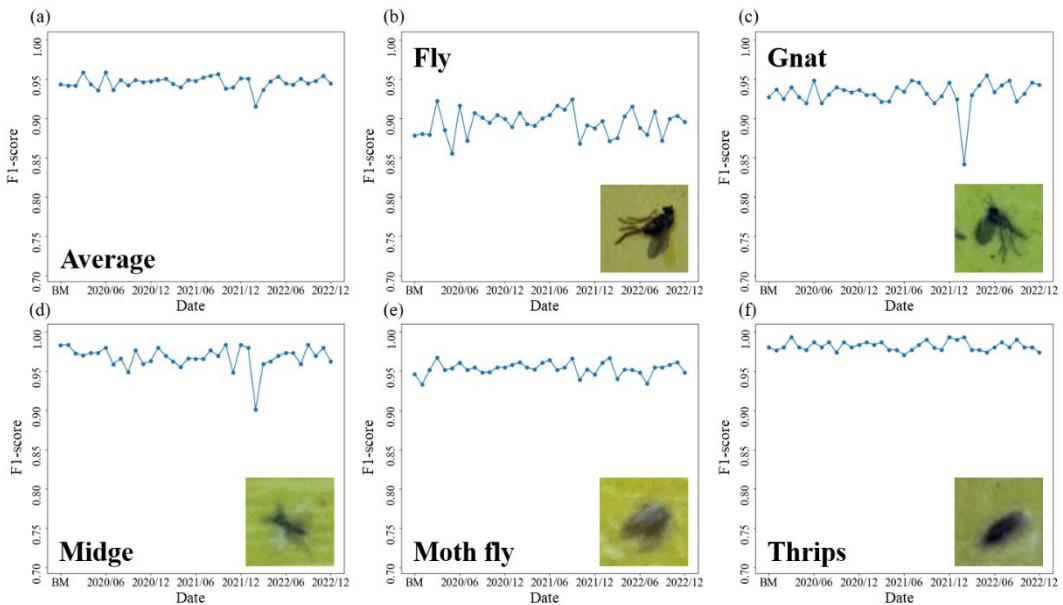


圖 4-35 使用 Model A4 進行不使用樣本清理演算法之迭代訓練結果：(a)五種類平均；(b)蠅；(c)蕈蠅；(d)蠓；(e)蕈蚋；與 (f)薊馬

表 4-6 顯示經由線上自主學習流程後，所得到最終的害蟲樣本數量和準確率。Model A1、Model A2、Model A3 和 Model A4 的平均準確率分別為 0.71、0.66、0.78 和 0.67。儘管某些類別的準確率相對較低，甚至只有 0.48，但這些錯誤的影



像已經通過高斯混合模型的對數機率閾值，這表示這些錯誤的樣本在某些特徵上與正確的樣本有一定的相似性，對模型的訓練還是有正向的幫助，使得模型能夠有效地容忍錯誤樣本並持續進步，而不會使模型訓練走向錯誤的方向。

表 4-6 經由線上自主學習最終所收集之樣本數量與準確率

Model	Fly (Accuracy)	Gnat (Accuracy)	Midge (Accuracy)	Moth fly (Accuracy)	Thrips (Accuracy)	Total (Accuracy)
Model A1	644 (0.55)	1244 (0.62)	201 (0.92)	639 (0.73)	1586 (0.73)	4314 (0.71)
Model A2	488 (0.48)	783 (0.72)	318 (0.87)	596 (0.63)	538 (0.59)	2723 (0.66)
Model A3	271 (0.67)	899 (0.78)	105 (0.89)	379 (0.80)	645 (0.77)	2308 (0.78)
Model A4	440 (0.51)	755 (0.74)	96 (0.77)	441 (0.55)	894 (0.76)	2626 (0.67)

根據實驗結果，證實線上自主學習演算法的有效性，可以持續地收集害蟲樣本以進一步提升模型性能。透過自動化的數據收集、樣本清理、模型再訓練和模型更新，成功地減輕傳統監督式訓練所需的工作量。四種不同基礎模型經過線上自主學習後，在測試集上的 F_1 -score 逐漸提高，從初始的 0.898、0.925、0.921 和 0.942 逐步增加到 0.956、0.966、0.958 和 0.968。儘管新收集到的樣本中可能存在一些未被 GMM 樣本清理演算法檢測到的錯誤樣本，但由於這些樣本在特徵上與正確樣本相似，它們仍然對模型的訓練過程產生正面影響，而不會讓模型崩壞。這證明 GMM 樣本清理方法在處理雜訊樣本方面的有效性。根據動態樣本測試和統計檢定的結果，本研究提出的自動化方法能夠達到或接近傳統監督式學習的效果，這進一步驗證所提出方法的可行性。

4.4 線上自主學習部署於 I²PDM 系統

在本章節中，將討論實際部署線上自主學習演算法於 I²PDM 系統中的運作與測試結果。前述的第 4.3 章節中，由於大蚊和蚊類樣本數量有限，僅使用五種類別進行測試。然而，經過更長時間的樣本累積，我們將大蚊和蚊類加入分類模型

中，使得模型的分類種類擴增到與現有 I²PDM 系統相同的害蟲類別。這將使我們能夠實際應用前面所探討的模型優化方法到現有系統上。



4.4.1 基礎模型訓練結果

基於前面章節的結果證明使用影像增強結合尺寸特徵分類模架構具有優異的分類能力，因此我們選擇該架構作為實際應用的模型基礎，稱為 Model B。使用表 3.4 中除粉蟲之外的七種害蟲影像以及表 3.1 的參數進行模型的訓練與測試。圖 4-34 為 Model B 的測試結果，平均 F₁-score 為 0.929。然而，在大蚊、蠅和蚊類這三個樣本數相對較少的類別上，模型的準確率稍低，分別為 0.87、0.76 和 0.84。另外，在蕈蠅方面，儘管其準確率接近 0.99，但由於其身體型態與蠅和蚊類相似，容易導致模型將這兩類別誤判為蕈蠅，因此 F₁-score 相較於其他訓練樣本充足的類別略低，約為 0.91。

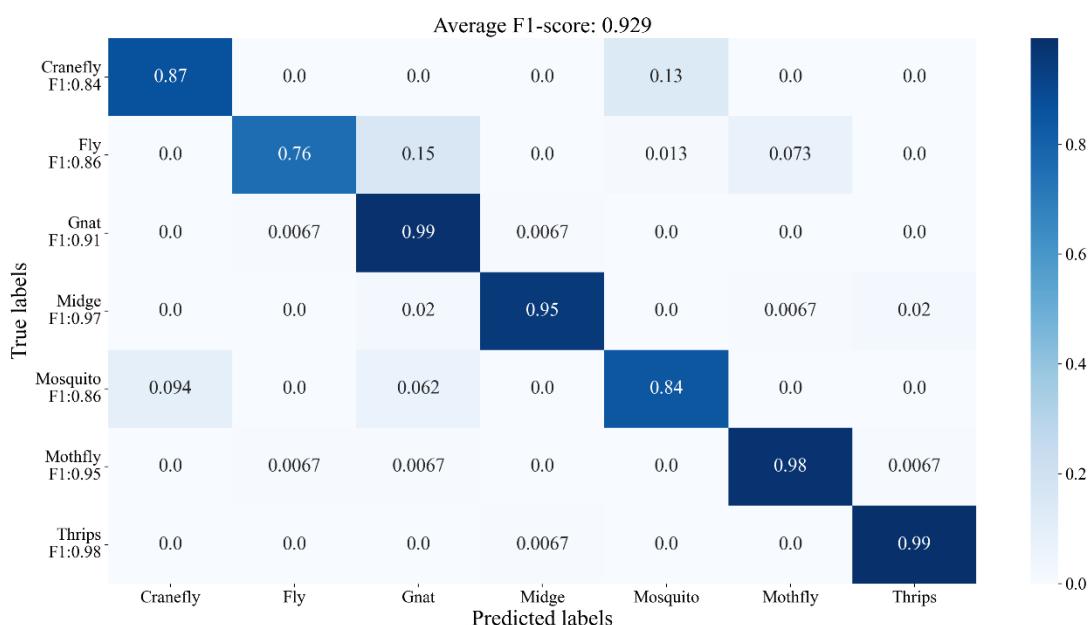


圖 4-36 Model B 基礎模型測試結果

4.4.2 程式架構

程式架構如圖 4-35 所示，使用 Python 作為程式語言，主要包含兩部電腦，分為主伺服器 (main server) 與訓練用電腦 (training PC)。這樣的架構是為避免在線上

自主學習運作時，佔用 I²PDM 系統後端程式所需的計算資源。整個流程使用 MQTT 協定 (message queuing telemetry transport)作為驅動。當流程指令被呼叫時，主伺服器會將黏蟲紙影像通過 ZMQ 協定 (zero message queue)傳送到訓練用電腦進行後續的線上自主學習流程。訓練完成後，判斷再訓練的模型是否優於基礎模型，決定是否進行模型更新流程。模型更新時，使用 TCP 協定 (transmission control protocol)將訓練結束的分類模型傳送回主伺服器。模型更新完畢後，重新啟動主伺服器端的害蟲辨識程式以完成更新流程。

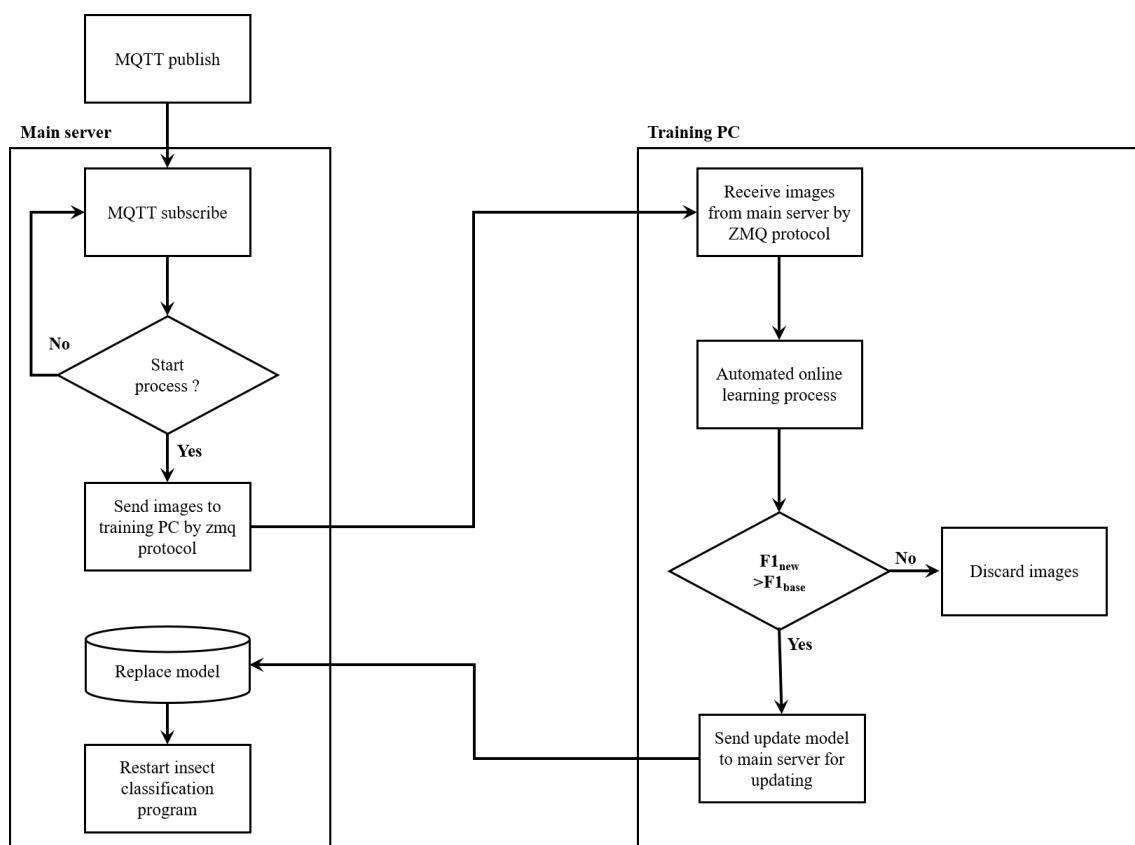


圖 4-37 線上自主學習實際部署架構圖

4.4.3 實際部署運作結果

根據圖 4-35 的程式架構，我們利用 2023 年 1 月至 2023 年 5 月，無線取像裝置於彰化、雲林、嘉義與台灣大學共計五個場域所收集的黏蟲紙資料，對線上自主學習演算法在 I²PDM 系統上進行測試。模型迭代與最終模型的測試結果呈現於圖 4-36 與 4-37。從圖表觀察到，隨著模型的迭代訓練，分類模型的 F₁-score 逐漸

從起始值 0.929 提升至 0.956。就各個類別而言，蠅類的改善效果最為明顯，由起始的 0.86 提升至 0.94 而蕈蠅從 0.91 提升至 0.95。至於蠓和薊馬，由於它們的起始表現已經相對良好，因此在訓練迭代後並未出現顯著變化。另外，蠅類誤判的減少也使得原本表現不錯的蕈蚋類別有約 2% 的改善提升到 0.97。然而，大蚊與蚊並未出現明顯增長的情況。這可能是由於這兩種類在溫室中相對少出現，透過自動化收集的新樣本數量相對較少，特別是在大蚊方面甚至未能收集到新的訓練樣本，這使得模型無法學習更多新的特徵，因此未呈現明顯的變化。

表 4-7 為經過線上自主學習後所收集到的新樣本與最終模型所使用的訓練樣本數量，經過 GMM 樣本清理演算法所收集到的樣本平均準確率約為 0.69，但在蚊類方面僅有 0.27，檢視樣本後發現，模型容易將蕈蠅判斷為蚊類，推測是因為兩者有著蠻高的相似度，且蚊類的訓練樣本數過少導致模型無法有效的做出正確判斷。

表 4-7 線上自主學習演算法部署於 I²PDM 系統所收集之樣本數量和準確率

Class	Newly added data	Accuracy
Cranefly	0	0
Fly	171	0.77
Gnat	554	0.92
Midge	16	0.63
Mosquito	22	0.27
Moth fly	147	0.75
Thrips	143	0.82
Total	1053	0.69

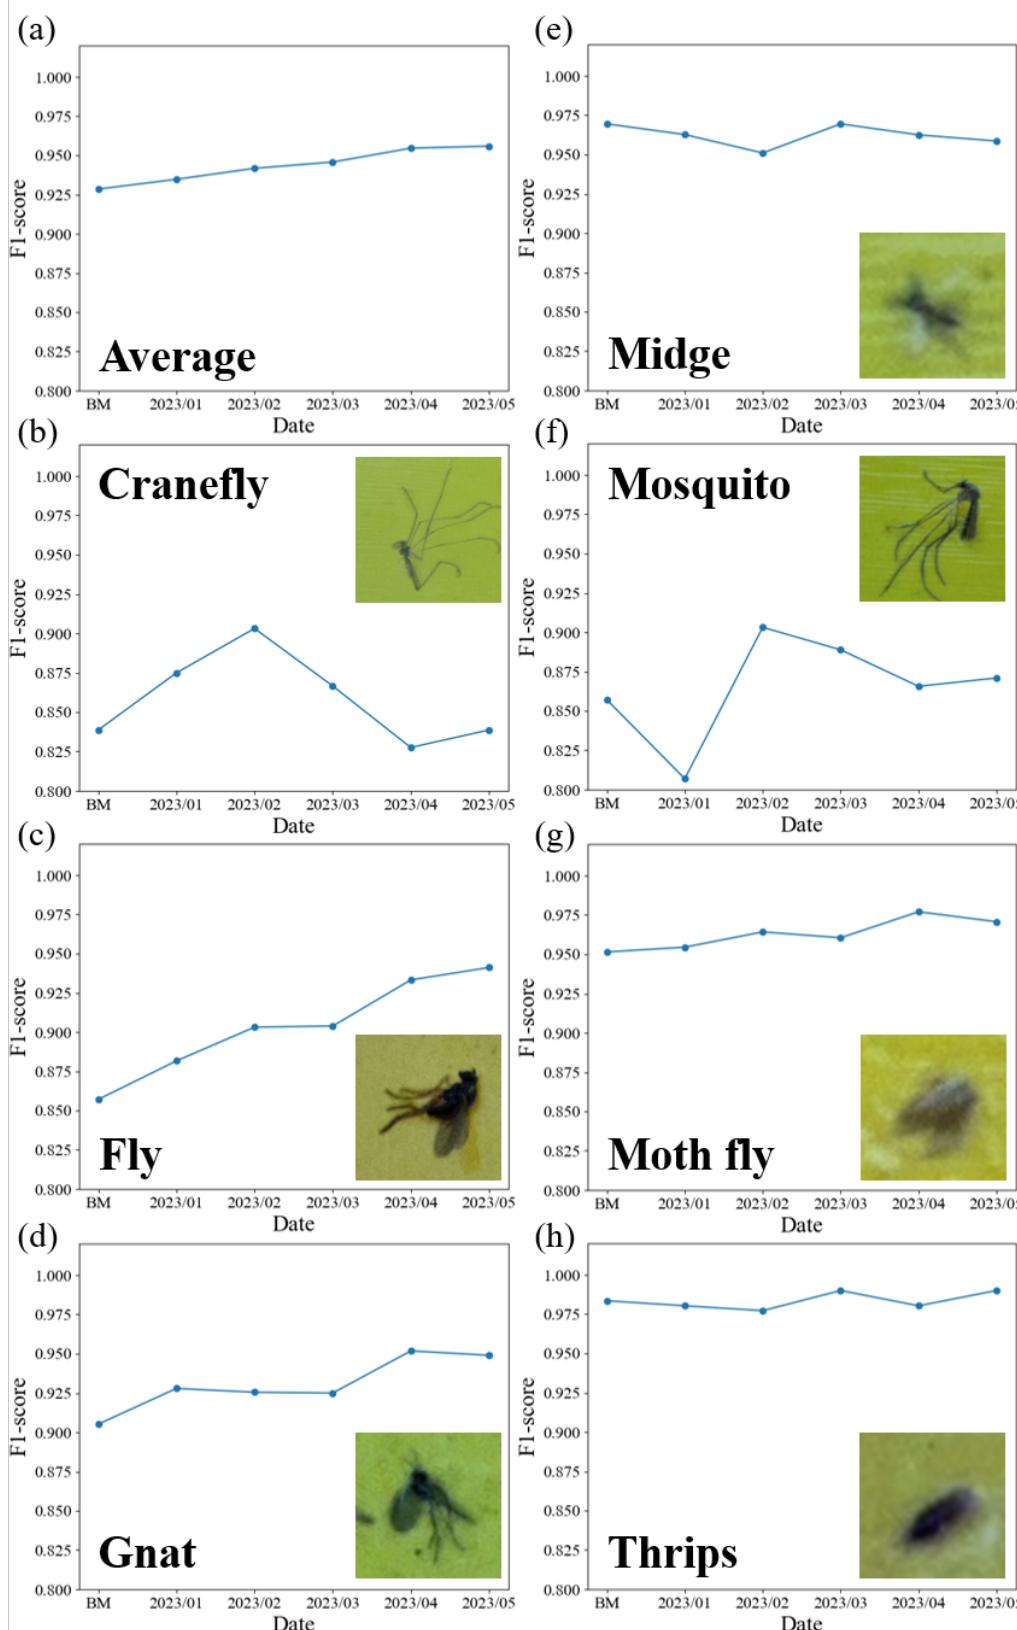


圖 4-38 線上自主學習演算法部署於 I²PDM 系統迭代訓練結果：(a)七種類平均；
 (b)大蚊；(c)蠅；(d)蕈蠅；(e)蠓；(f)蚊；(g)蕈蚋；與(h)薊馬

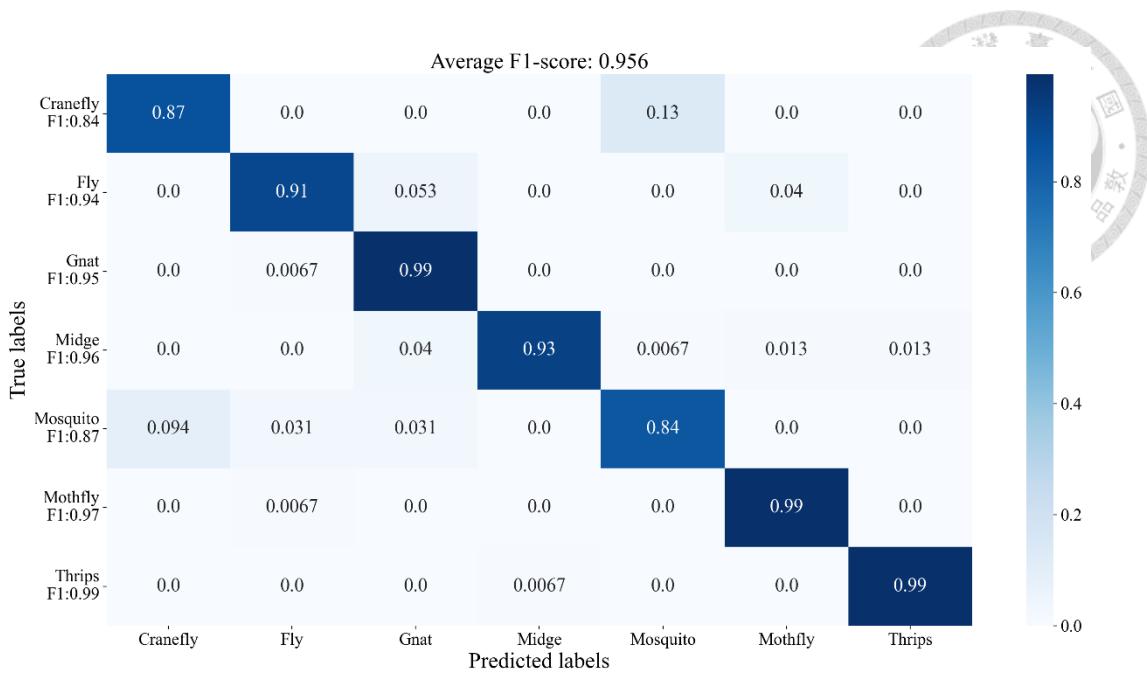


圖 4-39 Model B 經過線上自主學習的最終模型測試結果

我們也對 Model B 進行動態樣本測試，手動分類 2023 年 1 月至 2023 年 5 月的害蟲影像，形成五組新的測試集。由於某些類別測試數量較少或是沒有，因此在這項測試中僅顯示平均 F₁-score 以及蠅、蕈蚊、蕈蚋和薊馬這些類別的結果。根據圖 4-40 所示的測試結果，與基礎模型相比，經過自主學習後的模型在各個類別中都顯示出性能的提升。這意味著自主學習方法能夠有效地處理新的動態樣本並進一步改善模型的分類能力。該結果進一步支持線上自主學習方法在動態系統中的應用價值。

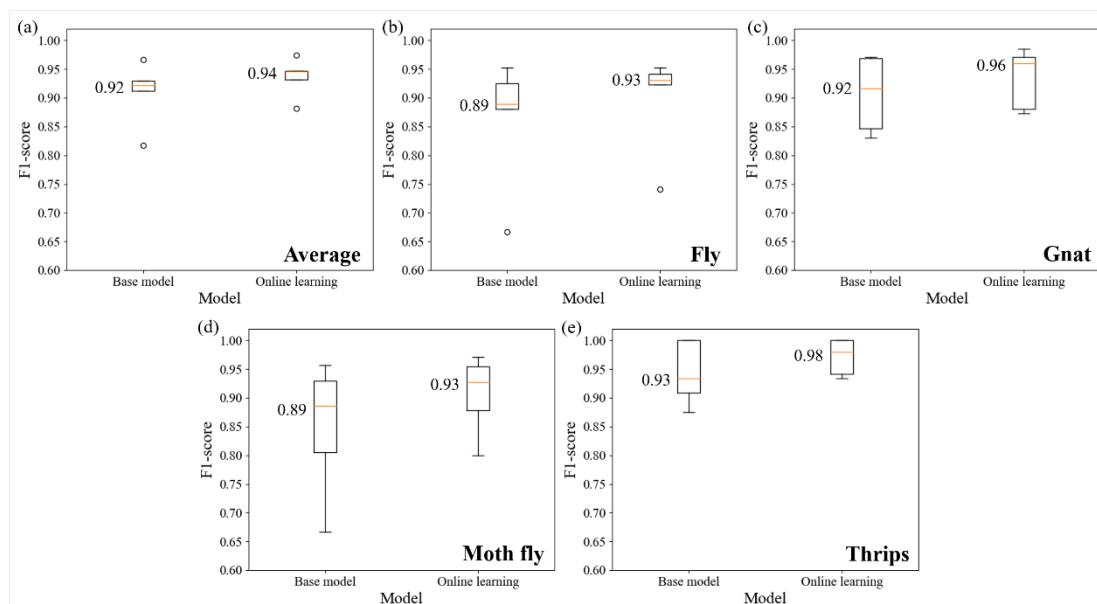


圖 4-40 Model B 之動態樣本測試結果

表 4-8 為使用配對 t 檢定統計結果，在蕈蠅上有顯著的提升，在平均值與蠅類 P 值分別為 0.052 與 0.051 接近顯著差異，而在蕈蚋和薊馬這兩個類別中，經過自主學習後的模型與基礎模型之間的差異並不顯著。儘管經過自主學習後的模型在各類別的效能上都有呈現改善的趨勢，但可能是因為進行統計檢定的樣本數量較少，僅有五組，導致統計檢定上還無法得出明顯的差異，仍然需要更多的樣本數據才能顯現出統計上的顯著性。

表 4-8 Model B 動態樣本測試之配對 t 檢定統計結果

Model	Average	Fly	Gnat	Moth fly	Thrips
Base model- Online learning	0.052	0.051	0.032	0.119	0.274

4.5 相機模組升級結果

4.5.1 實際拍攝結果與延長支架設計

圖 4-41 為 Raspberry pi camera v2 與 Arducam 64MP 的拍攝結果，在圖 4-41 (b)的右下角，可以清楚地看到蕈蠅的腳被分開，而在圖 4-41 (a)中，該蕈蠅的腳則是重疊在一起的。這顯示出相機的升級對於捕捉昆蟲細節有很大的幫助。這顯示相機的升級對於捕捉昆蟲的細節是有很大的幫助。然而，升級相機的一個缺點是其景深相對較淺。只有在焦點附近的昆蟲才會呈現較清晰的狀態，而焦點外圍則呈現模糊狀態。這一點可以在圖 4-41 (b)中觀察到，隨著距離焦點越遠，昆蟲的失焦現象越明顯，呈現較模糊的狀態。

為解決景深的問題，我們設計一對延長支架，將相機的工作距離延長到 14cm，如圖 4-42 所示。使用延長支架後，所得到的影像 DPI 約為 1275，相較於 10cm 工作距離的 1641 稍微降低，但相較於原始相機的 662 仍然獲得約兩倍的提升。這表示在保持影像解析度的同時，我們實際得到清晰的黏蟲紙影像範圍越大。

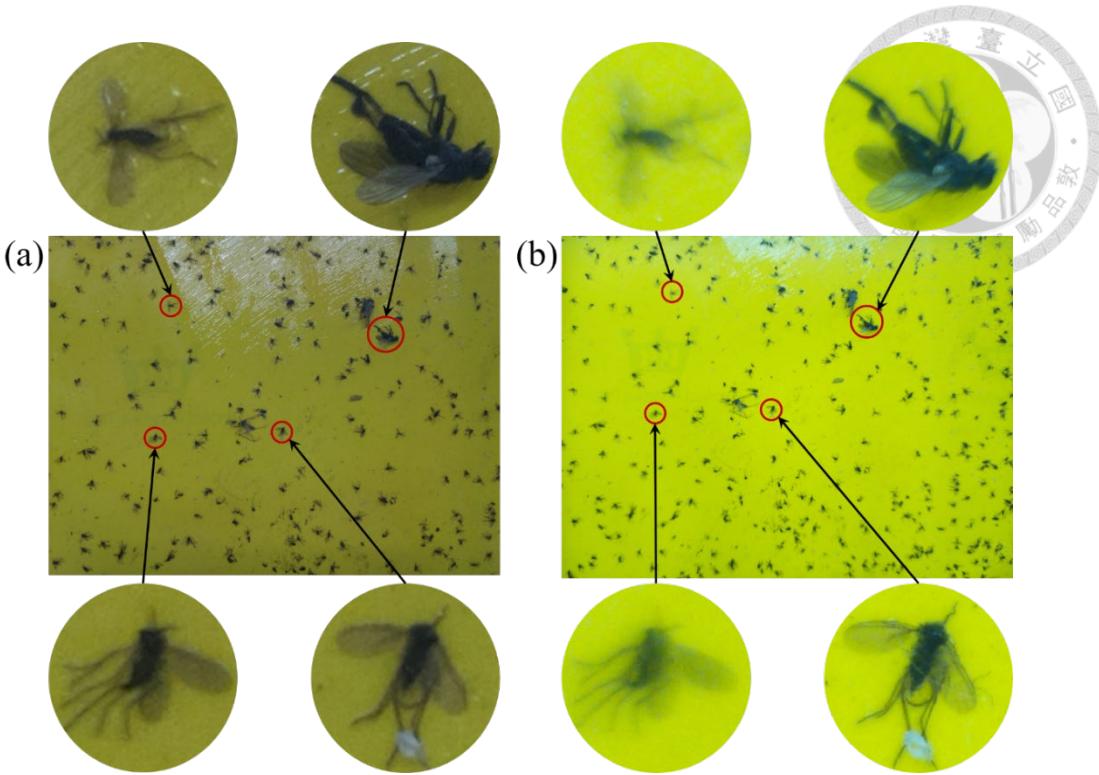


圖 4-41 使用不同相機拍攝之黏蟲紙影像，使用 (a)原始相機；與 (b)Arducam 64MP 相機的拍攝結果，經過相機更新後，在焦點附近可拍攝到更清楚的細節，而焦點外的昆蟲會呈現失焦的狀態

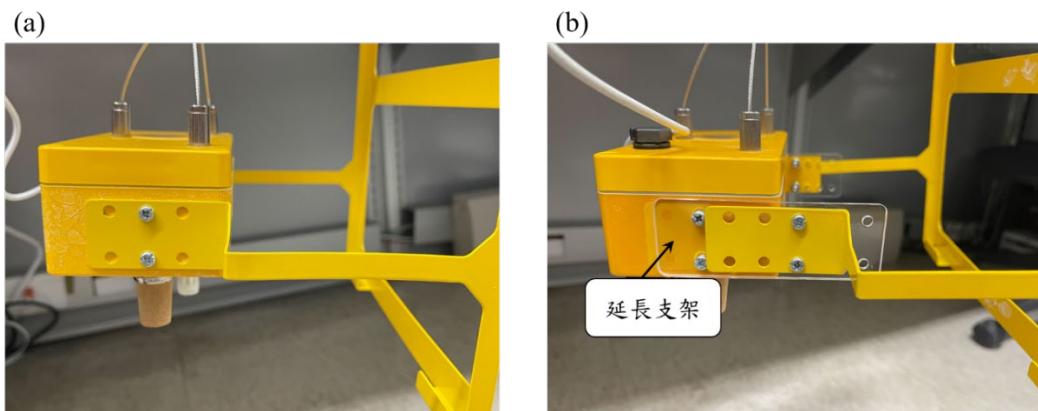


圖 4-42 相機工作距離示意圖：(a)原始的黏蟲紙支架工作距離約 10 cm；(b)安裝延長支架後將工作距離延長到 14cm

圖 4-43 為使用 Arducam 64MP 相機在不同工作距離下所拍攝的影像。雖然在焦點中間的影像可能會損失一些細節，但相較之下，我們使得中間清晰的黏蟲紙範圍越大，這表示在原始影像失焦的同一隻昆蟲上，可能在相機增加工作距離後，得到較清晰的影像。這意味著，即使在焦點中間的區域可能出現一些細節的損失，但整體影像仍然呈現出更好的清晰度。



圖 4-44 為放大後觀察的結果，在圖 4-44 (a)與 (c)上能看到放大後的影像已經有相當多的馬賽克，而相比之下在圖 4-44 (b)與 (d)，新的相機能夠捕捉更多的昆蟲細節，還是能看到清晰的昆蟲的足部特徵。

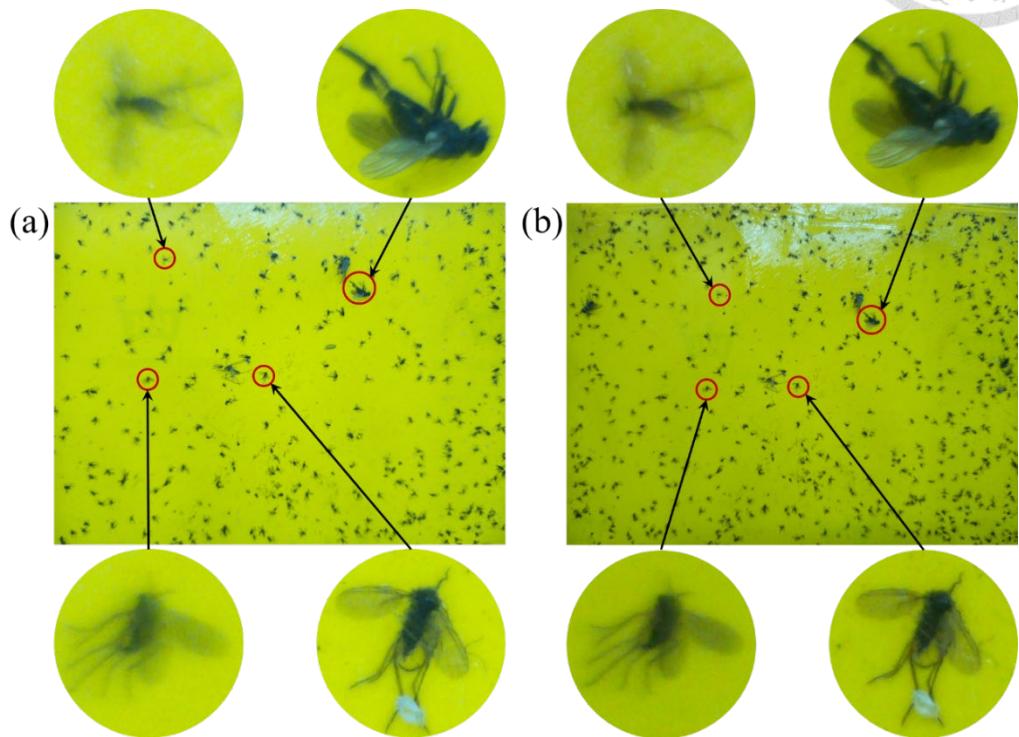


圖 4-43 使用相同相機在不同工作距離時所拍攝之黏蟲紙影像，當工作距離為
(a)10cm；與 (b) 14cm，延長工作距離可加大其清楚對焦的範圍

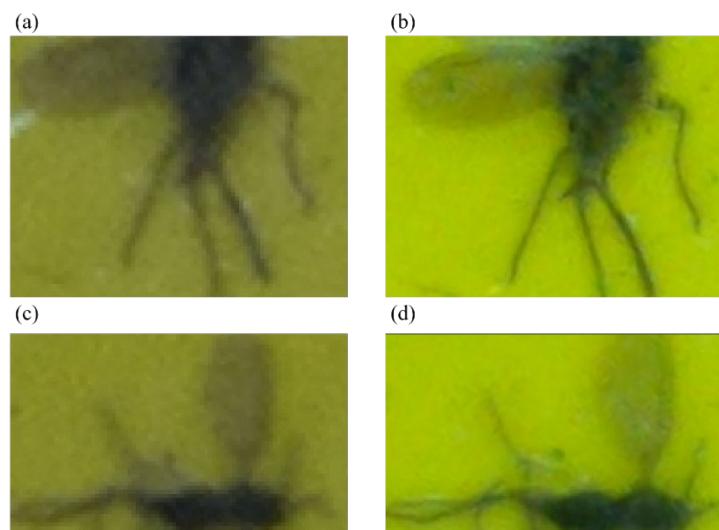


圖 4-44 使用原始相機 (a)(c)；與 Arducam 64MP 相機 (b)(d)在昆蟲身體細節上的表現，結果顯示更新相機能捕捉到昆蟲更細節的特徵



4.5.2 分類模型測試結果

在分類模型的測試中，我們分別使用 Raspberry pi camera v2 和 Arducam 64MP 相機拍攝相同的黏蟲紙影像。使用新相機所得到的影像只保留中間的 6400 x 4800 像素部分。這樣做的原因有兩個方面考量：一方面是捨棄周圍模糊的影像，以保留清晰的部分；另一方面是為盡可能維持與原始相機相同的視角。在初步的訓練中，我們使用五種害蟲（蠅、蕈蠅、蠓、蕈蚋和薊馬）訓練分類模型。訓練集中包含 95、82、114、51 和 99 張影像，使用 6:2:2 的比例將其劃分為訓練、驗證和測試集。模型架構方面，我們選用與 Model A4 相同的模型架構，在這個章節中將其稱為 Model C1 和 Model C2，分別代表使用原始相機和新相機的資料集進行訓練的模型。

圖 4-45 為使用不同相機所拍攝之害蟲樣本示意圖。如前一章節所提到，使用新相機能夠獲得更多害蟲身體細節的影像。此外，我們還計算不同相機的 Tenengrad 影像清晰度分數。從圖 4-46 中可以觀察到，使用新相機的影像在整體清晰度能有顯著提升。

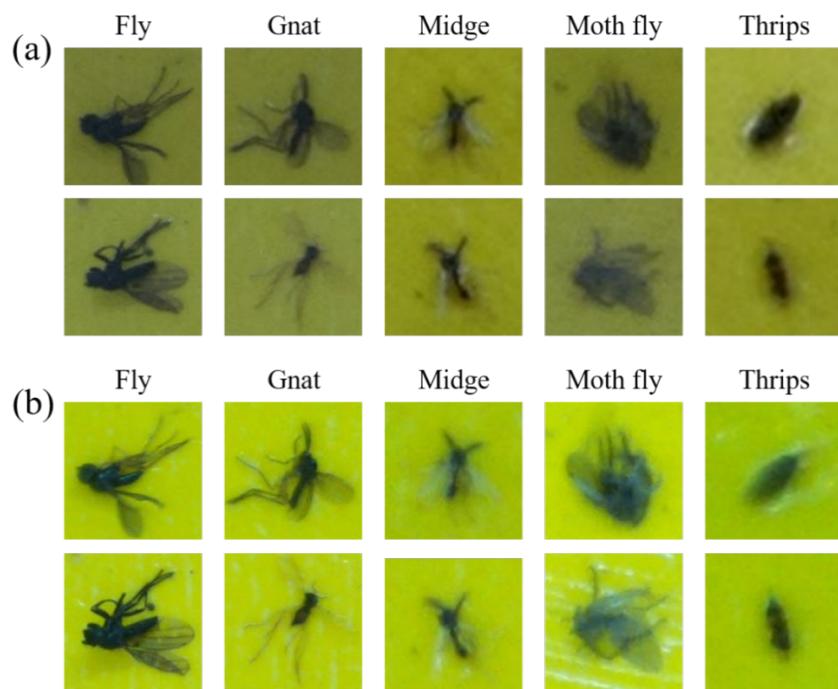


圖 4-45 不同相機拍攝之害蟲影像：(a)原始相機；(b)Arducam 64MP

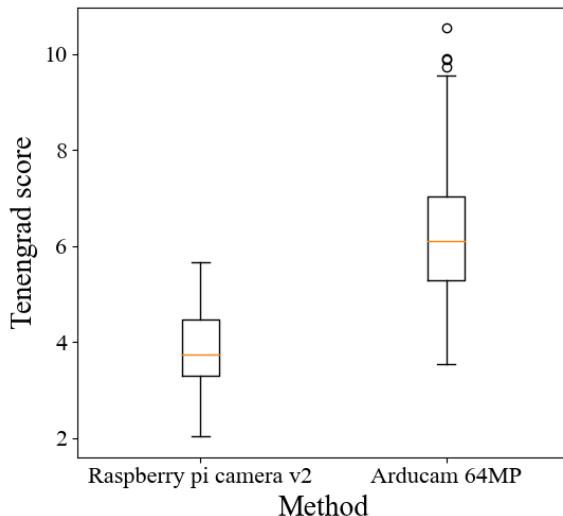


圖 4-46 不同相機所拍攝之害蟲影像清晰度計算結果，顯示更新相機後能顯著提升
影像清晰度

圖 4-47 顯示使用原始相機影像所訓練的分類模型 Model C1 測試結果，五種類別的平均 F_1 -score 約為 0.901，蠻、蕈蚋與薊馬的 F_1 -score 皆超過 0.95，顯示 Model C1 對於有效區分這三種類別，而在蠅與蕈蠅方面，Model C1 僅得到了 0.84 與 0.77 的 F_1 -score，初步推測除了體型相似外，訓練集的數量也是造成效能較差的原因。

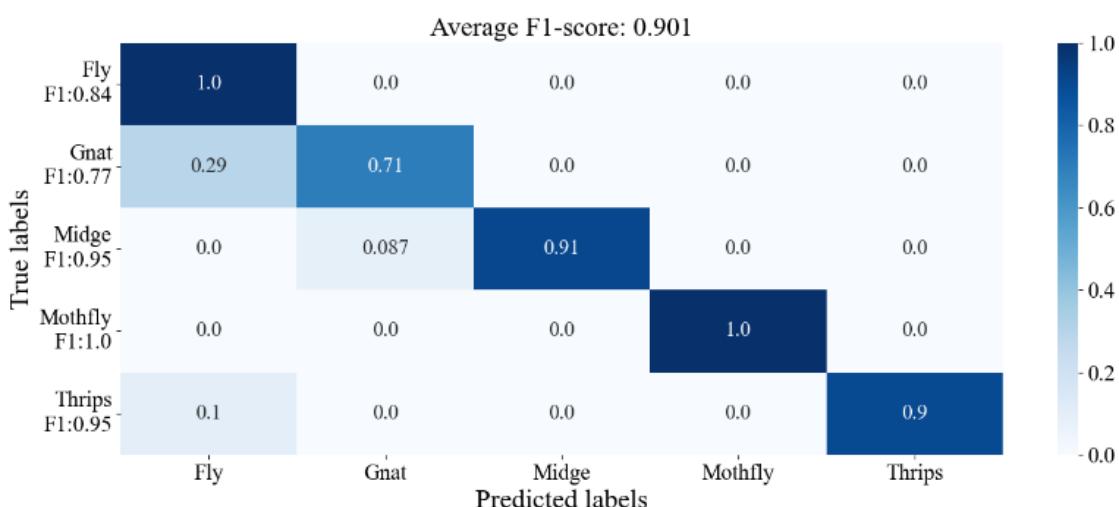


圖 4-47 Model C1 測試結果

圖 4-48 為使用新相機影像所訓練的分類模型 Model C2 測試結果，如 Model C1，在蠻、蕈蚋與薊馬的 F_1 -score 維持超過 0.95 的 F_1 -score，並且在蠅與蕈蠅的

F₁-score 分別提升 5% 與 14%，平均 F₁-score 達到 0.945，與使用原始影像相比整體提升 4.4% 的 F₁-score。

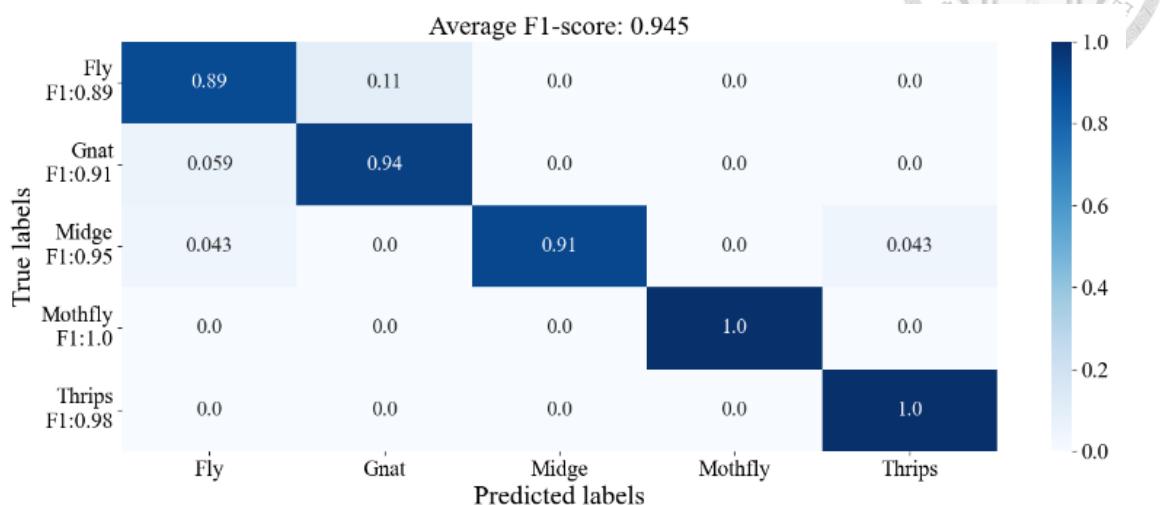


圖 4-48 Model C2 測試結果

根據前述的實驗顯示，升級相機確實可以獲得更好的影像品質，這些影像包含更多害蟲的細節特徵。進一步將這些含有更多細節特徵的影像應用於分類模型中，確實可以獲得更好的分類模型效能。由於新相機可以捕獲更多細節，這些影像提供了更豐富的資訊給分類模型。相比之下，使用原始相機拍攝的影像可能因為模糊或缺乏細節而丟失了一些重要的特徵，這會導致分類模型效能下降。因此，使用更高品質的影像進行訓練可以使模型更好地理解害蟲的特徵，從而提高模型的分類準確性。這將有助於提高我們 I²PDM 系統的性能和可靠性，並為害蟲檢測和監控等應用領域提供更準確的結果。

第五章 結論與建議



5.1 結論

本研究成功地優化害蟲辨識模型，透過影像增強和增加尺寸特徵的方法提升分類模型的效能。同時，我們提出一套自動化線上自主學習架構，在不需人力的介入下能隨著時間強化模型的效能。本研究具體觀察結果與達成目標條列如下：

SRGAN 影像增強模型：

1. 透過不同訓練樣本數量實驗得知，增加樣本數對於影像增強結果具有正向的影響，尤其在害蟲的背景雜訊的改善最為明顯，最終當各類別的樣本數增加到 350 張時可以達到最佳效果
2. 影像增強模型的方法改善，將原始的 128×128 影像直接輸入 SRGAN 模型做影像增強，在將其縮放至 128×128 能得到比起使用 32×32 做為輸入能得到更好的影像增強結果

害蟲辨識模型之優化：

1. 使用增強後的害蟲影像建立分類模型得到 F_1 -score 約 0.925，相對於使用原始影像的模型增加 2.7%，其中蠅的準確率提升約 9%；蠓提升約 3%
2. 將害蟲尺寸特徵注入 CNN 模型中建立分類模型得到 F_1 -score 約 0.921，相對原始模型增加 2.3%，其中蠅與蠓的準確率各提升約 6%
3. 結合影像增強與尺寸特徵的分類模型得到 F_1 -score 約 0.942，相對於使用原始模型增加 4.4%，其中蠅的準確率提升約 18%；蠓提升約 7%
4. 使用 McNemar 統計檢定，影像增強分類模型在蠅類取得顯著提升，尺寸特徵分類模型在蠓類上取得顯著提升，影像增強結合尺寸特徵分類模型在蠅與蠓都取得顯著提升



線上自主學習架構:

1. 經過線上自主學習流程訓練後的四種最終模型，Model A1、Model A2、Model A3 與 Model A4，分別由基礎模型的 0.898、0.925、0.921 與 0.942 提升到 0.956、0.966、0.958 與 0.968。
2. 經過動態樣本測試與統計檢定，線上自主學習更新後的模型效能，對比基礎模型有顯著的效能提升，且在 Model A1 與 Model A2 能達到與手動訓練無顯著差異的結果。
3. 使用樣本清理演算法所收集到的樣本，儘管某些類別的準確率相對較低，但在 GMM 樣本篩選的幫助下，這些錯誤的樣本與正確的樣本有一定的特徵相似性。這對模型的訓練仍然有正向的貢獻，使模型能夠有效地容忍錯誤樣本並持續進步，而不會使模型訓練走向錯誤的方向。
4. 只透過基礎模型分類新進樣本，而不使用樣本清理演算法，在線上自主學習過程中，並沒有辦法隨著時間的增加而提升模性效能，甚至可能導致模型效能下降，這驗證樣本清理演算法對於線上自主學習的重要性。
5. 成功將線上自主學習流程實際導入 I²PDM 系統中，經過五個月的資料測試，分類模型的 F₁-score 從 0.929 提升至 0.956

相機模型升級:

1. 使用 Arducam 64MP 相機進行升級，能夠拍攝到更多害蟲的細節，如足部特徵或身體紋路等。新相機拍攝的影像 DPI 約提升 2 倍，計算 Tenengrad 清晰分數後也呈現顯著提升。
2. 對比使用不同相機收集影像並訓練分類模型的測試結果顯示，相比於使用原始相機資料的分類模型的 0.901 F₁-score，使用新相機所訓練的模型可提升到 0.945，證明新相機對於分類模型的效能是有所幫助的。

本研究最終完成包括軟體和硬體兩個方面的優化。在軟體方面，使用影像增強技術和手工特徵的結合提出三種新的模型架構，相比原始的模型，這些模型各別提升約 2.7%、2.3% 與 4.4% 的 F₁-score。同時，提出一套自動化線上學習的演算法，用於自動地收集新樣本，並通過 GMM 樣本清理演算法提高樣本的可用性。

經過五個不同的基礎模型測試後，其分類能力均有效的提升。硬體方面，我們更新 I²PDM 無線取像裝置內的相機模組，捕捉更多的害蟲身體細節，經過測試，更新相機模組後，確實能對模型的效能有實際幫助。以上種種都是本研究對於 I²PDM 系統害蟲辨識效能提升所做出的貢獻。



5.2 建議

本研究優化害蟲辨識模型與建置線上自主學習架構已完成，但是，仍有幾點不足之處與建議方向，在此條列如下：

1. 目前樣本清理方法僅分析 Precision 與 Missing rate 與最終結果的關聯性，建議可嘗試分析其他指標與結果之間的關聯性，或是嘗試逐月分析樣本清理與 fine-tuning 結果之間的關聯性。
2. 目前 Training cycle 僅固定以一個月為單位，建議可嘗試比較不同的資料收集時間，如以兩個月、三個月或是半年為單位，觀察不同的時間與模型再訓練結果的關聯性。
3. 根據觀察得出，Missing rate 越低，能使自動化學習的效能接近手動的結果，建議之後可以朝著提高自動化收集樣本的 Precision 並降低 Missing rate 的方向研究。
4. 目前 SRGAN 資料集是以下採樣的方式組成，未來可嘗試使用 Arducam 64MP 相機搭配 Raspberry pi camera v2，以更高解析度的影像訓練，增進影像增強模型的效能。

參考文獻



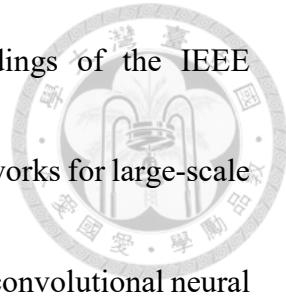
- Aiello, G., Giovino, I., Vallone, M., Catania, P., & Argento, A. (2018). A decision support system based on multisensor data fusion for sustainable greenhouse management. *Journal of Cleaner Production*, 172, 4057-4065.
- Alves, A. N., Souza, W. S., & Borges, D. L. (2020). Cotton pests classification in field-based images using deep residual networks. *Computers and Electronics in Agriculture*, 174, 105488.
- Azfar, S., Ahsan, K., Mehmood, N., Nadeem, A., Alkhodre, A. B., Alghmadi, T., & Alsaawy, Y. (2018). Monitoring, detection and control techniques of agriculture pests and diseases using wireless sensor network: a review. *International Journal of Advanced Computer Science and Applications*, 9(12), 424-433.
- Baucum, M., Belotto, D., Jeannet, S., Savage, E., Mupparaju, P., & Morato, C. W. (2017). Semi-supervised deep continuous learning. Proceedings of the 2017 International Conference on Deep Learning Technologies.
- Boyat, A. K., & Joshi, B. K. (2015). A review paper : Noise models in digital image processing. *Signal & Image Processing : An International Journal*, 6(2), 63-75.
- Bradski, G., & Kaehler, A. (2000). OpenCV. *Dr. Dobb's journal of software tools*, 3(2).
- Cho, J., Choi, J., Qiao, M., Ji, C., Kim, H., Uhm, K., & Chon, T. (2007). Automatic identification of whiteflies, aphids and thrips in greenhouse based on image analysis. *International Journal of Mathematics and Computers in Simulation*, 346(246), 244.
- Dai, Q., Cheng, X., Qiao, Y., & Zhang, Y. (2020). Agricultural pest super-resolution and identification with attention enhanced residual and dense fusion generative and adversarial network. *IEEE Access*, 8, 81943-81959.
- Domingues, R., Filippone, M., Michiardi, P., & Zouaoui, J. (2018). A comparative evaluation of outlier detection algorithms: Experiments and analyses. *Pattern recognition*, 74, 406-421.
- Dong, C., Loy, C. C., He, K., & Tang, X. (2015). Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence Access*, 38(2), 295-307.

- Dong, C., Loy, C. C., & Tang, X. (2016). Accelerating the super-resolution convolutional neural network. European conference on computer vision.
- Ehler, L. E. (2006). Integrated pest management (IPM): Definition, historical development and implementation, and the other IPM. *Pest Management Science*, 62(9), 787-789.
- Espinoza, K., Valera, D. L., Torres, J. A., López, A., & Molina-Aiz, F. D. (2016). Combination of image processing and artificial neural networks as a novel approach for the identification of *Bemisia tabaci* and *Frankliniella occidentalis* on sticky traps in greenhouse agriculture. *Computers and Electronics in Agriculture*, 127, 495-505.
- Gjestang, H. L., Hicks, S. A., Thambawita, V., Halvorsen, P., & Riegler, M. A. (2021). A self-learning teacher-student framework for gastrointestinal image classification. 2021 IEEE 34th International Symposium on Computer-Based Medical Systems (CBMS).
- Guérin, J., Thiery, S., Nyiri, E., & Gibaru, O. (2018). Unsupervised robotic sorting: Towards autonomous decision making robots. *arXiv preprint arXiv:1804.04572*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition.
- Hoi, S. C., Sahoo, D., Lu, J., & Zhao, P. (2021). Online learning: A comprehensive survey. *Neurocomputing*, 459, 249-289.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huddar, S. R., Gowri, S., Keerthana, K., Vasanthi, S., & Rupanagudi, S. R. (2012). Novel algorithm for segmentation and automatic identification of pests on plants using image processing. 2012 Third International Conference on Computing, Communication and Networking Technologies (ICCCNT'12).
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. International conference on machine learning.
- Khalifa, N. E. M., Loey, M., & Taha, M. H. N. (2020). Insect pests recognition based on deep transfer learning models. *Journal of Theoretical and Applied Information Technology*, 98(1), 60-68.

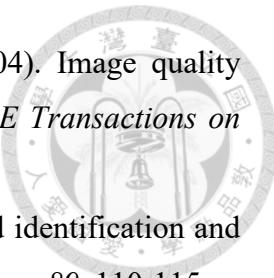


- Khan, M. A., Sharif, M., Akram, T., Raza, M., Saba, T., & Rehman, A. (2020). Hand-crafted and deep convolutional neural network features fusion and selection strategy: an application to intelligent human action recognition. *Applied Soft Computing*, 87, 105986.
- Kogan, M. (1998). Integrated pest management: historical perspectives and contemporary developments. *Annual Review of Entomology*, 43, 243-270.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., & Wang, Z. (2017). Photo-realistic single image super-resolution using a generative adversarial network. Proceedings of the IEEE conference on computer vision and pattern recognition.
- Li, F., & Xiong, Y. (2017). Automatic identification of butterfly species based on HoMSC and GLCMoIB. *The Visual Computer*, 34(11), 1525-1533.
- Lin, W. Y., Hasenstab, K., Cunha, G. M., & Schwartzman, A. (2020). Comparison of handcrafted features and convolutional neural networks for liver MR image adequacy assessment. *Scientific Reports*, 10(1), 11, Article 20336.
- Liu, T., Chen, W., Wu, W., Sun, C., Guo, W., & Zhu, X. (2016). Detection of aphids in wheat fields using a computer vision technique. *Biosystems Engineering*, 141, 82-93.
- Lu, S., & Ye, S.-j. (2020). Using an image segmentation and support vector machine method for identifying two locust species and instars. *Journal of Integrative Agriculture*, 19(5), 1301-1313.
- Maqsood, M. H., Mumtaz, R., Haq, I. U., Shafi, U., Zaidi, S. M. H., & Hafeez, M. (2021). Super resolution generative adversarial network (Srgans) for wheat stripe rust classification. *Sensors*, 21(23), 7903.
- Mohapatra, B. R., Mishra, A., & Rout, S. K. (2014). A comprehensive review on image restoration techniques. *International Journal of research in advent technology*, 2(3), 101-105.

- Oerke, E. C. (2005). Crop losses to pests. *The Journal of Agricultural Science*, 144(1), 31-43.
- Oliveira, C., Auad, A., Mendes, S., & Frizzas, M. (2014). Crop losses and the economic impact of insect pests on Brazilian agriculture. *Crop Protection*, 56, 50-54.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Pan, S. J., & Yang, Q. A. (2010). A Survey on Transfer Learning. *Ieee Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.
- Partel, V., Nunes, L., Stansly, P., & Ampatzidis, Y. (2019). Automated vision-based system for monitoring Asian citrus psyllid in orchards utilizing artificial intelligence. *Computers and Electronics in Agriculture*, 162, 328-336.
- Pech-Pacheco, J. L., Cristóbal, G., Chamorro-Martinez, J., & Fernández-Valdivia, J. (2000). Diatom autofocusing in brightfield microscopy: a comparative study. Proceedings 15th International Conference on Pattern Recognition. ICPR-2000.
- Picanço, M. C., Bacci, L., Crespo, A. L. B., Miranda, M. M. M., & Martins, J. C. (2007). Effect of integrated pest management practices on tomato production and conservation of natural enemies. *Agricultural and Forest Entomology*, 9(4), 327-335.
- Rajan, R. G., & Leo, M. J. (2020). American sign language alphabets recognition using hand crafted and deep learning features. 2020 International Conference on Inventive Computation Technologies (ICICT).
- Raschka, S. (2018). Model evaluation, model selection, and algorithm selection in machine learning. *arXiv preprint arXiv:1811.12808*.
- Reynolds, D. A. (2009). Gaussian mixture models. *Encyclopedia of biometrics*, 741(659-663).
- Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 20, 53-65.
- Rustia, D. J. A., Lin, C. E., Chung, J.-Y., Zhuang, Y.-J., Hsu, J.-C., & Lin, T.-T. (2020). Application of an image and environmental sensor network for automated greenhouse insect pest monitoring. *Journal of Asia-Pacific Entomology*, 23(1), 17-28.
- Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., & Wang, Z. (2016). Real-time single image and video super-resolution using an



- efficient sub-pixel convolutional neural network. Proceedings of the IEEE conference on computer vision and pattern recognition.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. International conference on machine learning.
- Tetila, E. C., Machado, B. B., Astolfi, G., Belete, N. A. d. S., Amorim, W. P., Roel, A. R., & Pistori, H. (2020). Detection and classification of soybean pests using deep learning with UAV images. *Computers and Electronics in Agriculture*, 179.
- Thenmozhi, K., & Srinivasulu Reddy, U. (2019). Crop pest classification based on deep convolutional neural network and transfer learning. *Computers and Electronics in Agriculture*, 164.
- Thomas, M. B. (1999). Ecological approaches and the development of "truly integrated" pest management. *Proceedings of the National Academy of Sciences of the United States of America*, 96(11), 5944-5951.
- Tianyu, Z., Zhenjiang, M., & Jianhu, Z. (2018). Combining cnn with hand-crafted features for image classification. 2018 14th ieee international conference on signal processing (icsp).
- Voulodimos, A., Doulamis, N., Doulamis, A., & Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Comput Intell Neurosci*, 2018, 7068349.
- Wang, Q.-J., Zhang, S.-Y., Dong, S.-F., Zhang, G.-C., Yang, J., Li, R., & Wang, H.-Q. (2020). Pest24: A large-scale very small object data set of agricultural pests for multi-target detection. *Computers and Electronics in Agriculture*, 175.
- Wang, X., Wang, C., Yao, J., Fan, H., Wang, Q., Ren, Y., & Gao, Q. (2022). Comparisons of deep learning and machine learning while using text mining methods to identify suicide attempts of patients with mood disorders. *Journal of affective disorders*, 317, 107-113.
- Wang, Y., Shen, J., Petridis, S., & Pantic, M. (2019). A real-time and unsupervised face re-identification system for human-robot interaction. *Pattern recognition letters*, 128, 559-568.



- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600-612.
- Wen, C., & Guyer, D. (2012). Image-based orchard insect automated identification and classification method. *Computers and Electronics in Agriculture*, 89, 110-115.
- Xie, C., Wang, R., Zhang, J., Chen, P., Dong, W., Li, R., Chen, T., & Chen, H. (2018). Multi-level learning features for automatic classification of field crop pests. *Computers and Electronics in Agriculture*, 152, 233-241.
- Yao, Q., Xian, D.-X., Liu, Q.-J., Yang, B.-J., Diao, G.-Q., & Tang, J. (2014). Automated Counting of Rice Planthoppers in Paddy Fields Based on Image Processing. *Journal of Integrative Agriculture*, 13(8), 1736-1745.
- Zhang, L., Zhang, L., Mou, X., & Zhang, D. (2012). A comprehensive evaluation of full reference image quality assessment algorithms. 2012 19th IEEE International Conference on Image Processing. Vienna, Austria.
- Zhang, T., & Zhang, X. (2021). Injection of traditional hand-crafted features into modern CNN-based models for SAR ship classification: What, why, where, and how. *Remote Sensing*, 13(11), 2091.
- Zhou, H., Miao, H., Li, J., Jian, F., & Jayas, D. S. (2019). A low-resolution image restoration classifier network to identify stored-grain insects from images of sticky boards. *Computers and Electronics in Agriculture*, 162, 593-601.