

整合深度學習與多目標追蹤技術於百香果 自動化篩選系統之研製¹

陳信彰²、洪榆宸^{2*}、張金元²、張佳偉²

摘 要

本研究旨在開發一套整合影像辨識與機電控制技術之「百香果病徵即時偵測與自動化篩選系統」。在影像辨識方面，導入多目標追蹤技術進行定位優化，僅使用 YOLO 進行高速辨識時，容易受運算負載而導致偵測不穩定或漏檢情形。實驗評估比較 YOLOv8-Nano(v8n)搭載 7 種追蹤演算法(ByteTrack、BoT-SORT、OC-SORT、DeepOC-SORT、Strong-SORT、BoostTrack、Hybrid-SORT)與單獨 v8n 模型之效能差異，採兩階段評估流程：首階段針對辨識效能(精確率、召回率與 F1-score)進行初步篩選，評估原生 v8n 以及結合 7 種不同追蹤演算法之 v8n 配置間的統計顯著性與系統穩定度；次階段則透過多目標追蹤效能指標進行演算法效能的綜合定論。結果顯示，在模型綜合辨識效能評估下，v8n-OC-SORT 與 v8n-BoostTrack 展現較佳的平衡，如兩者的 F1-score 分別達 88.6%與 88.0%，於統計表現上領先其它演算法。然而，兩者在多目標追蹤效能指標比較中，v8n-OC-SORT 展現出最佳整體效能：其多目標追蹤準確率(MOTA)達到 85.4%，相較之下 v8n-BoostTrack 只達 58.8%；且在衡量追蹤穩定性(IDF1)指標上高達 92.3%，身份切換次數(IDs)僅 7 次。因此，在百香果病果汰除作業上，使用 v8n-OC-SORT 能有效克服目標遮擋與身份混淆，具備系統可靠性，更能有效應對複雜環境，展現整體效能穩定性。

關鍵字：百香果、影像辨識、深度學習、追蹤演算法

前 言

臺灣百香果產業在採後處理階段長期仰賴人工進行分級與篩選，傳統作業不僅耗

¹ 農業部臺中區農業改良場研究報告第 1123 號。

² 農業部臺中區農業改良場計畫助理、助理研究員、副研究員、助理研究員。

*通訊作者：洪榆宸，Email: ychung@tcdares.gov.tw

時、勞力密集且成本高昂，更重要的是，人工判讀易受主觀意識與疲勞影響，導致篩選標準不一或計數誤差，難以作為供應鏈管理所需的精確數據。在市場對於無瑕疵、高品質水果的需求日益嚴格，為解決農業缺工與品質管控，迫切需要導入自動化、非侵入式的智慧偵測系統，以提升作業效率並確保農產品的經濟價值(Chen *et al.*, 2021)。百香果在進入自動化篩選產線後，其圓球狀外型在輸送帶上易產生無規則的滾動與碰撞，導致影像監測中的目標軌跡難以預測。此外，高密度作業下的果實密集堆疊與相互遮擋，加上輸送設備振動所引發的影像模糊，皆會影響影像辨識系統的追蹤穩定性與病害辨識率。這些場景下的技術瓶頸，使得傳統演算法難以直接應用，需要針對其特性進行最佳化設計。

為解決傳統方法的局限，影像辨識與深度學習技術在近年有顯著突破。以YOLO(You Only Look Once)系列為代表的單階段目標偵測演算法，因其在速度與準確度上的優異平衡，已成為農業領域的主流選擇。YOLOv8透過提出C2f模組的結構優勢，在保持輕量化的同時顯著提升特徵提取能力，適用於處理百香果這類具備複雜遮蔽與小目標特性的作物(Tu *et al.*, 2025; Wu *et al.*, 2025)。然而，單純的目標偵測在面對輸送帶或連續影像等動態場景時仍顯不足，必須結合多目標追蹤(Multi-Object Tracking, MOT)技術以避免重複計數並鎖定個別果實的ID。為解決上述傳統追蹤框架的侷限，多目標追蹤(MOT)技術近年來經歷了顯著的演進。Alex Bewley等人提出的SORT演算法有效利用卡爾曼濾波與匈牙利演算法可解決基本抖動與ID不連貫等問題，但應對複雜場景仍稍不足(Bewley *et al.*, 2016)。後續研究衍生出兩大改良方向：其一是以DeepSORT、StrongSORT為代表(Du *et al.*, 2023; Yang *et al.*, 2022)，透過引入重新識別(Re-ID)來解決身分交換問題，惟犧牲運算速度；其二是以ByteTrack、BoT-SORT與BoostTrack為代表，透過強化ID連貫性策略，例如利用低信心偵測框來提升召回率(Aharon *et al.*, 2022; Stanojevic & Todorovic, 2024; Zhang *et al.*, 2022)。然而傳統的卡爾曼濾波器在處理非線性運動或長時間遮蔽時容易產生ID切換(ID Switch)的錯誤(Du *et al.*, 2024)。近期研究OC-SORT演算法透過「以觀測為中心」的更新策略，能有效解決果實因遮蔽或震動造成的軌跡丟失問題，在百香果與蘋果的動態計數中展現優於DeepSORT的穩定性(Tan *et al.*, 2025)；而ByteTrack演算法則透過ID連貫性，使低信心分數的偵測框，進一步提升在密集場景下的追蹤精度(Dong *et al.*, 2025)。


基於上述背景，本研究旨在研發一套整合深度學習偵測模型與目標追蹤技術的「百香果病徵即時偵測與自動化篩選系統」。本研究將採用YOLOv8模型作為偵測

心，並結合多種追蹤演算法，搭配篩選機構，以解決百香果在動態輸送過程中因光影變化及高速移動所導致的辨識難題。

材料與方法

一、系統架構敘述(System Overview)


本研究開發一套百香果病徵即時偵測與自動化篩選系統，旨在整合深度學習影像辨識、多目標追蹤技術(MOT)與機電控制，以自動化作業取代傳統人工篩選。系統架構依功能屬性劃分為「影像辨識處理單元」與「自動化傳輸控制機構」兩大核心模組，採用分層式控制架構運作。整體硬體配置依據訊號處理流程，由左至右劃分為感知輸入、核心運算與控制輸出三大層級，如圖一所示：



圖一、系統系統組成與硬體架構示意圖。

Fig. 1. Schematic diagram of system components and hardware architecture.

當影像辨識判定果實為病果時，運算平台透過序列通訊發送觸發指令至微控制器(Arduino MEGA 2560 Rev3)。控制器驅動步進馬達，將病果精確導向至次級品收集區；若判定為無病害果實，則不觸發使果實順利通過。為確保影像識別之精確度與執行機構之響應速度，本系統選用Yabhoome高幀率廣角攝影機作為影像輸入核心，架設於輸送帶上方41 cm處以垂直俯視視角進行900×600解析度之連續影像採集；攝影機幀率(FPS)設定為60 fps，攝影機規格及參數如圖二、表一所示。



圖二、攝影機規格示意圖。

Fig. 2. Schematic diagram of camera specifications.


表一、攝影機參數性能表

Table 1. Specification and performance of camera

參數項目	設定值/說明
攝影機型號(Camera Model)	Yabhoome 高幀率廣角攝影機
解析度(Resolution)pixels	900 × 600
畫面更新率(FPS)	60
亮度(Brightness)	0
對比(Contrast)	32
曝光(Exposure)EV	-6.0
放大倍率(Magnification)	-1.0
焦距(Focal Length)	-1.0
飽和度(Saturation)	50
清晰度(Sharpness)	2
色差補正(Gamma Correction)	100
白平衡(White Balance)K	4600
背光補償(BLC)	1

二、外掛式篩選機構設計

本研究針對百香果重量式分級機設計外掛式篩選機構，其機構掛載於分級機之配重機構上，採用步進馬達作為動力來源，在控制端，由Arduino MEGA 2560 Rev3發送訊號至馬達控制板，精確驅動步進馬達帶動配重機構，在連續運作中達成精準的汰除病果作業，如圖三所示。攝影機架設於輸送路徑正上方，形成固定的拍攝視角與取像點，此配置不僅確保影像的穩定性，更確立了取像點至執行機構的固定距離，配合恆定的輸送速率，作為後續計算精確觸發延遲的基礎。



圖三、篩選系統硬體架構。(a)篩選機構設計示意圖；(b)百香果重量式分級機實體配置。
Fig. 3. Hardware architecture of the grading system. (a) Schematic Diagram of the Screening Mechanism; (b) Physical layout of the weight-based passion fruit grader.

系統採用「距離延遲控制」：當影像辨識到病果時，微控制器會依據「取像點至執行機構的距離」與「輸送速率」，計算出精確的延遲時間，如式(1)所示：

$$T_{delay} = \frac{L}{V} \quad (1)$$

其中：

- T_{delay} 為觸發延遲時間(s)
- L 為攝影機取像點至執行機構之距離(m)
- V 為輸送速率(m/s)

確保執行機構能在果實抵達作動區時精準觸發，系統需計算果實從取像點至作動點的物理位移時間(T_{delay})。經計算， $L = 0.39$ m 且 $V = 0.5$ m/s 時，經實測，整體機構之響應時間(Response Time)約為0.78 s，完成病果汰除作業後即自動復歸，以利後續篩選流程。

三、影像辨識流程與判斷策略

為滿足篩選系統之即時性(Real-time)需求，需要龐大系統計算量，於軟體端導入Python的多執行緒(Multi-threading)平行處理架構(Mei *et al.*, 2018)。傳統的序列式處理流程中，攝影機取像、演算法推論與硬體控制訊號發送皆在同一執行緒中依序進行，其將導致系統在等待影像辨識運算時，無法同時進行下一幀影像的擷取，進而造成幀率(FPS)下降與觸發延遲。

引入「非排序處理任務」設計，利用threading模組將核心任務解耦為3個獨立運行的執行緒，分別為：


- (一) 影像擷取執行緒(Image Capture Thread)：從攝影機持續讀取畫面、幀率，並存入共享緩衝區(Buffer Queue)，確保取像不因後端運算而中斷。
- (二) 辨識運算執行緒(Inference Thread)：從緩衝區提取影像進行YOLO模型推論，判斷病果與位置。
- (三) 硬體控制執行緒(Control Thread)：根據辨識結果計算延遲時間，並透過序列埠(Serial)非同步發送指令至微控制器，驅動步進馬達進行篩選。

透過佇列(Queue)作為執行緒間通訊橋樑，系統實現了非同步的資料擷取與處理機制，有效解決I/O阻塞問題，確保硬體機構動作與影像處理流程能精確同步，如圖四所示。


為實現自動化篩選系統的即時監控、除錯便利性以及運作狀態的可視化，本研究基於 Python開發一套整合式圖形使用者介面(GUI)。此介面採用多執行緒架構設計，將介面刷新、影像擷取辨識與硬體控制邏輯分離，確保在進行高負載運算時，監控畫面仍能保持流暢即時。如圖五所示，本系統之監控介面主要劃分為三個功能區塊，茲說明如下：

- (一) 即時影像處理顯示區(Live Video Feed)：介面主體為攝影機視野的即時串流。系統將後端演算法(如YOLO)辨識完成的結果，包含果實目標框(Bounding Box)、類別標籤及信心指數，顯示於原始影像上。

排序處理任務




非排序處理任務



圖四、非排序處理任務示意圖。

Fig. 4. Schematic diagram of a non-sequential processing task.




圖五、GUI 可視化界面示意圖。

Fig. 5. Schematic diagram of GUI visualization interface.

- (二)即時影像處理顯示區(Live Video Feed): 介面主體為攝影機視野的即時串流。系統將後端演算法(如YOLO)辨識完成的結果，包含果實目標框(Bounding Box)、類別標籤及信心指數，顯示於原始影像上。
- (三)篩選排序佇列動態監視(Dynamic Sorting Queue): 為視覺化軟體內部的決策流程，介面側邊設計一個動態列表，用以映射當前輸送帶上的果實狀態。此佇列依循先進先出(FIFO)原則，即時顯示即將經過執行機構的果實類別順序(例如：觸發Rule1、觸發Rule2)。
- (四)Arduino MEGA 2560 Rev3控制訊號觸發日誌(Control Signal Log): 介面下方設有滾動式的純文字日誌區，詳細記錄控制端發送至微控制器的所有關鍵指令及其精確的時間戳記。

四、追蹤演算法引入

在影像辨識領域中，目標偵測模型(如YOLO系列)雖然能提供單張影像中的目標位置，但若直接應用於連續影像分析，往往面臨「不穩定」的挑戰。根據Zhang等人的研究指出，影像偵測的品質不應僅由準確度(如Precision)來衡量，更應包含時間軸上的穩定性(Zhang & Wang, 2016)。事實上，偵測器的準確度與穩定性之間的相關性並不高，高準確度的偵測器仍可能產生劇烈的軌跡抖動。



圖六、影像偵測不穩定說明示意圖。目標框(綠色)、預測框(橘色)。

Fig. 6. Schematic diagram of unstable image detection. Target bounding box(green), prediction bounding box (orange).

單純使用YOLO即時演算法會導致多種不穩定誤差，如圖六所示，這些誤差正是引入追蹤演算法所要解決的核心問題：

- (一) 軌跡遺失(Fragment Error)：受限於遮擋或動態模糊，偵測器常在某些幀中遺漏目標(如圖紅色打叉處)，導致連續的軌跡斷裂，破壞了軌跡的完整性。
- (二) 中心位置與尺度抖動(Center Position & Scale Jittering)：如圖所示，偵測器對每一幀獨立運算，導致預測框的中心點與長寬比在連續畫面中產生隨機跳動。
- (三) 缺乏身分識別(Lack of Identity)：偵測器無法記憶目標，當多個目標彼此靠近或交錯時，無法區分個體。

為解決上述的穩定性問題，並同時維持系統的即時運算能力，單純依賴目標偵測器進行連續分析往往面臨中心抖動、軌跡破碎與身分缺失等穩定性挑戰，因此引入多目標追蹤(MOT)演算法。以下針對本研究所評估之7種追蹤演算法核心特色進行說明：

1. ByteTrack：藉由保留並回收低置信度(Low-confidence)的偵測框參與關聯匹配，有效降低因目標受遮蔽或模糊而造成的軌跡中斷與漏檢現象(Zhang *et al.*, 2022)。
2. BoostTrack：延續回收低置信度偵測框的優勢，並進一步針對追蹤演算法在複雜環境下的匹配機制進行優化，強化目標關聯的整體穩定度(Stanojevic & Todorovic, 2024)。
3. OC-SORT (Observation-Centric SORT)：主要利用真實觀測值來修正卡爾曼濾波器的預測誤差，透過慣性補償與虛擬軌跡策略，有效克服目標非線性運動與遮蔽帶來的軌跡漂移(Cao *et al.*, 2023)。
4. DeepOC-SORT：在OC-SORT強大的運動學修正基礎上，進一步融合了深度外觀特徵(Appearance Features)，使其在目標密集交錯或外觀相似的情境下，能更精準地維持身分(ID)一致性(Maggiolino *et al.*, 2023)。
5. BoT-SORT (Bag-of-Tricks SORT)：引入相機運動補償(Camera Motion Compensation, CMC)技術與優化後的卡爾曼濾波狀態，能有效穩定動態視角與背景位移下的目標追蹤(Aharon *et al.*, 2022)。
6. Strong-SORT：結合了強化的特徵提取網路與更嚴謹的運動狀態估計，並配備無外觀關聯機制(AFLink)，以提升整體軌跡的平滑度與長效身分保持能力(Du *et al.*, 2023)。

7. Hybrid-SORT：在匹配過程中加入目標高度等輔助狀態線索，結合運動學與特徵資訊，進一步強化在擁擠或高度重疊場景下的追蹤平滑度與穩定性(Yang *et al.*, 2024)。

五、統計方法與效能指標

評估系統實際之分類效能並確保實驗數據之可靠性，本研究於評估實驗中共採用45顆百香果作為測試樣本。樣本組態設定為正常果30顆、病果15顆，正常果與病果之比例為2:1。為確保實驗數據之可靠性並降低隨機誤差，首先採用九重複 (Triplicate, $n=9$)實驗設計。針對每一組參數設定均進行九次獨立測試，並以算術平均數(μ)與樣本標準差(s)作為數據之中心趨勢與離散程度代表，其計算方式分別如下，如式(2)所示：

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i, \quad s = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n - 1}} \tag{2}$$

其中 x_i 代表第 i 次測試之觀測值。在靜態分類效能方面，定義精確率 (Precision)與召回率(Recall)和F1-score作為核心指標；Precision用於衡量模型在判定為正類樣本中之準確程度，而Recall則反映模型對實際正類樣本的檢出能力；透過F1-score綜合評估，以全面衡量自動化篩選系統之分類性能。

(一) 混淆矩陣(Confusion Matrix)

透過比較模型預測與實際標籤，混淆矩陣可視覺化地呈現出模型的預測結果分佈，包含四個主要組成項目：真陽性(True Positive, TP)、假陽性(False Positive, FP)、真陰性(True Negative, TN)與假陰性(False Negative, FN)，如下圖九所示。

	Positive	Negative
Positive	TP (True Positive)	FP (False Positive)
Negative	FN (False Negative)	TN (True Negative)

圖七、混淆矩陣示意圖。
Fig. 7. Schematic Diagram of the Confusion Matrix.

其中：

1. TP(True Positive)：實際為病果，且模型正確辨識為病果。
2. FP(False Positive)：實際無病果，但模型誤判為病果(誤報)。
3. FN(False Negative)：實際有病果，但模型未能成功辨識(漏檢)。
4. TN(True Negative)：實際無病果，且模型正確判定為無病果。

基於混淆矩陣之統計結果，為更全面評估模型之分類效能，本研究進一步採用包含精確率(Precision)與召回率(Recall)及F1-score等指標進行分析，其定義如下所示：

精確率(Precision)：衡量所有被預測為病果樣本中，實際為病果的比例，如式(3)所示。

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

召回率(Recall)：衡量所有實際為病果樣本中，被模型正確辨識出的比例，如式(4)所示。

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

F1 - score :為Precision與Recall的調和平均，用以綜合評估模型在精確率與召回率之整體表現，其計算方式如式(5)所示。

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

透過 Precision、Recall 與 F1-score 等指標，可全面評估模型之分類效能。

(二) Tukey HSD事後檢定(Tukey HSD Post-hoc Test)

判別標準：如果計算出的 $P\text{-value} \leq 0.05$ ，則拒絕虛無假設(H_0)，代表至少有兩個模型的表現有顯著統計差異，如式(8)所示。

$$HSD = q_{\alpha, k, v} \sqrt{\frac{MS_W}{n}} \quad (8)$$

(三) 多目標追蹤準確率評估(MOTA Evaluation)

藉此精確區辨不同模型配置間的效能優劣。最後，為評估系統在動態場景下的連續監測能力，本研究導入多目標追蹤準確率(MOTA)。此指標綜

合考量漏檢(FN)、誤報(FP)以及目標編號切換($IDsw_t$)等誤差類型，其數學定義如下，如式(9)所示：

$$MOTA = 1 - \frac{\sum_t (FN_t + FP_t + IDsw_t)}{\sum_t GT_t} \quad (9)$$


其中 t 為幀數索引，GT為第 t 幀之真實目標總數。MOTA能與前述之Precision、Recall及F1-score互為補充，建構出完整的系統效能評估框架。

結果與討論

本章節旨在分析不同 YOLOv8-Nano(v8n)追蹤演算法配置在動態追蹤的綜合效能。透過分析 $n=9$ 次重複實驗數據，首先以辨識指標精確率(Precision)與召回率(Recall)進行比較後，透過 Tukey HSD 事後檢定分析各模型之統計顯著性差異，最後再以綜合評估指標 F1-score 進行探討。

一、辨識效能分析

根據圖八之實驗結果，v8n-Hybrid-SORT在精確率(Precision)指標上達91.2%，於本次比較的模型中表現最佳。此結果初步顯示，該模型在抑制背景雜訊對匹配機制的干擾上具備潛力，推測將有助於減少百香果病徵之誤報(False Positive, FP)情形。




圖八、YOLOv8-Nano 搭配各追蹤演算法配置精確率比較圖。

Fig. 8. Comparison of Average Precision Among YOLOv8-Nano Tracker Configurations.

其次為v8n-OC-SORT(86.0%)與v8n-BoostTrack(83.0%)，兩者亦維持相對穩定之精確率表現，顯示其特徵關聯與目標匹配機制具備良好可靠度。相較之下，v8n-BoT-SORT之平均精確率為48.2%，顯著低於其他模型，代表很多不是病果被判成病果，意指部分背景雜訊或瑕疵目標被錯誤賦予有效ID，導致誤報率增加。

根據圖九之召回率(Recall)結果，各追蹤演算法在避免漏檢能力上呈現差異。v8n-BoostTrack以94.2%之召回率位居首位，其後依序為v8n-BoT-SORT(94.1%)、v8n-Strong-SORT(93.9%)與v8n-DeepOC-SORT(93.2%)，皆維持於高召回率區間。此結果顯示上述模型在動態場景與短暫遮蔽條件下，能有效維持目標持續檢出能力，降低漏檢(False Negative, FN)發生機率。

然而，各模型結合在各追蹤演算法後，精確率與召回率之間呈現不同程度之權衡關係。例如，v8n-Hybrid-SORT之召回率為64.3%，為所有追蹤演算法中最低。此現象可能與其匹配門檻設定較為嚴格有關，使部分真實目標未被納入追蹤範圍。相對地，v8n-OC-SORT 在維持 91.4%召回率的同時，亦未出現精確率下降之情形，顯示其在目標關聯與匹配策略上取得較為均衡的表現。




圖九、YOLOv8-Nano 搭配各追蹤演算法配置召回率比較圖。

Fig. 9. Comparison of Average Recall Among YOLOv8-Nano Tracker Configurations.

二、Tukey HSD (Honestly Significant Difference)分析

在前述辨識效能評估中所觀察到之數據落差，本研究進一步採用Tukey HSD進行成對比較，並透過顯著性矩陣視覺化各追蹤演算法之間的統計距離，其中 $P \leq 0.05$

之深綠色區塊代表模型間存在顯著差異，而 $P > 0.05$ 之淺色或白色區塊則表示無顯著差異。



圖十、YOLOv8-Nano 搭配不同追蹤演算法於(a)精確率(b)召回率之 Tukey HSD 比較結果。

Fig. 10. Tukey HSD significance matrices for (a) precision and (b) recall among tracking algorithms.


從圖十(a)之精確率顯著性矩陣可觀察到，表現相對較低的v8n-BoT-SORT及v8n-Strong-SORT，比較多數模型之 P 值皆小於0.05(深綠色區塊)，顯示其精確率顯著低於其他演算法。此結果反映該類模型在抑制誤報方面之穩定性較不足，於複雜背景或特徵干擾情境下較易產生錯誤辨識。相對而言，精確率表現較佳之模型(如v8n-Hybrid-SORT、v8n-OC-SORT與v8n-BoostTrack)彼此間之 P 值皆大於0.05(如v8n-Hybrid-SORT與v8n-OC-SORT之比較 $P = 0.94$)，顯示其精確率於統計上並無顯著差異，可歸屬於同一表現。另一方面，在圖十(b)之召回率顯著性矩陣中，數據呈現不同之分布趨勢。v8n-Hybrid-SORT與其他所有模型之比較 P 值皆小於0.05，顯示其召回率顯著低於其餘模型，反映該模型於持續追蹤目標與避免漏檢方面存在明顯不足。相對地，召回率表現優異之模型(包括v8n-BoostTrack、v8n-OC-SORT及v8n-DeepOC-SORT等)彼此間之 P 值皆大於0.05，顯示其在目標捕捉能力上具備統計上的等效性與高度一致性。

綜合兩項指標之Tukey HSD檢定結果可知，部分模型(如Hybrid-SORT、BoT-

SORT)雖於單一評估指標上展現相對優勢，但同時伴隨另一指標之顯著劣勢，顯示其整體效能存在權衡現象。相較之下，v8n-OC-SORT與v8n-BoostTrack在精確率與召回率之統計檢定中皆維持於無顯著差異之領先群組內，顯示其於雙指標間具備較佳之平衡性與整體穩定度。

三、F1-score分析

由圖十一結果顯示，在整合不同追蹤演算法後，各模型於F1-score表現上存在差異。其中 v8n-OC-SORT之F1-score為88.6%，為所有方法中表現最佳，顯示其有多目標追蹤過程中能有效維持目標識別與追蹤的穩定性。其次為v8n-BoostTrack (88.0%)與v8n-DeepOC-SORT(84.9%)。相較之下，v8n-BoT-SORT之F1-score僅為62.7%，為所有追蹤演算法中最低，且其標準差相對較大，顯示在不同測試情境下表現較不穩定。而v8n-ByteTrack(79.5%)、v8n-StrongSORT(75.8%)及v8n-HybridSORT (74.9%)則屬於中等表現，綜合上述分析結果可知，v8n-OC-SORT與v8n-BoostTrack在精確率與召回率之平衡表現上，具有較佳表現。



圖十一、YOLOv8-Nano 搭配不同追蹤演算法之 F1-score 比較。

Fig. 11. Average F1 Score of YOLOv8-Nano with Various Tracking Algorithms.

四、多目標追蹤效能指標之分析

針對v8n-OC-SORT與v8n-BoostTrack兩種多目標追蹤演算法進行量化評估，實驗結果如表四、表五所示。在表四中，IDF1為衡量追蹤穩定性與身份一致性之指標，

其值v8n-OC-SORT高達92.3%，相較v8n-BoostTrack之59.4%，兩者相差約3成。其表明v8n-OC-SORT在處理目標遮擋或交互運動時，能夠極有效地維持同一目標的ID，大幅減少身份切換(ID Switch)的錯誤。此外，從識別精確率(IDP)與識別召回率(IDR)來看，v8n-OC-SORT分別達到96%與88.9%，均顯著優於v8n-BoostTrack，顯示出該模型在特徵提取與關聯匹配上的穩定性。

在軌跡完整性的表現上，v8n-OC-SORT同樣表現出色。數據顯示，v8n-OC-SORT將絕大多數的目標歸類為多數被追蹤(Mostly Tracked, MT)，數量達到52個，且僅有2個目標被歸類為多數丟失(Mostly Lost, ML)。相比之下，v8n-BoostTrack的MT僅為31個，且ML高達7個，說明BoostTrack在長時間追蹤過程中容易發生軌跡斷裂或丟失目標的情況。綜合RcII與Prcn的高水準表現，v8n-OC-SORT在偵測覆蓋率與追蹤連續性上均優於v8n-BoostTrack，更適合應用於對漏檢率與身份錯誤敏感的場景。

表四、多目標追蹤各項指標分析-1

Table 4. Comparison of Multi-Object Tracking Accuracy

Model	IDF1 (%) ¹	IDP (%) ²	IDR (%) ³	RcII (%) ⁴	Prcn (%) ⁵	GT ⁶	MT ⁷	PT ⁸	ML ⁹
v8n-OC-SORT	92.3	96	88.9	89.0	96.2	67	52	13	2
v8n-BoostTrack	59.4	71.4	50.9	66.5	93.4	86	31	48	7

¹IDF1 (Identification F1-score): the F1-score for identity recognition.

²IDP (Identification Precision): the precision of identity recognition.

³IDR (Identification Recall): the recall of identity recognition.

⁴RcII (Recall): the recall rate.

⁵Prcn (Precision): the precision rate.

⁶GT (Ground Truth): the total number of ground-truth trajectories.

⁷MT (Mostly Tracked): the number of trajectories that are mostly tracked.

⁸PT (Partially Tracked): the number of trajectories that are partially tracked.

⁹ML (Mostly Lost): the number of trajectories that are mostly lost.

在表五中，MOTA為多目標追蹤綜合整體之指標，其值v8n-OC-SORT達85.4%，優於v8n-BoostTrack之58.8%。另細究誤檢數(FP)、漏檢數(FN)與身份切換數(IDs)三項指標，兩者性能差異主要來自FN與IDs。v8n-BoostTrack的漏檢數(FN)高達1278，約為v8n-OC-SORT的2.6倍，顯示其在追蹤過程中較易發生目標遺失，進而導致追蹤中斷。進一步由目標身份轉移(IDt)、目標身份新增(IDa)與目標身份遺失(IDm)等指標觀察可知，v8n-BoostTrack在IDt與IDa上皆高於v8n-OC-SORT，且亦發生身份遺失(IDm)，反映其在目標身份管理上的不穩定性。在身份切換數(IDs)方面，

v8n-OC-SORT 僅發生7次，顯著低於v8n-BoostTrack之117次，顯示其在多目標情境下仍能維持穩定的目標身份對應關係。此外，在軌跡連續性方面，v8n-OC-SORT的軌跡碎片數(FM)為81，顯著低於v8n-BoostTrack之211，顯示其追蹤軌跡具有穩定且連續性。至於定位精度(MOTP)方面，v8n-BoostTrack略優於v8n-OC-SORT，顯示其在目標位置估計上具有較高精度。整體而言，v8n-OC-SORT在降低漏檢、抑制身份切換及維持軌跡完整性方面均具優勢，整體追蹤效為最具代表性的。

表五、多目標追蹤各項指標分析-2

Table 5. Comparison of Multi-Object Tracking Accuracy

Model	FP ¹	FN ²	IDs ³	FM ⁴	MOTA(%) ⁵	MOTP ⁶	IDt ⁷	IDa ⁸	Idm ⁹
v8n-OC-SORT	81	408	7	81	85.4	0.003	0	4	0
v8n-BoostTrack	179	1278	117	211	58.8	0.001	10	85	1

¹FP (False Positives): the number of false detections.

²FN (False Negatives): the number of missed detections.

³IDs (Identity Switches): the number of identity switches.

⁴FM (Fragmentations): the number of trajectory fragmentations.

⁵MOTA (Multiple Object Tracking Accuracy): the accuracy of multi-object tracking.

⁶MOTP (Multiple Object Tracking Precision): the precision of multi-object tracking.


⁷IDt (Identity Transfers): the number of identity transfers.

⁸IDa (Identity Additions): the number of identity additions.

⁹IDm (Identity Misses): the number of identity losses.


OC-SORT演算法主要在保留SORT高速架構的優勢下，引入2項關鍵技術以克服傳統濾波器的局限性(Mei *et al.*, 2023)。首先，針對百香果受影像光線遮擋等情況所造成的軌跡漂移，演算法利用以觀測修正預測(Observation-Centric Re-Update, ORU)機制，採取虛擬軌跡(Virtual Trajectory)策略來回溯並修正預測誤差，如圖十二所示。

其次，針對百香果在分級機上受到震動或輕微相機誤差產生的非線性運動，則引入以觀測為中心的動量(Observation-Centric Momentum, OCM)，將動量方向的一致性納入ID連貫性計算，如圖十三所示。上述機制使其能有效應對高速移動場景中的複雜變因，並在百香果於分級機上因震動或輕微干擾所產生的非線性運動情境下，精準修正卡爾曼濾波的預測誤差，進而提升單一ID連貫性的穩定，成為兼顧運算速度與追蹤穩定性的最佳選擇。



圖十二、OCM 模型中運動方向偏差之計算示意圖。

Fig. 12. Schematic diagram of movement direction deviation calculation in OCM model.



圖十三、(a)軌跡在 t_1 遺失後於 t_2 與 z_{t_2} 重新連貫。(b)無 ORU：即使 KF 獲得更新，但運動方向仍有偏差，導致後續與偵測值失配(藍色)。(c)有 ORU：透過更新速度修正運動方向，使估計值(紅色)貼近真實觀測，實現穩定追蹤。

Fig. 13. (a) Track re-association after loss; (b) Without ORU: Movement direction deviation remains despite KF update, leading to subsequent mismatch with detection (blue); (c) With ORU: Correcting movement direction by updating velocity, aligning estimation (red) with actual observation to achieve stable tracking.

結論與建議

本研究針對百香果病徵即時偵測與自動化篩選系統，整合YOLOv8目標偵測模型與多種多目標追蹤演算法進行量化評估。在精確率(Precision)方面，v8n-BoT-SORT表現最為低迷(僅48.2%)，其原因為追蹤機制易產生過度匹配(Over-matching)，無法有效過濾背景雜訊，進而造成大量誤報；相對地，v8n-Hybrid-SORT雖以嚴苛的匹配門檻取得高精確率(91.2%)，卻在召回率(Recall)上只有64.3%，說明其容易在目標遭遇搖晃或遭短暫遮蔽時發生漏檢，且透過Tukey HSD檢定，v8n-BoT-SORT在精確率，以及v8n-Hybrid-SORT在召回率皆與其他模型具備顯著差異($P < 0.05$)，確切表明此二款演算法因各自機制缺陷，無法在複雜影像中維持辨識穩定度。而在綜合評估指標(F1-score)上，v8n-OC-SORT與v8n-BoostTrack表現較為突出，故針對此兩種顯算法進行進一步之比較。因此在多目標追蹤效能指標分析方面，v8n-OC-SORT則展現了決定性的優勢，其多目標追蹤準確率(MOTA)高達85.4%，高於v8n-BoostTrack之58.8%。v8n-BoostTrack在此階段的表現落差，主因在於高達1278次的漏檢(FN)導致軌跡頻繁斷裂，更為關鍵的是，在衡量身份一致性IDF1指標上，v8n-OC-SORT達到92.3%，且全測試序列僅發生 7次身份切換(IDs)。綜合各項指標結果可知，v8n-OC-SORT在追蹤穩定性與身份一致性方面皆展現出最佳整體表現，透過此方法實現高精確度、低重複計數率的自動化辨識，為百香果提供精準辨識的解決方案。

致 謝

本研究承蒙農業部科技計畫項下補助經費，感謝中興大學生物產業機電工程學系蔡耀全教授、勤益科技大學電機工程系簡伯霖教授斧正，以及農機研究室茆聰銘、劉志聰、李安心及賴碧琴同仁鼎力配合協助，方得以順利完成，謹此一併誌謝。

參考文獻

1. Aharon, N., Orfaig, R. and Bobrovsky, B. Z. 2022. BoT-SORT: Robust associations multi-pedestrian tracking. arXiv preprint arXiv:2206.14651.
2. Bewley, A., Ge, Z., Ott, L., Ramos, F. and Upcroft, B. 2016. Simple online tracking. 2016 IEEE international conference on image processing (ICIP).
3. Cao, J., Pang, J., Weng, X., Khirodkar, R. and Kitani, K. 2023. Observation Rethinking sort for robust multi-object tracking. Proceedings of the conference on computer vision and pattern recognition.
4. Chen, Y., An, X., Gao, S., Li, S. and Kang, H. 2021. A Deep Learning-F System Combining Detection and Tracking for Fast On-Line Citrus Sorti Research]. *Frontiers in Plant Science*, Volume 12-2021.
<https://doi.org/10.3389/fpls.2021.622062>
5. Dong, Z., Long, W., Yang, F., Yu, C., Du, J., Wang, K. and Lyu, L. 2025. Fruit detection and yield estimation in *Camellia oleifera* based on improved YOLOv8 and ByteTrack algorithm. *Smart Agricultural Technology*, 12, 101435.
<https://doi.org/https://doi.org/10.1016/j.atech.2025.101435>
6. Du, P., Chen, S., Li, X., Hu, W., Lan, N., Lei, X. and Xiang, Y. 2024. Green pepper fruits counting based on improved DeepSort and optimized Yolov5s [Original Research]. *Frontiers in Plant Science*, Volume 15 - 2024. <https://doi.org/10.3389/fpls.2024.1417682>
7. Du, Y., Zhao, Z., Song, Y., Zhao, Y., Su, F., Gong, T. and Meng, H. 2023. Strongsort: Make deepsort great again. *IEEE Transactions on Multimedia*, 25, 8725-8737.
8. Maggolino, G., Ahmad, A., Cao, J. and Kitani, K. 2023. Deep oc-sort: Multi-pedestrian tracking by adaptive re-identification. 2023 IEEE International conference on image processing (ICIP).
9. Mei, Y., Shen, Y., Zhu, Y. and Huang, L. 2018. STEP: A Distributed Multi-threading Framework Towards Efficient Data Analytics. arXiv preprint arXiv:1812.04971.
10. Stanojevic, V. D. and Todorovic, B. T. 2024. BoostTrack: Boosting the similarity measure and detection confidence for improved multiple object tracking. *Machine Vision and Applications*, 35(3), 53.

參考文獻

1. Aharon, N., Orfaig, R. and Bobrovsky, B. Z. 2022. BoT-SORT: Robust associations multi-pedestrian tracking. arXiv preprint arXiv:2206.14651.
2. Bewley, A., Ge, Z., Ott, L., Ramos, F. and Upcroft, B. 2016. Simple online and realtime tracking. 2016 IEEE international conference on image processing (ICIP).
3. Cao, J., Pang, J., Weng, X., Khirodkar, R. and Kitani, K. 2023. Observation-centric sort: Rethinking sort for robust multi-object tracking. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition.
4. Chen, Y., An, X., Gao, S., Li, S. and Kang, H. 2021. A Deep Learning-Based Vision System Combining Detection and Tracking for Fast On-Line Citrus Sorting [Original Research]. *Frontiers in Plant Science*, Volume 12-2021.
<https://doi.org/10.3389/fpls.2021.622062>
5. Dong, Z., Long, W., Yang, F., Yu, C., Du, J., Wang, K. and Lyu, L. 2025. Fruit detection and yield estimation in *Camellia oleifera* based on improved YOLOv8 and ByteTrack algorithm. *Smart Agricultural Technology*, 12, 101435.
<https://doi.org/https://doi.org/10.1016/j.atech.2025.101435>
6. Du, P., Chen, S., Li, X., Hu, W., Lan, N., Lei, X. and Xiang, Y. 2024. Green pepper fruits counting based on improved DeepSort and optimized Yolov5s [Original Research]. *Frontiers in Plant Science*, Volume 15 - 2024. <https://doi.org/10.3389/fpls.2024.1417682>
7. Du, Y., Zhao, Z., Song, Y., Zhao, Y., Su, F., Gong, T. and Meng, H. 2023. Strongsort: Make deepsort great again. *IEEE Transactions on Multimedia*, 25, 8725-8737.
8. Maggolino, G., Ahmad, A., Cao, J. and Kitani, K. 2023. Deep oc-sort: Multi-pedestrian tracking by adaptive re-identification. 2023 IEEE International conference on image processing (ICIP).
9. Mei, Y., Shen, Y., Zhu, Y. and Huang, L. 2018. STEP: A Distributed Multi-threading Framework Towards Efficient Data Analytics. arXiv preprint arXiv:1812.04971.
10. Stanojevic, V. D. and Todorovic, B. T. 2024. BoostTrack: Boosting the similarity measure and detection confidence for improved multiple object tracking. *Machine Vision and Applications*, 35(3), 53.

11. Tan, S., Kuang, Z. and Jin, B. 2025. AppleYOLO: Apple yield estimation method using improved YOLOv8 based on Deep OC-SORT. *Expert Systems with Applications*, 272, 126764. <https://doi.org/https://doi.org/10.1016/j.eswa.2025.126764>
12. Tu, S., Huang, Y., Huang, Q., Liu, H., Cai, Y. and Lei, H. 2025. Estimation of passion fruit yield based on YOLOv8n + OC-SORT + CRCM algorithm. *Computers and Electronics in Agriculture*, 229, 109727. <https://doi.org/https://doi.org/10.1016/j.compag.2024.109727>
13. Wu, N., Wu, J., Wang, Z., Zhao, Y., Xu, X., Wang, Y., Skobelev, P. and Mi, Y. 2025. Maturity detection and counting of blueberries in real orchards using a novel STF-YOLO model integrated with ByteTrack algorithm [Original Research]. *Frontiers in Plant Science*, Volume 16 - 2025. <https://doi.org/10.3389/fpls.2025.1682024>
14. Yang, F., Zhang, X. and Liu, B. 2022. Video object tracking based on YOLOv7 and DeepSORT. *arXiv preprint arXiv:2207.12202*.
15. Yang, M., Han, G., Yan, B., Zhang, W., Qi, J., Lu, H. and Wang, D. 2024. Hybrid-sort: Weak cues matter for online multi-object tracking. *Proceedings of the AAAI conference on artificial intelligence*.
16. Zhang, H. and Wang, N. 2016. On the stability of video detection and tracking. *arXiv preprint arXiv:1611.06467*.
17. Zhang, Y., Sun, P., Jiang, Y., Yu, D., Weng, F., Yuan, Z., Luo, P., Liu, W. and Wang, X. 2022. Bytetrack: Multi-object tracking by associating every detection box. *European conference on computer vision*.

Development of an automated passion fruit grading system integrating deep learning and multi-object tracking technologies¹

Hsin-Chang Chen², Yu-Chen Hung^{2*}, Chin-Yuan Chang²
and Chia-Wei Chang²

ABSTRACT

This study develops a "Real-time Passion Fruit Disease Detection and Automated Sorting System" integrating image recognition and electromechanical control. To resolve detection instability and missed detections caused by high computational loads during high-speed YOLO recognition, multi-object tracking (MOT) was introduced to optimize localization. A two-stage evaluation compared a standalone YOLOv8-Nano (v8n) model against v8n paired with seven tracking algorithms (ByteTrack, BoT-SORT, OC-SORT, DeepOC-SORT, Strong-SORT, BoostTrack, and Hybrid-SORT). The first stage evaluated recognition performance (Precision, Recall, and F1-score) to assess statistical significance and system stability, while the second stage assessed overall algorithm performance using MOT metrics. Results showed v8n-OC-SORT and v8n-BoostTrack achieved the best recognition balance, leading with F1-scores of 88.6% and 88.0%, respectively. However, v8n-OC-SORT significantly outperformed in MOT metrics, achieving a Multi-Object Tracking Accuracy (MOTA) of 85.4%, compared to only 58.8% for v8n-BoostTrack. Furthermore, its tracking stability (IDF1) reached 92.3% with only 7 Identity Switches (IDs). Consequently, v8n-OC-SORT effectively overcomes target occlusion and identity confusion, ensuring highly reliable and stable automated culling of diseased passion fruits in complex environments.

Key words: passion fruit, image recognition, deep learning, tracking algorithm

¹ Contribution No.1123 from Taichung DARES, MOA.

² Project Assistant, Assistant Researcher, Associate Researcher and Assistant Researcher of Taichung DARES, MOA.

*Corresponding Author: Yu-Chen Hung , Email: ychung@tcdares.gov.tw