國立勤益科技大學工業工程與管理系

113 學年度實務專題競賽

基於 YOLOv5s 和數據增強技術的 PCB 檢測準確性提升研究

Research on PCB inspection accuracy improvement based on YOLOv5s and data augmentation technology

摘要

本專題針對印刷電路板（PCB）瑕疵檢測進行實驗，隨著 PCB 結構日益複雜，傳統 AOI 技術已難以應對多樣化的缺陷，深度學習技術因此成為提升檢測效能的關鍵。本專題選用輕量化的 YOLOv5s 模型進行物件偵測，具有高效的特徵提取能力，特別適合運行於資源受限的環境，為了進一步提升模型表現，搭配數據增強與超參數調整策略，有效減少過擬合情況並提升精確率。實驗使用 GitHub 網站 tangsanli5201 提供的 DeepPCB 資料集，對 PCB 進行瑕疵檢測，結果顯示 Precision 平均為 0.9805、Recall 為 0.9742、mAP@50 為 0.9898、mAP@50-95 為 0.7562、F1 為 0.9773 展現出中等資料量與低資源條件下的良好效能，整體實驗成果顯示，結合深度學習與參數優化能有效提升智慧製造中瑕疵檢測的準確性與效率。

關鍵字：YOLOv5s、PCB 瑕疵檢測、數據增強、超參數調整

ABSTRA

This report focuses on printed circuit board （PCB） defect detection.As PCB structures become increasingly complex, traditional automated optical inspection （AOI） technologies struggle to handle diverse defect types. Consequently, deep learning has emerged as a key approach to improving inspection performance. To further enhance model effectiveness, data augmentation and hyperparameter tuning strategies are employed to reduce overfitting and increase accuracy. The experiments utilize the DeepPCB dataset provided by the GitHub repository maintained by user tangsanli5201 to detect PCB defects. The results demonstrate that the model achieves an average Precision of 0.9805, Recall of 0.9742, mAP@50 of 0.9898, and mAP@50–95 of 0.7562. The F1-score of 0.9773 indicates strong performance under conditions of moderate data volume and limited computational resources. Overall, the experimental findings show that integrating deep learning with parameter optimization can significantly improve the accuracy and efficiency of defect detection in intelligent manufacturing.

Keywords: YOLOv5s, PCB defect detection, data augmentation, hyperparameter tuning

1. 緒論

1.1 研究動機與目的

近年印刷電路板（PCB）需求持續攀升，缺陷檢測變得日益重要，傳統檢測方式包括人工目視、飛針檢測與自動光學檢測（AOI）。林俊宇（2017）提出人工檢驗效率與穩定性不足，飛針檢測雖可找出短/斷路瑕疵，但仍有過度蝕刻等問題。葉峻賓等（2020）提出 AOI 利用光學影像與比對技術，可有效檢出缺陷且無需接觸產品，但高度依賴光線與設備狀況，光源不穩易造成誤判，且傳統 AOI 缺乏自我調整能力，導致過殺率（Overkill Rate）偏高。

人工智慧（AI）與邊緣運算（Edge Computing）結合，帶動工業製程發展潛力，而深度學習具備高度非線性與特徵自動提取能力，在處理非結構化數據時具明顯優勢，透過深度學習結合即時物件偵測

技術，可有效改善傳統 AOI 系統無法即時辨識與誤判問題，進一步提升生產效率。

YOLO（You Only Look Once）演算法是一種單階段物件偵測模型，兼具高速與高準確率，成為工業影像辨識應用的重要演算法，YOLOv5s 為 YOLOv5 系列中的輕量化版本，兼顧準確率與計算效率，非常適合用在邊緣裝置如工業攝影機等。在智慧工廠與工業 4.0 趨勢下，傳統依賴中央伺服器的架構已無法滿足即時反應需求，製造業因此逐步導入 AI 技術於產線品質管理流程。

AI 技術的成熟使深度學習結合 AOI 成為趨勢，利用大量瑕疵圖像進行模型訓練，深度學習模型可自動尋找瑕疵區域，提升檢測彈性與準確性，即使影像略有模糊，檢測依然有效，補足 AOI 依賴設備與過殺率高的問題，高翰文（2023）提出目前常見深度學習方法包括：隨機森林（Random Forest）與卷積神經網路（CNN）等。我們選擇以 CNN 為基礎的 YOLOv5s 進行模型訓練，原因在於 CNN 擅長圖像處理與自動特徵學習，YOLOv5s 則因計算資源需求低、運行速度快、檢測精度高，適合快速預測場景。

本專題主要是調整深度學習模型的參數值來作訓練，找到最佳的參數值並搭配 AOI 來作檢測，來提升檢測的能力，我們主要利用了 DeepPCB 資料集，裡面包含 1,500 個影像對，每個影像對均由無缺陷模板影像和對齊的測試影像組成，搭配了 YOLOv5s 來檢測出無缺陷（none）以及開路（open）、短路（short）、鼠咬（mousebite）、毛刺（spur）、針孔（pin hole）、雜散銅（copper）這七種類別。本專題將對 YOLO5s 模型各種參數下，不同表現做績效評估，來找出最佳的組合。

1.2 相關技術發展現況

隨著人工智慧（AI）和深度學習技術的快速進步，影像檢測運用到許多領域中，例如：醫療、交通、工業自動化等，都開始採用影像辨識技術來提升效率與準確性，而在電子製造方面，印刷電路板（PCB）的品質檢測更為重要。

本專題選用 YOLOv5s，它是一種高效的物件偵測模型，運用了無錨點檢測與多尺度特徵融合技術，即使在低資源環境下，依然也能夠保持好的檢測能力，跟傳統相比，YOLOv5s 不僅能大量縮短檢測時間，還能提高檢測的準確性與穩定性，因此，在 PCB 缺陷檢測方面，這項技術有助於提高生產效率，減少人工檢測的誤判，並確保電子產品的品質，成為現代電子製造流程中不可或缺的。

2. 文獻探討

2.1 PCB 印刷電路板（Printed circuit board）

林宸樂（2022）提出在早期，這些瑕疵的檢測通常依賴人工來進行區域判斷和分類，這使人工檢測成本變高而且耗時，也容易發生判斷錯誤，為了解決這些問題， AOI 逐漸取代傳統人工檢測方法，並被廣泛應用在印刷電路板（PCB）缺陷檢測中，儘管印刷電路板的 AOI 系統比人工檢測具有更多優勢，但目前的誤檢率和漏檢率仍未達到工業化生產所期望的精度，王炫尹（2019）提出印刷電路板（PCB）瑕疵檢測是針對印刷電路板在製造過程中可能出現的各類瑕疵進行檢測的技術，目的是保障產品品質、降低生產損失並提升產業效率，PCB 是電子設備的基礎元件，品質會直接影響整體的性能。

2.2 AOI 自動光學檢測（Automated Optical Inspection）

自動光學檢測（AOI）是一種高精度的無損檢測技術，廣泛用在各種產品的製造過程中，用以確保其符合品質標準，這項技術利用影像感測器和照明設備捕捉產品的數字圖片，然後透過先進的算法分析圖片，識別並分類缺陷，確保製造過程中的每個細節都能被準確的檢測，並且能實現高效、無間斷的檢測，對產品的品質控制具有極為重要的作用。

Dulal, R.等（2022）提出在電子行業中，自動光學檢測（AOI）系統被用來檢查，例如：印刷電路板（PCB）等元件的缺陷。硬體方面，選擇合適的相機和光源配置對於提高檢測的精度也很重要，而在軟體方面，圖片的預處理、特徵提取和分類算

法則是確保檢測結果準確性的關鍵。近年來，深度學習技術的應用使自動光學檢測（AOI）系統能夠更有智慧的識別各種複雜的缺陷，進一步提升檢測的靈活性和準確度。

2.3 缺陷檢測的挑戰與研究缺口

Bai, J.等（2024）提出在應用機器學習於材料缺陷檢測的過程中，資料品質會直接影響模型的訓練效果與檢測準確度，低品質資料會引入大量的雜訊，使模型容易產生誤判或漏檢的現象，導致深度學習模型難以有效學習有用特徵，此外，訓練資料通常需要大量經過標註的缺陷樣本，但實務上標註不僅耗時、費工，並且常因人為差異導致一致性不足，這些因素都會降低模型的可靠性，因此，提升資料清晰度、處理雜訊與準確標註，是需要重視的問題，然而，複雜缺陷的辨識也是另一項挑戰，隨著材料種類與加工技術的演進，產生的缺陷型態變得更加多樣，例如：裂痕（cracks）、孔洞（pores）、夾雜物（inclusions）等，缺陷的形狀、大小、出現位置皆有較高變異性，這些缺陷常以非對稱、非規則的方式出現，使傳統演算法難以精準分類或定位。機器學習模型雖然具備特徵學習能力，但在面對外觀相似或特徵不明顯的缺陷時，仍然可能出現混淆，因此，設計具備高感知能力與自動特徵提取能力的模型（如 CNN、GAN），以及搭配資料擴增與深層標註策略，是提升複雜缺陷辨識效能的重要方向。

2.4 深度學習

選擇 YOLO 模型的主要原因在於它在物件偵測領域（如 PCB 缺陷辨識）中展現出優異的整體效能，不僅在偵測速度上具備明顯優勢，同時也能維持良好的準確率，是目前物件偵測技術中相對先進且實用的選擇之一。本專題曾評估多種模型作為比較，包括 SSD、Faster R-CNN、VGG16 以及 MobileNet。SSD 雖然適合即時檢測，但對小型缺陷的辨識能力有限；Faster R-CNN 精度較高，但運行速度較慢；VGG16 結構簡單且特徵提取能力強，然而模型龐大、計算量高；MobileNet 則主打輕量化與高效能，但相對精度較低，需調整超參數才能達到較佳的效果，所以，我們最終選擇 YOLOv5s 作為我們的實驗模型，為 YOLOv5 系列中最輕量的版本，能兼顧準確率與推論速度，並有效降低系統資源需求，適合應用在即時反應與高效率要求的生產環境。研究中使用來自高翰文（2023）提出 A 公司生產線維修站的 1259 張 PCB 影像（多數為 X 光影像），其中 80% 劃分為測試集。YOLOv5s 的應用不僅有效改善傳統 AOI 系統的誤判與漏檢問題，更有助於提升整體生產效率與品質控制水平。

- 機器學習與深度學習

常用的模型包括基於卷積神經網絡（CNN）的模型，如 YOLO 系列（YOLOv1 至 YOLOv5）和 FasterR-CNN，其中 YOLO 的 One-stage 檢測模型強調速度與即時性，FasterR-CNN 的 Two-stage 檢測模型注重準確率，並以 Mosaic 數據增強技術和特徵融合技術（如 CSPNet 和 PANet）提升對小目標和多尺度目標的檢測能力。

- 模型選擇

採用 YOLOv5s 模型，用於對印刷電路板（PCB）的瑕疵進行檢測，以改善傳統 AOI（自動光學檢測）技術的缺陷。YOLOv5s 架構包含四個主要部分：輸入層（Input）、骨幹網路（Backbone）、Neck 和預測（Head），並使用 Mosaic 數據增強技術來提升小目標檢測的能力。

- 深度學習技術

使用的深度學習技術基於 YOLO 系列的卷積神經網絡（CNN），進行端到端的物體檢測，YOLOv5 的骨幹結構引入了 C3 模塊（基於 CSPNet）與改進的 SPPF 模塊，增強特徵提取能力，並結合 Mosaic 數據增強技術，有效提升對小目標的檢測能力。

此外，YOLOv5s 在確保檢測準確性的同時，也具備了高效的推理速度，適用在需要即時性與高效性的工業場景，而 YOLOv5s 有較高的準確性與運行效率，能夠滿足 PCB 瑕疵檢測的精度需求，是平衡性能與效能的最佳選擇。

- 目標框選

在瑕疵檢測中，模型基於標記的 YOLO 格式數據進行訓練，輸出框的中心點坐標、寬度、高度及類別，並以 IoU（Intersection over Union）作為主要的檢測精度評估指標。

- 成效

高翰文（2023）提出模型結果顯示，準確率 0.854、召回率 0.865、mAP0.88，各類瑕疵召回率均達 0.89 以上。透過剪枝技術，模型推理速度（FPS）從 43.66 提升至 86.21，計算複雜度（GFLOPS）降至 10.6，參數量由 702 萬減少至 462 萬，顯示剪枝後模型能在保持高準確度的同時，大幅降低計算資源需求並提升檢測效率。

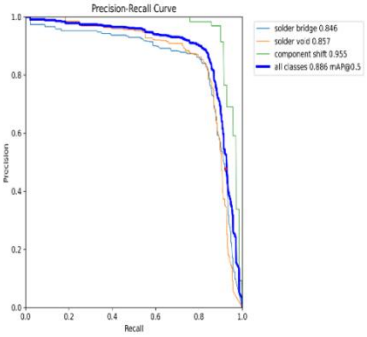


圖 1 PR 曲線圖

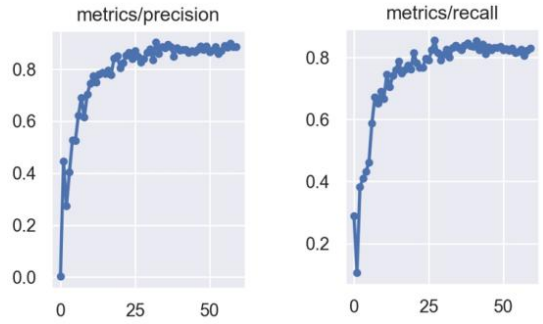


圖 2 精確率與召回率圖

2.4.1 數據增強

（Goenawan, C. R.,2024；Xu, B., & Yu, S.,2024）發現在目標檢測模型中，數據增強技術是提升模型準確度和泛化能力的關鍵方法，數據增強能夠幫助模型學習到更具多樣性的特徵，減少過擬合並提升在未見過的測試數據上的表現。

1. 馬賽克增強（Mosaic Augmentation）：

馬賽克增強是一種將四張隨機選取的圖片會被裁剪並調整大小，然後將這些圖片拼接成一張新的合成圖片，每張圖片中的標註框被保留，並根據新的位置進行調整，這樣生成的圖片通常包含多個缺陷，模擬了更為複雜的場景，並擴展訓練數據集的多樣性。

提升小目標檢測能力：將多個小物體放在同一張圖片中，能夠提高模型對小目標的識別能力，這種做法讓模型能夠學會如何在擁擠的場景中識別並區分不同物體。

增強數據多樣性：通過隨機拼接不同來源的圖片，生成的新圖片與原有的訓練數據集完全不同，這有助於模型學習更多樣化的特徵，從而提高其泛化能力。

減少批次大小要求：合成圖片將多個目標集合在一張圖片內，有效減少了每批次訓練中所需的圖片數量，這不僅提高了訓練效率，還能減少計算資源的需求。

2. 水平翻轉（Horizontal Flip）：

這是一種最基本的數據增強方法，通過將圖片沿水平方向進行翻轉來創建新的訓練樣本，翻轉後，圖片中的標註框也會隨著調整，確保物體的位置不會受到影響。

增加數據的多樣性：水平方向的翻轉能夠幫助模型學習物體在不同方向上的特徵，這對於物體的旋轉、平移等變化有效。

防止模型過擬合：翻轉的圖片能夠讓模型看到更多樣的視角，從而避免模型過度依賴特定方向或位置的特徵，這樣有助於提高其在測試集上的泛化能力。

3. 垂直剪切（Vertical Shear）：

通過在垂直方向上對圖片進行拉伸或傾斜來改變圖片的結構。這種操作會讓圖片中的物體看起來像是從不同的角度拍攝的，模擬了仰視或俯視的視角變化。

模擬真實世界的角度變化：這種增強方法能夠幫助模型學習如何識別在不同拍攝角度下的物體，特別是當物體出現在較高或較低位置時。

提升視覺特徵學習能力：垂直剪切增加了模型對物體外觀變化的適應性，讓模型能夠從多角度學習物體的特徵，提高其檢測準確率。

4. 水平剪切（Horizontal Shear）：

與垂直剪切（Vertical Shear）相似，水平剪切通過對圖片進行水平方向的拉伸或傾斜來改變物體的結構，模擬從不同視角拍攝物體的效果。

強化對視角變化的適應性：模型能學會識別在

不同水平角度下的物體特徵，從而提高檢測效果。

5. YOLO 訓練成效之影響

這些數據增強技術對 YOLO 訓練過程具有正面影響，透過這些增強策略，模型在訓練過程中能學習到更多元且具泛化能力的特徵，有效降低過擬合的風險，並在驗證集與測試集上表現出更穩定的準確率與召回率。

2.4.2 YOLO 模型各版本介紹

（Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M,2023；Yun, S., Han, D., Oh, S. J., Chun, S., Choe, J., & Yoo, Y.,2019）論文提出 YOLO 是由 Redmon 等人首次提出的 One-Stage 物件偵測演算法，是一種端到端的物體檢測方法，YOLO 可以直接從原始影像中預測缺陷的類別與位置，不需先提取特徵後再進行檢測。與傳統 CNN 方法比較，YOLO 在保持高準確度的同時，也大幅提升檢測速度，現今 YOLO 已被大範圍應用在各領域，例如：瑕疵檢測、路況分析與影像監控等，至今，YOLO 系列官方論文已發表多個版本，包括 Redmon 提出的 YOLOv1 至 YOLOv3，及 Bochkovskiy 等人發表的 YOLOv4 和 YOLOv7

YOLOv1（You Only Look Once v1）模型架構參考了 GoogLeNet，由 24 個卷積層與 2 個全連接層組成，透過將影像劃分為 S × S 網格來預測物體的位置與類別，每個網格生成 B 個邊界框，並使用置信度閾值與非最大抑制（NMS）來篩選預測的結果，YOLOv1 具備高速偵測能力，但對小物件檢測效果比較不好，而且定位精度比較低。

YOLOv2（You Only Look Once v2）以 VGG 為基礎，採用了 Darknet19 為骨幹網路，包含 19 個卷積層與 5 個最大池化層，相較於 YOLOv1 進行四項改進，如：引入 Batch Normalization 提高訓練穩定性與收斂速度、採用 Anchor Box，提高對不同尺寸與形狀物體的適應能力，使召回率（Recall）明顯提升、融合底層特徵（Fine-Grained Features），增強小物件檢測能力、使用多尺度訓練，提高不同大小物體的檢測準確度。

YOLOv3（You Only Look Once v3）最大的改進是網絡架構的更新，採用了更深的 Darknet-53 做基礎網絡，此網絡有包含 53 層卷積層，能更有效提取圖像特徵並避免梯度消失問題。以下三點為 YOLOv3 主要改進部分：ResNet 引入殘差連接（ResidualNetwork），允許梯度更好的流經網絡，解決深層網絡中梯度衰減問題、特徵金字塔網絡（FPN）將不同層次的特徵圖融合在一起，增強模型捕捉多尺度物體的能力，提升對各種物體大小的檢測精度、多尺度預測：在不同層次進行目標檢測，設計了三個尺度，每個尺度使用三個 Anchor Box，讓 YOLOv3 更好處理大小物體。

YOLOv4（You Only Look Once v4）採用 Backbone、Neck 和 Head 三個部分：

1. Backbone（CSP + Darknet53）：基於 YOLOv3 的 Darknet-53，並引入 CSP 來減少參數量與計算量，同時保持或提升網絡的表現，改善特徵融合的問題。
2. Neck （SPP + PANet） ： SPP 使用多尺度池化來捕捉不同大小物體的特徵，並融合全局與局部，而 PANet 增強了特徵的融合。
3. Head：與 YOLOv3 相似，負責目標檢測並輸出結果。

在湯仁愷（2023）論文中發現 YOLOv5（You Only Look Once v5），Ultralytics 在 2020 年改進 YOLOv4 的架構，推出 YOLOv5 物件偵測模型，提升了速度與準確性，YOLOv5 是目前在 GitHub 上的版本，還沒有發表正式論文，但它是一個業界應用比較廣泛且實用性較高的模型，而它最大的改進是改用 PyTorch 框架取代原先的 Darknet 框架，使它能在更多開發環境中運行，且訓練速度更快、模型更輕量化，方便在實際應用場景中使用，YOLOv5 的架構主要分為輸入層（Input）、骨幹網路（Backbone）、Neck 和預測（Head）四部分，此外，Ultralytics 提供了五種不同規模的模型結構，分別為 YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x，從輕量版本到較大版本依次排列，以滿足不同的需求。

YOLO v5s 架構主要分為輸入層（Input）、骨幹網路（Backbone）、Neck、預測（Prediction）。

- 輸入端（Input）：

輸入端的主要功能是對原始圖像進行處理，轉換為適合模型運行的格式。（Tseng, S. H., & Kuo, C.,2024）提出在 YOLOv5 中，這部分先使用 Focus 模塊，通過將圖像進行切片操作，增強模型對局部特徵的感知能力，接著，處理過的圖像會被調整為統一的大小（如 640x640）確保特徵維度的一致性，此外，還會在此階段進行數據增強，例如 Mosaic 數據增強技術，透過隨機縮放、裁剪等，將四張圖片拼接，此方法由 CutMix 演變而來，這不僅能增強小物體的檢測能力，還能提升訓練速度並降低內存的需求。

- 骨幹網路（Backbone）：

骨幹網路負責提取輸入圖像中的關鍵特徵，是 YOLOv5 的核心組件，該部分包含多個 CSP 模塊（Cross Stage Partial 模塊）和 SPP 模塊（Spatial Pyramid Pooling 模塊），CSP 模塊通過引入殘差結構，分割和融合特徵圖，有效降低了計算量，同時保留了特徵訊息；SPP 模塊則通過多尺度池化操作進一步提取全局上下文訊息。整個骨幹網路的設計，使模型能夠提取多層次的圖像特徵，從低層的空間細節到高層的訊息，為檢測工作奠定基礎。

- Neck：

Neck 是骨幹網路與預測層之間的橋樑，在進一步融合來自不同層次的特徵圖，YOLOv5 的 Neck 結合了特徵金字塔網絡（FPN）和路徑聚合網絡（PAN），FPN 負責將高層的訊息向上傳遞，而 PAN 則將低層的空間細節向下傳遞，這些操作通過 Upsampling 和 Concatenate 完成，實現了多尺度特徵的融合，這部分的設計，提升了 YOLOv5 在小物體檢測中的準確性，同時保持對大物體的檢測穩定性。

- 預測（Prediction）：

預測層負責將融合後的特徵圖轉換為最終的檢測結果，該部分會生成三個不同分辨率的特徵圖（80x80、40x40 和 20x20），分別對應於不同尺度物體檢測，實現多尺度檢測能力，每個特徵圖經過卷積操作後，輸出包括邊界框的座標、物體類別以及置信度的檢測結果，最後，通過 NMS 技術，過濾掉重疊的檢測框，保留最好的結果，實現高效且精確的目標檢測。

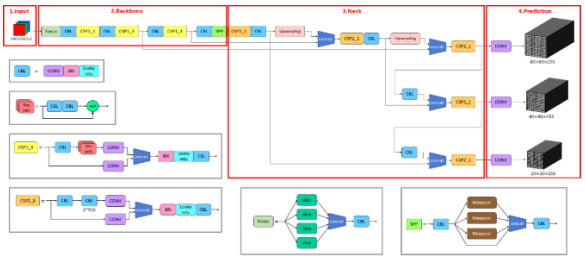


圖 3 YOLOv5 架構圖

在 YOLOv5 模型中，損失函數（Loss Function）是用來衡量模型預測結果與真實標註值之間的誤差。范紋慈（2023）提出在 YOLOv5 的總損失函數由以下三個部分組成：

1. 定位損失（Box_loss）

負責評估模型預測的邊界框與實際標註框之間的差異，其中 YOLOv5 採用了 GIoU（Generalized Intersection over Union）為標準，跟傳統的 IoU 相比，GIoU 不僅是考慮了預測框與真實框的重疊程度，還同時考量了它們之間的面積差異，進而更準確衡量模型的定位精度。

2. 目標置信度損失（Objectness Loss，Obj _loss）

這部分的損失是用在衡量模型對目標存在與不存在的預測準確度，YOLOv5 使用交叉熵損失（Cross-Entropy Loss）來看網絡對物件的置信度，使它能更有效區分背景區域與真正的目標缺陷。

3. 分類損失（Classification Loss，Cls_loss）

分類損失指的是模型對目標類別的識別能力，當這個模型確定某個區域存在物件之後，它還需要正確分類這個物件的類別。

YOLOv5 模型優化技術，除了 YOLOv5 的主要架構（輸入層、骨幹網路、Neck、預測層）外，還有一些較關鍵的運算機制在模型性能優化中也相當重要。其中，邊界框損失函數和非極大抑制技術是影響 YOLOv5 偵測準確性與效率的方法。

1. 邊界框損失函數：這部分用來計算預測邊界框與真實邊界框之間的差異。常見的損失函數包括 IOU 或 GIOU，這些損失函數通過衡量兩個邊界框的重疊程度來指導模型進行學習，損失函數的計算會考慮到位置誤差和尺寸誤差。

- IOU（Intersection over Union）：為物件標記範圍與模型所偵測範圍的交集與聯集的比例，如以下公式所示，右上方的框代表物件標記的邊界框範圍，而左下方的框為系統所偵測的物件邊界框範圍，因此，IOU 計算方式為右上方的框與左下方的框，它們的交集區域面積，除以兩者的聯集區域面積，IOU 值越接近 1 時，表示預測結果會越準確，公式如下所示：

$$\text{IoU} = \frac{\text{Area of overlap}}{\text{Area of union}} \qquad (1)$$



- GIOU（Generalized Intersection over Union）：考慮了邊界框中心點的距離，使模型更精確的對齊預測框與真實框，公式如下所示：

$$\text{GIOU} = \text{IOU} - \frac{|C - B \cup A|}{|C|} \qquad (2)$$

2. 非極大抑制（Non-Maximum Suppression，NMS）：非極大抑制是用來過濾掉重疊的邊界框的技術，當模型產生多個邊界框來預測同一物體時，NMS 會根據每個框的置信度（confidence）進行篩選，保留置信度最高的邊界框，並刪除與其重疊程度過高的其他框。這樣可以確保每個物體只被檢測出一次，從而提高檢測的準確性。

表 1 YOLOv1 至 YOLOv5 模型優劣比較表

版本	優點	缺點
YOLOv1	引入 Batch Normalization、使用 Anchor Box、多尺度訓練	對小目標檢測效果差、定位不準確
YOLOv2	採用 Darknet-53 架構、引入 ResNet 和 FPN、多尺度預測	mAP 沒有提高
YOLOv3	使用 CSPDarknet53、引入 SPP+PANet、提高檢測準確性	訓練和推理速度較慢
YOLOv4	模型輕量化、訓練速度快、高效能	訓練過程複雜
YOLOv5	引入 Batch Normalization、用 Anchor Box、多尺度訓練	沒有正式論文發表

YOLO 系列模型演進中，YOLOv5 透過 PyTorch 重新建構，大幅提升訓練的靈活度，同時提供輕量至大型模型的選擇。在本專題中，我們選擇 YOLOv5 的 s 版本，主要考量在模型體積小、推論速度快、訓練效率高，適合用在實際工廠環境中需要即時反應與快速處理的情況下，相較於前代模型，YOLOv5s 在維持不錯精度的同時，更適合應用在硬體資源有限的生產線，且結合 Mosaic 資料增強與自動錨點選擇等技術，有助於提升模型對瑕疵圖像中小型物件的辨識能力。因此，YOLOv5s 成為本專題應用在 PCB 瑕疵檢測的最佳選擇。

Tang, S., He, F., Huang, X., & Yang, J.（2019）指出在選擇 YOLOv5s 模型後，針對以下常見的超參數優化進行調整：

1. 初始學習率（lr0）：學習率起始值較大時，模型的訓練速度較快，但也可能因為步伐過大而跳過最佳解的區域，學習率較小則有助於較精細的調整，讓模型更穩定的收斂在最佳解，但訓練時間相對也會比較長。
2. 最終學習率衰減率（lrf）：調大學習率，在訓練初期和中期可能有助於快速找到較平坦的區域，提高收斂速度。但在 YOLOv5s 的後期訓練中，過大的最終學習率衰減率可能導致模型難以穩定，尤其在對小目標或細節敏感的任務上，可能降低準確度，調小學習率，適合訓練後期，特

別是在需要高精度的情況下，例如：瑕疵檢測或小目標檢測。對於 YOLOv5s 這樣的輕量模型，需平衡訓練時間與精度提升的需求。

3.研究方法

本專題目的是為了提升 PCB 瑕疵檢測的準確率，所使用的資料來自 GitHub 網站上 tangsanli5201 提供的 DeepPCB 瑕疵資料集，在資料前處理部分，本專題將原始標註檔轉換為 YOLO 格式，並運用 Mosaic 增強、HSV 色彩變換、隨機縮放與翻轉等技術進行數據增強，選用的演算法為 YOLO 系列中的 v5s，作為瑕疵檢測的方法，實驗過程中，透過不同的參數調整，以研究出最佳的訓練參數組合，最終，使用模型績效評估指標，包括：混淆矩陣、精確度（Precision）、召回率（Recall）、mAP@0.5 及 mAP@0.5：0.95，來進行結果分析。詳細流程如圖 4 所示。

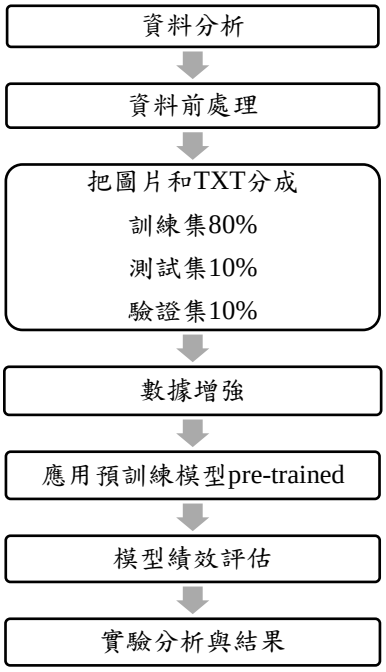


圖 4 研究方法圖

3.1 資料收集-數據集介紹

本專題所使用的資料集來源為 GitHub 網站上使用者 tangsanli5201 所提供的 DeepPCB-master.zip 檔案，資料集中共包含 1500 對影像，每對影像由一張缺陷影像與一張正確影像組成，其中正確影像比缺陷影像多一張，因此總影像數量為 3001 張，缺陷種類共分為七種，分別為：無缺陷（none）、開路（open）、短路（short）、鼠咬（mousebite）、毛刺（spur）、雜散銅（spurious copper）以及針孔（pinhole），每種類型約有 1500 個樣本，所有影像的尺寸均為 640x640 像素。在資料標註方面，每張缺陷影像皆配有一個對應的 TXT 標註檔，標註內容包含缺陷的邊框座標及對應的缺陷類別編號，而類別編號對應關係若為 0 代表 none、1 代表 broken、2 代表 short、3 代表 gap、4 代表 burr、5 代表 copper、6 代表 hole，由於正確影像（無缺陷）未提供標註檔，因此，統一建立一個標準格式的標註檔，內容為 0 0.5 0.5 0.5 0.5，代表一個完整覆蓋整張圖的無缺陷標籤。在資料集分割部分，將影像與標註檔分別存放於 images 與 labels 資料夾中，並劃分為三個子集，分別為訓練集（train）2400 張、驗證集（val）300 張，以及測試集（test）301 張，所有分割後的資料路徑資訊，統一會放到 custom_data.yaml 檔案中。為了更清楚資料集中的各種缺陷類型，所以整理了七種缺陷的示意圖，如圖 5 所示，展示了各類缺陷的外觀特徵與標註方式，此外，圖 6 呈現 PCB 缺陷偵測系統的輸出結果，圖中分別顯示（a）原圖、（b）缺陷圖、（c）標註圖，能清楚看出模型成功偵測並標記出缺陷的位置及精確度。



（0-none 無缺陷）（1-borken 開路）（2-short 短路）

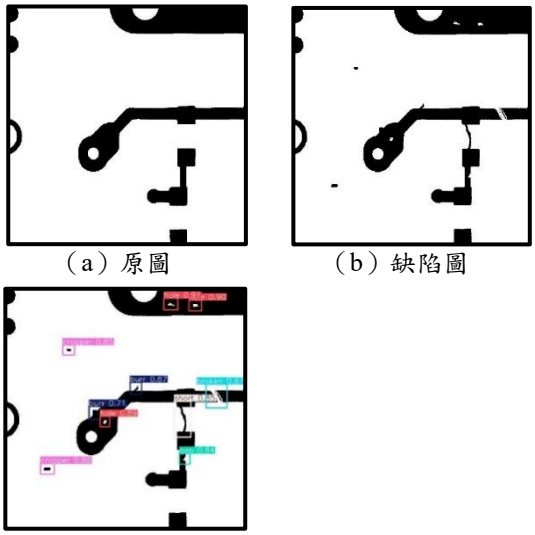


（3-gap 鼠咬）（4-burr 毛刺）（5-copper 雜散銅）



（6-hole 針孔）

圖 5 PCB 缺陷偵測之輸出結果



（a）原圖　（b）缺陷圖

（c）標註圖

圖 6 PCB 缺陷偵測之輸出結果

本實驗數據集與其他文獻相比屬於中型數據集，沒有缺陷（none） 圖片數量為 1501 張、開路（broken）為 1942 張、短路（short）為 1503 張、鼠咬（gap）為 1965 張、毛刺（burr ）為 1625 張、雜散銅（copper）為 1474 張、針孔（hole）為 1501 張，缺陷種類數量平均落在約 1650 張左右，可以說是相當平衡。

表 2 缺陷種類數量

缺陷	出現次數
沒有缺陷（none）	1501
開路（broken）	1942
短路（short）	1503
鼠咬（gap）	1965
毛刺（burr）	1625
雜散銅（copper）	1474
針孔（hole）	1501

3.2 模型績效評估準則

混淆矩陣在機器學習分類中，單純依賴準確率來衡量模型表現可能不夠全面，因此，會使用混淆矩陣（Confusion Matrix）來深入分析模型在不同類別上的預測表現。它常用於計算分類模型的關鍵指標，例如：準確率（Accuracy）、召回率（Recall）、精確率（Precision）以及 F1-score，這些指標可以讓我們瞭解模型在不同類別上的預測能力，找出可能的錯誤類型，提升分類準確度。

混淆矩陣主要由四個部分組成，分別代表模型在預測結果與實際狀況的對應情況：

1. TP（True Positive）：模型預測為正確，實際也是正確。
2. TN（True Negative）：模型預測為錯誤，實際上也是錯誤。
3. FP（False Positive）：模型預測正確，實際上是錯誤。
4. FN（False Negative）：模型預測錯誤，實際卻是正確。

表 3 混淆矩陣

混淆矩陣		實際狀況	
		實際為正	實際為負
預測狀況	預測為正	TP	FP
	預測為負	FN	TN

模型中有幾項指標是由混淆矩陣分類之後的數據，經由公式計算後所得出，公式如下：

- 精確度（Precision）：在所有被預測有瑕疵的樣本中，實際確實有瑕疵的圖像所佔的比例，主要在衡量模型預測準確性。

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

- 召回率（Recall）：在實際為正樣本中被正確預測正樣本的比例，衡量模型檢測到的所有瑕疵的比例。

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

- mAP@0.5：是目標檢測中的一項指標，當 IoU（Intersection over Union）閾值設定為 0.5 時，各類別平均精度（Average Precision ，AP）的平均值，此指標用來評估模型在檢測目標

時的準確性，若數值越高，則表示模型更能精確的識別。

- mAP@0.5：0.95：是比 mAP@0.5 更嚴格的評估指標，因為它考慮了多個不同的 IoU 閾值，而不只是 0.5。它在 IoU 介於 0.5 到 0.95 之間，以 0.05 為步長，計算各個閾值下的平均精度（AP），然後再取平均值。這個指標能更全面評估模型在不同難度下的偵測能力，如果數值越高，則表示模型在各種情況下的穩定性和精確度會越好。
- F1-Score：為綜合考量的指標，精準度（Precision）和召回率（Recall）的指標，透過計算它們的調和平均數進一步評估模型的整體表現。它能平衡「預測的準確性」和「找出所有正確瑕疵的能力」，因此能反映模型的準確性與穩定性，若數值越高，則表示模型在偵測目標時的表現越好，其公式為：

$$\text{F1-Score}=2 \times \frac{\text{Precision}\times\text{Recall}}{\text{Precision}+\text{Recall}} \qquad (5)$$

4.實驗結果與分析

4.1環境配置

本專題使用 YOLOv5s進行目標識別，使用 Pyorch 框架安裝git、CUDA、cuDNN 來使用 GPU進行YOLOv5s模型的訓練，開發環環境使用 Jupyter以及使用Anaconda建立訓練所需的環境。

表 4 設備規格

裝置名稱	DESKTOP-8DCI60T
處理器	Intel（R）Core（TM）i7-147002.10GHz
已安裝記憶體（RAM）	64.0GB（63.7GB 可用）
系統類型	64 位元作業系統，x64 型處理器
版本	Windows11 專業版
Os 組件	22631.4460
ANACONDA.NAVIGATOR 版本	64-bit
開發環境	Jupyter
Python 版本	3.9.19
PyTorch	2.4.1+cu118
git	2.47.0.windows.1
CUDA	11.8
cuDNN	8.9.7

4.2 實驗分析

在 epochs 為 100，Image size 為 640x640，Batch size 為 4 的情況下，將 lr0 設定為 0.01、0.009，lrf 設定為 0.01、0.05、0.15 進行訓練，過程中我們將結果進行星級篩選，最後發現最好的數值不一定出現在同一個組合上，因此，我們最終將選擇最多星數的組合作為我們的最佳參數組合。當 Precision 數值越高能預測出缺陷的機率越高、Recall 數值越高代表模型在檢測到的缺陷中有較多是真正的缺陷、mAP@50 指 IOU 設定為 0.5 時的平均精度，數值越高代表模型在 IOU 閾值在 0.5 的情況下整體性能越好、mAP@50-95 指模型在 0.5 的時候會取一次平均精度，在 0.6 會再取一次，以此類推，一直到 0.95，最後將所有的平均精度再平均一次，數值越高代表模型整體性能越好，越靠近 mAP@50 越穩定，F1 越大，代表模型在精確度和召回率之間取得更好的平衡，這表示模型既能準確預測正確的缺陷，又能盡可能的識別所有的正確缺陷，若 F1 越小，可能會有很多漏報或誤報的情況，在這些參數中，主要利用平均值來比較，標準差是指一種衡量一組數據與平均值之間分散程度的指標，標準差越小，代表數據越集中在平均值附近，表示模型較穩定。

表 5 實驗參數組合

實驗參數組合 Image size = 640x640　Batch size = 4　Epochs = 100		
組合1	lr0=0.01	lrf=0.01
組合2	lr0=0.01	lrf=0.05
組合3	lr0=0.01	lrf=0.15
組合4	lr0=0.009	lrf=0.01
組合5	lr0=0.009	lr0=0.05

在組合 3 lr0=0.01，lrf=0.15 中，Precision、Recall、mAP@50、mAP@50-95 及 F1 的五次測試後計算出平均數、樣本標準差為（0.9757，0.0162）、（0.9697，0.0136）、（0.9882，0.003）、（0.7635，0.0193）、（0.9727、0.0135），如下表 6。

表 6 組合 3 lr0=0.01，lrf=0.15 數據

	Precision	Recall	mAP@50	mAP@50-95	F1
1	0.9566	0.974	0.987	0.78	0.9653
2	0.9926	0.9811	0.9891	0.7542	0.9868
3	0.9842	0.9723	0.9911	0.7352	0.9782
4	0.9849	0.9751	0.9903	0.7667	0.98
5	0.96	0.9462	0.9837	0.7813	0.9530
Mean	0.9757	0.9697	0.9882	0.7635*	0.9727
Std.	0.0162	0.0136	0.003	0.0193	0.0135

在組合 4 lr0=0.009，lrf=0.01 中，Precision、Recall、mAP@50、mAP@50-95 及 F1 的五次測試後計算出平均數、樣本標準差為（0.9805，0.0088）、（0.9742，0.0132）、（0.9898，0.0036）、（0.7562，0.0157）、（0.9773，0.0109），如下表 7。

表 7 組合 4 lr0=0.009，lrf=0.01 數據

	Precision	Recall	mAP@50	mAP@50-95	F1
1	0.9672	0.9521	0.9844	0.7749	0.9596
2	0.9866	0.9832	0.9917	0.7493	0.9849
3	0.9843	0.9821	0.9933	0.7473	0.9832
4	0.9762	0.9719	0.9879	0.7705	0.974
5	0.9883	0.9816	0.9918	0.7389	0.985
Mean	0.9805*	0.9742*	0.9898*	0.7562	0.9773*
Std.	0.0088	0.0132	0.0036	0.0157	0.0109

在實驗過程中，我們將 Image size、Batch size、Epochs 設為固定，並將 lr0、lrf 分成五種不同組合（0.01，0.01）、（0.01，0.05）、（0.01，0.15）、（0.009，0.01）、（0.009，0.05），如下表 8，

lr0、lrf 越小，說明模型在偵測缺陷方面有較好的表現，組合 4（lr0=0.009，lrf=0.01）在 Precision 的 0.9805 為最好，Recall 的 0.9742 為最好，mAP@50 的 0.9898 為最好，F1 的 0.9773 為最好，因此我們發現組合 4（lr0=0.009，lrf=0.01）是綜合表現最好的一組，發現組合 3（lr0=0.01，lrf=0.15） 在 mAP@50-95 時的 0.7635 為最好。

表 8 實驗參數組合比較表

參數	組合1		組合2		組合3		組合4		組合5	
Image size	640x640		640x640		640x640		640x640		640x640	
Batch size	4		4		4		4		4	
Epochs	100		100		100		100		100	
lr0	0.01		0.01		0.01		0.009		0.009	
lrf	0.01		0.05		0.15		0.01		0.05	
Precision	Mean	0.973	Mean	0.975	Mean	0.9757	Mean	0.9805*	Mean	0.9753
	Std.	0.0083	Std.	0.0118	Std.	0.0162	Std.	0.0088	Std.	0.0047
Recall	Mean	0.957	Mean	0.972	Mean	0.9697	Mean	0.9742*	Mean	0.9634
	Std.	0.0095	Std.	0.01	Std.	0.0136	Std.	0.0132	Std.	0.0037
mAP@50	Mean	0.9836	Mean	0.9872	Mean	0.9882	Mean	0.9898*	Mean	0.9795
	Std.	0.0067	Std.	0.0063	Std.	0.003	Std.	0.0036	Std.	0.0058
mAP@50-95	Mean	0.7584	Mean	0.7575	Mean	0.7635*	Mean	0.7562	Mean	0.7581
	Std.	0.0251	Std.	0.022	Std.	0.0193	Std.	0.0157	Std.	0.0208
F1	Mean	0.9646	Mean	0.9735	Mean	0.9727	Mean	0.9773*	Mean	0.9693
	Std.	0.0057	Std.	0.01	Std.	0.0135	Std.	0.0109	Std.	0.003

從最佳組合4中，選取最好的一次作為判斷，圖8混淆矩陣（Confusion Matrix）圖中可以用來表示一個分類模型在不同類別上的預測效果，圖中的橫軸代表實際類別（True），縱軸代表模型預測結果（Predicted），每一格的數字代表在真實和預測組合下的比例，若方形矩陣中的顏色越深，則該種類的數值會越高，就代表模型在這個分類上的準確率越高。從實驗結果中可以看出在多數主要類別的預測上都具有良好準確性，例如：none、broken、gap、cropper與hole等類別，對角線上的數值幾乎都接近1，代表此模型對這些類別的預測高度準確，能有效將缺陷正確分類。其中，none的準確率達到0.99，broken為0.98，gap為0.97，而cropper與hole則達到0.99與0.97，然而，在部分類別上仍然可以看到混淆的情況，特別是burr與background之間的辨識結果。hole類別有0.03的比例被誤判為background，而short被誤判為background的比例更高，達到0.04。這樣的錯誤會使原本有缺陷的PCB板被當成良品流入後續流程，對產品品質造成風險，此外，background類別雖然整體誤殺率較低，但仍然可以見到被誤判為其他類別的情形，如short與hole，代表背景資訊在模型判斷中可能與某些瑕疵特徵具有部分重疊，導致誤判，這也代表即使整體分類準確率高，仍然會需要針對特定容易混淆的類

別進行模型強化或數據優化。

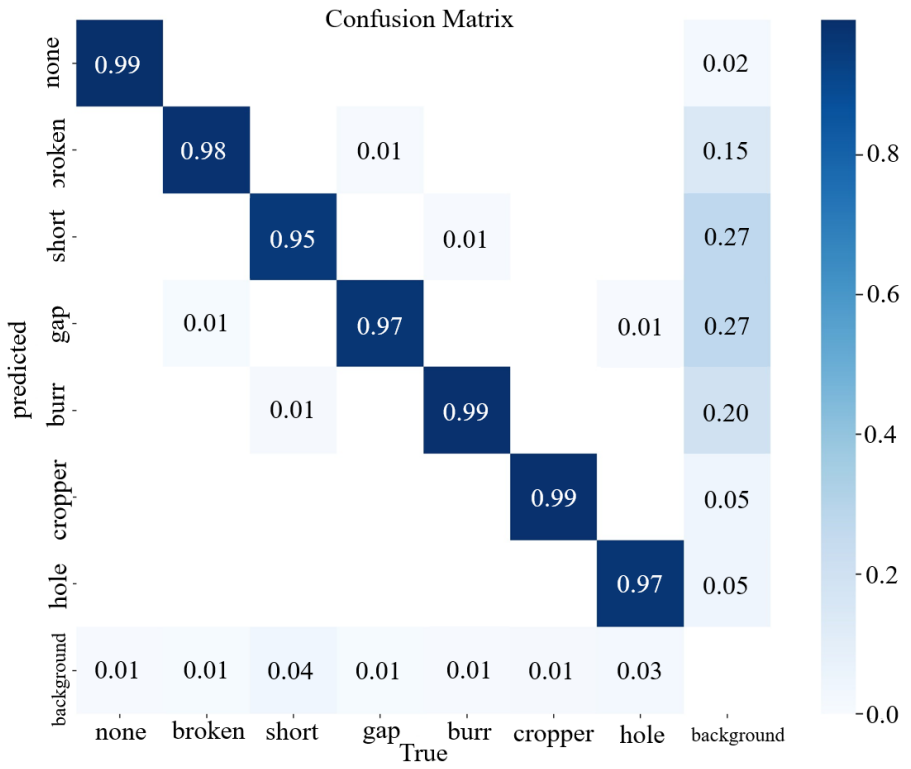


圖 7 混淆矩陣圖

4.3 實驗小結

透過實驗過程，本專題選出表現最佳的參數組合，為組合 4（lr0 = 0.009，lrf = 0.01），並與使用相同模型 YOLOv5s 的相關文獻進行比較。實驗結果比較顯示，在郭驥（2023）文獻中樣本數量為 10668 張、Epochs 為 300，而吳垚鋒（2023）的樣本數量為 786 張、Epochs 為 200，而本專題樣本數量為 3001 張、Epochs 為 100，因此，我們發現在較大的樣本數量及 Epochs 下，表現會較好，而與其他文獻相比，我們即便只使用中等的資料量，

但經過適當的參數調整，模型在 mAP@50-95 上仍然可以跑出比小樣本文獻更好的表現。而我們在使用較少的 Epochs、Batch size 和資料量的情況下，依然能達到相近的成果，因此，減少 Epochs 有助於縮短訓練時間，降低 Batch size 則可避免對高效能設備的需求，而減少資料量則能縮短前處理所需的時間，我們最終實驗出快速且有效的模型，如表 9 所示。

表 9 本專題與同模型文獻之比較

指標	Model	Batch size	Epochs	lr0	lrf	Precision	Recall	mAP@50	mAP@50-95	F1
本專題	YOLOv5s	4	100	0.009	0.01	98.05%	97.42%	98.98%	75.62%	97.73%
郭驥，2023	YOLOv5s	32	300	0.01	-	-	-	99.44%	85.14%	-
吳垚鋒，2023	YOLOv5s	4	200	0.01	0.01	99.9%	100%	99.5%	71.4%	99.95%

5.結論與未來展望

5.1 結論

本專題利用 GitHub 網站 tangsanli5201 所提供的 DeepPCB 瑕疵資料集提供的下載資料進行預測，最後設定參數為 Image size 640x640、Batch size 4、Epochs 100，組合 4（lr0=0.009，lrf=0.01），最終數據 Precision 的平均數為 0.9805、標準差為 0.0088，Recall 的平均數為 0.9742、標準差為 0.0132，mAP@50 的平均數為 0.9898、標準差為 0.0036，mAP@50-95 的平均數為 0.7562、標準差為 0.0157，F1 的平均數為 0.9773，標準差為 0.0109，誤殺率為 14%。從實驗結果可以發現 lr0、lrf 越小，說明模型在偵測缺陷方面有較好的表現，而與其他文獻相比，我們使用中樣本數量，mAP@50-95 卻比較小樣本量表現還要好，並且在減少 Epochs、Batch size 和資料量的前提下，我們仍然可以獲得與文獻相近的結果。減少 Epochs 可加快訓練速度，較小的 Batch size 可降低硬體需求，而減少資料量則能縮短前處理時間。由上述而言，我們所實驗出的模型具備高效率與良好效能的特性。

本專題應用的瑕疵檢測模型與適當超參數值具備三項實務優勢：（1）低資源可部署性：使用輕量化 YOLOv5s 架構與小 batch 設定，有助於應用於資源受限之邊緣裝置（2）縮短訓練時間：較少的 Epoch 與資料量仍達高效能，適合快速訓練迭代環境（3）誤殺率改善潛力：實驗混淆矩陣分析指出，本模型於多數類別預測準確度高，有助於降低生產線上錯判風險。

5.2 未來展望

1. 在現在工廠現場中，依舊是使用傳統 AOI 進行瑕疵檢測，而傳統檢測不具備學習功能，所以只能使用既有的資料進行檢測，導致誤殺率較高，未來可以將我們實驗所做出的模型導入現場中，可以使誤殺率降低，減少人力負擔，並提高缺陷檢測準確率，使生產線更有效率。
2. 使用 t 檢定分析來比較兩組樣本平均數，看出是否有顯著差異。
3. 本專題另一方面，瑕疵檢測系統的導入也需要考量實務中的資料收集與標註成本，因此建立一套高效的資料管理流程（如主動式學習、半監督學習等）也是提升 AI 導入效率的關鍵。
4. 未來若能提升實驗次數或升級硬體設備，將有助於模型表現的進一步提升。目前每組實驗僅進行 5 次，若能增加至 15 次，可以有效減少隨機性造成的誤差，使結果更具有穩定性與準確性，此外，因現有設備的限制，模型最多僅能訓練至 66 個 Epoch 就會出現資源不足的情況，若能升級硬體，將可進一步提升訓練輪數，讓模型學習更充分，提升整體預測結果。

參考文獻

1. 王炫尹（2019）。基於深度學習之 PCB 瑕疵偵測。國立暨南國際大學資訊工程學系學位論文，1-37。
2. 吳垚鋒（2023）。PCB 短路偵測基於 YOLO 各世代之邊緣運算。〔碩士論文。逢甲大學〕臺灣博碩士論文知識加值系統。
3. 林俊宇（2017）。改善擴散板表面缺陷的自動化檢測能力。中原大學工業與系統工程學系學位論文，1-62。
4. 林宸樂（2022）。PCB 瑕疵檢測使用區域注意力轉換器。宜蘭大學電子工程學系學位論文，2022，1-77。
5. 范紋慈（2023）。無線感測應用於室內人體偵測： 使用 YOLOv5 進行目標識別。中原大學電子工程學系學位論文，1-98。
6. 高翰文（2023）。使用 YOLO 模型對 PCB 做瑕疵檢測以改善 AOI 缺陷。〔碩士論文。逢甲大學〕臺灣博碩士論文知識加值系統。
7. 湯仁愷（2023）。應用 YOLOv5 和 CNN 深度學習技術於車牌辨識研究。〔碩士論文。國立臺北科技大學〕臺灣博碩士論文知識加值系統。
8. 葉峻賓、連健宏、許沁如、王裕清、黎煥昇、王裕銘、莊柏逸、蔡博翔（2020）。虛擬檢測員－全自動智慧 PCB 光學檢測技術。機械工業雜誌，（451），36-46。
9. Bai, J., Wu, D., Shelley, T., Schubel, P., Twine, D., Russell, J., ... & Zhang, J.（ 2024 ）. A comprehensive survey on machine learning driven material defect detection: Challenges, solutions, and future prospects. arXiv preprint arXiv:2406.07880.
10. ., Wang, C. Y., & Liao, H. Y. M. （2020）. YOLOv4：Optimal speed and accuracy of object detection. arXiv preprint arXiv：2004.10934.
11. Bochkovskiy, A., Wang, C. Y.,& Liao, H. Y. M.（2023）. YOLOv7：Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition （ pp. 7464-7475）.
12. Dulal, R., Zheng, L., Kabir, M. A., McGrath, S., Medway, J.,Swain,D., & Swain,W.（ 2022, November）. Automatic cattle identification using YOLOv5 and mosaic augmentation ： A comparative analysis. In 2022 International Conference on Digital Image Computing ： Techniques and Applications（DICTA）（pp. 1-8）. IEEE.
13. Goenawan, C. R.（2024）. ASTM： Autonomous Smart Traffic Management System Using Artificial Intelligence CNN and LSTM. arXiv preprint arXiv：2410.10929.
14. Smith, L. N., & Topin, N. （2019, May）. Super-convergence ： Very fast training of neural networks using large learning rates. In Artificial intelligence and machine learning for multi-domain operations applications （Vol. 11006, pp. 369-386）. SPIE.
15. Tang, S., He, F., Huang, X., & Yang, J. （2019）. Online PCB defect detector on a new PCB defect dataset. arXiv preprint arXiv：1902.06197.
16. Tseng, S. H., & Kuo, C. （2024）. PCB Defect Detection Based on Improved Deep Learning Model. International Journal of Pattern Recognition and Artificial Intelligence, 38（11）, 2454014.
17. Xu, B., & Yu, S. （2024）. Improving Data Augmentation for YOLOv5 Using Enhanced Segment Anything Model. Applied Sciences, 14（5）, 1819.
18. Yun, S., Han, D., Oh, S. J., Chun, S., Choe, J., & Yoo, Y. （2019）. Cutmix： Regularization strategy to train strong classifiers with localizable features. In Proceedings of the IEEE/CVF international conference on computer vision （pp. 6023-6032）.