

以深度學習進行全方位軌道缺失構件檢測¹

A COMPREHENSIVE DETECTION SYSTEM OF DEFECTIVE TRACK COMPONENTS BY DEEP LEARNING

謝禎岡 Chen-Chiung Hsieh²

謝幼屏 Yu-Ping Hsieh³

賴瑞應 Jui-Ying Lai⁴

黃維信 Wei-Hsin Huang⁵

謝尚琳 Shan-Lin Hsieh⁶

徐侖雲 Ti-Yun Hsu⁷

杜宇豪 Yu-How Du⁷

賈漢文 Han-Wen Jia⁷

(110 年 12 月 30 日收稿, 111 年 4 月 27 日第一次修改, 111 年 6 月 2 日接受)

摘 要

軌道扣件負責固定鋼軌於枕木上, 避免軌道鬆脫變形。傳統鐵路軌道扣件巡檢方式係採人工, 以目視方式進行巡檢。近年來, 人工智慧深度學習蓬勃發展, 在許多領域獲得突破性進展, 因此本研究以人工智慧 (Artificial Intelligence, AI) 方式進行鐵路軌道缺失構件檢測, 得以降低人工巡檢的負擔及時間, 並將此技術實地測試與應用推廣。首先蒐集國內外鐵

-
1. 本文為軌道扣件缺失人工智慧辨識現地測試及精進研究 (計畫編號: MOTC-IOT-110-H1CB001g) 部分研究成果, 特此致謝。
 2. 大同大學資訊工程系專任教授 (研究案計畫主持人, 聯絡地址: 臺北市中山北路 3 段 40 號, 電話: 02-21822928, E-mail: cchsieh@gm.ttu.edu.tw)。
 3. 交通部運輸研究所研究員。
 4. 交通部運輸研究所科長。
 5. 大同大學設計科學研究所專任教授兼任副校長、研發長。
 6. 大同大學資訊工程系專任副教授兼任學務長。
 7. 大同大學資訊工程系研究生。

路軌道構件檢測案例並分析其設備及方法，接著建立軌道構件樣本的擷取設備，包含影像記錄及照明，再依收集之上視、側視軌道構件樣本，分為上視 10 種缺失類別、側視 4 種缺失類別與 2 種正常類別。採用 YOLOv4-Tiny 模型進行深度學習訓練。在實驗中錄製超過 70 公里軌道構件影像，分別以上視缺失構件與側視構件資料集進行訓練，所得上視缺失與側視缺失檢出率分別為 91%與 94%，平均精確率各別為 91.7%與 99.2%，顯示辨識指標良好，執行效能也可達 150 張/秒。期間比較 YOLOv4-Tiny 模型與人工徒步巡檢，成本與效能均較佳。

關鍵詞： 鐵路軌道巡檢、軌道構件、深度學習、YOLO

ABSTRACT

The rail fasteners are responsible for fixing the tracks on the sleepers to prevent the tracks from loosening and deforming. The traditional inspection method of railway track fasteners adopts human visual inspection. Artificial intelligence (AI) deep learning has developed rapidly and made a breakthrough in many fields in recent years. Therefore, this study uses artificial intelligence to detect missing components of railway tracks and reduce the burden and time of manual inspection. The goal is to promote this technology to field applications. Firstly, we have surveyed some commercial track fastener inspection products from both domestic and foreign; analyze the deployed equipment and method for domestic applicability. Then, the image collecting equipment for the track components, including image recording and lighting, is established. There are ten and six types of classes defined for the top and side view of the track, respectively. YOLOv4-tiny, for its superior performance, is selected for our application. More than 70 km of track images were recorded in experiments. Moreover, the performance metrics (recall rate, mAP) are (91%, 91.7%) and (94%, 99.2%) for the top and side-view, respectively. The execution speed of YOLOv4-tiny also reached 150 fps. Meanwhile, the AI model was compared with the human eye-sight inspection, and the overall performance was better than human inspections.

Key Words : Rail Track Inspection; Track Fastener; Deep Learning; YOLO

一、前言

軌道運輸為臺灣地區最主要的交通運輸工具之一，影響軌道安全的因素有自然環境因素(地震、颱風、豪雨、邊坡滑動、落石等)、人為因素(破壞設備、縱火、爆裂物、暴力攻擊、挾持等)、與設備異常(軌道變形、號誌系統故障、道岔故障、列車轉向架故障、電

車線垂落等)，圖 1 所示是鋼軌焊接處因熱漲冷縮引起裂縫^[1]，先以魚尾板固定情形。軌道變形直接影響軌道安全，軌道扣件負責固定鋼軌於枕木上，避免軌道鬆脫變形。傳統鐵路軌道扣件巡檢方式係採用人工，以目視方式進行巡檢，而人工目視巡檢受限於巡檢車速及視察角度等問題，至今並無法有效快速進行，因此，提出利用人工智慧 (Artificial Intelligence, AI) 方式來協助完成巡檢任務，可有效提升巡檢效率，降低巡檢人員視察侷限等問題。因此，本研究利用攝影機搭配 AI 深度學習方法，作為鐵路軌道扣件自動缺失辨識分析之用途，用來替代目前人工巡檢工作，達到自動化鐵路軌道扣件檢測的目的。

本研究提供以 AI 方式來達到全方位自動辨識鐵路軌道構件外觀是否正常，得以降低人工巡檢的人力及時間，並配合測試，將此技術實際應用並進行推廣。首先蒐集國內外鐵路軌道扣件檢測案例並分析其設備、方法及國內適用性，利用現行深度學習方式，進行軌道扣件缺失辨識並搭配定位系統，進行軌道扣件缺失辨識系統精進及驗證，增加辨識準確性及定位精度，可解決道工人力日益短缺及人工目視僅能執行單側檢視等問題，可提升巡檢效能，有助於臺灣軌道維護管理，提升軌道行車安全。




圖 1 鋼軌因寒冷導致焊點拉裂，以魚尾板固定情形^[1]

本研究主要為建立臺中工務段轄區軌道扣件辨識資料庫、精進系統並提升辨識準確度，除了在原軌道正上方拍攝，辨識軌道缺失扣件外，另因應實務巡檢辨識需要，增加側向拍攝，以辨識鋼軌側面裂縫及魚尾板螺栓缺失，故辨識對象由軌道「扣件」改為軌道「構件」(扣件、道釘、鋼軌、魚尾板)，先建立軌道構件缺失之辨識準則，接著蒐集構件資料集，進行 AI 模型訓練與測試，提出軌道構件辨識檢出率 (Recall rate) 及辨識精確率 (Precision)。另外精進軌道隧道段缺失構件定位方式，並將系統移轉給臺鐵局臺中工務段進行實務運用，在臺中工務段所屬轄區，擇一軌道段進行人工巡檢與 AI 辨識缺失進行比較，以便修正 AI 辨識系統。接著再進行實地拍攝 (來回里程總計至少 70 公里)，含軌道正上方及側向拍攝，視其辨識穩定度及正確率變化情形。

由於臺鐵局軌道所使用的構件可能有許多種不同的型式及廠牌，所以與臺鐵局人員洽

詢後，以重要性較高之構件型式為研究範圍，包括 e-Clip、版式軌道 e-Clip、道釘、及魚尾鉸等，如圖 2 所示。本研究因應臺鐵局實務巡檢辨識需要，增加軌面及軌腹缺失辨識，故本研究主題與重點之辨識對象由軌道「扣件」改為軌道「構件」(扣件、道釘、鋼軌、魚尾鉸)；對於軌面缺失，亦與臺鐵局人員討論後，缺失分為兩項：鋼軌裂縫及踏面不整；至於軌腹缺失，則包括側面裂縫、魚尾鉸缺失(如螺栓鬆脫等)，在軌面下之凹槽則不在本研究範圍內。




圖 2 常見軌道構件，(a) e-Clip、(b) 版式軌道 e-Clip、(c) 道釘、與(d) 魚尾鉸

本研究於第二節介紹相關之研究案例，並做比較與分析，第三節描述本研究所提方法與步驟，第四節則說明軌道構件巡檢系統的精進與現地測試成果，最後在第五節做結論。

二、文獻回顧

本節介紹國內外之軌道檢測系統和相關研究案例，將各個案例進行統整，分析比較其優缺點，以利增進本研究之成果。

2.1 國內外檢測產品

瑞士電子和微技術中心 (Centre Suisse d'Electronique et de Microtechnique, CSEM) 在 2007 年就開始進行自動化系統^[2]開發，因為傳統影像辨識方法產生太多誤判 (False Positives/Negatives)，導致還需要人力再加以檢查一遍，所以改用深度學習改進這個缺點，使用配備多個高解析度的攝影機及其他感測器的「診斷列車」(Diagnosis Trains)，以時速 160 公里速度行駛取得分析所需的影像資料。透過深度學習技術，所希望達到的目的包括：

- (1) 改善鐵路軌道故障的檢測和分類技術。
- (2) 盡量減少現場目視檢查的次數。
- (3) 減少專家處理誤報的問題。

配合深度學習所需，針對收集到的影像進行標籤化處理，希望透過反覆不斷的學習與訓練，讓分析模型可以更為精準。正如許多以深度學習為起點的業務一樣，在專案開始時幾乎沒有標記資料可用。此外，某些故障類別需要訓練有素的鐵路專家的判斷，但他們可

能並不總是同意，為了解決這個問題，決定採用多數決的方式進行決策。在訓練時，將帶有標註的圖片上傳到一個網路服務器，在那裡可以考慮多位專家不同的回饋意見，再對資料進行標記，將資料回饋到訓練集中，然後對模型進行再訓練。通過反覆執行上述步驟，模型的準確性隨著時間的推移而提高，這就是所謂的終身機器學習 (Life-long Machine Learning)。

另一個值得採用的技巧，槓桿轉移學習 (Transfer Learning)，一種機器學習技術，它專注於在解決一個問題時獲得的知識，並將其應用於另一個相關的問題，重新訓練與執行推理，再部署訓練好的深度學習模型。他們的系統採用人工智慧工作站 NVIDIA DGX 工作站，有助於加速深度學習訓練和提高檢測精度，DGX 電腦正常工作在幾個小時內就完成，是一個擁有最新、最優化的深度學習框架的完整系統，與其擔心如何在系統上配置許多低階元件，不如集中精力收集正確的資料，增加訓練 AI 模型負擔，並與專家一起準確地分類樣本。

ENSCO^[3] 使用高解析度相機系統和先進影像處理演算法，使其系統具有可靠的圖像採集和處理能力，該檢測設備已成功地應用於一系列軌道扣件的檢測，包括魚尾鉸、枕木、扣件、軌面和電力線。特別對軌道接合處 (魚尾鉸) 進行自動裂紋檢測，測量鋼軌間隙，自動偵測出鋼軌的裂縫，以及採用專利線掃描成像方法，從移動的車輛上收集和記錄連續的高解析度軌道表面影像，檢查包括滾動接觸疲勞 (Rolling Contact Fatigue, RCF)、剝落、踏面裂紋、發動機燒傷和斷軌，以幫助安全和維護活動。

加拿大 Pavemetrics 公司的 Laser Rail Inspection System (LRAIL)^[4] 推出新式的全方位軌道檢測系統，可架設在改裝的車輛或是火車頭前，檢測速度可達 180 km/h，主要特點是同步 3D 幾何測量和高解析度影像，進行全自動鐵路檢查，包括枕木評分 (位置、歪斜角度、裂縫、斷裂、腐爛、缺少道釘)、扣件檢測 (位置、型式、移位、缺少、遮蔽)、鋼軌踏面缺失 (剝離、裂縫)、鋼軌接頭檢測及接頭軌縫量測、軌道軌距、水平、方向、高低檢測、軌頭 3D 剖面及磨損檢測，以及使用里程點和慣性校正的 GPS 自動對數據進行定位參考。

BvSys^[5] 的鐵路自動檢測系統，能將缺陷檢測與高速處理結合在一起，且不影響軌道交通的正常運作，此系統提供定期和經濟的軌道檢查，可以很早就發現損害，這使得採用預防措施的軌道大大延長其生命週期。其軌面檢測系統，可自動檢測軌道表面可見的異常、缺少扣件、混凝土軌枕破裂或損壞以及測量道碴輪廓等。他們採用高性能線掃描攝影機和雷射測距儀垂直安裝在軌道上方，觀察軌道兩側、軌枕指定區域和道碴。

MERMEC^[6] 檢測系統能夠自動檢測軌道魚尾鉸 (或鋼軌接頭桿) 任何裂紋，劃痕或任何其他缺陷，該系統能夠實現 0–320 公里/小時的測量，檢查的具體演算法包括魚尾鉸裂紋的自動檢測，但裂紋檢測需>1 毫米，以及螺栓遺失的自動檢測。

臺北大眾捷運股份有限公司也擁有一套軌道檢測系統^[7]，採用檢測車形式，其中央控制系統可顯示相關記錄資訊，如：路線別、里程位置及瑕疵狀況等，在車底左、右鋼軌上方設置攝影機組設備，經由中央控制電腦主機進行影像擷取、壓縮或轉換、瑕疵分類、報告紀錄產出等功能，影像工作站系統採用工業級電腦。

中國鐵道部與美國 ENSCO 於 80 年代開始合作，進入 21 世紀後，於 2008 年推出中國最先進的 0 號高速綜合檢測列車 (Comprehensive Inspection Train, CIT)^[8]，使用 ENSCO 軌檢系統，是一系列應用於中國高速鐵路的綜合檢測動車組列車，是為時速 200 公里以上的高速鐵路實施定期檢測、綜合檢測和高速檢測的重要裝備，擁有對軌道、接觸網、通信信號等基礎設施的綜合檢測能力，內部擺設包含機櫃、操作控制台、小型會議桌等。

2.2 機器學習檢測技術

最近幾年，應用深度學習進行軌道扣件的檢測越來越受到重視。由 Yang 等人^[9] 提出使用 ResNet 和 FCN (Fully Connection Network) 進行軌道接頭的檢測，此文利用鐵道檢查車進行軌道加速度數據收集，並將數據分為 3 種類別，分別是無接頭、左接頭、右接頭，藉由加速度進行軌道接頭的檢測，經測試得出 ResNet 的 Recall 平均約為 91%，精確率平均約為 84%，而 FCN 的 Recall 平均約為 92.8%，精確率平均約為 77.8%。

由 Gibert 等人^[10] 提出使用 Deep CNN(Convolution Neural Network) MTL(Multi-Task Learning)進行扣件檢測，此文類別主要分為背景、枕木材質、正常扣件與損壞扣件，並證明缺少訓練樣本的情況下可用 MTL 的方式進行訓練以提高檢測缺失扣件的準確性。

由 Ashish 等人^[11] 提出使用 TrackNet 進行軌面損壞的檢測，此文利用 ResNet 與 DenseNet 進行兩階段的軌面分類，在第一個神經網路檢測出損壞時不會立即發出警示，而是會將第一段的辨識結果進行語意分割交由第二個神經網路判斷是否誤判，這種方法可大幅減少誤判機率，讓誤報發生機率下降，經測試利用 ResNet 的 TrackNet 平均準確率為 88.8%，利用 DenseNet 的 TrackNet 平均準確率為 90.3%。還有由 Song 等人^[12]提出將高速鐵路上的鋼軌扣件分為 4 大種類，並分別蒐集 1000 張樣本後，使用優化後的 Faster-RCNN (Region Convolution Neural Network)^[13] 訓練並驗證得出檢出率 99.83%、精確率 99.93%，並在 Titan X GPU 上達到 35 fps 的辨識速度。

2.3 統整分析

2.1 節-2.2 節簡介目前各國具實用性軌道檢測系統，其中歐美先進國家起步都相當早，但是最近幾年 AI 的深度學習網路崛起，給我們很大機會可以在辨識軟體上做一良性競爭，至於辨識硬體，臺灣更是具有價格競爭力，表 1 將目前各國具實用性軌道檢測系統表列。其中本團隊所參與執行的「軌道扣件巡檢系統建置 (1/2) -扣件缺失辨識系統建置研究」^[14] 與「軌道扣件巡檢系統建置 (2/2) -扣件缺失辨識系統精進驗證」^[15] 中，透過收集之軌道扣件資料，進行影像標記處理，使用 You Only Look Once (YOLO) v3^[16]/v4^[17] 進行深度學習模型訓練，再從測試資料驗證缺失扣件檢出率，以建立一套扣件影像巡檢自動辨識系統，可用以檢測鐵路軌道扣件是否鬆脫。

在實際應用時，影像擷取的部份，採用運動型攝影機 GoPro 進行拍攝，交通部運輸研究所^[14]以 YOLOv3 驗證，正常扣件辨識率 82.5%，缺失扣件檢出率 (Recall rate) 74.5%，

平均精確率(mean Average Precision, mAP) 90.32%，雖可達到鐵路軌道扣件影像辨識檢測的目的，但是仍然有進步的空間。交通部運輸研究所^[17]繼續採用 YOLOv4，訓練方式改用缺失扣件資料，缺失扣件檢出率提升至 87%，平均精確率提升為 94.8%，系統辨識速度更高達 55 張/秒 (在伺服器電腦或高效能筆電上執行)。他們也採用 Single Shot Detector (SSD)^[18] 的 AI 模型進行驗證，經過調校後效果也不錯，與 YOLOv4 不相上下。為方便軌道巡檢人員尋找扣件，還另開發雲端儲存、辨識、與查詢等功能，可在 Google Maps 上顯示百公尺樁，容易定位缺失扣件，便於工作人員進行維修。

表 1 各國實用軌道檢測系統綜合比較

文 獻	發展 起始	辨識項目	取像 方式	列車運行 速度	辨識引擎	準確率	辨識 速度
瑞士 ^[2]	2007	Track/20 種	HR Cam	160km/h	AI/GAN	NA	Real Time
美國 ^[3]	1970	All	Line Scan	High speed	NA*	NA	Real Time
加拿大 ^[4]	2018	Track/All	Laser	180km/h	NA	NA	Real Time
德國 ^[5]	1990	All	HR Cam	>200 km/h	NA	NA	Real Time
義大利 ^[6]	1991	4 Types of Fishplates	Line Scan	<320km/h	AI	NA	Real Time
臺北捷運 公司 ^[7]	2013	MRT 版式 軌道扣件	Line Scan	NA	非深度學習	NA	NA
中國高鐵 ^[8]	2008	軌道、通信 信號	NA	200km/h	NA	NA	NA
運研所 ^[15]	2019	Track/10 種	Cam	30km/h	AI/YOLOv4	80.8%	Real Time

*NA (Not Available) 代表未蒐集到而非沒有。

比較國外及本土研發檢測設備，國外設備商品化較高，功能齊全，但價格昂貴，但是否適用於臺鐵局多規格的軌道與複雜線形，還須進一步的驗證，且相關設備引進後之維護與精進都需要依靠原廠來處理，也是日後會遭遇的問題。而本研究所開發之系統是針對臺鐵局軌道規格及線形客製化研發的系統，應用最新的深度學習神經網路模型 Scaled YOLOv4^[19] 進行 1-Stage Object Detection，將物件定位與瑕疵檢測一階段完成，一則考量速度較快，另一方面可以達到接近二階物件檢測的準確率。考慮未來推廣應用於該局全臺各工務段，較無適用性問題，且未來系統精進與維護，臺鐵局可自行處理，無須依靠原廠。

三、研究方法

本研究採用高速攝影機輔以足夠照明，透過無線網路或是 HDMI、USB 等介面，將攝影機拍攝的影像，傳送到前端系統，進行影像辨識或是儲存，再配合外接 GPS (Global Positioning System) 的定位功能，隧道段則輔以陀螺儀，即可標示出有問題的構件或軌面所

在的軌道範圍。影像辨識的深度學習模型，108 年度交通部運輸研究所^[14]採用 YOLOv3^[16]，雖然 YOLOv3 非常快，小型的模型可以達到 155 FPS (Frames Per Second)，但是隨之而來的是 mAP 的降低，以及框選位置不準的問題。109 年度交通部運輸研究所^[15]採用更為有效的 SSD^[18] 模型，SSD 則有點像 Faster R-CNN^[19] 中的多類別 RPN (Region Proposal Network) 網路，是一個十分成功的檢測框架。它採用特徵金字塔的多層預測方法，在不同的卷積層上設置前景方框，在不同大小的特徵圖上考慮不同的尺度，相當於每個層分開預測，最後一起得到結果。從 R-CNN 到 Faster R-CNN，再到 YOLOv3、YOLOv4^[16]，以及和其並駕齊驅的 SSD，目標檢測的發展在 2018~2020 年達到了一個巔峰。

本研究持續蒐集更多缺失構件樣本，其中尤以軌面缺失、版式軌道扣件缺失相對其他類別在數量上少了許多，若能增加，將有助於平均類別精確率 (mAP)、精確率 (Precision)、與檢出率 (Recall) 的提升。至於神經網路模型的選擇，仍然是 SSD 與 YOLO v4^[5] 為首選，但是隨著技術的演進，Scaled YOLOv4^[19]，YOLOv5^[20] 的相繼出現，也是本研究選項之一。其中 Scaled YOLOv4，可以調整神經網路的大小以因應使用環境的計算能力做調整，其輕量級縮小版 YOLOv4 tiny^[21] 的辨識速度為 YOLOv4 的 4 倍以上。

3.1 系統設計與架構

前端系統採用高速攝影機作為影像擷取裝置，攝影機透過無線網路或是 HDMI、USB 等介面連線，進行影像辨識，或是把原始影像轉存為適合傳輸的格式後，將欲判定的影像送至後端深度學習伺服器進行影像辨識與分析處理。影像擷取裝置設定在檢查期間能維持 1080P/60 FPS 情況下運作，預計單次工作最長時間為 5 小時。前端系統除擷取影像外，還會記錄時間與 GPS 位置資訊；前端辨識與儲存系統提供人機操作介面，選擇自動辨識、手動紀錄輸入、錄影檢視，或透過網路將錄製影像回傳至後端影像辨識伺服器進行辨識。在與後端影像辨識伺服器連線時，須具備足夠的 I/O (Input/Output) 效能與儲存資料能力，同時必須能運行 Windows 10 或 Ubuntu 18.04，方能在適當的時間內完成紀錄的壓縮與傳輸。而後端影像辨識伺服器，須具有足夠的效能以在最短時間內辨識完影片，並將資料統整分類。

在前端辨識與儲存系統運作的部份，當系統開機後會先進行自我檢測，先驗證伺服器狀態確保後續服務可正常進行。待驗證完成後，可選擇「即時模式」或「紀錄模式」。若選擇「即時模式」則會進行影像辨識，即時顯示辨識結果，並將辨識結果儲存前端，俟進場後再將資料傳送到後端伺服器。若選擇「紀錄模式」，則待完成錄影後再透過網路，將錄影資料傳送到後端伺服器，進行辨識與儲存辨識結果。目前規劃的前端辨識與儲存系統運作流程圖，整理如圖 3(a) 所示。其中影像前處理是同步 GPS 與影像資料。

在後端伺服器處理的部份，同樣開機時先進行自我檢測，以確定伺服器可正常運作，以接收前端回傳之影像資料。待完成自我檢測後即可進行待機模式，準備接收前端之請求。目前規劃的請求模式有三種：資料查詢、紀錄模式、即時模式。「資料查詢」的部份，係供使用者查詢歷次的分析結果，以做為研析判斷使用。若是「紀錄模式」時，影像採批

次上傳，待影像上傳後透過「影像辨識」服務，萃取出符合需求之結果，儲存辨識結果。若是「即時模式」服務，則快速回應辨識結果。目前規劃的後端處理伺服器流程整理如圖 3(b)所示。




圖 3 系統運作流程圖。(a)前端辨識與儲存系統流程、(b)後端處理伺服器系統流程

3.2 設備架設

本研究新增軌腹缺失辨識，包括側面裂縫與魚尾鉸缺失，若採上視攝影將無法拍攝到軌腹畫面，因此將採鋼軌側視攝影，如圖 4(a) 與 (b) 所示，單一軌道即需雙側燈光與 2 支攝影機，兩軌道就要共四側燈光，與 4 支攝影機；實際 LED 燈具仍建議 200W 以上，攝影機也採用 GoPro 7/8。除燈光由軌道上方八字側投射，並降低燈具高度如圖 4(c) 所示，以增加側視亮度。另增加 2 盞投射燈，將暗的地方補亮。因降低燈具高度，且燈具較大，容易導致與道碴撞擊，因此損失 1 燈具，已改安裝 2 盞較小的 LED 投射燈，亮度也夠，拍攝結果良好。上視攝影結果參見圖 5，最下面一列可清楚拍攝軌面與 e-Clip，且無軌面反光現象，更有利於 AI 辨識。圖 6 所示為軌側攝影，最後一列可清楚看到軌腹，遠比第一版側視攝影效果要好許多，無論上視或側視攝影，幾乎無盲區。



圖 4 燈光與 GoPro 攝影機架設情形

(a)降低燈光高度，左右側攝影、(b)八字投射燈光於被射物體，以增加亮度




圖 5 側向投射上視軌道構件攝影。(a)左軌上視、(b)右軌上視

3.3 AI 辨識模型

本研究採用 YOLO 演算法，是一種物件偵測的神經網路演算法，優點在於輕量且高效率，追求快速辨識與高準確度，可以即時產生結果，應用於物體辨識。神經網路的學習需



圖 6 側視軌道構件攝影
(a)右軌內側、(b)右軌外側、(c)左軌內側、(d)左軌外側

使用 CSP 化模型，所以很值得本研究參考。

YOLOv4 中的數據增強是 YOLOv4 令人印象深刻的性能的關鍵貢獻之一，在 Scaled YOLOv4 中，會先在增強較少的數據集上進行訓練，然後在訓練結束時調高增強以進行微調。還使用「測試時間增強」，其中在測試集上進行了許多增強。然後對這些測試增強的預測進行平均，以進一步提高其非即時結果。Scaled YOLOv4 與其他目標檢測模型的效能比較圖(如圖 8 所示)，在所有的 YOLO 系列模型中是最好最快的。

在低運算 GPU 中模型的推理速度除了會受到模型大小、計算量外，還會因為設備資源的限制而有所影響，因此需要考慮到記憶體頻寬、記憶體使用量、動態隨機存取記憶體流量，在 Scaled YOLOv4 模型中，有許多不同尺寸大小的模型可供選擇，考慮本研究的構件種類不多，執行速度的考量會比較優先，若選擇 YOLOv4-Tiny^[21]，可以在計算量小的情況下達到所要求的準確度，輕量模型會比大型模型的參數利用效率還要高。在進行模型縮放時，計算複雜度能夠盡可能的低，有效利用參數的網路。




圖 8 Scaled YOLOv4 之效能比較^[19]

3.4 即時辨識系統

實驗假設列車以時速 60 公里/小時速度進行辨識與移動，則移動距離為 $60 \times 1,000 = 60,000$ 公尺，每秒平均移動 17 公尺，攝影機拍攝長度約為 1 公尺，則至少需每秒完成辨識 17 張圖片。此外，若需同時進行兩個攝影機畫面的同時輸入處理並同步顯示，則需要兩倍的執行速度，即為每秒辨識 34 張照片(或 0.029 秒內完成單張圖片)的處理。為達即時辨識，在不影響辨識結果下，本研究使用伺服器規格執行 YOLOv4，將影像解析度由原本 416×416 降為 320×320 ，調整影像解析度對於檢測效能的影響如表 2 所示，約快 1.5 倍。在本研究中，

採用平車進行實測，行駛時速依臺鐵局規定不得超過 35km/h，否則有安全上的顧慮，因此在實驗中，所進行的測試都在 30km/h 左右，如此一來，所採用的電腦效能規格就可以較為便宜。

本研究將採用執行緒 (Thread) 來最佳化程式，它是作業系統能夠進行運算排程的最小單位，利用平行處理，多執行緒在理論上可以最大程度的利用電腦性能，但並非越多越快，如我們進行執行緒個數實驗，發現作業系統與電腦硬體需要切換才能存取不同程式的資料 (Context Switching)，在傳輸資料及等待資料的過程會產生內部延遲，以目前而言，採取 3 個執行緒處理是效能較佳的作法，分別為攝影機、辨識、與顯示介面，其中加入攝影機意外斷線時的糾錯，已可避免當機情形。主程式結構優化，現在攝影機控制函數已從中分離至獨立程序，避免因 OpenCV 版本問題造成引用失敗，且增加可讀性。

表 2 即時辨識效能時間分析

解析度	416×416	320×320
檢測階段	6.32 秒	6.32 秒
啟動攝影機	2 秒	2 秒
雙側攝影機影像處理	0.02 秒	0.02 秒
影像辨識(單張)	0.023 秒	0.015 秒
顯示結果	0.001 秒	0.001 秒
完整運行一次辨識流程	0.05 秒	0.033 秒

四、軌道構件巡檢系統建置與驗證

以第三節所提之研究方法與步驟進行實作與修正，尤其是平車設備架設與缺失構件照片的分類訓練最為耗費人力與時間，因為一方面資料量很大，標記資料可能忙中有錯，另一方面測試後的資料更新與再訓練。

4.1 缺失辨識準則與資料庫建立

軌道構件系統所採用的構件各國皆不相同，各國所發展的自動構件辨識標的也大相逕庭。臺灣所採用的構件種類更是聯合國，依據大甲分駐所專家建議，本研究先由較常見的軌道構件開始蒐集，進而擴及軌面，最後再蒐集軌側影像。AI 辨識系統要正常運作，發揮即時偵測與辨識的功能，需要靠專業團隊提供原始資料，以及對欲辨識構件的分類與正確標籤。對於此，本研究持續與臺鐵局大甲分駐所合作，由大甲分駐所先提供欲辨識構件影像，由本研究先行分類與訓練，再請大甲分駐所專家檢視構件分類狀況，並持續更新與收集不足之樣本，以做為訓練 AI 模型使用。

4.1.1 上視缺失構件分類與資料集

AI 訓練資料光有正樣本 (缺失構件影像) 還不夠，還必須提供負樣本 (正常構件影像) 供 AI 模型以區分缺損的構件與正常的構件。由臺鐵局大甲分駐所協助提供各類缺失構件，將以往上視軌道構件缺失如表 3 為基礎，X 代表輕微缺失，和 XX 代表嚴重損壞，整理缺失構件資料集為 8,085 張，來源為交通部運輸研究所^[14]所收集到的。

表 3 上視軌道缺失構件分類

編號	扣件分類	圖片	說明
1	e扣件缺失X		位置偏離、未定位
2	e扣件缺失XX		遺失、斷裂
3	道釘缺失X		位置偏離、未定位
4	道釘缺失XX		遺失、斷裂
5	其他錯誤		軌道上其他異物、錯誤
6	元件被遮蔽X		扣件因線路、道碴、植物等原因遭到遮蔽
7	軌面缺失X		踏面損傷: 軌面中間凹陷、邊緣裂縫
8	軌面缺失XX		鋼軌裂縫
9	版式e扣件缺失X		扣夾位置偏離、未定位 螺栓鬆動
10	版式e扣件缺失XX		扣夾遺失、斷裂 螺栓遺失

有鑑於構件辨識的目的是將有缺失的構件檢測出來，原來正常的構件主要是當作負樣本，於是訓練時會將有缺失的構件與正常構件一起進行訓練，訓練樣本張數 3420，測試樣本張數 380，資料集中上視正向拍攝之缺失構件影像為 1417 張，表 4 為上視正向資料集樣本數

分佈狀況，所有照片均為較清晰無殘影版本。以 1920*1080 的解析度拍攝 1m*0.5m 的範圍，1 pixel 相當於 0.5mm² 的面積，因此鋼軌裂縫在 1cm 以上，應該就可以被偵測出來。

表 4 上視正向資料集

類 別	真實影像 (張)	小計 (張)
1) e 扣件缺失 X	52	52
2) e 扣件缺失 XX	276	276
3) 道釘缺失 X	37	37
4) 道釘缺失 XX	58	58
5) 其他錯誤	17	17
6) 元件被遮蔽	611	611
7) 軌面缺失 X	77	77
8) 軌面缺失 XX	226	226
9) 版式 e 扣件缺失 X	35	35
10) 版式 e 扣件缺失 XX	28	28
11) 正常影像	2383	2383
合 計		3800

4.1.2 側視缺失構件分類

我們參考相關文獻與諮詢大甲軌道巡檢人員，得知魚尾鈹的種類繁多，但是可以歸納出缺失種類，依此提出側視攝影軌道構件缺失類別，如表 5 所示，並說明如下：

1. 鋼軌裂縫：在鋼軌側邊出現的裂縫，或延伸到表面裂縫。
2. 魚尾鈹裂縫：因接頭輪錘衝擊作用導致魚尾鈹斷裂。
3. 螺栓脫落：魚尾鈹螺栓鬆脫或脫落。
4. 魚尾鈹異物：非屬魚尾鈹扣件之物體，如其他螺帽、垃圾等物體。

因為鮮少有鋼軌裂縫、魚尾鈹斷裂、焊接處斷裂的圖像，所以我們利用圖片後製的方式將裂痕貼到鋼軌影像上，以人為方式製造出軌側缺失的圖片，如圖 9(a) 與 (b)。後製圖片的製作原則是將有裂縫的鋼軌圖片以繪圖軟體如 PhotoShop 等，複製裂縫的部份，貼在正常軌道構件上，並加以尺寸縮放與旋轉，或者改變裂縫的方向和粗細，不過這樣產生的圖片，是需要經過專業人士審查的。本研究以圖片後製所產生的軌側缺失圖片，均有經過臺中工務段大甲、苗栗、彰化等分駐所相關工作人員的確認，均一致認為相當接近真實狀況。

有鑑於構件辨識的目的是將有缺失的構件檢測出來，正常的構件一般無偵測的必要，於

是我們訓練時就以有缺失的側視構件加上容易混淆之正常構件進行訓練。表 6 為側視資料集樣本數之分佈狀況，缺失構件影像總張數為 961 張，資料集中所有照片均為較清晰無殘影版本，其中有增加部分人工圖片後製之缺失樣本，共 44 張。

表 5 側視軌道缺失構件分類

編號	構件分類	圖片	說明
1	鋼軌裂縫		軌腹裂痕
2	魚尾板裂縫		魚尾板、或螺栓處有裂痕
3	魚尾板螺栓脫落		螺栓脫落、空缺
4	魚尾板異物		道碴、雜草、或其他異物遮蔽軌腹



(a)



(b)

圖 9 人為製作之軌腹缺失種類

(a)人為圖片後製之鋼軌裂縫 (b)人為圖片後製之焊接點裂縫

表 6 側視資料集

編號類別	訓練數	測試數	總數量
1)鋼軌裂縫 (Rail_xx)	53	23	76
2)焊接處裂縫 (Rail_welding_xx)	35	17	52(26*)
3)焊接處 (Rail welding)	373	55	428
4)魚尾板裂縫 (Splice_bar_xx)	25	12	37(18*)
5)魚尾板螺栓脫落 (Splice_bar_x)	61	26	87
6)魚尾板 (Splice_bar)	247	34	281
合 計			961

*為人工圖片後製的張數。

4.2 AI 檢測模型訓練與辨識能力精進

本研究採用更快更準的 Scaled YOLOv4 與輕量級 YOLOv4 tiny、SSD 512/300，在檢出率、平均精確率、和辨識速度上，可再度提升。本研究所提 AI 的資料蒐集與標註，YOLO 模型的訓練與測試，如圖 10 所示，當完成測試時，即可用於實際的檢測系統。




圖 10 訓練資料集的建立與標註，YOLO 模型的訓練，以及實際使用流程

4.2.1 Scaled YOLOv4 and YOLOv4-tiny

表 7 先將神經網路模型評估所引出的指標混淆矩陣 (Confusion Matrix) 做一表列，以供後續參考，前面的 T(rue) 和 F(alse) 代表預測本身的結果是正確還是不正確的，而後面的 P(ositive) 和 N(egative) 則是代表預測的方向是正向還是負向的。當然我們希望 TP 和 TN 可以多多出現，而 FP 和 FN 可以盡量不要出現，因此這兩種狀況就稱之為 Error。

先以表 4 上視資料集為主，再加上陸續從大甲分駐所接收所錄影片，測試後辨識錯誤者如 FP/FN，再滾動式修正增加至原資料集，以 Scaled YOLOv4 模型進行訓練，結果如表 8 所示，精確率 Precision = 94%，檢出率 Recall = 91%，平均精確率 mAP = 94.47%。以 YOLOv4-tiny 模型進行訓練，結果如表 9 所示，精確率 Precision = 92%，檢出率 Recall = 91%，平均精確率 mAP = 91.7%，顯示結果也相差不遠，但是執行速度快了將近 7 倍多，在進行即時辨識相當有利。

表 7 神經網路評估指標

指標種類	準確率 Accuracy	精確率 Precision	檢出率 Recall
計算公式	$[TP+TN]/\text{全部資料總數}$	TP/模型預測結果為 positive 的總數	TP/真實資料為 positive 的總數
公式變形	$(TP+TN)/[TP+TN+FP+FN]$	$TP/[TP+FP]$	$TP/[TP+FN]$
中文解釋	預測結果皆正確 (包含 TP 與 TN)	模型預測結果為真 (TP+FP)，而真實資料為真的比率	真實資料為真 (TP+FN)，而模型預測為真的比率
重視之處	最經典的顯示模型的正確率	重視模型預測結果為真。	重視真實資料被預測為真。

表 8 Scaled YOLOv4 Confusion Matrix 上視訓練結果

e扣件缺失X,	ap = 71.88%	(TP = 9, FP = 2, FN = 5)									
e扣件缺失XX,	ap = 97.24%	(TP = 68, FP = 4, FN = 3)									
道釘缺失X,	ap = 97.37%	(TP = 36, FP = 0, FN = 2)									
道釘缺失XX,	ap = 100.00%	(TP = 16, FP = 2, FN = 0)									
軌面缺失X,	ap = 98.58%	(TP = 25, FP = 1, FN = 1)									
軌面缺失XX,	ap = 92.04%	(TP = 25, FP = 4, FN = 3)									
版式e扣件缺失X,	ap = 94.28%	(TP = 8, FP = 1, FN = 1)									
版式e扣件缺失XX,	ap = 100.00%	(TP = 11, FP = 2, FN = 0)									
其他錯誤,	ap = 100.00%	(TP = 5, FP = 0, FN = 0)									
元件被遮蔽X,	ap = 93.30%	(TP = 133, FP = 6, FN = 18)									
Recall rate(TP/TP+FN):0.91 Precision(TP/TP+FP):0.94 mAP:94.47%											
		<table> <tr> <th></th><th>辨識損毀</th><th>辨識正常</th></tr> <tr> <th>實際損毀</th><td>336(TP)</td><td>33(FN)</td></tr> <tr> <th>實際正常</th><td>22(FP)</td><td>X(TN)</td></tr> </table>		辨識損毀	辨識正常	實際損毀	336(TP)	33(FN)	實際正常	22(FP)	X(TN)
	辨識損毀	辨識正常									
實際損毀	336(TP)	33(FN)									
實際正常	22(FP)	X(TN)									

以辨識指標而言，若以 Recall rate 角度來看，Scaled YOLOv4 會是較佳的選擇，然而以 Precision 角度來看，Scaled YOLOv4 會是較佳的選擇，這也是意料中的，原本 YOLOv4 tiny 就是講究執行速度，犧牲些許精準度，辨識的指標當然會較低，不過在本研究，因為分類的數量不多，所以 YOLOv4 tiny 其實還是很有競爭優勢的，頂多是低 2 個百分點，卻可以在較低階的電腦環境中執行。

表 9 YOLOv4-tiny Confusion Matrix 上視訓練結果

e扣件缺失X,	ap = 58.38%	(TP = 8, FP = 2, FN = 6)									
e扣件缺失XX,	ap = 96.32%	(TP = 63, FP = 3, FN = 8)									
道釘缺失X,	ap = 96.90%	(TP = 35, FP = 1, FN = 3)									
道釘缺失XX,	ap = 97.25%	(TP = 16, FP = 3, FN = 0)									
軌面缺失X,	ap = 86.93%	(TP = 24, FP = 6, FN = 2)									
軌面缺失XX,	ap = 99.63%	(TP = 27, FP = 1, FN = 1)									
版式e扣件缺失X,	ap = 87.65%	(TP = 8, FP = 1, FN = 1)									
版式e扣件缺失XX,	ap = 100.00%	(TP = 11, FP = 2, FN = 0)									
其他錯誤,	ap = 100.00%	(TP = 5, FP = 0, FN = 0)									
元件被遮蔽X,	ap = 93.51%	(TP = 138, FP = 11, FN = 13)									
Recall rate(TP/TP+FN):0.91 Precision(TP/TP+FP):0.92 mAP:91.66%											
		<table> <tr> <th></th><th>辨識損毀</th><th>辨識正常</th></tr> <tr> <th>實際損毀</th><td>335(TP)</td><td>34(FN)</td></tr> <tr> <th>實際正常</th><td>30(FP)</td><td>X(TN)</td></tr> </table>		辨識損毀	辨識正常	實際損毀	335(TP)	34(FN)	實際正常	30(FP)	X(TN)
	辨識損毀	辨識正常									
實際損毀	335(TP)	34(FN)									
實際正常	30(FP)	X(TN)									

4.2.2 側視構件模型訓練

以表 6 側視資料集，包含人工圖片後製之缺失樣本，進行模型訓練，測試後辨識錯誤者如 FP/FN，再滾動式修正增加至原資料集，以增加缺失構件檢出率。訓練時大部分採用圖片後製之缺失構件照片，測試集盡量選擇實際照片。本研究以 YOLOv4-tiny 模型進行訓練，因為訓練時間較短，結果也還不錯，如表 10 所示，精確率 Precision = 96%，檢出率 Recall = 94%，平均精確率 mAP = 99.16%，驗證本系統的可行性，一些 AI 所偵測出的缺失構件，參見圖 11。

表 10 YOLOv4 tiny 側視訓練結果與 Confusion Matrix

焊接處裂縫,	ap = 100.00%	(TP = 7, FP = 9, FN = 0) Precision = 0.44									
魚尾板裂縫,	ap = 100.00%	(TP = 12, FP = 0, FN = 0) Precision = 1.00									
鋼軌裂縫,	ap = 100.00%	(TP = 37, FP = 0, FN = 1) Precision = 1.00									
魚尾鉸螺栓脫落,	ap = 96.15%	(TP = 26, FP = 0, FN = 0) Precision = 1.00									
焊接處,	ap = 98.82%	(TP = 73, FP = 0, FN = 12) Precision = 1.00									
魚尾鉸,	ap = 100.00%	(TP = 49, FP = 0, FN = 0) Precision = 1.00									
Recall rate(TP/TP+FN):0.94 Precision(TP/TP+FP):0.96 mAP:99.16%											
		<table> <tr> <th></th><th>辨識損毀</th><th>辨識正常</th></tr> <tr> <th>實際損毀</th><td>204(TP)</td><td>13(FN)</td></tr> <tr> <th>實際正常</th><td>9(FP)</td><td>X(TN)</td></tr> </table>		辨識損毀	辨識正常	實際損毀	204(TP)	13(FN)	實際正常	9(FP)	X(TN)
	辨識損毀	辨識正常									
實際損毀	204(TP)	13(FN)									
實際正常	9(FP)	X(TN)									




圖 11 YOLOv4-tiny 側視構件辨識實例

(a)左上：魚尾鉋斷裂(圖片後製) (b)右上：鋼軌斷裂(實際)
(c)左下：魚尾鉋斷裂(實際) (d)右下：正常焊接點，看起來像有裂縫(FP)

Rail_Welding_XX 有較多 FP，這些皆是正常的焊接處 (FP) 被誤判成焊接處裂縫，之後都會再加入到訓練集中，以降低誤判率。本次 Recall rate 稍有下降，是因為正常焊接處的 FN 較多，而這些 FN 都是在拍攝鋼軌外側時會連同後方內側軌道一起入鏡，後方軌道上所出現的焊接處因為影像過小 (遠)，因此沒辦法框到。

4.3 構件巡檢實測

缺失構件檢測的實測，以本案研究主題中所提，在臺鐵局臺中工務段轄管範圍內選定一鐵路軌道區線進行實測，驗證 AI 模型檢測系統所偵測的結果具有穩定性。實地拍攝至少 70 公里，大甲到大山來回：43.4km × 2 > 70km，三義到后里來回：13.5km × 2 = 27km。

4.3.1 YOLO v4 上視辨識

110 年 7 月巡檢大甲至大山路段共 13 部影片，檢測出 33 個 e_Clip 嚴重缺失，1 個道釘缺失，其中有 7 個 FP，精確率約為 80%，另於 8/13 測試了三義至后里正線路段來回，此區間樣本資料在系統內屬於很少蒐集的路段，影片內還包含數個隧道等設施，因此以 4.2 節之模型辨識缺失構件個數，參見表 11，其中三義-后里正線左 (右) 軌 1/2(3/4)，與后里-三義正線右 (左) 軌 6/4(5/1)，檢驗出一致的數量，顯示本系統具有穩定性，不致有劇烈變化。總共錄製 10 支影片，偵測出共 84 個 e_Clip_XX，其中誤判有 15 個，上視檢測精確率平均為 69/84=82.14%。

陸續再加入清水到臺中港路段資料後，重新訓練 AI 模型，希望能夠檢測出更多缺失，三義后里路段的影片經過重新測試，結果如表 12 所示，原模型辨識結果是➡左邊之數字，經過增加些許資料後重新訓練與辨識，新缺失構件個數是➡右邊之數字，()內數字是比原

AI 模型多找出的缺失構件個數，總計有 31 個原本是 FN 的 e_Clip_XX 嚴重缺失被偵測出來。

另外此次重新調整資料集後，因為每個類別在框選時都更加嚴格，才能夠偵測到更多缺失，但也會提高誤判的數量，之後會直接將這些誤判照片加入資料集當成背景訓練，來降低整體之誤判率。其中 FPpkm= FP per km = 764 FP/135km=5.6，雖然增加 764 個 FP，但是 FN 多了 31 個，算是值得。

表 11 山線實測上視檢測結果

路段影像	檔名	e 扣件-XX 嚴重損壞	實際 缺失	誤判 (FP)	精確率
三義-后里正線左軌 1	GH010036.MP4	4	2	2	2/4=50%
三義-后里正線左軌 2	GH020036.MP4	2	1	1	1/2=50%
三義-后里正線右軌 3	GH013972.MP4	17	16	1	16/17=94.1%
三義-后里正線右軌 4	GH023972.MP4	1	1	0	1/1=100%
后里-三義正線左軌 1	GH020038.MP4	0	0	0	—
后里-三義正線右軌 4	GH013973.MP4	2	1	1	1/2=50%
后里-三義正線左軌 5	GH023972.MP4	18	18	0	18/18=100%
后里-三義正線右軌 6	GH033973.MP4	1	1	0	1/1=100%
后里-三義正線左軌 2	GH010037.MP4	8	4	4	4/8=50%
后里-三義正線左軌 3	GH010038.MP4	31	25	6	25/31=80.6%
總計		84	69	15	82.14%

表 12 較嚴謹之 AI 模型山線實測上視檢測結果(→右邊數字)

路段影像	檔名	e 扣件-XX 嚴重損壞	實際缺失	誤判(FP)	FPpkm
三義-后里左軌 1	GH010036.MP4	4→275	2→5(+3)	2→270	270
三義-后里左軌 2	GH020036.MP4	2→32	1→1	1→31	31
三義-后里右軌 3	GH013972.MP4	17→50	16→16	1→35	35
三義-后里右軌 4	GH023972.MP4	1→3	1→1	0→2	2
后里-三義左軌 1	GH020038.MP4	0→2	0→0	0→2	2
后里-三義右軌 4	GH013973.MP4	2→20	1→1	1→19	19
后里-三義左軌 5	GH023972.MP4	18→53	18→28(+10)	0→25	25
后里-三義右軌 6	GH033973.MP4	1→182	1→5(+4)	0→177	177
后里-三義左軌 2	GH010037.MP4	8→61	4→5(+1)	4→56	56
后里-三義左軌 3	GH010038.MP4	31→185	25→38(+13)	6→147	147
總計		84→863	69→100(+31)	15→764	764/135→5.6

4.3.2 YOLOv4-tiny 側視辨識

側向缺失構件檢測相對比較難驗證，因為實務上很少有鋼軌裂縫的情形發生，我們一則以喜，一則以憂；喜的是臺鐵局的軌道檢測很嚴謹，都無嚴重的軌側裂縫，憂的是本研究 AI 模型偵測得出的都是偽陽性 (FP)，因此準確率為 0，所以我們能做的就是盡量減少 FP 的個數。

表 13 將所有后里-三義路段往返所錄得的影像全部用來測試，之前的誤判很多都是魚尾銼和焊接處，更新權重後幾乎沒有再誤判這兩個類別 (只有零星一兩個)，大多數的誤判都是在鋼軌裂縫這類別，但誤判之圖片大多都是跟大甲在驗證 AI 模型時所製作的鉛膠帶、奇異筆等記號或是樹枝極為相似，如圖 12 是從三義后里路段所辨識出來極為相似的斷軌

表 13 AI 模型的側向檢測結果

路段影像	檔名	嚴重損壞	誤判	每公里 FP 個數 FPpkm
后里-三義左軌外側	GH050283.MP4	0→0	0	0
后里-三義左軌外側	GH040283.MP4	0→0	20	1.48
后里-三義左軌外側	GH030283.MP4	0→0	45	3.34
后里-三義左軌外側	GH020283.MP4	0→0	10	0.74
后里-三義左軌外側	GH010283.MP4	0→0	2	0.15
后里-三義左軌內側	GH012838.MP4	0→0	442	32.7
后里-三義左軌內側	GH012837.MP4	0→0	37	2.74
后里-三義左軌內側	GH022838.MP4	1(疑似)→0	0	0
后里-三義右軌外側	GH033081.MP4	0→0	25	1.85
后里-三義右軌外側	GH023081.MP4	0→0	11	0.81
后里-三義右軌外側	GH013081.MP4	0→0	5	0.37
后里-三義右軌內側	GH032788.MP4	0→0	59	4.37
后里-三義右軌內側	GH022788.MP4	0→0	181	13.4
后里-三義右軌內側	GH012788.MP4	0→0	21	1.56
三義-后里左軌外側	GH030282.MP4	0→0	3	0.22
三義-后里左軌外側	GH020282.MP4	0→0	4	0.3
三義-后里左軌外側	GH010282.MP4	0→0	2	0.15
三義-后里左軌內側	GH022836.MP4	0→0	45	3.34
三義-后里左軌內側	GH012836.MP4	0→0	181	13.4
三義-后里右軌內側	GH022787.MP4	0→0	14	1.04
三義-后里右軌內側	GH012787.MP4	0→0	76	5.63
三義-后里右軌外側	GH013080.MP4	0→0	23	1.7
三義-后里右軌外側	GH023080.MP4	0→0	13	0.96
總 計			1219	1219FP/(23*13.5km)=3.9



圖 12 偽陽性誤判實例，因與訓練集的正樣本非常相似。

影像。實地測驗結果計算每公里誤判數 (FPpkm) = 總 FP 數 / (13.5 * 23) = 1219 / 310.5 = 3.9 個 FP/km，算是可以大幅減低人力負擔。

4.4 手機查詢與定位




圖 13 手機操作介面。

(a)登入。(b)查詢。(c)構件位置。(d)現在位置。(e)路線。(f)終點與構件距離。

為方便巡檢起見，手機 APP (Application Program) 是最方便的使用方式，查詢與定位是最重要的部分。本 APP 操作介面與版面配置也與一般網頁一樣，先進行權限設定如圖 13(a)，可適用於有 GPS 的裝置上，再來是使用的情境，先在地圖標示圖 13(b) 缺失構件位置，再來是圖 13(c) 本人位置，接著是巡檢路線圖 13(d)，接下來是圖 13(e) 路線終點與扣件距離。

4.5 AI 作業程序運作情形

為順利將自動巡檢系統移轉至臺鐵局運行，本研究先借 1 台 AI 伺服器給大甲分駐所，提供每次巡檢後的自動檢測，期間系統操作方式與整體運作，需要訂定一作業程序，以便有所遵循。茲條列如下：

1. [外業]以平車進行軌道構件攝影，設備安裝方式參見 3.2 節；外業運作方式依臺鐵各工務段自行調整運作方式進行，本研究僅著重設備安裝原則。
2. [以下為內業]透過網路或是 USB 連線，上傳至後端伺服器，進行缺失構件偵測。
3. 開工作會議，檢視報表，討論哪些是真實缺失 (True Positive)。
 - 假性缺失 (False Positive)，可將之剔除；
 - 人力檢視錄影檔，找出 False Negative，進行資料增強，將依照類別新增至構件資料集。
 - 啟動訓練機制，提出軌道構件 (扣件、軌面及軌腹) 缺失召回率 (Recall rate) 及精確率 (Precision)，檢視各項數據是否精進。
 - 更新構件辨識的 AI 模型權重檔。
4. 安排維修期程
5. 手機 APP 定位
6. 更新報表與資料庫

系統於 110 年 8 月初運行至今，大甲分駐所成員也已熟悉系統操作方式，並可據以維修缺失構件，若系統操作介面不符使用，本研究也依臺鐵局需求更新操作介面，如圖 14，逐漸變成日常生活的一部分。

五、結論與建議

傳統鐵路軌道構件巡檢方式係採用人工，以目視方式進行巡檢，而人工目視巡檢受限於巡檢車速及視察角度等問題，至今並無法有效快速進行，因此希望能利用人工智慧方式來協助完成巡檢任務，本研究則提出一個全方位軌道構件巡檢系統，包括上視構件和軌腹構件，較之前相關研究要完整，且檢測速度與精度均提昇許多，本節則做個結論以及建議未來之精進方向。



圖 14 伺服器操作介面更新，記錄維修與否。

5.1 結論

本研究主要完成精進軌道構件攝影及照明設備等影像擷取系統，在時速 30 公里拍攝時，可達到系統穩定、長時間拍攝及影像即時辨識之目的，除可在軌道正上方拍攝外，另進行軌道側向拍攝，之前側視攝影模糊，已調整高度與角度，並尋找更適合之燈具，已經多次測試並進行實測，總錄影片數超過 50 部，每部約 1~2 小時。

目前所建置軌道構件 (扣件、道釘、軌面、魚尾銼、與軌側) 資料庫，上視攝影有 10 類構件，側視攝影有 6 類構件，經人力目視挑出 3800 張上視缺失構件，與 539 張側視缺失構件，再加上相當之正常照片構成基本訓練資料集。訓練結果上視以 YOLOv4 模型得到 mAP 94.47%，執行速度可達 20fps，以 YOLOv4-tiny 模型得到 mAP 91.66%，執行速度更高達 150 fps。至於側視則以 SSD512 模型得到 mAP 99.98%，執行速度可達 22fps，以 YOLOv4-tiny 模型可得到 mAP 99.16%，執行速度也是 150 fps。

接著完成軌道構件缺失即時辨識系統、雲端辨識伺服器、手機巡檢 APP 之改版與精進，並在實驗場域實測，包括海線大甲~大肚 (67.5km*2)，山線三義~后里 (13.5km*2)，進行實地巡檢。首先進行 PK，先以人工製作 Ground Truth 缺失構件，包括上視 13 個缺失構件，側視 9 個缺失構件，以人工徒步巡檢各檢出 15 與 5，而 YOLOv4 則各檢出 14 與 8，顯示 AI 檢測準度與速度均優於人工巡檢。

最後進行實地測試，在三義至后里區段進行 10 趟上視測試，AI 辨識精確率 83.3%，

23 趟側視測試，AI 辨識精確率無法計算，因為無真實軌側缺失構件，所以改用 FP/km 當作檢測指標，結果為 5.6 個/km，也的確可以大幅減輕人力負擔。目前實地拍攝（上視+側視）里程已超過 70 公里，並以 YOLOv4/YOLOv4-tiny/SSD 完成測試，效果比研究^[3]更好，達成辨識系統精進目標。但是部分缺失構件如軌面裂縫、軌側裂縫、魚尾鉸裂縫等訓練資料集尚缺，有一半是圖片後製，與真實的軌道缺失應該是有些許差異的，雖然有經過臺中工務段維修人員的認可，未來仍將力求圖片後製盡量的接近真實狀況，以因應實際所需。本研究亦完成在同一軌道段，進行多次實地拍攝，比較其精確率及誤判率變化情形，顯示變動都不大，確實有一定的穩定度。

最後本研究訂定作業自動化程序，讓業務單位依序執行，巡檢軌道構件影像拍攝後，即可上傳雲端辨識伺服器，檢視輸出報表後，即可以手機查詢缺失影像及定位搜尋之現場維修應用，若有 FP 或 FN，則將此二類缺失影像新增至訓練資料集，重新訓練後並更新 AI 模型權重檔，目前在大甲分駐所已運作順利，較人力方式增進軌道巡檢精確度與速度，持續此運作，未來 AI 巡檢將越來越精準，與越來越節省時間。為推廣本研究成果，也舉辦教育訓練，說明巡檢自動化對鐵路管理機關之質化與量化效益。

5.2 建議與未來工作內容

目前建立具可擴充性的軌道構件缺失辨識準則與資料庫，以 YOLOv4/tiny/SSD 進行訓練，結合前端影像收集、影像處理及前後端影像分析與辨識，建立一套具實用價值的軌道構件判釋解決方案，並經實際正線測試驗證其可行性。其成本效益，未來可大量減輕道班工作人員之工作負擔，並可減少人力之支出，減輕經濟成本的壓力，期望能有效疏解目前臺鐵局基層鐵路巡檢人力不足之問題。

雖然透過 AI 技術的導入，對於辨識結果有頗高之正確率，然 AI 模型仍免不了會有誤判之情形：一是好的構件被誤認為缺失構件 (FP, False Positive)，這是誤殺，會增加維修人員負擔，但不會增加安全風險；另一種情況是缺失構件未被發現 (FN, False Negative)，這是誤放，未能即時檢修，此情形雖會發生，但是已經比人工巡檢要少發生。任何 AI 系統無法保證 100%無誤，但是只要能比現有作法要好，同時搭配持續學習，將此 FN 學習並辨認出來，對於推廣本研究成果將有很大吸引力。

後續工作內容包括：

1. 持續蒐集訓練資料，須以人力針對影像內容進行驗證 (Verify) 處理，將目前所錄製路段的缺失構件統計出來，以維護鐵道安全。持續增加缺失樣本以供訓練，可以增強本系統的辨識能力；也建議在側線製作接近真實之缺失樣本，或以圖片增強(Data Augmentation)方式複製真實缺失構件。未來將徵求工讀生協助進行標記工作，以期持續檢視資料，增加資料集。
2. 軌道巡檢的 SOP 作業處理機制，以本系統輔助缺失構件的檢測，進行後續的構件缺失辨識系統精進，依臺灣鐵路管理局實務執行情形，持續精進系統的辨識精度、功能與標

準操作程序。

3. 未來將與大甲分駐所詢問雲端網站增加之功能的介面設計，以切實用，例如增加彙整總表等功能。
4. 未來將朝模組化設計，以解決設備安裝與拍攝問題；另外定位將換更佳之 IMU 產品。

參考文獻

1. 曹悅華，「鋼軌裂縫」，取自 <https://udn.com/news/story/7266/5160558>，查詢日期：2021 年 1 月 12 日，聯合報。
2. Forbes, “How Swiss Federal Railways Is Improving Passenger Safety with the Power of Deep Learning”, <https://www.forbes.com/sites/nvidia/2018/08/02/how-swiss-federal-railway-is-improving-passenger-safety-with-the-power-of-deep-learning/?sh=4719312d50e3>, 2018.
3. ENSCO, “Rail Surface Imaging System”, <https://www.ensco.com/rail/track-imaging-systems>, Retrieved Jan 19, 2020.
4. Pavemetrics, “Laser Rail Inspection System (LRAIL),” Canada, <http://www.pavemetrics.com/applications/rail-inspection/laser-rail-inspection-system/>, Retrieved Jan 14, 2019.
5. BvSys Bildverarbeitungssysteme, “Visual Inspection Systems for Track Maintenance,” <https://www.railway-technology.com/contractors/track/bvsys/>, Retrieved Jun 18, 2020.
6. Mermec, “Fishplate/Joint bar Inspection”, <http://www.mermecgroup.com/inspect/track-inspection/65/fishplate-joint-bar.php>, Retrieved Jan 14, 2021.
7. 臺北捷運公司，「TRTC 臺北捷運北投機廠軌道檢查車 EM-80E」，<https://www.youtube.com/watch?v=JqEQARYCkag>，查詢日期：2020 年 6 月 18 日。
8. 侯衛星，**0 号高速综合检测列车**，中國鐵道出版社，北京，民國 109 年。
9. Yang, C., Sun, Y., Ladubec, C., and Liu, Y., “Developing Machine Learning-Based Models for Railway Inspection”, Applied Sciences, Vol.11, Iss.1, 2021, <https://doi.org/10.3390/app11010013>.
10. Gibert, X., Patel, V. M., and Chellappa, R., “Deep Multitask Learning for Railway Track Inspection”, IEEE Transactions on Intelligent Transportation Systems, Vol.18, Iss.1, 2017, pp. 153-T 164.
11. Ashish, J., Wang, J., Ye, C., Nguyen, B. N., Lou, Y., Su, Y., Vijay, C., Zeng, Z., “TrackNet -T A Deep Learning Based Fault Detection for Railway Track Inspection”, 2018 International Conference on Intelligent Rail Transportation (ICIRT), pp.1-5, doi: 10.1109/ICIRT.2018.8641608, 2018.
12. Song, Q., Guo, Y., Jiang, J., Liu, C., and Hu, M., “High-T speed Railway Fastener Detection and Localization Method based on Convolutional Neural Network”, arXiv:1907.01141v2 [cs.CV], <https://doi.org/10.48550/arXiv.1907.01141>, 2019.
13. S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-T CNN: Towards Real-Time Object Detection with Region Proposal Networks”, arXiv:1506.01497, <https://arxiv.org/abs/1506>.

01497, 2015.

14. 交通部運輸研究所，「軌道扣件巡檢系統建置(1/2)：扣件缺失辨識系統建置研究」，民國 109 年。
15. 交通部運輸研究所，「軌道扣件巡檢系統建置(2/2)：扣件缺失辨識系統精進驗證」，民國 110 年。
16. J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement”, arXiv:1804.02767, <https://doi.org/10.48550/arXiv.1804.02767>, 2018.
17. A. Bochkovskiy, C. Y. Wang, and H. Y. Mark, “YOLOv4: Optimal Speed and Accuracy of Object Detection”, arXiv:2004.10934, <https://doi.org/10.48550/arXiv.2004.10934>, 2020.
18. W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Y. Fu, and A. Berg, “SSD: Single Shot MultiBox Detector”, Lecture Notes in Computer Science, 2016, pp. 21–37.
19. C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, “Scaled-YOLOv4: Scaling Cross Stage Partial Network”, arXiv:2011.08036v2 [cs.CV], <https://doi.org/10.48550/arXiv.2011.08036>, 2020.
20. G. Jocher, “YOLOv5”, <https://github.com/ultralytics/yolov5>, Retrieved May, 2020.
21. Z. Jiang, L. Zhao, S. Li, and Y. Jia, “Real-time Object Detection Method based on Improved YOLOv4-tiny”, arXiv:2011.04244 [cs.CV], <https://arxiv.org/abs/2011.04244v2>, 2020.
22. M. Tan, R. Pang, Q. V. Le, “EfficientDet: Scalable and Efficient Object Detection”, arXiv:1911.09070 [cs.CV], <https://doi.org/10.48550/arXiv.1911.09070>, 2020.
23. Chien-Yao Wang, Hong-Yuan Mark Liao, I-Hau Yeh, Yueh-Hua Wu, Ping-Yang Chen, and Jun-Wei Hsieh, “CSPNet: A New Backbone that can Enhance Learning Capability of CNN,” arXiv: 1911.11929 [cs.CV], <https://doi.org/10.48550/arXiv.1911.11929>, 2019.

