

軌道扣件缺失辨識系統精進研究

謝禎岡	大同大學資訊工程系教授
林雅雯	交通部運輸研究所臺灣技術研究中心科長
謝尚琳	大同大學資訊工程系副教授
黃維信	大同大學媒體設計系教授
洪瑋宏	大同大學資訊工程系研究生
杜宇豪	大同大學資訊工程系研究生
賈漢文	大同大學資訊工程系研究生
徐倜雲	大同大學資訊工程系研究生

摘要

軌道扣件可將鐵軌緊扣在軌道上，對於列車能否平穩及安全的行駛影響至鉅。本研究建立軌道扣件影像的收集設備，依收集之軌道扣件資料，透過影像標記處理，採用 YOLOv4(You only look once)演算法進行深度學習模型訓練，再從測試資料驗證扣件缺失召回率，109 年實驗共錄製 70 公里軌道扣件影像，在 108 年以 YOLO v3 驗證，扣件準確率(Precision rate)為 82.5%，扣件缺失召回率(Recall rate)為 74.5%，109 年計畫採用 YOLOv4，訓練方式由原扣件正常資料，改用扣件缺失資料，扣件缺失召回率提升至 87%，類別平均準確率(mAP)提升為 94.8%，辨識系統速度超過 55 張/秒。為方便軌道巡檢人員尋找扣件，本研究另開發雲端儲存、辨識、與手機 APP 查詢，GPS/陀螺儀定位等功能，可於 Google Map 顯示鐵路里程樁號(每百公尺)，定位缺失扣件位置，方便檢修人員尋修，提升維管效能。

一、前言

人工巡檢目的為確保扣件的正常運作，依據「1067 公厘軌距鐵路長焊鋼軌鋪設及養護規範」[1]所訂內容「軌道扣件之巡查若有其他更有效率之巡檢方式，

得降低人工巡檢頻率，但人工巡檢頻率不得低於二個月一次」。傳統鐵路軌道扣件係採用人工目視方式進行巡檢，受限於巡檢車速及視察角度等問題，無法有效快速進行，因此希望利用人工智慧(Artificial Intelligence, AI)方式協助完成巡檢任務，有效提升巡檢效率，降低巡檢人員視察局限等問題。

本研究 108 年計畫已透過收集之軌道扣件影像資料，進行影像標記處理，並使用 YOLO v3 進行深度學習模型訓練，再從測試資料驗證扣件缺失召回率，建立一套扣件影像巡檢自動辨識系統，用以檢測軌道扣件是否脫落。本研究持續精進系統功能，影像擷取採用運動型攝影機 GoPro 最新型式進行拍攝，錄製 70 公里軌道扣件影像，扣件辨識率及扣件缺失召回率可達到軌道扣件影像辨識檢測的目的。另開發雲端儲存、辨識、與查詢及定位等功能，可上傳扣件影像進行辨識與查詢結果，方便檢修人員尋找缺失扣件，除在 Google Maps 上顯示鐵路里程樁號(每百公尺)，更利用 GPS 座標及里程定位缺失扣件，方便檢修人員進行維護。

二、文獻回顧

瑞士電子和微技術中心(Swiss Center for Electronics and Microtechnology, SCEM)[4] 採用深度學

習技術，每個月檢查 3,800 公里的軌道，記錄不同天氣條件（如下雨、下雪及結冰）及非軌道物件（如樹葉、泥土等）的影像資料。透過訓練模型檢測影像目標區域（如鐵軌、扣件等），利用「生成對抗網路」（Generative Adversarial Network, GAN）辨識軌道構件，並將約 20 種不同的故障類別濃縮為 5 大類（如焊接、接頭、表面缺陷、踏面擦傷、車輪滑移）。

美國 ENSCO 公司鐵路成像系統，利用高解析度相機系統和先進影像處理演算法，使系統具有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構件的檢測^[5]，包括魚尾鉋、枕木、扣件、軌面、電車線及軌道通行權（Right of Way, ROW），影像擷取判斷分析系統可以晝夜運行。

加拿大 Pavemetrics 公司的 Laser Rail Inspection System（LRAIL）^[6]全方位軌道檢測系統，可架設在改裝的車輪上或是火車頭前，其全自動鐵路檢查對象包括木枕木、混凝土枕木、扣件檢測、鋼軌踏面缺失、鋼軌接頭檢測等。

德國 bvSys 公司^[7]的鐵路自動檢測系統，可在不影響軌道交通的正常運作下，精確的執行軌道缺陷檢測及影像高速處理，此外，系統亦提供定期的軌道檢查，可用於自動檢測軌道表面可見的異常、扣件遺失、混凝土軌枕破裂或損壞，以及測量道碴輪廓等。高性能線掃描攝影機和雷射測距儀垂直安裝在軌道上方，用於巡檢軌道兩側、軌枕指定區域和道碴。

義大利 MERMEC^[8]公司，其軌道魚尾鉋（或鋼軌接頭桿）檢測系統能夠自動檢測任何裂紋、劃痕或任何其他缺陷。該系統能夠達到時速 320 公里下的檢查，其對象包括魚尾鉋缺失螺栓及裂紋的自動檢測。

三、扣件缺失辨識系統精進

本研究採用高速影像攝影機搭配足夠輔助照明，透過 HDMI、USB、LVDS 或是無線網路等介面，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，而定位功能，則以 GPS（非隧道段）及陀螺儀（隧道段）方式標示出問題扣件或軌面所在的軌道範圍。

影像辨識的深度學習模型，本研究前期計畫採用 YOLO v3^[9]，雖然 YOLO v3 辨識速度快，可達 155 fps，但會有 mAP 降低及定位不準的問題。109 年計畫採用 YOLOv4^[10]模型，其使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。回顧影像辨識的發展史，從 R-CNN 到 Faster R-CNN^[11]，再到並駕齊驅的 YOLO 和 SSD^[12]，影像辨識的發展在 2015~2016 年達到了一個巔峰，更在 2020 年 YOLOv4、YOLOv5^[13]亦相繼的出現，因兩者檢測率以 YOLOv4 為最佳，而 YOLOv5 未獲官方承認，在維護上較有疑慮，因此，本計畫採用 YOLOv4。

3.1 平車改進




圖 1 第二代平車

使用平車的方式進行軌道扣件拍攝，將來容易複製到其他維護單位使用，本研究將 108 年平車進行改良，第二代的平車如圖 1 所示，將攝影桿架改為四個支柱，每一支柱與平車固定處墊橡皮墊，

以達到減震效果，達到穩定長時間拍攝及即時辨識的目的。

3.2 高速影像攝影機之選用

為了在列車高速行駛的狀況下依然能夠取得清晰的影像資料，故採用高速影像攝影機。相較於傳統攝影機，高速影像攝影機提供每秒 60 張(每秒顯示張數，Frame per Second，FPS)以上的拍攝速度，以 120km/hr 的行駛速度作為預期的環境狀況，若每張拍攝範圍為 0.5m，則需要每秒拍攝 67 張相片。但若以夜間臺鐵局工程維修車時速約 30km/hr 為使用條件，高速影像攝影機足以達到需求。另外，考量外部環境的狀況，選用的高速影像攝影機須具備防水、防震及可遠端連線控制。

以往對於軌道巡查採用的攝影機以「線掃描相機」(Line Scan Camera)為主，如高速數位式攝影機 E2V 廠牌之 AViiVA UM4(掃描解析度為 8,192 pixels、資料產生頻率為 160MHz、掃描頻率為 19KHz)，並搭配資料儲存之 DVR (數位錄影機，Digital Video Recorder)使用。一般而言，此類「線掃描相機」視硬體規格價錢約 3、5 萬至 20 餘萬。

隨著硬體的進步，目前運動型錄影機的功能大幅提昇，只要每秒拍攝的幀數能滿足取樣頻率，影像直接儲存在記憶卡中或是透過無線網路直接回傳，可大幅降低設備費用。



(a)



(b)

圖 2 軌道扣件攝影(a)GoPro7(較模糊)。(b)GoPro8(較清晰)。

由於 GoPro 運動型攝影機是以極限運動的拍攝為主，因此特別強調手持防震技術，並有 GPS 記錄功能，經評估足以進行軌道扣件拍攝。前期採用是 GoPro Hero7 Black，本研究升級為 GoPro Hero8 Black 機型，官網訊息顯示 GoPro Hero8 Black 的散熱效果比 GoPro Hero7 Black 好。此外，GoPro 周邊配件相當完整，若要將其固定於工程維修車，可依需求選用適當的配件。圖 2(a)和圖 2(b)顯示，GoPro8 拍攝影像較 GoPro7 為清晰。

3.3 即時前端辨識

YOLO v4^[10] 屬於 One-Stage 的 Object Detection 演算法，但是 FPS 及 AP(average precision)都超越 Two-Stage 演算法。目前在 Tesla V100 的 GPU 上，使用 MS COCO 資料集，可達到約 65 FPS 及 43.5% AP，表現較 R-CNN 佳。YOLO v4 與其他 AI 模型之比較，如圖 3 所示。




圖 3 YOLO v4 與其他 AI 模型效能比較

假設列車以時速 60 公里進行辨識，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，本計畫需同時進行兩個攝影機畫面的同時輸入處理並同步顯示，即為需要兩倍的執行速度，即每秒辨識 34 張照片(或 0.029 秒內完成單張圖片)的處理。

本研究採用執行緒(Thread)改寫程式，為作業系統能夠進行運算排程的最小單位，也就是平行處理。多執行緒可以最有效利用電腦性能，但並非越多越快，如進行執行緒個數實測，發現作業系統與電腦硬體需要透過切換才能存取不同程式的資料 (Context Switching)，在傳輸資料時，等待資料的過程將產生內部延遲。實測結果如圖 4 所示，採取 3 個執行緒處理是效能較佳的作法。




圖 4 執行序個數實驗測試

為達到每張相片 0.029 秒之即時辨識，在不影響辨識結果下，本研究將影像解析度由原本 608×608 降為 416×416 ，即時辨識效能時間分析，如表 1 所示，辨識部分，建議以 nVidia 人工智慧加速卡為必要配備。加速卡處理資料須將資料自主記憶體複製至顯示卡記憶體內，處理完後再將結果複製回主記憶體，加速卡以批次方式處理資料，在處理大量資料的情況下有優勢，但如將單張圖片依序傳入，則效能優勢則較不凸顯（仍比 CPU 快），由此可得知主要耗時於辨識影像上，如欲加快即時模式的影像處理，仍應調整模型，並降低資料傳輸量。

表 1 即時辨識效能時間分析

解析度	608x608	416x416
檢測階段	6.32 秒	6.32 秒
啟動攝影機	2 秒	2 秒
雙攝影影像處理	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
完整一次辨識流程	0.05 秒	0.033 秒



圖 5 即時辨識程式流程




圖 6 採 3 個執行緒處理流程

原本辨識程式流程如圖 5 所示，經實測有其使用瓶頸，因此調整前端程式架構與流程，採用 3 個執行緒處理方式，分別為攝影機、辨識與顯示介面，辨識程式流程如圖 6 所示。其中已加入攝影機意外斷線時的糾錯，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。

於攝影機控制功能新增 1 個檢測函數，用於測試使用的影像來源是否可以達到指定的解析度與快門速度，影像來源函式目前可自動依據多線程或一般使用需求解析輸入參數。影像來源函式目前的輸出格式具有 BGR 與 RGB 兩種模式，轉換模式基於記憶體陣列轉換，影像來源函式的縮小函數從雙線性插值改為像素區域關係進行重採樣(resampling)。監視介面與圖片辨識功能進行拆分，如此，介面不再因辨識速度導致更新緩慢。

程式運行加入了 Signal 檢查，非正常關閉主程式時能自動將多執行緒的其它子程序一併關閉及控制辨識速度，為維持即時結果的呈現速度，系統將在面臨資源不足時套用控制，即略過部分輸入或縮小結果呈現時所顯示的影像。調整影像解析度對於召回率的影響，如表 2 所示。另電腦硬體因為連續運作，導致溫度上升，因此，必須考慮散熱功能。

表 2 調整影像解析度對於召回率的影響

	解析度 416*416	解析度 320*320
FPS	55.77	69.87
準確率	0.948	0.901
召回率	0.87	0.84
TP	130	125
FP	24	22
FN	19	24
閾值	0.5	

四、缺失辨識準則與資料庫建立

軌道扣件缺失分類如表 3 所示，將 e 扣件與道釘分為輕微缺失(X) (如圖 7 所示，e 扣件鬆脫外移)和嚴重損壞(XX) (如圖 8 所示，e 扣件遺失或斷裂)。

軌道扣件缺失分類由 108 年 11 類修正為 6 類，主要原因為滑床板、護軌墊板在實際應用中較少缺失，亦未收集到缺失樣本，故不列入辨識對象，另 e-Clip 斷裂需要改列為嚴重明顯損壞(XX)，而扣件遮蔽亦單獨列為一類。

表 3 軌道扣件缺失分類

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
10	版式 e 扣件缺失 XX		扣夾遺失、斷裂 螺栓遺失




圖 7 扣件較輕微之不明顯損壞 (e 扣件缺失 X)，稍微突出。




圖 8 扣件較嚴重明顯之損壞 (e 扣件缺失 XX)，完全脫落。

缺失扣件資料集由原本 3,800 張增加為 5,600 張(4,480 張訓練+ 1,120 張測試)，來源為 108 年計畫及本期 109 年 4 月 11、4 月 19 日、9 月 19 日所拍攝相片，取出 GoPro 7/8 所攝得或利用手機

以相同角度與解析度拍攝所有缺失的扣件照片。

軌面缺失辨識種類以鋼軌裂縫及踏面不整（魚鱗剝落現象）為主，並將軌面缺失納入缺失扣件資料庫，如表 3 的第 7 及 8 項，與其它缺失扣件一併進行 YOLO 訓練與辨識。

五、模型訓練與實地驗證

5.1 模型訓練

本研究使用遷移學習 (Transfer Learning)，將模型由原本 YOLOv3 改為以最新的 YOLOv4⁽¹⁰⁾來訓練與辨識，一般來說，Two-Stage(R-CNN、Faster R-CNN)AP(Average Precision)較高，但相對的 FPS 表現會較低。實驗顯示模型從 CSPResNet 遷移至 YOLOv4，速度提升約 15%，辨識率維持原先網路等級，雖然 Recall Rate 降低，但是 Over Kill(誤殺)的比率亦降低，如表 4 所示。測試結果，真陽性 TP 為 511 個，偽陽性 FP 為 117 個，偽陰性 FN 為 20 個，正確率為 0.81，召回率為 0.96，平均正確率為 86.8%，顯示有良好辨識效果。

表 4 YOLO v4 Confusion Matrix 與辨識結果

		辨識損毀	辨識正常
實際損毀	Recall rate=TP/(TP+FN)=0.96	511(TP)	20(FN)
實際正常	Precision=TP/(TP+FP)=0.81	117(FP)	X(TN)

- eclip_break_x : AP=99.82% , Precision=96% , Recall=100%
- eclip_break_xx : AP=99.15% , Precision=97% , Recall=100%
- railspike_break_x : AP=91.94% , Precision=68% , Recall=94%
- railspike_break_xx : AP=99.06% , Precision=74% , Recall=100%
- others_break : AP=68.39% , Precision=61% , Recall=58%
- covered : AP=92.99% , Precision=78% , Recall=96%
- rail_break_x : AP=100.00% , Precision=100% , Recall=80%
- rail_break_xx : AP=100.00% , Precision=68% , Recall=100%
- Slab_track_eclip_break_x : AP=28.00% , Precision=25% , Recall=50%
- Slab_track_eclip_break_xx : AP=88.81% , Precision=67% , Recall=100%

5.2 扣件缺失辨識系統實地驗證

實驗區段位於臺鐵局臺中工務段某鐵路軌道區，隨機於路段上製作缺失扣件，於維修車上同時進行人工目視巡檢及 GoPro7/8 錄影 AI 辨識。

人工搭乘工程維修車以時速 5 公里目視檢測，發現有 52 個缺失（平時軌道扣件巡檢時速為 30 公里），AI/GoPro7 系統以時速 30 公里檢測出人工檢測報告中的 46 個缺失，其中額外找出了不在人工檢測報告內的 7 個缺失扣件，此 7 個缺失扣件分類皆為 e-Clip 扣件嚴重缺失(XX)。

本研究 AI 影像辨識出人工目視巡檢 52 個軌道扣件缺失中之 46 個缺失，因此 Recall Rate= $46/52=88\%$ ，但 AI 影像辨識出比人工目視巡檢多 7 個缺失扣件，證實本系統確實可以輔助人工目視巡檢。

實際影片辨識結果，還有 2 個誤報，以及未訓練過的缺失扣件 5 個，為道叉處的扣件，因為鐵板上之 e-Clip 脫落，所以被辨識出來。所謂「未訓練過扣件」，即是本系統未曾訓練過的缺失扣件，但卻能被偵測出是缺失的扣件，因此 AI 針對不同背景之 e-Clip 亦能辨識。

六、結論

本研究採用 YOLO v4，訓練方式由原扣件正常資料改用扣件缺失資料，扣件缺失召回率提升至 87%，類別平均準確率提升為 94.8%，辨識系統速度更高達 55 張/秒，並經實際於鐵路正線上測試驗證其可行性。

AI 人工智慧辨識扣件缺失，可大量減輕道班工作人員之工作負擔，並減少人力支出，節省經濟成本，期望能有效疏解目前基層鐵路巡檢人力不足之問題。建議未來持續改善工作內容包括：

1. 訓練資料建立

持續增加缺失樣本以供訓練使用，可以增強本系統的辨識能力。未來將訓練人員協助進行標記工作，以期能加快資料處理速度，並將現有辨識結果中辨識錯誤者進行探討，若屬 FP 誤殺，則新增此負樣本，若屬 FN 誤放，就必須透過人工將整個影片看過，才找得出來正樣本，譬如鋼軌裂縫等重大軌面缺失，雖須透過大量人力進行影像內容驗證處理並統計目前所錄製路段的缺失扣件，但為維護鐵道行駛安全，必須落實辦理。

2. 軌面缺失的自動化處理機制

軌面缺失的照片相當少，本研究採用方法如下：

- (1) Review 並重新組合或調整 Model 架構。
- (2) 將資料進行正規化。
- (3) 使用 Dropout 技術。
- (4) 使用資料增強(Data augmentation)技術，以補足資料不足而導致的過度擬合(Over-fitting)問題。

一張圖片經過旋轉、調整大小、比例尺寸，或者改變亮度色溫、翻轉等處理後，人眼仍能辨識是同一相片，但對機器來說，是完全不同的新圖像，因此，Data Augmentation 就是將 Dataset 中既有的圖片予以修改變形，以創造出更多的圖片來讓機器學習，彌補資料量不足的困擾，本研究利用 Data Augmentation 方式，增加軌面缺失的資料，經驗證為可行方案，未來將持續擴增與維護扣件缺失資料集。

參考文獻

3. 交通部，「1067 公厘軌距鐵路長焊鋼軌鋪設及養護規範」，交通技術標準規範鐵路類工務部，2018。
4. 林雅雯、謝禎岡、黃維信、謝尚琳、洪瑋宏、李明德，「扣件缺失辨識系

- 統之建置研究」，港灣季刊，第 116 期，交通部運輸研究所，2020。
5. 臺鐵局各種里程標，Blair's 鐵道攝影，取自 http://blair-train.blogspot.com/2011/11/blog-post_8911.html，查詢日期：2019 年 1 月 16 日。
 6. “How Swiss Federal Railways is improving passenger safety with the power of deep learning,” 2018, Forbes.
 7. “Railway imaging systems,” ENSCO, <https://www.ensco.com/rail/track-imaging-systems>，查詢日期：2020 年 1 月 19 日。
 8. Pavemetrics, “Laser rail inspection system (LRAIL),” 2019, Canada, <http://www.pavemetrics.com/applications/rail-inspection/laser-rail-inspection-system/>，查詢日期：2019 年 1 月 14 日。
 9. “Visual inspection systems for track maintenance,” bvSysBildverarbeitungssysteme, <https://www.railway-technology.com/contractors/track/bvsys/>，查詢日期：2020 年 6 月 18 日。
 10. Mermec, “Leading the way forward,” <http://www.mermecgroup.com/inspect/track-measurement/185/track-geometry.php>，查詢日期：2021 年 2 月 27 日。
 11. Joseph Redmon and Ali Farhadi, “YOLOv3: An Incremental Improvement,” 1804.02767, arXiv, 2018.
 12. Alexey Bochkovskiy and Chien-Yao Wang and Hong-Yuan Mark, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” eprint=2004.10934, 2004.10934, arXiv, 2020.
 13. Shaoqing Ren and Kaiming He and Ross Girshick and Jian Sun, Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, 1506.01497, arXiv, 2015.
 14. Liu, Wei and Anguelov, Dragomir and Erhan, Dumitru and Szegedy, Christian and Reed, Scott and Fu, Cheng-Yang and Berg, Alexander C., “SSD: Single Shot MultiBox Detector,” Lecture Notes in Computer Science, pp. 21-37, 2016.
 15. Jacob Solawetz, “YOLOv5 New Version - Improvements and Evaluation,” June 29, 2020, <https://blog.roboflow.com/YOLOv5-improvements-and-evaluation/>，查詢日期：2020 年 7 月 12 日。
 16. Ya-Wen Lin, Chen-Chiung Hsieh, Wei-Hsin Huang, Sun-Lin Hsieh, and Wei-Hung Hung, Railway Track Fasteners Fault Detection using Deep Learning, 2019 IEEE Eurasia Conference on IOT, Communication and Engineering, 3-6 Oct. 2019.