

軌道扣件缺失辨識系統之建置研究

謝禎罔 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研究員
黃維信 大同大學媒體設計系教授
謝尚琳 大同大學資訊工程系副教授
洪瑋宏 大同大學資訊工程系研究生
李明德 大同大學媒體設計系研究員

摘要

鐵軌扣夾為軌道扣件系統之重要組件，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。早期由道班工作人員徒步進行軌道巡查與維修，逐步調整為利用軌道巡查車方式進行，但仍依賴人力目視檢查，由於目視巡查受限於巡檢車車速及視察角度侷限，長時間目視可能產生視覺疲勞，導致巡檢效率無法提昇。本研究除蒐集國內外軌道檢測相關研究成果外，亦建立軌道扣件影像的擷取設備，包含攝影及照明設備，再將軌道扣件影像資料，透過影像標記處理，採用 Yolo v3 進行深度學習模型訓練，從測試資料庫驗證正常與缺失扣件檢出率，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有缺失。在夜拍實驗中，影像擷取的部份，以兩盞 200W LED 探照燈投射，採用運動型攝影機 GoPro 進行拍攝，時速至少 30km/h 以上，共錄製 70 公里以上軌道扣件影像，經訓練與測試後，可達正常扣件檢出率 82.5%，缺失扣件檢出率 74.5%，達到鐵路軌道扣件影像自動辨識檢測之目的，可輔助軌道巡檢並提昇巡檢效能。

一、前言

依據交通部臺灣鐵路管理局(以

下簡稱臺鐵)所稱，鐵路路線包括軌道 (Track) 及承載軌道的路基 (Roadbed) 與橋涵等構造物。傳統的軌道係由道碴、軌枕、鋼軌及扣件所組成，鐵路路線構造如圖 1 所示 [1]。

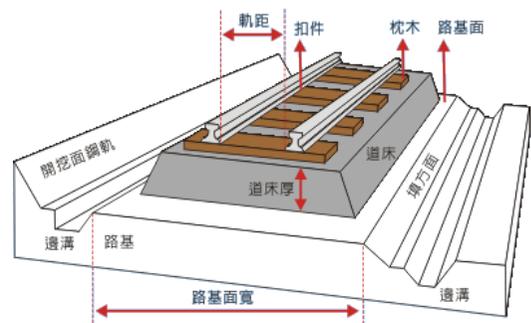


圖 1 鐵路路線構造 [1]

鐵軌扣夾為軌道扣件系統之重要組件，可將鐵軌緊扣在軌枕上。鐵軌承受垂直、縱向、側向等三向力時，須有足夠之扣壓力，避免鐵軌三向變位過大。軌道扣件系統對下部結構具有緩衝作用、並可分散承受重量、抵抗鋼軌側翻擾動、電氣絕緣及吸音減震等功能，讓鐵軌能穩定固定於軌道上，對於列車能否平穩安全行駛影響至鉅。當扣件無法正常發揮作用時，即可能造成火車出軌，為確保扣件正常運作，軌道巡檢人員採用人工目視方式巡檢。

軌道巡查主要於夜間無列車通行時段利用工程維修車進行，仍須依

賴人力目視檢測。軌道目視巡查易受限於巡檢車速及視察角度等問題，長時間目視易能造成疲乏，而易有疏漏的問題。為減輕巡檢人員的工作負擔，提高巡檢效能，實有必要結合科技力，提供更有效的解決方案。

AI發展至今已超過60年以上，近期發展突飛猛進，歸因於資料量遽增、儲存成本降低及電腦運算速度大幅提昇、深度學習技術的突破。其中資料量遽增的部份，主要因為網路、雲端及智慧型手機的普及，每人每日產生的數據資料遽增，因此容易取得大量的資料協助電腦進行訓練。另外，近60年來電腦處理器的運算效能提升了一兆倍以上，再加上雲端儲存成本降低後，代表遽增的資料不但有地方儲存，電腦也有能力去快速消化。最後深度學習技術的突破，讓電腦可以用類似人類思考的類神經網絡進行學習，這讓電腦的視覺、聽覺進步神速^[2]。

AI運作相當依賴訓練資料，當有愈多愈好的資料提供AI進行訓練時，就能提供更準確的判斷。因此本研究首先拍攝軌道扣件AI訓練所需的資料，再調校軌道扣件AI的辨識核心，以達到實務應用。本研究首先蒐集國內外軌道檢測相關之研究成果，然後建立軌道扣件影像的收集設備（包含影像擷取及照明），透過影像標記處理，提供AI深度學習訓練，從訓練結果確認扣件辨識準確率，符合臺鐵軌道扣件自動判釋之需求，用來輔助目前人工目視巡檢工作，俾利軌道扣件及時檢修，提升軌道安全。

二、相關研究

2.1 軌道扣件

市面上常用的軌道扣夾形式種

類繁多，而且外形差異頗大，軌道扣夾用以固定鋼軌於枕木上，防止鋼軌垂直、縱向、側向之三方向變位。目前世界各國軌道所使用的扣夾型式整理如表1所示^[3]。

其中英國 Pandrol International Limited 公司所生產的 Pandrol e-clip，如圖2所示，安裝方便且易於保養維修，廣泛使用於臺鐵環島鐵路路網。

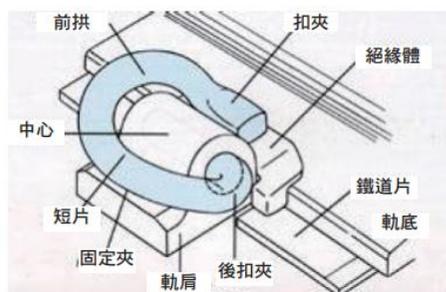


圖2 Pandrol e型扣夾^[3]

除了 Pandrol e型扣夾外，臺鐵還有使用其他類型的扣夾，後續進行AI影像辨識時，須先建立各式扣夾的影像資料庫，以做為判斷分析使用。

表1 各國大廠扣夾種類表^[3]

固定方式	外觀	扣件名稱
螺栓式	鋼條	德國 Vossloh W型扣夾
	鋼鈑	法國 Stedef Nabla扣夾、RN扣夾
		日本 102型扣夾等
	鋼塊	德國 K型扣夾
非螺栓式	鋼條	英國 Pandrol e型扣夾、PR型扣夾、FastClip
		荷蘭 DE扣夾
		美國 Sidewinder扣夾
		瑞士 Fist扣夾
		瑞典 Hambo扣夾
	鋼鈑	澳洲 Mc Kay Safelok扣夾
		英 Pandrol Safelok III型扣夾
		澳洲 Rex-Lok扣夾

2.2 軌道自動影像辨識

瑞士電子和微技術中心 (Swiss Center for Electronics and Micro-technology, CSEM) 為了自動診斷軌道，在 2007 年就開始進行自動化系統開發 [4]，因為傳統影像辨識方法易誤判 (False Positives/ Negatives)，致須人力再加以檢查，所以利用深度學習改進缺點。瑞士聯邦鐵路公司 (Swiss Federal Railway, SBB) 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，希望達到目的如下：

- (1) 提昇鐵路軌道故障檢測和分類技術
- (2) 減少現場目視檢查的次數
- (3) 減少專家處理誤報的問題

SBB 規劃每個月檢查 3,800 公里的軌道，以記錄不同天氣條件 (如下雨、下雪、結冰) 及非軌道物件 (如樹葉、泥土等) 的影像資料。透過訓練模型以檢測影像之目標區域 (如鐵軌、扣件等)，利用「生成對抗網路」 (GAN) 來辨識異常，並將約 20 種不同的故障類別區分為五大類 (如焊接、接頭、表面缺陷、車輪滑移)。另配合深度學習所需，針對收集到的影像進行標籤化處理，透過反覆不斷的學習與訓練，讓分析模型更為精準 [5]。

加拿大 Pavemetrics 公司的 Laser Rail Inspection System (LRAIL) [6] 推出新式的全方位軌道檢測系統，可加裝架設在車輛上，其檢測結果如圖 3 所示。LRAIL 主要之特點如下：

1. 檢測速度可達 180 km/h
2. 同步 3D 幾何測量和高分辨率成像
3. 白天和夜間操作，不受陰影影響。
4. 全自動鐵路檢查。
5. 自動使用里程點和慣性校正 GPS。

6. 組件安裝在環境密封的外殼中。



圖 3(a) LRAIL 架設方式

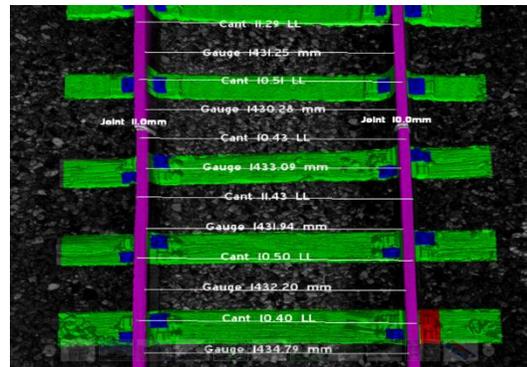


圖 3(b) LRAIL 檢測顯示結果 [6]

印度 Ladola et al. [7] 設計鐵路軌道故障自動檢測的一些組件，如紅外線傳感器，用於檢測裂縫，缺失定位利用全球定位系統 GPS (Global Positioning System)，使用全球移動通訊系統 GSM (Global System for Mobile Communications) 簡訊發送位置，運行系統採用 Arduino，檢測車輛由太陽能電池板和電池供電。

Ritika et al. [8] 以攝像頭結合 GPS，攝像頭以每秒 30 幀左右速度提供穩定的圖像，運用先進圖像分析和深度學習技術，檢測軌道信號，並創建其數據庫。前置攝像頭安裝在引導機車上，實驗了 150 公里，247 個信號的路線，總體準確率為 94.7%。

Karakose et al. [9] 以計算機視覺的監測方法，進行不良軌道偵測，把相機放在火車頂部，拍攝和火車相鄰的軌道圖像。在這些圖像上，應用邊緣偵測並提取特徵來確定軌道，由產

生的軌道之間距判斷是否有故障，試驗結果顯示，所提出的電腦檢驗方法是有效可靠的。

Gibert et al.^[10] 提出利用多重偵測器同時並行運作，得到對軌道和扣件優良的偵測精準度。劉鈺韋^[11] 設計高速影像擷取系統，自動改變線掃描攝影機的取樣率，以便固定檢測物件的影像解析度；枕木定位系統則可以將偵測到的枕木位置傳送給電腦終端機，以便工程人員查修。陳南鳴等人^[12] 提出軌道運輸系統的監控技術，系統利用鋼軌與枕木對扣件的相對位置做為扣件區域定位的依據，鋼軌定位由於需要對整張影像做鋼軌偵測，因此所需運算時間較長，主要由灰階值統計單元、鋼軌位置計算單元、同步動態隨機存取記憶體，因此演算法較複雜。

Fernando et al.^[13] 於 2011 提出以電腦視覺加攝像頭於道叉處檢驗軌道缺失，並整理 1998-2009 年間最常見造成脫軌的原因，使用機器視覺進行道岔部件/缺陷檢查包括開關點磨損或損壞、岔心開關和軌道設備缺陷、轉換岔器磨損或破損、操作桿破損或有缺陷、切換點 開關點和庫存軌道之間的間隙等。

三、系統設計

3.1 系統運作架構規劃

本研究採用高速影像攝影機，將拍攝的影像，傳送到後端的影像辨識深度學習伺服器，配合 GPS 的定位功能，標示出缺失扣件所在的軌道範圍。系統運作架構如圖 4 所示。



圖 4 系統運作架構

影像擷取裝置在檢查期間維持 1080P/60FPS 情況下運作，單筆紀錄最長時間為 5 小時。而影像擷取裝置除記錄影像外，還會記錄時間、速度與 GPS 位置資訊；前端控制系統具控制影像系統的記錄儲存功能，包含手動紀錄輸入、錄影檢視，記錄好之影像資料，透過網路將影像回傳至後端影像辨識深度學習伺服器進行辨識。與後端影像辨識深度學習伺服器連線時，須具備足夠的 I/O 效能與儲存資料能力，方能在適當的時間內完成紀錄的壓縮與傳輸。而後端影像辨識深度學習伺服器，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。系統說明如下：

- (1) 高速影像攝影機（需搭配適當的車外裝載方式），1080P/60fps 錄影，錄影時長 5 小時，抗震，防水、夜間錄影、GPS 座標紀錄
- (2) 後端處理伺服器（接收前端影像與統整，並進行辨識分析與資料儲存），CPU8 核心 5Ghz 以上，記憶體 64G、運算加速卡 Nvidia GTX 2080Ti 兩張、儲存空間：1T 固態硬碟兩顆，2TB 資料硬碟兩顆。

前端控制系統運作時，可選擇「紀錄模式」，待完成紀錄後再將資料傳送到後端伺服器，以取得並顯示辨識結果。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、即時模式及紀錄模式。「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。影像採批次上傳，待上傳後透過「影像辨識」服務，萃取出符合需求之結果，同樣回傳辨識結果，並針對異常狀況進行回報。分析結果都會儲

存在伺服器端，供後續「資料查詢」使用。伺服器端處理流程整理如圖 5 所示。

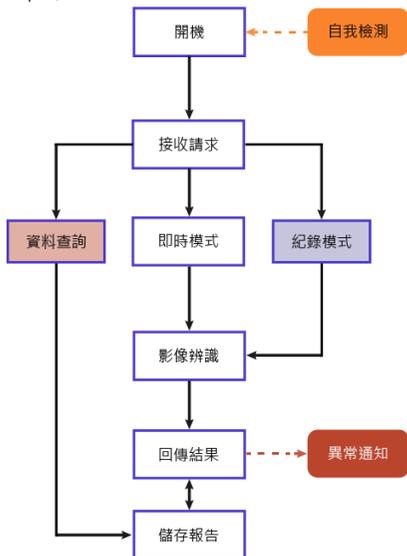


圖 5 處理伺服器系統流程

3.2 軌道扣件影像記錄

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。高速影像攝影機提供每秒 60 幀（每秒顯示張數，Frame per Second, FPS）以上的拍攝速度。若以行駛速度時速 120 公里作為預期的環境狀況，假如需要取得以每 0.5m 作為測量單位的精準度，則需要每秒拍攝 67 張相片的攝影機。本研究臺鐵工程維修車夜間行駛速度時速約為 30 公里，高速影像攝影機符合計畫需求。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為佳。

本研究採用 GoPro Hero7 Black，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，而且有 GPS 記錄，其周邊的配件相當完整，有利於將其固定在工程維修車或平車上。

3.3 平車製作與設備架設

本研究與臺鐵人員討論後，使用工程維修車加平車的方式，俾利未來於其他單位使用，平車由臺鐵人員設計與製作，設計圖如圖 6 所示，平車行駛時速可超過 50 公里。

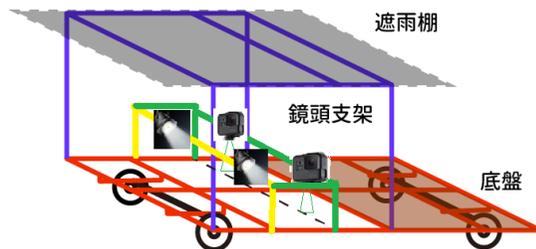


圖 6 平車設計示意圖

GoPro 除具備優異的防震效果外、鏡頭視野廣、GPS 定位、支援即時串流及支援 Python API 等功能，更重要的是周邊可選用的配件種類多元。GoPro 架設位置可視實際拍攝結果，彈性調整架設位置，實際架設結果如圖 7。



圖 7 平車上安裝 GoPro

照明燈具架設的部份，需評估測試不同架設位置的影響，避免陰影產生，支架採用鋁擠型架組立，方便於隨時調整燈具固定位置，架設情形如圖 8 所示。

在照明設備的選用上，希望能獲得清晰的影像，且考慮到光線亮度、方便固定、用電量，經評估決定選用 200W 工程版 LED 白光探照燈，設

備供電使用發電機供電。

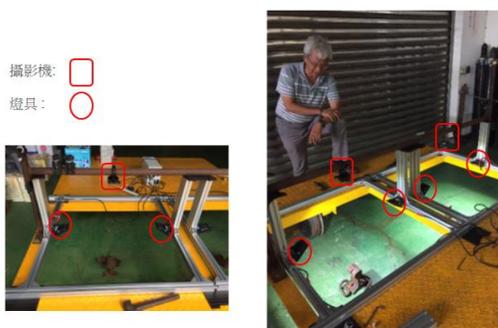


圖 8 燈具以鋁擠型架固定情形

3.4 缺失定位

本研究提出「虛擬偵測點」(Virtual Detection Point)方式協助定位,目前臺鐵內部已有百公尺的里程樁號(如圖 9 所示),針對每一個里程樁號設定半徑 20 公尺(將來可視需求調整半徑值)的「虛擬偵測圓」。當工程維修車行經這些「虛擬偵測圓」時,即可判斷工程維修車所在的位置,當 AI 影像辨識出扣件缺失時,即可快速鎖定扣件缺失的位置。



圖 9 臺鐵百公尺標^[14]

利用 GoPro 拍攝的相片或影片,其儲存格式內含 GPS 資訊,可直接解析使用,可用 Quik Desktop, Dashware, RaceRender 和 GoPro Mobile 應用程式顯示相機所捕獲的 GPS 數據,嵌入在 mp4 檔案中,稱為 GPX (如圖 10 所示),解析後的資料也可直接在任何 GIS 軟體(如

Google Maps)中顯示,本計畫也已完成從影片中解析 GPS 位置,並包含影片紀錄時間(CST)等資訊。

```
<name>../in/87ce4d6fc5d67aa2a3cb/GH010592</name>
<trkseg>
  <trkpt lat="24.3420355" lon="120.6257558">
    <ele>71.257</ele>
    <time>2019-03-28T06:38:36.674Z</time>
    <cmt>GpsAccuracy: 139; GpsFix: 3</cmt>
  </trkpt>
  <trkpt lat="24.3420354" lon="120.6257556">
    <ele>71.254</ele>
    <time>2019-03-28T06:38:36.732Z</time>
    <cmt>GpsAccuracy: 139; GpsFix: 3</cmt>
  </trkpt>
  <trkpt lat="24.3420353" lon="120.6257553">
    <ele>71.27</ele>
    <time>2019-03-28T06:38:36.790Z</time>
    <cmt>GpsAccuracy: 139; GpsFix: 3</cmt>
  </trkpt>
</trkseg>
```

圖 10 GPX 檔案內容

使用實測的 GoPro 影像,解析出的 GPS 資料,誤差大約在 5 公尺左右,已可接近實用程度,實測結果如圖 11 所示。若需再更精準到公分級,需搭配差分訊號,升級為差分 GPS。

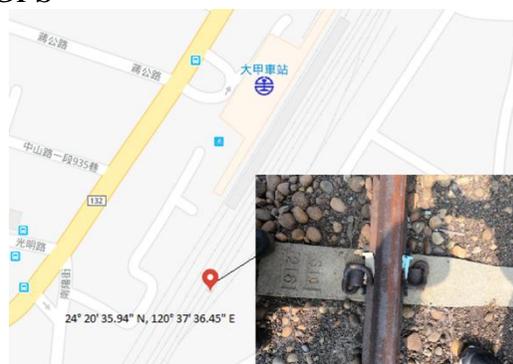


圖 11 大甲分駐所旁軌道側線拍攝軌道扣件定位測試

3.5 影像辨識演算法

本研究計畫採用的是 You Only Look Once (YOLO) v3 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,可以即時的產生結果,應用於物體辨識。神經網路的學習需要大量的樣本,樣本量決定神經網路的模型的泛用與準確度,為了辨識物件

的類型，需要盡可能多的訓練資料（包括正常的、故障的、各種情況的資料）。

Yolo v3 主要特點如下：

- (1) 使用 Resnet 網路 (Residual Network): 新的基底網路為 Darknet-53，有 53 層，隨著網路層數不斷加深（數量級從 20~30 層到 ~50 層），採用了一般類神經網路加深時常用的 ResNet 結構來解決梯度問題。
- (2) 使用特徵金字塔網路 FPN (Feature Pyramid Networks): 使用 FPN 多層級預測架構以提升小物體預測能力，特徵層從單層 13x13 變成了多層 13x13、26x26 和 52x52，單層預測 5 種 bounding box 變成每層 3 種 bounding box (共 9 種)，詳見網路結構圖(如圖 12 所示)。使用 FPN 的架構可以讓低層較佳的目標位置和高層較佳的語義特徵融合，並且在不同特徵層獨立進行預測，使得小物體檢測改善效果十分明顯。

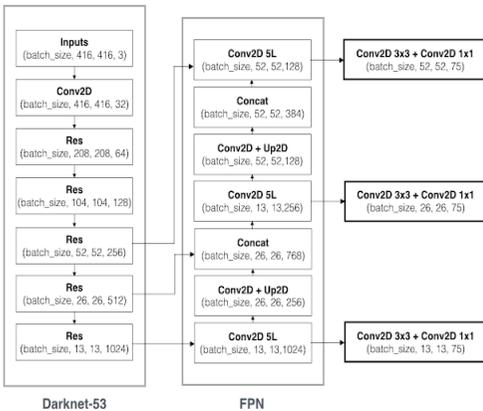


圖 12 Yolo v3 架構圖

四、實驗與討論

4.1 GoPro 安裝實測

本研究於 2019 年 3 月 28 日日間側線進行 GoPro 設備架設與實測，

在完成平車及 GoPro 固定後，即由工程維修車帶動平車在側線往返進行實測，最高行駛時速約 50 公里，影像畫面如圖 13(a)、(b)所示，影像清晰符合需求。

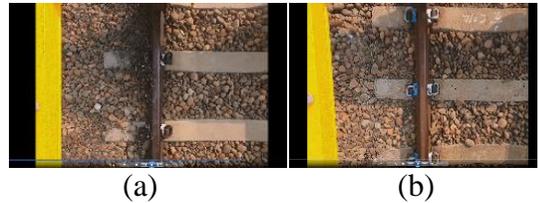
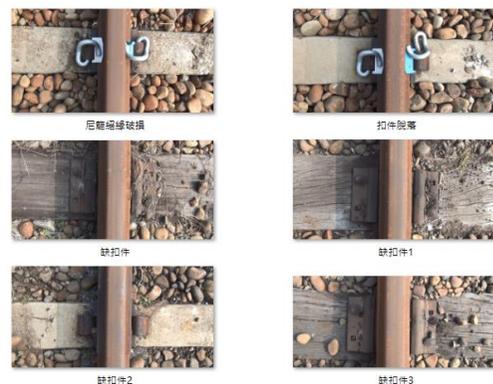


圖 13 實測軌道扣件影像(a)與(b)

於夜間長時間實測時，使用 4K 解析度進行影像錄製，約連續使用 1 小時左右 GoPro 便會因為設備過熱而啟動保護作業，自動關機。代理商建議不要使用內建的電池供電，改由 USB 充電，且調降影像解析度（1080P 60FPS），初步改善設備過熱而自動關機之問題。

4.2 扣件分類

AI 訓練資料須有正樣本及負樣本供 AI 模型可以區分正常與有缺失之扣件，各類缺損扣件，整理如圖 14 所示。



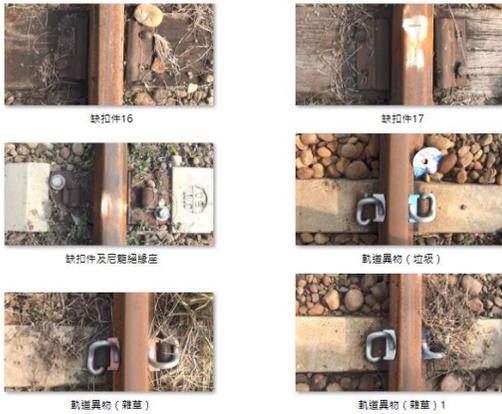


圖 14 軌道扣件負樣本

4.3 AI 模型建立

本研究使用 LabelImg 工具將偵測的扣件 bounding box 標上標籤，即圖片的 Annotation(註釋)。

Yolo 模型評估物件偵測 (Object Detection) 常見的指標:IoU 和 mAP，其定義如下：

1. IoU (Intersection over Union)

預測結果與 ground truth 的聯集分之交集(如下式)。一般預測任務最常用的指標是 0.5 IoU，表示在一次 bounding box 預測中，該 bounding box 算出的 $\text{IoU} > 0.5$ 時為預測成功。

$$\text{IoU}(A,B)=A \cap B / A \cup B(1)$$

2. mAP (Mean Average Precision)

計算各個種類的精確度並平均，這裡的精確度即是使用 IoU 作為判別準則，通常為 0.5 IoU。

- TP(c): True Positive in class c，預測的 proposal 和 ground true 吻合(種類正確且重疊部份夠高)。
- FP(c): False Positive in class c，預測的 proposal 和 ground true 不吻合(種類錯誤或重疊部份不夠高)。

因此由以上步驟可知在 class c 中的準確率為：

$$\text{TP}(c)=\text{TP}(c)/(\text{TP}(c)+\text{FP}(c))(2)$$
 因此每個 class 平均的準確率為：

$$\text{mAP}=1/|\text{classes}| \sum_{c \in \text{classes}} \frac{\text{TP}(c)}{\text{TP}(c)+\text{FP}(c)} \quad (3)$$

3. mAP@[.5:.95]

IoU 取一個 threshold (如 0.5) 可以計算 mAP，因此可以取 0.5 到 0.95 的每 0.05 一個間隔設定 threshold 都算一次 mAP 後將所有數值平均，即為 mAP@[.5:.95]。

4.4 扣件分類結果

由臺鐵人員所提供之正負樣本，本研究定義了如圖 15 的扣件種類，並以 LabelImg 製作訓練資料，總計訓練樣本為 288 張圖片，測試樣本為另外 30 張圖片，測試樣本為影像資料庫中隨機選出。初步分類結果，在各項扣件的類型偵測上取得了約 87% 的準確率，綜合準確率約為 75% (如圖 16 所示)，初步訓練成果整理如表 2。顯示一些照片辨識的結果，經過 5,000 回合，損失函數在 3.75，可以得到 mAP 趨近 75%。

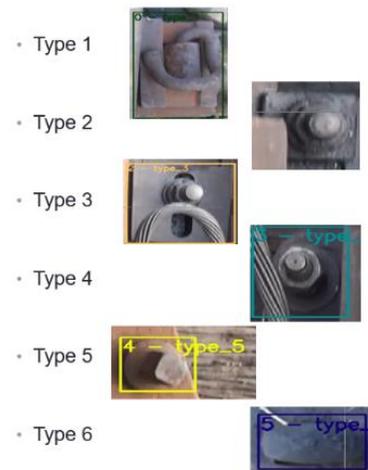


圖 15 台鐵軌道扣件初步分類

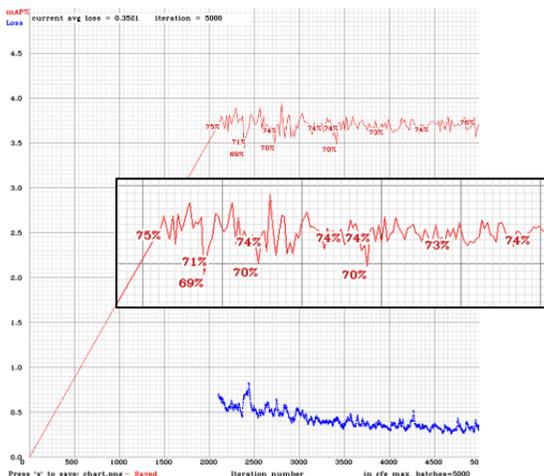


圖 16 YOLO 訓練結果數據(橫座標迭代次數 iteration number, 縱座標 mAP)

表 2、初步訓練成效

類型	偵測率
偵測到的物件個數	325
Type1	92.98%
Type2	95.00%
Type3	95.00%
Type4	74.66%
Type5	79.70%
Type6	85.13%
物件範圍偵測準確率	64.25%
判別準確率(precision)	0.86
捕獲準確率(recall)	0.88
F1-score	0.87
平均準確率(mAP)	75.54%

4.5 側線實測 AI 辨識結果

經過初步驗證後，與臺鐵人員討論後將扣件分類修正為 13 類，如表 3 所示，其中無圖片，均屬尚未蒐集到負樣本。

日間側線測試結果，正樣本 TP = 3,114 個，負樣本 FP = 378 個，誤判個數 FN = 180 個，正確率 Precision = 0.89, 召回率 Recall = 0.95, F1-score = 0.92, 平均正確率 mAP =

84.08%, IoU = 73.4%，顯示效果良好。一些照片辨識結果亦顯示於圖 17，證實本計畫所提方法具可行性。

表 3、修正後軌道扣件分類

編號	扣件分類	圖片	測試 800 張照片，內含 3294 個物件 準確率(解析度=1920*1080)
1	e_clip位於木枕(正常)		84.82%
2	e_clip位於木枕(損壞)		無資料
3	e_clip位於混凝土(正常)		88.27%
4	e_clip位於混凝土(損壞)		89.91%
5	e_clip遭到遮蔽		70.68%
6	鐵釘(正常)		79.52%
7	鐵釘(損壞)		無資料
8	魚尾板(正常)		84.82%
9	魚尾板(損壞)		無資料
10	滑床板(正常)		86.03%
11	滑床板(損壞)		無資料
12	護軌墊板(正常)		86.18%
13	護軌墊板(損壞)		無資料



圖 17 YOLO 進行側線辨識結果

4.6 正線實測夜拍扣件辨識

夜間試拍 I (6 月 6 日 17:00~21:00 側線夜拍)、夜間試拍 II (6 月 17 日 00:00~3:00 正線拍攝)、正線夜拍 (6 月 24 日 00:00~3:00)，夜間錄影品質尚可(當天下大雨也 OK)，人眼可辨識，但不如白天拍的清晰。進行燈光補強，用 2*200W 燈具，燈具架設於上方，與相機同向斜照。側正線試拍畫面良好，但時速未達 30km。

辨識結果如表 4 所示，扣件檢出率 85%，召回率 97%，辨識範例如圖 18 所示。訓練資料庫共 2850 張相片，測試資料庫共 952 張相片。本次

新增 0625 夜拍中之 879 張穩定清晰相片至訓練與測試資料庫中，驗證資料庫中物件個數 3728。



(a)



(b)

圖 18 進行正線夜拍辨識結果。(a) normal 為正常，(b) break 為損壞或缺失

表 4、新增夜拍軌道扣件辨識結果

eClip 木枕木_正常	85.62%
eClip 木枕木_損壞	50.76%
eClip 混凝土枕木_正常	88.19%
eClip 混凝土枕木_損壞	84.76%
eClip 遭到遮蔽	85.54%
道釘_正常	87.17%
道釘_損壞	50%
魚尾鈹_正常	67.79%
魚尾鈹_損壞	89.71%
滑床鈹_正常	88.23%
滑床鈹_損壞	無資料
護軌墊鈹_正常	87.39%
護軌墊鈹_損壞	無資料
斷軌	資料過少
precision = 0.85, recall = 0.97, F1-score = 0.91, average IoU = 70.52 %, mean average precision (mAP@0.50) = 0.721968, or 72.20 %	

本研究於 2019 年 6 月 24 日、7 月 27 日及 9 月 21 日夜間測試，一邊用 2 盞 200W 的 LED 燈，共 2*200=400 瓦燈，而且燈具降低高度

至平車下，貼近軌面，夜間拍攝影像如圖 19 所示，影像共 58,063 張。



圖 19 夜間實測扣件影像

58,063 張相片可作為訓練資料庫，80%作為訓練，20%做為測試。epoch 次數為 27,000，loss function 已經收斂。辨識結果如表 5 所示，正常扣件檢出率 82.5%及缺失扣件檢出率 74.5%，符合本研究預定目標，辨識結果如圖 20 所示。

表 5、正線 70km AI 模型辨識結果 (資料集 20%為測試集，其餘為訓練集)

類別名	Precision	TP	FP	TP+FN	Recall
e-Clip 木枕木_正常	0.91	590	61	701	0.84
e-Clip 木枕木_損壞	0.86	30	5	34	0.88
e-Clip 混凝土枕木_正常	0.89	6131	762	7824	0.78
e-Clip 混凝土枕木_損壞	0.80	194	47	316	0.61
e-Clip 遭到遮蔽	0.83	39	8	85	0.46
滑床鈹_正常	0.91	82	8	105	0.78
護軌墊鈹_正常	0.87	45	7	50	0.90
Precision = TP/(TP+FP)					
Recall = TP/(TP+FN)					
正常檢出率 = 0.825 損壞檢出率 = 0.745					
Thresh = 0.5					

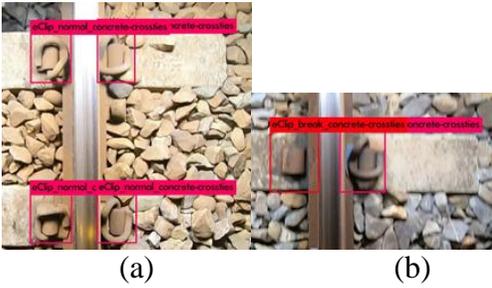


圖 20 進行正線夜拍辨識，normal 為正常，break 為損壞或遺失，(a) 均為 normal 正常，(b)左邊扣件遺失

4.7 扣件影像管理與辨識網站

網站包括四種模式：視頻上傳、扣件分類、扣件查詢和扣件定位，如圖 21 所示。通過使用 GPS 座標，可以在 Google Map 上顯示被識別出有缺陷的軌道扣件，如圖 22 所示。



圖 21 扣件影像管理與辨識網站 - 辨識結果清單



圖 22 扣件影像管理與辨識網站 - 缺失位置顯示

五、結論與建議

5.1 結論

本研究利用高速影像攝影設備，建立影像資料庫並利用 Yolo v3

軟體進行扣件影像辨識，經實際夜間正線拍攝驗證後證明其具可行性。綜合上述做以下結論：

1. 完成應用於軌道影像攝影設備之評估與測試。

因 GoPro Hero7 Black 主打拍攝極限運動及 4K 高畫質，除特別強調手持防震技術、防水防塵且輕巧方便，且周邊的配件完整，有助於將來的設備固定，經本研究評估決定使用 GoPro Hero7 Black，做為軌道影像攝影使用。

2. 照明設備與供電

在照明設備的選用上，為希望能獲得類似白天陽光下清晰的影像，且考慮到光線亮度、方便固定、用電量，經測試評估後最後方案為一邊各用兩盞 200W 燈具，而且光源擺設不只要低，位置還要位於中間，可以避免陰影的產生。電源的部份，使用發電機提供照明、GoPro 等設備使用。

3. 平車製作與設備架設

大甲分駐所代為打造本研究實驗測試用之平車，只要在實驗前利用吊車，即可將平車吊放於軌道上，並由動力火車頭推動。

在光源及 GoPro 設備固定的部份，本研究另利用鋁擠型管製作可放置光源的支架，並將其固定於平車上。經實測，GoPro 及光源在平車快速行駛時，均可牢牢固定在平車上，符合本研究使用需求。

4. 缺失扣件定位

本研究應用 GoPro 內建記錄的 GPS 訊號，可在電子地圖上顯示扣件位置。經測試 GPS 訊號與實際位置誤差約在 5 公尺左右，再結合軌道百公尺里程樁號的「虛擬偵測圓」，在實際定位缺失扣件時，確實可以快速找到目標物。

5. 影像管理與辨識網站建置

本研究已建置影像管理與辨識

網站，使用者可以方便的用行動裝置或個人電腦，以瀏覽器的方式，將前端錄得的影像或影片，上傳至後端網站，除了儲存查詢之外，還包括執行YOLO 扣件辨識，再將結果回傳至前端瀏覽器。

6. 影像辨識演算法

本研究採用的是 You Only Look Once (YOLO)演算法，經實測試，YOLO 的表現能符合本研究所需，目前使用 YOLO V3 版本。

7. GoPro 安裝實測

經多次測試，GoPro 仍有當機情形，原因推測 GoPro 採用電子防震，因實測時震動頻率高，評估購買三軸防震設備，取代 GoPro 電子防震功能。如果測試仍有當機情況，未來即不採用 GoPro 錄影，改評估取像方式為高速攝影，每取一張照片即馬上傳輸與辨識。

8. 扣件正負樣本分類

由大甲分駐所提供扣件分類協助，分類為 11 類，其中滑床板、護軌墊板尚未有缺失樣本。

9. 資料建立

YOLO 訓練資料集，經統計共擷取 58063 張相片可作為資料集。

10. 夜間實測

目前測試結果，扣件檢出率 82.5% 及扣件缺失辨識率 74.5%，可以符合本研究預定目標。

5.2 建議

1. 各種軌道段訓練資料建立

鐵路尚有多種軌道路段，如隧道、版式軌道等，仍需建立訓練資料。

2. 檢測項目種類更新

除扣件缺失外，可擴及軌面缺失等，未來軌面缺失辨識種類建議以斷軌及疲勞裂縫（魚鱗剝落現象）為主。

3. Edge Computing 前端辨識處理

缺失扣件即時辨識，馬上修復，需要前端有辨識功能，須架上工規電腦或是具加速卡之嵌入式系統做即時辨識，如此便須解決在平車上可能面臨防水、防震、防曬等問題。

4. 平車與電源問題

目前使用發電機及不斷電設備各一台，供 Edge Computing 計算所需，未來須再增加發電機及不斷電設備。

六、參考文獻

1. 臺灣鐵路路線建造史，交通部臺灣鐵路管理局，取自 <https://www.railway.gov.tw/tw/CP.aspx?sn=3700&n=6841>，查詢日期：2019 年 1 月 14 日。
2. 人工智慧 (AI) 大衝擊，2017，商業周刊，取自 <https://www.businessweekly.com.tw/article.aspx?id=33196&type=Indep>，查詢日期：2019 年 6 月 19 日。
3. 黃彥賓、王怡華、林安祥、楊子騰、陳嘉昌，“軌道扣件之種類與功能要求”，技術論壇。(http://www.cfwb2b.com/0_magazine/ebook/pdf_download/FW_142_C_101.pdf)
4. Deep Learning of Railway Track Faults using GPUs, 2018, <http://on-demand.gputechconf.com/gtc/2018/presentation/s8944-deep-learning-of-railway-track-faults-using-gpus.pdf>
5. How Swiss Federal Railways Is Improving Passenger Safety With The Power Of Deep Learning, 2018, Forbes.
6. Pavemetrics, Laser Rail Inspection System (LRAIL), 2019, Canada, <http://www.pavemetrics.com/applications/rail-inspection/laser-rail-inspection-system/>, March.

7. Abhi Ladola, Chirag Parekh, Dhaval Patel and Henal Bhagatwala, 2018, Solar Based Railway Track Fault Detection System, International Research Journal of Engineering, Vol. 5, Issue, 5, May.
8. S. Ritika, Shruti Mittal and Dattaraj Rao, Railway track Specific Traffic Signal Selection Using Deep Learning.
9. Mehmet Karakose, Orhan Yaman, Mehmet Baygin, Kagan Murat and Erhan Akin, 2017, A New Computer Vision Based Method for Rail Track Detection and Fault Diagnosis in Railways, International Journal of Mechanical Engineering and Robotics Research, Vol. 6, No. 1, Jan.
10. Xavier Gibert ; Vishal M. Patel ; Rama Chellapp, "Deep Multitask Learning for Railway Track Inspection," IEEE Transactions on Intellig. Transportation Systems, Volume 18 Issue 1, Jan, 2017.
11. 劉鈺韋，2010，高速影像擷取與枕木定位應用於軌道監視系統，國立臺灣科技大學電機工程系碩士論文，台北市。
12. 陳南鳴、謝翔宇、劉鈺韋，2008，軌道運輸系統之監控技術開發，科技部計畫編號：NSC 97-2221-E011-151-MY3，執行期間：97 年 8 月 1 日至 100 年 7 月 31 日。
13. Luis Fernando Molina Camargo, et al., 2011, Machine Vision Inspection of Railroad Track, Graduate Research Assistant, University of Illinois at Urbana Champaign, Grant No. DT RT07---G---005 of the U.S. Department of Transportation, Final Report, January.
14. 臺鐵局各種里程標，Blair's 鐵道攝影，

影，取自 http://blair-train.blogspot.com/2011/11/blog-post_8911.html，查詢日期：2019 年 1 月 16 日。