

應用深度學習技術輔助橋梁裂縫辨識

王姿樺^{1*} 高書屏² 林志憲³

摘要

臺灣橋梁約有兩萬九千座且橋齡 30 年以上橋梁佔總數 31%，傳統橋梁檢測方式容易使判斷結果過於主觀、耗時、高成本且使檢測人員暴露於危險當中，因此藉由深度學習取代傳統檢測並使用公開裂縫資料集及自行拍攝橋梁裂縫資料，選用 Faster-RCNN 模型搭配 ResNet 50 為骨幹的卷積神經網路做為裂縫辨識的方法。研究結果證實相較於傳統橋梁檢測方式之檢測效率、安全性及靈活性也相對提升，研究成果對於裂縫辨識平均精度可達到 80.7%、召回率可達 77%可成功檢測出橋梁受損區域，且測試影像中有 87.76% 影像能夠完全預測裂縫位置，另針對具干擾辨識的裂縫影像也僅有 12.24% 影像有誤判情形。

關鍵詞：橋梁檢測、深度學習、Faster-RCNN、卷積神經網路、裂縫辨識

1. 前言

1.1 研究背景與動機

臺灣多山多谷地形促使橋梁建設為我國舉足輕重的基礎建設之一，橋梁裂縫為混凝土結構物破壞的前兆也是結構維修最重要的環節，可視為構造物安全指標，一旦裂縫生成將會影響結構的安全性、耐用性和適用性。有鑑於傳統目視檢測混凝土結構物評估方法，可能導致裂縫判斷結果過於主觀使評估結果不一致、耗時、高成本且造成檢測人員暴露於危險的環境當中，近年來無人飛行載具已被多位學者以不同方式應用於橋梁影像裂縫萃取 (Kao *et al.*, 2022、林志憲, 2020)，隨著人工智慧的發展深度學習 (Deep Learning, DL) 技術廣泛應用在各個不同領域，為提升資料識別或預測之能力，若能嘗試將人工智慧導入橋梁檢測作業，透過電腦進行裂縫非接觸量測，進而改善橋檢人員作業難度並降低人為誤判之可能。因此由國內外之相關研究可發現，目前透過電腦進行裂縫非接觸量測尚無法達到百分之百的正確辨識，故相關研究都致力於提升辨識的成果品質及準確度。

1.2 研究目的

本研究之目的為透過深度學習自動檢測特性，加上無人機可到達人員無法靠近目標物、機動性較高的優勢，取代傳統目視法達到自動化且安全之裂縫辨識方式，找出橋梁受損區域，並使用可見光相機實地進行橋梁拍攝作業，將所得之影像作為模型測試資料集進一步評估並分析測試結果，探討深度學習應用於橋梁裂縫辨識之可行性及效益。

1.3 文獻回顧

1.3.1 混凝土橋梁檢測規範

交通部依據公路法第三十三條訂定公路橋梁檢測及補強規範，目的為提早發現橋梁結構物異常或損傷並維護橋梁的安全以及延長使用年限，其中橋梁檢測分為定期檢測、特別檢測與詳細檢測三類定期檢測其檢測原因、頻率及方式，詳表 1 整理自中華民國交通部 (2020)。

1.3.2 混凝土橋梁常見裂縫型態

形成混凝土裂縫之因素，如乾縮裂縫、氣候因素、施工不佳或是外力超載等，狀況皆會使混凝土

¹ 國立中興大學土木工程學系 碩士生

² 國立中興大學土木工程學系 教授

³ 國立中興大學土木工程學系 博士生

* 通訊作者，電話: 04-22840437 轉 306, E-mail: rotenwang@gmail.com

收到日期：民國 111 年 06 月 29 日

修改日期：民國 111 年 09 月 16 日

接受日期：民國 111 年 11 月 01 日

橋梁有裂縫產生，如表 2 所示，對於混凝土結構而言其裂縫成因許多但對於嚴重性而言，輕則影響外觀，重則干擾結構強度降低其耐久性 (蔡季恒，2020)。以下將歸納橋梁結構會產生裂縫的樣態及其主要可能成因，如表 2 整理自財團法人中華顧問工程司 (2017)。

1.3.3 深度學習技術於橋梁裂縫檢測應用

深度學習是機器學習的分支領域，而且是以「層」的概念來建構演算法，進而創造出能夠自主學習並做出智慧決定的「人工神經網路」。而就結構裂縫辨識課題，深度學習也已廣泛應用在各種案例探討上，Li & Zhao (2019) 提出利用卷積神經網路進行混凝土表面裂縫辨識，並比較三個 CNN 模型在同一混凝土裂縫數據集上的性能，卷積神經網路在過去相關研究中，已經被廣泛證明擁有極佳的特徵提取能力，能有效於影像中進行物件分類，而眾多裂縫影像辨識研究上大致可以再分成偵測有無

裂縫的「影像分類 (Image Classification)」，找出裂縫所在位置邊界框的「物件偵測 (Object Detection)」以及精準標示出屬於裂縫位置像素的「語義分割 (Semantic Segmentation)」，其詳細優缺點集代表模型等，如表 3 所示整理自 Omnixri (2020)，比較其優缺點後將選擇以物件偵測方式的模型作為後續本研究上使用。

物件偵測 (Object Detection) 為一種將影像內需要偵測物件做分類及位置定位的檢測法，其中又可分為 Anchor-based 與 Anchor-free 兩種類別，其主要區分就在於是否使用錨點 (anchor) 進行提取目標候選框，其中 Anchor-based 物件偵測演算其中又可大致被分為兩階式 (Two-Stage CNN) 和一階式 (One-Stage CNN)，兩階段 (Two-Stage) 的方法通常可以達到較高的準確率但同時需求更高的浮點運算量 (陳建佑，2021)，其偵測法示意本文後續將以兩階段性的方法 Faster R-CNN 為基礎，對橋梁混凝土裂縫進行檢測。

表 1 橋梁檢測規範分類表

分類	檢測頻率	檢測方式
定期檢測	新建橋梁完工後二年內進行第一次定期檢測，爾後定期檢測之間隔以兩年為原則。	直接目視或間接目視檢測為主
特別檢測	於重大事故、災害發生後或巡查發現顯著異狀及公路養護管理機關、公路養護單位認為必要時辦理之。	檢測項目由公路養護管理機關、公路養護單位依事故種類擇定。
詳細檢測	橋梁於定期檢測或特別檢測後，認為有必要時進行之。	橋梁構件之局部破壞檢測、非破壞檢測及跨河橋梁所在河道狀況、基礎沖刷情形之檢測。

表 2 混凝土橋梁常見裂縫型態表

項次	構件	裂化樣態	主要可能成因
1	伸縮縫	無收縮水泥裂縫、破碎	橋體熱漲冷縮；車輛反覆加載
2	橋護欄	混凝土裂縫	溫度效應；外力衝擊；腐蝕環境
3	主構件 (大梁)	裂縫	腐蝕環境；強度不足
4	支承	橡膠墊裂化、裂縫	環境因素引致材料老化及劣化
5	防落設施	混凝土裂縫、破損	外力擠壓；受潮；腐蝕環境此鋼筋鏽蝕膨脹所致
6	橋台	混凝土裂開	上部結構伸縮功能障礙；地震；不均勻沉陷

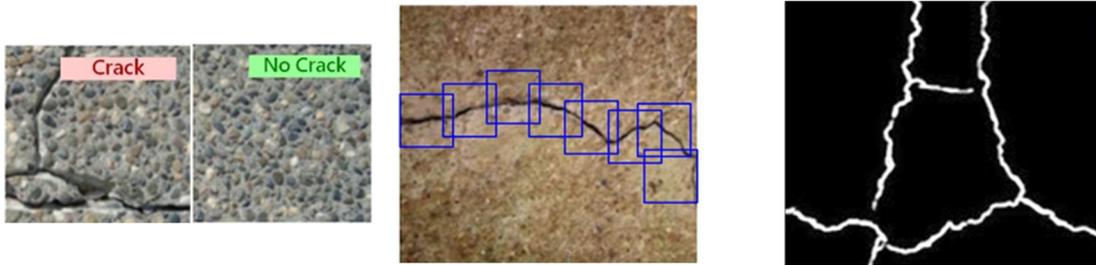


混凝土橋護欄、主構件、防落設施、橋台裂縫 (由左至右) 示意圖

表 3 深度學習模型作為裂縫偵測分類表

種類	影像分類	物件偵測	語義分割
成效	偵測有無裂縫	找出裂縫所在位置邊界框	精準標示裂縫位置像素
優點	1.計算速度快 2.可看到較大範圍裂縫	1.可精確找到裂縫正確位置且較不受背景干擾 2.可同時偵測不同裂縫狀況	可精準分析裂縫位置、粗細、長度、拓樸形狀
缺點	影像僅有無裂縫分類	不容易找到較小面積的裂縫	資料集標註成本很高，模型訓練時間極長，計算量極大
模型	VGG、InceptionV3、ResNet、SqueezeNet 等	R-CNN、Fast-R CNN、SSD、YOLO 等	FCN、U-Net、SegNet、Deeplab、Mask RCNN 等

圖示



1.3.4物件偵測演算法於橋梁裂縫檢測

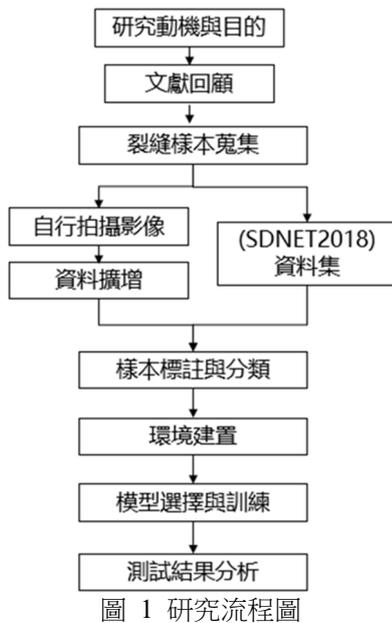
許舜翔等 (2020) 分別實作語義分割 (MaskR-CNN)、實例分割 (DeepLabv3+) 以及目標檢測 (Faster R-CNN) 三種深度學習於隧道裂縫檢測，提出其應用於裂縫影像辨識能夠在特定檢測目標達約 65~75%檢測精度，但對不同構造物仍需人工加入部分待檢測標影像做模型微調。證明深度學習應用於裂縫辨識具一定的辨識能力。Mohammed *et al.* (2021) 比較了三個 CNN 模型在同一混凝土裂縫數據集上的性能，卷積神經網路在過去相關研究中，已經被廣泛證明擁有極佳的特徵提取能力，能有效於影像中進行物件分類，張顯瀚 (2021) 透過損失函數的收斂值比較後，選擇以 ResNet 50 為骨幹卷積神經網路做為裂縫偵測主要方法，並蒐集數種混凝土場景進行裂縫的測試，在裂縫偵測成功率皆有達到 85%以上效果。Tang *et al.* (2019) 利用 Faster R-CNN 系列模型檢測準確度要優於 SSD 算法和 YOLO V2 算法，其中 SSD 與 YOLO 亦為深度學習中的一階式物件偵測演算法，為一種將影像內需要偵測物件做分類及位置定位的檢測法，而一階式物件偵測主要特點是能同時達成位置偵測與類別分類，其中 YOLO (You Only Look Once) 的模型步驟

為調整到固定大小→卷積網路運算→非極大抑制值抑制→輸出結果；SSD (Single Shot MultiBox Detector) 的模型步驟為多尺度特徵圖→Anchor→非極大抑制值抑制→輸出結果。在相同數據集訓練測試以不同基準網絡模型的準確度，ZF-Net 可達 66.51% mAP 值，VGG-16 達到 71.90% mAP 值，而 ResNet 網絡 mAP 值可以超過 78%，提高了 6%，其中 VGG 為深度學習中的經典模型結構，他主要的用途是將 CNN 透過較小的 Conv 堆疊使模型能夠變得更深，可以搭配各種不同演算法做使用。後續本文將以 Faster R-CNN 系列模型搭配 ResNet 為骨幹卷積神經網路作為後續研究。

2. 研究資料及方法

2.1 研究方法

本研究是以網路公開橋梁混凝土裂縫資料集 (SDNET 2018) 作為模型訓練及驗證集，並將上述資料進行影像標註，透過物件偵測模型來完成模型訓練，再經由實際拍攝橋梁裂縫影像集進行測試，評估此模型對於偵測混凝土裂縫檢測之可行性及效益。整體研究流程如圖 1 所示。



2.2 研究料蒐集與處理

2.2.1 混凝土裂縫公開資料集

SDNET2018 是一個帶註釋的圖像數據集，用於對基於人工智能的混凝土裂縫檢測算法進行訓練、驗證和基準測試。SDNET2018 包含超過 56,000 張開裂和非開裂混凝土橋面、牆壁和人行道的圖像，其中含有橋梁樣本共計 2025 張影像其圖像尺寸小為 256×256 (96dpi)。該數據集包括窄至 0.06 mm 和寬至 25 mm 的裂縫。該數據集還包括具有各種障礙物的圖像，包括陰影、表面粗糙度、縮放、邊緣、孔洞和背景碎片。其影像拍攝使用相機為 Nikon COOLPIX S6300 16 MP 其拍攝距離約與拍攝物保持 50 cm 距離，後續影像的拍攝也盡量以此距離為標準。

2.2.2 自行拍攝資料集介紹

本研究參考 107 年度交通部公路總局苗栗工務段橋檢手冊選定三座橋梁作為自行拍攝裂縫資料實驗橋梁，於 2022 年 2 月 9 日上午 11:00~下午 2:00 進行拍攝作業，共選定三座橋梁進行型拍攝作業，分別為台 61 線 106K 西湖溪橋、104K 觀海大橋及台 13 線 25K 橋下頭屋大橋如圖 2 所示，並使用 DJI Mavic 2 Pro (L1D-20c) 及 iPhone 12 進行拍攝，拍攝距離約 50 至 70 cm，三座橋梁皆有使用

iPhone 與 DJ 無人機做拍攝，拍攝前設備無經過特別率定動作，拍攝後共獲得尺寸 1108×1478 影像 106 張與尺寸 5472×3648 共 15 張，並透過裁切及資料擴增 (Data Augmentation) 方式來增加自行拍攝資料集的影像樣本數量，並配合 SDNET2018 資料及進行研究，另將以上拍攝影像作後處理皆裁切為尺寸 256×256 影像作為後續研究使用。



圖 2 實際橋梁拍攝地點圖

2.2.3 影像資料分類及標註

本研究共使用 4250 張 256×256 (96dpi) 影像並將資料劃分為訓練集 (training)、驗證集 (validation) 和測試集 (test) 其比例為 8:1:1，其中訓練集及驗證集部分影像使用 SDNET 資料集影像；測試集則使用自行拍攝影像作為影像測試，後續使用開源標註軟體 LabelIMG 進行裂縫邊界框標註，產出 VOC 格式標註檔案後儲存成 XML 標註檔，並與相對應的影像放置於同一資料夾如進行後續的模型訓練 (如圖 3)。

2.3 本研究 Faster R-CNN 模型架構

本文參考沈佳詠 (2021) 整理出圖 4 實驗模型架構圖，從圖 4 所示可以知道本研究 Faster R-CNN 模型架構主要是由三個主要架構組成，分別為卷積神經殘差網路 (ResNet-50)、區域提議網路 (Rwgn)

Proposal Network, RPN) 與感興趣區域池 (Region of Interest Pooling, ROI Pooling)。首先將標註完成的影像輸入到預先訓練好的卷積神經殘差網路中，從卷積神經殘差網路中可獲得影像對應的特徵圖，之後在特徵圖上的每一個錨點 (Anchor) 取得 9 個不同的感興趣區域 (Region of Interest, ROI)，接著將這些感興趣區域輸入到區域提議網路中，區域提議網路會針對這些興趣區域進行初步的分類目標框類別、偵測目標框位置，最後這些目標建議與特徵圖一併輸入到感興趣區域池中，在進行分類集偵測位置即可獲得最後圖像檢測結果。

2.4 模型訓練

預先將須使用的樣本完成標記與資料集分類

後，採用 Faster R-CNN 模型之訓練框架，利用 Python 編寫的開源神經網路庫 Keras 為模型實施環境，模型訓練執行步驟詳表 4 其訓練時間共花費 18 小時。

3. 研究成果與分析

3.1 研究成果

本研究的訓練集 (training dataset) 與驗證集 (validation dataset) 的模型損失函數圖 (Loss Functions) 如圖 5 與圖 6 所示，訓練集 (training dataset) 的 loss 曲線圖在 250 個 epoch 即可達到 0.03 值；驗證集 (validation dataset) 的 loss 曲線圖在 150 個 epoch 即穩定收斂維持約 0.04 值，兩者之間差值僅 0.01，表示本研究的模型泛化能力佳。

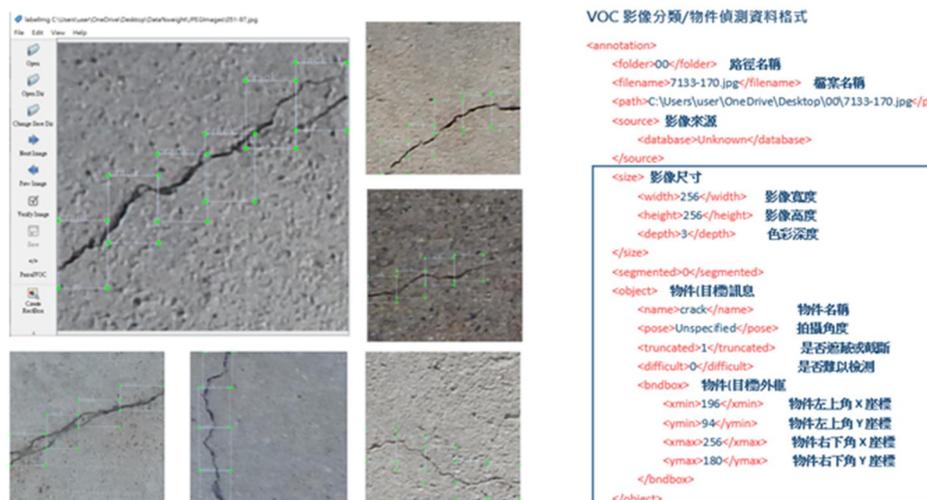


圖 3 (左) LabelIMG 影像標註圖；(右) VOC 格式標註檔案格式圖

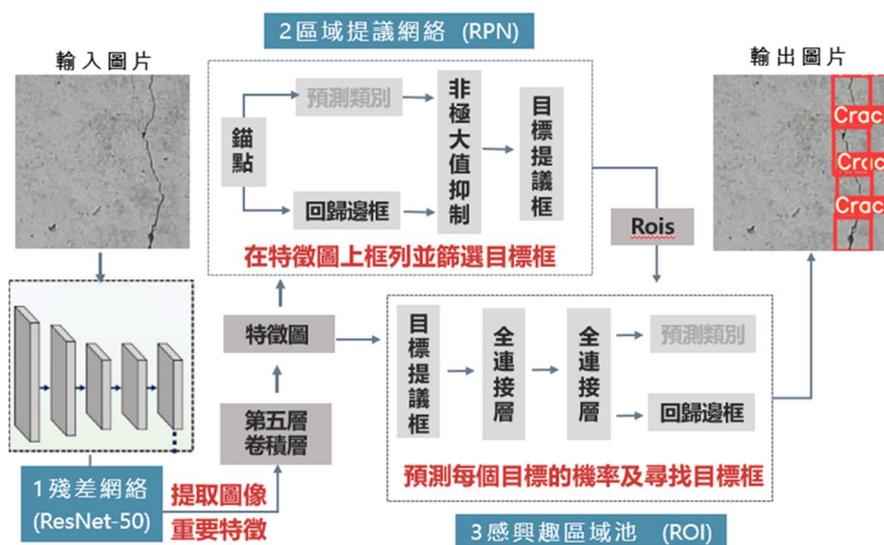
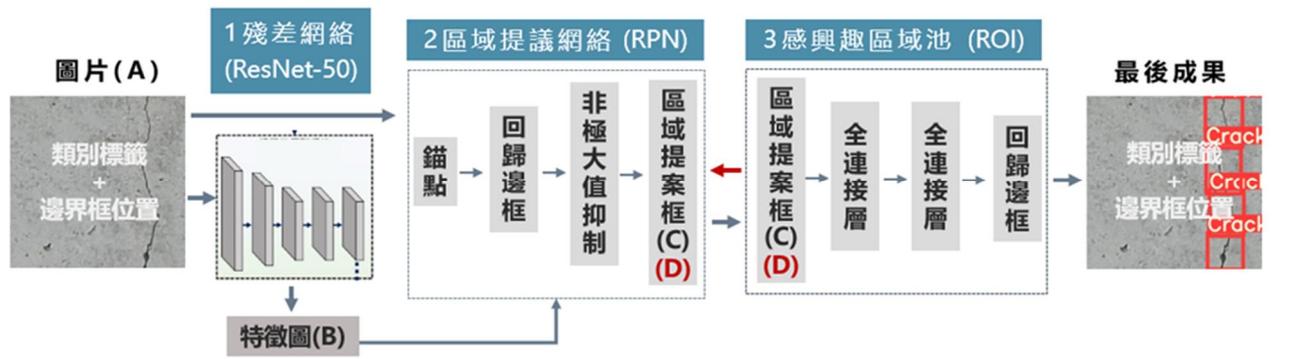


圖 4 本研究 Faster R-CNN 實驗模型架構圖

表 4 模型訓練執行步驟表



步驟	輸入資料	模型	輸出	對應模型執行檔案
1	(圖片+類別標籤+邊界框位置)=A	特徵提取器 (ResNet-50)	特徵圖=B	annotation.py+resnet.py
2	A+B	區域提議網路 (RPN)	區域提議框=C (類別標籤+邊界框位置)	Rpn.py+vision_for_anchor.py
3	A+B+C	感興趣區域池 (ROI)	訓練模型並進行參數更新	classifier.py+fcnn_training.py
4	訓練 Faster R-CNN 參數去初始化區域提議網路(RPN)		更新後區域提議框=D	Rpn.py+vision_for_anchor.py
5	A+B+D 重新訓練 Faster R-CNN		最後成果	classifier.py+fcnn_training.py



圖 5 訓練集 (training dataset) loss 曲線圖



圖 6 驗證集 (validation dataset) loss 曲線圖

本研究使用網路開放裂縫資料集並加入自行拍攝裂縫樣本進行 Faster R CNN 模型訓練，總共使用訓練集 3,400 張樣本、驗證集 425 張樣本、測試集 425 張樣本總數 4,250 張影像，其最終研究成果其裂縫辨識精確率 (Precision) 最高可達 79.81%如圖 7、召回率 (Recall) 最高可達 77%如圖 8 所示，

平均精度部份將 IoU (Intersection over Union) 設定為 0.5 時就認定此 Bounding Box 為 TP (True Positive) 的前提下，其裂縫辨識平均精度 (Map) 最高可達 80.7%如圖 9，本研究測試集資料預測時間共計訓練時間為 5 個小時，每張影像平均花費 42.35 秒進行裂縫位置辨識的預測。

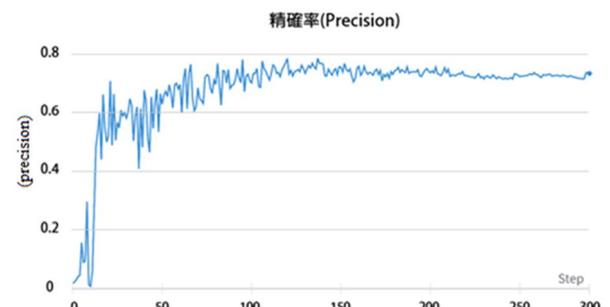


圖 7 實驗成果精確率 (precision) 圖



圖 8 實驗成果召回率 (Recall) 圖

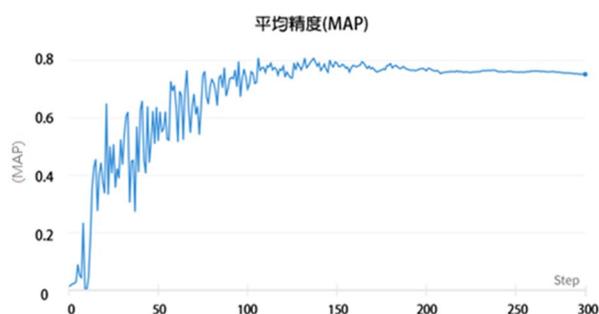


圖 9 實驗成果平均精度 (MAP) 圖

3.2 成果分析

本研究測試集中的 425 張影像測試結果顯示可完全偵測到圖片裂縫共佔總數量 84.94%，能偵測影像裡 50%以上裂縫共佔 11.29%，僅偵測到影像中部份裂縫僅佔 1.17%，無法偵測到影像中裂縫僅佔 2.58%，說明本模型對於影像裂縫偵測上能有效框選出裂縫存在位置佔總數 96.23%，僅 3.77%的影像沒有確切偵測到裂縫存在如表 5 所示。

其中測試集中無預測到裂縫存在的 11 張影像

表 5 測試集資料裂縫預測情形表

	100%預測到	預測 50%以上	僅預測不到 50%	沒有預測到
樣本數量	361 張	43 張	10 張	11 張
占比	84.94%	10.11%	2.35%	2.58%
圖示	A	B	C	D

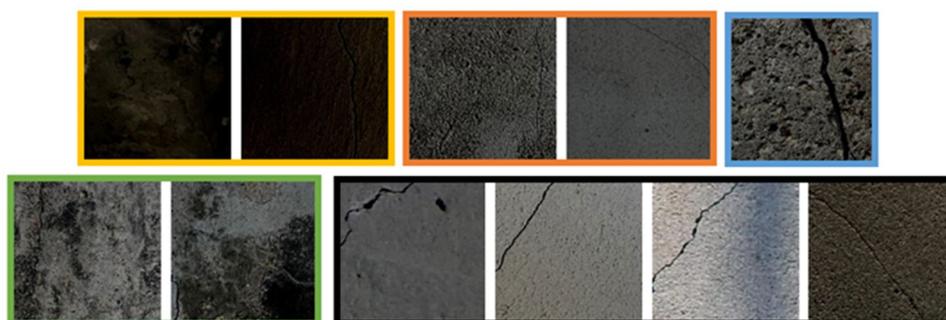
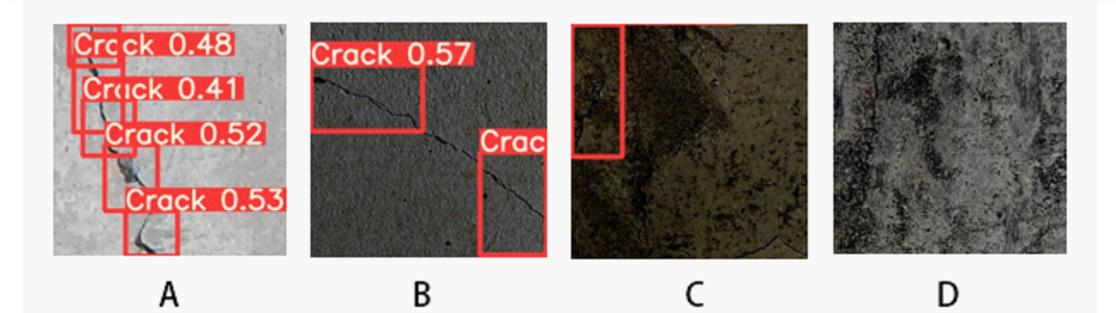


圖 10 無預測到裂縫影像圖

如圖 10 所示，推估黃框部份 2 張影像可能因影像過暗造成模型判讀不易；橘框部份 2 張影像可能因裂縫紋路不夠明顯所致；藍框部份 1 張影像可能因裂縫紋路太大已被視為不同表面；綠框部份 2 張影像可能因牆面紋理造成裂縫辨識不易；而黑框部份 4 張影像目視無任何影響其模型判斷裂縫因素。

此外本研究於測試集資料中放入 49 張具有干擾的影像資料，其干擾因素包含牆面剝落、各種面積大小污漬、噴漆、表面不平整、牆面無連續、雨滴水漬或其他突出外來物等如圖 11 所示，而模型詳細誤判狀況詳表 6，由表所示可見影像如有牆面剝落、噴漆、牆面無連續與雨滴水漬干擾下對於模型預測結果都不會受到影響，依然可正確判讀裂縫所在位置，而表面不平整與其他外來物在影像誤判情形尚有較高影響。

模型測試集中有 13 張影像暗度較高的裂縫影像，其兩次模型對於 13 張較暗裂縫影像預測情形比較如表 7 所示。

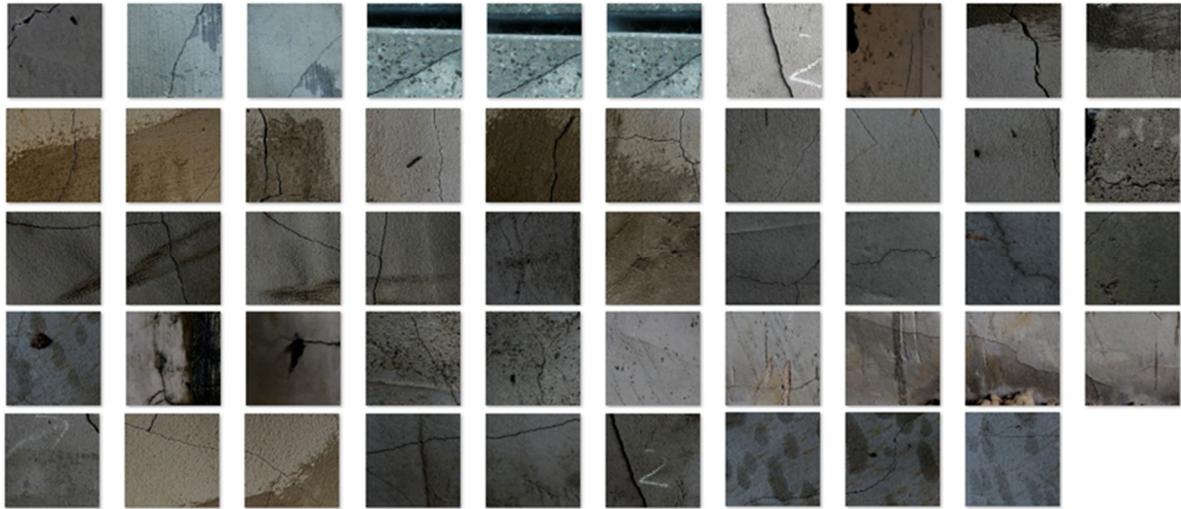


圖 11 具干擾裂縫辨識影像圖集圖

表 6 各種干擾因素影像分類及模型誤判情形表

干擾因素	影像張數	預測誤判		影像圖示
		張數	占比	
牆面剝落	2	0	0%	A
各種大小污漬	20	2	10.00%	B
噴漆	3	0	0%	C
表面不平整	14	3	21.42%	D
牆面無連續	3	0	0%	E
雨滴水漬	3	0	0%	F
其他外來物	4	1	25%	G
總和	49	6	12.24%	

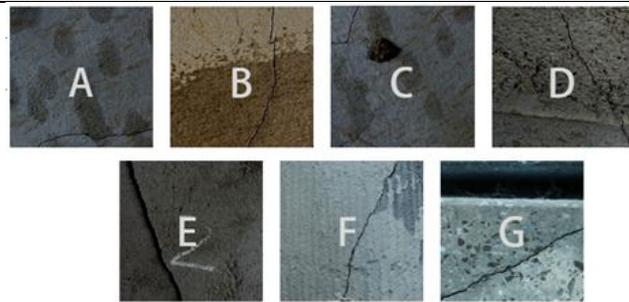


表 7 模型對於 13 張較暗裂縫影像預測情形表

項目	張數	
沒有預測到裂縫影像 (A 圖)	2 張	A
預測到部份裂縫影像 (B 圖)	6 張	B
100%預測到像 (C 圖)	5 張	C

4. 結論與建議

4.1 結論

本研究利用 Faster-RCNN 進行混凝土橋梁裂縫影像辨識，其成果精確率 (Precision) 最高可達 79.81%、召回率 (Recall) 最高可達 77%、平均精度 (Map) 最高可達 80.7%，測試成果可有效偵測到裂縫存在能協助橋梁檢測人員在定期檢測上使用，在測試集中有 84.94% 影像能夠百分之百預測裂縫存在位置；另 10.11% 影像能夠辨識出 50% 以上裂縫存在；2.35% 影像僅能夠預測到部份裂縫；其中 2.58% 影像因礙於影像亮度、壁面紋理及裂縫紋路不明顯而無法判別出裂縫位置，另研究結果證實模型對於具有干擾因素的裂縫影像尚具一定辨識能力，測試集中含有 49 張具干擾裂縫辨識的影像資料，測試結果顯示 87.76% 影像能夠正確裂縫位置僅 12.24% 影像有產生誤判情形發生，而模型對於牆面剝落、牆面噴漆、壁面無連續與雨滴水漬部份干擾不會造成模型誤判情形產生，最後本研究嘗試以國外混凝土裂縫公開資料集，搭配自行拍攝影像資料並經過資料擴增來嘗試做裂縫物件偵測的實驗，結果顯示其研究成果是可行且在最後成果表現上也能與其他參考文獻達到差不多成果，可減少實際資料樣本蒐集時間。

4.2 建議

本研究對於過暗影像裂縫辨識尚無法百分之百預測裂縫位置，建議可在拍攝時加入照明設備使影像後續辨識上能夠免受影像暗度干擾；另研究結果對於牆面剝落、牆面噴漆、壁面無連續與雨滴水漬部份不會造成模型誤判情形產生，建議檢測橋梁若有上述情況時可使用本模型進行裂縫辨識，將可避免模型有誤判情形發生；未來可另蒐集影像含非裂縫情形樣本如外來物石頭或污漬等，並新增不同預測類別讓模型學習，則可將收集而得樣本情形與裂縫情形區隔；本文針對橋梁裂縫以深度學習模型進行偵測，唯橋梁裂縫之評估為長期且需量化的一項任務，建議未來可加入量化效果達到更精確

的裂縫量測；最後本研究成果亦可用於不同材質上的裂縫辨識，例如：金屬鋼材、磁磚表面或柏油路面等，在分別針對其材質及裂縫特性做部份參數調整即可。

參考文獻

- Omnixri, J., 2020。【AI HUB 專欄】利用深度學習技術讓裂縫無所遁形，<https://reurl.cc/rDkYOb>，引用 2022/9/25。[Omnixri, J., 2020. [AI HUB Column] Using deep learning technology to make cracks invisible, Available at: <https://reurl.cc/rDkYOb>, Accessed September 25, 2022. (in Chinese)]
- 中華民國交通部，2020。公路橋梁檢測及補強規範，部頒規範。[Ministry of Transportation and Communications, 2020. Specification for inspection and reinforcement of highway bridges, ministerial norm. (in Chinese)]
- 沈佳詠，2021。以 Faster R-CNN 為基礎之目標檢測基本應用，碩士論文，國立中興大學應用數學系。[Shen, J.Y., 2021. Basic application of Faster R-CNN on object detection, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 林志憲，2020。以無人飛行載具進行自動化高架混凝土橋梁裂縫量測，碩士論文，國立中興大學土木工程系。[Lin, J.S., 2020. Automated measurement of cracks for elevated concrete bridge using Unmanned Aerial Vehicles, Master Thesis, National Chung Hsing University, Taiwan, ROC. (in Chinese)]
- 財團法人中華顧問工程司，2017。混凝土橋梁常見劣化樣態探討。[Consortium legal person China Consulting Engineering Division, 2017. Discussion on Common Deterioration Modes of Concrete Bridges. (in Chinese)]
- 張顯瀚，2021。應用深度學習與影像處理偵測混凝土表面裂縫，碩士論文，國立聯合大學電機工

- 程學系。[Zhang,H.H., 2021. Detecting cracks on concrete surfaces using deep learning and image processing, Master Thesis, National Union University, Taiwan, ROC. (in Chinese)]
- 許舜翔、張庭維、張家銘、陳俊杉、韓仁毓、林曜滄、李魁士、張廷榮，2020。深度學習應用於影像裂縫辨識：發展智慧維運系統以監控結構安全性，中華技術，128：76-87。[Hsu, S.H., Chang, T.W., Chang, C.M., Chen, C.S., Han, J.Y., Lin, Y.T., Li, K.S. L., and Chang, T.L., 2020. Deep learning applied to image crack identification: Developing smart maintenance systems to monitor structural safety, CECI Engineering Technology, 128: 76-87. (in Chinese)]
- 陳建佑，2021。適用於嵌入式平台的車道物件偵測模型設計，碩士論文，國立臺南大學資工系。[Chen, J.Y., 2021. A design of lane objection model suitable for embedded platform, Master Thesis, National Tainan University, Taiwan, ROC. (in Chinese)]
- 蔡季恒，2020。以應力波檢測混凝土結構裂縫修補狀況之研究，碩士論文，朝陽科技大學營建工程系。[Cai, J.H., 2020. Research on the repair quality of crack in concrete structures by stress waves, Chaoyang University of Science and Technology, Taiwan, ROC. (in Chinese)]
- Kao, S.P., Wang, F.L., Lin J.S, Tsai, J., Chu, Y.D., and Hung, P.S., 2022. Bridge crack inspection efficiency of an unmanned aerial vehicle system with a laser ranging module, Sensors, 22(12): 4469.
- Mohammed, M.A., Han, Z., and Li, Y.G., 2021. Exploring the detection accuracy of concrete cracks using various CNN models, Advances in Materials Science and Engineering, 2021: 9923704.
- Li, S.Y., and Zhao, X.F., 2019, Based concrete crack detection using convolutional neural network and exhaustive search technique, Proceedings of the Advances in Civil Engineering, Computer vision-based structure health monitoring, China, pp. 336-340.
- Tang, J.H., Mao, Y.C., Wang, J., and Wang, L.B., 2019, Multi-task enhanced dam crack image detection based on faster R-CNN, Proceedings of the IEEE 4th International Conference on Image, Vision and Computing (ICIVC), China, 2019(2):1-12.

Application of Deep Learning Technology to Assist Bridge Crack Identification

Zi-Hua Wang ^{1*} Szu-Pyng Kao ² Jhih-Sian Lin ³

Abstract

There are about 29,000 bridges in Taiwan and 31% of the bridges are over 30 years old. Traditional bridge inspection methods are too subjective, time-consuming, costly and expose inspectors to danger. Therefore, deep learning was used to replace the traditional inspection method and the Faster-RCNN model with ResNet 50 as the backbone of the convolutional neural network was chosen as the crack identification method using public crack dataset and self-photographed bridge crack data. The results of the study confirmed that the detection efficiency, safety and flexibility were relatively improved compared with the traditional bridge detection method. The average accuracy of the research results for crack identification reached 80.7% and the recall rate reached 77% to successfully detect the damaged area of the bridge. In addition, 87.76% of the test images were able to predict the crack location completely, and only 12.24% of the crack images with interference recognition were misidentified.

Keywords: Bridge Inspection, Deep Learning, Faster-RCNN, Neural Network, Crack Identification

¹ Master Student, Department of Civil Engineering, National Chung Hsing University

² Professor, Department of Civil Engineering, National Chung Hsing University

³ Ph.D. Student, Department of Civil Engineering, National Chung Hsing University

* Corresponding Author, Tel: 886-4-22840437 ext.306, E-mail: rotenwang@gmail.com

Received Date: Jun. 29, 2022

Revised Date: Sep. 16, 2022

Accepted Date: Nov. 01, 2022