



影像分析方法 應用於 構造物外觀異狀 自動化偵測 之發展

張庭維／國立臺灣大學土木工程研究所結構工程組 碩士班研究生

許筠曼、吳亭諤／國立臺灣大學土木工程學系 大學部學生

許舜翔／國立臺灣大學土木工程學系 專任研究助理

張家銘／國立臺灣大學土木工程學系 副教授

構造物外觀異狀自動化偵測為結構檢測之重要發展方向，結構巡檢通常需花費大量的人力與時間對資料進行判釋，為降低巡檢所花費之資源，目前工程領域積極發展自動化偵測技術，而影像分析方法為其中重要的研究方向，利用影像分析來快速且客觀地得到檢測結果。於本篇文章中將介紹影像分析方法於於結構外觀檢測，以及應用人工智慧影像分割於構造物外觀異狀偵測之案例。人工智慧能夠快速有效的進行構造物外觀異狀偵測，藉由經人工標註後的影像資料，深度學習模型能夠針對欲辨識之類別的特徵進行學習，配合不同的資料組合以及模型微調方式，能夠處理困難的檢測任務。在本文我們利用實際訓練深度學習模型，進行隧道裂縫以及橋梁之異狀檢測任務，探討模型於不同檢測任務所需採取的技巧以及資料集的微調方針，進而分析人工智慧於構造物外觀異狀自動化偵測之成果，以及實務上較佳的模型訓練方式，並歸納提出目前發展的潛力與挑戰。

介紹

影像分析方法為結構檢測中的一個重要研究方向，利用影像資料檢測構造物異狀，本文將介紹異狀偵測於目前結構檢測上的重要性，以法規中橋梁檢測方法做舉例，並介紹影像分析方法於結構檢測之優勢。本文亦針對純粹影像分析方法及人工智慧影像分析方法做介紹，分析各自的優勢及限制。

異狀偵測於結構檢測

裂縫、破損等構造物外觀異狀為結構安全的重要指標之一，藉由分析構造物外觀異狀之樣態，能夠初步評估構造物的安全性。結構之安全性監測建立在各項安全性指標的觀測，其所需觀測項目於法規皆有明確規範，

如《公路橋梁檢測及補強規範》中明定公路橋梁於定期檢測所需觀測項目，如橋面版、橋墩等，並規範特定的檢測方式，以及其損壞評估指標。以橋梁目視檢測為例，規範中明訂檢測方法以及其評分標準，根據規範即可評估各個橋梁構件的 DERU 值，將外觀上可視的裂縫、破損經規範中的量表給予客觀之評分，求出橋梁的總體評分，進而評估橋梁的安全是否無虞。

異狀偵測為非破壞性檢測的重要方法^[1-2]，構造物的外觀因經年劣化或是外力破壞而發展出裂縫、破損，導致部件發生非預期的變形或破壞，對構造物安全造成疑慮，為了確保結構的安全性，必須定期進行檢測作業。異狀偵測不需精密儀器，以相機等輕型影像蒐集儀器即能運作，也能夠針對不同的檢測任務擴

充發展設備以及偵測方式，異狀自動化偵測技術於結構健康檢測上為極具發展潛力之研究方向，隨著未來硬體及運算資源之整合，能夠輔助巡檢系統，增進行效率與準確度。

影像分析方法於結構外觀異狀辨識

結構外觀異狀偵測為辨識構造物劣化於影像中的特徵，來定位其外觀上所呈現的異狀。在過去的研究中，影像分析方法應用於異狀檢測被廣泛研究^[3-4]，以裂縫為例，由於裂縫於影像中的成像具備一定的特徵，可以藉由特定的影像濾波器來擷取影像中屬於裂縫的像素。

影像分析應用於結構外觀異狀辨識有多種方式，在前人的研究中，常見的為基於影像梯度的分析方法，在構造物的外觀影像上，由於裂縫的梯度變化較大，能夠經由影像處理方法萃取其特徵，再處理其鄰近像素使影像中的裂縫特徵得以被完整識別。Adhikari 等人^[5]利用裂縫於影像中呈現線型的特徵，以影像形態學、霍夫變換等一系列的影像處理程序，並結合影像後處理方法，於橋梁試體影像中，識別出混凝土表面的裂縫，並對其進行尺寸的測量。Salman 等人^[6]則是利用 Gabor 濾波器針對路面影像進行裂縫辨識，其使用的影像資料為單一材質的路面影像，Salman 等人以多層的濾波器輔以不同的閾值對影像進行處理，最後輸出裂縫的二元值影像。

影像分析方法應用於結構外觀異狀辨識，能夠針對特定檢測任務進行辨識，以往大多數的研究都是處理近照的影像資料，針對具有複雜背景的影像多需人工將背景去除，或是利用其他演算法擷取目標材質，大多數的研究並未同時進行消除背景以及辨識異狀之複合研究，為目前純粹影像分析方法之限制。

人工智慧應用於結構外觀異狀辨識

結構安全性可經由外觀異狀作為判斷依據，例如裂縫、壁癌、鋼筋外露等常見的外觀異狀，根據不同異狀的分布、位置及大小，進行不同的後續補強程序，因此辨識這些外觀異狀為檢測結構安全性不可或缺的一環，但目前實務上檢測方式多為拍攝影像後，再經由工程師人工標註異狀區域，此程序費時且需要大量的人力成本，因此基於深度學習影像辨識的外觀異狀檢測方式近年來被廣為研究，根據不同的工程問

題，訓練出合適的深度學習模型，經由模型去辨識結構外觀異狀，除了可大幅降低時間及人力成本，也能大幅降低人為的判釋誤差。

運用不同的深度學習模型可以針對不同工程情況解決問題，常見的作法為利用開源深度學習模型，並以自定義的資料集進行訓練，如 Chai 等人^[7]訓練 Faster R-CNN 模型以辨識鋼鐵及混凝土上的裂縫，又或是自行串建模型以達到辨識的效果，如 Zhang 等人^[8]設計同樣基於卷積運算的模型 - CrackNet，主要目標為辨識出瀝青鋪面上的裂縫，上述兩者皆可達到相當的分割準確度。隨著人工智慧方法的演進，模型高效且準確的辨識成效，將有機會於未來改變目前經由人工判釋結構異狀的方式，而如何提升判釋的精確度與模型的泛化性，同時整合至實務操作的標準流程，則是未來產學界應努力的方向。

本文將從人工智慧應用於結構外觀異狀檢測著手，介紹影像分割模型的種類以及其各自的特色，並且說明研究中實際被應用的模型訓練技巧，最後以隧道裂縫檢測以及橋梁劣化檢測此兩個實際案例，探討模型的檢測成果以及其限制。

人工智慧模型

影像辨識為人工智慧之主要研究領域之一，而依據其架構，又能更細分為多項不同技術，本文將介紹常用於異狀偵測之不同影像分割模型，介紹其偵測方式以及特色，並簡介相關模型微調之方法，以及微調方法對模型造成之影響。

影像分割模型

卷積神經網絡 (Convolutional Neural Network, CNN)，為深度學習應用於影像辨識中最被廣泛使用的模型架構，也是現今許多影像辨識模型的延伸基礎。CNN 模型在影像辨識上，藉由卷積運算提取保留重要影像特徵，並以梯度傳播更新模型權重，使模型具良好特徵提取能力，能夠有效完成影像辨識之任務。根據不同影像辨識任務，須採不同影像分割 (Image Segmentation) 技術，依照不同規則將圖片像素分成若干部分，並標記其類別，以下將介紹三種影像分割方式 - 語義分割、實例分割、全景分割。

語義分割 (Semantic Segmentation)：為像素級的圖像處理方法，將圖片中每一個像素標註為某一類別，可以識別物件存在的範圍，但無法區別同一類別的不同個體，見圖 1(b)。

實例分割 (Instance Segmentation)：先利用目標檢測 (Object Detection) 獲得目標物件框，再於框內分割出目標位置，目標種類採目標檢測之結果。此影像分割方式相較於語義分割，可標註出圖上同一類別之不同個體，見圖 1(c)。

全景分割 (Panoptic Segmentation)：為語義分割與實例分割之結合，將圖像中每個像素分配給一個語義標籤和一個實例編號，其中語義標籤為物體類別，實例編號為同類物體對應的不同編號。目前分割任務依照不可數目標和可數目標進行單獨分割。此方式與實例分割相比，由於全景分割要求每個像素只能有一個類別和一個編號，因此不能出現實例分割中的重疊現象，見圖 1(d)。

不同的影像分割方式著重的特色不盡相同，語義分割較注重「類別之間的區分」，而實例分割更注重「個體之間的區別」，而全景分割則是「圖像整體分類區別」，對於不同影像辨識目的，應採取影像分割方式也不同，方能凸顯辨識任務之重點，使模型訓練能符合預期成果。

模型訓練方針

深度學習中，有許多微調技巧被應用於模型訓練過程，以改善模型的辨識能力，而本文將針對研究中實際




圖 1 影像分割方式 [9]

使用的訓練技巧進行解說，介紹其目的以及操作手法，包含針對資料集進行之調整以及模型權重之調整等。

資料前處理

資料獲取不易，資料品質常參差不齊，因此資料的前處理相當重要，例如影像的大小不一，但由於每個模型輸入層所能處理的維度固定，因此訓練前大多需要進行尺寸調整，通常利用裁切或縮放來滿足模型輸入層可處理之維度大小。再者，為確保梯度能穩定反向傳播，普遍作法為對像素資訊進行標準化，而常用的標準化手法為 Z 分數標準化。

資料增強

資料增強主要功能包含「彌補資料不足」和「避免過擬合」。為訓練一準確性高、泛化性佳的模型，除模型架構外，最關鍵的就是資料，然而要蒐集大量、完整資料費時又不易達成，透過資料增強可彌補資料之不足，而適當的圖像增強也能降低模型過擬合之可能性，為幫助模型訓練常見的手段。資料增強即是在既有的資料集中去產生新的資料供模型學習，經過增強後的影像對於模型而言都是新的樣本，其中資料增強常見的方法包含翻轉、旋轉、裁切、高斯模糊、飽和度及亮度調整等，透過增加資料的多元性，避免模型過擬合，以提高辨識精度。

超參數調整

深度學習中，模型參數會隨著訓練過程尋找最佳解，而不同於模型參數，超參數為人為自訂且影響模型訓練方式，例如訓練時的學習率 (Learning Rate)、批次數量 (Batch Size) 都是常見的超參數，學習率為反向傳播時應修改值的折減係數、批次數量則為每次輸入模型進行訓練的影像張數。模型超參數會對於模型的收斂效果產生影響，大多只能透過試誤法或經驗來尋找最適合的超參數組合，在訓練的過程中觀察損失函數變化，也能做為調整超參數的依據。

遷移式學習

為實現不同的辨識目標，訓練過程中常會遇到資料不足的困境，若原來模型複雜度相對太高時，容易產生過擬合的現象，為解決此問題，在建立模型時，僅改變最後的輸出層，並在模型主要提取特徵的結構

中，載入其他人利用公開資料集訓練的模型權重，作為初始值再對模型進行訓練，得到更為泛用的模型，減少過擬合發生的機會。

人工智慧模型於結構檢測

人工智慧模型能夠針對不同的檢測任務進行構造物外觀異狀檢測，利用影像蒐集設備蒐集構造物影像，經訓練後產出之模型，能夠應用於辨識出不同構造物之外觀異狀。本文著重隧道裂縫以及橋梁劣化進行實際案例探討，實作模型於不同檢測任務上的辨識成果，並針對辨識結果進行討論，並且探討模型微調方針對於辨識成果之改善。

模型應用於隧道裂縫檢測

裂縫為隧道安全的重要指標之一，若能在隧道生命週期內定期檢測，將能及早發現隧道的潛在風險，並對其進行改善，進而避免潛在的危害以及消除對安全的疑慮，本文實作由 Google 開發之開源 Deeplabv3+ 以及 Facebook 開發之以 Detectron2 部署之 Mask R-CNN 模型，進行隧道影像之裂縫辨識，Deeplabv3+ [10] 屬於語義分割模型，能夠針對影像各個像素進行分類，Mask R-CNN [11] 屬於實例分割模型，相對於語義分割，實例分割能夠區分同一類別之不同個體。

本文使用之裂縫影像資料來源分兩部份其一為雷射掃描之點雲產製而成之隧道襯砌灰階影像，另一為過往研究者之公開裂縫影像資料，公開資料集的影像包含了混凝土表面、路面等資料，加入不同於目標隧道之影像，除了可以增加模型之泛用性之外，也可避免模型於訓練過程中發生過度擬合之情形，資料經由裁剪後，進行人工標註影像中的裂縫像素後作為訓練及驗證資料，組成之資料集即可用以訓練與驗證模型。標註後的影像裁剪成固定尺寸後，輸入所試驗的

兩種深度學習模型進行訓練，並調整適當的模型超參數。對於模型訓練過程進行調整，並以驗證資料集驗證模型的辨識成果，流程如圖 2。研究中使用之資料集由公開資料以及目標隧道之影像資料組成，於研究中測試了不同資料集組成對於模型辨識效果之影響，藉由調整公開資料集以及檢測目標之影像比例，驗證模型於不同訓練資料的辨識能力，資料集名稱及詳細內容見表 1，分為三種資料集，分別測試完全由公開資料組成之模型，以及加入 43 張以及 73 張之目標隧道影像之模型。

研究使用的深度學習模型為 Deeplabv3+、Mask R-CNN 兩種，將經過人工標註過的影像進行影像前處理後匯入深度學習模型內進行訓練，並經由模型於 Intersection-over-Union (IoU) 的表現，評估裂縫辨識的好壞，IoU 的計算如下所示。

$$IoU = \frac{(x \cap y)}{(x \cup y)}$$

由於一個模型可能辨識多種類別，因此在深度學習上以 mIoU 作為指標，mIoU 即為各類別之 IoU 之平均，以裂縫辨識為例，mIoU 為裂縫與背景之 IoU 的平均。各模型之 mIoU 見表 2，辨識輸出影像見圖 3。

表 1 資料集名稱和內容介紹

資料集名稱	資料集組成
10k	即完全由公開資料集組成，包括路面等不同構造物的裂縫特徵，由 90 張隧道影像作驗證，不經過資料增強
CC183	由公開資料集挑選出的 140 張影像，結合目標隧道影像資料集中的 43 張影像而組成，僅由剩下的 47 張作驗證，訓練資料再經過資料增強處理擴大張數
CC213	同 CC183，惟放入目標隧道影像資料集中的 73 張隧道影像，僅由剩下的 17 張作驗證，訓練資料再經過資料增強處理擴大張數





圖 2 隧道裂縫試驗步驟示意圖



(a) 原始資料截圖、(b) 遮罩標註、(c) Mask R-CNN 辨識結果、(d) Deeplabv3+ 辨識結果

圖 3 模型於驗證資料之裂縫辨識成果

表 2 Deeplabv3+ 以及 Mask R-CNN 模型 mIoU

資料集	Mask R-CNN			Deeplabv3+		
	10k	CC183	CC213	10k	CC183	CC213
mIoU	0.5537	0.7135	0.7426	0.4917	0.6602	0.6719

由試驗結果得知 Mask R-CNN 之模型辨識結果優於 Deeplabv3+，推論其原因為 Mask R-CNN 屬於實例分割模型，是基於物件框的結果，再生成物件遮罩，因此針對影像占比極小之裂縫，具有較佳的辨識能力。而在加入較多目標隧道影像之資料集的深度學習模型，裂縫辨識效果較佳，模型最高之 mIoU 可達 0.74，表示加入較多目標影像資料集可以使模型對於隧道的學習成果較佳。

於本文中，除了針對單一目標隧道，亦進行了對不同隧道之影像辨識研究，依深度學習模型訓練原

理，資料集主導了模型的辨識能力，若以未加入不同檢測目標影像之資料集訓練出的模型，將難以完成不同之檢測任務，但僅以該目標影像訓練之模型，雖能夠達成特定辨識任務，但其可能為資料量不足之模型過擬和結果，模型的偵測能力泛用性不足，考量實務需求，研究中將少量其他隧道影像加入資料集中，使模型也能學習到其他隧道之特徵，即能夠達成不錯的辨識成效，見圖 4，此方式能夠避免重新標註大量資料的時間、勞力，也能夠使模型掌握裂縫泛化特徵的辨識能力，若要進一步提高模型於特定目標的辨識準確度，則增加該目標之標註資料即可強化模型辨識能力。

模型應用於橋梁劣化檢測

人工目視巡檢為目前橋梁檢測之最主要採行之方式，傳統的巡檢方式仰賴於工程師專業判釋，由於受




圖 4 另一隧道之模型辨識結果

主觀判斷影響，不同工程師對於同樣建物的填表結果會有所差異，且需會花費大量時間，而傳統人工巡檢過程亦伴隨風險，為檢視特定構件，可能需利用繩索攀附其上，對巡檢人員之人身安危造成風險。人工智慧模型可以針對橋梁影像進行辨識，識別出橋梁的劣化樣態，能夠較全面的對劣化情形進行辨識，而利用無人機等影像蒐集工具也能夠安全的對橋梁影像資料進行收集。

本案例之影像資料包含兩部分，實際橋梁巡檢之劣化樣態影像以及無人機拍攝之橋梁側面影像，針對橋梁之劣化樣態進行辨識，將標註而得之資料組成訓練及驗證資料集，匯入模型進行訓練，並以試誤法調整模型之超參數，最佳化模型的辨識能力。試驗流程見圖 5。

本研究中的辨識目標為多種橋梁劣化樣態，為了能夠將每個劣化樣態清楚分割，研究採用 Mask R-CNN 模型，Mask R-CNN 模型為實例分割模型，相對語義分割及全景分割模型，能夠處理辨識物件重疊現象，能夠得到各別劣化物件的辨識結果，利於後續的分析進行。

於此案例中，檢測類別分為裂縫、噴漿剝落、混凝土破損、鋼筋外露等四類，資料經像素級標註後，組成資料集進行訓練，辨識成果見圖 6 至圖 8。由於該模型資料集中包含橋梁巡檢影像以及無人機拍攝影像，因此能夠學習到兩種資料集之特徵，於兩種類型之測試影像皆能有相當的辨識能力。相較於上一章對隧道裂縫此單一類別的預測，在此多類別辨識的案例中，特徵相近的類別模型有較高機率分類錯誤，其物件框的信心值也可能較低，以噴漿剝落及混凝土破損為例，兩者特徵較為相近，因此分類結果也發生不少誤判情形。

本文測試的模型辨識成果，大多數的劣化都能夠被成功辨識，而研究過程中，也發現影像占比極低的裂縫類別其辨識成果最差，於橋梁巡檢資料中，由於影像資料屬於近照，因此模型尚能辨識出裂縫位置並生成物件框，但 Mask R-CNN 的遮罩可能無法完整涵蓋裂縫像素，而針對無人機之影像，由於影像中裂縫的占比更為低，因此辨識成果較差。

於橋梁檢測案例中，整體而言，Mask R-CNN 具有




圖 5 橋梁異狀檢測試驗步驟示意圖




圖 6 模型於橋梁巡檢劣化樣態影像辨識結果




圖 7 模型於橋梁巡檢劣化樣態影像辨識結果




圖 8 模型於無人機拍攝影像辨識結果

良好的辨識能力，針對噴漿剝落以及混凝土破損此較大面積之類別，辨識效果最佳。模型之辨識能力與辨識目標之特徵相關，相近特徵的類別，則偶有誤判以及辨識之信心值相對較低。辨識目標之影像占比也影響模型辨識成果，影像占比極低之裂縫類別需特別進行模型微調，處理裂縫類別影像占比最直觀之方式為將輸入影像裁剪，並增加含裂縫影像進行模型微調，依實驗結果，此微調方式可使模型改善學習裂縫特徵之成效，並增進辨識能力，模型影像辨識成果見圖 9。




圖 9 裁剪影像之模型辨識成果


人工智慧於結構檢測之挑戰及展望

基於影像分析的人工智慧模型辨識成果會受限於影像資料的品質，若是以較低解析度的影像進行分析，會影響模型的分析成果，同時低解析度的影像也可能無法完整記錄部分構造物異狀，過於細小的異狀將無法被辨識，針對不同的檢測任務需搭配相對應的影像蒐集硬體。

於實際案例分析中，研究發現資料集之特性會強烈影響模型的辨識成果，以隧道裂縫檢測為例，以 A 隧道影像資料訓練之模型無法直接套用於 B 隧道案例上，但藉由將少量 B 隧道影像加入訓練資料集對模型微調，即得以運用於 B 隧道案例上，依文獻回顧與試驗結果分析，目前若要訓練單一人工智慧模型使用於不同的檢測案例是非常困難的事情，較可行的方式為針對不同的檢測目標，在既有的模型上加入部分檢測目標的資料，深度學習模型即可學習到該檢測目標的特徵，使其能夠應用於不同的檢測目標，可以減少為訓練泛用模型所需的龐大資料，也能使模型能於檢測目標上達到最佳成果。

目前人工智慧應用於結構檢測能夠達到約七成的準確率，針對不同的檢測任務以及欲判釋之異狀類別，準確率也有所不同，針對像是裂縫此類影像像素占比極小的類別，辨識效果較差，而影像特徵相似的類別則是可能有誤判的發生。人工智慧模型具備應用於構造物外觀異狀初步快速檢測之發展潛力，目前的辨識準確度已足以應用於異狀檢測上，但模型泛用性仍受限於案例本身資料特性，由於訓練資料主導了模型的辨識能力，因此為滿足實務上準確性的要求，還是需藉由半自動的調整過程，透過加入少量目標案例資料來微調模型權重的方式，使其能夠套用於不同檢測任務，此外，由於影像分割模型僅能判釋構造物外觀異狀，進行較初階之檢測任務，後續辨識結果如何延伸至安全性分析將為應用面上之挑戰。未來之研究發展方向為如何發展不同資料蒐集方式，將更多種類資料加入系統，使其能夠得以進行更深入之判斷，並且能夠擴充相關硬體以及結合資料庫科學等技術，有效建立構造物之結構健康病歷表，以最佳化巡檢流程與設施管理，使未來構造物巡檢更為精確且有效率。

參考資料

- 交通部，「公路橋梁檢測及補強規範」，公路工程部，民國 109 年。
- 蕭牟淵、游本志、王泰典、蕭興臺，「台灣公路隧道安全檢測及評估之研究」，臺灣公路工程第 36 卷第 5 期，民國 98 年。
- Liu, Y. F., Cho, S., Spencer Jr, B. F., and Fan, J. S. (2016). Concrete crack assessment using digital image processing and 3D scene reconstruction. *Journal of Computing in Civil Engineering*, 30(1), 04014124.
- Mohan, A., & Poobal, S. (2018). Crack detection using image processing: A critical review and analysis. *Alexandria Engineering Journal*, 57(2), 787-798.
- Adhikari, R. S., Moselhi, O., and Bagchi, A. (2014). Image-based retrieval of concrete crack properties for bridge inspection. *Automation in construction*, 39, 180-194.
- Salman, M., Mathavan, S., Kamal, K., & Rahman, M. (2013, October). Pavement crack detection using the Gabor filter. In 16th international IEEE conference on intelligent transportation systems (ITSC 2013) (pp. 2039-2044). IEEE.
- Cha, Y. J., Choi, W., Suh, G., Mahmoudkhani, S., and Büyüköztürk, O. (2018). Autonomous structural visual inspection using region based deep learning for detecting multiple damage types. *Computer Aided Civil and Infrastructure Engineering*, 33(9), 731-747.
- Zhang, A., Wang, K. C., Li, B., Yang, E., Dai, X., Peng, Y., and Chen, C. (2017). Automated pixel level pavement crack detection on 3D asphalt surfaces using a deep learning network. *Computer Aided Civil and Infrastructure Engineering*, 32(10), 805-819.
- Kirillov, A., He, K., Girshick, R., Rother, C., and Dollár, P. (2019). Panoptic segmentation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 9404-9413.
- Chen, L. C., Zhu, Y., Papandreu, G., Schroff, F., and Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)*, 801-818.
- He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, 2961-2969. 

110 年 3 月 29 日 資訊委員會工程參訪

本學會資訊委員會於 110.3.29 舉辦臺北市政府工務局「臺北市共同管道建設與智慧營運現況」工程參訪，感謝李惠裕副處長親自介紹及曾俊傑科長簡報。當天出席合計 22 人。

