計畫編號：SWCB-111-052

以深度學習模型發展智慧型影像分割應用於判識水土保持設施水泥表面裂損之研究分類

A Study of Developing Intelligent Image Segmentation Based on Deep Learning for Detection on Surface Defects of Concrete Structure for Water and Soil Conservation Facilities

成果報告書

執 行 單 位：國立中興大學

執 行 期 間：111 年 01 月 18 日至 111 年 12 月 31 日

計畫主持人 ：蔡鴻旭 教授

行政院農業委員會水土保持局　編印

中華民國 111 年 12 月

（本報告書內容及建議純屬執行單位意見，僅供本局施政參考）

以深度學習模型發展智慧型影像分割應用於判識水土保持設施水泥表面裂損之研究分類

摘要

近期物聯網的攝影監測已常見運用於水土保持研究領域，利用固定式攝影功能可建立水土保持樣態歷程、藉由影像分析可監測水土保持設施表面是否有裂損?目前上述工作，仍須人工介入來觀察水土保持設施表面否有裂損。因此，本計畫挑戰上述問題，利用人工智慧的深度學習影像分類及分割技術來克服上述問題，降低人工介入及建置工作。但是收集水土保持設施表面是否有裂損的影像不易，目前蒐集影像不多式普遍遇到瓶頸問題，因此，本計畫發展遷移學習中領域自適應技術克服上述少樣本問題，另外、也發展深度學習為基礎的影像分割及影像分類模型，本計畫有三項成果，兩階段影像裂隙影像偵測與分割模型，智慧型混凝土表面裂隙影像區塊偵測模型及智慧型混凝土表面裂隙影像分割模型，上述三項模型實作分類技術應用於自動判識水土保持設施中護岸與護坡之混擬土表面是否裂隙(裂隙或碎損)，最後，以響應式網頁提供使用者體驗三項模型自動判識成果。

關鍵詞：**影像分類、影像分割、深度學習、區域卷積神經網路、生成對抗網路、遷移學習、領域自適應、表面瑕疵、水土保持設施**

A Study of Developing Intelligent Image Segmentation Based on Deep Learning for Detection on Surface Defects of Concrete Structure for Water and Soil Conservation Facilities

Abstract

Recently, surveillance cameras in Internet of Things (IOT) are often applied in research area of water-and-soil conservation. Images are getting from fixed surveillance cameras can be used in construction of portfolio of changes of water-and-soil conservation area. By image analysis on these images, it can automatically detect the defects of concrete surfaces of the facilities such as embankment, slope protection, etc. That is, defects on the concrete surfaces of the facilities may occur crack, damage or other irregular changes. Up to now, it still relies on human who often monitor the detections on the surfaces of concretes for the facilities. Conventionally, the project will challenge above detection problems by image analysis based on deep learning. Here the project suffers from the difficulties getting lots of crack or damage images for training detection models. To overcome the problem, the project has attempt to apply Domain Adaption (DA) Training of Transfer Learning (TL) in devising image classification and segmentation schemes for the situation of less training images, which will be applied in detecting crack or damage on concrete surfaces images of embankment or slope protection facilities. There are three crack detection models are developed in the project, two-stage crack detection of concrete surfaces images based on block image classification and segmentation, crack detection of concrete surfaces images based on block image classification with domain adaption, and crack detection of concrete surfaces images based on block image segmentation with domain adaption. Finally, three models are implemented by Responsive Web Design (RWD)

for users' experience in crack detection of concrete surfaces images.

Keywords： Image Classification, Image segmentation, Deep Learning, Region Based Convolutional Neural Networks, Generative Adversarial Network, Transfer Learning, Domain Adaption Learning, Surface Defects, Soil and Water facilities

目次

摘要.....I

Abstract.....II

目次.....IV

表次.....VII

圖次.....VIII

第一章 計畫內容.....1

第一節 計畫動機.....1-1

第二節 計畫目的.....1-3

第三節 背景.....1-4

一、 自適應領域學習分類(Domain Adaptation for Classification).....1-4

二、 自適應領域學習分割(Domain Adaptation for Segmentation).....1-7

三、 Gard-CAM 模型可視化.....1-8

四、 DenseNet.....1-9

五、 影像分割效能量化指標.....1-11

第二章 工作項目與執行方法.....2-1

第一節 工作項目.....2-1

第二節 工作方法.....2-3

一、 實驗影像資料庫收集與建置之研究.....2-3

二、 標記影像.....2-**錯誤! 尚未定義書籤。**

三、 兩階段影像裂隙影像偵測與分割模型之研究.....2-3

四、 智慧型混凝土表面裂隙影像區塊偵測之研究.....2-3
五、 智慧型混凝土表面裂隙影像分割之研究.....2-4
六、 響應式網頁呈現混凝土表面裂隙影像偵測與分割模型.....2-4
第三節 工作執行步驟.....2-5
一、**主題(1):** 實驗影像資料庫收集與建置之研究.....2-5
二、**主題(2):** 標記影像.....2-9
三、**主題(3):** 兩階段影像裂隙影像偵測與分割模型之研究.....2-13
四、**主題(4):** 智慧型混凝土表面裂隙影像區塊偵測之研究.....2-28
五、**主題(5):** 智慧型混凝土表面裂隙影像分割之研究.2-43
六、**主題(6):** 響應式網頁呈現混凝土表面裂隙影像偵測與分割模型.....2-51
第三章 執行成果及效益.....3-1
第一節 執行成果.....3-1
第二節 執行效益.....3-2
第四章 結論及建議.....4-1
第一節 結論.....4-1
第二節 建議.....4-2
2
參考文獻..... 參-1
附錄..... 附錄-1
附錄一、111 年水保局創新研究計畫審查意見暨回覆說明 附錄-1
附錄二、111 年期初工作執行計畫書審查意見暨回覆說明 附錄-4

附錄三、111 年期中報告書審查意見暨回覆說明 附錄-9
附錄四、兩階段影像裂隙影像分割結果 附錄-14
附錄五、智慧型混凝土表面裂隙影像區塊偵測結果..... 附錄-15
附錄六、智慧型混凝土表面裂隙影像分割結果..... 附錄-16
附錄七、實地拍攝水土保持設施(頭汴坑) 附錄-17
附錄八、111 年水保局創新研究計畫期末報告審查意見暨回覆說明……...附錄-19

表次

表 2-1:實驗影像來源及數量說明……..……..……..…….....2-5

表 2-2: 影像來源及數量……....2-18

表 2-3:模型訓練超參數……..…....2-19

表 2-4: 影像來源及數量……...2-22

表 2-5:模型訓練超參數……..…....2-23

表 2-6: 影像來源及數量……...2-25

表 2-7:模型訓練超參數……..……...2-26

表 2-8: 影像來源及數量……...2-31

表 2-9：有無使用 DA 之比較表…….....2-37

表 2-10: SOURCE IMAGE 和 TARGET IMAGE 影像集數量及來源...2-45

表 2-11: DA MODEL 在不同的測試結果……....2-50

圖次

圖 1-1: 本計畫系統架構含六主題與各主題間的關聯流程圖.....1-2

圖 1-2: 自適應領域範例說明…….....1-4

圖 1-3: 自適應領域學習技術二分類範例說明……...1-5

圖 1-4: 自適應領域學習權重更新架構圖..……1-6

圖 1-5: DA FOR SEGMENTATION 之架構..…...……1-7

圖 1-6：GRAD-CAM 流程圖...……1-8

圖 1-7：DENSENET 架構圖…….……1-9

圖 2-1: 本計畫系統架構含六主題與各主題間的關聯流程圖…….2-2

圖 2-2: 歷史影像平台蒐集裂隙影像範例……....2-5

圖 2-3: KAGGLE 道裂隙檢測影像範例…….....2-6

圖 2-4: KAGGLE 混凝土橋面、牆壁裂隙影像範例. ……..2-7

圖 2-5: KAGGLE 混凝土路面裂隙影像範例……...2-7

圖 2-6: KAGGLE 混凝土路面裂隙影像範例……...2-8

圖 2-7: 水土保持局設施提供混凝土缺失影像集範例……...2-9

圖 2-8: 護岸裂隙影像標註範例…….....2-10

圖 2-9: 護岸裂損影像標註範例…….....2-11

圖 2-10: 護坡裂隙影像標註範例…….....2-11

圖 2-11：影像裂損區塊影像資料集及其標註流程圖……...2-13

圖 2-12: 水土保持設施混凝土表面影像偵測異常範例……....2-14

圖 2-13:兩階段混凝土裂隙影像偵測與分割模型流程……....2-14

圖 2-14: FCN 模型架構……..2-15

圖 2-15: FCN 之 UPSAMPLING 流程……..2-16

圖 2-16:FCN 計算單元……..2-16

圖 2-17: 水土保持設施表面影像集……..2-17

圖 2-18:混凝土表面影像分割流程概念圖……..2-18

圖 2-19:混凝土表面影像分割模型訓練損失函數曲線……..2-19

圖 2-20:混凝土表面影像分割模型訓練指標曲線……..2-20

圖 2-21:混凝土裂隙影像範例……..2-21

圖 2-22:裂隙影像分割流程概念圖……..2-22

圖 2-23:混凝土裂隙影像分割模型訓練損失函數曲線……..2-24

圖 2-24:混凝土裂隙影像分割模型訓練指標曲線……..2-24

圖 2-25:混凝土裂隙預測影像……..2-25

圖 2-26:兩階段混凝土裂隙影像偵測模型流程……..2-26

圖 2-27:兩階段混凝土裂隙混凝土裂隙偵測模型訓練損失函數曲線……..2-27

圖 2-28:兩階段混凝土裂隙混凝土裂隙偵測混淆矩陣……..2-28

圖 2-29:兩階段混凝土裂隙混凝土裂隙偵測混淆矩陣……..2-28

圖 2-30: 概念架構圖……..2-29

圖 2-31: SOURCE DOMAIN 與 TARGET DOMAIN 影像集……..2-30

圖 2-32: 影像增廣流程圖……..2-32

圖 2-33: 深度類神經網路模型架構圖……..2-33

圖 2-34: 測試階段輸出顯著圖與類別……..2-34

圖 2-35: 影像裂損辨識流程圖……..2-35

圖 2-36：學習曲線圖……..2-39

圖 2-37:未使用 DA 之混淆矩陣……...2-40

圖 2-38: 使用 DA 之混淆矩陣……2-41

圖 2-39：T-SNE 特徵視覺化……...2-43

圖 2-40: 智慧型混凝土表面裂隙影像分割模型……....2-44

圖 2-41: SOURCE IMAGE、SOURCE MASK 和 TARGET IMAGE 範例...2-45

圖 2-42: 領域自適應學習影像分割模型訓練架構……....2-46

圖 2-43: 領域自適應學習影像分割模型測試架構……....2-48

圖 2-44: DA 模型之 LEARNING CURVE...……..2-50

圖 2-45:響應式網頁呈現兩階段影像分割結果……...2-52

圖 2-46: 響應式網頁呈現影像偵測結果……..2-53

圖 2-47: 響應式網頁呈現影像分割結果……..2-54

第一章 計畫內容

第一節　計畫動機

近期無人機拍攝科技快速進步及物聯網的攝影監測愈來愈普遍，上述科技已常見運用於水土保持研究領域，例如，用無人機拍攝特定水土保持區域來建立其水土保持樣態歷程、攝影監測水土保持設施監測其安全性、山坡裸露地觀察及裸露區比例量化計算等等。可是，目前上述工作，仍須人工介入來觀察水土保持設施表面是否異常?人工框出裸露區塊後再觀察及裸露量化計算? 人工套疊水土保持樣態中各項物件來建立樣態歷程。因此，本計畫欲挑戰上述問題，發展遷移學習中領域自適應技術克服上述少樣本問題，另外、也發展深度學習為基礎的影像分割及影像分類模型，本計畫有三項成果，兩階段影像裂隙影像偵測與分割模型，智慧型混凝土表面裂隙影像區塊偵測模型及智慧型混凝土表面裂隙影像分割模型，上述三項模型實作分類技術應用於自動判識水土保持設施中護岸與護坡之混擬土表面是否裂隙(裂隙或碎損)，最後，以響應式網頁提供使用者體驗三項模型自動判識成果。圖 1-1 說明本計畫各主題關聯圖。

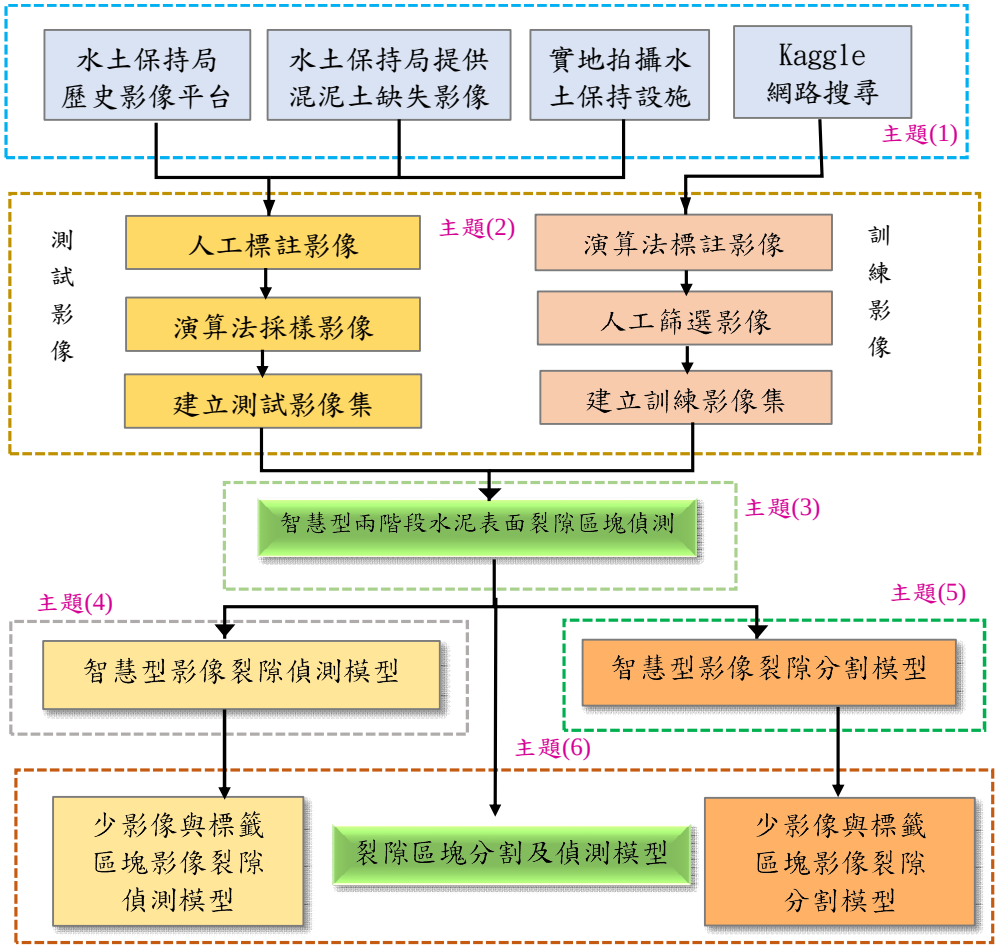


圖 1-1：本計畫系統架構含六主題與各主題間的關聯流程圖

第二節　計畫目的

本年度計畫目標為完成下列工作項目。

- 發展兩階段影像裂隙影像偵測與分割模型之研究。
- 發展智慧型混凝土表面裂隙影像區塊偵測之研究。
- 發展智慧型混凝土表面裂隙影像分割之研究。

第三節　背景

一、自適應領域學習分類(Domain Adaptation for Classification)

自適應領域學習 [1] 主要用來減緩訓練資料集與測試資料集差異所帶來的效能降低。圖 1-2 說明其差異範例可由 MNIST 與 M-MNIST 資料集看出。

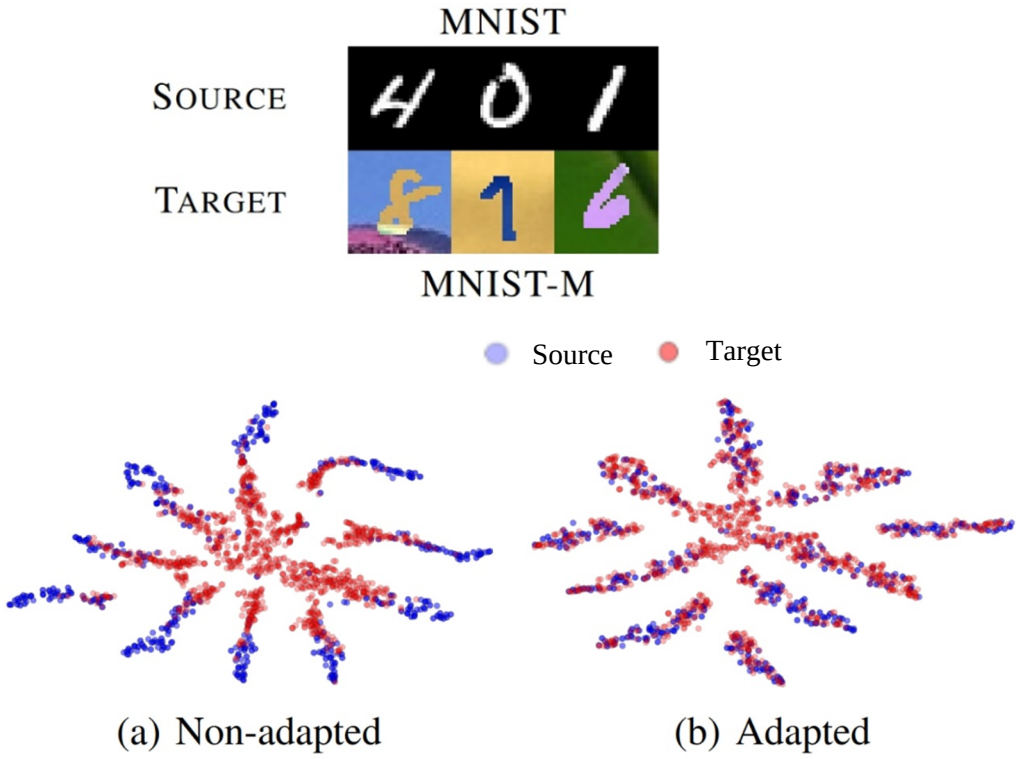


圖 1-2: 自適應領域範例說明

(資料來源：https://arxiv.org/pdf/1409.7495.pdf)

此問題假設來訓練資料集來自 source domain $\mathcal{D}_s$、測試資料集來自 target domain $\mathcal{D}_t$。令$(X_s, y_s) \in \mathcal{D}_s$, $(X_t, y_t) \in \mathcal{D}_t$，$X_s, X_t$分別為 source domain 與 target domain 的影像、y_s, y_t分別為 source domain 與 target domain 的類別標籤，在此y_t是未知的。令G_f, G_y, G_d分別為 feature extractor、classifier 和 domain discriminator。由於

G_f, G_y是由$\mathcal{D}_s$訓練出來的且X_s, X_t來自不同的 domain，為了讓G_y能夠正確分類X_t，$G_f(X_s)$和$G_f(X_t)$需要來自同一個 domain，圖 1-3 說明自適應領域學習技術二分類範例。

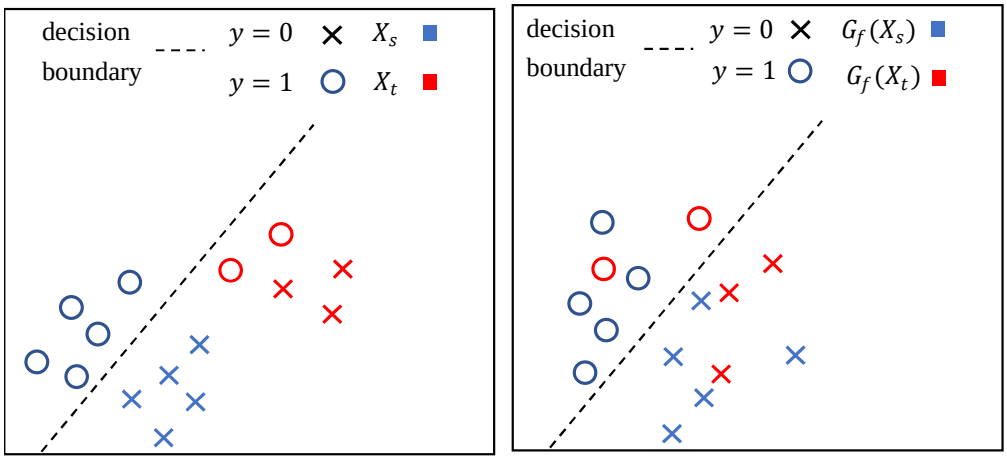


圖 1-3: 自適應領域學習技術二分類範例說明

圖 1-4 說明自適應領域學習權重更新流程。要G_f訓練成具有將X_s, X_t encode 成同一 domain 的 feature extractor 需要依靠G_d的輔助。在此架構中，G_d需要努力去判別$G_f(X)$來自哪一個 domain。而G_f則要盡量混淆G_d[1]。

假設$\theta_f, \theta_y, \theta_d$分別為$G_f, G_y, G_d$的權重，則損失函數分別為分類損失函數$\mathcal{L}_y$與 domain 損失函數$\mathcal{L}_d$，其定義如下：

$$\mathcal{L}_y(y, X) = \begin{cases} -\log G_y\left(G_f\left(X;\theta_f\right);\theta_y\right) & ,if\ y = 1 \\ -\log\left(1 - G_y\left(G_f\left(X;\theta_f\right)\right);\theta_y\right), & if\ y = 0 \end{cases}$$

$$\mathcal{L}_d(d, X) = \begin{cases} -\log G_d\left(G_f\left(X;\theta_f\right);\theta_d\right) & ,if\ d = d_t \\ -\log\left(1 - G_d\left(G_f\left(X;\theta_f\right)\right);\theta_d\right), & if\ d = d_s \end{cases}$$

在此，額外定義 domain 標籤$d_s = 0, d_t = 1$分別表示 source domain 和 target domain。此架構的重點在於權重的更新，以下式子說明$\theta_f, \theta_y, \theta_d$三個權重如何利用梯度下降進行更新：

$$\theta_y := \theta_y - \frac{\partial \mathcal{L}_y}{\partial \theta_y}$$

$$\theta_d := \theta_d - \frac{\partial \mathcal{L}_d}{\partial \theta_d}$$

$$\theta_f := \theta_f - \frac{\partial \mathcal{L}_y}{\partial \theta_f} + \frac{\partial \mathcal{L}_d}{\partial \theta_f}$$

值得注意的是在更新θ_d與θ_f的梯度中，對$\mathcal{L}_d$的梯度相反的，即G_f希望極大化$\mathcal{L}_d$而G_d希望極小化$\mathcal{L}_d$。此設計使得權重在迭代過程中G_f與G_d得以互相對抗，最後得出足以混淆G_d的G_f。

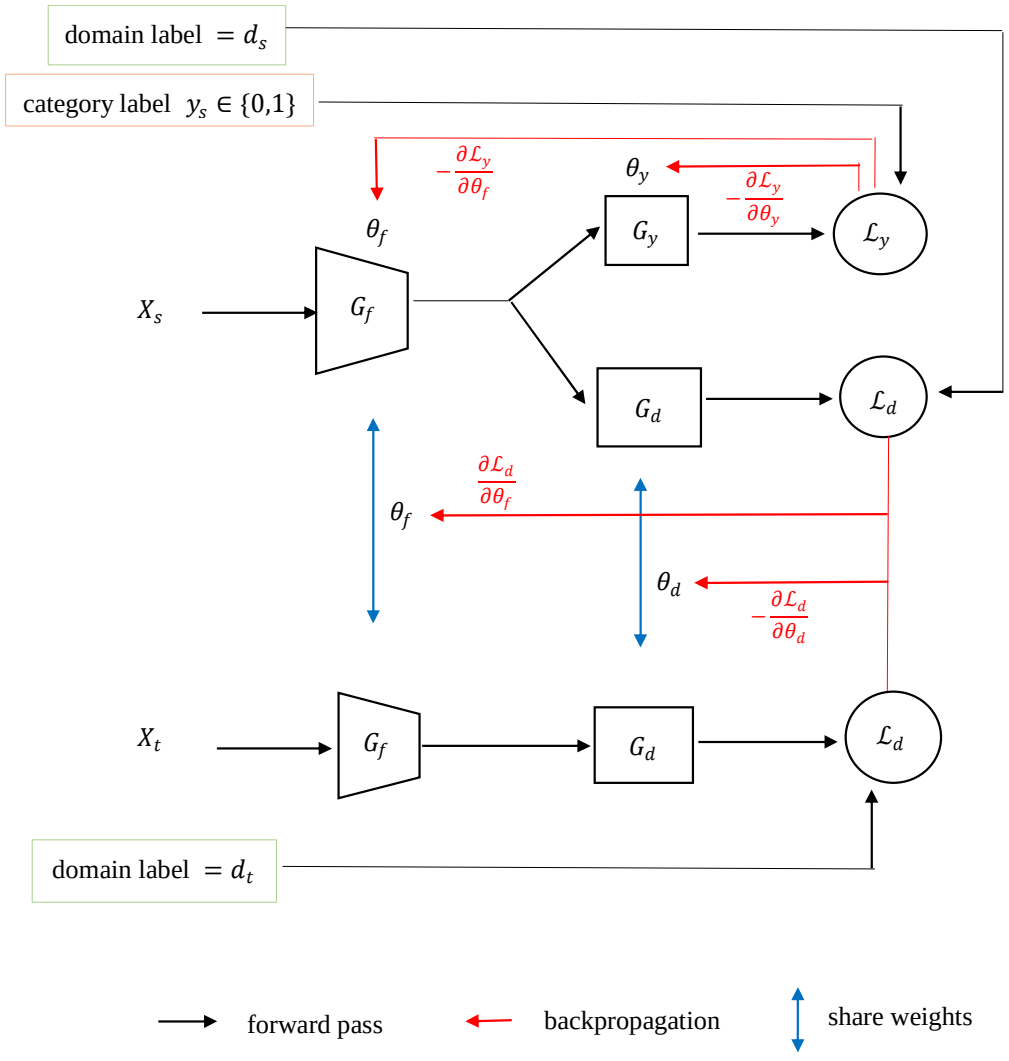


圖 1-4: 自適應領域學習權重更新架構圖

二、自適應領域學習分割(Domain Adaptation for Segmentation)

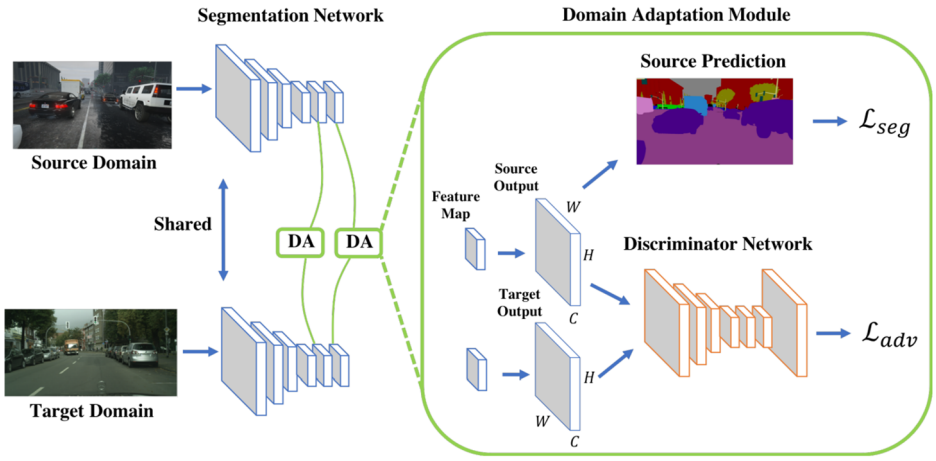


圖 1-5: DA for segmentation 之架構[2]

以下介紹 DA for image segmentation 之架構及技術[2]。圖 1-5，首先，輸入一張 Source image(I_s)，經過分割網路(Segmentation Network, G)，然後得到影像分割結果 Source Output ($\hat{Y}_s \in \mathbb{R}^{H\times W\times C}$)並和其配對的標準答案$Y_s$計算損失函數$\mathcal{L}_{seg}$。然後，輸入一張未標註的 Target Image(I_t)進 G 並得到其輸出結果 Target Output ($\hat{Y}_t \in \mathbb{R}^{H\times W\times C}$)。最後，將$\hat{Y}_s$和$\hat{Y}_t$分別輸入到辨別網路(Discriminator Network, D)得到預測結果。損失函數$\mathcal{L}_{seg}$計算如下列兩式。

$$\min_{G}\{\mathcal{L}_{seg} = -\sum_{ij}\sum_{y_{ij}} y_{s_{ij}} \log \hat{y}_{s_{ij}}\}$$

$$\min_{G}\max_{D}\{\mathcal{L}_{adv} = \log D(\hat{Y}_s) + \log\left(1 - D(\hat{Y}_t)\right)\}$$

此架構的 G 透過 Source 資料集學習做影像分割任務，並透過

對抗損失函數$\mathcal{L}_{adv}$來使與 Source 資料集影像性質相近但有差異的 Target 資料集的預測結果(形狀, 模態)接近 Source 資料集的預測結果。

三、Gard-CAM模型可視化

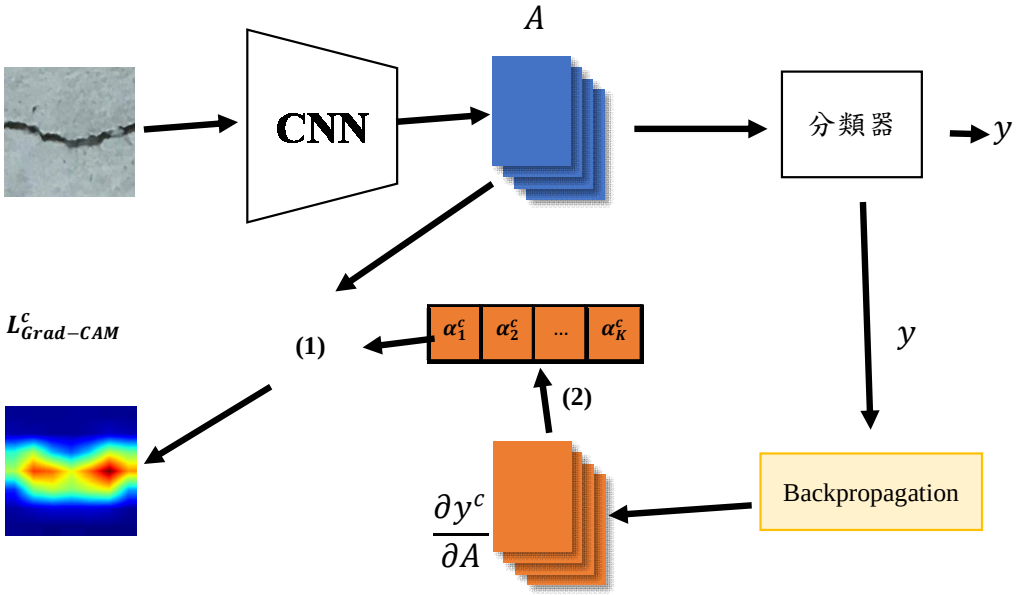


圖 1-6：Grad-CAM 流程圖

圖 1-6 表示 Grad-CAM[3] 為由 CAM[4] 衍生而來之 CNN 模型視覺化技術，可以用來生成 saliency map。令A為 CNN 輸出之K張 $H \times W$ feature map，其中A_{ij}^k為第k個 channel 上之第i列、第j行 pixel 的值。y^c為分類器對第c之預測機率。利用α_k^c與 feature map A^k的線性組合的出的$\boldsymbol{L^c_{Grad-CAM}}$即為 saliency map。計算說明如下

$$L^c_{Grad-CAM} = Relu\left(\sum_k \alpha_k^c A^k\right)$$

$$\alpha_k^c = \frac{1}{HW}\sum_{i,j}\frac{\partial y^c}{\partial A_{ij}^k}$$

四、DenseNet

DenseNet[5] 是一種 CNN 模型，圖 1-7 說明其架構，DenseNet 將淺層 layers 之輸出 feature map 對 channel 進行 concatenate，合成後之 feature maps 將成為下一個 layer 的輸入。此模型的特點是透過此多項前層輸入之設計。與 ResNet[6] 相同，可以緩解梯度消失問題。此外，DenseNet 還可以加強特徵重用以及減少參數。

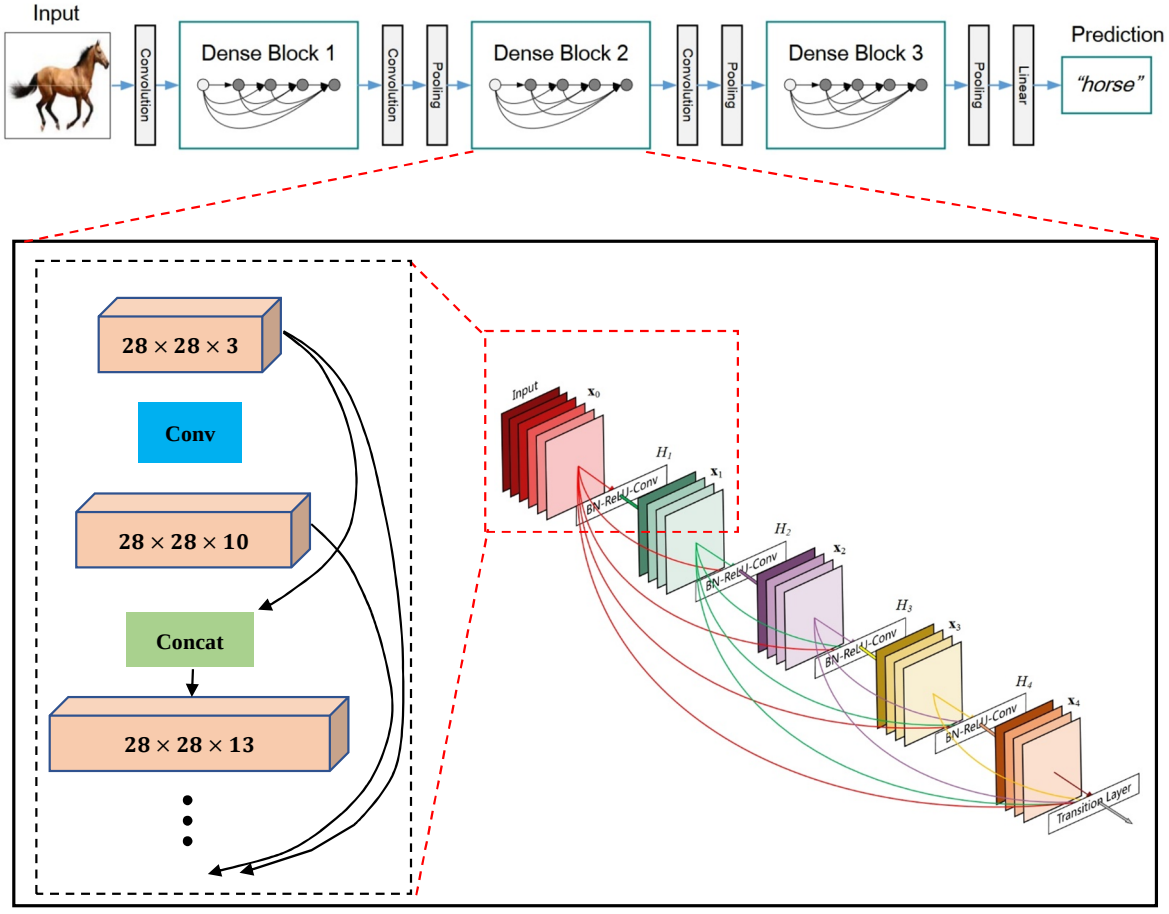
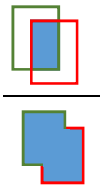


圖 1-7：DenseNet 架構圖

五、影像分割效能量化指標

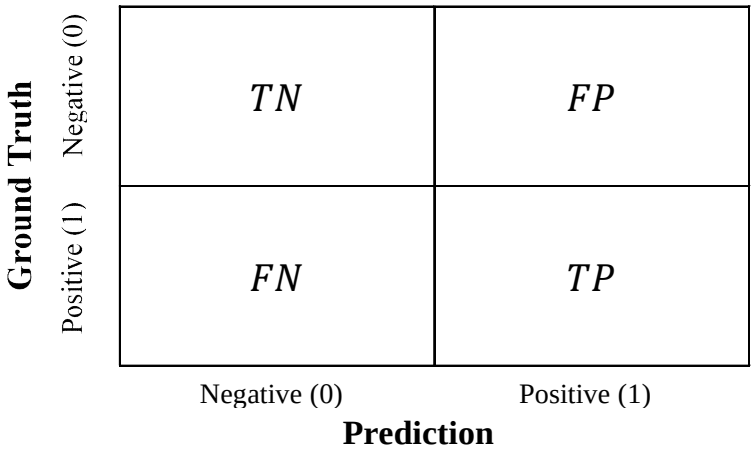
- IoU: 其公式如下

$$\text{IoU} = \frac{\text{area}(gt \cap pd)}{\text{area}(gt \cup pd)} =$$



green: Ground-truths

- 二元分類之 Confusion Matrix



Prediction 為預測結果，有 Negative 與 Positive 兩種可能。

Ground Truth 為真實情況，有 Negative 與 Positive 兩種可能。

Negative 以 0 表示、Positive 以 1 表示。

TP:預測與真實皆為 Positive 的樣本數

FP:預測為 Positive 但是真實為 Negative 的樣本數

FN:預測為 Negative 但是真實為 Positive 的樣本數

TN:預測與真實皆為 Negative 的樣本數

- Precision: 其公式如下

$$\text{Precision } p = \frac{\text{TP}}{TP + FP} = \frac{TP}{all\ detections}$$

- *Accuracy*: 其公式如下

$$\text{Accuray} = \frac{\text{TP} + \text{TN}}{TP + FN + TN + FP} = \frac{TP + TN}{all\ ground\ truths}$$

- PA(Pixel-level Accuracy): 其公式如下

$$PA = \frac{1}{pixel_{total}} \sum_{i \in img} \text{Accuray}_{i}$$

- $MIoU$(Mean IoU): 其公式如下

$$MIoU = \frac{1}{|classes|} \sum_{c \in classes} IoU_c$$

- AP: the Area Under the PR Curve (AUC-PR) 即 AP at IoU 要超過 50%，其公式如下。

$$\text{AP(AP@50)} = \int_0^1 p(r)dr$$

- mAP: m 張影像的平均 AP，其公式如下

$$\text{mAP(mAP @50)} = \frac{1}{m}\sum_{i=1}^{m} AP_i$$

mAP@50 : mean Average Precision at IoU threshold of 50%。

第二章 工作項目與執行方法

第一節　工作項目

圖 2-1 說明各主題間與各議題間的關聯流程圖，本計畫工作項目如下所述。

- 主題(1): 實驗影像資料庫收集與建置之研究。
- 主題(2): 影像前處理及影像標註。
- 主題(3): 兩階段影像裂隙影像偵測與分割模型之研究。
- 主題(4): 智慧型混凝土表面裂隙影像區塊偵測之研究。
- 主題(5): 智慧型混凝土表面裂隙影像分割之研究。
- 主題(6): 響應式網頁呈現混凝土表面裂隙影像偵測與分割模型。

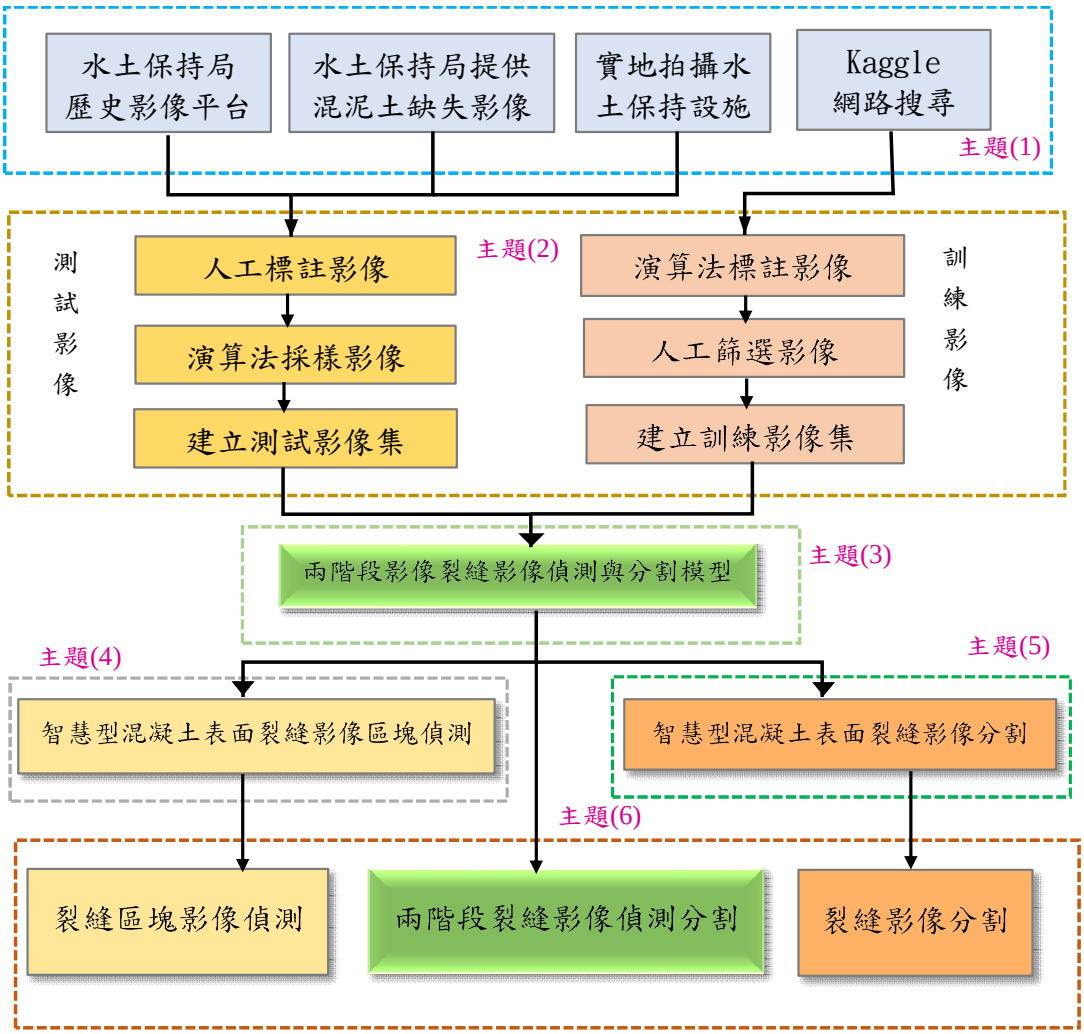


圖 2-1: 本計畫系統架構含六主題與各主題間的關聯流程圖。

第二節　工作方法

一、實驗影像資料庫收集與建置之研究

(一) 議題 1-1: 收集水土保持局的土砂災害歷史影像平台的影像

(二) 議題 1-2: 收集網路上的已標註影像

(三) 議題 1-3: 蒐集水土保持局設施提供混凝土缺失影像集

(四) 議題 1-4: 實地拍攝水土保持設施影像

二、影像前處理及影像標註

(一) 議題 2-1: 標註裂隙影像

(二) 議題 2-2: 區塊影像集及標註

三、兩階段影像裂隙影像偵測與分割模型之研究

(一) 議題 3-1: 發展影像分割模型。

(二) 議題 3-2: 水土保持混凝土設施影像分割。

(三) 議題 3-3: Kaggle 裂隙影像分割。

(四) 議題 3-4: 兩階段混凝土裂隙影像偵測。

(五) 議題 3-5: 測試兩階段混凝土裂隙分割及分類效能。

四、智慧型混凝土表面裂隙影像區塊偵測之研究

(一) 議題 4-1: Source 與 target domain 影像資料集說明。

(二) 議題 4-2: 影像增廣。

(三) 議題 4-3: 區塊影像裂隙偵測模型之訓練架構設計

(四) 議題 4-4: 區塊影像裂隙偵測模型之測試架構設計

(五) 議題 4-5: 實驗效能評估

五、智慧型混凝土表面裂隙影像分割之研究

(一) 議題 5-1: Source 與 Target domain 影像資料集說明。

(二) 議題 5-2: 領域自適應學習影像分割模型訓練架構設計。

(三) 議題 5-3: 領域自適應學習影像分割模型測試架構設計。

(四) 議題 5-4: 判識影像是否含有裂隙

(五) 議題 5-5: 實驗效能評估

六、響應式網頁呈現混凝土表面裂隙影像偵測與分割模型

(一) 議題 6-1: 兩階段影像裂隙影像偵測與分割模型之響應式網頁呈現。

(二) 議題 6-2: 智慧型混凝土表面裂隙影像區塊偵測之響應式網頁呈現。

(三) 議題 6-3: 智慧型混凝土表面裂隙影像分割之響應式網頁呈現。

第三節　工作執行步驟

一、主題(1): 實驗影像資料庫收集與建置之研究

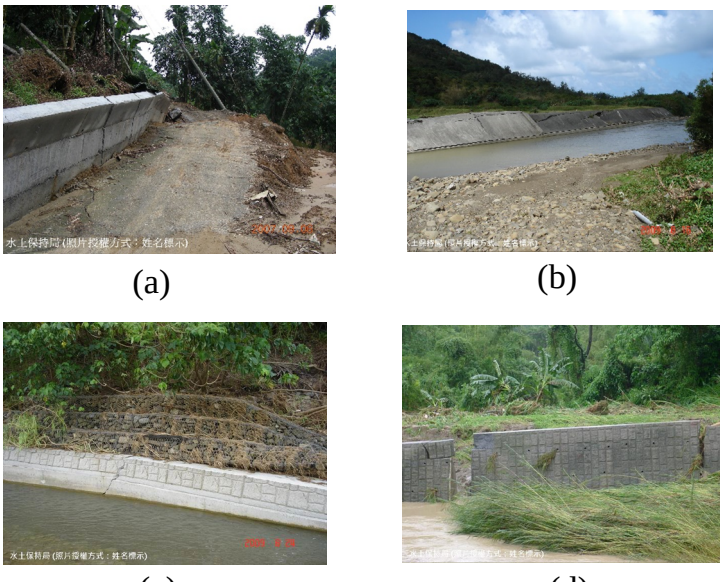
本主題初步針對特定水土保持相關網頁並蒐集相關水土保持護岸裂隙影像。其相關議題如下:

議題 1-1: 收集水土保持局的土砂災害歷史影像平台的影像

篩選混凝土護岸裂隙與混凝土護坡裂隙兩類照片。目前已收集595 張護岸相關影像、164 張護坡相關影像，將挑選混凝土護岸裂隙與混凝土護坡裂隙影像，數量如表 2-1 所述，其將作為本計畫模型測試影像。

表 2-1:實驗影像來源及數量說明

類別	數量
混凝土護岸裂隙	12
混凝土護坡裂隙	10



(a)　(b)

(c)　(d)

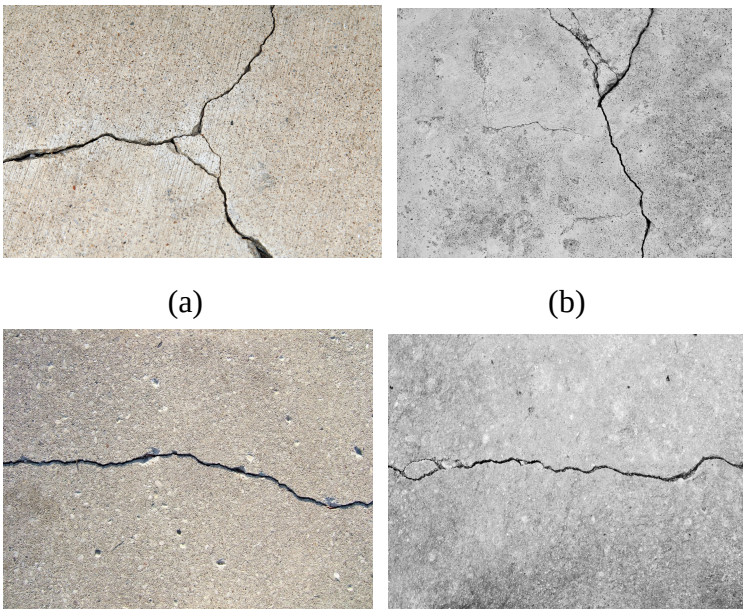
圖 2-2:　歷史影像平台蒐集裂隙影像範例

議題 1-2: 收集網路上已標註影像

目前由 Kaggle 平台有搜尋到 4 個有關混凝土表面裂隙影像資料集，挑選裂隙影像來觀察其影像特性，並整理成本計畫模型訓練影像。

❍道裂隙檢測

https://www.kaggle.com/hussainsalih/streetcrackdetection?select=Image



(a) (b)

(c) (d)

圖 2-3: Kaggle 道裂隙檢測影像範例

❍ 混凝土橋面、牆壁和人行道裂隙

https://www.kaggle.com/aniruddhsharma/structural-defects-network-concrete-crack-images?select=Decks

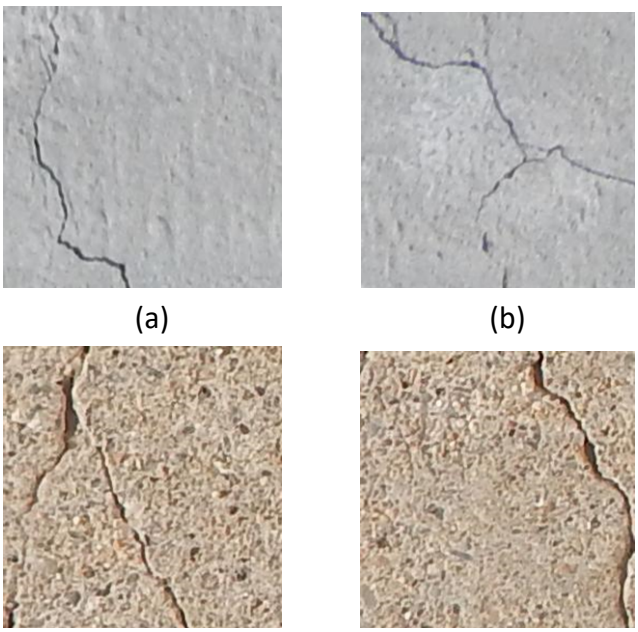


圖 2-4: Kaggle 混凝土橋面、牆壁裂隙影像範例

❍路面裂隙影像分割

https://www.kaggle.com/datasets/lakshaymiddha/crack-segmentation-dataset

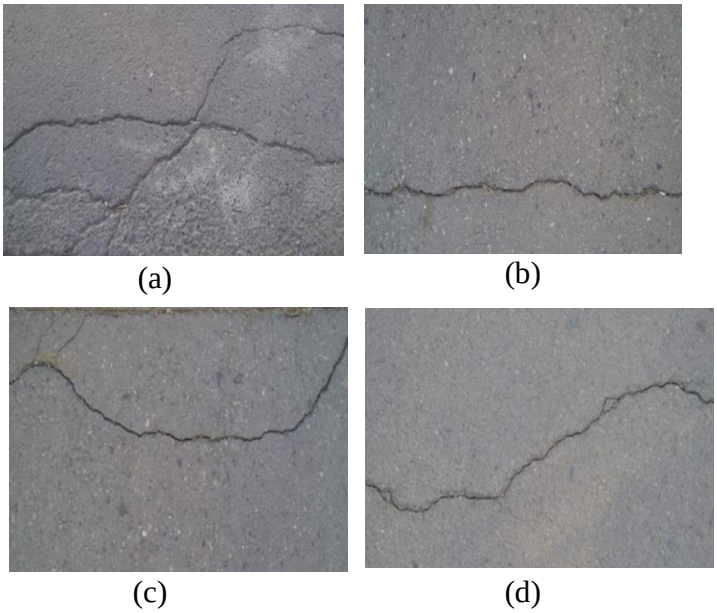
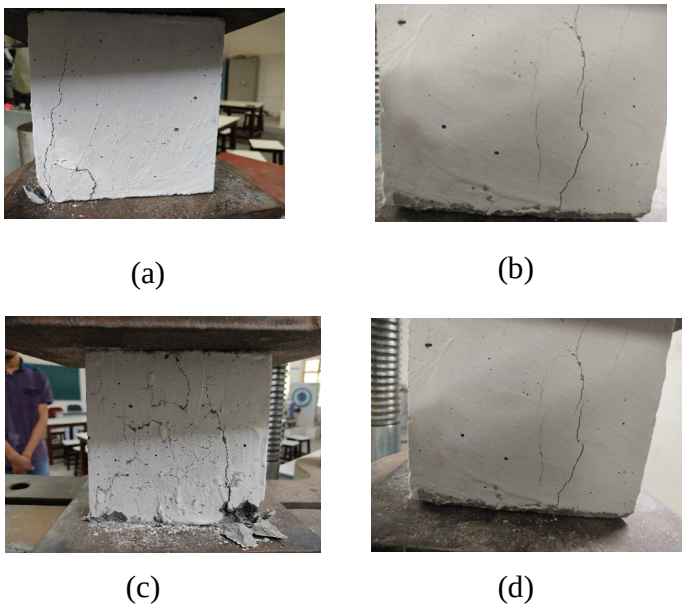


圖 2-5: Kaggle 混凝土路面裂隙影像範例

❍混凝土設施裂隙影像

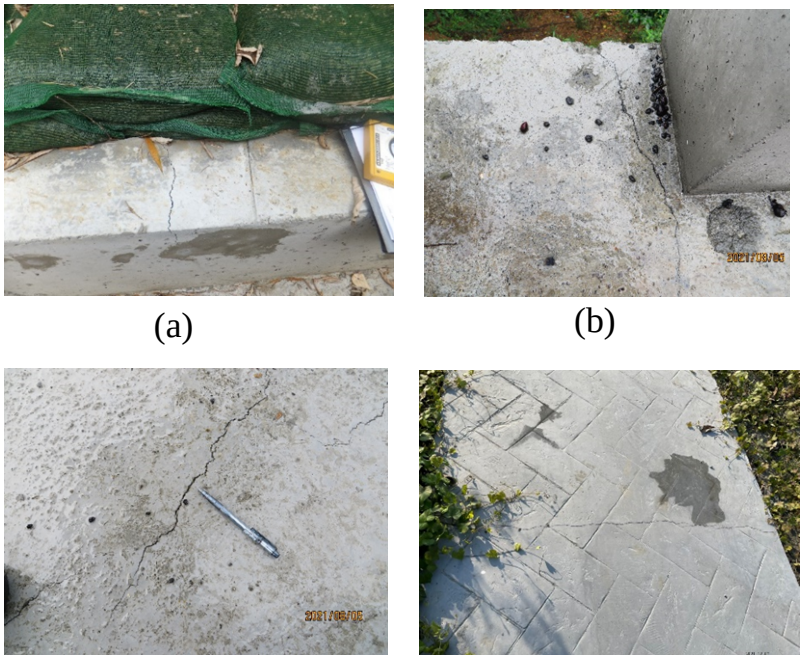
https://www.kaggle.com/datasets/roxystar/standard-cement-concrete-crack-segmentationdataset



(a) (b)

(c) (d)

圖 2-6: Kaggle 混凝土路面裂隙影像範例



(a) (b)

(c) (d)

圖 2-7: 水土保持局設施提供混凝土缺失影像集範例

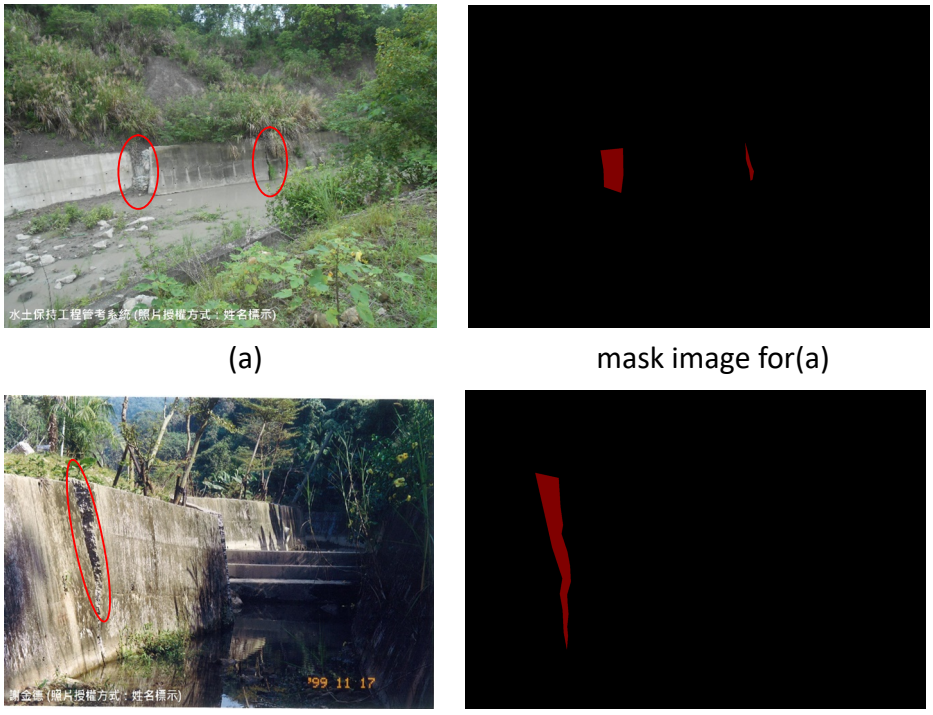
議題 1-3: 蒐集水土保持局設施提供混凝土缺失影像集

由水土保持局提供之混凝土巡檢影像集，將挑選有混凝土表面裂隙影像來觀察其影像特性，並整理成本計畫測試影像。圖 2-7 說明蒐集之混凝土缺失影像。

二、**主題(2):** 影像前處理及影像標註

議題 2-1: 標註裂隙影像

圖 2-8~圖 2-10 說明本計畫標註混凝土護岸及混凝土裂隙影像，其中部分為裂損影像。



(a) mask image for(a)

(b) mask image for(b)

圖 2-8: 護岸裂隙影像標註範例(左)原始影像(右)人工標註影像

❍護岸裂損



(a)



mask image for (a)



(b)

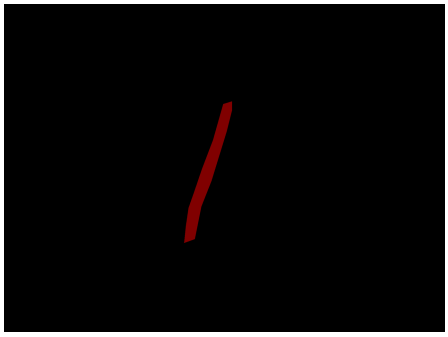


mask image for (b)

圖 2-9: 護岸裂損影像標註範例(左)原始影像(右)人工標註影像護坡裂隙



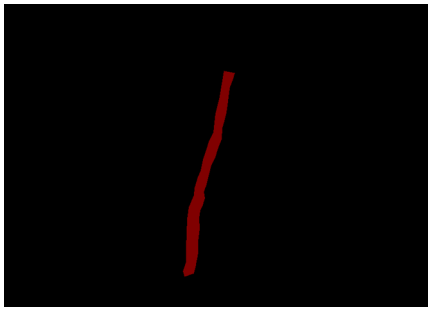
(a)



mask image for(a)



(b)



mask image for(b)

圖 2-10: 護坡裂隙影像標註範例(左)原始影像(右)人工標註影像

議題 2-2: 區塊影像集及標註

圖 2-11 表示本議題生成裂隙影像辨識之概念流程圖。其中 $I \in R^{V\times H}, Y = I_{masked} \in \{0,1\}^{V\times H}$ 分別為影像、標註影像，為 I_{masked} 之 pixel label，H 與 V 分別為 I 之寬與高。其中 $Y_{ij} = 1$ 表示對應 pixel I_{ij} 屬於裂隙，即 $Y_{ij} = \begin{cases} 1, & if\ I_{ij}\ is\ crack \\ 0, & otherwise \end{cases}$。

為了 n_B 個區塊影像為 B_{img}，令隨機生成演算法 $\mathcal{A}_{sample}$，其定義如下。

$$\mathcal{A}_{block}(I, I_{masked}, n_B; k_v, k_h) = \{B_{img}^l | l = 1,2,\dots,n_B\}$$

該演算法將 I_{masked} 以 sliding window 的方式生成 n_B 個(矩形區塊影像,標註)所構成之集合 B_{sample}，其中 $B_{sample}^l = (B_{img}^l, B_{mask}^l)$。接著，利用 labeling 演算法 $\mathcal{A}_{label}$ 判斷 B_{img}^l 之類別。

令 $B_{sample}^l = (B_{img}^l, B_{mask}^l)$

$$= \left(\begin{bmatrix} I_{(i,j)} & \cdots & I_{(i,j+k_h)} \\ \vdots & \ddots & \vdots \\ I_{(i+k_v,j)} & \cdots & I_{(i+k_v,j+k_h)} \end{bmatrix}, \begin{bmatrix} Y_{(i,j)} & \cdots & Y_{(i,j+k_h)} \\ \vdots & \ddots & \vdots \\ Y_{(i+k_v,j)} & \cdots & Y_{(i+k_v,j+k_h)} \end{bmatrix} \right)$$

若其 B_{img}^l 中之任意 pixel 為裂隙，則 B_{img}^l 之類別 B_{label} 設為 1，即有裂隙。其 labeling 演算法定義如下。

$$\mathcal{A}_{label}(B_{sample}^l) = B_{label}^l = \bigvee_{\substack{i=row(B_{mask}) \\ j=col(B_{mask})}} (B_{mask})_{ij}$$

最後，根據B^l_{label}將B_{sample}分成正樣本ϕ^+_{sample}與負樣本ϕ^-_{sample}，其定義如下。$\phi^+_{sample} = \{(B^l_{img}, B^l_{label}) \mid l = 1, \dots, n_{B^+}, B^l_{label} = 1\}\phi^-_{sample} = \{(B^l_{img}, B^l_{label}) \mid l = 1, \dots, n_{B^-}, B^l_{label} = 0\}$

$n_{B^+} + n_{B^-} = n_B$

$\phi_{sample} = \phi^+_{sample} \cup \phi^-_{sample}$

$|\phi_{sample}| = n_B;\ \phi^+_{sample} = n_{B^+}; \phi^-_{sample} = n_{B^-}$

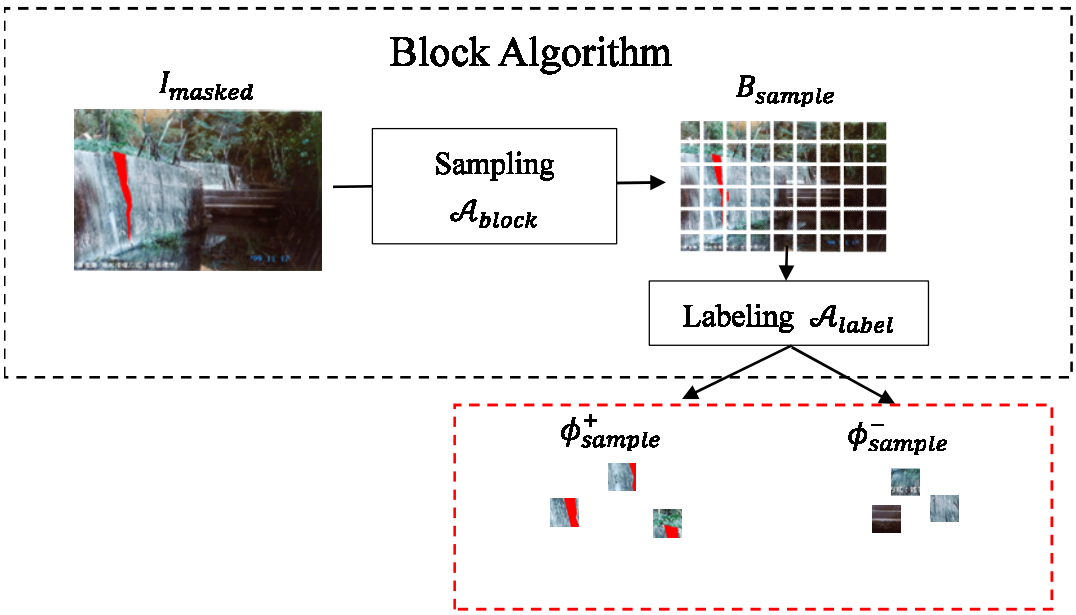
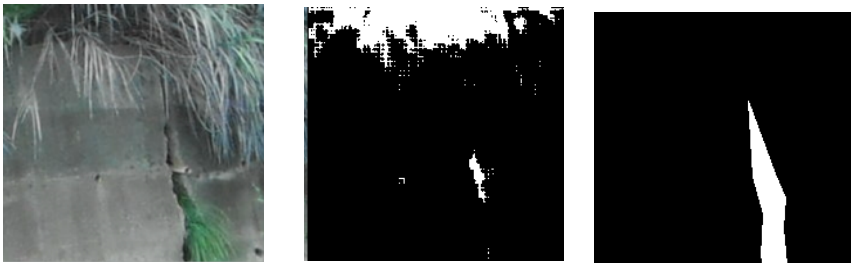


圖 2-11：影像裂損區塊影像資料集及其標註流程圖

三、**主題(3):** 兩階段影像裂隙影像偵測與分割模型之研究

為了克服水土保持護岸影像背景過於複雜，裂隙與植被特徵不易區分，本議題設計兩階段影像分割模型，強化辨識混凝土表面上的裂隙。圖 2-12 說明水土保持設施混凝土表面影像偵測結果，複雜背景易偵測錯誤。



(a) (b) (c)

圖 2-12: 水土保持設施混凝土表面影像偵測異常範例(a)輸入影像(b)預測結果(c)人工標註

圖 2-13 說明本主題兩階段混凝土裂隙影像偵測與分割模型流程。首先，分割水土保持混凝土設施表面，接著，將分割的區域作為遮罩，裁切輸入影像，再來，分割裁切影像中裂隙區域。

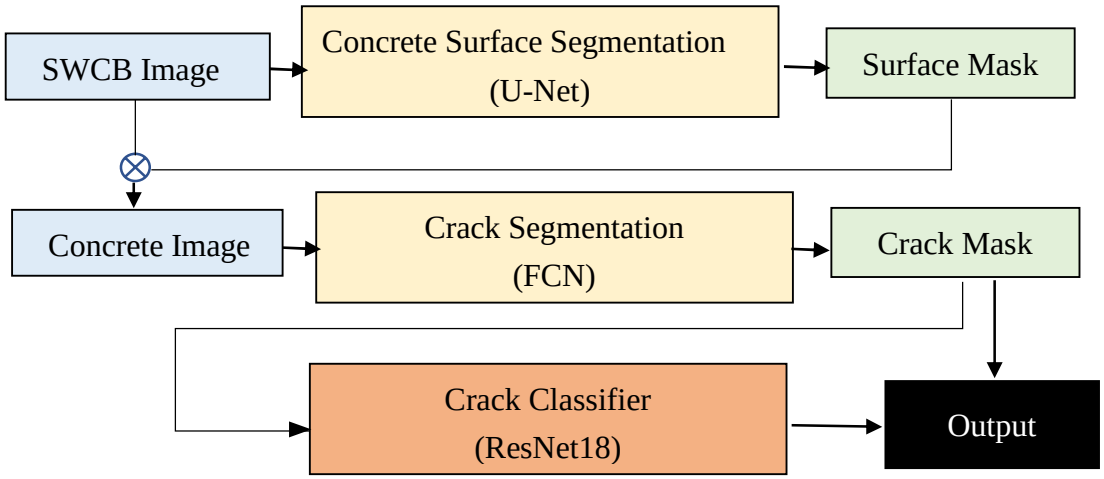


圖 2-13:兩階段混凝土裂隙影像偵測與分割模型流程

議題 3-1:發展影像分割模型

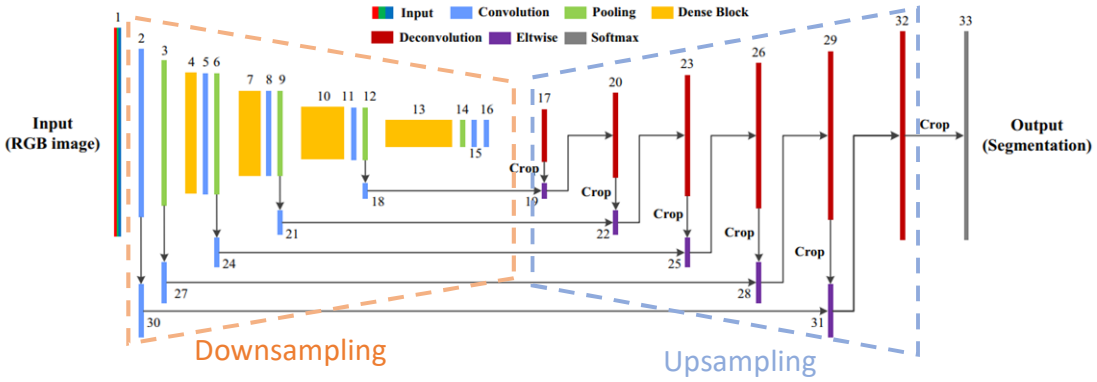


圖 2-14: FCN 模型架構

圖 2-14 說明 Fully Convolutional Network(FCN)影像分割模型架構[7] ，首先，使用卷積神經網路萃取影像特徵(Downsampling)，接著，逐步提升 Feature map 大小，再來，與卷積神經網路較早的卷積層輸出合併，重複上述步驟直到 Feature map 大小與輸入影像一致，最後，經由 Softmax 將各類輸出數值轉換為機率，即得到輸入影像物件分割預測 Mask。本議題 Downsampling 採用 DenseNet121，DenseNet 可以緩解訓練時梯度消失的問題，還可以提升模型參數重複使用率降低訓練成本，Upsampling 使用 Deconvolution 提升 Feature map 大小，並且使用加法與先前的卷積輸出合併。圖 2-15 說明 Upsampling 計算流程。

❶: 使用 Deconvolution 提升輸入 Feature map 大小

❷: 將步驟❶輸出 Feature map 大小裁切至與欲合併的卷積層輸出 Feature map 大小一致。

❸: 對欲合併的卷積層輸出做 conv 1x1 卷積使得 Feature map 的 Cannel 域分類數量相同

❹: 將步驟❷和步驟❸的輸出對應位置相加

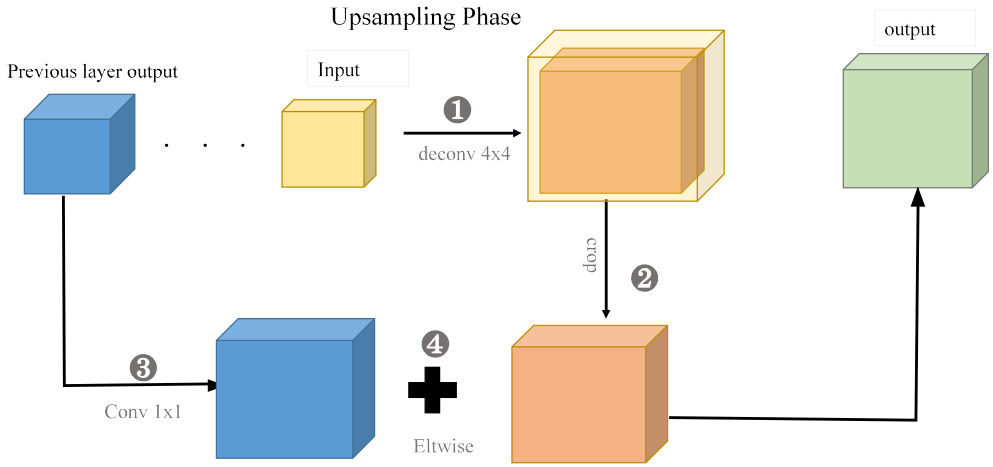
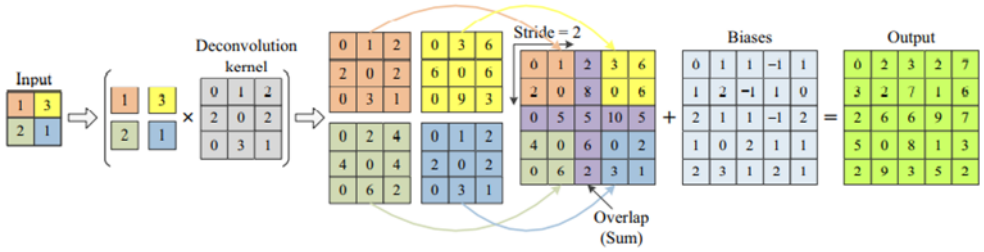
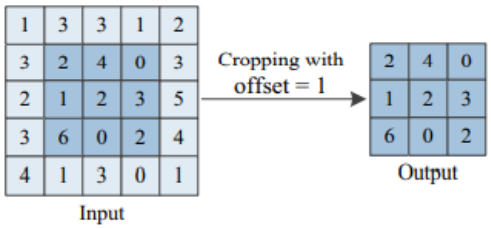


圖 2-15: FCN 之 Upsampling 流程



(a)



(b)

圖 2-16:FCN 計算單元 (a)Deconvolution 範例(b)Crop 範例

圖 2-16 (a)說明 Deconvolution 演算法計算流程，利用將每個數值與 kernel 相乘後，依據設定的 Stride 合併，重疊部分相加

即為輸出 Feature map。圖 2-16 (b)說明 Crop 演算法計算流程，透過 offset 將 Feature map 最外圍數值，修剪 Feature map 大小。

此外，因為裂隙在影像中面積相當細小，且隨著拍攝遠近差異甚大，本主題設計動態 cross-entropy loss，提升裂隙分割效能。λ_0, λ_1分別表示背景和裂隙權重，將變數乘上 cross-entropy loss 對應的項次，作為本主題模型損失函數。pix_{all}表示影像的像素數量，pix_0表示影像背景的像素數量，pix_1表示影像裂隙的像素數量。

- $\lambda_0 = \left(\frac{pix_{all}}{pix_{all}+pix_0}\right)^3 \in \left[\frac{1}{8}, 1\right]$
- $\lambda_1 = 5 \times \left(\frac{pix_{all}}{pix_{all}+pix_1}\right)^3 \in \left[\frac{5}{8}, 5\right]$
- $loss = \sum_{i \in Img} -(\lambda_1 \times y_i * logp_i) - (\lambda_0 \times (1 - y_i) log(1 - p_i))$

議題 3-2: 水土保持混凝土設施影像分割



圖 2-17: 水土保持設施表面影像集(a)原始影像(b)標註

表 2-2: 影像來源及數量

類別	數量(張)	來源
訓練影像(Train)	2,806	SWCB
驗證影像(Validation)	702	SWCB

圖 2-17 說明使用的 SWCB 混凝土表面影像集，(a)原始影像(b)人工標註。表 2-2 說明本議題模型訓練影像來源及數量，蒐集 SWCB 混凝土表面影像，總共 3,508 張，依照 8:2 比例分割，訓練影像 2,806 張，驗證 702 張。

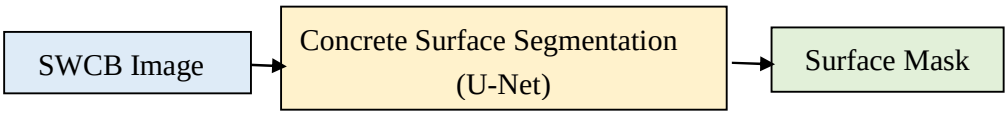


圖 2-18:混凝土表面影像分割流程概念圖

圖 2-18 說明混凝土表面影像分割流程，目的分割影像中混凝土表面區域，移除影像背景，提升**議題 3-3** 裂隙影像分割模型應

用在複雜影像的效能。表 2-3 說明模型訓練超參數。圖 2-19 說明模型訓練時的訓練(橘)及驗證(藍)損失曲線。圖 2-20 說明模型訓練時的指標曲線，(a)MIoU，(b)PA，訓練(橘)驗證(藍)。從圖中可以看到訓練損失大約在 40 epoch 之後，驗證影像的損失上升，且指標增長趨緩，出現過度擬和徵兆，人工抽取幾張預測結果，最終挑選第 41 個 epoch 的權重作為應用的模型。

表 2-3:模型訓練超參數

Batch_size	Loss	train_step_per_epoch	val_steps_per_epoch
16	Cross-entropy	200	40

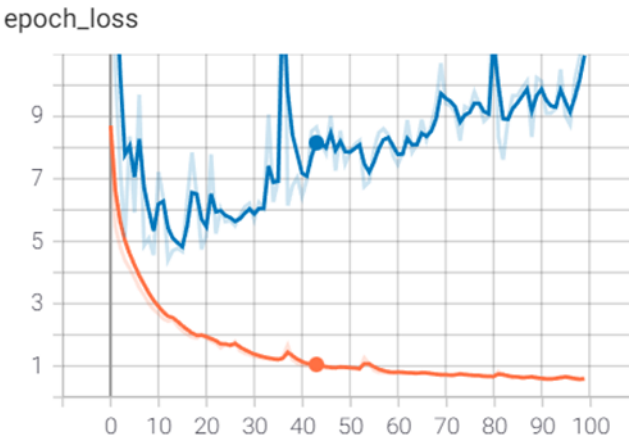
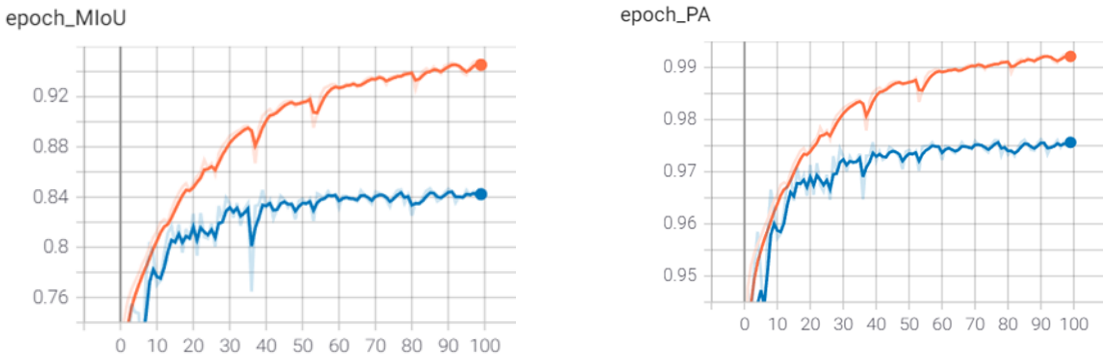


圖 2-19:混凝土表面影像分割模型訓練損失函數曲線。(橘)訓練損失曲線 (藍)驗證損失曲線



(a) (b)

圖 2-20:混凝土表面影像分割模型訓練指標曲線。

(a)MIoU(b)PA；(橘)訓練損失曲線 (藍)驗證損失曲線

議題 3-3: Kaggle 裂隙影像分割

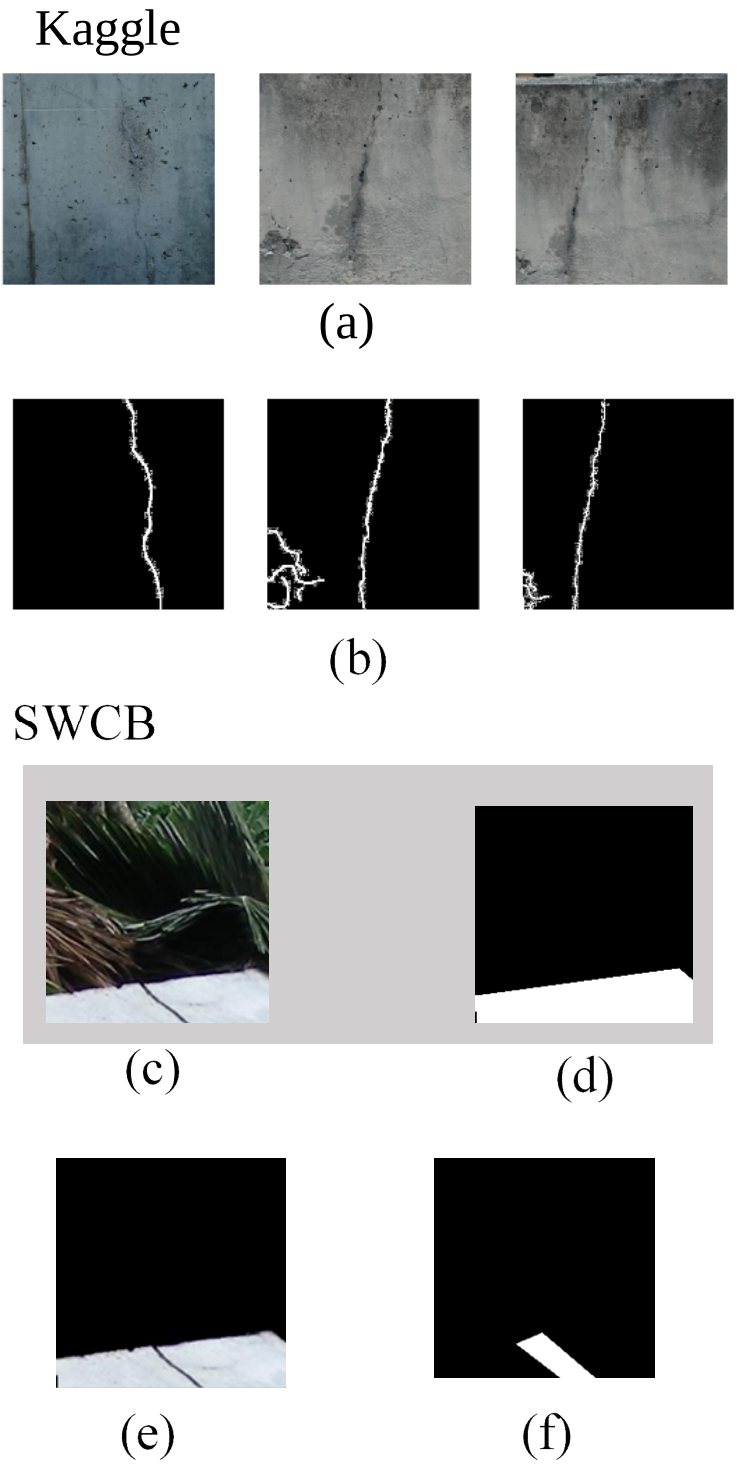


圖 2-21:混凝土裂隙影像範例(a)Kaggle 裂隙影像(b)Kaggle 標註(c)SWCB 裂隙影像(d)SWCB 混凝土表面標註(e)SWCB 混凝土表面裂隙影像(f)SWCB 混凝土表面裂隙標註

表 2-4: 影像來源及數量

類別	數量(張)	來源
訓練影像(Train)	7,876	Kaggle
驗證影像(Validation)	1,968	Kaggle
測試影像(Test)	576	SWCB

圖 2-21 說明混凝土裂隙影像影像集總共 9,844 張，作為本議題訓練、驗證及測試影像集， (a)Kaggle 混凝土裂隙影像，(b) Kaggle 混凝土裂隙標註。

SWCB 混凝土裂隙影像總共 576 張，(c)SWCB 裂隙影像 (d)SWCB 混凝土表面標註(e)SWCB 混凝土表面裂隙影像 (f)SWCB 混凝土表面裂隙標註，其中(c)與(d)疊合生成(e) SWCB 混凝土表面裂隙影像，並以(e)與(f)做為本議題模型測試影像。表 2-4 說明本議題模型使用影像來源及數量，訓練及驗證以 8:2 比例分割 Kaggle 裂隙影像，測試影像使用 SWCB 裂隙影像。

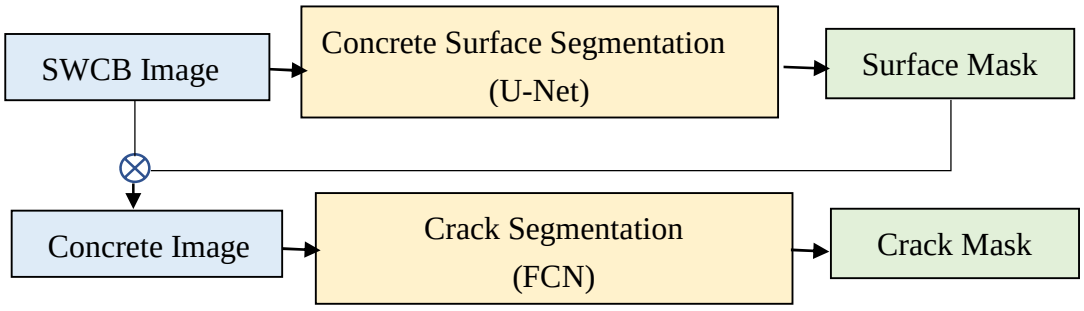


圖 2-22:裂隙影像分割流程概念圖

表 2-5:模型訓練超參數

Batch_size	Loss	Class_weight	train_step_per_epoch	val_steps_per_epoch
16	Cross-entropy	([1/8, 1], [5/8, 5])	200	40

圖 2-22 說明裂隙影像分割流程，分割影像中混凝土表面裂隙區域，標示出混凝土表面裂隙位置。表 2-5 說明模型訓練超參數，由於影像中裂隙區域通常面積不大，所以本議題模型訓練使用 Class_weights 平衡，裂隙和背景影像像素訓練的比重，提升影像中裂隙分割效能。圖 2-23 說明模型訓練時的訓練(橘)及驗證(藍)損失曲線。圖 2-24 說明模型訓練時的指標曲線，(a)MIoU，(b)PA，訓練(橘)驗證(藍)。從圖中可以看到訓練損失在部分 epoch 劇烈震盪，但整體趨勢訓練及驗證損失穩定下降，大約在 40 epoch 逐漸收斂，趨於穩定。在指標上增長也逐步趨緩，人工抽取幾張預測結果，最終挑選第個 epoch 的權重作為應用的模型。

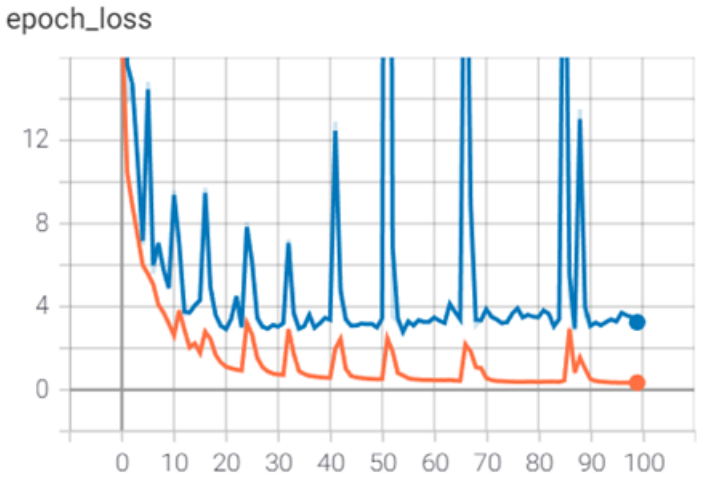
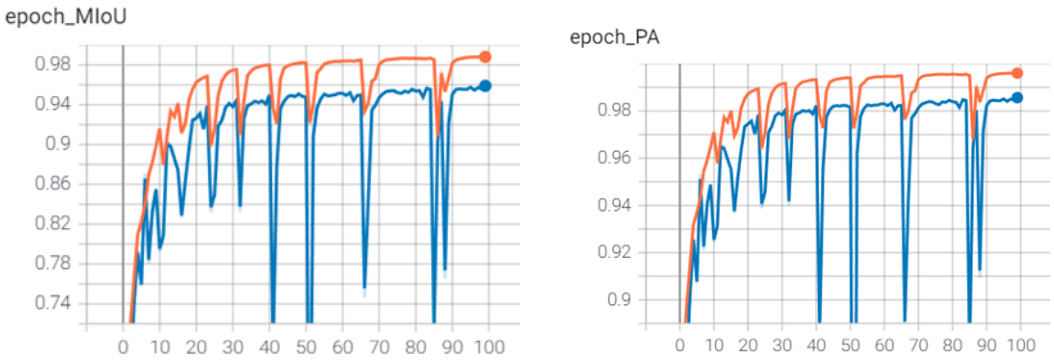


圖 2-23:混凝土裂隙影像分割模型訓練損失函數曲線。(橘)訓練損失曲線 (藍)驗證損失曲線



(a) (b)

圖 2-24:混凝土裂隙影像分割模型訓練指標曲線。(a)MIoU(b)PA；(橘)訓練損失曲線 (藍)驗證損失曲線

議題 3-4: 兩階段混凝土裂隙偵測

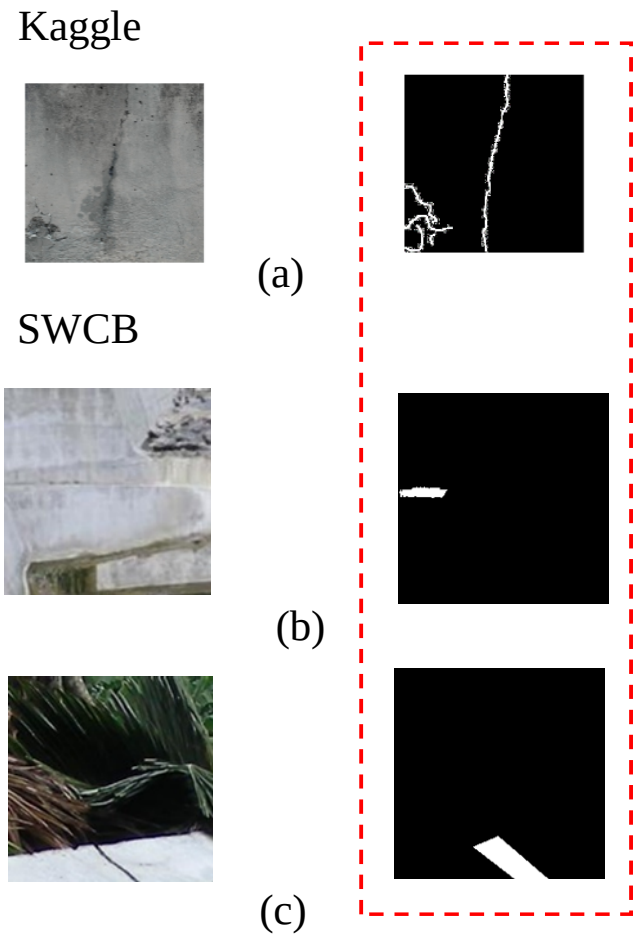


圖 2-25:混凝土裂隙預測影像

表 2-6: 影像來源及數量

類別	數量(張)	來源
訓練影像(Train)	10,682	Kaggle, SWCB
驗證影像(Validation)	2,670	Kaggle, SWCB
測試影像(Test)	576	SWCB

圖 2-25 說明使用的混凝土裂隙預測影像集，(a)Kaggle 裂隙影像(b)SWCB 混凝土表面無裂隙影像(c)SWCB 混凝土表面裂隙

影像，本議題模型使用兩階段混凝土裂隙分割的預測結果，當作本議題模型輸入。其中訓練及驗證影像使用(a)作為正樣本(裂隙)，(b)作為負樣本，而(c)因為影像數量相較於(a)數量稀少，所以僅作為測試樣本。表 2-6 說明本議題模型訓練影像來源及數量，蒐集 SWCB 混凝土表面影像，總共 13,352 張，依照 8:2 比例分割，訓練影像 10,682 張，驗證 2,670 張，測試 576 張。

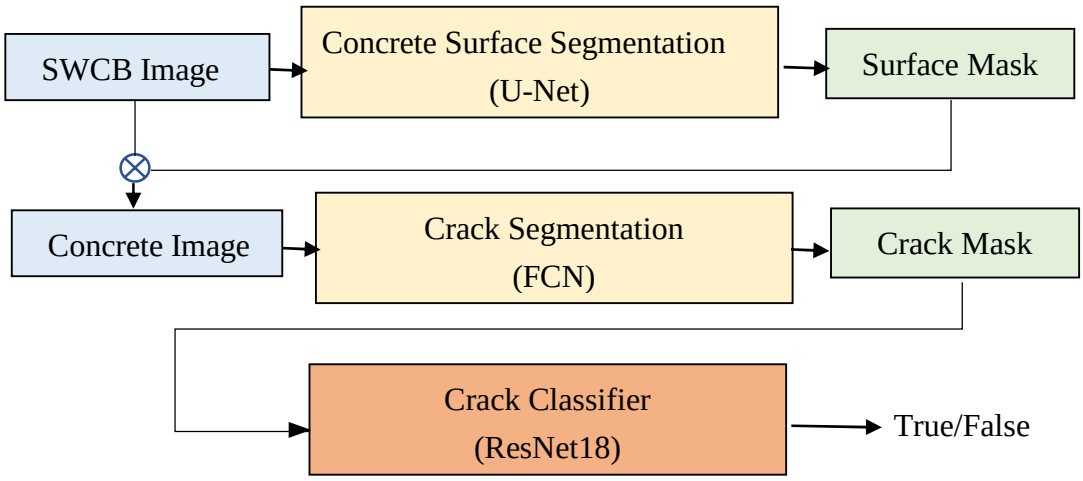


圖 2-26:兩階段混凝土裂隙影像偵測模型流程

表 2-7:模型訓練超參數

Batch_size	Loss	train_step_per_epoch	val_steps_per_epoch
16	Cross-entropy	200	40

圖 2-26 說明兩階段混凝土裂隙影像偵測流程，由分割結果判斷影像是否為裂隙，快速篩選出可能的混凝土裂隙影像。表 2-

7 說明模型訓練超參數。圖 2-27 說明模型訓練時的訓練(橘)及驗證(藍)損失曲線。僅管驗證影像損失在訓練時劇烈震盪，但整體趨勢訓練穩定下降，因此挑選最後 epoch 的權重。圖 2-28 說明兩階段混凝土裂隙混凝土裂隙偵測的混淆矩陣，結果顯示 ResNet18 能夠準確地分辨裂隙與非裂隙影像的預測結果，準確度高達九成以上。圖 2-29 說明測試影像結果，偵測影像均來自於蒐集之水土保持影像，可以看到應用在水土保持局裂隙影像，準確率也能夠維持在八成以上，效能尚可。

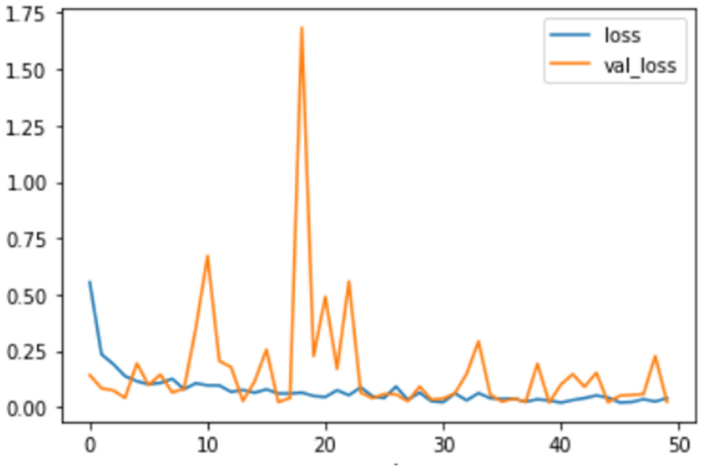
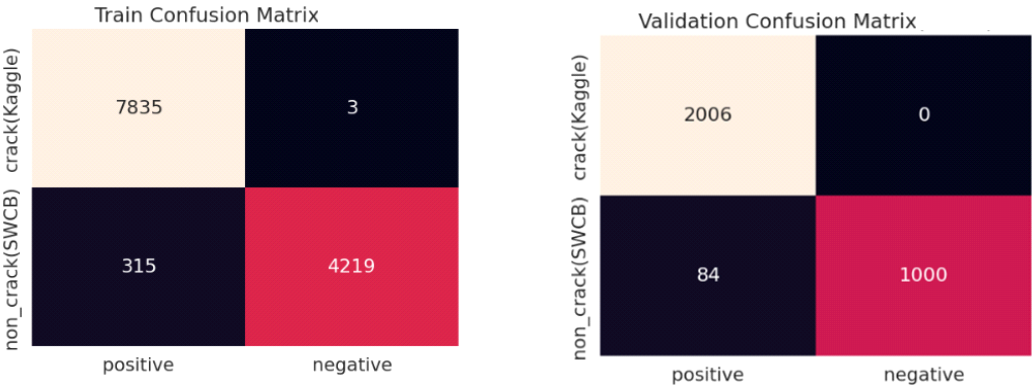


圖 2-27:兩階段混凝土裂隙混凝土裂隙偵測模型訓練損失函數曲線。(橘)訓練損失曲線 (藍)驗證損失曲線



(a) (b)

圖 2-28:兩階段混凝土裂隙混凝土裂隙偵測混淆矩陣。(a)訓練影像 (b)測試影像

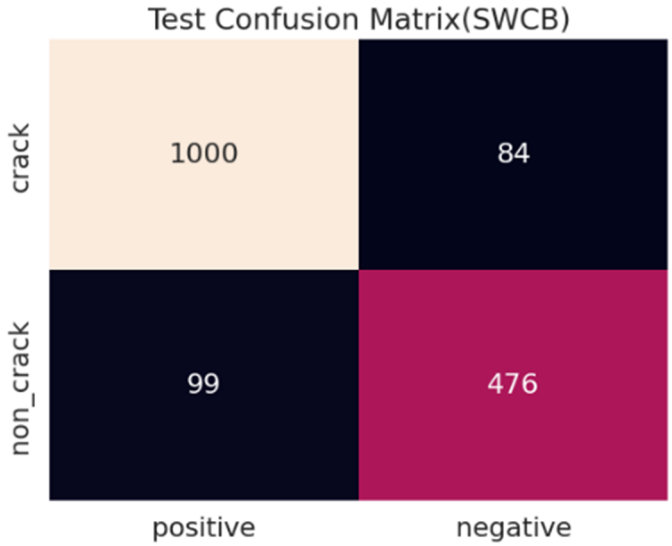


圖 2-29:兩階段混凝土裂隙混凝土裂隙偵測混淆矩陣。(水土保持影像)

四、**主題(4):** 智慧型混凝土表面裂隙影像區塊偵測之研究

圖 2-30 為本主題的概念架構圖，圖中分為三大階段，分別為 preprocessing、training 以及 inference。Preprocessing 階段對影像進行前處理，由議題 4-1、議題 4-2 與議題 4-3 詳細說明。Training 階段為訓練階段的架構以及流程，由議題 4-4 詳細說明。Inference 為模型正式啟用之階段，由議題 4-5 詳細說明。

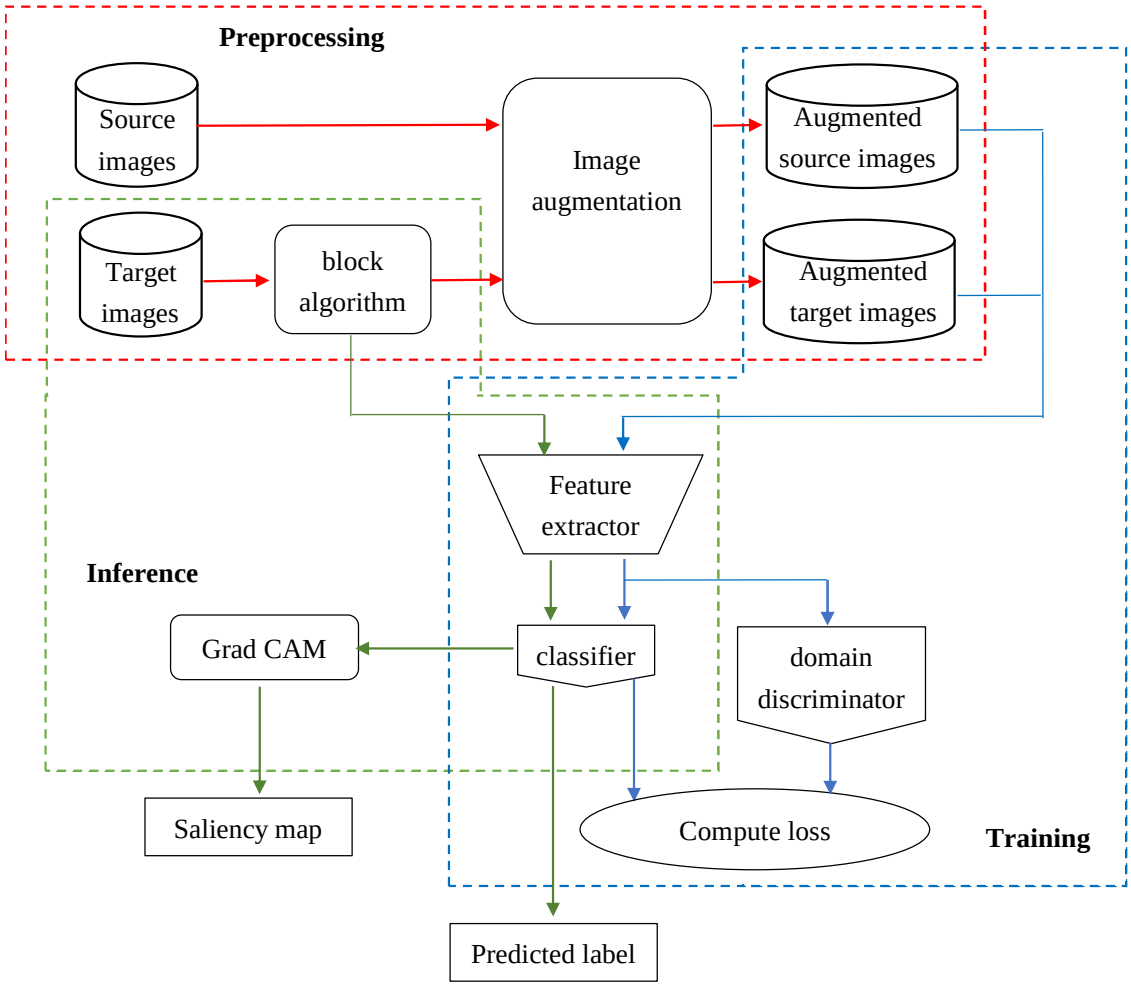


圖 2-30: 概念架構圖

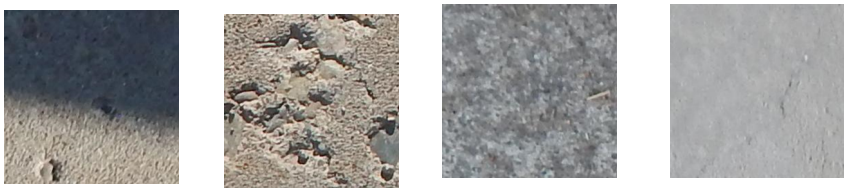
議題 4-1：Source 與 target domain 影像資料集說明

由於本主題使用第一章第三節背景中的第二小節所提及之自適應領域學習技術，圖 2-31 介紹 source domain 與 target domain 之資料集。

Source domain 之裂損影像：



Source domain 之背景影像：



Target domain 之裂損影像：



Target domain 之背景影像：



圖 2-31: source domain 與 target domain 影像集

表 2-8: 影像來源及數量

	數量(張)	來源
Source domain 裂損影像	5215	https://www.kaggle.com/c/crack-identification-ce784a-2020-iitk/data?select=train https://www.kaggle.com/datasets/aniruddhsharma/structural-defects-network-concrete-crack-images?select=Decks
Source domain 背景影像	54795	https://www.kaggle.com/c/crack-identification-ce784a-2020-iitk/data?select=train https://www.kaggle.com/datasets/aniruddhsharma/structural-defects-network-concrete-crack-images?select=Decks
Target domain 裂損影像	120	水保歷史影像平台
Target domain 背景影像	4550	水保歷史影像平台

議題 4-2：影像增廣

為了增加影像的多樣性，在此引入影像增廣演算法，增加類神經網路模型的泛化能力。圖 2-32 展示影像增廣流程。其演算法對影像做以下五種增廣：

●陰影

在大量訓練影像皆不存在陰影的情況下，類神經網路模型極有可能將所有陰影誤判成裂隙。這是因為在訓練過程中，類神經網路模型可能會取巧將所有包含黑色區域的影像判別為包含裂隙的影像，而不是以裂隙之紋理特徵作為評判標準，故在影像上隨機打上陰影，迫使類神經網路模型學習裂隙紋理特徵。其輸入的影像將有 0.5 的機率被打上陰影，其陰影將被隨機打在圖片的任意區域，其陰影強度離陰影中心越遠越淡。

●水平翻轉

由於輸入的影像可能有上下之分(如天空在上、河流在下)，因此不宜進行垂直翻轉，只能進行水平翻轉。其輸入的影像將有 0.5 的機率被水平翻轉。

●亮度、對比度與彩度調整

未來上架後的影像有可能是在晴天、陰天或雨天等不同條件下所拍攝，若只使用現有影像資料集可能導致類神經網路模型缺乏多樣性，故對訓練影像先進行亮度、對比度與彩度調整，模擬不同情景下所拍攝之影像。

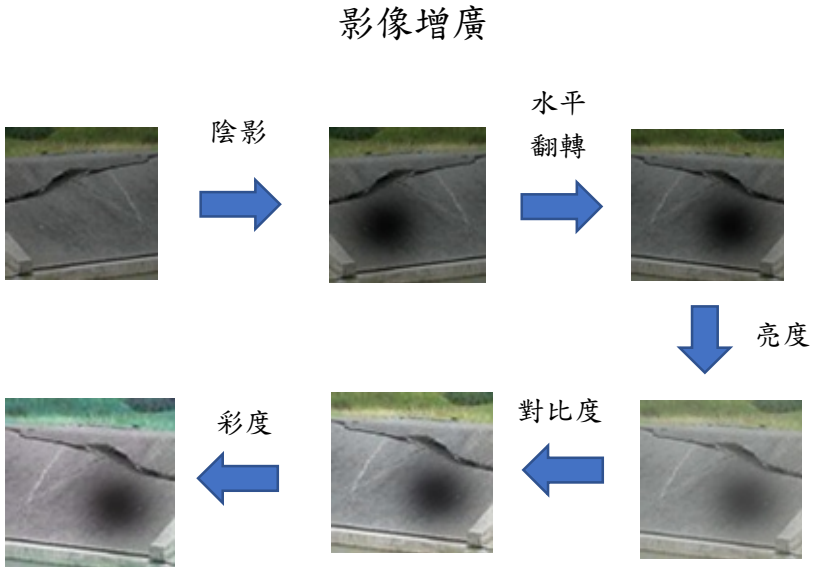


圖 2-32: 影像增廣流程圖

議題 4-3：區塊影像裂隙偵測模型之訓練架構設計

此議題將說明本主題之訓練階段設計。類神經網路架構遵從第一章第三節背景中的第二小節自適應領域學習分類，其中 feature extractor、classifier 與 domain discriminator，圖 2-33 詳述實作架構。

Layers	Output Size	Feature Extractor
Convolution	$56 \times 56 \times 128$	7×7 conv, stride 2
Dense Block	$56 \times 56 \times 512$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$, growth 64
Transition Block	$28 \times 28 \times 256$	1×1 conv
		2×2 avg pool, stride 2
Dense Block	$28 \times 28 \times 1024$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$, growth 64

Layers	Output Size	Classifier
Pool	1024	28×28 global avg pool
Dense Block	1	1D fully-connected
Activation	1	sigmoid

Layers	Output Size	Domain Discriminator
Convolution	$28 \times 28 \times 512$	3×3 conv
Convolution	$28 \times 28 \times 256$	3×3 conv
Convolution	$28 \times 28 \times 1$	3×3 conv
Pool	1	28×28 global avg pool
Activation	1	sigmoid

圖 2-33: 深度類神經網路模型架構圖

此外，輸入區塊影像之維度皆為$224 \times 224 \times 3$。在訓練階段，將使用由主題二的區塊影像集作為訓練影像資料集。在處理不

平衡類別問題的其中一個辦法為調整損失函數的權重，以二元分類為例，加權後的損失函數如下：

$$\mathcal{L}_y(y,\hat{y}) = \begin{cases} -\alpha_1 \log \hat{y} & ,if\ y=1 \\ -\alpha_0 \log(1-\hat{y}) & ,if\ y=0 \end{cases}$$

其中α_1與α_0分別為正負類別的權重。然而α_1與α_0的選擇卻是未知的，故在本議題引入自適應 recall loss function[8] 。此損失函數會根據類神經網路模型當下的 false negative 自動調整權重，其權重定義如下：

$$\alpha_1 = \sum_{y,\hat{y}} \mathbb{1}_{\hat{y}\leq 0.5 \vee y=1}(y,\hat{y}) = FN_1$$
$$\alpha_0 = \sum_{y,\hat{y}} \mathbb{1}_{\hat{y}> 0.5 \vee y=0}(y,\hat{y}) = FN_0$$

其中$\mathbb{1}_{\hat{y}\leq 0.5 \vee y=1}$為 indicator function。

議題 4-4：區塊影像裂隙偵測模型之測試架構設計

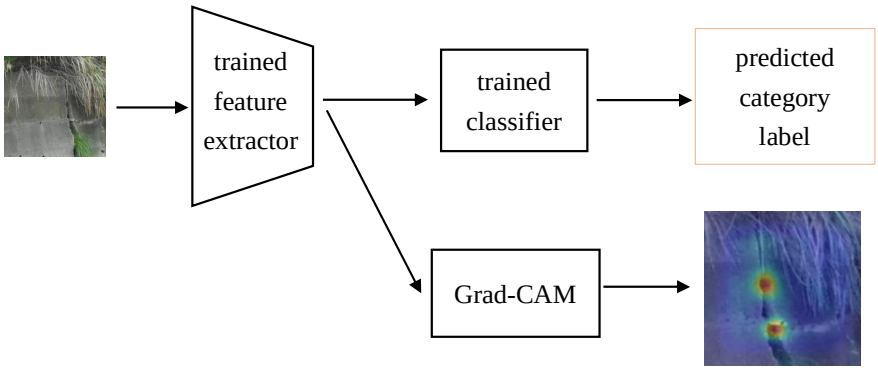


圖 2-34: 測試階段輸出顯著圖與類別

測試階段之輸出輸入模式由圖 2-34 解釋。在測試階段，domain discriminator 將被捨棄，僅留下 feature extractor 與 classifier，並加入 Grad CAM 用來生成顯著圖。

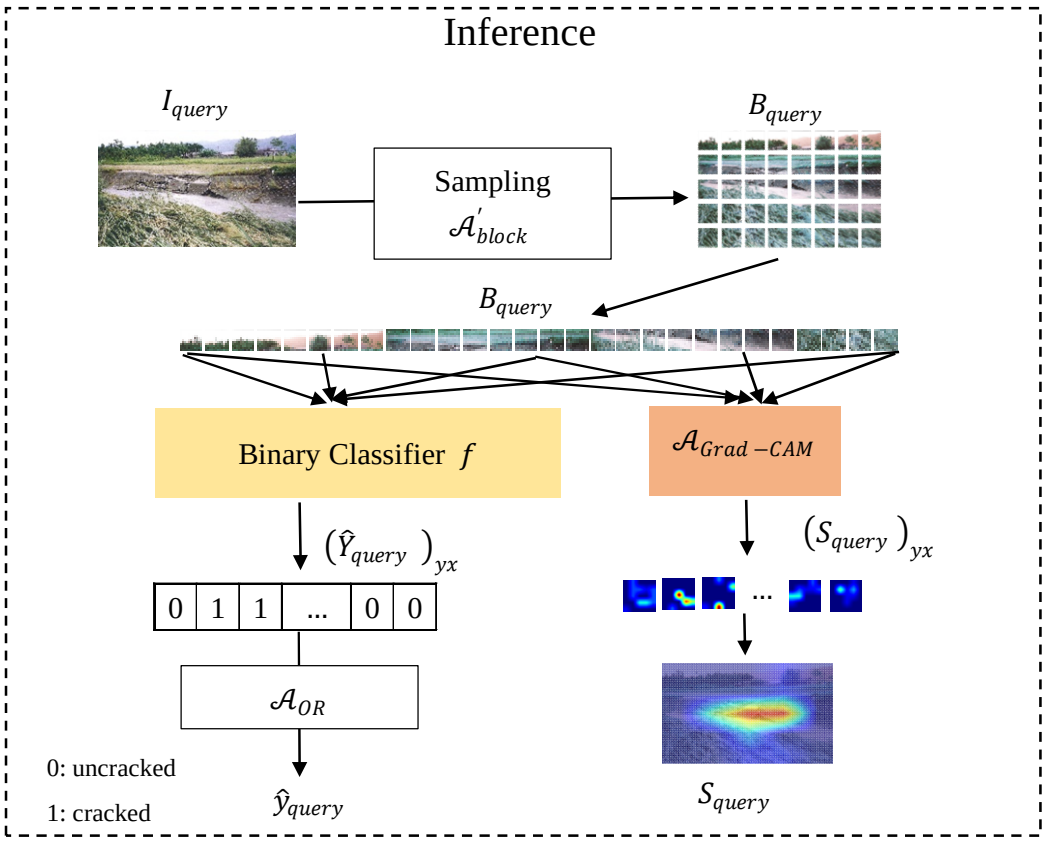


圖 2-35: 影像裂損辨識流程圖

圖 2-35 表示影像裂損辨識之測試流程圖。在此，輸入影像之處理方式與**議題 2-2** 區塊影像處理流程相同，一樣會將輸入影像I_{query}分割成矩形區塊影B_{query}，但差別在於I_{query}無標註 pixel label，因此本主題$B_{query} = \{B_{img}^{q,l} | l = 1, \dots, n_{B_q}\}$。$n_{B_q} =$

$\left\lceil \frac{V}{K_v} \right\rceil \times \left\lceil \frac{H}{K_H} \right\rceil = n_{B_q}^V \times n_{B_q}^H$，接著利用訓練之$f$預測$B_{img}^{q,l}$之label $\hat{y}^{q,l} = f\left(B_{img}^{q,l}\right) \in \{0,1\}$。最後整張$I_{query}$之預測結果$\hat{Y}_{query}$，將透過演算法得出$\mathcal{A}_{OR}\left(\hat{Y}_{query}\right) = \bigvee_l \left(\hat{y}^{q,l}\right) \in \{0,1\}$。

即只要有一張子影像被f判定為包含裂隙，整張影像I_{query}即包含裂隙。此外，本主題利用演算法$\mathcal{A}_{Grad-CAM}$生成 saliency map (顯著圖)，其演算法於背景三說明。多個區塊影像之顯著圖的合併方法與預測I_{query}之類別類似，首先，生成$B_{img}^{q,l}$之顯著圖$S_{img}^{q,l} = \mathcal{A}_{Grad-CAM}\left(B_{img}^{q,l}; f\right)$，在將$S_{img}^{q,l}$依據原始裁切影像位置拼接成$I_{query}$之顯著圖$S_{query}$。

$$S_{query} = \begin{bmatrix} \left(S_{img}^q\right)_{1\,1} & \cdots & \left(S_{img}^q\right)_{n_{B_q}^H,1} \\ \vdots & \ddots & \vdots \\ \left(S_{img}^q\right)_{1,\ n_{B_q}^V} & \cdots & \left(S_{img}^q\right)_{n_{B_q}^H,\ n_{B_q}^V} \end{bmatrix}$$

$\left(S_{img}^q\right)_{ij}$可用 Row-major 方式轉換成$S_{img}^{q,l}$，其公式為$l = (i-1)n_{B_q}^H + j$。

議題 4-5：實驗效能評估

實驗中 source domain 之影像資料集將分為訓練影像資料集(train)以及驗證影像資料集(val)。Target domain 之影像資料集在未使用自適應領域學習技術的情況下不行分割(target)，在使用自適應領域學習技術的情況下將分成訓練影像資料集(target train)以及驗證影像資料集(target val)。

表 2-9 表示使用自適應領域學習技術與未使用自適應領域學習技術之效能指標比較結果。從表 2-9 中可以看出使用自適應領域學習技術的效能皆比未使用自適應領域學習技術模型的效能還高。其中，未使用自適應領域學習技術之 target accuracy 為 0.7846，而使用自適應領域學習技術之訓練與驗證 target accuracy 分別為 0.8495 和 0.8098，皆高於未使用自適應領域學習技術之 target accuracy。

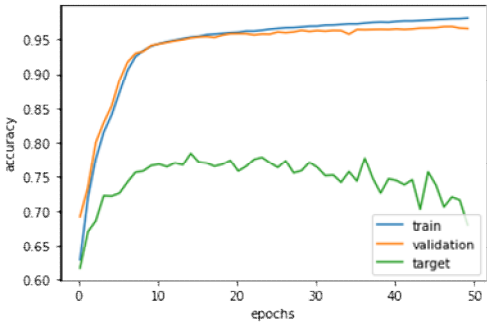
表 2-9：有無使用 DA 之比較表

	accuracy	**precision**	**recall**	**F1-score**
Source train w/o DA	0.9816	0.9821	0.9812	0.9816
Source val w/o DA	0.9695	0.9704	0.9685	0.9695
Target w/o DA	0.7846	0.7566	0.8392	0.7958
Source train w/DA	0.9975	0.9971	0.9979	0.9975
Source val w/ DA	0.9653	0.9822	0.9478	0.9647
Target train w/ DA	0.8495	0.9043	0.7816	0.8385
Target val w/ DA	0.8098	0.8185	0.7961	0.8071

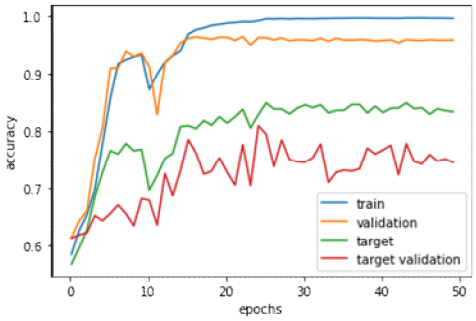
●Learning curve:

圖 2-36 展示使用 DA 與未使用 DA 之學習曲線。(a)為未使用 DA 的 accuracy、(b)為使用 DA 的 accuracy、(c)為無使用 DA 的 F1-score、(d)為使用 DA 的 F1-score。圖中藍線表示 source domain 的訓練指標(accuracy 和 F1-score)、黃線表示 source domain 的驗證指標。在未使用 DA 的情景下綠線在表示 target domain 整個影像資料集的指標，在使用 DA 的情景下綠線表示 target domain 的訓練指標、紅線表示 target domain 的驗證指標。

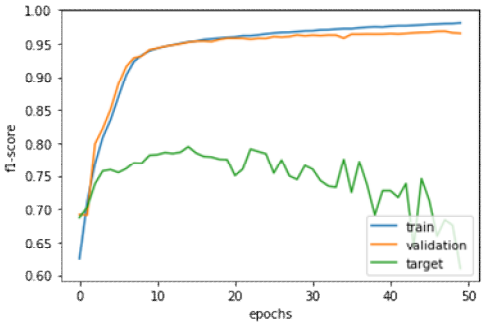
(a)與(c)顯示未使用 DA 之類神經網路模型在訓練後期出 target domain 效能低下的情形。而(b)與(d)則顯示使用 DA 之類神經網路模型對 target domain 之驗證影像資料集的效能雖然有小幅度降低，但是對 target domain 之訓練影像資料集卻有大幅提升。



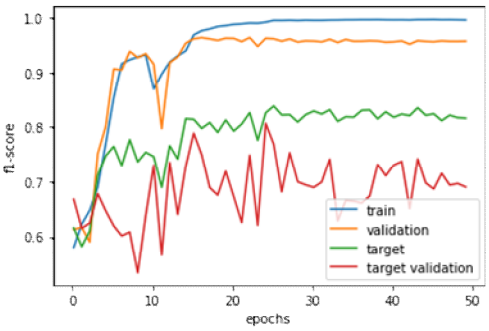
(a) Accuracy w/o DA



(b) Accuracy w/ DA



(c) F1-score w/o DA



(d) F1-score w/ DA

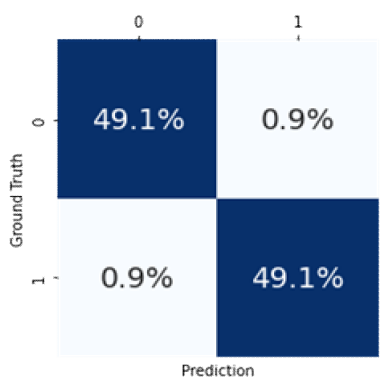
圖 2-36：學習曲線圖，(a)為未使用 DA 的 accuracy、(b)為使用 DA 的 accuracy、(c)為未使用 DA 的 F1-score、(d)為使用 DA 的 F1-score

●Confusion matrix:

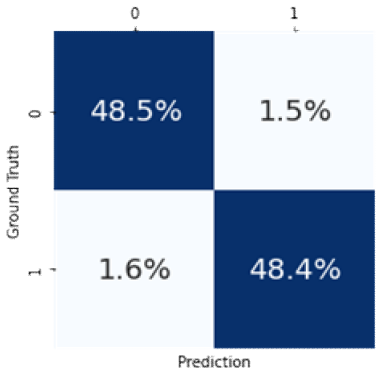
圖 2-37 與圖 2-38 分別表示未使用 DA 與使用 DA 之混淆矩陣。

圖 2-37 (c)與圖 2-38 (c)-(d)比較後可以發現圖 2-38 (c)-(d)之混淆矩陣皆優於圖 2-37 (c) 之混淆矩陣。此外，圖 2-37 (c)顯示未使用 DA 只類神經網路模型較容易將無裂隙判斷成有裂隙，而圖 2-38 (c)-(d)顯示使用 DA 只類神經網路模型較容易將有裂

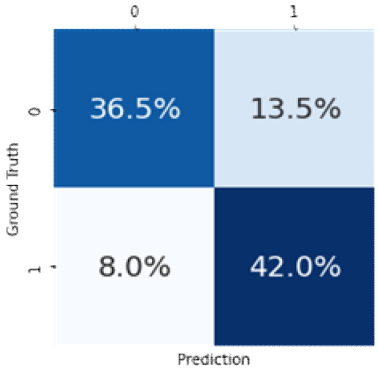
隙判斷成無裂隙。



(a) Source train

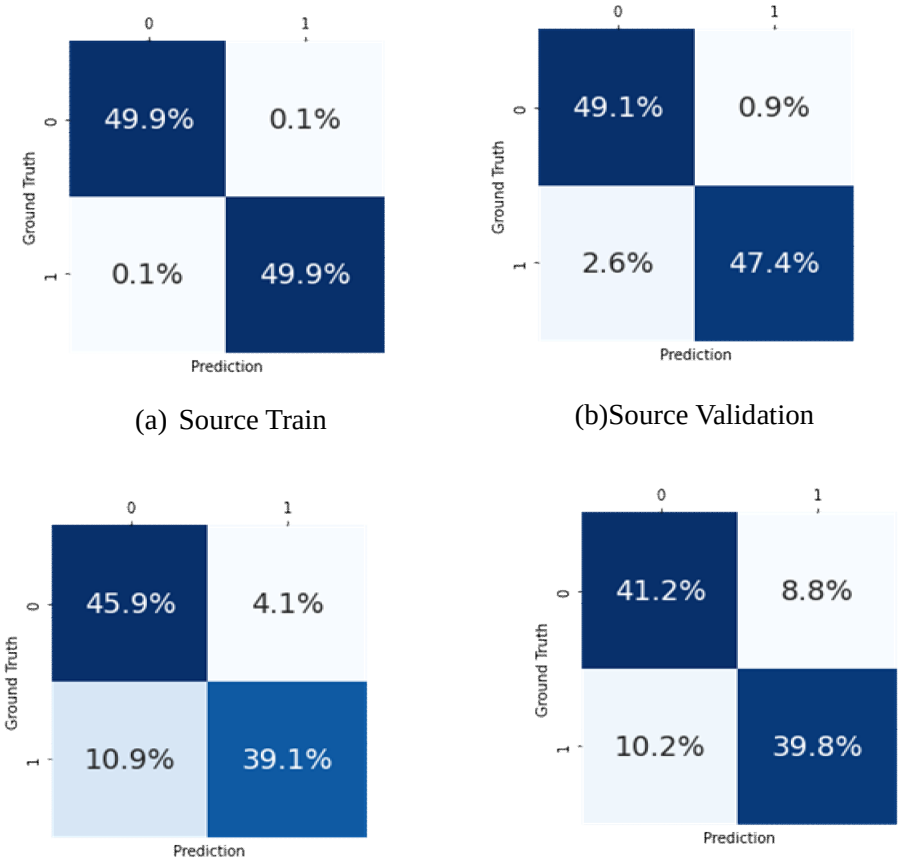


(b) Source validation



(c) Target

圖 2-37:未使用 DA 之混淆矩陣



(a) Source Train (b)Source Validation

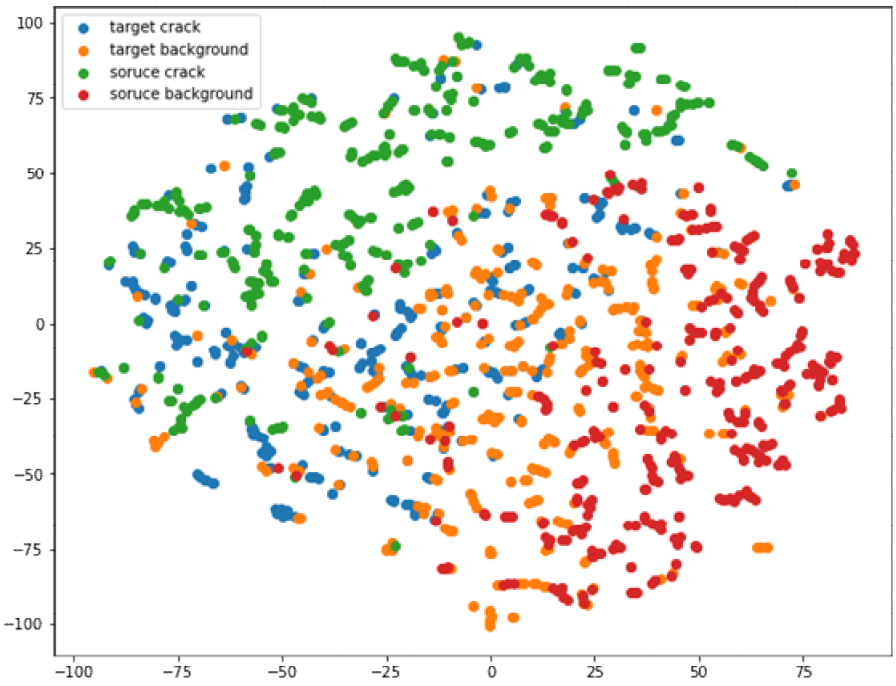
(c) Target train (d) Target validation

圖 2-38: 使用 DA 之混淆矩陣

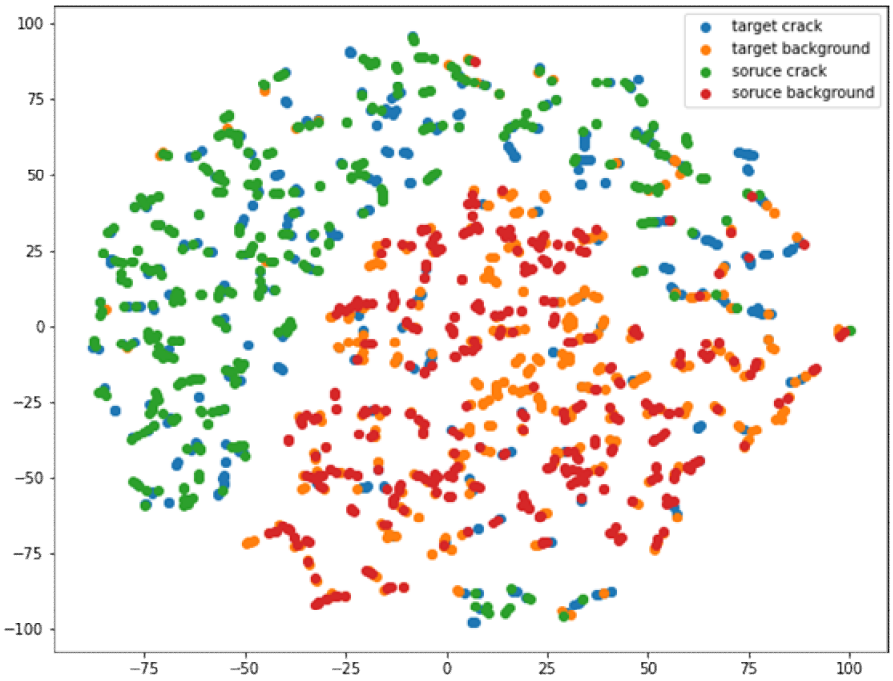
●t-Distributed Stochastic Neighbor Embedding (t-SNE):

圖 2-39 利用 t-SNE[9] 演算法對類神經網路模型之特徵從高維度降至二維以進行視覺化，其中(a)為未使用 DA 之特徵圖、(b)為使用 DA 之特徵圖，藍點表示 target domain 之裂隙影像特徵、黃點表示 target domain 之背景影像特徵、綠點表示 source domain 之裂隙影像特徵、紅點表示 source domain 之背景影像特徵。

在理想情況下，紅點與黃點應該交織在一起、藍點與綠點應該交織在一起，而且紅點黃點與藍點綠點應該要被分隔開來，表示 source domain 跟 target domain 之特徵應該依照其類別聚合，而非依照 domain 聚合。圖 2-39 (a)可以看出紅點與黃點並沒有被混合的很好，而藍點與黃點大部分都被混在一起，導致 target domain 影像之裂隙與背景難以區分。圖 2-39 (b)則可以看到紅點與黃點完美的重疊再一起，藍點與綠點也有不錯的重合度，雖然有部分藍點與黃點分類錯誤，但比起圖 2-39 (a)還是有明顯的提升。



(a) w/o DA

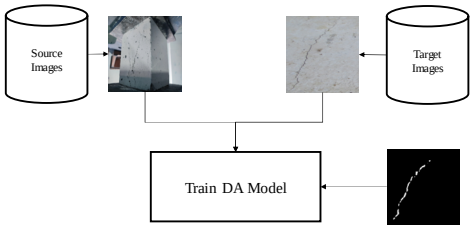


(b) w/ DA

圖 2-39：t-SNE 特徵視覺化

五、**主題(5):** 智慧型混凝土表面裂隙影像分割之研究

(a)Training



(b)Inference

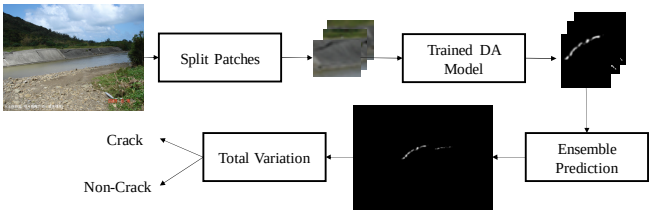


圖 2-40: 智慧型混凝土表面裂隙影像分割模型。 (a)模型訓練架構，(b)模型預測架構。

圖 2-40 表示本主題利用領域自適應技術發展智慧型混凝土表面裂隙影像分割模型。圖 2-40(a)表示模型訓練架構，從 Source Image 和 Target Image 資料集取樣牆壁裂隙和混凝土裂隙影像。Source Image 影像集為現有大量影像及已標註，本主題使用議題 2-1 的影像作為 Source Image，Target Image 影像集為少量影像且未標註的混凝土裂隙影像。圖 2-40(b)表示模型測試架構，將影像經過 Split Patches Algorithm (同議題 2-2)得到數個區塊影像，將每一個區塊影像輸入 Trained DA Model 後預測區塊影像的裂隙分割區域，最後將裂隙分割影像預測結果輸入至 Total Variation Algorithm 判斷是否含有裂隙。

議題 5-1: Source 與 Target domain 影像資料集說明：

本主題使用 kaggle 牆壁裂隙影像(議題 2-1 的圖 2-4)和水土保持局設施提供混凝土缺失影像集(議題 2-1 的圖 2-7)作為 Source images 及 Target images。內容描述及影像範例如下表 2-10 和圖 2-41。

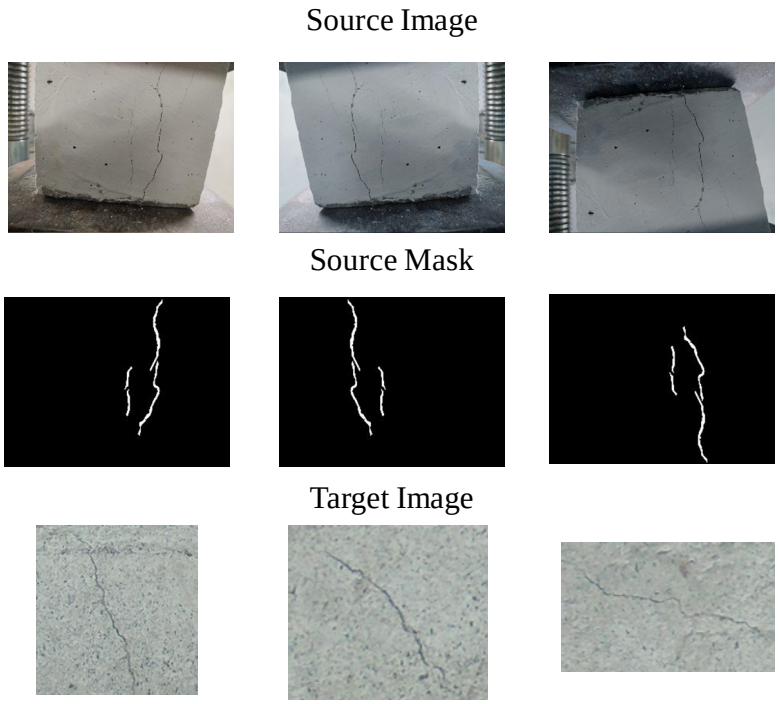


圖 2-41: Source Image、Source Mask 和 Target Image 範例

表 2-10: Source Image 和 Target Image 影像集數量及來源

	張數	來源
Source Images	812	https://www.kaggle.com/datasets/roxystar/standard-cement-concrete-crack-segmentationdataset
Target Images	66	水土保持局設施提供混凝土缺失影像

議題 5-2: 領域自適應學習影像分割模型訓練架構設計

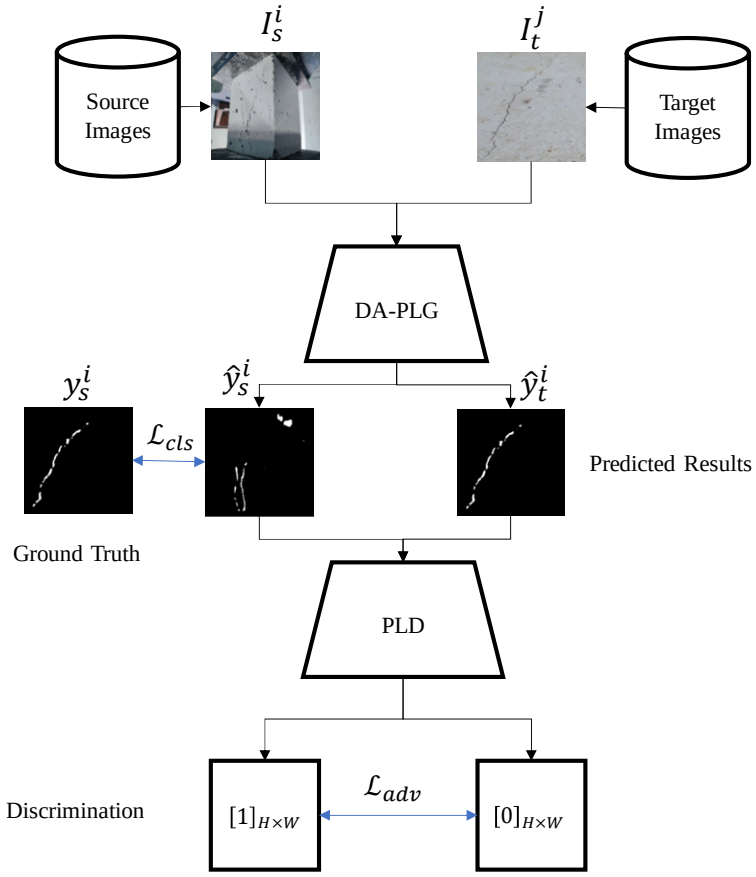


圖 2-42: 領域自適應學習影像分割模型訓練架構

本議題介紹領域自適應學習影像分割模型訓練架構。如圖 2-42，令I_s^i為從 Source Image Dataset 取樣出的第 i 張影像，I_t^j為從 Target Image Dataset 取樣的第 j 張影像，兩張影像為$H \times W$的彩色影像。兩張影像各自輸入 Domain-Adaption based Pixel-Level Generator(本議題命名為 DA-PLG)後得到其分割預測結果$\hat{y}_s^i$及$\hat{y}_t^i$(pixel-level prediction results)。為了訓練 DA-PLG，將$\hat{y}_s^i$和其分

割標準答案y_s^i去計算 pixel-level 的分類損失函數$\mathcal{L}_{cls}$並以此產生的誤差更新 DA-PLG。損失函數$\mathcal{L}_{cls}$的公式如下。

$$\min_{\text{DA-PLG}}\{\mathcal{L}_{cls} = -\sum_{h=1}^{H}\sum_{w=1}^{W} {y_s}_{hw}^{i} \log {\hat{y}_s}_{hw}^{j}\}$$

為了使模型提升對於 Target Image 的預測結果，本主題使用 DA 來實現此目標。將 DA-PLG 估計結果$\hat{y}_s^i$及$\hat{y}_t^i$輸入 Pixel-Level Discriminator(PLD)得到其預測結果並計算對抗損失函數$\mathcal{L}_{adv}$。對於 PLD，最大化$\mathcal{L}_{adv}$的誤差更新 PLD 的參數使得$\hat{y}_s^i$和$\hat{y}_t^i$的每個 pixel 被分類為第 1 類和第 0 類(二分類); 對於 PLG，為了能夠將預測 Source Image 的能力用於預測 Target Image，所以最小化$\mathcal{L}_{adv}$的誤差使得 DA-PLG 能夠使 PLD 將其預測結果$\hat{y}_t^i$判別為第 1 類。損失函數$\mathcal{L}_{adv}$的公式如下。

$$\min_{\text{DA-PLG}}\max_{\text{PLD}}\mathcal{L}_{adv} = \sum_{h=1}^{H}\sum_{w=1}^{W}\log D\left(\hat{y}_s^i\right)_{hw} + \log\left(1 - D\left(\hat{y}_t^j\right)_{hw}\right)$$

議題 5-3: 領域自適應學習影像分割模型測試架構設計

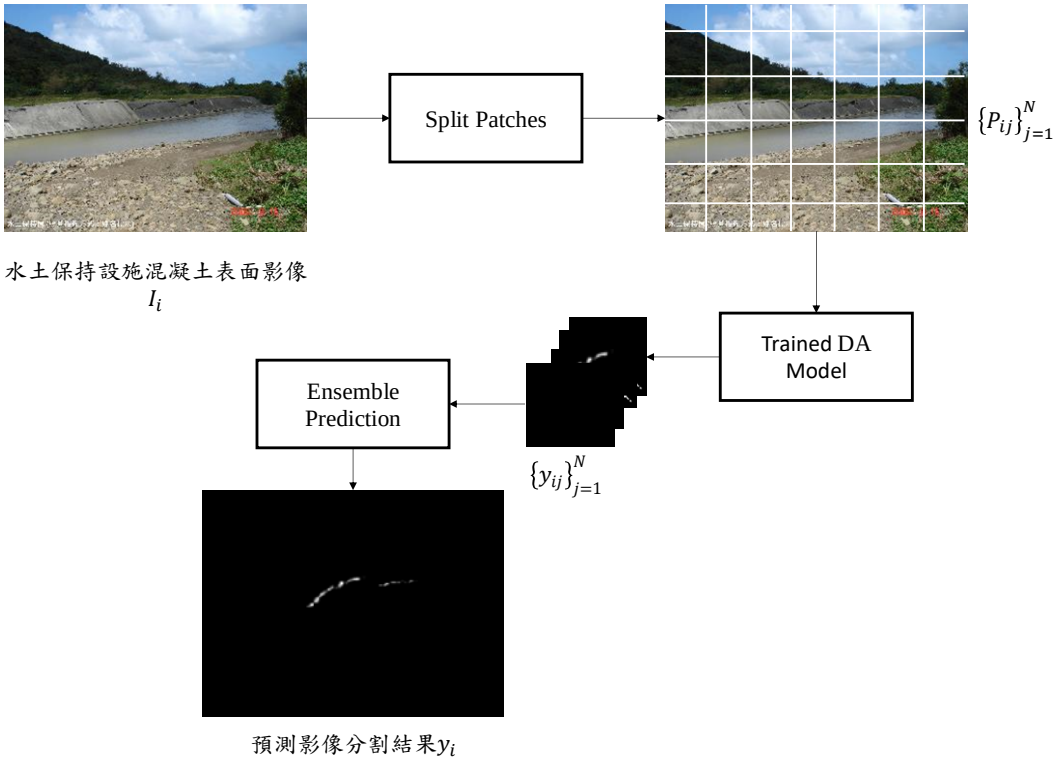


圖 2-43: 領域自適應學習影像分割模型測試架構

本議題利用議題 5-3 的結果預測水土保持設施混凝土表面影像。如圖 2-43，令I_i為一張$H \times W$的水土保持設施混凝土表面影像集的第 i 張影像，首先，輸入 Split Patches Algorithm(同議題 2-2)依 row-major 方法將影像分割成7×7個區塊後組合成由 49 張 patch images 的子影像集$\{p_{ij}\}_{j=1}^{N}$，p_{ij}表示第 i 張影像的第 j 個 patch image，N為 49 張。接著，將 49 張影像同時輸入到 Trained DA Model 得到每張影像裂隙分割的預測結果$\{y_{ij}\}_{j=1}^{N}$。最後，將預測結果依 reverse row-major 方法拼接成一張和原圖大小一樣的預測影像y_i。

議題 5-4: 判識影像是否含有裂隙

本議題應用**議題 5-3** 得結果，得到原影像I_i的裂隙分割預測影像y_i，引此可以判斷原影像I_i是否含有裂隙。觀察裂隙分割結果，可以發現有裂隙處(白色)為連續的圖形，其他無裂隙處(黑色)為平坦的圖形。根據此性質，本議題設計了決策函數$\gamma(\cdot)$來判別I_i是否含有裂隙。函數$\gamma(\cdot)$是利用影像的 total variation 來設計，將y_i輸入$\gamma(\cdot)$，若y_i的影像的 total variation $tv(y_i) = \|\nabla_x y_i\| + \|\nabla_y y_i\|$大於等於 threshold $T\gamma$(本議題設定T_γ為 0.5)，則判斷影像I_i中含有裂隙，若小於T_γ則判斷沒有裂隙。決策函數$\gamma(y_i)$的公式如下。

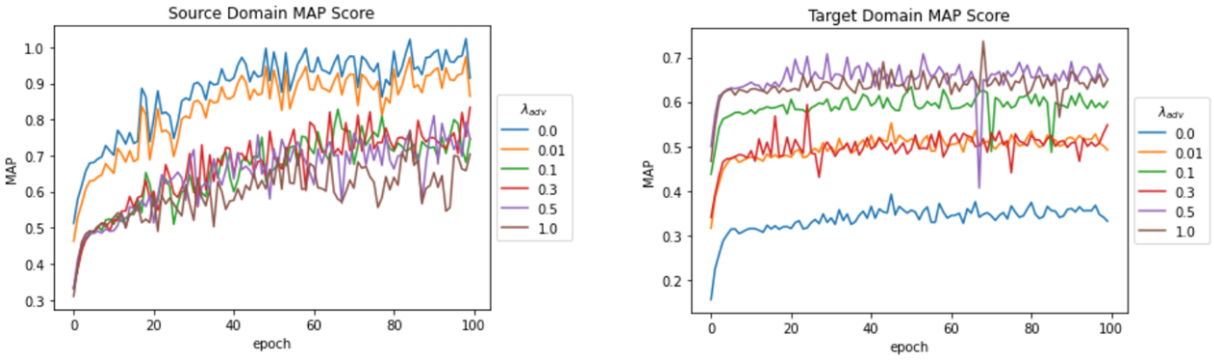
$$\gamma(y_i) = \begin{cases} 1\ , & tv(y_i) \geq T_\gamma \\ 0\ , & else \end{cases}, \qquad tv(y_i) = \|\nabla_x y_i\| + \|\nabla_y y_i\|$$

議題 5-5: 實驗效能評估

本議題呈現模擬實驗數據效能和視覺化結果。下列公式λ_{total}為整個訓練系統的損失函數。

$$\min_{\text{DA-PLG}} \max_{\text{PLD}} \mathcal{L}_{total} = \mathcal{L}_{cls} + \lambda_{adv}\mathcal{L}_{adv}$$

本議題討論$\mathcal{L}_{adv}$強度對於訓練 DA Model 的影響，λ_{adv}為λ_{adv}的強度係數，本實驗測試不同強度細述如下，$\lambda_{adv} = 0.0, 0.01, 0.1, 0.3, 0.5, 1.0$。



(a) Source Domain MAP Score

(b) Target Domain MAP Score

圖 2-44: DA 模型之 learning curve。(a)Source Domain MAP 效能，(b)Target Domain MAP 效能。

圖 2-44 呈現 DA Model MAP 指標的 Learning Curve。根據觀察，若$\mathcal{L}_{adv}$的強度增加，則 DA Model 在 Source Image Dataset

的 MAP 會越低，完全不使用$\mathcal{L}_{adv}$的情況下($\lambda_{adv} = 0.0$)則在 Source Image Dataset 有最佳的效能; 對於 Target Image Dataset，若給予λ_{adv}的影響越大，DA Model 在 Target Image Dataset 的 MAP 效能越好，若完全不使用$\mathcal{L}_{adv}$則 DA Model 在 Target Image Dataset 有極低的 MAP 效能。

表 2-11 為不同λ_{adv}在 Source 及 Target Image Dataset 的 Accuracy 和 MAP 效能比較。Accuracy 在此實驗的衡量的模型為議題 5-4 的決策函數$\gamma(y_i)$。由表 2-11 可發現，不使用λ_{adv}的 DA Model 在 Source Image Dataset 對 Accuracy 和 MAP 皆有最好的效能，但在 Target Image Dataset 有最差的效能。當$\lambda_{adv} = 1.0$時，DA Model 在 Target Image Dataset 的 Accuracy 有最佳效能，$\lambda_{adv} = 0.5$時，DA Model 在 Target Image Dataset 有最好的 MAP 效能。DA Model 在 Source 和 Target Image Datasets 的分割結果請看附錄六。

表 2-11: DA Model 在不同λ_{adv}的測試結果

Methods	Accuracy (Source)	Accuracy (Target)	MAP (Source)	MAP (Target)
$\lambda_{adv} = 0$	**0.92**	0.41	**0.89**	0.36
$\lambda_{adv} = 0.01$	0.86	0.52	0.84	0.49
$\lambda_{adv} = 0.1$	0.81	0.53	0.77	0.5
$\lambda_{adv} = 0.3$	0.81	0.53	0.78	0.54
$\lambda_{adv} = 0.5$	0.77	0.57	0.74	**0.64**
$\lambda_{adv} = 1.0$	0.72	**0.59**	0.70	0.63

六、**主題(6):** 響應式網頁呈現混凝土表面裂隙影像偵測與分割模型

本主題響應式網頁呈現主機的 URL 網址為 http:/140.120.7.219:8111，提供使用者上傳影像即時偵測影像是否有裂隙，能夠使用電腦版面及手機版面使用上傳影像及觀察偵測結果影像。因為系統架設在 VM 主機，無 GPU 運算資源，所以分析時間稍久，請耐心等待。

議題 6-1: 兩階段影像裂隙影像偵測與分割模型之響應式網頁呈現

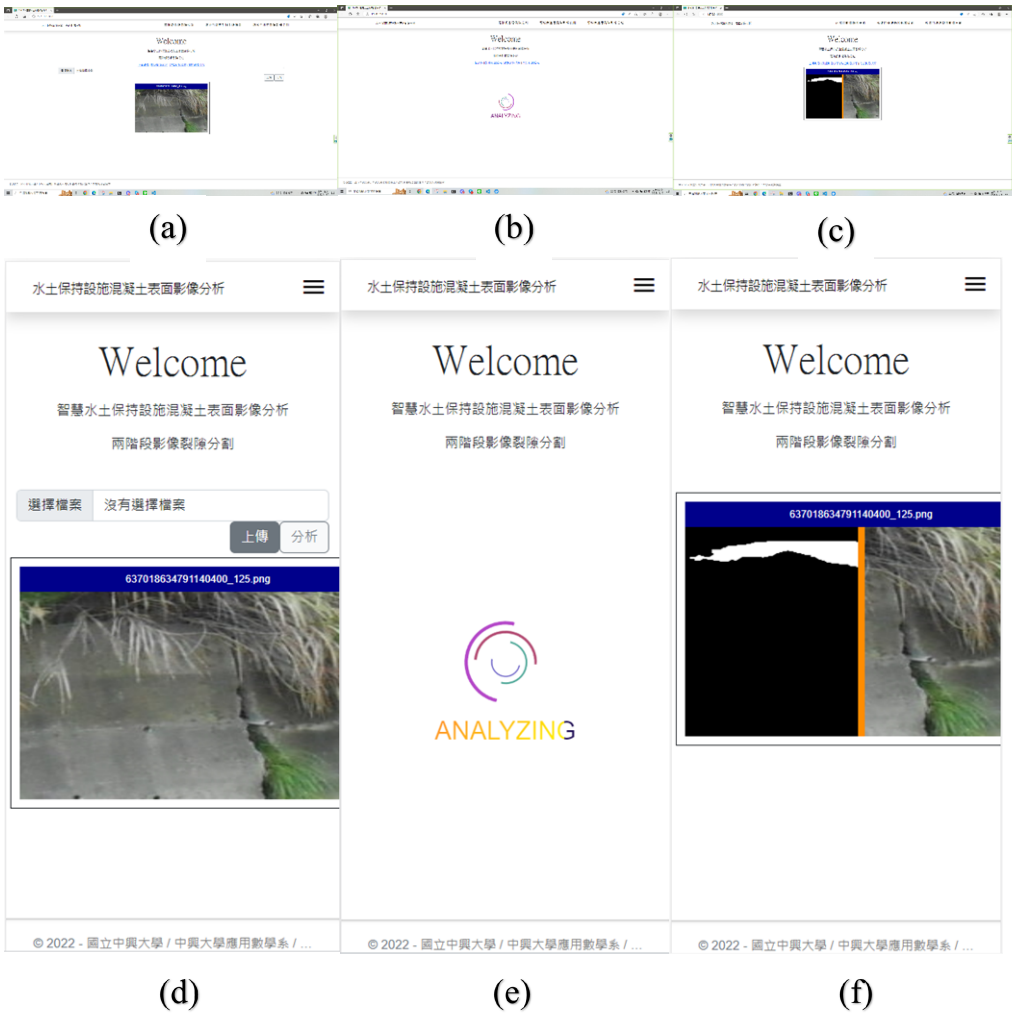


圖 2-45: 響應式網頁呈現兩階段影像分割結果。(a)電腦版上傳影像(b)電腦版執行過程(c) 電腦版結果影像呈現(d)手機版上傳影像(e)手機版執行過程(f)手機版影像呈現結果

議題 6-2: 智慧型混凝土表面裂隙影像區塊偵測之響應式網頁呈現

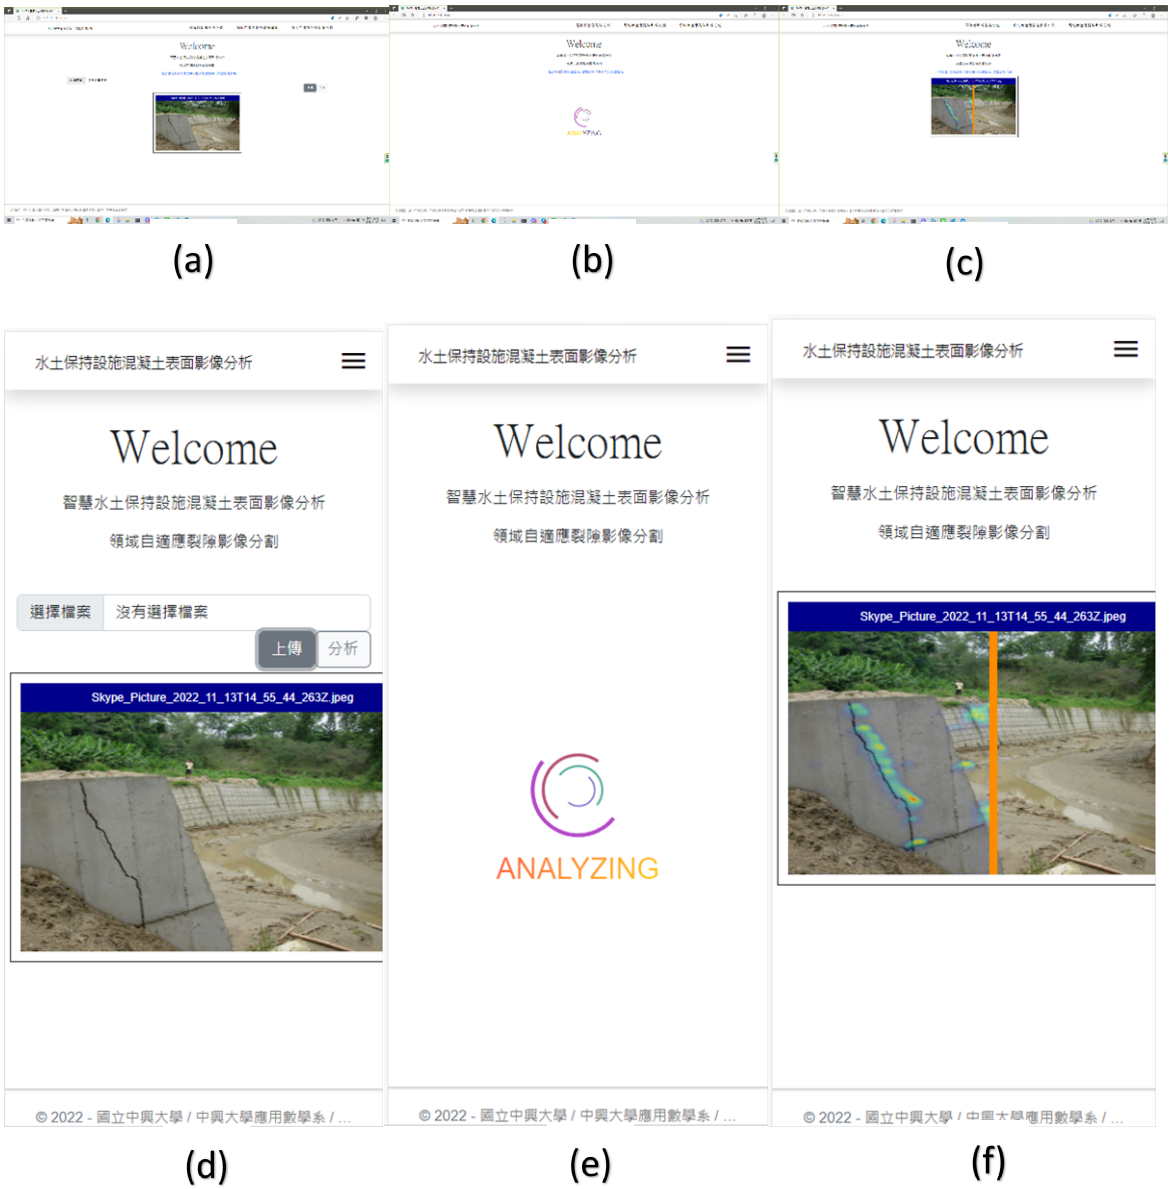
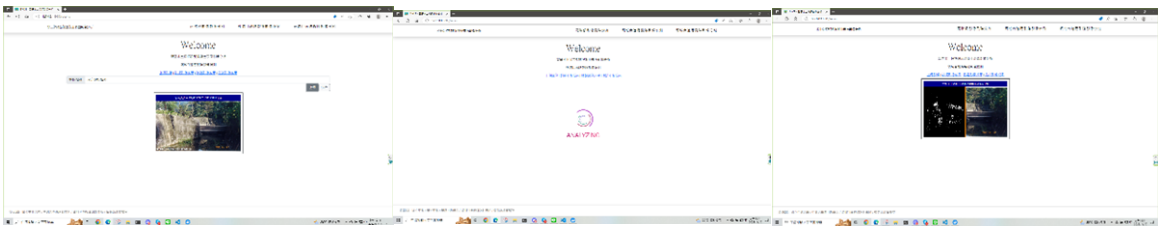
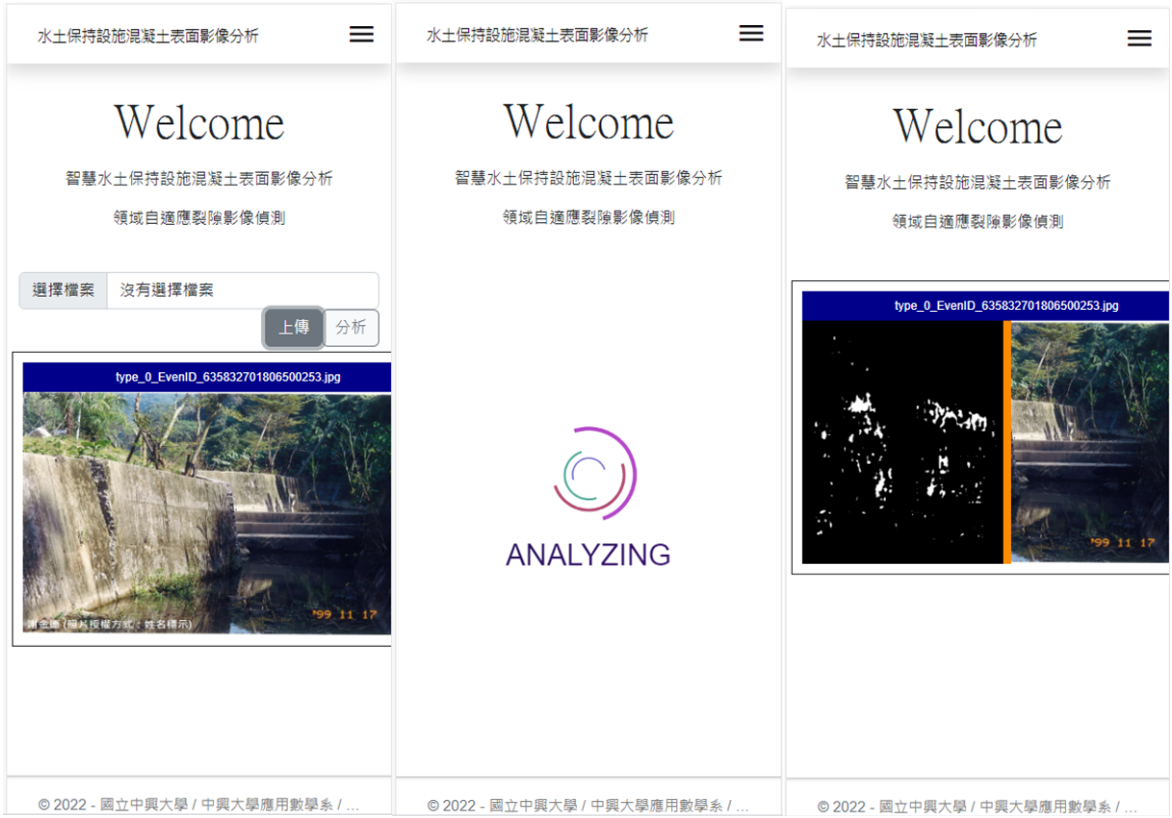


圖 2-46: 響應式網頁呈現影像偵測結果。(a)電腦版上傳影像(b) 電腦版執行過程(c) 電腦版結果影像呈現(d)手機版上傳影像(e)手機版執行過程(f)手機版影像呈現結果

議題 6-3: 智慧型混凝土表面裂隙影像分割之響應式網頁呈現



(a) (b) (c)



(d) (e) (f)

圖 2-47: 響應式網頁呈現影像分割結果。(a)電腦版上傳影像(b) 電腦版執行過程(c) 電腦版結果影像呈現(d)手機版上傳影像(e)手機版執行過程(f)手機版影像呈現結果

第三章 執行成果及效益

第一節　執行成果

聚焦於水土保持混凝土設施表面裂隙判識，蒐集水土保持局建置歷史影像平台(IRP)蒐集之歷年設施影像與部分水土保持竣工設施影像，來判識影像中是否有裂隙?主要利用深度影像分割及影像偵測技術，分析水土保持混凝土設施表面影像，本計畫可交付下列成果項目。

- 利用兩階段影像裂隙影像偵測與分割模型自動判識水土保持設混凝土設施表面影像，系統操作及展示影片各一份、系統效能分析結果報告一份。
- 利用領域自適應學習技術之智慧型混凝土表面裂隙影像區塊偵測模型自動判識水土保持設混凝土設施表面影像，系統操作及展示影片各一份、系統效能分析結果報告一份。
- 利用領域自適應學習技術之智慧型混凝土表面裂隙影像區塊分割模型自動判識水土保持設混凝土設施表面影像，系統操作及展示影片各一份、系統效能分析結果報告一份。
- 上述3系統的跨平台行動載具版(RWD網頁版)之操作說明及展示影片各一份。
- 提供標註資料庫一份。

第二節　執行效益

一、提供標註資料庫一份之效益，提供發展相關系統的實驗影像集。

二、利用兩階段影像裂隙影像偵測與分割模型，可以運用於自動判識水土保持設混凝土設施表面影像中是否含有裂隙內容，降低水土保持設施巡檢人力成本，提升巡查效率。

三、利用領域自適應學習技術之智慧型混凝土表面裂隙影像區塊偵測模型，可以運用於自動判識水土保持設混凝土設施表面影像中是否含有裂隙內容，降低水土保持設施巡檢人力成本，提升巡查效率。除了上述效益之外，可以在少量影像限制之下，訓練深度學習影像偵測模型。

四、利用領域自適應學習技術之智慧型混凝土表面裂隙影像區塊分割模型，可以運用於自動判識水土保持設混凝土設施表面影像中是否含有裂隙內容，標定影像中裂隙位置，降低水土保持設施巡檢人力成本，提升巡查效率。除了上述效益之外，可以在少量影像限制之下，訓練深度學習影像偵測與分割模型。

第四章 結論及建議

第一節　結論

本計畫已發展出三項技術，首先，「兩階段影像裂隙影像偵測與分割模型」，另外，基於領域自適應學習技術，來解決少量資料的問題，發展兩個模型，「智慧型混凝土表面裂隙影像區塊偵測模型」及「智慧型混凝土表面裂隙影像區塊分割模型」，能夠自動分析水土保持混凝土設施表面裂隙之識別。實驗測試影像來源以水土保持局建置歷史影像平台影像為主、土保持局提供影像及現場拍攝影像等三項為主，最後，也針對上述技術開發成本、效能及應用等面向進行可行性評估與分析。

第二節　建議

本計畫實驗影像蒐集範圍以水土保持局建置歷史影像平台(IRP)蒐集之歷年設施影像與部分水土保持竣工設施影像。初步分析此資料集，仍有些照片內容涉及個資、個人隱私、公告牌遮蔽設施結構及影像內容雜多(包含多項災害類別混合)，未來希望能先自動判識不適合建模的影像。另外，訓練深度學習的模型需要規格較高的硬體環境，例如 GPU 顯示卡的記憶體容量有限，無法設計較深多層模型，導致難以執行模擬實驗來證明，未來將尋找更佳效能的深度學習模型。再者，深度學習模型參數組合龐大，每項組合需要花費長時間來訓練模型，挑選更佳效能的模型。期望未來能夠針對無人機巡檢影像之影像分析研究，發展更佳的效能之分析模型及更便利的模型操作設計，提供水土保持局參考使用。

參考文獻

[1] Ganin, Y., & Lempitsky, V. (2015, June). Unsupervised domain adaptation by backpropagation. In *International conference on machine learning* (pp. 1180-1189). PMLR.

[2] TSAI, Yi-Hsuan, et al. Learning to adapt structured output space for semantic segmentation. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2018. p. 7472-7481.

[3] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In Proceedings of the IEEE international conference on computer vision (pp. 618-626).

[4] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2921-2929).

[5] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).

[6] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).

[7] Li, S., Zhao, X., & Zhou, G. (2019). Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network. Computer-Aided Civil and Infrastructure Engineering, 34(7), 616-634.

[8] Tian, J., Mithun, N. C., Seymour, Z., Chiu, H. P., & Kira, Z. (2022, May). Striking the Right Balance: Recall Loss for Semantic Segmentation. In 2022 International Conference on Robotics and Automation (ICRA) (pp. 5063-5069). IEEE.

[9] Van der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. Journal of machine learning research, 9(11).

附錄

附錄一、111 年水保局創新研究計畫審查意見暨回覆說明

項次	審查意見	回覆說明
為配合本局業務需求,計畫內容建議調整(或納入後續執行評估參考)部分：		
一	影像標註工作有的標註整個範圍,有的只標註裂縫範圍,例如第 20 頁所示例子。建議對於標註範圍再加以處理，讓標註範圍一致，彼此之間就可以比較了。	**議題 2-1(P2-9~P2-10)** 說明 將標註裂隙範圍與欲比較之範圍(例如: 裂隙背景)。
二	如果連用來訓練的影像數目都嚴重不足，那麼研究完成之後要如何驗證？將來又要如何應用？	**背景(P1-4~P1-9)**說明 有些特殊影像不易收集，導致影像數目都嚴重不足，一般常見的做法是用 oversampling 技術增加人工產生影像，即可增加訓練影像來訓練 AI 預測模型。而驗證 AI 模型時將使用非人工影像觀察其

項次	審查意見	回覆說明
		正確性。
三	保設施表面裂縫，可能係施工縫或申縮縫，因此如何避免誤判，或可利用光達或多光譜影像進行判釋，以增加正確性與可信程度。建議研究如何以空拍動態影像快速判斷裂縫之走向與連通程度，並量化提出預警。	本研究主力聚焦於設計 AI 模型偵測水保設施表面裂隙。至於利用光達或多光譜影像判釋施工縫或申縮縫之問題本研究也將進行評估，首先需要了解光達或多光譜影像定義，如果可以收集光達或多光譜影像及建立 AI 模型來判釋施工縫或申縮縫。有關空拍動態影像快速判斷裂隙之走向與連通程度，本研究進行評估是否可取得空拍動態影像?如果有空拍動態影像，可以針對固定水保設施表面來做空拍動態影像收集，也要觀察是否有收集到水保設施表面裂隙之走向之影像? 如果有

項次	審查意見	回覆說明
		就可以建 AI 模型判斷裂隙之走向與連通程度。
四	大量使用人造影像作為訓練樣本，是否會造成同質化太高的問題？	除人造影像作為訓練樣本外，還將加入 Augmented images，實際影像(非人工影像)作影像處理後的影像加入訓練樣本。儘量降低影像同質化太高的問題。

附錄二、111 年期初工作執行計畫書審查意見暨回覆說明

項次	審查意見	回覆說明
期初需求訪談**內容與意見：**		
委員一		
1.	請先明確設定影像特性,例如是任何種類影像,或是固定位置之監視影像。不同影像特性應該有對應的處置方式與判識正確率評估方式。	**結論(P4-1)**說明本計畫研究影像限制 本計畫主要研究影像來源為 CCTV 拍攝影像，從以下來源: • 水土保持局歷史影像平台 • 水土保持局提供混凝土設施缺失影像 • 與本校水土保持系教授合作至現場拍攝實驗影像 • 網路上公開提供之水泥表面裂隙影像集。
2.	影像紋理是否代表唯一解?用何種方法確定影像空間特性與物體空間的準確性?例如水泥表面水漬與裂隙如何在本模型中區隔?	本計畫用深度學習卷積模型，提取影像特徵，其中特徵以紋理及顏色為主，未來會在深度研究，來分辨水泥表面裂隙與水漬差異。
3.	深度學習的訓練模型打算做哪幾類?多少組?模型樹是以各類單獨 TF 訓練,還影像判識法則將內涵事件逐一找出來?	**背景(P1-4~P1-9)**說明 本研究將影像分為有裂損及無裂損，訓練模型來自於網路上公開提供之水泥表面裂隙影像集，各類別提供兩萬張影像，基於上述影像集，本計畫即將發展少量影像的訓練模型 (adversarial domain learning)，因為護岸及護坡設施裂損影像不多。

項次	審查意見	回覆說明
4.	建議宜清楚本方法適用時機與必要影像條件,例如解析度、距離、標的物大小等。	**結論(P4-1)**說明本計畫研究影像限制 • 當有大量影像輸入，本計畫可以自動辨識 • 一般 CCTV 拍攝影像解析度為主。 • 影像來自於水土保持局歷史影像平台、水土保持局提供混凝土設施缺失影像、與本校水土保持系教授合作至現場拍攝實驗影像、網路上公開提供之水泥表面裂隙影像集。
委員二		
1.	現今人工智慧對像判識算法頗多,各有其應用優劣與時機,建議針對演算法理論加強回顧說明,尤其是本計畫選用的方法。	謝謝委員意見，遵照辦理。
2.	攝影機之距離、角度及影像解析度不同都將影響判識成果,請敘明可判識的裂縫大小極限與限制。	**結論(P4-1)**說明本計畫研究影像限制 • 當有大量影像輸入，本計畫可以自動辨識 • 一般 CCTV 拍攝影像解析度為主。 • 影像來自於水土保持局歷史影像平台、水土保持局提供混凝土設施缺失影像、與本校水土保持系教授合作至現場拍攝實驗影像、網路上公開提供之水泥表面裂隙影像集。
3.	評估模型判讀果優劣的指標為何?	**背景(P1-10)**說明

項次	審查意見	回覆說明
		• 分類採用 Mean Average precision rate。 • 影像分割採用 MeanIoU。
委員三		
1.	本研究主要運用影像判識技術監測水泥表面裂損,除了訓練影像蒐集外,建議也應律定可用影像品質之標準。	**結論(P4-1)**說明 • 一般 CCTV 拍攝影像解析度為主。 • 影像來自於水土保持局歷史影像平台、水土保持局提供混凝土設施缺失影像、與本校水土保持系教授合作至現場拍攝實驗影像、網路上公開提供之水泥表面裂隙影像集。
委員四		
1.	為克服訓練影像不足困難,建議運用水土保持局既有之水土保持設施缺失態樣圖集、工程管考系統蒐集已有 20 年以上各工程施工、督導查核缺失及竣工等龐大相片圖庫,以避免以人造影像做為訓練樣本,影像同質化太高,導致運用範圍受限及可信度降低。	**主題一(P2-5~P2-8)**說明 本計畫亦從下列來源蒐集影像集 • 水土保持局提供混凝土設施缺失影像 • 與本校水土保持系教授合作至現場拍攝實驗影像。
2.	預定 8 月中旬至 11 中旬架設線上網站提供裂隙偵測服務,建議先赴工地現場拍攝圖像,用以驗證其功能之有效性,並對所需影像加以規範。	**附錄七(P 附錄-17~P 附錄-18)**說明 預計 8-9 月份，與本校水土保持系教授合作至現場拍攝實驗影像，該影像作為驗證本計畫 AI 模型之有效性。
委員五		

項次	審查意見	回覆說明
1.	使用人工產生影像作為學習樣本,是否會造成過度學習或同質性太高的問題?	本計畫蒐集網路上公開提供之混凝土表面裂隙影像集，並採用 adversarial domain learning 技術，
2.	影像分類時注意護岸型式是否砌石護岸、造型模板等。	謝謝委員意見，遵照辦理。
3.	使用情境宜先釐清,俾能確定研究目標有其應用可能,此部分建議先與領域專家討論。	**結論(P4-1)**說明 • 已定期諮詢興大水土保持系教授,提供意見。也協助一起至現場實地模擬巡查護岸及護坡地設施，拍攝影像，當本計畫實驗影像。 • 使用情境為分析 CCTV 回傳之大量影像輸入，本計畫可自動辨識裂損。
委員六		
1.	水上保持局歷年數萬件防砂工程,廣布於全台山坡地及野溪,以工程體檢及維運管理的概念而言,須加裝多少現場攝影機才足以進行相關工程品質維運管理的工作?	後續影像辨識技術成熟後，除了攝影機外，還可利用無人機(CCTV)大範圍拍攝影像,提升維運管理效率。
2.	建議進行可行性及成本效益之評估。	影像辨識技術成熟後，可以降低人力識別成本。
3.	以現場經驗來看,水土保持防砂工程損壞僅少部分係混凝土本身裂損破壞,大部分為基礎淘刷造成不均勻沉陷導致結構破壞,建議說明如何擴大本研究影像分析技術至防砂結	如果可以蒐集更多基礎淘刷影像，並分析基礎淘刷影像特性,於未來研究可來最佳化 AI 模型，應用於判識是否有基礎淘刷。

項次	審查意見	回覆說明
	構基礎淘刷問題,建構現場構造物預防保養及維運管理之機制。	
4.	本計畫影像辨識技術是否可能應用在本局現場土石流觀測系統所拍攝之影像分析,即時判識土石流發生與否,提供土石流相關預警訊息。	未來研究可以嘗試取得土石流觀測系統所拍攝之影像，於未來研究可來最佳化AI模型，應用於判識是否有土石流徵兆。
5.	本計畫在做分類判識是否需訂定最小的門檻值,如裂縫寬度超過多少以上才能判識,以瞭解其限制。	**結論(P4-1)**說明 實體標的物大小會隨著拍攝距離及角度產生極大影響，本計畫主要蒐集影像來自於網路，來源複雜難以確認拍攝地點與裂損區域距離，因此未來再將此意見列入研究議題。
委員七		
1.	本計畫未來應用為何?如透過相關監造或工程體檢計畫所拍照片,做影像判識可否找出狀況。	**結論(P4-1)**說明 本計畫可自動辨識裂損。未來可以分析相關監造或工程體檢計畫所拍照片。
2.	看到的均為已有破壞狀況,是否有利用正常照片進行誤判的檢核。	**(P 附錄-14~P 附錄-16)說明** • 網路上蒐集影像含無裂隙及有裂隙影像各兩萬張 • 水土保持局提供照片，針對照片取樣其子影像，分為有裂隙及非裂隙兩類。

附錄三、111 年期中報告書審查意見暨回覆說明

項次	審查意見	回覆說明
委員一		
一	為克服訓練影像不足困難，仍建議洽請主辦單位篩選取得水土保持局既有之水土保持工程管考系統 20 年以上各工程施工、督導查核缺失及竣工相片圖庫做為訓練樣本。	**主題一(P2-5~P2-8)**說明 • 已取得水土保持局部分竣工相片圖庫，影像涉及個資，因此數量不多。 • 水土保持歷史影像平台。 • 實地拍攝(測試影像) 。 訓練影像不多，本計畫已發展少量影像訓練辨識模型方法，可以克服訓練樣本不足困難。
二	內文之「混泥土」請依常用名詞修正為「混凝土」。	已更正，感謝委員。
三	由 Kggle 所收集之影像多偏向於路面之裂隙，與水土保持設施之護岸、擋土牆、防砂壩等產生之損害行為，差異甚大，應評估資料之可運用性。	本計畫研究聚焦於混凝土護岸裂隙偵測與分割，裂隙樣態較為相似，因此本計畫研究成果效能尚可，未來其他的水土保持設施，加入研究範圍，如:擋土牆、防砂壩等，再審慎評估運用性。
四	採樣影像區塊切割、合併、範圍大小選定原則、選取特徵如何	**議題 2-2(P2-11~P2-12)** 說明。

項次	審查意見	回覆說明
	比對，請予詳述以利往後推廣運用。	• 本計畫固定區塊切割大小，區塊大小由實驗模擬決定。 • 選取特徵及比對:由類神經網路判識影像中梯度變化量較大的區域，作為裂隙特徵，利用向量 L2 norm 來比對。
五	系統效能析應包含對比結果可信度、可攜帶現地操做性、設備需求等。	**背景(P1-10)** 說明量化指標 **主題六(P2-51~P2-53)** 說明 RWD • 使用量化指標來評估效能可信度。 • 主題六，RWD 網頁呈現研究成果，提供使用者上傳影像呈現辨識結果。
委員二		
一	建議針對水土保持設施其水泥表面裂情形進行不同嚴重程度之分類，亦即當判識出不同程度之表面裂損後，即可提出相對應之後續處理措施；同時建議參考並聯結目前水土保持局保育治理組有關治山防災構造物體檢之分類及操作程序，以使本計畫成果未來能更有實用之價值。	**主題六(P2-51~P2-53)** 說明 • 本計畫研究聚焦於裂隙偵測及 Grad-CAM 視覺呈現，另外亦提供裂隙影像分割。 • 本計畫先以可目視判識之裂隙作為初期自動識別研究，判斷混凝土表面是否有裂隙，至於其大小、深度等，本研究無法判識，尚無法自動達到治山防災構造物體檢之分類，希望未來研究可以望此方向研究精進。

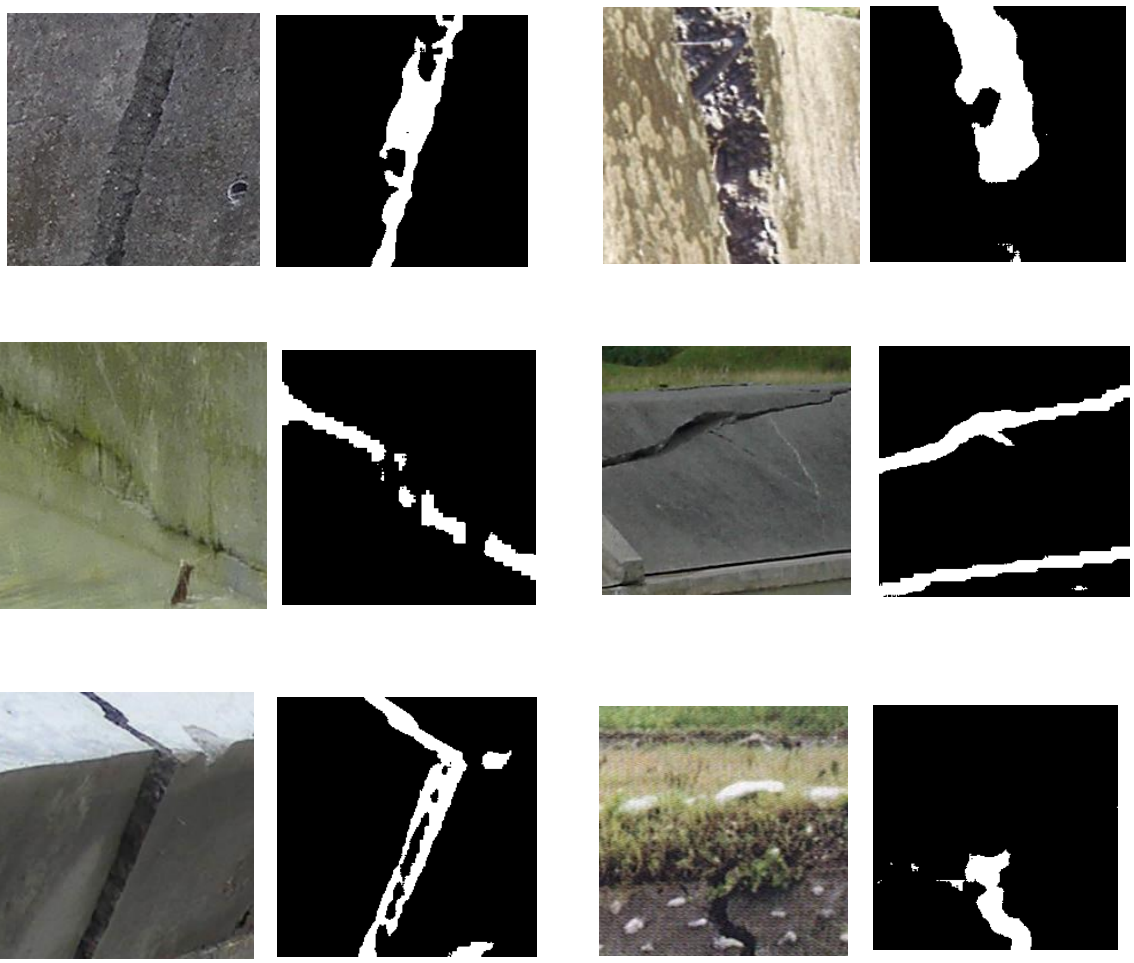
項次	審查意見	回覆說明
二	以實務上來說,水土保持治山防災構造物損壞的主因為基礎掏刷造成結構物破壞，建議本計畫除了發展水泥表面裂損情形的自動判釋技術外，亦能針對是否能自動判釋結構物基礎掏刷之能力進行客觀的評估，並說明其未來可能發展的方向及應用。	•今年度計畫聚焦於少量影像裂隙偵測及分割。 •基礎淘刷辨識是未來可能的研究方向。
三	建議針對本計畫可自動判釋之像影像品質進行完整的規範及說明，並提出影像品質參數的最低門檻值，以利後續其它人員應用本計畫成果時，建立影像品質之相關條件需求及限制。	**結論(P4-1)**說明 •相機拍攝影像解析度至少具有 4K 畫質。 •拍攝影像品質以人眼能辨識設施表面裂隙為基準。 •相關條件與限制寫入期末報告結論中。
四	有關各期審查會議員回，建議除應完整答覆之外，同時亦應於回覆內容中清楚說明其修訂於報告書之頁碼及位置，以利前後參照。	遵照辦理。
委員三		

項次	審查意見	回覆說明
一	P2-3 說明已蒐集水泥護岸裂縫、水泥護岸破損、水泥護坡裂縫、水泥護坡破損四類照片，但表 2-2-1 之分類又不相同?建議應一致，且「地基」應為「基礎」。	**議題 1-1(P2-5)**說明 於期末報告更正，謝謝委員。
二	承上，圖 2-2-1-1 之(a)~(d)四張照片，應選取對上述四個分類的代表性照片，以確認是否符合水土保持或土木領域之定義與分類。	**議題 1-1(P2-5)**說明 •簡化成護岸裂隙與護坡裂隙，即兩類護岸及護坡混凝土表面裂隙影像。
三	P2-4 「道裂縫檢測」是否應為「道路裂縫檢測」。	**議題 1-1(P2-5)**說明 期末報告更正，謝謝委員。
四	P2-7 圖 2-2-1-8(a)~(d)應說明屬於何種缺失。	**P2-8** 說明 •取得影像時，說明文件中僅標示此為裂隙影像。
五	P2-34 建置互動式水泥表面裂縫偵測模型之使用情境為何? 對一般人而言，裂縫乃直覺可見，為何需要一個網頁查詢有無裂縫?	**主題六(P2-51~P2-53)**說明 •網頁能夠讓使用者動態使用裂隙偵測模型結果，提供使用者體驗，作為宣傳使用。 •到護岸及護坡現場場域，用攝影器材拍攝，即可提供即時裂隙辨識成果。
六	建議應朝向發展如UAV定期巡後，自動判識及標註類似有毀	遵照辦理，委員建議列為下一年度研究重點議題。

項次	審查意見	回覆說明
	損或裂縫之功能，可能較有實務應用性。	
委員四		
一	模型偵測與辨識裂縫、裂損程度具有定成效，惟從報告中樣本來看，照片焦距遠近可能會影響大裂縫或小裂縫的辨識程度(裂縫與照片像素比例)，若未來以 CCTV 影像為主，或以勘查照片、UAV 巡等，建議可比較常見巡檢情境，以及適用之拍照距離、尺寸、像素等。	**結論(P4-1)**說明 •本計畫會同興大水土保持系詹教授及其團隊，至"頭汴溪 中埔十號橋"，介紹並教導拍攝影像護岸表面裂隙影像， 粗判相機其解析度至少具有 4K 以上畫質。 •拍攝影像品質以人眼能辨識設施表面裂隙為基準。 •UAV 巡檢情境拍攝影像品質，也應以人眼能辨識設施表面裂隙為基準，以此基準訂定 UAV 巡檢參數，如: 高度、飛行速率、固定航線、逆光拍攝、側風強度等。。 •相關條件與限制寫入期末報告結論中。
二	摘要中提到移學習的應用，建議於後續報告中補充(或研究架構圖補充)，用於遷移的其他模型、改良既有辨識模型的成效，或已經由目前演算法克服。	**背景(P1-4~P1-9)**說明 遵照辦理，於第一章第三節背景的 3-1 及 3-2 小節，提供本計畫使用的遷移學習，自適應領域學習技術(DA)說明，既有的遷移學習模型。

附錄四、兩階段影像裂隙影像分割結果

區塊混凝土設施裂隙影像分割

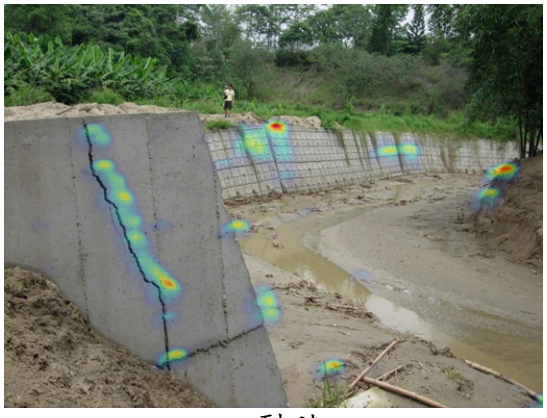


區塊混凝土設施表面分割



附錄五、智慧型混凝土表面裂隙影像區塊偵測結果

下圖偵測準確率較佳的結果



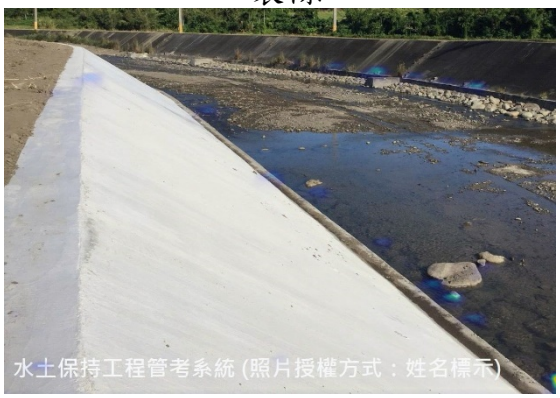
裂隙



裂隙



施工縫



表面無缺失

下圖偵測準確率不高的結果

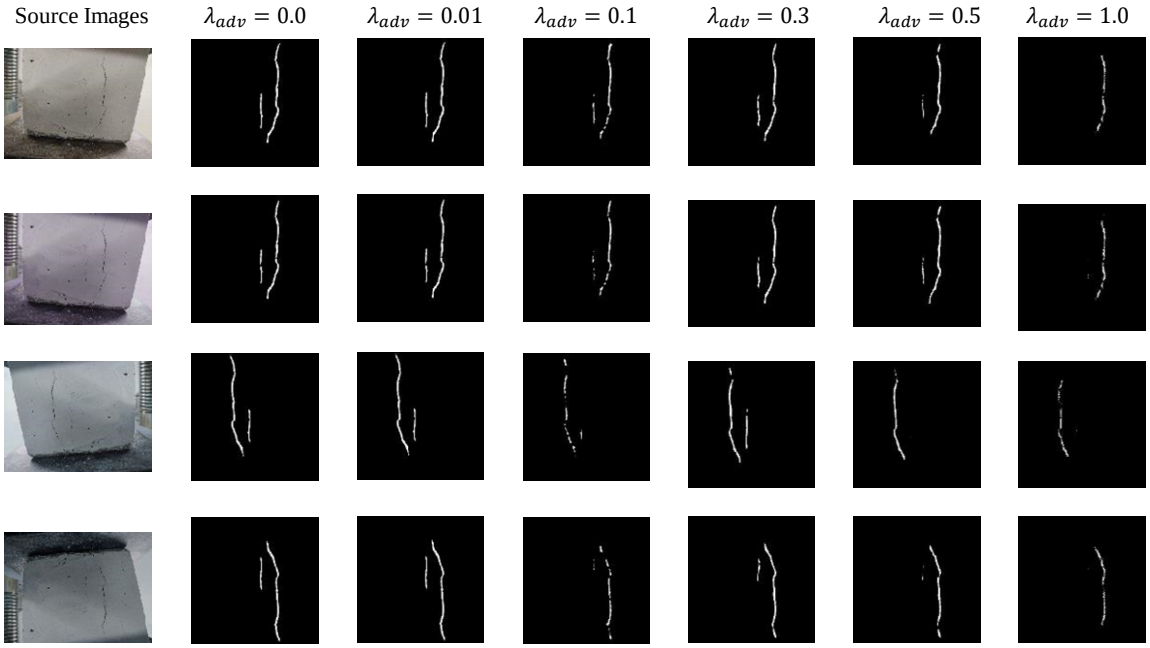


表面無裂隙(誤判)

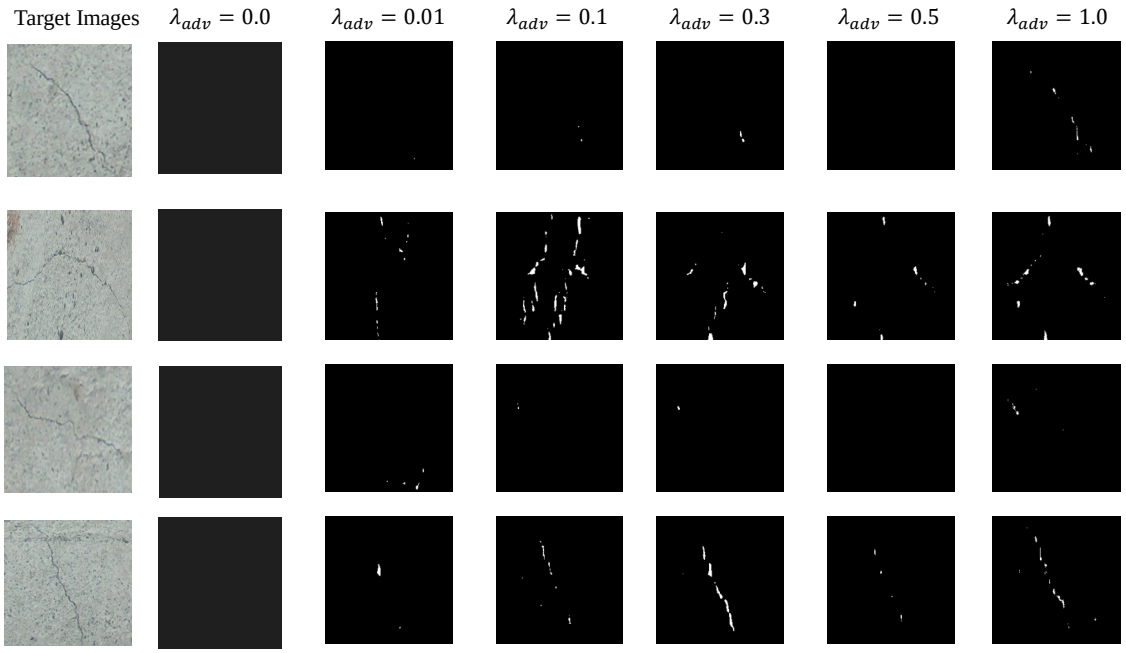


表面破損(無法辨識)

附錄六、智慧型混凝土表面裂隙影像分割結果



Source Image 裂隙預測結果



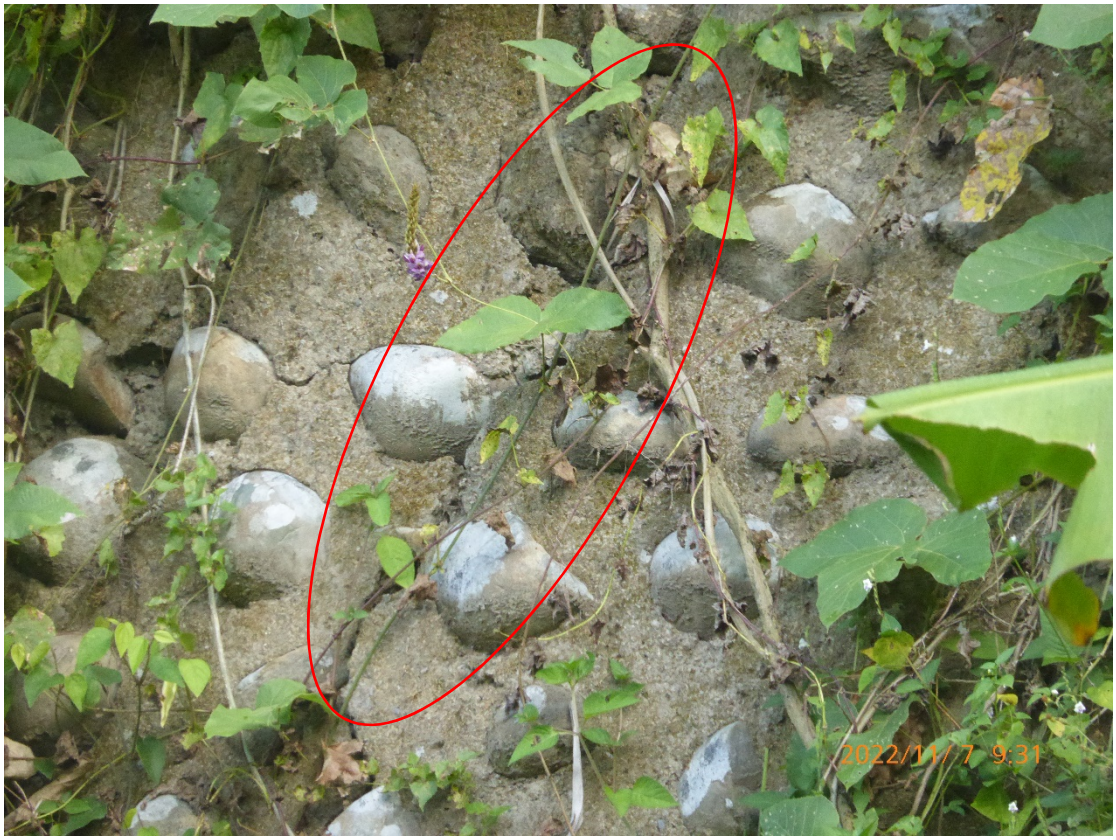
Target Image 裂隙預測結果

附錄七、實地拍攝水土保持設施(頭汴坑溪)

會同中興大學水土保持系主任 詹教授及其助理，實地至台中市太平區頭汴坑溪中游(中埔十號橋附近)，介紹水土保持設施混凝土表面裂隙狀況，提供拍攝樣本照片如下，紅色框表示裂隙區域。






2022/11/ 7 9:31


2022/11/ 7 9:31

附錄八、111 年水保局創新研究計畫期末報告審查意見暨回覆說明

項次	審查意見	回覆說明
為配合本局業務需求,計畫內容建議調整(或納入後續執行評估參考)部分：		
一	建議強調裂隙與構造物安全性之連結，較符合實際應用面。	**謝謝委員的意見。** • **未來執行計畫會積極與水土保持專家合作探究裂隙形狀大小與構造物安全性之連結。**
二	在水泥表面裂損圖片資料量不足的情況下,仍能有相當成果,實屬不易。	**謝謝委員，本計畫目標想發展少量影像資料建模方法。**
三	判識準確度仍有進步空間，另應用面上可再多發想，強化社群技術發展的必要性。	**強化辨識準確度** • **強化物件辨識:本研究預測模型以少量影像資料建模，其便是精確度比較有限，因此強化模型設計的效能，能去辨識影像中的物件，例如:天空,草地等,透過影像場景強化混淆物件的偵測，提升辨識準確度。** **社群技術發展未來計畫會再研究。**
四	影像辨識裂縫精度可達多少?對於水保局常用的造型模板辨識效果如何?可否有效辨識裂縫或模板形狀?	**影像辨識精度** • **精度以人眼能辨識設施表面裂隙為基準,且影像解析度足夠高,希望能蒐集夠多解析度為 4K 的影像。**

項次	審查意見	回覆說明
		造型模板辨識 •在實驗影像測試中，造型模板辨識效果較混凝土表面差。 •未來研究透過頻域訊息，分析有紋路的造型板模特徵，以此強化模型設計，強化辨識效能。
五	根據研究，模型學習需要配合大量資料來提升準確度，那在遇到照片資料量不足的情況下是如何克服?	針對少量影像訓練，本計畫採用以下三種方法克服。 •裁切原始影像為區塊影像，降低影像複雜度，擴增影像樣本數量。 •網路蒐集大量裂隙影像，作為輔助的訓練影像。 •利用領域自適應學習技術，這是一種以少量資料來建模的方法，克服影像資料量不足的問題。
六	想請問資料來源解析度及表面材質不一情形，對辨識效果會有何影響?未來又如何強化辨識準確度?	解析度 •在本計畫的實驗中，發現若解析度太低，裂隙影像難以辨識。 •因此如果影像解析度能大於 4K，將有較佳的辨識效果。 設施表面材質不同 •由於不同表面材質特徵差異甚大，效果較差。

項次	審查意見	回覆說明
		•未來如果有蒐集到不同表面材質之影像，可以微調模型參數，強化辨識準確度。
七	請問水泥表面裂損之判識，是否會受到水泥表面顏色或雜物(如雜草)等影響?本研究是否可有效辨識。經過一段時間，水泥顏色通常因潮濕而變色，且有雜草生長。	設施表面變化 •在測試影像中，水泥表面因潮濕變色或長青苔，仍然具有不錯的辨識效果。 •若是設施遭到雜草或其他遮蔽物遮擋，辨識效果較差。 •若混凝土表面存在與裂縫特徵相似的物件，如:黑色樹枝、黑色蜘蛛網等，可能人會誤判為裂縫。