



深度學習應用於近岸即時影像辨識 海岸線變化之研究

國立臺灣海洋大學河海工程學系助理教授 / 蘇元風
國立臺灣海洋大學河海工程學系碩士生 / 游皓月

關鍵字：監視影像 (CCTV)、深度學習 (Deep Learning)、岸線變遷 (Shoreline Dynamics)、
影像辨識 (Image Recognition)

摘要

臺灣沿岸地區常受到颱風、暴潮與東北季風交互作用影響，其中以颱風對沙灘短期且大範圍地形變動之影響最為顯著。然而，傳統侵淤測量需花費大量時間與人力，使用近岸 CCTV 影像監測，可即時記錄鹽寮沙灘的變動情況。本研究使用鹽寮沙灘 2024 年之 CCTV 監視影像，採用深度學習 U-Net 架構並加入注意力機制進行影像分類，藉此取得不同時間的海岸線變化，結合海上潮位觀測資料，取得鹽寮沙灘潮間帶的三維變化資料，量化分析近兩年間颱風事件對鹽寮沙灘寬度與地形變動之影響。

壹、前言

臺灣地理位置四面環海且位處西北太平洋颱風路徑上，沿岸地區長期承受颱風、暴潮與東北季風交互作用影響。

本研究以鹽寮沙灘為主要研究區域，由於地形量測多仰賴人工實測，不僅耗時費力且受天候條件限制，難以即時且高頻率地取得地形資料，期藉由引入 CCTV 影像辨識方法對沙灘進行長期監視，可從影像中提取沙灘岸線並計算沙灘寬度，以達到長期、高頻率對沙灘岸線監測。



貳、文獻回顧

深度學習 (Deep Learning) 在近年有快速的發展在各項領域中都有飛速的發展，例如：影像、語音、文字等。2012 年 Krizhevsky 等人的 AlexNet 在 ImageNet 分類比賽中使用深度卷積神經網路 (Convolutional Neural Network, CNN) [1]，大幅提升圖像識別準確度，開啟後來深度學習的發展。

在影像辨識任務上，常見包含影像分類的 CNN、物件偵測的 YOLO、以及影像分割的 U-Net [2,3]。CNN 透過卷積／池化與參數共享降低複雜度，適合做整張影像的類別判定 [4]，並已應用於裂流辨識與波破型態分類 [5,6]。YOLO 則強調演算速度與偵測即時性，適合用於物件偵測 (object detection)，例如：海洋垃圾偵測 [7]。U-Net 屬語意分割，透過編碼器／解碼器擷取多尺度特徵，能在較少標註資料下進行像素級分類；U-Net 在提出時，主要應用於醫學影像的物體分割 (object segmentation)，在海岸工程中則可應用於水陸邊界／岸線與地物 (沙灘、植生、浪花帶等) 分割。Chang 等以 U-Net 搭配 SAR 偵測臺灣多類沿海地形岸線 [8]，訓練準確度達 99.5%，且多數結果可在 5 像素內取得良好 F1-score；Santos 等人則以 U-Net 與 DeepLabv3+ 從固定式監測影像自動提取岸線 [9]，突顯出固定式影像在高頻、連續監測上的優勢。

參、研究方法

本研究於鹽寮沙灘設置 CCTV 影像系統自 2023 年 10 月起以高解析度之廣角鏡頭涵

蓋研究區域，並在研究區域中測量控制點，將 CCTV 畫面轉至地圖投影座標上，以利進行影像標籤化 (labeling) 作為深度學習訓練之用，最後藉此監測海岸線變化。本研究可分為三部分：影像前處理、影像品質檢查，及深度學習模型建立，最後透過混淆矩陣方法評估模型準確度。以下將依序說明各方法。

一、影像資料

1. 影像前處理

本研究所使用之 CCTV 影像拍攝時間從每日上午 6 點至下午 18 點間，每小時的前 30 分鐘內每十分鐘儲存一個影片，每天總計有 52 個影片檔。為方便後續深度學習模型辨識，需要先將影片前處理為平均影像後再繼續影像處理。

地面控制點測量實驗於 2024 年 1 月 18 日上午 11 點至下午 1 點之間進行，用黑白棋盤格板作為控制點標的，分批佈置在研究區域的沙灘上，並用 GPS 紀錄每一個控制板中心座標及高度，共取得 36 個控制點座標，作為影像轉換至地圖投影座標系統 (TWD97) 的檢核點，如下圖 1 所示。

2. 影像品質檢查

本研究使用之影像鏡頭位處建築物外，故鏡頭畫面易受到天氣因素影響，例如：下雨、颱風、日照時間，造成影像模糊不清不易辨識。將平均影像輸入卷積神經網路 (Convolutional Neural Network, CNN) 模型，自動判斷其品質是否符合分析標準，流

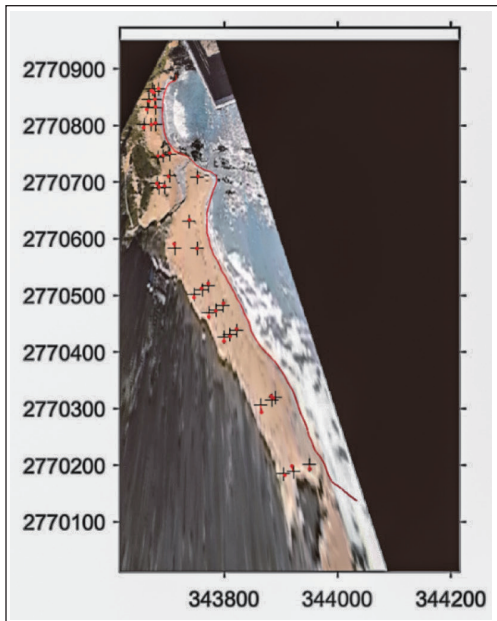


圖 1 地圖投影座標與控制點分布

程如圖 2 所示，當影像被分類為「正常」時，才會進入位移校正與正射校正流程；若為「夜間」或「模糊」類別，則不納入岸線分析，避免影像品質不佳造成的誤差。

由於 CCTV 鏡頭在外在環境下容易受到地震或是強風造成影像偏移，並將造成影像投影後的誤差擴大，因此本研究選擇位於南側之大礁石作為偵測標的物，以此進行影像偏移校正，其流程如圖 3 所示。

基於使用之深度學習模型為監督式學習，在模型訓練前需將前處理完成的影像進行類別標籤化 (labeling)，將影像中不同物件個別分類。依序為海水、沙灘、礁岩、植生、建築及無類別，成果如圖 4 所示。

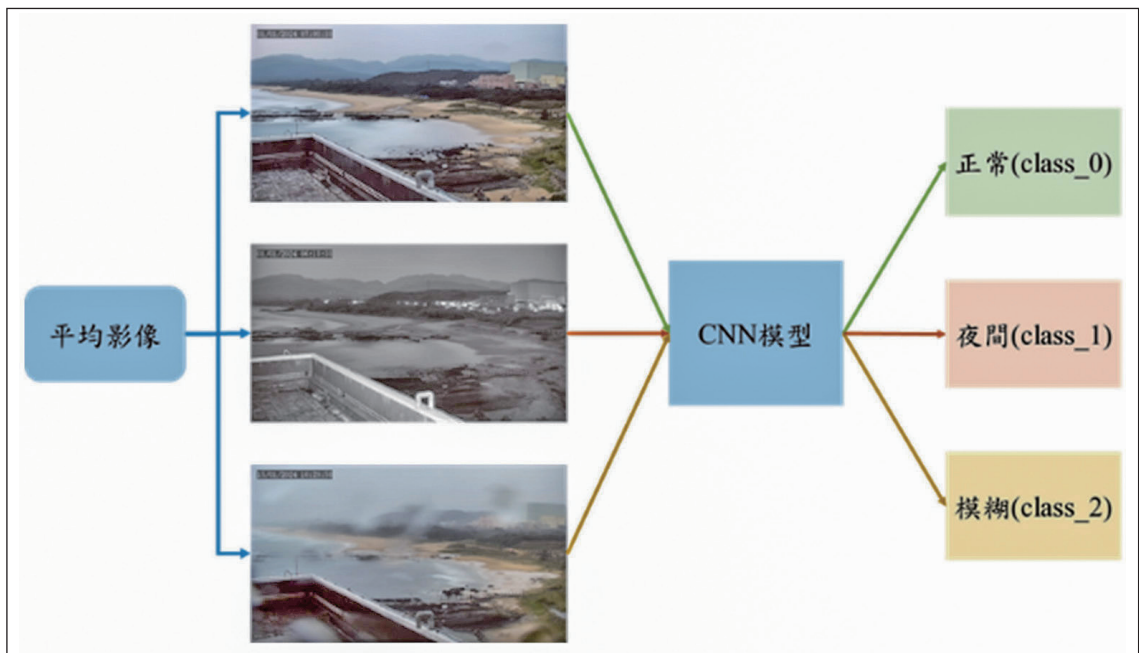


圖 2 CNN 模型之畫面品質分類流程圖

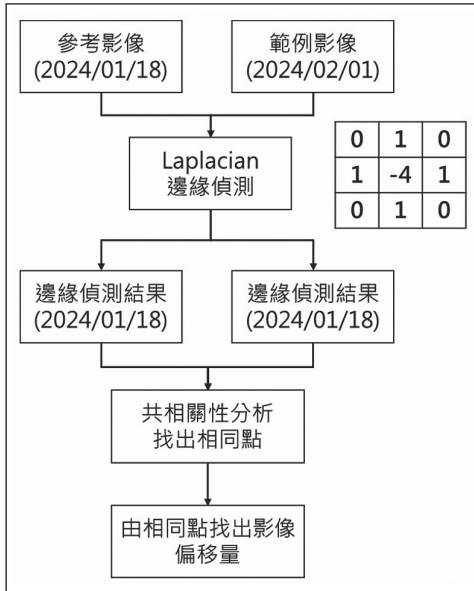


圖 3 影像位移偵測流程圖

二、深度學習模型建立

本研究採用 TensorFlow 架構建立 Attention U-Net 模型，如圖 5 所示。模型由結構包由四層編碼器 (Encoder) 與解碼器 (Decoder) 組成。Okta, O 等人提出 Attention Gate (AG) 機制 [10]，在基礎 U-Net 模型架構中導入注意力模組，並配置於編碼器與解碼器之跳躍連接 (skip connection) 中，以形成一個閘門控制 (gating)，強化特徵資訊的傳遞。Attention Gate 模組詳細架構圖 6 所示，其中， x 來自當前編碼層、經下採樣後跳躍連結輸入之數據； g 為解碼器上一層所提供之門控訊號。由於 x 與 g 尺寸可能不同，需分別透過卷積 $1 \times$

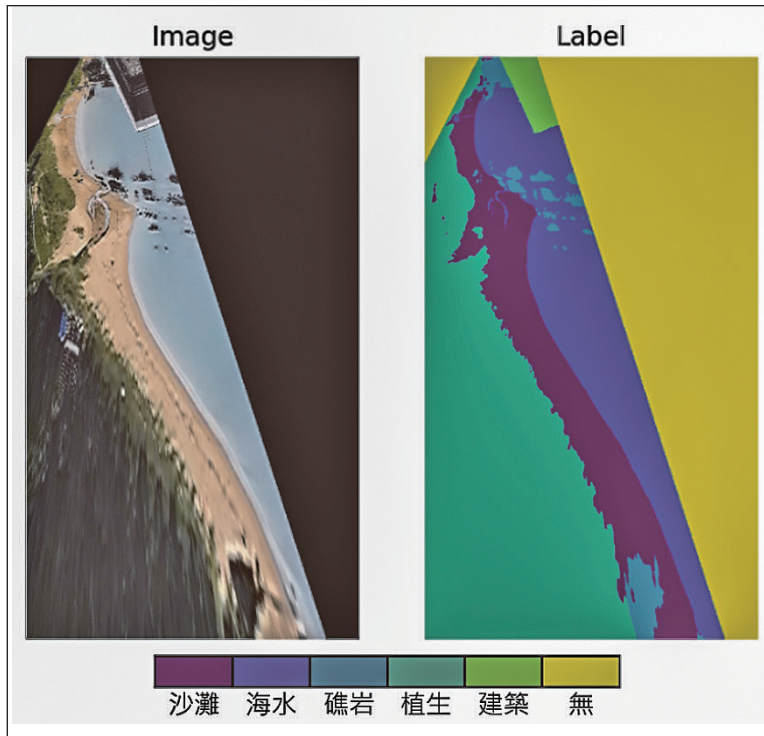


圖 4 影像標籤化範例

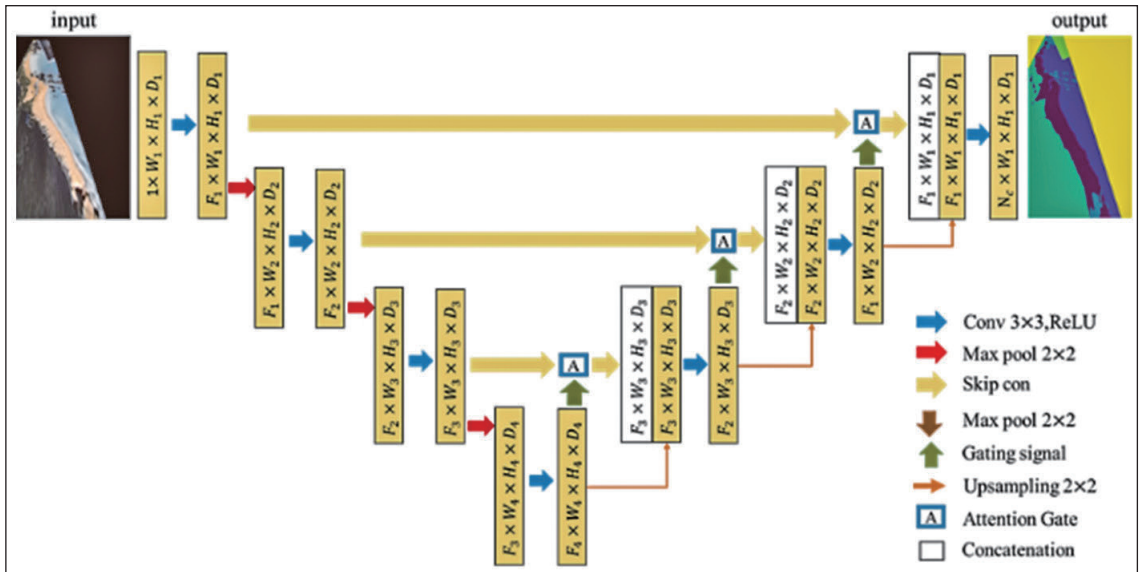


圖 5 Attention_U-Net 架構流程圖

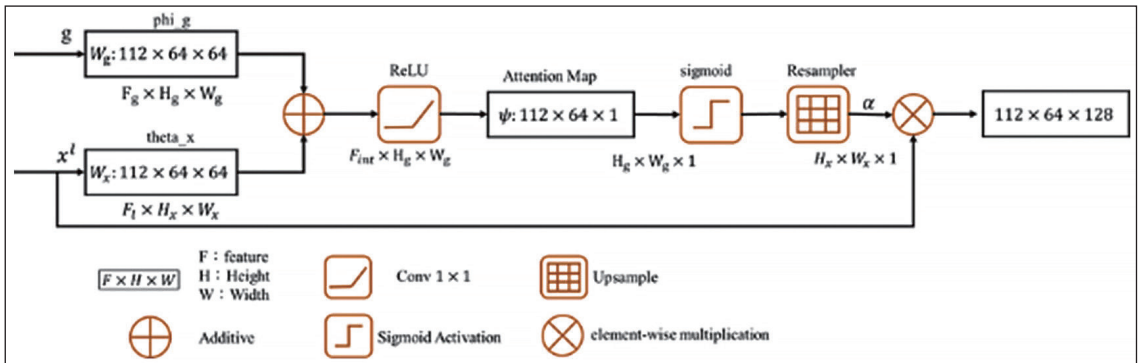


圖 6 Attention Gate 架構圖

1 來確保尺寸一致。接著將尺寸一致的 W_g 和 W_x 進行逐點加法，並通過 ReLU 激活函數；再經卷積 1×1 與 Sigmoid 函數引入非線性，得到注意力係數（attention coefficients）。最後，將輸入原特徵圖與注意力係數進行元素相乘，即可得到加權後之特徵圖。

1. 分類準確度評估方法

針對深度學習模型，使用混淆矩陣（Confusion Matrix）作為評估影像分類準確度的方法，將模型的預測結果與實際的真實標籤進行比較，混淆矩陣可表示如下表 1。



表 1 混淆矩陣與分類準確度

		人工標註類別				
		類別 1	類別 2	類別 3	合計	使用者準確度
分類結果	類別 1	a	b	c	a + b + c	a / (a + b + c)
	類別 2	d	e	f	d + e + f	e / (d + e + f)
	類別 3	g	h	i	g + h + i	i / (g + h + i)
	合計	a + d + g	b + e + h	c + f + i	A = a + b + c + d + e + f + g + h + i	
	生產者準確度	a / (a + d + g)	e / (b + e + h)	i / (c + f + i)		整體準確度 = (a + e + i) / A

2. 模型應用與岸線提取流程

深度學習模型訓練完成後，將篩選通過的影像輸入 Attention U-Net 模型進行分類，辨識各類地物並標註沙灘邊緣位置以提取岸線。完成岸線萃取後，進一步由岸線與預設斷面線之交點求得各斷面之岸線位置，作為後續量化分析基礎。研究區域內共設置 38 條斷面，間距 20 公尺，由北至南依序編號 740 至 0，以量化沙灘寬度之時空變化；沙灘寬度定義為各斷面起點至該斷面與沙灘岸線交點之水平距離。

肆、研究結果

一、Attention U-Net 模型評估

本研究使用 Attention U-Net 模型建置影像辨識系統，模型訓練過程如下圖 7 所示，由訓練集與測試集資料在疊代 (epoch) 過程中可見，兩者變動趨勢呈現一致性，顯示模型未出現過度擬合，具良好泛化能力與穩定性。另於訓練與測試階段之生產者準確度 (PA) 與使用者準確度 (UA) 如表 2 所示，其中沙灘與海水的準確度約介於 0.95 ~ 0.98，顯示模型具極高的分類精度。

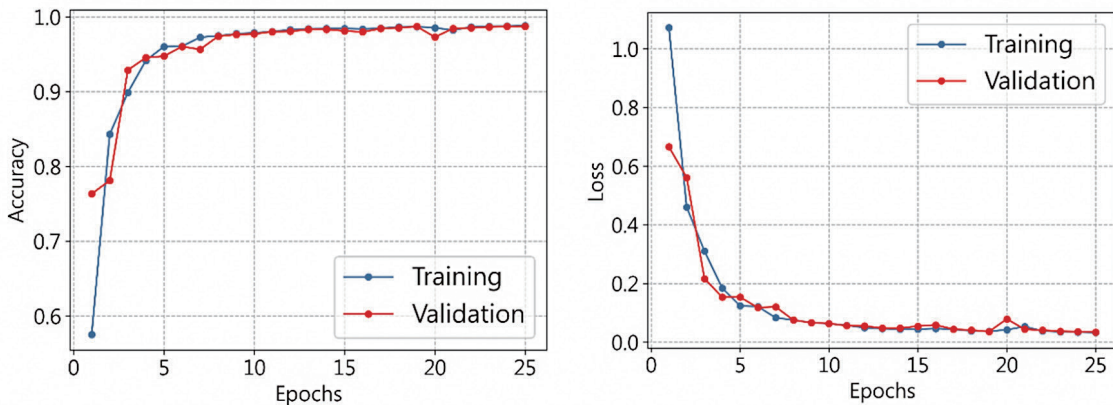


圖 7 Attention U-Net 模型訓練歷程



表 2 Attention U-Net 訓練與驗證準確度

訓練						
分類項目	沙灘	海水	礁岩	植生	建築	無
PA	0.95	0.98	0.96	1.00	0.99	1.00
UA	0.98	0.97	0.97	0.96	1.00	1.00
測試						
分類項目	沙灘	海水	礁岩	植生	建築	無
PA	0.95	0.98	0.95	1.00	0.99	1.00
UA	0.97	0.97	0.97	0.96	1.00	1.00

二、颱風前後岸線變化分析

以 2024 年三場颱風事件之 0 m 時刻海岸線寬度變化如圖 8 至圖 10 所示，其中以康芮颱風（圖 9）造成之岸線寬度變化最顯著，主因在於其路徑屬第三類，為較易影響此研究區域路徑之一；且其最大寬度變化出現 340 斷面，達 16.2 公尺。相較而言，山陀兒

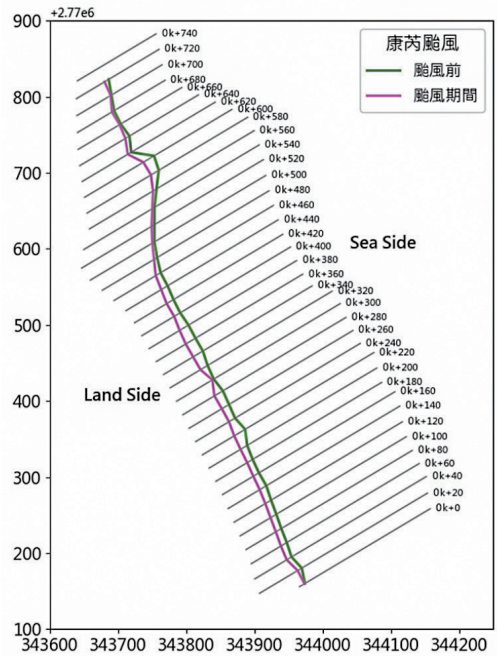


圖 9 康芮颱風




圖 8 山陀兒颱風




圖 10 天兔颱風



颱風與天兔颱風之路徑主要影響臺灣南部，故對本研究區域影響相對不明顯。

三、颱風前後潮間帶高程變化

潮間帶位於海陸交界處，2024 年三場颱風事件之潮間帶變化如圖 11 至圖 13 所示。本研究透過比較颱風前後潮間帶之差值面，分析颱風過後潮位之空間分佈變化。以侵襲研究區之康芮颱風為例，颱風前三天岸線分佈較寬，且潮位範圍呈現由正至負；颱風後三天岸線分佈相對較窄，且潮位多落在 0 m 以上，顯示颱風後岸線位置及潮位仍受影響。由康芮颱風前後潮位差值面（圖 12）可見，潮位空間差異並不一致，呈現局部升高與降低並存現象；其中，南端紅色區域表示颱風後潮位升高增加影響較內陸之沙灘區的




圖 12 康芮颱風

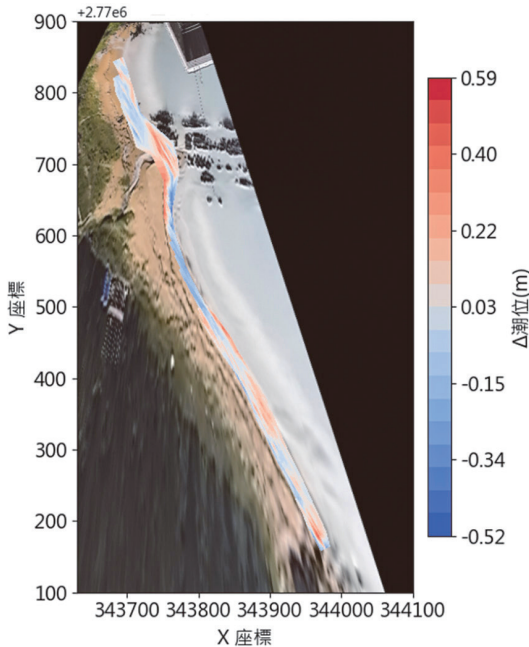


圖 11 山陀兒颱風

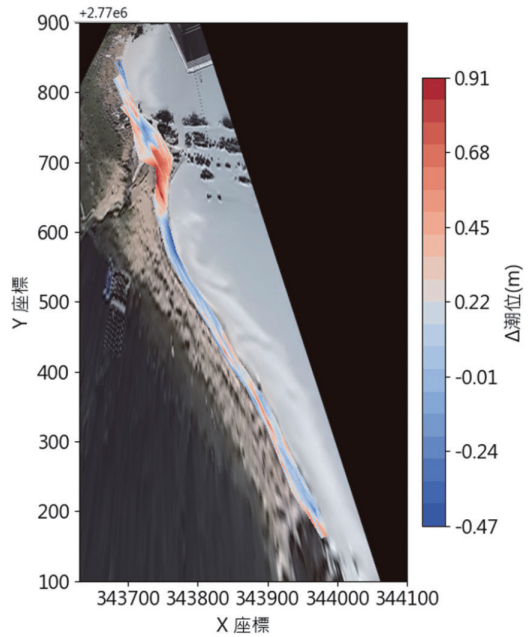


圖 13 天兔颱風



可能性；而上方的藍色區域表示颱風後潮位降低，代表該處有侵蝕的情形，但是此侵蝕的情況在颱風過後可能會再持續回復，因此需要長期的觀測。

伍、結論

1. Attention U-Net 模型成功應用於 CCTV 監視影像岸線提取，並結合時間序列分析，顯示岸線變動趨勢與沙灘寬度演變。
2. 即時影像辨識系統的建置，在緊急事件時可即時完成處理與分析，在颱風事件期間能快速判斷影響情形。
3. 由 2024 年影像資料針對三次颱風事件分析，可從有明顯侵襲研究區的康芮颱風發現沙灘岸線寬度在短期內明顯受到颱風影響，但此侵蝕與淤積的情形可能在海潮的作用之後再度回復，因此本系統正是最佳的長期且穩定的監測方法之一。

參考文獻

1. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. ArXiv.
2. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
3. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net Convolutional Networks for Biomedical Image Segmentation. ArXiv.
4. O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. ArXiv, abs/1511.08458.
5. Eadi Stringari, C., Veras Guimaraes, P., Filipot, J. F., Leckler, F., & Duarte, R. (2021). Deep neural networks for active wave breaking classification. *Sci Rep*, 11(1), 3604.
6. Hanling Zhu, D. Z., Xue Qin and Fawang Guo. (2023). Efficient and Accurate Beach Litter Detection Method Based on QSB-YOLO. *International Journal of Advanced Computer Science and Applications (IJACSA)* 14.7.
7. Fu, M., Ning, T., & Wang, Y. (2025). Improved YOLO network for marine litter detection in a low-carbon environment. *International Journal of Low-Carbon Technologies*, 20, 965–972.
8. Chang, L., Chen, Y.-T., Wu, M.-C., Alkhaleefah, M., & Chang, Y.-L. (2022). U-Net for Taiwan Shoreline Detection from SAR Images. *Remote Sensing*, 14(20).
9. Santos, F., Cunha, T. R., & Baptista, P. (2025). Deep Learning-Based Semantic Segmentation for Automatic Shoreline Extraction in Coastal Video Monitoring Systems. *Remote Sensing*, 17(23).
10. Oktay, O., Schlemper, J., Folgoc, L. L., Lee, M. J., Heinrich, M. P., Misawa, K., Mori, K., McDonagh, S. G., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018). Attention U-Net: Learning Where to Look for the Pancreas. ArXiv, abs/1804.03999.