

海岸線自動偵測與 AI 模型

陳聿新¹ 簡浩丞¹ 朱宏杰^{2*}

摘要

在遙測領域中，海岸線偵測是一重要的研究課題，尤其在面對氣候變遷、海平面上升和環境變遷等問題時，快速海岸線偵測有助於環境監測與管理。本研究結合水體指標和深度學習於外傘頂洲海岸線偵測，以指標如多種 NDWI (Normalized Difference Water Index)與 AWEI (Automated Water Extraction Index)相關公式來進行海岸線偵測研究，在 GEE 平台套用相關五個水體指標公式來區分出外傘頂洲區域的水體與陸地區域，產製二值化地圖，接著應用 Otsu 法自動找出閾值，以此閾值作為初始值後續再進行微調，本研究將所有結果來進行比對與觀察，確認整個海岸線偵測的自動化流程，最後，以深度學習模型產出海岸線偵測結果圖，使用深度學習 U-Net 模型，透過訓練後，U-Net 模型可對衛星影像直接進行海岸線自動偵測，模型的準確度(Accuracy)達到 99.6%、F1 Score 為 0.72，能有效的偵測出外傘頂洲主體的海岸線。

關鍵詞：海岸線偵測、NDWI、AWEI、U-Net

1. 前言

海岸線、灘線為海水和陸地的交界線，會隨潮汐升降而有不同，低潮時之交界線稱低潮線，高潮時之交界線稱高潮線(Boak & Turner, 2005)，本文指的是零米高程線，偵測提取之是環境監測的重要議題，尤其在氣候變遷和人類活動的影響下，海岸線變遷如侵蝕和人為開發等問題日益凸顯。隨著遙測技術的不斷進步，水體識別與海岸線偵測成為環境監測中的重要課題。針對這些需求，科學家們開發了多種公式以提高水體與其他地物的區別精度。這些公式不僅能在多種環境條件下保持穩定表現，還能在應對人類活動與氣候變遷引發的海岸線變化上，發揮重要作用。

針對這些挑戰，基於衛星影像的自動化海岸線提取技術成為了一種高效且準確的解決方案，藉由衛星影像指數公式來進行水體與非水體區域的分類，其中 NDWI (Normalized Difference Water Index)是具有代表性的水體指數公式，Gao (1996)定義的 NDWI (Normalized Difference Water Index)是近紅外

光(Near-Infrared Red, NIR)與短波紅外光波段(Short-Wave Infrared Red, SWIR)之間的正規化差值，雖然此指標最初是為了植被含水量評估所開發(Liuzzo *et al.*, 2020)，但有些研究將其用於沙漠地區的地表水體辨識。McFeeters (1996)則提出了另一種 NDWI 演算法，使用 Landsat 影像的綠光與 NIR 波段，旨在增強水體特徵，並抑制背景中的地表雜訊，利用綠波段和近紅外光波段之間的光譜差異，能夠在遙測影像中清晰地區分水體與非水體區域。然而，隨著不同環境條件的變化，研究者們發現 NDWI 在某些情況下的表現仍存在侷限性，為了解決這些問題，NDWI 經過了多次改進與擴展，其中，2006 年 Xu 提出的 MNDWI (Modified NDWI)，用短波紅外光波段(SWIR)代替 NIR，解決了在建成區環境中 NDWI 對水體提取精度不佳的問題，基於不同的光譜波段組合，設計了其他版本的 NDWI，以應對更廣泛的應用場景，如植被和水體混合區、濕地等環境。這些改進的 NDWI 公式為水體提取和海岸線偵測提供了更多元的選擇，特別是在不同的自然條件下，增強了偵測效果，在水體提取過程中，雲遮和

¹ 國立成功大學測量及空間資訊學系 碩士生

² 國立成功大學測量及空間資訊學系 教授

* 通訊作者, E-mail: honejaychu@geomatics.ncku.edu.tw

收到日期：民國 114 年 04 月 22 日

修改日期：民國 114 年 05 月 15 日

接受日期：民國 114 年 06 月 19 日

陰影等干擾因素是常見的挑戰。為了解決這一問題，Feyisa 等人在 2014 年提出了 AWEI (Automated Water Extraction Index)，陰影與暗色地表區域中，常因無法正確分類此類區域的水體，AWEI 的設計目標之一是提升在陰影區域水體提取的有效性，能適應不同環境條件，自動區分水體與其他地物，AWEI 針對無陰影和陰影區域兩種狀況下，設計了兩個不同的公式： $AWEI_{nsh}$ (無陰影區域) 和 $AWEI_{sh}$ (有陰影區域)，從而解決水體識別問題。NDWI 和 AWEI 的設計目標皆是增強水體與其他地物的區分，MNDWI (Xu, 2006) 藉由綠波段與短波紅外波段的光譜差異來強化水體特徵，而 AWEI 則結合了多波段資訊，透過所選光譜波段的算術組合提升水體提取的精度與效率。當我們在觀測雲影、建成地等干擾因素較多的地區時，比較各種指標結果圖再搭配了解本身公式與定義，可以幫助我們更清楚指標的應用場合，幫助往後的使用者能更加清晰地在多種環境中識別與偵測水體區域。有效進行交叉比對與驗證，也能降低誤分類的風險，確保提取結果的準確性，特別是在偵測邊界區域或其他分類困難的區域。本研究核心目標之一是提高水體提取過程的自動化程度，減少對人工參數調整的依賴，試著找出一個穩定且自動化的海岸線提取方案來勝任大範圍和長期的監測任務，以求在不同影像條件下持續提供可靠的水體提取結果。陳聿新及朱宏杰(2023) 透過觀察曾文溪口濕地近三十年的衛星影像來估計濕地區域的海岸線與面積變化，結合 NDWI 二值化與 Canny 邊緣偵測，判釋與數化曾文溪出海口濕地及沙洲的海岸線變化，快速計算長期移動速率。

基於衛星影像的自動化海岸線提取技術成為了一種高效且準確的解決方案來應對不同環境條件和分類難題。在這樣的背景下，我們比對 NDWI 與 AWEI 的多種公式偵測可為解決水體提取和海岸線偵測問題提供了比對與參考，期望能適用在所有的環境與影像條件下，也以此顯示出在提升分類精度、穩定性和自動化程度上的潛力，不僅滿足了現代環境監測的需求，還能夠為推動水體提取與海岸線偵測技術的發展提供助力。期望基於 NDWI 和 AWEI 公式的遙測技術能夠快速、高效地進行海岸線提取，

這使其在大規模和長期的動態監測中具有很高的應用潛力。隨著深度學習技術的發展(Seale *et al.*, 2022、Dang *et al.*, 2022)，可以訓練模型識別海岸線與其他周圍物體之間的區別，我們也發展深度學習模型能夠以衛星影像檢測海岸線和灘線；從而提供實時的海岸線變化快速監測模型。本次研究區域選擇東石漁港外的外傘頂洲，外傘頂洲為嘉義沿海養殖產業主要屏障，但逐漸受到侵蝕向內退縮，海岸線每年移動約為 70 - 200 m(彭新雅等，2019)。

1.1 研究區域

圖 1 為研究區域之 Sentinel 2 衛星影像圖，拍攝日期為 2023/06/29，本次研究區域為東石漁港外的整個外傘頂洲，因為外型似傘而得名，由於濁水溪流流域蘊含的沙源豐富，在出海時伴隨著大量的泥沙沖積而成，也是臺灣沿海最大的沙洲。多年來受到颱風暴潮、水道治理、沿海土地開發及設施興建等影響，外傘頂洲由於沙源補助減少及海潮作用下，逐漸侵蝕消失。

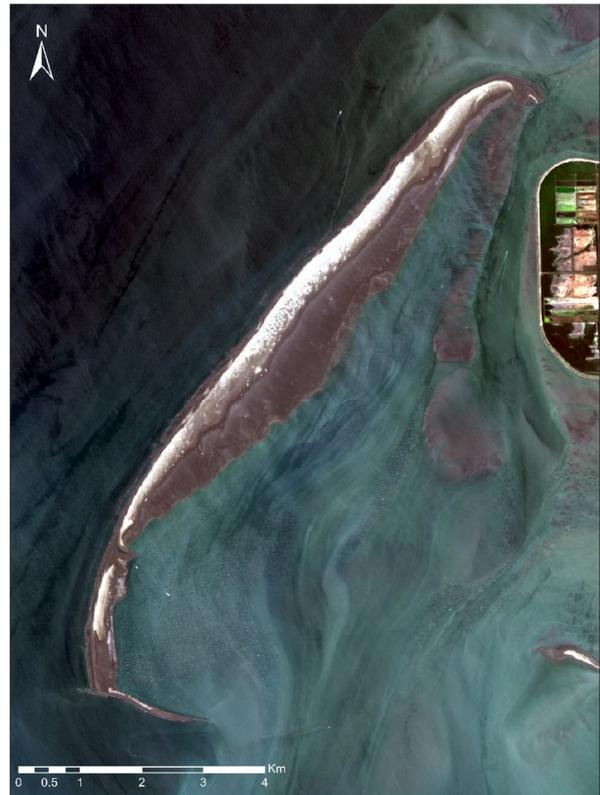


圖 1 研究區域(外傘頂洲)

2. 研究方法與步驟

研究使用 NDWI (Gao, 1996)、NDWI (McFeeters, 1996)、MNDWI (Xu, 2006)、 $AWEI_{sh}$ 及 $AWEI_{nsh}$ (Feyisa *et al.*, 2014) 等五種水體指標來偵測外傘頂洲的灘線，並運用 Otsu 法和目視調整法將水體與陸地進行二值化處理，最終從二值化影像中提取灘線，並將五種指標的灘線偵測結果與 GPS 車載的實測灘線資料進行比對。

(1) 資料收集與預處理：

衛星影像選擇：選擇適合進行海岸線偵測的衛星影像，本次研究選擇 Sentinel 2 的資料集，其具有多光譜波段，適合水體識別。影像應包含綠光波段 (Green)、藍光波段 (Blue)、近紅外光波段 (NIR) 和短波紅外波段 (SWIR)，這些波段對計算 NDWI 和 AWEI 至關重要。通常為了減少噪音和錯誤偵測，選擇過濾雲遮的影像，作為實驗案例。

(2) 計算相關指數：

使用選定的波段來計算三個 NDWI 和兩個 AWEI 公式，每個指數公式根據其使用的波段組合可能略有不同。

NDWI (McFeeters, 1996)：使用綠光波段和近紅外光波段來計算水體區域，這個指數特別適用於提取和識別水體，能夠將水體從其他地物如植被、土壤區分出來。

$$NDWI_{McFeeters} = \frac{Green - NIR}{Green + NIR} \dots\dots\dots (1)$$

NDWI (Gao, 1996)：使用近紅外光波段和短波紅外光波段來進行水體識別，強調水體與植被的區別，特別是在濕地環境中使用。

$$NDWI_{Gao} = \frac{NIR - SWIR1}{NIR + SWIR1} \dots\dots\dots (2)$$

MNDWI (Modified NDWI, Xu, 2006)：使用短波紅外光波段代替短波紅外光波段，可在建成區或城市環境中更有效地檢測水體。

$$MNDWI = \frac{Green - SWIR1}{Green + SWIR1} \dots\dots\dots (3)$$

$AWEI_{sh}$ (Shadows version, Feyisa *et al.*, 2014)：

針對不同環境條件下，利用多個關鍵波段，如藍光、綠光、近紅外光和短波紅外光波段，提取水體進行優化，此公式專門用來消除陰影的干擾。

$$AWEI_{sh} = Blue + 2.5 \times Green - 1.5 \times (NIR + SWIR1) - 0.25 \times SWIR2 \dots\dots\dots (4)$$

$AWEI_{nsh}$ (Non-shadows version, Feyisa *et al.*, 2014)：此公式適合在無陰影區域使用，得到水體特徵。

$$AWEI_{nsh} = 4 \times (Green - SWIR1) - (0.25 \times NIR + 2.75 \times SWIR2) \dots\dots\dots (5)$$

(3) 分類與海岸線提取：

水體分類閾值選擇：針對每個指數在觀測區域所累積的次數對應指標值所匯出的直方圖，本研究首先採用 Otsu 調整法來設定合理的水體分類閾值，目視調整法是用來驗證 Otsu 影像分割法之可行性，亦微調 Otsu 閾值強化灘線偵測的效果。

Otsu 調整法：使用 Otsu 法來自動設定閾值。Otsu 法是常見的水體分割技術，是種自適應的閾值分割方法，它能使組(類別)間變異最大(組內變異最小)，透過搜尋組內變異最小來自動選擇一閾值，將影像中的像素分為兩個類別，適合雙模態分佈的影像，常用於二值化。Otsu 法的計算過程不需要大量的計算資源，適合處理大規模的影像數據，Otsu 可自動選擇最佳閾值，不需要人工干預，這對於大量的衛星影像處理任務來說非常有利。因此，在海岸線偵測任務中，Otsu 法可以有效地區分水體和陸地，這類問題符合二元分類的要求，但影像中存在太多噪聲或灰度分佈不均，Otsu 法可能不適用。

目視調整法 (Custom)：針對不同公式，根據經驗設定一個固定閾值，先給定 Otsu 法結果作為初始閾值，接著再觀察偵測出的外傘頂洲灘線主體邊界是否趨於完整(與 RTK 車載實測資料比較)，若邊界有缺失則將值向上微調，若邊界過於飽滿則將值向下微調。

提取海岸線：根據水體與非水體的分類結果，進行海岸線邊界的提取：使用 Sobel 邊緣偵測方法進一步提取明確的海岸線。Sobel 邊緣偵測方法透

過計算影像在水平方向與垂直方向的梯度變化來突顯影像中的邊緣(Kanopoulos *et al.*, 1988)，其概念是使用兩個一階微分的卷積算子，偵測灰階值的強烈變化區域，即邊界位置，其中算子(Sobel operator)常以兩濾波器，如下面方程式所示，**S_x** 用於檢測水平的梯度變化，**S_y** 用於檢測垂直的梯度變化(Vincent & Folorunso, 2009)。

$$S_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \dots\dots\dots (6)$$

$$S_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \dots\dots\dots (7)$$

(4) 各種水體指標比較後與 RTK (Real Time Kinematic)車載實測資料驗證：

使用 Sentinel 2 資料集選擇與 RTK 車載實測資料時間貼近的影像(國家海洋研究院, 2024)，並將其轉換成指標及後續二值化與偵測，並將五種水體指標的偵測結果圖拿來與車載資料做比對。

(5) 深度學習模型

在上述的自動化流程中，首先是將衛星影像轉換成指標影像，接著再對指標影像進行二值化，最後對二值化後的指標影像進行偵測。雖然前述部分對五種不同的水體指標及二值化上不同閾值方法

進行了探討，但仍舊無法將自動化流程整體完善。本研究在這個部分，使用 U-Net 模型來對衛星影像直接進行海岸線偵測。U-Net 模型由對稱的編碼器與解碼器組成(如圖 2)，編碼器逐層提取特徵，包含 3 層卷積與池化操作，通道數逐層增加 (16、32、64)，特徵尺寸逐層減少；解碼器通過上採樣和跳接結構逐步恢復特徵空間，結合低層特徵進行重建，通道數逐層減少 (64、32、16)。核心層以 128 通道卷積進行特徵融合。輸出層為單通道卷積，使用 Sigmoid 激活函數生成預測結果。損失函數是 Binary Cross Entropy，超參數設定包含：批次大小為 4、學習率為 0.0001、迭代次數為 50。

此模型輸入為 Sentinel 2 的衛星影像，波段包含近紅外光、紅光、綠光等 12 個波段，訓練的樣本數量包含 12 期影像，共 1296 張切片影像，每張訓練影像切片大小為 256×256，使用的框架是 TensorFlow；標籤(即地真資料)為衛星影像偵測結果(如以 AWEI_{sh} 及 NDWI_{McFeeters} 經過不同閾值方法的二值化後偵測的結果)。假設沒有閾值是對所有場景皆適用的，因此以在不同閾值方法下，能得到完整主體邊界的偵測結果當作模型的標籤，而不直接使用 RTK 車載實測資料作為地真資料是因為訓練資料需要多期的衛星影像，若只使用與 RTK 車載實測資料相對應時間的衛星影像，訓練資料數量會不足。

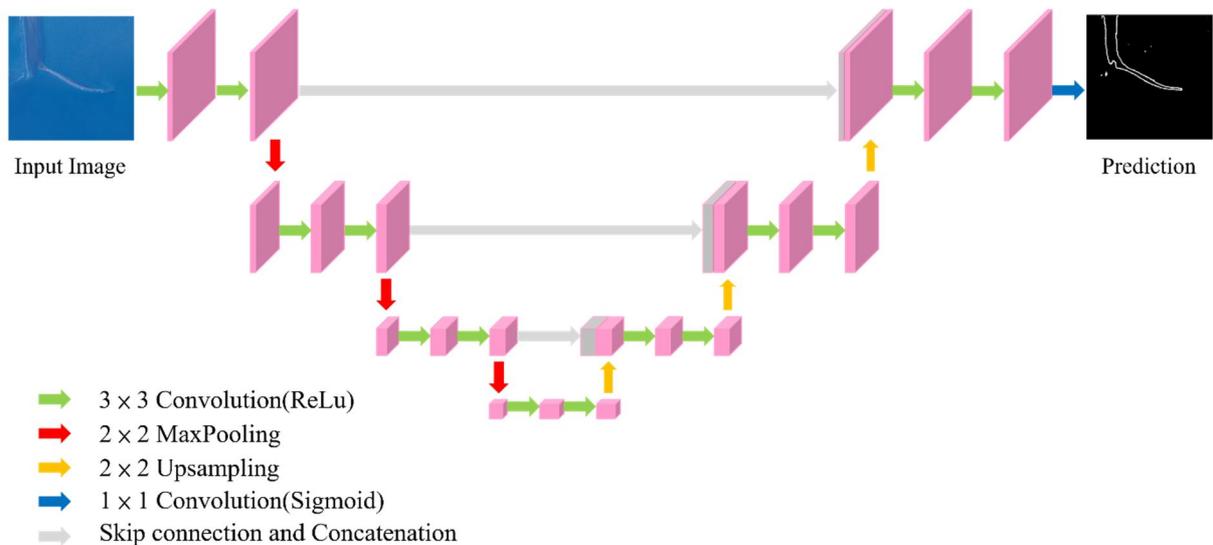


圖 2 海岸線偵測 U-Net 模型結構圖

3. 研究結果

3.1 偵測結果與比較

圖 3 為外傘頂洲在 2023/03/01 考量不同水體指標所呈現的結果，經由指標過後，發現外傘頂洲陸地與水體的辨識度都很高，在二值化(圖 4)及灘線偵測(圖 5)的結果圖中，Otsu 法 $NDWI_{Gao}$ 、 $MNDWI$ 、 $AWEI_{nsh}$ 無法得到完整主體會有右中段面積會有缺漏，目視調整後均有改善，但 $NDWI_{Gao}$ 無論是使用 Otsu 法或目視調整法，都無法有效區分水體和陸地，進而影響灘線偵測的效果；而 $NDWI_{McFeeters}$ 及 $AWEI_{sh}$ 這兩種指標，在 Otsu 法與目視調整法下均能有效區分水體和陸地。對於 $MNDWI$ 及 $AWEI_{nsh}$ 這兩種指標，Otsu 法二值化的結果顯示的外傘頂洲範圍均小於其原始指標圖中的範圍，對比下，目視調整法可加以改善；總結灘線偵測結果，除了無法有效區分水體和陸地的 $NDWI_{Gao}$ ，在其他四種指標中，目視調整法的結果均比 Otsu 法更接近原始圖中的外傘頂洲灘線範圍，尤以 $NDWI_{McFeeters}$ 與 $AWEI_{sh}$ ，但五種指標裡特別是 $NDWI_{McFeeters}$ 和 $AWEI_{sh}$ 透過 Otsu 法取得的二值化及灘線圖能完整顯示外傘頂洲的整體灘線。然而，對於其餘三種指標，特別使用目視調整法亦能產生更完整的二值化與灘線結果圖，特別是 $AWEI_{nsh}$ 與 $MNDWI$ 。圖 4 與圖 5 中， $NDWI_{Gao}$ 、 $MNDWI$ 、 $AWEI_{nsh}$ 目視法雖然相較於 Otsu 法使得主體邊界趨於完整，但圖面上卻存在有更多的雜訊。

後續進一步驗證，圖 6 中(a)至(e)分別為 $NDWI_{McFeeters}$ 、 $NDWI_{Gao}$ 、 $MNDWI$ 、 $AWEI_{sh}$ 、 $AWEI_{nsh}$ 等水體指標經由目視調整得到灘線，藍色灘線為 GPS 車載實測資料的灘線位置，而紅色灘線則是使用衛星影像偵測獲得的灘線位置。外傘頂洲偵測結果與車載資料做比對，綜合以上，從 RTK 車載實測資料來看，除了 $NDWI_{McFeeters}$ (圖 6(a))左中段邊界沒閉合， $NDWI_{Gao}$ (圖 6(b))右中段灘線有明顯的碎形區塊，及 $MNDWI$ 右中段灘線有點不一致(圖 6(c))，其餘兩種 $AWEI$ 指標所呈現的灘線結果均與 RTK 車載實測的灘線位置相符，計算五種指標偵測結果的準確度分別為 99.43、99.34、99.51、99.54、99.52(%)，亦說明 $AWEI$ 指標所呈現的灘線結果準確度較高， $NDWI_{Gao}$ 準確度最低。

綜合以上，Otsu 自動化方式適合快速二元分割；如果目標是快速、簡單地區分水體和陸地，並且影像的灰度分佈相對清晰，Otsu 閾值法是高效的選擇，這在需要處理大量影像時尤為重要，因此，選擇哪種方法應取決於任務的具體需求。建議如果數據量龐大且需要快速處理，Otsu 方法相當實用，Otsu 方法直接針對全局做分割劃分，以 Otsu 法作為初始閾值，後續再進行微調，找出完整主體邊界，表 1 為各種水體指標使用兩種方法所求之閾值，以及水體指標相關統計值，經過觀察目視法的閾值與平均值的數值非常相近，發現亦可採用平均值作為初始閾值，可快速偵測出海岸線。

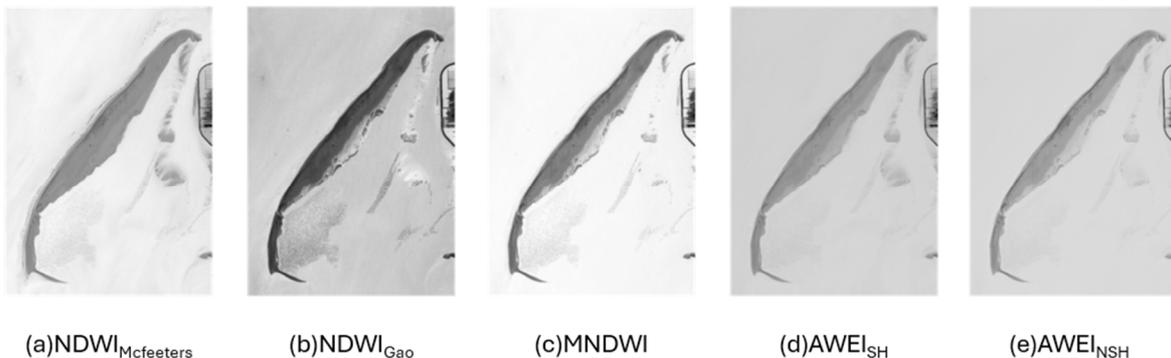


圖 3 以外傘頂洲為研究區域之水體指標圖

表 1 各種水體指標使用兩種方法所求之閾值，以及水體指標相關統計值(Min, Max, Mean and Std)

	$NDWI_{Mcfeters}$	$NDWI_{Gao}$	MNDWI	$AWEI_{sh}$	$AWEI_{nsh}$
Otsu	0.36	0.3	0.53	0.27	0.17
Custom	0.4	0.5	0.72	0.3	0.33
Min	-0.28	-0.26	-0.37	-0.24	-1.06
Max	0.57	0.75	0.87	0.49	0.66
Mean	0.47	0.49	0.76	0.34	0.35
Std	0.11	0.15	0.18	0.06	0.13

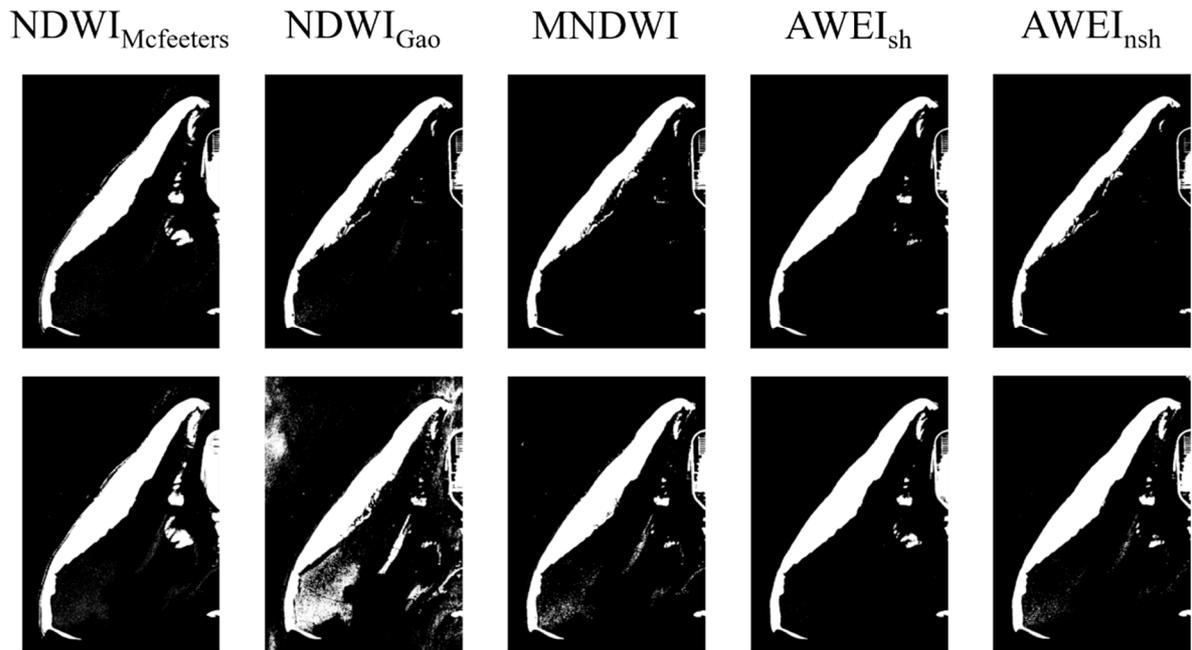


圖 4 各種水體指標二值化圖 (上排為 Otsu 法，下排為目視調整法)

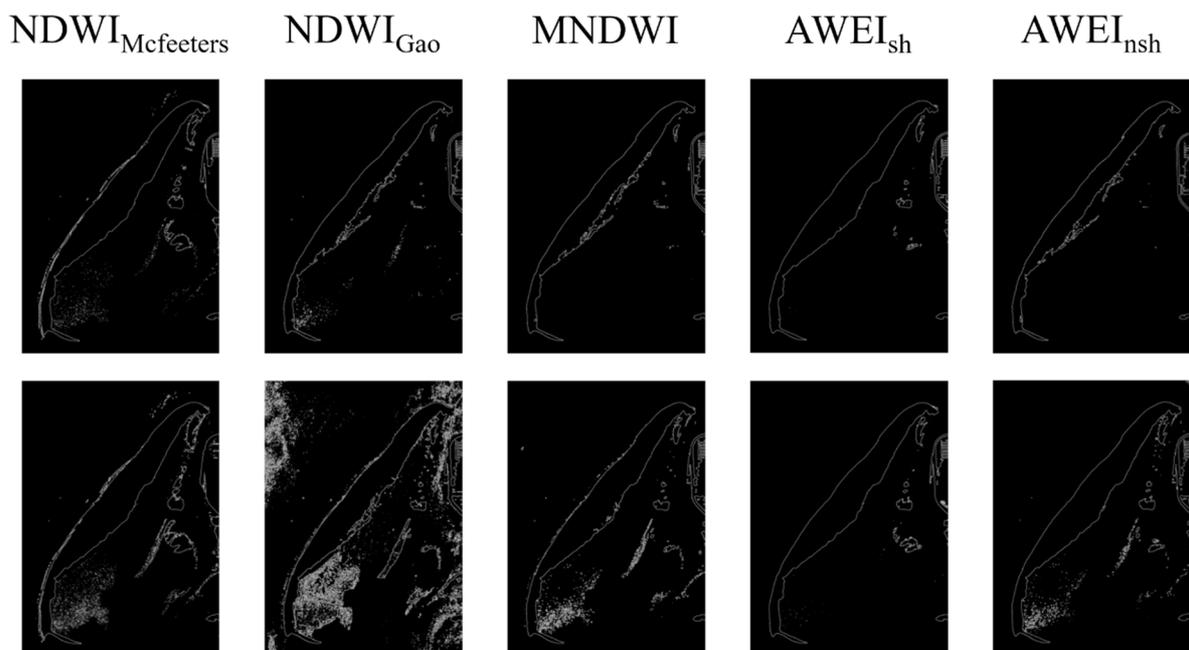


圖 5 各種水體指標灘線偵測圖(上排為 Otsu 法，下排為目視調整法)

3.2 深度學習模型

本研究結合遙測及深度學習技術，有望進一步提升海岸線偵測的自動化程度與分類精度，通過大數據訓練模型，不須考量公式的閾值或是選擇的水體指標，從而更靈活地實現更準確的分類結果。本研究輸入 Sentinel 2 的衛星影像到模型，可直接輸出海岸線偵測結果。如圖 7 所示，其拍攝時間為 2024/04/29，模型若輸入影像為圖 7(a)、則模型輸出結果圖 7(c) 與真值標籤圖 7(b) 很相似，因此可藉由模型能快速得到海岸線偵測結果，檢核模型相關的準確度 (Accuracy)、精確度 (Precision)、召回率 (Recall)、F1 Score 分別為 99.6%、69%、75%、0.72，實驗證實本研究之模型是利用簡化版的 U-Net，不論是層數或通道數皆較精簡，但能藉由此模型架構，模型能預測出外傘頂洲主體的灘線，模型的表現已經相當完善，僅在其外圍仍有些小沙洲則無法完全的預測出來。

3.3 討論

本研究使用三個 NDWI 與兩個 AWEI 公式進行海岸線偵測的研究動機在於提高偵測的精度、自動化、以及應對不同環境條件和光譜反射變化，甚至引入深度學習能以 AI 偵測，從而達到更精確的海岸線監測目的。在未來應用方面，這些水體偵測指標具有廣泛的潛力，可以用於水體監測，尤其適用於海岸線變化的長期監控，如海平面上升或海岸線侵蝕等問題，不同的指標和最佳閾值適應於不同環境和需求，從而達到更準確的偵測效果。在不同自然條件下，如植被覆蓋、濕地或建成區等，單一公式可能表現不佳，但多個公式的比對，能減少單一公式帶來的錯誤分類，能提升整體準確度。

未來研究可用於多種應用場景，如海岸開發規劃、生態環境保護、海岸線侵蝕監測等，如彭新雅等 (2019) 利用 MNDWI (Xu, 2006) 及 NDWI (McFeeters, 1996) 求得外傘頂洲不同時期的變化量及移動趨勢，也可以應用於海岸線變遷之管理與規劃，為鄰海的城市發展及基礎設施建設提供可靠的

數據支持，特別是對於鄰海城市海岸線的變化對城市規劃和建設具有重要影響，這些指標可以成為監控的有力工具。海岸線變遷，受到自然與社會因素影響的動態過程，這些海岸線變遷可能改變了土地利用方式或土地利用影響海岸線變遷(吳振發等，2015)，影響了該地區的環境和社會經濟結構，如海岸線退縮則對沿海土地的可持續利用造成了直接威脅，隨著海岸線後退，使得沿海土地變得不再適合耕作。其次，全球氣候變遷加劇了極端天氣事件的頻發，如暴潮、海嘯和洪水等，這些極端天氣對海岸線的影響不可忽視，可用於災害預警系統，如洪水或海嘯等極端事件中，這些偵測方法能夠及時提供水體範圍的變化，協助防災減災工作。

總結來說，NDWI 和 AWEI 系列指標的比較可有效區分水體和陸地區域，進行海岸線偵測，亦可應用於水體變化監控、災害預警及城市規劃，具有廣泛的實用價值和延伸應用的潛力。此外，能以深度學習 U-Net 模式，不用困擾不同公式和最佳閾值的選擇方式，直接以多光譜資訊直接得到海岸線及灘線，或是來區分水體與非水體區域，增加應用上的潛力與達成率。

4. 結論與未來展望

為了提供科學依據於監測海岸線變化及管理，本研究比較多種 NDWI 和 AWEI 公式對於海岸線提取的效果，這些指數公式利用不同的光譜波段，包括綠光、藍光、近紅外光和短波紅外光等，考量多個波段的資訊，可以實現清晰的水體與非水體分界，確保在各種環境條件下 (尤其是在複雜的環境條件下，如濕地、城市邊界和雲影區域等) 都能精準地提取海岸線。經過影像處理與分類，將它們所呈現的結果做綜合比較，得出穩定的海岸線偵測結果，同時將錯誤分類的風險降到最低，探討透過結合不同的光譜波段資訊，這些指標在設定的環境條件下均能穩定施行，以 AWEI_{sh} 結果最佳 (準確度 99.54%)，有效地解決水體與非水體分類問題，本研究也證實可使用水體指標加上 Otsu 調整法來自動設定閾值，再以 Otsu 法的閾值作為初始值後續再進行微調，可快

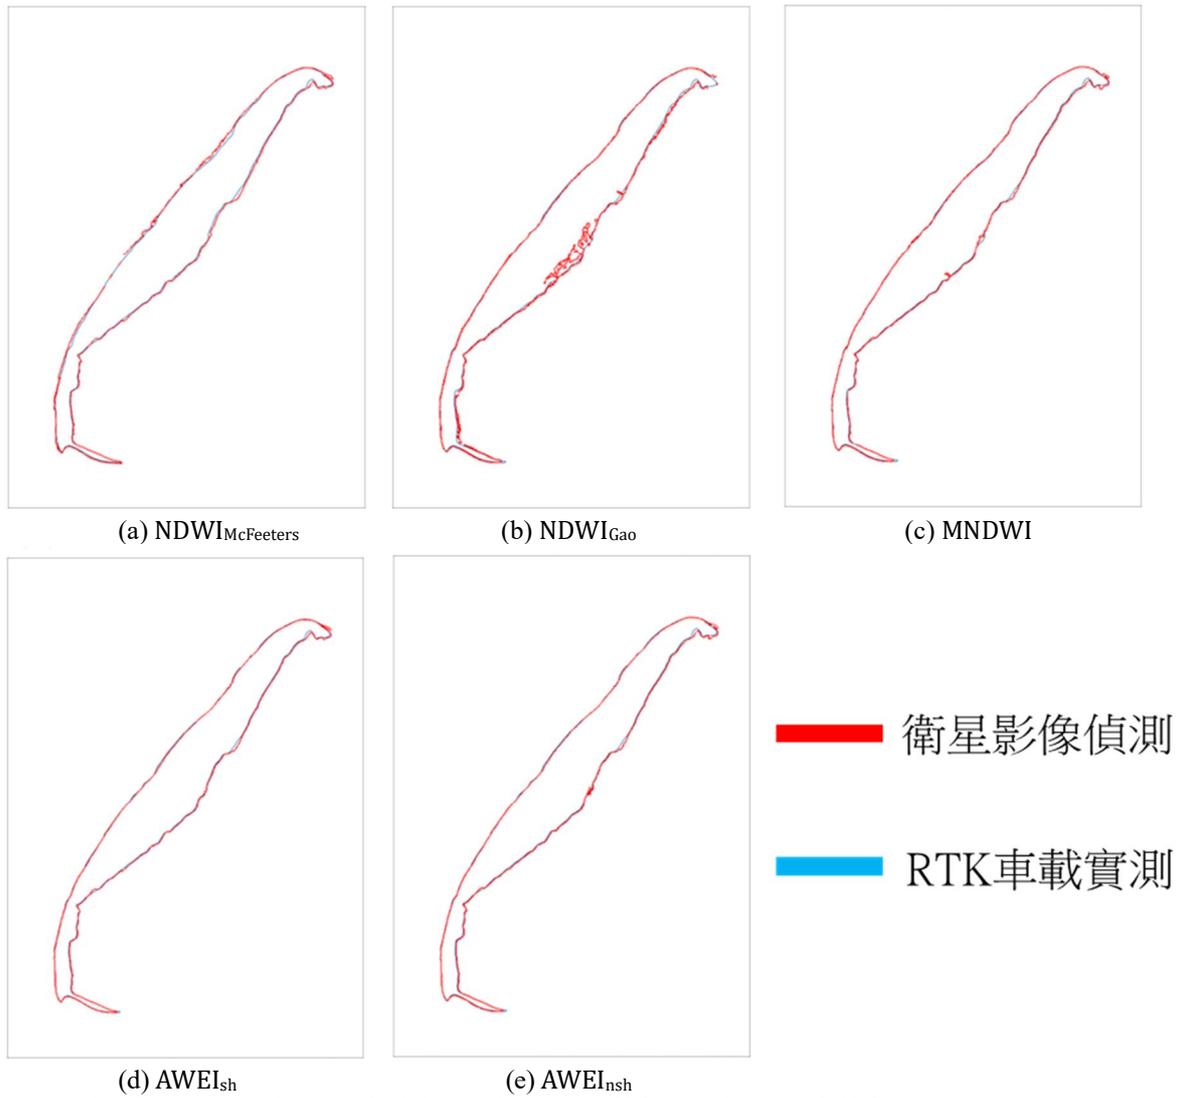
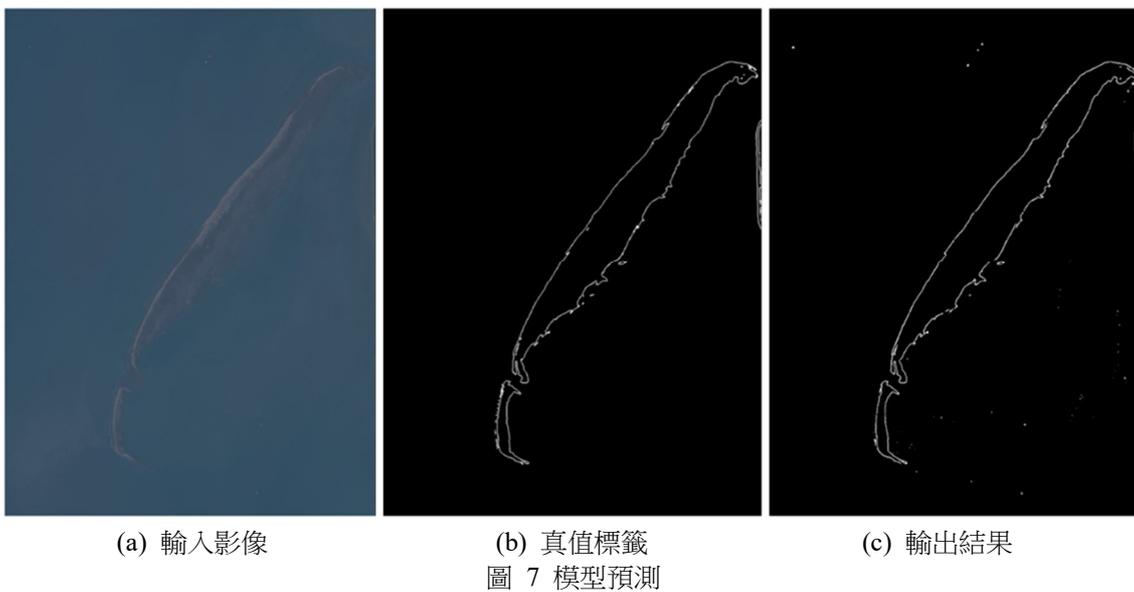


圖 6 水體指標灘線偵測與 RTK 車載實測資料對比圖(藍色灘線為 RTK 車載實測資料的灘線位置,而紅色灘線則是使用衛星影像偵測)



速偵測出海岸線。然而，本研究已使用深度學習 U-Net 模型，透過訓練後，對衛星影像直接進行海岸線自動偵測，深度學習之 U-Net 模式的準確度達到 99.6%能在海岸線偵測中展現出優勢，取得穩定的結果，基於 U-Net 的海岸線偵測方法在水體分類與海岸線提取，顯示其具有廣泛的可應用性，並展現出良好的效果與潛力，若應用於長期海岸線監測中，能實時追蹤海岸線變化趨勢。Otsu 法為一經典之閾值演算法，運算速度快，實作簡便，相較之下，U-Net 屬於深度學習架構，需要大量的資料與運算資源進行訓練，在實務應用上，建議 U-Net 模型應在資料及運算資源充足下預先被建立起來。此外，亦建議未來可在空間上進行隨機抽樣，以科學化評估影像分析方法與 RTK 實測之差異。

有鑑於遙測技術的進步，遙測技術可被應用於快速評估災害對海岸線的影響，並提供實時數據以協助制定應對措施。未來可融合來自不同衛星的數據如 Landsat、Sentinel 2 等，利用它們不同的空間解析度，進一步提升海岸線提取的精度與實用性，多元數據融合將有助於更全面地監測海岸線變化。再者，由於高空間解析度衛星數據的發展，海岸線偵測的精度將進一步提升，這些高解析度數據在捕捉細微變化方面具有顯著優勢，特別是在高密度人口或快速城市化的區域，能夠更準確地監測海岸線的細微變動，甚至可將衛星遙測數據與無人機遙測數據結合，進行多尺度海岸線監測，無人機可以提供更高解析度的近地數據，與衛星數據互補，實現從宏觀到微觀的全方位監測，有效提升海岸線監測的精細度。因此結合深度或機器學習、大數據分析及多元數據融合之海岸線偵測技術，將能更高效、精確地應對全球氣候變遷與自然災害帶來的挑戰，在災害監測中發揮重要的作用。

參考文獻

吳振發、周詩敏、劉昌文，2015。台江內海地區歷史土地利用變遷，興大園藝，40(1)：91-106。 [Wu, C.F., Chou, S.M., and Liu, C.W., 2015. Analyzing long term land use changes in Taijiang Inner Sea, Horticulture NCHU, 40(1): 91-106. (in

Chinese)]

國家海洋研究院，2024。外傘頂洲地形變遷評估勞務委託正式報告。[National Academy of Marine Research, 2024. Wai san ding jou di shing bian chian ping gu lau wu wei tuo jeng shr bau gau. (in Chinese)]

陳聿新、朱宏杰，2023。近三十年曾文溪出海口濕地變遷觀測，濕地學刊，12(1)：40-49。[Chen, Y.X., and Chu, H.J., 2023. Monitoring changes at the Zengwen River Estuary wetland in the past three decades, Journal of Wetlands, 12(1):40-49. (in Chinese)]

彭新雅、曾國欣、錢樺、陳彥欽，2019。運用多時期衛星影像探討外傘頂洲變遷，國土測繪與空間資訊，7(2)：103-119。[Peng, H.Y., Tseng, K.H., Chien, H., and Chen, Y.D., 2019. Utilizing multitemporal satellite images to investigate topographical changes of waisanding sandbar, Taiwan Journal of Geoinformatics, 7(2): 103-119. (in Chinese)]

Boak, E.H., and Turner, I.L., 2005. Shoreline definition and detection: A review, Journal of Coastal Research, 214: 688-703, DOI: 10.2112/03-0071.1.

Dang, K.B., Dang, V.B., Ngo, V.L., Vu, K.C., Nguyen, H., Nguyen, D.A., Nguyen, T.D.L., Pham, T.P.N., Giang, T.L., Nguyen, H.D., Do, T.H., 2022. Application of deep learning models to detect coastlines and shorelines, Journal of Environmental Management, 320: 115732, DOI: 10.1016/j.jenvman.2022.115732.

Feyisa, G.L., Meilby, H., Fensholt, R., and Proud, S.R., 2014. Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery, Remote Sensing of Environment, 140: 23-35, DOI: 10.1016/j.rse.2013.08.029.

Gao, B.C., 1996. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space, Remote Sensing of Environment, 58(3): 257-266, DOI:

- 10.1016/S0034-4257(96)00067-3.
- Kanopoulos, N., Vasanthavada, N., and Baker, R.L., 1988. Design of an image edge detection filter using the Sobel operator, *IEEE Journal of Solid-State Circuits*, 23(2): 358-367, DOI: 10.1109/4.996.
- Liuzzo, L., Puleo, V., Nizza, S., and Freni, G., 2020. Parameterization of a Bayesian normalized difference water index for surface water detection, *Geosciences*, 10(7): 260, DOI: 10.3390/geosciences10070260.
- McFeeters, S.K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, 17(7): 1425-1432, DOI: 10.1080/01431169608948714.
- Seale, C., Redfern, T., Chatfield, P., Luo, C., and Dempsey, K., 2022. Coastline detection in satellite imagery: A deep learning approach on new benchmark data, *Remote Sensing of Environment*, 278: 113044, DOI: 10.1016/j.rse.2022.113044.
- Vincent, O.R., and Folorunso, O., 2009. A descriptive algorithm for sobel image edge detection, in *Proceedings of Informing Science & IT Education Conference (InSITE)*, pp.97-107, DOI: 10.28945/3351.
- Xu, H., 2006. Modification of Normalized Difference Water Index (NDWI) to enhance open water features in remotely sensed imagery, *International Journal of Remote Sensing*, 27(14): 3025-3033, DOI: 10.1080/01431160600589179.

Coastline Automatic Detection and AI Model

Yu-Xin Chen ¹ Hao-Cheng Chien ¹ Hone-Jay Chu ^{2*}

Abstract

Coastline detection is an important research topic in the field of remote sensing, particularly in the context of climate change, sea-level rise, and environmental change. Rapid coastline detection plays a crucial role in environmental monitoring and management. This study combines water indices and deep learning for coastline detection. This study employs the Normalized Difference Water Index (NDWI) and the Automated Water Extraction Index (AWEI), among other related indices, to conduct coastline detection research. By applying five relevant water indices within the Google Earth Engine (GEE) platform, water and land areas in the Waisanding Sandbar region are distinguished to generate binary maps.

Subsequently, Otsu's method is used to automatically determine the optimal threshold and refinement for land and sea classification. The results are compared and analyzed to evaluate the automation process of the coastline detection workflow. Finally, a deep learning approach is applied to produce the coastline detection results. A U-Net deep learning model is trained to automatically detect coastlines directly from satellite imagery. The model achieved an accuracy of 99.6% and an F1 score of 0.72, indicating its effectiveness in detecting the coastline of the Waisanding Sandbar.

Keywords: Coastline Detection, NDWI, AWEI, U-Net

¹ Master Student, Department of Geomatics, National Cheng Kung University

² Professor, Department of Geomatics, National Cheng Kung University

* Corresponding Author, E-mail: honejaychu@geomatics.ncku.edu.tw

Received Date: Apr. 22, 2025

Revised Date: May. 15, 2025

Accepted Date: Jun. 19, 2025