

OAC-110-009 (研究報告)

運用衛星監測越界抽砂船與海底地形變化

(正式報告)

海洋委員會補助研究

中華民國 110年 10月

「本研究報告僅供海洋委員會施政參考，並不代表該會政策，該會保留採用與否之權利。」

OAC-110-009 (研究報告)

運用衛星監測越界抽砂船與海底地形變化

(正式報告)

學校：國立中央大學

指導教授：曾國欣

學生：蔡宗穎

研究期程：中華民國110年4月至110年11月

研究經費：新臺幣7萬元

海洋委員會補助研究

中華民國 110年 10月

「本研究報告僅供海洋委員會施政參考，並不代表該會政策，該會保留採用與否之權利。」

研究報告之書脊處，應印製如下字樣：

OAC-110-009 運用衛星監測越界抽砂船與海底地形變化研究 正式報告 海洋委員會

目次

目次	1
表次	3
圖次	4
摘要	7
第一章 前言	8
第一節 研究源起與問題背景	8
第二節 現況分析	8
第三節 研究目的及研究重點	8
第四節 預期目標	9
第二章 研究方法與過程	9
第一節 資料簡介與研究區域	9
第二節 影像前處理	11
第三節 影像預篩選	15
第四節 陸地遮罩	19
第五節 船舶特徵萃取和偵測	19
第六節 目標物種類判識	22
第七節 測高資料收集	23
第三章 結果與討論	25

第一節 影像前處理結果	25
第二節 影像預篩選結果	26
第三節 目標物分類結果	35
第四節 測高資料收集結果	36
第四章 結論	38
參考資料	39

表 次

表一、獨立物件之面積、形心座標	20
-----------------------	----

圖 次

圖一、研究區域	9
圖二、多視化處理	10
圖三、VV/VH 比較圖	11
圖四、影像前處理流程圖	11
圖五、熱雜訊去除示意圖	12
圖六、邊界雜訊去除示意圖	13
圖七、輻射校準幾何關係	14
圖八、測距都卜勒地形校正示意圖	14
圖九、滑動檢測窗示意圖	16
圖十、形態學運算概念	17
圖十一、膨脹 (左) 、腐蝕 (右)	18
圖十二、4-鄰域 (左) 、8-鄰域 (右)	18
圖十三、二值化影像陸地遮罩	19
圖十四、二值化影像.....	20
圖十五、遮罩後影像	21
圖十六、目標物子影像	21
圖十七、CNN 模型架構	22
圖十八、運砂船(左)、抽砂船(中)、其他(右)	23

圖十九、點雲高程	24
圖二十、前處理結果	25
圖二一、CA-CFAR 結果	26
圖二二、開運算結果	26
圖二三、膨脹運算結果	27
圖二四、連通成分標記結果	27
圖二五、2017年 臺灣淺灘熱區圖	28
圖二六、2018年 臺灣淺灘熱區圖	28
圖二七、2019年 臺灣淺灘熱區圖	29
圖二八、2020年 臺灣淺灘熱區圖	29
圖二九、2021年 臺灣淺灘熱區圖	30
圖三十、2017年 馬祖列島熱區圖	30
圖三一、2018年 馬祖列島熱區圖	31
圖三二、2019年 馬祖列島熱區圖	31
圖三三、2020年 馬祖列島熱區圖	32
圖三四、2021年 馬祖列島熱區圖	32
圖三五、臺灣淺灘逐月統計數量圖	33
圖三六、馬祖列島逐月統計數量圖	34
圖三七、CNN 模型訓練結果	35

圖三八、CNN 判識結果 vs 訓練標籤 36

圖三九、點雲資料預覽 37

摘要

關鍵詞：合成孔徑雷達 (SAR)、船隻偵測

有鑑於近年來台灣西部海域盜採海砂的事件層出不窮，本次研究希望利用衛星遙測技術來增強對此種事件的監測，以協助提升取締的效率。研究方法首先利用衛載合成孔徑雷達 (Synthetic Aperture Radar, SAR) 影像作為資料源，透過影像前處理、CA-CFAR (Cell-Averaging Constant False Alarm Rate) 預篩選、船隻特徵萃取、卷積神經網路 (Convolutional Neural Network, CNN) 目標物種類辨識等步驟來開發出一套自動化的抽砂船偵測演算法，以繪製出抽沙熱點地圖。同時配合 ICESat-2 衛載光達水深探測技術，將研究區域中的點雲資料校正，並擬合出海水表面以及海底表面，利用不同時間所測得的高程差作為依據，判斷抽砂船可能影響的範圍與量體。研究結果發現在所選取的研究區域中 (臺灣淺灘：22.85°N 到 23.35°N，117.85°E 到 118.45°E；馬祖列島：25.85°N 到 26.35°N，119.80°E 到 120.40°E)，船隻出沒的熱點隨著年份有位置和分布範圍上的變化，且各年份影像中偵測到的船隻數量亦有明顯的差異，下至數十艘，上至 1600 多艘。而透過人工分類的訓練資料集 (Training: 120×3; Validation: 325) 所訓練得的卷積神經網路分類器模型在初步的試驗中可以得到 83% 的驗證準確率。後續研究目標主要在於改善分類器的準確率，並且試著結合光達測深技術來估算熱點區域的海底地形變化。

第一章 前言

第一節 研究源起與問題背景

本次研究主題為利用多元衛星資料自動監測越界抽砂船，並探討量化海底地形變化的可行性。臺灣海峽由於其特殊地理位置及環境背景，造就其複雜的自然生態及豐富的資源。因臺灣西部主要為沙質海岸，在輸送與沉積作用下使海峽內呈現平緩的地形及廣大的海砂分布區，深度一般不超過一百公尺，尤其在臺灣淺灘深度更低於二十公尺。也因此近年來在離島周圍海域經常發生大陸抽砂船越界抽砂的情況，不論是離大陸沿岸較近的金門馬祖海域或澎湖西南方的臺灣淺灘，盜採海砂的事件更是層出不窮。而盜採海砂對於臺灣而言，除了破壞生態之外，影響最大的便是國土流失問題，海砂抽取造成的海岸帶影響不但顯著且難以回復。

第二節 現況分析

目前的查緝手段大多依靠海巡署的巡防勤務，然而受限於船艦數量以及日增的出勤成本，加上大陸船隻多在兩岸中線附近抽砂，可以迅速脫離我方海域，因此對於越界抽砂事件的查緝仍有窒礙難行之處。近年盜採海砂的事件層出不窮，每年的取締船數雖有成長但仍有提升執法效能的空間。有鑑於此，尋找更有效率的通報、查緝方法作為科技輔勤的基礎，有非常迫切的需求，且能提供實務上的幫助，若能提供一套即時監測的方法，將給予權責單位及時、有效的攔查依據與佐證。

第三節 研究目的及研究重點

本計畫擬利用雷達影像作為資料源，在影像中尋找可疑的抽砂區域，標記時空上的抽砂熱點。研究目的在於利用衛載合成孔徑雷達 (Synthetic Aperture Radar, SAR) 遙測技術達到船隻判識與量化的目標，透過自主開發的目標偵測演算法，將傳統人工判識船隻的過程改為電腦判識，提升偵測與計數效率。

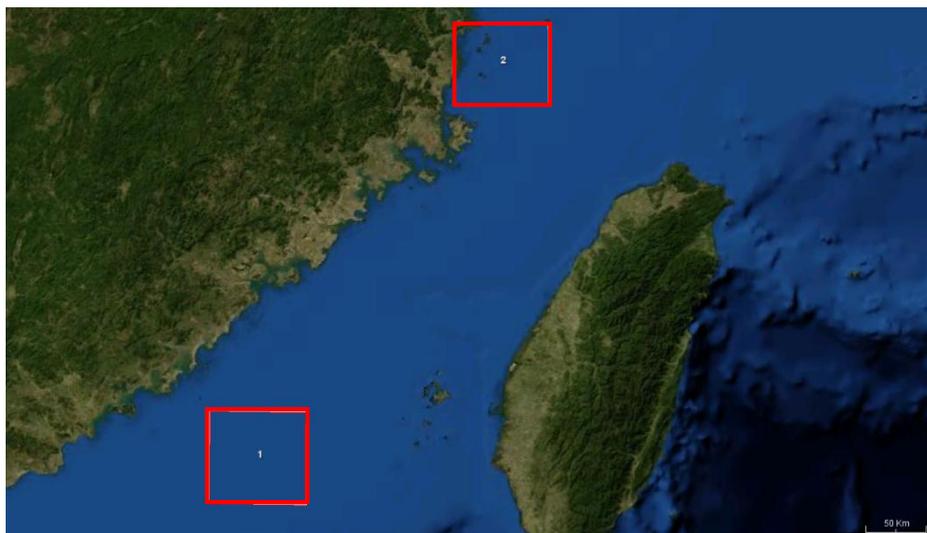
第四節 預期目標

本次研究的預期目標有： 1.利用船舶大小以及在SAR影像中的行為等特性來辨識目標船隻，並在時空上標示出可能的抽砂熱點。 2.嘗試不同的影像分析技術，增加船舶之辨識率。 3.開發出一套自動判識可疑船隻的系統。5.利用衛星遙測技術來探測周圍海域之水深變化，推估該區域的抽砂量。

第二章 研究方法與過程

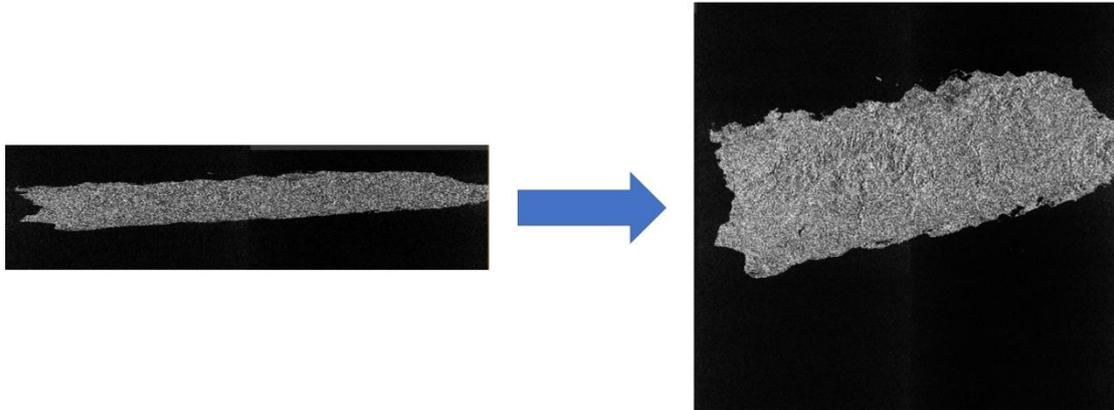
第一節 資料簡介與研究區域

本次研究所使用的影像資料為歐洲太空總署於2014年4月3號發射的地球觀測衛星 Sentinel-1 (哨兵一號) 所拍攝的合成孔徑雷達 (Synthetic Aperture Radar, SAR) 影像。所選用的影像產品為 Level-1 的 GRD (Ground Range Detected)，探測模式為 IW (Interferometric Wide Swath)，其空間解析度約為 20.4m×22.5 m (range × azimuth)，偏極模式 (polarization) 為 VH，拍攝期間為 2017 年 03 月至 2021 年 11 月，共計 98 張影像，研究區域如圖一所示。



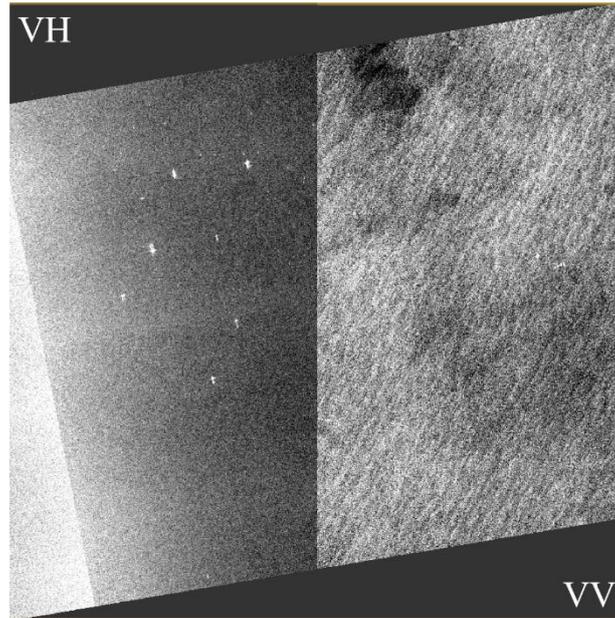
圖一、研究區域

GRD 產品提供的是經過多視化 (multilooking) 處理且利用地球橢球模型投影到地表測距 (ground range) 方向的 SAR 影像。多視化處理最主要的目的在於標稱化像素在測距方向 (range) 和軌道方向 (azimuth) 的大小，進而產出接近正方形的像素，其效果如圖二所示。



圖二、多視化處理

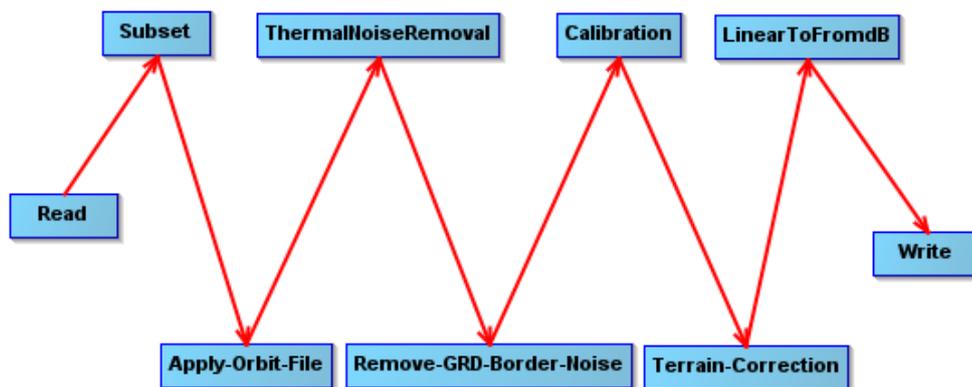
IW 是 Sentinel-1 四種探測模式 (acquisition mode) 的其中一種，IW 模式使用 TOPSAR (Terrain Observation with Progressive Scans SAR) 掃描技術來拍攝影像，所得到的影像具有 250km*3 的行跡寬度以及 5m×20m (single look) 的空間解析度，此模式的優勢在於良好的覆蓋率和解析度。IW 模式提供 VV 和 VH 兩種偏極模式，其中 VH 表示發射垂直方向並接收水平方向的雷達訊號，相較於 VV 模式，VH 模式於平坦表面上的反向散射通常較弱，因此更能凸顯平緩表面上的特徵點，圖三為 VH 和 VV 影像的比較圖。考量到以上對 GRD, IW, VH 的描述，本研究選擇使用 Sentinel-1 GRD IW VH 影像進行船隻偵測。



圖三、VH / VV 比較圖

第二節 影像前處理

本次研究中影像前處理的部分是利用歐洲太空總署所開發的 Sentinel Application Platform (SNAP) 對所有影像進行批量處理，一共有六個步驟 [11]，流程如圖四所示。

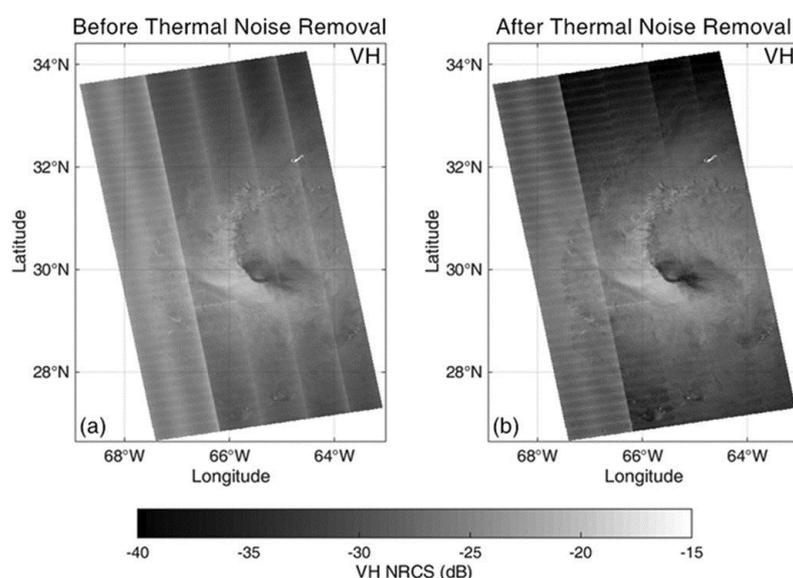


圖四、影像前處理流程圖

第一步是軌道校正 (Apply Orbit Correction)。由於衛星影像的數據 (metadata) 所提供的軌道資料通常不夠準確，因此需要利用額外的精確軌道資料

(precise orbit file) 進行校正。而以Sentinel-1來說，這些精確資料通常在當影像產品生成後的一周內可以得到。精確軌道資料提供了更加準確的衛星位置以及速度資訊，進而對影像的數據進行更新。在 SNAP 中，我們選用 Sentinel Precise 的資料來進行軌道校正。

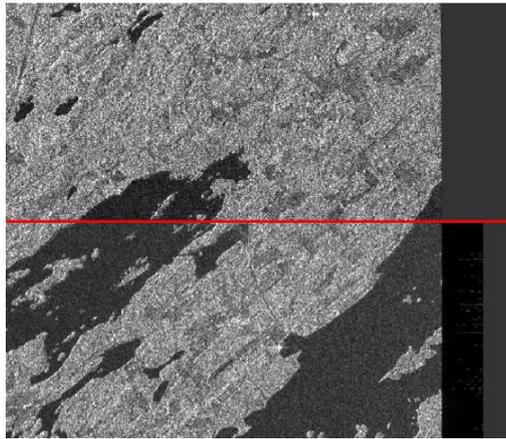
第二步是熱雜訊去除 (Thermal Noise Removal) 。原始 Sentinel-1 影像的像素強度 (intensity) 受到多餘的熱雜訊影響，尤其是正交極化 (cross-polarization) 的影像。透過減少各子掃描帶 (sub-swath) 中的雜訊、標準化整個影像的反向散射信號，以減少子掃描帶之間的不連續性，其效果如圖五所示。



圖五、熱雜訊去除示意圖 [12]

第三步是邊界雜訊去除 (Remove GRD Border Noise) 。 Sentinel-1 Level-1 影像在生成時，需要先經過一系列的處理步驟，主要為軌道方向/測距方向壓縮 (azimuth /range compression) 以及採樣開始時間 (sampling start time) 校正。後者會在影像邊界區域產生空白的像素，而前者則會產生輻射偽影 (radiometric artefacts) ，使得這些像素值變得複雜。這些像素所包含的極低像素值會增加後續閾值處理 (thresholding) 相關應用的難度，因此需要事先去除。此步驟的效果如圖六所示。

After Border Noise Removal



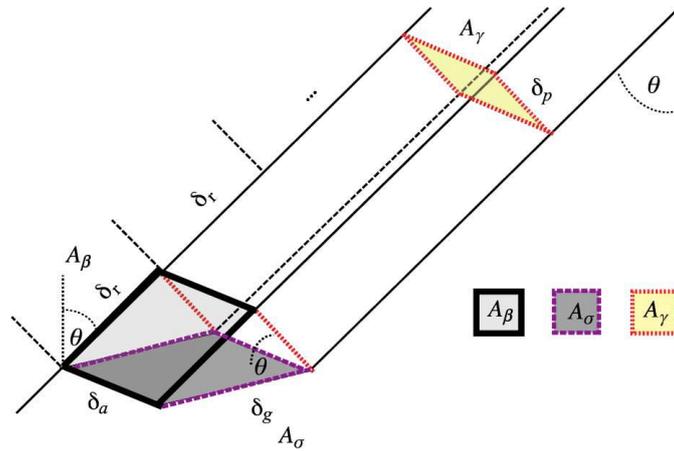
Before Border Noise Removal

圖六、邊界雜訊去除示意圖 [15]

第四步是校準 (Calibration) ，此步驟的主要目的在於轉換影像的像素質，使其與反射物表面的雷達反向散射 (backscatter) 有直接的關聯，通常透過 Sentinel-1 GRD 影像中隨附的校正向量 (calibration vector) 將影像的強度值 (Intensity) 轉換成正規化雷達截面 σ^0 (normalized radar cross section) ， σ^0 以幾何截面積 (geometric cross section) 表示反射訊號的強度。一般在生成 Level-1 的 SAR 影像時，通常不會進行輻射校準，導致 Level-1 產品中留有許多輻射偏差 (radiometric bias) 。因此，對 SAR 影像進行輻射校準是必須的。在比較不同來源、時間、模式的 SAR 影像時，輻射校準是必要的前處理步驟之一，對於 SAR 影像的量化及應用上極為重要。 Sentinel-1 Level-1 影像內含四個查找表 (LUT) 用於 β^0 , σ^0 , γ_i 和 DN (Digital Number) 之間的轉換，輻射校準的公式如下，相關的幾何關係如圖七所示：

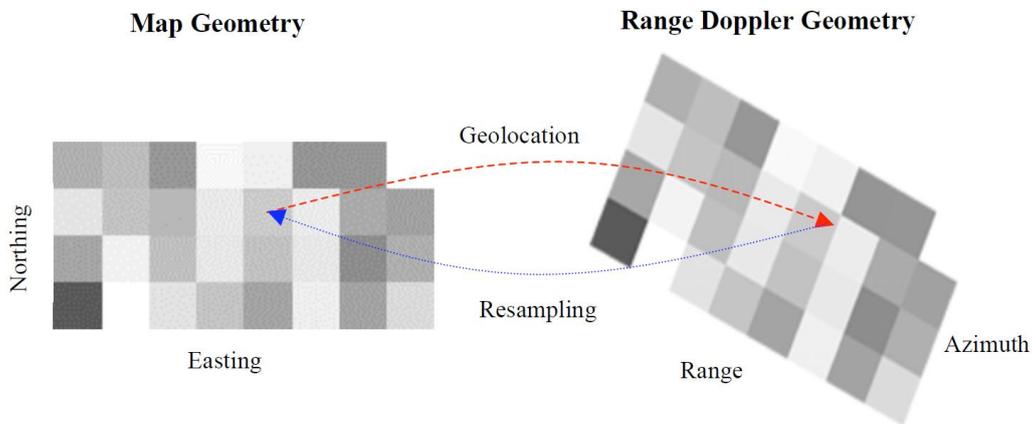
$$\text{value}(i) = \frac{|DN_i|^2}{A_i^2},$$

其中，根據所選用的查找表， $\text{value}(i)$ 可能為 β^0 , σ^0 , γ_i 或 DN_i ; A_i 可能為 $\text{betaNought}(i)$, $\text{sigmaNought}(i)$, $\text{gamma}(i)$ 或 $\text{dn}(i)$ 。



圖七、輻射校準幾何關係 [3]

第五步是地形校正 (Terrain Correction)。受到雷達觀測幾何以及地形變化的影響，所拍攝的雷達影像通常會形成失真，因此需要透過地形校正來將影像的幾何還原成真實情況。在 SNAP 中使用測距都卜勒正射校正 (Range doppler orthorectification) 進行地形校正，配合數值高程模型 (DEM, Digital Elevation Model) 將 SAR 影像地理編碼至正確的座標上。



圖八、測距都卜勒地形校正示意圖 [10]

最後一步則是將無單位的反向散射係數 σ^0 透過以下對數轉換公式換算成分貝值 (dB)：

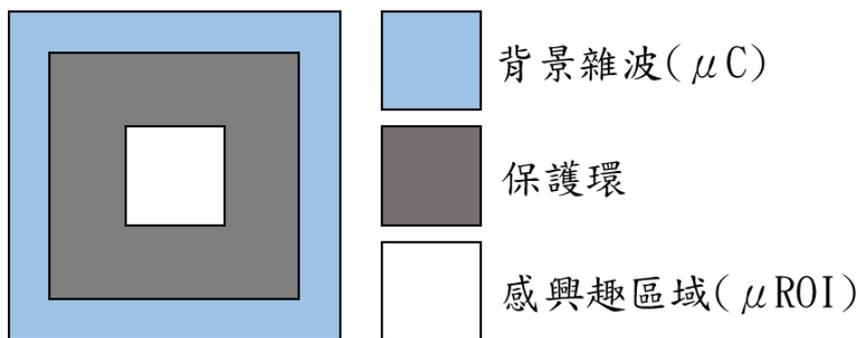
$$\sigma_0(dB) = 10 \log_{10} |\sigma_0|$$

由於 σ^0 的數值可以有幾個數量級的變化 (例如 0.001 和 10)，因此需要將其轉換為分貝 (如 -30dB 和 +10dB) 以方便後續處理。

第三節 影像預篩選

預篩選 (Prescreening) 的主要目的在於對整張影像進行篩選，以標示出可能為船隻的像素。為了能夠加快整個船隻偵測演算法的處理時間，通常會先利用預篩選步驟初步的減少有待辨識之資料，再透過後續識別階段的處理，來獲得最佳的結果。在預篩選的階段，通常會設計一個閾值 (threshold)，這個閾值控制著漏失偵測 (missed detection) 和誤警 (false alarm) 之間的取捨。而一般情況下會透過設計此閾值以達到較高的目標偵測率，但隨之而來的則是較高的誤警率。基於 SAR 影像的特性，船隻通常以較亮的像素顯示在影像中，因此預篩選階段會以搜尋異常亮點的方式處理。最簡單的方式為使用一個固定的全局閾值 (global threshold)，任何強度值高於此閾值的像素將會被檢測出來。這種方法會參考整張影像的強度值直方圖，尋找亮部與暗部像素值分布之間的波谷位置，以訂出特定的全局閾值。而由於 SAR 影像的訊號分布非常複雜，亮部像素與暗部像素的分布不夠明顯，單純透過直方圖分布難以訂出一個理想的閾值，所以全局閾值的方法不太適用於 SAR 船隻偵測。

使用自適應閾值 (adaptive threshold) 則可以彌補全局閾值算法的缺陷。自適應閾值為目前最常見的預篩選算法。雖然也是比較像素值，但是自適應閾值是針對各別像素進行處理。其原理為尋找與周圍像素相比異常明亮的像素值，周圍像素通常透過設置一滑動檢測窗來選取樣本像素進行分析，最基礎的檢測窗如圖九所示。其中，待檢測的像素由一個保護環 (guard ring) 和一個樣本環 (training ring) 所圍繞。保護環的用處在於確保樣本環中的像素值不受檢測目標物的影響，其大小應與檢測目標物的尺寸接近。整個檢測窗以一個像素為單位逐步掃描整張影像。



圖九、滑動檢測窗示意圖

為了使誤警率保持恆定，需要設置一閾值對檢測窗進行偵測，以限制樣本像素值高於此閾值的機率保持恆定，此方法稱為恆定誤警率 (Constant false alarm rate, CFAR)。一般透過對樣本像素值的分布進行參數化建模，以建立一個機率密度函數 $f(x)$ ，有了這個機率密度函數，便可以特定誤警率 PFA 與下列公式計算出所需之閾值 T ：

$$PFA = 1 - \int_{-\infty}^T f(x)dx = \int_T^{\infty} f(x)dx。$$

$$\int_{x_t}^{\infty} f(x)dx < PFA \Leftrightarrow \text{target}。$$

以多視化影像來說，較合適的參數化模型為伽瑪分佈 (Gamma distribution)，基於伽瑪分佈，可將上式改寫為：

$$x_t > \mu_b t \Leftrightarrow \text{target}。$$

其中 x_t 為待檢測之像素值； μ_b 為樣本平均值； t 為設計參數，用於控制誤警率 (PFA)。樣本平均值由樣本環中的像素值計算而來，而設計參數則為一定值。以此分佈所設計之檢測法稱為元素平均恆定誤警率 (Cell averaging constant false alarm, CA-CFAR)。觀察以上公式可以發現，使用 CFAR 來進行預篩選最重要的就是如何選擇設計參數 t ，最常見的做法是根據經驗法則來設置。

本研究使用 MATLAB 數學軟體中的 Phased Array System Toolbox 裡的 CFARDetector2D 函式來對 SAR 影像進行預篩選。在 CFARDetector2D 函式中，偵測閾值 T 的公式為：

$$T = \alpha P_n,$$

$$P_n = \frac{1}{N} \sum_{m=1}^N x_m.$$

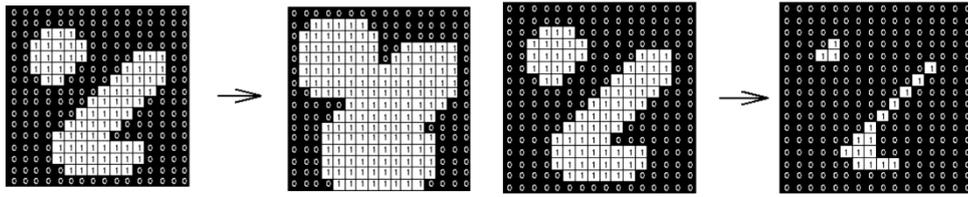
其中， α 為閾值因子 (threshold factor)； P_n 為雜訊功率估計 (noise power estimate)； N 為樣本像素數量； x_m 為樣本像素值。檢測窗大小的設置為：1×1, 21×21, 23×23 分別對應到目標窗口、保護環以及樣本環。保護環的大小依照 Sentinel-1 GRD IW 的空間解析度大約等於 210m×210m 的地面大小，足以容納一般船隻的尺寸。而閾值因子 α 則設置為 0.75 以盡可能偵測影像中所有異常亮點。影像經過預篩選處理後所得到的是一個二值化的矩陣，其中記錄著預篩選步驟對每個像素的判斷，0 代表該像素不可能屬於船隻，1 代表該像素有可能屬於船隻。

由於先前提到的，預篩選步驟的設置以盡可能偵測影像中所有異常亮點為目標，造成此結果可能會包含許多雜訊，因此需要進一步處理。形態學運算 (morphological operation) 可用於移除二值影像中的雜訊，其基本概念為使用一結構元素 (structure element) 來卷積整張影像，當待檢測之像素與其周圍像素的型態符合此結構元素與其判斷邏輯時，則保留其像素值，反之則去除，其概念如圖十所示。



圖十、形態學運算概念 [16]

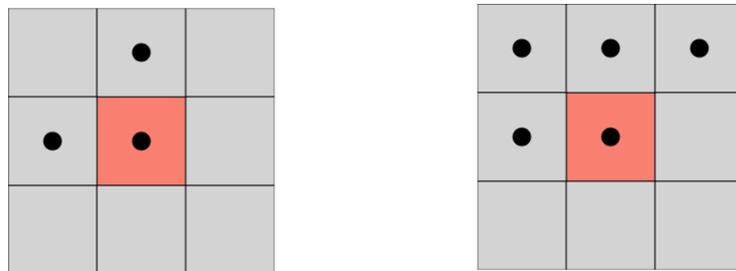
最基礎的形態學為膨脹 (Dilation) 和腐蝕 (Erosion)，膨脹的定義為「結構元素是否有探測到物件？」，而腐蝕的定義為「結構元素是否有全部探測到物件？」，各自的效果如圖十一所示。



圖十一、膨脹（左）、腐蝕（右）[16]

本研究中先對預篩選後的影像先進行開運算（opening）以去除細小的雜訊，再使用膨脹來還原偵測結果的尺寸，其中開運算為先腐蝕再膨脹。使用的結構元素為一 3×3 大小的正方形矩陣，對應的實際大小為 $60\text{m} \times 60\text{m}$ ，以保留大於此尺寸之目標。

經過形態學運算處理後，使用連通分量標記（connected component labeling）來計算各影像中所偵測到的目標物數量。連通分量標記可以對二值化影像進行標籤，把相鄰區塊的像素標示為同一標籤，最後計算出整張影像每個像素屬於哪個標籤，依照所參考的像素位置，又可分為 4-鄰域和 8-鄰域算法，其參考的像素位置如圖十二所示。



圖十二、4-鄰域（左）、8-鄰域（右）[17]

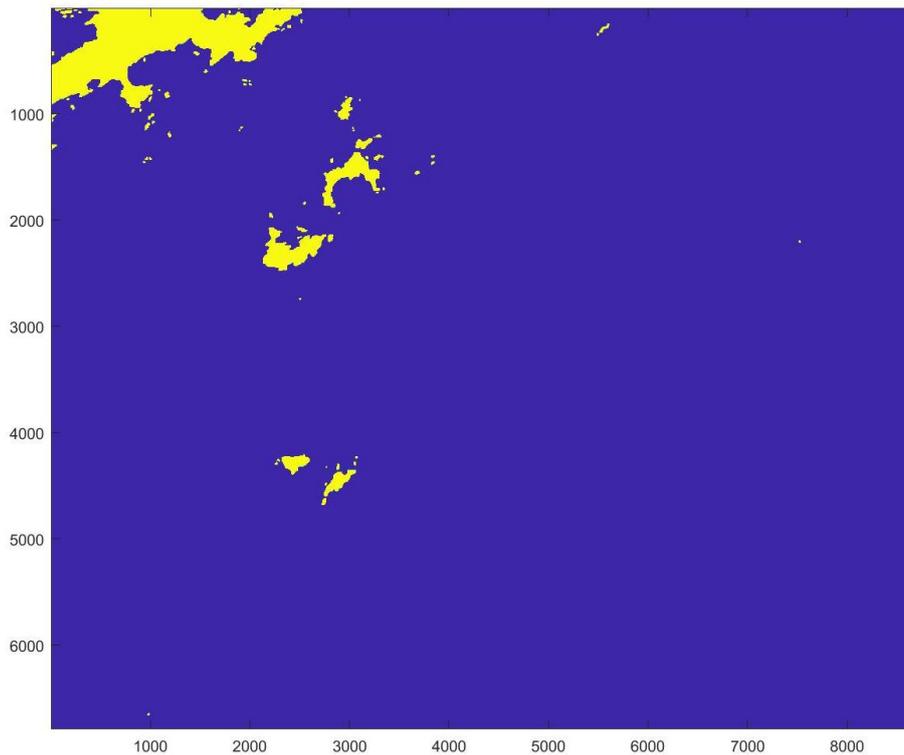
本研究中使用 8-鄰域算法，其判斷邏輯如下：

1. 如果這四個方向的值都是 0，就在該位置的原標號上加 1。
2. 如果這四個方向的標號都一樣，那麼該位置標號就是其領域的非 0 標號。
3. 如果這四個方向的非 0 值有兩個不同的標號，那麼該位置標號就選其中之一，並記錄這兩個不同的標號。

最後將相通但不同標號的區域進行整合，得到結果。

第四節 陸地遮罩

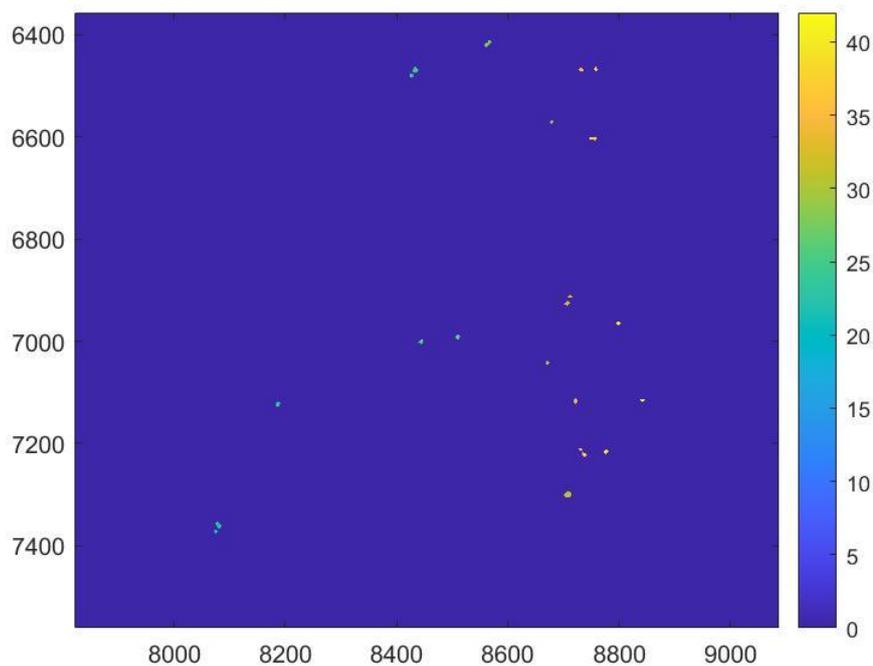
對預篩選後得到的二值化影像進行陸地遮罩，將屬於陸地的像素去除。本研究中使用 GSHHG (Global Self-consistent, Hierarchical, High-resolution Geography Database) 的海岸線資料，將其製作成研究區域的二值化陸地遮罩，並用其判斷影像中的像素是否屬於陸地，此遮罩如圖十三所示：



圖十三、二值化陸地遮罩

第五節 船舶特徵萃取和偵測

經過前面預篩選 (Prescreening) 以及形態學運算 (Morphological operation) 處理後所得到的二值影像可以進一步用來估算目標物的面積以及其形心座標。以 Subset_S1A_IW_GRDH_1SDV_20201223T101733_20201223T101802_035812_043130_4BFB_Orb_NR_Cal_TC_dB.tif 這張影像為例，在形態學運算處理後得到的二值影像如圖十四所示：



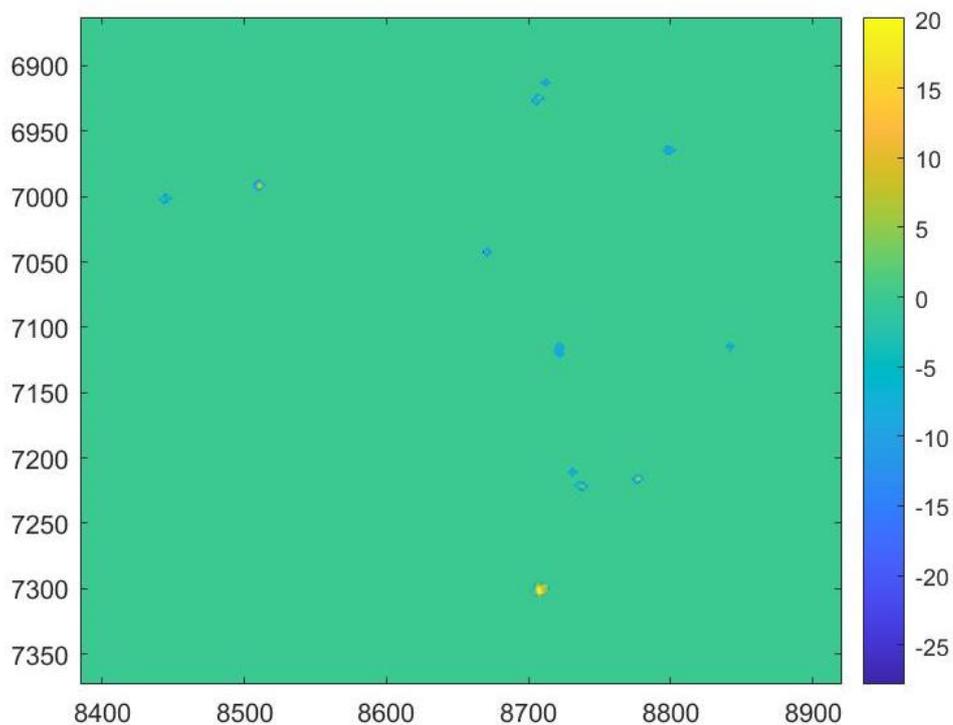
圖十四、二值化影像

為了方便觀察，上圖只顯示原始影像中的部分區域。利用連通分量標記 (connected component labeling) 可以標記出此影像中所有獨立物件的像素，從圖中可以看到，標記的結果有 42 獨立物件。接著利用 Matlab 中的函式 `regionprops` 去計算個別獨立物件的各種性質，其中包括面積、形心，部分得到的資料如表一所示：

表一、獨立物件之面積、形心座標

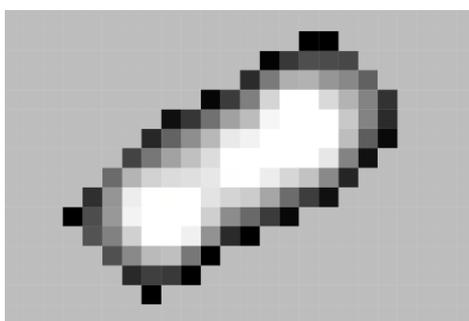
Fields	Area	Centroid
1	59	[87.4748,13.678e+03]
2	49	[337.5918,1363]
3	108	[1.1061e+03,4.3188e+03]
4	53	[1.1216e+03,4.3188e+03]
5	224	[1.4312e+03,3.8444e+03]

，利用面積資訊可以進一步去除掉剩餘的異常值。本研究中將篩選的面積大小設定在 300~25 個像素，以保留所有可能的目標物。接著利用此二值影像對原始影像進行遮罩，得到的結果如圖十五所示：



圖十五、遮罩後影像

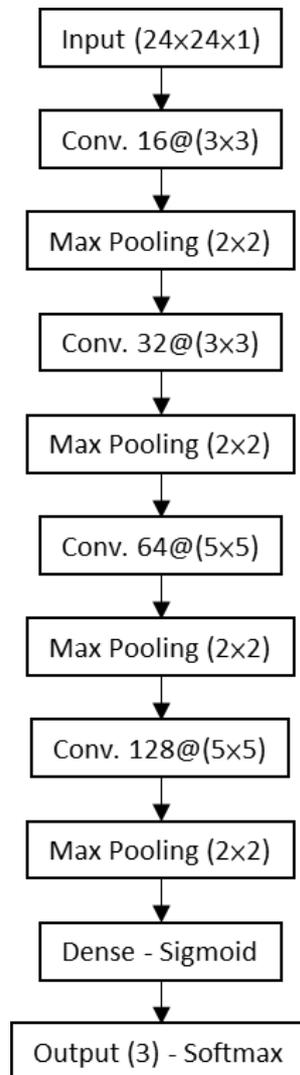
最後透過形心座標資料來擷取各個目標的子影像，本研究中以各個形心座標周圍 24x24 的範圍進行擷取，得到的子影像如圖十六所示。



圖十六、目標物子影像

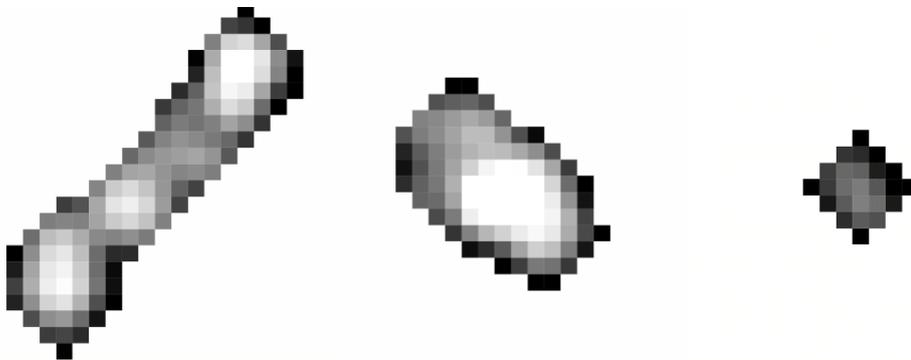
第六節 目標物種類判識

在船隻偵測的最後一個步驟中，本研究預計使用卷積神經網路 (Convolutional Neural Network, CNN) 對上個步驟所得到的所有子影像進行分類。卷積神經網路的特點在於運用多個過濾窗口 (filter window) 對輸入影像進行卷積，以讀取影像中的特徵，並保留其二維資訊。由於此種算法邏輯，卷積神經網路特別適合用於處理格狀資料方面的應用，例如影像判識。本研究利用 MATLAB 中的 Deep Learning Toolbox 來在進行卷積神經網路模型的建立和訓練。分類之前，首先要設定分類模型的架構，本研究中所使用的模型架構如圖十七所示：



圖十七、CNN 模型架構

其中輸入資料為 $24 \times 24 \times 1$ 的子影像，中間有四層卷積層 (Convolutional layer)，過濾窗口大小為 3×3 和 5×5 ，每層卷積層的後面都接著一個最大池化層 (Max-pooling layer) 以減少網路中的參數來避免過擬合 (Overfitting)，在最後一層最大池化層的後面接一個完全連接層 (Fully-connected layer)。設定好模型架構後，便可以利用事先標記好的訓練資料集來訓練模型，由於目前沒有現成的 Sentinel-1 抽砂船的訓練資料集，因此實驗中所使用的訓練資料集為人工分類標示的影像，一共分為三類，各類別的範例如圖十八所示：



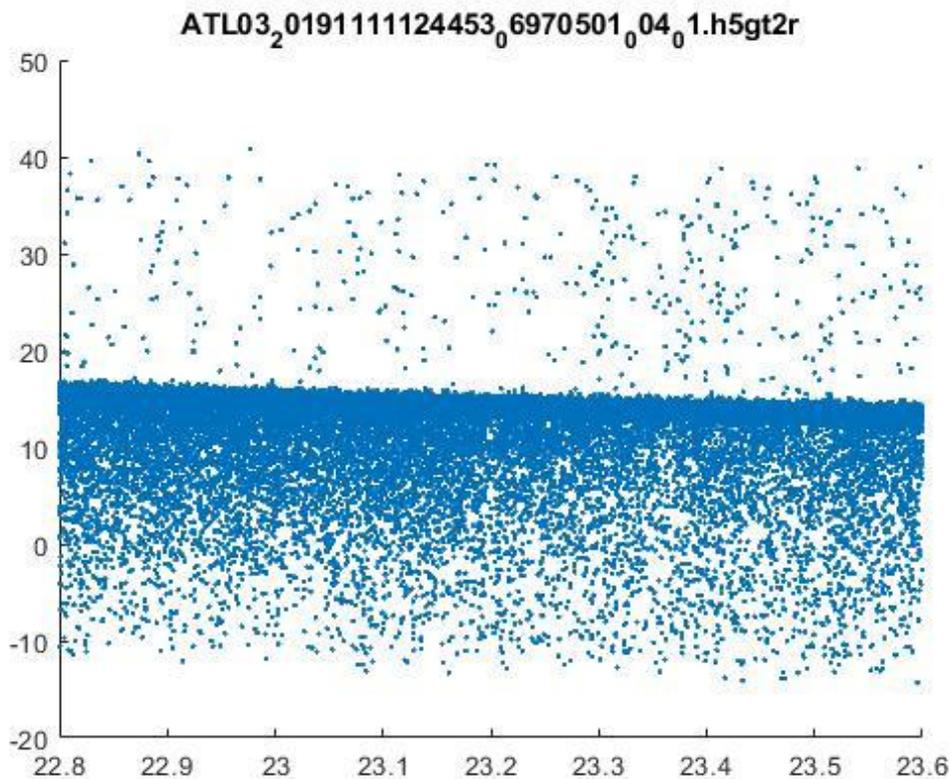
圖十八、運砂船(左)、抽砂船(中)、其他(右)

實驗中將這三個類別分別標記為 A、B、C，訓練集使用了十張的 Sentinel-1 原始影像中的子影像共 629 張，其中 A 類有 138 張；B 類有 197 張；C 類有 294 張，從這三類中隨機取出各 120 張來做為訓練資料，剩餘影像則做為驗證資料。卷積神經網路模型訓練完畢後還須對其進行驗證以計算其準確率，通過驗證的模型便可以用於目標分類。

第七節 測高資料收集

本次計畫的第二部分為 ICESat-2 衛載光達水深探測，使用的資料為國家冰雪數據中心 National Snow and Ice Data Center (NSIDC) 所提供的 ATL03 全球地理定位光子數據 (Global Geolocated Photon Data, Version 4)，資料中紀錄了以 WGS84 橢球為基準的光子高程和經緯座標。對應上一部分臺灣淺灘所使用的

Sentinel-1 影像的拍攝期間 (2019 年 01 月至 2021 年 06 月) 以及選取的研究範圍 (22.85°N 到 23.35°N ; 117.85°E 到 118.45°E) , 收集到的點雲資料一共有 46 筆, 所有點雲資料都以分層數據格式 (HDF5) 的格式儲存。由於 ATL03 點雲數據的地表測高品質會受到許多因素的影響, 例如雲層反射陽光, 會影響表面回波的偵測, 因此需要對點雲資料進行篩選。首先使用 Matlab 讀取 .h5 檔案, 將檔案中六個光束 (gt1l, gt1r, gt2l, gt2r, gt3l, gt3r) 的經度 (lon_{ph}), 緯度 (lat_{ph}), 高程 (h_{ph}) 資料提取出來, 利用經度和緯度資料來框選研究範圍中的資料, 並沿著緯度繪製點雲高程, 得到的點雲圖如圖十九所示。

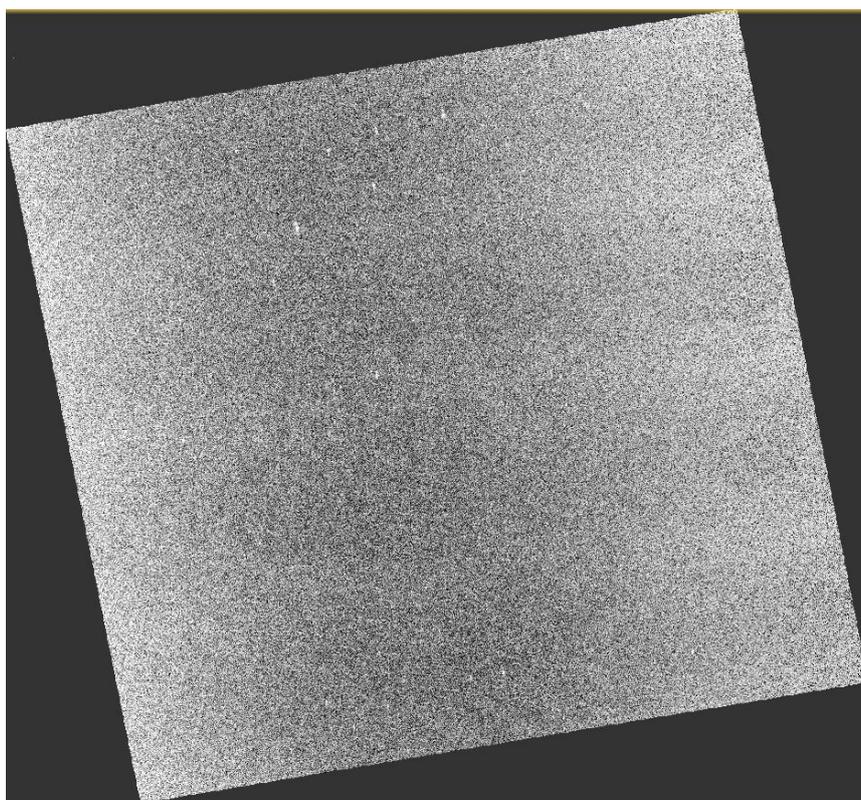


圖十九、點雲高程

第三章 結果與討論

第一節 影像前處理結果

原始 SAR 影像經由 SNAP 軟體進行影像前處理後，可以獲得較有利於船隻偵測分析的影像。考量到處理時間的因素，在實驗中在前處理之前先對原始影像進行分割，以減少所要分析的資料量，分割出來的區域為 22.9°N 到 23.5°N ； 117.8°E 到 118.4°E，最後所得到的子影像如圖二十所示。

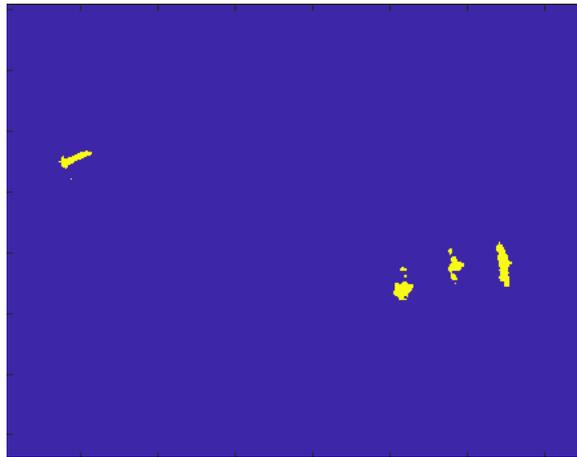


圖二十、前處理結果

從上圖中可以看到，雖然經過前處理的六個步驟，但是影像的訊號還是難以透過肉眼直接判識。如果時間允許，後續還可以嘗試其他前處理方法與調整參數來達到更好的效果。

第二節 影像預篩選結果

目前預篩選的程序為 CA-CFAR 預篩選加上形態學運算以最佳化結果，並利用連通分量標記來統計偵測目標數量。首先，經過 CA-CFAR 篩選的結果如圖二一所示：



圖二一、CA-CFAR 結果

由於偵測目標對於整張 SAR 子影像來說還是太小，難以辨識，因此報告中將偵測到目標物的區域放大，以方便解釋。可以看到，圖中出現四個可能為船隻的目標，但是其周圍還有殘留的雜訊。接著使用開運算處理，結果如圖二二所示：



圖二二、開運算結果

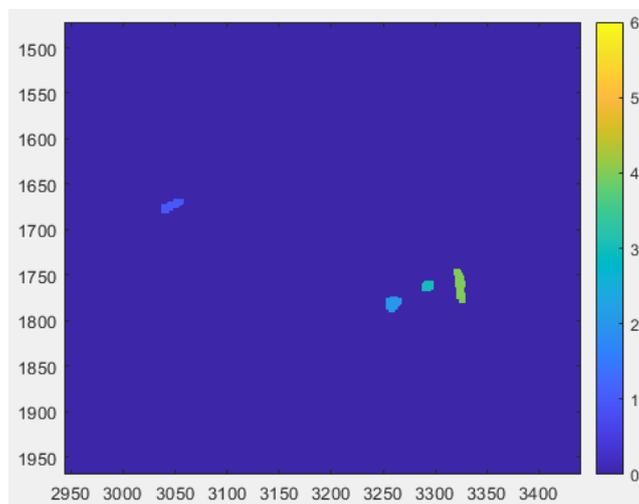
與圖十四比較，可以看出目標物經過開運算後，周圍的雜訊已被去除。但是預篩

選的結果在後續船隻判識的處理程序裡是作為目標指示二值遮罩使用，因此需要透過膨脹運算來還原目標物尺寸，結果如圖二三所示：



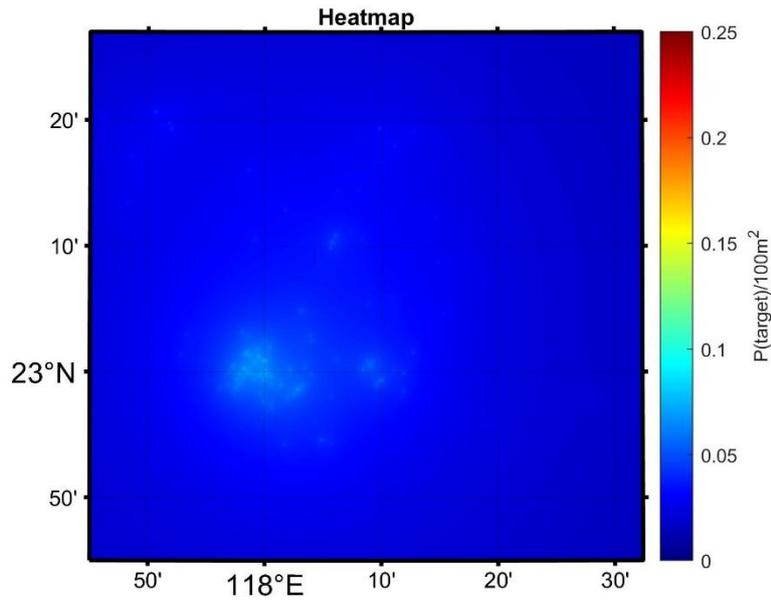
圖二三、膨脹運算結果

從上圖可以看出，得到的結果為各自獨立的偵測結果，並且範圍大於原始大小。接著利用連通成分標記配合此結果來統計偵測數，結果如圖二四所示，各影像統計結果列於表二：

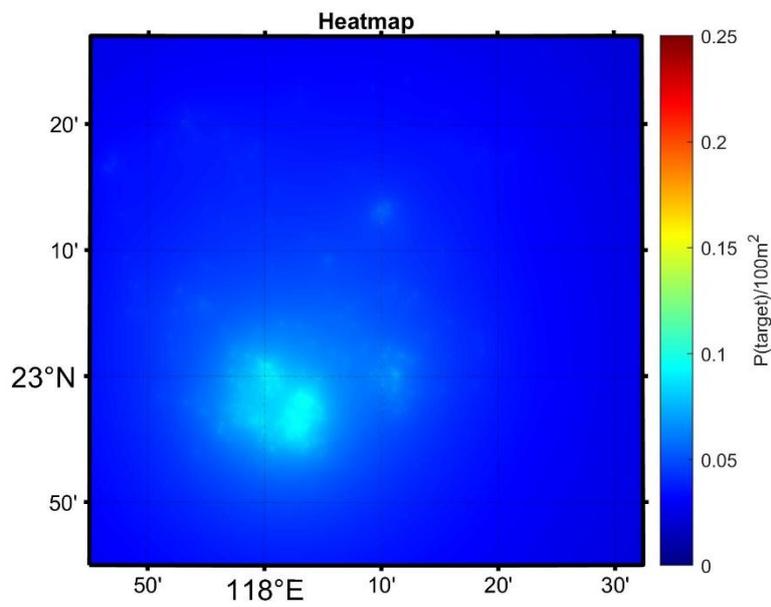


圖二四、連通成分標記結果

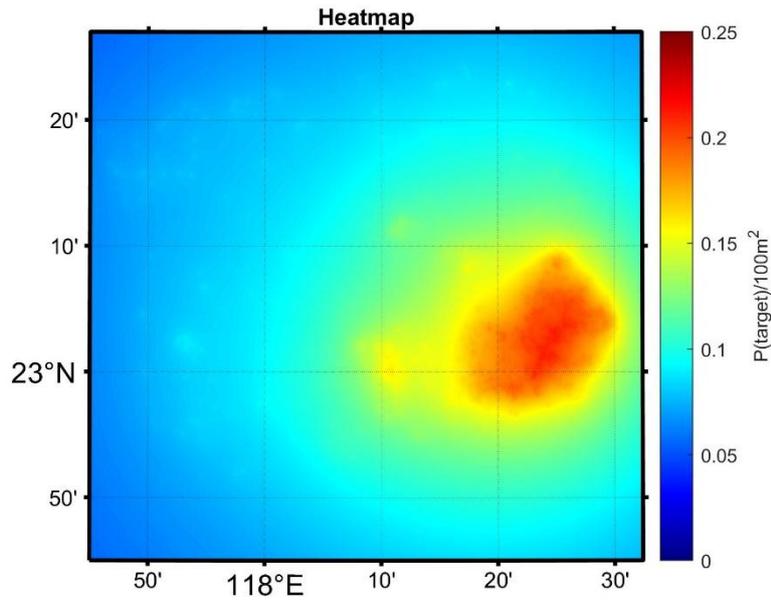
圖中顏色代表各偵測目標的標籤號碼，以此張影像為例，預篩選最終偵測到的目標數為六個。接著將所有影像的預篩選結果疊加，透過內插法可以得到此範圍的熱區圖，結果如圖二五～三四所示：



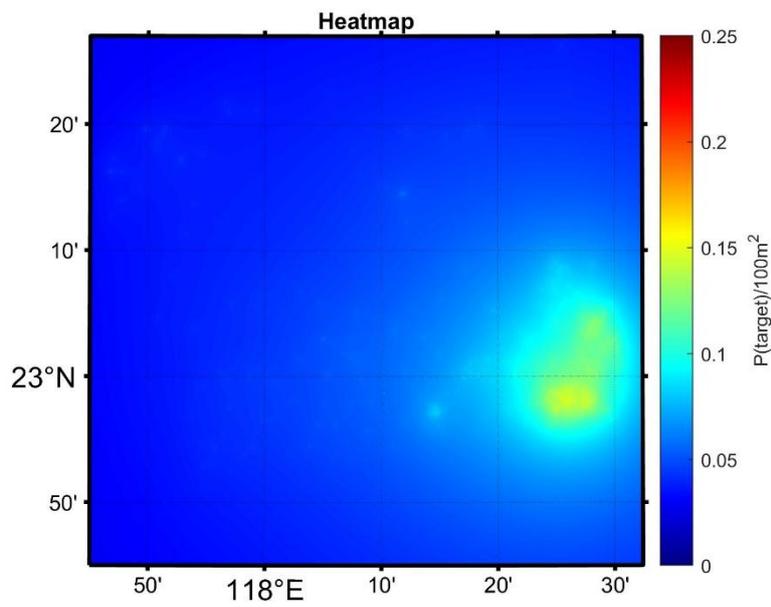
圖二五、2017年 臺灣淺灘熱區圖



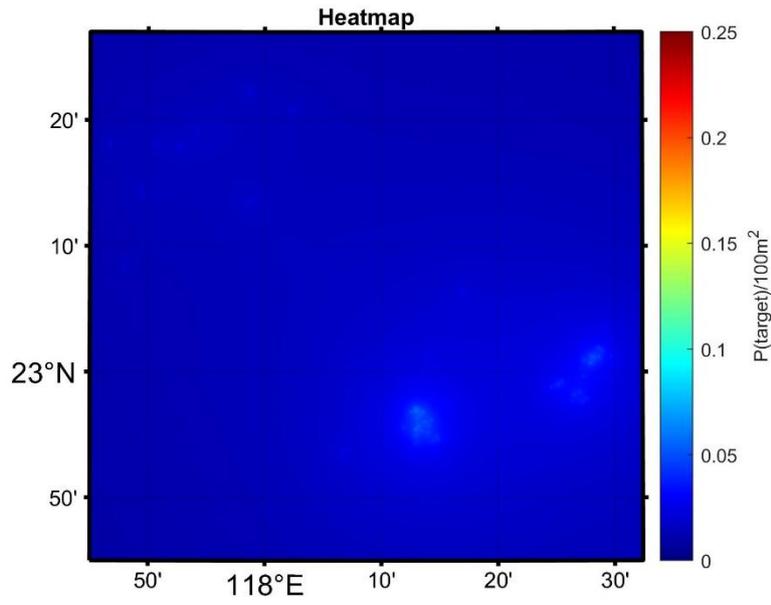
圖二六、2018年 臺灣淺灘熱區圖



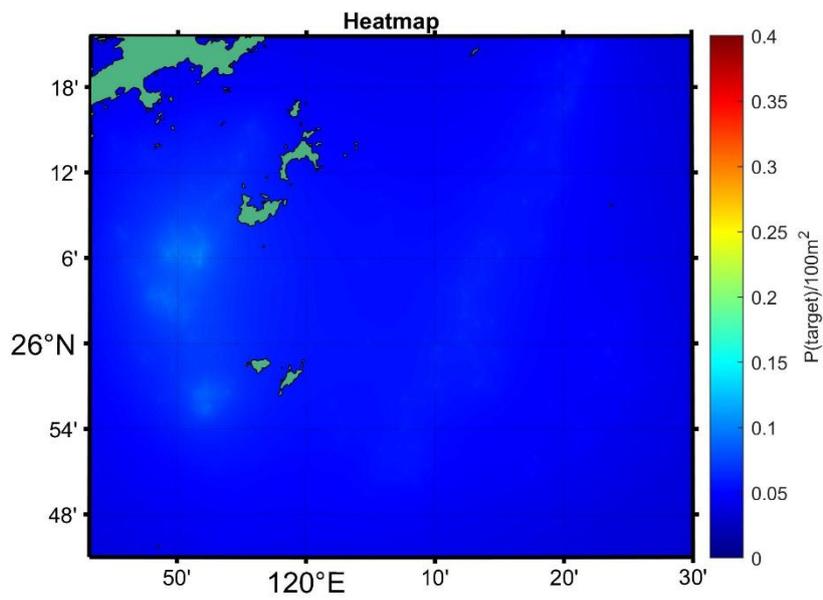
圖二七、2019年 臺灣淺灘熱區圖



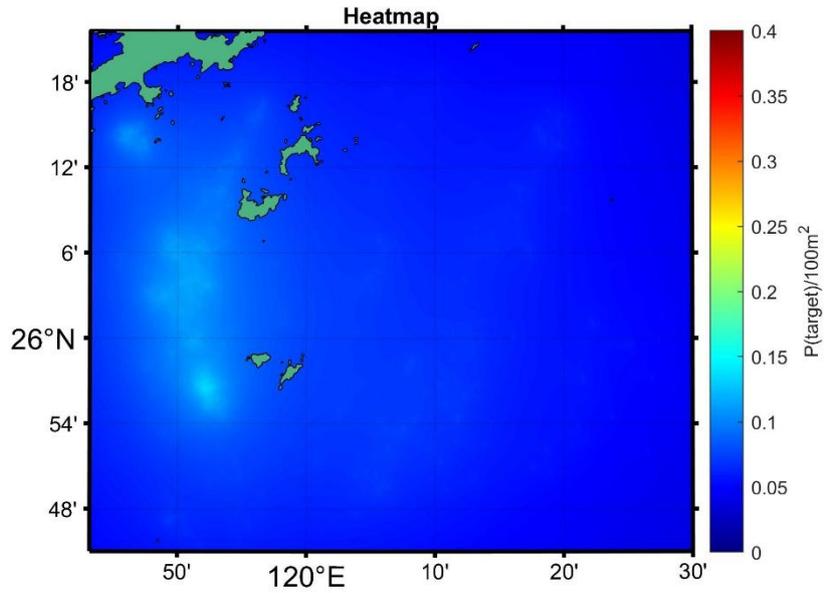
圖二八、2020年 臺灣淺灘熱區圖



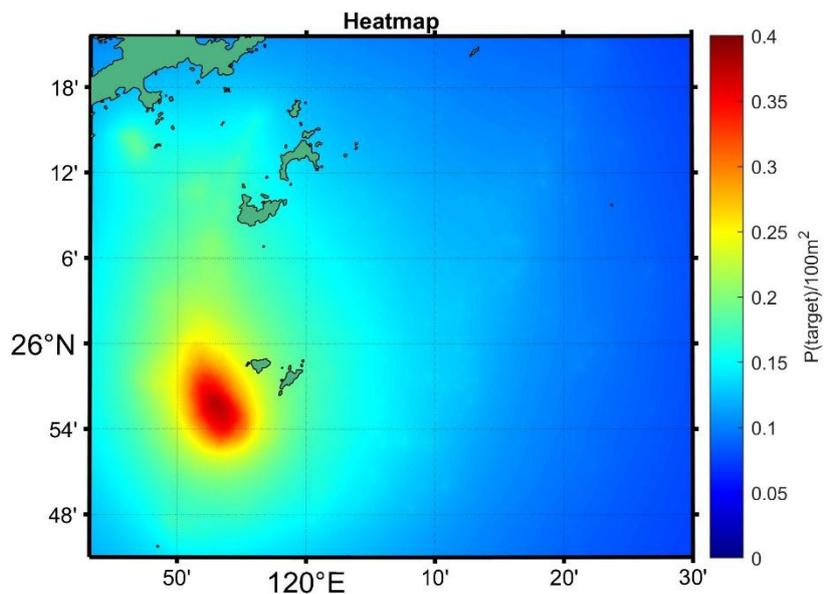
圖二九、2021年 臺灣淺灘熱區圖



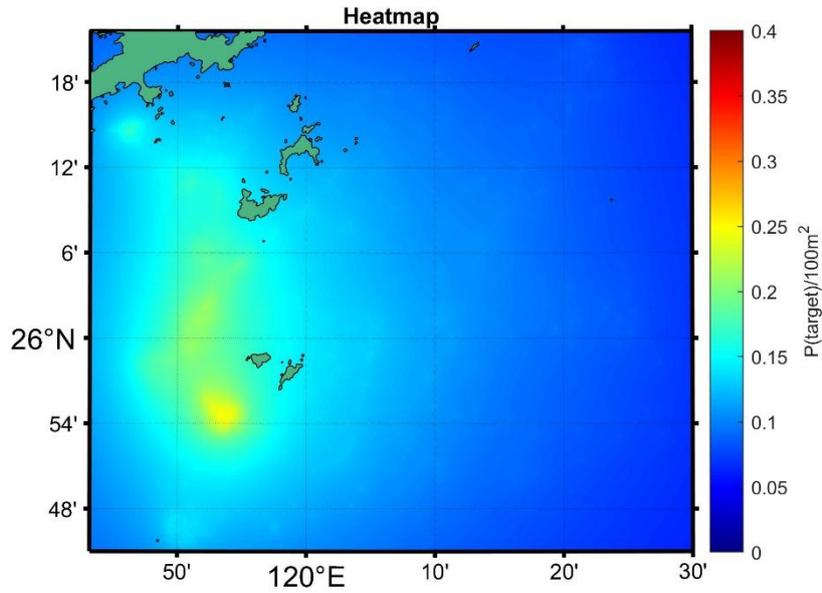
圖三十、2017年 馬祖列島熱區圖



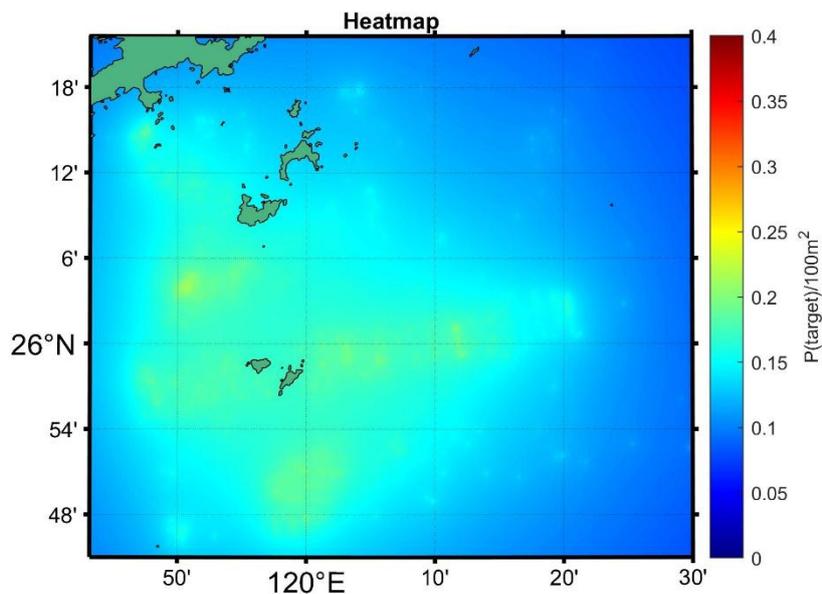
圖三一、2018年 馬祖列島熱區圖



圖三二、2019年 馬祖列島熱區圖



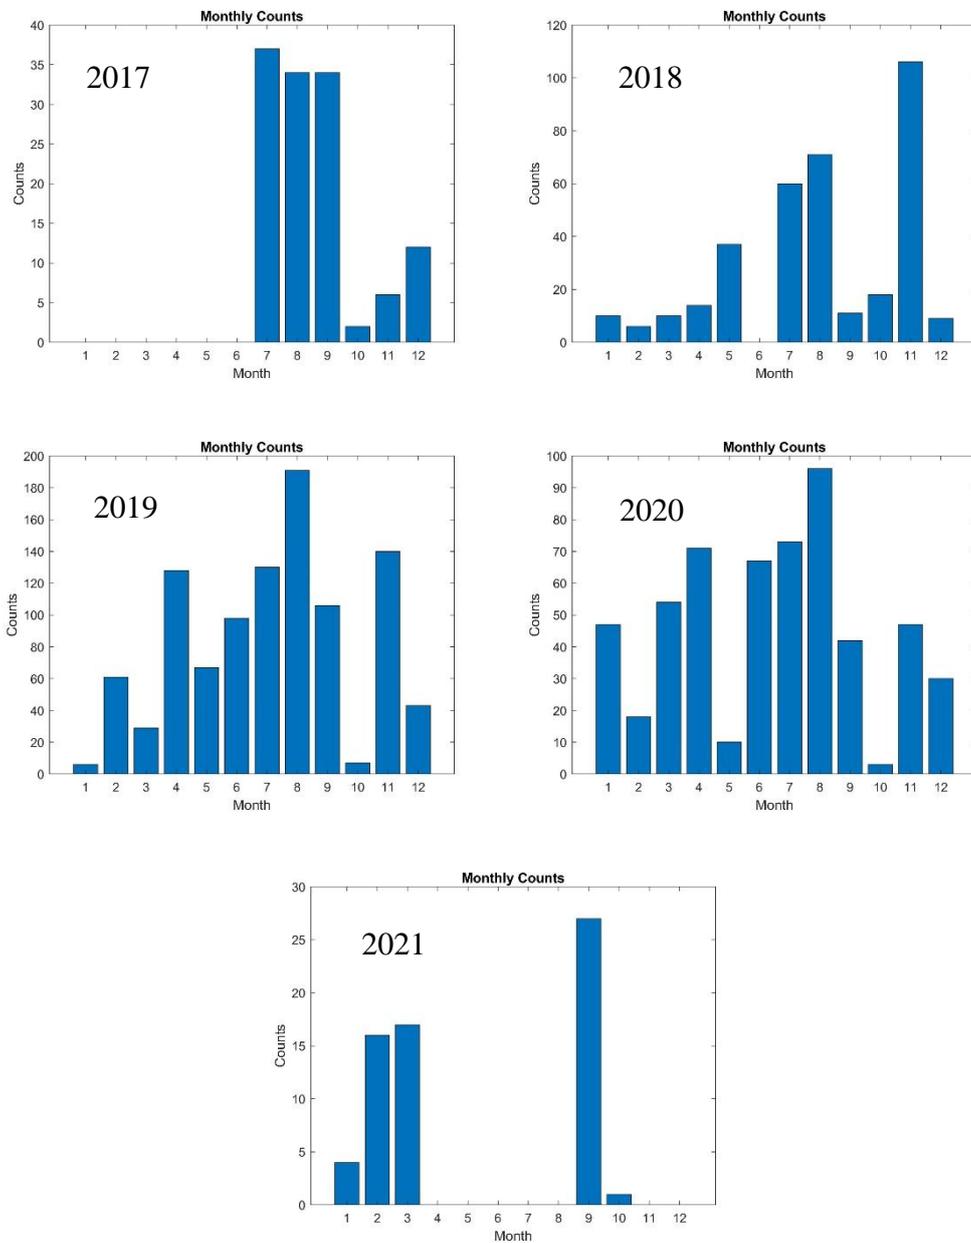
圖三三、2020年 馬祖列島熱區圖



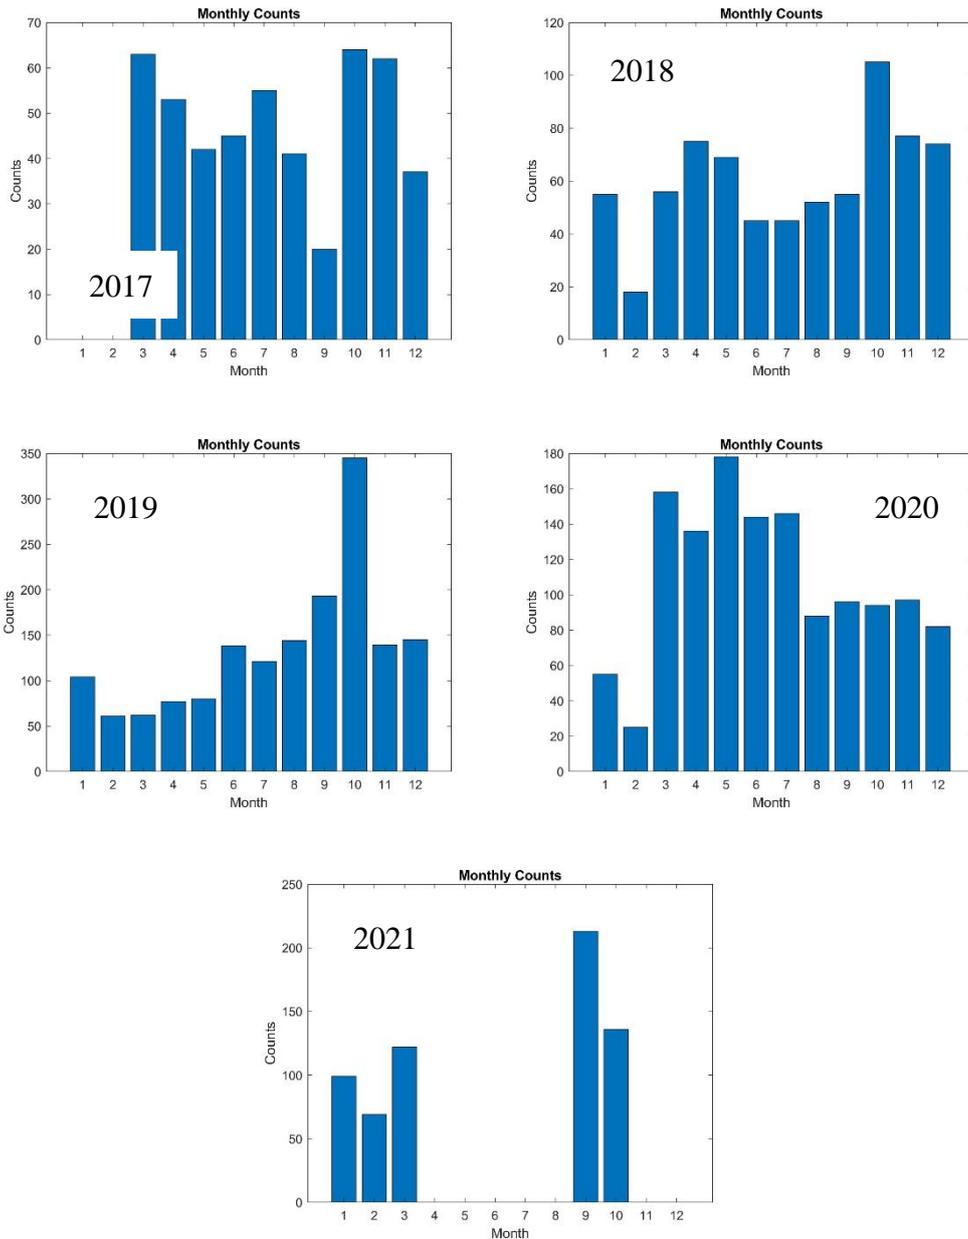
圖三四、2021年 馬祖列島熱區圖

從熱區圖中可以看到，對於臺灣淺灘來說，船隻主要出現位置在 2017~2018 年時集中在影像的西南部分，但是 2019~2021 年則較為偏向東南部分。而馬祖列島的部分，除了 2017 年以外，其餘年分的船隻出現位置大多集中在莒光島附近，2021 年的熱區分布則較為擴散。另外，從各個熱區圖的最大計數可以看出，兩

個區域的高峰期皆出現在 2019 年。時序預測的部分則是透過統計各月份影像中偵測到的目標數量並將其繪製成直方圖，結果如圖三五、三六所示：



圖三五、臺灣淺灘逐月統計數量圖

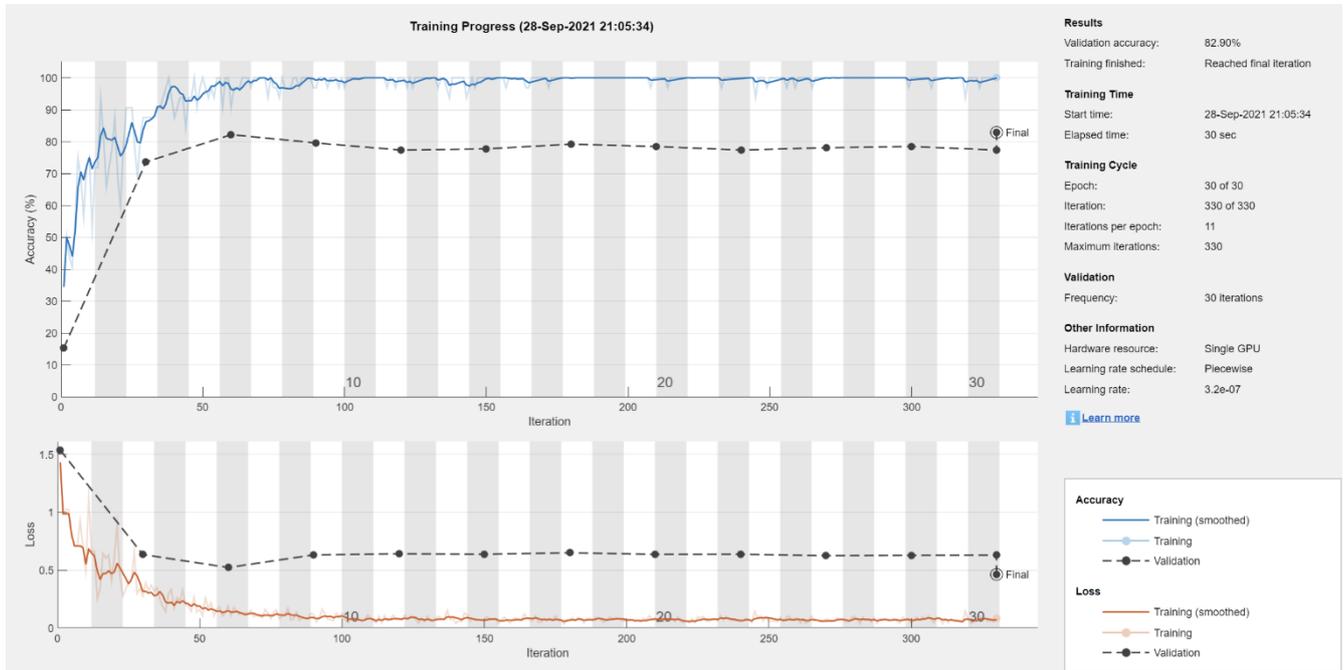


圖三六、馬祖列島逐月統計數量圖

其中臺灣淺灘 2017 年的一到六月和馬祖列島 2017 年的一、二月缺少影像；臺灣淺灘和馬祖列島 2021 年的四到六月則是因為 Sentinel-1A 的精密軌道資料無法下載，因此無法進行前處理。從臺灣淺灘各年的逐月統計數量圖可以大致看出，除了 2018 年以外，其餘年分的高峰皆發生在夏、秋季；至於馬祖列島的部分則較集中在春、秋季，但趨勢並不明顯。

第三節 目標物種類判識結果

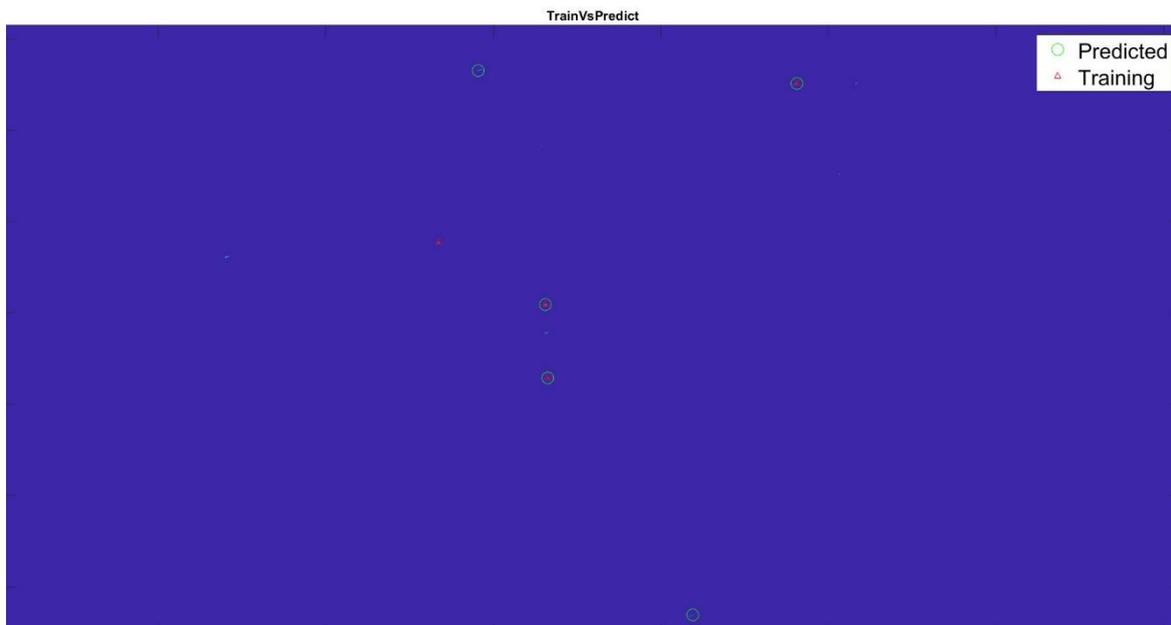
在利用卷積神經網路對偵測目標進行分類的部分，其訓練結果如圖三七所



示：

圖三七、CNN 模型訓練結果

從上圖中可以看到，使用人工分類的訓練資料集所訓練出來的卷積神經網路模型在驗證時的準確率為 82.9%。造成分類準確率過低有幾個主要原因，首先是訓練資料的數量太少，三個種類總共只用了 360 張子影像當作參考值，導致訓練結果不佳，因此接下來需要增加訓練用的樣本數，目標是提升到每個種類 300 個樣本。第二個原因則是因為人工分類訓練資料，由於缺乏現成的標記數據，因此只能選擇自行製作訓練資料，但是透過實驗發現，適當增加分類的種類數有助於提升訓練結果。第三個原因則可能是模型架構和訓練方法的設定，由於目前使用的架構和訓練選項多數還是使用預設值，因此可能不夠適合實驗中使用的資料，後續還要再對其進行調整，以最佳化模型的分類能力。



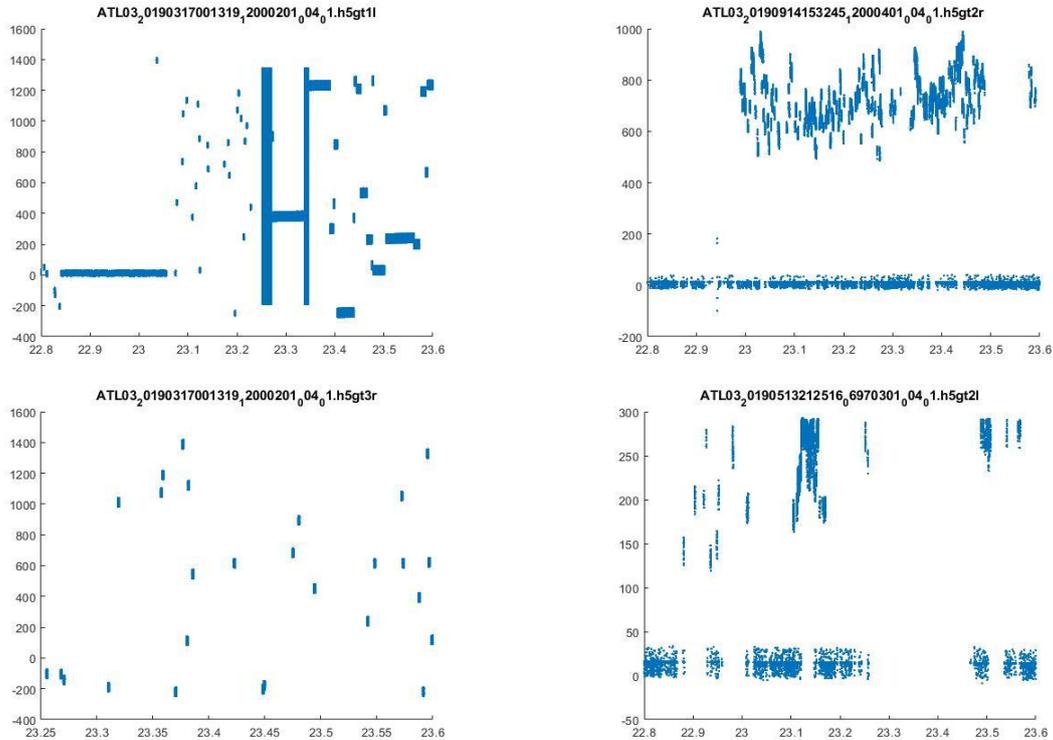
圖三八、CNN 判識結果 vs 訓練標籤

圖三八顯示了CNN 判識結果和訓練標籤的對比，紅色三角形所標示的點為訓練資料集中屬於抽砂船類別的目標物，綠色圓圈所標示的則是 CNN 分類器判識屬於抽砂船類別的目標物，可以發現在四個標籤中有三個被正確判識，同時有兩個非抽砂船類別的目標物被錯誤判識。得到的 TP (True Positive) = 3, FP (False Positive) = 2, FN (False Negative) = 1, 精確率 (precision = $TP / (TP + FP)$) 為 0.6, 召回率 (recall = $TP / (TP + FN)$) 為 0.75, F1-score = $2 * Precision * Recall / (Precision + Recall)$ 為 0.667, 不夠趨近 F1-score 的理想值, 顯示此模型還有待改善。

第四節 測高資料收集結果

前面研究方法與過程中有提到, 在測高資料收集的部分, 收集了時間從 2019 年 01 月到 2021 年 06 月、範圍在 22.85°N 到 23.35°N ; 117.85°E 到 118.45°E 之間的點雲資料, 一共收集到了 46 個 HDF5 檔案。對所收集到的資料進行擷取, 每個 HDF5 檔案都有六組經度、緯度、高程資料, 但是不一定每組資料都同過目標區域, 最後總共擷取出了 184 組資料, 利用 MATLAB 來預

覽這些資料，並進行初步的篩選，其中只有 44 個檔案的點雲資料沒有受到外在因素的干擾，而大部分的檔案都有受到些許的汙染或是資料不完整，如圖三九所示：



圖三九、點雲資料預覽

剩下的 44 個檔案雖然沒有資料缺失，點雲也沒有異常，但依舊無法觀察到海底表面的反射訊號，導致目前量化海底地形變化暫時還無法達成。

第四章 結論

越界盜採海砂是近幾年來臺灣西部海域一項重要的議題，對於臺灣的經濟、生態以及國防等各個方面都有著不小的影響。本研究嘗試利用衛星遙測技術來增強針對此種事件的監測，透過電腦自動化偵測目標區域中的抽砂船，經過影像前處理、CA-CFAR 預篩選、陸地遮罩和特徵萃取及分析等步驟處理後的二值化影像已經可以大致偵測出特定大小的可疑船隻。從臺灣淺灘區域的熱區圖可以發現，抽砂熱點有由西往東發展的趨勢，馬祖列島區域則是由南竿島往莒光島擴散。時間方面，兩個目標區域的最大數量皆出現在 2019 年，可以大致看出盜抽海砂活動開始興盛以及暫緩的時間。另外從逐月統計數量圖可以大致看出，臺灣淺灘區域多數年分的高峰皆發生在夏、秋季，而馬祖列島的部分則較集中在春、秋季，但趨勢並不明顯。本研究也嘗試使用卷積神經網路來分辨目標物是否為抽砂船，在初步的試驗中得到 83% 的驗證準確率，由於缺乏訓練樣本加上 Sentinel-1 影像之空間解析度不足，因此結果不盡理想。最後海底地形變化探測的部分則因為 ICESat-2 光子點雲資料的品質沒有達到預想中的程度，目前暫時還沒有辦法測得海底高程。

參考資料

- [1] Iervolino, P., Guida, R., & Whittaker, P. (2015, September). A novel ship-detection technique for Sentinel-1 SAR data. In 2015 IEEE 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR) (pp. 797-801). IEEE.
- [2] Wackerman, C. C., Friedman, K. S., Pichel, W. G., Clemente-Colón, P., & Li, X. I. A. O. F. E. N. G. (2001). Automatic detection of ships in RADARSAT-1 SAR imagery. *Canadian journal of remote sensing*, 27(5), 568-577.
- [3] Atwood, D. K., Small, D., & Gens, R. (2012). Improving PolSAR land cover classification with radiometric correction of the coherency matrix. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(3), 848-856.
- [4] Schwegmann, C. P., Kleynhans, W., & Salmon, B. P. (2015). Manifold adaptation for constant false alarm rate ship detection in South African oceans. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(7), 3329-3337.
- [5] Bentes, C., Velotto, D., & Tings, B. (2017). Ship classification in TerraSAR-X images with convolutional neural networks. *IEEE Journal of Oceanic Engineering*, 43(1), 258-266.
- [6] Bruschi, S., Lehner, S., Fritz, T., Soccorsi, M., Soloviev, A., & van Schie, B. (2010). Ship surveillance with TerraSAR-X. *IEEE transactions on geoscience and remote sensing*, 49(3), 1092-1103.
- [7] Schwegmann, C. P., Kleynhans, W., & Salmon, B. P. (2016). Synthetic aperture radar ship detection using Haar-like features. *IEEE Geoscience and Remote Sensing Letters*, 14(2), 154-158.
- [8] Crisp, D. J. (2004). The state-of-the-art in ship detection in synthetic aperture radar imagery. Defence Science And Technology Organisation Salisbury (Australia) Info Sciences Lab.
- [9] Small, D., Miranda, N., & Meier, E. (2009, July). A revised radiometric normalisation standard for SAR. In 2009 IEEE International Geoscience and Remote Sensing Symposium (Vol. 4, pp. IV-566). IEEE.
- [10] Small, D., & Schubert, A. (2008). Guide to ASAR geocoding. ESA-ESRIN Technical Note RSL-ASAR-GC-AD, 1, 36.
- [11] Filipponi, F. (2019). Sentinel-1 GRD preprocessing workflow. In *Multidisciplinary Digital Publishing Institute Proceedings* (Vol. 18, No. 1, p. 11).
- [12] Gao, Y., Guan, C., Sun, J., & Xie, L. (2020). Tropical Cyclone Wind Speed Retrieval from Dual-Polarization Sentinel-1 EW Mode Products. *Journal of Atmospheric and Oceanic Technology*, 37(9), 1713-1724.

- [13] <http://step.esa.int/docs/tutorials/S1TBX%20SAR%20Basics%20Tutorial.pdf>
- [14] <https://sentinel.esa.int/documents/247904/0/Sentinel-1-masking-no-value-pixels-grd-products-note/32f11e6f-68b1-4f0a-869b-8d09f80e6788>
- [15] <https://forum.step.esa.int/t/remove-grd-border-noise-does-not-seem-to-be-working/4693>
- [16] <https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm>
- [17] https://en.wikipedia.org/wiki/Connected-component_labeling