

整合深度學習與資料整合技術於地表變遷偵測

陳聿新¹ 朱宏杰^{2*}

摘要

本研究探討深度學習模型於地表變遷增益損失偵測之應用，採用雙時期影像(bi-temporal image)為輸入，透過端對端架構直接分析變遷前後之差異。研究主要以 Densely Attentive Refinement Network (DARNet) 模型為基礎，發展多類別辨識模型架構，並引入統計匹配與超解析技術以提升不同來源影像(Landsat 與 Sentinel-2)間的一致性。以海岸線變遷為案例，評估比較多種深度學習變遷偵測模型於多類別地景變化資料集的偵測表現，分析不同模型架構於變遷類別識別能力、邊界判釋精度與整體分類效果的差異，作為後續模型選用與改良之依據。研究結果顯示多分類 DARNet 結合資料整合技術於細尺度地物變遷上具優勢，考量超解析處理與統計匹配能提升模型精度與泛化性，有助於變遷偵測之實務效能。

關鍵詞：衛星影像、深度學習模型、增益損失、變遷偵測

1. 緒論

1.1 研究動機

地表變遷監測長期以來是遙測領域的重要研究課題(Zhu *et al.*, 2022)，尤其面對氣候變遷、都市擴張、自然災害與人為干擾等因素所導致地景快速變化，如何透過有效方法掌握環境變遷情形，進而提供決策支持，是學術與實務界共同關注的議題。衛星遙測技術因具備大範圍、定期更新、多光譜與高時間解析度等特性，使其成為觀測地表環境的關鍵工具。特別是雙時態影像(bi-temporal imagery)於變遷偵測中的應用(Zhang *et al.*, 2020)，可有效捕捉某區域於不同時間點的變異性，對於短期災後分析與長期環境監測皆具高度應用價值。然而，在實際應用中，雙時態影像常會遇到第一時刻影像缺失或品質不佳的問題，原因可能來自雲霧遮蔽、資料儲存不全、衛星重訪頻率低等限制。此外，隨著多源衛星影像的取得變得更加便利，不同解析度影像的整合與應用也成為研究焦點。例如，Landsat 與 Sentinel-2 影像在解析度、光譜涵蓋與重訪頻率上各

具優勢，若能有效結合並克服解析度不一致問題，將可進一步提升變遷偵測的時效性與空間精度。因此，本研究針對雙時態變遷偵測中面臨的兩大實務挑戰：第一為由二分類延伸至多分類的類別推估，第二為多解析度影像間的融合應用，分別提出相應方法並驗證其可行性與效益，以強化深度學習模型於地景變遷監測上的應用潛力。

1.2 研究目的

本研究旨在探討深度學習技術於多類別地景變遷偵測任務中的應用潛力，特別針對實際應用中經常遭遇之資料取得不完整、影像解析度不一致等問題，提出具有可行性之模型設計與資料處理方法。透過多組實驗設計與比較分析，期望能建立一套兼具準確性與實務可行性的深度學習變遷偵測流程，提升地表變遷監測的效率與精度。具體而言，本研究目標可分為以下四項：第一，評估並比較多種深度學習變遷偵測模型於多類別地景變化資料集上的預測表現，選定最適合於本研究應用場景之模型架構。透過引進不同模型架構，分析其於變遷類別識別能力、邊界判釋精度與整體分類效果的差異，

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 115 年 01 月 07 日

修改日期：民國 115 年 02 月 09 日

接受日期：民國 115 年 07 月 01 日

作為後續模型選用與改良的依據；第二，將以雙時態影像為主要輸入來源之變遷偵測模型應用於海岸線中的多類別變遷辨識與分類任務，建立能同時偵測無變化與多類別變遷(如沙洲堆積與流失等)之模型訓練架構，以驗證深度學習技術於多樣性變遷任務中的可行性與適用性；第三，針對多解析度影像的整合與應用進行深入探討，分別使用 Landsat 8 與 Sentinel-2 衛星影像作為雙時態輸入來源，比較不同解析度影像對模型預測結果之影響。此外，應用深度學習超解析模型提升 Landsat 8 影像之空間解析度，並透過統計匹配方法調整光譜分佈(Heo & FitzHugh, 2000)，減少不同資料源之光譜差異對模型判釋造成的影響，提升資料一致性與分類精度；第四，提供具備實務操作參考價值的變遷偵測資料處理流程與模型輸入設計方案，並驗證其於實際案例場域(如海岸線變遷)中的應用成效，以利未來地景變遷監測作業之推廣與應用。

本研究透過比較多種變遷偵測深度學習模型，選出最適合的模型架構。並在多類別與多解析度影像等實務情況下，對模型進行相對應的調整並分析模型的表現。

- (1) 多類別推估：由原先常見二分類(目標變化與不變化)延伸至多分類，將目標與非目標的無變化與增加或損失等變遷過程更細緻的呈現出來。
- (2) 結合多解析度影像應用：考量 Landsat 8 與 Sentinel-2 衛星影像在光譜涵蓋、空間解析度與資料取得頻率等層面的差異，設計跨解析度資料整合實驗，探討不同來源影像作為模型輸入時的預測差異與潛在誤差來源。並進一步應用深度學習超解析技術提升 Landsat 8 影像解析度，並輔以統計匹配方法修正其光譜分布，使其更趨近於 Sentinel-2 影像的特性，以強化資料一致性與預測精度，促進多源資料的互補整合應用。

2. 文獻回顧

2.1 變遷偵測技術發展概述

遙測變遷偵測技術自 20 世紀中葉以來持續演

進，從早期的影像目視解譯逐步轉向自動化的數位分類與演算法判釋，逐漸發展出各種適應不同應用需求與資料特性的方法(Tewkesbury *et al.*, 2015)。變遷偵測的核心目標在於透過分析多時期影像資料，辨識地表土地覆蓋類別於不同時間點的差異，藉此推估土地使用變遷、自然災害影響、生態環境變化等動態現象。為改善傳統像素為基礎方法(pixel-based approach)易受影像雜訊干擾的問題，Blaschke (2010)推廣物件導向影像分析(Object-Based Image Analysis, OBIA)，透過分割操作將影像切分為具有光譜與空間一致性的區塊，並結合紋理、形狀等空間特徵進行分類與變遷判釋。此類方法在高解析度影像中具備更佳的解析能力，但亦受限於分割參數設定敏感度與分類特徵挑選的主觀性。在處理時間序列資料方面，Verbesselt *et al.* (2010)提出 Breaks For Additive Season and Trend (BFASST)方法，能夠在影像時間序列中偵測趨勢變化與突變事件，進而廣泛應用於森林監測與長期變遷偵測上。隨著遙測影像資料的數量與光譜空間維度持續增加，傳統方法逐漸難以因應龐大且異質的資料結構，在影像分類與變遷判釋上表現出處理效率與精度的侷限。因此，深度學習逐漸成為變遷偵測技術發展的重要方向，不僅具備端對端訓練能力，亦能自動學習具有高度語意與空間脈絡的影像特徵，提升模型對地景變遷的辨識靈敏度與泛化能力。

2.2 長期變遷偵測

衛星影像因具備大範圍、週期性與多光譜觀測的特性，長期以來被廣泛應用於地表環境監測與地貌變遷分析，成為遙測研究與實務應用中最重要的資料來源之一。藉由多時期影像的整合與比較，可有效掌握土地利用變化、水體分布動態、都市擴張進程以及生態環境變異，進而作為環境治理、風險評估與資源管理的重要依據。Li & Gong(2016)利用 Landsat 影像進行西佛羅里達州泥濘海岸的變遷動態監測，採用穩健指標來表示動態海岸線的年平均位置，透過像素的每年淹水面積來代替傳統的線性海岸線表示方法，並利用所提出的模型估算每年海岸像素的淹水面積，研究進一步使用統計模型對時

間序列淹水面積的長期趨勢進行分析，其結果證明了使用時間序列 Landsat 資料進行連續海岸線動態監測的可行性。另一種應用方式為 Aman & Chu (2023)利用 Landsat 影像與多尺度時序分析，提出一個結合像素級水頻率與時間趨勢的框架來監測河川地貌的長期變化，並應用於湄公河與恆河流域之案例研究中，結果顯示該框架能有效捕捉河川範圍的細微變化，並具備高度的時空精度。Bishop-Taylor *et al.* (2021)利用長期 Landsat 影像，並結合次像素水線提取技術與基於像素的潮汐建模方法，繪製澳洲海岸線的長期變遷狀況，結果顯示該方法能將長期的海岸變化率在大陸尺度上得到準確的量化。由上述研究得知 Landsat 影像適合觀察長期的變遷動態觀測，並提供本研究有關於 Landsat 影像在變遷偵測上的應用。

2.3 深度學習模型於變遷偵測

近年來，隨著遙測影像解析度提升與計算資源進步，深度學習技術逐漸成為地表變遷偵測研究中的主流方法。相較於傳統以指標差異或影像分類為基礎的變遷分析方法，深度學習模型具有更強大的特徵擷取與空間語意理解能力(LeCun *et al.*, 2015)，能自動從大規模資料中學習影像之時序與語意變化，特別適合處理高解析度與多來源的雙時態影像資料。

目前多數變遷偵測模型採用雙分支結構作為基礎設計，分別處理變遷前(T1)與變遷後(T2)的影像，透過共享或非共享的權重提取特徵，再進行差異分析與變遷區域判別。以本研究改良的 Densely Attentive Refinement Network (DARNet)為例(Li *et al.*, 2022)，其架構奠基於 UNet 框架，並結合多尺度殘差模組與注意力機制，有效提升模型對於邊界與小面積變遷區域的解析度，適用於如沙洲演替、崩塌生成等細部變化的辨識任務。在其他典型模型中，不同設計重點也展現出各自優勢，例如 Deeply Supervised Image Fusion Network (DSIFN) (Zhang *et al.*, 2020)結合特徵差異建模與注意力強化策略，特別注重變遷區域內外特徵差異的對比性學習；而其引入多層監督機制，能使誤差訊號有效回傳至網路

深層，進一步強化模型對多尺度特徵的掌握。類似的概念亦可見於 Spatial Relationship Concerned Network (SRCNet) (Chen *et al.*, 2024)，此模型強調影像中空間關係的連續性與一致性，並設計互動模組加強時序間對應位置的感知能力，提升模型於空間結構變化之判別準確性，特別適用於建物、道路等具明顯空間形態的變遷分析。另有學者針對災害前後環境變遷，提出將時間序列建模與空間語意融合納入變遷偵測流程的架構，例如 MDPrePost-Net (Jamaluddin *et al.*, 2021)融合了時間特徵(透過 ConvLSTM)與空間特徵(透過多尺度卷積模組)的聯合學習，能有效捕捉短期劇烈地景變動，並產出多分類變遷圖。該方法特別強調模型對於局部災損區域的敏感性，並應用於紅樹林退化或颱風影響範圍之描繪，顯示深度網路在處理突發性環境變遷資料上的潛力。

總體而言，深度學習於變遷偵測中的應用已從早期的分類輔助工具，發展兼具時間、空間與語意資訊解析能力的綜合性架構。根據研究目標與資料特性之不同，模型可彈性整合多種模組與監督策略，發展出具針對性與泛化性的解決方案，未來亦可持續拓展至多時期、多來源與多尺度的地景變遷監測任務中。

3. 研究方法與資料

圖 1 為本研究流程圖。本研究整體流程可分為五階段，依序為資料建置、資料前處理、模型訓練、模型評估與結果分析。資料建置目的是彙整與建立適用於海岸線的多類別變遷偵測之衛星影像資料集，包括 Landsat 與 Sentinel-2 兩種不同影像來源的資料集。資料前處理為依據模型需求進行裁切(影像大小：256×256 pixels)，針對解析度不同的影像進行重採樣處理。此外，針對 Landsat 8 影像應用超解析模型提升其解析度，並透過統計匹配修正光譜分布，以縮小與 Sentinel-2 影像之間的光譜差異，以確保多源影像的融合預測比較。模型訓練為在先讓多組不同的深度學習架構進行訓練與比較後，以 DARNet 為本研究改良重點，進行多類別推估以及

多解析度影像等實驗。為客觀評估不同模型與不同輸入情境下之分類效能，模型評估採用整體準確率 (Overall Accuracy, OA)、F1 Score、交集比 (Intersection over Union, IoU) 與 Kappa 係數等指標評估模型效能，其中 F1 Score 與 IoU 特別針對變遷類別(如沙洲堆積與流失)進行計算，以表示模型於微小變化區域之辨識能力。結果分析為透過視覺化輸出與量化指標綜合評估不同實驗組別，檢驗多類別推估與多解析度融合方法在實務應用中的優劣與潛力。

3.1 資料集與前處理

本研究為探討地表海岸線於多時間尺度下之變遷狀況，建立一套涵蓋多時期與多解析度的海岸線變遷資料集，作為深度學習變遷偵測模型之訓練與驗證依據。此資料集內含兩種不同來源之衛星影像，分別為美國之 Landsat 衛星系列與歐洲哥白尼計畫之 Sentinel-2 衛星，兩組不同資料橫跨時間範圍分別為 1990 年至 2024 年與 2019 年至 2024 年，區域為臺灣沿海地區之最大沙洲外傘頂洲、曾文溪口與珠江三角洲之羅門沙島，具備高度代表性與分析潛力。

3.1.1 Landsat 影像資料集與前處理

本研究採用之影像資料來源為 Landsat 5 及 Landsat 8 第二代產品(Collection 2)中品質較高的 Tier 1 類別，其屬於 Level 2 處理層級，已完成大氣與幾何校正，能提供地表反射率(Surface Reflectance, SR)及地表溫度(Surface Temperature, ST)等重要參數。這些影像具有高度空間定位精度，並適合用於多時期影像的比較與分析。本研究透過 Google Earth Engine(GEE)平台將從 1990 年至 2024 年的 Landsat 5 及 Landsat 8 年合成影像(陳聿新等，2025a)與常態化差異水體指標(Normalized Difference Water Index, NDWI)(McFeeters, 1996)影像下載下來。NDWI 指標的計算方式如下：

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

其中 Green 為綠光、NIR 為近紅外光。Landsat 5 及 Landsat 8 年合成影像皆包含藍光、綠光、紅光、近紅外光、短波紅外光 1、短波紅外光 2 等 6 個波段，而 NDWI 影像則使用 Otsu 法(Liao *et al.*, 2001)轉換成二值化影像，Otsu 法是常見的影像分割技術，它能使組間變異最大(組內變異最小)，來自動選擇一閾值(陳聿新等，2025b)，接著再將不同年份的二值化影像相互進行判斷產製出水體不變、非水體不變、水體增加與水體減少共四分類的標籤。

3.1.2 Sentinel-2 影像資料集與前處理

本研究採用之 Sentinel-2 衛星影像資料，經資料處理單位標準化後，屬於已完成大氣校正與地形校正之 Level 2A 層級產品，具備地表反射率資訊、高時間解析度與空間解析度。影像經過去雲與遮蔽處理，適合用於不同時期影像間的疊合分析與變遷判釋。本研究透過 GEE 平台將從 2019 年至 2024 年的 Sentinel-2 年合成影像與 NDWI 影像下載下來。Sentinel-2 年合成影像同樣取對應 Landsat 資料集的 6 個波段，包含藍光、綠光、紅光、近紅外光、短波紅外光 1、短波紅外光 2 等波段且各波段解析度統一輸出為 10 m，標籤製作方式與前述 Landsat 影像資料集相同，最後會產製出水體不變、非水體不變、水體增加與水體減少共四分類的標籤。表 1 為 Landsat 影像資料集與 Sentinel-2 影像資料集的數據比較。

表 1 Landsat 影像資料集與 Sentinel-2 影像資料集比較

	Landsat 影像 資料集	Sentinel-2 影像 資料集
波段	6 波段	12 波段，本研究 取對應 Landsat 之 6 波段
影像類型	年合成影像	年合成影像
空間解析度	30 m	10 m
影像年份	1990-2024	2019-2024
影像張數	1740 張	360 張
影像大小	256×256 pixels	256×256 pixels




圖 1 研究流程圖

3.2 變遷偵測模型

深度學習模型近年廣泛應用於遙測影像的變遷偵測領域，其具備自動學習高階特徵的能力，能有效克服傳統方法需人工設計特徵所帶來的侷限。在本研究中，深度學習模型可透過大量已標記的時序影像資料進行訓練，自動提取空間與光譜資訊中潛藏的變化模式。與傳統基於物件或像素的分類方法相比，深度模型更能掌握複雜的非線性關係與多尺度特徵結構。常見的應用架構如卷積神經網路或編碼器－解碼器(Encoder-Decoder)結構，可用於像素層級的語意分割與變遷區域的提取。透過模型訓練與驗證，能進一步評估其在不同地區或資料條件

下的泛化能力與變遷偵測準確度，並與其他模型進行比較分析，找出最適合的遙測變遷偵測策略。

3.2.1 DARNet 與 Multiclass DARNet

在本研究中，改良源自於 DARNet (Li *et al.*, 2022)作為主要的變遷偵測模型，該模型屬於典型的編碼器－解碼器架構，並於原始設計中整合多尺度特徵抽取、時空注意力機制與逐層細化預測模組，展現了在遙測影像變遷偵測任務中的高度辨識能力。DARNet 主要由三大模組構成：特徵編碼器、特徵解碼器與遞迴式細化模組 (Recurrent Refinement Module, RRM)，並輔以密集跳接模組 (Dense Skip Connection Module, DSCM)與混合注意

力模組(Hybrid Attention Module, HAM)，以提升模型對時空變遷的表徵能力與分類精度。

在編碼器部分，DARNet 採用對稱式的孿生卷積神經網路(Siamese CNN)，用以從雙時態影像中分別抽取多層次特徵。每一個子網路由五個卷積區塊組成，分別對應不同解析尺度的特徵輸出，其通道數由淺至深分別為 16、32、64、128 與 256。每一區塊皆由兩組 3×3 卷積、Batch Normalization 與 ReLU 激活層組成，並於區塊之間插入最大池化層以進行特徵降維與提取。透過孿生架構，模型可確保兩個時間點的特徵在相同空間尺度下進行有效對齊與比對。

為了能充分整合來自不同尺度與時間的影像特徵，DARNet 導入 DSCM 模組，該模組不僅保留 UNet 架構中原有的高低層特徵串接，並進一步將來自不同層級的特徵統一重採樣至相同解析度後整合，使模型得以兼具語意抽象與空間細節，進而提升變遷區域的定位與邊界判別能力。緊接著，混合注意力模組(HAM)將多尺度特徵輸入進行空間、時間、通道三維度的非區域性注意力建模。該模組由空間時間注意力模組(Efficient Spatial-Temporal Attention Module, ESTAM)與通道注意力模組(Channel Attention Module, CAM)組成，前者可捕捉像素間的時空依存關係，而後者則強化與變遷相關的通道特徵，並抑制背景與非關聯特徵的干擾。在解碼器階段，模型會逐層融合來自編碼器與 HAM 輸出的多層次特徵，並搭配遞迴式細化模組 RRM 將初步的粗略預測不斷修正為空間解析度更高的變遷圖。每一層細化單元皆接收上一層預測圖與當前特徵圖，進行融合與重新判別，最終輸出一系列從低解析至高解析的變遷結果圖。為確保每一層輸出皆具監督訊號，DARNet 採用深度監督機制(Deep Supervision)，於每一階段輸出皆計算損失函數，並依不同階段加權後共同參與模型訓練。

本研究針對原始 DARNet 進行若干調整，以使其更適用於本研究所需之「四分類變遷偵測任務」。不同於原始設計中僅區分「變遷」與「未變遷」的二元分類模式，本文將變遷情形細分為四類，藉由標註類別間的轉換關係，進一步提升變遷偵測的解

析能力。四類標籤分別為類別 A 不變，表示地物類別維持不變，例如非目標地物持續存在；類別 B 不變，代表目標類別(如沙洲)在兩時態間皆存在，無發生變化；類別 A 變為類別 B，對應於目標地物的新出現，例如沙洲新堆積；以及類別 B 變為類別 A，則表示目標地物遭移除或消退，例如沙洲流失。此種四分類設定較傳統的二分類(變與不變)更具描述力與應用彈性，可依不同研究對象靈活調整標註邏輯，涵蓋多樣地景變遷的樣態。在模型訓練階段，四分類標籤不僅提供更豐富的語意資訊，有助於模型學習類別轉換的細節特徵，亦可針對特定類型變遷進行針對性評估與解析，有效提升變遷偵測任務的實務應用價值。

為因應多類別分類需求，本研究將原本設計為二分類損失的目標函數，改採多分類下的混合損失函數。具體而言，本文整合了交叉熵損失(Cross Entropy Loss)與多類別 Dice 損失(Multiclass Dice Loss)，構成混合型目標函數，以平衡類別不均與提升邊界精度為目標。交叉熵損失可有效處理多類別分類任務中各類別之預測偏差，Dice 損失則透過測量預測圖與標籤圖之重疊程度，有效緩解資料集中各類別樣本數不均所造成的偏差，尤其能強化邊界處的預測能力。綜合兩者優勢可大幅提升整體分類準確率與空間判別性能。改良後 DARNet 多分類模型架構如圖 2 所示。

3.2.2 其他模型

為驗證本研究所提出之多分類變遷偵測模型的效能，本文選用三種具有代表性的現有架構作為對照模型，分別為 DSIFN、SRCNet 與 MDPrePostNet。

DSIFN (Zhang *et al.*, 2020)為一種基於雙時態影像融合的變遷偵測架構，透過共享參數的深層特徵擷取網路對變遷前後影像進行多尺度特徵提取，並利用差異判別模組融合兩時態的語意特徵。為強化模型對變遷區域的辨識能力，DSIFN 引入通道與空間注意力機制，進一步聚焦於重要變遷資訊；同時，搭配多層監督策略，有助於改善梯度消失問題並提升訓練穩定性。




圖 2 改良後 DARNet 多分類模型架構圖

SRCNet (Chen *et al.*, 2024)強調雙時態影像間的空間結構關係，設計了感知與互動模組(Perception and Interaction Module, PIM)以及塊模式聯合特徵融合模組(Patch-mode Joint Feature Fusion Module, PJFFM)，前者可強化影像間的對應關係感知能力，後者則透過局部區塊方式進行細緻特徵融合，避免傳統融合方式可能造成的資訊損失。整體架構強調在特徵抽取與融合階段持續保留與強化影像間的空間一致性，有助於提升模型對變遷細節的識別能力。

MDPrePost-Net(Jamaluddin *et al.*, 2021)專為災前災後紅樹林環境監測任務設計，結合時間序列特徵與空間光譜資訊進行分類。其核心由兩部分組成：前後時序特徵擷取模組利用 ConvLSTM 結構捕捉時間差異，輔以 Inception 模組加強災後影像中細節變化的辨識能力；全卷積分類模組則以 UNet 為基礎架構，保留空間解析度並結合語意資訊，最終產出災前災後環境變遷的分類結果。此模型特別適合用於分析颶風等極端事件後的環境變遷情境。綜上所述，三種模型皆具備處理雙時態遙測影像的能力，

且各自針對特徵提取、注意力機制、時間序列處理等方面有所著墨，為本研究提出之模型提供關鍵的比較參考依據，所有模型訓練超參數如表 2 所示。

表 2 模型訓練超參數

Model	Learning Rate	Batch Size	Epoch
DARNet	1e-5	2	50
DSIFN	1e-5	2	50
SRCNet	1e-5	2	100
MDPrePost-Net	1e-4	2	100

3.3 多解析度影像

本研究針對實際應用中常見之衛星影像解析度不一致問題，進行多解析度影像之應用測試與方法設計。由於時序變遷模型多仰賴雙時態影像作為輸入資料，若在某時間點缺乏與訓練資料解析度相符之影像，則需考量是否可透過解析度轉換來替代使用。為探討此一問題對模型預測能力之影響，本研究以已使用 Sentinel-2 衛星影像所訓練之變遷模型為基礎，設計一系列輸入資料為不同解析度 Landsat 8 影像之替代實驗。此實驗架構分別採用重採樣處理與超解析度模型(Super Resolution)兩種方

法來處理解析度落差，並將結果與原始 Sentinel-2 影像進行比較分析，以評估不同解析度影像對預測準確性之影響及可行性。

3.3.1 重採樣

為使 Landsat 8 影像能作為 Sentinel-2 的替代輸入，並與既有模型維持相同的輸入維度與空間尺度，本研究在 GEE 平台中對原始 Landsat 8 Level2 產品進行重採樣處理。Landsat 8 原始影像波段解析度為 30 m，僅少數全色或熱紅外波段達 15 或 100 m，為提升空間一致性，本研究選取與 Sentinel-2 相對應之六個多光譜波段(藍光、綠光、紅光、近紅外光、短波紅外光 1、短波紅外光 2)，並透過最近鄰插值法將其統一重採樣至 10 m 解析度。重採樣後之 Landsat 8 影像具有與 Sentinel-2 相同的空間分辨率與波段數量，並可直接作為模型輸入用於推論階段。該處理方式雖無提升實際空間細節，但可確保模型接收影像格式與解析度一致之資料，避免模型因輸入維度差異而無法運作。

3.3.2 超解析深度學習模型

除了重採樣處理外，許多研究以深度學習提升衛星影像之解析度(Wang *et al.*, 2022)，本研究亦嘗試以深度學習方式提升 Landsat 8 衛星影像之解析

度，藉此接近 Sentinel-2 所提供之高解析度品質。本研究採用一套預訓練之超解析度模型，採用以 UNet 為基礎之全卷積神經網路，並結合 Landsat 8 之多光譜與高解析度全色影像作為輸入，進行影像重建與空間細節增強。

首先，超解析模型將問題形式化為影像退化模型的逆向學習問題，即視 Landsat 8 影像為經由某種退化函數對 Sentinel-2 影像進行空間與光譜轉換後所得之結果。為了反推此退化過程，模型透過學習一組深度神經網路參數，實現從低解析 Landsat 8 影像重建出高解析且光譜一致之 Sentinel-2 對應影像。超解析模型架構如圖 3 所示，本研究採用的預訓練之超解析模型為 Sambandham *et al.* (2024) 釋出之深度為五層的模型，在網路架構方面，核心採用經典 UNet 結構，具備編碼器與解碼器對稱配置，並透過跳接連結保留多尺度特徵。輸入資料由經雙三次插值(bicubic interpolation)放大後的 Landsat 8 多光譜影像與其全色影像組成，並經過通道串接後送入編碼器。解碼器端則依照不同設計選擇三種上採樣方式：「Up + Conv」即先上採樣後卷積、「Shuffle」為通道擴張後進行子像素卷積、「Conv Transpose」則為轉置卷積操作。實驗結果顯示「Up + Conv」與「Shuffle」兩種方式能有效提升重建影像品質，而「Conv Transpose」則因產生方格狀偽影而不被採納。




圖 3 超解析模型架構圖 (改繪於 Sambandham *et al.*, 2024)

此模型可自動重建較為細緻之紋理與邊界資訊，並將原始 30 m 解析度之 Landsat 8 影像升級至 10 m 解析度。透過此方式生成之高解析度 Landsat 8 影像，不僅在空間維度上達到與 Sentinel-2 相當，亦具備部分光譜與紋理細節的增強效果，有助於模型辨識地物變遷邊界與微小區塊。然而，須特別注意的是，超解析模型所生成之細節屬於推估結果，並非原始觀測資訊，因此仍需搭配後續分析驗證其影像特性與模型預測效能。

3.3.3 統計匹配

在多源影像整合應用中，資料的一致性為深度學習模型能否有效進行特徵學習與分類判釋的關鍵因素之一。由於不同衛星平台具備不同的感測器響應特性、光譜配置與輻射校正方法，即使觀測同一地區、同一時間，所產製之影像在光譜分佈與數值尺度上仍可能出現顯著差異。此種異質性將直接影響模型對跨來源影像的辨識與推論能力，亦可能造成特定地物類別在一個來源影像中表現穩定、但在另一來源中呈現偏移甚至錯誤分類的現象。

為解決上述問題，本研究對超解析處理後之 Landsat 8 影像進行統計匹配處理，透過統計匹配將超解析處理後之 Landsat 8 影像的光譜分佈進行調整，使其更趨近於 Sentinel-2 影像的光譜特性，進而提升變遷偵測模型於異質影像資料上的泛化能力與預測穩定性。統計匹配的執行流程如圖 4 所示。首先，對來源與目標影像進行波段標準化處理，將每個波段的像素值轉換至 0 到 1 的範圍，以消除不

同影像間原始像素數值尺度的差異。標準化方法為最小最大正規化，即每個波段的像素值以該波段內最小值與最大值進行線性縮放。對 Sentinel-2 影像進行標準化後，計算每個波段的平均值與標準差，作為統計匹配的目標特徵。這些統計值用以引導來源影像的分佈調整，使其能在標準化空間中模擬出與 Sentinel-2 影像一致的分佈特性。本研究採用迭代法，在標準化空間中對每個來源影像波段進行平均值與標準差的調整。具體作法為將每個來源波段視為一個常態分佈，使用 z score 標準化後，再依據目標平均與標準差進行重新縮放。本研究與學者 (Heo & FitzHugh, 2000、Du *et al.*, 2002) 所提出之相對輻射正規化具有相同目的，旨在降低影像間由感測器與觀測條件造成之輻射差異；然而，本研究以全域統計分佈進行匹配(標準化處理是針對所有影像，且來源影像與目標影像涵蓋相同的時/空間範圍)，而非考量擬不變特徵(Pseudo-Invariant Features, PIF)樣本。當所有波段於標準化空間完成統計匹配後，以 GeoTIFF 格式輸出標準化的匹配後的影像。

3.4 驗證方法

為全面評估本研究之深度學習變遷偵測模型於多類別地物變遷任務中的預測效能，特設計一套包含混淆矩陣與多項常用分類評估指標之驗證方法。該方法除考量整體分類表現(如整體準確度、Kappa 係數)，亦針對變遷類別進行強化，特別計算變遷類別(如沙洲流失與堆積等)之 F1 Score 與 IoU，以強化模型對細微變遷區域之解析能力的評估。




圖 4 統計匹配流程圖

3.4.1混淆矩陣(Confusion Matrix)

混淆矩陣是一種基本且直觀的分類驗證工具，主要用於記錄實際類別與模型預測結果之對應關係，並可延伸出多項性能指標。針對本研究處理之四分類問題，混淆矩陣結構如表 3 所示。對應類別說明如下，以沙洲流失與堆積舉例，類別 0 為無變化類(第一時刻與第二時刻皆為沙洲的區域)；類別 1 為無變化類(第一時刻與第二時刻皆為水體的區域)；類別 2 為沙洲變為水體的區域，即沙洲流失；類別 3 為水體變為沙洲的區域，即沙洲堆積。

表 3 四分類混淆矩陣示意表

真實\預測	類別 0	類別 1	類別 2	類別 3
類別 0	n_{00}	n_{01}	n_{02}	n_{03}
類別 1	n_{10}	n_{11}	n_{12}	n_{13}
類別 2	n_{20}	n_{21}	n_{22}	n_{23}
類別 3	n_{30}	n_{31}	n_{32}	n_{33}

其中 n_{ij} 代表實際為類別 i 而被預測為類別 j 的像素數量。該矩陣可延伸計算出多項整體與類別層級之分類指標。

3.4.2評估指標

為精準反映模型於多類別變遷偵測上的表現，本研究針對四分類情境設計多項評估指標，涵蓋整體準確度(OA)、Kappa 係數、F1 Score 及 IoU 等。其中，F1 Score 與 IoU 為針對變遷類別(類別 2 與類別 3)之區別能力進行加權計算，以更貼近實際應用中變遷識別的需求。整體準確度為所有正確分類像素占總像素數量的比例，計算公式如下：

$$OA = \frac{n_{00} + n_{11} + n_{22} + n_{33}}{N_{total}} \quad (2)$$

其中 N_{total} 為總像素數量。

Kappa 係數可用來衡量分類結果與隨機分類之差異程度，其計算公式如下：

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (3)$$

其中 p_o 表示觀察到的準確率，即 OA； p_e 表示期望隨機一致率，計算如下：

$$p_e = \frac{\sum_{i=0}^3 (\sum_j n_{ij})(\sum_j n_{ji})}{N_{total}^2} \quad (4)$$

F1 Score 為一種綜合考量精確率(Precision)與召回率(Recall)的指標，能有效衡量模型在特定類別上的分類性能，特別是在資料不均衡的情境下依然具有良好代表性。若模型對某類別的精確率或召回率偏低，F1 Score 會顯著下降，呈現模型在該類別的不足之處。若需計算每一類別的 F1 Score，需先定義精確率和召回率，其公式如下：

$$Precision_i = \frac{n_{ii}}{\sum_j n_{ji}} \quad (5)$$

$$Recall_i = \frac{n_{ii}}{\sum_j n_{ij}} \quad (6)$$

每一類別的 F1 Score 為：

$$F1_i = \frac{2 \cdot Precision_i \cdot Recall_i}{Precision_i + Recall_i} \quad (7)$$

總 F1 Score 可採用平均方式：

$$F1_{mean} = \frac{1}{4} \sum_{i=0}^3 F1_i \quad (8)$$

IoU 則是衡量預測區與實際區之重疊程度的空間指標，代表模型預測區塊與真實區塊的交集與聯集比例。IoU 值越高，表示模型在空間邊界上的判斷越準確，對於遙測應用中特別重視邊界精準度的任務(如沙洲流失與堆積等)具高度參考價值。

每一類別 IoU 的計算方式為：

$$IoU_i = \frac{n_{ii}}{\sum_j n_{ij} + \sum_j n_{ji} - n_{ii}} \quad (9)$$

總 IoU 可採用平均方式：

$$IoU_{mean} = \frac{1}{4} \sum_{i=0}^3 IoU_i \quad (10)$$

由於本研究重點在於探討變遷區(即類別 2 與 3)之預測準確性，因此針對這兩類設計，將類別 2 與類別 3 統一視為變遷區，其他類別(0 與 1)視為非變遷區，精確率和召回率定義如下：

$$Precision_i = \frac{\sum_{i=2}^3 n_{ii}}{\sum_{i=2}^3 \sum_j n_{ji}} \quad (11)$$

$$Recall_i = \frac{\sum_{i=2}^3 n_{ii}}{\sum_{i=0}^3 \sum_{j=2}^3 n_{ij}} \quad (12)$$

針對變遷類別的 F1 Score 為：

$$F1_{change} = \frac{2 \cdot Precision_i \cdot Recall_i}{Precision_i + Recall_i} \dots \dots \dots (13)$$

針對變遷 IoU 的計算方式為：

$$IoU_{change} = \frac{\sum_{i=2}^3 \sum_{j=0}^3 n_{ij}}{\sum_{i=0}^3 \sum_{j=2}^3 n_{ij} - \sum_{i=2}^3 \sum_{j=2}^3 n_{ij}} \dots \dots \dots (14)$$

本研究所採評估方式兼顧整體準確度與變遷類別之精細辨識能力，能有效掌握模型在多類別變遷偵測任務下之實用性與敏感度。相較傳統以整體分類為核心之評估架構，本方法針對實際地景變遷監測之應用需求，提出精細化之評估設計，特別強調模型於變遷區域的辨識能力，並可反映不同類別間混淆所帶來的影響，對於日後模型改良與應用策略制定，提供具體且量化之參考依據。

4. 研究成果分析

4.1 模型比較-海岸線變遷分析

為評估所提深度學習方法於實際遙測應用中的表現，本研究以海岸線變遷偵測作為主要應用場景，選取自建之海岸線資料集進行實驗，並分別於四種具代表性的時序影像變遷偵測模型上進行訓練與比較，包括：DARNet、DSIFN、SRCNet 與 MDPrePost-Net。此比較實驗旨在探討各模型於處理四分類變遷任務下的準確性、空間判釋能力與泛化能力，並藉此驗證所提出方法的實用性與穩定性。

為確保實驗結果的公平性與代表性，所有模型皆以相同的資料與分割方式進行訓練與測試。海岸線資料集 (大小：256×256 pixels) 依 8：1：1 的比例劃分為訓練集、驗證集與測試集，並確保各時態、各類別分布盡可能均衡。所有模型皆以雙時態 Landsat 合成影像作為輸入，輸入波段包含藍光、綠光、紅光、近紅外光、短波紅外光 1、短波紅外光 2 等 6 個波段，輸出則為四分類的預測結果圖。使用的標籤採用四分類策略進行地物變遷定義。黑色為在第一時刻與第二時刻皆為水體的區域、白色為第一時刻與第二時刻皆為陸地的區域、紅色為第一時刻為陸地但第二時刻為水體的區域(代表沙洲流失)、

綠色為第一時刻為水體但第二時刻為陸地的區域(代表沙洲新堆積)。此四分類設計可更清楚揭示海岸線動態變遷的空間位置與方向性，並優於傳統的二分類方法(僅判定變與不變)，使模型能針對不同型態的變遷進行細部判別與分析。

圖 5 顯示各模型於外傘頂洲測試資料上之預測結果，由 a 至 g 分別為第一時刻 RGB 影像、第二時刻 RGB 影像、海岸線變遷的四分類標籤圖(c)，以及 DSIFN、SRCNet、DARNet、MDPrePost-Net 四個模型之預測結果。由圖中可觀察到，DARNet 在沙洲變遷區域(紅色與綠色區域)的邊界判定最為準確，能清晰地對應至實際沙洲消失與新堆積位置。相較之下，DSIFN 與 SRCNet 在小區域沙洲堆積的偵測上略顯保守，部分新生成的沙洲區塊未能正確預測；而 MDPrePost-Net 表現雖亦穩定，但在邊界處仍有模糊現象。

為量化各模型在海岸線變遷任務中的表現，本研究採用四項常見分割評估指標包含 OA、F1 Score、IoU、Kappa，其中 F1 與 IoU 指標特別針對變遷類別(沙洲流失與沙洲堆積)進行計算，以評估模型對小區塊變化區之敏感度與區分能力。各個海岸線變遷模型的表現如表 4 所示。

表 4 海岸線變遷各模型評估指標比較

Method	OA (%)	F1	IoU	Kappa
DSIFN	99.04	0.9392	0.8863	0.9928
SRCNet	98.67	0.9123	0.8454	0.9900
DARNet	99.55	0.9716	0.9447	0.9966
MDPrePost-Net	99.51	0.9690	0.9402	0.9963

由表 4 得知 DARNet 在所有評估指標上皆為表現最優，尤其於 F1 Score 與 IoU 指標上領先幅度顯著，顯示其於沙洲變遷區的分類能力優於其他模型。而 MDPrePost-Net 亦具高度準確性，其結合預先與後處理結構，對整體分類穩定性有所貢獻，但在邊界處仍略遜於 DARNet。在視覺結果與數值評估雙重佐證下，DARNet 為最適用於本研究資料與任務需求之模型。

本研究亦將訓練完成的 DARNet 模型應用至羅門沙地區之影像進行推論測試(圖 6)。羅門沙島位於中國廣東省珠江口西岸海域，地處珠海市香洲區與

中山市南部之間，屬於珠江三角洲外緣的沿海沙洲島嶼。由結果可知，模型能成功辨識沙洲於時序影像間的明顯變化，明確標示出堆積與流失的空間區位，顯示其具有良好的泛化能力與實務應用潛力。

在多時期變遷預測方面，亦可將已訓練完成之 DARNet 模型，針對不同時間點的影像進行兩兩配對並推估變遷結果。圖 7 為 DARNet 在多時期的羅門沙地區預測三組前後不同時期(1990~2007、2007~2023、1990~2023)結果，由左至右分別為第一時刻、第二時刻、模型的預測結果。圖 7a 至 c 三組第一時刻分別為 1990 年、2007 年、1990 年，第二

時刻 a 至 c 三組分別為 2007 年、2023 年、2023 年。三組前後不同時期(1990~2007、2007~2023、1990~2023)的預測結果顯示，DARNet 在三組不同時期的組合皆能將沙洲的流失與堆積預測出來。

此外，從 a 至 c 三組預測結果亦可觀察到羅門沙地區在過去三十年間沙洲的整體變遷趨勢：原本分布於東北與西南兩端的沙洲逐漸向中央集中，反映出沙洲動態變遷過程的空間特徵。上述結果顯示，DARNet 不僅可應用於單一時間區間之變遷監測，亦具備處理長期變遷分析的潛力，對於地貌變遷追蹤與環境監測應用具有參考價值。




圖 5 外傘頂洲海岸線變遷各模型預測結果比較圖 (a)第一時刻的 RGB 影像、(b)第二時刻的 RGB 影像、(c)海岸線變遷的四分類標籤圖，以及 (d) DSIFN、(e) SRCNet、(f) DARNet、(g) MDPrePost-Net 四個模型之預測結果



圖 6 羅門沙變遷 DARNet 預測圖：黑色為在第一與第二時刻皆為水體的區域、白色為第一與第二時刻皆為陸地的區域、紅色為第一時刻為陸地但第二時刻為水體的區域(代表沙洲流失)、綠色為第一時刻為水體但第二時刻為陸地的區域(代表沙洲新堆積)




圖 7 羅門沙多時期變遷 DARNet 預測圖 (a)第一時刻為 1990 年、第二時刻為 2007 年的組別，(b)第一時刻為 2007 年、第二時刻為 2023 年的組別，(c)第一時刻為 1990 年、第二時刻為 2023 年的組別

4.2 海岸線變遷分析-Sentinel-2 資料集

在先前的實驗中，本研究以 Landsat 5 及 Landsat 8 所構建之海岸線四分類資料集作為主要研究對象，針對沙洲變遷類別進行多模型比較與效能驗證。雖然 Landsat 系列影像具有良好之時序延續性與光譜資訊，但其空間解析度受限於 30 m，在辨識小尺度沙洲變遷區塊或細緻邊界時，可能存在模糊或不完整的情況。

為進一步驗證所使用之深度學習模型在高解析度資料條件下的表現差異與適應能力，並探討解析度提升對變遷辨識準確性的影響，本研究另外建置一組以 Sentinel-2 衛星影像為基礎的海岸線變遷資料集。Sentinel-2 擁有最高 10 m 的空間解析度，並涵蓋可見光、近紅外光、短波紅外光等多個光譜波段，能提供比 Landsat 更細緻的地物紋理與空間細節，有助於提升模型對地表細微變化的辨識能力。

本實驗採用多分類的 DARNet 模型進行訓練與測試。資料集依 8:1:1 的比例劃分為訓練集、驗證集與測試集，模型的輸入一樣包含藍光、綠光、紅光、近紅外光、短波紅外光 1、短波紅外光 2 等 6 個波段，且所有波段在 GEE 平台上進行重採樣處理後解析度統一為 10 m 作為輸入，輸出則為與標籤對應的四分類預測圖。圖 8 顯示 DARNet 經過訓練後在測試資料上的預測結果，由 a 至 d 依序為第一時刻的 RGB 影像、第二時刻的 RGB 影像、海岸線變遷的四分類標籤圖、DARNet 的預測結果。從圖 8 中可觀察到，模型能成功辨識主要沙洲變遷區域，並對邊界區塊進行較為精細的判斷。然而，在特定變遷類別上仍存在預測偏差，顯示即便輸入解析度提升，仍可能受限於類別光譜混淆與樣本分佈不均等問題。

DARNet 模型於測試資料的 OA(%)、F1 Score、IoU、Kappa 等各項分類評估指標分別為 95.56%、0.8929、0.8078、0.9702，從整體指標來看，DARNet 在高解析度影像下依然維持良好的分類表現。特別是 F1 與 IoU 指標，雖較使用 Landsat 資料時略為下

降，但仍達可接受水準，顯示模型具備相當的穩定性與泛化能力。Kappa 值亦達 0.97，代表預測結果與標籤間具有高度一致性。

進一步觀察模型於不同類別間之分類誤差情形，可發現在沙洲流失的部分，模型偶有將實際不變的沙洲區錯誤分類為流失區；在沙洲堆積類別中，模型預測偏差更為明顯，部分區域將原本不變的沙洲誤判為新堆積區，或漏判實際發生堆積之區域。此現象顯示，即使使用空間解析度較高的 Sentinel-2 資料，若模型本身對變遷區特徵抽取未具足夠區辨性，仍可能發生誤判或漏判。因此，在處理高解析影像時，模型不僅需具備較深的網路結構與更強的空間學習能力，也需搭配適當的資料增強、類別平衡或語意引導機制，以提升對複雜地貌變遷的判斷精度。儘管如此，從整體結果而言，DARNet 模型於四個變遷類別上皆能產生合理預測，並具備穩定的區域分類能力。其結合殘差連接與遞進式預測策略，有助於強化空間與語意特徵融合，即使僅有雙時態輸入，亦可維持良好之變遷表示效果。

4.3 海岸線變遷分析-多解析度影像

以雙時態影像為輸入的模型，若遇到前一時刻無同一解析度的影像，可否使用其他解析度的影像來替代並預測？本研究以使用 Sentinel-2 海岸線資料集訓練好的變遷模型來測試此一情況，原本海岸線資料集的 Sentinel-2 影像包含藍光、綠光、紅光、近紅外光、短波紅外光 1、短波紅外光 2 等共 6 個波段，本研究在 GEE 平台上將原本 Sentinel-2 影像的 6 個波段，以 Landsat 8 相對應之 6 個波段替換掉，最後在 GEE 平台上統一重採樣輸出成解析度為 10 m 的 Landsat 影像。本研究另外以能提升 Landsat 8 衛星影像解析度之深度學習模型，進一步將 Landsat 8 影像之解析度提升後同樣讓模型進行預測，該深度學習模型能提升 Landsat 8 影像之解析度，使其更接近 Sentinel-2 影像的品質。而在找尋合適的海岸線變遷地點時，觀測到曾文溪口地區，在 2019 年至 2024 年間有明顯的沙洲新堆積與沙洲流失變化，因此選擇此地點為測試區域。




圖 8 外傘頂洲海岸線變遷 DARNet 預測圖(Sentinel-2 資料集) (a)第一時刻的 RGB 影像、(b)第二時刻的 RGB 影像、(c)海岸線變遷的四分類標籤圖、(d) DARNet 的預測結果

圖 9 為海岸線變遷模型的曾文溪口預測結果，由左至右分別為第一時刻(2019 年)的 RGB 影像、第二時刻(2024 年)的 RGB 影像、模型的預測結果。a 組為第一時刻與第二時刻皆使用 Sentinel-2 影像的組別，b 組為第一時刻使用 Landsat 8 影像、第二時刻使用 Sentinel-2 影像的組別，c 組為第一時刻使用經過深度學習模型提升解析度之 Landsat 8 影像，第二時刻使用 Sentinel-2 影像的組別。由圖 9 可看出 a 組的結果表現最佳，模型能夠準確捕捉沙洲的新堆積與流失區域，顯示在訓練與推論階段使用相同來源(Sentinel-2)資料時，模型的預測能力最為穩定。b 組的結果略遜於 a 組，儘管第一時刻的影像來源被替換為解析度匹配後的 Landsat 8 影像，模型仍能辨識出大部分沙洲的變遷，但可見在流失區域的邊緣出現部分錯誤預測。c 組的表現則不如 b 組，尤其在沙洲新生區域的附近，模型出現許多沙洲流失的錯誤預測，顯示經過深度學習模型提升解度之 Landsat 8 影像，即便解析度有所提升，但受到的影響反而比直接使用 Landsat 8 影像還大，使模型對變遷的敏感性降低。經由圖 9 中 a 至 c 之結果，可觀察到雖然 Landsat 8 影像在經過深度學習模型提升解析度後，雖然相較於原本的 Landsat 8 影像更為清晰，但在將其使用於模型預測變遷方面，則會出現許多錯誤預測。理論上來說 Landsat 8 影像在提升解析度後，使用在模型上應該會預測的不錯，但經過本研究將 Sentinel-2 影像、Landsat 8 影像及深度學習模型提升解析度之 Landsat 8 影像的各個波段，在標準化至 0 到 1 的範圍後，計算這些波段的平均值與標準差並觀察，各波段統計值如表 5 所示。

從表 5 可發現，經由深度學習模型提升解析度之 Landsat 8 影像在短波紅外光 1 與短波紅外光 2

的波段上，能明顯看出提升解析度後的 Landsat 8 影像相較於原本的 Landsat 8 影像與 Sentinel-2 影像的波段統計值相差更多。為使提升解析度後的 Landsat 8 影像與 Sentinel-2 影像具備一致的光譜特性，本研究針對這兩張影像進行統計匹配處理，將提升解析度後的 Landsat 8 影像光譜分佈調整為與 Sentinel-2 影像相近，以降低不同來源資料造成的光譜不一致問題，提高變遷模型於多解析度影像上的泛化能力與分類一致性。

本次實驗以圖 9 區域之第一時刻為例，將經過深度學習模型提升解析度之 Landsat 8 影像作為來源影像，並以 Sentinel-2 影像作為匹配目標。圖 9 中的 d 組為第一時刻進行統計匹配後的組別，由此預測結果可看出，在經過統計匹配後，模型的預測結果有顯著的改善。原先 c 組在沙洲新堆積區域的附近有許多地方出現沙洲流失的錯誤預測，而 d 組的結果則能排除 c 組原本關於沙洲流失的錯誤預測，整體預測也與 a 組較為貼近。綜合本研究於多解析度影像實驗之結果可知，經過統計匹配處理的提升解析度之 Landsat 8 影像，確實能在一定程度上改善模型預測表現，特別是在消除誤判沙洲流失區域方面，相較於未經統計匹配者，預測結果顯得更為接近實際變遷情形。然而，與原始 Sentinel-2 影像(a 組)及重採樣的 Landsat 8 影像(b 組)相比，統計匹配後的高解析度 Landsat 8 影像(d 組)預測結果仍存在一定誤差，顯示若其光譜特性與訓練資料仍存差異，可能影響模型對變遷類別的正確判斷。因此，在應用不同解析度或經過處理的衛星影像進行時序變遷偵測時，仍應審慎評估其與訓練資料在空間與光譜層面的差異性，並視情況進行額外調整與優化，以確保模型推論的準確性與穩定性。




圖 9 曾文溪口區域預測結果比較圖 (a)第一與第二時刻皆使用 Sentinel-2 影像，(b)第一時刻使用 Landsat 8 影像、第二時刻使用 Sentinel-2 影像，(c)第一時刻使用經過深度學習模型提升解析度之 Landsat 8 影像，第二時刻使用 Sentinel-2 影像，(d)第一時刻使用經過深度學習模型提升解析度之 Landsat 8 影像並考量統計匹配，第二時刻使用 Sentinel-2 影像

表 5 第一時刻各影像波段統計值表

Band	Sentinel-2	Landsat 8	Landsat 8 enhance
Blue-Mean	0.211915	0.213621	0.299420
Blue-Std	0.066849	0.161918	0.077704
Green-Mean	0.192156	0.242270	0.265192
Green-Std	0.080115	0.142934	0.081880
Red-Mean	0.105049	0.199971	0.203327
Red-Std	0.104132	0.175523	0.083281
NIR-Mean	0.073730	0.118756	0.120166
NIR-Std	0.139256	0.159504	0.133996
SWIR1-Mean	0.063003	0.085972	0.111305
SWIR1-Std	0.150744	0.146387	0.130027
SWIR2-Mean	0.056335	0.075592	0.091340
SWIR2- Std	0.134421	0.134430	0.115087

5. 結論與研究限制

本研究以深度學習變遷偵測模型及多源衛星影像融合為核心，建立一套應用於多類別地景變遷任務的分類架構，針對不同時期與來源的遙測資料進行整合處理與系統性分析，涵蓋海岸線變遷等主題，比較多種深度學習變遷偵測模型，並結合多來源、多解析度之衛星影像資料進行系統性評估。本

研究根據實驗結果與模型評估，提出以下結論與研究限制，最後提出未來研究建議。

- (1) 多類別 DARNet 變遷偵測任務中具穩定之表現：本研究評估比較多種深度學習變遷偵測模型於多類別變遷資料集上的預測表現，證明將原始 DARNet 的損失函數修改為能因應多類別的 CE + Dice 損失函數組合，而多類別變遷偵測相較於原先的二分類，能將目標變化與不變化更清

楚的分類，以目標不變、非目標不變、目標增加與目標損失等類別呈現，實驗結果顯示，相較於其他模型，多分類 DARNet 表現更佳，且在變遷任務中(如沙洲流失與堆積)展現良好的空間判別能力。

- (2) 統計匹配提升異質影像間之光譜一致性，增進融合應用穩定性：面對多源(Landsat 與 Sentinel-2)與多解析度影像所造成的光譜不一致問題，本研究透過統計匹配處理流程，將超解析後之 Landsat 8 影像光譜調整為與 Sentinel-2 影像相近。處理後模型預測結果顯示，統計匹配有效減少因光譜分布差異造成的分類偏誤與邊界雜訊，提升整體模型泛化能力。
- (3) 模型具備跨時期預測能力，可應用於地景演替分析：本研究進一步將訓練完成之多分類 DARNet 模型應用於外傘頂洲及羅門沙地區進行多時期影像推論實驗，結果顯示模型能有效辨識長時間尺度下沙洲堆積與流失之空間變遷趨勢，具備一定的時間泛化能力。此能力可應用於地貌演替研究、歷史變遷重建與環境監測中，顯示深度學習架構在長期序列影像應用中之潛力。

儘管本研究在模型應用及調整與資料整合方面取得具體成果，仍有以下幾項限制：

- (1) 資料品質受雲層與季節性變異影響：雖然本研究透過 GEE 平台進行年合成與雲遮蔽處理，惟 Landsat 與 Sentinel-2 影像仍可能因雲影、水氣等干擾，導致部分區域資料不連續或異常，進而影響模型學習效果與預測準確性。
- (2) 變遷標籤產製倚賴自動閾值法：本研究標籤主要仰賴 NDWI 指標配合 Otsu 法進行分類，缺乏人工標記輔助，使得部分邊界模糊區域或複雜變遷類型可能存在誤分類情形，影響模型評估的準確性與公平性。
- (3) 異質資料整合仍受限於感測器差異與幾何校正誤差：儘管本研究已導入統計匹配與超解析技術，仍無法完全克服來自不同感測器(如光譜響應、幾何偏移等)所造成的資料差異，部分測試場景仍可觀察到模型預測出現偏移或錯誤定位。

為進一步強化模型於實務應用中之適應能力與推廣性，未來可朝以下方向發展：

- (1) 引入主動式遙測資料以補足光學影像限制：本研究現階段模型訓練與推論皆使用光學衛星影像，易受雲層遮蔽與日照條件限制。未來可考慮整合 SAR(合成孔徑雷達)等主動式遙測資料，其不受氣候與光照影響，能與光學影像形成互補，進一步提升模型在多天候條件下的應用穩健性。
- (2) 改善標籤製作方式以提高訓練資料品質：本研究標籤使用 Otsu 法自動分類與 NDWI 指標產製，雖具效率但仍可能對複雜地景邊界判釋不足。未來可採用半自動標註流程，結合自動分類初標與人工修正方式，以提升標籤邊界之準確度與變遷類別之代表性，進而改善模型訓練成效。
- (3) Batch size 調整：本研究在現階段模型訓練時，Batch size 設定為 2，雖能獲得不錯的訓練結果，但未來可嘗試採用更高效能的計算設備，或透過適度縮小影像輸入尺寸，將 Batch size 提升至 16、32 等較大數值。較大的 Batch size 有助於模型在訓練過程中獲得更具代表性的批次統計資訊，降低由小批次樣本所造成的梯度波動。此外，較大的 Batch size 不僅有助於提升梯度估計的穩定性，亦可減少每個 epoch 所需的參數更新次數，因此在硬體資源允許的情況下，能有效提升訓練效率。

參考文獻

- 陳聿新、朱宏杰、盧韋勳，2025a。以衛星大數據觀察長期國土變遷-以外傘頂洲為例，國土測繪與空間資訊，13(2)：215-226。[Chen, Y.X., Chu, H.J., and Lu, W.S., 2005a. Observing long-term territorial changes through spatial big data: A case study of Waisanding sand bar, Taiwan Journal of Geoinformatics, 13(2): 215-226. (in Chinese)]
- 陳聿新、簡浩丞、朱宏杰，2025b。海岸線自動偵測與 AI 模型，航測及遙測學刊，30(2)：73-83，DOI：10.6574/JPRS.202506_30(2).0001。[Chen,

- Y.X., Chien, H.C., and Chu, H.J., 2025b. Coastline automatic detection and AI model, *Journal of Photogrammetry and Remote Sensing*, 30(2): 73-83, DOI:10.6574/JPRS.202506_30(2).0001 (in Chinese)]
- Aman, M.A., and Chu, H.J., 2023. Long-term river extent dynamics and transition detection using remote sensing: Case studies of Mekong and Ganga River, *Science of the Total Environment*, 876: 162774, DOI:10.1016/j.scitotenv.2023.162774.
- Bishop-Taylor, R., Nanson, R., Sagar, S., and Lymburner, L., 2021. Mapping Australia's dynamic coastline at Mean Sea level using three decades of Landsat imagery, *Remote Sensing of Environment*, 267: 112734, DOI:10.1016/j.rse.2021.112734.
- Blaschke, T., 2010. Object based image analysis for remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16, DOI:10.1016/j.isprsjprs.2009.06.004.
- Chen, H., Xu, X., and Pu, F., 2024. SRC-Net: Bi-temporal spatial relationship concerned network for change detection, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 11339-11351, DOI:10.1109/JSTARS.2024.3411622.
- Du, Y., Teillet, P.M., and Cihlar, J., 2002. Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection, *Remote Sensing of Environment*, 82(1): 123-134, DOI:10.1016/S0034-4257(02)00029-9.
- Heo, J., and FitzHugh, T.W., 2000. A standardized radiometric normalization method for change detection using remotely sensed imagery, *Photogrammetric Engineering and Remote Sensing*, 66(2): 173-181.
- Jamaluddin, I., Thaipsisutikul, T., Chen, Y.N., Chuang, C.H., and Hu, C.L., 2021. MDPrePost-Net: A spatial-spectral-temporal fully convolutional network for mapping of mangrove degradation affected by Hurricane Irma 2017 using Sentinel-2 data, *Remote Sensing*, 13(24): 5042, DOI:10.3390/rs13245042.
- LeCun, Y., Bengio, Y., and Hinton, G., 2015. Deep learning, *Nature*, 521(7553): 436-444, DOI:10.1038/nature14539.
- Li, W., and Gong, P., 2016. Continuous monitoring of coastline dynamics in western Florida with a 30-year time series of Landsat imagery, *Remote Sensing of Environment*, 179: 196-209, DOI:10.1016/j.rse.2016.03.031.
- Li, Z., Yan, C., Sun, Y., and Xin, Q., 2022. A densely attentive refinement network for change detection based on very-high-resolution bitemporal remote sensing images, *IEEE Transactions on Geoscience and Remote Sensing*, 60: 4409818, DOI:10.1109/TGRS.2022.3159544.
- Liao, P.S., Chen, T.S., and Chung, P.C., 2001. A fast algorithm for multilevel thresholding, *Journal of Information Science and Engineering*, 17(5): 713-727, DOI:10.6688/JISE.2001.17.5.1.
- 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.
- Samandham, V.T., Kirchheim, K., Ortmeier, F., and Mukhopadhyaya, S., 2024. Deep learning-based harmonization and super-resolution of Landsat-8 and Sentinel-2 images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 212: 274-288, DOI:10.1016/j.isprsjprs.2024.04.026.
- Tewkesbury, A.P., Comber, A.J., Tate, N.J., Lamb, A., and Fisher, P.F., 2015. A critical synthesis of remotely sensed optical image change detection

- techniques, *Remote Sensing of Environment*, 160: 1-14, DOI:10.1016/j.rse.2015.01.006.
- Verbesselt, J., Hyndman, R., Newnham, G., and Culvenor, D., 2010. Detecting trend and seasonal changes in satellite image time series, *Remote Sensing of Environment*, 114(1): 106-115, DOI:10.1016/j.rse.2009.08.014.
- Wang, P., Bayram, B., and Sertel, E., 2022. A comprehensive review on deep learning based remote sensing image super-resolution methods, *Earth-Science Reviews*, 232: 104110, DOI:10.1016/j.earscirev.2022.104110.
- Zhang, C., Yue, P., Tapete, D., Jiang, L., Shangguan, B., Huang, L., and Liu, G., 2020. A deeply supervised image fusion network for change detection in high resolution bi-temporal remote sensing images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 166: 183-200, DOI:10.1016/j.isprsjprs.2020.06.003.
- Zhu, Z., Qiu, S., and Ye, S., 2022. Remote sensing of land change: A multifaceted perspective, *Remote Sensing of Environment*, 282: 113266, DOI:10.1016/j.rse.2022.113266.

Leveraging Deep Learning and Data Integration Techniques for Land Surface Change Detection

Yu-Xin Chen¹ Hone-Jay Chu^{2*}

Abstract

This study investigates the application of deep learning models for gain–loss detection in land surface change using bi-temporal satellite imagery. An end-to-end framework is adopted to directly capture semantic and spectral differences between pre- and post-change images. The proposed approach is based on the Densely Attentive Refinement Network (DARNet) and extends it to a multi-class change detection architecture. To improve consistency between multi-source imagery, including Landsat and Sentinel-2, statistical matching and super-resolution techniques are incorporated into the preprocessing workflow. Coastal change detection is selected as the case study to evaluate and compare the performance of several state-of-the-art deep learning models on a multi-class land-cover change dataset. The analysis focuses on class discrimination capability, boundary delineation accuracy, and overall classification performance to provide guidance for future model selection and development. Experimental results demonstrate that the multi-class DARNet integrated with statistical matching and super-resolution achieves superior performance in detecting fine-scale land changes. Furthermore, the proposed data integration strategy enhances both model accuracy and generalization, indicating its strong potential for practical applications in land change detection.

Keywords: Satellite Imagery, Deep Learning, Gain and Loss, Change Detection

¹ Master, Department of Geomatics, National Cheng Kung University

² Professor, Department of Geomatics, National Cheng Kung University

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

Received Date: Jan. 07, 2026

Revised Date: Feb. 09, 2026

Accepted Date: Jul. 01, 2026