

國立臺灣師範大學文學院地理學系

博士論文

Department of Geography

College of Liberal Arts

National Taiwan Normal University

Doctoral Dissertation

六龜人工林與崩塌地干擾對森林長期動態影響之研究

A Study on the Long-Term Forest Dynamics Affected by
Plantations and Landslide Disturbances in Lioukuei

王韻皓

Wang, Uen-Hao

指導教授：廖學誠 博士

Advisor : Liaw, Shyue-Cherng, Ph.D.

中華民國 114 年 7 月

July 2025

謝辭

人生真的是一場奇幻之旅，從未想過在知天命的 50 歲時會再次回到學校進修，然後在 54 歲時順利取得學位，完成人生重要的里程碑。回首這段大齡念書的過程，似乎時時刻刻都在考驗著我，甚至讀到懷疑人生，不僅是因為記憶力及體力的衰退，同時工作的重量、家庭的照顧，也瓜分著我有限的時間，我常常覺得一天 24 小時真的不夠用，挫折感及無力感伴隨著我的生活。這段時間能讓我堅持下去，真的要感謝我的指導教授-廖學誠老師，老師亦師亦父不斷的勉勵與督促，持續帶領我向前進，同時一直提醒我「四年要畢業、四年要畢業、四年要畢業」，洗腦式的口號讓我只能全神貫注的跟著老師的腳步，不斷前行，並且順利如期畢業。同時也特別感謝在我碩士進修時期，啟蒙我的焦國模老師、鄭祈全老師及陳永寬老師，您們當初給我打的底子，讓我經過了 25 年後，還是足以使用，我沒有讓老師們失望。另外感謝我中年轉換職場跑道後，林試所大家長曾彥學所長及張彬前所長給予進修的機會，並且持續地關懷鼓勵，還有謝漢欽組長與農航所管立豪前所長的不斷加油打氣，這些溫暖都陪伴著我度過艱辛的進修過程。最後為我論文提供許多專業建議的詹進發委員、陳宛君委員、王素芬委員、王聖鐸委員及莊永忠委員，您們的用心指導，不僅提升了我論文的品質，也讓我學習良多，收穫滿滿。

最後特別要感謝我的家人們，我親愛的媽媽、經常挑燈陪讀的兒子胤安及兩位貼心懂事的雙胞胎女兒詠優與詠樂，還有在我身後一直努力做家事，全心支持著我念博士的先生致善，家庭的支持給予了我無盡的力量，全力衝刺。也謝謝愛我的天主及那些默默為我祈禱的教堂朋友們。最後，我謹將這本論文獻給我在天上父親。

摘要

臺灣森林因地處颱風頻繁且地質脆弱之地區，長期面臨天然災害與人工林退化的雙重壓力，導致森林結構與功能產生劇烈變動。為掌握森林演替與災後復育之動態，本研究以六龜試驗林為研究區，結合多時期衛星影像、空載光達與地理資訊系統，運用邏輯迴歸 (Logistic Regression, LG)、隨機森林 (Random forest, RF) 與細胞自動機-馬可夫鏈 (Cellular automaton and Markov Chain, CA-Markov) 等模型，進行森林變遷與崩塌復育潛勢之時空分析與預測。

本研究首先探討臺灣杉人工林的自然演替變化與地理因子關聯，並建立全區臺灣杉人工林變化之邏輯迴歸與隨機森林預測模型。其後考量造林地區位差異，分別建立北鳳岡林區與南多納林區的分區模型，結果顯示分區模型能顯著提升預測準確性。其中 RF 模型準確率高達 94.8%與 97.8%，AUC 值分別為 0.988 與 0.998，研究成果顯示高程、雨量與距林道距離為主要影響因子。

在崩塌與復育長期監測方面，莫拉克颱風後六龜崩塌整體呈現劇烈減少、後趨穩定變化趨勢，崩塌地景破碎化指標，也呈現下降趨勢，且地景連續性增加，顯示結構穩定性提升。崩塌復育則發現在崩塌發生後初期階段復育速度較快，較後期更具恢復力。在模型建構方面，空間解析度經測試以 10 m 解析度表現較佳。在模型方法上，以隨機森林較邏輯迴歸表現較好。其中崩塌潛勢 RF 模型，分別在 2009-2017 與 2017 - 2024 兩個時段建置模型，其 AUC 值皆超過 0.950，準確度分別為 89%及 90%，模型表現極佳，主要影響因子為冠層結構指標、NDVI 與高程。崩塌復育 RF 模型 AUC 值則分別為 0.87 與 0.90，準確度為 77%與 83%，表現亦佳，關鍵因子為距崩塌邊緣距離、高程及坡度，顯示地形與種源供應為復育重要因素。

在未來土地覆蓋變化預測部份，首先利用 2009 年與 2017 年兩期土地覆蓋型變化資料及潛在影響因子，結合 RF 模型產生轉移機率圖，並整合 CA-Markov 模型，模擬預測 2024 年之土地覆蓋空間分布。預測結果與實際 2024 年土地覆蓋型進行比對，並與傳統僅使用 CA-Markov 模型的預測效能進行比較。結果顯示 RF-CA-Markov 模型準確率達 95.78%，Kappa 值 0.522，顯著優於傳統 CA-Markov 模型之準確率 (84.88%) 與 Kappa 值 (0.253)。

完成模型驗證後，進一步以 2017 年至 2024 年期間之土地覆蓋變化與驅動因

子進行 RF 模型訓練，重新產生轉移機率圖，並模擬 2031 年土地覆蓋變遷。模擬結果顯示，植生及崩塌地面積與 2024 年預測結果相近，未持續擴大，森林覆蓋趨於穩定，反映出災後崩塌與復育趨於穩定。

本研究證實整合多時期遙測資料與機器學習模型，可有效掌握森林演替與災害復育動態，提升崩塌潛勢與森林變遷預測能力。研究成果可提供森林經營與防災調適政策制定的量化依據，以促進森林資源之永續發展與生態系功能之長期穩定。

關鍵詞：空載光達、邏輯迴歸、隨機森林、細胞自動機、馬可夫鏈



A Study on the Long-Term Forest Dynamics Affected by Plantations and Landslide Disturbances in Lioukuei

Abstract

Taiwan's forest ecosystems, residing in a landscape highly susceptible to typhoons and geological instability, face the dual pressures of natural disasters and plantations degradation, leading to significant changes in forest structure and function. To understand the dynamics of forest succession and post-disaster recovery, this study focused on the Lioukuei Experimental Forest, integrating multi-temporal satellite imagery, airborne LiDAR, and Geographic Information Systems (GIS). Logistic regression, Random Forest (RF), and Cellular Automaton-Markov Chain (CA-Markov) models were applied to conduct spatiotemporal analysis and prediction of forest changes and landslide recovery potential.

This study first investigates the natural succession dynamics of *Taiwania cryptomerioides* plantations and their relationship with geographic factors, establishing logistic regression and random forest models to predict the spatial distribution of forest transitions across the entire study area. To account for spatial heterogeneity between afforestation sites, separate zonal models were developed for the northern Fenggang and southern Duona forest districts. Results indicated that zonal models significantly improved prediction accuracy, with RF models accuracies of 94.8% and 97.8%, and AUC values of 0.988 and 0.998, respectively. Key influencing factors identified were elevation, precipitation, and distance to forest roads.

In terms of long-term landslide and vegetation recovery monitoring, post-Typhoon Morakot landslide activity in the Lioukuei region showed a marked initial decline followed by stabilization. Landscape fragmentation indices also exhibited decreasing trends, while landscape connectivity increased, indicating improved structural stability. Vegetation recovery was observed to proceed more rapidly in the early stages following landslides, suggesting higher resilience during the initial recovery phase. Model development showed that a spatial resolution of 10 m provided the best performance. Among modeling approaches, RF outperformed logistic regression. For landslide susceptibility, RF models were developed for the 2009–2017 and 2017–2024 periods, AUC values above 0.950 and accuracies of 89% and 90%, respectively. Key variables

included canopy structure indices, NDVI, and elevation. For vegetation recovery modeling, RF models achieved AUC values of 0.87 and 0.90, with accuracies of 77% and 83%. The most influential variables were distance to landslide edge, elevation, and slope, indicating that terrain characteristics and seed source proximity are critical to recovery.

For future land cover change prediction, RF models were first trained using land cover transitions and driving factors from 2009 to 2017 to generate transition probability maps, which were integrated with the CA-Markov model to simulate land cover distribution in 2024. Comparison with actual 2024 land cover data and the traditional CA-Markov model revealed that the RF-CA-Markov model outperformed the latter, achieving an overall accuracy of 95.78% and a Kappa coefficient of 0.522, significantly higher than the CA-Markov model's 84.88% accuracy and 0.253 Kappa value.

Following model validation, land cover transitions and driving factors from 2017 to 2024 were used to retrain the RF model, enabling simulation of land cover changes in 2031. Results showed that forest and landslide areas in 2031 remained similar to the 2024 projections, indicating no significant expansion of landslide zones and suggesting that post-disturbance vegetation recovery and landscape stabilization had reached a relatively steady state.

This study confirms that integrating multi-temporal remote sensing data with machine learning models can effectively capture forest succession and disaster recovery dynamics, enhancing the predictive capability for landslide susceptibility and forest changes. The findings provide a quantitative basis for forest management and disaster adaptation policy, promoting the sustainable development of forest resources and the long-term stability of ecosystem functions.

Keywords: Airborne LiDAR 、 Logistic Regression 、 Random Forest 、 Cellular Automaton 、 Markov Chain.

目次

第一章 前言	1
第一節 研究背景與動機	1
第二節 研究目的	2
第二章 文獻回顧	3
第一節 森林干擾	3
第二節 地景生態	6
第三節 遙測與 GIS 技術之應用	6
第四節 預測模型應用	10
第三章 研究材料與方法	13
第一節 研究區域	13
第二節 研究材料	14
第三節 研究方法	18
第四章 結果與討論	37
第一節 臺灣杉人工林自然演替	37
第二節 崩塌復育	55
第三節 崩塌地景監測與潛勢評估	64
第四節 不同空間解析度崩塌潛勢預測比較	76
第五節 細胞自動機-馬可夫鏈與隨機森林預測模型	87
第五章 結論	106
參考文獻	112

表次

表 1 航照正射影像資訊	14
表 2 衛星影像日期與種類	16
表 3 臺灣杉造林地資訊	20
表 4 使用地景層級之地景指標	24
表 5 臺灣杉造林地變遷驅動因子	25
表 6 崩塌地自然復育驅動因子	26
表 7 崩塌潛勢驅動因子	27
表 8 坡向分類表	28
表 9 使用之坵塊地景指標	29
表 10 臺灣杉造林地 2020 年現況覆蓋型面積及百分比	37
表 11 臺灣杉造林地變遷變數相關分析結果	43
表 12 邏輯迴歸參數與係數	44
表 13 邏輯迴歸分類誤差矩陣	44
表 14 隨機森林分類誤差矩陣	46
表 15 北區臺灣杉造林地變遷變數相關分析結果	48
表 16 南區臺灣杉造林地變遷變數相關分析結果	48
表 17 北區邏輯迴歸參數與係數	49
表 18 南區邏輯迴歸參數與係數	49
表 19 南北區邏輯迴歸與隨機森林分類準確度比較	51
表 20 邏輯迴歸與隨機森林南北區非臺灣杉發生機率	53
表 21 北區 2020 年土地覆蓋型面積比較	53
表 22 空間自相關結果	58
表 23 崩塌復育模型變數相關分析結果	61
表 24 崩塌復育模型邏輯迴歸參數與係數	62
表 25 影像分類整體精度與 Kappa 值	67
表 26 崩塌潛勢模型變數相關分析結果	73

表 27	8 個自變數邏輯迴歸分析結果	74
表 28	4 個自變數邏輯迴歸分析結果	74
表 29	崩塌潛勢模型準確度評估	75
表 30	不同解析度邏輯迴歸模式變數之勝算比	79
表 31	不同解析度影響因子邏輯迴歸分析結果	80
表 32	不同解析度模型驗證準確度評估結果	84
表 33	臺灣杉造林地三個時期崩塌比率結果	90
表 34	2009 - 2017 年 Markov 轉移矩陣	92
表 35	2017 - 2024 年 Markov 轉移矩陣	93
表 36	兩個時段崩塌潛勢與崩塌復育隨機森林模型變數重要性分析結果	95
表 37	兩個時段崩塌潛勢與崩塌復育 RF 模型 ROC 及 AUC 值	96
表 38	兩個時段崩塌潛勢與崩塌復育隨機森林模型準確度評估	96
表 39	CA 模型迭代次數與模型精度結果	99
表 40	迭代次數折線圖比較表	99
表 41	2024 實際土地覆蓋與模型預測面積比較表	101

圖次

圖 1 六龜試驗林位置圖	14
圖 2 六龜試驗林崩塌地圖	15
圖 3 六龜試驗林造林台帳圖	17
圖 4 研究流程圖	18
圖 5 六龜試驗林臺灣杉人工造林地圖	20
圖 6 隨機森林集成示意圖	32
圖 7 造林地 2020 年臺灣杉與非臺灣杉分布圖	38
圖 8 高程因子	39
圖 9 坡度因子	39
圖 10 坡向因子	40
圖 11 林齡因子	40
圖 12 距造林地邊界因子	41
圖 13 距林道距離因子	41
圖 14 雨量因子	42
圖 15 溫度因子	42
圖 16 邏輯迴歸的 ROC 曲線	45
圖 17 邏輯迴歸模型全區預測圖	45
圖 18 全區模型隨機森林變數重要性	46
圖 19 分區模型隨機森林變數重要性	50
圖 20 邏輯迴歸與隨機森林 ROC 曲線與 AUC 值	52
圖 21 北區邏輯迴歸(左)與隨機森林(右)模型非臺灣杉發生機率分布圖	54
圖 22 南區邏輯迴歸(左)與隨機森林(右)模型非臺灣杉發生機率分布圖	54
圖 23 2010-2018 年崩塌與復育面積	56
圖 24 天然林與人工林內自然復育面積佔全區復育面積比較	57
圖 25 2010-2018 年崩塌地景指標折線圖	59
圖 26 崩塌復育模型 ROC 曲線與 AUC 面積	63
圖 27 六龜試驗林多時序土地覆蓋型圖	66

圖 28 扣除陰影聯集區域之多時序土地覆蓋型圖	68
圖 29 多時序崩塌面積變化折線圖	69
圖 30 多時序新增崩塌面積變化折線圖	69
圖 31 多時序崩塌地 6 種地景指標折線圖	71
圖 32 崩塌潛勢 ROC 曲線	75
圖 33 六龜試驗林兩時期土地覆蓋型圖	77
圖 34 六龜試驗林新增崩塌地分布圖	77
圖 35 不同解析度隨機森林模型變數重要性分析結果	82
圖 36 邏輯迴歸和隨機森林模型訓練結果 ROC 曲線及 AUC 值	83
圖 37 邏輯迴歸和隨機森林模型驗證結果之 ROC 曲線及 AUC 值	83
圖 38 邏輯迴歸模型在不同空間解析度崩塌潛勢預測機率分布圖	85
圖 39 隨機森林模型在不同空間解析度崩塌潛勢預測機率分布圖	86
圖 40 六龜試驗林三時期土地覆蓋型圖	88
圖 41 兩個時段植生與崩塌地面積(ha)增減圖	89
圖 42 造林地三時期崩塌比率直方圖	91
圖 43 造林地六-20-74-10 地號位置圖	91
圖 44 臺灣杉變化率 vs 崩塌減少率散點圖	92
圖 45 2009 - 2017 年崩塌潛勢(左圖)與復育(右圖)轉換機率圖	97
圖 46 2017 - 2024 年崩塌潛勢(左圖)與復育(右圖)轉換機率圖	97
圖 47 2024 年實際土地覆蓋型圖與預測成果圖	101
圖 48 2024 年土地覆蓋型圖與 RF-CA-Markov 模型預測結果疊合圖	102
圖 49 2031 年 RF-CA-Markov 模型預測成果圖	105

第一章 前言

第一節 研究背景與動機

森林生態系統具備有水土保持、氣候調節、碳吸存、生物多樣性維護及木材供應等多元功能，是維繫著山林穩定與林業發展的重要自然資源。然而，臺灣位處太平洋颱風路徑帶，地形陡峭且地質脆弱，儘管擁有超過 60% 的森林覆蓋率，卻也面臨極高的天然災害風險。隨著全球氣候變遷加劇，極端氣候事件如強降雨與高強度颱風日益頻繁，對山區森林造成極大的衝擊。2009 年莫拉克颱風即為代表性的案例，其在六龜地區造成單日降雨量高達 1200 mm，引發大規模山崩與土石流，對森林生態系統造成嚴重破壞。

此外，臺灣森林經營的歷史亦對當前森林狀況產生深遠的影響。過去以木材生產為導向的政策使得 1970 年代大量皆伐天然林，並廣泛推動人工造林，尤其以臺灣杉等經濟樹種為主。然而，1991 年起全面禁止天然林伐採，人工林砍伐亦逐漸停滯，撫育與更新等經營管理措施相繼中斷，導致林分進入被動放任生長狀態。隨時間推移，這些純林林分逐漸受到天然闊葉樹種入侵，林分健康與生產力下降，木材利用價值亦隨之衰退。人工林的演替與生態功能轉變，反映出過往單一經營目標與管理策略在現今多元目標下的挑戰。

因此，面對天然災害與人工林退化的雙重壓力，臺灣山區森林的結構與功能正經歷顯著的變動，為未來森林經營帶來高度的不確定性。天然災害造成大面積的崩塌，嚴重破壞森林地景結構，並降低了森林生態系的服務功能，但同時森林也會隨著時間自我療癒。因災害所造成的崩塌，隨著時間慢慢的復育，逐漸恢復植被覆蓋與生態功能；另一方面，人工林在現行經營策略下也面臨生長停滯、競爭壓力增加、樹種適應性不佳等問題。上述變遷過程在時間與空間上皆具高度複雜性，若缺乏長期、系統性的觀測與分析，將難以掌握干擾後森林發展的趨勢與潛在風險。尤其在面對氣候變遷加劇與森林多元功能需求日益提升的情況下，如何整合歷史資料與遙測先進技術，深入瞭解人工林與天然災害對森林演替與景觀變化的影響，將是永續森林經營的重要依據。

第二節 研究目的

本研究以六龜試驗林為研究區，主要因其不僅具早期人工造林的歷史，且經歷過 2009 年莫拉克颱風重大天然災害的擾動，為觀察天然災害後森林結構變遷與人工林自然演替的理想場域。為全面掌握森林結構與崩塌復育時空變化，本研究整合多時期衛星影像、空載光達資料與地理資訊系統分析技術，並運用邏輯迴歸、隨機森林、細胞自動機與馬可夫鏈等統計與機器學習模型，進行長期森林變遷與崩塌動態之量化分析與預測，主要研究目的如下：

一、 探討人工林自然演替與地理因子關聯

針對六龜試驗林臺灣杉人工林，分析在不同區位之生長狀況與天然闊葉林入侵程度，並結合地形、氣候與環境條件等變數，建構邏輯迴歸與隨機森林模型，評估不同地理環境條件下人工林的生長表現與潛在經營風險，作為未來林分撫育或管理策略的參考依據。

二、 分析崩塌地與復育之影響因子與時空分布趨勢

利用多時期衛星與空間分析方法，監測崩塌與復育區位變化，並建立邏輯迴歸與隨機森林模型，探討其潛在驅動因子及空間分布特性，分析其變遷趨勢與潛在風險分布。

三、 模擬未來森林結構變化趨勢

利用隨機森林模型建立土地覆蓋變動轉移機率圖，結合細胞自動機與馬可夫鏈模型，模擬六龜試驗林 2031 年的森林覆蓋分布，進行未來空間模擬與風險預測，提供森林經營規劃與災害調適策略的量化基礎。

綜上所述，本研究期望建構具有空間預測能力之整合模型，掌握森林變遷關鍵因子與演替機制，因應天然擾動與經營管理的挑戰，提出有助於災害調適與木材利用的經營參考依據。

第二章 文獻回顧

第一節 森林干擾

一、崩塌與復育

森林區域的崩塌現象不僅威脅生態系統的穩定性，也對地表植被造成了巨大的破壞 (Mi et al., 2019)，崩塌發生時常造成樹木大量死亡，土壤加速流失，導致生物量損失並改變水文與地形，對森林長期健康構成潛在威脅 (Dale et al., 2001; Dislich and Huth, 2012)。在健康的森林生態系統下，強大的樹根系統和樹木可明顯提升坡面的穩定性，降低崩塌的發生機率 (Moos et al., 2016)。相反地，當森林植被退化或消失時，將導致崩塌風險明顯提高 (Jamal and Mandal, 2016)。因此在高風險區域實施造林，可有效減少崩塌發生次數，達到減災的目的 (Bathurst et al., 2010)。隨著氣候異常頻繁發生，如何準確評估森林區域的崩塌潛勢，並將其納入森林經營管理與坡地防災規劃，是現在森林管理中的重要課題。崩塌潛勢預測是指研究區域內崩塌發生區位的可能性評估，亦即歷史崩塌地及其影響環境因子的綜合評估 (Huang et al., 2023)。近年來，遙感技術的發展使得取得崩塌地空間分布及相關影響因子變得更為有效且精準 (Akosah et al., 2024)，並且多使用遙測影像與地理資訊系統 (GIS) 進行空間分析 (Nhu et al., 2020b)。此外，隨著空載光達技術的發展，地形資料的解析度得到了顯著提升，高解析的地形資料輔助了高精度地形與水文因子的產生，也提供森林垂直結構變量等資訊，為崩塌潛勢預測提供了更精準且多面向的影響因素 (Dislich and Huth, 2012)。Jamal and Mandal (2016) 研究發現森林結構與崩塌發生機率密切相關：森林冠層密度降低的區域，其崩塌發生率明顯提高，Moos et al. (2016) 提出將森林結構變數納入崩塌潛勢評估，可明顯提高預測能力。因此本研究也引入了光達衍生的冠層結構指標，探究其對崩塌風險的潛在影響，期望透過森林冠層的異質性對地表穩定性的影響，全面地評估崩塌潛勢可能影響之因子。

森林生態系統經歷大規模林地崩落與地貌改變，隨著時間推移，森林會對這類擾動做出回應，受損的樹木可能死亡倒下，原有林冠的空隙則為新的先鋒樹種提供了生長空間，森林社會開始進入演替與復原過程 (Frolking et al., 2009)。在臺灣崩

塌區多以自然復育為主要途徑研究顯示，健康森林生態系統往往具備自我恢復能力(陳建帆等，2021)，然而森林的自然復原進程與干擾強度息息相關，干擾越強，森林恢復所需時間越長。多數受嚴重破壞的森林生態系統需要超過 40 年才能自然恢復(邱清安和徐憲生，2015)；在單座山的區域尺度上，樹木生物量的恢復大約需要 80 年，而要使崩塌後的森林結構與成熟林相似，則至少需要 200 年 (Dislich and Huth, 2012)。這些研究突顯了時間是森林復育的關鍵因素。空間異質性對於崩塌後的森林復育過程亦有顯著影響，因為在復育的過程中，會受到許多與空間位置相關的因素交互作用。例如，Zhang et al. (2014) 在研究汶川地震後的森林復育時發現，植被恢復主要發生在坡度和海拔適宜的區域，邱清安和徐憲生 (2015) 強調了林木種子的可獲得性對植被恢復的重要性，同樣，宋承恩等 (2022) 則指出坡向、海拔和種源距離是影響崩塌復育的重要因素，這些因素使得崩塌區的森林可能循不同的演替途徑，其恢復過程因時空異質性而有所不同 (Dislich and Huth, 2012)。因此要深入理解森林在干擾後的過程和驅動機制，長期監測森林干擾與復原的動態至關重要。透過持續收集和長期科學數據分析，可以追蹤森林景觀隨時間的變化及其驅動因素。這種長期監測不僅有助於了解森林生態系統在面對不同類型和強度干擾時的反應，而且對於制定有效的森林管理和保護策略也至關重要。

二、 人工林演替

臺灣早期伐採天然林後，常於伐採跡地進行造林，這類人工林的形成可視為由社會人為因素所驅動的景觀改變。許多研究指出，這些人工林在後續較少經營管理下，其景觀特徵會隨時間而逐漸改變。Brockerhoff et al. (2008) 認為人工林缺乏人為干預，將透過自然演替逐漸恢復天然林的元素，單一樹種構成的人工林會被因天然母樹的種子入侵與演替序列中的樹種競爭，而逐步轉變為混淆林。孟慶繁 (1998) 在黑龍江天然闊葉林皆伐跡地的落葉松人工林研究發現，林中物種 60% 與鄰近天然闊葉林相同；林文雄等 (2002) 進一步指出，人工林中的闊葉樹種的來源，一是來自外部林地經由多種傳播途徑進入，另一則是來自保留於地內的前生樹種種子自然萌芽。關於人工林演替的影響因子；汪大雄等 (2001) 指出，人工林的生長受到土壤、生物、地形、林木競爭及後續撫育等多重因子影響，這些因子使人工林的空間分布具高度變異性，且更易受周圍天然闊葉樹種的影響，導致人工林生長範圍

縮小；游漢明 (2003) 對柳杉人工林地的植群調查發現，臺灣原生闊葉樹可自然進入這些針葉人工純林中生長，而其生長狀況亦受到環境因子所影響。由此可知人工林區域距離天然林分布的空間距離，也是影響自然演替的重要因子之一。此外，許多研究也提出植物生長與環境因子的密切關連，如陳永寬等 (1998) 指出一植物在某生育地能否生存與繁衍，主要視其對當地環境的適應性而定；Kumar (2015) 則認為，坡向是山地生態系中影響日照量和地表降雨接收量的重要因子；顏添明 (1999) 亦提出，坡度及高程同樣是影響林木生長的重要環境因子。此外，氣候因子在驅動自然演替過程中扮演關鍵角色，Tuhkanen (1980) 指出氣候是決定生態系及植群類型與分布的主要環境因子，謝依達等 (2013) 亦指出氣象條件對林木生長具有不同程度的影響，甚至可能改變森林結構 (Pendry and Proctor, 1997; Aiba and Kitayama, 1999)。除了上述自然因子外，部份人為設施亦可能成演替的驅動因素，Pauchard and Alaback (2004) 指出，林道因為光線進入而改變森林冠層及底層的微氣候環境，進而影響森林冠層生物多樣性與土壤中種子庫的萌發潛力，而林道所產生的邊緣效應可能促使造林地中原生樹種的萌發與生長 (Turton and Siegenthaler, 2004)。因此，臺灣的人工林在缺乏長期經營管理的情況下，往往會受到環境與樹種競爭的影響，轉向自然演替的趨勢。

在臺灣人工造林的歷史中，臺灣杉 (*Taiwania cryptomerioides*) 佔了重要一席之地，因具有生長快、木理通直，加工性良好等特性，因此為臺灣重要的人工造林樹種之一。臺灣杉同時也是全球唯一以臺灣為屬名的植物，為臺灣特產之珍貴樹種，名列臺灣五木。與世界爺 (*Sequoiadendron giganteum*)、水杉 (*Metasequoia glyptostroboides*) 及銀杏 (*Ginkgo biloba*)，同為中生代與新生代第三紀之子遺植物 (中華林學會, 1995)。臺灣杉生長特性，多分布於 1,300 至 2,600 m 高度之間，尤以 2000 m 左右最盛 (陳永寬等, 1998)，性喜多濕與遮蔭，天然林多發現於東北及北北東等坡向，而不喜向陽的南向坡，生育氣候長年氣溫以 11 - 15°C，年降雨量以 3,000 mm 為最理想 (中華林學會, 1995)。惟其生態幅度不如部份先驅針葉樹種如臺灣二葉松及紅檜，在發育良好的森林中，常為紅檜及其他闊葉樹的競爭者排擠 (劉業經等, 1985)。本研究參考相關前人研究，探討臺灣杉人工林在不同環境條件下其生長表現，期能幫助掌握人工林自然演替的動態趨勢及潛在限制，以提供人工林經營之參考。

第二節 地景生態

地景生態學是研究地景單元的類型組成、空間配置及其生態學過程相互作用的綜合性學科，強調空間異質性和生態過程之間的動態關係 (鄔建國，2003; Ekwealor et al., 2019)，隨著學科的發展，也建立起可量化景觀型態的地景指標 (Griffith, 2002)，McGarigal et al. (2002) 研發出 Fragstats 軟體，為分析地景結構的軟體，可計算地景指標。這指標以遙測資料結合實地測量進行地理空間分析，並透過此軟體進行土地覆蓋的空間模式量，包括坵塊指標、類別指標和地景層級指標 (Chen and Iannone, 2020; Ojoyi et al., 2016)，這些指標有助於了解生態系統在組成與配置的變化 (Narmada et al., 2021)。早期有許多研究運用地景指標進行變遷監測，如鄭祈全 (1999) 應用 GIS 與地景結構指標探討砍伐和林道開闢對地景結構的影響；王素芬 (1999) 則透過碎形維度指標分析經營作業對地景的改變。Fynn and Campbell (2018) 研究發現城市擴張對自然森林生態系統和生物多樣性產生長期重大衝擊；Talukdar et al. (2021) 利用地景指標監測地景結構變化，發現景觀多樣性呈現下降趨勢。隨著分析技術進步，愈來愈多研究將地景指標應用於預測模型的建構，例如 Dezhkam et al. (2017) 以地景指標評估土地變遷模擬模型的效能；Cushman et al. (2017) 將地景指標納入森林損失率的預測中，提高了模型的準確性；Arora et al. (2021) 則結合地景指標和支持向量機 (Support Vector Machine, SVM) 分類技術，從 Landsat 衛星分類出土地覆蓋圖，並預測地景變遷。新興的森林管理強調需要整合社會與生態條件，理解這些條件與過程如何塑造跨越時空的景觀，以調整管理策略因應生態系統特徵的變遷 (De Aranzabal et al., 2008; Angelstam et al., 2013)。Fischer (2018) 更指出，近年來已有越來越多的實證研究記錄森林生態系與社會經濟變化及土地利用在時間與空間上的複雜互動。

第三節 遙測與 GIS 技術之應用

一、航遙測影像應用

自 1970 年代 Landsat 資源衛星首次升空以來，多光譜衛星影像已成為監測地表覆蓋變化的重要工具，特別是在臺灣地形崎嶇、森林區域多為人力難以深入之處，

考量人力、安全與經費等因素，大範圍森林資訊的獲取多仰賴航遙測技術。多數衛星載光學感測器具備可見光與近紅外光波段，部分衛星則有獲取短波紅外光波段或其他波段，大量研究已證實多光譜影像在地表覆蓋判釋上具有相當高的準確度 (Stefanov et al., 2001; Jamal and Mandal, 2016; Song et al., 2021; Ghayour et al., 2021; Basheer et al., 2022)。除了提供廣域地物資訊之外，遙測技術最重要的優勢在於能夠運用時間序列影像資料，進行動態監測，如 Cheng et al. (2024) 利用遙測技術分析中國森林三十年來的變化，發現森林分佈受到緯度、經度、海拔和經濟條件等多重因素影響；Pham et al. (2024) 利用 Landsat 影像分析十年間土地利用和覆蓋變化，並應用人工神經網絡來預測未來趨勢。

在林業監測和經營管理上，精確且細緻的空間資訊常需透過航照判釋取得 (Morgan et al., 2010)，大尺度的森林資源盤點可藉此獲得完整的地景變遷紀錄，還原各時期植被覆蓋情形 (Cohen et al., 1996; Fensham and Fairfax, 2002)。航照技術亦可大幅降低資訊取得成本 (Paine and Kiser, 2012)，並支援森林調查、干擾測繪、生產力估計和野生動物管理等資訊需求 (Avery and Berlin, 1992)。例如林業暨自然資源保育署過去執行第三次及第四次全省森林資源調查，即採用航照判釋方法繪製森林林型圖，並透過立體觀測建置系統樣區樹高等相關資訊。

在崩塌地監測上，航遙測技術扮演了關鍵角色，不僅可用於自然災害後復育情形之評估與追蹤 (Zhou et al., 2021)，亦能同時觀察小尺度如單一崩塌區域與大尺度如整體地景結構的變動 (Dislich and Huth, 2012)，這種技術的應用對於森林區域在遭受自然擾動後即時和長期復育工作至關重要，進一步促進自然災害規劃、評估與應用的整合性發展 (Marlier et al., 2022)。此外，這些技術的持續發展也提升了我們對森林擾動後演替過程的理解與動態分析能力 (Cillis et al., 2021)。因此，航遙測技術已逐漸成為森林崩塌監測與生態評估中不可或缺的重要工具。

二、 空間解析度對模型建構影響

不同解析度的空間資訊可能會對崩塌潛勢的預測結果產生不同的影響 (Yang et al., 2024; Huang et al., 2023; Martinello et al., 2023; Zhao et al., 2019)。空間解析度的提高不一定能提升崩塌潛勢預測結果 (Huang et al., 2023)。在過去崩塌地相關的研究顯示，航遙測的空間解析度通常設定在 5 m 至 30 m 之間 (Wang et al., 2019;

Sevgen et al., 2019; Nhu et al., 2020a; Nhu et al., 2020b; Zhou et al., 2021)，其中多數將空間解析度設定為 10 m (Sevgen et al., 2019; Nhu et al., 2020a; Nhu et al., 2020b)。Zhao et al. (2019) 則探討 5 m、15 m 和 30 m 三種解析度在崩塌潛勢模型中的應用，結果顯示中等解析度 15 m 表現最佳；Garosi et al., (2018) 針對伊朗水庫流域，探討不同像元解析度 (2–30 m) 對進行崩塌潛勢建模之影響，研究結果指出 10 m 解析度資料在模型擬合度與預測能力上皆表現最佳；Huang et al. (2023) 則是針對 15、30、60、90 和 120 m 的空間解析度影響因子建模，結果顯示 15 m 為最適解析度；Yang et al. (2024) 利用 4 種解析度 25 m、50 m、75 m 和 100 m 建立預測模型，發現 25 m 解析度具相對較佳的預測能力。雖然多數研究均指出解析度對模型表現具有影響，但對於何者為最適空間解析度目前尚無一致的標準，且在不同的研究中，影響崩塌發生的環境因子在各空間解析度下可能有不同的解釋力 (Zhao et al., 2019; Huang et al., 2023)，因此，在建立崩塌潛勢預測模型的過程中，選擇適當的空間解析度是極為關鍵的環節 (Huang et al., 2023)。本研究為建構適用於六龜試驗林區之崩塌潛勢預測模型，並支援生態系統的長期監測與管理需求，初步即針對不同空間解析度進行適用性分析，以確立最佳解析尺度，進而發展具有高預測準確性的模型。

三、物件導向與支持向量機應用於土地覆蓋分類

在應用衛星影像進行長期監測時，多數研究通常會先進行影像分類，再根據所產製之土地覆蓋分類圖進行變化偵測 (Chughtai et al., 2021)。因此選擇合適且具高分類準確度的影像分類技術至關重要。傳統的像元式影像分類方法，容易因單一像元問題，而產生椒鹽效應，因此為解決問題，物件導向的分類方法被提出使用 (孔繁恩等，2014)，物件式的分類方法為將同質性區塊分割出來，作為分類的最小單元，可有效降低雜訊並且提升分類準確度，目前已被廣泛應用於各類遙測影像分類研究中 (Tzotsos and Argialas, 2008; Petropoulos et al., 2012)。

支持向量機 (SVM) 為常見的機器學習分類方法，特別適合處理高維度和非線性數據。近年來多項研究證實 SVM 在衛星影像上分類的效能，例如 Basheer et al. (2022) 結合 Sentinel-2 與 Planet 影像進行 SVM 分類方法，整體準確度可達 90% 以上；Ghayour et al. (2021) 則利用 Sentinel-2 與 Landsat-8 衛星影像比較多種影像分類方法，結果顯示 SVM 分類方法表現最好，準確度達 94% 以上。在結合物件導向

方面，Tzotsos and Argialas (2008) 提出將物件導向與 SVM 結合進行影像分類，證明具有優越的效果。近年在森林應用的研究中，Wu and Zhang (2019) 利用高光譜與光達資料，結合物件導向及 SVM，有效提升樹種辨識的精度，整體準確度高達 94.68%；Cechim et al. (2023) 將物件導向結合 SVM 應用於熱帶森林分類，結果在天然林分類精度達 89.5%。綜合上述成果，物件導向結合 SVM 技術在提升土地覆蓋分類精度方面具備高度可行性。因此本研究亦參考前人研究，以物件導向結合 SVM 進行衛星影像分類，以建立高精度的土地覆蓋型圖層，作為後續分析與應用之基礎。

四、空間自相關

空間自相關 (Spatial Autocorrelation) 為空間分析中常用的方法之一，主要用於判斷資料是否呈現空間群集現象，依分析層級可分為全域空間自相關 (Global Spatial Autocorrelation) 與區域空間自相關 (Local Spatial Autocorrelation) (Ping et al., 2004)，全域空間自相關用以分析特定現象於整體空間範圍內是否具有顯著的群集特性，而區域空間自相關則著重於分析單一空間單元與其鄰近單元之相關性，進而判釋局部顯著群集的熱點 (Hot Spot) 區域，並可透過熱點的位置探討其背後的环境或社會因素。目前已有許多國內外研究應用空間自相關方法探討不同主題的空間分布模式，例如 Ping et al. (2004) 利用全域空間自相關分析棉花產量的空間相依性，發現產量受到氣候條件的顯著影響，在乾旱年份呈現顯著自相關，而濕潤年則無顯著自相關。Fu et al. (2014) 的研究指出，中國東南部亞熱帶森林中枯落物碳分布具顯著的正空間自相關；Sun and Fan (2020) 探討天然與人工針葉林生物量碳密度空間格局，發現天然林針葉林的生物量碳密度有較高的空間相依性；Yeh and Liaw (2021) 針對臺灣東部自然干擾後的崩塌區域進行空間自相關分析，結果顯示崩塌區域有較高的正相關。在空間熱點分析方面，葉春國等 (2013) 研究水里溪上游集水區中檳榔園熱點的空間分佈，藉由 Moran's I 及 G statistics 空間自相關方法，識別出在不同網格大小下檳榔園的空間聚集現象與熱點區域；Pasha et al. (2016) 則研究長期土地覆蓋變化，並運用 ArcGIS 的熱點分析工具監測熱點和冷點分布，結果發現紅樹林造林熱點增加區域；Lin et al. (2017) 結合全域及區域空間自相關方法探討崩塌地的群集現象，發現在中台灣存在有崩塌熱點集中區域，進一步驗證

空間自相關在崩塌研究中應用的潛力與價值。本研究主要利用空間自相關探討崩塌復育的空間分佈，是否具有顯著的群聚特性。

第四節 預測模型應用

一、邏輯迴歸與隨機森林

邏輯迴歸是一種常用的統計模型，可用於分析事件發生的機率與自變量間的關聯性，透過二元因變量 (Dependent Variable) 與多個自變量 (Independent Variable) 建構模型，並計算發生機率。邏輯迴歸過去常被應用於土地利用變遷、城市擴張與森林覆蓋等議題 (Pueyo and Begueria, 2007; Lakes et al., 2009; Adzandeh et al., 2020)。例如 Kumar et al. (2014) 以森林邊緣、道路與定居點的距離、坡度等作為變量成功預測森林覆蓋率，準確度達 87%；Saha et al. (2020) 亦以此法預測森林砍伐機率，成果良好。在崩塌潛勢方面，Kuradusenge (2020) 結合雨量、土地覆蓋、坡度等因子進行邏輯迴歸建模，預測準確度高達 90% 以上；Wang et al. (2021) 與 Nhu et al. (2020a) 則結合地形、土壤、土地類型等驅動因子，進行邏輯迴歸建模並製作崩塌地潛勢圖，效果良好。由此可見邏輯迴歸在森林變遷與崩塌潛勢預測中皆能辨識關鍵驅動因子並提供良好預測力。

另一方面，隨著機器學習的發展，非參數模型如隨機森林在處理非線性問題與高維資料上展現強大優勢 (Durbha et al., 2007)，其能從大量資料中學習自變量與因變量之間的經驗關係，有效提升分類與預測能力，並被廣泛應用於遙測分類與森林資源預測 (Naidoo et al., 2012; Amini et al., 2018; Chunhui et al., 2018; Linhui et al., 2020; Liang et al., 2011; Qu et al., 2019)。Kuradusenge and Zennaro (2020) 在崩塌潛勢分析中發現隨機森林具極佳準確度；Geetha et al. (2020) 發現隨機森林在不同氣候條件下預測作物產量，有不錯的效果。Loozen et al. (2020) 利用隨機森林結合遙測影像和環境變數繪製歐洲森林冠層氮圖，也得到良好的準確度。Wang et al. (2021) 與 Silva et al. (2017) 則探討森林生產力與多樣性關聯，均證實隨機森林的應用效能。Ahmed et al. (2015) 更指出隨機森林在處理高維非線性資料與變數交互作用時效果良好，且可同時提供變數重要性排序以協助特徵選擇；Anselmetto et al. (2024) 使用隨機森林迴歸評估了自然重新造林的氣候、地形和社會經濟驅動因素，研究發現人口密度、道路密度以及工業與農業就業部門的工人比例是與重新造林最相關的

變數，並且在偏遠和人口稀少的城市內，乾燥景觀的朝南斜坡上的重新造林率最高。

過去已有多項研究應用邏輯迴歸、隨機森林與支持向量機等方法進行崩塌潛勢預測 (Wang et al., 2019; Kuradusenge et al., 2020; Yang et al., 2024)，其中隨機森林因具備處理非線性關係、不需資料歸一化、對離群值不敏感且可防止過擬合等特性，在多項研究中顯示出優異性能 (Nhu et al., 2020b; Kuradusenge et al., 2020)。其演算法由多棵決策樹組成，透過隨機特徵選擇與多次投票以提升整體預測效能 (Breiman, 2001; Hansen and Salamon, 1990)，並可利用袋外樣本評估模型準確率；與傳統迴歸方法比較，隨機森林在林分屬性預測中表現更佳，特別適用於異質性高的林分預測 (Ahmed et al., 2015; Ozkan et al., 2022)。在實務應用上，Milanović et al. (2020) 與 Nafouanti et al. (2021) 即採用 Python 的 scikit-learn 工具建構 100 棵決策樹模型以提升分類性能。本研究選擇邏輯迴歸與隨機森林兩種模型進行比較，除參考前人研究外，亦考量兩者各具不同的建模特性，其中邏輯迴歸作為統計模型，具有良好可解釋性，能明確解釋變數與崩塌事件或土地變遷之間的關聯性；而隨機森林則為集成式的機器學習方法，能處理變數間的非線性與交互作用，具備優異的分類與預測能力，因此本研究納入兩者，除能善用其模型優勢深入分析外，亦可比較其在人工林變遷與崩塌潛勢預測上的適用性與差異性，以期提供多元且具實務參考價值的分析結果。

二、 CA-Markov 與隨機森林整合發展

馬可夫鏈方法為預測空間變化現象常用的模型，廣泛應用於地理與地景生態相關研究中 (Mansour, 2020)，也是模擬植被動態與土地利用變遷最早且最普遍使用的模型之一 (莊智瑋等, 2010)，主要以轉換機率矩陣為基礎，來展示空間區位在不同時期間的利用變化與數量，因而能有效評估地貌變遷與土地利用變化之時序趨勢，並預測未來可能之發展 (張政亮, 2006)。Hsu and Cheng (2000) 利用馬可夫鏈分析六龜試驗林之地景變遷，預測若變遷機率不變，最終天然林將全面取代人工林；鄭祈全等 (2005) 結合馬可夫鏈與邏輯迴歸模式模擬山區民墾地分佈，結果顯示民墾地面積有明顯擴張趨勢；莊智瑋等 (2010) 則以馬可夫鏈探討九份二山崩塌地的植生復育過程，發現復育初期以草生植物為主，後期逐漸轉變為林地，最終穩定期則介於 2012 至 2028 年間；Peng and Chen (2010) 亦透過馬可夫鏈預測森林

從演替初期到成熟期階段的過程，結果顯示需時 150 年。

隨著科技進步，目前已發展出許多成熟的動態預測模式，如細胞自動機（呂明倫，2014），雖然馬可夫鏈模型能定量描述土地利用變化，但無法呈現空間格局的演變，因此學者們開始將其與細胞自動機結合，形成 CA-Markov 模型，以系統化模擬土地利用變遷之空間分布與面積變化，進而提升模型的解釋能力與準確度（Mansour et al., 2020; da Cunha et al., 2021; Zhang, 2021）。張政亮及張瑞津（2006）以四期 SPOT 衛星影像模擬九九峰經 921 地震後的崩塌與復育過程，結果指出 CA-Markov 模型優於單純的馬可夫鏈預測模式，在模擬植生變遷方面更為合理與有效；Mwabumba et al. (2022) 利用 CA-Markov 預測 2025 及 2035 年土地覆蓋型變化，結果顯示天然林將逐漸減少；Zhang et al. (2021) 則應用 CA-Markov 模型模擬預測 2018-2035 濕地演化的方向。

然而，CA-Markov 模型雖引入鄰近效應以考慮空間分布，但仍未能呈現空間變化與驅動因子間的關聯，因此近年來研究者開始嘗試將 CA-Markov 模型與機器學習方法結合，以克服傳統模型在變數解釋力上的限制，進一步強化預測準確性與空間分布合理性（陳鑄等，2020；Zhou et al., 2020；Shafizadeh et al., 2021）。陳鑄等（2020）利用邏輯迴歸結合 CA-Markov 耦合模型預測福州市未來土地利用空間分布。Zhou et al. (2020) 運用 CA-Markov 與隨機森林模型耦合探討土地利用變遷，研究指出隨機森林可有效推導土地利用與驅動因子之間的非線性關聯，並提供變數貢獻程度之評估，使空間模擬更加準確。由於目前結合 CA-Markov 與隨機森林（CA-Markov and Random forest, RF-CA-Markov）研究仍不多，因此本計畫將利用此方法建構預測模型，探索未來森林生態崩塌與復育空間格局。

第三章 研究材料與方法

第一節 研究區域

本研究以林業試驗所轄管之六龜試驗林為研究範圍(如圖 1)，該林區位於臺灣本島南部，荖濃溪以東，中央山脈西側之狹長地帶，南北長約 19.5 km，東西寬約 13.0 km。行政區大部份劃屬在高雄市茂林區。其東面及北角鄰接國有林之荖濃溪事業區，南及西南連接屏東事業區，西南及北隅大部份與保留地及公私有林連接，地形呈南北走向，全區面積約 9,882 ha，其中天然林約佔 83%，人工林約佔 15%，其他約佔 2%（林文智，2012）。

林區海拔高度介於 250-2,600 m 間，位於荖濃河流域，由其支流濁口溪底至林巴拉山，高程相差 2000 m 以上，加之境內地形複雜，區內局部氣候有空間差異。試驗林北半部嶺線東側及南面，因日照量較多，故較為乾燥；位於西側及面北之區域則較濕潤；南半部三面環山，中央為谷地，故遠較其他區域潮濕（林業試驗所，1982）。

臺灣光復後造林樹種多以針葉樹為主，於六龜試驗林第二期經營計畫（1979 年 7 月～1989 年 6 月）中，選定臺灣杉為示範經營之對象（林業試驗所，2002）。自 1972 年起逐年進行臺灣杉造林，至 1991 年六龜試驗林有 1,300 ha 的臺灣杉造林地（林照松，1991），主要集中於試驗林以北的鳳岡及以南的多納二大林區。

六龜試驗林的降雨高峰集中在 7 至 9 月，主要為颱風降雨。2009 年 8 月 8 日莫拉克颱風帶來的強降雨，引發了大規模的崩塌和土石流。六龜試驗林鳳崗觀測站在颱風期間觀測到該區歷史最大降雨紀錄，單日降雨量高達 1,290 mm（陸象豫、黃惠雪、孫銘源，2018），這場大豪雨引發了約 204 處崩塌，總面積約 804.49 ha（陸象豫、林昭遠、黃良鑫，2011）。




圖 1 六龜試驗林位置圖

第二節 研究材料

一、 航照影像

六龜試驗林臺灣杉造林地造林年度介於 1975 至 1991 年間，本研究主要使用 1980、1990 及 2020 年三個時期的正射影像，空間解析度為 15 與 25 cm，1980 及 1990 年影像來源取自航測及遙測分署，2020 年影像取自林業試驗所，詳細影像資訊如表 1。

表 1 航照正射影像資訊

主要拍攝時間	影像類型	空間解析度	備註（詳細拍攝時間組成）
1980 年	黑白正射影像	25 cm	包含 1980 年 6 月、1980 年 7 月、1980 年 11 月及 1981 年 4 月
1990 年	黑白正射影像	25 cm	包含 1988 年 12 月、1989 年 4 月、1989 年 5 月及 1990 年 2 月
2020 年	彩色正射影像	15 cm	包含 2020 年 11 月及 2021 年 4 月

二、 多時序崩塌地圖

本研究使用林業及自然保育署提供的多時序崩塌地圖層(圖 2)，時間範圍為 2009 年至 2018 年，製作這些地圖的主要資料來源為當年度 1 至 7 月的全島鑲嵌衛星影像，其中 2009 年至 2016 年使用了福衛二號衛星影像，而 2017 年至 2018 年則使用了 SPOT 衛星影像，崩塌地圖產製主要是運用自動特徵萃取及人工判釋的方法，判釋最小面積為 0.1 ha。




圖 2 六龜試驗林崩塌地圖

三、 衛星影像

由於上述所蒐集的多時序崩塌地圖層，取得資料僅為向量資料，在各時期崩塌變化的影像判釋及驗證有所限制，因此另行蒐集多時期衛星影像，並且利用影像分類技術，製作六龜試驗林多時期土地覆蓋型圖，所使用之衛星影像含 2009 年 5 月、8 月及 2011 的福衛 2 號影像，與 2013、2015、2017、2019、2021 及 2024 年的 SPOT 影像，影像詳細資訊如表 2。

表 2 衛星影像日期與種類

拍攝日期	感測器	波段	空間解析度
2009/05/09	FORMOSAT-2	4	2m (PAN)、8m (MS)
2009/08/19	FORMOSAT-2	4	2m (PAN)、8m (MS)
2011/08/17	FORMOSAT-2	4	2m (PAN)、8m (MS)
2013/07/03	SPOT6	4	1.5m (PAN)、6m (MS)
2015/04/14	SPOT6	4	1.5m (PAN)、6m (MS)
2017/11/17	SPOT6	4	1.5m (PAN)、6m (MS)
2019/12/11	SPOT6	4	1.5m (PAN)、6m (MS)
2021/02/02	SPOT7	4	1.5m (PAN)、6m (MS)
2023/01/15	SPOT6	4	1.5m PAN)、6m (MS)
2024/01/03	SPOT6	4	1.5m PAN)、6m (MS)

四、 光達資料

本研究所蒐集的光達資料有三期，包含有林業試驗所於 2020 年拍攝的六龜試驗林空載光達資料，空載光達設備為 Optech ALTM Regasus HA500，原始點雲回波平均密度每 m^2 大於 2 點。將取得之原始光達資料進行分類、編輯及內插等處理，製作完成 1 m x 1 m 網格解析度的數值高程模型 (Digital Elevation Model, DEM)。

另外蒐集有 2009 至 2010 年及 2016 至 2017 年兩期，內政部地政司所提供之空載光達測繪資料，包含 1 m x 1 m 網格解析度的數值高程模型及數值地表模型 (Digital Surface Model, DSM)，作為本研究使用之地形資料。

五、 氣象資料

本研究所使用之氣象資料取自「臺灣氣候變遷推估資訊與調適知識平台計畫」(TCCIP) 所產製的氣溫及雨量網格化觀測資料，網格大小為 1 km x 1 km，座標系統為 WGS84。

六、 造林台帳

造林台帳是一份記錄森林造林的文件，其中包括了每次造林活動的詳細資料，本研究使用六龜試驗林之造林台帳，造林年份從 1971 年至 1991 年，透過分析造

林台帳中所記錄的人工林的空間分布(圖 3)，能有效地區分六龜試驗林中的人工林和天然林的空間位置，作為後續林地類型分析的重要依據。




圖 3 六龜試驗林造林台帳圖

七、 向量資料

使用資料包含有水利署公開資訊內所提供之河川 GIS 的向量圖檔及六龜試驗林林道圖等向量資料。

第三節 研究方法

一、 研究流程

本研究整體流程如圖 4 所示，研究整合了多元航遙測資料、地形資訊與機器學習方法，以進行時間序列分析與空間預測建模。




圖 4 研究流程圖

在流程圖左側，主要針對臺灣杉造林地自然演替變化進行建模。研究整合歷年航照正射影像（1980、1990 與 2020 年）將早期造林地邊界劃分出來，並針對造林地範圍航照判釋 2020 年土地覆蓋型圖，結合地形、氣象及距離等潛在影響臺灣杉自然演替的因子，作為建模基礎資料。接續分別以邏輯迴歸與隨機森林建立全區模型與分區（北鳳岡林區及南多納林區）模型，並進行模型準確度評估，產製變化預測機率圖，探討臺灣杉人工林轉變為闊葉或針闊混淆林之可能性與空間分布。

右側流程為崩塌潛勢與復育模型建立，及透過土地覆蓋轉變模擬對未來進行預

測。首先透過 10 期衛星影像資料 (2009/5、2009/8、2011、2013、2015、2017、2019、2021、2023、2024) 以物件導向結合支持向量機分類方法，建立土地覆蓋圖。結合地形、樹冠結構、距離與地景等驅動因子，以 LG 與 RF 模型進行崩塌潛勢與復育建模及評估。最後採用 RF 方法建立崩塌潛勢與復育預測機率圖，結合 CA-Markov 所發展出之 RF-CA-Markov 模型模擬預測土地覆蓋型態分布，並與傳統 CA-Markov 預測結果進行驗證分析。最終以 RF-CA-Markov 模型預測 2031 年土地覆蓋型分布。同時，透過 10 期土地覆蓋型圖，輔以崩塌地變遷分析、面積變化分析、景觀指標分析與空間自相關分析，探討整體空間結構變化趨勢。

中間流程的空載光達與地形資料資料，主要提供模型所使用相關因子之計算，如地形因子，包含高程、坡度、坡向、地形濕度指數 (Topographic Wetness Index, TWI)、逕流強度指數 (Stream Power Index, SPI)、曲率、平面曲率、剖面曲率等；及冠層結構因子，包含冠層覆蓋率 (Canopy Cover Ratio, CCR)、平均冠層高 (Mean Top-of-the-Canopy Height, TCH)、冠層高度變異數 (Variance of Canopy Height, VCH) 及冠層容積率 (Canopy Volume Ratio, CVR) 等。以下各節將依據研究流程詳述相關方法與技術。

二、土地覆蓋圖產製

(一)臺灣杉造林地土地覆蓋現況圖

利用早期造林台帳資料，萃取出臺灣杉造林地的空間資訊，總共有 25 筆造林地號，總面積為 415.1 ha，其分布如圖 5 所示，造林地相關資訊如表 3。




圖 5 六龜試驗林臺灣杉人工造林地圖

表 3 臺灣杉造林地資訊

編號	造林地地號	造林樹種	造林年份	面積 (ha)
1	六-10-74-1	臺灣杉	1985	7.0
2	六-10-69-10	臺灣杉	1980	7.8
3	六-10-71-2	臺灣杉	1982	7.6
4	六-12-71-3	臺灣杉	1982	26.6
5	六-12-68-3	臺灣杉	1979	23.5
6	六-10-68-2	臺灣杉	1979	15.6
7	六-10-74-3	臺灣杉	1985	5.5
8	六-10-71-1	臺灣杉	1982	7.1
9	六-2-70-6	臺灣杉	1981	15.0
10	六-2-65-2	臺灣杉	1976	45.6
11	六-2-71-4	臺灣杉	1982	12.9
12	六-14-64-1	臺灣杉	1975	39.1
13	六-12-70-2	臺灣杉	1981	11.1
14	六-22-74-14	臺灣杉	1985	10.4
15	六-24-78-2	臺灣杉	1989	17.6
16	六-18-74-9	臺灣杉	1985	7.6

17	六-20-74-6	臺灣杉	1985	28.9
18	六-20-74-5	臺灣杉	1985	19.1
19	六-12-72-1	臺灣杉	1983	17.2
20	六-10-69-11	臺灣杉	1980	10.3
21	六-18-74-8	臺灣杉	1985	8.6
22	六-20-74-10	臺灣杉	1985	25.3
23	六-20-75-3	臺灣杉	1986	12.7
24	六-21-80-8	臺灣杉	1991	12.5
25	六-20-74-4	臺灣杉	1985	20.3
總面積				415.1

本研究將台灣杉人工造林地向量圖層，先套疊 1980 及 1990 年航照影像套疊，確認其造林地邊界是否與航照影像所呈現出的伐採跡地邊界吻合，然後依據影像進行造林地邊界編修，並將編修完成的臺灣杉造林地邊界圖設定為基線資料。後續並將臺灣杉造林地邊界套疊 2020 年航照正射影像，並判釋造林地範圍內土地覆蓋型現況圖，判釋類別包含「臺灣杉」、「針闊混淆林」、「闊葉樹林型」、「崩塌地」、「崩塌復育」及「草地」等六型。

判釋標準依據林業保育署「第四次全國森林資源調查土地利用型三維數化及航照樣點判釋工作手冊」。原則上以 1:1000 比例尺以下進行數化，其中臺灣杉類別比照手冊內的單一樹種判釋原則，只要佔林冠 80% 以上，視為臺灣杉純林；闊葉樹林型原則為闊葉樹佔林冠面積 80% 以上、闊葉樹及竹類佔全林冠面積未達 20% 者；針闊葉樹混淆林型原則為針、闊葉樹均佔林冠面積 20% 以上、80% 以下，且竹類佔全林冠面積未達 20% 者。

(二)六龜全區土地覆蓋型圖

全區土地覆蓋型圖主要利用衛星影像分類方法製作而成，分類方法主要利用物件導向影像分析結合 SVM 機器學習分類方法，對多時期衛星影像進行分類。所使用的主要工具為 eCognition 軟體，首先針對六龜全區衛星影像像元，依據光譜、色調、形狀等因子將同質性高的像元進行整合，變成具均質性影像物件型態，其後進行分割，劃分為多個物件。土地覆蓋型類別設定為崩塌地、裸露地、植生及陰影等四類，其後於分割後的物件，在不同類別間選取相應的訓練樣本，並結合物件特徵與光譜參數進行 SVM 分類器的訓練與建置。分類模型的變量包含有光譜參數紅光

(R)、綠光 (G)、藍光 (B)、近紅外 (NIR) 波段及常態化差異植生指數 (Normalized Difference Vegetation Index, NDVI)，這些變數作為輸入特徵並用於分類模型的訓練，之後再對全區進行分類。而在裸露地與崩塌地的區別，參考實際影像崩塌與裸露地的坡度，設定以坡度 20°為門檻值 (Phakdimek et al., 2023; Fayne et al., 2019)，輔助兩者類別的區分。

$$NDVI = \frac{(NIR-R)}{(NIR+R)} \quad (1)$$

NIR 為近紅外光段，R 為紅光段。

為了評估分類結果的準確性，本研究針對不同時期的衛星影像，每期影像選取 1,000 個隨機分佈的檢核點，並利用航照判釋方法，判釋檢核點在航照影像上實際土地覆蓋類別，並與透過影像分類所生成的多時期土地覆蓋圖進行驗證，計算分類結果的總體精度及 Kappa 值，以評估分類的效能，Kappa 介於 0 至 1 之間，Kappa 值越大則表示分類準確度越高。

$$Kappa = \frac{N \sum_{i=1}^n X_{ii} - \sum_{i=1}^n (X_{i+} * X_{+i})}{N^2 - \sum_{i=1}^n (X_{i+} * X_{+i})} \quad (2)$$

n 為分類矩陣之列數， X_{ii} 為分類矩陣中欄列對角之樣點數目， X_{i+} , X_{+i} 為分類矩陣中各欄及各列之樣點數目，N 為全部樣點數目。

三、 變遷分析

在多時期土地覆蓋變遷分析部份，主要透過 ArcGIS Pro 軟體進行空間資訊與時間序列變遷分析，利用圖層套疊與變遷檢測等工具，比對各期土地覆蓋類型的空間變化，並量化變遷面積與比率，以掌握森林覆蓋在時間與空間上的變化趨勢。

此外，變遷分析結果亦為預測模型建構的重要依據，根據不同時期土地覆蓋的轉換情形，可設定模型因變數的類別，並結合潛在驅動因子等自變數，進一步建構預測模型。

四、 空間自相關分析

為瞭解六龜試驗林在經歷崩塌干擾下，隨著生態系統自然運作下，復育是否會

有空間群集的現象，以進一步分析變動過程與空間的關連性，因此本研究利用 Moran's I 方法，研究全域空間群集現象。

全域空間自相關是一種用於測量空間資訊的群聚或分散程度的統計方法，其關鍵統計量是 Moran's I 指標，Moran's I 指標的計算公式如下式(3) (Ping et al., 2004, Yeh and Liaw, 2021)：

$$I = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \times \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

$j \neq 1$ ，公式中若 i 與 j 相鄰則 $w_{ij}=1$ ，若 i 與 j 不相鄰則 $w_{ij}=0$ ，變數 X 在 i 、 j 的值表示為 x_i 與 x_j ， $\bar{x}$ 變數平均值， n 為空間單元總數。

為了確定空間自相關的統計顯著性，對 Global Moran's I 值進行顯著性檢定，在 $P < 0.01$ 的顯著水準下，代表空間單元的分布不是隨機的，而是受到特定的空間因素驅動。

五、地景指標

由於莫拉克颱風對六龜試驗林森林生態系統造成嚴重的影響，特別是在崩塌災害發生後地景結構產生巨大的變動。本研究參考前人研究，選擇了代表不同空間特徵的地景層級指標，這些指標包括代表密度和邊緣特性的地景指標，如區塊數目 (Number of Patches, NP) 和邊緣密度 (Edge Density, ED)；代表形狀特徵的地景形狀指數 (Landscape Shape Index, LSI) 以及碎形維度 (Perimeter-Area Fractal Dimension, PAFRAC)；代表聚集特性的聚集度指數 (Contagion, CONTAG) 和分離度指數 (Splitting Index, SPLIT) 等，透過對這些地景指標（表 4）的量化計算，來分析評估崩塌地的地景結構變動情形。

坵塊地景指標是指用於描述景觀結構特徵的量化指標，能夠反映景觀的組成和配置，包括地景碎片化、坵塊大小和形狀、坵塊之間的連接度等。本研究納入崩塌地的坵塊地景指標作為崩塌復育的考量因子，以深入瞭解不同地景特徵對自然復育的影響。在本研究中，選取了六個坵塊層級的地景指標，這些指標包括坵塊面積 (AREA)、坵塊周長 (Patch Perimeter, PERIM)、周長面積比 (Perimeter-Area Ratio, PARA)、分形維數 (Fractal Dimension Index, FRAC)、近圓形形狀指標 (Related

Circumscribing Circle, CIRCLE) 及鄰近指數分佈 (Contiguity Index, CONTIG) 等。這些指標的計算主要是以莫拉克颱風後崩塌區塊為主，並利用 Fragstats 軟體，針對每個崩塌區塊計算求得，透過這些坵塊地景指標，能夠更全面地評估崩塌地區的地景結構特徵，並進一步分析其對崩塌復育的影響。

表 4 使用地景層級之地景指標

地景指標	代碼	公式	描述
區塊數量	NP	$NP = N$	N=坵塊數量
邊緣密度	ED	$ED = \frac{E}{A}(10000)$	E=坵塊總邊緣長度(m) A=地景總面積(m ²)
景觀形狀指標	LSI	$LSI = \frac{0.25E}{\sqrt{A}}$	E=坵塊總邊緣長度(m) A=地景總面積(m ²)
碎形維度	PAFRAC	$PAFRAC = \frac{2}{N \sum_{i=1}^m \sum_{j=1}^n (ln p_{ij} * ln a_{ij})} - \frac{[(\sum_{i=1}^m \sum_{j=1}^n ln p_{ij})(\sum_{i=1}^m \sum_{j=1}^n ln a_{ij})]}{N \sum_{i=1}^m \sum_{j=1}^n (ln p_{ij}^2) - (\sum_{i=1}^m \sum_{j=1}^n ln p_{ij})}$	a _{ij} =坵塊 ij 面積(m ²) p _{ij} =坵塊 ij 周長(m) N=坵塊數量
聚集度指標	CONTAG	$CONTAG = \left[1 + \frac{\sum_{i=1}^m \sum_{k=1}^m \left[(p_i) \left(\frac{g_{ik}}{\sum_{k=1}^m g_{ik}} \right) \right] * \left[\ln(p_i) \left(\frac{g_{ik}}{\sum_{k=1}^m g_{ik}} \right) \right] \right]}{2 \ln(m)} \right] (100)$	p _i =坵塊所佔景觀的比例 g _{ik} =i 與 k 類型區塊毗鄰的網格數，依據 double-count 方法 m=坵塊類型的數量
分離度指標	SPLIT	$SPLIT = \frac{A^2}{\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2}$	a _{ij} =坵塊 ij 面積(m ²) A=地景總面積(m ²)

六、森林變遷驅動因子

(一)臺灣杉造林地變遷

本研究針對臺灣杉造林地變遷進行分析，選取高程、坡度、坡向、溫度、雨量、林齡、距造林地邊界距離與距林道距離等 8 個因子，作為可能影響造林地自然演替的潛在因子。這些因子的選擇主要基於植物生長與環境間的密切關聯性，涵蓋地形、氣候、生態等層面。前述文獻回顧中亦指出，相關研究多強調地形與氣候條件在影響森林演替過程扮演關鍵色，亦有研究納入距林道距離作為影響自然演替潛在因子。地形條件如坡度、坡向與高程，會影響植被所接收的光照與水分；溫度與降雨則是驅動植物生理活動的關鍵因子；林齡可反映林分所處的發育階段與更新潛力，而距離林道與造林地邊界距離則可能影響微氣候條件與外來物種入侵程度，進而影響自然演替。因此，選取這些因子期能建構臺灣杉造林地自然演替模型。各因子詳細資料如表 5。

表 5 臺灣杉造林地變遷驅動因子

變數	代碼	資料來源
高程	DEM	2020 年空載光達資料取得
坡度	SP	2020 年空載光達資料求得
坡向	AP	2020 年空載光達資料求得
氣溫	TM	TCCIP 網站
雨量	RA	TCCIP 網站
林齡	AG	林業試驗所六龜試驗林造林台帳
距造林地邊界距離	DB	林業試驗所六龜試驗林造林台帳
距林道距離	DR	林業試驗所道路向量

(二)崩塌自然復育

在崩塌復育部份，本研究以高程、坡度、坡向、地形濕度指數 (TWI)、逕流強度指數 (SPI)、曲率、平面曲率、剖面曲率、溫度、雨量及距崩塌地邊界的距離等因子作為建模的變數。上述變數的選取主要參考前人研究(邱清安和徐憲生，2015; 宋承恩，2022; Zhang et al., 2014)，並考量空間異質性對崩塌地森林復育所造成之潛在影響。其中高程、坡度、坡向等地形因子與植生生長適宜性密切相關；TWI 反映地表濕潤程度，SPI 代表的地表水流侵蝕程度，兩者皆與崩塌地植生是否能重新建立有關；曲率、平面曲率與剖面曲率則代表地表的起伏特性，間接影響土壤濕度與種子是否順利生長。此外，考量研究地區 90% 為森林覆蓋，種子來源為重要影響，因此納入崩塌地的坵塊地景指標，以探討崩塌地景與周圍環境的關聯性，並評估地景結構對自然復育的影響。此外，雖然土壤是植生生長的重要因素之一，但由於本研究無法取得全區完整的土壤資料，因此未納入變數分析。所使用因子詳細資料如表 6。

表 6 崩塌地自然復育驅動因子

變數	代碼	資料來源
高程	DEM	2010 年空載光達資料取得 2017 年空載光達資料取得
坡度	SP	
坡向	AP	
地形濕度指數	TWI	
逕流強度指數	SPI	
曲率	CUE	
平面曲率	PNE	
剖面曲率	PFE	
氣溫	TM	TCCIP 網站
雨量	RA	
坵塊面積	AREA	2009 年崩塌地圖層計算求得 2017 年崩塌地圖層計算求得
坵塊周長	PERIM	
周長面積比	PARA	
分形維數	FRAC	
近圓形形狀指標	CIRCLE	
鄰近指數分佈	CONTIG	
距崩塌地邊界的距離	DS	2009 年崩塌地圖層求得 2017 年崩塌地圖層求得

(三)崩塌潛勢

在崩塌潛勢模型建構部份，本研究選取高程、坡度、坡向、地形濕度指數、逕流強度指數、曲率、平面曲率、剖面曲率、距河道距離及常態化差異植生指標等作為潛在影響崩塌發生之關鍵因子。上述變數的選取，係參考前人研究 (Dang et al., 2020; Sevgen et al., 2019; Nhu et al., 2020) 所常使用的因子。同時考量試區多為森林覆蓋區域，而植被覆蓋的程度對土壤性質有深遠的影響，可強化土壤強度和根系結構，進而降低崩塌發生率，因此引入光達資料衍生的四種樹冠結構指標，冠層覆蓋率 (CCR)、平均冠層高 (TCH)、冠層高度變異數 (VCH) 及冠層容積率 (CVR) 等，總共選取了上述 14 個崩塌影響因子，作為構建崩塌潛勢預測模型的核心變數。詳細因子資料如表 7。

表 7 崩塌潛勢驅動因子

變數	代碼	資料來源
高程	DEM	2010 年空載光達資料取得 2017 年空載光達資料取得
坡度	SP	
坡向	AP	
地形濕度指數	TWI	
逕流強度指數	SPI	
曲率	CUE	
平面曲率	PNE	
剖面曲率	PFE	
距河道距離	DR	水利署河川向量資料推估所得
常態化差異植生指標	NDVI	FORMOSAT-2(2009/08/19)影像求得 SPOT6(2017) 影像求得
冠層覆蓋率 平均冠層高 冠層高度變異數 冠層容積率	CCR TCH VCH CVR	2010 年空載光達資料取得 2017 年空載光達資料取得

(四)各項驅動因子計算

有關影響臺灣杉人工林自然演替及崩塌崩勢與復育，各項驅動因子的計算，綜整說明如下：

1. 地形參數

利用空載光達資料所產製 1 m x 1 m 解析度的 DEM 資料，配合變數資料集空間解析度設定，採用再取樣方法進行變數資料集建構。本研究所使的地形相關因子，包括高程、坡度、坡向、曲率、平面曲率、剖面曲率、地形濕度指數以及逕流強度指數等，其中曲率、剖面曲率及平面曲率皆透過 ArcGIS Pro 的 Curvature 功能計算取得。曲率為顯示坡度的形狀或曲率，正曲率表示該單元的表面向上凸。負曲率表示該單元的表面向下凹。值為 0 表示表面是平坦的。剖面曲率反映地形曲面沿垂直方向的變化率。平面曲率則反映地形曲面沿水平方向的變化率。坡向主要分為 8 類，坡向分類標準如表 8。

表 8 坡向分類表

坡向類別	方位	方位角（度）
坡向 1	北	337.5~22.5
坡向 2	東北	22.5~67.5
坡向 3	東	67.5~112.5
坡向 4	東南	112.5~157.5
坡向 5	南	157.5~202.5
坡向 6	西南	202.5~247.5
坡向 7	西	247.5~292.5
坡向 8	西北	292.5~337.5

另外，有關地形濕度指數 TWI 的公式如式(4)：

$$TWI = \ln \left(\frac{A}{\tan(\beta)} \right) \quad (4)$$

A 為各網格上游匯集面積， β 是坡度， $\ln$ 是自然對數。

TWI 可以幫助確定崩塌地區的水分條件，TWI 的值越高，代表該地點的水分聚集程度越高。

逕流強度指數 SPI 的公式如式 (5)，SPI 的值越高，表示該地點的水流侵蝕潛力越大，也代表著強大的水流動力，可能對崩塌地的穩定性構成威脅。

$$SPI = A \times \tan(\beta) \quad (5)$$

A 為各網格上游匯集面積， β 是坡度。

2. 坵塊地景指標

坵塊地景指標主要利用 Fragstats 軟體，針對每個崩塌區塊計算求得。坵塊面積 (AREA) 代表每個坵塊的面積；坵塊周長 (PERIM) 代表坵塊邊界的總長度；周長面積比 (PARA) 代表區塊邊長與面積的比值；分形維數 (FRAC) 是以坵塊的周長與面積的關係來代表形狀的複雜度；近圓形形狀指標 (CIRCLE) 是一種用來評估景觀坵塊形狀相對於理想圓形的近似程度；鄰近指數分佈 (CONTIG) 代表坵塊內部連續性，這指標與坵塊形狀、大小和景觀矩陣的複雜性有關，坵塊地景指標之相

關公式列如表 9。

表 9 使用之坵塊地景指標

地景指標	代碼	公式	描述
坵塊面積	AREA	$AREA = a_{ij}(\frac{1}{10000})$	a_{ij} =坵塊 ij 面積(m ²)
坵塊周長	PERIM	$PERIM = p_{ij}$	p_{ij} =坵塊 ij 周長(m)
周長面積 比	PARA	$PARA = \frac{p_{ij}}{a_{ij}}$	a_{ij} =坵塊 ij 面積(m ²) p_{ij} =坵塊 ij 周長(m)
分形維數	FRAC	$FRAC = \frac{2\ln(0.25p_{ij})}{\ln(a_{ij})}$	a_{ij} =坵塊 ij 面積(m ²) p_{ij} =坵塊 ij 周長(m)
近圓形形 狀指標	CIRCLE	$CIRCLE = 1 - \frac{a_{ij}}{a_{ijs}}$	a_{ij} =坵塊 ij 面積(m ²) a_{ijs} =坵塊最小外接圓面積
鄰近指數 分佈	CONTIG	$CONTIG = [(\sum_{r=1}^z C_{ijr}/a_{ij}^*) - 1]/(V - 1)$	C_{ijr} =坵塊中像元 r 的接觸值 a_{ij}^* =坵塊像元格數的數量 $V=3 \times 3$ 像元模板值的總和

3. 氣象因子

氣溫及雨量，是由臺灣氣候變遷推估資訊與調適知識平台 (TCCIP) 網站下載網格化觀測資料，網格大小為 1 km x 1 km，計算平均氣溫及平均年雨量。

4. 距離因子

本研究所使用因子，包含距林道、距造林地邊界、距崩塌地邊界及距河道距離等計算，主要利用 ArcGIS Pro 中的 NEAR 工具，來計算每個像元到最近的林道、造林地邊界、崩塌地邊界及河道的垂直距離。

5. 植生指標

植生指標主要是用來量測植生之生長況狀，通常可以反應出地表植生的覆蓋程度，本研究所使用之常態化差異植生指標 (NDVI)，主要利用 2009 年 8 月莫拉克風災後的福衛 2 號影像及 2017 年 SPOT6 影像計算求得。

6. 冠層結構指標

冠層結構指標主要利用內政部地政司 2010 及 2017 年空載光達所生成的 DEM 與 DSM 資料，來製作樹冠高度模型 (Canopy Height Model, CHM)，CHM 的計算

方式為將 DSM 減去 DEM，以獲取樹冠的高度資訊，並利用 CHM 計算以下四種冠層結構指標。

冠層覆蓋率 (CCR) 定義為空間單元內，高度超過 2 m 之像元面積佔該單元總面積的百分比，旨在量化樹冠覆蓋於單元內的比例，用以表達冠層覆蓋的程度，其公式如式 (6)。

$$CCR = \frac{\sum_i \text{Area of CHM}_{i, \text{value} > 2\text{m}}}{\text{Area of CHM}_{\text{stands}}} \times 100\% \quad (6)$$

其中 $\text{CHM}(i, \text{value} > 2 \text{ m})$ 表示空間單元內像元值大於 2 m 的第 i 個像元， $\text{CHM}_{\text{stands}}$ 為空間單元內所有 CHM 像元。

平均冠層高 (TCH) 指的是空間單元內冠層高度的平均值，用於量化整體冠層高度，其公式如式 (7)。

$$TCH = \frac{\sum_i \text{CHM}_i}{\text{Number of CHM}_{\text{stands pixels}}} \quad (7)$$

CHM_i 為空間單元內 CHM 的第 i 個像元值。

冠層高度變異數 (VCH) 是指空間單元內樹冠高度的變異係數，用於量化冠層高度的變異程度。VCH 值越高表示冠層高度的變化越大，冠層表面呈現較高的粗糙度，顯示出更多的冠層孔隙；相反，較低的 VCH 值則代表冠層高度差異較小，冠層表面變化較為平緩。該指標能有效反映空間單元內冠層結構的垂直異質性，其公式如式 (8)。

$$VCH = \text{Coefficient of variation of CHM}_{\text{stands}} \quad (8)$$

$\text{CHM}_{\text{stands}}$ 為空間單元內所有 CHM 像元。

冠層容積率 (CVR) 是一種量化空間單元內冠層垂直空間分布程度的指標，用於描述樹冠在垂直空間的分布情形，當其值接近 1 時，代表單元內多數像元的冠層高度接近於該單元的最大值，顯示冠層集中於單一高度範圍，結構相對均質。而其值接近 0 時，代表冠層整體高度總和明顯較低，可能有較多低矮冠層，顯示出結構較為分散或未完全填滿垂直空間，其公式如式(9)。

$$CVR = \frac{\sum_i CHM_i}{\max(CHM) \times area} \quad (9)$$

其中 CHM_i 為空間單元內 CHM 的第 i 個像元值； $\max(CHM)$ 為空間單元中最大 CHM 值；area 為空間單元面積。

七、模型建置

(一)邏輯迴歸

邏輯迴歸是用於預測類別資料的統計模型，其計算方式如公式 (10)，並透過公式 (11) 可求得預測事件發生的機率。

$$F(X) = \ln\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 X_1 + \cdots + \beta_n X_n \quad (10)$$

其中 X 為一系列的自變量， p 為事件發生的機率， $\frac{p}{1-p}$ 這個比值稱為事件的發生比， $\ln\left(\frac{p}{1-p}\right)$ 為發生比之自然對數。

$$p = \frac{\exp(F(X))}{1 + \exp(F(X))} \quad (11)$$

其中 p 為事件發生的機率， $\exp(F(X))$ 為勝算比，即事件成功機率與失敗機率的比值。

在臺灣杉人工林自然演替模型，模型因變數被定義為臺灣杉林地和非臺灣杉林地類型的二元變數模型；在崩塌潛勢與復育研究，因變數被定義為崩塌地和植生二元變數。在進行迴歸分析之前，先對自變數進行資料歸一化處理，主要目的是消除變數之間的尺度差異，由於不同變數可能具有不同的尺度和範圍，尺度差異可能對迴歸模型的性能產生不利影響，資料歸一化可將所有變數縮放到相同的尺度上，以確保它們具有相似的影響力，並有助於模型有效地比較這些變數的效果。

另外模型可能存在自變數之間的高度相關性，即多重共線性，這可能會對預測模型造成影響，因此，本計畫採用皮爾森積差相關分析，將具有顯著共線性的變數從模型中剔除。自變數排除標準的設定在相關分析中相關係數達 0.7 以上 (Shanley et al., 2021)。

(二)隨機森林分類

除了邏輯迴歸外，本研究亦應用隨機森林機器學習方法建立模型。隨機森林為一種機器學習集成模型，創建多棵決策樹以執行分類，一個隨機森林模型是由一系列 N 個決策樹分類器所組成，整體分類決策樹會比單顆決策樹更精確，每個決策樹都有一個投票權（圖 6），最終集合 N 棵樹的決策結果，投票表決方式決定樣本歸屬。每個決策樹會從原訓練樣本中抽取部分樣本進行訓練，從特徵集中隨機抽取 k 個特徵作為節點輸入，以 Gini 指數最小的原則選出最佳屬性進行內部節點連結，最終集合 N 棵樹的決策結果，投票表決方式決定樣本歸屬，而未被選用訓練之樣本通常被稱為袋外（out-of-bag, OOB）樣本，用來估計內部誤差，藉此預測分類的正確率。隨機森林優點為對參數不敏感，不容易產生過度擬合，且訓練速度快，非常適合處理高維度資料的分類問題，且隨機森林可藉由訓練後變數的貢獻度，評估各變數在模型中的重要性。




圖 6 隨機森林集成示意圖

本研究採用 Python 的 scikit-learn 庫中的 RandomForestClassifier 進行分類建模，並配置 100 棵決策樹以優化模型性能 (Milanović et al., 2020; Nafouanti et al., 2021)。

(三)分類模型評估

使用三種預測模型成效的評估方法，分別為準確度評估、操作特性曲線 (Receiver Operating Characteristic Curve, ROC) 及曲線下的面積 (Area Under the Curve, AUC)。主要使用已透過 70%的訓練樣本訓練完成的邏輯迴歸及隨機森林預測模型，針對預留 30%的驗證樣本 (Wang et al., 2019; Dang et al., 2020; Sahani et al., 2021) 資料去進行模型預測及評估。準確度評估係由於二元分類產生的混淆矩陣，即分類誤差矩陣，TP (True Positive) 表示真陽性是正確預測的發生，TN (True Negative) 表示真陰性，表示正確預測為陰性，FP (False Positive) 是假陽性，預測發生但實際未發生，FN (False Negative) 是假陰性，預測為陰性實際為陽性，準確度計算公式如公式 (12) 所示 (Wang et al., 2019; Sevgen et al., 2019; Kuradusenge et al., 2020)。

$$\text{Accuracy} = \left[\frac{(TP+TN)}{(TP+FN+TN+FP)} \right] \times 100\% \quad (12)$$

ROC 曲線是透過繪製各種概率閾值的敏感性與特異性來獲得的，預測模式之敏感度 (Sensitivity) 和特異度 (Specificity)，分別為 TPR 及 TNR (1-FPR) 公式如下式(13)、(14)，藉由 ROC 曲線可評估預測模型之效能 (Wang et al., 2019; Ozkan et al., 2022; Nafouanti et al., 2021; Sevgen et al., 2019; Nhu et al., 2020a; Nhu et al., 2020b)。

$$\text{TPR} = \frac{TP}{(TP+FN)} \quad (13)$$

$$\text{FPR} = \frac{FP}{(FP+TN)} \quad (14)$$

最後，AUC 也經常用於模型性能評估，AUC 越高表明模型擬合的性能越好 (Kuradusenge et al., 2020; Nhu et al., 2020a; Nhu et al., 2020b)。AUC 等於 0.5 表示無鑑別力，大於 0.5 且小於等於 0.7 表示不佳的鑑別力，大於 0.7 且小於等於 0.8 表示可接受的鑑別力，大於 0.8 且小於等於 0.9 優良的鑑別力，大於 0.9 則表示具極佳的鑑別力 (Milanović et al., 2020)。

(四) Cellular Automaton-Markov 預測模型

CA-Markov 模型其中 Markov 模型是依據馬可夫鏈理論，預測事件發生概率的一種方法，由 1907 年俄羅斯科學家 Andrei A. Markov 提出，原理係利用土地利用型演變成各種類型的轉移機率以推測未來土地利用變化的情形，而轉移機率是根據某一時期土地利用之各種狀態的變化求得，如公式 (15) 式中之 S_t 、 S_{t+1} 分別為 t 、 $t+1$ 時期的土地類型；而公式 (16) P_{ij} 為轉換機率矩陣 (Transitional Probability Matrix) (Mansour et al., 2020)。

$$S_{t+1} = P_{ij} \times S_t \quad (15)$$

$$P_{ij} = \begin{bmatrix} P_{11} & \dots & P_{1n} \\ \vdots & & \vdots \\ P_{n1} & \dots & P_{nn} \end{bmatrix} \quad (16)$$

其中 $0 \leq P_{ij} < 1$ ，且 $\sum_{j=1}^n P_{ij} = 1$ ($i, j = 1, 2, \dots, n$)。

CA 是細胞自動機模型，由 20 世紀著名的數學家 John von Neumann 提出。基本概念是假設一個最小的單元體稱細胞，細胞隨時間變化，細胞漸與附近其他細胞互動而改變狀態 (張政亮與張瑞津，2006)，標準的細胞自動體組成有四要件，分別為細胞 (Cells)、狀態 (State)、鄰近區域 (Neighborhoods) 與演化規則 (Transition Rules) 所構成。主要方法為利用前一個狀態與周邊鄰域的狀態按一定規則自主地變化，這過程與 Markov 模型過程相似，唯一不同的區別是應用轉換規則不僅依賴於前一個狀態，而且取決於周邊鄰域的狀態，利用這種空間中相互影響的關係加以演變，即可應用於模擬土地利用的空間和時間動態過程 (Solaimani and Shadman, 2024)。CA 模型的方法，如式 17 所示 (Mansour et al., 2020)。

$$LULC_{i,j}^{t+1} = f(LULC_{i,j}^t, S_{i,j}^t, P_{xy,i,j}^t, N_{ij}^t) \quad (17)$$

$LULC_{i,j}^{t+1}$ 為細胞 i, j 在時間 $t+1$ 潛在的狀態； $LULC_{i,j}^t$ 為細胞 i, j 在時間 t 潛在的狀態； $S_{i,j}^t$ 為細胞 i, j 在時間 t 的轉變潛力； $P_{xy,i,j}^t$ 為細胞 i, j 從土地覆蓋類別 x 轉變為 y 的機率； N_{ij}^t 為細胞 i, j 的鄰近指數。

整體而言，CA-Markov 模型的演化預測，為根據 Markov 轉移機率、鄰近域變化狀態及轉換潛力去進行計算而得。

(五)Random Forest- Cellular Automaton -Markov 預測模型

由於 CA-Markov 在模擬土地覆蓋變遷時，所使用演化規則，即所謂的轉變潛力圖，並無考量土地覆蓋變動與其驅動因子的量化關係，導致模型在動態變遷過程中可能忽略關鍵的環境與空間影響。因此本研究採用隨機森林模型，透過崩塌潛勢與復育驅動因子訓練土地覆蓋變遷的轉換規則，並生成轉變潛力圖，以取代 CA 模型中原始的演化規則，使模型更能反映不同環境條件對森林變遷的影響。

RF-CA-Markov 模型的作法，主要先利用 RF 模型，確定驅動因素與各土地利用類型之間的關係，並估算可能轉換為其他土地類別單元之機率，再結合 Markov 模型確定每種類別的發生概率。而森林覆蓋的空間過程則由 CA 模型進行估算，以補強 CA 演化規則的現實狀況，會產生更好的預測結果。

本研究主要利用 Terrset 軟體進行 Markov 及 CA 模擬運算，且為使隨機森林模型所產生的崩塌潛勢與復育兩個轉換機率圖，能進一步驅動 CA 模型進行演化模擬，首先將 RF 模型預測機率圖轉換為 TerrSet 軟體可讀取之轉變潛力圖格式 (.rst)，並將兩個潛力圖，結合成 CA 演化規則可讀取的格式 (.rgf 檔)，並作為 CA 模型所需之轉變潛力地圖，透過此方法，即可整合 RF 預測結果與 CA 模型規則演化機制，以提升土地覆蓋模擬過程對環境條件與空間特徵的反應能力。

在 CA 模型參數設定部份，其中迭代次數參數 (Number of Cellular Automata Iterations) 為影響模擬空間變化程度的重要參數，其主要是根據 Markov 轉移矩陣與 CA 轉換規則，將需要轉換的像元分配到適當的土地類別中，反複模擬的次數，直到達到每個土地覆蓋類別預定轉換的面積。迭代次數設定太低，模擬的空間變化趨勢尚無法充分計算，預測轉變情形結果可能低估，但若迭代次數過高，則易導致空間變化模擬過度，預測效果失真 (Mondal et al., 2020)。因此選擇最佳迭代參數，能展現預測模型最佳效果。參考前人研究在迭代次數選擇，多考量預測模擬時間間隔為選定依據。Jana and Choudhary (2022) 及 Douandji et al. (2025) 依據模擬時間間隔分別設定迭代次數為 10 及 15 次。部份學者也透過迭代次數測試分析確定最佳迭代次數，如 Mondal et al. (2020) 依據預測時間間隔為 20 年及 43 年，因此以迭代次數為 10、20、30、43 及 53 進行測試，發現時間間隔較短時，較少的迭代次數可以得到較精確的預測結果；Aljehani (2023)則利用 1 至 200 次迭代次數，發現模型在約 50 次迭代時能達到最佳性能。本研究參考前人研究，針對 2024 年預測

階段，進行 1、3、5、7、10、15 及 20 次不同迭代次數之敏感性分析，並透過與實際 2024 年土地覆蓋圖進行精度驗證，分析不同迭代次數下之預測表現與空間合理性。最終依據 Kappa 值與整體準確度選定最佳迭代參數，以作為 2031 年預測模擬依據。其他參數設定，尚包含細胞自動機鄰域濾波類型 (Cellular Automata Filter Type) 及比例誤差 (Proportional Error)，前者為 CA-Markov 模型中用以控制空間鄰域影響的設定參數。它定義了每個像元在模擬轉變時，應考量周圍哪些鄰近像元，以及這些鄰近像元對其影響力的分布方式。常見設定如標準 5×5 鄰域濾波器，即以中心像元為核心，考量其周圍 24 個像元，並賦予等權重，用以模擬均勻的空間擴散效應。考量本研究為模擬大尺度變遷並參考前人研究，在鄰近區域的規則，本研究採取 5 x 5 鄰域濾波器 (Arora et al., 2021; Zhang et al., 2023; Asif et al., 2023; Beroho et al., 2023)。比例誤差為控制轉變潛力圖的容許變動程度，設定適當參數可以模擬自然系統中潛在的隨機變異性，考量本研究為大尺度模擬，並且參考前人研究設定比例誤差為 0.15 (Zhou et al., 2020)。

(六) 預測模型驗證

本研究評估 RF-CA-Markov 和 CA-Markov 兩種模型的預測效能，主要透過比對其所預測的 2024 年土地覆蓋型圖與實際 2024 年土地覆蓋型圖的模型驗證結果。模型驗證的方法主要採用整體準確度及 Kappa 值兩種指標，以量化模型在土地覆蓋變遷模擬上的適用性與精度。

驗證過程主要利用 Terrset 軟體的 IDRISI Image Processing 模組，對土地覆蓋型預測與實際全區進行像元層級比對，並進一步透過準確度與 Kappa 值進行比較分析，以評估 RF-CA-Markov 與 CA-Markov 模型模型在不同轉變潛力圖來源下之預測表現，進一步分析機器學習演算法對細胞演化模擬空間精度之影響。

第四章 結果與討論

第一節 臺灣杉人工林自然演替

一、臺灣杉造林地現況

以 2020 年航照影像判釋六龜臺灣杉造林地現況組成，發現 25 塊臺灣杉造林地現存臺灣杉面積僅佔 53.7%，轉變為針闊混淆林面積佔 24.1%，轉變為闊葉樹林型佔 12.8%，崩塌復育地佔 9.0%，崩塌地佔 0.3%，草生地佔 0.1%，覆蓋型面積及百分比如表 10。

表 10 臺灣杉造林地 2020 年現況覆蓋型面積及百分比

土地覆蓋型	面積 (ha)	百分比 (%)
臺灣杉	222.7	53.7
闊葉樹林型	53.1	12.8
針闊混淆林	100.1	24.1
崩塌復育	37.4	9.0
草生地	0.4	0.1
崩塌地	1.4	0.3
總計 (ha)	415.1	100

研究結果顯示早期六龜試驗林臺灣杉造林地，經過 30、40 年後近 40%轉變為針闊混淆林、闊葉樹林型。臺灣杉人工造林地轉變為針闊混淆林及闊葉樹林型的趨勢，與 Hsu and Cheng (2000) 透過 1988 年及 1996 年之航照影像發現六龜試驗林內天然林取代了許多人工林所得結果一致。透過六龜試驗林 2020 年航照判釋所呈現臺灣杉與非臺灣杉之分布圖（圖 7）可明顯看出臺灣杉在鳳崗及多納兩林區生長情形不同，在鳳崗林區（北區）存留較大面積的臺灣杉（臺灣杉區域為深綠色），而在多納林區（南區）有近半數面積比例轉變為非臺灣杉（非臺灣杉區域為淺綠色）。這結果與陳麗琴等 (1997) 所提出六龜試驗林北部較高海拔山區提供了較佳的台灣杉生長環境，而南部低海拔丘陵則屬生長劣勢地現象一致。




圖 7 造林地 2020 年臺灣杉與非臺灣杉分布圖

二、 全區模型建置

(一)模型變數

模型因變數，主要以「臺灣杉」及「非臺灣杉」兩種類別為主，即以 2020 年航照判釋成果來進行類別分類。航照判釋結果為「臺灣杉」在因變數即歸為「臺灣杉」類別，航照判釋屬於闊葉樹林及針闊葉混淆林兩種林型，在因變數歸類為「非臺灣杉」類別。

自變數的部份，選取高程、坡度、坡向、溫度、雨量、林齡、距造林地邊界距離、距林道距離等 8 個潛在影響臺灣杉自然演替的因子，其空間分佈情形如圖 8-15。此模型將所有自變數集成一個具有相同解析度的資料集，其空間解析度為 1 m，並隨機抽取樣本數量 20,000 筆，其中抽取樣本 70% 作為訓練樣本，其餘 30% 作為驗證樣本以評估模型精度 (Wang et al., 2019; Dang et al., 2020; Sahani et al., 2021)。




圖 8 高程因子




圖 9 坡度因子




圖 10 坡向因子




圖 11 林齡因子




圖 12 距造林地邊界因子




圖 13 距林道距離因子




圖 14 雨量因子




圖 15 溫度因子

(二)變數相關分析

為避免模型變數共線性的影響，先針對 8 個自變數進行相關分析，所得結果如表 11，由表中相關係數可看出相關性最高的為高程與氣溫，相關係數為 -0.825，其絕對值 > 0.7 符合本研究設定之排除準則，因此氣溫變數於後續分析不予納入。

表 11 臺灣杉造林地變遷變數相關分析結果

	TM	SP	RA	DR	DB	DEM	AP	AG
TM	1	-	-	-	-	-	-	-
SP	0.101	1	-	-	-	-	-	-
RA	0.392	0.081	1	-	-	-	-	-
DR	-0.096	0.032	0.289	1	-	-	-	-
DB	0.033	0.028	0.106	-0.06	1	-	-	-
DEM	-0.825	0.084	0.047	0.022	.004	1	-	-
AP	0.185	0.067	0.512	-0.124	0.136	0.031	1	-
AG	0.188	0.068	0.649	-0.296	0.078	0.036	0.466	1

註:TM 為溫度；SP 為坡度；RA 為雨量；DR 為距離林道距離；DB 為距造林地邊界距離；DEM 為高程；AP 為坡向；AG 為林齡

(三)邏輯迴歸

排除氣溫變數，並投入其餘 7 個變數納入建模，產出結果如表 12，從自變量的顯著性值可看出所有的變數顯著性值皆小於 0.001，代表所選取之自變量全部具有顯著性差異，可有效解釋臺灣杉與非臺灣杉之出現機率，當迴歸係數為正值時，該變數數值增加，非臺灣杉發生的機率亦增加，而迴歸係數負值時，該變數數值增加，非臺灣杉發生的機率會減少，所以林齡、坡向、距造林地邊界之距離、坡度及雨量均為負值，代表數值愈大，對臺灣杉存留愈有利，而高程及距林道之距離變數均為正值，數值愈大，則非臺灣杉發生的機率愈大，由係數大小可推估影響邏輯迴歸預測模型之重要變數依序為坡向、高程及距林道之距離。將隨機抽樣所保留之 30%驗證樣本代入預測模型，所得之分類誤差矩陣如表 13，整體判釋正確率約為 69.9%。

表 12 邏輯迴歸參數與係數

	Estimate Coefficients	Std. Error	Wald	df	顯著性	Exp (B)
AG	-0.002	0.000	356.252	1	<0.001	0.998
AP	-0.230	0.009	717.183	1	<0.001	0.795
DEM	0.135	0.012	134.245	1	<0.001	1.144
DB	-0.002	0.000	474.633	1	<0.001	0.998
DR	0.020	0.002	137.892	1	<0.001	1.020
RA	-0.002	0.000	19.195	1	<0.001	0.998
SP	-0.002	0.000	473.001	1	<0.001	0.998

表 13 邏輯迴歸分類誤差矩陣

實際資料	預測資料		準確度
	臺灣杉	非臺灣杉	
臺灣杉	3384	144	95.9%
非臺灣杉	1662	810	32.8%
準確率			69.9%

有關模式係數的 Omnibus 檢定，本模型所得之卡方值為 4261.646，顯著性 $p < 0.01$ ，表示本模式所選取的自變項能有效的聯合影響依變項。Hosmer 與 Lemeshow 檢定，所得之卡方值為 185.312，顯著性 $p < 0.01$ ，代表本模型預測值和實際觀測值之間存在一定的差異，模型校準度差。另外為瞭解邏輯迴歸模型的預測能力，利用 SPSS 計算邏輯迴歸預測機率之 ROC 曲線及 AUC 值，所得結果如圖 16，從 ROC 曲線可看出模型預測曲線良好，且 AUC 為 0.802，代表模型預測具有優良的鑑別力。將全區自變量代入邏輯迴歸預測模型，並使用 ArcGIS Pro 軟體繪製空間分布的發生機率圖，將發生機率分成 5 個等級：非常低（大於等於 0 且小於等於 0.2）、低（大於 0.2 且小於等於 0.4）、中（大於 0.4 且小於等於 0.6）、高（大於 0.6 且小於等於 0.8）及非常高（大於 0.8 且小於等於 1）(Wang et al., 2019; Milanović et al., 2020)，所產出之全區預測圖如圖 17。




圖 16 邏輯迴歸的 ROC 曲線




圖 17 邏輯迴歸模型全區預測圖

(四)隨機森林

在隨機森林預測模式部份，排除氣溫變數，選用其餘 7 個自變數來進行隨機森林模型演算，30%檢核樣本代入預測模型，所得結果如表 14 分類誤差矩陣，分類準確率達 82.4%。

表 14 隨機森林分類誤差矩陣

實際資料	預測資料		準確度
	臺灣杉	非臺灣杉	
臺灣杉	3248	341	90.5%
非臺灣杉	710	1701	70.6%
準確率			82.4%

本研究進一步計算各變數重要性數值，以了解各變數在模型中的重要等級，在隨機森林中取得重要性的資訊即透過剔除該變數，並將剔除變數的模型與原模型比較，差異越大表示變數越重要，以此方式取得各變數之重要性，所得結果如圖 18，由重要性數值可看出除坡向重要性較低外，其餘 6 個變數，雨量、林齡、坡度、距林道之距離、高程及距造林地邊界之距離重要性數值相近。




圖 18 全區模型隨機森林變數重要性

由兩種模型準確度評估結果來看，邏輯迴歸整體分類精度為 69.9%，而隨機森林可達 82.4%。整體而言，隨機森林模型在臺灣杉與非臺灣杉分類，展現出更優異的預測效能，特別是在非臺灣杉分類部份，邏輯迴歸只有 33.8%，而隨機森林達 70.8%，代表隨機森林模型，相較於邏輯迴模型能掌握到非臺灣杉樣本的特徵，並適合應用於資料分布複雜且特徵間具有非線性的關係。這結果與許多研究一致，發現迴歸建模較無法分辨出森林變量之間的複雜關係 (Chen and Hay, 2011; Chen et al., 2012), Ozkan et al (2022)，也證實隨機森林在異質性森林表現較邏輯迴歸方法好。另外，在模型變數的重要性及貢獻度部份，邏輯迴歸模型，迴歸係數較高具影

響力之變數為坡向、高程及離林道之距離。隨機森林透過變數重要性分析，得到重要性變數依序為雨量、林齡、坡度、距林道之距離、高程及距造林地邊界距離。由兩種模型的重要性分析，可看出高程及離林道之距離均為兩個模型共同具有重要影響力的因子。

三、分區模型建置

根據六龜臺灣杉造林地現況分析結果顯示，六龜地區南北二大林區-鳳岡與多納，其造林地臺灣杉存留狀況呈現顯著差異，北部鳳岡林區臺灣杉存留的比率較高，而南部多納林區則有較高比例的臺灣杉減少(圖 7)。此差異初步反應出區域間在臺灣杉造林地自然演替過程的異質性，而這些差異可能與地形等環境條件有關。多納因位處南部，緯度較低，且年均溫高於鳳岡林區，氣候條件可能不適合臺灣杉的長期生存。另外高程等地形條件也會是造成臺灣杉是否生存或是被天然闊葉林入侵的潛在影響因子。因此為進一步釐清不同環境條件下臺灣杉造林地的存留機制與影響因子，並提升模型釋與預測的準確度，本研究除建立全區模型進行整體分析外，亦依據區域差異，劃分為南北兩區分別建立分區模型，藉此比較不同區域在環境變因下之模型反應差異，並探討區域化管理策略，以因應地區性人工林經營需求。

(一)模型變數與相關分析

分區模型所使用的變數仍參照全區模型所選用之變數進行模型建構，在訓練及驗證樣本部份，則分別在南北區選取各 20,000 筆樣本進行分區建模，變數資料集的空間解析度比照全區模型，以 1 m 解析度進行資料集建置。

皮爾森積差相關分析部份，則分別針對南北區域進行變數共線性分析，所得相關係數結果如表 15、16，在南北區域變數相關性，皆由氣溫與高程兩變數高於所設定門檻值 0.7。本研究利用逐步迴歸方法篩選結果，排除氣溫變數，納入其餘 7 個自變數於後續邏輯迴歸及隨機森林的模型建置。

表 15 北區臺灣杉造林地變遷變數相關分析結果

	RA	TM	DEM	SP	AP	AG	DB	DR
RA	1							
TM	0.024	1						
DEM	0.18	-0.973	1					
SP	-0.061	0.159	-0.169	1				
AP	0.079	0.101	-0.086	0.019	1			
AG	-0.104	-0.117	0.12	-0.44	0.079	1		
DB	0.201	0.072	-0.026	-0.25	0.22	0.104	1	
DR	-0.096	-0.033	0.048	-0.55	0.551	0.426	-0.169	1

註: RA 為雨量; TM 為溫度; DEM 為高程; SP 為坡度; AP 為坡向; AG 為林齡; DB 為距造林地邊界距離; DR 為距離林道距離

表 16 南區臺灣杉造林地變遷變數相關分析結果

	RA	TM	DEM	SP	AP	AG	DB	DR
RA	1							
TM	0.728	1						
DEM	-0.7	-0.997	1					
SP	0.023	0.013	-0.13	1				
AP	-0.58	0.092	-0.101	-0.041	1			
AG	0.766	0.401	-0.378	0.046	-0.143	1		
DB	-0.039	-0.06	0.6	-0.101	-0.062	-0.042	1	
DR	-0.375	-0.069	0.064	0.008	0.088	-0.736	0.792	1

(二)邏輯迴歸

邏輯迴歸模型使用 70%的樣本作為訓練資料，並納入篩選後的 7 個自變數進行建模，包含高程、坡度、坡向、雨量、林齡、距造林地邊界距離及距林道距離，以 SPSS 軟體進行分析，所得結果如表 17 及 18。由結果可看出，北區模型中，坡向及距造林地邊界 2 項變數的顯著性皆大於 0.01，表示對模型預測力並無顯著影響，而雨量、高程、坡度、林齡及距林道距離等 5 項變數，其顯著性均小於 0.01，顯示這些變數對於非臺灣杉發生具有顯著解釋力。南區模型除了坡度及距造林地邊界距離外，其餘 5 項變數雨量、高程、坡向、林齡及距林道距離，顯著性皆小於 0.01 具有顯著性差異，顯示這些變數在南區同樣對非臺灣杉的發生具有顯著影響。

在邏輯迴歸模型中，南北兩區區顯現出坡度與坡向兩項變數的顯著差異，其中坡度在北區具統計顯著性，但在南區則不顯著；反之坡向在北區不顯著，在南區則

呈現顯著性。此結果初步呈現出這兩項變數在不同區域重要性不同，及其對分區模型的影響。

表 17 北區邏輯迴歸參數與係數

	Estimate Coefficients	Std. Error	Wald	自由度	顯著性	Exp(B)
RA	-0.001	0	124.102	1	<0.001	0.999
DEM	-0.002	0	445.322	1	<0.001	0.998
SP	0.027	0.002	227.039	1	<0.001	1.027
AP	-0.016	0.012	1.849	1	0.174	0.984
AG	-0.251	0.008	881.928	1	<0.001	0.778
DB	<.001	0.001	0.253	1	0.615	1
DR	0.002	0	59.828	1	<0.001	1.002
常數	16.301	0.637	654.586	1	<0.001	12003622.4


註: RA 為雨量； DEM 為高程； SP 為坡度； AP 為坡向； AG 為林齡； DB 為距造林地邊界距離； DR 為距離林道距離

表 18 南區邏輯迴歸參數與係數

	Estimate Coefficients	Std. Error	Wald	自由度	顯著性	Exp(B)
RA	-0.034	0.001	1341.46	1	<0.001	0.967
DEM	-0.007	0	1850.47	1	<0.001	0.993
SP	0.004	0.002	5.733	1	0.017	1.004
AP	0.206	0.015	194.694	1	<0.001	1.229
AG	0.184	0.043	17.959	1	<0.001	1.201
DB	-0.001	0.001	2.482	1	0.115	0.999
DR	-0.003	0	699.972	1	<0.001	0.997
常數	102.995	2.058	2505.62	1	<0.001	5.37E+44

(三)隨機森林模型建構

應用隨機森林建模，所得模型變數重要性結果如圖 19。北區模型中，雨量為最重要的影響因子，其次為高程、林齡與距林道距離，而坡度與坡向為貢獻最低的變數；而在南區模型中，則以高程為最重要，其次為雨量、距林道距離與坡向，林齡與坡度則為貢獻最低。



註: RA 為雨量； DEM 為高程； SP 為坡度； AP 為坡向； AG 為林齡； DB 為距造林地邊界距離； DR 為距離林道距離

圖 19 分區模型隨機森林變數重要性

在南北兩區模型中，共同重要影響變數為雨量及高程，這兩項變數的重要性分數遠高於其他變數，顯示其對臺灣杉生長具有關鍵性的影響。根據陳永寬等 (1998) 提到臺灣杉之自然分佈於 2,000 m 左右最盛，性喜空氣濕潤，雨量充沛之環境；陳麗琴等 (1997) 研究發現高海拔（約 1200 m 以上）區域氣候涼濕，較適合台灣杉生長，林木枯死率偏低。因此透過前人研究發現雨量與高程確實是決定其生長的主要因素。另外除了雨量與高程，距林道距離在南北區模型中也是重要變數。陸象豫等 (2019) 指出林道形成的無遮蔽廊道，有利於風媒種子的傳播，日照增加，使陽性樹種在林道上下邊坡處出現頻度顯著增加，因此在林道邊緣有助於自然演替及陽性樹種生長，進而影響林分組成。

其他變數在重要性排序上則呈現南北兩區模型差異。北區模型中林齡具有較高的重要性，而在南區則不明顯；坡向在南區模型中排序較前，但在北區則是最後一位。另外對照邏輯迴歸的結果，發現與隨機森林模型有相近的趨勢，如北區模型中的坡度與坡向及南區模型中的林齡與坡度變數，皆為模型中解釋力較低的變數，反應出兩種模型對變數貢獻度的解釋具一致性。

進一步分析坡向結構，北區人工林多集中於西南、西、西北與南向，而南區則以東北、東、東南及北向為主，兩區在坡向上具明顯差異。參考前人研究，臺灣杉偏好北向山腹（中華林學會，1995），因此坡向在南區成為影響臺灣杉存留的重要因素，符合生態習性。在坡度條件方面，南、北兩區之臺灣杉人工林分布位置平均坡度約為 30 度，顯示該坡度範圍為臺灣杉早期造林作業常見之選址環境。此外，多項調查報導指出，臺灣杉天然林多呈群聚狀態分布於人跡罕至之深山區域，如雙

鬼湖地區等，其生育地多位於坡度陡峭之山地環境，顯示臺灣杉對於坡度條件之生長限制相對不高，亦與本研究結果中坡度對臺灣杉造林地分布變異解釋力較低的發現相符。

(四)預測模型評估

為評估預測模型之效能，將預留 30%的驗證樣本及已建立完成之預測模型進行演算，並使用準確度、ROC 曲線及 AUC 曲線下面積方式進行模型評估。在準確度評估部份，邏輯迴歸及隨機森林分區模型結果如表 19，由表中可看出隨機森林分區模型準確度在南北區域分別為 97.8%及 94.8%，遠超過邏輯迴歸分區模型的 75.7%及 63.7%。

表 19 南北區邏輯迴歸與隨機森林分類準確度比較

	邏輯迴歸	隨機森林
北	63.7%	94.8%
南	75.7%	97.8%

經計算兩種分區模型各種概率閾值的敏感性與特异性所繪製出之 ROC 曲線及 AUC 值如圖 20，由曲線形態可看出隨機森林分區模型較邏輯迴歸佳，而且南區模型又較北區模型佳。邏輯迴歸分區模型在北南區域 AUC 分別為 0.729 及 0.852，而隨機森林分區模型在北南區域分別為 0.988 及 0.998。




圖 20 邏輯迴歸與隨機森林 ROC 曲線與 AUC 值 (a)邏輯迴歸北區模型，(b)隨機森林北區模型，(c)邏輯迴歸南區模型，(d)隨機森林南區模型

(五)非臺灣杉發生機率預測圖

依據 RF 及 LG 兩種分區模型製作南北區非臺灣杉發生的機率，亦即原為臺灣杉後轉變成非臺灣杉之機率，將機率分成五個等級：非常低（大於等於 0 且小於等於 0.2）、低（大於 0.2 且小於等於 0.4）、中（大於 0.4 且小於等於 0.6）、高（大於 0.6 且小於等於 0.8）及非常高（大於 0.8 且小於等於 1），並繪製成非臺灣杉發生的機率分布圖，如圖 21 及 22，並且分別計算每個等級所佔面積百分比如表 20。

由表中可看出邏輯迴歸模型所產生之機率在每個等級的機率相較於隨機森林模型，隨機森林模型的機率分布多集中在非常低及非常高之等級，在北區非臺灣杉發生機率在非常低的等級佔比較高約佔 68.0%，南區非臺灣杉發生機率在非常高等級佔比較高約 61.0%，代表北區臺灣杉變動的機率較低，而南區臺灣杉變動為非臺灣杉的機率較高，此結果與面積分析結果（表 21）北區臺灣杉面積佔比約 67.2%，而南區非臺灣杉面積佔比約 58.6%結果接近，代表隨機森林模型機率分布在非常低與非常高的情形較邏輯迴歸模型明顯，並與實際現況吻合，提供了臺灣杉人工林轉變機率預測之空間分布資料。

表 20 邏輯迴歸與隨機森林南北區非臺灣杉發生機率

非臺灣杉發生 機率佔比	等級	北區		南區	
		LR	RF	LR	RF
$0 \leq p \leq 20$	非常低	1	68	28	31
$20 < p \leq 40$	低	20	7	18	3
$40 < p \leq 60$	中	29	4	11	2
$60 < p \leq 80$	高	27	5	25	3
$80 < p \leq 100$	非常高	23	16	18	61

表 21 北區 2020 年土地覆蓋型面積比較

土地覆蓋型	北區		南區	
	面積 (ha)	面積佔比(%)	面積 (ha)	面積佔比(%)
臺灣杉	169.5	67.2	53.1	32.6
闊葉樹	42.5	16.8	10.7	6.6
崩塌復育	24.4	9.7	13.0	8.0
針闊混淆林	15.2	6.0	84.8	52.0
草生地	0.4	0.2	0.0	0.0
崩塌地	0.1	0.1	1.3	0.8
合計	252.1	100	162.9	100

綜合本研究分區模型三種驗證結果，可明顯看出隨機森林模型在預測非臺灣杉發生機率方面表現最為優異，整體準確度與 AUC 值均高於邏輯迴歸分區模型，此結果與多項相關研究一致 (Ahemd et al., 2015; Guo et al., 2016; Sevgen et al., 2019; Milanović et al., 2020; Ozkan et al., 2022)。由於邏輯迴歸為單一參數模型，隨機森林屬集成學習演算法，可同時考量多組特徵交互作用，因此在處理複雜非線性問題時，往往展現更高的準確性。比較南北區模型分類準確度驗證樣準確度部份，隨機森林北區及南區模型的準確度都高於 90%，迴歸模型準確度明顯較隨機森林模型低，在 AUC 部份，隨機森林分區模型其值均大於 0.9，代表模型有極佳的鑑別力。




圖 21 北區邏輯迴歸(左)與隨機森林(右)模型非臺灣杉發生機率分布圖




圖 22 南區邏輯迴歸(左)與隨機森林(右)模型非臺灣杉發生機率分布圖

綜合全區與分區模型比較，全區邏輯迴歸模型的準確率為 69.6%，而分區後無論是隨機森林或邏輯迴歸預測準確度均有明顯提升。以隨機森林模型為例，北區與南區的準確度分別達 94.8%與 97.8%；邏輯迴歸模型在南區為 75.7%，僅有北區模型為 63.7%低於全區模型準確度，其他皆高於全區模型，顯示出分區建模，尤其是以隨機森林建模，在預測臺灣杉人工林變動時確有優勢。AUC 分析方面，全區邏輯迴歸模型 AUC 值為 0.802，而隨機森林模型南北區則分別高達 0.998 與 0.988，表現極佳；即使是在邏輯迴歸模型中，南區模型其 AUC 亦達 0.852，優於全區模型 AUC 值的 0.802。

此外，模型中各變數在南北兩區的重要性排序與顯著性差異亦有所不同，顯示

區域性環境條件會影響臺灣杉的變動機制。因此，從模型效能與變數解釋力來看，採用分區建模並選用適合的模型演算方法，不僅有助於提升分類準確性，更有助於掌握地區間人工林的變動趨勢，進而提出更具區域性與實用性的森林管理建議。

第二節 崩塌復育

此章節主要使用材料為林業保育署所提供的 2009-2018 年，每年一期的崩塌地向量圖，來進行長期崩塌地變動與復育分析。由於該資料目前僅提供至 2018 年，本章節先就現有資料範圍進行初步分析，以掌握過去十年間崩塌地空間分布與變化趨勢，並做為接續研究之參考。

一、 莫拉克颱風後崩塌變遷分析

在崩塌地變遷分析部份，利用 2009 年崩塌地圖（莫拉克颱風發生前）與 2010 年崩塌地圖（莫拉克颱風發生後），透過變遷分析萃取出新增崩塌地，作為基線資料，並分析 2011 至 2018 年崩塌地圖，找出基線崩塌地後來自然復育的區位，即為由崩塌轉變為植生的區域，並進行後續的分析，為確保研究的精確性和可靠性，在 2011 至 2018 年的分析中排除了原屬崩塌地，自然復育後又再次崩塌區域，並假設其為受新氣候事件（例如颱風或豪雨）所引發的再次崩塌，這些被排除的區域不納入分析範圍，以更聚焦在研究六龜試驗林莫拉克颱風所引發之崩塌及自然復育的過程。

此外，為了確定林地類型（天然林或人工林）對各時期的復育的影響，使用 ArcGIS Pro 將 2011 至 2018 年的自然復育圖層與造林台帳圖層進行套疊，並計算復育區域在天然林和人工林中的面積分布，以評估這兩種林地類型在復育過程的情形。

本研究針對 2010 至 2018 年間每年崩塌地及其復育面積的變化進行了統計分析，分析結果如圖 23 所示，圖中三條線分別代表不同年份的崩塌地面積、復育面積及復育後再次崩塌的面積，在崩塌地面積變化部份，從圖中藍色線條可見，崩塌地的總面積在最初兩年急劇下降，而自 2013 年起呈現緩慢的減少趨勢，橘色線條則顯示復育的面積變化，2012 年復育面積達到最大，然而之後受到各種干擾的影響，復育區域經常遭受再次崩塌的影響，導致復育面積的變化始終維持在一個相對

穩定的水平，灰色線條代表復育區域再次崩塌的面積，除 2013 年和 2018 年再次崩塌的面積較多，其餘年度大致維持一定面積。

本研究聚焦於莫拉克風災後的六龜試驗林區域，探討崩塌地景結構變化和復育情況，為排除其他干擾事件的影響，以每年的崩塌地圖層為基礎進行分析，排除已復育但再次崩塌的區域，以確保所研究的事件受到單一事件的影響。分析結果指出，2013 年和 2018 年再次崩塌的面積較多，與 2013 年臺灣發生多場重大豪雨事件，包括蘇力颱風、潭美颱風、康芮颱風和天兔颱風等及 2018 年臺灣南部也 823 水災事件有關，推測這些豪雨事件可能導致了大量的崩塌，進一步增加了再次崩塌的面積。




圖 23 2010-2018 年崩塌與復育面積

本研究亦比較了天然林和人工林中的復育面積，針對 2011 年至 2018 年間的資料進行分析，將天然林與人工林復育面積與全區復育面積進行比較，結果如圖 24 所示，在此期間內，自然復育發生在天然林(橘色)的比例介於 83.7%至 86.5% 之間，在人工林(藍色)的比例介於 13.5%至 16.3% 之間，自然復育區域分布在天然林與人工林的比例，在多數年份皆維持相對穩定的水準。依據這樣結果推論在六龜試驗林，自然復育的影響因素可能並非林地類型，而是受到其他環境條件的潛在驅動因子影響，所以不論是天然林還是人工林，只要具備環境的條件，皆可促使自然復育的發生。




圖 24 天然林與人工林內自然復育面積佔全區復育面積比較

二、 空間自相關

本研究針對 2011 年至 2018 年期間，崩塌地復育區位進行空間自相關分析，主要使用 Moran's I 指標去進行顯著性檢定，其結果如表 22，根據所得結果，在 2011 年崩塌地生態復育區域表現出了顯著的空間自相關性 ($P < 0.01$)，這表示 2011 年的復育區域在空間上存在明顯的關聯性，然而，從 2012 年至 2018 年，崩塌復育區域的空間分佈呈現隨機分散，顯著性檢定結果的 P 值均大於 0.01，這代表復育區域在這段時間內不再呈現明顯的空間自相關性特徵。

根據分析結果，2011 年復育區域呈現顯著的空間自相關，顯示此年度內崩塌復育集中在特定地區進行，然而，2012 年至 2018 年的復育區域空間自相關則未顯著，可能是由於在復育過程中存在其他干擾因素，這些干擾因素對崩塌地的復育進程造成了重大影響，影響了復育地區的空間分佈和連續性，因此未呈現出明顯的群聚特性。

表 22 空間自相關結果

Year	Moran's Index	P-Value
2011	0.0636	<0.0001
2012	-0.0011	0.8788
2013	-0.0004	0.8105
2014	-0.0001	0.6717
2015	0.0001	0.5719
2016	0.0002	0.5265
2017	0.0003	0.4866
2018	0.0001	0.6064

三、 地景指標

本研究對 2010 年至 2018 年期間的崩塌地地景層級指標進行了全面分析，結果如圖 25 所示，圖中顯示，區塊數量 (NP)、邊緣密度 (ED)、景觀形狀指標 (LSI) 及分離度指標 (SPLIT) 均呈現長期下降的趨勢，這反映了崩塌地地景結構的演變，長期來看，崩塌區塊數量逐漸減少，也呈現出崩塌地區域的複雜度降低、崩塌區塊形狀簡化，以及整體景觀的連續性和一致性增強，此外，聚集度指標 (CONTAG) 指標呈現上升趨勢，表明崩塌地在整體景觀的聚集程度逐漸增加。

綜合各地景層級指標的變化，觀察到莫拉克風災後的地景結構，崩塌地的數量逐年減少，且地景的複雜度逐漸減弱，此外，崩塌地的形狀也呈現簡化的趨勢，同時整體景觀呈現更多的連續性和一致性，這些長期趨勢似乎顯示出地景結構具自然復原的潛力。




圖 25 2010-2018 年崩塌地景指標折線圖

碎形維度指標 (PAFRAC) 於 2010 至 2013 年呈現大幅下降，顯示此時期崩塌地地景結構複雜度逐漸降低，邊界形狀趨於簡單化。在 2013 至 2016 年期間，指標維持平穩狀態，代表這段時間，地景破碎程度未出現顯著波動。然而 2016 至 2018 年間，指標再度上升，顯示崩塌區塊的邊界形狀變得更加複雜，地景破碎程度增加。整體而言，此一變化趨勢可能反應出崩塌地歷經初期大規模破壞後，隨時間推移，自然復育或後續崩塌動態的影響，導致地景結構再次趨於破碎與複雜，特別是後期 2017-2018 年指標快速回升，透過指標可初步看地景結構空間動態變化的現象。

四、崩塌復育模型建置

(一)模型變數

崩塌復育是一個受多重因素影響的高度複雜過程，本研究主在透過建立崩復育預測模型，深入分析影響崩塌復育的關鍵驅動因子。模型因變數主要為崩塌與崩復育的二元狀態，崩塌地類別指的是自 2010 年的崩塌範圍一直持續到 2018 年仍然保持崩塌狀態的區域，而崩塌復育類別指的是 2010 年屬於崩塌範圍但到了 2018 年不再屬於崩塌範圍的區域，即被視為已經發生復育的區域。自變數部份，所選用的變數包含高程、坡度、坡向、地形濕度指數、逕流強度指數、溫度、雨量、坵塊面積 (AREA)、坵塊周長 (PERIM)、周長面積比 (PARA)、分形維數 (FRAC)、近圓形形狀指標 (CIRCLE)、鄰近指數分佈 (CONTIG)及距崩塌地邊界共 14 個可能影響崩塌復育的變數，納入預測模型建構。變數空間解析度為 10 m，樣本數量 20,000 筆，其中 70% 作為訓練樣本，其餘 30%作為驗證樣本以評估模型精度。

(二)變數相關分析

本研究主要針對 14 個變數進行皮爾森積差相關分析，以評估其間的相關程度，並檢視是否存在潛在的多元共線性問題。分析結果如表 23，由表中可明顯看出一些變數呈現高度相關性，如 AREA 和 PERIM 之間的相關係數為 0.974，PERIM 和 FRAC 之間的相關係數為 0.758，PARA 和 CONTIG 之間的相關係數為 -0.997，DEM 和 TM 之間的相關係數為 -0.985。這些變數之間的高度線性關係，可能導致多元共線性的問題，進而影響模型的穩定性和可解釋性。

表 23 崩塌復育模型變數相關分析結果

	AREA	PERIM	PARA	FRAC	CONTIG	CIRCLE	DEM	SP	AP	TWI	SPI	RA	TM	DS
AREA	1.000													
PERIM	0.974	1.000												
PARA	-0.547	-0.528	1.000											
FRAC	0.661	0.758	-0.404	1.000										
CONTIG	0.558	0.538	-0.997	0.413	1.000									
CIRCLE	0.328	0.397	-0.280	0.689	0.277	1.000								
DEM	-0.135	-0.177	0.051	-0.147	-0.055	-0.100	1.000							
SP	-0.111	-0.110	0.065	-0.082	-0.065	-0.023	0.056	1.000						
AP	-0.078	-0.039	-0.003	-0.013	0.003	0.035	-0.158	-0.150	1.000					
TWI	-0.007	-0.003	0.027	0.013	-0.029	0.032	-0.038	-0.400	0.026	1.000				
SPI	-0.002	-0.003	0.010	-0.005	-0.011	-0.001	-0.022	-0.020	-0.008	0.233	1.000			
RA	-0.024	-0.018	-0.075	-0.011	0.079	0.079	0.015	0.100	-0.092	-0.039	-0.025	1.000		
TM	0.117	0.157	-0.048	0.125	0.053	0.084	-0.985	-0.050	0.158	0.021	0.010	-0.007	1.000	
DS	0.305	0.261	-0.387	0.139	0.394	0.073	-0.008	-0.070	0.014	0.003	-0.008	0.075	0.010	1.000

註: AREA 為坵塊面積; PERIM 為坵塊周長; PARA 為周長面積比; FRAC 為分形維數; CIRCLE 為近圓形形狀指標; CONTIG 為鄰近指數分佈; DEM 為高程; SP 為坡度; AP 為坡向; TWI 為地形濕度指數; SPI 為逕流強度指數; RA 為雨量; TM 為溫度; DS 為距崩塌地邊界

為符合本研究皮爾森積差相關分析所設定的變數篩選原則，即相關係數達 0.7 以上視為具有高度相關性並需排除，本研究剔除 PERIM、PARA 及 TM 等三個變數，以避免多元共線性對模型產生干擾。最後選取其餘 11 個變數納入邏輯迴歸分析中，以評估其對崩塌地復育的影響，並進行模型建構。

(三)邏輯迴歸

為減少變數單位不同對模型的影響，先將 11 個自變數進行歸一化處理，再利用 SPSS 軟體進行邏輯迴歸模型推估，所得結果如表 24，由表中可看出所有變數的 VIF 值均小於 10，代表模型中變數已不具多元共線性的問題，此外，所有變數的 P-value 均小於 0.01，顯示這些變數可有效解釋崩塌復育發生的機率。

表 24 崩塌復育模型邏輯迴歸參數與係數

	B	S.E.	Wald	P-value	Exp(B)	VIF
AREA	0.501	0.021	574.262	<.001	1.651	2.410
FRAC	-0.239	0.023	112.52	<.001	0.787	3.244
CONTIG	-0.907	0.027	1128.105	<.001	0.404	1.627
CIRCLE	0.211	0.017	158.758	<.001	1.235	2.067
DEM	-0.418	0.012	1267.522	<.001	0.659	1.059
SP	-0.287	0.014	406.229	<.001	0.751	1.263
AP	0.075	0.012	36.991	<.001	1.078	1.082
TWI	-0.105	0.015	50.661	<.001	0.9	1.279
SPI	0.197	0.053	13.628	<.001	1.218	1.066
RA	0.202	0.012	291.384	<.001	1.224	1.049
DS	-0.757	0.012	3674.223	<.001	0.469	1.223
常數	1.792	0.015	14224.188	<.001	6.004	

註: AREA 為坵塊面積; FRAC 為分形維數; CIRCLE 為近圓形形狀指標; CONTIG 為鄰近指數分佈; DEM 為高程; SP 為坡度; AP 為坡向; TWI 為地形濕度指數; SPI 為逕流強度指數; RA 為雨量; DS 為距崩塌地邊界

由崩塌復育模型的迴歸分析結果顯示，地景指標 CONTIG 為對復育影響最顯著的前五個變數之一。此指標主要用來評估不同坵塊之間連接程度，值越高時表示區塊之間有更多的連接，聚集程度高，而值越低時，表示區塊之間分散，連接性差。本研究結果 CONTIG 迴歸係數為 -0.907，負值表示當 CONTIG 值增加時，崩塌地復育的可能性明顯下降，代表當崩塌地呈現連接性較弱的地景結構時，復育機會相對較高。這結果說明在連通性低的崩塌地，具有較多與非崩塌區域連結之地景結構，有助於崩塌復育和物種分布。

此外，距離崩塌邊界的距離也對自然復育重要的驅動因子，透過迴歸分析顯示其在復育模型的迴歸係數為 -0.757，代表崩塌地越接近崩塌邊界，復育的可能性越高。這可能與邊界地區較易取得外來種源，並具備較穩定的邊緣環境條件，有助於植被恢復。這結果與前人研究一致，靠近崩塌邊界的區域更容易獲得種源，進而促進崩塌地的復育（黃雅莉和陳朝圳，2018；邱清安和徐憲生，2015）。另外，地景指標 AREA 對於復育具有正向影響，其迴歸係數為 0.501，表示崩塌地面積的增加會增加復育的可能性，大面積的崩塌地可能為植物提供更多的生長空間和生態環境，有利於物種多樣性的發展，進而促進復育的進程。

在地形因子方面，高程和坡度皆對復育呈現負向影響，高程的迴歸係數為 -0.418，代表地形越高的地區，自然復育的可能性較低，可能是由於高山地區的氣候和土壤條件不利於植被生長。而坡度的迴歸係數為-0.287，代表坡度較陡的地區，自然復育的可能性較低，可能是因為坡度較陡的地區容易受到水土流失和崩塌的影響，不利於植被的復育。此結果與陳永寬等 (1998) 及顏添明 (1999) 提出的觀點一致，顯示地形條件確為復育成效的重要限制因素。

在模型整體檢定方面，Omnibus 檢定結果卡方值為 10219.768，顯著性 $P < 0.01$ ，顯示模式所選取的自變數能對因變數具有統計上顯著的聯合力。Hosmer 與 Lemeshow 檢定卡方值為 260.291，顯著性 $P < 0.01$ ，代表模型預測值和實際觀測值之間存在一定的差異。進一步透過 ROC 曲線及 AUC 來檢驗模型鑑別能力，所得結果如圖 26，從 ROC 曲線可看出模型預測曲線良好，且 AUC 為 0.801，代表模型預測具有優良的鑑別力。




圖 26 崩塌復育模型 ROC 曲線與 AUC 面積

綜合本章節之研究結果顯示，六龜試驗林自莫拉克颱風後 2010 至 2018 年期間，崩塌地的總面積在最初兩年急劇下降，之後呈現緩慢減少趨勢。在自然復育方面，2012 年復育面積達到最大，但由於後續期間仍有零星干擾事件，自然復育區域常遭受再次崩塌，導致復育面積未能明顯增加。從崩塌地的地景結構變化來看，崩塌地數量逐年減少，地景複雜度降低，且崩塌地形狀趨於簡化，然而，CONTAG


指標呈現上升趨勢，顯示崩塌地在整體景觀中的聚集程度逐漸增加。在自然復育迴歸模型顯示，地景指標 CONTIG、距崩塌邊界的距離、地景指標 AREA、海拔高與坡度等變數，均為顯著影響自然復育潛勢的重要因子。這些結果強調了地景結構對崩塌地自然復育的重要性，分散且大面積的地景結構有利於自然復育，而較低的高度和較緩的坡度也有助於崩塌地的自然復育，此外與種源的距離也是重要的關鍵條件，顯示種子傳播能力與鄰近性在自然演替過程中的重要性。

第三節 崩塌地景監測與潛勢評估

由於前節主要以林業保育署公開提供之 2009 至 2018 年間的多時期崩塌地向量圖層作為研究材料。考量前述資料僅涵蓋至 2018 年，為延長六龜最新時序監測的需求，並取得崩塌以外的土地覆蓋型資訊，因此本節蒐集 2009 至 2024 年間每兩年一期的衛星影像，並運用物件導向與 SVM 進行土地覆蓋分類，建立多時期土地覆蓋型圖層，並且聚焦於崩塌地的變動情形與崩塌潛勢預測的相關研究。

一、 影像分類結果

本研究共使用 10 個時期的衛星影像，時間為 2009 年 5 月、2009 年 8 月、2011、2013、2015、2017、2019、2021、2023 及 2024 年，詳細衛星影像資訊詳如表 2，影像分類方法主要採用物件導向和 SVM 分類，分類類別為崩塌地、植生、裸露地及陰影等四類。分類的結果如圖 27 所示，其中綠色代表植生，紅色代表崩塌地，黃色代表裸露地，黑色代表陰影。從圖中可直觀看出土地覆蓋的動態變化，特別是崩塌地和陰影的轉變。在莫拉克颱風發生後，六龜試驗林崩塌地顯著增加，且分布廣泛，但隨著時間的推移，崩塌地逐漸減少。另一方面，由圖中可看出 2017-2024 年陰影所佔面積較 2009-2015 年多，主要原因為蒐集衛星影像時，主要目標以全區無雲影像為主，其次以夏季影像為輔，在山區夏季時段影像受地形效應相較於冬季影像小，陰影也較少。然在搜尋研究區範圍 SPOT 或福衛二號衛星影像時，2009-2015 年尚可蒐集到 4-8 月全區無雲影像，但 2017 年至 2024 年要找到全區無雲的影像，僅集中在 11-12 月及 1-2 月間，也因此陰影相對較多。






圖 27 六龜試驗林多時序土地覆蓋型圖

每期影像均選取 1,000 個隨機分佈的檢核點，計算分類結果的整體精度與 Kappa 值，結果如表 25 所示。從表中可看出，整體精度均超過 90%，顯示分類結果具有高度準確度。此外，Kappa 值均高於 0.88，代表分類模型效能良好。這些結果證明了物件導向結合 SVM 分類方法，在使用衛星影像進行長期崩塌監測方面，具有可行性與準確性。

表 25 影像分類整體精度與 Kappa 值

year	整體準確度	Kappa
2009/05	97.90%	0.95
2009/08	98.20%	0.97
2011	94%	0.91
2013	96.40%	0.94
2015	92.10%	0.89
2017	98.10%	0.97
2019	97.90%	0.97
2021	91.40%	0.88
2023	97.50%	0.96
2024	99%	0.98

二、 崩塌地變遷分析

使用 ArcGIS 的空間分析工具，對每期處理後的土地覆蓋型圖進行崩塌地面積的量化。主要目的是準確計算和比較不同時期崩塌地的面積，從而偵測崩塌地的動態變化趨勢。

為避免每期影像陰影變化對多時序崩塌地變遷分析造成影響，在進行分析前，本研究將每期土地覆蓋類型圖中的陰影區域進行統一處理，主要是將 10 期土地覆蓋圖中陰影聯集區域扣除（圖 28），並在此基礎上抽取崩塌地圖層進行變遷分析，以確保多時序崩塌地變遷分析的一致性。




圖 28 扣除陰影聯集區域之多時序土地覆蓋型圖

針對每期土地覆蓋型圖，本研究計算了崩塌地的面積，並繪製了時間序列崩塌面積變化圖(圖 29)。從圖中可以觀察到崩塌地面積在這段時間內的動態變化情況。2009 年 5 月至 2009 年 8 月期間，崩塌地面積從 111.9 ha 急劇增加至 748 ha，反應了莫拉克颱風期間的大豪雨，造成了六龜試驗林極大的災害，崩塌面積爆增近 7 倍。此後在 2009 年 8 月到 2011 年，崩塌地面積有所下降，減至 463.489 ha，之後幾年崩塌地面積相對穩定，在 471.9 ha 至 473.1 ha 之間波動。但自 2017 年開始，崩塌地面積呈現持續下降趨勢，從 357.3 ha 降至 2024 年的 230.5 ha。




圖 29 多時序崩塌面積變化折線圖

在新增崩塌地分析部份，本研究以 2009 年 8 月 19 日莫拉克颱風後所形成的崩塌地為基線資料，分析 2011 年至 2024 年間各時期新增的崩塌地面積，並繪製新增崩塌面積的時間序列變化圖（圖 30）。從圖中可以看出，2011 年新增崩塌面積為 88ha，至 2013 年顯著上升至 253 ha，之後 2015 年略降至 244.1 ha，至 2019 年進一步減少至 127.9 ha，顯示崩塌活動有逐漸趨緩之趨勢。然而，從 2023 年到 2024 年，新增崩塌地面積再次上升至 157.5 ha，顯示區域內崩塌活動再加劇。




圖 30 多時序新增崩塌面積變化折線圖

綜合圖 29 與圖 30，可發現新增崩塌面積於 2011-2015 及 2023-2024 年呈現顯著增幅，對應在圖 29 中，總崩塌面積於此兩時段呈現為水平的變化趨勢，顯示總崩塌面積未持續減少，反應出新增崩塌活動抵消了原有崩塌地的復育效應。這種崩塌持平現象，主要歸因於期間內再次發生干擾事件，造成新的崩塌地形成，進而影響整體崩塌面積的變化。

進一步比對此兩個時段與實際災害事件，發現在 2011-2015 年間，研究區域曾

受到 2012 年泰利颱風、2013 年蘇力颱風、康芮颱風和天兔颱風的接續影響。而 2023-2024 年間，則分別受到 2023 年的海葵及凱米兩次颱風侵襲。這些颱風所伴隨之強降雨對六龜試驗林造成重大的衝擊，為新增崩塌地形成的主要誘因。透過時間序列所顯示的新增崩塌面積變化趨勢，與實際災害事件高度吻合，進一步佐證干擾事件對於山區崩塌活動之影響。

三、地景指標分析

利用 Fragstats 軟體計算了 10 個時期的崩塌地在地景尺度的關鍵指標，包括區塊數目 (NP)、邊緣密度 (ED)、景觀形狀指數 (LSI)、碎形維度 (PAFRAC)、聚集度指數 (CONTAG) 以及分離度指數 (SPLIT)。這些指標反映了崩塌地的空間結構、形狀複雜性及聚集分散特性。研究結果透過折線圖呈現不同時期這些地景指標的變化情況，如圖 31 所示。






圖 31 多時序崩塌地 6 種地景指標折線圖

整體而言，地景指標 NP、ED、LSI 及 SPLIT 在 2009 年 8 月（即莫拉克颱風後）達到最高值，隨後呈現下降趨勢。這些指標的變化，代表隨著時間推移，地景的破碎化程度逐漸減少，各區塊形狀複雜度降低，地景的分散程度也有所減少。

與此相反，地景指標 CONTAG 顯示出相反趨勢，這反映了地景連續性的增強，隨著破碎化減少，地景逐漸穩定並變得連續。PAFRAC 指標的變化趨勢相較於其他 5 個地景指標，並未呈現明顯的上升或下降趨勢，除 2009 年 5 月莫拉克颱風前出現最低值外，其餘年份的指數變化呈現波動狀態，整體趨勢起伏不定。然而，仍可觀察到兩個明顯的高峰，分別出現在 2009 年 8 月至 2015 年及 2021 至 2024 年，顯示這兩個時期地景邊界的形狀較為複雜，結構破碎化程度較高。Wang et al. (2014) 指出 PAFRAC 指標對空間格局破碎變化極為敏感，羅紅等 (2021) 亦指出森林在

遭受擾動導致的破碎化過程中，PAFRAC 指標通常比 NP、ED、LSI 更準確反應出地景結構的改變。因此 PAFRAC 指標是具高度敏感度的地景指標，能有效偵測干擾事件發生的指標。PAFRAC 指標變化所顯示出兩個高峰時段，亦與前述新增崩塌面積時間序列變遷分析的結果相呼應，進一步驗證 PAFRAC 指標作為干擾偵測的可行性。

四、崩塌潛勢模型建置

(一) 模型變數

本研究主要透過兩個時期土地覆蓋型圖層及崩塌潛在驅動因子，建構崩塌潛勢預測模型。在模型的因變數部份，係由土地覆蓋型圖中擷取崩塌與非崩塌地的二元分類結果。其中，非崩塌地類別指自 2009 年 8 月莫拉克颱風後至 2024 年期間，未發生崩塌的區域，而崩塌地類別則指自 2009 年 8 月後莫拉克颱風後至 2024 年間新增崩塌區域。二元類別的設定主要在於界定崩塌事件的發生與否，以進行後續的崩塌潛勢預測分析。自變數部份，主要選取高程 (DEM)、曲率 (CUE)、地形濕度指數 (TWI)、逕流強度指數 (SPI)、坡度 (SP)、平面曲率 (PNE)、剖面曲率 (PFE)、距河道距離 (DR)、坡向 (AP) 等 9 項地形與水文相關因子作為潛在驅動變數。至於氣象因子部份，在此處未納入建模，主因其空間解析尺度較為粗略，與地形變數所採用資料的空間解析度存在顯著的差異，雖氣象因子對崩塌觸發具關鍵作用，惟考量尺度問題，將優先納入地形與水文因子建模並探討對模型的解釋力。後續可視需求進一步整合氣象變數進行多尺度模型測試與比較。此部份設定資料集空間解析度為 10 m，樣本數量 20,000 筆。

(二) 變數相關分析

先針對 9 個自變數，進行皮爾森積差相關分析，所得結果如表 26 所示，表中顯示曲率與平面曲率及剖面曲率高度相關，相關係數分別為 -0.91 與 0.799，均超過研究設定的 0.7 閾值，因此將曲率變數剔除，以提高模型的穩定性。

表 26 崩塌潛勢模型變數相關分析結果

	DEM	CUE	TWI	SPI	SP	PFE	PNE	DR	AP
DEM	1								
CUE	-0.01	1							
TWI	0.027	-0.28	1						
SPI	-0.01	-0.07	0.117	1					
SP	-0.06	0.035	-0.32	0.009	1				
PFE	0.01	-0.91	0.15	0.076	-0.04	1			
PNE	-0	0.799	-0.38	-0.04	0.018	-0.49	1		
DR	0.334	-0.02	0.063	-0.01	-0.12	0.018	-0.02	1	
AP	-0.02	-0.01	0.04	0.01	-0.12	0.017	-0	0.091	1

註: DEM 為高程；CUE 為曲率；TWI 為地形濕度指數；SPI 為逕流強度指數；SP 為坡度；PFE 為剖面曲率；PNE 為平面曲率；DR 為距河道距離；AP 為坡向

(三)模型建構

將納入邏輯迴歸模型的 8 個變數(DEM、TWI、SPI、SP、PFE、PNE、DR、AP)，進行歸一化處理，並利用 SPSS 進行邏輯迴歸模型的推算，結果如表 27 所示，其中 DEM、SP、DR、AP 變數的 P 值均小於 0.01，顯示這些變數對崩塌風險預測具有顯著性，代表高度、坡度、距河道距離和坡向是影響崩塌發生的關鍵因素。因此後續建模僅納入此 4 個變數，以精簡迴歸模型，結果如表 28 所示，其中距河道距離 (DR) 對崩塌潛勢的影響最為顯著，B 值為 -5.067，代表距河道越遠，崩塌風險顯著降低；其次是坡度 (SP)，其 B 值為 1.379，顯示坡度增加對崩塌潛勢有較大的作用；高程 (DEM) B 值為 0.582，代表隨高程增加，崩塌風險顯著上升；坡向的影響相對較小，B 值為 -0.882，代表特定坡向能夠降低崩塌風險。此結果顯示出距河道距離和坡度在崩塌風險預測具較重要的主導角色。本研究結果與 Sevgen et al. (2019) 及 Nhu et al. (2020a) 研究結論相符，這些研究均指出坡度、高程及距河道距離是對崩塌潛勢迴歸模型具顯著貢獻的變數。

表 27 8 個自變數邏輯迴歸分析結果

	B	S.E.	Wald	自由度	顯著性	Exp (B)
DEM	0.582	0.079	54.907	1	<0.001	1.790
TWI	-0.308	0.182	2.869	1	0.090	0.735
SPI	-.247	2.249	0.012	1	0.912	0.781
SP	1.310	0.115	130.215	1	<0.001	3.706
PFE	-1.540	1.514	1.034	1	0.309	0.214
PNE	0.105	0.933	0.013	1	0.911	1.110
DR	-5.062	0.128	1566.967	1	<0.001	0.006
AP	-0.882	0.067	173.145	1	<0.001	0.414
常數	1.603	1.174	1.864	1	0.172	4.966

註: DEM 為高程; TWI 為地形濕度指數; SPI 為逕流強度指數; SP 為坡度; PFE 為剖面曲率; PNE 為平面曲率; DR 為距河道距離; AP 為坡向

表 28 4 個自變數邏輯迴歸分析結果

	B	S.E.	Wald	自由度	顯著性	Exp (B)
DEM	0.582	.079	54.827	1	<0.001	1.789
SP	1.379	.108	163.450	1	<0.001	3.973
DR	-5.067	.128	1571.011	1	<0.001	0.006
AP	-0.882	.067	173.362	1	<0.001	0.414
常數	0.510	.069	54.479	1	<0.001	1.666

註: DEM 為高程; SP 為坡度; DR 為距河道距離; AP 為坡向

為了評估所建立的邏輯迴歸模型在崩塌潛勢預測上的適合度與整體解釋能力，本研究進行了 Hosmer 與 Lemeshow 檢定及 Omnibus 檢定。Hosmer 與 Lemeshow 適合度檢定結果顯示，卡方值為 139.770，自由度為 8，顯著性 $P < 0.01$ ，顯示模型預測值和實際觀測值之間存在一定的差異。而 Omnibus 檢定，卡方值達到 2501.465，自由度為 4，顯著性 $P < 0.01$ ，顯示模型所選取的自變數能有效的聯合影響因變數，具有較好的解釋力。

(四)模型驗證

使用 SPSS 計算模型預測機率之 ROC 曲線及其曲線下面積 AUC，結果如圖 32 所示。從 ROC 曲線可看出，模型預測曲線良好，AUC 值為 0.704，代表模型預測具有可接受的鑑別力，能夠準確地區分崩塌風險高低的區域。




圖 32 崩塌潛勢 ROC 曲線

針對模型進行準確度評估，所得結果如表 29。根據驗證結果，模型對非崩塌地的預測準確度為 60.78%，對崩塌地的預測準確度為 67.64%，總體準確率為 64.2%，這結果代表了模型在預測崩塌風險具一定的準確性，但整體而言仍有改進的空間。

表 29 崩塌潛勢模型準確度評估

實際資料	預測資料		準確度
	植生	崩塌地	
植生	3039	1961	60.78%
崩塌地	1618	3382	67.64%
準確率			64.2%

本章節主要利用 2009-2024 年衛星影像，結合物件導向方法和 SVM 分類方法製作多時期土地覆蓋型圖，並透過地景指標及邏輯迴歸模型，對六龜試驗林進行長期崩塌地景監測，並且建構崩塌潛勢預測模型，以掌握六龜區內崩塌發生之時空分布與潛在影響因子。

在長期地景結構變動部份，綜整第二節的研究成果來看，風災發生後，區塊數量(NP)、邊緣密度 (ED)、景觀形狀指數 (LSI) 與分離度指標 (SPLIT) 均在初期迅速上升，顯示地景破碎化程度、形狀複雜度及分散程度皆大幅增加，反映出莫拉克颱風造成的劇烈干擾。隨著時間推移，這些指標普遍呈現下降趨勢，說明崩塌區塊逐漸減少、形狀簡化、景觀連續性提升。相對地，聚集度指標 (CONTAG) 則呈現

穩定上升趨勢，代表地景聚集程度逐步回復。在碎形維度指標 (PAFRAC) 方面，短期資料 (2010 - 2018 年) 顯示其在 2010 至 2013 年間顯著下降，地景邊界形狀逐漸簡化，2016 年後再度上升，代表部分區域出現新的破碎化現象；而長期資料 (2009 - 2024 年) 則呈現兩個明顯的高峰，分別出現在 2009 年 8 月至 2015 年及 2021 至 2024 年，顯示這兩個時期受外界擾動，形狀較為複雜，結構破碎化程度較高。由兩期資料比對顯示，其變化程度大致相似，惟長期觀測更易掌握地景變動的趨勢，顯示出長期監測對於瞭解森林地景動態與生態系恢復歷程的重要性。

此外，本章節所建立之崩塌潛勢預測模型整體準確度達 64.2%，AUC 值為 0.704，雖具有一定的預測力，惟在潛在因子與演算方法的應用上，仍進一步精進的空間，後續章節將針對相關影響因子與模型優化進行更深入的分析與探討。

第四節 不同空間解析度崩塌潛勢預測比較

此章節主要使用第三節所製作之土地覆蓋型圖，並選取其中 2009 年 8 月及 2024 年兩期土地覆蓋型圖，用於建立與分析崩塌潛勢預測模型。由於多項研究指出，不同解析度可能對崩塌潛勢的預測結果產生不同的影響，因此本章節設計 5 m、10 m、20 m、30 m 四種不同解析度，以探討在六龜試驗林地區最適用於崩塌潛勢評估之空間解析度。此外，為提升模型準確性，新增空載光達所產生的冠層結構指標及 NDVI 值作為變數，並分別採用邏輯迴歸與隨機森林兩種模型方法進行分析與比較，評估不同解析度與建模方法下模型表現之差異，進一步確認適用於本區域崩塌潛勢之最佳方法與尺度。

一、土地覆蓋型圖

主要利用 2009 年 8 月 (莫拉克風災後) 及 2024 年兩期土地覆蓋型圖來進行崩塌潛勢分析。兩期土地覆蓋型圖如圖 33 所示，其中綠色代表植生，紅色代表崩塌地，黃色代表裸露地，區內白色區域代表陰影聯集區，此區域剔除不在後續分析範圍。本研究以 2009 年之植生區域作為基期資料，套疊 2024 年土地覆蓋型圖，並萃取期間新增之崩塌地區 (如圖 34 紅色區塊)，以作為後續崩塌發生分析之依據。




圖 33 六龜試驗林兩時期土地覆蓋型圖




圖 34 六龜試驗林新增崩塌地分布圖

二、 模型變數

本研究旨在透過兩個時期土地覆蓋型圖層及不同空間解析度的崩塌影響因子去建構崩塌潛勢預測模型，在模型的因變數部份，萃取土地覆蓋型圖內崩塌與非崩塌地的二元狀態，其中非崩塌地類別指自 2009 年 8 月莫拉克颱風後至 2024 年期間，未發生崩塌的區域，而崩塌地類別則指自 2009 年 8 月後莫拉克颱風後至 2024 年間新增崩塌區域，二元類別的設定主要在於界定崩塌事件的發生與否，以進行後續的崩塌潛勢預測分析。

在崩塌潛勢影響因子部份，選取高程、坡度、坡向、地形濕度指數、逕流強度指數、曲率、平面曲率、剖面曲率、距河道距離、常態化差異植生指標、冠層覆蓋率 (CCR)、平均冠層高 (TCH)、冠層高度變異數 (VCH) 及冠層容積率 (CVR) 等，共 14 個因子。主要採用四種不同空間解析度，包含 5m、10m、20 m、30 m，建立模型影響因子的資料集。並從崩塌與非崩塌地的範圍中隨機選取各 15,000 筆樣本數量，其中 70% 作為訓練樣本，其餘 30% 作為驗證樣本。

三、 邏輯迴歸模型

(一)變數相關分析

在進行邏輯迴歸建模前，先針對四種空間解析度下的 14 個自變數進行相關性分析，並根據設定的 0.7 閾值篩選變數。剔除變數的原則是優先排除相關性較高且保留變數較多的狀態。在 5 m 解析度下曲率 (CUE) 與平面曲率 (PNE) 及剖面曲率 (PFE)，以及冠層覆蓋率 (CCR) 與平均冠層高 (TCH) 之間的相關性均高於閾值，因此在 5 m 解析度的邏輯迴歸模型中剔除 CUE 及 TCH。依照篩選原則，10 m 解析度模型剔除 CUE、CCR、CVR，20 m 解析度模型剔除 CUE、CCR、CVR，在 30 m 解析度模型中則剔除 CUE、TCH、CVR。

(二)模型建構

利用不同空間解析度的變數資料集來建構邏輯迴歸模型，並分析各變數不同解析度下的期望值 ($\exp(B)$) 值與對應的勝算比 (odds ratio)，結果如表 30。整體而言，多數變數在不同解析度下的勝算比變化趨勢一致，部份變數則在解析度變化時，對崩塌潛勢判斷的敏感性產生明顯差異。例如地形變數 DEM、CUE、SP、AP 及

TWI，其勝算比在各解析度間變動幅度相對穩定。相對地冠層結構指標 (CCR、TCH、VCH、CVR) 則在 10 m 解析度呈現較高的勝算比。變數 PNE 與 DR 則與冠層結構指標恰好相反，在 10 m 解析度的勝算比低於其他解析度，顯示不同類型變數對模型的貢獻受空間解析度影響程度不同，突顯出解析度選擇對崩塌潛勢分析結果的重要性。進一步以 10 m 模型為例來分析變數影響的方向性，其中 TCH 為負向影響，顯示樹高愈高，崩塌風險愈低，此結果與生態機制一致，這是由於高的樹木通常具有發達的根系，能增強土壤的穩定性，並減少雨水對地表的直接沖刷，因而降低崩塌發生的可能性。VCH 呈現正向影響，表示冠層高度的變化越大，表面粗糙度增加，崩塌風險隨之增加，可能反映出林冠結構較為破碎或林間空隙增多，導致地表穩定性下降，然而，在 5 m 模型中，VCH 顯示負向影響，這可能是由於在較小解析度下，冠層高度變異僅反應局部微小波動，因此不足以反應出整體崩塌潛勢。

表 30 不同解析度邏輯迴歸模式變數之勝算比

變數	5 m		10 m		20 m		30 m	
	期望值	勝算比	期望值	勝算比	期望值	勝算比	期望值	勝算比
DEM	2.934	2.9	5.908	5.9	4.511	4.5	4.31	4.3
SP	1.983	2	1.688	1.7	3.002	3	4.413	4.4
AP	0.371	2.7	0.46	2.2	0.351	2.8	0.349	2.9
CUE	0.856	1.2	1.331	1.3	1.583	1.6	0.569	1.8
PNE	13.219	13.2	4.003	4	16.581	16.6	34.019	34
DR	0.031	32.3	0.204	4.9	0.03	33.3	0.038	26.3
NDVI	1.473	1.5	3.372	3.4	3.074	3.1	1.722	1.7
CCR	0.373	2.7	0.014	71.4	0.255	3.9	0.151	6.6
TCH	0.17	5.9	0.005	200	0.065	15.4	0.041	24.4
VCH	0.07	14.3	77.821	77.8	4.498	4.5	26.917	26.9
CVR	0.452	2.2	9.96	10	0.912	1.1	2.19	2.2
SPI	1	1	839.845	839.8	182774.981	182775	45995.22	45995
TWI	0.993	1	1.566	1.6	1.385	1.4	1.155	1.2

註:DEM 為高程；SP 為坡度；CUE 為曲率；PNE 為平面曲率；DR 為距河道距離；NDVI 為常態化差異植生指標；CCR 為冠層覆蓋率；TCH 為平均冠層高；VCH 為冠層高度變異數；CVR 為冠層容積率；SPI 為逕流強度指數；TWI 為地形濕度指數

經皮爾森積差相關分析分析篩選出相關性較低的變數，並將變數進行歸一化處理後，以 SPSS 進行崩塌潛勢邏輯迴歸模型分析，所得結果彙整如表 31，結果顯示，四種空間解析度邏輯迴歸模型，其 Nagelkerke R^2 評估結果以 10 m 模式所得模擬結果最佳 (Nagelkerke $R^2=0.49$)，其次為 30 m (Nagelkerke $R^2=0.21$)，而 20 m 及

5 m 所得結果較不佳 (Nagelkerke $R^2 < 0.200$)，這表示 10 m 解析度的模型具有最佳的預測效能和解釋力。此外 10 m 模型，其真陽性率、真陰性率和分類正確率均高於其他解析度，顯示在該解析度下，模型能夠較準確地區分崩塌地和非崩塌地。

表 31 不同解析度影響因子邏輯迴歸分析結果

解析度	變數	參數		適配度指標		效能評估 (Threshold=0.5)		
		β	p-value	概似比	調整判定係數	真陽性	真陰性	整體準確度
5M	Constant	-0.425	0.237					
	DEM	0.891	<0.001					
	SP	0.685	<0.001					
	AP	-0.988	<0.001					
	PNE	2.709	<0.001	2604.15	0.16	65.70	66.08	65.89
	DR	-3.345	<0.001					
	NDVI	0.500	<0.001					
	CCR	-1.355	<0.001					
	VCH	-6.129	<0.001					
10M	Constant	-0.817	0.007					
	DEM	2.204	<0.001					
	SP	0.692	<0.001					
	AP	-0.820	<0.001					
	PNE	1.918	<0.001	9620.17	0.49	83.63	78.25	80.94
	DR	-2.135	<0.001					
	NDVI	0.495	0.003					
	TCH	-17.542	<0.001					
	VCH	4.351	<0.001					
	TWI	0.866	<0.001					
20M	Constant	-0.621	<0.001					
	DEM	1.714	<0.001					
	SP	1.030	<0.001					
	AP	-1.072	<0.001					
	PNE	2.671	<0.001	3123.69	0.18	69.08	65.52	67.30
	DR	-3.709	<0.001					
	TCH	-5.229	<0.001					
	VCH	5.077	<0.001					
	SPI	14.653	<0.001					
30M	Constant	-0.716	<0.001					
	DEM	1.185	<0.001					
	SP	1.290	<0.001					
	AP	-1.065	<0.001					
	PNE	2.999	<0.001	3503.73	0.21	66.34	69.19	67.77
	DR	-3.075	<0.001					
	NDVI	0.724	<0.001					
	CCR	-2.495	<0.001					
	SPI	11.161	<0.001					

四、隨機森林模型

本研究採用四種不同解析度的變數資料，利用隨機森林建構崩塌潛勢預測模型。結果顯示，隨機森林模型的預測結果與邏輯迴歸分析結果一致，其中 10 m 解析度模型的效能最佳。對不同解析度模型中重要性因子進行分析（如圖 35），由圖

中可明顯看出不同解析度下重要性數值(Importance Score)有所差別，其代表每個變數對於模型的貢獻程度比例，透過此數值可以直觀的判斷出變數對模型的貢獻。總體而言，5 m、20 m 及 30 m 解析度模型在變數重要性呈現出相似的趨勢，距河道距離 (DR) 在這三個模型中顯示出最高的重要性，且顯著高於其他變數，其次為地形相關因子，如數值高程模型 (DEM) 等。然而，在效能最佳的 10 m 模型中，DR 及 DEM 重要性並未特別突出，取而代之的是四個冠層結構指標，佔據了前四位的重要性因子，其中又以平均冠層高 (TCH) 和冠層覆蓋率 (CCR) 的重要性比例顯著高於其他變數，初步推測，在六龜區域有許多的次生林的闊葉林的現況下，冠層結構指標用 10 m 解析度來建立時，與實際森林冠層結構較為相符，代表冠層結構指標能有效呈現地表樹木結構的狀態，與崩塌區域之間形成高度的耦合效果，較高的樹冠和密集的冠層覆蓋對土壤有穩固作用，從而降低了崩塌風險。綜合上述，隨機森林模型的結果顯示，新增冠層結構指標在崩塌潛勢預測中確實具有實質性作用，尤其在 10 m 解析度下顯著提升了模型的預測效能。






圖 35 不同解析度隨機森林模型變數重要性分析結果

五、 模型評估

(一) ROC 曲線與 AUC 面積

本研究使用邏輯迴歸與隨機森林構建崩塌潛勢預測模型，並基於不同概率閾值的敏感性和特異性，分別繪製模型訓練結果及驗證結果的 ROC 曲線及 AUC 值，如圖 36、37。在訓練模型的結果中，不同解析度下邏輯迴歸和隨機森林模型的 AUC 值顯示出顯著差異。邏輯迴歸模型於 5 m、10 m、20 m 和 30 m 解析度的 AUC 值分別為 0.702、0.872、0.722 和 0.731，顯示在 10 m 模型中預測效果最佳，而 5 m 和 20 m 模型僅具有可接受的鑑別力。隨機森林模型在所有解析度下的 AUC 值均為 1，表現出極高的預測能力與鑑別力。

在驗證模型的結果中，同樣的邏輯迴歸模型 AUC 值與訓練結果一致，10 m 模型的 AUC 值為 0.876，遠大於其他解析度模型，顯示具有優良的鑑別力。相比之下，隨機森林模型於不同解析度的 AUC 值均大於 0.8，而在 10 m 模型的 AUC 值更高達 0.929，顯示具極佳的鑑別力。

整體而言，從空間解析度角度來分析，邏輯迴歸與隨機森林模型均顯示出 10 m 解析度的模型效能優於其他解析度。從建模方法上比較，隨機森林在各解析度下的鑑別力均優於邏輯迴歸，尤其是在 10 m 解析度中，隨機森林模型的 AUC 值展現出極佳的鑑別能力，顯著提升了崩塌潛勢預測的準確性。




圖 36 邏輯迴歸和隨機森林模型訓練結果 ROC 曲線及 AUC 值




圖 37 邏輯迴歸和隨機森林模型驗證結果之 ROC 曲線及 AUC 值

(二)準確度評估

使用 30% 的驗證樣本，對已建構之邏輯迴歸及隨機森林模型進行準確度評估，所得結果如表 32 所示。隨機森林模型在 5 m、10 m、20 m 及 30 m 解析度下的分類的正確率分別為 73.81%、85.74%、78.99% 及 82.39%，而邏輯迴歸分類在相同解析度下的正確率分別為 65.98%、81.9%、65.21% 及 66.61%。結果顯示，隨機森林模型在各解析度下的預測準確度均優於邏輯迴歸模型。尤其 10 m 解析度，隨機森林及邏輯迴歸均展現了最佳的預測效能，反映出 10 m 模型，在崩塌潛勢預測中有其優越性。

此外，隨機森林模型在所有解析度的表現相對穩定，準確率皆在 70% 以上，而邏輯迴歸模型除 10 m 模型外，其他解析度的準確度均低於 70%，顯示出其在不同解析度的變數適應性較隨機森林差。代表隨機森林在崩塌潛勢預測較邏輯迴歸更為適用，這與多數前人研究的結果一致 (Guo et al., 2016; Sevgen et al., 2019; Milanović et al., 2020; Ozkan et al., 2022)。

表 32 不同解析度模型驗證準確度評估結果

解析度	方法	崩塌地預測			非崩塌地預測			準確度
		崩塌地	非崩塌地	真陽性率	崩塌地	非崩塌地	真陰性率	
5M	LG	2,787	1,713	61.93%	1,349	3,151	70.02%	65.98%
	RF	3,215	1,282	71.49%	1,075	3,428	76.13%	73.81%
10M	LG	3,461	1,039	76.91%	590	3,910	86.89%	81.90%
	RF	3,815	648	85.48%	635	3,902	86.00%	85.74%
20M	LG	3,488	1,012	77.51%	2,119	2,381	52.91%	65.21%
	RF	3,594	906	79.87%	985	3,515	78.11%	78.99%
30M	LG	2,483	2,017	55.18%	988	3,512	78.04%	66.61%
	RF	3,709	758	83.03%	827	3,706	81.76%	82.39%

六、崩塌潛勢預測分布圖

本研究分別以邏輯迴歸及隨機森林所建構的模型，產製出 5 m、10 m、20 m、30 m 四種空間解析度的預測結果圖。模型輸出為每一像元對應的崩塌發生機率值，依據預測機率值將其劃分為五個等級，間距為 0.2，分為非常低 (大於等於 0 且小於等於 0.2)、低 (大於 0.2 且小於等於 0.4)、中 (大於 0.4 且小於等於 0.6)、高 (大於 0.6 且小於等於 0.8) 及非常高 (大於 0.8 且小於等於 1)，進而繪製出崩塌潛勢機率分布圖如圖 38 及 39。

由圖中可觀察到，隨著解析度的變化，崩塌潛勢空間分布呈現一定程度的差異。在邏輯迴歸模型中，各解析度的預測結果差異極為明顯，5 m 模型預測極少量的潛在崩塌區，而在 10 m、20 m 與 30 m 模型中，則出現較大範圍的高潛勢預測區，其中以 20 m 模型預測的崩塌潛勢面積最大，且明顯高於實際新增崩塌地的分布，顯示出邏輯迴歸模型對解析度變化的反應較大，預測表現不穩定。相較之下，隨機森林模型在不同解析度的整體表現較為穩定，其中又以 10 m 模型預測結果與實際新增崩塌地分布最為接近，顯示其在該解析度下具有較高的預測準確性。而在 5 m、20 m、30 m 中，普遍可見沿河道附近預測出較多的崩塌高潛勢區，推測可能受到距離河道 DR 變數的影響，使得模型對河道鄰近區域的崩塌潛勢預測有偏高情形，此現象說明部份變數在特定解析度下對模型的影響甚大。




圖 38 邏輯迴歸模型在不同空間解析度崩塌潛勢預測機率分布圖




圖 39 隨機森林模型在不同空間解析度崩塌潛勢預測機率分布圖

綜合本章節研究上結果，初步確認選擇適當的空間解析度對於模型建構具有顯著的影響。根據本研究所選用的四種模型解析度來看，最高解析度 5 m 的模型，並未有效提升模型的準確度，反而是中等解析度 10 m 的模型，顯著提升了模型的效能，顯示出 10 m 空間解析度在崩塌潛勢預測的優勢。在建模方法的比較中，隨機森林在所有空間解析度下的表現均優於邏輯迴歸模型，其 AUC 值在四個解析度下均超過 0.8，並於 10 m 解析度下達到最高值 0.929，表現出極高的鑑別力。這結果與 Zhao et al. (2019) 的研究一致，其指出在 15m 空間解析度模型效能最佳，過小的尺度（如 5 m）容易放大微地形變異，導致較多空間雜訊，進而影響變數的穩定性與模型的預測精度。

在變數選取方面，考量研究區域是森林覆蓋密集區域，引入空載光達衍生的冠層結構指標進行模型建構，以探討森林覆蓋程度和樹高等因子對崩塌潛勢的影響。結果顯示，在隨機森林的 10 m 模型中，冠層結構指標 (TCH、CCR、CVR、VCH) 均為前四大關鍵影響變數，其中又以平均樹冠高度 (TCH) 及冠層覆蓋率 (CCR) 為最重要的變數，顯示林木高度越高，冠層覆蓋越密集，有助於降低崩塌發生的生機率。Jamal and Mandal (2016) 指出植被在坡地穩定性中扮演關鍵角色，其研究亦證實由遙測資料衍生的植生與冠層相關指標，對崩塌潛勢模型具有顯著的貢獻。本研究結果同樣驗證，光達資料所推估的冠層結構指標能有效提升模型的預測效能，並確認其在崩塌潛勢模型中的重要性。此外，研究結果也顯示出 10 m 解析度的冠層結構

指標能更準確地呈現森林結構特性，並與崩塌潛勢模型達到較佳的耦合效果，呼應了 Martinello et al. (2023) 的觀點，即模型預測的準確性取決於空間解析度的選擇與模型變數之間的最佳耦合。

第五節 細胞自動機-馬可夫鏈與隨機森林預測模型

本章節主要利用前面崩塌復育及崩塌潛勢模型的研究成果，運用細胞自動機-馬可夫鏈與隨機森林模型，探究莫拉克風災後六龜森林覆蓋未來的變動趨勢。使用的材料主要為 2009 年 8 月（莫拉克風災後）、2017 年及 2024 年三期土地覆蓋型圖。首先利用 2009 年與 2017 年兩期資料之間的土地覆蓋變化(植生與崩塌地)，建構隨機森林模型，推估植生與崩塌地類別間的轉換關係，產生土地轉移機率資料。利用轉移機率資料轉成轉變潛力圖，並結合 CA-Markov 模型，模擬預測 2024 年之土地覆蓋空間分布，並與實際 2024 年土地覆蓋型進行比對，以驗證模型之準確性與應用可行性。

為進一步探討機器學習演算法對模型效能的影響，本研究亦同時建立僅使用 CA-Markov 傳統預測模型，進行 2024 年土地覆蓋模擬，並與引入隨機森林演算法者相互比較，從預測精度與空間分布差異兩方面評估其優劣與適用性。

於模型驗證完成後，後續將以 2017 年至 2024 年資料建立新的隨機森林土地覆蓋轉移機率，並使用 RF-CA-Markov 模擬 2031 年之土地覆蓋變化情形。

一、植生與崩塌地變遷分析

本研究先針對三期土地覆蓋型圖，進行二個時段的植生與崩塌地變遷分析，所使用 2009 年 8 月（莫拉克風災後）、2017 年及 2024 年土地覆蓋型圖，扣除陰影區，擷取其中植生與崩塌地土地類別(圖 40)來進行後續研究。




圖 40 六龜試驗林三時期土地覆蓋型圖

利用三期資料來分析六龜 2009-2017 年及 2017-2024 年兩個時段之植生與崩塌地的變化，所得結果如圖 41 所示，綠色區塊代表面積增加，橘色區塊代表面積減少。由圖中可看出 2009-2017 年期間，崩塌地類別減少了 564 ha，但新增崩塌區域增加了 180 ha；植生類別減少 225 ha，但新增加的植生多了 581ha。這個階段整

體而言，崩塌地大幅減少，而植生面積大幅增加。到了 2017 - 2024 年，崩塌地的減少減緩，面積減少 195 ha，新增崩塌區增加 68 ha；在植生的部份，減少了 72 ha，但新增植生區域 215 ha。根據這些結果，可以推論研究區域在 2009 年莫拉克災害後，第一時段崩塌地減少及植生增加的面積，遠大於第二時段，但整體而言，植生仍是持續增加，而崩塌地仍持續減少的趨勢。




圖 41 兩個時段植生與崩塌地面積(ha)增減圖

二、 臺灣杉造林地崩塌變遷分析

在掌握整體區域崩塌地變化趨勢後，為進一步探討六龜試驗林內人工的造林地在崩塌變化趨勢上，是否因天然林與人工林不同而有所有差異，因此選取臺灣杉人工林 25 筆造林地號為研究範圍。針對這些地號彙整其於 2009 年、2017 年與 2024 年三個時期的崩塌比率，並納入 2020 年臺灣杉人工林變化比率(即自然演替程度)、造林年份與林區位置(北鳳岡或南多納林區)，如表 33 所示。由表中資料，可初步觀察各造林地在三個時期崩塌消長歷程，並進一步與人工林變化程度及造林地位置進行初步比對。為更直觀呈現各造林地時間序列的變化，將各造林地 2009、2017 及 2024 年三期崩塌率變化繪製成直方圖(如圖 42)，整體趨勢顯示 2009 年崩塌率最高，至 2017 與 2024 年逐漸下降，反映莫拉克颱風後長期復育效果明顯。

由圖中可清楚看出編號 18(六-20-74-10 地號)趨勢差異較大。透過表 33 崩塌率可看出，其於 2017 年崩塌率雖下降至 9.9%，但至 2024 年回升至 14.7%，與其

他造林地呈現差異。透過 GIS 套圖比對（如圖 43），可發現該地塊鄰近多納苗圃，並且位於林道路徑旁，屬人員會來往的地段，對人員或林道安全具有潛在風險。

此外，本研究亦統計各造林地在 2020 年臺灣杉人工林的變化率，作為自然演替程度之指標，並與 2009 至 2024 年間的崩塌率變化幅度進行分析，由圖 44 散點圖可清楚看出，二者之間未呈現顯著相關，顯示人工林是否演替為次生林，與其崩塌地面積減少的幅度並無直接關聯。

表 33 臺灣杉造林地三個時期崩塌比率結果

編號	臺灣杉造林地地號	2009 年崩塌比率	2017 年崩塌比率	2024 年崩塌比率	2020 年臺灣杉變化比率	造林年份	林區位置
1	六-2-65-2	0.1	0.0	0.0	9.3	1976	北鳳岡
2	六-2-70-6	2.9	0.0	0.0	29.1	1981	北鳳岡
3	六-2-71-4	0.0	0.0	0.0	24.1	1982	北鳳岡
4	六-10-68-2	30.7	19.5	0.6	8.2	1979	北鳳岡
5	六-10-69-10	30.8	18.2	0.4	40.2	1980	北鳳岡
6	六-10-69-11	21.0	5.2	0.0	0.4	1980	北鳳岡
7	六-10-71-1	27.0	9.7	5.3	0.0	1982	北鳳岡
8	六-10-71-2	11.8	6.7	0.0	65.9	1982	北鳳岡
9	六-10-74-1	2.2	0.0	0.0	48.3	1985	北鳳岡
10	六-10-74-3	1.0	0.0	0.0	15.6	1985	北鳳岡
11	六-12-68-3	0.0	0.0	0.0	0.0	1979	北鳳岡
12	六-12-70-2	3.7	1.5	1.3	28.5	1981	北鳳岡
13	六-12-71-3	5.0	5.8	4.0	88.4	1982	北鳳岡
14	六-12-72-1	6.6	4.1	0.1	13.8	1983	北鳳岡
15	六-14-64-1	3.0	0.7	0.0	6.2	1975	北鳳岡
16	六-18-74-8	0.0	0.0	0.0	48.0	1985	南多納
17	六-18-74-9	2.9	0.0	0.0	15.1	1985	南多納
18	六-20-74-10	54.7	9.9	14.7	100.0	1985	南多納
19	六-20-74-4	13.5	1.8	1.0	93.7	1985	南多納
20	六-20-74-5	1.8	0.0	0.0	0.3	1985	南多納
21	六-20-74-6	0.3	0.0	0.0	27.5	1985	南多納
22	六-20-75-3	24.3	4.8	5.4	89.3	1986	南多納
23	六-21-80-8	60.6	38.3	13.3	18.4	1991	南多納
24	六-22-74-14	0.0	0.0	0.0	78.4	1985	南多納
25	六-24-78-2	3.5	3.5	0.0	100.0	1989	南多納




圖 42 造林地三時期崩塌比率直方圖




圖 43 造林地六-20-74-10 地號位置圖




圖 44 臺灣杉變化率 vs 崩塌減少率散點圖

三、 土地覆蓋轉移機率矩陣

為建構後續 CA-Markov 模型，需先計算整體土地覆蓋的轉移機率矩陣，以作為預測分析的基礎。因此，本研究先運用 Markov 模型計算 2009 - 2017 年及 2017 - 2024 年兩個時段的土地覆蓋轉移機率矩陣，所得結果如表 34、35。從 2009 - 2017 年間的 land transfer probability results show that the proportion of vegetation maintained as vegetation is 82.6%, and 17.4% of the vegetation changes to collapse land; while in the collapse land, 78.8% changes to vegetation, showing a high degree of recovery progress in the initial stage.

在 2017 - 2024 年期間，植生維持率提高至 84.2%，轉為崩塌地的比例下降為 15.8%，顯示出第二階段整體森林覆蓋穩定性較前一階段高。然而崩塌地轉為植生的比例則下降至 60.8%，也代表此時段的復育速度相對於前一階段較慢。

表 34 2009 - 2017 年 Markov 轉移矩陣

From \ To	植生	崩塌地
植生	82.6%	17.4%
崩塌地	78.8%	21.2%

表 35 2017 - 2024 年 Markov 轉移矩陣

From \ To	植生	崩塌地
植生	84.2%	15.8%
崩塌地	60.8%	39.2%

整體而言，植生的穩定性提升：植生轉為崩塌地的比例由 17.4%降至 15.8%。崩塌地的復育率下降：崩塌地轉為植生的比例從 78.8%下降至 60.8%，顯示復育速度不如第一時段，整體森林恢復趨勢呈現遲緩。

四、崩塌潛勢與復育預測模型

在崩塌潛勢預測模型建構，主要參考前述第四節研究成果，採用高程、坡度、坡向、地形濕度指數、逕流強度指數、曲率、平面曲率、剖面曲率、距河道距離、常態化差異植生指標、冠層覆蓋率、平均冠層高、冠層高度變異數及冠層容積率，共 14 個因子建立隨機森林模型。而崩塌復育預測模型，參考第二節研究成果，惟所使用氣象因子，其中氣溫與高程具有一定相關性，而降雨量對模型貢獻相對有限，加上氣象因子受限於資料解析度較粗略，可能影響模型精度。因此，建構模型時，將不納入氣象因子，以提升模型穩定性與解釋力。因此除保留原先所採用高程、坡度、坡向、地形濕度指數、逕流強度指數、坵塊面積、坵塊周長、周長面積比、分形維數、近圓形形狀指標、鄰近指數分佈及距崩塌地邊界等 12 個因子，另外加上曲率、平面曲率及剖面曲率共 15 個因子建構隨機森林模型。為配合 RF-CA-Markov 預測機制，需建立兩個時段的土地轉換機率，因此分別依據 2009 - 2017 與 2017 - 2024 年兩個不同時段的資料，以建構兩個時期的模型，在模型驅動因子的使用，會依據不同時期取用的不同的資料來源，如 2009 - 2017 年期間的隨機森林模型，主要是使用 2009 及 2017 年衛星影像所產製的土地覆蓋型圖及 2010 年地形資料，而 2017 - 2024 年的隨機森林模型，主要是利用 2017 及 2024 年衛星影像所產製的土地覆蓋型圖及 2017 年地形資料。以空間解析度 10 m 為主，建立模型因子的資料集。

在崩塌潛勢與復育模型建構部份，透過 2009 - 2017 年及 2017 - 2024 年兩個不同時段的因子資料，進行隨機森林模型訓練，並分析驅動因子的重要性，所得結果

如表 36。由表中結果可看出，在崩塌潛勢預測模型中，不論是在第一或是第二時段，冠層結構指標皆為最具影響力的變數，其次為 NDVI 及高程。此結果顯示在六龜試驗林這樣森林高密度覆蓋的區域，影響崩塌潛勢最關鍵的因素，與森林冠層結構及植生狀況有著高度的相關性。


進一步分析各項冠層結構指標的相對重要性，可發現第一時段中影響力最大的平均冠層高 (TCH)，代表在莫拉克颱風造成大規模崩塌的初期階段，樹冠高度對地表穩定性具有顯著的影響。樹冠較高的區域通常代表林木根系較發達，能提供較佳的土壤固著作用，進而降低崩塌發生的可能性。而在第二時段，影響力最重要的指標則為冠層高度變異數 (VCH)。此變數在第一時段未進入前五大重要因子，但在第二時段位於首要因子，顯示冠層高度異質性在後期崩塌潛勢扮演更關鍵的角色。VCH 反映冠層高度的起伏程度，值愈高代表冠層表面較不均勻，存在較多孔隙，雨水較易直接穿透冠層進入地表，增加地表土壤含水量與不穩定性，進而提高崩塌發生機率。此現象可能與第二時段部份原屬莫拉克颱風造成的崩塌區，歷經復育後植生尚未發展至成熟林階段有關。此類區域雖地表已部份恢復覆蓋，但植被仍矮小，冠層變異高，加上結構不穩定，仍易再次發生崩塌。VCH 在第二時期的重要性推論與復育區域冠層結構異質性與崩塌潛勢有相關性，此結果呼應第二節圖 23 所示，部份復育區域經常遭受再次崩塌的影響，導致復育面積的變化維持在一個相對穩定且未明顯擴張的狀態。

在崩塌復育模型的分析中，兩個時段影響植被復育的前三大關鍵因子均為距崩塌地邊緣距離、高程與坡度。這也代表著崩塌地的自然復育條件主要受地形因子控制，其中較低海拔與適中的坡度環境較有利於植被恢復，同時距崩塌地邊緣距離較近的區域由於能夠獲得周邊植被的種源補充，復育速率相對較快。這結果與過去的研究一致，黃雅莉和陳朝圳 (2018) 指出，靠近崩塌地邊界的區域更容易獲得種源，進而促進崩塌地的復育，離得越遠則因種子傳播受限而較難復育。

在不同時段的比較上，第一時段以距崩塌地邊緣距離為最具影響力的因子，顯示復育初期種子來的可近性為主導因素，反映在莫拉克颱風後初期崩塌區域中，天然植被更新多仰賴鄰近林地的種源傳播與擴散。相較之下，第二時段則以高程與坡度等地形因子位居第一及第二重要地位，代表當初期種源建立完成，後續植被是否能成功生長與擴展，則更仰賴當生育環境的條件。當崩塌後坡度較為平緩，或是位

於海拔較低區域，土壤水分保持能力較好，有助於植被的自然復育 (Mi et al., 2019; Hotta et al., 2022)。綜合來看，本研究結果不僅支持前人研究的觀點，也進一步指出崩塌地復育過程中，復育早期以種源可獲得性為主要限制因子，而復育中後期則逐漸轉變為由地形環境條件所主導，顯示崩塌後的植被演替具有階段性特徵。

表 36 兩個時段崩塌潛勢與崩塌復育隨機森林模型變數重要性分析結果



利用驗證樣本進行模型精度評估，其中 ROC 與 AUC 所得結果如表 37。首先在崩塌潛勢預測模型檢驗結果，兩個時段的預測模型，其 AUC 值均超過 0.950，模型表現良好具有極佳的鑑別能力。此外，在崩塌復育模型部份，兩個時段模型的 AUC 值分別為 0.87 及 0.9，模型整體而言也具有極佳的表現，但又以第二時段模型表現較第一時段模型良好。

準確度評估結果如表 38，由表中顯示出崩塌潛勢兩個時段的隨機森林模型準確度評估結果分別為 89%及 90%，而崩塌復育兩個時段隨機森林模型的結果分別為 77%、83%的準確度。整體而言，不論以 AUC 值檢驗或是準確度評估，崩塌潛

勢預測模型表現都較崩塌復育好，代表崩塌潛勢所使用之潛在變數因子，確實較能預測出崩塌發生的區域。

表 37 兩個時段崩塌潛勢與崩塌復育 RF 模型 ROC 及 AUC 值




表 38 兩個時段崩塌潛勢與崩塌復育隨機森林模型準確度評估

模型	時間	實際崩塌地轉變預測			實際植生轉變預測			整體準確度
		崩塌地	植生	TPR	崩塌地	植生	TNR	
崩塌潛勢	2009-2017	2708	302	0.90	356	2634	0.88	0.89
	2017-2024	2824	186	0.94	409	2581	0.86	0.90
	時間	崩塌地	植生	TNR	崩塌地	植生	TPR	整體準確度
崩塌復育	2009-2017	2341	649	0.78	710	2300	0.76	0.77
	2017-2024	2492	498	0.83	536	2474	0.82	0.83

五、土地覆蓋轉變潛力圖建構

本研究於 2009 - 2017 及 2017 - 2024 兩個階段，分別應用所建立的崩塌潛勢和復育崩塌預測模型，產製全區域的土地轉換機率圖，如圖 45 及 46。




圖 45 2009 - 2017 年崩塌潛勢(左圖)與復育(右圖)轉換機率圖




圖 46 2017 - 2024 年崩塌潛勢(左圖)與復育(右圖)轉換機率圖

從圖中可大致可看出二個階段轉換機率的趨勢，在崩塌潛勢部份，第一時段植生轉換成崩塌地，轉換機率高的區域分布較多，如高機率轉換區（藍色區域）的分布明顯集中在中間區位。而第二時段的植生轉換成崩塌地的機率相對減少許多，零星散布在各區域。在崩塌復育部份，崩塌地轉變成植生在第一時段幾乎大部份區域都呈現高轉換機率（藍色區域），但在第二階段轉換機率普遍降低。

此處 RF 模型所生成的轉移機率分布圖，為配合 CA-Markov 模型需求，需將隨機森林模型輸出的機率圖轉換為 TerrSet 所支援的影像與轉變潛力圖格式（.rst 與 .rgf）。本研究使用 ArcGIS 將機率圖轉換為 ASCII 格式，並經由 TerrSet 轉存為 .rst 與 .rgf 格式，以作為 RF-CA-Markov 之轉變潛力圖。

六、不同 CA 迭代次數對模型精度影響之比較

為探討 CA 模型迭代次數對土地覆蓋變遷模擬精度之影響，本研究針對 2024 年土地覆蓋預測設定多組 CA 模擬條件，參考前人研究，考量預測模擬時間間隔為選定依據，因此設定以 1、3、5、7、10、15 及 20 次迭代進行測試，並搭配兩種 CA-Markov 與 RF-CA-Markov 不同的模型所預測的結果，與實際 2024 年土地覆蓋型圖比較，並計算整體準確度與 Kappa 值等指標，以評估不同迭代條件下模型預測效能之差異，所得結果如表 39。結果顯示，兩種模型在迭代次數為 3 時表現最佳。CA-Markov 模型於此條件下準確度達 84.88%，Kappa 值為 0.253，而 RF-CA-Markov 模型則達最高準確度 95.78%，Kappa 值為 0.522，模型效能較佳。


由表 40 兩種方法在不同迭代次數時整體準確度與 Kappa 值所呈現之折線圖，可清楚看到，隨著迭代次數增加，CA-Markov 模型的預測精度呈現緩幅下降趨勢。而 RF-CA-Markov 模型則於 3 次迭代後即維持穩定，顯示其潛勢圖已有效掌握轉換特性，模擬表現對迭代次數變動不具敏感性。Mondal et al. (2020) 研究結果提到較少的迭代次數與較短的預測時間間隔，空間預測準確度最高。本研究在預測間隔時間為 7 年的情形下，發現迭代次數 3 次即可呈現模型最佳效能。

綜合模型效能與穩定性考量，本研究選定迭代次數 3 次，作為 CA 模型模擬未來土地覆蓋變遷之最適參數設定，並以此進行 2031 年土地覆蓋類型的預測模擬。

表 39 CA 模型迭代次數與模型精度結果

迭代 次數	方法	實際植生		實際崩塌		整體準 確度	Kappa 值
		預測植生	預測崩塌	預測植 生	預測崩塌		
1	CA-Markov	537353	108122	12596	9523	81.50%	0.087
	RF-CA-Markov	625004	20471	5835	16284	95.57%	0.509
3	CA-Markov	548842	96633	1347	20772	84.88%	0.253
	RF-CA-Markov	626475	19000	5835	16284	95.78%	0.522
5	CA-Markov	548741	96734	1380	20739	84.86%	0.252
	RF-CA-Markov	626475	19000	5835	16284	95.78%	0.522
7	CA-Markov	548611	96864	1506	20613	84.82%	0.25
	RF-CA-Markov	626475	19000	5835	16284	95.78%	0.522
10	CA-Markov	548244	97231	1806	20313	84.72%	0.246
	RF-CA-Markov	626475	19000	5835	16284	95.78%	0.522
15	CA-Markov	548042	97433	2035	20084	84.64%	0.242
	RF-CA-Markov	626475	19000	5835	16284	95.78%	0.522
20	CA-Markov	547653	97822	2404	19715	84.55%	0.237
	RF-CA-Markov	626475	19000	5835	16284	95.78%	0.522

表 40 迭代次數折線圖比較表



七、 2024 年森林覆蓋預測與驗證

本研究利用 2009 - 2017 時段的資料，分別應用 CA-Markov 及 RF-CA-Markov 方法生成 2024 年土地覆蓋預測圖。預測結果如圖 47 所示，並透過空間統計計算植生與崩塌地覆蓋類別的分布面積，結果如表 41。由表中顯示 RF-CA-Markov 方法預測的植生面積為 6347.12 ha，崩塌地面積為與 351.51 ha，而 CA-Markov 方法預測的植生面積為 5505.56 ha，崩塌地面積為與 1193.84 ha。與 2024 實際植生覆蓋面積 6482.25 ha，崩塌地面積 226.28ha 相比，RF-CA-Markov 預測模型較與 CA-Markov 模型與實際情況較為接近，而 CA-Markov 模型明顯高估了崩塌地的範圍，導致植生覆蓋面積的低估。從圖 44 中亦可明顯看出，CA-Markov 模型預測的崩塌地（紅色區域），分布明顯較實際分布多，顯示該模型在崩塌地的模擬存在高估現象。

為比對 RF-CA-Markov 所預測植生與崩塌地空間分布圖與實際土地覆蓋情形的差異，本研究運用 GIS 進行空間套圖分析，並製作圖 48 進行視覺呈現。圖中以深綠色與咖啡色標示預測與實際不一致之區域，其中咖啡色區塊代表實際為崩塌地但模型預測為植生，深綠色區塊則為實際為植生但被模型錯誤預測為崩塌地。

從空間分布可觀察到，大多數錯誤為實際植生預測為崩塌地的區域集中於主要河道及其鄰近地帶，而實際為崩塌地預測為植生區域比例相對較小。結果顯示 RF 模型在面對地形起伏與水文環境的條件下，較容易將實際穩定之植生地誤判為不穩定的崩塌類型。這可能也與模型訓練資料中崩塌樣本與河道鄰近環境的高度重疊有關，使模型在此環境條件下產生誤判。

此外，空間誤判的現象亦反映於 RF 模型準確度評估結果。根據表 39，RF 崩塌復育模型於植生轉變為崩塌地類別之準確度僅為 0.76，代表在模擬復育的過程存在一定的錯誤率。此結果顯示 RF 模型在模擬崩塌復育如此複雜地形與環境交互作用的過程時，效能可能受限，導致所產生的機率轉移圖存在誤差，進而影響 RF-CA-Markov 模型整體模擬精度。建議未來除強化訓練與樣本的代表性與品質外，亦可從優化崩塌復育模型處理，加強變數選擇的面向，以整體提升土地覆蓋變化模擬模型之效能。




圖 47 2024 年實際土地覆蓋型圖與預測成果圖(左為 2024 實際土地覆蓋型圖,中為 2024 CA-Markov 模型預測圖,右為 2024 RF-CA-Markov 模型預測圖)

表 41 2024 實際土地覆蓋與模型預測面積比較表

型態	面積 (ha)		
	2024 實際土地覆蓋	CA_Markov 預測	RF-CA-Markov 預測
植生	6482.25	5505.56	6347.12
崩塌地	226.28	1193.84	351.51




圖 48 2024 年土地覆蓋型圖與 RF-CA-Markov 模型預測結果疊合圖

整體而言，本研究透過 RF-CA-Markov 與 CA-Markov 兩種預測模型，生成的 2024 年土地覆蓋預測圖，與實際 2024 年土地覆蓋型圖進行比對，根據表 40 中，CA-Markov 模型(迭代 3 次)的整體準確度為 84.88%，而 RF-CA-Markov 模型的整體準確度為 95.78%，顯示 RF-CA-Markov 模型的預測表現優於傳統 CA-Markov 模

型。

此外，透過 Kappa 值進一步評估模型的分類一致性，結果顯示 RF-CA-Markov 模型的 Kappa 值為 0.522，屬於中等可接受範圍。CA-Markov 模型的 Kappa 值為 0.253，反應其預測準確性較低，模型對土地覆蓋變化的適配性有限。

根據 Ait et al. (2023) 的研究，Kappa 值高於 0.40 被視為可接受的分類結果，而超過 0.75 則表示較高準確性。本研究結果顯示，RF-CA-Markov 的 Kappa 值達 0.52，符合可接受範圍，而 CA-Markov 模型則低於該標準，表示其在預測土地覆蓋變遷方面的準確度較低。

從 2024 RF-CA-Markov 模型預測結果圖年與實際土地覆蓋型圖的空間疊合分析，發現 RF-CA-Markov 在實際為植生預測為崩塌地這個類別，其空間位置集中於河道四周會有較多的偏移，除因 RF 模型訓練樣本之代表性影響外，參考表 38 及 39，RF 崩塌潛勢與復育模型的比較，發現崩塌復育模型準確度偏低，而其中實際植生預測為崩塌地，又較實際為崩塌預測為植生，失誤率較大。崩塌復育是一項高度複雜且具有長期連續性的生態過程，為優化模型效能，未來除建議強化模型變數選擇外，亦應持續進行崩塌復育的長期監測與資料蒐集，以提升模型的模擬與預測能力，進而作為掌握土地變遷動態的重要依據。

八、 2031 年森林覆蓋預測

本研究根據 RF-CA-Markov 與 CA-Markov 模型模擬 2024 年土地覆蓋型的評估結果，選擇預測效能較佳之 RF-CA-Markov 模型，作為預測 2031 年土地覆蓋變化的主要方法。首先以 2017 - 2024 年土地覆蓋變化與驅動因子資料訓練 RF 模型以產生轉移機率，並結合 CA-Markov 模型進行空間模擬。依據前述敏感性分析結果，設定迭代次數為 3 次，所得 2031 年預測結果如圖 49。

從預測結果圖可明顯看出植生（綠色）與崩塌地（紅色）的空間分布情形。植生的範圍涵蓋六龜試驗林大部份的區域，而崩塌地則主要集中在河道兩側，其中又以南部溫泉溪上游區域崩塌地現象較為密集，顯示出該區域地形與植生條件可能具有高脆弱性。

根據表 35 Markov 轉移矩陣顯示，全區「植生轉崩塌地」的轉變比例相對較低，僅餘 15.8%，而「崩塌地轉植生」則有 60.8%。顯示在災後中後期復育進程，

整體呈現恢復趨勢。結合 RF 模型推估之機率轉移圖與 CA 模型空間模擬，2031 年預測結果顯示，植生面積為 6350.29 ha，崩塌地面積為 356.1 ha。此結果與 2024 年 RF-CA-Markov 模型所預測的植生面積為 6347.12 ha，崩塌面積為 351.51 ha 相近。顯示若無重大擾動事件發生，2024–2031 年間的 land cover 變遷速率趨緩，崩塌與復育趨於穩定。

此外，從圖中 25 筆臺灣杉造林地(橘色線)之空間重疊分析可觀察到，2031 年預測多數造林地內仍為植生覆蓋，崩塌地分布較少，顯示臺灣杉造林地在 2031 年所面臨的崩塌風險相對較低。此一結果可作為未來經營策略擬定之依據，建議可將重點放在人工林經營與木材生產策略的優化。在自然演替低，林木生長良好的臺灣杉林地，依據可伐採地的相關規定，規劃適度伐採作業，並推動適地適木的造林經營策略，以提升木材自給率，並促進碳吸存效益。






圖 49 2031 年 RF-CA-Markov 模型預測成果圖

第五章 結論

本研究結合多時期的航遙測影像，針對六龜試驗林進行長期監測與模型建構，探討臺灣杉人工林的變遷、莫拉克風災後崩塌及復育之空間動態，並應用邏輯迴歸與隨機森林建構多項模型，進行因子探討與未來土地覆蓋變遷之模擬。整體研究成果歸納如下：

一、研究成果

- (一) 早期 1980-1990 年代所造的臺灣杉人工林林地，至 2020 年北鳳岡林區臺灣杉存留面積佔比為 67.2%，南多納林區僅為 32.6%。透過隨機森林模型分析發現，南北兩區模型中「雨量」及「高程」為共同的重要因子，顯示出其對臺灣杉生長具有普遍性的影響；此外，北區模型有納入「林齡」為關鍵因子，而南區模型則以「坡向」為具影響因子，這也說明不同區域對特定因子的敏感性不同，也會影響模型效能的表現。
- (二) 莫拉克颱風後六龜崩塌整體呈現劇烈減少、後趨穩定變化趨勢。2009-2011 年崩塌面積迅速下降，2011-2024 年間則趨於平穩。若以分段結果來看，2009-2017 年間崩塌地減少面積為 2017-2024 年間的 3 倍，這也顯示出災後初期生態系具備良好的自然恢復力。
- (三) 從崩塌相關地景指標變化來看，崩塌地堆塊數量逐年減少，地景複雜度降低，且崩塌地形狀趨於簡化。同時 CONTAG 指標逐漸上升，反映崩塌地景的聚集性提升。相較之下，PAFRAC 指標的變化趨勢則異於其他的地景指標，呈現波動狀態，且其高峰時期多與實際災害擾動發生時間相符，顯示 PAFRAC 指標對干擾事件具有高度敏感性，具作為干擾監測與偵測指標的應用性。
- (四) 在崩塌潛勢模型建構方面，本研究針對不同空間解析度進行測試，結果顯示 10 m 解析度在整體準確度、ROC 及 AUC 表現均優於其他解析度。因子重要性分析中，樹冠結構指標具高度貢獻，顯示地表森林結構與崩塌潛勢有密切耦合關係。整體而言，隨機森林模型不僅於崩塌潛勢分析表現優異，也在崩塌復育模型與臺灣杉人工林自然演替模型中皆優於邏輯迴歸模型，突顯其在複雜自然系統推論上的優勢。
- (五) 崩塌復育變遷分析顯示 2012 年為復育面積最高峰，而 2011 年具顯著空間相

關性，代表此年度崩塌復育集中在特定地區，而 2012 年至 2018 年間的復育區域空間未具顯著聚集性，可能因遭受多次極端降雨事件所致，也因為復育區反覆發生崩塌，也導致復育面積後續未持續增加，而是趨於平穩。隨機森林模型顯示「影響距崩塌地邊緣距離」、「高程」與「坡度」為影響復育潛力的三大關鍵因子，顯示種源的鄰近性、地形與環境條件為復育過程的重要決定素。

(六) 在崩塌潛勢與復育建模部份，崩塌潛勢模型預測的預測準確度相對較高。除了復育過程本身受時間與環境異質等複雜因子影響外，空間自相關分析亦顯示復育區的空間分布具有較高的不確定性，以致影響崩塌復育模型的預測效能。災後復育地區常遭遇再次崩塌干擾，導致其空間連續性與分布穩性降低，這也與長期監測崩塌面積變化分析，所觀察再崩塌發生的趨勢一致。

(七) 比較 CA-Markov 模型與 RF-CA-Markov 模型預測 2024 年土地覆蓋效能，CA-Markov 模型整體準確度達 84.88%，Kappa 值為 0.253；而 RF-CA-Markov 整體準確度達 95.78%，Kappa 值為 0.522，顯示 RF-CA-Markov 模型效能較佳。傳統 CA-Markov 模型未能納入土地覆蓋變動與其驅動因子之量化關係，使其在模擬土地覆蓋動態變遷過程中，可能忽略關鍵的環境與空間影響因素。因此，本研究引入隨機森林模型，藉由整合崩塌潛勢與復育之潛在驅動因子，訓練土地覆蓋變遷之轉換規則，並生成轉變潛力圖，取代 CA 模型中以鄰近性為主的演化規則，使預測更能反映真實環境條件下的土地變遷機制。

(八) 透過 2024 年土地覆蓋面積的統計分析進一步顯示，CA-Markov 模型明顯高估了崩塌地的範圍，導致植生覆蓋面積的低估。另外從 RF-CA-Markov 模型所產生之預測圖與實際 2024 年土地覆蓋類型圖進行空間疊合分析發現，原屬植生但被預測為崩塌地的類別，空間誤差多集中於河道周邊區域。此偏差除可能來自 RF 模型訓練樣本代表性不足外，亦反應崩塌復育模型模擬準確性的影響。

(九) 以 RF-CA-Markov 模型模擬 2031 年土地覆蓋變化，預測結果指出，六龜試驗林區整體以植生為主，崩塌地則集中分布於河道周邊，尤以南部溫泉溪上游為崩塌較為密集區域。轉移矩陣與面積變化分析亦顯示，崩塌地有明顯復育趨勢，且 2024 至 2031 年間的土地覆蓋變遷趨於穩定，推估在無重大擾動事件發生的情況下，未來崩塌與復育將呈現相對平衡狀態。

二、森林經營與模型建構建議

(一) 森林經營建議

為配合當前「加強森林經營管理、提高國產材利用」之施政策略，並兼顧森林生態與保安的功能，綜整本研究所得結果，提出以下森林經營管理建議：

1. 2031 年土地覆蓋變遷預測結果顯示，臺灣杉造林地區域整體仍以植生覆蓋為主，顯示其面臨崩塌風險相對較低。建議未來在臺灣杉造林地之經營規劃，可優先聚焦於人工經營與木材生產策略的發展。
2. 根據臺灣杉造林地之長期變遷分析結果顯示，六龜試驗林北鳳岡林區，臺灣杉人工林生長狀況良好，且歷經 40 年存活率仍高。因此建議在此區域應有積極經營作為，針對年齡較大的臺灣杉人工林，在坡度平緩，且非水源保護區的造林地內，設定適當的輪伐期，提供木材生產之所需外，亦需考量對環境干擾的頻度，減少對生態系的衝擊。除此之外，應配合適當疏伐作業，減少過密競爭，促進保留木生長，並促進地被植物的生長，減緩地表逕流及沖蝕，提升整體生物多樣性。
3. 臺灣杉人工林生長表現相對不佳的南多納林區，則可調整為低干擾經營策略，以近自然營林理念為核心，透過自然演替逐步轉為混交林或闊葉林，使林分結構與物種組成趨近天然林，形成複層混交異齡之林相，提高造林地生物多樣性與氣候調適能力。
4. 依據崩塌潛勢模型的研究結果，樹冠結構指標與崩塌潛勢具高度關聯，顯示樹冠結構在土壤穩定與水文調節上扮演關鍵角色，因此未來森林防災管理規劃，建議在高崩塌潛勢區域，強化樹冠結構的經營，如提高樹冠密度、促進多層次林冠發展，以提高土壤穩定與雨水攔截能力，降低崩塌風險，達成災害調適與生態保育的目標。
5. 依據 2009、2017 及 2024 年三時期崩塌地時間序列變遷分析，發現多納林區臺灣杉造林地號「六-20-74-10」為一具有高度崩塌風險區位，且該地號鄰近多納苗圃，並且位於林道路徑旁，屬人員來往的地段，對人員或林道安全具有潛在風險。應優先強化地表穩定措施。

(二) 模型建構建議

1. 本篇研究不管是崩塌潛勢、崩塌復育，或是臺灣杉人工林自然演替等多

項模型建構，均顯示隨機森林較傳統邏輯迴歸具更佳的預測表現。邏輯迴歸屬於較為簡化的線性統計模型，假設自變數與結因變數之間具線性關係，較難有效描述自然界中複雜且非線性的生態與地貌變化特性。而隨機森林可同時處理非線性關係與多個變數間的交互影響，能從大量資料中找出規律，對於推論自然系統中多重因子交互作用的情形更為適合。因此根據本研究結果，建議未來進行相關模型建構時，可考慮採用隨機森林等機器學習方法，以提升模型的適用性與預測準確度。

2. 此外在模型建構時，應考量區域異質性，如本研究在台灣杉人工造林地，南北區域造林地，環境條件差異較大，區域變化有明顯差異，因此研究結果發現利用分區建模其效能較全區建模效能提升。因此建議若研究區其空間在有異質性差異時，可考量建立分區模型，以提升模型的適用性與準確性。
3. 在模型建構過程，空間解析度為影響模型效能之關鍵因素之一。本研究針對六龜區域進行崩塌潛勢及崩塌復育分析，結果顯示以 10 m 解析度所建構之模型在整體準確度優於其他解析度，顯示其為六龜區域較為適宜之空間分析尺度。因此建議未來進行模型建構時，應優先針對研究區進行解析度適用性測試，選擇最適解析度後再進行後續分析與應用，以提升模型準確性與應用效能。
4. 在崩塌潛勢模型納入空載光達衍生的樹冠結構指標，有效提升了模型的預測效能。空載光達能提供高解析大範圍的地形資料，包含 DSM 及 DEM，可進一步快速推算樹冠高度模型及其他樹冠結構相關指標，作為森林結構變異之量化依據。結合多時期空載光達資料，更能掌握森林垂直結構在長期尺度下的變遷動態，對於森林監測與災後評估具有高度應用價值。隨著目前政府定期蒐集全臺空載光達資料，產製地形資料的能量，將可有效整合應用於災害潛勢分析與森林結構長期監測規劃。
5. 在進行 CA-Markov 與 RF-CA-Markov 模型模擬預測時，可進行迭代次數敏感性測試。當迭代次數設定太低，模擬的空間變化趨勢尚無法充分計算，預測轉變情形結果可能低估，但若迭代次數過高，則易導致空間變化模擬過度，預測效果失真。因此可先行透過測試選擇最佳迭代參數，

能展現預測模型最佳效果。並且本研究結果顯示，以 RF-CA-Markov 模型模擬預測六龜區域土地覆蓋變遷，其效能較 CA-Markov 模型好。

三、未來研究建議

本研究結合多期衛星影像、空間資訊分析與機器學習技術，針對臺灣杉造林地自然演替及崩塌潛勢與復育動態進行分析，並導入隨機森林預測發生變化機率潛力，結合 CA-Markov 進行未來土地覆蓋變遷模擬。研究成果顯示，RF-CA-Markov 模型相較傳統 CA-Markov 模型更具有應用於山區土地變遷預測的潛力。

此外，本研究亦針對崩塌潛勢與復育過程分別建模，並探討驅動因子於不同時段下之貢獻差異，證實冠層結構、NDVI 與地形環境因子在預測模型中的重要性。亦顯示森林垂直結構與地形條件對崩塌與復育動態具有高度解釋力。由於傳統光學影像對林分高度與結構資訊掌握有限，因此本研究證實導入空載光達資料之重要性，有助於量化樹冠垂直結構等特徵，補足現有光學影像在結構面向上的不足，提升模型在異質地貌與複雜森林環境中的預測效能。

本研究在分析結果與實務應用上提出具體參考的成果，惟在資料與模型應用上仍有若干限制，如本研究在崩塌潛勢與復育模型未納入氣象因子，主要受限於氣象資料於山區之精度，與本研究模型尺度有效對應問題，因此針對極端氣候事件並未納入模型預測；同時，山區地形起伏劇烈，造成衛星影像產生大量陰影區域，本研究以扣除陰影聯集區域進行相關研究，但相對使樣區取得範圍受到限制；另外航照正射與衛星影像屬垂直視角所取得之資料，主要反映森林上層冠層的光譜與結構特徵，無法穿透植被層觀察底層或林下結構，因此在臺灣杉自然演替模型主要針對航遙測影像可判釋的資訊進行相關分析，無法分析林下演替狀況。

因此綜合本研究之過程與結果，提出後續研究可強化與延伸的建議如下：

- (一) 建議未來研究可透過降尺度技術，取得高解析度的氣象資料，特別是以事件型降雨或強降雨時段資料作為潛在驅動因子，以提升模型對極端氣候影響之反應能力。此外，本研究分析中所應用之 PAFRAC 地景指標，經證實相較其他地景指標更敏感於地景結構之變化，具高度識別干擾事件的能力。因此建議可將 PAFRAC 與高時效性的颱風與強降雨事件資料結合，作為建模參考，以提升對於地景干擾發生與土地覆蓋變遷之早期預警與模擬能力。

- (二) 崩塌地類型可能包含坡面型或溪流型等不同崩塌形式，各型態之形成機制與控制因子可能會有所差異。建議未來可將崩塌潛勢模型依型態進行分類建模，針對不同類型建立專屬模型，有助於提升模型預測精度與適用性。
- (三) 建議未來模型應考慮影像資料與環境因子在時間序列中的效力持續時間，導入離散時間模型架構，評估各因子對不同時間尺度預測的穩定性與持續性，有助於提升時間動態模擬的準確性。
- (四) 崩塌與復育具高度時空異質性與動態性，建議持續進行多時期資料收集與監測作業，定期更新模型訓練資料與驗證，確保模型具備即時性與發展性，以支援未來風險管理與林地經營決策之需求。



參考文獻

- 王素芬、陳永寬、鄭祈全 (1999)。地理資訊系統和碎形維度於森林地景空間變化上之應用。 *航測及遙測學刊*，4(2)，33-53。
[https://doi.org/10.6574/JPRS.1999.4\(2\).3](https://doi.org/10.6574/JPRS.1999.4(2).3)。
- 孔繁恩、詹進發、邵怡誠、李茂園、葉堃生、陳連晃 (2014)。物件式分類法於高解析度航照影像萃取崩塌地之研究。 *航測及遙測學刊*，18(4)，267-281。
[https://doi.org/10.6574/JPRS.2014.18\(4\).5](https://doi.org/10.6574/JPRS.2014.18(4).5)。
- 中華林學會 (1995)。臺灣貴重針葉五木。 *中華林學叢書*，956 號。
- 宋承恩、王韻皓、林國聖、王培蓉、詹進發、陳毅青、王素芬 (2022)。以多時期衛星影像及樹冠高程模型分析崩塌植生復育與影響因素。 *農業工程學報*，68(4)，44-62。
[https://doi.org/10.29974/JTAE.202212_68\(4\).0006](https://doi.org/10.29974/JTAE.202212_68(4).0006)。
- 汪大雄、王兆桓、陳家玉 (2001)。臺灣地區人工林地位生產力指數模式之建立。 *臺灣林業科學*，16(4)，307-315。
<https://doi.org/10.7075/TJFS.200112.0307>。
- 呂明倫、何芄薇 (2014)。使用細胞自動化模擬烏石坑地區之地景動態。 *台灣生物多樣性研究*，16(3)，211-223。
- 邱清安、徐憲生 (2015)。面對退化地之抉擇：被動的自生演替恢復 vs. 主動的人為生態復育。 *林業研究季刊*，37(2)，85-98。
- 林文智 (2012)。六龜試驗林造林地清查成果及其後續經營。台北：林業試驗所造林地清查及後續經營研討會論文集。
- 林文雄、林登秋、陳毓禎、紀正良 (2002)。臺灣東北部三種相鄰林分林下光照環境之比較。 *林業研究季刊*，24(3)，49-58。
- 林照松、洪富文 (1991)。六龜地區臺灣杉人工林之生長。 *林業試驗所研究報告季刊*，6(3)，229-248。
- 林業試驗所 (1982)。臺灣省林業試驗所六龜分所試驗林經營計畫（民國 71 年 7 月-民國 81 年 6 月）。臺灣省林業試驗所。

- 林業試驗所 (2002)。農委會林業試驗所六龜試驗林經營計畫 (民國 91 年- 95 年)。台北：行政院農業委員會林業試驗所。
- 孟慶繁 (1998)。人工林生物多樣性研究的現狀及展望。 *世界林業研究*，11(2)，26-31。
- 顏添明 (1999)。林木生長收穫相關問題之探討。 *臺灣林業*，25(5)，30-35。
- 陳麗琴、黃進睦、林俊秀 & 邱祈榮 (1997)。六龜試驗林台灣杉人工林蓄積量及生長估測之研究。 *台灣林業科學*，12(3)，319-327。
<https://doi.org/10.7075/TJFS.199709.0319>。
- 陳永寬、鄭祈全、廖錦偉 (1998)。應用地理資訊系統篩選臺灣杉造林地。 *航測及遙測學刊*，3(2)，47-70。[https://doi.org/10.6574/JPRS.1998.3\(2\).3](https://doi.org/10.6574/JPRS.1998.3(2).3)。
- 陳建帆、蘇迎晨、林奐宇 (2021)。向自然演替植群學習-中高海拔崩塌地植群演替與復育芻議。 *林業研究專訊*，28(6)，13-17。
- 陳鑄、傅偉聰、黃鈺麟、闕晨曦、鄭祈全、董建文 (2020)。福州市土地利用景觀格局變化及驅動力研究。 *西南師範大學學報*，45(1)，99-107。
- 張政亮、張瑞津 (2006)。運用馬可夫鏈模型與細胞自動機理論模擬植生復育之研究:以九九峰地區為例。 *地理研究*，45，23-142。
- 張政亮 (2006)。馬可夫鏈模型 (Markov Chain Model) 在地理學研究之運用。 *國教新知*，53(1)，72-86。[https://doi.org/10.6701/TEEJ.200603_53\(1\).0012](https://doi.org/10.6701/TEEJ.200603_53(1).0012)。
- 莊智瑋、林昭遠、錢滄海 (2010)。以馬可夫鏈模式推估九份二山崩塌地植生復育之研究。 *水土保持學報*，42(3)，329-344。
- 陸象豫、范義彬、孫銘源 (2019)。林道對環境生態的影響。 *林業研究專訊*，26(5)，66-69。
- 陸象豫、黃惠雪、孫銘源 (2018)。六龜試驗林氣候概況。 *林業研究專訊*，25(5)，58-62。
- 陸象豫、林昭遠、黃良鑫 (2011)。莫拉克颱風後六龜試驗林崩塌地空間分佈特性

- 探討。 *台灣林業科學*，26(4)，399-408。
<https://doi.org/10.29953/FRN.201206.0016>.
- 游漢明 (2003)。臺灣針葉人工林的植種多樣性——以竹東造林中心柳杉人工林為例。 *林業研究季刊*，25(4)，99-102。
- 黃雅莉、陳朝圳 (2018)。以地景指數探討高屏河流域崩塌地之時序變遷。 *林業研究季刊*，40(1)，13-30。
- 葉春國、莊永忠、廖學誠 (2013)。水里溪上游集水區檳榔園熱點空間分析之研究。 *中華水土保持學報*，44(3)，202-214。
[https://doi.org/10.29417/JCSWC.201309_44\(3\).0002](https://doi.org/10.29417/JCSWC.201309_44(3).0002).
- 鄔建國 (2003)。景觀生態學-格局、過程、尺度與等級。台北:五南出版社。
- 羅紅、陳磊、姜運力、李從瑞、周鳳嬌、吳建普 (2021)。自然保護地整合優化的景觀格局變化分析——以貴州省思南縣為例。 *生態學報*，41(20)，8076–8086。
- 鄭祈全、詹進發、許立達 (1999)。應用碎形維度監測森林地景結構與變遷之研究。 *臺灣林業科學*，14(4)，397-407。<https://doi.org/10.7075/TJFS.199912.0397>。
- 鄭祈全、吳治達、王素芬 (2005)。應用 Markov 和 Logit 模式監測地景變遷之研究。 *台灣林業科學*，20(1)，29-36。<https://doi.org/10.7075/TJFS.200503.0029>。
- 臺灣氣候變遷推估資訊與調適知識平台。<https://tccip.ncdr.nat.gov.tw/>。(2020/2/25 瀏覽)
- 劉業經、鄭宗元、賀主伯、歐辰雄、朱成本、呂金誠 (1985)。臺灣杉種源之研究。 *中華林學季刊*，18(1)，1-8。
- 謝依達、吳守從、鄭祖安、魏浚紘、鍾玉龍、陳建彰 (2013)。氣象因子對臺東地區柳杉與樟樹人工林生長之影響。 *作物、環境與生物資訊*，10(3)，209-216。
[https://doi.org/10.30061/CEB.201309_10\(3\).0005](https://doi.org/10.30061/CEB.201309_10(3).0005).
- Adzandeh, E. A., Alaigba, D., & Nkemasong, C. N. (2020). Application of Geospatial

- Techniques and Logistic Regression Model for Urban Growth Analysis in Limbe, Cameroon. *Nigerian Journal of Environmental Sciences and Technology (NIJEST)* Vol, 4(1), 138-151. <https://doi.org/10.1036263/nijest.2020.01.0193>.
- Ahmed, O. S., Franklin, S. E., Wulder, M. A., & White, J. C. (2015). Characterizing stand-level forest canopy cover and height using Landsat time series, sample of airborne LiDAR, and the Random Forest algorithm. *ISPRS Journal of Photogrammetry and remote sensing*, 101, 89-101. <https://doi.org/10.1016/j.isprsjprs.2014.11.007>.
- Aiba, S. I., & Kitayama, K. (1999). Structure, composition and species diversity in an altitude-substrate matrix of rain forest tree communities on Mount Kinabalu, Borneo. *Plant Ecology*, 140, 139-157. <https://doi.org/10.1023/A:1009710618040>.
- Ait El Haj, F., Ouadif, L., & Akhssas, A. (2023). Simulating and predicting future land-use/land cover trends using CA-Markov and LCM models. *Case Studies in Chemical and Environmental Engineering*, 7, 100342. <https://doi.org/10.1016/j.cscee.2023.100342>.
- Aljehani, L. (2023). Integrating Markov chain and cellular automata models in gis to monitor and predict land use and cover change in Rabigh city, Saudi Arabia. *Int J Appl Eng Technol*, 5(4), 1-9.
- Akosah, S., Gratchev, I., Kim, D. H., & Ohn, S. Y. (2024). Application of artificial intelligence and remote sensing for landslide detection and prediction: systematic review. *Remote Sensing*, 16(16), 2947. <https://doi.org/10.3390/rs16162947>.
- Amini, S., Homayouni, S., Safari, A., & Darvishsefat, A. A. (2018). Object-based classification of hyperspectral data using Random Forest algorithm. *Geo-spatial information science*, 21(2), 127-138. <https://doi.org/10.1080/10095020.2017.1399674>.
- Angelstam, P., Grodzynski, M., Andersson, K., Axelsson, R., Elbakidze, M., Khoroshev, A., & Naumov, V. (2013). Measurement, collaborative learning and research for sustainable use of ecosystem services: Landscape concepts and Europe as laboratory. *Ambio*, 42, 129-145. <https://doi.org/10.1007/s13280-012-0368-0>.
- Anselmetto, N., Weisberg, P. J., & Garbarino, M. (2024). Global change in the European

- Alps: A century of post-abandonment natural reforestation at the landscape scale. *Landscape and Urban Planning*, 243, 104973.
<https://doi.org/10.1016/j.landurbplan.2023.104973>.
- Arora, A., Pandey, M., Mishra, V. N., Kumar, R., Rai, P. K., Costache, R., & Di, L. (2021). Comparative evaluation of geospatial scenario-based land change simulation models using landscape metrics. *Ecological Indicators*, 128, 107810.
<https://doi.org/10.1016/j.ecolind.2021.107810>.
- Asif, M., Kazmi, J. H., Tariq, A., Zhao, N., Guluzade, R., Soufan, W., ... & Aslam, M. (2023). Modelling of land use and land cover changes and prediction using CA-Markov and Random Forest. *Geocarto International*, 38(1), 2210532.
<https://doi.org/10.1080/10106049.2023.2210532>.
- Avery, T. E., & Berlin, G. L.(1992). Fundamentals of remote sensing and air photo interpretation, Macmillan.
- Basheer, S., Wang, X., Farooque, A. A., Nawaz, R. A., Liu, K., Adekanmbi, T., & Liu, S. (2022). Comparison of land use land cover classifiers using different satellite imagery and machine learning techniques. *Remote Sensing*, 14(19), 4978.
<https://doi.org/10.3390/rs14194978>.
- Bathurst, J. C., Bovolo, C. I., & Cisneros, F. (2010). Modelling the effect of forest cover on shallow landslides at the river basin scale. *Ecological Engineering*, 36(3), 317-327. <https://doi.org/10.1016/j.ecoleng.2009.05.001>.
- Beroho, M., Briak, H., Cherif, E. K., Boulahfa, I., Ouallali, A., Mrabet, R., ... & Aboumaria, K. (2023). Future scenarios of land use/land cover (LULC) based on a CA-markov simulation model: case of a mediterranean watershed in Morocco. *Remote Sensing*, 15(4), 1162. <https://doi.org/10.3390/rs15041162>.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Brockerhoff, E. G., Jactel, H., Parrotta, J. A., Quine, C. P., & Sayer, J. (2008). Plantation forests and biodiversity: oxymoron or opportunity?. *Biodiversity and Conservation*, 17, 925-951. <https://doi.org/10.1007/s10531-008-9380-x>.
- Cechim Junior, C., Araki, H., & de Campos Macedo, R. (2023). Object-based image

- analysis (obia) and machine learning (ml) applied to tropical forest mapping using sentinel-2. *Canadian Journal of Remote Sensing*, 49(1), 2259504.
<https://doi.org/10.1080/07038992.2023.2259504>
- Chen, G., & Hay, G. J. (2011). A support vector regression approach to estimate forest biophysical parameters at the object level using airborne LiDAR transects and quick bird data. *Photogrammetric Engineering Remote Sensing*, 77, 733-741.
<https://doi.org/10.14358/PERS.77.7.733>.
- Chen, G., Hay, G. J., & St-Onge, B. (2012). A GEOBIA framework to estimate forest parameters from LiDAR transects, Quickbird imagery and machine learning: a case study in Quebec, Canada. *International Journal of Applied Earth Observation and Geoinformation*, 15, 28-37. <https://doi.org/10.1016/j.jag.2011.05.010>.
- Chen B, & Iannone B. (2020). FRAGSTATS: A Free Tool for Quantifying and Evaluating Spatial Patterns: FOR362/FR431, 6/2020, 2020(6), 9-9.
<https://doi.org/10.32473/edis-fr431-2020>.
- Cheng, K., Yang, H., Guan, H., Ren, Y., Chen, Y., Chen, M., & Guo, Q. (2024). Unveiling China's natural and planted forest spatial-temporal dynamics from 1990 to 2020. *ISPRS Journal of Photogrammetry and Remote Sensing*, 209, 37-50.
<https://doi.org/10.1016/j.isprsjprs.2024.01.024>.
- Chughtai, A. H., Abbasi, H., & Karas, I. R. (2021). A review on change detection method and accuracy assessment for land use land cover. *Remote Sensing Applications: Society and Environment*, 22, 100482. <https://doi.org/10.1016/j.rsase.2021.100482>.
- Chunhui, Z., Bing, G., Lejun, Z., & Xiaoqing, W. (2018). Classification of Hyperspectral Imagery based on spectral gradient, SVM and spatial random forest. *Infrared Physics & Technology*, 95, 61-69. <https://doi.org/10.1016/j.infrared.2018.10.012>.
- Cillis, G., Statuto, D., & Picuno, P. (2021). Historical gis as a tool for monitoring, preserving and planning forest landscape: A case study in a mediterranean region. *Land*, 10(8), 851. <https://doi.org/10.3390/land10080851>.
- Cohen, W. B., Kushla, J. D., Ripple, W. J., & Garman, S. L. (1996) An introduction to digital methods in remote sensing of forested ecosystems: Focus on the Pacific

- Northwest USA. *Environmental Management*, 20(3), 421–435.
<https://doi.org/10.1007/BF01203849>.
- Cushman, S. A., Macdonald, E. A., Landguth, E. L., Malhi, Y., & Macdonald, D. W. (2017). Multiple-scale prediction of forest loss risk across Borneo. *Landscape Ecology*, 32, 1581–1598. <https://doi.org/10.1007/s10980-017-0520-0>.
- Da Cunha, E. R., Santos, C. A. G., da Silva, R. M., Bacani, V. M., & Pott, A. (2021). Future scenarios based on a CA-Markov land use and land cover simulation model for a tropical humid basin in the Cerrado/Atlantic forest ecotone of Brazil. *Land Use Policy*, 101, 105141. <https://doi.org/10.1016/j.landusepol.2020.105141>.
- Dale, V. H., Joyce, L. A., McNulty, S., Neilson, R. P., Ayres, M. P., Flannigan, M. D., & Wotton, B. M. (2001). Climate change and forest disturbances: climate change can affect forests by altering the frequency, intensity, duration, and timing of fire, drought, introduced species, insect and pathogen outbreaks, hurricanes, windstorms, ice storms, or landslides. *BioScience*, 51(9), 723–734. [https://doi.org/10.1641/0006-3568\(2001\)051\[0723:CCAFD\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2001)051[0723:CCAFD]2.0.CO;2).
- Dang, V. H., Hoang, N. D., Nguyen, L. M. D., Bui, D. T., & Samui, P. (2020). A novel GIS-based random forest machine algorithm for the spatial prediction of shallow landslide susceptibility. *Forests*, 11(1), 118. <https://doi.org/10.3390/f11010118>.
- De Aranzabal, I., Schmitz, M. F., Aguilera, P., & Pineda, F. D. (2008). Modelling of landscape changes derived from the dynamics of socio-ecological systems: A case of study in a semiarid Mediterranean landscape. *Ecological indicators*, 8(5), 672–685. <https://doi.org/10.1016/j.ecolind.2007.11.003>.
- Dezhkam, S., Jabbarian Amiri, B., Darvishsefat, A. A., & Sakieh, Y. (2017). Performance evaluation of land change simulation models using landscape metrics. *Geocarto international*, 32(6), 655–677. <https://doi.org/10.1080/10106049.2016.1167967>.
- Dislich, C., & Huth, A. (2012). Modelling the impact of shallow landslides on forest structure in tropical montane forests. *Ecological Modelling*, 239, 40–53.
<https://doi.org/10.1016/j.ecolmodel.2012.04.016>.
- Douandji, F. M. D., Kamga, B. Y., Ndumbe, L. N., Nkondjoua, A. D. T., Ngoh, M. L., &

- Franç, V. (2025). Land Use/Land Cover Dynamics and Future Changes Using a CA-Markov Model in the Mount Nlonako Forest and Peripheries (Littoral, Cameroon). *Journal of Geoscience and Environment Protection*, 13(2), 230-260.
<https://doi.org/10.4236/gep.2025.132015>.
- Durbha, S. S., King, R. L., & Younan, N. H. (2007). Support vector machines regression for retrieval of leaf area index from multiangle imaging spectroradiometer. *Remote sensing of environment*, 107(1-2), 348-361.
<https://doi.org/10.1016/j.rse.2006.09.031>.
- Ekwealor KU, Echereme CB, Ofobeze TN, & Okereke CN. (2019). Landscape Ecology: A Helicopter View. *International Journal of Plant & Soil Science* ,31(1), 1-20.
<https://doi.org/10.9734/IJPSS/2019/v31i130200>.
- Fayne, J. V., Ahamed, A., Roberts-Pierel, J., Rumsey, A. C., & Kirschbaum, D. (2019). Automated satellite-based landslide identification product for Nepal. *Earth Interactions*, 23(3), 1-21. <https://doi.org/10.1175/EI-D-17-0022.1>.
- Fensham, R. J., & Fairfax, R. J. (2002). Aerial photography for assessing vegetation change: a review of applications and the relevance of findings for Australian vegetation history. *Australian Journal of Botany*, 50(4), 415-429.
<https://doi.org/10.1071/BT01032>.
- Fischer, A. P. (2018). Forest landscapes as social-ecological systems and implications for management. *Landscape and Urban Planning*, 177, 138-147.
<https://doi.org/10.1016/j.landurbplan.2018.05.001>.
- Frolking, S., Palace, M. W., Clark, D. B., Chambers, J. Q., Shugart, H. H., & Hurtt, G. C. (2009). Forest disturbance and recovery: A general review in the context of spaceborne remote sensing of impacts on aboveground biomass and canopy structure. *Journal of Geophysical Research: Biogeosciences*, 114(G2).
<https://doi.org/10.1029/2008JG000911>.
- Fu, W. J., Jiang, P. K., Zhou, G. M., & Zhao, K. L. (2014). Using Moran's I and GIS to study the spatial pattern of forest litter carbon density in a subtropical region of southeastern China. *Biogeosciences*, 11(8), 2401-2409. <https://doi.org/10.5194/bg-11-2401-2014>.

- Fynn, I. E., & Campbell, J. (2018). Forest fragmentation and connectivity in Virginia between 2001 and 2011. *Journal of Landscape Ecology*, 11(3), 98-119.
<https://doi.org/10.2478/jlecol-2018-0014>.
- Garosi, Y., Sheklabadi, M., Pourghasemi, H. R., Besalatpour, A. A., Conoscenti, C., & Van Oost, K. (2018). Comparison of differences in resolution and sources of controlling factors for gully erosion susceptibility mapping. *Geoderma*, 330, 65-78.
<https://doi.org/10.1016/j.geoderma.2018.05.027>.
- Geetha, V., Punitha, A., Abarna, M., Akshaya, M., Illakiya, S., & Janani, A. P. (2020). An effective crop prediction using random forest algorithm. In *2020 international conference on system, computation, automation and networking (ICSCAN) IEEE*, pp.1-5. <https://doi.org/10.1109/ICSCAN49426.2020.926231>.
- Ghayour, L., Neshat, A., Paryani, S., Shahabi, H., Shirzadi, A., Chen, W., ... & Ahmad, A. (2021). Performance evaluation of sentinel-2 and landsat 8 OLI data for land cover/use classification using a comparison between machine learning algorithms. *Remote Sensing*, 13(7), 1349. <https://doi.org/10.3390/rs13071349>.
- Griffith J. A. (2002). Geographic techniques and recent applications of remote sensing to landscape-water quality studies. *Water Air and Soil Pollution*, 138, 181-197.
<https://doi.org/10.1023/A:1015546915924>.
- Guo F, Zhang L, Jin S, Tigabu M, Su Z, & Wang W. (2016). Modeling anthropogenic fire occurrence in the boreal forest of China using logistic regression and random forests. *Forests*, 7(11), 250. <https://doi.org/10.3390/f7110250>.
- Hansen, L. K., & Salamon, P. (1990). Neural network ensembles IEEE Transactions on Pattern Analysis and Machine Intelligence, 12(10), 993-1001.
<https://doi.org/10.1109/34.58871>.
- Hotta, W., Morimoto, J., Yanai, S., Uchida, Y., & Nakamura, F. (2022). Long-term recoveries of forest ecosystem components after shallow landslides were asynchronised among slope positions. *bioRxiv*, 2022-11.
<https://doi.org/10.1101/2022.11.07.515411>
- Hsu, L., & Cheng, C. (2000). Assessing landscape changes in the Liukuei ecosystem

- management area using Markov models. *Taiwan Journal of Forest Science*, 15(1), 41-49. <https://doi.org/10.7075/TJFS.200003.0041>.
- Huang, F., Teng, Z., Guo, Z., Catani, F., & Huang, J. (2023). Uncertainties of landslide susceptibility prediction: Influences of different spatial resolutions, machine learning models and proportions of training and testing dataset. *Rock Mechanics Bulletin*, 2(1), 100028. <https://doi.org/10.1016/j.rockmb.2023.100028>.
- Jamal, M., & Mandal, S. (2016). Monitoring forest dynamics and landslide susceptibility in Mechi–Balason interfluvies of Darjiling Himalaya, West Bengal using forest canopy density model (FCDM) and Landslide Susceptibility Index model (LSIM). *Modeling Earth Systems and Environment*, 2, 1-17. <https://doi.org/10.1007/s40808-016-0243-2>.
- Jana, A., Jat, M. K., Saxena, A., & Choudhary, M. (2022). Prediction of land use land cover changes of a river basin using the CA-Markov model. *Geocarto International*, 37(26), 14127-14147.
- Kuradusenge, M., Kumaran, S., & Zennaro, M. (2020). Rainfall-induced landslide prediction using machine learning models: The case of Ngororero District, Rwanda. *International journal of environmental research and public health*, 17(11), 4147. <https://doi.org/10.3390/ijerph17114147>.
- Kumar, R., Nandy, S., Agarwal, R., & Kushwaha, S. P. S. (2014). Forest cover dynamics analysis and prediction modeling using logistic regression model. *Ecological indicators*, 45, 444-455. <https://doi.org/10.1016/j.ecolind.2014.05.003>.
- Kumar, J., Talwar, P., & Krishna, A. P. (2015). Forest canopy density and ASTER DEM based study for dense forest investigation using remote sensing and GIS techniques around East Singhbhum in Jharkhand, India. *International Journal of Advanced Remote Sensing and GIS*, 4(1), 1026-1032. <https://doi.org/10.23953/cloud.ijarsg.96>.
- Lakes, T., Müller, D., & Krüger, C. (2009). Cropland change in southern Romania: a comparison of logistic regressions and artificial neural networks. *Landscape Ecology*, 24, 1195-1206. <https://doi.org/10.1007/s10980-009-9404-2>.

- Liang, J., Zhou, M., Verbyla, D. L., Zhang, L., Springsteen, A. L., & Malone, T. (2011). Mapping forest dynamics under climate change: A matrix model. *Forest ecology and management*, 262(12), 2250-2262. <https://doi.org/10.1016/j.foreco.2011.08.017>.
- Lin, S. C., Ke, M. C., & Lo, C. M. (2017). Evolution of landslide hotspots in Taiwan. *Landslides*, 14, 1491-1501. <https://doi.org/10.1007/s10346-017-0816-9>.
- Linhui, Li., Weipeng, J., & Huihui, W. (2020). Extracting the forest type from remote sensing images by random forest. *IEEE Sensors Journal*, 21(16), 17447-17454. <https://doi.org/10.1109/JSEN.2020.3045501>.
- Loozen, Y., Rebel, K. T., De jong, S. M., Lu, M., Ollinger, S.V., Wassen, M. J., & Karssenber, D.(2020). Mapping canopy nitrogen in European forests using remote sensing and environmental variables with the random forests method. *Remote Sensing of Environment*, 247,111933. <https://doi.org/10.1016/j.rse.2020.111933>.
- Mansour, S., Al-Belushi, M., & Al-Awadhi, T. (2020). Monitoring land use and land cover changes in the mountainous cities of Oman using GIS and CA-Markov modelling techniques. *Land use policy*, 91, 104414. <https://doi.org/10.1016/j.landusepol.2019.104414>.
- Marlier ME, Resetar SA, Lachman BE, Anania K, & Adams K. (2022). Remote sensing for natural disaster recovery: Lessons learned from Hurricanes Irma and Maria in Puerto Rico. *Environmental Science & Policy* ,132,153-159. <https://doi.org/10.1016/j.envsci.2022.02.023>.
- Martinello, C., Cappadonia, C., & Rotigliano, E. (2023). Investigating the effects of cell size in statistical landslide susceptibility modelling for different landslide typologies: a test in central–northern sicily. *Applied Sciences*, 13(2), 1145. <https://doi.org/10.3390/app13021145>.
- McGarigal, K., S. A. Cushman, and E. Ene, 2002, FRAGSTATS: spatial pattern analysis program for categorical maps, Computer software program produced by the authors at the University of Massachusetts, Amherst. Available at the following web site: <http://www.umass.edu/landeco/research/fragstats/fragstats.html>.
- Mi, J., Liu, R., Zhang, S., Hou, H., Yang, Y., Chen, F., & Zhang, L. (2019). Vegetation

- patterns on a landslide after five years of natural restoration in the Loess Plateau mining area in China. *Ecological Engineering*, 136, 46-54.
<https://doi.org/10.1016/j.ecoleng.2019.05.022>.
- Milanović, S., Marković, N., Pamučar, D., Gigović, L., Kostić, P., & Milanović, S. D. (2020). Forest fire probability mapping in eastern Serbia: Logistic regression versus random forest method. *Forests*, 12(1), 5. <https://doi.org/10.3390/f12010005>.
- Mondal, M. S., Sharma, N., Kappas, M., & Garg, P. K. (2020). CA Markov modeling of land use land cover change predictions and effect of numerical iterations, image interval (time steps) on prediction results. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 713-720.
- Moos, C., Bebi, P., Graf, F., Mattli, J., Rickli, C., & Schwarz, M. (2016). How does forest structure affect root reinforcement and susceptibility to shallow landslides?. *Earth Surface Processes and Landforms*, 41(7), 951-960. <https://doi.org/10.1002/esp.3887>.
- Morgan, J. L., Gergel, S. E., & Coops, N. C. (2010). Aerial photography: A Rapidly Evolving tool for ecological management. *BioScience*, 60(1), 7-59.
<https://doi.org/10.1525/bio.2010.60.1.9>.
- Mwabumba, M., Yadav, B. K., Rwiza, M. J., Larbi, I., & Twisa, S. (2022). Analysis of land use and land-cover pattern to monitor dynamics of Ngorongoro world heritage site (Tanzania) using hybrid cellular automata-Markov model. *Current Research in Environmental Sustainability*, 4, 100126.
<https://doi.org/10.1016/j.crsust.2022.100126>.
- Nafouanti, M. B., Li, J., Mustapha, N. A., Uwamungu, P., & Al-Alimi, D. (2021). Prediction on the fluoride contamination in groundwater at the Datong Basin, Northern China: comparison of random forest, logistic regression and artificial neural network. *Applied geochemistry*, 132, 105054.
<https://doi.org/10.1016/j.apgeochem.2021.105054>.
- Naidoo, L., Cho, M. A., Mathieu, R., & Asner, G. (2012). Classification of savanna tree species, in the Greater Kruger National Park region, by integrating hyperspectral and LiDAR data in a Random Forest data mining environment. *ISPRS journal of Photogrammetry and Remote Sensing*, 69, 167-179.

<https://doi.org/10.1016/j.isprsjprs.2012.03.005>.

Narmada K, Gogoi D, & Dhanusree B. G. (2021). Landscape metrics to analyze the forest fragmentation of Chitter Hills in Eastern Ghats, Tamil Nadu. *Journal of Civil Engineering and Environmental Sciences* ,7(1), 001-007.

<https://dx.doi.org/10.17352/jcees>.

Nhu, V. H., Shirzadi, A., Shahabi, H., Singh, S. K., Al-Ansari, N., Clague, J. J., ... & Ahmad, B. B. (2020a). Shallow landslide susceptibility mapping: A comparison between logistic model tree, logistic regression, naïve bayes tree, artificial neural network, and support vector machine algorithms. *International journal of environmental research and public health*, 17(8), 2749.

<https://doi.org/10.3390/ijerph17082749>.

Nhu, V. H., Mohammadi, A., Shahabi, H., Ahmad, B. B., Al-Ansari, N., Shirzadi, A., ... & Nguyen, H. (2020b). Landslide detection and susceptibility modeling on cameron highlands (Malaysia): A comparison between random forest, logistic regression and logistic model tree algorithms. *Forests*, 11(8), 830.

<https://doi.org/10.3390/f11080830>.

Ojoyi MM, Odindi J, Mutanga O, & Abdel-Rahman EM. (2016). Analysing fragmentation in vulnerable biodiversity hotspots in Tanzania from 1975 to 2012 using remote sensing and fragstats. *Nature Conservation* ,16, 19-37.

<https://doi.org/10.3897/natureconservation.16.9312>.

Ou, Q., Lei, X., & Shen, C. (2019). Individual tree diameter growth models of larch–spruce–fir mixed forests based on machine learning algorithms. *Forests*, 10(2), 187.

<https://doi.org/10.3390/f10020187>.

Ozkan, U. Y., Demirel, T., Ozdemir, I., Saglam, S., & Mert, A. (2022). Predicting forest stand attributes using the integration of airborne laser scanning and Worldview-3 data in a mixed forest in Turkey. *Advances in Space Research*, 69(2), 1146-1158.

<https://doi.org/10.1016/j.asr.2021.10.049>.

Paine, D. P., & Kiser, J. D. (2012). Aerial photography and image interpretation. John Wiley and Sons.

- Pasha, S. V., Reddy, C. S., Jha, C. S., Rao, P. P., & Dadhwal, V. K. (2016). Assessment of land cover change hotspots in Gulf of Kachchh, India using multi-temporal remote sensing data and GIS. *Journal of the Indian Society of Remote Sensing*, 44, 905-913. <https://doi.org/10.1007/s12524-016-0562-9>.
- Pauchard, A., & Alaback, P. B. (2004). Influence of elevation, land use, and landscape context on patterns of alien plant invasions along roadsides in protected areas of South-Central Chile. *Conservation biology*, 18(1), 238-248. <https://doi.org/10.1111/j.1523-1739.2004.00300.x>.
- Pendry, C. A., & Proctor, J. (1997). Altitudinal zonation of rain forest on Bukit Belalong, Brunei: soils, forest structure and floristics. *Journal of Tropical Ecology*, 13(2), 221-241. <https://doi.org/10.1017/S0266467400010427>.
- Peng, S. L., Hou, Y. P., & Chen, B. M. (2010). Establishment of Markov successional model and its application for forest restoration reference in Southern China. *Ecological Modelling*, 221(9), 1317-1324. <https://doi.org/10.1016/j.ecolmodel.2010.01.016>.
- Petropoulos, G. P., Kalaitzidis, C., & Vadrevu, K. P. (2012). Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery. *Computers & Geosciences*, 41, 99-107. <https://doi.org/10.1016/j.cageo.2011.08.019>.
- Phakdimek, S., Komori, D., & Chaithong, T. (2023). Combination of optical images and SAR images for detecting landslide scars, using a classification and regression tree. *International Journal of Remote Sensing*, 44(11), 3572-3606. <https://doi.org/10.1080/01431161.2023.2224096>.
- Pham, Q. B., Ali, S. A., Parvin, F., Van On, V., Sidek, L. M., Đurin, B., ... & Minh, N. N. (2024). Multi-spectral remote sensing and GIS-based analysis for decadal land use land cover changes and future prediction using random forest tree and artificial neural network. *Advances in space research*, 74(1), 17-47. <https://doi.org/10.1016/j.asr.2024.03.027>.
- Ping, J. L., Green, C. J., Zartman, R. E., & Bronson, K. F. (2004). Exploring spatial dependence of cotton yield using global and local autocorrelation statistics. *Field*

- Crops Research*, 89(2-3), 219-236. <https://doi.org/10.1016/j.fcr.2004.02.009>.
- Pueyo, Y., & Beguería, S. (2007). Modelling the rate of secondary succession after farmland abandonment in a Mediterranean mountain area. *Landscape and Urban Planning*, 83(4), 245-254. <https://doi.org/10.1016/j.landurbplan.2007.04.008>.
- Saha, S., Saha, M., Mukherjee, K., Arabameri, A., Ngo, P. T. T., & Paul, G. C. (2020). Predicting the deforestation probability using the binary logistic regression, random forest, ensemble rotational forest, REPTree: A case study at the Gumani River Basin, India. *Science of the Total Environment*, 730, 139197. <https://doi.org/10.1016/j.scitotenv.2020.139197>.
- Sahani, N., & Ghosh, T. (2021). GIS-based spatial prediction of recreational trail susceptibility in protected area of Sikkim Himalaya using logistic regression, decision tree and random forest model. *Ecological Informatics*, 64, 101352. <https://doi.org/10.1016/j.ecoinf.2021.101352>.
- Sevgen E, Kocaman S, Nefeslioglu HA, & Gokceoglu C. (2019). A novel performance assessment approach using photogrammetric techniques for landslide susceptibility mapping with logistic regression, ANN and random forest. *Sensors*, 19(18), 3940. <https://doi.org/10.3390/s19183940>.
- Shanley, C. S., Eacker, D. R., Reynolds, C. P., Bennetsen, B. M., & Gilbert, S. L. (2021). Using LiDAR and Random Forest to improve deer habitat models in a managed forest landscape. *Forest Ecology and Management*, 499, 119580. <https://doi.org/10.1016/j.foreco.2021.119580>.
- Silva Pedro, M., Rammer, W., & Seidl, R. (2017). Disentangling the effects of compositional and structural diversity on forest productivity. *Journal of Vegetation Science*, 28(3), 649-658. <https://doi.org/10.1111/jvs.12505>.
- Solaimani, K., & Darvishi, S. (2024). Comparative analysis of land use changes modeling based-on new hybrid models and CA-Markov in the Urmia lake basin. *Advances in Space Research*, 74(8), 3749-3764. <https://doi.org/10.1016/j.asr.2024.06.078>.
- Song, X. P., Huang, W., Hansen, M. C., & Potapov, P. (2021). An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping. *Science of Remote*

- Sensing*, 3, 100018. <https://doi.org/10.1016/j.srs.2021.100018>.
- Stefanov, W. L., Ramsey, M. S., & Christensen, P. R. (2001). Monitoring urban land cover change: An expert system approach to land cover classification of semiarid to arid urban centers. *Remote sensing of Environment*, 77(2), 173-185.
- [https://doi.org/10.1016/S0034-4257\(01\)00204-8](https://doi.org/10.1016/S0034-4257(01)00204-8).
- Sun L, Wang M, & Fan X. 2020. Spatial pattern and driving factors of biomass carbon density for natural and planted coniferous forests in mountainous terrain, eastern Loess Plateau of China. *Forest ecosystems*, 7(1), 1-13.
- <https://doi.org/10.1186/s40663-020-0218-7>.
- Talukdar, S., Eibek, K. U., Akhter, S., Ziaul, S. K., Islam, A. R. M. T., & Mallick, J. (2021). Modeling fragmentation probability of land-use and land-cover using the bagging, random forest and random subspace in the Teesta River Basin, Bangladesh. *Ecological indicators*, 126, 107612. <https://doi.org/10.1016/j.ecolind.2021.107612>.
- Tuhkanen, S. (1980). Climatic Parameters and Indices in Plant Geography. Sweden: Almqvist and Wiksell International.
- Turton, S. M., & Siegenthaler, D. T. (2004). Immediate impacts of a severe tropical cyclone on the microclimate of a rain-forest canopy in north-east Australia. *Journal of Tropical Ecology*, 20(5), 583-586. <https://doi.org/10.1017/S0266467404001622>.
- Tzotsos, A., & Argialas, D. (2008). Support vector machine classification for object-based image analysis. *Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications*, 663-677. https://doi.org/10.1007/978-3-540-77058-9_36.
- Wang, X., Blanchet, F. G., & Koper, N. (2014). Measuring habitat fragmentation: An evaluation of landscape pattern metrics. *Methods in ecology and evolution*, 5(7), 634-646. <https://doi.org/10.1111/2041-210X.12198>.
- Wang, Y., Wu, X., Chen, Z., Ren, F., Feng, L., & Du, Q. (2019). Optimizing the predictive ability of machine learning methods for landslide susceptibility mapping using SMOTE for Lishui City in Zhejiang Province, China. *International journal of environmental research and public health*, 16(3), 368.

<https://doi.org/10.3390/ijerph16030368>.

- Wang, Z., Zhang, X., Chhin, S., Zhang, J., & Duan, A. (2021). Disentangling the effects of stand and climatic variables on forest productivity of Chinese fir plantations in subtropical China using a random forest algorithm. *Agricultural and Forest Meteorology*, 304, 108412. <https://doi.org/10.1016/j.agrformet.2021.108412>.
- Wu, Y., & Zhang, X. (2019). Object-based tree species classification using airborne hyperspectral images and LiDAR data. *Forests*, 11(1), 32. <https://doi.org/10.3390/f11010032>.
- Yang, S., Li, D., Sun, Y., & She, X. (2024). Effect of landslide spatial representation and raster resolution on the landslide susceptibility assessment. *Environmental Earth Sciences*, 83(4), 132. <https://doi.org/10.1007/s12665-024-11442-3>.
- Yeh, C. K., & Liaw, S. C. (2021). Applying spatial autocorrelation and logistic regression to analyze land cover change trajectory in a forested watershed. *TAO: Terrestrial, Atmospheric and Oceanic Sciences*, 32(1), 3. <https://doi.org/10.3319/TAO.2020.12.03.01>.
- Zhang, J., Hull, V., Huang, J., Yang, W., Zhou, S., Xu, W., ... & Liu, J. (2014). Natural recovery and restoration in giant panda habitat after the Wenchuan earthquake. *Forest Ecology and Management*, 319, 1-9. <https://doi.org/10.1016/j.foreco.2014.01.029>.
- Zhang, Z., Hu, B., Jiang, W., & Qiu, H. (2021). Identification and scenario prediction of degree of wetland damage in Guangxi based on the CA-Markov model. *Ecological Indicators*, 127, 107764. <https://doi.org/10.1016/j.ecolind.2021.107764>.
- Zhang, Z., Hörmann, G., Huang, J., & Fohrer, N. (2023). A random forest-based CA-Markov model to examine the dynamics of land use/cover change aided with remote sensing and GIS. *Remote Sensing*, 15(8), 2128. <https://doi.org/10.3390/rs15082128>.
- Zhao, Y., Wang, R., Jiang, Y., Liu, H., & Wei, Z. (2019). GIS-based logistic regression for rainfall-induced landslide susceptibility mapping under different grid sizes in Yueqing, Southeastern China. *Engineering geology*, 259, 105147. <https://doi.org/10.1016/j.enggeo.2019.105147>.

Zhou, L., Dang, X., Sun, Q., & Wang, S. (2020). Multi-scenario simulation of urban land change in Shanghai by random forest and CA-Markov model. *Sustainable Cities and Society*, 55, 102045. <https://doi.org/10.1016/j.scs.2020.102045>.

Zhou X, Wu W, Lin Z, Zhang G, Chen R, Song Y, & Liu W. (2021). Zonation of landslide susceptibility in Ruijin, Jiangxi, China. *International journal of environmental research and public health*, 18(11), 5906. <https://doi.org/10.3390/ijerph18115906>.

