



應用 AI 學習技術 於 坡地崩塌預測 分析 — 以高雄市小林村為例

林彥廷／財團法人國家實驗研究院國家地震工程研究中心 專案助理研究員

顏筱穎、張乃軒、林宏明／國立臺灣大學土木工程學系 碩士生

韓仁毓、楊國鑫、陳俊杉／國立臺灣大學土木工程學系 教授

鄭宏達／台灣世曦工程顧問股份有限公司地理空間資訊部 協理

徐若堯／台灣世曦工程顧問股份有限公司地理空間資訊部 工程師

在極端氣候影響條件下，現今人們對於災害的應變觀念已大幅轉變，過去為當災害發生時思考如何全力救災以降低生命財產的損失，而現今已經轉化成災害的預防為各界最努力的目標之一，故本研發針對地表變位高潛勢的區域進行預測，使人們得以提早預防因地表變位而造成生命財產的損害，也可以對於工程選址上有所幫助。研究使用新式遙測技術 InSAR 地表變位資料，加上近年來最流行的人工智慧學習技術，利用時空因子與發生地表變位進行相關性分析，再將顯著性時空因子作為模型訓練資料，透過 AI 模型預測高潛勢斜坡單元變位區域。本研究以高雄市小林村里為測試案例，經由混淆矩陣比對預測成果和歷史發生崩塌斜坡單元，成果以優於 80% 正確率證實其預測分析技術之可行性。未來將能提供工程在不同階段上之應用，像是工程地點的選址、施工時之周遭坡地的防護治理、以及針對公共設施周遭持續進行邊坡面變位分析，以提供防災等計畫研擬之策略。

關鍵字：時空因子、機器學習、斜坡單元、崩塌預測、小林村

前言

台灣島造山帶地殼抬升速率與年平均降雨量幾近世界之冠，且台灣位處環太平洋地震帶上，不僅地震常發生，更因為近年的氣候變遷關係造成極端氣候加劇，地震及豪雨造成台灣山區崩塌、土石流、河道淤積等土石災害頻繁，加上地表的侵蝕速率高，造成河流地形與集水區變化劇烈，使得水災、山崩、土石流、地滑等大規模災害發生的頻率與對於人們生命財產安全的衝擊也日益增加。其中，坡地災害常因強烈的颱風豪雨或地下水位變化，產生不同規模的災情，如 2009 年莫拉克颱風，小林村里發生大規模崩塌，其崩塌土方量高達 2,500 萬立方公尺，造成 491 人罹難與

失蹤，因而不可輕忽坡地災害對於公共設施及人們生命財產安全帶來威脅。

複合自然災害普遍存在地狹人稠台灣這片土地，加上台灣國土 70% 以上皆屬山坡地，各項土地利用易與山坡地區域交集。因山坡地常位於地質敏感破碎之區域，當面臨強降雨或地震，便容易發生坡地崩塌等災害；坡地災害的發生成因除了地形演育的自然過程外，人為因素也會導致坡地災害的發生，且造成的災害規模與嚴重性更不容忽視。以坡地災害為例，發生邊坡崩塌的成因可以分成二大類，分別為環境條件（潛因）及促發因子（誘因），潛因為山坡地本身的自然條件，像是地形、地質材料、地質構造以及地下水等條件；而誘因

是指誘發地形災害發生的驅動因子，如降雨、地震、河流衝擊及人為等因素。其中，引發坡地災害的人為因素包含山坡地的過度開發、森林砍伐、集水區內濫墾及超限利用、工程選址或道路選線不當及邊坡排水系統與護坡工程維護不佳。上述各項因子由不同政府機關管理，像是雨量站資料為氣象局管理、全台灣數值高程模型為內政部地政司，而台灣地質資料管理單位為經濟部地質調查所等，故各種資料應予以整合以利進行時空上的綜合分析。環境影響因子利用統計分析的方法建立邊坡崩塌與影響因子的相互關係式，如簡李濱（1992）採用不安定指數法（Instability Index Method）^[1]，以及 Shou *et al.*（2018）採用邏輯回歸法（Logistic Regression Method）^[2]，最終獲取邊坡的崩塌潛勢值或是崩塌機率，以評估邊坡崩塌發生的潛勢。現行利用統計分析模式多適用於預算大範圍的邊坡崩塌潛勢，但其預測的準確度或是誤判率仍有改善的空間。

在現今豐富空間資訊觀測技術不斷演進及發展，從過去使用的單點量測方式，如經緯儀、水準儀等，隨著 GNSS 系統的發展，使人們可以針對特定區域進行長時間的地表監測，然而受限於測站的布設數量及位置故無法獲取大範圍的地表變化資訊。近年來廣域的遙測技術不斷進步，各式遙測資訊種類增加、取得的成本降低、遙測影像解析度與相關技術提升等，遙測技術於土木水利相關工程領域之應用層面也因此更加擴增。像是合成孔徑雷達干涉技術（InSAR）、光達（LiDAR）等遙測技術，可以大範圍的獲取地表的空間資訊。其中，InSAR 技術是利用衛星軌道重複觀測方式，獲取不同時間同一地區 SAR 影像，由相位值（Phase）來獲取出地表的三維資訊，精度可達公釐等級，現今廣泛應用於地表變形測量及地形

測繪等地球環境監測相關領域之中。InSAR 易受如：植被分布、土地利用情形、雨量、地質條件等變化影響所觀測變位資料數值，因此需透過其他上述邊坡崩塌影響因子之相關性分析，以釐清 InSAR 觀測值與邊坡崩塌影響因子的關係，並了解發生邊坡坡面變位的成因。

近年來加上人工智慧技術興起，針對大量的原始資料做訓練，建立網路模型架構，往後即可透過輸入的原始資料，進行未來事件的預測及推估。在土木工程領域中亦可結合人工智慧技術與空間觀測數據，以輔助人們進行決策及判斷，像是在構造物的安全性評估、河流水位預測提供橋梁預警性封橋等應用。故若能夠結合人工智慧技術與現代化遙測觀測成果，預期對於地表不穩定行為之分析與預測將會有顯著性的助益。本研究將應用 InSAR 資料與邊坡相關的各項環境條件與促發因子進行時空上相關性的研究與探討，並配合人工智慧之技術預測，以建立邊坡不穩定與各相關影響因子之間的相關性，預期能優化目前邊坡崩塌潛勢模式，提升其預測的準確度，提供後續工程設計與防災應變上之評估與應用。

研究方法

本研究基於斜坡單元為分析基礎，結合時空因子、InSAR 變位觀測及過去公告崩塌範圍，針對因子與地表變位進行相關性分析，找出顯著性的時空因子後，作為人工智慧模型之訓練樣本，整體研究方法與步驟流程如圖 1 所示。詳細研究方法共分成四大部分：(1) 依斜坡單元分割，(2) 環境時空因子指標分析，(3) 相關性分析 (4) 常見機器學習方法，以各時空觀測因子與地表變位之關係建構變位預測分析。最後，利用混淆矩陣驗證變位預測分析成果。

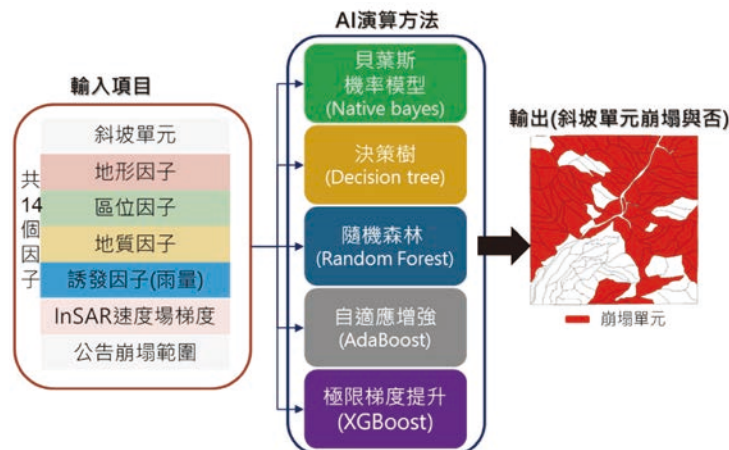


圖 1 應用 AI 學習技術於坡地崩塌預測分析研究方法流程圖

斜坡單元分割

為保留邊坡原本之地形特性，故使用斜坡單元作為分析單元基礎詮釋時空環境因子之數值。斜坡單元分割方法係參考 Xie *et al.* (2004) 所提出集水區重疊法^[3]，如圖 2 所示。以 ArcGIS 軟體中 Hydrology 模組進行數值高程模型 (Digital Elevation Model, DEM) 中集水區辨識，經反轉數值高程模型使水系線轉為稜線，分割為左右兩個斜坡單元。其中，在 Hydrology 模組進行集水區之辨識時，並以 Flow Accumulation 等於 500 作為劃分河道之門檻值，產出之斜坡單元面積皆小於 30 公頃。分割斜坡單元透過套疊陰影圖、坡向圖、坡度圖、水系圖及衛星正射影像等輔助，判釋各單元間是否重疊或密合。




圖 2 集水區重疊法分割斜坡單元示意圖，修改參考^[3]。

環境時空因子指標化分析

環境時空因子共可分為地形因子、區位因子、地質因子、誘發因子等三大類別，其中地形因子能夠表現地表高程幾何變化及覆蓋分布，包括高程、坡度、坡向、地形粗糙度、剖面曲率、植生指標；區位因子顯示斜坡單元受到變動因素如道路、水系、斷層之距離影響性；地質因子反映區域岩層之強度、褶皺性及斜坡順向性；誘發因子為雨量。於下進行各因子及 InSAR 變位速度場梯度指標分析。

(1) 地形因子

● 坡度

依據水平面上的移動距離中所產生的高度變化以三角函數的正切 (tangent) 函數表示空間梯度 (gradient) 變化為坡度，以每九宮格網格為單位，依

均分雙向計算方式獲得九宮格網中心之坡度值，再以每斜坡單元中最顯著 (大) 坡度值作為表示 (圖 3)。

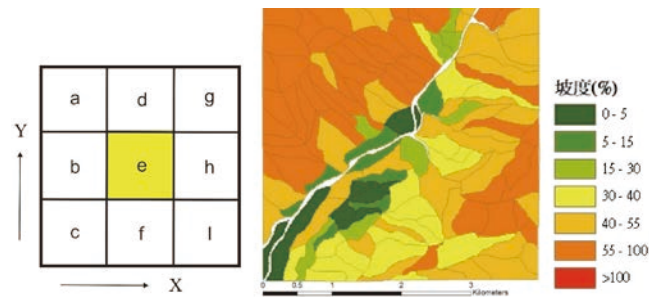


圖 3 以九宮格格網中心計算小林村斜坡單元之坡度指標

● 坡向

以地形高程為基礎，每九宮格網格為單位，計算九宮格網中心之主要坡度方向，主要坡度方向即是高程數值變化最大程度的方向，視為地表坡度方向。計算主要方向與正北方向之夾角 θ ，以正北方向為 0 度，隨順時針方向增加角度至 360 度，再以每斜坡單元中最顯著 (大) 坡向值作為表示 (圖 4)。

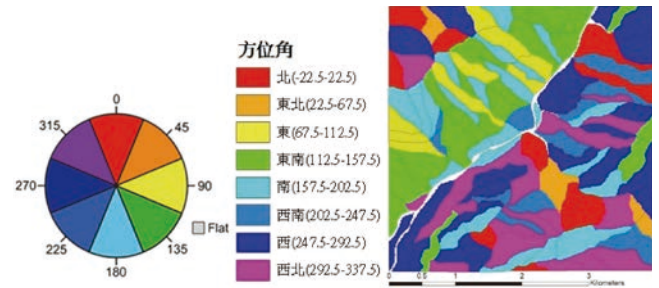


圖 4 以八方位分布角度計算小林村斜坡單元坡向圖

● 地形粗糙度

地形粗糙度代表邊坡上高度變化的程度，高度變化越大，代表其地形起伏變化越大，當邊坡材料不穩定時，其所受的重力作用越大，且抵抗力越小，邊坡崩塌的可能性越高。透過各斜坡單元的高程標準差 σ 來描述斜坡單元中高程變化程度 (圖 5)。

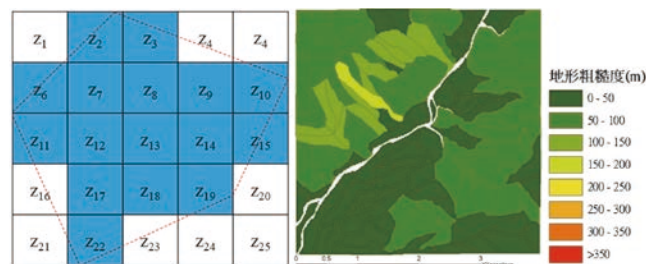


圖 5 以斜坡單元中格網高程標準差計算小林村斜坡單元地形粗糙度圖

● 剖面曲率

剖面曲率代表地面坡度沿最大斜率方向的高程變化程度，即坡的急緩程度。本研究利用 ArcMap 軟體的空間分析模組，在數值高程模型中以每九宮格網格為計算單位，求得中心剖面曲率，再以每個斜坡單元為基礎，計算出各單元之代表曲率，其中曲率負值代表凸坡，正值代表凹坡（圖 6）。

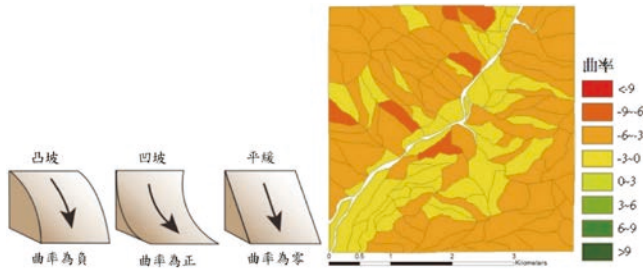


圖 6 斜坡曲率計算小林村斜坡單元剖面曲率圖

● 植生指標

因植物具吸收藍光、紅光及強列反射近紅外光的特性，因此能使用可見光（紅、綠、藍光）與近紅外光之比值或差值監測植生變化，常態化差異植生指標（Normalized Difference Vegetation Index, NDVI）能夠進行地表植生覆蓋分析，NDVI 之值介於 -1 至 +1 之間，因綠色植物生長愈旺盛，其吸收之紅光愈多，紅外光反射亦強因此 NDVI 值愈大 [4]。植生與非植生區域之判定，可藉由 NDVI 門檻加以設定區分，許多相關研究成果顯示門檻值並非單一特定值，隨著分析範圍、植生種類、衛星影像取樣角度、拍攝時間及大氣環境狀況等原因影響，根據亞洲地區植生進行 NDVI 門檻測試，建議其值可選用 0.15 進行篩選植生區域判定 [5]。本研究進而定義植生指標為斜坡單元內所佔植生地面積與斜坡單元面積之比值，如圖 7 所示。




圖 7 利用 NDVI 指標計算小林村斜坡單元植生指標圖

(2) 區位因子

區位因子指該山崩潛因具邊坡的距離遠近，會對該邊坡造成影響之因子，本研究選定水系距、道路距、斷層距三個區位因子進行分析，依三個區位因子分別計算至斜坡單元形心的距離（圖 8）。

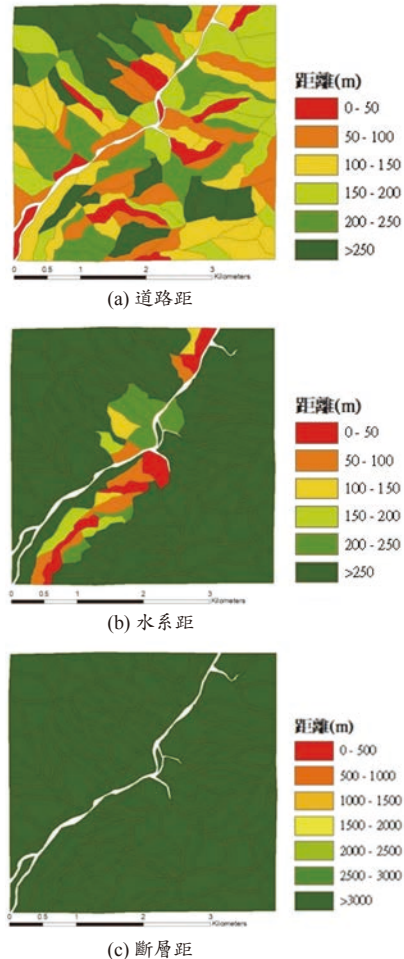


圖 8 計算至斜坡單元形心距離之小林村斜坡單元區位因子圖

(3) 地質因子

地質因子為描述不同地質材料特性，根據其岩性、沉積年代、沉積狀況、破碎程度等，導致不同邊坡特性而影響崩塌之可能性，本研究依岩體強度、褶皺度、順向坡指標進行分析。

● 岩體強度

岩體強度越弱，代表其抵抗外力擾動的能力越低，越容易發生崩塌。利用岩石結構的破碎程度及與岩石的單壓強度大小，可將岩體強度由大至小分為 I ~ VII 類，共七級 [6]。本研究利用二萬五分之一環境地質圖的岩體強度調查成果與斜坡單元進行套疊，繪製出各個斜坡單元的岩體強度（圖 9）。

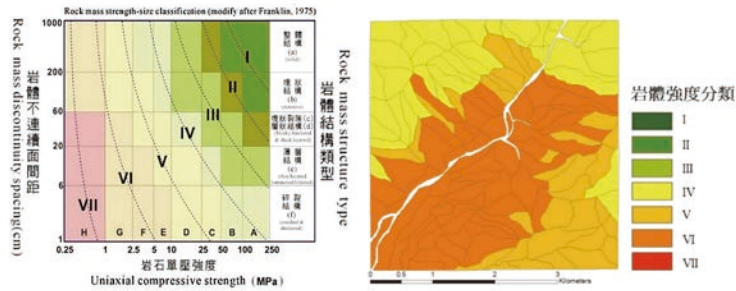


圖 9 利用中央地質調查所岩體強度分類計算小林村斜坡單元岩體強度指標圖

● 褶皺度

褶皺是岩石受力作用後，呈現波浪狀彎曲的狀態，褶皺所經的地方代表其受複雜的應力作用，進而造成該處邊坡岩層較為破碎，影響其抵抗外力擾動的能力容易發生崩塌，本研究將斜坡單元中所經過的褶皺數目定義為褶皺度（圖 10）。




圖 10 以岩層類別計算小林村斜坡單元中褶皺度圖

● 順向坡指標

當地層的傾向與邊坡的坡向一致時，邊坡可能會沿著層面滑動，造成邊坡崩壞的可能性提高，稱為順向坡。本研究利用五萬分之一地質圖，繪製出區域位態圖，並參考水土保持技術規範地層傾向與坡面坡向一致，且交角在 20° 以內定義為順向坡，並輔以中央地質調查所所公告之順向坡圖資，確認本研究產製出之順向坡皆涵蓋公告資料。本研究進而定義順向坡指標為斜坡單元內所佔的順向坡面積與邊坡單元面積之比值，如圖 11 所示。




圖 11 以岩層類別及坡向計算小林村斜坡單元中順向坡百分比指標

(4) InSAR 變位速度場梯度指標

InSAR 利用兩期以上合成孔徑雷達觀測，根據回波相位差推估地表變位，為改善 InSAR 年變位於尺度及系統性誤差，並考量 InSAR 變位資訊具備正負數值分布，採用平均值正規化（mean normalization）將資料投放至 -1 至 1 區間。基於正規化處理後 InSAR 能夠反應地表相對性變位之特性，以年為分析單位計算獲得 InSAR 年變位速度。為了凸顯 InSAR 變位所在分布，透過 3 × 3 大小單窗於規則網格中執行梯度計算獲得 InSAR 年變位速度場梯度，如圖 12 所示。

(5) 年雨量內插模型

台灣雨量觀測來源為雨量站設站蒐集，山區雨量站分布密度遠小於都市區，相關雨量內插分析研究多以離雨量測站距離或高程等因素，單獨進行統計回歸建構內插模型；然而，台灣顯著降雨事件如




圖 12 小林村斜坡單元之 InSAR 變位速度場梯度指標圖

颱風及梅雨，雲系受地形抬昇，易於迎風背風兩側產生不均降雨情況，本研究除了考量測站距離及高程因素，並加入地勢坡向之影響因素，完成建構雨量觀測內插模型。

時空因子與地表變位相關性分析

針對時空因子與地表變位進行相關性分析，考量時空因子數值分布情形差異，未必能滿足母數統計（常態分佈）之嚴格假設，因此本研究採用無需分佈假設之統計方法，Spearman 相關分析僅需將資料依大小排列，以順序變數線性關係描述，其定義如式 1。相關係數 γ_s 分布於 1 和 -1，其正、負數值表示正、負相關性，當 γ_s 趨近於 0 代表兩者間不具有相關性。

$$\gamma_s = 1 - \frac{6 \sum \Delta_i^2}{n(n^2 - 1)} \quad (1)$$

式中， γ_s 為 Spearman 相關係數， Δ_i 為兩等級之差異量、 n 為樣本數。

為了確立各時空因子與地表變位是否具備顯著相關性，使用 SPSS 統計軟體輸入時空因子 Spearman 相關係數，執行運算轉換等級尺度，再歸納各因子與地表變位之顯著相關性，其相關性是否顯著檢定如式 2。

$$t = 1 - \frac{\gamma_s - \rho_0}{\sqrt{\frac{1 - \gamma_s^2}{n - 2}}} \quad (2)$$

式中， ρ_0 為 0 時是虛無假設（Null hypothesis）表示「沒有相關」，由 P-value 檢核是否顯著，以 99% 之信賴區間為嚴格顯著相關條件下，當顯著水準 t 大於 0.99 代表拒絕虛無假設，表示因子與崩塌存在相關性。

機器學習變位預測分析與品質評估

透過相關性分析偵測顯著影響崩塌主要因子後，環境條件及誘發因子進而作為人工智慧機器資料學習訓練建立預測模型，應用於邊坡崩塌與變位潛勢預測。常見 AI 機器學習演算應用於分類預測包括貝葉斯機率（Naive bayes）、決策樹（Decision tree）、隨機森林（Random forest）、自適應增強法（AdaBoost）和極限梯度提升法（XGBoost），於下分別進行說明。

(1) 貝葉斯機率（Naive bayes）

決定崩塌分類為崩塌及非崩塌共兩種，依已知兩種類別斜坡單元中時空因子作為訓練樣本，並計算後續未知類別斜坡單元屬於各類別之機率密度函數，其中機率密度函數依貝葉斯法分類法^[7]。各斜坡單元經時空因子出現機率加總最大值者，預測為所屬崩塌或未崩塌類別。由於貝葉斯機率模型於每個輸入變量，假設相互獨立並符合高斯分佈，將有助於釐清大量複雜分類問題。

(2) 決策樹（Decision tree）

決策樹應用假設各時空因子間彼此獨立，依因子特徵定義決策樹每條路徑所屬類別機率分布，採用如同雙叉樹枝二分法方式，在節點以加總機率方式進行數值計算，再依最大加總值作為預測所屬類別^[8]。決策樹能避免如正規化節省資料預處理時間，同時以二分法快速判別，對於連續性資料或離散型資料皆能提出有效分類處理。

(3) 隨機森林（Random forest）

隨機森林為多個決策樹集合，並加入隨機挑選訓練資料（Bootstrap Aggregation, Bagging）方式，將原始觀測資料取出樣本 n 數量並訓練為 n 種分類器，依照每顆決策樹中樣本差異考慮了資料隨機不確性，在權重一致條件下分類器計以加總多數決定最佳分類樹作為預測分類成果^[9]。

(4) 自適應增強法（Adaptive Boosting, AdaBoost）

Boost 是針對已建立分類模型中錯誤資料提高權重，增加對錯誤資訊加強練習，並訓練衍生新的分類器降低先期錯誤機會的一種演算法。AdaBoost 演算疊代過程對於噪聲（noise）或異常數據極為敏感，容易聚焦於難以分類的特徵因子^[10]。

(5) 極限梯度提升法（eXtreme Gradient Boosting, XGBoost）

XGBoost 結合了決策樹和 Boost 兩種演算概念，透過特徵因子分類生成樹，每當完成一顆樹亦是擬合前一次預測殘差所建置學習新函數，透過計算預測與真實觀測之誤差，融合決策樹的複雜度，涵蓋了節點數量和節點機率數值^[11]。

實驗分析

研究測區擇選高雄市小林村實驗區域進行本研究方法驗證，該測區於 2009 年莫拉克風災後持續大量出

現崩塌事件，測區中台 29 線公路呈現南北縱向，測區面積總共為 15.8 平方公里，共涵蓋 129 個斜坡單元。各項因子觀測時間由小時至年等尺度不一問題，為了達到共同時間尺度，採用「年」作為單位基礎分析時間。實驗第一部份，以測區斜坡單元為分析基礎，透過時空因子和 InSAR 變位速度梯度指標，與各單元崩塌情況進行相關性分析，釐清偵測實驗區域崩塌之顯著影響環境因子；第二部分，利用先期（2007 年至 2009 年）時空因子、InSAR 變位速度梯度、雨量誘發因子等指標數值與崩塌與否進行學習演算，並以後期（2010 年）時空條件預估是否具崩塌情況，最後與經濟部中央地質調查所公告崩塌進行混淆矩陣比對分析，驗證本研究方法實際應用於地表變位預測分析之可行性。

時空因子顯著性分析

時空因子之數值分布範圍不一，透過數值標準化將因子尺度統一於 1 至 -1 間分布，再與各斜坡單元是否存在崩塌情況進行 Spearman 相關性分析。分析相關係數及顯著性如表 1 所示，相關係數值介於 -0.47 至 0.01 之間，顯著性數值分布由 0.1 至 1，以 99% 信賴度為檢定門檻設置要求，依顯著性排序通過檢定門檻時空因子包括岩性強度、年平均降雨量、坡度、坡向、地形粗糙度、順向坡指標、高程等共七項因子。

時空地形因子中岩性強度最具相關性 ($\gamma_s = -0.47$)、次之為年平均降雨量 ($\gamma_s = -0.37$)、再者為坡度 ($\gamma_s = 0.27$)、坡向指標 ($\gamma_s = -0.25$)、地形粗糙度指標 ($\gamma_s = 0.31$)、順向坡指標 ($\gamma_s = 0.24$)，最後為高程 ($\gamma_s = 0.22$)。

預測分析及成果驗證

以小林村測區共 129 個斜坡單元中 13 個環境時空因子、1 個誘發因子指標與崩塌情況作為分析基礎，其中 2007 ~ 2009 年共 3 年之作為機器學習演算學習對象，再由 2010 年時空因子及誘發因子條件，預測

表 1 時空因子相關係數及顯著性數值表

時空因子	相關係數 γ_s (依絕對值排序)	顯著性	通過檢定 (99%信賴區間)
岩性強度	-0.47	1	是
平均降雨量	-0.37	1	是
坡度	0.27	1	是
坡向	-0.25	1	是
地形粗糙度	0.31	1	是
順向坡指標	0.24	0.99	是
高程	0.22	0.99	是
曲率	-0.12	0.81	否
InSAR 變位指標	0.08	0.62	否
褶皺度	0.07	0.57	否
植生指標	-0.06	0.49	否
河道距	-0.04	0.37	否
道路距	0.01	0.1	否
斷層距	0.01	0.1	否

各斜坡單元是否發生崩塌，比對 2010 年中央地質調查所公告崩塌位址所在斜坡單元計算預測正確率。透過常見五種機器學習預測崩塌成果如表 2 所示，其中以貝葉斯預測正確率最高為 82.95%；次之為隨機森林 79.84%；再者為自適應增強法為 77.52%、極限梯度法為 75.97%；最後決策樹為 62.02%。

以最佳學習演算（貝葉斯）預測成果，透過混淆矩陣交叉驗證並細部評估預測分類成果。由圖 13 顯示 129 個斜坡單元中，正確預測崩塌之斜坡單元以紅色標示（共 74 個）；正確預測未崩塌之斜坡單元以綠色標示

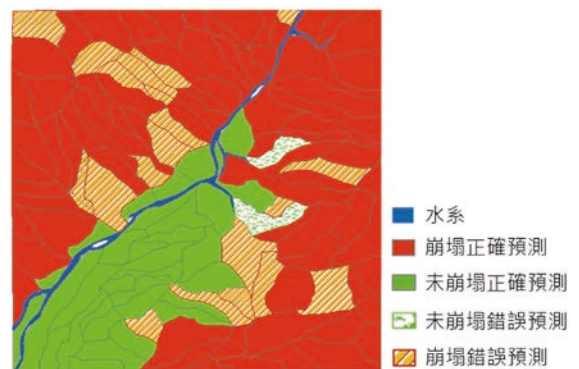


圖 13 與實際崩塌比較之正確及錯誤預測斜坡單元分布圖

表 2 機器學習法預測小林村崩塌斜坡單元之正確百分比表

方法	貝葉斯 (Naive Bayes)	決策樹 (Decision Tree)	隨機森林 (Random Forest)	自適應增強 (AdaBoost)	極限梯度 (XGBoost)
正確率 (%)	82.95	62.02	79.84	77.52	75.97

(共 33 個)；將實際崩塌斜坡單元錯誤預測為未崩塌者標示綠色斜紋 (共 2 個)；將實際未崩塌斜坡單元錯誤預測為崩塌者以橘紅色斜紋表示 (共 20 個)。表 3 以混淆矩陣比較顯示，崩塌預測正確率為 97.4%、非崩塌預測正確率為 62.3%，整體預測平均正確率為 82.9%。

表 3 以混淆矩陣驗證崩塌預測斜坡單元之正確百分比統計表

實際 \ 預測	崩塌	未崩塌	正確百分比 (%)
崩塌	74 	2 	97.4
未崩塌	20 	33 	62.3
整體準確率 (%)			82.9

結果與討論

本研究為了解斜坡單元隨著時序及空間演進造成地表崩塌之環境因子，透過時空環境觀測資料蒐集建構時空因子指標，選用了 InSAR 變位資料、雨量資料、地貌因子、區位因子與地質因子共 14 種時空因子指標，以斜坡單元為基礎，依序將時空因子與崩塌進行相關性分析，依相關性分析之結果可知，崩塌是由各種因子相互影響下而發生。由相關性分析發現，小林村測區 7 個顯著因子包括坡度、坡向、高程、地形粗糙度、岩體強度、順向坡指標及平均降雨量等。應用五種常見機器學習演算預測崩塌分類，其預測可達到六至八成分類正確率，其中貝葉斯法預測正確率為最高 82.95%，該種演算法能有效針對高維度多特徵進行相互獨立訓練，訓練中考慮因子特徵彼此影響性，最後凸顯重要特徵因子。實驗區域 129 個斜坡單元中，於 2010 年實際崩塌數量與非崩塌數分別為 74 個和 33 個 (近似 2:1 數量比)，透過混淆矩陣交叉比對預測崩塌成果，能獲得預測崩塌或非崩塌之正確性，其中實際崩塌誤判為未崩塌僅只有 2 處斜坡單元，顯示崩塌區域預測正確率高達 97.4%，能夠有效掌握崩塌區域之預測分析。後續研究除了可將現行年觀測之環境時空因子時間尺度精化為月或日，提升演算資料豐富性；亦可考量增加力學計算如流體沖刷力、滑動等相關因子，進一步提升預測準確度。針對易崩塌斜坡單元制定雨量誘發指標級距，依此分級發布即時警戒，可成為往後應用於邊坡養護及災害防救一項具前瞻性整合地表監測及預測方法。現行研究亦顯示誘發因子

(雨量) 為相關重要因子之一，除了需改善台灣山區雨量站分布密度較為稀疏問題外，亦須考量格網化降雨資訊提供即時性輔助崩塌預測，如雨量雷達回波觀測網格資訊將能可能成為加值分析與應用重要課題，配合本研究現行人工智慧預測技術開發，預期能優化邊坡崩塌潛勢模式，提升其預測的準確度，提供防災應變評估及預警模式建置。

參考文獻

1. 簡李濱 (1992)，應用地理資訊系統建立坡地安定評估之計量方法，國立中興大學土木工程研究所碩士論文：台中市。
2. Shou, K.J., Wu, C.C., and Lin, J.F. "Predictive analysis of landslide susceptibility under climate change conditions - a study on the Ai-Liao watershed in southern Taiwan," *Journal of GeoEngineering*, Vol. 13, No 1, pp. 13-27 (2018).
3. Xie, M., Esaki, T., and Zhou, G. "GIS-Based Probabilistic Mapping of Landslide Hazard Using a Three-Dimensional Deterministic Model," *Natural Hazards*, Vol. 33, No. 2, pp. 265-282 (2004).
4. Townshend, J.R., Goff, T.E., and Tucker, C.J. "Multitemporal dimensionality of images of normalized difference vegetation index at continental scales," *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 6, pp. 888-895 (1985).
5. Wen, C.G., Tateishi, R., and Harahsheh, H. "Asian 30-Second Land Cover Dataset," *The Arab World Geographer*, Vol. 3, No. 2, pp. 132-140 (2000).
6. Franklin, J.A. "Safety and economy in tunneling," *In Proceedings of the 10th Canadian rock mechanics symposium*, Queens University, Kingston, Ontario, Vol. 1, pp. 27-53, (1975).
7. Rish, I. "An empirical study of the naive Bayes classifier," *In IJCAI 2001 workshop on empirical methods in artificial intelligence*, Vol. 3, No. 22, pp. 41-46 (2001).
8. Safavian, S.R. and Landgrebe, D. "A survey of decision tree classifier methodology," *IEEE transactions on systems, man, and cybernetics*, Vol. 21, No. 3, pp. 660-674 (1991).
9. Ho, T.K. "Random decision forests," *In Proceedings of 3rd international conference on document analysis and recognition IEEE*, Vol. 1, pp. 278-282 (1995).
10. Freund, Y. and Schapire, R.E. "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of computer and system sciences*, Vol. 55, No. 1, pp. 119-139 (1997).
11. Friedman, J.H. "Greedy function approximation: a gradient boosting machine," *Annals of statistics*, pp. 1189-1232 (2001).

歡迎加入學會



www.ciche.org.tw

下載入會申請書



中國土木水利工程學會
CIVIL AND HYDRAULIC ENGINEERING

e-mail: service@ciche.org.tw

電話：(02) 2392-6325

傳真：(02) 2396-4260