

การเพิ่มสมรรถนะการทำนายเสถียรภาพและระยะวิบัติของลาดดินโดยใช้การปรับแต่งไฮเปอร์พารามิเตอร์และคุณสมบัติพหุนาม

Enhanced prediction of slope stability and failure distance using hyperparameter tuning and polynomial features

พัฒนศักดิ์ ชัยพรรณา¹, พรเกษม จงประดิษฐ์², จิรวัดน์ ศุภโกศล¹, ปิโยรส ทะเสนหอด¹, รัชชศิริ สุขรักษ์³ และ นัฐวุฒิ เหมะรุฉิน^{1*}

Pattanasak Chaipanna¹, Pornkasem Jongpradist², Jirawat Supakosol¹, Piyoros Tasenhod¹, Raksiri Sukkarak³ and Nattawut Hemathulin^{1*}

Received: 5 July 2024 ; Revised: 15 October 2024 ; Accepted: 21 January 2025

บทคัดย่อ

การศึกษานี้นำเสนอการวิเคราะห์เสถียรภาพของลาดดินโดยใช้แบบจำลองการเรียนรู้ของเครื่อง (ML) ต่างๆ โดยเน้นที่ความสำคัญของการปรับแต่งไฮเปอร์พารามิเตอร์และคุณสมบัติ การทำนายค่าความปลอดภัย (FS) ระยะทางการพังทลายของลาดดินเมื่อเทียบกับความสูงของลาดดิน และระดับความปลอดภัยของลาดดิน พารามิเตอร์นำเข้า ได้แก่ หน่วยแรงยึดเหนี่ยว (C), มุมเสียดทานภายใน (Phi), มุมลาดชัน (Slope) และความสูงของลาดดิน (H) ประสิทธิภาพของแต่ละโมเดลถูกประเมินโดยใช้ค่าความผิดพลาดเฉลี่ยสัมบูรณ์เป็นเปอร์เซ็นต์ (MAPE), ค่าความผิดพลาดกำลังสองเฉลี่ย (MSE), และค่าความผันแปรของตัวแปรตอบสนอง (R^2) สำหรับการทำนายแบบถดถอย ในขณะที่งานการจำแนกประเภทถูกประเมินโดยใช้ค่าความแม่นยำ (Accuracy), ความถูกต้อง (Precision), การระลึก (Recall), คะแนน F1 (F1-score) และพื้นที่ใต้เส้นโค้ง (AUC) การวิเคราะห์แสดงให้เห็นถึงประสิทธิภาพของแบบจำลอง ML ที่แตกต่างกัน แบบจำลองที่มีประสิทธิภาพทั้งในการทำนายถดถอยและจำแนกคือป่าสุ่ม การใช้คุณสมบัติแบบพหุนามเพิ่มประสิทธิภาพให้วิธีเชิงเส้นได้อย่างมีนัยสำคัญ ในขณะที่การปรับแต่งไฮเปอร์พารามิเตอร์เพิ่มประสิทธิภาพแบบจำลองซัพพอร์ตเวกเตอร์และโครงข่ายประสาทเทียมที่มีหลายชั้นได้เป็นอย่างดี

คำสำคัญ: การวิเคราะห์เสถียรภาพลาดดิน, การเรียนรู้ของเครื่อง, ระยะวิบัติของลาดดิน

Abstract

This study presents an extensive analysis of slope stability using various machine learning (ML) models, focusing on hyperparameter tuning and feature importance and model validation for predicting factor safety (FS), slope failure distance relative to the height of the slope, and the safety level of the slope. The input parameters include cohesion (C), internal friction angle (Phi), slope angle (Slope), and height of the slope (H). The performance of each model was assessed using Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), and R-squared (R^2) for regression tasks, while classification tasks were evaluated using accuracy, precision, recall, F1-score, and Area Under the Curve (AUC). The analysis demonstrates the efficacy of different ML models. The model that performed well in

¹ สาขาวิศวกรรมโยธา, คณะอุตสาหกรรมและเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

² ภาควิชาวิศวกรรมโยธา, คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

³ ภาควิชาครุศาสตร์โยธา, คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

¹ Division of Civil Engineering, Faculty of Industrial and Technology, Rajamangala University of Technology Isan

² Department of Civil Engineering, Faculty of Engineering, King Mongkut's University of Technology Thonburi

³ Department of Teacher Training in Civil Engineering, Faculty of Technical Education, King Mongkut's University of Technology North Bangkok

* Corresponding author, e-mail: nattawut.he@rmuti.ac.th

both regression and classification is the Random Forest. The use of polynomial features significantly improved the performance of linear methods, while hyperparameter tuning greatly enhanced the performance of Support Vector and MLP models.

Keywords: Slope stability analysis, machine learning, slope failure distance

บทนำ

การขาดเสถียรภาพของลาดดินเป็นปัญหาสำคัญสำหรับวิศวกรธรณีเทคนิค การวิบัติลาดดินสามารถก่อให้เกิดความเสียหายต่อสิ่งแวดลอมและโครงสร้างที่มนุษย์สร้างขึ้น รวมถึงสูญเสียชีวิตและบาดเจ็บ จากรายงานขององค์การอนามัยโลก ตั้งแต่ปี 1998-2017 ดินถล่มส่งผลกระทบต่อประชากร 4.8 พันล้านคน และทำให้เสียชีวิต 18,000 คน (World Health Organization, 2023) นอกจากนี้การวิบัติลาดดินยังส่งผลให้บ้านเรือน อาคาร และโครงสร้างพื้นฐานต่างๆ เสียหาย การสัญจรและสาธารณูปโภคได้รับผลกระทบ นำไปสู่ค่าใช้จ่ายในการซ่อมแซมและสร้างใหม่ รวมถึงค่าใช้จ่ายทางกฎหมายและประกัน ทำให้เกิดการสูญเสียทางเศรษฐกิจ ธนาคารโลก ประเมินว่าดินถล่มก่อให้เกิดความสูญเสียทางเศรษฐกิจประมาณ 6 พันล้านดอลลาร์ต่อปี (World Bank, 2020) การวิบัติลาดดินยังทำให้ดินและหินเคลื่อนที่ เปลี่ยนแปลงสภาพภูมิประเทศ ดินไม่เหมาะสมสำหรับการเพาะปลูก สูญเสียพืชพรรณ และเปลี่ยนทิศทางการไหลของน้ำหรือทำให้เกิดน้ำท่วม การวิเคราะห์เสถียรภาพและระยะวิบัติลาดดินมีความสำคัญในการประเมินความปลอดภัย ช่วยระบุความเสี่ยงจากดินถล่มและลดความเสียหายต่อชีวิตและโครงสร้าง วิศวกรใช้การวิเคราะห์เสถียรภาพลาดดินในการออกแบบและวางแผนโครงสร้างพื้นฐานเพื่อลดความเสี่ยง ซึ่งอาจรวมถึงการเสริมเสถียรภาพ การปรับปรุงระบบระบายน้ำ หรือการใช้มาตรการทางวิศวกรรมอื่นๆ การวิเคราะห์ระยะวิบัติลาดดินยังช่วยทำความเข้าใจขอบเขตและขนาดของการทรุดตัวของดิน ซึ่งมีความสำคัญในการประเมินความเสี่ยงและออกแบบมาตรการบรรเทาความเสี่ยง

วิธีการแบบดั้งเดิมในการวิเคราะห์เสถียรภาพลาดดินมักใช้หลักการสมดุลจำกัด (Limit Equilibrium Method, LEM) เช่น วิธีของ Bishop (1955), Fellenius (1927), Morgenstern and Price (1965) และ Spencer (1967) วิธีเหล่านี้ถูกใช้งานมาเป็นเวลานานและมีบทบาทสำคัญในวิศวกรรมธรณีเทคนิค การประเมินเสถียรภาพของลาดดินจะพิจารณาค่าอัตราส่วนความปลอดภัย (Factor of Safety, FS) โดยเปรียบเทียบกำลังรับแรงเฉือนกับแรงขับ อีกวิธีที่ได้รับความนิยมในปัจจุบันคือ การวิเคราะห์เชิงตัวเลข (Numerical Analysis) ซึ่งพัฒนาขึ้น

ตามความก้าวหน้าของคอมพิวเตอร์ วิธีนี้สามารถวิเคราะห์ลาดดินที่มีรูปทรงซับซ้อนและคุณสมบัติของดินที่แตกต่างกันได้ และสามารถวิเคราะห์การให้แรงแบบไดนามิกได้ วิธีเชิงตัวเลขแบ่งเป็นสองแบบ ได้แก่ การเคลื่อนที่แบบต่อเนื่อง เช่น วิธีการไฟไนต์ดิฟเฟอเรนซ์ (Finite Difference Method, FDM), วิธีการไฟไนต์เอลิเมนต์ (Finite Element Method, FEM), และวิธีเบาดาร์เอลิเมนต์ (Boundary Element Method, BEM) และการเคลื่อนที่แบบไม่ต่อเนื่อง เช่น การวิเคราะห์เคลื่อนที่ไม่ต่อเนื่อง (Discontinuous Deformation Analysis, DDA) และการวิเคราะห์แบบเม็ดดิน (Bonded Particle Model, BPM) ข้อจำกัดของวิธีเชิงตัวเลขคือต้องใช้คอมพิวเตอร์ประสิทธิภาพสูงและซอฟต์แวร์เฉพาะทาง ซึ่งมีค่าใช้จ่ายสูง และต้องใช้ผู้เชี่ยวชาญในการสร้างแบบจำลองและควบคุมการวิเคราะห์ ในช่วงไม่กี่ปีที่ผ่านมา การใช้ปัญญาประดิษฐ์ (Artificial Intelligence, AI) โดยเฉพาะเทคนิคการเรียนรู้ของเครื่อง (Machine Learning, ML) ได้ถูกนำมาใช้ในการวิเคราะห์ที่ซับซ้อนไม่ว่าจะเป็นด้านการแพทย์ (ณัฐวุฒิ แถมเงิน และคณะ, 2023) ด้านการพยากรณ์ปริมาณการส่งออก (สุภาวิณี ชันคำ และ สิโรรัตน์ จันทงาม, 2023) เนื่องจากสามารถทำนายเสถียรภาพลาดดินได้อย่างมีประสิทธิภาพ (Azarafa *et al.*, 2021; Nikoobakht *et al.*, 2022; Pham *et al.*, 2022) และแม่นยำกว่าวิธีที่ผ่านมา (Wang *et al.*, 2020; Huang *et al.*, 2021) หลายอัลกอริทึม ML เช่น k-NN, OPFK-NN, และ LSTM (Huang *et al.*, 2023) ได้แสดงให้เห็นถึงความแม่นยำที่เพิ่มขึ้นและความสามารถในการค้นพบรูปแบบที่ซ่อนอยู่ในข้อมูลเสถียรภาพลาดดิน แบบจำลองเหล่านี้ไม่เพียงเพิ่มความแม่นยำในการทำนาย แต่ยังให้ข้อมูลที่มีคุณค่าเกี่ยวกับความไม่แน่นอนที่เกี่ยวข้องกับการทำนาย ซึ่งช่วยในการตัดสินใจในการประเมินเสถียรภาพลาดดิน

วัตถุประสงค์ของงานวิจัย

1. เพื่อทำนายเสถียรภาพและระยะวิบัติของลาดดินโดยใช้เทคนิคการเรียนรู้ของเครื่อง
2. เพื่อเปรียบเทียบการเพิ่มประสิทธิภาพของเทคนิคการเรียนรู้ของเครื่องด้วยการปรับแต่งไฮเปอร์พารามิเตอร์และการใช้คุณสมบัติพหุนาม

ขั้นตอนการวิจัย

1. การสร้างข้อมูล

สำหรับขั้นตอนการทำนายโดยใช้แบบจำลองข้อมูลที่น่าเข้ากระบวนการวิเคราะห์ที่ได้จากการวิเคราะห์โดยวิธี LEM ที่กำหนดให้เป็นดินชั้นเดียวมีคุณสมบัติเหมือนกันทุกตำแหน่งและทุกทิศทาง หน่วยน้ำหนักดินคงที่เท่า 18 kN/m^3 โดยไม่พิจารณาถึงความชื้นและน้ำในดิน ตัวแปรต้นที่ใช้ในการศึกษาประกอบด้วยหน่วยแรงยึดเหนี่ยว (Cohesion, C) มุมเสียดทานภายใน (Internal friction angle, Phi) มุมลาดชันของลาดดิน (Slope) และความสูงของลาดดิน (H) (Figure 1) ตัวแปรเป้าหมายที่ศึกษาได้แก่ อัตราส่วนความปลอดภัยที่คำนวณจากโปรแกรมคอมพิวเตอร์ตามสมมติฐานของ Janbu อัตราส่วนระหว่างระยะวิกฤตต่อความสูงของลาดดิน (L/H) และสุดท้ายคือระดับความเสถียรของลาดดินแบ่งเป็น 3 ระดับได้แก่ ระดับไม่ปลอดภัย (Fail) ระดับวิกฤต (Critical) ระดับปลอดภัย (Safe) แบ่งตามค่าอัตราส่วนความปลอดภัย น้อยกว่า 1.0, 1.0-1.5 และมากกว่า 1.5 ตามลำดับ (Harabinová & Panulinová, 2020; WSDOT, 2013) ทั้งหมด 627 ชุดข้อมูล

2. การประมวลผลข้อมูลเบื้องต้น (Exploratory Data Analysis, EDA)

ขั้นตอนการประมวลผลข้อมูลเบื้องต้นคือขั้นตอนสำคัญในเทคนิคการเรียนรู้ของเครื่อง เป็นขั้นตอนตรวจสอบข้อมูลที่สูญหาย ตรวจสอบการซ้ำกันของข้อมูล ช่วยให้เข้าใจถึงชุดข้อมูลไม่ว่าจะเป็น ขนาด โครงสร้าง และชนิดของตัวแปร ช่วยตรวจสอบความผิดปกติของข้อมูล ช่วยในการจัดกลุ่มและแสดงความสัมพันธ์ของข้อมูลแต่ละกลุ่ม

การตรวจจับข้อมูลผิดปกติ Outlier Detection Techniques

ในการศึกษาครั้งนี้เลือกใช้วิธี Interquartile Range (IQR) ในการวิเคราะห์ข้อมูลที่มีค่าผิดปกติ ใช้ในการตรวจจับข้อมูลที่ไม่เป็น Normal Distribution หรือมีการกระจายตัวไม่เป็นแบบปกติ โดยที่ IQR คือความแตกต่างระหว่างควอไทล์ที่สามและควอไทล์ที่หนึ่ง ($Q3 - Q1$) โดยที่ $Q1$ คือควอไทล์ที่ 25% และ $Q3$ คือ ควอไทล์ที่ 75% ของข้อมูล จากนั้นคำนวณเส้นขอบบน (Upper Bound) และเส้นขอบล่าง (Lower Bound) โดยใช้สูตร $Upper Bound = Q3 + 1.5 * IQR$ และ $Lower Bound = Q1 - 1.5 * IQR$ ข้อมูลที่มีค่า FS ต่ำกว่า Lower Bound หรือสูงกว่า Upper Bound ถือว่าเป็นค่าผิดปกติ (Outliers) และถูกตัดออก

ข้อมูลที่ถูกจัดการเบื้องต้นเหลือจำนวน 588 ชุดข้อมูลแสดงใน Table 1 ที่แสดงถึงจำนวนข้อมูล (Count) ค่าเฉลี่ย (Mean) ค่าเบี่ยงเบนมาตรฐาน (Std) ค่าต่ำสุด (Min)

ค่าควอไทล์ที่ 25%, 50% และ 75% และค่าสูงสุดของตัวแปร (Max) จากตารางจะเห็นได้ว่าส่วนเบี่ยงเบนมาตรฐานทั้งของ C และ FS ต่างก็มากกว่าค่าเฉลี่ยแสดงว่ามีการกระจายข้อมูลที่กว้าง Figure 2 แสดงค่าสัมประสิทธิ์สหสัมพันธ์และแผนภาพการกระจายของข้อมูลแต่ละคู่ การกระจายตัวของข้อมูลสี่เหลี่ยม สีน้ำเงิน และสีแดง แสดงถึงความปลอดภัยของลาดดินในระดับ Fail, Critical และ Safe ตามลำดับ ส่วนด้านซ้ายล่างของภาพแสดงการกระจายตัวของข้อมูล มีเส้นสีแดง, น้ำเงิน, เขียวและดำแสดงแนวโน้มสำหรับจำแนกระดับความปลอดภัยลาดดินระดับต่างและแนวโน้ม ตามลำดับ

FS: มีค่าสหสัมพันธ์กับหน่วยแรงยึดเหนี่ยว (0.78) และมุมเสียดทานภายใน (0.13) ซึ่งแสดงให้เห็นว่าเมื่อหน่วยแรงยึดเหนี่ยวและมุมเสียดทานภายในเพิ่มขึ้น อัตราส่วนความปลอดภัยจะเพิ่มขึ้นเช่นกัน มีความสัมพันธ์ลบกับความลาดชัน (-0.049) และความสูง (-0.21) ซึ่งหมายความว่าเมื่อมุมลาดชันและความสูงเพิ่มขึ้นอัตราส่วนความปลอดภัยจะลดลงจากการกระจายความหนาแน่นของข้อมูลแถวแนวตั้งของ C จะพบว่า เส้นสีแดงค่าไม่เกิน 10 kN/m^2 แสดงว่าความปลอดภัยในระดับ Fail เกิดขึ้นในกรณีที่ C ต่ำมีค่าไม่ถึง

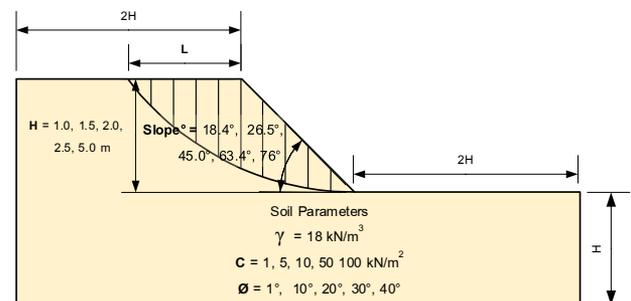


Figure 1 Soil slope model for stability analysis

Table 1 Summary statistics of all input and output variables

Item	C	Phi	Slope	H	FS	L/H
Count	588	588	588	588	588	588
Mean	29.47	20.35	45.42	2.440	5.807	2.919
Std	35.08	14.01	21.25	1.410	5.954	1.448
Min	1.000	1.000	18.43	1.000	0.083	0.500
25%	5.000	10.00	26.50	1.500	1.522	1.667
50%	10.00	20.00	45.00	2.000	3.290	2.776
75%	50.00	30.00	63.43	2.500	8.509	3.800
Max	100.0	40.00	75.96	5.000	23.69	7.000

10 kN/m^2 สอดคล้องกับการกระจายตัวของระดับความปลอดภัยเทียบกับตัวแปรต้น ใน Figure 3 พบว่า

จุดสีแดงอยู่ห่างจากตัวแปร C และ Phi หมายถึง ระดับความปลอดภัย Fail เกิดขึ้นใน C และ Phi ที่ต่ำ และ Slope และ H ที่สูง และระดับความปลอดภัย Safe อยู่ใกล้ C และ Phi สูง และ Slope และ H ที่ต่ำ ส่วนระดับ Critical อยู่ระหว่างข้อมูลทั้งสองก่อนมาทาง Slope

การกระจายความหนาแน่นของตัวแปรในรูปแบบไวโอลินแสดงใน Figure 4 ซึ่งแสดงตัวแปรที่เกี่ยวข้องการวิเคราะห์เสถียรภาพลาดดินด้วยค่าสูงสุด และค่าต่ำสุด นอกจากนี้ควอไทล์ที่หนึ่ง, ควอไทล์ที่สองและควอไทล์ที่สามแสดงเป็นเส้นขีดด้านล่างและตรงกลางและด้านบนตามลำดับ จากรูปจะเห็นได้ว่า ระดับความปลอดภัย Fail กระจุกตัวที่ค่า C และ Phi ต่ำ มีแนวโน้มที่จะเกิดในค่า Slope ที่สูงมากกว่า และมีโอกาสเกิดขึ้นทุกระดับความสูง (H) ส่วนความปลอดภัยระดับ Critical ปรากฏ C ระดับต่ำ ที่ Phi ก่อนข้างต่ำ ที่ Slope ก่อนข้างสูงแต่มีอัตราส่วนความหนาแน่นข้อมูลน้อยกว่าความปลอดภัยระดับ Fail

3. แบบจำลองการเรียนรู้ของเครื่อง (ML)

การศึกษาครั้งนี้วิเคราะห์ลาดดินโดยใช้ 14 แบบจำลองถดถอย ได้แก่ Linear Regression (LR), Ridge (Ridge), Lasso (Lasso), Elastic Net (EN), KNeighbor Regressor (KNR), Support Vector Regressor (SVR), Decision Tree Regressor (DTR), Extra Tree Regressor (XTR), Random Forest Regressor (RFR), Bagging Regressor (BR), Gradient Boosting Regressor (GBR), AdaBoost Regressor (ABR), CatBoost Regressor ((CBBR) และ MLP Regressor (MLPR) และแบบจำลองการจำแนกอีก 12 แบบจำลอง ได้แก่ Logistic Regression (LgR), KNeighbors Classifier (KNC), Support Vector Classification (SVC), Decision Tree Classifier (DTC), Extra Tree Classifier (XTC), Random Forest Classifier (RFC), Bagging Classifier (BC), Gradient Boosting Classifier (GBC), AdaBoost Classifier (ABC), CatBoost Classifier (CBC), Label Spreading (LS), และ MLP Classifier (MLPC).

4. การแบ่งชุดข้อมูล

การกำหนดจำนวนข้อมูลฝึกสอนในงานวิจัยนี้ใช้ไลบรารี Learning Curve Display ใน scikit-learn และ matplotlib โดยแบ่งตามกลุ่มโมเดลดังนี้: กลุ่ม Linear Models (LR, Ridge, Lasso, EN) 284 ชุด, KNR 470 ชุด, SVR 470 ชุด, กลุ่ม Trees Models (DTR, ETR) 397 ชุด, กลุ่ม Ensemble Models (RFR, BR, GBR, ABR, CBR) 383 ชุด และ MLPR 443 ชุด ค่าเฉลี่ยข้อมูลฝึกสอนในทุกกลุ่มเท่ากับ 408 ชุด และข้อมูลทดสอบ 150 ชุด ทั้งนี้ ไม่ได้นำการหาค่าเหมาะสมจากแบบจำลองการจำแนกมาใช้ เนื่องจากพบความผันผวนอย่างมีนัยสำคัญในแต่ละจำนวนข้อมูลการสอนของแต่ละแบบจำลอง

5. การปรับปรุงประสิทธิภาพการทำนายของแบบจำลอง ML

การสร้างข้อมูลคุณสมบัติพหุนาม (Polynomial Feature)

เทคนิคการสร้างตัวแปรต้นเป็นพหุนามเป็นการประมวลผลเบื้องต้น (Preprocessing) ใน ML โดยเฉพาะอย่างยิ่งในการถดถอยพหุนาม เพื่อสร้างคุณสมบัติพหุนามจากคุณสมบัติดั้งเดิมของชุดข้อมูล ในการวิจัยนี้ ได้กำหนดระดับของคุณสมบัติพหุนาม (Polynomial Feature Degree) ที่ระดับ 2 อย่างชัดเจน ซึ่งหมายความว่า ข้อมูลอินพุตถูกแปลงให้มีมิติสูงขึ้น โดยการเพิ่มชุดค่าผสมพหุนามของตัวแปรต้นในลักษณะดังนี้: $[1, x_1, x_2, x_1^2, x_1x_2, x_2^2]$

ขั้นตอนการประมวลผลเบื้องต้นนี้มีประโยชน์เมื่อความสัมพันธ์ระหว่างตัวแปรต้นและตัวแปรเป้าหมายไม่ได้เป็นเชิงเส้น ด้วยการเพิ่มคุณสมบัติพหุนาม แบบจำลอง ML สามารถจับความสัมพันธ์ที่ซับซ้อนมากขึ้นระหว่างตัวแปรต้นและตัวแปรเป้าหมาย ซึ่งอาจปรับปรุงประสิทธิภาพของแบบจำลองได้

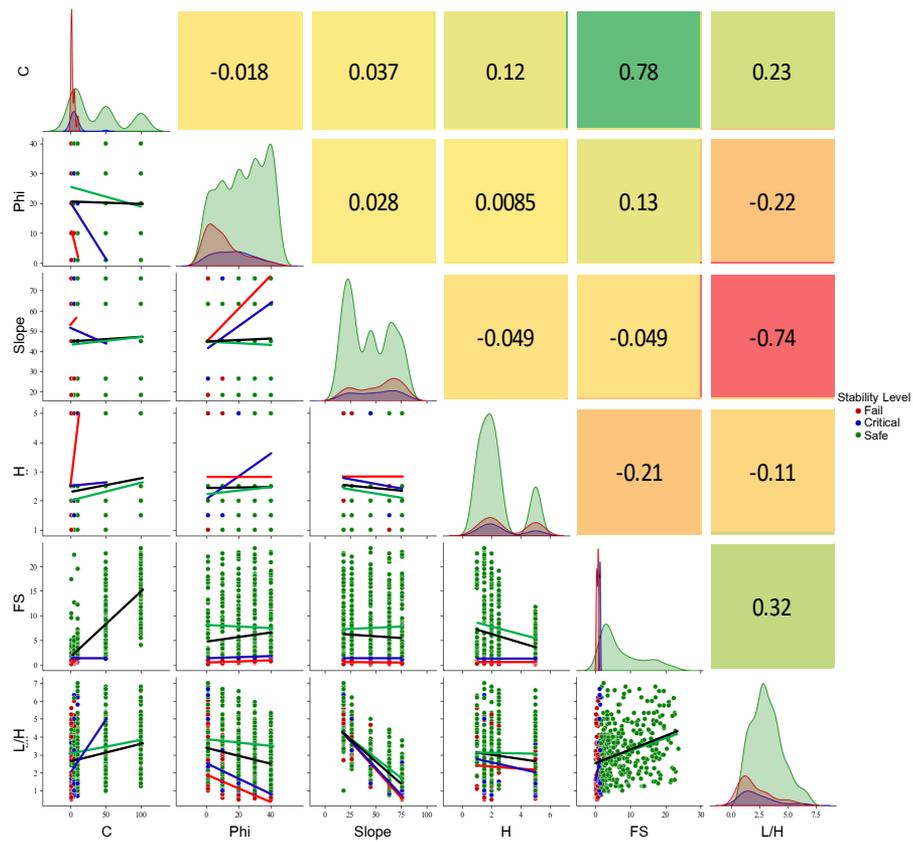


Figure 2 Distribution and correlation of influencing variables in the dataset

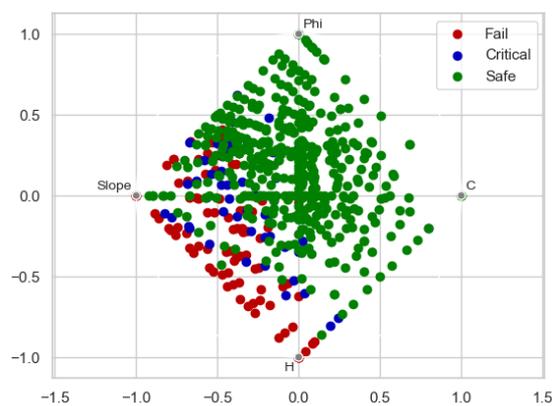


Figure 3 Distribution of radial data

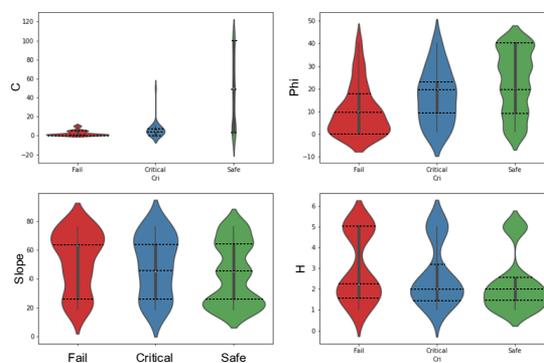


Figure 4 Violin plots showing the distribution of stability level

การปรับแต่งไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning)

การปรับแต่งไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) เป็นกระบวนการสำคัญในวิทยาการข้อมูลและการเรียนรู้ของเครื่อง ซึ่งมีจุดมุ่งหมายเพื่อหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดสำหรับแบบจำลองที่กำลังพัฒนา ไฮเปอร์พารามิเตอร์เป็นค่าที่ต้องกำหนดก่อนการฝึกอบรวมแบบจำลองและไม่สามารถเรียนรู้จากข้อมูลได้ เช่น ค่า learning rate สำหรับการเรียนรู้แบบปรับปรุงพารามิเตอร์, จำนวนชั้นในโครงข่ายประสาทเทียม (Neural Network), หรือค่าปรับ (Regularization) ในการจำแนกด้วย SVM

การปรับแต่งไฮเปอร์พารามิเตอร์ที่ดีที่สุดสามารถเพิ่มประสิทธิภาพของแบบจำลองได้อย่างมาก เนื่องจากช่วยให้แบบจำลองสามารถจับความสัมพันธ์ในข้อมูลได้ดีขึ้น วิธีการ

ปรับแต่งที่นิยมใช้มีหลายแบบ เช่น Grid Search ซึ่งเป็น การทดสอบค่าทุกค่าในกรอบที่กำหนด, Random Search ซึ่งเป็น การสุ่มค่าในกรอบที่กำหนด และ Bayesian Optimization ซึ่งใช้วิธีทางสถิติเพื่อทำนายค่าที่ดีที่สุด

นอกจากนี้ การตรวจสอบความถูกต้องข้ามกลุ่ม (Cross-Validation) มักถูกใช้ร่วมกับการปรับแต่งไฮเปอร์พารามิเตอร์เพื่อประเมินผลการปรับแต่งอย่างเป็นระบบ โดยแบ่งข้อมูลเป็นหลายกลุ่มและใช้กลุ่มเหล่านั้นในการทดสอบและฝึกอบรวมหลายรอบ เพื่อให้มั่นใจว่าแบบจำลองไม่ได้เหมาะสมกับข้อมูลเพียงชุดเดียว การปรับแต่งไฮเปอร์พารามิเตอร์เป็นขั้นตอนที่ใช้เวลาและทรัพยากร แต่เป็นสิ่งจำเป็นในการสร้างแบบจำลองที่มีความแม่นยำและประสิทธิภาพสูง ค่าปรับแต่งไฮเปอร์พารามิเตอร์แบบ Grid Search ที่ใช้ในการศึกษาครั้งนี้แสดงใน Table 2

Table 2 The hyperparameters utilized by implemented predictive models

Model	Hyperparameters [Default]	Values Used	Best for		
			Regression		Classification
			FS	L/H	Criterion
Ridge	alpha [1.0]	1e-06, 1e-05, 1e-04, 0.001, 0.01, 0.1, 1	1e-06	1e-06	
Lasso	alpha [1.0]	1e-06, 1e-05, 1e-04, 0.001, 0.01, 0.1, 1	1e-06	1e-06	
EN	Alpha [1.0]	1e-06, 1e-05, 1e-04, 0.001, 0.01, 0.1, 1	1e-06	1e-06	
	l1_ratio [0.5]	np.linspace (0, 1, 5)	0.0	0.0	
LgR	C [1.0]	0.5, 1, 5			0.5
	max_iter [100]	np.arange (50, 1000, 50)			50
KNR	metric ['minkowski']	'euclidean', 'manhattan', 'minkowski'	'euclidean'	'euclidean'	
	n_neighbors [5]	1, 2, 3, 5, 7	1	1	
	weights ['uniform']	'uniform', 'distance'	'uniform'	'uniform'	
KNC	n_neighbors [5]	range (1, 21)			6
	Weights ['uniform']	'uniform', 'distance'			'distance'
	P [2]	1, 2			1
SVR	Kernel ['rbf']	'linear', 'poly', 'rbf'	'linear'	'linear'	
	C [1.0]	0.001, 0.01, 0.1, 1, 10, 100	0.001	0.0001	
	Epsilon [0.1]	0.00001, 0.0001, 0.001, 0.01, 0.1	1e-06	1e-06	
SVC	C [1.0]	0.01, 0.1, 1, 10, 100			100
	gamma ['scale']	0.01, 0.1, 1, 10			0.01
DTR	criterion ['squared_error']	'squared_error', 'friedman_mse', 'absolute_error', 'poisson'	'squared_error'	'squared_error'	
	min_samples_split [2]	2, 4, 8	2	2	
DTC	max_depth ['None']	3, 5, 7, 9, 'None'			7
	min_samples_split [2]	2, 5, 10			5
	min_samples_leaf [1]	1, 3, 5			3
XTR	n_estimators [100]	np.arange(10,100,5)	50	50	
	min_samples_split [2]	2, 4, 8	2	2	

Table 2 The hyperparameters utilized by implemented predictive models (continue)

Model	Hyperparameters [Default]	Values Used	Best for		
			Regression		Classification
			FS	L/H	Criterion
XTC	max_depth ['None']	3, 5, 7, 9, 'None'			9
	min_samples_split [2]	2, 5, 10			10
RFR	n_estimators [100]	50, 100, 200, 300	50	50	
	min_samples_split [2]	2, 4, 8	2	2	
RFC	n_estimators [100]	100, 200, 300			300
	max_depth ['None']	3, 5, 7, 9, 'None'			9
	max_features ['sqrt']	'sqrt', 'log2'			'log2'
BR,	n_estimators [10]	5, 10, 50, 100, 500, 1000	5	5	50
BC	max_samples [1.0]	np.arange(0.4, 0.8, 0.05)	0.5	0.5	0.7
GBR,	n_estimators [100]	50, 100, 200, 300	50	50	50
GBC	learning_rate [0.1]	0.01, 0.05, 0.1, 0.5, 1	0.01	0.01	1
	min_samples_split [2]	2, 4, 8,	2	2	3
ABR,	n_estimators [50]	25, 50, 100, 200	25	25	100
ABC	learning_rate [1.0]	0.01, 0.05, 0.1, 0.5, 1.0	0.1	0.01	0.1
CBR	Depth [6]	2, 3, 5, 8	2	2	
CBC	learning_rate [0.3]	0.0001, 0.001, 0.01, 0.05, 0.1	0.0001	0.00001	0.05
	Iterations [1000]	500, 1000, 1500, 2000	500	500	500
LS	Kernel ['rbf']	'rbf', 'knn'			'knn'
	Alpha [0.2]	1.e-03, 1.e-02, 1.e-01, 1.e+00, 1.e+01, 1.e+02			0.001
	max_iter [30]	50, 100, 200			50
MLPR,	hidden_layer_sizes [100]	(300,200,100), (270,180,90), (240,160,80), (300,200,100)	(300,	(240,160,80)	
MLPC		(210, 140, 70)	200,100)		
	Activation ['relu']	'identity', 'logistic', 'tanh', 'relu'	'identity'	'identity'	'logistic'
	max_iter [200]	100, 200, 400, 600, 1000	100	100	1000

6. การประเมินประสิทธิภาพแบบจำลองการประเมินสิทธิภาพแบบจำลองถดถอย

เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error, MAPE) วัดประสิทธิภาพของแบบจำลองพยากรณ์โดยเทียบความคลาดเคลื่อนเฉลี่ยเป็นร้อยละของค่าที่ทำนายเทียบกับค่าจริง หาก $MAPE \leq 10\%$ ถือว่าแม่นยำสูง, 10%-20% แม่นยำใช้ได้, 20%-50% แม่นยำพอใช้ และ >50% ไม่แม่นยำ

ค่าความคลาดเคลื่อนเฉลี่ย (Mean Square Error, MSE) วัดค่าเฉลี่ยของความแตกต่างยกกำลังสองระหว่างค่าทำนายและค่าจริง MSE ที่ต่ำหมายถึงแบบจำลองมีความแม่นยำสูง

ค่าความผันแปรตอบสนอง (R^2) วัดความสอดคล้องระหว่างค่าทำนายและค่าจริง โดยค่า R-squared ใกล้ 1 หมายถึงแบบจำลองอธิบายความแปรปรวนของข้อมูลได้ดี

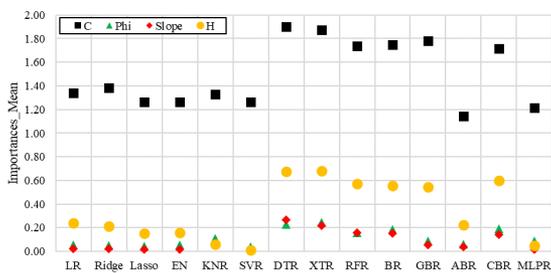
การประเมินประสิทธิภาพแบบจำลองแบบจำแนก

Confusion Matrix เป็นเครื่องมือประเมินประสิทธิภาพการจำแนกประเภท โดยมีองค์ประกอบ 4 ส่วนคือ TP, FP, TN, FN ใช้วัดค่า Accuracy, Precision, Recall และ F1-score กำหนดโดยค่าที่สูงกว่า 0.8 คือความสามารถของแบบจำลองในการจำแนกความปลอดภัยของลาดดินได้อย่างมีประสิทธิภาพ

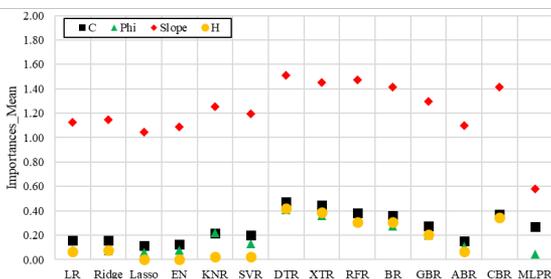
เส้นโค้ง ROC และพื้นที่ใต้กราฟ AUC ใช้ประเมินประสิทธิภาพแบบจำลองแบบจำแนก Hosmer Jr *et al.* (2013) เสนอได้จำแนกระดับประสิทธิภาพของ AUC คือ $AUC > 0.9$ ถือว่ายอดเยี่ยม (Excellent) อยู่ระหว่าง 0.8-0.9 ถือดีมาก (Very Good), อยู่ระหว่าง 0.7-0.8 ถือดี (Good), อยู่ระหว่าง 0.6-0.7 ถือว่าพอใช้ (Fair), อยู่ระหว่าง 0.5-0.6 ถือว่าแย่มาก (Poor), และต่ำกว่า 0.5 ถือว่าแย่มาก (Fail)

ผลการวิจัย

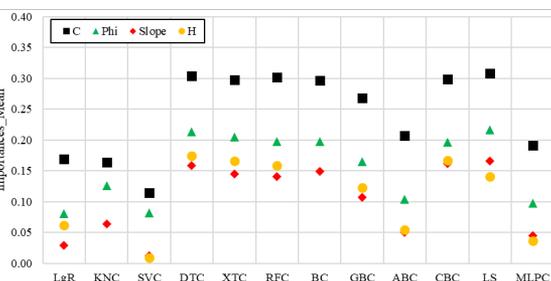
การวิเคราะห์ค่าความสำคัญของตัวแปรสำหรับการทำนายถดถอยอัตราส่วนความปลอดภัย (FS) แสดงให้เห็นว่าตัวแปรหน่วยแรงยึดเหนี่ยว (C) มีความสำคัญสูงสุด รองลงมาคือความสูงของลาดดิน (H) ดังแสดงใน Figure 5(a) สำหรับการทำนายถดถอยระยะวิบัติต่อความสูงของลาดดิน (L/H) ตัวแปรที่มีความสำคัญสูงสุดคือมุมลาดเอียง (Slope) รองลงมาคือหน่วยแรงยึดเหนี่ยว (C) โดยในบางแบบจำลองเช่น Lasso และ Elastic Net (EN) ความสูงของลาดดินมีค่าความสำคัญเป็นศูนย์หรือค่าติดลบในกรณีของแบบจำลอง MLP Regressor (MLPR) ดังแสดงใน Figure 5(b) และใน Figure 5(c) ในการทำนายแบบจำแนกระดับความปลอดภัยตัวแปรที่มีความสำคัญสูงสุดคือหน่วยแรงยึดเหนี่ยว (C) เช่นเดียวกับ Figure 5(a) ส่วนตัวแปรที่สำคัญรองลงมาคือมุมเสียดทานภายใน (Phi)



(a) factor of safety regression prediction



(b) failure distance regression prediction



(c) classified prediction of safety level

Figure 5 The importance of variables in each model

Table 3 และ 4 แสดงผลการวิเคราะห์ความเสถียรภาพและระยะวิบัติต่อความสูงของลาดดินตามลำดับโดยใช้แบบจำลอง ML ต่างๆ ประเมินประสิทธิภาพของแบบจำลองเหล่านี้จากค่า Mean Squared Error (MSE), R-squared (R^2) สำหรับชุดข้อมูลฝึกสอนและทดสอบ โดยทดสอบแบบจำลองแต่ละตัวภายใต้สามกรณี ได้แก่ การใช้คุณสมบัติปกติ คุณสมบัติแบบพหุนาม และการปรับแต่งไฮเปอร์พารามิเตอร์ ในการเปรียบเทียบจะเปรียบเทียบในข้อมูลหลักเดียวกันซึ่งบ่งบอกถึงประสิทธิภาพสูง ในขณะที่ข้อสังเกตบ่งบอกถึงประสิทธิภาพต่ำวิธีเชิงเส้น LR, Ridge, Lasso และ EN แสดงค่า MAPE และ MSE ในระดับปานกลาง และมีค่า R^2 สูงทั้งสำหรับชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ สิ่งนี้ชี้ให้เห็นว่าแบบจำลองเหล่านี้ยังเป็นฐานที่เชื่อถือได้สำหรับการเปรียบเทียบ โดยเฉพาะอย่างยิ่งในกรณีคุณสมบัติแบบพหุนามมีค่าความคลาดเคลื่อน (MAPE และ MSE) ลดลง และค่า R^2 เพิ่มขึ้นอย่างเห็นได้ชัด

ชี้ว่าคุณสมบัติแบบพหุนามช่วยให้วิธีการเชิงเส้นจับความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นของการวิบัติลาดดินได้ แต่ด้วย Ridge, Lasso และ EN มีการทำให้เป็นปกติ (Regularization) ที่ป้องกันไม่ให้เกิดโอเวอร์ฟิตตั้งรวมทั้งลดสัมประสิทธิ์ในการคำนวณถดถอยสำหรับตัวแปรที่มีความสำคัญต่ำ เห็นได้ว่าในกรณีคุณสมบัติปกติ Lasso และ EN ที่มีการกรองตัวแปรที่ไม่สำคัญออก แสดงค่าคลาดเคลื่อนที่น้อยกว่า LR และ Ridge แต่ในกรณีคุณสมบัติแบบพหุนามนั้นแสดงค่าความคลาดเคลื่อนสูงกว่า และการปรับแต่งไฮเปอร์พารามิเตอร์ไม่ได้ช่วยปรับปรุงประสิทธิภาพแบบจำลองเชิงเส้น

แบบจำลอง LgR มีประสิทธิภาพดีในทุกกรณีสามารถจำแนกประเภทได้แม่นยำ (accuracy) มีค่า Precision, Recall และ F1-score ที่สูง บ่งบอกถึงประสิทธิภาพโดยรวมที่ดีในการจำแนกความปลอดภัยของลาดดินประสิทธิภาพเพิ่มในกรณีคุณสมบัติพหุนาม ปรับปรุงประสิทธิภาพแบบจำลองอย่างเห็นได้ชัดแสดงใน Table 5 ที่แสดงค่า Precision, Recall และ F1-score สำหรับการจำแนกระดับความปลอดภัย โดยค่าเหล่านี้คำนวณเป็นค่าเฉลี่ยแบบถ่วงน้ำหนัก (Weighted Average) จากผลการประเมินทั้งสามคลาส (Fail, Critical, Safe) วิธีการนี้ใช้เพื่อลดการเอนเอียงในกรณีที่จำนวนตัวอย่างในแต่ละคลาสไม่เท่ากัน

แบบจำลอง KNR และ SVR แสดงค่า MAPE และ MSE ที่สูงกว่าเมื่อเทียบกับแบบจำลองเชิงเส้น ซึ่งบ่งชี้ถึงการคาดการณ์ที่แม่นยำน้อยกว่า ยิ่งในกรณีคุณสมบัติแบบพหุนามยิ่งเพิ่มตัวแปรให้กับแบบจำลองเหล่านี้ยิ่งทำให้ประสิทธิภาพ

ในการทำนายลดลง อย่างไรก็ตาม การปรับแต่งไฮเปอร์พารามิเตอร์นำไปสู่การปรับปรุงที่สำคัญในค่า R² โดยเฉพาะอย่างยิ่งสำหรับ KNR แต่ส่งผลให้ R² ของชุดข้อมูลการสอนสูงขึ้นและ R² ของชุดข้อมูลทดสอบต่ำลงแสดงให้เห็นว่าแบบจำลองเกิด overfit ซึ่งไม่ผลดี วิธีการแก้ไขที่เป็นไปได้คือการใช้เทคนิค Cross-Validation หรือ Regularization

กลุ่มวิธีต้นไม้ (DTR, XTR, RFR, BR) ทำงานได้ดีโดยมีค่า MAPE และ MSE ต่ำและค่า R² สูง ซึ่งแสดงให้เห็นถึงความแข็งแกร่งในการทำนายเสถียรภาพของลาดดินสอดคล้องกับผลการศึกษาก่อนหน้านี้ของ Tien *et al.* (2019), Singh and Chakravarty (2023) และ Lin *et al.* (2021) การปรับแต่งไฮเปอร์พารามิเตอร์ไม่แสดงผลกระทบที่มีนัยสำคัญต่อประสิทธิภาพการทำงาน (Tien Bui *et al.*, 2019)

Table 3 Safety factor regression prediction performance

FS													
Model	Normal Feature				Polynomial Feature				Hyperparameter Tuning				
	MAPE	MSE	R ²		MAPE	MSE	R ²		MAPE	MSE	R ²		
			Train	Test			Train	Test			Train	Test	
LR	1.31	6.9	0.70	0.81	0.47	3.41	0.81	0.91					
Ridge	1.31	6.89	0.70	0.81	0.45	3.40	0.81	0.91	1.31	6.90	0.70	0.81	
Lasso	0.93	6.74	0.69	0.81	0.62	4.06	0.78	0.89	1.31	6.90	0.70	0.81	
EN	0.93	6.71	0.69	0.81	0.53	3.92	0.79	0.89	1.31	6.90	0.70	0.81	
KNR	0.58	9.93	0.71	0.72	0.60	11.31	0.71	0.68	0.50	12.40	0.95	0.65	
SVR	0.48	9.96	0.62	0.72	0.66	10.12	0.61	0.72	0.44	8.19	0.61	0.77	
DTR	0.29	6.07	0.98	0.83	0.30	4.33	0.98	0.88	0.30	6.08	0.98	0.83	
XTR	0.27	4.35	0.98	0.88	0.27	4.22	0.98	0.88	0.27	4.34	0.98	0.88	
RFR	0.26	3.43	0.95	0.90	0.28	3.49	0.95	0.90	0.28	3.38	0.95	0.91	
BR	0.27	3.62	0.94	0.90	0.32	3.79	0.94	0.89	0.48	4.51	0.89	0.87	
GBR	0.35	2.68	0.88	0.93	0.35	3.40	0.91	0.91	2.56	18.35	0.47	0.49	
ABR	0.59	6.21	0.97	0.83	2.70	12.74	0.66	0.64	0.72	6.41	0.76	0.82	
CBR	0.47	3.22	0.96	0.91	0.31	3.44	0.97	0.90	3.58	32.24	0.11	0.10	
MLPR	0.77	9.8	0.64	0.73	2.46	94.18	-1.32	-1.63	0.82	8.98	0.57	0.75	

Table 4 Slope failure distance regression prediction performance

L/H													
Model	Normal Feature				Polynomial Feature				Hyperparameter Tuning				
	MAPE	MSE	R ²		MAPE	MSE	R ²		MAPE	MSE	R ²		
			Train	Test			Train	Test			Train	Test	
LR	0.24	0.64	0.68	0.71	0.22	0.48	0.80	0.78					
Ridge	0.24	0.64	0.68	0.71	0.23	0.48	0.80	0.78	0.24	0.64	0.68	0.71	
Lasso	0.28	0.71	0.64	0.68	0.26	0.68	0.69	0.69	0.24	0.64	0.68	0.71	
EN	0.27	0.69	0.65	0.68	0.25	0.58	0.74	0.73	0.24	0.64	0.68	0.71	
KNR	0.26	0.58	0.80	0.74	0.26	0.60	0.80	0.73	0.31	0.93	0.99	0.58	
SVR	0.23	0.64	0.75	0.71	0.24	0.75	0.70	0.66	0.22	0.66	0.67	0.70	
DTR	0.2	0.61	0.99	0.72	0.20	0.67	0.99	0.69	0.20	0.61	0.99	0.72	
XTR	0.17	0.45	0.99	0.80	0.17	0.48	0.99	0.78	0.17	0.47	0.99	0.78	
RFR	0.16	0.38	0.97	0.83	0.16	0.37	0.97	0.83	0.16	0.39	0.97	0.82	
BR	0.16	0.43	0.96	0.81	0.18	0.42	0.96	0.81	0.16	0.42	0.90	0.81	
GBR	0.16	0.35	0.90	0.84	0.16	0.36	0.93	0.84	0.43	1.20	0.46	0.45	
ABR	0.28	0.53	0.76	0.76	0.17	0.45	0.99	0.80	0.25	0.57	0.76	0.74	
CBR	0.15	0.38	0.97	0.83	0.15	0.34	0.98	0.85	0.58	2.19	0.01	0.00	
MLPR	0.5	2.19	0.19	0.00	3.24	87.9	-38.4	-39.1	0.59	3.65	-0.56	-0.67	

กลุ่ม Boosting (GBR, ABR, CBR) มีประสิทธิภาพที่แตกต่างกันอยู่ระหว่างกลุ่มเชิงเส้นและกลุ่มต้นไม้ จากตารางเห็นได้ว่าการปรับแต่งไฮเปอร์ พารามิเตอร์ไม่ได้ช่วยเพิ่มประสิทธิภาพให้กับแบบจำลองเหล่านี้ เกิดขึ้นจากการเลือกชุดไฮเปอร์

พารามิเตอร์ที่ไม่เหมาะสม สามารถแก้ปัญหาได้ด้วยการใช้ไฮเปอร์พารามิเตอร์ที่ละเอียดยิ่งขึ้นและขยายขอบเขตเพิ่มขึ้น

MLP แสดงประสิทธิภาพต่ำกว่าทุกแบบจำลองทั้งสามกรณี โดยเฉพาะอย่างยิ่งกรณีคุณสมบัติแบบพหุนามนั้น ค่าความคลาดเคลื่อนเพิ่มขึ้นอย่างมาก และค่า R^2 ตีตลาดบ่งบอกถึงปัญหาการลู่เข้าระหว่างฝึก ทำให้ผลลัพธ์ไม่น่าเชื่อถือ คุณสมบัติแบบพหุนามโดยทั่วไปช่วยปรับปรุงประสิทธิภาพสำหรับแบบจำลองส่วนใหญ่ กล่าวคือ การนำความสัมพันธ์ที่ไม่ใช่เชิงเส้นระหว่างคุณสมบัติกับตัวแปรเป้าหมายมาพิจารณานั้นมีความสำคัญต่อการทำนายที่แม่นยำ ซึ่งสอดคล้องกับแนวทางปฏิบัติทั่วไปในการใช้คุณสมบัติพหุนามในงานวิศวกรรมเทคนิค เนื่องจากลักษณะการไหลของดินมักแสดงความเป็นเส้นตรง

การใช้คุณสมบัติพหุนามช่วยปรับปรุงประสิทธิภาพเฉพาะในกลุ่มแบบจำลองเชิงเส้น เช่น Linear Regression, Ridge, Lasso, และ Elastic Net อย่างมีนัยสำคัญ ผลการปรับปรุงนี้ชัดเจนในเรื่องการลดค่าความคลาดเคลื่อน (MAPE, MSE) และเพิ่มค่า R-squared ในแบบจำลองเชิงเส้น สำหรับแบบจำลองที่ไม่ใช่เชิงเส้น เช่น KNR, SVR, หรือ Random Forest การใช้คุณสมบัติพหุนามไม่ได้ส่งผลให้ประสิทธิภาพ

ของแบบจำลองดีขึ้นอย่างมีนัยสำคัญ และในบางกรณีอาจทำให้ประสิทธิภาพลดลง

จากผลการประเมินพบว่า การปรับแต่งไฮเปอร์พารามิเตอร์ไม่ได้ช่วยปรับปรุงประสิทธิภาพของแบบจำลอง RFR และ GBR อย่างมีนัยสำคัญ โดยไม่ว่าจะพิจารณาจากตัวชี้วัดใด แสดงให้เห็นว่าโมเดลเหล่านี้ทำงานได้อย่างมีประสิทธิภาพอยู่แล้วโดยไม่จำเป็นต้องปรับแต่งเพิ่มเติม อาจมาจากโครงสร้างของโมเดลที่มีความเสถียรและประสิทธิภาพสูงในตัวเอง การปรับแต่งไฮเปอร์พารามิเตอร์จึงไม่ได้เพิ่มประสิทธิภาพอย่างที่คาดหวัง

แบบจำลอง LgR มีประสิทธิภาพดีในทุกกรณี สามารถจำแนกประเภทได้แม่นยำ (accuracy) มีค่า Precision, Recall และ F1-score ที่สูง บ่งบอกถึงประสิทธิภาพโดยรวมที่ดีในการจำแนกความปลอดภัยของลาดดิน ประสิทธิภาพเพิ่มในกรณีคุณสมบัติพหุนาม ปรับปรุงประสิทธิภาพแบบจำลองอย่างเห็นได้ชัดแสดงใน Table 5 ที่แสดงประสิทธิภาพในการจำแนกความปลอดภัยทั้งสามระดับแบบจำลอง KNC, SVC, DTC, XTC, RFC, BR, GBC, ABC, CBC, LS และ MLPC ส่วนใหญ่แสดงประสิทธิภาพที่เหมาะสมในส่วนของ Accuracy, Precision, Recall และ F1-score KNC และ SVC มีประสิทธิภาพต่ำกว่าการจำแนกประเภทอื่นๆ เล็กน้อย โดยเฉพาะในด้าน Precision และ Recall ในแบบจำลอง DTC, XTC และ RFC ซึ่งมีพื้นฐานเป็น Tree Model มีประสิทธิภาพคงที่ในทุกกรณี หรือกล่าวอีกอย่างคือ คุณสมบัติพหุนาม และการปรับแต่งไฮเปอร์พารามิเตอร์ไม่ส่งผลต่อความถูกต้องของแบบจำลองดังกล่าว

Table 5 Performance in predicting the safety level classification of soil slope.

Model	Normal Feature					Polynomial Feature				Hyperparameter Tuning			
	Acc.	Pre.	Recall	F1	AUC	Acc.	Pre.	Recall	F1	Acc.	Pre.	Recall	F1
LgR	0.88	0.67	0.63	0.63	0.90	0.92	0.95	0.71	0.73	0.87	0.58	0.62	0.60
KNC	0.79	0.55	0.58	0.56	0.84	0.78	0.56	0.59	0.57	0.83	0.62	0.62	0.62
SVC	0.84	0.54	0.58	0.56	0.90	0.78	0.48	0.47	0.47	0.85	0.67	0.67	0.67
DTC	0.85	0.73	0.70	0.71	0.75	0.84	0.67	0.66	0.66	0.82	0.65	0.60	0.62
XTC	0.92	0.86	0.77	0.80	0.89	0.91	0.80	0.76	0.78	0.90	0.76	0.66	0.65
RFC	0.90	0.77	0.69	0.71	0.91	0.91	0.78	0.72	0.74	0.89	0.59	0.63	0.61
BC	0.86	0.71	0.69	0.70	0.89	0.85	0.71	0.65	0.67	0.92	0.82	0.73	0.75
GBC	0.87	0.67	0.63	0.65	0.93	0.90	0.77	0.71	0.72	0.84	0.67	0.66	0.66
ABC	0.84	0.68	0.65	0.66	0.89	0.83	0.70	0.69	0.68	0.88	0.59	0.61	0.60
CBC	0.89	0.75	0.71	0.73	0.94	0.90	0.74	0.69	0.70	0.90	0.72	0.67	0.67
LS	0.81	0.60	0.60	0.60	0.82	0.16	0.64	0.34	0.13	0.82	0.50	0.58	0.53
MLPC	0.90	0.82	0.68	0.68	0.95	0.83	0.65	0.58	0.60	0.93	0.84	0.79	0.81

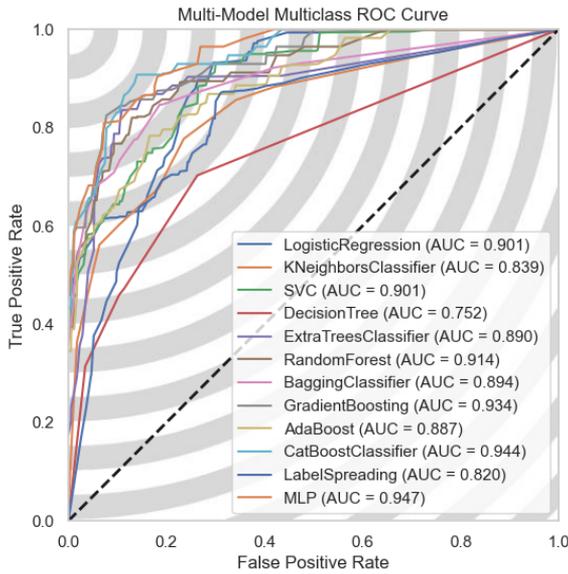


Figure 6 ROC curves and AUC values of the classifier models

จากการประเมินผลใน Table 5 พบว่า MLP Classifier (MLPC) มีประสิทธิภาพเพิ่มขึ้นหลังการปรับแต่งไฮเปอร์พารามิเตอร์ โดยเฉพาะในด้าน Accuracy, Precision Recall และ F1-score อย่างไรก็ตามการใช้สมบัติพหุนามทำให้ประสิทธิภาพของ MLPC ลดลง การใช้สมบัติพหุนามในแบบจำลองที่มีโครงสร้างซับซ้อนอยู่แล้ว เช่น MLPC อาจไม่ได้ช่วยเพิ่มประสิทธิภาพเสมอไป และในบางกรณีอาจทำให้เกิดการ overfitting ส่งผลให้ประสิทธิภาพโดยรวมลดลง

Figure 6 แสดงผล ROC curves ซึ่งเป็นค่าเฉลี่ยของ AUC ที่คำนวณจากทั้งสามคลาส (Fail, Critical, Safe) โดยใช้วิธี One-vs-Rest (OvR) การเฉลี่ยนี้สะท้อนผลการจำแนกโดยรวมของโมเดลเพื่อให้การนำเสนอเข้าใจง่าย อย่างไรก็ตาม ค่า AUC สำหรับแต่ละคลาส ได้แก่ Fail vs [Critical, Safe], Critical vs [Fail, Safe], และ Safe vs [Fail, Critical] ในแบบจำลองการจำแนกชนิดต่างๆ สามารถแบ่งได้เป็นแบบจำลองที่มีประสิทธิภาพยอดเยี่ยม ดีมาก และดีได้ดังนี้

แบบจำลองประสิทธิภาพยอดเยี่ยม: แบบจำลอง MLP แสดงค่า AUC สูงสุด มีประสิทธิภาพสูงสุดในบรรดาแบบจำลองจำแนกทั้งหมด รองมาคือ CBC ถึงแม้จะมีค่า AUC ต่ำกว่าของ MLP แต่อยู่ใกล้จุดสมบูรณ์แบบ (พิกัด 0, 1) กว่า MLP ถัดมาคือแบบจำลอง Gradient Boosting สร้างแผนผังการตัดสินใจหลายแบบและรวมผลลัพธ์เพื่อปรับปรุงความแม่นยำ สะท้อนให้เห็นด้วยใน AUC ที่สูง แบบจำลอง RandomForest จะสร้างแผนผังการตัดสินใจหลายแบบและรวมผลลัพธ์เข้าด้วยกันนำไปสู่ประสิทธิภาพที่ดีที่สุดท้ายในกลุ่มนี้คือแบบจำลอง LgR และ SVC มีค่า AUC เท่ากัน แบบจำลอง

ประสิทธิภาพดีมาก: แบบจำลอง BC XTC ADB SVC KNC และ LS กลุ่มสุดท้ายแบบจำลองประสิทธิภาพดีคือ Decision Tree

เมื่อพิจารณาถึงความเสถียรและสมรรถนะของแบบจำลองแล้ว วิธีแบบรวม เช่น RandomForest, ExtraTrees และ Gradient Boosting โดยทั่วไปจะแสดงค่า AUC ที่สูงกว่าบ่งชี้ว่าการรวมหลายแบบจำลองจะช่วยลดความแปรปรวน (variance) และความเอนเอียง (bias) ซึ่งจะช่วยปรับปรุงความเสถียรภาพและประสิทธิภาพของแบบจำลอง

สรุปผลและอภิปรายผล

งานวิจัยนี้นำเสนอการใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning, ML) ในการทำนายเสถียรภาพและระยะวิบัติของลาดดินโดยพิจารณาจากตัวแปรที่สำคัญ ได้แก่ หน่วยแรงยึดเหนี่ยว (C) มุมเสียดทานภายใน (Phi) มุมลาดชัน (Slope) และความสูงของลาดดิน (H) ผลจากการวิจัยสามารถสรุปได้ว่า

Random Forest มีประสิทธิภาพสูงสุดทั้งในการทำนายอัตราส่วนความปลอดภัย (Factor of Safety, FS) และระยะวิบัติของลาดดินต่อความสูง (L/H) นอกจากนี้

การใช้คุณสมบัติพหุนามช่วยเพิ่มประสิทธิภาพของแบบจำลองเชิงเส้นได้อย่างมีนัยสำคัญ ในขณะที่การปรับแต่งไฮเปอร์พารามิเตอร์ช่วยปรับปรุงประสิทธิภาพของแบบจำลองที่ซับซ้อน เช่น Support Vector Machine (SVM) และ Multilayer Perceptron (MLP) ได้เป็นอย่างดี โดยเฉพาะในการทำนายระดับความปลอดภัยของลาดดิน

ผลการวิจัยแสดงให้เห็นว่าการใช้เทคนิคการเรียนรู้ของเครื่องในงานด้านวิศวกรรมธรณีเทคนิค โดยเฉพาะการทำนายเสถียรภาพลาดดิน มีศักยภาพสูงในการทำนายผลลัพธ์ที่แม่นยำกว่าวิธีการแบบดั้งเดิม เช่น วิธีสมดุลจำกัด (Limit Equilibrium Method, LEM) แบบจำลอง Random Forest ทำงานได้อย่างมีประสิทธิภาพทั้งในส่วนของการทำนายถดถอย (FS และ L/H) และการจำแนกระดับความปลอดภัย (Fail, Critical, Safe) ซึ่งสามารถอธิบายได้จากการที่แบบจำลองนี้มีความสามารถในการจัดการกับข้อมูลที่ซับซ้อนและมีความแปรปรวนสูง

นอกจากนี้ การใช้คุณสมบัติพหุนามในแบบจำลองเชิงเส้น เช่น Linear Regression, Ridge และ Lasso ช่วยให้แบบจำลองสามารถจับความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นระหว่างตัวแปรได้ดีขึ้น ทำให้ค่าความคลาดเคลื่อน (MAPE, MSE) ลดลง และค่าความผันแปรตอบสนอง (R²) เพิ่มขึ้น การปรับแต่งไฮเปอร์พารามิเตอร์ก็แสดงผลลัพธ์ในเชิงบวก

โดยเฉพาะอย่างยิ่งในแบบจำลองที่มีโครงสร้างซับซ้อน เช่น SVM และ MLP ที่ต้องการการปรับแต่งเพื่อให้สามารถจับรูปแบบที่ซ่อนอยู่ในข้อมูลได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม สำหรับบางแบบจำลอง การใช้คุณสมบัติพหุนามอาจส่งผลให้เกิดการ overfitting ซึ่งบ่งชี้ว่าการเลือกคุณสมบัติพหุนามและการปรับแต่งไฮเปอร์พารามิเตอร์ต้องทำอย่างระมัดระวัง

ในภาพรวม การศึกษานี้ชี้ให้เห็นว่า การประยุกต์ใช้การเรียนรู้ของเครื่องสามารถเป็นทางเลือกที่ดีในการเพิ่มประสิทธิภาพและความแม่นยำในการทำนายเสถียรภาพของลาดดิน ซึ่งเป็นประโยชน์ต่อการออกแบบและวางแผนงานวิศวกรรมธรณีเทคนิคในการป้องกันและลดความเสี่ยงจากการพังทลายของลาดดิน

เอกสารอ้างอิง

- ณัฐวุฒิ แกมเงิน, ปกรณ์ ล่องทอง, พงศศรันย์ ทองหนู้อย, กนกวรรณ ละอองศรี, อนามัย เทศกะทีก, พีรพล ศิริพงศ์ วุฒิกุล, ณฐนนท์ เทพตะขบ และวิริยะ มหิกุล. (2023). การเรียนรู้ของเครื่องเพื่อทำนายระดับความรุนแรงของความผิดปกติของความยืดหยุ่นปอดของพนักงานโรงงาน. *Science and Technology Journal Mahasarakham University*, 43(2), 84–95.
- สุภาวีย์ ชันคำ และสิโรรัตน์ จันทาม. (2023). แบบจำลองการพยากรณ์สำหรับปริมาณการส่งออกเครื่องเทศของประเทศไทย. *Science and Technology Journal Mahasarakham University*, 43(1), 74–83.
- Azarafza, M., Azarafza, M., Akgün, H., Atkinson, P. M., & Derakhshani, R. (2021). Deep learning-based landslide susceptibility mapping. *Scientific Reports*, 11(1), 24112.
- Bishop, A. W. (1955). The use of the slip circle in the stability analysis of slopes. *Géotechnique*, 5(1), 7–17.
- Fellenius, W. (1927). *Erdstatische statik*. Meyer and Zeller.
- Harabinová, S., & Panulinová, E. (2020). *Impact of shear strength parameters on slope stability*. MATEC Web of Conferences, 310, 00040. <https://doi.org/10.1051/mateconf/202031000040>
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. John Wiley & Sons.
- Huang, F., Xiong, H., Chen, S., Lv, Z., Huang, J., Chang, Z., & Catani, F. (2023). Slope stability prediction based on a long short-term memory neural network: Comparisons with convolutional neural networks, support vector machines and random forest models. *International Journal of Coal Science & Technology*, 10(1), 18.
- Huang, F., Ye, Z., Jiang, S. H., Huang, J., Chang, Z., & Chen, J. (2021). *Uncertainty study of landslide susceptibility prediction considering the different attribute interval numbers of environmental factors and different data-based models*. Catena, 202, 105250.
- Lin, S., Zheng, H., Han, C., Han, B., & Li, W. (2021). Evaluation and prediction of slope stability using machine learning approaches. *Frontiers of Structural and Civil Engineering*, 15(4), 821–833.
- Morgenstern, N. U., & Price, V. E. (1965). The analysis of the stability of general slip surfaces. *Géotechnique*, 15(1), 79–93.
- Nikoobakht, S., Azarafza, M., Akgün, H., & Derakhshani, R. (2022). Landslide susceptibility assessment by using convolutional neural network. *Applied Sciences*, 12(12), 5992.
- Pham, B. T., Vu, V. D., Costache, R., Phong, T. V., Ngo, T. Q., Tran, T. H., ... & Prakash, I. (2022). Landslide susceptibility mapping using state-of-the-art machine learning ensembles. *Geocarto International*, 37(18), 5175–5200.
- Singh, S. K., & Chakravarty, D. (2023). Assessment of slope stability using classification and regression algorithms subjected to internal and external factors. *Archives of Mining Sciences*, 68(1), 87–102.
- Spencer, E. (1967). A method of analysis of the stability of embankments assuming parallel inter-slice forces. *Géotechnique*, 17(1), 11–26.
- Tien Bui, D., Moayed, H., Gör, M., Jaafari, A., & Foong, L. K. (2019). Predicting slope stability failure through machine learning paradigms. *ISPRS International Journal of Geo-Information*, 8(9), 395.
- Wang, Y., Sun, D., Wen, H., Zhang, H., & Zhang, F. (2020). Comparison of random forest model and frequency ratio model for landslide susceptibility mapping (LSM) in Yunyang County (Chongqing, China). *International Journal of Environmental Research and Public Health*, 17(12), 4206.

World Bank. (2020). *Global landslide hazard 1 [Data set]*.

World Bank Data Catalog. <https://datacatalog.world-bank.org/dataset/global-landslide-hazard-1>

World Health Organization. (2023). *Landslides*. [https://](https://www.who.int/health-topics/landslides)

www.who.int/health-topics/landslides

WSDOT. (2013). *Geotechnical design manual M 46-03*.

Washington State Department of Transportation.