



## แบบจำลองการเรียนรู้เครื่องแบบกลุ่มสำหรับประเมินความอ่อนไหวต่อการเกิดดินถล่มในจังหวัดอุตรดิตถ์ ประเทศไทย

นธิมา เนื่องจำนงค์ กฤษญาน อินทรรัตน์\* และ โจจินดา แซ่จิ่ง

หน่วยวิจัยเฉพาะทางด้านการประยุกต์เชิงพื้นที่ (คาปีบารา จีโอ แล็บ)

คณะศิลปศาสตร์ มหาวิทยาลัยธรรมศาสตร์ ประเทศไทย

### Ensemble Machine Learning Models for Landslide Susceptibility Assessment in Uttaradit, Thailand

Nithima Nuengjumng, Kritchayan Intarat\*, and Jojinda Sae-Jung

Research Unit in Geospatial Application (Capybara Geo Lab),

Faculty of Liberal Arts, Thammasat University, Thailand

#### Article Info

##### Research Article

Article History:

Received 27 June 2024

Revised 25 July 2024

Accepted 26 July 2024

#### คำสำคัญ

ความอ่อนไหวต่อการเกิดดินถล่ม,  
การเรียนรู้เครื่อง,  
การเรียนรู้แบบกลุ่ม,  
อัลกอริทึม boosting,  
อุตรดิตถ์

\* Corresponding author

E-mail address:

intaratt@tu.ac.th

#### บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพการเรียนรู้เครื่องแบบกลุ่ม (ensemble learning) ด้วยอัลกอริทึม boosting สามแบบ ได้แก่ adaptive boosting (ADA) gradient boosting (GB) และ eXtreme gradient boosting (XGB) เพื่อหาแบบจำลองที่มีความเหมาะสมในการประเมินความอ่อนไหวของการเกิดดินถล่มในจังหวัดอุตรดิตถ์ โดยใช้ข้อมูลจุดเกิดและไม่เกิดดินถล่มที่ถูกบันทึกไว้ย้อนหลัง 30 ปี ในการฝึกสอนและทดสอบประสิทธิภาพของแบบจำลอง ใช้ข้อมูล 14 ประเภท ในการวิเคราะห์ปัจจัยที่ส่งผลต่อความอ่อนไหวในการเกิดดินถล่ม ประกอบไปด้วยปัจจัยทางธรรมชาติและปัจจัยที่ได้รับอิทธิพลจากมนุษย์ ทั้งนี้ เพื่อลดอิทธิพลจากความสัมพันธ์กันเองของตัวแปรอิสระ งานวิจัยนี้ได้ทดสอบ multicollinearity โดยกำหนดเกณฑ์ค่า VIF น้อยกว่า 5 และค่า TOL มากกว่า 0.10 มีปัจจัยที่ผ่านการคัดเลือกเข้าสู่แบบจำลอง 9 ปัจจัย และประสิทธิภาพของแบบจำลองจะถูกทดสอบด้วยค่าสถิติเพื่อให้ได้แบบจำลองที่ดีที่สุด ผลการศึกษาพบว่า 1) ปัจจัยด้านธรณีวิทยามีความสำคัญของปัจจัยสูงสุดในทุกแบบจำลอง 2) ทั้งสามแบบจำลองสามารถใช้ประเมินความอ่อนไหวต่อการเกิดดินถล่มได้ โดยแบบจำลอง GB และ XGB มีประสิทธิภาพสูงสุด เมื่อทดสอบด้วยค่าสถิติ F1-score และค่าความถูกต้องโดยรวม ส่วนการเปรียบเทียบพื้นที่ใต้กราฟ ROC แบบจำลอง XGB มีประสิทธิภาพสูงสุด 3) การทำนายการกระจายตัวของพื้นที่อ่อนไหวต่อดินถล่มของทั้งสามแบบจำลองมีความคล้ายคลึงกัน บริเวณที่มีระดับความอ่อนไหวมากที่สุด ยกเว้นแบบจำลอง ADA ที่มีการแบ่งช่วงในระดับปานกลางถึงน้อยละเอียดกว่าแบบจำลองอื่น ๆ จากข้อค้นพบในครั้งนี้สามารถใช้เป็นเครื่องมือที่มีศักยภาพสำหรับการทำนายและใช้เป็นแนวทางในการลดความเสี่ยงจากภัยพิบัติได้

**Keywords:**

landslide susceptibility,  
machine learning,  
ensemble learning,  
boosting algorithms,  
Uttaradit

---

**Abstract**

---

This research compared the performance of ensemble learning methods by using different boosting algorithms: adaptive (ADA), gradient (GB), and eXtreme gradient boosting (XGB) for assessing landslide susceptibility in Uttaradit Province. It uses 30 years of historical data on landslide occurrences and non-occurrences to train and validate the models. The analysis includes 14 natural and human-induced factors influencing landslide susceptibility. Multicollinearity testing set criteria ( $VIF < 5$  and  $TOL > 0.10$ ) with nine factors selected for modelling. Model performance was statistically evaluated. Key findings include: 1) geomorphological factors were consistently the most significant across all models; 2) all three models effectively assessed landslide susceptibility, with GB and XGB achieving the highest performance (97%) based on harmonic mean of precision and recall (F1) score and overall accuracy; 3) XGB demonstrated the highest effectiveness (99%) in receiver operating characteristic (ROC) curve analysis. Predictive susceptibility distributions among the three models were similar in high-risk areas, except ADA, which showed broader and less detailed segmentation than other models. These findings confirm the potential of ensemble learning techniques, especially GB and XGB for accurate landslide prediction and risk reduction strategy.

## 1. บทนำ

ภัยธรรมชาติมีแนวโน้มและความรุนแรงเพิ่มมากขึ้นเนื่องจากการเปลี่ยนแปลงของสภาพอากาศ ส่งผลให้เกิดสภาวะโลกร้อนที่มีความแปรปรวนของสภาพภูมิอากาศเกิดขึ้นทั่วโลก นำไปสู่ภัยพิบัติทางธรรมชาติที่รุนแรงและการสูญเสียในด้านของทรัพย์สินและชีวิตของผู้คน นอกจากนี้ยังส่งผลกระทบต่อเศรษฐกิจ (Akinci et al., 2020) ดินถล่ม (landslide) เป็นภัยพิบัติทางธรรมชาติที่หากเกิดขึ้นแล้วจะมีความอันตรายต่อชีวิตและทรัพย์สิน พบในภูมิภาคแบบภูเขาที่มีพื้นที่ลาดเอียงสูงและมีหินฐานเป็นหินเนื้อแน่น ส่วนใหญ่เป็นหินแกรนิตซึ่งมีแร่ประกอบหินหลักเป็นเฟลด์สปาร์และควอตซ์เมื่อเกิดการผุพังแล้วจะให้หินเหนียวและทราย ประกอบกับปัจจัยที่อยู่ภายในพื้นที่อื่น เช่น ความลาดชัน ทิศทางความลาดชัน รอยเลื่อน ฯลฯ ที่ล้วนมีผลต่อการเกิดดินถล่ม นอกจากนี้ การเกิดดินถล่มยังเป็นผลมาจากการถูกระตุ้นโดยปัจจัยภายนอก เช่น ปริมาณฝนที่ตกมากในพื้นที่ การเกิดแผ่นดินไหว การเกิดภูเขาไฟระเบิด และกิจกรรมของมนุษย์ (Guzzetti et al., 2004; Keefer, 1984) จังหวัดอุดรธานีมีลักษณะภูมิประเทศเป็นภูเขาสลับซับซ้อนที่มีความลาดชัน มีรอยเลื่อนกลุ่มที่มีพลังอยู่ภายในพื้นที่ (กลุ่มรอยเลื่อนอุดรดิตถ์) มีที่ราบอยู่ระหว่างหุบเขาและเชิงเขา คิดเป็นร้อยละ 60 ของพื้นที่ทั้งหมด ลักษณะภูมิอากาศเป็นแบบเขตฝนเมืองร้อน (tropical savannah climate: AW) สภาพภูมิประเทศและภูมิอากาศดังกล่าวส่งผลให้จังหวัดอุดรธานีประสบภัยพิบัติทางธรรมชาติอยู่บ่อยครั้ง อาทิ น้ำท่วม แผ่นดินไหว การพังทลายของหน้าดิน (soil erosion) และดินถล่ม สถานการณ์ความแปรปรวนของสภาพอากาศที่เกิดจากภาวะโลกร้อน (global warming) มีความรุนแรงมากขึ้น ยิ่งเป็นผลให้ภัยพิบัติที่มีความรุนแรงมากยิ่งขึ้นเช่นกัน ใน พ.ศ. 2549 เกิดเหตุการณ์ดินถล่มขนาดใหญ่ในจังหวัดอุดรธานี เนื่องจากเกิดฝนตกหนักต่อเนื่องเป็นเวลาหลายวัน ส่งผลให้พื้นที่บริเวณดังกล่าวซึ่งเป็นพื้นที่ที่มีความลาดชันสูงและมีลักษณะตะกอนทรายไม่สามารถรองรับปริมาณน้ำฝนได้เพียงพอ พื้นที่บางบริเวณจึงเกิดการพังทลายลงสร้างความเสียหายต่อบ้านเรือนถึง 3,500 หลังคาเรือน (Hydro-Informatics Institute, n.d.) และดินถล่มมีโอกาสดังกล่าวเกิดขึ้นซ้ำพื้นที่เดิมในอนาคตหากสภาพของปัจจัยในพื้นที่มีลักษณะที่สนับสนุนการเกิดภัย เช่น การผุพังของหินฐานในพื้นที่ ซึ่งต้องอาศัยระยะเวลาของกระบวนการ

การวิเคราะห์ความอ่อนไหวเป็นการจำแนกเพื่อหาโอกาสเกิดหรือความน่าจะเป็นที่จะเกิดของเหตุการณ์ (probability of occurrences) มีวิธีการจำแนกที่นิยมใช้วิเคราะห์ความอ่อนไหวอยู่หลายวิธี เช่น การวิเคราะห์แบบลำดับชั้น (Alizadeh et al., 2018; Park et al., 2013; Yalcin, 2008) การวิเคราะห์ความถี่ (Choi et al., 2012; Regmi et al., 2014) และการวิเคราะห์การถดถอยโลจิสติกส์ (Akgun, 2012; Pham et al., 2016; Trigila et al., 2013) จากการพัฒนาของการเรียนรู้เครื่อง (machine learning: ML) ทั้งด้านอัลกอริทึมและทรัพยากรประมวลผลส่งผลให้แบบจำลอง ML ได้ถูกนำมาประยุกต์ในงานด้านการวิเคราะห์ความอ่อนไหวต่อการเกิดดินถล่มเป็นจำนวนมาก

(H. Yu et al., 2023) แบบจำลอง ensemble learning เป็นอีกเทคนิคหนึ่งของแบบจำลอง ML ที่ใช้แบบจำลองหลายแบบจำลองร่วมกัน มีประสิทธิภาพสูงกว่าการใช้เพียงแบบจำลองเดี่ยว อัลกอริทึมดังกล่าวมีพื้นฐานมาจากต้นไม้ตัดสินใจ (decision tree) ที่ได้รับการพัฒนาให้มีประสิทธิภาพที่ดีขึ้น แบ่งออกเป็น 2 ประเภทหลัก ได้แก่ 1) bagging เป็นการรวมแบบจำลอง และสุ่มตัวอย่างด้วยวิธีการ bootstrap โดยแต่ละแบบจำลองจะประมวลผลแบบขนาน (parallel computing) จนได้ผลลัพธ์ของแต่ละแบบจำลองออกมา จากนั้นจะเลือกวิธีการเพื่อหาผลลัพธ์ที่ดีที่สุด โดยใช้ค่าเฉลี่ย (mean) หรือค่าที่มีจำนวนมากที่สุด (vote) เป็นคำตอบสุดท้าย ตัวอย่างเช่น ป่าสุ่ม (random forest: RF) และ 2) boosting มีหลักการคล้ายกับ bagging แต่จะนำข้อผิดพลาด (error) ของแบบจำลองตัวก่อนหน้ามาเป็นข้อมูลสอนให้กับแบบจำลองตัวต่อไป โดยแบบจำลองจะใช้ข้อมูลฝึกสอนชุดเดียวกันทั้งหมด ลักษณะการทำงานจะเป็นแบบเรียงลำดับ (sequential method) การทำงานของ boosting จะช่วยลดการเกิด overfitting และลดความซับซ้อนของแบบจำลอง (Intarat et al., 2024) นอกจากนี้ยังช่วยให้ค่าฟังก์ชันการสูญเสีย (loss function) มีค่าลู่เข้าศูนย์ (Huan et al., 2023)

อย่างไรก็ตาม แบบจำลอง ML มุ่งเน้นไปที่การเรียนรู้จากข้อมูลที่เกิดขึ้นจริงในพื้นที่ การสร้างแบบจำลองจำเป็นต้องอาศัยข้อมูลที่เกิดขึ้นในพื้นที่ศึกษาจึงจะให้ผลการประเมินความอ่อนไหวได้มีประสิทธิภาพ (Halder et al., 2024) ไม่สามารถนำแบบจำลอง ML ที่ผ่านการเรียนรู้จากพื้นที่อื่นมาใช้ร่วมกัน นอกจากนี้แบบจำลอง ML แต่ละตัวยังให้ผลลัพธ์การประเมินความอ่อนไหวที่แตกต่างกันขึ้นอยู่กับลักษณะของข้อมูลที่ใช้สอนแบบจำลอง จึงจำเป็นต้องทดสอบเพื่อหาแบบจำลอง ML ที่มีประสิทธิภาพเหมาะสมกับชุดข้อมูลของพื้นที่ศึกษา งานวิจัยนี้ได้สร้างแบบจำลอง ensemble แบบ boosting จำนวนสามแบบจำลอง ได้แก่ adaptive boosting (ADA) gradient boosting (GB) และ eXtreme gradient boosting (XGB) เพื่อเปรียบเทียบประสิทธิภาพและหาแบบจำลองที่มีความเหมาะสมในการประเมินความอ่อนไหวของการเกิดดินถล่มในจังหวัดอุดรธานี ประสิทธิภาพของแบบจำลองทั้งสามจะถูกทดสอบด้วยค่าสถิติเพื่อให้ได้แบบจำลองที่ดีที่สุด ผลการศึกษาสามารถนำไปใช้ประเมินพื้นที่ที่มีโอกาสเกิดดินถล่มในอนาคตสำหรับวางแผนปรับตัวแก่ประชาชนในพื้นที่และเตรียมพร้อม กับเหตุการณ์ดินถล่มที่อาจเกิดขึ้นได้ต่อไป

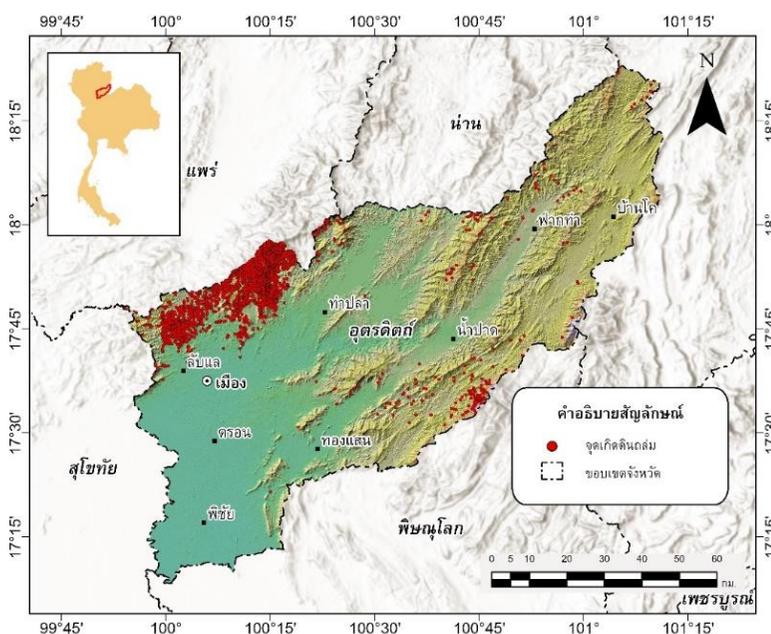
## 2. ขอบเขตพื้นที่ศึกษา

จังหวัดอุดรธานีตั้งอยู่บริเวณภาคเหนือตอนล่างของประเทศไทย ระหว่างละติจูด 17 องศา 37 ลิปดาเหนือ กับ 19 องศา 30 ลิปดาเหนือ และระหว่างลองจิจูด 100 องศา 5 ลิปดาตะวันออก กับ 101 องศา 11 ลิปดาตะวันออก (แผนภาพที่ 1) มีพื้นที่ประมาณ 7,838 ตารางกิโลเมตร ขนาดของเนื้อที่คิดเป็นอันดับ 25 ของประเทศไทยและเป็นอันดับ 11 ของจังหวัดภาคเหนือจาก

จำนวนทั้งหมด 17 จังหวัด ลักษณะภูมิประเทศแบ่งออกเป็น 3 ลักษณะ คือ 1) พื้นที่ราบลุ่มแม่น้ำน่าน เป็นพื้นที่สองฝั่งแม่น้ำน่าน มีลักษณะเป็นพื้นที่ราบลุ่ม อยู่ในเขตอำเภอตรอน อำเภอพิชัย และพื้นที่บางส่วนของอำเภอเมืองอุตรดิตถ์ คิดเป็นร้อยละ 20 ของพื้นที่ทั้งหมด 2) พื้นที่ราบระหว่างภูเขาและเชิงเขา มีลักษณะเป็นที่ราบระหว่างหุบเขาตามแนวคลองตรอน แม่น้ำปาด และลำธารสายต่าง ๆ สลับกับภูมิประเทศแบบภูเขา อยู่ในเขตอำเภอเมืองอุตรดิตถ์ อำเภอลับแล และอำเภอน้ำปาด คิดเป็นร้อยละ 20 ของพื้นที่ทั้งหมด 3) พื้นที่ภูเขาและที่สูง มีลักษณะเป็นภูเขาและที่สูง ตั้งอยู่ทางด้านทิศเหนือและทิศตะวันออกของจังหวัดในเขตอำเภอเมืองอุตรดิตถ์ อำเภอลับแล อำเภอเมืองน้ำปาด อำเภอท่าปลา และอำเภอบ้านโคก คิดเป็นร้อยละ 60 ของพื้นที่ทั้งหมด ลักษณะพื้นที่มากกว่าร้อยละ 50 เป็นพื้นที่ป่าไม้ พื้นที่การเกษตรคิดเป็นร้อยละ 25 พื้นที่ชุมชนและสิ่งปลูกสร้างร้อยละ 17 และพื้นที่แหล่งน้ำร้อยละ 1 ลักษณะภูมิอากาศเป็นแบบเขตฝนเมืองร้อน (tropical savannah climate: AW) ตามการจำแนกสภาพภูมิอากาศของ Köppen-Geiger ฝนที่ตกเกิดจากอิทธิพลลมมรสุมตะวันออกเฉียงใต้ โดยช่วงฤดูฝนเริ่มในเดือนพฤษภาคมและสิ้นสุดในเดือนกันยายน ค่าเฉลี่ยปริมาณน้ำฝนประมาณ 1,300-1,400 มิลลิเมตร อุณหภูมิเฉลี่ยตลอดปีประมาณ 27 องศาเซลเซียส (กรมอุตุนิยมวิทยา, 2566)

**แผนภาพที่ 1**

พื้นที่ศึกษาจังหวัดอุตรดิตถ์ และตำแหน่งการเกิดดินถล่มย้อนหลัง 30 ปี (จุดสีแดง)



จากแผนภาพที่ 1 จุดเกิดดินถล่ม (จุดสีแดงในภาพ) เกิดขึ้นอย่างหนาแน่นที่บริเวณเขาพญาพ้อทางทิศตะวันตก (เขาพญาพ้อเป็นเขตแดนกั้นระหว่างอำเภอท่าปลา จังหวัดอุตรดิตถ์ และอำเภอเมือง จังหวัดแพร่) และทางตะวันออกของจังหวัด โดยที่ภูเขาบริเวณตอนกลางที่มีลักษณะเป็นที่ราบระหว่างหุบเขา (เกิดจากกลุ่มรอยเลื่อนอุตรดิตถ์) ที่วางตัวแนวทิศตะวันออกเฉียงเหนือและตะวันตกเฉียงใต้พบการเกิดดินถล่มอยู่ตลอดแนว ลักษณะธรณีวิทยาของภูเขาด้านตะวันตกของจังหวัด (พื้นที่ทางเหนือของอำเภอลับแล อำเภอเมือง) ซึ่งเป็นพื้นที่ที่มีความหนาแน่นของการเกิดดินถล่มสูง (แผนภาพที่ 1) ถูกจัดอยู่ในหมวดหินลับแลและหมวดหินเขาพริง ในหมวดหินลับแลประกอบด้วยหินดินดาน หินโคลน และหินทรายเกรย์แวก ยุคคาร์บอนิเฟอรัส-เพอร์เมียน ที่บางส่วนมีการผุพัง มีรอยเลื่อนตัดผ่าน ชั้นหินมีการคดโค้งเป็นแบบประทุนคว่ำและประทุนหงาย ส่วนหมวดหินเขาพริงเป็นหินโคลนสลับหินทรายเกรย์แวกที่เกิดในยุคไทรแอสซิก ชั้นหินถูกแทรกดันและตัดผ่านด้วยหินอัคนีประเภทแกรนิต นอกจากนี้ยังพบหินแอนดีไซต์และไดโอไรต์ในพื้นที่

### 3. ข้อมูลและวิธีการที่ใช้ในการวิจัย

#### 3.1 ข้อมูลจุดเกิดดินถล่ม

นำเข้าข้อมูลจุดเกิดดินถล่ม (landslide occurrence point) จากกรมทรัพยากรธรณี ซึ่งเป็นข้อมูลจุดการเกิดดินถล่มที่ถูกบันทึกไว้ย้อนหลัง 30 ปี ตั้งแต่ พ.ศ. 2532 ถึง 2562 จำนวนทั้งหมด 4,192 จุด ในจังหวัดอุตรดิตถ์ (จุดสีแดงในภาพที่ 1) จากนั้นสร้างจุดไม่เกิดดินถล่ม (non-landslide occurrence point) โดยคำนวณจากรัศมี 1 กิโลเมตรจากจุดเกิดดินถล่ม (Huan et al., 2023) โดยให้มีจำนวนเท่ากับจำนวนจุดเกิดแผ่นดินถล่ม ข้อมูลทั้งสอง (จุดเกิดและไม่เกิดดินถล่ม) จะถูกรวมเข้าด้วยกันเพื่อสร้างเป็นชุดข้อมูลสำหรับฝึกสอนแบบจำลอง (sample dataset) โดยชุดข้อมูลดังกล่าวจะถูกแบ่งข้อมูลออกเป็นสองชุดโดยใช้สัดส่วน 70:30 ข้อมูลชุดแรกที่มีสัดส่วนร้อยละ 70 จะถูกใช้เพื่อเป็นข้อมูลสำหรับฝึกสอนแบบจำลอง (training) และข้อมูลที่มีสัดส่วนร้อยละ 30 จะถูกใช้เพื่อเป็นข้อมูลสำหรับทดสอบประสิทธิภาพของแบบจำลอง (validation)

#### 3.2 ปัจจัยต่อการเกิดดินถล่ม

ปัจจัยที่นำเข้าสู่การวิเคราะห์ความอ่อนไหวต่อการเกิดดินถล่มเป็นปัจจัยที่อยู่ภายในพื้นที่ศึกษา (intrinsic factors) ประกอบไปด้วยปัจจัยทางธรรมชาติและปัจจัยที่ได้รับอิทธิพลจากการรบกวนของมนุษย์ โดยปัจจัยทางธรรมชาติ ได้แก่ ความสูงภูมิประเทศเชิงเลข (digital elevation model) ซึ่งได้จากโครงการ Shuttle Radar Topography Mission (SRTM) ความลาดชัน (slope) ทิศทางลาดเขา (aspect) ความโค้ง (curvature) ประเภทของธรณีวิทยา

(geology) ดัชนีพลังงานกระแสน้ำ (standardized precipitation index: SPI) ดัชนีความชื้น (topographic wetness index: TWI) ดัชนีความหยาบทางภูมิศาสตร์ (terrain ruggedness index: TRI) ข้อมูลชุดดิน (soil) ได้จากกระบวนการวิเคราะห์ จากปัจจัยความสูง ดัชนีพืชพรรณ (normalized difference vegetation index: NDVI) ดัชนีน้ำ (normalized difference water index: NDWI) จากข้อมูลดาวเทียม Landsat 8-OLI (USGS) ระยะห่างจากลำน้ำ (distance from stream) ระยะห่างจากรอยเลื่อน (distance from fault) จากกรมทรัพยากรธรณี และปัจจัยที่ได้รับอิทธิพลจากการรบกวนของมนุษย์ ได้แก่ ระยะห่างจากเส้นทางขนส่ง (distance from transportation) จากกรมการปกครอง โดยทุกปัจจัยจะถูกประมวลผลให้อยู่ในมาตรฐานเดียวกัน โดยทุกปัจจัยมีความละเอียดเชิงพื้นที่เท่ากับ 30 เมตรและขนาดพื้นที่ข้อมูล (extent) เท่ากัน เพื่อให้ข้อมูลสามารถซ้อนกันได้

### 3.3 ปัญหาภาวะร่วมของตัวแปรในแบบจำลองเส้นตรง (multicollinearity)

เนื่องจากตัวแปรอิสระอาจเกิดปัญหาภาวะร่วมของตัวแปรในตัวแบบเส้นตรงซึ่งเป็นภาวะที่ตัวแปรอิสระมากกว่าสองตัวมีความสัมพันธ์กันเองในระดับสูง (H. Yu et al., 2023) ซึ่งส่งผลให้เกิดความคลาดเคลื่อนในการทำนายโอกาสของการเกิดดินถล่มในแบบจำลอง ปัญหาดังกล่าวสามารถแก้ไขได้โดยวิเคราะห์ค่า variance inflation factor (VIF) และ tolerance (TOL) เป็นวิธีการเพื่อกำจัดปัญหาภาวะร่วมของตัวแปรในตัวแบบเส้นตรงโดยการทดสอบความสัมพันธ์ระหว่างตัวแปรอิสระ แสดงการคำนวณค่า VIF ในสมการที่ 1

$$VIF_i = \frac{1}{1-R_i^2} \quad (1)$$

$$TOL_i = 1 - R_i^2 \quad (2)$$

โดย VIF คือ variance inflation factor สำหรับตัวแปรที่  $i^{th}$  และ  $R_i^2$  คือ ค่าสัมประสิทธิ์แสดงการตัดสินใจ ( $R^2$ ) ของตัวแปร  $i^{th}$  โดยทั่วไปค่า VIF ที่ยอมรับได้น้อยกว่า 10 และ TOL มากกว่า 0.10 (Bui et al., 2011) โดยตัวแปรอิสระที่มีค่ามากกว่า 10 อาจเกิดปัญหาภาวะร่วมของตัวแปรในตัวแบบเส้นตรงได้ ปัจจัยที่ผ่านการคัดเลือกจะถูกนำไปเป็นตัวแปรสำหรับสอนแบบจำลอง ML เพื่อประเมินความอ่อนไหวต่อการเกิดดินถล่มในพื้นที่ศึกษา

### 3.4 แบบจำลอง boosting ensemble สำหรับประเมินความอ่อนไหวต่อการเกิดดินถล่ม

#### 3.4.1 แบบจำลอง adaptive boosting (ADA)

ADA เป็นแบบจำลองพื้นฐานของ boosting method โดยพื้นฐาน ADA นำเสนอโดย Freund and Schapire (1997) เป็นการรวม weak learner จำนวนหลายตัวเข้าด้วยกันเพื่อสร้างเป็น strong learner โดยในแต่ละการสร้าง weak learner จะมีการปรับแก้ค่าถ่วงน้ำหนักเพิ่มขึ้นในทุกรอบการวนซ้ำเมื่อมีการจำแนกข้อมูลการเกิดดินถล่มผิด (misclassified) เกิดขึ้นในทางกลับกันจะปรับลดค่าถ่วงน้ำหนักเมื่อสามารถจำแนกข้อมูลการเกิดดินถล่ม correctly classified โดยในแต่ละรอบจะมีการสร้าง weak learner และสุดท้ายจึงนำมารวมกันกลายเป็น strong learner มีแนวคิดเบื้องหลังการเพิ่มหรือลดค่าถ่วงน้ำหนัก โดยกระบวนการนี้จะวนซ้ำหลายรอบเพื่อเพิ่มประสิทธิภาพของการทำนายในแต่ละรอบให้ดีขึ้น

#### 3.4.2 แบบจำลอง gradient boosting (GB)

GB เป็นแบบจำลองที่ได้รับความนิยมอย่างแพร่หลาย ถูกนำมาใช้ในหลากหลายงาน (Aydin & Iban, 2023; Rong et al., 2020) สามารถใช้กับงาน regression และ classification โดยหลักการของ GB คือการรวบรวม weak learner หลาย ๆ ตัวเข้าด้วยกันกลายเป็น strong learner ซึ่งเป็นพื้นฐานของอัลกอริทึมแบบ boosting แต่ GB มุ่งเน้นไปที่การเรียนรู้จากความคลาดเคลื่อน (error) ในรอบก่อนหน้าจากนั้นจึงปรับแก้ให้เหมาะสมเพื่อเพิ่มประสิทธิภาพและลดความคลาดเคลื่อนที่เกิดขึ้น ซึ่งกระบวนการนี้จะเกิดการวนซ้ำหลายรอบจนกว่าจะไม่สามารถเพิ่มประสิทธิภาพได้อีก โดยวิธีนี้ช่วยให้แบบจำลอง GB มีประสิทธิภาพและความแม่นยำสูงสุด

#### 3.4.3 แบบจำลอง eXtreme gradient boosting (XGB)

XGB ได้รับการพัฒนาต่อยอดมาจาก GB หลักการทำงานคล้ายคลึงกันคือการสร้าง weak learner หลายตัวมารวมกันกลายเป็น strong learner โดยจะเรียนรู้จากค่าความคลาดเคลื่อนในรอบก่อนหน้าและปรับแก้ค่าดังกล่าวเพื่อลดความคลาดเคลื่อนลง โดยจุดเด่นของ XGB คือสามารถรับมือกับข้อมูลขนาดใหญ่ได้ดีกว่า GB และสามารถเรียนรู้ได้รวดเร็ว ในทางกลับกัน XGB ใช้ทรัพยากรน้อยกว่า GB และสามารถปรับใช้ GPU ในการประมวลผลข้อมูล โดยในปัจจุบัน XGB เป็นแบบจำลองที่นิยมใช้อย่างแพร่หลายและประสิทธิภาพสูง (Inan & Rahman, 2023)

### 3.5 ค่า hyperparameter ของแบบจำลอง

แบบจำลองการเรียนรู้เครื่องแต่ละแบบจำลองจำเป็นต้องทดสอบ hyperparameter เพื่อหาค่าที่เหมาะสมในการสอนแบบจำลองและให้ประสิทธิภาพที่ดีที่สุด แบบจำลองแต่ละแบบจำลองจะมีชุดของค่า hyperparameter ที่แตกต่างกัน อีกทั้งการสอนแบบจำลองกับชุดข้อมูลที่แตกต่างกันไม่สามารถใช้ค่า hyperparameter ชุดเดียวกันได้ ค่า hyperparameter ที่ต้องทดสอบของแต่ละแบบจำลองแสดงในตารางที่ 1

**ตารางที่ 1**

ค่า *hyperparameter* ของแต่ละแบบจำลอง

ML models	Hyperparameters
ADA	n_estimators, learning_rate, algorithm
GB	n_estimators, max_depth, min_samples_leaf, min_samples_split, learning_rate
XGB	booster, eta, max_depth, subsample, colsample_bytree

**3.6 ค่าสถิติสำหรับการวัดประสิทธิภาพของผลลัพธ์**

ในการตรวจสอบประสิทธิภาพของแบบจำลองทำนายดินถล่มนั้นมีความสำคัญเนื่องจากสามารถช่วยสะท้อนประสิทธิภาพของแบบจำลองได้เป็นอย่างดี โดยในการประเมินค่าความถูกต้องเป็นชุดของค่าสถิติที่คิดคำนวณจากค่า true positive (TP), true negative (TN), false positive (FP), false negative (FN) ดังตารางที่ 2 ได้แก่ precision คำนวณจากค่า TP และ FP ใช้วัดสัดส่วนของผลลัพธ์ที่ได้รับการจำแนกได้ตรงตามคลาส recall คำนวณจาก TP และ FN ซึ่งเป็นค่าวัดความถูกต้องของสัดส่วนของพื้นที่ดินถล่มที่ถูกประเมินว่าเป็นดินถล่มจริง overall accuracy (OA) แสดงถึง ผลรวมของสัดส่วนพื้นที่ที่เกิดดินถล่มและไม่เกิดดินถล่มที่จำแนกได้ถูกต้อง F1-score เป็นค่าเฉลี่ยแบบ harmonic (Sokolova et al., 2006) ซึ่งมักถูกใช้เพื่อประเมินประสิทธิภาพของแบบจำลองการเรียนรู้ด้วยเครื่อง ซึ่งเป็นสัดส่วนระหว่างค่า precision และ recall ดังสมการที่ 3-5 โดยชุดของค่าสถิติข้างต้นมีค่าระหว่าง 0 ถึง 1

**ตารางที่ 2**

ตารางแมทริกซ์ความสับสน (*confusion matrix*)

	Predicted Positive (1)	Predicted Negative (0)
Actual positive (1)	TP	FN
Actual negative (0)	FP	TN

$$Precision = \frac{TP}{TP+FP} \tag{3}$$

$$Recall = \frac{TP}{TP+FN} \tag{4}$$

$$F1 - score = \frac{(Precision \times Recall)}{(Precision+ Recall)} \tag{5}$$

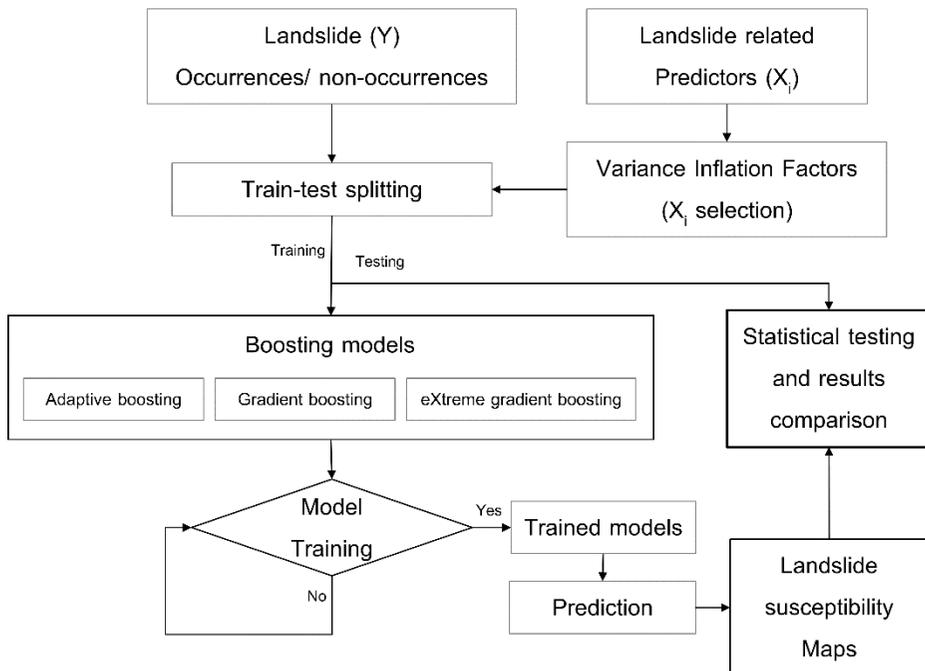
$$OA = \frac{TP+TN}{TP+TN+FP+FN} \tag{6}$$

การวัดประสิทธิภาพของแบบจำลอง ML นิยมใช้ receiver operating characteristic curve (ROC-curve) โดยเฉพาะอย่างยิ่งในบริบทของการจำแนกแบบสองค่า (binary classification) ที่สามารถสะท้อนถึงประสิทธิภาพของแบบจำลองได้เป็นอย่างดี (Muschelli, 2020) เป็นการหาความสัมพันธ์ระหว่าง true positive rate (TPR) ซึ่งอธิบายส่วนที่แบบจำลองทำนายพื้นที่เสี่ยงต่อการเกิดดินถล่มได้ถูกต้อง และ false positive rate (FPR) อธิบายส่วนที่แบบจำลองทำนายพื้นที่ไม่เสี่ยงต่อการเกิดดินถล่มได้ถูกต้อง

การประมวลผลงานวิจัยใช้ระบบปฏิบัติการ Windows 10 (educational license) โดยมีทรัพยากรประมวลผล Intel Xeon CPU-E5 2696 V2 2.50 GHz (24 cores, 48 threads) Ram 64 GB และ GPU Nvidia GeForce GTX1080Ti 11 GB ใช้ซอฟต์แวร์รหัสเปิด (Python) และ library ที่เกี่ยวข้อง เช่น Scikit-learn, GDAL และ Geo-Pandas สำหรับสอนแบบจำลองการเรียนรู้ของเครื่อง โดยมีแผนผังขั้นตอนการทำงานดังแผนภาพที่ 2

## แผนภาพที่ 2

แผนผังขั้นตอนการทำงาน



## 4. ผลการศึกษา

### 4.1 ภาวะร่วมของตัวแปรในตัวอย่างแบบเส้นตรงและการคัดเลือกตัวแปรอิสระ

ปัจจัยที่ส่งผลให้เกิดดินถล่มทั้งหมดจะถูกคัดเลือกด้วยกระบวนการ variance inflation factor (VIF) และ tolerance (TOL) เพื่อลดอิทธิพลที่ตัวแปรอิสระมากกว่า 2 ตัว มีความสัมพันธ์กันเอง การทดสอบจะคัดเลือกปัจจัยที่เหมาะสมสำหรับการสร้างแบบจำลองเพื่อทำนายพื้นที่อ่อนไหวต่อการเกิดดินถล่มด้วย VIF ซึ่งปัจจัยทุกตัวที่ถูกคัดเลือกต้องผ่านเกณฑ์โดยมีค่าน้อยกว่า 5 และค่า TOL มากกว่า 0.10 ปัจจัยที่ผ่านการคัดเลือกเข้าสู่แบบจำลองมีจำนวนทั้งหมด 9 ปัจจัย ดังแสดงในตารางที่ 3

### ตารางที่ 3

ตารางแสดงการคัดเลือกปัจจัยด้วยวิธีการ VIF และ TOL (Y = Yes และ N = No)

Factor	VIF	TOL	Selection
DEM	4.94	0.20	Y
TRI	27.23	0.04	N
TWI	12.06	0.08	N
Slope	4.40	0.22	Y
Aspect	3.32	0.30	Y
NDVI	541.88	0.00	N
NDWI	585.15	0.00	N
Curvature	1.03	0.96	Y
SPI	1.05	0.94	Y
Distance from fault	4.70	0.21	Y
Distance From trans	2.85	0.35	Y
Distance from stream	2.77	0.35	Y
Soil	20.77	0.05	N
Geology	4.25	0.23	Y

จากตารางที่ 3 ปัจจัยที่ผ่านการคัดเลือกเพื่อนำไปวิเคราะห์ร่วมกับแบบจำลองเรียนรู้เครื่องทั้ง 3 ชนิด มี 9 ปัจจัย ดังต่อไปนี้ แบบจำลองความสูงภูมิประเทศ (digital elevation model) ความลาดชัน (slope) ทิศทางลาดเขา (aspect) ความโค้ง (curvature) ดัชนีพลังงานกระแส น้ำ (SPI) ระยะห่างจากรอยเลื่อน (distance from fault) ระยะห่างจากลำน้ำ (distance from stream) ระยะห่างจากเส้นทางขนส่ง (distance from trans) และประเภทของธรณีวิทยา (geology)

## 4.2 ผลการทดสอบ hyperparameters

ทดสอบหาชุด hyperparameter ที่ดีที่สุดของแต่ละแบบจำลองด้วยการสอนแบบจำลองด้วย hyperparameter ครั้งละตัว ให้ค่า hyperparameter ตัวอื่นเป็นค่าตั้งต้น (default value) ของอัลกอริทึม วนทำจนครบทุกค่า เลือกค่าจากชุด parameter ที่ดีที่สุด แสดงผลในตารางที่ 4

### ตารางที่ 4

ตารางแสดง hyperparameter ที่ดีที่สุดของแต่ละแบบจำลอง

Models	Hyperparameters	Value / Method
ADA	algorithm	SAMME.R
	learning_rate	0.01
	n_estimators	1000
GB	learning_rate	0.05
	max_depth	10
	n_estimators	900
	min_samples_split	5
	min_samples_leaf	1
XGB	booster	gbtree
	eta	0.1
	max_depth	9
	subsample	0.8
	colsample_bytree	1

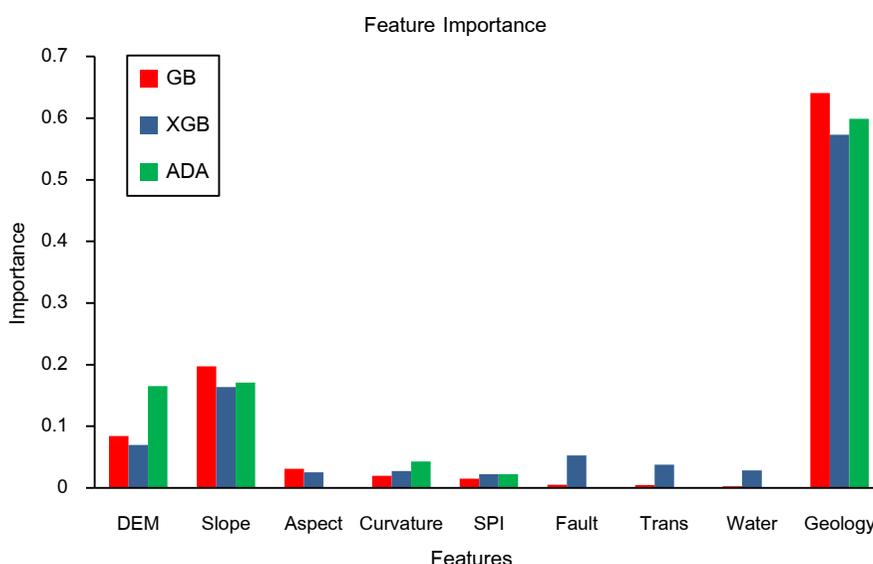
จากตารางที่ 4 hyperparameter ที่ดีที่สุดของแบบจำลอง ADA ได้แก่ n\_estimators = 300 learning\_rate = 0.01 และ algorithm = SAMME ในขณะที่ GB มีค่า n\_estimators = 300 max\_depth = 10 min\_samples\_split = 2 min\_samples\_leaf = 2 และ learning\_rate = 0.1 ส่วนแบบจำลอง XGB ให้ชุด hyperparameter ที่ดีที่สุด ประกอบด้วย booster = gbtree eta = 0.1 max\_depth = 5 subsample = 0.9 และ colsample\_bytree = 0.7 โดยชุด hyperparameter กลุ่มนี้จะถูกใช้เป็นค่าสำหรับฝึกสอนของแบบจำลอง ML

### 4.3 ความสำคัญของปัจจัยที่ส่งผลต่อความอ่อนไหวของการเกิดดินถล่ม

ในการศึกษาปัจจัยที่เกี่ยวข้องของต่อดินถล่มนั้น งานวิจัยนี้ได้จัดเรียงลำดับความสำคัญด้วยวิธี feature importance แสดงให้เห็นว่าแบบจำลองแต่ละประเภทให้ความสำคัญกับปัจจัยไหนมากน้อยตามลำดับในการเรียนรู้ข้อมูลเพื่อสร้างเป็นแบบจำลองความอ่อนไหวต่อการเกิดดินถล่มขึ้นมา โดยลำดับความสำคัญแสดงในแผนภาพที่ 3

แผนภาพที่ 3

ลำดับความสำคัญของปัจจัยในแต่ละแบบจำลอง (GB สีแดง XGB สีน้ำเงิน และ ADA สีเขียว ตามลำดับ)



แผนภาพที่ 3 แสดงความสำคัญของตัวแปรสำหรับการทำนายของสามแบบจำลองการเรียนรู้เครื่อง ADA GB และ XGB จากปัจจัยที่ส่งผลต่อการเกิดดินถล่มทั้งหมด 9 ปัจจัย โดยการวัดว่าตัวแปรแต่ละตัวมีส่วนในการทำนายมากน้อยเพียงใด ซึ่งเป็นสัดส่วนจำนวนเต็มหนึ่งอธิบายความสำคัญของปัจจัยในแต่ละแบบจำลองเรียงตามลำดับ ดังนี้

แบบจำลอง GB (สีแดง) แสดงให้เห็นว่าปัจจัยธรณีวิทยาให้ความสำคัญสูงสุด มีบทบาทสำคัญในการทำนายของแบบจำลองนี้ ความลาดชันมีความสำคัญสูงเป็นอันดับสอง ความสูงภูมิประเทศเชิงเลขมีความสำคัญปานกลาง ระยะห่างจากรอยเลื่อนมีความสำคัญน้อยที่สุดในแบบจำลองนี้ แต่ยังคงมีส่วนในการทำนาย ทิศทางลาดเขา ความโค้งงอของภูมิประเทศ ดัชนีพลังของกระแสน้ำ ระยะทางจากเส้นทางขนส่ง และระยะทางจากเส้นทางน้ำ มีความสำคัญน้อยมากถึงน้อยที่สุด

แบบจำลอง XGB (สีน้ำเงิน) ให้ปัจจัยธรณีวิทยามีความสำคัญสูงสุดเช่นเดียวกับแบบจำลอง GB ที่ให้ธรณีวิทยาเป็นปัจจัยที่มีอิทธิพลหลัก ความลาดชัน มีความสำคัญสูงเป็นอันดับสองในการทำนาย ความสูงภูมิประเทศเชิงเลขมีความสำคัญปานกลาง ระยะห่างจากรอยเลื่อนมีความสำคัญปานกลางถึงน้อย บ่งบอกว่ารอยเลื่อนมีบทบาทในการทำนายแต่ไม่เด่นชัดเท่าปัจจัยอื่น ทิศทางลาดเขา ความโค้งของภูมิประเทศ ดัชนีพลังของกระแสน้ำ ระยะทางจากเส้นทางขนส่ง และระยะทางจากเส้นทางน้ำ มีความสำคัญน้อยมากถึงน้อยที่สุด

ผลการทดสอบความสำคัญของปัจจัยจากแบบจำลอง ADA (สีเขียว) บ่งบอกถึงปัจจัยด้านธรณีวิทยามีความสำคัญสูงสุดเช่นเดียวกับสองแบบจำลองก่อนหน้า ย้ำถึงบทบาทหลักของธรณีวิทยาในการทำนาย ความลาดชัน มีความสำคัญสูงเป็นอันดับสอง แสดงถึงบทบาทสำคัญของความลาดชันและความสูงภูมิประเทศเชิงเลขมีความสำคัญปานกลางถึงน้อย ทิศทางลาดเขา ระยะห่างจากรอยเลื่อนมีความสำคัญน้อยกว่าระดับความสูงเชิงเลข แต่มีความสำคัญน้อยในการทำนาย ความโค้งของภูมิประเทศ ดัชนีพลังของกระแสน้ำ ระยะทางจากเส้นทางขนส่ง และระยะทางจากเส้นทางน้ำ มีความสำคัญน้อยมากถึงน้อยที่สุด

#### 4.4 เปรียบเทียบประสิทธิภาพของแต่ละแบบจำลองในการประเมินความอ่อนไหวต่อการเกิดดินถล่ม

งานวิจัยนี้เปรียบเทียบประสิทธิภาพของแต่ละแบบจำลองการจำแนกประเภททั้ง 3 ด้วยวิธีการ 5 ประเภท ดังต่อไปนี้ precision, recall, F1-score, accuracy และการประเมินค่า ROC-AUC จากกราฟ ROC Curve ผลลัพธ์จากการประเมินประสิทธิภาพของแต่ละแบบจำลองแสดงในตารางที่ 5 และแผนภาพที่ 4

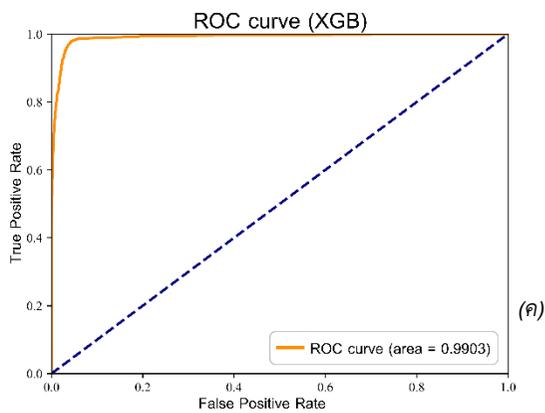
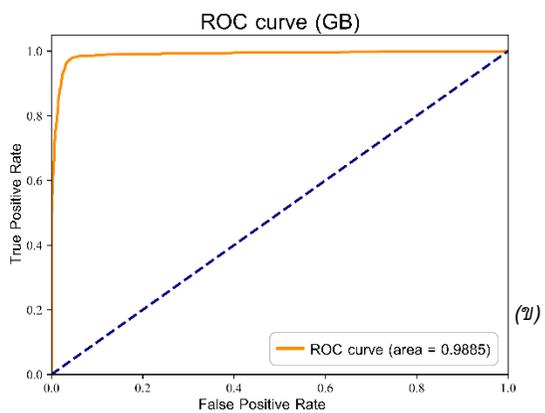
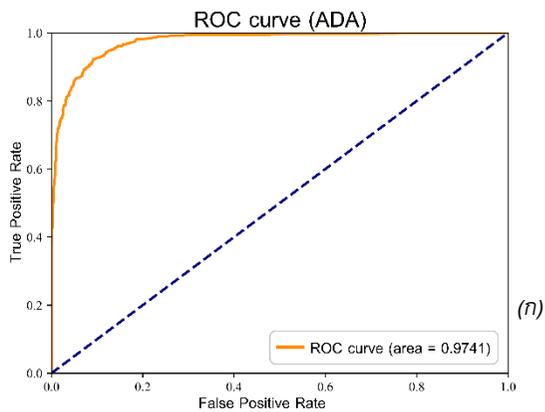
#### ตารางที่ 5

ตารางเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยค่า precision, recall, F1-score และ accuracy

Models	Precision	Recall	F1-Score	Accuracy
ADA	0.9240	0.8943	0.9089	0.9108
GB	0.9718	0.9611	0.9664	0.9667
XGB	0.9612	0.9707	0.9659	0.9656

แผนภาพที่ 4

ผลการทดสอบค่า ROC จากแบบจำลองทั้งสามแบบจำลอง (ก) ADA (ข) GB และ (ค) XGB ตามลำดับ



จากตารางที่ 5 เปรียบเทียบประสิทธิภาพของแบบจำลอง ในแต่ละค่าสามารถสรุปได้ดังต่อไปนี้

การทดสอบค่า precision พบว่าแบบจำลอง GB มีค่าสูงสุดที่ 0.9718 รองลงมาเป็นแบบจำลอง XGB มีค่าที่ 0.9612 และค่าที่ต่ำที่สุด คือ แบบจำลอง ADA มีค่าที่ 0.9240

ในส่วนของคุณค่า recall พบว่าแบบจำลอง XGB มีค่าสูงสุดที่ 0.9707 รองลงมาเป็นแบบจำลอง GB มีค่าที่ 0.9611 และค่าที่ต่ำที่สุด คือ แบบจำลอง ADA มีค่าที่ 0.8940

เมื่อพิจารณา F1-score พบว่าแบบจำลอง GB มีค่าสูงสุดที่ 0.9664 รองลงมาเป็นแบบจำลอง XGB มีค่าที่ 0.9659 และค่าที่ต่ำที่สุด คือ แบบจำลอง ADA มีค่าที่ 0.9080

การตรวจสอบค่า accuracy พบว่าแบบจำลอง GB มีค่าสูงสุดที่ 0.9667 รองลงมาเป็นแบบจำลอง XGB มีค่าที่ 0.9656 และค่าที่ต่ำที่สุด คือ แบบจำลอง ADA มีค่าที่ 0.9100 การประเมินค่า ROC-AUC จากกราฟ ROC Curve แสดงดังภาพที่ 3 (ก) - 3 (ค)

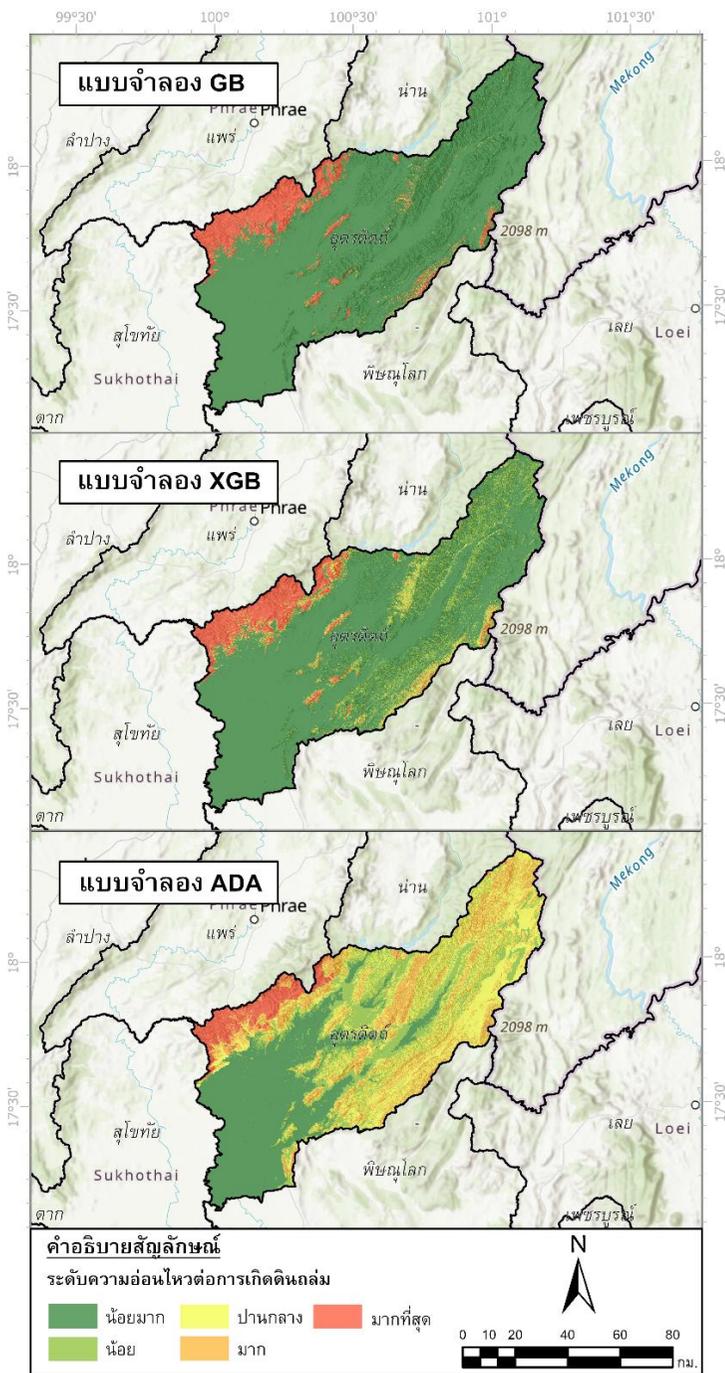
ผลจากการประเมินค่า ROC-AUC จากกราฟ ROC Curve ของทั้ง 3 แบบจำลอง พบว่า แบบจำลอง XGB มีพื้นที่ใต้กราฟสูงที่สุด คือ 0.9903 รองลงมา คือ แบบจำลอง GB มีค่าพื้นที่ใต้กราฟ 0.9885 และแบบจำลอง ADA มีค่าพื้นที่ใต้กราฟน้อยที่สุด คือ 0.9741

#### 4.5 ผลการประเมินความอ่อนไหวต่อการเกิดดินถล่มจากสามแบบจำลอง

ผลของการประเมินความอ่อนไหวต่อการเกิดดินถล่มนั้น จะถูกแบ่งออกเป็น 5 ระดับชั้นตามค่าความอ่อนไหว ได้แก่ น้อยมาก (very low) น้อย (low) ปานกลาง (moderate) สูง (high) สูงมาก (very high) โดยค่าความอ่อนไหวถูกแบ่งโดยวิธีแบบ natural breaks (Jenks) (Wu et al., 2020) แสดงผลการประเมินความอ่อนไหวต่อการเกิดดินถล่มจากสามแบบจำลองในแผนภาพที่ 5

### แผนภาพที่ 5

แผนที่ความอ่อนไหวต่อการเกิดดินถล่มจากแบบจำลอง GB, XGB และ ADA



จากแผนที่แสดงระดับความอ่อนไหวต่อการเกิดดินถล่มของทั้ง 3 แบบจำลอง สามารถสรุปได้ว่าแต่ละแบบจำลองแสดงผลพื้นที่ความอ่อนไหวตามระดับ แบ่งเป็น 5 ระดับ ได้แก่ น้อยมาก น้อย ปานกลาง มาก และมากที่สุด ดังแสดงในตารางที่ 6

**ตารางที่ 6**

ร้อยละของระดับความอ่อนไหวต่อการเกิดดินถล่มต่อพื้นที่ทั้งหมด (ตารางกิโลเมตร) ในแต่ละแบบจำลอง

แบบจำลอง	น้อยมาก	น้อย	ปานกลาง	มาก	มากที่สุด
ADA	30.2750	17.5392	28.4815	17.9023	5.8020
GB	87.3820	1.1113	0.6565	0.6995	10.1506
XGB	74.4835	11.1351	3.5624	2.4794	8.3395

ตารางที่ 6 ข้อมูลจากสามแบบจำลอง ได้แก่ ADA GB และ XGB ซึ่งแสดงผลพื้นที่ที่แตกต่างกันสำหรับแต่ละระดับความอ่อนไหว 1) แบบจำลอง ADA มีการกระจายพื้นที่มากที่สุด ในระดับความอ่อนไหวน้อยมากและปานกลาง โดยพื้นที่ในความอ่อนไหวระดับมากที่สุดมีน้อยที่สุด 2) สำหรับแบบจำลอง GB พื้นที่ส่วนใหญ่คาดการณ์ว่าอยู่ในความอ่อนไหวระดับน้อยมาก โดยมีพื้นที่ความอ่อนไหวมากที่สุดอยู่ร้อยละ 10.1506 (มีขนาดพื้นที่มากที่สุด) 3) แบบจำลอง XGB มีการกระจายพื้นที่ที่หลากหลายมากที่สุด ความอ่อนไหวส่วนใหญ่ยังคงอยู่ในระดับน้อยมาก โดยรวมแล้วแบบจำลองแต่ละแบบมีการกระจายความอ่อนไหวต่อการเกิดดินถล่มที่แตกต่างกัน โดย ADA มีแนวโน้มความอ่อนไหวไปในระดับน้อยมากและปานกลาง GB มีแนวโน้มความอ่อนไหวในระดับน้อยมากและมากที่สุด ส่วน XGB มีลักษณะความอ่อนไหวคล้ายคลึงกับ GB โดยมีแนวโน้มความอ่อนไหวในระดับน้อยมากและมากที่สุด โดยเฉพาะพื้นที่ความอ่อนไหวระดับน้อยมากคิดเป็นพื้นที่สามในสี่ของจังหวัด แต่ในช่วงความอ่อนไหวระดับปานกลางจะมีค่าที่สูงกว่า GB

**5. อภิปรายผล**

**5.1 ลักษณะธรณีวิทยาของพื้นที่ศึกษาที่ส่งผลต่อการเกิดดินถล่ม**

บริเวณด้านตะวันตกของจังหวัดมีลักษณะเป็นกลุ่มหินราชบุรี ซึ่งเป็นหินประเภท หินคาบอร์เน็ตหรือจำพวกหินปูน ได้รับอิทธิพลมาจากรอยเลื่อนเถิน ที่พาดผ่านบริเวณจังหวัดแพร่ ซึ่งคือตอนเหนือของกลุ่มหินราชบุรี ทำให้เกิดการผุพังของชั้นหินและส่งผลให้เกิดดินถล่มได้ ซึ่งจากงานวิจัยนี้พบว่า ตำแหน่งที่เกิดดินถล่มในอดีตเกิดบนกลุ่มหินราชบุรีไปแล้วร้อยละ 62.54 จากทั้งพื้นที่ศึกษา จึงสามารถสรุปได้ว่าพื้นที่ด้านตะวันตกของจังหวัดที่เกิดเหตุการณ์

ดินถล่มหลายครั้งในอดีต ได้รับอิทธิพลมาจากรอยเลื่อนเถินที่ส่งผลต่อความผูกพันของหินปูน นอกจากนี้เนินเขาหรือหุบเขาที่มีโครงสร้างถูกแยกออกอย่างละเอียดและได้รับอิทธิพลจากรอยเลื่อนเหล่านี้ เผยให้เห็นชั้นหินที่อยู่ข้างใต้ ส่งผลให้เกิดความหนาแน่นของการระบายน้ำสูงในพื้นที่ ทำให้น้ำส่วนเกินสามารถไหลลงไปตามรอยแยกของชั้นหินพื้นฐานและเข้าสู่เขตที่ไม่มั่นคง ซึ่งเป็นสาเหตุให้เกิดดินถล่ม พื้นที่ที่อยู่ใกล้กับรอยเลื่อนประสมกับสถานการณ์คล้ายกัน จึงมีความสำคัญเป็นพิเศษ ดังนั้นสามารถสรุปได้ว่ายิ่งพื้นที่ที่อยู่ใกล้รอยเลื่อนมากเท่าใด ความอ่อนไหวต่อการเกิดดินถล่มก็ยิ่งสูงขึ้นเท่านั้น (Jennifer, 2022)

ช่วงตอนกลางของจังหวัด เป็นลักษณะของกลุ่มหินคาร์บอนิเฟอรัสประเภทหินแกรนิต เป็นจุดที่เกิดดินถล่มในอดีตน้อย แต่แบบจำลองแสดงให้เห็นว่ามีระดับความเสี่ยงที่สูงมาก สาเหตุเกิดจากการผูกพันหลายของหินแกรนิต ซึ่งได้รับอิทธิพลจากรอยเลื่อนบริเวณตอนกลางของจังหวัด และเนื่องจากบางพื้นที่มีการแทรกซอนของหินแกรนิต จึงทำให้เกิดการเปลี่ยนแปลงทางเคมีและชั้นหินผูกพัน วัสดุที่เกิดจากการผูกพันประกอบด้วยดินเหนียวปนทราย อันเกิดจากการผูกพันของแร่เฟลด์สปาร์และควอตซ์ซึ่งเป็นแร่ประกอบหลักในหินแกรนิต (กรมทรัพยากรธรณี, 2551) ชั้นดินเหล่านี้มีความหนาเฉพาะที่ เมื่อรวมกับชั้นหินที่มีมุมเอียงสูงชัน ทำให้น้ำไหลซึมผ่านชั้นหินได้ง่ายขึ้น ส่งผลให้ชั้นดินเกิดการเคลื่อนตัวลงมาได้ง่าย บริเวณดังกล่าวจึงมีความเสี่ยงสูง ทั้งที่จุดเกิดดินถล่มมีไม่มากนัก

ด้านบริเวณทางตะวันตกเฉียงใต้ ที่เกิดร่องรอยดินถล่มในอดีต เป็นหินประเภทหินตะกอนทรายที่เกิดขึ้นช่วงมหายุคมีโซโซอิก ในยุคจูแรสซิก และครีเทเชียสซึ่งเป็นชั้นหินมีอายุมากและเกิดการผูกพัน จากการซ้อนทับกับรอยเลื่อนมีพลัง จึงทำให้มีโอกาสเกิดดินถล่มขณะเดียวกันในส่วนของบริษัทตอนกลางที่มีรอยเลื่อนมีพลังพาดผ่าน ชั้นตะกอน กรวด ทราย และศิลาแลงของแม่น้ำคิ่นพลัง (rejuvenated river) เป็นส่วนที่ไม่มีร่องรอยดินถล่ม เนื่องจากชั้นหินตะกอนนี้เกิดจากการพัดพาของแม่น้ำ ทำให้เกิดเป็นชั้นตะกอนที่เกิดขึ้นมาทีหลัง

## 5.2 ความเหมาะสมของปัจจัยที่ส่งผลต่อการเกิดดินถล่ม

การเลือกปัจจัยที่มีความเกี่ยวข้องนั้นมีความสำคัญอย่างยิ่งต่อการประเมินพื้นที่อ่อนไหวต่อการเกิดดินถล่มในขั้นตอนของการเรียนรู้เครื่อง ปัจจัยบางตัวช่วยให้การทำนายออกมาแม่นยำ ในทางกลับกันหากปัจจัยดังกล่าวไม่มีความสำคัญต่อการเกิดแผ่นดินถล่ม อาจส่งผลกระทบต่อประสิทธิภาพของแบบจำลองได้ โดยในการศึกษาค้างนี้มีปัจจัยที่ผ่านการวิเคราะห์ VIF ซึ่งเป็นการทดสอบภาวะร่วมของตัวแปรในตัวแบบเส้นตรง และการคัดเลือกตัวแปรอิสระ โดยที่ VIF น้อยกว่า 5 และ TOL มากกว่า 0.10 (Bui et al., 2011) ในการอธิบายความมีนัยสำคัญของปัจจัยที่มีผลต่อการทำนายของแบบจำลองนั้น ทำได้โดยการศึกษาค่าความสำคัญของปัจจัยในแต่ละแบบจำลอง แผนภาพที่ 7 แสดงให้เห็นค่าความสำคัญของแต่ละปัจจัยโดยแบ่งตามชนิดของแบบจำลอง พบว่าปัจจัยธรณีวิทยานั้น

แบบจำลองทั้งสามให้ความสำคัญสูงสุด ซึ่งสะท้อนถึงความสำคัญของสภาพธรณีวิทยาต่อการเกิดดินถล่ม เนื่องจากธรณีวิทยาอาจมีผลต่อความเสถียรของดินและการเคลื่อนที่ของดิน (X. Yu et al., 2021) รองลงมาคือความลาดชัน แบบจำลองทุกแบบให้ความสำคัญที่ค่อนข้างสูง โดยความลาดชันเป็นตัวบ่งชี้ถึงความเสี่ยงในการเกิดดินถล่มเนื่องจากแรงโน้มถ่วงส่งผลให้ดินมีแนวโน้มที่จะเคลื่อนตัวลงในพื้นที่ที่มีความชันมาก และความสูงภูมิประเทศเชิงเลขแม้จะมีความสำคัญน้อยแต่มีบทบาทในการกำหนดลักษณะภูมิประเทศที่สามารถเอื้อต่อการเกิดดินถล่มได้ในส่วนของปัจจัยอื่น ๆ ได้แก่ มุมรับแสงอาทิตย์ ความโค้ง ดัชนีพลังงานน้ำ รอยเลื่อน เส้นทางการขนส่ง (ถนน) และเส้นทางของแม่น้ำ มีความสำคัญที่ต่ำในแบบจำลองทั้งหมด บ่งชี้ว่าปัจจัยเหล่านี้มีบทบาทน้อยหรือไม่มีบทบาทในการทำนายความเสี่ยงการเกิดดินถล่มในพื้นที่ศึกษา ดังนั้นพิจารณาความสำคัญของปัจจัยในแต่ละแบบจำลอง จะพบว่าแบบจำลอง XGB และ GB ให้ความสำคัญกับทุกปัจจัย (แผนภาพที่ 2) จึงทำให้มีประสิทธิภาพในการทำนายสูง เนื่องจากสามารถจัดการกับปัจจัยหลายอย่างที่มีผลต่อการเกิดดินถล่มได้ดี ในทางกลับกัน แบบจำลอง ADA ให้ความสำคัญกับปัจจัยเพียง 5 ปัจจัยเท่านั้น ได้แก่ ธรณีวิทยา แบบจำลองความสูงภูมิประเทศ ความลาดชัน ความโค้ง และดัชนีพลังงานน้ำ ส่งผลให้ประสิทธิภาพในการทำนายลดลงเนื่องจากการใช้ปัจจัยในการพิจารณาที่จำกัดกว่า

### 5.3 ประสิทธิภาพของแบบจำลอง

จากการแบ่งการจำแนกค่าด้วยวิธี natural breaks (Jenks) เพื่อแบ่งระดับความเสี่ยงต่อความอ่อนไหวที่จะเกิดดินถล่ม โดยแบ่งตามค่าที่ทำนายมาได้ของแบบจำลองเป็น 5 ระดับ แบบจำลอง ADA มีความแตกต่างจากแบบจำลองอื่นโดยช่วงค่าที่กว้างกว่าสำหรับระดับความอ่อนไหวน้อยและแคบกว่าสำหรับค่าระดับที่มากกว่า เนื่องจาก ADA ปรับน้ำหนักของตัวอย่างที่จำแนกผิดได้ดี ส่งผลให้มีการแยกแยะที่ละเอียดมากขึ้น ระหว่างความอ่อนไหวระดับน้อย ปานกลาง และสูง เป็นเหตุผลการจำแนกช่วงความอ่อนไหวมีความแตกต่างจากแบบจำลองอื่น ในขณะที่ GB และ XGB มีการแบ่งค่าในระดับดังกล่าวเป็นช่วงแคบกว่า ADA และมีค่าการกระจายของระดับความอ่อนไหวที่มีความสม่ำเสมอซึ่งเป็นผลจากวิธีการปรับค่าการทำนายและการเพิ่มประสิทธิภาพที่ใช้ในแบบจำลองเหล่านี้ แบบจำลองแต่ละแบบมีการปรับปรุงความแม่นยำในการทำนาย เช่น แบบจำลอง ADA จะให้ความสำคัญกับพื้นที่ที่ตัวจำแนกรูปก่อนหน้าให้ผลลัพธ์ที่มีค่าคลาดเคลื่อนสูง ส่งผลให้มีการกระจายค่าที่ต่างกัน เนื่องจากระบวนการปรับน้ำหนักซ้ำ ส่งผลให้มีการจำแนกที่ละเอียดในบางช่วงความอ่อนไหวเท่านั้น

เมื่อเปรียบเทียบกับวิธีการทำนายความอ่อนไหวต่อการเกิดดินถล่มแบบดั้งเดิม การใช้อัลกอริทึมการเรียนรู้เครื่องสามารถเพิ่มความแม่นยำในการทำนาย (Akgun, 2012) จากการประเมินตัวชี้วัดหลายรายการ ผลการศึกษาพบว่าแบบจำลองทั้งสามสามารถทำนาย

ความอ่อนไหวต่อการเกิดดินถล่มในพื้นที่ศึกษาได้อย่างแม่นยำ ในบรรดาแบบจำลองทั้งหมดพบว่า แบบจำลอง GB และ XGB มีประสิทธิภาพสูงที่สุดเทียบกับการทดสอบทางสถิติด้วย F1-score และ OA อย่างไรก็ดี เมื่อเปรียบเทียบพื้นที่ได้กราฟ ROC พบว่าแบบจำลอง XGB ทำหน้าที่ได้ดีที่สุด สอดคล้องกับงานของ Inan and Rahman (2023) ที่ศึกษาเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง ADA กับ XGB พบว่าแบบจำลอง XGB แสดงประสิทธิภาพได้ดีที่สุด จากการทดสอบสถิติค่า F1-score นอกจากนี้ผลการวิจัย พบว่า GB และ XGB มี OA และ F1-score ใกล้เคียงกัน สอดคล้องกับงานของ Halder et al. (2024) อย่างไรก็ดี จากงานวิจัยนี้ ค่าพื้นที่ได้กราฟ ROC ของ XGB มีค่ามากกว่า GB

ในประเทศไทย Intarat et al. (2024) วิเคราะห์ความอ่อนไหวต่อการเกิดดินถล่มในพื้นที่จังหวัดเชียงใหม่ หนึ่งในจังหวัดภาคเหนือ โดยใช้แบบจำลอง ensemble ML 4 ตัว ประกอบด้วย RF, GB, XGB และ stacking พบว่าวิธีการ stacking ให้ประสิทธิภาพดีที่สุด รองลงมาคือแบบจำลอง XGB และ GB ตามลำดับ ซึ่งงานนี้สอดคล้องกันในเชิงของประสิทธิภาพของแบบจำลองและลักษณะทางกายภาพที่ใกล้เคียงกัน เนื่องจากจังหวัดอุตรดิตถ์เป็นพื้นที่ราบระหว่างหุบเขา (intermontane basin area) คล้ายคลึงกับจังหวัดเชียงใหม่ ทางด้านตะวันตกของจังหวัดอุตรดิตถ์เป็นแนวทิวเขาผีปันน้ำ ทิวเขานี้มีอิทธิพลต่อภูมิประเทศและรูปแบบการระบายน้ำของภูมิภาค ในด้านตะวันออกของจังหวัดเป็นที่ตั้งทิวเขาหลวงพระบาง ซึ่งการมีอยู่ของแม่น้ำน่านและแม่น้ำสาขาอื่น ๆ ภายในลุ่มน้ำทำให้เกิดแหล่งน้ำและแอ่งน้ำธรรมชาติระหว่างเขาอุตรดิตถ์สะสมตะกอนจากการกัดเซาะของภูเขาโดยรอบ จากตำแหน่งร่องรอยดินถล่มในอดีตสอดคล้องกับการวางตัวของทิวเขาผีปันน้ำในด้านตะวันตกและทิวเขาหลวงพระบางในด้านตะวันออก

วิธีการเรียนรู้แบบกลุ่ม (ensemble learning) ซึ่งผสมผสานตัวจำแนกหลายตัวเพื่อใช้ในการตัดสินใจ ถูกนำมาใช้มากขึ้นในการทำนายความเสี่ยงต่อการเกิดดินถล่ม การศึกษาการเปรียบเทียบงานวิจัยหลายชิ้น พบว่าวิธีการเรียนรู้เครื่องแบบ ensemble มีความแม่นยำและความแข็งแกร่งเหนือกว่าวิธีการเรียนรู้เครื่องแบบเพียงแบบจำลองเดี่ยว โดยทั่วไปแล้วเทคนิคการเรียนรู้แบบกลุ่ม สามารถให้ความแม่นยำสูงกว่าเมื่อใช้แบบจำลองแยกเป็นรายตัว ควรสำรวจและประยุกต์ใช้การรวมแบบจำลองที่หลากหลายมากขึ้นในการประเมินความอ่อนไหวต่อการเกิดดินถล่ม (Wu et al., 2020) การปรับค่าพารามิเตอร์ของแต่ละแบบจำลองเป็นปัจจัยสำคัญที่ช่วยในการพัฒนาแบบจำลองให้มีประสิทธิภาพ (Jennifer, 2022) โดยรวมแล้วประสิทธิภาพของแบบจำลองการเรียนรู้เครื่องขึ้นอยู่กับข้อมูลที่ใช้และขึ้นอยู่กับลักษณะทางกายภาพของพื้นที่ศึกษาเป็นสำคัญ (Reichenbach et al., 2018)

## 6. สรุปผลการศึกษา

แบบจำลองการเรียนรู้แบบกลุ่ม (ensemble learning models) เป็นเทคนิคที่นำมาใช้ในการพัฒนาแบบจำลองการเรียนรู้หลายแบบจำลองใน ML เพื่อเพิ่มประสิทธิภาพการทำงาน นิยมนำมาประยุกต์ใช้ในงานที่เกี่ยวข้องกับภัยธรรมชาติอย่างแพร่หลาย ด้วยการเปรียบเทียบประสิทธิภาพและหาแบบจำลองที่มีความเหมาะสมในการประเมินความอ่อนไหวต่อการเกิดดินถล่มนั้น ไม่สามารถใช้แบบจำลองที่ผ่านการเรียนรู้จากพื้นที่อื่นจึงจำเป็นต้องหาแบบจำลองที่มีประสิทธิภาพเหมาะสมกับชุดข้อมูลของพื้นที่ศึกษาโดยตรง จากผลการศึกษานี้สามารถสรุปประสิทธิภาพของแบบจำลองในกลุ่มของ boosting algorithms ได้แก่ ADA GB และ XGB ในเชิงเปรียบเทียบได้ดังต่อไปนี้ 1) เปรียบเทียบกับการทดสอบทางสถิติ ทั้งสามแบบจำลองสามารถใช้ในการประเมินความอ่อนไหวการเกิดดินถล่มได้ทั้งหมดในพื้นที่ศึกษา โดยแบบจำลองที่มีประสิทธิภาพดีที่สุดเมื่อทดสอบด้วยค่า F1-score และ OA คือ แบบจำลอง GB และ XGB อย่างไรก็ตามเมื่อทดสอบด้วยค่าพื้นที่ใต้กราฟ ROC ปรากฏว่าแบบจำลอง XGB มีประสิทธิภาพมากที่สุด มีจุดเด่นในการรับมือกับข้อมูลขนาดใหญ่ได้ดี ใช้ทรัพยากรน้อยกว่า และสามารถเรียนรู้ได้รวดเร็ว 2) เปรียบเทียบในมิติการกระจายตัวของระดับความอ่อนไหวต่อการเกิดดินถล่ม ทั้งสามแบบจำลองสามารถประเมินความอ่อนไหวต่อการเกิดดินถล่มได้คล้ายคลึงกัน เฉพาะในระดับความอ่อนไหวมากที่สุด (บริเวณอำเภอลับแล อำเภอเมือง และอำเภอท่าปลา) แต่แบบจำลอง ADA จะแตกต่างกับแบบจำลองอื่นในระดับความอ่อนไหวปานกลางถึงน้อย 3) เปรียบเทียบการให้ความสำคัญกับแต่ละปัจจัย ทั้งสามแบบจำลองให้ความสำคัญกับปัจจัยเรียงจากมากไปน้อย 3 อันดับแรก ได้แก่ ลักษณะทางธรณีวิทยา ความลาดชัน และความสูงภูมิประเทศเชิงเลข ตามลำดับ สะท้อนให้เห็นถึงความสำคัญของลักษณะทางกายภาพของพื้นที่ มีเพียงแบบจำลอง ADA เท่านั้นที่ไม่ได้ให้ความสำคัญกับทุกปัจจัย ซึ่งอาจส่งผลให้ประสิทธิภาพการประเมินพื้นที่อ่อนไหวลดลง กล่าวโดยสรุป แบบจำลอง XGB มีประสิทธิภาพและเหมาะสมมากที่สุด ตามด้วยแบบจำลอง GB และ ADA

ด้วยหลักการสร้างแบบจำลองจำเป็นต้องอาศัยข้อมูลที่เกิดขึ้นในพื้นที่ศึกษา และไม่สามารถนำแบบจำลองที่ผ่านการเรียนรู้จากพื้นที่อื่นมาใช้ร่วมกันได้ ดังนั้น ผลการศึกษาในครั้งนี้นอกจากจะหาแบบจำลองที่ดีและเหมาะสมที่สุดสำหรับการประเมินความอ่อนไหวต่อการเกิดดินถล่มในจังหวัดอุตรดิตถ์แล้ว ยังสามารถนำไปใช้ประเมินพื้นที่ที่มีโอกาสเกิดดินถล่มและใช้ในการวางแผนการปรับตัวและเตรียมความพร้อมสำหรับเหตุการณ์ที่อาจเกิดขึ้นในอนาคตต่อไป

## 7. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนการจัดตั้งหน่วยวิจัยเฉพาะทางด้านการประยุกต์เชิงพื้นที่ (คาปีบารา จีโอ แล็บ) ประจำปีงบประมาณ 2566 คณะศิลปศาสตร์ มหาวิทยาลัยธรรมศาสตร์ และทุนสนับสนุนการวิจัยประเภทพัฒนาศักยภาพผลงานวิจัย (Fast Track) จากกองทุนวิจัยคณะศิลปศาสตร์ มหาวิทยาลัยธรรมศาสตร์ คณะผู้วิจัยขอขอบคุณนายวรมรรค์ แจ่มสว่าง และนายปฏิมากร อยู่มี ที่ร่วมดำเนินงานจนบรรลุเป้าหมาย

## เอกสารอ้างอิง/References

- กรมทรัพยากรธรณี. (2551). *ธรณีวิทยาของจังหวัดอุตรดิตถ์*. จังหวัดอุตรดิตถ์  
<http://www.uttaradit.go.th>
- กรมอุตุนิยมวิทยา. (2566). ภูมิอากาศจังหวัดอุตรดิตถ์. ศูนย์ภูมิอากาศกรมอุตุนิยมวิทยา.  
<http://climate.tmd.go.th/data/province/เหนือ/ภูมิอากาศอุตรดิตถ์.pdf>
- Akinci, H., Kilicoglu, C., & Dogan, S. (2020). Random forest-based landslide susceptibility mapping in coastal regions of Artvin, Turkey. *ISPRS International Journal of Geo-Information*, 9(9), 553. <https://doi.org/10.3390/ijgi9090553>
- Akgun, A. (2012). A comparison of landslide susceptibility maps produced by logistic regression, multi-criteria decision, and likelihood ratio methods: a case study at zmir, Turkey. *Landslides*, 9(1), 93-106.
- Alizadeh, M., Hashim, M., Alizadeh, E., Shahabi, H., Karami, M., Beiranvand Pour, A., Pradhan, B., & Zabihi, H. (2018). Multi-criteria decision making (MCDM) model for seismic vulnerability assessment (SVA) of urban residential buildings. *ISPRS International Journal of Geo-Information*, 7(11), 444. <https://doi.org/10.3390/ijgi7110444>
- Aydin, H. E., & Iban, M. C. (2023). Predicting and analyzing flood susceptibility using boosting-based ensemble machine learning algorithms with SHapley Additive exPlanations. *Natural Hazards*, 116(1), 2957-2991. <https://doi.org/10.1007/s11069-022-05793-y>
- Bui, D. T., Lofman, O., Revhaug, I., & Dick, O. (2011). Landslide susceptibility analysis in the Hoa Binh province of Vietnam using statistical index and logistic regression. *Natural hazards*, 59(3), 1413-1444. <https://doi.org/10.1007/s11069-011-9844-2>
- Choi, J., Oh, H.-J., Lee, H.-J., Lee, C., & Lee, S. (2012). Combining landslide susceptibility maps obtained from frequency ratio, logistic regression, and artificial neural network models using ASTER images and GIS. *Engineering Geology*, 124, 12-23. <https://doi.org/10.1016/j.enggeo.2011.09.011>
- Guzzetti, F., Cardinali, M., Reichenbach, P., Cipolla, F., Sebastiani, C., Galli, M., & Salvati, P. (2004). Landslide hazard assessment in the Collazzone area, Umbria, Central Italy. *Natural Hazards and Earth System Sciences*, 4(1), 1-15. <https://doi.org/10.5194/nhess-4-1-2004>

- Keefer, D. K. (1984). Landslides caused by earthquakes. *Geological Society of America Bulletin*, 95(4), 406-421.
- Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., & Guzzetti, F. (2018). A review of statistically based landslide susceptibility models. *Earth-science reviews*, 180, 60-91.
- Regmi, A. D., Devkota, K. C., Yoshida, K., & Pourghasemi, H. R. (2014). Application of frequency ratio, statistical index, and weights-of-evidence models and their comparison in landslide susceptibility mapping in Central Nepal Himalaya. *Arabian Journal of Geosciences*, 7, 725–742. <https://doi.org/10.1007/s12517-012-0807-z>
- Rong, G., Alu, S., Li, K., Su, Y., Zhang, J., Zhang, Y., & Li, T. (2020). Rainfall induced landslide susceptibility mapping based on Bayesian optimized random forest and gradient boosting decision tree models—A case study of Shuicheng County, China. *Water*, 12(11), 3066. <https://doi.org/10.3390/w12113066>
- Sokolova, M., Japkowicz, N., & Szpakowicz, S. (2006). Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. In A. Sattar, & B. H. Kang (Eds.), *AI 2006: Advances in Artificial Intelligence* (pp. 1015-1021). Springer. [https://doi.org/10.1007/11941439\\_114](https://doi.org/10.1007/11941439_114)
- Inan, M. S. K., & Rahman, I. (2023). Explainable AI integrated feature selection for landslide susceptibility mapping using Tree SHAP. *SN Computer Science*, 4, 482. <https://doi.org/10.1007/s42979-023-01960-5>
- Intarat, K., Yoomee, P., Hussadin, A., & Lamprom, W. (2024). Assessment of landslide susceptibility in the intermontane basin area of Northern Thailand. *Environment and Natural Resources Journal*, 22(2), 158-170. <https://doi.org/10.32526/enrj/22/20230241>
- Halder, K., Srivastava, A. K., Ghosh, A., Das, S., Banerjee, S., Pal, S. C., Chatterjee, U., Bisai, D., Ewert, F., & Gaiser, T. (2024). Improving landslide susceptibility prediction through ensemble Recursive Feature Elimination and meta-learning framework. *Research Square*. Advance online publication. <https://doi.org/10.21203/rs.3.rs-3991474/v1>

- Huan, Y., Song, L., Khan, U., & Zhang, B. (2023). Stacking ensemble of machine learning methods for landslide susceptibility mapping in Zhangjiajie City, Hunan Province, China. *Environmental Earth Sciences*, 82(1), Article 35. <https://doi.org/10.1007/s12665-022-10413-1>
- Hydro-Informatics Institute. (n.d.). *North flood situation in May 2006*. Retrieved May 06, 2024, from [https://tiwrm.hii.or.th/current/FloodNorth\\_May49.html](https://tiwrm.hii.or.th/current/FloodNorth_May49.html)
- Trigila, A., Frattini, P., Casagli, N., Catani, F., Crosta, G., Esposito, C., Ladanza, C., Lagomarsino, D., Mugnozza, G. S., Segoni, S., Spizzichino, D., Tofani, V., & Lari, S. (2013). Landslide susceptibility mapping at national scale: The Italian case study. In C. Margottini, P. Canuti, & K. Sassa (Eds.), *Landslide science and practice* (pp. 287-295). Springer.
- Park, S., Choi, C., Kim, B., & Kim, J. (2013). Landslide susceptibility mapping using frequency ratio, analytic hierarchy process, logistic regression and artificial neural network methods at the Inje area, Korea. *Environmental Earth Sciences*, 68, 1443-1464. <https://doi.org/10.1007/s12665-012-1842-5>
- Pham, B. T., Pradhan, B., Bui, D. T., Prakash, I., & Dholakia, M. (2016). A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India). *Environmental Modelling & Software*, 84, 240-250. <https://doi.org/10.1016/j.envsoft.2016.06.019>
- Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139.
- Jennifer, J. J. (2022). Feature elimination and comparison of machine learning algorithms in landslide susceptibility mapping. *Environmental Earth Sciences*, 81, 489. <https://doi.org/10.1007/s12665-022-10620-5>
- Muschelli, J. (2020). ROC and AUC with a binary predictor: A potentially misleading metric. *Journal of Classification*, 37(3), 696-708. <https://doi.org/10.1007/s00357-019-09345-1>
- Wu, Y., Ke, Y., Chen, Z., Liang, S., Zhao, H., & Hong, H. (2020). Application of alternating decision tree with AdaBoost and bagging ensembles for landslide susceptibility mapping. *CATENA*, 187, 104396. <https://doi.org/10.1016/j.catena.2019.104396>

- Yu, H., Pei, W., Zhang, J., & Chen, G. (2023). Landslide susceptibility mapping and driving mechanisms in a vulnerable region based on multiple machine learning models. *Remote Sensing*, 15(7), 1886. <https://doi.org/10.3390/rs15071886>
- Yu, X., Zhang, K., Song, Y., Jiang, W., & Zhou, J. (2021). Study on landslide susceptibility mapping based on rock-soil characteristic factors. *Scientific Reports*, 11(1), 15476. <https://doi.org/10.1038/s41598-021-94936-5>
- Yalcin, A. (2008). GIS-based landslide susceptibility mapping using analytical hierarchy process and bivariate statistics in Ardesen (Turkey): Comparisons of results and confirmations. *CATENA*, 72(1), 1-12. <https://doi.org/10.1016/j.catena.2007.01.003>