

## นิพนธ์ต้นฉบับ

## การประยุกต์อัลกอริทึมป่าสุ่มและข้อมูลดาวเทียมหลายช่วงเวลาในการจำแนกชนิดป่า จังหวัดเชียงใหม่

อัฐวีร์ พิมพา<sup>1</sup>, สุธีระ เหมฮัก<sup>1,2\*</sup>, วิชญ์ภาส สังพาลี<sup>1,2</sup> และ วีระภาส คุณรัตนศิริ<sup>3</sup>

รับต้นฉบับ: 26 มกราคม 2569

ฉบับแก้ไข: 12 มีนาคม 2569

รับลงพิมพ์: 25 มีนาคม 2569

## บทคัดย่อ

**ความเป็นมาและวัตถุประสงค์:** จังหวัดเชียงใหม่มีความสำคัญเชิงยุทธศาสตร์ในฐานะพื้นที่ป่าต้นน้ำลำธารหลักของระบบนิเวศลุ่มน้ำปิง และเป็นพื้นที่ที่มีความหลากหลายทางชีวภาพสูงที่สุดแห่งหนึ่งของประเทศไทย อย่างไรก็ตาม ในปัจจุบันพื้นที่ดังกล่าวกำลังเผชิญกับวิกฤตการณ์ด้านสิ่งแวดล้อมที่รุนแรงและทำลาย โดยเฉพาะปัญหาการลดลงของพื้นที่ป่าอย่างรวดเร็วและการเกิดไฟป่าซ้ำซากในช่วงฤดูแล้ง ส่งผลกระทบต่อเนื่องทำให้เกิดปัญหาหมอกพิษทางอากาศข้ามพรมแดนและฝุ่นละอองขนาดเล็ก (PM 2.5) ที่เป็นอันตรายต่อสุขภาพของประชาชนและเศรษฐกิจในระดับภูมิภาค ความรุนแรงและพฤติกรรมการลุกลามของไฟป่านั้นมีความสัมพันธ์โดยตรงกับประเภทของเชื้อเพลิงและชนิดป่า โดยเฉพาะพื้นที่ป่าผลัดใบ (Deciduous forests) เช่น ป่าเต็งรังและป่าเบญจพรรณ ซึ่งมีการทิ้งใบและสะสมเชื้อเพลิงชีวมวลแห่งปริมาณมากในช่วงหน้าแล้ง ย่อมมีความเสี่ยงต่อการเกิดไฟและลุกลามรุนแรงกว่าป่าไม่ผลัดใบ (Evergreen forests) ที่มีความชื้นสูงกว่า ดังนั้นการมีฐานข้อมูลแผนที่จำแนกประเภทป่าไม้ที่มีความถูกต้องแม่นยำ ความละเอียดสูง และเป็นปัจจุบัน จึงเป็นสิ่งจำเป็นเร่งด่วนในการวางแผนจัดการเชื้อเพลิง การกำหนดเขตพื้นที่เสี่ยงไฟป่า และการฟื้นฟูทรัพยากรธรรมชาติ แต่ทว่า การจำแนกประเภทป่าไม้ในพื้นที่ที่มีสภาพภูมิประเทศเป็นเทือกเขาสูงสลับซับซ้อนอย่างจังหวัดเชียงใหม่ นับเป็นความท้าทายสำคัญของการสำรวจระยะไกล เนื่องจากปัจจัยทางกายภาพเรื่องเงาภูเขาและความคล้ายคลึงกันของค่าการสะท้อนแสงทางสเปกตรัมของพืชพรรณต่างชนิดในบางช่วงเวลา ทำให้วิธีการดั้งเดิมที่ใช้ภาพถ่ายดาวเทียมเพียงช่วงเวลาเดียวไม่สามารถแยกแยะป่าผลัดใบและป่าไม่ผลัดใบได้อย่างมีประสิทธิภาพ เพื่อแก้ไขข้อจำกัดดังกล่าว การบูรณาการข้อมูลภาพถ่ายดาวเทียมหลายช่วงเวลา (Multi-temporal imagery) ที่สามารถติดตามการเปลี่ยนแปลงทางชีพลักษณ์ (Phenology) ของพืชพรรณในรอบปี ร่วมกับเทคโนโลยีการเรียนรู้ของเครื่อง (Machine learning) บนแพลตฟอร์มประมวลผลข้อมูลขนาดใหญ่อย่าง Google Earth Engine (GEE) จึงเป็นแนวทางที่ทรงประสิทธิภาพ งานวิจัยนี้มีวัตถุประสงค์หลักเพื่อ 1) จัดทำแผนที่จำแนกประเภทป่าไม้ของจังหวัดเชียงใหม่ ประจำปี พ.ศ. 2567 โดยประยุกต์ใช้อัลกอริทึมป่าสุ่ม (Random forest algorithm) และ 2) วิเคราะห์ลำดับความสำคัญของตัวแปร (Feature importance) ทั้งด้านดัชนีเชิงสเปกตรัมและปัจจัยสภาพภูมิประเทศ เพื่อระบุปัจจัยทางนิเวศวิทยาที่มีอิทธิพลสูงสุดต่อความถูกต้องของการจำแนก

**วิธีการ:** ดำเนินการบนแพลตฟอร์ม Google Earth Engine (GEE) เพื่อประมวลผลข้อมูลเชิงพื้นที่ขนาดใหญ่ โดยใช้ข้อมูลหลักจากภาพถ่ายดาวเทียม Sentinel-2 ระดับ 2A (Surface reflectance) ที่ผ่านการแก้ไขค่าการกระเจิงของบรรยากาศแล้ว ครอบคลุมพื้นที่ศึกษา 22,436 ตารางกิโลเมตร กระบวนการเตรียมข้อมูลแบ่งออกเป็นสองส่วนสำคัญ ส่วนแรกคือการสร้างภาพสังเคราะห์แบบค่ามัธยฐาน (Median composite) ในช่วงฤดูแล้ง (1 ธันวาคม พ.ศ. 2566 – 31 มีนาคม พ.ศ. 2567) โดยคัดเลือกเฉพาะภาพที่มีเมฆปกคลุมน้อยกว่าร้อยละ 60 เพื่อใช้เป็นข้อมูลฐานที่ปราศจากเมฆสำหรับวิเคราะห์ความสัมพันธ์ของตัวแปร ส่วนที่สองคือการสร้างชุดข้อมูลอนุกรมเวลา (Time-series stack) ครอบคลุมภาพตัวแทนรายเดือนฤดูแล้ง (4 ช่วงเวลา) และฤดูฝน (1 ช่วงเวลา) เพื่อดึงลักษณะเด่นทางชีวลักษณะของการผลัดใบ นอกจากนี้ได้ผนวกข้อมูลสภาพภูมิประเทศ ได้แก่ ระดับความสูง (Elevation) ความลาดชัน (Slope) และทิศด้านลาด (Aspect) จากแบบจำลองความสูงเชิงเลข (SRTM DEM) โดยปรับความละเอียดเชิงพื้นที่ให้เป็น 20 เมตร โดยกำหนดตัวแปรตั้งต้นจำนวน 26 ตัวแปร ครอบคลุมดัชนีพืชพรรณ ดัชนีน้ำและดิน ดัชนีเฉพาะทางป่าไม้ และคลื่นสเปกตรัมดั้งเดิม กระบวนการคัดเลือกตัวแปร (Feature selection) ทำใน 2 ขั้นตอน คือ การคัดกรองความซ้ำซ้อนด้วยสัมประสิทธิ์สหสัมพันธ์ของเพียร์สัน (ตัดตัวแปรที่มีค่า  $r > 0.90$  และ  $r < -0.90$ ) และการจัดลำดับความสำคัญตามค่าการลดลงของความไม่บริสุทธิ์จินี (Mean decrease in gini impurity) ด้วยอัลกอริทึมป่าสุ่ม แบบจำลองกำหนดชั้นเป้าหมาย 3 ประเภท ได้แก่ ป่าผลัดใบ ป่าไม้ผลัดใบ และพื้นที่ไม่ใช่ป่า โดยใช้จุดตัวอย่างอ้างอิงมาตรฐาน 750 จุด ที่ได้จากการสุ่มแบบแบ่งชั้นภูมิ (Stratified random sampling) แบ่งเป็นชุดข้อมูลฝึกสอนร้อยละ 80 และชุดข้อมูลทดสอบร้อยละ 20 โดยกำหนดค่าพารามิเตอร์จำนวนต้นไม้ ในแบบจำลองเท่ากับ 500 ต้น

**ผลการศึกษา:** ผลการคัดเลือกตัวแปรได้ชุดข้อมูลที่เหมาะสมและปราศจากความซ้ำซ้อนจำนวน 12 ตัวแปร ผลการวิเคราะห์พบว่าปัจจัยที่มีอิทธิพลสูงสุดต่อความถูกต้องของแบบจำลองคือ ข้อมูลสภาพภูมิประเทศ โดยระดับความสูง (Elevation) มีค่าความสำคัญที่ห่างเป็นอันดับหนึ่ง (629.27) รองลงมาคือความลาดชัน (492.16) สำหรับดัชนีเชิงสเปกตรัมพบว่า ดัชนีเงา (SI) (215.45) และดัชนีความต่างพืชพรรณสีเขียว (GNDVI) (184.90) มีความสำคัญสูงสุด เนื่องจากสามารถสะท้อนความซับซ้อนของโครงสร้างเรือนยอดและพฤติกรรมการทิ้งใบในหน้าแล้งได้อย่างเด็ดขาด แบบจำลอง Random Forest ที่พัฒนาขึ้นแสดงประสิทธิภาพที่ยอดเยี่ยม โดยให้ค่าความถูกต้องแบบ Out-of-Bag (OOB) สูงถึงร้อยละ 90.30 และเมื่อประเมินกับชุดข้อมูลทดสอบพบที่มีความถูกต้องโดยรวม (Overall accuracy) สูงถึงร้อยละ 95.92 พร้อมค่าสัมประสิทธิ์แคปปา (Kappa coefficient) 0.94 ผลการจำแนกรายประเภทพบว่า พื้นที่ไม่ใช่ป่า มีความถูกต้องสูงสุด (ความถูกต้องของผู้ผลิต 97.92% ความถูกต้องของผู้ใช้ 100%) รองลงมาคือ ป่าไม้ผลัดใบ (ความถูกต้องของผู้ผลิต 94.12% ความถูกต้องของผู้ใช้ 96.00%) และป่าผลัดใบ (ความถูกต้องของผู้ผลิต 95.83% ความถูกต้องของผู้ใช้ 92.00%) แผนที่ผลลัพธ์เชิงพื้นที่ระบุว่าจังหวัดเชียงใหม่มีพื้นที่ป่าผลัดใบประมาณร้อยละ 48.70 (10,779.68 ตร.กม.) กระจายตัวหนาแน่นในพื้นที่ราบเชิงเขา

และระดับความสูงปานกลาง ในขณะที่ป่าไม้ผลัดใบครอบคลุมพื้นที่ร้อยละ 32.37 (7,164.34 ตร.กม.) ซึ่งสอดคล้องกับหลักนิเวศวิทยาป่าไม้บนพื้นที่สูง อย่างไรก็ตาม การตรวจสอบความถูกต้องเชิงพื้นที่ยังคงพบข้อจำกัดบางประการ โดยเฉพาะบริเวณรอยต่อทางนิเวศวิทยา (Ecotone) ที่ระดับความสูง 800–1,150 เมตร ซึ่งสังคมพืชมีความซับซ้อน และการจำแนกชนิดพลาตในพื้นที่เกษตรกรรมประเภทไม้ผลยืนต้นอายุยาว เช่น สวนลำไยและสวนส้ม ที่มีลักษณะเรือนยอดสีเขียวตลอดปีคล้ายคลึงกับป่าธรรมชาติ

**สรุป:** การศึกษาครั้งนี้พิสูจน์ให้เห็นว่า การประยุกต์ใช้อัลกอริทึมป่าไม้ร่วมกับข้อมูลภาพถ่ายดาวเทียม Sentinel-2 แบบอนุกรมเวลาบนแพลตฟอร์มคลาวด์คอมพิวติ้ง เป็นเครื่องมือที่มีประสิทธิภาพสูงและมีความทนทาน (Robustness) ในระดับแนวหน้าสำหรับการจัดทำแผนที่ป่าไม้ในภูมิภาคที่สลับซับซ้อน ข้อค้นพบเชิงประจักษ์ยืนยันว่า ระดับความสูงทำหน้าที่เสมือนเส้นแบ่งเขตทางนิเวศวิทยาที่สำคัญที่สุดในการจำแนกประเภทป่าไม้ในภาคเหนือของไทย แผนที่ผลลัพธ์ที่ได้จากงานวิจัยนี้มีความแม่นยำสูงและเหมาะสมอย่างยิ่งต่อการนำไปประยุกต์ใช้เป็นฐานข้อมูลเชิงพื้นที่ เพื่อกำหนดขอบเขตพื้นที่เสี่ยงและบริหารจัดการไฟป่าระดับพื้นที่ได้อย่างตรงจุด เพื่อการพัฒนาแบบจำลองในอนาคต ผู้วิจัยเสนอแนะให้มีการปรับปรุงการจำแนกชั้นข้อมูลพื้นที่ไม้ใช้ป่าให้มีรายละเอียดมากขึ้น โดยแยกพื้นที่สวนผลไม้ออกเป็นประเภทย่อย และพิจารณาบูรณาการข้อมูลจากเซนเซอร์เรดาร์ (Sentinel-1 SAR) หรือการวิเคราะห์พื้นผิว (Texture analysis) เพื่อยกระดับความสามารถในการแยกแยะโครงสร้างทางกายภาพของพืชพรรณให้สมบูรณ์ยิ่งขึ้น

**คำสำคัญ:** การสำรวจระยะไกล, Sentinel-2, ภูเกิลเอิร์ธเอนจิน, การเรียนรู้ของเครื่อง, อัลกอริทึมป่าไม้

<sup>1</sup> สาขาวิชาการจัดการป่าไม้ มหาวิทยาลัยแม่โจ้-แพร่ เฉลิมพระเกียรติ แพร่ 54140

<sup>2</sup> คณะผลิตกรรมการเกษตร มหาวิทยาลัยแม่โจ้ เชียงใหม่ 50290

<sup>3</sup> ภาควิชาการจัดการป่าไม้ คณะวนศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพฯ 10900

\* ผู้รับผิดชอบบทความ; sutheera@mju.ac.th หรือ h.sutheera@gmail.com

<https://doi.org/10.34044/tferj.2026.10.1.6595>

## ORIGINAL ARTICLE

**Application of Random Forest Algorithm and Multi-Temporal Satellite Data  
for Forest Types Classification in Chiang Mai Province**Atthavee Phimpa<sup>1</sup>, Sutteera Hermhuk<sup>1,2\*</sup>, Witchaphart Sungpalee<sup>1,2</sup> and Weeraphart Khunrattanasiri<sup>3</sup>

Received: 26 January 2026

Revised: 12 March 2026

Accepted: 25 March 2026

**ABSTRACT**

**Background and Objectives:** Chiang Mai Province is strategically important as a major watershed area for the Ping River basin ecosystem and boasts one of the highest biodiversity levels in Thailand. However, this area is currently facing a severe and challenging environmental crisis, particularly the rapid decline in forest area and recurring wildfires during the dry season. These fires have ongoing consequences, leading to transboundary air pollution and PM 2.5 levels that are hazardous to public health and the regional economy. The severity and spread of wildfires are directly related to fuel type and forest types. Deciduous forests, such as dry dipterocarp forest and mixed deciduous forest, which ecologically shed leaves and accumulate large amounts of dry biomass fuel during the dry season, are more susceptible to fire and more severe fire spread than evergreen forests, which have higher humidity levels. Therefore, an accurate, high-resolution, and up-to-date forest classification map database is urgently needed for fuel management planning, wildfire risk zone identification, and natural resource restoration. However, classifying forest types in the complex mountainous terrain of Chiang Mai Province presents a significant challenge for remote sensing due to physical factors such as mountain shadows and the similarity of spectral reflectance values among different vegetation species at certain times. Traditional methods using single-temporal satellite imagery cannot effectively distinguish between deciduous and evergreen forests. To overcome this limitation, integrating multi-temporal satellite imagery capable of tracking vegetation phenology changes throughout the year, along with machine learning technology on a large-scale data processing platform like Google Earth Engine (GEE), is a powerful approach. This research therefore aims to: 1) create a forest classification map of Chiang Mai Province for the year 2024 using a random forest (RF) algorithm, and 2) analyze the feature importance of both spectral indices and topographic factors to identify the ecological factors that have the greatest influence on classification accuracy.

**Method:** This study was conducted on the Google Earth Engine (GEE) platform to process large-scale geospatial data. The primary dataset comprised Sentinel-2 Level 2A (Surface Reflectance) imagery, which had been atmospherically corrected, covering the entire 22,436 square kilometers. The data preparation process was divided

into two main parts. The first involved creating a median composite image during the dry season (December 1, 2023 – March 31, 2024), selecting only images with less than 60% cloud cover to serve as a cloud-free baseline for analyzing the relationships between variables. The second component involved constructing a time-series stack comprising representative monthly images from four dry-season periods and one wet-season period. This multi-temporal approach was specifically designed to capture the distinct phenological signatures of leaf shedding and greening. Furthermore, topographic data, including elevation, slope, and aspect, were derived from the Shuttle Radar Topography Mission Digital Elevation Model (SRTM DEM) and resampled to a 20-meter spatial resolution. The researchers initially calculated a comprehensive set of 26 predictor variables, encompassing vegetation indices, water and soil indices, forest-specific indices, and original spectral bands. To optimize model performance, a two-step Feature Selection process was implemented. Initially, Pearson's correlation coefficient analysis was used to eliminate highly redundant variables (excluding those with  $r > 0.90$  or  $r < -0.90$ ). Subsequently, the remaining variables were ranked based on the Mean Decrease in Gini Impurity metric using the Random Forest algorithm. The classification model targeted three distinct classes: deciduous forest, evergreen forest, and non-forest. Reference data consisted of 750 standard ground-truth points, collected via stratified random sampling to ensure spatial independence. These points were randomly partitioned into an 80% training set (600 points) and a 20% testing set (150 points). The RF classifier was parameterized with 500 decision trees (ntrees) to maximize stability.

**Results:** The feature selection process successfully refined the dataset to an optimal subset of 12 non-redundant variables. The analysis revealed that topographic features were the most influential factors governing the model's predictive capability. Specifically, elevation was dominance the ranking with the highest importance score (629.27), followed by slope (492.16). Among the spectral predictors, the shadow index (SI) (215.45) and the Green Normalized Difference Vegetation Index (GNDVI) (184.90) proved to be the most critical variables, as they effectively captured the complexities of canopy structures and mitigated topographic shadow effects during the dry season. The developed RF model demonstrated exceptional performance, achieving a high Out-of-Bag (OOB) accuracy of 90.30%. When evaluated against the independent testing set, the model yielded an Overall Accuracy of 95.92% and a Kappa coefficient of 0.94. Class-specific performance analysis indicated that the non-forest class achieved the highest accuracy (Producer's Accuracy 97.92%, User's Accuracy 100%), followed by evergreen forest (Producer's Accuracy 94.12%, User's Accuracy 96.00%), and deciduous forest (Producer's Accuracy 95.83%, User's Accuracy 92.00%). The final spatial map revealed that deciduous forests cover approximately 48.70% (10,779.68 km<sup>2</sup>) of the province, predominantly distributed in foothills and mid-elevation zones, while evergreen forests account for 32.37% (7,164.34 km<sup>2</sup>), densely dominating the higher mountain ranges, which perfectly aligns with highland forest ecology principles. However, spatial verification identified specific limitations. Minor misclassifications were observed within ecological

transition zones (ecotones) at elevations between 800 and 1,150 meters due to highly mixed forest structures. Additionally, spectral confusion occurred in agricultural areas containing perennial, long-living fruit orchards (e.g., longan and orange orchards), which maintain permanent green canopies that closely resemble the spectral signatures of natural evergreen forests.

**Conclusion:** This study demonstrates that applying a RF algorithm with multi-temporal Sentinel-2 imagery on a cloud computing platform provides a highly robust, cutting-edge tool for mapping complex forest ecosystems in mountainous regions. Empirical findings confirm that elevation serves as the most important ecological boundary for forest classification in northern Thailand. The resulting high-precision classification map serves as a vital spatial database for accurately delineating wildfire risk zones and supporting targeted natural resource management. For further enhance model accuracy in future research, it is highly recommended to refine the non-forest class by explicitly separating perennial fruit orchards into distinct sub-categories. Furthermore, incorporating Synthetic Aperture Radar (Sentinel-1 SAR) data or employing advanced texture analysis should be strongly considered to improve the differentiation of physical vegetation structures across complex landscapes.

**Keyword:** Remote Sensing, Sentinel-2, Google Earth Engine, Machine Learning, Random Forest

---

<sup>1</sup> Program in Forest Management, Maejo University Phrae Campus, Phrae Province 54140, Thailand

<sup>2</sup> Faculty of Agricultural Production, Maejo University, Chiang Mai Province 50290, Thailand

<sup>3</sup> Department of Forest Management, Faculty of Forestry, Kasetsart University, Bangkok 10900, Thailand

\*Corresponding author; [sutheera@mju.ac.th](mailto:sutheera@mju.ac.th) or [h.sutheera@gmail.com](mailto:h.sutheera@gmail.com)

<https://doi.org/10.34044/tferj.2026.10.1.6595>

### คำนำ (Introduction)

ทรัพยากรป่าไม้มีความสำคัญอย่างยิ่งต่อความมั่นคงทางระบบนิเวศและเสถียรภาพด้านสิ่งแวดล้อมของประเทศไทย ซึ่งรัฐบาลได้กำหนดเป้าหมายยุทธศาสตร์ชาติ 20 ปี ในการเพิ่มพื้นที่ป่าให้ได้ร้อยละ 40 ของพื้นที่ประเทศ (Subcommittee on Drafting National Forest Policy and National Forest Development Master Plan, 2020) อย่างไรก็ตาม ข้อมูลจากกรมป่าไม้ในปี พ.ศ. 2567 ชี้ให้เห็นสถานการณ์ที่น่ากังวล โดยพื้นที่ป่าของประเทศเหลือเพียงร้อยละ 31.46 และมีแนวโน้มลดลงอย่างต่อเนื่อง โดยเฉพาะอย่างยิ่งในจังหวัดเชียงใหม่ ซึ่งเป็นพื้นที่ที่มีความสำคัญเชิงนิเวศสูงสุดในภาคเหนือ พบการสูญเสียพื้นที่ป่ามากที่สุดในประเทศถึง 39.96 ตารางกิโลเมตร หรือ 3,995.93 เฮกตาร์ ภายในระยะเวลาเพียงหนึ่งปี (Forest Land Management Bureau, 2025) สาเหตุหลักมาจากการขยายพื้นที่เกษตรกรรม การบุกรุกพื้นที่ และปัญหาไฟป่าที่ทวีความรุนแรงขึ้น ซึ่งมีความสัมพันธ์โดยตรงกับประเภทของป่าไม้ กล่าวคือ ป่าผลัดใบ (Deciduous forests) มีความเสี่ยงต่อการเกิดไฟป่าสูงกว่าป่าไม่ผลัดใบ (Evergreen forests) เนื่องจากมีการสะสมเชื้อเพลิงชีวมวลในช่วงฤดูแล้ง (Yatar *et al.*, 2024) และป่าไม่ผลัดใบมักมีการบุกรุกการขยายพื้นที่เกษตรมากกว่าพื้นที่ป่าผลัดใบ จากความอุดมสมบูรณ์ของดิน (Hermhuk *et al.*, 2020) และประกอบกับมีการตั้งถิ่นฐานของกลุ่มชาติพันธุ์บนพื้นที่สูง (Yamvudhi *et al.*, 2016) ดังนั้นการมีข้อมูลจำแนกประเภทป่าไม้ที่มีความถูกต้อง แม่นยำ

และเป็นปัจจุบัน จึงเป็นสิ่งจำเป็นเร่งด่วนสำหรับการวางแผนจัดการไฟป่าและการฟื้นฟูทรัพยากรธรรมชาติอย่างมีประสิทธิภาพ (Royal Forest Department, 2023)

การจำแนกประเภทป่าไม้ในพื้นที่ที่มีความซับซ้อนทางภูมิประเทศและมีความหลากหลายทางชีวภาพสูงอย่างจังหวัดเชียงใหม่ เป็นความท้าทายสำคัญของการสำรวจระยะไกล (Remote sensing) การใช้ข้อมูลภาพถ่ายดาวเทียมเพียงช่วงเวลาเดียวมักไม่เพียงพอต่อการแยกแยะป่าผลัดใบออกจากป่าไม่ผลัดใบ เนื่องจากพืชพรรณอาจมีค่าการสะท้อนแสงทางสเปกตรัมที่คล้ายคลึงกันในบางฤดูกาล (Zhu & Liu, 2014) งานวิจัยในอดีตจึงมุ่งเน้นการใช้ข้อมูลหลายช่วงเวลา (Multi-temporal imagery) เพื่อดึงลักษณะเด่นทางชีวลักษณ์ (Phenology) หรือลายเซ็นต์ทางเวลา (Temporal signature) ของพืชพรรณออกมาใช้ประโยชน์ โดยเฉพาะการเปลี่ยนแปลงของดัชนีพืชพรรณในช่วงฤดูแล้งเปรียบเทียบกับฤดูฝน ซึ่งได้รับการพิสูจน์แล้วว่าสามารถเพิ่มความแม่นยำในการจำแนกได้อย่างมีนัยสำคัญ (Khongseng, 2017; Cheng & Wang, 2019) นอกจากนี้การเลือกใช้ข้อมูลจากดาวเทียม Sentinel-2 ที่มีความละเอียดเชิงพื้นที่สูงและมีช่วงคลื่น Red-edge ร่วมกับแพลตฟอร์มประมวลผลประสิทธิภาพสูงอย่าง Google earth engine (GEE) ยังช่วยเปิดโอกาสให้นักวิจัยสามารถวิเคราะห์ข้อมูลอนุกรมเวลาขนาดใหญ่ได้อย่างรวดเร็วและแม่นยำยิ่งขึ้น (Gorelick *et al.*, 2017; Forkuor *et al.*, 2018)

อัลกอริทึมป่าสุ่ม (Random forest algorithm, RFA) ได้รับการยอมรับอย่างกว้างขวางว่าเป็นเครื่องมือที่มีประสิทธิภาพสูงสำหรับจำแนกข้อมูลที่มีความซับซ้อนและมีมิติสูง โดยเฉพาะในงานด้านป่าไม้ เนื่องจากมีการป้องกันต่อสัญญาณรบกวนและสามารถจัดการกับตัวแปรจำนวนมากได้ดีกว่าวิธีดั้งเดิม (Belgiu & Dragut, 2016) อย่างไรก็ตาม ยังมีงานวิจัยจำนวนน้อยที่บูรณาการข้อมูล Sentinel-2 แบบหลายช่วงเวลา ร่วมกับชุดดัชนีพืชพรรณ ดัชนีความชื้น และข้อมูลภูมิประเทศ บนแพลตฟอร์ม GEE เพื่อจำแนกป่าผลัดใบและป่าไม้ผลัดใบในบริบทพื้นที่ภูเขาสูงของภาคเหนือตอนบนของไทยอย่างเจาะจง งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อ (1) จัดทำแผนที่จำแนกประเภทป่าไม้ของจังหวัดเชียงใหม่ ปี 2567 ในระดับความละเอียดที่เหมาะสมต่อการจัดการป่าไม้ และ (2) การวิเคราะห์ความสำคัญของตัวแปร (Feature importance) ที่ส่งผลต่อความแม่นยำของแบบจำลอง เพื่อเป็นแนวทางในการติดตามและบริหารจัดการทรัพยากรป่าไม้อย่างยั่งยืนต่อไป

## อุปกรณ์และวิธีการ (Materials and Methods)

### 1. พื้นที่ศึกษา (Study area)

การศึกษานี้ครอบคลุมพื้นที่ทั้งหมดของจังหวัดเชียงใหม่ (Figure 1) ตั้งอยู่ระหว่าง พิกัด UTM (WGS84 โซน 47N) ที่ 402,554 ถึง 559,252 ตะวันออก (East) และ 1,907,443 ถึง 2,218,959 เหนือ (North) มีสภาพภูมิอากาศโดยทั่วไปเป็นแบบร้อนชื้นสลับแล้ง (Tropical wet and dry climate) โดยอ้างอิงข้อมูลสถิติภูมิอากาศคาบ 30 ปี

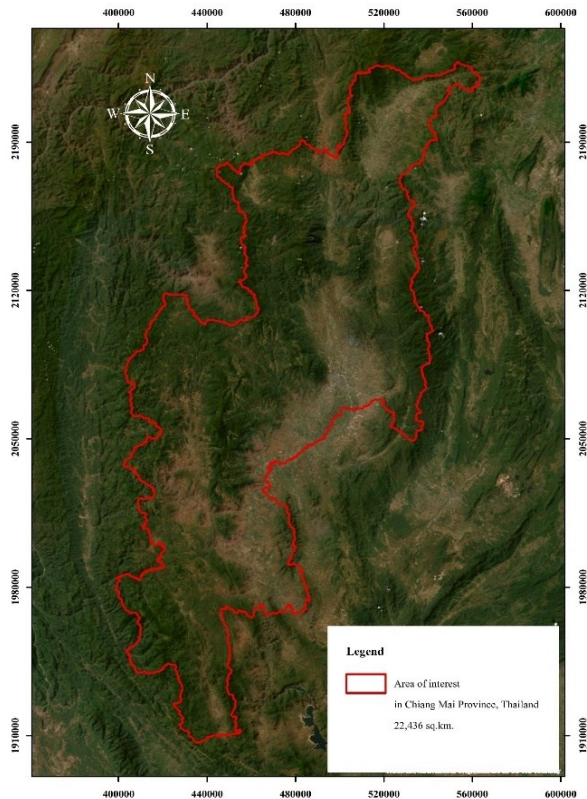
(พ.ศ. 2534 – พ.ศ. 2563) มีอุณหภูมิเฉลี่ยรายปีประมาณ 25.4 องศาเซลเซียส มีอุณหภูมิเฉลี่ยรายเดือนต่ำสุดในช่วงฤดูหนาว (เดือนมกราคม) ประมาณ 22 องศาเซลเซียส และสูงสุดในช่วงฤดูร้อน (เดือนเมษายน) ประมาณ 29-30 องศาเซลเซียส และมีปริมาณน้ำฝนเฉลี่ยรายปี 1,100–1,200 มิลลิเมตร (Thai Meteorological Department, 2024)

ลักษณะดินในพื้นที่ราบลุ่มและที่ดอนประกอบด้วยชุดดินที่สำคัญ ได้แก่ ชุดดินเชียงใหม่ (Chiang Mai series) ชุดดินหางดง (Hang Dong series) และชุดดินสันทราย (San Sai series) ซึ่งเป็นดินร่วนปนทรายที่เกิดจากตะกอนลำนํ้า ในขณะที่พื้นที่ป่าไม้ในเขตภูเขาสูงส่วนใหญ่จัดอยู่ในกลุ่มชุดดินที่ลาดชัน (Slope Complex: SC) ซึ่งมีความเสี่ยงต่อการชะล้างพังทลายสูง (Royal Irrigation Department, 2020)

สภาพป่าไม้ในพื้นที่ประกอบด้วยสังคมพืชที่มีความหลากหลาย โดยสามารถจำแนกกลุ่มป่าผลัดใบ (Deciduous forests) ได้แก่ ป่าเบญจพรรณ (Mixed deciduous forest) และป่าเต็งรัง (Deciduous dipterocarp forest) ซึ่งมักพบในพื้นที่ที่มีความสูงต่ำกว่า 1,000 เมตร และกลุ่มป่าไม้ผลัดใบ (Evergreen forests) ได้แก่ ป่าดิบเขา (Montane evergreen forest) ป่าดิบแล้ง (Dry evergreen forest) และป่าสน (Pine forest) ซึ่งมักกระจายตัวในพื้นที่ภูเขาสูง (Department of National Parks, Wildlife and Plant Conservation, 2022) มีพื้นที่ 22,436 ตารางกิโลเมตร

ลักษณะภูมิประเทศส่วนใหญ่เป็นภูเขาสูงสลับซับซ้อนและที่ราบระหว่างหุบเขา มีความ

หลากหลายของพืชพรรณสูงและเป็นพื้นที่ป่าต้นน้ำที่สำคัญของประเทศ โดยขอบเขตการศึกษาอ้างอิงตามเขตการปกครองของกรมการปกครองเพื่อจำแนกพื้นที่ป่าไม้ (Figure 1)



**Figure 1** Area of interest in Chiang Mai Province, Thailand

## 2. วิธีการ (Methods)

### 2.1 การเตรียมข้อมูล (Data preparation)

การประมวลผลข้อมูลทั้งหมดดำเนินการบนแพลตฟอร์ม Google earth engine (GEE) ซึ่งเป็นระบบประมวลผลภูมิสารสนเทศบนคลาวด์สำหรับการวิเคราะห์ข้อมูลขนาดใหญ่ (Gorelick *et al.*, 2017) โดยใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ระดับ 2A (Surface reflectance) ที่ผ่านการแก้ไขค่าบรรยากาศแล้ว ร่วมกับข้อมูลแบบจำลองความสูง

เชิงเลข (Digital elevation model, DEM) จากชุดข้อมูลความสูงแบบดิจิทัลจากภารกิจ (Shuttle radar topography, SRTM) ความละเอียด 30 เมตร เพื่อสกัดตัวแปรด้านสภาพภูมิประเทศ ได้แก่ ระดับความสูง ความลาดชัน และทิศด้านลาด โดยข้อมูลสภาพภูมิประเทศถูกปรับความละเอียดเชิงพื้นที่ (Resampling) ให้เป็น 20 เมตร ด้วยวิธี Bilinear interpolation (Jensen, 2015) ให้สอดคล้องกับความละเอียดของข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ที่ถูกปรับให้อยู่ในสเกล 20 เมตร ด้วยวิธี Nearest neighbor

### 2.2 การเก็บข้อมูล (Data collection)

1. การเตรียมชุดข้อมูลภาพถ่ายดาวเทียม (Satellite data preparation) กำหนดกระบวนการเตรียมข้อมูลออกเป็น 2 ส่วนหลัก ได้แก่

1.1 สำหรับการคัดเลือกตัวแปรตั้งต้น: สร้างภาพสังเคราะห์แบบค่ามัธยฐาน (Median composite) จากภาพถ่ายในช่วงฤดูแล้ง (1 ธันวาคม พ.ศ. 2566 – 31 มีนาคม พ.ศ. 2567) ที่ผ่านการกรองเมฆให้น้อยกว่าร้อยละ 60 เพื่อให้ได้ภาพตัวแทนที่ปราศจากเมฆและมีความสมบูรณ์ที่สุดสำหรับวิเคราะห์ความสัมพันธ์ของตัวแปร

1.2 สำหรับการสร้างชุดตัวแปรอนุกรมเวลา: จัดเตรียมภาพตัวแทนรายเดือนในช่วงฤดูแล้งจำนวน 4 ช่วงเวลา และภาพตัวแทนช่วงฤดูฝน (1 พฤษภาคม – 31 ตุลาคม พ.ศ. 2567) จำนวน 1 ช่วงเวลา รวมเป็น 5 ช่วงเวลา เพื่อสร้างชุดข้อมูลอนุกรมเวลา (Time-series stack) ที่สามารถสะท้อนพลวัตการเปลี่ยนแปลงทางชีวลักษณะ (Phenology)

ของพืชพรรณในรอบปี (Khongseng, 2017; Cheng & Wang, 2019)

**2. การคำนวณและคัดเลือกตัวแปร (Variable Calculation and Selection)** กำหนดชุดตัวแปรตั้งต้นเพื่อใช้ในการวิเคราะห์ รวมทั้งหมด 26 ตัวแปร แบ่งเป็น 6 กลุ่ม ดังนี้

2.1 กลุ่มดัชนีพืชพรรณ จำนวน 4 ตัวแปร ได้แก่ Normalized difference vegetation index (NDVI), Enhanced vegetation index (EVI), Soil-adjusted vegetation index (SAVI) และ Green normalized difference vegetation index (GNDVI)

2.2 กลุ่มดัชนีน้ำและความชื้น จำนวน 3 ตัวแปร ได้แก่ Normalized Difference Water Index (NDWI), Normalized Difference Moisture Index (NDMI) และ Modified Normalized Difference Water Index (MNDWI)

2.3 กลุ่มดัชนีสิ่งปลูกสร้างและดิน จำนวน 4 ตัวแปร ได้แก่ Normalized Difference Built-up Index (NDBI), Urban Index (UI), Bare Soil Index (BSI) และ Modified Built-Up Index (MBUI)

2.4 กลุ่มดัชนีเฉพาะทางป่าไม้ จำนวน 2 ตัวแปร ได้แก่ Forest Discrimination Index (FDI) และ Shadow Index (SI)

2.5 กลุ่มข้อมูลคลื่นสเปกตรัมดั้งเดิม จำนวน 10 ตัวแปร ได้แก่ B2-Blue, B3 – Green, B4 – Red, B5 - Red Edge 1, B6 - Red Edge 2, B7 - Red Edge 3, B8 – NIR, B8A - Narrow NIR, B11 - SWIR 1 และ B12 - SWIR 2

2.6 กลุ่มข้อมูลสภาพภูมิประเทศ จำนวน 3 ตัวแปร ได้แก่ Elevation, Slope และ Aspect

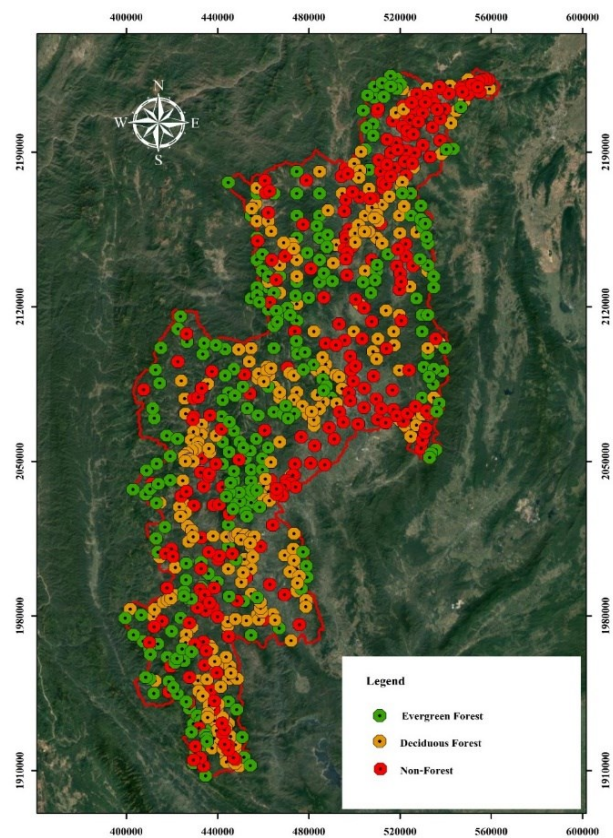
โดยตัวแปรในกลุ่มที่ 1 ถึง 5 ถูกคำนวณและสกัดจากภาพสังเคราะห์แบบค่ามัธยฐาน (จากข้อ 1.1) จากนั้นทำการคัดเลือกตัวแปร (Feature selection) 2 ขั้นตอน คือ (1) การวิเคราะห์สัมประสิทธิ์สหสัมพันธ์ของเพียร์สัน (Pearson's correlation) เพื่อตัดตัวแปรที่มีความซ้ำซ้อนกันสูง (โดยพิจารณาว่า  $r > 0.90$  และ  $r < -0.90$ ) ออกตามเกณฑ์ของ Dormann *et al.* (2013) และ (2) การจัดลำดับความสำคัญของตัวแปร (Feature importance) ด้วยอัลกอริทึม RF เพื่อคัดเลือกตัวแปรที่มีประสิทธิภาพสูงสุด ซึ่งได้รับการยอมรับว่าเป็นวิธีที่มีประสิทธิภาพในการระบุตัวแปรทางนิเวศวิทยา (Cutler *et al.*, 2007) ผลจากการคัดเลือกได้ชุดตัวแปรตัวแทนที่เหมาะสมที่สุดจำนวน 12 ตัวแปร โดยแบ่งเป็นตัวแปรเชิงสเปกตรัม จำนวน 9 ตัวแปร และตัวแปรภูมิประเทศคงที่ จำนวน 3 ตัวแปร จากนั้นผู้วิจัยจึงนำเฉพาะตัวแปรเชิงสเปกตรัมทั้ง 9 ตัวแปร ไปดึงค่าจากภาพตัวแทนทั้ง 5 ช่วงเวลา (จากข้อ 1.2) เพื่อสร้างเป็นอนุกรมเวลาจำนวน 45 ชั้นข้อมูล (9 ตัวแปร x 5 ช่วงเวลา) และนำมาซ้อนทับ (Stacking) ร่วมกับข้อมูลภูมิประเทศ 3 ชั้นข้อมูล รวมเป็นชุดข้อมูลนำเข้าสำหรับแบบจำลองทั้งสิ้น 48 ชั้นข้อมูล วิธีการนี้ช่วยป้องกันปัญหามิติข้อมูลสูงเกินความจำเป็น ที่อาจเกิดขึ้นหากนำตัวแปรเริ่มต้นทั้ง 26 ตัวแปรไปคำนวณในทุกช่วงเวลา

**3. การสร้างแบบจำลองและการจำแนกประเภทป่า (Model development):** กำหนดชั้นข้อมูลเป้าหมายเป็น 3 กลุ่ม คือ 1) ป่าผลัดใบ ได้แก่ ป่าเต็งรัง ป่าเบญจพรรณ และป่าเต็งรังผสมสน

2) ป่าไม้ผลัดใบ ได้แก่ ป่าดิบแล้ง ป่าดิบเขา และป่า  
 ริมน้ำ และ 3) พื้นที่ไม่ใช่ป่า (Non-forest) คือ พื้นที่  
 เกษตรกรรม และพื้นที่เบ็ดเตล็ด โดยใช้จุดตัวอย่าง  
 อ้างอิงจำนวน 750 จุด ซึ่งรวบรวมจากการสำรวจ  
 ภาคสนามและการแปลภาพถ่ายดาวเทียมความ  
 ละเอียดสูง โดยใช้วิธีการสุ่มแบบแบ่งชั้นภูมิ  
 (Stratified random sampling) เพื่อให้กระจายตัว  
 ครอบคลุมทั่วพื้นที่จังหวัดเชียงใหม่ (Figure 2) โดย  
 กำหนดระยะห่างขั้นต่ำระหว่างจุดตัวอย่างแต่ละจุด  
 ไว้ไม่น้อยกว่า 500 เมตร เพื่อสร้างความเป็นอิสระ  
 เชิงพื้นที่ และป้องกันปัญหาความสัมพันธ์เชิงพื้นที่  
 ที่อาจส่งผลให้แบบจำลองเรียนรู้เกินพอดีและ  
 ประเมินค่าความถูกต้องสูงเกินจริง

จากนั้นนำชุดข้อมูลดังกล่าวมาแบ่งสัดส่วน  
 เป็นชุดข้อมูลฝึกสอน (Training set) ร้อยละ 80 และ  
 ชุดข้อมูลทดสอบ (Testing set) ร้อยละ 20 ตาม  
 หลักเกณฑ์มาตรฐานการประเมินความถูกต้อง  
 (Congalton & Green, 2019) เพื่อให้มั่นใจว่าชุด  
 ข้อมูลทดสอบมีความเป็นอิสระเชิงพื้นที่และไม่ม  
 การซ้อนทับกับชุดข้อมูลฝึกสอนอย่างแท้จริง ใน  
 การแบ่งชุดข้อมูลได้กำหนดค่าเมล็ดสุ่ม (Random  
 seed) ไว้ที่ 42 เพื่อให้มั่นใจว่าผลการสุ่มมีความคงที่  
 และสามารถทำซ้ำได้ (Reproducibility) ดำเนินการ  
 สร้างและฝึกสอนแบบจำลองด้วย RFA ซึ่งพัฒนา  
 โดย Breiman (2001) โดยกำหนดพารามิเตอร์  
 จำนวนต้นไม้ (Number of trees) เท่ากับ 500 ต้น  
 และใช้การสุ่มตัวอย่างแบบ Bagging ในสัดส่วน  
 ร้อยละ 50 (Bag fraction = 0.5) ของข้อมูลฝึกสอน  
 นอกจากนี้ได้กำหนดจำนวนตัวแปรที่สุ่มในแต่ละ

จุดแตกแขนง (mtry) ให้เท่ากับรากที่สองของ  
 จำนวนตัวแปรทั้งหมด และไม่มีการจำกัดความลึก  
 สูงสุดของต้นไม้ (Max depth = None) เพื่อให้  
 แบบจำลองสามารถเรียนรู้ความสัมพันธ์ของข้อมูล  
 พืชพรรณได้อย่างสมบูรณ์



**Figure 2** Distribution of 750 reference points for model training and testing, generated using stratified random sampling across Chiang Mai Province.

**4. การประเมินความถูกต้อง (Accuracy Assessment):** ประเมินประสิทธิภาพของแผนที่  
 ผลลัพธ์ด้วยตารางความสับสน (Confusion matrix)  
 โดยคำนวณค่าความถูกต้องโดยรวม (Overall  
 accuracy) ค่าสัมประสิทธิ์แคปปา (Kappa  
 coefficient) รวมถึงความถูกต้องของผู้ผลิต

(Producer's accuracy) และความถูกต้องของผู้ใช้ (User's accuracy) จากชุดข้อมูลทดสอบอิสระ ตามแนวทางของ Congalton & Green (2019)

## ผลและวิจารณ์ (Results and Discussion)


### 1. การคัดเลือกตัวแปร

เพื่อให้ได้ชุดข้อมูลที่มีประสิทธิภาพสูงสุด และลดปัญหาความซ้ำซ้อนของข้อมูลนำเข้า ผู้วิจัยได้ดำเนินการวิเคราะห์สหสัมพันธ์ของเพียร์สัน (Pearson's correlation) ระหว่างคู่ตัวแปรตั้งต้นทั้งหมด 26 ตัวแปร ผลการศึกษาพบว่ามีกลุ่มตัวแปรที่มีค่าสัมประสิทธิ์สหสัมพันธ์เชิงบวกสูงกว่า 0.90 และ เชิงลบในทิศทางตรงกันข้ามที่น้อยกว่า -0.90 ซึ่งบ่งชี้ถึงความซ้ำซ้อนและผกผันของข้อมูล โดยเฉพาะในกลุ่มดัชนีพืชพรรณ กลุ่มดัชนีน้ำ กลุ่มดัชนีสิ่งปลูกสร้าง และคลื่นสเปกตรัม ที่มีความสัมพันธ์กันสูงมาก จึงมีความจำเป็นต้องคัดเลือกตัวแปรตัวแทนที่ดีที่สุดเพียงตัวแปรเดียวในแต่ละกลุ่มเพื่อนำไปใช้ในการวิเคราะห์ขั้นต่อไป

หลังจากพิจารณาความซ้ำซ้อน ผู้วิจัยได้ดำเนินการจัดลำดับความสำคัญของตัวแปร ด้วย Random forest algorithm (RFA) เพื่อคัดเลือกตัวแปรตัวแทนที่มีประสิทธิภาพสูงสุด โดยพิจารณาจากคะแนนการลดลงของความไม่บริสุทธิ์จินี (Mean decrease in Gini impurity) ซึ่งเป็นค่าสถิติมาตรฐานที่คำนวณโดยอัตโนมัติจากชุดคำสั่งของแบบจำลอง (Gislason *et al.*, 2006) ผลการวิเคราะห์แสดงให้เห็นว่า ข้อมูลสภาพภูมิประเทศ (Topographic features) เป็นปัจจัยที่มีอิทธิพลสูงสุดต่อการจำแนกประเภทป่าไม้ (Figure 3) โดยระดับ

ความสูงจากน้ำทะเล (Elevation) มีค่าความสำคัญสูงสุดเป็นอันดับ 1 (629.27) รองลงมาคือความลาดชัน (slope) (492.16) สำหรับกลุ่มดัชนีความต่างของพืชด้วยช่วงคลื่นแสงสีเขียว (GNDVI) มีค่าความสำคัญสูงสุด (184.90) ซึ่งสูงกว่าค่าดัชนีการสะท้อนของพืช (NDVI) (163.09) แสดงให้เห็นว่าดัชนีที่ใช้ช่วงคลื่นสีเขียวมีความไวต่อการจำแนกประเภทป่าไม้ในพื้นที่ศึกษานี้ได้ดีกว่า นอกจากนี้ดัชนีเงา (SI) ยังมีค่าความสำคัญสูงถึง 215.45 ซึ่งสะท้อนถึงบทบาทในการช่วยลดผลกระทบจากเงาภูเขาในพื้นที่ที่มีความสลับซับซ้อน

จากกระบวนการคัดกรองข้างต้น ผู้วิจัยได้คัดเลือกตัวแปรที่มีความเหมาะสมที่สุด จำนวน 12 ตัวแปร เพื่อนำไปสร้างแบบจำลอง ได้แก่ ความสูงจากระดับน้ำทะเล (Elevation) ทิศด้านลาด (Aspect) และความลาดชัน (Slope) ที่ได้จากแผนที่ช่วงชั้นความสูงเชิงเลข (Digital elevation model) ดัชนี Green normalized difference vegetation index (GNDVI), Normalized difference water index (NDWI), Urban index (UI), Shadow index (SI) ที่ได้จากสมการของ Gitelson *et al.* (1996); Kawamura *et al.* (1996); McFeeters (1996) และ Rikimaru (1997) และข้อมูลคลื่นสเปกตรัม (Spectrum index) 5 ช่วงคลื่น ได้แก่ Band 2 (Blue), Band 3 (Green), Band 5 (Red-edge 1), Band 8A (NIR narrow) และ Band 11 (SWIR 1) ซึ่งได้ข้อมูลจากดาวเทียม Sentinel-2



**Figure 3** Factors variable importance scores derived from the random forest algorithm (RFA)

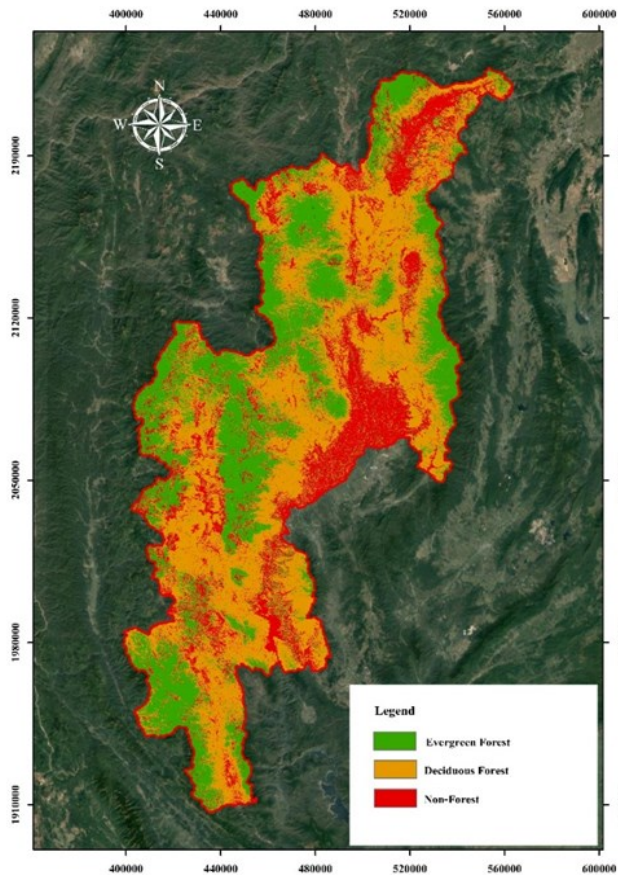
## 2. การจำแนกประเภทป่าไม้

เมื่อนำชุดข้อมูลอนุกรมเวลาและตัวแปรคงที่ มาสร้างแบบจำลองด้วย RFA ได้แผนที่การจำแนกประเภทป่าไม้จังหวัดเชียงใหม่ ปี พ.ศ. 2567 (Figure 4) และจากการประเมินความถูกต้องทางสถิติด้วยตารางความสับสน (Confusion matrix) พบว่าแบบจำลองมีความถูกต้องโดยรวม (Overall accuracy) สูงถึงร้อยละ 95.92 และค่าสัมประสิทธิ์

แคปปา (Kappa coefficient) เท่ากับ 0.94 (Table 1) มีรายละเอียดในแต่ละประเภท ดังนี้

1. ป่าไม้ผลัดใบ (Evergreen forests): มีความถูกต้องของผู้ใช้ (UA) 96.00% และความถูกต้องของผู้ผลิต (PA) 94.12% โดยพบการปะปนกันกับป่าผลัดใบ จำนวน 3 จุดตัวอย่าง พบว่าจุดดังกล่าวตั้งอยู่ที่ระดับความสูงประมาณ 832, 1,075 และ 1,151 เมตรจากระดับน้ำทะเลปานกลาง ซึ่งเป็น

บริเวณรอยต่อของระบบนิเวศ ระหว่างป่าเต็งรัง ป่าเบญจพรรณกับป่าดิบเขา ที่มีปรากฏขึ้นที่ระดับความสูงประมาณ 1,000 เมตร ในพื้นที่ภูเขาของจังหวัดเชียงใหม่ ทำให้โครงสร้างป่าและค่าการสะท้อนแสงมีความใกล้เคียงกัน ส่งผลให้แบบจำลองเกิดความสับสนในการจำแนก



**Figure 4** Forest types classification map of Chiang Mai province in 2024

2. ป่าผลัดใบ (Deciduous forests): มีความถูกต้องของผู้ใช้ (UA) 92.00% และความถูกต้องของผู้ผลิต (PA) 95.83% สะท้อนให้เห็นว่าแบบจำลองสามารถจับสัญญาณการผลัดใบในช่วง

ฤดูแล้งได้แม่นยำ โดยมีความคลาดเคลื่อนไปเป็นป่าไม้ผลัดใบเพียงเล็กน้อย จำนวน 2 จุดตัวอย่างพบว่าจุดดังกล่าวขึ้นที่ระดับความสูงประมาณ 793 และ 832 เมตร ซึ่งยังคงอยู่ในช่วงความสูงที่เป็นรอยต่อของป่า (Forest ecotone) นอกจากนี้อาจเกิดจากปัจจัยของความชื้นในหุบเขา ที่ทำให้ป่าผลัดใบผสมในบริเวณดังกล่าวมีความชื้นสูงกว่าปกติหรือมีพืชพื้นล่างจำพวกไผ่ (Bamboo) ค่อนข้างหนาแน่น ทำให้พืชยังคงความเขียวสดในช่วงเวลาที่บันทึกภาพ จึงมีลักษณะทางสเปกตรัมคล้ายคลึงกับป่าไม้ผลัดใบ

3. พื้นที่ไม่ใช่ป่า (Non-forest) ในทางสถิติมีความถูกต้องของผู้ใช้ (UA) สูงถึง 100% และความถูกต้องของผู้ผลิต (PA) 97.92% อย่างไรก็ตามจากการตรวจสอบความถูกต้องเชิงพื้นที่บนแผนที่ผลลัพธ์ พบข้อสังเกตที่สำคัญคือ พื้นที่เกษตรกรรมบางแห่งบริเวณชายขอบป่าหรือพื้นที่รอยต่อ ถูกจำแนกคลาดเคลื่อนเป็นพื้นที่ป่า สาเหตุหลักเนื่องจากการศึกษานี้ได้กำหนดชั้นข้อมูลพื้นที่ไม่ใช่ป่า ให้ครอบคลุมทั้งพื้นที่เมือง แหล่งน้ำ และพื้นที่เกษตรกรรม ไว้ในกลุ่มเดียวกัน ทำให้เกิดความแปรปรวนภายในกลุ่มสูง โดยเฉพาะพื้นที่เกษตรกรรมที่มีรอบการเพาะปลูกและการเก็บเกี่ยว (Growing season/planting season) หรือลักษณะทางชีพลักษณ์ (Phenology) คล้ายคลึงกับวงจรการผลัดใบของป่าธรรมชาติ เช่น กลุ่มไม้ผลอายุยาว ได้แก่ สวนส้ม สวนลิ้นจี่ และสวนลำไย ที่อยู่ตามพื้นที่ลาดชัน หรือไหล่เขา มีรูปแบบการแสดงออกทางชีพลักษณ์ของพรรณไม้คล้ายพื้นที่ป่าไม้


**Table 1** Confusion matrix of forest type classification in Chiang Mai Province

		Classified data			Total	PA
		Evergreen forests	Deciduous forests	Non-forest		
Reference data	Evergreen forests	48	3	0	51	94.12%
	Deciduous forests	2	46	0	48	95.83%
	Non-forest	0	1	47	48	97.92%
UA		96.00%	92.00%	100%	147	OA=95.92% Kappa = 0.94

**Remarks:** UA = User accuracy, PA = Producer accuracy, OA = Overall accuracy

ส่งผลให้แบบจำลองเกิดความสับสนในบางพื้นที่ที่มีรูปแบบสเปกตรัมคล้ายคลึงกัน (Figure 5) ผลการศึกษานี้แสดงให้เห็นว่า ข้อมูลภูมิประเทศ โดยเฉพาะระดับความสูง เป็นปัจจัยสำคัญในการจำแนกประเภทป่าไม้ สอดคล้องกับการศึกษาของ Thammanu *et al.* (2021) ในป่าชุมชนภาคเหนือของประเทศไทยซึ่งระดับความสูงและสมบัติดินมีอิทธิพลต่อการกระจายตัวของกลุ่มพรรณไม้ ประเด็นที่น่าสนใจจากการศึกษานี้รูปแบบการกระจายตัวที่สอดคล้องกับหลักนิเวศวิทยาป่าไม้และบริบททางภูมิศาสตร์ พบว่าพื้นที่ไม่ใช่ป่า (Non-forest) ส่วนใหญ่เป็นพื้นที่เกษตรกรรมมักกระจายตัวอยู่ในที่ราบลุ่มระดับต่ำเป็นหลัก เนื่องจากเป็นพื้นที่ที่ง่ายต่อการทำการเกษตรและการคมนาคม แม้จะมีการทำเกษตรบนที่สูงอยู่บ้างก็ตาม ดังกรณีศึกษาที่ดอยสุเทพ-ปุย (Hermhuk *et al.*, 2020) ในส่วนการกระจายตัวของป่าไม้ พบว่าป่าผลัดใบ เช่น ป่าเต็งรังและป่าเบญจพรรณจะกระจายตัวอยู่ในระดับความสูงที่ต่ำกว่า ซึ่งส่วนใหญ่ไม่เกิน 1,000 เมตร ในขณะที่ป่าไม้ผลัดใบจะ

ปรากฏในพื้นที่ระดับความสูงตั้งแต่ 1,000 เมตร เช่น สังกมพิชป่าดิบเขาระดับต่ำและป่าสนเขา



**Figure 5** Example of spatial misclassification where agricultural areas (Non-forest) were incorrectly classified as forest types

จากรายงานของ Khamyong *et al.* (2004) ได้ระบุถึงโครงสร้างสังคมพืชคอยอินทนนท์ และ สอดคล้องกับรูปแบบการใช้ประโยชน์ที่ดินในการศึกษาล่าสุดของ Kamyong *et al.* (2025) ทั้งนี้ตามหลักนิเวศวิทยา สังคมพืชป่าไม้ผลัดใบชนิดป่าดิบแล้ง (Dry evergreen forest) ยังสามารถพบการกระจายตัวแทรกอยู่ในพื้นที่ระดับต่ำกว่า 1,000 เมตรได้ ในบริเวณที่สภาพดินและน้ำมีความอุดมสมบูรณ์ เช่น ตามหุบเขาหรือริมลำธาร อีกประเด็นหนึ่งที่สำคัญคือ พื้นที่รอยต่อทางนิเวศวิทยา ที่ระดับความสูงประมาณ 800–1,150 เมตร ซึ่งมักเป็นจุดอ่อนของการจำแนกด้วยภาพถ่ายดาวเทียมเนื่องจากการผสมผสานของเรือนยอดไม้ แต่การศึกษานี้สามารถจำแนกความแตกต่างได้ด้วย ความแม่นยำสูง สาเหตุหลักมาจากการบูรณาการข้อมูลอนุกรมเวลา ที่ช่วยดึงลักษณะเฉพาะของการทิ้งใบในฤดูแล้งของป่าผลัดใบออกจากป่าไม้ผลัดใบได้อย่างชัดเจน ความสามารถในการจำแนกนี้มีประโยชน์อย่างยิ่งต่อการจัดการไฟป่า ดังที่ Talukdar *et al.* (2024) ได้ระบุไว้ว่า พื้นที่ป่าผลัดใบมีความเสี่ยงต่อการเกิดไฟป่าสูงกว่าป่าชนิดอื่น เนื่องจากปริมาณเชื้อเพลิงสะสม ดังนั้น แผนที่ที่ได้จากการศึกษานี้จึงสามารถนำไปใช้ระบุพื้นที่เสี่ยงไฟป่าในระดับพื้นที่ได้อย่างแม่นยำและมีประสิทธิภาพกว่าข้อมูลแผนที่ป่าไม้แบบกว้าง ๆ ความแม่นยำและศักยภาพในการนำไปประยุกต์ใช้ดังกล่าว ถือว่ามีความสอดคล้องกับงานวิจัยที่ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine learning) เพื่อจำแนกประเภทการใช้ประโยชน์ที่ดินและป่าไม้

ในพื้นที่ภาคเหนือของประเทศไทยในช่วงที่ผ่านมา ตัวอย่างเช่น งานวิจัยของ Kruasilp *et al.* (2023) ที่ประยุกต์ใช้อัลกอริทึมป่าสุ่ม (RFA) ร่วมกับข้อมูลดาวเทียมหลายระบบบนแพลตฟอร์ม GEE เพื่อจำแนกการใช้ประโยชน์ที่ดินจังหวัดน่าน โดยให้ค่าความถูกต้องโดยรวมสูงถึงร้อยละ 96.95 ซึ่งยืนยันถึงประสิทธิภาพของการใช้ข้อมูลเชิงสเปกตรัมร่วมกับปัจจัยทางภูมิประเทศ นอกจากนี้ RFA ยังได้รับการพิสูจน์แล้วว่ามีความมีประสิทธิภาพสูงในการจัดการกับพลวัตทางนิเวศวิทยาที่มีความซับซ้อนในภาคเหนือตอนบน ดังที่ Worachairungreung *et al.* (2024) ได้รายงานผลการเปรียบเทียบแบบจำลอง Machine learning ในพื้นที่จังหวัดแม่ฮ่องสอนและจังหวัดเชียงใหม่ พบว่าแบบจำลอง RFA มีความโดดเด่นเหนืออัลกอริทึมอื่น ๆ ในการวิเคราะห์และจำแนกปัจจัยที่มีอิทธิพลต่อการเปลี่ยนแปลงพื้นที่ป่าไม้ในพื้นที่ภูเขาสูง สอดคล้องกับการศึกษาของ Bihari *et al.* (2025) ที่ได้บูรณาการข้อมูลภาพถ่ายดาวเทียมแบบอนุกรมเวลาร่วมกับแบบจำลอง RFA เพื่อประเมินความน่าจะเป็นของการเกิดไฟป่าตามฤดูกาลใน 9 จังหวัดภาคเหนือตอนบน โดยงานวิจัยดังกล่าวชี้ให้เห็นว่าการมีฐานข้อมูลจำแนกประเภทป่าไม้ที่มีความแม่นยำสูง เป็นปัจจัยพื้นฐานที่สำคัญที่สุดในการบริหารจัดการและลดความเสี่ยงจากไฟป่าได้อย่างมีประสิทธิภาพ การเปรียบเทียบผลการศึกษากับงานวิจัยที่เกี่ยวข้องเหล่านี้ จึงเป็นการยืนยันความน่าเชื่อถือและความทนทานของแบบจำลองในการศึกษานี้ได้อย่างชัดเจน

### สรุป (Conclusion)

การศึกษานี้ประสบความสำเร็จในการประยุกต์ใช้ RFA ร่วมกับข้อมูลภาพถ่ายดาวเทียม Sentinel-2 แบบอนุกรมเวลาบนแพลตฟอร์ม GEE เพื่อจำแนกประเภทป่าในพื้นที่ซับซ้อนของจังหวัดเชียงใหม่ ซึ่งข้อมูลสภาพภูมิประเทศ โดยเฉพาะระดับความสูง และความลาดชัน เป็นปัจจัยที่มีอิทธิพลสูงสุดต่อความถูกต้องของการจำแนกรองลงมาคือ SI และ GNDVI ตามลำดับ แบบจำลองที่พัฒนาขึ้นให้ค่าความถูกต้องโดยรวมสูงถึงร้อยละ 95.92 และค่าสัมประสิทธิ์แคปปา 0.94 ซึ่งยืนยันประสิทธิภาพในการจำแนกความแตกต่างระหว่างป่าผลัดใบและป่าไม่ผลัดใบได้อย่างแม่นยำตามลักษณะภูมิประเทศและชีวลักษณ์ นอกจากนี้การประเมินประสิทธิภาพภายในด้วยค่าความถูกต้องแบบ Out-of-Bag (OOB accuracy) มีค่าสูงถึงร้อยละ 90.30 เป็นหลักฐานทางสถิติที่ช่วยยืนยันความสามารถในการจำแนกของแบบจำลอง และลดข้อกังวลเรื่องการเกิดสภาวะการเรียนรู้เกินพอดี (Overfitting) อีกทั้งการทดสอบแบบแยกส่วน ยังพบว่าหากกำหนดให้แบบจำลองเรียนรู้จากข้อมูลสภาพภูมิประเทศเพียงอย่างเดียว ค่าความถูกต้องจะลดลงอย่างมีนัยสำคัญเหลือเพียงร้อยละ 76.87 เนื่องจากไม่สามารถแยกแยะป่าผลัดใบ ป่าไม่ผลัดใบ และพื้นที่เกษตรกรรมบนที่สูงออกจากพื้นที่ป่าธรรมชาติได้ ในขณะที่การให้แบบจำลองเรียนรู้จากข้อมูลดาวเทียมอนุกรมเวลาเพียงอย่างเดียว กลับให้ค่าความถูกต้องสูงถึงร้อยละ 95.92 ซึ่งเทียบเท่ากับการใช้ชุดข้อมูลนำเข้าแบบครบถ้วน ผลทางสถิติ

ดังกล่าวเป็นเครื่องยืนยันว่า การที่แบบจำลองให้น้ำหนักกับระดับความสูงมากที่สุดนั้นไม่ใช่ข้อบกพร่อง แต่เป็นการสะท้อนความสำคัญของนิเวศวิทยาของพื้นที่ภาคเหนือ โดยระดับความสูงทำหน้าที่เสมือนตัวกรองเชิงพื้นที่ ซึ่งช่วยกำหนดขอบเขตอุณหภูมิและความชื้นเบื้องต้น จากนั้นข้อมูลเชิงสเปกตรัม เช่น ดัชนี GNDVI และ SI จะทำหน้าที่เป็นตัวจำแนกรายละเอียด เพื่อแยกแยะพฤติกรรมการผลัดใบตามฤดูกาล กระบวนการดังกล่าวแสดงให้เห็นถึงรูปแบบการทำงานร่วมกันของชุดข้อมูล ซึ่งช่วยแก้ปัญหาข้อจำกัดของการแปลภาพถ่ายดาวเทียมในพื้นที่ภูเขาสูงที่มีความสลับซับซ้อนได้อย่างมีประสิทธิภาพและสอดคล้องกับความเป็นจริงทางนิเวศวิทยา

การประยุกต์ใช้แผนที่จำแนกชนิดป่าปี พ.ศ. 2567 ที่ได้จากการศึกษานี้ มีความเหมาะสมอย่างยิ่งที่จะนำไปใช้เป็นฐานข้อมูลเชิงพื้นที่สำหรับการบริหารจัดการพื้นที่ไฟป่าและหมอกควัน โดยหน่วยงานที่เกี่ยวข้องสามารถใช้แผนที่นี้ระบุพิกัดและขอบเขตของป่าผลัดใบ (ป่าเต็งรังและป่าเบญจพรรณ) ซึ่งเป็นแหล่งสะสมเชื้อเพลิงแห้งสำคัญในช่วงฤดูแล้ง เพื่อกำหนดเขตพื้นที่เสี่ยง (Risk area) และวางแผนจัดสรรทรัพยากรในการเฝ้าระวังไฟป่าได้อย่างตรงจุดและมีประสิทธิภาพมากกว่าการใช้แผนที่ป่าไม้แบบกว้าง ๆ นอกจากนี้ฐานข้อมูลแผนที่จำแนกชนิดป่าที่มีความละเอียดสูงจากการศึกษานี้ สามารถนำไปประยุกต์ใช้ในงานบริหารจัดการทรัพยากรธรรมชาติมิติอื่น ๆ ได้อย่างกว้างขวาง เช่น การตรวจสอบการบุกรุกพื้นที่ป่า

การประเมินศักยภาพการกักเก็บคาร์บอนในภาคป่าไม้ การบริหารจัดการพื้นที่ต้นน้ำ และการประเมินความเสี่ยงจากการชะล้างพังทลายของดิน เป็นต้น เพื่อสนับสนุนการพัฒนาที่ยั่งยืนต่อไป

แม้ว่าแบบจำลองที่พัฒนาขึ้นให้ค่าความถูกต้องสูงในการจำแนกชนิดป่าไม้ แต่การศึกษาในขั้นยังมีข้อจำกัดที่ควรนำมาพิจารณา ดังนี้

1. ข้อจำกัดของข้อมูลดาวเทียม Sentinel-2 เนื่องจากเป็นระบบเซนเซอร์แบบออปติคัล (Optical sensor) จึงมีข้อจำกัดในการทะลุทะลวงกลุ่มเมฆและหมอกควัน ในพื้นที่ภาคเหนือของประเทศไทย ที่ต้องเผชิญกับปัญหาฝุ่นละอองขนาดเล็ก (PM2.5) หนาแน่นในช่วงฤดูแล้ง และมีปริมาณเมฆปกคลุมหนาแน่นในช่วงฤดูฝน

2. การกำหนดเกณฑ์ปริมาณเมฆ (Cloud cover threshold) ไว้ที่ร้อยละ 60 แม้ว่าการตั้งค่าดังกล่าวจะมีความจำเป็น เพื่อให้ระบบสามารถดึงภาพดาวเทียมมาประมวลผลได้จำนวนมากพอสำหรับการสร้างภาพผสมปราศจากเมฆโดยเฉพาะในช่วงฤดูฝน แต่ปัญหาที่ตามมาคือความเสี่ยงที่จะมีสัญญาณรบกวนตกค้าง เช่น เมฆบาง หรือเงาเมฆ นอกจากนี้ในการสร้างชุดข้อมูลอนุกรมเวลา การกำจัดพิกเซลที่มีเมฆอาจทำให้บางพื้นที่ไม่มีข้อมูล (No data) ซึ่งอาจส่งผลกระทบต่อความต่อเนื่องในการคำนวณค่าดัชนีเชิงสเปกตรัมในบางพิกเซล

3. ข้อจำกัดของการใช้ชุดข้อมูลภาพถ่ายดาวเทียมเพียงปีเดียว เนื่องจากแบบจำลองได้รับการฝึกสอนด้วยข้อมูลพฤติกรรมผลการผลัดใบของช่วงเวลาใดเวลาหนึ่ง ข้อมูลดังกล่าวอาจมีความ

เฉพาะเจาะจงต่อสภาพภูมิอากาศของปีนั้น ๆ ซึ่งอาจไม่เพียงพอและครอบคลุมหากนำแบบจำลองไปประยุกต์ใช้ทำนายข้ามปี เนื่องจากวัฏจักรการผลัดใบอาจมีความคลาดเคลื่อนไปตามความแปรปรวนของสภาพอากาศและปริมาณน้ำฝนในแต่ละปี

### กิตติกรรมประกาศ (Acknowledgement)

งานวิจัยฉบับนี้สำเร็จลุล่วงได้ด้วยดี คณะผู้วิจัยขอขอบคุณ กรมป่าไม้ และ กรมอุทยานแห่งชาติ สัตว์ป่า และพันธุ์พืช เป็นอย่างสูง ที่ให้ความอนุเคราะห์สนับสนุนข้อมูลภาคสนาม และ ข้อมูลสารสนเทศภูมิศาสตร์ ซึ่งเป็นข้อมูลสำคัญยิ่ง ในการฝึกสอนแบบจำลองและตรวจสอบความถูกต้องของผลการศึกษา ทำให้งานวิจัยนี้มีความสมบูรณ์และถูกต้องแม่นยำ และขอขอบคุณเจ้าหน้าที่ทุกท่านที่มีส่วนเกี่ยวข้องในการเก็บรวบรวมข้อมูลและให้คำแนะนำที่เป็นประโยชน์ต่อการดำเนินงานวิจัยในครั้งนี้

### เอกสารอ้างอิง (References)

- Belgiu, M., & L. Dragut. 2016. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing** 114: 2 4 – 3 1 .  
<https://doi.org/10.1016/j.isprsjprs.2016.01.011>

- Bihari, E., Dyson, K., Johnston, K., dela Torre, D. M. G., Chaiyana, A., Tenneson, K., Sittirin, W., Poortinga, A., Tanpipat, V., Wanthongchai, K., Kunlamai, T., Dalton, E., Saisaward, C., Tornorsam, M., Ganz, D., & Saah, D. 2025. Modeling Seasonal Fire Probability in Thailand: A Machine Learning Approach Using Multiyear Remote Sensing Data. **Remote Sensing** 17 ( 19 ) , 3378 . <https://doi.org/10.3390/rs17193378>
- Breiman, L. 2001. Random forests. **Machine Learning** 45 ( 1 ) : 5 – 32 . <https://doi.org/10.1023/A:1010933404324>
- Cheng, K., & J. Wang. 2019. Forest-type classification using time-weighted dynamic time warping analysis in mountain areas: A case study in southern China. **Forests** 10 ( 11 ) : 1040 . <https://doi.org/10.3390/f10111040>
- Congalton, R. G., & K. Green. 2019. **Assessing the accuracy of remotely sensed data: Principles and practices** (3<sup>rd</sup> ed.). CRC Press.
- Cutler, D. R., T. C. Edwards, K. H. Beard, A. Cutler, K. T. Hess, J. Gibson, & J. J. Lawler. 2007. Random forests for classification in ecology. **Ecology** 88(11): 2783–2792. <https://doi.org/10.1890/07-0539.1>
- Department of National Parks, Wildlife and Plant Conservation. 2022. **Forest Statistics**. Available source: <https://portal.dnp.go.th/Content/statistics?contentId=28811>. (Accessed: February 6, 2026).
- Dormann, C. F., J. Elith, S. Bacher, C. Buchmann, G. Carl, G. Carré, J. R. G. Marquéz, B. Gruber, B. Lafourcade, P. J. Leitão, T. Münkemüller, C. McClean, P. E. Osborne, B. Reineking, B. Schröder, A. K. Skidmore, D. Zurell, & S. Lautenbach. 2013. Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. **Ecography** 36(1): 27–46. <https://doi.org/10.1111/j.1600-0587.2012.07348.x>
- Forest Land Management Bureau. 2025. **Forest area data project 2024**. Royal Forest Department. (in Thai)
- Forkuor, G., K. Dimobe, I. Serme, & J. E. Tondoh. 2018. Landsat-8 vs. Sentinel-2: Examining the added value of Sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso. **GIScience & Remote Sensing** 55 ( 3 ) : 331 – 354 . <https://doi.org/10.1080/15481603.2017.1413794>

- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. 2006. Random forests for land cover classification. **Pattern Recognition Letters** 27(4): 294-300.
- Gitelson, A. A., Y. J. Kaufman, & M. N. Merzlyak. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment** 58 ( 3 ) : 289 – 298 .  
[https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Gorelick, N., M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, & R. Moore. 2017. Google earth engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment** 202: 18–27.  
<https://doi.org/10.1016/j.rse.2017.06.031>
- Hermhuk, S., A. Chaiyes, S. Thinkampheang, N. Danrad, & D. Marod. 2020. Land use and above-ground biomass changes in a mountain ecosystem, northern Thailand. **Journal of Forestry Research** 37(5): 1733–1742. <https://doi.org/10.1007/s11676-019-00924-x>
- Jensen, J. R. 2015. **Introductory digital image processing: A remote sensing perspective** (4<sup>th</sup> ed.). Pearson Education.
- Kamyo, T., D. Marod, S. Pattanakiat, & L. Asanok. 2025. Valuation of potential and realized ecosystem services based on land use data in Northern Thailand. **Land** 14(3): 529.  
<https://doi.org/10.3390/land14030529>
- Kawamura, M., S. Jayamana, & Y. Tsujiko. 1996. Relation between social and environmental conditions in Colombo Sri Lanka and the urban index estimated by satellite remote sensing data. **International Archives of Photogrammetry and Remote Sensing** 31: 321–326.
- Khamyong, S., A. M. Lykke, D. Seramethakun, & A. S. Barfod. 2004. Species composition and vegetation structure of an upper montane forest at the summit of Doi Inthanon, Thailand. **Nordic Journal of Botany** 24 ( 1 ) : 73 – 96 .  
<https://doi.org/10.1111/j.1756-1051.2003.tb00371.x>
- Khongseng, P. 2017. **Land use and land cover classification of Phuket province from Landsat 8 satellite imagery using phenological properties** (Master's thesis). Prince of Songkla University. (in Thai)
- Kruasilp, J., Pattanakiat, S., Phutthai, T., Vardhanabindu, P., & Nakmuenwai, P. 2023. Evaluation of Land Use Land Cover Changes in Nan Province, Thailand, Using Multi-Sensor Satellite Data and Google Earth Engine. **Environment and Natural Resources Journal** 21(2): 186–197.  
<https://doi.org/10.32526/enrj/21/202200200>

- McFeeters, S. K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing** 17 ( 7 ) : 1 4 2 5 – 1 4 3 2 .  
<https://doi.org/10.1080/01431169608948714>
- Rikimaru, A. 1997. **Landsat TM data processing guide for forest canopy density mapping and monitoring model**. ITTO Workshop on Utilization of Remote Sensing in Site Assessment and Planning for Logged-over Forests, Bangkok, Thailand.
- Royal Forest Department. 2023. **Forestry statistics 2022**. Royal Forest Department, Ministry of Natural Resources and Environment. (in Thai)
- Royal Irrigation Department. 2020. **Provincial River Basin Development Master Plan Report: Chiang Mai Province**. Project Management Office, Royal Irrigation Department. (in Thai)
- Subcommittee on Drafting National Forest Policy and National Forest Development Master Plan. 2020. **National forest policy**. National Forest Policy Committee. (in Thai)
- Talukdar, S., F. Ahmad, & H. Hashim. 2024. Forest fire in Thailand: Spatio-temporal distribution and future risk identification. **Natural Hazards Research** 4(2): 87–96.  
<https://doi.org/10.1016/j.nhres.2023.09.002>
- Thai Meteorological Department. 2024. **Annual Mean Temperature in Thailand**. Available source:  
<https://www.tmd.go.th/en/ClimateChart/annual-mean-temperature-in-thailand>.  
(Accessed: February 6, 2026).
- Thammanu, S., D. Marod, H. Han, N. Bhusal, L. Asanok, P. Ketdee, N. Gaewsingha, S. Lee, & J. Chung. 2021. The influence of environmental factors on species composition and distribution in a community forest in Northern Thailand. **Journal of Forestry Research** 32: 649–662.  
<https://doi.org/10.1007/s11676-020-01239-y>
- Worachairungreung, M., Kulpanich, N., Yodsuk, P., Ngansakul, P., Thanakunwutthirot, K., & Hemwan, P. (2024). Using a Logistic Regression Model to Examine the Variables Influencing Changes in Northern Thailand's Forest Cover and Comparing Machine Learning Algorithms. **Forests**, 15(6), 981.  
<https://doi.org/10.3390/f15060981>

Yatar, C., S. Thinkampheang, S. Sungkaew, C. Wachrinrat, L. Asanok, T. Kamyao, S. Hermhuk, P. Kachina, J. Thongsawi, W. Phumphuang, A. Yarnvudhi, S. Waengsoyhorn, S. Cheysawat, & D. Marod. 2024. The dynamics of deciduous dipterocarp forest in relation to climate variability in the Sakaerat Biosphere Reserve, Northeastern Thailand. **Biodiversitas Journal of Biological Diversity** 25(7): 3088–3098. <https://doi.org/10.13057/biodiv/d250730>

Yarnvudhi, A., S. Sungkaew, S. Hermhuk, P. Sunthornhao, & S. Onprom, S. 2016. Plant diversity and utilization on ethnobotany of local people at Hmong Doi Pui village in Doi Suthep-Pui national park, Chiang Mai Province. **Thai Journal of Forestry** 35(3): 136-146. (in Thai)

Zhu, X., & D. Liu. 2014. Accurate mapping of forest types using dense seasonal Landsat time-series. **ISPRS Journal of Photogrammetry and Remote Sensing** 96: 1–11. <https://doi.org/10.1016/j.isprsjprs.2014.08.014>