

## A Comparative Study of CNN Architectures Combined with Data Augmentation Techniques for Land Use Classification from Sentinel-2 Satellite Imagery

### การเปรียบเทียบประสิทธิภาพสถาปัตยกรรม CNN ร่วมกับเทคนิคการเสริมข้อมูลสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2

Anusorn Chirakitphattharakun<sup>1</sup>, and Sangdaow Noppitak<sup>2,\*</sup>

อนุสรณ์ จิรกีตภัทรกุล<sup>1</sup>, และ แสงดาว นพพิทักษ์<sup>2,\*</sup>

Received: 15 March 2025;

Revised: 20 April 2025;

Accepted: 21 April 2025;

Published: 23 April 2025;

#### Abstract

Land use classification constitutes a critical component of effective natural resource management and urban planning, providing essential insights into land-use changes and their environmental impacts. This research study aims to construct and evaluate the performance of three Convolutional Neural Network (CNNs) architectures-ResNet50V2, DenseNet121, and EfficientNetV2B0-applied to Sentinel-2 satellite imagery. To address challenges related to data imbalance and overfitting, data augmentation techniques were employed to enhance model robustness. The study area, Tambon Sai Ta Ku, was classified into five distinct land use categories. Among the evaluated models, ResNet50V2 demonstrated superior performance, achieving an accuracy of 88% with data augmentation, followed by DenseNet121 with 77%, while EfficientNetV2B0 exhibited comparatively lower performance at 47%. These findings indicate that ResNet50V2, when combined with data augmentation, is the most effective model for land use classification tasks, underscoring its potential to improve precision in resource management and environmental planning.

**Keywords:** Land Use Classification, Deep Learning, Satellite Image, Data Augmentation

#### บทคัดย่อ

การจำแนกประเภทการใช้ประโยชน์ที่ดินมีบทบาทสำคัญในการจัดการทรัพยากรธรรมชาติและ การวางผังเมือง โดยให้ข้อมูลที่จำเป็นสำหรับการประเมิน การเปลี่ยนแปลงเชิงพื้นที่และผลกระทบต่อระบบนิเวศ วัตถุประสงค์ของงานวิจัย เพื่อสร้างและวิเคราะห์ประสิทธิภาพของสถาปัตยกรรมโครงข่ายประสาทเทียมแบบ คอนโวลชัน (CNNs) สามรูปแบบ ได้แก่ ResNet50V2, DenseNet121 และ EfficientNetV2B0 ในการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่าย ดาวเทียม Sentinel-2 งานวิจัยนี้ได้ประยุกต์ใช้เทคนิคการเสริมข้อมูล เพื่อแก้ไข

<sup>1,\*</sup> Student, Program in Information Technology, Faculty of Science, Buriram Rajabhat University, Buriram 32000, Thailand; นักศึกษา สาขาวิชาเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยราชภัฏบุรีรัมย์ จังหวัดบุรีรัมย์ 31000 ประเทศไทย; Email: 650112418050@bru.ac.th

<sup>2</sup> Lecturer, Dr., Program in Information Technology, Faculty of Science, Buriram Rajabhat University, Buriram 32000, Thailand; อาจารย์ ดร. สาขาวิชาเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยราชภัฏบุรีรัมย์ จังหวัดบุรีรัมย์ 31000 ประเทศไทย; Email: sangdaow.np@bru.ac.th

\*Corresponding authors: Sangdaow Noppitak (sangdaow.np@bru.ac.th)



ปัญหาความไม่สมดุลของชุดข้อมูลและลดปัญหาการเรียนรู้เกิน พื้นที่ศึกษาในตำบลสายตะกูได้รับการจำแนกออกเป็นห้าประเภทการใช้ประโยชน์ที่ดิน ผลการวิเคราะห์แสดงให้เห็นว่า ResNet50V2 มีประสิทธิภาพสูงสุด โดยให้ค่าความถูกต้อง ร้อยละ 88 เมื่อใช้ร่วมกับเทคนิคการเสริมข้อมูล ในขณะที่ DenseNet121 แสดงประสิทธิภาพปานกลางที่ร้อยละ 77 และ EfficientNetV2B0 แสดงประสิทธิภาพต่ำกว่าที่ร้อยละ 47 ผลการศึกษานี้บ่งชี้ว่า ResNet50V2 เมื่อประยุกต์ใช้ร่วมกับเทคนิคการเสริมข้อมูลเป็นวิธีการที่มีประสิทธิภาพสูงสุดสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดิน แสดงให้เห็นถึงศักยภาพในการสนับสนุนการจัดการทรัพยากร และการวางแผนเชิงพื้นที่อย่างมีประสิทธิภาพสำหรับการประยุกต์ใช้ในอนาคต

**คำสำคัญ:** การจำแนกประเภทการใช้ประโยชน์ที่ดิน, การเรียนรู้เชิงลึก, ภาพถ่ายดาวเทียม, การเสริมข้อมูล

## 1. บทนำ (Introduction)

การจำแนกประเภทการใช้ประโยชน์ที่ดิน (Land Use Classification) ถือเป็นกระบวนการที่มีบทบาทสำคัญในการวางแผนและจัดการทรัพยากรธรรมชาติอย่างยั่งยืน โดยเฉพาะอย่างยิ่งในบริบทของการเติบโตของเมือง การเปลี่ยนแปลงของสิ่งแวดล้อม และการใช้ประโยชน์ที่ดินอย่างเข้มข้น ความเข้าใจเกี่ยวกับรูปแบบและการเปลี่ยนแปลงของการใช้ประโยชน์ที่ดินในแต่ละพื้นที่ที่สามารถนำไปใช้ในการวางแผนนโยบายด้านสิ่งแวดล้อม การเกษตร การอนุรักษ์ทรัพยากรธรรมชาติ และการพัฒนาเมืองได้อย่างมีประสิทธิภาพ (Singh et al., 2022; Vali et al., 2020) อย่างไรก็ตาม การรวบรวมข้อมูลที่ดินอย่างต่อเนื่องและครอบคลุมพื้นที่ขนาดใหญ่ยังคงเป็นความท้าทายสำคัญในระดับประเทศและระดับโลก

ในปัจจุบันเทคโนโลยีการสำรวจระยะไกล (Remote Sensing) ได้เข้ามามีบทบาทในการเก็บรวบรวมข้อมูลเชิงพื้นที่จากภาพถ่ายดาวเทียม ซึ่งช่วยลดข้อจำกัดของการสำรวจภาคสนามแบบดั้งเดิมที่ใช้เวลาและงบประมาณสูง โดยเฉพาะอย่างยิ่งภาพถ่ายจากดาวเทียม Sentinel-2 ซึ่งพัฒนาโดยองค์การอวกาศยุโรป (European Space Agency – ESA) ได้กลายเป็นแหล่งข้อมูลสำคัญในการวิเคราะห์การใช้ประโยชน์ที่ดิน เนื่องจากมีความละเอียดเชิงพื้นที่สูงถึง 10 เมตรในบางแถบสเปกตรัม ครอบคลุมถึง 13 แถบสเปกตรัม และมีระยะเวลาในการวนถ่ายภาพซ้ำที่สั้นเพียง 5 วัน ทำให้สามารถติดตามการเปลี่ยนแปลงของพื้นที่ได้อย่างใกล้ชิด (Dobrinic et al., 2020; Zhang et al., 2021)

แม้ว่าข้อมูลภาพถ่ายดาวเทียมจะมีศักยภาพสูง แต่การจำแนกประเภทการใช้ประโยชน์ที่ดินจากข้อมูลดังกล่าวยังคงเผชิญกับความท้าทายสำคัญ เช่น ความซับซ้อนของลักษณะภูมิประเทศ ความคล้ายคลึงกันของข้อมูลสเปกตรัมในบางประเภทที่ดิน รวมถึงปริมาณข้อมูลขนาดใหญ่ที่ต้องใช้ในการวิเคราะห์ ซึ่งเทคนิคการวิเคราะห์แบบดั้งเดิมมักไม่สามารถรองรับได้อย่างมีประสิทธิภาพ ด้วยเหตุนี้ เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) จึงได้รับความสนใจเพิ่มมากขึ้น โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network – CNN) ซึ่งสามารถเรียนรู้ลักษณะเฉพาะของข้อมูลเชิงภาพได้อย่างมีประสิทธิภาพ จึงเหมาะสำหรับการจำแนกการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม อย่างไรก็ตาม การพัฒนาโมเดลการเรียนรู้เชิงลึกที่มีประสิทธิภาพจำเป็นต้องคำนึงถึงหลายปัจจัย เช่น การปรับแต่งค่าพารามิเตอร์ (Hyperparameter Tuning) รวมถึงการจัดการกับปัญหาทางเทคนิค เช่น การเรียนรู้มากเกินไป (Overfitting) และความไม่สมดุลของชุดข้อมูล (Data Imbalance) ซึ่งเป็นปัญหาที่ส่งผลโดยตรงต่อประสิทธิภาพและความแม่นยำของโมเดล (Liang et al., 2020)

งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 โดยให้ความสำคัญกับปัจจัยที่มีผลต่อประสิทธิภาพของโมเดล ได้แก่ คุณภาพของข้อมูล โครงสร้างของโมเดล และการปรับค่าพารามิเตอร์ ซึ่งจะนำไปสู่การพัฒนาโมเดลที่มีความแม่นยำและสามารถประยุกต์ใช้ในงานวางแผนและจัดการทรัพยากรที่ดินได้อย่างมีประสิทธิภาพในอนาคต

## 2. วัตถุประสงค์งานวิจัย (Research Objectives)

เพื่อสร้างและวิเคราะห์ประสิทธิภาพของสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลชัน (CNNs) สามรูปแบบ ได้แก่ ResNet50V2, DenseNet121 และ EfficientNetV2B0 ในการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2

## 3. กรอบแนวคิดงานวิจัย (Conceptual Framework)

การวิจัยนี้เริ่มต้นจากการนำ ข้อมูลนำเข้า ได้แก่ ภาพถ่ายดาวเทียมจาก Sentinel-2 โดยเลือกใช้พื้นที่ศึกษาคือ ตำบลสายตะกู จังหวัดบุรีรัมย์ ซึ่งมีลักษณะการใช้ประโยชน์ที่ดินที่หลากหลาย เช่น เมือง ป่าไม้ พื้นที่เกษตรกรรม และแหล่งน้ำ ข้อมูลภาพถูกคัดกรองให้มีเมฆน้อยกว่า 50% และเลือกเฉพาะแถบสีแดง เขียว และน้ำเงิน (RGB) เพื่อใช้ในการฝึกและทดสอบโมเดลในการจำแนกประเภทการใช้ประโยชน์ที่ดิน

การประมวลผลข้อมูลภาพถ่ายจะถูกแบ่งออกเป็นสองชุด ได้แก่ ชุดข้อมูลสำหรับฝึก (Training Set) และชุดข้อมูลสำหรับทดสอบ (Testing Set) พร้อมทั้งประยุกต์ใช้เทคนิคการเสริมข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายของชุดข้อมูล เช่น การหมุนภาพ การซูม การปรับแสง และการสะท้อนขอบภาพ ซึ่งมีเป้าหมายเพื่อลดปัญหาความไม่สมดุลของข้อมูลและลดความเสี่ยงจากการเรียนรู้เกินในแบบจำลอง

แบบจำลองการเรียนรู้ งานวิจัยนี้เลือกใช้สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลชัน (CNNs) 3 แบบ ได้แก่ ResNet50V2, DenseNet121 และ EfficientNetV2B0 โดยใช้กระบวนการเรียนรู้เชิงลึกและเทคนิค 5-fold Cross Validation เพื่อประเมินประสิทธิภาพของโมเดลผ่านตัวชี้วัด เช่น Accuracy, Precision, Recall, F1-Score และ Confusion Matrix เพื่อวัดความแม่นยำของการจำแนกในแต่ละประเภทการใช้ประโยชน์ที่ดินอย่างละเอียด ผลการประเมินแสดงให้เห็นถึงความแตกต่างของประสิทธิภาพระหว่างสถาปัตยกรรมต่าง ๆ โดยพิจารณาทั้งในกรณีที่มีการใช้เทคนิคการเสริมข้อมูล ซึ่งสามารถใช้เป็นเกณฑ์ในการเลือกแบบจำลองที่มีความเหมาะสมที่สุดสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 ดัง Figure 1.




Figure 1. Conceptual Framework.

#### 4. การทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง (Literature Review)

##### 4.1 สถาปัตยกรรม CNN สำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดิน

การพัฒนาสถาปัตยกรรมเครือข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) สำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม เป็นหัวข้อที่งานวิจัยหลายชิ้นได้ศึกษาอย่างต่อเนื่อง โดยมีพัฒนาการที่เชื่อมโยงกันทั้งด้านการปรับปรุงโมเดล การจัดการข้อมูล และการแก้ไขข้อจำกัดทางปฏิบัติ งานวิจัยของ Kussul et al. (2017) แสดงให้เห็นศักยภาพเบื้องต้นของ CNN ในการแยกแยะการปกคลุมดินและพืชผลทางการเกษตรจากข้อมูล Sentinel-2 ได้ดีกว่าวิธีดั้งเดิม เช่น SVM และ Random Forests เนื่องจาก CNN สามารถดึงคุณลักษณะเชิงพื้นที่และสเปกตรัมได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม งานวิจัยนี้ชี้ให้เห็นข้อจำกัดสำคัญ 2 ประการ คือ (1) ความต้องการข้อมูลสำหรับการเรียนรู้ขนาดใหญ่ และ (2) การประมวลผลที่ใช้ทรัพยากรสูง เพื่อแก้ไขข้อจำกัดดังกล่าว Zhu et al. (2017) ได้เสนอแนวทางในการบูรณาการข้อมูลหลายแหล่ง (Multi-source Data) เช่น การรวมภาพถ่ายดาวเทียม Sentinel-2 และ Landsat-8 พร้อมใช้ข้อมูลแบบหลายช่วงเวลา (Multi-temporal) เพื่อลดการพึ่งพาข้อมูลเรียนรู้ขนาดใหญ่ โดยการวิเคราะห์ความแปรผันตามฤดูกาลช่วยเพิ่มความแม่นยำในการจำแนกประเภทการใช้ประโยชน์ที่ดินได้อย่างมีนัยสำคัญ อย่างไรก็ตาม แนวทางนี้ยังต้องการเทคนิคการเตรียมข้อมูลที่ซับซ้อน ต่อมา Shorten & Khoshgoftaar (2019) ได้ขยายแนวคิดการจัดการข้อมูลด้วยเทคนิคการเสริมข้อมูล (Data Augmentation) เช่น การหมุนภาพ การปรับความสว่าง และการตัดต่อภาพ ซึ่งช่วยเพิ่มความหลากหลายของชุดข้อมูลฝึกแม้มีตัวอย่างจำกัด ส่งผลให้โมเดล CNN ของ Kussul et al. (2017) และ Zhu et al. (2017) มีความทนทานต่อการเกิด Overfitting และทำงานได้ดีขึ้นในสภาพข้อมูลจริง และ Belgiu & Csillik (2018) ชี้ให้เห็นความท้าทายที่ยังคงเหลืออยู่จากการศึกษาที่ผ่านมา ทั้งในแง่ความต้องการข้อมูลติดป้ายกำกับ (Labeled Data) จำนวนมาก และความยากในการถ่ายโอนโมเดล (Transferability) ระหว่างพื้นที่ทางภูมิศาสตร์ที่แตกต่างกัน ซึ่งแนวทางแก้ไขคือการบูรณาการข้อมูลเสริม เช่น ข้อมูลภูมิประเทศ (Topography) หรือการใช้การเรียนรู้แบบกึ่งควบคุม (Semi-supervised Learning) ร่วมกับเทคนิคการเสริมข้อมูลของ Shorten & Khoshgoftaar (2019)

##### 4.2 เทคนิคการเสริมข้อมูล

การเสริมข้อมูล (Data Augmentation) สำหรับการจำแนกการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียมในช่วง 5 ปีที่ผ่านมา แสดงให้เห็นความก้าวหน้าที่เกี่ยวข้องกันในการแก้ปัญหาข้อมูลจำกัดและความซับซ้อนของภูมิประเทศจริง เริ่มต้นจากงานวิจัยของ Alzahem et al. (2023) นำเสนอการใช้ Generative Adversarial Networks (GANs) ร่วมกับ Vision Transformers (ViT) เพื่อสร้างภาพสังเคราะห์จากข้อมูล Sentinel-2 ซึ่งเพิ่มความแม่นยำในการจำแนกประเภทได้ถึง 98.7% อย่างไรก็ตาม ข้อจำกัดด้านทรัพยากรการคำนวณและความซับซ้อนของโมเดลส่งผลให้ Hao et al. (2024) หันมาพัฒนาเทคนิคเสริมข้อมูลแบบดั้งเดิม (Figure 2.) เช่น การหมุนภาพและการพลิกภาพ ร่วมกับสถาปัตยกรรม Swin-UNet ที่ใช้ Transformer ในการดึงบริบทระยะไกล (Long-range Context) ช่วยลดปัญหาการ Overfitting และให้ความแม่นยำ 96.01% ในชุดข้อมูลขนาดเล็ก แต่ยังคงขาดการวิเคราะห์การเปลี่ยนแปลงตามฤดูกาล ซึ่งต่อมา Sierra et al. (2025) ได้แก้ไขด้วยการบูรณาการข้อมูล Sentinel-2 แบบหลายช่วงเวลา (Multi-temporal Data) และการปรับความสว่าง/ความคมชัด ให้ความแม่นยำเพิ่มขึ้น 30% เมื่อใช้โมเดล DeepLabV3+ แต่ยังเผชิญความท้าทายในการสร้างข้อมูลสังเคราะห์ที่สอดคล้องกับภูมิประเทศจริง ส่งผลให้ Paramanathan & Seenivasan (2025) พัฒนา AMSDAN ร่วมกับ Wasserstein GAN โดยใช้กลไก Attention เพื่อโฟกัสพื้นที่สำคัญและสร้างข้อมูลส่วนขอบเขตที่สมจริง แม้ความแม่นยำจะเพิ่มขึ้น 12.34% แต่ยังคงมีข้อจำกัดด้านการคำนวณสูง

##### 4.3 ภาพถ่ายดาวเทียม Sentinel-2

ภาพถ่ายดาวเทียม Sentinel-2 ถูกประยุกต์ใช้ด้านการตรวจสอบสิ่งแวดล้อมและการจัดการทรัพยากรธรรมชาติ โดยเฉพาะอย่างยิ่งในบริบทของประเทศไทย งานวิจัยของ Phiri et al. (2020) ชี้ให้เห็นว่าความละเอียดเชิงพื้นที่ระดับ 10–60 เมตร และความสามารถในการบันทึกข้อมูลหลายช่วงคลื่น (Multispectral) ของ Sentinel-2 ช่วยเพิ่มความแม่นยำในการจำแนกประเภทพืชผลทางการเกษตรได้ถึง 85% เมื่อใช้ข้อมูลจากแถบคลื่น Near-Infrared (NIR) และ Short-Wave Infrared (SWIR) ขณะที่ Lu et al. (2023) พบว่าการประยุกต์ใช้ดัชนีน้ำ (NDWI) จาก Sentinel-2 สามารถตรวจจับพื้นที่น้ำท่วมได้ภายใน 24 ชั่วโมงด้วยความคลาดเคลื่อนเพียง  $\pm 5\%$  ส่วน Llodrà-Llabrés et al. (2023) เน้นย้ำถึงศักยภาพในการตรวจสอบคุณภาพน้ำด้วยการวิเคราะห์ความเข้มข้นของคลอโรฟิลล์-เอ จากแถบคลื่นสีเขียว (Band 3) ที่ให้ค่าสหสัมพันธ์สูงถึง  $R^2 = 0.92$  สำหรับการศึกษาปรากฏการณ์บลูมของสาหร่าย ในด้านการจัดการภัยพิบัติ Gibson et al. (2020)

ระบุว่าดัชนีเผาไหม้ (BAI) จากแถบคลื่น SWIR ของ Sentinel-2 ให้ความแม่นยำในการประเมินความเสี่ยงจากไฟป่าสูงกว่าแบบจำลองเดิมที่ใช้ Landsat-8 ถึง 15% ขณะที่งานล่าสุดของ Mahakalanda et al. (2022) แสดงให้เห็นถึงศักยภาพของการผสมผสานข้อมูล Sentinel-2 กับเทคนิค Deep Learning โดยใช้แถบคลื่น Red Edge (Band 5) และ NIR (Band 8) เพื่อทำนายผลผลิตยางพาราได้แม่นยำถึง 89% ซึ่งสะท้อนถึงความก้าวหน้าทางวิชาการในการใช้ประโยชน์จากข้อมูลดาวเทียมเพื่อการตัดสินใจเชิงนโยบายและการจัดการทรัพยากรอย่างยั่งยืน




Figure 2. Example images of data augmentation techniques.

#### 4.4 การประเมินประสิทธิภาพโมเดล

การประเมินประสิทธิภาพโมเดลด้วย Confusion Matrix เป็นตารางที่ใช้ประเมินประสิทธิภาพของโมเดลการจำแนกประเภท (Classification) โดยเปรียบเทียบค่าจริง (Actual) กับค่าที่คาดการณ์ (Predicted) ประกอบด้วยค่า True Negative (TN), False Positive (FP), False Negative (FN), และ True Positive (TP) ซึ่งใช้คำนวณค่าประเมินสำคัญได้แก่ ค่าความถูกต้อง (Accuracy) ดังสมการที่ 1) ค่าความแม่นยำ (Precision) ดังสมการที่ 2) ค่าการเรียกคืน (Recall) ดังสมการที่ 3) และค่าคะแนนเอฟวัน (F1-score) ดังสมการที่ 4) (Sudta, 2023)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad \dots (1)$$

$$Precision = \frac{TP}{TP+FP} \quad \dots (2)$$

$$Recall = \frac{TP}{TP+FN} \quad \dots (3)$$

$$F_1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad \dots (4)$$

#### 5. วิธีดำเนินงานวิจัย (Research Methodology)

การศึกษานี้มีจุดมุ่งสร้างและวิเคราะห์ประสิทธิภาพโครงข่ายประสาทแบบคอนโวลูชันด้วยเรียนรู้เชิงลึก สำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินโดยใช้ข้อมูลจากดาวเทียม Sentinel-2 โดยมีขั้นตอนการดำเนินงานดังต่อไปนี้

## 5.1 การรวบรวมข้อมูลจาก Sentinel-2


การศึกษานี้ดำเนินการรวบรวมข้อมูลภาพถ่ายดาวเทียม Sentinel-2 โดยใช้ Python ไลบรารี pystac\_client สำหรับค้นหาข้อมูลภาพถ่ายดาวเทียมจาก Sentinel-2 ผ่าน API ของ Earth Search แล้วทำการค้นหาภาพถ่ายที่ครอบคลุมพิกัด (Lon, Lat) จากชุดข้อมูล Sentinel-2 ระบุช่วงเวลาตามภาพถ่ายทางอากาศ Google Earth Pro ระหว่างวันที่ 6 กุมภาพันธ์ 2021 ถึงวันที่ 14 มีนาคม 2023 กรองภาพที่มีปริมาณเมฆครอบคลุมน้อยกว่า 50% และเลือกเฉพาะแถบสี (Band) Red, Green, และ Blue แล้วทำการปรับข้อมูลภาพถ่ายให้เป็นรายสัปดาห์ เพื่อสร้างชุดข้อมูลสำหรับการเรียนรู้และทดสอบ

## 5.2 การเตรียมข้อมูล

1. การศึกษานี้เลือกเขตพื้นที่ตำบลสายตะกู อำเภอบ้านกรวด จังหวัดบุรีรัมย์ เนื่องจากเป็นพื้นที่ที่มีความหลากหลายทางการใช้ประโยชน์ที่ดิน ได้แก่ พื้นที่เกษตรกรรมที่ครอบคลุมพืชเศรษฐกิจสำคัญ (เช่น ข้าว และสวนยางพารา เป็นต้น) แหล่งน้ำตามธรรมชาติและแหล่งน้ำที่มนุษย์สร้างขึ้น นอกจากนี้ยังมีป่าไม้และพื้นที่อยู่อาศัยที่กระจายตัวอย่างชัดเจน ซึ่งมีการเปลี่ยนแปลงการใช้ประโยชน์ที่ดินอย่างรวดเร็วจากการขยายพื้นที่การเกษตรและการพัฒนาโครงสร้างพื้นฐาน ลักษณะภูมิประเทศที่หลากหลายและการเปลี่ยนแปลงที่ชัดเจนทำให้เหมาะสำหรับการศึกษาเชิงลึกเกี่ยวกับการจำแนกประเภทการใช้ประโยชน์ที่ดิน โดยใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ที่มีความละเอียดสูงและสามารถติดตามการเปลี่ยนแปลงพื้นที่ได้อย่างแม่นยำ ดัง Figure 3(a)

2. การจัดเตรียมข้อมูลสำหรับการวิเคราะห์ด้วยการเรียนรู้เชิงลึกดำเนินการผ่านระบบสารสนเทศภูมิศาสตร์ (QGIS, 2024) โดยเริ่มจากการตรวจสอบภาพถ่ายพื้นที่ศึกษาจาก Google Map และทำการคัดเลือกพื้นที่ตัวอย่างสำหรับแต่ละประเภทที่ดิน การจำแนกประเภทการใช้ประโยชน์ที่ดินในการศึกษานี้แบ่งออกเป็น 5 ประเภทหลัก ได้แก่ เมือง (Urban: U) แหล่งน้ำ (Water: W) สวนยางพารา (Rubber Plantation: P) นาข้าว (Rice Field: R) และป่าไม้ (Forest: F) ซึ่งแสดงตัวอย่างการจำแนกประเภทการใช้ประโยชน์ที่ดินด้วยระบบสารสนเทศภูมิศาสตร์ โดยใช้สีที่แตกต่างกันเพื่อแสดงการใช้ประโยชน์ที่ดินแต่ละประเภท โดยสีเขียวอ่อนแทนพื้นที่สวนยาง สีส้มแทนพื้นที่เมือง และสีฟ้าแทนพื้นที่แหล่งน้ำดัง Figure 3(b)

3. การกำหนดจุดตัวอย่างด้วยวิธีการสุ่มเชิงพื้นที่ (Spatial Random Sampling) โดยใช้เทคนิคการสร้างจุดสุ่ม (Random Points) เพื่อกำหนดตำแหน่งพิกัดสำหรับการเก็บข้อมูลภาพถ่ายดาวเทียม Sentinel-2 การศึกษานี้กำหนดให้แต่ละประเภทการใช้ประโยชน์ที่ดินมีจุดสุ่มตัวอย่างจำนวน 10 จุด ครอบคลุมทั้ง 5 ประเภท รวมทั้งสิ้น 50 จุดตัวอย่าง ซึ่งแสดงการกระจายตัวของจุดสุ่มตัวอย่างบนพื้นที่ศึกษา โดยการกระจายตัวของจุดสุ่มนี้ช่วยให้ได้ข้อมูลที่เป็นตัวแทนของแต่ละประเภทการใช้ประโยชน์ที่ดินอย่างครอบคลุมและเป็นระบบ ดัง Figure 3(c)



**Figure 3.** (a) SaiTaKu Subdistrict Study Area, (b) Land use classification, and (c) Randomly select sample coordinate points.

4. การจัดเตรียมชุดข้อมูลสำหรับพัฒนาแบบจำลองการเรียนรู้เชิงลึก ได้ดำเนินการรวบรวมชุดข้อมูลภาพถ่ายดาวเทียม Sentinel-2 จำนวน 2,500 ภาพ แบ่งเป็นชุดข้อมูลเรียนรู้ (Training Dataset) 2,000 ภาพ และชุดทดสอบ (Testing Dataset) 500 ภาพ ในการจำแนกประเภทการใช้ประโยชน์ที่ดิน 5 ประเภท ได้แก่ เมือง (U) แหล่งน้ำ (W) สวนยางพารา (P) นาข้าว (R) และป่าไม้ (F) โดยจัดสรรจำนวนภาพเท่ากันแต่ละประเภท (ชุดเรียนรู้ 400 ภาพ ชุดทดสอบ 100 ภาพ) เพื่อลดปัญหาความไม่สมดุลของข้อมูลและเพิ่มประสิทธิภาพในการเรียนรู้ของแบบจำลอง ดัง Table 1.

**Table 1.** Satellite Image Dataset Table of Sentinel-2

| Type                  | Train | Test |
|-----------------------|-------|------|
| U - Urban Area        | 400   | 100  |
| W - Water Source      | 400   | 100  |
| P - Rubber Plantation | 400   | 100  |
| R - Rice Field        | 400   | 100  |
| F - Forest            | 400   | 100  |

### 5.3 การพัฒนาแบบจำลองการเรียนรู้เชิงลึก

การพัฒนาแบบจำลองในงานวิจัยนี้ดำเนินการโดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกผ่าน CNN สำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 โดยคัดเลือกสถาปัตยกรรมโครงข่ายที่มีประสิทธิภาพสูงสามรูปแบบ ได้แก่ ResNet50V2, DenseNet121 และ EfficientNetV2B0 พร้อมทั้งประยุกต์ใช้เทคนิคการเสริมข้อมูล เพื่อเพิ่มความหลากหลายของข้อมูลและลดปัญหา Overfitting อาทิ การหมุนภาพ การพลิกภาพ และการปรับค่าความสว่าง จากนั้นดำเนินการฝึกแบบจำลองด้วยชุดข้อมูลที่แบ่งเป็นชุดฝึกและชุดทดสอบในสัดส่วน 80:20 และประเมินประสิทธิภาพของแบบจำลองโดยใช้ตัวชี้วัดหลายมิติ ได้แก่ ค่าความถูกต้อง ค่าความแม่นยำ ค่าการเรียกคืน และค่าคะแนนเอฟวัน รวมถึงการวิเคราะห์รายละเอียดการจำแนกประเภทด้วย Confusion Matrix เพื่อคัดเลือกแบบจำลองที่มีประสิทธิภาพสูงสุดสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2

### 5.4 เทคนิคการเสริมข้อมูล

การศึกษานี้ได้ประยุกต์ใช้เทคนิคการเสริมข้อมูลหลายรูปแบบ ได้แก่ การหมุนภาพ  $\pm 15$  องศา เพื่อจำลองมุมมองที่แตกต่างกัน การเลื่อนภาพแนวนอนและแนวตั้ง โดยเลื่อนภาพ 5% ของความกว้างและความสูง เพื่อเพิ่มความยืดหยุ่นในตำแหน่งของข้อมูล การบิดเบี้ยวภาพ 1% เพื่อเพิ่มความหลากหลายเชิงโครงสร้าง การซูมเข้า-ออกโดยปรับขนาดภาพ  $\pm 10\%$  เพื่อจำลองระยะทางที่ต่างกัน การปรับความสว่างโดยเปลี่ยนความสว่างเล็กน้อยระหว่าง 0.95-1.05 เพื่อรองรับสภาพแสงที่แตกต่างกัน และการเติมพิกเซลนอกขอบภาพด้วยการสะท้อน เพื่อป้องกันข้อมูลสูญเสียชีวิตบริเวณขอบภาพ ซึ่งเทคนิคเหล่านี้ช่วยให้ชุดข้อมูลมีความหลากหลายมากขึ้น และยังคงรักษาลักษณะสำคัญของภาพเดิมไว้ ลดโอกาสเกิดการเรียนรู้เกินและเพิ่มประสิทธิภาพของแบบจำลองในการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 ได้อย่างแม่นยำดัง Figure 2.

## 6. ผลการวิจัย (Results)

การศึกษานี้ได้ดำเนินการสร้างและปรับแต่งแบบจำลองการเรียนรู้เชิงลึกสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 โดยทำการทดสอบประสิทธิภาพของแบบจำลองในสองเงื่อนไข คือ การใช้และไม่ใช้เทคนิคการเพิ่มความหลากหลายของข้อมูล การวิเคราะห์ข้อมูลได้เปรียบเทียบประสิทธิภาพของสถาปัตยกรรมโครงข่ายสามรูปแบบ ได้แก่ ResNet50V2, DenseNet121 และ EfficientNetV2B0 โดยกำหนดค่าพารามิเตอร์พื้นฐานดังนี้ ตัวปรับค่าความเหมาะสม (Optimizer) แบบ Adam ที่มีอัตราการเรียนรู้ 0.01 ฟังก์ชันการสูญเสีย (Loss Function) แบบ Categorical Crossentropy จำนวนรอบการเรียนรู้ 100 รอบ (Epochs) ขนาดชุดข้อมูลย่อย (Batch Size) 64 และใช้การตรวจสอบไขว้แบบ 5-fold

### 6.1 ผลการเรียนรู้และทดสอบประสิทธิภาพของแบบจำลองในการจำแนกประเภทการใช้ประโยชน์ที่ดินแบบใช้และไม่ใช้เทคนิคการเสริมข้อมูล


การประเมินประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกทั้งสามสถาปัตยกรรม ได้แก่ ResNet50V2, DenseNet121 และ EfficientNetV2B0 ดำเนินการผ่านการวิเคราะห์ประสิทธิภาพ ประกอบด้วย ค่าความถูกต้อง ค่าความแม่นยำ ค่าการเรียกคืน และค่าคะแนนเอฟวัน ผลการวิเคราะห์แสดงให้เห็นว่า แบบจำลอง ResNet50V2 แสดงประสิทธิภาพสูงสุดในทุกเมตริกการวัด โดยมีค่าความถูกต้องที่ร้อยละ 98 - 99 ทั้งในกรณีที่มีและไม่มีการใช้เทคนิคการเสริมข้อมูล รองลงมาคือ DenseNet121 ที่แสดงประสิทธิภาพในระดับที่ดี โดยมีค่าความถูกต้องและค่าเมตริกอื่น ๆ อยู่

ประมาณร้อยละ 97 - 99 ในขณะที่ EfficientNetV2B0 แสดงประสิทธิภาพต่ำที่สุด โดยมีค่าความถูกต้องเพียงร้อยละ 47 - 50 และค่าเมตริกอื่น ๆ ต่ำกว่าร้อยละ 45 ดัง Table 2.

**Table 2.** Comparison Results of ResNet50V2, DenseNet121, and EfficientNetV2B0 Model Performance in Land Use Classification Using Performance Metric Values.

| Models           | Data Augmentation | Accuracy (%)       | Precision (%)      | Recall (%)         | F1 Score (%)       |
|------------------|-------------------|--------------------|--------------------|--------------------|--------------------|
| ResNet50V2       | Yes               | 98 ( $\pm 0.006$ ) | 98 ( $\pm 0.007$ ) | 98 ( $\pm 0.007$ ) | 98 ( $\pm 0.007$ ) |
| ResNet50V2       | No                | 99 ( $\pm 0.002$ ) | 99 ( $\pm 0.003$ ) | 99 ( $\pm 0.003$ ) | 99 ( $\pm 0.003$ ) |
| DenseNet121      | Yes               | 98 ( $\pm 0.007$ ) | 97 ( $\pm 0.009$ ) | 97 ( $\pm 0.009$ ) | 97 ( $\pm 0.009$ ) |
| DenseNet121      | No                | 99 ( $\pm 0.004$ ) | 99 ( $\pm 0.003$ ) | 99 ( $\pm 0.003$ ) | 99 ( $\pm 0.003$ ) |
| EfficientNetV2B0 | Yes               | 50 ( $\pm 0.010$ ) | 42 ( $\pm 0.049$ ) | 39 ( $\pm 0.026$ ) | 34 ( $\pm 0.034$ ) |
| EfficientNetV2B0 | No                | 47 ( $\pm 0.217$ ) | 38 ( $\pm 0.072$ ) | 39 ( $\pm 0.056$ ) | 35 ( $\pm 0.075$ ) |

การประเมินประสิทธิภาพของแบบจำลองได้ดำเนินการผ่านวิธีการตรวจสอบไขว้แบบ 5 ส่วน (5-fold Cross-Validation) โดยทำการแบ่งชุดข้อมูลออกเป็น 5 ส่วนที่มีขนาดเท่ากัน การทดสอบถูกดำเนินการภายใต้สองสถานะการทดลอง ได้แก่ การประยุกต์ใช้และไม่ใช้เทคนิคการเสริมข้อมูล ผลการวิเคราะห์แสดงให้เห็นถึงความแปรปรวนของประสิทธิภาพในแต่ละส่วนของการตรวจสอบไขว้ในแต่ละ Fold ดัง Figure 4.




**Figure 4.** Comparison of Accuracy with and without Data Augmentation (a) ResNet50V2, (b) DenseNet121, and (c) EfficientNetV2B0.

จาก Figure 4. แสดงผลการวิเคราะห์ประสิทธิภาพของโมเดล ResNet50V2, DenseNet121 และ EfficientNetV2B0 ในการจำแนกประเภทการใช้ประโยชน์ที่ดิน โดยใช้วิธี 5-fold Cross-Validation และเปรียบเทียบแบบการใช้และไม่ใช้เทคนิคการเสริมข้อมูล ผลการวิเคราะห์แสดงให้เห็นว่าโมเดล ResNet50V2 มีค่าความแม่นยำสูงและคงที่ในช่วงร้อยละ 97 - 99 ในทุก Fold โดยความแตกต่างของผลลัพธ์แบบการใช้และไม่ใช้การเสริมข้อมูล มีค่าไม่แตกต่างกันมากนัก แสดงให้เห็นถึงความเสถียรและความน่าเชื่อถือของโมเดลในการประมวลผลข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ดัง Figure 4(a)

จาก Figure 4(b) แสดงผลการวิเคราะห์ประสิทธิภาพของโมเดล DenseNet121 ผลลัพธ์อยู่ในช่วงร้อยละ 96 - 99 ซึ่งมีความใกล้เคียงกับ ResNet50V2 อย่างไรก็ตาม การใช้เทคนิคการเสริมข้อมูล ช่วยเพิ่มประสิทธิภาพของโมเดลในบาง Fold โดยเฉพาะ Fold 1 และ Fold 4 ที่มีความแตกต่างในการใช้เทคนิคการเสริมข้อมูล และไม่ใช้เทคนิคการเสริมข้อมูล อย่างเห็นได้ชัด แสดงให้เห็นว่าเทคนิคนี้มีส่วนช่วยปรับปรุงความแม่นยำของโมเดลในกรณีของ DenseNet121

จาก Figure 4(c) แสดงผลการวิเคราะห์ประสิทธิภาพของโมเดล EfficientNetV2B0 ผลลัพธ์มีค่าความแม่นยำต่ำกว่ามากเมื่อเทียบกับสองโมเดลแรก โดยค่าความแม่นยำอยู่ในช่วงร้อยละ 34-40 ทั้งนี้ การใช้เทคนิคการเสริมข้อมูล ส่งผลให้ค่าความแม่นยำเพิ่มขึ้นในทุก Fold อย่างไรก็ตาม ค่าที่ได้ยังคงต่ำกว่าโมเดลอื่น ๆ อย่างมาก ซึ่งอาจบ่งชี้ว่า EfficientNetV2B0 ไม่เหมาะสมกับชุดข้อมูลและการตั้งค่าการทดลองในครั้งนี้

การวิเคราะห์ประสิทธิภาพของโมเดล ResNet50V2 มีประสิทธิภาพสูงในการจำแนกประเภทการใช้ประโยชน์ที่ดิน โดยเฉพาะในกรณีไม่มีการเสริมข้อมูล ซึ่งสามารถจำแนกตัวอย่างในทุกคลาสได้อย่างถูกต้องทั้งหมด 400 ตัวอย่าง อย่างไรก็ตาม ในกรณีที่มีการเสริมข้อมูล พบข้อผิดพลาดเล็กน้อยในบางคลาส เช่น คลาส P ผิดพลาดในคลาส R จำนวน 6 ตัวอย่าง และคลาส R ผิดพลาดในคลาส W จำนวน 6 ตัวอย่าง การเพิ่มข้อมูลอาจส่งผลให้แบบจำลองต้องเผชิญกับความหลากหลายของตัวอย่างที่มากขึ้น ทำให้เกิดข้อผิดพลาดเล็กน้อยในคลาสที่มีคุณลักษณะใกล้เคียงกัน ดัง Figure 5.




**Figure 5.** Comparison of ResNet50V2 model performance in land use classification using confusion matrix between a) with data augmentation and b) without data augmentation.

## 6.2 การเปรียบเทียบประสิทธิภาพการจำแนกประเภทการใช้ประโยชน์ที่ดินด้วย Confusion Matrix

ผลการวิเคราะห์ประสิทธิภาพจากชุดข้อมูลการเรียนรู้ของโมเดลที่ดีที่สุดทั้งสามสถาปัตยกรรม พบว่า ResNet50V2 และ DenseNet121 การจำแนกประเภทการใช้ประโยชน์ที่ดินแสดงค่าความถูกต้องที่ใกล้เคียงกัน โดยแบบจำลอง ResNet50V2 ที่ประยุกต์ใช้เทคนิคการเสริมข้อมูลให้ค่าความถูกต้องร้อยละ 98 และเมื่อไม่มีการใช้เทคนิคการเสริมข้อมูลให้ค่าความถูกต้องร้อยละ 99 ในทำนองเดียวกัน แบบจำลอง DenseNet121 แสดงค่าความถูกต้องร้อยละ 98 และ 99 ในกรณีที่มีและไม่มีการเสริมข้อมูลตามลำดับ อย่างไรก็ตาม แบบจำลอง EfficientNetV2B0 แสดงประสิทธิภาพต่ำที่สุด โดยมีค่าความถูกต้องเพียงร้อยละ 50 และ 47 ในกรณีที่มีและไม่มีการเสริมข้อมูลตามลำดับ ดัง Figure 6(a)

ผลการวิเคราะห์ประสิทธิภาพจากชุดข้อมูลทดสอบของโมเดลที่ดีที่สุดทั้งสามสถาปัตยกรรม พบว่า ResNet50V2 แสดงค่าความถูกต้องสูงสุดทั้งในกรณีที่มีการประยุกต์ใช้เทคนิคการเสริมข้อมูล (ร้อยละ 88) และไม่มีการเสริมข้อมูล

(ร้อยละ 81) ในขณะที่แบบจำลอง DenseNet121 แสดงประสิทธิภาพในระดับปานกลาง โดยมีค่าความถูกต้องร้อยละ 77 เมื่อใช้เทคนิคการเสริมข้อมูล และร้อยละ 74 เมื่อไม่ใช้เทคนิคการเสริมข้อมูล ส่วนแบบจำลอง EfficientNetV2B0 แสดงประสิทธิภาพต่ำที่สุด โดยมีค่าความถูกต้องเพียงร้อยละ 44 และ 47 ในกรณีที่มีและไม่มีการเสริมข้อมูลตามลำดับ ดัง Figure 6(b)



**Figure 6.** Comparative analysis of ResNet50V2, DenseNet121, and EfficientNetV2B0 model performance in land use classification: Evaluation of data augmentation impact on a) training set and b) testing set.

## 7. สรุปผลการวิจัย (Conclusion)

ผลการวิเคราะห์ พบว่า แบบจำลอง ResNet50V2 แสดงประสิทธิภาพสูงสุด โดยมีค่าความถูกต้องร้อยละ 88 เมื่อประยุกต์ใช้เทคนิคการเสริมข้อมูล และร้อยละ 81 ในกรณีที่ไม่ใช้เทคนิคดังกล่าว รองลงมาคือ DenseNet121 ที่แสดงค่าความถูกต้องร้อยละ 77 และ 74 ตามลำดับ ในทางตรงกันข้าม EfficientNetV2B0 แสดงประสิทธิภาพต่ำที่สุด โดยมีค่าความถูกต้องเพียงร้อยละ 44 และ 47 ตามลำดับ การประยุกต์ใช้เทคนิคการเสริมข้อมูลแสดงให้เห็นผลกระทบเชิงบวกต่อประสิทธิภาพของแบบจำลอง โดยเฉพาะอย่างยิ่งใน ResNet50V2 และ DenseNet121 ซึ่งแสดงการปรับปรุงประสิทธิภาพด้วยเทคนิคดังกล่าวช่วยเพิ่มความสามารถในการปรับตัวของแบบจำลองต่อความหลากหลายของข้อมูลภาพถ่าย อย่างไรก็ตาม EfficientNetV2B0 กลับแสดงข้อจำกัดในการประมวลผลข้อมูลต่ำที่สุด ส่งผลให้มีประสิทธิภาพต่ำในทุกสถานการณ์การทดสอบ จากผลการศึกษาสามารถสรุปได้ว่า ResNet50V2 เป็นสถาปัตยกรรมที่เหมาะสมที่สุดสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 โดยการประยุกต์ใช้เทคนิคการเสริมข้อมูล สามารถเพิ่มประสิทธิภาพการจำแนกได้เป็นอย่างดี ในขณะที่ DenseNet121 แสดงศักยภาพเป็นทางเลือกที่น่าพิจารณา แต่ EfficientNetV2B0 ไม่เหมาะสมสำหรับการประยุกต์ใช้ในกรณีของการศึกษานี้ EfficientNetV2B0 แสดงประสิทธิภาพต่ำกว่าโมเดลอื่น ๆ โดยมีค่าความถูกต้องเพียงร้อยละ 50 เมื่อใช้เทคนิคการเสริมข้อมูล และร้อยละ 47 เมื่อไม่ได้ใช้เทคนิคดังกล่าว รวมถึงความแม่นยำ และค่าความครอบคลุม ที่ต่ำกว่าเกณฑ์มาตรฐาน สาเหตุที่ EfficientNetV2B0 มีประสิทธิภาพต่ำอาจเกิดจากข้อจำกัดหลายประการ เช่น โครงสร้างโมเดลที่ไม่เหมาะสมกับลักษณะของข้อมูลภาพถ่ายดาวเทียม Sentinel-2 อีกทั้ง EfficientNetV2B0 ถูกออกแบบมาเพื่อเพิ่มประสิทธิภาพในการคำนวณ (Efficiency) มากกว่าความแม่นยำในกรณีของข้อมูลที่ซับซ้อน การใช้สถาปัตยกรรมดังกล่าวในปัญหาที่ต้องการความสามารถในการเรียนรู้คุณลักษณะเชิงพื้นที่ เช่น การจำแนกประเภทการใช้ประโยชน์ที่ดิน อาจทำให้โมเดลไม่สามารถดึงข้อมูลสำคัญได้อย่างเต็มที่

## 8. อภิปรายผลการวิจัย (Discussion)

ผลการวิจัยในครั้งนี้แสดงให้เห็นว่า ResNet50V2 เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงสุดในการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 โดยสามารถให้ค่าความแม่นยำสูงสุดถึงร้อยละ 88 เมื่อใช้เทคนิคการเสริมข้อมูล (Data Augmentation) ซึ่งสอดคล้องกับงานวิจัยก่อนหน้า Singh et al. (2022) และ Zhang et al. (2021) ที่ชี้ให้เห็นว่าโครงข่ายประสาทเชิงลึกสามารถเพิ่มความแม่นยำในการจำแนกประเภทการใช้ประโยชน์ที่ดินได้อย่างมีประสิทธิภาพเมื่อใช้เทคนิคที่เหมาะสม ผลลัพธ์นี้อธิบายได้จากหลักการของ Residual Connections ใน

ResNet50V2 ที่ช่วยลดปัญหาการสูญหายของ กราเดียนต์ (Vanishing Gradient Problem) ซึ่งเป็นปัจจัยสำคัญที่ส่งผลต่อการเรียนรู้ของแบบจำลองที่มีความลึกมาก งานวิจัยของ Wubineh et al. (2024) ยืนยันว่าโครงข่าย ResNet50V2 มีประสิทธิภาพสูงในการจำแนกภาพที่มีลักษณะซับซ้อน เนื่องจากสามารถเรียนรู้คุณลักษณะของข้อมูลได้ลึกขึ้นโดยไม่สูญเสียประสิทธิภาพ ในขณะที่เดียวกัน DenseNet121 แสดงให้เห็นว่ามีประสิทธิภาพรองลงมา ด้วยค่าความแม่นยำร้อยละ 77 เมื่อใช้การเสริมข้อมูล ความสามารถของ DenseNet121 ในการแก้ปัญหาคุณลักษณะผ่าน Dense Connections ทำให้สามารถเรียนรู้ข้อมูลจากภาพถ่ายดาวเทียมได้ดี อย่างไรก็ตาม ค่าความแม่นยำที่ต่ำกว่า ResNet50V2 อาจเนื่องมาจากโครงสร้างของ DenseNet ที่มีความซับซ้อนมากขึ้น ทำให้เกิดปัญหาการคำนวณที่มากกว่าปกติเมื่อจัดการกับข้อมูลภาพถ่ายจาก Sentinel-2 สำหรับ EfficientNetV2B0 นั้นแสดงประสิทธิภาพต่ำสุด ด้วยค่าความแม่นยำร้อยละ 47 เมื่อใช้เทคนิคการเสริมข้อมูล และร้อยละ 44 เมื่อนำไปใช้ในการทดสอบจริง ซึ่งสอดคล้องกับงานวิจัยของ Gerdan Koc et al. (2024) ที่ได้ระบุว่า EfficientNetV2B0 ออกแบบมาเพื่อเพิ่มประสิทธิภาพด้านการคำนวณมากกว่าความแม่นยำ จึงอาจไม่เหมาะสมสำหรับปัญหาที่ต้องการการเรียนรู้คุณลักษณะเชิงพื้นที่ที่ซับซ้อน เช่น การจำแนกประเภทการใช้ประโยชน์ที่ดิน นอกจากนี้ การใช้เทคนิคการเสริมข้อมูลช่วยเพิ่มความแม่นยำของแบบจำลองโดยเฉพาะใน ResNet50V2 และ DenseNet121 ซึ่งสอดคล้องกับงานวิจัยของ Murel & Kavlakoglu (2024) ที่แสดงให้เห็นว่าการเสริมข้อมูลสามารถช่วยลดปัญหาความไม่สมดุลของข้อมูล (Data Imbalance) และปัญหาการเรียนรู้เกินได้ อย่างไรก็ตาม ผลลัพธ์จาก Confusion Matrix แสดงให้เห็นว่าในบางกรณีการเสริมข้อมูลอาจทำให้เกิดข้อผิดพลาดเพิ่มขึ้น เนื่องจากแบบจำลองต้องเผชิญกับตัวอย่างข้อมูลที่มีความหลากหลายมากขึ้น โดยสรุป งานวิจัยนี้ยืนยันว่า ResNet50V2 เป็นสถาปัตยกรรมที่เหมาะสมที่สุดสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดินจากภาพถ่ายดาวเทียม Sentinel-2 และการใช้ เทคนิคการเสริมข้อมูล สามารถช่วยเพิ่มประสิทธิภาพของแบบจำลองได้อย่างชัดเจน อย่างไรก็ตาม EfficientNetV2B0 อาจไม่เหมาะสมกับการประยุกต์ใช้ในการศึกษาครั้งนี้

## 9. ข้อเสนอแนะงานวิจัย (Recommendation)

ข้อเสนอแนะงานวิจัยสำหรับการศึกษาในอนาคต ควรพิจารณาตรวจสอบสถาปัตยกรรมการเรียนรู้เชิงลึกที่ทันสมัย เช่น Vision Transformers (ViTs) (Khan et al., 2024; Rozario et al., 2024) หรือการใช้โมเดลโครงข่ายประสาทแบบคอนโวลูชันร่วมกับ Attention Mechanism (Seydi et al., 2022; Wang et al., 2021) เพื่อเพิ่มประสิทธิภาพในการจำแนกประเภทการใช้ประโยชน์ที่ดิน นอกจากนี้ การรวมข้อมูลภาพถ่ายดาวเทียมแบบอนุกรมเวลา (Time-series Data) เช่น ข้อมูลจาก Sentinel-2, Landsat-8, และ PlanetScope เป็นต้น ซึ่งมีความละเอียดเชิงพื้นที่และเชิงเวลาที่หลากหลาย อาจช่วยเพิ่มความแม่นยำในการติดตามการเปลี่ยนแปลงของพื้นที่ อีกทั้งการผสมผสานแหล่งข้อมูลอื่น ๆ ได้แก่ ข้อมูล LiDAR หรือข้อมูลภาคพื้นดินจะช่วยเพิ่มความละเอียดและความลึกซึ้งของชุดข้อมูล รวมถึงการพัฒนาแบบจำลองแบบ End-to-end ที่สามารถรวมกระบวนการประมวลผลข้อมูลและการจำแนกประเภทเข้าด้วยกัน จะช่วยเพิ่มประสิทธิภาพและความน่าเชื่อถือสำหรับการนำไปประยุกต์ใช้งานในสถานการณ์จริงได้

## 10. เอกสารอ้างอิง (References)

- Alzahem, A., Boulila, W., Koubaa, A., Khan, Z., & Alturki, I. (2023). Improving Satellite Image Classification Accuracy Using GAN-based Data Augmentation and Vision Transformers. *Earth Science Informatics*, 16(4), 4169–4186. <https://doi.org/10.1007/s12145-023-01153-x>.
- Belgiu, M., & Csillik, O. (2018). Sentinel-2 Cropland Mapping Using Pixel-based and Object-based Time-weighted Dynamic Time Warping Analysis. *Remote Sensing of Environment*, 204, 509–523. <https://doi.org/10.1016/j.rse.2017.10.005>.
- Dobrinic, D., Medak, D., & Gašparović, M. (2020). Integration of Multitemporal Sentinel-1 and Sentinel-2 Imagery for Land-cover Classification Using Machine Learning Methods. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B1-2020, 91–98. <https://doi.org/10.5194/isprs-archives-XLIII-B1-2020-91-2020>.

- Gerdan Koc, D., Koc, C., Polat, H. E., & Koc, A. (2024). Artificial Intelligence-based Camel Face Identification System for Sustainable Livestock Farming. *Neural Computing and Applications*, 36(6), 3107–3124. <https://doi.org/10.1007/s00521-023-09238-w>.
- Gibson, R., Danaher, T., Hehir, W., & Collins, L. (2020). A Remote Sensing Approach to Mapping Fire Severity in South-eastern Australia Using Sentinel 2 and Random Forest. *Remote Sensing of Environment*, 240, 111702. <https://doi.org/10.1016/j.rse.2020.111702>.
- Hao, M., Dong, X., Jiang, D., Yu, X., Ding, F., & Zhuo, J. (2024). Land-use classification based on high-resolution remote sensing imagery and deep learning models. *PLOS ONE*, 19(4), e0300473. <https://doi.org/10.1371/journal.pone.0300473>.
- Khan, M., Hanan, A., Kenzhebay, M., Gazzea, M., & Arghandeh, R. (2024). Transformer-based Land Use and Land Cover Classification with Explainability Using Satellite Imagery. *Scientific Reports*, 14(1), 16744. <https://doi.org/10.1038/s41598-024-67186-4>.
- Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778–782. <https://doi.org/10.1109/LGRS.2017.2681128>.
- Liang, J., Deng, Y., & Zeng, D. (2020). A Deep Neural Network Combined CNN and GCN for Remote Sensing Scene Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 4325–4338. <https://doi.org/10.1109/JSTARS.2020.3011333>.
- Llodrà-Llabrés, J., Martínez-López, J., Postma, T., Pérez-Martínez, C., & Alcaraz-Segura, D. (2023). Retrieving water chlorophyll-a concentration in inland waters from Sentinel-2 imagery: Review of operability, performance and ways forward. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103605. <https://doi.org/10.1016/j.jag.2023.103605>.
- Lu, L., Wang, L., Yang, Q., Zhao, P., Du, Y., Xiao, F., & Ling, F. (2023). Extracting a Connected River Network from DEM by Incorporating Surface River Occurrence Data and Sentinel-2 Imagery in the Danjiangkou Reservoir Area. *Remote Sensing*, 15(4), 1014. <https://doi.org/10.3390/rs15041014>.
- Mahakalanda, I., Demotte, P., Perera, I., Meedeniya, D., Wijesuriya, W., & Rodrigo, L. (2022). Deep Learning-based Prediction for Stand Age and Land Utilization of Rubber Plantation. In Khan, M. A., Khan, R., & Ansari, M. A. (Eds), *Application of Machine Learning in Agriculture* (131–156). Elsevier. <https://doi.org/10.1016/B978-0-323-90550-3.00008-4>.
- Murel, J., & Kavlakoglu, E. (2024). *What is Data Augmentation?*. IBM. <https://www.ibm.com/topics/data-augmentation>.
- Paramanantham, P. M., & Seenivasan, S. R. (2025). Optimized Deep Learning based Classification and Prediction of Land Use/ Land Cover Changes from Satellite Images. *Signal, Image and Video Processing*, 19(5), 415. <https://doi.org/10.1007/s11760-025-03937-8>.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14), 2291. <https://doi.org/10.3390/rs12142291>.
- QGIS. (2024). *Spatial without Compromise*. <https://www.qgis.org>.
- Rozario, P. F., Gadgil, R., Lee, J., Gomes, R., Keller, P., Liu, Y., Sipos, G., McDonnell, G., Impola, W., & Rudolph, J. (2024). Optimizing Mobile Vision Transformers for Land Cover Classification. *Applied Sciences*, 14(13), 5920. <https://doi.org/10.3390/app14135920>.



- Seydi, S. T., Amani, M., & Ghorbanian, A. (2022). A Dual Attention Convolutional Neural Network for Crop Classification Using Time-Series Sentinel-2 Imagery. *Remote Sensing*, 14(3), 498. <https://doi.org/10.3390/rs14030498>.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>.
- Sierra, S., Ramo, R., Padilla, M., & Cobo, A. (2025). Optimizing Deep Neural Networks for High-resolution Land Cover Classification through Data Augmentation. *Environmental Monitoring and Assessment*, 197(4), 423. <https://doi.org/10.1007/s10661-025-13870-5>.
- Singh, G., Singh, S., Sethi, G., & Sood, V. (2022). Deep Learning in the Mapping of Agricultural Land Use Using Sentinel-2 Satellite Data. *Geographies*, 2(4), 691–700. <https://doi.org/10.3390/geographies2040042>.
- Sudta, P. (2023). *Marketers and AI: Confusion Matrix and Principles for Evaluating ML Models*. Everyday Marketing. <https://everydaymarketing.co/business-and-marketing-case-study/ai/confusion-matrix-ml-evaluation>. (In Thai)
- Vali, A., Comai, S., & Matteucci, M. (2020). Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sensing*, 12(15), 2495. <https://doi.org/10.3390/rs12152495>.
- Wang, Y., Zhang, Z., Feng, L., Ma, Y., & Du, Q. (2021). A New Attention-based CNN Approach for Crop Mapping Using Time Series Sentinel-2 Images. *Computers and Electronics in Agriculture*, 184, 106090. <https://doi.org/10.1016/j.compag.2021.106090>.
- Wubineh, B. Z., Rusiecki, A., & Halawa, K. (2024). Classification of Cervical Cells from the Pap Smear Image Using the RES\_DCGAN Data Augmentation and ResNet50V2 with Self-attention Architecture. *Neural Computing and Applications*, 36(34), 21801–21815. <https://doi.org/10.1007/s00521-024-10404-x>.
- Zhang, T., Su, J., Xu, Z., Luo, Y., & Li, J. (2021). Sentinel-2 Satellite Imagery for Urban Land Cover Classification by Optimized Random Forest Classifier. *Applied Sciences*, 11(2), 543. <https://doi.org/10.3390/app11020543>.
- Zhu, X. X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>.

