

กรรมวิธีสร้างชุดข้อมูลสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดิน/ การปกคลุมดินด้วย CNN: กรณีศึกษาพื้นที่ชนบทของประเทศไทย

Laurent Mezeix^{1*} และ Max Garcia Casanova²

วันที่รับ 28 กันยายน 2565 วันที่แก้ไข 28 ธันวาคม 2565 วันตอบรับ 24 มกราคม 2566

บทคัดย่อ

การวิเคราะห์ภาพสิ่งปกคลุมดินหรือ Land Cover เป็นเครื่องมือที่มีประสิทธิภาพจากการสำรวจระยะไกล และสามารถใช้ประโยชน์จาก Convolutional Neural Network (CNN) ในการจดจำและจำแนกวัตถุภายในภาพ อย่างไรก็ตาม กระบวนการจดจำและการจำแนกจะมีความแม่นยำสูงหรือไม่ขึ้นอยู่กับการเตรียมข้อมูลหรือชุดข้อมูลที่มีปริมาณที่เหมาะสม ในบทความนี้ได้เสนอวิธีการและรายละเอียดในการสร้างชุดข้อมูลเพื่อใช้สำหรับหาสิ่งปกคลุมดินผ่าน CNN กรรมวิธีนี้ประกอบด้วย 5 ขั้นตอน คือ 1) การรวบรวมรูปภาพจากการสำรวจระยะไกล 2) การสร้างไทล์ (Tile) ของแต่ละภาพ 3) การทำ Label โดยใช้ coarse model โดยอัตโนมัติเพื่อแบ่งกลุ่มข้อมูล 4) การตัดแยกชุดข้อมูลที่ติดป้ายกำกับผิดออก และ 5) การนำชุดข้อมูลไปใช้ในแบบจำลอง CNN โดยในบทความนี้เป็นการศึกษาพื้นที่ชนบทในประเทศไทย แบ่งชุดข้อมูลเป็น 4 กลุ่ม (Class) ได้แก่ อาคาร พืชพรรณ ถนน และพื้นที่รกร้าง โดยในขั้นตอนแรก ภาพถ่ายดาวเทียมจะถูกปรับขนาดโดยใช้กระบวนการ Overlapping เพื่อสร้างชุดข้อมูล จากนั้นจึงพัฒนาแบบจำลองพื้นฐานตามค่าแถบจุดภาพ RGB และด้วยการใช้อัตราส่วนกับ RGB Filter เหล่านี้ จึงสามารถจำแนกวัตถุของไทล์ดังกล่าวได้ ผลลัพธ์ที่ได้แสดงให้เห็นว่าสามารถสร้างชุดข้อมูลภาพในกลุ่มของอาคารและพื้นที่รกร้างที่ใช้โมเดลในการจำแนกได้ด้วย ความแม่นยำสูงมากถึง 98% ซึ่งแสดงให้เห็นถึงประสิทธิภาพของวิธีการที่เสนอเพื่อดำเนินการกับชุดข้อมูลภาพได้อย่างรวดเร็ว และในชุดข้อมูลภาพในกลุ่มของพืชพรรณให้ผลลัพธ์ที่มีความแม่นยำในระดับที่ 90% อย่างไรก็ตาม ชุดข้อมูลภาพในกลุ่มของถนนมีความแม่นยำต่ำที่ 68% ซึ่งเป็นข้อจำกัดของการตัดแยกข้อมูลสำหรับชุดข้อมูลกลุ่มนี้ สุดท้ายจะมีการตรวจสอบผลกระทบของขนาดการตัดและขนาดที่ซ้อนทับกัน และผลลัพธ์แสดงให้เห็นว่าการใช้ขนาดการตัดที่แตกต่างกันจำเป็นต้องมีการปรับเทียบวิธีการใหม่

คำสำคัญ : ชุดข้อมูล, การปกคลุมดิน, การประมวลผลภาพ, ภาพซ้อนทับ, ภาพถ่ายดาวเทียม

¹ คณะวิศวกรรมศาสตร์, มหาวิทยาลัยบูรพา

² Université de Toulouse, INSA, UPS, Mines d'Albi, ISAE, ICA (Institut Clément Ader)

* ผู้แต่ง, อีเมล: laurent.mezeix@hotmail.com

Dataset Creation Methodology for CNN Land Use/ Cover Classification: Thailand's Rural Area Study Case

Laurent Mezeix^{1*} and Max Garcia Casanova²

Received 28 September 2022, Revised 28 December 2022, Accepted 24 January 2023

Abstract

Land cover is a powerful tool and takes advantage of Convolutional Neural Network (CNN) in remote sensing image recognition. However, the existing datasets are pretty small or are not related to the studied class where the land cover is performed. In this paper, a methodology is proposed and detailed to create dataset images to be used for land cover through CNN. This method consists in 4 steps. Firstly, large remote sensing images are collected. Then, a large amount of tiles are created using an adequate sampling method. Using a coarse model tiles are automatically labeled. Finally, dataset is cleaned from mislabeled images in order to be used in a CNN model. Rural area in Thailand is used as study case for a 4 class dataset: buildings, forest, roads and wasteland. In a first step, satellite images are cropped using overlapping process to create dataset tiles. Then, coarse model based on pixel RGB bands value is developed and by applying ratio on these RGB filters, tiles can be classified. Results show that building and wasteland class can be created with a very high precision of at least 98% demonstrating the robustness of the proposed method to quickly perform a dataset image. Forest presents a good precision with a value of 90%. On the opposite, roads class presents a low precision of 68% and therefore, this datasets needs to be manually cleaned by the users. Finally, effects of cropping and overlapping size are investigated and results show that using a different cropping size requires a new calibration of the methodology.

Keywords : Dataset, Land cover, Image processing, Overlapped images, Satellite image

¹ Faculty of Engineering, Burapha University

² Université de Toulouse, INSA, UPS, Mines d'Albi, ISAE, ICA (Institut Clément Ader)

* Corresponding author, E-mail: laurent.mezeix@hotmail.com

1. บทนำ

เป้าหมายของการจำแนกการใช้ประโยชน์ที่ดิน หรือพื้นที่ที่มีการปกคลุมดิน คือการเชื่อมโยงตำแหน่ง ด้วยป้ายกำกับหรือฉลาก (Label) เข้ากับพื้นที่ของ พื้นผิวโลก โดยฉลากจะอธิบายถึงทรัพยากรทาง นิเวศวิทยา หรืออธิบายว่ามีพื้นที่อย่างไร โดยการวิเคราะห์สิ่งปกคลุมดินได้มีการนำมาประยุกต์กับ งานด้านการสนับสนุนนโยบายและการวางแผนเมือง [1]-[10] การคุ้มครองพืชพรรณ [11] ผลกระทบจาก น้ำท่วม [12] วิวัฒนาการของปริมาณคาร์บอนสะสม [13] การศึกษาชนกลุ่มน้อย [14] คุณภาพอากาศ [15] การพังทลายของดิน [16] หรือการพัฒนาโครงข่ายถนน [17]-[18]

การจำแนกประเภทภาพถ่ายจากการรับรู้ ระยะไกลใช้ประโยชน์จาก Convolutional Neural Network (CNN) ซึ่งเป็นวิธีการเรียนรู้เชิงลึกจากการจดจำวัตถุและการจัดประเภทภาพ [19] ข้อมูล สเปกตรัมและข้อมูลเชิงพื้นที่จากภาพเรียนรู้ได้จาก CNN [20]-[25] พบว่า CNN มีความถูกต้องสูงกว่า วิธีการจำแนกมาตรฐานอื่น ๆ เช่น SVM [26]-[29] Random Forest [30]-[31] Logistic Regression และวิธีอื่น ๆ ที่คล้ายคลึงกัน [32]-[33] เมื่อใช้ CNN ข้อมูลการใช้ประโยชน์ที่ดินสามารถสร้างได้ โดยอัตโนมัติจากคลังข้อมูลภาพถ่ายดาวเทียม [34]-[37] โดยเฉพาะภาพถ่ายดาวเทียมจาก โครงการ Landsat และ Sentinel ที่ให้บริการ ภาพถ่ายพื้นที่เขตเมืองที่มีความละเอียดต่ำโดยไม่มี ค่าใช้จ่าย ซึ่งสามารถนำไปใช้สร้างข้อมูลปกคลุมดินได้ [38]-[42]

ไม่ว่าวิธีใดก็ตามที่ใช้ในการวิเคราะห์หากการ ปกคลุมดิน ปัจจัยสำคัญที่จะส่งผลต่อความแม่นยำ ในการจำแนกภาพคือคุณภาพและขนาดของชุด ข้อมูล รวมไปถึงจำนวนของภาพในชุดข้อมูล [43]-[44] อย่างไรก็ตาม คุณภาพของชุดข้อมูลยังไม่มีค่า พารามิเตอร์ที่ชัดเจนเป็นตัวกำหนด เนื่องจากเชื่อมโยง กับขั้นตอนการจำแนกประเภท เช่น เซอร์ที่ไชน ดาวเทียมเพื่อรับข้อมูลดิบ หรือสภาพอากาศในขณะ

เก็บข้อมูล เป็นต้น พารามิเตอร์เหล่านี้ล้วนมีส่วนทำให้ เกิดความไม่ถูกต้องระหว่างชุดข้อมูล [45]-[47] ดังนั้น การสร้างชุดข้อมูลสำหรับจำแนกประเภทการใช้ ประโยชน์ที่ดิน/การปกคลุมดิน จึงเป็นความท้าทายที่ซับซ้อน

เพื่อตรวจสอบความสำคัญของชุดข้อมูลในการ วิเคราะห์การปกคลุมดินโดยใช้ CNN นั้น บทความนี้ ทำการตรวจสอบและทบทวนวรรณกรรมเกี่ยวกับการ ปกคลุมดินตั้งแต่ปี ค.ศ. 2010 ถึงปัจจุบัน ผล การตรวจสอบทางวรรณกรรมนี้สรุปไว้ในตารางที่ 1 ผลปรากฏว่าขนาดชุดข้อมูลของการปกคลุมดินมีการ เพิ่มขึ้นอย่างต่อเนื่อง จากประมาณ 3,000 ภาพ ในช่วง ต้นปี ค.ศ. 2010 เป็นมากกว่า 500,000 ภาพ ในปัจจุบัน ซึ่งจำนวนภาพที่เพิ่มมากขึ้นสอดคล้องกับความแม่นยำ ของแบบจำลองที่เพิ่มขึ้น ในปี ค.ศ. 2010 Yang และ Newsam [48] นำเสนอชุดข้อมูลการใช้ประโยชน์ ที่ดินด้วยชุดข้อมูลขนาด 2,100 ภาพ ที่ประกอบด้วย 21 ประเภทของวัตถุในชุดข้อมูล และจนถึงปี ค.ศ. 2016 ชุดข้อมูลประกอบด้วยภาพประมาณ 3,000 ภาพ ยกเว้นชุดข้อมูล DeepSat [49] ซึ่งค่าความแม่นยำ เฉลี่ยจากการศึกษาต่าง ๆ โดยใช้ชุดข้อมูลขนาดเล็ก เหล่านี้อยู่ที่ 87.8% หลังจากนั้น ชุดข้อมูล เหล่านี้มีขนาดเฉลี่ยที่ขยายตัวเพิ่มขึ้นถึง 10 เท่า โดยมีจำนวนภาพเฉลี่ย 30,000 ภาพ เช่น ในงานของ Helber และคณะ [50] ซึ่งแนะนำชุดข้อมูล 10 ประเภท ของวัตถุในชุดข้อมูล โดยมีป้ายกำกับและอ้างอิงทาง ภูมิศาสตร์ทั้งหมด 27,000 ภาพ ที่ขนาด 64x64 จุดภาพ จากดาวเทียม Sentinel-2 ในทำนองเดียวกัน แบบจำลองที่เสนอโดย Yuri และคณะ [41] ซึ่งมีการ ตรวจสอบเมฆ เงา และดิน โดยคิดว่าชุดข้อมูลทั้งหมด 3 ชุด รวมเป็นภาพเกือบ 50,000 ภาพ ชุดข้อมูลแรก ประกอบด้วยรูปภาพ 40,479 ภาพ ที่ขนาด 256x256 จุดภาพ ที่มี 17 ประเภทของวัตถุในชุดข้อมูล ในขณะที่ ชุดข้อมูลอื่นอีก 2 ชุด ประกอบด้วยภาพ 9,939 ภาพ ที่ขนาด 180x180 จุดภาพ ทั้งหมดสำหรับ 12 ประเภทของ วัตถุในชุดข้อมูล โดยใช้ภาพถ่ายดาวเทียม Sentinel-2 การเพิ่มขนาดชุดข้อมูลในส่วนของ 2 ของช่วงปี ค.ศ. 2010 ทำให้ ผู้เขียนได้ ความถูกต้อง โดยเฉลี่ย 93.2%

อย่างไรก็ตาม ชุดข้อมูลการใช้ประโยชน์ที่ดิน/การคลุมดิน ส่วนใหญ่ที่เสนอเหล่านี้ยังคงมีรูปภาพต่อประเภทของวัตถุในชุดข้อมูลค่อนข้างน้อย ตั้งแต่ปี ค.ศ. 2019 ภาพจำนวนครึ่งล้านภาพมักถูกนำมาใช้ในการศึกษา การคลุมดิน Sumbul และคณะ [51] ได้สร้างชุดข้อมูลหลายป้ายกำกับขนาดใหญ่จาก Sentinel-2 benchmark archive แม้ว่าจำนวนภาพจะเพิ่มขึ้น

เป็น 600,000 ภาพ แต่จำนวนภาพต่อประเภทของวัตถุในชุดข้อมูลยังคงต่ำ (ค่ามัธยฐาน 9,000) ซึ่งสามารถอธิบายความถูกต้องโดยรวมที่ค่อนข้างต่ำของการศึกษาได้ เมื่อใช้รูปภาพจำนวนมากต่อประเภทของวัตถุในชุดข้อมูล เช่น ในงานของ Ruiz Emparanza และคณะ [52] หรือผลงานของ Chermprayong และคณะ [53] ความถูกต้องเพิ่มขึ้นเป็น 98%

ตารางที่ 1 การเปรียบเทียบระหว่างชุดข้อมูลที่แตกต่างกันสำหรับการคลุมดินโดยใช้ CNN

Archive Name	จำนวนภาพ	จำนวนประเภทของวัตถุในชุดข้อมูล	ภาพต่อประเภทของวัตถุในชุดข้อมูล	ขนาดภาพ (จุดภาพ)	ความถูกต้อง
UC Merced [48]	2,100	21	-	28x28	81.19%
WHU-RS19 [54]	1,005	19	50	600x600	93%
RSSCN7 [55]	2,800	7	400	400x400	77%
DeepSat [49]	500,000 405,000	4 6	-	28x28	97.95%
SIRI-WHU [56]	2,400	12	200	200x200	88.00%
AID [57]	10,000	30	200 to 400	600x600	89.64% VGG-VD-16
NWPU-RESISC45 [58]	31,500	45	700	256x256	90.36% VGGNet-16
RSI-CB [59]	36,000 24,150	45 35	800 690	128x128 256x256	95.02% ResNet
EuroSat [50]	27,000	10	2,000 to 3,000	64x64	98.57% ResNet-50
PatternNet [60]	30,400	38	800	256x256	94.13% ResNet-50
[41]	40,479 9,939	17 12	-	256x256 180x180	88% DenseNet201
BigEarthNet [51]	590,326	44	328 to 217,119	120x120 And 60x60	69.93%
[52]	585,430	4	122,965 to 205,863	64x64	98%
[53]	633,743	4	132,597 to 205,863	64x64	98%

ผลจากการทบทวนวรรณกรรมพบว่า หากชุดข้อมูลมีขนาดใหญ่เท่าใด แบบจำลองจะได้รับการฝึก (Train) ได้ดีขึ้นเช่นกัน และการคาดการณ์จะดำเนินการได้ดียิ่งขึ้น อย่างไรก็ตาม การสร้างชุดข้อมูลดังกล่าวเพื่อใช้ในการศึกษารการคลุมดินนั้นใช้ทรัพยากรมาก

เนื่องจากการดำเนินการแบบ Manual ในบทความนี้ จึงมีการพัฒนาระเบียบวิธีใหม่เพื่อรองรับการสร้างชุดข้อมูลขนาดใหญ่ของรูปภาพโดยอัตโนมัติ ซึ่งเหมาะสำหรับการใช้ในงานจำแนกการคลุมดินโดยใช้ CNN ชุดข้อมูลขนาดใหญ่สร้างขึ้นโดยการเพิ่มชุดข้อมูล


ที่มีขนาดเล็กลงจากภาพถ่ายดาวเทียมที่มีอยู่ วิธีการนี้ได้รับการพัฒนาและสาธิตบนภาพชุดแรกจากพื้นที่ชนบทในประเทศไทย บทความนี้จะอธิบายวิธีการเบื้องต้น ก่อนที่จะนำไปใช้งานจริงในพื้นที่ชนบทในประเทศไทยที่มีหวังที่จะสร้างชุดข้อมูล 4 ประเภทของวัตถุในชุดข้อมูลขนาดใหญ่ คุณภาพของวิธีการนี้ได้รับการตรวจสอบด้วยความถูกต้อง ความแม่นยำ และ Recall สุดท้ายจะมีการกล่าวถึงความอ่อนไหวบางประการของกรรมวิธีต่อพารามิเตอร์

2. ระเบียบวิธีวิจัย

2.1 คำอธิบายระเบียบวิธีวิจัย

จุดมุ่งหมายของวิธีการที่เสนอในบทความนี้คือ เพื่อลดความซับซ้อนในการสร้างภาพชุดข้อมูลของประเภทของวัตถุในชุดข้อมูลต่าง ๆ สำหรับการใช้ประโยชน์ที่ดิน/การคลุมดินที่ดำเนินการโดย CNN กระบวนการโดยรวมในการสร้างชุดข้อมูลประเภทของวัตถุในชุดข้อมูลประกอบด้วย 5 ขั้นตอนอย่างกว้าง ๆ (รูปที่ 1) และ 4 ขั้นตอนแรก มีรายละเอียดดังนี้

1. การรับชุดข้อมูลเริ่มต้น - ภาพที่ได้จากการรับรู้ระยะไกลขนาดใหญ่
2. สร้างภาพถ่ายจำนวนมากจากภาพถ่ายดาวเทียมเหล่านี้โดยใช้วิธีการสุ่มตัวอย่างที่เพียงพอ
3. ตัดป้ายกำกับรูปภาพ/สร้างแผนที่เข้ากับประเภทของวัตถุในชุดข้อมูลโดยอัตโนมัติ โดยใช้แบบจำลองพื้นฐาน
4. การคัดชุดข้อมูลจากภาพที่ติดฉลากผิดออก
5. การใช้ชุดข้อมูลในกระบวนการ CNN



รูปที่ 1 กระบวนการโดยรวมในการสร้างชุดข้อมูลประเภทของวัตถุในชุดข้อมูล

2.2 การรับชุดข้อมูลแรกเริ่ม


ภาพพื้นที่ดินสำหรับการวิเคราะห์การคลุมดินสามารถรวบรวมได้จากเวกเตอร์และเซนเซอร์ต่าง ๆ (UAV เครื่องบิน และดาวเทียม) โดยทั่วไปจะได้รับการใช้ดาวเทียมที่ให้บริการแก่สาธารณะ (Copernicus ของ ESA และ Landsat ของ NASA) หรือการให้บริการคลังภาพถ่ายดาวเทียม รูปภาพเหล่านี้มีข้อมูลจำนวนมาก ดังนั้น ชุดข้อมูลจึงไม่สามารถสร้างได้โดยตรงจากภาพถ่ายดาวเทียมเหล่านี้ และจำเป็นต้องตัดให้มีขนาดที่เหมาะสมก่อน

2.3 การสร้างชุดข้อมูลภาพ

เพื่อให้ได้ภาพชุดข้อมูลนั้น ภาพที่ได้จากการรับรู้จากระยะไกลมักจะถูกตัดเป็นภาพสี่เหลี่ยมจัตุรัสเรียกว่า ไทล์ซึ่งมีจุดภาพ $N \times N$ จำนวนจุดภาพ N ถูกเลือกโดยสัมพันธ์กับคุณลักษณะที่ต้องการตรวจจับและความละเอียดของภาพเริ่มต้น ขนาดปกติที่ใช้ในชุดข้อมูลการคลุมดินมีตั้งแต่ 28×28 จุดภาพ จนถึง 600×600 จุดภาพ โดยมีขนาดเฉลี่ย 220×220 จุดภาพ (ตารางที่ 1) หากต้องการเพิ่มจำนวนรูปภาพในชุดข้อมูลให้มากขึ้น ผู้วิจัยใช้วิธีการ “สุ่มตัวอย่างซ้ำ” วิธี Overlapping ที่เสนอโดย Chermprayong และคณะ [53] ถูกนำมาใช้ในบทความนี้ ขนาดภาพถ่ายดาวเทียมจะลดลงในขั้นแรก เพื่อให้จำนวนจุดภาพรวมเป็นทวีคูณของขนาดที่ซ้อนทับกัน ซึ่งแสดงเป็น S จากนั้นภาพถ่ายดาวเทียมที่มีขนาด $L \times H$ จะถูกแปลงเป็นชุดของภาพที่เล็กกว่าของจุดภาพ $N \times N$ โดยแต่ละภาพที่มีขนาดเล็กกว่าจะซ้อนทับกับภาพก่อนหน้าและภาพถัดไป (รูปที่ 2) ทั้งในทิศทาง X และ Y จากขั้นตอนนี้จะได้รับอิมเมจ $N \times N$ จำนวนมาก ซึ่งจะต้องติดป้ายกำกับเพื่อให้สามารถใช้ในการฝึกอบรม การทดสอบ และการตรวจสอบความถูกต้องของโมเดล CNN จำนวนไทล์ทั้งหมดถูกกำหนดโดยสมการที่ (1)

$$\text{จำนวนไทล์โดยรวม} = \frac{L \times H}{S^2} - \frac{(L+H)}{S} + 1 \quad (1)$$

ด้วยวิธีนี้จะมีการสร้างไทม์ทั้งหมด 1,075 ไทม์ ขนาด 64x64 จุดภาพ โดยใช้ S ที่ทับซ้อนกัน 32 จุดภาพ จากภาพถ่ายดาวเทียมดั้งเดิมขนาด 1408x832 จุดภาพ (รูปที่ 3) ตามที่ระบุไว้ การให้ค่าทับซ้อน 2 จะเพิ่มจำนวนไทม์ประมาณ 4 ไทม์



รูปที่ ๒ กระบวนการซ้อนทับเพื่อสร้างไทม์ขนาด $N \times N$ จุดภาพ



รูปที่ ๓ ตัวอย่างไทม์

2.4 การติดป้ายกำกับข้อมูล

การจำแนกประเภทของภาพเป็นงานที่ใช้เวลา และการติดป้ายกำกับมักจะทำโดยผู้เชี่ยวชาญในด้าน การตีความภาพถ่ายจากการรับรู้ระยะไกล [54], [57], [61]-[62] เพื่อให้กระบวนการนี้เป็นไปโดยอัตโนมัติ จึงเกิดเป็นแนวคิดคือการใช้โมเดลพื้นฐานระดับกลาง เพื่อพยายามติดป้ายกำกับแต่ละไทม์ ต้องเลือกแบบ จำลองพื้นฐานที่ความละเอียดต่ำด้วยความระมัดระวัง และออกแบบให้สัมพันธ์กับเป้าหมายสุดท้ายของ การศึกษาการคลุมดิน เราสามารถใช้วิธีการต่าง ๆ ในการสร้างแบบจำลองคร่าว ๆ เบื้องต้นนี้ได้ ซึ่งรวมไปถึง เทคนิคการเรียนรู้ของเครื่องโดยไม่มีกำกับ [63]-[64] ไม่ว่าจะในกรณีใด โมเดลเหล่านี้จะไม่ต้องพึ่งพาการระบุ และแยกคุณลักษณะที่สอดคล้องกับประเภทของวัตถุ

ในชุดข้อมูลเฉพาะในรูปภาพ สำหรับการสาธิตกรณี การใช้งานในปัจจุบัน คุณลักษณะเหล่านี้ได้รับการ กำหนดตามสีของจุดภาพ (แถบ RGB) เนื่องจากพบว่า มีประสิทธิภาพค่อนข้างมากในการประมาณครั้งแรก ค่าจำกัดความของตัวกรอง RGB เหล่านี้ดำเนินการ โดยผู้ใช้งาน และเมื่อนำไปใช้กับชุดข้อมูลโดยรวมแล้ว ไทม์สามารถจำแนกออกเป็นประเภทของวัตถุในชุด ข้อมูลเป้าหมายได้ทันที

2.5. การคัดกรองชุดข้อมูล

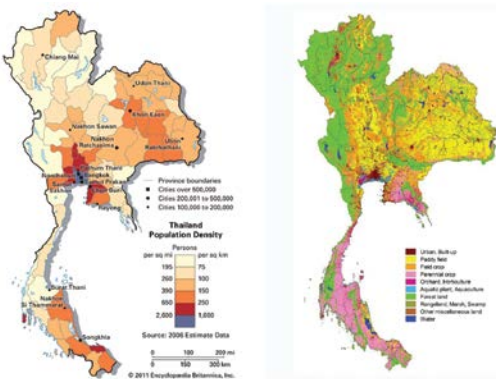
ข้อมูลที่ได้จากแบบจำลองพื้นฐานยังคงมีความ ผิดพลาดในการติดป้ายกำกับ เช่นเดียวกับความผันแปร ของภาพถ่ายดาวเทียมที่เกิดจากตำแหน่งของดาวเทียม คุณภาพของภาพ การปรากฏของเมฆบนภาพ หรือ

ผลกระทบตามฤดูกาลต่าง ๆ ซึ่งจะทำให้เกิดข้อผิดพลาดในการตีค่ากำกับ ซึ่งต้องอาศัยการคัดกรองชุดข้อมูลแบบ Manual

3. กรณีใช้งาน: การวิเคราะห์พื้นที่ชนบทของประเทศไทย

3.1 ความเป็นมาและวัตถุประสงค์ของการศึกษาการคลุมดิน


ประเทศไทยเป็น 1 ใน 10 ประเทศ ของสมาคมประชาชาติแห่งเอเชียตะวันออกเฉียงใต้ (อาเซียน) มีประชากรทั้งหมด 69.79 ล้านคน ในปี ค.ศ. 2020 และมีพื้นที่ทั้งหมด 513,120 ตารางกิโลเมตร ประชากรในเมืองมีจำนวนน้อยกว่า 35.12 ล้านคน ในปี ค.ศ. 2020 คิดเป็น 50.5% [65] ความหนาแน่นของประชากรแสดงให้เห็นความแตกต่างอย่างมากระหว่างเขตเมืองรอบกรุงเทพฯ (5,294 คน/ตารางกิโลเมตร) กับภาคเหนือ (100 คน/ตารางกิโลเมตร) ภาคใต้ (126 คน/ตารางกิโลเมตร) และภาคตะวันออกเฉียงเหนือ (130 คน/ตารางกิโลเมตร) ของประเทศ (รูปที่ 4ก) กิจกรรมหลักในประเทศไทย ได้แก่ อุตสาหกรรม (39% ของ GDP) และบริการ (52% ของ GDP) เกษตรกรรมเป็นตัวแทนของ GDP ของประเทศไทยเพียง 8% ในปี ค.ศ. 2019 [66] แต่คน 31.16% ทำงานในพื้นที่เกษตรกรรมในปี 2020 พื้นที่เกษตรกรรมถูกรายงานที่ 43.28% ในปี 2561 (รูปที่ 4 ข)



รูปที่ ๔ (ก) ความหนาแน่นของประชากรในประเทศไทย [67] และ (ข) การใช้ประโยชน์ที่ดิน/การคลุมดิน [68]

ดังจะสังเกตได้ ประชากรไทยส่วนใหญ่อาศัยอยู่ในพื้นที่เกษตรกรรมที่มีความหนาแน่นต่ำ พื้นที่ดังกล่าวประกอบด้วยหมู่บ้านเล็ก ๆ ที่ล้อมรอบด้วยทุ่งนา ฟาร์ม และพืชพรรณ/พืชพรรณ (รูปที่ 5) เพื่อเป็นข้อมูลสนับสนุนให้ผู้กำหนดนโยบายในการตัดสินใจการคลุมดินในพื้นที่ชนบทสามารถเป็นเครื่องมือที่มีประสิทธิภาพ ด้วยการวิเคราะห์การคลุมดินนี้เอง ข้อมูลจำนวนมากจึงสามารถรับรู้ได้ เช่น จำนวนและที่ตั้งของถนน อาคาร ประเภทของที่ดินและทุ่งนา เป็นต้น ด้วยข้อมูลเหล่านี้การพัฒนาโครงสร้างพื้นฐานจึงสามารถดำเนินการเพื่ออำนวยความสะดวกให้ประชาชนในพื้นที่ชนบทได้ เพื่อจุดประสงค์นี้เองภาพถ่ายดาวเทียมที่มีความคมชัด 0.25 เมตรต่อจุดภาพ จะช่วยให้ได้รับข้อมูลในระดับความแม่นยำที่เพียงพอ และอยู่ในระดับ 6 ประเภท ที่ผู้วิจัยสนใจ (รูปที่ 5) ประกอบด้วย

- สิ่งปลูกสร้าง: บ้าน โรงงาน อาคารอุตสาหกรรม
- ทุ่งนา: นาข้าว ที่รกร้าง
- กิจกรรมจากมนุษย์: น้ำมันปาล์ม กล้าย
- ป่า/บริเวณที่มีพืชพรรณหนาแน่นมากและหนาแน่นน้อย
- ถนน: ยางมะตอยและถนนคอนกรีต
- ที่รกร้างว่างเปล่า: พื้นดินเปล่า



รูปที่ ๕ หมู่บ้านเล็ก ๆ ทั่วไปและพื้นที่ชนบทในประเทศไทย

3.2 การสร้างชุดข้อมูล

หลังจากการทบทวนวรรณกรรมในบทนำ จะเห็นได้ว่ามีความพยายามสร้างชุดข้อมูลที่มีไทล์จำนวนมาก

สำหรับแต่ละประเภทที่ต้องการ สำหรับการศึกษาค้นคว้าในลักษณะนี้สามารถสร้างประเภทของชุดข้อมูลที่เป็นทุ่งนา สวน และพืชพรรณได้โดยง่ายโดยใช้ภาพถ่ายดาวเทียมที่มีเพียงหนึ่งในประเภทเหล่านี้ (รูปที่ 6) ในทางกลับกัน อาคาร ถนน และพื้นที่รกร้าง อาจถูกล้อมรอบด้วยที่ดินประเภทอื่น (รูปที่ 5) ดังนั้น จึงต้องระบุและดึงข้อมูลนี้ออกมาจากภาพถ่ายดาวเทียม การดำเนินการนี้สามารถทำได้ด้วยตนเอง แต่ต้องมีการตรวจสอบด้วยตนเองและใช้เวลานาน ดังนั้น จึงใช้วิธีการที่น่าเสนอในบทความนี้เพื่อสร้างชุดข้อมูลที่เกี่ยวข้อง (รูปที่ 1) โดยเริ่มจากภาพ Sentinel ที่รวบรวมไว้ในปี พ.ศ. 2564 และใช้กระบวนการซ้อนทับกันของ [53] ที่ทับซ้อนกัน 32 จุดภาพ กลุ่มแรก 6,988 ไทล์ ขนาด 64x64 จุดภาพ ได้ถูกสร้างขึ้นจากภาพถ่ายดาวเทียมของพื้นที่ชนบทที่มีค่าจำกัดความของ 0.25 เมตรต่อจุดภาพ



รูปที่ 6 ภาพถ่ายดาวเทียมระดับโมโนของป่า สวน และทุ่งนา

3.3 การจำแนกประเภทภาพในชุดข้อมูล

ไทล์ที่สร้างขึ้นเหล่านั้นจำเป็นต้องจำแนกประเภทตามที่อยู่ข้างต้น ในการดำเนินการนี้แบบจำลองพื้นฐานตาม “คุณสมบัตินี้” ของแต่ละประเภทได้ถูกกำหนดไว้โดยพิจารณาจากคุณลักษณะสีของจุดภาพที่ได้รับจากแถบ RGB จากนั้นกำหนดตัวกรอง RGB ที่เกี่ยวข้องกับแต่ละประเภท หากจุดภาพของไทล์มีความแตกต่างอย่างชัดเจนตามตัวกรองที่เกี่ยวข้อง การจัดประเภทจะถูกดำเนินการทันที

3.3.1 ตัวกรอง RGB (RGB Filters)

ดังรูปที่ 5 ภาพทั้ง 5 ประเภท สามารถระบุได้อย่างแม่นยำโดยอาศัยสีหลักที่ปรากฏของประเภทนั้น ได้แก่ อาคาร พืชพรรณ ทุ่งนา พื้นที่รกร้าง และถนนสายหลัก (รูปที่ 7) อาคารในประเทศไทยสามารถระบุ

ได้ด้วยสีหลังคาและมักเป็น 1 ใน 5 สี ได้แก่ สีฟ้าอ่อน สีน้ำเงินเข้ม สีแดงอ่อน สีแดงเข้ม และสีขาว (รูปที่ 7) ในขณะที่ประเภทอื่น ๆ มีสีของตัวเอง ตัวกรอง RGB 9 ตัว ได้รับการสร้างขึ้นด้วยคน เพื่อแยกประเภทของวัตถุในชุดข้อมูลเหล่านี้โดยอัตโนมัติ ตัวกรองเหล่านี้อิงตามค่าจุดภาพผ่านแถบ RGB ที่ต้องอยู่ภายในกรอบที่กำหนดดังสมการที่ (2)

$$RGB\ filter_{feature,i} = \begin{cases} Lower\ R\ value < pixel\ value < higher\ R\ value & \& \\ Lower\ G\ value < pixel\ value < higher\ G\ value & \& \\ Lower\ B\ value < pixel\ value < higher\ B\ value. \end{cases} \quad (2)$$


สำหรับแต่ละไทล์ อัตราส่วน (Ratio) ของจำนวนจุดภาพภายในแต่ละกรอบถูกกำหนดโดยสมการที่ (3)

$$Ratio_i = \frac{\sum \text{จุดภาพภายในตัวกรอง RGB}}{\text{จำนวนจุดภาพทั้งหมด}} \quad (3)$$

ในส่วนที่เกี่ยวข้องกับหลังคาทั้ง 5 นั้น ชั้นสีแดงและสีเขียวครอบคลุมค่าทั้งหมดตั้งแต่ 10 ถึง 255 และชั้นสีเขียวเริ่มต้นจาก 90 ถึงสิ้นสุดที่ค่า 255 (รูปที่ 8) พืชพรรณแสดงค่าแถบ RGB ที่ต่ำกว่า 60 ค่าแถบ RGB สำหรับฟิลด์ส่วนใหญ่อยู่ระหว่าง 50 ถึง 140 (รูปที่ 8) ที่ดินรกร้างแสดงให้เห็นเป็นชั้นสีแดงที่มีค่าสูงกว่า 200 และอีก 2 ชั้น ส่วนใหญ่อยู่ระหว่าง 130 ถึง 210 (รูปที่ 8) สุดท้าย ถนนสายหลักจะแสดงแถบ RGB ที่เหมือนกัน 3 แถบที่มีค่าระหว่าง 100 ถึง 200 (รูปที่ 8)



รูปที่ 7 ภาพที่ตัดขนาด 64x64 จุดภาพตามปกติที่ระบุประเภทของวัตถุในชุดข้อมูลได้



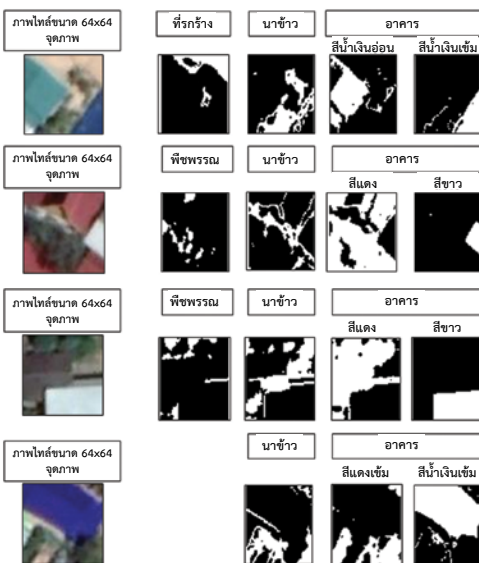
รูปที่ ๘ ตัวกรอง RGB

หลังคาสีขาว		
หลังคาสีน้ำเงิน		
หลังคาสีน้ำเงินเข้ม		
หลังคาสีแดงอ่อน		
หลังคาสีแดงเข้ม		

ที่รกร้าง		
ถนนสายหลัก		
พืชพรรณ		
นาข้าว		

3.3.2 ผลที่ได้จากตัวกรอง RGB

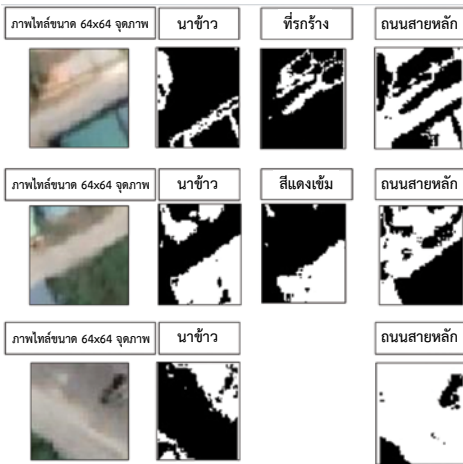
ตัวกรอง RGB จะถูกนำมาใช้กับชุดข้อมูลภาพจำนวน 6,988 ไทล์ ผลลัพธ์แสดงในรูปที่ 9-12 พร้อมกับผลลัพธ์ตัวกรอง RGB หลัก เมื่อเน้นพื้นที่ชนบท อาคารส่วนใหญ่จะล้อมรอบไปด้วยทุ่งนา พื้นที่รกร้างว่างเปล่า และพืชพรรณ ดังนั้น จึงสังเกตเห็นทุกประเภทของภาพ (รูปที่ 9) พืชพรรณ/ชั้นป่าส่วนใหญ่เป็นป่าและหลังคาสีแดงเข้ม แต่แปลงนาในอัตราส่วนที่เล็กกว่า (รูปที่ 10) ในชนบทมีถนนสายหลักผ่านทุ่งนาหรือหมู่บ้าน ดังนั้นจึงสังเกตเห็นทุ่งนาและพื้นที่รกร้างว่างเปล่า (รูปที่ 11) ชั้นของความสูงเปล่าประกอบด้วยพื้นที่รกร้างจำนวนมาก แต่ยังคงสังเกตเห็นหลังคาและถนนสีแดงอ่อน (รูปที่ 12)



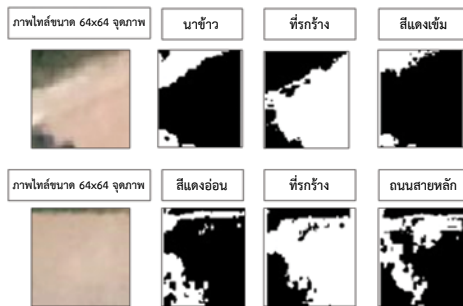
รูปที่ ๙ ฟิวเจอร์ RGB ตามแบบฉบับสำหรับอาคาร (ฟิวเจอร์ RGB แสดงด้วยสีขาว)



รูปที่ ๑๐ ฟิวเจอร์ RGB ตามแบบฉบับสำหรับพืชพรรณ (ฟิวเจอร์ RGB แสดงด้วยสีขาว)



รูปที่ ๑๑ ฟิวเจอร์ RGB ตามแบบฉบับสำหรับทางหลัก (ฟิวเจอร์ RGB แสดงด้วยสีขาว)




รูปที่ ๑๒ ฟิวเจอร์ RGB ตามแบบฉบับสำหรับที่รกร้าง (ฟิวเจอร์ RGB แสดงด้วยสีขาว)

3.3.3 แบบจำลองพื้นฐานและการติดป้ายกำกับ

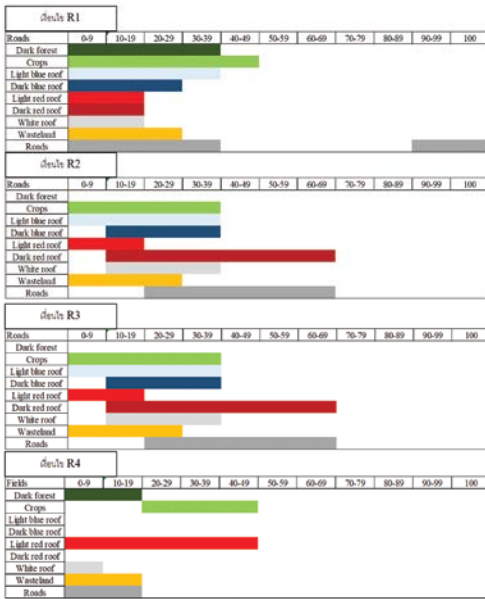
โพลีของชุดข้อมูลเกิดจากกระบวนการรวมกันของชุดข้อมูลที่กำหนดไว้ก่อนหน้านี้ (รูปที่ 7) ดังนั้นในการจำแนกโพลีเหล่านี้ อาศัยเกณฑ์การพิจารณาความเด่นชัดที่ปรากฏออกมา ดังนั้น อัตราส่วนของประเภทของวัตถุในชุดข้อมูลจึงถูกกำหนดในฟิวเจอร์ RGB ต่าง ๆ อัตราส่วนของประเภทของวัตถุในชุดข้อมูลที่ว่านี่คือสิ่งที่ประกอบขึ้นเป็นโมเดลแบบพื้นฐานตามที่กำหนดไว้ โดยในการจำแนกโพลีต้องใช้อัตราส่วนของชั้นที่แตกต่างกัน (สมการที่ 4)

$$\text{อัตราส่วนประเภทของวัตถุในชุดข้อมูล} = \left[\begin{array}{l} \text{ขีดจำกัดล่าง } < \frac{f_i}{F} \text{ ของอัตราส่วน } f_i < \text{ขีดจำกัดบน } & \text{ขีดจำกัดล่าง } < \frac{f_j}{F} \text{ ของอัตราส่วน } f_j < \text{ขีดจำกัดบน } \\ \text{ขีดจำกัดล่าง } < \frac{f_k}{F} \text{ ของอัตราส่วน } f_k < \text{ขีดจำกัดบน } \dots \end{array} \right] \quad (4)$$


ค่า Lower Limit และ Higher Limit ของฟิวเจอร์ RGB เป็นค่าเริ่มต้นที่กำหนดขึ้นก่อนใช้งาน โดยแบ่งออกเป็นสำหรับพื้นที่ชนบทในประเทศไทย ด้วยภาพที่มีความละเอียด 0.25 เมตร/จุดภาพ เพื่อลดการจำแนกประเภทที่ผิดพลาดและทำให้ขั้นตอนการคัดกรองชุดข้อมูลทำได้สะดวกขึ้นในภายหลัง อัตราส่วนของประเภทของชุดข้อมูลจะถูกจำกัดเพื่อให้ได้ความแม่นยำที่สูงขึ้น โดยในชุดข้อมูลประเภทพืชพรรณและที่รกร้างมีคุณลักษณะเฉพาะทางย่านสีเนื่องจากส่วนใหญ่เป็นสีเขียวและทราาย ในขณะที่ถนนและอาคารต้องการอัตราส่วนของประเภทชุดข้อมูลที่มากขึ้น ในทางปฏิบัติชุดข้อมูล 2 ประเภทนี้แสดงถึงพื้นที่การใช้ประโยชน์ที่ดินประเภทอื่น ๆ ดังนั้นจึงจำเป็นต้องมีอัตราส่วนคลาวด์ถึง 4 ชั้น เงื่อนไขสำหรับแต่ละประเภทของวัตถุในชุดข้อมูลถูกกำหนดไว้ด้านล่าง (รูปที่ 13-16) ระเบียบวิธีทั้งหมด (Global methodology) ที่ใช้ในกรณีศึกษาที่เป็นพื้นที่ชนบทในประเทศไทย สรุปไว้ในรูปที่ 17






รูปที่ ๑๓ อัตราส่วนประเภทของวัตถุในชุดข้อมูลของพืชพรรณ



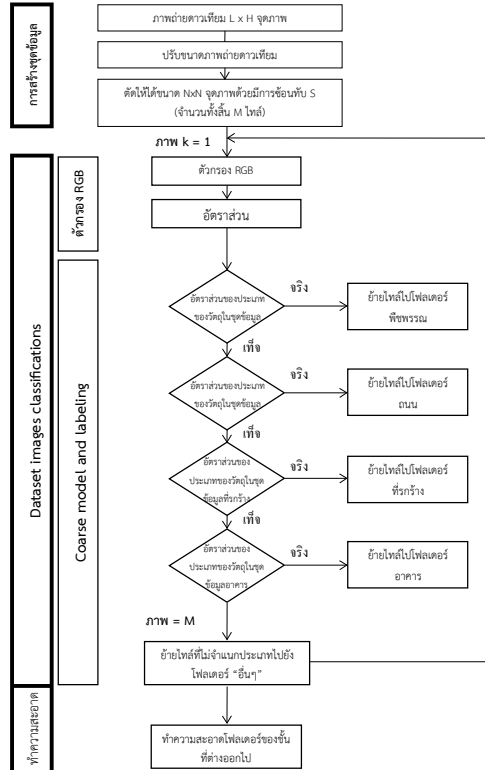
รูปที่ ๑๔ อัตราส่วนประเภทของวัตถุในชุดข้อมูลของถนน



รูปที่ ๑๕ อัตราส่วนประเภทของวัตถุในชุดข้อมูลของที่รกร้าง



รูปที่ ๑๖ อัตราส่วนประเภทของวัตถุในชุดข้อมูลของอาคาร



รูปที่ ๑๗ กระบวนการสร้างชุดข้อมูลสำหรับกรณีศึกษาพื้นที่ชนบทในประเทศไทย

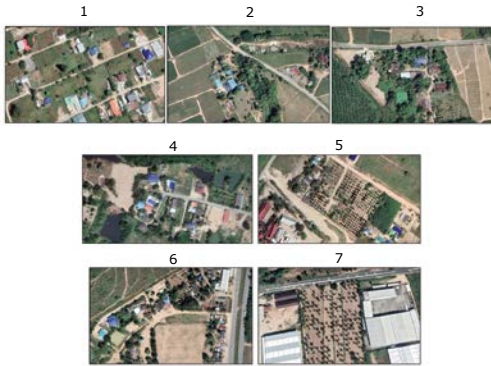
4. ผลการศึกษา

4.1 ฮาร์ดแวร์และซอฟต์แวร์

บทความวิชาการนี้ดำเนินการโดยใช้ Rstudio 1.2.1335 พร้อม R 3.6.0 การจำลองทำงานบนระบบปฏิบัติการ Windows บนอุปกรณ์ประมวลผลแบบ Dell Precision T1700, Intel Core i7-4790 CPU @3.6 GHz, หน่วยความจำ 8 GB DDR4 และฮาร์ดดิสก์ HDD 7200 RPM

4.2 การตรวจสอบความถูกต้องของระเบียบวิธีวิจัย

เพื่อตรวจสอบความถูกต้องของระเบียบวิธีวิจัย (รูปที่ 17) ได้ทำการศึกษาภาพถ่ายดาวเทียมใหม่ขนาด 1,408x832 จุดภาพ จำนวน 7 ภาพ และมีความละเอียด 0.25 เมตร/จุดภาพ (รูปที่ 18)



รูปที่ ๑๘ ภาพถ่ายดาวเทียมที่ใช้ศึกษาพื้นที่ชนบทของประเทศไทย

ภาพถ่ายดาวเทียมถูกตัดออกเป็นไทล์ 64x64 จุดภาพ โดยใช้การซ้อนทับกัน 32 จุดภาพ และสร้าง

ตารางที่ 2 เปอร์เซ็นต์ของภาพชุดข้อมูลขนาด 64x64 จุดภาพที่สร้างต่อประเภทของวัตถุในชุดข้อมูล

ภาพ	อาคาร [%]	ป่า/พืชพรรณ [%]	ถนน [%]	ที่รกร้าง [%]	ระบุไม่ได้ [%]
1	8.0	1.0	9.4	0.6	81.0
2	1.2	6.8	6.1	0.0	85.9
3	1.8	18.3	6.1	0.5	73.3
4	3.2	21.3	6.7	2.4	66.4
5	3.3	20.5	3.5	5.3	82.1
6	3.9	10.7	10.1	1.0	74.3
7	25.0	5.0	7.5	1.8	60.7

ในการประเมินประสิทธิภาพการระบุตัวตน โดยทั่วไปจะใช้ความแม่นยำ อัตรา Recall และอัตราความแม่นยำ ความแม่นยำสำหรับแต่ละประเภทของวัตถุในชุดข้อมูลคือเปอร์เซ็นต์ของผลลัพธ์ที่เกี่ยวข้อง และกำหนดโดยสมการที่ 6

$$\text{ความแม่นยำ} = \frac{TP}{TP+FP} \quad (6)$$

โดยที่ TP และ FP คือค่าลบจริง (True Positive) และค่าลบเท็จ (False Positive) ตามลำดับ อัตรา Recall คือความสามารถของวิธีการในการค้นหากรณี

ภาพทั้งหมด 7,525 ภาพ โดยในขั้นแรกเป็นการบันทึกจำนวนรูปภาพทั้งหมดสำหรับแต่ละประเภทของวัตถุของชุดข้อมูล และกำหนดเปอร์เซ็นต์ของแต่ละประเภทของวัตถุในชุดข้อมูลดังสมการที่ 5

$$\% \text{ประเภทของวัตถุในชุดข้อมูล} = \frac{\text{จำนวนของภาพ } 64 \times 64 \text{ จุดภาพของประเภทของวัตถุในชุดข้อมูล}}{\text{จำนวนของภาพขนาด } 64 \times 64 \text{ จุดภาพ}} \times 100 \quad (5)$$

เนื่องจากวัตถุที่จำแนกได้จากภาพถ่ายจากดาวเทียมมีเพียงอาคาร พืชพรรณ ถนน และพื้นที่รกร้างเท่านั้น จำนวนชุดข้อมูลภาพที่สร้างขึ้นจึงน้อยมากเมื่อเทียบกับภาพขนาด 64x64 จุดภาพ ที่รวบรวมได้ในตอนเริ่มต้น ส่งผลให้ภาพกว่า 75% ไม่สามารถระบุได้ (ตารางที่ 2)

และปัญหาที่เกี่ยวข้องทั้งหมดภายในชุดข้อมูลและกำหนดโดยสมการที่ (7)

$$\text{อัตราการเรียกคืน} = \frac{TP}{TP+FN} \quad (7)$$

โดยที่ FN เป็นค่าลบเท็จ (False Positive) รหัสความถูกต้องที่กำหนดเป็นสัดส่วนในการตรวจนับประเภทของวัตถุในชุดข้อมูลอย่างถูกต้องจากจำนวนประเภทของวัตถุในชุดข้อมูลทั้งหมดและกำหนดโดยสมการที่ (8)

$$\text{ความถูกต้อง} = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

โดยที่ TN เป็นค่าลบจริง (True Positive) ค่าลบจริงและค่าลบเท็จได้รับการยืนยันด้วยคนในโพลเดอร์อื่นที่สร้างไว้ (รูปที่ 17) ในการประเมินความถูกต้องของวิธีการที่เสนอนี้ รูปภาพชุดข้อมูลที่สร้างขึ้นได้รับการตรวจสอบด้วยคน (ตารางที่ 3) พื้นที่กร้างแสดงความแม่นยำสูงสุดในขณะที่ถนนมีค่าต่ำสุดใน 100% ของภาพที่ระบุว่าเป็นพื้นที่กร้างมาจากประเภทของวัตถุในชุดข้อมูลนี้ ในทางตรงกันข้าม ถนนมีความแม่นยำถึง 68% นั่นคือประมาณ 1 ใน 3 ของประเภทถนนที่ระบุไม่ได้มาจากประเภทของวัตถุในชุดข้อมูลนี้ อาคารและพืชพรรณมีความแม่นยำ 98% และ 90.5% ตามลำดับ ดังนั้น มีเพียง 2% ของอาคารที่ระบุ

เท่านั้นที่ไม่ได้มาจากประเภทของวัตถุในชุดข้อมูลนี้ การเรียกคืนอาคารและที่กร้างนั้นต่ำที่สุดคือ 48% และ 42.6% ตามลำดับ หมายความว่าภาพเริ่มต้นส่วนใหญ่ของทั้ง 2 ประเภทของวัตถุในชุดข้อมูลนี้ไม่ได้รับการระบุ 71% ของภาพพืชพรรณเมื่อเริ่มต้นถูกระบุ ในทางตรงกันข้าม การเรียกคืนประเภทของวัตถุในชุดข้อมูลถนนคือ 76% หมายความว่าภาพถนนทั้งหมดเมื่อเริ่มต้นส่วนใหญ่ได้รับการระบุมาเป็นอย่างดี ดังนั้น จึงต้องดำเนินการทำความสะอาดเพื่อหลีกเลี่ยงภาพถ่ายของชุดข้อมูลที่ไม่ถูกต้องในแต่ละประเภทของวัตถุในชุดข้อมูล หายที่สุดความถูกต้องสำหรับทั้ง 4 ประเภทของวัตถุในชุดข้อมูลมีค่าสูงกว่า 94%

ตารางที่ 3 Recall ความแม่นยำและความถูกต้องสำหรับชุดข้อมูลแต่ละชุดที่ประเภทของวัตถุในชุดข้อมูลของภาพ 64x64 จุดภาพ

ประเภทของวัตถุในชุดข้อมูล		ภาพ						
		1	2	3	4	5	6	7
อาคาร	การเรียกคืน	49.6	45.9	38.4	48.6	36.4	32.8	86.3
	ความแม่นยำ	98.6	92.2	100.0	100.0	100.0	97.6	98.1
	ความถูกต้อง	90.9	98.4	96.2	95.1	93.2	89.9	94.9
พืชพรรณ	การเรียกคืน	25.7	73.2	84.2	75.1	96.7	79.3	62.6
	ความแม่นยำ	88.9	97.3	100.0	100.0	96.7	100.0	49.8
	ความถูกต้อง	96.7	97.2	96.2	92.0	99.6	96.7	93.9
ถนน	การเรียกคืน	89.9	63.1	78.4	73.3	92.0	81.6	55.0
	ความแม่นยำ	63.2	57.3	83.2	55.3	62.1	89.9	65.3
	ความถูกต้อง	95.4	94.9	97.0	94.1	98.2	96.4	90.3
ที่กร้าง	การเรียกคืน	57.4		17.7	42.9	50.0	24.0	63.8
	ความแม่นยำ	100.0		100.0	100.0	100.0	100.0	100.0
	ความถูกต้อง	99.5	99.6	96.8	95.4	93.9	95.8	98.4

4.3 ผลกระทบของภาพถ่ายดาวเทียมที่ใส่เข้าไป

ภาพถ่ายดาวเทียมในพื้นที่ชนบทของประเทศไทยแตกต่างกันจำนวน 4 ภาพ (รูปที่ 19) มีความละเอียดเท่ากัน คือ 0.25 เมตร/จุดภาพ ได้รับการตรวจสอบโดยใช้กระบวนการที่เสนอแบบเดียวกันและด้วยพารามิเตอร์เดียวกันในแง่ของการทับซ้อนกันและขนาดไทล์ (ตารางที่ 4) มีการรายงานรูปภาพที่ไม่ได้ระบุโดยเฉลี่ย 76.5%

ซึ่งใกล้เคียงกับผลลัพธ์ที่ได้จากภาพก่อนหน้า (75%) ยกเว้นรูปที่ 19 ก) รูปภาพอื่น ๆ แสดงค่าความแม่นยำและการเรียกคืนที่ใกล้เคียงกับภาพก่อนหน้า การเลือกภาพถ่ายจากการรับรู้ระยะไกลที่ใส่เข้าไปจะต้องทำอย่างระมัดระวัง เพื่อให้พารามิเตอร์แบบจำลองพื้นฐานมีความเหมาะสม



รูปที่ ๑๙ กรณีศึกษา

4.3 ผลกระทบของขนาดการซ้อนทับ

ในการเพิ่มจำนวนไทล์ในชุดข้อมูลนั้น ขนาดที่ซ้อนทับกันได้ลดลงเหลือ 16 จุดภาพ ดังนั้น ภาพเริ่มต้นที่ 1,408x832 จุดภาพ จะสร้าง 4,165 ไทล์ที่มีขนาด 64x64 จุดภาพ การใช้การทับซ้อนที่มีขนาดเล็กลงไม่ได้มีอิทธิพลอย่างมีนัยสำคัญต่อร้อยละของไทล์ชุดข้อมูลที่ระบุ (ตารางที่ 4) ตามความเป็นจริงแล้วมีการรายงานรูปภาพที่ไม่สามารถระบุได้โดยเฉลี่ย 76.9% ซึ่งใกล้เคียงกับค่าเฉลี่ยสำหรับการซ้อนทับกัน 32 จุดภาพ (76.6%) ดังนั้น จึงมีความเป็นไปได้ว่าการลดขนาดทับซ้อนจะเพิ่มความแม่นยำขึ้นเพียงไม่กี่เปอร์เซ็นต์

ตารางที่ 4 เปอร์เซ็นต์ของประเภทของวัตถุในชุดข้อมูลที่ได้จากการใช้การทับซ้อนกันที่ 16 และ 32 จุดภาพ

ภาพ	อาคาร [%]		พืชพรรณ [%]		ถนน [%]		ที่รกร้าง [%]		อื่นๆ [%]	
ซ้อนทับ	32	16	32	16	32	16	32	16	32	16
a	4.5	3.8	5.3	6	8.2	7.1	0.8	1.1	81.2	82
b	2.5	1.6	10.1	11.2	10.9	9.8	0	0	76.5	77.4
c	4.7	3.8	7.3	8.5	9.3	8.3	0	0	78.7	79.4
d	5.3	4.1	20.5	23.8	4.3	3.6	0	0	69.9	68.6

ตารางที่ 5 Recall ความแม่นยำ และความแม่นยำสำหรับแต่ละประเภทของวัตถุในชุดข้อมูล โดยใช้การซ้อนทับกันที่ 16 และ 32 จุดภาพ

ประเภทของวัตถุ ในชุดข้อมูล	การซ้อนทับกัน	Images							
		a		b		c		d	
		32	16	32	16	32	16	32	16
อาคาร	การเรียกคืน	33.6	33	21.1	24.1	59.8	67.5	43.4	47.4
	ความแม่นยำ	79.9	74.9	92.6	96.0	94.1	97.2	98.2	99.0
	ความถูกต้อง	90.7	92.2	88.8	93.5	96.1	97.4	90.9	91.9
พืชพรรณ	การเรียกคืน	65.7	68.9	70.6	70.0	74.6	76.2	80.8	96.2
	ความแม่นยำ	77.2	91.5	90.8	96.0	97.5	99.0	80	94.3
	ความถูกต้อง	96.1	96.6	94.5	94.1	97	96.5	91.2	97.0
ถนน	การเรียกคืน	38.3	42.8	56.2	42.7	85.2	80.0	72.1	77.8
	ความแม่นยำ	24	30.4	47.5	50.0	46	48.9	50.2	41.2
	ความถูกต้อง	89.5	91.2	86.4	86.3	91.5	93.3	96	95.4
ที่รกร้าง	การเรียกคืน	32.3	36.3						
	ความแม่นยำ	100	100						
	ความถูกต้อง	98	97.7						

4.4 ผลกระทบของสัดส่วนของภาพ

ผลกระทบของสัดส่วนของภาพได้รับการศึกษาโดยใช้ภาพถ่ายดาวเทียมของรูปที่ 19 ใช้ขนาดที่ตัด 128x128 จุดภาพ และซ้อนทับกัน 64 จุดภาพ ไม่พบผลกระทบที่มีนัยสำคัญต่อจำนวนรูปภาพที่ไม่ได้ระบุโดยเฉลี่ย 76.5% เทียบกับ 75% ที่มีการตัด 64x64 จุดภาพ (ตารางที่ 6) อย่างไรก็ตาม จำนวนรูปภาพที่ระบุต่อประเภทของวัตถุในชุดข้อมูลได้รับการแก้ไข (ตารางที่ 6) เมื่อขนาดของไพล์เพิ่มขึ้น บริบทของแต่ละรายการก็เปลี่ยนไปอย่างมาก และการใช้พารามิเตอร์เดียวกันจะแก้ไขผลลัพธ์ได้ โดยสรุปแล้วไพล์ใหญ่ขึ้น

แสดงองค์ประกอบในภาพที่มากขึ้น และที่ยากยิ่งขึ้นคือระบุประเภทของวัตถุในชุดข้อมูลที่ต้องการ ด้วยขนาดที่ใหญ่ขึ้น ไพล์ที่รกร้างว่างเปล่าไม่ได้มีเพียงประเภทของวัตถุในชุดข้อมูลนี้เท่านั้น ดังนั้น จำนวนภาพที่ตรวจพบจึงลดลง (รูปที่ 20) ในทางกลับกัน จำนวนภาพที่ระบุว่าเป็นอาคารและถนนเพิ่มขึ้นเล็กน้อย นอกจากนี้เนื่องจากอาคารตั้งอยู่ติดถนนตลอดเวลา จึงยากที่จะแยกความแตกต่างระหว่าง 2 ประเภทของวัตถุในชุดข้อมูลนี้ (รูปที่ 20) สุดท้าย การเลือกขนาดไพล์จึงเป็นจุดสำคัญ เพื่อรักษาบริบทที่ใหญ่ขึ้นอย่างมีนัยสำคัญตามที่อธิบายโดย [49], [69]

ตารางที่ 6 เปอร์เซ็นต์ของชุดข้อมูลภาพขนาด 128x128 จุดภาพ ที่สร้างต่อประเภทของวัตถุในชุดข้อมูลโดยใช้การซ้อนทับกัน 16 จุดภาพ

ภาพ	อาคาร [%]	ป่า/พืชพรรณ [%]	ถนน [%]	ที่รกร้าง [%]	ระบุไม่ได้ [%]
1	7.6	0.0	15.7	0.0	76.7
2	1.2	4.0	6.3	0.0	88.5
3	1.2	12.3	4.8	0.0	81.7
4	5.8	16.1	12.0	0.8	65.3
5	2.2	3.9	3.9	2.2	87.8
6	2.8	5.6	15.5	0.0	76.1
7	29.0	2.0	9.5	0.4	59.1



รูปที่ ๒๐ อาคาร ถนน และพื้นที่รกร้างโดยใช้การตัด 128x128 จุดภาพ

5. การอภิปรายผล

จากการสังเกตจะเห็นได้ว่าอาคารและพื้นที่รกร้างมีค่า Recall ต่ำสุด 40% และ 32% ตามลำดับ (ตารางที่ 3 และ 5) ภาพสองประเภทของวัตถุในชุดข้อมูลเริ่มต้นเหล่านี้ส่วนใหญ่ไม่สามารถระบุได้ ไพล์ขนาด 64x64 จุดภาพ ที่มีอัตราส่วนต่อการบ่งชี้วัตถุประเภทอาคารต่ำจะไม่ถูกรวมอยู่ในส่วนที่มีการบ่งชี้ (รูปที่ 21) นอกจากนี้ อาคารที่มีหลังคาสีน้ำตาลเข้ม มีผลต่อการบ่งชี้เนื่องจากมีแถบ RGB ที่พบได้ทั่วไปในชุดภาพประเภทพืชพรรณ เนื่องจากต้องใช้ความแม่นยำสูงเพื่อหลีกเลี่ยงการระบุประเภทของวัตถุในชุดข้อมูลที่ไม่ถูกต้อง การระบุอาคารจึงถูกจำกัดโดยใช้ค่าที่ต่ำกว่าของประเภทของวัตถุในชุดข้อมูลอื่น ดังนั้น จึงไม่รวมภาพบางภาพ (รูปที่ 21) ที่รกร้างแสดง

ความแม่นยำ 100% ด้วยวิธีการนี้ แต่ไม่รวมภาพจำนวนมาก (รูปที่ 21)



รูปที่ ๒๑ ภาพขนาด 64x64 จุดภาพ ตามแบบฉบับของ FN อาคาร, FP พืชพรรณ และ FN ที่รกร้าง

ตามที่ได้ตรวจสอบแล้วในการทบทวนวรรณกรรม ภาพประเภทถนนมีข้อจำกัดในการสกัดข้อมูล [70] โดยใช้วิธีการที่เสนอ (รูปที่ 17) โดยผลลัพธ์ที่ได้มีความแม่นยำต่ำ โดยมีค่าเฉลี่ยที่ 68% (ตารางที่ 3 และ 5) ไทล์ที่มี False Positive ส่วนใหญ่สร้างด้วยหลังคาสีเทาและที่จอดรถ (รูปที่ 22) ซึ่งแสดงตัวกรอง RGB เดียวกันกับถนน (รูปที่ 8) ค่า Recall เป็นที่ยอมรับได้โดยมีค่าเฉลี่ย 76% ไทล์ที่เป็นลบเท็จแสดงอัตราส่วนของถนนต่ำ (รูปที่ 22) เนื่องจากข้อจำกัดอัตราส่วนของชั้นเรียนที่ใช้ (รูปที่ 14)



รูปที่ ๒๒ FP และ FN ประเภทของวัตถุในชุดข้อมูลถนนขนาด 64x64 จุดภาพ ตามแบบฉบับ

เวลาที่ใช้ในการสร้างภาพประมาณ 100 ภาพต่อชั้นประเภทของวัตถุในชุดข้อมูล คือประมาณ 2 ชั่วโมง 30 นาที โดยใช้คอมพิวเตอร์เดสก์ท็อปที่ขายในท้องตลาดและมีประสิทธิภาพต่ำ การวิจัยตามการทบทวนวรรณกรรมแสดงให้เห็นว่าจำเป็นต้องมีชุดข้อมูลขนาดใหญ่ [51] ตัวอย่างเช่น มีการใช้รูปภาพมากกว่า 100,000 ภาพต่อประเภทของวัตถุในชุดข้อมูล เพื่อดำเนินการให้ครอบคลุมพื้นที่ของประเทศไทย [52]-[53] อย่างไรก็ตาม ชุดข้อมูลถูกสร้างขึ้นเพียงครั้งเดียว ดังนั้น ด้วยการใช้คอมพิวเตอร์ประสิทธิภาพสูงและการระบุประเภทของวัตถุในชุดข้อมูลบนคอมพิวเตอร์เครื่องอื่นเข้ามาช่วย จะทำให้เวลาลดลงอย่างมาก สังเกตได้ว่าเวลาที่ใช้ในการกรอง RGB นั้น มีค่าสูงที่สุด การดำเนินการเหล่านี้ต้องใช้เวลา 11.7 วินาที (ต่อภาพขนาด 64x64 จุดภาพ) ในขณะที่ต้องใช้เพียง 0.10 วินาที ในการเรียกใช้อัตราส่วนของประเภทของวัตถุในชุดข้อมูลที่ต่างกัน

6. สรุปผลการศึกษา

โดยทั่วไปการสร้างชุดข้อมูลสำหรับการใช้พื้นที่ด้วยแบบจำลอง CNN นั้น มีกระบวนการที่ต้องใช้เวลาและทรัพยากร เนื่องจากต้องดำเนินการที่ละเอียดรอบคอบและระยะเวลาในการดำเนินการในขั้นตอนนี้ บทความนี้ได้เสนอวิธีการผลิตภาพชุดข้อมูลสำหรับสิ่งปกคลุมดินโดยอ้างอิงจาก 5 ขั้นตอน ประกอบด้วย การรับข้อมูลภาพจากการรับรู้ระยะไกล การสร้างไทล์ให้ได้จำนวนมากๆ โดยวิธีการสุ่มตัวอย่าง การสร้างชุดข้อมูลและการติดป้ายกำกับโดยใช้แบบจำลองแบบพื้นฐาน การคัดกรองชุดข้อมูล และการนำไปใช้งาน สำหรับแบบจำลอง CNN มีการเสนอระเบียบวิธีวิจัยสำหรับชุดข้อมูล 4 ประเภทของวัตถุในชุดข้อมูล ประกอบด้วย อาคาร ถนน พื้นที่รกร้าง และพืชพรรณ สำหรับพื้นที่ชนบทในประเทศไทย มีการรวบรวมภาพถ่ายดาวเทียมและใช้กระบวนการซ้อนทับกันเพื่อสร้างไทล์ขนาด 64x64 จุดภาพ ที่มีความละเอียด 0.25 เมตร/จุดภาพ มีการเสนอแบบจำลองพื้นฐานเพื่อจำแนกและติดป้ายกำกับตามค่าจุดภาพตามย่านสี RGB โดยใช้อัตราส่วนของประเภทของวัตถุในชุดข้อมูลที่แตกต่างกันในการจำแนก

กระบวนการที่นำเสนอในบทความนี้มีความแม่นยำสูงมากถึง 98% และ 100% สำหรับประเภทของวัตถุในชุดข้อมูลอาคารและประเภทของวัตถุในชุดข้อมูลพื้นที่รกร้างตามลำดับ ประเภทของวัตถุในชุดข้อมูลถนนมีความแม่นยำที่ต่ำกว่าด้วยค่า 68% จึงมีความจำเป็นในการคัดกรองชุดข้อมูลที่สร้างขึ้น อย่างไรก็ตามวิธีการนี้สามารถนำมาใช้เพื่อระบุภาพถนนเพื่อเป็นการคัดกรองประเภทของภาพในขั้นต้นได้ ซึ่งช่วยลดระยะเวลาในการสร้างชุดข้อมูล อีกทั้งยังมีการศึกษาขนาดที่ทับซ้อนกันและค้นพบว่าไม่มีผลกระทบที่มีนัยสำคัญ ปัจจัยสำคัญที่ส่งผลต่อความแม่นยำคือขนาดของไฟล์ที่ 128x128 จุดภาพ ที่จะพอเพียงพอการแสดงองค์ประกอบเพื่อคงไว้ซึ่งอัตราความแม่นยำถูกต้องที่น่าเชื่อถือได้

อย่างไรก็ตาม จากการวิเคราะห์ระเบียบวิธีวิจัยพบว่าการสร้าง RGB Filter นั้น เป็นอีกหนึ่งกระบวนการที่ใช้เวลา ระเบียบวิธีวิจัยนี้สามารถแก้ไขได้ง่ายโดยใช้ Filter เดียวกันเพื่อสร้างประเภทของวัตถุในชุดข้อมูลเพิ่มเติมหรือเพื่อปรับปรุงความแม่นยำ ซึ่งจะเป็นการปรับปรุงวิธีการให้เหมาะสมโดยการเพิ่มประเภทของชุดข้อมูลภาพที่เป็นพื้นที่ว่างเปล่า โดยใช้ RGB Filter นอกจากนี้ อัตราส่วนประเภทของวัตถุในชุดข้อมูลใหม่สำหรับถนนและพืชพรรณยังอยู่ระหว่างการตรวจสอบเพื่อเพิ่มความแม่นยำ

7. กิตติกรรมประกาศ

ผู้เขียนขอขอบคุณสำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (GISTDA) สำหรับการดำเนินงานและเรื่องอื่น ๆ ที่เกี่ยวข้องเพื่อให้เกิดความมั่นใจในความคืบหน้าของการวิจัย และผู้เขียนขอขอบคุณ AIRBUS ที่ให้การสนับสนุนด้วยดีมาตลอด

8. คำชี้แจงและประกาศ

เงินทุน: งานวิจัยนี้ไม่ได้รับทุนสนับสนุนเป็นการเฉพาะใด ๆ จากหน่วยงานให้ทุนอุดหนุนในภาครัฐ ภาคการค้า หรือหน่วยงานไม่แสวงหาผลกำไรอื่น ๆ

ความขัดแย้งทางผลประโยชน์หรือผลประโยชน์

ทับซ้อน: ผู้เขียนไม่มีส่วนได้เสียที่จะประกาศว่ามีความเกี่ยวข้องกับเนื้อหาของบทความนี้

การอนุมัติด้านจริยธรรม: ไม่มี

ความยินยอมในการเข้าร่วม: ผู้เขียนทุกคนอ่านและอนุมัติต้นฉบับและการส่งต้นฉบับ

ความพร้อมใช้งานของข้อมูลและวัสดุ: ไม่เกี่ยวข้อง

ความพร้อมใช้งานของรหัส: การใช้งานและการคำนวณทั้งหมดที่นำเสนอในเอกสารนี้ดำเนินการภายใต้สภาพแวดล้อม Windows โดยใช้ Rstudio 1.2.1335 กับ R 3.6.0

ผลงานของผู้เขียน: Dr. Mezeix รับผิดชอบการเขียนโปรแกรม พัฒนาวិธีการและวิเคราะห์ข้อมูล ดร.หงษ์กัญจนากุล ดำเนินการสร้างชุดข้อมูลและเขียนบทความ Dr. Schwob เข้าร่วมทั้งวิธีการและการเพิ่มประสิทธิภาพแบบจำลอง

9. เอกสารอ้างอิง

- [1] S. A. A. Rafee *et al.*, “Large-Scale Hydrological Modelling of the Upper Paraná River Basin,” *Water*, vol. 11, no. 5, p. 882, 2019.
- [2] Y. Bai, M. Feng, H. Jiang, J. Wang, Y. Zhu, and Y. Liu, “Assessing Consistency of Five Global Land Cover Datasets in China,” *Remote Sens.*, vol. 6, no. 9, pp. 8739 - 8759, 2014.
- [3] J. A. Foley *et al.*, “Global Consequences of Land Use,” *Science*, vol. 309, no. 5734, pp. 570 - 574, 2005.
- [4] M. Höjer *et al.*, “Scenarios in Selected Tools for Environmental Systems Analysis,” *J. Clean. Prod.*, vol. 16, no. 18, pp. 1958 - 1970, 2008.
- [5] R. Hollmann *et al.*, “The ESA Climate change Initiative: Satellite Data Records for Essential Climate Variables,” *Bull. Amer. Meteorological Soc.*, vol. 94, no. 10, pp. 1541 - 1552, 2013.
- [6] C. Homer *et al.*, “Completion of the 2011 National Land Cover Database for the

- Conterminous United States-Representing a Decade of Land Cover Change Information,” *Photogramm. Eng. Remote Sens.*, vol. 81, no. 5, pp. 345 - 354, 2015.
- [7] J. A. Martins, V. S. Brand, M. N. Capucim, C. B. Machado, D. G. A. Piccilli, and L. D. Martins, “The Impact of Rainfall and Land Cover Changes on the Flow of a Medium-sized River in the South of Brazil,” *Energy Procedia*, vol. 95, pp. 272 - 278, 2016.
- [8] W. B. Meyer and B. L. Turner II, *Changes in Land Use and Land Cover: A Global Perspective*. 1st ed. Cambridge, UK: Cambridge Univ. Press, 1994.
- [9] M. V. B. de Moraes, V. V. U. Guerrero, L. D. Martins, and J. A. Martins, “Dynamical Downscaling of Future Climate Change Scenarios in Urban Heat Island and Its Neighborhood in a Brazilian Subtropical Area,” in *2nd Int. Electron. Conf. Atmospheric Sci.*, Proc., vol. 1, no. 15, Jul. 2017, pp. 1 - 13.
- [10] R. H. Moss *et al.*, “The Next Generation of Scenarios for Climate Change Research and Assessment,” *Nature*, vol. 463, pp. 747 - 756, 2010.
- [11] M. Schaefer and N. X. Thinh, “Evaluation of Land Cover Change and Agricultural Protection Sites: A GIS and Remote Sensing Approach for Ho Chi Minh City, Vietnam,” *Heliyon*, vol. 5, no. 5, p.e01773, 2019.
- [12] S. D. Tarigan, “Land Cover Change and Its Impact on Flooding Frequency of Batanghari Watershed, Jambi Province, Indonesia,” *Procedia Environ. Sci.*, vol. 33, pp. 386 - 392, 2016, doi: 10.1016/j.proenv.2016.03.089.
- [13] D. T. Nguyen, I. Iskandar, and S. Ho, “Land Cover Change and the CO₂ Stock in the Palembang City, Indonesia: A Study Using Remote Sensing, GIS Technique and LUMENS,” *Egypt. J. Remote. Sens. Space Sci.*, vol. 19, no. 2, pp. 313 - 321, Dec. 2016, doi: 10.1016/j.ejrs.2016.08.004.
- [14] K. Trincsi, T-T-H. Pham, and S. Turner, “Mapping Mountain Diversity: Ethnic Minorities and Land Use Land Cover Change in Vietnam’s Borderlands,” *Land Use Policy*, vol. 41, pp. 484 - 497, 2014.
- [15] N. D. A. Halim *et al.*, “Spatial Assessment of Land Use Impact on Air Quality in Mega Urban Regions, Malaysia,” *Sustain. Cities Soc.*, vol. 63, 2020.
- [16] D. P. Shrestha, M. Suriyaprasit, and S. Prachansri, “Assessing Soil Erosion in Inaccessible Mountainous Areas in the Tropics: The Use of Land Cover and Topographic Parameters in a Case Study in Thailand,” *Catena*, vol. 121, pp. 40 - 52, Oct. 2014, doi: 10.1016/j.catena.2014.04.016.
- [17] R. Patarasuk, “Road Network Connectivity and Land-cover Dynamics in Lop Buri Province, Thailand,” *J. Transp. Geogr.*, vol. 28, pp. 111 - 123, 2013.
- [18] R. Patarasuk and M. W. Binford, “Longitudinal Analysis of the Road Network Development and Land-cover Change in Lop Buri Province, Thailand, 1989-2006,” *Appl. Geogr.*, vol. 32, no. 2, pp. 228 - 239, 2012.
- [19] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based Learning Applied to Document Recognition,” in *Proc. IEEE*,

- vol. 86, no. 11, pp. 2278 - 2324, 1998.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, "Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition," in *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 37, no. 9, pp. 1904-1916, 2015, doi: 10.1109/TPAMI.2015.2389824.
- [21] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," in *IEEE Conf. Comput. Vision Pattern Recognit.*, 2016, pp. 2261 - 2269.
- [22] O. Russakovsky *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, vol. 115, pp. 211 - 252, Apr. 2015, doi: 10.1007/s11263-015-0816-y.
- [23] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," in *ICLR 2015*, May. 2015, pp. 1 - 14.
- [24] C. Szegedy *et al.*, "Going Deeper with Convolutions," in *2015 IEEE Conf. Comput. Vision Pattern Recognit. (CVPR)*, Boston, MA, USA, 2015, pp. 1 - 9, doi: 10.1109/CVPR.2015.7298594.
- [25] B. Zoph, V. Vasudevan, J. Shlens, and Q. V. Le, "Learning Transferable Architectures for Scalable Image Recognition," in *2018 IEEE/CVF Conf. Comput. Vision Pattern Recognit.*, Salt Lake City, UT, USA, 2018, pp. 8697 - 8710, doi: 10.1109/CVPR.2018.00907.
- [26] W. Li, C. Chen, M. Zhang, H. Li, and Q. Du, "Data Augmentation for Hyperspectral Image Classification With Deep CNN," in *IEEE Geosci. Remote Sens. Lett.*, vol. 16, no. 4, pp. 593 - 597, 2019.
- [27] L. Ma, Y. Liu, X. Zhang, Y. Ye, G. Yin, and B. A. Johnson, "Deep Learning in Remote Sensing Applications: A Meta-analysis and Review," *ISPRS J. Photogramm. Remote Sens.*, vol. 152, pp. 166 - 177, 2019.
- [28] M. Panahi, N. Sadhasivam, H. R. Pourghasemi, F. Rezaie, and S. Lee, "Spatial Prediction of Groundwater Potential Mapping Based on Convolutional Neural Network (CNN) and Support Vector Regression (SVR)," *J. Hydrol.*, vol. 588, p.125033, 2020.
- [29] S. Ji, Z. Chi, A. Xu, Y. Shi, and Y. Duan, "3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images," *Remote Sens.*, vol. 10, p. 75, Jan. 2018, doi: 10.3390/rs10010075.
- [30] C. Yoo, D. Han, J. Im, and B. Bechtel, "Comparison between Convolutional Neural Networks and Random Forest for Local Climate Zone Classification in Mega Urban Areas Using Landsat Images," *ISPRS J. Photogramm. Remote Sens.*, vol. 157, pp. 155 - 170, 2019.
- [31] F. S. Y. Watanabe *et al.*, "Inland Water's Trophic Status Classification Based on Machine Learning and Remote Sensing Data," *Remote Sens. Appl.: Soc. Environ.*, vol. 19, p. 100326, 2020.
- [32] K. Chen, K. Fu, M. Yan, X. Gao, X. Sun, and X. Wei, "Semantic Segmentation of Aerial Images With Shuffling Convolutional Neural Networks," in *IEEE Geosci. Remote Sens. Lett.*, vol. 15, no. 2, pp. 173 - 177, 2018.
- [33] D. Marmanis, J. D. Wegner, S. Galliani,

- K. Schindler, M. Datcu, and U. Stilla, "Semantic Segmentation of Aerial Images with an Ensemble of CNNs," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. III-3, pp. 473 – 480, 2016.
- [34] C. Zhang, P. Yue, D. Tapete, B. Shanguan, M. Wang, and Z. Wu, "A Multi-level Context-guided Classification Method with Object-based Convolutional Neural Network for Land Cover Classification Using Very High Resolution Remote Sensing Images," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 88, p. 102086, 2020.
- [35] D. Konstantinidis, V. Argyriou, T. Stathaki, and N. Grammalidis, "A Modular CNN-based Building Detector for Remote Sensing Images. *Comput. Netw.*, vol. 168, p. 107034, 2020.
- [36] J.-D. Sylvain, G. Drolet, and N. Brown, "Mapping Dead Forest Cover Using a Deep Convolutional Neural Network and Digital Aerial Photography," *ISPRS J. Photogramm. Remote Sens.*, vol. 156, pp. 14 - 26, 2019.
- [37] R. Shang, J. He, J. Wang, K. Xu, L. Jiao, and R. Stolkin, "Dense Connection and Depthwise Separable Convolution Based CNN for Polarimetric SAR Image Classification," *Knowl. Based Syst.*, vol. 194, p. 105542, 2020.
- [38] K. D. Ngo, A. M. Lechner, and T. T. Vu, "Land Cover Mapping of the Mekong Delta to Support Natural Resource Management with Multi-temporal Sentinel-1A Synthetic Aperture Radar Imagery," *Remote Sens. Appl.: Soc. Environ.*, vol. 17, p. 100272, 2020.
- [39] S. Baamonde, M. Cabana, N. Sillero, M. G. Penedo, H. Naveira, and J. Novo, "Fully Automatic Multi-temporal Land Cover Classification Using Sentinel-2 Image Data," *Procedia Comput. Sci.*, vol. 159, pp. 650 - 657, 2019, doi: 10.1016/j.procs.2019.09.220.
- [40] T. Talema and B. T. Hailu, "Mapping Rice Crop Using Sentinels (1 SAR and 2 MSI) Images in Tropical Area: A Case Study in Fogera Wereda, Ethiopia," *Remote Sens. Appl.: Soc. Environ.*, vol. 18, Apr. 2020, doi: 10.1016/j.rsase.2020.100290.
- [41] Y. Shendryk, Y. Rist, C. Ticehurst, and P. Thorburn, "Deep Learning for Multi-modal Classification of Cloud, Shadow and Land Cover Scenes in Planet Scope and Sentinel-2 Imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 157, pp. 124 - 136, Nov. 2019, doi: 10.1016/j.isprsjprs.2019.08.018.
- [42] Z. Xu, K. Guan, N. Casler, B. Peng, and S. Wang, "3D Convolutional Neural Network Method for Land Cover Classification Using LiDAR and Multi-temporal Landsat Imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 144, pp. 423 - 434, Oct. 2018, doi: 10.1016/j.isprsjprs.2018.08.005.
- [43] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet Classification with Deep Convolutional Neural Networks," in *Adv. Neural Inf. Process. Syst.*, vol. 25, pp. 1097 - 1105, 2012.
- [44] M. U. Müller, N. Ekhtiari, R. M. Almeida, and C. Rieke, "Super-resolution of Multispectral Satellite Images Using Convolutional Neural Networks," *ISPRS Ann. Photogramm. Remote Sens. Spat.*

- Inf. Sci.*, vol. 1-2020, pp. 33 - 40, 2020.
- [45] G. Castilla and G. J. Hay, "Uncertainties in Land Use Data," *Hydrol. Earth Syst. Sci.*, vol. 11, no. 6, pp. 1857 - 1868, 2007.
- [46] R. Fuchs, M. Herold, P. H. Verburg, and J. G. P. W. Clevers, "A High-resolution and Harmonized Model Approach for Reconstructing and Analysing Historic Land Changes in Europe," *Biogeosciences*, vol. 10, pp. 1543 - 1559, 2013.
- [47] P. H. Verburg, K. Neumann, and L. Nol, "Challenges in Using Land Use and Land Cover Data for Global Change Studies," *Glob. Change Biol.*, vol. 17, pp. 974 - 989, 2011, doi: 10.1111/j.1365-2486.2010.02307.x.
- [48] Y. Yang and S. Newsam, "Bag-of-visual-words and Spatial Extensions for Land-use Classification," in *18th ACM SIGSPATIAL Int. Conf. Adv. Geographic Inf. Syst. (ACM SIGSPATIAL GIS 2010)*, San Jose, CA, USA, Nov. 2010, pp. 270 - 279.
- [49] S. Basu, S. Ganguly, S. Mukhopadhyay, R. DiBiano, M. Karki, and R. Nemani, "DeepSAT: A Learning Framework for Satellite Imagery," in *23rd SIGSPATIAL Int. Conf. Adv. Geographic Inf. Syst.*, Nov. 2015, pp. 1 - 10.
- [50] P. Helber, B. Bischke, A. Dengel, and D. Borth, "EuroSAT: A Novel Dataset and Deep Learning Benchmark for Land Use and Land Cover Classification," in *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 12, no. 7, pp. 2217 - 2226, 2019, doi: 10.1109/JSTARS.2019.2918242.
- [51] G. Sumbul, M. Charfuelan, B. Demir, and V. Markl, "BigEarthNet: A Large-Scale Benchmark Archive for Remote Sensing Image Understanding," in *2019 IEEE Int. Geosci. Remote Sens. Symp.*, Yokohama, Japan, 2019, pp. 5901 - 5904, doi: 10.1109/IGARSS.2019.8900532.
- [52] P. R. Emparanza, N. Hongkarnjanakul, D. Rouquette, C. Schwob, and L. Mezeix, "Land Cover Classification in Thailand's Eastern Economic Corridor (EEC) Using Convolutional Neural Network on Satellite Images." *Remote Sens. Appl.: Soc. Environ.*, vol. 20, p. 100394, 2020.
- [53] P. Chermprayong, N. Hongkarnjanakul, D. Rouquette, C. Schwob, and L. Mezeix, "Convolutional Neural Network for Thailand's Eastern Economic Corridor (EEC) Land Cover Classification Using Overlapping Process on Satellite Images." *Remote Sens. Appl.: Soc. Environ.*, vol. 23, p. 100543, 2021.
- [54] G. Sheng, W. Yang, T. Xu, and H. Sun, "High-resolution Satellite Scene Classification Using a Sparse Coding Based Multiple Feature Combination," *Int. J. Remote Sens.*, vol. 33, no. 8, pp. 2395 - 2412, Apr. 2012, doi:10.1080/01431161.2011.608740.
- [55] Q. Zou, L. Ni, T. Zhang, and Q. Wang, "Deep Learning Based Feature Selection for Remote Sensing Scene Classification," in *IEEE Geosci. Remote Sens. Lett.*, vol. 12, no. 11, pp. 2321 - 2325, Nov. 2015, doi: 10.1109/LGRS.2015.2475299.
- [56] Kristo and C. C. Chua, "Cost Effective Window Arrangement for Spatial Pyramid Matching," *J. Vis. Commun. Image Represent.*, vol. 29, pp. 79 - 88, 2015.
- [57] G.-S. Xia *et al.*, "AID: A Benchmark

- Data Set for Performance Evaluation of Aerial Scene Classification,” *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 7, pp. 3965 - 3981, Jul. 2017, doi: 10.1109/TGRS.2017.2685945.
- [58] G. Cheng, J. Han, and X. Lu, “Remote Sensing Image Scene Classification: Benchmark and State of the Art,” in *Proc. IEEE*, vol. 105, no. 10, pp. 1865 - 1883, 2017.
- [59] H. Li *et al.*, “RSI-CB: A Large-Scale Remote Sensing Image Classification Benchmark Using Crowdsourced Data,” *Sensors*, vol. 20, no. 6, p. 1594, 2020.
- [60] W. Zhou, S. Newsam, C. Li, and Z. Shao, “PatternNet: A Benchmark Dataset for Performance Evaluation of Remote Sensing Image Retrieval,” *ISPRS J. Photogramm. Remote Sens.*, vol. 145, Part A, pp. 197 - 209. Nov. 2018, doi: 10.1016/j.isprsjprs.2018.01.004.
- [61] G.-S. Xia, W. Yang, J. Delon, Y. Gousseau, H. Sun, and H. Maitre, “Structural High-resolution Satellite Image Indexing,” in *ISPRS TC VII Symp.-100 Years ISPRS*, Vienna, Austria, Jul. 2010, vol. 38, pp. 298 - 303.
- [62] L. Zhao, P. Tang, and L.-Z. Huo, “Feature Significance-based Multibag-of-visual-words Model for Remote Sensing Image Scene Classification,” *J. Appl. Remote Sens.*, vol. 10, no. 3, p. 035004. Jun. 2016, doi: 10.1117/1.JRS.10.035004.
- [63] M. Wang, H. Zhang, W. Sun, S. Li, F. Wang, and G. Yang, “A Coarse-to-Fine Deep Learning Based Land Use Change Detection Method for High-Resolution Remote Sensing Images,” *Remote Sens.*, vol. 12, no. 12, p. 1933, 2020.
- [64] G. C. Veerabhadrapa, S. C., T. K. Jaya Ram, and A. Haswanth, “Unsupervised Learning for Satellite Image Classification,” *IOSR J. VLSI Signal Processing*, vol. 4, no. 2, pp. 01 - 04, Jan. 2014, doi: 10.9790/4200-04240104.
- [65] The World Bank. “Indicators.” DATA. WORLD BANK.org. <https://data.worldbank.org/indicator> (accessed Dec. 14, 2021).
- [66] Anonymous. “Statista.” STATISTA.com. <https://www.statista.com/> (accessed Dec. 17, 2021).
- [67] Britannica. “Encyclopædia Britannica.” BRITANNICA.com. <https://www.britannica.com> (accessed Jul. 28, 2011).
- [68] Food and Agriculture Organization of the United Nations, “National Agro-Economic Zoning for Major Crops in Thailand (NAEZ),” FAO, Rome, Italy, Rep. Project TCP/THA/3403, 2017.
- [69] V. Mnih and G. E. Hinton, “Learning to Detect Roads in High-resolution Aerial Images,” in *Proc. 11th European Conf. Comput. Vision (ECCV)*, Sep. 2010.
- [70] A. R. Choudhury, B. Parajuli, and P. Kumar, “Quad Road: An Ensemble of CNNs for Road Segmentation,” *Procedia Comput. Sci.*, vol. 176, pp. 138 - 147, 2020.