



การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับบอทโลยีเพื่อวิเคราะห์การใช้ที่ดิน
ในจังหวัดพิษณุโลก



อรรชพร เลิศอร่ามแสง

วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนเรศวร
เพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรปรัชญาดุษฎีบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศ
ปีการศึกษา 2565
ลิขสิทธิ์เป็นของมหาวิทยาลัยนเรศวร

การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดิน
ในจังหวัดพิษณุโลก



วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนเรศวร
เพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรปรัชญาดุษฎีบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศ
ปีการศึกษา 2565
ลิขสิทธิ์เป็นของมหาวิทยาลัยนเรศวร

วิทยานิพนธ์ เรื่อง "การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีเพื่อวิเคราะห์
การใช้ที่ดินในจังหวัดพิษณุโลก"
ของ อรรถพร เลิศอร่ามแสง
ได้รับการพิจารณาให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการสอบวิทยานิพนธ์
(รองศาสตราจารย์ ดร.ทศนัย ชุ่มวัฒนะ)

..... ประธานที่ปรึกษาวิทยานิพนธ์
(ผู้ช่วยศาสตราจารย์ ดร.จันทร์จิรา พยัคฆ์แพศ)

..... กรรมการผู้ทรงคุณวุฒิภายใน
(ผู้ช่วยศาสตราจารย์ ดร.สุธาสินี จิตต์อนันต์)

..... กรรมการผู้ทรงคุณวุฒิภายใน
(ผู้ช่วยศาสตราจารย์ ดร.วินัย วงษ์ไทย)

..... กรรมการผู้ทรงคุณวุฒิภายใน
(ผู้ช่วยศาสตราจารย์ ดร.จรัสศรี รุ่งรัตนอุบล)

อนุมัติ

.....
(รองศาสตราจารย์ ดร.กรองกาญจน์ ชูทิพย์)
คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก
ผู้วิจัย	อรรถพร เลิศอร่ามแสง
ประธานที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.จันทร์จรีรา พยัคฆ์เทศ
ประเภทสารนิพนธ์	วิทยานิพนธ์ ปร.ด. เทคโนโลยีสารสนเทศ, มหาวิทยาลัยนเรศวร, 2565
คำสำคัญ	การใช้ที่ดินและสิ่งปกคลุมดิน, การวิเคราะห์ข้อมูลเชิงวัตถุ, ออนโทโลยี, ข้อมูลภาพถ่ายดาวเทียม

บทคัดย่อ

การใช้ที่ดินและสิ่งปกคลุมดินมีแนวโน้มการเปลี่ยนแปลงตลอดเวลาและเป็นไปอย่างต่อเนื่องโดยเฉพาะการทำแผนที่การใช้ที่ดินและสิ่งปกคลุมดินหรือการติดตามตรวจสอบพื้นที่รวมถึงการจำแนกประเภทจะต้องได้รับข้อมูลที่ถูกต้องและรวดเร็วถือเป็นสิ่งสำคัญ การได้มาของข้อมูลการใช้ที่ดินและสิ่งปกคลุมที่สามารถติดตามหรือนำมาปรับปรุงได้นั้นมีข้อจำกัดในด้านการแปลตีความ เพราะต้องอาศัยผู้เชี่ยวชาญเฉพาะด้านในการแปลตีความ บางครั้งต้องมีการลงพื้นที่เพื่อสำรวจภาคสนาม การสำรวจแต่ละครั้งใช้ระยะเวลาในการทำงานนานและมีค่าใช้จ่ายค่อนข้างสูง จึงมีการนำเทคโนโลยีมาช่วยในการแปลตีความภาพถ่ายดาวเทียมตัวอย่างเช่น วิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมให้ค่าความถูกต้องโดยภาพรวมสูงกว่าวิธีการอื่น แต่การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก แสดงให้เห็นว่าการนำวิธีการทางออนโทโลยีมาช่วยในการจำแนกร่วมกับวิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมสามารถจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมได้ดีขึ้นเมื่อเทียบกับการใช้วิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมแบบเดิมดูได้จากค่าความถูกต้องโดยรวมมากกว่าร้อยละ 80

Title	APPLYING THE OBJECT-ORIENTED IMAGE ANALYSIS WITH ONTOLOGY TO ANALYZE LAND USE IN PHITSANULOK PROVINCE
Author	Uttaporn Lertaramsaeng
Advisor	Assistant Professor Janjira Payakpate, Ph.D.
Academic Paper	Ph.D. Dissertation in Information Technology - (Type 2.1), Naresuan University, 2022
Keywords	Land use and Land cover (LULC), Object-based image analysis, Ontology, Satellite images

ABSTRACT

Land use and Land cover (LULC) tend to change over time and continuously. LULC mapping or site monitoring and classification must be obtained quickly and accurately. Acquisition of LULC data that can be tracked or improved is limited in terms of interpretation because it requires specialists in interpretation, sometimes field surveys are required. Each survey takes a long time and is quite expensive. Therefore, technology has been employed to aid in the interpretation of satellite images. The object-based image analysis method has achieved higher overall accuracy than other approaches. In the analysis of land use in Phitsanulok Province, the combination of object-based image analysis and ontological methods has shown superior effectiveness in land use and Land cover classification compared to traditional data analysis techniques. By incorporating ontological practices, the classification process can achieve an overall accuracy rate exceeding 80 percent.

ประกาศคุณูปการ

ความสำเร็จในการทำวิจัยครั้งนี้ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงในความกรุณาของผู้ช่วยศาสตราจารย์ ดร.จันทร์จิรา พยัคฆ์เทศ ประธานที่ปรึกษาวิทยานิพนธ์ที่ได้เสียสละเวลาอันมีค่ามาเป็นทั้งที่ปรึกษาพร้อมทั้งให้คำแนะนำตลอดระยะเวลาในการทำวิทยานิพนธ์ฉบับนี้และขอกราบขอบพระคุณคณะกรรมการวิทยานิพนธ์อันประกอบไปด้วย ผู้ช่วยศาสตราจารย์ ดร.จรัสศรี รุ่งรัตนอุบล ผู้ช่วยศาสตราจารย์ ดร.วินัย วงษ์ไทย ผู้ช่วยศาสตราจารย์ ดร.สุธาสินี จิตต์อนันต์ และรองศาสตราจารย์ ดร.ทศนัย ชุ่มวัฒนะ กรรมการผู้ทรงคุณวุฒิจากภายนอกที่ได้กรุณาให้คำแนะนำตลอดจนแก้ไขข้อบกพร่องของวิทยานิพนธ์ด้วยความเอาใจใส่จนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปด้วยดี

กราบขอบพระคุณมหาวิทยาลัยราชภัฏพิบูลสงครามที่ได้ให้ความอนุเคราะห์เงินทุนสนับสนุนในการศึกษาและวิจัยในครั้งนี้

เหนือสิ่งอื่นใดขอกราบขอบพระคุณ บิดา มารดา ครอบครัว และเพื่อนร่วมสาขาเทคโนโลยีสารสนเทศของผู้วิจัยที่ให้กำลังใจและให้การสนับสนุนในทุก ๆ ด้านเป็นอย่างดี

สุดท้ายนี้ผู้วิจัยหวังเป็นอย่างยิ่งว่างานวิจัยนี้จะเป็นประโยชน์ต่อผู้ที่สนใจเกี่ยวกับด้านการพัฒนาเทคโนโลยีสารสนเทศต่อไปในอนาคต

อรรถพร เลิศอร่ามแสง

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
ประกาศศุณฺพการ	จ
สารบัญ	ฉ
สารบัญตาราง	ฌ
สารบัญภาพ	ญ
บทที่ 1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
จุดมุ่งหมายของการศึกษา.....	3
กรอบแนวคิดที่ใช้ในงานวิจัย.....	4
ขอบเขตการวิจัย.....	4
ประโยชน์ที่คาดว่าจะได้รับ	6
นิยามศัพท์เฉพาะ	6
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	8
การใช้ที่ดินและสิ่งปกคลุมดิน	8
ข้อมูลพื้นที่จังหวัดพิษณุโลก.....	9
การรับรู้จากระยะไกล.....	12
ข้อมูลภาพดาวเทียม.....	14
การประมวลผลข้อมูลภาพถ่ายดาวเทียม.....	17

การวิเคราะห์ภาพเชิงวัตถุ (Object-Based Image Analysis).....	20
ออนโทโลยี	25
งานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุเพื่อวิเคราะห์การใช้ที่ดิน	29
งานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้ออนโทโลยีกับการจำแนกข้อมูลภาพถ่ายดาวเทียม .	31
บทที่ 3 วิธีดำเนินงานวิจัย	34
การวิเคราะห์ข้อมูลภาพเชิงวัตถุ (Object-Based Image Analysis).....	34
การวิเคราะห์ออนโทโลยี (Ontology Analysis).....	41
การจำแนกประเภทตามออนโทโลยี (Ontology-based Classification).....	43
การประเมินความถูกต้อง (Accuracy Assessment).....	45
บทที่ 4 ผลการวิจัย	47
ผลการวิเคราะห์ข้อมูลภาพเชิงวัตถุ.....	47
ผลการวิเคราะห์ออนโทโลยี	51
ผลการจำแนกประเภทตามออนโทโลยี	53
บทที่ 5 สรุป อภิปรายผล และข้อเสนอแนะ	61
สรุป	61
อภิปรายผลการวิจัย	63
ข้อเสนอแนะ	65
ข้อจำกัดของงานวิจัย	65
บรรณานุกรม	67
ภาคผนวก.....	72
ผลงานตีพิมพ์	72



สารบัญตาราง

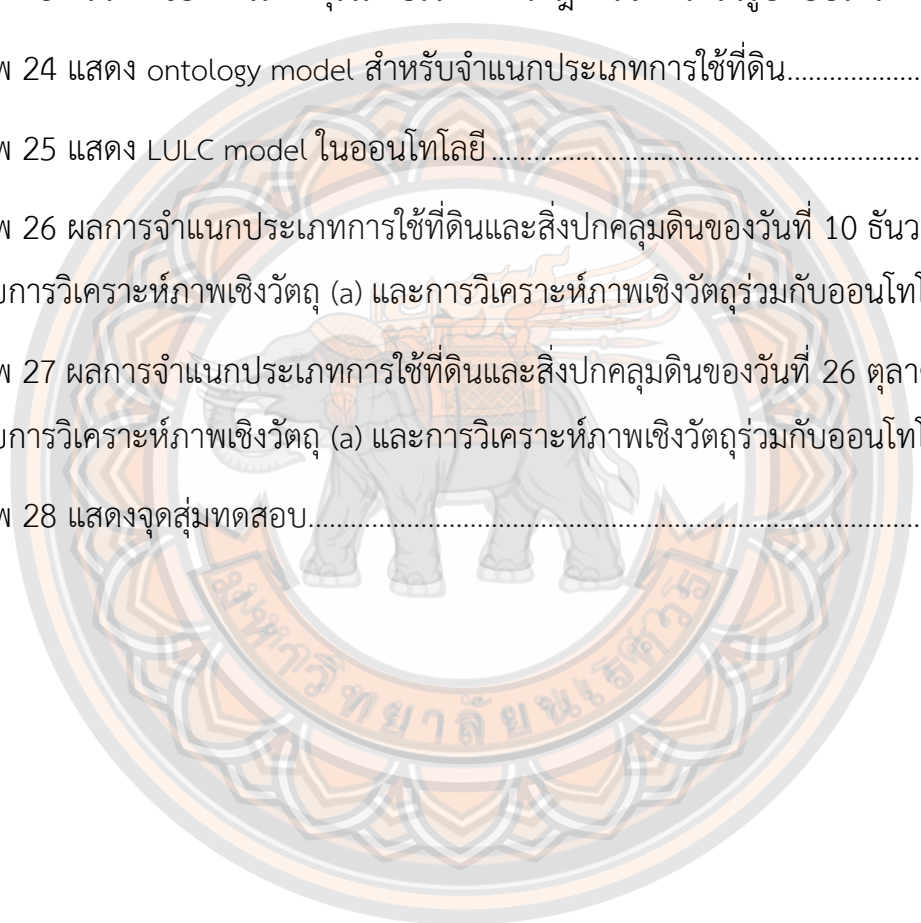
หน้า

ตาราง 1 ตัวอย่างการจำแนกการใช้ที่ดินประเทศไทยของพื้นที่ชุมชนและสิ่งปลูกสร้าง.....	9
ตาราง 2 ความยาวช่วงคลื่นและรายละเอียดจุดภาพของดาวเทียม Landsat 8.....	16
ตาราง 3 ประเภทของการจำแนกข้อมูลภาพดาวเทียม.....	18
ตาราง 4 ค่าพารามิเตอร์ที่ใช้ในการแบ่งส่วนภาพ.....	38
ตาราง 5 แสดงภาพ กฎ ของประเภทการใช้ที่ดินและสิ่งปกคลุมดิน.....	40
ตาราง 6 แสดงกฎจากโครงสร้างออนโทโลยีและรูปแบบ SWRL.....	44
ตาราง 7 ค่าพารามิเตอร์ในการแบ่งส่วนภาพ.....	47
ตาราง 8 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ.....	57
ตาราง 9 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีวิเคราะห์เชิงวัตถุร่วมกับออนโทโลยี.....	58
ตาราง 10 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ.....	59
ตาราง 11 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีวิเคราะห์เชิงวัตถุร่วมกับออนโทโลยี.....	60

สารบัญภาพ

	หน้า
ภาพ 1 กรอบแนวคิดในการวิจัย.....	4
ภาพ 2 แสดงพื้นที่อำเภอเมือง จังหวัดพิษณุโลก	5
ภาพ 3 แสดงเขตการปกครองจังหวัดพิษณุโลก.....	10
ภาพ 4 กระบวนการและองค์ประกอบการรับรู้จากระยะไกล	13
ภาพ 5 การประมวลผลภาพด้วยคอมพิวเตอร์ (Kamavisdar et al., 2013).....	17
ภาพ 6 แสดงความสัมพันธ์ของพารามิเตอร์การแบ่งส่วนภาพ (Definiens, 2007).....	21
ภาพ 7 การแบ่งส่วนภาพแบบกระดานหมากรุก (Chessboard Segmentation) (Definiens, 2007).....	22
ภาพ 8 แสดงวิธีการแบ่งส่วนภาพแบบควอดทรี (Definiens, 2007).....	22
ภาพ 9 การแบ่งส่วนภาพแบบควอดทรี (Quadtree Segmentation) (Definiens, 2007)	23
ภาพ 10 การแบ่งส่วนภาพแบบความละเอียดหลายระดับ (Definiens, 2007).....	23
ภาพ 11 ขั้นตอนการจำแนกประเภทการใช้ที่ดินและสิ่งคลุมดินโดยภาพรวม	34
ภาพ 12 แสดงขอบเขตพื้นที่ศึกษา.....	35
ภาพ 13 แสดงพื้นที่ศึกษาข้อมูลวันที่ 26 ตุลาคม 2558.....	36
ภาพ 14 แสดงพื้นที่ศึกษาข้อมูลวันที่ 10 ธันวาคม 2563.....	36
ภาพ 15 Land Use and Land Cover class hierarchy	39
ภาพ 16 โดเมนความรู้ในออนโทโลยี	42
ภาพ 17 แบบจำลองออนโทโลยีการใช้ที่ดินและสิ่งปกคลุมดิน	43
ภาพ 18 แบบจำลองออนโทโลยีของกฎ	43

ภาพ 19 ผลการแบ่งส่วนภาพพื้นที่อำเภอเมืองวันที่ 26 ตุลาคม 2558.....	48
ภาพ 20 ผลการแบ่งส่วนภาพพื้นที่อำเภอเมืองวันที่ 10 ธันวาคม 2563	49
ภาพ 21 แสดง Class Hierarchy.....	50
ภาพ 22 แสดงผลการสกัดคุณลักษณะจากภาพถ่าย.....	50
ภาพ 23 ผลลัพธ์ของการสกัดคุณลักษณะที่ผ่านกฎการจำแนกในรูปแบบไฟล์ CSV.....	51
ภาพ 24 แสดง ontology model สำหรับจำแนกประเภทการใช้ที่ดิน.....	52
ภาพ 25 แสดง LULC model ในออนโทโลยี.....	53
ภาพ 26 ผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินของวันที่ 10 ธันวาคม 2563 ด้วยการวิเคราะห์ภาพเชิงวัตถุ (a) และการวิเคราะห์ภาพเชิงวัตถุร่วมกับออนโทโลยี (b)..	54
ภาพ 27 ผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินของวันที่ 26 ตุลาคม 2558 ด้วยการวิเคราะห์ภาพเชิงวัตถุ (a) และการวิเคราะห์ภาพเชิงวัตถุร่วมกับออนโทโลยี (b)..	55
ภาพ 28 แสดงจุดสุ่มทดสอบ.....	56



บทที่ 1

บทนำ

ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบันนี้พบว่าการใช้ที่ดินและสิ่งปกคลุมดิน (Land Use and Land Cover: LULC) มีแนวโน้มการเปลี่ยนแปลงตลอดเวลาและเป็นไปอย่างต่อเนื่องโดยเฉพาะพื้นที่ในตัวเมืองหรือพื้นที่ที่มีการพัฒนาทางด้านเศรษฐกิจที่มีการขยายตัวอย่างมาก การทำแผนที่การใช้ที่ดินและสิ่งปกคลุมดินหรือการติดตามตรวจสอบพื้นที่รวมถึงการจำแนกจะต้องได้รับข้อมูลที่ถูกต้องและรวดเร็วถือเป็นสิ่งสำคัญ (เปรม ศิริคงเส็ง, 2560) แต่การได้มาของข้อมูลการใช้ที่ดินและสิ่งปกคลุมที่สามารถติดตามหรือนำมาปรับปรุงได้นั้นมีข้อจำกัด ในด้านการแปลตีความ (Forestier et al., 2012; Lillesand et al., 2015; White et al., 2009) เนื่องจากต้องมีการลงพื้นที่เพื่อสำรวจภาคสนาม ในการสำรวจแต่ละครั้งใช้ระยะเวลาในการทำงานค่อนข้างนาน อีกทั้งงบประมาณที่ใช้ค่อนข้างสูง รวมถึงต้องใช้ความสามารถของผู้เชี่ยวชาญเฉพาะด้านในการแปลตีความ ดังนั้นการนำเทคโนโลยีการรับรู้จากระยะไกล (Remote Sensing) สามารถนำมาใช้ในการแปลตีความภาพถ่ายดาวเทียม รวมถึงการติดตามการเปลี่ยนแปลงของการใช้ที่ดินและสิ่งปกคลุมดิน สามารถนำมาปรับปรุงข้อมูลให้เป็นปัจจุบัน อีกทั้งยังช่วยลดระยะเวลาการทำงาน ลดจำนวนคน และลดงบประมาณในการลงพื้นที่สำรวจภาคสนาม เนื่องจากเทคโนโลยีการรับรู้จากระยะไกลสามารถทำงานในพื้นที่กว้าง พื้นที่ที่มีความลึกหรือพื้นที่ที่มนุษย์ไม่สามารถเข้าถึง และสามารถเรียกดูข้อมูลได้บ่อยครั้งแต่ขึ้นอยู่กับระยะเวลาของวงโคจรดาวเทียมในแต่ละดวง ด้วยเหตุนี้จึงนิยมนำเทคโนโลยีการรับรู้จากระยะไกลมาประยุกต์กับการจำแนกที่ดินและสิ่งปกคลุมดิน เช่น ในด้านการติดตามการเปลี่ยนแปลงพื้นที่เหมืองทองคำ การจำแนกพื้นที่ที่ร้าง และการพัฒนาอัลกอริทึมในการจำแนกประเภทสิ่งปกคลุมดิน ร่วมกับการนำค่าดัชนีพืชพรรณมาใช้ในการจำแนกประเภทได้ดีขึ้น (คราวุฒิ ไวยสุศรี, 2561; ชนิวิษฐ์ สุรัสวดี และ ประคุณ พงษ์ภัทรานนท์, 2556; อภิเสกฐ์ สุวรรณสะอาด, 2556) อีกทั้งใช้วิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงจุดภาพ (Pixel-Based Image Analysis) เป็นการอาศัยค่าการสะท้อนแสงที่แตกต่างกันของจุดภาพ เพื่อแยกวัตถุในแต่ละชนิดบนภาพถ่ายดาวเทียมให้ทราบว่าประกอบไปด้วยวัตถุอะไรในพื้นที่นั้นๆ แต่ถ้าพื้นที่ที่มีการปะปนของประเภทการใช้ที่ดินและสิ่งปกคลุมดินที่มีความหลากหลายในพื้นที่เดียวกันส่งผลให้ค่าความถูกต้อง (Accuracy) จากวิธีการนี้แสดงค่าในระดับค่อนข้างต่ำ (Phiri & Morgenroth, 2017) แต่สามารถแก้ไขปัญหานี้ด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ (Object-Based Image Analysis) เนื่องจากวิธีการนี้อาศัยการจำแนกวัตถุบนภาพถ่ายดาวเทียมจากการแบ่งส่วนภาพ (Segmentation) เป็นการแบ่งส่วนภาพออกเป็น

หลายพื้นที่ (Region) หรือวัตถุ (Object) หลายชนิดตามแต่ลักษณะที่เป็นเนื้อเดียวกันหรือมีความสัมพันธ์กัน เพื่อใช้อธิบายชั้นข้อมูล (Class) ของวัตถุที่สร้างขึ้นมา (ทบทอง ชั้นเจริญ, 2558) ทำให้วิธีการนี้สามารถแก้ปัญหาการจำแนกในลักษณะของข้อมูลภาพที่มีการปะปนกันด้วยการนำมาเปรียบเทียบผลการวิเคราะห์ข้อมูลภาพระหว่างวิธีการวิเคราะห์ข้อมูลภาพเชิงจุดภาพกับการวิเคราะห์ข้อมูลภาพเชิงวัตถุของดาวเทียมชนิดต่างๆ (เพ็ญพรรณ บัญเดิม และวิจัย เยี่ยงวีรชน, 2555; สรรทราย สุทธินนท์ และคณะ, 2557) ผลปรากฏว่าวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุแสดงค่าความถูกต้องโดยภาพรวมที่ดีกว่าวิธีการวิเคราะห์ข้อมูลภาพเชิงจุดภาพ ซึ่งชี้ให้เห็นว่าวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุสามารถนำมาวิเคราะห์เพื่อจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินที่มีความหลากหลายของวัตถุในพื้นที่เดียวกันได้เหมาะสมกว่า

การนำเทคโนโลยีการรับรู้จากระยะไกลมาประยุกต์ใช้กับการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินนั้นจะต้องผ่านกระบวนการจำแนกประเภทเพื่อให้ได้ลักษณะของแต่ละประเภทการใช้ที่ดินและสิ่งปกคลุมดินเป็นผลมาจากการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม ซึ่งการวิเคราะห์ข้อมูลภาพโดยส่วนใหญ่นิยมใช้ 2 วิธีคือ การวิเคราะห์ข้อมูลภาพเชิงจุดภาพ และการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ซึ่งความสามารถในการวิเคราะห์ข้อมูลภาพเพื่อจำแนกประเภทนั้นจะให้ผลลัพธ์ที่แตกต่างกันดังจะเห็นได้จากหลายๆ งานวิจัย การวิเคราะห์ข้อมูลภาพเชิงจุดภาพให้ค่าความถูกต้องโดยรวมในการจำแนกประเภทที่น้อยกว่าการวิเคราะห์ข้อมูลภาพเชิงวัตถุ แต่ปัจจัยหนึ่งที่ทำให้การวิเคราะห์ข้อมูลภาพในแต่ละวิธีมีความแตกต่างกันนั้นคือความละเอียดเชิงพื้นที่ (Spatial Resolution) เป็นปัจจัยที่ส่งผลเกี่ยวกับการเลือกวิธีในการวิเคราะห์ภาพ ทว่าความละเอียดเชิงพื้นที่ของข้อมูลภาพถ่ายดาวเทียมนั้นยังความละเอียดเชิงพื้นที่สูงก็จะตามมาด้วยค่าใช้จ่ายในการเข้าถึงข้อมูลที่สูงตามไปด้วย รวมถึงระยะหรือขอบเขตของพื้นที่ข้อมูลไม่กว้างมากนัก และดาวเทียมบางดวงมีวงโคจรในการวนซ้ำที่ใช้เวลานาน ในบางครั้งการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินอาจจะใช้พื้นที่ในการศึกษาเป็นบริเวณกว้างทำให้ข้อมูลภาพถ่ายดาวเทียมที่มีความละเอียดเชิงพื้นที่สูงมีระยะของพื้นที่ไม่มากนักจึงจำเป็นต้องใช้ข้อมูลภาพถ่ายดาวเทียมเป็นจำนวนมากมาเรียงต่อกันส่งผลให้การประมวลผลด้วยคอมพิวเตอร์จำเป็นต้องใช้เครื่องที่มีประสิทธิภาพสูงสำหรับการจำแนกประเภทและในบางครั้งทำให้ใช้เวลาในการประมวลผลสูงตามมาด้วย รวมถึงบางกรณีการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินไม่จำเป็นต้องใช้ข้อมูลภาพถ่ายดาวเทียมที่มีความละเอียดเชิงพื้นที่สูงก็สามารถจำแนกประเภทได้เช่นกัน แต่จะมีอีกแนวทางในการเลือกใช้ข้อมูลภาพถ่ายดาวเทียมที่สามารถเปิดให้เข้าถึงข้อมูลโดยไม่เสียค่าใช้จ่ายสามารถช่วยลดปัญหาด้านค่าใช้จ่ายงบประมาณที่จำกัดรวมถึงการประมวลผลที่เร็วขึ้นแต่อาจจะแลกกับค่าความละเอียดเชิงพื้นที่ที่ลดลงและมีให้บริการเพียงไม่กี่ดวง เช่น ดาวเทียม Landsat สามารถดาวน์โหลดข้อมูลมาจาก กรมทรัพยากรธรณีประเทศสหรัฐอเมริกา (U.S. Geological Survey: USGS) ในปัจจุบันจะเป็นดาวเทียม Landsat 8 ซึ่งความ

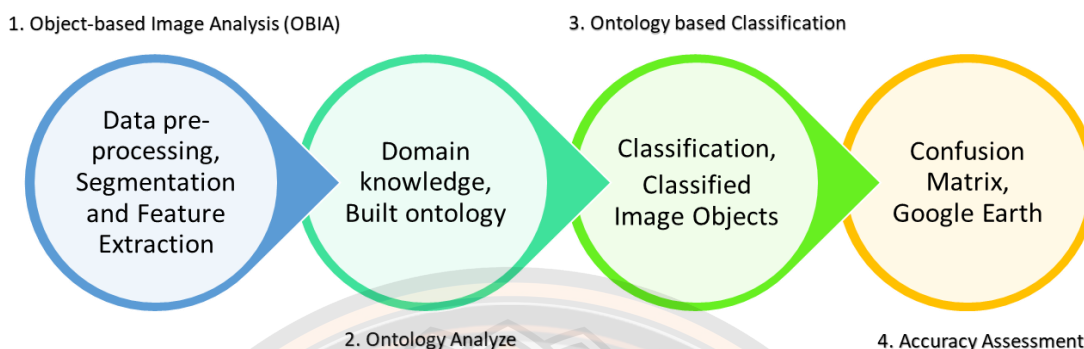
ละเอียดเชิงพื้นที่ประมาณ 30 เมตร ถือว่าอยู่ในระดับกลาง (Medium Spatial Resolution) นอกจากนี้ปัจจัยเหล่านี้แล้วยังมีอีกหนึ่งปัจจัยที่เกี่ยวข้องก็คือการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินโดยส่วนใหญ่ต้องอาศัยผู้เชี่ยวชาญเฉพาะด้านเพื่อเป็นผู้กำหนดกระบวนการจำแนกข้อมูลภาพถ่ายดาวเทียมรวมถึงการแปลตีข้อมูลภาพ

ดังนั้นจากเหตุผลที่กล่าวมาแสดงให้เห็นว่าการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินจากข้อมูลภาพถ่ายดาวเทียมจะมีปัจจัยที่สำคัญที่ต้องคำนึงถึงคือลักษณะของข้อมูลภาพถ่ายดาวเทียม กระบวนการแปลตีความภาพถ่ายดาวเทียม และองค์ความรู้จากผู้เชี่ยวชาญในการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดิน เพื่อเป็นแนวทางในการลดปัญหาดังกล่าวผู้วิจัยจึงเกิดแนวคิดที่จะนำเทคโนโลยีออนโทโลยีซึ่งเป็นเทคโนโลยีทางการพัฒนาเชิงความหมายที่สามารถตีความหมายและทำตามคำสั่งได้ โดยลักษณะของออนโทโลยีคือการนิยามรูปแบบ (Model) ภายในขอบเขตขององค์ความรู้เพื่ออธิบายสิ่งที่สนใจ (Domain) ให้ได้ใจความและความถูกต้องมากที่สุด ในการนำเทคโนโลยีออนโทโลยีมาประยุกต์ใช้กับการจำแนกข้อมูลภาพถ่ายดาวเทียม ในปัจจุบันพบว่าเริ่มมีการนำมาประยุกต์ใช้กับเทคโนโลยีการรับรู้จากระยะไกลสำหรับจำแนกข้อมูลภาพถ่ายดาวเทียมอยู่บ้าง ส่วนการนำมาประยุกต์ใช้ในการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินยังมีน้อยอีกทั้งลักษณะของสิ่งปกคลุมดินในแต่ละพื้นที่ยังมีความหลากหลายและแตกต่างกันทำให้การจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินอาจยังไม่ครอบคลุมทั้งหมด จึงเกิดแนวคิดที่จะนำเสนอการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก ซึ่งจะเป็นตัวช่วยให้ลดการทำงานของผู้เชี่ยวชาญในการแปลตีความข้อมูลภาพถ่ายดาวเทียมพร้อมทั้งช่วยเสริมการวิเคราะห์ข้อมูลภาพเชิงวัตถุจากข้อมูลภาพถ่ายดาวเทียมให้สามารถจำแนกประเภทได้ดีขึ้น ตลอดจนเป็นการช่วยลดระยะเวลาในการสำรวจภาคสนาม ช่วยลดค่าใช้จ่ายและงบประมาณในการทำงาน และการได้มาซึ่งข้อมูลอันเป็นประโยชน์สำหรับการนำไปประยุกต์ใช้ในงานด้านที่เกี่ยวข้องกับการใช้ที่ดินในอนาคต

จุดมุ่งหมายของการศึกษา

1. เพื่อประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีในการวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก
2. เพื่อประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีในการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินจากข้อมูลภาพถ่ายดาวเทียม Landsat 8
3. เพื่อเป็นรูปแบบที่สามารถช่วยผู้เชี่ยวชาญในการแปลตีความข้อมูลภาพถ่ายดาวเทียม

กรอบแนวคิดที่ใช้ในงานวิจัย




ภาพ 1 กรอบแนวคิดในการวิจัย

กรอบแนวคิดในภาพ 1 เริ่มจากกระบวนการจำแนกข้อมูลภาพถ่ายดาวเทียมด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ (Object-Based Image Analysis) เนื่องจากวิธีการนี้อาศัยการจำแนกวัตถุบนภาพถ่ายดาวเทียมจากการแบ่งส่วนภาพ (Segmentation) เป็นการแบ่งส่วนภาพออกเป็นหลายพื้นที่ (Region) หรือวัตถุ (Object) หลายชนิดตามแต่ลักษณะที่เป็นเนื้อเดียวกันหรือมีความสัมพันธ์กัน เพื่อใช้อธิบายชั้นข้อมูล (Class) ของวัตถุที่สร้างขึ้นมา และส่วนของการวิเคราะห์อัตโนมัติด้วยการสร้างโมเดลออนโทโลยี (Ontology Model) จะเป็นส่วนของขั้นตอนในการวิเคราะห์โครงสร้างของออนโทโลยีโดยใช้โดเมนความรู้จากข้อมูลผู้เชี่ยวชาญ ข้อมูลภาพถ่ายดาวเทียม ข้อมูลเอกสารที่เกี่ยวข้องกับการใช้ที่ดินและสิ่งปกคลุมดินจากคุณลักษณะของภาพ (Image Feature) ใช้สำหรับกำหนดคลาสและคุณสมบัติที่เกี่ยวข้องกับรูปภาพ จนได้การจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินด้วยออนโทโลยีตามที่กำหนดไว้ และสุดท้ายทำการประเมินค่าความถูกต้องด้วยข้อมูลจาก Google Earth และค่า Error matrix

ขอบเขตการวิจัย

1. ขอบเขตด้านพื้นที่ศึกษา

พื้นที่ศึกษาในครั้งนี้คือ อำเภอเมือง จังหวัดพิษณุโลก มีเนื้อที่ทั้งหมดประมาณ 469,250 ไร่ (750.81 ตร.กม.) ซึ่งพื้นที่ส่วนใหญ่เป็นที่ราบลุ่ม มีแม่น้ำน่านไหลผ่าน



ภาพ 2 แสดงพื้นที่อำเภอเมือง จังหวัดพิษณุโลก

2. ขอบเขตด้านข้อมูล

ข้อมูลภาพถ่ายดาวเทียม Landsat 8 จาก USGS (<https://earthexplorer.usgs.gov/>) อยู่ใน Path 130 และ Row 48 วันที่ 26 ตุลาคม 2558 และวันที่ 10 ธันวาคม 2563 เนื่องจากเป็นช่วงเวลาในประเทศไทยไม่ได้อยู่ในช่วงฤดูฝนและมีเมฆปกคลุมไม่มาก คุณสมบัติของภาพถ่ายจากดาวเทียม Landsat 8 มีช่วงคลื่นของการตรวจวัด (Spectral range) หรือ แบนด์ (Band) เหมาะสมในการวิเคราะห์การใช้ที่ดินและสิ่งปกคลุมดิน โดยใช้แบนด์ 2, 3, 4, 5, 6 และ 7 เป็นแบนด์ Multispectral ได้แก่ ช่วงคลื่นสีน้ำเงิน (Band 2 Blue) ช่วงคลื่นสีเขียว (Band 3 Green) ช่วงคลื่นสีแดง (Band 4 Red) ช่วงคลื่นอินฟราเรดใกล้ (Band 5 NIR) ช่วงคลื่นอินฟราเรดสั้น 1 (Band 6 SWIR1) และช่วงคลื่นอินฟราเรดสั้น 2 (Band 7 SWIR2)

3. ขอบเขตด้านเครื่องมือที่ใช้ในการพัฒนา

เครื่องมือที่ใช้ในการวิจัยครั้งนี้แบ่งออกเป็น 2 ส่วนหลักๆ คือ เครื่องมือที่ใช้ส่วนของการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม และเครื่องมือที่ใช้ส่วนของการพัฒนาออนไลน์

3.1 เครื่องมือที่ใช้ในการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมใช้โปรแกรม eCognition Developer 9 เป็นโปรแกรมสำหรับวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ซึ่งวัตถุจะถูกสร้างขึ้นโดยอัตโนมัติจากการกำหนดค่าพารามิเตอร์ในโปรแกรม ผลจากการประมวลผลจะแสดงออกมาเป็นลักษณะของกลุ่มวัตถุภาพที่มีการจัดกลุ่มของพิกเซลตามลักษณะค่าทางสถิติ รวมถึงลักษณะของพื้นที่ที่มีความเหมือนหรือมีความใกล้เคียงกันจะถูกจัดให้อยู่ในกลุ่มเดียวกันทำให้สามารถช่วยในการวิเคราะห์ภาพได้สะดวกและรวดเร็วมากขึ้น

3.2 เครื่องมือที่ใช้ในการพัฒนาออนโทโลยีใช้โปรแกรม Protégé มาใช้สำหรับพัฒนาออนโทโลยีด้วยเหตุผลที่ว่าตัวโปรแกรมมีส่วนการติดต่อกับผู้ใช้ในรูปแบบกราฟิกที่เข้าใจง่าย ใช้หลักการสร้างโดเมนและฐานความรู้ (Knowledge-Based) ในรูปแบบออนโทโลยี แสดงความสัมพันธ์แบบลำดับชั้นด้วย is-a รวมทั้งสามารถจัดเก็บไฟล์ได้หลายรูปแบบ เช่น RDF, OWL และ XML

ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถเป็นแนวทางในการประยุกต์ใช้สำหรับการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินในจังหวัดพิษณุโลก
2. สามารถช่วยผู้เชี่ยวชาญในการแปลตีความข้อมูลภาพถ่ายดาวเทียม
3. สามารถนำไปประยุกต์ใช้ในการวิเคราะห์การใช้ที่ดิน
4. สามารถช่วยให้การจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินได้ดีขึ้น

นิยามศัพท์เฉพาะ

1. การรับรู้จากระยะไกล (Remote Sensing) หมายถึง เป็นวิทยาศาสตร์และศิลปะในการได้มาซึ่งข้อมูลเกี่ยวกับวัตถุ พื้นที่ และปรากฏการณ์บนพื้นโลกจากเครื่องรับรู้ (Sensor) โดยปราศจากการเข้าไปสัมผัสวัตถุเป้าหมายโดยตรง แต่อาศัยพลังงานแม่เหล็กไฟฟ้า (Electromagnetic Energy) เป็นสื่อกลาง

2. ออนโทโลยี (Ontology) หมายถึง แนวคิดที่ใช้กำหนดความหมายที่เป็นทางการของคำศัพท์พร้อมทั้งประกาศคุณลักษณะที่ชัดเจนเพื่อนำมาใช้ในการอธิบายความเป็นตัวตนของแนวคิด (Concepts) หรือแบบจำลอง (Model) ของกลุ่มชุมชนสารสนเทศที่ใช้ร่วมกัน (Information Communities) ซึ่งโครงสร้างความสัมพันธ์ดังกล่าว เครื่องคอมพิวเตอร์สามารถสามารถเข้าใจและแปลความได้ โดยใช้คลาส (Class) ความสัมพันธ์ระหว่างคลาส หมายรวมถึงลำดับชั้นของคลาสและคุณสมบัติ (Properties) ของคลาส ความรู้ที่ได้จากออนโทโลยีมีขอบเขตอยู่เฉพาะทาง (Domain) ซึ่งช่วยสนับสนุนกระบวนการค้นคืนสารสนเทศ (Information Retrieval) ในแง่ของการตัดทอนคำศัพท์

ที่สับสน หรือ บรรยายเชิงความหมายจากหลายแนวคิด (Concepts) ให้สอดคล้องกันภายใต้แนวคิด (Concept) เพียงหนึ่งเดียว

3. การวิเคราะห์ข้อมูลภาพเชิงวัตถุ (Object-Based Image Analysis) หมายถึง การวิเคราะห์หรือการจำแนกข้อมูลภาพเชิงวัตถุเพื่อตีความหรืออธิบายปรากฏการณ์หรือสิ่งที่ปรากฏบนโลกจริง โดยมีวิธีการที่สำคัญคือการแบ่งส่วนภาพ (Segmentation) ทั้งนี้การแบ่งส่วนภาพออกเป็นหลายพื้นที่ (Region) หรือวัตถุ (Object) หลายชนิดตามลักษณะของการเป็นเนื้อเดียวกัน (Homogenous Area) หรือมีความสัมพันธ์กัน (Relatively Homogeneous Areas) เพื่อพยายามสร้างวัตถุและใช้วัตถุที่สร้างขึ้นมาอธิบายชั้นข้อมูล (Class)

4. การใช้ที่ดิน (Land Use) หมายถึง กิจกรรมที่มนุษย์สร้างขึ้นและเปลี่ยนแปลงลักษณะทางกายภาพของพื้นที่ให้เป็นไปตามสิ่งที่มนุษย์ต้องการเพื่อสอดคล้องกับวัตถุประสงค์ เช่น การเลี้ยงสัตว์ การเพาะปลูก การสร้างสิ่งปลูกสร้าง เป็นต้น

5. สิ่งปกคลุมดิน (Land Cover) หมายถึง ลักษณะทางกายภาพของพื้นที่เหล่านั้น เช่น แหล่งน้ำ ภูเขา ป่าไม้ ทุ่งหญ้า เป็นต้น



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การวิจัยในครั้งนี้ผู้วิจัยได้ศึกษาค้นคว้า แนวความคิด ทฤษฎี เอกสาร และงานวิจัยที่เกี่ยวข้องกับการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินจากภาพถ่ายดาวเทียมด้วยออนโทโลยี เพื่อเป็นแนวทางดำเนินการวิจัยประกอบไปด้วยการใช้ที่ดินและสิ่งปกคลุมดิน ข้อมูลพื้นที่จังหวัดพิษณุโลก การรับรู้จากระยะไกล ข้อมูลภาพจากดาวเทียม การประมวลผลข้อมูลภาพถ่ายดาวเทียม การวิเคราะห์ข้อมูลภาพเชิงวัตถุ ออนโทโลยี รวมถึงงานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุเพื่อวิเคราะห์การใช้ที่ดิน และงานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้ออนโทโลยีกับการจำแนกข้อมูลภาพถ่ายดาวเทียม

การใช้ที่ดินและสิ่งปกคลุมดิน

การใช้ที่ดิน (Land Use) เป็นกิจกรรมที่สร้างขึ้นและเปลี่ยนแปลงลักษณะทางกายภาพของพื้นที่ให้เป็นไปตามสิ่งที่มนุษย์ต้องการเพื่อสอดคล้องกับวัตถุประสงค์ เช่น พื้นที่ที่อยู่อาศัย พื้นที่อุตสาหกรรม พื้นที่เกษตรกรรม พื้นที่พาณิชยกรรม เป็นต้น ส่วนสิ่งปกคลุมดิน (Land Cover) เป็นลักษณะของวัตถุ สิ่งของ รวมถึงพืชพรรณที่เกิดจากการปกคลุมทางกายภาพของพื้นผิวโลก เช่น ป่าไม้ ต้นหญ้า พืชพรรณ ถนน บ้าน อาคาร เป็นต้น (Gregrio & Jansen, 2000; ทรงกต ทศานนท์, 2555; สรรค์ใจ กลิ่นดาว, 2550) กล่าวโดยสรุปได้ว่าการใช้ที่ดินคือกิจกรรมที่สร้างขึ้นเพื่อตอบสนองกับวัตถุประสงค์ของมนุษย์และสิ่งปกคลุมดินคือลักษณะทางกายภาพที่แสดงถึงวัตถุที่อยู่บนพื้นผิวโลก

การจำแนกการใช้ที่ดินของประเทศไทยถูกพัฒนาโดยกรมพัฒนาที่ดินเป็นการปรับปรุงจากระบบของกรมทรัพยากรธรณีประเทศสหรัฐอเมริกา (U.S. Geological Survey : USGS) แบ่งการจำแนกออกเป็น 3 ระดับ (กรมพัฒนาที่ดิน, 2563) ดังนี้

ระดับที่ 1 แบ่งเป็นพื้นที่ชุมชนและสร้างสิ่งปลูกสร้าง (U) พื้นที่เกษตรกรรม (A) พื้นที่ป่าไม้ (F) พื้นที่น้ำ (W) และพื้นที่เบ็ดเตล็ด (M)

ระดับที่ 2 จำแนกรายละเอียดพื้นที่แต่ละประเภทในระดับ 1 ตัวอย่างเช่น พื้นที่ชุมชนและสิ่งก่อสร้าง แบ่งย่อยเป็น ตัวเมืองและย่านการค้า หมู่บ้าน สถานที่ราชการ สถานีคมนาคม

ระดับที่ 3 จำแนกรายละเอียดพื้นที่แต่ละประเภทในระดับที่ 2 ดังตัวอย่างตามตาราง 1

ตาราง 1 ตัวอย่างการจำแนกการใช้ที่ดินประเทศไทยของพื้นที่ชุมชนและสิ่งปลูกสร้าง

ระดับ/ Level 1	ระดับ/ Level 2	ระดับ/ Level 3
U พื้นที่ชุมชนและสิ่งปลูกสร้าง	U1 ตัวเมืองและย่านการค้า	U200 โครงการที่ดินจัดสรร
	U2 หมู่บ้าน	U201 หมู่บ้าน
	U3 สถานที่ราชการ และสถาบัน ต่างๆ	U202 หมู่บ้านบนพื้นที่สูง U401 สนามบิน
	U4 สถานีคมนาคม	U402 สถานีรถไฟ
	U5 ย่านอุตสาหกรรม	U403 สถานีขนส่ง
	U6 อื่นๆ	U404 ท่าเรือ
		U501 นิคมอุตสาหกรรม
U502 โรงงานอุตสาหกรรม		
U601 สถานที่พักผ่อนหย่อนใจ		
	U602 สนามกอล์ฟ	
	U603 สุสาน ป่าช้า	
	U604 ศูนย์อพยพ	

การจำแนกการใช้ที่ดินของประเทศไทยที่พัฒนาโดยกรมพัฒนาที่ดินมีการกำหนดระดับการจำแนกทั้งหมด 3 ระดับโดยแต่ละระดับจะมีการแบ่งตามลักษณะของการใช้ที่ดินและสิ่งปลูกคลุมดินซึ่งสามารถนำมาใช้เป็นแนวทางในการกำหนดประเภทของการใช้ที่ดินและสิ่งปลูกคลุมดินซึ่งจะใช้กับการกำหนดประเภทในกระบวนการแปลตีความข้อมูลภาพถ่ายเทียมตลอดจนกระบวนการวิเคราะห์ข้อมูลภาพถ่ายเทียม แต่ว่าการกำหนดการจำแนกนั้นจะต้องคำนึงถึงความละเอียดเชิงพื้นที่ของข้อมูลภาพถ่ายเทียมในแต่ละประเภทที่จะนำมาใช้งาน เนื่องจากจะส่งผลต่อระดับของการจำแนกประเภทนั่นเอง

ข้อมูลพื้นที่จังหวัดพิษณุโลก

เป็นจังหวัดที่ตั้งอยู่ในเขตภาคเหนือตอนล่างภาคกลางตอนบนของประเทศไทยมีพื้นที่ 10,815.854 ตารางกิโลเมตร แบ่งออกเป็น 9 อำเภอ ประกอบด้วย อำเภอเมืองพิษณุโลก วังทอง บางกระพุ่ม พรหมพิราม นครไทยชาติตระการ วัดโบสถ์และบางระกำ มีเทศบาลนครพิษณุโลกเป็นเขตเมืองศูนย์กลางของจังหวัดและเป็นที่ตั้งศาลากลางจังหวัด (จังหวัดพิษณุโลก, 2563)

1. ที่ตั้งและอาณาเขต

จังหวัดพิษณุโลกห่างจากกรุงเทพมหานคร 377 กิโลเมตร มีเนื้อที่ทั้งหมดประมาณ 10,815 ตารางกิโลเมตร หรือ 6,759,909 ไร่ มีอาณาเขตติดต่อกับจังหวัดใกล้เคียงดังนี้

ทิศเหนือ ติดต่อกับอำเภอพิชัย อำเภอทองแสนขัน และอำเภอน้ำป่าด จังหวัดอุตรดิตถ์, แขวงไชยบุรี ประเทศลาว

ทิศตะวันออก ติดต่อกับอำเภอหล่มสัก อำเภอเขาค้อ อำเภอวังโป่ง จังหวัดเพชรบูรณ์, อำเภอด่านซ้าย และอำเภอนาแห้ว จังหวัดเลย

ทิศใต้ ติดต่อกับอำเภอเมืองพิจิตร อำเภอลำลูกขัน อำเภอสามง่าม และอำเภอสามโก้ จังหวัดพิจิตร


ทิศตะวันตก ติดต่อกับอำเภอองไกรลาค อำเภอศรีสำโรง จังหวัดสุโขทัย, อำเภอลานกระบือ จังหวัดกำแพงเพชร

2. ลักษณะภูมิประเทศ

ทางตอนเหนือและตอนกลางเป็นเขตเทือกเขาสูงและที่ราบสูง โดยมีเขตภูเขาสูงด้านตะวันออกเฉียงเหนือซึ่งอยู่ในเขตอำเภอวังทอง อำเภอวัดโบสถ์ อำเภอเนินมะปราง อำเภอนครไทย และอำเภอชาติตระการจุดสูงสุดคือภูสอยดาว 2,102 เมตร เป็นยอดเขาปันเขตแดนไทย-ลาว พื้นที่ตอนกลางมาทางใต้เป็นที่ราบ และตอนใต้เป็นที่ราบลุ่ม โดยเฉพาะบริเวณลุ่มแม่น้ำน่านและแม่น้ำยม ซึ่งเป็นแหล่งการเกษตรที่สำคัญที่สุดของจังหวัดพิษณุโลก อยู่ในเขตอำเภอบางระกำ อำเภอเมืองพิษณุโลก อำเภอพรหมพิราม อำเภอเนินมะปราง และบางส่วนของอำเภอวังทอง (จังหวัดพิษณุโลก, 2563)

3. เขตการปกครอง

จังหวัดพิษณุโลกแบ่งการปกครองออกเป็น 9 อำเภอ 93 ตำบล 1,032 หมู่บ้าน ซึ่งอำเภอทั้ง 9 อำเภอมีดังนี้ 1) อำเภอเมืองพิษณุโลก 2) อำเภอนครไทย 3) อำเภอชาติตระการ 4) อำเภอบางระกำ 5) อำเภอบางกระทุ่ม 6) อำเภอพรหมพิราม 7) อำเภอวัดโบสถ์ 8) อำเภอวังทอง และ 9) อำเภอเนินมะปราง (จังหวัดพิษณุโลก, 2563) ดังภาพ 3



ภาพ 3 แสดงเขตการปกครองจังหวัดพิษณุโลก

เนื่องจากสถานการณ์ปัญหาการใช้ที่ดินของประเทศไทยในช่วงหลายปีที่ผ่านมาจะเกี่ยวข้องกับการบุกรุกพื้นที่อนุรักษ์ ความขัดแย้งเรื่องแนวเขตที่ดิน การใช้ที่ดินที่ไม่เหมาะสมหรือเต็มศักยภาพ ความเสื่อมล้ำและการกระทำการถือครองที่ดินไม่เป็นธรรม การไร้ที่ดินทำกิน การขาดเอกภาพในการบริหารจัดการที่มีความเกี่ยวข้องกัน และเป็นอุปสรรคต่อการพัฒนาทางเศรษฐกิจ สังคม การรักษาความสมดุลของระบบนิเวศ ตลอดจนส่งผลต่อความมั่นคงของฐานทรัพยากรธรรมชาติ โดยเฉพาะ ที่ดิน ซึ่งเป็นฐานหลักสำหรับใช้ในการผลิตอาหารที่มั่นคงและปลอดภัย รวมถึงที่ดินยังมีบทบาทที่สำคัญในการพัฒนาเศรษฐกิจของประเทศไทยไม่ว่าจะเป็น ภาคอุตสาหกรรม อสังหาริมทรัพย์ และภาคบริการ ส่งผลให้ความต้องการที่ดินเพื่อกิจกรรมทางเศรษฐกิจต่างๆ เพิ่มขึ้นตามอัตราการขยายตัวทางเศรษฐกิจเพื่อพัฒนาประเทศ นอกเหนือจากนี้ทรัพยากรดินของประเทศไทย ยังประสบปัญหาดินเสื่อมโทรมและขาดความอุดมสมบูรณ์ (กองนโยบายและแผนการใช้ที่ดิน, 2562) จากสถานการณ์ที่เกิดขึ้น รัฐธรรมนูญแห่งราชอาณาจักรไทย พ.ศ. 2560 มาตรา 72(1) ได้มีการบัญญัติให้มีการวางแผนการใช้ที่ดินของประเทศไทยให้เหมาะสมกับสภาพพื้นที่และศักยภาพของที่ดินตามหลักการพัฒนาอย่างยั่งยืน และเพื่อให้เป็นไปในการปฏิบัติตามรัฐธรรมนูญแห่งราชอาณาจักรไทย พ.ศ. 2560 สำนักนายกรัฐมนตรี จึงมีประกาศแผนการปฏิรูปประเทศโดยมีแผนการปฏิรูปด้านทรัพยากรธรรมชาติและสิ่งแวดล้อม เรื่องทรัพยากรดิน ที่ได้กำหนดให้มีการจัดทำแผนการใช้ที่ดินของชาติทั้งระบบให้สอดคล้องและเหมาะสมกับศักยภาพของพื้นที่และการพัฒนาเศรษฐกิจและสังคมของประเทศ มีเป้าหมายให้ประเทศมีแผนการใช้ที่ดินที่มีความถูกต้อง แม่นยำ และเป็นปัจจุบันทั้งระบบ และเกษตรกรสามารถนำข้อมูลแผนการใช้ที่ดินดังกล่าว ไปใช้ในการพัฒนาพื้นที่การเกษตรให้เหมาะสมกับศักยภาพของพื้นที่ของตนได้ ดังนั้นในจังหวัดพิษณุโลกได้ดำเนินการให้เป็นไปตามรัฐธรรมนูญฯ พ.ศ. 2560 และแผนการปฏิรูปประเทศดังกล่าว สำนักงานปฏิรูปที่ดินจังหวัดพิษณุโลกรับพันธกิจหลักในการปรับปรุงบำรุงดิน รวมถึงการอนุรักษ์ดินและน้ำ จึงได้ยึดการจัดทำแผนการใช้ที่ดินระดับชาติ ระดับจังหวัด และระดับตำบลขึ้น โดยมีเป้าหมายในการปรับปรุงแผนที่สภาพการใช้ที่ดินให้มีความละเอียด ความถูกต้อง แม่นยำมากขึ้น โดยใช้เทคโนโลยีและนวัตกรรมสมัยใหม่ให้มีความสอดคล้องกับสภาพแวดล้อม และสถานการณ์ทรัพยากรดินที่เปลี่ยนแปลงไป ซึ่งจะส่งผลให้แผนการใช้ที่ดินที่สอดคล้องและเหมาะสมกับศักยภาพพื้นที่และสภาพทางเศรษฐกิจและสังคม ทั้งระบบตั้งแต่ระดับประเทศจนถึงระดับพื้นที่ สามารถนำไปใช้ในการบริหารจัดการพื้นที่เกษตรที่มีอยู่อย่างจำกัดให้สามารถใช้ประโยชน์ได้อย่างมีประสิทธิภาพเพื่อรองรับเกษตร 4.0 ตัวอย่างเช่น แผนการใช้ที่ดินตำบลมะขามสูง อำเภอเมือง จังหวัดพิษณุโลก (กองนโยบายและแผนการใช้ที่ดิน, 2562) มีการจัดทำแผนการใช้ที่ดินระดับตำบล มีกรอบระยะเวลาในการดำเนินงานทั้งสิ้น 5 ปี เพื่อสนับสนุนการจัดทำแผนปฏิบัติการการใช้ที่ดินระดับตำบล ให้มีการใช้ที่ดินอย่างมี

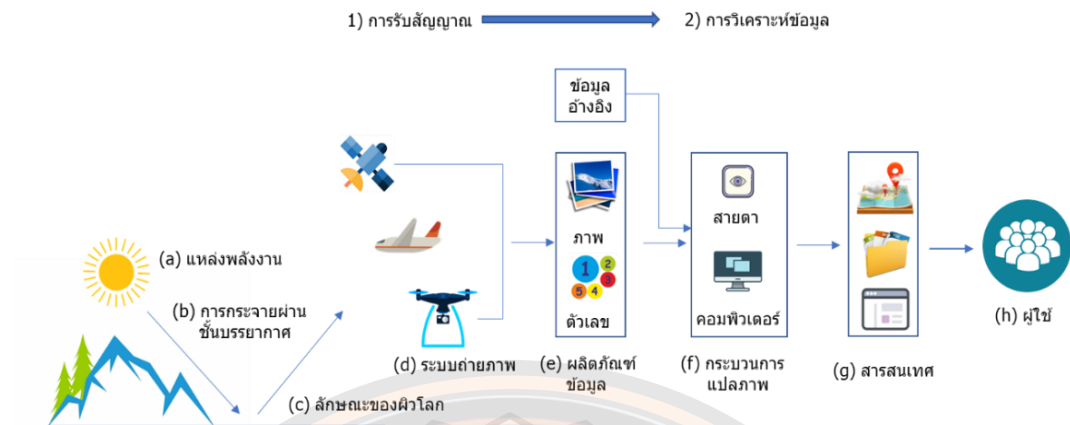
ประสิทธิภาพ สอดคล้องกับศักยภาพของที่ดิน และความต้องการของชุมชนในตำบล อำเภอ และ จังหวัด

การรับรู้จากระยะไกล

การรับรู้จากระยะไกลเริ่มในศตวรรษที่ 20 จากรูปถ่ายทางอากาศ (Aerial Photographs) เกิดจากการถ่ายภาพที่ใช้ช่วงคลื่นตามมองเห็นของคลื่นแม่เหล็กไฟฟ้าเป็นลักษณะของรูปถ่ายที่บันทึกบนฟิล์ม ต่อมาเป็นลักษณะของภาพที่ถูกบันทึกด้วยระบบกวาดภาพ (Scanner System) ซึ่งเป็นลักษณะของการบันทึกข้อมูลเชิงเลข ทำให้ได้ข้อมูลโดยใช้คลื่นแม่เหล็กไฟฟ้าที่ยาวกว่าช่วงคลื่นตามมองเห็น (สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ, 2552) ตัวอย่างเช่น ช่วงคลื่นอินฟราเรดความร้อน (Thermal Infrared) หรือในช่วงคลื่นไมโครเวฟ (Microwave) ตั้งแต่ปี ค.ศ. 1960 เป็นต้นมาได้มีการพัฒนาดาวเทียมสำรวจทรัพยากรขึ้นสู่วงโคจรหลายดวงเช่น LANDSAT, SPOT, IRS และ JERS-1 ซึ่งมีความละเอียดของภาพต่ำกว่า 100 เมตร

การรับรู้จากระยะไกล (Remote Sensing) คือการบันทึกหรือการได้มาของข้อมูลเกี่ยวกับวัตถุ พื้นที่ และปรากฏการณ์บนพื้นโลกจากเครื่องรับรู้ (Sensor) ปรากฏจากการเข้าสัมผัสวัตถุเป้าหมาย อาศัยพลังงานจากคลื่นแม่เหล็กไฟฟ้า (Electromagnetic Energy) เป็นสื่อกลางในการได้มาของข้อมูลซึ่งมีคุณสมบัติ 3 ประการ คือ ลักษณะการสะท้อนช่วงคลื่นแม่เหล็กไฟฟ้า (Spectral Characteristics) ลักษณะเชิงพื้นที่ของวัตถุบนพื้นผิวโลก (Spatial Characteristics) และลักษณะการเปลี่ยนแปลงของวัตถุตามช่วงเวลา (Temporal Characteristics) (สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ, 2552) ซึ่งสามารถนำมาสกัดข้อมูลเพื่อทำการวิเคราะห์และประมวลผล

กระบวนการและองค์ประกอบการรับรู้จากระยะไกล (Processes and Elements of Remote Sensing) ประกอบด้วย 2 ส่วนคือ การได้มาซึ่งข้อมูล (Data Acquisition) และการวิเคราะห์ข้อมูล (Data Analysis) (สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ, 2552) ดังภาพ 4



ภาพ 4 กระบวนการและองค์ประกอบการรับรู้จากระยะไกล
ปรับปรุงจาก สำนักงานเทคโนโลยีอวกาศและภูมิสารสนเทศ (2552)

1) การได้มาซึ่งข้อมูล (Data Acquisition) เกิดจากคลื่นแม่เหล็กไฟฟ้าที่ได้จากแหล่งกำเนิดพลังงาน เช่น ดวงอาทิตย์ (a) เคลื่อนผ่านชั้นบรรยากาศ (b) เกิดปฏิสัมพันธ์ของพลังงานกับรูปลักษณะบนพื้นผิวโลก (c) และเดินทางเข้าสู่เครื่องรับที่ติดตั้งในตัวยาน เช่น เครื่องบิน ยานอวกาศ อากาศยานไร้คนขับ และดาวเทียม (d)

2) การวิเคราะห์ข้อมูล (Data Analysis) จะเกี่ยวข้องกับข้อมูลอ้างอิงต่าง ๆ เช่น ชุดข้อมูลดิน ข้อมูลปฏิทิน สถิติการปลูกพืช และอื่นๆ เป็นต้น (e) ผ่านกระบวนการวิเคราะห์และแปลตีความภาพ (Image Analysis and Interpretation) ประกอบไปด้วย การแปลตีความภาพด้วยสายตา (Visual Interpretation) และการวิเคราะห์เชิงเลข (Digital analysis) หรือการแปลตีความภาพด้วยคอมพิวเตอร์ (f) จนได้ผลลัพธ์ (g) ของการแปลตีความในรูปแบบแผนที่ ข้อมูลเชิงเลข ตารางคำอธิบาย หรือแผนภูมิ เป็นต้น เพื่อนำไปใช้ประโยชน์ต่อไป (h)

การรับรู้จากระยะไกลสามารถแบ่งออกเป็น 2 ระบบ คือ การรับรู้จากระยะไกลแบบพาสซีฟ (Passive Remote Sensing System) และ การรับรู้จากระยะไกลแบบแอ็กทีฟ (Active Remote Sensing System) โดยการรับรู้ระยะไกลแบบพาสซีฟ เป็นการตรวจวัดพลังงานคลื่นแม่เหล็กไฟฟ้าที่ได้จากการสะท้อน (Reflect) จากพื้นผิว และรับพลังงานจากดวงอาทิตย์ทำให้พลังงานที่ตรวจวัดได้อยู่ในช่วงคลื่นที่ตามองเห็น และอินฟราเรด (Infrared) ช่วงคลื่นแม่เหล็กไฟฟ้าที่สามารถทะลุผ่านชั้นบรรยากาศลงมาได้ เพราะถ้าช่วงคลื่นสั้นกว่าความยาวของคลื่นนี้จะถูกดูดกลืนโดยชั้นบรรยากาศ ตัวอย่างดาวเทียมในระบบพาสซีฟ เช่น ดาวเทียม LANDSAT, SPOT เป็นต้น ส่วนการรับรู้จากระยะไกลแบบแอ็กทีฟ เป็นระบบที่มนุษย์สร้างพลังงานรวมทั้งส่งพลังงานมากระทบวัตถุเป้าหมาย

ในช่วงคลื่นไมโครเวฟ เช่น ระบบเรดาร์ (Radio Detection And Ranging : RADAR) ตัวอย่างดาวเทียมในระบบแอ็กทิฟ เช่น ดาวเทียม RADARSAT, ERS, ENVISAT ซึ่งบางครั้งข้อมูลที่ได้จากการรับรู้ระยะไกลทั้ง 2 ระบบนี้อาจเรียกว่า “ข้อมูลภาพดาวเทียม” (กิตติศักดิ์ ศรีกลาง, 2557; สุรชัยรัตน์เสริมพงศ์, 2553)

ข้อมูลภาพดาวเทียม

ข้อมูลภาพดาวเทียม คือข้อมูลจากการใช้ดาวเทียมทำการถ่ายภาพเก็บข้อมูลพื้นผิวโลกตามช่วงเวลาวงโคจรของแต่ละชนิดดาวเทียม แต่การที่จะนำข้อมูลมาใช้งานจะต้องผ่านกระบวนการวิเคราะห์และตีความภาพ (Image Analysis and Interpretation) โดยข้อมูลภาพดาวเทียมมีลักษณะการเก็บภาพในระบบเชิงตัวเลขเพื่อใช้แทนวัตถุบนพื้นผิวโลก เก็บเป็นแบบแถวจุดภาพ (Arrays of Pixel) ในแต่ละจุดภาพ (Pixel) มีระดับสีเทา และตำแหน่งอ้างอิงจากแถวและคอลัมน์ ค่าของจุดภาพ (Pixel Value) หรือ จำนวนตัวเลข (Digital Number) เป็นค่าที่บันทึกได้จากพลังงานที่สะท้อนจากวัตถุบนพื้นผิวโลกไปยังเครื่องตรวจจับ (เขาวลิต ศิลปทอง, 2553) กระบวนการต่างๆ ในการประมวลผลและการวิเคราะห์ข้อมูลเชิงตัวเลข มีไว้เพื่อช่วยให้เกิดประโยชน์ของการนำข้อมูลภาพไปใช้งาน แต่พบว่าในอดีตการประมวลผลภาพเพื่อให้ได้มาซึ่งข้อมูล จะอาศัยการตีความหมายจากภาพถ่ายทางอากาศหรือข้อมูลภาพจากดาวเทียมแต่ต้องใช้วิธีการแปลตีความด้วยสายตา ซึ่งวิธีนี้ความถูกต้องจะขึ้นอยู่กับประสบการณ์ของผู้แปลรวมถึงองค์ประกอบต่าง ๆ สำหรับการตัดสินใจในแปลเพื่อจำแนกประเภทข้อมูล อีกทั้งใช้งบประมาณค่อนข้างสูงและระยะเวลาในการทำงานค่อนข้างนานตลอดจนผู้แปลต้องมีความรู้และความชำนาญเป็นอย่างมาก ซึ่งในปัจจุบันเพื่อเป็นการลดปัญหาการแปลตีความภาพด้วยสายตาจึงเกิดวิธีการนำคอมพิวเตอร์เข้ามาช่วยประมวลผลภาพในกระบวนการของการจำแนกอาศัยการจำแนกค่าของจุดภาพในประเภท (Class) ของการจำแนกข้อมูล เพื่อเป็นการจัดกลุ่มจุดภาพให้เป็นประเภทตามเงื่อนไขที่กำหนด การจำแนกประเภทข้อมูลภาพ (Image Classification) มีการพัฒนาวิธีการจำแนกประเภทข้อมูลภาพด้วยการประมวลผลภาพในหลายวิธี อาทิเช่น 1) การจำแนกแบบควบคุม (Supervised Classification) คือการแบ่งประเภทของการสะท้อนช่วงคลื่นออกเป็นกลุ่มหลายๆ กลุ่มแล้วกำหนดให้เป็นพื้นที่ของกลุ่มข้อมูลฝึกฝน (Training Area) เป็นตัวแทนของลักษณะต่างๆ ใช้สำหรับคำนวณค่าทางสถิติ เช่น ค่าเฉลี่ยของแต่ละประเภทข้อมูล ค่าสถิตินี้ใช้เป็นตัวแทนสำหรับการจำแนกประเภทของข้อมูลภาพ 2) การจำแนกแบบไม่ควบคุม (Unsupervised Classification) เป็นการจำแนกโดยใช้การจำแนกประเภทข้อมูลจากค่าสถิติของการสะท้อนของช่วงคลื่นในวัตถุต่างๆ เรียกว่า การจัดกลุ่มของข้อมูล (Clustering) และ 3) การจำแนกแบบเชิงวัตถุ (Object-based Classification) เป็นการจำแนกโดยใช้ค่าการสะท้อนแสงแบบสองวิธีที่ผ่านมาแต่จะพิจารณาจากรูปร่าง สี ความเรียบ และความเกาะกลุ่มของข้อมูลภาพถ่าย

ดาวเทียมรวมถึงค่าความสำคัญของช่วงคลื่นเรียกว่า “ขั้นตอนการแบ่งส่วน (Segmentation)” และการจำแนกวัตถุนั้นเกิดจากค่าการสะท้อนแสงรวมของวัตถุที่สร้างขึ้นซึ่งวิธีการนี้เป็นการรวมค่าการสะท้อนแสงที่ใกล้เคียงของจุดภาพเข้าด้วยกัน (ทบทอง ชั้นเจริญ, 2558)

คุณลักษณะข้อมูลดาวเทียม (สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ, 2552) ดังนี้

1. ข้อมูลมีลักษณะเป็นข้อมูลเชิงตัวเลข มีความละเอียดของค่าการสะท้อนช่วงคลื่นแสงในค่าระดับสีเทาจำนวน 256 ระดับ (ในกรณี 8 บิต) โดยในแต่ละช่วงคลื่นสามารถนำไปผลิตเป็นภาพขาวดำและภาพสีผสมสามารถนำไปวิเคราะห์ด้วยเครื่องคอมพิวเตอร์ได้

2. ข้อมูลมีค่าที่สะท้อนจากดาวเทียมที่กำลังโคจรผ่านสถานีสามารถส่งมายังภาคพื้นได้ทันที

3. ข้อมูลถูกบันทึกในช่วงคลื่นที่กล้องธรรมดาไม่สามารถบันทึกได้ ตลอดจนข้อมูลที่ได้รับมีความละเอียดในหลายระดับ

4. ข้อมูลสามารถบันทึกเป็นบริเวณกว้าง (Synoptic View) ความกว้างของแนวถ่ายภาพครอบคลุมพื้นที่กว้างทำให้ได้ข้อมูลที่มีความต่อเนื่อง สามารถศึกษาลักษณะของสภาพแวดล้อมต่างๆ ในบริเวณที่กว้างอย่างต่อเนื่องในระยะเวลาเดียวกันทั้งภาพ เช่น ข้อมูลจากภาพถ่ายดาวเทียม Landsat ระบบ MSS และระบบ TM หนึ่งภาพสามารถครอบคลุมพื้นที่ขนาด 185 x 185 ตารางกิโลเมตร ส่วนข้อมูลจากภาพถ่ายดาวเทียม SPOT หนึ่งภาพสามารถครอบคลุมพื้นที่ขนาด 60 x 60 ตารางกิโลเมตร เป็นต้น

5. ภาพจะถูกบันทึกได้หลายช่วงคลื่น ดาวเทียมสำรวจทรัพยากรมีทั้งกล้อง และระบบการกราดภาพที่บันทึกข้อมูลได้หลายช่วงคลื่นในบริเวณเดียวกัน ทั้งช่วงคลื่นสายตามองเห็นและช่วงคลื่นที่นอกเหนือสายตามนุษย์จึงทำให้แยกวัตถุต่างๆ บนพื้นผิวโลกได้ เช่น ระบบ MSS และระบบ MESSR มี 4 ช่วงคลื่น ระบบ TM มี 7 ช่วงคลื่น ระบบ HRV แพนโครมมาติก และระบบหลายสเปกตรัมมี 1 และ 3 ช่วงคลื่นตามลำดับ

6. ข้อมูลสามารถบันทึกซ้ำบริเวณ (Repetitive Coverage) ดาวเทียมทรัพยากรมีวงโคจรจากทิศเหนือไปทางทิศใต้ และจะกลับมายังบริเวณเดิมในเวลาท้องถิ่นเดียวกันในช่วงเวลาที่แน่นอน เช่น ดาวเทียม LANDSAT จะบันทึกข้อมูลซ้ำทุกๆ 16 วัน ส่วนดาวเทียมดวงอื่นๆ ก็จะมีการบันทึกข้อมูลซ้ำที่แตกต่างกัน จึงทำให้ได้ข้อมูลบริเวณเดียวกันในหลายๆ ช่วงเวลา และสามารถนำมาเปรียบเทียบ ติดตามการเปลี่ยนแปลงบนพื้นผิวโลกได้รวมถึงมีโอกาสที่จะได้ข้อมูลที่เห็นพื้นผิวได้อย่างชัดเจนโดยไม่มีเมฆมาปิดบัง

7. ภาพสามารถให้ความละเอียดได้ในหลายระดับ (Multi-resolution) ข้อมูลจากดาวเทียมที่มีความละเอียดภาพหลายระดับมีผลดีในการเลือกนำไปใช้ประโยชน์สำหรับการศึกษาด้านต่างๆ ขึ้นอยู่กับวัตถุประสงค์ที่นำไปใช้ เช่น ข้อมูลจากดาวเทียม Landsat ระบบ TM ความละเอียดภาพ

30 เมตร ข้อมูลดาวเทียม SPOT ความละเอียดภาพ 2.5 เมตร ข้อมูลจากดาวเทียม THEOS ความละเอียด 2 เมตร ข้อมูลจากดาวเทียม IKONOS ความละเอียดภาพ 1 เมตร และข้อมูลจากดาวเทียม QuickBird ความละเอียดภาพ 61 เซนติเมตร

8. ภาพสีผสม (Color Composite) จากข้อมูลภาพถ่ายดาวเทียมสามารถสร้างภาพสีจากการผสมภาพ 3 ช่วงคลื่น จากช่วงคลื่นของดาวเทียมที่บันทึกภาพ

ข้อมูลภาพถ่ายดาวเทียม Landsat 8 จะได้จากระบบบันทึกภาพ 2 ชนิด คือ Operation Land Imager (OLI) และ The Thermal Infrared Sensor (TIRS) จำนวน 11 ช่วงคลื่น ให้รายละเอียดจุดภาพช่วงคลื่น Visible, NIR, SWIR 30 เมตร ช่วงคลื่น Thermal 100 เมตร และ Panchromatic 15 เมตร แสดงในตาราง 2

ตาราง 2 ความยาวช่วงคลื่นและรายละเอียดจุดภาพของดาวเทียม Landsat 8

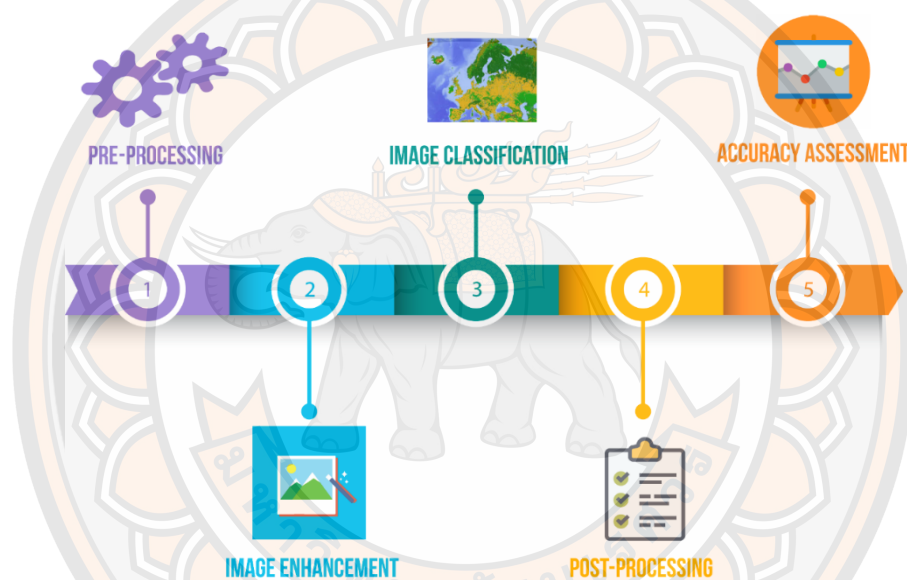
ประเภทช่วงคลื่น	ข้อมูลจากดาวเทียม Landsat 8	
	ขนาดช่วงคลื่น (μm)	รายละเอียด จุดภาพ (เมตร)
1. Coastal Aerosol	0.43 – 0.45	30
2. ช่วงสายตามองเห็นสีน้ำเงิน (Blue)	0.45 – 0.51	30
3. ช่วงสายตามองเห็นสีเขียว (Green)	0.53 – 0.59	30
4. ช่วงสายตามองเห็นสีแดง (Red)	0.64 – 0.67	30
5. อินฟราเรดใกล้ (Near Infrared - NIR)	0.85 – 0.88	30
6. อินฟราเรดคลื่นสั้น 1 (SWIR 1)	1.57 – 1.65	30
7. อินฟราเรดคลื่นสั้น 2 (SWIR 2)	2.11 – 2.35	30
8. ระบบขาว – ดำ (Panchromatic)	0.50 – 0.68	15
9. เมฆชั้นสูง (Cirrus)	1.36 – 1.38	30
10. อินฟราเรดความร้อน 1 (Thermal Infrared - TIRS 1)	10.60 – 11.19	100
11. อินฟราเรดความร้อน 2 (Thermal Infrared - TIRS 2)	11.50 – 12.51	100

ซึ่งดาวเทียม Landsat 8 เป็นดาวเทียมประเภทดาวเทียมสำรวจทรัพยากรธรรมชาติของประเทศสหรัฐอเมริกา พัฒนาจากความร่วมมือระหว่างองค์การ NASA และ USGS (U.S. Geological Survey) ถูกส่งขึ้นสู่วงโคจรในวันที่ 11 กุมภาพันธ์ 2556 โคจรซ้ำตำแหน่งเดิมทุกๆ 16 วัน ความกว้างของแนวถ่ายภาพ 185 กิโลเมตร สามารถเข้าถึงข้อมูลผ่านทางเว็บไซต์

<http://earthexplorer.usgs.gov> (USGS, 2017)

การประมวลผลข้อมูลภาพถ่ายดาวเทียม

การประมวลผลข้อมูลภาพถ่ายดาวเทียมแบ่งออกเป็นการแปลตีความด้วยสายตา (Visual Interpretation) เกิดจากการใช้องค์ประกอบในการแปลความหมายพิจารณาจากความเข้มของสีและสี (Tone/Color) ขนาด (Size) รูปร่าง (Shape) เนื้อภาพ (Texture) รูปแบบ (Pattern) ความสูงและเงา (Height and Shadow) ที่ตั้ง (Site) ความเกี่ยวพัน (Association) และการประมวลผลภาพด้วยคอมพิวเตอร์ (Image Processing) ซึ่งมีกระบวนการตามภาพ 5



ภาพ 5 การประมวลผลภาพด้วยคอมพิวเตอร์ (Kamavisdar et al., 2013)

การประมวลผลภาพด้วยคอมพิวเตอร์เป็นกระบวนการของการประมวลผลข้อมูลภาพจากดาวเทียม ประกอบด้วย กระบวนการก่อนการประมวลผลภาพ (Pre-processing) การเน้นข้อมูลภาพ (Image enhancement) การจำแนกประเภทข้อมูลภาพ (Image Classification) การวิเคราะห์หลังการจำแนก (Post-processing) และการตรวจสอบความถูกต้อง (Accuracy Assessment) (Kamavisdar et al., 2013)

1. กระบวนการก่อนการประมวลผลภาพ (Pre-processing) เป็นการปรับแก้ความคลาดเคลื่อนของข้อมูล (Data Error) สัญญาณรบกวน (Noise) และความบิดเบี้ยวเชิงเรขาคณิตที่เกิดขึ้นในระหว่างการถ่ายภาพ การบันทึกข้อมูลสัญญาณของการสะท้อนคลื่นแม่เหล็กไฟฟ้า การส่งสัญญาณ และการโคจรของดาวเทียม

2. การเน้นข้อมูลภาพ (Image Enhancement) เป็นกระบวนการปรับเปลี่ยนค่าของจุดภาพหรือค่าระดับสีเทา เพื่อเพิ่มรายละเอียด ความชัดเจนของข้อมูลหรือการเพิ่มระดับความแตกต่างระหว่างวัตถุ ทำให้สังเกตเห็นขอบเขตของวัตถุต่างชนิดกันได้ชัดเจนมากขึ้นหรือสามารถเน้นความคมชัดเฉพาะในส่วนที่ต้องการศึกษาช่วยให้การตีความประเภทวัตถุง่ายขึ้นแล้วนำผลลัพธ์ที่ได้ไปทำการตีความเพื่อกำหนดประเภทข้อมูลก่อนนำไปใช้เพื่อการจำแนกประเภทข้อมูล เทคนิคต่างๆ ที่จะใช้ในการเน้นข้อมูลภาพนั้น

3. การจำแนกประเภทข้อมูลภาพ (Image Classification) การจำแนกประเภทข้อมูลภาพเป็นการกระบวนการประมวลผลในทางสถิติ เพื่อแยกข้อมูลจุดภาพทั้งหมดที่ประกอบเป็นพื้นที่ศึกษาออกเป็นกลุ่มย่อยใช้ลักษณะทางสถิติเป็นตัวกำหนดความแตกต่างระหว่างกลุ่มจุดภาพ โดยจุดภาพที่ถูกจัดให้อยู่กลุ่มเดียวกันจะมีลักษณะทางสถิติเฉพาะกลุ่มเป็นไปในทิศทางเดียวกัน แต่ละกลุ่มจุดภาพที่จำแนกได้นั้นจะแสดงถึงสิ่งปกคลุมพื้นดินประเภทใดประเภทหนึ่งที่แตกต่างกันไป ในการจำแนกข้อมูลภาพดาวเทียมมีหลายวิธีซึ่งขึ้นอยู่กับประเภทของการจำแนกที่เลือกใช้ (Kamavisdar et al., 2013; Natya & Rehna, 2016; Salah, 2017) แสดงในตาราง 3

ตาราง 3 ประเภทของการจำแนกข้อมูลภาพดาวเทียม

ประเภท	ลักษณะ	ตัวอย่างวิธีการจำแนก
Supervised	กำหนดพื้นที่ตัวอย่างลักษณะของประเภทข้อมูลเอง	K-nearest neighbor Minimum distance Mahalanobis distance Maximum likelihood Parallelepiped Spectral angle mapper
Unsupervised	ไม่ต้องกำหนดพื้นที่ตัวอย่างของข้อมูลแต่ละประเภท	ISODATA K-means Support vector machine
Object-Based	การแบ่งส่วนภาพ (Segmentation) ออกเป็นหลายพื้นที่ (Region) หรือวัตถุ (Object) หลายชนิดตามลักษณะของการเป็นเนื้อเดียวกัน (Homogenous Area) หรือมีความสัมพันธ์กัน (Relatively Homogeneous Areas) เพื่อพยายามสร้างวัตถุและใช้วัตถุที่สร้างขึ้นมาอธิบายชั้นข้อมูล (Class)	eCognition

4. การวิเคราะห์หลังการจำแนก (Post-processing) หลังการประมวลผลเพื่อจำแนกวัตถุแต่ละชนิด จะนำผลลัพธ์ที่ได้มาวิเคราะห์และแก้ไขให้มีความถูกต้องมากขึ้น เช่น บริเวณขอบของพื้นที่เนื่องจากข้อจำกัดของความละเอียดจุดภาพของข้อมูลภาพถ่ายดาวเทียมทำให้บางจุดภาพมีข้อมูลของวัตถุมากกว่า 1 ชนิด เช่น มีข้อมูลจากพื้นที่นา 50% และมีพื้นที่ดิน 50% เป็นต้น ส่งผลให้การแปลผิดพลาดเพราะจุดภาพดังกล่าวเป็นนาข้าวแค่ 50% จึงไม่สามารถบอกได้ว่าจุดดังกล่าวเป็นพื้นที่นาหรือไม่ใช่พื้นที่นา (Prasad & Krishna, 2015)

5. การตรวจสอบความถูกต้อง (Accuracy Assessment) เป็นการเปรียบเทียบผลที่ได้จากการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมหรือร่วมกับการออกสำรวจในภาคสนามก่อนที่จะมีการสรุปผลตีความ เพื่อนำข้อมูลที่เกี่ยวข้องได้ในภาคสนามมาทำการตรวจสอบแก้ไขผลการแปลภาพให้สมบูรณ์ยิ่งขึ้นในบางครั้งการสำรวจภาคสนามต้องคำนึงถึงช่วงเวลาที่ต้องสำรวจต้องเป็นช่วงเวลาใกล้เคียงกับภาพที่ใช้ในการแปลตีความ แล้วนำมาแจกแจงให้อยู่ในรูปของตารางข้อมูลที่เรียกว่า Error Matrix สามารถใช้แสดงค่าความถูกต้อง ได้แก่ ความถูกต้องของผู้ผลิต (Producer's Accuracy) ความถูกต้องของผู้ใช้ (User's Accuracy) ความถูกต้องโดยรวม (Overall Accuracy) และ ค่าสัมประสิทธิ์แคปปา (Kappa coefficient: \hat{K}_l) ดังสมการ 1-4 ซึ่งทำให้การจำแนกภาพถ่ายดาวเทียมมีความถูกต้องมากขึ้น

$$\text{Overall accuracy} = \frac{\text{ผลรวมจุดตรวจสอบทั้งหมดที่ตรงกัน} * 100}{\text{จำนวนจุดตรวจสอบทั้งหมดที่ใช้เป็นตัวอย่างตรวจสอบ}} \quad (1)$$

$$\hat{K}_l = \frac{N(X_{ii}) - (X_{i+} * X_{+i})}{N^2 - (X_{i+} * X_{+i})} \quad (2)$$

$$\text{Producer's accuracy} = \frac{X_{ii}}{X_{+i}} \quad (3)$$

$$\text{User's accuracy} = \frac{X_{ii}}{X_{i+}} \quad (4)$$

เมื่อ	X_{ii}	คือ จำนวนในแนวเฉียงของแถว i และคอลัมน์ i
	X_{i+}	คือ จำนวนรวมในแถว i
	X_{+i}	คือ จำนวนรวมในคอลัมน์ i
	N	คือ จำนวนรวมทั้งหมด

การวิเคราะห์ภาพเชิงวัตถุ (Object-Based Image Analysis)

การวิเคราะห์ภาพเชิงวัตถุเป็นหลักการของการจำแนกข้อมูลภาพเพื่อใช้ในการตีความหรืออธิบายปรากฏการณ์หรือสิ่งที่ปรากฏบนโลกจริง (Real World) โดยมีวิธีการที่สำคัญคือการแบ่งส่วนภาพ (Segmentation) เนื่องจากการแบ่งส่วนภาพจะทำการแบ่งภาพ (Image) ออกเป็นพื้นที่ (Region) หลายๆ ส่วน หรือวัตถุ (Object) หลายๆ ชนิดขึ้นอยู่กับคุณลักษณะของการเป็นเนื้อเดียวกัน (Homogenous Areas) หรือมีความสัมพันธ์กัน (Relatively Homogeneous Areas) เพื่อที่จะสร้างวัตถุและใช้วัตถุนั้นนำมาอธิบายชั้นข้อมูล (Class)

กระบวนการการวิเคราะห์ภาพเชิงวัตถุประกอบด้วยกระบวนการ 2 ขั้นตอนคือ การแบ่งส่วนภาพ (Image Segmentation) และการจำแนกวัตถุภาพ (Object Image Classification) (ตรีภรณ์ ไชยนรา และวิชัย เยี่ยงวีรชน, 2556)

1. การแบ่งส่วนภาพ (Image Segmentation)

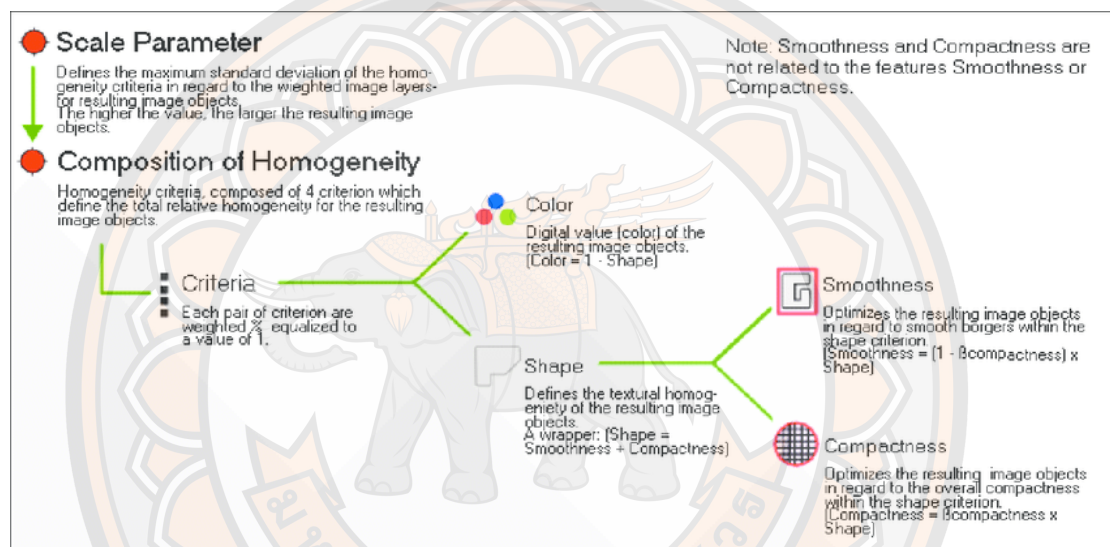
การแบ่งส่วนภาพคือ วิธีการที่ใช้สำหรับแบ่งภาพออกเป็นส่วนๆ อาศัยค่าการสะท้อนแสงของจุดภาพในบริเวณใกล้เคียงที่มีลักษณะของความเป็นเนื้อเดียวกันเข้าไว้ด้วยกัน อาจพิจารณาจากพารามิเตอร์ ได้แก่ ขนาด รูปร่าง สี ความเรียบ และการเกาะกลุ่มกันของข้อมูลที่ได้จากภาพถ่ายดาวเทียมรวมไปถึงค่าน้ำหนักของช่วงคลื่น ดังต่อไปนี้

1.1 พารามิเตอร์มาตราส่วน (Scale Parameter) เป็นการกำหนดขนาดในการสร้างวัตถุจากภาพโดยเกี่ยวข้องกับขนาดของวัตถุ ซึ่งจะเป็นตัวกำหนดความแตกต่างของขนาดวัตถุที่ได้ ถ้าขนาดของวัตถุนั้นมีความแตกต่างกันมาก ควรต้องกำหนดค่าให้น้อยเพื่อไม่ให้กลุ่มของวัตถุมากขึ้น มิฉะนั้นจะเกิดการปะปนกันของข้อมูล มีผลทำให้ความเป็นเนื้อเดียวกันจะมีค่าที่ต่ำลงไปด้วย

1.2 พารามิเตอร์รูปร่างหรือสี (Shape/Color Parameter) เป็นค่าของขอบเขตรูปร่างของข้อมูลจะแปรผันตามความสัมพันธ์ระหว่างรูปร่างกับสีของข้อมูล จะพิจารณาจากการให้ค่าน้ำหนักของรูปร่างหรือค่าน้ำหนักของสีมากกว่ากัน ถ้ากำหนดค่าสีมากกว่าต้องพิจารณาจากค่าการสะท้อนตามช่วงคลื่นที่เลือก ซึ่งในภาพจากดาวเทียมที่มีค่าของสีแต่ละวัตถุที่ชัดเจน จะส่งผลให้ค่าน้ำหนักของสีมากกว่ารูปร่างในขณะที่รูปร่างจะพิจารณาเพียงรูปร่างหรือรูปทรงของวัตถุที่ปรากฏบนภาพจากดาวเทียม ดังนั้นการกำหนดค่าน้ำหนักของรูปร่างและสีที่ได้รวมกันไม่เกิน 1 (แสดงในภาพ 6)

การให้ค่าน้ำหนักควรจะเน้นไปที่การให้ค่าความน่าจะเป็นของสีมากกว่ารูปร่าง ด้วยเหตุที่ว่าข้อมูลที่อยู่ในจุดภาพเหล่านั้นเป็นข้อมูลเชิงคลื่นซึ่งมีความสำคัญมากในการสร้างวัตถุ แต่ขณะที่รูปร่างเป็นอีกปัจจัยหนึ่งที่นำมาช่วยในการแยกประเภทวัตถุออกจากรูปร่างของวัตถุ

1.3 พารามิเตอร์ความอัดแน่นหรือความเรียบ (Smoothness/Compactness) คือ การกำหนดปัจจัยด้านความเรียบและการเกาะกลุ่มจะใช้กับวัตถุที่มีความแตกต่างของขนาดเพื่อทำการแยกวัตถุขนาดเล็กออกจากวัตถุที่มีขนาดใหญ่ ส่วนค่าการสะท้อนแสงนั้นไม่ชัดเจน ซึ่งเป็นค่าที่ช่วยในการให้รูปทรงของวัตถุ



ภาพ 6 แสดงความสัมพันธ์ของพารามิเตอร์การแบ่งส่วนภาพ (Definiens, 2007)


กระบวนการทำงานของการแบ่งส่วนภาพ มี 3 วิธีการหลัก ได้แก่ 1) การแบ่งส่วนภาพแบบกระดานหมากรุก (Chessboard Segmentation), 2) การแบ่งส่วนภาพแบบควอตรี (Quadtree Segmentation) และ 3) การแบ่งส่วนภาพแบบความละเอียดหลายระดับ (Multiresolution Segmentation)

1) การแบ่งส่วนภาพแบบกระดานหมากรุก (Chessboard Segmentation) เป็นการแบ่ง (Split) จุดภาพหรือวัตถุในภาพเป็นกระดานหมากรุกหรือรูปสี่เหลี่ยมที่มีขนาดเท่ากัน โดยเรียงจากขอบด้านซ้ายบนสุดของภาพไปจนถึงขอบด้านขวาล่างสุดจากนั้นวัตถุแต่ละชั้นจะถูกแบ่งตามเส้นกริด (Grid) ขนาดวัตถุจะถูกกำหนดตามขนาดของตารางกริดในรูปของจุดภาพที่สามารถกำหนดขนาดกระดานหมากรุกได้มากกว่าขนาดของจุดภาพในภาพนั้นๆ แสดงในภาพ 7



ภาพ 7 การแบ่งส่วนภาพแบบกระดานหมากรุก (Chessboard Segmentation) (Definiens, 2007)

2) การแบ่งส่วนภาพแบบควอดทรี (Quadtree Segmentation) เป็นการแบ่งจุดภาพหรือวัตถุในลักษณะตารางรูปสี่เหลี่ยมจัตุรัสหรือควอดทรี ตารางกริดของควอดทรีจะประกอบด้วยสี่เหลี่ยมที่มีสี่ส่วน มีสองลักษณะเกิดจากการเปรียบเทียบค่าความเหมือน โดยเรียงจากขอบด้านซ้ายบนสุดของภาพไปจนถึงขอบด้านขวาล่างสุดจะพิจารณาจากเกณฑ์ความเหมือนที่กำหนด ในการการแบ่งส่วนจะถูกแบ่งภาพเริ่มต้นนั้นออกเป็น 4 ส่วน และทำการทดสอบค่าความเหมือนตามเกณฑ์ที่กำหนด สำหรับส่วนที่ไม่ผ่านเกณฑ์จะถูกแบ่งส่วนต่อไปเรื่อยๆ แสดงในภาพ 8 และ 9




ภาพ 8 แสดงวิธีการแบ่งส่วนภาพแบบควอดทรี (Definiens, 2007)



ภาพ 9 การแบ่งส่วนภาพแบบควอดทรี (Quadtree Segmentation) (Definiens, 2007)

3) การแบ่งส่วนภาพแบบความละเอียดหลายระดับ (Multiresolution Segmentation) เป็นวิธีการรวมจุดภาพที่มีลักษณะใกล้เคียงกันและอยู่ติดกัน เข้าไว้ด้วยกันเป็นกลุ่มจุดภาพหรือวัตถุ โดยสามารถกำหนดค่าพารามิเตอร์ต่างๆ ได้แก่ สี รูปร่าง ความอัดแน่น และความเรียบ ได้ตามต้องการ ข้อดีของวิธีนี้เป็นการแบ่งหรือสร้างวัตถุจะแปรผันตามค่าพารามิเตอร์ที่กำหนดไว้ทำให้ได้ขนาดวัตถุที่มีความแตกต่างกัน และมีขนาดใกล้เคียงกับสภาพที่เป็นจริงมากกว่าวิธีอื่น แสดงในภาพ 10



ภาพ 10 การแบ่งส่วนภาพแบบความละเอียดหลายระดับ (Definiens, 2007)

2. การจำแนกวัตถุภาพ (Object Image Classification)

การจำแนกวัตถุภาพ คือการแบ่งจุดภาพที่มีคุณสมบัติของการสะท้อนแสงที่คล้ายหรือเหมือนกันออกเป็นกลุ่มหรือเป็นระดับ โดยส่วนใหญ่เรียกว่า ชนิดหรือประเภท (Class) เพื่อใช้การแบ่งแยกวัตถุที่แสดงในภาพออกจากกันในการจำแนกวัตถุภาพจะต้องใช้กฎการตัดสินใจหรือความรู้ที่เกี่ยวข้องทางสถิติเข้าช่วย โดยวิธีการทางสถิติมีส่วนช่วยในขั้นตอนการประมวลผล เพื่อใช้สำหรับแยกหรือแบ่งกลุ่มของจุดภาพบริเวณพื้นที่ศึกษาตามลักษณะร่วมทางสถิติที่มีลักษณะเฉพาะร่วมกันของแต่ละกลุ่มที่แสดงถึงวัตถุที่ปกคลุมอยู่บนพื้นที่นั้นๆ และในบางครั้งจะมีการวิเคราะห์ค่าดัชนีผลต่างเข้ามาช่วยในการจัดกลุ่มเช่น การวิเคราะห์ค่าดัชนีผลต่างพืชพรรณ (Normalized Difference Vegetation Index : NDVI) เป็นค่าบอกถึงความแตกต่างของการสะท้อนของพื้นผิวในช่วงคลื่นอินฟราเรดใกล้ (NIR) กับช่วงคลื่นตามองเห็นสีแดง (Red) ทำสัดส่วนกับค่าผลบวกของทั้งสองช่วงคลื่นอยู่ในลักษณะของการกระจายแบบปกติ โดย ค่า NDVI มีค่าอยู่ระหว่าง -1 ถึง 1 ซึ่งค่า 0 หมายถึงบริเวณที่ไม่มีพืชพรรณใบเขียวอยู่ในพื้นที่ในขณะที่ค่ามากกว่า 0.6 จะหมายถึงพื้นที่บริเวณนั้นมีพืชพรรณใบเขียวหนาแน่นมาก เช่น พื้นที่ป่าไม้ ในพื้นที่ดังกล่าวถ้าพื้นผิวมีพืชพรรณปกคลุมการสะท้อนค่าในช่วงคลื่นอินฟราเรดใกล้สูงกว่าช่วงคลื่นตามองเห็นสีแดงทำให้ค่า NDVI เป็นบวกแต่ถ้าพื้นผิวเป็นพื้นดินจะมีค่าการสะท้อนของทั้งสองช่วงคลื่นใกล้เคียงกันทำให้ค่า NDVI ใกล้เคียงกับ 0 แต่ในกรณีที่พื้นผิวเป็นพื้นน้ำจะมีค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้ต่ำกว่าช่วงคลื่นตามองเห็นสีแดงทำให้ค่า NDVI ติดลบ ดังสมการ 5

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (5)$$

เมื่อ	NDVI	คือ ค่าดัชนีผลต่างพืชพรรณ
	NIR	คือ ค่าการสะท้อนช่วงคลื่นอินฟราเรดใกล้
	RED	คือ ค่าการสะท้อนช่วงคลื่นตามองเห็นสีแดง

ส่วนการวิเคราะห์ค่าดัชนีผลต่างความชื้นของน้ำ (Normalized Difference Water Index : NDWI) เป็นค่าที่บอกถึงพื้นที่ที่มีน้ำปกคลุมผิวดิน โดยมาจากปริมาณรังสีของดวงอาทิตย์ที่สะท้อนมาจากดินหรือพืชพรรณในช่วงคลื่นอินฟราเรดใกล้ (NIR) และช่วงคลื่นที่ตามองเห็นสีเขียว (Green) ถ้าเกิดพื้นที่ที่มีปริมาณน้ำมากจะทำให้รังสีในช่วงคลื่น Green ถูกดูดซับมากและมีการสะท้อนรังสีออกมา น้อยลงมีผลให้ค่าดัชนี NDWI มีค่าที่สูงขึ้น (McFeeters, 1996) ดังสมการ 6

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (6)$$

เมื่อ	NDWI	คือ ค่าดัชนีผลต่างความชื้นของน้ำ
	GREEN	คือ ค่าการสะท้อนช่วงคลื่นตามองเห็นสีเขียว
	NIR	คือ ค่าการสะท้อนช่วงคลื่นอินฟราเรดใกล้

และการวิเคราะห์ค่าดัชนีผลต่างสิ่งปลูกสร้าง (Normalized Difference Built-up Index: NDBI) เป็นค่าดัชนีที่ศึกษาความสัมพันธ์ระหว่างอุณหภูมิพื้นผิวในเมืองรวมถึงประเภทการใช้ที่ดินและสิ่งปกคลุมดินโดยการวิเคราะห์ข้อมูลจากการตรวจจับดาวเทียมที่ดูค่าการสะท้อนคลื่นของความหนาแน่นของวัตถุสิ่งปลูกสร้างทั้งช่วงกลางวันและช่วงกลางคืนกับอุณหภูมิของแต่แต่ละช่วงเวลา (Douset & Gourmelon, 2003) ดังสมการ 7

$$NDBI = \frac{SWIR - NIR}{SWIR + NIR} \quad (7)$$

เมื่อ	NDBI	คือ ค่าดัชนีผลต่างสิ่งปลูกสร้าง
	NIR	คือ ค่าการสะท้อนช่วงคลื่นอินฟราเรดใกล้
	SWIR	คือ ค่าการสะท้อนช่วงคลื่นอินฟราเรดคลื่นสั้น

ออนโทโลยี

ออนโทโลยี (Ontology) เป็นแนวคิดที่นำมาประยุกต์ใช้เพื่อการจัดความรู้และนำเสนอความรู้ในรูปแบบที่อาศัยกลุ่มแนวคิดและความสัมพันธ์ระหว่างกันอยู่ภายใต้ขอบเขตที่สนใจ ออนโทโลยีถูกกล่าวถึงในสาขาปัญญาประดิษฐ์นั้นมีการใช้งานมานานแล้ว โดยในปัจจุบันได้ถูกนำมาใช้ในมาตรฐานของการออกแบบจำลองโครงสร้างของภาษาเอ็กซ์เทนซิเบิล (eXtensible Markup Language : XML) ซึ่งเป็นภาษาที่เป็นมาตรฐาน และถูกรับรองโดยองค์กร W3C ที่ใช้รูปแบบและไวยากรณ์ตามแบบภาษารัฐิเฟอ (Resource Description Framework : RDF Language) โดยที่ภาษารัฐิเฟอถูกสร้างเพื่อใช้สำหรับรองรับการทำออนโทโลยีรวมถึงใช้เป็นมาตรฐานของการทำเว็บเชิงความหมาย (Semantic Web) และการสร้างออนโทโลยีนั้นจะต้องอาศัยภาษาเว็บออนโทโลยี (Ontology Web Language: OWL) เพื่อสำหรับอธิบายโครงสร้างของความรู้อีกด้วย (Antoniou & Van Harmelen, 2003; Noy & McGuinness, 2001; ธีรวิษณุ วงษา และรัฐสิทธิ์ สุขะหุต, 2557)

ออนโทโลยีเข้ามามีบทบาทสำคัญสำหรับการบรรยายเชิงความหมายในลักษณะของการใช้แนวคิดเดี่ยวเพื่อลดหรือตัดทอนแนวคิดหรือลดคำศัพท์ที่มีความสับสนรวมถึงการสนับสนุนการแลกเปลี่ยน การค้นคืนของสารสนเทศต่อการพัฒนาระบบฐานความรู้ (Noy & McGuinness, 2001) และยังเป็นกำหนดยานิยามของแนวคิด (Concept) ในขอบเขตของความรู้เรื่องใดเรื่องหนึ่งที่สนใจ (Domain of Interest) ถูกกำหนดด้วยคุณสมบัติ (Property) ที่เกี่ยวข้องกับแนวคิดและลักษณะความสัมพันธ์ (Relationship) ตรีภาคในการเปลี่ยนแปลงความสัมพันธ์สำหรับสร้างความหมาย เช่น ลักษณะของความสัมพันธ์ที่มีความถูกต้องซึ่งจะเกี่ยวข้องหรือไม่เกี่ยวข้องของแนวคิดก็ได้ แม้กระทั่งความสัมพันธ์ระหว่างแนวคิดกับคุณสมบัติของขอบเขตที่สนใจ โดยสร้างเป็นองค์ความรู้ที่เกี่ยวข้องกับด้านเหล่านั้น และจะแสดงในลักษณะโครงสร้างของความสัมพันธ์ผ่านการใช้คลาส (Class) หรือแนวคิด ของความสัมพันธ์ระหว่างคลาสและคุณสมบัติของคลาส (มาลี กาบมาลา และคณะ, 2549)

1. โครงสร้างออนโทโลยี

โครงสร้างของออนโทโลยีจะอยู่ในรูปแบบมีลำดับชั้น (Hierarchical Data Structure) และแบบแทกโซโนมี (Taxonomy) ในลักษณะ Parent-child จึงทำให้โครงสร้างของออนโทโลยีจะประกอบด้วยกำหนดยานิยามความหมายผ่านทางแนวคิด (Concept) คุณสมบัติ (Property) ความสัมพันธ์ (Relationship) ตรีภาคการแปลความสัมพันธ์ (Axioms) และคำศัพท์ (Instances) (Benjamins & Gómez-Pérez, 2000)

1.1 แนวคิด (Concept) คือขอบเขตความรู้เรื่องใดเรื่องหนึ่งที่สนใจสามารถเป็นอะไรก็ได้แต่ต้องเกี่ยวข้องกับเรื่องที่กำลังกล่าวถึงหรือสามารถอธิบายรายละเอียดของเรื่องนั้นได้

1.2 คุณสมบัติ (Property) เป็นคุณสมบัติที่มีความสัมพันธ์หรือเกี่ยวข้องกับแนวคิดที่สามารถอธิบายแนวคิดนั้นได้

1.3 ความสัมพันธ์ (Relationship) เป็นลักษณะของการนำเสนอการปฏิสัมพันธ์ (Interaction) ของแนวคิดกับแนวคิดในขอบเขตความรู้ของเรื่องที่กำลังสนใจรวมถึงมีการกำหนดแบบแผนความสัมพันธ์ โดยมีลักษณะของความสัมพันธ์ในหลายรูปแบบดังนี้

1) ความสัมพันธ์แบบลำดับชั้น (Subclass หรือ is-a hierarchy) เป็นความสัมพันธ์ที่มีคุณสมบัติของการถ่ายทอด คุณสมบัติเหล่านี้จะถูกสืบทอดจากแนวคิดแม่ไปยังแนวคิดลูก เช่น Chemistry is-a Science อธิบายได้ว่า เคมี (Chemistry) เป็นสาขาของวิทยาศาสตร์ (Science)

2) ความสัมพันธ์แบบเป็นส่วนหนึ่ง (Part-of) เป็นความสัมพันธ์ที่เป็นส่วนประกอบ เช่น Leaves part-of Tree อธิบายได้ว่า ใบไม้ (Leaves) เป็นส่วนหนึ่งของต้นไม้ (Tree)

3) ความสัมพันธ์เชิงความหมาย (Syn-of) เป็นความสัมพันธ์ที่แสดงถึงแนวคิดที่มีความเหมือนเชิงความหมายต่อกัน เช่น Degree syn-of Education อธิบายได้ว่า ระดับการศึกษา (Degree) มีความหมายเดียวกับการศึกษา (Education) สามารถแทนกันได้

4) ความสัมพันธ์การเป็นตัวแทน (Instance-of) เป็นความสัมพันธ์ที่แสดงว่าเป็นตัวแทนหรือสมาชิกของแนวคิด

5) นอกจากนี้ออนโทโลยียังประกอบไปด้วยความสัมพันธ์เชิงความหมายในรูปแบบอื่นที่สอดคล้องกับแนวคิด แต่แนวคิดจะถูกกำหนดโดยผู้เชี่ยวชาญ

1.4 ตรรกะการแปลความสัมพันธ์ (Axioms) เป็นตรรกะของการแปลความสัมพันธ์ของแนวคิดกับคุณสมบัติหรือแนวคิดกับแนวคิดหรือการตรวจสอบคุณสมบัติของคุณสมบัติสำหรับการแปลความหมายที่ถูกต้อง

1.5 คำศัพท์ (Instances) เป็นตัวกำหนดนิยามความหมายร่วมกันทั้งหมดในออนโทโลยี

2. การพัฒนาออนโทโลยี

การพัฒนาออนโทโลยีเป็นสิ่งที่ต้องทำตลอดเวลาเนื่องจากจะต้องมีการเปลี่ยนแปลงตลอดเวลาตามพัฒนาการของความรู้หรือองค์ความรู้เหล่านั้นในแต่ละสาขาวิชา เพราะฉะนั้นการกำหนดแนวคิดและความสัมพันธ์ให้กับแนวคิดในออนโทโลยีจะต้องมีความสอดคล้องกับสิ่งที่จะศึกษาให้มากที่สุดเนื่องจากความเหมาะสมของการพัฒนาออนโทโลยีเกี่ยวข้องกับวัตถุประสงค์จากการนำเอาออนโทโลยีไปใช้งาน โดย Noy and McGuinness (2001) ได้นำเสนอการพัฒนาออนโทโลยีดังต่อไปนี้

2.1 กำหนดขอบเขตความรู้และขอบเขตของออนโทโลยี

2.2 พิจารณาออนโทโลยีที่มีอยู่แล้วและนำกลับมาใช้หรือปรับใช้หรือทำการขยายเพิ่ม

2.3 กำหนดรายการคำศัพท์ รวบรวมรายการสำคัญที่อยากจะให้มีในออนโทโลยีเพื่อใช้สร้างคำอธิบายคุณสมบัติให้กับคำศัพท์

2.4 กำหนดคลาสหรือแนวคิดและลำดับชั้นของคลาส โดยกระบวนการพัฒนาจะแบ่งออกเป็น 3 รูปแบบ

1) แบบบนลงล่าง (Top-Down) เป็นการกำหนดแนวคิดแบบกว้างลงไปหาแนวคิดแบบเฉพาะเจาะจง เริ่มจากการสร้างคลาสสำหรับแนวคิดทั่วไปและทำการกำหนดคลาสแบบเฉพาะเจาะจง โดยการสร้างคลาทย่อย

2) แบบล่างขึ้นบน (Bottom-Up) เป็นการกำหนดแนวคิดแบบเฉพาะเจาะจงขึ้นไปหาแนวคิดแบบกว้างหรือแนวคิดทั่วไป และทำการจัดกลุ่มคลาสของแนวคิดทั่วไป

3) แบบเชื่อมโยง (Combination) เป็นวิธีการนำทั้ง 2 แบบมาผสมกัน คือ แบบบนลงล่าง และแบบล่างขึ้นบนเป็นการกำหนดแนวคิดที่สำคัญหรือมีการอธิบายในการกำหนดขอบเขตความรู้นั้นๆ ก่อนหลังจากนั้นทำการกำหนดแนวคิดอื่นที่เกี่ยวข้องเพื่อพิจารณาความหมายในเชิงทั่วไปและเฉพาะเจาะจงจากคำสำคัญไปพร้อมกัน

2.5 การกำหนดคุณสมบัติของคลาส

2.6 การกำหนดชุดของคุณสมบัติ โดยพิจารณาจากคุณลักษณะต่างๆ เช่น การกำหนดจำนวนค่า ชนิดของค่า และค่าที่เป็นไปได้ของคุณสมบัติในคลาสนั้นๆ

2.7 สร้างคำศัพท์ ถือเป็นขั้นตอนสุดท้ายซึ่งการสร้างคำศัพท์ในแต่ละคลาส

3. เครื่องมือการพัฒนาออนโทโลยี

ในปัจจุบันพบว่าเครื่องมือที่ใช้สำหรับพัฒนาออนโทโลยีมีความหลากหลายและแตกต่างกันของแต่ละโปรแกรมรวมทั้งมีข้อดีข้อเสียที่แตกต่างกัน (Norta et al., 2010) แต่ทั้งนี้ขึ้นอยู่กับความเหมาะสมกับการใช้งาน โดยโปรแกรมที่เป็นเครื่องมือพัฒนาออนโทโลยี (Ontology Editor) ที่นิยมใช้กันในปัจจุบันเช่น โปรแกรม Protégé พัฒนาขึ้นที่มหาวิทยาลัยสแตนฟอร์ด (Stanford University) ตัวโปรแกรมมีส่วนติดต่อกับผู้ใช้งานที่เป็นลักษณะกราฟิก สามารถสร้างไฟล์ในหลายรูปแบบ เช่น OWL, XML และ RDF เป็นต้น (Noy & McGuinness, 2001) และโปรแกรม Hozo-Ontology Editor พัฒนาขึ้นที่มหาวิทยาลัยโอซากา (Osaka University) ซึ่งสามารถทำการจัดเก็บองค์ความรู้ในรูปแบบของออนโทโลยีได้อย่างสะดวก (Kozaki et al., 2005) ซึ่งทั้งสองโปรแกรมที่กล่าวมานี้เป็นโปรแกรมแบบรหัสเปิด (Open Source) ซึ่งไม่เสียค่าใช้จ่ายในการนำมาประยุกต์ใช้

สำหรับงานวิจัยนี้เลือกใช้โปรแกรม Protégé มาใช้สำหรับพัฒนาออนโทโลยีด้วยเหตุผลที่ว่าตัวโปรแกรมมีส่วนติดต่อกับผู้ใช้ในรูปแบบกราฟิกที่เข้าใจง่าย ใช้หลักการสร้างโดเมนและฐานความรู้ (Knowledge-Based) ในรูปแบบออนโทโลยี แสดงความสัมพันธ์แบบลำดับชั้นด้วย is-a รวมทั้งสามารถจัดเก็บไฟล์ได้หลายรูปแบบ เช่น RDF, OWL และ XML และสามารถติดตั้งชุดคำสั่งเพิ่มเติมได้ โดยการกำหนดคุณลักษณะของข้อมูลโดยใช้โปรแกรม Protégé มาออกแบบและจัดเก็บข้อมูลออนโทโลยีหลังจากได้สกัดข้อมูลจากดาวเทียมเป็นที่แล้วเรียบร้อยแล้วและจัดเก็บในรูปแบบไฟล์ OWL

การนำโปรแกรม Protégé มาใช้เป็นเครื่องมือพัฒนาออนโทโลยีมีมากมายเช่น ระบบสืบค้นหาสถานที่ท่องเที่ยวในประเทศไทยนำ Protégé มาใช้พัฒนาโครงสร้างออนโทโลยีเพื่อแสดงผลข้อมูลบนออนไลน์ที่แตกต่างต่างกันไปแต่เนื้อหาเดียวกันและสามารถเชื่อมโยงความสัมพันธ์ของข้อมูลการท่องเที่ยวต่างๆ เข้าไว้ด้วยกัน (นฤพนธ์ พนาวงศ์ และจักรกรฤกษ์ เสน่ห์, 2010) ส่วนการพัฒนาออนโทโลยีเชิงสุขภาพในประเทศไทยนำ Protégé มาใช้ออกแบบและสร้างออนโทโลยีเพื่อใช้พัฒนาระบบสืบค้นสารสนเทศ (Chansiriwat & Polsawat, 2018)เช่นเดียวกับระบบเฝ้าระวังและวางแผนสุขภาพ

สำหรับผู้สูงอายุด้วยหลักการออนโทโลยีโดยใช้ Protégé มาเป็นเครื่องมือสร้างออนโทโลยีที่สามารถเชื่อมโยงอย่างมีความสัมพันธ์ต่อกันและผสมผสานกับทฤษฎีระบบผู้เชี่ยวชาญมาใช้ในการวางแผนสุขภาพสำหรับผู้สูงอายุเพื่อให้เกิดความถูกต้องแม่นยำและเหมาะสมกับความต้องการของผู้ใช้ (Sivilai & Snae, 2013)

นอกจากนี้พบว่ามีการนำออนโทโลยีมาประยุกต์ใช้สำหรับจำแนกข้อมูลภาพถ่ายดาวเทียม เนื่องจากออนโทโลยีสามารถเป็นตัวแทนและจัดเก็บองค์ประกอบของข้อมูลภาพถ่ายดาวเทียม เป็นสะพานสำหรับช่องว่างความหมาย (Semantic Gap) รวมถึงเพิ่มประสิทธิภาพของระบบการจำแนกแบบเดิมให้สามารถจำแนกได้มากขึ้นและช่วยให้ผู้ใช้เข้าใจถึงผลลัพธ์ที่ได้จากระบบการจำแนกสามารถนำไปประยุกต์ใช้กับระบบสารสนเทศทางภูมิศาสตร์ได้

งานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมเพื่อวิเคราะห์การใช้ที่ดิน

การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมเพื่อวิเคราะห์การใช้ที่ดินโดยส่วนใหญ่จะนำไปประยุกต์ใช้กับการทำแผนที่การใช้ที่ดินเนื่องจากในปัจจุบันพบว่าการเปลี่ยนแปลงด้านเศรษฐกิจและสังคม เป็นสาเหตุที่ทำให้เกิดความเจริญทางด้านเมืองได้รุกล้ำเข้าสู่พื้นที่เกษตรกรรม ป่าไม้และวิถีชีวิตของชุมชนชนบทดังนั้นแผนที่จึงใช้เป็นตัวบอกให้เห็นถึงการเปลี่ยนแปลงการใช้ที่ดินในพื้นที่นั้นๆ ได้อย่างรวดเร็วและทันกับสถานการณ์ ตัวอย่างเช่น Pattanasak (2020) การทำแผนที่การใช้ประโยชน์ที่ดินด้วยการจำแนกข้อมูลเชิงวัตถุจากข้อมูลภาพถ่ายดาวเทียมไทยโชต แสดงให้เห็นว่าการทำแผนที่ที่มีความสำคัญเป็นอย่างยิ่งที่จะเป็นตัวบอกให้เห็นถึงการเปลี่ยนแปลงพื้นที่ซึ่งการทำแผนที่การใช้ที่ดินในปัจจุบัน มีข้อจำกัดด้านงบประมาณ และการทำแผนที่ให้ถูกต้องนั้นต้องอาศัยความชำนาญของผู้เชี่ยวชาญในการแปลภาพ สุดท้ายผลประเมินความถูกต้องโดยใช้การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมให้ค่าความถูกต้องที่มากกว่าวิธีการอื่น ซึ่งสอดคล้องกับ วิลาวณิชย์ ประสมทรัพย์ (2564) ได้ทำแผนที่การใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินด้วยการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม Sentinel-2A ถูกนำมาใช้การจำแนกการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินบริเวณอำเภอครบุรี จังหวัดนครราชสีมา ผลการศึกษาพบว่าวิธีการที่เหมาะสมสำหรับการจำแนกการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินคือ วิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม และยังมีวิธีการที่ใช้ในการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมกับลักษณะข้อมูลภาพถ่ายดาวเทียมประเภทอื่น เช่น ทบทอง ชื่นเจริญ และวิระ ศรีมาลา (2560) ใช้วิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกับการประมวลผลภาพถ่ายเชิงเลขมาใช้ติดตามการเปลี่ยนแปลงชายฝั่งในหมู่บ้านคลองทก ต.เกาะเปริด อ.แหลมสิงห์ จ.จันทบุรี ระหว่างปี พ.ศ. 2533 และ พ.ศ. 2547 โดยใช้ข้อมูลภาพถ่ายดาวเทียม Landsat เป็นการใช่วิธีการจำแนกแบบความน่าจะเป็นสูงสุดและวิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม ร่วมกับเทคนิคการตรวจสอบการเปลี่ยนแปลงจากผลการจำแนกข้อมูลใน 2 ช่วงเวลา เพื่อประเมินความเหมาะสมของการเลือกใช้

วิธีการจำแนกข้อมูล และเพื่อถ่ายทอดเทคโนโลยีการรับรู้จากระยะไกล รวมทั้งนำผลการศึกษาปัญหา การเปลี่ยนแปลงชายฝั่งที่ได้รับไปใช้ในการวางแผนการจัดการ การอนุรักษ์ การฟื้นฟูทรัพยากรชายฝั่ง ที่มีอยู่อย่างจำกัดให้คงอยู่ ผลการศึกษาพบว่าการใช้วิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ร่วมกับวิธีการ อื่นสามารถช่วยในการจำแนกประเภทการใช้ที่ดินได้เช่นเดียวกัน ส่วน Sujaree et al. (2021) ได้ใช้ ข้อมูลภาพถ่ายดาวเทียมแบบพาสซีฟ (Passive) และแบบแอคทีฟ (Active) เพื่อวางแผนและจัดการ เกี่ยวกับการใช้ประโยชน์ที่ดินในพื้นที่เมืองขอนแก่นด้วยการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ผลการศึกษา ชี้ให้เห็นว่าวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุสามารถช่วยเพิ่มความถูกต้องโดยรวมของการจำแนกได้ นอกจากนี้การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุเพื่อวิเคราะห์การใช้ที่ดินสำหรับการทำแผนที่ การเปลี่ยนแปลงพื้นที่ต่างๆ รวมถึงการใช้ข้อมูลภาพถ่ายดาวเทียมที่หลากหลายรูปแบบ การวิเคราะห์ วิเคราะห์ข้อมูลภาพเชิงวัตถุยังสามารถนำมาศึกษาด้านอื่นๆ เช่น ธนวุฒิ ทองมี และคณะ (2562) ได้ ทำการศึกษาการประเมินการกักเก็บคาร์บอนเหนือพื้นดินของพื้นที่ป่าในมหาวิทยาลัยมหาสารคาม ด้วยข้อมูลภาพถ่ายดาวเทียม Sentinel-2 กับภาพถ่ายจากอากาศยานไร้คนขับ และประเมินการกัก เก็บคาร์บอนด้วยการวิเคราะห์ข้อมูลภาพเชิงวัตถุนำมาใช้ในการจำแนกพื้นที่ป่าและเปรียบเทียบค่า ความถูกต้องโดยรวมของจากข้อมูลทั้งสอง ผลปรากฏว่าข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ให้ค่า ความถูกต้องโดยภาพรวมดีกว่าข้อมูลภาพถ่ายจากอากาศยานไร้คนขับ และอัมพิกา ชุมมัตยา และ ญวิทย์ อ่องแสงชัย (2562) ใช้วิธีการวิเคราะห์ภาพเชิงวัตถุสำหรับการศึกษาเพื่อศึกษารูปแบบ สันฐาน และปัจจัยที่เกี่ยวข้องกับการขยายตัวของเมืองเชียงใหม่ จากข้อมูลภาพถ่ายดาวเทียม Landsat 5 และ Landsat 8 ตั้งแต่ปี พ.ศ. 2543-2558 แสดงให้เห็นถึงการขยายตัวของเมือง เชียงใหม่ได้อย่างชัดเจนผลจากการศึกษาพบว่าวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุสามารถจำแนกการใช้ ที่ดินเพื่อแสดงการขยายตัวของเมืองได้

การศึกษางานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุเพื่อวิเคราะห์ การใช้ที่ดินพบว่าวิธีการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุโดยส่วนใหญ่นิยมใช้ในการทำแผนที่ การใช้ที่ดินเนื่องจากสามารถชี้ให้เห็นถึงการเปลี่ยนแปลงได้อย่างรวดเร็ว และทันต่อสถานการณ์ ปัจจุบัน ไม่ว่าจะเป็นพื้นที่ชายฝั่ง พื้นที่ป่าไม้ หรือแม้แต่การขยายตัวของเมือง ส่วนข้อมูลภาพถ่าย ดาวเทียมที่สามารถนำมาใช้ในวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุมีอยู่ 2 รูปแบบคือ ข้อมูลภาพ ดาวเทียมแบบพาสซีฟ และแบบแอคทีฟ โดยส่วนมากจะนิยมใช้ข้อมูลภาพถ่ายดาวเทียมแบบพาสซีฟ เช่น ดาวเทียมไทยโชติ ดาวเทียม Landsat และดาวเทียม Sentinel-2 เป็นต้น และนอกจากนี้วิธีการ วิเคราะห์ข้อมูลภาพเชิงวัตถุยังสามารถนำมาใช้ร่วมกับวิธีอื่นได้ด้วยเช่นกัน

งานวิจัยที่เกี่ยวกับการประยุกต์ใช้ออนโทโลยีกับการจำแนกข้อมูลภาพถ่ายดาวเทียม

ออนโทโลยีเป็นเทคโนโลยีเป็นเทคโนโลยีที่เกิดจากแนวความคิดที่กำหนดความหมายแบบเป็นทางการของคำศัพท์พร้อมทั้งประกาศคุณลักษณะที่ชัดเจนเพื่อนำมาใช้ในการอธิบายความเป็นตัวแทนของแนวคิดหรือแบบจำลองของกลุ่มชุมชนสารสนเทศที่ใช้ร่วมกันซึ่งโครงสร้างความสัมพันธ์ดังกล่าวที่เครื่องคอมพิวเตอร์สามารถสามารถเข้าใจและแปลความได้ และสามารถนำมาประยุกต์ใช้กับการจำแนกข้อมูลภาพถ่ายดาวเทียม ดังนี้

- Almendros-Jimenez et al. (2012) ประยุกต์ใช้ออนโทโลยีสำหรับการจำแนกภาพถ่ายดาวเทียมในมหาสมุทร แสดงวิธีการใช้ออนโทโลยีเพื่อเป็นตัวแทนและจัดเก็บองค์ประกอบของภาพถ่ายดาวเทียม คุณลักษณะข้อมูลทางภูมิศาสตร์และจำแนกประเภทด้วยกฎ SWRL และโครงสร้างแผนผังการตัดสินใจรวมถึงการพัฒนาปลั๊กอิน Protégé สำหรับจัดประเภทรูปภาพ และกรอบการทำงานที่นำเสนอกลไกในการแบ่งปันข้อมูลการจัดประเภทรูปภาพระหว่างแอปพลิเคชันต่างๆ
- Andres et al. (2012) เสนอวิธีการใช้ออนโทโลยีเพื่อเชื่อมโยงความรู้ของผู้เชี่ยวชาญเข้ากับข้อมูลภาพจากการสำรวจระยะไกล ทำให้สามารถจำแนกประเภทได้ดีขึ้น ออนโทโลยีของรูปภาพถูกสร้างขึ้นเพื่อกำหนดส่วนของรูปภาพตามลักษณะของสเปกตรัม (Spectral) และลักษณะพื้นผิว (Textural) ความรู้ทางออนโทโลยีจากการรับรู้จากระยะไกลได้สร้างขึ้นเพื่ออธิบายวิธีการที่ผู้เชี่ยวชาญใช้ในการระบุประเภทสิ่งปกคลุมดินในภาพถ่ายดาวเทียม วิธีการนี้จำแนกประเภทออกเป็น 3 ประเภท ได้แก่ พืชพรรณ สิ่งปลูกสร้างหรือเหมือง และน้ำ ผลลัพธ์ที่ได้แสดงให้เห็นว่าแนวทางนี้สามารถนำมาใช้ในการจำแนกประเภทการใช้ที่ดินจากข้อมูลภาพถ่ายดาวเทียมแบบอัตโนมัติได้
- Messaoudi et al. (2014) เสนอวิธีการทางออนโทโลยีสำหรับคำอธิบายประกอบและการตีความภาพจากการสำรวจระยะไกล fuzzy spatio-spectro-temporal ontology นำเสนอนั้นคำนึงถึงความไม่สมบูรณ์ของข้อมูลเชิงพื้นที่ ความชั่วคราวของวัตถุในธรรมชาติ และความจำเพาะของภาพจากการสำรวจระยะไกล
- Bouyerbou et al. (2014) นำเสนอวิธีการปรับปรุงการจำแนกแผนที่ความเสียหายที่เกิดจากภาพถ่ายดาวเทียมระหว่างเหตุการณ์ภัยพิบัติ วิธีการนี้ใช้วิธีการจำแนกลำดับชั้นเชิงความหมายตามออนโทโลยีเพื่อเชื่อมช่องว่างทางความหมายระหว่างผลลัพธ์ของเทคนิคการจำแนกประเภทอัตโนมัติและความหมายระดับสูงโดยใช้ออนโทโลยีที่มนุษย์กำหนด พื้นที่ศึกษาสำหรับงานนี้คือแผ่นดินไหวที่ประเทศเฮติในปี 2010 และทำการทดลองโดยใช้ภาพถ่ายดาวเทียม QuickBird แบบหลายช่วงเวลา ผลลัพธ์แสดงให้เห็นถึงศักยภาพของวิธีการทางออนโทโลยี และจำเป็นต้องมีการทดลองเพิ่มเติมเพื่อปรับปรุงความแม่นยำในการจำแนกประเภท

- Chu et al. (2016) อธิบายถึงวิธีการใหม่สำหรับการจำแนกภาพการรับรู้จากระยะไกล ซึ่งใช้ความรู้เฉพาะของข้อมูลเชิงพื้นที่จากหลายแหล่งเพื่อสร้างแบบจำลองเครือข่ายความหมายทางออนโทโลยีเชิงภูมิศาสตร์ ผลการทดลองแสดงให้เห็นว่าวิธีนี้มีประสิทธิภาพดีกว่าอัลกอริทึมการจำแนกประเภทแบบดั้งเดิมในด้านความแม่นยำในการจำแนกประเภท โดยเฉพาะอย่างยิ่งในการจำแนกประเภทอาคาร วิธีการนี้พิจารณาถึงข้อได้เปรียบของข้อมูลเชิงพื้นที่จากหลายแหล่ง และตระหนักถึงการบูรณาการความรู้ของข้อมูลเชิงพื้นที่จากหลายแหล่ง และการประยุกต์ใช้ความรู้ในด้านการจัดประเภทสิ่งคลุมดินจากการสำรวจระยะไกล

- Gu et al. (2016) เสนอวิธีการสำหรับการจำแนกเชิงความหมายเชิงวัตถุของภาพถ่ายดาวเทียมความละเอียดสูงโดยใช้ออนโทโลยี วิธีการนี้มีจุดมุ่งหมายเพื่อใช้ประโยชน์จากข้อได้เปรียบของออนโทโลยีกับการวิเคราะห์รูปภาพตามวัตถุทางภูมิศาสตร์ (Geographic Object-Based Image Analysis: GEOBIA) และให้การแสดงออกอย่างเป็นทางการและการสร้างแบบจำลองวัตถุประสงค์ของกระบวนการทั้งหมดของ GEOBIA

- Luo et al. (2016) อธิบายว่าสามารถใช้ภาพถ่ายดาวเทียมความละเอียดสูงเพื่อตรวจสอบสิ่งปกคลุมดินได้ แต่การดึงข้อมูลจากภาพเหล่านี้อาจทำได้ยากและใช้เวลานาน จึงเสนอกรอบการทำงานที่ใช้ออนโทโลยีเพื่อดึงข้อมูลสิ่งปกคลุมดินออกจากภาพถ่ายดาวเทียมโดยอัตโนมัติ กรอบนี้ได้ทำการทดสอบกับภาพของเขตหนึ่งในประเทศจีน และผลลัพธ์ที่ได้อยู่ในระดับที่ดี

- Rajbhandari et al. (2019) นำเสนอวิธีการในการวิเคราะห์ข้อมูลภาพเชิงวัตถุ (OBIA) ซึ่งใช้วิธีการที่ขับเคลื่อนด้วยออนโทโลยีเพื่อระบุวัตถุที่มีความหมาย และมุ่งเน้นไปที่การใช้เซ็นเซอร์หลายตัวเพื่อแยกคุณสมบัติสำหรับการจำแนกประเภท และนำเสนอกรณีศึกษาเกี่ยวกับการทำแผนที่ประเภทป่าในแทสมเนีย ประเทศออสเตรเลีย ซึ่งใช้ข้อมูลภาพถ่ายจากดาวเทียม LiDAR ผสมกับข้อมูลการตีความภาพถ่ายดาวเทียมโดยผู้เชี่ยวชาญเพื่อการแยกประเภทและจำแนกคุณลักษณะ ผลลัพธ์แสดงให้เห็นว่าการใช้คุณสมบัติสเปกตรัมและ LiDAR ส่งผลให้ความแม่นยำในการจำแนกประเภทดีขึ้น

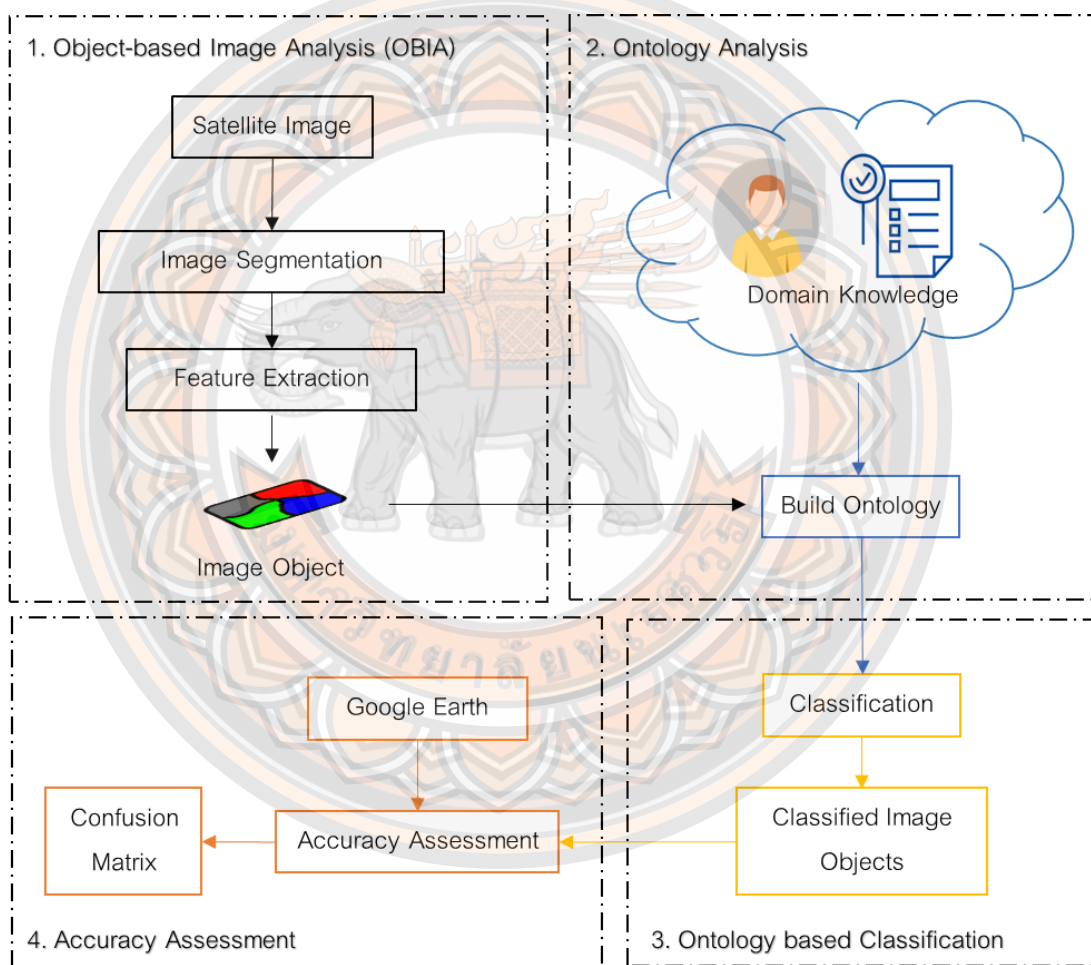
การประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีเพื่อการวิเคราะห์การใช้ที่ดินพบว่าออนโทโลยีเป็นเทคนิคอย่างหนึ่งที่สำคัญสำหรับการนำมาช่วยในการแปลตีความข้อมูลภาพถ่ายดาวเทียมและสามารถนำมาพัฒนาเพื่อใช้สำหรับการจำแนกข้อมูลภาพถ่ายดาวเทียมได้ เช่น การจำแนกประเภททางสมุทรศาสตร์ การจำแนกประเภทพื้นที่ภัยพิบัติ การหาความเปลี่ยนแปลงในพื้นที่เมือง เป็นต้น เนื่องจากออนโทโลยีสามารถเป็นตัวแทนและจัดเก็บองค์ประกอบของข้อมูลภาพถ่ายดาวเทียม เช่น คุณลักษณะของดาวเทียม ตัวรับสัญญาณ ช่วงคลื่น รวมถึงคุณลักษณะระดับต่ำ (Low-level Features) ที่ได้จากวัตถุไปสู่การอนุมานเพื่ออ้างถึงคุณลักษณะระดับสูง (High-level

Features) ที่ได้จากองค์ความรู้ของผู้เชี่ยวชาญ เพื่อนำมาสร้างโครงสร้างออนโทโลยี โดยส่วนใหญ่ในการจำแนกข้อมูลภาพถ่ายดาวเทียมด้วยออนโทโลยีจะมีกระบวนการทำงานแบ่งออกเป็น 2 ส่วน คือส่วนของการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม และการออกแบบโครงสร้างรวมถึงการพัฒนาออนโทโลยี ดังนั้นในส่วนของการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมจากงานวิจัยที่ผ่านมาพบว่าจะจะเป็นลักษณะของการนำข้อมูลภาพที่มีความละเอียดเชิงพื้นที่สูงมาใช้ในการวิเคราะห์เนื่องจากลักษณะของข้อมูลภาพถ่ายดาวเทียมเหล่านี้จะต้องใช้วิธีการวิเคราะห์ภาพเชิงวัตถุเท่านั้นเนื่องจากภาพมีความละเอียดสูงถ้าใช้วิธีการวิเคราะห์เชิงจุดภาพจะทำให้เกิดการปะปนกันของข้อมูลสูงส่งผลต่อการวิเคราะห์ แต่การใช้ข้อมูลภาพถ่ายดาวเทียมความละเอียดสูงจะแลกมาด้วยค่าใช้จ่ายหรือใช้งบประมาณสูง การประมวลผลจะต้องใช้ทรัพยากรของเครื่องที่มีประสิทธิภาพสูง การครอบคลุมพื้นที่ศึกษาต่อหนึ่งภาพได้ในขอบเขตที่จำกัด และส่วนของการวิเคราะห์โครงสร้างหรือการพัฒนาออนโทโลยีพบว่าสิ่งที่สำคัญประการหนึ่งคือการกำหนดโดเมนความรู้ที่ได้จากผู้เชี่ยวชาญหรือข้อมูลที่เกี่ยวข้องเนื่องจากข้อมูลเหล่านี้สามารถเป็นองค์ความรู้ที่ทำให้ออนโทโลยีสร้างความสัมพันธ์กับองค์ประกอบที่เกี่ยวข้องได้

ส่วนงานวิจัยในครั้งนี้นำเสนอการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกันออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลกแบ่งกระบวนการทำงานเป็น 4 ส่วนหลัก คือส่วนที่ 1 การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม ส่วนที่ 2 การวิเคราะห์ออนโทโลยี ส่วนที่ 3 การจำแนกประเภทด้วยออนโทโลยี และส่วนที่ 4 การตรวจสอบความถูกต้อง ในแต่ละส่วนจะใช้ข้อมูลภาพถ่ายดาวเทียม Landsat 8 วันที่ 26 ตุลาคม 2558 และ วันที่ 10 ธันวาคม 2563 เขตพื้นที่ศึกษาอำเภอเมือง จังหวัดพิษณุโลก ข้อมูลภาพจากดาวเทียม Landsat 8 เป็นข้อมูลภาพความละเอียดเชิงพื้นที่ระดับกลาง เป็นข้อมูลแบบเปิด (Open Data) สามารถเข้าถึงข้อมูลโดยไม่มีค่าใช้จ่ายเข้าถึงข้อมูลได้จากเว็บไซต์ของสำนักงานสำรวจทางธรณีวิทยาแห่งสหรัฐฯ (USGS) รวมถึงขอบเขตของพื้นที่ศึกษาจากภาพถ่ายดาวเทียมหนึ่งภาพสามารถครอบคลุมพื้นที่ได้มากกว่าข้อมูลภาพถ่ายดาวเทียมความละเอียดเชิงพื้นที่สูง ในส่วนของการกระบวนการแบ่งส่วนภาพ (Image Segmentation) ก็กับการสกัดคุณลักษณะเฉพาะ (Feature Extract) ของภาพด้วยโปรแกรม eCognition ผสมผสานกับการตั้งกฎ (Rule Set) เฉพาะกับพื้นที่ที่มีความสามารถในการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมให้มีความละเอียดมากขึ้น จากนั้นผลลัพธ์ที่ได้จะอยู่ในรูปแบบของข้อมูลที่มีค่าต่างๆ เพื่อนำไปเป็นที่ป็นคุณสมบัติหนึ่งในกระบวนการพัฒนาออนโทโลยีรวมถึงกระบวนการสร้างโดเมนความรู้ (Domain Knowledge) จากข้อมูลที่ได้จากผู้เชี่ยวชาญผ่านเอกสารหรืองานวิจัยที่เกี่ยวข้องกับข้อมูลภาพถ่ายดาวเทียม และองค์ประกอบที่เกี่ยวข้องมาใช้ในการสร้างโครงสร้างของออนโทโลยีเพื่อทำให้ออนโทโลยีสามารถใช้คุณลักษณะที่ได้จากการสร้างโดเมนความรู้มาใช้เพื่อจำแนกประเภทการใช้ที่ดินและสิ่งคลุมดินรวมถึงคุณลักษณะของดาวเทียม Landsat 8 เพื่อมาวิเคราะห์และนำมาสร้างแนวคิด (Concept) และกฎ (Rules) ในกระบวนการทางออนโทโลยีเพื่อใช้สำหรับการจำแนกประเภทจะแสดงในบทที่ 3

บทที่ 3 วิธีดำเนินงานวิจัย

การวิจัยการประยุกต์ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีเพื่อการวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลกมีการดำเนินงานวิจัยแสดงในภาพ 11 โดยมีรายละเอียดของแต่ละส่วนสรุปได้ดังนี้




ภาพ 11 ขั้นตอนการจำแนกประเภทการใช้ที่ดินและสิ่งคลุมดินโดยภาพรวม

การวิเคราะห์ข้อมูลภาพเชิงวัตถุ (Object-Based Image Analysis)

ส่วนที่ 1 การวิเคราะห์ข้อมูลภาพเชิงวัตถุมี 3 ขั้นตอนประกอบด้วย 1) การนำเข้าข้อมูลภาพถ่ายดาวเทียม 2) การแบ่งส่วนภาพ และ 3) การสกัดคุณสมบัตินี้

1. ขั้นตอนการนำเข้าข้อมูลภาพถ่ายดาวเทียมและการเตรียมข้อมูล (Data pre-processing) ในการวิจัยครั้งนี้ใช้ข้อมูลภาพถ่ายดาวเทียม Landsat 8 จำนวน 2 ภาพ ประกอบด้วยข้อมูลภาพวันที่ 26 ตุลาคม 2558 และวันที่ 10 ธันวาคม 2563 เขตพื้นที่อำเภอเมือง จังหวัดพิษณุโลกซึ่งครอบคลุมพื้นที่ศึกษาทั้งหมด นำข้อมูลที่ได้มาทำการรวมแบนด์ข้อมูลภาพ (Layer Stack) โดยรวมแบนด์ 2, 3, 4, 5, 6 และ 7 เป็นแบนด์ Multispectral ต่อด้วยการผสมสี (Band Combination) ของภาพถ่ายดาวเทียม Landsat 8 เป็นการเน้นคุณลักษณะของภาพจากดาวเทียมที่มีความแตกต่างกันให้เด่นออกมาในช่วงคลื่นที่ไม่สามารถมองเห็นด้วยตาเปล่า แสดงผลในรูปของสีแดง เขียว และน้ำเงิน (RGB) ต่อด้วยการปรับแก้เชิงเรขาคณิต เพื่อให้เกิดความสัมพันธ์ระหว่างข้อมูลภาพจากดาวเทียมกับข้อมูลที่ใช้ในการอ้างอิงระบบพิกัดทางภูมิศาสตร์ และทำการตัดข้อมูลภาพถ่ายดาวเทียม (Sub Set Image) ให้ได้เฉพาะขอบเขตของพื้นที่ศึกษาดังภาพ 12-14



ภาพ 12 แสดงขอบเขตพื้นที่ศึกษา



ภาพ 13 แสดงพื้นที่ศึกษาข้อมูลวันที่ 26 ตุลาคม 2558



ภาพ 14 แสดงพื้นที่ศึกษาข้อมูลวันที่ 10 ธันวาคม 2563

จากนั้นนำข้อมูลภาพถ่ายดาวเทียม Landsat 8 มาใช้งานต้องทำการแปลงค่า Digital numbers (DNs) เป็น Top Of Atmosphere (TOA) Reflectance ในระบบ Multispectral bands ค่าของข้อมูลที่ใช้ในการคำนวณมาจาก Meta data ของไฟล์ภาพ (Congedo, 2016; USGS, 2019)

2. ขั้นตอนการแบ่งส่วนภาพ (Image Segmentation) จะทำการแบ่งกลุ่มข้อมูลของข้อมูลจุดภาพพิกัดค่าการสะท้อนแสงที่ใกล้เคียงกันหรืออยู่ติดกันเข้าด้วยกันเพื่อสร้างเป็นวัตถุ และใช้วัตถุที่สร้างขึ้นเพื่อนำมาอธิบายชั้นข้อมูลที่เป็นตัวแทนของวัตถุที่ใช้ในการจำแนก

การแบ่งส่วนภาพในการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุใช้การแบ่งส่วนภาพด้วยวิธีการ Multi-resolution Segmentation มีกำหนดค่าพารามิเตอร์ได้แก่ พารามิเตอร์มาตราส่วนหรือขนาด (Scale Parameter) พารามิเตอร์รูปร่าง (Shape Parameter) พารามิเตอร์สี (Color Parameter) พารามิเตอร์ความอัดแน่นหรือความหนาแน่น (Compactness Parameter) และพารามิเตอร์ความเรียบ (Smoothness Parameter) เพื่อให้ได้ขนาดของวัตถุที่มีขนาดเหมาะสมกับการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดิน โดยกำหนดค่าพารามิเตอร์ดังกล่าวคือ

2.1 ค่ามาตราส่วน (Scale) เป็นตัวกำหนดขนาดของการสร้างวัตถุภาพ ในการกำหนดค่ามาตราส่วนนั้นต้องพิจารณาค่าที่ต้องการเช่น ค่าที่ต่ำหมายถึงขนาดของวัตถุมีขนาดเล็กหรือมีความละเอียดมากข้อมูลที่ไต่ยังมีขนาดเล็กก็จะมีค่าความเหมือนกันค่อนข้างสูง และถ้าค่ามาตราส่วนที่มีค่าสูงหรือมีความละเอียดน้อยจะหมายถึงขนาดของวัตถุภาพจะมีขนาดใหญ่ข้อมูลที่ไต่ยังมีขนาดใหญ่ก็จะมีค่าความเหมือนกันค่อนข้างต่ำเนื่องจากขนาดข้อมูลใหญ่จะมีการปะปนกันของวัตถุมากตามมาจึงต้องมีการกำหนดค่าขนาดให้มีความเหมาะสมกับพื้นที่

2.2 ค่ารูปร่างและค่าสี

การกำหนดค่ารูปร่าง (Shape) และค่าสี (Color) ในการสร้างวัตถุภาพจะเลือกให้ค่าความน่าจะเป็นของสีหรือค่าความน่าจะเป็นของรูปร่าง ถ้าพิจารณาความเป็นสีมากกว่าควรพิจารณาจากค่าการสะท้อนตามช่วงคลื่นต่าง ๆ ที่เลือกมาทำภาพสีผสม ซึ่งในข้อมูลดาวเทียมใดๆ ที่มีค่าของสีแต่ละวัตถุที่ชัดเจนจะมีผลให้น้ำหนักของสีมากกว่ารูปร่าง แต่รูปร่างจะพิจารณาจากรูปร่างของวัตถุภาพและองค์ประกอบใดๆ ที่ปรากฏในภาพถ่ายดาวเทียม การให้ค่าความน่าจะเป็นของสีและรูปร่างค่าที่ได้รวมกันต้องไม่เกิน 1 ตัวอย่างเช่นการให้ค่าความน่าจะเป็นของรูปร่างเป็น A ค่าน้ำหนักของความน่าจะเป็นของสีที่จะได้เท่ากับ $1-A$ การให้ค่าความน่าจะเป็นที่ควรให้ค่าความน่าจะเป็นของสีมากกว่าค่าของรูปร่าง เนื่องด้วยข้อมูลภาพถ่ายดาวเทียมที่อยู่ในจุดภาพเป็นข้อมูลเชิงคลื่นที่มีส่วนสำคัญในการสร้างวัตถุภาพจึงทำให้ส่วนของรูปร่างนั้นเป็นเพียงปัจจัยที่เข้ามาช่วยในเรื่องของรูปร่างที่ใช้สำหรับการจำแนกประเภทวัตถุภาพ และการให้ค่ารูปร่างและค่าสีที่มีความแตกต่างกัน โดยกำหนดค่ามาตราส่วนและค่าการเกาะกลุ่มหรือค่าความราบเรียบที่คงที่ ลักษณะวัตถุภาพที่ได้ทั้งสามประเภทเมื่อให้ค่าของของสีมากขึ้นลักษณะของวัตถุภาพจะมีความมีความหลากหลายของข้อมูลน้อย ถ้าดูที่ภาพจะเห็นได้ว่าบางพื้นที่แบ่งสีกันอย่างชัดเจน แต่ถ้าให้ค่าของรูปร่างมากกว่าสีลักษณะวัตถุภาพที่ได้

ยังมีขนาดใหญ่มากขึ้นซึ่งหมายความว่าวัตถุภาพในพื้นที่ที่มีความหลากหลายทางข้อมูลมากและบางพื้นที่จะไม่สามารถแยกออกจากกันได้ชัดเจน

2.3 การกำหนดค่าการเกาะกลุ่มและค่าความเรียบ

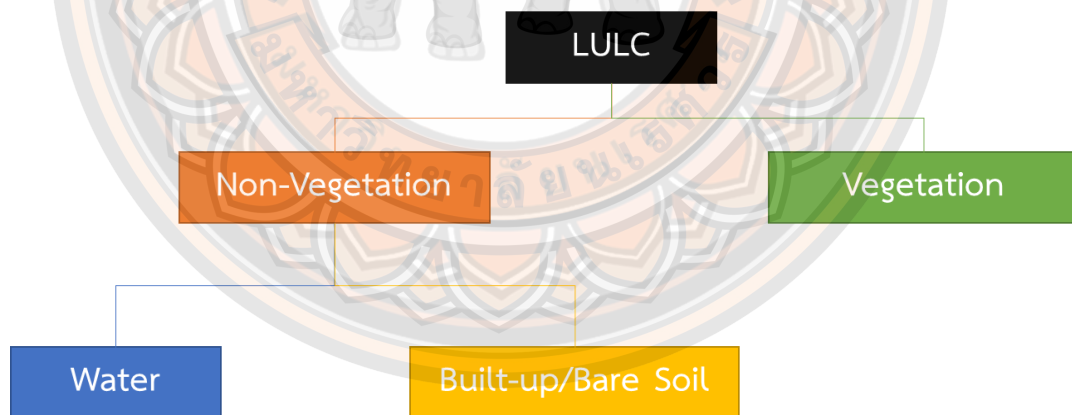
ค่าการเกาะกลุ่ม (Compactness) และค่าความเรียบ (Smoothness) ถ้าเน้นการให้ความสำคัญกับรูปร่างของวัตถุ ค่าความน่าจะเป็นของการเกาะกลุ่มเป็น A2 ค่าน้ำหนักความน่าจะเป็นของความเรียบจะเท่ากับ 1-A2 ค่าของทั้งการเกาะกลุ่มและความเรียบต้องรวมกันไม่เกิน 1 การให้ค่าความน่าจะเป็นของการเกาะกลุ่มจะมีผลต่อรูปทรงของวัตถุที่เปลี่ยนแปลงไป ซึ่งจะถูกใช้เมื่อวัตถุสองสิ่งมีความแตกต่างกันอย่างเห็นได้ชัดหมายความว่าวัตถุภาพนั้นมีความสัมพันธ์เชิงคลื่นต่ำ เช่น วัตถุที่เป็น น้ำกับดิน จะมีค่าสีของวัตถุทั้งสองประเภทนี้มีความแตกต่างกันอย่างชัดเจนในขณะที่ค่าความเรียบนั้นจะถูกใช้ก็ต่อเมื่อวัตถุทั้งสองไม่สามารถแยกออกจากกันอย่างชัดเจน เช่น วัตถุที่เป็นพื้นที่ว่าง กับพื้นที่สิ่งปลูกสร้างที่มีการสะท้อนเชิงคลื่นใกล้เคียงกันทำให้ในบางครั้งอาจมองเห็นขอบเขตที่ไม่ชัดเจน แล้วถ้าค่าการเกาะกลุ่มสูงกว่าค่าความเรียบมีผลให้วัตถุถูกทำการบีบอัดให้เล็กลง และกลุ่มของวัตถุที่ได้จะมีความเหมือนกันค่อนข้างมาก ส่วนความเรียบนั้นจะทำให้ได้วัตถุที่มีรูปทรงขอบที่ราบเรียบมากขึ้น และกลุ่มของวัตถุที่ได้มีความหลากหลายของข้อมูล ในการให้ค่าของการเกาะกลุ่มและความราบเรียบที่แตกต่างกัน โดยให้ค่ามาตราส่วนและค่ารูปร่างและสีให้มีค่าที่คงที่ ลักษณะวัตถุภาพที่เกิดขึ้นทั้งสามประเภทนั้น เมื่อให้ค่าการเกาะกลุ่มที่มากขึ้น ลักษณะวัตถุภาพที่เกิดขึ้นจะให้ความเป็นเอกภาพหรือความหลากหลายของข้อมูลที่น้อยลง บางพื้นที่ที่สามารถที่จะแยกออกจากกันได้ อย่างชัดเจน เช่นเดียวกันถ้าให้ค่าของความราบเรียบที่มากขึ้นความหลากหลายทางข้อมูลก็จะมีมากขึ้นทำให้บางพื้นที่ไม่สามารถแยกออกจากกันได้ชัดเจน

งานวิจัยนี้ได้มีการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้องโดยพิจารณาความเหมาะสมจากข้อมูลภาพถ่ายดาวเทียม Landsat 8 ผ่านการแบ่งส่วนภาพในพื้นที่ศึกษาโดยใช้โปรแกรม eCognition 9 แสดงในตาราง 4

ตาราง 4 ค่าพารามิเตอร์ที่ใช้ในการแบ่งส่วนภาพ

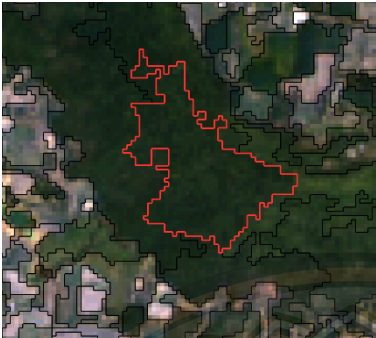
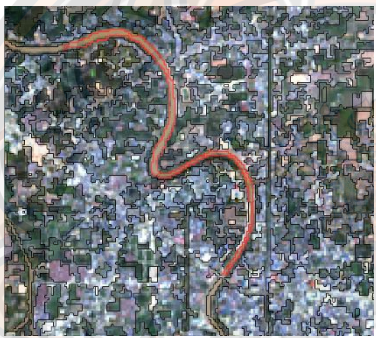
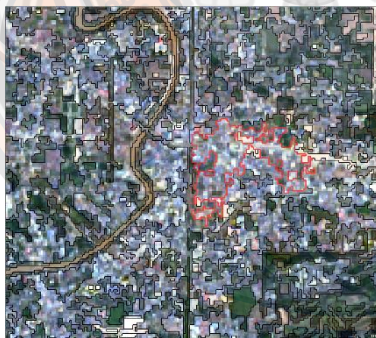

Parameter	Value
ค่ามาตราส่วน (Scale)	100
ค่ารูปร่าง (Shape)	0.1
ค่าสี (Color)	0.9
ค่าการเกาะกลุ่ม (Compactness)	0.5
ค่าความเรียบ (Smoothness)	0.5

3. การสกัดคุณลักษณะ (Feature Extraction) จากคุณสมบัติของการสะท้อนช่วงคลื่นโดยกำหนดโครงสร้างของลำดับชั้นในจำแนกข้อมูล (Class Hierarchy) เป็นการสร้างชั้นข้อมูลเพื่อใช้ในการประกอบการจำแนกรวมถึงการกำหนดปัจจัยต่างๆ ที่เกี่ยวข้องกับระดับชั้น (Class) โดยกำหนดโครงสร้างระดับชั้นของการจำแนกจะพิจารณาจากคุณสมบัติของวัตถุที่ต้องการในรูปแบบโครงสร้างต้นไม้ (Tree structure) ซึ่งลำดับชั้นช่วยทำให้เห็นถึงความเหมือนกันหรือแตกต่างกันของสิ่งต่างๆ ได้ง่ายขึ้นประกอบด้วยค่าต่างๆ ได้แก่ ค่าเฉลี่ยช่วงคลื่น (Mean) ค่าความสว่าง (Brightness) ค่าส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ค่าส่วนต่างสูงสุด (Max. diff.) ค่าการสะท้อนของช่วงคลื่นแบนด์ 2-7 ค่าดัชนีผลต่างพืชพรรณ (Normalized Difference Vegetation Index : NDVI) ค่าดัชนีผลต่างความชื้นของน้ำ (Normalized Difference Water Index : NDWI) และค่าดัชนีผลต่างสิ่งปลูกสร้าง (Normalized Difference Built-up Index : NDBI) เพื่อทำการจำแนกโดยการกำหนดเงื่อนไขจากค่าของข้อมูล (Threshold) และทำการตั้งกฎ (Rule Set) ในการศึกษาเริ่มจากการจำแนกพื้นที่ออกเป็นพื้นที่ไม่ใช่พืชพรรณ (Non-vegetation) และพื้นที่พืชพรรณ (Vegetation) พิจารณาจากค่าการสะท้อนคลื่นแม่เหล็กไฟฟ้า ค่าลายเซ็นเชิงคลื่น และค่า NDVI ต่อจากนั้นจำแนกส่วนของพื้นที่น้ำ (Water), พื้นที่สิ่งปลูกสร้าง (Built-up) และพื้นที่ว่างเปล่า (Bare soil) ประกอบด้วยค่า NDWI เพื่อแยกพื้นที่ดังกล่าวออกจากพื้นที่ไม่ใช่พืชพรรณตามลำดับ ดังภาพ 15



ภาพ 15 Land Use and Land Cover class hierarchy

ตาราง 5 แสดงภาพ กฎ ของประเภทการใช้ที่ดินและสิ่งปกคลุมดิน

ประเภท	ตัวอย่างพื้นที่	กฎ
พืชพรรณ		$NDVI \geq 0.2$ and $Brightness \geq 10000$
น้ำ		$NDVI < 0.2$ and $Brightness < 10000$ and $NDWI \geq 0.0$
สิ่งปลูก สร้าง		$NDVI < 0.2$ and $Brightness < 14000$ and $NDBI < 0.05$
ที่ว่างเปล่า		$NDVI < 0.2$ and $Brightness \geq 14000$ and $NDBI \geq 0.05$

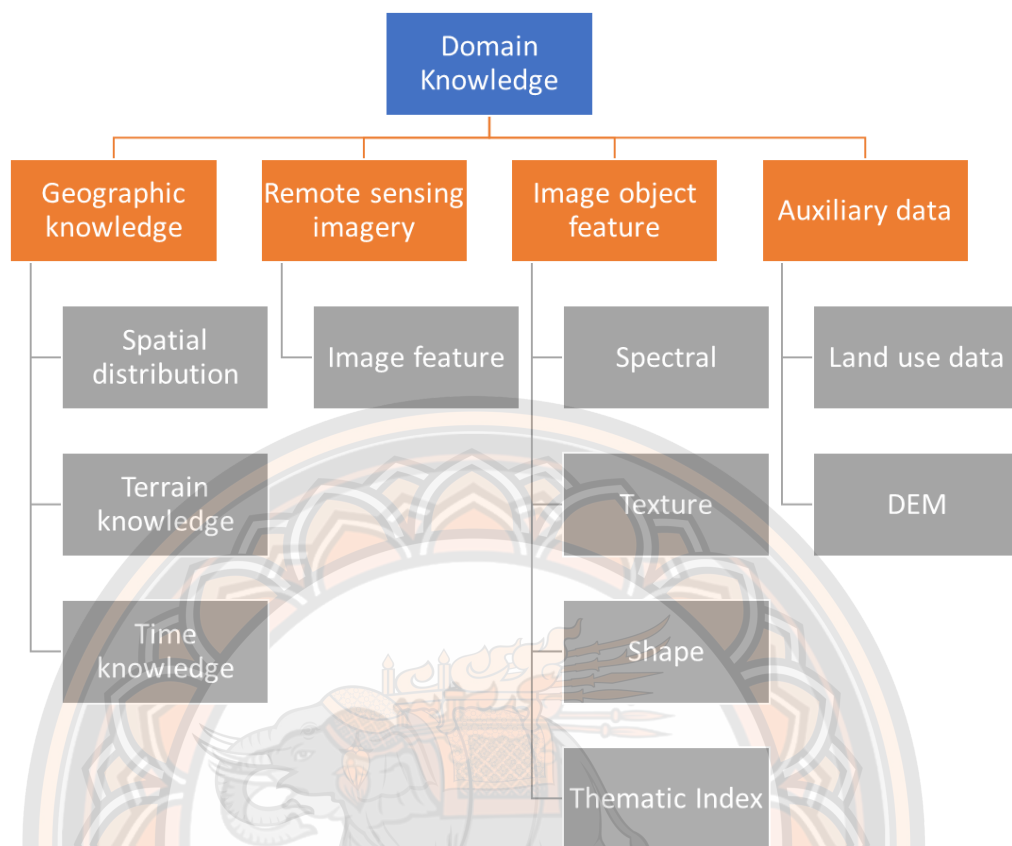
จากตาราง 5 ผลลัพธ์ที่ได้จากกฎที่สร้างขึ้นจากคุณสมบัติของวัตถุภาพแสดงให้เห็นถึงการวิเคราะห์ค่าดัชนีผลต่างพืชพรรณ (NDVI) ค่าดัชนีผลต่างความชื้นของน้ำ (NDWI) และการวิเคราะห์ค่าดัชนีผลต่างสิ่งปลูกสร้าง (NDBI) เป็นการประมวลผลข้อมูลภาพถ่ายดาวเทียม Landsat 8 ตามสมการการวิเคราะห์ค่า NDVI NDWI และ NDBI ซึ่งผลที่ได้จากการประมวลผลแสดงให้เห็นว่าค่า NDVI ของพื้นที่ที่ไม่มีพืชพรรณมีค่าต่ำสุด ($NDVI < 0.2$, $NDWI < 0.0$ และ $NDBI < 0.0$) เนื่องจากเป็นพื้นที่ที่มีพืชอยู่น้อยซึ่งสามารถใช้ยืนยันร่วมกับค่าการสะท้อนเชิงคลื่นเพื่อจำแนกประเภทพื้นที่พืชพรรณออกจากพื้นที่ไม่ใช่พืชพรรณ ส่วนเมื่อพิจารณาพื้นที่ที่มีพืชพรรณเป็นหลัก จะพบว่าพื้นที่พืชพรรณจะมีค่า NDVI สูงกว่าค่าอื่น ($NDVI \geq 0.2$, $NDWI < 0.0$ และ $NDBI < 0.0$) เนื่องจากปริมาณและความหนาแน่นของพืชพรรณสามารถใช้ค่าดังกล่าวเป็นค่าเกณฑ์สำหรับจำแนกพื้นที่พืชพรรณออกจากพื้นที่ไม่ใช่พืชพรรณได้ ส่วนพื้นที่น้ำเมื่อพิจารณาพบว่าจะมีค่า NDWI สูงกว่าค่าอื่น ($NDVI < 0.0$, $NDWI \geq 0.0$ และ $NDBI < 0.0$) ทำให้สามารถจำแนกประเภทพื้นที่น้ำออกจากพื้นที่ที่ไม่ใช่พืชพรรณได้ และเมื่อพิจารณาค่าพื้นที่สิ่งปลูกสร้างและพื้นที่ว่างเปล่าจะพบว่าค่า NDBI มีค่าสูงกว่าค่าอื่น ($NDVI < 0.0$, $NDWI < 0.0$ และ $NDBI \geq 0.0$) ทำให้สามารถจำแนกประเภทพื้นที่สิ่งปลูกสร้างและพื้นที่ว่างเปล่าออกจากพื้นที่น้ำได้

หลังจากการสกัดคุณลักษณะวัตถุภาพจากคุณสมบัติของการสะท้อนช่วงคลื่น และค่าดัชนีผลต่างจะได้ข้อมูลที่มีคุณสมบัติจากค่าต่างๆ คือ วัตถุภาพ (Image object) เกิดจากกระบวนการแบ่งส่วนภาพกับการสกัดข้อมูลผลลัพธ์ที่ได้จะถูกบันทึกเป็นรูปแบบไฟล์ CSV (Comma-Separated Values) เพื่อนำไฟล์ข้อมูลไปใช้ในกระบวนการวิเคราะห์ออนโทโลยีแต่ด้วยลักษณะของภาษาที่ออนโทโลยีเข้าใจจำเป็นต้องนำไฟล์ CSV แปลงอยู่ในรูปแบบไฟล์ที่ให้ออนโทโลยีสามารถเข้าใจได้ด้วยการแปลงเป็นไฟล์ OWL (Web Ontology Language) เพื่อใช้เป็นข้อมูลนำเข้าในส่วนของการวิเคราะห์ออนโทโลยี และสร้างโครงสร้างออนโทโลยีต่อไป

การวิเคราะห์ออนโทโลยี (Ontology Analysis)

ส่วนที่ 2 การวิเคราะห์ออนโทโลยี (Ontology Analysis) มีขั้นตอนดังนี้

1. โดเมนความรู้ (Domain Knowledge) มาจากข้อมูลเอกสาร ข้อมูลภาพ ข้อมูลจากผู้เชี่ยวชาญที่เกี่ยวข้องกับข้อมูลการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินเพื่อนำมาสร้างแนวความคิด (Concept) ของออนโทโลยี ตัวอย่างเช่น ข้อมูลภาพจากการสำรวจระยะไกล (Remote sensing imagery) ข้อมูลเสริม (Auxiliary data) และข้อมูลคุณลักษณะของวัตถุ (Image object feature) เป็นต้น แสดงในภาพ 16

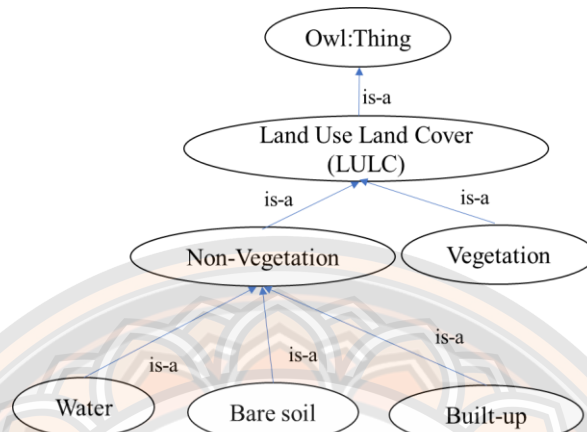


ภาพ 16 โดเมนความรู้ในออนโทโลยี

2. การสร้างออนโทโลยี (Build Ontology) เป็นกระบวนการสร้างโมเดลออนโทโลยี (Ontology Model) ในส่วนของขั้นตอนในการวิเคราะห์โครงสร้างของออนโทโลยีโดยใช้โดเมนความรู้จากข้อ 1 เพื่อนำมาเป็นต้นแบบในการสร้างออนโทโลยีโดยเลือกเฉพาะส่วนที่เกี่ยวข้องแต่ข้อมูลที่ได้อาจไม่ได้อยู่ในรูปแบบทางการที่ทำให้เครื่องสามารถอ่านได้จึงต้องมีการเลือกข้อมูลหรือกำหนดนิยามความหมายผ่านทางแนวคิด (Concept) คุณสมบัติ (Property) ความสัมพันธ์ (Relationship) ตรรกะการแปลความสัมพันธ์ (Axioms) และคำศัพท์ (Instances) ที่เกี่ยวข้องให้เป็นรูปแบบที่เครื่องสามารถเข้าใจได้จะอยู่ในรูปแบบของภาษา OWL สร้างกฎด้วย SWRL สำหรับการให้เหตุผลเกี่ยวกับออนโทโลยีโดยใช้ reasoner และ Instances ของวัตถุภาพที่ได้จากการแบ่งส่วนภาพ ถูกกำหนดให้กับแนวคิดที่เป็นตัวแทนของเอนทิตีเพื่อใช้ในการจำแนกวัตถุรูปภาพ

การกำหนดคลาสและความสัมพันธ์ กำหนดคลาสและลำดับชั้นของคลาสด้วยวิธีจากบนลงล่าง (Top-down Approach) แนวทางแรกกำหนดชั้นแรกเป็นพื้นที่ไม่ใช่พืชพรรณ (Non-vegetation) กับพื้นที่พืชพรรณ (Vegetation) ชั้นที่สองซึ่งสามารถแบ่งได้เป็นชั้นน้ำ (Water) กับชั้น

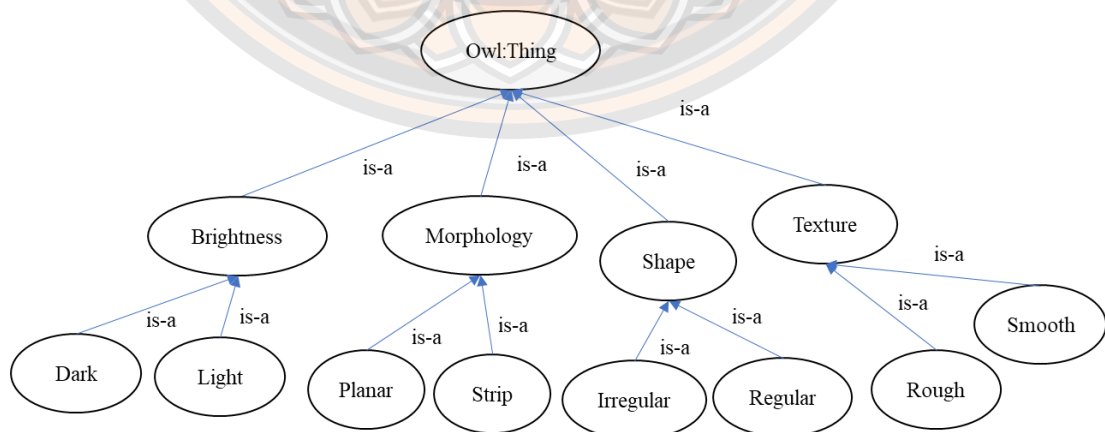
พื้นที่สิ่งปลูกสร้างอาคาร (Built-up) และพื้นที่ว่างเปล่า (Bare Soil) ออกจากชั้น พื้นที่ไม้ใช้พืชพรรณ ซึ่งมีลักษณะเป็นโครงสร้างของต้นไม้และสร้างความสัมพันธ์ระหว่างคลาส ดังภาพ 17



ภาพ 17 แบบจำลองออนโทโลยีการใช้ที่ดินและสิ่งปกคลุมดิน

การจำแนกประเภทตามออนโทโลยี (Ontology-based Classification)

ส่วนที่ 3 การจำแนกประเภทตามออนโทโลยี ส่วนนี้เป็นการสร้างแบบจำลองออนโทโลยีของกฎที่ใช้ในการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดิน กฎดำเนินการโดยใช้ภาษา SWRL (Semantic Web Rule Language) เป็นหนึ่งในภาษาเว็บเชิงความหมายโดย W3C และเป็นภาษาที่ใช้ในการแสดงกฎสำหรับตรรกะการอนุมานทำให้เกิดข้อมูลใหม่เพื่อสร้างองค์ความรู้ที่ได้ด้วย SWRL และใช้ reasoner เป็นตัวจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยออนโทโลยี แสดงในภาพ 18



ภาพ 18 แบบจำลองออนโทโลยีของกฎ

ตาราง 6 แสดงกฎจากโครงสร้างออนโทโลยีและรูปแบบ SWRL

ประเภท	กฎออนโทโลยี	กฎ SWRL
พืชพรรณ	$\text{Vegetation} \equiv \text{Irregular} \cap \text{Planar} \cap \text{Rough} \cap \text{Dark}$	$\text{Irregular} (?x), \text{Planar} (?x), \text{Rough} (?x), \text{Dark} (?x) \rightarrow \text{Vegetation}$
น้ำ	$\text{Water} \equiv \text{Irregular} \cap \text{Planar} \cap \text{Smooth} \cap \text{Dark}$	$\text{Irregular} (?x), \text{Planar} (?x), \text{Smooth} (?x), \text{Dark} (?x) \rightarrow \text{Water}$
สิ่งปลูก สร้าง	$\text{Built-up} \equiv \text{Regular} \cap \text{Planar} \cap \text{Rough} \cap \text{Light}$	$\text{Regular} (?x), \text{Planar} (?x), \text{Rough} (?x), \text{Light} (?x) \rightarrow \text{Built-up}$
ที่ว่างเปล่า	$\text{Bare soil} \equiv \text{Irregular} \cap \text{Planar} \cap \text{Rough} \cap \text{Light}$	$\text{Irregular} (?x), \text{Planar} (?x), \text{Rough} (?x), \text{Light} (?x) \rightarrow \text{Bare soil}$

จากตาราง 6 บนพื้นฐานของการจำแนกประเภทเริ่มต้นโดยแต่ละวัตถุจะถูกจัดประเภทใหม่ และตรวจสอบโดยกฎความหมายใน SWRL เพื่อรับข้อมูลเชิงความหมาย โดยที่ข้อมูลความหมายของ วัตถุภาพตัวอย่างเช่น Regular, Planar, Rough, Dark เป็นประเภท Vegetation นิพจน์ของการ จำแนกวัตถุทั้งหมดจะถูกจัดประเภทจึงส่งออกไปในรูปแบบ OWL เป็นตัวช่วยในการดึงคุณสมบัติวัตถุ จากกฎจะแสดงเป็นภาษา SWRL และความสัมพันธ์ทางความหมายระหว่างวัตถุคุณสมบัติ และคลาสถูกสร้างขึ้น ตัวอย่างเช่น ประเภทความสว่าง (Brightness) จะแสดงเป็น SWRL ดังนี้

$\text{Mean} (?x, ?y), \text{greaterThanOrEqual} (?y, 10000) \rightarrow \text{Light} (?x)$

$\text{Mean} (?x, ?y), \text{lessThan} (?y, 10000) \rightarrow \text{Dark} (?x)$

จากตัวอย่างหมายความว่าคุณลักษณะเฉลี่ยของวัตถุ ≥ 10000 หมายถึง สว่าง (Light) ในขณะที่ < 10000 หมายถึง มืด (Dark) ดังนั้น $C(?x), X$ เป็น individual ของ $C, P(? X? Y)$ แทน attribute, x และ y เป็นตัวแปร

กฎที่ใช้สำหรับจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินทั้ง 4 ประเภทแบ่งออกเป็น พื้นที่ พืชพรรณ (Vegetation) พื้นที่น้ำ (Water) พื้นที่สิ่งปลูกสร้าง (Built-up) และพื้นที่ว่างเปล่า (Bare

soil) นั้นได้มาจากข้อมูลที่เกี่ยวข้อง โทนมแนความรู้ และแบบจำลองออนโทโลยีของกฎที่กำหนด กฎที่ใช้จะถูกกำหนดอย่างเป็นทางการโดยใช้ OWL ดังนี้

Vegetation \equiv Irregular \cap Planar \cap Rough \cap Dark

Water \equiv Irregular \cap Planar \cap Smooth \cap Dark

Built-up \equiv Regular \cap Planar \cap Rough \cap Light

Bare soil \equiv Irregular \cap Planar \cap Rough \cap Light

จากกฎที่ใช้จำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินจะแสดงในรูปแบบภาษา SWRL และความสัมพันธ์เชิงความหมายระหว่างกฎและประเภทที่สร้างขึ้น ตัวอย่างเช่น พื้นที่พืชพรรณ (Vegetation) จะแสดงเป็น SWRL ดังนี้

Irregular (?x), Planar (?x), Rough (?x), Dark (?x), -> Vegetation (?x)

จากตัวอย่างแสดงให้วัตถุภาพมีคุณสมบัติได้แก่ ผิดปกติ (Irregular), ระนาบ (Planar), หลาย (Rough), และมีมืด (Dark) เป็นคุณสมบัติของประเภทพื้นที่พืชพรรณ (Vegetation)

สุดท้ายผลการจำแนกประเภทตามออนโทโลยีจะอยู่ในรูปแบบไฟล์ OWL ต้องเข้าสู่กระบวนการแปลงไฟล์ให้อยู่ในรูปแบบไฟล์ CSV หรือ Shape file เพื่อที่จะใช้ในการแสดงผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินในลักษณะของแผนที่การจำแนกประเภท และสามารถนำไปสู่กระบวนการประเมินความถูกต้องของการจำแนกประเภทต่อไป

การประเมินความถูกต้อง (Accuracy Assessment)

ส่วนที่ 4 การประเมินความถูกต้องของการจำแนกข้อมูลการใช้ที่ดินและสิ่งปกคลุมดินที่ได้ถูกนำมาประเมินความถูกต้องของผลการจำแนกโดยใช้ข้อมูลภาพถ่ายดาวเทียมที่มีความละเอียดเชิงพื้นที่สูงมาจาก Google Earth โดยนำจำนวนจุดตัวอย่างที่ได้ไปสุ่มหาตำแหน่งที่จะทำการสำรวจด้วยวิธีการสุ่มตัวอย่าง (Random Sampling) เป็นการสุ่มตัวอย่างที่เป็นไปโดยสุ่ม พร้อมทั้งทำการประเมินความถูกต้องของการจำแนกการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินโดยอาศัยการคำนวณค่าทางสถิติ ข้อมูลที่ได้จาก Google Earth จะถูกนำมาเปรียบเทียบกับผลที่ได้จากการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินในรูปของเมทริกซ์ความผิดพลาด (Error matrix) โดยจะคำนวณค่าความ

ถูกต้องของผู้ผลิต (Producer's accuracy) ค่าความถูกต้องของผู้ใช้งาน (User's accuracy) ค่าความถูกต้องโดยรวม (Overall accuracy) และค่าสัมประสิทธิ์แคปปา (Kappa coefficient: \hat{K}_v)



บทที่ 4

ผลการวิจัย

ผลการวิจัยการวิเคราะห์ข้อมูลภาพเชิงวัตถุรวมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลกตามขั้นตอนในบทที่ 3 ประกอบด้วย 1) ผลการวิเคราะห์ข้อมูลภาพเชิงวัตถุ 2) ผลการวิเคราะห์ออนโทโลยี 3) ผลการจำแนกประเภทตามออนโทโลยี และ 4) ผลการประเมินความถูกต้อง ดังต่อไปนี้

ผลการวิเคราะห์ข้อมูลภาพเชิงวัตถุ


นำเข้าข้อมูลภาพถ่ายดาวเทียม Landsat 8 จาก USGS (<https://earthexplorer.usgs.gov/>) วันที่ 26 ตุลาคม 2558 และวันที่ 10 ธันวาคม 2563 อยู่ใน Path 130 และ Row 48 ซึ่งครอบคลุมพื้นที่ศึกษาทั้งหมด เนื่องจากเป็นช่วงเวลาที่ประเทศไทยไม่ได้อยู่ในช่วงฤดูฝนมีเมฆปกคลุมไม่มาก เลือกใช้ข้อมูลภาพถ่ายจากดาวเทียม Landsat 8 เฉพาะแบนด์ (Band) 2, 3, 4, 5, 6 และ 7 และทำการตัดข้อมูลภาพถ่ายดาวเทียม (Sub Set Image) ให้ได้เฉพาะพื้นที่ศึกษาคือขอบเขตของพื้นที่เขตอำเภอเมือง จังหวัดพิษณุโลก

ผลการแบ่งส่วนภาพในการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินในพื้นที่ศึกษาด้วยวิธีการแบ่งส่วนภาพด้วยวิธีการ Multi-resolution Segmentation มีกำหนดค่าพารามิเตอร์ได้แก่ พารามิเตอร์มาตราส่วนหรือขนาด (Scale Parameter) พารามิเตอร์รูปร่าง (Shape Parameter) พารามิเตอร์สี (Color Parameter) พารามิเตอร์ความอัดแน่นหรือความหนาแน่น (Compactness Parameter) และพารามิเตอร์ความเรียบ (Smoothness Parameter) แสดงในตาราง 7 และผลการแบ่งส่วนภาพดังภาพ 19 และ 20


ตาราง 7 ค่าพารามิเตอร์ในการแบ่งส่วนภาพ

Parameter	Value
Scale	100
Shape	0.1
Color	0.9
Smoothness	0.5
Compactness	0.5

จากตาราง 7 การกำหนดค่าพารามิเตอร์พบว่า การกำหนดค่าขนาดของภาพจะเป็นค่าที่แสดงขนาดเล็กหรือใหญ่ของวัตถุภาพ ดังนั้นจึงพิจารณาจากการปะปนกันของวัตถุภาพในระหว่างการแบ่งส่วนแล้วหาค่าที่เหมาะสมกับการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินในครั้งนี ส่วนค่าอื่นๆ เช่น ค่ารูปร่างจะไม่เน้นเนื่องจากงานวิจัยนี้จะเน้นการสะท้อนช่วงคลื่นมากกว่ารูปร่างที่แสดงบนข้อมูลภาพถ่ายดาวเทียมจึงจะเน้นค่าสีมากกว่า ส่วนค่าความหนาแน่นและค่าความเรียบจะเป็นส่วนย่อยของค่ารูปร่างจึงกำหนดค่าให้เท่ากันเนื่องจากไม่ได้เน้นที่รูปร่างเช่นกัน

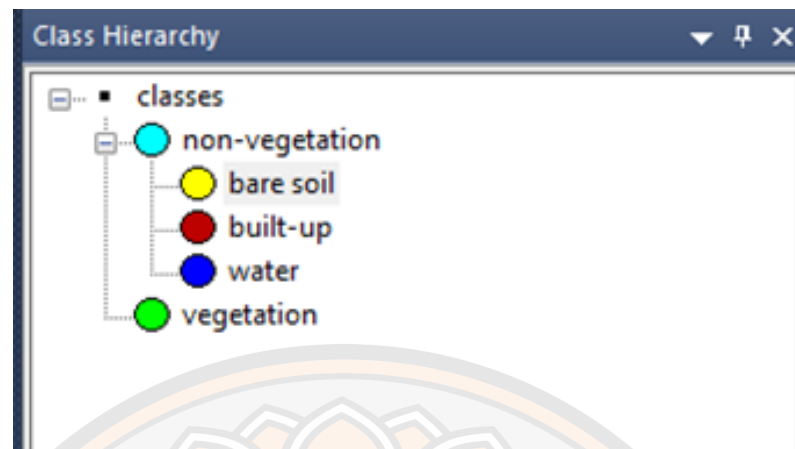


ภาพ 19 ผลการแบ่งส่วนภาพพื้นที่อำเภอเมืองวันที่ 26 ตุลาคม 2558

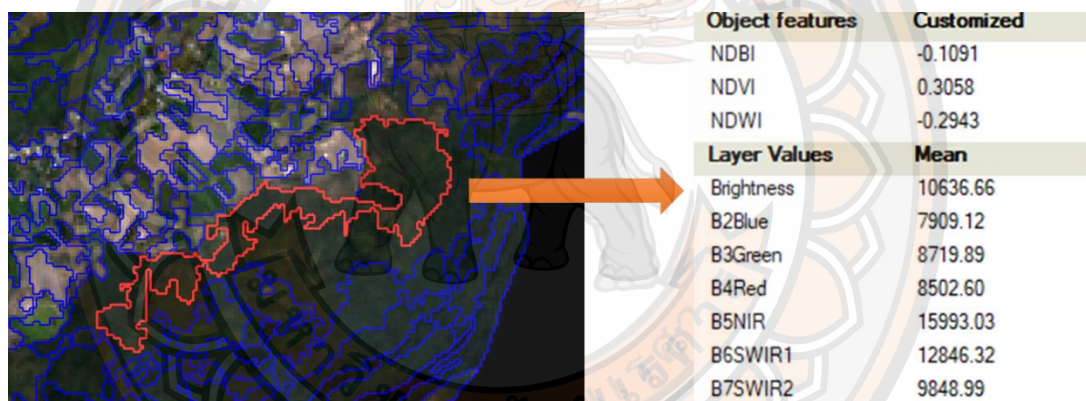


ภาพ 20 ผลการแบ่งส่วนภาพพื้นที่อำเภอเมืองวันที่ 10 ธันวาคม 2563

ผลการสกัดคุณลักษณะ (Feature Extraction) จากคุณสมบัติของการสะท้อนช่วงคลื่นโดยกำหนดโครงสร้างของลำดับชั้นในจำแนกข้อมูล (Class Hierarchy) เป็นการสร้างชั้นข้อมูลเพื่อใช้ในการประกอบการจำแนกรวมถึงการกำหนดปัจจัยต่างๆ ที่เกี่ยวข้องกับระดับชั้น (Class) โดยกำหนดโครงสร้างระดับชั้นของการจำแนกจะพิจารณาจากคุณสมบัติของวัตถุที่ต้องการ เช่น ค่าเฉลี่ยช่วงคลื่น (Mean) ของแบนด์ 2-7 ค่าความสว่าง (Brightness) ค่าส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ค่าส่วนต่างสูงสุด (Max. diff) ค่าดัชนีผลต่างพืชพรรณ (NDVI) ค่าดัชนีผลต่างความชื้นของน้ำ (NDWI) และค่าดัชนีผลต่างสิ่งปลูกสร้าง (NDBI) เป็นต้นเพื่อทำการจำแนกโดยการกำหนดเงื่อนไขจากค่าของข้อมูล (Threshold) และทำการตั้งกฎ (Rule Set) แสดงในภาพ 21 และ 22



ภาพ 21 แสดง Class Hierarchy



ภาพ 22 แสดงผลการสกัดคุณลักษณะจากภาพถ่ายดาวเทียม

จากภาพ 22 ผลลัพธ์ที่ได้จากกฎที่สร้างขึ้นจากคุณสมบัติของภาพถ่ายดาวเทียมจะถูกส่งออกบันทึกเป็นรูปแบบไฟล์ CSV หลังจากนั้นจะเข้าสู่กระบวนการแปลงไฟล์ข้อมูลให้เป็นรูปแบบไฟล์ OWL เพื่อใช้เป็นข้อมูลนำเข้าในส่วนของการวิเคราะห์ออนโทโลยี และสร้างโครงสร้างออนโทโลยีต่อไป ดังภาพ

NDWI	NDVI	NDBI	Max. diff.
-0.27123366	0.211937918	0.058954108	0.78932005
-0.24387346	0.191966366	0.059537686	0.71558446
-0.32500152	0.33244951	-0.13082649	0.86251862
-0.33869313	0.340450766	-0.11072473	0.88964142
-0.30656198	0.317190616	-0.10586632	0.79219733
-0.27886399	0.25990126	-0.03041687	0.69206668
-0.26342249	0.215114587	0.055161756	0.76633874
-0.31367659	0.304245731	-0.06609176	0.79103845
-0.31143269	0.329203511	-0.13673144	0.81941722
-0.23221648	0.167101342	0.097619016	0.78098515
-0.21411329	0.157194618	0.114834068	0.77067682
-0.28831571	0.263435208	-0.01334692	0.69717091
-0.29065561	0.2644306	-0.02899499	0.71791389
-0.29054249	0.246958199	0.011706461	0.72351372
-0.29983853	0.281762083	-0.02294884	0.73477438
-0.22901765	0.170179549	0.093067961	0.76249022
-0.20603661	0.150311165	0.125354201	0.76343867
-0.34193126	0.354439596	-0.10928396	0.87847442

ภาพ 23 ผลลัพธ์ของการสกัดคุณลักษณะที่ผ่านกฎการจำแนกในรูปแบบไฟล์ CSV


ผลการวิเคราะห์ออนโทโลยี

การวิเคราะห์โครงสร้างของออนโทโลยีโดยใช้โดเมนความรู้จากข้อมูลผู้เชี่ยวชาญในเอกสารงานวิจัยที่เกี่ยวข้อง ข้อมูลภาพถ่ายดาวเทียม เพื่อนำมาเป็นต้นแบบในการสร้างโดเมนความรู้ออนโทโลยีมีการกำหนดนิยามความหมายผ่านทางแนวคิด (Concept) คุณสมบัติ (Property) ความสัมพันธ์ (Relationship) ตรรกะการแปลความสัมพันธ์ (Axioms) และคำศัพท์ (Instances) ที่เกี่ยวข้องให้เป็นรูปแบบที่เครื่องสามารถเข้าใจได้แสดงดังภาพ 24



ภาพ 24 แสดง ontology model สำหรับจำแนกประเภทการใช้ที่ดิน

ผลการสร้างออนโทโลยีการกำหนดคลาสและความสัมพันธ์สำหรับการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีจากบนลงล่าง (Top-down Approach) แนวทางแรกกำหนดชั้นแรกเป็นพื้นที่ไม่ใช่พืชพรรณ (Non-vegetation) กับพื้นที่พืชพรรณ (Vegetation) ชั้นที่สองซึ่งสามารถแบ่งได้เป็นชั้นน้ำ (Water) กับชั้นพื้นที่สิ่งปลูกสร้าง (Bulit-up) และพื้นที่ว่างเปล่า (Bare Soil) ออกจากชั้นพื้นที่ไม่ใช่พืชพรรณ ซึ่งมีลักษณะเป็นโครงสร้างของต้นไม้และสร้างความสัมพันธ์ระหว่างคลาส ดังภาพ 25



ภาพ 25 แสดง LULC model ในออนโทโลยี

ผลการจำแนกประเภทตามออนโทโลยี

การจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินจากการสร้างออนโทโลยีโดยกฎที่กำหนดสำหรับจำแนกประเภทใช้ภาษา SWRL บนพื้นฐานของการจำแนกประเภทเริ่มต้นโดยแต่ละวัตถุจะถูกจัดประเภทใหม่และตรวจสอบโดยกฎความหมายใน SWRL เพื่อรับข้อมูลเชิงความหมายโดยที่ข้อมูลความหมายของ วัตถุภาพตัวอย่างเช่น Regular, Planar, Rough, Dark เป็นประเภท Vegetation นิพจน์ของการจำแนกวัตถุทั้งหมดจะถูกจัดประเภทจึงส่งออกไปในรูปแบบ OWL เป็นตัวช่วยในการดึงคุณสมบัติวัตถุ

ข้อมูลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินในรูปแบบ OWL ถูกแปลงเป็นรูปแบบ Shapefile ของวันที่ 10 ธันวาคม 2563 ดังแสดงในภาพ 26 (a) การจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินด้วยการวิเคราะห์ภาพเชิงวัตถุทั่วไปโดยไม่มีออนโทโลยีซึ่งยังคงใช้ "การแบ่งส่วนภาพ การสกัดคุณลักษณะ การจัดประเภทภาพ" เหมือนเดิม และผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินด้วยการวิเคราะห์ภาพเชิงวัตถุร่วมกับออนโทโลยีดังกล่าวแสดงในภาพ 26 (b) ส่วนผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินของวันที่ 26 ตุลาคม 2558 แสดงในภาพ 27 (a) การจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินด้วยการวิเคราะห์ภาพเชิงวัตถุ และการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมด้วยด้วยการวิเคราะห์ภาพเชิงวัตถุร่วมกับออนโทโลยี ดังแสดงในภาพ 27 (b)



Bare soil
 Built-up
 Vegetation
 Water

(a) OBIA

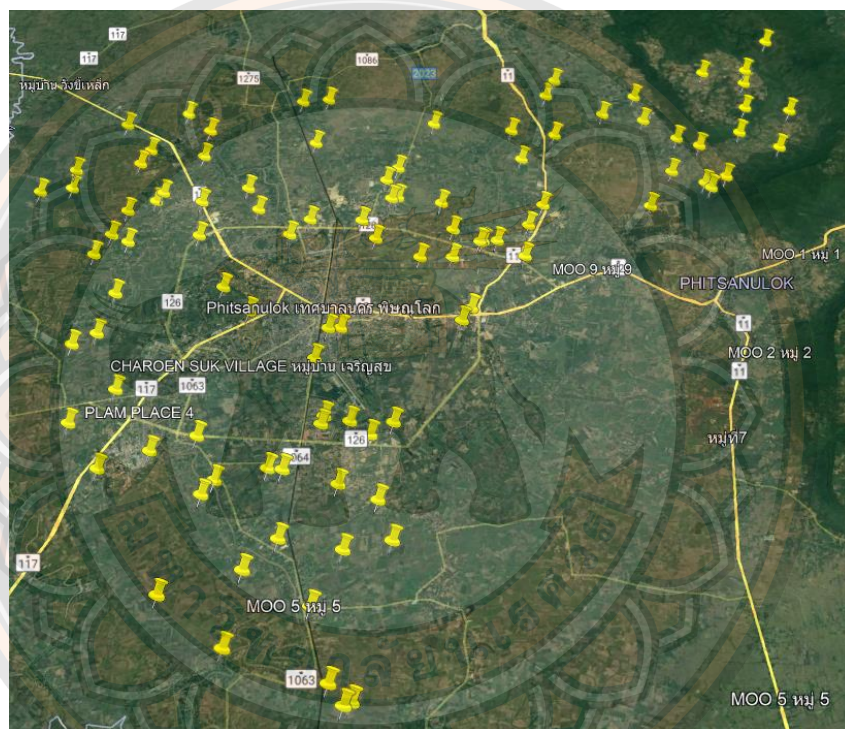
(b) OBIA with Ontology

ภาพ 26 ผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินของวันที่ 10 ธันวาคม 2563 ด้วยการวิเคราะห์ภาพเชิงวัตถุ (a) และการวิเคราะห์ภาพเชิงวัตถุร่วมกับออนโทโลยี (b)

จากภาพ 26 พบว่าผลการแบ่งส่วนภาพพื้นที่อำเภอเมืองพิษณุโลก วันที่ 10 ธันวาคม 2563 สามารถแบ่งส่วนภาพจำนวนทั้งหมด 13,568 วัตถุภาพ แสดงให้เห็นถึงผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินพบว่าการใช้วิธีการวิเคราะห์ภาพเชิงวัตถุร่วมกับออนโทโลยี (ภาพ 26 b) ดังนี้ 1) พื้นที่สีเหลืองเป็นสัญลักษณ์แทนพื้นที่ว่างเปล่า จำนวน 2,592 วัตถุภาพ 2) พื้นที่สีแดงเป็นสัญลักษณ์แทนพื้นที่สิ่งปลูกสร้าง จำนวน 4,891 วัตถุภาพ 3) พื้นที่สีเขียวเป็นสัญลักษณ์แทนพื้นที่พืชพรรณ จำนวน 5,226 วัตถุภาพ และ 4) พื้นที่สีน้ำเงินเป็นสัญลักษณ์แทนพื้นที่น้ำ จำนวน 859 วัตถุภาพ ตามลำดับ และผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินพบว่าการใช้วิธีการวิเคราะห์ภาพเชิงวัตถุ (ภาพ 26 a) สามารถจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินได้ดังนี้ 1) พื้นที่สีเหลืองเป็นสัญลักษณ์แทนพื้นที่ว่างเปล่า จำนวน 2,783 วัตถุภาพ 2) พื้นที่สีแดงเป็นสัญลักษณ์แทนพื้นที่สิ่งปลูกสร้าง จำนวน 4,636 วัตถุภาพ 3) พื้นที่สีเขียวเป็นสัญลักษณ์แทนพื้นที่พืชพรรณ จำนวน 5,157 วัตถุภาพ และ 4) พื้นที่สีน้ำเงินเป็นสัญลักษณ์แทนพื้นที่น้ำ จำนวน 992 วัตถุภาพ ตามลำดับ

ผลการประเมินความถูกต้อง

การประเมินความถูกต้องของการวิเคราะห์ข้อมูลภาพเชิงวัดถูรวมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก ผลจากการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินถูกนำมาประเมินหาความถูกต้องของผลการจำแนกโดยใช้ข้อมูลภาพถ่ายดาวเทียมที่มีความละเอียดเชิงพื้นที่สูงจาก Google Earth โดยนำจำนวนจุด ตัวอย่างที่ได้ไปสุ่มหาตำแหน่งที่จะทำการสำรวจด้วยวิธีการสุ่มตัวอย่าง (Random Sampling) เป็นการสุ่มตัวอย่างที่เป็นไปโดยสุ่ม โดยใช้การสุ่มจำนวน 100 จุด ดังภาพ 28



ภาพ 28 แสดงจุดสุ่มทดสอบ

ต่อจากนั้นทำการประเมินความถูกต้องของการจำแนกการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินโดยอาศัยการคำนวณค่าทางสถิติ ข้อมูลที่ได้จาก Google Earth จะถูกนำมาเปรียบเทียบกับผลที่ได้จากการจำแนกประเภทการใช้ประโยชน์ที่ดิน และสิ่งปกคลุมดินในรูปของเมทริกซ์ความผิดพลาด (Error matrix) โดยจะคำนวณค่าความถูกต้องของผู้ผลิต (Producer's accuracy) สามารถสะท้อนให้เห็นถึงประสิทธิภาพของการจำแนกประเภทของข้อมูลในแต่ละชั้น (Class) ของตัวจำแนก (Classifier) เป็นการวัดว่าในพื้นที่นั้นๆ มีตัวจำแนกที่สามารถจัดชั้นของข้อมูลได้มากน้อยเพียงใดเมื่อพิจารณาจากข้อมูลอ้างอิงของชั้นนั้นๆ มีการจำแนกข้อมูลถูกต้องเท่าไรสนใจในความผิดพลาดของ

การแปลที่เกิดขึ้นจากการที่ไม่ได้จำแนกข้อมูลชั้นนั้นๆ ตามที่เป็นจริง เป็นประโยชน์ในการพิจารณาว่าตัวจำแนกนั้นมีความสามารถเพียงพอในการจำแนกข้อมูลประเภทนั้นหรือไม่ ค่าความถูกต้องของผู้ใช้งาน (User's accuracy) สามารถนำมาแสดงให้เห็นถึงการสะท้อนประสิทธิผลที่เกิดขึ้นของการจำแนกที่มีความน่าเชื่อถือในการที่จะนำข้อมูลเหล่านั้นของแต่ละชั้นไปใช้ เป็นการวัดค่าของผลการจำแนกชั้นข้อมูลในพื้นที่ประเภทนั้นๆ มีความถูกต้องเพียงไร เป็นประโยชน์ในการพิจารณาว่าชั้นของการจำแนกไหนที่ได้ผลออกมาดีเป็นที่น่าเชื่อถือ ค่าความถูกต้องโดยรวม (Overall accuracy) เป็นการแสดงความถูกต้องของจำนวนการจำแนกที่มีความสอดคล้องหรือตรงกันระหว่างจุดตรวจสอบกับข้อมูลที่นำมาอ้างอิงคิดเป็นเปอร์เซ็นต์ของจุดที่นำมาตรวจสอบทั้งหมดโดยไม่คำนึงถึงลักษณะของความผิดพลาดของการจำแนก และค่าสัมประสิทธิ์แคปปา (Kappa coefficient: \hat{K}_1) เป็นการแสดงความถูกต้องโดยภาพรวม แต่มีการพิจารณาจากลักษณะของความผิดพลาดที่เกิดขึ้นใน Error matrix ด้วย การใช้ค่าสัมประสิทธิ์แคปปาเป็นการประเมินความถูกต้องที่ถือว่ามี การพิจารณาจากความสอดคล้องกันระหว่างข้อมูลตรวจสอบกับข้อมูลอ้างอิงที่เป็นไปตามโอกาสและที่เป็นไปตามจริงใช้วิเคราะห์เพื่อแสดงควบคู่ไปกับค่าความถูกต้องโดยรวม แสดงในตาราง 8-11

ตาราง 8 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ

	Reference data						PA (%)	UA (%)	
	Vegetation	Water	Built-up	Bare soil	Total				
Classified data	Vegetation	37	2	4	6	49	88.09	75.51	
	Water	0	7	0	0	7	63.63	100	
	Built-up	2	2	8	10	22	66.67	36.36	
	Bare soil	3	0	0	19	22	54.28	86.36	
	Total	42	11	12	35	100			
	OA (%)	71.00							
	Kappa (%)	58.0							

Note: PA= producer accuracy, UA = user accuracy, OA = overall accuracy, and Kappa = kappa coefficient

จากตาราง 8 ผล Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ของข้อมูลภาพถ่ายดาวเทียม Landsat 8 วันที่ 26 ตุลาคม 2558 พบว่า

ผลการประเมินค่าความถูกต้องโดยรวม (Overall accuracy) เท่ากับร้อยละ 71 ค่าสัมประสิทธิ์แคปปา (K_t) เท่ากับร้อยละ 58 ค่าทั้งสองอยู่ในเกณฑ์ดีแต่เมื่อพิจารณา ค่าความคลาดเคลื่อน (Errors) และความแม่นยำ (Accuracy) แยกตามประเภทของการใช้ที่ดินและสิ่งปกคลุมดินแสดงให้เห็นว่าพื้นที่พืชพรรณ (Vegetation) พื้นที่น้ำ และพื้นที่ว่างเปล่า มีความถูกต้องในการจำแนกมากกว่าพื้นที่สิ่งปลูกสร้างซึ่งแสดงให้เห็นว่าพื้นที่สิ่งปลูกสร้างมีความถูกต้องในการจำแนกน้อยกว่าพื้นที่อื่น เนื่องจากอาจมีค่าการสะท้อนแสงที่ใกล้เคียงกับพื้นที่อื่นๆ เช่น ใกล้เคียงกับพื้นที่ว่างเปล่า ทำให้เกิดการปะปนกันของข้อมูล

ตาราง 9 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีวิเคราะห์เชิงวัตถุ ร่วมกับออนโทโลยี

	Reference data					Total	PA (%)	UA (%)
	Vegetation	Water	Built-up	Bare soil				
Classified data	Vegetation	37	2	2	4	45	92.5	82.22
	Water	0	7	0	0	7	63.63	100
	Built-up	1	2	17	5	25	89.47	68.00
	Bare soil	2	0	0	21	23	70.00	91.30
	Total	40	11	19	30	100		
	OA (%)	82.00						
	Kappa (%)	74.13						

Note: PA= producer accuracy, UA = user accuracy, OA = overall accuracy, and Kappa = kappa coefficient

จากตาราง 9 ผล Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยี ของข้อมูลภาพถ่ายดาวเทียม Landsat 8 วันที่ 26 ตุลาคม 2558 พบว่าผลการประเมินค่าความถูกต้องโดยรวม (Overall accuracy) เท่ากับร้อยละ 82 ค่าสัมประสิทธิ์แคปปา (K_t) เท่ากับร้อยละ 74.13 ค่าทั้งสองอยู่ในเกณฑ์ดีแต่เมื่อพิจารณา ค่าความคลาดเคลื่อน (Errors) และความแม่นยำ (Accuracy) แยกตามประเภทของการใช้ที่ดินและสิ่งปกคลุมดินแสดงให้เห็นว่าพื้นที่พืชพรรณ (Vegetation) พื้นที่น้ำ และพื้นที่ว่างเปล่า มีความถูกต้องในการจำแนกมากกว่าพื้นที่สิ่งปลูกสร้างซึ่งแสดงให้เห็นว่าพื้นที่สิ่งปลูกสร้างมีความถูกต้องในการจำแนก

น้อยกว่าพื้นที่อื่นเนื่องจากอาจมีค่าการสะท้อนแสงที่ใกล้เคียงกับพื้นที่อื่นๆ เช่นใกล้เคียงกับพื้นที่ว่างเปล่า ทำให้เกิดการปะปนกันของข้อมูลสอดคล้องกับผลจากตาราง 8 แต่การใช้วิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีทำให้ประสิทธิภาพในการจำแนกประเภทนั้นๆ ดีขึ้น เช่น ประเภทสิ่งปลูกสร้างจำแนกได้ดีขึ้นจากเดิมที่ค่า UA เพิ่มจากร้อยละ 36.36 เป็นร้อยละ 68.00

ตาราง 10 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปลูกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ

Classified data	Reference data					Total	PA (%)	UA (%)
	Vegetation	Water	Built-up	Bare soil				
Vegetation	36	2	2	4	44	92.3	81.82	
Water	0	7	0	0	7	70.00	100	
Built-up	1	0	16	6	23	72.72	69.57	
Bare soil	2	1	4	19	26	65.51	73.07	
Total	39	10	22	29	100			
OA (%)	78.00							
Kappa (%)	77.55							

Note: PA= producer accuracy, UA = user accuracy, OA = overall accuracy, and Kappa = kappa coefficient

จากตาราง 10 ผล Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปลูกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ของข้อมูลภาพถ่ายดาวเทียม Landsat 8 วันที่ 10 ธันวาคม 2563 พบว่า ผลการประเมินค่าความถูกต้องโดยรวม (Overall accuracy) เท่ากับร้อยละ 78 ค่าสัมประสิทธิ์แคปปา (K_i) เท่ากับร้อยละ 77.55 ค่าทั้งสองอยู่ในเกณฑ์ดีแต่เมื่อพิจารณา ค่าความคลาดเคลื่อน (Errors) และความแม่นยำ (Accuracy) แยกตามประเภทของการใช้ที่ดินและสิ่งปลูกคลุมดินแสดงให้เห็นว่าพื้นที่พืชพรรณ (Vegetation) พื้นที่น้ำ และพื้นที่ว่างเปล่า มีความถูกต้องในการจำแนกมากกว่าพื้นที่สิ่งปลูกสร้างซึ่งแสดงให้เห็นว่าพื้นที่สิ่งปลูกสร้างมีความถูกต้องในการจำแนกน้อยกว่าพื้นที่อื่นเนื่องจากอาจมีค่าการสะท้อนแสงที่ใกล้เคียงกับพื้นที่อื่นๆ เช่นใกล้เคียงกับพื้นที่ว่างเปล่า ทำให้เกิดการปะปนกันของข้อมูล

ตาราง 11 Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีวิเคราะห์เชิงวัตถุ ร่วมกับออนโทโลยี

Classified data	Reference data					Total	PA (%)	UA (%)
	Vegetation	Water	Built-up	Bare soil				
Vegetation	36	2	2	4	44	92.3	81.82	
Water	0	7	0	0	7	77.78	100	
Built-up	1	0	18	5	24	77.27	73.91	
Bare soil	2	0	3	20	25	70.00	80.77	
Total	39	9	22	30	100			
OA (%)						81.00		
Kappa (%)						80.61		

Note: PA= producer accuracy, UA = user accuracy, OA = overall accuracy, and Kappa = kappa coefficient

จากตาราง 11 ผล Error matrix ของการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ร่วมกับออนโทโลยี ของข้อมูลภาพถ่ายดาวเทียม Landsat 8 วันที่ 10 ธันวาคม 2563 พบว่าผลการประเมินค่าความถูกต้องโดยรวม (Overall accuracy) เท่ากับร้อยละ 81 ค่าสัมประสิทธิ์แคปปา (K_p) เท่ากับร้อยละ 80.61 ค่าทั้งสองอยู่ในเกณฑ์ดีแต่เมื่อพิจารณา ค่าความคลาดเคลื่อน (Errors) และความแม่นยำ (Accuracy) แยกตามประเภทของการใช้ที่ดินและสิ่งปกคลุมดินแสดงให้เห็นว่าพื้นที่พืชพรรณ (Vegetation) พื้นที่น้ำ และพื้นที่ว่างเปล่า มีความถูกต้องในการจำแนกมากกว่าพื้นที่สิ่งปลูกสร้างซึ่งแสดงให้เห็นว่าพื้นที่สิ่งปลูกสร้างมีความถูกต้องในการจำแนกน้อยกว่าพื้นที่อื่นเนื่องจากอาจมีค่าการสะท้อนแสงที่ใกล้เคียงกับพื้นที่อื่นๆ เช่น ใกล้เคียงกับพื้นที่ว่างเปล่า ทำให้เกิดการปะปนกันของข้อมูลสอดคล้องกับผลจากตาราง 10 แต่การใช้วิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุ ร่วมกับออนโทโลยีทำให้ประสิทธิภาพในการจำแนกประเภทนั้นๆ ดีขึ้น เช่น ประเภทสิ่งปลูกสร้างจำแนกได้ดีขึ้นจากเดิมที่ค่า UA เพิ่มจากร้อยละ 69.57 เป็นร้อยละ 73.91

บทที่ 5

สรุป อภิปรายผล และข้อเสนอแนะ

การวิจัยเรื่องการวิเคราะห์ข้อมูลภาพเชิงวัตถุรวมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก สามารถสรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะแนวทางเพื่อการประยุกต์ใช้ในอนาคตดังต่อไปนี้

สรุป

การวิจัยครั้งนี้เป็นการวิเคราะห์ข้อมูลภาพเชิงวัตถุรวมกับออนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก ใช้ข้อมูลภาพถ่ายดาวเทียม Landsat 8 วันที่ 26 ตุลาคม 2558 และวันที่ 10 ธันวาคม 2563 โดยใช้พื้นที่เฉพาะอำเภอเมือง จังหวัดพิษณุโลกเป็นตัวแทนของพื้นที่อำเภออื่นๆ ในจังหวัดพิษณุโลกเนื่องจากพื้นที่อำเภอเมือง มีความหลากหลายของพื้นที่เช่น เป็นพื้นที่ราบลุ่ม พื้นที่เมือง พื้นที่การเกษตร และพื้นที่ว่างเปล่า เป็นต้น ในการวิเคราะห์ข้อมูลภาพเชิงวัตถุรวมกับออนโทโลยีทำการแบ่งส่วนการวิเคราะห์ข้อมูลเป็น 2 ส่วนหลักคือ ส่วนแรกเป็นการวิเคราะห์ข้อมูลภาพเชิงวัตถุแบบปกติทั่วไปและส่วนสองเป็นการนำวิธีออนโทโลยีเข้ามาร่วมกันวิเคราะห์สำหรับการจำแนกประเภทการใช้ที่ดินและสิ่งปลูกคลุมดินในพื้นที่ศึกษา

เกณฑ์ที่ใช้ในการวิเคราะห์ข้อมูลภาพเชิงวัตถุจะมีการแบ่งส่วนภาพด้วยวิธีการ Multi-resolution Segmentation มีกำหนดค่าพารามิเตอร์ได้แก่ พารามิเตอร์ขนาดเท่ากับ 100 พารามิเตอร์รูปร่างเท่ากับ 0.1 พารามิเตอร์สี เท่ากับ 0.9 พารามิเตอร์ความหนาแน่นเท่ากับ 0.5 และพารามิเตอร์ความเรียบ 0.5 ตามลำดับ เพื่อให้ได้ขนาดของวัตถุที่มีขนาดเหมาะสมกับการจำแนกประเภทการใช้ที่ดินและสิ่งปลูกคลุมดิน สามารถสกัดคุณลักษณะ (Feature Extraction) จากคุณสมบัติของการสะท้อนช่วงคลื่นและกำหนดโครงสร้างของลำดับชั้นในจำแนกข้อมูล จากคุณสมบัติของวัตถุที่ต้องการ เช่น ค่าเฉลี่ยช่วงคลื่น (Mean) ค่าความสว่าง (Brightness) ค่าส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ค่าส่วนต่างสูงสุด (Max. diff.) ค่าการสะท้อนของช่วงคลื่นแบนด์ 2-7 รวมค่าดัชนีผลต่างพืชพรรณ (NDVI) ค่าดัชนีผลต่างความชื้นของน้ำ (NDWI) และค่าดัชนีผลต่างสิ่งปลูกสร้าง (NDBI) สามารถแบ่งประเภทของการใช้ที่ดินและสิ่งปลูกคลุมดิน 4 ประเภทได้แก่ พื้นที่พืชพรรณ พื้นที่น้ำ พื้นที่ว่างเปล่า และพื้นที่สิ่งปลูกสร้าง สามารถเป็นปัจจัยหนึ่งในกระบวนการวิเคราะห์ออนโทโลยี โดยส่งออกข้อมูลที่ได้ในรูปแบบไฟล์ CSV จากนั้นแปลงให้อยู่ในรูปแบบไฟล์ OWL เพื่อให้ออนโทโลยีสามารถอ่านค่าได้

การวิเคราะห์โครงสร้างออนโทโลยีเกิดจากการสร้างแนวคิดของออนโทโลยีที่ได้จากโดเมนความรู้ที่รวบรวมจากข้อมูลผู้เชี่ยวชาญจากเอกสารงานวิจัยเกี่ยวข้อง และข้อมูลภาพถ่ายดาวเทียม เพื่อนำมาสู่กระบวนการหาความสัมพันธ์ สร้างกฎการจำแนกที่ได้จากโดเมนความรู้จากนั้นเปลี่ยนกฎให้อยู่ในรูปแบบ OWL โดยใช้ภาษา SWRL สร้างกฎในการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินและใช้ reasoner เป็นตัวจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยออนโทโลยี แต่ข้อมูลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินอยู่ในรูปแบบ OWL จึงต้องทำการแปลงเป็นรูปแบบ Shapefile เพื่อนำไปเปรียบเทียบประเมินค่าความถูกต้องของการจำแนกประเภท และผลการวิจัยพบว่าการวิเคราะห์ข้อมูลภาพเชิงวัตถุร่วมกับออนโทโลยีแสดงให้เห็นว่าสามารถนำไปใช้จำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินในพื้นที่อำเภอเมือง จังหวัดพิษณุโลกได้ โดยผลการประเมินความถูกต้องจากข้อมูล Google Earth นำมาเปรียบเทียบกับผลที่ได้จากการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินในรูปของเมทริกซ์ความผิดพลาด (Error matrix) ผลการจำแนกมีความถูกต้องอยู่ในเกณฑ์ดีมีค่าความถูกต้องโดยภาพรวมสูงกว่าร้อยละ 80 ค่า Kappa coefficient สูงกว่าร้อยละ 70

ผลการวิจัยชี้ให้เห็นว่าการนำเข้าข้อมูลภาพถ่ายดาวเทียม Landsat 8 ทั้งสองช่วงเวลาคือ ข้อมูลภาพวันที่ 26 ตุลาคม 2558 และข้อมูลภาพวันที่ 10 ธันวาคม 2563 เพื่อใช้ในการเปรียบเทียบผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินในพื้นที่อำเภอเมือง จังหวัดพิษณุโลกแสดงให้เห็นว่าการใช้ที่ดินในเวลาดังกล่าวมีการเปลี่ยนแปลงอย่างเห็นได้ชัดจากภาพ 30 และ 31 แสดงผลการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินของวันที่ 10 ธันวาคม 2563 และ วันที่ 26 ตุลาคม 2558 เป็นไปในทิศทางเดียวกันคือ พื้นที่พืชพรรณจะมีจำนวนมากที่สุด รองลงมาเป็นพื้นที่ว่างเปล่า พื้นที่สิ่งปลูกสร้าง และพื้นที่น้ำ แต่สังเกตได้ว่าเมื่อเปรียบเทียบระหว่างช่วงเวลาที่ทั้งสองจะพบว่าพื้นที่ที่มีการเปลี่ยนแปลงไปอย่างเห็นได้ชัดคือพื้นที่พืชพรรณมีจำนวนลดลง และพื้นที่สิ่งปลูกสร้างมีจำนวนเพิ่มมากขึ้นสาเหตุมาจากการเพิ่มจำนวนประชากร การขยายตัวของชุมชนเมืองเข้าสู่ชุมชนชนบททำให้มีการรื้อถอนพื้นที่พืชพรรณและมีแนวโน้มลดลงเนื่องจากการเปลี่ยนพื้นที่ไปเป็นพื้นที่สิ่งปลูกสร้างหรือประชากรรุ่นใหม่ ๆ ไม่นิยมประกอบอาชีพทางการเกษตร รวมถึงพื้นที่ป่าไม้ถูกบุกรุก ถูกนำไปใช้เป็นพื้นที่ทำสวน ทำไร่ จากผลที่เกิดขึ้นแสดงให้เห็นว่าการบูรณาการการวิเคราะห์ข้อมูลภาพเชิงวัตถุกับวิธีออนโทโลยีนอกเหนือวิธีการวิเคราะห์ข้อมูลภาพเชิงวัตถุแบบเดิมช่วยให้มีประสิทธิภาพในการจำแนกมากขึ้นและถ้ามีการเพิ่มเติมองค์ความรู้ในส่วนโดเมนความรู้เชื่อว่าจะสามารถจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดินได้หลากหลายประเภทมากขึ้นเช่นเดียวกัน รวมทั้งสามารถเป็นรูปแบบหรือวิธีการหนึ่งสำหรับช่วยให้ผู้เชี่ยวชาญที่ต้องการแปลตีความข้อมูลภาพถ่ายดาวเทียมนำไปใช้ในการจำแนกประเภทการใช้ที่ดินในอนาคตได้

อภิปรายผลการวิจัย

1. การวิเคราะห์ข้อมูลภาพเชิงวัตถุเป็นหลักการของการจำแนกข้อมูลภาพเพื่อใช้ในการตีความหรืออธิบายปรากฏการณ์หรือสิ่งที่ปรากฏ โดยมีวิธีการที่สำคัญคือการแบ่งส่วนภาพ (Segmentation) เนื่องจากการแบ่งส่วนภาพจะทำการแบ่งภาพ (Image) ออกเป็นพื้นที่ (Region) หลายๆ ส่วน หรือวัตถุ (Object) หลายๆ ชนิดขึ้นอยู่กับคุณลักษณะของการเป็นเนื้อเดียวกัน หรือมีความสัมพันธ์กัน (Relatively Homogeneous Areas) เพื่อที่จะสร้างวัตถุมาอธิบายชั้นข้อมูล การวิเคราะห์ภาพเชิงวัตถุประกอบด้วยกระบวนการ 2 ขั้นตอนคือ การแบ่งส่วนภาพ และการจำแนกวัตถุภาพ โดยการแบ่งส่วนภาพด้วยวิธีการ Multi-resolution Segmentation มีกำหนดค่าพารามิเตอร์ได้แก่ พารามิเตอร์ขนาด พารามิเตอร์รูปร่าง พารามิเตอร์สี พารามิเตอร์ความหนาแน่น และพารามิเตอร์ความเรียบ แสดงให้เห็นว่าการกำหนดขนาดในการสร้างวัตถุจากภาพโดยเกี่ยวข้องกับขนาดของวัตถุ ซึ่งจะเป็นตัวกำหนดความแตกต่างของขนาดวัตถุที่ได้ ถ้าขนาดของวัตถุนั้นมีความแตกต่างกันมาก ควรต้องกำหนดค่าให้น้อยเพื่อไม่ให้กลุ่มของวัตถุมากขึ้นมิฉะนั้นจะเกิดการปะปนกันของข้อมูล มีผลทำให้ความเป็นเนื้อเดียวกันจะมีค่าที่ต่ำลงไปด้วย พารามิเตอร์รูปร่างหรือสี จะแปรผันตามความสัมพันธ์ระหว่างรูปร่างกับสีของข้อมูล จะพิจารณาจากการให้ค่าน้ำหนักของรูปร่างหรือค่าน้ำหนักของสีมากกว่ากัน ถ้ากำหนดค่าสีมากกว่าต้องพิจารณาจากค่าการสะท้อนตามช่วงคลื่นที่เลือก ซึ่งในภาพจากดาวเทียมที่มีค่าของสีแต่ละวัตถุที่ชัดเจน จะส่งผลให้น้ำหนักของสีมากกว่ารูปร่าง ในขณะที่รูปร่างจะพิจารณาเพียงรูปร่างหรือรูปทรงของวัตถุที่ปรากฏบนภาพจากดาวเทียม และพารามิเตอร์ความอัดแน่นหรือความเรียบ เป็นการกำหนดปัจจัยด้านความเรียบและการเกาะกลุ่มจะใช้กับวัตถุที่มีความแตกต่างของขนาดเพื่อทำการแยกวัตถุขนาดเล็กออกจากวัตถุที่มีขนาดใหญ่ ส่วนค่าการสะท้อนแสงนั้นไม่ชัดเจน ซึ่งเป็นค่าที่ช่วยในการให้รูปทรงของวัตถุ ซึ่งงานวิจัยนี้จะไม่นำค่ารูปร่าง แต่ใช้ค่าการสะท้อนตามช่วงคลื่นจึงเน้นที่ค่าสีมากกว่าค่าอื่นๆ สอดคล้องกับ Chu, Z., Liu, Z., & Gu, H. (2016) ทำให้มีการกำหนดค่าพารามิเตอร์เน้นไปที่ค่าสีมากกว่าค่ารูปร่าง การสกัดคุณลักษณะของวัตถุจะใช้เพียงค่าคุณสมบัติการสะท้อนช่วงคลื่นของแบนด์จากข้อมูลภาพดาวเทียม อาจไม่เพียงพอจำเป็นต้องนำค่าดัชนีผลต่างเข้ามาเป็นคุณสมบัติในการสกัดคุณลักษณะของวัตถุ เช่น ค่าดัชนีพืชพรรณ ค่าดัชนีผลต่างความชื้นของน้ำ และค่าดัชนีสิ่งปลูกสร้าง เป็นต้น เป็นผลให้สามารถช่วยสกัดคุณลักษณะได้ดีขึ้น

2. การวิเคราะห์ออนโทโลยีเป็นแนวคิดที่นำมาประยุกต์ใช้เพื่อการจัดความรู้และนำเสนอความรู้ในรูปแบบที่อาศัยกลุ่มแนวคิดและความสัมพันธ์ระหว่างกันอยู่ภายใต้ขอบเขตที่สนใจ ออนโทโลยีเข้ามามีบทบาทสำคัญสำหรับการบรรยายเชิงความหมายในลักษณะของการใช้แนวคิดเดียวเพื่อลดหรือตัดทอนแนวคิดหรือลดคำศัพท์ที่มีความสับสนรวมถึงการสนับสนุนการแลกเปลี่ยน การค้นคืนของสารสนเทศต่อการพัฒนาระบบฐานความรู้ และยังเป็นกำหนดนิยามของแนวคิดในขอบเขตของ

ความรู้เรื่องใดเรื่องหนึ่งที่สนใจถูกกำหนดด้วยคุณสมบัติที่เกี่ยวข้องกับแนวคิดและลักษณะความสัมพันธ์ตรรกะในการเปลี่ยนแปลงความสัมพันธ์สำหรับสร้างความหมาย โดยสร้างเป็นองค์ความรู้ที่เกี่ยวข้องกับด้านเหล่านั้น และจะแสดงในลักษณะโครงสร้างของความสัมพันธ์ผ่านการใช้คลาส หรือแนวคิด ของความสัมพันธ์ระหว่างคลาสและคุณสมบัติของคลาส จะเห็นได้ว่าออนโทโลยีสามารถเข้ามาช่วยในการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินได้เหมือนกับงานวิจัยนี้ได้นำออนโทโลยีเข้ามาช่วยให้การจำแนกการใช้ที่ดินและสิ่งปกคลุมดินจากข้อมูลภาพถ่ายดาวเทียม ซึ่งสอดคล้องกับ Almendros-Jimenez (2012) เสนอกรอบสำหรับการจำแนกภาพถ่ายดาวเทียมในการจำแนกมหาสมุทรด้วยออนโทโลยี และ Belgiu (2014) จัดประเภทเป็นประเภทอาคารต่างๆ โดยใช้โดเมนออนโทโลยี แสดงให้เห็นว่าการจำแนกประเภทจากข้อมูลภาพถ่ายดาวเทียมสามารถใช้ออนโทโลยีผ่านการสร้างแบบจำลองทางออนโทโลยีได้เช่นกัน

3. ข้อมูลภาพถ่ายดาวเทียมเป็นแหล่งข้อมูลที่สามารถนำมาใช้ในการศึกษาวิเคราะห์รูปแบบการใช้ประโยชน์ที่ดิน ช่วยให้นักวิจัยสามารถประเมินและติดตามการเปลี่ยนแปลงของสิ่งปกคลุมดินและการใช้ที่ดินเมื่อเวลาผ่านไป ในบริบทของการใช้ประโยชน์ที่ดินสามารถนำมาประยุกต์ใช้กับการจำแนกประเภทสิ่งปกคลุมดินภาพถ่ายดาวเทียมสามารถใช้เพื่อจำแนกสิ่งปกคลุมดินประเภทต่างๆ ไม่ว่าจะเป็นป่าไม้ พื้นที่เกษตรกรรม เขตเมือง แหล่งน้ำ และพื้นที่แห้งแล้ง การจำแนกประเภทนี้ช่วยในการทำความเข้าใจเกี่ยวกับการกระจายเชิงพื้นที่ของชั้นสิ่งปกคลุมดินและการเปลี่ยนแปลงเมื่อเวลาผ่านไป ส่วนการตรวจจับการเปลี่ยนแปลง การเปรียบเทียบภาพถ่ายดาวเทียมที่ได้รับในช่วงเวลาต่างๆ ทำให้สามารถตรวจจับและวิเคราะห์การเปลี่ยนแปลงรูปแบบการใช้ที่ดินได้ ข้อมูลนี้มีความสำคัญอย่างยิ่งต่อการติดตามการตัดไม้ทำลายป่า การขยายตัวของเมือง การทำการเกษตร และการเปลี่ยนแปลงการใช้ที่ดินอื่นๆ ที่อาจส่งผลกระทบต่อสิ่งแวดล้อม ส่วนที่เกี่ยวข้องการวางผังเมือง ข้อมูลภาพถ่ายจากดาวเทียมสามารถช่วยนักวางผังเมืองในการประเมินการขยายตัวของเมืองและระบุตำแหน่งที่เหมาะสมสำหรับการพัฒนาโครงสร้างพื้นฐาน ช่วยในการประเมินการกระจายเชิงพื้นที่ของเขตเมือง การระบุพื้นที่ที่มีความหนาแน่นของประชากรสูง และการวางแผนการใช้ที่ดินอย่างมีประสิทธิภาพภายในสภาพแวดล้อมของเมือง ส่วนเรื่องการประเมินผลกระทบสิ่งแวดล้อม ข้อมูลภาพถ่ายดาวเทียมช่วยให้สามารถประเมินผลกระทบสิ่งแวดล้อมที่เกิดจากกิจกรรมต่างๆ อาทิเช่น การทำเหมือง การก่อสร้าง และการพัฒนาที่ดิน ช่วยในการตรวจสอบขอบเขตของความเสื่อมโทรมของที่ดิน การตัดไม้ทำลายป่า และการสูญเสียที่อยู่อาศัย อำนวยความสะดวกในการตัดสินใจและวางแผนการใช้ที่ดินอย่างยั่งยืนได้ดีขึ้น และส่วนที่เกี่ยวข้องกับการวางแผนการใช้ที่ดินและการแบ่งเขตข้อมูลภาพถ่ายดาวเทียมช่วยในการวางแผนและการแบ่งเขตการใช้ที่ดินโดยการให้ข้อมูลที่ถูกต้องและเป็นปัจจุบันเกี่ยวกับรูปแบบการใช้ที่ดินที่มีอยู่ ช่วยในการกำหนดพื้นที่ที่เหมาะสมสำหรับที่อยู่อาศัย พาณิชยกรรม อุตสาหกรรม และการเกษตร โดยคำนึงถึงปัจจัยด้านสิ่งแวดล้อม ความพร้อมของ

โครงสร้างพื้นฐาน และการพิจารณาทางสังคม จากที่กล่าวมาจะเห็นได้ว่าข้อมูลภาพถ่ายดาวเทียมมีความสำคัญที่สามารถนำมาประยุกต์ใช้กับงานด้านการใช้ประโยชน์ที่ดินที่หลากหลาย เช่นเดียวกับงานวิจัยนี้ได้ใช้วิธีการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกับบ่อนโทโลยีเพื่อวิเคราะห์การใช้ที่ดิน ซึ่งสามารถนำมาใช้เป็นแนวทางในการประยุกต์กับการใช้ที่ดินในลักษณะอื่นๆ นอกเหนือจากเพียงแค่การจำแนกประเภทของการใช้ที่ดินและสิ่งปกคลุมดินที่ได้จากข้อมูลภาพถ่ายดาวเทียม

ข้อเสนอแนะ

ผลจากการวิจัยการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกับบ่อนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในจังหวัดพิษณุโลก ผู้วิจัยมีข้อเสนอแนะสำหรับนำไปใช้ในการศึกษาวิจัยในอนาคต ดังต่อไปนี้

1. ควรนำวิธีการวิจัยที่ได้จากการวิจัยในครั้งนี้ไปประยุกต์ใช้กับพื้นที่อื่นๆ ที่มีลักษณะเชิงพื้นที่เหมือนหรือคล้ายกับพื้นที่ศึกษา เพื่อเพิ่มความถูกต้องและเพิ่มประสิทธิภาพของการจำแนกประเภทการใช้ที่ดินและสิ่งปกคลุมดิน
2. ควรนำวิธีการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยบ่อนโทโลยีไปทดสอบกับพื้นที่อื่นๆ ที่มีความแตกต่างของลักษณะเชิงพื้นที่ เช่น ภูมิประเทศ ดิน น้ำ และพื้นที่การเกษตร เป็นต้น รวมถึงทดสอบกับชุดข้อมูลที่มีหลายช่วงเวลา เพื่อใช้ในการประเมินความถูกต้องว่ามีผลลัพธ์ที่ได้แตกต่างกันหรือไม่
3. ควรศึกษาเพิ่มเติมเกี่ยวกับการประยุกต์ใช้ออนโทโลยีในการจำแนกการใช้ที่ดินและสิ่งปกคลุมดิน โดยการเพิ่มเติมในส่วนของความรู้หรือองค์ความรู้ให้เพิ่มมากขึ้นเพื่อพัฒนาบ่อนโทโลยีในการจำแนกประเภทที่หลากหลายมากขึ้น เพราะการกำหนดแนวคิดและความสัมพันธ์ให้กับแนวคิดในบ่อนโทโลยีจะต้องมีความสอดคล้องกับสิ่งที่จะศึกษาให้มากที่สุด และทำให้บ่อนโทโลยีมีประสิทธิภาพมากที่สุด
4. ควรนำการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมร่วมกับบ่อนโทโลยีเพื่อวิเคราะห์การใช้ที่ดินในลักษณะหรือประเภทอื่นๆ เช่น การตรวจจับและการวิเคราะห์การเปลี่ยนแปลงการใช้ที่ดิน การวิเคราะห์การวางผังเมือง การวางแผนการใช้ที่ดินในพื้นที่ต่างๆ เป็นต้น

ข้อจำกัดของงานวิจัย

งานวิจัยการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินด้วยบ่อนโทโลยีมีข้อจำกัดในด้านของข้อมูลภาพถ่ายดาวเทียมเนื่องจากใช้ข้อมูลภาพถ่ายดาวเทียม Landsat 8 เป็นดาวเทียมประเภทดาวเทียมสำรวจทรัพยากรธรรมชาติมีความละเอียดเชิงพื้นที่ 30 เมตร จัดอยู่ในความละเอียดเชิงพื้นที่ระดับกลาง ถึงจะครอบคลุมพื้นที่การทำงานได้มากกว่าข้อมูลภาพถ่ายดาวเทียมที่ค่าความละเอียดเชิงพื้นที่ระดับสูงก็ตาม แต่ต้องแลกมาด้วยความชัดของจุดภาพทำให้สามารถจำแนกการใช้ที่ดินและสิ่ง

ปกคลุมดินได้ในระดับไม่สูงมากนัก รวมถึงการใช้อนโทโลยีเข้ามาช่วยในการจำแนกการใช้ที่ดินและสิ่งปกคลุมดินความแม่นยำขึ้นอยู่กับความพร้อมของโดเมนอนโทโลยีที่กำหนดไว้ ซึ่งหมายความว่า การสร้างโดเมนความรู้ของอนโทโลยีที่ไม่ดีจะส่งผลให้เกิดความคล้ายคลึงกันทางความหมายระหว่างคลาสของโดเมน นอกจากนี้ความคล้ายคลึงกันจะถูกคำนวณจากลำดับชั้นความสัมพันธ์อาจทำให้เกิดการผิดพลาดในการจำแนกได้



บรรณานุกรม

- Almendros-Jimenez, J. M., Domene, L., & Piedra-Fernandez, J. A. (2012). A framework for ocean satellite image classification based on ontologies. *IEEE Journal of selected topics in applied earth observations and remote sensing*, 6(2), 1048-1063.
- Andres, S., Arvor, D., & Pierkot, C. (2012). Towards an ontological approach for classifying remote sensing images. 2012 Eighth International Conference on Signal Image Technology and Internet Based Systems,
- Antoniou, G., & Van Harmelen, F. (2003). Web Ontology Language: OWL. Handbook on Ontologies in Information Systems. In: Springer-Verlag.
- Benjamins, V. R., & Gómez-Pérez, A. (2000). Knowledge-system technology: ontologies and problem-solving methods. *Department of Social Science Informatics, University of Amsterdam, The Netherlands*.
- Bouyerbou, H., Bechkoum, K., Benblidia, N., & Lepage, R. (2014). Ontology-based semantic classification of satellite images: Case of major disasters. 2014 IEEE Geoscience and Remote Sensing Symposium,
- Chansirawat, T., & Polsawat, A. (2018). การพัฒนาออนโทโลยีการท่องเที่ยวเชิงสุขภาพ ใน ประเทศไทย. *FEU Academic Review*, 12(4), 113-113.
- Chu, Z., Liu, Z., & Gu, H. (2016). Objected-oriented remote sensing image classification method based on geographic ontology model. IOP Conference Series: Earth and Environmental Science,
- Congedo, L. (2016). Semi-automatic classification plugin documentation. *Release*, 4(0.1), 29.
- Definiens. (2007). *Definiens Developer 7 User Guide*. Definiens AG.
- Dousset, B., & Gourmelon, F. (2003). Satellite multi-sensor data analysis of urban surface temperatures and landcover. *ISPRS journal of photogrammetry and remote sensing*, 58(1-2), 43-54.
- Forestier, G., Puissant, A., Wemmert, C., & Gançarski, P. (2012). Knowledge-based region labeling for remote sensing image interpretation. *Computers, Environment and*

Urban Systems, 36(5), 470-480.

Gregrio, A., & Jansen, J. (2000). Land cover classification system (LCCS); Classification concepts and user manual for software version 2.

Gu, H., Li, H., Yan, L., & Blaschke, T. (2016). An object-based semantic classification method of high resolution satellite imagery using ontology.

Kamavisdar, P., Saluja, S., & Agrawal, S. (2013). A survey on image classification approaches and techniques. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(1), 1005-1009.

Kozaki, K., Sunagawa, E., Kitamura, Y., & Mizoguchi, R. (2005). Hozo: an ontology development environment-treatment of "role concept" and dependency management. Proc. of Posters and Demos of the 4th International Semantic Web Conference, ISWC,

Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.

Luo, H., Li, L., Zhu, H., Kuai, X., Zhang, Z., & Liu, Y. (2016). Land cover extraction from high resolution ZY-3 satellite imagery using ontology-based method. *ISPRS International Journal of Geo-Information*, 5(3), 31.

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), 1425-1432.

Messaoudi, W., Farah, I. R., & Solaiman, B. (2014). A new ontology for semantic annotation of remotely sensed images. 2014 1st International Conference on Advanced Technologies for Signal and Image Processing (ATSIP),

Natya, S., & Rehna, V. (2016). Land cover classification schemes using remote sensing images: a recent survey. *Br. J. Appl. Sci. Technol*, 13(4), 1-11.

Norta, A., Carlson, L., & Yangarber, R. (2010). Utility survey of ontology tools. *Department of Computer Science, Department of Linguistics-University of Helsinki, Finland*, 62, 63-65.

Noy, N. F., & McGuinness, D. L. (2001). Ontology development 101: A guide to creating your first ontology. In: Stanford knowledge systems laboratory technical report KSL-01-05 and

- Pattanasak, P. (2020). การทำแผนที่การใช้ประโยชน์ที่ดินด้วยการจำแนกข้อมูลเชิงวัตถุ จากภาพถ่ายดาวเทียมไทยโชต. *The Journal of Spatial Innovation Development*, 1(2), 83-90.
- Phiri, D., & Morgenroth, J. (2017). Developments in Landsat land cover classification methods: A review. *Remote Sensing*, 9(9), 967.
- Prasad, M. S., & Krishna, I. V. M. (2015). Techniques in Image Classification; A Survey. *Global Journals of Research in Engineering*, 15(F6), 17-32.
- Rajbhandari, S., Aryal, J., Osborn, J., Lucieer, A., & Musk, R. (2019). Leveraging machine learning to extend ontology-driven geographic object-based image analysis (O-GEOBIA): A case study in forest-type mapping. *Remote Sensing*, 11(5), 503.
- Salah, M. (2017). A survey of modern classification techniques in remote sensing for improved image classification. *Journal of Geomatics*, 11(1), 21.
- Sivilai, S., & Snae, C. (2013). ระบบเฝ้าระวังและวางแผนสุขภาพสำหรับผู้สูงอายุด้วยหลักการออนไลน์. *Journal of Community Development Research (Humanities and Social Sciences)*(2), 83-97%V 84. <https://www.journal.nu.ac.th/JCDR/article/view/293>
- Sujaree, T., Waisurasingha, C., Klungboonkrong, P., Sridet, A., Waisurasingha, C., & Pattanapiroj, S. (2021). การประยุกต์ใช้ตัวจำแนกแบบจักรแห่งการเรียนรู้ในการ วิเคราะห์ข้อมูลภาพถ่ายดาวเทียมเชิงผสมผสาน ระหว่างแบบพาสซีฟ และแบบแอคทีฟเพื่อประเมินการเปลี่ยนแปลงการใช้ที่ดิน: กรณีศึกษาเมืองขอนแก่น. *KKU Research Journal (Graduate Studies)*, 21(1), 14-25.
- USGS. (2017). *Landsat 8 Instruments*.
- USGS. (2019). *Landsat 8 (L8) data users handbook Version 5.0* U.S. Geological Survey.
- White, M. A., de Beurs, K. M., Didan, K., Inouye, D. W., Richardson, A. D., Jensen, O. P., O'keefe, J., Zhang, G., Nemani, R. R., & van Leeuwen, W. J. (2009). Intercomparison, interpretation, and assessment of spring phenology in North America estimated from remote sensing for 1982–2006. *Global Change Biology*, 15(10), 2335-2359.
- เขาวลิต ศิลปทอง. (2553). หลักการเบื้องต้นการสำรวจข้อมูลจากระยะไกล (*Remote Sensing*). สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน).
- เปรม ศิริคงเส้ง. (2560). การจำแนกการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินของจังหวัดภูเก็ตจากภาพถ่ายดาวเทียม แลนด์แซท 8 ด้วยคุณสมบัตินทางซีพลักษณะ มหาวิทยาลัย สงขลานครินทร์].
- เพ็ญพรรณ บุญเดิม และวิชัย เยี่ยงวีรชน. (2555). การเปรียบเทียบกระบวนการจำแนกข้อมูลด้วยวิธีเชิง

- จุดภาพ และเชิงวัตถุโดยใช้ภาพถ่ายดาวเทียม SPOT 5. การประชุมวิชาการวิศวกรรมโยธา
แห่งชาติ ครั้งที่ 17, อุตรธานี.
- กรมพัฒนาที่ดิน. (2563). บัญชีรายการกรมพัฒนาที่ดิน. กรมพัฒนาที่ดิน. Retrieved 14 เมษายน
2563 from <http://sql.ddd.go.th/ddddata/mapsoilB1.html>
- กองนโยบายและแผนการใช้ที่ดิน. (2562). แผนการใช้ที่ดิน ตำบลมะขามสูง อำเภอเมือง จังหวัดพิษณุโลก.
- กิตติศักดิ์ ศรีกลาง. (2557). การสำรวจข้อมูลระยะไกล (*Remote Sensing*). กรมแผนที่ทหาร.
- ศราวุฒิ ไวยสุศรี. (2561). การประยุกต์ใช้ข้อมูลดาวเทียม เพื่อติดตามการเปลี่ยนแปลงการใช้ประโยชน์
ที่ดินโดยรอบพื้นที่ เขื่อนทองคำบริเวนลุ่มน้ำห้วย น้ำ ฮวยจังหวัดเลย. Proceeding National
& International Conference,
จังหวัดพิษณุโลก. (2563, 19 มิถุนายน 2563). จังหวัดพิษณุโลก. Retrieved 30 เมษายน from
<http://www2.phitsanulok.go.th/home>
- ชินวัชร สุรัสวดี และประคุณ พงษ์ภักทรานนท์. (2556). การจำแนกประเภทสิ่งปกคลุมดินสำหรับลุ่มน้ำ
คลองอู่ตะเภา จังหวัดสงขลา ประเทศไทย โดยใช้ข้อมูล Landsat ETM+. การประชุมวิชาการ
แห่งชาติ มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตกำแพงแสน ครั้งที่ 10,
ตรังราภรณ์ ไชยนา และวิชัย เยี่ยงวีรชน. (2556). การจำแนกเชิงวัตถุของภาพถ่ายดาวเทียม THEOS
โดยใช้เทคนิคการแบ่งส่วนเชิงลำดับชั้น. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 18,
เชียงใหม่.
- ทบทอง ชันเจริญ. (2558). พื้นฐานของการรับรู้จากระยะไกล. มหาวิทยาลัยราชภัฏรำไพพรรณี.
- ทบทอง ชันเจริญ และวิระ ศรีมาลา. (2560). วิธีการติดตามการเปลี่ยนแปลง ชายฝั่งกรณีศึกษา:
หมู่บ้านคลอง หก ต. เกาะ เปร็ด อ. แหลมสิงห์ จ. จันทบุรี. วารสาร วิจัย รำไพ พรรณี, 11(3),
170-183.
- ทรงกต ทศานนท์. (2555). หลักการรับรู้จากระยะไกล. สำนักวิชาวิทยาศาสตร์ มหาวิทยาลัยเทคโนโลยี
สุรนารี.
- ธีรวิษณุ วงษา และรัฐสิทธิ์ สุขะหุต. (2557). อนินโทยกับการจัดการความรู้. ข่าวสารคณะวิทยาศาสตร์
มช, 20, 1-3.
- นฤพนธ์ พนาวงค์ และจักรกฤษณ์ เสน่ห์. (2010). Search System for Attractions in Thailand
with Ontology and Name Matching. *Journal of Information Science and
Technology*, 1(2), 60-69.
- มาลี กาบมาลา, ลำปาง แม่นมาตย์ และครรชิต มาลัยวงศ์. (2549). อนินโทย: แนวคิดการพัฒนา.
Journal of Information Science, 24(1-3), 24-49.
- วิลาวัลย์ ประสมทรัพย์. (2564). เทคนิคการสำรวจระยะไกลสำหรับการจำแนกการใช้ประโยชน์ ที่ดิน

- และ สิ่งปกคลุมดินจากข้อมูลภาพถ่ายดาวเทียม Sentinel-2A โดย ใช้การวิเคราะห์ข้อมูลภาพเชิงวัตถุ. การ ประชุม วิชาการ วิศวกรรม โยธา แห่ง ชาติ ครั้งที่ 26, 26.
- สรรรค์ใจ กลิ่นดาว. (2550). การสำรวจจากระยะไกล : การประมวลผลภาพเชิงเลขเบื้องต้น. โอเดียนสโตร์.
- สรรรทราย สุทธิพันธ์, กัมปนาท ปิยะธำรงชัย และจันทร์จิรา พยัคฆ์เทศ. (2557). การเปรียบเทียบกระบวนการจำแนกข้อมูลระหว่างวิธีการจำแนกข้อมูลเชิงจุดภาพและวิธีการจำแนกข้อมูลเชิงวัตถุ โดยใช้ภาพถ่ายปรับความคมชัดจากดาวเทียมไทยโชต การประชุมวิชาการสารสนเทศ ภูมิศาสตร์นเรศวร ครั้งที่ 4, พิษณุโลก.
- สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ. (2552). ตำราเทคโนโลยีอวกาศและภูมิสารสนเทศศาสตร์. อมรินทร์พริ้นติ้งแอนด์พับลิชชิ่ง จำกัด (มหาชน).
- สุรัชชัย รัตนเสริมพงศ์. (2553). ความก้าวหน้าเทคโนโลยีภูมิสารสนเทศ. สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน).
- อภิเสฏฐ์ สุวรรณสะอาด. (2556). แนวทางการสำรวจข้อมูลจากระยะไกลในการจำแนกพื้นที่ที่ทิ้งร้างเพื่อเพิ่มประสิทธิภาพการใช้ดิน กรณีศึกษา ตำบลศาลายา อำเภอพุทธมณฑล จังหวัดนครปฐม.

A Review of Using Maximum Likelihood Classifier to Identify Land Use/Land Cover

Uttaporn Lertaramsaeng^{1,a} and Janjira Payakpate^{1,b}

¹ Department of Computer Science and Information Technology, Faculty of Science,
Naresuan University, 99 Moo. 9, Mueang, Phitsanulok, Thailand

^a uttapornl60@email.nu.ac.th, ^b janjirap@nu.ac.th

Abstract

Land Use and Land Cover (LU/ LC) map plays an important role in the digital society. These spatial data are applied to various applications such as monitoring, planning, management and etc. In order to generate the high accuracy LU/LC map, the suitable classifier is an important factor. The objective of this study is to review the process of classification, showing the Maximum Likelihood Classifier (MLC) steps and give some examples of MLC which is the most popular image classifier. Class signature is a representative of each class. Each pixel whose probability is closed to specific class signature; it would be in that class. Accuracy assessment is in the form of an error matrix table. Overall accuracy (OA) and Kappa coefficient of MLC are higher than the other classifiers. Examples of application on MLC are shown.

Keywords: Error Matrix Table, LU/LC, Maximum likelihood, Supervised Classification

Introduction

Land Use and Land Cover (LU/ LC) generally refers to the categorization of human activities and natural elements on the landscape. The examples of LU/LC are (1) detecting the change of urban area in India [1], (2) LU/LC map of Nakhonnayok province of Thailand [2], Monitoring LU/LC with GIS techniques [3] and etc. Both of LU/LC can be obtained from the satellite image depending on scientific and statistical methods of the image interpretation [4]. Five processes of interpretation are pre-works by orienting the image with the base map, image reading, image measurement, image analysis and thematic map. In image analysis process, classification methods effect to the interpretation results, mostly [5-6]. There are traditionally two types of classification: unsupervised image classification and supervised image classification. Unsupervised image classification is working under an algorithm which determines and groups pixels in classes. It can be operated as an automatic classification. While, supervised image classification requires a training set as references for grouping the pixels. The training set which is selected from the image is operated as data entry to supervised classification algorithm or supervised classifier. Result is displayed in the form of class signatures. Rest of the image is determined and grouped in class based on each class signature [5] [7]. Commonly used supervised classifier parallelepiped (PP), minimum distance (MD), K-nearest neighbor (KNN) and spectral angle mapper (SAM) [5], [8-10]. Maximum

Likelihood Classifier (MLC), a traditional classifier, seem to be effective to the accuracy of interpreting the satellite image. Due to the formats of its class signature are the class mean vectors and the covariance metrics [11]. Both of them can be obtained from the quality of training set, probably the quality of the satellite image. Reports also show that a large number of users prefers to employ this MLC to their applications [6, 11]. The purpose of this paper is to review on using MLC to identify LU/LC. It consists of the processes of satellite image classification, MLC method, application of MLC and, finally, conclusion.

Satellite Image Techniques for Identifying Land Use and Land Cover

There are two types of classification: unsupervised classification and supervised classification. According to Figure 1, unsupervised classification techniques operate all analysis based on the image classification algorithms such as K-means and Iterative Self-Organizing Data Analysis Technique (ISODATA) [9], [12, 13].

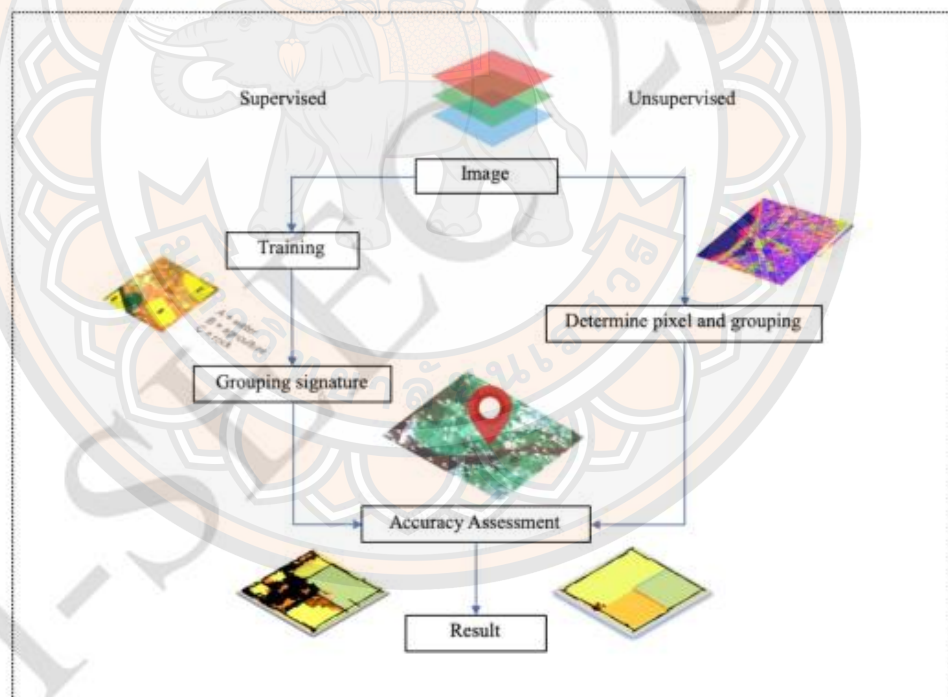


Figure 1 Supervised and unsupervised image classification

Supervised classifications analyst a satellite image, almost similar. Just only, this classification must generate the class signature from the training set before grouping the pixel into classes. Its

accuracy depends on the quality of training set. In order to achieve the good quality of training set, the spatial resolution of the satellite image should be considered. Figure 2 shows the suitable scene cover size (Local scale, Medium scale and Global scale) and spatial resolution.




Figure 2 Scale of Satellite Image Data (Adapt from [14-15])

Satellite image of the local scale size can be obtained from IKONOS, SPOT 5, Quickbird are helpful. At the medium scale size can be obtained from Landsat TM/ETM+/OLI, Sentinel-2, and ASTER are the most used data, At a continental or global scale size can be obtained from MODIS, SPOT vegetation, Orbview-1, and AVHRR are prevalent and etc. [6], [14-15].

The last process of classification, the accuracy assessment, is calculated from an error matrix table as shown in Table 1.

Table 1- An error matrix [16]

		Ground truth classes			Total
		A	B	C	
Thematic map classes	A	35	2	2	39
	B	10	37	3	50
	C	5	1	41	47
Number of ground truth pixels		50	40	46	136

Classes of the thematic map are generated from the classifier. While, classes of the ground truth come from the field survey. Comparison the value of random pixel between these classes are filled

in the table. Four assessment approaches are calculated from the error matrix table: producer accuracy, user accuracy, over all accuracy and Kappa.

- Producer accuracy depends on the number of correct pixels in that class divided by the total number of pixels of that class (the corresponding column sum in Table 1). It shows how much accuracy the classifier does. For example, fifty pixels of thematic map class A are selected. The result founds that class A, class B and class C are thirty-five, ten, and five pixels of the ground truth, respectively. Therefore, the value of producer accuracy of class A is thirty-five divided by total number of pixel and multiply by a hundred is equal seventy percent.
- User accuracy describes that how often the user does. To calculate the user accuracy, it does the same steps as the producer accuracy. Just only it is calculating based on the row of table. For example, thirty-five pixels of thematic map class A are selected. The result founds that class A, class B and class C are thirty-five, two, and two pixels of the ground truth, respectively. Therefore, user accuracy of Class A in Table 1 is thirty-five divided by total number of pixel and multiply by a hundred is equal eighty-nine percent.
- Overall corrected value is calculated from the corrected value on the diagonal direction. For example, one hundred and thirteen pixels of thematic map all class are selected. The result founds that class A, class B and class C are thirty-five, thirty-seven, and fourth-one correct pixels of the ground truth, respectively. Therefore, overall accuracy of error matrix in Table 1 are total number of correct pixels each class divided by total number of pixel and multiply by a hundred is equal eighty-three percent.
- Kappa coefficient assists in considering the consistency between the testing data and the reference data. It always considers Kappa with the overall accuracy. If both values of them are similar in the high direction, the classifier is considered good. In other cases, the classifier is not suitable for the classification [20].

Maximum Likelihood classifier

Classifier is the main factor for the image classification process. Using the proper classifier in the image interpretation will lead to a highly accurate LU/LC map [8], [21-22]. Maximum Likelihood Classifier (MLC) is one of supervised classifiers which widely applied to a variety of application. This method classifies the calculation of the probability for each given pixel in a class, in which the pixels are allocated to the class that has the highest probability. It calculates the mean vector and covariance matrix for training sample based on one assumption. That is each data class must have a normal distribution. According to Figure 3, the probability of pixel number 1 is closed to the group of class C. Therefore, pixel number 1 is classified as a member of Class C [23].

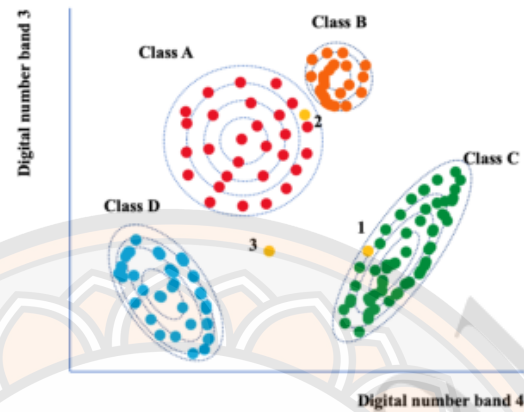


Figure 3 Maximum Likelihood Classifier

The normal distribution of MLC can be calculated as the following equation:

$$L_k(X) = \frac{1}{2\pi^{n/2} |\Sigma_k|^{1/2}} \exp -\frac{1}{2} (X - m_k) \Sigma_k^{-1} (X - m_k)^t \quad (1)$$

X indicates as the image data of n bands. $L_k(X)$ represents the likelihood of X belonging to class k . m_k is mean vector of class k . Σ_k is the variance covariance matrix of class k [23]. There are various applications of LU/LC based on MLC as shown below.

- The study of monitoring about the change of LU/LC in Hawalbagh block, district Almora, Uttarakhand, India [3] - MLC was applied on the Landsat satellite images of two different periods: 1990 and 2010. Results showed that the image was divided into five classes including: vegetation, agriculture, barren, built-up and water body. In 2010, the number of vegetation and built-up area were more than their numbers in 1990. While, the number of agricultures, barren land and water body area were less than their numbers in 1990. Survey result of the year 2010 also showed in the same direction.
- Detecting and learning the agriculture situation of Nakhon Nayok, Thailand [2] - this study determined the class of LU/LC based on MLC. The Landsat satellite images of 2004 until 2015 were used as the primary resources. The satellite image was divided into five classes namely water, agriculture, urban, bare soil, and forest. Result showed as the series of LU/LC changes during these 10 years.

- Monitoring the LU/LC of Selangor, Malaysia [11] – a comparative study was conducted based on ISODATA classifier and MLC. Clustering method of ISODATA could generate eight classes: urban, industry, oil palm, dry-land forest, coastal swamp forest, cleared land, water and sediment plumes. While, MLC classified it into eleven classes more than ISODATA and they were coconut, rubber and bare land. MLC has a higher classification accuracy than ISODATA.
- Pixel-based classification analysis of LU/LC using Sentinel-2 and Landsat-8 data in Zonguldak, Turkey [25]. – Two satellite images of Sentinel-2 and Landsat-8 were analysed for LU/LC map. Based on MLC, there were five classes: water body, settlement, forest, bare-land and vegetation. Accuracy assessment of these two types of image tended to the good direction. However, the Sentinel-2 presented the OA higher than Landsat-8 data. Due to, Sentinel-2 had a spatial resolution higher than Landsat 8.
- Island management in Italy [26] - Landsat satellite images were analyzed for detecting the change of small island areas. Using MLC, there were four classes in these satellite images: urban, bare soil (with rocks), sparse vegetation and dense vegetation. The accuracy assessment was based on field survey. Results showed that the OA is 85 percent and the evaluation of the specific map accuracy received guarantees the quality of the results at the level of 1: 25,000.
- A LU/LC map of Prahova Subcarpathians, Romania [27] – Two classifiers (minimum distance classifier and MLC) were applied on Landsat-8 satellite images of the local area in Prahova Subcarpathians. Result showed that MLC displayed the LU/LC map with high accuracy, while, the other displayed the LU/LC map with low accuracy.
- Finding the appropriate classifier for Ralegaon Siddhi watershed, Ahmednagar district of Maharashtra state, India [17] – the satellite image of IRS-1C LISS-III were used in this study. Four classifiers (MLC, box, minimum distance and mahalanobis) were applied. Five classes (agricultural land, shrubs, water body, wasteland and barren land) were assigned for each classifier. Ground investigation had been conducted to check and assess the accuracy of classification. Result showed that the accuracy assessment of MLC, mahalanobis, minimum distance and box were 88.52, 84.26, 81.85 and 58.15, respectively. Kappa value of these classifier also revealed in the same direction with the accuracy assessment. Hence, MLC could be the most appropriate classifier for this study.

According from above examples, LU/LC map is classified as basic spatial information for managing and deciding in several areas such as city management, forest management, and etc. The accuracy assessment of MLC is higher than the other assessments. The OA value is increasing along with Kappa coefficient value. Hence, LU/LC map is generated with high accurate and consistency. It can be said that MLC is classified the most suitable classifier for generating LU/LC map.

Conclusion

In order to select the suitable classifier, many factors must take into account. They are area size and spatial resolution, classifier and accuracy assessment of classification. Study area may lead to specify the scales of satellite image which are local scale, medium scale and global scale (Figure 2). To interpret a satellite image, two classification methods (supervised method and unsupervised method) are considered. Pixels on a satellite image may be identified in any information depending on the classification. Classification is a process of image analysis which determines, and groups related pixels in each class. Supervised classifiers, MLC, PP, MD, KNN, SAM and Maharanobis, are often applied due to the training process can guarantee the class signatures are actual representative of the particular area. Classifier performs well depending on sampling of training areas, statistical of sample areas (e.g. spectral signature, variance, correlation), and its own algorithm. An error metric table is used to calculate four assessment values: producer accuracy, user accuracy, over all accuracy and kappa. MLC are the most utilized classifier as shown in Section 3, due to the OA value and Kappa coefficient value is higher in the same direction. While, these values of other classifiers are lower.

References

- [1] Mallupattu, P. K., Reddy, S., & Reddy, J. (2013). Analysis of land use/land cover changes using remote sensing data and GIS at an Urban Area, Tirupati, India. **The Scientific World Journal**. Vol. 2013.
- [2] Diem, P. K., Sitthi, A., Pimple, U., & Pungkul, S. (2015). Mapping Land Cover Dynamics in Nakhon Nayok Province of Thailand. **Suan Sunandha Science and Technology Journal**. Vol. 2(2) : 1-5.
- [3] Rawat, J. S., & Kumar, M. (2015). Monitoring land use/cover change using remote sensing and GIS techniques: A case study of Hawalbagh block, district Almora, Uttarakhand, India. **The Egyptian Journal of Remote Sensing and Space Science**. Vol. 18(1) : 77-84.
- [4] Fisher, P. F., Comber, A. J., & Wadsworth, R. (2005). Land use and land cover: contradiction or complement. **Re-presenting GIS**. John Wiley & Sons : 85-98.
- [5] Kurian, J., & Karunakaran, V. (2012). A survey on image classification methods. **International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE)**. Vol. 1.
- [6] Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. **International journal of Remote sensing**. Vol 28(5) : 823-870.
- [7] Kamavisdar, P., Saluja, S., & Agrawal, S. (2013). A survey on image classification approaches and techniques. **International Journal of Advanced Research in Computer and Communication Engineering**. Vol. 2(1) : 1005-1009.

- [8] Rong, R. (2016, May). Research and analysis of hyperspectral remote sensing image classification algorithms. **2016 Chinese Control and Decision Conference (CCDC)**, 28-30 May 2016. Yinchuan, China : 3960-3964.
- [9] Salah, M. (2017). A survey of modern classification techniques in remote sensing for improved image classification. **Journal of Geomatics**. Vol. 11(1).
- [10] Jawak, S. D., Devliyal, P., & Luis, A. J. (2015). A comprehensive review on pixel oriented and object oriented methods for information extraction from remotely sensed satellite images with a special emphasis on cryospheric applications. **Advances in Remote Sensing**. Vol. 4(3).
- [11] Ahmad, A., & Quegan, S. (2012, November). Analysis of maximum likelihood classification technique on Landsat 5 TM satellite data of tropical land covers. **2012 IEEE International Conference on Control System, Computing and Engineering**, 23-25 November 2012. Penang, Malaysia : 280-285.
- [12] Abburu, S., & Golla, S. B. (2015). Satellite image classification methods and techniques: A review. **International journal of computer applications**. Vol 119(8).
- [13] Natya, S., & Rehna, V. J. (2016). Land cover classification schemes using remote sensing images: a recent survey. **Current Journal of Applied Science and Technology**. Vol. 13(4) : 1-11.
- [14] Rogan, J., & Chen, D. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. **Progress in planning**, Vol. 61(4) : 301-325.
- [15] Kumpula, T., Forbes, B., & Stammler, F. (2006). Combining data from satellite images and reindeer herders in Arctic petroleum development: the case of Yamal, West Siberia. **Nordia Geographical Publications**, Vol. 35(2) : 17-30.
- [16] Richards John, A., & Xiuping, J. (1999). **Remote sensing digital image analysis: an introduction**.
- [17] Bharatkar, P. S., & Patel, R. (2013). Approach to accuracy assessment for RS Image classification techniques. **International Journal of Scientific & Engineering Research**. Vol 4(12) : 79-86.
- [18] Banko, G. (1998). **A review of assessing the accuracy of classifications of remotely sensed data and of methods including remote sensing data in forest inventory**. International Institute for Applied Systems Analysis.
- [19] Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**. Vol 37(1) Vol. 37(1) : 35-46.
- [20] Thomas M., Lillesand, & Ralph W., Kiefer. (2000). **Remote Sensing and Image Interpretation**. John Wiley & Sons.
- [21] Fuller, R. M., Groom, G. B., & Jones, A. R. (1994). The land-cover map of great Britain: an automated classification of landsat thematic mapper data. **Photogrammetric engineering and remote sensing**. Vol 60(5) : 553-562.
- [22] Sisodia, P. S., Tiwari, V., & Kumar, A. (2014, May). Analysis of supervised maximum likelihood classification for remote sensing image. **International Conference on Recent Advances and Innovations in Engineering (ICRAIE-2014)**. 9-11 May 2014. Jaipur, India : 1-4.

- [23] Nair, M., & Bindhu, J. S. (2016). Supervised techniques and approaches for satellite image classification. **International Journal of Computer Applications**. Vol. 134(16).
- [24] Du, P., Liu, P., Xia, J., Feng, L., Liu, S., Tan, K., & Cheng, L. (2014). Remote sensing image interpretation for urban environment analysis: methods, system and examples. **Remote Sensing**. Vol. 6(10) : 9458-9474.
- [25] Sekertekin, A., Marangoz, A. M., & Akcin, H. (2017). Pixel-based classification analysis of land use land cover using Sentinel-2 and Landsat-8 data. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. Vol. 42(6) : 91-93.
- [26] Mei, A., Manzo, C., Fontinovo, G., Bassani, C., Allegrini, A., & Petracchini, F. (2016). Assessment of land cover changes in Lampedusa Island (Italy) using Landsat TM and OLI data. **Journal of African Earth Sciences**. Vol. 122 : 15-24
- [27] Rujoiu-Mare, M. R., & Mihai, B. A. (2016). Mapping land cover using remote sensing data and GIS techniques: A case study of Prahova Subcarpathians. **Procedia Environmental Sciences**. Vol. 32 : 244-255.
- [28] M. C. Paliwal and S. K. Katiyar. (2015). Accuracy Assessment of Land Cover /Land Use Mapping Using Medium Resolution Satellite Imagery. **International Journal of Scientific & Engineering Research**. Vol 6(7).
- [29] Jagadeeswaran, R., Poornima, A., & Kumaraperumal, R. (2018). Mapping and classification of crops using high resolution satellite image. *Journal of Applied and Natural Science*. Vol. 10(3) : 818-825.
- [30] Phiri, D., & Morgenroth, J. (2017). Developments in Landsat land cover classification methods: A review. **Remote Sensing**. Vol. 9(9) : 967.
- [31] Baatuwue, N. B., & Van Leeuwen, L. (2011). Evaluation of three classifiers in mapping forest stand types using medium resolution imagery: a case study in the Offinso Forest District, Ghana. **African Journal of Environmental Science and Technology**. Vol. 5(1) : 25-36.



Uttaporn Lertaramsaeng received the B.Sc. degree (Computer science) and the M.Sc (Information technology) from Naresuan University (NU), Phitsanulok, Thailand, in 2006 and 2010 respectively, His research interests are in the areas of knowledge representation, management information system, ontology, and geographic information system.



Janjira Payakpate received her bachelor's degree (Computer Science), from Naresuan University, Thailand, in 1998. She had worked as a lecturer at the department of Computer Science and Information Technology (CSIT) from 1998 until 1999. In 2001, she got the Master of Computer Science from University of Wollongong, Australia and pursuit her Ph.D. (Information Technology) at Murdoch University, Australia in 2009. She has been working at CSIT. Her research interests are in the field of knowledge management system (KMS), decision support system (DSS), image processing and Geographic Information System (GIS).



An Appropriate Interpretation Approach for Land Use/Land Cover Map in Chomthong, Phitsanulok, Thailand

Uttaporn Lertaramsaeng and Janjira Payakpate*

Department of Computer Science and Information Technology, Faculty of Science, Naresuan University, Phitsanulok, 65000, Thailand

*Corresponding author. E-mail: janjirap@nu.ac.th

ABSTRACT

The study of land use/land cover (LU / LC) has belonged to an important aspect of resource management, planning and mapping, etc. The acquisition of these results is due to the interpretation process, consists of two methods which are visual interpretation and digital interpretation. The tools used in the interpretation are classifiers in image processing software. Currently, there are many classifiers, but there is one method that provides better results than the other, maximum likelihood classifier (MLC). MLC is one of supervised classifiers, this method classifies the calculation of the probability for each given pixel in LU/LC class. The comparative study of the interpretation results with MLC through three image processing software (ERDAS, ENVI, QGIS) is the purpose of this study. Interpretation results show that ERDAS (OA = 83%, Kappa = 76%) provides better overall accuracy (OA) and kappa coefficient (Kappa) than ENVI (OA = 81%, Kappa = 74%) and QGIS (OA = 79%, Kappa = 71%).

Keywords: Chomthong, Interpretation, LU/LC, MLC

INTRODUCTION

Land use /Land cover (LU/LC) map is a significant spatial information for decision maker who are planning, managing and designing any matter related to particular area (Giri, 2016, Natya & Rehna, 2016). For example, LU/LC map of Nakhonnayok province of Thailand (Diem et al., 2015) showed the change of LU/LC between 2004 and 2015. The governor could design an economic plan or a city plan for coming year. The results of the LU/LC change in Nakhonnayok presented as Figure 1. Another example is a LU/LC map of Hawalbagh block, district Almora, Uttarakhand in India (Rawat & Kumar, 2015). This map displayed the change of this district during 1990-2010 which assisted in planning for urban development. next example is assessment of LU/LC changes Island in Italy (Mei et al., 2016) showed the changes in LU / LC between 1984 and 2014 to get spatial and temporal data of changes that occurred on the island. Next example is LU/LC mapping in Bhopal city of Madhya Pradesh State of India (Paliwal & Katiyar, 2015) illustrates classification and accuracy assessment of LU/LC mapping using satellite imagery. next example is a classification of LU/LC map in Zonguldak city, Turkey (Sekertekin et al., 2017) conduct accuracy analyses of LU/LC mapping in 2016 for sustainable land

Article history:

Received 11 March 2020; Received in revised form 20 April 2020;

Accepted 15 May 2020; Available online 2 June 2020

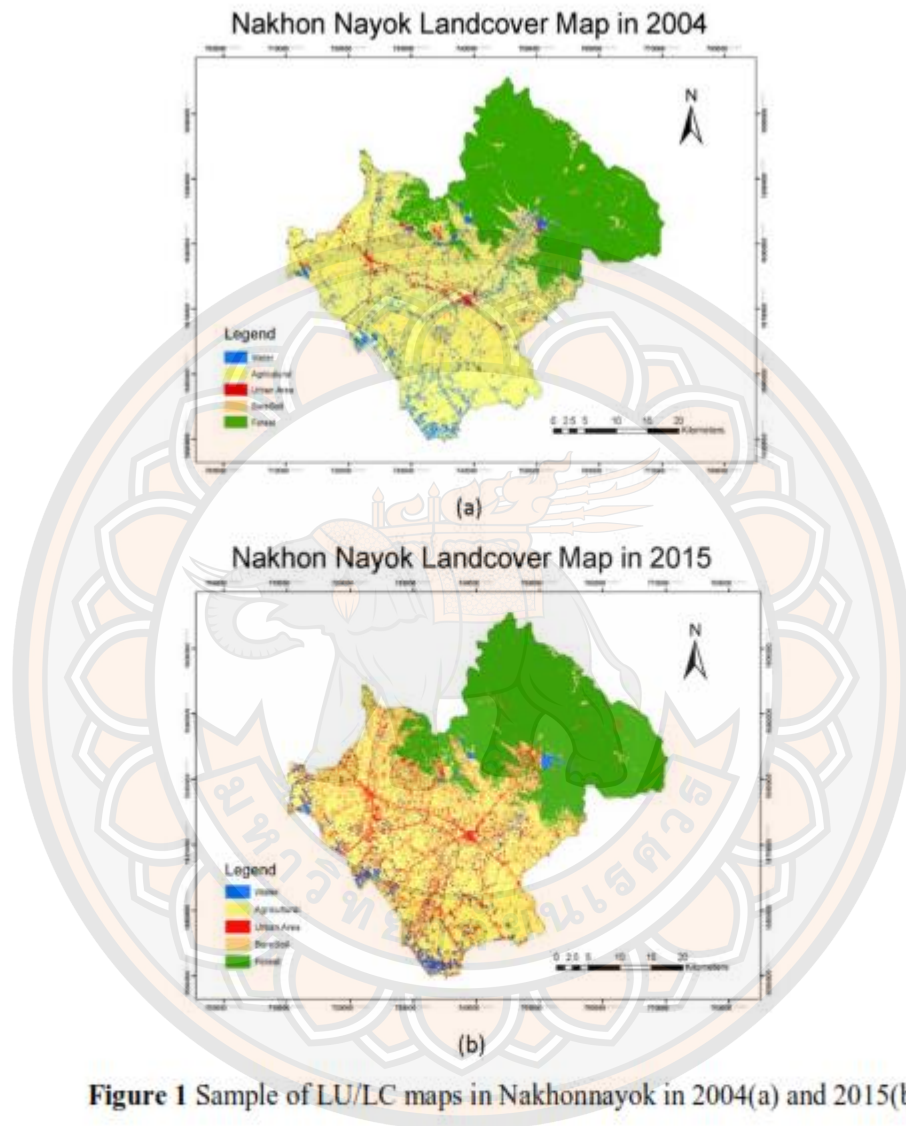


Figure 1 Sample of LU/LC maps in Nakhonnayok in 2004(a) and 2015(b)

management, landscape ecology and climate related researches. The last example is on environmental management in Tirupati, India (Mallupattu et al., 2013). LU/LC map was generated in order to determine the changes in Tirupati from 1976 to 2003. To obtain LU/LC map, the satellite images of interested area have to be interpreted. There are two types of image interpretation: visual interpretation and digital interpretation (Dalsted & Queen, 1999). The first type is analyst the image based on human being sense. Another type always involves in interpreting by image processing software. Three popular software are ERDAS Imagine (ERDAS), Environment for Visualizing Images (ENVI) and Quantum Geographic Information System (QGIS). Using data and remote sensing techniques urgently makes geographic processes fast and efficient, even though the increased complexity makes more opportunities for

errors. This paper aims to interpret LU/LC of the study area by using remote sensing and images processing software and conducting an accurate assessment to assess how well the classification is doing. Most of LU/LC maps are generated from digital interpretation. The consistency of digital interpretation depends on satellite image, classifier and accuracy assessment. There are two main types of digital interpretation: unsupervised and supervised approaches. Both of them will return the result on the form of information group (e.g. agriculture, wetland, forest). However, supervised approach will generate the class signature from the training set before identifying the pixel into each group. In this paper, we focus on the supervised approach. It outlines the image interpretation, a case study on interpreting the satellite image of Chomthong, Phitsanulok, result and discussion and conclusion.

IMAGE INTERPRETATION

Image interpretation process consists of detecting, identifying, describing and estimating the importance of objects and pattern imaged. Interpretation methods can be either visual or digital. Both interpretation techniques have pros and cons, even if analyzed with digital, the final result must be analyzed visually (Lillesand et al., 2015). The ability of humans to identify objects through the content of images by combining many interpretive elements. There are two types of data extraction from images: Interpretation with visual analysis and digital interpretation (digital image processing) followed by visual analysis such as vector layer models from raster images via on-screen digitization and Digital Terrain Model (DTM) / Digital Elevation Model (DEM) creation (Zhou, 2016). Similarly, aerial imagery is interpreted through 3D visualization through visual study. In general, analog form in remote sensing data is being used to visual interpretation. This involves systematic data validation, studying existing maps, collecting field data and working at various complex levels. The analysis depends on the perception of the individual and the experience of the interpreter, the nature of the material, the quality of the data, size, combination of special bands, etc. The whole process of visual interpretation can be divided into the following phases: object detection, interpretation, perception and identification, analysis, classification, deduction and optimization, and depends on the inference of the object.

Therefore, the interpretation is the sum of identifying properties through the composition, photo recognition, field examination and final thematic mapping. Interpreting images that are helped by satellite imagery. The general flow of the interpretation process is shown in the Figure 2.

In the case of digital interpretation refers to managing digital images with the help of computers that is programmed to perform calculations using mathematical equations on the value of pixels and groups of pixels taken from the raw image as input. The output of the digital image processing is a new digital image whose pixel values are the result of those calculations. There are some disadvantages in visual interpretation techniques. However, they may want extensive training and intensive labor. In addition, the spectrum characteristics are not evaluated when attempting in

visual interpretation images. In part because of the limited ability of the eye to see the tonal values in the image and the difficulty of interpreters in the analysis of multiple spectral images simultaneously. In applications that have high spectral data, Therefore it is popular to analyze digital data instead of visual data (Ratanopad & Kainz, 2006).

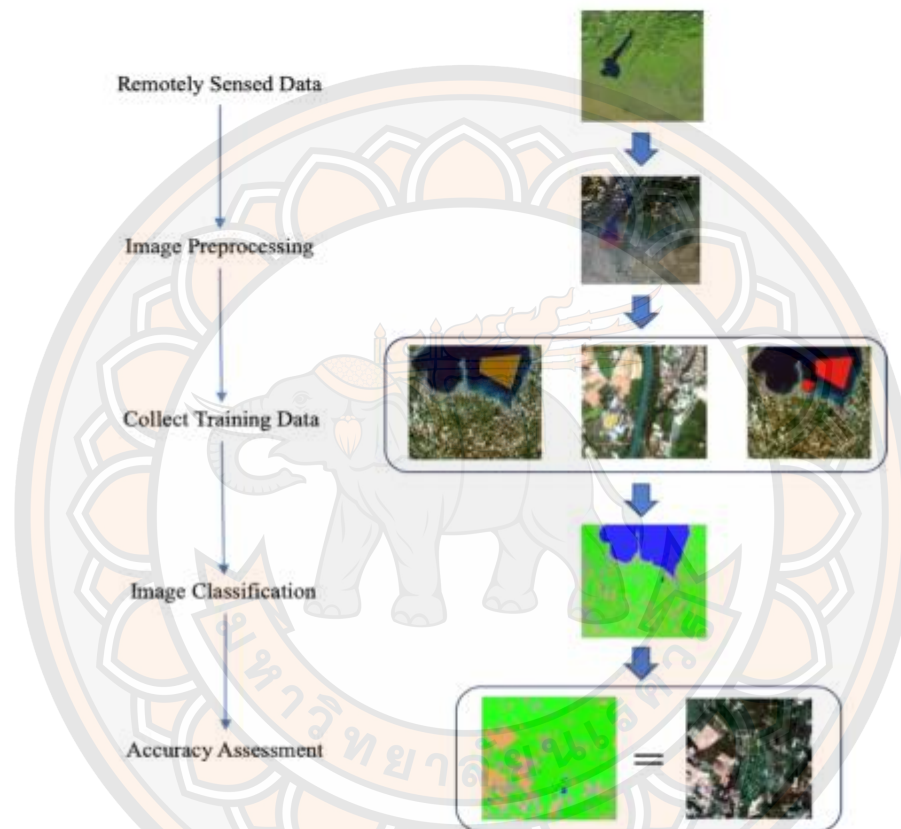


Figure 2 Flow for the image interpretation process

Image interpretation applications are used extensively such as monitoring, resource management, planning activities and mapping (Bayouhd et al., 2015, Du et al., 2014, Jagadeeswaran et al., 2018, Rawat & Kumar, 2015, Rujoiu-Mare & Mihai, 2016). For the application of the LU/LC classification interpretation. In practice, the remote sensing method can be used to classify LU/LC types, saving and duplicate pattern, in a large area. As the case study in the next section.

CASE STUDY

This study focused on a process of image interpretation for LU/LC classification. This process consists of an image pre-processing step, specifying of LU/LC as training areas, Image classification with maximum likelihood classifier (MLC), and accuracy assessment.

Image Pre-processing

The study area is an area of 35.8 km² including and surrounding Chomthong subdistrict Muang district, Phitsanulok province (Figure 3). The Nan river flows north-south through the study site. The whole area is flat river plain. The agricultural usage areas are completely under irrigation.

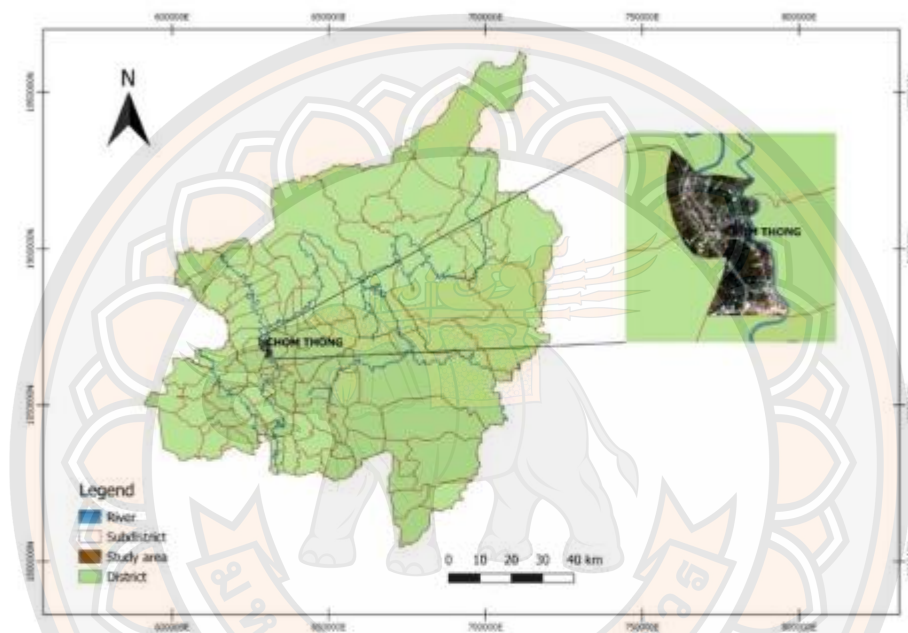


Figure 3 The location of Chomthong

A multi-temporal satellite data observed by LANDSAT 8 Operational Land Imager (OLI) from USGS (<https://earthexplorer.usgs.gov/>) on March 8, 2018 (Path 130/Row 48) was used for the analysis. The LANDSAT 8 satellite payload consists of two scientific instruments; the Operational Land Imager (OLI) and the Thermal Infrared Sensor (TIRS). Both of these sensors provide a seasonal coverage of the earth with a spatial resolution of 30 meters visible (Near infrared (NIR), Shortwave infrared (SWIR)), 100 meters thermal, and 15 meters panchromatic (Lillesand et al., 2015). The initial processing is done using a 6-spectral-band layer stack comprised of Band-2 (blue, 0.450 - 0.51 μm), Band-3 (green, 0.53 - 0.59 μm), Band-4 (red, 0.64 - 0.67 μm), Band-5 (NIR, 0.85 - 0.88 μm), Band-6 (SWIR 1, 1.57 - 1.65 μm) and Band-7 (SWIR 2, 2.11 - 2.29 μm), with false color composites, RGB: 5-6-4 for OLI. This combination of NIR (Band 5), SWIR 1 (Band 6) and red (Band 4) offers additional definitions of land-water scope highlights subtle details not readily apparent in the visible bands alone. Lakes and freshwater streams can be located increasingly precision when using more infrared bands. By this band combination, vegetation type and condition show as different of hues (oranges, browns, and greens), as well as in

tone. The 5-6-4 combination shows different moisture content and is useful for soil and vegetation condition analysis. In general, the wet soil will be darker due to the infrared absorption of water. The relationship between the remotely sensed data and data used to reference geographic coordinates in systems is subject to geometrical correction and cutting out sub images of the study area from the remote sensing imagery (Subset image) (Figure 4).




Figure 4 False colour composites: 5 6 4

Training Area

Supervised classification is a technique commonly used for analysis of remote sensing image. Supervised classification depends on the user to select sample pixels in the image that is used to represent a particular class and then use the image processing software on the training area as a reference for the classification all other pixels in the image.

The training area is chosen from the raw images. The data in the training area must be good quality and be representative of the data from the area on the remote sensing image to be classified as a reference. The training area data pixel characteristics must have the same relative characteristics as the reference area, making the comparison between the training data and the reference data more accurate. As well, the training area must overlay the reference area accurately in regard to geographical coordinates. These factors will enhance the accuracy of the statistical analysis of the reference area and reduce the bias potentially in the statistical analysis of the reference area (Figure 5).

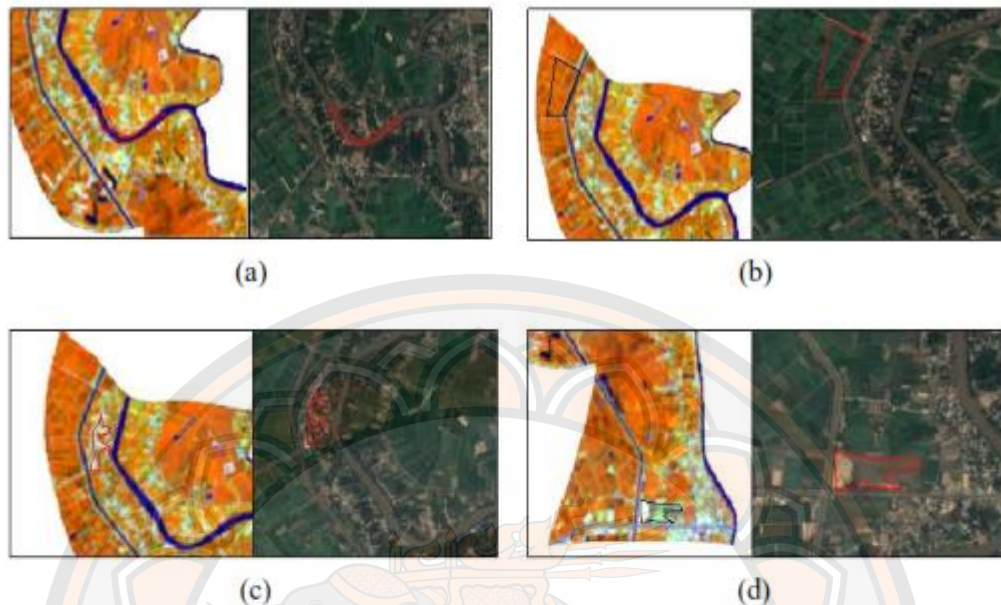


Figure 5 The training area for classifier; water area (a), vegetation area (b), built-up (c) and bare soil (d)

The LU/LC was generated based on field visits and interpretation of remote sensing imagery. The total number of pixels is chosen randomly from each type of land cover as training areas. Every pixel in the training area is additionally examined using high-resolution images of Google Earth and Landsat images to assure the land cover labels were correctly assigned (Zhu et al., 2016).

The training area were extracted from four categories (Table 1) of land use/land cover.

Table 1 Landcover description

Classes	Description
Water	Reservoirs, stream, river, swamps
Vegetation	All plants and trees collectively, forest, agriculture, shrubs
Built-up	Land covered by buildings or houses structures, residential, urban area
Bare soil	The land has sandy, rocky, soil, never has more than 10% plant cover all year round

Image Classification with MLC

According to the idea that various types of properties on the surface of the earth has different spectral reflections and transmittance properties, their awareness is applied through the classification process into the widest sense. Image classification is described as the process of classifying all pixels in an image or remote sensing data to take a set of labels or land cover themes (Al-Doski et al., 2013). This paper classifies

the data based on the type of LU/LC, divided into four types; bare soil, built-up water and vegetation.

Image classification of remotely sensed data is one step in the information extraction process. This is done using different techniques in image classification whether training samples are used or not. Other relevant factors to be considered in the information extraction process include the use of parametric or non-parametric statistical analysis, the kind of pixel information used, whether or not the output will provide a definitive decision about land cover class, and whether or not spatial information is used (Rong, 2016). These techniques are used to classify each pixel as representing a water area, or a vegetation area, or a built-up area and area of bare soil, based on its spectral response.

In our analysis the classification method known as Maximum Likelihood Classifier (MLC), was used to map out the four classes. This method is a supervised classification method that calculates the probability of a pixel being representative of each class thereby allowing them to be allocated to a particular class with the maximum probability. MLC calculates from the mean and covariance matrix for the training area and assumes that the pixel values are normally distributed. A class can stated as a feature by using the mean and covariance matrix value (Domadia & Zaveri, 2011; Nair & Bindhu, 2016). MLC is one of the most potent methods for processing training data when available and is one of the most widely used algorithms (Chutia et al., 2016; Perumal & Bhaskaran, 2010). In our research, MLC was used with three image processing software tools; Erdas Imagine, ENVI and QGIS to assess the accuracy of pixel classification in each method, and thus indicating the ability of each method to accurately classify LULC. The classification results of LULC areas by each of the three software tools is shown in Figure 6.

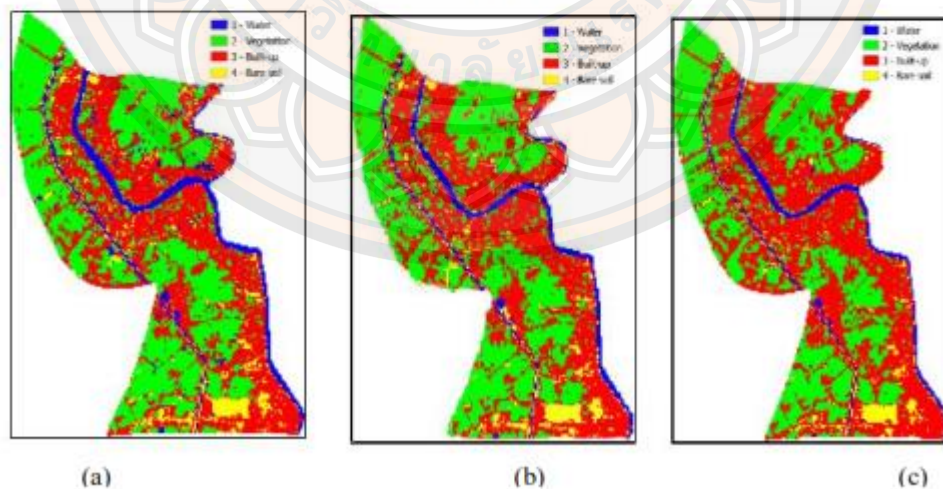


Figure 6 Classification results using MLC of Erdas Imagine (a), ENVI (b) and QGIS (c)

Accuracy Assessment

Accuracy assessment is the verification process which evaluates how accuracy of classification result or LU/LC map. Comparing this LU/LC map with reference maps is performed by comparing pixel per pixel, point per point and polygon per polygon based on the reference objects stated. The result determined correct and error of each of them and display in the format of an error matrix. Error matrix is an array of numbers given in rows and columns. Particularly, the number of sample units selected to a specific category is related to the actual category obtained from the ground truth. The column shows the reference data while the row defines the classification that is created from the remote sensing data (Congalton, 1991, 2001; Story & Congalton, 1986). The diagonals represent sites that are categorized correctly as references. Diagonal outside being wrongly made type. The error matrix of MLC classification on these three software (ERDAS, ENVI and QGIS) are shown below (Table 2 to Table 5).

Table 2 Error matrix of LU/LC classification of ERDAS

		Reference data				
		Water	Vegetation	Built-up	Bare soil	Total
Classified data	Water	37	1	6	6	50
	Vegetation	1	45	1	3	50
	Built-up	1	3	33	13	50
	Bare soil	0	0	0	50	50
	Total	39	49	40	72	200

Table 3 Error matrix of LU/LC classification of ENVI

		Reference data				
		Water	Vegetation	Built-up	Bare soil	Total
Classified data	Water	37	1	6	6	50
	Vegetation	1	44	2	3	50
	Built-up	1	3	33	13	50
	Bare soil	0	0	2	48	50
	Total	39	48	43	70	200

Table 4 Error matrix of LU/LC classification of QGIS

		Reference data				
		Water	Vegetation	Built-up	Bare soil	Total
Classified data	Water	37	1	6	6	50
	Vegetation	1	40	6	3	50
	Built-up	1	6	30	13	50
	Bare soil	0	0	0	50	50
	Total	39	47	42	72	200

Information of each error matrix table are used to calculate overall accuracy (OA), producer accuracy (PA) and user accuracy (UA). These values are useful for decision maker to design which software are appropriate for their works. OA can calculate from equation (1) below:

$$OA = \frac{\text{Number of correct pixels}}{\text{Total number of pixels}} \quad (1)$$

OA is the average. It does not reveal whether the errors are equally distributed between classes or if some classes are certainly not good and some are good. Hence, the other two values, UA and PA, may be considered. User accuracy shows the map accuracy from the user's perspective in the classified map. A pixel which is grouped into one of the classified class on the image, can be two or more types of matter on the reference map. The 'correct' class, which refers to the same land cover class on the map and on the ground, and the 'incorrect' class, which shows the different land cover for the ground than those classified on the map. The following classes are called a commission error. More commission errors, the lower the user accuracy (Banko, 1998; Congalton & Green, 2002; Nagamani et al., 2015). The calculations of UA and commission error (CE) are shown as in equation (2) and (3).

$$UA = \frac{\text{Number of correctly identified in a given map class}}{\text{Number claimed to be in that map class}} \quad (2)$$

$$CE = 1 - UA \quad (3)$$

Producer accuracy comes from dividing the correct number of pixels in one class divided by the total number of pixels obtained from the reference data. PA is a measure of how well the category is classified. It includes omission errors which refer to the proportion of features seen on the ground that are not classified in the map. More omission error, the lower the producer accuracy (Banko, 1998; Congalton & Green, 2002; NAGAMANI et al., 2015). The calculations of PA and omission error (OE) are shown as in equation (4) and (5).

$$PA = \frac{\text{Number of correctly identified in ref. pixels of a given class}}{\text{Number actually in that reference class}} \quad (4)$$

$$OE = 1 - PA \quad (5)$$

Kappa is a statistical value which measures the different of agreement or accuracy between the classification map obtained from remote sensing and the reference data specified. Can calculate the Kappa coefficient (Kappa) as follows,

$$K = \frac{P_o - P_c}{1 - P_c} \quad (6)$$

Where,

P_o = proportion of units agreed, OA

P_c = proportion of units for expected chance agreement

The Kappa coefficient is not sensitive to the difference in sample size between classes, so it is considered a more reliable measurement. The general range for Kappa values is divided into three groups: a value greater than 0.80 indicates a high agreement, values between 0.40 and 0.80 indicates medium agreements, and a value lower than 0.40 indicates poor agreement (Banko, 1998; Congalton, 2001). In Table 5 show all accuracy measurement for classification.

Table 5 Classification accuracies for various image processing software tools

	Name of image processing software											
	ERDAS				ENVI				QGIS			
	Accuracy measurement (%)											
	PA	UA	CE	OE	PA	UA	CE	OE	PA	UA	CE	OE
Water	94.87	74	26	5.13	94.87	74	26	5.13	94.87	74	26	5.13
Vegetation	91.84	90	10	8.16	91.67	88	12	8.33	85.10	80	20	14.90
Built-up	82.50	66	34	17.50	76.74	66	34	23.26	71.43	60	40	28.57
Bare soil	69.44	100	0	30.56	68.57	96	4	31.43	69.44	100	0	30.56
OA	83				81				79			
Kappa	76				74				71			

Note: PA= producer accuracy, UA = user accuracy, CE = commission error, OE = omission error, OA = overall accuracy, and Kappa = kappa coefficient

The comparison of classification results in LU/LC map was based on the value of accuracy assessment. An error matrix table was generated for each result map, and calculate the overall accuracy (OA), producer accuracy (PA), user accuracy (UA), and kappa coefficient (Kappa). Moreover, the main focus for pixel selection, accuracy assessment, is in areas that can be identified, both in high resolution and Landsat images. The pixel selection uses reference data to classify from Google Earth

and Google maps. Create a total of 200 points from classified images in the study area using stratified random sampling. Stratified sampling is suggested according to the minimum number of samples to choose from in each category (Congalton, 1991). Accuracy assessment results have shown in Table: 2, 3, 4 and 5 respectively.

RESULTS AND DISCUSSION

Comparison of interpretation on satellite image of Chomthong with three image processing software is shown in Table 5. The results of the accuracy assessment in Table V show the OA received from the process of sampling for the images of 83%, 81% and 79% (ERDAS, ENVI and QGIS). UA is between 60% to 100% while PA is between 68.57% to 94.87%. Multiple accuracies in predicting specific categories. The UA shows the reliability of classification to users. UA is a more pertinent measurement of true classification in the field. Found that bare soil is more reliable with 100% of UA except for ENVI (96%). To indicate the strong complexity of built-up with other land cover classes. In addition, PA measurements show CE, reflecting the pixels included in the category while not in that category. For example, CE is the highest level in the case of the built-up area, which means that many pixels not in this category will be categorized as the built-up area. Nearly, OE shows the number of pixels that are not included in the same category in that category. The OE in the case of bare soil is more (30.56% in ERDAS and QGIS, 31.43% in ENVI) with 22 pixels which be members of this category, are not classified in this class. In this study, Kappa of 76%, 74% and 71% (ERDAS, ENVI and QGIS) were received which is rated as considerable. As stated earlier, Kappa is over 70% higher. It may be interpreted that the classification is more accurate than expected by a random class assignment. Kappa value of 76% for ERDAS indicates better classification of LU/LC map. But that does not mean that the other software is not effective in identifying LU/LC, which can be seen from the Kappa values (74% and 71%) that are similar. It is possible that each software will hide the adjustment of various parameters in the background, resulting in different classification performance. Because the study area, identifier and training are the same.

CONCLUSIONS

In this study, MLC is done through image processing software, to interpret LULC in Chomthong, in which leads to the conclusion. MLC classifies existing classes in the study area with good agreement with the reference area. MLC classified the study area through ERDAS, ENVI, and QGIS into four classes (e.g. water, bare soil, vegetation and built-up). The accuracy assessment is useful in evaluating the effectiveness of the model for a specific interest class for the study. The error matrix has been carried out, with OA of more than 79% of the three-image processing software and Kappa is better by 70%. Kappa is ranked as important and makes the classified images suitable. The result shows that OA and Kappa are better for ERDAS compared to ENVI and QGIS. Therefore, it can be concluded that ERDAS is a better tool for effective LULC classification in Chomthong. Selection of a suitable software requires consideration of main factor, such as classifier performance, classification

accuracy and software type (e.g. commercial software or open source software). Which it depends on the user's decision to use the software. If you want to use open source software, QGIS is as effective in interpreting LULC as well as commercial software.

ACKNOWLEDGMENTS

We acknowledge the contribution of Mr. Roy I. Morien from the Naresuan University Graduate School for his editing and checking of English grammar and expression in this paper and we are highly thankful to Department of Computer Science and Information Technology Faculty of Science, Naresuan University for supporting everything.

REFERENCES

- Al-Doski, J., Mansori, S. B., & Shafri, H. Z. M. (2013). Image classification in remote sensing. *Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia.*
- Banko, G. (1998). *A review of assessing the accuracy of classifications of remotely sensed data and of methods including remote sensing data in forest inventory.*
- Bayouduh, M., Roux, E., Richard, G., & Nock, R. (2015). Structural knowledge learning from maps for supervised land cover/use classification: Application to the monitoring of land cover/use maps in French Guiana. *Computers & Geosciences, 76*, 31–40.
- Chutia, D., Bhattacharyya, D. K., Sarma, K. K., Kalita, R., & Sudhakar, S. (2016). Hyperspectral remote sensing classifications: A perspective survey. *Transactions in GIS, 20*(4), 463–490.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment, 37*(1), 35–46.
- Congalton, R. G. (2001). Accuracy assessment and validation of remotely sensed and other spatial information. *International Journal of Wildland Fire, 10*(4), 321–328.
- Congalton, R. G., & Green, K. (2002). *Assessing the accuracy of remotely sensed data: Principles and practices.* CRC press.
- Dalsted, K., & Queen, L. (1999). Interpreting remote sensing data. *The Site-Specific Management Guideline SSMG-26.*
- Diem, P. K., Sitthi, A., Pimple, U., & Pungkul, S. (2015). Mapping Land Cover Dynamics in Nakhon Nayok Province of Thailand. *Suan Sunandha Science and Technology Journal, 1.*
- Domadia, S. G., & Zaveri, T. (2011). Comparative analysis of unsupervised and supervised image classification techniques. *Proceeding of National Conference on Recent Trends in Engineering & Technology, 1–5.*
- Du, P., Liu, P., Xia, J., Feng, L., Liu, S., Tan, K., & Cheng, L. (2014). Remote sensing image interpretation for urban environment analysis: Methods, system and examples. *Remote Sensing, 6*(10), 9458–9474.

- Giri, C. P. (2016). *Remote sensing of land use and land cover: Principles and applications*. CRC press.
- Jagadeeswaran, R., Poornima, A., & Kumaraperumal, R. (2018). Mapping and classification of crops using high resolution satellite image. *Journal of Applied and Natural Science*, 10(3), 818–825.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- Mallupattu, P. K., Reddy, S., & Reddy, J. (2013). Analysis of land use/land cover changes using remote sensing data and GIS at an Urban Area, Tirupati, India. *The Scientific World Journal*, 2013.
- Mei, A., Manzo, C., Fontinovo, G., Bassani, C., Allegrini, A., & Petracchini, F. (2016). Assessment of land cover changes in Lampedusa Island (Italy) using Landsat TM and OLI data. *Journal of African Earth Sciences*, 122, 15–24.
- Nagamani, D. K., Jayakumar, K., Suresh, Y., & Ganesh, J. S. (2015). Study on Error Matrix Analysis of Classified Remote Sensed Data for Pondicherry Coast. *Journal of Advanced Research in Geo Sciences & Remote Sensing*, 2(3).
- Nair, M., & Bindhu, J. S. (2016). Supervised techniques and approaches for satellite image classification. *International Journal of Computer Applications*, 134(16).
- Natya, S., & Rehna, V. J. (2016). Land cover classification schemes using remote sensing images: A recent survey. *Current Journal of Applied Science and Technology*, 1–11.
- Paliwal, M. C., & Katiyar, S. K. (2015). Accuracy Assessment of Land Cover /Land Use Mapping Using Medium Resolution Satellite Imagery. *International Journal of Scientific & Engineering Research*, 6(7), 1428–1432.
- Perumal, K., & Bhaskaran, R. (2010). Supervised classification performance of multispectral images. *ArXiv Preprint ArXiv:1002.4046*.
- Ratanopad, S., & Kainz, W. (2006). Land cover classification and monitoring in northeast thailand using landsat5 TM data. *ISPRS Technical Commission II Symposium, Vienna*, 7.
- Rawat, J. S., & Kumar, M. (2015). Monitoring land use/cover change using remote sensing and GIS techniques: A case study of Hawalbagh block, district Almora, Uttarakhand, India. *The Egyptian Journal of Remote Sensing and Space Science*, 18(1), 77–84.
- Rong, R. (2016). Research and analysis of hyperspectral remote sensing image classification algorithms. *2016 Chinese Control and Decision Conference (CCDC)*, 3960–3964.
- Rujoiu-Mare, M.-R., & Mihai, B.-A. (2016). Mapping land cover using remote sensing data and GIS techniques: A case study of Prahova Subcarpathians. *Procedia Environmental Sciences*, 32, 244–255.
- Sekertekin, A., Marangoz, A. M., & Akcin, H. (2017). Pixel-based classification analysis of land use land cover using Sentinel-2 and Landsat-8 data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(6), 91–93.
- Story, M., & Congalton, R. G. (1986). Accuracy assessment: A user's perspective. *Photogrammetric Engineering and Remote Sensing*, 52(3), 397–399.

- Zhou, Q. (2016). Digital elevation model and digital surface model. *International Encyclopedia of Geography: People, the Earth, Environment and Technology: People, the Earth, Environment and Technology*, 1–17.
- Zhu, Z., Fu, Y., Woodcock, C. E., Olofsson, P., Vogelmann, J. E., Holden, C., Wang, M., Dai, S., & Yu, Y. (2016). Including land cover change in analysis of greenness trends using all available Landsat 5, 7, and 8 images: A case study from Guangzhou, China (2000–2014). *Remote Sensing of Environment*, 185, 243–257.



Integrating Object-based Image Analysis with Ontology for Land Use Land Cover Classification

Uttaporn Lertaramsaeng and Janjira Payakpate*

Department of Computer Science and Information Technology,
Faculty of Science, Naresuan University, Phitsanulok 65000, Thailand

*Corresponding author: janjirap@nu.ac.th

ABSTRACT. *Object-based image analysis (OBIA) has emerged as a popular method for land use and land cover (LULC) classification from satellite imagery. Integrating ontology with OBIA has shown promise in improving the accuracy and efficiency of LULC classification. This approach involves developing domain knowledge with input from experts, generating classification rules using Semantic Web Rule Language (SWRL), and using ontology for LULC classification reasoning. In this study, we present the potential of OBIA with ontology for LULC classification. We demonstrate that the approach achieves an overall accuracy of over 80% with improved efficiency compared to conventional OBIA methods. The ontological model for image object properties uses OBIA with an ontological structure for further extension, feature extraction, rule generation, and ontology-based classification. The results of this study suggest that OBIA with ontology can be a useful approach for accurate and efficient LULC classification. Further research could explore its application to different regions and compare its performance with other classification techniques.*

Keywords: Object-based image analysis, ontology, land use and land cover, satellite image

1. Introduction. Remote sensing technology is commonly employed for land use and land cover (LULC) classification, which involves the analysis of satellite image data. Two primary methods for analyzing image data are pixel based image analysis (PBIA) and object based image analysis (OBIA) [1, 2]. The PBIA assigns the individual pixels to different geographic classes solely based on their reflectance values which obtained from various spectral bands. This method does not make use of other spatial, geometrical, or contextual characteristics that could be valuable. [3]. PBIA operates at the pixel level, which creates the issue of mixed pixels where a single pixel represents multiple types of image objects. As satellite image resolutions improve, the utilization of PBIA reduces because of concerns like the "salt and pepper" effect. In this effect, single pixels are incorrectly classified within a cluster of pixels that represent a specific class [4-6]. The change has occurred over a few years. Most classification method of LULC has been moved from PBIA to OBIA [7]. OBIA is a method used for analyzing satellite imagery that focuses on identifying and classifying image objects based on their spectral, spatial, and contextual features, rather than individual pixels. OBIA allows for more accurate and efficient analysis of satellite imagery, as it can account for mixed pixels and incorporate additional features beyond just spectral reflectance [8]. OBIA uses the feature values of image objects to establish rule sets that can categorize them

into diverse classifications. This technique varies from PBIA approaches in that it considers several characteristics, such as spatial, textural, and contextual, in addition to spectral features to classify image objects. Object-based methods can be applied at multiple scales, making them more versatile than PBIA methods. One limitation of OBIA is the requirement for manual parameter tuning, which is not only subjective but also time-consuming. OBIA relies on a set of parameters, including scale, shape, and compactness, to determine the segmentation process. However, these parameters can vary depending on the image resolution, study area, and desired level of detail. Thus, users must manually adjust the parameters to achieve the optimal segmentation outcome, which can be a time-consuming and subjective process. To enhance the efficiency of classification, knowledge representation methods were employed to aid in the process, including forest classification, farmland classification, and ocean classification [9-11].

An ontology is a language for presenting knowledge that offers a particular lexicon for a given subject or field. It is a precise and unambiguous explanation of a shared understanding of a field that is established by specialists and intended to encourage interoperability, reuse, and distribution of domain expertise [12]. The Web Ontology Language (OWL) is a machine-readable language that is utilized for expressing and distributing ontologies. It allows ontologies to be exchanged and repurposed across various applications and systems. Description logic, a formal logic employed for knowledge representation, is the foundation for OWL. It offers an extensive array of constructs to establish classes, properties, and connections between them [13]. Reasoning engines can examine and uphold the logical coherence of an ontology by identifying and reporting any discrepancies, paradoxes, or other inaccuracies in the ontology. Commonly used reasoning engines for ontologies include Pellet, HermiT, and FaCT++ [14]. The Semantic Web Rule Language (SWRL) enables the development of conditional rules to supplement the reasoning abilities of semantic web reasoners [15]. These regulations are executed via a semantic reasoner, which uncovers new implications and integrates them into an established ontology.

This study integrates OBIA with ontology for LULC classification. The methodology involves constructing a domain ontology using OWL, writing SWRL rules, and using a semantic reasoner for object classification. Section 2 reviews related work, while Section 3 presents a case study of LULC in Phitsanulok, explaining the integration of OBIA with Ontology. Section 4 discusses the results, and Section 5 concludes the paper, summarizing the study's implications. This study demonstrates the benefits of integrating OBIA with Ontology, including enhanced accuracy, semantic understanding, flexibility, interoperability, and decision support for LULC classification.

2. Related Work

2.1. Image Interpretation for LULC. Image interpretation involves the analyzing of satellite or aerial images to identify and classify different types of LULC [16, 17]. It can be for monitoring the changes of land use patterns [18] in particular area. In this interpretation, there are several steps including preprocessing the image to correct for distortions or atmospheric effects, segmenting the image into individual objects, extracting features from the objects, and classifying the objects into different land cover or land use categories using machine learning or rule-based approaches. Accuracy depends on various factors such as the spatial resolution, the effectiveness of the classification algorithm, etc. LULC classification can be applied and deployed as a tool for planning in the geographic area or sector such as environmental monitoring, urban planning, and

natural resource management.

2.2. OBIA with Ontology. OBIA is a technique commonly utilized for analyzing remote sensing imagery [16, 19, 20], which involves breaking down images into meaningful objects, such as buildings, roads, and fields [21-23]. To improve the accuracy and efficiency of image analysis, ontology has been integrated with OBIA [24]. An example of using the domain-specific ontologies is to verify the result of an image interpretation [25, 26]. A domain ontology is created to capture the semantic relationships among the objects in the image. Then this semantic relation also provides an easy to segment and classify the image. The inclusion of ontology enhances the precision of object classification and minimizes the computational burden associated with image analysis. Another example of OBIA with ontology is the use of ontologies to select features for object classification in remote sensing images [27]. In this approach, ontologies define a set of relevant features likely to be present in the image objects of interest, and these features are used to train machine learning algorithms for object classification. The use of ontology in this technique reduces the dimensionality of the feature space, which can improve the efficiency of machine learning algorithms for object classification. Overall, integrating ontology into OBIA has great potential for improving the accuracy and efficiency of image analysis in remote sensing applications. As technology advances, the use of ontology in OBIA is expected to become more widespread, leading to more precise and informed decision-making in various fields.

3. Integrating OBIA for LULC classification: A Case Study of LULC in Phitsanulok. This section introduces the concept of using OBIA with ontology for LULC classification in satellite images. The workflow will be presented, and case studies conducted for this research will be described. Figure 1 illustrates the methodology for OBIA with ontology, which comprises the following steps:

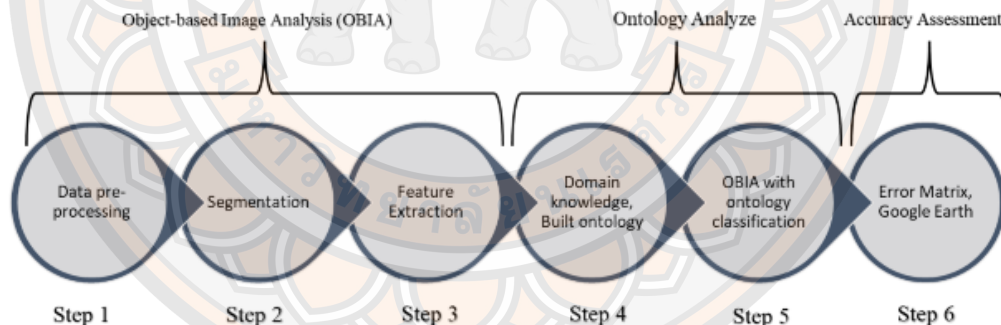


FIGURE 1. An overall methodological workflow for OBIA with Ontology

Step 1: The initial step in the methodology involves preprocessing the image data, which includes tasks like atmospheric correction, noise removal, and georeferencing of satellite imagery. In this study, multi-temporal satellite data from the USGS Earth Explorer platform was utilized,

which was captured on December 10, 2020, covering Path 130/Row 48, utilizing the Landsat 8 OLI. The data contained six spectral bands: Band 2 (blue, 0.450 - 0.51 μm), Band 3 (green, 0.53 - 0.59 μm), Band 4 (red, 0.64 - 0.67 μm), Band 5 (near-infrared, 0.85 - 0.88 μm), Band 6 (short-wave infrared 1, 1.57 - 1.65 μm), and Band 7 (short-wave infrared 2, 2.11 - 2.29 μm).

Step 2: Image Segmentation - The next step is to segment the image into meaningful objects using a segmentation algorithm. The Multi-resolution Segmentation algorithm is often utilized for this purpose and is configured with appropriate parameters [28] such as scale, shape, color, compactness, and smoothness to produce precise outcomes. The research focuses on the Muang District of Phitsanulok Province, Thailand, encompassing an area of 750.8 square kilometers. The district is located primarily in the lower and northern parts of the upper central region of Thailand, with the Nan River flowing through the city's center. The area is known for its diverse LULC, as displayed in Figure 2. The segmentation techniques applied in this study utilized the multiresolution method and were executed using eCognition Developer Version 9 software. Multispectral data (Band 2-7) was used to perform a multiresolution segmentation process to extract image objects. The scale parameter was set to 100, while the shape, color, compactness, and smoothness parameters were set to 0.1, 0.9, 0.5, and 0.5, respectively.




FIGURE 2. The geographical position of study area

Step 3: Feature Extraction - after segmenting the image into objects, the next step is to extract relevant features from each object. The features that can be extracted from the segmented objects include mean wavelength, brightness, standard deviation, maximum difference, reflection values of specific spectral bands (Band 2-7), as well as vegetation indices such as NDVI, NDWI, and NDBI (Figure 3). As an instance of feature extraction, areas that exhibit NDVI values of 0.3 or higher are potentially indicative of vegetation, while NDWI values greater than 0 may indicate water areas. Similarly, NDBI values greater than a certain threshold may indicate built-up areas, and so on.

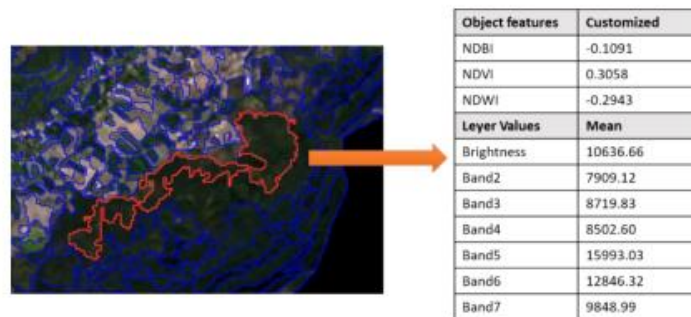


FIGURE 3. Examples of objects that can be classified as vegetation.

Step 4: Create a domain-specific ontology for capturing LULC class knowledge in the methodology. This ontology is constructed with inputs from experts and research papers and provides a structured and consistent framework for organizing and representing knowledge. The process of ontology analysis involves the identification of concepts and relationships that exist within a particular domain of knowledge. In this study, the domain knowledge was derived from various sources related to LULC classification, such as documents, images, and expert information. The ontology was developed using Protégé 5.6.1, an open-source tool by Stanford University [29]. The ontology model is created by analyzing the structure of the domain using expert knowledge from various sources. In some cases, satellite image data may be used, but it requires selecting or defining concepts and properties to include in the model. These properties, relationships, axioms, and associated instances are transformed into a machine-readable format using OWL and presented in Figure 4.

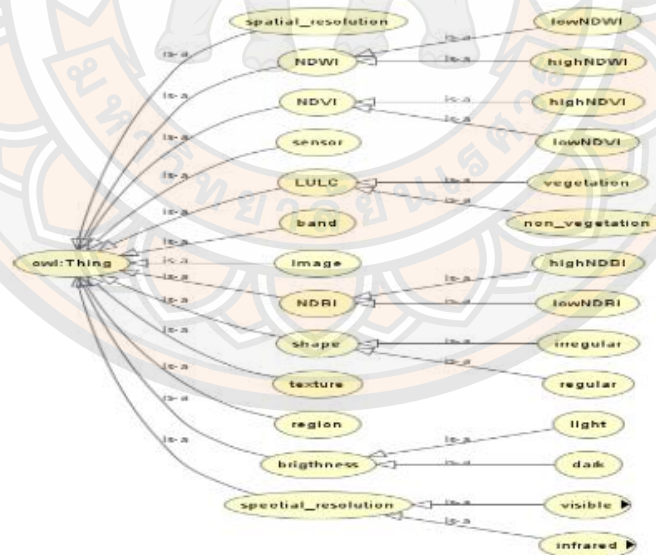


FIGURE 4. Ontology Model for LULC

Step 5: Using OBIA with ontology for classification involves generating classification rules using a SWRL editor, which define the relationships between features and LULC classes. The SWRL specification is used to create these rules, and a reasoner is utilized to execute them using reasoning tools. An example SWRL rule is presented below:

$$\text{highNDVI} (? x) \wedge \text{dark} (? x) \wedge \text{rough} (? x) \wedge \text{irregular} (? x) \rightarrow \text{vegetation} (? x)$$

In this context, a vegetation can be identified as an image object exhibiting highNDVI, dark, rough, and irregular. Here, $C(?X)$ represents a class, where X is an individual belonging to that class. Taking vegetation as an example, the presence of dark, rough, irregular, and highNDVI characteristics indicates that the object should be classified as vegetation. SWRL can express an instance of the NDVI type as shown below:

$$\text{NDVI} (? x ? y), \text{greaterThanOrEqual} (? y, 0.3) \rightarrow \text{highNDVI} (? x)$$

The formula means that when NDVI is greater than or equal to 0.3, the object is highNDVI.

Step 6: Accuracy assessment: Finally, the reasoner is used to classify the objects based on the rules generated in the previous step. Additionally, we need to convert the OWL format file and SHP format file to obtain image objects in SHP format. The classification results are validated using ground truth data from Google Earth. To evaluate the accuracy of a classification result, a comparison is made between the result and data obtained from Google Earth, and Random Sampling is used. The standard error matrix is used to calculate various metrics, such as the overall accuracy (OA), producer accuracy (PA), user accuracy (UA), and Kappa statistics (K) (Equation 1-4) [30, 31].

$$OA = \frac{\text{The count of pixels that are correctly classified}}{\text{Total number of pixels}} \quad (1)$$

$$PA = \frac{\text{Number of correctly identified pixels of a given class in the reference data}}{\text{Number actually in that reference class}} \quad (2)$$

$$UA = \frac{\text{Number of correctly identified in a given map class}}{\text{The number of correctly classified pixels in the reference data for a given class}} \quad (3)$$

$$K = \frac{P_o - P_c}{1 - P_c} \quad (4)$$

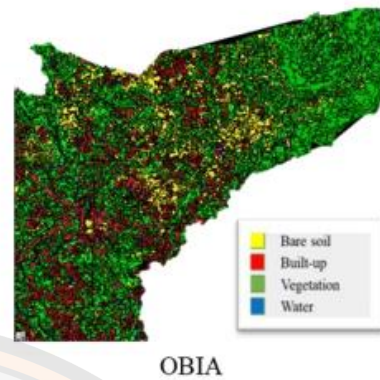
Where, P_o = The proportion of units for which there is agreement, OA
 P_c = Proportion of units expected to agree by chance

4. Results and Discussion.

4.1. **The result.** The study area's feature classification using OBIA and OBIA with ontology is demonstrated in the results, as shown in Figure 4 and Figure 5.

TABLE 1. Error matrix of LULC classification by OBIA

Classified image	Reference data from field						
	Vegetation	Water	Built-up	Bare soil	Total	PA (%)	UA (%)
Vegetation	36	2	2	4	44	92.3	81.82
Water	0	7	0	0	7	70.00	100
Built-up	1	0	16	6	23	72.72	69.57
Bare soil	2	1	4	19	26	65.51	73.07
Total	39	10	22	29	100		
OA (%)	78.00						
Kappa (%)	77.55						

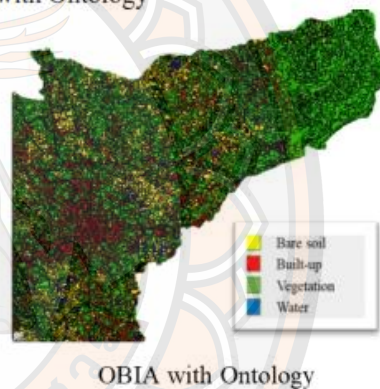


Note that PA refers to producer accuracy, UA refers to user accuracy, OA refers to overall accuracy, and Kappa refers to kappa coefficient

FIGURE 4. The result of OBIA classification

TABLE 2. Error matrix of LULC classification by OBIA with Ontology

Classified image	Reference data from field						
	Vegetation	Water	Built-up	Bare soil	Total	PA (%)	UA (%)
Vegetation	36	2	2	4	44	92.3	81.82
Water	0	7	0	0	7	77.78	100
Built-up	1	0	18	5	24	77.27	73.91
Bare soil	2	0	3	20	25	70.00	80.77
Total	39	9	22	30	100		
OA (%)	81.00						
Kappa (%)	80.61						



Note that PA refers to producer accuracy, UA refers to user accuracy, OA refers to overall accuracy, and Kappa refers to kappa coefficient

FIGURE 5. The result of OBIA with ontology classification

Figure 4 illustrates the LULC classification result of the study area employing OBIA. The most extensive area of the study area is covered by vegetation, represented by the green color. The second most dominant category is bare soil, identified by the yellow color. The built-up area is displayed in red, while the water area has the smallest coverage, represented by the blue color. And table 1 presents the range of user accuracy (UA) and producer accuracy (PA), where UA ranges from 69.57% to 100% and PA ranges from 65.51% to 92.30%. The UA values for specific categories indicate the reliability of the classification for users, with a higher UA indicating a more accurate classification. In particular, the water surface category had a UA of 100%, while the built-up area had a UA of 69.57%. On the other hand, PA reflects pixels that are classified in a category

but do not belong to that category.

Figure 5 depicts the results of LULC classification in the study area using OBIA with ontology. The dominant land cover type is vegetation, which is represented by the green color. Bare soil, represented by the yellow color, is the second most dominant category. The built-up area is displayed in red, while the water area has the smallest coverage, represented by the blue color. It should be noted that the number of yellow areas representing bare soil has decreased, while the number of red areas representing built-up areas has increased. Table 2 presents the overall accuracy between the OBIA method and the integration of OBIA with ontology. The findings indicate a significant enhancement in classification accuracy through the integration of ontology with OBIA. Specifically, the overall accuracy value for the generated category improved from 78% to 81%. The UA and PA for the generated classification demonstrated notable performance, reaching as high as 77.27% and 73.91% respectively. Moreover, the classification of bare soil, vegetation, and water areas also exhibited improved accuracy compared to the traditional OBIA method. It is important to note that although misclassifications may occur due to incomplete knowledge of OBIA with ontology, the classification results obtained using this integrated approach are slightly superior to those achieved with the traditional OBIA method, the difference is not significant.

4.2. Discussion. Three issues have arisen, with the first one being related to the marginal improvement in classification accuracy that can be achieved by using ontology with OBIA. Nevertheless, it is essential for human operators and software agents to comprehend the intricate structures involved. Ontological frameworks enable in-depth knowledge analysis and explicit ontologies, which promote the reuse of common ontology frameworks and expand the knowledge domain in other areas. The LULC ontology model caters to the specific requirements of different problem domains based on geographic models and enhances the semantic comprehension of land cover types. Expert image interpretation in geographic domains necessitates parameter fine-tuning based on the problem domain [32]. Ontology-classified OBIA proficiently identify regional disparities in changing land use and land cover. Integrating building map data into the knowledge domain resulted in improved building-related classification accuracy and overall accuracy exceeding 80%, Table 2 presents the improvements in classification results achieved by using OBIA with ontology for the study area.

The second issue concerns the potential impact of random sampling on the accuracy of LULC classification. Both large and small sampling approaches can be effective, depending on the research question and study objectives. Large sampling provides a broad overview of the study area, while small sampling offers a more detailed and accurate assessment of specific areas or features of interest [33]. The choice of sampling method should consider the research question, study objectives, and data availability and quality.

The last issue concerns the possible future directions for utilizing OBIA with Ontology for LULC classification. These include integrating additional data sources, examining alternative ontological frameworks, refining OBIA algorithms, comparing the approach to alternative classification techniques, and extending the methodology to other geographic regions. Exploring these opportunities for further research may enhance our comprehension and capability to accurately classify LULC.

5. Conclusion. The objective of this study was to use OBIA and ontological techniques for

classifying LULC using Landsat 8 satellite imagery. The OBIA analysis involved using Multi-resolution Segmentation with specific configuration parameters, allowing for feature extraction based on wavelength reflection properties and establishing a hierarchical structure for data classification. The features were determined using properties such as mean wavelength, brightness, and reflection values of specific bands, along with vegetation difference indices like NDVI, NDWI, and NDBI. Four LULC types were classified: vegetation, water, bare soil, and built-up areas. Domain knowledge and ontology concepts were developed using input from experts and relevant information such as building information. Classification rules were established using SWRL language, leading to improved classification demonstrated in Table 2. The integration of OBIA with ontological analysis resulted in successful LULC classification with over 80% overall accuracy in the study area. The ontology approach proved to be more efficient in LULC classification than traditional OBIA methods, as indicated by the high kappa coefficient of 80.61, signifying good agreement between the classification results and ground truth data from Google Earth.

REFERENCES

- [1] S. Abburu and S. B. Golla, "Satellite image classification methods and techniques: A review," *International journal of computer applications*, vol. 119, no. 8, 2015.
- [2] S. Dhingra and D. Kumar, "A review of remotely sensed satellite image classification," *International Journal of Electrical and Computer Engineering*, vol. 9, no. 3, p. 1720, 2019.
- [3] N. Zerrouki and D. Bouchaffra, "Pixel-based or object-based: Which approach is more appropriate for remote sensing image classification?," in *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2014: IEEE, pp. 864-869.
- [4] Y. Gao and J. F. Mas, "A comparison of the performance of pixel-based and object-based classifications over images with various spatial resolutions," *Online journal of earth sciences*, vol. 2, no. 1, pp. 27-35, 2008.
- [5] D. Liu and F. Xia, "Assessing object-based classification: advantages and limitations," *Remote sensing letters*, vol. 1, no. 4, pp. 187-194, 2010.
- [6] R. C. Weih and N. D. Riggan, "Object-based classification vs. pixel-based classification: Comparative importance of multi-resolution imagery," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 38, no. 4, p. C7, 2010.
- [7] T. Blaschke, "Object based image analysis for remote sensing," *ISPRS journal of photogrammetry and remote sensing*, vol. 65, no. 1, pp. 2-16, 2010.
- [8] T. Blaschke, S. Lang, and G. Hay, *Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications*. Springer Science & Business Media, 2008.
- [9] J. M. Almendros-Jimenez, L. Domene, and J. A. Piedra-Fernandez, "A framework for ocean satellite image classification based on ontologies," *IEEE Journal of selected topics in applied earth observations and remote sensing*, vol. 6, no. 2, pp. 1048-1063, 2012.
- [10] H. Gu, H. Li, L. Yan, and X. Lu, "A FRAMEWORK FOR GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS (GEOBIA) BASED ON GEOGRAPHIC ONTOLOGY," *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, vol. 40, 2015.
- [11] S. Rajbhandari, J. Aryal, J. Osborn, A. Lucieer, and R. Musk, "Leveraging machine learning to extend ontology-driven geographic object-based image analysis (O-GEOBIA): A case study in forest-type mapping," *Remote Sensing*, vol. 11, no. 5, p. 503, 2019.
- [12] D. Arvor, L. Durieux, S. Andrés, and M.-A. Laporte, "Advances in Geographic Object-Based Image Analysis with ontologies: A review of main contributions and limitations from a remote sensing perspective," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 82, pp. 125-137, 2013.
- [13] D. L. McGuinness and F. Van Harmelen, "OWL web ontology language overview," *W3C recommendation*, vol. 10, no. 10, p. 2004, 2004.
- [14] E. Sirin, B. Parsia, B. C. Grau, A. Kalyanpur, and Y. Katz, "Pellet: A practical owl-dl reasoner," *Journal of*

- Web Semantics*, vol. 5, no. 2, pp. 51-53, 2007.
- [15] I. Horrocks, P. F. Patel-Schneider, H. Boley, S. Tabet, B. Grosz, and M. Dean, "SWRL: A semantic web rule language combining OWL and RuleML," *W3C Member submission*, vol. 21, no. 79, pp. 1-31, 2004.
- [16] T. Lillesand, R. W. Kiefer, and J. Chipman, *Remote sensing and image interpretation*. John Wiley & Sons, 2015.
- [17] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, "Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification," *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022.
- [18] Q. Zhou, "Digital elevation model and digital surface model," *International Encyclopedia of Geography: People, the Earth, Environment and Technology*, pp. 1-17, 2017.
- [19] G. Forestier, A. Puissant, C. Wemmert, and P. Gançarski, "Knowledge-based region labeling for remote sensing image interpretation," *Computers, Environment and Urban Systems*, vol. 36, no. 5, pp. 470-480, 2012.
- [20] M. A. White *et al.*, "Intercomparison, interpretation, and assessment of spring phenology in North America estimated from remote sensing for 1982–2006," *Global Change Biology*, vol. 15, no. 10, pp. 2335-2359, 2009.
- [21] G. Antoniou and F. Van Harmelen, "Web Ontology Language: OWL. Handbook on Ontologies in Information Systems," ed: Springer-Verlag, 2003.
- [22] N. F. Noy and D. L. McGuinness, "Ontology development 101: A guide to creating your first ontology," ed: Stanford knowledge systems laboratory technical report KSL-01-05 and ... , 2001.
- [23] S. Gadal, M. Zakharov, J. Kamičaitytė, and Y. Danilov, "Alas Landscape Modeling by Remote Sensing Image Analysis and Geographic Ontology. Study case of Central Yakutia (Russia)," in *6th International Conference on Geographic Information Systems Theory, Applications and Management*, 2020, no. 59: SCITEPRESS, pp. 112-118.
- [24] E. F. Lambin, H. J. Geist, and E. Lepers, "Dynamics of land-use and land-cover change in tropical regions," *Annual review of environment and resources*, vol. 28, no. 1, pp. 205-241, 2003.
- [25] H. Luo, L. Li, H. Zhu, X. Kuai, Z. Zhang, and Y. Liu, "Land cover extraction from high resolution ZY-3 satellite imagery using ontology-based method," *ISPRS International Journal of Geo-Information*, vol. 5, no. 3, p. 31, 2016.
- [26] A. Azad and X. Wang, "Land use change ontology and traffic prediction through recurrent neural networks: A case study in Calgary, Canada," *ISPRS International Journal of Geo-Information*, vol. 10, no. 6, p. 358, 2021.
- [27] S. Andres, D. Arvor, and C. Pierkot, "Towards an ontological approach for classifying remote sensing images," in *2012 Eighth International Conference on Signal Image Technology and Internet Based Systems*, 2012: IEEE, pp. 825-832.
- [28] A. Definiens, "Definiens Developer 7 user guide," *Document version*, vol. 7, no. 5.968, 2007.
- [29] "Protégé." <https://protege.stanford.edu/software.php> (accessed 18 June, 2022).
- [30] R. G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data," *Remote sensing of environment*, vol. 37, no. 1, pp. 35-46, 1991.
- [31] R. G. Congalton and K. Green, *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press, 2019.
- [32] H. Gu, H. Li, L. Yan, Z. Liu, T. Blaschke, and U. Soergel, "An object-based semantic classification method for high resolution remote sensing imagery using ontology," *Remote Sensing*, vol. 9, no. 4, p. 329, 2017.
- [33] Y. Li, J. Chen, and Y. Rao, "A practical sampling method for assessing accuracy of detected land cover/land use change: Theoretical analysis and simulation experiments," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 144, pp. 379-389, 2018.