

การเปรียบเทียบการจำแนกภาพถ่ายดาวเทียมแบบกำกับควบคุมโดยการเลือกกลุ่มตัวอย่างจากวัตถุภาพและจากจุดตัวอย่างแบบจุดเวกเตอร์: กระบวนการจำแนกแบบเชิงวัตถุ

Comparison of the satellite image supervised classification by the selection of samples from segmented image objects and vector point samples: Object-oriented classification approach

โสภณวิชญ์ คำพิลัง^{1*}

Sopholwit Khamphilung^{1*}

Received: 24 December 2020 ; Revised: 9 April 2021 ; Accepted: 7 May 2021

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อจำแนกภาพถ่ายดาวเทียมรายละเอียดสูงโดยใช้กระบวนการวิเคราะห์แบบเชิงวัตถุโดยการเปรียบเทียบกระบวนการในการสุ่มตัวอย่างวัตถุภาพ 2 กระบวนการได้แก่ (1) การสร้างจุดตัวอย่างโดยตรงจากการแปลภาพถ่ายด้วยสายตาและ (2) การเลือกกลุ่มตัวอย่างจากวัตถุภาพที่ตัดวัตถุภาพแล้วโดยจำแนกแบบ Nearest Neighbor Classifier (NN) จุดตัวอย่างจากกระบวนการที่ (1) ประกอบด้วย 46 จุดสุ่มและวัตถุภาพที่เลือกจากใช้ในกระบวนการวิเคราะห์ที่ (2) ประกอบด้วย 36 วัตถุภาพ กลุ่มตัวอย่างทั้งหมดที่ถูกเลือกใช้เป็นตัวแทนของชั้นสิ่งปกคลุมดินทั้งสิ้น 5 ชั้นการจำแนกได้แก่ (1) หลังคาเรือน (2) ไม้ยืนต้น (3) แหล่งน้ำ (4) นาข้าวและ (5) พืชไร่ สำหรับการจำแนกแบบที่ (2) ได้เลือกกลุ่มตัวอย่างจากวัตถุภาพที่ถูกตัดแล้วโดยเลือกให้ตรงกับจุดตัวอย่างในกระบวนการที่ 1 นอกจากนี้ยังได้ใช้เกณฑ์เงื่อนไขเดียวกันกับที่ใช้ในกระบวนการการวิเคราะห์ในกระบวนการแรก ผลการศึกษาพบว่า การจำแนกแบบที่ (1) มีความความถูกต้องโดยรวมร้อยละ 85.71 K_{hat} มีค่าเท่ากับ 0.82 โดยในกระบวนการนี้พบว่าไม้ยืนต้นมีค่าความถูกต้องสูงสุด Users' accuracy 94% และมีค่าต่ำสุดได้แก่แหล่งน้ำคิดเป็นร้อยละ 74 สำหรับการจำแนกแบบที่ (2) มีความความถูกต้องโดยรวมร้อยละ 79.19 และ K_{hat} มีค่าเท่ากับ 0.73 โดยในกระบวนการนี้พบว่าไม้ยืนต้นมีค่าความถูกต้องสูงสุด Users' accuracy 87% และมีค่าต่ำสุดได้แก่นาข้าว คิดเป็นร้อยละ 65 ตามลำดับ

คำสำคัญ: การจำแนกแบบกำกับควบคุม กลุ่มตัวอย่าง การวิเคราะห์ภาพเชิงวัตถุ การรับรู้จากระยะไกล

Abstract

This study aims at classifying high resolution satellite images by using object-based image analysis by comparing 2 sampling methods, namely (1) point sample-based directly derived from visual interpretation and (2) segmented image objects sampling utilizing Nearest Neighbor classifier (NN). There were 46 vector point samples used for analytical scenario 1, and 36 sample image objects were used for process 2. These selected samples represented of 5 land cover classes, i.e. (1) Roofs, (2) Trees, (3) Waterbodies, (4) Paddy field, and (5) Crops, respectively. For the second scenario, the sample image objects were directly selected from segmented image objects by visual interpretation at the same location from the sample points selected from the first scenario. Moreover, the threshold conditions were the same data set applied to the first scenario. The results indicated that the overall accuracy from the scenario 1 showed 85.71 with a Kappa statistic (K_{hat}) of 0.82. The highest Users' accuracy was the Trees class (94%), and the lowest accuracy was Waterbodies, which showed 74% of users' accuracy. For the second scenario, the overall accuracy found was 79.19% with K_{hat} 0.73, respectively. The highest users' accuracy was Trees (87%), and the lowest of producers' accuracy was Paddy field (65%).

Keywords: Nearest neighbor, sample-based, object-based image analysis, remote sensing

¹ อาจารย์, ภาควิชาภูมิสารสนเทศ คณะวิทยาการสารสนเทศ มหาวิทยาลัยมหาสารคาม อำเภอกันทรวิชัย มหาสารคาม 44150

¹ Lecturer, Department of Geoinformatics, Faculty of Informatics, Mahasarakham University 44150 Thailand.

* Corresponding author ; Sopholwit Khamphilung, Faculty of Informatics, Mahasarakham University, Maha Sarakham 44150, Thailand.
Sopholwit.c@msu.ac.th

บทนำ

การจำแนกภาพถ่ายดาวเทียมด้วยกระบวนการจำแนกแบบเชิงวัตถุ (Object-based image analysis) เป็นกระบวนการจำแนกข้อมูลภาพถ่ายดาวเทียมอีกรูปแบบหนึ่งที่มีความนิยมเพิ่มมากขึ้น (Rozali *et al.*, 2020) เนื่องจากเป็นกระบวนการวิเคราะห์ภาพถ่ายที่พิจารณาทั้งองค์ประกอบของรายละเอียดต่างๆ ทั้งคุณสมบัติเชิงคลื่น (Spectral information) (Huang *et al.*, 2020) และคุณสมบัติเชิงรูปร่าง (Shape) ของวัตถุหรือคุณลักษณะทางเรขาคณิต (Geometry information) (Hegyi *et al.*, 2020) มาใช้ในกระบวนการจำแนกเพื่อเพิ่มความถูกต้องของผลการจำแนกข้อมูลภาพถ่ายดาวเทียม โดยเฉพาะอย่างยิ่งดาวเทียมที่มีรายละเอียดของจุดภาพสูง (High resolution imagery) (Song *et al.*, 2020) อย่างไรก็ตามการจำแนกข้อมูลภาพถ่ายดาวเทียมแบบกำกับควบคุม (Supervised classification) เป็นกระบวนการจำแนกข้อมูลที่ยึดตามตัวอย่างที่ทราบกันดีที่ผู้จำแนกต้องการจำแนกซึ่งสอดคล้องกับสิ่งปกคลุมดินหรือการใช้ประโยชน์ที่ดิน ณ เวลาที่ใช้ข้อมูล การเลือกกลุ่มตัวอย่างมีอิทธิพลอย่างยิ่งต่อความถูกต้องหลังการจำแนกซึ่งต้องอาศัยประสบการณ์และองค์ความรู้ในการตีความภาพถ่ายดาวเทียมจากคุณสมบัติต่างๆ เช่น สี รูปร่าง รูปทรง เป็นต้น หากการเลือกกลุ่มตัวอย่างไม่พอเพียงหรือไม่ตรงกับขั้นตอนการจำแนกที่แท้จริงย่อมส่งผลต่อภาพรวมของการจำแนกข้อมูล อย่างไรก็ตามการการจำแนกข้อมูลแบบเชิงวัตถุมีนั้นนั้นได้นำคุณสมบัติในการจำแนกแบบกำกับควบคุมมาใช้เช่นเดียวกันกับที่มีการใช้ในกระบวนการวิเคราะห์แบบเชิงจุดภาพได้แก่เครื่องมือจำแนกแบบ Nearest neighbor (NN Classifiers) (Delfan *et al.*, 2020 ; Lubis *et al.*, 2020 ; Wu & Zhang, 2020) ซึ่งเป็นกระบวนการที่ผู้แปลภาพต้องมีการกำหนดหรือเลือกกลุ่มตัวอย่าง ซึ่งกระบวนการเลือกกลุ่มตัวอย่างสามารถทำได้ 2 วิธีหลักๆ ได้แก่ (1) การสร้างกลุ่มตัวอย่างจากภายนอกในรูปแบบเวกเตอร์หรือราสเตอร์และ (2) การเลือกกลุ่มตัวอย่างโดยตรงจากวัตถุภาพที่ถูกตัดแล้วจากค่า Scale parameter ที่ผู้แปลกำหนดโดยจะมีผลต่อขนาด รูปร่างและปริมาณของวัตถุภาพ ซึ่งกระบวนการในการจำแนกภาพถ่ายด้วย 2 กระบวนการนี้อาจมีความถูกต้องหรือความคลาดเคลื่อนที่แตกต่างกันไปตามกระบวนการและรายละเอียดในการเลือกกลุ่มตัวอย่าง ดังนั้นผู้วิจัยจึงได้ทำการศึกษาเปรียบเทียบกระบวนการจำแนกโดยใช้ภาพถ่ายดาวเทียมรายละเอียดสูง ณ หมู่บ้าน

แห่งหนึ่งตั้งอยู่ในอำเภอ นาดีน จังหวัดมหาสารคามเป็นพื้นที่ทดสอบกระบวนการจำแนกภาพโดยใช้คุณสมบัติเชิงช่วงคลื่นและเชิงจุดภาพควบคุมชุดเดียวกันเทียบกับความแปรปรวนของกลุ่มตัวอย่าง ดังที่ได้กล่าวมาแล้วข้างต้น เนื่องจากเป็นชุมชนที่ตั้งอยู่ในเขตเมืองโบราณ นครจำปาศรีและมีการใช้ประโยชน์ที่ดินรอบๆ ชุมชนที่มีการบันทึกไว้ด้วยภาพถ่ายดาวเทียมรายละเอียดสูง

วัตถุประสงค์

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบความถูกต้องของการจำแนกข้อมูลภาพถ่ายดาวเทียมรายละเอียดสูงโดยใช้กระบวนการการจำแนกแบบกำกับควบคุม (Supervised classification: Nearest Neighbor) โดยกระบวนการจำแนกแบบเชิงวัตถุ (Object-based image analysis) ด้วยการเลือกกลุ่มตัวอย่างจากวัตถุภาพที่ถูกสร้างขึ้นแล้วเปรียบเทียบกับ การเลือกกลุ่มตัวอย่างแบบจุดเวกเตอร์ที่ได้จากการแปลภาพด้วยสายตา

วัสดุ อุปกรณ์และวิธีการศึกษา

การศึกษานี้ได้ใช้ภาพถ่ายจากดาวเทียม QuickBird ที่ขยายความแยกชัดเชิงพื้นที่ (Pansharpened image) แล้วจำนวน 4 ช่วงคลื่น (Blue, Green, Red, NIR และ Panchromatic รายละเอียด 0.6 ซม.) รายละเอียดของจุดภาพ 0.6 เซนติเมตร โดยภาพถ่ายดาวเทียมนี้ทำการบันทึกเมื่อปี พ.ศ. 2548 WGS 84 zone 48 ขนาดของภาพ 805x745 จุดภาพ (Figure 1)




Figure 1 The selected village located in Na Dun cultural settlement, Maha Sarakham Province

กระบวนการที่ 1 (Scenario 1: S1) การวิเคราะห์ภาพถ่ายจากดาวเทียมได้ใช้เทคนิคการวิเคราะห์ภาพแบบเชิงวัตถุ โดยใช้เทคนิคการจำแนกแบบ Nearest neighbor (Cariou *et al.*, 2020 ; Luo *et al.*, 2020 ; Tang *et al.*, 2020) ซึ่งเป็นกระบวนการจำแนกแบบกำกับควบคุม ภายในสิ่งแวดล้อมของการจำแนกข้อมูลแบบเชิงวัตถุ ภาพถ่ายดาวเทียม Pansharpened QuickBird รายละเอียด 0.6 เซนติเมตรถูกแยกดำเนินการ 2 กระบวนการได้แก่ การเลือกกลุ่มตัวอย่างด้วยสายตาแบบสร้างจุดสุ่มตัวอย่างด้วยการจำแนกด้วยสายตา (NN with

point samples) (Wang *et al.*, 2020) โดยในกระบวนการนี้ผู้วิจัยได้ใช้ซอฟต์แวร์ทางด้านสารสนเทศภูมิศาสตร์ในการสร้างจุด โดยเลือกจุดให้ครอบคลุมทุกชั้นการจำแนกโดยกำหนดให้มีชั้นการจำแนกสิ่งปกคลุมดินทั้งสิ้น 5 ชั้นการจำแนกได้แก่ หลังคาเรือน (Roofs) นาข้าว (A1) พืชไร่ (A2) แหล่งน้ำ (Water bodies) และไม้ยืนต้น (Trees) รายละเอียดของจุดควบคุมหรือจุดสุ่มตัวอย่างของทั้ง 2 กระบวนการวิเคราะห์แสดงได้ดัง Table 1

Table 1 Samples data derived from visual interpretation (S1) and image objects segmentation (S2)

Class	Class_id	Sample point number (S1)	Image object sample number (S2)
Roofs	1	17	7
Trees	2	10	7
Waterbodies (w1)	3	6	3
Paddy field (A1)	4	5	6
Crops	5	9	13
Total		46	36

จากนั้นจุดควบคุมหรือกลุ่มตัวอย่างเหล่านี้ถูกนำเข้าสู่ eCognition ในรูปแบบของชั้นข้อมูลจำเพาะ (Thematic layer) โดยภาพถ่ายดาวเทียม QuickBird ถูกตัดวัตถุภาพด้วยค่า Scale parameter = 80, Shape = 0.1 และ Compactness = 0.5 และให้ค่าถ่วงน้ำหนักกับทั้ง 4 ช่วงคลื่นเท่ากับ 1 โดยใช้ อัลกอริทึม Multiresolution segmentation เพื่อสร้างชั้นจำแนกชื่อ Landcover สำหรับเป็นชั้นการจำแนกเป้าหมายในการรองรับผลการทดสอบกลุ่มตัวอย่างดังกล่าว ในการตัดวัตถุภาพและได้ใช้จุดตัวอย่างที่ถูกสร้างขึ้นดังกล่าวรวมในกระบวนการตัดวัตถุภาพซึ่งทำให้ได้วัตถุภาพทั้งสิ้นจำนวน 600 วัตถุภาพ จากจำนวนจุดภาพทั้งสิ้น 808x745 จุดภาพ จำนวนจุดตัวอย่างสำหรับเป็นตัวแทนของการจำแนกสิ่งปกคลุมดินทั้ง 5 ชั้นการจำแนกได้แก่ หลังคาเรือน ประกอบด้วยจุดตัวแทน 11 จุด ไม้ยืนต้น 10 จุด แหล่งน้ำ จำนวน 6 จุด พื้นที่นาข้าว จำนวน 5 จุดและพื้นที่พืชไร่ จำนวนจุดตัวแทน 6 จุดซึ่งรวมจุดตัวอย่างที่ใช้ในพื้นที่ศึกษาขนาดเล็กนี้ทั้งสิ้นจำนวน 46 จุดตัวอย่าง โดยในตารางคุณลักษณะสัมพันธ์ ได้สร้างฟิลด์เก็บข้อมูลชื่อ Class_id เป็นชนิด Short integer เพื่อใช้รองรับรหัสตัวแทนการใช้ที่ดินโดยรหัสของสิ่งปกคลุมดิน Class_id = 1 ได้แก่ roofs Class_id = 2 ได้แก่ ไม้ยืนต้น Class_id = 3 ได้แก่ แหล่งน้ำ Class_id = 4 นาข้าวและ Class_id = 5 ได้แก่

พืชไร่ตามลำดับ ภายหลังจากที่ตัดวัตถุภาพแล้วได้ใช้อัลกอริทึม Assign class เพื่อจำแนกชั้นการจำแนกโดยยึดตามตารางคุณลักษณะสัมพันธ์ที่สร้างขึ้นจากฟิลด์ชื่อ Class_id โดยกำหนดให้ Threshold condition อ้างอิงไปยัง Thematic attribute ดังกล่าว โดยใช้เงื่อนไข **if Sample.shp (Class_id = 1) then Classify to roofs** และได้ใช้เงื่อนไขจนครบทั้ง 5 ชั้นการจำแนก หลังจากนั้นวัตถุภาพที่ถูกจำแนกโดยอาศัยจุดตัวอย่างดังกล่าวถูกแปลงให้เป็น Sample โดยใช้ อัลกอริทึม **Classified image object to sample** เพื่อที่จะแปลงค่าตัวแทนของชั้นการจำแนกที่ได้จากการแปลภาพด้วยสายตาเหล่านั้นให้เป็นกลุ่มตัวอย่างที่ใช้ได้ภายใต้สิ่งแวดล้อมของ eCognition developer จากนั้นได้ทำการตั้งค่าให้คุณสมบัติการจำแนกแบบ Nearest neighbor: NN classification โดยใช้เงื่อนไขได้แก่ Mean value, Standard deviation และ Pixel-based จากนั้นได้ทำการจำแนกจากค่าคุณสมบัติที่เลือกใช้โดยใช้การจำแนกแบบ NN classifier ซึ่งคุณสมบัติเหล่านี้ได้ถูกกำหนดด้วยกฎที่ใช้ในการจำแนกให้แต่ละชั้นการจำแนกด้วย Assign class algorithm โดยเลือก Class filter ทุกๆ ชั้นการจำแนกรวมๆ กันเพียงครั้งเดียว คุณสมบัตินี้ใช้ในการจำแนกแสดงได้ดัง Table 2

Table 2 Threshold condition for image classification

Features types	Feature names
Spectral	Mean bands: Mean Blue, Mean Green, Mean Red, Mean NIR
Standard Deviation	Sdev.Red, Sdev. Green, Sdev blue, and Sdev. NIR
Pixel-based	Band ratios: Ratio Blue, Ratio Green, Ratio Red, and Ratio NIR

กระบวนการที่ 2 (Scenario 2: S2) เป็นกระบวนการจำแนกภาพถ่ายโดยทำการตัดวัตถุภาพซึ่งใช้ภาพถ่ายดาวเทียมเช่นเดียวกันกับที่ใช้ในกระบวนการที่ 1 คุณสมบัติในการตัดวัตถุภาพเท่ากันเพื่อให้เกิดคุณสมบัติทางวัตถุภาพที่ใกล้เคียงกันได้แก่ค่า Scale parameter = 80 Shape = 0.1 และ Compactness = 0.5 โดยใช้อัลกอริทึม Multiresolution segmentation ทำให้ได้วัตถุภาพหลังจากที่ตัดวัตถุภาพแล้วจำนวนทั้งสิ้น 610 วัตถุภาพโดยไม่นำข้อมูลเวกเตอร์หรือ Thematic layer ใดๆ เข้ามาร่วมในการตัดวัตถุภาพ¹⁴ ผู้วิจัยได้ทำการเลือกวัตถุภาพตัวอย่างจากวัตถุภาพที่ตัดแล้ว (Sample selection from existing image objects) และเป็นพื้นที่เดียวกันกับที่เลือกจุดภาพในกระบวนการที่ 1 (Scenario 1: S1) ซึ่งขั้นการจำแนกที่ใช้ในกระบวนการนี้ประกอบด้วย 5 ขั้นการจำแนกได้แก่หลังเครื่อง นาข้าว พืชไร่ แหล่งน้ำและไม้ยืนต้น ในกระบวนการจำแนกข้อมูลได้ใช้วิธีเลือกวัตถุภาพ (Image objects) (Laliberte *et al.*, 2007 ; Wang *et al.*, 2018 ; Zhai *et al.*, 2018) โดยทำการเลือกวัตถุภาพให้ตรงกับชุดข้อมูลตำแหน่งที่จุดสุ่มดังเช่นในกระบวนการที่ 1 ทุกประการ นอกจากนี้คุณสมบัติเชิงคลื่นและคุณสมบัติของวัตถุภาพอื่นๆ ก็มีคุณลักษณะเดียวกันในกระบวนการที่ 1 เช่นเดียวกัน

การเปรียบเทียบผลการจำแนกทำได้โดยใช้วัตถุภาพที่ได้จากการแปลงหรือนำเข้าจากข้อมูลภายนอกและจุดที่ได้จากการแปลงภาพด้วยสายตาในกระบวนการที่ 1 โดยถือว่ากลุ่มของวัตถุภาพที่เลือกให้เป็นข้อมูลอ้างอิงนี้ได้รับการพิจารณาแล้วจากกระบวนการแปลงภาพด้วยสายตา ซึ่งถือว่าเป็นวัตถุภาพที่มีความถูกต้องตรงกับสิ่งปกคลุมดินหรือการใช้ประโยชน์ที่ดินที่แท้จริงในพื้นที่ศึกษา (Radoux & Bogaert, 2017) การตรวจสอบความถูกต้องได้แยกทำในแต่ละวิธีซึ่งพิจารณา Overall accuracy และ Kappa statistics ซึ่งเป็นกระบวนการในการศึกษาเปรียบเทียบแบบตาราง Error matrix ซึ่งประกอบด้วย User's accuracy/ Producers' accuracy/ Overall accuracy และ Kappa statistic (K_{hat}) (Costa *et al.*, 2018) โดยกลุ่มตัวอย่างใช้วิธีในการสุ่มแบบ Stratified Random Sampling (Cai *et al.*, 2018 ; Kramm *et al.*, 2017) เนื่องจากเป็นกระบวนการในการจัดเก็บกลุ่มตัวอย่างแบบสุ่มทั่วทั้งพื้นที่สอดคล้องกันขั้นการจำแนกของขั้นการจำแนกแต่ละประเภท โดย Kappa coefficient หรือ K_{hat} มีค่าอยู่ระหว่าง

0 ถึง 1 ซึ่งเป็นค่าทางสถิติที่ใช้ในการประเมินความถูกต้องของการคำนวณค่าความถูกต้องจากตาราง Error matrix ที่มีการเปรียบเทียบจากตารางของเมทริกซ์แนวเฉียงซึ่งประกอบด้วยความถูกต้อง 3 ประเภทดังที่ได้กล่าวไว้แล้ว ทั้งนี้ K_{hat} สามารถคำนวณได้จาก Equation 1

$$k_{hat} = \frac{Obs-exp}{1-Exp} \quad (1)$$

เมื่อ

Obs = ความถูกต้องหลังการจำแนกโดยรวม (Overall accuracy)

Exp = ความถูกต้องหลังการจำแนกที่ผู้จำแนกคาดหวัง (Expected correct)

ซึ่งหากพิจารณาความถูกต้องโดยรวมของจุดภาพหรือวัตถุภาพที่ได้รับการจำแนกแบบแนวเฉียงร่วมกันระหว่างผลที่ได้จากการจำแนกเทียบกับแหล่งข้อมูลอ้างอิงแล้วจะสามารถคำนวณได้ดัง Equation 2 โดยค่า Khat ควรมีค่า ≥ 0.8 จึงจะถือว่าการจำแนกครั้งนี้ได้ผลเป็นที่น่าพึงพอใจ (Ma *et al.*, 2017)

$$K_{hat} = \frac{N \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (x_{i+})(x_{+i})}{N^2 - \sum_{i=1}^k (x_{i+})(x_{+i})} \quad (2)$$

โดย

$N \sum_{i=1}^k x_{ii}$ = จำนวนจุดภาพทั้งหมดคูณด้วยผลรวมของขั้นการจำแนกทั้งชั้นตามแนวทแยง

$\sum_{i=1}^k (x_{i+})(x_{+i})$ = ผลรวมของค่าผลคูณจากจุดภาพที่ได้รับการจำแนกทั้งหมดทั้งในแนวตั้งและแนวนอน

กระบวนการดำเนินงานทั้งหมดของการศึกษานี้แสดงได้ดัง Figure 2




Figure 2 Work flow diagram

ผลการศึกษา

การศึกษานี้ได้ทำการเปรียบเทียบกระบวนการในการจำแนกแบบเชิงวัตถุโดยทำการเปรียบเทียบการจำแนกแบบกำกับควบคุมโดยนำเข้าข้อมูล 2 ชุดข้อมูลได้แก่ การใช้จุดตัวอย่างจากการแปลภาพด้วยสายตาและกระบวนการในการคัดเลือกกลุ่มตัวอย่างโดยตรงจากภาพถ่ายที่ทำการตัดแล้ว

ผลการศึกษาพบว่า การวิเคราะห์ภาพถ่ายด้วยกระบวนการที่ 1 ซึ่งเป็นการจำแนกแบบใช้จุดควบคุมจากภายนอกในรูปแบบเวกเตอร์แบบจุดผลการจำแนกภาพถ่ายในกระบวนการวิเคราะห์ที่ 1 พบว่าจากชั้นการจำแนกทั้งสิ้น 5 ชั้นการจำแนกหลังคาเรือนถูกจำแนกทั้งสิ้น 35,341.92 ตร.ม. เป็นจำนวน 187 จุดภาพ ชั้นการจำแนกไม้ยืนต้นได้รับการจำแนกคิดเป็นพื้นที่ 50,905.80 ตร.ม. พื้นที่แหล่งน้ำได้รับการจำแนกทั้งสิ้น 3,583.08 ตร.ม. พื้นที่นาข้าวถูกจำแนก 64,346.04 ตร.ม. พืชไร่ ถูกจำแนก 61,555.68 ตร.ม. ตามลำดับ ซึ่งพบว่า ในกระบวนการวิเคราะห์ที่ 1 พื้นที่นาข้าว ได้รับการจำแนกมากที่สุด รองลงมาได้แก่พื้นที่เกษตรกรรมและพื้นที่แหล่งน้ำได้รับการจำแนกน้อยที่สุดมีจำนวน 7 วัตถุภาพรายละเอียดแสดงได้ดัง Table 3 และผลการจำแนกแสดงได้ดัง Figure 3




Figure 3 Classification result from points sample-based (scenario 1)

Table 3 Area of classified image objects from scenario 1 (S1)

Class name	Area (sq.m.)	Classified Image objects
Roofs	35,341.92	187
Trees	50,905.80	174
Water bodies	3,583.08	7
Paddy field	64,346.04	96
Crops	61,555.68	133
Total	215,732.52	597

สำหรับผลการวิเคราะห์ภาพจากกระบวนการที่ 2 (Scenario 2: S2) พบว่าพบจากชั้นการจำแนกทั้งสิ้น 5 ชั้น การจำแนก หลังคาเรือนถูกจำแนกทั้งสิ้น 31,793.76 ตร.ม. เป็นจำนวน 160 วัตถุภาพ ชั้นการจำแนกไม้ยืนต้นได้รับการจำแนกคิดเป็นพื้นที่ 51,765.12 ตร.ม. พื้นที่แหล่งน้ำได้รับการจำแนกทั้งสิ้น 1,945.80 ตร.ม. พื้นที่นาข้าวถูกจำแนก 55,955.88 ตร.ม. พื้นที่ไร่ถูกจำแนก 73,614.96 ตร.ม. ตามลำดับ

ซึ่งพบว่า ในกระบวนการวิเคราะห์ที่ 2 พื้นที่พืชไร่ได้รับการจำแนกมากที่สุด รองลงมาได้แก่พื้นที่นาข้าวและไม้ยืนต้นตามลำดับ สำหรับพื้นที่ที่ได้รับการจำแนกน้อยที่สุดได้แก่ แหล่งน้ำจำนวน 6 วัตถุภาพซึ่งสอดคล้องกับสภาพที่แท้จริงของพื้นที่ ศึกษารายละเอียดแสดงได้ดัง Table 4 ผลการจำแนกแสดงได้ดัง Figure 4

Table 4 Classification result from image objects sample-based (scenario 2: S2)

Class name	Area (sq.m.)	Classified Image objects
Roofs	31,793.76	160
Trees	51,765.12	171
Water bodies	1,945.80	6
Paddy field	55,955.88	92
Crops	73,614.96	172
Total	215,075.52	601




Figure 4 Classification result from image objects sample-based (scenario 2)

การตรวจสอบความถูกต้อง

ในการศึกษานี้ได้ใช้กระบวนการในการตรวจสอบความถูกต้องแบบ การเปรียบเทียบผลการจำแนก Stratified Random Sampling โดยได้เตรียมจุดควบคุมอ้างอิงที่ทราบแน่ชัดสอดคล้องกับชั้นการจำแนกที่ได้ทำการจำแนกทั้ง 5 ชั้น สำหรับกระบวนการจำแนกที่ 1 (S1) ซึ่งพบว่าความถูกต้องหลังการจำแนกผลการจำแนกโดยรวมร้อยละ 85.71 และค่า $Kappa statistic = 0.82$ สำหรับกระบวนการจำแนกที่ 2 (S2) ซึ่งพบว่าความถูกต้องหลังการจำแนกผลการจำแนกมีค่าความถูกต้องโดยรวม = 79.19% และ $Kappa statistic = 0.73$ ตามลำดับ ผลการตรวจสอบความถูกต้องโดยรวมของทั้ง 2 กระบวนการแสดงดัง Table 5

Table 5 Accuracy assessment process for each Land cover class from scenario 1 (S1) and 2 (S2)

Classes	Users' accuracy (UA)		Producer's accuracy (PA)	
	S1	S2	S1	S2
Roofs	77%	74%	88%	77%
Trees	94%	87%	89%	83%
Water bodies	89%	81%	74%	85%
Paddy field	85%	83%	79%	65%
Crops	81%	69%	88%	73%
Overall accuracy	S1: 85.71 %		S2: 79.19%	
K_{hat}	S1: 0.82		S2: 0.73	

วิจารณ์และสรุปผลการศึกษา

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบความถูกต้องของการจำแนกข้อมูลภาพถ่ายดาวเทียมรายละเอียดสูง QuickBird รายละเอียดเชิงพื้นที่ 0.60 เซนติเมตร โดยใช้กระบวนการการจำแนกแบบ Nearest Neighbor โดยการเลือกกลุ่มตัวอย่างจากวัตถุภาพที่ถูกสร้างขึ้นและเปรียบเทียบกับวิธีการเลือกกลุ่มตัวอย่างจากข้อมูลแบบจุดเวกเตอร์ที่ได้จากการแปลภาพด้วยสายตาจากระบบสารสนเทศภูมิศาสตร์ โดยมีขั้นตอนการจำแนกที่ใช้จำนวน 5 ขั้นตอนการจำแนก ได้แก่ หลังคาเรือน ไม้ยืนต้น แหล่งน้ำ นาข้าวและพืชไร่ การจำแนกพบว่า การเลือกจุดตัวอย่าง (S1) ในระบบสารสนเทศภูมิศาสตร์เพื่อนำมาใช้ในการสร้างกลุ่มตัวอย่าง พบว่าค่าที่ได้จากการตรวจสอบความถูกต้องโดยรวมสูงกว่ากระบวนการวิเคราะห์ที่ 2 (S2) โดยคิดเป็นร้อยละ 85.71 และค่า Khat มีค่าเท่ากับ 0.82 ในขณะที่ความถูกต้องโดยรวมของกระบวนการวิเคราะห์แบบที่ 2 มีค่าเท่ากับ 79.19 และค่า khat มีค่าเท่ากับ 0.73 โดยกระบวนการตรวจสอบความถูกต้องนี้ผู้วิจัยได้ใช้ตารางความคลาดเคลื่อน (Error matrix) ในการคำนวณโดยเปรียบเทียบกับจุดที่ได้จากการแปลภาพด้วยสายตาและเวกเตอร์ที่ได้ทำการดิจิทัลเพื่อใช้เป็นข้อมูลอ้างอิงในการคำนวณเพื่อเปรียบเทียบผลการศึกษาดังกล่าว อย่างไรก็ตามเมื่อพิจารณาเป็นรายขั้นตอนการจำแนกของแต่ละกระบวนการวิเคราะห์พบว่า ยังมีความเหลื่อมล้ำและค่าความถูกต้องโดยรวมอาจยังไม่ใช้คำตอบท้ายที่สุดที่ต้องพิจารณา โดยพบว่ากระบวนการจำแนกในวิธีการที่ 2 มีบางชั้นข้อมูลที่มีความถูกต้องใกล้เคียงกันเช่น ชั้นหลังคาเรือน (Roofs) และนาข้าว (Paddy field) เป็นต้น ทั้งนี้หากเป็นพื้นที่ศึกษาขนาดเล็กทำให้สะดวกและใช้เวลาไม่มากนักในการเตรียมจุดตัวอย่างจากภายนอกมาใช้เพื่อเป็นพื้นที่ตัวอย่างหรือตัวแทนในแต่ละขั้นตอนการจำแนกแน่นอนว่าจากผลการศึกษาผู้วิจัยแนะนำว่าใช้กระบวนการวิเคราะห์แบบที่ 1 น่าจะเหมาะสมที่สุดเนื่องจากได้ผ่านกระบวนการแปลด้วยสายตามาแล้วในระดับหนึ่ง แต่หากพื้นที่ศึกษามีขนาดใหญ่ครอบคลุมบริเวณที่กว้างขึ้นอาจต้องใช้เวลาหรือในการจัดเตรียมข้อมูลหากเป็นเช่นนั้นผู้วิจัยแนะนำว่าควรใช้กระบวนการวิเคราะห์ภาพแบบที่ 2 จะเหมาะสมที่สุดแต่เพื่อให้ความถูกต้องหลังการจำแนกให้ได้ค่าที่พึงพอใจมากที่สุดผู้ศึกษาอาจต้องมีการเพิ่มกระบวนการต่างๆ เข้าไปในกระบวนการวิเคราะห์ เช่น ใช้คุณสมบัติการวิเคราะห์ทั้งในส่วนของคุณสมบัติเชิงคลื่นและเชิงรูปร่างของวัตถุภาพเพิ่มเติมเข้าไปในกฎการจำแนกร่วมกับการเทียบเคียงกับแหล่งข้อมูลจากหน่วยงานอื่นๆ เช่น ข้อมูลการใช้ประโยชน์ที่ดินจากกรมพัฒนาที่ดินมาช่วยร่วมกับการวิเคราะห์ทั้งก่อนและหลัง

กระบวนการซึ่งนับเป็นทางเลือกที่เหมาะสมในการได้มาซึ่งผลการวิเคราะห์ภาพถ่ายดาวเทียมรายละเอียดสูงแบบเชิงวัตถุ นั่นเอง นอกจากนี้อาจมีการผสมผสานกระบวนการทั้ง 2 ข้างต้นเข้าด้วยกันกล่าวคือการใช้กลุ่มตัวอย่างทั้งแบบจุดในบางขั้นตอนการจำแนกที่ต้องการความถูกต้องสูงหรืออาจใช้ในกรณีที่เกิดความลังเลสงสัยว่าลักษณะที่ปรากฏในภาพถ่ายเป็นการใช้ประโยชน์ที่ดินหรือสิ่งปกคลุมดินประเภทใด

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณสำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน) ที่ได้ให้ความอนุเคราะห์ภาพถ่ายดาวเทียมรายละเอียดสูง QuickBird แบบหลายช่วงคลื่นเพื่อใช้ในการวิจัยในครั้งนี้

เอกสารอ้างอิง

- Cai, L., Shi, W., Miao, Z., & Hao, M. (2018). Accuracy assessment measures for object extraction from remote sensing images . *Remote Sensing*, 10(2), 303. <https://doi.org/10.3390/rs10020303>
- Cariou, C., Chehdi, K., & Moan, S. L. (2020). Improved nearest neighbor density-based clustering techniques with application to hyperspectral images. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 4127–4131. <https://doi.org/10.1109/ICASSP40776.2020.9053489>
- Costa, H., Foody, G. M., & Boyd, D. S. (2018). Supervised methods of image segmentation accuracy assessment in land cover mapping. *Remote Sensing of Environment*, 205, 338–351. <https://doi.org/10.1016/j.rse.2017.11.024>
- Delfan, E., Naghavi, H., Maleknia, R., & Nouredini, A. (2020). Comparing the capability of sentinel 2 and landsat 8 satellite imagery in land use and land cover mapping using pixel-based and object-based classification methods . *Desert Ecosystem Engineering Journal*, 8(25), 1–12. <https://doi.org/10.22052/deej.2018.7.25.25>
- Hegyi, A., Vernica, M.-M., & Drăguț, L. (2020). An object-based approach to support the automatic delineation of magnetic anomalies. *Archaeological Prospection*, 27(1), 3–12. <https://doi.org/10.1002/arp.1752>

- Huang, H., Lan, Y., Yang, A., Zhang, Y., Wen, S., & Deng, J. (2020). Deep learning versus object-based image analysis (OBIA) in weed mapping of UAV imagery . *International Journal of Remote Sensing*, 41(9), 3446–3479. <https://doi.org/10.1080/01431161.2019.1706112>
- Kramm, T., Hoffmeister, D., Curdt, C., Maleki, S., Khormali, F., & Kehl, M. (2017). Accuracy assessment of landform classification approaches on different spatial scales for the Iranian loess plateau . *ISPRS International Journal of Geo-Information*, 6(11), 366. <https://doi.org/10.3390/ijgi6110366>
- Laliberte, A. S., Rango, A., Herrick, J. E., Fredrickson, E. L., & Burkett, L. (2007). An object-based image analysis approach for determining fractional cover of senescent and green vegetation with digital plot photography. *Journal of Arid Environments*, 69(1), 1–14. <https://doi.org/10.1016/j.jaridenv.2006.08.016>
- Lubis, A. R., Lubis, M., & Khowarizmi, A.-. (2020). Optimization of distance formula in k-nearest neighbor method . *Bulletin of Electrical Engineering and Informatics*, 9(1), 326–338. <https://doi.org/10.11591/eei.v9i1.1464>
- Luo, S., Miao, D., Zhang, Z., & Wei, Z. (2020). Non-numerical nearest neighbor classifiers with value-object hierarchical embedding. *Expert Systems with Applications*, 150, 113206. <https://doi.org/10.1016/j.eswa.2020.113206>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., & Weng, Q. (2011). Per-pixel vs. Object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5), 1145–1161. <https://doi.org/10.1016/j.rse.2010.12.017>
- Papakonstantinou, A., Stamati, C., & Topouzelis, K. (2020). Comparison of true-color and multispectral unmanned aerial systems imagery for marine habitat mapping using object-based image analysis. *Remote Sensing*, 12(3), 554. <https://doi.org/10.3390/rs12030554>
- Radoux, J., & Bogaert, P. (2017). Good practices for object-based accuracy assessment. *Remote Sensing*, 9(7), 646. <https://doi.org/10.3390/rs9070646>
- Rozali, S., Latif, Z. A., Adnan, N. A., Hussin, Y., Blackburn, A., & Pradhan, B. (2020). Estimating feature extraction changes of berkelah forest, malaysia from multisensor remote sensing data using an object-based technique . *Geocarto International*, 0(ja), 1–15. <https://doi.org/10.1080/10106049.2020.1852610>
- Song, A., Kim, Y., & Han, Y. (2020). Uncertainty Analysis for object-based change detection in very high-resolution satellite images using deep learning network . *Remote Sensing*, 12(15), 2345. <https://doi.org/10.3390/rs12152345>
- Tang, Z., Wang, H., Li, X., Li, X., Cai, W., & Han, C. (2020). An object-based approach for mapping crop coverage using multiscale weighted and machine learning methods . *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1700–1713. <https://doi.org/10.1109/JSTARS.2020.2983439>
- Wang, X., Liu, S., Du, P., Liang, H., Xia, J., & Li, Y. (2018). Object-based change detection in urban areas from high spatial resolution images based on multiple features and ensemble learning . *Remote Sensing*, 10(2), 276. <https://doi.org/10.3390/rs10020276>
- Wang, Z., Li, X., Jin, J., Liu, Z., & Liu, W. (2020). Unsupervised clustering of neighborhood associations and image segmentation applications. *Algorithms*, 13(12), 309. <https://doi.org/10.3390/a13120309>
- Wu, Y., & Zhang, X. (2020). Object-Based Tree Species classification using airborne hyperspectral images and lidar data . *Forests*, 11(1), 32. <https://doi.org/10.3390/f11010032>
- Zhai, D., Dong, J., Cadisch, G., Wang, M., Kou, W., Xu, J., Xiao, X., & Abbas, S. (2018). Comparison of pixel- and object-based approaches in phenology-based rubber plantation mapping in fragmented landscapes . *Remote Sensing*, 10(1), 44. <https://doi.org/10.3390/rs10010044>