

การตรวจหาและสกัดแหล่งน้ำจากภาพถ่าย Bing Maps ด้วยเทคนิคของ มาร์คอฟแบบสุ่มพื้นที่

Water Body Detection and Extraction from Bing Maps Images Using Markov
Random Fields Technique

ธีรภัทร์ บุตรโคตร¹ และ พิพัทธ์ เรืองแสง^{1,2}

Teerapat Butkhot and Pipat Reungsang

¹ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยขอนแก่น

²ศูนย์ภูมิสารสนเทศเพื่อการพัฒนาภาคตะวันออกเฉียงเหนือ มหาวิทยาลัยขอนแก่น

โทรศัพท์: 043-362188 / โทรสาร: 043-324910 / email: reungsang@kku.ac.th

บทคัดย่อ

น้ำเป็นทรัพยากรสำคัญที่ใช้ในเกี่ยวข้องกับชีวิตประจำวันของมนุษย์ซึ่งต้องมีการวางแผนการใช้ทรัพยากรอย่างเป็นระบบเพื่อให้สามารถมีใช้ได้อย่างยั่งยืน ดังนั้นเพื่อให้การวางแผนและบริหารจัดการน้ำเป็นไปอย่างถูกต้อง ข้อมูลแหล่งน้ำที่ถูกต้องและทันสมัยจึงเป็นข้อมูลที่สำคัญ งานวิจัยชิ้นนี้มีจุดประสงค์ในการตรวจหาและสกัดแหล่งน้ำอัตโนมัติจากภาพถ่ายดาวเทียม Bing Maps โดยการประยุกต์ใช้เทคนิคของมาร์คอฟแบบสุ่มพื้นที่ (Markov Random Filed: MRF) ร่วมกับการจำแนกข้อมูลภาพแบบควบคุม (Supervised Image Classification) ซึ่งมีขั้นตอนในการทำงานประกอบไปด้วย: 1) ทำการแบ่งภาพเป็นหน้าต่าง (Super pixels); 2) ทำการสกัดเอกลักษณ์โดยใช้สี; 3) ทำการจำแนกหน้าต่างภาพออกเป็นสองกลุ่ม คือ น้ำและไม่ใช่ น้ำ โดยใช้เทคนิคการสุ่มแบบป่า (Random Forest); และ 4) ทำการเพิ่มประสิทธิภาพในการจำแนกด้วยวิธี MRF ผลการทดลองพบว่าการจำแนกแหล่งน้ำจากภาพถ่ายดาวเทียม Bing Maps ด้วยวิธีแบบควบคุมร่วมกับเทคนิคมาร์คอฟแบบสุ่มพื้นที่ให้ประสิทธิภาพที่ดีกว่าการจำแนกแบบควบคุมโดยไม่ใช้มาร์คอฟแบบสุ่มพื้นที่

คำสำคัญ : การจำแนกข้อมูลแบบควบคุม, เทคนิคมาร์คอฟแบบสุ่มพื้นที่, Bing Maps, การสกัดแหล่งน้ำ

ABSTRACT

Water is an important resource for human daily life, which needs to be planned systematic in order to sustain the resource. For effective planning and managing the resource, accurate and update water body information is important. The objective of the research was to detect and extract water body automatically from Bing Maps Satellite images using supervised image classification with Markov Random Fields (MRFs) technique. The research procedure was divided into 4 steps including: 1) super pixels generation; 2) feature extraction using color-based properties; 3) classification water body using random forest classifier; and 4) improving of the image classification by applying MRFs technique. Experimental results were concluded that classification of water boy from Bing Maps Satellite images using supervised image classification with MRFs gave better performance compare to classification without MRFs.

KEY WORDS: Supervised classification, Markov Random Fields, Bing Maps, water body extraction

บทนำ

น้ำเป็นทรัพยากรที่สำคัญต่อสิ่งมีชีวิตต่างๆ บนโลก เป็นปัจจัยหลักในการดำรงชีวิต สามารถนำไปใช้ได้หลายประเภท อาทิเช่น ใช้อุปโภค บริโภค และทำความสะอาดสิ่งของต่างๆ โดยผสมกับวัตถุที่ทำความสะอาดได้ นอกจากนี้ น้ำยังเป็นที่อยู่ที่พักพิงของสิ่งมีชีวิตต่างๆ เช่น ปลา ปลาหมึก และสิ่งมีชีวิตอื่นๆ อีกมากมาย น้ำจึงจำเป็นต่อสิ่งมีชีวิตซึ่งไม่สามารถขาดได้ จากระบบนิเวศน์หรือวัฏจักรของน้ำทำให้น้ำที่อยู่บนโลกไม่มีวันหมดไป โดยน้ำจะเริ่มจากการก่อตัวในอากาศของน้ำหรือไอน้ำจากนั้นจะลอยไปข้างบน เมื่อโดนอุณหภูมิต่ำที่เย็นก็จะเริ่มก่อตัวเป็นก้อนน้ำแข็งขนาดใหญ่ จากนั้นจะเริ่มแตกสลายลงมาจึงกลายเป็นน้ำฝน ในด้านเกษตรกรรม น้ำมีความสำคัญอย่างมากต่อชาวเกษตรกร โดยเฉพาะในภาคตะวันออกเฉียงเหนือของประเทศไทย ที่ประชากรส่วนมากประกอบอาชีพเกษตรกรรม เมื่อเกิดการเปลี่ยนแปลงของฤดูกาลจากภัยธรรมชาติต่างๆ จากน้ำท่วม ภัยแล้ง ทำให้ส่งผลกระทบต่ออาชีพ การดำรงชีวิตของเกษตรกร ดังนั้นเพื่อแก้ปัญหาการเพิ่ม-ลดของปริมาณน้ำจากแหล่งน้ำธรรมชาติ จึงเกิดการสำรวจหาพื้นที่แหล่งน้ำอื่นเพื่อนำมาเป็นแนวทางในการบริหารจัดการน้ำ การป้องกัน และการแก้ปัญหาที่เกิดขึ้นจากแหล่งน้ำที่เพิ่มขึ้นหรือลดลงในแต่ละพื้นที่

การตรวจจำแนกและระบุพื้นที่น้ำในภาพถ่ายดาวเทียมแบบอัตโนมัติถือได้ว่าเป็นงานที่ทำหายและยังเป็นที่สนใจจากนักวิจัยหลายๆ กลุ่ม ตัวอย่าง เช่น Frazier และ Page ได้ทำการศึกษาวิจัยเทคนิคในการจำแนกพื้นที่น้ำในภาพถ่ายดาวเทียมแบบ Landsat TM โดยงานวิจัยนี้ใช้เทคนิคการจำแนกแบบฝึกฝนด้วยตัวจำแนก maximum likelihood (Frazier & Page, 2003) หรือ Xin และ Yetik ได้จำแนกข้อมูลภาพถ่ายโดยอาศัยคุณสมบัติของสีของพิกเซล โดยการจำแนกจะทำการจำแนกน้ำจากภาพถ่ายดาวเทียมแต่ละช่องภาพ (image bands) แยกกัน ซึ่งมีทั้งหมด 7 ช่องภาพ จากการทดลองพบว่าการใช้ช่องภาพที่ 5 ให้ผลลัพธ์ในการจำแนกพื้นที่น้ำได้เป็นที่พอใจ (Xin & Yetik, 2009) นอกจากการใช้เอกลักษณ์คุณลักษณะของสีในการจำแนกพื้นที่น้ำในภาพถ่ายดาวเทียมแล้ว นักวิจัยหลายๆ กลุ่มยังสนใจที่จะใช้เอกลักษณ์อื่นในการจำแนกพื้นที่น้ำ อาทิเช่น Tiagrajah และ Win ได้ใช้เอกลักษณ์แบบคลื่นภาพ (frequency image domain) ในการสร้างเอกลักษณ์ของภาพซึ่งจะถือได้เป็นเอกลักษณ์ที่บ่งบอกถึงลักษณะของพื้นผิวของพื้นที่ในภาพ นอกจากการใช้เอกลักษณ์แบบคลื่นภาพแล้วงานวิจัยชิ้นนี้ทำการจำแนกพื้นที่น้ำด้วยตัวจำแนกแบบ self-organization map (SOM) โดยใช้โครงข่ายประสาทเทียม (neural network) การทดลองในงานวิจัยชิ้นนี้โดยใช้ภาพถ่ายดาวเทียมแบบ Landsat TM พบว่า เทคนิคที่งานวิจัยได้นำเสนอในการจำแนกพื้นที่น้ำนั้นให้ประสิทธิภาพที่ดี (Tiagrajah & Win, 2003) หรืองานวิจัยของ Nath และ Deb ซึ่งได้ทำการศึกษาถึงเทคนิคและวิธีการในการจำแนกพื้นที่น้ำในภาพถ่ายดาวเทียม ในการศึกษานี้ได้ทำการศึกษาทั้งประเภทภาพถ่ายดาวเทียม เอกลักษณ์ที่ใช้ในการจำแนก รวมถึงวิธีในการสร้างตัวจำแนก จากนั้นได้ทำการทดลองเพื่อวัดประสิทธิภาพการจำแนกพื้นที่น้ำโดยใช้ข้อมูลภาพต่าง เอกลักษณ์ที่ต่างกัน (เช่น สี ขอบขอบวัตถุ พื้นผิว เงา เป็นต้น) และใช้ตัวจำแนกที่ต่างกัน เช่น support vector machine และ K-nearest neighboring จากการทดลองของงานวิจัยนี้พบว่า เทคนิควิธีที่ใช้ในการจำแนกภาพถ่ายดาวเทียมนั้นจะเหมาะกับข้อมูลเฉพาะบางข้อมูลเท่านั้น ยังไม่มีเทคนิคไหนที่สามารถนำมาประยุกต์ได้กับทุกๆ ประเภทของภาพถ่ายดาวเทียม (Nath & Deb, 2010)

งานวิจัยชิ้นนี้ได้ทำการประมวลผลภาพแบบอัตโนมัติในการจำแนกและระบุพื้นที่น้ำ (water body) ในภาพถ่ายดาวเทียมของ Bing maps โดยการจำแนกพิกเซลในภาพออกเป็นสองกลุ่ม ได้แก่ พื้นที่น้ำและพื้นที่ที่ไม่ใช่ น้ำ จากนั้นจะทำการประมวลผลเพื่อปรับปรุงผลการจำแนกโดยการพิจารณาถึงความสัมพันธ์ของพิกเซลที่สนใจกับพิกเซลข้างเคียงโดยใช้เทคนิคมาร์คอฟแบบสุ่มพื้นที่ (Markov random fields)

วิธีการดำเนินการ

ในหัวข้อนี้จะอธิบายถึงกระบวนการดำเนินการในการระบุพื้นที่น้ำในภาพถ่ายดาวเทียม Bing maps หลักการโดยทั่วไปในการระบุพื้นที่น้ำนั้นจะอาศัยเทคนิคและวิธีการทางด้านการประมวลผลภาพ และเทคนิคการเรียนรู้ของเครื่องจักร (machine learning techniques) โดยจะทำการจำแนกพิกเซลในภาพออกเป็นสองกลุ่ม ได้แก่ พิกเซลที่เป็นส่วนของพื้นที่น้ำ และพิกเซลที่ไม่ใช่ส่วนของพื้นที่น้ำ โดยการจำแนกนี้จะอาศัยวิธีการในการจำแนกแบบไม่เรียนรู้ (unsupervised techniques) จากนั้นจะทำการปรับปรุงผลการจำแนกด้วยการใช้เทคนิค Markov Random Fields เพื่อให้ผลลัพธ์ที่ดีขึ้น ในหัวข้อนี้จะทำการแบ่งหัวข้อย่อยออกเป็น 3 หัวข้อดังต่อไปนี้

1. ข้อมูลภาพ

ข้อมูลภาพที่ใช้ในการศึกษารั้งนี้ได้มาจาก Bing maps ซึ่งเป็นภาพแผนที่ในเขตภาคตะวันออกเฉียงเหนือของประเทศไทย ภาพจะถูกกำหนดให้มีขนาด 1000x1000 พิกเซล โดยภาพจะมีองค์ประกอบที่มีพื้นน้ำ (water body) และส่วนที่ไม่ใช่พื้นน้ำ (non water body) โดยแต่ละภาพของ Bing Map จะถูกลากขอบเขต (digitize) เพื่อใช้เป็นข้อมูลต้นแบบเพื่อใช้ในการวัดประสิทธิภาพของวิธีการจำแนกแหล่งน้ำที่นำเสนอในงานวิจัยนี้ ตัวอย่างของข้อมูลภาพแสดงในรูปที่ 1 ข้างล่าง



(ก)

(ข)

รูปที่ 1 แสดงตัวอย่างของภาพที่ใช้ในการศึกษา (ก) ภาพ Bing map และ (ข) ข้อมูลที่ลากขอบเขตด้วยมือ

2. การจัดกลุ่มพิกเซล

เมื่อได้ภาพเพื่อประมวลผลแล้ว ขั้นตอนแรกคือการจัดกลุ่มพิกเซลในภาพ โดยงานชิ้นนี้จะทำการจัดกลุ่มหรือจำแนกข้อมูลพิกเซลในภาพออกเป็นสองกลุ่ม ได้แก่ น้ำ และไม่ใช่พื้นน้ำ ซึ่งพิจารณาจากค่าสีในปริภูมิ RGB (RGB color-space) งานชิ้นนี้จะใช้เทคนิค K-means ในการจำแนก เทคนิคนี้เป็นเทคนิคที่ไม่ต้องมีผู้สอนที่ง่ายที่สุด โดยเป็นวิธีการในการจำแนกแบบไม่ฝักใฝ่ฝ่ายใด ซึ่งจะต้องกำหนดจำนวนกลุ่มของข้อมูลหรือ K โดยกำหนดให้ข้อมูลประกอบไปด้วยกลุ่มของพิกเซล x_n และตัวแปรควบคุม $r_{nk} \in \{1,0\}$ เมื่อ n คือ จำนวนพิกเซลในภาพ และที่ K=2 (MacQueen, 1967) จากนั้น K-mean จะทำการกำหนดกลุ่ม K ให้กับข้อมูล x_n ใดๆ กล่าวคือ $r_{nk} = 1$ และ $r_{nj} = 0$ เมื่อ $j \neq k$ เราสามารถสร้างฟังก์ชันจุดประสงค์เพื่อทำการจำแนกข้อมูลได้ดังต่อไปนี้

$$J = \sum_{n=1}^N \sum_{k=1}^K r_{nk} \|x_n - \mu_k\|^2 \tag{1}$$

หลักการคือจะต้องทำการ optimize ค่า J ให้มีค่าน้อยที่สุดโดยจะต้องหาค่า r_{nk} และ μ_k ที่เหมาะสม ซึ่งสามารถทำได้โดยการ optimize ค่า r_{nk} แล้วหลังจากนั้นทำการ optimize ค่า μ_k โดยเริ่มต้นจะทำการกำหนดค่าเริ่มต้นให้กับ μ_k จากนั้นจะทำการปรับค่า r_{nk} โดยพิจารณาให้ค่า J มีค่าน้อยที่สุด เมื่อได้ค่า r_{nk} แล้วจะทำการปรับค่า μ_k จนทำให้ค่า J มีค่าน้อยที่สุดตาม เนื่องจากว่าค่า r_{nk} ในสมการที่ x เป็นค่า binary โดยค่า r_{nk} จะมีค่าเป็น 1 เมื่อ $\|x_n - \mu_k\|^2$ มีค่าน้อยที่สุดเพื่อจะทำให้ค่า J มีค่าน้อยที่สุด ดังนั้นจะได้ว่า

$$r_{nk} = \begin{cases} 1 & \text{ถ้า } k = \arg \min_j \|x_n - \mu_j\|^2 \\ 0 & \text{กรณีที่ไม่ใช่} \end{cases} \quad (2)$$

พิจารณาที่ค่า μ_k เมื่อได้ค่า r_{nk} มาแล้วเราสามารถ optimize ค่า J ให้มีค่าน้อยที่สุดโดยพิจารณาค่า μ_k โดยการกำหนดอนุพันธ์อันดับ 1 ให้กับสมการที่ (1) มีค่าให้เท่ากับ 0 จะได้ว่า

$$2 \sum_{n=1}^N r_{nk} (x_n - \mu_k) = 0 \quad (3)$$

ซึ่งสามารถแก้สมการได้ค่า μ_k ดังต่อไปนี้

$$\mu_k = \frac{\sum_n r_{nk} x_n}{\sum_n r_{nk}} \quad (4)$$

ดังนั้นผลลัพธ์ที่ได้จาก K-means คือ ค่ากลางของกลุ่มพิกเซลที่ถูกจัดกลุ่มให้เป็นพื้นที่น้ำ μ_w ค่ากลางของกลุ่มพิกเซลที่ถูกจัดกลุ่มให้เป็นพื้นที่ไม้เขื่อน้ำ μ_o

3. การปรับปรุงประสิทธิภาพการจำแนกด้วย Markov random fields


เมื่อทำการจำแนกพิกเซลในภาพแล้ว ขั้นตอนต่อไปคือการปรับปรุงผลของการจำแนกพิกเซล โดยการปรับปรุงนี้จะพิจารณาถึงความสัมพันธ์ของพิกเซลในพื้นที่ (local interaction of pixels) การปรับปรุงผลการจำแนก ในงานชิ้นนี้ได้มีการใช้เทคนิคการสุ่มแบบมาคอฟฟิลด์ (Penny, 2002) โดยทั่วไปการสุ่มแบบมาคอฟฟิลด์จะประกอบไปด้วยกราฟแบบไม่กำหนดทิศทาง (Undirected Graph) $G = \{N, E\}$ โดย N คือ โหนดของตัวแปรสุ่ม กำหนดให้ X_s เป็นเซตของตัวแปรสุ่มข้างเคียง (เชื่อมต่อ) กับตัวแปรสุ่ม S เส้นเชื่อม (Edges) E จะแสดงความสัมพันธ์ของตัวแปรสุ่มตามกฎที่ว่า เมื่อกำหนดให้ตัวแปรสุ่ม A, B และ C ใดๆ จะได้ว่า X_A มีความสัมพันธ์แบบไม่ขึ้นตรงแบบมีเงื่อนไขกับ X_B เมื่อ X_A และ X_B เชื่อมต่อ X_C ก็ต่อเมื่อไม่มีเส้นทางโดยตรงที่เชื่อม X_A และ X_B ทำให้สามารถแสดงความสัมพันธ์แบบไม่ขึ้นตรงแบบมีเงื่อนไข (Conditional Independent) ได้ว่า $X_A \perp\!\!\!\perp X_B \mid X_C$ เซตของโหนดข้างเคียง B_n ของโหนด n ใดๆ สามารถกำหนดได้จากกลุ่มของโหนดที่เชื่อมต่อกับ n ผ่านเส้นเชื่อมใดๆ ในกราฟ

$$B_n = \{ m \in n \mid (m, n \in \mathcal{E}) \} \quad (5)$$

กำหนดให้เซตของโหนดข้างเคียงของโหนด n โดยที่ n จะไม่ขึ้นตรงกับโหนดอื่นๆ ยกเว้นโหนดข้างเคียง ดังนั้นเราสามารถเขียนความน่าจะเป็นเชิงเงื่อนไขของ X_n ได้ดังต่อไปนี้

$$P(X_n \mid X_N - X_n) = P(X_n \mid X_{B_n}) \quad (6)$$

ซึ่งแสดงถึงคุณสมบัติของมาร์คอฟ ซึ่งแสดงดังภาพที่ 2



รูปที่ 2 แสดงความสัมพันธ์ของพิกเซลในภาพตามคุณสมบัติมาร์คอฟ โหนดสีดำในกราฟมีความสัมพันธ์แบบมีเงื่อนไขกับโหนดสีเทาที่อยู่รอบๆ

จากคุณสมบัติของมาร์คอฟดังกล่าว สามารถอธิบายถึงการแจกแจงแบบร่วมความสัมพันธ์ที่เป็นไปได้ X (ความเป็นไปได้ทั้งหมดที่จะสามารถเกิดขึ้นได้จากตัวแปรสุ่มในกราฟ) โดยพิจารณาได้จากการแจกแจงแบบมีเงื่อนไขของกลุ่มของตัวแปรสุ่ม $P(X_n | X_{N_n})$ อย่างไรก็ตามเมื่อพิจารณาถึงภาพรวมทั้งหมดของตัวแปรสุ่ม เราสามารถสร้างการแจกแจงแบบมีเงื่อนไขของตัวแปรสุ่มทั้งหมดโดยอาศัยหลักการของการแจกแจงแบบ Gibbs (Casella, 1992) ในกราฟใดๆ ดังสมการดังต่อไปนี้

$$P(x) = \frac{1}{Z} \prod \phi_c(x_c) \quad (7)$$

โดยสมการที่ 7 เกิดจากผลคูณของคลิก (Clique) ทั้งหมดที่อยู่ในกราฟ โดยคลิกคือกลุ่มของโหนดในกราฟที่มีเส้นเชื่อมต่อกันทั้งหมดทุกโหนด ค่า Z คือค่านอร์มอลไลซ์ หรือ ฟังก์ชันของพาร์ติชัน (Partition Function) โดยนิยามดังต่อไปนี้

$$Z = \sum \prod \phi_c(x_c) \quad (8)$$

โดย

$$\phi_c(x_c) = e^{-\frac{1}{T}V_c(x_c)} \quad (9)$$

ซึ่งค่า T จะเรียกว่าตัวแปรอุณหภูมิที่คอยควบคุมความสมดุลในขั้นตอนการ optimization ดังนั้นเราสามารถเขียน $P(x)$ ใหม่ได้ดังสมการข้างล่าง

$$P(x) = \frac{1}{Z} e^{-\frac{1}{T}U(x)} \quad (10)$$

โดย

$$U(x) = \sum V_c(x) \quad (11)$$

ซึ่งถูกเรียกว่าฟังก์ชันพลังงาน (Energy Function) จากบทพิสูจน์ของ Hammersley-Clifford (Bilmes, 2006) ระบุว่า การสุ่มแบบมาคอฟฟิลด์ใดๆ สามารถที่จะเขียนในรูปแบบของการแจกแจงแบบ Gibbs ข้างต้นได้ หลักการสำคัญในการนำการสุ่มแบบมาคอฟฟิลด์มาใช้ในการแบ่งภาพ (Image Segmentation) คือ การออกแบบฟังก์ชันพลังงานที่เหมาะสมในคลิกใดๆ (ตัวแปรสุ่มข้างเคียงหรือพิกเซลในภาพ) ซึ่งโดยทั่วไปนั้นจะสามารถสร้างฟังก์ชันพลังงานได้สอง

เทอม คือ ฟังก์ชันเดี่ยว (Unary term) และฟังก์ชันคู่ (Binary Term) โดยสามารถแสดงความสัมพันธ์เฉพาะพื้นที่ (Locality) ของตัวแปรสุ่มได้ดังนี้

$$V_{c(x)} = Bin(x) + Un(x) \tag{12}$$

เมื่อทำการออกแบบฟังก์ชันได้เหมาะสมแล้ว ขั้นตอนต่อไปคือการ Optimization เพื่อให้ได้ค่าความน่าจะเป็นร่วมที่สูงที่สุดในกราฟ ซึ่งหมายความว่าพิกเซลจะมีค่าที่เหมาะสมที่สุดตามฟังก์ชันที่ได้ออกแบบไว้

ในงานชิ้นนี้เราได้กำหนดค่า $Bin(x)$ เป็นฟังก์ชันที่ขึ้นอยู่กับค่าความเป็นสมาชิกของ $\phi_c(x_c)$ โดย ถ้าพิกเซลที่อยู่ใน $\phi_c(x_c)$ ถูกจัดให้อยู่ในกลุ่มเดียวกันกับ x จะกำหนดให้ $Bin(x) = 1$ และถ้า $\phi_c(x_c)$ ถูกจัดให้อยู่ในกลุ่มต่างจาก x จะกำหนดให้ $Bin(x) = 3$

สำหรับ $Un(x)$ จะทำการคำนวณจากค่าความน่าจะเป็นหลังการจัดกลุ่ม ซึ่งงานชิ้นนี้จะสมมติให้ข้อมูลมีการกระจายแบบปกติ (normal distribution) ดังนั้นจะได้ว่า

$$Un(x_k) = G(x, \mu_k, \sigma_k) \tag{13}$$

โดย

$$G(x, \mu_k, \sigma_k) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu_k)^2}{2\sigma^2}} \tag{14}$$

μ_k และ σ_k คือค่ากลางของพิกเซลกลุ่ม k และความแปรปรวนของพิกเซลกลุ่ม k ซึ่งได้จากขั้นตอนการจำแนกพิกเซลด้วย K-means

เมื่อทำการกำหนดฟังก์ชันเพื่อที่จะทำการ optimize แล้ว optimization จะถูกดำเนินการโดยเทคนิคกราฟคัท (Graph cut technique) (Olga, 2001)

การทดลองและผลการทดลอง

งานชิ้นนี้ทำการประมวลผลภาพแบบอัตโนมัติในการจำแนกและระบุพื้นที่น้ำในภาพถ่ายดาวเทียมของ Bing maps ในหัวข้อที่ผ่านมาได้อธิบายถึงวิธีการในการระบุพื้นที่น้ำ โดยการจำแนกพิกเซลในภาพออกเป็นสองกลุ่ม ได้แก่ น้ำ และพื้นที่ที่ไม่ใช่น้ำ จากนั้นจะทำการประมวลผลเพื่อปรับปรุงผลการจำแนกโดยการพิจารณาถึงความสัมพันธ์ของพิกเซลที่สนใจกับพิกเซลข้างเคียง ด้วยเทคนิคการสุ่มแบบมาร์คอฟ ในหัวข้อนี้จะทำการอธิบายถึงการทดลองเพื่อประเมินประสิทธิภาพของเทคนิคที่น่าเสนอ

เพื่อประเมินประสิทธิภาพของวิธีการที่น่าเสนอ เราได้ทำการเก็บรวบรวมข้อมูลภาพถ่ายดาวเทียม Bing maps โดยทำการเก็บรวบรวม 5 ภาพ ในแต่ละภาพจะมีองค์ประกอบภาพที่เป็นพื้นที่น้ำ และขนาดของภาพถูกกำหนดให้มีขนาด 1000x1000 พิกเซล เพื่อลดระยะเวลาในการประมวล นอกจากภาพทดสอบแล้วเราได้ทำการลากขอบเขตภาพถ่ายดาวเทียมเพื่อใช้เป็นข้อมูลเบื้องต้นสำหรับประเมินประสิทธิภาพ

จากการทดลองพบว่าวิธีการในการระบุพื้นที่น้ำแบบอัตโนมัติที่ได้นำเสนอมีประสิทธิภาพในการระบุกลุ่มพิกเซลได้ถูกต้องถึง 98% โดยค่าการจำแนกแสดงดังตาราง confusion matrix ในตารางที่ 1


ตารางที่ 1 confusion matrix

		True class	
		น้ำ	ไม่ใช่ น้ำ
Proposed technique	น้ำ	401201	10376
	ไม่ใช่ น้ำ	32355	4560778


ผลการทดลองในการระบุพื้นที่น้ำแบบอัตโนมัติด้วยวิธีการที่นำเสนอแสดงดังรูปที่ 3 และ 4



(ก)



(ข)




(ค)


รูปที่ 3 แสดงผลลัพธ์จากการจำแนกด้วยวิธีการที่นำเสนอ (ก) ภาพต้นฉบับ Bing Maps (ข) ภาพที่ทำการลากขอบเขต และ (ค) ผลลัพธ์ที่ได้จากการจำแนก



(ก)



(ข)



(ค)

รูปที่ 4 แสดงผลลัพธ์จากการจำแนกด้วยวิธีการที่นำเสนอ (ก) ภาพต้นฉบับ Bing Maps (ข) ภาพที่ทำการลากขอบเขต และ (ค) ผลลัพธ์ที่ได้จากการจำแนก

สรุปผลการวิจัย

งานชิ้นนี้ศึกษาถึงวิธีการในการจำแนกและระบุพื้นที่น้ำในภาพถ่ายดาวเทียม Bing maps ซึ่งวิธีการหลักในการระบุพื้นที่น้ำ คือ ใช้หลักการการเรียนรู้ในการจำแนกพิกเซลในภาพออกเป็นสองกลุ่ม ซึ่งในการจำแนกนี้จะใช้เทคนิคการจำแนก K-means โดยจะระบุประเภทให้กับพิกเซลในภาพได้แก่ พิกเซลที่เป็นพื้นที่น้ำ และพิกเซลที่ไม่ใช่พื้นที่น้ำตามลำดับ หลังจากทำการจำแนกพิกเซลในภาพแล้ว ผลการจำแนกจะถูกปรับปรุงเพื่อเพิ่มความถูกต้องในการจำแนกมากยิ่งขึ้น ในการปรับปรุงการจำแนกนี้ งานชิ้นนี้ได้ทำการพิจารณาถึงความสัมพันธ์ของพิกเซลรอบข้างเพื่อทำการจำแนกพิกเซล โดยการพิจารณาความสัมพันธ์ของพิกเซลนี้ด้วยเทคนิคการสุ่มแบบมาร์คอฟ

จากการทดลองพบว่าวิธีการที่นำเสนอสามารถจำแนกและระบุพื้นที่น้ำได้ถูกต้อง โดยมีความถูกต้อง 98 % และมีค่า precision = 0.98 และค่า recall = 0.97 แนวทางในการพัฒนาในอนาคตสามารถทำได้ด้วยการใช้เอกลักษณ์แบบพื้นผิว (textures) ในการจำแนก เนื่องจากพื้นที่ที่เป็นบริเวณน้ำจะมีความเข้มของสีที่เข้มและมีพื้นผิวที่เรียบ ดังนั้นการนำเอกลักษณ์แบบพื้นผิวมาใช้ อาจจะทำให้ประสิทธิภาพในการจำแนกได้มากขึ้น

เอกสารอ้างอิง

- Al-Muallim, M.T., & El-Kouatly, R. (2010). Unsupervised Classification Using Immune Algorithm. *International Journal of Computer Applications*, 2(7), 0975 – 8887.
- Barandel, R., & Juarez M. (2001). Supervised classification of remotely sensed data with ongoing learning capability. *International journal remote sensing*, 23(22), 4965–4970.
- Bilmes, J. (2006). Handout 2: Hammersley–Clifford. Course notes from University of Washington course.
- Bishop, C. M. (2006). *Pattern Recognition And Machine Learning*, Springer, 383-393.
- Borman, S. (2009). The Expectation Maximization Algorithm A short tutorial.
- Casella G., & Edward I. (1992). Explaining the Gibbs sampler. *The American Statistician*, 46(3), 167–174.
- Dempster, A.P., & Laird, N. M., and Rubin, D. B. (1977). Maximum likelihood from in complete data via the em algorithm. *Journal of the Royal Statistical Society: Series B*, 39(1), 1–38.
- Frazier, P.S. & Page, K.J. (2003). Water body detection and delineation with Landsat TM data”, *Photogrammetric Engineering and Remote Sensing*, Vol. 66(12) pp.1461-1468, 2000
- Gielen, G., Wambacq, P., & Sansen, W. (1998). Symbolic Analysis Methods and Application for Analog Circuits : A Tutorial Overview”, *Proceedings of the IEEE*, Vol.. 82, No.2, pp.287 – 304, 1994.
- Gong, P. & Marceau, D.J. & Howarth, P.J. (1992). A Comparison of Spatial Feature Extraction Algorithms for Land-Use Classification with SPOT HRV Data. *REMOTE SENS ENVIRON*, 40, 137-151.
- Hames, A. S. & Ahmadi, F. S. (2009). Comparison of Four Classification Methods to Extract Land Use and Land Cover from Raw Satellite Images for Some Remote Arid Areas, Kingdom of Saudi Arabia. *JKAU; Earth Sci*, 20(1), 167-191.
- Hussin, Y.A. & Atmopawiro, V.P. (2002). sub-pixel and maximum likelihood classification of landsat etm+images for detecting illegal logging and mapping tropical rain forest cover types in berau, east kalimantan, indonesia. Department of Natural Resources, The International Institute for Geoinformation Science and Earth Observation (ITC), Hengelstraat 99.

- Lang, R., & Shao, G. (2007). Optimizing unsupervised classifications of remotely sensed imagery with a data-assisted labeling approach. *Computers & Geosciences*, 34,1877–1885.
- Lu, D. & Batistella, M. & Moran, E. and Mausel, P. (2004). Application of spectral mixture analysis to Amazonian land-use and land-cover classification. ACT Publication, 04-09.
- MacQueen, J. B. (1967). Some Methods for classification and Analysis of Multivariate Observations, *Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability*, Berkeley, University of California Press, 1, 281-297
- Manandhar, R. (2009). Improving the Accuracy of Land Use and Land Cover Classification of Landsat Data Using Post-Classification Enhancement. *Remote Sens*, 1, 330-344.
- Nath, R. K., & Deb, S. K. (2010). Water-Body Area Extraction from High Resolution Satellite Images-An Introduction, Review, and Comparison”, *International Journal of Image Processing*, Vol. 3 (6), pp. 353-372
- Pahikkala, T. & Boberg, J & Salakoski, T. (2006). Fast n-Fold Cross-Validation for Regularized Least-Squares. *Turku Centre for Computer Science (TUCS), Department of Information Technology, University of Turku Lemminkäisenkatu.*
- Penny, W. (2002). An EM algorithm for Gaussian Markov Random Fields. *Wellcome Department of Imaging Neuroscience, University College, London WC1N 3BG.*
- Reis, S. (2008). Analyzing Land Use/Land Cover Changes Using Remote Sensing and GIS in Rize. North-East Turkey. *Sensors*, 8(10), 6188-6202.
- Stehman, S.V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*, 62(1), 77–89.
- Szuster, B.W. & Chen, Q. & Borger, M. (2011). A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Applied Geography*, 31, 525-532.
- Tiagrajah, V. J., & Win, K. (2003). SOM based segmentation method for water region detection in satellite Images. *World Journal of Engineering*, Vol. 10(1), pp. 65-100, 2013.
- Xin, L., & Yetik, I.S. (2009). A Maximum Likelihood Classification method for image segmentation considering subject variability," *Image Analysis & Interpretation (SSIAI), 2010 IEEE Southwest Symposium on* , vol., no., pp.125,128, 23-25 May 2010.