

การวิเคราะห์พื้นที่ปกคลุม ทางการเกษตรในประเทศไทยด้วยกระบวนการ CNN

C. Arnal¹ S. Bassanetti¹ H. Corbin¹ วิษณุ มั่งคั่ง² และ Laurent Mezeix^{3*}

วันที่รับ 28 กันยายน 2565 วันที่แก้ไข 9 มกราคม 2566 วันที่ออกรับ 24 มกราคม 2566

บทคัดย่อ

การพัฒนาด้านเกษตรกรรมจำเป็นต้องมีความเข้าใจและมีข้อมูลเชิงภาพที่แสดงถึงพื้นที่ปกคลุมที่จะแสดงให้เห็นถึงภูมิทัศน์ทางภูมิศาสตร์ของพื้นที่ศึกษา บทความวิจัยฉบับนี้นำเสนอการวิเคราะห์พื้นที่ปกคลุมเพื่อการเกษตรในประเทศไทยโดย Convolutional Neural Network (CNN) โดยมีการสร้างชุดข้อมูลรูปภาพ 4 คลาส จำแนกออกเป็น ป่า ดันป่าล้ม นาข้าว และสิ่งปลูกสร้าง รวมกันทั้งสิ้นประมาณ 1,500,000 ภาพ แต่ละภาพจะมีขนาด 64x64 จุดภาพ อีกทั้งแต่ละชุดข้อมูลจะผ่านกระบวนการประมวลผลด้วยโมเดล CNN ที่มีการปรับค่าพารามิเตอร์จนได้ความแม่นยำอยู่ระหว่าง 80-90% ภายหลังจากการประมวลผล โมเดลจะจำแนกพื้นที่ปกคลุมตัดแยกตามชุดข้อมูลรูปภาพแต่ละชุด หลังจากนั้นจะใช้กระบวนการตัดแยก RGB เพื่อจำแนกระดับการเจริญเติบโตของข้าวและขนาดของดันป่าล้ม ก่อนที่จะทำการประมาณการผลผลิตจากดันป่าล้มและนาข้าว

คำสำคัญ : โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การประมวลผลภาพ, พื้นที่ปกคลุม, ภาพถ่ายดาวเทียม

¹ Université de Toulouse, INSA, UPS, Mines d'Albi, ISAE, ICA (Institut Clément Ader)

² ฝ่ายวิเคราะห์เทคโนโลยีป้องกันประเทศ, สถาบันเทคโนโลยีป้องกันประเทศ

³ คณะวิศวกรรมศาสตร์, มหาวิทยาลัยบูรพา

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

Land Cover Analysis for Agricultural Area in Thailand using CNN Method

C. Arnal¹ S. Bassanetti¹ H. Corbin¹ Vissanu Mungkung² and Laurent Mezeix^{3*}

Received 28 September 2022, Revised 9 January 2023, Accepted 24 January 2023

Abstract

To support agricultural development, increased understanding and data is needed. Performing a land cover enables obtain physical landscapes. The aim of this paper is to propose a land cover for agricultural area in Thailand using CNN method. A four-class dataset is created: forest, palm, rice, and buildings. It is composed of about 1,500,000 with a size of 64x64 pixels. Each class is associated with an optimized CNN model showing an accuracy between 80 and 90%. After post-processing of each prediction, the land cover is successfully obtained by aggregating the different class predictions. An RGB filter is used to determine the maturation state of the rice and to differentiate the type of palm field. Finally, the estimation of the production of palm and rice can be performed.

Keywords : Convolutional neural network, Image processing, Land cover, Satellite image

¹ Université de Toulouse, INSA, UPS, Mines d'Albi, ISAE, ICA (Institut Clément Ader)

² Defence Technology Analysis Department, Defence Technology Institute

³ Faculty of Engineering, Burapha University

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

1. บทนำ

องค์การสหประชาชาติคาดการณ์ว่าในปี ค.ศ. 2030 จะมีประชากรโลกอยู่ที่ 8.5 พันล้านคน และเพิ่มเป็น 9.7 พันล้านคน ภายในปี ค.ศ. 2050 ซึ่งโลกต้องประสบกับปัญหาความมั่นคงด้านอาหาร [1] จึงจำเป็นต้องเพิ่มอัตราการผลิตอาหารเพื่อรองรับการเติบโตด้วยเหตุนี้การตรวจสอบพื้นที่เพื่อเกษตรกรรมและการจัดการด้านการผลิตอาหารจึงมีบทบาทสำคัญอย่างยิ่ง [2] โดยเฉพาะการเพิ่มอัตราการผลิตอาหารให้มากขึ้นโดยลดการใช้ทรัพยากรที่มีอยู่อย่างจำกัด จึงนับเป็นความท้าทายสำหรับภาคการเกษตรในอนาคตเพื่อแก้ไขปัญหาหนี้ จึงเกิดเป็นแนวคิดการเกษตรแบบแม่นยำโดยมีจุดมุ่งหมายเพื่อเพิ่มประสิทธิภาพภาคการผลิตในอุตสาหกรรมเกษตรจากการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์และเทคโนโลยีการรับรู้จากระยะไกล [3]

การเฝ้าตรวจและตรวจจับข้อมูลเชิงภูมิศาสตร์ของพื้นที่ที่สามารถทำได้ด้วยเทคโนโลยีการรับรู้จากระยะไกล ซึ่งอยู่ในรูปแบบของดาวเทียมหรืออากาศยาน [4], [5] ความก้าวหน้าทางด้านเทคโนโลยีและการเข้าถึงข้อมูลทางภูมิศาสตร์สารสนเทศนำไปสู่การประยุกต์ใช้งานได้หลากหลายมิติ [6] สำหรับในประเทศไทยได้มีการนำไปใช้ในการศึกษาการพังทลายของหน้าดินในบริเวณพื้นที่ที่เข้าถึงได้ยากลำบาก [7] การสำรวจพื้นที่เพาะเลี้ยงสัตว์น้ำ [8] และการศึกษาทางอุทกวิทยา เป็นต้น ในการทำแผนที่สิ่งปกคลุมดินนั้นมีวิธีการที่หลากหลาย ซึ่งโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks) หรือ CNN เป็นวิธีที่มีประสิทธิภาพเหมาะสมต่อการวิเคราะห์บริเวณพื้นที่ปกคลุมที่ดิน โดยผลการประมวลมีความแม่นยำ (Accuracy) สูงกว่าอัลกอริทึมการจำแนกประเภทอื่นๆ เช่น Support Vector Machine (SVM), Random Forest (RF), การถดถอยโลจิสติก (Logistic regression analysis) และวิธีการอื่นที่คล้ายคลึงกัน [9]-[13]

Mahdi Panahi และคณะ [13] แสดงให้เห็นว่าแบบจำลอง CNN ให้ผลลัพธ์จากการประมวลที่มีความ

แม่นยำกว่า SVM ถึง 12% สำหรับการทำแผนที่บริเวณที่คาดว่าจะมีน้ำบาดาล อีกทั้งมีงานวิจัยที่ใช้ CNN ในการประเมินคุณภาพของแหล่งน้ำในแม่น้ำ Tietê ประเทศบราซิล [10] สำหรับในอุตสาหกรรมการเกษตรสามารถใช้ประโยชน์จาก CNN โดยใช้ตรวจการเจริญเติบโตของรวงข้าวและคาดการณ์ระยะการเจริญเติบโตได้ [14] นอกจากนี้ยังสามารถใช้ CNN เพื่อสนับสนุนการจัดการทรัพยากรที่ใช้ในการเกษตร เช่น แหล่งน้ำ และการควบคุมอัตราการเกิดมลพิษ [15]

ที่ผ่านมาได้มีการพัฒนาแผนที่สิ่งปกคลุมดินในประเทศไทยด้วย CNN [16]-[18] ในการประมวลผลชุดข้อมูลภาพ โดยใช้หนึ่งแบบจำลองต่อหนึ่งชุดข้อมูลภาพ หลังจากนั้นจึงคำนวณค่าจากความแตกต่างเพื่อให้ได้ค่าพื้นที่ครอบคลุม โดยได้มีการแบ่งพื้นที่ออกเป็น 4 คลาส (ป่าไม้ พืชผล อาคาร และถนน) ตามลักษณะพื้นที่ชนบทของประเทศไทย [19]

ในบทความวิจัยฉบับนี้มีวัตถุประสงค์เพื่อนำเสนอแบบจำลองสำหรับการจำแนกประเภทของพื้นที่ทางการเกษตรในประเทศไทยและเพื่อให้สามารถประมาณผลผลิตจากการเพาะปลูกพืชไร่ รวมถึงการศึกษาสภาพแวดล้อมโดยรอบของพื้นที่เพาะปลูกเพื่อเป็นข้อมูลแก่หน่วยงานภาครัฐที่เกี่ยวข้องได้นำไปใช้ประโยชน์ ในการดำเนินการดังกล่าวได้มีการสร้างชุดข้อมูลภาพ 4 คลาส ได้แก่ นาข้าว ต้นปาล์ม ป่าไม้ และสิ่งปลูกสร้าง โดยใช้แบบจำลอง CNN ประมวลผลชุดข้อมูลภาพในแต่ละชุดและทำการทวนสอบ พร้อมกับการวิเคราะห์หาข้อผิดพลาดและไร้น้ำฝน

2. กรณศึกษา

ประเทศไทยมีพื้นที่ประมาณ 513,000 ตารางกิโลเมตร จากข้อมูลปี พ.ศ. 2558 พื้นที่ดังกล่าวจำแนกเป็นพื้นที่เกษตรกรรมประมาณ 221,000 ตารางกิโลเมตร คิดเป็น 43% ของพื้นที่ทั้งหมด ซึ่งอุตสาหกรรมเกษตรมีอัตราการจ้างงานคิดเป็น 8.7% ของผลิตภัณฑ์มวลรวมภายในประเทศ (GDP) ประเทศไทยเป็นหนึ่งในผู้ผลิตข้าว ยางพารา และปาล์มน้ำมันรายใหญ่ที่สุดของโลก โดยที่ประเทศไทย

ส่งออกน้ำมันปาล์มคิดเป็น 4% ของการผลิตทั่วโลก [20] ด้วยแนวโน้มอุปสงค์ของพืชเศรษฐกิจที่เพิ่มสูงขึ้นอย่างต่อเนื่อง ส่งผลให้มีความสนใจในแบบจำลองที่สามารถประมาณการผลิตจากพืชไร่ต่อไป ซึ่งในบทความวิจัยฉบับนี้จะจำแนกชุดข้อมูลภาพออกเป็น 4 คลาส คือ

นาข้าว ต้นปาล์ม พื้นที่ป่าไม้ และสิ่งปลูกสร้าง เพื่อให้สอดคล้องกับสภาพทางภูมิศาสตร์ของประเทศไทย เพื่อใช้ในการประมวลผลด้วยแบบจำลอง CNN นอกจากนี้ยังสามารถจำแนกพื้นที่ป่าไม้และสิ่งปลูกสร้างพื้นที่ชนบท (รูปที่ 1)



รูปที่ ๑ พื้นที่เกษตรกรรมทั่วไปของประเทศไทยและชุดข้อมูลภาพ 4 ชุด ที่ใช้ในการทำแผนที่สิ่งปกคลุมดิน

ชุดข้อมูลภาพได้มาจากการนำภาพถ่ายดาวเทียมในย่านแสง RGB จาก Google Earth ที่รวบรวมในปี พ.ศ. 2565 โดยทำการคัดเลือกภาพถ่ายดาวเทียมที่ครอบคลุมบริเวณพื้นที่ในประเทศไทยที่มีความละเอียด 0.072 เมตรต่อจุดภาพ ชุดข้อมูลภาพมีขนาดไทม์รูปทรงสี่เหลี่ยมจัตุรัสขนาด 64x64 จุดภาพ เทียบเท่ากับพื้นที่ขนาด 21 ตารางเมตรต่อไทม์ จากผลการศึกษา [16]-[17], [19] พบว่าหากแบบจำลองจะมีความแม่นยำมากกว่า 90% ชุดข้อมูลภาพต้องประกอบด้วยไทม์โดยเฉลี่ยจำนวน 376,000 ไทม์ต่อชุดข้อมูลภาพ รวมเป็นประมาณทั้งสิ้น 1,500,000 ไทม์ (ตารางที่ 1)

ในประเภทของภาพทั้ง 4 คลาส จะประกอบด้วย ชุดข้อมูลภาพทั้ง 4 ชุด โดยใช้ไทม์เริ่มต้นเดียวกัน (ตารางที่ 2) ชุดข้อมูลแต่ละชุดสร้างขึ้นโดยแบ่งออกเป็น 2 ส่วน ส่วนแรก คือ ส่วนที่จะผ่านกระบวนการวิเคราะห์ และส่วนที่สองเรียกว่า “อื่น ๆ” ส่วนย่อยที่สองนี้เป็นการรวมกันของประเภทที่ไม่ได้รับการตรวจสอบ 3 ประเภท ตามที่ได้ตรวจสอบในการทบทวนวรรณกรรมจะมีการสุ่มเลือกในชุดข้อมูล โดย 70% ของไทม์ทั้งหมดเป็นชุดการฝึก ข้อมูล 15% เป็นชุดตรวจสอบความถูกต้อง และ 15% เป็นชุดทดสอบ [21]-[23]

ตารางที่ 1 คำอธิบายของคลาสและจำนวนของไทม์ 64x64 จุดภาพ

คลาส	คำอธิบาย	ภาพ
ข้าว	นาข้าว	329,974
ปาล์ม	สวนปาล์ม	416,592
ป่า	พื้นที่ป่าทึบและป่าโปร่ง	309,563
อาคาร	อาคารและถนน	448,635
จำนวนภาพทั้งสิ้น		1,504,764

ตารางที่ 2 คำอธิบายของชุดข้อมูลที่ใช้โดยโมเดล CNN ทั้ง 3 แบบ

คลาสต่อแบบจำลอง CNN	จำนวนไทม์ที่เกี่ยวข้องกับคลาสที่ทำการตรวจสอบ	จำนวนไทม์ “อื่นๆ”
CNN ข้าว	329,974	1,136,811
CNN ปาล์ม	416,592	941,676
CNN ป่า	309,563	310,000
CNN อาคาร	448,635	498,702

3. กรรมวิธีในการศึกษา


3.1 สิ่งปกคลุมดิน

วิธีการสร้างแผนที่สิ่งปกคลุมดิน (รูปที่ 2ก) โดยการรวมผลลัพธ์ของ CNN จากแต่ละประเภทตามอ้างอิงจากเอกสารตีพิมพ์ของ Fitton และคณะ [19] โดยได้ระบุว่าแบบจำลอง CNN ของแต่ละประเภท จะถูกนำไปใช้เพื่อทำนายประเภทเฉพาะ (รูปที่ 2ข) จากนั้นขั้นตอนหลังการประมวลผลจะดำเนินการในแต่ละครั้งที่จำแนกประเภทเพื่อลบจุดที่มีขนาดเล็กเกินไปหรือใหญ่เกินไปที่จะเป็นคุณลักษณะที่เป็นตัวแทน (รูปที่ 2ค) และท้ายที่สุดแผนที่สิ่งปกคลุมดินจะดำเนินการโดยรวมผลการทำนายประเภทต่าง ๆ เข้าด้วยกัน (รูปที่ 2ง) ในกรณีศึกษาที่ตรวจสอบด้วยความละเอียดที่ใช้้นั้น พารามิเตอร์จะถูกกำหนดโดยการทดลอง (ตารางที่ 3)

ก) ภาพถ่ายดาวเทียม



ข) การทำนายคลาส



ค) หลังประมวลผล



ง) แผนที่สิ่งปกคลุมดิน



รูปที่ ๒ กรรมวิธีในการได้มาซึ่งแผนที่สิ่งปกคลุมดินจากภาพถ่ายดาวเทียม


ตารางที่ 3 พารามิเตอร์หลังการประมวลผลในฟังก์ชันของคลาส

เกณฑ์ \ แบบจำลองคลาส	ข้าว	ปาล์ม	ป่า	อาคาร
ความถูกต้องในการทำนาย (%)	85	90	85	80
คลัสเตอร์คลาสหลักที่เป็นเกณฑ์ขนาดเล็ก (ม. ²)	0.51			
คลัสเตอร์คลาสจำแนกไม่ได้ที่เป็นเกณฑ์ขนาดเล็ก (ม. ²)	0.76			
เกณฑ์ความกว้าง (ม. ²)	0.12	0.25	0.76	0.76

3.2 การทำแบบจำลองทางกายภาพของพืช

3.2.1 กรรมวิธีการเจริญเติบโตของข้าว

ข้าวมีการพัฒนา 4 ระยะ (รูปที่ 3) ได้แก่ ระยะต้นกล้า ระยะแตกกอ ระยะสร้างรวง และระยะเก็บเกี่ยว เนื่องจากบทความวิจัยนี้มีวัตถุประสงค์เพื่อบ่งบอกถึงข้าวในแปลงนาเท่านั้น ขั้นตอนการพัฒนาจึงกำหนดการทดสอบใน 2 ระยะ คือ การปลูกและการเก็บเกี่ยว (รูปที่ 3) โดยคุณลักษณะเฉพาะของแต่ละระยะสามารถอ่านค่าได้จากสีของต้นข้าว ในระหว่างระยะเจริญเติบโตสีหลักจะเป็นสีเขียว ในขณะที่ระยะที่ 2 สีมินาโน้มที่จะเป็นสีน้ำตาลอ่อน [24]



รูปที่ ๓ วงจรชีวิตของข้าว [25]

ในการกำหนดสถานะการเติบโตของต้นข้าว นั้นอาศัยการสะท้อนของแสงในย่าน RGB โดยได้มีการเก็บภาพถ่ายดาวเทียมของนาข้าวในระยะปลูกและเก็บเกี่ยวเป็นจำนวนมาก สำหรับแต่ละรูปภาพจะมีการคำนวณค่าเฉลี่ยของชั้นสี RGB แต่ละชั้น (ตารางที่ 4) โดยที่ชั้นสีน้ำเงินแสดงถึงความแตกต่างที่ใหญ่ที่สุดระหว่างสถานะการสุกของต้นข้าวทั้งสองระยะมากที่สุด เกณฑ์สำหรับจำแนกสถานะการสุกจะคำนวณโดยมีค่าเท่ากับ 80 หากค่าที่ต่ำกว่าจะบ่งบอกถึงสถานะของต้นข้าวที่กำลังเติบโต ในขณะที่ค่าที่มากกว่าจะบ่งบอก

สถานการณ์เก็บเกี่ยว พืชข้าวทั่วไปให้ผลผลิตเฉลี่ย 2,300 กก./เฮกเตอร์ ในประเทศไทย ดังนั้น ผลผลิตเฉลี่ยสามารถหาได้จากสิ่งปกคลุมดินโดยใช้สมการที่(1)


$$\text{ผลผลิตเฉลี่ย (กก.)} = 2300 \left(\frac{\text{กก.}}{\text{เฮกเตอร์}} \right) x \text{ พื้นที่ (เฮกเตอร์)} \quad (1)$$

ตารางที่ 4 ความแตกต่างของค่าเฉลี่ยระหว่างฟิล์มที่เก็บเกี่ยวและสุกเมื่อใช้ RGB Filter

	ส่วนเก็บเกี่ยว	ส่วนกำลังโต	ค่าเบี่ยงเบน
แดง	104.31	43.30	61.01
เขียว	115.83	66.44	49.39
น้ำเงิน	139.5	34.13	105.37

3.2.2 กรรมวิธีการแบ่งสวนปาล์ม

ในการศึกษารั้วนี้กำหนดค่าจำกัดความของสวนปาล์ม 2 ประเภท ได้แก่ ต้นปาล์มอ่อนและต้นปาล์มที่โตเต็มที่แล้ว (รูปที่ 4) ประเภทแรกหมายถึง สวนปาล์มที่ปาล์มแต่ละต้นยังไม่โตเต็มที่ จึงสามารถจำแนกต้นปาล์มแต่ละต้นได้ง่าย ในขณะที่ต้นปาล์มประเภทที่ 2 มีลักษณะเป็นพุ่มทึบส่งผลให้การจำแนกมีความซับซ้อนมากกว่า ดังนั้นเพื่อให้สามารถประมาณการผลผลิตเฉลี่ยได้จึงต้องระบุสวนปาล์ม 2 ประเภทนี้ได้ จึงประยุกต์ใช้ Filter เดียวกับที่ใช้ในการวิเคราะห์แปลงนาข้าว โดยใช้เกณฑ์สำหรับจำแนกจากย่านแสงสีน้ำเงิน โดยหากค่าต่ำกว่า 80 บ่งบอกถึงสวนปาล์มที่มีความหนาแน่นสูง



รูปที่ ๔ สวนปาล์มอ่อนและสวนปาล์มหนาแน่น

ในพื้นที่ที่แบ่งคลาสเป็นปาล์ม (รูปที่ 5ก) RGB Filter แบบเดียวกับที่ใช้สำหรับข้าวจะถูกนำไปใช้เพื่อแยกต้นปาล์มออกจากพื้นดิน (รูปที่ 5ข) จากนั้นจึงระบุต้นปาล์มแต่ละต้นและกำหนดขนาดโดยใช้ฟังก์ชัน K-mean (รูปที่ 5ค) ผลผลิตเฉลี่ย

ต่อปาล์มสามารถแบ่งออกเป็น 4 ประเภท ที่เกี่ยวข้องกับอายุ [26] สามารถหาพื้นที่ทรงพุ่มของต้นปาล์มแต่ละต้นได้จากการปกคลุมดินและสามารถตรวจสอบอายุได้โดยใช้สมการที่ 2 [10]

$$\text{อายุ} = 0.59 + 0.15 x \text{ พื้นที่} \quad (2)$$


สำหรับต้นปาล์มที่จำแนกแล้วมีขนาดใหญ่กว่าขนาดเรือนยอดสูงสุด [27] ให้คำนวณขนาดต้นปาล์มเฉลี่ยและใช้อายุของต้น โดยที่ผลผลิตทั้งหมด (รูปที่ 5ง) ของสวนปาล์มสามารถคำนวณได้โดยใช้สมการที่ 3

$$\text{ผลผลิตรวม} = \sum_{i=1}^4 (\text{ผล}_i x \text{ จำนวนของพืช}_i) \quad (3)$$

ในการศึกษานี้ ‘ผลผลิตรวม’ หมายถึง ผลผลิตเฉลี่ยของต้นปาล์มแต่ละต้นตามอายุ (ตารางที่ 5) และ “จำนวนของพืช” คือจำนวนต้นปาล์มทั้งหมดต่ออายุ

ตารางที่ 5 ผลผลิตปาล์มแต่ละคลาสและตามอายุ [26]

ลำดับ	คลาส	อายุการยืนต้น	ผลผลิตเฉลี่ย (กก./6 เดือน)
1	เมล็ดพันธุ์	0-3	0
2	ต้นอ่อน	4-8	68.77
3	รุ่น	9-14	109.08
4	แก่	15-25	73.91




รูปที่ ๕ การแบ่งสวนสวนปาล์มไม่หนาแน่น

สำหรับพื้นที่ที่มีเรือนยอดหนาแน่นเกินกว่าจะแยกปาล์มแต่ละต้น จะทำการคำนวณผลผลิตเฉลี่ย (รูปที่ 6) ภายใต้ข้อสมมติฐานว่าต้นปาล์มที่โตเต็มที่จะมีพุ่มทึบโดยได้มีการพิจารณารูปแบบเฉพาะ แต่ละแถวของต้นปาล์มเป็นแถวที่มีระยะห่างกัน 7.8 เมตร โดยระยะระหว่างต้นปาล์มแต่ละต้นอยู่ที่ 9 เมตร [27] ดังนั้นจึงได้ผลการคำนวณจำนวนต้นปาล์มเฉลี่ย 143 ต้นต่อเฮกตาร์โดยให้ผลผลิต 73.91 กิโลกรัมต่อ 6 เดือนสุดท้ายนี้

สามารถคำนวณผลผลิตเฉลี่ยของสวนปาล์มที่จัดประเภทโดย CNN ได้โดยใช้ขนาดของพื้นที่ที่ดังสมการที่ 4

$$\text{ผลผลิตเฉลี่ย (กก.)} = 73.91 \left(\frac{\text{กก.}}{\text{เฮกเตอร์}} \right) \cdot x \text{ พื้นที่ (เฮกเตอร์)} \quad (4)$$




รูปที่ ๖ รูปแบบสวนปาล์มหนาแน่น [27]

4. การสร้างและการทดสอบแบบจำลอง CNN

4.1 การสร้างแบบจำลอง

จากการเปรียบเทียบเอกสารทางวิชาการพบว่า CNN มีประสิทธิภาพสูงสุดเมื่อเทียบกับแบบจำลองวิธีอื่น [9]-[10], [12]-[13] สำหรับการศึกษาในบทความวิจัยนี้ มีการสร้างแบบจำลอง CNN จำนวน 4 แบบ กล่าวคือ หนึ่งแบบต่อคลาส (รูปที่ 7) สถาปัตยกรรมของคลาสเหล่านั้นประกอบด้วย 6 ชั้น แบ่งออกเป็น Convolutional Layer 4 ชั้น ธรรมดา และ Dense Layer 2 ชั้น ตามด้วย Dropout Layer เพื่อลดโอกาสที่จะเกิด *Overfitting* โดยที่ค่า Pooling Rate กำหนดไว้ที่ 0.4 และ Learning Rate ที่ 0.0001 เพื่อปรับปรุงความแม่นยำและตรวจสอบค่า Loss โดยใช้ขนาดภาพที่ 64x64 จุดภาพ (รูปที่ 1) และใช้ขนาด Kernel 3x3 สำหรับแต่ละแบบมีการทดสอบการกำหนดค่าหลายอย่างและการกำหนดค่าที่ดีที่สุดยังคงอยู่ที่ส่วนท้าย ซึ่งหมายความว่า 64 โหนดต่อ Filter และขนาด Batch ที่ 128 สำหรับคลาสข้าวและปาล์ม (ตารางที่ 6) สำหรับคลาสอาคารและป่า จำเป็นต้องมีโหนดจำนวนมากขึ้นและมีขนาด Batch ที่มากขึ้น คือ 128 และ 256 ตามลำดับ และกำหนดให้มี Callback ที่ 30 รอบการคำนวณ (Epoch) เพื่อหลีกเลี่ยงการเกิด *Overfitting*



รูปที่ ๗ แผนผังลำดับงานของสถาปัตยกรรม Convolutional Neural Network

ตารางที่ 6 คำอธิบายชั้นและขนาดชุดสำหรับแบบจำลอง CNN แต่ละแบบ

Layers\CNN mode	CNN ข้าว	CNN ปาล์ม	CNN ป่า	CNN อาคาร
Conv_1 to Conv_4	64	64	128	128
Den_1 and Den_2	64	64	128	128
ขนาดของชุด	128	128	256	256

4.2 การตรวจสอบ CNN

ในการตรวจสอบ CNN อัตรา Precision และ Recall [28] ถูกนำมาใช้ในการคำนวณความถูกต้อง โดยคำนวณได้จากสมการที่ 5

$$\text{ความถูกต้อง} = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$


โดยมี TP, FP, TN, FN เป็น true positive, false positive, false negative และ true negative ตามลำดับ ผลจากการคำนวณพบว่าคลาสปาล์มและคลาสอาคารได้ค่าความถูกต้องสูงกว่า 0.96 ขณะที่อีก 2 คลาส ได้ค่าที่ต่ำกว่าที่ 0.95 อันมีปัจจัยมาจากจำนวนภาพชุดข้อมูลที่ต่ำกว่า

ตารางที่ 7 คำอธิบายความถูกต้องและค่าความสูญเสียสำหรับแบบจำลอง CNN แต่ละแบบ

ผล CNN \ แบบจำลอง CNN	CNN ข้าว	CNN ปาล์ม	CNN ป่า	CNN อาคาร
ความถูกต้อง	0.9572	0.9676	0.9484	0.9848
ความสูญเสีย	0.15	0.0940	0.1499	0.0837
ความถูกต้องจากการตรวจสอบ	0.96	0.9778	0.9618	0.9866
ความสูญเสียจากการตรวจสอบ	0.13	0.0695	0.1181	0.0708

5. ผลการศึกษา


บทความวิจัยฉบับนี้ได้ทำการวิเคราะห์สิ่งปกคลุมดินดำเนินการโดยใช้ CNN (รูปที่ 1) จากภาพถ่ายดาวเทียมเหนือพื้นที่เกษตรกรรมในประเทศไทย ขนาดเนื้อที่ 14,500 ตร.ม. (รูปที่ 8)



รูปที่ ๘ ภาพถ่ายดาวเทียมพื้นที่ชนบทของประเทศไทย

5.1 การคาดการณ์ของแบบจำลองแต่ละแบบ


แบบจำลอง CNN ได้ถูกนำมาใช้กับภาพถ่ายดาวเทียม (รูปที่ 5ก) เพื่อชี้บ่งวัตถุแต่ละประเภทโดยมีการชี้บ่งต้นปาล์ม (รูปที่ 5ข) อาคาร (รูปที่ 5ค) แปลงข้าว (รูปที่ 5ง) และพื้นที่ป่า (รูปที่ 5จ) โดยที่การชี้บ่งแปลงข้าวให้ผลลัพธ์ที่มีความถูกต้องสูงกว่าวัตถุอีก 3 ประเภท นำเสนอตัวเลขผลบวกเท็จที่แม่นยำยิ่งขึ้น แบบจำลอง CNN สำหรับวัตถุประเภทอาคารและข้าว พบว่ามีการรวมพื้นที่ผิวหน้าดินของไร่ปาล์มเข้าไปเป็นส่วนหนึ่ง นอกจากนี้ แบบจำลอง CNN ของวัตถุประเภทต้นปาล์มและป่าให้ผลลัพธ์ที่คล้ายคลึงกัน อันเป็นผลมาจากลักษณะของโครงสร้างลำต้นและใบที่หากวิเคราะห์จากภาพถ่ายดาวเทียมที่มีความละเอียดที่ได้รับส่งผลให้การวิเคราะห์ภาพได้ค่าที่ใกล้เคียงกัน ดังนั้น จึงจำเป็นต้องใช้กระบวนการ Treatment เพื่อเพิ่มความถูกต้อง (รูปที่ 2)



รูปที่ ๙ (ก) ภาพถ่ายดาวเทียมนำมาตรวจสอบการคาดการณ์ของแบบจำลอง CNN กับ (ข) ปาล์ม (ค) อาคาร (ง) ข้าวและ (จ) ป่าไม้ (สีแดงประเภทตามต้องการ)

5.2 กระบวนการ Post-process และการสร้างภาพสิ่งปกคลุมดิน

กระบวนการ Post-process ได้ถูกนำมาใช้ภายหลังจากที่ภาพถ่ายของแต่ละประเภทผ่านการประมวลผล (รูปที่ 2) ดังแสดงในรูปที่ 10 เป็นผลของกระบวนการ Post-process ของภาพแปลงนาข้าวโดยจุดที่ไม่สามารถระบุหรือบ่งชี้ได้จะถูกจำแนกรวมให้เป็นแปลงนาข้าว โดยการรวมผลลัพธ์ต่าง ๆ นี้ เข้าด้วยกัน (รูปที่ 11)




รูปที่ ๑๐ หลังการประเมินผลกับคลาสข้าว




รูปที่ ๑๑ แผนที่สิ่งปกคลุมดิน (สีแดงคลาสตามต้องการ)

5.3 ผลผลิตปาล์ม

สำหรับการคำนวณผลผลิตจากต้นปาล์ม ดังแสดงในรูปที่ 12 เป็นการจำแนกวัตถุโดยใช้ RGB Filter โดยใช้สมการที่ 3 ซึ่งแปลงต้นปาล์มอายุน้อย จะประกอบด้วยต้นปาล์มอายุระหว่าง 4 ถึง 8 ปี (รูปที่ 13) และสามารถคำนวณผลผลิตน้ำมันปาล์ม (รูปที่ 13) และสามารถคำนวณผลผลิตเฉลี่ย 11,073 กิโลกรัม โดยใช้ระยะเวลา 6 เดือน สำหรับพื้นที่ ปาล์มหนาแน่น สามารถประมาณผลผลิตเฉลี่ย 11,073 กิโลกรัมต่อ 6 เดือน โดยคำนวณได้จากสมการที่ 4




รูปที่ ๑๒ การแบ่งส่วนของต้นปาล์มอ่อนและสวนปาล์ม หนาแน่น



รูปที่ ๑๓ จำนวนต้นปาล์มต่ออายุ

5.4 การเจริญเติบโตและผลผลิตของนาข้าว

จากกระบวนการสร้างแผนที่สิ่งปกคลุมดิน ช่วยให้แปลงนาข้าว (รูปที่ 14ก) สามารถถูกบ่งชี้ และสามารถคำนวณผลผลิตเฉลี่ย รวมถึงสถานะของการสุกของข้าวได้ ดังที่ปรากฏในรูปที่ 14ก แสดงแปลงนาข้าวในระยะการเติบโต 3 ระยะ (1-3) และสวนปาล์มหนึ่งแปลง ระยะของนาข้าว (รูปที่ 3) สามารถระบุได้โดยใช้ชั้นสีน้ำเงินของ RGB (ตารางที่ 4) แสดงในรูปที่ 14ข และยังสามารถระบุระยะการเจริญเติบโต (รูปที่ 14ค) รวมถึงการประมาณผลผลิตตามตารางที่ 8



รูปที่ ๑๔ (ก) ภาพถ่ายดาวเทียมของนาข้าว (ข) ชั้นสีน้ำเงินของภาพ RGB และ (ค) แผนที่สิ่งปกคลุมดินและการจำแนกประเภทที่กำหนดโดย CNN

ตารางที่ 8 สถานะของนาข้าวและผลผลิตข้าวโดยประมาณ

จำนวนคลัสเตอร์	สถานะของนาข้าว	ขนาด (ม. ^๒)	ผลผลิต (กก./ม. ^๒)
1	เก็บเกี่ยว	1851	426
2	เจริญเติบโต	2350	541
3	เจริญเติบโต	2423	557

6. การอภิปรายผลและภาพรวมการดำเนินการ

6.1 ชุดข้อมูล

บทความวิจัยนี้ใช้ไฟล์ขนาด 64x64 จุดภาพ ที่ความละเอียด 0.07 ม./จุดภาพ ที่เล็กเกินกว่าที่จะระบุประเภทของวัตถุได้อย่างแม่นยำ (รูปที่ 1)

การปรับเพิ่มขนาดในสัดส่วนที่เหมาะสมจะช่วยปรับปรุงการจำแนกได้อย่างแม่นยำยิ่งขึ้น โดยยังคงการใช้พารามิเตอร์เดิมในการปรับแก้ผลลัพธ์ บทความวิจัยฉบับนี้รวบรวมภาพถ่ายดาวเทียมของพื้นที่จากทุกภาคของประเทศไทย เพื่อนำมาสร้างชุดข้อมูล 4 ชุด ตามประเภทของวัตถุที่ทำการวิเคราะห์อย่างไรก็ตาม คุณภาพในเชิงของความละเอียดของภาพมีความแตกต่างกันไปตามแต่ละภูมิภาค พื้นที่กรุงเทพ ปริมณฑล และชลบุรีมีภาพถ่ายที่มีความละเอียดเหมาะสม ขณะที่ภาคเหนือและภาคตะวันออกเฉียงเหนือจะมีความละเอียดต่ำกว่า ส่งผลให้ชุดข้อมูลมีความหลากหลายทางความละเอียดที่แตกต่างกัน ทำให้ความถูกต้องและความแม่นยำในการประมวลผลด้วยแบบจำลอง CNN ได้รับผลกระทบซึ่งสามารถลดข้อจำกัดได้ด้วยการเพิ่มขนาดชุดข้อมูลที่ต้องใช้ระบบประมวลผลที่สูงขึ้นด้วย

6.2 การจำแนกวัตถุด้วยกระบวนการ Segmentation

ในกรณีสวนปาล์ม ผู้วิจัยได้ใช้การจำแนกแบบ RGB Filter เพื่อทำการจำแนกต้นปาล์มออกเป็น 2 กลุ่ม ได้แก่ ต้นปาล์มอ่อนและต้นปาล์มที่เติบโตหนาแน่นเต็มพื้นที่ (รูปที่ 4) จากนั้นทำการคำนวณผลผลิตของต้นปาล์มแต่ละกลุ่ม อย่างไรก็ตาม ในกรณีวิธีคำนวณนี้เมื่อใช้กับบริเวณที่มีความหนาแน่นมีความผันแปรจะให้ผลลัพธ์ที่มีความแม่นยำต่ำ เพื่อทำการปรับปรุงการประมาณการผลิตปาล์ม สามารถสร้างคลาสปาล์มขึ้นมา 2 คลาส โดยสร้างชุดข้อมูลที่แตกต่างกัน 2 ชุด อย่างไรก็ตาม การได้มาซึ่งชุดข้อมูลขนาดใหญ่ 2 ชุดของสวนปาล์มที่อายุน้อยและที่เติบโตต้องใช้ทรัพยากรและเวลามาก อีกทั้งการใช้แบบจำลอง CNN เพียงแบบเดียวส่งผลกระทบต่อความถูกต้องในการจำแนกประเภทสวนปาล์มและพืชพรรณอื่น ๆ เนื่องจากข้อจำกัดในการจำแนกของแบบจำลอง [29] เพื่อลดข้อจำกัดดังกล่าว จึงได้มีการใช้แบบจำลอง Two-Stage CNN [30] โดยแบบจำลอง CNN แรกถูกใช้จำแนกประเภทพื้นที่ที่ครอบคลุมด้วยไทม์ขนาด 65×65 จุดภาพ และแบบจำลอง CNN ที่สองสำหรับการจำแนกประเภทวัตถุโดยใช้ไทม์ขนาด 17×17 จุดภาพ ผลลัพธ์แสดง

ค่าคะแนน F1 ที่ 95% ซึ่งในการจำแนกจะใช้วิธีการใช้ค่าดัชนี Normalized Difference Vegetation Index (NDVI) ที่อิงตามลักษณะสีของภาพจากการสำรวจจากระยะไกล เทคนิคนี้ใช้องค์ประกอบสีเขียวและย่านอินฟราเรดของภาพ ที่สามารถระบุถึงพืชพรรณ รวมถึงการวัดการเปลี่ยนแปลงของพืชพรรณตามฤดูกาลหรือในห้วงหลายปี [31] วิธีนี้ใช้ได้ผลกับการตรวจจับสภาพการเจริญเติบโตของทุ่งนา [32] และการระบุนาข้าวขนาดใหญ่ได้ดำเนินการโดยใช้ NDVI ได้แล้ว [33]

7. สรุป

การเกษตรแบบแม่นยำเป็นเครื่องมือที่มีประโยชน์ในการปรับปรุงกระบวนการจัดการผลผลิต ในงานนี้ได้เสนอโครงข่าย Convolutional Neural Network (CNN) เพื่อสร้างพื้นที่ครอบคลุมสำหรับพื้นที่เกษตรกรรมในประเทศไทย มีการสร้างสิ่งปกคลุมดินครอบคลุม 4 คลาสขึ้น ประกอบด้วย อาคาร ป่า ต้นปาล์ม และแปลงนาข้าว ชุดข้อมูลประกอบด้วยรูปภาพทั้งหมด 1,640,902 ภาพ ขนาด 64×64 จุดภาพ และความละเอียด 0.072 ม./จุดภาพ แบบจำลอง CNN ทั้งหมดได้รับการปรับค่าพารามิเตอร์ให้เหมาะสมเพื่อให้ได้ความถูกต้องที่สูงกว่า 95% ในที่สุด ภายหลังการประมวลผลถูกนำไปใช้กับการคาดการณ์ทั้ง 4 แบบ และผลลัพธ์จะถูกรวมเข้าด้วยกันเพื่อให้ได้พื้นที่ครอบคลุม จากนั้นจึงสามารถประมาณการผลิตข้าวและปาล์มได้ด้วยวิธีการที่เสนอโดยใช้ RGB Filter โดยที่ในส่วนของการสวนต้นปาล์มถูกแบ่งออกเป็น 2 ประเภท คือ ปาล์มอ่อนและปาล์มที่เติบโตหนาแน่น ในกรณีแรก RGB Filter ใช้เพื่อจำแนกต้นปาล์มที่อยู่เหนือพื้นดิน จากนั้นจะกำหนดขนาดของต้นปาล์มแต่ละต้นและคำนวณผลผลิตสำหรับสวนปาล์มที่มีการเติบโตแน่นสูง จะประมาณการผลิตเฉลี่ยโดยพิจารณาจากพื้นที่ทั้งหมดของสวน และจำนวนต้นปาล์มต่อเฮกตาร์โดยใช้รูปแบบที่ได้กำหนดไว้แล้ว ในด้านของการวิเคราะห์แปลงนาข้าวสามารถทำได้โดยใช้ RGB Filter เดียวกัน ซึ่งช่วยให้สามารถคำนวณปริมาณผลผลิตข้าวเฉลี่ยต่อเฮกตาร์

บทความวิจัยฉบับนี้ยังได้รวบรวมข้อจำกัดของแบบจำลองและระเบียบวิธีวิจัยที่ใช้ โดยประการแรกเนื่องจากความแปรผันของความละเอียดและรูปแบบไฟล์ส่งผลต่อความถูกต้อง ดังนั้น จึงควรปรับปรุงชุดข้อมูล โดยเฉพาะอย่างยิ่งสำหรับคลาสมัลม โดยแยกปาล์มที่อายุน้อยและเติบโตหนาแน่นออกจากกัน เพื่อปรับปรุงการคำนวณผลผลิต นอกจากนี้ RGB Filter ที่ใช้กับแปลงนาข้าวยังไม่สามารถบ่งบอกระยะเจริญเติบโตได้ ซึ่งควรใช้ค่าดัชนี NDVI ในการปรับปรุงความถูกต้องของการวิเคราะห์ต่อไปในอนาคต

8. เอกสารอ้างอิง

- [1] ONU Info. “La Population Mondiale Atteindra 8 Milliards d’habitants en Novembre (ONU).” NEWS.UN.org. <https://news.un.org/fr/story/2022/07/1123492> (accessed Jul. 11, 2022).
- [2] P. Griffiths, C. Nendel and P. Hostert, “Intra-annual Reflectance Composites from Sentinel-2 and Landsat for National-scale Crop and Land Cover Mapping,” *Remote Sens. Environ.*, vol. 220, pp.135 - 151, 2019.
- [3] V. Palazzi, S. Bonafoni, F. Alimenti, P. Mezzanotte, and L. Roselli., “Feeding the World With Microwaves: How Remote and Wireless Sensing Can Help Precision Agriculture,” *IEEE Microw. Mag.*, vol. 20, pp. 72-86, 2019.
- [4] D. Saah et al., “Land Cover Mapping in Data Scarce Environments: Challenges and Opportunities,” *Front. Environ. Sci.*, vol. 7, pp. 150-160, 2019.
- [5] L. Yu et al., “Meta-discoveries from a Synthesis of Satellite-based Land-cover Mapping Research,” *Int. J. Remote Sens.*, vol. 35, no. 13, pp. 4573–4588, 2014.
- [6] D. Saah et al., “Collect Earth: An Online Tool for Systematic Reference Data Collection in Land Cover and Use Applications,” *Environ. Model. Softw.*, vol. 118, pp. 166 - 171, 2019.
- [7] D.P. Shrestha, M. Suriyaprasit and S. Prachansri, “Assessing Soil Erosion in Inaccessible Mountainous Areas in the Tropics: The Use of Land Cover and Topographic Parameters in a Case Study in Thailand,” *Catena*, vol. 121, pp. 40 - 52, 2014.
- [8] M. Dorber, F. Verones, M. Nakaoka and K. Sudo, “Can We Locate Shrimp Aquaculture Areas from Space? - A Case Study for Thailand,” *Remote Sens. Appl.: Soc. Environ.*, vol. 20, p. 100416, 2020.
- [9] C. Yoo, D Han, J. Im and B. Bechtel, “Comparison between Convolutional Neural Networks and Random Forest for Local Climate Zone Classification in Mega Urban Areas Using Landsat Images,” *ISPRS J. Photogramm. Remote Sens.*, vol. 157, pp.155 - 170, 2019.
- [10] F. S. Y. Watanabe *et al.*, “Inland Water’s Trophic Status Classification Based on Machine Learning and Remote Sensing Data,” *Remote Sens. Appl.: Soc. Environ.*, vol. 19, p. 100326, 2020.
- [11] W. Li, C. Chen, M. Zhang, H. Li and Q. Du. “Data Augmentation for Hyperspectral Image Classification With Deep CNN,” in *IEEE Geoscience and Remote Sensing Letters*, vol. 16, no.4, pp.593 - 597, April 2019, doi: 10.1109/LGRS.2018.2878773.
- [12] L. Ma, Y. Liu, X. Zhang, Y. Ye, G. Yin and B. A. Johnson, “Deep Learning in Remote Sensing Applications: a Meta-analysis and Review,” *ISPRS J. Photogramm. Remote Sens.*, vol. 152, pp. 166 - 177, 2019.
- [13] M. Panahi, N. Sadhasivam, H. R. Pourghasemi, F. Rezaie and S. Lee, “Spatial Prediction of Groundwater Potential Mapping Based on Convolutional Neural Network (CNN) and Support Vector Regression (SVR),” *J. Hydrol.*, vol. 588, p. 125033, 2020.
- [14] Y. Zhang, D. Xiao, Y. Liu and H. Wu, “An Algorithm for Automatic Identification of Multiple Developmental Stages of Rice Spikes Based on Improved Faster R-CNN,” *Crop J.*, vol. 10, no. 5, pp. 1323 - 1333, 2022.
- [15] H. Chen *et al.*, “A Deep Learning CNN Architecture Applied in Smart Near-infrared Analysis of Water Pollution for Agricultural Irrigation Resources,” *Agric. Water Manag.*, vol. 240, p. 106303, 2020.

- [16] P. Chermprayong, N. Hongkarnjanakul, D. Rouquette, C. Schwob and L. Mezeix, "Convolutional Neural Network for Thailand's Eastern Economic Corridor (EEC) Land Cover Classification Using Overlapping Process on Satellite Images," *Remote Sens. Appl.: Soc. Environ.*, vol. 23, p. 100543, 2021.
- [17] P. Emparanza, N. Hongkarnjanakul, D. Rouquette, C. Schwob and L. Mezeix, "Land Cover Classification in Thailand's Eastern Economic Corridor (EEC) Using Convolutional Neural Network on Satellite Images," *Remote Sens. Appl.: Soc. Environ.*, vol. 20, p. 100394, 2020.
- [18] M. Mentet, N. Hongkarnjanakul, C. Schwob and L. Mezeix, "Method to Apply and Visualize Physical Models Associated to a Land Cover Performed by CNN: A Case Study of Vegetation and Water Cooling Effect in Bangkok Thailand," *Remote Sens. Appl.: Soc. Environ.*, vol. 28, 2022.
- [19] D. Fitton, E. Laurens, N. Hongkarnjanakul, C. Schwob and L. Mezeix, "Land Cover Classification through Convolutional Neural Network Model Assembly: A Case Study of a Local Rural Area in Thailand," *Remote Sens. Appl.: Soc. Environ.*, vol. 26, p. 100740, 2022.
- [20] H. Ritchie and M. Roser, "Palm Oil," *OURWORLDINDATA.org*. <https://ourworldindata.org/palm-oil>. (accessed Aug. 11, 2022).
- [21] M. Cihan, M. Ceylan, H. Soylu and M. Konak, "Fast Evaluation of Unhealthy and Healthy Neonates Using Hyperspectral Features on 700-850 Nm Wavelengths, ROI Extraction, and 3D-CNN," *IRBM*, vol. 43, no. 5, pp. 362 - 371, 2022.
- [22] F. Elmaz, R. Eyckerman, W. Casteels and S. Latré, P. Hellinckx, "CNN-LSTM Architecture for Predictive Indoor Temperature Modeling," *Build Environ*, vol. 206, p. 108327, 2021.
- [23] J. Xie, K. Hu, Y. Guo, Q. Zhu and J. Yu, "On Loss Functions and CNNs for Improved Bioacoustic Signal Classification," *Ecol. Inform.*, vol. 64, p. 101331, 2021.
- [24] J. Soriano-González, E. Angelats, M. Martínez-Eixarch and C. Alcaraz, "Monitoring Rice Crop and Yield Estimation with Sentinel-2 Data," *Field Crops Res.*, vol. 281, p. 108507, 2022.
- [25] FertiGlobal, "Paddy Rice," *FERTIGLOBAL.com*. <https://www.fertiglobal.com/cmp/paddyrice/> (accessed Aug. 10, 2022).
- [26] A. C. Fitrianto, K. Tokimatsu and M. S. Wijaya, "Estimation the Amount of Oil Palm Trees Production Using Remote Sensing Technique," in *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 98, no. 1, Dec. 2017, p. 012016.
- [27] R. Hernawati, K. Wikantika and S. Darmawan, "Modeling of Oil Palm Phenology Based on Remote Sensing Data: Opportunities and Challenges," *J. Appl. Rem. Sens.*, vol. 16, no. 2, p. 021501, 2022, doi: 10.1117/1.JRS.16.021501.
- [28] D. L. Olson and D. Delen, *Advanced Data Mining Techniques*. Heidelberg, Germany: Springer, 2008, pp. 151 - 167.
- [29] W. Li, H. Fu, L. Yu and A. Cracknell, "Deep Learning Based Oil Palm Tree Detection and Counting for High-Resolution Remote Sensing Images," *Remote Sens.*, vol. 9, no. 1, p. 22, 2017.
- [30] W. Li, R. Dong, H. Fu and L. Yu, "Large-Scale Oil Palm Tree Detection from High-Resolution Satellite Images Using Two-Stage Convolutional Neural Networks," *Remote Sens.*, vol. 11, no. 1, pp. 1 - 20, 2019.
- [31] M. M. Aburas, S. H. Abdullah, M. F. Ramli and Z. H. Ash'aari, "Measuring Land Cover Change in Seremban, Malaysia Using NDVI Index," *Procedia Environ. Sci.*, vol. 30, pp. 238 - 243, 2015.
- [32] J. Kong *et al.*, "Evaluation of Four Image Fusion NDVI Products Against In-situ Spectral -measurements over a Heterogeneous Rice Paddy Landscape," *Agric. For. Meteorol.*, vol. 297, p. 108255, 2021.
- [33] B. Li, C. Ti and X. Yan, "Estimating Rice Paddy Areas in China Using Multi-temporal Cloud-free Normalized Difference Vegetation Index (NDVI) Imagery Based on Change Detection," *Pedosphere*, vol. 30, no. 6, pp. 734 - 746, 2020.