



การประมาณความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงด้วย
ปัญญาประดิษฐ์จากข้อมูลภาพถ่ายท้องฟ้าและมุมเซนนิธของดวงอาทิตย์
Estimation of photosynthetically active radiation by Artificial intelligence
from Sky view and zenith angle

อรรถพล ศรีประดิษฐ์¹

¹คณะวิทยาศาสตร์และสังคมศาสตร์ มหาวิทยาลัยบูรพา วิทยาเขตสระแก้ว อำเภอวัฒนานคร จังหวัดสระแก้ว 27106

Auttapon Sripradit¹

¹Faculty of Science and Social science, Burapha University Sakaeo campus, Watthana Nakhon, Sakaeo, 27160, Thailand

E-mail: auttapon@buu.ac.th

Received: 8 March 2021 | Revised: 16 June 2021 | Accepted: 30 June 2021

บทคัดย่อ

ในงานวิจัยนี้จะประมาณความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงด้วยวิธีโครงข่ายประสาทเทียม (ANN) โดยใช้ข้อมูลปริมาณเมฆที่คำนวณจากภาพถ่ายสภาพท้องฟ้าด้วยวิธีการโครงข่ายประสาทแบบคอนโวลูชัน (CNN) และมุมเซนนิธของดวงอาทิตย์ ข้อมูลทั้งหมดได้จากข้อมูลการวัดใน 4 ภูมิภาคหลักของประเทศไทย ได้แก่ภาคเหนือที่ศูนย์อุตุนิยมวิทยาภาคเหนือ จังหวัดเชียงใหม่ ภาคตะวันออกเฉียงเหนือที่ศูนย์อุตุนิยมวิทยาภาคตะวันออกเฉียงเหนือจังหวัดอุบลราชธานี ภาคกลางที่ภาควิชาฟิสิกส์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร จังหวัดนครปฐม และภาคใต้ ที่ศูนย์อุตุนิยมวิทยาภาคใต้ฝั่งตะวันออก จังหวัดสงขลา จากนั้นนำข้อมูลดังกล่าวมาสร้างแบบจำลองด้วยวิธีโครงข่ายประสาทเทียม ในส่วนข้อมูลการทดสอบแบบจำลองจะใช้ข้อมูลภาคตะวันออกเฉียงเหนือที่มหาวิทยาลัยบูรพา วิทยาเขตสระแก้ว ดังนั้นข้อมูลการสร้างและทดสอบแบบจำลองจึงไม่มีความเกี่ยวข้องกันแต่ประการใด ในการสร้างแบบจำลองสำหรับคำนวณปริมาณเมฆจากวิธีโครงข่ายประสาทเทียมแบบคอนโวลูชัน พบว่าแบบจำลองให้ค่าความแม่นยำในการเรียนรู้ (learning rate) สูงถึงประมาณ 87% และเมื่อนำข้อมูลปริมาณเมฆที่ได้จากแบบจำลองและมุมเซนนิธของดวงอาทิตย์มาทดสอบแบบจำลองสำหรับประมาณความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงด้วยวิธีโครงข่ายประสาทเทียม พบว่าวิธีการคำนวณปริมาณเมฆโดยวิธีโครงข่ายประสาทเทียมแบบคอนโวลูชันให้ผลดีที่สุดมีค่าสัมประสิทธิ์สหสัมพันธ์ (R^2) เท่ากับ 0.80 ค่า RMSE เท่ากับ 19.3% และค่า MBE เท่ากับ 1.18%

ABSTRACT

In this study, the photosynthetically active radiation was estimated by using the artificial neural network (ANN) method based on the cloud index data which was calculated from sky view images by using convolutional neural network (CNN) method and zenith angle. All data in this study was collected from 4 main regions of Thailand including the northern region, Chiang Mai Meteorological Station, the north-eastern region, Ubon Ratchathani Meteorological Station, the central region, Department of Physics Faculty of Science Silpakorn University Nakhon

Pathom, and the southern region, Meteorological Station in the south, east coast, Songkhla Province. The data was then created a model by using the ANN method. For the model testing, the data from the eastern region, Burapha University, Sakaeo Campus, was used. Therefore, the data for model construction and testing were not actually related. In the model construction for calculating of the cloud index, it was found that the accuracy of the model in learning rate was approximately of 87%. The cloud index and zenith angle data were then tested for the model in estimation of photosynthetic active radiation by using ANN method. The results showed that the cloud index calculation method by using CNN was the best method with the R2 of 0.80, the root square mean error (RMSE) of 19.3 %, and the mean bias error (MBE) of 1.18 %.

คำสำคัญ: ความยาวคลื่นที่พืชใช้สังเคราะห์แสง โครงข่ายประสาทเทียม ภาพถ่ายท้องฟ้า

Keywords: Photosynthetically active radiation, Artificial neural network, Sky view

บทนำ

Photosynthetically Active Radiation หรือ PAR คือความเข้มรังสีดวงอาทิตย์ที่พืชสามารถนำพลังงานหรืออนุภาคโฟตอนเหล่านี้ไปใช้ในกระบวนการสังเคราะห์แสง ซึ่งอยู่ในช่วงความยาวคลื่นระหว่าง 400-700 นาโนเมตร โดยปริมาณของ PAR จะบอกในรูป Photosynthetic Photon Flux Density ในหน่วย $\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ โดย $1 \mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ จะหมายถึงจำนวนโฟตอนของแสงในช่วงความยาวคลื่นดังกล่าวจำนวน 6.022×10^{17} โฟตอนที่ตกกระทบพื้นที่ 1 ตารางเมตรใน 1 วินาที (McCree, 1966) PAR จึงเป็นข้อมูลพื้นฐานในการนำไปใช้ประโยชน์ทางเกษตรกรรม (Caya et al., 2018) และเป็นข้อมูลพื้นฐานที่สำคัญทางอุตุนิยมวิทยา (Tao et al., 2018) เพื่อใช้ศึกษาปรากฏการณ์ต่าง ๆ เช่นปรากฏการณ์ก๊าซเรือนกระจกในบรรยากาศโลก เนื่องจากการสังเคราะห์แสงของพืชจำเป็นจะต้องใช้ก๊าซคาร์บอนไดออกไซด์ซึ่งเป็นก๊าซเรือนกระจก (greenhouse gas) (Tkemaladze and Makhashvili, 2016) กล่าวได้ว่า PAR เป็นข้อมูลพื้นฐานที่สำคัญของการศึกษาสภาวะการเปลี่ยนแปลงระบบบรรยากาศของโลก (climate change) (Frouin and Murakami, 2007) ซึ่งเป็นกลไกสำคัญในการศึกษาสภาวะโลกร้อน (global warming) แต่ปริมาณ PAR จำเป็นต้องใช้เครื่องมือวัดปริมาณโฟตอนที่เรียกว่าโฟตอนเซนเซอร์ (photon sensor) และเก็บข้อมูลด้วยเครื่องบันทึกข้อมูล data logger ซึ่งเป็นเครื่องมือที่มีราคาสูง

ดังนั้นผู้วิจัยจึงพัฒนาแบบจำลองเพื่อคำนวณปริมาณ PAR ด้วยข้อมูลพื้นฐานที่สามารถเข้าถึงได้ง่ายโดยนำเอาปัญญาประดิษฐ์ซึ่งเป็นเทคโนโลยีที่เข้ามามีบทบาทในชีวิตประจำวัน (Sumaya et al., 2021) มาช่วยในการคำนวณ วิธีการประมวลผลของปัญญาประดิษฐ์เป็นการใช้วิธีการเลียนแบบโครงข่ายประสาทของมนุษย์ซึ่งมีการเรียนรู้และสามารถเพิ่มประสิทธิภาพการเรียนรู้จากข้อมูลที่เพิ่มมากขึ้นผ่านการเรียนรู้ด้วยตนเองและเชื่อมโยงข้อมูลที่ซับซ้อน (deep learning) ได้ ผู้วิจัยได้พัฒนาแบบจำลองสำหรับคำนวณปริมาณ PAR โดยใช้ปัญญาประดิษฐ์ที่เรียกว่าโครงข่ายประสาทเทียมแบบคอนโวลูชัน convolutional neural network (CNN) มาคำนวณปริมาณเมฆโดยใช้ภาพถ่ายท้องฟ้าเป็นข้อมูลอินพุต จากนั้นนำเอาข้อมูลปริมาณเมฆที่ได้และตำแหน่งของดวงอาทิตย์มาเป็นข้อมูลอินพุตของแบบจำลองสำหรับคำนวณ PAR ด้วยโครงข่ายประสาทเทียมแบบหลายชั้น (artificial neural network method, ANN)

วิธีดำเนินการวิจัย

งานวิจัยนี้ผู้วิจัยจะทำการพัฒนาแบบจำลองด้วยวิธีโครงข่ายประสาทเทียมสำหรับคำนวณหาค่า PAR โดยใช้ข้อมูลตำแหน่งดวงอาทิตย์และสภาพท้องฟ้าที่แบ่งระดับหรือดัชนีเมฆด้วยวิธีโครงข่ายประสาทเทียมแบบคอนโวลูชัน ข้อมูลที่ใช้ในการพัฒนาแบบจำลองได้จากสถานีวัดในภูมิภาคต่าง ๆ ของประเทศไทยจากนั้นจะทำการทดสอบสมรรถนะของแบบจำลอง ข้อมูลความเข้มรังสีดวงอาทิตย์จากสถานีวัดตามภูมิภาคต่าง ๆ 5 แห่งมีรายละเอียดดังรูปที่ 1 ประกอบด้วย ภาคเหนือ ที่ศูนย์อุตุนิยมวิทยาภาคเหนือ จังหวัดเชียงใหม่ (18.78° N, 98.98° E) ภาคตะวันออกเฉียงเหนือ ที่ศูนย์อุตุนิยมวิทยาภาคตะวันออกเฉียงเหนือ จังหวัดอุบลราชธานี

(15.25° N, 104.87° E) ภาคกลาง ที่คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร จังหวัดนครปฐม (13.82° N, 100.04° E) ภาคใต้ ที่ศูนย์อุตุนิยมวิทยาภาคใต้ฝั่งตะวันออก จังหวัดสงขลา (7.2° N, 100.6° E) และ ภาคตะวันออกที่มหาวิทยาลัยบูรพา วิทยาเขตสระแก้ว จังหวัดสระแก้ว (13.7° N, 102.3° E)



รูปที่ 1 สถานีติดตั้งเครื่องมือวัดทั้ง 5 แห่ง

ตำแหน่งที่ตั้งของสถานีวัดทั้ง 5 แห่งติดตั้งเครื่องมือที่ชื่อว่า Photon sensor สำหรับเก็บข้อมูล PAR และเครื่องมือบันทึกข้อมูลสภาพท้องฟ้าหรือ sky view สำหรับเก็บข้อมูลภาพถ่ายท้องฟ้าใน 4 สถานีแรก และใช้กล้อง CCD สำหรับเก็บข้อมูลภาพถ่ายท้องฟ้าสำหรับสถานีวัดมหาวิทยาลัยบูรพา วิทยาเขตสระแก้ว ตัวอย่างเครื่องมือดังกล่าวแสดงดังรูปที่ 2




รูปที่ 2 (ก) Photon sensor สถานีวัดที่มหาวิทยาลัยบูรพา วิทยาเขตสระแก้ว (ข) เครื่องบันทึกข้อมูลภาพถ่ายท้องฟ้า Sky view สถานีวัดที่มหาวิทยาลัยศิลปากร จังหวัดนครปฐม

1. มุมเซนนิธของดวงอาทิตย์ (Zenith Angle)

เมื่อรังสีดวงอาทิตย์เคลื่อนที่ผ่านชั้นบรรยากาศมายังพื้นผิวโลกจะถูกดูดกลืน (absorption) และกระเจิง (scattering) โดยองค์ประกอบต่าง ๆ ในชั้นบรรยากาศได้แก่ โมเลกุลของอากาศ ไอน้ำ และฝุ่นละออง (Iqbal, 1983) เป็นเหตุให้ปริมาณรังสีดวงอาทิตย์ที่ส่งผ่านยังพื้นโลกลดลง ทั้งนี้การลดลงจะมากหรือน้อยขึ้นกับชนิดและปริมาณของอนุภาคนั้น ๆ นอกจากองค์ประกอบของบรรยากาศแล้วยังขึ้นกับทางเดินของรังสีดวงอาทิตย์ (path length) อีกด้วย เนื่องจากทางเดินของรังสีดวงอาทิตย์ที่เพิ่มขึ้นจะเพิ่มการกระเจิงรังสีดวงอาทิตย์ ซึ่งมีผลต่อรังสีในช่วงความยาวคลื่นสั้นและจะเพิ่มการดูดกลืนรังสีดวงอาทิตย์ ซึ่งมีผลต่อรังสีในช่วงรังสีคลื่นยาว ดังนั้นทางเดินของรังสีดวงอาทิตย์จึงมีอิทธิพลที่สำคัญต่อความเข้ม PAR ทางเดินของรังสีดวงอาทิตย์สามารถคำนวณได้จากมุมเซนนิธของดวงอาทิตย์ วิธีวัดมุมเซนนิธจะวัดจากเส้นตั้งฉากจากบนพื้นราบไปยังตำแหน่งของดวงอาทิตย์ซึ่งสัมพันธ์กับมุมเงยของดวงอาทิตย์ที่เป็นมุม

ระหว่างเส้นตรงที่เชื่อมต่อดูดสังเกตไปยังดวงอาทิตย์กับระนาบขอบฟ้า (horizontal plane) ดังรูปที่ 3 ดังนั้นเราสามารถคำนวณมุมเซนนิธจากมุมเงยของดวงอาทิตย์ด้วยสมการดังต่อไปนี้



รูปที่ 3 แสดงมุมเงยของดวงอาทิตย์ (α_s)

$$\sin \alpha_s = \sin \delta \sin \phi + \cos \delta \cos \phi \cos \omega \quad (1)$$

เมื่อ α_s คือมุมเงยของดวงอาทิตย์ (องศา) ω คือมุมชั่วโมง (องศา) ϕ คือตำแหน่งละติจูด (องศา) และ δ คือเดคลิเนชัน (องศา) โดยมุมเดคลิเนชันและมุมชั่วโมงสามารถคำนวณได้จากสมการที่ (2) และ (3)

$$\delta = (0.006918 - 0.399912 \cos \Gamma + 0.070257 \sin \Gamma - 0.006758 \cos 2\Gamma + 0.000907 \sin 2\Gamma - 0.006758 \cos 2\Gamma + 0.000907 \sin 2\Gamma - 0.002697 \cos 3\Gamma + 0.00148 \sin 3\Gamma)(180/\pi) \quad (2)$$

โดยที่

$$\Gamma = 2\pi(d_n - 1)/365$$

เมื่อ Γ คือมุมวัน (day angle) (เรเดียน) δ คือมุมเดคลิเนชันของดวงอาทิตย์ (องศา) และ d_n คือวันในรอบปี, $d_n = 1$ สำหรับวันที่ 1 มกราคม

$$\omega = 15(12 - ST) \quad (3)$$

เมื่อ ω มุมชั่วโมง (องศา) และ ST คือเวลาดวงอาทิตย์ (ชั่วโมง : นาที)

โดยที่

$$ST = LST + 4(L_s - L_{loc}) + E_t$$


เมื่อ LST คือ เวลามาตรฐานท้องถิ่น (ชั่วโมง : นาที) L_s คือเส้นลองจิจูดมาตรฐาน (องศา) และ ST คือเส้นลองจิจูดมาตรฐาน (องศา)

ดังนั้นเราสามารถหามุมเซนนิธของดวงอาทิตย์ได้จาก

$$\theta_z = 90^\circ - \alpha_s \quad (4)$$

2. การบันทึกข้อมูล


โฟตอนเซนเซอร์เป็นอุปกรณ์ที่เก็บข้อมูลความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงในขณะใด ๆ และบันทึกข้อมูลเฉลี่ยทุก ๆ 10 นาทีในรูปแบบของความต่างศักย์ไฟฟ้าในอุปกรณ์บันทึกข้อมูล (datalogger) หลังจากนั้นจะแปลงสัญญาณไฟฟ้าดังกล่าวกลับมาอยู่ในรูปความเข้มรังสีดวงอาทิตย์ในรูปของฟลักซ์โฟตอนต่อพื้นที่ในหน่วย ($\mu\text{mol}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$) สำหรับข้อมูลภาพถ่ายท้องฟ้าจะเก็บข้อมูลโดยการถ่ายภาพสภาพท้องฟ้าทุก ๆ 10 นาที ข้อมูลที่ได้จะเป็นสภาพท้องฟ้าในรูปแบบต่าง ๆ ซึ่งเปลี่ยนแปลงไปตามเวลาและมีความสัมพันธ์กับปริมาณ PAR รูปที่ 4(ก) 4(ข) และ 4(ค) แสดงตัวอย่างสภาพท้องฟ้าแบบปราศจากเมฆ (Clear) แบบมีเมฆบางส่วน (Partly Cloudy) และ แบบมีเมฆเต็มท้องฟ้า (Overcast) ตามลำดับ จากข้อมูลทั้งหมดที่ได้จะนำข้อมูลดังกล่าวมาใช้ในการประมาณค่าของ PAR ด้วยโครงข่ายประสาทเทียมแบบหลายชั้น



รูปที่ 4 สภาพท้องฟ้า (ก) ปราศจากเมฆ (ข) มีเมฆบางส่วน (ค) มีเมฆเต็มท้องฟ้า

3. ดัชนีเมฆโดยใช้โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network, CNN)

โครงข่ายประสาทแบบคอนโวลูชันเป็นโครงข่ายประสาทเทียมในกลุ่มวิธีการค้นหาคำตอบที่เหมาะสมที่สุด (Optimizations) โดยได้รับแรงบันดาลใจจากสิ่งมีชีวิต (Bio-inspired) โดยที่ CNN จะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นส่วนที่ย่อย ๆ จากนั้นนำกลุ่มของพื้นที่ย่อย ๆ เหล่านั้นมาผสานกันเพื่อสกัดลักษณะเด่น (Feature extraction) ของภาพ และเรียกว่าเป็น “Local feature” ของภาพนั้น ๆ ค่า Local feature ของภาพที่ตรงจจับได้นั้นถือเป็นส่วนหนึ่งของโครงข่ายประสาทเทียม (Artificial neural networks, ANN) ที่จะถูกปรับไปพร้อม ๆ กับตัวที่ใช้ในการแบ่งแยกประเภท (Classifier) ดังนั้นเมื่อทำการสอนให้โครงข่ายทำการเรียนรู้ (Training) เสร็จสิ้นแล้วจะได้ลักษณะของโครงข่ายประสาทเทียมที่สามารถสกัดและจำแนกลักษณะเด่น (Feature extractor) ที่เหมาะสมกับงาน ซึ่งถือว่าเป็นจุดเด่นของ CNN ซึ่งจัดเป็นการเรียนรู้เชิงลึก (Deep learning) การเรียนรู้เชิงลึกนั้นมีการใช้โครงข่าย ANN ที่มีชั้นซ่อน (Hidden layers) แบบหลายชั้น เพื่อเพิ่มศักยภาพและความสามารถในการคิดที่มากกว่าปกติทำให้สามารถคำนวณโจทย์ปัญหาซับซ้อนได้ สามารถใช้ เทคนิคต่าง ๆ ได้มากขึ้นและที่สำคัญที่สุดคือ CNN สามารถทำการคิดอย่างเป็นขั้นเป็นตอนได้ซึ่งสามารถลอกเลียนแบบการทำงานของสมองมนุษย์ได้ดีขึ้น (Kim et al., 2016) ตัวอย่างสถาปัตยกรรมของโครงข่ายประสาทแบบ CNN แสดงในรูปที่ 5 (Mathworks, 2019) จากรูปที่ 5 แสดงสถาปัตยกรรมของโครงข่ายประสาทแบบคอนโวลูชันแสดงให้เห็น Neural networks (NN) ที่มีหลายเลเยอร์ (Layers) รูปแบบของโครงข่ายถูกสร้างเพิ่มความสามารถในการสกัดเอาลักษณะเด่น (Features) ที่มีความซับซ้อนมากยิ่งขึ้นจากข้อมูล



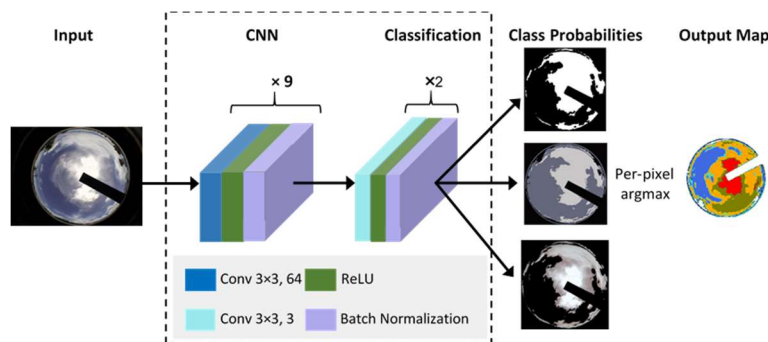
รูปที่ 5 สถาปัตยกรรมของโครงข่ายประสาทแบบคอนโวลูชัน (Mathworks, 2019)

ขั้นตอนการเรียนรู้ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ได้นำมาประยุกต์ใช้ในการระบุสภาพท้องฟ้าหรือดัชนีเมฆสามารถสรุปได้ดังนี้

1. ทำการจัดเตรียมฐานข้อมูลสำหรับการเรียนรู้ให้กับโครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งเป็น ข้อมูลภาพที่ไม่ผ่านการปรับแต่งใด ๆ (Natural images) ประมาณ 60,000 รูปจากข้อมูลภาพถ่ายท้องฟ้าของ 4 สถานีวัดได้แก่ เชียงใหม่ อุบลราชธานี นครปฐม และสงขลา
2. ทำการกำหนดจำนวนกลุ่มภาพย่อยขนาดเล็ก (Mini-batch) สำหรับการเรียนรู้ในแต่ละรอบของ โครงข่ายประสาทเทียม และกำหนดขนาดพิกเซลของภาพเพื่อใช้ในการดึงหรือสกัดลักษณะเด่นข้อมูลภาพสำหรับ ใช้ในการเรียนรู้ ซึ่งโดยทั่วไปจะใช้กลุ่มภาพย่อยขนาดเล็กเท่ากับ 64 กลุ่ม
3. กำหนดจำนวนชั้น (Layers) ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ผู้วิจัยได้กำหนดจำนวนชั้น ของโครงข่าย และใช้การคำนวณคอนโวลูชันแบบ 2 มิติ (2-D convolution layer) โดยแสดงรายละเอียดดังรูปที่ 6

4. ทำการกำหนดตัวเลือก (Options) ในการเรียนรู้ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน วิธีการหาค่าที่เหมาะสมที่สุด (Optimization) มีหลายวิธี ในงานนี้ผู้วิจัยเลือกใช้ Stochastic gradient descent with momentum (SGDM) ในตอนเริ่มต้นได้กำหนดอัตรา การเรียนรู้ (Learning rate) ให้มีค่าเริ่มต้นเท่ากับ 0.1 และลดลงเป็นจำนวนเท่าของ 10 ในทุก ๆ รอบของการคำนวณ (Epochs)


5. เมื่อทำการตั้งค่าการเรียนรู้ให้โครงข่ายประสาทเทียมแบบคอนโวลูชันตามเงื่อนไขที่ได้กล่าวถึงข้างต้น เรียบร้อยแล้วสามารถทำการรันโปรแกรมเพื่อให้โครงข่าย CNN ดังกล่าวทำการเรียนรู้โดยใช้ฐานข้อมูลภาพ จำนวน 60,000 ภาพ เมื่อได้ทำการเรียนรู้เสร็จแล้ว เราสามารถนำผลลัพธ์จากการเรียนรู้ ไปใช้งานโดยไม่ต้องทำการเรียนรู้ใหม่อีกนอกจากจะมีการเปลี่ยนแปลงฐานข้อมูลรูปภาพที่ใช้ในการเรียนรู้ ผลการเรียนรู้ของโครงข่าย CNN ที่รอบของการเรียนรู้ (Epoch) เท่ากับ 100 นอกจากนี้ผู้วิจัยยังนำเอาวิธี K-Means และMask R-CNN มาร่วมทดสอบเพื่อเปรียบเทียบประสิทธิภาพกับโครงข่าย CNN



รูปที่ 6 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน 11 ชั้นสำหรับการจำแนกสภาพท้องฟ้าประกอบด้วย 9 ชั้นของ 3×3 คอนโวลูชันกับ 64 กลุ่ม และ 2 ชั้นของ 1×1 คอนโวลูชันกับ 3 กลุ่ม และดำเนินการแบบไม่เชิงเส้นด้วย ReLU จากนั้นจัดกลุ่มเอาต์พุตด้วยความน่าจะเป็นต่อพิกเซลสำหรับแต่ละคลาสโดยมีรายละเอียดเดียวกันกับอินพุต

4. โครงข่ายประสาทเทียม

ผู้วิจัยจะใช้โครงข่ายประสาทเทียมแบบหลายชั้น (multi-layer perceptron) และใช้การเรียนรู้แบบแพร่กลับ (backpropagation algorithm) ในการสร้างแบบจำลองเพื่อคำนวณค่า PAR รายชั่วโมงด้วยข้อมูลดัชนีเมฆ (n) ที่ได้จากของโครงข่ายประสาทเทียมแบบคอนโวลูชัน และมุมเซนธิธของดวงอาทิตย์ (θ_z) เป็นอินพุตที่ให้ป้อนกับโครงข่ายประสาทเทียมที่ใช้สำหรับคำนวณค่า PAR รายชั่วโมงโดยจะใช้แบบ 2:3:2:1 แสดงดังรูปที่ 7



รูปที่ 7 โครงสร้างของโครงข่ายประสาทเทียมที่ใช้สำหรับคำนวณค่า PAR รายชั่วโมง

1. การเตรียมข้อมูลฝึกสอน (training pairs) และข้อมูลทดสอบ (testing data) ให้กับ โครงข่ายประสาทเทียม ผู้วิจัยใช้ข้อมูลของสถานีเชียงใหม่ อุบลราชธานี นครปฐมและสงขลาในระยะเวลา 1 ปี ช่วงเวลาตั้งแต่เดือน มกราคม - ธันวาคม 2010 เป็นข้อมูลฝึกสอน โดยข้อมูลที่เตรียมได้แก่ ดัชนีเมฆ (n) มุมเซนธิธของดวงอาทิตย์ (θ_z) และค่า PAR รายชั่วโมง หลังจากเตรียมข้อมูลเรียบร้อยแล้ว ขั้นตอนต่อไปคือการฝึกสอนโครงข่ายประสาทเทียม

2. การฝึกสอนโครงข่ายประสาทเทียม ผู้วิจัยจะทำการฝึกสอนโครงข่ายประสาทเทียมในทุกสภาพท้องฟ้าโดยใช้โปรแกรมภาษาไพทอนและการเรียนรู้แบบแพร่กลับ (backpropagation algorithm) ซึ่งมีขั้นตอนการฝึกสอนดังนี้

- 1) ป้อนชุดข้อมูลอินพุตและเอาต์พุต (training) ที่สอดคล้องกับอินพุตนั้น ๆ ให้กับ โครงข่ายประสาทเทียมทำการฝึกสอน
- 2) ทำการคำนวณเอาต์พุต และเปรียบเทียบกับค่าที่ได้กับเอาต์พุตที่ต้องการ
- 3) ปรับเปลี่ยนค่าน้ำหนัก โดยใช้ delta rule (Basheer and Hajmeer, 2000) เพื่อให้ค่าความคลาดเคลื่อน (error) มีค่าน้อยที่สุด ป้อนข้อมูลอินพุตและเอาต์พุตให้กับโครงข่ายประสาทเทียมและทำซ้ำชุดข้อมูลเดิม จนกระทั่งค่า error มีค่าที่สามารถยอมรับได้

ผลการวิจัยและวิจารณ์ผล


ความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงจะขึ้นกับเส้นทางเดินของดวงอาทิตย์ (Janjai et al., 2015) และสิ่งสำคัญอย่างหนึ่งก็คือปริมาณเมฆ ซึ่งส่งผลอย่างมากกับการลดทอนความเข้มรังสีดวงอาทิตย์ เมฆประกอบด้วยน้ำเป็นส่วนใหญ่โดยมีสถานะทั้งของแข็ง และของเหลว ซึ่งมีผลต่อการดูดกลืนและการกระเจิงแสง ที่ผ่านมารสร้างแบบจำลองเพื่อการประมาณความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงส่วนใหญ่ใช้ข้อมูลที่มีผลต่อการเปลี่ยนแปลงความเข้มรังสีดวงอาทิตย์ตั้งแต่แสงอาทิตย์เริ่มต้นส่องผ่านเข้ามาถึงชั้นบรรยากาศโลกได้แก่ โมเลกุลในบรรยากาศซึ่งประกอบด้วย ก๊าซต่าง ๆ ไอน้ำ โอโซน ฝุ่นละออง ซึ่งข้อมูลบางอย่างอาจเข้าถึงได้ยากเนื่องจากเป็นข้อมูลเฉพาะกลุ่มและมีการแปรผลที่ซับซ้อน ในงานวิจัยนี้จะใช้การสร้างแบบจำลองอย่างง่ายโดยใช้ข้อมูลพื้นฐานได้แก่ตำแหน่งของดวงอาทิตย์ที่แปรตามเวลาในรอบวันซึ่งคำนวณได้จากมุมเซนนิธของดวงอาทิตย์ และข้อมูลปริมาณเมฆที่คำนวณได้จากภาพถ่ายท้องฟ้า จากนั้นทำการเปรียบเทียบระหว่างข้อมูลความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงที่ได้จากแบบจำลองโครงข่ายประสาทเทียมเปรียบเทียบกับข้อมูลที่ได้จากการวัด ข้อมูลอินพุตได้แก่ มุมเซนนิธของดวงอาทิตย์ (θ_z) ที่คำนวณได้จากสมการที่ 4 และปริมาณเมฆ (cloud index) ที่ได้จากการคำนวณด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งการคำนวณจะเริ่มต้นด้วยการแบ่งส่วนภาพเป็นซึ่งขั้นตอนสำคัญในการประมวลผลภาพและสิ่งที่อยู่ในภาพ การแบ่งส่วนภาพจะทำหน้าที่เป็นการประมวลผลล่วงหน้าก่อนการจดจำรูปแบบการแยกคุณลักษณะและการบีบอัดภาพ การแบ่งส่วนภาพคือการจำแนกภาพออกเป็นกลุ่มต่าง ๆ มีการวิจัยหลายประเภทในด้านการแบ่งส่วนภาพโดยใช้การจัดกลุ่มซึ่งมีวิธีการที่แตกต่างกันหลายวิธี ในงานวิจัยนี้จะใช้วิธี โครงข่ายประสาทเทียมแบบ CNN Mask-RCNN3 และ K-Means ทั้ง 3 วิธี เป็นโครงข่ายประสาทเทียมที่มีวัตถุประสงค์เพื่อแก้ปัญหาการแบ่งส่วนอินสแตนซ์ในการเรียนรู้ของเครื่องหรือการมองเห็นด้วยคอมพิวเตอร์ กล่าวอีกนัยหนึ่งก็คือสามารถแยกวัตถุต่าง ๆ ในรูปภาพหรือวิดีโอได้ จากการนำเอาทั้ง 3 วิธีมาคำนวณหาปริมาณเมฆผลที่ได้ในความแม่นยำในการสร้างและทดสอบแบบจำลองแสดงดังตารางที่ 1

ตารางที่ 1 แสดงผลความแม่นยำในการสร้างและทดสอบแบบจำลอง

Method	Cloud index			ANN-Prediction			
	Accuracy of Validation (%)	accuracy of training (%)	Loss of validation (%)	Loss of training (%)	R ²	RMSE (%)	MBE (%)
Mask R-CNN	82	83	39	37	77	20.9	-0.42
K-Means	79	81	40	38	79	21.2	-0.38
CNN	85	87	36	35	80	19.3	1.18

จากตารางที่ 1 แสดงค่าการทดสอบต่าง ๆ ของแบบจำลองได้แก่ ความถูกต้องแม่นยำของการฝึกสอนแบบจำลอง (accuracy of training) ความถูกต้องการทดสอบแบบจำลอง (Accuracy of Validation) ค่าการสูญเสียความถูกต้องการทดสอบ (Loss of validation) ค่าความสูญเสียความแม่นยำของการฝึกสอนแบบจำลอง (Loss of training) ค่าเหล่านี้แสดงถึงความถูกต้องและแม่นยำในการสร้างและทดสอบแบบจำลองเพื่อหาค่าปริมาณเมฆ จากตารางแสดงให้เห็นว่าทั้ง 3 วิธี มีค่าใกล้เคียงกันโดยโครงข่ายประสาทเทียม

แบบ CNN จะให้ค่า Accuracy of Validation, accuracy of training, Loss of validation และ Loss of training ที่ดีที่สุดโดยมีค่า 85%, 87%, 36% และ 35% ตามลำดับ จากนั้นผู้วิจัยจะใช้ข้อมูลตั้งแต่เดือนมกราคม - ธันวาคม 2018 จากสถานีวัดมหาวิทยาลัยบูรพา วิทยาเขตสระแก้ว สำหรับการทดสอบแบบจำลองที่สร้างขึ้น จากนั้นเปรียบเทียบผลที่ได้จากแบบจำลองและผลที่ได้จากการวัดโดยผลดังกล่าวแสดงดังรูปที่ 8



รูปที่ 8 การเปรียบเทียบค่า PAR รายชั่วโมงที่ได้จากการวัดและจากการคำนวณด้วย ANN

จากรูปที่ 8 พบว่าค่า R^2 แสดงความสมรูประหว่างแบบจำลองกับข้อมูลการวัด ค่า RMSE และ ค่า MBE ค่าทั้งสองนี้จะแสดงถึงความคลื่อนระหว่างแบบจำลองกับข้อมูลการวัด ค่าที่น้อยจะทำให้ประสิทธิภาพแบบจำลองให้ผลที่ดีเครื่องหมายลบบ่งบอกถึงแบบจำลองที่ได้ให้การประมาณที่ต่ำกว่าค่าที่ได้จากการวัด แบบจำลอง ที่ดีที่สุดได้แก่ โครงข่ายประสาทเทียมแบบ CNN ซึ่งมีค่า R^2 เท่ากับ 0.80 % RMSD เท่ากับ 19.3 % และ MBD เท่ากับ 1.18%

สรุปผลการวิจัย

ในงานวิจัยได้กล่าวถึงการคำนวณความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงโดยใช้ข้อมูลมุมเซนนิธของดวงอาทิตย์และปริมาณเมฆโดยใช้ปัญญาประดิษฐ์ด้วยวิธีโครงข่ายประสาทเทียม มุมเซนนิธของดวงอาทิตย์ คำนวณได้จาก เส้นทางการเดินของดวงอาทิตย์ในรอบวัน ปริมาณเมฆ (cloud Index) จะใช้วิธี โครงข่ายประสาทเทียมแบบคอนโวลูชันในการคำนวณ โดยมีอินพุทเป็นภาพถ่ายท้องฟ้า จาก 4 สถานีหลักได้แก่ศูนย์อุตุนิยมวิทยาภาคเหนือจังหวัดเชียงใหม่ ศูนย์อุตุนิยมวิทยาภาคตะวันออกเฉียงเหนือจังหวัดอุบลราชธานี ภาคกลางที่มหาวิทยาลัยศิลปากรจังหวัดนครปฐม และภาคใต้ศูนย์อุตุนิยมวิทยาภาคใต้ ผังตะวันออกจังหวัดสงขลา ในการฝึกสอนจะใช้จำนวนรอบ 100 รอบในการฝึกสอน ความแม่นยำในการฝึกสอนมีค่าเท่ากับ 87% และนำเอาข้อมูลที่ฝึกสอนมาใช้คำนวณหาปริมาณเมฆของสถานีวิทยาลัยบูรพาวิทยาเขตสระแก้ว จากนั้นนำข้อมูลเมฆที่ได้และมุมเซนนิธของดวงอาทิตย์มาประมาณค่าความเข้มรังสีดวงอาทิตย์ในช่วงความยาวคลื่นที่พืชใช้สังเคราะห์แสงโดยวิธีโครงข่ายประสาทเทียม(ANN) พบว่าวิธีที่ให้ค่าการประมาณได้ดีที่สุดได้แก่วิธี โครงข่ายประสาทเทียมแบบ CNN ซึ่งมีค่า R^2 เท่ากับ 0.80 RMSE เท่ากับ 19.3% และ MBE เท่ากับ 19.3% ซึ่งวิธีการเหล่านี้สามารถนำไปประยุกต์ใช้ในการคำนวณความเข้มรังสีดวงอาทิตย์เพื่อเป็นข้อมูลในการเลือกพืชให้เหมาะสมกับความเข้มรังสีดวงอาทิตย์ในแต่ละพื้นที่หรือใช้ในการประมาณผลผลิตทางการเกษตรต่อไป

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณ คณะวิทยาศาสตร์และสังคมศาสตร์มหาวิทยาลัยบูรพาวิทยาเขตสระแก้ว ที่ได้เอื้อเฟื้อสถานที่และอุปกรณ์ต่าง ๆ สำหรับใช้ในการทดลอง และคณาจารย์คณะวิทยาศาสตร์และสังคมศาสตร์มหาวิทยาลัยบูรพาวิทยาเขตสระแก้ว ที่ให้การสนับสนุนช่วยเหลือการทำวิจัยเป็นอย่างดี จนทำให้งานวิจัยสำเร็จลุล่วงตามเป้าหมายทุกประการ

เอกสารอ้างอิง

- Basheer, I. A. and Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and Application. *Journal of Microbiological Methods* 43(1): 3-31.
- Caya, M. V. C., Alcantara, J. T., Carlos, J. S. and Cereno, S. S. B. (2018). Photosynthetically Active Radiation (PAR) Sensor Using an Array of Light Sensors with the Integration of Data Logging for Agricultural Application. In: *International Conference on Computer and Communication Systems (ICCCS)*. 377-381.
- Frouin, R. and Murakami, H. (2007). Estimating photosynthetically available radiation at the ocean surface from ADEOS-II global imager data. *Journal of Oceanography* 63(2007): 493-503.
- Iqbal, M. (1983). *An Introduction to Solar Radiation*. New York: Academic Press.
- Janjai, S., Wattan, R. and Sripradit, A. (2015). Modeling the ratio of photosynthetically active radiation to broadband global solar radiation using ground and satellite-based data in the tropics. *Advances in Space Research* 56(11): 2356-2364.
- Kim, J., Lee, J. K. and Lee, K. M. (2016). Accurate Image Super-Resolution Using Very Deep Convolutional Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 1646-1654.
- Mathworks (2019). Convolution neural networks, Available at: <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>.
- McCree, K. J. (1966). A solarimeter for measuring photosynthetically active radiation. *Agricultural Meteorology* 3(5): 353-366.
- Tao, X., Liang, S., Wang, D., He, T. and Huang, C. (2018). Improving Satellite Estimates of the Fraction of Absorbed Photosynthetically Active Radiation Through Data Integration: Methodology and Validation. *IEEE Transactions on Geoscience and Remote Sensing* 56(4): 2107-2118.
- Tkemaladze, G. Sh. and Makhashvili, K. A. (2016). Climate changes and photosynthesis. *Annals of Agrarian Science* 14(2): 119-126.

