

การพยากรณ์ความเข้มรังสีอาทิตย์โดยใช้โครงข่ายแบบ
หน่วยความจำระยะสั้นแบบยาวในประเทศไทย

Forecasting Solar Radiation Using Long Short-Term
Memory Neuron Network in Thailand

พศิน กิรติพงษ์วุฒิ¹ สมเจตน์ ภัทรพานิชชัย² ชนินาท ศรีเมือง²
กุลวลัญช์ วรณสิน³ และ สุมามาลย์ บรรเทิง^{2*}
Pasin Kiratipongwut¹, Somjet Pattarapanitchai²,
Chaninat Srimueang², Kulwarun Warunsin³
and Sumaman Buntoung^{2*}

Received: 9 July 2025

Revised: 11 December 2025

Accepted: 15 December 2025

บทคัดย่อ

พลังงานแสงอาทิตย์เป็นพลังงานทางเลือกหนึ่งที่สำคัญในปัจจุบันซึ่งจะช่วยในการลดปริมาณ การปลดปล่อยก๊าซคาร์บอนไดออกไซด์ในบรรยากาศได้ ซึ่งพลังงานแสงอาทิตย์นี้สามารถนำไปประยุกต์ใช้โดยแปลงให้เป็นพลังงานไฟฟ้าหรือพลังงานความร้อน เช่น ระบบผลิตไฟฟ้าจากแผงเซลล์แสงอาทิตย์ ระบบทำน้ำร้อนพลังงานแสงอาทิตย์ และระบบอบแห้งพลังงานแสงอาทิตย์ สำหรับระบบที่ใช้ในการแปลงพลังงานแสงอาทิตย์เป็นพลังงานดังกล่าวนี้จำเป็นต้องทราบค่าความเข้มรังสีอาทิตย์ที่ตกกระทบเพื่อใช้ในการประเมินศักยภาพและการควบคุมการทำงานของระบบให้มีศักยภาพสูงที่สุดในการใช้งาน ดังนั้นในงานวิจัยนี้จึงทำการพัฒนาแบบจำลองการเรียนรู้ของเครื่องแบบโครงข่ายหน่วยความจำระยะสั้นแบบยาวเพื่อพยากรณ์ค่าความเข้มรังสีอาทิตย์ล่วงหน้า 1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง โดยใช้ข้อมูลความเข้มรังสีอาทิตย์จาก

¹ภาควิชาฟิสิกส์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหิดล กรุงเทพฯ ประเทศไทย 10400

¹Department of Physics, Faculty of Science, Mahidol University, Bangkok, Thailand 10400

²ภาควิชาฟิสิกส์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร นครปฐม ประเทศไทย 73000

²Department of Physics, Faculty of Science, Silpakorn University, Nakhon Pathom, Thailand 73000

³สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยรามคำแหง กรุงเทพฯ ประเทศไทย 10240

³Department of Computer Engineering, Faculty of Engineering, Ramkhamhaeng University, Bangkok, Thailand 10240

*ผู้รับผิดชอบประสานงาน (Corresponding author) e-mail: Buntoung_s@silpakorn.edu

การวัดภาคพื้นดิน และข้อมูลตัวแปรทางบรรยากาศต่าง ๆ จากฐานข้อมูล ERA5 ที่จังหวัดนครปฐม (13.82 °N, 100.04 °E) ตั้งแต่ปี ค.ศ. 2019 – 2023 ผลการทดสอบสมรรถนะของแบบจำลองพบว่าแบบจำลองที่พัฒนาขึ้นสามารถพยากรณ์ความเข้มรังสีอาทิตย์ล่วงหน้า 1 ชั่วโมงได้ดีที่สุด โดยมีค่าความคลาดเคลื่อนในรูปของค่า normalized root mean square error (nRMSE) ของรากที่สองของค่าเฉลี่ยของความแตกต่างยกกำลังสองเท่ากับ 20.93% และค่า normalized mean bias error (nMBE) ของค่าเฉลี่ยของความแตกต่างเท่ากับ 0.12% เมื่อเทียบกับค่าที่ได้จากการวัดจริง

คำสำคัญ: พยากรณ์ หน่วยความจำระยะสั้นแบบยาว รังสีอาทิตย์ บรรยากาศ

ABSTRACT

Solar energy is an important alternative energy nowadays, as it helps reduce carbon emissions. Solar energy can be converted into electricity or thermal energy using specialized systems. Common types of solar energy systems include photovoltaic systems, solar thermal systems, and solar drying systems. To evaluate and optimize the performance of these systems, it is essential to know the amount of incident solar energy received by the devices. For this reason, this study aims to forecast solar radiation at 1 hour 2 hours 3 hours 4 hours and 24 hours ahead using a Long Short-Term Memory (LSTM) machine learning model. Ground-based solar radiation data and several atmospheric parameters from ERA5 at Nakhon Pathom site (13.82°N, 100.04°E), Thailand, were used for the period from 2019 to 2023. The results show that the developed LSTM model performs best for 1-hour ahead forecasting, achieving a normalized root mean square error (nRMSE) of 20.93% and a normalized mean bias error (nMBE) of 0.12%, compared to the measured data.

Keywords: Forecast; LSTM; Solar radiation; Atmosphere

บทนำ

ดวงอาทิตย์ถือเป็นแหล่งพลังงานหลักของโลกซึ่งประโยชน์ในทางตรงสามารถให้ความสว่างและความอบอุ่นแก่ร่างกายของสิ่งมีชีวิตได้ [1] และในทางอ้อมสามารถนำมาแปลงเป็นพลังงานในรูปแบบอื่น ๆ ที่สำคัญได้แก่ พลังงานไฟฟ้าที่มีความจำเป็นต่อการดำเนินชีวิตประจำวันของมนุษย์ ในปัจจุบันประเทศต่าง ๆ ให้ความสำคัญและผลักดันในด้านการใช้พลังงานทดแทน โดยพลังงานแสงอาทิตย์ถือเป็นพลังงานทดแทนทางเลือกหนึ่งที่สำคัญ เช่น การจัดตั้งโรงงานไฟฟ้าเซลล์แสงอาทิตย์ การติดตั้งแผงเซลล์แสงอาทิตย์บนหลังคาบ้านเพื่อนำมาผลิตไฟฟ้า อย่างไรก็ตามการติดตั้งเซลล์แสงอาทิตย์ดังกล่าวจำเป็นต้องทราบถึงความคุ้มค่าและความคุ้มค่าในการติดตั้งด้วย ซึ่งจำเป็นต้องทราบปริมาณความเข้มรังสีอาทิตย์ที่ตกกระทบบนแผงเซลล์แสงอาทิตย์ในแต่ละช่วงเวลาและแต่ละพื้นที่ [2] นอกจากนี้ในปัจจุบันมีการประกอบธุรกิจขนาดเล็กที่ใช้พลังงานแสงอาทิตย์ เช่น การอบแห้งผลิตภัณฑ์ทางการเกษตร ดังนั้นการทราบปริมาณความเข้มรังสีอาทิตย์ล่วงหน้าจะทำให้สามารถวางแผนการดำเนินงานเพื่อให้เกิดความคุ้มค่าและความคุ้มค่าได้ด้วย

การวัดความเข้มรังสีอาทิตย์โดยทั่วไปสามารถทำได้โดยการติดตั้งเครื่องไพราโนมิเตอร์ [3] แต่เครื่องวัดดังกล่าวอาจไม่ครอบคลุมทุกพื้นที่ อีกทั้งเครื่องมือดังกล่าวจำเป็นต้องได้รับการสอบเทียบมาตรฐานทุกปีและจำเป็นต้องมีการบำรุงรักษา และซ่อมแซมอย่างสม่ำเสมอ ทำให้มีค่าใช้จ่ายในการดำเนินงานค่อนข้างสูง นักวิจัยจึงได้พยายามประมาณค่าความเข้มรังสีอาทิตย์ด้วยวิธีอื่นๆ เช่น จากข้อมูลดาวเทียม จากแบบจำลองทางฟิสิกส์และคณิตศาสตร์ [4, 5]

แบบจำลองแบบดั้งเดิม เช่น การทำนายสภาพอากาศเชิงตัวเลข (Numerical Weather Prediction, NWP) แม้จะถูกใช้ในการพยากรณ์ความเข้มรังสีอาทิตย์อย่างแพร่หลาย แต่ยังมีข้อจำกัดด้านความแม่นยำ ความละเอียดเชิงพื้นที่ และระยะเวลาที่ใช้ในการคำนวณ [6] ด้วยความก้าวหน้าของเทคนิคปัญญาประดิษฐ์ (AI) ที่ประกอบด้วยการเรียนรู้ของเครื่อง (Machine Learning, ML) และการเรียนรู้เชิงลึก (Deep Learning, DL) ทำให้สามารถพัฒนาระบบพยากรณ์ที่ตอบสนองต่อความผันแปรของสภาพอากาศเฉพาะพื้นที่ได้อย่างมีประสิทธิภาพยิ่งขึ้น [6] จากงานวิจัยก่อนหน้าแบบจำลอง ML ที่นิยมใช้ ได้แก่ การถดถอยเชิงเส้น (Linear Regression) เค-ใกล้เคียงที่สุด (K-Nearest Neighbor) เครื่องเวกเตอร์สนับสนุน (Support Vector Machine) และแบบจำลองเชิงต้นไม้ (Tree-based Models) เช่น ป่าสุ่ม (Random Forest) เกรเดียนต์บูสต์ (Gradient Boosting) และเอ็กซ์จีบูสต์ (XGBoost) ได้ถูกนำมาใช้ในการพยากรณ์รังสีอาทิตย์ที่สามารถเรียนรู้จากข้อมูลสภาพอากาศในอดีต จัดการข้อมูลจำนวนมากได้ดีและให้ผลลัพธ์ที่ตีความง่าย แต่มีข้อจำกัดในการจับรูปแบบความสัมพันธ์เชิงเวลาที่ซับซ้อนในระยะยาวของข้อมูลอนุกรมเวลา (Time series) [7, 8]

โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) ได้รับการพิสูจน์แล้วว่ามีประสิทธิภาพสูงกว่าแบบจำลองแบบดั้งเดิม โดยเฉพาะในพื้นที่ที่ข้อมูลมีลักษณะไม่เป็นเชิงเส้นและมีความสัมพันธ์ของตัวแปรจำนวนมาก [9] ในขณะที่แบบจำลอง DL เช่น โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks, CNN) โครงข่ายประสาทแบบวนซ้ำ (Recurrent Neural Networks, RNN) และโครงข่ายหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory, LSTM) เรียนรู้และสกัดคุณลักษณะจากข้อมูลได้อย่างเป็นลำดับขั้นและซับซ้อนยิ่งขึ้น และแสดงให้เห็นถึงประสิทธิภาพที่ดีกว่าแบบจำลอง ML ทั่วไปอย่างมีนัยสำคัญในการพยากรณ์ความเข้มรังสีอาทิตย์ [10] แบบจำลอง CNN เป็นแบบจำลองที่มีความสามารถโดดเด่นในการสกัดคุณลักษณะเชิงพื้นที่ (Spatial Features) จึงมักถูกนำมาใช้ประมวลผลข้อมูลในรูปแบบกริด เช่น ภาพถ่ายเมฆจากดาวเทียม (Satellite Imagery) หรือภาพถ่ายท้องฟ้า (Sky-Imager) เพื่อวิเคราะห์การปกคลุมและการเคลื่อนที่ของเมฆ ซึ่งเป็นปัจจัยสำคัญที่ส่งผลต่อรังสีอาทิตย์ [11] สำหรับแบบจำลอง LSTM ซึ่งถูกพัฒนาขึ้นเพื่อจัดการกับข้อจำกัดของ RNN ดั้งเดิมที่มีเกรเดียนต์ที่หายไป (vanishing gradient) ซึ่งทำให้แบบจำลองไม่สามารถเรียนรู้ความสัมพันธ์ระยะยาวได้อย่างมีประสิทธิภาพ และปัญหาเกรเดียนต์ระเบิด (exploding gradient) ซึ่งอาจทำให้ค่าน้ำหนักปรับตัวรุนแรงเกินควบคุม โครงสร้างการทำงานของแบบจำลอง LSTM ประกอบด้วยหน่วยความจำ (cell state) และกลไกเกต 3 ชนิด ช่วยให้แบบจำลองสามารถเลือกเก็บหรือละทิ้งข้อมูลตามลำดับเวลาได้อย่างยืดหยุ่น [8, 10-12] ความสามารถนี้ทำให้แบบจำลอง LSTM เหมาะอย่างยิ่งในการจัดการข้อมูลอนุกรมเวลาเชิงซับซ้อน เช่น การพยากรณ์ความเข้มรังสีอาทิตย์ที่มีความผันผวนตามฤดูกาลและสภาพอากาศ จากการศึกษาเปรียบเทียบงานวิจัยก่อนหน้าพบว่าแบบจำลอง LSTM จะให้ค่าความแม่นยำสูงกว่าแบบจำลองอื่น ๆ เช่น ANN, RNN และ XGBoost [8, 10] ซึ่งสนับสนุนถึงประสิทธิภาพของแบบจำลอง LSTM ในการพยากรณ์ความเข้มรังสีอาทิตย์ในกรณีของภูมิภาคอากาศของประเทศไทย

สำหรับประเทศไทย Chawphongphang et al. [13] ใช้แบบจำลอง ANN ในการพยากรณ์ความเข้มรังสีอาทิตย์รวมและรังสีกระจายล่วงหน้า 1 ชั่วโมงโดยใช้ข้อมูลปี ค.ศ. 2019 - 2021 ที่มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี กรุงเทพมหานคร (13.58°N, 100.11°E) ตัวแปรอินพุตที่ใช้ประกอบด้วย อุณหภูมิอากาศ มุมเงยของดวงอาทิตย์ และค่านอร์มัลไลซ์ของความเข้มรังสีอาทิตย์ ซึ่งผลการพยากรณ์มีค่าใกล้เคียงกับค่าที่ได้จากการวัด โดยมีค่าความคลาดเคลื่อนในรูปของค่านอร์มัลไลซ์ของค่าเฉลี่ยของความแตกต่าง (normalized mean bias error, nMBE) และค่านอร์มัลไลซ์ของค่ารากที่สองของค่าเฉลี่ยของความแตกต่างยกกำลังสอง (normalized root mean square error, nRMSE) เท่ากับ 1.79% และ 26.20% ตามลำดับ สำหรับรังสีรวม และ 7.78% และ 36.21% ตามลำดับ สำหรับรังสีกระจาย

สำหรับในงานวิจัยนี้ ผู้วิจัยเสนอที่จะทำการพัฒนาแบบจำลอง LSTM และใช้ข้อมูลอินพุตจากการวัดจริงร่วมกับข้อมูลจาก ERA5 เพื่อเป็นอีกทางเลือกหนึ่งในการพยากรณ์ความเข้มรังสีอาทิตย์ซึ่งยังไม่เคยมีการวิจัยมาก่อนในประเทศไทย โดยจะเลือกการพยากรณ์ความเข้มรังสีอาทิตย์ล่วงหน้า 1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง ทั้งนี้เพื่อใช้ในการประเมินประสิทธิภาพของแบบจำลองที่พัฒนาขึ้นในช่วงเวลาต่าง ๆ

วิธีดำเนินการวิจัย

สำหรับวิธีการพัฒนาแบบจำลอง LSTM เพื่อใช้ในการพยากรณ์ความเข้มรังสีอาทิตย์มีรายละเอียดในแต่ละขั้นตอนดังต่อไปนี้

1. เครื่องมือและข้อมูลที่ใช้

1.1 ข้อมูลภาคพื้นดิน

ข้อมูลความเข้มรังสีอาทิตย์รวมบนพื้นผิวในแนวระนาบ (Global Horizontal Irradiance, GHI) ที่ใช้ในงานวิจัยนี้ได้มาจากการวัดภาคพื้นดินด้วยเครื่องไพราโนมิเตอร์ (pyranometer) รุ่น CM21 ของบริษัท Kipp & Zonen ซึ่งติดตั้งไว้ที่คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร จังหวัดนครปฐม (13.82 °N, 100.04 °E) ดังรูปที่ 1 โดยเครื่องวัดดังกล่าวเชื่อมต่อกับเครื่องบันทึกข้อมูลรุ่น DX2000 ของบริษัท Yokogawa เพื่อบันทึกศักย์ไฟฟ้าทุกๆ 1 วินาที ตลอด 24 ชั่วโมง ซึ่งค่าศักย์ไฟฟ้านี้สามารถนำมาแปลงให้เป็นค่าความเข้มรังสีอาทิตย์ราย 1 วินาทีได้โดยใช้ค่า sensitivity ของเครื่องวัด ตามสมการ

$$GHI = \frac{V}{S} \tag{1}$$

เมื่อ GHI คือ ค่าความเข้มรังสีอาทิตย์ [W/m²]

V คือ ค่าศักย์ไฟฟ้า [V]

S คือ ค่า sensitivity [V/(W/m²)]

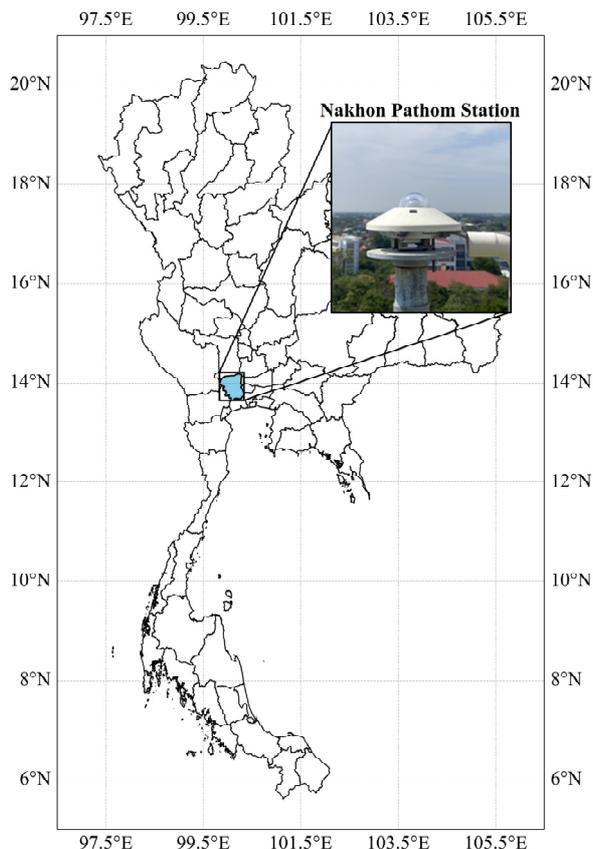


Figure 1 The pyranometer installed at Silpakorn University, Nakhon Pathom

ผู้วิจัยทำการรวบรวมข้อมูลค่าศักย์ไฟฟ้าจากเครื่องไพราโนมิเตอร์ที่สถานีดังกล่าวตั้งแต่วันที่ 8:00 – 16:00 น. ในช่วงปี ค.ศ. 2019 – 2023 และทำการแปลงให้เป็นค่าความเข้มรังสีอาทิตย์รายวินาที หากค่าความเข้มรังสีอาทิตย์ที่ได้มีค่าสูงกว่าค่าความเข้มรังสีอาทิตย์นอกบรรยากาศโลกจะถือว่าข้อมูลที่ได้มีความผิดพลาด ผู้วิจัยจะทำการตัดข้อมูลดังกล่าวออก จากนั้นคำนวณเป็นค่าเฉลี่ยรายชั่วโมงในหน่วย W/m^2 โดยระยะเวลาที่กึ่งกลางชั่วโมง ได้แก่ 8:30 9:30 10:30 11:30 12:30 13:30 14:30 และ 15:30 น. เนื่องจากเป็นช่วงที่ดวงอาทิตย์มีมุมเงยสูงทำให้ลดผลกระทบจากการกระเจิงและความผันผวนของข้อมูลที่เกิดจากบรรยากาศในช่วงที่ดวงอาทิตย์อยู่ใกล้ขอบฟ้า ตัวอย่างของค่าความเข้มรังสีอาทิตย์ที่เวลา 12:30 น. ตั้งแต่ปี ค.ศ. 2019 – 2023 แสดงดังรูปที่ 2

จากกราฟจะเห็นได้ว่าความเข้มรังสีอาทิตย์มีการแปรค่าในรอบปี โดยในช่วงต้นปีและปลายปี ความเข้มรังสีอาทิตย์จะมีค่าต่ำ ส่วนช่วงกลางปีค่าความเข้มรังสีอาทิตย์จะค่อนข้างสูง อย่างไรก็ตามในช่วงฤดูฝนจะมีเมฆปกคลุมท้องฟ้าค่อนข้างมากทำให้ค่าความเข้มรังสีอาทิตย์ลดลงอย่างเห็นได้ชัด ดังนั้นจะเห็นได้ว่า

ตำแหน่งของโลกเทียบกับดวงอาทิตย์ ฤดูกาล และองค์ประกอบต่าง ๆ ในบรรยากาศมีผลอย่างมากต่อปริมาณรังสีอาทิตย์ที่พื้นผิวโลก

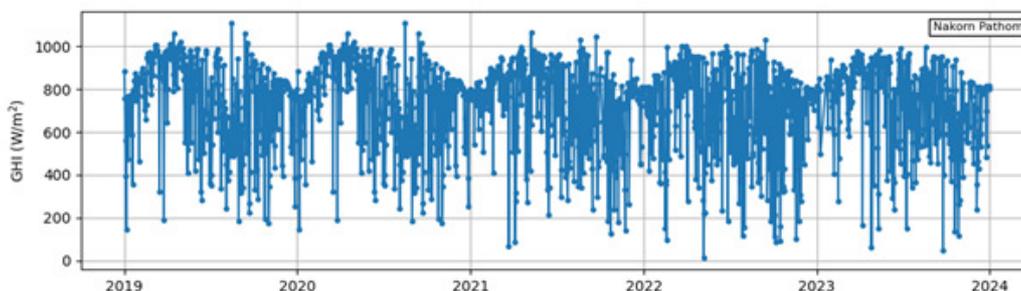


Figure 2 Variation of solar radiation at 12:30 local time measured at Nakhon Pathom station

1.2 ข้อมูล ERA5

ข้อมูล ERA5 เป็นข้อมูลตัวแปรทางบรรยากาศแบบวิเคราะห์ย้อนหลัง (Reanalysis) ของ European Centre for Medium-Range Weather Forecasts (ECMWF) ที่ใช้สำหรับงานด้านภูมิอากาศและสภาพอากาศทั่วโลก ซึ่งให้ข้อมูลที่มีความละเอียดเชิงเวลา 1 ชั่วโมง และความละเอียดเชิงพื้นที่ $0.25^{\circ} \times 0.25^{\circ}$ ในงานวิจัยนี้ผู้วิจัยเลือกใช้ข้อมูลองค์ประกอบในบรรยากาศที่มีผลกระทบต่อ การเปลี่ยนแปลงปริมาณความเข้มรังสีอาทิตย์ที่พื้นผิวโลก ได้แก่ เมฆ ซึ่งสามารถสะท้อนและกระเจิงรังสีอาทิตย์ได้ดี รวมถึงไอน้ำและโอโซนที่สามารถดูดกลืนรังสีอาทิตย์ในช่วงความยาวคลื่นต่าง ๆ ได้ โดยผู้วิจัยได้ทำการดาวน์โหลดข้อมูลปริมาณเมฆระดับสูง (high cloud cover, HCC) ปริมาณเมฆระดับกลาง (middle cloud cover, MCC) ปริมาณเมฆระดับต่ำ (low cloud cover, LCC) ปริมาณไอน้ำในคอลัมน์บรรยากาศ (total column water vapour, TCWV) และปริมาณโอโซนในคอลัมน์บรรยากาศ (total column ozone, TCO) จาก <https://cds.climate.copernicus.eu/datasets/reanalysis-era5-single-levels> ที่เวลา 8:00 - 16:00 น. ระหว่างปี ค.ศ. 2019 - 2023 ณ ตำแหน่งสถานีวัดภาคพื้นดิน จังหวัดนครปฐม แล้วนำมาหาค่าเฉลี่ยที่เวลา 8:30 - 15:30 น. ซึ่งสอดคล้องกับเวลาของข้อมูลความเข้มรังสีอาทิตย์ที่ได้จากการวัดภาคพื้นดินข้อมูลที่ได้จาก ERA5 แสดงดังรูปที่ 3 โดยตัวแปรเหล่านี้จะใช้เป็นอินพุตในแบบจำลอง

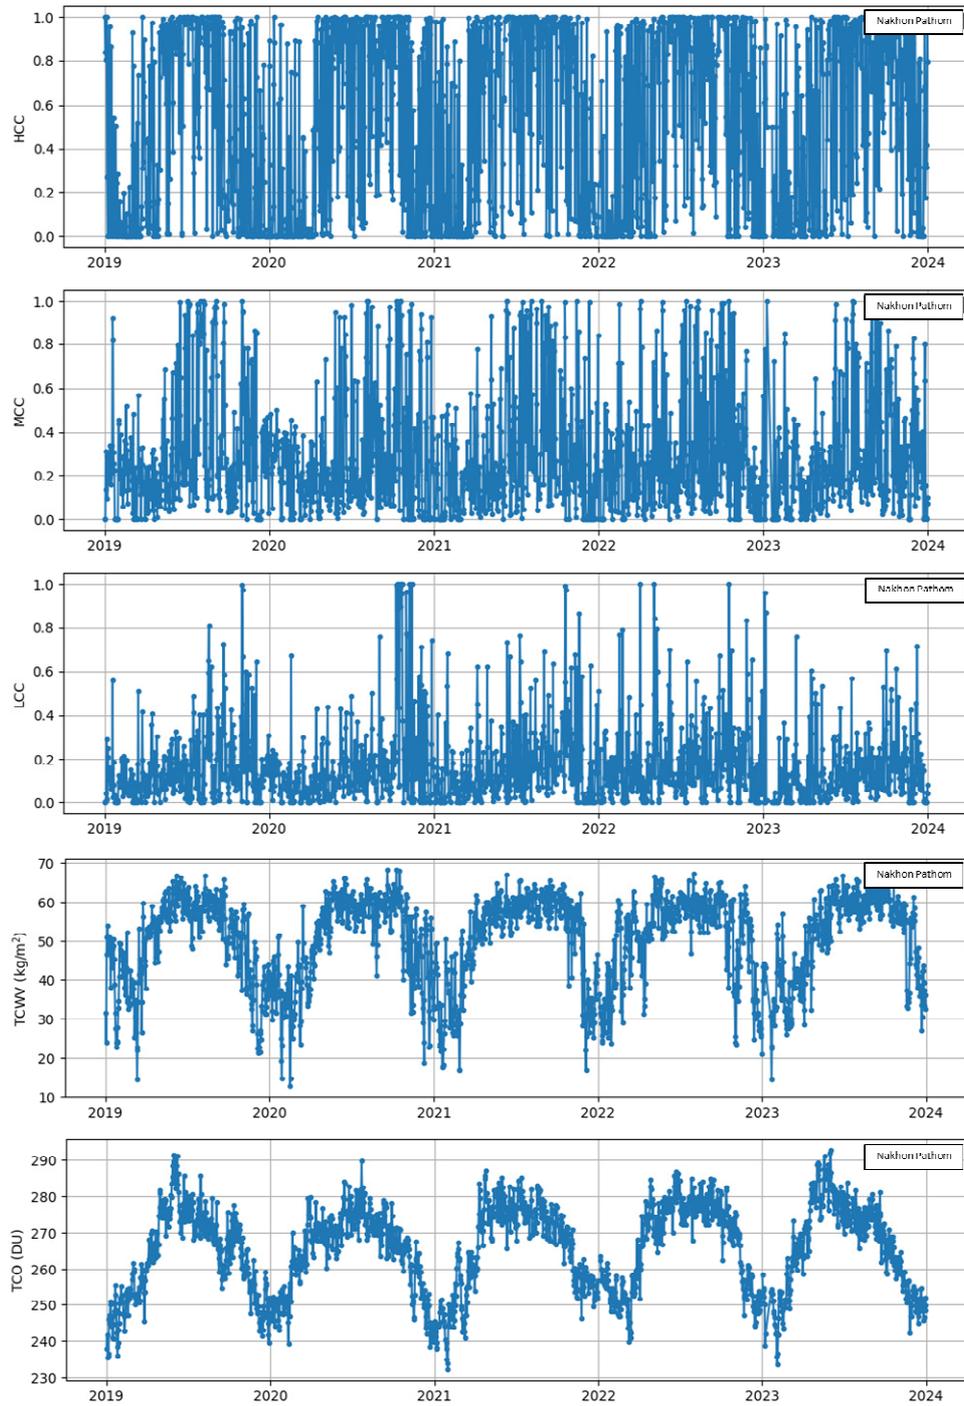


Figure 3 Variations of atmospheric parameters from ERA5 at Nakhon Pathom station

นอกจากข้อมูลภาคพื้นดินและข้อมูลจาก ERA5 แล้ว ในงานวิจัยนี้ยังใช้ค่าความเข้มรังสีอาทิตย์นอกบรรยากาศ (Extraterrestrial solar irradiance, I_0) ซึ่งสามารถคำนวณได้ [14] รวมถึงเวลาและลำดับวันในรอบปี เป็นตัวแปรอินพุตในแบบจำลองด้วย

1.3 แบบจำลอง LSTM

ในการพยากรณ์ความเข้มรังสีอาทิตย์โดยใช้ปัญญาประดิษฐ์โดยเฉพาะอย่างยิ่งแบบจำลอง LSTM เป็นการพัฒนาจากแบบจำลอง RNN ดั้งเดิมเพื่อแก้ปัญหาการสูญหายของ vanishing gradient และ exploding gradient ซึ่งส่งผลต่อความสามารถในการเรียนรู้ลำดับข้อมูลระยะยาว โดยแบบจำลอง LSTM ถูกออกแบบโครงสร้างมาโดยเฉพาะเพื่อจัดการกับข้อมูลอนุกรมเวลาที่มีความสัมพันธ์ระยะยาวและซับซ้อนได้อย่างมีประสิทธิภาพ คุณสมบัตินี้เป็นสิ่งสำคัญอย่างยิ่งสำหรับข้อมูลความเข้มรังสีอาทิตย์ ซึ่งเป็นข้อมูลอนุกรมเวลาที่มีความผันผวนและขึ้นอยู่กับปัจจัยในอดีตหลายอย่าง เช่น ฤดูกาล สภาพอากาศ และตำแหน่งดวงอาทิตย์ เป็นต้น โครงสร้างทั่วไปของแบบจำลอง LSTM ประกอบด้วยโหนด (Node) ซึ่งแต่ละ Node ประกอบด้วยหน่วยความจำภายใน (cell state) และกลไกเกต ซึ่งแบ่งเป็นเกตอินพุต (input gate) เกตลืม (forget gate) และเกตเอาต์พุต (output gate) สำหรับควบคุมเส้นทางของข้อมูลในแต่ละช่วงเวลา โดยกลไกเหล่านี้มีการดำเนินการตามสมการ (2) - (6) [12] เพื่อคัดกรอง จัดเก็บ และส่งผ่านข้อมูลอนุกรมเวลาอย่างมีประสิทธิภาพ คุณสมบัติดังกล่าวทำให้ LSTM สามารถเรียนรู้และจดจำความสัมพันธ์ระยะยาวได้ดี จึงได้รับความนิยมอย่างแพร่หลายในการประยุกต์ใช้กับปัญหาที่เกี่ยวข้องกับข้อมูลลำดับเวลาที่มีความซับซ้อน

สำหรับโครงสร้างของแบบจำลอง LSTM แสดงได้ดังรูปที่ 4 ประกอบด้วยข้อมูลอินพุต (input) การสกัดคุณลักษณะ (feature extraction) และข้อมูลเอาต์พุต (output) โดยสถาปัตยกรรมหรือโครงสร้างของแบบจำลองประกอบด้วยชั้น (Layer) ของแบบจำลอง LSTM และจำนวน Node โดยแต่ละ Node มีหน่วยความจำภายใน และเกตหลัก 3 ชนิด ได้แก่ เกตอินพุต (i_t) เกตลืม (f_t) และเกตเอาต์พุต (o_t) โดยเกตเหล่านี้มีกลไกการทำงานตามสมการ (2) - (4) ทำหน้าที่ตัดสินใจเลือกผลลัพธ์ระหว่างข้อมูลอินพุตปัจจุบัน (x_t) และสถานะของ Node ก่อนหน้า (h_{t-1}) ด้วยการใช้ฟังก์ชัน Tanh (\tanh) ในการตัดสินใจที่ให้ผลลัพธ์อยู่ในช่วง -1 ถึง 1 แสดงถึงระดับของข้อมูลที่ควรนำมาใช้ในการตัดสินใจดั้งเดิม สำหรับสมการ (5) ใช้ในการอัปเดตสถานะหน่วยความจำ (c_t) ของ LSTM โดยนำข้อมูลจากเวลา (timestep) ก่อนหน้า (c_{t-1}) มาควบคุมด้วยเกตลืม เพื่อคัดกรองข้อมูลที่ควรเก็บไว้ และรวมกับข้อมูลใหม่สะท้อนความจำใน timestep ปัจจุบัน ส่วนสมการ (6) คำนวณสถานะของชั้นซ่อน (hidden layer: h_t) โดยแปลงสถานะหน่วยความจำด้วยฟังก์ชัน Tanh และใช้เกตเอาต์พุตควบคุมการส่งผ่านข้อมูลไปยังขั้นตอนถัดไป

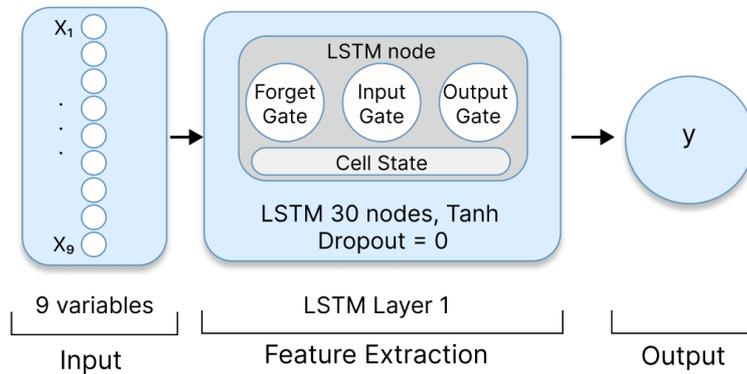


Figure 4 Arcitecture of LSTM model developed in this study

$$i_t = \tanh(\theta_i[x_t, h_{t-1}] + b_i) \quad (2)$$

$$f_t = \tanh(\theta_f[x_t, h_{t-1}] + b_f) \quad (3)$$

$$o_t = \tanh(\theta_o[x_t, h_{t-1}] + b_o) \quad (4)$$

$$c_t = c_{t-1} \odot f_t + [\tanh(\theta_c[x_t, h_{t-1}] + b_c)] \odot i_t \quad (5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

โดยที่ $\theta_i, \theta_f, \theta_o$ และ θ_c แทนค่าน้ำหนักของโครงสร้างของแบบจำลอง LSTM ส่วน b_i, b_f, b_o และ b_c คือ พารามิเตอร์ไบแอสค่าคงที่เอนเอียง และ \odot คือการคูณแบบรายองค์ประกอบ

ความแม่นยำของแบบจำลอง LSTM ขึ้นอยู่กับการปรับแต่งพารามิเตอร์หลัก เช่น อัตราการเรียนรู้ (Learning rate) สำหรับควบคุมความเร็วในการฝึกจำนวน Layer และจำนวน Node เพื่อกำหนดความลึกในการเรียนรู้ลำดับข้อมูลขนาดแบตช์ (Batch sizes) ส่งผลต่อเสถียรภาพของเกรเดียนต์ อัตราการดรอปเอาต์ (Dropout rate) สำหรับปรับเพื่อลดการปรับค่าสูง (overfitting) ของแบบจำลอง และจำนวนรอบของการฝึก (Epoch) สำหรับควบคุมระดับการเรียนรู้ รวมถึงการเลือกใช้ฟังก์ชันออปติไมเซชัน (optimization) [12] เช่น Adam และ RMSProp ช่วยให้แบบจำลองเรียนรู้ได้เร็วขึ้น เสถียรมากขึ้น การปรับแต่งพารามิเตอร์เหล่านี้มีบทบาทสำคัญต่อประสิทธิภาพของแบบจำลอง และสามารถจับลักษณะข้อมูลรังสีอาทิตย์ที่แปรผันได้อย่างแม่นยำยิ่งขึ้น

2. การพัฒนาแบบจำลองสำหรับพยากรณ์ความเข้มรังสีอาทิตย์

ในงานวิจัยนี้เลือกใช้แบบจำลองการเรียนรู้ของเครื่องแบบ LSTM ในการพยากรณ์ความเข้มรังสีอาทิตย์โดยมีกระบวนการต่างๆดังต่อไปนี้

2.1 การคัดเลือกตัวแปรอินพุตในแบบจำลอง

เนื่องจากองค์ประกอบในบรรยากาศ ตำแหน่งของดวงอาทิตย์ รวมถึงตำแหน่งของโลกเทียบกับดวงอาทิตย์ มีผลต่อการลดทอนความเข้มรังสีอาทิตย์ที่ผ่านชั้นบรรยากาศลงมาถึงพื้นผิวโลก ดังนั้นในงานวิจัยนี้จึงเลือกใช้ตัวแปรจำนวน 9 ตัวแปร เป็นอินพุตสำหรับแบบจำลอง ประกอบด้วย ความเข้มรังสีอาทิตย์นอกบรรยากาศโลก (I_0) ปริมาณเมฆระดับสูง (HCC) ปริมาณเมฆระดับกลาง (MCC) ปริมาณเมฆระดับต่ำ (LCC)

ปริมาณไอน้ำในคอลัมน์บรรยากาศ (TCWV) ปริมาณโอโซนในคอลัมน์บรรยากาศ (TCO) และค่าความเข้มรังสีอาทิตย์ (GHI) ค่าโคไซน์ของลำดับวันในรอบปี ($\cos D_n$) และเวลา (T)

2.2 การฝึกสอนแบบจำลอง

ในการฝึกสอนแบบจำลองจะใช้ข้อมูลช่วงปี ค.ศ. 2019 – 2021 (คิดเป็น 60%) สำหรับเป็นชุดฝึกสอน (training set) และใช้ข้อมูลปี ค.ศ. 2022 (คิดเป็น 20%) เป็นชุดตรวจสอบ (validation set) โดยผู้วิจัยนำข้อมูลอินพุตทั้ง 9 ตัวแปร เข้ารับการฝึกสอนแบบจำลองเพื่อพยากรณ์ความเข้มรังสีอาทิตย์ล่วงหน้า 1 ชั่วโมง โดยแปรค่าโครงสร้างของแบบจำลอง LSTM ให้มีจำนวน Layer ตั้งแต่ 1 – 4 ชั้น ค่า Epoch ตั้งแต่ 300-900 จำนวน Node ตั้งแต่ 10-40 และ Dropout rate ตั้งแต่ 0.0 - 0.3 แล้วพิจารณาค่า Loss value (mean square error) ที่ต่ำที่สุดซึ่งค่า Loss value ที่มีค่าน้อยแสดงถึงประสิทธิภาพของแบบจำลองที่ดี จากนั้นนำแบบจำลองที่มีประสิทธิภาพที่ดีที่สุดในการพยากรณ์ล่วงหน้า 1 ชั่วโมง ไปใช้ในการพยากรณ์ล่วงหน้า 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง

2.3 การทดสอบแบบจำลอง

เมื่อได้โครงสร้างของแบบจำลอง LSTM ที่เหมาะสมแล้ว ผู้วิจัยจะนำข้อมูลปี ค.ศ. 2023 (คิดเป็น 20%) ซึ่งเป็นชุดทดสอบ (testing set) มาใช้ในการประเมินประสิทธิภาพของแบบจำลองที่พัฒนาขึ้น โดยจะนำความเข้มรังสีอาทิตย์ที่ได้จากการพยากรณ์ล่วงหน้า 1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง มาเปรียบเทียบกับค่าความเข้มรังสีอาทิตย์ที่ได้จากการวัดภาคพื้นดิน และบอกประสิทธิภาพของแบบจำลองด้วยค่าทางสถิติ 3 ค่า ได้แก่ ค่าสัมประสิทธิ์สหสัมพันธ์ของเพียร์สัน (Pearson’s correlation coefficient, PCC) ค่านอร์มัลไลซ์ของค่ารากที่สองของค่าเฉลี่ยของความแตกต่างยกกำลังสอง (normalized root mean square error, nRMSE) และค่านอร์มัลไลซ์ของค่าเฉลี่ยของความแตกต่าง (normalized mean bias error, nMBE) ดังสมการ

$$PCC = \frac{\sum_{i=1}^n (y_i - \bar{y})(y'_i - \bar{y}')}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (y'_i - \bar{y}')^2}} \quad (7)$$

$$nRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}}{\bar{y}} \times 100\% \quad (8)$$

$$nMBE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y'_i - y_i}{\bar{y}} \right) \times 100\% \quad (9)$$

- เมื่อ y_i คือ ค่าความเข้มรังสีอาทิตย์ที่ได้จากการวัด [W/m^2]
 y'_i คือ ค่าความเข้มรังสีอาทิตย์ที่ได้จากการพยากรณ์ [W/m^2]
 \bar{y} คือ ค่าเฉลี่ยของ y_i [W/m^2]
 \bar{y}' คือ ค่าเฉลี่ยของ y'_i [W/m^2]
 n คือ จำนวนข้อมูลทั้งหมด [-]

ผลการวิจัย

จากการใช้อินพุตจำนวน 9 ตัวแปร ในการฝึกสอนแบบจำลอง LSTM ทำให้ได้โครงสร้าง LSTM ที่เหมาะสมที่สุดสำหรับจำนวน Layer ตั้งแต่ 1 – 4 ชั้น ดังตารางที่ 1

Table 1 Arcritecture of LSTM model

Parameters	Value/Function			
	1	2	3	4
Layer	1	2	3	4
Node	30	40	20	30
Dropout rate	0	0	0.2	0.1
Epoch	360	460	450	500
Activation	Tanh	Tanh	Tanh	Tanh
Optimize	Adam	Adam	Adam	Adam

เมื่อนำแบบจำลอง LSTM ที่พัฒนาขึ้นโดยใช้โครงสร้างที่ต่างกันนี้ไปพยากรณ์ความเข้มรังสีอาทิตย์ ล่วงหน้า 1 ชั่วโมง แล้วเปรียบเทียบกับความเข้มรังสีอาทิตย์ที่ได้จากการพยากรณ์กับการวัดภาคพื้นดิน ให้ผลของค่าทางสถิติดังตารางที่ 2

Table 2 Comparison between the 1-hour ahead solar radiation forecast from the LSTM model and the measurements

Statistic parameters	Number of Layer			
	1	2	3	4
PCC	0.82	0.82	0.82	0.82
nMBE (%)	0.12	0.55	-0.38	-0.59
nRMSE (%)	20.92	20.97	20.91	20.93

จากตารางที่ 2 จะเห็นว่าการใช้จำนวน Layer ที่แตกต่างกันให้ผลการเปรียบเทียบใกล้เคียงกัน อย่างไรก็ตามจะเห็นได้ว่าจำนวน Layer เท่ากับ 1 ให้ค่า nMBE น้อยที่สุด ดังนั้นผู้วิจัยจึงนำแบบจำลองดังกล่าวไปใช้ในการพยากรณ์ความเข้มรังสีอาทิตย์ล่วงหน้า 2 ชั่วโมง 3 ชั่วโมง และ 24 ชั่วโมง ซึ่งให้ผลการเปรียบเทียบค่าที่ได้จากการพยากรณ์และค่าที่ได้จากการวัดจริงแสดงดังตารางที่ 3

Table 3 Comparison between solar radiation from the LSTM model and measurement

Time-ahead to forecast (hour)	Statistic parameters		
	PCC	nMBE (%)	nRMSE (%)
1	0.82	0.12	20.92
2	0.72	-0.04	25.55
3	0.69	0.87	27.97
4	0.66	0.16	30.12
24	0.62	2.04	31.10

ตารางที่ 3 แสดงการประเมินประสิทธิภาพของแบบจำลอง LSTM ในการพยากรณ์ความเข้มรังสีอาทิตย์ สำหรับช่วงเวลาล่วงหน้า 1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง โดยพิจารณาจากค่า PCC nMBE และ nRMSE พบว่าสำหรับการพยากรณ์ล่วงหน้า 1 ชั่วโมง ค่า PCC มีค่าสูงถึง 0.82 ซึ่งแสดงให้เห็นถึงความสัมพันธ์เชิงเส้นที่ดีและความสอดคล้องกับข้อมูลการวัดจริงอย่างมาก อย่างไรก็ตามค่า PCC มีแนวโน้มลดลงอย่างต่อเนื่องเมื่อช่วงเวลาการพยากรณ์ล่วงหน้าเพิ่มขึ้น ในส่วนของ nMBE พบว่ามีค่า 0.12% สำหรับการพยากรณ์ล่วงหน้า 1 ชั่วโมง ซึ่งหมายถึงโดยรวมแล้วค่าที่พยากรณ์ได้มากกว่าค่าจากการวัดจริงเพียงเล็กน้อย แต่ค่า nMBE มีแนวโน้มเพิ่มขึ้นเล็กน้อยเป็น 2.04% เมื่อพยากรณ์ล่วงหน้า 24 ชั่วโมง บ่งชี้ถึงการเกิดความเอนเอียงเพียงเล็กน้อยในระยะยาว สำหรับ nRMSE ค่าเริ่มต้นที่ 20.92% สำหรับการพยากรณ์ 1 ชั่วโมงล่วงหน้า และเพิ่มขึ้นอย่างชัดเจนเป็น 31.10% สำหรับการพยากรณ์ล่วงหน้า 24 ชั่วโมง การเพิ่มขึ้นของ nRMSE นี้สะท้อนให้เห็นว่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์สูงขึ้นเมื่อคาดการณ์ในระยะเวลาที่ไกลออกไป ซึ่งเป็นลักษณะที่คาดการณ์ได้จากแบบจำลอง LSTM ของงานวิจัย

สำหรับผลการเปรียบเทียบค่าความเข้มรังสีอาทิตย์ที่ได้จากการพยากรณ์และจากการวัดจริงในรูปแบบกราฟอนุกรมเวลา (Time series) และแบบกราฟกระจาย (Scatter) แสดงดังรูปที่ 4 และ 5 ตามลำดับ รูปที่ 4 แสดงผลการพยากรณ์ความเข้มรังสีอาทิตย์ด้วยแบบจำลอง LSTM เปรียบเทียบกับค่าการวัดจริง สำหรับช่วงเวลาล่วงหน้า 1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง ณ สถานีนครปฐม ตลอดปี ค.ศ. 2023 โดยภาพรวมสำหรับการพยากรณ์ล่วงหน้า 1 ชั่วโมง ค่าพยากรณ์แสดงความใกล้เคียงและสอดคล้องกับค่าวัดจริงอย่างมีนัยสำคัญ โดยเฉพาะอย่างยิ่งในช่วงที่ค่า GHI สูง อย่างไรก็ตามเมื่อช่วงเวลาพยากรณ์เพิ่มขึ้น การเบี่ยงเบนระหว่างค่าพยากรณ์และค่าวัดจริงมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง ซึ่งบ่งชี้ถึงความแม่นยำที่ลดลง โดยเฉพาะในวันที่ค่า GHI มีความผันผวนสูง เช่น วันที่มีเมฆปกคลุมท้องฟ้าบางส่วน การเบี่ยงเบนนี้จะชัดเจนที่สุดในการพยากรณ์ล่วงหน้า 24 ชั่วโมง ซึ่งแบบจำลองยังคงสามารถจับแนวโน้มหลักได้ แต่มีความสามารถลดลงในการพยากรณ์การเปลี่ยนแปลงที่รวดเร็วหรือความผันผวนรายวันได้อย่างแม่นยำเท่าช่วงเวลาสั้นกว่าสำหรับกราฟกระจายดังแสดงในรูปที่ 5 แสดงการเปรียบเทียบค่า GHI ที่พยากรณ์ด้วยแบบจำลอง LSTM กับค่าที่วัดได้จริง ณ สถานีนครปฐม สำหรับช่วงเวลาพยากรณ์ล่วงหน้าที่แตกต่างกัน (1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง) สำหรับการพยากรณ์ล่วงหน้า 1 ชั่วโมง จุดข้อมูลส่วนใหญ่จะกระจุกตัวอยู่ใกล้เส้นอ้างอิง $y=x$ อย่างชัดเจนและมีการกระจายตัวแคบซึ่งบ่งชี้ถึงความแม่นยำในการพยากรณ์ที่สูง โดยมีค่า PCC อยู่ที่ 0.82 และค่า nRMSE ที่ 20.92% ซึ่งสอดคล้องกับผลในตารางที่ 3 อย่างไรก็ตามเมื่อช่วงเวลาพยากรณ์ล่วงหน้าเพิ่มขึ้นจุดข้อมูลจะเริ่มกระจายตัวออกห่างจากเส้นอ้างอิงมากขึ้นอย่างต่อเนื่อง และความหนาแน่น

ของจุดข้อมูลที่อยู่ที่ใกล้เส้นจะลดลงโดยเฉพาะอย่างยิ่งในการพยากรณ์ล่วงหน้า 24 ชั่วโมง การกระจายตัวของจุดข้อมูลจะกว้างขึ้นอย่างเห็นได้ชัดเมื่อเทียบกับช่วงเวลาที่ยาวนานกว่า ซึ่งแสดงให้เห็นถึงความแม่นยำที่ลดลงและข้อผิดพลาดที่สูงขึ้น โดยค่า PCC ลดลงเหลือ 0.62 และ nRMSE เพิ่มขึ้นเป็น 31.10% ผลที่ได้นี้แสดงถึงความสามารถที่ลดลงของแบบจำลองในการพยากรณ์การเปลี่ยนแปลงที่รวดเร็วหรือความผันผวนรายวันได้อย่างแม่นยำในระยะเวลาที่ยาวนานขึ้นโดยเฉพาะในวันที่ค่า GHI มีความผันผวนสูง เช่น มีเมฆมาก กราฟกระจายเหล่านี้จึงเป็นเครื่องมือสำคัญที่ช่วยให้เห็นภาพรวมของความสอดคล้องและแนวโน้มของความคลาดเคลื่อนของการพยากรณ์เมื่อเทียบกับค่าวัดจริงได้อย่างชัดเจน

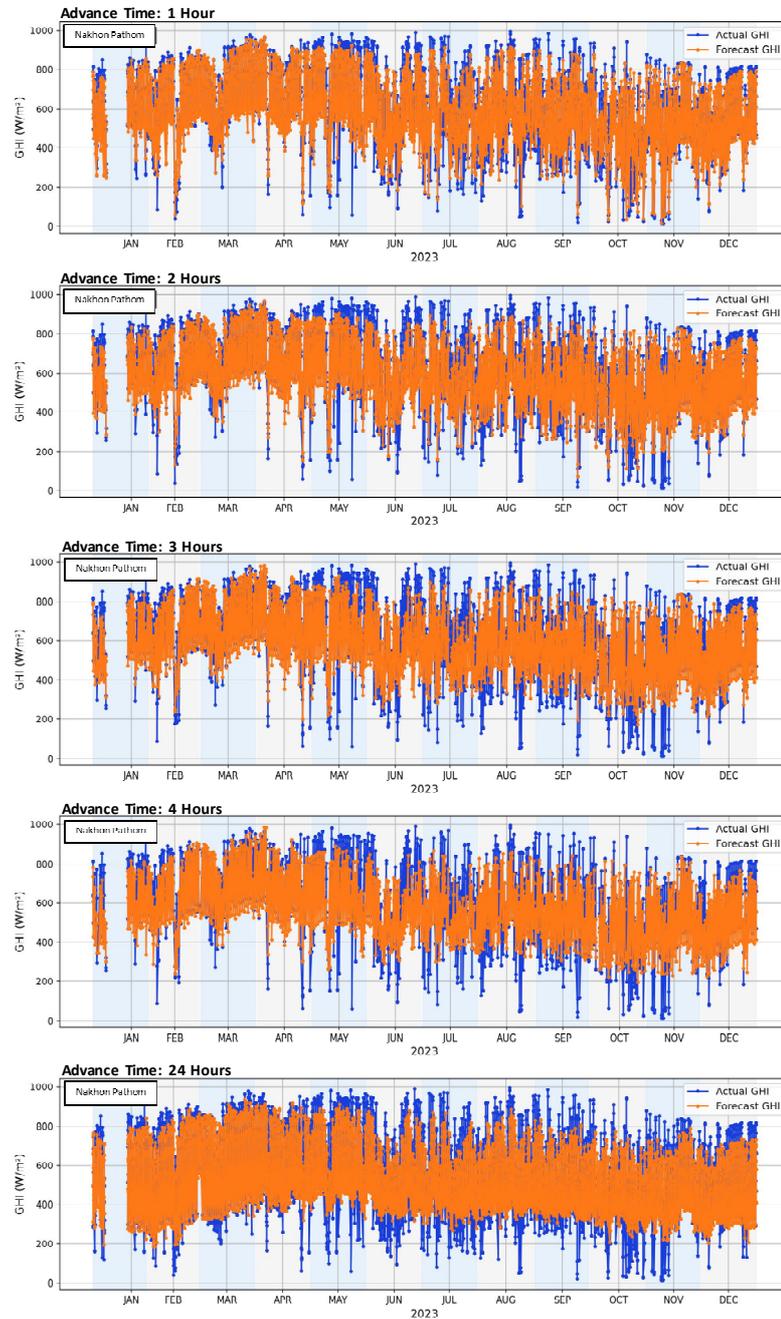


Figure 4 Time series of solar radiation forecasting at 1 hour 2 hours 3 hours 4 hours and 24 hours ahead obtained from the LSTM model and solar radiation from the measurement at Nakhon Pathom site

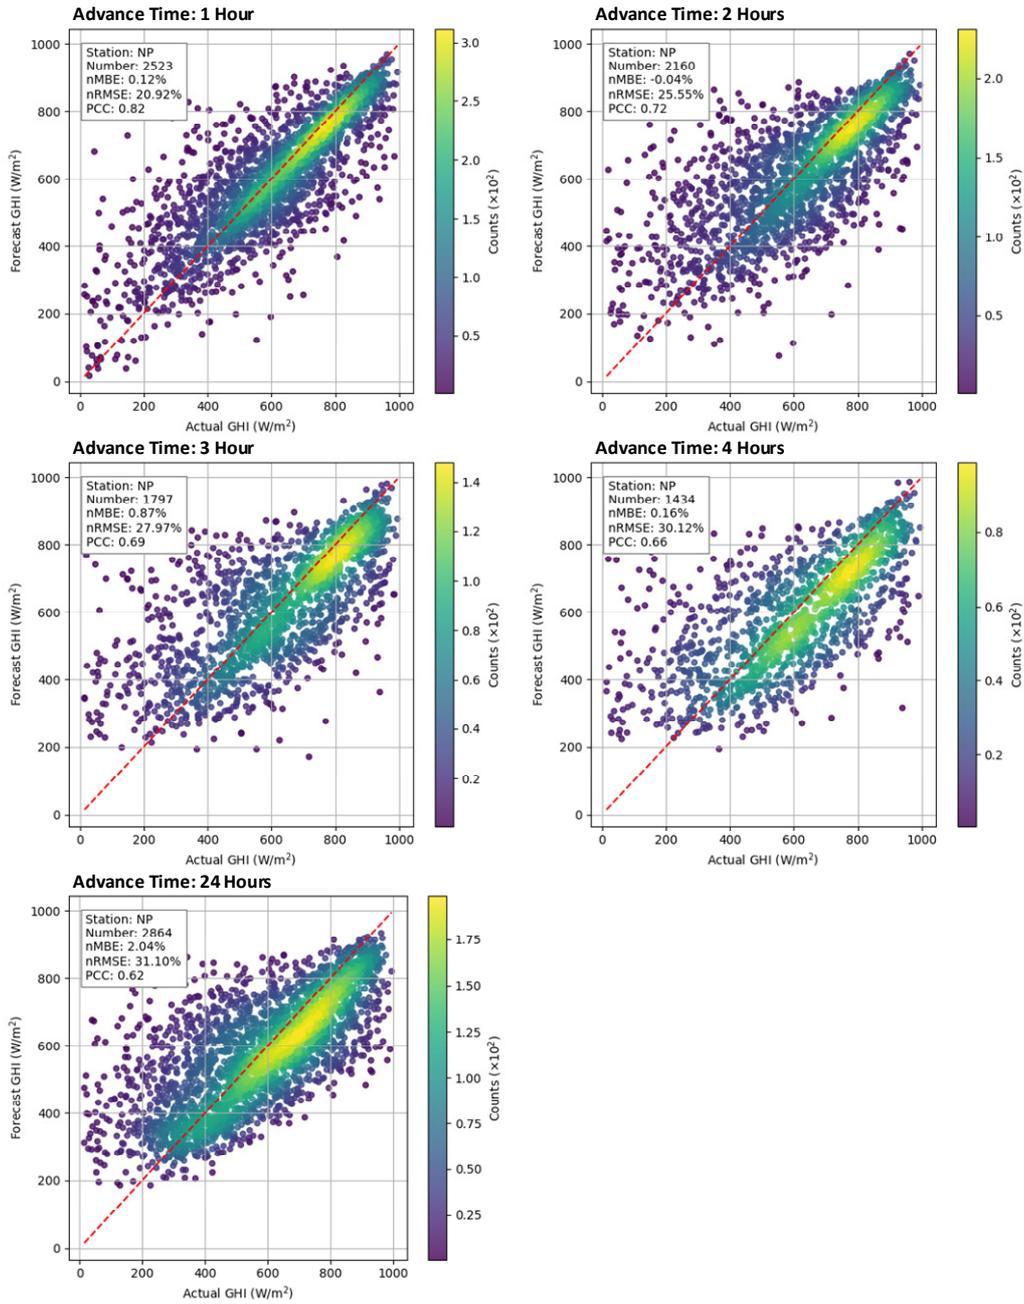


Figure 5 Scatter plots between solar radiation forecasted from the LSTM model and measured from the ground-based instrument

อภิปรายและสรุปผลการวิจัย

งานวิจัยนี้ทำการพัฒนาแบบจำลองการเรียนรู้ของเครื่องแบบ LSTM สำหรับพยากรณ์ความเข้มรังสีอาทิตย์ล่วงหน้า 1 ชั่วโมง 2 ชั่วโมง 3 ชั่วโมง 4 ชั่วโมง และ 24 ชั่วโมง ที่สถานีนครปฐม โดยข้อมูลอินพุตประกอบด้วย ความเข้มรังสีอาทิตย์ ข้อมูลปริมาณเมฆระดับสูง ปริมาณเมฆระดับกลาง ปริมาณเมฆระดับต่ำ ปริมาณไอน้ำในคอลัมน์บรรยากาศ ปริมาณโอโซนในคอลัมน์บรรยากาศ ความเข้มรังสีอาทิตย์นอกบรรยากาศโลก เวลา และลำดับวันในรอบปี ในการฝึกสอนแบบจำลอง LSTM พบว่าโครงสร้างที่เหมาะสมเป็นแบบ 1 ชั้น ซึ่งให้ผลดีกว่าแบบ 2 ชั้น 3 ชั้น และ 4 ชั้น โดยมีค่าจำนวน Node เท่ากับ 30 ค่า Dropout rate เท่ากับ 0 และค่า Epoch เท่ากับ 360 ผลจากการทดสอบประสิทธิภาพของแบบจำลองพบว่าแบบจำลอง LSTM ที่พัฒนาขึ้นนี้สามารถพยากรณ์ความเข้มรังสีอาทิตย์ได้ดีที่สุดล่วงหน้า 1 ชั่วโมง โดยมีค่าความคลาดเคลื่อนเมื่อเทียบกับข้อมูลที่ได้จากการวัดภาคพื้นดินในรูปของค่า nRMSE เท่ากับ 20.92% และ nMBE เท่ากับ 0.12% ซึ่งค่าความคลาดเคลื่อนนี้ต่ำกว่าค่าที่ได้จากการพยากรณ์ความเข้มรังสีรวมของ Chawphongphang et al. [13] ที่ใช้แบบจำลอง ANN ซึ่งได้ค่า nRMSE สูงสุดเท่ากับ 26.20% ในการพัฒนาแบบจำลองให้มีประสิทธิภาพสูงขึ้นอาจทำได้โดยการพิจารณาวิเคราะห์ตัวแปรอินพุตที่ส่งผลต่อความเข้มรังสีอาทิตย์ทั้งทางตรงและทางอ้อมเพิ่มเติม และการเพิ่มจำนวนข้อมูลสำหรับใช้ในการฝึกสอนเพื่อให้แบบจำลองเรียนรู้ได้อย่างมีประสิทธิภาพมากขึ้น

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนอุดหนุนการวิจัยเพื่อผลิตผลงานวิจัยตีพิมพ์ในวารสารวิชาการจากกองทุนสนับสนุนการวิจัยนวัตกรรมและการสร้างสรรค์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร สัญญาเลขที่ SRIF-JRG-2567-11 ซึ่งผู้วิจัยขอขอบพระคุณไว้ ณ โอกาสนี้

References

- [1] Dhaked, D. K., et al. (2023). Power Output Forecasting of Solar Photovoltaic Plant Using LSTM. *Green Energy and Intelligent Transportation*, 2(5), 100113.
- [2] El Alani, O., et al. (2021). Short Term Solar Irradiance Forecasting Using Sky Images Based on a Hybrid CNN-MLP Model. *Energy Reports*, 7, 888-900.
- [3] Nadeem, T. B., et al. (2024). Forecasting Daily Solar Radiation: An Evaluation and Comparison of Machine Learning Algorithms. *AIP Advances*, 14(7), 075010.
- [4] Bristow, K. (1984). On the Relationship Between Incoming Solar Radiation and Daily Maximum and Minimum Temperature. *Agricultural and Forest Meteorology*, 30, 159-166.
- [5] Besharat, F., et al. (2013). Empirical Models for Estimating Global Solar Radiation: A Review and Case Study, *Renewable and Sustainable Energy Reviews*, 21, 798-821
- [6] Voyant, C., et al. (2017). Machine Learning Methods for Solar Radiation Forecasting: A Review. *Renewable Energy*, 105, 569-582.
- [7] Shouman, E. R. M. (2024). Solar Power Prediction with Artificial Intelligence. In Abdelaziz, A. Y., et al. (Eds.). *Advances in Solar Photovoltaic Energy Systems* (p. 1-28). InTechOpen.

doi: 10.5772/intechopen.1002726.

- [8] Vanlalchuanawmi, C., et al. (2025). Solar Radiation Prediction: A Multi-Model Machine Learning and Deep Learning Approach. *AIP Advances*, 15, 055201.
- [9] Premalatha, N. & Arasu, A. V. (2016). Prediction of Solar Radiation for Solar Systems by Using ANN Models with Different Back Propagation Algorithms. *Journal of Applied Research and Technology*, 14(3), 206–214.
- [10] Rajagukguk, R. A., et al. (2020). A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power. *Energies*, 13(24), 6623.
- [11] Hou, X., et al. (2023). Prediction of Solar Irradiance Using Convolutional Neural Network and Attention Mechanism-Based Long Short-Term Memory Network Based on Similar Day Analysis and an Attention Mechanism. *Heliyon*, 9(11), e21484.
- [12] Warunsin, K., et al. (2023). Human Activity Recognition Using Long Short-Term Memory Network. *International Journal of Innovative Computing, Information and Control*, 19(3), 973–990.
- [13] Chawphongphang, N., et al. (2022). Global and Diffuse Solar Radiation Characteristics of Bangkok and its Forecast Using Artificial Neural Network, *International Energy Journal*, 22, 339-356.
- [14] Iqbal, M. (1983). *An Introduction to Solar Radiation*. New York: Academic Press.