

รายงานโครงการวิศวกรรมไฟฟ้า วิชา 2102499

การพยากรณ์กำลังไฟฟ้าแสงอาทิตย์ภายในวัน
ด้วยการใช้ภาพถ่ายเมฆจากดาวเทียมฮิมาวาริ

Intra-day solar power forecasting using cloud images
from Himawari satellite

นายณฐนนท โตงามรักษ์ เลขประจำตัวนิสิต 6232007121
นายณัฐพล เดชตระกูลวงศ์ เลขประจำตัวนิสิต 6232011621
อาจารย์ที่ปรึกษา รศ.ดร. จิตโกมุท ส่งศิริ

ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์
จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2565

ลงชื่ออาจารย์ที่ปรึกษาหลัก

.....

(รศ.ดร. จิตโกมุท ส่งศิริ)

วันที่

บทคัดย่อ

การพยากรณ์กำลังไฟฟ้าแสงอาทิตย์มีส่วนสำคัญในการดูแลเสถียรภาพของโครงข่ายไฟฟ้าให้มีความมั่นคง โครงการนี้มีจุดประสงค์เพื่อพัฒนาแบบจำลองพยากรณ์ความเข้มแสงอาทิตย์ซึ่งเป็นตัวแปรหลักที่ส่งผลต่อกำลังไฟฟ้าที่ผลิตได้ในระยะการพยากรณ์ล่วงหน้า 4 ชั่วโมง ปัจจัยหนึ่งส่งผลต่อความผันผวนของความเข้มแสงอาทิตย์ในพื้นที่คือปริมาณเมฆโดยรอบ โครงการนี้จะเปรียบเทียบประสิทธิภาพของค่าประมาณดัชนีเมฆที่สกัดจากภาพถ่ายดาวเทียมฮิมาวาริ-8 ด้วยวิธีที่แตกต่างกัน ได้แก่ การคำนวณเวกเตอร์ความเร็วเมฆจากวิธีเทียบบล็อกและวิธีการไหลของแสง แล้วนำไปฝึกสอนแบบจำลองการเรียนรู้ด้วยเครื่องร่วมกับข้อมูลนำเข้าอื่น จากนั้นเปรียบเทียบแบบจำลองที่สกัดความสัมพันธ์เชิงพื้นที่และเวลาของข้อมูลภาพถ่ายเมฆด้วยการทำสังวัตนาการ ได้แก่ แบบจำลองโครงข่ายประสาทเทียมแบบสังวัตนาการในสามมิติ (3D-CNN) และแบบจำลอง CNN-LSTM การทดลองใช้ชุดข้อมูลของบริษัท Impact solar ที่มีข้อมูลวัดความเข้มแสงอาทิตย์ 56 สถานีและข้อมูลภาพถ่ายเมฆจากดาวเทียมฮิมาวาริ-8 ตั้งแต่วันที่ 5 กุมภาพันธ์ พ.ศ. 2565 ถึง 28 กุมภาพันธ์ พ.ศ. 2566 ผลการทดลองพบว่า การสกัดคุณลักษณะด้วยวิธี Horn-Schunck มีประสิทธิภาพการประมาณดัชนีเมฆในอนาคตได้ดีกว่าวิธีเทียบบล็อก เมื่อเปรียบเทียบสมรรถนะการพยากรณ์ความเข้มที่ระยะ 30 นาทีล่วงหน้าพบว่าแบบจำลอง CNN-LSTM มีสมรรถนะดีที่สุดด้วย NRMSE เท่ากับ 25.17 % แต่สำหรับระยะการพยากรณ์ 4 ชั่วโมงล่วงหน้า แบบจำลองที่มีสมรรถนะดีที่สุดคือแบบจำลองแบบป่าสุ่มด้วย NRMSE เท่ากับ 40.15 % แล้วจึงพัฒนาแบบจำลองแปลงความเข้มแสงอาทิตย์เป็นกำลังไฟฟ้าในแต่ละสถานีทดลอง การพยากรณ์กำลังไฟฟ้าจะใช้ข้อมูลนำเข้าในชุดทดสอบคือค่าพยากรณ์ความเข้มแสงอาทิตย์ และมีสมรรถนะการพยากรณ์ของแบบจำลองถดถอยเชิงเส้นวัดด้วยค่า NRMSE เท่ากับ 22.75 %

คำสำคัญ: การพยากรณ์ความเข้มแสงอาทิตย์, การไหลของแสง, วิธีเทียบบล็อก, แบบจำลองการเรียนรู้ด้วยเครื่อง, แบบจำลองโครงข่ายประสาทเทียมแบบสังวัตนาการ

Abstract

Solar power forecasting plays an important role in maintaining the grid stability. This project aims to develop an irradiance forecasting model, which is the main factor affecting the generating power, at 4 hours ahead. The factor that causes a variability of irradiance is the surrounding cloud. The study compares the performance of estimated cloud index that extracts from Himawari-8 satellite imagery with different methods including block-matching method and optical flow method, then train the model along with other inputs. We compare with models that can extract a spatial and temporal relation of cloud image by convolution including 3D-CNN model and CNN-LSTM model. The experiment was conducted on a dataset from Impact solar company containing 56 sites' irradiance measurement and cloud images from Himawari-8 satellite between February 5, 2022 and February 28, 2023. The results indicate that cloud extraction from Horn-Schunck method is more effective in estimating cloud index than the block-matching method. The CNN-LSTM model showed the best performance of forecasting at 30 minutes ahead with an NRMSE of 25.17%, while the random forest model showed the best performance at four hours ahead with an NRMSE of 40.15%. The forecasted irradiance was then used as a test dataset for predicting solar power. It was found that the linear regression model yielded the performance of forecasting with NRMSE of 22.75%.

Keywords: irradiance forecasting, optical flow, block matching, machine learning, convolutional neural network model

สารบัญ

1	บทนำ	6
1.1	ที่มาและความสำคัญของโครงการ	6
1.2	วัตถุประสงค์ของโครงการ	8
1.3	ขอบเขตของโครงการ	8
1.4	ผลลัพธ์ที่คาดหวังของโครงการ	8
2	หลักการและทฤษฎีที่เกี่ยวข้อง	8
2.1	การพยากรณ์ความเข้มแสงอาทิตย์	8
2.2	แบบจำลองทอ้งฟ้าใส	9
2.3	เวกเตอร์ความเร็วเมฆ	10
2.3.1	วิธีเทียบบล็อก	10
2.3.2	วิธีการไหลของแสง	10
2.4	การประมาณความเข้มที่พิกเซลย่อย	11
2.5	แบบจำลองการทำนาย	12
2.5.1	แบบจำลอง Seasonal autoregressive integrated moving average with exogenous factors	12
2.5.2	แบบจำลอง Linear regression	13
2.5.3	แบบจำลอง Polynomial regression	13
2.5.4	แบบจำลอง Random forest	13
2.5.5	แบบจำลอง Support vector regression	13
2.5.6	แบบจำลอง Gradient boosting tree	14
2.5.7	แบบจำลอง Convolutional neural networks	15
2.6	สมรรถนะของแบบจำลอง	16
3	ระเบียบวิธี	16
3.1	รายละเอียดชุดข้อมูล	16
3.2	การจัดเตรียมข้อมูล	17
3.3	การแบ่งข้อมูลในการพัฒนาแบบจำลอง	18
3.4	ขั้นตอนการประมาณและเลือกแบบจำลอง	18
4	ผลลัพธ์การดำเนินการ	19
4.1	ผลการสกัดดัชนีเมฆ	19
4.2	ผลลัพธ์การพยากรณ์ความเข้มแสงอาทิตย์	21
4.3	ผลลัพธ์การพยากรณ์กำลังไฟฟ้าแสงอาทิตย์	28
5	บทสรุป	29
6	กิตติกรรมประกาศ	30
	เอกสารอ้างอิง	30
7	ภาคผนวก	32
7.1	การสกัดปริมาณเมฆที่ส่งผลกับตำแหน่งที่สนใจ	32
7.2	ปัญหาการหาค่าเหมาะสมสุดใน Horn-Schunck	34
7.3	การปรับ hyperparameters หรืออันดับของแบบจำลอง	35
7.3.1	แบบจำลอง SARIMAX	35
7.3.2	แบบจำลอง Random forest	35

7.3.3	แบบจำลอง Support vector regression	36
7.3.4	แบบจำลอง LightGBM	37
7.3.5	แบบจำลอง ANN	38

สารบัญรูป

1	การพยากรณ์ความเข้มแสงอาทิตย์ในระยะ 30, 60, ..., 240 นาทีล่วงหน้า	6
2	ภาพรวมโครงสร้างแบบจำลองต่าง ๆ ที่พิจารณาในโครงการ	8
3	ความเข้มแสงอาทิตย์ในสภาวะฟ้าใส	9
4	การเทียบบล็อกโดยค้นหาทั้งโดเมนและค้นหาโดเมนย่อยด้วยกล่องขนาด 2×2	10
5	การประมาณค่าความเข้มฟลักเซลจากการเฉลี่ยแบบถ่วงน้ำหนักของฟลักเซลโดยรอบ	12
6	ปัญหาตั้งต้นของ ϵ -SVR	14
7	แผนผังความสัมพันธ์ของตัวแปรภายในแบบจำลอง CNN-LSTM [GCM+22]	15
8	ตัวอย่างภาพจาก Cloud mask, Overview R channel และ RGB ตามลำดับ	17
9	ตัวอย่างภาพถ่ายที่ไม่สามารถนำมาใช้ในการทดลองได้	17
10	ความผิดพลาดในการวัดข้อมูลความเข้มแสงอาทิตย์จากตัวรับรู้ บริษัท Impact solar	18
11	ตัวอย่างการสกัด CMV จากภาพถ่ายเมฆที่ลำดับติดกัน	19
12	ตัวอย่างการพยากรณ์ภาพถ่ายเมฆ Overview R channel ในระยะ 1, 2, 3 และ 4 ชั่วโมงล่วงหน้าของเวลาเริ่มต้น ณ วันที่ 11 พฤศจิกายน พ.ศ. 2565 เวลา 12:40 (UTC+7)	20
13	ผลลัพธ์การปรับ hyperparameter ของแต่ละวิธีในการคำนวณ CMV	20
14	ผลการเปรียบเทียบสมรรถนะแต่ละ hyperparameter ของวิธีเทียบบล็อกและวิธี Horn-Schunck ที่ระยะ 30 นาทีล่วงหน้า	21
15	ความสัมพันธ์ระหว่างค่าดัชนีเมฆที่ผ่านการประมาณ เทียบกับดัชนีเมฆจริงที่เวลา 30 นาทีข้างหน้าของตัวอย่างสถานีที่ 7 และ 48 ด้วยวิธี Horn-Schunck จากช่อง Overview R channel	21
16	การเปรียบเทียบลำดับความสำคัญของตัวแปรเพื่อบรรยาย I ด้วยกราฟแลสโซ	22
17	ตัวอย่างการพยากรณ์ล่วงหน้า 30 นาทีด้วยแบบจำลอง SARIMAX	22
18	แผนผังตัวแปรขาเข้าและตัวแปรขาออกสำหรับแบบจำลองพยากรณ์ความเข้มแสงอาทิตย์	23
19	แผนผังตัวแปรขาเข้าและตัวแปรขาออกสำหรับแบบจำลองการเรียนรู้เชิงลึก	24
20	MAE รายชั่วโมงในระยะพยากรณ์ 30 นาทีล่วงหน้า ของแบบจำลอง SVR, LightGBM, ANN และ CNN-LSTM	25
21	ตัวอย่างการพยากรณ์ระยะ 30 นาทีล่วงหน้าในวันที่ประมาณได้ดีและไม่ดีของแบบจำลอง SVR	26
22	ตัวอย่างการพยากรณ์ด้วยแบบจำลอง SVR, LightGBM, ANN และ CNN-LSTM ในระยะพยากรณ์ล่วงหน้า 30 นาที ในวันที่สภาพอากาศดี, กลางและแย่ ตามลำดับ	26
23	ความสัมพันธ์ระหว่างค่าพยากรณ์แสงอาทิตย์ และค่าความเข้มแสงอาทิตย์ที่วัดได้จริงของทุกแบบจำลองในแต่ละระยะการพยากรณ์ โดยเส้นคอนทัวร์ประมาณมาจากวิธี KDE	27
24	สมรรถนะแบบจำลองในทุกระยะพยากรณ์	27
25	ความสัมพันธ์ระหว่างความเข้มแสงอาทิตย์เทียบกับกำลังการผลิตไฟฟ้าของสถานีที่ 48 และ 2	29
26	เงื่อนไขความเร็วเริ่มต้นที่ทำให้ $t_c \geq 0$ และตัวอย่างค่า t_c ในแต่ละกรณี	32
27	กระบวนการหาค่าดัชนีเมฆที่ส่งผลต่อตำแหน่งที่สนใจในเวลา k ชั้นล่วงหน้า	33
28	ผลการทดลองปรับค่า R ในการสกัดดัชนีเมฆด้วยวิธี candidate pixel	34
29	Autocorrelation function และ Partial autocorrelation function ของความเข้มแสงอาทิตย์	35

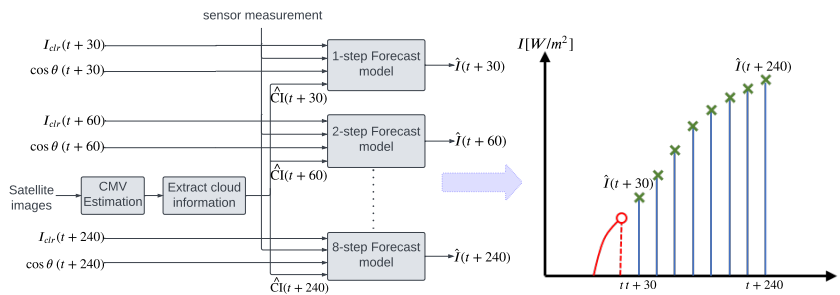
สารบัญตาราง

1	สัมประสิทธิ์จากการประมาณแบบจำลอง SARIMAX	21
2	ประสิทธิภาพการพยากรณ์ของแบบจำลอง SARIMAX	22
3	MAE ของการพยากรณ์ความเข้มแสงอาทิตย์พิจารณาในแต่ละจุดเวลาของค่าพยากรณ์ สำหรับระยะเวลาพยากรณ์ล่วงหน้า 30 นาที ของทุกแบบจำลอง	24
4	MAE ของทุกแบบจำลองในแต่ละระยะเวลาพยากรณ์ล่วงหน้า	28
5	NRMSE ของทุกแบบจำลองในแต่ละระยะเวลาพยากรณ์ล่วงหน้า	28
6	ผลการเปรียบเทียบ NRMSE ในการทำนายกำลังไฟฟ้าแสงอาทิตย์ของแบบจำลองต่าง ๆ	28
7	ผลการปรับอันดับของแบบจำลอง SARIMAX	35
8	ผลการปรับ hyperparameters แบบจำลอง Random forest	36
9	ผลการปรับ hyperparameters แบบจำลอง SVR	37
10	ผลการปรับ hyperparameters แบบจำลอง LightGBM	38
11	ผลการปรับโครงสร้างแบบจำลอง ANN	39

1 บทนำ

1.1 ที่มาและความสำคัญของโครงการ

ปัจจุบันพบว่ามีสัดส่วนการใช้พลังงานทดแทนมากขึ้นในระบบโครงข่ายไฟฟ้าของประเทศต่าง ๆ ทั่วโลก พลังงานแสงอาทิตย์เป็นหนึ่งในพลังงานที่เริ่มเข้ามามีบทบาทอันเนื่องจากแนวโน้มต้นทุนการติดตั้งที่ต่ำลง อย่างไรก็ตาม การรวมเข้ากันกับระบบโครงข่ายไฟฟ้าของพลังงานแสงอาทิตย์ ต้องคำนึงถึงสมดุลระหว่างกำลังไฟฟ้าที่ใช้และกำลังไฟฟ้าที่ผลิตได้ในระบบ พลังงานแสงอาทิตย์มีความไม่แน่นอนเนื่องมาจากความแปรปรวนของสภาพอากาศ เมื่อนำมารวมเข้าไปในระบบโครงข่ายอาจส่งผลกระทบต่อเสถียรภาพของระบบ ความเข้มแสงอาทิตย์ (I) เป็นตัวแปรหลักของปริมาณกำลังไฟฟ้าที่ผลิตได้ (P) หากสามารถประมาณศักยภาพหรือพยากรณ์ I แต่ละพื้นที่ในแต่ละช่วงเวลาได้ จะสามารถวางแผนและเตรียมพร้อมระบบโครงข่ายให้มีประสิทธิภาพการทำงานสูงสุด ระยะเวลาพยากรณ์หนึ่งที่มีส่วนช่วยในการบริหารจัดการวางแผนเดินเครื่องกำเนิดไฟฟ้าให้มีความคุ้มค่าทางเศรษฐศาสตร์คือ การพยากรณ์แบบภายในวัน (Intra-day) เป็นการพยากรณ์ระยะไม่เกิน 6 ชั่วโมง มีบริษัทต่าง ๆ ทั่วโลกที่มีบริการหรือผลิตภัณฑ์สำหรับการประมาณปริมาณแสงอาทิตย์ในช่วงเวลาต่าง ๆ เช่นบริษัท Reunivatt มีบริการประมาณ I ที่มีชื่อว่า SunSat™ โดยไม่ต้องติดตั้งตัวรับรู้ (sensor) บนภาคพื้น แต่จะใช้ภาพถ่ายจากดาวเทียมทางอุตุนิยมวิทยาที่มีวงโคจรแบบค้างฟ้า (geostationary satellite) ทั้ง 5 ดวง ได้แก่ Meteosat-10, Meteosat-8, GOES-E, GOES-W และ Himawari-8 ดาวเทียมทั้งห้าให้บริการภาพถ่ายได้ครอบคลุมพื้นที่ทั่วโลก รวมถึงยังมีบริการพยากรณ์ค่า I โดยการใช้ข้อมูลทางอุตุนิยมวิทยาร่วมกับภาพถ่ายเมฆในแต่ละระยะการพยากรณ์ล่วงหน้า หรือบริษัท Solar Anywhere ที่ใช้ข้อมูลพยากรณ์จากแบบจำลองทำนายอากาศเชิงเลข (Numerical weather prediction หรือ NWP) ร่วมกับข้อมูลภาพถ่ายเมฆสำหรับการสกัดเวกเตอร์ความเร็วเมฆ (Cloud motion vectors หรือ CMV) ช่วยในการพยากรณ์ปริมาณ I ภายในวันได้ โครงการนี้มีจุดประสงค์เพื่อพัฒนาแบบจำลองพยากรณ์ความเข้มแสงอาทิตย์ภายในวันด้วยการใช้คุณลักษณะที่สกัดจากข้อมูลภาพถ่ายเมฆร่วมกับข้อมูลภาพถ่ายเชิงพื้นที่ที่ระยะเวลาพยากรณ์ 240 นาทีล่วงหน้าดังรูปที่ 1



รูปที่ 1: การพยากรณ์ความเข้มแสงอาทิตย์ในระยะ 30, 60, ..., 240 นาทีล่วงหน้า

มีงานวิจัยมากมายที่มีจุดมุ่งหมายในการพยากรณ์ปริมาณ I โดยการใช้ภาพถ่ายเมฆ โดยทั่วไปนั้นจะต้องมีการติดตั้งตัวรับรู้ที่ภาคพื้นในการเก็บข้อมูล I ที่ระยะเวลาต่าง ๆ ซึ่งอาจมีไม่ครอบคลุมในทุกพื้นที่และมีต้นทุนในการติดตั้ง การใช้ข้อมูลภาพถ่ายจะมีข้อดีคือ หากสามารถพยากรณ์ได้ในหนึ่งพื้นที่ จะสามารถขยายขอบเขตพื้นที่การพยากรณ์ไปยังพื้นที่อื่นได้ง่าย ในช่วงแรกที่เริ่มมีการนำข้อมูลภาพถ่ายเมฆมาใช้ในการทดลอง ได้ใช้วิธีเทียบบล็อก (block-matching) เป็นวิธีในการวิเคราะห์การเคลื่อนที่ของเมฆในแต่ละพิกเซลจากการใช้ภาพถ่ายเมฆที่มีลำดับติดกันในการสร้างเวกเตอร์การเคลื่อนที่ของเมฆ ด้วยหลักการหาทิศทางที่ทำให้ผลรวมความต่างของความเข้มของพิกเซลโดยรอบของภาพในลำดับก่อนหน้ากับความเข้มโดยรอบในภาพลำดับถัดไปมีค่าต่ำสุด จากนั้นประมาณค่านอกช่วง (extrapolate) เวกเตอร์ที่ได้ในการพยากรณ์ภาพถ่ายเมฆที่ระยะเวลาพยากรณ์ล่วงหน้าต่าง ๆ และใช้แบบจำลอง Heliosat ในการแปลงค่าดัชนีเมฆในแต่ละพิกเซลเป็นปริมาณ I ที่ต้องการ [LHH04] วิธีเทียบบล็อกสำหรับการหา CMV นี้ยังปรากฏในอีกหลายงานวิจัย เช่น มีการเปรียบเทียบว่าการใช้ I ที่ได้มา

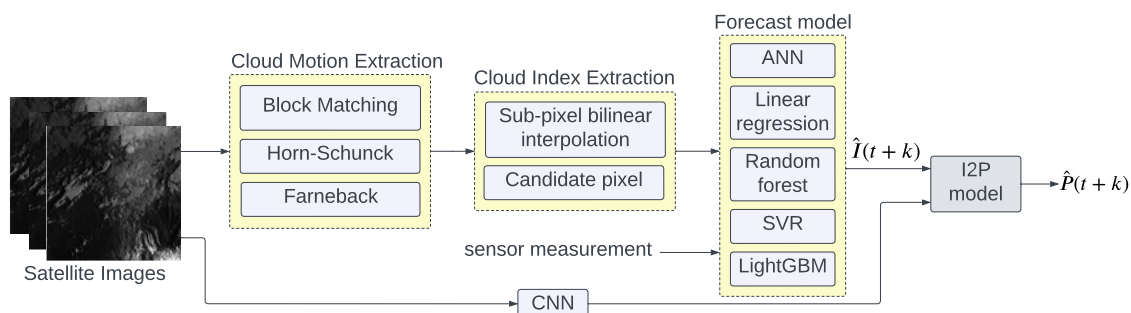
จาก CMV ให้ผลลัพธ์ที่ดีกว่าการใช้ค่า I จาก NWP เพื่อเป็นตัวแปรต้นสำหรับแบบจำลอง Support vector regression (SVR) ในการพยากรณ์ค่ากำลังไฟฟ้าที่ผลิตได้จากเซลล์แสงอาทิตย์ [CBSH20] หรือ ได้มีการใช้ CMV เปรียบเทียบผลลัพธ์การพยากรณ์กับการใช้ข้อมูล I จากดาวเทียมในอดีตของพื้นที่โดยรอบ (satellite-derived irradiance) ในการพยากรณ์ I 1 ชั่วโมงข้างหน้าเป็นต้น [APS+19]

อีกเทคนิคของการวิเคราะห์การเคลื่อนที่ของเมฆที่ได้รับความนิยมคือ การไหลของแสง (Optical flow) เป็นการประมวลผลภาพที่ใช้สำหรับติดตามการเคลื่อนที่ของวัตถุในภาพหรือวิดีโอ และสามารถใช้ในการหา CMV ของภาพถ่ายเมฆได้ดีอีกด้วย เมื่อเปรียบเทียบการใช้การไหลของแสงที่มีเงื่อนไขบังคับที่ต่างกัน 4 เงื่อนไข ได้แก่ Horn-Schunck [HS81], Lucas-Kanade [LK81], Farneback [Far03] และ TVL1 [BGLC12] รวมไปถึงถึงวิธีเทียบบล็อก [LHH04] จากการวิเคราะห์พบว่าการใช้การไหลของแสงที่ใช้เงื่อนไข TVL1 ให้ผลลัพธ์การพยากรณ์ที่ดีที่สุดสำหรับการพยากรณ์ภายในวัน [AMAS22] หรือมีงานวิจัยที่ได้มีการปรับปรุงสมการการไหลของแสง โดยคำนึงถึงความต่อเนื่องของความสว่างภายในภาพผ่านการใช้ฟังก์ชันแกร่ง (robust function) [CBK15] อีกทั้งยังมีงานวิจัยที่ประยุกต์ใช้การประมาณ CMV ด้วยเทคนิคการไหลของแสง วิธี Horn-Schunck [HS81] ในงานพยากรณ์ความเข้มแสงอาทิตย์เชิงความน่าจะเป็น (Probabilistic solar forecasting) อีกด้วย [CeSZ+21]

นอกเหนือจากการวิเคราะห์การเคลื่อนที่ของเมฆที่จะส่งผลต่อ I ณ ตำแหน่งที่สนใจด้วยการคำนวณ CMV แล้ว ยังได้มีการใช้แบบจำลองการเรียนรู้เชิงลึก (Deep learning) ที่มีข้อมูลนำเข้าเป็นลำดับของภาพถ่ายเมฆที่ติดกัน เช่น การใช้ข้อมูลค่า I ในอดีตร่วมกับความเข้มแสงอาทิตย์ในสภาวะท้องฟ้าใส (Clear-sky irradiance) ร่วมกับภาพถ่ายเมฆเป็นข้อมูลนำเข้าของแบบจำลองโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural network หรือ CNN) ในการพยากรณ์ความเข้มแสงอาทิตย์ภายในวัน [PPSTB21] การใช้ข้อมูลภาพถ่ายท้องฟ้าที่เป็นลำดับในการพยากรณ์ความเข้มแสงอาทิตย์ภายในชั่วโมง (Intra-hour) โดยประยุกต์ใช้เทคนิค CNN เทียบระหว่าง CNN แบบ 2 มิติ (2D-CNN) กับ CNN แบบ 3 มิติ (3D-CNN) ที่พิจารณาทั้งความสัมพันธ์เชิงพื้นที่และเชิงเวลาของข้อมูล พบว่า 2D-CNN ให้ประสิทธิภาพการพยากรณ์ที่ดีในด้านต้นทุนการคำนวณที่ต่ำกว่า [ZQJ+22] อีกทั้งยังมีงานวิจัยที่สกัดคุณลักษณะโดยเริ่มต้นจากสมมติฐานของสมการการไหลของแสง ผ่านวิธีเรียนรู้เชิงกราฟ สำหรับเป็นข้อมูลนำเข้าในแบบจำลองการเรียนรู้เชิงลึกพร้อมกับข้อมูลกำลังไฟฟ้าที่ผลิตได้ในอดีตและความเข้มแสงอาทิตย์ในสภาวะท้องฟ้าใสในการพัฒนาแบบจำลองพยากรณ์กำลังไฟฟ้าภายในชั่วโมงเป็นต้น [CZW+22], SolarNet [FZ20] ได้มีการใช้ภาพถ่ายท้องฟ้า TSI (Total sky imager) จากชุดข้อมูลของ solar radiation laboratory (SRRL) ในการพัฒนาแบบจำลองในการพยากรณ์ I ที่ระยะการพยากรณ์ล่วงหน้า 1 ชั่วโมง เมื่อใช้แบบจำลอง CNN โครงสร้าง Visual Geometry Group (VGG16) ที่มี pre-trained weight จาก ImageNet โดยผลลัพธ์เมื่อเทียบสมรรถภาพกับแบบจำลองการเรียนรู้ด้วยเครื่องที่ใช้คุณลักษณะเชิงตัวเลข ได้แก่แบบจำลอง ANNs, Gradient boosting machine (GBM) และ Random forest พบว่า SolarNet มีประสิทธิภาพดีกว่ากลุ่มแบบจำลองดังกล่าว โดยมี NRMSE เท่ากับ 8.85% และ NMBE เท่ากับ 0.35% ที่ระยะการพยากรณ์ล่วงหน้า 1 ชั่วโมง รวมไปถึงได้มีการเสนอแบบจำลอง IrradianceNet [NIK21] ที่ใช้ชุดข้อมูล Surface Radiation Data Set - Heliosat (SARAH) 2.1 ซึ่งสกัด effective cloud albedo จากภาพถ่ายเมฆ เป็นตัวทำนายร่วมกับข้อมูลตำแหน่งลองจิจูด-ละติจูดของค่าวัด, ข้อมูลเกี่ยวกับเวลา-ฤดูกาล ในการพยากรณ์ความเข้มแสงอาทิตย์ระยะ 4 ชั่วโมงล่วงหน้า ผ่านแบบจำลอง CNN-LSTM พบว่า ค่าพยากรณ์ความเข้มแสงอาทิตย์จาก IrradianceNet มีสมรรถภาพที่ดีกว่าค่าพยากรณ์ที่ใช้ CMV จาก TVL1 โดยมี MAE = 101.92 W/m² ที่ระยะการพยากรณ์ล่วงหน้า 4 ชั่วโมง

จากข้อมูลที่ได้ศึกษามาในข้างต้นจะเห็นได้ว่าการสกัดเวกเตอร์ความเร็วเมฆจากภาพถ่ายเมฆด้วยเทคนิคต่าง ๆ หรือการวิเคราะห์การเคลื่อนที่ของเมฆโดยใช้กลุ่มแบบจำลองการเรียนรู้เชิงลึก เป็นวิธีที่ได้รับความนิยมอย่างแพร่หลายในงานพยากรณ์ความเข้มแสงอาทิตย์ภายในวัน และด้วยเหตุผลความแตกต่างของปัจจัยด้านภูมิอากาศและพื้นที่ โครงการนี้จึงสนใจจะเปรียบเทียบเทคนิคการวิเคราะห์ความเร็วเมฆรวมถึงการสกัดคุณลักษณะจากภาพถ่ายเมฆในการพัฒนาการพยากรณ์ความเข้มแสงอาทิตย์ โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง รวมถึงแบบจำลองการเรียนรู้เชิงลึก (ANN, CNN) เพื่อเสนอตัวแปรทำนายและแบบจำลองที่ให้ผลลัพธ์การพยากรณ์ภายในวันที่ดีที่สุดในชุดข้อมูลวัดทั้ง 56 สถานีจากบริษัท Impact solar และภาพถ่ายจากดาวเทียมฮิมาวาริ-8 มีภาพ

รวมการทำงานดังรูปที่ 2 ผลลัพธ์การทดลองพบว่าแบบจำลองในกลุ่ม CNN ได้แก่ CNN-LSTM มีสมรรถนะการพยากรณ์ที่ดีที่สุดในระยะ 30 นาทีแรกและแบบจำลอง Random forest ด้วยคุณลักษณะดัชนีเมฆที่สกัดจากวิธี Horn-Schunck มีประสิทธิภาพการพยากรณ์ดีที่สุดที่ระยะพยากรณ์ 240 นาที



รูปที่ 2: ภาพรวมโครงสร้างแบบจำลองต่าง ๆ ที่พิจารณาในโครงการ

1.2 วัตถุประสงค์ของโครงการ

1. วิเคราะห์ข้อมูลเมฆจากภาพถ่ายเมฆสำหรับสกัดข้อมูลเป็นตัวแปรขาเข้าในการพยากรณ์ I ภายในวัน
2. พัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์ I ที่ใช้คุณลักษณะที่สกัดจากข้อมูลภาพถ่ายเมฆจากวิธีต่าง ๆ

1.3 ขอบเขตของโครงการ

1. การพยากรณ์ค่า I และ P จากข้อมูลวัดบริษัท Impact solar ทั้ง 56 สถานีร่วมกับข้อมูลภาพถ่ายเมฆจากดาวเทียมฮิมาวาริ-8
2. แบบจำลองการพยากรณ์ปริมาณ I ระยะตั้งแต่ 30, 60, ..., 240 นาทีล่วงหน้า จากข้อมูลภาพถ่ายเมฆ และข้อมูลจากตัวรับรู้ โดยจะพยากรณ์ตั้งแต่ช่วงเวลา 7.00 น. ถึง 17.00 น.
3. การเปรียบเทียบคุณลักษณะทางภาพที่ได้จากกระบวนการสกัดด้วยวิธีเทียบบล็อก และวิธีการไหลของแสง ได้แก่ วิธีของ Horn-Schunck และวิธีของ Farneback

1.4 ผลลัพธ์ที่คาดหวังของโครงการ

1. ผลการวิเคราะห์ผลของปริมาณเมฆที่มีผลต่อสมรรถนะการพยากรณ์ I ภายในวัน
2. ชุดคำสั่งแบบจำลองพยากรณ์ค่า I ด้วยแบบจำลองที่เสนอไว้ข้างต้น

2 หลักการและทฤษฎีที่เกี่ยวข้อง

2.1 การพยากรณ์ความเข้มแสงอาทิตย์

การพยากรณ์ (Forecasting) คือ การคำนวณหรือการประมาณค่าใด ๆ ในอนาคต โดยสามารถใช้ตัวแปรต้น X เป็นข้อมูลในอดีต (past data) หรือข้อมูลปัจจุบันในการประมาณค่าตัวแปรตาม ณ ตำแหน่งเวลาในอนาคต

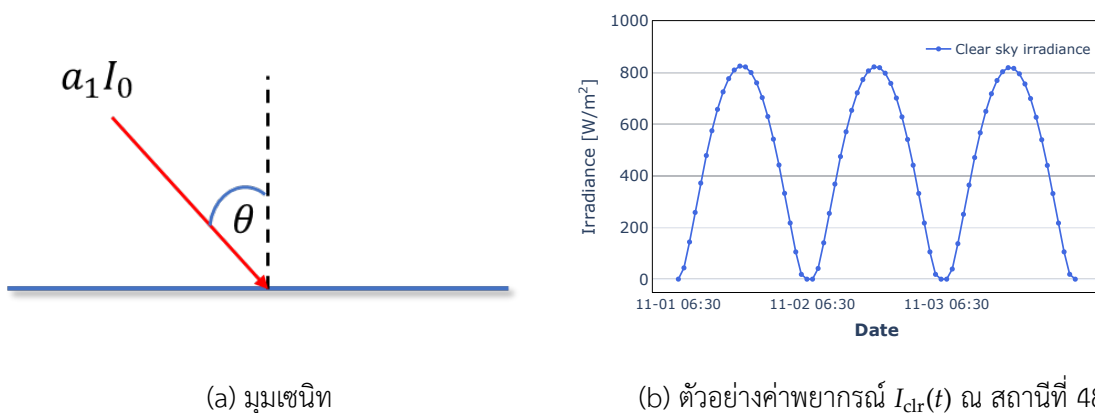
ระยะการพยากรณ์ล่วงหน้า (Forecasting horizon) คือ ระยะเวลาที่แบบจำลองสามารถพยากรณ์ค่าตัวแปรตามออกมาได้ ในส่วนของการพยากรณ์ I นั้นจะแบ่งออกเป็น 4 ช่วงเวลา [AOE+16]

1. การพยากรณ์ในระยะไม่เกิน 1 ชั่วโมง (Intra-hour หรือ nowcasting) เป็นการพยากรณ์ในระยะเวลาที่สั้นมาก มีจุดประสงค์เพื่อควมมีเสถียรภาพ (stability) ของโครงข่าย และการตอบสนองด้านโหลด (demand response)
2. การพยากรณ์ภายในวัน (Intra-day) เป็นการพยากรณ์ในระดับ 1 ถึง 6 ชั่วโมง มีความสำคัญสำหรับการควบคุมการทำงานของระบบโครงข่ายไฟฟ้า (grid operation) หรืองานด้าน load-following
3. การพยากรณ์ในระดับ 6 ชั่วโมงถึง 1 วัน (Six hours to day ahead) เป็นการพยากรณ์ในระดับ 6 ถึง 48 ชั่วโมง มีความสำคัญสำหรับการวางแผนหรือเดินเครื่องการผลิตภายในโรงไฟฟ้า (unit commitment)
4. การพยากรณ์ในระยะ 2 วันขึ้นไป (Two days ahead) เป็นการพยากรณ์ในระดับ 48 ชั่วโมงขึ้นไป มีความสำคัญต่อการวางแผนเดินเครื่องการผลิตภายในโรงไฟฟ้า หรือการวางแผนบำรุงรักษาโครงข่าย โดยในการพยากรณ์ประเภทนี้ยังมีจำนวนงานวิจัยที่เกี่ยวข้องไม่มากนัก

จากงานวิจัยในอดีตสามารถสรุปประเภทข้อมูลนำเข้าหรือตัวแปรต้นที่นิยมสำหรับแต่ละระยะการพยากรณ์ล่วงหน้าภายในวันจะเป็นข้อมูลภาพถ่ายเมฆ (Satellite image) และข้อมูลพยากรณ์จากแบบจำลองทำนายอากาศเชิงเลข (NWP) แต่ในการทดลองนี้ไม่ได้ถูกนำมาใช้เนื่องด้วยประสิทธิภาพของข้อมูลและความละเอียดเชิงเวลาที่ต่ำกว่าซึ่งถ้านำมาเพิ่มอัตราสุ่มจะยิ่งทำให้สมรรถนะของแบบจำลองต่ำลง โครงการนี้จึงใช้เพียงข้อมูลภาพถ่ายเมฆสำหรับการพยากรณ์ภายในวัน

2.2 แบบจำลองท้องฟ้าใส

แบบจำลองท้องฟ้าใส (Clear-sky model) คือ แบบจำลองที่ทำนายค่าความเข้มแสงในสภาวะฟ้าใสออกมาได้ โดยในทางอุดมคติความเข้มแสงในสภาวะฟ้าใส (I_{clr}) นั้นเป็นค่าสูงสุดที่เป็นไปได้ของความเข้มแสงอาทิตย์ ณ เวลาต่าง ๆ ซึ่งขึ้นอยู่กับลักษณะทางกายภาพของตำแหน่งที่สนใจดังรูปที่ 3a เช่น มุมเซนิต (Solar-zenith angle) ความสูงจากระดับน้ำทะเล องค์ประกอบของไอน้ำและโอโซนภายในอากาศ เป็นต้น ตัวอย่าง $I_{clr}(t)$ จะแสดงในรูปที่ 3b



รูปที่ 3: ความเข้มแสงอาทิตย์ในสภาวะฟ้าใส

เราจึงนำค่าความเข้มแสงในสภาวะฟ้าใสมาเป็นคุณลักษณะหนึ่งของแบบจำลอง ในโครงการนี้ใช้แบบจำลองท้องฟ้าใสที่ถูกพัฒนาโดย P. Ineichen และ R. Perez [IP02] ที่มีตัวแปรเข้าที่สำคัญคือ ละติจูด ลองจิจูด ความ

สูงจากระดับน้ำทะเล และ ลำดับวันในปี (day of year) โดยมีความสัมพันธ์ดังนี้

$$I_{clr}(t) = a_1 I_0 \cos \theta(t) e^{-a_2(f_{h_1} + f_{h_2}(T_L - 1)AM(t))} \quad (1)$$

โดยที่ h คือ ระดับความสูงจากน้ำทะเล หน่วยคือเมตร, $f_{h_1} = e^{-\frac{h}{8000}}$, $f_{h_2} = e^{-\frac{h}{1250}}$, $a_1 = 5.09 \times 10^{-5}h + 0.868$, $a_2 = 3.92 \times 10^{-5}h + 0.0387$, T_L คือ ค่าความขุ่นของบรรยากาศ (Linke turbidity factor) เป็นปริมาณที่จะคำนึงถึงปัจจัยที่ไม่กระเจิงแสงทั้งหมด (non-Rayleigh effects) ได้แก่ ฝุ่นละออง ไอน้ำ และโอโซน [Kle13] ซึ่งคำนวณจากวิธีถดถอยเชิงเส้นโดยมีค่าเท่ากับ 4.7737 [TS23], $AM(t)$ คือ ค่าสัมประสิทธิ์มวลอากาศ, และ $\theta(t)$ คือ มุมเซนนิท แม้แบบจำลองท้องฟ้าใสถูกนำเสนอในหลากหลายรูปแบบ แต่ความแม่นยำของแบบจำลองจะขึ้นอยู่กับคุณภาพของข้อมูลนำเข้าเป็นหลัก และเราสามารถคำนวณความฟ้าใสได้จากดัชนีฟ้าใส (Clear-sky index) คือ $k = \frac{I}{I_{clr}}$


2.3 เวกเตอร์ความเร็วเมฆ

เวกเตอร์ความเร็วเมฆ (Cloud motion vector) คือเวกเตอร์แสดงความเร็วของแต่ละพิกเซลในภาพ $v = (v_x, v_y)$ มีหน่วยคือ พิกเซลต่อหนึ่งหน่วยความละเอียดเชิงเวลาของข้อมูลภาพหรือสปีนาทิก การสกัดหา CMV มีอยู่ 2 วิธี ได้แก่ วิธีเทียบบล็อกและวิธีการไหลของแสง

2.3.1 วิธีเทียบบล็อก

วิธีเทียบบล็อกใช้ข้อมูลเข้าเป็นภาพถ่ายเมฆ โดยจะคำนวณหา CMV จาก Cross-correlation method (CCM) จากภาพถ่ายเมฆ 2 ภาพที่นำเข้า ปริมาณ CCM จะบอกถึงตำแหน่งที่พิกเซล ณ เวลา $t - 1$ จะเคลื่อนที่ไปยังตำแหน่งใด ๆ ณ เวลา t ซึ่งตัวแปรที่จะใช้มี x, y คือระยะทางในแกน X และ Y ของโดเมนในภาพทั้งหมด และ x_s, y_s คือระยะค้นหา (search radius) ในระยะแกน X และ Y ตามลำดับ การค้นหาสามารถทำได้ 2 วิธี [JK18] คือ

1. ค้นหาทั้งโดเมน จะค้นหาด้วยพิกเซลทั้งโดเมน แต่เพื่อให้การค้นหาไม่ตกขอบของโดเมน เราจึงสร้างกล่องที่มีขนาด $(x - 2x_s, y - 2y_s)$ ในการค้นหา โดยเวกเตอร์ความเร็วที่ได้จะมาจากคู่พิกเซลที่มีค่า cross-correlation coefficient สูงที่สุด
2. ค้นหาโดเมนย่อย จะแบ่งโดเมนทั้งหมดเป็นกล่องขนาดเล็ก เช่น กล่องขนาด 2×2 พิกเซล โดยยังแบ่งกล่องขนาดเล็กเท่าใดจะส่งผลให้ CMV ที่ได้มีความละเอียดมากขึ้น



รูปที่ 4: การเทียบบล็อกโดยค้นหาทั้งโดเมนและค้นหาโดเมนย่อยด้วยกล่องขนาด 2×2

2.3.2 วิธีการไหลของแสง

การไหลของแสง (Optical flow หรือ OF) คือ การไหลของความเข้มพิกเซล ในโครงงานนี้จึงหมายถึง ความเร็วจากการเคลื่อนที่ของความเข้มพิกเซล (intensity) ที่ปรากฏจากภาพสองภาพที่ต่อเนื่องกัน [HS81] เทคนิคการ

ไหลของแสงจึงมีไว้เพื่อหาความเร็วของแต่ละพิกเซลหรือในบริบทโครงงานนี้คือเมฆ การอธิบายในหัวข้อนี้ตัวแปร $I(x, y, t)$ จะหมายถึงความเข้มในแต่ละพิกเซลที่พิกัด (x, y) ณ เวลา t โดยมีสมมติฐานคือ (1) ค่าความเข้มในแต่ละพิกเซลของสองภาพที่ต่อเนื่องกันมีค่าเท่ากัน (2) เมฆไม่มีการก่อตัวและสลายตัว [CeSZ+21] จึงสามารถเขียนสมมติฐานนี้เป็นความสัมพันธ์ทางคณิตศาสตร์ได้ดัง (2)

$$I(x + dx, y + dy, t + dt) = I(x, y, t) \quad (2)$$

เมื่อกระจายอนุกรมเทเลอร์อันดับหนึ่งและหาอนุพันธ์เทียบเวลาของ (2)

$$\frac{\partial I(x, y, t)}{\partial x} v_x + \frac{\partial I(x, y, t)}{\partial y} v_y + \frac{\partial I(x, y, t)}{\partial t} \approx 0 \quad (3)$$

วิธีการไหลของแสงจึงมีจุดประสงค์ในการหาค่า (v_x, v_y) ที่ทำให้ (3) มีค่าเข้าใกล้ศูนย์มากที่สุด โดยมีคุณสมบัติที่ต่างกันไปขึ้นอยู่กับค่าที่ต่ำสุดฟังก์ชันวัตถุประสงค์ที่ต่างกัน เช่น ต้องการให้เวกเตอร์ความเร็วเมฆมีความต่อเนื่องกันทั้งหมดหรือต้องการให้เวกเตอร์ความเร็วเมฆมีความต่อเนื่องกันบางส่วน

วิธีของ Farneback มีรากฐานจากประมาณความเข้มของแต่ละพิกเซลด้วยพหุนามดีกรีสอง [Far03] กล่าวคือ เราจะบรรยายความเข้มของพิกเซลที่ตำแหน่ง $z = (x, y) \in \mathbb{R}^2$ ณ เวลา $t - 1$ ดัง (4)

$$I_{t-1}(z) = z^T A_1 z + b_1^T z + c_1 \quad (4)$$

โดยในแต่ละตำแหน่ง z จะมี A, b และ c ที่แตกต่างกันซึ่งได้มาจากการหาค่ากำลังสองต่ำสุดแบบถ่วงน้ำหนักกับพิกเซลบริเวณโดยรอบ จากสมมติฐาน (2) จึงสามารถมองได้ว่าความเข้ม $I_t(z)$ คือความเข้ม $I_{t-1}(z)$ ที่ถูกเลื่อนมาเป็นระยะทาง $d \in \mathbb{R}^2$

$$\begin{aligned} I_{t-1}(z - d) &= (z - d)^T A_1 (z - d) + b_1^T (z - d) + c_1 \\ &= z^T A_2 z + b_2^T z + c_2 = I_t(z) \end{aligned}$$

เมื่อเทียบสัมประสิทธิ์ของ $I_{t-1}(z - d)$ และ $I_t(z)$ จึงได้ $A_2 = A_1$ และ $b_2 = b_1 - 2A_1 d$ ดังนั้น เราสามารถหาเวกเตอร์ความเร็วเมฆได้จาก $d = (1/2)A^{-1}(b_2 - b_1)$ ซึ่งมีค่าก็ต่อเมื่อ A มีเมทริกซ์ผกผัน

เนื่องจากในทางปฏิบัติจะมีสัญญาณรบกวนอยู่มาก เราจึงประมาณใหม่โดยการใช้ค่าเฉลี่ยระหว่าง A ในเวลาอดีตและปัจจุบัน $A(z) = \frac{A_1(z) + A_2(z)}{2}$ เพื่อใช้ในการประมาณเวกเตอร์ความเร็วเมฆที่เหมาะสมยิ่งขึ้น

วิธีของ Horn-Schucnk เป็นการหาเวกเตอร์ความเร็วเมฆที่โดยรวมมีความต่อเนื่องกัน นั่นคือ ต้องการให้การเปลี่ยนแปลงความเร็วในแกน x หรือก็คือ $(\frac{\partial v_x}{\partial x})^2 + (\frac{\partial v_x}{\partial y})^2$ มีค่าน้อย และการเปลี่ยนแปลงความเร็วในแกน y มีค่าน้อย อีกทั้งเวกเตอร์ที่ได้จะต้องสอดคล้องกับสมมติฐาน (3) เราจึงเขียนเป็นการหาค่าเหมาะสมที่สุดดัง (5) [HS81]

$$\arg \min_{v_x, v_y} \int_{\text{pic}} \|\nabla v_x\|_2^2 + \|\nabla v_y\|_2^2 + \lambda \left(\frac{\partial I_{\text{pix}}}{\partial x} \cdot v_x + \frac{\partial I_{\text{pix}}}{\partial y} \cdot v_y + \frac{\partial I_{\text{pix}}}{\partial t} \right)^2 \quad (5)$$

โดยที่ λ คือพารามิเตอร์ลงโทษ เมื่อค่า λ มากจะส่งผลให้ (3) มีค่าน้อย แต่จะทำให้เวกเตอร์ความเร็วเมฆมีความต่อเนื่องที่น้อยลงด้วย และ (\cdot) คือการคูณแบบ element-wise

2.4 การประมาณความเข้มที่พิกเซลย่อย


หลังจากที่เราได้เวกเตอร์ความเร็วเมฆแล้ว กระบวนการถัดไปคือการประมาณภาพในอนาคตโดยใช้เวกเตอร์ความเร็วเมฆเหล่านั้น ในโครงงานนี้เราจะประมาณภาพในอนาคตด้วยความสัมพันธ์

$$I(x, y, t) = I(x + v_x, y + v_y, t - 1)$$

กล่าวคือ ตำแหน่งพิกเซลในเวลาปัจจุบัน t มาจากตำแหน่งพิกเซลในเวลาอดีต $t - 1$ ที่ถูกเลื่อนโดยเวกเตอร์ความเร็วเมฆ v_x, v_y เนื่องจากค่าตำแหน่งที่ได้จากการเลื่อนนั้นอาจไม่เป็นจำนวนเต็ม เมื่อเราได้ค่า $I(x - v_x, y - v_y, t)$ แล้วจึงประมาณค่าความเข้มใหม่ด้วยวิธี Sub-pixel bilinear interpolation โดยจะเป็นการเฉลี่ยแบบถ่วงน้ำหนักกับพิกเซลบริเวณโดยรอบ [LFQ09]

$$\begin{aligned}
 I(x_{\text{new}}, y_{\text{new}}) &= (y_1 - y_{\text{new}})I(x_{\text{new}}, y_0) + (y_{\text{new}} - y_0)I(x_{\text{new}}, y_1) \\
 &= (y_1 - y_{\text{new}})[(x_1 - x_{\text{new}})I(x_0, y_0) + (x_{\text{new}} - x_0)I(x_1, y_0)] \\
 &\quad + (y_{\text{new}} - y_0)[(x_1 - x_{\text{new}})I(x_0, y_1) + (x_{\text{new}} - x_0)I(x_1, y_1)] \\
 &= (x_1 - x_{\text{new}})(y_1 - y_{\text{new}})I(x_0, y_0) + (x_1 - x_{\text{new}})(y_{\text{new}} - y_0)I(x_0, y_1) \\
 &\quad + (x_{\text{new}} - x_0)(y_1 - y_{\text{new}})I(x_1, y_0) + (x_{\text{new}} - x_0)(y_{\text{new}} - y_0)I(x_1, y_1)
 \end{aligned} \tag{6}$$

ในที่นี้ $x_{\text{new}} = x - v_x$, $y_{\text{new}} = y - v_y$, $(x_0, y_0) = \lfloor x_{\text{new}}, y_{\text{new}} \rfloor$ และ $(x_1, y_1) = \lceil x_{\text{new}}, y_{\text{new}} \rceil$



รูปที่ 5: การประมาณค่าความเข้มพิกเซลจากการเฉลี่ยแบบถ่วงน้ำหนักของพิกเซลโดยรอบ

2.5 แบบจำลองการทำนาย

2.5.1 แบบจำลอง Seasonal autoregressive integrated moving average with exogenous factors

ในโครงงานนี้จะมีแบบจำลองที่ใช้ทั้งข้อมูลภาพ และข้อมูลวัดจากตัวรับรู้ เราจึงเลือกใช้แบบจำลองฐาน ซึ่งเป็นแบบจำลองเชิงเส้นอนุกรมเวลา SARIMAX ที่ใช้ Exogenous factors คือ ค่าความเข้มแสงอาทิตย์ในสภาวะท้องฟ้าใส และดัชนีเมฆที่สกัดจากภาพถ่ายเมฆ โดยจะมีโครงสร้างของแบบจำลอง SARIMAX(p, d, q)(P, D, Q) T ดัง (7)

$$\tilde{A}(L^T)A(L)(1 - L)^d(1 - L^T)^D I(t) = u(t) + \tilde{C}(L^T)C(L)v(t) \tag{7}$$

โดยที่

$$\begin{aligned}
 A(L) &= I - (a_1L + \dots + a_pL^p), & C(L) &= I + C_1L + \dots + C_qL^q, \\
 \tilde{A}(L) &= I - (\tilde{a}_1L^T + \dots + \tilde{a}_pL^{PT}), & \tilde{C}(L) &= I + \tilde{c}_1L^T + \dots + \tilde{c}_qL^{QT},
 \end{aligned}$$

L คือตัวดำเนินการผลต่าง, $y(t)$ คือ ลำดับอนุกรมเวลา แบบจำลอง SARIMAX นั้นมีโครงสร้างความสัมพันธ์ระหว่างตัวแปรเป็นแบบเชิงเส้น แต่จะมีสมมติฐานเพิ่มเติม คือ ในตัวแปร y และ v ซึ่งในโครงงานนี้คือความเข้มแสงอาทิตย์และสัญญาณรบกวนขาวตามลำดับ มีความเป็นฤดูกาล (seasonality) เราจึงเลือกใช้เป็นแบบจำลองฐานเพื่อทดสอบว่าในแบบจำลองอื่น ๆ ที่มีโครงสร้างไม่เป็นเชิงเส้นระหว่างตัวแปรจะมีประสิทธิภาพที่ดีกว่าหรือไม่ โครงงานนี้จะใช้อันดับของแบบจำลองจากหัวข้อที่ 7.3.1 คือ

$$\text{SARIMAX}(1, 0, 1)(0, 1, 1)_{24}$$

2.5.2 แบบจำลอง Linear regression

เนื่องจากแบบจำลองการ Linear regression ใช้ทรัพยากรในการคำนวณที่น้อยเมื่อเทียบกับแบบจำลองอื่น ๆ แต่จะเหมาะสำหรับการวิเคราะห์ที่ตัวแปรทำนายและตัวแปรขาออกมีความสัมพันธ์ในลักษณะเชิงเส้น ซึ่งสามารถอธิบายด้วย $y = X\beta$ โดยที่ y และ X คือ เวกเตอร์ของข้อมูลขาออกและเมทริกซ์ของตัวแปรทำนายที่เราเป็นผู้กำหนดตามลำดับ ขณะที่ β คือ เวกเตอร์สัมประสิทธิ์การถดถอยที่ต้องการประมาณเพื่อให้ $\|y - X\beta\|_2$ มีค่าที่น้อยที่สุด

2.5.3 แบบจำลอง Polynomial regression

ในส่วนของ การแปลง I เป็น P แบบจำลองควรมีความซับซ้อนต่ำเพื่อที่จะ upscale ให้เข้ากับความรู้ในการแปลงเป็นกำลังไฟฟ้าของแต่ละสถานีได้ เราจึงเลือกแบบจำลอง Polynomial regression ที่มีดีกรีอันดับสองเป็นหนึ่งในการทดสอบ โดยมีความสัมพันธ์ระหว่างตัวแปรคือ $P = \beta_0 + \beta_1 I + \beta_2 I^2$ โดยที่ $\beta_0, \beta_1, \beta_2$ คือสัมประสิทธิ์การถดถอย

2.5.4 แบบจำลอง Random forest

แบบจำลอง Random forest เป็นแบบจำลองที่พัฒนามาจากต้นไม้ตัดสินใจ (Decision tree) เพื่อเพิ่มประสิทธิภาพและลดปัญหาความแปรปรวนของการทำนายที่สูงจากการใช้ชุดข้อมูลฝึกทั้งหมดในการฝึกแบบจำลองหลักเพียงแบบจำลองเดียว (high-variance) โดยมีขั้นตอนคือ เริ่มจากการสร้างชุดข้อมูล bootstrap ซึ่งชุดข้อมูลดังกล่าวจะเป็นการสุ่มเลือกมาจากชุดข้อมูลเดิมและสามารถเลือกตัวอย่างซ้ำได้ต่อชุดข้อมูล bootstrap 1 ชุด ซึ่งเราจะสุ่มสร้างมาทั้ง B ชุดข้อมูลสำหรับแบบจำลองต้นไม้ย่อย (subtree) B ต้น ในแต่ละต้นไม้ย่อยนั้น เราจะสุ่มใช้บางตัวแปรทำนาย (Predictor) เท่านั้น โดยเราจะได้ค่าทำนายสุดท้ายจากการเฉลี่ยผลลัพธ์จากต้นไม้ย่อยแต่ละต้น ดัง (8) เราจะเรียกวิธีการได้ผลลัพธ์สุดท้ายจากหลาย ๆ ผลการทำนายของแบบจำลองย่อยนี้ว่าเป็นการใช้เทคนิคแบบ ensemble [GDTR21]

$$\hat{y}_{\text{avg}} = \frac{1}{B} \sum_{i=1}^B \hat{y}_i \quad (8)$$

ในโครงการนี้ใช้ hyperparameters ของแบบจำลองจากหัวข้อที่ 7.3.2 คือ


$$n_{\text{estimators}} = 1500, \text{max depth} = 30$$

2.5.5 แบบจำลอง Support vector regression

แบบจำลอง SVR นั้นเป็นรูปแบบหนึ่งที่มาจากแบบจำลอง SVM โดยจุดประสงค์ของแบบจำลอง SVR คือการหา hyperplane ที่จะบรรยายชุดข้อมูลในความสัมพันธ์แบบเชิงเส้นดังรูปที่ 6 แต่เมื่อข้อมูลมีความไม่เป็นเชิงเส้นแบบจำลองจะไม่สามารถหา hyperplane ที่เหมาะสมในการบรรยายชุดข้อมูลได้ เราจึง map ข้อมูลไปยังปริภูมิที่มีมิติสูงกว่าเดิมผ่านฟังก์ชัน $h(\cdot)$ โดยเราสามารถเขียนปัญหาการสร้างแบบจำลอง SVR ได้ดัง (9)

โดยที่ $C \in \mathbb{R}$ คือ พารามิเตอร์ลงโทษ (penalty parameter) การปรับ C ที่มีค่ามากจะลงโทษทำให้ค่า $\|w\|^2$ มากขึ้น จึงส่งผลให้ margin น้อยลง, $\epsilon \in \mathbb{R}$ คือ ค่าความเบี่ยงเบนจากขอบ, $\xi_i, \xi_i^* \in \mathbb{R}$ คือ ตัวแปรหย่อน (slack variable) ซึ่งจะคอยหย่อนให้ข้อมูลอยู่นอก ϵ -tube และ $h(\cdot)$ คือ ฟังก์ชันไม่เชิงเส้นที่แมปให้ข้อมูลนำเข้ามีมิติที่มากขึ้น โดย (9) นั้นจะมีปัญหา dual ที่เขียนได้เป็น

$$\begin{aligned} & \text{minimize} && \frac{1}{2}(\alpha - \alpha^*)^T Q (\alpha - \alpha^*) + \epsilon \mathbf{1}^T (\alpha + \alpha^*) - y^T (\alpha - \alpha^*) \\ & \text{subject to} && \mathbf{1}^T (\alpha - \alpha^*) = 0 \\ & && 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, 2, \dots, N \end{aligned}$$



$$\begin{aligned}
 & \text{minimize} && \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \\
 & \text{subject to} && y_i - w^T h(x_i) - b \leq \epsilon + \xi_i \\
 & && w^T h(x_i) + b - y_i \leq \epsilon + \xi_i^* \\
 & && \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, N
 \end{aligned} \quad (9)$$

รูปที่ 6: ปัญหาตั้งต้นของ ϵ -SVR

โดยที่ $Q \geq 0$ ซึ่ง $Q_{ij} \equiv K(x_i, x_j) = h(x_i)^T h(x_j)$ คือ Kernel ในโครงงานนี้จะใช้ Radial basis function kernel $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ และ hyperparameters ของแบบจำลองจากหัวข้อที่ 7.3.3 คือ

$$C = 100, \epsilon = 1, \gamma = 0.1$$

2.5.6 แบบจำลอง Gradient boosting tree

ในกลุ่มแบบจำลอง ensemble มีการพัฒนาโครงสร้างของแบบจำลอง โดยให้แต่ละแบบจำลองย่อยมีการเรียนรู้ในลักษณะ sequential กล่าวคือ สำหรับแบบจำลองย่อยในลำดับที่ m จะเป็นการเรียนรู้กับความผิดพลาดของแบบจำลองลำดับที่ $m - 1$ ได้ว่าสำหรับแบบจำลองย่อยที่ m ของ regression tree $T(x; \Theta_m)$ ที่มีพารามิเตอร์แบบจำลอง $\Theta_m = \{R_{jm}, \gamma_{jm}\}_1^m$ เมื่อ R_{jm} คือเซตของสมาชิก region ที่ j ที่มีค่าตัวแทนของสมาชิกใน region นั้นเป็น γ_{jm} สามารถประมาณค่าพารามิเตอร์ของแบบจำลองนั้นได้จากการพิจารณา squared-loss function ดัง (10)

$$\hat{\Theta}_m = \arg \min_{\Theta_m} \sum_{i=1}^N (y_i - (f_{m-1}(x_i) + T(x_i; \Theta_m)))^2 \quad (10)$$

โดย f_{m-1} เป็นผลรวมค่าการทำนายของแบบจำลองตั้งแต่แบบจำลองที่ 1 ที่เป็น initial guess จนถึงแบบจำลองที่เรียนรู้จากความผิดพลาดลำดับที่ $m - 1$ นั่นคือ สำหรับแบบจำลองที่มีการเรียนรู้ทั้งหมด M ลำดับ จะได้ค่าการทำนายสุดท้ายดัง (11)

$$f_M(x) = \sum_{m=1}^M T(x; \Theta_m) \quad (11)$$

ปัญหา (10) สามารถหาคำตอบได้โดยการใช้วิธีการหาค่าเหมาะสมที่สุดเชิงตัวเลขที่มีการใช้อนุพันธ์ของฟังก์ชัน เรียกแบบจำลองในกลุ่มนี้ว่า Gradient boosting tree [HTF09] ซึ่งการแก้ปัญหาดังกล่าวนั้น เดิมจะประสบกับปัญหาด้านต้นทุนการคำนวณที่สูงหากจำนวนข้อมูลและตัวแปรทำนายมีปริมาณมาก ในโครงงานนี้ใช้แบบจำลอง LightGBM [KMF+17] ที่มีการใช้อัลกอริทึม Gradient-based one-side sampling (GOSS) โดยจะลดอัตราสุ่มของกลุ่มข้อมูลที่มีอนุพันธ์ต่ำและเก็บชุดข้อมูลที่มีอนุพันธ์สูงไว้ และ อัลกอริทึม Exclusive feature bundling (EFB) เป็นขั้นตอนการทำ feature engineering ที่มีการพิจารณาจับกลุ่ม features เป็น bundle และ aggregate แต่ละ features ใน bundle เดียวกัน เพื่อลดต้นทุนจากการเลือกใช้ feature ทั้งหมดที่มีแทน ในโครงงานนี้ใช้ hyperparameters ของแบบจำลองจากหัวข้อที่ 7.3.4 คือ

$$\text{learning rate} = 0.01, n_{\text{estimators}} = 1000, \text{max depth} = 10$$

2.5.7 แบบจำลอง Convolutional neural networks

โครงการนี้มีจุดประสงค์ในการใช้ภาพถ่ายเมฆในอดีตสำหรับการพยากรณ์ I ในอนาคต ณ ตำแหน่งที่สนใจที่มีพิกัดอยู่ในภาพถ่ายดังกล่าว นั่นคือเป็นปัญหาที่สนใจความสัมพันธ์เชิงพื้นที่และเวลาของข้อมูล (spatiotemporal correlations) ในงานวิจัยของกลุ่มแบบจำลองโครงข่ายประสาทเทียมแบบสังวัตนาการ (CNN) จึงได้มีการเสนอโครงสร้างแบบจำลองสำหรับปัญหาดังกล่าว โดยโครงการนี้ทดลองในสองโครงสร้างได้แก่

3D-convolutional neural networks (3D-CNN) เมื่อข้อมูลนำเข้าเป็นวิดีโอหรือภาพถ่ายที่มีลำดับติดกัน การใช้แบบจำลอง 2D-CNN จะไม่เพียงพอต่อการหาความสัมพันธ์ในเชิงเวลาของข้อมูล แบบจำลอง 3D-CNN [TBF⁺15] สามารถสกัดความสัมพันธ์ทั้งเชิงพื้นที่และเวลาของข้อมูลตั้งต้นจากการทำสังวัตนาการในสามมิติเมื่อมิติที่สามคือมิติในเชิงเวลาด้วย 3D-kernel ดัง (12)

$$z_{ij}^{xyz} = f \left(b_{ij} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijm}^{pqr} z_{(i-1)m}^{(x+p)(y+q)(z+r)} \right) \quad (12)$$

สมการดังกล่าวเป็นการส่งผ่านข้อมูลจากชั้นที่ $i - 1$ ไปยังคุณลักษณะที่ j ของชั้นที่ i ด้วย kernel ที่มีมิติเป็นจำนวนเฟรม, ความสูงและความกว้าง (R_i, P_i, Q_i) ตามลำดับ การทำสังวัตนาการจะต้องบวกผลของทุกคุณลักษณะ m ของชั้นที่ $i - 1$ ผ่านไปยัง activation function f เมื่อผ่านการทำสังวัตนาการและตัวดำเนินการ pooling จนเหมาะสมกับความซับซ้อนของโหนดและข้อมูลที่มีแล้ว สำหรับโหนดการพยากรณ์ I จะนำผ่านชั้น fully connected เพื่อเข้าสู่ชั้น dense ของแบบจำลอง ANN หาค่าทำนายสุดท้ายต่อไป

Convolutional LSTM networks (CNN-LSTM) มีการเสนอโครงสร้างที่พัฒนามาจากแบบจำลอง Long short term memory (LSTM) ซึ่งแบบจำลองดังกล่าวโดยปกติจะไม่พิจารณาความสัมพันธ์เชิงพื้นที่ของข้อมูลนำเข้าไประหว่างการเรียนรู้ แบบจำลอง Convolutional-LSTM [SCW⁺15] ปรับปรุงข้อบกพร่องดังกล่าวได้ด้วยการทำสังวัตนาการข้อมูลภายในเซลล์ LSTM กล่าวคือ กำหนดข้อมูลนำเข้าเซลล์ X_t , ข้อมูลขาออกของเซลล์ c_t , ข้อมูลสถานะ hidden state h_t และ gate ที่เกี่ยวข้อง f_t, i_t, o_t เป็นข้อมูลสองมิติที่มีความสัมพันธ์ในเชิงพื้นที่ที่มีความสัมพันธ์ดังรูปที่ 7 gate แต่ละตัวทำหน้าที่คือ f_t จะควบคุมอิทธิพลของข้อมูลที่เวลา t ที่ส่งผลต่อตัวแปร

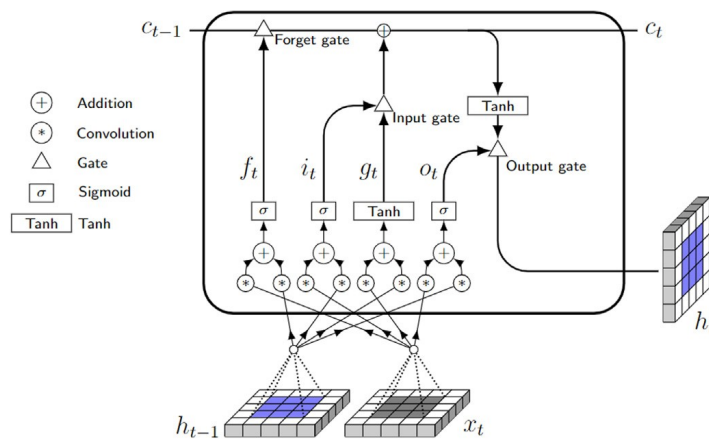


Figure 1: The LSTM cell.

รูปที่ 7: แผนผังความสัมพันธ์ของตัวแปรภายในแบบจำลอง CNN-LSTM [GCM⁺22]

ออก C_t , gate f_t ควบคุมอิทธิพลของข้อมูลในสถานะก่อนหน้า และ gate o_t ควบคุมอิทธิพลของตัวแปรขาออก c_t ต่อตัวแปร h_t

2.6 สมรรถนะของแบบจำลอง

สำหรับโครงการนี้จะใช้ 4 ดัชนีในการประเมินความแม่นยำการพยากรณ์ของแบบจำลอง ได้แก่

- Mean absolute error (MAE)

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i(t+k) - y_i(t+k)|$$

- Root mean square error (RMSE)

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (\hat{y}_i(t+k) - y_i(t+k))^2}{N}}$$

ในบริบทของโครงการนี้ $y(t+k)$ คือค่าจริงของ I ที่วัดในเวลาล่วงหน้า k ชั้น และ $\hat{y}(t+k)$ คือค่าที่พยากรณ์ล่วงหน้า k ชั้น แต่ค่า I ในแต่ละพื้นที่มีสภาพภูมิอากาศต่างกันจะมีค่าอยู่ในคนละช่วง ดัชนี MAE, RMSE จึงควรมีการ normalize ด้วยค่าฐาน เพื่อให้ดัชนีสามารถนำไปเปรียบเทียบกับงานอื่น ๆ ได้ ตัวอย่างการใช้ค่าฐานคือการใช้ค่าเฉลี่ยของ I ในช่วงเวลากลางวัน

- Normalized root mean square error (NRMSE)

$$\text{NRMSE} = \frac{1}{\bar{y}} \sqrt{\frac{\sum_{i=1}^N (\hat{y}_i(t+k) - y_i(t+k))^2}{N}} \times 100\%$$

โดยที่ $\bar{y} = \frac{1}{N} \sum_{i=1}^N y(t+k)$

- Normalized mean absolute error (NMAE)

$$\text{NMAE} = \frac{1}{N\bar{y}} \sum_{i=1}^N |\hat{y}_i(t+k) - y_i(t+k)| \times 100\%$$


ดัชนีที่กล่าวมาทั้งหมดจะประเมินกับข้อมูลในแต่ละระยะการพยากรณ์ที่แยกกันและอยู่ในช่วงเวลา 06.30 - 17.00 เพื่อไม่ให้ผลลัพธ์ที่ได้มีความเอนเอียง

3 ระเบียบวิธี

3.1 รายละเอียดชุดข้อมูล

ข้อมูลที่ถูกใช้ในการสร้างแบบจำลองการพยากรณ์มาจาก 2 แหล่งด้วยกัน ได้แก่

1. ข้อมูลภาพถ่ายเมฆ เป็นภาพถ่ายจากดาวเทียมฮิมาวาริ-8 ซึ่งเป็นดาวเทียมค้างฟ้า มีไฟล์สกุล (.TIFF) ขนาด 1725×1670 พิกเซล ในแต่ละพิกเซลมีค่าความหนาแน่นของเมฆอยู่ระหว่าง 0 ถึง 255 และขนาดเชิงพื้นที่เท่ากับ 2×2 ตารางกิโลเมตร ข้อมูลภาพถ่ายเมฆที่ได้มานี้ มีสถานีรับภาพอยู่บนดาวเทียมภาคิวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย (CUEE) ให้บริการตั้งแต่วันที่ 5 กุมภาพันธ์ 2565 เป็นต้นมา ด้วยความละเอียดเชิงเวลาเท่ากับ 10 นาที แต่จะมีเวลาประวิง 30 นาทีก่อนภาพถูกส่งมาถึงสถานีรับนับตั้งแต่เวลาจริงที่ภาพนั้นถูกถ่าย โดยในส่วนของ การทดลองและผลลัพธ์ของหัวข้อที่ 4.1 จะใช้ภาพ **Cloud mask** แต่การพัฒนาและทดสอบแบบจำลองจะใช้ภาพ **Overview R channel** เนื่องจากกลุ่มก้อนสีเหลืองลักษณะคล้ายเมฆที่ลดทอน I ได้นั้นจะปรากฏในภาพ **Overview R channel** เท่านั้น [TS23]




รูปที่ 8: ตัวอย่างภาพจาก Cloud mask, Overview R channel และ RGB ตามลำดับ

- ข้อมูลจากตัวรับรู้ของบริษัท Impact solar เป็นค่าวัตของกำลังไฟฟ้าที่ผลิตได้, ค่าความเข้มแสงอาทิตย์ และค่าอุณหภูมิของทั้งตัวแผงเซลล์แสงอาทิตย์และอุณหภูมิโดยรอบ ข้อมูลเป็นอนุกรมเวลาจากสถานีทั้งหมด 56 ตำแหน่งทั่วประเทศไทย

3.2 การจัดเตรียมข้อมูล

เนื่องจากข้อมูลค่าวัตและภาพถ่ายเมฆมีความละเอียดเชิงเวลาที่ไม่เท่ากัน โดยข้อมูลภาพมีความถี่เชิงเวลาเท่ากับ 10 นาที และข้อมูลจากตัวรับรู้มีความถี่เชิงเวลาเท่ากับ 15 นาที จึงเลือกเวลาที่ข้อมูลทั้งสองมีความถี่ตรงกันคือ 30 นาที และจัดการข้อมูลเบื้องต้นดังนี้


- ข้อมูลภาพถ่ายเมฆจากสถานีรับภาพ CUEE ทำการตรวจสอบภาพว่ามีภาพใดบ้างที่ไม่สามารถนำมาใช้ในการทดลองได้ด้วยเงื่อนไขคือ จะต้องไม่มีแถบดำปรากฏภายในภาพที่ใช้ในการทดลองดังรูปที่ 9 ข้อมูลภาพจะเป็นข้อมูลตั้งแต่วันที่ 5 กุมภาพันธ์ พ.ศ.2565 - 28 กุมภาพันธ์ พ.ศ.2566



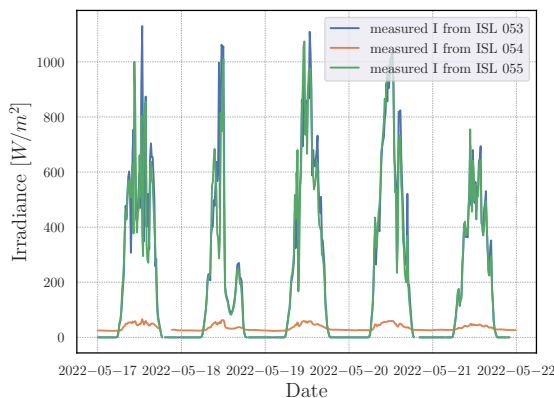
รูปที่ 9: ตัวอย่างภาพถ่ายที่ไม่สามารถนำมาใช้ในการทดลองได้

- ข้อมูลจากตัวรับรู้บริษัท Impact solar ในโครงการนี้จะใช้ข้อมูลสองตัวแปรได้แก่ I และ P ความผิดพลาดที่พบคือสถานีที่ 32 ตัวรับรู้สามารถวัดค่า I ได้เป็นค่าศูนย์หรือวัดค่าได้เป็นตัวเลขที่ออกมาน้อยมากจนแทบเป็นไปไม่ได้ เช่น รูปที่ 10a ความเข้มแสงอาทิตย์ที่อ่านได้ตั้งแต่วันที่ 5 พฤษภาคม 2565 มีระดับที่ลดลงอย่างเห็นได้ชัดแต่ค่ากำลังผลิตไฟฟ้ายังอยู่ในระดับเดิม เป็นไปได้ว่าอาจเกิดปัญหาขึ้นกับตัวรับรู้สำหรับวัดความเข้มแสงอาทิตย์ในตำแหน่งนั้น และสถานี 54 ที่มีพิกัดภูมิศาสตร์ (13.09284 °N, 100.9597 °E) ซึ่งใกล้กับตำแหน่งสถานีที่ 53 (13.08754 °N, 100.9545 °E) และตำแหน่งสถานีที่ 55 (13.09915 °N,

100.9643 °E) โดยทั่วไปควรมีระดับความเข้มแสงอาทิตย์ที่วัดได้ในระดับใกล้เคียงกัน แต่จากรูปที่ 10b จะเห็นว่าค่าความเข้มแสงอาทิตย์ของสถานีที่ 53 และ 55 มีรูปแบบที่วัดได้ในระดับใกล้เคียงกัน แต่ของสถานีที่ 54 นั้นกลับมีค่าที่วัดได้ต่ำซึ่งมีโอกาสเป็นไปได้ต่ำมาก ในโครงการนี้จะไม่พิจารณาข้อมูลที่มีลักษณะข้างต้นนั่นคือ ตัดข้อมูลวัดสถานีที่ 54 ทั้งหมดและข้อมูลตั้งแต่วันที่ 5 พฤษภาคม 2565 ของสถานีที่ 32 ทั้งหมดทิ้ง รวมถึงข้อมูลที่เฉพาะตัวรับรู้วัด I ผิดพลาดโดยใช้เกณฑ์ว่าหากมี P วัดได้เกิน 10 วัตต์ แต่ค่าวัด I มีค่าเป็น 0 จะไม่นำมาพิจารณาเช่นกัน ข้อมูลจากตัวรับรู้จะเป็นข้อมูลตั้งแต่วันที่ 5 กุมภาพันธ์ พ.ศ. 2565 - 28 กุมภาพันธ์ พ.ศ. 2566 เช่นเดียวกันกับข้อมูลภาพถ่ายเมฆ



(a) ข้อมูลวัดของสถานีที่ 32



(b) ข้อมูลวัดของสถานีที่ 54

รูปที่ 10: ความผิดพลาดในการวัดข้อมูลความเข้มแสงอาทิตย์จากตัวรับรู้ บริษัท Impact solar

3.3 การแบ่งข้อมูลในการพัฒนาแบบจำลอง

โครงการนี้ทำการรวมข้อมูลค่าวัดและภาพถ่ายเมฆทุกสถานี เพื่อพัฒนาแบบจำลองพยากรณ์ I ในทุกตำแหน่งที่ตั้ง แต่เนื่องจากข้อมูลของเรามีประมาณหนึ่งปีโดยธรรมชาติของข้อมูล I จะมีค่าเฉลี่ยไม่เท่ากันในแต่ละฤดูกาลของปี ถ้าแบ่งข้อมูลเพื่อพัฒนาแบบจำลองแบบเรียงวันให้ข้อมูลส่วนต้นเป็นชุดข้อมูลฝึกสอน และข้อมูลส่วนท้ายเป็นข้อมูลทดสอบ แบบจำลองจะมีความเอนเอียงกับชุดข้อมูลส่วนต้น ถ้าทดสอบกับชุดข้อมูลทดสอบที่มีค่าเฉลี่ยต่างกัน จะทำให้แบบจำลองมีสมรรถนะที่ไม่ดีมากนัก เราจึงแบ่งข้อมูลให้ทั้งข้อมูลฝึกสอน (training data), ข้อมูลตรวจสอบ (validation data) และข้อมูลทดสอบ (test data) ให้แต่ละชุดข้อมูลมีวันทุกฤดูกาลโดยการสุ่มจำนวนวันใน 1 ปีลงในทั้งสามชุดข้อมูล โดยสัดส่วนจำนวนวัน 80:10:10 ตามลำดับ เมื่อจับคู่ข้อมูลวัดที่ตัดข้อมูลที่มีความผิดพลาดกับข้อมูลภาพถ่ายที่มีความต่อเนื่องติดกันได้สองภาพแล้ว จะมีจำนวนข้อมูลที่สามารถใช้ได้คือ ข้อมูลฝึกสอน 240,959 ตัวอย่าง, ข้อมูลตรวจสอบ 30,488 ตัวอย่าง และข้อมูลทดสอบ 26,097 ตัวอย่าง

3.4 ขั้นตอนการประมาณและเลือกแบบจำลอง

แบบจำลองฐาน SARIMAX สำหรับแบบจำลองอนุกรมเวลาที่มีความเป็นฤดูกาล เราจะเลือกอันดับ d โดยการสังเกตกราฟ ACF ของค่า I ที่หาผลต่าง เลือกอันดับ T โดยดูความเป็นฤดูกาลของ I กำหนดช่วงที่เป็นไปได้ของอันดับ p, q โดยสังเกตจากกราฟ PACF และ ACF ตามลำดับ [SS10] และกำหนดค่า P, D, Q ด้วยความรู้เดิม เนื่องจากแบบจำลอง SARIMAX เป็นแบบจำลองอนุกรมเวลา การประมาณแบบจำลองจะใช้ข้อมูลตั้งแต่วันที่ 5 กุมภาพันธ์ 2565 จนถึงวันที่ 31 ตุลาคม 2565 และทดสอบแบบจำลองด้วยข้อมูลตั้งแต่วันที่ 1 พฤศจิกายน 2565 เป็นต้นไป ในขณะที่การแบ่งข้อมูลสำหรับฝึกสอนและทดสอบแบบจำลองอื่น ๆ จะมีการคละวันภายในปี

จึงเป็นเหตุผลที่เราจะไม่นำผลสมรรถนะของแบบจำลองนี้มาเทียบโดยตรงกับแบบจำลองอื่น ๆ ได้


แบบจำลองการพยากรณ์ความเข้มแสงอาทิตย์ ในขั้นตอนการพัฒนาจะใช้ข้อมูล I และ P จริงในการประมาณแบบจำลอง และทดสอบความคลาดเคลื่อนของการทำนาย P ด้วยข้อมูล $I(t+30)$ ที่ได้จากการพยากรณ์ของแบบจำลอง CNN-LSTM

4 ผลลัพธ์การดำเนินการ

ผลลัพธ์การดำเนินการแบ่งเป็น 3 ส่วน ได้แก่ ผลการสกัดคุณลักษณะที่บ่งบอกถึงดัชนีเมฆ ผลลัพธ์การพยากรณ์ I ของแบบจำลองต่าง ๆ และผลลัพธ์การพยากรณ์ P


4.1 ผลการสกัดดัชนีเมฆ

การสกัดเวกเตอร์ความเร็วเมฆจะสกัดจากภาพถ่ายเมฆที่มีลำดับติดกัน (ในบริบทของโครงการนี้คือ 10 นาที) เพื่อหาเวกเตอร์ความเร็วสำหรับทุก ๆ พิกเซลในภาพ **Overview R channel** ดังตัวอย่างรูปที่ 11 จากนั้นนำเวกเตอร์ที่ได้ไปประมาณความเข้มของพิกเซลในอนาคตด้วยวิธีการประมาณความเข้มที่พิกเซลย่อย ซึ่งผลลัพธ์จะเป็นการทำนายภาพถ่ายเมฆในอนาคตตัวอย่างดังรูปที่ 12

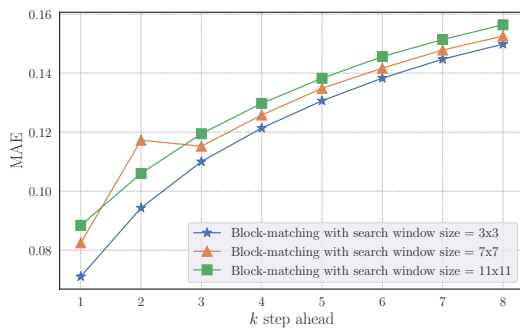


รูปที่ 11: ตัวอย่างการสกัด CMV จากภาพถ่ายเมฆที่มีลำดับติดกัน

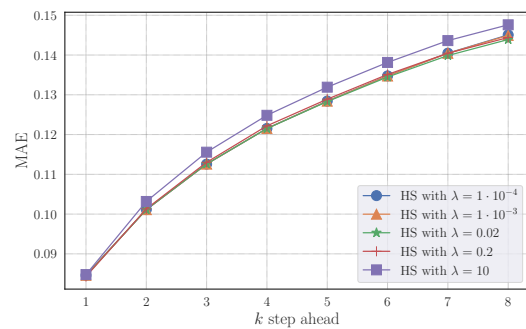
รูปที่ 13a และรูปที่ 14b แสดงให้เห็นว่าการสกัดเมฆด้วยวิธีเทียบบล็อกให้ผลที่ดีเมื่อใช้ระยะค้นหาน้อย เนื่องจากการกำหนดระยะค้นหาส่งผลให้ขนาดของ CMV โดยรวมมีค่าน้อย เราจึงสรุปว่าเมฆที่สกัดจากภาพ **Cloud mask** มีความเร็วเมฆที่ค่อนข้างน้อย ในส่วนของรูปที่ 13b และรูปที่ 14a พบว่าเมื่อ $\lambda = 0.2$ จะให้ผลลัพธ์ที่ดีกว่า สะท้อนให้เห็นว่าเมฆมีคุณสมบัติที่ขัดแย้งกับสมมติฐานตั้งต้น นั่นคือ พิกเซลของเมฆไม่ได้เคลื่อนที่ด้วยความเร็วเดียวกันอย่างต่อเนื่อง เมฆมีการก่อตัว/สลายตัว และมีการแผ่ขยาย เนื่องจากที่ระยะการพยากรณ์น้อย ๆ นั้นความแปรปรวนของเมฆ เช่น การแผ่ขยาย หรือการก่อตัวสลายตัวของเมฆนั้นยังไม่แสดงผลที่ชัดเจน จึงทำให้ที่ระยะการพยากรณ์ 30, 60, 90 และ 120 นาทีนั้นวิธีเทียบบล็อกให้ผลลัพธ์ที่ดีกว่า แต่เมื่อระยะการพยากรณ์สูงขึ้นเป็น 150, 180, 210 และ 240 นาที วิธีของ Horn-Schunck จะให้ผลลัพธ์ที่ดีกว่าดังรูปที่ 13c



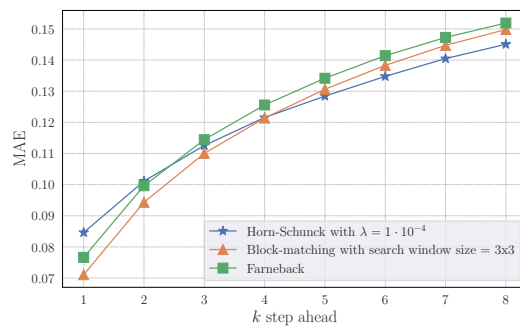
รูปที่ 12: ตัวอย่างการพยากรณ์ภาพถ่ายเมฆ Overview R channel ในระยะ 1, 2, 3 และ 4 ชั่วโมงล่วงหน้าของเวลาเริ่มต้น ณ วันที่ 11 พฤศจิกายน พ.ศ. 2565 เวลา 12:40 (UTC+7)



(a) Block-matching




(b) Horn-Schunck




(c) เปรียบเทียบผลการทดลองจากทุกวิธี

รูปที่ 13: ผลลัพธ์การปรับ hyperparameter ของแต่ละวิธีในการคำนวณ CMV




(a) Horn-Schunck

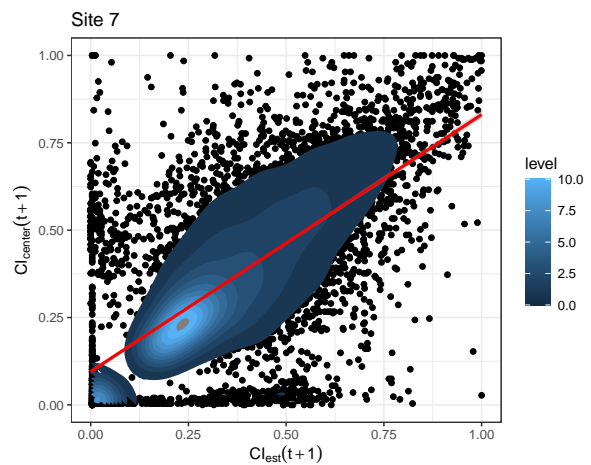


(b) Block-matching

รูปที่ 14: ผลการเปรียบเทียบสมรรถนะแต่ละ hyperparameter ของวิธีเทียบบล็อกและวิธี Horn-Schunck ที่ระยะ 30 นาทีล่วงหน้า



(a) สถานที่ 48 (13.7364 °N, 100.5226 °E)



(b) สถานที่ 7 (15.6353 °N, 100.4763 °E)

รูปที่ 15: ความสัมพันธ์ระหว่างค่าดัชนีเมฆที่ผ่านการประมาณ เทียบกับดัชนีเมฆจริงที่เวลา 30 นาทีข้างหน้าของตัวอย่างสถานที่ 7 และ 48 ด้วยวิธี Horn-Schunck จากช่อง Overview R channel

4.2 ผลลัพธ์การพยากรณ์ความเข้มแสงอาทิตย์


ในหัวข้อนี้จะอธิบายถึงผลลัพธ์การพัฒนาแบบจำลองพยากรณ์ซึ่งมีการเลือกตัวแปรทำนายและตัวแปรขาออก และผลลัพธ์การพยากรณ์ของแบบจำลองดังนี้

แบบจำลองฐาน SARIMAX

ในส่วนนี้จะแสดงผลที่ได้จากการพยากรณ์ด้วยแบบจำลองฐาน SARIMAX โดยจากการประมาณแบบจำลองที่มี exogeneous input คือ I_{clr} และดัชนีเมฆ มีผลลัพธ์ของสัมประสิทธิ์ดังตารางที่ 1

ตารางที่ 1: สัมประสิทธิ์จากการประมาณแบบจำลอง SARIMAX

Variable	Coefficient	Standard error	z	p-value	Confidence bound
I_{clr}	0.702	0.012	56.63	0.000	[0.677 0.726]
CI	-252.22	9.65	-26.13	0.000	[-271.13 -233.30]

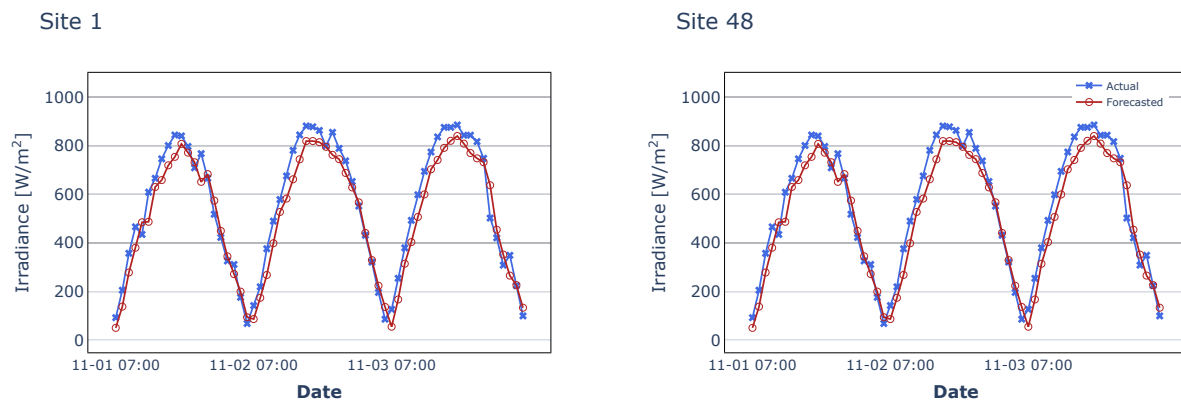


รูปที่ 16: การเปรียบเทียบลำดับความสำคัญของตัวแปรเพื่อทำนาย I ด้วยกราฟแลสโซ

โดยการสังเกตค่า p - value จะพบว่าเมื่อใช้ดัชนีเมฆเป็นตัวแปรภายนอกจะสามารถทำนาย I ได้ และจากรูปที่ 16 ที่แสดงให้เห็นว่าความสัมพันธ์ของ $CI(t)$ ส่งผลต่อ I มากกว่าที่ $I(t - 25)$ ส่งผลต่อ I เราจึงสามารถสรุปว่าข้อมูลเมฆช่วยเพิ่มสมรรถนะให้การพยากรณ์ แต่เนื่องจากการใช้ดัชนีเมฆที่สกัดมาพยากรณ์ในแบบจำลองอนุกรมเวลานั้น เราจะมีข้อจำกัดในเรื่องของข้อมูลภาพที่ขาดหาย จึงส่งผลให้การใช้ค่า lag ของตัวแปรนอกหรือก็คือ I เกิดความผิดพลาด ทำให้ประสิทธิภาพการพยากรณ์เมื่อใช้ดัชนีเมฆด้วยไม่ดีเท่าที่ควร เราจึงนำเสนอเพียงประสิทธิภาพการพยากรณ์ที่ใช้ exogenous factors คือ I_{ct} เท่านั้น โดยผลการพยากรณ์ล่วงหน้า 30 นาที มีตัวอย่างแสดงในรูปที่ 17 และประสิทธิภาพการพยากรณ์ดังตารางที่ 2

ตารางที่ 2: ประสิทธิภาพการพยากรณ์ของแบบจำลอง SARIMAX

Metric	$t + 30$	$t + 60$	$t + 90$	$t + 120$	$t + 150$	$t + 180$	$t + 210$	$t + 240$
MAE	67.89	90.20	106.32	118.04	126.68	132.46	135.81	136.85
NRMSE	21.05	24.65	26.88	28.4	29.58	30.47	31.15	31.71



(a) สถานีที่ 1

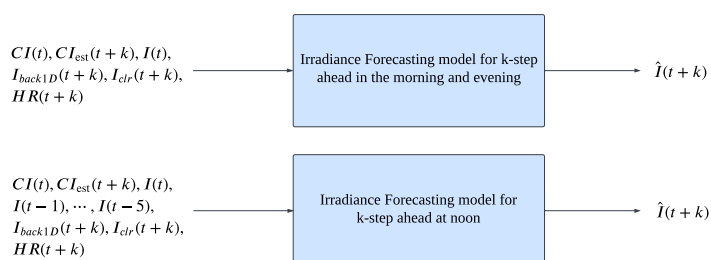
(b) สถานีที่ 48

รูปที่ 17: ตัวอย่างการพยากรณ์ล่วงหน้า 30 นาทีด้วยแบบจำลอง SARIMAX

กลุ่มแบบจำลองการเรียนรู้ด้วยเครื่อง

ได้แก่ Linear regression, Support vector regression, Random forest, LightGBM จะแบ่งตามช่วงเวลาของค่าพยากรณ์ สำหรับตัวแปรขาออกที่เป็นค่าความเข้มแสงอาทิตย์ที่ระยะ k ชั้นล่วงหน้า $\hat{I}(t + k)$ ได้แก่

1. แบบจำลองสำหรับค่าพยากรณ์ในช่วงเช้าและเย็น หมายถึงแบบจำลองที่ค่าพยากรณ์ที่มีค่าพยากรณ์ตั้งแต่ 07.00 - 09.00 น. และ 16.00 - 17.00 น. ตามลำดับ มีตัวแปรต้นเป็น ค่าดัชนีเมฆจริงที่เวลาปัจจุบัน $CI(t)$, ค่าประมาณดัชนีเมฆเวลาที่ต้องการทำนาย $CI_{est}(t+k)$, ค่าความเข้มแสงอาทิตย์ที่เวลาปัจจุบัน $I(t)$, ค่าความเข้มแสงอาทิตย์ในสภาวะฟ้าใสของเวลาที่ต้องการทำนาย $I_{clr}(t+k)$, ค่าความเข้มแสงอาทิตย์ของเวลาที่ต้องการทำนายของ 1 วันก่อนหน้า $I_{back1D}(t+k)$ และตัวเลขชั่วโมงของเวลาที่ต้องการทำนาย $HR(t+k)$
2. แบบจำลองสำหรับค่าพยากรณ์ช่วงกลางวัน หมายถึงแบบจำลองที่ค่าพยากรณ์อยู่ในช่วงเวลา 09.30 - 15.30 น. มีตัวแปรต้นเหมือนกับแบบจำลองในช่วงเช้าและเย็นแต่จะเพิ่มความเข้มแสงอาทิตย์ในเวลา ก่อนหน้าได้แก่ $I(t-1), \dots, I(t-5)$ ดังรูปที่ 18



รูปที่ 18: แผนผังตัวแปรขาเข้าและตัวแปรขาออกสำหรับแบบจำลองพยากรณ์ความเข้มแสงอาทิตย์

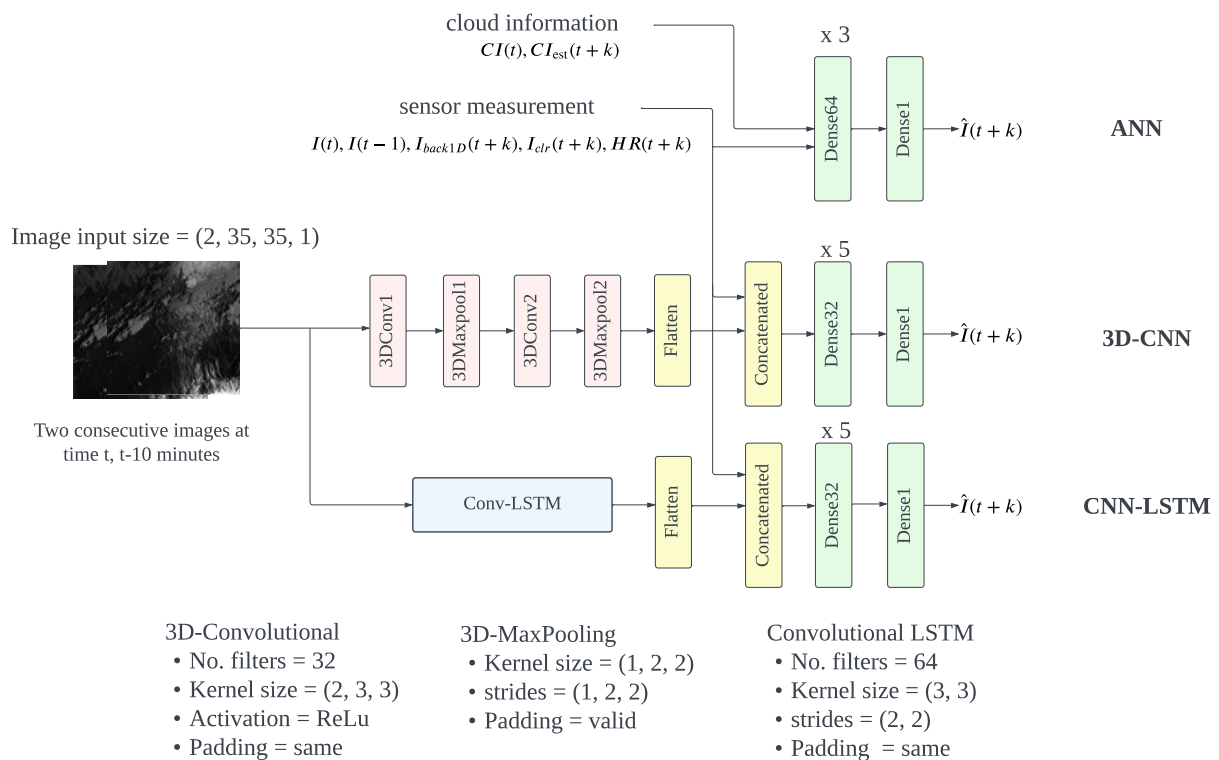
กลุ่มแบบจำลองการเรียนรู้เชิงลึก

แบบจำลองการเรียนรู้เชิงลึกที่ใช้สำหรับการพยากรณ์ค่า $\hat{I}(t+k)$ มีตัวแปรทำนายที่ใช้ดังนี้

1. ANN ใช้ข้อมูลการประมาณดัชนีเมฆร่วมกับตัวแปรจากข้อมูลวัดแต่ไม่แบ่งแยกช่วงของค่าพยากรณ์นั้นคือ มีตัวแปรขาเข้าเป็น $CI(t), CI_{est}(t+k), I(t-1), I(t), I_{clr}(t+k), I_{back1D}(t+k)$ และ $HR(t+k)$
2. 3D-CNN ไม่ใช้ดัชนีเมฆที่สกัดได้เหมือนวิธีอื่นแต่จะอาศัยโครงสร้างแบบจำลองที่มีการทำสังวัตนาการสามมิติ เพื่อสกัดความสัมพันธ์เชิงพื้นที่และเวลาของข้อมูลภาพถ่ายเมฆร่วมกับข้อมูลวัดผ่านชั้น dense ของแบบจำลอง ได้แก่ $I(t), I(t-1), I_{clr}(t+k), I_{back1D}(t+k)$ และ $HR(t+k)$
3. CNN-LSTM ใช้โครงสร้างของแบบจำลองที่สกัดหาความสัมพันธ์ของข้อมูล โดยการทำสังวัตนาการข้อมูลภาพในสองมิติเพื่อส่งผ่านไปยังเซลล์ LSTM จากนั้นนำข้อมูลขาออกพร้อมกับข้อมูลวัดชุดเดียวกับแบบจำลอง 3D-CNN

รายละเอียดโครงสร้างภายในของแบบจำลองปรากฏดังรูปที่ 19

จากตารางที่ 3 ของการพยากรณ์ I ระยะ 30 นาทีล่วงหน้า จะเห็นว่าค่าความผิดพลาดของทุกแบบจำลองมีค่าสูงสำหรับค่าพยากรณ์ช่วงกลางวัน เนื่องจากปริมาณ I ในช่วงกลางวันมีค่าเฉลี่ยและความผันผวนสูงเทียบ กับปริมาณ I ในช่วงเช้าและเย็น เมื่อพิจารณาสมรรถนะแต่ละแบบจำลองพบว่า แบบจำลอง CNN-LSTM ที่สกัดความสัมพันธ์เชิงพื้นที่และเวลาผ่านการทำสังวัตนาการแล้วนำผ่านเข้าเซลล์ LSTM มีประสิทธิภาพดีที่สุดในเกือบทุกรายชั่วโมงของค่าพยากรณ์ รองลงมาด้วยแบบจำลอง 3D-CNN ที่สกัดความสัมพันธ์ของข้อมูลผ่านการทำสังวัตนาการในสามมิติ ผลลัพธ์ที่ได้ชี้ให้เห็นว่าในระยะการพยากรณ์ระยะ 30 นาทีล่วงหน้า การใช้แบบจำลองกลุ่ม CNN ที่สกัดคุณลักษณะจากภาพถ่ายเมฆลำดับติดกันสองภาพ สามารถอธิบายตัวแปร $I(t+1)$ ได้ดีกว่าการใช้ตัวแปรที่สกัดคุณลักษณะของข้อมูลภาพด้วยการใช้เวกเตอร์ความเร็วเมฆ




รูปที่ 19: แผนผังตัวแปรขาเข้าและตัวแปรขาออกสำหรับแบบจำลองการเรียนรู้เชิงลึก

ตารางที่ 3: MAE ของการพยากรณ์ความเข้มแสงอาทิตย์พิจารณาในแต่ละจุดเวลาของค่าพยากรณ์ สำหรับระยะเวลาการพยากรณ์ล่วงหน้า 30 นาที ของทุกแบบจำลอง

เวลาของค่าพยากรณ์	Linear	SVR	RF	LGBM	ANN	3D-CNN	CNN-LSTM
07:00	32.84	21.31	21.25	21.61	21.76	24.73	21.52
07:30	37.39	32.41	32.37	32.83	32.97	33.50	32.24
08:00	46.55	40.69	41.28	41.26	41.19	40.94	40.57
08:30	56.75	52.35	53.77	53.47	52.37	53.23	51.28
09:00	69.11	65.79	67.39	67.23	66.39	66.90	64.02
09:30	85.24	80.56	82.44	82.85	81.09	78.97	76.93
10:00	94.19	88.31	89.95	90.37	88.84	83.58	82.88
10:30	101.10	95.06	97.79	98.40	95.81	92.53	90.27
11:00	114.77	104.39	107.50	108.49	105.64	102.26	100.86
11:30	112.81	105.05	109.42	109.53	105.46	97.83	98.14
12:00	125.53	116.52	120.58	121.06	117.33	114.25	110.21
12:30	128.89	121.10	124.93	125.76	120.97	118.59	116.71
13:00	125.41	116.25	121.37	120.85	116.57	114.98	111.45
13:30	121.24	116.71	119.87	118.50	117.29	116.31	115.44
14:00	110.33	106.21	110.75	109.20	107.30	104.32	104.27
14:30	104.50	101.01	101.31	99.54	99.05	99.48	101.68
15:00	97.18	90.12	90.55	90.24	88.86	88.16	87.76
15:30	70.43	63.28	66.12	66.99	64.16	65.87	67.89
16:00	54.76	51.60	54.03	54.07	51.55	50.74	53.88
16:30	46.32	42.88	44.06	43.49	42.38	44.32	48.33
17:00	35.69	28.98	30.43	30.48	30.20	30.73	31.62


พิจารณาในกลุ่มแบบจำลองการเรียนรู้ด้วยเครื่องที่ใช้คุณลักษณะจากวิธีเวกเตอร์ความเร็วเมฆ แบบจำลองกลุ่ม tree-based ได้แก่ Random forest และ LightGBM มีประสิทธิภาพแบบจำลองใกล้เคียงกันในเกือบทุกจุดเวลา แต่ดีกว่าแบบจำลอง SVR และ ANN ดังรูปที่ 20 จากรูปที่ 21a ในวันที่แบบจำลองพยากรณ์ได้ดีจะเป็นวันที่ดัชนีเมฆมีค่าต่ำเกือบทั้งวัน กล่าวคือ เป็นวันที่ท้องฟ้าโปร่งและค่าวัด I จะมีความผันผวนต่ำ ค่าประมาณดัชนีเมฆ CI_{est} ก็มีแนวโน้มเดียวกับค่าดัชนีเมฆจริงเช่นกัน แต่ในวันที่แบบจำลองพยากรณ์ออกมาได้ไม่ดีดังรูปที่ 21b เป็นวันที่ทั้งค่าวัด I และดัชนีเมฆจริงมีความผันผวนสูง ค่าประมาณดัชนีเมฆมีความผิดพลาดและเปลี่ยนแปลงตามความผันผวนของดัชนีเมฆจริงไม่ทันในหลายจุดเวลา ทำให้แบบจำลองพยากรณ์ออกมาได้ไม่ดีขึ้น ตัวอย่างการพยากรณ์ตัวแทนแต่ละกลุ่มแบบจำลองในการพยากรณ์ระยะ 30 นาทีล่วงหน้าของวันที่สภาพอากาศดี, กลางและแย่พิจารณาจากดัชนีฟ้าใสปรากฏดังรูปที่ 22




รูปที่ 20: MAE รายชั่วโมงในระยะพยากรณ์ 30 นาทีล่วงหน้า ของแบบจำลอง SVR, LightGBM, ANN และ CNN-LSTM

สำหรับทุกระยะการพยากรณ์ 30,60, ..., 240 นาทีล่วงหน้า จากรูปที่ 23 ยิ่งระยะพยากรณ์นานขึ้น ค่าความผิดพลาดในการทำนายของแบบจำลองจะยิ่งสูงขึ้น โดยความสัมพันธ์ของค่าพยากรณ์และค่าวัด I จริงจะกระจายตัวมากขึ้น เมื่อพิจารณา MAE และ NRMSE ในรูปที่ 24a, รูปที่ 24b, ตารางที่ 4 และ ตารางที่ 5 จะเห็นว่าหากเราไม่ Normalized ค่าความผิดพลาด กราฟ MAE จะมีแนวโน้มหักลงในระยะพยากรณ์ที่สูงขึ้น อันเนื่องมาจากแบบจำลองที่ระยะพยากรณ์ต่างกันจะมีค่าเฉลี่ยของความเข้มแสงอาทิตย์ที่ไม่เท่ากัน เมื่อดูจากแนวโน้มของค่า NRMSE ในระยะการพยากรณ์ล่วงหน้าไม่เกิน 120 นาที แบบจำลองกลุ่ม CNN มีประสิทธิภาพที่ดีกว่ากลุ่มแบบจำลองการเรียนรู้ด้วยเครื่องปกติ แต่เมื่อระยะการพยากรณ์มากขึ้นแบบจำลองในกลุ่ม tree-based จะมีสมรรถนะที่ดีกว่า (ยกเว้นระยะ 180 นาที) จึงสรุปได้ว่าการใช้ภาพถ่ายเมฆเพียงสองรูปที่ติดกันจะสามารถสกัดความสัมพันธ์ออกมาได้ดีในระยะการพยากรณ์ที่ไม่มากนัก การใช้เพียงแค่สองภาพอาจไม่สามารถอธิบายความสัมพันธ์ภาพถ่ายเมฆในอดีตกับตัวแปร I ในอนาคตได้ดีพอ แต่หากจะเพิ่มจำนวนลำดับภาพถ่ายเมฆที่ติดกันแหล่งข้อมูลภาพจากสถานี CUEE ก็มีข้อมูลสูญหายในลักษณะคาดเดาไม่ได้สัดส่วนสูง กล่าวคือ ไม่สามารถเลือกลำดับภาพติดกันต่อเนื่องได้ยาวมากนัก อีกทั้งแบบจำลองการเรียนรู้เชิงลึกโดยทั่วไปต้องใช้ปริมาณข้อมูลฝึกสอนที่เยอะ ซึ่งแปรผันตรงกับความซับซ้อนของแบบจำลอง ในที่นี้แบบจำลอง CNN-LSTM มีพารามิเตอร์แบบจำลองเท่ากับ 5,172,065 โดยที่ข้อมูลในการฝึกสอนมีเพียง 271,447 ลำดับภาพถ่ายสองรูปติดกัน ด้วยข้อจำกัดนี้แบบจำลอง tree-based ที่ใช้คุณลักษณะจากเวกเตอร์ความเร็วเมฆที่มีสมรรถนะที่ดีกว่าหรือพอ ๆ กันจึงเหมาะสมและใช้ต้นทุนการคำนวณที่น้อยกว่าในกรณีที่กำหนดการใช้ภาพถ่ายที่ติดกันได้เพียงสองรูปต่อเนื่อง

หากเปรียบเทียบกับแบบจำลองจากงานวิจัยในอดีต เช่น จาก [GCM+22] ที่พัฒนาแบบจำลองจากภาพถ่ายเมฆด้วยโครงสร้างแบบจำลอง 3D-CNN และ CNN-LSTM โดยไม่ใช้ข้อมูลวัดอื่น มีประสิทธิภาพการพยากรณ์ในระยะ 30 นาทีล่วงหน้าด้วย NRMSE เท่ากับ 35 % และ NRMSE เท่ากับ 55 % ที่ระยะการพยากรณ์ล่วงหน้า 240 นาที อาจเห็นได้ว่าแบบจำลองที่ดีที่สุดจากโครงการนี้มีสมรรถนะที่ดีกว่า แต่ต้องคำนึงถึงปัจจัยที่ว่าโครงการนี้ มีการใช้ข้อมูลวัด ได้แก่ ความเข้มแสงอาทิตย์ที่เวลาปัจจุบันและอดีต ซึ่งเป็นตัวแปรสำคัญที่สามารถ




(a) ตัวอย่างการพยากรณ์ความเข้มแสงอาทิตย์ใน 3 วันที่ค่า MAE ต่ำที่สุด




(b) ตัวอย่างการพยากรณ์ความเข้มแสงอาทิตย์ใน 3 วันที่ค่า MAE สูงที่สุด

รูปที่ 21: ตัวอย่างการพยากรณ์ระยะ 30 นาทีล่วงหน้าในวันที่ประมาณได้ดีและไม่ดีของแบบจำลอง SVR




รูปที่ 22: ตัวอย่างการพยากรณ์ด้วยแบบจำลอง SVR, LightGBM, ANN และ CNN-LSTM ในระยะพยากรณ์ล่วงหน้า 30 นาที ในวันที่สภาพอากาศดี, กลางและแย่มากตามลำดับ


อธิบายความเข้มแสงอาทิตย์ในอนาคตได้ดีตัวหนึ่ง จึงทำให้สมรรถนะแบบจำลองของเราดีกว่า หรือถ้าเทียบกับแบบจำลอง Irradiance Net [NIK21] ที่มีสมรรถนะการพยากรณ์ I อยู่ที่ MAE เท่ากับ 101.32 W/m^2 ที่ระยะการพยากรณ์ 240 นาที แบบจำลองของโครงการเราที่สมรรถนะดีที่สุดหาคัดจาก MAE คือแบบจำลอง 3D-CNN มี MAE เท่ากับ 127.27 W/m^2 เห็นว่ามีค่าต่างกันเป็นหลักถึงสิบวัตต์ หรือผลิตภัณฑ์ของบริษัท Solcast ที่มีสมรรถนะการพยากรณ์อยู่ที่ NRMSE เท่ากับ 4.3 % ที่ระยะพยากรณ์ 60 นาทีและ NRMSE เท่ากับ 6.4 % (รวมค่าพยากรณ์ในช่วงกลางคืน) ที่ระยะพยากรณ์ 120 นาที แบบจำลองที่ดีที่สุดของโครงการนี้ในระยะดังกล่าว



รูปที่ 23: ความสัมพันธ์ระหว่างค่าพยากรณ์แสงอาทิตย์ และค่าความเข้มแสงอาทิตย์ที่วัดได้จริงของทุกแบบจำลองในแต่ละระยะการพยากรณ์ โดยเส้นคอนทัวร์ประมาณมาจากวิธี KDE



(a) Mean absolute error



(b) Normalized root mean squared error

รูปที่ 24: สมรรถนะแบบจำลองในแต่ละระยะการพยากรณ์

คือ CNN-LSTM NRMSE เท่ากับ 25.17 % และ NRMSE เท่ากับ 28.81 % ตามลำดับ แต่ทั้งนี้ต้องพิจารณาถึงชนิดข้อมูลภาพที่ต่างกัน แบบจำลอง Irradiance Net ใช้ภาพถ่าย Cloud albedo ซึ่งสามารถอธิบายเมฆจริงได้

ตารางที่ 4: MAE ของทุกแบบจำลองในแต่ละระยะการพยากรณ์ล่วงหน้า

Minutes Ahead	Linear	SVR	RF	LGBM	ANN	3D-CNN	CNN-LSTM	\bar{I} [W/m^2]
30	85.24	79.09	81.33	81.31	79.41	78.09	77.34	481.71
60	106.97	99.12	101.40	101.90	99.43	105.73	97.93	503.40
90	120.86	112.66	116.00	115.73	112.98	111.14	112.14	515.93
120	130.24	124.03	125.77	125.58	122.09	119.74	119.52	515.25
150	138.34	132.30	134.56	134.39	130.55	129.15	129.47	516.83
180	141.93	136.31	139.34	138.99	135.28	134.70	133.09	508.80
210	140.84	135.82	138.31	138.35	135.19	140.01	132.59	483.81
240	135.71	131.17	133.40	133.50	130.73	127.27	127.92	449.94

ตารางที่ 5: NRMSE ของทุกแบบจำลองในแต่ละระยะการพยากรณ์ล่วงหน้า

Minutes Ahead	Linear	SVR	RF	LGBM	ANN	3D-CNN	CNN-LSTM
30	26.27	25.98	25.70	25.62	25.91	25.82	25.17
60	29.88	29.66	29.12	29.11	29.57	31.77	28.81
90	32.03	32.03	31.46	31.35	31.91	31.23	31.44
120	34.18	34.68	33.66	33.54	34.20	33.25	33.25
150	35.83	36.60	35.47	35.41	36.20	35.59	36.09
180	37.11	38.10	36.91	36.85	38.01	36.31	37.21
210	38.61	39.82	38.48	38.46	39.08	40.25	38.95
240	40.21	41.61	40.15	40.16	41.49	40.26	40.32

ดี แต่โครงการนี้ไม่ได้ใช้ข้อมูลภาพเมฆดังกล่าว รวมถึงปริมาณข้อมูลที่ใช้ในการฝึกสอนแบบจำลอง Irradiance Net มีปริมาณข้อมูลสะสมถึง 5 ปี มากกว่าโครงการนี้ที่ใช้ข้อมูลเพียงหนึ่งปี อีกทั้งข้อมูลที่ใช้มีปัจจัยทางด้านตำแหน่งพื้นที่และภูมิอากาศที่ต่างกัน ข้อมูลที่เราใช้แท้จริงแล้วมาจาก I ในหลายพื้นที่ที่มีค่าเฉลี่ย I ต่างกัน การนำข้อมูลมารวมกันเพื่อฝึกสอนเป็นแบบจำลองเดี่ยวจะทำให้แบบจำลองพยายามทำให้ดีในทุก ๆ ที่ตั้งสถานี ซึ่งอาจเป็นเหตุผลที่ทำให้สมรรถนะไม่ได้ดีเทียบเท่ากับการทดลองที่พิจารณาข้อมูลเฉพาะตำแหน่งที่ตั้งเดียว

4.3 ผลลัพธ์การพยากรณ์กำลังไฟฟ้าแสงอาทิตย์


ในขั้นตอนการแปลงความเข้มแสงอาทิตย์ไปยังกำลังไฟฟ้าแสงอาทิตย์นั้น เราได้สำรวจข้อมูลพบว่าในแต่ละสถานี โดยส่วนมากนั้นจะมีความสัมพันธ์ความเข้มแสงอาทิตย์และกำลังไฟฟ้าแสงอาทิตย์เป็นแบบเชิงเส้นดังรูปที่ 25a และสถานีส่วนน้อยที่มีความแปรปรวนเกิดขึ้นดังรูปที่ 25b

เราจึงเปรียบเทียบแบบจำลอง Linear regression, แบบจำลอง Linear regression ที่ใช้ Loss function คือ Huber และแบบจำลอง Polynomial regression ในการทำนายค่ากำลังไฟฟ้าแสงอาทิตย์ในแต่ละสถานีแยกกัน เนื่องจากในแต่ละสถานีมีความจุกำลังการติดตั้ง (installed capacity) ไม่เท่ากัน เราจึงใช้ NRMSE เป็นตัวชี้วัดประสิทธิภาพการทำนาย โดยมีผลลัพธ์แสดงในตารางที่ 6 ซึ่งแสดงให้เห็นว่าแบบจำลอง Linear regression

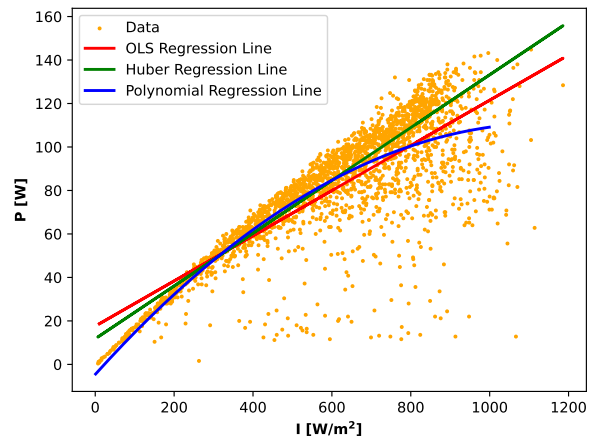
ตารางที่ 6: ผลการเปรียบเทียบ NRMSE ในการทำนายกำลังไฟฟ้าแสงอาทิตย์ของแบบจำลองต่าง ๆ

สถานีที่	Linear	Linear _{Huber}	Polynomial
2	22.50	24.08	22.81
48	19.75	19.97	19.96
ทุกสถานี	22.75	23.42	22.79

ให้ผลลัพธ์ที่ดีที่สุด ด้วยหลัก Bias-Variance Decomposition จึงสรุปว่าค่า \bar{I} ที่ได้จากการพยากรณ์ของโมเดล



(a) สถานีที่ 48



(b) สถานีที่ 2

รูปที่ 25: ความสัมพันธ์ระหว่างความเข้มแสงอาทิตย์เทียบกับกำลังการผลิตไฟฟ้าของสถานีที่ 48 และ 2

CNN-LSTM มีความแปรปรวนที่สูงและในแง่ของการนำไปใช้งานจริง การเลือกใช้แบบจำลองที่มีความซับซ้อนต่ำจึงเหมาะสม

5 บทสรุป

ในโครงการนี้ได้เปรียบเทียบการประมาณดัชนีเมฆในอนาคตด้วยวิธีเทียบบล็อกและวิธีการไหลของแสง พบว่าวิธีเทียบบล็อกสามารถประมาณดัชนีเมฆในอนาคตได้ดีกว่าในระยะการพยากรณ์ล่วงหน้า 120 นาทีแรก หลังจากนั้นวิธีการไหลของแสง Horn-Schunck จะประมาณดัชนีเมฆในอนาคตได้ดีกว่า ถ้าคำนึงถึงการนำไปใช้จริงเพื่อลดต้นทุนการคำนวณ จึงเลือกใช้เฉพาะค่าประมาณดัชนีเมฆในอนาคตจากวิธี Horn-Schunck เพียงวิธีเดียว จากนั้นเมื่อนำไปพัฒนาแบบจำลองพยากรณ์ แบบจำลองที่ใช้คุณลักษณะดังกล่าวจะมีสมรรถนะที่ดีกว่าแบบจำลองที่ใช้วิธีสกัดความสัมพันธ์จากการทำสังวัตนาการ นั่นคือ แบบจำลอง CNN-LSTM ด้วย NRMSE เท่ากับ 25.17% ในขณะที่แบบจำลองที่มีสมรรถนะดีที่สุดในกลุ่มแบบจำลองการเรียนรู้ด้วยเครื่อง ได้แก่ แบบจำลอง LightGBM ที่มี NRMSE เท่ากับ 25.62 % ที่ระยะการพยากรณ์ล่วงหน้า 30 นาทีแรก แต่หากระยะการพยากรณ์ล่วงหน้ามากขึ้นตั้งแต่ 120 นาทีขึ้นไปจะเห็นว่าแบบจำลองการเรียนรู้ด้วยเครื่องในกลุ่ม tree-based มีสมรรถนะที่ดีกว่า ขณะที่ระยะการพยากรณ์ 240 นาทีล่วงหน้า แบบจำลองที่ประสิทธิภาพดีสุดคือ RF ซึ่งมี NRMSE เท่ากับ 40.15% ขณะที่แบบจำลองที่มีสมรรถนะดีที่สุดในกลุ่ม CNN คือ 3D-CNN มี NRMSE เท่ากับ 40.32% อาจไม่มีความแตกต่างกันมากในตัวเลข แต่ถ้าเทียบต้นทุนการคำนวณในการฝึกสอน แบบจำลองในกลุ่ม tree-based มีต้นทุนการคำนวณและปริมาณข้อมูลที่ต้องใช้ในการฝึกสอนต่ำกว่าแบบจำลองในกลุ่ม CNN หากคำนึงถึงการนำไปใช้งานจริงจึงอาจพิจารณาฝึกสอนแบบจำลอง CNN และนำไปใช้จริงเฉพาะช่วงระยะพยากรณ์ไม่เกิน 120 นาที จากนั้นจึงพิจารณาใช้เพียงแบบจำลองในกลุ่ม tree-based สำหรับระยะพยากรณ์ 150-240 นาทีล่วงหน้า ในท้ายที่สุดเมื่อนำค่า \hat{I} ที่ได้มาทำนายค่า P ด้วยแบบจำลองที่มีความซับซ้อนต่ำ จะพบว่าแบบจำลอง Linear regression มีประสิทธิภาพดีที่สุสุดด้วย NRMSE เท่ากับ 22.75 W/m^2

การพยากรณ์ความเข้มแสงอาทิตย์ในอนาคต มีปัจจัยที่เกี่ยวข้อง เช่น ชนิดข้อมูล ปริมาณข้อมูลที่ใช้ในการทดลอง หรือพื้นที่ทำการทดลองที่มีภูมิอากาศและตำแหน่งที่ตั้งแตกต่างกัน ล้วนเป็นสาเหตุให้สมรรถนะการพยากรณ์จากหลากหลายงานวิจัยมีความแตกต่างกัน การเปรียบเทียบประสิทธิภาพระหว่างเทคนิคอาจทำได้โดยควบคุมให้ใช้ชุดข้อมูลเดียวกันเพื่อไม่ให้เกิดความเอนเอียงระหว่างชุดข้อมูล แต่ทั้งนี้หากคำนึงถึงการนำแบบจำลองไปใช้จริงยังคงจำเป็นต้องพัฒนาแบบจำลองในชุดข้อมูลของพื้นที่ที่ต้องการนำไปใช้ รวมไปถึงต้องคำนึงถึงทรัพยากรข้อมูล ต้นทุนการคำนวณต่าง ๆ ให้เหมาะสมกับการใช้งานจริงอีกด้วย

6 กิตติกรรมประกาศ

โครงการนี้สำเร็จลุล่วงไปได้ด้วยดีผู้จัดทำขอขอบคุณทุกคนที่มีส่วนเกี่ยวข้อง ได้แก่ รศ.ดร. จิตโกมุท ส่งศิริ อาจารย์ที่ปรึกษาโครงการที่สละเวลาให้ความรู้และคำปรึกษาอันเป็นประโยชน์ในการทำโครงการด้วยความใส่ใจ ตั้งแต่วันแรกจนถึงวันที่งานเสร็จสมบูรณ์ ขอขอบคุณบริษัท Impact solar ที่สนับสนุนชุดข้อมูลทั้ง 56 สถานีที่ใช้ในการทดลอง รวมถึงขอบคุณสมาชิกภายในครอบครัวทุกคนที่คอยสนับสนุนทรัพย์และกำลังใจ จนผู้จัดทำสามารถสำเร็จมาถึงขั้นปีที่ 4 ได้ คณะผู้จัดทำขอขอบคุณทุกท่านไว้ในโอกาสนี้

เอกสารอ้างอิง

- [AMAS22] Daniel Aicardi, Pablo Musé, and Rodrigo Alonso-Suárez. A comparison of satellite cloud motion vectors techniques to forecast intra-day hourly solar global horizontal irradiation. *Solar Energy*, 233:46–60, 2022.
- [AOE+16] Javier Antonanzas, Natalia Osorio, Rodrigo Escobar, Ruben Urraca, Francisco J Martinez-de Pison, and Fernando Antonanzas-Torres. Review of photovoltaic power forecasting. *Solar energy*, 136:78–111, 2016.
- [APS+19] Maïna André, Richard Perez, Ted Soubdhan, James Schlemmer, Rudy Calif, and Stéphanie Monjoly. Preliminary assessment of two spatio-temporal forecasting techniques for hourly satellite-derived irradiance in a complex meteorological context. *Solar Energy*, 177:703–712, 2019.
- [BGLC12] Coloma Ballester, Lluís Garrido, Vanel Lazcano, and Vicent Caselles. A TV-L1 optical flow method with occlusion detection. In *Joint DAGM (German Association for Pattern Recognition) and OAGM Symposium*, pages 31–40. Springer, 2012.
- [CBK15] Chi Wai Chow, Serge Belongie, and Jan Kleissl. Cloud motion and stability estimation for intra-hour solar forecasting. *Solar Energy*, 115:645–655, 2015.
- [CBSH20] Sylvain Cros, Jordi Badosa, André Szantai, and Martial Haeffelin. Reliability predictors for solar irradiance satellite-based forecast. *Energies*, 13(21):5566, 2020.
- [CeSZ+21] Thomas Carrière, Rodrigo Amaro e Silva, Fuqiang Zhuang, Yves-Marie Saint-Drenan, and Philippe Blanc. A new approach for satellite-based probabilistic solar forecasting with cloud motion vectors. *Energies*, 14(16):4951, 2021.
- [CZW+22] Lilin Cheng, Haixiang Zang, Zhinong Wei, Tao Ding, and Guoqiang Sun. Solar power prediction based on satellite measurements – a graphical learning method for tracking cloud motion. *IEEE Transactions on Power Systems*, 37(3):2335–2345, 2022.
- [Far03] Gunnar Farneback. Two-frame motion estimation based on polynomial expansion. In *Scandinavian conference on Image analysis*, pages 363–370. Springer, 2003.
- [FZ20] Cong Feng and Jie Zhang. Solarnet: A sky image-based deep convolutional neural network for intra-hour solar forecasting. *Solar Energy*, 204:71–78, 2020.
- [GCM+22] Raimondo Gallo, Marco Castangia, Alberto Macii, Enrico Macii, Edoardo Patti, and Alessandro Aliberti. Solar radiation forecasting with deep learning techniques integrating geostationary satellite images. *Engineering Applications of Artificial Intelligence*, 116:105493, 2022.
- [GDTR21] James Gareth, Witten Daniela, Hastie Trevor, and Tibshirani Robert. *An Introduction to Statistical Learning - with Applications in R*. Springer Texts in Statistics. Springer Science+Business Media, 2 edition, 2021.

- [HS81] Berthold KP Horn and Brian G Schunck. Determining optical flow. *Artificial intelligence*, 17(1-3):185–203, 1981.
- [HTF09] Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The elements of statistical learning: data mining, inference and prediction*. Springer, 2 edition, 2009.
- [IP02] Pierre Ineichen and Richard Perez. A new airmass independent formulation for the linke turbidity coefficient. *Solar Energy*, 73(3):151–157, 2002.
- [JK18] Mohammad Jamaly and Jan Kleissl. Robust cloud motion estimation by spatio-temporal correlation analysis of irradiance data. *Solar Energy*, 159:306–317, 2018.
- [Kle13] Jan Kleissl. Solar energy forecasting and resource assessment. pages 21–48, 2013.
- [KMF⁺17] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. Lightgbm: A highly efficient gradient boosting decision tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, pages 3149–3157, 2017.
- [LFQ09] Yong Lv, Qibo Feng, and Liangyu Qi. A study of sub-pixel interpolation algorithm in digital speckle correlation method. In *2008 International Conference on Optical Instruments and Technology: Optoelectronic Measurement Technology and Applications*, volume 7160, pages 740–748. SPIE, 2009.
- [LHH04] Elke Lorenz, Annette Hammer, and Detlev Heinemann. Short term forecasting of solar radiation based on satellite data. In *EUROSUN2004 (ISES Europe Solar Congress)*, volume 1. Freiburg Germany, 2004.
- [LK81] Bruce D Lucas and Takeo Kanade. *An iterative image registration technique with an application to stereo vision*, volume 81. Vancouver, 1981.
- [NIK21] Andreas H Nielsen, Alexandros Iosifidis, and Henrik Karstoft. Irradiancenet: Spatiotemporal deep learning model for satellite-derived solar irradiance short-term forecasting. *Solar Energy*, 228:659–669, 2021.
- [PPSTB21] Emilio Pérez, Javier Pérez, Jorge Segarra-Tamarit, and Hector Beltran. A deep learning model for intra-day forecasting of solar irradiance using satellite-based estimations in the vicinity of a pv power plant. *Solar Energy*, 218:652–660, 2021.
- [SCW⁺15] Xingjian Shi, Zhourong Chen, Hao Wang, Dit Yan Yeung, Wai Kin Wong, and Wang chun Woo. Convolutional lstm network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28, 2015.
- [SS10] R.H. Shumway and D.S. Stoffer. *Time series analysis and its applications: with R examples*. Springer Science & Business Media, 2010.
- [TBF⁺15] Du Tran, Lubomir Bourdev, Rob Fergus, Lorenzo Torresani, and Manohar Paluri. Learning spatiotemporal features with 3D convolutional networks. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, December 2015.
- [TS23] Nuttamon Thungka and Boonyarit Sangsuksunti. Improving cloud attenuation model for ground irradiance estimation across thailand using cloud images from himawari satellite. Faculty of Engineering, Chulalongkorn University, 2023.
- [ZQJ⁺22] Hui-Min Zuo, Jun Qiu, Ying-Hui Jia, Qi Wang, and Fang-Fang Li. Ten-minute prediction of solar irradiance based on cloud detection and a long short-term memory (LSTM) model. *Energy Reports*, 8:5146–5157, 2022.


7 ภาคผนวก

7.1 การสกัดปริมาณเมฆที่ส่งผลกับตำแหน่งที่สนใจ

หลังจากที่คำนวณ CMV แล้ว ขั้นแรกจะกำหนดขอบเขตที่เราคัดเลือกพิกเซลที่ส่งผลต่อแบบจำลอง (candidate pixel) สำหรับทุกพิกเซลในขอบเขตที่เลือกที่มี CMV ในแกน X และ แกน Y เป็น v_x, v_y ตามลำดับ จากนั้นกำหนดฟังก์ชันในตัวแปรเวลา t ของระยะห่างระหว่างพิกเซลที่กำลังคัดเลือกกับพิกเซลที่ตำแหน่งที่ตั้งที่สนใจดัง (13) [CeSZ+21]

$$s(t) = \sqrt{[(x - x_{\text{site}}) + tv_x]^2 + [(y - y_{\text{site}}) + tv_y]^2} \quad (13)$$

เมื่อพิจารณาเงื่อนไขด้านตำแหน่งและความเร็วที่ส่งผลให้พิกเซลเข้าใกล้ตำแหน่งที่ตั้งที่สนใจมากขึ้นเรื่อย ๆ นั่นคือ $\frac{d}{dt}s(t) < 0$ จะได้ว่าถ้าพิกเซลมีตำแหน่งและความเร็วเริ่มต้นดังรูปที่ 26a แล้วพิกเซลจะเข้าใกล้ตำแหน่งที่สนใจมากขึ้นเรื่อย ๆ เสมอ



รูปที่ 26: เงื่อนไขความเร็วเริ่มต้นที่ทำให้ $t_c \geq 0$ และตัวอย่างค่า t_c ในแต่ละกรณี

จากเงื่อนไขจำเป็นของอนุพันธ์อันดับหนึ่งในการเป็นจุดต่ำสุด จะได้ว่าเวลาที่แต่ละพิกเซลจะเข้าใกล้ตำแหน่งที่ตั้งที่สนใจมากที่สุดนั่นคือ $\frac{d}{dt}s(t) = 0$ เป็น

$$t_c = -\frac{(x - x_{\text{site}})v_x + (y - y_{\text{site}})v_y}{v_x^2 + v_y^2} \quad (14)$$

ในกรณีที่พิกเซลไม่ได้มีความเร็วเริ่มต้นดังรูปที่ 26a จะได้ว่า $s(t)$ เป็นฟังก์ชันเพิ่มเสมอ ดังนั้น $t_c = 0$ เมื่อรวม 2 กรณีเข้าด้วยกันจะได้ (15) และมีตัวอย่างแสดงในรูปที่ 26b และรูปที่ 26c

$$t_c = \max\left(0, -\frac{(x - x_{\text{site}})v_x + (y - y_{\text{site}})v_y}{v_x^2 + v_y^2}\right) \quad (15)$$

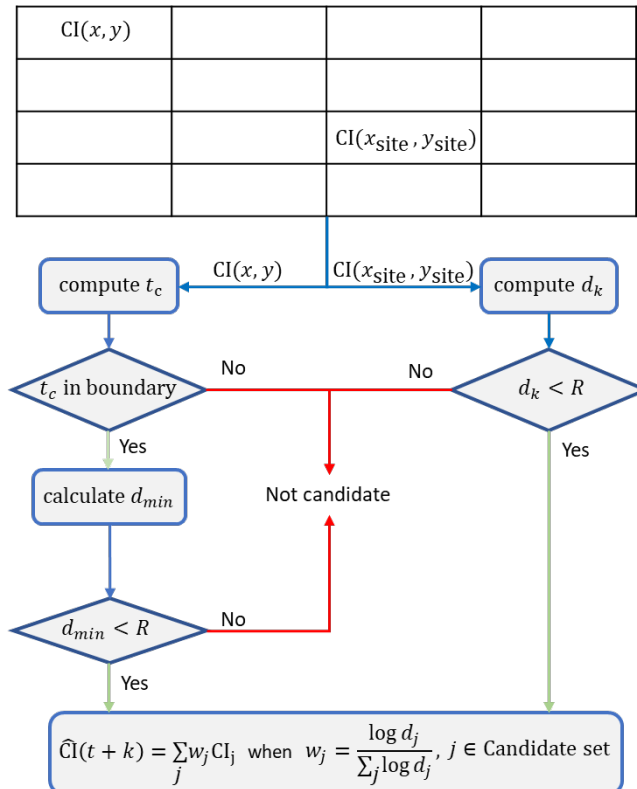
เกณฑ์การคัดเลือก candidate พิกเซล คือ พิกเซลจะต้องมีเวลา t_c อยู่ในช่วงระยะที่ต้องการพยากรณ์ หรือ $t_c \in [f_h - e_0, f_h + e_0]$ เมื่อ $f_h = 3, 6, \dots, 24$ คือระยะที่ต้องการพยากรณ์ และมี $d_{\min} \triangleq d(t_c)$ ไม่เกินระยะ R โดยค่า e_0, R จะถูกปรับให้เหมาะสมสำหรับระยะการพยากรณ์ล่วงหน้าที่แตกต่างกัน หลังจากคัดเลือกตัวแทนพิกเซลจากพิกเซลทั้งหมดในขอบเขตที่กำหนดไว้ นำค่าดัชนีเมฆของพิกเซลที่ถูกเลือกมาหาค่าเฉลี่ย และกำหนดเป็นตัวแปร CI ที่บ่งบอกถึงปริมาณเมฆ ณ ตำแหน่งที่สนใจในอนาคต

การนำเสนอผลรวมดัชนีเมฆ ในโครงการนี้จะนำเสนอวิธีการรวมดัชนีเมฆจากพิกเซลที่ผ่านการคัดเลือกโดยการหาค่าเฉลี่ยถ่วงน้ำหนักที่มีสมมติฐานคือ ยังมีปริมาณเมฆเข้าใกล้ตำแหน่งที่สนใจมาก ก็ยิ่งส่งผลต่อการลด

ทอนความเข้มแสงอาทิตย์มากขึ้นตั้ง (16) ซึ่งจะพิจารณาทั้งตำแหน่งพิกเซลที่ทำการทดลองและตำแหน่งโดยรอบ โดยมีแผนผังขั้นตอนการประมาณค่าดัชนีเมฆ ที่เวลา k ชั้นล่องหนาดังรูปที่ 27

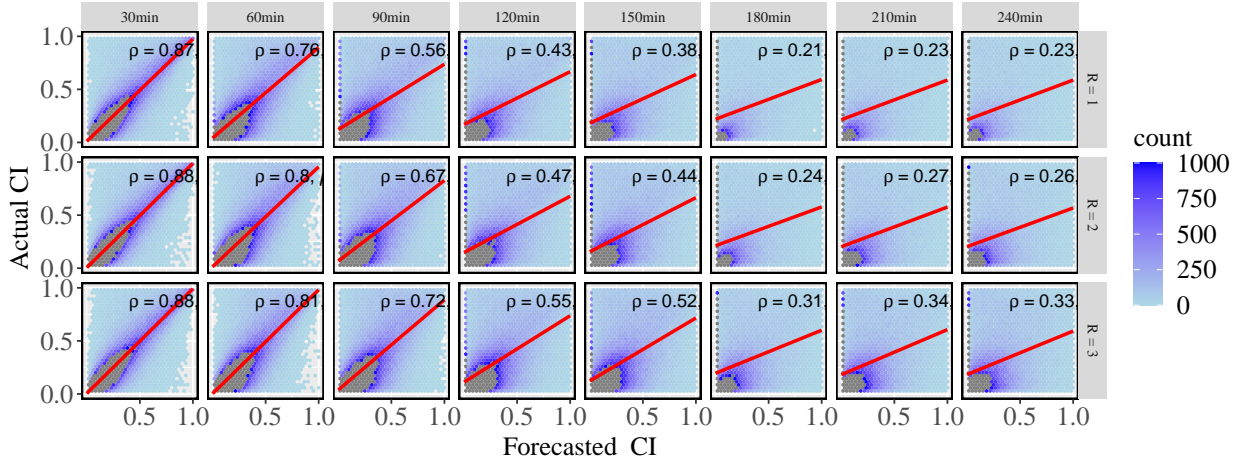
$$\hat{CI}(t+k) = \sum_{j \in \text{candidate}} w_j CI_j \text{ เมื่อ } k = 1, 2, \dots, 8 \tag{16}$$

โดยที่ $w_j = \frac{d_j}{\sum_j d_j}$



รูปที่ 27: กระบวนการหาค่าดัชนีเมฆที่ส่งผลต่อตำแหน่งที่สนใจในเวลา k ชั้นล่องหน้า

ผลการสกัดดัชนีเมฆด้วยเกณฑ์การคัดเลือก รูปที่ 28 แสดงให้เห็นว่าในบางการคัดเลือกนั้นไม่มีดัชนีเมฆที่ผ่านเกณฑ์ แม้อัตราที่ผ่านเกณฑ์ก็จะเป็นตัวแทนดัชนีเมฆในอนาคตได้ดีแค่ในช่วงระยะเวลาการพยากรณ์ 30, 60 และ 90 นาทีล่องหน้าเท่านั้น เราจึงสรุปว่าการสกัดดัชนีเมฆด้วยเกณฑ์การคัดเลือกนั้นยังไม่มีประสิทธิภาพที่ดีพอจะนำมาใช้ในการทดลองต่อไป



รูปที่ 28: ผลการทดลองปรับค่า R ในการสกัดดัชนีเมฆด้วยวิธี candidate pixel

7.2 ปัญหาการหาค่าเหมาะสมสุดใน Horn-Schunck

จาก (5) เราสามารถเขียนให้อยู่ในรูปผลรวมของผลต่างตามตำแหน่งในแกน x, y และเวลา t โดยสมมติให้ภาพที่เป็นข้อมูลนำเข้าสำหรับการสกัดหาเวกเตอร์ความเร็วเมฆมีขนาดเท่ากับ $m \times n$ เราสามารถเขียน (5) ใหม่ได้ดังนี้

$$\begin{aligned} \arg \min_{v_x, v_y} & \sum_{j=1}^{m-1} \sum_{i=1}^{n-1} [v_x(i+1, j) - v_x(i, j)]^2 + [v_x(i, j+1) - v_x(i, j)]^2 \\ & + [v_y(i+1, j) - v_y(i, j)]^2 + [v_y(i, j+1) - v_y(i, j)]^2 \\ & + \lambda \{ [I(i+1, j) - I(i, j)]v_x(i, j) + [I(i, j+1) - I(i, j)]v_y(i, j) + I(i, j, t) - I(i, j, t-1) \}^2 \end{aligned} \quad (17)$$

ด้วย (17) เราจึงสามารถจัดให้อยู่ในรูป (18)

$$\arg \min_{V_x, V_y} \|V_x D_x\|_F^2 + \|D_y V_x\|_F^2 + \|V_y D_x\|_F^2 + \|D_y V_y\|_F^2 + \lambda \|(ID_x) \cdot V_x + (D_y I) \cdot V_y + I_t - I_{t-1}\|_F^2 \quad (18)$$

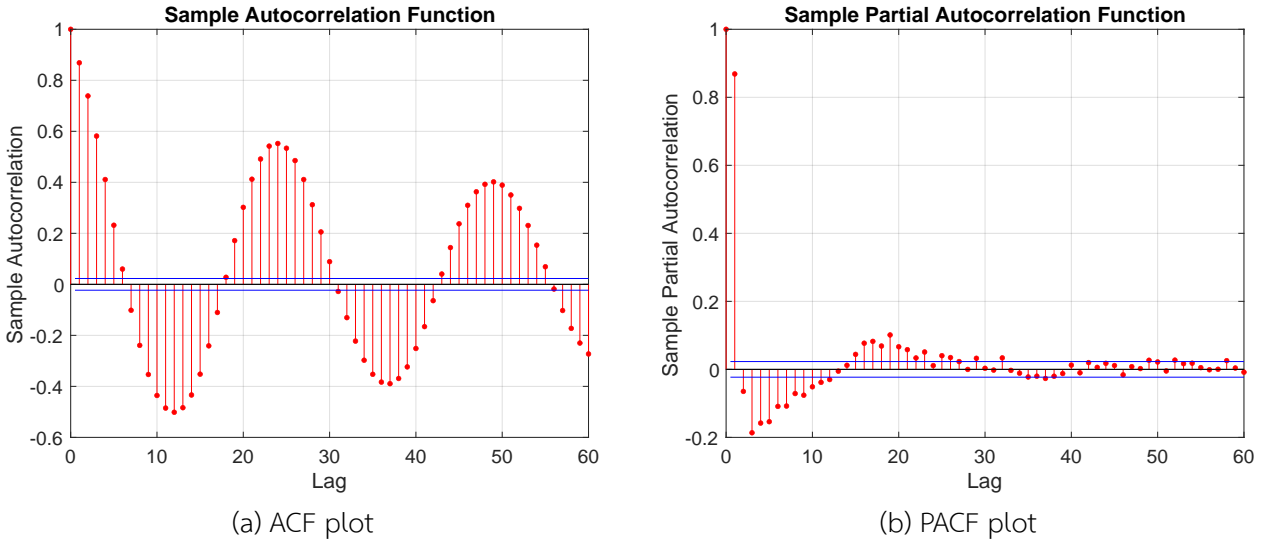
โดยที่ $V_x, V_y \in \mathbb{R}^{1725 \times 1670}$ คือเมทริกซ์ความเร็วเมฆและ D_x, D_y เป็นเมทริกซ์ผลต่าง ซึ่งเขียนอยู่ในรูปเมทริกซ์ได้ดังนี้

$$D_x = \begin{bmatrix} -1 & 0 & 0 & \dots & 0 & 0 \\ 1 & -1 & 0 & \dots & 0 & 0 \\ 0 & 1 & -1 & & \vdots & \vdots \\ & & \ddots & \ddots & & \\ 0 & & & 1 & -1 & 0 \\ 0 & \dots & & 0 & 1 & -1 \\ 0 & & & 0 & 0 & 1 \end{bmatrix}, D_y = \begin{bmatrix} -1 & 1 & 0 & \dots & 0 & 0 \\ 0 & -1 & 1 & & 0 & 0 \\ 0 & 0 & -1 & \ddots & 0 & 0 \\ \vdots & & & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & -1 & 1 \end{bmatrix}$$

7.3 การปรับ hyperparameters หรืออันดับของแบบจำลอง

7.3.1 แบบจำลอง SARIMAX

จากรูปที่ 29 จะเห็นว่ากราฟ ACF มีค่าที่ลู่เข้าหาศูนย์แม้จะยังไม่ได้หาผลต่าง (differencing) เราจึงเลือก $d = 0$ กราฟ ACF มีลักษณะ damped sine function ตั้งแต่ความหน่วงที่ศูนย์ นั่นคือ $\max(0, q - p) = 0$ ดังนั้น $q \leq p$ กราฟ PACF มีอิทธิพลของ damped exponential ตั้งแต่ความหน่วงที่ศูนย์ นั่นคือ $\max(0, p - q) = 0$ ดังนั้น $p \leq q$ จากทั้งสองกรณี เราจะสรุปว่า $p = q$ [SS10] เนื่องจากข้อมูลมีความเป็นคาบ โดยจะมีช่วงเวลาที่ตรงกัน



รูปที่ 29: Autocorrelation function และ Partial autocorrelation function ของความเข้มแสงอาทิตย์

ทุก ๆ 24 ข้อมูล เราจึงเลือกอันดับของคาบฤดูกาล T (seasonal period) เท่ากับ 24 โดยการมีผลการคัดเลือกอันดับแบบจำลองโดยใช้ BIC เป็นตัวชี้วัดแสดงดังตารางที่ 7

ตารางที่ 7: ผลการปรับอันดับของแบบจำลอง SARIMAX

p	q	BIC	Δ BIC
0	0	94842	4502
1	1	90340	0
2	2	90358	18
3	3	90342	2

7.3.2 แบบจำลอง Random forest

แบบจำลอง Random forest มี hyperparameters ที่ต้องเลือกก่อนฝึกสอนแบบจำลองดังนี้

1. $n_{estimators}$ จำนวนต้นไม้ทั้งหมดใน forest หากต้นไม้มีจำนวนมาก ความแปรปรวนที่ส่งผลต่อการเปลี่ยนชุดข้อมูลจะลดลง
2. $max\ depth$ ความลึกสูงสุดของต้นไม้แต่ละต้นที่แบบจำลองยอมรับได้ เป็นพารามิเตอร์ที่ป้องกันไม่ให้ต้นไม้แต่ละต้นมีความลึกมากเกินไป เพราะหากต้นไม้มีความลึก ต้นไม้จะพยายามเข้ากันได้กับชุดข้อมูลฝึกสอนให้มากที่สุด ซึ่งจะก่อให้เกิดความแปรปรวนหากเปลี่ยนชุดข้อมูลที่ใช้ทดลอง

3. min samples split เป็นพารามิเตอร์ที่ควบคุมจำนวนชุดข้อมูลน้อยสุดที่แต่ละ node ต้องมี เพื่อการแตก node ขึ้นต่อไป หากปรับค่าน้อยต้นไม้เติบโตและแตก node ในทิศลึกลงไปได้ง่าย ซึ่งอาจส่งผลให้เกิดปัญหาความแปรปรวนจากการเปลี่ยนชุดข้อมูลฝึกสอน
4. min samples leaf เป็นพารามิเตอร์ที่ควบคุมจำนวนชุดข้อมูลน้อยสุดที่แต่ละต้นไม้ต้องมีในแต่ละ leaf node หากมีค่าน้อย ต้นไม้จะเติบโตจนอาจมีจำนวนข้อมูลเหลือใน leaf node น้อยได้ หมายความว่า ต้นไม้อาจเติบโตในทิศทางที่ลึกเกิน ไปซึ่งอาจส่งผลให้เกิดปัญหาความแปรปรวนจากการเปลี่ยนชุดข้อมูลฝึกสอน

ในการทดลองนี้ได้ทำการปรับ hyperparameters โดยเลือก min samples split = min samples leaf = 25 และทำการปรับ $n_{\text{estimators}} = 100, 500, 1000, 1500, 2000$ และปรับค่า max depth = 5, 10, ..., 30 ดังตารางที่ 8 ได้พารามิเตอร์ที่ดีที่สุดในช่วงข้อมูลตรวจสอบ คือ $n_{\text{estimators}} = 1500$ และ max depth = 30

ตารางที่ 8: ผลการปรับ hyperparameters แบบจำลอง Random forest

$n_{\text{estimators}}$	max depth	training MAE	validation MAE
100	5	112.129	108.765
100	10	101.844	103.213
100	15	94.998	102.338
100	20	93.197	102.152
100	25	93.010	102.136
100	30	93.000	102.135
500	5	112.118	108.751
500	10	101.808	103.185
500	15	94.914	102.246
500	20	93.097	102.022
500	25	92.910	101.993
500	30	92.900	101.992
1000	5	112.116	108.747
1000	10	101.805	103.164
1000	15	94.912	102.209
1000	20	93.092	101.982
1000	25	92.904	101.953
1000	30	92.893	101.951
1500	5	112.118	108.749
1500	10	101.801	103.166
1500	15	94.904	102.214
1500	20	93.084	101.978
1500	25	92.895	101.948
1500	30	92.884	101.946
2000	5	112.116	108.744
2000	10	101.800	103.168
2000	15	94.903	102.219
2000	20	93.081	101.986
2000	25	92.893	101.955
2000	30	92.882	101.954

7.3.3 แบบจำลอง Support vector regression

ในโครงการนี้ได้ทดลองปรับ hyperparameters ของแบบจำลอง SVR ดังนี้

1. C เป็นค่าน้ำหนักที่ควบคุมสมดุลระหว่างการยอมรับความคลาดเคลื่อนของชุดข้อมูลและความซับซ้อนของแบบจำลอง การปรับค่า C ที่สูงจะทำให้แบบจำลองยอมรับความคลาดเคลื่อนที่น้อย แบบจำลองจึงมีความซับซ้อนมากขึ้น และอาจนำไปสู่ปัญหาการเข้ากันระหว่างแบบจำลองและชุดข้อมูลฝึกที่มากเกินไป (overfit)
2. ϵ เป็นพารามิเตอร์ที่บอกถึงความคลาดเคลื่อนระหว่างค่าที่ทำนายและค่าจริงที่มากที่สุดที่จะยอมรับ การปรับค่า ϵ ที่มากจะทำให้บริเวณที่ยอมรับได้ของแบบจำลองมีความกว้างขึ้น
3. γ เป็นพารามิเตอร์ที่กำหนดอิทธิพลของจุดข้อมูลฝึกหนึ่ง ๆ ซึ่งจะส่งผลต่อความซับซ้อนของรูปร่าง ϵ -tube

ตารางที่ 9 ได้ปรับ $C = 10, 100, 200, 400$ $\epsilon = 0.1, 1, 10$ และ $\gamma = 0.1, 0.01$ ได้พารามิเตอร์ดีที่สุดในชุดตรวจสอบคือ $C = 100, \epsilon = 1, \gamma = 0.1$

ตารางที่ 9: ผลการปรับ hyperparameters แบบจำลอง SVR

C	ϵ	γ	training MAE	validation MAE
10	0.1	0.01	102.341	104.630
10	0.1	0.1	100.664	104.251
10	1	0.01	102.339	104.628
10	1	0.1	100.665	104.249
10	10	0.01	102.378	104.676
10	10	0.1	100.766	104.322
100	0.1	0.01	101.230	103.655
100	0.1	0.1	97.847	103.346
100	1	0.01	101.232	103.659
100	1	0.1	97.857	103.345
100	10	0.01	101.267	103.695
100	10	0.1	98.004	103.402
200	0.1	0.01	101.042	103.536
200	0.1	0.1	96.880	103.419
200	1	0.01	101.043	103.535
200	1	0.1	96.893	103.416
200	10	0.01	101.083	103.572
200	10	0.1	97.059	103.488
400	0.1	0.01	100.861	103.453
400	0.1	0.1	95.727	103.644
400	1	0.01	100.863	103.454
400	1	0.1	95.742	103.638
400	10	0.01	100.904	103.484
400	10	0.1	95.931	103.728

7.3.4 แบบจำลอง LightGBM

ในโครงการนี้ได้ทดลองปรับ hyperparameters ของแบบจำลอง LightGBM ดังนี้

1. **learning rate** เป็นอัตราการเรียนรู้จาก residual ของแบบจำลองก่อนหน้าในแต่ละลำดับขั้นไม่ย่อย เป็นพารามิเตอร์ที่ต้องปรับให้เหมาะสมเพราะหากมีค่ามากหรือน้อยเกินไป อาจทำให้คำตอบที่ได้ไม่ใช่ค่าเหมาะสมที่สุดของปัญหา
2. $n_{estimators}$ จำนวนลำดับขั้นไม่ย่อยที่แบบจำลองทำการเรียนรู้ทั้งหมด ต้องปรับให้เหมาะสมกับค่า **learning rate** เพราะหากปรับน้อยเกินไป อาจทำให้แบบจำลองเรียนรู้ไปไม่ถึงค่าเหมาะสมที่สุดของปัญหา

3. max depth ความลึกสูงสุดของต้นไม้แต่ละต้นที่แบบจำลองยอมรับได้ เป็นพารามิเตอร์ที่ป้องกันไม่ให้ต้นไม้แต่ละต้นมีความลึกมากเกินไป เพราะหากต้นไม้มีความลึก ต้นไม้จะพยายามเข้ากันได้กับชุดข้อมูลฝึกสอนให้มากที่สุด ซึ่งจะก่อให้เกิดความแปรปรวนหากเปลี่ยนชุดข้อมูลที่ใช้ทดลอง

ตารางที่ 10 ได้ทำการปรับ learning rate = 0.005, 0.01 และ $n_{estimators}$ = 500, 1000, 1500, 2000 และปรับค่า max depth = 500, 1000, 1500, 2000 ได้พารามิเตอร์ที่ดีที่สุดที่ชุดข้อมูลตรวจสอบคือ learning rate = 0.01, $n_{estimators}$ = 1000 และ max depth = 10

ตารางที่ 10: ผลการปรับ hyperparameters แบบจำลอง LightGBM

learning rate	$n_{estimators}$	max depth	training MAE	validation MAE
0.005	500	5	108.000	112.140
0.005	500	10	107.613	111.941
0.005	500	15	107.617	111.944
0.005	1000	5	102.305	107.356
0.005	1000	10	101.759	107.329
0.005	1000	15	101.754	107.334
0.005	1500	5	101.208	107.038
0.005	1500	10	100.296	107.016
0.005	1500	15	100.284	107.031
0.005	2000	5	100.502	107.039
0.005	2000	10	99.256	107.032
0.005	2000	15	99.217	107.037
0.01	500	5	102.274	107.337
0.01	500	10	101.800	107.344
0.01	500	15	101.782	107.359
0.01	1000	5	100.481	107.038
0.01	1000	10	99.279	107.023
0.01	1000	15	99.256	107.058
0.01	1500	5	99.229	107.089
0.01	1500	10	97.445	107.115
0.01	1500	15	97.383	107.106
0.01	2000	5	98.150	107.170
0.01	2000	10	95.800	107.206
0.01	2000	15	95.734	107.268

7.3.5 แบบจำลอง ANN

ในโครงการนี้ได้ทำการทดลองปรับโครงสร้างแบบจำลอง ANN โดยการปรับจำนวน layers เท่ากับ 1, 2, 3, 4, 5 และจำนวน neurons เท่ากับ 32, 64 ในการฝึกสอนใช้ Adam optimizer ด้วย learning rate = 0.01 เลือกฟังก์ชันสูญเสียคือ Mean absolute error ได้โครงสร้างที่ดีที่สุดที่ชุดข้อมูลตรวจสอบคือจำนวน layers 3 ชั้น แต่ละชั้นมี 64 neurons ดังตารางที่ 11

*แบบจำลอง ANN ใช้แบบจำลองเดียวสำหรับทุกช่วงเวลาในวัน แต่แบบจำลองอื่นจะแบ่งตามช่วงเวลาเช้า-กลางวัน-เย็น การปรับค่า hyperparameters ของแบบจำลองก่อนหน้าจะทดลองปรับเฉพาะแบบจำลองที่ค่าพยากรณ์อยู่ในช่วงกลางวันแล้วนำ hyperparameters ที่ได้ไปใช้กับแบบจำลองในทุกช่วงเวลา แต่ของ ANN จะเป็นแบบจำลองสำหรับทุกช่วงเวลาอยู่แล้ว

ตารางที่ 11: ผลการปรับโครงสร้างแบบจำลอง ANN

จำนวน layers	จำนวน neurons	training MAE	validation MAE
1	32	70.360	72.881
1	64	69.612	72.470
2	32	69.395	72.071
2	64	69.335	72.126
3	32	69.526	72.063
3	64	69.405	72.030
4	32	69.759	72.161
4	64	69.603	72.122
5	32	69.826	72.171
5	64	69.905	72.420