

การพยากรณ์ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคา ในประเทศไทย

วันที่ได้รับต้นฉบับบทความ : 1 กุมภาพันธ์ 2566

วันที่แก้ไขปรับปรุงบทความ : 12 มีนาคม 2566

วันที่ตอบรับตีพิมพ์บทความ : 21 มีนาคม 2566

ดร.เอกจิตต์ จิ่งเจริญ

รองศาสตราจารย์ประจำสาขาวิชาการบริหารการปฏิบัติการ
คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์

ดร.สถาพร โอภาสานนท์

รองศาสตราจารย์ประจำสาขาวิชาการบริหารธุรกิจระหว่างประเทศ โลจิสติกส์และการขนส่ง
คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์

จารึก คงนันทะ

การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์ เพื่อศึกษาความสัมพันธ์ระหว่างปัจจัยระดับมหภาคกับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย ในรูปแบบของปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์ โดยมีหน่วยเป็นเมกะวัตต์ (MW) และพัฒนาตัวแบบถดถอยเชิงพหุคูณ ตัวแบบอนุกรมเวลา ได้แก่ ตัวแบบ Holt-Winters ตัวแบบ ARIMA และตัวแบบรวมผลพยากรณ์ เพื่อให้ได้ตัวแบบพยากรณ์ที่มีความแม่นยำที่สุด จากการศึกษาพบว่า ตัวแปรที่มีความสัมพันธ์กับปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคาในประเทศไทยและสามารถนำไปใช้พยากรณ์ ได้แก่ จำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน และการใช้ไฟฟ้าต่อหัวประชากร ตามลำดับ ในส่วนของความแม่นยำของตัวแบบพยากรณ์พบว่า ตัวแบบรวมผลพยากรณ์ระหว่าง Holt-Winters (0.97, 0.68, 0.06) และ ARIMA (5,1,4) ให้ค่าน้ำหนักของสองตัวแบบ 0.45 และ 0.55 มีความเหมาะสมที่สุด โดยมีค่า MAPE เท่ากับ 3.05% และ r^2 เท่ากับ 98.73% ตามลำดับ ได้ค่าพยากรณ์ปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคาในประเทศไทยโดยรวมใน 3 ปีข้างหน้าระหว่างปี 2022–2024 ที่ 11,961.22 MW 13,125.86 MW และ 14,262.26 MW ตามลำดับ หรือมีอัตราเติบโตอยู่ที่ปีละประมาณ 10 % โดยผลลัพธ์ของการพยากรณ์นี้สามารถช่วยให้ภาครัฐกำหนดมาตรการสนับสนุนการติดตั้งเซลล์แสงอาทิตย์บนหลังคา เพื่อให้บรรลุเป้าหมายตามแผนพัฒนากำลังผลิตไฟฟ้าของประเทศไทยระหว่างปี 2018–2037 และช่วยกระตุ้นให้ภาคเอกชนมีการลงทุนด้านธุรกิจการผลิตและการให้บริการเกี่ยวกับเซลล์ไฟฟ้าแสงอาทิตย์มากขึ้น ซึ่งจะส่งผลให้ประเทศไทยมีความมั่นคงด้านพลังงานในที่สุด

คำสำคัญ : ตัวแบบพยากรณ์ ปริมาณกำลังผลิตไฟฟ้า เซลล์แสงอาทิตย์บนหลังคา การวิเคราะห์ถดถอยพหุคูณ การรวมผลพยากรณ์

Forecasting of Solar Rooftop Consumption in Thailand

Received: February 1, 2023

Revised: March 12, 2023

Accepted: March 21, 2023

Dr.Ekachidd Chungcharoen

Associate Professor of Department of Operations Management,
Thammasat Business School, Thammasat University

Dr.Sathaporn Opasanon

Associate Professor of Department of International Business, Logistics and Transport,
Thammasat Business School, Thammasat University

Jaruek Khongnantha

The Electricity Generating Authority of Thailand (EGAT)

ABSTRACT

This research is aimed to determine the relationships between macro factors and solar rooftop demand in Thailand in term of electricity power generation in megawatts (MW) and to develop the best forecasting model among 4 techniques, i.e. multiple linear regression, Holt-Winters, ARIMA, and combined forecast. Based on the multiple linear regression model, important factors affecting rooftop demand are the number of solar rooftop installations, the electricity generation from renewable resources, and the electricity consumption per user, respectively. In terms of forecasting accuracy, the combined forecast model between Holt-Winters (0.97, 0.68, 0.06) and ARIMA (5,1,4) with the optimal weights of 0.45 and 0.55 is the most accurate model with MAPE of 3.05% and r^2 of 98.73%. The forecasts of solar rooftop demand for the next 3 years between 2022–2024 will be 11,961.22 MW, 13,125.86 MW, and 14,262.26 MW, respectively, accounting for the growth rate of 10% each year. The outcome of this research can help Thai government to initiate incentive plans for supporting solar rooftop installation to meet the PDP2018–2037 plan and can help businesses to invest in producing and serving solar energy equipment for the energy sustainability of Thailand in the future.

Keywords: Forecasting Model, Electricity Production Demand, Solar Rooftop, Multiple Linear Regression, Combined Forecasts

บทนำ

พลังงานไฟฟ้าเป็นปัจจัยสำคัญในทุกภาคส่วนของประเทศ ทั้งการดำรงชีวิตของประชาชนทุกครัวเรือน ภาคเกษตรกรรม และภาคอุตสาหกรรม จากการเติบโตทางเศรษฐกิจและสังคมของประเทศทำให้ความต้องการพลังงานไฟฟ้ามีแนวโน้มสูงขึ้นทุกปี เมื่อพิจารณาความสัมพันธ์ระหว่างความต้องการใช้ไฟฟ้าต่อหัวของประชากรพบว่า ตลอดระยะเวลาหลังจากภาวะถดถอยครั้งใหญ่ทางเศรษฐกิจของประเทศตั้งแต่ปี 1997 เป็นต้นมาจนถึงปี 2020 ความต้องการใช้ไฟฟ้ามีแนวโน้มสูงขึ้นทุกปี จากข้อมูลทางสถิติของสำนักงานนโยบายและแผนพลังงานกระทรวงพลังงานพบว่า สัดส่วนการใช้พลังงานไฟฟ้าต่อเศรษฐกิจของประเทศไทยในปี 2020 นั้น มีการใช้ไฟฟ้าต่อหัวประชากรอยู่ที่ 2,826 กิโลวัตต์ชั่วโมง (KW-H) ต่อคน โดยความต้องการพลังงานไฟฟ้าของประเทศไทยเมื่อสิ้นปี 2020 อยู่ที่ 28,637 เมกะวัตต์ (MW) ขณะที่ข้อมูลจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทยสรุปความสามารถในการผลิตไฟฟ้ารวมทั้งประเทศในปีเดียวกันอยู่ที่ 55,390.99 MW และจากแผนพัฒนากำลังผลิตไฟฟ้าของประเทศไทย 2018–2037 ปรับปรุงครั้งที่ 1 (PDP2018 Revision 1) คาดว่าในอีก 10 ปีข้างหน้าในปี 2030 ความต้องการใช้ไฟฟ้าของประเทศไทยจะมีปริมาณเพิ่มขึ้นถึงประมาณ 44,781 เมกะวัตต์ จากการขยายตัวของประชากรและทุกภาคส่วนตามอัตราการเติบโตทางเศรษฐกิจวัดโดยผลิตภัณฑ์มวลรวมในประเทศ (GDP) และถึงแม้ว่าในระหว่างปี 2020–2021 เศรษฐกิจจะมีการหดตัวจากการแพร่ระบาดของโรคติดเชื้อ COVID-19 และจากมาตรการควบคุมการระบาดจากภาครัฐที่ทำให้กิจกรรมทางเศรษฐกิจหยุดชะงักชั่วคราว ประชาชนต้องอยู่บ้านมากขึ้น การท่องเที่ยวได้รับผลกระทบรุนแรงจากจำนวนนักท่องเที่ยวต่างชาติลดลงอย่างมาก ภาคอุตสาหกรรมและภาคการส่งออกสินค้าหดตัวในหลายหมวดตามอุปสงค์ของประเทศคู่ค้าที่ลดลง อย่างไรก็ตามการส่งออกสินค้าบางหมวด เช่น อาหาร และถั่วมีอย่างทางการแพทย์ ก็ยังสามารถขยายตัวได้ตามความต้องการที่เพิ่มขึ้น สำนักงานสภาพัฒนาการเศรษฐกิจและสังคมแห่งชาติ (สศช.) ได้ทำการพยากรณ์ค่าความต้องการใช้ไฟฟ้าของประเทศไทยจากการประมาณการแนวโน้มการขยายตัวทางเศรษฐกิจระยะยาวระหว่างปี 2017–2037 ที่มีค่าเพิ่มขึ้นเฉลี่ยร้อยละ 3.80 ต่อปี โดยใช้อัตราการเพิ่มของประชากรเฉลี่ยร้อยละ -0.02 ต่อปี ส่วนการพยากรณ์ความต้องการไฟฟ้าในแผนพัฒนากำลังผลิตไฟฟ้าของประเทศไทยปี 2018–2037 ตามแผน PDP2018 Revision 1 ของสำนักงานนโยบายและแผนพลังงานกระทรวงพลังงาน สรุปความต้องการพลังงานไฟฟ้ารวมสุทธิของระบบทั้ง 3 การไฟฟ้าที่ประกอบด้วย การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) การไฟฟ้านครหลวง (กฟน.) และการไฟฟ้าส่วนภูมิภาค (กฟภ.) โดยพลังไฟฟ้าสูงสุดสุทธิ (Peak) ของประเทศไทยในปี 2037 มีค่าประมาณ 367,458 ล้านหน่วย และ 53,997 MW ตามลำดับ โดยจากปี 2018 มีสัดส่วนการผลิตไฟฟ้าจากพลังงานหมุนเวียนดังต่อไปนี้ พลังงานแสงอาทิตย์ 2,962.45 MW ชีวมวล 3,372.93 MW พลังงานลม 1,102.82 MW ก๊าซชีวภาพ 505.24 MW ชยะชุมชน 317.82 MW พลังน้ำขนาดเล็ก 187.72 MW และพลังน้ำขนาดใหญ่ 2,919.66 MW รวมกับพลังงานความร้อนและเชื้อเพลิงชีวภาพคิดเป็น 15.48% ของสัดส่วนการใช้พลังงานขั้นสุดท้าย โดยตั้งเป้าหมายให้ในปี 2037 มีสัดส่วนการผลิตไฟฟ้าจากพลังงานหมุนเวียนดังต่อไปนี้ พลังงานแสงอาทิตย์ 12,139 MW พลังงานแสงอาทิตย์จากทุ่นลอยน้ำ 2,725 MW ชีวมวล 5,790 MW พลังงานลม 2,989 MW ก๊าซชีวภาพ 1,565 MW ชยะชุมชน 900 MW ชยะอุตสาหกรรม 75 MW พลังน้ำขนาดเล็ก 308 MW พลังน้ำขนาดใหญ่ 2,920 MW ตามลำดับ นอกจากนี้ยังมีในส่วนของความร้อนและเชื้อเพลิงชีวภาพรวมแล้วคิดเป็น 30% ของสัดส่วนการใช้พลังงานขั้นสุดท้าย จากข้อมูลความต้องการที่เพิ่มขึ้นดังกล่าวนี้ การสร้างโรงไฟฟ้าขึ้นใหม่เพื่อรองรับอัตราความต้องการเพิ่มขึ้นปีละกว่า 1,200 MW นั้นมีความเป็นไปได้ยาก เนื่องจากข้อจำกัดทางด้านสิ่งแวดล้อม จึงเป็นเหตุให้กระทรวงพลังงานมีนโยบายส่งเสริมการผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ตามแผนพัฒนาพลังงานทดแทนและพลังงานทางเลือกระหว่าง 2018–2037 ขึ้น โดยกำหนดเป้าหมายให้เกิดการใช้พลังงานหมุนเวียนหรือพลังงานสะอาดคิดเป็นร้อยละ 30 ของปริมาณการใช้พลังงานทั้งหมด จึงส่งผลให้พลังงานแสงอาทิตย์เริ่มมีบทบาทมากขึ้น ดังนั้นในการพยากรณ์ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศในช่วงระยะเวลาข้างหน้านี้จึงมีความสำคัญอย่างยิ่ง เพราะสามารถนำไปใช้ประโยชน์ในการวางแผนของทางภาครัฐและเอกชนได้ เพื่อกระตุ้นให้มีการลงทุนด้านพลังงานไฟฟ้า การให้บริการ และการสร้างนวัตกรรม

ใหม่ ๆ ในอุตสาหกรรมพลังงานแสงอาทิตย์ การใช้เซลล์แสงอาทิตย์บนหลังคาในภาคธุรกิจและอุตสาหกรรมจะทำให้สามารถลดการใช้พลังงานไฟฟ้าจากโครงข่ายไฟฟ้าในระบบหลักและช่วยลดต้นทุนการผลิตไฟฟ้าได้ นอกจากนี้การใช้เซลล์แสงอาทิตย์บนหลังคาในภาคครัวเรือนจะช่วยลดค่าไฟฟ้าทำให้เศรษฐกิจในครัวเรือนดีขึ้น และยังเป็น การช่วยลดการลงทุนของภาครัฐตามแนวทางการผลิตไฟฟ้าจากพลังงานทางเลือกเพื่อลดการใช้ไฟฟ้า ส่งผลให้ประเทศไทยมีความมั่นคงด้านพลังงานในที่สุด

บทวนวรรณกรรม

งานวิจัยเกี่ยวกับการคุณสมบัติและการประยุกต์ใช้เซลล์แสงอาทิตย์ในเรื่องต่าง ๆ โดยทั่วไปโดยเฉพาะในด้านเกษตรกรรมและที่อยู่อาศัยมีหลากหลายงานวิจัย แต่งานวิจัยที่เกี่ยวข้องกับการพยากรณ์ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในเรื่องนี้สำหรับประเทศไทยยังมีไม่มากนัก ตัวอย่าง ได้แก่

ในส่วนของประเทศไทยงานวิจัยของ Singchai & Keeratiwintakorn (2014) ที่ศึกษาเกี่ยวกับการพยากรณ์ความต้องการพลังงานไฟฟ้าจากการเติบโตของกลุ่มโรงงานอุตสาหกรรม กลุ่มอาคารพาณิชย์ และกลุ่มบ้านพักอาศัย สำหรับศูนย์จัดการความต้องการพลังงานไฟฟ้าของประเทศไทย เพื่อการผลิตพลังงานไฟฟ้าให้สอดคล้องกับจัดการด้านความต้องการให้สอดคล้องกัน เพื่อลดค่าใช้จ่ายในส่วนที่มีการผลิตพลังงานไฟฟ้าเกิน โดยใช้การวิเคราะห์ถดถอยแบบ Multivariate Regression Analysis (MLR) และ Artificial Neural Network (ANN) สำหรับการพยากรณ์ระยะยาว โดยใช้ตัวแปรสภาพภูมิอากาศ และจำนวนประชากร และใช้เทคนิค Support Vector Machine-Regression (SVM-R) ร่วมกับ Radial Basis Function (RBF) ในการพยากรณ์ระยะสั้นจากข้อมูลปริมาณการใช้พลังงานไฟฟ้าราย 15 นาทีมาทำการวิเคราะห์และวิเคราะห์ค่า Mean Squared Error (MSE) และ Squared Correlation Coefficient (r^2) รวมทั้งเวลาที่ใช้ในการประมวลผล เพื่อวัดประสิทธิภาพของการพยากรณ์ โดยโมเดลนี้มีค่าตัวแปรที่เหมาะสมกับข้อมูลปริมาณการใช้พลังงานไฟฟ้าจริง และตัวแปรเวลาของแต่ละวันและชนิดของวัน มาช่วยในการพยากรณ์ความต้องการพลังงานไฟฟ้า

Saophan (2018) ได้ทำการพัฒนาตัวแบบพยากรณ์พลังงานแสงอาทิตย์สำหรับความต้องการของครัวเรือนในประเทศไทย โดยใช้ System Dynamics Model โดยให้ผู้เชี่ยวชาญระบุถึงปัจจัยสำคัญที่ส่งผลต่อกำลังการผลิตไฟฟ้าจากเซลล์แสงอาทิตย์ (Photovoltaic Cells หรือ PV) ในแต่ละเดือนทั้งหมด 19 ปัจจัย ได้แก่ จำนวนการติดตั้ง PV การผลิตพลังงานรวม จำนวนติดตั้งในครัวเรือน ปริมาณการติดตั้ง ปริมาณการเสื่อมสภาพ จำนวนผู้ใช้ PV ใหม่ จำนวนของครัวเรือนระยะเวลาคืนทุน ต้นทุนการติดตั้ง ต้นทุนการบำรุงรักษา ราคาไฟฟ้าต่อหน่วย ปริมาณผลิตโดยเฉลี่ยต่อครัวเรือน ชั่วโมงการทำงานต่อวัน การแผ่พลังงานแสงอาทิตย์ ค่าใช้จ่ายสนับสนุนการติดตั้งจากรัฐบาล อัตราเสื่อมสภาพ อัตราครัวเรือนที่สามารถติดตั้งได้ อัตราส่วนของประสิทธิภาพ และเวลา ข้อมูลได้จากแบบสอบถามจากกลุ่มตัวอย่าง 411 คน มีการศึกษาความสัมพันธ์ระหว่างปัจจัยต่าง ๆ ในแบบจำลองและมีการศึกษาความสามารถในการติดตั้ง PV โดยใช้การระดมความคิดเห็นเชิงลึกของผู้เชี่ยวชาญ และใช้ตัวแบบ System Dynamics Model (SD) เป็นแนวทางในการทำความเข้าใจพฤติกรรมที่ไม่เป็นเชิงเส้นของระบบ เพื่อตรวจสอบความสัมพันธ์เชิงเหตุผลระหว่างปัจจัยสำคัญที่มีผลต่อกำลังการผลิตไฟฟ้าจากเซลล์แสงอาทิตย์ของครัวเรือน และทำ Model Verification และ Model Validation เพื่อตรวจสอบความถูกต้องของตัวแบบ ผลพยากรณ์พบว่า แนวโน้มกำลังการผลิตไฟฟ้าจากเซลล์แสงอาทิตย์จากครัวเรือนในปี 2037 จะเพิ่มขึ้นเป็น 2,091.76 MW ในกรณีภาครัฐสนับสนุนค่าติดตั้ง 40% ทุกปี ทำให้กำลังการผลิตไฟฟ้าไปถึงเป้าหมายที่รัฐบาลต้องการ

Phumikanjana (2019) ศึกษาการพยากรณ์กำลังการผลิตของระบบไฟฟ้าพลังงานแสงอาทิตย์ในช่วงเวลา 15 นาทีล่วงหน้า ซึ่งเป็นการพยากรณ์ระยะสั้นมาก โดยใช้วิธีการพยากรณ์ Time Series Forecasting และ Support Vector Machine (SVM) เป็นระบบการเรียนรู้ และการพยากรณ์ใช้วิธีปรับเรียบด้วยวิธี Holt-Winters โดยใช้ MRE และ RMSE ในการประเมิน

ความแม่นยำในการพยากรณ์ โดยเลือกค่าตัวแปรที่สำคัญสำหรับพยากรณ์คือ จำนวนวันของข้อมูลย้อนหลัง (N) และดัชนีพยากรณ์ (Forecasting Index) งานวิจัยนี้ได้นำเสนอการเลือกตัวแปรดังกล่าวจำแนกเป็นกรณีศึกษา ได้แก่ ตามฤดูกาล และตามสภาพอากาศ เป็นข้อมูลของวันที่ต้องการพยากรณ์ ได้ผลลัพธ์ความแม่นยำของวันที่ท้องฟ้าปลอดโปร่งและวันที่มีเมฆบางส่วนในระดับดี และระดับปานกลางสำหรับวันที่มีเมฆและวันที่ฝนตก

Chaianong, A., Bangviwat, A., & Menke, C. (2019) ทำการพยากรณ์การยอมรับโซลาร์เซลล์ (Photovoltaic, PV) บนหลังคาในประเทศไทย โดยใช้แนวทางในการคาดการณ์การนำ PV บนหลังคาโดยใช้ด้วย Customer-adoption Model มีการประเมินการใช้ PV ในกรอบเวลาและใช้ Bass Diffusion Model เพื่อจัดการกับการยอมรับ PV ประจำปีของลูกค้า 4 กลุ่มคือ ที่อยู่อาศัย ธุรกิจขนาดเล็ก ธุรกิจขนาดกลาง และธุรกิจขนาดใหญ่ โดยมี 2 ตัวแปรหลักคือ อัตราการซื้อคืนและการลดต้นทุนการติดตั้ง PV รวมอยู่ในการคาดการณ์การนำ PV ไปใช้ใน 8 สถานการณ์ ภายใต้สมมติฐานการลดต้นทุน PV เท่ากับ 2% ต่อปีและไม่มีอัตราการซื้อคืน ทำให้ในปี 2036 คาดว่า PV จะอยู่ที่ประมาณ 9%–14% ของพื้นฐานพลังงานของระบบโดยรวม เนื่องจากความสนใจในระบบ PV บนหลังคาเพิ่มขึ้นในประเทศไทย

Fachrizal & Tang (2019) พัฒนาตัวแบบพยากรณ์ปริมาณการติดตั้ง PV ประจำปีของภาคที่อยู่อาศัยในประเทศไทย โดยแบ่งผู้อยู่อาศัยออกเป็นสี่ประเภท ได้แก่ ผู้ใช้ PV ที่มีแบตเตอรี่สำรอง ผู้ใช้ PV ที่ไม่มีแบตเตอรี่สำรอง ผู้ใช้ PV ที่มีศักยภาพและผู้ที่ไม่ใช้ PV โดยมีวัตถุประสงค์ เพื่อทำความเข้าใจผู้ใช้ประเภทต่าง ๆ โดยเก็บข้อมูลจากแบบสอบถามออนไลน์เกี่ยวกับการใช้ประโยชน์ของ PV ของที่พักอาศัยในประเทศไทย ระยะเวลาการเก็บข้อมูลระหว่างเดือนธันวาคม 2017 ถึง กุมภาพันธ์ 2018 และใช้วิธี Regression Analysis เพื่อพยากรณ์จำนวนครัวเรือนในประเทศไทยจนถึงปี 2036 โดยมีตัวแปรหลักในการพยากรณ์ ได้แก่ ระยะเวลาคืนทุน อัตราการเติบโตของผู้ใช้เซลล์แสงอาทิตย์ และกำลังการผลิตติดตั้ง มีการใช้ Scenario ในการพยากรณ์การติดตั้งจากสองตัวแปรร่วมกันคือ เปอร์เซ็นต์อัตราการเติบโตของต้นทุนการติดตั้งและเปอร์เซ็นต์อัตราการเติบโตของราคาไฟฟ้า ซึ่งตัวแปรทั้งสองส่งผลต่อระยะเวลาคืนทุน ผลการวิจัยพบว่า มีแนวโน้มของการติดตั้ง PV ที่อยู่อาศัยที่เพิ่มขึ้น ตามด้วยการลดลงของระยะเวลาคืนทุนเมื่อเวลาผ่านไป คาดว่า PV จะช่วยให้ผู้มีอำนาจตัดสินใจปรับปรุงนโยบายส่งเสริมอัตราการติดตั้ง PV ทั่วประเทศได้

Saengsuwan (2020) ได้ทำการศึกษาเกี่ยวกับปัจจัยที่ส่งผลกระทบต่อการผลิตกระแสไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคา โดยใช้พื้นที่ศึกษาจากอาคารของมหาวิทยาลัยราชภัฏเชียงราย ผลการวิจัยพบว่า มีสองปัจจัยหลักที่มีความสัมพันธ์กับการผลิตกระแสไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคาตามลำดับความสำคัญ ได้แก่ การแผ่กระจายของรังสีดวงอาทิตย์และอุณหภูมิ โดยมีค่าสัมประสิทธิ์สหสัมพันธ์อยู่ที่ 0.997 และ 0.951 ตามลำดับ โดยที่ปัจจัยทั้งสองก็มีความสัมพันธ์กันเองสูงมากเช่นเดียวกันที่ค่าสัมประสิทธิ์สหสัมพันธ์ 0.948 ดังนั้นผู้วิจัยจึงพัฒนาตัวแบบ Simple Linear Regression ในการพยากรณ์กำลังการผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังการรายวันจากข้อมูลการแผ่กระจายรังสีของดวงอาทิตย์เพียงปัจจัยเดียว ซึ่งข้อมูลการแผ่รังสีของดวงอาทิตย์ใช้ผลลัพธ์จากการจำลองสถานการณ์ในลักษณะ Stochastic Model ผลการวิจัยพบว่าตัวแบบมีความแม่นยำในการพยากรณ์การผลิตกระแสไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคาสูง โดยผิดพลาดไม่เกิน 3%

ในต่างประเทศมีงานวิจัยด้านการพยากรณ์ที่เกี่ยวข้อง อาทิ Lobel & Perakis (2011) ได้พัฒนา Discrete Consumer Choice Model สำหรับพยากรณ์ความต้องการใช้เซลล์ไฟฟ้าแสงอาทิตย์สำหรับผู้บริโภคในครัวเรือน โดยเลียนแบบพฤติกรรมของลูกค้าและพิจารณาผลกระทบต่อต้นทุนในการลงทุนภาครัฐ เพื่อนำมาพัฒนาทางเลือกของนโยบายภาครัฐในการสนับสนุนให้ประชาชนหันมาใช้เซลล์แสงอาทิตย์บนหลังคาภายใต้ต้นทุนที่ต่ำที่สุด ผู้วิจัยได้วิเคราะห์ความไวของการเปลี่ยนนโยบายซึ่งมีผลต่อต้นทุนของระบบการติดตั้งเซลล์แสงอาทิตย์ในภาพรวมและทดสอบความน่าเชื่อถือของตัวแบบ โดยใช้ข้อมูลปริมาณการใช้เซลล์แสงอาทิตย์ในประเทศเยอรมัน ผลจากการวิจัยพบว่า นโยบายในการชักจูงให้ประชาชนหันมาใช้เซลล์แสงอาทิตย์

ในขณะนั้นยังไม่ค่อยมีประสิทธิภาพมากนักและแนะนำว่า ภาครัฐควรเพิ่มการสนับสนุนมากกว่านี้และการทยอยลดการสนับสนุนของภาครัฐสามารถกระทำให้เร็วขึ้นได้

Zhang, et al. (2014) พัฒนาตัวแบบสำหรับคาดการณ์ปริมาณการใช้งานเซลล์แสงอาทิตย์บนหลังคาในอนาคต โดยใช้หลักการของการจำลองสถานการณ์แบบ Agent-Based Simulation Model มีการประมาณค่าข้อมูลสำหรับตัวแปรนำเข้าที่เกี่ยวข้อง โดยใช้ Multiple Regression Model และมีการคาดการณ์การติดตั้งหรือไม่ติดตั้งของประชาชนโดยใช้ Logistic Regression Model ซึ่งพบว่า การจำลองสถานการณ์จาก Agent-Based Simulation Model สามารถทำนายจำนวนผู้ติดตั้งเซลล์แสงอาทิตย์ได้และสามารถนำไปใช้ เพื่อช่วยภาครัฐในการกำหนดนโยบายสนับสนุนการติดตั้งของภาครัฐได้

Assouline, Mohajeri, & Scartezini (2018) ได้พัฒนาตัวแบบพยากรณ์ความเหมาะสมของพื้นที่ในการติดตั้งเซลล์แสงอาทิตย์บนหลังคาสำหรับประเทศสวิสเซอร์แลนด์ โดยผสมผสานกับข้อมูลทางภูมิสารสนเทศหรือ Geographic Information Systems (GIS) กับตัวแบบทางด้าน Solar Models และ Machine Learning (ML) ในการทำนายตัวแปรต่าง ๆ ที่เหมาะสมในการติดตั้งเซลล์แสงอาทิตย์บนหลังคา เช่น ขนาด รูปร่าง ความชันของพื้นที่ รวมทั้งทิศทางการติดตั้ง ฯลฯ เพื่อให้เหมาะสมกับการกระจายรังสีของแสงอาทิตย์ในแต่ละพื้นที่ โดยตัวแบบนี้สามารถขยายกรอบการใช้งานไปยังพื้นที่อื่น ๆ ที่มีข้อมูลของพื้นที่ในลักษณะที่คล้ายกันและผลลัพธ์ที่ได้ยังเป็นประโยชน์สำหรับการคำนวณปริมาณกำลังการผลิตไฟฟ้าจากเซลล์แสงอาทิตย์ในพื้นที่ได้เป็นอย่างดี

Lee & Hong (2019) พัฒนาตัวแบบ Agent-Based Model (ABM) แบบผสมสำหรับจำลองสถานการณ์การตัดสินใจใช้เซลล์แสงอาทิตย์บนหลังคาของอาคารต่าง ๆ ในเขต Gangnam District ในกรุงโซล ประเทศเกาหลี โดยมีการรวมข้อมูลภูมิสารสนเทศ (GIS) และตัวแบบ Logistic Regression เข้าด้วยกัน โดยมีข้อมูลที่เกี่ยวข้อง ได้แก่ ด้านกายภาพ ประชากรและเศรษฐกิจสังคม และพฤติกรรมของผู้ใช้ เป็นส่วนสำคัญในการตัดสินใจเลือกใช้งานเซลล์แสงอาทิตย์ติดตั้งบนหลังคา ซึ่งผลลัพธ์ของงานวิจัยสามารถนำไปใช้โดยภาครัฐหรือบริษัททางด้านสาธารณูปโภคของประเทศในการประเมินรูปแบบการขยายการใช้งานเซลล์แสงอาทิตย์ของประชาชนและประเมินแผนธุรกิจของตนเองได้

Houchati, Beitelmal, & Khraishehm (2022) ได้พัฒนาตัวแบบเพื่อพยากรณ์ปริมาณความต้องการใช้พลังงานจากเซลล์แสงอาทิตย์รายวันพร้อมกับหลักการในการบริหารจัดการความต้องการพลังงานจากเซลล์แสงอาทิตย์นั้นโดย Machine Learning-Based Optimization แบบ Support Vector Regression (SVR) และใช้ข้อมูล 1 ปีของอาคารสำนักงานเพื่อวิเคราะห์ความน่าเชื่อถือของตัวแบบพยากรณ์

จากการทบทวนวรรณกรรมพบว่า ยังไม่มีงานวิจัยด้านการศึกษาความสัมพันธ์ระหว่างปัจจัยระดับมหภาคกับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย และพัฒนาตัวแบบพยากรณ์แนวโน้มการเติบโตของปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคา เพื่อนำผลลัพธ์ที่ได้ไปใช้ในการกำหนดนโยบายของภาครัฐในการสนับสนุนภาคธุรกิจและภาคครัวเรือน ให้หันมาใช้พลังงานแสงอาทิตย์บนหลังคาเพิ่มขึ้น ซึ่งจะเป็นประโยชน์ในเชิงนโยบายต่อประเทศไทยในการลดต้นทุนพลังงานงานในระยะยาว และเป็นการนำพลังงานงานสะอาดมาใช้ เพื่อรองรับการเติบโตทางเศรษฐกิจของประเทศอย่างยั่งยืน

ในส่วนของการทบทวนตัวแบบพยากรณ์ทั้งในลักษณะของการใช้ข้อมูลเชิงเหตุผลและอนุกรมเวลาที่วิเคราะห์หัตถิพลที่ส่งผลกระทบต่อข้อมูล มีดังนี้

วิธีการพยากรณ์ข้อมูลเชิงเหตุผล

ตัวแบบถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

ตัวแบบถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression) เป็นตัวแบบที่ใช้การวิเคราะห์ความสัมพันธ์แบบเหตุผลของตัวแปรอิสระตั้งแต่ 2 ตัวแปรขึ้นไปกับตัวแปรตามในลักษณะเชิงเส้นตามหลักการของ Ordinary Least Squares (OLS) โดยมีรูปแบบทั่วไปอธิบายใน Chungcharoen (2017) สำหรับข้อมูลกลุ่มตัวอย่าง ดังนี้

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + e$$

$$\text{หรือ } y = \hat{y} + e$$

โดยที่	y	คือ ตัวแปรตาม
	$x_1, x_2, \dots, x_n$	คือ ตัวแปรอิสระ
	b_0	คือ ค่าคงที่
	$b_1, b_2, \dots, b_n$	คือ ค่าสัมประสิทธิ์ของสมการถดถอยพหุคูณ
	n	คือ จำนวนตัวแปรอิสระ
	$\hat{y}$	คือ ค่าพยากรณ์
	e	คือ ค่าความคลาดเคลื่อน

โดยที่ข้อมูลที่น่ามาวิเคราะห์จะต้องปราศจากความผิดปกติ (Outlier) และตัวแบบถดถอยเชิงเส้นพหุคูณนี้จะมี ความน่าเชื่อถือจะพิจารณาได้จากการที่ตัวแปรอิสระอย่างน้อยหนึ่งตัวมีความสัมพันธ์กับตัวแปรตามจริงและสมมติฐานของ ค่าความผิดพลาดในการพยากรณ์ ($y - \hat{y}$) ต้องเป็นจริง กล่าวคือ จะต้องเป็นอิสระจากกัน (Independence) มีการแจกแจง แบบปกติ (Normality) และมีค่าความแปรปรวนคงที่ (Homoscedasticity) นอกจากนี้จะต้องไม่มีปัญหาตัวแปรอิสระ มีความสัมพันธ์กันเองสูง (Multicollinearity) และค่าความผิดพลาดมีความสัมพันธ์กันเอง (Positive or Negative Serial Correlation) ซึ่งจะส่งผลต่อความน่าเชื่อถือและความแม่นยำของตัวแบบพยากรณ์ โดยความแม่นยำของตัวแบบสามารถ วัดได้จากค่า Coefficient of Determination (r^2) ค่า Mean Absolute Percentage Error (MAPE) และค่า Root Mean Square Error (RMSE) เป็นต้น

วิธีการพยากรณ์อนุกรมเวลา

ตัวแบบ Winters Exponential Smoothing

ตัวแบบ Winters Exponential Smoothing เป็นตัวแบบที่เหมาะสมกับข้อมูลที่มีอิทธิพลของแนวโน้มและฤดูกาล โดยพิจารณาค่า Smoothing Factor ค่า Growth Factor และ ค่า Seasonal Factor เข้าไปในตัวแบบ โดยรูปแบบการคูณของตัวแบบ Holt-Winters (α, β, γ) มีดังนี้ (Winters, 1960)

$$\begin{aligned}F_t &= \alpha X_t / S_{t-p} + (1 - \alpha)(F_{t-1} + T_{t-1}) \\S_t &= \beta X_t / F_t + (1 - \beta)S_{t-p} \\T_t &= \gamma(F_t - F_{t-1}) + (1 - \gamma)T_{t-1} \\W_{t+m} &= (F_t + mT_t)S_{t+m-p}\end{aligned}$$

โดยที่	F_t	คือ ค่าพยากรณ์ข้อมูลที่เวลา t
	α	คือ ค่า Smoothing Factor ($0 < \alpha < 1$)
	X_t	คือ ค่าข้อมูลจริงที่เวลา t
	F_{t+1}	คือ ค่าพยากรณ์ข้อมูลที่เวลา $t+1$
	T_{t+1}	คือ ค่าพยากรณ์แนวโน้มที่เวลา $t+1$
	S_1	คือ ค่าพยากรณ์ฤดูกาลที่เวลา t
	β	คือ ค่า Seasonal Factor สำหรับพยากรณ์ฤดูกาล ($0 < \beta < 1$)
	γ	คือ ค่า Growth Factor สำหรับพยากรณ์แนวโน้ม ($0 < \gamma < 1$)
	m	คือ จำนวนช่วงเวลาที่ต้องการจะพยากรณ์
	p	คือ จำนวนช่วงเวลาในรอบฤดูกาล
	W_{t+m}	คือ ค่าพยากรณ์โดยตัวแบบ Winter ที่เวลา $t+m$

ตัวแบบ Autoregressive Moving Average (ARMA)

ตัวแบบ Autoregressive Moving Average หรือ ARMA (p, q) ถูกคิดค้นโดย Box and Jenkins (1970) โดยตัวแบบมีการนำข้อมูลอนุกรมเวลาในอดีตมาพัฒนาตัวแบบที่เหมาะสม เพื่อพยากรณ์ข้อมูลในอนาคต โดยข้อมูลอนุกรมเวลาที่จะนำมาวิเคราะห์ต้องมีสมบัติสำคัญคือ มีค่าเฉลี่ยและความแปรปรวนคงที่ ตัวแบบ ARMA (p, q) จะมีรูปแบบหลัก ได้แก่ รูปแบบ Autoregressive (AR) รูปแบบ Moving Average (MA) และรูปแบบผสม ซึ่งค่าพารามิเตอร์ 2 ตัว ได้แก่ p เป็นพารามิเตอร์ของเทอม AR ส่วนค่า q เป็นพารามิเตอร์ของเทอม MA โดยสามารถเขียนตัวแบบได้ ดังนี้

$$Y_t = a + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + W_1 e_{t-1} + W_2 e_{t-2} + \dots + W_q e_{t-q} + e_t$$

โดย	Y_t	คือ ค่าพยากรณ์ที่คาบเวลา
	a	คือ ค่าคงที่
	$A_1, A_2, \dots, A_p$	คือ ค่าสัมประสิทธิ์ของ $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ ตามลำดับ
	$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$	คือ ค่าพยากรณ์ที่คาบเวลา $t-1, t-2, \dots, t-p$ ตามลำดับ
	$W_{1,2,\dots,q}$	คือ ค่าคงที่เป็นค่าถ่วงน้ำหนักของความผิดพลาดของการพยากรณ์ในอดีต
	e_t	คือ ค่า Residual ที่เวลา t ซึ่งเป็น White noise
	$e_{t-1}, \dots, e_{t-q}$	คือ ค่า Residual ที่คาบเวลา $t-1, \dots, t-q$ หรือ $1, \dots, q$ Time Lag

กรณีข้อมูลอนุกรมเวลาไม่มีแนวโน้ม ค่า p และ q สามารถอ่านได้โดยตรงจากการดู Significant Lags ของภาพ Partial Correlation Function (PACF) และ Autocorrelation Function (ACF) ตามลำดับ แต่ในกรณีที่ข้อมูลอนุกรมเวลามีแนวโน้มต้องทำการปรับแนวโน้มออกก่อน สำหรับแนวโน้มในลักษณะเชิงเส้น จะหาอนุกรมเวลาชุดใหม่จากผลต่างของข้อมูลที่เวลา t และที่เวลา $t-1$ หรือการทำ 1st Difference (ΔY_t) ซึ่งกรณีนี้ตัวแบบจะกลายเป็น Autoregressive Integrated Moving Average หรือ ARIMA (p,d,q) โดยมีค่า d เป็นจำนวนครั้งของการทำ Differencing ซึ่งจะเท่ากับ 0 ในกรณีที่อนุกรมเวลาไม่มีแนวโน้ม (Stationary) และเท่ากับ 1 กรณีที่อนุกรมเวลามีแนวโน้มหลังจากนั้นจึงค่อยมาหาค่า p และ q จาก Significant Lags ของ PACF และ ACF ตามลำดับ ซึ่งตัวแบบ ARIMA ($p,1,q$) สามารถเขียนรูปแบบทั่วไปได้ ดังนี้

$$\Delta Y_t = a + A_1 \Delta Y_{t-1} + A_2 \Delta Y_{t-2} + \dots + A_p \Delta Y_{t-p} + W_1 e_{t-1} + W_2 e_{t-2} + \dots + W_q e_{t-q} + e_t$$

ส่วนกรณีมีอิทธิพลของฤดูกาลร่วมด้วยตัวแบบจะกลายเป็น ARIMA (p,d,q) (p',d',q') โดย ค่า p' ค่า d' และค่า q' คือค่า Significant Lags ของ PACF ค่าจำนวนครั้งของการทำ Difference และค่า Significant Lags ของ ACF ที่นับเฉพาะ Seasonal Lags ตามลำดับ หลังจากทำการพัฒนาตัวแบบแล้วจึงทดสอบความน่าเชื่อถือของตัวแบบ โดยพิจารณาค่าความผิดพลาดในการพยากรณ์ว่า มีความสัมพันธ์กันเองหรือไม่ กรณีค่าความผิดพลาดในการพยากรณ์ไม่มีความสัมพันธ์กันเองที่เรียกว่า เป็น White Noise ตัวแบบจะมีความน่าเชื่อถือ แต่ในกรณีที่ค่าความผิดพลาดในการพยากรณ์ไม่เป็น White Noise ตัวแบบจะขาดความน่าเชื่อถือ ซึ่งการทดสอบความน่าเชื่อถือนี้จะกระทำโดยพิจารณาจากภาพ ACF ของค่าความผิดพลาดในการพยากรณ์ (Residuals) หรือพิจารณาค่า Ljung-Box-Pierce Q Statistic โดยมีการกำหนดสมมติฐานการทดสอบ ดังนี้

H_0 : Residuals ไม่มีความสัมพันธ์กันเองหรือเป็น White noise

H_1 : Residuals มีความสัมพันธ์กันเองหรือไม่เป็น White noise

สูตรการคำนวณค่าสถิติ Ljung-Box-Pierce Q Statistic มีดังนี้

$$Q_m = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$$

โดย Q_m คือ ค่าสถิติ Ljung-Box-Pierce Q Statistic

n คือ จำนวนของข้อมูลใน Residuals

m คือ จำนวนคาบเวลา Residuals ที่ต้องการทดสอบ

r_k คือ ค่าสัมประสิทธิ์สหสัมพันธ์ของ Residuals ระหว่าง e_t กับ e_{t-k} (k Time Lag) ที่แสดงในกราฟ ACF ของ Residuals

ซึ่งค่า Q_m นี้มีการกระจายแบบ Chi-Square โดยมีความเป็นอิสระของข้อมูลเท่ากับ $m-p-q-p'-q'$ และมีค่าวิกฤตสำหรับการทดสอบคือ $Critical \chi_{m-p-q-p'-q'}^2$

ตัวแบบรวมผลพยากรณ์ (Combined Forecast)

ตัวแบบรวมผลพยากรณ์ในงานวิจัยนี้ใช้วิธีของ Nelson (1984) ซึ่งเป็นวิธีที่ประยุกต์ใช้การวิเคราะห์ตัวแบบถดถอยเชิงเส้นพหุคูณในการคำนวณค่าน้ำหนักของแต่ละตัวแบบ เพื่อให้ผลพยากรณ์มีความผิดพลาดต่ำที่สุด โดยตัวแบบแต่ละตัวที่นำมารวมผลพยากรณ์จะเปรียบเสมือนตัวแปรอิสระที่ควรจะมาจากรีพยากรณ์ที่มีพื้นฐานต่างกัน เพื่อให้ได้มีข้อมูลจากหลายแหล่งมารวมกัน นอกจากนี้ค่าพยากรณ์จากแต่ละตัวแบบจะต้องปราศจาก Bias คือ ต้องไม่ Over หรือ Under Estimate ข้อมูลจริง ตัวแบบรวมผลพยากรณ์จากสองตัวแบบเขียนได้ ดังนี้

$$Combined_F = b_0 + b_1F_1 + b_2F_2$$

โดยที่ $Combined_F$ คือ ผลลัพธ์ของการรวมผลพยากรณ์

F_1 คือ ค่าพยากรณ์ของตัวแบบที่ 1

F_2 คือ ค่าพยากรณ์ของตัวแบบที่ 2

b_0 คือ ค่าคงที่ซึ่งสะท้อนการมี Bias

b_1 คือ น้ำหนักของตัวแบบพยากรณ์ที่ 1

b_2 คือ น้ำหนักของตัวแบบพยากรณ์ที่ 2

ในกรณีที่ไม่มี Bias เกิดขึ้นจากการทดสอบ t_{test} เราสามารถจะพัฒนาตัวแบบถดถอยพหุคูณ โดยบังคับให้ผ่านจุด Origin โดยค่าคงที่ $b_0 = 0$ ก็จะส่งผลให้ได้น้ำหนัก b_1 และ b_2 ที่เหมาะสมที่สุดสำหรับแต่ละตัวแบบ เพื่อนำไปใช้ในการรวมผลพยากรณ์ โดยค่าน้ำหนักนี้ควรมีค่าเป็นบวกและผลรวมของน้ำหนักของแต่ละตัวแบบจะต้องเท่ากับ 1 เสมอ ตัวแบบรวมผลพยากรณ์ที่เหมาะสมที่สุดสามารถเขียนได้ ดังนี้

$$Combined_F^* = b_1^*F_1 + b_2^*F_2$$

โดยที่ค่า $Combined_F^*$ คือ ผลลัพธ์ที่ได้จากการรวมผลพยากรณ์ที่เหมาะสมที่สุด และค่า b_1^* และ b_2^* คือ ค่าน้ำหนักที่ดีที่สุดของแต่ละตัวแบบ

การตรวจสอบความน่าเชื่อถือของตัวแบบพยากรณ์

ในงานวิจัยนี้ได้เลือกใช้ค่า Mean Absolute Percentage Error (MAPE) เป็นตัววัดความเหมาะสมของตัวแบบ เนื่องจากเป็นตัววัดความคลาดเคลื่อนของการพยากรณ์ที่ละเอียด สามารถแก้ปัญหาการมีค่าความคลาดเคลื่อนมีการหักล้างกันเอง และใช้ในเชิงเปรียบเทียบได้ดี โดยมีสูตรการคำนวณ ดังนี้

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{(A_t - F_t)}{A_t} \right| \times 100\%$$

โดย F_t คือ ค่าพยากรณ์ที่เวลา t

A_t คือ ข้อมูลจริงที่เวลา t

n คือ จำนวนข้อมูลที่ใช้ในการคำนวณ

นอกจากนี้ยังเลือกใช้ค่าสัมประสิทธิ์ตัวกำหนด (r^2) สำหรับวัดความแม่นยำของตัวแบบในการพยากรณ์

วิธีการวิจัย (Research Methodology)

งานวิจัยฉบับนี้มีวัตถุประสงค์ เพื่อพัฒนาตัวแบบสำหรับพยากรณ์ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยในรูปแบบของปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคา โดยมีหน่วยเป็นเมกะวัตต์ (MW) โดยสร้างตัวแบบการถดถอยเชิงพหุคูณ ตัวแบบอนุกรมเวลา ได้แก่ ตัวแบบ Holt-Winters ตัวแบบ ARIMA และตัวแบบรวมผลพยากรณ์จากตัวแบบที่กล่าวมาแล้ว เพื่อให้ได้ผลลัพธ์ที่มีความแม่นยำมากที่สุด โดยใช้ข้อมูลอนุกรมเวลาเป็นรายเดือนตั้งแต่เดือนพฤษภาคม ปี 2016 จนถึงธันวาคม ปี 2021 เมื่อคัดเลือกตัวแบบที่แม่นยำที่สุดได้แล้วจึงทำการพยากรณ์ออกไปในอีก 3 ปี ข้างหน้าระหว่าง ปี 2022-2024 เพื่อดูแนวโน้มการเติบโตของปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย

การพัฒนาตัวแบบถดถอยเชิงเส้นพหุคูณ

การพัฒนาตัวแบบถดถอยเชิงเส้นพหุคูณ เพื่อพยากรณ์ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยอยู่บนสมมติฐานที่ว่า ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยขึ้นอยู่กับสภาพทางเศรษฐกิจในระดับมหภาค โดยตัวแปรที่เป็นข้อมูลระดับมหภาคที่มีความสัมพันธ์กับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยที่สำคัญมีอยู่ 5 ตัวแปรเก็บจากหลายหน่วยงานภาครัฐ ได้แก่ ข้อมูลจำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย หน่วยเป็นจำนวนรายติดตั้ง (No._Solar_RT) และข้อมูลค่าไฟฟ้าเฉลี่ยสำหรับผู้ใช้ไฟฟ้า หน่วยเป็นบาท/กิโลวัตต์-ชั่วโมง (Avg_Ele_Cost) เก็บจากสำนักงานคณะกรรมการกำกับกิจการพลังงาน ข้อมูลกำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน หน่วยเป็นกิกะวัตต์-ชั่วโมง GWh (Gen_Renew) และข้อมูลการใช้ไฟฟ้าต่อหัวประชากร หน่วยเป็นกิโลวัตต์-ชั่วโมง/หัวประชากร (Ele_per_Cap) เก็บจากสำนักงานนโยบายและแผนพลังงาน กระทรวงพลังงานและข้อมูลจำนวนประชากรในประเทศไทย หน่วยเป็นคน (Pop) เก็บจากส่วนบริหารและพัฒนาเทคโนโลยีทะเบียนสำนัการบริหารการทะเบียน กรมการปกครอง ตามลำดับ ส่วนตัวแปรตาม ได้แก่ ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย โดยผู้วิจัยเลือกใช้ข้อมูลปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคา หน่วยเป็นเมกะวัตต์ MW (Solar_RT_Con) รวบรวมโดยสำนักงานคณะกรรมการกำกับกิจการพลังงาน (กกพ.) เพื่อเป็นตัวแทนปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย เนื่องจากปริมาณของการผลิตไฟฟ้านั้นเป็นผลลัพธ์ที่เกิดจากการใช้เซลล์แสงอาทิตย์ ซึ่งสามารถคำนวณได้โดยตรงจากปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคาทั้งหมดหารด้วยกำลังไฟต่อแผงวงจรโซลาร์เซลล์มาตรฐาน ดังนั้นข้อมูลปริมาณกำลังผลิตไฟฟ้าจากเซลล์พลังงานแสงอาทิตย์บนหลังคาจึงมีความเหมาะสมในการใช้เป็นตัวแทนปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยนำตัวแปรทั้งหมดมาทดสอบความสัมพันธ์ระหว่างกัน โดยวิธีภาพการกระจายและค่าสัมประสิทธิ์สหสัมพันธ์ (r) เพื่อดูความเหมาะสมของตัวแปรต้นในการอธิบายตัวแปรตามและปัญหา Multicollinearity ที่อาจเกิดขึ้น มีการใช้เทคนิค Stepwise MLR พร้อมพิจารณา ค่า Tolerance และ VIF ในการเลือกตัวแปรอิสระเข้ามาไว้ในตัวแบบ โดยพิจารณาค่า Tolerance ไม่ควรต่ำกว่า 0.19 และ VIF ไม่ควรสูงเกิน 5.30 (Hair et al., 2006) และประเมินความน่าเชื่อถือของแบบ โดยใช้ค่าสถิติต่าง ๆ ได้แก่ ค่า r^2 ค่า Standard Error of the Estimate ค่า F-Test และค่า T-Test ของตัวแปรอิสระที่อยู่ในตัวแบบพร้อมทั้งตรวจสอบสมมติฐานของการถดถอยพหุคูณ ได้แก่ ค่า Residuals มีการแจกแจงแบบปกติ โดยใช้ Normality Test ค่าความผิดพลาดเป็นอิสระต่อกันโดยพิจารณาค่า Durbin-Watson (DW) และค่าความแปรปรวนของค่าความผิดพลาดคงที่โดยใช้ภาพการกระจายระหว่างค่า Predicted Values และค่า Residuals


การพัฒนาตัวแบบอนุกรมเวลาและตัวแบบรวมผลพยากรณ์

ผู้วิจัยได้ทำการพัฒนาตัวแบบอนุกรมเวลา โดยวิธี Holt-Winters และวิธี Decomposition โดยใช้การเปรียบเทียบค่า r^2 และค่า MAPE เพื่อให้ได้ตัวแบบที่มีความผิดพลาดในการพยากรณ์น้อยที่สุดในแต่ละวิธี แล้วจึงนำไปรวมผลพยากรณ์กับตัวแบบที่ได้จากการวิเคราะห์สมการถดถอยเชิงเส้นแบบพหุคูณ ซึ่งสามารถอธิบายผลกระทบของปัจจัยต่าง ๆ ที่อยู่ในตัวแปรอิสระต่อตัวแปรตามอย่างมีนัยสำคัญได้ เพื่อผลการพยากรณ์มีความแม่นยำมากขึ้น

ผลการศึกษา (Results)

ผลการวิเคราะห์ข้อมูลเบื้องต้น

ผลการวิเคราะห์ข้อมูลเบื้องต้นแสดงในภาพที่ 1 ซึ่งแสดงกราฟอนุกรมเวลารายเดือนของปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยระหว่างเดือนพฤษภาคมปี 2016 ถึงธันวาคมปี 2021 รวบรวมโดยสำนักงานคณะกรรมการกำกับกิจการพลังงาน (กกพ.)




ภาพที่ 1: อนุกรมเวลาปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย

ระหว่างเดือนพฤษภาคมปี 2016 ถึงธันวาคมปี 2021

แหล่งที่มา: สำนักงานคณะกรรมการกำกับกิจการพลังงาน

จากภาพที่ 1 พบว่า ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยค่อนข้างคงที่ตั้งแต่ช่วงเดือนพฤษภาคมปี 2016 ถึงสิงหาคมปี 2018 แล้วขยับตัวสูงขึ้นจนถึงเดือนธันวาคมปี 2021 โดยไม่ปรากฏอิทธิพลของฤดูกาล ซึ่งยืนยันได้จากกราฟ ACF และ ACF หลังจากกำจัดแนวโน้มออกโดยวิธี 1st Difference ในภาพที่ 2 a) และ b)



ภาพที่ 2: แสดงกราฟ a) ACF และ b) ACF หลังจากกำจัดแนวโน้มออกโดยวิธี 1st Difference

จากภาพที่ 2 เนื่องจากค่า r_k ในภาพ ACF ค่อย ๆ ลดลงอย่างต่อเนื่องเป็นการยืนยันว่า อนุกรมเวลาชุดนี้มีแนวโน้มชัดเจนและเมื่อทำ 1st Difference เพื่อเอาแนวโน้มออกแล้วพบว่า ค่า r_{12} r_{24} r_{36} ไม่ได้สูงและค่อย ๆ ลดลงอย่างมีนัยสำคัญ ซึ่งสะท้อนว่า อนุกรมเวลาชุดนี้ไม่ปรากฏอิทธิพลของฤดูกาล โดยจะเห็นว่า มี r_5 และ r_{32} ที่สูงอย่างมีนัยสำคัญแต่สรุปได้ว่าเป็นเหตุการณ์ที่เกิดโดยบังเอิญไม่มีผลกระทบต่อการพัฒนาตัวแบบแต่อย่างใด

ผลการวิเคราะห์ตัวแบบกคกอยเชิงเส้นพหุคูณ

จากการคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ (r) ระหว่างปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยกับตัวแปรอิสระระดับมหภาคจำนวน 5 ตัวแปรภายใต้ความสำคัญ 0.05 พบว่า มีความสัมพันธ์กันจากสูงสุดไปต่ำสุด ได้แก่ ข้อมูลจำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน ข้อมูลการใช้ไฟฟ้าต่อหัวประชากร ข้อมูลค่าไฟฟ้าเฉลี่ยสำหรับผู้ใช้ไฟฟ้า และจำนวนประชากรในประเทศไทย หน่วยเป็นคน (Pop) โดยมีค่า r เท่ากับ 0.859 0.732 0.720 0.496 และ 0.363 ตามลำดับในตารางที่ 1

ตารางที่ 1: แสดงค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย
กับตัวแปรอิสระทั้ง 5 ตัวแปร

		Correlations					
		Solar_RT_Con	No._Solar_RT	Avg_Ele_Cost	Gen_Renew	Ele_per_cap	Pop
Solar_RT_Con	Pearson Correlation	1	.859**	.496**	.732**	.720**	.363**
	Sig. (2-tailed)		.000	.000	.000	.000	.002
	N	68	68	68	68	68	68
No._Solar_RT	Pearson Correlation	.859**	1	.207	.455**	.441**	.004
	Sig. (2-tailed)	.000		.090	.000	.000	.976
	N	68	68	68	68	68	68
Avg_Ele_Cost	Pearson Correlation	.496**	.207	1	.721**	.638**	.841**
	Sig. (2-tailed)	.000	.090		.000	.000	.000
	N	68	68	68	68	68	68
Gen_Renew	Pearson Correlation	.732**	.455**	.721**	1	.755**	.697**
	Sig. (2-tailed)	.000	.000	.000		.000	.000
	N	68	68	68	68	68	68
Ele_per_cap	Pearson Correlation	.720**	.441**	.638**	.755**	1	.675**
	Sig. (2-tailed)	.000	.000	.000	.000		.000
	N	68	68	68	68	68	68
Pop	Pearson Correlation	.363**	.004	.841**	.697**	.675**	1
	Sig. (2-tailed)	.002	.976	.000	.000	.000	
	N	68	68	68	68	68	68

** . Correlation is significant at the 0.01 level (2-tailed)

นอกจากนี้ผลการทดสอบสหสัมพันธ์ระหว่างตัวแปรอิสระด้วยกันเองชี้ให้เห็นว่า ค่า r ระหว่างค่าไฟฟ้าเฉลี่ยสำหรับผู้
ใช้ไฟฟ้า กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน ข้อมูลการใช้ไฟฟ้าต่อหัวประชากร และจำนวนประชากร มีค่าสูงกว่า ค่า r
ระหว่างตัวแปรเหล่านี้กับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย รวมทั้งเมื่อดูผลลัพธ์ของการพัฒนาตัวแบบ
ถดถอยพหุคูณแบบวิธี Enter พบว่า ค่า Tolerance ของตัวแปร Pop มีค่าอยู่ที่ 0.17 และค่า VIF เท่ากับ 1/0.17 หรือ 5.88
สะท้อนความสัมพันธ์กับตัวแปรอิสระอื่น เช่น Avg_Ele_Cost ในระดับสูงมาก จึงส่งผลให้ค่า $\sqrt{VIF}$ ที่อธิบายการเพิ่มขึ้นของ
Standard Error ของความชันของตัวแปรในตัวแบบ Regression เพิ่มขึ้นทำให้ไม่สามารถสรุปถึงความสัมพันธ์ของตัวแปร
อิสระกับตัวแปรตามได้ ผลลัพธ์การวิเคราะห์ระหว่าง Correlation และ Regression จึงขัดแย้งกันสะท้อนถึงการเกิดปัญหา
Multicollinearity อย่างชัดเจน ผลของการพัฒนาตัวแบบถดถอยพหุคูณ โดยใช้วิธี Stepwise MLR เพื่อหลีกเลี่ยงปัญหาดังกล่าว
ดังกล่าว ส่งผลให้ตัวแปรอิสระ 3 ตัวแปร ได้แก่ จำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้า
จากพลังงานหมุนเวียน และข้อมูลการใช้ไฟฟ้าต่อหัวประชากร ถูกเลือกเข้ามาไว้ในตัวแบบ ดังนี้

$$\text{Solar_RT_Con} = -6,945.030 + [(\text{No_Solar_RT}) * 0.123] + [(\text{Gen_Renew}) * 0.216] \\ + [(\text{Ele_per_Cap}) * 2.170]$$

ผลการวิเคราะห์ความน่าเชื่อถือของตัวแบบพบว่า จำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน และข้อมูลการใช้ไฟฟ้าต่อหัวประชากร มีความสัมพันธ์ที่เป็นบวกกับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยอย่างมีนัยสำคัญ โดยมีค่าสัมประสิทธิ์ความถดถอยอยู่ที่ 0.123 0.216 และ 2.170 ตามลำดับ และสะท้อนความสัมพันธ์จากมากไปน้อย โดยดูจากค่า Standardized Coefficients Beta ซึ่งเท่ากับ 0.633 0.260 และ 0.244 ตามลำดับ นอกจากนี้ยังอธิบายได้ว่า จำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน และข้อมูลการใช้ไฟฟ้าต่อหัวประชากรสามารถอธิบายปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยได้โดยมี r^2 อยู่ที่ 90.68 % ตัวแบบมีค่าความผิดพลาดมาตรฐานของการประมาณค่าเท่ากับ 78.352 MW ซึ่งน้อยกว่าค่าเบี่ยงเบนมาตรฐานของปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย ซึ่งมีค่าเท่ากับ 254.988 MW โดยมีค่า MAPE เท่ากับ 27.64% สะท้อนถึงความเหมาะสมของตัวแบบยังไม่ค่อยดีนัก ส่วนผลวิเคราะห์ความน่าเชื่อถือของตัวแบบในส่วนของความผิดพลาดเป็นตามสมมติฐาน

ผลการวิเคราะห์ตัวแบบอนุกรมเวลา

เนื่องจากอนุกรมเวลามีแนวโน้มชัดเจนแต่ไม่มีฤดูกาลเด่นชัด ดังนั้นตัวแบบ Holt-Winters จึงมีค่า Level Seasonal และ Trend เท่ากับ 0.97 0.68 และ 0.06 ตามลำดับ ซึ่งสามารถเขียนสมการได้ ดังนี้

$$F_t = 0.97 * X_t / S_{t-12} + 0.03 * (F_{t-1} + T_{t-1})$$

$$S_t = 0.68 * X_t / F_t + 0.32 * S_{t-12}$$

$$T_t = 0.06 * (F_t - F_{t-1}) + 0.94 * T_{t-1}$$


$$W_{t+m} = (F_t + mT_t)S_{t+m-12}$$

และได้ผลลัพธ์ของการพยากรณ์มีค่า MAPE เท่ากับ 3.38% และค่า r^2 เท่ากับ 98.63% ในส่วนของตัวแบบ ARIMA (p, d, q) (p', d', q') เมื่อพิจารณาตามภาพ ACF และ PACF ของข้อมูลอนุกรมเวลาหลังการทำ 1st Difference เพื่อปรับแนวโน้มออกไปในภาพที่ 3 พบว่า r_5 ของทั้งสองภาพหรือ Lag ที่ 5 ของ p และ q มีความสูงอย่างมีนัยสำคัญ ดังนั้นตัวแบบ ARIMA (5,1,5) ควรจะเป็นตัวแบบที่ถูกเลือกอย่างไรก็ตามเมื่อทำการประมาณค่าพารามิเตอร์ของตัวแบบ ทดสอบความแม่นยำและค่าสถิติต่าง ๆ พบว่า ตัวแบบ ARIMA (5,1,4) ก็ให้ผลเช่นเดียวกันทุกประการ ผู้วิจัยจึงเลือกตัวแบบ ARIMA (5,1,4) เป็นตัวแบบที่เหมาะสมที่สุด เพื่อลดความซับซ้อนของตามหลัก Parsimony โดยสามารถเขียนสมการ ARIMA (5,1,4) พร้อมค่าพารามิเตอร์ต่าง ๆ ได้ ดังนี้


$$\Delta Y_t = 6.640 - 0.263 \Delta Y_{t-1} - 0.173 \Delta Y_{t-2} + 0.247 \Delta Y_{t-3} + 0.420 \Delta Y_{t-4} + 0.201 \Delta Y_{t-5} \\ - 0.420 e_{t-1} - 0.349 e_{t-2} + 0.381 e_{t-3} + 0.523 e_{t-4} + e_t$$

ซึ่งได้ผลลัพธ์ของการพยากรณ์มีค่า MAPE เท่ากับ 2.57% และค่า r^2 เท่ากับ 98.62% โดยมี Ljung-box Statistic อยู่ที่ 4.80 เทียบกับ Critical Chi-square $\chi^2_{0.5,3}$ ที่ 7.82 และวิเคราะห์ Residual ACF ในภาพที่ 4 พบว่า ความผิดพลาดเป็น White Noise ส่วน Lag ที่มีค่าสูงคือ Lag ที่ 32 ซึ่งไกลมากน่าจะมาจากเหตุการณ์โดยบังเอิญจึงไม่นำมาพิจารณาสรุปผล

การพยากรณ์ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคา
ในประเทศไทย



ภาพที่ 3: ACF และ PACF ของอนุกรมเวลาปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย
หลังจากการทำ 1st Difference



ภาพที่ 4: แสดง Residual ACF ของตัวแบบ ARIMA (5,1,4)


ผลการวิเคราะห์ตัวแบบรวมผลพยากรณ์

ผลการวิเคราะห์ตัวแบบอนุกรมเวลาทั้ง 3 ตัวแบบและตัวแบบรวมผลพยากรณ์ใน 3 กรณีระหว่างตัวแบบถดถอยพหุคูณแบบ Stepwise MLR กับ Holt-Winters (0.97, 0.68, 0.06) ระหว่างตัวแบบถดถอยพหุคูณแบบ Stepwise MLR กับ ARIMA (5,1,4) และระหว่าง Holt-Winters (0.97, 0.68, 0.06) กับ ARIMA (5,1,4) ได้ผลดังตารางที่ 2 ดังนี้

ตารางที่ 2: ผลการวิเคราะห์ตัวแบบอนุกรมเวลาทั้ง 3 ตัวแบบและตัวแบบรวมผลพยากรณ์ใน 3 กรณี

ตัวแบบ	น้ำหนักตัวแบบ			MAPE (%)	r^2 (%)
	Stepwise MLR	Holt-Winters	ARIMA (5,1,4)		
Stepwise MLR				27.64	90.98
Holt-Winters				3.38	98.63
ARIMA (5,1,4)				2.57	98.62
Stepwise MLR + Holt-Winters	0.09	0.92		4.97	98.72
Stepwise MLR + ARIMA (5,1,4)	0.09		0.92	4.75	98.75
Holt-Winters + ARIMA (5,1,4)		0.46	0.55	3.05	98.73

จากตารางที่ 2 พบว่า ตัวแบบถดถอยพหุคูณแบบ Stepwise MLR มีความแม่นยำอยู่ที่ 90.98% แต่มีความแม่นยำน้อยกว่าตัวแบบอนุกรมเวลาอย่างเห็นได้ชัดรวมทั้งมีค่าความผิดพลาดโดยเฉลี่ยที่ค่อนข้างสูง ในขณะที่ตัวแบบอนุกรมเวลาระหว่าง Holt-Winters (0.97, 0.68, 0.06) และ ARIMA (5,1,4) นั้นมีความแม่นยำที่ใกล้เคียงกัน ส่งผลให้เมื่อทำการรวมผลพยากรณ์ คำนวณน้ำหนักของตัวแบบ Stepwise MLR จึงมีอยู่เพียงประมาณ 0.09 เท่านั้นเมื่อเทียบกับตัวแบบของ Holt-Winters (0.97, 0.68, 0.06) และตัวแบบ ARIMA (5,1,4) ซึ่งมีน้ำหนักประมาณ 0.92 และเมื่อนำตัวแบบ Holt-Winters (0.97, 0.68, 0.06) และ ARIMA (5,1,4) มารวมผลพยากรณ์ก็พบว่า ได้น้ำหนักของทั้งสองตัวแบบที่ใกล้เคียงกันที่ 0.46 และ 0.55 ตามลำดับ สาเหตุที่ตัวแบบอนุกรมเวลาที่มีความแม่นยำกว่าตัวแบบถดถอยพหุคูณในกรณีนี้ เนื่องจากตัวแบบ Holt-Winters มีองค์ประกอบภายในที่สามารถจับอิทธิพลของแนวโน้มและฤดูกาลได้โดยตรงขณะที่ตัวแบบ ARIMA ใช้ข้อมูลจริงและความผิดพลาดในการพยากรณ์ในอดีตมาถ่วงน้ำหนักเพื่อพยากรณ์อนาคต ซึ่งข้อมูลอนุกรมเวลาปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยไม่มีอิทธิพลของฤดูกาลจึงลดความผันผวนลงไปมากทำให้ตัวแบบทั้งสองมีความแม่นยำในการพยากรณ์สูง ขณะที่ตัวแบบ Multiple Linear Regression นั้นความแม่นยำของตัวแบบจะอยู่ที่การเลือกปัจจัยสำคัญที่ส่งผลกระทบต่อตัวแปรตาม ในกรณีนี้เริ่มจากการพิจารณา 5 ปัจจัยแต่เนื่องจากมีปัญหา Multicollinearity จึงถูกคัดออกโดยเทคนิค Stepwise Selection จึงเหลือเพียง 3 ปัจจัยเท่านั้น ซึ่งส่งผลกระทบต่อความแม่นยำของตัวแบบ ดังนั้นการนำตัวแบบพยากรณ์ไปใช้งานนั้นกรณีที่มีจุดประสงค์ทางด้านการพยากรณ์เป็นหลัก ตัวแบบทางอนุกรมเวลาให้ความแม่นยำของการพยากรณ์เกินกว่า 98% ควรถูกนำไปใช้ซึ่งเป็นไปได้ทุกกรณีคือ ตัวแบบ Holt-Winters (0.97, 0.68, 0.06) ตัวแบบ ARIMA (5,1,4) หรือตัวแบบ Combined Forecast ของทั้งสอง เนื่องจากมีความแตกต่างกันน้อยกว่า 1% และการเลือกตัวแบบเดียวในทางปฏิบัติจะลดความซับซ้อนของการคำนวณลง อย่างไรก็ตามสำหรับงานวิจัยนี้ ผู้วิจัยเลือกตัวแบบ Combined Forecast ระหว่างตัวแบบ Holt-Winters (0.97, 0.68, 0.06) และตัวแบบ ARIMA (5,1,4) มาใช้ เนื่องจากให้น้ำหนักของตัวแบบทั้งสองใกล้เคียงกันและมีความแม่นยำสูงสุดเมื่อเปรียบเทียบกับตัวแบบเดี่ยว ภาพที่ 5 แสดงผลเปรียบเทียบค่าพยากรณ์จากตัวแบบ Combined Forecast ระหว่าง Holt-Winters (0.97, 0.68, 0.06) และ ARIMA (5,1,4) กับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยจริงในช่วง พ.ศ. 2016 – ธ.ค. 2021 ค่าพยากรณ์ระหว่าง ม.ค. 2022 – ธ.ค. 2024 เพื่อให้เห็นแนวโน้มปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยในช่วง 3 ปีข้างหน้า ในส่วนของวัตถุประสงค์ เพื่ออธิบายสาเหตุของการเปลี่ยนแปลงปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทย ตัวแบบ Stepwise MLR สามารถถูกนำมาใช้ได้ เนื่องจากมีความแม่นยำเกิน 90% แต่ยังคงควรที่จะมีการพัฒนาให้ตัวแบบมีความแม่นยำสูงขึ้นจนใกล้เคียงจากตัวแบบอนุกรมเวลาต่อไป



ภาพที่ 5: แสดงผลค่าพยากรณ์จากตัวแบบ Combined Forecast ระหว่าง Holt-Winters (0.97, 0.68, 0.06) และ ARIMA (5,1,5) กับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยจริง ในช่วง พ.ศ. 2016 – ค.ศ. 2022 และค่าพยากรณ์ในอีก 3 ปีข้างหน้า

ดังนั้นจึงสรุปผลการวิจัยได้ว่า ในส่วนของการพิจารณาปัจจัยระดับมหภาคที่มีความสัมพันธ์กับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยพบว่า จำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน และข้อมูลการใช้ไฟฟ้าต่อหัวประชากร มีความสัมพันธ์ที่เป็นบวกอย่างมีนัยสำคัญจากมากไปน้อยกับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยตามลำดับ และอธิบายได้ว่า จำนวนติดตั้งระบบเซลล์แสงอาทิตย์บนหลังคาในประเทศไทย กำลังผลิตไฟฟ้าจากพลังงานหมุนเวียน และข้อมูลการใช้ไฟฟ้าต่อหัวประชากรสามารถอธิบายปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยได้ 90.98% ในส่วนของความแม่นยำของตัวแบบพยากรณ์พบว่า ตัวแบบรวมผลพยากรณ์ระหว่าง Holt-Winters (0.97, 0.68, 0.06) และ ARIMA (5,1,4) ให้ค่าน้ำหนักของสองตัวแบบที่ 0.45 และ 0.55 นั้นมีความเหมาะสมที่สุด โดยมีค่า MAPE เท่ากับ 3.05% และ r^2 เท่ากับ 98.73% ตามลำดับ โดยเมื่อทำการพยากรณ์ปริมาณกำลังผลิตไฟฟ้าจากเซลล์แสงอาทิตย์บนหลังคาในประเทศไทยโดยรวมในอีก 3 ปีข้างหน้าระหว่างปี 2022–2024 ตามภาพที่ 5 พบว่า ปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในประเทศไทยจะอยู่ที่ 11,961.22 MW 13,125.86 MW และ 14,262.26 MW ตามลำดับ หรือมีอัตราเติบโตอยู่ที่ปีละประมาณ 10 % ซึ่งข้อมูลพยากรณ์นี้มีความสำคัญเป็นอย่างยิ่ง เพราะสามารถนำไปใช้ประโยชน์กับภาครัฐในการเทียบเคียงการเติบโตของปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคา กับเป้าหมายของแผนพัฒนากำลังผลิตไฟฟ้าของประเทศไทยปี 2018–2037 (PDP2018 Revision I) สำหรับเป็นข้อมูลในการวางแผนเชิงนโยบายในการคิดมาตรการส่งเสริม (Incentives) เพื่อการติดตั้งเซลล์แสงอาทิตย์บนหลังคาของทั้งภาคอุตสาหกรรม เกษตรกรรมและครัวเรือนให้มากขึ้น และเพื่อกระตุ้นผู้ประกอบการเอกชนให้มีการลงทุนด้านธุรกิจการผลิตและการให้บริการเกี่ยวกับเซลล์ไฟฟ้าแสงอาทิตย์ รวมทั้งการสร้างนวัตกรรมใหม่ๆ ในอุตสาหกรรมพลังงานแสงอาทิตย์ของประเทศไทย ซึ่งการใช้เซลล์แสงอาทิตย์บนหลังคาในภาคธุรกิจและอุตสาหกรรมจะส่งผลให้สามารถลดการใช้พลังงานไฟฟ้าจากโครงข่ายไฟฟ้าในระบบหลักและช่วยลดต้นทุนการผลิตไฟฟ้าได้ นอกจากนี้การใช้เซลล์แสงอาทิตย์บนหลังคาในภาคครัวเรือนจะช่วยลดค่าไฟฟ้า ทำให้เศรษฐกิจในครัวเรือนดีขึ้น และยังเป็นการช่วยลดการลงทุนของภาครัฐตามแนวทางการผลิตไฟฟ้าจากพลังงานทางเลือก เพื่อลดการใช้ไฟฟ้าและให้บรรลุเป้าหมายของแผน PDP2018–2037 ที่ตั้งเป้าให้มีการใช้พลังงานหมุนเวียนประมาณ 30% ของการใช้พลังงานทั้งหมด ส่งผลให้ประเทศไทยมีความมั่นคงด้านพลังงานในที่สุด

สำหรับข้อจำกัดในงานวิจัยนี้ ได้แก่ ข้อมูลที่นำมาใช้ในการศึกษามีจำนวนที่ค่อนข้างจำกัด เนื่องจากเป็นข้อมูลจากสำนักงานคณะกรรมการกำกับกิจการพลังงาน (กกพ.) ที่เริ่มเก็บข้อมูลตั้งแต่ปี 2016 หลังจากคณะกรรมการนโยบายพลังงานแห่งชาติ (กพช.) ได้เห็นชอบในการรับซื้อไฟฟ้าจากโครงการผลิตไฟฟ้าพลังงานแสงอาทิตย์ติดตั้งบนหลังคา ดังนั้นในอนาคตเมื่อมีข้อมูลมากขึ้นก็สามารถขยายขอบเขตของข้อมูลสำหรับการวิจัยได้ โดยอาจมีการพิจารณาเพิ่มตัวแปรอิสระระดับมหภาคที่อาจมีความสัมพันธ์กับปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาให้มากขึ้น อาทิ ราคาน้ำมันดิบ ในส่วนของตัวแบบอนุกรมเวลานั้น ผู้วิจัยได้ยึดหลัก Pasimony ในการเลือกเครื่องมือเพื่อวิเคราะห์ข้อมูลที่เหมาะสมก่อน ถึงแม้ว่าตัวแบบ Winters และ ARIMA จะได้ถูกพัฒนามาอย่างยาวนาน แต่ในงานวิจัยนี้ก็พบว่า ตัวแบบทั้งสองสามารถทำหน้าที่ได้เป็นอย่างดี โดยเฉพาะเมื่อตรวจสอบความผิดพลาดในการพยากรณ์ MAPE มีค่าน้อยกว่า 3% และความแม่นยำในการพยากรณ์อยู่ในระดับสูงกว่า 98% ในอนาคตเมื่อมีข้อมูลมากขึ้นตามลำดับผู้วิจัยจะได้มีการทดลองวิเคราะห์ด้วยตัวแบบที่มีความซับซ้อนขึ้น เช่น Machine Learning ตามความเหมาะสมต่อไป สำหรับงานวิจัยนี้ผู้วิจัยได้ทำการทดลองพยากรณ์ข้อมูลออกไปในช่วง 3 ปีข้างหน้าระหว่าง ปี 2022-2024 ซึ่งเมื่อข้อมูลยอดปริมาณการใช้ไฟฟ้าจากเซลล์แสงอาทิตย์จริงเกิดขึ้นล่าสุดและสามารถเข้าถึงได้ ก็ควรมีการปรับปรุงค่าพยากรณ์ โดยนำข้อมูลจริงล่าสุดเข้ามาพิจารณาด้วย เพื่อประสิทธิผลของการพยากรณ์ นอกจากนี้ควรมีการศึกษาปริมาณการใช้เซลล์แสงอาทิตย์บนหลังคาในเชิงเปรียบเทียบ เช่น ประเภทบ้านพักอาศัย ประเภทธุรกิจ และประเภทโรงงานอุตสาหกรรมในอนาคต เพื่อช่วยให้ภาครัฐและเอกชนสามารถนำผลลัพธ์ของการพยากรณ์ไปใช้วางแผนในแต่ละส่วนได้ตามวัตถุประสงค์อย่างชัดเจนและแม่นยำมากยิ่งขึ้นนั่นเอง

REFERENCES

- Assouline, D., Mohajeri, N., & Scartezzini, J. L. (2018). Large-scale rooftop solar photovoltaic technical potential estimation using Random Forests. *Applied energy*, 217, 189–211.
- Box, G.E. P., & Jenkins, G.M. (1970) *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- Chaianong, A., Bangviwat, A., & Menke, C. (2019). Forecast of rooftop PV adoption in Thailand. *Science & Technology Asia*, 13–41.
- Chungcharoen, E. (2017). *Business Forecasting*. Bangkok: Thammasat University Press.
- Department of Alternative Energy Development and Efficiency (2020). THAILAND: Alternative Energy Development Plan 2018–2037 (AEDP 2018–2037).
- Department of Alternative Energy Development and Efficiency (n.d.). Solar Energy Production Manual.
- Department of Alternative Energy Development and Efficiency (n.d.). Alternative Energy Development and Investment Series 2: Solar Energy Manual.
- Energy Policy and Planning Office Ministry of Energy (2021). *Energy Statistics of Thailand 2021*. Sahamitr Printing & Publishing Company Limited.
- Fachrizal, M., & Tang, J. (2019). Forecasting annual solar PV capacity installation in Thailand residential sector: A user segmentation approach. *Engineering Journal*, 23(6), 99–115.
- Hair, J.F, Black, W.C, Babin, B.J., Anderson, R.E, & Tatham, R.L., (2006). *Multivariate Data Analysis*. 6th Edition, Pearson Education International.
- Houchati, M., Beitelmal, A. H., & Khraisheh, M. (2022). Predictive modeling for rooftop solar energy throughput: a machine learning-based optimization for building energy demand scheduling. *Journal of Energy Resources Technology*, 144(1).
- Khongnantha, J. (2021). Forecasting of Solar Rooftop Consumption in Thailand. Independent Study. *Master of Business Administration*. Bangkok: Thammasat University.
- Lee, M., & Hong, T. (2019). Hybrid agent-based modeling of rooftop solar photovoltaic adoption by integrating the geographic information system and data mining technique. *Energy conversion and management*, 183, 266–279.
- Lobel, R., & Perakis, G. (2011). Consumer Choice Model for Forecasting Demand and Designing Incentives For Solar Technology. *Operations Research Center*. Sloan School of Management, MIT.
- Nelson, C. R. (1984). A benchmark for the accuracy of econometric forecasts of GNP. *Business Economics*, 52–58.
- Phumikanjana, W. (2019). *Forecasting of Solar Energy System Production*. Master Thesis. Bangkok: Kasetsart University.

- Singchai, P., & Keeratiwintakorn, P. (2014). Electricity Demand Forecast for Thailand Demand Side Management Center. *Information Technology Journal*, 10(2), 32–42.
- Saengsuwan, T. (2020). Prediction Model for Solar PV Rooftop Production. *Journal of Renewable Energy and Smart Grid Technology*, 15(2), 16–25.
- Saophan, P. (2018). Forcecasting Solar power for Self-Consumption of Households in Thailand Using System Dynamics Model. *Master' thesis*. Sirindhorn International Institute of Technology Thammasat University.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management science*, 6(3), 324–342.
- Zhang, H., Vorobeychik, Y., Letchford, J., & Lakkaraju, K. (2014). *Predicting Rooftop Solar Adoption Using Agent-Based Modeling*. Energy Market Prediction: Papers from the 2014 AAAI Fall Symposium.