

การพยากรณ์ความเร็วลมด้วยการเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก และปัญญาประดิษฐ์ แบบอธิบายได้: กรณีศึกษา จังหวัดภูเก็ต ประเทศไทย

เกศรา พลไชย¹, อีระพงษ์ บุญรักษา², พรหมพัทธ์ บุญรักษา^{3,*}

¹สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยกรุงเทพธนบุรี

²สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์

³สาขาวิชาวิศวกรรมเมคคาทรอนิกส์ คณะวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ

Received: 3 November 2025

Revised: 24 December 2025

Accepted: 25 December 2025

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพยากรณ์ความเร็วลมรายชั่วโมงในจังหวัดภูเก็ตเพื่อสนับสนุนการวางแผนการผลิตไฟฟ้าจากพลังงานลม โดยประยุกต์ใช้และเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกควบคู่กับเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ ข้อมูลที่ใช้เป็นข้อมูลสภาพอากาศรายชั่วโมงย้อนหลังของเดือนมกราคม-ธันวาคม 2567 จำนวน 12 เดือน แบ่งเป็นชุดฝึกสอน 8 เดือน และชุดทดสอบ 4 เดือน ผลการทดลองพบว่าแบบจำลองการเรียนรู้ของเครื่อง (การถดถอยเชิงเส้น) มีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เท่ากับ 1.5679 ค่ารากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ยเท่ากับ 2.0739 และค่าสัมประสิทธิ์การตัดสินใจเท่ากับ 0.8113 ขณะที่แบบจำลองการเรียนรู้เชิงลึกให้ค่าสัมประสิทธิ์การตัดสินใจอยู่ในช่วง 0.2581–0.5760 ในส่วนของการวิเคราะห์ด้วยเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ชี้ให้เห็นว่าความเร็วลมย้อนหลังระยะสั้นและตัวแปรด้านเวลาเป็นปัจจัยสำคัญที่สุดที่ส่งผลต่อความเร็วลม ซึ่งสะท้อนรูปแบบลมรายวันของพื้นที่ชายฝั่ง ผลการวิจัยยืนยันว่าแบบจำลองการเรียนรู้ของเครื่อง (การถดถอยเชิงเส้น) มีความเหมาะสมในการใช้พยากรณ์ความเร็วลมทั้งด้านความแม่นยำและความสามารถในการอธิบายผลลัพธ์ ผลการพยากรณ์ความเร็วลมที่ได้จากแบบจำลองนี้สามารถนำไปประยุกต์ใช้ในการวางแผนบริหารจัดการพลังงานลมและเสถียรภาพของระบบการผลิตไฟฟ้าจากพลังงานลมได้อย่างมีประสิทธิภาพ

คำสำคัญ: การพยากรณ์ความเร็วลม การเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก ปัญญาประดิษฐ์แบบอธิบายได้

*ผู้ประสานงานหลัก; อีเมล: promphak.b@rmutsb.ac.th

Wind Speed Forecasting using Machine Learning, Deep Learning, and Explainable AI: A Case Study of Phuket, Thailand

Kedsara Palachai¹, Terapong Boonraksa², Promphak Boonraksa^{3,*}

¹Electrical Engineering, Faculty of Engineering, Bangkok Thonburi University

²Electrical Engineering, Faculty of Engineering,

Rajamangala University of Technology Rattanakosin

³Mechatronics Engineering, Faculty of Engineering and Architecture,

Rajamangala University of Technology Suvarnabhumi

Received: 3 November 2025

Revised: 24 December 2025

Accepted: 25 December 2025

Abstract

This study aims to forecast hourly wind speed in Phuket Province to support wind power generation planning by applying and comparing machine learning and deep learning models in conjunction with explainable artificial intelligence (XAI) techniques. The dataset consists of historical hourly meteorological data covering a 12-month period from January to December 2024. The data were divided into an eight-month training set and a four-month testing set. Experimental results indicate that the machine learning model, particularly linear regression, outperformed deep learning models, achieving a mean absolute error (MAE) of 1.5679, a root mean square error (RMSE) of 2.0739, and a coefficient of determination (R^2) of 0.8113. In contrast, the deep learning models yielded R^2 values ranging from 0.2581 to 0.5760. XAI-based analysis reveals that short-term lagged wind speed variables and temporal features are the most influential factors affecting wind speed, reflecting the daily wind patterns characteristic of coastal areas. The findings confirm that the linear regression model is well suited for hourly wind speed forecasting in terms of both predictive accuracy and interpretability. The resulting wind speed forecasts can be effectively applied to wind energy management, storage planning, and enhancing the operational stability of wind power generation systems.

Keywords: Wind Speed Forecasting, Machine Learning, Deep Learning, Explainable Artificial Intelligence

*Corresponding Author; E-mail: promphak.b@rmutsb.ac.th

ความเป็นมาและความสำคัญของปัญหา

ตั้งแต่ช่วงปี พ.ศ. 2543 เป็นต้นมา โลกได้ให้ความสำคัญต่อการลดการปล่อยก๊าซเรือนกระจกและการเปลี่ยนผ่านสู่พลังงานสะอาดอย่างจริงจัง ภายหลังการลงนามในพิธีสารเกียวโต พ.ศ. 2540 และความตกลงปารีส พ.ศ. 2558 หลายประเทศจึงเริ่มลดการพึ่งพาเชื้อเพลิงฟอสซิลและเพิ่มสัดส่วนการใช้พลังงานหมุนเวียนในระบบผลิตไฟฟ้าเพื่อบรรลุเป้าหมาย Net Zero Emission ภายในปี พ.ศ. 2593 (United Nations, 2015) จากรายงานของ Global Wind Energy Council ในปี พ.ศ. 2567 พบว่าพลังงานลมมีกำลังผลิตติดตั้งทั่วโลกเกินกว่า 1,000 กิกะวัตต์ (GW) และมีสัดส่วนในการผลิตไฟฟ้าราว 7% ของปริมาณไฟฟ้าทั่วโลก (GWEC, 2024) สอดคล้องกับรายงานของ International Energy Agency (2023) ซึ่งยืนยันว่าพลังงานลมเป็นแหล่งพลังงานหมุนเวียนที่เติบโตเร็วที่สุดในช่วง 10 ปีที่ผ่านมา (IEA, 2023) อย่างไรก็ตาม พลังงานลมมีลักษณะผันผวนและไม่ต่อเนื่องส่งผลให้กำลังการผลิตไฟฟ้าไม่สามารถควบคุมได้ หากไม่สามารถคาดการณ์ความเร็วลมล่วงหน้าอย่างแม่นยำอาจเกิดความเสียหายต่อเสถียรภาพของระบบไฟฟ้าและการเดินเครื่องโรงไฟฟ้าสำรอง (Ackermann, 2012)

ในประเทศไทย รัฐบาลได้บรรจุพลังงานลมไว้ในแผนพัฒนากำลังผลิตไฟฟ้า PDP พ.ศ. 2567–2580 ซึ่งระบุว่าประเทศไทยมีกำลังผลิตจากพลังงานลมกว่า 1,500 เมกะวัตต์ในปี พ.ศ. 2567 และตั้งเป้าเพิ่มเป็น 3,000 เมกะวัตต์ในปี พ.ศ. 2580 เพื่อเสริมความมั่นคงทางพลังงานของประเทศ (Electricity Generating Authority of Thailand., 2024) โดยเฉพาะพื้นที่ชายฝั่งทะเลอันดามัน เช่น จังหวัดภูเก็ต ได้รับการระบุว่าเป็นทำเลที่มีศักยภาพด้านความเร็วลมสูง เหมาะสมกับการติดตั้งกังหันลมเพื่อผลิตไฟฟ้าเชิงพาณิชย์ (Department of Alternative Energy Development and Efficiency, 2024) แต่พลังงานลมมีความไม่แน่นอนสูง ขึ้นอยู่กับสภาพภูมิอากาศ เช่น ความเร็วลม ความชื้น อุณหภูมิ และรังสีดวงอาทิตย์ หากไม่มีการพยากรณ์ความเร็วลมที่แม่นยำจะทำให้การวางแผนผลิตไฟฟ้า การจ่ายไฟเข้าสู่ระบบสายส่ง และการบริหารระบบกักเก็บพลังงานไม่สามารถดำเนินการได้อย่างมีประสิทธิภาพ (Li and Shi, 2010) วิธีการพยากรณ์แบบดั้งเดิม เช่น แบบจำลองการพยากรณ์อากาศเชิงตัวเลข แบบจำลองอัตราถดถอยเชิงบูรณาการและค่าเฉลี่ยเคลื่อนที่ และแบบจำลองการทำให้เรียบแบบเอ็กซ์โพเนนเชียลแม้จะใช้ในทางอุตุนิยมวิทยา แต่ไม่สามารถรองรับลักษณะของข้อมูลลมที่มีความไม่เชิงเส้นและมีความสัมพันธ์ตามเวลาได้ดี (Hyndman and Athanasopoulos, 2021) ดังนั้นแนวคิดการประยุกต์ใช้การเรียนรู้ของเครื่อง เช่นแบบจำลองป่าการตัดสินใจแบบสุ่มและแบบจำลองการถดถอยด้วยการเพิ่มพูนเชิงชั้นและการเรียนรู้เชิงลึก เช่น โครงข่ายประสาทเทียมแบบหน่วยความจำระยะยาว และโครงข่ายประสาทเทียมแบบหน่วยความจำระยะยาวสองทิศทางจึงได้รับความสนใจมากขึ้นในการพยากรณ์พลังงานลม (Friedman, 2001; Hochreiter and Schmidhuber, 1997) ถึงแม้โมเดลเหล่านี้จะให้ความแม่นยำสูงแต่ยังมีข้อจำกัดสำคัญคือไม่สามารถอธิบายได้อย่างชัดเจนว่าโมเดลตัดสินใจจากอะไร ดังนั้นงานวิจัยปัจจุบันจึงเริ่มนำปัญญาประดิษฐ์แบบอธิบายได้ เช่นการจัดอันดับความสำคัญของตัวแปรด้วยการสลัค่า และ SHAP มาใช้เพื่อระบุตัวแปรใด เช่นความเร็วลมย้อนหลัง เวลาในหนึ่งวัน ความชื้น หรือรังสีดวงอาทิตย์ ส่งผลต่อค่าความเร็วลมมากที่สุด (Breiman, 2001)

จากการทบทวนวรรณกรรมที่เกี่ยวข้อง (Zhang et al., 2024), (Li et al., 2023), (Wang et al., 2022) พบว่างานวิจัยด้านการพยากรณ์ความเร็วลมส่วนใหญ่มุ่งเน้นการเพิ่มความแม่นยำของแบบจำลอง โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก อย่างไรก็ตามยังขาดการศึกษาเชิงเปรียบเทียบอย่างเป็นระบบที่ประเมินความเหมาะสมของแบบจำลองทั้งสองกลุ่มควบคู่กันในบริบทของพื้นที่ชายฝั่งของประเทศไทย โดยเฉพาะจังหวัดภูเก็ตซึ่งมีลักษณะภูมิอากาศเฉพาะตัว แม้ว่าการวิจัยจำนวนมากจะแสดงให้เห็นว่าแบบจำลองสมัยใหม่

สามารถให้ผลการพยากรณ์ที่มีความแม่นยำสูง แต่ส่วนใหญ่ยังมุ่งเน้นการประเมินประสิทธิภาพเชิงตัวเลขเป็นหลัก และขาดการอธิบายเชิงลึกเกี่ยวกับปัจจัยที่แบบจำลองใช้ในการตัดสินใจพยากรณ์ ส่งผลให้การนำผลการพยากรณ์ไปใช้ในการวางแผนการผลิตไฟฟ้าจากพลังงานลม การบริหารจัดการระบบกักเก็บพลังงาน และการรักษาเสถียรภาพของระบบไฟฟ้าในเชิงปฏิบัติยังมีข้อจำกัด


ด้วยเหตุนี้งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อประยุกต์ใช้และเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการพยากรณ์ความเร็วลมรายชั่วโมงในจังหวัดภูเก็ต โดยใช้ข้อมูลสภาพอากาศจริง พร้อมทั้งประเมินความสามารถในการอธิบายผลของแบบจำลองด้วยเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ เพื่อระบุแบบจำลองที่ให้ผลการพยากรณ์มีความแม่นยำสูงและสามารถอธิบายที่มาของผลลัพธ์ได้อย่างเหมาะสม อันจะนำไปสู่การประยุกต์ใช้ในการวางแผนพลังงานลม การบริหารจัดการระบบกักเก็บพลังงาน และการเสริมสร้างเสถียรภาพของระบบไฟฟ้าของประเทศไทยในอนาคต

วัตถุประสงค์ของการวิจัย

1. เพื่อเสนอแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการพยากรณ์ความเร็วลมรายชั่วโมงของจังหวัดภูเก็ต โดยอาศัยข้อมูลสภาพอากาศจริง
2. เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองแต่ละประเภท ด้วยตัวชี้วัด ค่า MAE, RMSE และ R^2 เพื่อระบุว่าโมเดลใดมีความแม่นยำสูงที่สุดในการพยากรณ์ความเร็วลม
3. เพื่อใช้เทคนิคปัญญาประดิษฐ์แบบอธิบายได้ในการวิเคราะห์ปัจจัยที่มีอิทธิพลต่อการพยากรณ์ความเร็วลม และสนับสนุนการประยุกต์ใช้ผลการพยากรณ์ในการบริหารจัดการระบบพลังงานลมและระบบไฟฟ้า

กรอบแนวคิดในการวิจัย

เพื่อให้การดำเนินงานวิจัยมีทิศทางที่ชัดเจน และสามารถเชื่อมโยงระหว่างปัญหาการวิจัย วัตถุประสงค์ วิธีดำเนินการ และผลลัพธ์ที่คาดหวังได้อย่างเป็นระบบ จึงมีความจำเป็นต้องกำหนด กรอบแนวคิดในการวิจัย ซึ่งเป็นแผนผังแสดงความสัมพันธ์ของตัวแปรต่าง ๆ ที่ใช้ในการพยากรณ์ความเร็วลมในจังหวัดภูเก็ตดังภาพที่ 1



ภาพที่ 1 กรอบแนวคิดในการวิจัย

เอกสาร ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

การพยากรณ์ความเร็วลมที่มีความแม่นยำมีบทบาทสำคัญต่อการประเมินศักยภาพพลังงานลม การดำเนินงานของระบบไฟฟ้า และการวางแผนพลังงานหมุนเวียน อย่างไรก็ตาม ความเร็วลมมีลักษณะไม่เป็นเชิงเส้น ไม่คงที่ และมีความสับสน เนื่องจากได้รับอิทธิพลจากปัจจัยด้านอุตุนิยมวิทยาและบรรยากาศ ส่งผลให้วิธีการพยากรณ์เชิงสถิติแบบดั้งเดิมไม่สามารถให้ผลลัพธ์ที่แม่นยำได้อย่างเพียงพอ งานวิจัยในช่วงหลังจึงหันมาให้ความสนใจกับการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก และปัญญาประดิษฐ์แบบอธิบายได้ เพื่อยกระดับทั้งความแม่นยำและความสามารถในการตีความผลลัพธ์ของแบบจำลอง

งานวิจัยของ Zhang et al. (2024) ได้นำเสนอการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมแบบหน่วยความจำระยะยาวร่วมกับเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ เพื่อพยากรณ์ความเร็วลม โดยใช้ตัวแปรด้านอุตุนิยมวิทยา ได้แก่ ความเร็วลม อุณหภูมิ และความชื้น ผลการศึกษาพบว่าแบบจำลองดังกล่าวให้ผลการพยากรณ์ที่แม่นยำกว่าแบบจำลองเชิงสถิติและแบบจำลองการเรียนรู้ของเครื่องทั่วไปอย่างมีนัยสำคัญ นอกจากนี้ การวิเคราะห์ด้วยเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ยังชี้ให้เห็นว่า ค่าความเร็วลมย้อนหลังในช่วงระยะสั้นประมาณ 1–3 ชั่วโมงเป็นปัจจัยที่มีอิทธิพลสูงสุดต่อผลการพยากรณ์ ซึ่งช่วยเพิ่มทั้งความแม่นยำและความสามารถในการตีความของแบบจำลอง

ในทำนองเดียวกัน Li et al. (2023) ได้ศึกษาการใช้แบบจำลองหน่วยความจำระยะยาวสองทิศทาง โดยใช้ข้อมูลความเร็วลมและตัวแปรอุตุนิยมวิทยา ภายใต้การแบ่งข้อมูลสำหรับการฝึกสอนร้อยละ 70 และการทดสอบร้อยละ 30 ผลการทดลองแสดงให้เห็นว่าแบบจำลองหน่วยความจำระยะยาวสองทิศทางให้ค่าความคลาดเคลื่อนต่ำกว่าแบบจำลองหน่วยความจำระยะยาวแบบทิศทางเดียวและแบบจำลองป่าการตัดสินใจแบบสุ่ม เนื่องจากสามารถเรียนรู้ความสัมพันธ์เชิงเวลาทั้งในอดีตและอนาคตได้ อย่างไรก็ตาม งานวิจัยดังกล่าวยังไม่ได้ทำการวิเคราะห์อิทธิพลของตัวแปรนำเข้าเชิงลึกในด้านการอธิบายผลลัพธ์ของแบบจำลอง

ในส่วน Khortsriwong et al. (2023) ได้นำเสนอการประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึกหลายรูปแบบ ได้แก่ แบบจำลองคอนโวลูชัน แบบจำลองหน่วยความจำระยะยาว และแบบจำลองเชิงผสม เพื่อพยากรณ์กำลังไฟฟ้าจากระบบเซลล์แสงอาทิตย์ โดยใช้ข้อมูลอุตุนิยมวิทยาเป็นตัวแปรนำเข้า ผลการศึกษาพบว่าแบบจำลองการเรียนรู้เชิงลึกสามารถลดข้อผิดพลาดในการพยากรณ์ได้อย่างมีนัยสำคัญเมื่อเทียบกับวิธีการทั่วไป และมีประสิทธิภาพสูงในการจัดการข้อมูลที่มีความผันผวน อย่างไรก็ตาม งานวิจัยดังกล่าวยังไม่ได้พิจารณาประเด็นด้านความสามารถในการอธิบายผลลัพธ์ของแบบจำลองอย่างเป็นระบบ

นอกจากนี้ Wang et al. (2022) ได้เสนอการใช้เทคนิคการวิเคราะห์องค์ประกอบหลักร่วมกับแบบจำลองหน่วยความจำระยะยาว เพื่อพยากรณ์ความเร็วลมจากตัวแปรอุตุนิยมวิทยาหลายตัว โดยแบ่งข้อมูลสำหรับการฝึกสอนร้อยละ 75 และการทดสอบร้อยละ 25 ผลการศึกษาชี้ให้เห็นว่าการวิเคราะห์องค์ประกอบหลักช่วยลดสัญญาณรบกวนของข้อมูลและเพิ่มความแม่นยำของการพยากรณ์อย่างมีนัยสำคัญ อย่างไรก็ตาม การลดมิติข้อมูลดังกล่าวส่งผลให้ความสามารถในการตีความเชิงกายภาพของตัวแปรนำเข้าแต่ละตัวลดลง


ในกลุ่มแบบจำลองการเรียนรู้ของเครื่อง Ahmad et al. (2021) ได้เปรียบเทียบประสิทธิภาพของแบบจำลองเวกเตอร์สนับสนุนสำหรับการถดถอย แบบจำลองป่าการตัดสินใจแบบสุ่ม และแบบจำลองการถดถอยด้วยการเพิ่มพูนเชิงชั้น โดยใช้ข้อมูลความเร็วลมและตัวแปรอุตุนิยมวิทยา ผลการทดลองภายใต้การแบ่งข้อมูลสำหรับการฝึกสอนร้อยละ 70 และการทดสอบร้อยละ 30 พบว่าแบบจำลองป่าการตัดสินใจแบบสุ่มให้ผลการพยากรณ์

ดีที่สุด โดยมีค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด รองลงมาคือแบบจำลองการเพิ่มพูนเชิงชั้น ขณะที่แบบจำลอง
เวกเตอร์สนับสนุนสำหรับการถดถอยให้ผลการพยากรณ์ต่ำที่สุด แม้ว่าแบบจำลองเชิงกลุ่มจะให้ความแม่นยำ
สูงกว่าแบบจำลองเดี่ยว แต่ยังมีข้อจำกัดในการเรียนรู้ความสัมพันธ์เชิงเวลาในระยะยาวเมื่อเทียบกับแบบจำลอง
การเรียนรู้เชิงลึก

จากการทบทวนวรรณกรรมข้างต้นสามารถสรุปได้ว่า งานวิจัยส่วนใหญ่มักใช้การแบ่งข้อมูลเป็นชุดฝึกสอน
และชุดทดสอบในสัดส่วนประมาณร้อยละ 70–80 และร้อยละ 20–30 ตามลำดับ เพื่อประเมินความสามารถของ
แบบจำลองบนข้อมูลที่ไม่เคยเห็นมาก่อน ผลการศึกษาส่วนใหญ่ชี้ว่าแบบจำลองการเรียนรู้เชิงลึก โดยเฉพาะ
แบบจำลองหน่วยความจำระยะยาวและแบบจำลองต่อยอด เช่น แบบจำลองหน่วยความจำระยะยาวสองทิศทาง
และแบบจำลองผสมคอนโวลูชันกับหน่วยความจำระยะยาว ให้ความแม่นยำสูงในการพยากรณ์ข้อมูลอนุกรมเวลา
เนื่องจากสามารถเรียนรู้ความสัมพันธ์เชิงเวลาที่ซับซ้อนได้ดี ขณะเดียวกัน แบบจำลองการเรียนรู้ของเครื่องเชิง
กลุ่ม เช่น แบบจำลองป่าการตัดสินใจแบบสุ่มและแบบจำลองการเพิ่มพูนเชิงชั้น ยังคงเป็นทางเลือกที่มี
ประสิทธิภาพสำหรับข้อมูลที่มีความผันผวนสูง อย่างไรก็ตาม งานวิจัยล่าสุดเริ่มให้ความสำคัญกับการประยุกต์ใช้
ปัญญาประดิษฐ์แบบอธิบายได้ เพื่อเพิ่มความโปร่งใสและความน่าเชื่อถือของผลการพยากรณ์ ซึ่งยังคงเป็นประเด็น
ที่ต้องได้รับการศึกษาเพิ่มเติม โดยเฉพาะในบริบทของพื้นที่ชายฝั่งทะเลของประเทศไทย


วิธีดำเนินการวิจัย

การวิจัยนี้เป็นการวิเคราะห์เชิงปริมาณโดยประยุกต์ใช้เทคนิค การเรียนรู้ของเครื่อง เรียนรู้เชิงลึก
ในการพยากรณ์ความเร็วลมรายชั่วโมง และทำการวิเคราะห์เชิงลึกด้วยเทคนิคปัญญาประดิษฐ์แบบอธิบายได้เพื่อ
ประเมินความสำคัญของคุณลักษณะโครงสร้างการดำเนินงานวิจัยสามารถแบ่งออกเป็น 6 ขั้นตอนหลักแสดงดัง
ภาพที่ 2




ภาพที่ 2 ขั้นตอนการทำงานของแบบจำลองพยากรณ์โพลไฟฟ้า


ข้อมูลที่ใช้ในการวิจัยเป็นข้อมูลสภาพอากาศในอดีต รายชั่วโมงสำหรับพื้นที่จังหวัดภูเก็ต โดยรวบรวมข้อมูลย้อนหลังรวม 12 เดือนตั้งแต่เดือนมกราคม พ.ศ. 2567 ถึงเดือนธันวาคม พ.ศ. 2567 จำนวนชั่วโมงประมาณ 8,784 ชั่วโมง ใช้ข้อมูลจาก Open-Meteo API โดยเน้นช่วงเวลาที่มีความผันผวนของลมตามฤดูกาล เพื่อให้โมเดลสามารถเรียนรู้รูปแบบที่หลากหลาย ข้อมูลใช้ในการพยากรณ์ประกอบด้วย ความเร็วลมในภาพที่ 3 อุณหภูมิในภาพที่ 4 ความชื้นในภาพที่ 5 ความกดอากาศในภาพที่ 6 และการแผ่รังสีดวงอาทิตย์ในภาพที่ 7




ภาพที่ 3 ข้อมูลความเร็วลมของพื้นที่จังหวัดภูเก็ต




ภาพที่ 4 ข้อมูลอุณหภูมิของพื้นที่จังหวัดภูเก็ต



ภาพที่ 5 ข้อมูลความชื้นของพื้นที่จังหวัดภูเก็ต



ภาพที่ 6 ข้อมูลความกดอากาศของพื้นที่จังหวัดภูเก็ต



ภาพที่ 7 ข้อมูลความเข้มการแผ่รังสีดวงอาทิตย์ของพื้นที่จังหวัดภูเก็ต

เพื่อให้สามารถประเมินประสิทธิภาพของแบบจำลองได้อย่างถูกต้อง งานวิจัยนี้แบ่งข้อมูลออกเป็น 2 ชุด โดยใช้ข้อมูลฝึกสอนช่วงเวลา 8 เดือนแรก ตั้งแต่เดือนมกราคม ถึง เดือนสิงหาคม พ.ศ. 2567 ประมาณ 5,856 ชั่วโมง เพื่อให้โมเดลเรียนรู้รูปแบบของข้อมูลและชุดทดสอบ 4 เดือนหลังตั้งแต่เดือนกันยายน ถึง เดือนธันวาคม พ.ศ. 2567 ประมาณ 2,928 ชั่วโมง ใช้ตรวจสอบความสามารถในการพยากรณ์ของโมเดลที่ไม่เคยเห็นมาก่อนในอัตราส่วน 80:20 โดยชุดตรวจสอบถูกใช้เพื่อติดตามประสิทธิภาพของแบบจำลองระหว่างการฝึก และใช้เทคนิค early stopping เพื่อป้องกันปัญหาการเรียนรู้มากเกินไป

เพื่อให้โมเดลเรียนรู้รูปแบบเชิงเวลาของความเร็วลมได้ดีขึ้น จึงมีการสร้างคุณลักษณะเพิ่มเติมได้แก่ ค่าความเร็วลมย้อนหลัง โดยสร้างตัวแปรแทนค่าความเร็วลมในอดีตก่อนเวลา t เพื่อให้โมเดลเข้าใจแนวโน้มก่อนหน้าดังสมการที่ 1

$$\text{Wind Speed Lag}_n(t) = \text{Wind Speed}(t - n) \quad (1)$$

โดย

t	คือ	เวลาปัจจุบัน (ชั่วโมงที่ต้องการทำนายความเร็วลม)
N	คือ	จำนวนชั่วโมงย้อนหลัง
$\text{Wind Speed}_{(t-n)}$	คือ	ค่าความเร็วลมที่บันทึกไว้เมื่อ n ชั่วโมงก่อนหน้า
$\text{Wind Speed Lag}_n(t)$	คือ	ตัวแปรใหม่ที่นำมาใช้ในการฝึกโมเดล เพื่อให้โมเดลเรียนรู้จากอดีต

เพื่อสะท้อนว่า ความเร็วลมในปัจจุบันมีความต่อเนื่องจากข้อมูลในอดีตนอกจากนี้เพื่อให้โมเดลเข้าใจรูปแบบการเปลี่ยนแปลงของลมในวงจรรายวันได้สร้างตัวแปรเวลาแบบไซน์และโคไซน์สมการที่ 2

$$\begin{aligned} Hour_sin(t) &= \sin\left(\frac{2\pi \times Hour(t)}{24}\right) \\ Hour_cos(t) &= \cos\left(\frac{2\pi \times Hour(t)}{24}\right) \end{aligned} \quad (2)$$

โดย

Hour(t) คือ ชั่วโมงของวัน
sin,cos คือ ฟังก์ชันคณิตศาสตร์สำหรับแทนลักษณะวนซ้ำของเวลา

จากสมการที่ 2 เพื่อช่วยให้โมเดลการเรียนรู้เชิงลึกให้สามารถเรียนรู้ลักษณะเป็นคาบได้อย่างมีประสิทธิภาพ หลังจากเตรียมข้อมูลและสร้างคุณลักษณะแล้ว ขั้นตอนถัดไปคือการนำข้อมูลเข้าสู่แบบจำลอง 2 กลุ่ม คือ การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ซึ่งใช้ไฮเปอร์พารามิเตอร์ของแบบจำลองที่ใช้ในการจำลองตารางที่ 1

ตารางที่ 1 ไฮเปอร์พารามิเตอร์ของแบบจำลองการเรียนรู้ของเครื่องและแบบจำลองการเรียนรู้เชิงลึก

ประเภทของปัญหาประติษฐ์	แบบจำลอง	ไฮเปอร์พารามิเตอร์
แบบจำลองการเรียนรู้เชิงลึก	แบบจำลองการถดถอยเชิงเส้น	fit_intercept = default
	แบบจำลองป่าสุ่ม	n_estimators = 250, random_state = 42, n_jobs = -1
	แบบจำลองการเพิ่มประสิทธิภาพแบบไล่ระดับ	n_estimators = 250, learning_rate = 0.05, max_depth = 3, random_state = 42
	แบบจำลองเวกเตอร์สนับสนุนสำหรับการถดถอย	kernel = RBF, C = 10, gamma = scale
	แบบจำลองการปรับเรียบเชิงเลขชี้กำลัง	trend = additive, seasonal = additive, seasonal_periods = 24, initialization = estimated
แบบจำลองการเรียนรู้ของเครื่อง	แบบจำลองหน่วยความจำระยะยาว	units = 50, activation = ReLU, optimizer = Adam, loss = MSE, epochs = 50, batch_size = 32, look-back = 24 ชม.
	แบบจำลองหน่วยความจำระยะยาวสองทิศทาง	units = 50, activation = ReLU, optimizer = Adam, loss = MSE, epochs = 50, batch_size = 32, look-back = 24 ชม.

หลังจากกำหนดค่าไฮเปอร์พารามิเตอร์ที่สอดคล้องกันสำหรับแบบจำลองการเรียนรู้ของเครื่อง ได้แก่ แบบจำลองการถดถอยเชิงเส้น แบบจำลองป่าการตัดสินใจแบบสุ่ม แบบจำลองการถดถอยด้วยการเพิ่มพูนเชิงชั้น แบบจำลองเวกเตอร์สนับสนุนสำหรับการถดถอย และแบบจำลองการปรับเรียบเชิงเลขชี้กำลัง รวมถึงแบบจำลองการเรียนรู้เชิงลึก ได้แก่ แบบจำลองโครงข่ายประสาทเทียมแบบหน่วยความจำระยะยาว แบบจำลองโครงข่ายประสาทเทียมแบบหน่วยความจำระยะยาวสองทิศทาง และแบบจำลองคอนโวลูชันหนึ่งมิติร่วมกับหน่วยความจำระยะยาว เพื่อใช้ในการพยากรณ์ความเร็วลมแล้ว ขั้นตอนถัดไปคือการประเมินประสิทธิภาพของแบบจำลองแต่ละประเภทอย่างเป็นระบบ เพื่อให้สามารถระบุได้ว่าแบบจำลองใดมีความเหมาะสมมากที่สุดสำหรับชุดข้อมูลของจังหวัดภูเก็ต

เครื่องมือวิจัย

การประเมินผลในงานวิจัยนี้ใช้ตัวชี้วัดที่ครอบคลุมทั้งด้านความคลาดเคลื่อนและความแม่นยำของแบบจำลองพยากรณ์ ได้แก่ ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย และสัมประสิทธิ์การตัดสินใจซึ่งเป็นตัวชี้วัดที่ได้รับการยอมรับอย่างแพร่หลายในงานวิจัยด้านการพยากรณ์และการวิเคราะห์ข้อมูลเชิงสถิติ โดยตัวชี้วัดดังกล่าวสามารถสะท้อนทั้งระดับความผิดพลาดเชิงปริมาณและความสามารถของแบบจำลองในการอธิบายข้อมูลจริงได้อย่างเหมาะสม (Dawan et al., 2020; Khortsriwong et al., 2023)

ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE) เป็นตัวชี้วัดที่ใช้วัดค่าเฉลี่ยของความแตกต่างเชิงสัมบูรณ์ระหว่างค่าที่แบบจำลองพยากรณ์กับค่าจริง โดยให้ความสำคัญกับความคลาดเคลื่อนของข้อมูลทุกจุดอย่างเท่าเทียมกัน ข้อดีของค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์คือสามารถตีความได้ง่าย เนื่องจากมีหน่วยเดียวกับข้อมูลจริง เช่น เมตรต่อวินาทีสำหรับความเร็วลม และมีความไวต่อค่าผิดปกติน้อยกว่าตัวชี้วัดที่อาศัยการยกกำลังสองของความคลาดเคลื่อนทำให้เหมาะสำหรับการประเมินความคลาดเคลื่อนเฉลี่ยโดยรวมของแบบจำลองในเชิงปฏิบัติค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์คำนวณได้ดังสมการที่ 2

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

โดย

y	คือ	ค่าจริงของความเร็วลม
$\hat{y}_i$	คือ	ค่าที่แบบจำลองพยากรณ์
n	คือ	จำนวนข้อมูลทั้งหมด

รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) เป็นตัวชี้วัดที่คำนึงถึงขนาดของความคลาดเคลื่อนเป็นพิเศษ เนื่องจากมีการยกกำลังสองของความแตกต่างระหว่างค่าพยากรณ์และค่าจริงก่อนนำมาหาค่าเฉลี่ยและถอดราก ดังนั้นรากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย จึงมีความไวต่อค่าคลาดเคลื่อนที่มีค่าสูงผิดปกติมากกว่า ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ การใช้ รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย ช่วยให้สามารถตรวจสอบได้ว่าแบบจำลองมีข้อผิดพลาดรุนแรงในช่วงเวลาหรือไม่ ซึ่งมีความสำคัญอย่างยิ่งในงานพยากรณ์ความเร็วลมที่ค่าความคลาดเคลื่อนสูงอาจส่งผลกระทบต่อวางแผนผลิตพลังงานและความมั่นคงของระบบไฟฟ้ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย สามารถคำนวณได้ดังสมการที่ 3

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

ปัญญา เชี่ยวชาญ เอ็กบาน คุณธรรม

Intellectual, Professional, Cheerfulness, Morality

สัมประสิทธิ์การตัดสินใจ (R^2) เป็นตัวชี้วัดที่ใช้ประเมินความสามารถของแบบจำลองในการอธิบายความแปรปรวนของข้อมูลจริง โดยมีค่าอยู่ในช่วงตั้งแต่ค่าติดลบไปจนถึง 1 ค่าสัมประสิทธิ์การตัดสินใจ ที่เข้าใกล้ 1 แสดงว่าแบบจำลองสามารถอธิบายข้อมูลจริงได้ดี ในขณะที่ค่าสัมประสิทธิ์การตัดสินใจ เท่ากับ 0 หมายถึงแบบจำลองมีประสิทธิภาพไม่แตกต่างจากการเดาค่าเฉลี่ยของข้อมูล และหากค่าสัมประสิทธิ์การตัดสินใจมีค่าติดลบ แสดงว่าแบบจำลองมีประสิทธิภาพต่ำกว่าการเดาค่าเฉลี่ย ซึ่งบ่งชี้ว่าแบบจำลองยังไม่เหมาะสมสำหรับการพยากรณ์ในกรณีนั้นสัมประสิทธิ์การตัดสินใจสามารถคำนวณได้ดังสมการที่ 4

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

โดย

	$\bar{y}$	คือ	ค่าเฉลี่ยของข้อมูลจริง
ถ้า	$R^2=1$		แบบจำลองทำนายได้สมบูรณ์ที่สุด
ถ้า	$R^2=0$		แบบจำลองแย่มาก ๆ กับการเดาค่าเฉลี่ย
ถ้า	$R^2<0$		แบบจำลองแย่กว่าการเดาค่าเฉลี่ย

แม้แบบจำลองให้ค่าการพยากรณ์ที่แม่นยำสูงแต่ยังมีข้อจำกัดสำคัญคือไม่สามารถอธิบายได้อย่างชัดเจนว่าโมเดลตัดสินใจจากอะไร ดังนั้น เพื่อเพิ่มความน่าเชื่อถือของผลการพยากรณ์ งานวิจัยนี้จึงประยุกต์ใช้เทคนิค XAI ได้แก่ การจัดอันดับความสำคัญของตัวแปรด้วยการสลับค่า และ SHAP ในการวิเคราะห์บทบาทของตัวแปรอิสระแต่ละตัวต่อการคาดการณ์ความเร็วลม

การวัดความสำคัญของตัวแปรด้วยการสลับค่า ใช้วัดว่าหากสลับค่าของตัวแปรใดตัวแปรหนึ่งแล้วทำให้ค่าความคลาดเคลื่อนของโมเดลเพิ่มขึ้นมากเพียงใดดังสมการที่ 5 (Breiman, 2001)

$$FI_i = Error_{shuffled}(X_i) - Error_{original} \quad (5)$$

โดย

FI_j	คือ	ค่าความสำคัญของตัวแปรที่ j
$Error_{original}$	คือ	ค่าความคลาดเคลื่อนของโมเดลก่อนสลับค่า
$Error_{shuffled}(X_j)$	คือ	ค่าคลาดเคลื่อนหลังจากสลับข้อมูลของตัวแปร X_j แบบสุ่ม
หากค่า FI_j สูง	คือ	ตัวแปรนั้นมีความสำคัญมาก เพราะการสลับค่าทำให้โมเดลแม่นยำน้อยลง

การอธิบายแบบจำลองด้วยค่าเชปเพลย์ ใช้คำนวณว่า ตัวแปรแต่ละตัวมีส่วนเพิ่มหรือลดค่าผลลัพธ์จากโมเดลมากน้อยเพียงใด โดยอิงจากทฤษฎีเกมแบบร่วมมือสมการที่ 6 (Shapley, 1953; Lundberg and Lee, 2017)

$$\phi_j = \sum_{S \subseteq F \setminus \{j\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f(S \cup \{j\}) - f(S)] \quad (6)$$

โดย

F	คือ	ชุดของตัวแปรทั้งหมดในแบบจำลอง
S	คือ	ชุดย่อยของตัวแปรที่ไม่รวมตัวแปร j
f(s)	คือ	ค่าพยากรณ์เมื่อใช้เฉพาะตัวแปรในชุด S

$f(SU_{ij})$ คือ ค่าพยากรณ์หลังจากเพิ่มตัวแปร j
 ϕ_j คือ ค่าผลกระทบของตัวแปร j (SHAP Value)

ผลการวิจัย


หลังจากดำเนินการพัฒนาแบบจำลองและประเมินประสิทธิภาพด้วยค่าชี้วัด ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE) รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และ สัมประสิทธิ์การตัดสินใจ (R^2) แล้วงานวิจัยนี้ได้นำเสนอผลการพยากรณ์ความเร็วลมจากแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก โดยเปรียบเทียบกับค่าจริงที่ได้จากข้อมูลสภาพอากาศในจังหวัดภูเก็ตผลดังตารางที่ 2

ตารางที่ 2 ผลประเมินประสิทธิภาพด้วยค่าชี้วัด

โมเดล	MAE	RMSE	R^2
แบบจำลองการถดถอยเชิงเส้น	1.5679	2.0739	0.8113
แบบจำลองป่าการตัดสินใจแบบสุ่ม	1.6255	2.1420	0.7987
แบบจำลองการถดถอยด้วยการเพิ่มพูนเชิงชั้น	1.6742	2.1796	0.7916
แบบจำลองการถดถอยด้วยเวกเตอร์สนับสนุน	1.6827	2.2263	0.7826
แบบจำลองการทำให้เรียบแบบเอ็กซ์โพเนนเชียล	4.9705	6.2585	-0.7184
แบบจำลองหน่วยความจำระยะยาว	2.5618	4.1205	0.2581
แบบจำลองหน่วยความจำระยะยาวสองทิศทาง	2.3716	3.1152	0.5760
แบบจำลองผสมคอนโวลูชันหนึ่งมิติกับหน่วยความจำระยะยาว	2.4593	3.1792	0.5584

จากตารางที่ 2 พบว่า แบบจำลองการเรียนรู้ของเครื่องให้ผลการพยากรณ์ความเร็วลมดีกว่ากลุ่มแบบจำลองการเรียนรู้เชิงลึกอย่างชัดเจน โดยแบบจำลองการถดถอยเชิงเส้นให้ผลดีที่สุด มีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เท่ากับ 1.5679 รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ยเท่ากับ 2.0739 และค่าสัมประสิทธิ์การตัดสินใจเท่ากับ 0.8113 แสดงว่าสามารถอธิบายความแปรปรวนของข้อมูลจริงได้มากกว่าร้อยละ 81 รองลงมาคือแบบจำลองป่าการตัดสินใจแบบสุ่มและแบบจำลองการถดถอยด้วยการเพิ่มพูนเชิงชั้น ซึ่งให้ค่าความคลาดเคลื่อนและค่าสัมประสิทธิ์การตัดสินใจใกล้เคียงกัน ขณะที่แบบจำลองการเรียนรู้เชิงลึก โดยเฉพาะแบบจำลองหน่วยความจำระยะยาวสองทิศทาง ให้ผลการพยากรณ์ดีที่สุดในกลุ่มนี้ แต่ยังมีประสิทธิภาพต่ำกว่าแบบจำลองการเรียนรู้ด้วยเครื่อง


งานวิจัยนี้ได้ทดสอบ Diebold–Mariano โดยเปรียบเทียบชุดค่าความคลาดเคลื่อนจากการพยากรณ์ของแบบจำลองการถดถอยเชิงเส้นกับแบบจำลองตัวแทนในแต่ละกลุ่ม ทั้งกลุ่มการเรียนรู้ของเครื่องและกลุ่มการเรียนรู้เชิงลึก ภายใต้ระดับนัยสำคัญทางสถิติที่ 0.05 ผลการทดสอบแสดงให้เห็นว่าแบบจำลองการถดถอยเชิงเส้นให้ผลการพยากรณ์ที่ดีกว่าแบบจำลองอื่นอย่างมีนัยสำคัญทางสถิติ ซึ่งสอดคล้องกับผลการประเมินด้วยค่าชี้วัดค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์, รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย และ สัมประสิทธิ์การตัดสินใจ และยืนยันถึงความเหมาะสมของแบบจำลองดังกล่าวสำหรับการพยากรณ์ความเร็วลมในพื้นที่จังหวัดภูเก็ต




ภาพที่ 8 ผลการพยากรณ์ความเร็วลม

จากภาพที่ 8 ซึ่งแสดงการเปรียบเทียบระหว่างค่าความเร็วลมจริงกับค่าที่ได้จากการพยากรณ์ของแบบจำลองต่าง ๆ พบว่า แบบจำลองในกลุ่มการเรียนรู้ด้วยเครื่อง ได้แก่ การถดถอยเชิงเส้น ป่าการตัดสินใจแบบสุ่ม และการถดถอยด้วยการเพิ่มพูนเชิงซ้อน สามารถติดตามแนวโน้มของค่าความเร็วลมจริงได้ดี โดยเฉพาะในช่วงที่ความเร็วลมเปลี่ยนแปลงในระดับต่ำถึงปานกลาง ซึ่งสอดคล้องกับผลการประเมินเชิงปริมาณที่แสดงว่าแบบจำลองการถดถอยเชิงเส้นให้ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ต่ำที่สุดเท่ากับ 1.5679 และมีค่าสัมประสิทธิ์การตัดสินใจสูงถึง 0.8113

ในขณะที่แบบจำลองการถดถอยด้วยเวกเตอร์สนับสนุนให้ผลการพยากรณ์ด้อยกว่ากลุ่มข้างต้นเล็กน้อย โดยมีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เท่ากับ 1.6827 และค่าสัมประสิทธิ์การตัดสินใจเท่ากับ 0.7826 ส่วนแบบจำลองการทำให้เรียบแบบเอ็กซ์โพเนนเชียลให้ผลการพยากรณ์ต่ำที่สุด โดยมีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์สูงถึง 4.9705 และค่าสัมประสิทธิ์การตัดสินใจเป็นลบ (-0.7184) ซึ่งสะท้อนว่าแบบจำลองไม่เหมาะสมกับข้อมูลความเร็วลมที่มีความผันผวนและไม่เป็นเชิงเส้น สำหรับกลุ่มแบบจำลองการเรียนรู้เชิงลึก ได้แก่ แบบจำลองหน่วยความจำระยะยาว แบบจำลองหน่วยความจำระยะยาวสองทิศทาง และแบบจำลองผสมคอนโวลูชันหนึ่งมิติกับหน่วยความจำระยะยาว พบว่าให้ผลการพยากรณ์ต่ำกว่าแบบจำลองการเรียนรู้ด้วยเครื่อง โดยมีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์อยู่ในช่วง 2.3716–2.5618 และค่าสัมประสิทธิ์การตัดสินใจอยู่ในช่วง 0.2581–0.5760 ทั้งนี้ แม้จะใช้ข้อมูลฝึกเป็นระยะเวลา 8 เดือน และข้อมูลทดสอบ 4 เดือน แบบจำลองการเรียนรู้เชิงลึกยังไม่สามารถแสดงศักยภาพได้อย่างเต็มที่ ซึ่งอาจเกิดจากการกำหนดช่วงเวลาย้อนกลับเพียง 24 ชั่วโมงที่ยังไม่เพียงพอในการจับรูปแบบเชิงลำดับระยะยาวของความเร็วลม โดยความสำคัญของตัวแปรต่อแบบจำลอง Gradient Boosting Regressor จากการวิเคราะห์ด้วย SHAP (10 อันดับแรก) แสดงดังรูปที่ 9 และความสำคัญของตัวแปรจากการสลับลำดับคุณลักษณะสำหรับแบบจำลอง Gradient Boosting Regressor (10 อันดับแรก) แสดงดังรูปที่ 10



ภาพที่ 9 ความสำคัญของตัวแปรต่อแบบจำลอง Gradient Boosting Regressor
จากการวิเคราะห์ด้วย SHAP (10 อันดับแรก)



ภาพที่ 10 ความสำคัญของตัวแปรจากการสลับลำดับคุณลักษณะสำหรับแบบจำลอง
Gradient Boosting Regressor (10 อันดับแรก)

จากภาพที่ 9 และภาพที่ 10 ซึ่งแสดงผลการวิเคราะห์ความสำคัญของตัวแปรด้วยเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ ทั้งจากค่า SHAP และวิธีการสลับลำดับคุณลักษณะสำหรับแบบจำลองการถดถอยเชิงเส้น พบว่าผลการวิเคราะห์จากทั้งสองวิธีมีความสอดคล้องกัน โดยชี้ให้เห็นว่า ความเร็วลมย้อนหลัง 1 ชั่วโมงและ 2 ชั่วโมงเป็นปัจจัยที่มีอิทธิพลสูงสุดต่อการพยากรณ์ความเร็วลม สะท้อนถึงลักษณะการเปลี่ยนแปลงของลมในจังหวัดภูเก็ตที่มีความต่อเนื่องในระยะสั้น ซึ่งเป็นลักษณะเด่นของพื้นที่ชายฝั่งทะเล นอกจากนี้ ตัวแปรด้านเวลาในรูปแบบของฟังก์ชันไซน์และโคไซน์ของชั่วโมงมีบทบาทสำคัญในลำดับถัดมา แสดงให้เห็นว่าความเร็วลมในจังหวัดภูเก็ตมีรูปแบบการเปลี่ยนแปลงตามช่วงเวลาของวัน ขณะที่ตัวแปรด้านสภาพอากาศอื่น ๆ เช่น ความชื้นสัมพัทธ์ ทิศทางลม และอุณหภูมิย้อนหลัง มีอิทธิพลต่อการพยากรณ์ในระดับรองลงมา ส่วนรังสีแสงอาทิตย์มีความสำคัญต่ำ ซึ่งบ่งชี้ว่ามีผลต่อความเร็วลมทางอ้อมมากกว่าทางตรงในบริบทพื้นที่ศึกษา

ผลการวิเคราะห์ดังกล่าวแสดงให้เห็นว่า แบบจำลองสามารถอธิบายการพยากรณ์ความเร็วลมได้อย่างสอดคล้องกับลักษณะภูมิอากาศของจังหวัดภูเก็ต และงานวิจัยมีการวิเคราะห์และอธิบายปัจจัยที่มีอิทธิพลต่อการพยากรณ์ความเร็วลมด้วยเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ ทั้งนี้ ผลการพยากรณ์ที่สามารถอธิบายได้อย่างโปร่งใสยังสามารถนำไปใช้ประโยชน์ในการวางแผนการผลิตไฟฟ้าจากพลังงานลม การควบคุมระบบกักเก็บพลังงาน และการเพิ่มเสถียรภาพของระบบไฟฟ้าในจังหวัดภูเก็ตในอนาคตได้อย่างมีประสิทธิภาพ

อภิปรายผล

งานวิจัยที่ผ่านมาได้ให้ความสนใจกับการพยากรณ์ความเร็วลมโดยอาศัยเทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในบริบทที่หลากหลาย งานของ (Wang et al., 2022) แสดงให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียมแบบหน่วยความจำระยะยาวสามารถให้ผลการพยากรณ์ที่มีความแม่นยำสูงเมื่อใช้ข้อมูลระยะยาวหลายปีร่วมกับการลดมิติข้อมูลด้วยการวิเคราะห์องค์ประกอบหลัก แม้ผลลัพธ์จะมีประสิทธิภาพดีในเชิงตัวเลข แต่การศึกษาดังกล่าวไม่ได้ให้ความสำคัญกับการอธิบายบทบาทของตัวแปรนำเข้าที่มีผลต่อการตัดสินใจของแบบจำลองอย่างชัดเจน ในทำนองเดียวกัน (Hong et al., 2023) รายงานว่าแบบจำลองการเรียนรู้เชิงลึกและแบบจำลองการเรียนรู้ของเครื่องสามารถให้ผลการพยากรณ์ที่ใกล้เคียงกันเมื่อผสมผสานข้อมูลพยากรณ์อากาศเชิงตัวเลขกับข้อมูลย้อนหลัง โดยพบว่าแบบจำลองการเพิ่มพูนเชิงชั้นให้ผลดีที่สุด อย่างไรก็ตาม ผลลัพธ์ยังไม่ได้ถูกเชื่อมโยงกับลักษณะทางอุตุนิยมวิทยาในเชิงกายภาพอย่างเป็นระบบ ในบริบทของพื้นที่ชายฝั่ง (Zhang et al., 2021) ชี้ให้เห็นว่าแบบจำลองป่าการตัดสินใจแบบสุ่มมีความทนทานต่อความผันผวนของข้อมูลความเร็วลม และสามารถให้ผลการพยากรณ์ที่มีเสถียรภาพสูง ขณะเดียวกัน (Sankari et al., 2023) รายงานว่าแบบจำลองการเรียนรู้เชิงลึก เช่นแบบจำลองหน่วยความจำระยะยาวสองทิศทางมีประสิทธิภาพเหนือกว่าแบบจำลองเชิงเส้นเมื่อใช้ข้อมูลระยะยาวที่มีรูปแบบฤดูกาลชัดเจนแต่ประสิทธิภาพของแบบจำลองจะลดลงอย่างเห็นได้ชัดเมื่อปริมาณข้อมูลฝึกไม่เพียงพอต่อการตีความผลลัพธ์ (Lundberg and Lee, 2017) ได้เสนอการใช้ค่า SHAP เพื่ออธิบายผลลัพธ์ของแบบจำลองอย่างโปร่งใสซึ่งแนวคิดดังกล่าวเริ่มได้รับการประยุกต์ใช้ในงานพยากรณ์พลังงานมากขึ้น แม้ว่างานวิจัยจำนวนมากยังไม่ได้บูรณาการการวิเคราะห์เชิงอธิบายเข้ากับการเปรียบเทียบประสิทธิภาพของแบบจำลองอย่างครบถ้วน

ผลการศึกษาชี้ให้เห็นภาพที่แตกต่างจากงานวิจัยก่อนหน้านี้หลายฉบับ โดยพบว่าแบบจำลองการถดถอยเชิงเส้นให้ผลการพยากรณ์ความเร็วลมรายชั่วโมงของจังหวัดภูเก็ตดีที่สุด ด้วยค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เท่ากับ 1.5679 รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ยเท่ากับ 2.0739 และค่าสัมประสิทธิ์การตัดสินใจเท่ากับ 0.8113 ความแตกต่างดังกล่าวสะท้อนให้เห็นว่า ในกรณีของข้อมูลที่มีระยะเวลาเพียง 12 เดือนและมีความผันผวนสูงตามลักษณะภูมิอากาศชายฝั่ง แบบจำลองที่มีโครงสร้างไม่ซับซ้อนสามารถเรียนรู้ความสัมพันธ์เชิงเวลาระยะสั้นได้อย่างมีประสิทธิภาพมากกว่าแบบจำลองการเรียนรู้เชิงลึกซึ่งต้องอาศัยข้อมูลจำนวนมากและรูปแบบฤดูกาลที่ชัดเจน

นอกจากนี้ การนำเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ช่วยเพิ่มคุณค่าให้กับผลการศึกษา โดยการวิเคราะห์ด้วยค่า SHAP และการสลับลำดับคุณลักษณะสามารถระบุได้อย่างชัดเจนว่าความเร็วลมย้อนหลังในช่วง 1 และ 2 ชั่วโมงมีอิทธิพลสูงสุดต่อผลการพยากรณ์ ซึ่งสอดคล้องกับกลไกการเปลี่ยนแปลงของลมในระยะสั้นและหลักการทางอุตุนิยมวิทยาของพื้นที่ชายฝั่ง การตีความดังกล่าวช่วยเพิ่มความน่าเชื่อถือของแบบจำลองและเอื้อต่อการนำ

ผลลัพธ์ไปใช้ในเชิงปฏิบัติได้ดีกว่างานวิจัยก่อนหน้านี้ แต่การศึกษานี้ยังมีข้อจำกัดบางประการ โดยเฉพาะระยะเวลาของข้อมูลที่ครอบคลุมเพียงหนึ่งปี ซึ่งอาจยังไม่สะท้อนรูปแบบฤดูกาลระยะยาวของความเร็วลมอย่างครบถ้วน รวมถึงการกำหนดช่วงเวลาย้อนกลับเพียง 24 ชั่วโมงและการปรับจูนไฮเปอร์พารามิเตอร์ของแบบจำลองการเรียนรู้เชิงลึกที่ยังอยู่ในขอบเขตจำกัด งานวิจัยในอนาคตจึงควรขยายช่วงเวลาของข้อมูลให้ครอบคลุมหลายปี ทดลองใช้หน้าต่างเวลาย้อนกลับที่ยาวขึ้น และพัฒนาแบบจำลองเชิงผสมระหว่างการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกเพื่อเพิ่มทั้งความแม่นยำและความสามารถในการอธิบายผลลัพธ์ซึ่งในเชิงการประยุกต์ใช้ ผลการพยากรณ์ที่มีความแม่นยำและสามารถอธิบายได้สามารถนำไปใช้สนับสนุนการจัดทำระบบแจ้งเตือนการเปลี่ยนแปลงของความเร็วลมระยะสั้น การวางแผนการทำงานของระบบกักเก็บพลังงานไฟฟ้า และการตัดสินใจของผู้ควบคุมระบบโครงข่ายไฟฟ้าในการรักษาเสถียรภาพของระบบในพื้นที่ที่มีการใช้พลังงานลมเป็นสัดส่วนสูง

งานวิจัยนี้ได้บรรลุวัตถุประสงค์ในการพยากรณ์ความเร็วลมรายชั่วโมงของจังหวัดภูเก็ตโดยการประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกบนข้อมูลสภาพอากาศจริง ผลการเปรียบเทียบประสิทธิภาพด้วยค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย และสัมประสิทธิ์การตัดสินใจแสดงให้เห็นอย่างชัดเจนว่าแบบจำลองในกลุ่มการเรียนรู้ของเครื่องให้ผลการพยากรณ์ที่ดีกว่าแบบจำลองการเรียนรู้เชิงลึกในบริบทของข้อมูลที่มีระยะเวลาและความผันผวนจำกัด โดยแบบจำลองการถดถอยเชิงเส้นให้ผลดีที่สุดสามารถอธิบายความแปรปรวนของข้อมูลจริงได้มากกว่าร้อยละ 80 ซึ่งสะท้อนถึงความเหมาะสมของแบบจำลองที่มีโครงสร้างไม่ซับซ้อนสำหรับการพยากรณ์ความเร็วลมรายชั่วโมงในพื้นที่ชายฝั่ง นอกจากนี้ การนำเทคนิคปัญญาประดิษฐ์แบบอธิบายได้มาช่วยให้อธิบายการวิเคราะห์และอธิบายปัจจัยที่มีอิทธิพลต่อการพยากรณ์ความเร็วลมได้อย่างเป็นรูปธรรม โดยผลการวิเคราะห์ยืนยันว่าความเร็วลมย้อนหลังระยะสั้นและตัวแปรด้านเวลาเป็นปัจจัยสำคัญที่สุด ซึ่งสอดคล้องกับลักษณะการเปลี่ยนแปลงของลมในจังหวัดภูเก็ตและหลักการทางอุตุนิยมวิทยา ผลลัพธ์ดังกล่าวช่วยเพิ่มความน่าเชื่อถือของแบบจำลอง ทำให้สามารถนำผลการพยากรณ์ไปใช้สนับสนุนการวางแผนการผลิตไฟฟ้าจากพลังงานลม การบริหารจัดการระบบกักเก็บพลังงาน และการเพิ่มเสถียรภาพของระบบไฟฟ้าได้อย่างเหมาะสม โดยงานวิจัยนี้แสดงให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่องเมื่อผสมผสานกับเทคนิคปัญญาประดิษฐ์แบบอธิบายได้ สามารถตอบโจทย์ทั้งด้านความแม่นยำและการตีความผลลัพธ์ได้อย่างครบถ้วนและมีศักยภาพสูงในการนำไปประยุกต์ใช้ในงานด้านพลังงานลมและการวางแผนระบบไฟฟ้าจากพลังงานลมในพื้นที่ชายฝั่งของประเทศไทยในอนาคต

กิตติกรรมประกาศ

คณะผู้วิจัยขอขอบพระคุณ มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ มหาวิทยาลัยกรุงเทพธนบุรี และมหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ ที่ให้สนับสนุนการวิจัยในครั้งนี้ สำเร็จลุล่วงไปด้วยดี

เอกสารอ้างอิง

- Ackermann, T. (2012). *Wind power in power systems*. Wiley.
- Ahmad, T., Zhang, D., and Huang, C. (2021). Wind speed prediction using machine learning techniques. *Energy Reports*, 7, 576–586.

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Dawan, P., Sriprapha, K., Kittisontirak, S., Boonraksa, T., Junhuathon, N., Titiroongruang, W., and Niemcharoen, S. (2020). Comparison of power output forecasting on the photovoltaic system using adaptive neuro-fuzzy inference systems and particle swarm optimization–artificial neural network model. *Energies*, 13(2), 1-18.
- Department of Alternative Energy Development and Efficiency. (2024). *Thailand renewable energy outlook 2024*. Department of Alternative Energy Development and Efficiency.
- Electricity Generating Authority of Thailand. (2024). *Power development plan 2567–2580 (PDP 2024)*. Electricity Generating Authority of Thailand.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232.
- Global Wind Energy Council. (2024). *Global wind report 2024*. GWEC.
- Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Hong, Y., Zhou, Z., andamp; Zhao, J. (2023). Can we trust explainable AI in wind power forecasting? *Energy and AI*, 12, 100241.
- Hyndman, R. J., and Athanasopoulos, G. (2021). *Forecasting: Principles and practice*. 3rd ed. OTexts.
- International Energy Agency. (2023). *Net zero by 2050: A roadmap for the global energy sector*. International Energy Agency.
- Khortsriwong, N., Boonraksa, P., Boonraksa, T., Fangsuwannarak, T., Boonsrirat, A., Pinthurat, W., and Marungsri, B. (2023). Performance of deep learning techniques for forecasting PV power generation: A case study on a 1.5 MWp floating PV power plant. *Energies*, <https://doi.org/10.3390/en16052119>
- Khortsriwong, N., Boonraksa, P., Boonraksa, T., Fangsuwannarak, T., Boonsrirat, A., Pinthurat, W., and Marungsri, B. (2023). Performance of deep learning techniques for forecasting PV power generation: A case study on a 1.5 MWp floating PV power plant. *Energies*, 16(5), 2119. <https://doi.org/10.3390/en16052119>
- Li, G., and Shi, J. (2010). Application of forecasting methods in wind power integration. *Renewable Energy*, 35(12), 2850–2859.
- Li, X., Chen, Y., and Sun, W. (2023). Short-term wind speed forecasting using optimized BiLSTM networks. *Applied Energy*, 334, 120653.
- Lundberg, S. M., and Lee, S. I. (2017). *A unified approach to interpreting model predictions*. In *Advances in neural information processing systems*, pp. 4765–4774.

- Sankari, S., Paramasivan, S. K., Arockiasamy, K., andamp; Senthivel, S. (2023). Deep learning for wind speed forecasting using Bi-LSTM with selected features. *Intelligent Automation andamp; Soft Computing*, 35(3), 3829–3844. <https://doi.org/10.32604/iasc.2023.030480>
- Shapley, L. S. (1953). A value for n-person games. In H. W. Kuhn and A. W. Tucker (Eds.), *Contributions to the theory of games*. Princeton University Press.
- United Nations. (2015). *Paris agreement*. United Nations Treaty Series, 3156, 79.
- Wang, Q., Li, K., and Liu, S. (2022). Short-term wind speed prediction using PCA and LSTM. *Energy Conversion and Management*, 254, 115256.
- Zhang, Y., Liu, H., and Wang, J. (2024). Interpretable short-term wind speed forecasting using LSTM and SHAP. *Energy*, 286, 128640.