

การเปรียบเทียบการพยากรณ์สำหรับจำนวนจดทะเบียนรถยนต์ไฟฟ้าไฮบริด  
และรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีอนุกรมเวลา  
และวิธีซัพพอร์ตเวกเตอร์แมชชีน

COMPARISON OF THE FORECASTING MODELS FOR REGISTERED  
HYBRID ELECTRIC VEHICLES AND BATTERY ELECTRIC VEHICLES BY  
TIME SERIES AND SUPPORT VECTOR MACHINE METHODS



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
วิทยาศาตรมหาบัณฑิต สาขาวิชาสถิติและการวิเคราะห์ธุรกิจ  
ภาควิชาสถิติ คณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2566

KMITL-2023-SC-M-050-060

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

COMPARISON OF THE FORECASTING MODELS FOR REGISTERED  
HYBRID ELECTRIC VEHICLES AND BATTERY ELECTRIC VEHICLES BY  
TIME SERIES AND SUPPORT VECTOR MACHINE METHODS



THANITA KUMNURDNUKOOL

AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE  
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE IN STATISTICS AND  
BUSINESS ANALYTICS

DEPARTMENT OF STATISTICS SCHOOL OF SCIENCE  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2023

KMITL-2023-SC-M-050-060

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2023

SCHOOL OF SCIENCE

**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การเปรียบเทียบการพยากรณ์สำหรับจำนวนจดทะเบียนรถยนต์ไฟฟ้าไฮบริดและรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีอนุกรมเวลาและวิธีซัพพอร์ตเวกเตอร์แมชชีน
ชื่อนักศึกษา	ธนิดา กำเนิดนุกูล
รหัสประจำตัว	64605049
ปริญญา	วิทยาศาสตรมหาบัณฑิต (สถิติและการวิเคราะห์ธุรกิจ)
ภาควิชา	สถิติ
พ.ศ.	2566
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ผู้ช่วยศาสตราจารย์ ดร.กนกวรรณ ลีโรจนาประภา

### บทคัดย่อ

งานวิจัยฉบับนี้มีวัตถุประสงค์เพื่อเปรียบเทียบตัวแบบพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด และรถยนต์ไฟฟ้าแบตเตอรี่ในประเทศไทยจากข้อมูลรายเดือนที่จัดเก็บโดยกรมขนส่งทางบก ตั้งแต่เดือนมกราคม ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2022 โดยแบ่งข้อมูลเป็น 2 ส่วน ได้แก่ ส่วนที่ 1 สำหรับการสร้างตัวแบบพยากรณ์ โดยใช้ข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 รวมทั้งสิ้นจำนวน 48 เดือน และส่วนที่ 2 สำหรับการวัดประสิทธิภาพของตัวแบบพยากรณ์ โดยใช้ข้อมูลตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ค.ศ. 2022 วิธีในการสร้างตัวแบบพยากรณ์สำหรับงานวิจัยนี้มี 3 วิธี ได้แก่ วิธีแยกส่วนประกอบ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ และวิธีซัพพอร์ตเวกเตอร์แมชชีน โดยใช้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เป็นวิธีเปรียบเทียบตัวแบบพยากรณ์ที่เหมาะสมพบว่า วิธีซัพพอร์ตเวกเตอร์แมชชีนด้วยฟังก์ชันเคอร์เนล แบบ NU-Regression เป็นตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ซึ่งมีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 484.79 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 4.73% สำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 611.43 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 43.06%

**คำสำคัญ :** รถยนต์ไฟฟ้าแบตเตอรี่ รถยนต์ไฟฟ้าไฮบริด วิธีซัพพอร์ตเวกเตอร์แมชชีน  
วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ วิธีแยกส่วนประกอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

<b>Independent Study Title</b>	Comparison of the Forecasting Models for Registered Hybrid Electric Vehicles and Battery Electric Vehicles by Time Series and Support Vector Machine Methods
<b>Student Name</b>	Thanita Kumnurdnukool
<b>Student ID</b>	64605049
<b>Degree</b>	Master of Science (Statistics and Business Analytics)
<b>Department</b>	Statistics
<b>Year</b>	2023
<b>Independent Study Advisor</b>	Asst. Prof. Dr. Kanogkan Leerojanaprapa

### Abstract

This research aims to compare forecasting models for the number of registered Hybrid Electric Vehicles (HEVs) and Battery Electric Vehicles (BEVs) in Thailand based on monthly data collected by the Department of Transportation from January 2018 to December 2022. The data is divided into two parts: Part 1 is used for training data, consisting of data from January 2018 to December 2021, totaling 48 months, and Part 2 is used for testing data, consisting of data from January 2022 to December 2022. There are three methods for forecasting: decomposition, Holt-Winters method, and Support Vector Machine: Support Vector Regression (SVR) with Kernel functions. The performance of these models is evaluated by using the Root Mean Square Error (RMSE) and the Mean Absolute Percentage Error (MAPE). The analysis revealed that the Support Vector Machine: Support Vector Regression (SVR) with Kernel functions: NU-Regression, is the most suitable forecasting model for forecasting the number of registered Hybrid Electric Vehicles. This model achieved an RMSE of 484.79 and an MAPE of 4.73%. As for the number of registered Battery Electric Vehicles, the Support Vector Machine: Support Vector Regression (SVR) with Kernel functions: NU-Regression had an RMSE of 611.43 and an MAPE of 43.06%

Keywords: Battery Electric Vehicles, Hybrid Electric Vehicles, Support Vector Machine Method, Holt-Winters Method, Decomposition Method

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## กิตติกรรมประกาศ

ผู้จัดทำขอขอบพระคุณ ผศ.ดร.กนกวรรณ ลีโรจนประภา อย่างสูงสำหรับความเมตตากรุณา ความอดทนในการให้คำปรึกษา และมอบความหวังใให้ผู้จัดทำเสมอมา อาจารย์ได้เสนอแนะชี้แนะ ให้ผู้จัดทำได้มีการพัฒนา และปรับปรุงงานวิจัยอย่างต่อเนื่อง รวมถึงคอยเป็นกำลังใจสำคัญอีกหนึ่งกำลังใจที่ผลักดันให้ผู้จัดทำยืนหยัดจนถึงวันนี้ ผู้จัดทำหวังว่าจะสามารถนำความรู้ ประสบการณ์ รวมถึงพลังบวก และจิตวิญญาณที่แน่วแน่ในการฝ่าฟันอุปสรรคต่างๆ ที่ได้รับจากอาจารย์ไปใช้ในการพัฒนาตนเอง และงานในอนาคตได้อย่างเต็มที่

ขอขอบพระคุณรองศาสตราจารย์ ดร.อัชมา อระวีพร และผศ.ดร.พรพิมล ชัยวุฒิศักดิ์ ที่ได้ให้คำแนะนำ และเตือนสติในการเลือกวิธีดำเนินงานวิจัย คำแนะนำ และการเตือนสติที่ท่านได้ให้ไว้ เป็นแรงผลักดันให้ผู้จัดทำทบทวนตนเอง และปรับปรุงวิธีการดำเนินงานเพื่อให้ได้ผลลัพธ์ที่เหมาะสมกับสิ่งที่ผู้จัดทำได้ร่ำเรียนในสองปีที่ผ่านมา ผู้จัดทำจะใช้คำแนะนำเป็นแนวทางในการดำเนินชีวิตว่าการทำสิ่งใดก็ตาม ควรพิจารณาให้ถี่ถ้วนถึงสิ่งที่ยากทำกับความสามารถที่มี สองสิ่งนี้ควรสอดคล้องไปด้วยกัน เพื่อสุขภาพกาย และสุขภาพจิตที่ดีต่อตัวเอง

ขอขอบพระคุณอาจารย์ทุกท่าน ที่ได้สอนผู้จัดทำตลอดระยะเวลาสองปีที่ผ่านมา ความรู้และประสบการณ์ที่อาจารย์ทุกท่านได้แบ่งปันไปให้กับผู้จัดทำ เป็นทรัพย์ากรที่มีค่าที่สุดที่จะติดตัวผู้จัดทำไปตลอดกาล ผู้จัดทำจะนำไปประยุกต์ใช้ในการทำงาน หรือการเรียนรู้ในอนาคต รวมถึงแบ่งปันให้กับผู้อื่น เพื่อสร้างสรรค์สิ่งใหม่ๆ

ขอขอบคุณเทคโนโลยีในปัจจุบันที่มีบทบาทสำคัญในการทำให้ข้อมูลเป็นสิ่งที่เข้าถึงได้สะดวก และรวดเร็ว ขอขอบพระคุณกรมขนส่งทางบกที่พัฒนา และอัปเดตข้อมูลเกี่ยวกับรถยนต์ได้ดี ทำให้ผู้จัดทำสามารถเข้าถึงข้อมูลที่ต้องการได้อย่างสะดวก และถูกต้อง ซึ่งข้อมูลเหล่านี้เป็นสิ่งที่มีความสำคัญอย่างยิ่งของงานวิจัยนี้

ขอขอบคุณกลุ่มเพื่อนสาขาสถิติและการวิเคราะห์ธุรกิจที่ได้เรียนรู้ ทำงานร่วมกัน และใช้ชีวิตหลังเลิกเรียนด้วยกัน ขอให้ความสัมพันธ์ที่ดีที่ได้สร้างขึ้นด้วยกันยังคงเป็นแรงบันดาลใจ และเป็นกำลังใจให้กัน และกันเสมอไป

สุดท้ายนี้ ผู้จัดทำขอกราบขอบพระคุณครอบครัวที่เป็นกำลังใจให้กับผู้จัดทำเสมอมา แม้ว่า ณ ช่วงเวลานี้ เกิดสถานการณ์ยากลำบากของครอบครัว แต่แรงผลักดันนี้ ทำให้ผู้จัดทำพยายามอย่างสูงเพื่อให้ตัวเองสำเร็จในการศึกษาให้ได้ตามเป้าหมายที่ตั้งไว้ และหวังว่าจะมีโอกาสได้อยู่ปรองมตร่วมกับครอบครัวอย่างพร้อมหน้าพร้อมตาในวันรับปริญญาได้อย่างมีความสุข และเป็นที่ยึดจำตลอดไป

นางสาวธนิศา กำเนิดนุกูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ซ
<b>บทที่ 1 บทนำ.....</b>	<b>1</b>
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	4
1.3 ขอบเขตของงานวิจัย.....	4
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	5
1.5 นิยามคำศัพท์เฉพาะ.....	5
<b>บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>6</b>
2.1 ทฤษฎีที่เกี่ยวข้อง.....	6
2.1.1 การทดสอบแนวโน้มและอิทธิพลของฤดูกาล.....	6
2.1.2 การพยากรณ์เชิงปริมาณ.....	9
2.1.3 การพยากรณ์อนุกรมเวลา.....	9
2.1.4 ส่วนประกอบของอนุกรมเวลา.....	9
2.1.5 วิธีแยกส่วนประกอบ.....	10
2.1.6 วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์.....	11
2.1.7 วิธีซัพพอร์ตเวกเตอร์แมชชีน.....	13
2.1.8 วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน.....	14
2.1.9 การประเมินประสิทธิภาพวิธีพยากรณ์.....	15
2.2 งานวิจัยที่เกี่ยวข้อง.....	18
<b>บทที่ 3 วิธีการดำเนินงานวิจัย.....</b>	<b>21</b>
3.1 เก็บรวบรวมข้อมูล.....	21
3.2 ทำการวิเคราะห์ข้อมูลเบื้องต้น.....	21
3.3 สร้างตัวแบบพยากรณ์ที่เหมาะสม.....	22
3.2.1 วิธีแยกส่วนประกอบ.....	22

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
3.2.2 วิธีปรับให้เรียบแบบโฮสต์-วินเทอร์.....	23
3.2.3 วิธีซัพพอร์ตเวกเตอร์แมชชีน.....	23
3.2.4 เปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์.....	25
3.3 สรุปผลวิจัยและอภิปรายผล.....	25
<b>บทที่ 4 ผลการวิจัยและการอภิปรายผล.....</b>	<b>26</b>
4.1 การเก็บรวบรวมข้อมูล.....	26
4.2 การวิเคราะห์ข้อมูลเบื้องต้น.....	27
4.2.1 ผลการทดสอบข้อมูลเพื่อพิจารณาการแจกแจงปกติ.....	27
4.2.2 ผลการทดสอบแนวโน้มแบบไม่ใช้พารามิเตอร์.....	29
4.2.3 ผลการทดสอบอิทธิพลฤดูกาลแบบไม่ใช้พารามิเตอร์.....	30
4.3 สร้างตัวแบบพยากรณ์ที่เหมาะสมประเภทรถยนต์ไฟฟ้าไฮบริด.....	32
4.3.1 ตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบ.....	32
4.3.2 ผลการวิเคราะห์ด้วยวิธีปรับเรียบแบบโฮสต์-วินเทอร์.....	39
4.3.3 ผลการวิเคราะห์ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน.....	43
4.4 เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด จากข้อมูลชุดทดสอบ.....	48
4.5 สร้างตัวแบบพยากรณ์ที่เหมาะสมประเภทรถยนต์ไฟฟ้าแบตเตอรี่.....	49
4.5.1 ผลการวิเคราะห์ด้วยวิธีแยกส่วนประกอบ.....	49
4.5.2 ผลการวิเคราะห์ด้วยวิธีปรับเรียบแบบโฮสต์-วินเทอร์.....	55
4.5.3 ผลการวิเคราะห์ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน.....	58
4.6 เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่.....	63
4.7 การอภิปรายผล.....	64
<b>บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....</b>	<b>65</b>
5.1 สรุปผลการวิจัย.....	65
5.1.1 ผลการทดสอบข้อมูล.....	65
5.1.2 ผลการทดสอบตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด.....	65
5.1.3 ผลการทดสอบตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่.....	67
5.2 ข้อเสนอแนะ.....	71
เอกสารอ้างอิง.....	72

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
ภาคผนวก.....	74
ภาคผนวก ก ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้า.....	75
ภาคผนวก ข คำสั่ง และผลลัพธ์วิธีแยกส่วนประกอบ.....	78
ภาคผนวก ค คำสั่ง และผลลัพธ์วิธีปรับให้เรียบแบบโพลต์-วินเทอร์.....	87
ภาคผนวก ง คำสั่ง และผลลัพธ์วิธีซัพพอร์ตเวคเตอร์แมชชีน.....	90
ประวัติผู้เขียน.....	97



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญตาราง

ตารางที่	หน้า
4.1 ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน การจดทะเบียนรถยนต์ไฟฟ้าไฮบริด โดยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก.....	34
4.2 ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน การจดทะเบียนรถยนต์ไฟฟ้าไฮบริด โดยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ.....	37
4.3 ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน การจดทะเบียนรถยนต์ไฟฟ้าไฮบริดโดยวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ.....	41
4.4 ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดปี ค.ศ. 2022 โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์.....	46
4.5 ค่า RMSE และ MAPE ของตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด.....	48
4.6 ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน การจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก.....	50
4.6 ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน การจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ.....	53
4.8 ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน การจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ.....	57
4.9 ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ปี ค.ศ. 2022 โดยวิธี ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์.....	61
4.10 ค่า RMSE และ MAPE ของตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่.....	63
5.1 ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดโดยวิธี ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์ในปี ค.ศ. 2022.....	66
5.2 ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธี ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์ในปี ค.ศ. 2022.....	69

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญรูป

รูปที่	หน้า
1.1 ประเภทของรถยนต์ไฟฟ้า (Electric Vehicle).....	5
4.1 จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด ตั้งแต่ปี ค.ศ. 2018 – 2022 มีแนวโน้ม เพิ่มมากขึ้น.....	26
4.2 จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ ตั้งแต่ปี ค.ศ. 2018 – 2022 มีแนวโน้ม เพิ่มมากขึ้น.....	26
4.3 การทดสอบการแจกแจงปกติของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด โดยใช้วิธีการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง.....	28
4.4 การทดสอบการแจกแจงปกติของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ โดยใช้วิธีการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง.....	29
4.5 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก ของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด.....	33
4.6 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบ ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดด้วยวิธีแยกส่วนประกอบ ด้วยโลเอสแบบบวก.....	35
4.7 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ ของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด.....	36
4.8 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบ ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดด้วยวิธีแยกส่วนประกอบ ด้วยโลเอสแบบคูณ.....	38
4.9 กราฟแสดงการเปรียบเทียบระหว่างข้อมูลฝึกสอนและค่าประมาณที่ได้จากการพยากรณ์.....	40
4.10 ผลการวิเคราะห์ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดโดยวิธีปรับให้เรียบ แบบโฮลต์-วินเทอร์แบบคูณ.....	42
4.11 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดโดยวิธี ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท EPS-Regression.....	45
4.12 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดโดยวิธี ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression.....	45

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.13 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท EPS-Regression.....	47
4.14 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression.....	47
4.15 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวกของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่.....	49
4.16 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก.....	51
4.17 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่.....	52
4.18 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ.....	54
4.19 กราฟแสดงการเปรียบเทียบระหว่างข้อมูลฝึกสอนและค่าประมาณที่ได้จากการพยากรณ์.....	55
4.20 ผลการวิเคราะห์ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ.....	58
4.21 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท EPS-Regression...	58
4.22 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression....	58
4.23 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย ด้วย Radial Basis Kernel ประเภท EPS-Regression.....	62
4.24 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย ด้วย Radial Basis Kernel ประเภท NU-Regression.....	62
5.1 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression.....	65

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญญรูป (ต่อ)

รูปที่	หน้า
5.2 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริดด้วยวิธีซัพพอร์ตเวกเตอร์ แมชชีนแบบถดถอย.....	67
5.3 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่โดยวิธี ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression.....	68
5.4 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ด้วยวิธีซัพพอร์ตเวกเตอร์ แมชชีนแบบถดถอย.....	70



# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

รถยนต์พลังงานไฟฟ้าถูกคิดค้นขึ้นมาตั้งแต่ปี ค.ศ. 1880 และได้รับความนิยมเช่นเดียวกับรถยนต์ที่ใช้น้ำมันเป็นเชื้อเพลิงในช่วงเวลาอีก 30 ปีต่อมา อย่างไรก็ตามรถยนต์ไฟฟ้ามีความเร็วต่ำ และระยะการขับต่อการชาร์จที่สั้น ซึ่งทำให้ความนิยมของรถยนต์ไฟฟ้าลดลงพร้อมกับรถยนต์ที่ใช้น้ำมันกลายเป็นยานพาหนะทางบกหลัก ในขณะที่เดียวกันระบบถนนที่พัฒนามากขึ้นในยุโรปและสหรัฐอเมริกา เพิ่มความสะดวกในการเดินทางระยะไกลด้วยรถยนต์ ทำให้รถยนต์ไฟฟ้าสูญเสียความนิยมเมื่อเทียบกับรถยนต์ที่ใช้น้ำมัน และใช้เวลานานกว่าประมาณหนึ่งศตวรรษในการพัฒนารถยนต์ไฟฟ้าจนกลับมาที่ความสนใจของผู้บริโภคอีกครั้ง (รชฎ เลียงจันทร์, 2565)

ปัจจัยที่ส่งผลให้ผู้บริโภคสนใจรถยนต์ไฟฟ้า ณ ปัจจุบัน อันเนื่องมาจากราคา และตัวเลือกของรถยนต์ไฟฟ้าในอุตสาหกรรมรถยนต์ไฟฟ้าในประเทศไทย ในอดีต รถยนต์ไฟฟ้าหลักค่านั้นมีแบรด์จากญี่ปุ่นและยุโรป โดยราคาอยู่ในช่วงประมาณ 2 ล้านบาทถึง 7 ล้านบาท แต่เมื่อค่ายรถยนต์ไฟฟ้าจากจีนเข้ามาเปิดตัวที่ประเทศไทยในช่วงปี ค.ศ. 2021 - 2022 รถยนต์ไฟฟ้าจากจีนมีราคาอยู่ในช่วงแสนบาทถึงล้านบาทต่อแบรด์ นอกจากนี้ยังมีมาตรการสนับสนุนจากภาครัฐที่ช่วยลดราคาให้กับรถยนต์ไฟฟ้าจากจีนให้ใกล้เคียงกับรถยนต์ที่ใช้เครื่องยนต์สันดาป ซึ่งรวมถึงการยกเว้นภาษีจดทะเบียนและมูลค่าเพิ่ม ส่วนลดภาษีรถยนต์รายปี การงดเว้นค่าจอดในที่สาธารณะ หรือการให้บริการชาร์จไฟในจุดชาร์จสาธารณะ รวมถึงเทคโนโลยีแบตเตอรี่ที่มีความสำคัญ โดยปัจจุบันรถยนต์ไฟฟ้าสามารถวิ่งได้มากขึ้นต่อการชาร์จหนึ่งครั้งและใช้เวลาในการชาร์จน้อยลงและปัจจัยสุดท้ายราคาน้ำมันที่สูง ซึ่งเป็นปัจจัยกระตุ้นที่ทำให้ผู้คนสนใจรถยนต์ไฟฟ้ามากขึ้น เนื่องจากค่าใช้จ่ายในการใช้งานรถยนต์ไฟฟ้าน้อยกว่ารถยนต์ที่ใช้น้ำมันเช่นกัน (เพียร์ พาวเวอร์, 2565)

รายงานจากสำนักงานพลังงานระหว่างประเทศ (International Energy Agency: IEA) ระบุว่ายอดขายรถยนต์ไฟฟ้าทั่วโลกในปี ค.ศ. 2021 เพิ่มขึ้น 2 เท่าจากปี ค.ศ. 2020 และมีจำนวนทั้งหมดอยู่ที่ 6.6 ล้านคัน โดยมีส่วนแบ่งของยอดขายทั่วโลกประมาณ 53% (ประมาณ 3.4 ล้านคัน) มาจากประเทศจีน และตลาดยุโรปมีส่วนแบ่งร้อยละ 33 และตลาดสหรัฐอเมริกา มีส่วนแบ่งร้อยละ 11 ในปี ค.ศ. 2021 ยอดขายรถยนต์ไฟฟ้าคิดเป็นสัดส่วนร้อยละ 8.6 ของยอดขายรถยนต์ทั่วโลก ซึ่งมีการเพิ่มขึ้นมาจากสัดส่วนร้อยละ 0.9 ในปี ค.ศ. 2016 ปัจจุบันมีรถยนต์ไฟฟ้าที่ใช้งานทั่วโลกประมาณ 16 ล้านคัน เนื่องจากไทยเป็นประเทศผู้ผลิตรถยนต์ที่สำคัญ การปรับตัวของประเทศเป็นเรื่องสำคัญ ไม่ว่าจะเป็นผู้ผลิตรถยนต์หรือชิ้นส่วน ซึ่งสามารถรักษาความสามารถในการเป็นฐานการผลิตที่สำคัญของโลกในอนาคตได้ (รชฎ เลียงจันทร์, 2565)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อไม่นานนี้ คณะกรรมการนโยบายยานยนต์ไฟฟ้าแห่งชาติได้เห็นชอบแนวทางการส่งเสริมยานยนต์ไฟฟ้าตามนโยบาย 30/30 เพื่อเป็นฐานการผลิตยานยนต์ไฟฟ้าและชิ้นส่วนที่สำคัญของโลก โดยมีเป้าหมายที่ต้องผลิตยานยนต์ไฟฟ้าอย่างน้อย 30% ของการผลิตในปี ค.ศ. 2030 (พชรพจน์ นันทรามาศ, มานะ นิมิตรวานิช และพิมพ์ฉัตร เอกฉันทน์, 2564) นั้นหมายความว่า หากผู้บริโภคในประเทศไทยมีแนวโน้มความต้องการใช้รถยนต์ไฟฟ้ามากขึ้น ผู้ประกอบการรถยนต์ที่ผลิตรถยนต์ไฟฟ้าที่สนใจลงทุนสร้างฐานการผลิตในประเทศไทย หรือแม้กระทั่งผู้ประกอบการที่ผลิตแต่รถยนต์เครื่องยนต์สันดาปภายใน อาจตัดสินใจที่จะปรับฐานการผลิตเพื่อให้สอดคล้องกับความต้องการของผู้บริโภค และวางแผนการผลิตได้อย่างเหมาะสม โดยหากสามารถประมาณความต้องการที่กำลังเพิ่มขึ้นในอนาคต นอกจากนี้ ยังเป็นโอกาสของผู้ประกอบการสถานีบริการน้ำมันเชื้อเพลิงที่ต้องปรับโฉมสถานีเพื่อรองรับปริมาณการชาร์จไฟฟ้าของผู้บริโภค และยังเป็นโอกาสให้อีกหลากหลายธุรกิจ อาทิ ธุรกิจห้างสรรพสินค้า อาจพิจารณาปรับพื้นที่จอดรถเพื่อเพิ่มสถานีชาร์จไฟฟ้าให้ลูกค้าผู้มาใช้บริการ ธุรกิจวางแผนการติดตั้งแผงโซลาร์เซลล์ เนื่องจากผู้บริโภคจำเป็นต้องชาร์จพลังงานให้รถยนต์ไฟฟ้าของตนเองผ่านการเสียบปลั๊กชาร์จ ณ ที่พักอาศัยของผู้บริโภคด้วยเช่นกัน เพื่อเป็นการประหยัดค่าไฟฟ้าบ้านในระยะยาว ดังนั้นการพยากรณ์จำนวนของรถยนต์ไฟฟ้าในอนาคตของประเทศไทยด้วยเครื่องมือทางสถิติ สามารถช่วยให้ผู้ประกอบการเกี่ยวกับธุรกิจรถยนต์ไฟฟ้าโดยตรง และทางอ้อม สามารถวางแผนแนวทางธุรกิจในอนาคตอันใกล้ได้

การพยากรณ์ในทางสถิติเป็นกระบวนการทางวิทยาศาสตร์ที่ใช้ข้อมูลในอดีต เพื่อทำการคาดการณ์ หรือทำนายเหตุการณ์ที่อาจเกิดขึ้นในอนาคต ซึ่งการพยากรณ์นั้นอาจมีความเป็นไปได้ในระดับความเสี่ยงที่ต่างกัน และสามารถใช้ในการตัดสินใจ หรือวางแผนในอนาคต การพยากรณ์จำนวนรถยนต์ไฟฟ้าในอนาคตที่เหมาะสมสามารถใช้ได้หลายวิธี อย่างไรก็ตาม การใช้โมเดลทางสถิติเป็นวิธีที่ได้รับความนิยมในการพยากรณ์ดังกล่าว โดยเฉพาะการใช้โมเดลอนุกรมเวลา (Time Series Models) อนุกรมเวลามีหลายโมเดลที่ใช้ในการพยากรณ์ งานวิจัยของกมล จิงมานนท์ (2562) ได้ศึกษาการพยากรณ์ยอดขายรถยนต์ใช้ไฟฟ้าในประเทศสหรัฐอเมริกา และจีน เพื่อเทียบวิธีพยากรณ์ที่แม่นยำที่สุดด้วยกระบวนการทางสถิติด้วยวิธีการพยากรณ์ 4 แบบ ได้แก่ การพยากรณ์อนุกรมเวลาวิธีแยกองค์ประกอบ วิธีแบบจำลองเอกซ์โพเนนเชียลของวินเทอร์ วิธีแบบจำลองแบบถดถอยพหุคูณ และวิธีการรวมผลพยากรณ์ แล้วนำผลลัพธ์มาเทียบหาวิธีที่ให้ค่าความแม่นยำสูงสุด จากการทดสอบพบว่าวิธีการพยากรณ์ที่เหมาะสมกับยอดขายรถยนต์ใช้ไฟฟ้าในประเทศจีนคือ วิธีการรวมผลพยากรณ์ นอกจากให้ค่าความแม่นยำสูง ยังให้ค่าผิดพลาดที่น้อยกว่าวิธีอื่นๆ วิธีการพยากรณ์ที่เหมาะสมกับยอดขายรถยนต์ใช้ไฟฟ้าในสหรัฐอเมริกาคือ การพยากรณ์ด้วยวิธีแยกองค์ประกอบ ที่มีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุด

จากงานวิจัยที่กล่าวมาในข้างต้นพบว่า วิธีการรวมผลพยากรณ์ และวิธีแยกองค์ประกอบเป็นวิธีที่ให้ผลพยากรณ์ที่มีความแม่นยำ ทั้งนี้ ผู้วิจัยต้องการเปรียบเทียบกับงานวิจัยของท่านอื่นเพิ่มเติม เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เพื่อตรวจสอบว่างานวิจัยที่มีการพยากรณ์ด้วยวิธีอนุกรมเวลา และมีความเกี่ยวข้องกับรถยนต์ของ ท่านอื่นมีผลลัพธ์เป็นเช่นไร จึงได้พบ Liangcai Dong และ Ziqi Xu (2011) ได้ทำการพยากรณ์การผลิตรถยนต์ในประเทศจีน โดยใช้วิธีการซัพพอร์ตเวกเตอร์แมชชีน เปรียบเทียบกับวิธี ARIMA (Autoregressive Integrated Moving Average) โดยการใช้การผลิตรถยนต์รายเดือนในประเทศจีนเป็น ข้อมูลในการทำนายตั้งแต่เดือนมกราคม ค.ศ. 2005 ถึงเดือนมีนาคม ค.ศ. 2010 ผลลัพธ์แสดงให้เห็นว่าโมเดลซัพพอร์ตเวกเตอร์แมชชีน มีการทำนายที่แม่นยำสุด เนื่องจากมีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุด

อีกงานวิจัยที่น่าสนใจคือ งานวิจัยของอรุชา จันทร์ภา และ นันทชัย กานตานันทะ (2564) เป็นการศึกษา และเปรียบเทียบวิธีการพยากรณ์มูลค่าการส่งออกรถยนต์อุปกรณ์และส่วนประกอบของประเทศไทย โดยใช้วิธีการอนุกรมเวลา โดยเปรียบเทียบระหว่างวิธีการพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ และวิธี SARIMA (Seasonal Autoregressive Integrated Moving Average) โดยใช้ข้อมูลมูลค่าการส่งออกรถยนต์อุปกรณ์ และส่วนประกอบรายเดือน ตั้งแต่เดือนมกราคม พ.ศ. 2551 ถึงเดือนธันวาคม พ.ศ. 2562 จากผลการศึกษาพบว่า วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ มีความแม่นยำในการพยากรณ์มูลค่าการส่งออกรถยนต์อุปกรณ์และส่วนประกอบของประเทศไทยมากที่สุด เนื่องจากมีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุด

จากการศึกษาวิจัยที่กล่าวมาข้างต้นพบว่าวิธีการพยากรณ์ทางอนุกรมเวลามีหลายวิธี ควรพิจารณาถึงข้อมูลในงานวิจัยว่าเหมาะสมกับวิธีเหล่านั้นหรือไม่ ซึ่งชุดข้อมูลรถยนต์ไฟฟ้าในงานวิจัยนี้มีแนวโน้ม และฤดูกาล ดังนั้น วิธีที่อาจไม่เหมาะสมสำหรับการพยากรณ์สำหรับข้อมูลที่มีแนวโน้ม และฤดูกาล ได้แก่ วิธีบ็อกซ์-เจนกินส์ เนื่องจากวิธีบ็อกซ์-เจนกินส์มักใช้กับข้อมูลที่มีลักษณะเปลี่ยนแปลงตามเวลา และฤดูกาลที่ไม่ชัดเจน ซึ่งในกรณีของข้อมูลที่มีแนวโน้ม และฤดูกาลอย่างชัดเจน อาจทำให้การประมาณค่าพารามิเตอร์ ARIMA ในตัวแบบบ็อกซ์-เจนกินส์ เกิดความคลาดเคลื่อนไม่สามารถให้ผลลัพธ์ที่แม่นยำได้ รวมถึงวิธี ARIMA (Auto Regressive Integrated Moving Average) และ SARIMA (Seasonal Autoregressive Integrated Moving Average) มักใช้กับข้อมูลที่มีความเปลี่ยนแปลงที่ไม่แน่นอน ซึ่งไม่เหมาะสมสำหรับข้อมูลที่มีแนวโน้ม และฤดูกาลที่เกิดขึ้นอย่างชัดเจน ดังนั้นวิธีที่เหมาะสมกับข้อมูลมีแนวโน้ม และฤดูกาล ได้แก่ วิธีแยกส่วนประกอบ และวิธีปรับให้เรียบ สำหรับการเรียนรู้ของเครื่อง (Machine Learning) วิธีที่เหมาะสมสำหรับการพยากรณ์ในเชิงอนุกรมเวลา ได้แก่ วิธีซัพพอร์ตเวกเตอร์แมชชีน วิธีที่กล่าวมานี้ เป็นวิธีที่ให้ผลพยากรณ์ได้อย่างแม่นยำจากงานวิจัยที่กล่าวไว้ข้างต้น ดังนั้นผู้วิจัยจึงนำวิธีแยกส่วนประกอบ วิธีปรับให้เรียบ และวิธี

ซัพพอร์ตเวกเตอร์แมชชีน มาประยุกต์ใช้ในงานวิจัยนี้ โดยใช้วิธีการทดสอบแบบพยากรณ์ที่เหมาะสม จากค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ที่ต่ำที่สุด เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์

## 1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 ศึกษาวิธีพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์การจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย

1.2.2 เปรียบเทียบวิธีพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์การจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย

1.2.3 พยากรณ์แนวโน้มในอนาคตของการจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย

## 1.3 ขอบเขตของงานวิจัย

การศึกษานี้ ผู้วิจัยใช้ข้อมูลทุติยภูมิโดยการรวบรวมข้อมูลจากฐานข้อมูลในระบบของกรมการขนส่งทางบก ได้แก่ จำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) จดทะเบียนในประเทศไทยรายเดือน ดังรูปที่ 1.1 และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือน ดังรูปที่ 1.2 ตั้งแต่ปี ค.ศ. 2018 – 2022 เป็นจำนวนทั้งสิ้น 60 เดือน โดยแบ่งข้อมูลออกเป็น 2 ชุด ข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ ด้วยวิธีพยากรณ์ 3 วิธี ได้แก่ วิธีแยกส่วนประกอบ วิธีปรับให้เรียบแบบโพลต์-วินเทอร์ และวิธีซัพพอร์ตเวกเตอร์แมชชีน โดยจะพิจารณาเลือกแบบพยากรณ์ที่เหมาะสมจากค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุด สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบเพื่อเปรียบเทียบวิธีพยากรณ์ 3 วิธี ได้แก่ วิธีแยกส่วนประกอบ วิธีปรับให้เรียบแบบโพลต์-วินเทอร์ และวิธีซัพพอร์ตเวกเตอร์แมชชีน โดยจะพิจารณาเลือกแบบพยากรณ์ที่เหมาะสมจากค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุด ด้วยโปรแกรม R

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. การพยากรณ์แนวโน้มการจดทะเบียนรถยนต์ไฟฟ้าสามารถช่วยส่งเสริมให้ผู้ประกอบการรถยนต์ไฟฟ้าสนใจวางแผนการลงทุนในการสร้างฐานการผลิตในประเทศไทย เมื่อพบว่าความต้องการของผู้บริโภคเพิ่มสูงขึ้น ซึ่งอาจเป็นโอกาสที่ดีในการสร้างงานจ้างและส่งเสริมการเติบโตของอุตสาหกรรมรถยนต์ไฟฟ้าในประเทศไทย

2. การพยากรณ์ความต้องการในอนาคตของจำนวนรถยนต์ไฟฟ้าสามารถนำมาวางแผนการเตรียมสถานีชาร์จไฟฟ้าที่สามารถรองรับการชาร์จไฟฟ้าของผู้บริโภค ซึ่งสร้างโอกาสให้กับธุรกิจสถานีบริการน้ำมันเชื้อเพลิงในการปรับโฉม และปรับปรุงสถานีเพื่อรองรับการชาร์จไฟฟ้า

3. การพยากรณ์ความต้องการในอนาคตของจำนวนรถยนต์ไฟฟ้าจะส่งผลให้สามารถวางแผนความต้องการในอุปกรณ์ชาร์จรถยนต์ไฟฟ้าที่เพิ่มขึ้น ธุรกิจผู้ผลิต และจำหน่ายอุปกรณ์ชาร์จรถยนต์ไฟฟ้าในประเทศไทยมีโอกาสเติบโต และขยายตลาดได้

## 1.5 นิยามคำศัพท์เฉพาะ

รถยนต์ไฟฟ้า (Electric Vehicle) หมายถึง รถยนต์ที่ขับเคลื่อนด้วยพลังงานไฟฟ้า ทั้งประเภทที่ขับเคลื่อนด้วยพลังงานไฟฟ้าเพียงอย่างเดียว และประเภทที่พลังงานไฟฟ้าทำงานร่วมกับเครื่องยนต์สันดาป โดยแบ่งออกเป็น 2 ประเภท ดังนี้

1. รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) คือ รถยนต์ที่ขับเคลื่อนด้วยพลังงานไฟฟ้า 100% ซึ่งมีการเติมพลังงานไฟฟ้าให้รถยนต์ผ่านการเสียบปลั๊กชาร์จไฟฟ้าเท่านั้น
2. รถยนต์ปลั๊กอินไฮบริด (HEVs และ PHEVs) คือ รถยนต์ที่ขับเคลื่อนด้วยพลังงานไฟฟ้า แต่ใช้พลังงานจากแหล่งอื่นร่วมด้วย โดยรถไฟฟ้าประเภทไฮบริดเป็นรถยนต์ที่มีการใช้เครื่องยนต์สันดาปคือเครื่องยนต์ที่ใช้พลังงานจากน้ำมันเบนซินหรือดีเซล และมอเตอร์ไฟฟ้ามาขับเคลื่อนร่วมกัน สำหรับปลั๊กอินไฮบริด เป็นรถยนต์ที่พัฒนาต่อมาจากรถยนต์ไฟฟ้าชนิดไฮบริด ซึ่งจะมีทั้งเครื่องยนต์สันดาป มอเตอร์ไฟฟ้า และแบตเตอรี่ที่สามารถบรรจุไฟฟ้าจากภายนอกมาเก็บที่แบตเตอรี่ได้ (Tadsaneeya, 2020)



รูปที่ 1.1 ประเภทของรถยนต์ไฟฟ้า (Electric Vehicle)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 2

# ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ผู้วิจัยได้ทำการค้นคว้าข้อมูลเพิ่มเติม ทั้งในด้านข่าวสาร บทความ และงานวิจัยที่เกี่ยวข้องกับรถยนต์ไฟฟ้าในประเทศไทย เพื่อเป็นส่วนหนึ่งในการเข้าใจสถานการณ์ปัจจุบันของตลาดรถยนต์ไฟฟ้า และศึกษาการพยากรณ์ความเป็นไปได้ในเชิงธุรกิจ โดยรวบรวมละเอียดของเนื้อหาตามหัวข้อดังต่อไปนี้

การพยากรณ์ (Forecasting) หมายถึง การคาดคะเนการทำนายการเกิดเหตุการณ์ หรือสภาพการณ์ต่าง ๆ ในอนาคต โดยการพยากรณ์จะทำการศึกษาแนวโน้มและรูปแบบการเกิดเหตุการณ์จากข้อมูลในอดีต และ/หรือใช้ความสามารถ ความรู้ประสบการณ์ และดุลยพินิจของผู้พยากรณ์ (นิภา นิรุตติกุล, 2551)

ปัจจุบันประเภท หรือวิธีของการพยากรณ์ธุรกิจแบ่งเป็น 2 ลักษณะ ได้แก่ วิธีการพยากรณ์เชิงคุณภาพ (Qualitative Forecasting Methods) ซึ่งอาศัยความคิดเห็นของผู้เชี่ยวชาญ หรือประสบการณ์ของผู้พยากรณ์เป็นหลัก และวิธีการพยากรณ์เชิงปริมาณ (Quantitative Forecasting Methods) ซึ่งอาศัยข้อมูล และตัวแบบพยากรณ์ทางคณิตศาสตร์ที่ได้รับความนิยมอย่างสูงพร้อมกับการใช้โปรแกรมคอมพิวเตอร์สำหรับการพยากรณ์ ซึ่งมีความก้าวหน้า และสะดวกในการใช้งานเป็นอย่างมาก (เอกจิตต์ จิงเจริญ, 2560) โดยในงานวิจัยนี้ ผู้วิจัยเลือกใช้วิธีการพยากรณ์เชิงปริมาณ (Quantitative Forecasting Methods) สำหรับการพยากรณ์จำนวนรถยนต์ไฟฟ้าที่จดทะเบียนในประเทศไทย

### 2.1 ทฤษฎีที่เกี่ยวข้อง

#### 2.1.1 การทดสอบแนวโน้ม และอิทธิพลของฤดูกาล

การทดสอบแนวโน้ม และอิทธิพลของฤดูกาลเป็นขั้นตอนสำคัญก่อนที่จะวิเคราะห์อนุกรมเวลา เพื่อให้เกิดรูปแบบของอนุกรมเวลาที่ถูกต้อง ในการทดสอบแนวโน้มและอิทธิพลของฤดูกาล ควรพิจารณา และวิเคราะห์ส่วนประกอบหลายๆ อย่าง เช่น แนวโน้มของข้อมูล ฤดูกาล วัฏจักร และเหตุการณ์ที่ผิดปกติ เพื่อให้ได้รูปแบบของอนุกรมเวลาที่ถูกต้อง นอกจากนี้ เพื่อทดสอบสมมติฐานที่เกี่ยวข้องกับรูปแบบของอนุกรมเวลา ควรใช้วิธีการทดสอบแบบใช้พารามิเตอร์ และแบบไม่ใช้พารามิเตอร์ การทดสอบแบบใช้พารามิเตอร์อาจจะซับซ้อนและใช้เวลามากกว่า แต่มีอำนาจการทดสอบที่สูงกว่า ในขณะที่การทดสอบแบบไม่ใช้พารามิเตอร์มีความง่าย และรวดเร็วกว่า แม้ว่าอำนาจการทดสอบของมันจะต่ำกว่า แต่ยังสามารถให้ผลลัพธ์ที่น่าเชื่อถือได้ ทั้งนี้ ข้อมูลจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือน

ตั้งแต่ปี ค.ศ. 2018 - 2022 ไม่มีการแจกแจงปกติ จึงใช้การทดสอบอทิพิลแนวโน้ม และอทิพิลฤดูกาลแบบไม่ใช้พารามิเตอร์

การทดสอบแนวโน้มด้วยวิธีสถิติแมน-เคนดัลล์ (Mann Kendall Test: MK) คือการทดสอบสถิติทางการอ้างอิงที่ใช้ในการตรวจสอบว่าชุดข้อมูลที่ไม่เกี่ยวข้องกันหรือไม่เกี่ยวข้องกับเวลา มีแนวโน้มเพิ่มหรือลดลงตามเวลา โดยใช้การสังเกตการณ์ที่ข้อมูลในชุดข้อมูลมีความสัมพันธ์ระหว่างกันเชิงลำดับ การทดสอบนี้สามารถใช้กับชุดข้อมูลที่ไม่เกี่ยวข้องกันได้ เช่น การทดสอบแนวโน้มของความเข้มของแสงอาทิตย์รายวัน หรือการทดสอบแนวโน้มของระดับน้ำในแม่น้ำรายปี เป็นต้น การทดสอบวิธีสถิติแมน-เคนดัลล์ จะสร้างตัวแปรที่เรียกว่า  $U$  ซึ่งเป็นค่าสถิติที่ใช้ในการคำนวณค่าสถิติทดสอบ โดยการเปรียบเทียบความสัมพันธ์ระหว่างข้อมูลในชุดข้อมูล โดยพิจารณาการเพิ่ม หรือลดของข้อมูลในแต่ละคู่ที่เป็นไปได้และการเปรียบเทียบลำดับของข้อมูลเพื่อประเมินแนวโน้มที่เกิดขึ้นในชุดข้อมูลตามเวลา การทดสอบวิธีสถิติแมน-เคนดัลล์ จะใช้ค่าสัมประสิทธิ์สหสัมพันธ์อันดับเคนดัลล์ (Kendall's Rank Correlation: tau) เพื่อวัดความสัมพันธ์ระหว่างการจัดลำดับของข้อมูลตามเวลา ค่าสัมประสิทธิ์สหสัมพันธ์อันดับเคนดัลล์ (ค่า tau) ที่ได้จะอยู่ในช่วง  $-1$  ถึง  $1$  โดยที่ค่าที่เป็นบวกหมายถึงมีแนวโน้มเพิ่มขึ้นตามเวลา ค่าที่เป็นลบหมายถึงมีแนวโน้มลดลงตามเวลา และค่าที่เป็นศูนย์หมายถึงไม่มีแนวโน้มเพิ่มหรือลดลงตามเวลา (Yue. et al., 2004) โดยมีขั้นตอนดังต่อไปนี้

กำหนด  $H_0$  และ  $H_1$

$H_0$  : ข้อมูลไม่มีอทิพิลของแนวโน้มเข้ามาเกี่ยวข้อง

$H_1$  : ข้อมูลมีอทิพิลของแนวโน้มเข้ามาเกี่ยวข้อง

โดยมีสมการ ดังนี้

$$\text{sgn}(x_i - x_j) = \begin{cases} 1, & x_i - x_j > 0 \\ 0, & x_i - x_j = 0 \\ -1, & x_i - x_j < 0 \end{cases} U \quad (2.1)$$

ซึ่ง โดยที่  $x_i$  และ  $x_j$  คือค่าในชุดข้อมูล

ในกรณีนี้ไม่มีข้อมูลเพิ่มเติมเกี่ยวกับค่า  $x_i$  และ  $x_j$  จะไม่สามารถคำนวณค่า  $U$  ได้โดยตรง แต่ค่า tau ที่ได้จากแสดงถึงความสัมพันธ์ระหว่างการจัดลำดับของข้อมูลในชุดข้อมูลตามเวลา โดยค่า tau ที่เป็นบวกหมายถึงมีแนวโน้มเพิ่มขึ้น และค่าสัมประสิทธิ์สหสัมพันธ์อันดับเคนดัลล์ (ค่า tau) ที่เป็นลบหมายถึงมีแนวโน้มลดลง ค่าสัมประสิทธิ์สหสัมพันธ์อันดับเคนดัลล์ (ค่า tau) ที่เป็น 0 หมายถึงไม่มีแนวโน้มเพิ่มหรือลดลงตามเวลา

การทดสอบฤดูกาลแบบไม่ใช้พารามิเตอร์เป็นขั้นตอนที่สำคัญในงานวิจัยเพื่อตรวจสอบว่าอนุกรมเวลาที่กำจัดแนวโน้มแล้วมีอทิพิลฤดูกาลเข้ามาเกี่ยวข้องหรือไม่ ในการทดสอบนี้จะใช้เทคนิค

การทดสอบแบบครัสคัล-วอลลิส (The Kruskal-Wallis Test) ซึ่งเป็นการทดสอบแบบไม่ใช้เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พารามิเตอร์ที่ใช้ในการประเมินค่าสถิติเพื่อทดสอบว่ามีความแตกต่างทางสถิติระหว่างกลุ่ม การทดสอบนี้จะใช้ขั้นตอนการเรียงลำดับค่าสังเกต (Rank Ordering) เพื่อกำจัดแนวโน้ม และพิจารณาค่าสังเกตในการวิเคราะห์ ดังนั้น การทดสอบแบบไม่ใช้พารามิเตอร์เป็นวิธีที่สามารถให้ผลลัพธ์ที่น่าเชื่อถือได้ในการวิเคราะห์หือทธิพลของฤดูกาลในงานวิจัยนี้ โดยมีขั้นตอนดังต่อไปนี้

กำหนด  $H_0$  และ  $H_1$

$H_0$  : ข้อมูลไม่มีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

$H_1$  : ข้อมูลมีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

โดยมีสมการ ดังนี้

$$H = \frac{12}{n(n-1)} \left[ \sum_{i=1}^L \frac{R_i^2}{n_i} \right] - 3(n+1) \quad (2.2)$$

ซึ่ง  $n_i$  คือ จำนวนค่าสังเกตในฤดูกาลที่  $i$

$n$  คือ  $\sum n_i$

$R_i$  คือ  $\sum$  ของลำดับที่ของค่าสังเกตที่ปรับแนวโน้มแล้วในแต่ละฤดูกาล

$L$  คือ จำนวนครั้งต่อปี

ตัวสถิติ  $H$  มีการแจกแจงแบบไคสแควร์ที่ขึ้นหึ่งความเป็นอิสระเท่ากับ  $L-1$  โดยมีเกณฑ์การตัดสินใจ ดังนี้

บริเวณวิกฤต คือ  $H \geq \chi_{\alpha, L-1}^2$  ซึ่ง  $\chi_{\alpha, L-1}^2$  เป็นค่าวิกฤตที่ได้จากตารางไคสแควร์

### 2.1.2 การพยากรณ์เชิงปริมาณ (Quantitative Forecasting Methods)

เทคนิคการพยากรณ์เชิงปริมาณเป็นวิธีการวิเคราะห์อย่างมีระบบ โดยอาศัยข้อมูลในอดีตจนถึงปัจจุบันมาวิเคราะห์ โดยใช้ความรู้ทางสถิติประกอบการพยากรณ์ ดังนั้นความถูกต้องแม่นยำของการพยากรณ์นี้จะขึ้นอยู่กับข้อมูลที่มีในการพยากรณ์ ทำให้การพยากรณ์เชิงปริมาณเป็นที่ยอมรับอย่างกว้างขวาง การพยากรณ์เชิงปริมาณนั้นอาจแบ่งได้ 2 ลักษณะ ดังนี้

1) การวิเคราะห์ข้อมูลเชิงเหตุผล (Associative Models) เป็นการพยากรณ์ด้วยการวิเคราะห์ปัจจัยแวดล้อมต่างๆ ที่ผลกระทบต่อสิ่งที่ทำการพยากรณ์ เช่น การวิเคราะห์การถดถอย (Regression Analysis) โดยวิธีการนี้อาจไม่จำเป็นต้องเก็บข้อมูลไปตามช่วงเวลา

2) รูปแบบอนุกรมเวลา (Time Series Models) เป็นวิธีการใช้รูปแบบ (Pattern) ของข้อมูลในลักษณะที่บันทึกได้จากอดีตถึงปัจจุบัน เช่น วิธีการหาค่าเฉลี่ยแบบทรงตัว (Native Approach) วิธีการหาค่าเฉลี่ยเคลื่อนที่ (Moving Average) วิธีการปรับเทียบแบบเอ็กซ์โปเนนเชียล (Exponential Smoothing) (เฉลิมพร จตุพร, 2560)

### 2.1.3 การพยากรณ์อนุกรมเวลา (Time Series Models)

อนุกรมเวลา (Time Series) เป็นข้อมูลที่เก็บรวบรวมตัวแปรต่างๆ ในช่วงเวลาตามลำดับของเวลา ซึ่งมีการนำมาใช้ในการวิเคราะห์และพยากรณ์เพื่อทำนายค่าในอนาคต การพยากรณ์อนุกรมเวลาเป็นการใช้โมเดลทางสถิติและวิศวกรรมคำนวณเพื่อประมาณค่าของตัวแปรในอนาคต ซึ่งสามารถใช้ในการทำนายและวิเคราะห์แนวโน้ม วัฏจักร ฤดูกาล และความผันผวนของข้อมูลในอนาคตได้นอกจากนี้ยังมีการพัฒนาโมเดลที่เหมาะสมสำหรับการพยากรณ์อนุกรมเวลา

การพยากรณ์อนุกรมเวลาสามารถใช้กับข้อมูลตัวแปรต่างๆ ที่มีลักษณะการเปลี่ยนแปลงตามลำดับเวลา อาทิ ข้อมูลการขายสินค้า เช่น การพยากรณ์อนุกรมเวลาสามารถใช้ในการทำนายยอดขายสินค้าในอนาคต โดยใช้ข้อมูลยอดขายของสินค้าในช่วงเวลาที่ผ่านมาเพื่อสร้างโมเดลที่สามารถทำนายยอดขายในอนาคตได้ ข้อมูลอัตราแลกเปลี่ยน เช่น การพยากรณ์อนุกรมเวลาสามารถใช้ในการทำนายอัตราแลกเปลี่ยนของสกุลเงินต่าง ๆ ในอนาคต โดยใช้ข้อมูลอัตราแลกเปลี่ยนในช่วงเวลาที่ผ่านมาเพื่อสร้างโมเดลที่สามารถทำนายอัตราแลกเปลี่ยนในอนาคตได้ ข้อมูลการเงิน เช่น การพยากรณ์อนุกรมเวลาสามารถใช้ในการทำนายตัวแปรทางการเงินเพื่อช่วยในการวางแผนการเงินและการลงทุนในอนาคต ข้อมูลปริมาณผลิตสินค้า เช่น การพยากรณ์อนุกรมเวลาสามารถใช้ในการทำนายปริมาณผลิตสินค้าในอนาคต โดยใช้ข้อมูลปริมาณผลิตสินค้าในช่วงเวลาที่ผ่านมาเพื่อสร้างโมเดลที่สามารถทำนายปริมาณผลิตในอนาคตได้ ข้อมูลอากาศ: การพยากรณ์อนุกรมเวลาสามารถใช้ในการทำนายสภาพอากาศในอนาคตเพื่อช่วยในการวางแผนกิจกรรมที่เกี่ยวข้องกับสภาพอากาศในอนาคต เป็นต้น

โดยการพยากรณ์อนุกรมเวลานั้นสามารถใช้โมเดลทางสถิติ หรือวิศวกรรมคำนวณเพื่อประมาณค่าของตัวแปรในอนาคต ซึ่งสามารถปรับปรุง และเลือกใช้โมเดลที่เหมาะสมกับข้อมูล และลักษณะของอนุกรมเวลาได้ตามความต้องการ

### 2.1.4 ส่วนประกอบของอนุกรมเวลา (Components of a Time Series)

อนุกรมเวลาของตัวแปรหนึ่งประกอบด้วย 4 ส่วนหลัก ดังนี้

1. แนวโน้ม (Trend) คือส่วนที่ทำให้อนุกรมเวลามีค่าเพิ่มขึ้นหรือลดลงเรื่อยๆ เมื่อเวลาผ่านไป ใช้ในการบอกลักษณะการเพิ่มหรือลดของอนุกรมเวลาในระยะยาว
2. วัฏจักร (Cycle) คือส่วนที่ทำให้อนุกรมเวลามีค่าเพิ่มหรือลดลงสลับกันรอบๆ ค่าแนวโน้ม การนับระยะเวลาของวัฏจักรจะนับจุดสูงสุดหนึ่ง (Peak) ไปยังอีกจุดสูงสุดหนึ่ง หรือจากจุดต่ำสุดหนึ่ง (Trough) ไปยังอีกจุดต่ำสุดหนึ่ง เวลาที่ใช้ในการกลับมาสู่จุดสูงสุดหรือต่ำสุดอาจจะใช้เป็นระยะเวลาที่ยาวเท่าไรก็ได้ แต่อาจเป็นประเภทของช่วงฟื้นตัวหรือถดถอยในกรณีที่วัฏจักรอยู่ในช่วงลดลงหรือเพิ่มขึ้น

3. ความผันแปรจากฤดูกาล (Seasonal Variations) คือรูปแบบในช่วงเวลาที่เป็นภายในหนึ่งปี และซ้ำกันทุกปี เช่น อุณหภูมิเฉลี่ยในเดือนเมษายนที่สูงกว่าเดือนอื่นๆ ส่วนนี้มีลักษณะว่าเกิดซ้ำๆ ในแต่ละปี

4. ความผันผวนจากเหตุการณ์ไม่ปกติ (Irregular Fluctuations) คือส่วนที่ทำให้อนุกรมเวลามีค่าที่ผิดปกติไปจากแบบที่คาดหวัง อาจเกิดจากเหตุการณ์ไม่คาดฝัน เช่น แผ่นดินไหว สึนามิ ระเบิด หรือการหยุดงานประท้วง เป็นต้น ในการคำนวณความผันผวนจากเหตุการณ์ไม่ปกติ ใช้การนำค่าแนวโน้ม ค่าวัฏจักร และค่าผันแปรจากฤดูกาลมาหักลบค่าอนุกรมเวลา เพื่อให้ได้ค่าที่แสดงถึงผันผวนที่ไม่ปกติของอนุกรมเวลา

ข้อมูลอนุกรมเวลาที่เก็บรวบรวมอาจประกอบด้วยส่วนใดส่วนหนึ่งหรือทั้งสี่ส่วน และสามารถอยู่ในรูปของผลรวมหรือผลคูณได้ การเลือกใช้ส่วนใดขึ้นอยู่กับลักษณะของข้อมูลและวัตถุประสงค์ในการวิเคราะห์ (ภูมิฐาน รังคกุลนุวัฒน์, 2562)

### 2.1.5 วิธีแยกส่วนประกอบ (Decomposition)

#### วิธีแยกส่วนประกอบ (Decomposition Method)

ส่วนประกอบของข้อมูลอนุกรมเวลา คือสาเหตุของการแปรผันแบบต่างๆ ในข้อมูลอนุกรมเวลา ซึ่งสามารถแยกส่วนประกอบของข้อมูลอนุกรมเวลาออกได้เป็น 4 ส่วนด้วยกัน คือ

1. แนวโน้ม (Trend Component)
2. วัฏจักร (Cyclical Component)
3. ฤดูกาล (Seasonal Component) และ
4. สิ่งที่เกิดผิดปกติ (Irregular Component)

โดยแบ่งออกเป็น 2 รูปแบบ ได้แก่

รูปแบบวิธีแยกส่วนประกอบเชิงบวก (Additive Decomposition) มีสมการ ดังนี้

$$Y = T + S + C + I \quad (2.3)$$

รูปแบบวิธีแยกส่วนประกอบเชิงคูณ (Multiplicative Decomposition) มีสมการ ดังนี้

$$Y = T \times S \times C \times I \quad (2.4)$$

รูปแบบวิธีแยกส่วนประกอบเชิงบวก (Additive Decomposition) เป็นวิธีการแยกส่วนประกอบของชุดข้อมูลเพื่อให้เห็นความเปลี่ยนแปลงของแนวโน้มทางเวลาและฤดูกาล โดยแยกส่วนประกอบออกเป็นสามส่วนหลัก คือ ส่วนความเปลี่ยนแปลงทางเวลา (Trend) ส่วนฤดูกาล (Seasonal) และส่วนความสุ่ม (Residual) โดยทั้งสามส่วนนี้ถูกบวกกันเพื่อให้ได้ชุดข้อมูลเดิมที่สมบูรณ์ เหมาะสำหรับข้อมูลที่มีการเปลี่ยนแปลงทางเวลาและฤดูกาลที่ไม่เกี่ยวข้องกับตัวแปรอื่น ๆ

และสามารถนำไปใช้ในการวิเคราะห์และทำนายข้อมูลที่มีความเปลี่ยนแปลงตามแนวโน้มและฤดูกาลได้อย่างมีประสิทธิภาพ

สำหรับรูปแบบเชิงคูณ (Decomposition Multiplicative) พบมากในข้อมูลอนุกรมเวลาทางเศรษฐกิจ และทางธุรกิจ ตัวแบบชนิดนี้เป็นตัวแบบที่มีส่วนประกอบของอนุกรมเวลาที่มีความสัมพันธ์กัน ตัวแบบเชิงคูณเป็นตัวแบบที่นิยมใช้กันมากกว่าตัวแบบอื่น ทั้งนี้เนื่องจากการแยกส่วนประกอบแต่ละส่วนทำได้สะดวกกว่า และในความเป็นจริง ส่วนประกอบของอนุกรมเวลามีต้นกำเนิดต่างกัน แต่มีส่วนเกี่ยวข้องกัน ในกรณีที่ส่วนประกอบของอนุกรมเวลาเกิดจากต้นกำเนิดเดียวกัน การแยกส่วนประกอบจะทำได้ยากกว่าของอนุกรมเวลาที่มีจุดกำเนิดต่างกัน

ทั้งนี้สามารถใช้วิธีการโลเอส (Loess) เพื่อปรับแต่งข้อมูลให้สอดคล้องกับแนวโน้ม และฤดูกาล ให้มีความเหมาะสมมากยิ่งขึ้น โดยเรียกว่าการแยกส่วนฤดูกาล และแนวโน้มโดยใช้วิธีโลเอส (Seasonal and Trend Decomposition using Loess: STL Decomposition) คือเทคนิคหนึ่งที่ใช้ในการแยกส่วนประกอบภายในชุดข้อมูล เพื่อปรับแต่งข้อมูลให้สอดคล้องกับฤดูกาลและแนวโน้ม โดยประกอบด้วย 3 ส่วนหลักคือฤดูกาล (Seasonal) ที่แสดงแนวโน้มซ้ำในชุดข้อมูล แนวโน้ม (Trend) ที่แสดงแนวโน้มหรือค่าเฉลี่ยเคลื่อนที่ของข้อมูล และส่วนที่เหลือ (Remainder) ที่แสดงผลต่างของข้อมูลเฉพาะที่ไม่สามารถอธิบายได้ด้วยฤดูกาล หรือแนวโน้ม โดยมีขั้นตอนคำนวณส่วนฤดูกาลก่อน และลบออกเพื่อคำนวณส่วนแนวโน้ม ส่วนที่เหลือคือส่วนที่คำนวณได้โดยการลบส่วนฤดูกาล และส่วนแนวโน้มออกจากชุดข้อมูลเวลา การแยกส่วนประกอบชุดข้อมูลทำให้สามารถสำรวจ และวิเคราะห์แนวโน้มของข้อมูลในระยะยาว และฤดูกาล หรือแนวโน้มที่เกิดซ้ำกันเป็นประจำ ซึ่งส่วนนี้มีประโยชน์ในการทำนาย และวิเคราะห์ข้อมูลในชุดข้อมูลเวลาที่เกิดรูปแบบที่เปลี่ยนแปลงตามฤดูกาล

### 2.1.6 วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ (Holt-Winters Exponential Smoothing)

วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ เป็นวิธีเพื่อจัดการกับข้อมูลที่มีแนวโน้ม และฤดูกาลที่ชัดเจน โดยวิธีนี้จะใช้การประมาณค่าเฉลี่ยเคลื่อนที่ และการประมาณค่าฤดูกาล เพื่อสร้างโมเดลที่สามารถพยากรณ์ และแยกส่วนประกอบของข้อมูลได้

ทฤษฎีวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ เป็นเทคนิคทางสถิติที่ถูกพัฒนาขึ้นโดย ชาลส์ โฮลต์ (Charles C. Holt) และ ปีเตอร์ วินเทอร์ส (Peter Winters) ในปี ค.ศ. 1960 ซึ่งเป็นการพัฒนาต่อยอดจากเทคนิคการจัดการแบบเอ็กซ์โปเนนเชียลปรับให้เรียบที่พัฒนาขึ้นในปี ค.ศ. 1950 โฮลต์ และ วินเทอร์สได้พัฒนา วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ ถูกคิดค้นเพื่อใช้ในการจัดการ และทำนายข้อมูลแบบลำดับเวลาที่มีแนวโน้ม (Trend) และฤดูกาล (Seasonality) โดยเฉพาะ เมื่อมีแนวโน้ม (Trend) และฤดูกาล (Seasonality) เกิดขึ้นในข้อมูลแบบลำดับเวลา แนวโน้มเป็นการเปลี่ยนแปลงที่ต่อเนื่องของข้อมูลในระยะยาว ในขณะที่ฤดูกาลคือความผันแปรที่ซ้ำกันในระยะเวลาที่เกิดขึ้นในแต่ละปี ทั้งนี้ทั้งแนวโน้ม และฤดูกาลสามารถมีผลกระทบต่อการทำนายข้อมูลในอนาคต โดยมีการจัดการ และทำนายข้อมูลแบบลำดับเวลา 2 รูปแบบ ได้แก่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ ที่มีฤดูกาลแบบคูณ (Holt-Winters Multiplicative Seasonal Exponential Smoothing Method) มีสมการ ดังนี้

$$\begin{aligned} L_t &= \alpha \times (Y_t - S_{t-p}) + (1 - \alpha) \times (L_{t-1} + T_{t-1}) \\ T_t &= \gamma \times (L_t - L_{t-1}) + (1 - \gamma) \times T_{t-1} \\ S_t &= \delta \times (Y_t - L_t) + (1 - \delta) \times S_{t-p} \end{aligned} \quad (2.5)$$

โดยที่

$L_t$  คือ ระดับ (Level) ของข้อมูลในช่วงเวลา  $t$

$T_t$  คือ แนวโน้ม (Trend) ของข้อมูลในช่วงเวลา  $t$

$S_t$  คือ ค่าฤดูกาล (Seasonality) ในช่วงเวลา  $t$

$Y_t$  คือ ค่าข้อมูลในช่วงเวลา  $t$

$S_{t-p}$  คือ ค่าฤดูกาลในช่วงเวลาที่  $t-p$  โดยที่  $p$  คือ ระยะเวลาฤดูกาล (Seasonal Period)

$\alpha, \gamma, \delta$  คือ พารามิเตอร์สมการการเรียนรู้

เมื่อ  $\gamma$  คือค่าคงที่แสดงฤดูกาล และ  $S$  คือความยาวช่วงของฤดูกาล ใช้ตัวแบบการพยากรณ์นี้เมื่อข้อมูลมีฤดูกาลเป็นแบบวิธีการบวก คือในเวลาเดียวกันของแต่ละฤดูกาล ค่าสังเกตจะเพิ่มขึ้นหรือลดลงเป็นค่าคงที่ ในทางปฏิบัติไม่จำเป็นต้องกำหนดค่าความยาวเคลื่อนที่เฉลี่ยเท่าไรก็ดี จึงทำให้ค่าผิดพลาด (Error) หรือค่าวัดความผิดพลาดอื่นๆ ให้ค่าต่ำที่สุด ดังนั้น ควรจะต้องกำหนดค่า  $\alpha$  ให้เหมาะสม

**แบบวิธีการคูณ (Multiplicative Seasonal Model):** มีสมการ ดังนี้

$$\begin{aligned} L_t &= \alpha \times (Y_t / S_{t-p}) + (1 - \alpha) \times (L_{t-1} + T_{t-1}) \\ T_t &= \gamma \times (L_t - L_{t-1}) + (1 - \gamma) \times T_{t-1} \\ S_t &= \delta \times (Y_t / L_t) + (1 - \delta) \times S_{t-p} \end{aligned} \quad (2.6)$$

โดยที่

$L_t$  คือ ระดับ (Level) ของข้อมูลในช่วงเวลา  $t$

$T_t$  คือ แนวโน้ม (Trend) ของข้อมูลในช่วงเวลา  $t$

$S_t$  คือ ค่าฤดูกาล (Seasonality) ในช่วงเวลา  $t$

$Y_t$  คือ ค่าข้อมูลในช่วงเวลา  $t$

$S_{t-p}$  คือ ค่าฤดูกาลในช่วงเวลาที่  $t-p$  โดยที่  $p$  คือ ระยะเวลาฤดูกาล (Seasonal Period)

$\alpha, \gamma, \delta$  คือ พารามิเตอร์สมการการเรียนรู้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ  $y$  คือค่าคงที่แสดงฤดูกาล และ  $S$  คือความยาวช่วงของฤดูกาล ใช้ตัวแบบการพยากรณ์นี้เมื่อข้อมูลมีฤดูกาลเป็นแบบวิธีการคูณ คือในเวลาเดียวกันของแต่ละฤดูกาล ค่าสังเกตจะเพิ่มขึ้น หรือลดลงเป็นค่าร้อยละ (วัชรินทร์ แสงมา, พิษณุ ทองขาว และอรศิริ จันทรเมือง, 2556)

### 2.1.7 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)

วิธีการเรียนรู้ของเครื่องที่เรียกว่าซัพพอร์ตเวกเตอร์แมชชีนเป็นหนึ่งในวิธีการในการเรียนรู้ของเครื่อง (Machine Learning) ในหมวดหมู่ที่เรียกว่าแบบจำลองการเรียนรู้ภายใต้การกำกับ (Supervised learning) โดยใช้ขั้นตอนวิธีที่เรียกว่าอัลกอริทึม (Algorithm) เพื่อวิเคราะห์ข้อมูลเพื่อใช้ในการจำแนกประเภท (Classification) และการวิเคราะห์การถดถอย (Regression) วิธีนี้ถูกพัฒนาขึ้นโดย Vladimir Vapnik และเพื่อนร่วมงานที่ปฏิบัติงานใน AT&T Bell Laboratories (Vladimir Vapnik. et al., 1995)

วิธีซัพพอร์ตเวกเตอร์แมชชีนนั้นสามารถปรับให้เหมาะสมกับข้อมูลที่ซับซ้อน และมีมิติสูงได้ และสามารถนำไปใช้งานในหลายๆ ด้าน อย่างเช่นการประยุกต์ใช้ซัพพอร์ตเวกเตอร์แมชชีนในการจำแนกสิ่งของหรือภาพ การตรวจสอบความคล้ายคลึงของเอกลักษณ์ การหาสัญญาณเตือนล่วงหน้า และอื่นๆ นอกจากนี้ยังมี ซัพพอร์ตเวกเตอร์แมชชีนแบบอนุกรมเวลา (Time Series) ที่ใช้ในการจำแนกและทำนายข้อมูลที่มีลำดับเวลา เช่น ข้อมูลการเคลื่อนไหวของตลาดหลักทรัพย์ การทำนายการเปลี่ยนแปลงในเวลาข้างหน้าของข้อมูล และอื่นๆ การนำซัพพอร์ตเวกเตอร์แมชชีนไปใช้ในงานที่เกี่ยวข้องกับอนุกรมเวลาสามารถช่วยให้ได้คำตอบที่แม่นยำและเป็นประโยชน์ (Gavrishchaka. et al., 2003)

วิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทที่สามารถนำไปใช้ในการพยากรณ์อนุกรมเวลาได้คือ วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย (Support Vector Regression: SVR) ซึ่งเป็นการใช้ซัพพอร์ตเวกเตอร์แมชชีนในการทำนายค่าต่อเนื่อง โดยการหาฟังก์ชันที่เหมาะสมที่สุดเพื่อทำนายค่าต่อเนื่องของชุดข้อมูลอนุกรมเวลา โดยใช้ค่าของตัวแปรอิสระ (Independent Variables) เป็นตัวทำนายค่าตัวแปรตาม (Dependent Variable) ซึ่งในกรณีอนุกรมเวลา จะเป็นค่าของช่วงเวลาต่อเนื่องกัน โดยซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยจะหาเส้นถดถอย (Regression) ที่มีความคล้ายคลึงกับชุดข้อมูลอนุกรมเวลา โดยใช้เทคนิคการหามาร์จิ้น (Margin) และใช้ฟังก์ชันเคอร์เนล (Kernel Function) เพื่อแปลงข้อมูลอนุกรมเวลาเข้าสู่มิติสูงขึ้น ทำให้ซัพพอร์ตเวกเตอร์แมชชีนสามารถใช้ในการพยากรณ์อนุกรมเวลาได้โดยมีประสิทธิภาพสูง และได้ผลลัพธ์ที่แม่นยำในการทำนายค่าต่อเนื่องของชุดข้อมูลอนุกรมเวลาในอนาคต (W Gerstner. et al., 1999)

ฟังก์ชันเคอร์เนล (Kernel Function) เป็นฟังก์ชันที่ใช้ในการคำนวณค่าความคล้ายคลึง หรือค่าเชิงความเป็นไปได้ ระหว่างข้อมูลในการประมาณค่า หรือแปลงข้อมูลในการทำซัพพอร์ตเวกเตอร์แมชชีน ซึ่งเป็นเทคนิคทางการเรียนรู้เชิงประจักษ์ในซัพพอร์ตเวกเตอร์แมชชีน การจัดกลุ่มหรือการจำแนกข้อมูลนั้นขึ้นอยู่กับการคำนวณค่าความคล้ายคลึงระหว่างข้อมูล ซึ่งฟังก์ชันเคอร์เนลจะแปลงเอกสารนี้เป็นเอกสารที่สแกนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลให้อยู่ในรูปของระยะทางหรือค่าเชิงความเป็นไปได้ ระหว่างข้อมูลเพื่อให้ง่ายต่อการจัดกลุ่มหรือการจำแนก

ในซัพพอร์ตเวกเตอร์แมชชีนนั้นมีหลายประเภทของฟังก์ชันเคอร์เนลที่สามารถใช้ได้ เช่น Linear Kernel, Polynomial Kernel, Gaussian Kernel (หรือ Radial Basis Function), Sigmoid Kernel, และอื่นๆ โดยแต่ละประเภทจะมีสมการที่แตกต่างกัน ดังนี้

$$\begin{aligned} \text{Linear Kernel:} \quad & K(x, x_i) = x^T x_i \\ \text{Polynomial Kernel:} \quad & K(x, x_i) = (1 + \langle x^T x_i \rangle) \\ \text{Gaussian Kernel:} \quad & K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \end{aligned} \quad (2.7)$$

เมื่อ  $\gamma$  คือ ค่าพารามิเตอร์ของ Radial Basis Function

เนื่องจากข้อมูลบางชนิดไม่เหมาะกับการใช้สมการเส้นตรงในการจำแนกข้อมูลจึงได้มีการพัฒนาเคอร์เนลที่ใช้กับอัลกอริทึม ซัพพอร์ตเวกเตอร์แมชชีน ซึ่งเคอร์เนลต่างๆ นั้นจะเป็นการใช้สมการต่างๆ เพื่อกำหนดไฮเปอร์เพลน (Hyperplane) ในรูปแบบอื่นๆ ที่ไม่ใช่เส้นตรง

### 2.1.8 ซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR)

เป็นเทคนิคที่ใช้วิธีการของซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) มาวิเคราะห์ความถดถอยระหว่างอินพุตเวกเตอร์ (Input Vector) และตัวแปรเอาต์พุต (Output Variables) ซึ่งนำมาใช้กับการพยากรณ์อนุกรมเวลาได้ โดยเปลี่ยนการจำแนกคลาสด้วยซัพพอร์ตเวกเตอร์แมชชีนเป็นการทำนายค่าด้วยซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR) โดยมีเป้าหมายคือต้องการค้นหาความสัมพันธ์เชิงเส้นระหว่างอินพุตเวกเตอร์ในมิติ  $n (X \in R^n)$  และตัวแปรเอาต์พุต  $(Y \in R)$  และเพราะ ซัพพอร์ตเวกเตอร์รีเกรสชันดัดแปลงจากซัพพอร์ตเวกเตอร์แมชชีน ดังนั้น สมการซัพพอร์ตเวกเตอร์รีเกรสชัน จึงคล้ายคลึงกับสมการไฮเปอร์เพลน (Hyperplane) ของซัพพอร์ตเวกเตอร์แมชชีน (รณชัย ชื่นธวัช และคณะ, 2560)

ซัพพอร์ตเวกเตอร์รีเกรสชันเป็นเทคนิคที่ถูกนำมาใช้สำหรับการคาดการณ์ซึ่งเป็นรูปแบบที่แสดงค่าความสัมพันธ์ของค่าตัวปรับ (b) และค่าน้ำหนัก (w) ในกรณีที่น่าซัพพอร์ตเวกเตอร์รีเกรสชันมาใช้ในการพยากรณ์นั้น จะทำได้ก็ต่อเมื่อได้ทำการปรับการเรียนรู้แล้ว เพื่อให้ได้ค่าตัวปรับ (b) และค่าน้ำหนัก (w) ที่เหมาะสมกับชุดข้อมูลการฝึกฝน (Training Data) ดังนั้นการนำซัพพอร์ตเวกเตอร์รีเกรสชันมาใช้ในงานวิจัย จะต้องมีการกำหนดค่าตัวแปรเพิ่มเติมโดยขึ้นอยู่กับฟังก์ชันเคอร์เนล โดยงานวิจัยนี้ได้เลือกฟังก์ชันเคอร์เนลแบบ Radial Basis Function (RBF) ด้วยการใช้ฟังก์ชัน svm() ใน แพคเกจ e1071 ของโปรแกรม R โดยจำเป็นต้องทำการกำหนดค่าตัวแกมมา ( $\gamma$ ) ค่าคงที่ (C) และเอ็บซิลลอน ( $\epsilon$ ) ให้เหมาะสมกับชุดข้อมูลที่จะนำซัพพอร์ตเวกเตอร์รีเกรสชันไปฝึกเรียนรู้ โดยตัวแกมมา ( $\gamma$ ) เป็นตัวแปรในสมการฟังก์ชันเคอร์เนลแบบ Radial Basis Function (RBF) ที่จะเป็นตัวกำหนดรูปร่างของเส้นระนาบ ส่วนตัวแปรค่าคงที่ (C) นั้นเป็นค่าคงที่ที่ใช้ในการกำหนดระยะขอบ

ของความผิดพลาดในการเรียนรู้ และตัวแปรเอ็บซิลลอน ( $\epsilon$ ) นั้นคือ  $\epsilon$ -insensitive ที่ใช้ในการหา

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ระดับของค่าความถูกต้องของฟังก์ชันประมาณค่า แต่ทั้งนี้ผลของการกำหนดค่าตัวแปรแกมมา ( $\gamma$ ) ค่าคงที่ (C) และเอ็บซิลอน ( $\epsilon$ ) ให้กับแต่ละชุดข้อมูลอาจจะแตกต่างกันไป (อนุธิดา อาษา และ อชฌา ปราบกมล, 2562)

งานวิจัยนี้ ผู้วิจัยใช้ฟังก์ชันเคอร์เนลแบบ Radial Basis Function (RBF) เนื่องจากฟังก์ชันเคอร์เนลแบบ Radial Basis Function (RBF) เป็นฟังก์ชันที่ใช้งานได้ดีในการประมาณค่าข้อมูลที่มีลักษณะซับซ้อน และมีความสามารถในการจับความสัมพันธ์ของข้อมูลที่แตกต่างกันได้ ซึ่งในงานวิจัยนี้ ที่ต้องการพยากรณ์จำนวนรถยนต์ไฟฟ้าในแต่ละเดือนที่มีแนวโน้ม และฤดูกาลที่ซับซ้อน ซึ่งฟังก์ชันเคอร์เนลแบบ Radial Basis Function (RBF) จึงเป็นตัวเลือกที่เหมาะสมมากกว่าฟังก์ชัน Polynomial Kernel ที่เหมาะสมสำหรับข้อมูลที่มีลักษณะเป็นพหุคูณ และฟังก์ชัน Sigmoid Kernel ที่เหมาะสมสำหรับข้อมูลที่มีลักษณะที่เปลี่ยนแปลงเชิงเส้นรูปตัวเอส

โดยฟังก์ชันเคอร์เนลแบบ Radial Basis Function (RBF) มีสมการ ดังนี้

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (2.8)$$

โดยที่

$K(x, x_i)$  คือ ค่าเคอร์เนลระหว่างเวกเตอร์  $x$  และ  $x_i$

$\gamma$  คือ พารามิเตอร์ที่ควบคุมการกระจายของค่าเคอร์เนล

$\|x - x_i\|^2$  คือ ระยะทางยูคลิเดียน (Euclidean Distance) ระหว่างเวกเตอร์  $x$  และ  $x_i$

### 2.1.9 การประเมินประสิทธิภาพของค่าพยากรณ์

#### ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE)

คือตัวชี้วัดที่ใช้ในการประเมินความคลาดเคลื่อนของการพยากรณ์จากข้อมูลจริง โดยนำค่าส่วนเบี่ยงเบนมาตรฐานระหว่างค่าจริง และค่าที่พยากรณ์ได้มาคำนวณ จากนั้นหาค่าเฉลี่ยของค่าส่วนเบี่ยงเบนมาตรฐานนั้น และทำการหาค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) โดยมีสมการดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (2.9)$$

โดยที่

$n$  คือจำนวนข้อมูลทั้งหมด

$y_i$  คือค่าจริงของข้อมูลที่  $i$

$\hat{y}_i$  คือค่าที่พยากรณ์ได้สำหรับข้อมูลที่  $i$

$\sum$  คือผลรวม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสองยังมีค่าเท่ากับศูนย์ยิ่งดี และค่ายิ่งมากเท่าไร ก็ยิ่งแสดงถึงความคลาดเคลื่อนของการพยากรณ์ไปจากข้อมูลจริงมากขึ้น

**ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE)**

เป็นตัวชี้วัดที่ใช้ในการประเมินความคลาดเคลื่อนของการพยากรณ์เป็นเปอร์เซ็นต์จากข้อมูลจริง โดยคำนวณค่าคลาดเคลื่อนเป็นสัดส่วนของค่าคลาดเคลื่อนและค่าจริง จากนั้นหาค่าเฉลี่ยของสัดส่วนเปอร์เซ็นต์เหล่านี้ เพื่อให้ได้ค่าคลาดเคลื่อนเฉลี่ยในรูปแบบของเปอร์เซ็นต์ที่มีค่าสัมบูรณ์เท่ากับการพยากรณ์ มีสมการดังนี้

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.10)$$

โดยที่

$n$  คือจำนวนข้อมูลทั้งหมด

$y_i$  คือค่าจริงของข้อมูลที่  $i$

$\hat{y}_i$  คือค่าที่พยากรณ์ได้สำหรับข้อมูลที่  $i$

$||$  คือค่าสัมบูรณ์

$\Sigma$  คือผลรวม

ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเป็นตัวชี้วัดที่แสดงถึงความคลาดเคลื่อนของการพยากรณ์ในรูปของเปอร์เซ็นต์ ค่าคลาดเคลื่อนเฉลี่ยในรูปแบบนี้ที่มีค่าสัมบูรณ์เท่ากับการพยากรณ์เป็นจำนวนเต็มแสดงถึงความคลาดเคลื่อนเป็น 0% ซึ่งแสดงถึงความแม่นยำสูงสุดของการพยากรณ์ และในกรณีที่ค่าคลาดเคลื่อนเฉลี่ยในรูปแบบนี้มีค่าสัมบูรณ์เท่ากับการพยากรณ์ที่มีค่ามากกว่าหนึ่ง แสดงถึงความคลาดเคลื่อนมาก อย่างไรก็ตาม ถ้าค่าคลาดเคลื่อนเฉลี่ยในรูปแบบนี้มีค่าเป็น Inf (Infinity) นั้นหมายความว่าไม่มีค่าจริง (Actual) ที่เป็นศูนย์ ซึ่งทำให้ไม่สามารถหาเปอร์เซ็นต์คลาดเคลื่อนได้ ดังนั้น ค่าคลาดเคลื่อนเฉลี่ยในรูปแบบนี้ที่มีค่าสัมบูรณ์เท่ากับการพยากรณ์จึงไม่สามารถคำนวณได้ จึงควรใช้ตัววัดอื่น เช่น รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองแทน

งานวิจัยนี้ทำการพยากรณ์ตัวแบบผ่านโปรแกรม R โดยผู้วิจัยใช้ฟังก์ชันจากไลบรารี (Library) ที่ผ่านการพัฒนาจากนักพัฒนาท่านอื่น โดยมีไลบรารีที่สำคัญได้แก่ library(forecast) library(e1071) และ library(zoo) โดยแต่ละไลบรารีมีการทำงาน ดังต่อไปนี้

library(forecast) เป็นไลบรารีที่ใช้ในการวิเคราะห์ และทำนายข้อมูลที่เป็นชุดข้อมูลช่วงเวลา ในภาษา R ไลบรารีนี้มีฟังก์ชันที่สามารถช่วยในการสร้าง และปรับแบบจำลองในการทำนายข้อมูลเชิงเส้น และเชิงสถิติ ซึ่งสามารถนำไปใช้ในการทำนายแนวโน้ม และค่าในอนาคต รวมถึงสร้างกราฟ และ

แสดงผลการทำนายข้อมูลเชิงเส้น โลบรารีนี้เป็นที่นิยมในงานที่เกี่ยวกับการพยากรณ์ โดยในโลบรารีนี้มีฟังก์ชันที่สำคัญ ดังนี้

1. ฟังก์ชัน `stl` มีหน้าที่ในการแยกส่วนประกอบแนวโน้ม และฤดูกาลโดยใช้วิธีการโลเอส ซึ่งเป็นเทคนิคทางสถิติที่ใช้ในการแยกส่วนประกอบของอนุกรมเวลา เพื่อหาแนวโน้ม (Trend) และฤดูกาล (Seasonal) ที่มีอยู่ในข้อมูล อย่างไรก็ตาม ฟังก์ชันนี้ ยังสามารถตรวจจับ และแยกส่วนประกอบอื่น ๆ ในอนุกรมเวลาได้ เช่น ค่าส่วนที่เหลือ (Residuals) เป็นต้น การใช้งานฟังก์ชันนี้ช่วยให้สามารถทำความเข้าใจ และวิเคราะห์ข้อมูลอนุกรมเวลาได้ง่ายขึ้น เนื่องจากสามารถแยก และวิเคราะห์ส่วนประกอบต่างๆ ได้แยกกัน

2. ฟังก์ชัน `tslm()` ใช้ในการสร้างตัวแบบพยากรณ์โดยใช้เทคนิคการวิเคราะห์เชิงเส้นสำหรับข้อมูลที่เป็นอนุกรมเวลา โดยคำนึงถึงแนวโน้ม และฤดูกาลของข้อมูลที่ส่งเข้าไปในฟังก์ชัน เพื่อทำนายค่าที่คาดการณ์ว่าจะเกิดขึ้นในช่วงเวลาถัดไป

`library(e1071)` เป็นโลบรารีในภาษา R ที่ใช้ในงานทางด้านการเรียนรู้แบบเครื่องจักร (Machine Learning) โลบรารีนี้ให้เครื่องมือที่จำเป็นสำหรับการสร้าง และใช้งานโมเดลการจำแนก และการพยากรณ์ ซึ่งรวมถึงการสร้างแบบจำลอง เช่น วิธีซัพพอร์ตเวกเตอร์แมชชีน วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน เป็นต้น โลบรารีนี้มีความสามารถในการพยากรณ์ค่ากลุ่มของข้อมูลที่ไม่ทราบคำตอบล่วงหน้า และเหมาะสำหรับงานที่ซับซ้อน และมีข้อมูลที่มีลักษณะแปรปรวน โดยในโลบรารีนี้มีคำสั่ง และฟังก์ชันที่สำคัญ ดังนี้

1. คำสั่ง `param_ranges` เป็นการกำหนดชุดค่าของพารามิเตอร์ที่ใช้ในการปรับแต่งแบบจำลองในการเรียนรู้แบบเครื่องจักร (Machine Learning) โดยในที่นี้คือชุดค่าของพารามิเตอร์ `eps` `nu` `cost` และ `gamma` ในวิธีซัพพอร์ตเวกเตอร์แมชชีน ค่าที่กำหนดไว้ใน `param_ranges` จะถูกใช้ในการทดลอง และปรับแต่งพารามิเตอร์ของซัพพอร์ตเวกเตอร์แมชชีน เพื่อหาค่าที่เหมาะสมที่สุดในการสร้างตัวแบบพยากรณ์ซัพพอร์ตเวกเตอร์แมชชีน โดยผู้วิจัยกำหนดชุดค่าของพารามิเตอร์ ดังนี้

ค่า `eps` และ `nu` มีชุดค่าพารามิเตอร์เท่ากับ 0.1 0.2 0.3 และ 0.4

ค่า `cost` มีชุดค่าพารามิเตอร์เท่ากับ 1 10 100 และ 1000

ค่า `gamma` มีชุดค่าพารามิเตอร์เท่ากับ 0.1 0.01 และ 0.001

2. ฟังก์ชัน `tune()` เป็นฟังก์ชันที่ใช้ในการปรับแต่งพารามิเตอร์ของตัวแบบพยากรณ์ในการพยากรณ์ หรือการจำแนกข้อมูล ฟังก์ชันนี้ทำหน้าที่ในการทดสอบค่าพารามิเตอร์ต่างๆ ที่กำหนดให้กับแบบจำลองเพื่อหาค่าที่เหมาะสมที่สุดสำหรับการพยากรณ์ โดยการทดสอบค่าพารามิเตอร์นี้จะใช้ข้อมูลที่เก็บไว้ในชุดทดสอบ เพื่อวัดประสิทธิภาพของแบบจำลองที่ใช้ค่าพารามิเตอร์แต่ละค่า และตัวแปรอื่นๆ ที่มีอยู่ จากนั้นฟังก์ชันจะควบคุมค่าพารามิเตอร์ให้กับแบบจำลองที่มีประสิทธิภาพดีที่สุด ซึ่งทำให้แบบจำลองสามารถให้ผลลัพธ์ที่แม่นยำ และเสถียรมากขึ้นในการพยากรณ์

library(zoo) มีความสามารถในการจัดการ และแปลงข้อมูลชุดเวลาอย่างมีประสิทธิภาพ มีฟังก์ชันที่ช่วยในการเรียงลำดับข้อมูลตามเวลา ซึ่งเป็นองค์ประกอบสำคัญในการแสดงผล และการวิเคราะห์ข้อมูลชุดเวลา มีฟังก์ชันที่ช่วยในการสร้างกราฟเพื่อแสดงข้อมูลชุดเวลาอย่างง่ายสามารถแสดงผลข้อมูลทั้งข้อมูลจริง และค่าพยากรณ์ในรูปแบบกราฟเพื่อให้เห็นภาพการเปรียบเทียบได้ชัดเจน นอกจากนี้ zoo แล้ว ยังมีไลบรารีอื่นๆ เช่น xts และ tsibble ซึ่งเป็นไลบรารีที่มีความสามารถในการจัดการ และแสดงผลข้อมูลชุดเวลาเช่นเดียวกัน อย่างไรก็ตาม การเลือกใช้ไลบรารีขึ้นอยู่กับความต้องการ และความถนัดของผู้ทำวิจัย

นอกจากนี้ยังมีฟังก์ชัน และคำสั่งอื่นๆ ที่อยู่นอกเหนือจากไลบรารีที่กล่าวไปข้างต้นที่สำคัญได้แก่

คำสั่ง `hw_model` ซึ่งอยู่ในฟังก์ชัน `HoltWinters()` จากแพ็คเกจ `stats` สามารถกำหนดพารามิเตอร์ได้เนื่องจากการใช้ปรับให้เรียบโฮลต์-วินเทอร์ ซึ่งเป็นเทคนิคแบบแยกส่วน (Exponential Smoothing) ที่มีการปรับค่าพารามิเตอร์ต่างๆ อัตโนมัติ เพื่อให้ตัวแบบสามารถปรับใกล้เคียงกับแบบโมเดลข้อมูลจริงได้ดีที่สุด พารามิเตอร์ที่กำหนดให้กับ `hw_model` ได้แก่ค่าอัลฟา (Alpha), เบต้า (Beta), และแกมมา (Gamma)

คำสั่ง `param_ranges` เป็นการกำหนดช่วงของพารามิเตอร์ที่ใช้ในกระบวนการตรวจสอบและปรับค่าพารามิเตอร์ (Parameter Tuning) ของอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยของอนุกรมเวลา ซึ่งตัวแปร `param_ranges` เป็นรูปแบบของรายการที่ประกอบด้วยชื่อพารามิเตอร์ที่ต้องการปรับค่าและช่วงของค่าที่ต้องการทดลองปรับ โดยในที่นี้มีพารามิเตอร์ที่กำหนดคือ EPS NU Cost และ Gamma ซึ่งแต่ละพารามิเตอร์จะมีช่วงของค่าที่ต้องการทดลองเพื่อหาค่าที่ดีที่สุดสำหรับการสร้างตัวแบบพยากรณ์ซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยในอนุกรมเวลา

ฟังก์ชัน `plot()` เป็นฟังก์ชันที่ใช้ในการพล็อต (แสดงผลในรูปแบบกราฟ) ข้อมูลที่ต้องการวิเคราะห์ หรือผลลัพธ์ที่ได้จากการวิเคราะห์ต่างๆ

## 2.2 งานวิจัยที่เกี่ยวข้อง

รชฎ เลียงจันทร์ (2565) จากศูนย์วิจัยกรุงเทพฯ ได้ศึกษาความต้องการ และโอกาสที่กำลังมาถึงของรถยนต์ไฟฟ้าในประเทศไทย โดยพบว่า คนที่ใช้รถยนต์ไฟฟ้าตัดสินใจซื้อเนื่องจากค่าใช้จ่ายถูกกว่าดีต่อสิ่งแวดล้อม และเทคโนโลยีที่ก้าวหน้า ขณะที่สถานีชาร์จไฟที่ยังมีจำนวนไม่ครอบคลุม ระยะทางการขับขี่ต่อการชาร์จหนึ่งครั้งสั้น ระยะเวลาการชาร์จที่นาน และราคาของรถยนต์ไฟฟ้าที่ยังสูงกว่ารถ จากการสำรวจพบว่ามากกว่าร้อยละ 80 ของผู้ตอบแบบสอบถามวางแผนจะซื้อรถยนต์ใน 5 ปีข้างหน้า และรถยนต์ไฟฟ้าประเภทแบตเตอรี่ เป็นรถที่ผู้บริโภคให้ความสนใจสูงสุด โดยความต้องการรถยนต์ไฟฟ้าจะเริ่มเกิดขึ้นในปี ค.ศ. 2022 – 2023 ในช่วงนี้ความต้องการจะกระจุกอยู่ที่รถยนต์ไฟฟ้าที่มีราคาในระดับปานกลางถึงสูง จากนั้นความต้องการรถยนต์ไฟฟ้าจะเร่งตัวขึ้นในปี ค.ศ. 2024 เป็นต้น เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ไป ลักษณะของรถยนต์ไฟฟ้าที่เป็นที่ต้องการขยับลงมาที่รถขนาดเล็กและมีราคาถูกลง โดยทั้งลักษณะของรถยนต์ที่เป็นที่ต้องการ และกลุ่มลูกค้าเป้าหมายมีแนวโน้มเปลี่ยนแปลงตามระยะเวลา นอกจากนี้ผู้บริโภคยังมองรถยนต์ไฟฟ้าเป็นสินค้าชนิดใหม่ จึงทำให้ความภักดีต่อแบรนด์ลดน้อยลง Liangcai Dong และ Ziqi Xu (2011) ได้ทำการพยากรณ์การผลิตรถยนต์ในประเทศจีน โดยใช้วิธีการซัพพอร์ตเวกเตอร์แมชชีน (SVM) เปรียบเทียบกับวิธี ARIMA (Autoregressive Integrated Moving Average) เพื่อเป็นแนวทางการในการตัดสินใจทางธุรกิจของผู้ผลิตรถยนต์ในประเทศจีน โดยใช้การผลิตรถยนต์รายเดือนในประเทศจีนเป็นข้อมูลในการพยากรณ์ตั้งแต่เดือนมกราคม ค.ศ. 2005 ถึงเดือนมีนาคม ค.ศ. 2010 โดยมีจำนวนทั้งหมด 63 เดือน ผลลัพธ์แสดงให้เห็นว่าโมเดลซัพพอร์ตเวกเตอร์แมชชีน มีการพยากรณ์ที่แม่นยำสุด เนื่องจากมีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 5.9% ซึ่งมีค่าต่ำสุดในงานวิจัยนี้

อุรุชา จันทรรภา และ นันทชัย กานตานันทะ (2564) ศึกษา และเปรียบเทียบวิธีการพยากรณ์มูลค่าการส่งออกรถยนต์อุปกรณ์และส่วนประกอบของประเทศไทย โดยใช้วิธีการอนุกรมเวลา และเปรียบเทียบระหว่างวิธีการพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ (Simple Moving Average) วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ (Holt-Winters Exponential Smoothing) และวิธี SARIMA (Seasonal Autoregressive Integrated Moving Average) โดยใช้ข้อมูลมูลค่าการส่งออกรถยนต์อุปกรณ์ และส่วนประกอบรายเดือนจากสำนักงานปลัดกระทรวงพาณิชย์ ตั้งแต่เดือนมกราคม พ.ศ. 2551 ถึงเดือนธันวาคม พ.ศ. 2562 โดยมีจำนวนทั้งหมด 144 เดือน ในการศึกษานี้ได้แบ่งข้อมูลออกเป็น 2 ชุด โดยชุดแรกเป็นข้อมูลตั้งแต่เดือนมกราคม พ.ศ. 2551 ถึงเดือนธันวาคม พ.ศ. 2561 ที่ใช้ในการสร้างตัวแบบพยากรณ์ ชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคมถึงเดือนธันวาคม พ.ศ. 2562 ที่ใช้ในการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ จากผลการศึกษาพบว่า วิธีให้ปรับเรียบแบบโฮลต์-วินเทอร์ มีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 9.68% ดังนั้นวิธีปรับเรียบแบบโฮลต์-วินเทอร์ มีความเหมาะสม และมีความแม่นยำในการพยากรณ์มูลค่าการส่งออกรถยนต์อุปกรณ์ และส่วนประกอบของประเทศไทยมากที่สุดในงานวิจัยนี้

กมล จิงมานนท์ (2562) ได้ศึกษาการพยากรณ์ยอดขายรถยนต์ใช้ไฟฟ้าในประเทศสหรัฐอเมริกา และจีน เพื่อเทียบวิธีพยากรณ์ที่แม่นยำที่สุดด้วยกระบวนการทางสถิติ ด้วยวิธีการพยากรณ์ 4 แบบ ได้แก่ การพยากรณ์อนุกรมเวลาวิธีแยกส่วนประกอบ (Decomposition) วิธีแบบจำลองเอกซ์โพเนนเชียลของวินเทอร์ วิธีแบบจำลองแบบถดถอยพหุคูณ และวิธีการรวมผลพยากรณ์ แล้วนำผลลัพธ์มาเทียบหาวิธีที่ให้ค่าความแม่นยำสูงสุด จากการทดสอบพบว่า วิธีการพยากรณ์ที่เหมาะสมกับยอดขายรถยนต์ใช้ไฟฟ้าในประเทศจีนคือ วิธีการรวมผลพยากรณ์ นอกจากให้ความแม่นยำสูง ยังให้ค่าผิดพลาดที่น้อยกว่าวิธีอื่น ๆ วิธีการพยากรณ์ที่เหมาะสมกับยอดขายรถยนต์ใช้ไฟฟ้าในสหรัฐอเมริกาคือ การพยากรณ์ด้วยวิธีแยกส่วนประกอบ ในการศึกษาวิจัยนี้ถือเป็นวิธีที่ให้ผลแม่นยำวิธีหนึ่ง อย่างไรก็ตาม ด้วยเทคโนโลยีรถยนต์ใช้ไฟฟ้าเป็นเทคโนโลยีใหม่ รวมถึงการบันทึกข้อมูลยอดขายจริง

ยังไม่ครบถึงปลายปี หรือครบฤดูกาล นอกจากนี้ยังคงเป็นสินค้าเฉพาะกลุ่ม และภาครัฐยังไม่มีนโยบายในการผลักดันที่ชัดเจน จึงควรต้องอาศัยข้อมูลแวดล้อมประกอบการพิจารณา



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 3

### วิธีการดำเนินงานวิจัย

ขั้นตอนวิธีการดำเนินงานวิจัย มีขั้นตอนดังนี้

1. เก็บรวบรวมข้อมูล
2. วิเคราะห์ข้อมูลเบื้องต้น
3. สร้างตัวแบบพยากรณ์ที่เหมาะสม
4. เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์
5. สรุปผลการวิจัย และอภิปรายผล

รายละเอียดของแต่ละขั้นตอน มีดังนี้

#### 3.1 เก็บรวบรวมข้อมูล

ข้อมูลที่ใช้ในการวิจัยนี้ ผู้วิจัยจัดเก็บข้อมูลทุติยภูมิของจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือน ตั้งแต่ปี ค.ศ. 2018 – 2022 จำนวนทั้งหมด 60 เดือน จากฐานข้อมูลในระบบของกรมการขนส่งทางบก (ข้อมูลแสดงในภาคผนวก ก)

#### 3.2 ทำการวิเคราะห์ข้อมูลเบื้องต้น

ทำการทดสอบข้อมูลจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือน ตั้งแต่ปี ค.ศ. 2018 – 2022 จำนวนทั้งหมด 60 ค่า ว่ามีการแจกแจงปกติหรือไม่ เพื่อตรวจสอบแนวโน้ม และอิทธิพลฤดูกาล ซึ่งจะช่วยให้ทราบว่าข้อมูลที่ใช้ในการวิเคราะห์เป็นข้อมูลที่เหมาะสมและเพียงพอหรือไม่ หากข้อมูลไม่มีการแจกแจงปกติ การทดสอบแนวโน้ม และอิทธิพลฤดูกาลแบบไม่ใช้พารามิเตอร์ เป็นทางเลือกที่เหมาะสมในการวิเคราะห์แนวโน้มของข้อมูล เนื่องจากเป็นวิธีที่มีความยืดหยุ่นในการใช้กับข้อมูลที่มีลักษณะ และความซับซ้อนต่างกัน ทำให้เหมาะสมกับการวิเคราะห์แนวโน้ม และอิทธิพลฤดูกาลของข้อมูลในสถานการณ์ที่หลากหลาย จากการนำข้อมูลทดสอบแนวโน้ม และอิทธิพลฤดูกาลด้วยการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง (Anderson-Darling Test) พบว่าข้อมูลไม่มีการการแจกแจงปกติ ดังนั้นจึงทำการทดสอบแนวโน้มแบบไม่พารามิเตอร์ด้วยวิธีทดสอบแมน-เคนดัลล์ (Mann-Kendall Test) และทำการทดสอบอิทธิพลฤดูกาลแบบไม่พารามิเตอร์ด้วยวิธีทดสอบครัสคัล-วอลลิส (Kruskal-Wallis Test) พบว่าข้อมูลมีแนวโน้ม และอิทธิพลของฤดูกาล จึงเลือกใช้วิธีแยกส่วนประกอบ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ และวิธีซัพพอร์ตเวกเตอร์แมชชีนในการสร้างตัวแบบพยากรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.3 สร้างตัวแบบพยากรณ์ที่เหมาะสม

#### 3.2.1 วิธีแยกส่วนประกอบ

งานวิจัยนี้ ใช้วิธีแยกส่วนประกอบผ่านโปรแกรม R ในการวิเคราะห์ข้อมูล มีขั้นตอนการวิเคราะห์ ดังนี้

1. แบ่งข้อมูลจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือนเป็น 2 ชุด ข้อมูลชุดที่ 1 คือข้อมูลฝึกสอน ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 จำนวน 48 ค่า เพื่อใช้ในการสร้างตัวแบบพยากรณ์ และชุดที่ 2 คือข้อมูลทดสอบ ตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ค.ศ. 2022 จำนวน 12 ค่า เพื่อใช้ประเมินประสิทธิภาพของตัวแบบพยากรณ์

2. ทำการแยกส่วนประกอบข้อมูลโดยเริ่มที่การตรวจจับแนวโน้ม ใช้เทคนิคการวิเคราะห์เชิงเส้น เพื่อตรวจจับแนวโน้มของข้อมูลที่ได้นำเข้ามา เพื่อหาค่าแนวโน้ม และนำไปสร้างอนุกรมเวลาใหม่ที่ไม่มีแนวโน้ม หลังจากนั้น ลบแนวโน้มออกจากอนุกรมเวลา เพื่อให้เหลือเฉพาะส่วนของฤดูกาล และส่วนคงเหลือ จากนั้น คำนวณหาค่าฤดูกาล (Seasonality) จากส่วนที่เหลือหลังจากลบแนวโน้ม และคำนวณดัชนีฤดูกาล (Seasonal Index) จากค่าฤดูกาล เพื่อหาค่าฤดูกาลเฉลี่ย หลังจากนั้นทำการตรวจจับค่าส่วนที่เหลือหลังจากที่ลบแนวโน้ม และฤดูกาลออกแล้ว เมื่อได้ค่าแนวโน้ม ค่าฤดูกาล และค่าสุ่มแล้ว นำมาสร้างอนุกรมเวลาการแยกส่วนประกอบ หลังจากนั้นใช้เทคนิค STL (Seasonal-Trend Decomposition Using LOESS) ในการตรวจจับแนวโน้ม และฤดูกาลของข้อมูลอีกครั้งเพื่อเปรียบเทียบผลลัพธ์ โดยใช้ฟังก์ชัน `stl` จากแพ็คเกจ `forecast`

3. สร้างตัวแบบพยากรณ์จากชุดฝึกสอน โดยใช้ฟังก์ชัน `tslm()` จากแพ็คเกจ `forecast` เพื่อสร้างตัวแบบพยากรณ์ โดยกำหนดตัวแปรที่ต้องการทำนายซึ่งเป็นข้อมูลที่ใช้ ที่ได้แยกส่วนประกอบต่างๆ ออกจากอนุกรมเวลาก่อนหน้านี้ ตัวแบบพยากรณ์นี้จะใช้แนวโน้ม และฤดูกาล เพื่อทำนายค่าในอนาคตของข้อมูลอนุกรมเวลา

4. พยากรณ์ค่าของชุดทดสอบ โดยใช้ตัวแบบพยากรณ์ที่ได้สร้างขึ้นมากับชุดข้อมูลที่ได้รับการแยกค่าฤดูกาลและแนวโน้มจากขั้นตอนก่อนหน้านี้เพื่อพยากรณ์ค่าของชุดทดสอบ พร้อมทั้งสร้างกราฟเพื่อแสดงค่าจำนวนรถยนต์ไฟฟ้าแบบผู้ใช้งานจริง และค่าพยากรณ์

4. คำนวณค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าคลาดเคลื่อนเฉลี่ยในรูปแบบของเปอร์เซ็นต์ที่มีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เพื่อวัดประสิทธิภาพของตัวแบบพยากรณ์ที่สร้าง โดยใช้ข้อมูลที่ทำนายได้ และข้อมูลจริงในชุดทดสอบ

### 3.2.2 วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์

งานวิจัยนี้ ใช้วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ ผ่านโปรแกรม R ในการวิเคราะห์ข้อมูล มีขั้นตอนการวิเคราะห์ ดังนี้

1. แบ่งข้อมูลจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือนเป็น 2 ชุด ข้อมูลชุดที่ 1 คือข้อมูลฝึกสอน ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 จำนวน 48 ค่า เพื่อใช้ในการสร้างตัวแบบพยากรณ์ และชุดที่ 2 คือข้อมูลทดสอบ ตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ค.ศ. 2022 จำนวน 12 ค่า เพื่อใช้ประเมินประสิทธิภาพของตัวแบบพยากรณ์

2. สร้างตัวแบบปรับให้เรียบแบบโฮลต์-วินเทอร์จากข้อมูลฝึกสอน โดยมีการกำหนดให้เป็นการพยากรณ์ปรับให้เรียบแบบโฮลต์-วินเทอร์ที่มีฤดูกาลแบบบวก และแบบคูณ พร้อมทั้งกำหนดพารามิเตอร์ที่ได้จากค่าพารามิเตอร์อัตโนมัติจากฟังก์ชัน HoltWinters() โดยคำสั่งนี้ให้ผลลัพธ์พารามิเตอร์อัตโนมัติ ได้แก่

ค่าอัลฟา (Alpha) เท่ากับ 0

ค่าเบต้า (Beta) เท่ากับ 0

ค่าแกมมา (Gamma) เท่ากับ 0.08131686

3. พยากรณ์ค่าของชุดทดสอบ โดยใช้ตัวแบบพยากรณ์ที่ได้สร้างขึ้นมากับชุดข้อมูลที่ได้รับการแยกค่าฤดูกาล และแนวโน้มจากขั้นตอนก่อนหน้านี้เพื่อพยากรณ์ค่าของชุดทดสอบ พร้อมทั้งสร้างกราฟเพื่อแสดงค่าจำนวนรถยนต์ไฟฟ้าแบบผู้ใช้จริง และค่าพยากรณ์

4. คำนวณค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าคลาดเคลื่อนเฉลี่ยในรูปแบบของเปอร์เซ็นต์ที่มีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เพื่อวัดประสิทธิภาพของตัวแบบพยากรณ์ที่สร้าง โดยใช้ข้อมูลที่ทำนายได้ และข้อมูลจริงในชุดทดสอบ

### 3.2.3 วิธีซัพพอร์ตเวกเตอร์แมชชีน

งานวิจัยนี้ ใช้วิธีซัพพอร์ตเวกเตอร์แมชชีน ผ่านโปรแกรม R ในการวิเคราะห์ข้อมูล มีขั้นตอนการวิเคราะห์ ดังนี้

1. แบ่งข้อมูลจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือนเป็น 2 ชุด ข้อมูลชุดที่ 1 คือข้อมูลฝึกสอน ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 จำนวน 48 ค่า เพื่อใช้ในการสร้างตัวแบบพยากรณ์ และชุดที่ 2 คือข้อมูลทดสอบ ตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ค.ศ. 2022 จำนวน 12 ค่า เพื่อใช้ประเมินประสิทธิภาพของตัวแบบพยากรณ์

2. หาค่าพารามิเตอร์ที่ดีที่สุดก่อนทำการปรับแต่งตัวแบบพยากรณ์ โดยใช้คำสั่ง param\_ranges เพื่อเป็นการสร้างตัวแปรที่เป็นรายการ หรืออาร์เรย์ ซึ่งประกอบด้วยค่าพารามิเตอร์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หรือ อัลกอริทึมที่ต้องการทดลองในการปรับแต่งตัวแบบพยากรณ์ โดยคำสั่งนี้ จะเลือกค่าพารามิเตอร์ และอัลกอริทึมที่ดีที่สุดให้โดยอัตโนมัติ ทั้งนี้การเลือกค่าในค่าทดลองของพารามิเตอร์สามารถทำได้หลายวิธี โดยอาจใช้ข้อกำหนดเกณฑ์ต่างๆ หรือขึ้นอยู่กับความเชื่อของผู้วิจัย และความซับซ้อนของปัญหา ผู้วิจัยกำหนดค่าพารามิเตอร์ และอัลกอริทึมที่ต้องการทดลองในการปรับแต่งตัวแบบพยากรณ์ ดังนี้

ค่าเอ็ปซิลอน (EPS-Regression) และ ค่าเอ็นยู (NU-Regression) มีค่าทดลองที่ 0.1 0.2 0.3 และ 0.4

ค่าคงที่ (Cost) มีค่าทดลองที่ 1 10 100 และ 1000

ค่าแกมมา (Gamma) มีค่าทดลองที่ 0.1 0.01 และ 0.001

อัลกอริทึมเอ็ปซิลอน (EPS-Regression) และ ค่าเอ็นยู (NU-Regression) เป็นตัวแปรที่มีความสำคัญในการควบคุมความซับซ้อนของตัวแบบพยากรณ์ในกระบวนการปรับแต่ง ซึ่งค่าที่ต้องการทดลอง คือ 0.1 0.2 0.3 และ 0.4 จะช่วยให้ผู้วิจัยสามารถทดสอบความสามารถของโมเดลในการปรับความซับซ้อนของเส้นแบ่งกลุ่ม (Hyperplane) และควบคุมความยืดหยุ่นของตัวแบบพยากรณ์ ซึ่งจะมีผลต่อประสิทธิภาพในการทำนาย และการควบคุมความผิดพลาดของโมเดล

พารามิเตอร์คงที่ (Cost) มีความสำคัญในการกำหนดค่าความคงที่ของตัวแบบพยากรณ์ ในกระบวนการการตรวจสอบ และปรับค่าพารามิเตอร์ ค่าที่ต้องการทดลอง มีดังนี้ 1 10 100 และ 1000 จะช่วยให้ผู้วิจัยสามารถทดสอบความสามารถในการควบคุมความขัดแย้งของข้อมูล และควบคุมความผิดพลาดของตัวแบบพยากรณ์เพื่อให้สอดคล้องกับข้อมูลที่ใช้ในการฝึกสอน

พารามิเตอร์แกมมา (Gamma) มีความสำคัญในการกำหนดค่าความซับซ้อนของเส้นแบ่งกลุ่ม (Hyperplane) ซึ่งค่าที่ต้องการทดลอง คือ 0.1 0.01 และ 0.001 จะช่วยให้ผู้วิจัยสามารถทดสอบความสามารถในการเรียนรู้และการทำนายของตัวแบบพยากรณ์ว่าเส้นแบ่งกลุ่มที่เกิดขึ้นมีความซับซ้อน และความยืดหยุ่นเพียงพอในการควบคุมการฝึกสอน และทำนายข้อมูล

โดยผลลัพธ์ของค่าพารามิเตอร์ที่ดีที่สุดของตัวแบบพยากรณ์ของรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีค่าแตกต่างกัน ผลลัพธ์ของค่าพารามิเตอร์เหล่านี้ แสดงในบทที่ 4

3. ระบุค่าอัลกอริทึม และค่าพารามิเตอร์ที่ดีที่สุดจากคำสั่งก่อนหน้านี้ เพื่อใช้ในการปรับแต่งตัวแบบพยากรณ์ซัพพอร์ตเวกเตอร์แมชชีนด้วยฟังก์ชัน `tune()` เพื่อปรับแต่งตัวแบบพยากรณ์ให้มีประสิทธิภาพด้วยข้อมูลชุดฝึกสอน โดยใช้ฟังก์ชัน `tune()` ในรูปแบบถดถอย เนื่องจากต้องการพยากรณ์ตัวแบบที่ทำนายค่าต่อเนื่องของอนุกรมเวลา (Time Series Regression) โดยมีตัวแปรอิสระคือ `train_data_df$train_data` ซึ่งเก็บข้อมูลของจำนวนรถยนต์ไฟฟ้าที่ลงทะเบียนในแต่ละเดือนของปี ค.ศ. 2018 - 2021

4. พยากรณ์ค่าของชุดทดสอบ โดยใช้ตัวแบบพยากรณ์ที่ได้รับการปรับแต่งจากขั้นตอนก่อนหน้านี้เพื่อพยากรณ์ค่าของชุดทดสอบโดยมีตัวแปรตาม คือ `test_data_df$test_data` หรือเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

test\_data ซึ่งเก็บข้อมูลของจำนวนรถยนต์ไฟฟ้าที่ลงทะเบียนในแต่ละเดือนของปี ค.ศ. 2022 ที่ใช้ในกระบวนการทดสอบประสิทธิภาพของตัวแบบพยากรณ์หลังจากที่ได้ทำการปรับแต่งพารามิเตอร์เสร็จสิ้นแล้ว พร้อมทั้งสร้างกราฟเพื่อแสดงค่าจำนวนรถยนต์ไฟฟ้าแบบผู้ใช้จริง และค่าพยากรณ์ ด้วยไลบรารี zoo

5. คำนวณค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าคลาดเคลื่อนเฉลี่ยในรูปแบบของเปอร์เซ็นต์ที่มีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เพื่อวัดประสิทธิภาพของตัวแบบพยากรณ์ที่สร้าง โดยใช้ข้อมูลที่ทำนายได้ และข้อมูลจริงในชุดทดสอบ

### 3.2.4 เปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์

ผู้วิจัยทำการเปรียบเทียบประสิทธิภาพของการพยากรณ์ทั้ง 3 วิธี ได้แก่ วิธีแยกส่วนประกอบ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ และวิธีซัพพอร์ตเวกเตอร์แมชชีน โดยเปรียบเทียบค่าที่ต่ำที่สุดของค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เพื่อประเมินประสิทธิภาพของแบบพยากรณ์ที่สร้างขึ้นจากการทำนาย โดยค่าที่ต่ำที่สุดของค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) จะแสดงถึงความเข้ากันได้ของแบบจำลองกับข้อมูลจริง ส่วนค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) จะช่วยในการประเมินความคลาดเคลื่อนเป็นเปอร์เซ็นต์ของการพยากรณ์ ค่ายิ่งต่ำ ยิ่งมีความคลาดเคลื่อนน้อย การเปรียบเทียบทั้งสองค่านี้ จะช่วยให้ผู้วิจัยสามารถวัดประสิทธิภาพของตัวแบบพยากรณ์ได้

### 3.3 สรุปผลวิจัย และอภิปรายผล


ผู้วิจัยเลือกตัวแบบที่เหมาะสมที่สุดสำหรับการเปรียบเทียบการพยากรณ์จำนวนรถยนต์ไฟฟ้า โดยเลือกตัวแบบพยากรณ์ที่ให้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุด และสรุปผลการวิจัยว่าตัวแบบใดเหมาะสมสำหรับนำไปใช้ในการพยากรณ์ พร้อมทั้งอภิปรายผล

## บทที่ 4


### ผลการวิจัยและการอภิปรายผล

#### 4.1 การเก็บรวบรวมข้อมูล

ข้อมูลที่ใช้ในการวิจัยนี้ ผู้วิจัยจัดเก็บข้อมูลสถิติของจำนวนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) จดทะเบียนในประเทศไทยรายเดือน ตั้งแต่ปี ค.ศ. 2018 – 2022 จำนวนทั้งหมด 60 เดือน จากฐานข้อมูลในระบบของกรมการขนส่งทางบก ดังนี้



รูปที่ 4.1 จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ตั้งแต่ปี ค.ศ. 2018 – 2022 มีแนวโน้มเพิ่มมากขึ้น



รูปที่ 4.2 จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ตั้งแต่ปี

ค.ศ. 2018 – 2022 มีแนวโน้มเพิ่มมากขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากการพิจารณาแนวโน้มจำนวนการจดทะเบียนรถยนต์ไฟฟ้าประเภทรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ในเบื้องต้น พบว่า รถยนต์ไฟฟ้าทั้ง 2 ประเภท มีแนวโน้มการจดทะเบียนสูงขึ้น โดยเฉพาะการจดทะเบียนที่สูงขึ้นอย่างก้าวกระโดดของรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ตั้งแต่ช่วงเดือนที่ 48 - 50 เป็นต้นไป ซึ่งพิจารณาจากในรูปที่ 4.1 และ 4.2

## 4.2 การวิเคราะห์ข้อมูลเบื้องต้น

### 4.2.1 ผลการทดสอบข้อมูลเพื่อพิจารณาการแจกแจงปกติ

การทดสอบแอนเดอร์สัน-ดาร์ลิ่ง มักจะถูกนำมาใช้เป็นขั้นตอนก่อนการหาแนวโน้ม และอิทธิพลฤดูกาลเพื่อตรวจสอบความเหมาะสมในการใช้ข้อมูลในการวิเคราะห์ และการตัดสินใจในงานที่เกี่ยวข้องกับชุดเวลา เพื่อทดสอบการแจกแจงปกติข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

1. การทดสอบการแจกแจงปกติของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยใช้วิธีการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง มีสมมติฐานการทดสอบ ดังนี้


$H_0$ : ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) มีการแจกแจงปกติ

$H_1$ : ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ไม่มีการแจกแจงปกติ

จากผลลัพธ์ที่ได้จากการแอนเดอร์สัน-ดาร์ลิ่งสำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ได้ผลลัพธ์ดังนี้

ค่าสถิติการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง = 2.992 และ p-value = 1.32e-07

จากผลลัพธ์ที่ได้ ค่า p-value ที่ได้เป็น 1.32e-07 ซึ่งมีค่าน้อยกว่าระดับความเชื่อมั่นที่ตั้งไว้ที่ 0.05 แสดงว่าสามารถปฏิเสธสมมติฐาน  $H_0$ : ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) มีการแจกแจงปกติ กล่าวคือข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ไม่มีการแจกแจงปกติ ดังรูปที่ 4.3



**รูปที่ 4.3** การทดสอบการแจกแจงปกติของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยใช้วิธีการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง

2. การทดสอบการแจกแจงปกติของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยใช้วิธีการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง มีสมมติฐานการทดสอบ ดังนี้


$H_0$ : ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีการแจกแจงปกติ

$H_1$ : ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ไม่มีการแจกแจงปกติ

จากผลลัพธ์ที่ได้จากการทดสอบแอนเดอร์สัน-ดาร์ลิ่งสำหรับข้อมูล BEVs ได้ผลลัพธ์ดังนี้  
ค่าสถิติการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง = 8.0067 และ p-value < 2.2e-16

จากผลลัพธ์ที่ได้ ค่า p-value ที่ได้มีค่าน้อยกว่า 2.2e-16 ซึ่งมีค่าน้อยกว่าระดับความเชื่อมั่นที่ตั้งไว้ที่ 0.05 แสดงว่าสามารถปฏิเสธสมมติฐาน  $H_0$ : ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีการแจกแจงปกติ กล่าวคือข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ไม่มีการแจกแจงปกติ ดังรูปที่ 4.4

QQ Plot for BEVs by Anderson-Darling Test



รูปที่ 4.4 การทดสอบการแจกแจงปกติของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้า  
แบตเตอรี่ (BEVs) โดยใช้วิธีการทดสอบแอนเดอร์สัน-ดาร์ลิ่ง

สรุปได้ว่าข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และข้อมูล  
จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ไม่มีการแจกแจงปกติจึงใช้การทดสอบอิทธิพล  
แนวโน้มแบบไม่ใช้พารามิเตอร์

#### 4.2.2 ผลการทดสอบแนวโน้มแบบไม่ใช้พารามิเตอร์

การทดสอบแมน-เคนดัลล์ (Mann-Kendall test) เป็นเทคนิคทางสถิติที่ใช้ในการวิเคราะห์  
แนวโน้ม และการเปลี่ยนแปลงของข้อมูลตามเวลา โดยเฉพาะอย่างยิ่งในกรณีที่ไม่มีการใช้พารามิเตอร์  
ใดๆ ในการกำหนดรูปแบบของข้อมูล กรณีที่มีข้อมูลรายเดือนที่เก็บรวบรวมมา 5 ปี และต้องการ  
วิเคราะห์แนวโน้มของข้อมูลนั้น การใช้การทดสอบแมน-เคนดัลล์เป็นทางเลือกที่เหมาะสม เนื่องจาก  
สามารถตรวจสอบการเปลี่ยนแปลงทางสถิติของข้อมูลในช่วงเวลาโดยไม่ต้องมีการกำหนดโครงสร้าง  
ของแบบพยากรณ์ ซึ่งเหมาะสำหรับข้อมูลที่มีลักษณะที่ค่อนข้างซับซ้อน หรือมีความผันผวนในการ  
เปลี่ยนแปลงของค่าในช่วงเวลาที่กำหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. การทดสอบแนวโน้มโดยวิธีทดสอบแมน-เคนดัลล์ของรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) มีสมมติฐานการทดสอบ ดังนี้

$H_0$  : ข้อมูลไม่มีแนวโน้มเข้ามาเกี่ยวข้อง (ค่า tau เท่ากับ 0)

$H_1$  : ข้อมูลมีแนวโน้มเข้ามาเกี่ยวข้อง (ค่า tau ไม่เท่ากับ 0)

จากผลลัพธ์ที่ได้จากการทดสอบด้วยวิธีสถิติแมน-เคนดัลล์ สำหรับข้อมูล HEVs และ PHEVs ได้ผลลัพธ์ดังนี้

ค่าสถิติการทดสอบแมน-เคนดัลล์ (ค่า tau) = 0.6572478 และ p-value = 1.192e-13

ผลลัพธ์ที่ได้จากการทดสอบด้วยวิธีสถิติแมน-เคนดัลล์ ค่าแมน-เคนดัลล์ (ค่า tau) ที่ได้คือ 0.6572478 ซึ่งเป็นค่าที่บวก และแสดงถึงความสัมพันธ์ระหว่างการจัดลำดับของข้อมูลตามเวลาที่มีแนวโน้มเพิ่มขึ้น และ ค่า p-value (1.192e-13) ที่ได้มีค่าน้อยกว่าระดับความเชื่อมั่นที่กำหนด (0.05) แสดงว่าสามารถปฏิเสธสมมติฐาน  $H_0$  : ข้อมูลไม่มีแนวโน้มเข้ามาเกี่ยวข้อง (ค่า tau เท่ากับ 0) กล่าวคือข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) มีแนวโน้มเข้ามาเกี่ยวข้อง

2. การทดสอบแนวโน้มโดยวิธีทดสอบแมน-เคนดัลล์ของรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีสมมติฐานการทดสอบ ดังนี้

$H_0$  : ข้อมูลไม่มีแนวโน้มเข้ามาเกี่ยวข้อง (ค่า tau เท่ากับ 0)

$H_1$  : ข้อมูลมีแนวโน้มเข้ามาเกี่ยวข้อง (ค่า tau ไม่เท่ากับ 0)

จากผลลัพธ์ที่ได้จากการทดสอบด้วยวิธีสถิติแมน-เคนดัลล์ สำหรับข้อมูล BEVs ได้ผลลัพธ์ดังนี้

ค่าสถิติการทดสอบแมน-เคนดัลล์ (ค่า tau) = 0.7295004 และ p-value = 2.408e-16

ผลลัพธ์ที่ได้จากการทดสอบด้วยวิธีสถิติแมน-เคนดัลล์ ค่าแมน-เคนดัลล์ (ค่า tau) ที่ได้คือ 0.7295004 ซึ่งเป็นค่าที่บวก และแสดงถึงความสัมพันธ์ระหว่างการจัดลำดับของข้อมูลตามเวลาที่มีแนวโน้มเพิ่มขึ้น และ ค่า p-value (2.408e-16) ที่ได้มีค่าน้อยกว่าระดับความเชื่อมั่นที่กำหนด (0.05) แสดงว่าสามารถปฏิเสธสมมติฐาน  $H_0$  : ข้อมูลไม่มีแนวโน้มเข้ามาเกี่ยวข้อง (ค่า tau เท่ากับ 0) กล่าวคือข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีแนวโน้มเข้ามาเกี่ยวข้อง

สรุปได้ว่าข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีแนวโน้มเข้ามาเกี่ยวข้อง

#### 4.2.3 ผลการทดสอบอิทธิพลฤดูกาลแบบไม่ใช้พารามิเตอร์

การทดสอบอิทธิพลของฤดูกาลโดยวิธีครัสคัล-วอลลิส (Kruskal-Wallis test) เป็นเทคนิคทางสถิติที่ใช้ในการวิเคราะห์ความแตกต่างของตัวอย่างหนึ่ง หรือมากกว่าที่เกิดจากกลุ่ม โดยเฉพาะอย่างยิ่งเมื่อข้อมูลมีฤดูกาล และไม่มีการใช้พารามิเตอร์ในการกำหนดลำดับหรือระดับของข้อมูล โดยข้อมูลเอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปเผยแพร่หรือใช้โดยไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่เก็บรวบรวมรายเดือนเป็นเวลา 5 ปี และต้องการทดสอบอิทธิพลของฤดูกาล การใช้คริสต์-วอลลิส เป็นทางเลือกที่เหมาะสม เนื่องจากมันสามารถทำการทดสอบความแตกต่างของกลุ่มข้อมูลที่เกิดขึ้นในช่วงฤดูกาลได้ โดยไม่ต้องกำหนดระดับความสำคัญในข้อมูล

1. การทดสอบอิทธิพลแนวโน้มโดยวิธีทดสอบแมน-เคนดัลล์ของรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) มีสมมติฐานการทดสอบ ดังนี้

$H_0$  : ข้อมูลไม่มีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

$H_1$  : ข้อมูลมีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

จากผลลัพธ์ที่ได้จากการทดสอบแบบคริสต์-วอลลิสสำหรับจำนวนจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ได้ผลลัพธ์ดังนี้

ค่าสถิติการทดสอบคริสต์-วอลลิส = 34.104 และ p-value = 3.931e-08 โดยมีค่า ดังนี้

$$H = [12 / (3*2)] * [197.3333 - 3*4] = 370.6666$$

โดยที่

$$H = 34.104 \text{ (ค่าทดสอบคริสต์-วอลลิส)}$$

$$n = 3 \text{ (จำนวนฤดูกาล)}$$

$$\sum_{i=1}^L \frac{R_i^2}{n_i} = 197.3333$$

ผลลัพธ์ที่ได้จากการทดสอบ สรุปได้ว่ามีความแตกต่างทางสถิติที่มีความน่าสนใจระหว่างฤดูกาลในการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยที่ค่า H ที่ได้เท่ากับ 370.6666 และ ค่า p-value (1.192e-13) ที่ได้มีค่าน้อยกว่าระดับความเชื่อมั่นที่กำหนด (0.05) แสดงว่าสามารถปฏิเสธสมมติฐาน  $H_0$  : ข้อมูลไม่มีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง กล่าวคือข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ข้อมูลมีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

2. การทดสอบอิทธิพลแนวโน้มโดยวิธีทดสอบแมน-เคนดัลล์ของรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีสมมติฐานการทดสอบ ดังนี้

$H_0$  : ข้อมูลไม่มีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

$H_1$  : ข้อมูลมีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

จากผลลัพธ์ที่ได้จากการทดสอบคริสต์-วอลลิสสำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ได้ผลลัพธ์ดังนี้

ค่าสถิติการทดสอบคริสต์-วอลลิส = 47.158 และ p-value = 5.751e-11 โดยมีค่า ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$H = [12 / (3*2)] * [47.158 - 3*4] = 70.316$$

โดยที่

$$H = 70.316 \text{ (ค่าทดสอบครัสคัล-วอลลิส)}$$

$$n = 3 \text{ (จำนวนฤดูกาล)}$$

$$\sum_{i=1}^L \frac{R_i^2}{n_i} = 47.158$$

ผลลัพธ์ที่ได้จากการทดสอบ สรุปได้ว่ามีความแตกต่างทางสถิติที่มีความน่าสนใจระหว่างฤดูกาลในการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยที่ค่า H ที่ได้เท่ากับ 70.316 และค่า p-value ( $5.751e-11$ ) ที่ได้มีค่าน้อยกว่าระดับความเชื่อมั่นที่กำหนด (0.05) แสดงว่าสามารถปฏิเสธสมมติฐาน  $H_0$ : ข้อมูลไม่มีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง กล่าวคือข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ข้อมูลมีอิทธิพลของฤดูกาลเข้ามาเกี่ยวข้อง

จากผลการทดสอบอิทธิพลแนวโน้ม และอิทธิพลฤดูกาลแบบไม่ใช้พารามิเตอร์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) พบว่า ข้อมูลทั้ง 2 ชุดมีอิทธิพลแนวโน้ม และอิทธิพลฤดูกาลเกี่ยวข้อง จึงเหมาะสมแก่การพยากรณ์ด้วยวิธีอนุกรมเวลาหลากหลายประเภท โดยในงานวิจัยนี้ ผู้วิจัยเลือกพยากรณ์ด้วยวิธีแยกส่วนประกอบ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์ และวิธีซัพพอร์ตเวกเตอร์แมชชีน

หลังจากทำการตรวจสอบความแจ่มแจ้งปรกติ ตรวจสอบแนวโน้ม และอิทธิพลฤดูกาลของข้อมูลรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ขั้นตอนสร้างตัวแบบพยากรณ์ที่เหมาะสม และขั้นตอนการเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์ แบ่งออกเป็น 2 ส่วน ได้แก่ ส่วนแรกเป็นการพยากรณ์ตัวแบบที่เหมาะสมของแบบพยากรณ์สำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าประเภทรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และเปรียบเทียบประสิทธิภาพตัวแบบพยากรณ์ ในส่วนที่ 2 เป็นการพยากรณ์ตัวแบบที่เหมาะสมของแบบพยากรณ์สำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าประเภทรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) และเปรียบเทียบประสิทธิภาพตัวแบบพยากรณ์

#### 4.3 สร้างตัวแบบพยากรณ์ที่เหมาะสมประเภทรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)


##### 4.3.1 ตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบ

การใช้วิธีแยกส่วนประกอบด้วยวิธีแยกส่วนประกอบโลเอส (Loess) แบบบวก และแบบคูณ ช่วยในการแยกส่วนประกอบที่เกี่ยวข้องกับฤดูกาลออกจากโมเดล ซึ่งช่วยให้สามารถพยากรณ์ และตรวจสอบการเปลี่ยนแปลงของจำนวนทะเบียนรถยนต์ไฟฟ้าได้ในแต่ละฤดูกาล โดยทำให้เห็นภาพของแนวโน้ม และลักษณะการเพิ่มขึ้นหรือลดลงของจำนวนทะเบียนรถยนต์ไฟฟ้าในระยะเวลาที่สั้นๆ

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ (Train Data Set) สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2022 ถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบเพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ (Test Data Set) ดังนี้

1. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีแยกส่วนประกอบโลเอสแบบบวก

ผู้วิจัยสร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีแยกส่วนประกอบของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยเลือกวิธี แยกส่วนประกอบด้วยโลเอสแบบบวก ผลการพยากรณ์ มีดังนี้




**รูปที่ 4.5** ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก ของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)

หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีแยกส่วนประกอบด้วยโลเอสแบบบวกที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์การทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีการจดทะเบียน ดังนี้ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**ตารางที่ 4.1** ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน  
การจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีแยกส่วนประกอบ  
ด้วยโลเอสแบบบวก

เดือน	ค่าจริง	ค่าพยากรณ์	ช่วงความเชื่อมั่น (80%)	ช่วงความเชื่อมั่น (95%)
มกราคม	5,057	4,155.979	3,303.562 – 5,008.396	2,831.157 – 5,480.802
กุมภาพันธ์	6,289	4,073.229	3,220.812 – 4,925.646	2,748.407 – 5,398.052
มีนาคม	8,546	4,198.229	3,345.812 – 5,050.646	2,873.407 – 5,523.052
เมษายน	5,519	3,546.479	2,694.062 – 4,398.896	2,221.657 – 4,871.302
พฤษภาคม	6,385	3,736.979	2,884.562 – 4,589.396	2,412.157 – 5,061.802
มิถุนายน	6,639	3,801.729	2,949.312 – 4,654.146	2,476.907 – 5,126.552
กรกฎาคม	5,261	3,389.229	2,536.812 – 4,241.646	2,064.407 – 4,714.052
สิงหาคม	6,728	4,049.979	3,197.562 – 4,902.396	2,725.157 – 5,374.802
กันยายน	7,745	3,909.729	3,057.312 – 4,762.146	2,584.907 – 5,234.552
ตุลาคม	5,887	3,922.979	3,070.562 – 4,775.396	2,598.157 – 5,247.802
พฤศจิกายน	6,006	3,937.229	3,084.812 – 4,789.646	2,612.407 – 5,262.052
ธันวาคม	4,738	3,277.729	2,425.312 – 4,130.146	1,952.907 – 4,602.552
RMSE	2,569.561			
MAPE	37.28%			

จากผลลัพธ์การทำนายในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ในตารางที่ 4.1 ที่ได้แยกส่วนประกอบด้วยวิธีแยกส่วนประกอบโลเอสแบบบวกที่ถูกฝึกสอน พบว่าตัวแบบพยากรณ์ที่ถูกฝึกสอนสามารถทำนายค่าในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ได้ไม่ไกลเคียงกับค่าจริงเท่าที่ควร และในช่วงกลางปีมีแนวโน้มลดลงต่ำสุดเหมือนกันทั้งค่าจริง และค่าพยากรณ์ เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ดังนี้



รูปที่ 4.6 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022

ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก

โดยมีสมการค่าพยากรณ์ ดังนี้

$$\hat{Y}_{t+m} = 1879.147 + 46.466(m) \times \hat{S}_t$$

เมื่อ:

$\hat{Y}_{t+m}$  คือค่าพยากรณ์ในเดือนที่  $t+m$

$L$  คือค่าคงที่ ได้แก่ 1879.147

$b$  คือค่าตัวแปรที่กำหนดตามแนวโน้มในสมการเชิงเส้น ได้แก่ 46.466


$m$  คือระยะเวลาที่ต้องการทำนายล่วงหน้า

$\hat{S}_t$  คือค่าฤดูกาลเฉลี่ยที่ได้จากกระบวนการวิธีแยกส่วนประกอบโลเอสแบบบวก

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 2,569.56 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 37.28%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีแยกส่วนประกอบโลเอสแบบคูณ  
 ผู้วิจัยสร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอน และปรับแต่งตัวแบบพยากรณ์วิธีแยกส่วนประกอบของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยเลือกวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ ผลการพยากรณ์ได้มีดังนี้



รูปที่ 4.7 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ ของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)

จากรูปที่ 4.7 ด้านบนสุด คือข้อมูลเดิมที่ผู้วิจัยต้องการแยกส่วนประกอบ รองลงมาคือแนวโน้มหรือค่าเฉลี่ยเคลื่อนที่ของข้อมูล จะเห็นว่าข้อมูลมีแนวโน้มเพิ่มสูงขึ้นอย่างเห็นได้ชัดในช่วงรอยต่อปี ค.ศ. 2022 รองลงมาคือปัจจัยฤดูกาล หรือรูปแบบซ้ำในชุดข้อมูล ซึ่งแสดงให้เห็นว่าช่วงใกล้สิ้นปีของทุกๆ ปี จะมีฤดูกาลที่สูง ก่อนที่จะเพิ่มตกมาต่ำสุดในช่วงต้นปีของทุกๆ ปี และส่วนสุดท้ายคือผลต่างของข้อมูลเฉพาะที่ไม่สามารถอธิบายได้ โดยใช้แนวโน้มหรือฤดูกาล ส่วนนี้เป็นค่าที่เหลืออยู่หลังจากแยกส่วนประกอบอื่นๆ แล้ว จะเห็นได้ว่ามีค่าบวก และลบสลับกัน

หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีแยกส่วนประกอบด้วยโลเอสแบบคูณที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีการจดทะเบียน ดังนี้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**ตารางที่ 4.2** ข้อมูลจริง ค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน

การจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีแยกส่วนประกอบ  
ด้วยโลเอสแบบคุณ

เดือน	ค่าจริง	ค่าพยากรณ์	ช่วงความเชื่อมั่น (80%)	ช่วงความเชื่อมั่น (95%)
มกราคม	5,057	5,543.5	4,566.268 – 6,520.732	4,013.0301 – 7,073.97
กุมภาพันธ์	6,289	5,144.0	4,166.768 – 6,121.232	3,613.5301 – 6,674.47
มีนาคม	8,546	5,234.0	4,256.768 – 6,211.232	3,703.5301 – 6,764.47
เมษายน	5,519	3,413.0	2,435.768 – 4,390.232	1,882.5301 – 4,943.47
พฤษภาคม	6,385	3,507.0	2,529.768 – 4,484.232	1,976.5301 – 5,037.47
มิถุนายน	6,639	3,114.5	2,137.268 – 4,091.732	1,584.0301 – 4,644.97
กรกฎาคม	5,261	1,987.5	1,010.268 – 2,964.732	457.0301 – 3,517.97
สิงหาคม	6,728	3,674.5	2,697.268 – 4,651.732	2,144.0301 – 5,204.97
กันยายน	7,745	3,495.5	2,518.268 – 4,472.732	1,965.0301 – 5,025.97
ตุลาคม	5,887	3,511.0	2,533.768 – 4,488.232	1,980.5301 – 5,041.47
พฤศจิกายน	6,006	4,097.0	3,119.768 – 5,074.232	2,566.5301 – 5,627.47
ธันวาคม	4,738	3,278.0	2,300.768 – 4,255.232	1,747.5301 – 4,808.47
RMSE	2,695.31			
MAPE	39.02%			

จากผลลัพธ์การทำนายในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ที่ได้แยกส่วนประกอบด้วยวิธีแยกส่วนประกอบโลเอสแบบคุณที่ถูกฝึกสอน พบว่าตัวแบบพยากรณ์ที่ถูกฝึกสอนสามารถทำนายค่าในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ได้ไม่ไกลเกินไปกับค่าจริงเท่าที่ควร แต่ในช่วงกลางปีมีแนวโน้มลดลงต่ำสุดเหมือนกันทั้งค่าจริง และค่าพยากรณ์ เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 และค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้



รูปที่ 4.8 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ

โดยมีสมการค่าพยากรณ์ ดังนี้

$$\hat{Y}_{t+m} = [1000.38 + 92.72(m)] \times \hat{S}_t$$

เมื่อ:

$\hat{Y}_{t+m}$  คือค่าพยากรณ์ในเดือนที่  $t + m$

$L$  คือค่าคงที่ ได้แก่ 1000.38

$b$  คือค่าตัวแปรที่กำหนดตามแนวโน้มในสมการเชิงเส้น ได้แก่ 92.72

$m$  คือระยะเวลาที่ต้องการทำนายล่วงหน้า

$\hat{S}_t$  คือค่าฤดูกาลเฉลี่ยที่ได้จากกระบวนการวิธีแยกส่วนประกอบโลเอสแบบคูณ

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้ค่ารากที่สองของความคลาดเคลื่อนนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 2,695.311 และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 39.02%

#### 4.3.2 ตัวแบบพยากรณ์ด้วยวิธีปรับเรียบแบบโฮลต์-วินเทอร์


วิธีปรับเรียบแบบโฮลต์-วินเทอร์เป็นวิธีการสร้างโมเดลทำนายเพื่อวิเคราะห์ และทำนายแนวโน้มของข้อมูลที่มีแนวโน้มเปลี่ยนแปลงไปตามฤดูกาล ซึ่งวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคุณ สามารถจับตามแนวโน้มของข้อมูลได้ดีกว่าวิธีอื่นๆ เนื่องจากสามารถปรับข้อมูลตามพื้นฐานที่มีอยู่ในแต่ละช่วงของเวลา และฤดูกาล ทำให้สามารถคาดการณ์เหตุการณ์ในอนาคตได้มีความแม่นยำมากขึ้น สามารถใช้ข้อมูลที่เกิดขึ้นในอดีตเพื่อทำนายในอนาคตในช่วงเวลาที่ยาวนานกว่าวิธีอื่นๆ อีกทั้งยังให้ความสำคัญในการคาดการณ์ข้อมูลขึ้นอยู่กับฤดูกาล ทำให้สามารถปรับปรุง และปรับค่าพารามิเตอร์ของโมเดลให้เหมาะสมกับฤดูกาลที่มีอยู่ในข้อมูล รวมถึงข้อมูลที่มีแนวโน้มแต่อิทธิพลฤดูกาลมักมีการเปลี่ยนแปลงที่ไม่คงที่ การใช้วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคุณสามารถช่วยในการจัดการกับความเปลี่ยนแปลงเหล่านี้ได้ในวิธีที่มีประสิทธิภาพ

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ (Train Data Set) สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2022 ถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบเพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ (Test Data Set) ดังนี้

1. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีปรับเรียบแบบโฮลต์-วินเทอร์แบบคุณของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)

ผู้วิจัยสร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอน และปรับแต่งโมเดลของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยเลือกวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคุณ ได้ผลการพยากรณ์ ดังนี้

Comparing training data and estimated values: HEVs &amp; PHEVs



รูปที่ 4.9 กราฟแสดงการเปรียบเทียบระหว่างข้อมูลฝึกสอน และค่าประมาณที่ได้จากการพยากรณ์

จากรูปที่ 4.9 เป็นกราฟแสดงการเปรียบเทียบระหว่างข้อมูลฝึกสอน และค่าประมาณที่ได้จากตัวแบบพยากรณ์ ซึ่งประกอบไปด้วยส่วนของระดับฐาน และส่วนของฤดูกาล ซึ่งสามารถช่วยในการวิเคราะห์ และตรวจสอบความสอดคล้องของโมเดลกับข้อมูลจริงได้ จะเห็นได้ว่าค่าประมาณที่ได้จากโมเดล (เส้นสีแดง) มีค่าใกล้เคียงกับข้อมูลฝึกสอน (เส้นสีดำ) โดยได้สมการจากชุดข้อมูลฝึกสอน และปรับแต่งพารามิเตอร์ และค่าเชิงพหุนาม ด้วยคำสั่ง `hw_model` ดังนี้

ค่าปรับแต่งพารามิเตอร์:

อัลฟา (Alpha) = 0.8858259 คือค่าที่ใช้ในการควบคุมระดับ (Level)

เบต้า (Beta) = 0 คือค่าที่ใช้ในการควบคุมการเปลี่ยนแปลง (Trend)

แกมมา (Gamma) = 1 คือค่าที่ใช้ในการควบคุมฤดูกาล (Seasonality)

ค่าเชิงพหุนาม (Coefficients):

ค่าสัมประสิทธิ์ในการปรับรูปแบบของระดับ (Level) = 4,653.5200387

การเปลี่ยนแปลง (Trend) = 37.1879371

$S_1 - S_{12}$  แทนค่าสัมประสิทธิ์ในการปรับรูปแบบของฤดูกาลสำหรับแต่ละช่วงเวลาในปี

$S_1 = 1.2107559, S_2 = 1.1129156, S_3 = 1.1054045,$

$S_4 = 0.8780882, S_5 = 1.0039433, S_6 = 1.0396233,$

$S_7 = 1.0364902, S_8 = 1.2454225, S_9 = 1.0111362,$

$S_{10} = 0.9049768, S_{11} = 0.8404643, S_{12} = 0.5941739$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีการจดทะเบียน ดังนี้

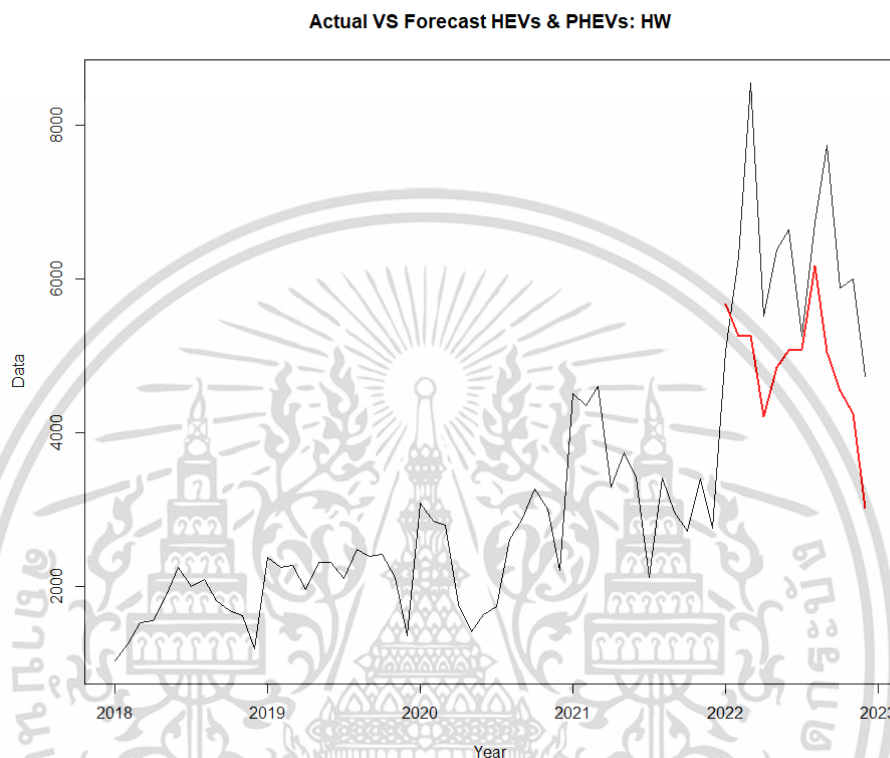
**ตารางที่ 4.3** ข้อมูลจริงปี และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ

เดือน	ค่าจริง	ค่าพยากรณ์	ช่วงความเชื่อมั่น (80%)	ช่วงความเชื่อมั่น (95%)
มกราคม	5,057	5,679.302	5,052.609 – 6,305.996	4,720.857 – 6,637.747
กุมภาพันธ์	6,289	5,261.749	4,453.583 – 6,069.914	4,025.767 – 6,497.731
มีนาคม	8,546	5,267.345	4,290.787 – 6,243.903	3,773.829 – 6,760.861
เมษายน	5,519	4,216.818	3,246.687 – 5,186.949	2,733.131 – 5,700.505
พฤษภาคม	6,385	4,858.543	3,628.714 – 6,088.373	2,977.681 – 6,739.405
มิถุนายน	6,639	5,069.877	3,682.807 – 6,456.946	2,948.537 – 7,191.216
กรกฎาคม	5,261	5,093.143	3,602.816 – 6,583.470	2,813.884 – 7,372.401
สิงหาคม	6,728	6,166.116	4,301.334 – 8,030.898	3,314.178 – 9,018.053
กันยายน	7,745	5,043.761	3,422.296 – 6,665.226	2,563.944 – 7,523.578
ตุลาคม	5,887	4,547.870	2,988.682 – 6,107.058	2,163.298 – 6,932.442
พฤศจิกายน	6,006	4,254.924	2,700.374 – 5,809.474	1,877.445 – 6,632.403
ธันวาคม	4,738	3,030.153	1,950.503 – 4,109.803	1,378.971 – 4,681.336
RMSE	1,685.64			
MAPE	22.70%			

จากตารางที่ 4.3 ภาพรวมของผลลัพธ์คือในทุกเดือนของปี ค.ศ. 2022 ค่าทำนายอยู่ในช่วงความเชื่อมั่น 80% และ 95% โดยทั่วไปแล้ว ค่าทำนายอยู่ในช่วงกลางของช่วงความเชื่อมั่น 80% และมีค่าต่ำลงในช่วงความเชื่อมั่น 95% นอกเหนือจากเดือนสิงหาคมที่มีค่าทำนายสูงสุด ดังนั้นเดือนสิงหาคมมีความเชื่อมั่นที่สูงสุดในการทำนายข้อมูลในปี ค.ศ. 2022 โดยภาพรวมจะเห็นได้ว่าค่าพยากรณ์มีค่าค่อนข้างต่ำกว่าค่าจริง และมีเดือนมกราคมที่มีการพยากรณ์สูงกว่าค่าจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผู้วิจัยทำเปรียบเทียบข้อมูลจริง ค.ศ. 2022 กับข้อมูลทำนายในชุดข้อมูลทดสอบโดยใช้วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ โดยพบว่าค่าพยากรณ์มีค่าที่ต่ำกว่าค่าจริง แต่ไม่มากเท่าวิธีแยกส่วนประกอบ ทั้งนี้ลักษณะกราฟเป็นไปในทิศทางเดียวกันกับค่าจริง เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ซึ่งได้ผลการพยากรณ์ ดังนี้



**รูปที่ 4.10** ผลการวิเคราะห์ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs) โดยวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 1,685.64 และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 22.70%

### 4.3.3 ผลการวิเคราะห์ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน

ผู้วิจัยเลือกใช้การพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอย (Support Vector Regression) โดยเลือกใช้ Radial Basis Kernel ประเภท EPS-Regression และ NU-Regression เนื่องจากมีความเหมาะสมดังนี้

1. ฟังก์ชัน Radial Basis Kernel เป็นเคอร์เนลฟังก์ชันที่มีความยืดหยุ่นสูง ทำให้สามารถจับคู่แนวโน้มของข้อมูลซับซ้อนที่มีรูปแบบไม่แน่นอน และมีการเปลี่ยนแปลงตามฤดูกาลได้ดี ซึ่งเหมาะสมสำหรับข้อมูลอนุกรมเวลาที่มีความซับซ้อน และอิทธิพลฤดูกาลในการพยากรณ์ ความยืดหยุ่นของ Radial Basis Kernel ช่วยให้โมเดลสามารถปรับแต่งตัวอย่างในพื้นที่ซับซ้อนของข้อมูลได้ดีขึ้น

2. ข้อมูลอนุกรมเวลาที่เปลี่ยนแปลงตามฤดูกาลอาจไม่สามารถใช้เส้นตรงในการจับคู่แนวโน้มได้ การใช้ Radial Basis Kernel ในตัวแบบพยากรณ์ซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอย (Support Vector Regression) ช่วยให้สามารถจับคู่แนวโน้มของข้อมูลที่ไม่เป็นเชิงเส้นได้

3. การใช้ NU-Regression ใน Radial Basis Kernel ช่วยให้สามารถควบคุมค่าคลาดเคลื่อนในการพยากรณ์ได้เป็นอย่างดี การควบคุมค่าคลาดเคลื่อนนี้เป็นประโยชน์ในการปรับแต่งตัวอย่างในเหตุการณ์ที่ความแตกต่างของข้อมูลภายในเส้น ระหว่างเส้นใน และเส้นนอก ในกรณีของข้อมูลที่มีการเปลี่ยนแปลงตามฤดูกาล อาจต้องการควบคุมค่าคลาดเคลื่อนในเวลาที่แตกต่างกันได้ ซึ่ง NU-Regression ช่วยให้สามารถปรับค่าความยืดหยุ่นในการจับคู่ข้อมูลได้ทำให้มีความแม่นยำ น่าเชื่อถือในการพยากรณ์ข้อมูลอนุกรมเวลาของจำนวนจดทะเบียนรถยนต์ไฟฟ้าในที่มีแนวโน้ม และอิทธิพลฤดูกาล

วิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยใช้กำลังของเคอร์เนลฟังก์ชัน (Kernel Function) ในการแบ่งแยกข้อมูล ซึ่ง Radial Basis Kernel เป็นหนึ่งในเคอร์เนลฟังก์ชันที่นิยมใช้เมื่อมีข้อมูลที่ซับซ้อน การใช้ซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยสามารถให้ผลลัพธ์ที่แม่นยำและเหมาะสมกับข้อมูลที่มีแนวโน้มเปลี่ยนแปลงได้ อีกทั้งซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยสามารถจัดการกับข้อมูลที่มีความซับซ้อน และไม่เชิงเส้นได้ดี เช่น แบบจำลองที่ใช้ Radial Basis Kernel สามารถจับคู่ความสัมพันธ์ระหว่างข้อมูล และตัวแปรตามได้ดีทั้งในกรณีข้อมูลที่มีความเป็นเส้นตรงและข้อมูลที่มีความซับซ้อน อีกทั้งยังสามารถปรับค่าความยืดหยุ่น (Epsilon และ NU) และการกำหนดค่าฟังก์ชันสนับสนุน (C) เพื่อให้สอดคล้องกับความสำคัญของข้อมูล โดย 2 ฟังก์ชันนี้ มีลักษณะดังนี้

EPS-Regression เป็นรูปแบบของซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยที่ใช้ค่าพารามิเตอร์เอปซิลอนเพื่อกำหนดช่วงที่อยู่ภายใน และภายนอกของเส้นระหว่างข้อมูลตัวอย่าง และตัวแปรตาม โดยเอปซิลอนหมายถึงความคลาดเคลื่อนที่ยอมรับได้ภายในช่วงเส้นระหว่างเส้นใน และเส้นนอก รูปแบบนี้ให้ความยืดหยุ่นและอนุญาตให้ข้อมูลที่อยู่ภายในช่วงเส้นใน และเส้นนอกถูก

ยอมรับในการพยากรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

NU-Regression เป็นรูปแบบของซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยที่ใช้ค่าพารามิเตอร์ NU-Regression เพื่อกำหนดการควบคุมความคลาดเคลื่อนในข้อมูลตัวอย่าง และตัวแปรตาม ค่า เอ็นยูอยู่ในช่วง 0-1 โดยหมายถึงขีดจำกัดของข้อมูลที่ต้องอยู่ภายในขอบเขตช่วงเส้นระหว่างเส้นใน และเส้นนอก รูปแบบนี้ให้ความยืดหยุ่นต่ำกว่า EPS-Regression และมีการควบคุมค่าคลาดเคลื่อนในการพยากรณ์ที่เข้มงวดมากขึ้น (Smola. et al., 2004)

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ (Train Data Set) สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2022 ถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบเพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ (Test Data Set) ดังนี้

1. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยของรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)

ผลการสร้างตัวแบบพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอย (Support Vector Regression: SVR) ด้วย Radial Basis Kernel ประเภท EPS-Regression และ NU-Regression ได้รับการปรับแต่งพารามิเตอร์โดยคำสั่ง param\_ranges เพื่อเลือกค่าพารามิเตอร์ที่ดีที่สุดจากค่าอัลกอริทึม และพารามิเตอร์ที่กำหนดไว้ ดังนี้

ค่าอัลกอริทึม NU และ EPS มีค่าทดลองที่ 0.1 0.2 0.3 และ 0.4

พารามิเตอร์ Cost มีค่าทดลองที่ 1 10 100 และ 1000

พารามิเตอร์ Gamma มีค่าทดลองที่ 0.1 0.01 และ 0.001

โดยได้ค่าพารามิเตอร์ที่ดีที่สุด ของ EPS-Regression และ NU-Regression มีดังนี้


ประเภทที่ 1 EPS-Regression:

พารามิเตอร์ที่ดีที่สุดคือ Epsilon = 0.2 Cost = 1000 Gamma = 0.1


ประเภทที่ 2 NU-Regression :

พารามิเตอร์ที่ดีที่สุดคือ NU = 0.4 Cost = 1000 Gamma = 0.1

ผู้วิจัยทำการแสดงผลการพยากรณ์ด้วยตัวแบบประเภทที่ 1 และประเภทที่ 2 ตามพารามิเตอร์ที่มีการปรับแต่งข้างต้น ได้ผลการพยากรณ์ชุดข้อมูลฝึกฝน ดังต่อไปนี้



รูปที่ 4.11 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท EPS-Regression



รูปที่ 4.12 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression

จากรูปที่ 4.11 และ 4.12 จะเห็นว่าข้อมูลฝึกฝน (เส้นสีแดง) ด้วยประเภท EPS-Regression มีค่าที่ไม่ใกล้เคียงค่าจริง (เส้นสีดำ) เมื่อเทียบกับข้อมูลฝึกฝนด้วยประเภท NU-Regression และ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เส้นกราฟของข้อมูลฝึกฝนด้วยประเภท NU-Regression ทับเส้นกราฟค่าจริงเกือบทั้งหมด มีช่วงต้นปี ค.ศ. 2021 ที่เส้นกราฟค่าพยากรณ์ต่ำกว่าจนเห็นเส้นกราฟสีแดงที่ไม่ได้ทับเส้นกราฟค่าจริง


หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ดังนี้

**ตารางที่ 4.4** ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ปี ค.ศ. 2022 โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์


เดือน	ค่าจริง	ค่าพยากรณ์รถยนต์ไฟฟ้าไฮบริด (PHEVs & HEVs)	
		EPS-Regression	NU-Regression
		Cost = 100 EPS = 0.1 Gamma = 0.01	Cost = 100 NU = 0.4 Gamma = 0.01
มกราคม	5057	4898.7504	5003.5865
กุมภาพันธ์	6289	5750.0718	6023.6664
มีนาคม	8546	6467.8860	7268.6925
เมษายน	5519	5251.6027	5408.0549
พฤษภาคม	6385	5803.6607	6094.5731
มิถุนายน	6639	5935.8256	6275.3252
กรกฎาคม	5261	5059.1213	5185.0632
สิงหาคม	6728	5978.7851	6336.2292
กันยายน	7745	6343.3502	6934.7899
ตุลาคม	5887	5504.6532	5712.2057
พฤศจิกายน	6006	5580.7732	5806.7713
ธันวาคม	4738	4634.6700	4711.5938
RMSE		838.76	484.79
MAPE		9.11%	4.73%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านอื่นๆ  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.4 จะเห็นได้ว่าค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริงค่อนข้างมากเมื่อเทียบกับค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท EPS-Regression เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 กับค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้



รูปที่ 4.13 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย ด้วย Radial Basis Kernel ประเภท EPS-Regression



รูปที่ 4.14 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย ด้วย Radial Basis Kernel ประเภท NU-Regression

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.13 และ 4.14 จะเห็นได้ว่าค่าพยากรณ์ (เส้นสีแดง) ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริง (เส้นสีดำ) ค่อนข้างมากกว่าเมื่อเทียบกับค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท EPS-Regression

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้

ประเภทที่ 1 EPS-Regression ค่า RMSE = 838.7658 และ ค่า MAPE = 9.11%

ประเภทที่ 2 NU-Regression ค่า RMSE = 484.79 และ ค่า MAPE = 4.73%

#### 4.4 เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) จากข้อมูลชุดทดสอบ

ผลการเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ของตัวแบบพยากรณ์วิธีแยกส่วนประกอบแบบบวก และแบบคูณ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ และวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วยฟังก์ชัน EPS-Regression และ NU-Regression พบว่ามีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 2,569.56 2,695.31 1,685.64 838.76 และ 484.79 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 37.28% 39.02% 22.70% 9.11% และ 4.73% ตามลำดับ จะเห็นว่าวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วยฟังก์ชัน NU-Regression มีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำสุด

**ตารางที่ 4.5** ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ของตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs)

ตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs)	RMSE	MAPE
วิธีแยกส่วนประกอบแบบบวก	2,569.56	37.28%
วิธีแยกส่วนประกอบแบบคูณ	2,695.31	39.02%
วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ	1,685.64	22.70%
วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน (EPS-Regression)	838.76	9.11%
วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน (NU-Regression)	484.79	4.73%

ดังนั้น ตัวแบบพยากรณ์วิธีซัพพอร์ตแมชชีนแบบถดถอย ประเภท NU-Regression เป็นตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.5 สร้างตัวแบบพยากรณ์ที่เหมาะสมประเภทรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

### 4.5.1 ผลการวิเคราะห์ด้วยวิธีแยกส่วนประกอบ

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ (Train Data Set) สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2022 ถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบ เพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ (Test Data Set) ดังนี้

1. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีแยกส่วนประกอบโลเอสแบบบวก

ผู้วิจัยสร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยเลือกวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก ผลการพยากรณ์ มีดังนี้



รูปที่ 4.15 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก ของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

จากรูปที่ 4.15 ด้านบนสุดคือข้อมูลเดิมที่ผู้วิจัยต้องการแยกส่วนประกอบ รองถัดลงมาคือแนวโน้มหรือค่าเฉลี่ยเคลื่อนที่ของข้อมูล จะเห็นได้ว่าข้อมูลมีแนวโน้มเพิ่มสูงขึ้น รองลงมาคือปัจจัยฤดูกาล หรือรูปแบบซ้ำในชุดข้อมูล ซึ่งแสดงให้เห็นว่าช่วงใกล้สิ้นปีของทุกๆ ปี จะมีฤดูกาลที่ต่ำ ก่อนที่จะเพิ่มขึ้นสูงสุดในเดือนถัดไปของทุกๆ ปี และส่วนสุดท้ายคือผลต่างของข้อมูลเฉพาะที่ไม่สามารถเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปเผยแพร่ในเชิงพาณิชย์ การค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อธิบายได้ โดยใช้แนวโน้มหรือฤดูกาล ส่วนนี้เป็นค่าที่เหลืออยู่หลังจากแยกส่วนประกอบอื่นๆ แล้ว จะเห็นได้ว่ามีค่าบวก และลบสลับกันไป


หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีแยกส่วนประกอบด้วยโลเอสแบบบวกที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีการจดทะเบียน ดังนี้

**ตารางที่ 4.6** ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก

เดือน	ค่าจริง	ค่าพยากรณ์	ช่วงความเชื่อมั่น (80%)	ช่วงความเชื่อมั่น (95%)
มกราคม	261	232.2917	149.18461 - 315.3987	103.12709 - 361.4562
กุมภาพันธ์	341	205.7917	122.68461 - 288.8987	76.62709 - 334.9562
มีนาคม	634	199.0417	115.93461 - 282.1487	69.87709 - 328.2062
เมษายน	389	181.2917	98.18461 - 264.3987	52.12709 - 310.4562
พฤษภาคม	509	184.5417	101.43461 - 267.6487	55.37709 - 313.7062
มิถุนายน	872	197.2917	114.18461 - 280.3987	68.12709 - 326.4562
กรกฎาคม	575	173.7917	90.68461 - 256.8987	44.62709 - 302.9562
สิงหาคม	1184	188.0417	104.93461 - 271.1487	58.87709 - 317.2062
กันยายน	1065	215.2917	132.18461 - 298.3987	86.12709 - 344.4562
ตุลาคม	1216	228.7917	145.68461 - 311.8987	99.62709 - 357.9562
พฤศจิกายน	1296	243.0417	159.93461 - 326.1487	113.87709 - 372.2062
ธันวาคม	1242	209.2917	126.18461 - 292.3987	80.12709 - 338.4562
RMSE	697.41			
MAPE	66.08%			

จากผลลัพธ์การทำนายในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ในตารางที่ 4.6 ที่ได้แยกส่วนประกอบด้วยวิธีแยกส่วนประกอบโลเอสแบบบวกกับข้อมูลที่ถูกฝึกสอน พบว่าตัวแบบพยากรณ์ฝึกสอนสามารถทำนายค่าในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ได้ไม่ไกล่เคียงกับค่าจริงเท่าที่ควร และในช่วงกลางปีมีแนวโน้มลดลงต่ำสุดเหมือนกันทั้งค่าจริง และค่าพยากรณ์ เพื่อให้เห็นภาพอย่างชัดเจน

มากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 กับค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้



รูปที่ 4.16 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022

ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบบวก โดยมีสมการค่าพยากรณ์ ดังนี้

$$\hat{Y}_{t+m} = 27.6486 + 4.1764(m) \times \hat{S}_t$$

เมื่อ:

- $\hat{Y}_{t+m}$  คือค่าพยากรณ์ในเดือนที่  $t + m$
- $L$  คือค่าคงที่ ได้แก่ 27.6486
- $b$  คือค่าตัวแปรที่กำหนดตามแนวโน้มในสมการเชิงเส้น ได้แก่ 4.1764
- $m$  คือระยะเวลาที่ต้องการทำนายล่วงหน้า
- $\hat{S}_t$  คือค่าฤดูกาลเฉลี่ยที่ได้จากกระบวนการวิธีแยกส่วนประกอบโลเอสแบบบวก


สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้ค่ารากที่สองของความ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 697.41 และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 66.08%

## 2. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีแยกส่วนประกอบโลเอสแบบคูณ

ผู้วิจัยสร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอน และปรับแต่งตัวแบบพยากรณ์วิธีแยกส่วนประกอบของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยเลือกวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ ผลการพยากรณ์ได้มีดังนี้



รูปที่ 4.17 ผลการฝึกสอน และปรับแต่งตัวแบบพยากรณ์ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ ของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

จากรูปที่ 4.17 ด้านบนสุด คือข้อมูลเดิมที่ผู้วิจัยต้องการแยกส่วนประกอบ ถัดลงมาคือแนวโน้มหรือค่าเฉลี่ยเคลื่อนที่ของข้อมูล จะเห็นว่าข้อมูลมีแนวโน้มเพิ่มสูงขึ้นอย่างเห็นได้ชัดในช่วงรอยต่อปี ค.ศ. 2022 ถัดลงมาคือปัจจัยฤดูกาล หรือรูปแบบซ้ำในชุดข้อมูล ซึ่งแสดงให้เห็นว่าช่วงใกล้สิ้นปีของทุกๆ ปี จะมีฤดูกาลที่สูง ก่อนที่จะเพิ่มตกมาต่ำสุดในช่วงต้นปีของทุกๆ ปี และส่วนสุดท้ายคือผลต่างของข้อมูลเฉพาะที่ไม่สามารถอธิบายได้ โดยใช้แนวโน้มหรือฤดูกาล ส่วนนี้เป็นค่าที่เหลืออยู่หลังจากแยกส่วนประกอบอื่นๆ แล้ว จะเห็นได้ว่ามีค่าบวก และลบสลับกัน


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีแยกส่วนประกอบด้วยโลเอสแบบคูณที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีการจดทะเบียน ดังนี้

**ตารางที่ 4.7** ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ

เดือน	ค่าจริง	ค่าพยากรณ์	ช่วงความเชื่อมั่น (80%)	ช่วงความเชื่อมั่น (95%)
มกราคม	261	287.5	158.580745 - 416.4193	85.596062 - 489.4039
กุมภาพันธ์	341	223.5	94.580745 - 352.4193	21.596062 - 425.4039
มีนาคม	634	232.5	103.580745 - 361.4193	30.596062 - 434.4039
เมษายน	389	171.0	42.080745 - 299.9193	-30.903938 - 372.9039
พฤษภาคม	509	179.5	50.580745 - 308.4193	-22.403938 - 381.4039
มิถุนายน	872	197.5	68.580745 - 326.4193	-4.403938 - 399.4039
กรกฎาคม	575	131.5	2.580745 - 260.4193	-70.403938 - 333.4039
สิงหาคม	1184	189.0	60.080745 - 317.9193	-12.903938 - 390.9039
กันยายน	1065	284.5	155.580745 - 413.4193	82.596062 - 486.4039
ตุลาคม	1216	192.0	63.080745 - 320.9193	-9.903938 - 393.9039
พฤศจิกายน	1296	204.0	75.080745 - 332.9193	2.096062 - 405.9039
ธันวาคม	1242	166.0	37.080745 - 294.9193	-35.903938 - 367.9039
RMSE	706.01			
MAPE	66.30%			

จากผลลัพธ์การทำนายในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ที่ได้แยกส่วนประกอบด้วยวิธีแยกส่วนประกอบโลเอสแบบคูณที่ถูกฝึกสอน พบว่าตัวแบบพยากรณ์ที่ถูกฝึกสอนสามารถทำนายค่าในชุดข้อมูลทดสอบในปี ค.ศ. 2022 ได้ไม่ไกลเคียงกับค่าจริงเท่าที่ควร แต่ในช่วงกลางปีมีแนวโน้มลดลงต่ำสุดเหมือนกันทั้งค่าจริง และค่าพยากรณ์ เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 และค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้



รูปที่ 4.18 การเปรียบเทียบข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ด้วยวิธีแยกส่วนประกอบด้วยโลเอสแบบคูณ

โดยมีสมการค่าพยากรณ์ ดังนี้

$$\hat{Y}_{t+m} = [-7.3167 + 6.0167(m)] \times \hat{S}_t$$

เมื่อ:

$\hat{Y}_{t+m}$  คือค่าพยากรณ์ในเดือนที่  $t+m$

$L$  คือค่าคงที่ ได้แก่ -7.3167

$b$  คือค่าตัวแปรที่กำหนดตามแนวโน้มในสมการเชิงเส้น ได้แก่ 6.0167

$m$  คือระยะเวลาที่ต้องการทำนายล่วงหน้า

$\hat{S}_t$  คือค่าฤดูกาลเฉลี่ยที่ได้จากกระบวนการวิธีแยกส่วนประกอบโลเอสแบบคูณ

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 706.01 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 66.30%


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4.5.2 ผลการวิเคราะห์ด้วยวิธีปรับเรียบแบบโฮลต์-วินเทอร์

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ (Train Data Set) สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2022 ถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบเพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ (Test Data Set) ดังนี้

1. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีปรับเรียบแบบโฮลต์-วินเทอร์แบบคุณของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)

ผู้วิจัยสร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอน และปรับแต่งโมเดลของชุดข้อมูลการฝึกจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยเลือกวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคุณ ได้ผลการพยากรณ์ ดังนี้



รูปที่ 4.19 กราฟแสดงการเปรียบเทียบระหว่างข้อมูลฝึกสอน และค่าประมาณที่ได้จากการพยากรณ์

จากรูปที่ 4.19 เป็นกราฟแสดงการเปรียบเทียบระหว่างข้อมูลฝึกสอน และค่าประมาณที่ได้จากตัวแบบพยากรณ์ ซึ่งประกอบไปด้วยส่วนของระดับฐาน และส่วนของฤดูกาล ซึ่งสามารถช่วยในการวิเคราะห์ และตรวจสอบความสอดคล้องของโมเดลกับข้อมูลจริงได้ จะเห็นได้ว่าค่าประมาณที่ได้จากโมเดล (เส้นสีแดง) มีค่าใกล้เคียงกับข้อมูลฝึกสอน (เส้นสีดำ) โดยได้สมการจากการฝึกสอน และปรับแต่งพารามิเตอร์ และค่าเชิงพหุนาม ดังนี้

ค่าปรับแต่งพารามิเตอร์:

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัลฟา (Alpha) = 0 คือค่าที่ใช้ในการควบคุมระดับ (Level)

เบต้า (Beta) = 0 คือค่าที่ใช้ในการควบคุมการเปลี่ยนแปลง (Trend)

แกมมา (Gamma) = 0.08 คือค่าที่ใช้ในการควบคุมฤดูกาล (Seasonality)

ค่าเชิงพหุนาม (Coefficients):

ค่าสัมประสิทธิ์ในการปรับรูปแบบของระดับ (Level) = 145.2195027

การเปลี่ยนแปลง (Trend) = 4.4577506

$S_1 - S_{12}$  แทนค่าสัมประสิทธิ์ในการปรับรูปแบบของฤดูกาล (Seasonality) สำหรับแต่ละช่วงเวลาในปี

$S_1 = 2.9585146, S_2 = 0.9273901, S_3 = 0.4741000,$

$S_4 = 0.4733419, S_5 = 0.9223474, S_6 = 1.1746158,$

$S_7 = 0.2606797, S_8 = 2.1482367, S_9 = 0.8814068,$

$S_{10} = 1.1268251, S_{11} = 1.9719280, S_{12} = 0.6292755$

หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีปรับให้เรียบแบบโฮสต์-วินเทอร์แบบคูณที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีการจดทะเบียน ดังนี้

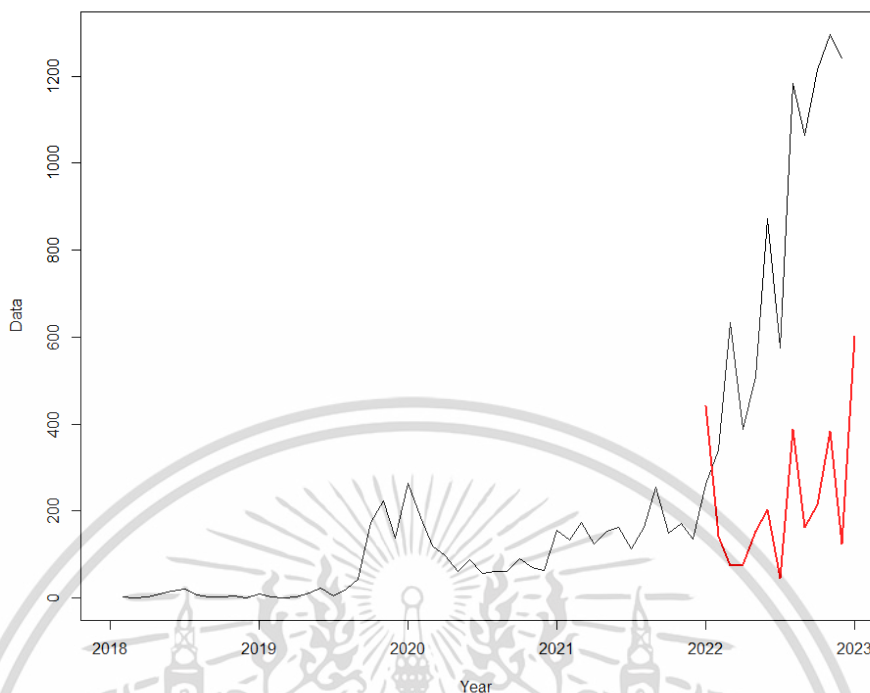
**ตารางที่ 4.8** ข้อมูลจริง และค่าพยากรณ์ในปี ค.ศ. 2022 ในชุดข้อมูลทดสอบของจำนวน  
การจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยวิธีปรับให้เรียบแบบ  
โพลต์-วินเทอร์แบบคูณ

เดือน	ค่าจริง	ค่าพยากรณ์	ช่วงความเชื่อมั่น (80%)	ช่วงความเชื่อมั่น (95%)
มกราคม	261	442.82233	434.06975 - 451.57492	429.43641 - 456.20825
กุมภาพันธ์	341	142.94327	134.19069 - 151.69586	129.55735 - 156.32919
มีนาคม	634	75.18882	66.43624 - 83.94141	61.80290 - 88.57474
เมษายน	389	77.17864	68.42606 - 85.93123	63.79272 - 90.56456
พฤษภาคม	509	154.50081	145.74822 - 163.25339	141.11489 - 167.88673
มิถุนายน	872	201.99398	193.24140 - 210.74657	188.60806 - 215.37990
กรกฎาคม	575	45.99009	37.23750 - 54.74267	32.60416 - 59.37601
สิงหาคม	1184	388.57630	379.82371 - 397.32888	375.19038 - 401.96222
กันยายน	1065	163.35929	154.60671 - 172.11187	149.97337 - 176.74521
ตุลาคม	1216	213.86803	205.11544 - 222.62061	200.48210 - 227.25395
พฤศจิกายน	1296	383.05640	374.30382 - 391.80899	369.67048 - 396.44232
ธันวาคม	1242	125.04491	123.80936 - 126.28046	123.15530 - 126.93453
RMSE	699.23			
MAPE	77.42%			

จากตารางที่ 4.8 ภาพรวมของผลลัพธ์คือในทุกเดือนของปี ค.ศ. 2022 ค่าทำนายอยู่ในช่วงความเชื่อมั่น 80% และ 95% โดยทั่วไปแล้ว ค่าทำนายอยู่ในช่วงกลางของช่วงความเชื่อมั่น 80% และมีค่าต่ำลงในช่วงความเชื่อมั่น 95% นอกเหนือจากเดือนสิงหาคมที่มีค่าทำนายสูงสุด ดังนั้นเดือนสิงหาคมมีความเชื่อมั่นที่สูงสุดในการทำนายข้อมูลในปี ค.ศ. 2022 สำหรับค่าพยากรณ์มีค่าต่ำกว่าค่าจริงค่อนข้างสูง และมีเดือนมกราคมที่มีการพยากรณ์สูงกว่าค่าจริง

ผู้วิจัยทำเปรียบเทียบข้อมูลจริง ค.ศ. 2022 กับข้อมูลทำนายในชุดข้อมูลทดสอบโดยใช้วิธีปรับให้เรียบแบบโพลต์-วินเทอร์แบบคูณ โดยพบว่าค่าพยากรณ์มีค่าที่ต่ำกว่าค่าจริง แต่ไม่มากเท่าวิธีแยกส่วนประกอบ ทั้งนี้ลักษณะกราฟเป็นไปในทิศทางเดียวกันกับค่าจริง เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ซึ่งได้ผลการพยากรณ์ ดังนี้

Actual VS Forecast BEVs: HW



**รูปที่ 4.20** ผลการวิเคราะห์ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยวิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 699.23 และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 77.42%

#### 4.5.3 ผลการวิเคราะห์ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน

ผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยข้อมูลชุดแรกเป็นข้อมูล ตั้งแต่เดือนมกราคม ปี ค.ศ. 2018 ถึงเดือนธันวาคม ค.ศ. 2021 เพื่อใช้ในการสร้างตัวแบบพยากรณ์ (Train Data Set) สำหรับข้อมูลชุดที่สองเป็นข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2022 ถึงเดือนธันวาคม ค.ศ. 2022 เพื่อใช้ในการทดสอบเพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ (Test Data Set) ดังนี้

1. สร้างตัวแบบพยากรณ์จากชุดข้อมูลฝึกสอนด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอยของรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

ผลการสร้างตัวแบบพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนประเภทถดถอย (Support Vector Regression: SVR) ด้วย Radial Basis Kernel ประเภท EPS-Regression และ NU-Regression ได้รับการปรับแต่งเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พารามิเตอร์โดยคำสั่ง `param_ranges` เพื่อเลือกค่าพารามิเตอร์ที่ดีที่สุดจากค่าอัลกอริทึม และพารามิเตอร์ที่กำหนดไว้ ดังนี้

ค่าอัลกอริทึม NU และ EPS มีค่าทดลองที่ 0.1 0.2 0.3 และ 0.4

พารามิเตอร์ Cost มีค่าทดลองที่ 1 10 100 และ 1000

พารามิเตอร์ Gamma มีค่าทดลองที่ 0.1 0.01 และ 0.001

โดยได้ค่าพารามิเตอร์ที่ดีที่สุด ของ EPS-Regression และ NU-Regression มีดังนี้

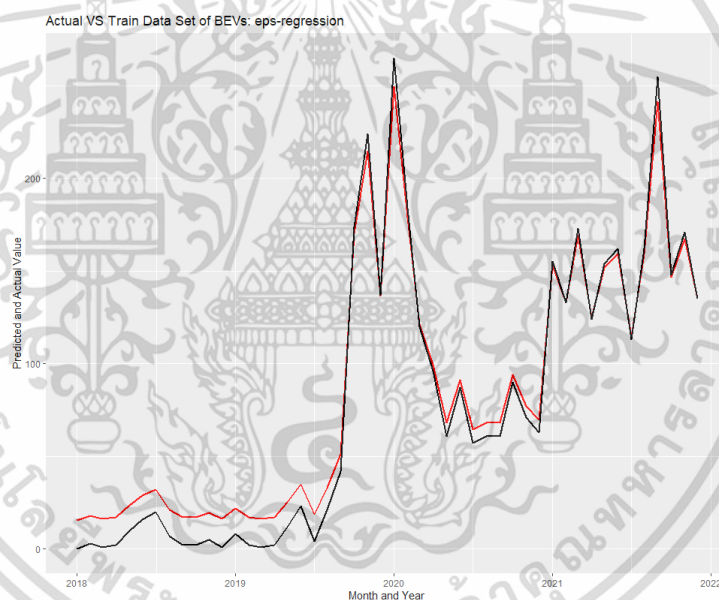
ประเภทที่ 1 EPS-Regression:

พารามิเตอร์ที่ดีที่สุดคือ EPS = 0.1 Cost = 100 Gamma = 0.01

ประเภทที่ 2 NU-Regression :

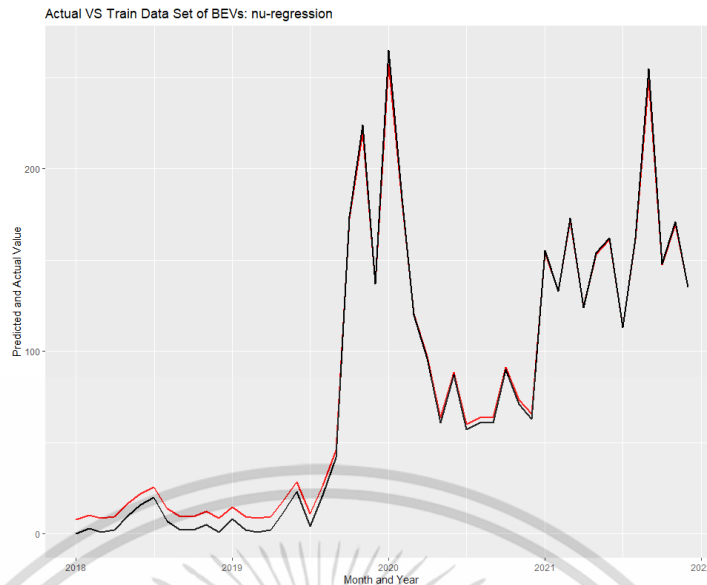
พารามิเตอร์ที่ดีที่สุดคือ NU = 0.4 Cost = 100 Gamma = 0.01

ผู้วิจัยทำการแสดงผลการพยากรณ์ด้วยตัวแบบประเภทที่ 1 และประเภทที่ 2 ตามพารามิเตอร์ที่มีการปรับแต่งข้างต้น ได้ผลการพยากรณ์ชุดข้อมูลฝึกฝน ดังต่อไปนี้



รูปที่ 4.21 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท EPS-Regression

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



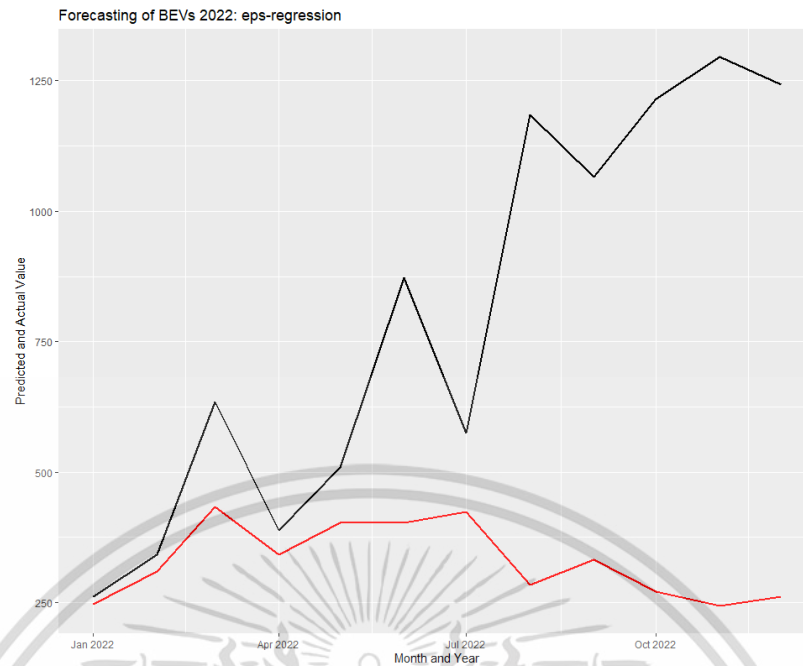
รูปที่ 4.22 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้า  
แบตเตอรี่ (BEVs) โดยใช้วิธีพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย  
Radial Basis Kernel ประเภท NU-Regression

จากรูปที่ 4.21 และ 4.22 จะเห็นว่าข้อมูลฝึกฝน (เส้นสีแดง) ด้วยประเภท EPS-Regression มีค่าต่างจากค่าจริง (เส้นสีดำ) มากกว่าข้อมูลฝึกฝนด้วยประเภท NU-Regression เล็กน้อย หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์การทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ดังนี้


ตารางที่ 4.9 ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)  
ปี ค.ศ. 2022 โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์

เดือน	ค่าจริง	ค่าพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)	
		EPS-Regression	NU-Regression
		Cost = 100 EPS = 0.2 Gamma = 0.01	Cost = 100 NU = 0.2 Gamma = 0.01
มกราคม	261	246.3289	253.7764
กุมภาพันธ์	341	309.0747	320.6275
มีนาคม	634	432.7024	452.3438
เมษายน	389	341.7876	355.4807
พฤษภาคม	509	403.1467	420.8544
มิถุนายน	872	402.9796	420.6763
กรกฎาคม	575	423.1690	442.1867
สิงหาคม	1184	283.9224	293.8295
กันยายน	1065	331.6023	344.6290
ตุลาคม	1216	271.7231	280.8321
พฤศจิกายน	1296	243.2662	250.5132
ธันวาคม	1242	262.1281	270.6093
RMSE		619.56	611.43
MAPE		45.21%	43.06%

จากตารางที่ 4.9 จะเห็นได้ว่าค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริงค่อนข้างมากเมื่อเทียบกับค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท EPS-Regression เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 และค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้



รูปที่ 4.23 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย ด้วย Radial Basis Kernel ประเภท EPS-Regression



รูปที่ 4.24 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในห้องปฏิบัติการเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.23 และ 4.24 จะเห็นได้ว่าค่าพยากรณ์ (เส้นสีแดง) ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริง (เส้นสีดำ) ค่อนข้างมากเมื่อเทียบกับค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท EPS-Regression

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ได้ผลลัพธ์ ดังนี้

ประเภทที่ 1 EPS-Regression ค่า RMSE = 619.56 และ ค่า MAPE = 45.21%

ประเภทที่ 2 NU-Regression ค่า RMSE = 611.43 และ ค่า MAPE = 43.06%

#### 4.6 เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

ผลการเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ของตัวแบบพยากรณ์วิธีแยกส่วนประกอบแบบบวก และแบบคูณ วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ และวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วยฟังก์ชัน EPS-Regression และ NU-Regression พบว่ามีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 697.41 706.01 699.23 619.56 และ 611.43 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 66.08 % 66.30% 77.42% 45.21% และ 43.06% ตามลำดับ จะเห็นได้ว่าวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วยฟังก์ชัน NU-Regression มีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำสุด

**ตารางที่ 4.10** ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ของตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

ตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)	RMSE	MAPE
วิธีแยกส่วนประกอบแบบบวก	697.41	66.08 %
วิธีแยกส่วนประกอบแบบคูณ	706.01	66.30%
วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณ	699.23	77.42%
วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน (EPS-Regression)	619.56	45.21%
วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน (NU-Regression)	611.43	43.06%

ดังนั้น ตัวแบบพยากรณ์วิธีซัพพอร์ตแมชชีนแบบถดถอย ประเภท NU-Regression เป็นตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs)

#### 4.7 การอภิปรายผล

งานวิจัยนี้ได้ใช้วิธีซัพพอร์ตเวกเตอร์แมชชีน (SVM) ในการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย โดยค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ที่ได้เป็นตัวบ่งชี้ประสิทธิภาพของการพยากรณ์ ซึ่งในงานวิจัยนี้พบว่าตัวแบบพยากรณ์วิธีซัพพอร์ตเวกเตอร์แมชชีนมีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และ ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำสุด ทั้งรถยนต์ไฟฟ้าไฮบริด และรถยนต์ไฟฟ้าแบตเตอรี่ โดยการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ซึ่งมีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 484.79 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 4.73% สำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) มีค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 611.43 และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 43.06% มีประสิทธิภาพกว่าวิธีแยกส่วนประกอบ และวิธีปรับให้เรียบโฮลต์-วินเทอร์

เมื่อเปรียบเทียบความสอดคล้องงานวิจัยของ Liangcai Dong และ Ziqi Xu (2011) ที่ได้ทำการพยากรณ์การผลิตรถยนต์ในประเทศจีน และสรุปว่าวิธีซัพพอร์ตเวกเตอร์แมชชีน เป็นวิธีที่ให้ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ต่ำที่สุดในงานวิจัยเมื่อเปรียบเทียบกับเปรียบเทียบกับวิธี ARIMA (Autoregressive Integrated Moving Average) ซึ่งมีค่า MAPE เท่ากับ 5.9%

ผลการพยากรณ์ในงานวิจัยนี้ สอดคล้องกับผลงานวิจัยของ Liangcai Dong และ Ziqi Xu (2011) ที่พบว่าตัวแบบพยากรณ์วิธีซัพพอร์ตเวกเตอร์แมชชีนมีประสิทธิภาพในการพยากรณ์อนุกรมเวลามากกว่าตัวแบบพยากรณ์อนุกรมเวลาดั้งเดิม (Classical Time Series Methods)

## บทที่ 5

# สรุปผลการวิจัยและข้อเสนอแนะ

### 5.1 สรุปผลการวิจัย

#### 5.1.1 ผลการทดสอบข้อมูล

จากการพิจารณาแนวโน้ม และฤดูกาลของข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) และจำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) พบว่า ข้อมูลทั้ง 2 ไม่มีการแจกแจงปกติ มีแนวโน้ม และอิทธิพลฤดูกาลเกี่ยวข้อง

#### 5.1.2 ผลการทดสอบตัวแบบพยากรณ์รถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs)


สำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ตัวแบบพยากรณ์ที่มีประสิทธิภาพที่สุด ได้แก่ตัวแบบพยากรณ์วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วยฟังก์ชัน Kernel: NU-Regression ที่ได้รับการปรับแต่งพารามิเตอร์ ดังนี้

ค่าอัลกอริทึม NU เท่ากับ 0.4

พารามิเตอร์ Cost มีค่าทดลองที่ 100

พารามิเตอร์ Gamma มีค่าทดลองที่ 0.1

โดยตัวแบบพยากรณ์หลังจากที่ปรับแต่งพารามิเตอร์ แสดงดังรูปที่ 5.1



รูปที่ 5.1 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้า

ไฮบริด (HEVs และ PHEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย

ด้วย Radial Basis Kernel ประเภท NU-Regression

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 5.1 จะเห็นว่าเส้นกราฟของข้อมูลฝึกฝน (เส้นสีแดง) ด้วยประเภท NU-Regression ทับเส้นกราฟค่าจริง (เส้นสีดำ) เกือบทั้งหมด มีช่วงต้นปี ค.ศ. 2021 ที่เส้นกราฟค่าพยากรณ์ต่ำกว่าจนเห็นเส้นกราฟสีแดงที่ไม่ได้ทับเส้นกราฟค่าจริง


หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์ผลการทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ดังนี้

**ตารางที่ 5.1** ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ปรับแต่งพารามิเตอร์ในปี ค.ศ. 2022

เดือน	ค่าจริง	ค่าพยากรณ์ PHEVs & HEVs NU-Regression C = 100 NU = 0.4 Gamma = 0.01
มกราคม	5057	5003.5865
กุมภาพันธ์	6289	6023.6664
มีนาคม	8546	7268.6925
เมษายน	5519	5408.0549
พฤษภาคม	6385	6094.5731
มิถุนายน	6639	6275.3252
กรกฎาคม	5261	5185.0632
สิงหาคม	6728	6336.2292
กันยายน	7745	6934.7899
ตุลาคม	5887	5712.2057
พฤศจิกายน	6006	5806.7713
ธันวาคม	4738	4711.5938
RMSE		484.79
MAPE		4.73%

จากตารางที่ 5.1 จะเห็นได้ว่าค่าพยากรณ์ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริงค่อนข้างมาก เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 และค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้

Forecasting of HEVs &amp; PHEVs: 2022: nu-regression



รูปที่ 5.2 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย

จากรูปที่ 4.12 จะเห็นได้ว่าค่าพยากรณ์ (เส้นสีแดง) ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริง (เส้นสีดำ) ค่อนข้างมาก

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) มีค่าดังนี้ ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 484.79 และ ค่า ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 4.73%

ดังนั้น ตัวแบบพยากรณ์วิธีซัพพอร์ตแมชชีนแบบถดถอย ประเภท NU-Regression เป็นตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs)

### 5.1.3 ผลการทดสอบตัวแบบพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs)

สำหรับจำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ตัวแบบพยากรณ์ที่มีประสิทธิภาพที่สุด ได้แก่ตัวแบบพยากรณ์วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วยฟังก์ชัน

เอกสารนี้เป็นการนำเสนองานวิจัยที่ผ่านการปรับปรุงแก้ไขแล้ว โดยอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า


ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่าอัลกอริทึม NU เท่ากับ 0.2

พารามิเตอร์ Cost มีค่าทดลองที่ 100

พารามิเตอร์ Gamma มีค่าทดลองที่ 0.01

โดยตัวแบบพยากรณ์หลังจากที่ปรับแต่งพารามิเตอร์ แสดงดังรูปที่ 5.3



รูปที่ 5.3 ผลการวิเคราะห์ตัวแบบพยากรณ์ของจำนวนการจดทะเบียนรถยนต์ไฟฟ้า แบตเตอรี่ (BEVs) โดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยด้วย Radial Basis Kernel ประเภท NU-Regression


จากรูปที่ 5.3 จะเห็นว่าข้อมูลฝึกฝน (เส้นสีแดง) ด้วยประเภท NU-Regression มีค่าต่างจากค่าจริง (เส้นสีดำ) ไม่มาก

หลังจากพิจารณาผลการฝึกสอน และปรับแต่งพารามิเตอร์แล้ว ผู้วิจัยทำการทำนายค่าในชุดข้อมูลทดสอบโดยใช้วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอยที่ถูกฝึกสอน และปรับแต่ง โดยได้ผลลัพธ์การทำนายในชุดข้อมูลทดสอบพบว่าในปี ค.ศ. 2022 มีค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs และ PHEVs) ดังนี้

ตารางที่ 5.2 ค่าจริง และค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) โดยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบลดรอยที่ปรับแต่งพารามิเตอร์ในปี ค.ศ. 2022

เดือน	ค่าจริง	ค่าพยากรณ์รถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ด้วย NU-Regression $C = 100$ $NU = 0.2$ $\Gamma = 0.01$
มกราคม	261	253.7764
กุมภาพันธ์	341	320.6275
มีนาคม	634	452.3438
เมษายน	389	355.4807
พฤษภาคม	509	420.8544
มิถุนายน	872	420.6763
กรกฎาคม	575	442.1867
สิงหาคม	1184	293.8295
กันยายน	1065	344.6290
ตุลาคม	1216	280.8321
พฤศจิกายน	1296	250.5132
ธันวาคม	1242	270.6093
RMSE		611.43
MAPE		43.06%

จากตารางที่ 5.2 จะเห็นได้ว่าค่าพยากรณ์ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริงค่อนข้างมากในช่วงต้นปี แต่หลังจากกลางปีมีการพยากรณ์ที่ห่างจากค่าจริงค่อนข้างมาก เพื่อให้เห็นภาพอย่างชัดเจนมากขึ้น ผู้วิจัยทำการเปรียบเทียบข้อมูลจริงปี ค.ศ. 2022 กับค่าพยากรณ์ในปี ค.ศ. 2022 ด้วยกราฟ โดยมีผลลัพธ์ ดังนี้



รูปที่ 5.4 ค่าพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าแบตเตอรี่ (BEVs) ด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย

จากรูปที่ 5.4 จะเห็นได้ว่าค่าพยากรณ์ (เส้นสีแดง) ที่ผ่านการปรับแต่งด้วยประเภท NU-Regression มีค่าที่ใกล้เคียงค่าจริง (เส้นสีดำ) ในช่วงต้นปี และเมื่อเริ่มเข้าสู่กลางปี ค่าพยากรณ์ห่างออกจากค่าจริงมากยิ่งขึ้น ซึ่งเป็นช่วงหลังจากที่รัฐบาลได้ประกาศอย่างเป็นทางการเรื่องการสนับสนุนเงินอุดหนุนรถยนต์ไฟฟ้า ทำให้ยอดจดทะเบียนของจำนวนรถยนต์ไฟฟ้าสูงเพิ่มมากขึ้นในช่วงกลางปี เป็นต้นไป

สำหรับค่าประเมินประสิทธิภาพตัวแบบพยากรณ์ด้วยค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) มีค่าดังนี้ ค่าค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error: RMSE) = 611.43 และ ค่า ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) = 43.06%

ดังนั้น ตัวแบบพยากรณ์วิธีซัพพอร์ตเวกเตอร์แมชชีนแบบถดถอย ประเภท NU-Regression เป็นตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์จำนวนการจดทะเบียนรถยนต์ไฟฟ้าไฮบริด (HEVs & PHEVs)

## 5.2 ข้อเสนอแนะ

1. เนื่องจากปริมาณไฟฟ้าเป็นผลิตภัณฑ์ที่ได้รับความสนใจในช่วงไม่กี่ปีที่ผ่านมา และมีการเติบโตที่ก้าวกระโดดในปี ค.ศ. 2022 จากการสนับสนุนของรัฐบาลไทย ทำให้ข้อมูลที่น่าสนใจในครั้งนี้อาจยังไม่มากพอในการคำนวณเพื่อหาตัวแบบที่เหมาะสม (Fitted Model) ได้ดีเท่าที่ควร ดังนั้น ในอนาคตสำหรับงานวิจัยที่เกี่ยวข้องกับจำนวนรถยนต์ไฟฟ้าสามารถหาตัวแบบที่เหมาะสมได้แม่นยำมากยิ่งขึ้น เนื่องจากมีจำนวนข้อมูลจำนวนรถยนต์ไฟฟ้ามากยิ่งขึ้น
2. อาจมีปัจจัยอื่นที่เกี่ยวข้อง หรือมีความสัมพันธ์ที่สามารถทำให้การพยากรณ์จำนวนรถยนต์ไฟฟ้าแม่นยำมากขึ้น เช่น ปัจจัยทางด้านเศรษฐกิจ ราคาน้ำมัน เป็นต้น ดังนั้น งานวิจัยในอนาคตสามารถนำข้อมูลเหล่านี้ประยุกต์ใช้กับข้อมูลอนุกรมเวลา
3. ผลการวิจัยนี้สามารถนำไปพัฒนาตัวแบบเพิ่มเติมในเชิงอนุกรมเวลา เพื่อการวิเคราะห์ธุรกิจรถยนต์ไฟฟ้าของประเทศไทยในอนาคตอันใกล้ โดยผู้สนใจนำตัวแบบนี้ไปปรับปรุงพัฒนาเพิ่มเติม ควรใช้ข้อมูลปริมาณการจดทะเบียนรถยนต์ไฟฟ้าในปีล่าสุดในการสร้างตัวแบบพยากรณ์ รวมถึงใช้ตัวแปรอิสระ เช่น ปัจจัยทางด้านเศรษฐกิจ ราคาน้ำมัน เป็นต้น เพื่อเพิ่มประสิทธิภาพในการสร้างตัวแบบพยากรณ์ให้ดียิ่งขึ้น

## เอกสารอ้างอิง

- กลุ่มสถิติการขนส่ง กองแผนงาน กรมการขนส่งทางบก. 2566. จำนวนรถจดทะเบียนครั้งแรก.  
[Online]. Available: <https://web.dlt.go.th/statistics>.
- เพียร์พาวเวอร์. 2565. ปัจจัยที่มีผลต่อเทรนด์รถยนต์ไฟฟ้า (รถ EV) และ 5 โอกาสในการลงทุน.  
[Online]. Available: <https://www.peerpower.co.th/blog/ev-and-investment>.
- Rachot Leingchan. 2566. "รถยนต์ไฟฟ้า: ความต้องการและโอกาสที่กำลังมาถึง."  
[Online]. Available: <https://www.krungsri.com/th/research/researchintelligence/ev-survey-22>.
- Tadsaneeya. 2563. ทำความรู้จัก 4 ประเภทรถยนต์ไฟฟ้า พร้อมคำอธิบายตัวย่อต่างๆ.  
[Online]. Available: <https://www.autospinn.com/2020/04/electric-vehicle-types-hev-phev-bev-fcev-78020>.
- มัลลิกา ภูมิวาร. 2565. รถยนต์ไฟฟ้าเจาะมาตรการสนับสนุน EV ทางเลือกใหม่สำหรับอนาคตต่างๆ. [Online]. Available: <https://thestandard.co/thailand-ev-future/>.
- BizReps. 2564. HEV vs BEV vs PHEV: Which Electric Vehicle Type Is Better?.  
[Online]. Available: <https://biz-reps.com/hev-bev-phev-which-electric-vehicle-type-better/>.
- นิภา นีรุตติกุล. 2551. การพยากรณ์การขาย. กรุงเทพฯ : สำนักพิมพ์มหาวิทยาลัยเกษตรศาสตร์.
- เอกจิตต์ จีจเจริญ. 2563. การพยากรณ์ทางธุรกิจ. กรุงเทพฯ : สำนักพิมพ์มหาวิทยาลัยธรรมศาสตร์.
- ภูมิฐาน รั้งกุลณัฐวัฒน์. 2562. การวิเคราะห์อนุกรมเวลาสำหรับเศรษฐศาสตร์และธุรกิจ.  
กรุงเทพฯ : สำนักพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย.
- พชรพจน์ นันทรามาศ, มานะ นิมิตรวานิช และพิมพ์ฉัตร เอกฉันท. 2564. จับกระแสอุตสาหกรรมยานยนต์ไทย กับความท้าทายใหม่...สู่ฐานผลิต EV ของภูมิภาค. กรุงเทพฯ : Krungthai Compass.
- กมล จีงมานนท์. 2562. “การพยากรณ์ยอดขายรถยนต์ไฟฟ้าในประเทศสหรัฐอเมริกา และประเทศจีน”. การค้นคว้าอิสระบริหารธุรกิจมหาบัณฑิต คณะพาณิชยศาสตร์และการบัญชี, มหาวิทยาลัยธรรมศาสตร์.
- อนุธิดา อาษา และอัชฌา ปราบกุลผล. 2562. “การเปรียบเทียบประสิทธิภาพการพยากรณ์หนี้ต่างประเทศของไทย โดยวิธีการวิเคราะห์อนุกรมเวลา และซอฟต์แวร์เวกเตอร์แมชชีน”. ปริญาวิทยาศาสตรบัณฑิต(สถิติประยุกต์), สถาบันเทคโนโลยีพระจอมเกล้าคุณทหารลาดกระบัง.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- วัชรินทร์ แสงมา, พิษณุ ทองขาว และอรศิริ จันทร์เมือง. 2556. “ตัวแบบการพยากรณ์ความต้องการเหล็กภายใต้ความไม่แน่นอนโดยวิธีเบย์”. ทุนสนับสนุนงบประมาณปี พ.ศ. 2556, มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
- อุรษา จันทระกา และนันทชัย กานตานั้นทะ. 2564. “การพยากรณ์มูลค่าการส่งออกรถยนต์ อุปกรณ์ และส่วนประกอบของประเทศไทยด้วยวิธีอนุกรมเวลา”. *Thai Journal of Operations Research: TJOR Vol 9 No 2*.
- W Gerstner, A Germond, M Hasler and J-D Nicoud. 1999. “Advances in kernel methods: support vector learning”. *MIT Press Editors*. pp.243-253.
- Cortes, C., Vapnik and V. 1995. “Support-vector networks”. *Mach Learn 20*, pp.273–297.
- Meral Sari, Halil Ibrahim Demir, Onur Canpolat and Caner Erden. 2021. “Implementation of Sales Demand Forecasting in An Automotive Company”. *IMSS'21 Sakarya University - Sakarya/Turkey (Online)*. pp. 419-429.
- P. Wirotcheewan, Atthakorn Kengpol, K. Ishii and Y. Shimada. 2011. “Modelling and Forecasting for Automotive Parts Demand of Foreign Markets on Thailand”. *AJSTPME*. 4(1): 1-13
- Fuad Dwi Hanggara. 2021. “Forecasting Car Demand in Indonesia with Moving Average Method”. *Journal of Engineering Science and Technology Management-VOL.1*. NO. 1.
- Zhang Y, Zhong M, Geng N and Jiang Y. 2017. “Forecasting electric vehicles sales with univariate and multivariate time series models: The case of China”. School of Transportation, Southeast University.
- Anshul Agarwal and Arvind Jayant. 2019. “Support Vector Machine Model for Demand Forecasting in an Automobile parts industry: A Case Study”. *Research Journal of Applied Sciences, Engineering and Technology* 9(2):33-49.
- Yue, S., Wang and C. Y. 2004. “The Mann-Kendall Test Modified by Effective Sample Size to Detect Trend in Serially Correlated Hydrological Series”. *Water Resources Management*, 18, 201-218.
- L. Dong and Z. Xu. (2011). “Forecast and Application of Chinese Automobile Production Based on SVM”. *Third Pacific-Asia Conference on Circuits, Communications and System (PACCS)*, pp. 1-3.



## ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ก

ตารางภาคผนวก ก-1 ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าประเภทไฮบริด (PHEVs & HEVs) ตั้งแต่ปี ค.ศ. 2018 - ค.ศ. 2022

M/Y	2018	2019	2020	2021	2022
Jan	1045	2389	3096	4518	5057
Feb	1266	2249	2850	4352	6289
Mar	1536	2279	2800	4602	8546
Apr	1561	1967	1777	3305	5519
May	1891	2320	1417	3744	6385
Jun	2252	2315	1647	3417	6639
Jul	2010	2109	1739	2123	5261
Aug	2104	2484	2619	3417	6728
Sep	1825	2393	2874	2971	7745
Oct	1695	2427	3271	2723	5887
Nov	1626	2130	3014	3403	6006
Dec	1191	1362	2217	2765	4738

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางภาคผนวก ก-2 ข้อมูลจำนวนการจดทะเบียนรถยนต์ไฟฟ้าประเภทแบตเตอรี่ (BEVs)  
ตั้งแต่ปี ค.ศ. 2018 - ค.ศ. 2022

M/Y	2018	2019	2020	2021	2022
Jan	0	8	265	155	261
Feb	3	2	184	133	341
Mar	1	1	120	173	634
Apr	2	2	96	124	389
May	10	12	61	154	509
Jun	16	23	87	162	872
Jul	20	4	57	113	575
Aug	7	21	61	162	1184
Sep	2	42	61	255	1065
Oct	2	174	90	148	1216
Nov	5	224	71	171	1296
Dec	1	137	63	135	1242

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ข

### คำสั่ง และผลลัพธ์วิธีแยกส่วนประกอบ

#### 1. วิธีแยกส่วนประกอบแบบบวกของรถยนต์ไฟฟ้าไฮบริด

```
# (Import the Data)
data_hev <- c(1045, 1266, 1536, 1561, 1891, 2252, 2010, 2104, 1825, 1695, 1626,
1191, 2389, 2249, 2279, 1967, 2320, 2315, 2109, 2484, 2393, 2427, 2130, 1362, 3096,
2850, 2800, 1777, 1417, 1647, 1739, 2619, 2874, 3271, 3014, 2217, 4518, 4352, 4602,
3305, 3744, 3417, 2123, 3417, 2971, 2723, 3403, 2765, 5057, 6289, 8546, 5519, 6385,
6639, 5261, 6728, 7745, 5887, 6006, 4738)

# Create data_hev_ts
data_hev_ts <- ts(data_hev, start = c(2018, 1), frequency = 12)

# (Detect the Trend)
line_reg <- lm(data_hev_ts ~ time(data_hev_ts))
trend_hev <- ts(line_reg$fitted.values, start = c(2018, 1), frequency = 12)

# Time Series (Detrend the Time Series)
detrend_hev <- data_hev_ts - trend_hev

# Seasonal Index (Average the Seasonality)
m_hev <- matrix(data = detrend_hev, nrow = 12, byrow = TRUE)
seasonal_hev <- rowMeans(m_hev, na.rm = TRUE)
average_hev <- sum(seasonal_hev) / frequency(data_hev_ts)
seasonalindex_hev <- seasonal_hev / average_hev # Additive
seasonalindex_hev <- ts(rep(seasonalindex_hev, length.out = length(data_hev_ts)),
start = c(2018, 1), frequency = 12)

# (Examining Remaining Random Noise)
random_hev <- data_hev_ts - trend_hev - seasonalindex_hev

# (Reconstruct the Original Signal)
recomposed_hev <- trend_hev + seasonalindex_hev + random_hev
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# STL (Seasonal-Trend decomposition using LOESS)
library(forecast)
stl_result <- stl(data_hev_ts, "periodic")
print(stl_result)

stl(x = data_hev_ts, s.window = "periodic")
seasonal_stl_data_hev <- stl_result$time.series[, 1]
trend_stl_data_hev <- stl_result$time.series[, 2]
random_stl_data_hev <- stl_result$time.series[, 3]
autoplot(stl_result)

#
train_data_hev <- window(data_hev_ts, start = c(2018, 1), end = c(2021, 12))
test_data_hev <- window(data_hev_ts, start = c(2022, 1), end = c(2022, 12))
forecast_model <- tslm(train_data_hev ~ trend + season)
summary(forecast_model)

# ทำนายค่าของชุดทดสอบ
new_data <- data.frame(trend = trend_stl_data_hev, seasonal =
seasonal_stl_data_hev)
forecasted_values <- forecast(forecast_model, newdata = new_data)

# ทำนายค่าของชุดทดสอบในปี 2022
forecasted_values <- forecast(forecast_model, h = 12)
print(forecasted_values)

# หาค่าผลต่างระหว่างค่าจริงและค่าทำนาย
actual_values <- test_data_hev
predicted_values <- forecasted_values$mean

# RMSE
rmse <- sqrt(mean((actual_values - predicted_values)^2))
mape <- mean(abs((actual_values - predicted_values) / actual_values)) * 100

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2. วิธีแยกส่วนประกอบแบบคูณของรถยนต์ไฟฟ้าไฮบริด

```

# (Import the Data)
data_hev1 <- c(1045, 1266, 1536, 1561, 1891, 2252, 2010, 2104, 1825, 1695, 1626,
1191, 2389, 2249, 2279, 1967, 2320, 2315, 2109, 2484, 2393, 2427, 2130, 1362,
3096, 2850, 2800, 1777, 1417, 1647, 1739, 2619, 2874, 3271, 3014, 2217, 4518, 4352,
4602, 3305, 3744, 3417, 2123, 3417, 2971, 2723, 3403, 2765, 5057, 6289, 8546, 5519,
6385, 6639, 5261, 6728, 7745, 5887, 6006, 4738)

# data_hev
data_hev1_ts <- ts(data_hev1, start = c(2018, 1), frequency = 12)

# (Detect the Trend)
line_reg <- lm(log(data_hev1_ts) ~ time(data_hev1_ts))
trend_hev1 <- ts(exp(line_reg$fitted.values), start = c(2018, 1), frequency = 12)

# Time Series (Detrend the Time Series)
etrend_hev1 <- data_hev1_ts / trend_hev1

# Seasonal Index (Average the Seasonality)
m_hev1 <- matrix(data = detrend_hev1, nrow = 12, byrow = TRUE)
seasonal_hev1 <- rowMeans(m_hev1, na.rm = TRUE)
average_hev1 <- sum(seasonal_hev1) / frequency(data_hev1_ts)
seasonalindex_hev1 <- seasonal_hev1 / average_hev1
seasonalindex_hev1 <- ts(rep(seasonalindex_hev1, length.out =
length(data_hev1_ts)), start = c(2018, 1), frequency = 12)

# (Examining Remaining Random Noise)
random_hev1 <- data_hev1_ts / (trend_hev1 * seasonalindex_hev1)

# (Reconstruct the Original Signal)
recomposed_hev1 <- trend_hev1 * seasonalindex_hev1 * random_hev1

# STL (Seasonal-Trend decomposition using LOESS)
library(forecast)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

stl_result <- stl(data_hev1_ts, s.window = "periodic", t.window = 12, l.window = 12,
robust = TRUE, na.action = na.omit)
print(stl_result)

seasonal_stl_data_hev1 <- stl_result$time.series[, 1]
trend_stl_data_hev1 <- stl_result$time.series[, 2]
random_stl_data_hev1 <- stl_result$time.series[, 3]
autoplot(stl_result)

#
train_data_hev1 <- window(data_hev1_ts, start = c(2018, 1), end = c(2021, 12))
test_data_hev1 <- window(data_hev1_ts, start = c(2022, 1), end = c(2022, 12))
forecast_model1 <- tslm(train_data_hev1 ~ trend * season)
summary(forecast_model1)

# ทำนายค่าของชุดทดสอบ
new_data1 <- data.frame(trend = trend_stl_data_hev1, seasonal =
seasonal_stl_data_hev1)
forecasted_values1 <- forecast(forecast_model1, newdata = new_data)

# ทำนายค่าของชุดทดสอบในปี 2022
forecasted_values1 <- forecast(forecast_model1, h = 12)
print(forecasted_values1)

# หาค่าผลต่างระหว่างค่าจริงและค่าทำนาย
actual_values1 <- test_data_hev1
predicted_values1 <- forecasted_values1$mean

#
rmse <- sqrt(mean((actual_values1 - predicted_values1)^2))
mape <- mean(abs((actual_values1 - predicted_values1) / actual_values1)) * 100

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3. วิธีแยกส่วนประกอบแบบบวกของรถยนต์ไฟฟ้าแบตเตอรี่

```
# (Import the Data)
```

```
data_bev <- c(0, 3, 1, 2, 10, 16, 20, 7, 2, 2, 5, 1, 8, 2, 1, 2, 12, 23, 4, 21, 42, 174, 224,
137, 265, 184, 120, 96, 61, 87, 57, 61, 61, 90, 71, 63, 155, 133, 173, 124, 154, 162, 113,
162, 255, 148, 171, 135, 261, 341, 634, 389, 509, 872, 575, 1184, 1065, 1216, 1296,
1242)
```

```
# data_bev
```

```
data_bev_ts <- ts(data_bev, start = c(2018, 1), frequency = 12)
```

```
# (Detect the Trend)
```

```
line_reg <- lm(data_bev_ts ~ time(data_bev_ts))
```

```
trend_bev <- ts(line_reg$fitted.values, start = c(2018, 1), frequency = 12)
```

```
# Time Series (Detrend the Time Series)
```

```
detrend_bev <- data_bev_ts - trend_bev
```

```
# Seasonal Index (Average the Seasonality)
```

```
m_bev <- matrix(data = detrend_bev, nrow = 12, byrow = TRUE)
```

```
seasonal_bev <- rowMeans(m_bev, na.rm = TRUE)
```

```
average_bev <- sum(seasonal_bev) / frequency(data_bev_ts)
```

```
seasonalindex_bev <- seasonal_bev - average_bev
```

```
seasonalindex_bev <- ts(rep(seasonalindex_bev, length.out = length(data_bev_ts)),
start = c(2018, 1), frequency = 12)
```

```
# (Examining Remaining Random Noise)
```

```
random_bev <- data_bev_ts - trend_bev - seasonalindex_bev
```

```
# (Reconstruct the Original Signal)
```

```
recomposed_bev <- trend_bev + seasonalindex_bev + random_bev
```

```
# STL (Seasonal-Trend decomposition using LOESS)
```

```
library(forecast)
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

stl_result <- stl(data_bev_ts, "periodic")
print(stl_result)

stl(x = data_bev_ts, s.window = "periodic")
seasonal_stl_data_bev <- stl_result$time.series[, 1]
trend_stl_data_bev <- stl_result$time.series[, 2]
random_stl_data_bev <- stl_result$time.series[, 3]
autoplot(stl_result)

#
train_data_bev <- window(data_bev_ts, start = c(2018, 1), end = c(2021, 12))
test_data_bev <- window(data_bev_ts, start = c(2022, 1), end = c(2022, 12))
forecast_model <- tslm(train_data_bev ~ trend + season)
summary(forecast_model)

# ทำนายค่าของชุดทดสอบ
new_data <- data.frame(trend = trend_stl_data_bev, seasonal =
seasonal_stl_data_bev)
forecasted_values <- forecast(forecast_model, newdata = new_data)

# ทำนายค่าของชุดทดสอบในปี 2022
forecasted_values <- forecast(forecast_model, h = 12)
print(forecasted_values)

# หาค่าผลต่างระหว่างค่าจริงและค่าทำนาย
actual_values <- test_data_bev
predicted_values <- forecasted_values$mean

#
rmse <- sqrt(mean((actual_values - predicted_values)^2))
mape <- mean(abs((actual_values - predicted_values) / actual_values)) * 100

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4. วิธีแยกส่วนประกอบแบบคูณของรถยนต์ไฟฟ้าแบตเตอรี่

```
# (Import the Data)
```

```
data_bev1 <- c(0, 3, 1, 2, 10, 16, 20, 7, 2, 2, 5, 1, 8, 2, 1, 2, 12, 23, 4, 21, 42, 174, 224,
137, 265, 184, 120, 96, 61, 87, 57, 61, 61, 90, 71, 63, 155, 133, 173, 124, 154, 162, 113,
162, 255, 148, 171, 135, 261, 341, 634, 389, 509, 872, 575, 1184, 1065, 1216, 1296,
1242)
```

```
# data_bev
```

```
data_bev1_ts <- ts(data_bev1, start = c(2018, 1), frequency = 12)
```

```
# (Detect the Trend)
```

```
line_reg <- lm(log(data_bev1_ts) ~ time(data_bev1_ts))
```

```
trend_bev1 <- ts(exp(line_reg$fitted.values), start = c(2018, 1), frequency = 12)
```

```
# Time Series (Detrend the Time Series)
```

```
detrend_bev1 <- data_bev1_ts / trend_bev1
```

```
# Seasonal Index (Average the Seasonality)
```

```
m_bev1 <- matrix(data = detrend_bev1, nrow = 12, byrow = TRUE)
```

```
seasonal_bev1 <- rowMeans(m_bev1, na.rm = TRUE)
```

```
average_bev1 <- sum(seasonal_bev1) / frequency(data_bev1_ts)
```

```
seasonalindex_bev1 <- seasonal_bev1 / average_bev1
```

```
seasonalindex_bev1 <- ts(rep(seasonalindex_bev1, length.out =
length(data_bev1_ts)), start = c(2018, 1), frequency = 12)
```

```
# (Examining Remaining Random Noise)
```

```
random_bev1 <- data_bev1_ts / (trend_bev1 * seasonalindex_bev1)
```

```
# (Reconstruct the Original Signal)
```

```
recomposed_bev1 <- trend_bev1 * seasonalindex_bev1 * random_bev1
```

```
# STL (Seasonal-Trend decomposition using LOESS)
```

```
library(forecast)
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

stl_result <- stl(data_bev1_ts, s.window = "periodic", t.window = 12, l.window = 12,
robust = TRUE, na.action = na.omit)
print(stl_result)

```

```

stl(x = data_bev1_ts, s.window = "periodic", t.window = 12, l.window = 12,
robust = TRUE, na.action = na.omit)
seasonal_stl_data_bev1 <- stl_result$time.series[, 1]
trend_stl_data_bev1 <- stl_result$time.series[, 2]
random_stl_data_bev1 <- stl_result$time.series[, 3]
autoplot(stl_result)
print(stl_result)

```

```

stl(x = data_bev1_ts, s.window = "periodic", t.window = 12, l.window = 12,
robust = TRUE, na.action = na.omit)

#
train_data_bev1 <- window(data_bev1_ts, start = c(2018, 1), end = c(2021, 12))
test_data_bev1 <- window(data_bev1_ts, start = c(2022, 1), end = c(2022, 12))
forecast_model1 <- tslm(train_data_bev1 ~ trend * season)
summary(forecast_model1)
tslm(formula = train_data_bev1 ~ trend * season)
Residual standard error: 61.87 on 24 degrees of freedom
Multiple R-squared: 0.6674, Adjusted R-squared: 0.3486
F-statistic: 2.094 on 23 and 24 DF, p-value: 0.03923

```

```

#
new_data1 <- data.frame(trend = trend_stl_data_bev1, seasonal =
seasonal_stl_data_bev1)
forecasted_values1 <- forecast(forecast_model1, newdata = new_data)

```

```

# 2022
forecasted_values1 <- forecast(forecast_model1, h = 12)
print(forecasted_values1)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
predicted_values1 <- forecasted_values1$mean  
  
#  
rmse <- sqrt(mean((actual_values1 - predicted_values1)^2))  
mape <- mean(abs((actual_values1 - predicted_values1) / actual_values1)) * 100
```



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ค

### คำสั่ง และผลลัพธ์วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์

1. วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณของรถยนต์ไฟฟ้าไฮบริด

```
data_hev <- c(1045, 1266, 1536, 1561, 1891, 2252, 2010, 2104, 1825, 1695, 1626,
1191, 2389, 2249, 2279, 1967, 2320, 2315, 2109, 2484, 2393, 2427, 2130, 1362, 3096,
2850, 2800, 1777, 1417, 1647, 1739, 2619, 2874, 3271, 3014, 2217, 4518, 4352, 4602,
3305, 3744, 3417, 2123, 3417, 2971, 2723, 3403, 2765, 5057, 6289, 8546, 5519, 6385,
6639, 5261, 6728, 7745, 5887, 6006, 4738)
data_ts <- ts(data_hev, start = c(2018, 1), frequency = 12)
```

```
# Split the data into train and test sets
train_data <- window(data_ts, start = c(2018, 1), end = c(2021, 12))
summary(train_data)
```

# สร้างโมเดล Holt-Winters

```
hw_model <- HoltWinters(train_data, seasonal = "multiplicative")
> print(hw_model)
```

Holt-Winters exponential smoothing with trend and multiplicative seasonal component.

Call:

```
HoltWinters(x = train_data, seasonal = "multiplicative")
```

Smoothing parameters:

alpha: 0.8858259

beta : 0

gamma: 1

# ทำนายข้อมูลทดสอบ

```
forecast_data <- forecast(hw_model, h = length(data_ts) - length(train_data))
```

# สร้างกราฟข้อมูลทดสอบที่เรียนรู้จากชุดข้อมูลฝึกฝน

```
plot(forecast_data, main = "กราฟข้อมูลทดสอบที่เรียนรู้", ylab = "ฝึกฝน")
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
#
rmse <- sqrt(mean((data_ts - forecast_data$mean)^2))
mape <- mean(abs((data_ts - forecast_data$mean)/data_ts)) * 100
```

## 2. วิธีปรับให้เรียบแบบโฮลต์-วินเทอร์แบบคูณของรถยนต์ไฟฟ้าแบตเตอรี่

```
data <- c(0, 3, 1, 2, 10, 16, 20, 7, 2, 2, 5, 1, 8, 2, 1, 2, 12, 23, 4, 21, 42, 174, 224, 137,
265, 184, 120, 96, 61, 87, 57, 61, 61, 90, 71, 63, 155, 133, 173, 124, 154, 162, 113, 162,
255, 148, 171, 135, 261, 341, 634, 389, 509, 872, 575, 1184, 1065, 1216, 1296, 1242)
data_ts <- ts(data, start = c(2018, 1), frequency = 12)
```

```
# แบ่งข้อมูลเป็นชุดฝึกฝนและทดสอบ
```

```
train_data <- window(data_ts, start = c(2018, 1), end = c(2021, 12))
summary(train_data)
```

```
# สร้างโมเดล Holt-Winters
```

```
hw_model <- HoltWinters(train_data, seasonal = "multiplicative")
plot(hw_model, main = "Comparing training data and estimated values: BEVs", ylab =
"Fitted", xlab = "Year")
```

```
# Create Holt-Winters model
```

```
hw_model <- HoltWinters(train_data, seasonal = "multiplicative")
plot(hw_model, main = "Comparing training data and estimated values: BEVs", ylab =
"Fitted", xlab = "Year")
print(hw_model)
```

Holt-Winters exponential smoothing with trend and multiplicative seasonal component.

Call:

```
HoltWinters(x = train_data, seasonal = "multiplicative")
```

Smoothing parameters:

alpha: 0

beta : 0

gamma: 0.08131686

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# Forecast the test data using the trained Holt-Winters multiplicative model
forecast_data <- forecast(hw_model, h = length(data_ts) - length(train_data))
print(forecast_data)

# Compare the actual data with the forecasted data
plot(data_ts, main = "Actual VS Forecast BEVs: HW", ylab = "Data", xlab = "Year")
lines(forecast_data$mean, col = "red", lwd = 2)

#
rmse <- sqrt(mean((data_ts - forecast_data$mean)^2))
mape <- mean(abs((data_ts - forecast_data$mean) / data_ts)) * 100

```



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ง

### คำสั่ง และผลลัพธ์วิธีซัพพอร์ตเวกเตอร์แมชชีน

1. วิธีซัพพอร์ตเวกเตอร์แมชชีนของรถยนต์ไฟฟ้าไฮบริดแบบ EPS-Regression

```
data_hev <- c(1045, 1266, 1536, 1561, 1891, 2252, 2010, 2104, 1825, 1695, 1626,
1191, 2389, 2249, 2279, 1967, 2320, 2315, 2109, 2484, 2393, 2427, 2130, 1362, 3096,
2850, 2800, 1777, 1417, 1647, 1739, 2619, 2874, 3271, 3014, 2217, 4518, 4352, 4602,
3305, 3744, 3417, 2123, 3417, 2971, 2723, 3403, 2765, 5057, 6289, 8546, 5519, 6385,
6639, 5261, 6728, 7745, 5887, 6006, 4738)
```

```
# data_hev_ts
```

```
data_hev_ts <- ts(data_hev, start = c(2018, 1), frequency = 12)
```

```
# train and test sets
```

```
train_data <- window(data_hev_ts, start = c(2018, 1), end = c(2021, 12))
```

```
test_data <- window(data_hev_ts, start = c(2022, 1), end = c(2022, 12))
```

```
# data frame for train set
```

```
train_data_df <- data.frame(train_data = as.vector(train_data))
```

```
# data frame for test set
```

```
test_data_df <- data.frame(test_data = as.vector(test_data))
```

```
# SVR
```

```
tuned_model_eps <- tune(svm, train_data_df$train_data, train_data_df$train_data,
```

```
  ranges = list(eps = c(0.1), cost = c(100), gamma = c(0.01)),
```

```
  kernel = "radial",
```

```
  type = "eps-regression")
```

```
# SVR
```

```
svr_model <- svm(train_data_df$train_data, train_data_df$train_data,
```

```
  kernel = "radial", cost = tuned_model_eps$best.parameters$cost,
```

```
  gamma = tuned_model_eps$best.parameters$gamma,
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

eps = tuned_model_eps$best.parameters$eps)

# train set
predicted_train <- predict(svr_model, train_data_df$train_data)
print(predicted_train)

# test set ( 2022)
predicted_test <- predict(svr_model, test_data_df$test_data)
print(predicted_test)

# train set ( 2018 - 2021)
prediction_table_train <- data.frame(Date = seq(from = as.Date("2018-01-01"), by =
"month", length.out = length(predicted_train)),
  Predicted_Value = predicted_train,
  Actual_Value = train_data_df$train_data)

# test set ( 2022)
prediction_table_test <- data.frame(Date = seq(from = as.Date("2022-01-01"), by =
"month", length.out = length(predicted_test)),
  Predicted_Value = predicted_test,
  Actual_Value = test_data_df$test_data)

#
rmse <- sqrt(mean((predicted_test - test_data_df$test_data)^2))
mape <- mean(abs((predicted_test - test_data_df$test_data) /
test_data_df$test_data)) * 100

```

## 2. วิธีชี้พอร์ตเวคเตอร์แมชชีนของรถยนต์ไฟฟ้าไฮบริดแบบ NU-Regression

```

data_hev <- c(1045, 1266, 1536, 1561, 1891, 2252, 2010, 2104, 1825, 1695, 1626,
1191, 2389, 2249, 2279, 1967, 2320, 2315, 2109, 2484, 2393, 2427, 2130, 1362, 3096,
2850, 2800, 1777, 1417, 1647, 1739, 2619, 2874, 3271, 3014, 2217, 4518, 4352, 4602,
3305, 3744, 3417, 2123, 3417, 2971, 2723, 3403, 2765, 5057, 6289, 8546, 5519, 6385,
6639, 5261, 6728, 7745, 5887, 6006, 4738)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# data_hev_ts
data_hev_ts <- ts(data_hev, start = c(2018, 1), frequency = 12)

# Split the data into train and test sets
train_data <- window(data_hev_ts, start = c(2018, 1), end = c(2021, 12))
test_data <- window(data_hev_ts, start = c(2022, 1), end = c(2022, 12))

# Create a data frame for training data
train_data_df <- data.frame(train_data = as.vector(train_data))

# Perform parameter tuning
tuned_model_nu <- tune(svm, train_data_df$train_data, train_data_df$train_data,
  ranges = list(nu = c(0.4), cost = c(100), gamma = c(0.01)),
  kernel = "radial",
  type = "NU-Regression")

# Print the best parameters and performance
print(tuned_model_nu)

# ทำนาย train set
predicted_train_nu <- predict(tuned_model_nu$best.model,
  train_data_df$train_data)
print(predicted_train_nu)

# ทำนาย test set (2022)
predicted_test_nu <- predict(tuned_model_nu$best.model, test_data_df$test_data)
print(predicted_test_nu)

# สร้างอ็อบเจกต์แทนค่าจริงในชุด test
actual <- as.vector(test_data)

# แสดงค่า actual และ predictions
print(paste("actual:", actual))

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

print(paste("predictions:", predicted_test_nu))

# ทำนาย train set (2018 - 2021)
prediction_table_train_nu <- data.frame(Date = seq(from = as.Date("2018-01-01"), by
= "month", length.out = length(predicted_train_nu)),
      Predicted_Value = predicted_train_nu,
      Actual_Value = train_data_df$train_data)

# ทำนาย test set (2022)
prediction_table_test_nu <- data.frame(Date = seq(from = as.Date("2022-01-01"), by =
"month", length.out = length(predicted_test_nu)),
      Predicted_Value = predicted_test_nu,
      Actual_Value = test_data)

#
rmse <- sqrt(mean((predicted_test_nu - test_data)^2))
mape <- mean(abs((predicted_test_nu - test_data) / test_data)) * 100

3. วิธีซัพพอร์ตเวกเตอร์แมชชีนของรถยนต์ไฟฟ้าแบตเตอรี่แบบ EPS-Regression
# data_bev
data_bev <- c(0, 3, 1, 2, 10, 16, 20, 7, 2, 2, 5, 1, 8, 2, 1, 2, 12, 23, 4, 21, 42, 174, 224,
137, 265, 184, 120, 96, 61, 87, 57, 61, 61, 90, 71, 63, 155, 133, 173, 124, 154, 162, 113,
162, 255, 148, 171, 135, 261, 341, 634, 389, 509, 872, 575, 1184, 1065, 1216, 1296,
1242)

# time series object data_bev
data_bev_ts <- ts(data_bev, start = c(2018, 1), frequency = 12)

# train and test sets
train_data <- window(data_bev_ts, start = c(2018, 1), end = c(2021, 12))
test_data <- window(data_bev_ts, start = c(2022, 1), end = c(2022, 12))

# data frame for train set

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

train_data_df <- data.frame(train_data = as.vector(train_data))

# data frame for test set
test_data_df <- data.frame(test_data = as.vector(test_data))

# SVR
tuned_model_eps <- tune(svm, train_data_df$train_data, train_data_df$train_data,
                        ranges = list(eps = c(0.2), cost = c(100), gamma = c(0.01)),
                        kernel = "radial",
                        type = "eps-regression")

# SVR
svr_model <- svm(train_data_df$train_data, train_data_df$train_data,
                kernel = "radial", cost = tuned_model_eps$best.parameters$cost,
                gamma = tuned_model_eps$best.parameters$gamma,
                eps = tuned_model_eps$best.parameters$eps)

# train set
predicted_train <- predict(svr_model, train_data_df$train_data)
print(predicted_train)

# test set ( 2022)
predicted_test <- predict(svr_model, test_data_df$test_data)
print(predicted_test)

# train set ( 2018 - 2021)
prediction_table_train <- data.frame(Date = seq(from = as.Date("2018-01-01"), by =
"month", length.out = length(predicted_train)),
                                     Predicted_Value = predicted_train,
                                     Actual_Value = train_data_df$train_data)

# test set ( 2022)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
prediction_table_test <- data.frame(Date = seq(from = as.Date("2022-01-01"), by =
"month", length.out = length(predicted_test)),
Predicted_Value = predicted_test,
Actual_Value = test_data_df$test_data)
```

```
#
rmse <- sqrt(mean((predicted_test - test_data_df$test_data)^2))
mape <- mean(abs((predicted_test - test_data_df$test_data) /
test_data_df$test_data)) * 100
```

#### 4. วิธีใช้พอร์ตเวคเตอร์แมชชีนของรถยนต์ไฟฟ้าแบตเตอรี่แบบ NU-Regression

```
# data_bev
data_bev <- c(0, 3, 1, 2, 10, 16, 20, 7, 2, 2, 5, 1, 8, 2, 1, 2, 12, 23, 4, 21, 42, 174, 224,
137, 265, 184, 120, 96, 61, 87, 57, 61, 61, 90, 71, 63, 155, 133, 173, 124, 154, 162, 113,
162, 255, 148, 171, 135, 261, 341, 634, 389, 509, 872, 575, 1184, 1065, 1216, 1296,
1242)

# time series object data_bev
data_bev_ts <- ts(data_bev, start = c(2018, 1), frequency = 12)

# train and test sets
train_data <- window(data_bev_ts, start = c(2018, 1), end = c(2021, 12))
test_data <- window(data_bev_ts, start = c(2022, 1), end = c(2022, 12))

# data frame for train set
train_data_df <- data.frame(train_data = as.vector(train_data))

# data frame for test set
test_data_df <- data.frame(test_data = as.vector(test_data))

# SVR with NU-Regression
tuned_model_nu <- tune(svm, train_data_df$train_data, train_data_df$train_data,
```

```
ranges = list(nu = c(0.2), cost = c(100), gamma = c(0.01)),
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

kernel = "radial",
type = "NU-Regression ")

# SVR with NU-Regression
svr_model_nu <- svm(train_data_df$train_data, train_data_df$train_data,
kernel = "radial", cost = tuned_model_nu$best.parameters$cost,
gamma = tuned_model_nu$best.parameters$gamma,
nu = tuned_model_nu$best.parameters$nu)

# train set
predicted_train_nu <- predict(svr_model_nu, train_data_df$train_data)
print(predicted_train_nu)

# test set ( 2022)
predicted_test_nu <- predict(svr_model_nu, test_data_df$test_data)
print(predicted_test_nu)

# train set (2018 - 2021)
prediction_table_train_nu <- data.frame(Date = seq(from = as.Date("2018-01-01"), by
= "month", length.out = length(predicted_train)),
Predicted_Value = predicted_train_nu,
Actual_Value = train_data_df$train_data)

# test set (2022)
prediction_table_test_nu <- data.frame(Date = seq(from = as.Date("2022-01-01"), by =
"month", length.out = length(predicted_test)),
Predicted_Value = predicted_test_nu,
Actual_Value = test_data_df$test_data)

#
rmse <- sqrt(mean((predicted_test_nu - test_data_df$test_data)^2))
mape <- mean(abs((predicted_test_nu - test_data_df$test_data) /
test_data_df$test_data)) * 100

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ประวัติผู้เขียน

ชื่อ	นางสาวธนิศา กำเนิดนุกูล
วัน เดือน ปีเกิด	27 เมษายน 2535
ที่อยู่ปัจจุบัน	55/451 ซอยประเสริฐมนูกิจ 42 แขวงนวมินทร์ เขตบึงกุ่ม กรุงเทพมหานคร 10240
ประวัติการศึกษา	(2557) บริหารธุรกิจบัณฑิต สาขาการจัดการธุรกิจแบบบูรณาการ มหาวิทยาลัยธรรมศาสตร์
ประวัติการทำงาน	(2562 - ปัจจุบัน) ผู้เชี่ยวชาญด้านการตลาด บริษัท คาร์มา โมบิลิตี้ จำกัด



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้