

การทำนายอุปสงค์อะไหล่รถจักรยานยนต์โดยวิธีการผสมผสาน
ระหว่างเทคนิคการประมวลผลสัญญาณและเทคนิคการพยากรณ์
อนุกรมเวลา

Motorcycle Spare Parts Demand Forecasting Using a
Hybrid Approach of Signal Processing and Time
Series Forecasting Techniques




สหกิจศึกษานี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรบัณฑิต (สถิติประยุกต์)
ภาควิชาสถิติ คณะวิทยาศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ปีการศึกษา 2566
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Motorcycle Spare Parts Demand Forecasting Using a
Hybrid Approach of Signal Processing and Time
Series Forecasting Techniques



WADFAH KULRAT

ARUNRUT PUTTHIPRAYONGCHAI

A COOPERATIVE EDUCATION SUBMITTED IN PARTIAL
FULFILLMENT OF THE REQUIREMENT FOR
THE DEGREE OF BACHELOR OF SCIENCE (APPLIED STATISTICS)
DEPARTMENT OF STATISTICS, SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
ACADEMIC YEAR 2023

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อสหกิจศึกษา	การทำนายอุปสงค์อะไหล่รถจักรยานยนต์โดยวิธีการผสมผสานระหว่างเทคนิคการประมวลผลสัญญาณและเทคนิคการพยากรณ์อนุกรมเวลา Motorcycle Spare Parts Demand Forecasting Using a Hybrid Approach of Signal Processing and Time Series Forecasting Techniques
ชื่อนักศึกษา	นางสาววาดฟ้า กุศลรัตน์ รหัสนักศึกษา 63050661 นายอรุณรุจน์ พุฒิประยงค์ชัย รหัสนักศึกษา 630506690
ปริญญา	วิทยาศาสตรบัณฑิต (สถิติประยุกต์)
ภาควิชา	สถิติ
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์

คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.) อนุมัติให้สหกิจศึกษานี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต (สถิติประยุกต์) ประจำปีการศึกษา 2566

คณะกรรมการสอบ	ลายมือชื่อ
ผู้ช่วยศาสตราจารย์ ดร.กนกวรรณ ลิ้นโรจนางาม ประธานกรรมการ	<i>Kanokorn L.</i>
คุณ เรวัตร์ มากคงแก้ว กรรมการ	<i>15/10/25</i>
ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์ กรรมการและอาจารย์ที่ปรึกษา	<i>Pornpimol Chainuttisak</i>

ลิขสิทธิ์ของคณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สหกิจศึกษา	การทำนายอุปสงค์อะไหล่รถจักรยานยนต์โดยวิธีการผสมผสานระหว่างเทคนิคการประมวลผลสัญญาณและเทคนิคการพยากรณ์อนุกรมเวลา			
ชื่อนักศึกษา	นางสาววาดฟ้า	กุลรัตน์	รหัสนักศึกษา	63050661
	นายอรุณรุจน์	วุฒิประยงค์ชัย	รหัสนักศึกษา	630506690
ปริญญา	วิทยาศาสตรบัณฑิต (สถิติประยุกต์)			
ภาควิชา	สถิติ			
คณะ	วิทยาศาสตร์			
มหาวิทยาลัย	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.)			
ปีการศึกษา	2566			
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์			

บทคัดย่อ

รถจักรยานยนต์เป็นยานพาหนะสองล้อที่ใช้กันอย่างแพร่หลายของประชาชนในประเทศไทย โดยการบำรุงรักษาและเปลี่ยนชิ้นส่วนอะไหล่รถจักรยานยนต์เป็นสิ่งที่ควรคำนึงเพื่อความปลอดภัยในการขับขี่ โดยงานวิจัยนี้มีวัตถุประสงค์เพื่อพยากรณ์อุปสงค์รายเดือนของสินค้าอะไหล่รถจักรยานยนต์ A โดยอาศัยการผสมผสานระหว่างวิธีการพยากรณ์และเทคนิคเชิงประจักษ์ และเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์ และผลการศึกษาพบว่าตัวแบบพยากรณ์ผสมระหว่าง SARIMA และเทคนิคเชิงประจักษ์มีประสิทธิภาพในการพยากรณ์อุปสงค์ของอะไหล่รถจักรยานยนต์รายเดือน ได้ดีกว่าตัวแบบพยากรณ์เชิงเดี่ยว ส่งผลให้องค์กรสามารถนำค่าพยากรณ์ไปประกอบการตัดสินใจสำหรับวางแผนกลยุทธ์ บริหารจัดการสินค้าคงคลัง ลดค่าเสียโอกาสทางการขาย และเตรียมพร้อมรับมือกับความต้องการของตลาดได้อย่างมีประสิทธิภาพงาน โดยเฉพาะธุรกิจอะไหล่รถจักรยานยนต์

คำสำคัญ : การพยากรณ์อุปสงค์, อะไหล่รถจักรยานยนต์, เทคนิคเชิงประจักษ์, ตัวแบบพยากรณ์เชิงเดี่ยว, ตัวแบบพยากรณ์ผสม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Title	Motorcycle Spare Parts Demand Forecasting Using a Hybrid Approach of Signal Processing and Time Series Forecasting Techniques		
Students	Miss Wadfah Kulrat	StudentID	63050661
	Mr. Arunrut Putthiprayongchai	StudentID	63050690
Degree	Bachelor of Science (Applied Statistics)		
Department	Statistics		
School	Science		
University	King Mongkut's Institute of Technology Ladkrabang (KMITL)		
Academic Year	2023		
Advisor	Asst Prof. Dr. Pornpimol Chaiwuttisak		

Abstract

Motorcycles are a widely used two-wheeled vehicle among people in Thailand. Maintenance and replacement of motorcycle parts should be considered for safe riding. This research focuses on motorcycle spare parts A, intending to forecast monthly demand using a combination of forecasting methods and Empirical Mode Decomposition techniques and comparing the efficiency of forecasting models. Motorcycle spare part A. The study showed that the hybrid forecasting model combining SARIMA and Empirical Mode Decomposition techniques is more effective in predicting monthly demand for motorcycle spare parts than single forecasting models. As a result, organizations can use these forecasts to make decisions for strategic planning, and inventory management, reduce sales opportunity costs, and efficiently prepare for market demands, especially in the motorcycle spare parts business.

Keywords: Demand Forecasting, Motorcycle Spare Parts, Empirical Mode Decomposition, Single Forecasting Model, Hybrid Forecasting Model

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

โครงการสหกิจศึกษาเล่มนี้สำเร็จไปได้โดยดี เนื่องจากได้รับความกรุณาเป็นอย่างสูงจากผู้มีส่วนเกี่ยวข้องทุกท่าน ที่ได้ให้ความช่วยเหลือและคำแนะนำต่างๆ ตลอดระยะเวลาที่ทำสหกิจศึกษาทำให้โครงการสหกิจศึกษาเล่มนี้สมบูรณ์ไปได้ด้วยดี ผู้วิจัยจึงขอขอบพระคุณผู้ที่มีส่วนเกี่ยวข้องดังต่อไปนี้

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิสักดิ์ อาจารย์ที่ปรึกษาสหกิจ ที่คอยชี้แนะแนวทางแนะนำ ตรวจสอบตรา สละเวลาในการตรวจสอบ และคอยช่วยเหลือในทุก ๆ ด้านด้วยความเต็มใจในการทำสหกิจศึกษาครั้งนี้ จึงขอกราบพระคุณด้วยความเคารพเป็นอย่างสูงไว้ ณ ที่นี้ด้วย

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.กนกภรณ์ ลีโรจนาประภาประธานกรรมการ คณะกรรมการสอบที่กรุณาให้คำแนะนำในการแก้ไขปรับปรุงเพิ่มเติมจนทำให้การทำสหกิจครั้งนี้มีความสมบูรณ์ยิ่งขึ้น

ขอขอบพระคุณบริษัทแห่งหนึ่ง ที่ให้สถานที่ในการทำงาน จนจบโครงการสหกิจศึกษา

ขอขอบพระคุณ เรวัตร์ มากคงแก้วผู้ที่ได้มอบหมายหัวข้อการทำสหกิจศึกษาในครั้งนี้ รวมทั้งขอขอบคุณพี่ ๆ ในบริษัทที่คอยให้คำแนะนำ ให้ความรู้ และวิธีการทำงานต่าง ๆ ทั้งที่เกี่ยวข้องกับโครงการสหกิจศึกษาจนลุล่วงไปได้ด้วยดี

ขอขอบคุณเพื่อน ๆ พี่ ๆ น้อง ๆ ทุกคน ที่ร่วมทุกข์ร่วมสุข และให้ความช่วยเหลือเกื้อกันด้วยดีตลอดมา

สุดท้ายนี้ขอขอบพระคุณบุคคลที่ไม่ได้กล่าวมาที่มีส่วนเกี่ยวข้องอื่นๆ ข้าพเจ้าหวังว่าโครงการสหกิจฉบับนี้จะมีประโยชน์แก่ผู้ที่สนใจ เพื่อนำไปประยุกต์ใช้ให้เกิดประโยชน์และความรู้ด้านอื่น ๆ ต่อไป หากมีข้อผิดพลาดประการใด ข้าพเจ้าขออภัยไว้ ณ ที่นี้ และจะนำไปปรับปรุง พัฒนา และแก้ไขในโอกาสต่อไป

วาดฟ้า

กุลรัตน์

อรุณรุจน์

พุดิประยงค์ชัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	จ
สารบัญรูป	ฉ
คำย่อ/สัญลักษณ์	ช
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญ	1
1.2 วัตถุประสงค์	2
1.3 ขอบเขต.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 นิยามศัพท์เฉพาะ	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 การวิเคราะห์ข้อมูลเบื้องต้น.....	4
2.1.1 การแจกแจงปรกติ	4
2.1.2 การทดสอบแนวโน้มและอิทธิพลฤดูกาล	5
2.1.3 การแปลงอนุกรมเวลาให้เป็นสเตชันนารีด้วยวิธีหาผลต่าง (Differencing).....	7
2.1.4 ค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองและ ค่าสัมประสิทธิ์สหสัมพันธ์ ในตัวเองบางส่วน.....	8
2.1.5 ตัวแบบพยากรณ์ด้วยวิธี Box - Jenkins สำหรับอนุกรมเวลา	9
2.1.6 ขั้นตอนการพยากรณ์โดยวิธีของBox-Jenkins.....	11
2.2 ทฤษฎีเกี่ยวกับการประมวลสัญญาณ.....	12
2.2.1 นิยามหรือความหมายที่เกี่ยวข้องกับการประมวลสัญญาณ.....	12
2.2.2 เทคนิคเชิงประจักษ์(Empirical Mode Decomposition, EMD).....	13
2.3 วิศวกรรมคุณลักษณะ (Feature Engineering)	16
2.3.1 นิยามของ Feature Engineering	16
2.3.2 ความสำคัญของ Feature Engineering	16
2.4 โครงสร้างประสาทเทียมหน่วยความจำระยะยาว-ระยะสั้น (Long Short-Term (Long Short-Term Memory, LSTM).....	16
2.5 ภาษาไพธอน (Python Programming Language).....	19

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

	หน้า
2.6 การวัดประสิทธิภาพของตัวแบบพยากรณ์	21
2.6.1 วิธีค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์	21
2.6.2 ค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนสมมาตร	21
2.7 งานวิจัยที่เกี่ยวข้อง.....	22
2.7.1 งานวิจัยที่มีการประยุกต์ใช้ตัวแบบ ARIMA ร่วมกับเทคนิคเชิงประจักษ์.....	22
2.7.2 งานวิจัยที่มีการประยุกต์ใช้ตัวแบบ SARIMA ร่วมกับเทคนิคเชิงประจักษ์...	23
2.7.3 งานวิจัยที่มีการประยุกต์ใช้ตัวแบบ LSTM ร่วมกับเทคนิคเชิงประจักษ์	23
บทที่ 3 วิธีการดำเนินงานวิจัย	25
3.1 ขั้นตอนการดำเนินงาน	25
3.2 เครื่องมือที่ใช้ในงานวิจัย.....	27
3.2.1 ซอฟต์แวร์ (Software)	27
3.2.2 ฮาร์ดแวร์ (Hardware)	27
3.2.3 ชุดคำสั่งที่ใช้ในงานวิจัย (Library).....	27
3.3 การจัดเตรียมข้อมูล.....	27
3.3.1 การแบ่งข้อมูล (split Data).....	28
3.4 การวิเคราะห์ข้อมูล	28
3.4.1 การวิเคราะห์การแจกแจงของข้อมูล	28
3.4.2 การวิเคราะห์อนุกรมเวลาโดยวิธีบ็อกซ์-เจนกินส์	29
3.4.3 การสร้างตัวแบบพยากรณ์ด้วยวิธีบ็อกซ์-เจนกินส์.....	29
3.4.4 การพยากรณ์ด้วยวิธี LSTM	30
3.5 การพยากรณ์ยอดขายอะไหล่รถจักรยานยนต์ด้วยวิธีผสม.....	31
3.6 เกณฑ์การประเมินประสิทธิภาพของตัวแบบพยากรณ์.....	31
บทที่ 4 ผลการวิจัยและการอภิปรายผล	33
4.1 ผลการวิเคราะห์ข้อมูลเบื้องต้น.....	33
4.1.1 ผลการวิเคราะห์ปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A	33
4.1.2 การทดสอบการแจกแจงปกติของปริมาณการสั่งซื้อสินค้าอะไหล่ รถจักรยานยนต์A	34
4.1.3 การทดสอบแนวโน้มแบบไม่อิงพารามิเตอร์ โดย ใช้การทดสอบของแดนเนียล(Danial's Test).....	35
4.1.4 การทดสอบอหิพลักษณะแบบไม่อิงพารามิเตอร์ โดยใช้การทดสอบ ของครัสคาลวอลลิส	36
4.1.5 ผลการสร้างตัวแบบพยากรณ์เชิงเดี่ยวด้วยวิธีการบ็อก-เจนกินส์.....	37
4.1.6 ผลการสร้างตัวแบบพยากรณ์เชิงเดี่ยวด้วยวิธีการเรียนรู้เชิงลึก.....	44

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

	หน้า
4.2 การแยกสัญญาณรบกวนด้วยเทคนิคเชิงประจักษ์	45
4.2.1 ผลการสร้างตัวแบบผสมกับเทคนิคเชิงประจักษ์.....	46
4.3 การเปรียบเทียบผลประสิทธิผลของตัวแบบพยากรณ์.....	55
4.3.1 ผลลัพธ์ที่ได้จากการเปรียบเทียบค่าพยากรณ์กับค่าจริง.....	55
4.3.2 การเปรียบเทียบความคลาดเคลื่อนของตัวแบบเชิงเดี่ยว	56
4.3.3 การเปรียบเทียบความคลาดเคลื่อนของตัวแบบผสม.....	57
4.3.4 การเปรียบเทียบความคลาดเคลื่อนระหว่างตัวแบบเชิงเดี่ยวกับ ตัวแบบผสม	58
4.4 การอภิปรายผล.....	59
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	60
5.1 สรุปผลการวิจัย.....	60
5.1.1 วัตถุประสงค์ข้อที่ 1	60
5.1.2 วัตถุประสงค์ข้อที่ 2	60
5.2 ข้อจำกัดและข้อเสนอแนะ.....	61
5.2.1 ข้อเสนอแนะ.....	61
เอกสารอ้างอิง.....	62
ภาคผนวก.....	66
ภาคผนวก ก.....	67
ภาคผนวก ข.....	84
ภาคผนวก ค.....	92
ภาคผนวก ง.....	107

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1	ลักษณะของ ACF และ PACF ของตัวแบบ SARIMA 8
2.2	ข้อดีและข้อเสียของการประมวลผลสัญญาณอนาล็อก 13
2.3	ข้อดีและข้อเสียของการประมวลผลสัญญาณดิจิทัล 13
4.1	การทดสอบค่าพารามิเตอร์ของตัวแบบ ARIMA(4,1,1)..... 39
4.2	ค่า AIC ในแต่ละอันดับของตัวแบบ ARIMA(p,d,q)..... 39
4.3	การทดสอบค่าพารามิเตอร์ ARIMA(p,d,q)..... 40
4.4	การทดสอบความเป็นอิสระของค่าความคลาดเคลื่อนของตัวแบบ ARIMA ด้วย Box Pierce and Ljung-Box Test 41
4.5	ค่าพารามิเตอร์ของตัวแบบที่เหมาะสมที่สุดของตัวแบบ ARIMA 41
4.6	การทดสอบค่าพารามิเตอร์ของตัวแบบ $ARIMA(4,1,1) \times SARIMA(1,1,1)_{12}$ 41
4.7	ค่า AIC ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$ 42
4.8	การทดสอบค่าพารามิเตอร์ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$ 43
4.9	การทดสอบความเป็นอิสระของค่าความคลาดเคลื่อนของตัวแบบ SARIMA ด้วย Box Pierce and Ljung-Box Tests..... 44
4.10	ค่าพารามิเตอร์ของตัวแบบที่เหมาะสมที่สุดของตัวแบบ SARIMA..... 44
4.11	การกำหนดค่าไฮเปอร์พารามิเตอร์ 45
4.12	การเปรียบเทียบค่า MAPE สำหรับแต่ละ Epoch ของตัวแบบ LSTM..... 45
4.13	ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ ARIMA(p,d,q)..... 46
4.14	ค่า AIC ของ IMF 2 ในแต่ละอันดับของตัวแบบ ARIMA(p,d,q)..... 47
4.15	ค่า AIC ของ IMF 3 ในแต่ละอันดับของตัวแบบ ARIMA(p,d,q)..... 47
4.16	ค่า AIC ของ IMF 4 ในแต่ละอันดับของตัวแบบ ARIMA(p,d,q)..... 48
4.17	ค่า AIC ของ Residual ในแต่ละอันดับของตัวแบบ ARIMA(p,d,q)..... 48
4.18	สรุป AIC ที่น้อยที่สุดของแต่ละ IMF ใน SARIMA..... 49
4.19	ค่า IMF ของตัวแบบ EMD-ARIMA..... 49
4.20	ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$ 50
4.21	ค่า AIC ของ IMF 2 ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$ 50
4.22	ค่า AIC ของ IMF 3 ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$ 51
4.23	ค่า AIC ของ IMF 4 ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$ 52

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง(ต่อ)

ตารางที่	หน้า
4.24 ค่า AIC ของ Residual ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_{12}$	52
4.25 ค่า AIC ของตัวแบบที่ใช้ใน EMD-SARIMA.....	53
4.26 ค่า IMF ของตัวแบบ EMD-SARIMA	53
4.27 การกำหนดค่าไฮเปอร์พารามิเตอร์	54
4.28 การเปรียบเทียบค่า MAPE สำหรับแต่ละ Epoch ของตัวแบบ EMD-LSTM	54
4.29 ผลลัพธ์ที่ได้จากการเปรียบเทียบผลพยากรณ์กับค่าจริง.....	55
4.30 การเปรียบเทียบประสิทธิภาพตัวแบบเชิงเดี่ยว	56
4.31 การเปรียบเทียบประสิทธิภาพของตัวแบบผสม	57
4.32 การเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเดี่ยวและตัวแบบผสม.....	58



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 กราฟแจกแจงปรกติ.....	4
2.2 สัญญาณอนาล็อก	13
2.3 สัญญาณดิจิทัล.....	13
2.4 แผนภาพแสดงขั้นตอนการวิเคราะห์เทคนิคเชิงประจักษ์.....	14
2.5 สัญญาณตั้งต้นและกลุ่มสัญญาณ IMF ด้วยเทคนิคเชิงประจักษ์	15
2.6 กระบวนการทำ Feature Engineering.....	16
2.7 โครงสร้างการทำงานของ RNN	16
2.8 โครงสร้างการทำงานของ LSTM.....	17
2.9 โครงสร้าง Forget gate layer.....	17
2.10 โครงสร้าง Input Gate Layer	18
2.11 Output gate layer	19
3.1 ขั้นตอนการดำเนินงาน	26
3.2 ตัวอย่างข้อมูล “สินค้าอะไหล่รถจักรยานยนต์ A” ก่อนทำการแปลงข้อมูล	28
3.3 ตัวอย่างข้อมูล “สินค้าอะไหล่รถจักรยานยนต์ A” ที่ทำการแปลงเป็นข้อมูลอนุกรมเวลา ..	28
3.4 อนุกรมเวลาจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A.....	29
4.1 อนุกรมเวลาจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A.....	33
4.2 ฮิสโทแกรมของปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A.....	34
4.3 การทดสอบการแจกแจงปรกติคอลโมโกรอฟ-สมิร์นอฟ	35
4.4 อนุกรมเวลาจากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง.....	37
4.5 คอเรลโรลแกรม Autocorrelation Function (ACF) ของอนุกรมจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ที่จากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง.....	38
4.6 คอเรลโรลแกรม Partial Autocorrelation Function (PACF) ของอนุกรมจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ที่จากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง.....	38
4.7 องค์ประกอบสัญญาณที่ได้จากการแยกส่วนประกอบโดยใช้เทคนิคเชิงประจักษ์.....	46
4.8 กราฟแสดงการเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเดี่ยว.....	57
4.9 กราฟแสดงการเปรียบเทียบประสิทธิภาพของตัวแบบผสม.....	58
4.10 การเปรียบเทียบประสิทธิภาพในการพยากรณ์ค่าพยากรณ์ของทุกตัวแบบพยากรณ์	59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คำย่อ/สัญลักษณ์

คำย่อ/สัญลักษณ์	คำอธิบาย
EMD	Empirical Mode Decomposition
ARIMA	Autoregressive Integrated Moving Average
SARIMA	Seasonal Autoregressive Integrated Moving Average
LSTM	Long Short-Term Memory
EMD-ARIMA	Empirical Mode Decomposition - Autoregressive
EMD-SARIMA	Empirical Mode Decomposition - Seasonal
EMD-LSTM	Empirical Mode Decomposition - Long Short-Term
MAPE	Mean Absolute Percentage Error
IMFs	Intrinsic Mode Functions



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ตัวแบบพยากรณ์อนุกรมเวลาเป็นเครื่องมือหนึ่งที่ได้รับคามนิยมและเป็นที่ยอมรับว่ามีประสิทธิภาพที่นำมาใช้ในแก้ปัญหาและพยากรณ์ข้อมูลในอนาคตเพื่อช่วยในการตัดสินใจ (ชนกร, 2566) แต่อย่างไรก็ตาม ตัวแบบพยากรณ์อนุกรมเวลายังมีข้อจำกัด กล่าวคือ ถ้าข้อมูลอนุกรมเวลาที่นำมาพยากรณ์มีความถี่หรือความกว้างไวของข้อมูลมาก จะส่งผลให้เกิดความแม่นยำในการพยากรณ์ที่ต่ำ และมีความคลาดเคลื่อนที่สูง ด้วยเหตุนี้จึงได้มีการนำเทคนิคประมวลผลสัญญาณ (Signal Processing) ซึ่งเป็นเทคนิคที่ใช้ในการจัดการกับสัญญาณและข้อมูลต่าง ๆ มาผสมกับตัวแบบพยากรณ์อนุกรมเวลา เพื่อปรับปรุงประสิทธิภาพของการพยากรณ์ให้ดีขึ้น

การประมวลผลสัญญาณได้ถูกนำไปประยุกต์ใช้ร่วมกับการพยากรณ์อนุกรมเวลา การประมวลผลสัญญาณมีหลายเทคนิค โดยเทคนิคเชิงประจักษ์ (Empirical Mode Decomposition, EMD) เป็นการประมวลผลสัญญาณที่นำมาใช้ในการลดความถี่หรือสัญญาณแกว่งไวของข้อมูลก่อนนำไปพยากรณ์ ซึ่งจะช่วยแก้ปัญหาในเรื่องความแม่นยำของการพยากรณ์ที่ยังไม่สูงพอ (ชนกร และ สุรัตน์, 2563) เทคนิคเชิงประจักษ์เป็นเทคนิคที่พัฒนามาเพื่อแยกองค์ประกอบของสัญญาณที่ไม่เป็นเชิงเส้น (Non-Linear) และไม่คงที่ (Non-Stationary) เพื่อให้ข้อมูลมีความคงที่ (Yang and Chang, 2009)

คณะผู้วิจัยสนใจศึกษาการนำวิธีการพยากรณ์เชิงเดี่ยว ได้แก่ ARIMA, SARIMA และ LSTM เนื่องจากทั้ง 3 ตัวแบบมีประสิทธิภาพในการพยากรณ์ที่ดีและมีการนิยมใช้อย่างแพร่หลาย มาผสมกับเทคนิคเชิงประจักษ์ ตัวอย่างงานวิจัยที่มีการประยุกต์ใช้เทคนิคเชิงประจักษ์ร่วมกับตัวแบบพยากรณ์อนุกรมเวลาเชิงเดี่ยว ได้แก่ งานวิจัยของ Miao et al. (2023) ได้ศึกษาเกี่ยวกับการพยากรณ์ติดตามสถานะจราจรแบบเรียลไทม์ โดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยวแบบดั้งเดิมกับตัวแบบงานวิจัยของ Liu et al. (2022) ได้ศึกษาการพยากรณ์ระยะเวลาที่แบตเตอรี่ลิเทียมไอออนที่ใช้งานได้เพื่อหาความเสถียรของแบตเตอรี่ โดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยวแบบดั้งเดิม ได้แก่ ARIMA กับตัวแบบผสม และ Nandan and Tripathi (2023) ได้ศึกษาการพยากรณ์ผลกระทบของการเปลี่ยนแปลงสภาพภูมิอากาศต่ออุณหภูมิป็นเดือนโดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยวแบบดั้งเดิม ได้แก่ SARIMA กับตัวแบบผสม ผลการวิจัยพบว่า ตัวแบบผสมให้ประสิทธิภาพในการพยากรณ์ที่ดีที่สุดของทุกงานวิจัย นอกจากนี้ LSTM มีความสามารถประมาณฟังก์ชันต่อเนื่องไม่เชิงเส้นใด ๆ ก็ได้โดยไม่ต้องกำหนดรูปแบบอย่างเป็นทางการให้กับตัวแบบ (Niu and Wang, 2014) ทั้งนี้ คณะผู้วิจัยคาดว่าตัวแบบผสมจะช่วยเพิ่มประสิทธิภาพและความแม่นยำของตัวแบบพยากรณ์ได้ดีกว่าตัวแบบพยากรณ์เชิงเดี่ยว ในการศึกษาวิจัยครั้งนี้ คณะผู้วิจัยได้อาศัยข้อมูลปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ของบริษัทแห่งหนึ่ง ซึ่งเป็นข้อมูลอนุกรมเวลาที่มีความแกว่งไว เนื่องจากมาจากหลายปัจจัยที่มีผลกระทบต่อการเปลี่ยนแปลงของข้อมูลในอนุกรมเวลา ได้แก่ ความผันผวนของตลาดภาวะเศรษฐกิจที่มีผลต่อการซื้อขายสินค้าอะไหล่เป็นอย่างมาก การพัฒนาเทคโนโลยีใหม่ๆ ในวงการรถจักรยานยนต์ ผู้บริโภคอาจมีความต้องการอะไหล่ที่ทันสมัยและเข้ากับเทคโนโลยีในยุคปัจจุบัน ผลการศึกษานี้ จะช่วยให้องค์กรสามารถนำค่าพยากรณ์ที่แม่นยำไปประกอบการตัดสินใจในการ

วางแผนกลยุทธ์และดำเนินงานต่าง ๆ ส่งผลต่อการเพิ่มประสิทธิภาพการบริหารจัดการสินค้าคงคลัง และลดค่าเสียโอกาสของยอดขายที่จะเกิดขึ้นในอนาคต

1.2. วัตถุประสงค์ของงานวิจัย

1. เพื่อสร้างตัวแบบพยากรณ์ที่เหมาะสมสำหรับพยากรณ์อุปสงค์สินค้า A ของอะไหล่รถจักรยานยนต์โดยอาศัยเทคนิคอนุกรมเวลาและการเรียนรู้เชิงลึก
2. เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์เมื่อมีการผสมเทคนิคเชิงประจักษ์ในขั้นตอนการเตรียมข้อมูลกับตัวแบบพยากรณ์เชิงเดี่ยวแบบดั้งเดิม

1.3. ขอบเขตของงานวิจัย

1.3.1. ขอบเขตด้านข้อมูล

งานวิจัยนี้ใช้ข้อมูลจากบริษัทเอกชนแห่งหนึ่ง ซึ่งเป็นข้อมูลทุติยภูมิ โดยข้อมูลที่ใช้ในการศึกษาครั้งนี้เป็นข้อมูลอนุกรมเวลารายเดือนจำนวนยอดขายสินค้าอะไหล่รถจักรยานยนต์

1.3.2. ขอบเขตด้านระยะเวลา

ข้อมูลรายเดือนถูกเก็บรวบรวมตั้งแต่เดือนมกราคม พ.ศ. 2557 ถึง เดือนธันวาคม พ.ศ. 2565 สำหรับการสร้างตัวแบบพยากรณ์ และข้อมูลเดือนมกราคม พ.ศ. 2566 ถึง เดือนพฤศจิกายน พ.ศ. 2566 ระยะเวลา 11 เดือนมาใช้ในการทดสอบประสิทธิภาพของตัวแบบพยากรณ์

1.3.3. ขอบเขตด้านเครื่องมือ

เครื่องมือที่ใช้สำหรับการจัดเตรียมข้อมูลและสร้างตัวแบบ ได้แก่

1. ภาษาไพธอนเวอร์ชันที่ 3 (Python3) บน Jupyter Notebook และ Pycharm
2. โปรแกรมสำเร็จรูป Minitab

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถนำค่าพยากรณ์ไปใช้ประกอบการวางแผนการผลิตอะไหล่รถจักรยานยนต์ให้เพียงพอต่อความต้องการและสำรองสินค้าให้มีการจำหน่ายได้ตลอด
2. สามารถนำค่าพยากรณ์ได้ไปเป็นแนวทางหรือข้อมูลเพิ่มเติมในการตัดสินใจการวางแผนกลยุทธ์และการบริหารจัดการสินค้าคงคลัง
3. สามารถนำแนวคิดการพัฒนาตัวแบบผสมไปประยุกต์ในการพยากรณ์อะไหล่รถจักรยานยนต์อื่น ๆ ต่อไป

1.5. นิยามศัพท์เฉพาะ

1. เทคนิคเชิงประจักษ์ (Empirical Mode Decomposition, EMD) เป็นเทคนิคการวิเคราะห์สัญญาณแบบยืดหยุ่น ที่สามารถแยกสัญญาณออกเป็นองค์ประกอบย่อยที่มีความหมายทางกายภาพ โดยไม่ต้องพึ่งพาฟังก์ชันฐานที่กำหนดไว้ล่วงหน้า

2. สัญญาณแกว่งไว คือ สัญญาณที่ยากต่อการคาดเดา มีหลายปัจจัยเข้ามาทำให้เกิดการเปลี่ยนแปลงที่ไม่แน่นอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ตัวแบบพยากรณ์เชิงเดี่ยว คือ โมเดลหรือวิธีการที่ใช้กันมานาน มีการพิสูจน์แล้วว่า มีประสิทธิภาพ และเป็นที่ยอมรับในวงกว้าง เป็นโมเดลพื้นฐานที่ไม่ได้มีการผสมวิธีการอื่นๆ

4. ตัวแบบผสม คือ โมเดลทางสถิติที่ดึงข้อดีของโมเดลหลายตัวมาเข้าด้วยกันเพื่อพัฒนาโมเดลใหม่ที่มีประสิทธิภาพมากขึ้น โมเดลเหล่านี้มักใช้ในงานวิเคราะห์ข้อมูลและการพยากรณ์ โดยเฉพาะอย่างยิ่งเมื่อโมเดลเดี่ยวไม่สามารถอธิบายหรือคาดการณ์ข้อมูลได้อย่างแม่นยำ ในงานวิจัยนี้จะเป็นการนำเทคนิคเชิงประจักษ์มาประยุกต์ใช้ร่วมกับเทคนิคการพยากรณ์อนุกรมเวลา

5. วิศวกรรมคุณลักษณะ คือกระบวนการแปลงข้อมูลดิบเพื่อช่วยทำให้โมเดลมีประสิทธิภาพมากขึ้น



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในการศึกษาวิจัยครั้งนี้ ผู้วิจัยได้มีการศึกษาแนวคิดและทฤษฎีที่เกี่ยวข้อง ก่อนทำการวิจัยเพื่อใช้ประกอบการศึกษางานวิจัยเรื่อง “การทำนายอุปสงค์อะไหล่รถจักรยานยนต์โดยวิธีการประมวลผลสัญญาณและเทคนิคอนุกรมเวลา” โดยมีรายละเอียดดังต่อไปนี้

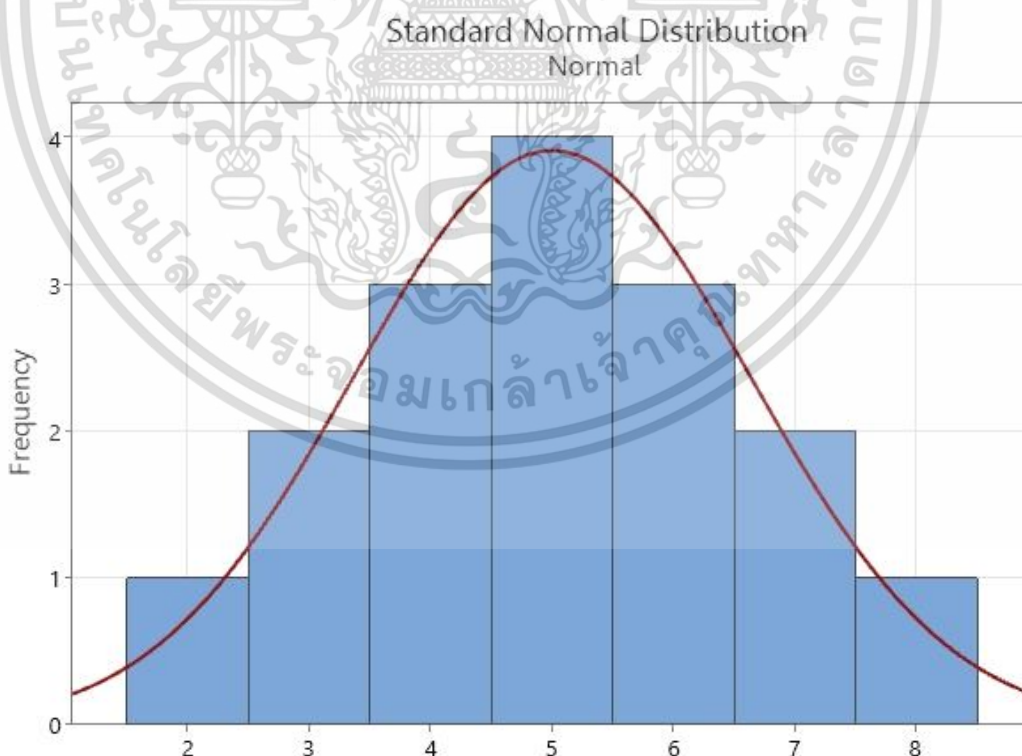
2.1. การวิเคราะห์ข้อมูลเบื้องต้น

2.1.1. การทดสอบการแจกแจงปกติ

การวิเคราะห์ข้อมูลโดยอาศัยสถิติที่ใช้พารามิเตอร์ จะมีข้อตกลงเบื้องต้นว่าข้อมูลนั้นต้องถูกสุ่มมาจากประชากรที่มีการแจกแจงปกติ ดังนั้นก่อนการวิเคราะห์ข้อมูลจึงควรมีการทดสอบก่อนว่าข้อมูลถูกสุ่มมาจากประชากรที่มีการแจกแจงปกติ โดยมีวิธีการดังนี้

1. ฮิสโตแกรม (Histogram)

การตรวจสอบการแจกแจงปกติโดยใช้กราฟฮิสโตแกรม การแบ่งอันตรภาคชั้นนั้นอาจทำให้ลักษณะของกราฟมีการแตกต่างกันไป และเป็นการพิจารณาของแต่ละบุคคลซึ่งมีการมองเห็นที่อาจจะแตกต่างกัน Histogram เป็นกราฟแท่ง ซึ่งข้อมูลที่มีการแจกแจงเป็นโค้งปกติ ข้อมูลส่วนใหญ่จะกระจุกตัวใกล้ค่าเฉลี่ย (ตรงกลาง) คล้ายระฆังคว่ำ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้รูปที่ 2.1 กราฟแจกแจงปกติ ญาติให้หน้าไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. การทดสอบคอลโมโกรอฟ-สมิร์นอฟ (Kolmogorov-Smirnov Test)

การทดสอบว่าเป็นข้อมูลตัวอย่างสุ่มจากประชากรที่มีการแจกแจงหรือไม่ ต้องกำหนดค่าพารามิเตอร์คือค่าเฉลี่ยและค่าความแปรปรวน ข้อมูลที่นำมาทดสอบโดยใช้ คอลโมโกรอฟ-สมิร์นอฟ จะต้องเป็นข้อมูลเชิงปริมาณ มีมาตราวัดแบบเรียงลำดับ (Ordinal Scale) และข้อมูลต้องมีค่ามากกว่าหรือเท่ากับ 50 (Chakravart et al.,1967) ขั้นตอนการคำนวณค่าเพื่อทดสอบการแจกแจงปกติด้วยคอลโมโกรอฟ-สมิร์นอฟ มีดังนี้

1. กำหนดสมมติฐาน

H_0 : ข้อมูลมีการแจกแจงแบบปกติ

H_1 : ข้อมูลไม่มีการแจกแจงแบบปกติ

2. กำหนดให้ข้อมูลที่เก็บได้เรียงจากน้อยไปมาก มีค่าเป็น $x_1, x_2, x_3, \dots, x_n$ โดยที่ x_n มีค่ามากที่สุด

3. ตัวสถิติทดสอบ ดังสมการที่ 2.1

$$D = \max(\max_{1 \leq i \leq n} [\frac{i}{n} - F(X_{(i)})], \max_{1 \leq i \leq n} [F(X_{(i)}) - \frac{i-1}{n}]) \quad (2.1)$$

เมื่อ $F(X_{(i)})$ คือ ขอบเขตล่างของการแจกแจงตามลำดับฟังก์ชันการแจกแจงสะสมของข้อมูลที่ตรวจสอบที่ประเมินที่ $(X_{(i)})$ ซึ่งเป็นค่าตัวอย่างที่ i ในข้อมูลที่ตรวจสอบ

n คือ ขนาดของข้อมูลที่ตรวจสอบ

\max คือ การเลือกค่าสูงสุด

หลังจากคำนวณค่า D จะต้องเปรียบเทียบกับค่าวิกฤติที่คำนวณได้จากกรทดสอบ ในกรณีของสมมติฐานทางเดียว สามารถใช้ตารางของ คอลโมโกรอฟ-สมิร์นอฟ สำหรับการทดสอบที่ระดับนัยสำคัญ α และขนาดของข้อมูล (n) ในการตัดสินใจว่าค่า D มากกว่าหรือเท่ากับค่าวิกฤติหรือไม่ (Chakravart et al.,1967)

2.1.2. การทดสอบแนวนอนและอิทธิพลฤดูกาล

การทดสอบแนวนอนและอิทธิพลฤดูกาลมีทั้งแบบอิงพารามิเตอร์และไม่อิงพารามิเตอร์ จากการทดสอบการแจกแจงปกติ พบว่าอนุกรมเวลาไม่มีการแจกแจงปกติ จึงเลือกใช้การทดสอบแนวนอนและอิทธิพลฤดูกาลแบบไม่อิงพารามิเตอร์

1. การทดสอบแนวนอนแบบไม่อิงพารามิเตอร์

การทดสอบของแดนเนียล (Daniel's Test) เป็นการทดสอบแนวนอนที่ใช้ค่าสัมประสิทธิ์สหสัมพันธ์ของสเปียร์แมน (Spearman: r_s) ซึ่งเป็นค่าวัดสหสัมพันธ์ระหว่างตัวแปร 2 ตัวแปร แต่ละตัวแปรใช้ค่าแทนลำดับ (Rank) ของค่าสังเกต หรือแปลงค่าสังเกตเป็นลำดับแล้ว กรณีที่อนุกรมเวลามีแนวโน้มขึ้นหรือลงค่า r_s จะมีค่าเข้าใกล้ 1 หรือ -1 (ทรงศิริ, 2549) มีขั้นตอนการทดสอบ ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. กำหนดสมมติฐาน
 H_0 : อนุกรมเวลาไม่มีแนวโน้ม
 H_1 : อนุกรมเวลาที่มีแนวโน้ม
2. ตัวสถิติทดสอบ ดังสมการที่ 2.2

$$r_s = 1 - \frac{6 \sum_{t=1}^n d_t^2}{n(n^2 - 1)} \quad (2.2)$$

โดยที่ $d_t = t - R(Y_t)$ โดยที่ $R(Y_t)$ เป็นลำดับที่ของ Y_t

3. เกณฑ์การตัดสินใจ
 - 3.1 สำหรับอนุกรมเวลาขนาดเล็ก ($n < 30$)

บริเวณวิกฤติ คือ $|r_s| \geq r_{\frac{\alpha}{2}}$

ซึ่ง $r_{\frac{\alpha}{2}}$ เป็นค่าวิกฤติที่ได้จากตารางสถิติ Critical Values of

Spearman's Rho

- 3.2 สำหรับอนุกรมเวลาขนาดใหญ่ ($n \geq 30$)

ใช้ตัวสถิติทดสอบ ดังสมการที่ 2.3

$$Z = \frac{r_s - \mu_{r_s}}{\sigma_{r_s}} \quad (2.3)$$

เมื่อ $\mu_{r_s} = 0$ และ $\sigma_{r_s} = \frac{1}{\sqrt{n-1}}$ มีบริเวณวิกฤติ คือ $|Z| \geq Z_{\frac{\alpha}{2}}$

2. การทดสอบอหิพลฤดูกาลแบบไม่อิงพารามิเตอร์

การทดสอบอหิพลฤดูกาลแบบไม่อิงพารามิเตอร์ จะใช้การทดสอบครัสคาล-วอลลิส (Kruskal-Wallis) เป็นการทดสอบความแตกต่างระหว่างหลายกลุ่ม ซึ่งนำมาปรับใช้ในการทดสอบอหิพลของฤดูกาล (ทรงศิริ, 2549) โดยมีขั้นตอนดังนี้

1. กำหนดสมมติฐาน
 - 1.1 สำหรับรูปแบบบวก
 $H_0 : S_1 = S_2 = S_3 = \dots = S_L = 0$
 $H_1 : S_i \neq 0$ สำหรับบางฤดูกาล เมื่อ $i = 1, 2, 3, \dots, L$
 - 1.2 สำหรับรูปแบบคูณ
 $H_0 : S_1 = S_2 = S_3 = \dots = S_L = 1$
 $H_1 : S_i \neq 1$ สำหรับบางฤดูกาล เมื่อ $i = 1, 2, 3, \dots, L$

2. ตัวสถิติทดสอบ ดังสมการที่ 2.4

$$H = \frac{12}{n(n+1)} \left[\sum_{i=1}^L \frac{R_i^2}{n_i} \right] - 3(n+1) \quad (2.4)$$

และ $n = \sum_{i=1}^L n_i$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิเมื่อ แปล n_i นี้คือ จำนวนค่าสังเกตในฤดูกาลที่ i ทุกครั้งที่มีการนำไปใช้

- L คือ จำนวนฤดูกาลใน 1 ปี
 Y'_t คือ ค่าสังเกตที่ปรับแนวโน้มแล้ว ณ เวลา t
 R_i คือ ผลรวมของลำดับที่ของ Y'_t ในฤดูกาล i

ตัวสถิติ H มีการแจกแจงประมาณด้วยการแจกแจงไคสแควร์ที่ชั้นแห่งความเป็นอิสระเท่ากับ $L-1$

3. เกณฑ์การตัดสินใจ

บริเวณวิกฤต คือ $H \geq \chi^2_{\alpha, L-1}$

ซึ่ง $\chi^2_{\alpha, L-1}$ เป็นค่าวิกฤตที่เปิดได้จากตารางไคสแควร์ (Chi-Square Table) ที่ตาราง ง.1 ของภาคผนวก ง

2.1.3. การแปลงอนุกรมเวลาให้เป็นสเตชันนารีด้วยวิธีหาผลต่าง (Differencing)

การแปลงอนุกรมเวลาเพื่อทำให้อนุกรมเวลาเดิมไม่สเตชันนารีเป็นอนุกรมเวลาใหม่ที่เป็นสเตชันนารีมีดังนี้

1. หาอนุกรมเวลาผลต่าง ถ้าอนุกรมเวลา $\{y_t\}$ มีการเคลื่อนไหวเนื่องจากแนวโน้ม จะแปลงอนุกรมเวลาเดิม $\{y_t\}$ เป็นอนุกรมเวลาใหม่ $\{Z_t\}$ ที่ไม่มีแนวโน้มซึ่ง $Z_t = \nabla^d Y_t$ โดยเป็นจำนวนครั้งของการหาผลต่าง เช่น

$$\begin{aligned} \text{เมื่อ } d = 1 \text{ จะมี } Z_t &= \nabla Y_t = Y_t - Y_{t-1} \\ Z_t &= \nabla^2 Y_t \\ &= \nabla^2 (Y_t - Y_{t-1}) \\ &= \nabla Y_t - \nabla Y_{t-1} \\ &= Y_t - 2Y_{t-1} + Y_{t-2} \end{aligned}$$

จำนวนครั้งที่หาผลต่างขึ้นอยู่กับว่าเมื่อหาผลต่างแล้วอนุกรมเวลาใหม่เป็นสเตชันนารีแล้วหรือไม่ ถ้ายังไม่เป็นสเตชันนารีต้องหาผลต่างต่อไป

2. หาอนุกรมเวลาผลต่างฤดูกาล ถ้าอนุกรมเวลา $\{y_t\}$ มีการเคลื่อนไหวเนื่องจากฤดูกาลจะแปลงอนุกรมเดิม $\{y_t\}$ เป็นอนุกรมเวลาใหม่ $\{Z_t\}$ ที่ไม่มีฤดูกาล ซึ่ง $Z_t = \nabla_L^D Y_t$ โดย D เป็นจำนวนครั้งของการหาผลต่างฤดูกาลและ L เป็นจำนวนฤดูกาลต่อปี เช่น สำหรับอนุกรมเวลารายไตรมาส ($L = 4$)

$$\begin{aligned} \text{เมื่อ } D = 1 \text{ จะมี } Z_t &= \nabla_4 Y_t = Y_t - Y_{t-4} \\ \text{เมื่อ } D = 2 \text{ จะมี } Z_t &= \nabla^2 Y_4 \\ &= \nabla_4 (Y_t - Y_{t-4}) \\ &= Y_t - 2Y_{t-4} + Y_{t-8} \end{aligned}$$

จำนวนครั้งที่หาผลต่างฤดูกาลขึ้นอยู่กับว่าเมื่อหาผลต่างฤดูกาลแล้ว อนุกรมเวลาใหม่เป็นสเตชันนารีแล้วหรือไม่ ถ้ายังไม่เป็นสเตชันนารีต้องหาผลต่างฤดูกาลต่อไป

3. หาค่าอนุกรมเวลาผลต่างและผลต่างฤดูกาล กรณีที่อนุกรมเวลา $\{y_t\}$ มีการเคลื่อนไหวเนื่องจากแนวโน้มและฤดูกาล จะแปลงอนุกรมเวลาเดิม $\{y_t\}$ เป็นอนุกรมเวลาใหม่ $\{Z_t\}$ เอกสารนี้ที่ไม่มีแนวโน้มและฤดูกาลโดยหาผลต่างและผลต่างฤดูกาลซึ่ง $Z_t = \nabla \nabla_L^D Y_t$ เช่น สำหรับอนุกรมเวลารายไตรมาสที่มีการเคลื่อนไหวเนื่องจากแนวโน้มและฤดูกาลถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\begin{aligned}
 \text{เมื่อ } d = 1 \text{ และ } D = 1 \text{ จะมี } Z_t &= \nabla \nabla_4 Y_t \\
 &= \nabla(Y_t - Y_{t-4}) \\
 &= Y_t - Y_{t-1} + Y_{t-4} + Y_{t-5}
 \end{aligned}$$

จำนวนครั้งที่หาผลต่างและผลต่างฤดูกาลที่กำหนดด้วย d และ D ตามลำดับขึ้นกับว่าอนุกรมเวลาใหม่ที่สร้างขึ้นเป็นสเตชันนารีแล้วหรือไม่

2.1.4. ค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองและค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองบางส่วน

ค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองหรือ Autocorrelation Function (ACF) คือ ความสัมพันธ์ของข้อมูลระหว่างค่า $\{y_t\}$ กับค่า $\{y_t\}$ ที่ห่างกัน k ค่า หรือความสัมพันธ์ระหว่างค่า $\{y_t\}$ กับ $\{y_{t-k}\}$ โดยค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองของตัวอย่าง แทนด้วย r_k และค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองขอประชากร แทนด้วย ρ_k

ค่าสัมประสิทธิ์ สหสัมพันธ์ในตัวเองบางส่วนหรือ Partial Autocorrelation Function (PACF) เป็นค่าที่ใช้วัดความสัมพันธ์ระหว่าง Y_t กับค่า Y_{t+k} โดยไม่มีอิทธิพลของ $Y_{t+1} \dots Y_{t+k-1}$ เข้ามาเกี่ยวข้อง ดังตารางที่ 2.1 แสดงลักษณะของ ACF และ PACF ของตัวแบบ SARIMA

โดยค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองบางส่วนของตัวอย่าง แทนด้วย r_{kk} และค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองบางส่วนขอประชากร แทนด้วย ρ_{kk}

ตารางที่ 2.1 ลักษณะของ ACF และ PACF ของตัวแบบ SARIMA

รูปแบบ	ลักษณะ ACF	ลักษณะของ PACF
$SAR(1)_{30}$ * กรณีฤดูกาลเกิดขึ้น 30 วัน $S = 30$	$\rho_{30}, \rho_{60}, \dots$ ลดลงเร็วใกล้ 0	ρ_{30}, ρ_{30} โดยที่ $\rho_{kk} = 0$ สำหรับ $k = 60, 90, \dots$
$SAR(2)_{30}$	$\rho_{30}, \rho_{60}, \dots$ ลดลงเร็วใกล้ 0	ρ_{30}, ρ_{30} และ $\rho_{60}, \rho_{60} \neq 0$ โดยที่ $\rho_{kk} = 0$ สำหรับ $k = 90, 120, \dots$
$SMA(1)_{30}$	$\rho_{30} \neq 0$ โดยที่ $\rho_k = 0$ สำหรับ $k = 60, 90, \dots$	$\rho_{30}, \rho_{30}, \rho_{60}, \rho_{60}$ ลดลงเร็วใกล้ 0
$SMA(2)_{30}$	$\rho_{30},$ และ $\rho_{60} \neq 0$ โดยที่ $\rho_k = 0$ สำหรับ $k = 90, 120, \dots$	$\rho_{30}, \rho_{30}, \rho_{60}, \rho_{60}$ ลดลงเร็วใกล้ 0

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.5. ตัวแบบพยากรณ์ด้วยวิธี Box - Jenkins สำหรับอนุกรมเวลา

1. ตัวแบบ Autoregressive Moving Average (ARMA)

รูปแบบ ARMA เป็นรูปแบบที่นำรูปแบบ AR (p) ผสมกับรูปแบบ MA (q) สร้างรูปแบบ ARMA (p, q) เมื่อกำหนดอันดับ p และ q สามารถกำหนดสมการตามรูปแบบ ARMA (p, q) โดยสามารถแสดงดังสมการที่ 2.5

$$Y_t = \theta_0 + \phi_1 y_{t-1} + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_q \varepsilon_{t-q} \quad (2.5)$$

โดยทั่วไป รูปแบบ ARMA(p, q) จะมีอันดับ $p + q \leq 2$ เช่น รูปแบบ ARMA (1, 1) ที่มีรูปแบบ โดยสามารถแสดงดังสมการที่ 2.6

$$Y_t = \theta_0 + \phi_1 y_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad \text{เมื่อ } p=1, q=1 \quad (2.6)$$

เมื่อกำหนดตัวดำเนินการย้อนกลับ B จะสามารถเขียนสมการที่ 2.5 ในรูปแบบของตัวดำเนินการย้อนกลับ โดยสามารถแสดงดังสมการที่ 2.7

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Y_t = \theta_0 + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (2.7)$$

2. ตัวแบบ Autoregressive Integrated Moving Average Model (ARIMA)

Box et al. (2018) กล่าวว่า รูปแบบ ARIMA เป็นรูปแบบที่ใช้กับอนุกรมเวลาที่ไม่เป็นสเตชันนารี เนื่องจากแนวโน้มต้องแปลงอนุกรมเวลาเดิม $\{Y_t\}$ ที่ไม่เป็นสเตชันนารีให้เป็นอนุกรมเวลาใหม่ $\{Z_t\}$ ที่เป็นสเตชันนารี ด้วยการหาผลต่างระหว่างค่าสังเกตในอนุกรมเวลาเดิมนั้นคือ $Z_t = \nabla^d Y_t$ ซึ่งกำหนดได้ด้วยการใช้รูปแบบ ARIMA (p, d, q) โดยสามารถแสดงดังสมการที่ 2.8

$$\phi(B) Y_t = \phi_1(B) \nabla^d Y_t = \theta_0 \theta(B) \varepsilon_t \quad (2.8)$$

$$\text{เมื่อ } \phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

โดยกำหนดให้

D แทน ระยะห่างของคาบเวลาที่น่ามาหาผลต่างระหว่างค่าสังเกต

d แทน อันดับของรูปแบบ AR

q แทน อันดับของรูปแบบ MA

θ_0 แทน ค่าคงที่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ตัวแบบ Seasonal Autoregressive Moving Average (SARMA)

รูปแบบ SARMA เป็นรูปแบบที่ใช้สำหรับอนุกรมเวลาที่มีการเคลื่อนไหวเนื่องจากฤดูกาลจะกำหนดรูปแบบ $SAMA(P, Q)_S$ โดยมีส่วนประกอบ 2 ส่วน ได้แก่

ส่วนที่ 1 คือ รูปแบบ $AR(P)_S$ ที่ค่าสังเกต Y_t ขึ้นอยู่กับค่าสังเกตก่อนหน้าที่ล่าช้าไป $P \cdot S$ คาบเวลา

ส่วนที่ 2 คือ รูปแบบ $MA(Q)_S$ ที่ค่าสังเกต Y_t ขึ้นอยู่กับค่าคลาดเคลื่อนก่อนหน้าที่ล่าช้าไป $Q \cdot S$ คาบเวลา ดังนั้นสามารถกำหนดรูปแบบ $SAMA(P, Q)_S$ โดยสามารถแสดงดังสมการที่ 2.9

$$Y_t = \theta_0 \phi_s Y_{t-s} + \theta_s \varepsilon_{t-s} \quad (2.9)$$

และสามารถกำหนดตัวแบบในรูปแบบของตัวดำเนินการย้อนกลับ ได้ดังสมการที่ 2.10

$$\phi_p (B^S) Y_t = \theta_0 (B^S) \varepsilon_t \quad (2.10)$$

โดยกำหนดให้

S คือ จำนวนคาบเวลาใน 1 ฤดูกาล

P คือ จำนวนฤดูกาลล่าช้า

Q คือ จำนวนฤดูกาลล่าช้า

4. ตัวแบบ Seasonal Autoregressive Integrated Moving Average (SARIMA)

รูปแบบ SARIMA เป็นรูปแบบที่ใช้สำหรับอนุกรมเวลาที่ไม่เป็นสเตชันนารี เนื่องจากมีฤดูกาล โดยต้องแปลงอนุกรมเวลาเดิม $\{Y_t\}$ ที่ไม่เป็นสเตชันนารี ให้เป็นอนุกรมเวลาใหม่ $\{Z_t\}$ ที่เป็นสเตชันนารี ด้วยการหาผลต่างฤดูกาล ซึ่ง $Z_t = \nabla_S^D Y_t = (1 - B^{DS})$ โดยสามารถกำหนดรูปแบบ $SARIMA(P, D, Q)_S$ เป็นรูปแบบเต็มแสดงดังสมการที่ 2.10

$$Y_t = \theta_0 + (1 + \phi_s) Y_{t-s} - \phi_s Y_{t-2s} + \varepsilon_t - \theta_s \varepsilon_{t-12} \quad (2.10)$$

และสามารถกำหนดตัวแบบในรูปแบบของตัวดำเนินการย้อนกลับ ได้ดังสมการที่ 2.11

$$\phi_p (B^{DS})(1 - B^S) Y_t = \theta_0 + \theta_Q (B^S) \varepsilon_t \quad (2.11)$$

โดยที่ S คือ จำนวนคาบเวลาใน 1 ฤดูกาล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับ D คือ จำนวนครั้งของการหาผลต่างฤดูกาล ให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.6. ขั้นตอนการพยากรณ์โดยวิธีของ Box-Jenkins

ขั้นตอนการพยากรณ์โดยวิธีของ Box - Jenkins มี 4 ขั้นตอน ดังนี้

1. การตรวจสอบข้อมูล

การพิจารณาข้อมูลอนุกรมเวลานั้นมีส่วนประกอบของแนวโน้มหรือมีความแปรผันของฤดูกาลหรือไม่ โดยพิจารณาจากฟังก์ชันสหสัมพันธ์ในตัวเอง (ACF) และฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (PACF)

2. การกำหนดตัวแบบ

Akaike (1978) กล่าวว่า เป็นการหารูปแบบที่คาดว่าจะเหมาะสมให้กับอนุกรมเวลา โดยพิจารณาจากเกณฑ์การคัดเลือกตัวแบบโดยข้อสนเทศของอาไคเคะ (Akaike's Information Criterion: AIC) เป็นเกณฑ์ที่พิจารณาจากการประมาณความคลาดเคลื่อนรวมเข้ากับ ข้อสนเทศ (Information) ของค่าสังเกตและใช้แนวคิดค่าต่ำสุดของคูลแบ็ค - โลทเบอร์ (Kullback - Lieber) เพื่อนำมาใช้ในการปรับค่าประมาณของการพยากรณ์ให้มีความแม่นยำมากขึ้น โดยตัวแบบที่ให้ค่า AIC ต่ำสุด จะเป็นตัวแบบที่ดีที่สุดสมการ AIC สามารถเขียนได้ดังสมการที่ 2.12

$$AIC = n \log \sigma^2 + 2(p+1) \quad (2.12)$$

โดยที่ n คือ ขนาดตัวอย่าง

p คือ จำนวนพารามิเตอร์

σ^2 คือ $\frac{SSE}{n}$

$$\text{และ } SSE = \sum_{t=1}^n e_t^2 = \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$$

3. การประมาณค่าพารามิเตอร์

จินตามาส (2554) กล่าวว่า เป็นการหาความสัมพันธ์ของฟังก์ชันสหสัมพันธ์กับพารามิเตอร์ซึ่งเป็นความสัมพันธ์สำหรับ อนุกรมเวลาแต่ละรูปแบบ การประมาณค่าพารามิเตอร์โดยใช้วิธีกำลังสองน้อยที่สุด (Ordinary Least Square : OLS) ซึ่งสามารถใช้โปรแกรมสำเร็จรูปคำนวณในการกำหนดค่าเบื้องต้น จนกว่าจะได้ตัวประมาณที่ได้ความคลาดเคลื่อนน้อยที่สุด

4. การตรวจสอบความเหมาะสมของตัวแบบ

การพิจารณาว่า $\rho_k(e_t) = 0$ สำหรับ $k = 1, \dots, m$ หรือไม่ นั่นคือ พิจารณาว่าค่าคลาดเคลื่อนของการพยากรณ์ที่อยู่ห่างกัน $1, \dots, m$ ช่วงเวลาเป็นอิสระกันหรือไม่ การทดสอบสมมติฐานจะทำโดยใช้การทดสอบของ Box และ Pierce หรือการทดสอบของ Box และ Ljung ซึ่งต่างก็เป็นการทดสอบสมมติฐานที่กำหนดสมมติฐานหลักและสมมติฐานทางเลือกเหมือนกัน มีช่วงวิกฤติเดียวกัน แต่ตัวสถิติทดสอบต่างกัน

1. สมมติฐานในการทดสอบ

$$H_0 : \rho_1(e_t) = \dots = \rho_m(e_t) = 0$$

$$H_1 : \rho_k(e_t) \text{ อย่างน้อยหนึ่งค่าไม่เท่ากับ } 0 \text{ สำหรับ } k = 1, \dots, m$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้เพื่อการศึกษาค้นคว้าเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. ระดับนัยสำคัญ $\alpha = 0.05$

3. สถิติทดสอบ

Box-Pierce ได้ตั้งสมการที่ 2.13

$$Q = n \sum_{m=k=1}^m r_k^2(e_t) \quad (2.13)$$

Box-Ljung ได้ตั้งสมการที่ 2.14

$$Q_m = n(n+2) \sum_{k=1}^m \frac{r_k^2(e_t)}{(n-k)} \quad (2.14)$$

โดยกำหนดให้

n คือ ขนาดของอนุกรมเวลา $\{e_t\}$

m คือ ช่วงเวลาห่างสูงสุดของ e_t ในอนุกรมเวลา $\{e_t\}$ ที่นำมาพิจารณา

Q คือ จำนวนพารามิเตอร์ทั้งหมดในรูปแบบ ซึ่งรวมทั้ง θ_0 ด้วย

r_k คือ ค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองของตัวอย่าง

4. การตัดสินใจ

ปฏิเสธ H_0 ถ้า Q หรือ $Q_m \geq \chi_{\alpha, m-H_0}^2$

ยอมรับ H_0 ถ้า Q หรือ $Q_m < \chi_{\alpha, m-H_0}^2$

ถ้าปฏิเสธ H_0 จะสรุปได้ว่ามี $\rho_k(e_t)$ อย่างน้อยหนึ่งค่าไม่เท่ากับ 0 สำหรับ $k = 1, \dots, m$ นั่นคือมีสหสัมพันธ์ในตนเองระหว่างค่าความคลาดเคลื่อนของการพยากรณ์ที่อยู่ห่างกัน k ค่า หรือสรุปได้ว่ารูปแบบที่กำหนดให้กับอนุกรมเวลายังไม่เหมาะสม

2.2. ทฤษฎีเกี่ยวกับการประมวลสัญญาณ

2.2.1 นิยามหรือความหมายที่เกี่ยวข้องกับการประมวลสัญญาณ


สัญญาณ (Signals) หมายถึง ข้อมูลหรือข่าวสารที่ได้จากการสังเกต หรือเป็นผลที่ได้มาจากการวัด (Measurement) ด้วยเครื่องมือวัดหลากหลายประเภท โดยสัญญาณจะถูกกำหนดให้เป็นฟังก์ชันค่าเดียวของตัวแปรอิสระอย่างน้อยหนึ่งตัวสัญญาณ (พีระพล, 2552)

การประมวลผลสัญญาณ (Signal Processing) หมายถึง การนำสัญญาณเข้าสู่ระบบประมวลผลที่ภายในประกอบด้วยระบบปฏิบัติการทางคณิตศาสตร์ เช่น การบวก การคูณ การหาร การถอดรากที่สอง หรืออินทิเกรต เป็นต้น ประเภทของการประมวลผลสัญญาณมี 2 ประเภทคือ

1. การประมวลผลสัญญาณอนาล็อก (Analog Signal)

คือ การประมวลผลสัญญาณโดยมี ขาเข้าและขาออกของระบบเป็นสัญญาณต่อเนื่อง องค์ประกอบภายในระบบ เช่น ไดโอด ทรานซิสเตอร์ ออปแอมป์ ตัวต้านทาน เป็นต้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.2 สัญญาณอนาล็อก (ที่มา: รัชชัย, 2559)

ตารางที่ 2.2 ข้อดีและข้อเสียของการประมวลผลสัญญาณอนาล็อก

ข้อดี	ข้อเสีย
<ul style="list-style-type: none"> - การออกแบบทำได้ง่าย - ราคาถูก 	<ul style="list-style-type: none"> - ความแม่นยำต่ำ - อุปกรณ์แปรตามสภาพแวดล้อมมีปัญหาเรื่องสัญญาณรบกวน

2. การประมวลผลสัญญาณดิจิทัล (Digital Signal)

คือ การประมวลผลสัญญาณโดยมี ขาเข้าและขาออกของระบบเป็นสัญญาณไม่ต่อเนื่อง เป็นผลจากการพัฒนาเทคโนโลยีการออกแบบและการผลิตวงจรรวม



รูปที่ 2.3 สัญญาณดิจิทัล (ที่มา: รัชชัย, 2559)

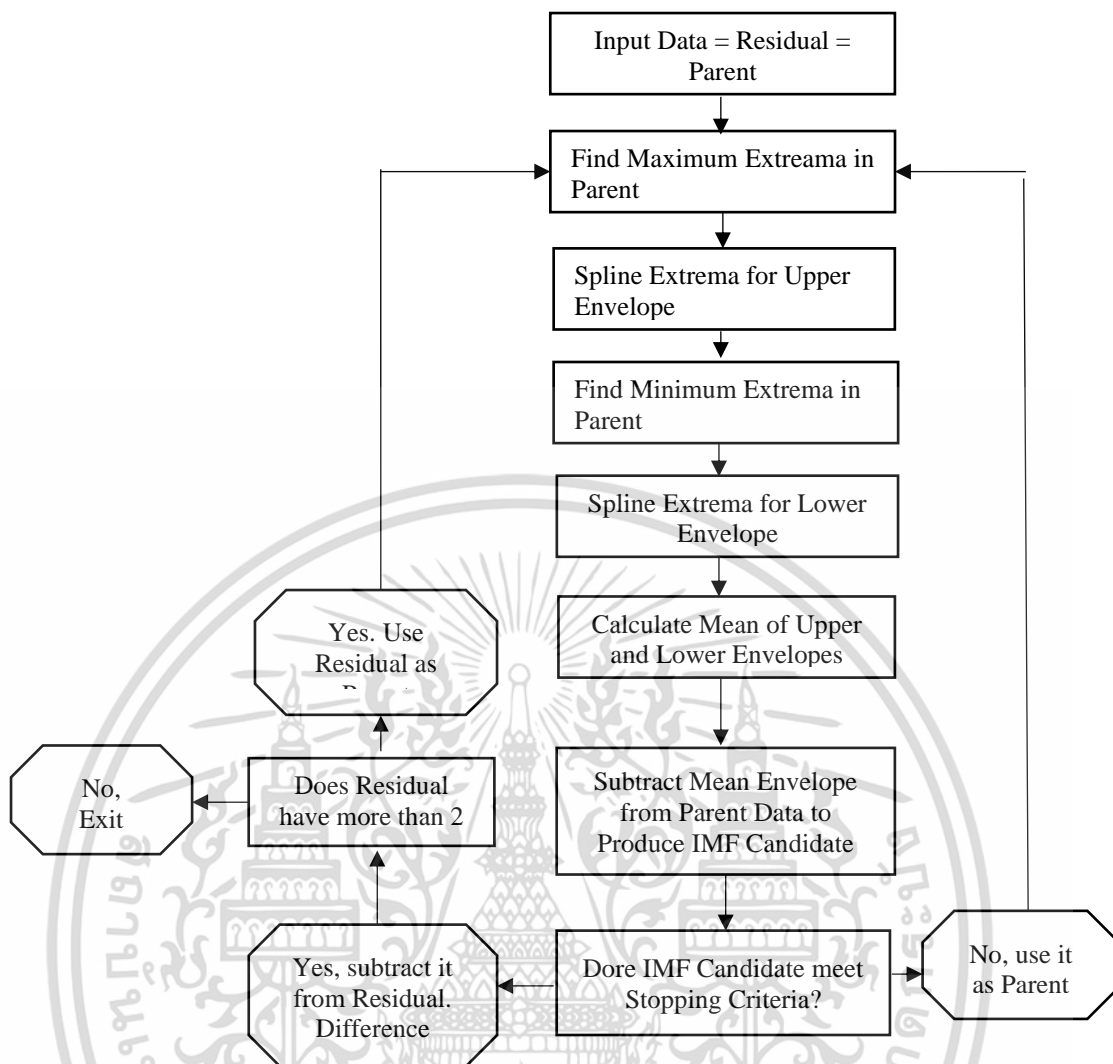
ตารางที่ 2.3 ข้อดีและข้อเสียของการประมวลผลสัญญาณดิจิทัล (สุภัทรชัย, 2547)

ข้อดี	ข้อเสีย
<ul style="list-style-type: none"> - มีความทนทานต่อสัญญาณรบกวนได้ดีกว่า 	<ul style="list-style-type: none"> - ระยะทางการส่งสัญญาณข้อมูลจะไกลกว่าสัญญาณอนาล็อก หากต้องการยืดระยะทางในการส่งข้อมูลดิจิทัลต้องใช้อุปกรณ์ทวนสัญญาณ

2.2.2 เทคนิคเชิงประจักษ์ (Empirical Mode Decomposition, EMD)

เทคนิคเชิงประจักษ์สร้างขึ้นเพื่อมาใช้วิเคราะห์สัญญาณที่มีลักษณะสัญญาณไม่คงที่และไม่เป็นเส้นตรง แท้จริงแล้วสัญญาณประเภทนี้เกิดจากการรวมตัวกันของกราฟสัญญาณพื้นฐานย่อย (Intrinsic Mode Function ,IMF) เทคนิคนี้ จะสามารถนำสัญญาณดังกล่าวมาวิเคราะห์ค่าความถี่ภายในของแต่ละกราฟสัญญาณแยกย่อยได้ (พณสรณ์, 2560) โดยมีขั้นตอนตามรูปที่ 2.4 ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.4 แผนภาพแสดงขั้นตอนการวิเคราะห์เทคนิคเชิงประจักษ์ (ที่มา: Crowley et al.,2009)

1. เมื่อได้กราฟสัญญาณตั้งต้น ซึ่งจะแทนด้วยสัญลักษณ์ $x(t)$
2. หาค่าจุดวิกฤตต่ำสุดและสูงสุดทั้งหมดของกราฟ $x(t)$
3. เชื่อมต่อจุดวิกฤตที่ต่ำสุดในแต่ละช่วงข้อมูลเข้าด้วยกัน เพื่อกำหนดกรอบบนซึ่งจะแทนด้วยสัญลักษณ์ $U(t)$ และเชื่อมต่อจุดวิกฤตที่สูงสุดในแต่ละช่วงข้อมูลเข้าด้วยกัน เพื่อกำหนดกรอบล่าง ซึ่งจะแทนด้วยสัญลักษณ์ $L(t)$
1. หาค่ากราฟเฉลี่ยของช่วงข้อมูลในจุดวิกฤตต่ำสุดและช่วงวิกฤตสูงสุด ได้ดังสมการที่

2.15

$$m(t) = \frac{U(t) + L(t)}{2} \tag{2.15}$$


โดยกำหนดให้ $m(t)$ คือ กราฟเฉลี่ยของช่วงข้อมูลในจุดวิกฤตต่ำสุดและช่วงวิกฤต

สูงสุด
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. นำกราฟเฉลี่ยที่ได้ไปลบออกจากกราฟสัญญาณตั้งต้น เพื่อสร้าง IMF ได้ตั้งสมการที่ 2.16

$$h(t) = x(t) - m(t) \quad (2.16)$$

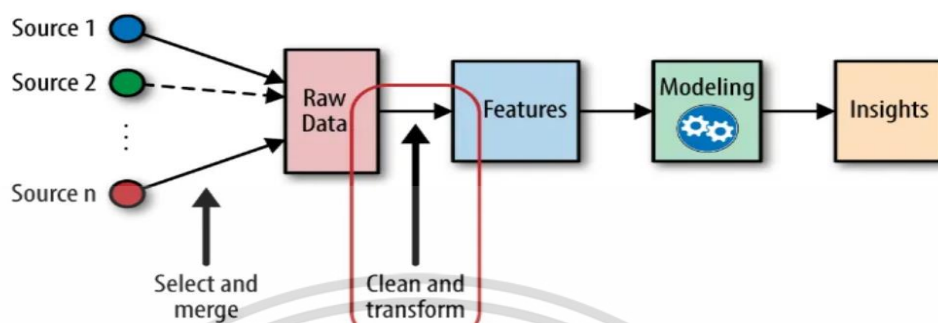
3. พิจารณา $h(t)$ เป็นอนุกรมเวลาและทำซ้ำขั้นตอนที่ 2 ถึง 5 จนกว่ากรอบบนและกรอบล่าง จะสมมาตรซึ่งจะหมายถึง
- ค่าเฉลี่ยของทั้ง $U(t)$ และ $L(t)$ ที่มีค่าเป็น 0 ที่ทุกจุดของข้อมูล
 - ให้ $h(t)$ เป็น IMF ลำดับที่ i (เริ่มต้นที่ 1 และเพิ่มขึ้นทีละ 1)
 - แทนที่ $x(t)$ ด้วยส่วนเหลือ (Residual)
4. ทำซ้ำขั้นตอนที่ 1 ถึง 6 โดยสกัดส่วนเหลือ (Residual) จนกระทั่งถึงเงื่อนไขการหยุด หลังจากเสร็จสิ้นขั้นตอนการสกัดทั้งหมด เราได้ส่วนเหลือ (Residual) และกลุ่มของ IMF
5. เมื่อใดก็ตามที่เงื่อนไขการหยุดหนึ่งหรือทั้งสองบรรลุ การแยก IMFs จะหยุดลง เงื่อนไขการหยุดมีดังนี้
1. เงื่อนไขค่าเฉลี่ยเป็นศูนย์
ตรวจสอบว่าค่าเฉลี่ยของสัญญาณที่เหลืออยู่ใกล้เคียงกับศูนย์หรือไม่
 2. เงื่อนไขค่ามาตรฐาน
ตรวจสอบว่าค่ามาตรฐานของสัญญาณที่เหลืออยู่ใกล้เคียงกับศูนย์หรือไม่



เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้สำหรับการใช้งานเท่านั้น ไม่อนุญาตให้ไปใช้ในประโยชน์ด้านการค้า
รูปที่ 2.5 สัญญาณตั้งต้นและกลุ่มสัญญาณ IMF ด้วยเทคนิคเชิงประจักษ์
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปดข้อมูลหรือข้อความใดๆ ของเอกสารทุกครั้งที่มีการนำไปใช้
 (ที่มา: Crowley et al.,2009)

2.3. วิศวกรรมคุณลักษณะ (Feature Engineering)

2.3.1 นิยามของ Feature Engineering




รูปที่ 2.6 กระบวนการทำ Feature Engineering (Singh, 2019)

วิศวกรรมคุณลักษณะ (Feature Engineering) คือ กระบวนการแปลงข้อมูลดิบ (raw data) หรือทำความสะอาดข้อมูล (Clean Data) ให้เป็น Feature ที่มีความหมายมากขึ้น Feature Engineering เป็นกระบวนการที่สำคัญมากใน Data Science ในการสร้าง Machine Learning Model ที่มีประสิทธิภาพ (นรุตม์, 2667)

2.3.2 ความสำคัญของ Feature Engineering

1. ช่วยปรับปรุงประสิทธิภาพของตัวแบบ
2. ช่วยลดข้อมูลที่ไม่มีความเกี่ยวข้อง ลดสัญญาณรบกวนและข้อมูลที่มีความซ้ำซ้อน
3. ช่วยให้ตัวแบบสามารถเรียนรู้ได้รวดเร็ว ทำให้การเรียนรู้มีประสิทธิภาพขึ้น (นรุตม์, 2667)


2.4. โครงสร้างประสาทเทียมหน่วยความจำระยะยาว-ระยะสั้น (Long Short-Term Memory, LSTM)



รูปที่ 2.7 โครงสร้างการทำงานของ RNN (ที่มา: Olah, 2015)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Recurrent Neural Network หรือ RNN ซึ่งในรูปที่ 2.7 แสดงหลักการทำงานของ RNN นำผลลัพธ์ที่ได้จากการคำนวณจากโหนดก่อนหน้าไว้วนกลับมาใช้เป็นข้อมูล input ในโหนดถัดไป ซึ่งในแต่ละโหนดของ RNN จะมีข้อมูลที่เข้ามา 2 ทาง คือ ข้อมูล input กับ output ที่ได้มาจากการคำนวณของโหนดก่อนหน้า โดยทั้งจากข้อมูล 2 ชุดที่เข้ามาในโหนดจะถูกรวมเข้าด้วยกัน ก่อนจะถูกแยกผลลัพธ์ออกเป็น 2 ส่วน คือ ผลลัพธ์ที่ได้จากโหนดนั้น ๆ และผลลัพธ์ที่จะถูกนำไปเป็นข้อมูล input ของโหนดถัดไป เทคนิค RNN นั้นเหมาะนำมาใช้งานกับข้อมูลที่มีลักษณะเป็นลำดับ (sequence) หรือข้อมูลที่มีความต่อเนื่อง โดยข้อเสียคือ ดูข้อมูลย้อนหลังได้แค่ระยะสั้น ซึ่งจะทำให้เกิดปัญหาในการทำการคำนวณหาค่าความผิดพลาดย้อนหลังของแต่ละโหนด จึงได้พัฒนา RNN ขึ้นเป็น LSTM (กานต์กมล, 2562)



รูปที่ 2.8 โครงสร้างการทำงานของ LSTM (ที่มา: Olah, 2015)

Long Short-Term Memory (LSTM) เริ่มเป็นที่รู้จักในปี ค.ศ. 1997 ในรูปที่ 2.8 แสดงหลักการทำงาน คือสามารถเก็บ 'สถานะ' หรือข้อมูลของแต่ละโหนดเอาไว้เพื่อที่เวลาย้อนกลับไปดูจะได้รู้ว่าเดิมเป็นค่าอะไร LSTM มีฟังก์ชันพิเศษที่ทำหน้าที่เสมือน 'Gate' ที่คอยควบคุมข้อมูลที่เข้ามาในแต่ละโหนด คือ Forget Gate Layer, Input Gate Layer และ Output Gate Layer หลักการทำงานของแต่ละฟังก์ชันมีดังนี้ (กานต์กมล, 2562)



รูปที่ 2.9 โครงสร้าง Forget Gate Layer (ที่มา: Olah, 2015)


ในรูปที่ 2.9 แสดงโครงสร้างของ Forget Gate Layer การทำงานคือ มี "ประตูคัดกรอง" ควบคุมข้อมูลเข้าออกใน "เซลล์หน่วยความจำ" ซึ่งการตัดสินใจเก็บหรือทิ้งข้อมูลนั้นได้ขึ้นอยู่กับข้อมูลที่เข้ามารวม ผลลัพธ์จากโหนดก่อนหน้าผ่านฟังก์ชัน Sigmoid (กานต์กมล, 2562) ดังสมการที่ 2.17

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.17)$$

โดยที่

- f_t คือ Forget Gate
- σ คือ ฟังก์ชัน Sigmoid
- w_f คือ ค่าน้ำหนักของ Matrices
- h_{t-1} คือ ค่า Output ของ Cell State ก่อนหน้า (ที่ Timestamp T-1)
- x_t คือ ค่า Input ที่เข้ามาใน Cell State ณ เวลา T
- b_f คือ ค่า Bias



รูปที่ 2.10 Input Gate Layer (ที่มา: Olah, 2015)

ในรูปที่ 2.10 คือการทำงานของ Input Gate Layer ประมวลรับข้อมูล ทำหน้าที่บันทึกข้อมูลใหม่ลงเซลล์หน่วยความจำการทำงานเป็น 2 ขั้นตอน ขั้นตอนแรกฟังก์ชัน Sigmoid จะควบคุมประตูในการจะรับข้อมูลว่าจะ Update ข้อมูลหรือไม่ ขั้นตอนต่อมาเขียนหรือบันทึกข้อมูลลงเซลล์ซึ่งฟังก์ชัน Tanh ก็จะทำการสร้าง Candidate Values (\tilde{C}_t) ขึ้นมาใน State (กานต์กมล, 2562) ดังสมการที่ (2.18) และ (2.19)

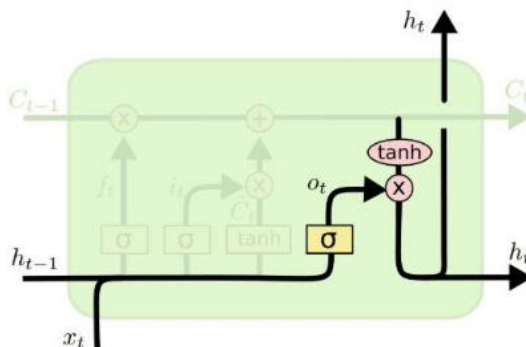
$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.18)$$

$$c_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.19)$$

โดยที่

- i_t คือ Input Gate
- σ คือ ฟังก์ชัน Sigmoid
- \tilde{c}_t คือ ค่า Candidate ของ Cell State ที่เวลา T
- \tanh คือ ฟังก์ชัน Tanh
- w_i, w_c คือ ค่าน้ำหนักของ Matrices
- h_{t-1} คือ ค่า Output ของ Cell State ก่อนหน้า (ที่ Timestamp T-1)
- x_t คือ ค่า Input ที่เข้ามาใน Cell State ณ เวลา T

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์และใช้เพื่อการเรียนการสอนเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.11 Output Gate Layer (ที่มา: Olah, 2015)

รูปที่ 2.11 แสดงโครงสร้างของ Output Gate Layer คือเตรียมส่งออกข้อมูล ผ่านประตูส่งออก ข้อมูลที่ส่งออกได้มาจาก "เซลล์หน่วยความจำ" โดยผ่านการคำนวณแบ่งการทำงานเป็น 3 ขั้นตอน ขั้นตอนแรก คัดกรองข้อมูลจากฟังก์ชัน sigmoid โดยเลือกข้อมูลในเซลล์หน่วยความจำที่ต้องการจะส่งออก ขั้นตอนที่สอง นำข้อมูลที่ได้จากขั้นตอนแรกมาแปลงค่าข้อมูลด้วยฟังก์ชัน tanh ขั้นตอนที่สาม นำค่าจาก sigmoid และ tanh มาคำนวณเพื่อหาค่า output สุดท้าย (กานตักมล ,2562) ดังสมการที่ 2.20

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \tag{2.20}$$

โดยที่

- o_t คือ Output Gate
- σ คือ ฟังก์ชัน Sigmoid
- w_o คือ ค่าน้ำหนักของ Marices
- h_{t-1} คือ ค่า Output ของ Cell State ก่อนหน้า (ที่ Timestamp T-1)
- x_t คือ ค่า Input ที่เข้ามาใน Cell State ณ เวลา T
- b_o คือ ค่า Bias

2.5 ภาษาไพธอน (Python Programming Language)

ภาษาไพธอน เป็นภาษาโปรแกรมมิ่งระดับสูงของคอมพิวเตอร์ เป็นภาษาสคริปต์ และเป็นภาษาโอเพนซอร์ซ นิยมใช้งานอย่างแพร่หลายในหลาย ๆ ด้าน ไม่ว่าจะเป็น ปัญญาประดิษฐ์, เว็บ, วิทยาศาสตร์ข้อมูล เป็นต้น ปัจจุบัน ภาษาไพธอน เป็นที่นิยมอย่างมากในการโปรแกรมมิ่ง เนื่องจากเป็นภาษาที่ง่ายต่อการเข้าใจ และมีประสิทธิภาพความเร็วในการเขียนโค้ดเร็วที่สุด (ภททัยไพบูลย์, 2017) อีกอย่างหนึ่งภาษานี้เป็น Open Source เหมือนอย่าง PHP ทำให้ทุกคนสามารถที่จะนำ Python มาพัฒนาโปรแกรมได้โดยไม่ต้องเสียค่าใช้จ่าย และด้วยการเป็น Open Source ทำให้มีคนเข้ามาช่วยกันพัฒนาให้ Python มีความสามารถสูงขึ้น และใช้งานได้ครอบคลุมกับทุกลักษณะงาน

Data Science กับ Python ซึ่ง Data Science คือ วิทยาศาสตร์ข้อมูล คือศาสตร์ที่รวมเอาความรู้ด้านการเขียนโปรแกรม (Programming) ด้านคณิตศาสตร์ (Mathematics) และด้านสถิติ

(Statistics) มาประยุกต์รวมกันเพื่อทำให้ข้อมูลที่มีอยู่เกิดความรู้ใหม่ ๆ เกิดเป็นข้อมูลที่มีค่า สามารถนำไปใช้ช่วยสนับสนุนการตัดสินใจวางแผนธุรกิจ และช่วยสร้างประโยชน์ทางธุรกิจได้ซึ่งในการนำข้อมูลผ่านกระบวนการวิเคราะห์ข้อมูลเพื่อนำไปประยุกต์ใช้กับธุรกิจมีความสำคัญอย่างมาก โดยเฉพาะในการตัดสินใจสำหรับการบริหารงานในเรื่องต่าง ๆ ในการวางกลยุทธ์ให้สำหรับองค์กร ดังนั้นในกระบวนการทำ Data Science จึงต้องอาศัยการเขียนโปรแกรมที่นำมาใช้แล้วเกิดความยืดหยุ่น และมีฟังก์ชันการทำงานเพื่อรองรับการประมวลผลทางคณิตศาสตร์ได้ดี ซึ่งภาษาที่นิยมเป็นอย่างตอนนี้อย่างตอนนี้ คือ Python (อรพิน, 2564)

ข้อดีของการใช้ Python ทำงาน Data Science สามารถสรุปได้ดังนี้ (อรพิน, 2564)

1. เป็นภาษาที่ง่ายต่อการเรียนรู้สามารถประมวลผลได้โดยเขียนโปรแกรมเพียงไม่กี่บรรทัดเมื่อเทียบกับภาษาอื่น เช่น ภาษา R

2. ทำงานได้เร็วกว่าภาษา R และ MATLAB

3. มีการจัดการทรัพยากรได้ดี ทำให้หน่วยความจำน้อยในการประมวลผล

4. โดยเฉพาะอย่างยิ่งในการทำงานกับข้อมูลขนาดใหญ่

5. มีไลบรารีต่าง ๆ มากมายในด้าน Data Science เช่น NumPy Panda เป็นต้น

ไลบรารีที่จำเป็นสำหรับการสำหรับพยากรณ์

1. matplotlib.pyplot คือไลบรารีหนึ่งของภาษาโปรแกรมมิ่ง Python ที่ใช้สำหรับการ Visualize Data หรือคือการพล็อตข้อมูลออกมาเป็นรูป กราฟ และชาร์ตต่าง ๆ สามารถใช้งานร่วมกับ Numpy ที่เหมาะสำหรับการประมวลผลข้อมูลแบบตารางในปริมาณที่เยอะได้ ใช้งานง่าย และสามารถนำไปวิเคราะห์ข้อมูลได้หลากหลายรูป

2. numPy ย่อมาจาก Numeric Python ในการใช้งานจะต้องทำการติดตั้งไลบรารีเพิ่ม เนื่องจากไม่ใช่ไลบรารีพื้นฐานของไพธอน ซึ่ง NumPy เป็นไลบรารีที่จัดการเกี่ยวกับคณิตศาสตร์ และการคำนวณต่าง ๆ ทั้งข้อมูลที่เกี่ยวข้องกับวิทยาศาสตร์ วิศวกรรมศาสตร์ สถิติ ธุรกิจ เป็นต้น โดยมีความสามารถในการจัดการอาร์เรย์หลายมิติ ซึ่งจะเรียกอาร์เรย์ใน NumPy ว่า ndarray

3. pandas ย่อมาจาก Python Data Analysis Library ใช้ในการจัดการและวิเคราะห์ข้อมูลแบบโครงสร้าง (Structured Data) เช่น ข้อมูลที่จัดเก็บในรูปแบบของตาราง (Table) ได้อย่างมีประสิทธิภาพ ความสามารถหลักของ Pandas คือ

- นำเข้าและจัดการข้อมูลได้หลากหลายรูปแบบ เช่น CSV, Excel, SQL database, JSON เป็นต้น
- จัดการข้อมูลที่ขาดหายไป (missing data) ได้อย่างมีประสิทธิภาพ
- การปรับขนาด (reshape) และจัดเรียงข้อมูลใหม่
- การรวม (merge) และเชื่อมต่อข้อมูลจากแหล่งต่าง ๆ
- การสร้างกราฟและพล็อตข้อมูลได้อย่างง่ายดาย
- การคำนวณทางสถิติและนำเสนอผลลัพธ์ได้อย่างรวดเร็ว (McKinney, 2012)

4. PyEMD เป็นชื่อของไลบรารี (library) หรือแพ็คเกจ (Package) สำหรับภาษาไพธอน ที่ใช้ในการประมวลผลสัญญาณด้วยวิธี Empirical Mode Decomposition (EMD)

5. pmdarima.arima สร้างตัวแบบ ARIMA อัตโนมัติจากข้อมูล พร้อมทั้งคำนวณผลพยากรณ์ล่วงหน้าได้

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

6. tensorflow.keras.models เป็นส่วนหนึ่งของ Keras API ในไลบรารี TensorFlow ซึ่ง เป็นไลบรารีสำหรับการเขียนโปรแกรมปัญญาประดิษฐ์ (AI) โดยเฉพาะโครงข่ายประสาทเทียม (Neural Networks) Models เป็นโมดูลย่อยภายใต้ tensorflow.keras ที่ให้คลาสและฟังก์ชัน สำหรับสร้างและจัดการตัวแบบปัญญาประดิษฐ์แบบต่าง ๆ ได้แก่ Sequential สำหรับสร้างตัวแบบ เชิงเส้นตรง, Model สำหรับสร้างตัวแบบเชิงความสัมพันธ์ที่ซับซ้อน เป็นต้น

7. TensorFlow.keras.layers คือโมดูลย่อยภายใต้ keras API ในไลบรารี TensorFlow ซึ่ง ประกอบด้วยชั้นข้อมูล (layers) ต่าง ๆ ที่ใช้ในการสร้างและกำหนดคุณสมบัติของโมเดล ปัญญาประดิษฐ์ โดยเฉพาะอย่างยิ่งโครงข่ายประสาทเทียม (Neural Networks) โมดูล Layers ในทาง Keras นี้จะทำหน้าที่เป็นอิฐก้อนสำคัญสำหรับก่อสร้างตัวแบบขึ้นมา โดยประกอบไปด้วย ประเภทของเลเยอร์ต่าง ๆ เช่น Dense - เลเยอร์ข้อมูลแบบเต็ม ทุกหน่วยจะเชื่อมโยงกับทุกหน่วย ของเลเยอร์ถัดไป

8. sklearn.preprocessing เป็นโมดูลย่อยภายใต้ไลบรารี Scikit-learn ในภาษาไพธอน ซึ่ง ให้ฟังก์ชันและคลาสสำหรับการกำหนดรูปแบบข้อมูล (Data Preprocessing) ก่อนที่จะนำไปใช้ในการ สร้างและฝึกสอนตัวแบบปัญญาประดิษฐ์ และเป็นโมดูลที่สำคัญมากสำหรับขั้นตอนการเตรียม และปรับแต่งรูปแบบข้อมูลในกระบวนการ Machine Learning Pipeline

2.6 การวัดประสิทธิภาพของตัวแบบพยากรณ์

2.6.1 ค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error, MAPE)

เป็นการวัดความแม่นยำของการพยากรณ์ โดยคำนวณหาค่าความผิดพลาดจากการ พยากรณ์ในแต่ละช่วงเวลา หาค่าจริง ณ เวลานั้น และเฉลี่ยความผิดพลาดที่แท้จริงเป็นร้อยละ (Lewis et, 1982) ในสมการที่ 2.21

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100 \quad (2.21)$$

โดยที่

Y_t คือ ค่าจริงในช่วงเวลา t

\hat{Y}_t คือ ค่าพยากรณ์ในช่วงเวลา t

n คือ จำนวนจุดข้อมูลในข้อมูลแบบอนุกรมเวลา

2.6.2 ค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนสมมาตร (Symmetric Mean Absolute Percentage Error, SMAPE)

เป็นมาตรวัดอีกชนิดหนึ่งที่นิยมใช้ วัดความแม่นยำของการพยากรณ์ สามารถแก้ไขปัญหา การหารด้วย 0 ได้ และยังสามารถจำกัดค่าความคลาดเคลื่อนของแต่ละกรณีให้อยู่ระหว่าง 0-200% อย่างไรก็ตาม ตัวชี้วัดแบบสมมาตรนี้ยังคงมีความไวสูงต่อกรณีที่ทั้งค่าจริงและค่าทำนายมีค่าเข้าใกล้ 0 (Armstrong, 1985) ในสมการที่ 2.22

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{(|Y_t| + |\hat{Y}_t|) / 2}$$

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ไม่อนุญาตให้นำไปใช้ประโยชน์ซ้ำ (2.22) ถ้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแบบสงวนลิขสิทธิ์และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่

Y_t คือ ค่าจริงในช่วงเวลา t

\hat{Y}_t คือ ค่าพยากรณ์ในช่วงเวลา t

n คือ จำนวนจุดข้อมูลในข้อมูลแบบอนุกรมเวลา

2.7 งานวิจัยที่เกี่ยวข้อง

2.7.1 งานวิจัยที่มีการประยุกต์ใช้ตัวแบบ ARIMA ร่วมกับเทคนิคเชิงประจักษ์

Athipayoon et al.(2018) ได้ทำการศึกษาตัวแบบพยากรณ์เพื่อเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์อนุกรมเวลาแบบไม่เป็นเชิงเส้นและไม่คงที่ โดยใช้ตัวแบบพยากรณ์เชิงเดี่ยว ARIMA ตัวแบบผสม EMD-ARIMA และตัวแบบผสม EEMD-ARIMA บนข้อมูลอนุกรมเวลา 6 รูปแบบ จากผลการศึกษาค้นพบว่า ตัวแบบการพยากรณ์ที่ดีที่สุดขึ้นอยู่กับรูปแบบของข้อมูลอนุกรมเวลา ดังนั้น ตัวแบบ ARIMA เหมาะสำหรับอนุกรมเวลาที่มีแนวโน้มแบบเอ็กซ์โปเนนเชียล เลขชี้กำลังบวก, ตัวแบบ EMD-ARIMA เหมาะสำหรับอนุกรมเวลาที่มีแนวโน้มแบบเอ็กซ์โปเนนเชียล เลขชี้กำลังลบ และตัวแบบ EEMD-ARIMA เหมาะสำหรับอนุกรมเวลาที่มีแนวโน้มแบบโพลีโนเมียล และโลจิสติก เลขชี้กำลังลบ

Hossain et al.(2021) ได้ทำการศึกษาการทำนายราคาหุ้น โดยใช้ตัวแบบ ARIMA ตัวแบบ EWMA ตัวแบบTheta,ตัวแบบผสม EMD-ARIMA, ตัวแบบผสม EMD-EWMA ตัวแบบผสม EMD-Theta และตัวแบบผสม affEMD-Theta จากการศึกษาพบว่า ตัวแบบ affEMD-Theta ให้ผลการพยากรณ์ที่มีประสิทธิภาพสูงที่สุด เนื่องจากให้ค่า รากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) ,ความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) และ เปอร์เซ็นความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAPE) ต่ำที่สุด วิธีการเหล่านี้มีประโยชน์สำหรับนักลงทุน ผู้ซื้อและขายสินทรัพย์ทางการเงิน ผู้จัดการกองทุน

Liu et al. (2022) ได้ทำการศึกษาการพยากรณ์ระยะเวลาที่แบตเตอรี่ลิเทียมไอออนที่ใช้งานได้เพื่อหาความเสถียรของแบตเตอรี่ โดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยว ARIMA กับตัวแบบผสม EMD-ARIMA ผลการวิจัยพบว่าตัวแบบผสม EMD-ARIMA มีประสิทธิภาพในการพยากรณ์ได้ดีกว่าตัวแบบ ARIMA เนื่องจากให้ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) ต่ำที่สุด

Miao et al.(2023) ได้ทำการศึกษาเกี่ยวกับการพยากรณ์ติดตามสถานะจราจรแบบเรียลไทม์ โดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยว ARIMA, ตัวแบบเชิงเดี่ยว SVD, ตัวแบบเชิงเดี่ยว HA, ตัวแบบเชิงเดี่ยว GRU และตัวแบบผสม ESARIMA (EMD+SVD+ARIMA) โดยใช้เกณฑ์รากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) และความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) ผลการวิจัยพบว่าตัวแบบผสม ESARIMA มีประสิทธิภาพในการพยากรณ์ปริมาณการจราจรสูงกว่าตัวแบบเชิงเดี่ยว (HA ,ARIMA,GRU,T-GCN)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.7.2 งานวิจัยที่มีการประยุกต์ใช้ตัวแบบ SARIMA ร่วมกับเทคนิคเชิงประจักษ์

Nai et al.(2017) ได้ทำการศึกษาการพยากรณ์การจราจรทางอากาศของการบินพลเรือนจีน โดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยว SARIMA, ตัวแบบพยากรณ์เชิงเดี่ยว HOLT-WINTER และตัวแบบผสม EMD-SARIMA และเปรียบเทียบข้อมูลอนุกรมเวลา 4 รูปแบบคือ 1. สินค้าภายในประเทศ 2. สินค้าระหว่างประเทศ 3. ผู้โดยสารระหว่างประเทศ 4. ผู้โดยสารภายในประเทศ ทำการเปรียบเทียบโดยใช้เกณฑ์เปอร์เซ็นต์ความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAPE) จากการศึกษาพบว่าตัวแบบผสม EMD-SARIMA จะช่วยให้สามารถปรับปรุงความแม่นยำในการพยากรณ์ได้ดีที่สุด

Muftic et al. (2021) ได้ทำการศึกษาการพยากรณ์ระบบสุริยะมาใช้ในระบบทำความร้อนด้วยไฟฟ้าเพื่อลดมลพิษทางอากาศและพัฒนาคุณภาพชีวิตในแคนตันซาราเยโว ซึ่งใช้ AQI ในการวัดระดับมลพิษทางอากาศ โดยเปรียบเทียบระหว่างตัวแบบพยากรณ์เชิงเดี่ยว SARIMA กับตัวแบบผสม EMD-SARIMA ผลที่ได้คือค่า AQI ลดลงการใช้ตัวแบบผสม EMD-SARIMA มีประสิทธิภาพที่สูงกว่าตัวแบบเชิงเดี่ยว

Li et al. (2022) ได้ทำการศึกษาการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบผสม EMD-SARIMA กับตัวแบบพยากรณ์เชิงเดี่ยว SARIMA ในการปรับค่าและพยากรณ์การเคลื่อนตัวของเขื่อนคอนกรีต โดยใช้เกณฑ์เปอร์เซ็นต์ความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAPE) และรากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) จากการศึกษาพบว่าตัวแบบผสม EMD-SARIMA มีประสิทธิภาพสูงกว่าตัวแบบพยากรณ์เชิงเดี่ยว

Nandan and Tripathi (2023) ได้ทำการศึกษาการพยากรณ์ผลกระทบของการเปลี่ยนแปลงสภาพภูมิอากาศต่ออนุทวีปอินเดีย โดยใช้ตัวแบบเชิงเดี่ยว TBATS, ตัวแบบพยากรณ์เชิงเดี่ยว SARIMA, ตัวแบบผสม Denoised-SARIMA, ตัวแบบผสม EMD-SARIMA, ตัวแบบผสม WT-SARIMA, ตัวแบบผสม Denoised EMD-SARIMA เมื่อทดสอบประสิทธิภาพด้วยรากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) จากการศึกษาพบว่าตัวแบบผสม EMD-SARIMA มีประสิทธิภาพสูงสุด

2.7.3 งานวิจัยที่มีการประยุกต์ใช้ตัวแบบ LSTM ร่วมกับเทคนิคเชิงประจักษ์

Lee (2020) ได้ทำการศึกษาการพยากรณ์อนาคตของจุดดับบนพระอาทิตย์ โดยเปรียบเทียบระหว่างตัวแบบผสม EMD-LSTM กับตัวแบบเชิงเดี่ยว LSTM ซึ่งเป็น Deep Learning Model ที่ใช้งานง่ายและมีประสิทธิภาพในการเรียนรู้โครงสร้างของข้อมูลที่เปลี่ยนแปลงตามเวลา จากการศึกษาพบว่าตัวแบบผสม EMD-LSTM ให้ผลการพยากรณ์ที่ดีกว่าตัวแบบเชิงเดี่ยว LSTM

Lin Lin and Wei Huang (2020) ได้ทำการศึกษาการพยากรณ์แนวโน้มทางการเงินและข้อมูลทางการเงินโดยใช้ข้อมูลดัชนีความรับผิดชอบต่อสังคม (CSR) ขององค์กรในไต้หวัน ตั้งแต่วันที่ 15 มิถุนายน 2558 โดยเปรียบเทียบระหว่างตัวแบบผสม LSTM กับตัวแบบเชิงเดี่ยว เมื่อทดสอบประสิทธิภาพด้วยรากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) จากการศึกษาพบว่าตัวแบบผสม EMD-LSTM มีประสิทธิภาพการพยากรณ์ที่ดีกว่า

Zhou et al. (2022) ได้ทำการศึกษาการพยากรณ์ความสูงคลื่นให้มีประสิทธิภาพที่ดีขึ้นเพื่อใช้ในการพยากรณ์ทั้งระยะสั้นและยาว โดยการเปรียบเทียบระหว่างตัวแบบ LSTM และ

ตัวแบบผสม EMD-LSTM จากการศึกษาพบว่าตัวแบบผสม EMD-LSTM มีประสิทธิภาพในการพยากรณ์ความสูงคลื่นที่แม่นยำกว่าตัวแบบเชิงเดี่ยว LSTM เนื่องจากข้อดีของ EMD ในการแยกสัญญาณข้อมูลเป็น IMF ซึ่งช่วยให้ตัวแบบสามารถติดตามการเปลี่ยนแปลงแนวโน้มได้ดีขึ้น

Hao et al. (2022) ได้ทำการศึกษาการพยากรณ์ความสูงคลื่นทะเลเพื่อรับประกันความปลอดภัยในการเดินเรือใช้ข้อมูลความสูงคลื่นจริง โดยเปรียบเทียบระหว่างตัวแบบเชิงเดี่ยว LSTM กับตัวแบบผสม EMD-LSTM เมื่อทดสอบประสิทธิภาพด้วยรากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) จากการศึกษาพบว่าตัวแบบผสม EMD-LSTM มีความแม่นยำในการพยากรณ์ที่ดีกว่าตัวแบบเชิงเดี่ยว LSTM และสามารถเพิ่มระยะเวลาล่วงหน้าของการพยากรณ์ได้มากกว่าสองเท่า

Feng et al. (2022) ได้ทำการศึกษาการพยากรณ์ความเข้มข้นของก๊าซเรดอนในน้ำใต้ดิน งานวิจัยนี้ใช้การเปรียบเทียบระหว่างตัวแบบผสม EMD-LSTM กับตัวแบบเชิงเดี่ยว LSTM จากการศึกษาพบว่าตัวแบบผสม EMD-LSTM มีประสิทธิภาพในการในการระบุสัญญาณเบื้องต้นได้แม่นยำกว่าตัวแบบเชิงเดี่ยว LSTM

Zhang et al. (2023) ได้ทำการศึกษาการพยากรณ์ดัชนี DST ซึ่งการพยากรณ์ดัชนีนี้มีความสำคัญอย่างยิ่งต่อการศึกษาพายุแม่เหล็กโลกและกระบวนการที่เกิดบนดวงอาทิตย์ งานวิจัยนี้เปรียบเทียบประสิทธิภาพระหว่างตัวแบบเชิงเดี่ยว LSTM และตัวแบบผสม EMD-LSTM โดยใช้ชุดข้อมูลดัชนี DST ตั้งแต่ปี 2018-2023 เมื่อทดสอบประสิทธิภาพด้วยรากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) จากการศึกษาพบว่าตัวแบบผสม EMD-LSTM มีประสิทธิภาพในการพยากรณ์ที่ดีกว่าตัวแบบเชิงเดี่ยว

สรุปสาระสำคัญจากการทบทวนวรรณกรรม

งานวิจัยที่เกี่ยวข้องที่กล่าวมาข้างต้น จะเห็นว่าเมื่อใช้เทคนิคเชิงประจักษ์มาผสมกับตัวแบบเชิงเดี่ยว จะส่งผลให้ค่าพยากรณ์มีประสิทธิภาพที่สูงขึ้น เมื่อเทียบกับตัวแบบเชิงเดี่ยว เนื่องมาจากเทคนิคเชิงประจักษ์สามารถจัดการกับสัญญาณที่ซับซ้อน

บทที่ 3

วิธีการดำเนินงานวิจัย

บทความนี้นำเสนอขั้นตอนการศึกษาการพยากรณ์ยอดขายสินค้าของบริษัทเอกชนแห่งหนึ่ง โดยเลือกจากประเภทสินค้าที่สร้างประโยชน์สูงสุด นำมาเปรียบเทียบประสิทธิภาพของตัวแบบผสมกับตัวแบบพยากรณ์เชิงเดี่ยวเพื่อหาตัวแบบที่มีประสิทธิภาพมากที่สุด โดยมีรายละเอียดการดำเนินงานดังนี้

3.1 ขั้นตอนการดำเนินงาน

รูปที่ 3.1 แสดงให้เห็นถึงขั้นตอนการดำเนินงานวิจัยโดยเริ่มจากการนำข้อมูลยอดขายสินค้าอะไหล่รถจักรยานยนต์มาทำการจัดเตรียมข้อมูลให้เหมาะสมกับการพยากรณ์ สร้างตัวแบบพยากรณ์เชิงเดี่ยว ได้แก่ ARIMA, SARIMA และ LSTM ในขั้นตอนการสร้างตัวแบบของ ARIMA และ SARIMA นั้น จะทำการทดสอบเสถียรภาพ ถ้าข้อมูลไม่เสถียรจะทำการหาผลต่างฤดูกาล 1 ครั้งเพื่อให้เสถียรก่อนไปกำหนดตัวแบบ และตรวจสอบความเหมาะสมของตัวแบบ เมื่อได้ตัวแบบที่เหมาะสมจะเลือกตัวแบบที่มีค่า AIC ต่ำสุดเป็นตัวแบบพยากรณ์ ในส่วนของตัวแบบ LSTM จะทำการปรับค่าไฮเปอร์พารามิเตอร์ เพื่อให้ได้ตัวแบบพยากรณ์ที่เหมาะสม ในการสร้างตัวแบบพยากรณ์ผสมนำตัวแบบพยากรณ์เชิงเดี่ยวร่วมกับเทคนิคเชิงประจักษ์ อันดับแรกนำข้อมูลไปแยกสัญญาณได้เป็นสัญญาณ IMFs และสัญญาณส่วนเหลือ (Residual) โดยการสร้างตัวแบบพยากรณ์สำหรับแต่ละสัญญาณ IMFs และ Residual จะทำตามขั้นตอนของการสร้างตัวแบบพยากรณ์เชิงเดี่ยว แล้วรวมตัวแบบพยากรณ์เชิงเดี่ยวเข้าด้วยกันจะได้ตัวแบบพยากรณ์ผสม หลังจากทำการสร้างตัวแบบพยากรณ์เชิงเดี่ยวและตัวแบบพยากรณ์ผสมแล้วนั้นจะทำการพยากรณ์ นำค่าพยากรณ์ที่ได้ ณ เวลา $t+1$ มาเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์ด้วยเกณฑ์ MAPE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 เครื่องมือที่ใช้ในงานวิจัย

3.2.1. ซอฟต์แวร์ (Software)

1. โปรแกรม Microsoft Excel
2. โปรแกรม Minitab
3. ภาษา Python 3
4. เครื่องมือที่ช่วยในการพัฒนาตัวแบบ ใช้ในการเปิดไฟล์ python และการแก้ไขโค้ด ได้แก่ PyCharm

3.2.2. ฮาร์ดแวร์ (Hardware)

1. หน่วยประมวลผล Intel(R) Core(TM) i7-6700HQ CPU @ 2.60GHz 2.59 GHz
2. หน่วยความจำ 12.0 GB

3.2.3. ชุดคำสั่งที่ใช้ในงานวิจัย (Library)

1. matplotlib.pyplot ใช้สำหรับการพล็อตกราฟและแผนภูมิ
2. numpy ใช้สำหรับการคำนวณทางตัวเลข จัดการ array และฟังก์ชันทางคณิตศาสตร์
3. pandas ใช้สำหรับการจัดการและวิเคราะห์ข้อมูลแบบตาราง
4. PyEMD ใช้สำหรับการแยกสัญญาณ (Empirical Mode Decomposition)
5. pmdarima.arima ใช้สำหรับการวิเคราะห์ข้อมูลแบบ ARIMA (Autoregressive Integrated Moving Average)
6. tensorflow.keras.models ใช้สำหรับการพัฒนาและการทำงานกับตัวแบบเรียนรู้เชิงลึก (Deep Learning)
7. TensorFlow.keras.layers ใช้สำหรับสร้างเลเยอร์ของตัวแบบเครือข่ายประสาทเทียม (Neural Network) เลเยอร์เหล่านี้ทำหน้าที่แปลงข้อมูลอินพุต ผ่านการคำนวณต่าง ๆ และส่งผลลัพธ์ไปยังเลเยอร์ถัดไป หรือส่งออกผลลัพธ์สุดท้ายของตัวแบบ
8. sklearn.preprocessing ใช้สำหรับการแปลงข้อมูลก่อนการนำเข้าสู่การฝึกสอนตัวแบบหรือการประมวลผลเพื่อให้ข้อมูลเหมาะสมสำหรับการใช้งาน
9. scipy.stats ใช้ในการทำงานกับการคำนวณทางสถิติและความน่าจะเป็น

3.3. การจัดเตรียมข้อมูล

ในการจัดเตรียมข้อมูลเริ่มจากการนำข้อมูลยอดขายสินค้าอะไหล่รถจักรยานยนต์ทั้งหมดมาพิจารณา และคัดเลือกชนิดสินค้าที่ส่งผลกระทบต่อธุรกิจผลิตอะไหล่รถจักรยานยนต์มากที่สุด ซึ่งก็คือ “สินค้าอะไหล่รถจักรยานยนต์ A” แสดงดังรูปที่ 3.2 มาเป็นชุดข้อมูลที่ต้องการนำมาวิเคราะห์หาค่าพยากรณ์ยอดขายอะไหล่รถจักรยานยนต์ ซึ่งนำข้อมูลที่เลือกแปลงเป็นข้อมูลอนุกรมเวลา แสดงดังรูปที่ 3.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กลุ่มสินค้า	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	รวม
A	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx
B	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx
C	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx
D	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx
F	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx	xxxx

รูปที่ 3.2 ตัวอย่างข้อมูล “สินค้าอะไหล่รถจักรยานยนต์ A” ก่อนทำการแปลงข้อมูล

1	Time	Value
2	2014-01	xxxx
3	2014-02	xxxx
4	2014-03	xxxx
5	2014-04	xxxx
6	2014-05	xxxx
7	2014-06	xxxx
8	2014-07	xxxx
9	2014-08	xxxx
10	2014-09	xxxx
11	2014-10	xxxx

รูปที่ 3.3 ตัวอย่างข้อมูล “สินค้าอะไหล่รถจักรยานยนต์ A” ที่ทำการแปลงเป็นข้อมูลอนุกรมเวลา

3.3.1. การแบ่งข้อมูล (split Data)

ข้อมูลที่ใช้ในการศึกษาจะถูกแบ่งออกเป็น 2 ส่วน ดังนี้

- ชุดข้อมูลฝึกสอน (Training Set) จำนวน 108 รายการ เริ่มตั้งแต่เดือน มกราคม พ.ศ. 2557 ถึง เดือน ธันวาคม พ.ศ. 2565 สำหรับการสร้างตัวแบบพยากรณ์
- ชุดข้อมูลทดสอบ (Test Set) จำนวน 11 รายการ เริ่มตั้งแต่เดือน มกราคม พ.ศ. 2566 ถึง เดือน พฤศจิกายน พ.ศ. 2566 สำหรับการประเมินตัวแบบพยากรณ์

3.4 การวิเคราะห์ข้อมูล

3.4.1. การวิเคราะห์การแจกแจงของข้อมูล

1. การวิเคราะห์การแจกแจงของข้อมูลยอดขายสินค้าอะไหล่รถจักรยานยนต์ “A” พิจารณาได้จากฮิสโทแกรม และสามารถทดสอบการแจกแจงปกติด้วยสถิติทดสอบคอลโมโกรอฟ-สมิร์นอฟ (Kolmogorov-Smirnov Test) เพื่อประเมินว่าข้อมูลมีการแจกแจงปกติหรือไม่

2. ถ้าข้อมูลมีการแจกแจงปกติ จะใช้สถิติอิงพารามิเตอร์ โดยที่

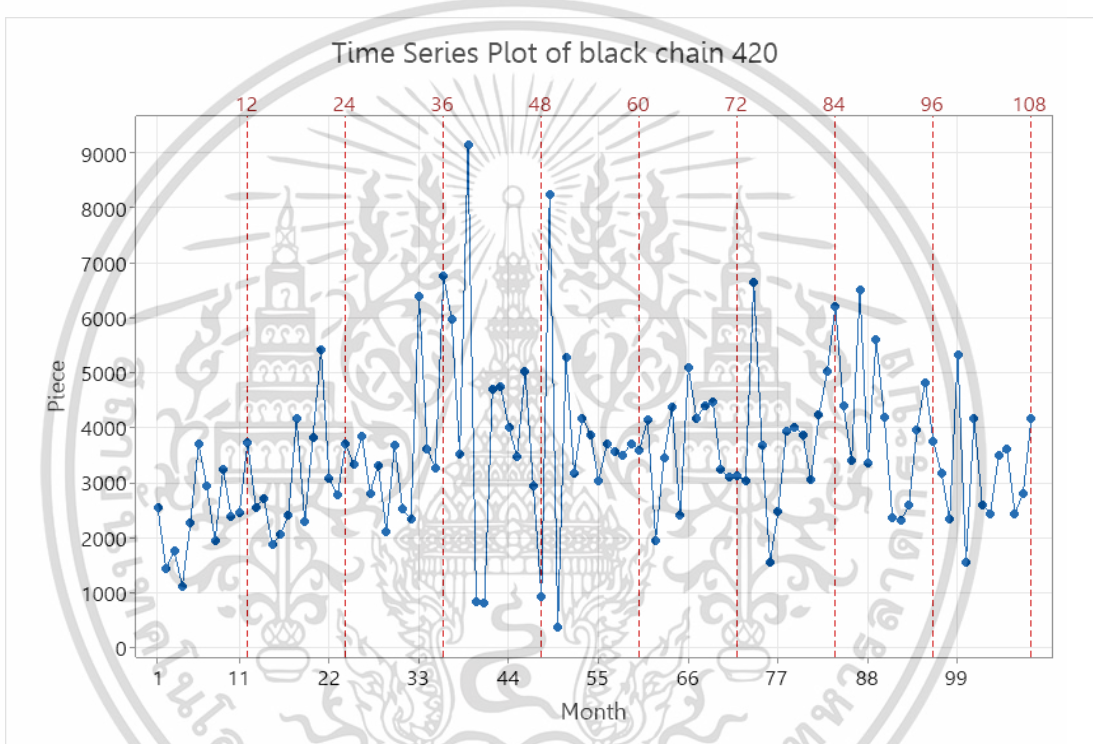
- การทดสอบแนวโน้ม: การทดสอบของฟอน นอยมันน์
- การทดสอบฤดูกาล: การทดสอบค่าสัมประสิทธิ์สหสัมพันธ์ในตนเอง และถ้าข้อมูลไม่มีการแจกแจงไม่ปกติ จะใช้สถิติไม่อิงพารามิเตอร์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในห้องเรียนเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามเผยแพร่ไปยังที่อื่น และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ถ้าข้อมูลอนุกรมเวลามีแนวโน้มหรือฤดูกาล แสดงว่าข้อมูลอนุกรมเวลาไม่เป็นสเตชันนารี แต่ถ้าข้อมูลอนุกรมเวลาไม่มีแนวโน้มหรือฤดูกาล แสดงว่าข้อมูลอนุกรมเวลาสเตชันนารี

3.4.2. การวิเคราะห์อนุกรมเวลา โดยวิธีบ็อกซ์-เจนกินส์

1. นำข้อมูลอนุกรมเวลามาพล็อตกราฟว่ามีค่าเฉลี่ยคงที่และค่าความแปรปรวนคงที่หรือไม่ กล่าวคือต้องมีสมบัติเป็นสเตชันนารี ตามรูปที่ 3.4
2. ถ้าหากข้อมูลอนุกรมเวลามีสมบัติไม่เป็นสเตชันนารี จะต้องทำการปรับข้อมูลให้มีสมบัติเป็นสเตชันนารี โดยการหาผลต่าง 1 ครั้งก่อนนำไปสร้าง PACF และ ACF



รูปที่ 3.4 อนุกรมเวลาจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

จากรูปที่ 3.4 จะเห็นได้ว่าอนุกรมเวลาจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีแนวโน้ม และอิทธิพลฤดูกาล

3.4.3 การสร้างตัวแบบพยากรณ์ด้วยวิธีการบ็อกซ์-เจนกินส์

วิธีการของบ็อกซ์-เจนกินส์ เหมาะกับข้อมูลที่มีลักษณะคงที่และไม่มีส่วนประกอบของแนวโน้มหรือความแปรผันเกี่ยวกับฤดูกาล หากข้อมูลยังมีลักษณะไม่คงที่หรือมีส่วนประกอบของแนวโน้มหรือความแปรผันเกี่ยวกับฤดูกาลอย่างชัดเจน จะต้องทำการหาผลต่างครั้งที่ 1 (1st Differencing) ซึ่งแบบจำลองมีข้อตกลงเบื้องต้นคือค่าสังเกตปัจจุบันมีความสัมพันธ์เป็นกระบวนการเชิงเส้นระหว่างค่าสังเกตและค่าคลาดเคลื่อนในอดีต (Chatfield, 2016) ให้นำหน้าไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เนื่องจากพบว่าข้อมูลมีความแปรผันทางฤดูกาลอย่างชัดเจน ทางผู้วิจัยจึงใช้การพยากรณ์วิธีบ็อกซ์-เจนกินส์ด้วยตัวแบบ ARIMA และ SARIMA ซึ่งเป็นตัวแบบที่เหมาะสมกับข้อมูลที่มีลักษณะนี้

ขั้นตอนการพยากรณ์ยอดขายอะไหล่รถจักรยานยนต์ ด้วยวิธีตัวแบบ ARIMA

1. การตรวจสอบข้อมูล และตรวจสอบส่วนประกอบของแนวโน้ม ว่ามีความแปรผันของฤดูกาลหรือไม่ โดยพิจารณาจากฟังก์ชันสหสัมพันธ์ในตัวเอง (ACF) และ ฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (PACF)

2. กำหนดตัวแบบ พิจารณา ค่า AIC (Akaike Information Criterion) ต่ำสุด

3. กำหนดช่วงของพารามิเตอร์ p , q และ d

4. ทดสอบค่าพารามิเตอร์

5. ตรวจสอบความเหมาะสมของตัวแบบ โดยใช้ตัวสถิติ ทดสอบ Box-Pierce and Ljung-Box Tests

6. สร้างผลลัพธ์การพยากรณ์

ขั้นตอนการพยากรณ์ยอดขายอะไหล่รถจักรยานยนต์ ด้วยวิธีตัวแบบ SARIMA

1. การตรวจสอบข้อมูล และตรวจสอบส่วนประกอบของแนวโน้ม ว่ามีความแปรผันของฤดูกาลหรือไม่ โดยพิจารณาจากฟังก์ชันสหสัมพันธ์ในตัวเอง (ACF) และ ฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (PACF)

2. กำหนดตัวแบบ พิจารณา ค่า AIC (Akaike Information Criterion) ต่ำสุด

3. กำหนดช่วงของพารามิเตอร์ p , d , q , P , D และ Q

4. ทดสอบค่าพารามิเตอร์

5. ตรวจสอบความเหมาะสมของตัวแบบ โดยใช้ตัวสถิติ ทดสอบ Box-Pierce and Ljung-Box Tests

6. สร้างผลลัพธ์การพยากรณ์

3.4.4 การพยากรณ์ ด้วยวิธี Long Short-Term Memory Networks (LSTMs)

ตัวแบบ LSTM ได้รับความนิยมในการจัดการกับข้อมูลชุดลำดับ (Sequential Data) เช่น ข้อความ (Text), เสียง (Audio) และชุดข้อมูลช่วงเวลา (Time Series Data) โดยเฉพาะ

ขั้นตอนการสร้างตัวแบบ LSTM

1. เตรียมข้อมูลให้เหมาะสมกับตัวแบบ LSTM

2. กำหนดโครงสร้างของโมเดล LSTM โดยระบุจำนวนของชั้น LSTM, ชั้น Dropout (สำหรับการป้องกันการเกิด Overfitting) และชั้น Dense (Fully Connected Layer) หรือชั้นอื่น ๆ ตามความเหมาะสมของงาน

3. กำหนด Optimizer

4. สร้างผลลัพธ์การพยากรณ์

การสร้างตัวแบบ LSTM โดยการเลือกค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมโดยวิธีการค้นหาแบบ Manual Search ดังนี้

1. จำนวน Epoch : ทำการกำหนดจำนวน Epoch เป็น 500, 1000, 1500, 2000, 2500 และ 3000 โดยพิจารณาเปรียบเทียบค่า MAPE ของตัวแบบที่มีจำนวน Epoch อยู่ในวง
ไม่ต่ำกว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การศึกษา พบว่า เมื่อจำนวน Epoch เท่ากับ 3000 จะให้ค่า MAPE ต่ำที่สุด ซึ่งจะได้ตัวแบบที่ดีที่สุด ดังนั้นผู้วิจัยจึงเลือกใช้จำนวน Epoch เท่ากับ 3000

2. จำนวน Batch size : กำหนดจำนวน Batch size เท่ากับ 64 ซึ่งเป็นขนาดมาตรฐานที่มักนิยมใช้กัน (Lin et al, 2020, Xian et al, 2019 and Yadav et al, 2020)
3. จำนวน Dropout : กำหนดจำนวน Dropout เท่ากับ 0.7
4. ฟังก์ชันการสูญเสีย (Loss Function) : ผู้วิจัยได้กำหนดเป็น Mean Absolute Percentage Error
5. Optimizer : ผู้วิจัยได้กำหนดเป็น amsgrad ซึ่งเป็น Optimizer ที่มีการพัฒนามาจาก Adam

3.5 การพยากรณ์ยอดขายอะไหล่รถจักรยานยนต์ด้วยวิธีผสม

ในขั้นตอนการสร้างตัวแบบพยากรณ์ผสมนั้น มีขั้นตอนการสร้างตัวแบบพยากรณ์ตามหัวข้อ

3.4.3 และ 3.4.4 แต่จะมีขั้นตอนเทคนิคเชิงประจักษ์เพิ่มเข้ามาดังนี้

1. แยกสลายอนุกรมเวลาด้านฉบับ ด้วยวิธี EMD เพื่อแยกเป็นองค์ประกอบย่อย (Intrinsic Mode Functions : IMFs) และส่วนเหลือ (Residual)
2. สร้างตัวแบบในการพยากรณ์ให้แก่ค่า IMF และค่า Residual สำหรับทั้ง 3 ตัวแบบ ได้แก่ ARIMA, SARIMA และ LSTM ตามหัวข้อ 3.4.4 – 3.4.5
3. ประเมินความเหมาะสมของตัวแบบพยากรณ์
4. นำผลการพยากรณ์ของแต่ละ IMF และค่า Residual มารวมเข้าด้วยกันเพื่อให้ได้ค่าพยากรณ์ ณ เวลาที่ t ดังสมการที่ 3.1

$$\hat{y}_t = \sum_{k=1}^N IMF_{kt} + \hat{r}_t \quad (3.1)$$

โดย \hat{y}_t คือ ค่าพยากรณ์ ณ เวลาที่ t

N คือ จำนวนของฟังก์ชัน IMF

K คือ ลำดับที่ของ IMF

t คือ 109-119

\hat{r}_t คือ ส่วนเหลือ (Residual)

5. สร้างผลลัพธ์การพยากรณ์

จากข้อมูลที่ใช้ในการพยากรณ์เป็นข้อมูลที่มีตัวแปรเดียว จึงใช้วิธี Empirical Mode Decomposition (EMD) เข้ามาผสมผสานกับแบบจำลองทั้ง 3 แบบจำลอง เพื่อเพิ่มประสิทธิภาพในการพยากรณ์

3.6 เกณฑ์การประเมินประสิทธิภาพของตัวแบบพยากรณ์

ประสิทธิภาพของตัวแบบพยากรณ์จะพิจารณาจากร้อยละการคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAPE) หากค่า MAPE ที่คำนวณได้มีค่าน้อย แสดงถึง การพยากรณ์มีความแม่นยำ โดย MAPE สามารถคำนวณหาค่าความผิดพลาดจากค่าพยากรณ์ในแต่ละช่วงเวลาหารด้วยข้อมูลจริง ณ เวลานั้น และเฉลี่ยความผิดพลาดที่แท้จริงเป็นร้อยละ โดยมีเกณฑ์ที่ใช้สำหรับการพยากรณ์ (Lewis et, 1982) ดังนี้

น้อยกว่า 10%	จัดว่าผลการพยากรณ์ค่อนข้างแม่นยำ
10% - 20%	จัดว่าผลการพยากรณ์ใช้ได้ดี
20% - 50%	จัดว่าผลการพยากรณ์พอใช้
มากกว่า 50%	จัดว่าผลการพยากรณ์ไม่แม่นยำ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


บทที่ 4

ผลการวิจัยและอภิปรายผล

ในบทนี้จะกล่าวถึงผลของการวิเคราะห์ข้อมูลปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A และทำการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบพยากรณ์เชิงเดียวกับตัวแบบผสม

4.1 ผลการวิเคราะห์ข้อมูลเบื้องต้น

4.1.1. ผลการวิเคราะห์ปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A




รูปที่ 4.1 อนุกรมเวลาปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A

จากรูปที่ 4.1 พบว่า อนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีลักษณะมีแนวโน้มและอิทธิพลของฤดูกาล จึงนำข้อมูลอนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ไปทดสอบการแจกแจงปกติ เพื่อเลือกสถิติทดสอบแนวโน้มและอิทธิพลของฤดูกาล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


4.1.2. การทดสอบการแจกแจงปกติของปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A



รูปที่ 4.2 ฮิสโทแกรมของปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A

จากรูปที่ 4.2 แสดงการกระจายตัวของข้อมูลปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A จากฮิสโทแกรมจะพิจารณาได้ว่า การแบ่งช่วงในแต่ละชั้นภูมิส่งผลต่อการพิจารณาไม่ชัดเจน ดังนั้นฮิสโทแกรมเพียงอย่างเดียวไม่สามารถยืนยันได้แน่ชัดว่าข้อมูลชุดนี้มีการแจกแจงแบบปกติ จึงจำเป็นต้องทดสอบเพิ่มเติมโดยใช้การทดสอบ คอลโมโกรอฟ-สมิร์นอฟ (Kolmogorov-Smirnov Test)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.3 การทดสอบการแจกแจงปกติคอลโมโกรอฟ-สมิ์รโนฟ

สมมติฐานการทดสอบ

H_0 : ข้อมูลมีการแจกแจงแบบปกติ

H_1 : ข้อมูลไม่มีการแจกแจงแบบปกติ

จากผลการคำนวณที่ได้พบว่ามีค่า <0.010 ซึ่งมีค่าน้อยกว่าระดับนัยสำคัญที่ 0.05 จึงปฏิเสธสมมติฐานว่ายอมรับสมมติฐานรอง คือข้อมูลไม่มีการแจกแจงแบบปกติ ดังนั้นจึงเลือกใช้การทดสอบแนวนอนและอิทธิพลฤดูกาลแบบไม่อิงพารามิเตอร์ นั่นคือ ทดสอบแนวนอนโดยใช้การทดสอบของแดเนียล (Danial’s Test) และทดสอบอิทธิพลฤดูกาลโดยการใช้การทดสอบครัสคาล-วอลลิส (Kruskal-Wallis)

4.1.3. การทดสอบแนวนอนแบบไม่อิงพารามิเตอร์ โดยใช้การทดสอบของแดเนียล (Danial’s Test)

สมมติฐานการทดสอบ

H_0 : อนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ไม่มีแนวนอน

H_1 : อนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีแนวนอน

ตัวสถิติทดสอบ

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

$$= 1 - \frac{6(352292)}{108(108^2 - 1)}$$

$$= 0.6781$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ในงานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมีเหตุดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กำหนดระดับนัยสำคัญ คือ 0.05 มีบริเวณวิกฤตเป็น $|Z| \leq -Z_{\frac{\alpha}{2}}$

โดย

$$\begin{aligned} Z &= \frac{(r_s - \mu_{r_s})}{\sigma_{r_s}} \\ &= \frac{-0.6781}{1} \\ &= \frac{-0.6781}{\sqrt{108-1}} \\ &= -7.1044 \end{aligned}$$

เนื่องจาก $Z = -7.1044 < Z_{0.025} = -1.96$ ซึ่งตกอยู่ในบริเวณวิกฤต จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 รายละเอียดแสดงได้ดังรูปที่ ค.1 ของภาคผนวก ค
ดังนั้น อนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีแนวโน้ม

4.1.4. การทดสอบแนวโน้มแบบไม่อิงพารามิเตอร์ โดยใช้การทดสอบของครัสคาล-วอลลิส (Kruskal-Wallis)

สำหรับรูปแบบบวก

สมมติฐานการทดสอบ

$$H_0 : S_1 = S_2 = S_3 = \dots = S_9 = 0$$

$$H_1 : S_i \neq 0 \text{ สำหรับบางฤดูกาล เมื่อ } i=1,2,3,\dots,9$$

ตัวสถิติทดสอบ

$$\begin{aligned} H &= \frac{12}{n(n+1)} \left[\sum_{i=1}^L \frac{R_i^2}{n_i} \right] - 3(n+1) \\ &= \frac{12}{96(96+1)} \left[\frac{468^2}{8} + \frac{280^2}{8} + \frac{515^2}{8} + \dots + \frac{481^2}{8} \right] - 3(96+1) \\ &= \frac{12}{96(97)} [238643.50] - 3(97) \\ &= 16.5303 \end{aligned}$$

กำหนดระดับนัยสำคัญ คือ 0.05 มีบริเวณวิกฤตเป็น $H \geq \chi^2_{\alpha, L-1}$

เนื่องจาก $H = 16.5303 > \chi^2_{0.05, 8} = 15.507$ ซึ่งตกอยู่ในบริเวณวิกฤต จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 รายละเอียดแสดงได้ดังรูปที่ ค.2 ของภาคผนวก ค

ดังนั้น อนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีอิทธิพลฤดูกาล

สำหรับรูปแบบคูณ

สมมติฐานการทดสอบ

$$H_0 : S_1 = S_2 = S_3 = \dots = S_9 = 1$$

$$H_1 : S_i \neq 1 \text{ สำหรับบางฤดูกาล เมื่อ } i=1,2,3,\dots,9$$

ตัวสถิติทดสอบ

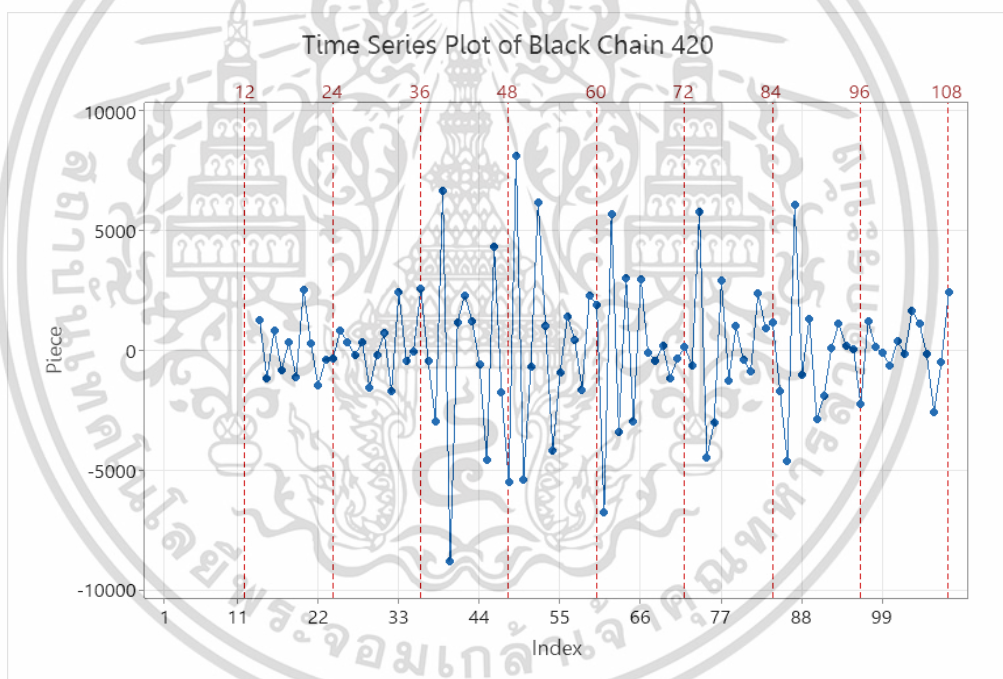
เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของสำนักงานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\begin{aligned}
 H &= \frac{12}{n(n+1)} \left[\sum_{i=1}^L \frac{R_i^2}{n_i} \right] - 3(n+1) \\
 &= \frac{12}{96(96+1)} \left[\frac{466^2}{8} + \frac{293^2}{8} + \frac{514^2}{8} + \dots + \frac{482^2}{8} \right] - 3(96+1) \\
 &= \frac{12}{96(97)} [238234.25] - 3(97) \\
 &= 16.0029
 \end{aligned}$$

กำหนดระดับนัยสำคัญ คือ 0.05 มีบริเวณวิกฤตเป็น $H \geq \chi^2_{\alpha, L-1}$

เนื่องจาก $H = 16.0029 > \chi^2_{0.05, 8} = 15.507$ ซึ่งตกอยู่ในบริเวณวิกฤต จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 รายละเอียดแสดงได้ดังรูปที่ ค.2 ของภาคผนวก ค ดังนั้น อนุกรมเวลาปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีอิทธิพลฤดูกาล

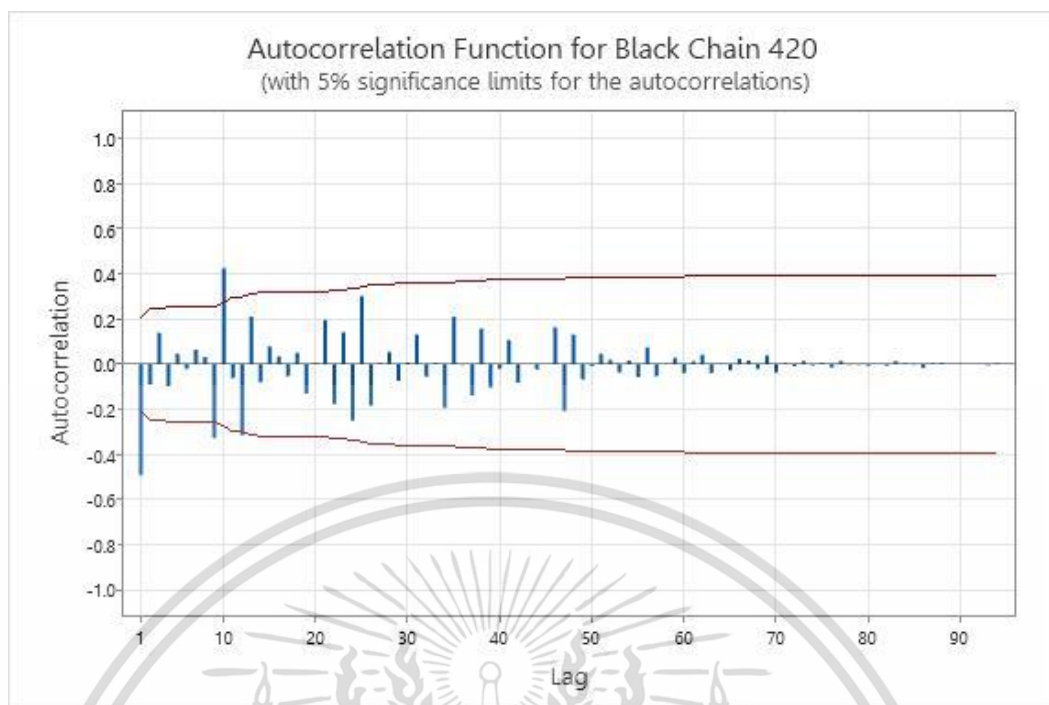
4.1.5. ผลการสร้างตัวแบบพยากรณ์เชิงเดี่ยวด้วยวิธีการบ็อก-เจนกินส์



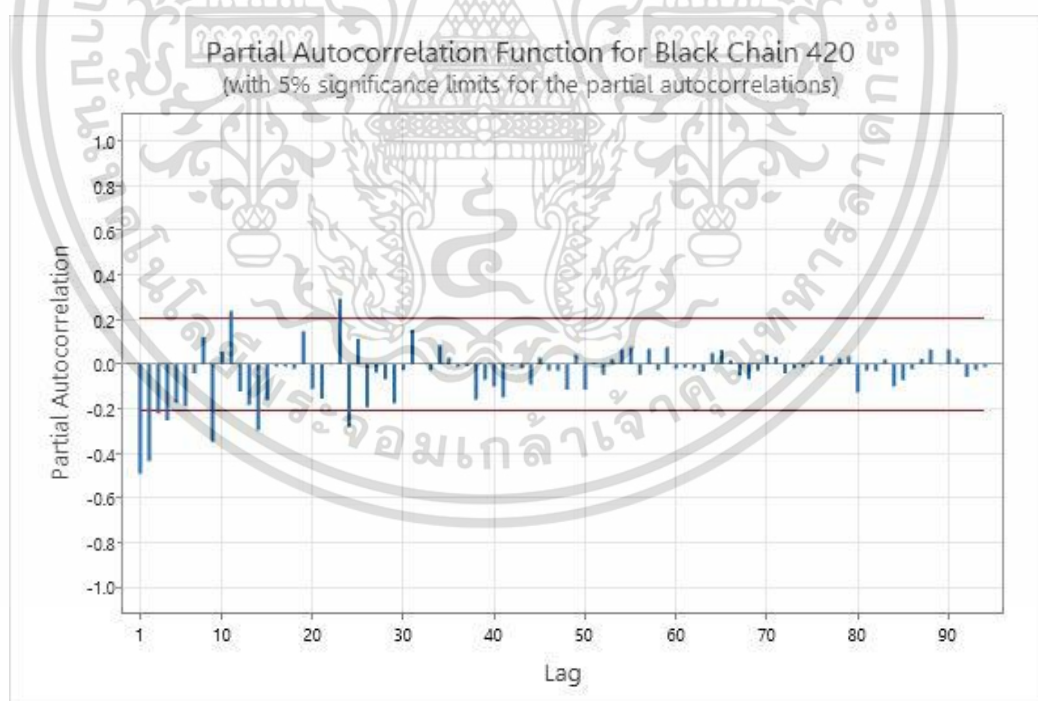
รูปที่ 4.4 อนุกรมเวลาจากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง

จากรูปที่ 4.4 พบว่า อนุกรมเวลาที่ได้จากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง ของอนุกรมเวลามูลค่าการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A มีค่าเฉลี่ย และความแปรปรวนคงที่แล้ว ดังนั้นจึงนำอนุกรมเวลาชุดใหม่นี้ ไปพล็อตคอเรโลแกรมของ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) ดังรูปที่ 4.5 และ 4.6 เพื่อหาตัวแบบพยากรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.5 คอเรลโรลแกรม Autocorrelation Function (ACF) ของอนุกรมจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ที่จากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง



รูปที่ 4.6 คอเรลโรลแกรม Partial Autocorrelation Function (PACF) ของอนุกรมจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A ที่จากการหาผลต่าง 1 ครั้ง และหาผลต่างฤดูกาล 1 ครั้ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. การพยากรณ์ด้วยตัวแบบ ARIMA

ผลการวิเคราะห์การแจกแจงข้อมูลปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A สามารถแสดงดังรูปที่ 4.5 ซึ่งจะเห็นได้ว่า ACF มีลักษณะลดลงอย่างรวดเร็วตั้งแต่ Lag 1 และจากรูปที่ 4.6 PACF มีลักษณะลดลงอย่างรวดเร็วตั้งแต่ Lag 4 และมีการหาผลต่าง 1 ครั้ง ดังนั้นตัวแบบของอนุกรมเวลาคือ $ARIMA(4,1,1)$

ตารางที่ 4.1 การทดสอบค่าพารามิเตอร์ของตัวแบบ $ARIMA(4,1,1)$

Statistics	Coef.	SE Coef.	t	P-value
ϕ_1	-0.1932	0.120	-1.607	0.108
ϕ_2	-0.0251	0.167	-0.150	0.881
ϕ_3	0.1174	0.168	0.698	0.485
ϕ_4	-0.0463	0.176	-0.263	0.792
θ_1	-0.8734	0.111	-7.881	0.000

สมมติฐานในการทดสอบ

$$H_0: \phi_1 = 0$$

$$H_1: \phi_1 \neq 0$$

จากตารางที่ 4.1 พบว่าค่า p-value = 0.108 > $\alpha = 0.05$ จึงยอมรับ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ ϕ_1 ในตัวแบบมีค่าเท่ากับ 0 หรือ พารามิเตอร์ ϕ_1 ไม่ควรมีในตัวแบบ

จากการทดสอบค่าพารามิเตอร์พบตัวพารามิเตอร์ที่ควรมีในตัวแบบ ดังนั้นตัวแบบ $ARIMA(4,1,1)$ ไม่เป็นตัวแบบที่เหมาะสม จึงทำการกำหนดช่วงของพารามิเตอร์ คือ p อยู่ในช่วง [0 – 5], d อยู่ในช่วง [0 – 1] และ q อยู่ในช่วง [0 – 5] เพื่อที่จะหาตัวแบบที่เหมาะสมจากการพิจารณาตัวแบบที่มีค่า AIC น้อยที่สุด ดังตารางที่ 4.2 รายละเอียดแสดงได้ดังรูปที่ ข.1 ของภาคผนวก ข

ตารางที่ 4.2 ค่า AIC ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q)$

$ARIMA(p,d,q)$	AIC
ARIMA(0,1,0)	1597.483
ARIMA(1,1,0)	1570.139
ARIMA(0,1,1)	1516.862
ARIMA(0,1,0)	1595.484
ARIMA(2,1,0)	1461.783
ARIMA(2,1,0)	1459.796
...	...
ARIMA(1,1,0)	1568.139

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับ... การศึกษาเท่านั้น... โปรดใช้ประโยชน์ด้านการค้า...
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อพิจารณาตารางที่ 4.2 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่สุด ได้แก่ $p=2$, $d=1, q=0$ และตัวแบบที่เหมาะสมคือ ตัวแบบ $ARIMA(2,1,0)$ ซึ่งมีรูปแบบทั่วไปดังสมการที่ 4.1

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B) Y_t = \theta_0 + \varepsilon_t \quad (4.1)$$

โดยกำหนด

Y_t แทน ค่าพยากรณ์ ณ เวลา t

ε_t แทน ค่าความคลาด ณ เวลาที่ t

B แทน ตัวดำเนินการย้อนหลัง

ϕ_1 แทน การถดถอยในตัวเองแบบไม่มีฤดูกาลอันดับ 1

ϕ_2 แทน การถดถอยในตัวเองแบบไม่มีฤดูกาลอันดับ 2

θ_0 แทน ค่าเฉลี่ยเคลื่อนที่แบบไม่มีฤดูกาล

หลังจากได้ตัวแบบที่เหมาะสมจากสมการที่ 4.1 แล้วจึงนำตัวแบบดังกล่าวมาประมาณค่าพารามิเตอร์ดังตารางที่ 4.3

ตารางที่ 4.3 การทดสอบค่าพารามิเตอร์ $ARIMA(p,d,q)$

Statistics	Coef.	SE Coef.	t	P-value
ϕ_1	-0.8404	0.061	-13.807	0.000
ϕ_2	-0.4649	0.089	-5.199	0.000

สมมติฐานในการทดสอบ

$$H_0: \phi_1 = 0$$

$$H_1: \phi_1 \neq 0$$

จากตารางที่ 4.3 พบว่าค่า $p\text{-value} = 0.000 < \alpha = 0.05$ จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ ϕ_1 ในตัวแบบมีค่าไม่เท่ากับ 0 หรือ พารามิเตอร์ ϕ_1 ควรมีในตัวแบบ

$$H_0: \phi_2 = 0$$

$$H_1: \phi_2 \neq 0$$

จากตารางที่ 4.3 พบว่าค่า $p\text{-value} = 0.000 < \alpha = 0.05$ จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ ϕ_2 ในตัวแบบมีค่าไม่เท่ากับ 0 หรือ พารามิเตอร์ ϕ_2 ควรมีในตัวแบบ ดังนั้นตัวแบบ $ARIMA(2,1,0)$ เป็นตัวแบบที่เหมาะสม

จากนั้นทำการตรวจสอบค่าความคลาดเคลื่อนว่าจะต้องไม่มีสหสัมพันธ์ในตัวเองด้วย Box-Pierce and Ljung-Box Tests ดังตารางที่ 4.4

ตารางที่ 4.4 การทดสอบความเป็นอิสระของค่าความคลาดเคลื่อนของตัวแบบ ARIMA ด้วย Box-Pierce and Ljung-Box Tests

Modified Box-Pierce (Ljung-Box) Chi-square Statistics	
Q	0.93
p-value	0.33

สมมติฐานในการทดสอบ

$$H_0 : \rho_e(1) = \rho_e(2) = \rho_e(3) = \dots = \rho_e(k) = 0$$

(ค่าความคลาดเคลื่อนของตัวแบบไม่มีสหสัมพันธ์ในตัวเองทุกช่วงเวลา)

$$H_1 : \rho_e(k) \text{ อย่างน้อยหนึ่งค่าไม่เท่ากับ } 0 \text{ สำหรับ } k = 1, 2, 3, \dots, m$$

(ค่าความคลาดเคลื่อนของตัวแบบมีสหสัมพันธ์ในตัวเองทุกช่วงเวลา)

จากตารางที่ 4.4 พบว่าค่า p-value = 0.33 < $\alpha = 0.05$ จึงยอมรับ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปว่า ค่าความคลาดเคลื่อนของตัวแบบไม่มีสหสัมพันธ์ในตัวเองทุกช่วงเวลา ดังนั้น แสดงว่า $ARIMA(2,1,0)$ เป็นตัวแบบที่เหมาะสมที่สุดดังตาราง 4.4

ตารางที่ 4.5 ค่าพารามิเตอร์ของตัวแบบที่เหมาะสมที่สุดของตัวแบบ ARIMA

ตัวแบบ	พารามิเตอร์		
	P	d	q
$ARIMA(2,1,0)$	2	1	0

ดังนั้นสมการพยากรณ์ตัวแบบ ARIMA คือ

$$Y_t = \theta_0 + (1 + \phi_1)Y_{t-1} + (\phi_2 - \phi_1)Y_{t-2} - \phi_2 Y_{t-3} + \varepsilon_t$$

2. การพยากรณ์ด้วยตัวแบบ SARIMA

จากที่กล่าวในการวิเคราะห์การแจกแจงข้อมูลปริมาณการสั่งซื้ออะไหล่รถจักรยานยนต์ A จากรูปที่ 4.5 ว่า ACF มีลักษณะลดลงอย่างรวดเร็วตั้งแต่ Lag 1 จากรูปที่ 4.6 PACF มีลักษณะลดลงอย่างรวดเร็วตั้งแต่ Lag 4 และมีการหาผลต่าง 1 ครั้งจึงได้ตัวแบบ $ARIMA(4,1,1)$ ในส่วนของอิทธิพลฤดูกาล พบว่า ACF ที่ Lag 12, 24, 36, 48, ... มีลักษณะลดลงอย่างรวดเร็ว และ PACF ที่ Lag 12, 24, 36, 48, ... มีลักษณะลดลงอย่างรวดเร็วและมีการหาผลต่างฤดูกาล 1 ครั้ง จึงได้ตัวแบบ $SARIMA(1,1,1)_{12}$ ดังนั้น ตัวแบบอนุกรมเวลา คือ $ARIMA(4,1,1) \times SARIMA(1,1,1)_{12}$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.6 การทดสอบค่าพารามิเตอร์ของตัวแบบ $ARIMA(4,1,1) \times SARIMA(1,1,1)_{12}$

Statistics	Coef.	SE Coef.	t	P-value
ϕ_1	-0.0175	0.124	-0.142	0.887
ϕ_2	0.0710	0.127	0.558	0.577
ϕ_3	0.1992	0.134	1.484	0.138
ϕ_4	-0.0914	0.139	0.660	0.509
θ_1	-0.9390	0.125	-7.515	0.000
Φ_{12}	0.0680	0.134	0.508	0.611
Θ_{12}	-0.9997	0.171	-5.832	0.000

สมมติฐานในการทดสอบ

$$H_0 : \phi_1 = 0$$

$$H_1 : \phi_1 \neq 0$$

จากตารางที่ 4.6 พบว่าค่า p-value = 0.887 > $\alpha = 0.05$ จึงยอมรับ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ ϕ_1 ในตัวแบบมีค่าเท่ากับ 0 หรือ พารามิเตอร์ ϕ_1 ไม่ควรมีในตัวแบบ

จากการทดสอบค่าพารามิเตอร์ พบตัวพารามิเตอร์ที่ไม่ควรมีในตัวแบบ ดังนั้นตัวแบบ $ARIMA(4,1,1) \times SARIMA(1,1,1)_{12}$ ไม่เป็นตัวแบบที่เหมาะสม จึงทำการกำหนดช่วงของพารามิเตอร์ คือ $p = 4, d = 1, q = 1, P = 1, D = 1, Q = 1$ เพื่อที่จะหาตัวแบบที่เหมาะสมจากการพิจารณาตัวแบบที่มีค่า AIC น้อยที่สุด ดังตารางที่ 4.7 รายละเอียดแสดงได้ดังรูปที่ ข.2 ของภาคผนวก ข

ตารางที่ 4.7 ค่า AIC ในแต่ละอันดับของตัวแบบ $ARIMA(p, d, q) \times SARIMA(P, D, Q)_s$

$ARIMA(p, d, q) \times SARIMA(P, D, Q)_s$	AIC
$ARIMA(0,1,0) \times SARIMA(0,1,0)_{12}$	1850.192
$ARIMA(1,1,0) \times SARIMA(1,1,0)_{12}$	1806.212
$ARIMA(2,1,0) \times SARIMA(2,1,0)_{12}$	1768.981
$ARIMA(2,1,0) \times SARIMA(1,1,0)_{12}$	1790.389
$ARIMA(0,1,2) \times SARIMA(1,1,0)_{12}$	1769.136
$ARIMA(0,1,1) \times SARIMA(2,1,0)_{12}$	1756.394
...	...
$ARIMA(0,1,0) \times SARIMA(2,1,0)_{12}$	1827.185
$ARIMA(1,1,1) \times SARIMA(2,1,0)_{12}$	1756.689
$ARIMA(1,1,0) \times SARIMA(2,1,0)_{12}$	1792.918
$ARIMA(1,1,2) \times SARIMA(2,1,0)_{12}$	1766.713

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการสงวนสิทธิ์อื่น ๆ ที่ปรากฏ ไม่อนุญาตให้ทำซ้ำโดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อพิจารณาตารางที่ 4.7 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่สุด ได้แก่ $p=0$, $d=1$, $q=1$ และ $P=2$, $D=1$, $Q=0$ ดังนั้น ตัวแบบที่เหมาะสมคือ ตัวแบบ $ARIMA(0,1,1) \times SARIMA(2,1,0)_{12}$ ซึ่งมีรูปแบบทั่วไปดังสมการที่ 4.2

$$(1 - \Phi_{12} B^{12})(1 - B^{12})(1 - B) Y_t = \theta_0(1 - \theta_1 B) + \varepsilon_t \quad (4.2)$$

โดยกำหนด

Y_t แทน ค่าพยากรณ์ ณ เวลา t

ε_t แทน ค่าความคลาดเคลื่อน ณ เวลาที่ t

B แทน ตัวดำเนินการย้อนหลัง

θ_1 แทน การถดถอยในตัวเองแบบไม่มีฤดูกาลอันดับที่ 1

Φ_{12} แทน ค่าเฉลี่ยเคลื่อนที่แบบไม่มีฤดูกาลอันดับที่ 1

หลังจากได้ตัวแบบที่เหมาะสมจากสมการที่ 4.2 แล้วจึงนำตัวแบบดังกล่าวมาประมาณค่าพารามิเตอร์ดังตารางที่ 4.8

ตารางที่ 4.8 การทดสอบค่าพารามิเตอร์ $ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$

Statistics	Coef.	SE Coef.	t	P-value
θ_1	-0.9137	0.048	-18.843	0.000
Φ_{12}	-0.5155	0.112	-4.616	0.000
Φ_{24}	-0.3634	0.097	-3.751	0.000

สมมติฐานในการทดสอบ

$$H_0 : \theta_1 = 0$$

$$H_1 : \theta_1 \neq 0$$

จากตารางที่ 4.8 พบว่าค่า $p\text{-value} = 0.000 < \alpha = 0.05$ จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ θ_1 ในตัวแบบมีค่าไม่เท่ากับ 0 หรือ พารามิเตอร์ θ_1 ควรมีในตัวแบบ

$$H_0 : \Phi_{12} = 0$$

$$H_1 : \Phi_{12} \neq 0$$

จากตารางที่ 4.8 พบว่าค่า $p\text{-value} = 0.000 < \alpha = 0.05$ จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ Φ_{12} ในตัวแบบมีค่าไม่เท่ากับ 0 หรือ พารามิเตอร์ Φ_{12} ควรมีในตัวแบบ

$$H_0 : \Phi_{24} = 0$$

$$H_1 : \Phi_{24} \neq 0$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.8 พบว่าค่า p-value = 0.000 < $\alpha = 0.05$ จึงปฏิเสธ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปคือ ค่าพารามิเตอร์ Φ_{24} ในตัวแบบมีค่าไม่เท่ากับ 0 หรือ พารามิเตอร์ Φ_{24} ควรมีในตัวแบบ ดังนั้นตัวแบบ $ARIMA(0,1,1) \times SARIMA(2,1,0)_{12}$ เป็นตัวแบบที่เหมาะสม

จากนั้นทำการตรวจสอบค่าความคลาดเคลื่อนว่าจะต้องไม่มีสหสัมพันธ์ในตัวเองด้วย Box-Pierce and Ljung-Box Tests ดังตารางที่ 4.9

ตารางที่ 4.9 การทดสอบความเป็นอิสระของค่าความคลาดเคลื่อนของตัวแบบ SARIMA ด้วย Box-Pierce and Ljung-Box Tests

Modified Box-Pierce (Ljung-Box) Chi-square Statistics	
Q	2.48
p-value	0.12

สมมติฐานในการทดสอบ

$$H_0: \rho_e(1) = \rho_e(2) = \rho_e(3) = \dots = \rho_e(k) = 0$$

(ค่าความคลาดเคลื่อนของตัวแบบไม่มีสหสัมพันธ์ในตัวเองทุกช่วงเวลา)

$$H_1: \rho_e(k) \text{ อย่างน้อยหนึ่งค่าไม่เท่ากับ } 0 \text{ สำหรับ } k = 1, 2, 3, \dots, m$$

(ค่าความคลาดเคลื่อนของตัวแบบมีสหสัมพันธ์ในตัวเองทุกช่วงเวลา)

จากตารางที่ 4.9 พบว่าค่า p-value = 0.33 < $\alpha = 0.05$ จึงยอมรับ H_0 ที่ระดับนัยสำคัญ 0.05 สรุปว่า ค่าความคลาดเคลื่อนของตัวแบบไม่มีสหสัมพันธ์ในตัวเองทุกช่วงเวลา ดังนั้นแสดงว่า $ARIMA(0,1,1) \times SARIMA(2,1,0)_{12}$ เป็นตัวแบบที่เหมาะสมที่สุดดังตารางที่ 4.10

ตารางที่ 4.10 ค่าพารามิเตอร์ของตัวแบบที่เหมาะสมที่สุดของตัวแบบ SARIMA

ตัวแบบ	พารามิเตอร์					
	p	D	q	P	D	Q
$ARIMA(0,1,1) \times SARIMA(2,1,0)_{12}$	0	1	1	2	1	0

ดังนั้นสมการพยากรณ์ตัวแบบ ARIMA คือ

$$Y_t = \theta_0 + Y_{t-1} + Y_{t-12}(1 + \Phi_{12}) - Y_{t-13}\Phi_{12}(Y_{t-24} + Y_{t-25}) + \theta_1\varepsilon_{t-1} + \varepsilon_t$$

4.1.6. ผลการสร้างตัวแบบพยากรณ์เชิงเดี่ยวด้วยวิธีการเรียนรู้เชิงลึก

การกำหนดค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมด้วยวิธี Manual Search โดยทำการเลือกค่าไฮเปอร์พารามิเตอร์ที่จะศึกษา ดังตารางที่ 4.11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.11 การกำหนดค่าไฮเปอร์พารามิเตอร์

ข้อกำหนดต่างๆในการสร้างตัวแบบ	ค่าไฮเปอร์พารามิเตอร์
อัลกอริทึม (Algorithm)	LSTM
จำนวน Epoch	500, 1000, 1500, 2000, 2500 และ 3000
จำนวน Batch size	64
จำนวน Dropout	0.7
ฟังก์ชันการสูญเสีย (Loss Function)	Mean Absolute Percentage Error
Optimizer	Amsgrad

จากการศึกษา พบว่าค่าของ Mean Absolute Percentage Error (MAPE) ลดลงตามจำนวน Epoch ที่เพิ่มขึ้นในการสร้างตัวแบบพยากรณ์ พบว่า เมื่อจำนวน Epoch เท่ากับ 3000 จะให้ค่า MAPE เท่ากับร้อยละ 39.75 ซึ่งจะได้ตัวแบบพยากรณ์ที่ดีที่สุด ตามตารางที่ 4.12

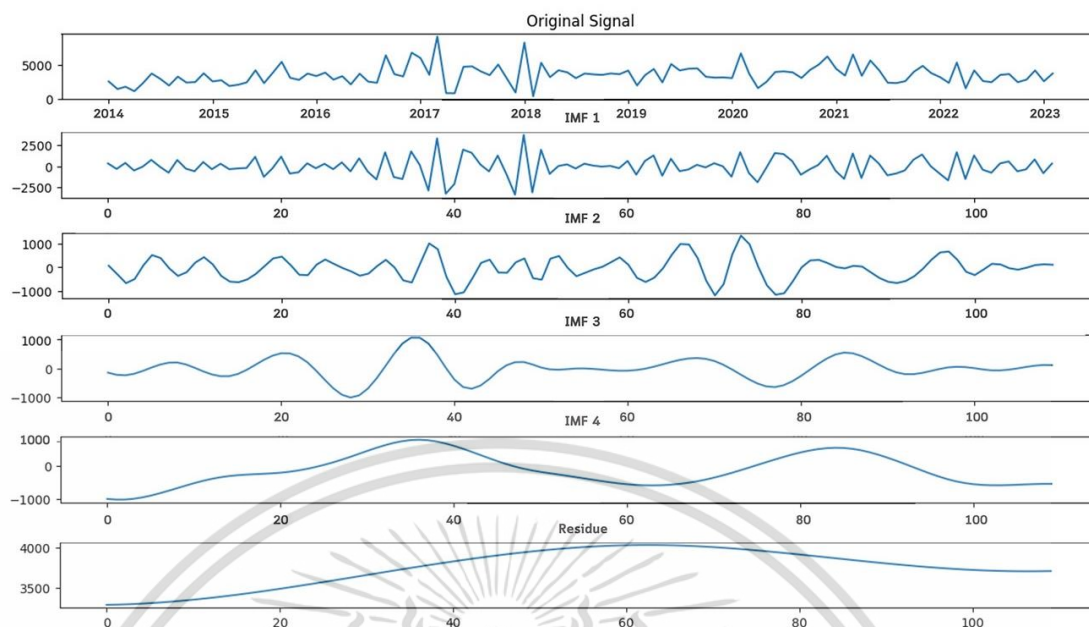
ตารางที่ 4.12 การเปรียบเทียบค่า MAPE สำหรับแต่ละ Epoch ของตัวแบบ LSTM

Epoch	MAPE
500	57.64
1000	50.36
1500	47.67
2000	43.62
2500	41.41
3000	39.75

4.2 การแยกสัญญาณรบกวนด้วยเทคนิคเชิงประจักษ์

ข้อมูลปริมาณการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A (Original signal) ถูกแยกสัญญาณรบกวนตามขั้นตอนจะได้เป็น IMF_1 ถึง IMF_4 เรียกว่าสัญญาณย่อย (Intrinsic Mode Functions, IMFs) โดยสัญญาณย่อยลำดับที่ 1 (IMF_1) ถึงสัญญาณย่อยลำดับที่ 2 (IMF_2) จะเป็นสัญญาณที่มีความถี่สูง และสัญญาณย่อยลำดับที่ 3 (IMF_3) ถึงสัญญาณย่อยลำดับที่ 4 (IMF_4) จะเป็นสัญญาณที่มีความถี่ต่ำ และ Residual คือสัญญาณส่วนเหลือที่มีความถี่ต่ำที่สุด ตามรูปที่ 4.7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.7 องค์ประกอบสัญญาณที่ได้จากการแยกส่วนประกอบโดยใช้เทคนิคเชิงประจักษ์

4.2.1 ผลการสร้างตัวแบบผสมกับเทคนิคเชิงประจักษ์

1. ตัวแบบ EMD-ARIMA

ในการพิจารณาตัวแบบที่เหมาะสม จะทำการพิจารณาตัวแบบที่มีค่า AIC น้อยที่สุด ของในแต่ละ IMF1-4 และ Residual ดังตารางที่ 4.13 - 4.17

ตารางที่ 4.13 ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q)$

$ARIMA(p,d,q)$	AIC
ARIMA(0,1,0)	1941.238
ARIMA(1,1,0)	1891.410
ARIMA(2,1,0)	1851.912
ARIMA(3,1,0)	1843.506
ARIMA(4,1,0)	1839.128
ARIMA(5,1,0)	1828.319
ARIMA(4,1,0)	1837.127
ARIMA(5,1,1)	inf
ARIMA(4,1,1)	inf

เมื่อพิจารณตารางที่ 4.13 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 5, d = 1, q = 0$ และตัวแบบที่เหมาะสมของ IMF1 คือตัวแบบ $ARIMA(5,1,0)$ รายละเอียดแสดงได้ดังรูปที่ ข.3 ของภาคผนวก ข เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.14 ค่า AIC ของ IMF 2 ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q)$

$ARIMA(p,d,q)$	AIC
ARIMA(0,1,0)	1597.483
ARIMA(1,1,0)	1570.139
ARIMA(0,1,1)	1516.862
ARIMA(3,1,1)	1456.563
ARIMA(3,1,0)	1461.422
ARIMA(2,1,1)	1453.400
...	...
ARIMA(1,1,1)	1507.267
ARIMA(2,1,0)	1459.796
ARIMA(3,1,1)	1454.575
ARIMA(1,1,0)	1568.139
ARIMA(3,1,0)	1459.435

เมื่อพิจารณตารางที่ 4.14 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 2$, $d = 1$, $q = 1$ และตัวแบบที่เหมาะสมของ IMF 2 คือตัวแบบ $ARIMA(2,1,1)$ รายละเอียดแสดงได้ดังรูปที่ ข.4 ของภาคผนวก ข

ตารางที่ 4.15 ค่า AIC ของ IMF 3 ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q)$

$ARIMA(p,d,q)$	AIC
ARIMA(0,1,0)	1396.810
ARIMA(4,1,2)	873.303
ARIMA(3,1,1)	868.843
ARIMA(2,1,1)	869.754
ARIMA(3,1,0)	873.290
ARIMA(4,1,1)	868.773
ARIMA(4,1,0)	873.258
ARIMA(5,1,1)	869.216
ARIMA(4,1,2)	871.748
$ARIMA(p,d,q)$	AIC
ARIMA(3,1,2)	869.440
ARIMA(5,1,0)	874.137

เมื่อพิจารณตารางที่ 4.15 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 4$, $d = 1$, $q = 1$ และตัวแบบที่เหมาะสมของ IMF 3 คือตัวแบบ $ARIMA(4,1,1)$ รายละเอียดแสดงได้ดังรูปที่ ข.5 ของภาคผนวก ข

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งไม่มีเหตุเปลี่ยนแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.16 ค่า AIC ของ IMF 4 ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q)$

$ARIMA(p,d,q)$	AIC
ARIMA(0,1,0)	1131.903
ARIMA(1,1,0)	769.882
ARIMA(2,1,2)	280.838
ARIMA(4,1,0)	242.351
ARIMA(4,1,2)	242.605
ARIMA(3,1,1)	238.473
...	...
ARIMA(2,1,1)	325.024
ARIMA(3,1,0)	263.207
ARIMA(4,1,1)	238.949
ARIMA(3,1,2)	239.007
ARIMA(2,1,2)	279.424

เมื่อพิจารณตารางที่ 4.16 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 3, d = 1, q = 1$ และตัวแบบที่เหมาะสมของ IMF 4 คือ ตัวแบบ $ARIMA(3,1,1)$ รายละเอียดแสดงได้ดังรูปที่ ข.6 ของภาคผนวก ข

ตารางที่ 4.17 ค่า AIC ของ Residual ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q)$

$ARIMA(p,d,q)$	AIC
ARIMA(0,1,0)	564.166
ARIMA(1,1,0)	Inf
ARIMA(0,1,1)	inf
ARIMA(0,1,0)	738.098
ARIMA(1,1,1)	inf

เมื่อพิจารณตารางที่ 4.17 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 0, d = 1, q = 0$ และตัวแบบที่เหมาะสมของ Residual คือตัวแบบ $ARIMA(0,1,0)$ รายละเอียดแสดงได้ดังรูปที่ ข.7 ของภาคผนวก ข

โดยสามารถสรุปค่า AIC ที่น้อยที่สุดของแต่ละ IMF ในตัวแบบ EMD-ARIMA ได้ดังตารางที่ 4.18

ตารางที่ 4.18 สรุป AIC ที่น้อยที่สุดของแต่ละ IMF ใน SARIMA

ARIMA(p,d,q)	AIC
ARIMA(5,1,0)	1828.319
ARIMA(2,1,1)	1453.400
ARIMA(4,1,1)	868.773
ARIMA(3,1,1)	238.473
ARIMA(0,1,0)	564.166

ตารางที่ 4.19 ค่า IMF ของตัวแบบ EMD-ARIMA

เดือน	ม.ค.	ก.พ.	มี.ค.	เม.ย.	...	พ.ย.
IMF 1	-14.99	-1.84	-5.22816	-11.73617	...	-1.92516
IMF 2	1.10	-0.22	-5.23533	-4.633827	...	0.149516
IMF 3	-23.78	-22.11	-24.1988	-23.81949	...	-25.6394
IMF 4	-6.03	-4.92	-6.7858	-5.492392	...	-2.55456
Residual	98.02	99.19	97.35637	98.6821	...	102.2859

ยกตัวอย่างเดือนมกราคมในการหาค่าพยากรณ์จากค่า IMF ตามตารางที่ 4.25
จะได้ว่า

$$\begin{aligned} \text{ค่าพยากรณ์} &= \text{IMF1} + \text{IMF2} + \text{IMF3} + \text{IMF4} + \text{Residual} \\ \text{ค่าพยากรณ์มกราคม} &= -14.99 + 1.10 - 23.78 - 6.03 + 98.02 \\ &= 54.32 \end{aligned}$$

ซึ่งคือค่าพยากรณ์ของเดือนมกราคม พ.ศ. 2566 ตามตารางที่ 4.29 ค่าพยากรณ์
ของเดือนอื่นก็ทำเช่นเดียวกัน

2. ตัวแบบ EMD-SARIMA

การพิจารณาตัวแบบพยากรณ์ที่เหมาะสม จะทำการพิจารณาตัวแบบที่มีค่า AIC
น้อยที่สุด ของในแต่ละ IMF1-4 และ Residual ดังตารางที่ 4.20 – 4.24

ตารางที่ 4.20 ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ
 $ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$	AIC
ARIMA(0,1,0) \times SARIMA(0,1,0) ₁₂	1766.922
ARIMA(1,1,0) \times SARIMA(1,1,0) ₁₂	1716.627
ARIMA(2,1,0) \times SARIMA(2,1,0) ₁₂	1674.124
ARIMA(2,1,0) \times SARIMA(1,1,0) ₁₂	1690.675
ARIMA(7,1,2) \times SARIMA(2,1,0) ₁₂	1627.549
ARIMA(6,1,1) \times SARIMA(2,1,0)₁₂	1625.792
...	...
ARIMA(5,1,1) \times SARIMA(2,1,0) ₁₂	1627.867
ARIMA(6,1,2) \times SARIMA(2,1,0) ₁₂	1627.652
ARIMA(5,1,2) \times SARIMA(2,1,0) ₁₂	1627.365
ARIMA(7,1,2) \times SARIMA(2,1,0) ₁₂	1631.118
ARIMA(6,1,1) \times SARIMA(2,1,0) ₁₂	1629.071

เมื่อพิจารณตารางที่ 4.20 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่สุด ได้แก่ $p = 6$, $d = 1$, $q = 1$ และ $P = 2$, $D = 1$, $Q = 0$ และตัวแบบที่เหมาะสมของ IMF 1 คือตัวแบบ $ARIMA(6,1,1) \times SARIMA(2,1,0)_{12}$ รายละเอียดแสดงได้ดังรูปที่ ข.8 ของภาคผนวก ข

ตารางที่ 4.21 ค่า AIC ของ IMF 2 ในแต่ละอันดับของตัวแบบ
 $ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$	AIC
ARIMA(0,1,0) \times SARIMA(0,1,0) ₁₂	1500.260
ARIMA(1,1,0) \times SARIMA(1,1,0) ₁₂	1451.412
ARIMA(2,1,0) \times SARIMA(2,1,0) ₁₂	1336.120
ARIMA(2,1,0) \times SARIMA(1,1,0) ₁₂	1352.438
ARIMA(7,1,2) \times SARIMA(2,1,0) ₁₂	1336.953
ARIMA(2,1,1) \times SARIMA(2,1,0)₁₂	1333.019
...	...
ARIMA(2,1,2) \times SARIMA(2,1,0) ₁₂	1347.631
ARIMA(1,1,1) \times SARIMA(2,1,0) ₁₂	1376.716
ARIMA(3,1,1) \times SARIMA(2,1,0) ₁₂	1334.003
ARIMA(2,1,1) \times SARIMA(2,1,0) ₁₂	1335.023

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อพิจารณาตารางที่ 4.21 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 2, d = 1, q = 1$ และ $P = 2, D = 1, Q = 0$ และตัวแบบที่เหมาะสมของ IMF คือตัวแบบ $ARIMA(2,1,1) \times SARIMA(2,1,0)_{12}$ รายละเอียดแสดงได้ดังรูปที่ ข.9 ของภาคผนวก ข

ตารางที่ 4.22 ค่า AIC ของ IMF 3 ในแต่ละอันดับของตัวแบบ $ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$	AIC
$ARIMA(0,1,0) \times SARIMA(0,1,0)_{12}$	1283.546
$ARIMA(1,1,0) \times SARIMA(1,1,0)_{12}$	1105.617
$ARIMA(1,1,0) \times SARIMA(0,1,0)_{12}$	1105.904
$ARIMA(1,1,0) \times SARIMA(2,1,0)_{12}$	1352.438
$ARIMA(7,1,2) \times SARIMA(2,1,0)_{12}$	1079.610
$ARIMA(2,1,1) \times SARIMA(2,1,0)_{12}$	1333.019
...	...
$ARIMA(1,1,0) \times SARIMA(2,1,2)_{12}$	1074.001
$ARIMA(0,1,0) \times SARIMA(2,1,1)_{12}$	1243.154
$ARIMA(1,1,1) \times SARIMA(2,1,1)_{12}$	inf
$ARIMA(0,1,1) \times SARIMA(2,1,1)_{12}$	Inf

เมื่อพิจารณาตารางที่ 4.22 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 2, d = 1, q = 1$ และ $P = 2, D = 1, Q = 0$ และตัวแบบที่เหมาะสมของ IMF 3 คือตัวแบบ $ARIMA(2,1,1) \times SARIMA(2,1,0)_{12}$ รายละเอียดแสดงได้ดังรูปที่ ข.10 ของภาคผนวก ข

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.23 ค่า AIC ของ IMF 4 ในแต่ละอันดับของตัวแบบ

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$	AIC
$ARIMA(0,1,0) \times SARIMA(0,1,0)_{12}$	1068.120
$ARIMA(1,1,0) \times SARIMA(1,1,0)_{12}$	733.222
$ARIMA(1,1,0) \times SARIMA(0,1,0)_{12}$	785.329
$ARIMA(1,1,0) \times SARIMA(2,1,0)_{12}$	728.409
$ARIMA(4,1,0) \times SARIMA(2,1,0)_{12}$	265.306
$ARIMA(4,1,1) \times SARIMA(2,1,0)_{12}$	258.838
...	...
$ARIMA(3,1,2) \times SARIMA(2,1,0)_{12}$	262.959
$ARIMA(5,1,2) \times SARIMA(2,1,0)_{12}$	265.424
$ARIMA(3,1,3) \times SARIMA(2,1,0)_{12}$	263.265
$ARIMA(5,1,3) \times SARIMA(2,1,0)$	266.086
$ARIMA(4,1,2) \times SARIMA(2,1,0)_{12}$	261.699

เมื่อพิจารณาตารางที่ 4.23 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 2, d = 1, q = 1$ และ $P = 2, D = 1, Q = 0$ และตัวแบบที่เหมาะสมของ IMF 4 คือตัวแบบ $ARIMA(2,1,1) \times SARIMA(2,1,0)_{12}$ รายละเอียดแสดงได้ดังรูปที่ ข.11 ของภาคผนวก ข

ตารางที่ 4.24 ค่า AIC ของ Residual ในแต่ละอันดับของตัวแบบ

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$

$ARIMA(p,d,q) \times SARIMA(P,D,Q)_s$	AIC
$ARIMA(0,1,0) \times SARIMA(0,1,1)_{12}$	inf
$ARIMA(0,1,0) \times SARIMA(0,1,0)_{12}$	451.606
$ARIMA(1,1,0) \times SARIMA(1,1,0)_{12}$	inf
$ARIMA(0,1,1) \times SARIMA(0,1,1)_{12}$	inf
$ARIMA(0,1,1) \times SARIMA(1,1,0)_{12}$	386.523
...	...
$ARIMA(0,1,0) \times SARIMA(1,1,1)_{12}$	inf
$ARIMA(0,1,0) \times SARIMA(2,1,1)_{12}$	inf
$ARIMA(0,1,1) \times SARIMA(1,1,0)_{12}$	inf
$ARIMA(0,1,0) \times SARIMA(1,1,0)_{12}$	387.832

เมื่อพิจารณาตารางที่ 4.25 ค่า AIC ที่น้อยที่สุด พบว่าอันดับที่ดีที่สุด ได้แก่ $p = 0, d = 1, q = 1$ และ $P = 1, D = 1, Q = 0$ และตัวแบบที่เหมาะสมของ Residual คือตัวแบบ $ARIMA(0,1,1) \times SARIMA(1,1,0)_{12}$ รายละเอียดแสดงได้ดังรูปที่ ข.12 ของภาคผนวก ข

สรุปค่า AIC ที่น้อยที่สุดของแต่ละ IMF ในตัวแบบ EMD-SARIMA ได้ดังตารางที่

4.16

ตารางที่ 4.25 ค่า AIC ของตัวแบบที่ใช้ใน EMD-SARIMA

ARIMA(p,d,q)	AIC
ARIMA(6,1,1)(2,1,0) ₁₂	1625.792
ARIMA(2,1,1)(2,1,0) ₁₂	1333.019
ARIMA(2,1,1)(2,1,0) ₁₂	1333.019
ARIMA(4,1,1)(2,1,0) ₁₂	258.838
ARIMA(0,1,1)(1,1,0) ₁₂	386.523

ตารางที่ 4.26 ค่า IMF ของตัวแบบ EMD-SARIMA

เดือน	ม.ค.	ก.พ.	มี.ค.	เม.ย.	...	พ.ย.
IMF 1	-38.61842	0.61181	14.01015	-45.03896	...	1.20772
IMF 2	10.39636	6.58090	5.35708	2.01948	...	5.12755
IMF 3	-20.22227	-25.43747	-42.22537	-14.33741	...	22.53848
IMF 4	-0.60057	-0.48940	-0.37330	-0.26397	...	-0.15544
Residual	93.11786	93.34182	93.35607	93.35983	...	93.04503

ยกตัวอย่างเดือนมกราคมในการหาค่าพยากรณ์จากค่า IMF ตามตารางที่ 4.26 จะได้ว่า

$$\text{ค่าพยากรณ์} = \text{IMF1} + \text{IMF2} + \text{IMF 3} + \text{IMF4} + \text{Residual}$$

$$\begin{aligned} \text{ค่าพยากรณ์มกราคม} &= -38.61842 + 10.39636 - 20.22227 - 0.60057 + 93.11786 \\ &= 44.07296 \end{aligned}$$

ซึ่งคือค่าพยากรณ์ของเดือนมกราคม พ.ศ. 2566 ตามตารางที่ 4.29 ค่าพยากรณ์ของเดือนอื่นก็ทำเหมือนกัน

3. ตัวแบบ EMD-LSTM

การกำหนดค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมด้วยวิธี Manual Search โดยทำการเลือกค่าไฮเปอร์พารามิเตอร์ที่จะศึกษา ได้ดังตารางที่ 4.27

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.27 การกำหนดค่าไฮเปอร์พารามิเตอร์

ข้อกำหนดต่างๆในการสร้างตัวแบบ	ค่าไฮเปอร์พารามิเตอร์
อัลกอริทึม (Algorithm)	LSTM
จำนวน Epoch	500, 1000, 1500, 2000, 2500 และ 3000
จำนวน Batch size	64
จำนวน Dropout	0.7
ฟังก์ชันการสูญเสีย (Loss Function)	Mean Absolute Percentage Error
Optimizer	Amsgrad

จากการศึกษา พบว่าค่าของ Mean Absolute Percentage Error (MAPE) ลดลงตามจำนวน Epoch ที่เพิ่มขึ้นในการสร้างตัวแบบพยากรณ์ พบว่า เมื่อจำนวน Epoch เท่ากับ 3000 จะให้ค่า MAPE เท่ากับร้อยละ 29.93 ซึ่งจะได้ตัวแบบพยากรณ์ที่ดีที่สุด ตามตารางที่ 4.28

ตารางที่ 4.28 การเปรียบเทียบค่า MAPE สำหรับแต่ละ Epoch ของตัวแบบ EMD-LSTM

Epoch	MAPE
500	68.48187
1000	50.50649
1500	45.03731
2000	38.88773
2500	34.49148
3000	29.92987

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 การเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์

4.3.1 ผลลัพธ์ที่ได้จากการเปรียบเทียบค่าพยากรณ์กับค่าจริง

ตารางที่ 4.29 ผลลัพธ์ที่ได้จากการเปรียบเทียบผลพยากรณ์กับค่าจริง

เดือน	Y_t	ตัวแบบเชิงเดี่ยว						ตัวแบบผสม					
		ARIMA		SARIMA		LSTM		EMD-ARIMA		EMD-SARIMA		EMD-LSTM	
		Y'_t	MAPE	Y'_t	MAPE	Y'_t	MAPE	Y'_t	MAPE	Y'_t	MAPE	Y'_t	MAPE
มกราคม	43	47.46	11.012	48.54	13.540	59.66	39.549	54.32	27.074	54.32	27.074	64.41	50.678
กุมภาพันธ์	62	69.07	11.700	62.95	1.805	63.51	2.711	70.11	13.378	70.11	13.378	63.39	2.509
มีนาคม	48	58.11	20.013	74.63	54.151	59.60	23.099	55.91	15.473	55.91	15.473	55.89	15.430
เมษายน	28	50.88	78.627	36.44	27.922	57.73	102.670	53.00	86.075	53.00	86.075	32.30	13.405
พฤษภาคม	41	51.54	26.793	53.53	31.695	60.79	49.547	42.76	5.195	42.76	5.195	64.69	59.131
มิถุนายน	68	95.69	41.374	89.84	32.731	78.22	15.570	83.28	23.042	83.28	23.042	67.86	0.262
กรกฎาคม	46	53.66	15.440	50.16	7.905	58.42	25.672	48.64	4.634	48.64	4.634	50.33	8.281
สิงหาคม	27	51.64	94.609	50.66	90.927	57.93	118.312	44.41	67.381	44.41	67.381	60.06	126.351
กันยายน	79	105.32	32.927	113.96	43.832	102.12	28.887	97.68	23.283	97.68	23.283	101.46	28.048
ตุลาคม	82	119.46	45.890	114.79	40.186	107.41	31.179	121.73	48.662	121.73	48.662	84.07	2.669
พฤศจิกายน	58	60.61	5.135	62.05	7.638	57.70	0.083	72.32	25.440	72.32	25.440	70.60	22.466

ตารางที่ 4.29 แสดงผลลัพธ์ที่ได้จากการเปรียบเทียบผลพยากรณ์กับค่าจริงของตัวแบบเชิงเดี่ยว และตัวแบบผสมได้ดังนี้

1. ตัวแบบเชิงเดี่ยว

เมื่อนำชุดข้อมูลทดสอบมาใช้ตัวแบบ ARIMA ในการพยากรณ์ ได้ว่าเดือนที่มีค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์สูงสุดคือ สิงหาคม เท่ากับร้อยละ 94.609 ส่วนเดือนที่ให้ค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ต่ำที่สุดคือ พฤศจิกายน เท่ากับร้อยละ 5.13

เมื่อนำชุดข้อมูลทดสอบมาใช้ตัวแบบ SARIMA ในการพยากรณ์ ได้ว่าเดือนที่มีค่าความคลาดเคลื่อนสูงที่ได้จากการพยากรณ์สูงสุดคือ สิงหาคม เท่ากับร้อยละ 90.93 ส่วนเดือนที่ให้ค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ต่ำที่สุดคือ พฤศจิกายน เท่ากับร้อยละ 7.64

เมื่อนำชุดข้อมูลทดสอบมาใช้ตัวแบบ LSTM ในการพยากรณ์ ได้ว่าเดือนที่มีค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์สูงสุดคือ สิงหาคม เท่ากับร้อยละ 118.31 ส่วนเดือนที่ให้ค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ต่ำที่สุดคือ พฤศจิกายน เท่ากับร้อยละ 0.08

2. ตัวแบบผสม

เมื่อนำชุดข้อมูลทดสอบมาใช้ตัวแบบผสม ARIMA ได้ว่าเดือนที่มีค่าความคลาดเคลื่อนสูงที่ได้จากการพยากรณ์สูงสุดคือ เมษายน เท่ากับร้อยละ 86.075 ส่วนเดือนที่ให้ค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ต่ำที่สุดคือ กรกฎาคม เท่ากับร้อยละ 4.634

เมื่อนำชุดข้อมูลทดสอบมาใช้ตัวแบบผสม SARIMA ในการพยากรณ์ ได้ว่าเดือนที่มีค่าความคลาดเคลื่อนสูงที่ได้จากการพยากรณ์สูงสุดคือ สิงหาคม เท่ากับร้อยละ 83.26 ส่วนเดือนที่ให้ค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ต่ำที่สุดคือ เมษายน เท่ากับร้อยละ 3.76

เมื่อนำชุดข้อมูลทดสอบมาใช้ตัวแบบ LSTM ในการพยากรณ์ ได้ว่าเดือนที่มีค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์สูงสุดคือ สิงหาคม เท่ากับร้อยละ 126.35 เดือนที่ให้ค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ต่ำที่สุดคือ มิถุนายน เท่ากับร้อยละ 0.262


4.3.2 การเปรียบเทียบความคลาดเคลื่อนของตัวแบบเชิงเดี่ยว

ในตารางที่ 4.30 และรูปที่ 4.8 แสดงผลการเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเดี่ยวระหว่าง ตัวแบบ ARIMA ตัวแบบ SARIMA และ ตัวแบบ LSTM จะเห็นได้ว่าตัวแบบ SARIMA มีประสิทธิภาพในการพยากรณ์ที่ดีที่สุด

ตารางที่ 4.30 การเปรียบเทียบประสิทธิภาพตัวแบบเชิงเดี่ยว

ตัวแบบ	MAPE
ARIMA	34.865
SARIMA	32.03
LSTM	39.753

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.8 กราฟแสดงการเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเดี่ยว


4.3.3 การเปรียบเทียบความคลาดเคลื่อนของตัวแบบผสม

ในตารางที่ 4.31 และรูปที่ 4.9 จะแสดงผลการเปรียบเทียบประสิทธิภาพของตัวแบบผสมระหว่างตัวแบบ EMD-ARIMA, ตัวแบบ EMD-SARIMA และตัวแบบ EMD-LSTM จะเห็นได้ว่าตัวแบบ EMD-SARIMA มีประสิทธิภาพในการพยากรณ์ที่ดีที่สุด

ตารางที่ 4.31 การเปรียบเทียบประสิทธิภาพของตัวแบบผสม

ตัวแบบ	MAPE
EMD-ARIMA	30.876
EMD-SARIMA	28.019
EMD-LSTM	29.93

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.9 กราฟแสดงการเปรียบเทียบประสิทธิภาพของตัวแบบผสม

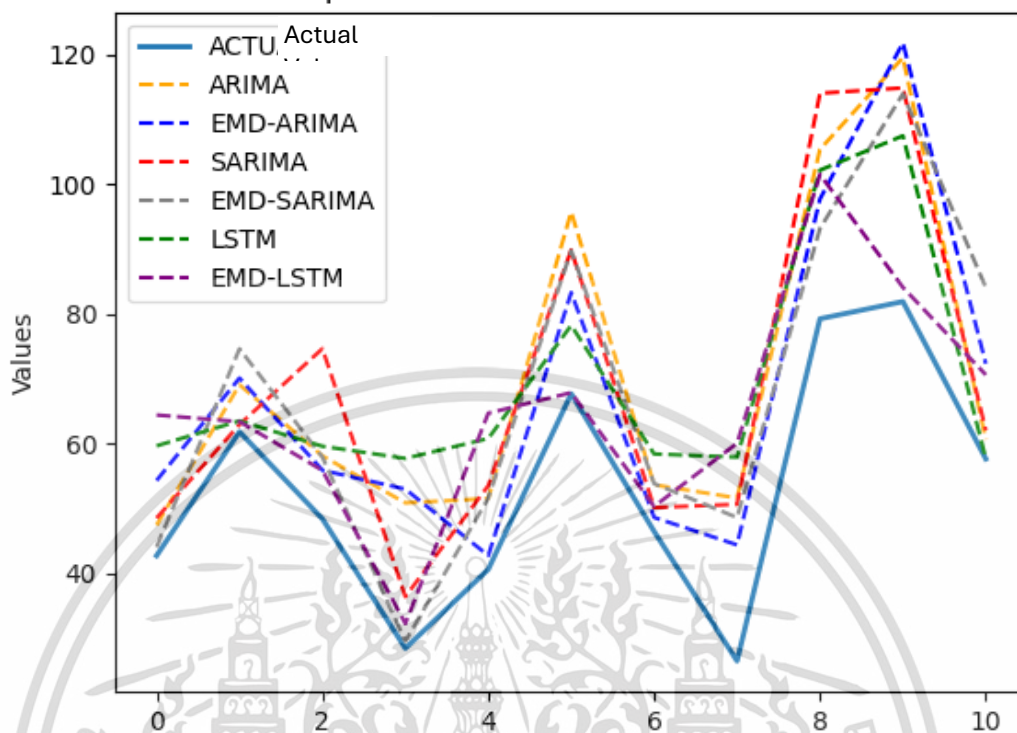
4.3.4 การเปรียบเทียบความคลาดเคลื่อนระหว่างตัวแบบเชิงเดียวกับตัวแบบผสม ในตาราง 4.31 และรูปที่ 4.10 เมื่อเปรียบเทียบระหว่างตัวแบบเชิงเดียวกับตัวแบบผสม พบว่าตัวแบบผสมดีกว่าตัวแบบเชิงเดียว จะเห็นได้ว่าตัวแบบ EMD-SARIMA มีประสิทธิภาพในการพยากรณ์ดีที่สุด

ตารางที่ 4.32 การเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเดียวและตัวแบบผสม

ตัวแบบ		MAPE
ตัวแบบเชิงเดียว	ARIMA	34.865
	SARIMA	32.03
	LSTM	39.753
ตัวแบบผสม	EMD-ARIMA	30.876
	EMD-SARIMA	28.019
	EMD-LSTM	29.93

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Comparison of Actual vs Predicted Values



รูปที่ 4.10 การเปรียบเทียบประสิทธิภาพในการพยากรณ์ค่าพยากรณ์ของทุกตัวแบบพยากรณ์

4.4 การอภิปรายผล

งานวิจัยมีวัตถุประสงค์เพื่อหาตัวแบบพยากรณ์ที่มีประสิทธิภาพดีที่สุดในการทำนายอุปสงค์อะไหล่รถจักรยานยนต์ ซึ่งเปรียบเทียบประสิทธิภาพของทั้งตัวแบบเชิงเดี่ยวและตัวแบบผสมทั้ง 6 แบบ ได้แก่ ARIMA, SARIMA, LSTM, EMD-ARIMA, EMD-SARIMA และ EMD-LSTM ผลการวิจัยพบว่า ตัวแบบผสม SARIMA มีประสิทธิภาพที่ดีกว่าตัวแบบผสม LSTM อาจเนื่องมาจากข้อจำกัดในจำนวนข้อมูลอนุกรมเวลาที่ใช้ในการวิจัย เพราะตัวแบบ LSTM ต้องการข้อมูลจำนวนมากเพื่อให้ได้ผลลัพธ์ที่แม่นยำ การที่มีข้อมูลไม่เพียงพออาจส่งผลให้ตัวแบบ LSTM ไม่สามารถทำงานได้เต็มประสิทธิภาพ ขณะที่ตัวแบบ SARIMA สามารถทำงานได้ดีแม้มีข้อมูลน้อย ด้วยค่า MAPE เท่ากับร้อยละ 28.02 ซึ่งสอดคล้องกับงานวิจัยของ Muftic et al. (2020) ทำการศึกษาาระบบสุริยะมาใช้ในระบบทำความร้อนด้วยไฟฟ้าเพื่อลดมลพิษทางอากาศและพัฒนาคุณภาพชีวิตในแคนตันซาราเยโว ข้อมูลอนุกรมรายเดือนตั้งแต่ 2014 - 2018 โดยตัวแบบที่ให้ประสิทธิภาพดีสุดคือ EMD-SARIMA ซึ่งให้ค่า MAPE เท่ากับร้อยละ 4.52 และจากการศึกษาของงานวิจัยของ Nai et al. (2017) ได้ทำการเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณการขนส่งสินค้าและผู้โดยสารระหว่างประเทศ ในพื้นที่แคนตันซาราเยโว โดยใช้ระยะเวลารายเดือนตั้งแต่ 2006 - 2014 ด้วย 4 ตัวแบบ ซึ่งตัวแบบที่ให้ประสิทธิภาพดีสุดคือ EMD-SARIMA ซึ่งให้ค่า MAPE เท่ากับ ร้อยละ 6.01. ให้ค่าความคลาดเคลื่อนต่ำกว่า MAPE ของตัวแบบ SARIMA คิดเป็นร้อยละ 0.56 โดยผู้วิจัยได้ตั้งข้อสังเกตว่าเมื่อใช้เทคนิคเชิงประจักษ์มาผสมกับตัวแบบเชิงเดี่ยวจะทำให้เพิ่มประสิทธิภาพในการพยากรณ์ที่ดีขึ้น

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

งานวิจัยนี้มีวัตถุประสงค์เพื่อที่จะศึกษาตัวแบบพยากรณ์ที่เหมาะสมสำหรับการทำนายอุปสงค์อะไหล่รถจักรยานยนต์ เพื่อนำค่าพยากรณ์ที่ได้ไปเป็นแนวทางหรือข้อมูลเพิ่มเติมในการตัดสินใจในการวางแผนกลยุทธ์และการบริหารจัดการสินค้าคงคลัง ความต้องการสินค้าอะไหล่รถจักรยานยนต์ของลูกค้า ช่วยให้บริษัทลูกค้าสามารถกำหนดปริมาณการสั่งซื้อและจัดเตรียมสินค้าให้เพียงพอต่อความต้องการของตลาดในแต่ละเดือน โดยวิธีการพยากรณ์ที่ทำการศึกษา 3 วิธีได้แก่ ARIMA, SARIMA และ LSTM รวมถึงเทคนิคเชิงประจักษ์(Empirical Mode Decomposition: EMD) และเปรียบเทียบตัวแบบพยากรณ์แบบเชิงเดียวกับตัวแบบผสม ได้แก่ EMD-ARIMA, EMD-SARIMA และ EMD-LSTM ซึ่งพิจารณาจากค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) โดยตัวแบบพยากรณ์ที่มีความแม่นยำในการพยากรณ์มากที่สุด คือ ตัวแบบพยากรณ์ที่มีค่า MAPE ต่ำที่สุด ซึ่งสามารถสรุปผลการวิจัยได้ดังนี้

5.1 สรุปผลการวิจัย

การศึกษาการทำนายอุปสงค์อะไหล่รถจักรยานยนต์โดยวิธีการผสมผสานระหว่างเทคนิคการประมวลผลสัญญาณและเทคนิคการพยากรณ์อนุกรมเวลา มีวัตถุประสงค์เพื่อสร้างตัวแบบพยากรณ์ที่เหมาะสมสำหรับพยากรณ์สินค้า A ของอะไหล่รถจักรยานยนต์ ระหว่างปี 2557 ถึงปี 2565 เพื่อเปรียบเทียบประสิทธิภาพระหว่างตัวแบบเชิงเดี่ยวและตัวแบบผสมเทคนิคเชิงประจักษ์ ได้ผลสรุปเพื่อตอบวัตถุประสงค์ดังนี้

5.1.1 วัตถุประสงค์ข้อที่ 1

จากการศึกษาต้นแบบพยากรณ์ที่เหมาะสมกับอุปสงค์อะไหล่รถจักรยานยนต์ A ของโดยวิธีการพยากรณ์อนุกรมเวลาและการเรียนรู้เชิงลึก โดยตัวแบบพยากรณ์ที่เหมาะสมของ ARIMA คือ $ARIMA(2,1,0)$ และตัวแบบพยากรณ์ที่เหมาะสมของ SARIMA คือ $ARIMA(4,1,1) \times SARIMA(1,1,1)_{12}$ และวิธีการเรียนรู้เชิงลึกได้แก่ LSTM ซึ่งไฮเปอร์พารามิเตอร์ที่ทำให้ได้ตัวแบบพยากรณ์เหมาะสมคือ Epoch เท่ากับ 3000, Epoch เท่ากับ 3000, Dropout เท่ากับ 0.7, Batch size เท่ากับ 64, Optimizer เป็น amsgrad

5.1.2 วัตถุประสงค์ข้อที่ 2

การเปรียบเทียบประสิทธิภาพการพยากรณ์ของตัวแบบเชิงเดี่ยว คือ ตัวแบบ ARIMA, ตัวแบบ SARIMA และตัวแบบ LSTM จะเห็นได้ว่าตัวแบบ SARIMA มีประสิทธิภาพในการพยากรณ์ที่ดีที่สุด ให้ค่า MAPE เท่ากับร้อยละ 32.03

การเปรียบเทียบประสิทธิภาพการพยากรณ์ของตัวแบบผสม คือ ตัวแบบ EMD-ARIMA, ตัวแบบ EMD-SARIMA และตัวแบบ EMD-LSTM จะเห็นได้ว่าตัวแบบ EMD-SARIMA มีประสิทธิภาพในการพยากรณ์ที่ดีที่สุด ให้ค่า MAPE เท่ากับร้อยละ 28.019

เมื่อทำการเปรียบเทียบประสิทธิภาพของตัวแบบทั้ง 6 ตัวแบบ พบว่า ตัวแบบ EMD-SARIMA ให้ค่า MAPE ต่ำที่สุด เนื่องจากข้อมูลยอดขายสินค้านั้นอาจจะมีรูปแบบที่ซับซ้อน

เช่น มีทั้งฤดูกาล การเปลี่ยนแปลงระยะยาว และความผันผวนของข้อมูลรายเดือน เทคนิคเชิงประจักษ์ (EMD) จะมาแก้ไขปัญหาก็กล่าวมาข้างต้น โดยการแยกสัญญาณของข้อมูล ซึ่งแต่ละสัญญาณจะมีรูปแบบที่แตกต่าง เมื่อนำมาพยากรณ์จึงทำให้ค่าพยากรณ์ที่ได้มีความแม่นยำมากกว่าตัวแบบเชิงเดี่ยว

5.2 ข้อจำกัดและข้อเสนอแนะ

5.2.1 ข้อจำกัด

เนื่องจากข้อมูลอนุกรมที่ได้นำมาพยากรณ์นั้นเป็นข้อมูลที่เกิดในช่วงสถานการณ์โควิด-19 ซึ่งทำให้ยอดขายตกต่ำอย่างผิดปกติในช่วงเวลา ข้อมูลยอดขายที่นำมาใช้ในการพยากรณ์อาจมีแนวโน้มที่ผิดเพี้ยนหรือไม่สอดคล้องกับรูปแบบการขายที่เป็นปกติ ส่งผลให้การพยากรณ์ที่ได้ อาจมีความแม่นยำลดลง เนื่องจากตัวแบบพยากรณ์อาจไม่สามารถจับลักษณะของความผันผวนที่เกิดขึ้นจากเหตุการณ์ที่ไม่คาดคิดได้อย่างมีประสิทธิภาพ

5.2.2 ข้อเสนอแนะ

เทคนิคเชิงประจักษ์สามารถนำไปประยุกต์ใช้ร่วมกับวิธีการอื่น ๆ ได้ เช่น Backpropagation Neural Network (BPNN) และ Exponentially Weighted Moving Average (EWMA) นอกจากนี้ ตัวแบบผสมไม่ได้จำกัดแค่การรวมวิธีสองวิธีเท่านั้น แต่ยังสามารถผสมผสานวิธีต่าง ๆ ได้ถึงสามวิธีหรือมากกว่า เช่น ตัวแบบ affEMD-Theta เป็นต้น

นอกจากการใช้ EMD เข้ามาช่วยแยกส่วนประกอบของอนุกรมเวลาในการพยากรณ์ ยังมีวิธีอื่น ๆ ที่สามารถแยกส่วนประกอบของอนุกรมเวลาได้ เช่น Ensemble Empirical Mode Decomposition (EEMD) และ Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) และยังมีวิธีการแปลงอนุกรมเวลารูปแบบอื่นที่สามารถใช้ร่วมกับวิธีบ็อกซ์และเจนกินส์ เช่น Wavelet Transform และ Fourier Transform ซึ่งอาจจะทำให้การพยากรณ์ยอดขายสินค้าอะไหล่รถจักรยานยนต์ให้มีประสิทธิภาพที่ดีขึ้น และยังสามารถนำตัวแบบนี้ไปเป็นต้นแบบในการพยากรณ์ยอดขายสินค้าประเภทอื่น ๆ ได้อีกด้วย

เอกสารอ้างอิง

- กานต์กมล ทวีผล. 2562. แบบจำลองโครงข่ายประสาทเทียมแบบลึกสำหรับการทำนายปริมาณความหนาแน่นของฝุ่นละออง PM2.5 บริเวณพื้นที่จังหวัดกรุงเทพมหานครชั้นใน. วิทยาศาสตร์มหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ. มหาวิทยาลัยศรีนครินทรวิโรฒ.
- เฉลิมพล จตุพร. 2562. การพยากรณ์ทางอนุกรมเวลา.[Online]. เข้าถึงได้จาก <https://cj007blog.files.wordpress.com>.
- ทรงศิริ แต่สมบัติ. 2549. การพยากรณ์เชิงปริมาณ. พิมพ์ครั้งที่ 1. กรุงเทพฯ :สำนักพิมพ์มหาวิทยาลัยเกษตรศาสตร์
- ชัยชัย ตระกูลเลิศยศ. 2559 .ความแตกต่างของ Analog และ Digital. [Online]. เข้าถึงได้จาก <https://www.scimath.org>.
- ธนกร สุทธิสนธิ์. 2566 .ตัวแบบผสมสำหรับการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย. วารสารวิทยาศาสตร์บูรพา. 1: 155-174.
- สุทธิสนธิ์ และสุรัตน์ หารวย. 2563.การพัฒนาตัวแบบผสมเพื่อพยากรณ์ข้อมูลอนุกรมเวลาปริมาณหน่วยจำหน่ายไฟฟ้าบ้านอยู่อาศัยรายเดือนของประชาชนในเขตภาคตะวันออกเฉียงเหนือของประเทศไทย. 4: 630-644.
- นรุตม์ สุนทรานนท์. 2667 . Feature Engineering อาวุธลับของ Data Scientist. [Online]. เข้าถึงได้จาก <https://www.nerd-data.com>
- พลสรณ์ งามศิริจิตร. 2560. การวิเคราะห์ภาพถ่ายการบีบตัวของกระเพาะอาหารส่วนปลายด้วยวิธีแยกสัญญาณแบบเอมพีรีเคิลโมด. วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมศาสตร์. จุฬาลงกรณ์มหาวิทยาลัย
- พีระพล ยุวภูษตานนท์. 2552. การประมวลผลสัญญาณดิจิทัลขั้นสูงพื้นฐานของทฤษฎีการประมาณค่า.ภาควิชาวิศวกรรมอิเล็กทรอนิกส์. มหาวิทยาลัยเทคโนโลยีมหานคร
- สุภัทรชัย ชมพันธ์ุ. 2547.Digital Signal Processing. กรุงเทพฯ . สำนักพิมพ์มหาวิทยาลัยเกษตรศาสตร์
- อรพิน ประวัตติบริสุทธิ. 2564. Python สำหรับงาน Data Science Data Visualization และ Machine Learning. พิมพ์ครั้งที่ 1. กรุงเทพฯ : โปรวิชัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง(ต่อ)

- Aghmadi, A. and Mohammed, O. 2023. **Enhancing Solar Radiation Forecasting with Hybrid Ensemble Empirical Mode Decomposition and Machine Learning Techniques.** Department of Electrical and Computer Engineering. 23: 1150-1156.
- Athipayoon, Thongteeraparp, A. and Chaipitak, S. 2018. **Comparison of Forecasting Methods for Non-Linear and Non-Stationary Time Series.** Department of Statistics. 28: 197-207.
- Abadan, S. and Shabri, A. 2014. **Hybrid empirical mode decomposition-ARIMA for forecasting price of rice.** Journal of Appl. Math. Sci.8: 3133-3143
- Bao, D. and Chen, J. 2012. **Orecasting software reliability using Arima with ensemble empirical mode decomposition.** Int. J.Model.Simul. 32: 104-110.
- Brian, H and Ang, H. 2001. **A simple neural network for ARIMA (p,q) time series.** Omega, 29: 319-333
- Chakravarti, Laha. and Roy. 1967. **Handbook of Methods of Applied Statistics.** Volume: 392-394
- Chambers, J, William, C. and Paul, T. 1983.**Graphical Methods for Data Analysis.** Wadsworth.
- Crowley, P., Policyand, M. and Department, R. 2009. "How do you make a time series sing like a choir? Using the Hilbert-Huang transform to extract embedded frequencies from economic or financial time series," Using the Hilbert-Huang Transform to Extract Embedded Frequencies from Economic or Financial Time Series. Finland. Helsinki.
- Feng, X. and Zhong, J. 2022. **Groundwater Radon Precursor Anomalies Identification by EMD-LSTM Model.** Water. 14: 69.
- Hossain, M. Ismail, M. and Hossain, J. 2021. **Stock Price Prediction Using Empirical Mode Decomposition Based Theta Method and Forecast Combination.** International Conference on Decision Aid Sciences and Application. 21: 1115-1119.
- Hao, W. and Sun, X. 2022. **A hybrid EMD-LSTM model for non-stationary wave prediction in offshore China.** Ocean Engineering. 9.110566.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง(ต่อ)

- Lin, S. and Huang, H. 2020. **Improving Deep Learning for Forecasting Accuracy in Financial Data**. Discrete Dynamics in Nature and Society Volume. 5803407.
- Liu, Z. Zhang, J. and Feng, F. 2022. **Research on the prediction method of lithium-ion battery remaining life based on EMD-Arima**. Industrial Automation and Electronics. 22: 357-360.
- LI, B. BAI, X. and Jun, L. 2022. **Deformation Prediction of Gravity Dam Based on EMD-SARIMA Model**. Advances in transdisciplinary engineering. 10: 344-352.
- Lee, T. 2020. **EMD and LSTM Hybrid Deep Learning Model for Predicting Sunspot Number Time Series with a Cyclic Pattern**. Solar Phys. 295:82.
- Min, Y. Bin, Y. Liang-li, Z. and Xi, C. 2015. **Wind Speed Forecasting Based on EEMD and ARIMA**. Chinese Automation Congress. Wuhan.
- Miao, Y. Bai, X. Cao, Y. Liu, Y. and Dai, F. 2023. **A Novel Short-Term Traffic Prediction Model Based on SVD and ARIMA With Blockchain in Industrial Internet of Things**. INTERNET OF THINGS JOURNAL. 10: 21217-21226.
- Mohamad. 2019. **MDA - Mean Directional Accuracy**. [Online]. เข้าถึงได้จาก <https://support.numxl.com>.
- McKinney, W. 2012. **Python for Data Analysis**. O'Reilly Media
- Muja, M. Avdakovic, S. and Mujezinovic, A. **The Hybrid EMD-SARIMA Model for Air Quality Index Prediction, Case of Canton Sarajevo**. Energies.
- Nai, W. Liu, L. Wang, S. and Dong, D. 2017. **An EMD-SARIMA-based modeling approach for air traffic forecasting**. Algorithms, 10:1-16.
- Nandan; R.and Tripathi, S. **Analysis of Autoregressive Models Used to Predict Climate Change over the Indian Subcontinent**. International Conference on Automation, Control and Electronics Engineering. 23: 67-71.
- Niu, H. and Wang, J. 2014. **Financial time series prediction by a random data time effective RBF neural network**. Journal of Soft Comput. 18: 497-508.
- Olah, C. 2015. **Understanding LSTM Networks – colah's blog**. Retrieved [Online]. เข้าถึงได้จาก <http://colah.github.io>.
- Park,H. 2008. **Univariate Analysis and Normality Test Using SAS, Stata, and SPSS**.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง(ต่อ)

- Sanvendra Singh. 2019 . **IMPORTANCE OF FEATURE ENGINEERING - PART-1**. [Online].
เข้าถึงได้จาก<https://medium.com>.
- Yang, Y. and Chang, K. 2009. **Extraction of Bridge Frequencies from the Dynamic Response of a Passing Vehicle Enhanced By The EMD Technique**. Journal of Sound and Vibration, 322, 718–739.
- Zhou, Y. and Huang, M. 2016. **Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model**. Microelect. Reliab. 65: 265-273
- Zhou, S. Bethel, B. Sun, W. Zhao, Y. Xie, W. and Dong, C. 2022. **Improving Significant Wave Height Forecasts Using a Joint Empirical Mode Decomposition–Long Short-Term Memory Network**. Journal of Marine Science and Engineering. 9:744.
- Zhang, J. Feng, Y. Zhang, Z. and Li, Y. 2023. **The Short Time Prediction of the Dst Index Based on the LSTM and the EMD-LSTM Models**. Preprints.10.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก

ภาคผนวก ก.1 ชุดคำสั่งที่ใช้ในการหาตัวแบบ ARIMA ที่เหมาะสม

```

sheet_name = 'สินค้าอะไหล่รถจักรยานยนต์ A'
df = pd.read_excel(r"product.xlsx", sheet_name=sheet_name, parse_dates=['Time'],
index_col='Time')
TEST_SIZE = 11
train, test = df.iloc[:-TEST_SIZE], df.iloc[-TEST_SIZE:]
x_train, x_test = np.array(range(train.shape[0])), np.array(range(train.shape[0],
df.shape[0]))
# Plot train and test sets
fig, ax = plt.subplots(1, 1, figsize=(15, 5))
ax.plot(x_train, train)
ax.plot(x_test, test)
plt.show(block=False)
plt.pause(1)
plt.close()
# Forecast using auto_arima
model = auto_arima(train['Value'].values,
start_p=0,
start_q=0,
test='adf',
max_p=10,
max_q=10,
m=1,
d=1,
seasonal=False,
start_P=0,
D=None,
trace=True,
error_action='ignore',
suppress_warnings=True,
stepwise=True)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.2 ชุดคำสั่งที่ใช้ในการทดสอบตัวแบบ ARIMA

```

# load dataset
series = pd.read_excel('product.xlsx', sheet_name='สินค้าอะไหล่รถจักรยานยนต์ A',
usecols=['Value'])
selected_series = series.iloc[:108]
print(selected_series)
# fit model
model = ARIMA(selected_series, order=(2,1,0))
model_fit = model.fit()
# summary of fit model
print(model_fit.summary())
# line plot of residuals
residuals = DataFrame(model_fit.resid)
residuals.plot()
pyplot.show()
# density plot of residuals
residuals.plot(kind='kde')
pyplot.show()
# summary stats of residuals
print(residuals.describe())

```

ภาคผนวก ก.3 ชุดคำสั่งที่ใช้ในการพยากรณ์ด้วยตัวแบบ ARIMA

```

df = pd.read_excel('product.xlsx', sheet_name='สินค้าอะไหล่รถจักรยานยนต์ A',
usecols=['Value'])
predictions = []
cal_mape = []
actual_data = []
for round_number in range(11):
    # Split data into train and test sets
    if round_number == 0:
        TEST_SIZE = 11
    else:
        TEST_SIZE = 11 - round_number
    train, test = df.iloc[:-TEST_SIZE], df.iloc[-TEST_SIZE:]

```

เอกสารนี้เป็นเอกสารลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่สามารถเผยแพร่ ฟังสั่น ยกย่องให้มีเห็นแก่ผลประโยชน์และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

d = 1 # ค่า d ในโมเดล ARIMA
q = 0 # ค่า q ในโมเดล ARIMA
# สร้างโมเดล ARIMA
model = ARIMA(train['Value'].values, order=(p, d, q))
model_fit = model.fit()
# ทำนายค่าต่อไปโดยใช้โมเดล ARIMA
prediction = model_fit.forecast(steps=TEST_SIZE)
print(prediction)
# reshape
original_values = test.values.reshape(-1)
# Calculate Mean Absolute Percentage Error (MAPE)
def mape(original_values, prediction):
    return mean(np.abs((original_values - prediction) / original_values)) * 100
mape_cal = mape(original_values[0], prediction[0])
print(f'MAPE: {mape_cal:.2f}%')
actual_data.append(original_values[0])
predictions.append(prediction[0])
cal_mape.append(mape_cal)
result_df = pd.DataFrame({'Actual ': actual_data, ' Forecast': predictions, 'MAPE':
cal_mape})
# บันทึก DataFrame ลงในไฟล์ Excel
result_df.to_excel('result.xlsx', index=False)

```

ภาคผนวก ก.4 ชุดคำสั่งที่ใช้ในการพยากรณ์ด้วยตัวแบบ EMD-ARIMA

```

#parameter เก็บข้อมูล
all_predictions = []
all_mape = []
actual_data = []
all_smape = []
#loop ให้เก็บค่า forecast และค่า Error
for round_number in range(11):
    # Load data for forecasting
    sheet_name = 'สินค้าอะไหล่รถจักรยานยนต์ A'
    df = pd.read_excel(r"product.xlsx", sheet_name=sheet_name, parse_dates=['Time'],
index_col='Time')
    # Plot data
    df.plot(figsize=(15, 5))

```

เอกสารนี้เป็นเอกสารที่เผยแพร่ไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ หากมีข้อผิดพลาดประการใดขออภัยเป็นอย่างสูงและต้องอภัยถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

plt.show(block=False)
plt.pause(1)
plt.close()
# Split data into train and test sets
if round_number == 0:
    TEST_SIZE = 11
else:
    TEST_SIZE = 11 - round_number
train, test = df.iloc[:-TEST_SIZE], df.iloc[-TEST_SIZE:]
x_train, x_test = np.array(range(train.shape[0])), np.array(range(train.shape[0],
df.shape[0]))
print(test)
print(train)
# Plot train and test sets
fig, ax = plt.subplots(1, 1, figsize=(15, 5))
ax.plot(x_train, train)
ax.plot(x_test, test)
plt.show(block=False)
plt.pause(1)
plt.close()
# Empirical Mode Decomposition
emd = EMD()
IMFs = emd(train['Value'].values)
print(IMFs)
# Plot the IMFs
fig, ax = plt.subplots(len(IMFs)+1, 1, figsize=(16, 8*(len(IMFs)+1)))
ax[0].plot(train['Value'])
ax[0].set_title('Original Signal')
for i in range(len(IMFs)):
    ax[i+1].plot(IMFs[i])
    ax[i+1].set_title(f'IMF {i+1}')
plt.close()
# Forecast each IMF using auto_arima

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่สามารถใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

model = auto_arma(IMFs[i],
                  start_p=0,
                  start_q=0,
                  test='adf',
                  max_p=5, # Reduce the max_p to avoid overfitting
                  max_q=5, # Reduce the max_q to avoid overfitting
                  m=1,
                  d=1,

# Since it's the first-order difference in EMD
                  seasonal=False,
                  start_P=0,
                  D=None,
                  trace=True,
                  error_action='ignore',
                  suppress_warnings=True,
                  stepwise=True)

prediction, __ = model.predict(n_periods=TEST_SIZE, return_conf_int=True)
predictions.append(prediction)

# Combine the forecasted IMFs to get the final forecast
final_prediction = np.sum(predictions, axis=0)
print("Forecast for t+1:", final_prediction[0])
print(final_prediction)

#reshampe
original_values = test.values.reshape(-1)
print(original_values[0])

# Calculate Mean Absolute Percentage Error (MAPE)
def mape(original_values, final_prediction):
    return mean(np.abs((original_values - final_prediction) / original_values)) * 100
mape_cal = mape(original_values[0], final_prediction[0])

# เพิ่มข้อมูลใน data frame
all_predictions.append(final_prediction[0])
actual_data.append(original_values[0])
all_mape.append(mape_cal)

```

เอกสารนี้เป็นเอกสารที่จัดทำขึ้นเพื่อใช้ในการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่สามารถเผยแพร่หรือใช้ซ้ำโดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# Plot the forecast and original series
fig, ax = plt.subplots(1, 1, figsize=(15, 5))
ax.plot(df['Value'])
ax.plot(df.index[-TEST_SIZE:], final_prediction)
plt.show(block=False)
plt.pause(1)
plt.close()

# Calculate Mean Directional Accuracy (MDA)
def mda(actual_data, all_predictions):
    actual = np.array(actual_data)
    predicted = np.array(all_predictions)
    # calculate the signs of the differences between consecutive values
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    # count the number of times the signs are the same
    num_correct = np.sum(actual_signs == predicted_signs)
    # calculate the MDA value
    mda = num_correct / (len(actual) - 1)
    return mda

# เพิ่มข้อมูลใน data frame
result_mda = mda(actual_data, all_predictions)
print("Mean Directional Accuracy (MDA):", result_mda)

# Save the forecast_df DataFrame to 'result.xlsx'
result_df = pd.DataFrame({'Actual': actual_data, 'Forecast': all_predictions, 'MAPE':
all_mape, 'MDA':result_mda})

# บันทึก DataFrame ลงในไฟล์ Excel
result_df.to_excel('result.xlsx', index=False)

# พล็อตกราฟ Error data ที่เก็บมาได้
df_error = pd.read_excel('result.xlsx')
plt.plot(df_error['MAPE'], marker='o', linestyle='-', color='b')
plt.title('Error over Time')
plt.ylabel("percent of Error")
plt.show()

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ทำกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.5 ชุดคำสั่งที่ใช้ในการหาตัวแบบ SARIMA ที่เหมาะสม

```

sheet_name = 'สินค้าอะไหล่รถจักรยานยนต์ A'
df = pd.read_excel(r"product.xlsx", sheet_name=sheet_name, parse_dates=['Time'],
index_col='Time')
TEST_SIZE = 11
train, test = df.iloc[:-TEST_SIZE], df.iloc[-TEST_SIZE:]
x_train, x_test = np.array(range(train.shape[0])), np.array(range(train.shape[0],
df.shape[0]))

# Plot train and test sets
fig, ax = plt.subplots(1, 1, figsize=(15, 5))
ax.plot(x_train, train)
ax.plot(x_test, test)
plt.show(block=False)
plt.pause(1)
plt.close()

# Forecast using auto_arima
model = auto_arima(train['Value'].values,
start_p=0,
start_q=0,
test='adf',
max_p=7,
max_q=7,
m=12,
d=1,
seasonal=True,
start_P=0,
D=1,
trace=True,
error_action='ignore',
suppress_warnings=True,
stepwise=True)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.6 ชุดคำสั่งที่ใช้ในการทดสอบตัวแบบ SARIMA

```

# load dataset
series = pd.read_excel('product.xlsx', sheet_name='สินค้าอะไหล่รถจักรยานยนต์ A',
usecols=['Value'])
selected_series = series.iloc[:108]
print(selected_series)
# สร้างโมเดล SARIMA
model = SARIMAX(selected_series, order=(0, 1, 1), seasonal_order=(2, 1, 0, 12))
# ฟิตโมเดล SARIMA กับข้อมูล
model_fit = model.fit()
# แสดงรายละเอียดของโมเดลที่ฟิตแล้ว
print(model_fit.summary())

```

ภาคผนวก ก.7 ชุดคำสั่งที่ใช้ในการพยากรณ์ด้วยตัวแบบ SARIMA

```

df = pd.read_excel('product.xlsx', sheet_name='สินค้าอะไหล่รถจักรยานยนต์ A',
usecols=['Value'])
predictions = []
cal_mape = []
actual_data = []
for round_number in range(11):
    # Split data into train and test sets
    if round_number == 0:
        TEST_SIZE = 11
    else:
        TEST_SIZE = 11 - round_number
    train, test = df.iloc[:-TEST_SIZE], df.iloc[-TEST_SIZE:]
    # สร้างโมเดล SARIMA
    model = SARIMAX(train['Value'].values, order=(0, 1, 1), seasonal_order=(2, 1, 0, 12))
    # ฟิตโมเดล SARIMA กับข้อมูล
    model_fit = model.fit()
    # ทำนายค่าต่อไปโดยใช้โมเดล SARIMA
    prediction = model_fit.forecast(steps=TEST_SIZE)
    # แสดงผลการทำนาย
    print(prediction)
    # reshape
    original_values = test.values.reshape(-1)
    # Calculate Mean Absolute Percentage Error (MAPE)

```

เอกสารนี้เป็นทรัพย์สินทางปัญญาของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ไม่อนุญาตให้拿去ใช้ประโยชน์ด้านการค้า
 ไม่มีการตีพิมพ์สิ่งใดที่มิได้เห็นแต่ก่อน และสงวนลิขสิทธิ์ของเอกสารทุกครั้งที่มีการนำไปใช้

```

def mape(original_values, prediction):
    return mean(np.abs((original_values - prediction) / original_values)) * 100
mape_cal = mape(original_values[0], prediction[0])
print(f'MAPE: {mape_cal:.2f}%')
actual_data.append(original_values[0])
predictions.append(prediction[0])
cal_mape.append(mape_cal)
result_df = pd.DataFrame({'Actual ': actual_data, ' Forecast': predictions, 'MAPE':
cal_mape})
result_df.to_excel('result_sarima.xlsx', index=False)

```

ภาคผนวก ก.8 ชุดคำสั่งที่ใช้ในการพยากรณ์ด้วยตัวแบบ EMD-SARIMA

```

# parameters for storing data
all_predictions = []
all_mape = []
actual_data = []
# loop to store forecast and error values
for round_number in range(11):
    print(round_number)
    # Load data for forecasting
    sheet_name = 'สินค้าอะไหล่รถจักรยานยนต์ A'
    df = pd.read_excel(r"product.xlsx", sheet_name=sheet_name, parse_dates=['Time'],
index_col='Time')
    # Plot data
    df.plot(figsize=(15, 5))
    plt.show(block=False)
    plt.pause(1)
    plt.close()
    # Split data into train and test sets
    if round_number == 0:
        TEST_SIZE = 11
    else:
        TEST_SIZE = 11 - round_number
    train, test = df.iloc[:-TEST_SIZE], df.iloc[-TEST_SIZE:]
    x_train, x_test = np.array(range(train.shape[0])), np.array(range(train.shape[0],
df.shape[0]))

```

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ทำกรณีใดๆ ทั้งสิ้น ยกเว้นที่มิมีเหตุแต่สงสัยและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

ax.plot(x_train, train)
ax.plot(x_test, test)
plt.show(block=False)
plt.pause(1)
plt.close()
# Empirical Mode Decomposition
emd = EMD()
IMFs = emd(train['Value'].values)
# Plot the IMFs
fig, ax = plt.subplots(len(IMFs)+1, 1, figsize=(15, 5*(len(IMFs)+1)))
ax[0].plot(train['Value'])
ax[0].set_title('Original Signal')
plt.show(block=False)
plt.pause(1)
plt.close()
for i in range(len(IMFs)):
    ax[i+1].plot(IMFs[i])
    ax[i+1].set_title(f'IMF {i+1}')
# Forecast each IMF using auto_arima
predictions = []
for i in range(len(IMFs)):
    model = auto_arima(IMFs[i],
                        start_p=0,
                        start_q=0,
                        test='adf',
                        max_p=7,
                        max_q=7,
                        m=12,
                        start_P=0,
                        seasonal=True,
                        d=1,
                        D=1,
                        trace=True,
                        error_action='ignore',
                        suppress_warnings=True,
                        stepwise=True)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ทำกรณีใดๆ ทั้งสิ้น ยกเว้นกรณีที่มีเหตุจำเป็นและต้องอย่างองเคใจของเอกสารทุกประการไม่ให้นำไปใช้

```

predictions.append(prediction)

# Combine the forecasted IMFs to get the final forecast
final_prediction = np.sum(predictions, axis=0)
#reshape
original_values = test.values.reshape(-1)
# Calculate Mean Absolute Percentage Error (MAPE)
def mape(original_values, final_prediction):
    return mean(np.abs((original_values - final_prediction) / original_values)) * 100
mape_cal = mape(original_values[0], final_prediction[0])
# Append data to the data frame
all_predictions.append(final_prediction[0])
actual_data.append(original_values[0])
all_mape.append(mape_cal)
# Plot the forecast and original series
fig, ax = plt.subplots(1, 1, figsize=(15, 5))
ax.plot(df['Value'])
ax.plot(df.index[-TEST_SIZE:], final_prediction)
plt.show(block=False)
plt.pause(1)
plt.close()
# Calculate Mean Directional Accuracy (MDA)
def mda(actual_data, all_predictions):
    actual = np.array(actual_data)
    predicted = np.array(all_predictions)
    # calculate the signs of the differences between consecutive values
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    # count the number of times the signs are the same
    num_correct = np.sum(actual_signs == predicted_signs)
    # calculate the MDA value
    mda = num_correct / (len(actual) - 1)
    return mda
# Append data to the data frame
result_mda = mda(actual_data, all_predictions)
# Save the DataFrame to 'result_sarima.xlsx'

```

เอกสารนี้เป็นลิขสิทธิ์ของสถาบันวิจัยจุฬาลงกรณ์มหาวิทยาลัย ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่สามารถเผยแพร่ ฟังสั่น อีกทั้งห้ามมีเหตุที่บ่งชี้ถึงและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

result_df = pd.DataFrame({'Actual ': actual_data, ' Forecast': all_predictions, 'MAPE':
all_mape,'MDA':result_mda})
result_df.to_excel('result_sarima.xlsx', index=False)
# Plot the graph of errors over time
df_error = pd.read_excel('result_sarima.xlsx')
plt.plot(df_error['MAPE'], marker='o', linestyle='-', color='b')
plt.title('Error over Time')
plt.ylabel("percent of Error")
plt.show()

```

ภาคผนวก ก.9 ชุดคำสั่งที่ใช้ในการพยากรณ์ด้วยตัวแบบ LSTM

```

# parameters for storing data
all_predictions = []
all_mape = []
actual_data = []
# loop to store forecast and error values
for round_number in range(11):
    print(f"Running round {round_number + 1}...")
    # Load data for forecasting
    df = pd.read_excel('product.xlsx', sheet_name='สินค้าอะไหล่รถจักรยานยนต์ A',
    usecols=['Value'])
    data = np.array(df)
    y = data
    train_data = data.reshape(-1, 1)
    scaler = MinMaxScaler()
    train_data_scaled = scaler.fit_transform(train_data)

# Prepare data for LSTM
def create_dataset(data, look_back=1):
    X, Y = [], []
    for i in range(len(data) - look_back):
        # Add 'look_back' time steps as input features
        X.append(data[i:(i + look_back), 0])
        # Add the next time step as the output target
        Y.append(data[i + look_back, 0])
    return np.array(X), np.array(Y)

# Split data into train and test sets

```

เอกสารนี้เป็นเอกสารที่จัดทำขึ้นเพื่อใช้ในการเรียนการสอนเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่สามารถ
 ต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

if round_number == 0:
    SIZE = 11
else:
    SIZE = 11 - round_number
# Example look-back window size
look_back = 12
X, Y = create_dataset(train_data_scaled, look_back)
X_train, Y_train = X[:-SIZE] , Y[:-SIZE]
X_test, Y_test = X[-SIZE:] , Y[-SIZE:]
# Reshape input to be [samples, time steps, features]
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))
# Build LSTM model
model = Sequential()
model.add(LSTM(10, input_shape=(None, 1), recurrent_dropout = 0.7,
return_sequences=True))
model.add(LSTM(10, recurrent_dropout = 0.7, return_sequences=True))
model.add(LSTM(10, recurrent_dropout = 0.7))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer=Adam(amsgrad=True))
model.fit(X_train, Y_train, epochs=1000, batch_size=64, verbose=1)
# Make predictions using LSTM
lstm_predictions_scaled = model.predict(X_test)
lstm_predictions = scaler.inverse_transform(lstm_predictions_scaled)
lstm_predictions = lstm_predictions.reshape(-1)
#reshape
original_values = data[-SIZE:]
original_values = original_values.reshape(-1)
# Calculate Mean Absolute Percentage Error (MAPE)
def mape(original_values, lstm_predictions):
    return mean(np.abs((original_values - lstm_predictions) / original_values)) * 100
mape_cal = mape(original_values[0], lstm_predictions[0])
# Plot the results
plt.figure(figsize=(16, 8))
plt.plot(data[-SIZE:], label='True Values')
plt.plot(lstm_predictions, label='LSTM Predictions')
plt.title('Time Series Forecasting')
plt.xlabel('Time')
plt.ylabel('Value')

```

```

plt.legend()
plt.show(block=False)
plt.pause(1)
plt.close()

# Append data to the data frame
all_predictions.append(lstm_predictions[0])
actual_data.append(original_values[0])
all_mape.append(mape_cal)

# Calculate Mean Directional Accuracy (MDA)
def mda(actual_data, all_predictions):
    actual = np.array(actual_data)
    predicted = np.array(all_predictions)
    # calculate the signs of the differences between consecutive values
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    # count the number of times the signs are the same
    num_correct = np.sum(actual_signs == predicted_signs)
    # calculate the MDA value
    mda = num_correct / (len(actual) - 1)
    return mda

# Append data to the data frame
result_mda = mda(actual_data, all_predictions)
print("Mean Directional Accuracy (MDA):", result_mda)

# Save the DataFrame to 'result_lstm.xlsx'
result_df = pd.DataFrame({'Actual ': actual_data, 'Forecast': all_predictions, 'MAPE':
all_mape, 'MDA': result_mda})
result_df.to_excel('result_lstm.xlsx', index=False)

# Plot the graph of errors over time
df_error = pd.read_excel('result_lstm.xlsx')
plt.plot(df_error['MAPE'], marker='o', linestyle='-', color='b')
plt.title('Error over Time')
plt.ylabel("percent of Error")
plt.show()

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.10 ชุดคำสั่งที่ใช้ในการพยากรณ์ข้อมูลตัวแบบ EMD-LSTM

parameters for storing data

```
all_predictions = []
```

```
all_mape = []
```

```
actual_data = []
```

```
for round_number in range(11):
```

```
    print(f"Running round {round_number + 1}...")
```

```
    df = pd.read_excel('product.xlsx', sheet_name='สินค้าอะไหล่รถจักรยานยนต์ A',
        usecols=['Value'])
```

```
    data = np.array(df)
```

Scale the data

```
    scaler = MinMaxScaler()
```

```
    train_data_scaled = scaler.fit_transform(data)
```

Empirical Mode Decomposition

```
    emd = EMD()
```

```
    IMFs = emd(train_data_scaled.squeeze())
```

Prepare data for LSTM

```
    def create_look_back(dataset, look_back=1):
```

```
        dataX, dataY = [], []
```

```
        for i in range(len(dataset[0]) - look_back):
```

```
            dataX.append(dataset[:, i:(i + look_back)])
```

```
            dataY.append(dataset[:, i + look_back])
```

```
        return np.array(dataX), np.array(dataY)
```

Split data into train and test sets

```
    if round_number == 0:
```

```
        SIZE = 11
```

```
    else:
```

```
        SIZE = 11 - round_number
```

Example look-back window size

```
    look_back = 12
```

```
    X, Y = create_look_back(IMFs, look_back)
```

```
    X_train, Y_train = X[:-SIZE], Y[:-SIZE]
```

```
    X_test, Y_test = X[-SIZE:], Y[-SIZE:]
```

Build LSTM model

```
    model = Sequential()
```

```
    model.add(LSTM(10, input_shape=(5, look_back), recurrent_dropout = 0.7,
        return_sequences=True))
```

```
    model.add(LSTM(10, recurrent_dropout = 0.7, return_sequences=True))
```

```

model.add(LSTM(10,recurrent_dropout = 0.7))
model.add(Dense(5))
model.compile(loss='mean_squared_error', optimizer=Adam(amsgrad=True))
model.fit(X_train, Y_train, epochs=3000, batch_size=64, verbose=1)
# Make predictions using LSTM
lstm_predictions_scaled = model.predict(X_test)
lstm_predictions = scaler.inverse_transform(lstm_predictions_scaled)
# Combine the forecasted IMFs to get the final forecast
reconstructed_signal = np.sum(lstm_predictions, axis=1)
reconstructed_signal = reconstructed_signal.reshape(-1)
# reshape
original_values = data[-SIZE:]
original_values = original_values.reshape(-1)
# Calculate Mean Absolute Percentage Error (MAPE)
def mape(original_values, reconstructed_signal):
    return mean(np.abs((original_values - reconstructed_signal) / original_values)) *
100
mape_cal = mape(original_values[0], reconstructed_signal[0])
# Append data to the data frame
all_predictions.append(reconstructed_signal[0])
actual_data.append(original_values[0])
all_mape.append(mape_cal)
# Plot the results
plt.figure(figsize=(16, 8))
plt.plot(data[-10:], label='True Values')
plt.plot(reconstructed_signal, label='LSTM Predictions')
plt.title('Time Series Forecasting')
plt.xlabel('Time')
plt.ylabel('Value')
plt.legend()
plt.show(block=False)
plt.pause(1)
plt.close()
plt.close()
# Calculate Mean Directional Accuracy (MDA)
def mda(actual_data, all_predictions):
    actual = np.array(actual_data)
    predicted = np.array(all_predictions)

```

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ทำกรณีใดๆ ทั้งสิ้น อีกทั้งยังไม่เห็นผลบ่งชี้ และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# calculate the signs of the differences between consecutive values
actual_diff = np.diff(actual)
actual_signs = np.sign(actual_diff)
predicted_diff = np.diff(predicted)
predicted_signs = np.sign(predicted_diff)
# count the number of times the signs are the same
num_correct = np.sum(actual_signs == predicted_signs)
# calculate the MDA value
mda = num_correct / (len(actual) - 1)
return mda

# Append data to the data frame
result_mda = mda(actual_data, all_predictions)
# Save the forecast_df DataFrame to 'result_lstm.xlsx'
result_df = pd.DataFrame({'Actual ': actual_data, ' Forecast': all_predictions, 'MAPE':
all_mape, 'MDA':result_mda})
result_df.to_excel('result_lstm.xlsx', index=False)
# Plot the graph of errors over time
df_error = pd.read_excel('result_lstm.xlsx')
plt.plot(df_error['MAPE'], marker='o', linestyle='-', color='b')
plt.title('Error over Time')
plt.ylabel("percent of Error")
plt.show()

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ข

ข.1 ผลการสร้างตัวแบบพยากรณ์เชิงเดียวด้วยวิธีการบ็อก-เจนกินส์

ข.1.1 การพยากรณ์ด้วยตัวแบบ ARIMA

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=1597.483, Time=0.00 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=1570.139, Time=0.03 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=1516.862, Time=0.06 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=1595.484, Time=0.01 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=1509.267, Time=0.09 sec
ARIMA(2,1,1)(0,0,0)[0] intercept : AIC=1455.388, Time=0.23 sec
ARIMA(2,1,0)(0,0,0)[0] intercept : AIC=1461.783, Time=0.03 sec
ARIMA(3,1,1)(0,0,0)[0] intercept : AIC=1456.563, Time=0.15 sec
ARIMA(2,1,2)(0,0,0)[0] intercept : AIC=inf, Time=0.29 sec
ARIMA(1,1,2)(0,0,0)[0] intercept : AIC=inf, Time=0.13 sec
ARIMA(3,1,0)(0,0,0)[0] intercept : AIC=1461.422, Time=0.04 sec
ARIMA(3,1,2)(0,0,0)[0] intercept : AIC=inf, Time=0.23 sec
ARIMA(2,1,1)(0,0,0)[0] : AIC=1453.400, Time=0.06 sec
ARIMA(1,1,1)(0,0,0)[0] : AIC=1507.267, Time=0.05 sec
ARIMA(2,1,0)(0,0,0)[0] : AIC=1459.796, Time=0.02 sec
ARIMA(3,1,1)(0,0,0)[0] : AIC=1454.575, Time=0.22 sec
ARIMA(2,1,2)(0,0,0)[0] : AIC=inf, Time=0.10 sec
ARIMA(1,1,0)(0,0,0)[0] : AIC=1568.139, Time=0.01 sec
ARIMA(1,1,2)(0,0,0)[0] : AIC=inf, Time=0.09 sec
ARIMA(3,1,0)(0,0,0)[0] : AIC=1459.435, Time=0.06 sec
ARIMA(3,1,2)(0,0,0)[0] : AIC=inf, Time=0.15 sec

Best model: ARIMA(2,1,1)(0,0,0)[0]

```

รูปที่ ข.1 ค่า AIC ในแต่ละอันดับของตัวแบบพยากรณ์เชิงเดียว ARIMA

ข.1.2 การพยากรณ์ด้วยตัวแบบ SARIMA

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,1,1)[12] : AIC=inf, Time=0.12 sec
ARIMA(0,1,0)(0,1,0)[12] : AIC=1850.192, Time=0.01 sec
ARIMA(1,1,0)(1,1,0)[12] : AIC=1806.212, Time=0.14 sec
ARIMA(0,1,1)(0,1,1)[12] : AIC=inf, Time=0.28 sec
ARIMA(1,1,0)(0,1,0)[12] : AIC=1822.678, Time=0.02 sec
ARIMA(1,1,0)(2,1,0)[12] : AIC=1790.993, Time=0.56 sec
ARIMA(1,1,0)(2,1,1)[12] : AIC=inf, Time=1.13 sec
ARIMA(1,1,0)(1,1,1)[12] : AIC=inf, Time=0.49 sec

```

รูปที่ ข.2 ค่า AIC ในแต่ละอันดับของตัวแบบพยากรณ์เชิงเดียว ARIMA

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

ARIMA(0,1,0)(2,1,0)[12] : AIC=1825.188, Time=0.38 sec
ARIMA(2,1,0)(2,1,0)[12] : AIC=1768.981, Time=0.76 sec
ARIMA(2,1,0)(1,1,0)[12] : AIC=1790.389, Time=0.10 sec
ARIMA(2,1,0)(2,1,1)[12] : AIC=inf, Time=1.05 sec
ARIMA(2,1,0)(1,1,1)[12] : AIC=inf, Time=0.39 sec
ARIMA(3,1,0)(2,1,0)[12] : AIC=1767.061, Time=0.80 sec
ARIMA(3,1,0)(1,1,0)[12] : AIC=1787.674, Time=0.10 sec
ARIMA(3,1,0)(2,1,1)[12] : AIC=inf, Time=1.37 sec
ARIMA(3,1,0)(1,1,1)[12] : AIC=inf, Time=0.89 sec
ARIMA(4,1,0)(2,1,0)[12] : AIC=1767.383, Time=1.90 sec
ARIMA(3,1,1)(2,1,0)[12] : AIC=1759.757, Time=1.20 sec
ARIMA(3,1,1)(1,1,0)[12] : AIC=1774.231, Time=0.51 sec
ARIMA(3,1,1)(2,1,1)[12] : AIC=inf, Time=1.75 sec
ARIMA(3,1,1)(1,1,1)[12] : AIC=inf, Time=0.89 sec
ARIMA(2,1,1)(2,1,0)[12] : AIC=1759.280, Time=2.80 sec
ARIMA(2,1,1)(1,1,0)[12] : AIC=1772.598, Time=0.46 sec
ARIMA(2,1,1)(2,1,1)[12] : AIC=inf, Time=1.68 sec
ARIMA(2,1,1)(1,1,1)[12] : AIC=inf, Time=0.81 sec
ARIMA(1,1,1)(2,1,0)[12] : AIC=1757.722, Time=0.79 sec
ARIMA(1,1,1)(1,1,0)[12] : AIC=1770.635, Time=0.34 sec
ARIMA(1,1,1)(2,1,1)[12] : AIC=inf, Time=1.25 sec
ARIMA(1,1,1)(1,1,1)[12] : AIC=inf, Time=0.82 sec
ARIMA(0,1,1)(2,1,0)[12] : AIC=1757.990, Time=0.82 sec
ARIMA(1,1,2)(2,1,0)[12] : AIC=1759.567, Time=1.49 sec
ARIMA(0,1,2)(2,1,0)[12] : AIC=1757.572, Time=0.92 sec
ARIMA(0,1,2)(1,1,0)[12] : AIC=1770.656, Time=0.39 sec
ARIMA(0,1,2)(2,1,1)[12] : AIC=inf, Time=1.53 sec
ARIMA(0,1,2)(1,1,1)[12] : AIC=inf, Time=0.74 sec
ARIMA(0,1,3)(2,1,0)[12] : AIC=1759.558, Time=0.84 sec
ARIMA(1,1,3)(2,1,0)[12] : AIC=1761.552, Time=1.51 sec
ARIMA(0,1,2)(2,1,1)[12] intercept : AIC=inf, Time=1.47 sec
ARIMA(0,1,2)(1,1,1)[12] intercept : AIC=inf, Time=0.87 sec
ARIMA(0,1,1)(2,1,0)[12] intercept : AIC=1756.394, Time=1.23 sec
ARIMA(0,1,1)(1,1,0)[12] intercept : AIC=inf, Time=0.34 sec
ARIMA(0,1,1)(2,1,1)[12] intercept : AIC=inf, Time=1.38 sec
ARIMA(0,1,1)(1,1,1)[12] intercept : AIC=inf, Time=0.72 sec
ARIMA(0,1,0)(2,1,0)[12] intercept : AIC=1827.185, Time=0.53 sec
ARIMA(1,1,1)(2,1,0)[12] intercept : AIC=1756.689, Time=1.36 sec
ARIMA(1,1,0)(2,1,0)[12] intercept : AIC=1792.918, Time=0.62 sec
ARIMA(1,1,2)(2,1,0)[12] intercept : AIC=1766.713, Time=1.66 sec

```

รูปที่ ข.2 (ต่อ) ค่า AIC ในแต่ละอันดับของตัวแบบพยากรณ์เชิงเดี่ยว SARIMA
 เอกสารนี้เป็นเอกสารที่ลงนามแล้วหรือการเขียนเพื่อการศึกษาเท่านั้น เมื่อผู้ดูแลเห็นไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆ ผลการสร้างสรรค์ตัวแบบผสมเทคนิคเชิงประจักษ์
 ไม่ว่าการนำข้อมูลไปใช้ของเอกสารทุกครั้งที่มีการนำไปใช้

ข.2.1 ตัวแบบ EMD-ARIMA

ในการพิจารณาตัวแบบที่เหมาะสม จะทำการพิจารณาตัวแบบที่มีค่า AIC น้อยที่สุด ของในแต่ละ IMF 1-4 และ Residual ดังรูปที่ ข.3-ข.7

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=1947.940, Time=0.02 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=1907.329, Time=0.02 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=1869.885, Time=0.41 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=1945.950, Time=0.00 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=1868.451, Time=0.17 sec
ARIMA(2,1,1)(0,0,0)[0] intercept : AIC=1870.015, Time=0.22 sec
ARIMA(1,1,2)(0,0,0)[0] intercept : AIC=1870.279, Time=0.21 sec
ARIMA(0,1,2)(0,0,0)[0] intercept : AIC=1868.311, Time=0.15 sec
ARIMA(0,1,3)(0,0,0)[0] intercept : AIC=1870.230, Time=0.18 sec
ARIMA(1,1,3)(0,0,0)[0] intercept : AIC=1872.084, Time=0.32 sec
ARIMA(0,1,2)(0,0,0)[0] : AIC=1866.799, Time=0.06 sec
ARIMA(0,1,1)(0,0,0)[0] : AIC=1868.574, Time=0.04 sec
ARIMA(1,1,2)(0,0,0)[0] : AIC=1869.565, Time=0.05 sec
ARIMA(0,1,3)(0,0,0)[0] : AIC=1868.737, Time=0.18 sec
ARIMA(1,1,1)(0,0,0)[0] : AIC=1866.979, Time=0.06 sec
ARIMA(1,1,3)(0,0,0)[0] : AIC=1870.446, Time=0.25 sec

```

รูปที่ ข.3 ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=1597.483, Time=0.00 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=1570.139, Time=0.03 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=1516.862, Time=0.06 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=1595.484, Time=0.01 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=1509.267, Time=0.09 sec
ARIMA(2,1,1)(0,0,0)[0] intercept : AIC=1455.388, Time=0.23 sec
ARIMA(2,1,0)(0,0,0)[0] intercept : AIC=1461.783, Time=0.03 sec
ARIMA(3,1,1)(0,0,0)[0] intercept : AIC=1456.563, Time=0.15 sec
ARIMA(2,1,2)(0,0,0)[0] intercept : AIC=inf, Time=0.29 sec
ARIMA(1,1,2)(0,0,0)[0] intercept : AIC=inf, Time=0.13 sec
ARIMA(3,1,0)(0,0,0)[0] intercept : AIC=1461.422, Time=0.04 sec
ARIMA(3,1,2)(0,0,0)[0] intercept : AIC=inf, Time=0.23 sec
ARIMA(2,1,1)(0,0,0)[0] : AIC=1453.400, Time=0.06 sec
ARIMA(1,1,1)(0,0,0)[0] : AIC=1507.267, Time=0.05 sec
ARIMA(2,1,0)(0,0,0)[0] : AIC=1459.796, Time=0.02 sec
ARIMA(3,1,1)(0,0,0)[0] : AIC=1454.575, Time=0.22 sec
ARIMA(2,1,2)(0,0,0)[0] : AIC=inf, Time=0.10 sec
ARIMA(1,1,0)(0,0,0)[0] : AIC=1568.139, Time=0.01 sec
ARIMA(1,1,2)(0,0,0)[0] : AIC=inf, Time=0.09 sec
ARIMA(3,1,0)(0,0,0)[0] : AIC=1459.435, Time=0.06 sec
ARIMA(3,1,2)(0,0,0)[0] : AIC=inf, Time=0.15 sec

Best model: ARIMA(2,1,1)(0,0,0)[0]

```

รูปที่ ข.4 ค่า AIC ของ IMF 2 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=1396.810, Time=0.01 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=1221.827, Time=0.03 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=inf, Time=0.15 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=1394.958, Time=0.00 sec
ARIMA(2,1,0)(0,0,0)[0] intercept : AIC=919.730, Time=0.06 sec
ARIMA(3,1,0)(0,0,0)[0] intercept : AIC=875.050, Time=0.05 sec
ARIMA(4,1,0)(0,0,0)[0] intercept : AIC=874.936, Time=0.15 sec
ARIMA(5,1,0)(0,0,0)[0] intercept : AIC=875.873, Time=0.16 sec
ARIMA(4,1,1)(0,0,0)[0] intercept : AIC=870.462, Time=0.24 sec
ARIMA(3,1,1)(0,0,0)[0] intercept : AIC=870.435, Time=0.12 sec
ARIMA(2,1,1)(0,0,0)[0] intercept : AIC=871.146, Time=0.08 sec
ARIMA(3,1,2)(0,0,0)[0] intercept : AIC=871.126, Time=0.24 sec
ARIMA(2,1,2)(0,0,0)[0] intercept : AIC=871.261, Time=0.15 sec
ARIMA(4,1,2)(0,0,0)[0] intercept : AIC=873.303, Time=0.41 sec

```

รูปที่ ข.5 ค่า AIC ของ IMF 3 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=1131.903, Time=0.01 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=769.882, Time=0.02 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=inf, Time=0.07 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=1134.848, Time=0.00 sec
ARIMA(2,1,0)(0,0,0)[0] intercept : AIC=inf, Time=0.05 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=inf, Time=0.23 sec
ARIMA(2,1,1)(0,0,0)[0] intercept : AIC=326.408, Time=0.08 sec
ARIMA(3,1,1)(0,0,0)[0] intercept : AIC=240.241, Time=0.24 sec
ARIMA(3,1,0)(0,0,0)[0] intercept : AIC=265.072, Time=0.12 sec
ARIMA(4,1,1)(0,0,0)[0] intercept : AIC=240.666, Time=0.25 sec
ARIMA(3,1,2)(0,0,0)[0] intercept : AIC=240.740, Time=0.12 sec
ARIMA(2,1,2)(0,0,0)[0] intercept : AIC=280.838, Time=0.14 sec
ARIMA(4,1,0)(0,0,0)[0] intercept : AIC=242.351, Time=0.12 sec
ARIMA(4,1,2)(0,0,0)[0] intercept : AIC=242.605, Time=0.24 sec
ARIMA(3,1,1)(0,0,0)[0] : AIC=238.473, Time=0.10 sec
ARIMA(2,1,1)(0,0,0)[0] : AIC=325.024, Time=0.05 sec
ARIMA(3,1,0)(0,0,0)[0] : AIC=263.207, Time=0.13 sec
ARIMA(4,1,1)(0,0,0)[0] : AIC=238.949, Time=0.18 sec
ARIMA(3,1,2)(0,0,0)[0] : AIC=239.007, Time=0.18 sec
ARIMA(2,1,0)(0,0,0)[0] : AIC=inf, Time=0.03 sec
ARIMA(2,1,2)(0,0,0)[0] : AIC=279.424, Time=0.07 sec
ARIMA(4,1,0)(0,0,0)[0] : AIC=240.681, Time=0.07 sec
ARIMA(4,1,2)(0,0,0)[0] : AIC=240.885, Time=0.21 sec

```

รูปที่ ข.6 ค่า AIC ของ IMF 4 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,0,0)[0] intercept : AIC=564.166, Time=0.00 sec
ARIMA(1,1,0)(0,0,0)[0] intercept : AIC=inf, Time=0.11 sec
ARIMA(0,1,1)(0,0,0)[0] intercept : AIC=inf, Time=0.16 sec
ARIMA(0,1,0)(0,0,0)[0] : AIC=738.098, Time=0.01 sec
ARIMA(1,1,1)(0,0,0)[0] intercept : AIC=inf, Time=0.18 sec

```

รูปที่ ข.7 ค่า AIC ของ Residual ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)

ข.2.2 ตัวแบบ EMD-SARIMA

ในการพิจารณาตัวแบบที่เหมาะสม จะทำการพิจารณาตัวแบบที่มีค่า AIC น้อยที่สุด ของในแต่ละ IMF 1-4 และ Residual ดังรูปที่ ข.8-ข.11

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,1,1)[12] : AIC=inf, Time=0.22 sec
ARIMA(0,1,0)(0,1,0)[12] : AIC=1766.922, Time=0.02 sec
ARIMA(1,1,0)(1,1,0)[12] : AIC=1716.627, Time=0.37 sec
ARIMA(0,1,1)(0,1,1)[12] : AIC=inf, Time=0.33 sec
ARIMA(1,1,0)(0,1,0)[12] : AIC=1733.151, Time=0.02 sec
ARIMA(1,1,0)(2,1,0)[12] : AIC=1706.936, Time=0.63 sec
ARIMA(1,1,0)(2,1,1)[12] : AIC=inf, Time=0.84 sec
ARIMA(1,1,0)(1,1,1)[12] : AIC=inf, Time=0.34 sec
ARIMA(0,1,0)(2,1,0)[12] : AIC=1746.419, Time=2.37 sec
ARIMA(2,1,0)(2,1,0)[12] : AIC=1674.129, Time=0.73 sec
ARIMA(2,1,0)(1,1,0)[12] : AIC=1690.675, Time=0.28 sec
ARIMA(2,1,0)(2,1,1)[12] : AIC=inf, Time=1.09 sec
ARIMA(2,1,0)(1,1,1)[12] : AIC=inf, Time=0.46 sec
ARIMA(3,1,0)(2,1,0)[12] : AIC=1664.705, Time=0.88 sec
ARIMA(3,1,0)(1,1,0)[12] : AIC=1684.154, Time=0.34 sec
ARIMA(3,1,0)(2,1,1)[12] : AIC=inf, Time=1.53 sec
ARIMA(3,1,0)(1,1,1)[12] : AIC=inf, Time=0.83 sec
ARIMA(4,1,0)(2,1,0)[12] : AIC=1661.542, Time=1.01 sec
ARIMA(4,1,0)(1,1,0)[12] : AIC=1678.647, Time=0.46 sec
ARIMA(4,1,0)(2,1,1)[12] : AIC=inf, Time=1.99 sec
ARIMA(4,1,0)(1,1,1)[12] : AIC=inf, Time=0.96 sec
ARIMA(5,1,0)(2,1,0)[12] : AIC=1656.196, Time=1.30 sec
ARIMA(5,1,0)(1,1,0)[12] : AIC=1673.462, Time=0.57 sec
ARIMA(5,1,0)(2,1,1)[12] : AIC=inf, Time=1.61 sec
ARIMA(5,1,0)(1,1,1)[12] : AIC=inf, Time=1.01 sec
ARIMA(6,1,0)(2,1,0)[12] : AIC=1639.958, Time=1.68 sec

```

รูปที่ ข.8 ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q) x SARIMA(P, D, Q)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

ARIMA(6,1,0)(1,1,0)[12] : AIC=1662.741, Time=0.72 sec
ARIMA(6,1,0)(2,1,1)[12] : AIC=inf, Time=2.76 sec
ARIMA(6,1,0)(1,1,1)[12] : AIC=inf, Time=1.30 sec
ARIMA(7,1,0)(2,1,0)[12] : AIC=1634.992, Time=2.24 sec
ARIMA(7,1,0)(1,1,0)[12] : AIC=1657.434, Time=0.94 sec
ARIMA(7,1,0)(2,1,1)[12] : AIC=inf, Time=3.08 sec
ARIMA(7,1,0)(1,1,1)[12] : AIC=inf, Time=1.55 sec
ARIMA(7,1,1)(2,1,0)[12] : AIC=1627.549, Time=4.57 sec
ARIMA(7,1,1)(1,1,0)[12] : AIC=inf, Time=1.41 sec
ARIMA(7,1,1)(2,1,1)[12] : AIC=inf, Time=3.59 sec
ARIMA(7,1,1)(1,1,1)[12] : AIC=inf, Time=2.23 sec
ARIMA(6,1,1)(2,1,0)[12] : AIC=1625.792, Time=3.64 sec
ARIMA(6,1,1)(1,1,0)[12] : AIC=inf, Time=1.33 sec
ARIMA(6,1,1)(2,1,1)[12] : AIC=inf, Time=3.08 sec
ARIMA(6,1,1)(1,1,1)[12] : AIC=inf, Time=1.55 sec
ARIMA(5,1,1)(2,1,0)[12] : AIC=1627.867, Time=1.76 sec
ARIMA(6,1,2)(2,1,0)[12] : AIC=1627.652, Time=2.87 sec
ARIMA(5,1,2)(2,1,0)[12] : AIC=1627.365, Time=2.43 sec
ARIMA(7,1,2)(2,1,0)[12] : AIC=1631.118, Time=3.09 sec
ARIMA(6,1,1)(2,1,0)[12] intercept : AIC=1629.071, Time=4.52 sec

```

รูปที่ ข.8(ต่อ) ค่า AIC ของ IMF 1 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)xSARIMA(P, D, Q)

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,1,1)[12] : AIC=inf, Time=0.10 sec
ARIMA(0,1,0)(0,1,0)[12] : AIC=1500.260, Time=0.01 sec
ARIMA(1,1,0)(1,1,0)[12] : AIC=1451.412, Time=0.29 sec
ARIMA(0,1,1)(0,1,1)[12] : AIC=inf, Time=0.39 sec
ARIMA(1,1,0)(0,1,0)[12] : AIC=1475.337, Time=0.01 sec
ARIMA(1,1,0)(2,1,0)[12] : AIC=1426.395, Time=0.42 sec
ARIMA(1,1,0)(2,1,1)[12] : AIC=inf, Time=0.71 sec
ARIMA(1,1,0)(1,1,1)[12] : AIC=inf, Time=0.25 sec
ARIMA(0,1,0)(2,1,0)[12] : AIC=1448.227, Time=0.29 sec
ARIMA(2,1,0)(2,1,0)[12] : AIC=1336.120, Time=0.53 sec
ARIMA(2,1,0)(1,1,0)[12] : AIC=1352.438, Time=0.18 sec
ARIMA(2,1,0)(2,1,1)[12] : AIC=inf, Time=1.79 sec
ARIMA(2,1,0)(1,1,1)[12] : AIC=inf, Time=0.60 sec
ARIMA(3,1,0)(2,1,0)[12] : AIC=1336.953, Time=0.58 sec
ARIMA(2,1,1)(2,1,0)[12] : AIC=1333.019, Time=0.94 sec
ARIMA(2,1,1)(1,1,0)[12] : AIC=1347.631, Time=0.32 sec
ARIMA(2,1,1)(2,1,1)[12] : AIC=inf, Time=2.02 sec
ARIMA(2,1,1)(1,1,1)[12] : AIC=inf, Time=1.65 sec
ARIMA(1,1,1)(2,1,0)[12] : AIC=1376.716, Time=6.00 sec
ARIMA(3,1,1)(2,1,0)[12] : AIC=1334.003, Time=6.87 sec
ARIMA(2,1,2)(2,1,0)[12] : AIC=inf, Time=3.86 sec
ARIMA(1,1,2)(2,1,0)[12] : AIC=inf, Time=3.29 sec
ARIMA(3,1,2)(2,1,0)[12] : AIC=inf, Time=2.51 sec
ARIMA(2,1,1)(2,1,0)[12] intercept : AIC=1335.023, Time=1.12 sec

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 รูปที่ ข.9 ค่า AIC ของ IMF 2 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)xSARIMA(P, D, Q)
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกและเผยแพร่ข้อมูลของเอกสารนี้แก่บุคคลอื่นโดยไม่ได้รับอนุญาต

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,1,1)[12] : AIC=inf, Time=0.16 sec
ARIMA(0,1,0)(0,1,0)[12] : AIC=1283.546, Time=0.01 sec
ARIMA(1,1,0)(1,1,0)[12] : AIC=1105.617, Time=0.16 sec
ARIMA(0,1,1)(0,1,1)[12] : AIC=inf, Time=0.24 sec
ARIMA(1,1,0)(0,1,0)[12] : AIC=1105.904, Time=0.03 sec
ARIMA(1,1,0)(2,1,0)[12] : AIC=1079.610, Time=0.32 sec
ARIMA(1,1,0)(2,1,1)[12] : AIC=1072.920, Time=0.87 sec
ARIMA(1,1,0)(1,1,1)[12] : AIC=inf, Time=1.24 sec
ARIMA(1,1,0)(2,1,2)[12] : AIC=1074.001, Time=2.40 sec
ARIMA(1,1,0)(1,1,2)[12] : AIC=inf, Time=0.88 sec
ARIMA(0,1,0)(2,1,1)[12] : AIC=1243.154, Time=0.59 sec
ARIMA(2,1,0)(2,1,1)[12] : AIC=inf, Time=2.71 sec
ARIMA(1,1,1)(2,1,1)[12] : AIC=inf, Time=2.56 sec
ARIMA(0,1,1)(2,1,1)[12] : AIC=inf, Time=1.35 sec
ARIMA(2,1,1)(2,1,1)[12] : AIC=inf, Time=1.75 sec
ARIMA(1,1,0)(2,1,1)[12] intercept : AIC=1074.858, Time=1.05 sec

```

รูปที่ ข.10 ค่า AIC ของ IMF 3 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)xSARIMA(P, D, Q)

```

ARIMA(0,1,0)(0,1,1)[12] : AIC=inf, Time=0.07 sec
ARIMA(0,1,0)(0,1,0)[12] : AIC=1068.120, Time=0.01 sec
ARIMA(1,1,0)(1,1,0)[12] : AIC=733.222, Time=0.25 sec
ARIMA(0,1,1)(0,1,1)[12] : AIC=inf, Time=0.26 sec
ARIMA(1,1,0)(0,1,0)[12] : AIC=785.329, Time=0.02 sec
ARIMA(1,1,0)(2,1,0)[12] : AIC=728.409, Time=0.27 sec
ARIMA(1,1,0)(2,1,1)[12] : AIC=inf, Time=1.37 sec
ARIMA(1,1,0)(1,1,1)[12] : AIC=inf, Time=0.68 sec
ARIMA(0,1,0)(2,1,0)[12] : AIC=1052.833, Time=0.20 sec
ARIMA(2,1,0)(2,1,0)[12] : AIC=inf, Time=0.45 sec
ARIMA(1,1,1)(2,1,0)[12] : AIC=inf, Time=1.28 sec
ARIMA(0,1,1)(2,1,0)[12] : AIC=inf, Time=0.49 sec
ARIMA(2,1,1)(2,1,0)[12] : AIC=333.668, Time=0.89 sec
ARIMA(2,1,1)(1,1,0)[12] : AIC=337.094, Time=0.29 sec
ARIMA(2,1,1)(2,1,1)[12] : AIC=inf, Time=2.48 sec
ARIMA(2,1,1)(1,1,1)[12] : AIC=inf, Time=0.41 sec
ARIMA(3,1,1)(2,1,0)[12] : AIC=262.411, Time=3.40 sec
ARIMA(3,1,1)(1,1,0)[12] : AIC=271.572, Time=0.33 sec
ARIMA(3,1,1)(2,1,1)[12] : AIC=inf, Time=3.50 sec
ARIMA(3,1,1)(1,1,1)[12] : AIC=inf, Time=1.45 sec
ARIMA(3,1,0)(2,1,0)[12] : AIC=289.822, Time=0.75 sec
ARIMA(4,1,1)(2,1,0)[12] : AIC=262.187, Time=3.65 sec
ARIMA(4,1,1)(1,1,0)[12] : AIC=271.236, Time=0.76 sec
ARIMA(4,1,1)(2,1,1)[12] : AIC=inf, Time=4.36 sec
ARIMA(4,1,1)(1,1,1)[12] : AIC=inf, Time=1.58 sec
ARIMA(4,1,0)(2,1,0)[12] : AIC=265.306, Time=1.06 sec
ARIMA(5,1,1)(2,1,0)[12] : AIC=inf, Time=3.20 sec
ARIMA(4,1,2)(2,1,0)[12] : AIC=258.838, Time=3.27 sec

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
รูปที่ ข.11 ค่า AIC ของ IMF 4 ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)xSARIMA(P, D, Q)
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Performing stepwise search to minimize aic
ARIMA(0,1,0)(0,1,1)[12]           : AIC=inf, Time=0.17 sec
ARIMA(0,1,0)(0,1,0)[12]           : AIC=451.606, Time=0.01 sec
ARIMA(1,1,0)(1,1,0)[12]           : AIC=inf, Time=0.37 sec
ARIMA(0,1,1)(0,1,1)[12]           : AIC=inf, Time=0.37 sec
ARIMA(0,1,0)(1,1,0)[12]           : AIC=386.523, Time=0.05 sec
ARIMA(0,1,0)(2,1,0)[12]           : AIC=inf, Time=0.15 sec
ARIMA(0,1,0)(1,1,1)[12]           : AIC=inf, Time=0.34 sec
ARIMA(0,1,0)(2,1,1)[12]           : AIC=inf, Time=0.93 sec
ARIMA(0,1,1)(1,1,0)[12]           : AIC=inf, Time=0.32 sec
ARIMA(1,1,1)(1,1,0)[12]           : AIC=inf, Time=0.60 sec
ARIMA(0,1,0)(1,1,0)[12] intercept : AIC=387.832, Time=0.09 sec

```

รูปที่ ข.12 ค่า AIC ของ Residual ในแต่ละอันดับของตัวแบบ ARIMA(p, d, q)xSARIMA(P, D, Q)



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ค

ค.1 ผลการทดสอบแนวโน้มและอิทธิพลฤดูกาลแบบไม่อิงพารามิเตอร์

ค.1.1 การทดสอบแนวโน้มแบบไม่อิงพารามิเตอร์ โดยใช้การทดสอบของแดเนียล

ตารางที่ ค.1 การคำนวณสถิติทดสอบแดเนียลของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	$R(Y_t)$	d_t	d_t^2
2014	1	63	29	-28	784
2014	2	36	6	-4	16
2014	3	44	9	-6	36
2014	4	28	5	-1	1
2014	5	57	15	-10	100
2014	6	93	66	-60	3600
2014	7	73	37	-30	900
2014	8	49	11	-3	9
2014	9	81	48	-39	1521
2014	10	59	21	-11	121
2014	11	61	26	-15	225
2014	12	93	69	-57	3249
2015	1	64	30	-29	841
2015	2	68	33	-31	961
2015	3	47	10	-7	49
2015	4	51	13	-9	81
2015	5	60	22	-17	289
2015	6	104	83	-77	5929
2015	7	57	16	-9	81
2015	8	96	71	-63	3969
2015	9	135	99	-90	8100
2015	10	77	42	-32	1024
2015	11	69	34	-23	529
2015	12	92	65	-53	2809
2016	1	83	51	-50	2500

เอกสารนี้เป็นเอกสารที่สงวนไว้เพื่อการใช้งานเท่านั้น 51 | อนุญาตให้ไป 2500 | โยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.1(ต่อ) การคำนวณสถิติทดสอบแดเนียลของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	$R(Y_t)$	d_t	d_t^2
2016	2	96	72	-70	4900
2016	3	70	35	-32	1024
2016	4	83	50	-46	2116
2016	5	53	14	-9	81
2016	6	92	63	-57	3249
2016	7	63	28	-21	441
2016	8	59	19	-11	121
2016	9	160	103	-94	8836
2016	10	90	61	-51	2601
2016	11	82	49	-38	1444
2016	12	169	106	-94	8836
2017	1	149	101	-100	10000
2017	2	88	58	-56	3136
2017	3	229	108	-105	11025
2017	4	21	3	1	1
2017	5	20	2	3	9
2017	6	117	91	-85	7225
2017	7	119	92	-85	7225
2017	8	100	77	-69	4761
2017	9	87	55	-46	2116
2017	10	126	94	-84	7056
2017	11	73	38	-27	729
2017	12	23	4	8	64
2018	1	206	107	-106	11236
2018	2	9	1	1	1
2018	3	132	97	-94	8836

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งาน เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้拿去ใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมีเหตุดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.1 (ต่อ) การคำนวณสถิติทดสอบแตเนี่ยลของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	$R(Y_t)$	d_t	d_t^2
2018	4	79	45	-41	1681
2018	5	104	84	-79	6241
2018	6	97	74	-68	4624
2018	7	76	39	-32	1024
2018	8	93	67	-59	3481
2018	9	89	59	-50	2500
2018	10	88	56	-46	2116
2018	11	93	68	-57	3249
2018	12	90	60	-48	2304
2019	1	104	79	-78	6084
2019	2	49	12	-10	100
2019	3	86	54	-51	2601
2019	4	109	87	-83	6889
2019	5	60	23	-18	324
2019	6	127	96	-90	8100
2019	7	104	80	-73	5329
2019	8	110	89	-81	6561
2019	9	111	90	-81	6561
2019	10	81	47	-37	1369
2019	11	77	43	-32	1024
2019	12	78	44	-32	1024
2020	1	76	40	-39	1521
2020	2	166	105	-103	10609
2020	3	92	64	-61	3721
2020	4	39	8	-4	16
2020	5	62	27	-22	484

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งาน เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้拿去ไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมีเหตุดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.1(ต่อ) การคำนวณสถิติทดสอบแคเนียลของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์

A

ปี	t	Y_t	$R(Y_t)$	d_t	d_t^2
2020	8	97	73	-65	4225
2020	9	76	41	-32	1024
2020	10	106	86	-76	5776
2020	11	126	95	-84	7056
2020	12	155	102	-90	8100
2021	1	110	88	-87	7569
2021	2	85	53	-51	2601
2021	3	162	104	-101	10201
2021	4	84	52	-48	2304
2021	5	140	100	-95	9025
2021	6	105	85	-79	6241
2021	7	59	20	-13	169
2021	8	58	17	-9	81
2021	9	65	31	-22	484
2021	10	99	76	-66	4356
2021	11	121	93	-82	6724
2021	12	94	70	-58	3364
2022	1	79	46	-45	2025
2022	2	58	18	-16	256
2022	3	133	98	-95	9025
2022	4	38	7	-3	9
2022	5	104	82	-77	5929
2022	6	65	32	-26	676
2022	7	61	24	-17	289
2022	8	88	57	-49	2401
2022	9	91	62	-53	2809

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาติให้ไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.1(ต่อ) การคำนวณสถิติทดสอบเดเนียลของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์

A

ปี	t	Y_t	$R(Y_t)$	d_t	d_t^2
2022	10	61	24	-14	196
2022	11	70	36	-25	625
2022	12	104	81	-69	4761



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค.1.2 การทดสอบแนวโน้มแบบไม่อิงพารามิเตอร์ โดยใช้การทดสอบของครัสคาล-วอลลิส

ตารางที่ ค.2 การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y _t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T _t)	แบบบวก		แบบคูณ	
						Y' _t	Rank(Y' _t)	Y' _t	Rank(Y' _t)
2014	1	1	63						
2014	2	2	36						
2014	3	3	44						
2014	4	4	28						
2014	5	5	57						
2014	6	6	93	737					
2014	7	7	73	737	1,475	61.4417	12	66	1.1922
2014	8	8	49	769	1,507	62.7875	-14	34	0.7732
2014	9	9	81	772	1,542	64.2375	17	76	1.2629
2014	10	10	59	796	1,568	65.3385	-6	40	0.9099
2014	11	11	61	799	1,595	66.4552	-5	41	0.9220
2014	12	12	93	811	1,610	67.0792	26	80	1.3901
2015	1	64	795	1,606	66.9052	-3	43	0.9510	42

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_t)	แบบบวก		แบบคูณ	
						Y'_t	$Rank(Y'_t)$	Y''_t	$Rank(Y''_t)$
2015	3	47	896	1,738	72.4115	-26	16	0.6473	13
2015	4	51	913	1,809	75.3844	-24	18	0.6822	15
2015	5	60	921	1,834	76.4333	-16	27	0.7843	23
2015	6	104	920	1,841	76.7260	28	81	1.3600	81
2015	7	57	940	1,860	77.5031	-20	24	0.7384	19
2015	8	96	968	1,908	79.4927	16	74	1.2023	76
2015	9	135	991	1,959	81.6354	54	90	1.6568	93
2015	10	77	1,023	2,014	83.9156	-7	38	0.9137	39
2015	11	69	1,015	2,038	84.9219	-16	31	0.8152	28
2015	12	92	1,003	2,018	84.0979	8	63	1.0978	63
2016	1	83	1,009	2,011	83.8115	-1	49	0.9927	48
2016	2	96	972	1,980	82.5042	13	68	1.1627	73
2016	3	70	996	1,967	81.9750	-12	36	0.8554	36
2016	4	83	1,009	2,005	83.5490	-1	48	0.9922	47
2016	5	53	1,022	2,031	84.6375	-32	12	0.6218	11

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_t)	แบบบวก		แบบคูณ	
						Y'_t	$Rank(Y'_t)$	Y''_t	$Rank(Y''_t)$
2016	6	92	1,099	2,121	88.3563	4	59	1.0401	60
2016	7	63	1,165	2,263	94.2990	-31	13	0.6660	14
2016	8	59	1,157	2,321	96.7125	-38	9	0.6062	8
2016	9	160	1,315	2,471	102.9760	57	91	1.5489	90
2016	10	90	1,253	2,568	106.9854	-17	26	0.8431	34
2016	11	82	1,220	2,473	103.0458	-21	22	0.7941	25
2016	12	169	1,246	2,466	102.7521	66	93	1.6445	92
2017	1	149	1,302	2,547	106.1417	43	87	1.4054	86
2017	2	88	1,343	2,645	110.2146	-22	19	0.7973	26
2017	3	229	1,271	2,614	108.9156	120	96	2.0980	95
2017	4	21	1,306	2,576	107.3500	-87	2	0.1933	3
2017	5	20	1,297	2,603	108.4667	-88	1	0.1865	2
2017	6	117	1,151	2,449	102.0250	15	73	1.1492	67
2017	7	119	1,208	2,359	98.2990	21	78	1.2086	77
2017	8	100	1,129	2,337	97.3698	3	56	1.0309	56

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_t)	แบบบวก		แบบคูณ	
						Y'_t	$Rank(Y'_t)$	Y''_t	$Rank(Y''_t)$
2017	9	87	1,033	2,162	90.0625	-3	42	0.9613	43
2017	10	126	1,091	2,124	88.4813	37	85	1.4189	87
2017	11	73	1,175	2,266	94.4250	-21	23	0.7760	22
2017	12	23	1,155	2,330	97.0813	-74	4	0.2361	4
2018	1	206	1,112	2,266	94.4302	111	95	2.1794	96
2018	2	9	1,104	2,215	92.3063	-83	3	0.0970	1
2018	3	132	1,107	2,210	92.0979	40	86	1.4338	88
2018	4	79	1,069	2,175	90.6271	-11	37	0.8745	37
2018	5	104	1,088	2,157	89.8573	15	71	1.1616	71
2018	6	97	1,155	2,243	93.4656	3	58	1.0362	59
2018	7	76	1,053	2,208	91.9969	-16	28	0.8215	29
2018	8	93	1,093	2,146	89.3990	3	57	1.0361	58
2018	9	89	1,047	2,140	89.1625	0	52	1.0018	52
2018	10	88	1,077	2,124	88.5104	-1	46	0.9886	46
2018	11	93	1,033	2,110	87.9083	5	62	1.0562	62

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_t)	แบบบวก		แบบคูณ	
						Y'_t	$Rank(Y'_t)$	Y''_t	$Rank(Y''_t)$
2018	12	90	1,063	2,096	87.3250	3	55	1.0301	55
2019	1	206	1,112	2,266	94.4302	111	95	2.1794	96
2019	2	9	1,104	2,215	92.3063	-83	3	0.0970	1
2019	3	132	1,107	2,210	92.0979	40	86	1.4338	88
2019	4	79	1,069	2,175	90.6271	-11	37	0.8745	37
2019	5	104	1,088	2,157	89.8573	15	71	1.1616	71
2019	6	97	1,155	2,243	93.4656	3	58	1.0362	59
2019	7	76	1,053	2,208	91.9969	-16	28	0.8215	29
2019	8	93	1,093	2,146	89.3990	3	57	1.0361	58
2019	9	89	1,047	2,140	89.1625	0	52	1.0018	52
2019	10	88	1,077	2,124	88.5104	-1	46	0.9886	46
2019	11	93	1,033	2,110	87.9083	5	62	1.0562	62
2019	12	90	1,063	2,096	87.3250	3	55	1.0301	55
2020	1	76	1,092	2,188	91.1677	-15	32	0.8320	32
2020	2	166	1,079	2,171	90.4625	76	94	1.8389	94

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_t)	แบบบวก		แบบคูณ	
						Y'_t	$Rank(Y'_t)$	Y'_t	$Rank$
2020	3	92	1,044	2,122	88.4354	4	61	1.0417	
2020	4	39	1,069	2,112	88.0042	-49	5	0.4432	
2020	5	62	1,117	2,185	91.0490	-29	14	0.6829	
2020	6	98	1,194	2,310	96.2625	2	53	1.0219	
2020	7	100	1,227	2,421	100.8781	-1	50	0.9950	
2020	8	97	1,146	2,374	98.8979	-2	44	0.9785	
2020	9	76	1,216	2,363	98.4396	-22	20	0.7743	
2020	10	106	1,262	2,478	103.2500	2	54	1.0232	
2020	11	126	1,340	2,601	108.3823	17	77	1.1586	
2020	12	155	1,346	2,685	111.8917	43	88	1.3866	
2021	1	110	1,304	2,650	110.4229	-1	47	0.9932	
2021	2	85	1,265	2,570	107.0646	-22	21	0.7939	
2021	3	162	1,254	2,519	104.9490	58	92	1.5481	
2021	4	84	1,247	2,500	104.1844	-20	25	0.8072	

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_t)	แบบบวก		แบบคูณ	
						Y'_t	$Rank(Y'_t)$	Y''_t	$Rank(Y''_t)$
2021	5	140	1,242	2,489	103.6938	37	84	1.3525	80
2021	6	105	1,181	2,423	100.9375	4	60	1.0355	57
2021	7	59	1,150	2,331	97.1240	-38	8	0.6072	9
2021	8	58	1,124	2,274	94.7448	-37	10	0.6077	10
2021	9	65	1,094	2,218	92.4021	-28	15	0.6997	17
2021	10	99	1,048	2,143	89.2719	10	64	1.1076	64
2021	11	121	1,012	2,061	85.8604	35	82	1.4043	85
2021	12	94	973	1,985	82.6979	11	65	1.1367	66
2022	1	79	974	1,947	81.1208	-2	45	0.9776	44
2022	2	58	1,004	1,979	82.4458	-24	17	0.7068	18
2022	3	133	1,030	2,035	84.7729	48	89	1.5686	91
2022	4	38	992	2,022	84.2625	-46	6	0.4566	6
2022	5	104	942	1,934	80.5740	23	79	1.2907	79
2022	6	65	952	1,893	78.8875	-14	35	0.8224	30
2022	7	61							

ตารางที่ ค.2(ต่อ) การคำนวณสถิติทดสอบครัสคาล-วอลลิสของจำนวนการสั่งซื้อสินค้าอะไหล่รถจักรยานยนต์ A

ปี	t	Y_t	ผลรวม 12 เดือน	ผลรวมของผลรวม 12 เดือน	แนวโน้ม (T_i)	แบบบวก		แบบคูณ	
						Y'_i	$Rank(Y'_i)$	Y''_i	$Rank(Y''_i)$
2022	8	88							
2022	9	91							
2022	10	61							
2022	11	70							
2022	12	104							

ตารางที่ ค.3 การคำนวณสถิติทดสอบครัสคาล-วอลลิส รูปแบบบวก


ฤดูกาล	ลำดับที่									R_i	n_i	R_i^2	$\frac{R_i^2}{n_i}$
1		43	49	87	95	70	32	47	45	468	8	219024	27378.00
2		51	68	19	3	7	94	21	17	280	8	78400	9800.00
3		16	36	96	86	39	61	92	89	515	8	265225	33153.13
4		18	48	2	37	72	5	25	6	213	8	45369	5671.13
5		27	12	1	71	11	14	84	79	299	8	89401	11175.13
6		81	59	73	58	83	53	60	35	502	8	252004	31500.50
7	66	24	13	78	28	69	50	8		336	8	112896	14112.00
8	34	74	9	56	57	75	44	10		359	8	128881	16110.13
9	76	90	91	42	52	67	20	15		453	8	205209	25651.13
10	40	38	26	85	46	30	54	64		383	8	146689	18336.13
11	41	31	22	23	62	29	77	82		367	8	134689	16836.13
12	80	63	93	4	55	33	88	65		481	8	231361	28920.13
												sum	238643.50

ตารางที่ ค.4 การคำนวณสถิติทดสอบครัสคาล-วอลลิส รูปแบบคุณ

ฤดูกาล	ลำดับที่									R _i	n _i	R _i ²	$\frac{R_i^2}{n_i}$
1		42	48	86	96	69	32	49	44	466	8	217156	27144.50
2		50	73	26	1	7	94	24	18	293	8	85849	10731.13
3		13	36	95	88	41	61	89	91	514	8	264196	33024.50
4		15	47	3	37	72	5	27	6	212	8	44944	5618.00
5		23	11	2	71	12	16	80	79	294	8	86436	10804.50
6		81	60	67	59	82	53	57	30	489	8	239121	29890.13
7	75	19	14	77	29	68	51	9		342	8	116964	14620.50
8	20	76	8	56	58	74	45	10		347	8	120409	15051.13
9	78	93	90	43	52	65	21	17		459	8	210681	26335.13
10	38	39	34	87	46	33	54	64		395	8	156025	19503.13
11	40	28	25	22	62	31	70	85		363	8	131769	16471.13
12	84	63	92	4	55	35	83	66		482	8	232324	29040.50
												sum	238234.25

ภาคผนวก ง


ตารางที่ ง.1 ค่าวิกฤตการแจกแจงความน่าจะเป็นแบบโคสแควร์



d.f.	α									
	0.995	0.990	0.975	0.950	0.900	0.100	0.050	0.025	0.010	0.005
1	0.0000	0.0002	0.0010	0.0039	0.0158	2.7055	3.8415	5.0239	6.6349	7.8794
2	0.0100	0.0201	0.0506	0.1026	0.2107	4.6052	5.9915	7.3778	9.2103	10.5966
3	0.0717	0.1148	0.2158	0.3518	0.5844	6.2514	7.8147	9.3484	11.3449	12.8382
4	0.2070	0.2971	0.4844	0.7107	1.0636	7.7794	9.4877	11.1433	13.2767	14.8603
5	0.4117	0.5543	0.8312	1.1455	1.6103	9.2364	11.0705	12.8325	15.0863	16.7496
6	0.6757	0.8721	1.2373	1.6354	2.2041	10.6446	12.5916	14.4494	16.8119	18.5476
7	0.9893	1.2390	1.6899	2.1673	2.8331	12.0170	14.0671	16.0128	18.4753	20.2777
8	1.3444	1.6465	2.1797	2.7326	3.4895	13.3616	15.5073	17.5345	20.0902	21.9550
9	1.7349	2.0879	2.7004	3.3251	4.1682	14.6837	16.9190	19.0228	21.6660	23.5894
10	2.1559	2.5582	3.2470	3.9403	4.8652	15.9872	18.3070	20.4832	23.2093	25.1882
11	2.6032	3.0535	3.8157	4.5748	5.5778	17.2750	19.6751	21.9200	24.7250	26.7568
12	3.0738	3.5706	4.4038	5.2260	6.3038	18.5493	21.0261	23.3367	26.2170	28.2995
13	3.5650	4.1069	5.0088	5.8919	7.0415	19.8119	22.3620	24.7356	27.6883	29.8195
14	4.0747	4.6604	5.6287	6.5706	7.7895	21.0641	23.6848	26.1189	29.1412	31.3194
15	4.6009	5.2293	6.2621	7.2609	8.5468	22.3071	24.9958	27.4884	30.5779	32.8013
16	5.1422	5.8122	6.9077	7.9616	9.3122	23.5418	26.2962	28.8454	31.9999	34.2672
17	5.6972	6.4078	7.5642	8.6718	10.0852	24.7690	27.5871	30.1910	33.4087	35.7185
18	6.2648	7.0149	8.2307	9.3905	10.8649	25.9894	28.8693	31.5264	34.8053	37.1565
19	6.8440	7.6327	8.9065	10.1170	11.6509	27.2036	30.1435	32.8523	36.1909	38.5823
20	7.4338	8.2604	9.5908	10.8508	12.4426	28.4120	31.4104	34.1696	37.5662	39.9968
21	8.0337	8.8972	10.2829	11.5913	13.2396	29.6151	32.6706	35.4789	38.9322	41.4011
22	8.6427	9.5425	10.9823	12.3380	14.0415	30.8133	33.9244	36.7807	40.2894	42.7957
23	9.2604	10.1957	11.6886	13.0905	14.8480	32.0069	35.1725	38.0756	41.6384	44.1813
24	9.8862	10.8564	12.4012	13.8484	15.6587	33.1962	36.4150	39.3641	42.9798	45.5585
25	10.5197	11.5240	13.1197	14.6114	16.4734	34.3816	37.6525	40.6465	44.3141	46.9279
26	11.1602	12.1981	13.8439	15.3792	17.2919	35.5632	38.8851	41.9232	45.6417	48.2899
27	11.8076	12.8785	14.5734	16.1514	18.1139	36.7412	40.1133	43.1945	46.9629	49.6449
28	12.4613	13.5647	15.3079	16.9279	18.9392	37.9159	41.3371	44.4608	48.2782	50.9934
29	13.1211	14.2565	16.0471	17.7084	19.7677	39.0875	42.5570	45.7223	49.5879	52.3356
30	13.7867	14.9535	16.7908	18.4927	20.5992	40.2560	43.7730	46.9792	50.8922	53.6720
40	20.7065	22.1643	24.4330	26.5093	29.0505	51.8051	55.7585	59.3417	63.6907	66.7660
50	27.9907	29.7067	32.3574	34.7643	37.6886	63.1671	67.5048	71.4202	76.1539	79.4900
60	35.5345	37.4849	40.4817	43.1880	46.4589	74.3970	79.0819	83.2977	88.3794	91.9517
70	43.2752	45.4417	48.7576	51.7393	55.3289	85.5270	90.5312	95.0232	100.4252	104.2149
80	51.1719	53.5401	57.1532	60.3915	64.2778	96.5782	101.8795	106.6286	112.3288	116.3211
90	59.1963	61.7541	65.6466	69.1260	73.2911	107.5650	113.1453	118.1359	124.1163	128.2989
100	67.3276	70.0649	74.2219	77.9295	82.3581	118.4980	124.3421	129.5612	135.8067	140.1695

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้วิจัย



วาดฟ้า กุลรัตน์ (วาด)

ที่อยู่ 626 ซ.ลาดพร้าว 107 ถ.ลาดพร้าว แขวงคลองจั่น เขต
บางกะปิ 10240

เบอร์โทรศัพท์ : 097-221-528

E-mail : wadfah.fah@gmail.com

ประวัติการศึกษา

- ระดับมัธยมศึกษา
โรงเรียนนวมินทราชินูทิศบดินทรเดชา
จังหวัดกรุงเทพมหานคร
- ระดับปริญญาตรี
วิทยาศาสตร์บัณฑิต สาขาสถิติประยุกต์
ภาควิชาสถิติ คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง



อรุณรุจน์ พุ่มประยงค์ชัย (เลโก้)

ที่อยู่ 239\58 หมู่3 ถนน พระยาสุรเสนา ตำบล บ้านสวน อำเภอ
เมือง จังหวัดชลบุรี 20000

เบอร์โทรศัพท์ : 081-561-4551

E-mail : palayu.b@gmail.com

ประวัติการศึกษา

- ระดับมัธยมศึกษา
โรงเรียนชลราษฎรอำรุง
จังหวัดชลบุรี
- ระดับปริญญาตรี
วิทยาศาสตร์บัณฑิต สาขาสถิติประยุกต์
ภาควิชาสถิติ คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



งานทะเบียนคณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
คำรับรองเล่มสหกิจศึกษา

วันที่ 27 เดือน มิถุนายน พ.ศ. 2567

ข้าพเจ้า นางสาววาดฟ้า กุศลรัตน์ รหัสประจำตัว 63050661

นายอรุณรุจน์ พุฒประยงค์ชัย รหัสประจำตัว 63050690

นักศึกษาหลักสูตร วิทยาศาสตร์บัณฑิต สาขาวิชา สถิติประยุกต์ ภาควิชา สถิติ .

ขอรับรอง สหกิจศึกษา เรื่อง

ชื่อภาษาไทย การทำนายอุปสงค์อะไหล่รถจักรยานยนต์โดยวิธีการผสมผสานระหว่าง
เทคนิคการประมวลผลสัญญาณและเทคนิคการพยากรณ์อนุกรมเวลา

ชื่อภาษาอังกฤษ Motorcycle Spare Parts Demand Forecasting Using a Hybrid Approach
of Signal Processing and Time Series Forecasting Techniques

ปีการศึกษา 2566

เป็นผลงานวิจัยของข้าพเจ้าแต่เพียงผู้เดียวโดยมิได้คัดลอกหรือละเมิดลิขสิทธิ์ของผู้อื่นและได้ผ่านการ
ตรวจสอบความซ้ำซ้อนโดยใช้โปรแกรมเรียบร้อยแล้ว และได้แนบเอกสารการตรวจสอบการลอกเลียน
งานวรรณกรรมที่ตรวจสอบจากวิทยานิพนธ์ฉบับสมบูรณ์แล้ว

โปรแกรมอักขราวิสุทธิ์ 3.94%

ลงชื่อ..... วาดฟ้า กุศลรัตน์

(วาดฟ้า กุศลรัตน์)

นักศึกษา

ลงชื่อ..... อรุณรุจน์ พุฒประยงค์ชัย

(อรุณรุจน์ พุฒประยงค์ชัย)

นักศึกษา

ข้าพเจ้า ผ.ศ.ดร.พรพิมล ชัยวุฒิศักดิ์ อาจารย์ที่ปรึกษาโครงการสหกิจศึกษา ได้ตรวจสอบโครงการ
สหกิจศึกษาของนักศึกษาข้างต้นแล้ว ขอรับรองว่าเป็นผลงานวิจัยของนักศึกษาจริงและมีเนื้อหา
สมบูรณ์จึงขอลงชื่อไว้เป็นหลักฐาน

ลงชื่อ..... Pornpimol Chaiwuttisak

(ผ.ศ.ดร.พรพิมล ชัยวุฒิศักดิ์)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการสืบเสาะเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
อาจารย์ที่ปรึกษา
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Plagiarism Checking Report

Created on 2024-06-26 10:00:06 at 10:00 AM

Submission Information

ID	SUBMISSION DATE	SUBMITTED BY	ORGANIZATION	FILENAME	STATUS	SIMILARITY INDEX
3801273	Jun 26, 2024 at 09:56 AM	63050661@kmitl.ac.th	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง	เล่มสหกิจศึกษา_วาดฟ้า_อรุณรัตน์.pdf	Completed	3.94 %

Match Overview

NO.	TITLE	AUTHOR(S)	SOURCE
1	การเปรียบเทียบความแม่นยำของการพยากรณ์ด้วยตัวแบบอนุกรมเวลาแบบผสม	บุญมานะ, ชญานิน	วารสารวิทยาศาสตร์และเทคโนโลยี
2	การเปรียบเทียบวิธีการพยากรณ์จำนวนผู้โดยสารทางอากาศในภาคตะวันออกเฉียงเหนือของประเทศไทย	สวนีย์ กระจงกลาง	มหาวิทยาลัยเกษตรศาสตร์
3	Improving Prediction Accuracy of Time Series Data Using ARIMA-ANN Hybrid Model and Regression Analysis	กุลวานิช, นัท	วารสารวิทยาศาสตร์และเทคโนโลยี
4	การพยากรณ์การแพร่เชื้อโรคเลปโตสไปโรซิสในจังหวัดสกลนคร	ศรพรหม, มาลี	SNRU Journal of Science and Technology
5	FORECASTING RUSSIAN TOURIST ARRIVALS TO THAILAND USING SARIMA MODEL	Nitinai Rungjindarat, นิตินัย รุ่งจินดารัตน์	วารสารวิทยาลัยดุสิต
6	ตัวแบบการพยากรณ์สำหรับลักษณะการเคลื่อนไหวในการรับและการจำหน่ายผู้ป่วยรายเดือนของโรงพยาบาลราชวิถี	เพ็ญลัดดา โสภา	มหาวิทยาลัยเกษตรศาสตร์
7	Predicting Stock Return Using Machine Learning	Buaraiking, Witsarut Kaewmaha and Varis Punyachatporn	วารสารนวัตกรรมการจัดการและสังคมศาสตร์
8	https://www.sci.nu.ac.th/sciencejournal/index.php/journal/article/download/86/pdf	sci.nu.ac.th	sci.nu.ac.th_nutch
9	The impact of laws enforcement on the fish landings at Pattani fishery port by using SARIMA with intervention model.	Laipaporn, Jetsada	วารสารเศรษฐศาสตร์ มหาวิทยาลัยเชียงใหม่
10	https://agkb.lib.ku.ac.th/sugardb/search_detail/download_digital_file/157787/46383	agkb.lib.ku.ac.th	agkb.lib.ku.ac.th_nu

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้