การศึกษาและเปรียบเทียบวิธีการพยากรณ์อุปสงค์ระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม กรณีศึกษา: โรงงานผลิตพลาสติก

ชัยชนะ อารีย์วิจิตรวงษ์

งานนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน
คณะโลจิสติกส์ มหาวิทยาลัยบูรพา
2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

การศึกษาและเปรียบเทียบวิธีการพยากรณ์อุปสงค์ระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม กรณีศึกษา: โรงงานผลิตพลาสติก

ชัยชนะ อารีย์วิจิตรวงษ์

งานนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน
คณะโลจิสติกส์ มหาวิทยาลัยบูรพา
2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

A STUDY AND COMPARISON OF DEMAND FORECASTING METHODS BETWEEN MACHINE LEARNING TECHNIQUES AND TRADITIONAL STATISTICAL TIME SERIES FORECASTING: A PLASTIC MANUFACTURER CASE STUDY

CHAICHANA AREEVIJITWONG

AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF
THE REQUIREMENTS FOR MASTER DEGREE OF SCIENCE
IN LOGISTICS AND SUPPLY CHAIN MANAGEMENT
FACULTY OF LOGISTICS
BURAPHA UNIVERSITY
2025

COPYRIGHT OF BURAPHA UNIVERSITY

คณะกรรมการควบคุมงานนิพนธ์และคณะกรรมการสอบงานนิพนธ์ได้พิจารณางานนิพนธ์ของ ชัยชนะ อารีย์วิจิตรวงษ์ ฉบับนี้แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน ของมหาวิทยาลัยบูรพาได้

คณะกรรมการควบคุมงานนิพนธ์
อาจารย์ที่ปรึกษาหลัก

.....
(ผู้ช่วยศาสตราจารย์ ดร.อนิรุทธ์ ขันธสะอาด)

คณะกรรมการสอบงานนิพนธ์

..... ประธาน
(รองศาสตราจารย์ ดร.สราวุธ ลักษณะโต)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ฐิติมา วงศ์อินตา)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.อนิรุทธ์ ขันธสะอาด)

..... คณบดีคณะโลจิสติกส์
(ผู้ช่วยศาสตราจารย์ ดร. ไพโรจน์ เร้าธนชลกุล)
วันที่.....เดือน.....พ.ศ.....

บัณฑิตวิทยาลัย มหาวิทยาลัยบูรพา อนุมัติให้รับงานนิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน ของมหาวิทยาลัยบูรพา

..... คณบดีบัณฑิตวิทยาลัย
(รองศาสตราจารย์ ดร.วิทวัส แจ้งเอี่ยม)
วันที่.....เดือน.....พ.ศ.....

66920342: สาขาวิชา: การจัดการโลจิสติกส์และโซ่อุปทาน; วท.ม. (การจัดการโลจิสติกส์และโซ่อุปทาน)
คำสำคัญ: การพยากรณ์, การเรียนรู้ของเครื่อง, นิวรัลเน็ตเวิร์ค, การพยากรณ์อนุกรมเวลา

ชัยชนะ อารีย์วิจิตรวงษ์ : การศึกษาและเปรียบเทียบวิธีการพยากรณ์อุปสงค์ระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม กรณีศึกษา: โรงงานผลิตพลาสติก. (A STUDY AND COMPARISON OF DEMAND FORECASTING METHODS BETWEEN MACHINE LEARNING TECHNIQUES AND TRADITIONAL STATISTICAL TIME SERIES FORECASTING: A PLASTIC MANUFACTURER CASE STUDY) คณะกรรมการควบคุมงานนิพนธ์: อนิรุทธ์ ขันธสะอาด ปี พ.ศ. 2568.

เนื่องจากปัจจัยธุรกิจทั้งภายในและนอกของบริษัทกรณีศึกษานั้นได้ส่งผลต่อการวางแผนในการจัดการทรัพยากรเป็นอย่างมากการพยากรณ์จึงถือเป็นปัจจัยที่สำคัญในการวางแผนการจัดการกิจกรรมต่าง ๆ ของห่วงโซ่อุปทาน ซึ่งบริษัทมีความต้องการศึกษาวิธีที่เหมาะสมเพื่อใช้ในการจัดการวางแผนในด้านต่าง ๆ เช่นการวางแผนสั่งซื้อวัตถุดิบหรือความเหมาะสมของระดับวัตถุดิบคงคลัง โดยงานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบวิธีการพยากรณ์แบบดั้งเดิมและวิธีการพยากรณ์ด้วยการเรียนรู้ของเครื่อง (Machine Learning) ของบริษัทกรณีศึกษาด้วยข้อมูลยอดขายตั้งแต่เดือนเมษายน 2563 ถึงมีนาคม 2567 (รวม 36 เดือน) และมุ่งเน้นกลุ่มสินค้าที่ส่งผลกระทบกับการจัดการในห่วงโซ่อุปทานมากที่โดยทำการเลือกสินค้า 7 จากทั้งหมด 35 รายการด้วยหลักการวิเคราะห์แบบพาเรโตโดยใช้วิธีการพยากรณ์แบบดั้งเดิม เช่น ค่าเฉลี่ยเคลื่อนที่, ARIMA และการแบบปรับเรียบเอ็กซ์โปเนียนเชียล กับเทคนิคการเรียนรู้ของเครื่อง เช่น โครงข่ายประสาทเทียม (ANN) โครงข่ายประสาทแบบวนซ้ำ (RNN) และโครงข่ายแบบหน่วยความจำระยะยาว (LSTM)

ผลการศึกษาพบว่าเทคนิคการเรียนรู้ของเครื่องมีผลการพยากรณ์แม่นยำมากกว่าโดยสามารถใช้ได้ดีกับสินค้าทั้งหมด 4 รายการจาก 7 รายการคิดเป็นสัดส่วน 57% ของ SKU ที่ทดสอบโดยเฉพาะโมเดล ANN ซึ่งประเมินค่าความคลาดเคลื่อนการพยากรณ์โดยค่า MAPE ต่ำที่สุดสำหรับ SKU02 อยู่ที่ 9.09% ซึ่งสามารถใช้ได้ดีกับข้อมูลที่มีแนวโน้มและผันผวนสูง

66920342: MAJOR: LOGISTICS AND SUPPLY CHAIN MANAGEMENT; M.Sc. (LOGISTICS AND SUPPLY CHAIN MANAGEMENT)
KEYWORDS: DEMAND FORECASTING, MACHINE LEARNING, NEURAL NETWORK, TIME SERIES FORECASTING

CHAICHANA AREEVIJITWONG : A STUDY AND COMPARISON OF DEMAND FORECASTING METHODS BETWEEN MACHINE LEARNING TECHNIQUES AND TRADITIONAL STATISTICAL TIME SERIES FORECASTING: A PLASTIC MANUFACTURER CASE STUDY. ADVISORY COMMITTEE: ANIRUT KANTASAARD, PH.D. 2025.

Due to various internal and external factors affecting the business operations of the case study company, resource planning has been significantly impacted. Forecasting plays a crucial role in planning and managing supply chain activities. This study explores appropriate forecasting methods to support planning in areas such as raw material ordering and inventory level optimization. The objective of this research is to compare traditional forecasting methods with machine learning-based forecasting techniques in a plastic manufacturing factory case study. The study uses sales data from April 2020 to March 2024 (a total of 36 months) and selects 7 out of 35 products using Pareto analysis to focus on items that have the greatest impact on supply chain management. Two groups of forecasting methods are examined: traditional methods such as Moving Average, ARIMA, and Exponential Smoothing; and machine learning techniques including Artificial Neural Networks (ANN), Recurrent Neural Networks (RNN), and Long Short-Term Memory (LSTM).

The results show that machine learning techniques provide more accurate forecasts, performing well for 4 out of the 7 selected products, accounting for 57% of the tested SKUs. In particular, the ANN model achieved the lowest MAPE for SKU02 at 9.09%, demonstrating its effectiveness in handling data with trends and high volatility.

กิตติกรรมประกาศ

งานวิจัยฉบับนี้สามารถสำเร็จลุล่วงได้ด้วยดี ด้วยความเมตตาช่วยเหลือและความกรุณาจาก ผศ.ดร.อนิรุทธ์ ขันธสะอาด อาจารย์ที่ปรึกษา ซึ่งสละทั้งเวลาและแนะนำของความรู้ความที่เกี่ยวกับเนื้อหาในงานวิจัยนี้ ตลอดจนให้คำปรึกษาในการศึกษาหาข้อมูล จัดทำ และเรียบเรียง อีกทั้งช่วยเหลือในการตรวจทานและแก้ไขข้อบกพร่องของงานวิจัยฉบับนี้แก่ผู้วิจัยตลอดระยะเวลาในการจัดทำงานวิจัยรวมถึงคณะกรรมการสอบ ผศ.ดร.ฐิติมา วงศ์อินตาและ รศ.ดร. สราวุธ ลักษณะโต ซึ่งได้มอบคำแนะนำและคำชี้แนะซึ่งช่วยให้เนื้อหางานวิจัยนี้มีความสมบูรณ์มากขึ้น และขอขอบคุณผู้บริหารของบริษัทกรณีศึกษาที่เมตตาอนุเคราะห์ข้อมูลในการทำการศึกษานี้ซึ่งเป็นมีส่วนสำคัญในการเริ่มต้นของการศึกษางานวิจัยนี้

สุดท้ายนี้ขอขอบคุณครอบครัว เพื่อน ๆ ที่ให้กำลังใจและสนับสนุนผู้วิจัยมาโดยตลอด และขอขอบพระคุณบุคคลอื่นที่มีส่วนเกี่ยวข้องในการช่วยเหลือ ให้คำแนะนำจนงานวิจัยฉบับนี้สำเร็จลุล่วงไปด้วยดี

ชัยชนะ อารียว์จิตรวงษ์

สารบัญ

หน้า

บทคัดย่อภาษาไทย ..... ง

บทคัดย่อภาษาอังกฤษ ..... จ

กิตติกรรมประกาศ ..... ฉ

สารบัญ ..... ช

สารบัญตาราง ..... ฌ

สารบัญภาพ ..... ฎ

บทที่ 1 บทนำ 1

ความเป็นมาและความสำคัญของปัญหา 1

วัตถุประสงค์ของการวิจัย 7

ขอบเขตของการวิจัย 7

คาดหวังจากการวิจัย 7

ประโยชน์ที่คาดว่าจะได้รับ 7

นิยามศัพท์ที่เกี่ยวกับกับงานวิจัย 8

บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง 9

ทฤษฎีที่เกี่ยวข้อง 9

การวิเคราะห์พาเรโต 9

ความหมายของการพยากรณ์ 9

ประเภทของการพยากรณ์ 11

การพยากรณ์แบบอนุกรมเวลาแบบดั้งเดิม 12

การพยากรณ์โดยการเรียนรู้ของเครื่อง 16

การวัดค่าความแม่นยำของตัวแบบพยากรณ์ 20

งานวิจัยที่เกี่ยวข้อง 20
บทที่ 3 ระเบียบวิธีวิจัย 35
ขั้นตอนการดำเนินงานวิจัย 36
รวบรวมข้อมูลและกำหนดขอบเขตการวิจัย 36
สร้างแบบจำลองการพยากรณ์ (Forecast Modeling) 36
การวัดค่าความถูกต้องของผลการพยากรณ์ด้วยค่าต่าง ๆ 37
สรุปผลการดำเนินการ 38
บทที่ 4 ผลการวิจัย 39
การเลือกกลุ่มรายการสินค้าที่จะนำมาพยากรณ์หลักการวิเคราะห์แบบ Pareto 39
การศึกษาวิธีการพยากรณ์จำแนกตามแบบอนุกรมเวลาแบบดั้งเดิมและการพยากรณ์โดยการเรียนรู้ของเครื่อง 44
ผลการพยากรณ์แบบอนุกรมเวลาแบบดั้งเดิม 44
ผลการพยากรณ์โดยการเรียนรู้ของเครื่อง 49
เปรียบเทียบผลการศึกษาแบ่งตามรายการสินค้าของวิธีการพยากรณ์ทั้ง 2 กลุ่ม 8 วิธี 52
สรุปผลการประเมินแบ่งตามค่าความแม่นยำของตัวแบบพยากรณ์ 59
บทที่ 5 สรุปอภิปรายผลและข้อเสนอแนะ 62
สรุปผลการวิจัยของเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม 62
สรุปผลการวิจัยของเทคนิคการเรียนรู้ด้วยเครื่อง 62
สรุปผลการศึกษา 62
ข้อเสนอแนะ 64
บรรณานุกรม 66
ประวัติย่อของผู้วิจัย 69

สารบัญตาราง

หน้า

ตารางที่ 1 สรุปงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ 26

ตารางที่ 2 สรุปวิธีการศึกษาการพยากรณ์ในงานวิจัยที่เกี่ยวข้อง 33

ตารางที่ 3 ข้อมูลรายการสินค้าและยอดขายสะสมตั้งแต่ปี 2563 – 2567 39

ตารางที่ 4 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองการหาค่าเฉลี่ยเคลื่อนที่ (Simple moving average, SMA) 44

ตารางที่ 5 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองการหาค่าเฉลี่ยเคลื่อนที่คู่ (Double moving average, DMA) 45

ตารางที่ 6 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองแบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว (Single exponential smoothing, SES) 46

ตารางที่ 7 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองแบบปรับเรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double exponential smoothing, DES) 47

ตารางที่ 8 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองแบบ Autoregressive Integrated Moving Average (ARIMA) 48

ตารางที่ 9 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยโครงข่ายประสาทเทียม (Artificial Neural Network, ANN) 49

ตารางที่ 10 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยนิวรัลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network, RNN) 50

ตารางที่ 11 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยด้วย Long Short-Term Memory (LSTM) 51

ตารางที่ 12 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU01 52

ตารางที่ 13 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU02 53

ตารางที่ 14 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU03 54

ตารางที่ 15 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU04 55

ตารางที่ 16 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU05 56

ตารางที่ 17 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU06 57

ตารางที่ 18 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU07 58

ตารางที่ 19 ผลค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ Mean Absolute Error (MAE) ที่ได้โดยเป็นหน่วยยอดขายเป็นกิโลกรัม 59

ตารางที่ 20 ผลค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่าความคลาดเคลื่อนที่ได้จะแสดงส่วนต่างกำลังสอง Mean Squared Error (MSE) ระหว่างค่าที่พยากรณ์และค่าจริง 60

ตารางที่ 21ผลค่าความคลาดเคลื่อนจะแสดงในรูปแบบเปอร์เซ็นต์ของยอดขาย Mean Absolute Percentage Error (MAPE) 60

ตารางที่ 22 ตารางสรุปวิธีการพยากรณ์ที่แม่นยำที่สุดของสินค้าแต่ละรายการ 61

สารบัญภาพ

หน้า

ภาพที่ 1 แผนภาพแสดงยอดขาย (ตัน) ตั้งแต่ปี 2563 – 2567 4

ภาพที่ 2 กราฟแสดงสัดส่วนการขายของปี 2563-2567 แบ่งตามการขายในประเทศและส่งออก (เปอร์เซ็นต์) 5

ภาพที่ 3 กรอบแนวคิดขั้นตอนการวิจัย..... 35

ภาพที่ 4 แผนภูมิ Pareto แสดงยอดขายสะสมของรายการสินค้าทั้งหมด 42

ภาพที่ 5 แผนภาพแสดงยอดขายจริงของสินค้าที่เลือกทำการศึกษาการพยากรณ์..... 43

ภาพที่ 6 สัดส่วนวิธีการพยากรณ์ที่แม่นยำที่สุดของแต่ละวิธีการพยากรณ์ 63

ภาพที่ 7 สัดส่วนวิธีการพยากรณ์ที่แม่นยำที่สุดแบ่งระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม 64

บทที่ 1
บทนำ

ความเป็นมาและความสำคัญของปัญหา

ด้านความสำคัญของอุตสาหกรรมพลาสติกนั้น หากมองในประเทศไทย ก็ถือว่าเป็นหนึ่งในฐานการผลิตพลาสติกที่สำคัญของโลกมีมูลค่าทางเศรษฐกิจของอุตสาหกรรมโดยรวมอยู่ที่ 1.1 ล้านล้านบาท (ปี 2565) โดยมีจุดแข็งสำคัญจากอุตสาหกรรมปิโตรเคมีของไทยมีขนาดใหญ่และมีศักยภาพการผลิตค่อนข้างสูงเมื่อเทียบกับประเทศในอาเซียนจึงช่วยเพิ่มจุดแข็งและความสามารถในการแข่งขันให้แก่อุตสาหกรรมเม็ดพลาสติกซึ่งเป็นผลิตภัณฑ์ปลายน้ำของอุตสาหกรรมปิโตรเคมี อีกทั้งผู้ประกอบการรายใหญ่ของไทยมีความพร้อมในการวิจัยและพัฒนาประสิทธิภาพของเม็ดพลาสติกเพื่อตอบสนองความต้องการของตลาดที่ เปลี่ยนแปลงอยู่เสมอ ทำให้ไทยสามารถผลิตเม็ดพลาสติกเพื่อสนับสนุนอุตสาหกรรมต่อเนื่องได้หลากหลายทั้งด้านคุณภาพและราคาโดยปี 2564 ไทยสามารถผลิตเม็ดพลาสติกได้สูงถึง 9.5 ล้านตัน และนำเข้าเพียง 2.0 ล้านตัน โดยเม็ดพลาสติก 59% จะถูกส่งออกไปตลาดต่างประเทศและ 41% ถูกนำมาแปรรูปเป็นผลิตภัณฑ์สนับสนุนอุตสาหกรรมต่อเนื่องในประเทศ อาทิ ยานยนต์ เครื่องใช้ไฟฟ้าและอิเล็กทรอนิกส์ และก่อสร้าง อุตสาหกรรมการแปรรูปผลิตภัณฑ์พลาสติก (Plastics converter) ของไทยจึงมีห่วงโซ่การผลิตที่ครอบคลุมทั้งวัตถุดิบต้นน้ำ ได้แก่ ผลิตภัณฑ์ก๊าซธรรมชาติในประเทศ อุตสาหกรรมกลางน้ำ ได้แก่ อุตสาหกรรมปิโตรเคมี (ผลิตเม็ดพลาสติก) และอุตสาหกรรมปลายน้ำ ได้แก่ อุตสาหกรรมปลายทางต่าง ๆ (เฑียร เทียมศักดิ์, 2566)

จุดที่เป็นคอขวดในห่วงโซ่อุปทาน (Supply chain chokepoint) จุดคอขวดเดิมทีเป็นคำศัพท์ทางการทหารที่หมายถึงสถานที่ที่มีภูมิประเทศคับแคบทำให้กองทัพขนาดใหญ่ต้องเคลื่อนพลผ่านผู้คนเพียงไม่กี่คนในเวลาเดียวกันจุดคอขวดเป็นตำแหน่งที่ดีเยี่ยมสำหรับการซุ่มโจมตีหรือสำหรับกองกำลังขนาดเล็กในการเผชิญหน้ากับกองกำลังขนาดใหญ่ ซึ่งได้รับการพิสูจน์แล้วในยุทธการที่เทอร์โมไพลี ซึ่งโด่งดังจากภาพยนตร์เรื่อง “300” โดยธุรกิจและการจัดการห่วงโซ่อุปทาน คำว่าจุดคอขวดหมายถึงจุดใด ๆ ในกระบวนการที่จุดล้มเหลวเพียงจุดเดียวอาจเป็นอันตรายต่อห่วงโซ่อุปทานและธุรกิจทั้งหมดตัวอย่างเช่นผู้ขายเนื้อสัตว์ในท้องถิ่นรายหนึ่งไม่ใช่จุดคอขวดสำหรับร้านอาหารเนื่องจากมีผู้ขายรายอื่นอยู่และต้องการทำธุรกิจกับร้านอาหารหากร้านอาหารนั้นเป็นแฟรนไชส์ที่มีข้อผูกพันตามสัญญาในการซื้อเนื้อสัตว์จากผู้ขายรายใดรายหนึ่งเท่านั้นผู้ขายรายนั้นก็จะเป็นจุดคอขวดเนื่องจากสามารถซื้อของจากแหล่งอื่นได้ โดยประเด็นที่เป็น

อันดับแรกที่ธุรกิจพบมากที่สุดและข้อเสนอแนะที่อาจใช้สำหรับการแก้ไขเบื้องต้น (Zimmerman, 2020)

การผลิตโดยมีการจัดซื้อวัตถุดิบจากต่างประเทศ โดยเฉพาะอย่างยิ่งการมีซัพพลายเออร์ต่างประเทศเพียงรายเดียวอาจทำให้เกิดปัญหาได้ ร่วมถึงส่งผลให้ห่วงโซ่การผลิตที่ยาวนานขึ้น แม้ว่าจะยังคงมีสัดส่วนวัตถุดิบอยู่ภายในประเทศก็ตามซึ่งอาจทำให้การไหลของผลิตภัณฑ์ช้าลงและก่อให้เกิดปัญหาได้ เมื่อมีส่วนของการจัดหาจากต่างประเทศ เช่น การขนส่ง ความมั่นคงในภูมิภาคภาษีศุลกากรและภาษีนำเข้าซึ่งทำให้เกิดความเสี่ยงมากขึ้น โดยการแก้ไขเบื้องต้นคือการหาแหล่งวัตถุดิบมากขึ้นเพื่อป้องกันความเสี่ยง

การขนส่งวัตถุดิบซึ่งเป็นส่วนสำคัญต่อการส่งมอบวัตถุดิบไปยังโรงงานผลิตหรือสินค้าไปยังลูกค้า โดยหากเกิดข้อผิดพลาดอาจส่งผลทำให้สินค้าของบริษัทอาจจะเสียโอกาสให้การขายหรือส่งมอบให้แก่ลูกค้าโดยเฉพาะอย่างยิ่งห่วงโซ่ของสินค้าที่มีการจัดหาจากต่างประเทศซึ่งการขนส่งภายในหนึ่งครั้งอาจจะมีการผ่านการควบคุมโดยองค์กรต่าง ๆ ทั้งประเทศต้นทางและประเทศปลายทางหลายส่วนงานซึ่งเป็นจุดคอขวดที่มีความอ่อนไหวและมีการปรับเปลี่ยนที่รวดเร็วขึ้นเช่นมาตรการที่เกิดหลังจากการระบาดของโรคติดต่อหรือ การปรับเปลี่ยนนโยบายการนำเข้าโดยการป้องกันเบื้องต้นมีอยู่สองขั้นตอนคือ ขั้นแรกต้องคอยติดตามสถานการณ์ที่อาจส่งผลกระทบต่อภูมิภาค เส้นทาง และบริษัทต่าง ๆ ที่เกี่ยวข้องการขนส่ง เพื่อเตรียมการรับมือได้ทันเวลา ขั้นที่สองคือการรักษาความสัมพันธ์คู่แข่งในตลาดในด้านห่วงโซ่อุปทานเพื่อสร้างความได้เปรียบหากมีโอกาสทางธุรกิจ

จุดคอขวดในเรื่องของช่วงจังหวะเวลาซึ่งบางสถานการณ์อาจสร้างโอกาสในเชิงความได้เปรียบในการแข่งขันเพราะฉะนั้นแล้วการตอบสนองที่ช้าหรือเร็วเกินไปอาจสร้างปัญหาให้กับห่วงโซ่อุปทานเช่นการอนุมัติหรือการตัดสินใจในการสั่งวัตถุดิบก่อนช่วงเวลาที่ถึงจุดสูงสุดเนื่องจากสถานการณ์ต่าง ๆ เช่น การประท้วงปิดท่าเรือจากแหล่งที่วัตถุต้นทางซึ่งการตัดสินใจที่ล่าช้าอาจส่งผลให้ระยะรอคอยหรือให้ห่วงโซ่ผลิตภัณฑ์ล่าช้าขึ้นหรือเสียโอกาสในการขายสินค้าซึ่งการแก้ไขเบื้องต้นคือจำเป็นที่จะต้องพิจารณาระดับสินค้าคงคลังใหม่หรือปรับกรอบเวลาการสั่งซื้อเป็นต้น

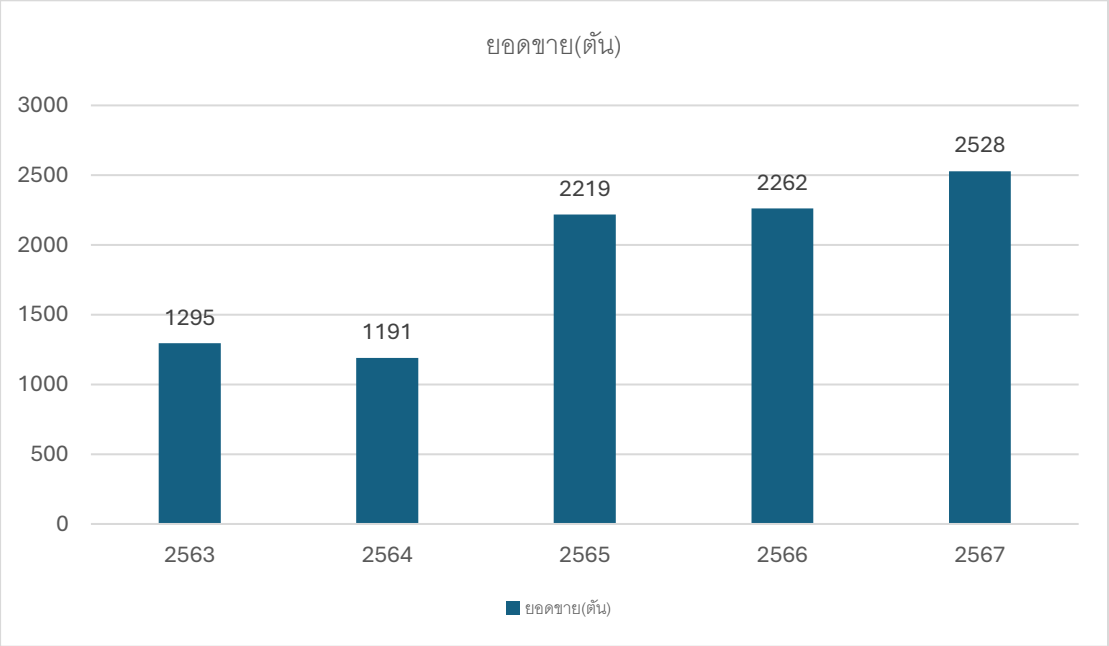
ปัญหาระหว่างจัดส่งสินค้า จุดคอขวดนี้เป็นต่างจากปัญหาการจัดส่งวัตถุดิบโดยการส่งสินค้าซึ่งจะเป็นส่วนที่ว่าด้วยเรื่องระหว่างแผนกจัดส่งและลูกค้าซึ่งมีส่วนสร้างประสบการณ์ที่ไม่ดีให้กับลูกค้าและลดโอกาสในการขายครั้งต่อไป หรือเป็นปัญหาการส่งสินค้าซึ่งเกิดจาก

ผู้รับเหมาจัดส่งสินค้ารวมถึงการขโมยในพื้นที่ที่มีอาชญากรรมสูงเช่นจุดที่มีความเสี่ยงต่อการเผชิญต่อโจรสลัด

ในขณะเดียวกันการเปลี่ยนแปลงของเทคโนโลยีในช่วงที่ผ่านมา ความรวดเร็ววิวัฒนาการของเทคโนโลยีเกี่ยวกับการเรียนรู้เครื่องได้พัฒนาอย่างรวดเร็วและมีการนำมาใช้ในหลากหลายอุตสาหกรรม เทคโนโลยี โดยสามารถช่วยในการวิเคราะห์ข้อมูลขนาดใหญ่และการพยากรณ์แนวโน้มในอนาคตได้อย่างแม่นยำ การนำการเรียนรู้เครื่องมาใช้ในอุตสาหกรรมพลาสติกสามารถช่วยให้ผู้ประกอบการสามารถปรับตัวต่อความผันผวนของตลาดได้ดีขึ้น และเพิ่มประสิทธิภาพในการจัดการทรัพยากรผู้วิจัยจึงมีความสนใจและต้องการนำเสนอเครื่องมือที่อาจจะช่วยเพิ่มประสิทธิภาพในตัดสินใจของบริษัทกรณีศึกษานี้คือการเรียนรู้ของเครื่องโดยปัจจุบันการเรียนรู้ของเครื่องนั้นมาพัฒนาและปรับปรุงให้สะดวกและมีประสิทธิภาพสูงขึ้นรวมถึงง่ายต่อการเข้าถึงโดยประโยชน์ของแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความสามารถในการจับความสัมพันธ์ที่ซับซ้อนจับความสัมพันธ์ไม่เชิงเส้น (Non-linear relationships) แบบจำลองทางสถิติแบบดั้งเดิม เช่น ARIMA มักจับความสัมพันธ์เชิงเส้นได้ดี แต่ การเรียนรู้เครื่องสามารถเรียนรู้ความสัมพันธ์ไม่เชิงเส้นที่ซับซ้อนได้ รวมถึงรองรับข้อมูลขนาดใหญ่และหลากหลายโดยสามารถประมวลผลข้อมูลจำนวนมากและรองรับตัวแปรหลายตัวโดยไม่ต้องกังวลเรื่องการขาดเสถียรภาพของแบบจำลอง อีกทั้งรองรับข้อมูลหลายประเภทซึ่งสามารถผสมผสานข้อมูลต่างประเภท เช่น ตัวเลข ข้อความ รหัส มีความแม่นยำที่สูงขึ้นและลดความผิดพลาดในการพยากรณ์กว่าวิธีการแบบดั้งเดิมสำหรับชุดข้อมูลที่มีความซับซ้อนและสามารถผสมผสานจำลอง หลายแบบจำลองเพื่อเพิ่มความแม่นยำ

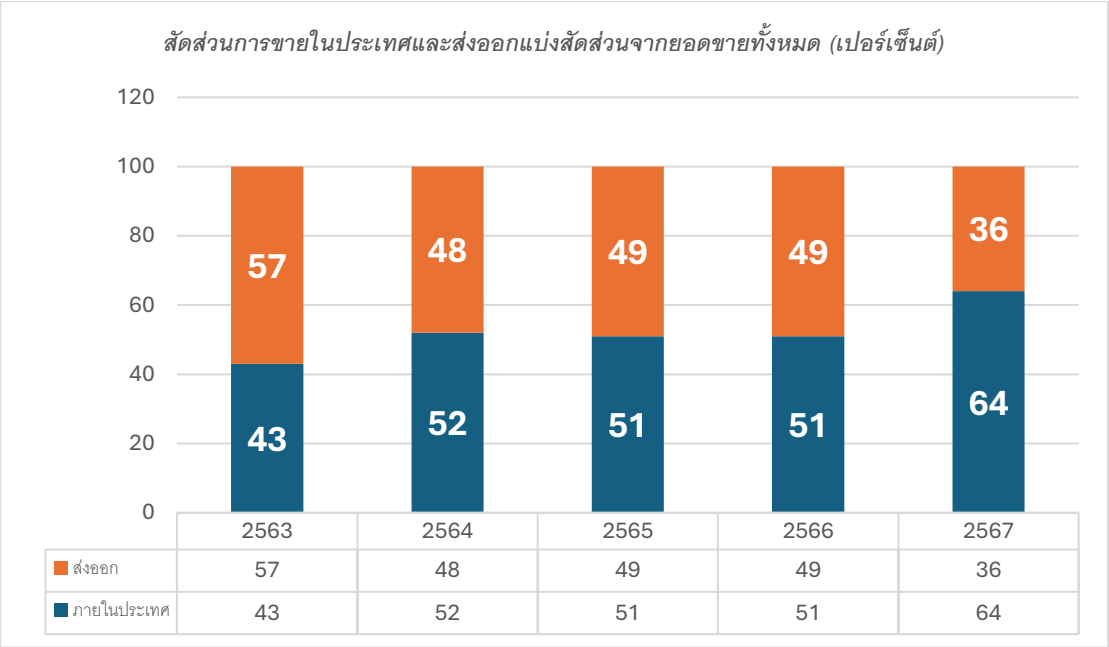
ประการสุดท้ายซึ่งเป็นกระแสด้านการรักษาสิ่งแวดล้อมที่เข้มงวดขึ้นในหลายประเทศยังส่งผลให้ผู้ประกอบการต้องปรับตัวเพื่อให้สอดคล้องกับกฎหมายและข้อบังคับใหม่ ๆ เช่น การลดการใช้พลาสติกประเภทใช้ครั้งเดียวทิ้ง (Single-use plastics) และการส่งเสริมการใช้วัสดุที่เป็นมิตรต่อสิ่งแวดล้อม การเปลี่ยนแปลงเหล่านี้ทำให้บริษัทต้องเผชิญกับความท้าทายในการปรับตัวและรักษาความสามารถในการแข่งขันในตลาดที่มีความผันผวนสูงการอีกทั้งการเปลี่ยนแปลงของสภาพภูมิอากาศโลกยังส่งผลให้การผลิตวัตถุดิบมีความไม่แน่นอนมากขึ้นทั้งภัยพิบัติทางธรรมชาติ เช่น น้ำท่วม ภัยแล้ง และพายุ ทำให้การผลิตวัตถุดิบมีความผันผวน ส่งผลให้ราคาวัตถุดิบเพิ่มสูงขึ้น จึงมีความจำเป็นที่บริษัทกรณีศึกษาต้องปรับตัวเพื่อรับมือกับความท้าทายเหล่านี้เพื่อรักษาความสามารถในการแข่งขันในตลาดที่มีความผันผวนสูง

จากข้อมูลการดำเนินการของบริษัทกรณีศึกษามีการผลิตพลาสติกขั้นปฐมซึ่งเป็นส่วนประกอบของหลายอุตสาหกรรมเช่นอุตสาหกรรมอิเล็กทรอนิกส์,ชิ้นส่วนยานยนต์รวมถึงอุตสาหกรรมผลิตภาชนะบรรจุภัณฑ์ทั้งขายภายในและส่งออกไปยังต่างประเทศโดยยอดขายสามปีล่าสุดเมื่อเทียบก่อนปี 2565 นั้นมีการเพิ่มขึ้นอย่างมากกว่า 86% เมื่อเทียบกับยอดขายปี 2564 ซึ่งเกิดจากปัจจัยการฟื้นตัวของอุตสาหกรรมภายในประเทศหลังจากการแพร่ระบาดของโควิด-19 ทำให้บริษัทต้องทำการปรับตัวเพื่อรองรับกับความต้องการที่เพิ่มขึ้นอย่างรวดเร็ว



ภาพที่ 1 แผนภาพแสดงยอดขาย (ตัน) ตั้งแต่ปี 2563 – 2567

ที่มา: ผู้วิจัย



ภาพที่ 2 กราฟแสดงสัดส่วนการขายของปี 2563-2567 แบ่งตามการขายในประเทศและส่งออก (เปอร์เซ็นต์)

ที่มา: ผู้วิจัย

โดยสถานการณ์ความต้องการที่มีเพิ่มขึ้นทำให้บริษัทต้องเผชิญกับความท้าทายในการตอบสนองความต้องการของลูกค้าที่มีเพิ่มมากขึ้นอย่างต่อเนื่อง แต่เหมือนว่าการลงทุนของบริษัทยังมีท่าทีว่าจะไม่มีการลงทุนเพิ่มเติมเนื่องจากผู้บริหารมองว่ากำลังการผลิตของบริษัทที่มีอยู่นั้นยังเพียงพอต่อความต้องการต่อเดือนในปัจจุบันที่มีอยู่เฉลี่ยประมาณ 200 ตันต่อเดือนแต่อาจจะไม่ได้พิจารณาปัจจัยด้านอื่นนอกจากกำลังการผลิตซึ่งความจากการวิเคราะห์ของผู้วิจัยบริษัทจำเป็นที่ต้องพิจารณาถึงข้อจำกัดโดยแบ่งข้อจำกัดที่เกิดจากตัวบริษัทกรณีศึกษาเองหรือปัจจัยภายนอกที่เป็นความท้าทายในการจัดการดังนี้

ประเด็นปัญหาของบริษัทกรณีศึกษา

เนื่องจากข้อจำกัดเช่นเรื่องพื้นที่ภายในโรงงานจึงจำเป็นต้องพิจารณาในเรื่องที่จัดเก็บทั้งวัตถุดิบและสินค้าสำเร็จรูป โดยต้องการอาศัยการวางแผนเรื่องพื้นที่อย่างมีประสิทธิภาพแต่บริษัทนั้นยังอาจจะมีข้อมูลหรือการคาดการณ์ที่ขาดประเมินหรือวัดประสิทธิภาพ ซึ่งการพยากรณ์การขายนั้นถือเป็นข้อมูลที่สำคัญและเป็นข้อมูลที่ส่งผลต่อการวางแผนทั้งวัตถุดิบ ทรัพยากร รวมถึงสินค้าคงคลัง ซึ่งในปัจจุบันบริษัทยังไม่ได้นำวิธีการคำนวณทางสถิติหรือการพยากรณ์เชิง

ปริมาณช่วยประกอบในการตัดสินใจหรือทำการทบทวนประสิทธิภาพของการพยากรณ์ในปัจจุบันส่งผลให้มีความคลาดเคลื่อนสูง รวมถึงข้อมูลที่ไม่เพียงพอต่อการกำหนดนโยบายต่าง ๆ เช่น การกำหนดจำนวนสินค้าคงคลังที่เหมาะสมต่อความต้องการของลูกค้า หรือการวางแผนผลิตต้องพิจารณาจากสินค้าสำเร็จรายการไหนที่มีความเหมาะสมต่อความต้องการของลูกค้า รวมถึงข้อจำกัดด้านพื้นที่รองรับวัตถุดิบและสินค้าคงคลังที่จำเป็นต้องเพิ่มประสิทธิภาพในการวางแผนเพื่อการจัดการที่เหมาะสมการสินค้าหรือวัตถุดิบแต่ละรายการ

ประกอบกับความผันผวนจากปัจจัยภายนอกที่มีความผันผวนอย่างเช่นสถานการณ์น้ำมันโลกซึ่งปัจจัยนี้ส่งผลโดยตรงต่อการวางแผนด้านวัตถุดิบของบริษัทซึ่งเป็นปัญหาที่มีผลจากปัญหาราคาวัตถุดิบที่ผันผวนและควบคุมได้ยากรวมถึงการวางแผนเพื่อเติมเต็มวัตถุดิบคงคลังมีความซับซ้อนเนื่องจากต้องพิจารณาสถานะอื่น ๆ ร่วมเช่น การหยุดชะงักของห่วงโซ่อุปทานในอุตสาหกรรมปิโตเลียม ผลกระทบจากจุดคอขวดโดยเฉพาะอย่างยิ่งการดำเนินนการต่าง ๆ ระหว่างประเทศทั้งการนำเข้าและส่งออกวัตถุดิบหรือสินค้าสำเร็จรูป มีความผันผวนของค่าระวางขนส่ง ทำให้บริษัทต้องเก็บสินค้าคงคลังไว้มากขึ้นห่วงโซ่อุปทานของวัตถุดิบหยุดชะงักปัญหาสงครามระหว่างประเทศในแถบยุโรปทำให้ต้นทุนของวัตถุดิบที่ต้องนำเข้ามีความผันผวนมากขึ้นทั้งระยะเวลาให้การส่งมอบรวมถึงราคามีความผันผวนเนื่องความต้องการในการขนส่งมีมากขึ้นเนื่องจากการปรับเปลี่ยนเส้นทางการเดินเรือตามสถานการณ์ต่าง ๆ เช่นการก่อการร้ายแทบตะวันออกกลางซึ่งส่งให้เรือต้องเปลี่ยนเส้นทางการเดินเรือ หรือนโยบายภาษี

ดังนั้นสาเหตุจากแนวโน้มการเพิ่มขึ้นของความต้องการร่วมถึงปัจจัยต่าง ๆ ที่ส่งผลโดยตรงต่อการดำเนินธุรกิจของบริษัทผู้วิจัยเห็นว่าบริษัทจำเป็นต้องมีการพิจารณาในด้านอื่นมากขึ้น นอกจากกำลังการผลิตของเครื่องจักรเพื่อเพิ่มประสิทธิของการใช้ทรัพยากรของบริษัทที่มีอย่างจำกัดอีกทั้งต้องการนำเสนอความสำคัญของการคาดการณ์ความต้องการ ซึ่งเป็นขั้นตอนแรกในการนำมาพิจารณาถึงกลยุทธ์ของบริษัทเช่น นโยบายการจัดเก็บสินค้า การจัดความสำคัญของสินค้าสำเร็จรูปเทียบกับความต้องการของลูกค้าเพื่อเพิ่มประสิทธิภาพในการตอบสนองความต้องการของลูกค้าภายใต้ข้อจำกัดทั้งในเรื่องการวางแผนสั่งวัตถุดิบ พื้นที่จัดเก็บรวมถึง Stock service level ที่เหมาะสมของสินค้าสำเร็จรูปแต่ละรายการ

วัตถุประสงค์ของการวิจัย

ทำการศึกษาแบบจำลองวิธีการพยากรณ์ โดยสามารถเปรียบเทียบโมเดลระหว่างการพยากรณ์แบบเดิมและการพยากรณ์โดยการเรียนรู้เครื่อง เพื่อทำความเข้าใจลักษณะการพยากรณ์ทั้งสองรูปแบบกับข้อมูลที่ต้องการทำการพยากรณ์โดยสามารถเข้าใจแนวทางในการเลือกทำวิธีการพยากรณ์ต่าง ๆ ให้เหมาะสมกับลักษณะข้อมูลที่มีอยู่ในกรณีศึกษาและสามารถเสนอในการนำไปใช้ในบริษัทกรณีศึกษาได้

ขอบเขตของการวิจัย

การศึกษานี้ได้นำข้อมูลช่วงเดือนเมษายน 2564 ถึง มีนาคม 2567 ระยะเวลา 36 เดือน ซึ่งประกอบไปด้วยข้อมูลยอดขายของบริษัทกรณีศึกษาโดยผู้วิจัยได้ทำการเลือกสินค้าโดยคิดจากยอดขายสะสม 80% จากยอดขายสินค้าทั้งหมด 35 รายการโดยพิจารณาตามหลักการวิเคราะห์แบบ Pareto ซึ่งใช้เลือกกลุ่มของสินค้าที่มีผลต่อการดำเนินการโดยรวม

คาดหวังจากการวิจัย

สามารถนำเสนอการศึกษาการพยากรณ์ความต้องสินค้าการจากข้อมูลอุปสงค์จริงของบริษัทกรณีศึกษาเพื่อแสดงให้เห็นตัวอย่างของการดำเนินการพยากรณ์ที่อาจช่วยในการเพิ่มความแม่นยำของการพยากรณ์อย่างมีประสิทธิภาพมากขึ้น

ประโยชน์ที่คาดว่าจะได้รับ

- มีความเข้าใจถึงรูปแบบการพยากรณ์ที่มีความแม่นยำสอดคล้องกับสภาพแวดล้อมและข้อมูลที่มีอย่างปัจจุบันได้อย่างรวดเร็วและมีประสิทธิภาพมากขึ้น โดยบริษัทกรณีศึกษาสามารถนำข้อมูลเพื่อประกอบการตัดสินใจในกิจกรรมอื่นเช่นการจัดการระดับสินค้าคงคลัง และการกำหนด ระดับการให้บริการแก่ลูกค้าได้ดีมากขึ้น
- เป็นแนวทางให้บริษัทในอุตสาหกรรมเดียวกัน กลุ่มอุตสาหกรรมอื่น หรือผู้ที่มีความสนใจศึกษาในเรื่องของการพยากรณ์โดยการนำรูปแบบการพยากรณ์ด้วยการเรียนรู้ของเครื่องมาประยุกต์ใช้เพื่อเพิ่มประสิทธิภาพของการพยากรณ์ในธุรกิจ

นิยามศัพท์ที่เกี่ยวกับกับงานวิจัย

- การพยากรณ์ (Forecasting) การประมาณการปริมาณหรือสิ่งใดสิ่งหนึ่งที่น่าจะเกิดขึ้นในอนาคตซึ่งการพยากรณ์ที่ได้นั้นมักจะนำมาใช้ในประกอบการพิจารณาเพื่อการตัดสินใจต่าง ๆ เช่น ปริมาณการขายในอนาคต เป็นต้น
- รูปแบบการพยากรณ์ (Forecasting model) การกำหนดวิธีการการพยากรณ์ โดยนำข้อมูลไปออกแบบเพื่อการแก้ไขปัญหาและนำไปใช้พยากรณ์เหตุการณ์ในอนาคต
- การพยากรณ์เชิงคุณภาพ (Qualitative forecast) เป็นการพยากรณ์ถึงเหตุการณ์ที่จะเกิดขึ้นในอนาคตโดยไม่ใช้การแก้ไขทางคณิตศาสตร์ แต่อาจมีการนำข้อมูลในอดีตมาพิจารณาด้วยความคิดเห็นหรือประสบการณ์ของผู้เชี่ยวชาญ
- การพยากรณ์เชิงปริมาณ (Quantitative forecast) เป็นการพยากรณ์โดยใช้รูปแบบพื้นฐานทางคณิตศาสตร์ซึ่งนำข้อมูลที่เป็นตัวเลขจากอดีตเช่นปริมาณยอดขายหรือยอดการผลิตมาเป็นข้อมูลในการ พยากรณ์ถึงสถานการณ์ที่อาจจะเกิดขึ้นในอนาคต
- การวัดค่าความคลาดเคลื่อนของการพยากรณ์ (Measuring forecast errors) คือการประเมินผลค่าความคลาดเคลื่อนที่ได้จากการพยากรณ์ โดยพิจารณาค่าที่ได้ว่ามีความแตกต่างจากค่าจริงมากหรือน้อยเพียงใด
- การเรียนรู้ของเครื่อง (Machine learning) เป็นรูปแบบหนึ่งของปัญญาประดิษฐ์ที่ใช้ระบบคอมพิวเตอร์เรียนรู้และพัฒนาจากประสบการณ์โดยตรงไม่ต้องใช้การเขียนโปรแกรมอย่างชัดเจน เพียงแต่อาจจะกำหนดโครงสร้างแนวคิดหรืออัลกอลิทึมเป็นแนวทางในการประมวลผลของระบบคอมพิวเตอร์

บทที่ 2
ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้อง

การวิเคราะห์พาเรโต

การวิเคราะห์พาเรโต แผนภูมิพาเรโตถูกตั้งชื่อตามนักเศรษฐศาสตร์ชาวอิตาลี วิลเฟรโด พาเรโต ซึ่งในช่วงปลายศตวรรษที่ 19 ขณะทำการวิจัยเกี่ยวกับการกระจายความมั่งคั่ง ได้ข้อสรุปว่าส่วนใหญ่ของความมั่งคั่งอยู่ในมือของคนส่วนน้อยของประชากร จากการวิเคราะห์นี้ได้พัฒนากฎพาเรโตที่มีชื่อเสียงโดยบอกว่า 80% ของปัญหามาจาก 20% ของกระบวนการ บางครั้งรู้จักกันในชื่อกฎ 80/20 (Sallis, 2002) ซึ่งเป็นแนวคิดสำคัญโดยใช้ระบุปัญหาที่สำคัญโดยเปรียบเทียบด้วยสัดส่วน 80 ต่อ 20 ซึ่งหมายถึงการบรรลุผลสำเร็จในการแก้ปัญหาหรือเพิ่มประสิทธิภาพเพิ่มขึ้น 80% เพียงแค่การแก้ปัญหาหรือเลือกดำเนินการต่อส่วนที่สำคัญที่สุดเพียง 20%เท่านั้น โดยการแสดงผลของการวิเคราะห์อาจใช้แผนภาพเพื่อให้ง่ายต่อการจัดกลุ่มสิ่งที่เราสนใจเพื่อใช้ในการแก้ปัญหาได้เข้าใจง่ายและมีประสิทธิภาพมากขึ้นโดยทฤษฎีดังกล่าวได้ถูกนำมาพิจารณารายการสินค้าที่สำคัญที่ควรเลือกนำมาใช้ในการสร้างแบบพยากรณ์ซึ่งปรากฏว่าจากข้อมูล ผู้วิจัยได้นำข้อมูลยอดขายของทุกรายการมีทำการสร้างแผนภาพและเลือกรายการที่มีสัดส่วนของการขายคิดเป็น 80% ซึ่งเป็นสัดส่วนรายการสินค้า 20% จากรายการสินค้าทั้งหมดด้วย ซึ่งหลักการที่เลือกนั้นพิจารณาจากการเลือกสัดส่วนที่น่าจะมีผลกระทบในต่อการจัดการความต้องการสินค้าที่มีความจำเป็นมากที่สุดภายในการความจำกัดของทรัพยากร

ความหมายของการพยากรณ์

สภาพการแข่งขันในปัจจุบันการพยากรณ์นับว่าเป็นปัจจัยที่มีผลอย่างมากในการดำเนินธุรกิจและการวางแผนซึ่งมีความจำเป็นต้องใช้ข้อมูลในการประกอบการตัดสินใจซึ่งวัตถุประสงค์ของการพยากรณ์ก็มีเป้าหมาย เพื่อช่วยเป็นหลักในการวางแผนเพื่อตัดสินใจให้กับผู้ที่เกี่ยวข้อง ดังนั้นการพยากรณ์จึงเป็นวิธีการที่ถูกนำไปประยุกต์ใช้อย่างกว้างขวางในหลายภาคส่วน เช่น การนำไปประยุกต์ใช้ในการประมาณการความต้องการสินค้าในอนาคต การประมาณการสภาพภูมิอากาศ เป็นต้น

ในภาวการปัจจุบันการพยากรณ์นับว่ามีอิทธิพลอย่างมากต่อการดำเนินงานทางธุรกิจ เพราะการวางแผนทางธุรกิจทุกประเภทล้วนแล้วแต่ มีความจำเป็นที่จะต้องใช้ข้อมูลประกอบการ

ตัดสินใจดังนั้น ไม่ว่า จะเป็นการเลือกเทคนิคในการพยากรณ์ที่เหมาะสมกับลักษณะข้อมูลหรือจะเป็นผลจากการพยากรณ์ที่แม่นยำก็รวมแล้วแต่จะส่งผลต่อประสิทธิภาพของการบริหารธุรกิจ

การพยากรณ์ คือ การคาดการณ์ถึงสิ่งใดสิ่งหนึ่งที่จะเกิดขึ้นในช่วงเวลาในอนาคตและนำค่าพยากรณ์ที่ได้นั้นมาใช้ประโยชน์เพื่อการตัดสินใจใด ๆ โดยทั่วไปแล้วการพยากรณ์จะถูกจัดแบ่งตามหน้าที่หลักที่เกี่ยวข้องได้ดังนี้

ในด้านการตลาดซึ่งจำเป็นต้องอาศัยการพยากรณ์ที่เชื่อถือได้เพื่อการตัดสินใจเกี่ยวกับขนาดของตลาดและลักษณะของตลาด เช่น บริษัทที่ผลิตและขายอุปกรณ์เครื่องใช้ไฟฟ้าภายในบ้าน (เครื่องซักผ้า ทีวี ตู้เย็น) จะต้องสามารถพยากรณ์ความต้องการในอนาคตของผลิตภัณฑ์แต่ละชนิดในแต่ละภูมิภาค ตลอดจนประเภทของผู้ซื้อเพื่อวางแผนกการตลาดจะได้นำค่าพยากรณ์ดังกล่าวไปจัดทำแผนโฆษณาแผนการขายแผนการส่งเสริมการขายนอกจากนั้นแผนกขายสามารถนำค่าพยากรณ์ไปใช้เพื่อจุดประสงค์อื่น ๆ อีก เช่น หาส่วนแบ่งของตลาด แนวโน้มการขึ้นลงของราคา และการพัฒนาผลิตภัณฑ์ใหม่ ๆ

ในด้านการผลิต ค่าพยากรณ์ที่แสดงถึงจำนวนการขายของผลิตภัณฑ์ มีความจำเป็นอย่างยิ่งต่อการวางแผนเนื่องจากว่าบริษัทต้องนำมาใช้จัดทำเป็นตารางเวลาการผลิตและการควบคุมวัสดุคงคลังเพื่อตอบสนองต่อความต้องการของลูกค้าในราคาที่หมาะสม ดังนั้น สำหรับสภาวการณ์เช่นนี้ ผู้จัดการจะต้องรู้ค่าพยากรณ์ในแต่ละช่วงเวลาของสินค้าแต่ละชนิดเพื่อว่าเขาจะได้นำมาใช้ในการตัดสินใจได้อย่างถูกต้อง ส่วนด้านอื่น ๆ ที่เกี่ยวข้องกับหน้าที่การผลิตจำเป็นต้องรู้เรื่องต่าง ๆ เกี่ยวกับความต้องการวัสดุ แนวโน้มของราคาวัสดุ ค่าจ้างแรงงาน แนวโน้มของแหล่งวัตถุดิบและแรงงาน ความต้องการการซ่อมบำรุง และความสามารถในการผลิตของโรงงาน

ในด้านการเงินและการบัญชีจากค่าพยากรณ์ที่ได้ทำให้แผนกการเงินสามารถวางแผนการล่วงหน้าเกี่ยวกับการจัดสรรงบประมาณเงินลงทุนกำหนดรายรับและรายจ่ายในแต่ละช่วงเวลา เพื่อให้บริษัทดำรงอยู่ในสถานะสภาพคล่องและการดำเนินงานเป็นไปอย่างมีประสิทธิภาพแม้กระทั่งในแผนกบุคคล ยังต้องใช้ค่าพยากรณ์เพื่อการจัดเตรียมการไว้ล่วงหน้า เช่น การวางแผน แรงงานในแต่ละประเภท การจัดโปรแกรมการฝึกอบรมด้านต่าง ๆ
(ชุมพล ศฤงคารศิริ, 2565)

จากความหมายของพยากรณ์ในมุมมองของการดำเนินธุรกิจด้วยมีความสำคัญและสามารถนำไปใช้ได้กับหลายส่วนในบริษัทยกตัวอย่างเช่นฝ่ายบัญชี เป็นต้นโดยไม่จำเป็นต้องใช้กับฝ่ายการผลิตหรือฝ่ายโลจิสติกส์เสมอไป

ประเภทของการพยากรณ์

การพยากรณ์แบ่งออกเป็นประเภทใหญ่ ๆ ได้ 2 ประเภทคือ

การพยากรณ์เชิงปริมาณ (Quantitative Forecasting)

การพยากรณ์เชิงปริมาณเป็นเทคนิคที่อาศัยข้อมูลในอดีตเป็นหลัก สูตรหรือวิธีที่ได้กำหนดขึ้น โดยอาศัยหลักการทางคณิตศาสตร์หรือสถิติ มาช่วยการพยากรณ์สิ่งที่ต้องการในอนาคต เทคนิคที่จัดอยู่ใน ประเภทนี้และเป็นที่นิยมใช้กันอย่างกว้างขวาง ได้แก่วิธีการปรับเรียบ (Exponential smoothing) วิธีแยกส่วน (Decomposition) และวิธีวิเคราะห์การถดถอย (Regression analysis) การพยากรณ์เชิงปริมาณได้เป็นที่ยอมรับกันโดยทั่วไปทั้งนี้เนื่องจากเหตุผล 3 ประการคือ ประการแรกค่าพยากรณ์จะถูกปรับให้มีความถูกต้องมากที่สุดและบันทึกไว้เพื่อใช้ในการพยากรณ์ครั้งต่อไปซึ่งทำให้เกิดความมั่นใจในการตัดสินใจเพิ่มขึ้น ประการที่สองได้มีการนำคอมพิวเตอร์มาใช้ในการคำนวณค่าพยากรณ์ ซึ่งนับว่าเป็นปัจจัยที่สำคัญและมีประโยชน์มากเพราะสามารถทำได้จำนวนมากครั้งและรวดเร็ว นอกจากนั้นยังใช้บันทึกข้อมูลในอดีตได้เป็นจำนวนมากและสามารถป้อนกลับข้อมูลได้รวดเร็วเมื่อต้องการจะทำการพยากรณ์ครั้งใหม่ ประการที่สามการพยากรณ์โดยวิธีเชิงปริมาณโดยทั่ว ๆ ไปแล้วจะเสียค่าใช้จ่ายถูกกว่ามากเมื่อเปรียบเทียบกับวิธีการพยากรณ์แบบอื่น ๆ

การพยากรณ์เชิงคุณภาพ (Qualitative Forecasting)

การพยากรณ์เชิงคุณภาพเป็นการพยากรณ์ที่ไม่อาศัยข้อมูลในอดีตเป็นหลัก แต่จะใช้ความรู้สึกหรือสามัญสำนึกและจากประสบการณ์ต่าง ๆ ที่ผ่านมาประกอบกับข้อมูลซึ่งส่วนใหญ่จะได้จากผู้บริหารหรือผู้ที่มีหน้าที่เกี่ยวข้องเช่นฝ่ายขาย เป็นต้น เป้าหมายของการพยากรณ์ประเภทนี้ก็เพื่อที่จะพยากรณ์การเปลี่ยนแปลงในรูปแบบขั้นพื้นฐาน (Basic pattern) และรูปแบบของตัวมันเองทั้งนี้อาจจะมีผลมาจากปัจจัยภายนอกต่าง ๆ ดังตัวอย่างเช่น ผู้จัดการอาจจะมีความรู้สึกว่าผลิตภัณฑ์ชนิดหนึ่งของบริษัทมีแนวโน้มของความนิยมถึงขีดสุดยอดและครบวงจรชีวิตของมันแล้วการพยากรณ์ถึงจุดเปลี่ยนแปลงดังกล่าว (Turning point) นี้อาจจะเหมาะสมกับวิธีการพยากรณ์เชิงคุณภาพ

ตามปกติการพยากรณ์มักจะใช้ทั้งเชิงปริมาณและเชิงคุณภาพประกอบกัน กล่าวคือในช่วงแรก จะใช้ข้อมูลในอดีตหาค่าพยากรณ์ หลังจากนั้นจึงใช้แฟกเตอร์ที่น่าจะมีผลกระทบต่อค่าพยากรณ์ในช่วงเวลาใด ๆ เป็นตัวปรับรูปแบบชั้นพื้นฐานอีกครั้งหนึ่งนอกจากวิธีการพยากรณ์ซึ่งโดยทั่ว ๆ ไปจะมีการจัดแบ่งตามประเภทดังที่ได้กล่าวมาแล้วก็อาจจะใช้ลักษณะของช่วงเวลาในอนาคตเป็นตัวกำหนดวิธีการพยากรณ์โดยจะจำแนกออกได้เป็น 4 ประเภทดังจะได้กล่าวในหัวข้อต่อไปนี้

1. การพยากรณ์ 1 หน่วยเวลาล่วงหน้า (Immediate-Term Forecasting) เป็นการพยากรณ์ ที่มีช่วงเวลาน้อยกว่า 1 เดือนโดยทั่ว ๆ ไปจะเกี่ยวข้องกับกิจกรรมด้านปฏิบัติงานที่อยู่ในความรับผิดชอบของผู้บริหารระดับกลางและระดับต่ำเป้าหมายของการพยากรณ์จะมุ่งเพื่อการปรับปรุงวิธีการทำงานให้ดีขึ้นมากกว่าการเปลี่ยนแปลงวิธีการตัวอย่างการหายอดขายในแต่ละวันหรือสัปดาห์จะเป็นการตรวจสอบจากใบสั่งซื้อดังนั้นการพยากรณ์ประเภทนี้จึงเป็นการทำนายถึงสถานะที่เกี่ยวข้องซึ่งต้องมีรายละเอียดของข้อมูลมากกว่าวิธีอื่น

2. การพยากรณ์ช่วงสั้น (Short-Term Forecasting) เป็นการพยากรณ์ที่อยู่ระหว่างช่วง 1-3 เดือน โดยทั่ว ๆ ไปจะเป็นการพยากรณ์ถึงระดับอุปสงค์ของสินค้าประเภทแฟชั่น เช่น เสื้อผ้า กระเป๋า รองเท้า สตรี เป็นต้น

3. การพยากรณ์ช่วงกลาง (Medium-Term Forecasting) โดยปกติเป็นการพยากรณ์ที่อยู่ ระหว่าง 3 เดือน - 2 ปี จากค่าพยากรณ์ที่ได้จะนำมาใช้ทำแผนการผลิตหลัก ซึ่งเกี่ยวข้องกับการจัดหาทรัพยากร เช่น อุปกรณ์ เครื่องจักร กำลังคน และวัสดุเพื่อใช้ในการผลิต เทคนิคการพยากรณ์ที่นับว่ามีประโยชน์ สำหรับการพยากรณ์ช่วงกลางได้แก่ วิธีแยกส่วน และวิธีวิเคราะห์การถดถอย

4. การพยากรณ์ระยะยาว (Long-Term Forecasting) เป็นการพยากรณ์ตั้งแต่ 2 ปีขึ้นไปส่วน ใหญ่แล้วมักจะเกี่ยวข้องกับแผนกลยุทธ์ (Strategic planning)โดยจะกำหนดทิศทางและขนาดของการลงทุนในการขยายกิจการในช่วงระยะเวลาต่าง ๆ วิธีกการพยากรณ์ในระยะยาวที่พบเห็นมักจะเป็นแบบเชิงคุณภาพแต่ถ้าใช้ร่วมกับเชิงปริมาณแล้วก็น่าจะใช้ค่าพยากรณ์แต่ดีกว่ากล่าวคือเทคนิคเชิงปริมาณโดยทั่ว ๆ ไปจะแสดงถึงรูปแบบที่เป็นพื้นฐานและค่านอกช่วง (Extrapolation) สำหรับการพยากรณ์ในอนาคต ในขณะที่เทคนิคเชิงคุณภาพนั้นจะใช้วัดเพื่อหาความเบี่ยงเบนของการเปลี่ยนแปลงจากแนวทิศทางนั้น ๆ รูปแบบที่นิยมใช้กันในการพยากรณ์ระยะยาวได้แก่ อนุกรมเวลา (Time series) การวิเคราะห์ถดถอยการวิเคราะห์ปัจจัยนำเข้าและผลลัพธ์ (Input-output) และวิธีเชิงคุณภาพอื่น ๆ (ชุมพล ศฤงคารศิริ, 2565)

การพยากรณ์แบบอนุกรมเวลาแบบดั้งเดิม

การพยากรณ์ที่อยู่ในข้อสมมุติฐานว่ารูปแบบของข้อมูลในอดีตยังคงเกิดขึ้นต่อไปในอนาคตหรือลักษณะของการเปลี่ยนแปลงรูปแบบของข้อมูลหรือตัวแปรที่เราสนใจศึกษาจะประกอบไปด้วยพื้นฐานที่สำคัญ 4 ปัจจัย ได้แก่ ปัจจัยแนวโน้ม (Trend) อิทธิพลของฤดูกาล (Seasonal) อิทธิพลของวัฏจักร (Cycling) และเหตุการณ์ที่ผิดปกติ (Irregular) โดยการเลือกวิธีการพยากรณ์ที่เหมาะสมจึงขึ้นอยู่กับองค์ประกอบทั้ง 4 ส่วนนี้ (Chase, 2013)

การพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่ (Simple moving average method)

การหาค่าเฉลี่ยเคลื่อนที่ (Simple moving average method) เป็นวิธีอนุกรมทางคณิตศาสตร์ที่สามารถใช้ได้กับข้อมูลรูปแบบที่เป็นการพยากรณ์ที่มีแนวโน้มเพียงเล็กน้อยหรือไม่มีแนวโน้ม แต่มักใช้กับการพยากรณ์ที่มีแนวโน้มคงที่โดยใช้สมการดังต่อไปนี้

$$\mathrm{F_t} = \frac{\sum \textbf{Most recent n data value}}{\mathrm{n}}$$

โดยที่

$\mathrm{F_t} =$ ค่าพยากรณ์แบบ Moving averange สำหรับช่วง t

$\mathrm{n} =$ ช่วงของข้อมูลในพยากรณ์

โดยข้อดีของการพยากรณ์แบบหาค่าเคลื่อนที่เฉลี่ยนี้คือเข้าใจง่ายและก็มีการคำนวณไม่ซับซ้อนส่วนข้อเสียก็คือการตอบสนองการเปลี่ยนแปลงที่เช่าโดยสามารถทำนายได้เพียงจุดเดียวและน้ำหนักจะเท่ากันกับทุกค่าในช่วงที่พิจารณาเนื่องจากเป็นการเฉลี่ยจากค่าที่กำหนด

การพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่คู่ (Double moving average)

การพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่คู่ (Double moving average) คือการนำเอาข้อมูลค่าเฉลี่ยเคลื่อนที่มาเฉลี่ยเคลื่อนที่ต่อเนื่องจากข้อมูลชุดแรก ซึ่งจะใช้กับการพยากรณ์ข้อมูลอนุกรมเวลาที่มีแนวโน้มเชิงเส้นตรง โดยมีขั้นตอนและสมการที่ใช้ในการคำนวณดังนี้

คำนวณหาค่าเฉลี่ยเคลื่อนที่ (Mt)

$$M_t = (Y_t + Y_{t-1} + \ldots + Y_{t-k+1})/k$$

คำนวณค่าเฉลี่ยเคลื่อนที่ในระดับที่ 2 (Double moving average: D_t)

$$D_t = (M_t + M_{t-1} + \ldots + M_{t-k+1})/k$$

คำนวณผลต่างของค่าเฉลี่ยเคลื่อนที่ทั้งสองระดับ (E_t)

$$E_t = 2M_t - D_t$$

คำนวณความลาดชัน (Slope) ของอนุกรมเวลา (T_t)

$$T_t = 2(M_t - D_t)/(k-1)$$

สมการที่ใช้ในการพยากรณ์ข้อมูลในช่วงเวลา t

$$F_{t+n} = E_t + nT_t$$

โดยที่

M_t = ค่าเฉลี่ยเคลื่อนที่

D_t = ค่าเฉลี่ยเคลื่อนที่ระดับที่ 2

E_t = ค่าการประมาณระดับ

T_t = ค่าการประมาณแนวโน้ม t

k = จำนวนข้อมูลที่ใช้ในการเฉลี่ยเคลื่อนที่

F_{t+n} = ค่าพยากรณ์ในช่วงเวลาถัดไป

n = ช่วงของข้อมูลในการพยากรณ์

การพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่คู่นี้จะเหมาะสำหรับการพยากรณ์กับข้อมูลที่มีแนวโน้มเชิงเส้นได้ดีและช่วยลดค่าความผิดปกติและสามารถพยากรณ์ได้หลายช่วงเวลาแต่ข้อเสียคือยังคงตอบสนองช้าต่อการเปลี่ยนแปลงฉับพลันของจำนวนข้อมูล ที่ใช้ในการคำนวณนั้นก็มีผลมากดังนั้นจึงต้องอาศัยจำนวนข้อมูลที่มีมาก

การพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว

(Single Exponential Smoothing Method, SES)

เป็นเทคนิคการพยากรณ์ที่ได้รับความนิยมมากอีกวิธีหนึ่งเนื่องจากใช้ข้อมูลน้อยคือใช้เพียง ค่าของข้อมูลค่าพยากรณ์ก่อนหน้าค่าความต้องการในปัจจุบันและค่าปัจจัยถ่วงน้ำหนักปรับเรียบการพยากรณ์แบบปรับเรียบเอ็กซ์โพเนนเชียล

$$F_t = \propto Y_t + (1-\propto)F_t$$

โดยที่

F_{t+1} = ค่าพยากรณ์ในช่วงเวลาต่อไป

Y_t = ค่าความต้องการจริงในช่วงเวลาปัจจุบัน

F_t = ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

$\propto$ = ค่าถ่วงน้ำหนักปรับเรียบ

การพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียวนี้เหมาะสมกับอนุกรมเวลาที่มีความผิดปกติและไม่มีแนวโน้มหรือฤดูกาลในข้อมูลข้อดีก็คือการให้น้ำหนักกับข้อมูลล่าสุดและดูแค่ค่าพยากรณ์ครั้งก่อนหน้าเท่านั้น

การพยากรณ์แบบวิธีปรับเรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double Exponential Smoothing Method, DES)

การปรับเรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double Exponential Smoothing) การพยากรณ์โดยวิธีนี้จะใช้หลักการคำนวณหาค่าพยากรณ์เหมือนกับวิธีหาค่าเฉลี่ยเคลื่อนที่ซ้ำสองครั้ง และเป็นที่นิยมใช้กันมากกว่าทั้งนี้พราะต้องการจำนวนข้อมูลน้อยมากคือเพียง 3 ค่า นอกจากนั้นยังสามารถแก้ไขข้อจำกัดต่าง ๆ ที่เกิดขึ้นกับวิธีหาค่าเฉลี่ยเคลื่อนที่ดังที่ได้กล่าวมาแล้วการพยากรณ์โดยวิธีเอ็กซ์โปเนนเชียลซ้ำสองครั้ง จะช่วยปรับค่าพยากรณ์ให้ขึ้นหรือลงเป็นไปตามแนวทิศทางซึ่งมีขั้นตอนในการค้านวณดังสรุปเป็นสูตรได้ดังนี้
(ชุมพล ศฤงคารศิริ, 2565)

$$S'_t = \propto X_t + (1-\propto) S'_{t-1}$$

$$S''_t = \propto X_t + (1-\propto) S''_{t-1}$$

$$b = \frac{\propto}{1-\propto} (S'_t - S''_t)$$

$$a = a + b.m$$

เมื่อ $\propto$ = ค่า (คงที่) ปรับเรียบเอ็กโปเนนเชียล

m = จำนวนช่วงเวลาล่วงหน้าที่ต้องการพยากรณ์

การปรับเรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง เหมาะกับการจัดการข้อมูลที่เป็นแนวโน้มและมีความผิดปกติได้ดีรวมถึงสามารถพยากรณ์ได้หลายช่วงเวลาและปรับตัวได้รวดเร็วกว่าการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียวแต่ยังต้องอาศัยการปรับค่าพารามิเตอร์ α และ β ให้เหมาะสม

การพยากรณ์แบบ Autoregressive Integrated Moving Average (ARIMA)

Autoregressive Integrated Moving Average เป็นแบบพยากรณ์ในทางสถิติที่ใช้ในการวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลา (Time series data) โดยจะใช้ข้อมูลในอดีตในการทำนายค่าของข้อมูลในอนาคตแบบจำลองนี้ประกอบด้วยสามส่วนหลักได้แก่

- Autoregressive (AR): ส่วนนี้หมายถึงการใช้ค่าของตัวแปรในอดีตเพื่อ ทำนายค่าของตัวแปรในอนาคต

- Integrated (I): ส่วนนี้หมายถึงการทำให้ข้อมูลเป็นสถานี (Stationary) โดยการหาความแตกต่างระหว่างค่าของข้อมูลในแต่ละช่วงเวลาMoving Average (MA): ส่วนนี้หมายถึงการใช้ค่าเฉลี่ยเคลื่อนที่ของข้อผิดพลาดในการทำนายเพื่อปรับปรุงความแม่นยำของการพยากรณ์

วิธีการทำงานของ ARIMAสามารถแบ่งออกเป็นขั้นตอนหลัก ๆ โดยการระบุค่าพารามิเตอร์ของ ARIMA ได้แก่ p, d, และ q โดย

(p) คือจำนวนของการถดถอยเชิงเส้น (Autoregressive terms)

(d) คือจำนวนครั้งที่ต้องทำการหาความแตกต่างเพื่อทำให้ข้อมูลเป็นสถานี

(q) คือจำนวนของค่าเฉลี่ยเคลื่อนที่ (Moving average terms)

การประมาณค่า (Parameter estimation)ใช้วิธีการทางสถิติเพื่อประมาณค่าพารามิเตอร์ของโมเดล ARIMA การตรวจสอบโมเดล (Model checking)ตรวจสอบว่าโมเดลที่สร้างขึ้นมีความเหมาะสมกับข้อมูลหรือไม่ โดยใช้การวิเคราะห์ข้อผิดพลาดและการทดสอบทางสถิติการพยากรณ์ (Forecasting) ใช้โมเดล ARIMA ที่สร้างขึ้นในการทำนายค่าของข้อมูลในอนาคต รูปแบบการพยากรณ์สามารถจัดการข้อมูลที่เป็นแนวโน้มได้ผ่านการหาผลต่างรวมถึงจัดการข้อมูลที่มีความผิดปกติในบางช่วงเวลา และจัดการข้อมูลที่เป็นวัฏจักรและบางส่วนผ่าน Autoregressive

การพยากรณ์โดยการเรียนรู้ของเครื่อง

เป็นการสร้างรูปแบบการประมวลผลเพื่อคำนวณโดยตั้งเงื่อนไขในการตัดสินใจซึ่งผู้พัฒนาจะนำชุดข้อมูลที่เป็นทั้งส่วนของข้อมูลดิบและผลลัพธ์เข้าไปในคอมพิวเตอร์เพื่อสร้างการเรียนรู้และรูปแบบชุดการพยากรณ์ความคิดหลักของโปรแกรมและผู้พัฒนาสามารถกำหนดข้อจำกัดเพิ่มเติมได้ถือเป็นการสอนเพื่อให้โปรแกรมเรียนรู้และแยกแยะข้อมูลของตัวแบบขั้นต้นก่อน จากนั้นจึงนำข้อมูลอีกชุดมาทดสอบ เพื่อได้มาซึ่งการวัดค่าความคลาดเคลื่อนว่าสามารถยอมรับได้หรือไม่ จากนั้นนำข้อมูลอีกส่วนที่ไม่ได้ทำการฝึกฝน มาทำการทดสอบเพื่อลดค่าความคลาดเคลื่อนการพยากรณ์โดยการเรียนรู้ของเครื่องเป็นกระบวนการที่ใช้เทคนิคและอัลกอริทึมในการวิเคราะห์ข้อมูลในอดีตเพื่อทำการคาดการณ์ผลลัพธ์ที่อาจจะเกิดขึ้นเหตุการณ์ในอนาคตและสามารถนำไปใช้ประโยชน์ได้ในหลาย ๆ ด้าน เช่น การพยากรณ์ยอดขาย การพยากรณ์ความต้องการสินค้า หรือการพยากรณ์ตลาดหุ้นเพื่อการลงทุน

หลักการทำงานของการเรียนรู้ของเครื่องในการทำการพยากรณ์

■ การเก็บรวบรวมข้อมูลที่เกี่ยวข้องจะถูกเก็บรวบรวม เช่น ข้อมูลยอดขาย ข้อมูลสภาพอากาศ หรือข้อมูลการตลาด เป็นต้น

■ การเตรียมข้อมูลโดยเก็บรวบรวมและเตรียมพร้อมสำหรับการวิเคราะห์ รวมถึงการทำความสะอาดข้อมูลเพื่อลดค่าความคลาดเคลื่อนที่ไม่จำเป็น เช่น ข้อมูลที่ขาดหายหรือผิดพลาดในการบันทึก

■ การสร้างโมเดลโดยใช้อัลกอริทึมเลือกอัลกอลิทึมที่เหมาะสมกับปัญหาการพยากรณ์ยกตัวอย่างเช่น

- Linear regression ที่ใช้สำหรับการพยากรณ์ข้อมูลที่มีค่าต่อเนื่องในการวิเคราะห์
- ข้อมูลอนุกรมเวลาสำหรับข้อมูลที่มีความสัมพันธ์กับช่วงเวลา
- Neural network (LSTM, RNN) สำหรับการพยากรณ์ที่มีความซับซ้อน

■ การทดสอบและปรับปรุงโมเดล โดยการทำการนำข้อมูลที่มีแบ่งส่วนในการทำการทดสอบโมเดล ตรวจสอบและปรับปรุงโมเดลให้มีความแม่นยำมากขึ้น

■ การนำโมเดลที่พัฒนาแล้วไปใช้ โดยนำโมเดลที่ผ่านฝึกฝนและทดสอบไปใช้ในการพยากรณ์เหตุการณ์ในอนาคต เช่น การพยากรณ์ยอดขายหรือการพยากรณ์ความต้องการสินค้า

ประโยชน์ของการพยากรณ์ด้วยการเรียนรู้ของเครื่อง

■ การเรียนรู้จากข้อมูลทางสถิติจำเป็นที่จะต้องใช้สมการทางคณิตศาสตร์กำหนดไว้ล่วงหน้าโดย Machine learning จะเรียนรู้ความสัมพันธ์จากข้อมูลได้โดยตรง

■ สามารถปรับตัวเข้ากับรูปแบบข้อมูลที่เปลี่ยนแปลงได้โดยอัตโนมัติไม่ได้รับข้อมูลใหม่ได้รวดเร็วขึ้น

โดยภาพรวมนั้นประโยชน์ของการเรียนรู้เครื่องในการทำ Forecasting สามารถวิเคราะห์ข้อมูลที่มีจำนวนมากและมีความซับซ้อนได้ ทำให้การพยากรณ์มีความแม่นยำมากขึ้นเมื่อเทียบกับวิธีการแบบดั้งเดิมซึ่งสามารถปรับตัวและเรียนรู้จากข้อมูลใหม่ ๆ ได้อย่างต่อเนื่องทำให้การพยากรณ์มีความทันสมัยและสอดคล้องกับสถานการณ์ปัจจุบันการระบุรูปแบบการพยากรณ์ด้วยการเรียนรู้เครื่องสามารถระบุรูปแบบและแนวโน้มในข้อมูลได้โดยอัตโนมัติซึ่งช่วยให้การพยากรณ์มีความละเอียดและครอบคลุมมากขึ้นสามารถจัดการและวิเคราะห์ข้อมูลขนาดใหญ่ได้อย่างมีประสิทธิภาพ

โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) เป็นการใช้เรียนรู้โดยนำหลักการจากการจำลองการทำงานของเซลล์ประสาท (Neuron) โดยแต่ละเซลล์จะทำการสื่อสารกันผ่านการกระตุ้นด้วยศักย์ไฟฟ้า ซึ่งกระแสประสาทเริ่มต้นส่งสัญญาณจากตัวเซลล์ (Cell body) ผ่านแกนประสาท (Axon) ไปยังจุดเส้นประสาท(Synapse) ซึ่งการสื่อสารเชื่อมต่อกับเซลล์ประสาทอื่นผ่านไยประสาทนำเข้า (Dendrite) ซึ่งนำไปสู่การประยุกต์การใช้โครงข่ายประสาทเทียมกับการจำลองทางคณิตศาสตร์ ซึ่งโครงข่ายประสาทเทียสามารถเรียนรู้ได้ 2 ประเภท ทั้ง การเรียนรู้แบบมีผู้สอน (Supervised learning) และ การเรียนรู้แบบไม่มีการสอน (Unsupervised learning) ซึ่งแบบจำลองเซลล์ประสาทเทียม จะเป็นใช้การจำลองที่แสดงการเชื่อมระหว่างเซลล์ประสาท (Neuron) กับปม (Node) และการเชื่อมต่อด้วยเส้นเชื่อม (Edge) ที่กำกับด้วยค่าน้ำหนัก(Weight) ซึ่งจะแทนความสัมพันธ์ของข้อมูลนำเข้าแต่ละตัว เมื่อข้อมูลถูกนำพาไปที่ตัวเซลล์จะได้ผลรวมน้ำหนักและจากนั้นจะถูกนำไปวิเคราะห์ด้วยการกระตุ้น Step function เมื่อวิเคราะห์แล้วจึงได้ผลลัพธ์จากการประมวณผล(Output)ออกมา

นิวรัลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network, RNN) เป็นโมเดลการเรียนรู้ที่ได้รับการฝึกฝนเพื่อประมวลผลและแปลงข้อมูลอินพุตเป็นเอาต์พุตข้อมูลตามลำดับเฉพาะ ข้อมูลตามลำดับ คือข้อมูล เช่น คำ ประโยค หรือข้อมูลแบบอนุกรมเวลา ซึ่งส่วนประกอบตามลำดับจะสัมพันธ์กันตามความหมายที่ซับซ้อนและกฎไวยากรณ์ RNN เป็นระบบซอฟต์แวร์ที่ประกอบด้วยส่วนประกอบที่เชื่อมต่อกันมากมายที่เลียนแบบวิธีที่มนุษย์แปลงข้อมูลตามลำดับ เช่น การแปลข้อความจากภาษาหนึ่งเป็นอีกภาษาหนึ่ง RNN ส่วนใหญ่ถูกแทนที่ด้วยปัญญาประดิษฐ์ (AI) และโมเดลภาษาขนาดใหญ่ (LLM) ซึ่งมีประสิทธิภาพในการประมวลผลข้อมูลมากขึ้นตามลำดับ โดย RNN มีความสามารถในการจดจำข้อมูลจากขั้นตอนก่อนหน้าและใช้ข้อมูลนั้นในการคาดการณ์ขั้นตอนถัดไป ทำให้เหมาะสำหรับงานที่ต้องการการจดจำลำดับ เช่น การแปลภาษา การรู้จำเสียงพูด และการสร้างข้อความ

Long Short-Term Memory (LSTM) เป็นประเภทหนึ่งของสถาปัตยกรรมแบบ Recurrent neural network (RNN) ที่ออกแบบมาเพื่อแก้ปัญหา Long-term dependency LSTM มีความสามารถในการจดจำข้อมูลในระยะยาวได้ดีโดยใช้กลไกการเปิด-ปิด (Gating Mechanisms) ที่ช่วยควบคุมการไหลของข้อมูลเข้าและออกจากเซลล์หน่วยความจำ LSTM เหมาะสำหรับงานที่ต้องการการประมวลผลข้อมูลตามลำดับ เช่น การทำนายอนุกรมเวลา (Time-series prediction) การแปลภาษา (Language translation) และการรู้จำเสียงพูด

การสร้างแบบจำลองการพยากรณ์ด้วย Python และการปรับHyperparameter

วิธีการสร้างแบบพยากรณ์ที่มีความเหมาะสมนั้น การกำหนดค่าพารามิเตอร์ถือเป็นส่วนสำคัญที่ส่งผลต่อความแม่นยำของแบบพยากรณ์ โดยสามารถดำเนินการตรวจสอบโมเดลและพารามิเตอร์ว่ามีความเหมาะสมหรือไม่ด้วยวิธีการต่าง ๆ ดังนี้

- การแบ่งข้อมูลเพื่อทำการฝึกชุดข้อมูลที่เป็นชุดข้อมูลสร้างแบบพยากรณ์และ ชุดข้อมูลที่ตัวแบบพยากรณ์ยังไม่เคยนำมาใช้เพื่อทำการทดสอบตัวแบบการพยากรณ์เพื่อชี้วัดความแม่นยำของการพยากรณ์ ซึ่งถือเป็นรูปแบบการดำเนินการเพื่อการวัดประสิทธิภาพของการพยากรณ์โดยผู้วิจัยได้ทำการแบ่งข้อมูลออกเป็น 2 ส่วนเพื่อดำเนินการในการพยากรณ์ ARIMA และแบบการเรียนรู้ของเครื่อง

- การวิเคราะห์ข้อมูลอนุกรมเวลาสามารถดำเนินการได้โดยใช้เทคนิคที่มีประสิทธิภาพหลากหลาย ผ่านภาษาการเขียนโปรแกรม เช่น Python, R และอื่น ๆ ผู้ใช้งานสามารถทำความเข้าใจข้อมูลได้โดยการสำรวจและตรวจสอบข้อมูลทางสถิติ เช่น ค่ากลาง หรือสามารถนำเทคนิคการเรียนรู้ของเครื่อง (Machine learning) และการเรียนรู้เชิงลึก (Deep learning) มาใช้เพื่อค้นหาข้อมูลเชิงลึกที่ซ่อนอยู่ หรือเพื่อการพยากรณ์และคาดการณ์อนาคตข้อมูลอนุกรมเวลา (Time series) เป็นข้อมูลที่มีความสำคัญอย่างยิ่งในการทำความเข้าใจการเปลี่ยนแปลงของข้อมูลตามช่วงเวลา โดยการวิเคราะห์ข้อมูลประเภทนี้สามารถดำเนินการได้อย่างมีประสิทธิภาพด้วยเครื่องมือที่มีอยู่ในภาษา Python ซึ่งมีไลบรารีที่ได้รับความนิยมหลายตัวที่รองรับการจัดการและวิเคราะห์ข้อมูลอนุกรมเวลาโดยเฉพาะ (Aloorravi, 2024)

- การปรับค่า Hyperparameter เป็นกระบวนการสำคัญในการเพิ่มประสิทธิภาพของแบบจำลองการพยากรณ์ โดยหนึ่งในวิธีที่นิยมใช้คือ Grid search ซึ่งเป็นเทคนิคที่ทำการทดลองค่าของ Hyperparameter ทุกค่าที่อยู่ในช่วงที่กำหนด (Grid) อย่างเป็นระบบ โดยกระบวนการนี้จะสร้างตารางที่ประกอบด้วยชุดค่าพารามิเตอร์ที่ต้องการทดสอบ และนำแต่ละชุดค่าดังกล่าวไปประเมินผลผ่านแบบจำลองตามเกณฑ์ที่กำหนด เช่น ค่าความแม่นยำของแบบจำลอง หรือค่าความคลาดเคลื่อนระหว่างค่าที่พยากรณ์กับค่าจริง การประเมินผลในแต่ละชุดค่าพารามิเตอร์จะช่วยให้สามารถเลือกค่าที่ให้ผลลัพธ์ดีที่สุดได้อย่างมีประสิทธิภาพ ซึ่งเป็นแนวทางที่ได้รับการยอมรับในงานวิจัยและการประยุกต์ใช้ด้านการเรียนรู้ของเครื่อง (VanderPlas, 2016)

การวัดค่าความแม่นยำของตัวแบบพยากรณ์

ค่าเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error, MAE) เป็นเทคนิคที่วัดความแม่นยำโดยแก้ปัญหาเทคนิคค่าเฉลี่ยความผิดพลาดโดยใช้การพิจารณาความแตกต่างของยอดพยากรณ์ยกกำลังสอง

ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error, MSE) เป็นวิธีวัดความแม่นยำโดยแก้ปัญหาวิธีค่าเฉลี่ยความผิดพลาด โดยพิจารณาระหว่างความแตกต่างยอดจริงกับยอดพยากรณ์ด้วยวิธียกกำลังสอง

ค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error, MAPE) เป็นเทคนิคที่วัดค่าความแม่นยำโดยคำนวณจากเปอร์เซ็นต์ของความผิดพลาดในการพยากรณ์ โดยไม่คำนึงถึงเครื่องหมาย ค่าที่ได้ต่ำ แสดงว่าเทคนิคนั้นมีความแม่นยำ

ค่าความคลาดเคลื่อนสัมบูรณ์และค่าเฉลี่ยความผิดพลาดกำลังสองนั้นใช้แสดงผลเพื่อการดูเปรียบเทียบลักษณะของข้อมูลเพื่อประเมินประสิทธิภาพของแบบประเมินของแต่ละรายการและประเมินรูปแบบการตั้งค่าการพยากรณ์ในแต่ละวิธีส่วน MAPE เนื่องจากเป็นค่าที่สามารถอ่านเข้าใจได้ง่ายเหมาะสมกับการประเมินในเชิงการดำเนินการด้านธุรกิจซึ่งหลังจากการทดลองผู้วิจัยจะนำ MAPE เป็นเครื่องมือในการประเมินประสิทธิภาพในแต่ละวิธีการพยากรณ์สำหรับการวิจัยนี้

งานวิจัยที่เกี่ยวข้อง

งานวิจัยภายในประเทศ

ชยากร อุปกรณ์ (2564) งานวิจัยนี้ได้ทำการนำเสนอและเปรียบเทียบตัวแบบเพื่อใช้สำหรับการพยากรณ์ยอดขายรายวันของผลิตภัณฑ์ที่ขายดีที่สุดจาก 7 กลุ่มผลิตภัณฑ์ที่มียอดขายสูงสุดได้แก่ นม นมผง ซอส ผงซักฟอก ผ้าอ้อม น้ำอัดลม และน้ำมันจากบริษัทกรณีศึกษา โดยเปรียบเทียบผลการพยากรณ์ตัวแบบอนุกรมเวลา ตัวแบบการถดถอยเชิงพหุคูณ ตัวแบบการเรียนรู้ของเครื่อง และตัวแบบผสม โดยพิจารณาการพยากรณ์ 4 รูปแบบการพยากรณ์ยอดขายโดยตรงกับตัวแปรอิสระปกติ การพยากรณ์ลอการิทึมธรรมชาติของยอดขายกับตัวแปรอิสระที่เพิ่มข้อมูลยอดขายตัวเองในอดีต การพยากรณ์ลอการิทึมธรรมชาติของยอดขายกับตัวแปรอิสระ และการพยากรณ์ยอดขายโดยตรงกับตัวแปรอิสระที่เพิ่มข้อมูลยอดขายตัวเองในอดีต ความแม่นยำของตัวแบบการพยากรณ์ถูกเปรียบเทียบด้วยเปอร์เซ็นต์ค่าเฉลี่ยเคลื่อนที่สมบูรณ์(MAPE) โดยตัวแบบที่ศึกษาในงานวิจัยนี้ได้แก่ TBATS, Multiple linear regression (MLR), XGBoost, Artificial

Neural Network (ANN) และตัวแบบผสม โดยผลการศึกษาพบว่าตัวแบบ ANN ให้ผล MAPE ต่ำสุดที่ 16.04% หากแยกเป็นกลุ่มรูปแบบข้อมูลพบว่ากลุ่มที่มีฤดูกาลและแนวโน้ม และกลุ่มไม่มีฤดูกาลและไม่มีแนวโน้มนั้น ตัวแบบ ANN ได้ผลดีที่สุด ส่วนกลุ่มที่มีฤดูกาลแต่ไม่มีแนวโน้มพบว่าตัวแบบผสม (Hybrid model) ได้ผลดีที่สุด

ภมร สถิรมนวงศ์ (2564) งานวิจัยนี้ทำการศึกษาปรับปรุงการพยากรณ์ความต้องการสินค้าสำเร็จรูป และการพัฒนาระบบเติมเต็มสินค้าคงคลังของพัสดุบรรจุของโรงงานผลิตเครื่องดื่มแอลกอฮอล์แห่งหนึ่ง เนื่องจากผู้วิจัยมองว่าการพยากรณ์ที่ไม่แม่นยำเพียงพอนั้นจะส่งผลต่อการวางแผนการผลิตที่คลาดเคลื่อน และการจัดเก็บพัสดุบรรจุที่สูงเกินจริงผู้วิจัยจึงเตรียมตัวแบบการพยากรณ์ Naïve, Simple Moving average, Single exponential smoothing, ARIMA Moving average, Double exponential smoothing, ARIMA และ Triple exponential smoothing (Holt-Winter's) และวัดความแม่นยาของการพยากรณ์ 3 รูปแบบได้แก่ Mean Absolute Error (MAE) Mean Square Error (MSE) และ Mean absolute percentage error (MAPE) ทั้งนี้ผู้วิจัยพบว่ามูลค่าพัสดุคงคลังเฉลี่ยต่อเดือนของบริษัทกรณีศึกษามีค่าสูงถึงกว่า 92.3 ล้านบาท แต่อัตราการหมุนเวียนของพัสดุบรรจุเฉลี่ยมีค่าค่อนข้างต่ำที่ 3.05 รอบต่อปีเท่านั้น นอกจากนี้บริษัทกรณีศึกษา ยังไม่มีนโยบายการควบคุมปริมาณสินค้าคงคลังของพัสดุบรรจุอย่างเป็นระบบผู้วิจัยจึงได้นำเสนอการปรับปรุงและพัฒนา โดยสามารถแบ่งออกได้เป็น 2 ส่วน คือ การพยากรณ์ความต้องการสินค้าที่มีความแม่นยำ และการควบคุมระดับสินค้าคงคลังของพัสดุบรรจุให้มีความสอดคล้องกับพัสดุบรรจุแต่ละประเภท โดยผู้วิจัยเริ่มจากการจำแนกผลิตภัณฑ์ออกเป็นกลุ่มตามลำดับความสำคัญแบบ ABC (ABC pareto analysis) จากนั้นนำกลุ่มผลิตภัณฑ์สำเร็จรูปที่สำคัญไปศึกษาต่อด้วยการพยากรณ์ และทำการวัดความแม่นยำของการพยากรณ์แบบต่าง ๆ ซึ่งผู้วิจัยพบว่าวิธีการพยากรณ์แบบดั้งเดิมมีความแม่นยำสูงที่สุดสำหรับผลิตภัณฑ์ B285700 และ B2851000 ในขณะที่วิธี ARIMA นั้นมีความแม่นยำสูงที่สุด และมีค่าสูงกว่าการพยากรณ์แบบดั้งเดิม สำหรับผลิตภัณฑ์ B285345 ในส่วนของการพัฒนาระบบเติมเต็มสินค้าคงคลังของพัสดุบรรจุ จะจำแนกพัสดุบรรจุออกเป็นกลุ่มตามลำดับความสำคัญแบบ ABC และเสนอให้เลือกใช้นโยบายทบทวนการสั่งซื้ออย่างต่อเนื่อง (Continuous review policy) สำหรับพัสดุบรรจุที่สำคัญ (กลุ่ม A) และนโยบายทบทวนการสั่งซื้อตามช่วงเวลา (Periodic review policy) สำหรับพัสดุบรรจุที่สำคัญรองลงมา (กลุ่ม B และ C) ด้วยรอบระยะเวลาการทบทวนที่แตกต่างกัน การประยุกต์ใช้ระบบเติมเต็มพัสดุคงคลังที่นำเสนอสามารถลดมูลค่าการจัดเก็บพัสดุบรรจุคงคลังเฉลี่ยของกลุ่มผลิตภัณฑ์ B285 ในช่วงเวลาที่ทำการจำลองสถานการณ์ (เดือนธันวาคม พ.ศ. 2563 ถึง

พฤษภาคม พ.ศ. 2564) ลงได้ 6.61 ล้านบาท หรือ 16.54% ตลอดจนสามารถเพิ่มอัตราการหมุนเวียนพัสดุคงคลังขึ้น จากเดิม 3.40 เป็น 4.07 หรือเพิ่มขึ้น 0.67 หน่วย

อุรชา จันทรภา (2564) งานวิจัยได้ทำการศึกษาตัวแบบพยากรณ์ที่เหมาะสมสำหรับพยากรณ์มูลค่าการส่งออกรถยนต์ อุปกรณ์และส่วนประกอบโดยรวมของประเทศไทย และมูลค่าการส่งออกรถยนต์ อุปกรณ์และส่วนประกอบไปประเทศคู่ค้าที่มีมูลค่าการส่งออกจากประเทศไทยมากที่สุด 2 อันดับแรก ได้แก่ ประเทศออสเตรเลียและประเทศญี่ปุ่นด้วยวิธีอนุกรมเวลา วิธีการวิเคราะห์การถดถอยเชิงเส้นพหุคูณ วิธีการเรียนรู้ของเครื่อง และวิธีพยากรณ์แบบผสม โดยใช้ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) ในการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ ข้อมูลที่ใช้ในการศึกษาวิธีการพยากรณ์ของงานวิจัยนี้เป็นข้อมูลรายเดือนตั้งแต่เดือนมกราคม พ.ศ. 2551 ถึงเดือนธันวาคม พ.ศ. 2563 เป็นจำนวนทั้งหมด 156 เดือน วิธีที่ใช้ในการพยากรณ์ ได้แก่ Moving Average, Holt-Winters, SARIMA, Multiple Linear Regression, Artificial Neural Networks, Support Vector Regression, XGBoost, LSTM และวิธีพยากรณ์แบบผสม ผลการศึกษาพบว่า ตัวแบบพยากรณ์ที่มีความแม่นยำและเหมาะสมมากที่สุดสำหรับพยากรณ์มูลค่าการส่งออกรถยนต์ อุปกรณ์และส่วนประกอบโดยรวมของประเทศไทย มูลค่าการส่งออกรถยนต์ อุปกรณ์และส่วนประกอบของประเทศไทยไปประเทศออสเตรเลียและประเทศญี่ปุ่น ได้แก่ ตัวแบบพยากรณ์ผสมวิธี LSTM-XGB วิธี SARIMA-XGB และวิธี LSTM-SARIMA มีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเท่ากับ 6.63% 15.40% และ 6.27% ตามลำดับ

พัชรี สุขแก้ว (2565) ได้ทำการศึกษาเทคนิคการพยากรณ์ในการวางแผนความต้องการสั่งซื้อวัตถุดิบล่วงหน้าเพื่อหาปริมาณการสั่งซื้อที่เหมาะสมในการวางแผนความต้องการสั่งซื้อวัตถุดิบของบริษัทชิ้นส่วนรถยนต์แห่งหนึ่งซึ่งโดยใช้ข้อมูลตัวเลขการสั่งซื้อวัตถุดิบย้อนหลังตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึง เดือนมิถุนายน พ.ศ. 2564 รวมจำนวน 18 เดือนเพื่อเป็นการพยากรณ์ความต้องการของการสั่งซื้อวัตถุดิบล่วงหน้าโดยใช้การพยากรณ์แบบวิธีอนุกรมเวลาและข้อมูลวัตถุดิบในการสั่งซื้อจำแนกเป็น 6 ประเภทรวม 101 ชนิดซึ่งการทำวิจัยในครั้งนี้ผู้วิจัยเลือกประเภทกลุ่มวัตถุดิบ 1 กลุ่มที่มีความสำคัญและจำเป็นต่อการผลิตยางรถยนต์ที่มีปริมาณการใช้ที่สูงใช้เทคนิคการพยากรณ์แบบอนุกรมเวลา ทั้งหมด 4 วิธีคือ 1) วิธีหาค่าเฉลี่ยเคลื่อนที่ 2) วิธีหาค่าเฉลี่ยเคลื่อนที่แบบถ่วงน่าหนัก 3) วิธีปรับเรียบเอ็กซ์โพเนนเชียล 4)วิธีเอ็กซ์โพเนนเชียลแบบวินเทอร์ โดยทำการเลือกกลุ่มตัวอย่างแบบเจาะจง (Purposive sampling) ที่มีความสำคัญสูงสุดอการผลิตจำนวน 6 รายการจากข้อมูลการพยากรณ์ปริมาณการใช้วัตถุดิบย้อนหลัง 1 เดือนจากและเปรียบเทียบผลการพยากรณ์ทั้ง 4 วิธี จากค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE)

และค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) โดยพิจารณาจากค่าความผิดพลาดที่มีค่าต่ำที่สุด จากผลการศึกษาพบว่าค่าพยากรณ์ปริมาณการใช้วัตถุดิบย้อนหลังมีจำนวนที่สูงและจากการใช้ Solver ช่วยในการคำนวณหาค่าที่แม่นยำของการพยากรณ์พบว่าเทคนิคการพยากรณ์แบบวิธีหาค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักมีความเหมาะสมที่สุดเพราะมีค่าใกล้เกี่ยงกับข้อมูลจริง นำค่าพยากรณ์จากวีธีที่เลือกไปหาปริมาณการสั่งซื้อที่ประหยัด (EOQ) พบว่าต้นทุนการสั่งซื้อเปรียบเทียบแบบเดิมและแบบใหม่นั้นสามารถลดต้นทุนได้มูลค่า 22.655.010.98 บาทหรือคิดเป็น 2.71%

ธนพนธ์ สาริกา (2566)ได้ทำการเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกหลายช่องทาง (Omni channel) : กรณีศึกษาผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทยโดยได้ทำการวิเคราะห์ ABC เพื่อระบุรายการสินค้าที่มีผลกระทบต่อภาคธุรกิจมากที่สุด และได้กำหนดการพยากรณ์ ได้แก่ การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก, การพยากรณ์ด้วยวิธีปรับ เรียบแบบเอ็กซ์โปเนนเชียลชั้นเดียว, การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง , Autoregressive Integrated Moving Average และ Feed-Forward Neural Network โดยทำ ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE), ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE), ค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ในการวัดค่าความคลาดเคลื่อนของการพยากรณ์ ซึ่งผลการวิจัยพบว่า รายการสินค้าช่องทางขายออนไลน์ 6 จาก 10 พบว่าวิธีการพยากรณ์แบบการพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักมีความแม่นยำมากที่สุด โดยมีค่า MAPE เฉลี่ยอยู่ที่ 25.89% และช่องทางออฟไลน์พบว่ารายการสินค้า 4 จาก 8 รายการ มีค่าความคลาดเคลื่อนน้อยที่สุดด้วยวิธีการพยากรณ์แบบ ARIMA โดยมีค่า MAPE เฉลี่ยอยู่ที่ 26.74% และต้นทุนมูลค่าการถือครองสินค้าขั้นต่ำต่อสัปดาห์หลังคำนวณ Safety Stock ใหม่พบว่ามีต้นทุนลดลงไป 1,746,848 บาท โดยวิธีการที่นำเสนอสามารถลดต้นทุนของคงคลังต่อสัปดาห์ได้ประมาณ 45%

วิทิตยาพร พรหมณะ (2566) ทำการศึกษาการพยากรณ์ราคายางแผ่นรมควันชั้น 3 ในประเทศไทย โดยใช้ข้อมูลราคายางแผ่นรมควันชั้น 3 รายวัน โดยนำข้อมูลจากการยางแห่งประเทศไทยตั้งแต่ ปี พ.ศ.2554 ถึงปี 2564 จำนวน 2,618 ค่าแบ่งข้อมูลออกเป็น 2 ชุด ชุดที่ 1 ชุดเรียนรู้จำนวน 2,376 ค่า (ปี พ.ศ.2554 ถึงปี พ.ศ.2563) สำหรับสร้างตัวแบบการพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ การพยากรณ์ด้วยเลขชี้กำลังของโฮลต์ วิธีการบอกซ์-เจนกินส์และ วิธีโครงข่ายประสาทเทียม ชุดที่ 2 ชุดทดสอบจำนวน 242 ค่า (ปี พ.ศ.2564) เพื่อเปรียบเทียบประสิทธิภาพการพยากรณ์ที่มีค่าความคลาดเคลื่อนน้อยที่สุด เมื่อทำการพยากรณ์และวัดประสิทธิภาพตัวแบบ

การพยากรณ์กับชุดทดสอบแล้ว พบว่า การพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบ nonlinear autoregressive neural network (NNAR) มีความเหมาะสมที่จะใช้พยากรณ์ราคายางแผ่นรมควันชั้น 3 มากที่สุด มีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE) เท่ากับ 4.5352 ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (RMSE) เท่ากับ 5.7807 และค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (MAPE) เท่ากับ 7.33097 ซึ่งมีค่าน้อยที่สุดเทคนิคพยากรณ์ที่มีความแม่นน้อยลงมาตามลำดับคือ วิธีการบอกซ์-เจนกินส์วิธีการหาค่าเฉลี่ยเคลื่อนที่ และวิธีการพยากรณ์ด้วยเลขชี้กำลังของโฮลต์ตามลำดับ

งานวิจัยต่างประเทศ

Rodrigues et al. (2021) การวิจัยนี้มีวัตถุประสงค์เพื่อประเมินวิธีการพยากรณ์ต่าง ๆ ในการคาดการณ์การบริโภคน้ำมันเชื้อเพลิงในบราซิล ซึ่งผู้วิจัยเห็นว่าเป็นสิ่งสำคัญต่อการการวางแผนการดำเนินงานของภาคเอ็กซนและนโยบายสาธารณะเพื่อรับประกันการจัดหาพลังงานที่เพียงพอ การวิจัยนี้มุ่งเน้นไปที่การพยากรณ์การบริโภคน้ำมันเชื้อเพลิงเบา (น้ำมันที่ใช้ในยานพาหนะที่มีเครื่องยนต์สันดาปภายใน) ในบราซิล โดยผู้วิจัยดำเนินวิธีการการวิจัยนี้ใช้วิธีการพยากรณ์ 8 วิธี ได้แก่ SARIMA (Seasonal Autoregressive Integrated Moving Average), ARIMA with binary variables for seasonality VECM (Vector Error Correction Model), Univariate and multivariate Artificial Neural Networks (ANN and MANN), Support Vector Machine (SVM), Hybrid Neural Fuzzy Inference System (HyFIS), Random Forest (RF) และ Combined models (Ensemble learning) และทำการวัดค่าความคลาดเคลื่อนโดยวัดความแตกต่างระหว่างค่าที่พยากรณ์และค่าจริงโดยคำนวณจากรากที่สองของค่าเฉลี่ยของผลต่างยกกำลังสอง RMSE (Root Mean Square Error) และการวัดความแตกต่างระหว่างค่าที่พยากรณ์และค่าจริงในรูปแบบเปอร์เซ็นต์ ซึ่งการประเมินผลดำเนินการโดยใช้ข้อผิดพลาดในการพยากรณ์สำหรับช่วงเวลาพยากรณ์ 3, 6 และ12 เดือน โดยใช้ข้อมูลการบริโภคน้ำมันเชื้อเพลิงเบาในบราซิลตั้งแต่เดือนมกราคม 2002 ถึงเมษายน 2021 จากผลการวิจัยพบว่า Support Vector Machine (SVM) เป็นวิธีการที่มีประสิทธิภาพดีที่สุดสำหรับการพยากรณ์การบริโภคน้ำมันเชื้อเพลิงเบาในบราซิล โดยมีค่า MAPE ต่ำที่สุดในช่วงเวลาพยากรณ์ 12 เดือน นอกจากนี้ยังมีวิธีการอื่น ๆ ที่มีประสิทธิภาพดีเช่นกัน ได้แก่ Random Forest (RF) มีประสิทธิภาพดีในช่วงเวลาพยากรณ์ 6 – 12 เดือน และ ARIMA with binary variables for seasonality (AR.Bin) มีประสิทธิภาพดีในช่วงเวลาพยากรณ์ 3 และ 6 เดือน

Hopfe et al. (2023) ทำการวิจัยเพื่อประเมินประสิทธิภาพและความสามารถในการปรับตัวของโมเดลการพยากรณ์โดยทำการเทียบระหว่างเครือข่ายประสาทเทียม (Neural Network) ต่าง ๆ เช่น RNN, LSTM, GRU, Deep LSTM, Bidirectional LSTM, multivariate RNN และ multivariate LSTM เปรียบเทียบกับโมเดลอนุกรมเวลาแบบดั้งเดิม ARIMA, SARIMA, และ SARIMAX ในการพยากรณ์จำนวนผู้โดยสารที่จุดตรวจรักษาความปลอดภัยในสนามบินหลัก 5 แห่งของสหรัฐอเมริกาในช่วงที่มีความผันผวนสูง เช่น ช่วงการระบาดของ COVID-19 โดยดำเนินวิธีการวิจัยโดยรวบรวมข้อมูล ข้อมูลจำนวนผู้โดยสารที่จุดตรวจรักษาความปลอดภัยในสนามบินหลัก 5 แห่งของสหรัฐอเมริกา (ATL, DEN, ORD, LAX, DFW) ในช่วงเดือนกุมภาพันธ์ 2020 ถึงตุลาคม 2022 และทำการสร้างโมเดลในการพยากรณ์คือโมเดลเครือข่ายประสาทเทียม (RNN, LSTM, GRU, Deep LSTM, Bidirectional LSTM, multivariate RNN และ multivariate LSTM) และการพยากรณ์อนุกรมเวลาแบบดั้งเดิม (ARIMA, SARIMA, SARIMAX) เพื่อพยากรณ์จำนวนผู้โดยสาร โดยทำการประเมินผลเปรียบเทียบความแม่นยำของการพยากรณ์โดยใช้ตัวชี้วัดต่าง ๆ เช่น MAE, MAPE, RMSE, และ MSE จากการวิจัยพบว่าโมเดล RNN มีความแม่นยำในการพยากรณ์สูงกว่าโมเดลอนุกรมเวลาแบบดั้งเดิม SARIMA โดยมีค่า MAPE ต่ำกว่า 34% โมเดล RNN สามารถจับความซับซ้อนและความไม่เป็นเชิงเส้นของข้อมูลได้ดีกว่าโมเดลอื่น ๆ การรวมตัวแปรภายนอกช่วยเพิ่มความแม่นยำในการพยากรณ์ของโมเดลเครือข่ายประสาทเทียม แต่ไม่ช่วยเพิ่มความแม่นยำของโมเดลอนุกรมเวลาแบบSARIMAX)

Rivera et al. (2023) การวิจัยนี้มีจุดมุ่งหมายเพื่อประเมินโมเดลการพยากรณ์ความต้องการ (Demand forecasting) โดยใช้ปัจจัยภายนอกและเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อดูว่าช่วยปรับปรุงประสิทธิภาพเมื่อเทียบกับโมเดลสถิติแบบ Univariate หรือไม่ การวิจัยนี้โดยใช้ข้อมูลผลิตภัณฑ์ไฟฟ้าในอุตสาหกรรมก่อสร้างในบริษัทผลิตในโคลอมเบีย โดยทำการรวบรวมข้อมูลความต้องการและยอดขายรายเดือนของผลิตภัณฑ์ไฟฟ้าสำหรับอุตสาหกรรมก่อสร้างจากปี 2013 ถึง 2020 และใช้การวิเคราะห์ Pareto เพื่อเลือกผลิตภัณฑ์ที่สำคัญ การวิจัยได้ใช้การพยากรณ์แบบ Multivariate Auto-Regressive Moving Average with eXogenous input (ARMAX) โดยทำการทดสอบ Dickey-Fuller เพื่อตรวจสอบว่าซีรีส์เวลาเป็นสถานีหรือไม่รวมถึงใช้ฟังก์ชันการวิเคราะห์การเชื่อมโยงอัตโนมัติ (ACF) และฟังก์ชันการวิเคราะห์การเชื่อมโยงอัตโนมัติบางส่วน (PACF) เพื่อระบุตัวแปรอิสระ AR และ MA รวมถึงใช้ข้อมูลความต้องการและปัจจัยภายนอกที่เลือกผ่านการวิเคราะห์การเชื่อมโยงข้ามบางส่วน (CCF) เป็นข้อมูลการฝึกอบรม จากนั้นจึงเลือกโมเดล ARMAX ที่เหมาะสมที่สุดตามค่า p-value และ R^2

จากข้อมูลทดสอบ และส่วนของโมเดลไฮบริด Neural Network-ARMAX (NN-ARMAX) ได้ใช้โมเดล ARMAX ที่พัฒนาขึ้นก่อนหน้านี้เพื่อสร้างโมเดล NN-ARMAX ข้อมูลถูกแบ่งเป็นสองประเภท: ข้อมูลการฝึกอบรม (มกราคม 2013 ถึง กันยายน 2019) และข้อมูลทดสอบ (ตุลาคม 2019 ถึง ธันวาคม 2020) และใช้วิธีการคำนวณค่าเฉลี่ยเคลื่อนที่และการเพิ่มข้อมูล (Data Augmentation) หลังจากนั้นทำการวัดผลด้วย MAPE, RMASE และ R^2 จากผลการวิจัยแสดงให้เห็นว่าโมเดล NN-ARMAX มีประสิทธิภาพดีกว่าโมเดลอื่น ๆ โดยการจัดการความต้องการดีขึ้นด้วยการลดปัญหาสินค้าคงคลังเกินและสินค้าขาดสต็อก

ตารางที่ 1 สรุปงานวิจัยที่เกี่ยวข้องกับการพยากรณ์

แหล่งที่มาของวิจัย	**ผู้แต่ง/วิจัย**	**วิธีการพยากรณ์**	**ผลลัพธ์ที่ได้**
ในประเทศ	ชยากร อุปกรณ์ (2564)	ดำเนินการพยากรณ์ ปริมาณการขายของสินค้าข้อมูลสินค้าที่มีมูลค่าการขายมากที่สุด ในแต่ละกลุ่มสินค้าจำนวน 7 กลุ่มสินค้า ได้แก่ นม นมผงเด็กผงซักฟอก น้ำมันปรุงอาหาร ผ้าอ้อม ซอส และน้ำอัดลม โดยใช้เทคนิคการพยากรณ์ TBATS, Multiple linear regression (MLR), XGBoost, Artificial Neural Network (ANN) และตัวแบบผสม TBATS-XGBoost และ TBATS-ANN การวัดความคลาดเคลื่อนที่ใช้ในงานวิจัยนี้ คือ ค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสมบูรณ์ (Mean Absolute Percentage Error, MAPE)	แบบANN ให้ผล MAPE ต่ำสุดที่ 16.04% หากแยกเป็นกลุ่มข้อมูลพบว่ากลุ่มที่มีฤดูกาล แนวโน้ม และกลุ่มไม่มีฤดูกาลและแนวโน้มนั้น ANN ได้ผลดีที่สุด ส่วนกลุ่มที่มีฤดูกาลแต่ไม่มีแนวโน้มตัวแบบผสมได้ผลดีที่สุด

ตารางที่ 1 (ต่อ)

แหล่งที่มาของวิจัย	ผู้แต่ง/วิจัย	วิธีการพยากรณ์	ผลลัพธ์ที่ได้
ในประเทศ	ภมร สถิรมนวงศ์ (2564)	ทำการศึกษาปรับปรุงการพยากรณ์ความต้องการสินค้าสำเร็จรูป และการพัฒนาระบบเติมเต็มสินค้าคงคลังของพัสดุบรรจุของโรงงานผลิตเครื่องดื่มแอลกอฮอล์แห่งหนึ่ง โดยทำการพยากรณ์ด้วยวิธี Naïve, Simple Moving average, Single exponential smoothing, ARIMA Moving average, Double exponential smoothing, ARIMA และ Triple exponential smoothing (Holt-Winter's) โดยวัดความคลาดเคลื่อนของการพยากรณ์แต่ละวิธีด้วย MAE, RMSE และ MAPE	วิธีการพยากรณ์แบบดั้งเดิมมีความแม่นยำสูงที่สุดสำหรับผลิตภัณฑ์ B285700 และ B2851000 ในขณะที่วิธี ARIMA นั้นมีความแม่นยำสูงที่สุดและมีค่าสูงกว่าการพยากรณ์แบบดั้งเดิมสำหรับผลิตภัณฑ์ B285345
	อุรชา จันทรภา (2564)	ทำการศึกษาตัวแบบพยากรณ์ที่เหมาะสมสำหรับพยากรณ์มูลค่าการส่งออกรถยนต์ ข้อมูลที่ใช้ในการศึกษาวิธีการพยากรณ์ของงานวิจัยนี้เป็นข้อมูลรายเดือนตั้งแต่เดือนมกราคม พ.ศ. 2551 ถึงเดือนธันวาคม พ.ศ. 2563 เป็นจำนวนทั้งหมด 156 เดือน วิธีที่ใช้ในการพยากรณ์ ได้แก่ Moving Average, Holt-Winters, SARIMA, Multiple Linear Regression, ANN, Support Vector Regression, XGBoost, LSTM และวิธีพยากรณ์แบบผสม โดยใช้ค่า (MAPE) ในการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์	ตัวแบบพยากรณ์ที่มีความแม่นยำที่สุดสำหรับพยากรณ์คือตัวแบบพยากรณ์ผสมวิธี LSTM-XGB วิธี SARIMA-XGB และวิธี LSTM-SARIMA มีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเท่ากับ 6.63 15.40 และ 6.27% ตามลำดับ

ตารางที่ 1 (ต่อ)

แหล่งที่มาของวิจัย	ผู้แต่ง/วิจัย	วิธีการพยากรณ์	ผลลัพธ์ที่ได้
ในประเทศ	พัชรี สุขแก้ว (2565)	ทำการพยากรณ์ในการวางแผนความต้องการสั่งซื้อวัตถุดิบล่วงหน้าเพื่อหาปริมาณการสั่งซื้อที่เหมาะสมโดยใช้ข้อมูลตัวเลขการสั่งซื้อวัตถุดิบย้อนหลังตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึง เดือนมิถุนายน พ.ศ. 2564 รวมจำนวน 18 เดือน โดยใช้ใช้เทคนิคการพยากรณ์แบบอนุกรมเวลา ทั้งหมด4วิธี คือ 1) วิธีหาค่าเฉลี่ยเคลื่อนที่ 2) วิธีหาค่าเฉลี่ยเคลื่อนที่แบบถ่วงน่าหนัก 3) วิธีปรับเรียบเอ็กซ์โพเนนเชียล 4)วิธีเอ็กซ์โพเนนเชียลแบบวินเทอร์ และเปรียบเทียบผลการพยากรณ์ทั้ง 4 วิธี จากค่าเฉลี่ยความผิดพลาด สัมบูรณ์ (MAD) และค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE)	การพยากรณ์พบว่า ผลค่าความเคลื่อน ทั้ง 4 วิธี พบว่า วิธีเอ็กซ์โพเนนเชียลแบบง่าย ให้ค่า MAPE วัตถุดิบ 3 รายการที่ต่ำ เช่น B0217, B0227, B0251 เท่ากับ 27.32, 9.93, 17.16% ตามลำดับ และให้ค่า MAD รายการ B0251 เท่ากับ 74,497.62 เป็นค่าที่ต่ำ

ตารางที่ 1 (ต่อ)

แหล่งที่มาของวิจัย	ผู้แต่ง/วิจัย	วิธีการพยากรณ์	ผลลัพธ์ที่ได้
ในประเทศ	ธนพนธ์ สาริกา (2566)	การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้า โดยใช้ข้อมูลยอดขายของสาขาออนไลน์และออฟไลน์จากระบบภายในขององค์กรกรณีศึกษาเป็นระยะเวลา 1 ปี ตั้งแต่เดือน มกราคม – ธันวาคม 2565 ซึ่งสาขาที่เลือกจะแบ่งเป็นสาขาออนไลน์ 1 สาขา และสาขาออฟไลน์อีก 5 สาขา การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลชั้นเดียว, การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง , ARIMA และFNN การวัดค่าความคลาดเลื่อนโดย MSE, MAD และ MAPE	รายการสินค้าช่องทางขายออนไลน์ 6 จาก 10 พบว่าวิธีการพยากรณ์แบบ การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักมีความแม่นยำมากที่สุด โดยมีค่า MAPE เฉลี่ยอยู่ที่ 25.89% และช่องทางออฟไลน์พบว่ารายการสินค้า 4 จาก 8 รายการ มีค่าความคลาดเคลื่อนน้อยที่สุดด้วยวิธีการพยากรณ์แบบ ARIMA โดยมีค่า MAPE เฉลี่ยอยู่ที่ 26.74%

ตารางที่ 1 (ต่อ)

แหล่งที่มาของวิจัย	ผู้แต่ง/วิจัย	วิธีการพยากรณ์	ผลลัพธ์ที่ได้
ในประเทศ	วิทิตยาพร พรหมณะ (2566)	ทำการศึกษาการพยากรณ์ราคายางแผ่นรมควันชั้น 3 ในประเทศไทย โดยใช้ข้อมูลราคายางแผ่นรมควันชั้น 3 รายวัน โดยนำข้อมูลจากการยางแห่งประเทศไทย ตั้งแต่ปี พ.ศ.2554 ถึงปี 2564 จำนวน 2,618 ค่า การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ การพยากรณ์ด้วยเลขชี้กำลังของโฮลต์ วิธีการบอกซ์-เจนกินส์และ วิธีโครงข่ายประสาทเทียม NNAR โดยวัดความคลาดเคลื่อนของการพยากรณ์แต่ละวิธีด้วย MAE, RMSE และ MAPE	การพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบ nonlinear autoregressive neural network (NNAR) มีความเหมาะสมที่จะใช้พยากรณ์ราคายางแผ่นรมควันชั้น 3 มากที่สุด มีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE) เท่ากับ 4.5352 ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (RMSE) เท่ากับ 5.7807 และค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (MAPE) เท่ากับ 7.3309

ตารางที่ 1 (ต่อ)

แหล่งที่มาของวิจัย	ผู้แต่ง/วิจัย	วิธีการพยากรณ์	ผลลัพธ์ที่ได้
ต่างประเทศ	Rodrigues et al. (2021)	ทำการประเมินวิธีการพยากรณ์ต่าง ๆ ในการคาดการณ์การบริโภคน้ำมันเชื้อเพลิงในบราซิล โดยผู้วิจัยดำเนินวิธีการการวิจัยนี้ใช้วิธีการพยากรณ์ 8 วิธี ได้แก่ SARIMA (Seasonal Autoregressive Integrated Moving Average), ARIMA with binary variables for seasonality VECM (Vector Error Correction Model), Univariate and multivariate Artificial Neural Networks (ANN and MANN), Support Vector Machine (SVM), Hybrid Neural Fuzzy Inference System (HyFIS), Random Forest (RF) และ Combined models (ensemble learning) และทำการวัดค่าความคลาดเคลื่อนโดยคำนวณจากรากที่สองของค่าเฉลี่ยของผลต่างยกกำลังสอง RMSE (Root Mean Square Error)	ผลการประเมิน Support Vector Machine (SVM) เป็นวิธีการที่มีประสิทธิภาพดีที่สุดสำหรับการพยากรณ์การบริโภคน้ำมันเชื้อเพลิงเบาในบราซิล โดยมีค่า MAPE ต่ำที่สุดในช่วงเวลาพยากรณ์ 12 เดือน ความคลาดเคลื่อนสัมบูรณ์ (MAPE) เท่ากับ 7.3309

ตารางที่ 1 (ต่อ)

แหล่งที่มาของวิจัย	ผู้แต่ง/วิจัย	วิธีการพยากรณ์	ผลลัพธ์ที่ได้
ต่างประเทศ	Hopfe et al. (2023)	ประเมินประสิทธิภาพและความสามารถในการปรับตัวของโมเดลการพยากรณ์โดยทำการเทียบระหว่างเครือข่ายประสาทเทียม (Neural Network) ต่าง ๆ เช่น RNN, LSTM, GRU, Deep LSTM, Bidirectional LSTM, multivariate RNN และ multivariate LSTM เปรียบเทียบกับโมเดลอนุกรมเวลาแบบดั้งเดิม ARIMA, SARIMA, และ SARIMAX ในการพยากรณ์จำนวนผู้โดยสารที่จุดตรวจรักษาความปลอดภัยในสนามบินหลัก 5 แห่งของสหรัฐอเมริกา โดยทำการประเมินผลเปรียบเทียบความแม่นยำของการพยากรณ์โดยใช้ตัวชี้วัดต่าง ๆ เช่น MAE, MAPE, RMSE, และ MSE	โมเดล RNN มีความแม่นยำในการพยากรณ์สูงกว่าโมเดลอนุกรมเวลาแบบดั้งเดิม SARIMA โดยมีค่า MAPE ต่ำกว่า 34%
	Rivera et al. (2023)	ทำการประเมินโมเดลการพยากรณ์ความต้องการโดยทำการรวบรวมข้อมูลความต้องการและยอดขายรายเดือนของผลิตภัณฑ์ไฟฟ้าสำหรับอุตสาหกรรมก่อสร้างจากปี 2013 ถึง 2020 และใช้การวิเคราะห์ Pareto เพื่อเลือกผลิตภัณฑ์ที่สำคัญ โดยใช้เทคนิคการพยากรณ์แบบ Multivariate Auto-Regressive Moving Average with eXogenous input (ARMAX) และ Neural Network-ARMAX (NN-ARMAX) และทำการวัดค่าคลามคลาดเคลื่อนโดย MAPE, RMSE และ R^2	การพยากรณ์แบบ NN-ARMAX มีประสิทธิภาพดีกว่าโดยค่าความคลาดเคลื่อนต่ำสุดคือ Product A MAPE 14.39%

ตารางที่ 2 สรุปวิธีการศึกษาการพยากรณ์ในงานวิจัยที่เกี่ยวข้อง

ผู้แต่ง/วิจัย	เทคนิคที่ใช้ในการพยากรณ์				
	Simple moving Average (SMA) / Weighted Moving Average (WMA)	Exponential Smoothing	Autoregressive Integrated Moving Average (ARIMA)	Machine learning	Hybrid Forecasting method
ชยากร อุปกรณ์ (2564)			O	O	O
ธนพนธ์ สาริกา (2566)	O	O	O	O	
พัชรี สุขแก้ว (2565)	O	O	O		
วิทิตยาพร พรหมณะ (2566)	O	O	O	O	
ภมร สถิรมนวงศ์ (2564)	O	O	O		
อุรชา จันทรภา (2564)	O		O	O	O
Rodrigues et al. (2021)			O	O	O
Hopfe et al. (2023)			O	O	
Rivera et al. (2023)			O	O	O

หลังจากการศึกษางานวิจัยที่เกี่ยวข้องซึ่งผู้วิจัยได้เลือกงานวิจัยที่ดำเนินการในหลายวิธีการพยากรณ์ทั้งที่มีแค่การพยากรณ์ด้วยอนุกรมเวลาหรือมีการนำการพยากรณ์การเรียนรู้ของเครื่องและรวมถึงวิธีผสมผสานกัน เพื่อใช้แก้ไขปัญหาในด้วยการกำหนดจำนวนการสั่งซื้อหรือการกำหนดสินค้าคงคลังซึ่งเป็นเป้าหมายในการเพิ่มประสิทธิภาพและลดต้นทุนการสั่งซื้อและการถือครองสินค้าในการจัดการ Supply chain ซึ่งที่ได้จากการทบทวนวิจัยที่เกี่ยวข้องสามารถแบ่งได้เป็นหลายด้าน

ประการแรกพบว่ารูปแบบการพยากรณ์แต่ละรูปแบบอาจจะไม่เหมาะสมกับข้อมูลบางรูปแบบเช่นรูปแบบข้อมูลที่มีลักษณะที่เป็นฤดูกาลและแนวโน้มอาจจะเหมาะกับการใช้ ANN และอาจจะไม่เหมาะสมกับข้อมูลที่มีฤดูกาลเพียงอย่างเดียวจะมีการใช้แบบพยากรณ์แบบผสมผสาน

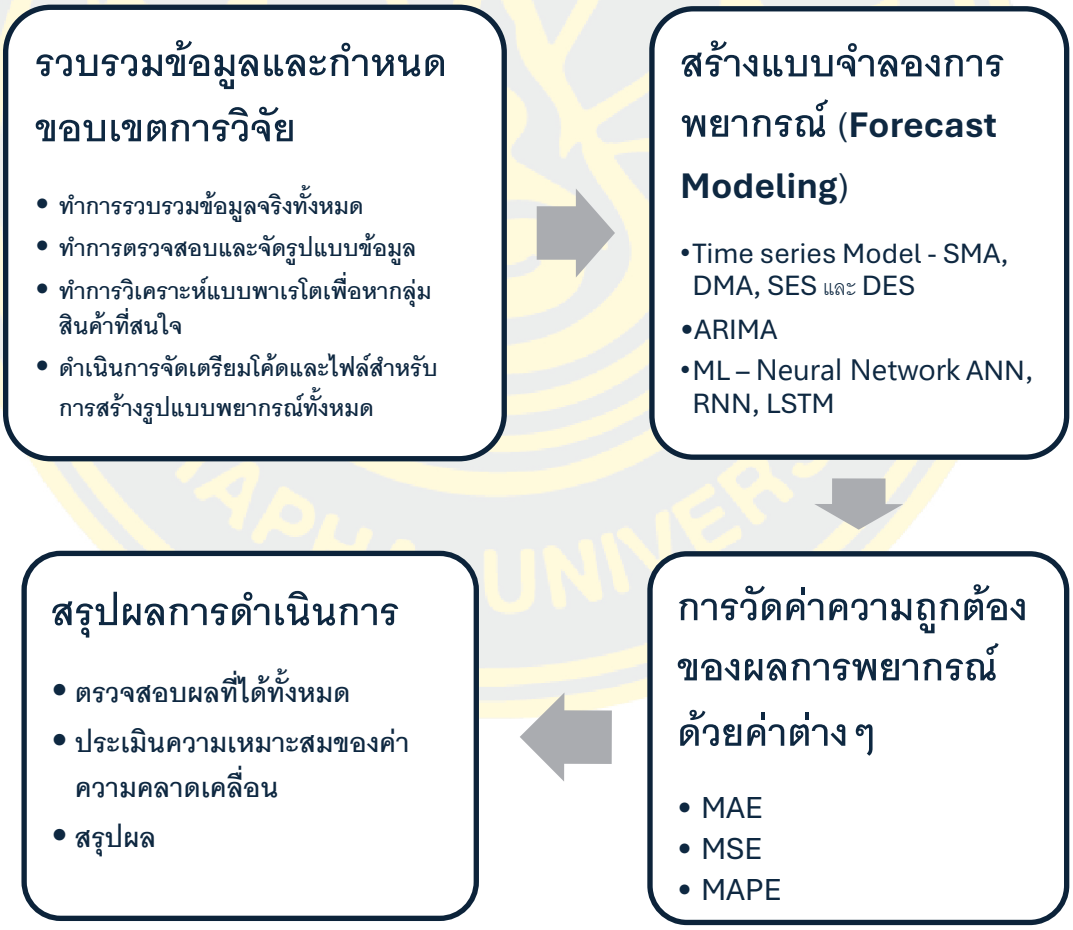
มากกว่า โดยการเลือกตัวแบบพยากรณ์ที่เหมาะสมจะส่งผลต่อความแม่นยำในการพยากรณ์มากขึ้น

ประการที่สองคือการพิจารณาการส่งผลของปัจจัยภายนอกซึ่งอาจทำให้ผลต่อความแม่นยำของการพยากรณ์ลดลงจึงจำเป็นต้องคำนึงถึงความสัมพันธ์หรือสอดคล้องของตัวแปรต่าง ๆ และพิจารณารูปแบบการพยากรณ์ที่เหมาะสมได้อย่างมีประสิทธิภาพมากขึ้น

สุดท้ายจากการพิจารณารูปแบบการพยากรณ์หลายรูปแบบสามารถทำให้เราเข้าใจลักษณะข้อมูลที่ทำการพยากรณ์ได้มากขึ้นรวมถึงการพยากรณ์ยอดขายด้วยการเรียนรู้เครื่องและ Neural Networks อาจถือได้ว่าเป็นแนวทางที่มีประสิทธิภาพในการเพิ่มความแม่นยำในการพยากรณ์ การเลือกตัวแบบที่เหมาะสมโดยการนำแนวคิดเหล่านี้มาประยุกต์ใช้ในการพยากรณ์ที่เหมาะสมน่าจะสามารถช่วยเพิ่มประสิทธิภาพในการวางแผนและการตัดสินใจในธุรกิจได้มีประสิทธิภาพมากขึ้น

บทที่ 3
ระเบียบวิธีวิจัย

การศึกษาวิจัยนี้ได้ศึกษาถึงวิธีการพยากรณ์ความต้องการของบริษัทในกรณีศึกษาซึ่งลักษณะความต้องการมีความผันผวนและมีความต้องการในการเพิ่มขีดความสามารถในการแข่งขัน เนื่องด้วยข้อจำกัดในด้านการทรัพยากร รวมถึงความต้องการเพิ่มประสิทธิภาพในการตอบสนองความต้องการกับลูกค้าให้ดีขึ้น โดยจากเดิมการคาดการณ์ข้อมูลพยากรณ์จะถูกกำหนดโดยฝ่ายขายและข้อมูลจากลูกค้าซึ่งอาศัยการคาดคะเนเชิงคุณภาพจากความรู้สึกและประสบการณ์ในการกำหนดปริมาณยอดขายในเดือนถัดไป



ภาพที่ 3 กรอบแนวคิดขั้นตอนการวิจัย

ที่มา: ผู้วิจัย

ขั้นตอนการดำเนินงานวิจัย

รวบรวมข้อมูลและกำหนดขอบเขตการวิจัย

ทำการรวบรวมข้อมูลของธุรกิจในกรณีศึกษาได้แก่ ข้อมูลยอดขายของรายการสินค้าทั้งหมดซึ่งประกอบไปด้วย รหัสสินค้า จำนวนขาย และ ช่วงเวลาที่ทำการขายโดยแบ่งตามเดือน หลังจากนั้นทำการแบ่งกลุ่มที่สนใจโดยใช้หลักการวิเคราะห์แผนภาพ Pareto ในการกำหนดกลุ่มสินค้าที่นำมาทำการพยากรณ์

ทำการแปลงรูปแบบข้อมูลให้สามารถอ่านค่าได้อย่าถูกต้องซึ่งประกอบไปด้วยความเหมือนกันของรหัสสินค้าของข้อมูลทั้งหมด รูปแบบจำนวนยอดขายที่ต้องเป็นรูปแบบตัวเลข และรูปแบบของการบันทึกเวลาของข้อมูลและทำการตรวจสอบข้อมูลบ้างส่วนกรณีที่มีข้อมูลไม่ครบอาจต้องดำเนินการใส่ค่า 0 หรือทำการลบออกเพื่อป้องกันความคลาดเคลื่อนของข้อมูล

ทำการนำข้อมูลทั้งหมดมาแปลงหาค่ารวมของแต่ละรายการและทำการสร้างกราฟเพื่อทำการวิเคราะห์จำแนกกลุ่มตามแบบวิเคราะห์พาเรโต

จัดการเตรียมไฟล์ให้เหมาะสมและพร้อมสำหรับการนำเข้าสู่ระบบเพื่อป้องกันความคลาดเคลื่อนที่อาจจะเกิดขึ้นหลังจากนั้นทำการจัดเตรียม Code สำหรับการสร้างแบบพยากรณ์ต่าง ๆ

สร้างแบบจำลองการพยากรณ์ (Forecast Modeling)

การพยากรณ์ด้วยแบบจำลองอนุกรมเวลา (Time-Series) ด้วยวิธี SMA, DMA, SES และ DES จะใช้ Google colab ในการพยากรณ์ทั้งหมดโดยการพยากรณ์แบบ SMA และ DMA ทางผู้วิจัยได้แบ่งเป็นสองระยะคือ n= 2 ถึง 6 เดือนเพื่อทำการเทียบเคียงโดยทั้งค่านี้กำหนดโดยการสุ่มขึ้น และทำการกำหนดคำสั่งเพื่อหาน้ำหนัก Alpha และ Beta ซึ่งในส่วนของที่เหมาะสมของวิธีการพยากรณ์แบบ SES และ DES โดยการหาวิธีการค่าน้ำหนักที่ดีที่สุดด้วย Grid Search

การพยากรณ์แบบ Autoregressive Integrated Moving Average (ARIMA)

1.แบ่งข้อมูลออกเป็น 70/30 โดย 70% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการฝึก และอีก 30% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการทดสอบ โดยทำการสร้าง Data frame โดยนำสินค้าทั้งหมด 7 รายการทำเป็นตาราง 1 Column และมีการแบ่งข้อมูลเป็นรายเดือนทั้งหมด 36 เดือน

2.ทำการตรวจสอบว่าชุดข้อมูลนั้นคงที่ (Stationary) หรือไม่ โดยทำการทดสอบ Augmented Dickey-Fuller test (ADF) ถ้าหากค่า p-value ออกมามากกว่า 0.05 จะทำการ Differencing และทดสอบ ADF test

3.ทำการปรับค่าชุดข้อมูลให้คงที่ และทำการพล็อตกราฟ ACF และ PACF เพื่อใช้ในการวิเคราะห์และคาดการณ์อนุกรมเวลาโดยจะให้ข้อมูลเชิงลึกเกี่ยวกับโครงสร้างความสัมพันธ์ของข้อมูลอนุกรมเวลาและเพื่อหาค่า p, d, q

4.เริ่มพยากรณ์โดยกำหนดพารามิเตอร์ p, d, q โดยค่า p เราจะได้มาจากการพล็อตกราฟ PACF ค่า d เราจะได้มาจากการทำ Differencing และค่า q เราจะได้มาจากการพล็อตกราฟ ACFและเก็บค่าความคลาดเคลื่อนครั้งที่ 1 จากนั้นล้างรันไทม์ใหม่และใช้ Akaike Information Criterion (AIC) ในการช่วยปรับค่าพารามิเตอร์

ทำการสร้างแบบพยากรณ์แบบ Machine Learning ด้วยเทคนิค Neural network เนื่องจากผู้วิจัยสนใจเทคนิค Neural network ในการนำมาพัฒนาโมเดลสำหรับการพยากรณ์และทำการเลือกมา 3 เทคนิคคือ ANN, RNN และ LSTM โดยแต่ละเทคนิคจะทำการผ่าน Google colab ซึ่งขั้นตอนดังต่อไปนี้จะเป็นวิธีดำเนินการของแต่ละเทคนิค

1.ทำการเตรียมไฟล์ข้อมูลสำหรับนำเข้าสู่ระบบโดยทำการแปลงข้อมูลช่วงเวลาให้เป็นรูปแบบของวันที่ตัวเลขแล้วตรวจสอบรูปแบบข้อมูลปริมาณว่าอยู่ในรูปแบบของตัวเลขหรือไม่และความสะอาดข้อมูลโดยด้วยสอบข้อมูลบางรายการที่ไม่มีจำนวนหรือใส่ค่าที่ไม่ใช่ตัวเลข

2.ทำการกำหนดสัดส่วนของข้อมูลสำหรับการฝึกและทดสอบในกรณีนี้จะทำการแบ่งข้อมูล 70% สำหรับทำการฝึก และ 30%สำหรับทำการทดสอบ

3.สร้างโมเดลการพยากรณ์โดยการใช้ Library TensorFlow ในการสร้างโมเดลและทำการกำหนดจำนวนชั้น Layer และจำนวน Neurons ในแต่ละโดยทำการสุ่มเพื่อหาค่าพยากรณ์ที่ได้ค่าความคลาดเคลื่อนต่ำที่สุดโดยทำการปรับจำนวนรอบและขนาดชุดของข้อมูลย่อยด้วย Grid search ซึ่งจะถูกกำหนดด้วยค่าสุ่มสำหรับค่าที่ใช้พิจารณา

4.ทำการประเมินผลของโมเดลที่ทำการสร้างขึ้นมาด้วยค่า MAE, MSE, MAPE

การวัดค่าความถูกต้องของผลการพยากรณ์ด้วยค่าต่าง ๆ

การแสดงค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ Mean Absolute Error (MAE) ที่ได้โดยเป็นหน่วยยอดขายเป็นกิโลกรัม

การแสดงค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่าความคลาดเคลื่อนที่ได้จะแสดงส่วนต่างกำลังสอง Mean Squared Error (MSE) ระหว่างค่าที่พยากรณ์และค่าจริง

ค่าความคลาดเคลื่อนจะแสดงในรูปแบบเปอร์เซ็นต์ของยอดขาย Mean Absolute Percentage Error (MAPE)

สรุปผลการดำเนินการ

ทำการแสดงผลที่ได้รับจากการวิจัยตามวัตถุประสงค์ที่ตั้งไว้คือทำการวิเคราะห์เปรียบเทียบค่าความคลาดเคลื่อนของการพยากรณ์ในแต่ละแบบรวมถึงปัญหาที่พบระหว่างการดำเนินการวิจัย เพื่อเป็นแนวทางแก้และปรับปรุงให้กับงานวิจัยต่อ ๆ ไปรวมไปถึงเสนอแนะแนวทางการศึกษาเพิ่มเติมที่มีความเป็นไปเป็นได้ในการนำไปใช้การปรับปรุงวิธีการดำเนินการในบริษัทกรณีศึกษา

บทที่ 4
ผลการวิจัย

จากการขั้นตอนกการวิจัยที่ได้อธิบายไว้ในบทที่ 3 ผู้วิจัยได้เริ่มทำการศึกษาข้อมูลตัวอย่างก่อนซึ่งการที่จะดำเนินการผู้วิจัยได้นำหลักในการคัดเลือกกลุ่มสินค้าที่มีส่งผลกระทบอย่างมากนำมาใช้ในการพยากรณ์ทั้งในส่วนวิธีการพยากรณ์จำแนกตามแบบอนุกรมเวลาแบบดั้งเดิมและการพยากรณ์โดยการเรียนรู้ของเครื่องและทำการประเมินผลค่าความคลาดเคลื่อนที่ได้ในแต่ละแบบโดยแบ่งตามวิธีการพยากรณ์และแบ่งตามรายกากรสินค้าเพื่อทำการเทียบเคียงและศึกษาผลที่เกิดขึ้นจากการพยากรณ์ในรูปแบบต่าง ๆ

การเลือกกลุ่มรายการสินค้าที่จะนำมาพยากรณ์หลักการวิเคราะห์แบบ Pareto

ในการเลือกกลุ่มสินค้าที่นำมาพยากรณ์ในครั้งนี้ ผู้วิจัย เพื่อทำการคำนวณมูลค่ายอดขายสะสมของรายการสินค้าซึ่งมีอยู่ทั้งหมด 35 รายการและทำการหาสัดส่วนที่เป็นกลุ่มรายการสินค้าที่มายอดขายมากที่สุดรวมกับคิดเป็น 80% จากยอดขายสะสมของรายการสินค้าทั้งหมดจากช่วงเวลาข้อมูลที่นำมาวิเคราะห์ผ่าน Microsoft Excel เพื่อหายอดขายรวมของสินค้าและคำนวณหายอดรวมสะสมของรายการทั้งหมดที่อยู่ในกลุ่มยอดขายส่วนใหญ่คิดเป็น 80% ของยอดขายสะสมทั้งหมด

โดยหลังจากทำการรวบรวมและทำการจัดเรียงข้อมูลพบว่ามีรายการสินค้าทั้ง 7 รายการที่มีจำนวนยอดขายสะสมรวมคิดเป็น 80% จากจำนวนสินค้าทั้งหมด 35 รายการซึ่งมีจำนวนรวมทั้งหมด 5,601,567 กิโลกรัม คิดเป็น 80% ของจำนวนยอดขายสะสมทั้งหมด

ตารางที่ 3 ข้อมูลรายการสินค้าและยอดขายสะสมตั้งแต่ปี 2563 – 2567

รายการสินค้า	ยอดขายสะสม	สัดส่วนเปอร์เซ็นต์จากยอดขายรวม	สัดส่วนเปอร์เซ็นต์สะสม
SKU01	1,291,048	18.3%	18%
SKU02	1,123,871	16.0%	34%
SKU03	1,006,670	14.3%	49%
SKU04.	828,480	11.8%	60%

ตารางที่ 3 (ต่อ)

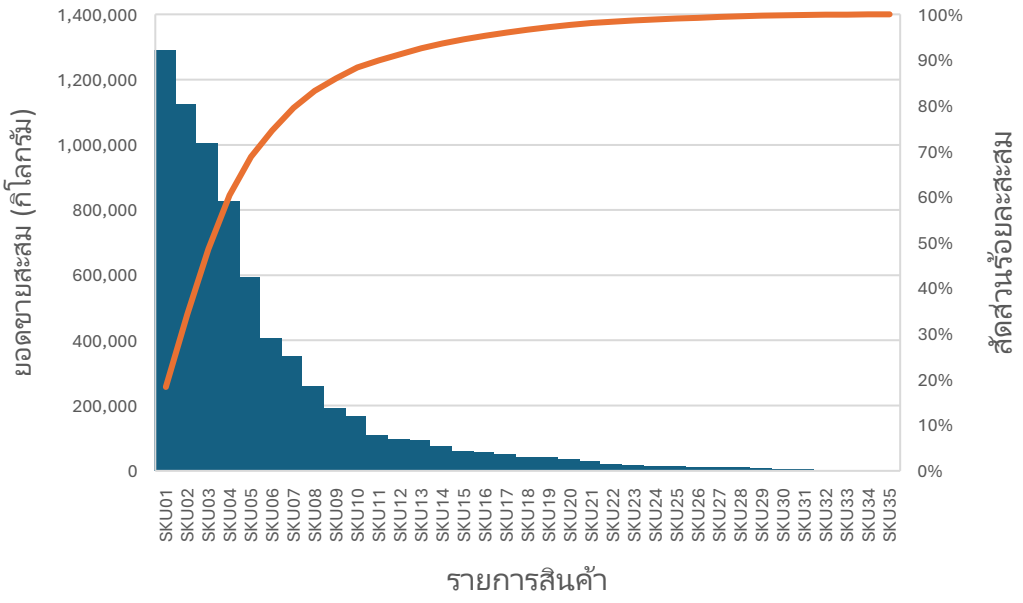
รายการสินค้า	ยอดขายสะสม	สัดส่วนเปอร์เซ็นต์จากยอดขายรวม	สัดส่วนเปอร์เซ็นต์สะสม
SKU05	593,912	8.4%	69%
SKU06	406,478	5.8%	75%
SKU07	351,108	5.0%	80%
SKU08	260,705	3.7%	83%
SKU09	193,336	2.7%	86%
SKU10	168,910	2.4%	88%
SKU11	108,608	1.5%	90%
SKU12	95,943	1.4%	91%
SKU13	92,630	1.3%	93%
SKU14	74,099	1.1%	94%
SKU15	61,038	0.9%	95%
SKU16	57,210	0.8%	95%
SKU17	50,510	0.7%	96%
SKU18	41,100	0.6%	97%
SKU19	40,920	0.6%	97%
SKU20	34,896	0.5%	98%
SKU21	30,220	0.4%	98%
SKU22	19,912	0.3%	98%
SKU23	17,656	0.3%	99%
SKU24	15,480	0.2%	99%
SKU25	14,794	0.2%	99%
SKU26	12,196	0.2%	99%
SKU27	11,800	0.2%	99%
SKU28	10,030	0.1%	100%
SKU29	9,380	0.1%	100%

ตารางที่ 3 (ต่อ)

รายการสินค้า	ยอดขายสะสม	สัดส่วนเปอร์เซ็นต์จากยอดขายรวม	สัดส่วนเปอร์เซ็นต์สะสม
SKU30	6,336	0.1%	100%
SKU31	4,500	0.1%	100%
SKU32	3,600	0.1%	100%
SKU33	3,405	0.0%	100%
SKU34	1,632	0.0%	100%
SKU35	320	0.0%	100%

ที่มา: ผู้วิจัย

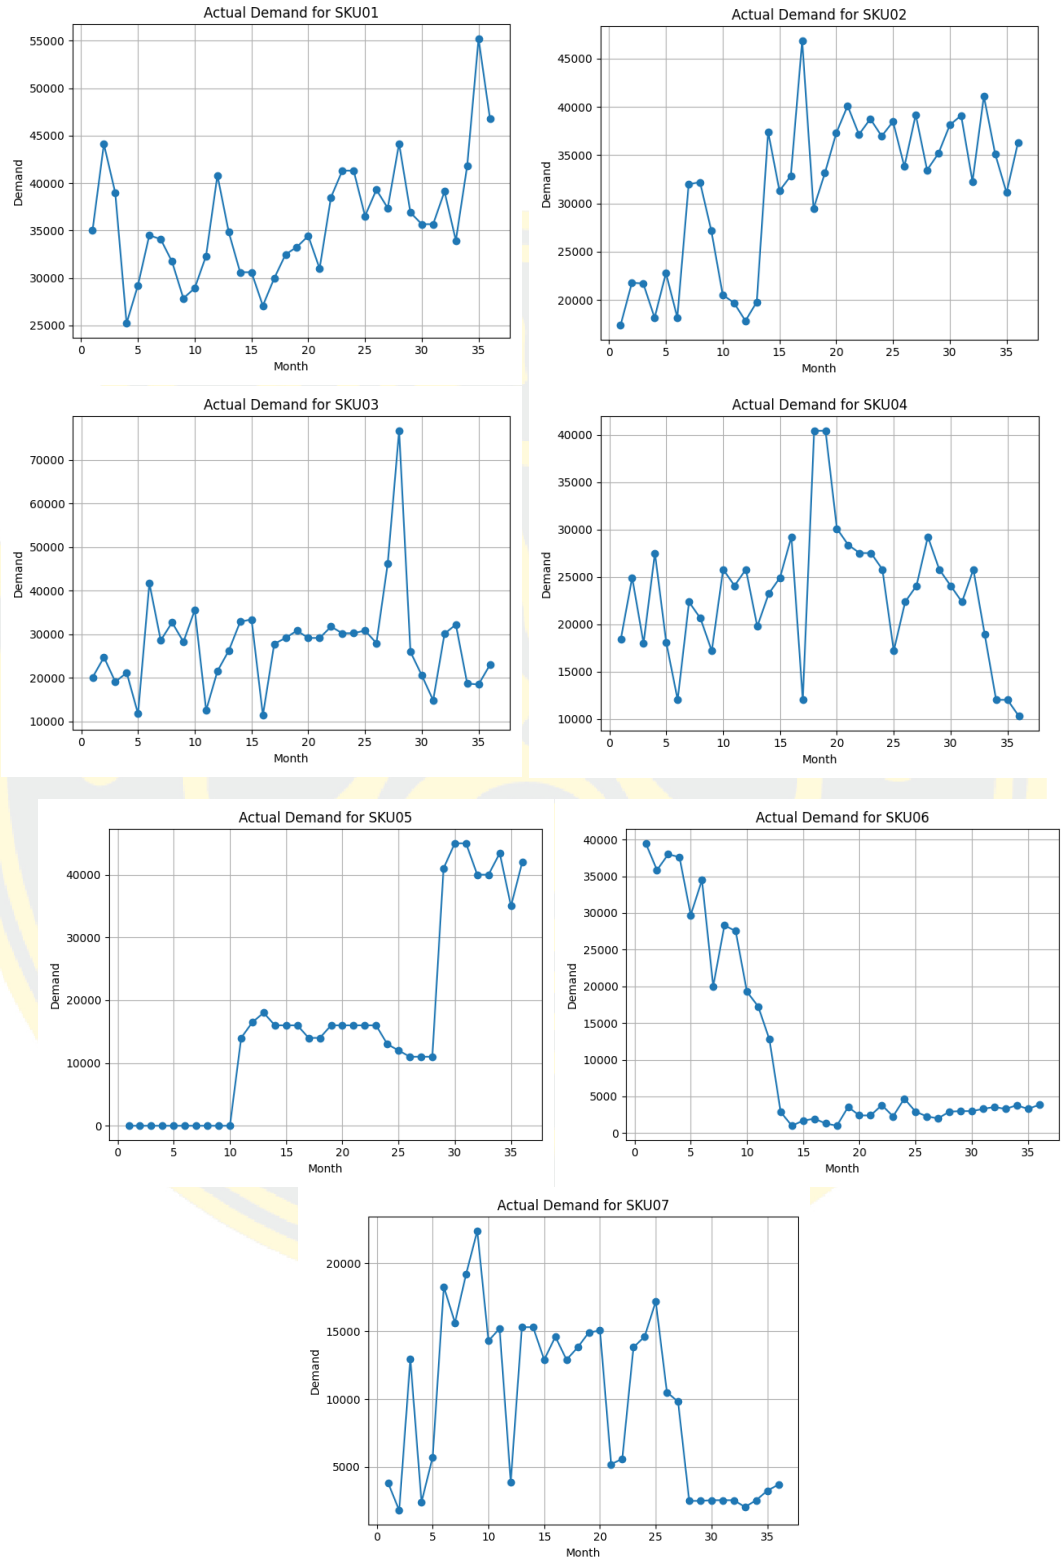
ซึ่งหลังจากได้ข้อมูลยอดขายสะสมและนำมาสร้างเป็นแผนภูมิพาเรโตซึ่งในสัดส่วนยอดขายสะสมทั้งหมดมีสินค้าอยู่ 7 รายการที่คิดเป็นยอดขายสะสมอยู่ที่ 80% คือรายการที่ SKU01,SKU02, SKU03, SKU04, SKU05, SKU06 และ SKU07 ตามลำดับ



ภาพที่ 4 แผนภูมิ Pareto แสดงยอดขายสะสมของรายการสินค้าทั้งหมด

ที่มา: ผู้วิจัย

ทั้งนี้ผู้วิจัยได้ทำการศึกษาแผนภูมิของแต่ละรายการสินค้าเพื่อดูลักษณะความคงที่ของข้อมูลก่อนเริ่มศึกษาวิธีการพยากรณ์อีกด้วยพบว่ารูปแบบของข้อมูลมีลักษณะที่แตกต่างกันเช่น แนวโน้มและความสม่ำเสมอของยอดขายในแต่ละช่วง



ภาพที่ 5 แผนภาพแสดงยอดขายจริงของสินค้าที่เลือกทำการศึกษาการพยากรณ์

ที่มา: ผู้วิจัย

การศึกษาวิธีการพยากรณ์จำแนกตามแบบอนุกรมเวลาแบบดั้งเดิมและการพยากรณ์โดยการเรียนรู้ของเครื่อง

ผลการพยากรณ์แบบอนุกรมเวลาแบบดั้งเดิม

ในกลุ่มของการพยากรณ์แบบอนุกรมเวลาแบบดั้งเดิม จะใช้ Google colab ในการพยากรณ์ อนุกรมเวลาแบบดั้งเดิมโดยมีการกำหนดค่า ช่วงระยะเวลาที่พยากรณ์ที่ n จากการสังเกตุช่วงระยะในการเปลี่ยนแปลงของสินค้าแต่ละรายการเพื่อหาผลการประเมินค่าความคลาดเคลื่อนที่ดีที่สุดสำหรับวิธีการคำนวณในของที่เป็นแบบการหาค่าเฉลี่ยเคลื่อนที่ทั้งในแบบ SMA และ DMA ทำการกำหนดคำสั่งเพื่อหาน้ำหนัก Alpha และ Beta เพื่อหาค่าที่เหมาะสมสำหรับวิธีการพยากรณ์แบบ SES และ DES ด้วยวิธีการ Grid search

ผลการพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่ (Simple moving average, SMA)

จากผลของการแบบหาค่าเฉลี่ยเคลื่อนที่ผ่าน Google colab โดยกำหนดช่วงระยะเวลาที่พยากรณ์ที่ n จากการสังเกตุช่วงระยะในการเปลี่ยนแปลงของสินค้าแต่ละรายการเพื่อหาผลการประเมินค่าความคลาดเคลื่อนที่ดีที่สุดซึ่งได้ผลลัพธ์ดังนี้

ตารางที่ 4 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองการหาค่าเฉลี่ยเคลื่อนที่ (Simple moving average, SMA)

รายการสินค้า	Simple moving average method			
	n	MAE	MSE	MAPE
SKU01	5	3751	27032020	9.85%
SKU02	3	4447	36624170	14.56%
SKU03	5	8463	163580300	34.27%
SKU04	3	5294	45794370	26.50%
SKU05	2	3746	58276999	12.66%
SKU06	2	2368	17033340	55.95%
SKU07	2	3940	820695	56.77%

ที่มา: ผู้วิจัย

โดยหลังการกำหนดช่วงระยะเวลาจากการสังเกตุช่วงรอบการเปลี่ยนแปลงของแต่ละรายการสินค้าพบว่าการพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่นั้น ผลประเมินของสินค้า SKU01 มีค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 9.85%

ผลการพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่คู่ (Double moving average, DMA)

จากผลของการแบบหาค่าเฉลี่ยเคลื่อนที่ผ่าน Google colab โดยกำหนดช่วงระยะเวลาที่พยากรณ์ที่ n จากการสังเกตุช่วงระยะในการเปลี่ยนแปลงของสินค้าแต่ละรายการเพื่อหาผลการประเมินค่าความคลาดเคลื่อนที่ดีที่สุดซึ่งได้ผลลัพธ์ดังนี้

ตารางที่ 5 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองการหาค่าเฉลี่ยเคลื่อนที่คู่ (Double moving average, DMA)

รายการสินค้า	Double moving average method			
	n	MAE	MSE	MAPE
SKU01	6	4346	34164140	10.84%
SKU02	3	4548	38622118	14.84%
SKU03	6	8974	198282600	31.31%
SKU04	2	5573	48884100	27.72%
SKU05	2	4486	79277610	14.91%
SKU06	2	2716	22285960	75.00%
SKU07	2	4038	28655750	62.77%

ที่มา: ผู้วิจัย

หลังการกำหนดช่วงระยะเวลาจากการสังเกตุช่วงรอบการเปลี่ยนแปลงของแต่ละรายการสินค้าพบว่าการพยากรณ์แบบหาค่าเฉลี่ยเคลื่อนที่นั้น ผลประเมินของสินค้า SKU01 มีค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 10.84%

ผลการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว (Single exponential smoothing, SES)

จากผลของการแบบหาค่าเฉลี่ยเคลื่อนที่ผ่าน Google colab โดยกำหนดคำสั่งเพื่อหาน้ำหนัก Alpha ซึ่งในส่วนของที่เหมาะสมของวิธีการพยากรณ์แบบ SES การหาวิธีการค่าน้ำหนักที่ดีที่สุดด้วย Grid search ได้ผลลัพธ์ดังนี้

ตารางที่ 6 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองแบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว (Single exponential smoothing, SES)

รายการสินค้า	Single Exponential Smoothing Method			
	Alpha	MAE	MSE	MAPE
SKU01	0.4	3986	28680627	11.09%
SKU02	0.4	4368	34392388.5	14.27%
SKU03	0.3	8061	146509187	34.08%
SKU04	0.2	5016	43876369	25.94%
SKU05	1.0	2913	44163905	9.86%
SKU06	0.8	2383	16379443	44.49%
SKU07	0.8	3562	27920460	56.67%

ที่มา: ผู้วิจัย

หลังจากกำหนดคำสั่งหาน้ำหนัก Alpha และ Beta เพื่อหาค่าที่เหมาะสมสำหรับวิธีการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว ด้วยวิธีการ Grid search ของแต่ละรายการสินค้าพบว่าการพยากรณ์แบบหาแบบจำลองแบบปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว ผลประเมินของสินค้า SKU01 มีค่า น้ำหนักอยู่ที่ Alpha 0.4 ซึ่งส่งผลให้การพยากรณ์มีผลประเมินค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 11.09%

ผลการพยากรณ์แบบวิธีปรับเรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double exponential smoothing method, DES)

จากผลของการแบบหาค่าเฉลี่ยเคลื่อนที่ผ่าน Google colab โดยกำหนดคำสั่งเพื่อหาน้ำหนัก Alpha และ Beta ซึ่งในส่วนของที่เหมาะสมของวิธีการพยากรณ์แบบ DES โดยการหาวิธีการค่าน้ำหนักที่ดีที่สุดด้วย Grid search ได้ผลลัพธ์ดังนี้

ตารางที่ 7 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองแบบปรับเรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double exponential smoothing, DES)

รายการสินค้า	Double Exponential Smoothing Method				
	Alpha	Beta	MAE	MSE	MAPE
SKU01	0.5	0.01	4087	32512950	11.10%
SKU02	0.5	0.01	4424	34899840	15.03%
SKU03	0.2	0.1	8010	157141590	37.32%
SKU04	0.2	0.01	5059	44058304	26.44%
SKU05	0.2	0.2	2986	44643175	10.13%
SKU06	0.9	0.2	2672	16542968	56.43%
SKU07	0.8	0.06	3637	29836502	64.38%

ที่มา: ผู้วิจัย

หลังจากกำหนดคำสั่งหาน้ำหนัก Alpha และ Beta เพื่อหาค่าที่เหมาะสมสำหรับวิธีการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลสองชั้น ด้วยวิธีการ Grid search ของแต่ละรายการพบว่าการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียลสองชั้นผลประเมินของสินค้า SKU01 มีค่าน้ำหนักอยู่ที่ Alpha 0.5 และ Beta 0.01 ซึ่งส่งผลให้การพยากรณ์มีผลประเมินค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 11.10%

ผลการพยากรณ์แบบ Autoregressive Integrated Moving Average (ARIMA)

จากผลการคำนวณผ่าน Google colab ซึ่งเริ่มจากการทำความสะอาดข้อมูลและทำการแบ่งข้อมูลเพื่อทำการฝึกฝน 70% และทดสอบ 30% หลังจากนั้นทำการปรับชุดข้อมูลให้คงที่และดำเนินการหาวิธีการค่าน้ำหนัก p,d,q ที่ดีที่สุดด้วย Grid search โดยกำหนดช่วง p อยู่ที่ 0-3 ,dอยู่ที่ 0-2 และ q อยู่ที่ 0-3 ซึ่งผลลัพธ์ที่ได้ มีดังนี้

ตารางที่ 8 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยแบบจำลองแบบ Autoregressive Integrated Moving Average (ARIMA)

รายการสินค้า	Autoregressive Integrated Moving Average (ARIMA)					
	p	q	d	MAE	MSE	MAPE
SKU01	3	1	0	2817	13457923	8.29%
SKU02	0	1	1	4942	47549493	17.22%
SKU03	0	0	0	5828	54043007	29.21%
SKU04	0	0	0	5253	47401834	25.02%
SKU05	1	1	0	90427	935199378	73.29%
SKU06	3	1	1	2890	15452765	57.59%
SKU07	1	0	0	4300	27470783	77.09%

ที่มา: ผู้วิจัย

หลังจากการประมวลผลการพยากรณ์ของรายการสินค้าแต่ละรายการด้วยแบบจำลองแบบ Autoregressive Integrated Moving Average (ARIMA) พบว่า ผลประเมินของสินค้า SKU01 มีค่า น้ำหนักอยู่ที่ p,q,d = 3,1,0 ซึ่งส่งผลให้การพยากรณ์มีผลประเมินค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 8.29%

ผลการพยากรณ์โดยการเรียนรู้ของเครื่อง

ในกลุ่มของการพยากรณ์การเรียนรู้ของเครื่องได้นำ Google colab ในการพยากรณ์เช่นเดียวกันกับการพยากรณ์แบบอนุกรมเวลาแบบดั้งเดิมโดยจากการสำรวจรูปแบบของข้อมูลและทำการความสะอาดข้อมูล หลังจากนั้นทำการปรับ Hyperparameter ในแต่ละรูปแบบพยากรณ์โดยการใช้ Grid search เพื่อทำการหาค่าที่ให้ในการปรับแต่งรูปแบบการเรียนรู้โดยการกำหนด Hyperparameter Optimizer ['adam', 'rmsprop'] , Batch size [8, 16, 32], และ epochs [50, 100, 150] โดยวัดเลือกค่าที่ดีที่สุด

ผลการพยากรณ์ด้วยโครงข่ายประสาทเทียม (Artificial Neural Network, ANN)

ตารางที่ 9 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยโครงข่ายประสาทเทียม (Artificial Neural Network, ANN)

รายการสินค้า	Parameter		Train			Test		
	Epoch	Optimizer	MAE	MSE	MAPE	MAE	MSE	MAPE
SKU01	100	adam	4246	28965958	13.14%	5083.54	52067094.9	11.26%
SKU02	100	adam	5288	51395112	17.27%	3370	14433054	9.09%
SKU03	50	adam	5568	76257376	28.17%	17729.59	456521664	65.96%
SKU04	50	adam	5343	49540752	24.22%	3852	21510016	22.72%
SKU05	100	adam	2636	58176560	10.00%	5525	41688316	13.29%
SKU06	50	adam	3007	23502018	34.73%	913	956170	28.19%
SKU07	150	Adam	5065	43135288	35.98%	823	968783	28.56%

ที่มา: ผู้วิจัย

หลังจากการประมวลผลการพยากรณ์ของรายการสินค้าแต่ละรายการการพยากรณ์ด้วยโครงข่ายประสาทเทียมพบว่าผลประเมินของสินค้า SKU02 มีมีผลประเมินค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 9.09%

ผลการพยากรณ์ด้วยนิวรัลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network, RNN)

ตารางที่ 10 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วย นิวรัลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network, RNN)

รายการสินค้า	Parameter		Train			Test		
	Epoch	Optimizer	MAE	MSE	MAPE	MAE	MSE	MAPE
SKU01	50	rmsprop	6987	63771955	19.87%	5826.03	64140552.2	12.92%
SKU02	100	adam	5402	58144052	16.63%	4160	23745935	11.12%
SKU03	100	rmsprop	14006	242407570	46.87%	17822.92	670099655	46.87%
SKU04	50	adam	7517	105867854	28.03%	6482	61398291	35.37%
SKU05	50	rmsprop	3564	60547577	15.43%	18849	372068840	44.92%
SKU06	50	adam	9740	230123740	62.57%	1969	4118931	60.38%
SKU07	50	rmsprop	7140	77682260	50.32%	951	1619639	33.36%

ที่มา: ผู้วิจัย

จากการประมวลผลการพยากรณ์ของรายการสินค้าแต่ละรายการการพยากรณ์ด้วยนิวรัลเน็ตเวิร์กแบบวนกลับพบว่าผลประเมินของสินค้า SKU02 มีมีผลประเมินค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 11.12%

ผลการพยากรณ์ด้วย Long Short-Term Memory (LSTM)

ตารางที่ 11 ผลประเมินค่าความคลาดเคลื่อนจากการพยากรณ์สินค้าทั้ง 7 รายการด้วยด้วย Long Short-Term Memory (LSTM)

รายการสินค้า	Parameter		Train			Test		
	Epoch	Optimizer	MAE	MSE	MAPE	MAE	MSE	MAPE
SKU01	100	rmsprop	7471	76178030	21.02%	10809.79	169453411	24.97%
SKU02	100	adam	16.51	59044584	16.51%	4146	23110392	11.13%
SKU03	50	rmsprop	15799	301396972	52.22%	18943	670693719	52.34%
SKU04	50	adam	6805	73859163	26.59%	5425	37826728	28.92%
SKU05	100	adam	4930	70220624	24.31%	30033	913166206	72.19%
SKU06	50	adam	9740	230123740	62.57%	1969	4118931	60.38%
SKU07	50	adam	7495	76052247	51.20%	980	1982490	29.69%

ที่มา: ผู้วิจัย

จากการประมวลผลการพยากรณ์ของรายการสินค้าแต่ละรายการการพยากรณ์ด้วยนิวรัลเน็ตเวิร์กแบบวนกลับพบว่าผลประเมินของสินค้า SKU02 มีมีผลประเมินค่าความคลาดเคลื่อนต่ำที่สุดโดย MAPE อยู่ที่ 12.49%

เปรียบเทียบผลการศึกษาแบ่งตามรายการสินค้าของวิธีการพยากรณ์ทั้ง 2 กลุ่ม 8 วิธี

หลังจากได้ผลการประเมินค่าความคลาดเคลื่อนทั้งหมด 8 วิธีและนำมาเปรียบเทียบกับทุกรายการสินค้า โดยกรณีการพยากรณ์โดยการเรียนรู้เครื่องได้ทำการแบ่งสัดส่วนของการ Training ข้อมูลและทำการ Test เพื่อนำค่าความคลาดเคลื่อนจากข้อมูล Test ของแต่ละเทคนิคซึ่งสามารถจำแนกโดยแบ่งตามรายการสินค้าตามตารางที่ 12 – 18 ได้ดังนี้

ตารางที่ 12 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU01

Item	Category	Forecast Model	MAD	MSE	MAPE
SKU01	Traditional Statistical Time Series	SMA	3789.93	27032015	9.89%
		DMA	4112	22939641	10.91%
		SES	4517	35553195	12.39%
		DES	4543	35291	12.38%
		ARIMA	4835	69337060	14.46%
	Neural Network	ANN	4151	35759580	9.48%
		RNN	**4192**	**42866464**	**9.20%**
		LSTM	5608	59672976	12.49%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์ด้วยด้วยด้วยนิวรัลเน็ตเวิร์กแบบวนกลับมีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU01 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 9.20%

ตารางที่ 13 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU02

Item	Category	Forecase Model	MAD	MSE	MAPE
SKU02	Traditional Statistical Time Series	SMA	4447	36624173	14.57%
		DMA	4548	38622177	14.84%
		SES	4737	42145341	15.80%
		DES	4809	38764122	16.75%
		ARIMA	4946	43728746	18.23%
	Neural Network	ANN	2773	10163329	7.78%
		RNN	**2704**	**10287718**	**7.61%**
		LSTM	35.22	1742	40.56%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์ด้วยด้วยนิวรัลเน็ตเวิร์กแบบวนกลับมีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU02 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 7.61%

ตารางที่ 14 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU03

Item	Category	Forecast Model	MAD	MSE	MAPE
SKU03	Traditional Statistical Time Series	SMA	8463.43	163580300	34.27%
		DMA	8974.29	198282600	31.31%
		SES	8061.01	146509187	34.08%
		DES	8010.26	157141590	37.32%
		ARIMA	**5827.88**	**54043007**	**29.21%**
	Neural Network	ANN	17729.59	456521664	65.96%
		RNN	17822.92	670099655	46.87%
		LSTM	18943	670693719	52.34%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์ด้วยARIMA มีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU03 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 29.21%

ตารางที่ 15 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU04

Item	Category	Forecast Model	MAD	MSE	MAPE
SKU04	Traditional Statistical Time Series	SMA	5294	45794370	26.50%
		DMA	5573	48884100	27.72%
		SES	5016	43876369	25.94%
		DES	5059	44058304	26.44%
		ARIMA	5253	47401834	25.02%
	Neural Network	ANN	**3852**	**21510016**	**22.72%**
		RNN	6482	61398291	35.37%
		LSTM	5425	37826728	28.92%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์แบบโครงข่ายประสาทเทียม มีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU04 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 22.72%

ตารางที่ 16 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU05

Item	Category	Forecast Model	MAD	MSE	MAPE
SKU05	Traditional Statistical Time Series	SMA	3746	58276999	12.66%
		DMA	4486	79277610	14.91%
		SES	**2913**	**44163905**	**9.86%**
		DES	2986	44643175.25	10.13%
		ARIMA	90427	935199378	73.29%
	Neural Network	ANN	5525	41688316	13.29%
		RNN	18849	372068840	44.92%
		LSTM	30033	913166206	72.19%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์แบบแบบหาค่าเฉลี่ยเคลื่อนที่คู่ซึ่งค่า Alpha ที่ทำการพยากรณ์มีค่าเท่ากับ 1 มีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU05 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 9.86%

ตารางที่ 17 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU06

Item	Category	Forecast Model	MAD	MSE	MAPE
SKU06	Traditional Statistical Time Series	SMA	2368	17033340	55.95%
		DMA	2716	22285960	75.00%
		SES	2383	16379443	44.49%
		DES	2672	16542968	56.43%
		ARIMA	2890	15452765	57.59%
	Neural Network	ANN	913	956170	28.19%
		RNN	968	1126236	28.98%
		LSTM	1969	4118931	60.38%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์ด้วยด้วยโครงข่ายประสาทเทียมมีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU06 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 28.19%

ตารางที่ 18 ผลการประเมินค่าความคลาดเคลื่อนด้วยทั้งหมดของสินค้า SKU07

Item	Category	Forecast Model	MAD	MSE	MAPE
SKU07	Traditional Statistical Time Series	SMA	3940	820695	56.77%
		DMA	4038	28655750	62.77%
		SES	3562	27920460	56.67%
		DES	3637	29836502	64.38%
		ARIMA	4300	27470783	77.09%
	Neural Network	ANN	**823**	**968783**	**28.56%**
		RNN	951	1619639	33.36%
		LSTM	980	1982490	29.69%

ที่มา: ผู้วิจัย

จากผลการประเมินค่าความคลาดเคลื่อนทั้ง 2 กลุ่มทั้งหมด 8 วิธีพบว่าการพยากรณ์แบบด้วยโครงข่ายประสาทเทียมมีผลประเมินค่าความคลาดเคลื่อนเมื่อทำการพยากรณ์ยอดขายของสินค้ารายการ SKU07 ที่ให้ค่า MAPE ต่ำที่สุดอยู่ที่ 28.56%

สรุปผลการประเมินแบ่งตามค่าความแม่นยำของตัวแบบพยากรณ์

ตารางที่ 19 ผลค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ Mean Absolute Error (MAE) ที่ได้โดยเป็นหน่วยยอดขายเป็นกิโลกรัม

Method	Traditional Statistical Time Series					Neural Network		
Item	SMA	DMA	SES	DES	ARIMA	ANN	RNN	LSTM
SKU01	3751	4346	3986	4087	**2817**	5084	5826	10810
SKU02	4447	4548	4368	4424	4942	**3370**	4160	4146
SKU03	8463	8974	8061	8010	**5828**	17730	17823	18943
SKU04	5294	5573	5016	5059	5253	**3852**	6482	5425
SKU05	3746	4486	**2913**	2986	90427	5525	18849	30033
SKU06	2368	2716	2383	2672	2890	**913**	1969	1969
SKU07	3940	4038	3562	3637	4300	**823**	951	980

ที่มา: ผู้วิจัย

หลังจากประเมินและได้ผลค่าความคลาดเคลื่อนด้วยค่าเฉลี่ยคลาดเคลื่อนสัมบูรณ์มีจุดสังเกตุเกี่ยวกับค่า MAE ในหลายประเด็นเริ่มจากการพยากรณ์แบบ ARIMA มีค่า MAE เฉลี่ยสูงมากเช่นรายการ SKU05 ซึ่งมีค่า MAE สูงผิดปกติถึง 90427 ซึ่งอาจเป็นค่าผิดปกติของข้อมูลหรืออาจจะเกิดจากการตั้งค่าที่ไม่เหมาะสมซึ่งอาจจะเกิดเช่นเดียวกับกรณีของ LSTM และ RNN มีค่า MAE สูงในหลาย SKU โดยเฉพาะ SKU03 และ SKU05 หรือไม่เหมาะกับข้อมูลชุดนี้ ANN มีประสิทธิภาพดีในหลาย SKU โดยเฉพาะ SKU ที่มีค่า MAE ต่ำมาก เช่น SKU06 และ SKU07

ตารางที่ 20 ผลค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่าความคลาดเคลื่อนที่ได้จะแสดงส่วนต่างกำลังสอง Mean Squared Error (MSE) ระหว่างค่าที่พยากรณ์และค่าจริง

Method	Traditional Statistical Time Series					Neural Network		
Item	SMA	DMA	SES	DES	ARIMA	ANN	RNN	LSTM
SKU01	27032020	34164140	28680627	32512950	**13457923**	52067095	64140552	169453411
SKU02	36624170	38622118	34392389	34899840	47549493	**14433054**	23745935	23110392
SKU03	163580300	198282600	146509187	157141590	**54043007**	456521664	670099655	670693719
SKU04	45794370	48884100	43876369	44058304	47401834	**21510016**	61398291	37826728
SKU05	58276999	79277610	44163905	44643175	935199378	**41688316**	372068840	913166206
SKU06	17033340	22285960	16379443	16542968	15452765	**956170**	4118931	4118931
SKU07	**820695**	28655750	27920460	29836502	27470783	968783	1619639	1982490

ที่มา: ผู้วิจัย

จากผลของค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MSE) การพยากรณ์แบบ ANN เป็นวิธีที่ให้ผลดีที่สุดใน 4 จาก 7 รายการ ถัดมาคือ ARIMA 2 รายการโดยค่า MSE ต่ำที่สุดเป็นการพยากรณ์ด้วย SMA ของ SKU07 โดยANN มีแนวโน้มให้ผลลัพธ์ที่ดีและเสถียรในหลาย SKU เมื่อเทียบกับการพยากรณ์ด้วยวิธีอื่น

ตารางที่ 21ผลค่าความคลาดเคลื่อนจะแสดงในรูปแบบเปอร์เซ็นต์ของยอดขาย Mean Absolute Percentage Error (MAPE)

Method	Traditional Statistical Time Series					Neural Network		
Item	SMA	DMA	SES	DES	ARIMA	ANN	RNN	LSTM
SKU01	9.85%	10.84%	11.09%	11.10%	**8.29%**	11.26%	12.92%	24.97%
SKU02	14.56%	14.84%	14.27%	15.03%	17.22%	**9.09%**	11.12%	11.13%
SKU03	34.27%	31.31%	34.08%	37.32%	**29.21%**	65.96%	46.87%	52.34%
SKU04	26.50%	27.72%	25.94%	26.44%	25.02%	**22.72%**	35.37%	28.92%
SKU05	12.66%	14.91%	**9.86%**	10.13%	73.29%	13.29%	44.92%	72.19%
SKU06	55.95%	75.00%	44.49%	56.43%	57.59%	**28.19%**	60.38%	60.38%
SKU07	56.77%	62.77%	56.67%	64.38%	77.09%	**28.56%**	33.36%	29.69%

ที่มา: ผู้วิจัย

ผลที่ได้มีความสอดคล้องการค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ คือการพยากรณ์แบบ ANN เป็นวิธีที่ให้ผลดีที่สุดใน 4 จาก 7 รายการ ถัดมาคือ ARIMA 2 รายการ โดยANN มีการมีค่าเฉลี่ย MAPE ที่น้อยและต่ำที่สุด ARIMA และ LSTM มีค่าเฉลี่ย MAPE สูงโดยบาง SKU ได้ผลดีมาก แต่บาง SKU แย่มากวิธีอนุกรมแบบดั้งเดิม ทั้ง SMA, DMA, SES, DES มีความผันผวนปานกลาง

ตารางที่ 22 ตารางสรุปวิธีการพยากรณ์ที่แม่นยำที่สุดของสินค้าแต่ละรายการ

รายการสินค้า	วิธีการพยากรณ์มีค่าความคลาดเคลื่อนน้อยที่สุด
SKU01	Autoregressive Integrated Moving Average (ARIMA)
SKU02	โครงข่ายประสาทเทียม (ANN)
SKU03	Autoregressive Integrated Moving Average (ARIMA)
SKU04	โครงข่ายประสาทเทียม (ANN)
SKU05	ปรับเรียบเอ็กซ์โปเนียนเชียลชั้นเดียว (SES)
SKU06	โครงข่ายประสาทเทียม (ANN)
SKU07	โครงข่ายประสาทเทียม (ANN)

ที่มา: ผู้วิจัย

พบว่าวิธีการพยากรณ์ที่ส่งผลให้ค่าความคลาดเคลื่อนน้อยที่สุดคือวิธีการพยากรณ์แบบโครงข่ายประสาทเทียมใช้ได้ดีกับสินค้ารายการที่ SKU02, SKU04, SKU06, SKU07 และแบบ Autoregressive Integrated Moving Average (ARIMA) ซึ่งใช้ได้ดีกับสินค้ารายการที่ SKU01 และ SKU03 2 รายการตามด้วยการพยากรณ์ปรับเรียบเอ็กซ์โปเนนเชียลชั้นเดียว (SES) ให้ค่าความคลาดเคลื่อนของการพยากรณ์ที่ใช้ได้ดีกับสินค้ารายการ SKU05

บทที่ 5
สรุปอภิปรายผลและข้อเสนอแนะ

สรุปผลการวิจัยของเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม

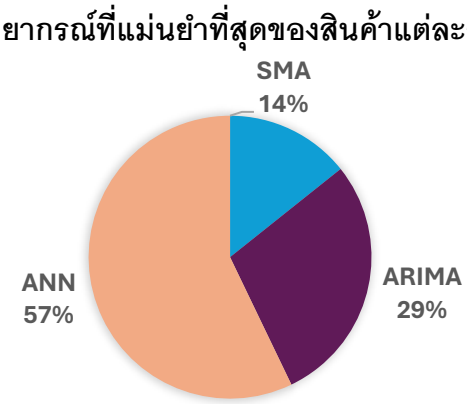
ค่าเฉลี่ยของ MAE และ MSE ในกลุ่มนี้ต่ำกว่ากลุ่ม Machine Learning อย่างมีนัยสำคัญโดย MAE เฉลี่ยอยู่ที่ประมาณ 6,980 และ MSE เฉลี่ยอยู่ที่ 75,470,487 ซึ่งแสดงค่าความแตกต่างที่มีความแม่นยำที่ดีและค่าความผิดพลาดไม่มากนอกจากนี้ ค่า MAPE เฉลี่ยอยู่ที่ 32%

สรุปผลการวิจัยของเทคนิคการเรียนรู้ด้วยเครื่อง

ผลการการศึกษาพบว่าค่า MAE และ MSE เฉลี่ยของกลุ่มนี้สูงกว่ากลุ่มอนุกรมเวลาแบบดั้งเดิม โดย MAE เฉลี่ยอยู่ที่ 7,888 และ MSE เฉลี่ยสูงถึง 171,699,467 ซึ่งอาจสะท้อนถึงความไม่เสถียรหรือการโมเดลมีความไม่เหมาะสม overfit โดยเฉพาะเมื่อข้อมูลไม่เพียงพอ อย่างเช่น SKU05 ที่มีไม่มีข้อมูลการขายใน 10 เดือนแรกหรือ การลดลงอย่างรวดเร็วของสินค้ารายการ SKU06 และ SKU07 อย่างไรก็ตาม ค่า MAPE เฉลี่ยอยู่ที่ 33% ซึ่งใกล้เคียงกับกลุ่มอนุกรมเวลาแสดงให้เห็นว่าในเชิงสัดส่วนของความผิดพลาดของการพยากรณ์ด้วยการเรียนรู้ด้วยเครื่องยังสามารถพิจารณาใช้ได้โดยความสามารถในการเรียนรู้จากข้อมูลจำนวนมากและการจับความสัมพันธ์ที่ซับซ้อนเพื่อการตีความและการพิจารณาการเพิ่มปัจจัยที่พิจารณาในอนาคตเช่น วงจรการขายสินค้าราย รายการสินค้าเป็นต้น

สรุปผลการศึกษา

ผลการศึกษาการพยาการณ์อุปสงค์เปรียบเทียบระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิมซึ่งมีวัตถุประสงค์คือสามารถเปรียบเทียบโมเดลระหว่างการพยากรณ์แบบเดิมและการพยากรณ์โดยการเรียนรู้เครื่องเพื่อทำความเข้าใจเพื่อการนำไปใช้กับข้อมูลต่าง ๆ ที่ต้องการทำการพยากรณ์ได้อย่างเหมาะสมยิ่งขึ้น โดยหลังจากดำเนินการทดสอบและดำเนินการจนได้ผลของการพยากรณ์ดังนี้



ภาพที่ 6 สัดส่วนวิธีการพยากรณ์ที่แม่นยำที่สุดของแต่ละวิธีการพยากรณ์
ที่มา: ผู้วิจัย

การพยากรณ์โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) มีค่าความคลาดเคลื่อนต่ำที่สุดสำหรับ SKU02 (MAPE = 9.09%), SKU04 (MAPE = 22.72%), SKU06 (MAPE = 28.19%) และ SKU07 (MAPE = 28.56%) ตามด้วยแบบ Autoregressive Integrated Moving Average (ARIMA) มีค่าความคลาดเคลื่อนต่ำที่สุดสำหรับ SKU01 (MAPE = 8.29%), SKU05 (MAPE = 12.66%) และ SKU03 (MAPE = 29.21%) และหากแบ่งตามสัดส่วนระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิมนั้นพบว่าเทคนิคการเรียนรู้ด้วยเครื่องมีผลการประเมินค่าความคลาดเคลื่อนในการพยากรณ์สามารถใช้ได้ดีกับการพยากรณ์สินค้าทั้งหมด 4 รายการคิดเป็น 57% โดยมากกว่าเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม 3 รายการหรือคิดเป็น 43%



ภาพที่ 7 สัดส่วนวิธีการพยากรณ์ที่แม่นยำที่สุดแบ่งระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิม

ที่มา: ผู้วิจัย

ข้อเสนอแนะ

ผลการศึกษาในงานวิจัยนี้เป็นการศึกษาระหว่างเทคนิคการเรียนรู้ด้วยเครื่องกับเทคนิคการพยากรณ์อนุกรมเวลาด้วยวิธีสถิติแบบดั้งเดิมซึ่งทางผู้วิจัยได้มีข้อเสนอแนะหลังจากการวิจัย รวมถึงแนวทางได้การปรับปรุงพัฒนาที่ได้การการศึกษาดังนี้

รูปแบบของข้อมูลในการพยากรณ์

จะเห็นได้ว่าลักษณะความต้องการบางรายการสินค้านั้นมีความผันผวนสูงและจับแนวโน้มได้ยากจึงอาจจะจำเป็นที่ต้องการประเมินโมเดลใหม่และมีการประเมินเป็นระยะเช่น 3 เดือนซึ่งอิงจากข้อมูลความแม่นยำของค่าเฉลี่ยเคลื่อนที่ซึ่งน่าจะมีความอยู่ที่ประมาณ 3 เดือน เมื่อดูจากสินค้าทุกรายการทั้งการพยากรณ์ในแบบ SMA และ DMA

การปรับปรุงคุณภาพของข้อมูลความต้องการจริงที่นำมาใช้ในการพยากรณ์ เช่น การทำความสะอาดข้อมูลการเติมข้อมูลที่ขาดหายและการตรวจสอบความถูกต้องของข้อมูลอาจพิจารณาการใช้ข้อมูลเพิ่มเติมจากแหล่งข้อมูลภายนอก เช่น ข้อมูลเศรษฐกิจ ข้อมูลสภาพอากาศ และข้อมูลการตลาด เพื่อเพิ่มความแม่นยำในการพยากรณ์เพราะเนื่องจากระยะเวลาของข้อมูลที่มี 36 เดือนอาจจะไม่เพียงพอต่อการปรับปรุงความแม่นยำในการพยากรณ์

การเลือกรูปแบบการพยากรณ์นำไปใช้

ลักษณะของข้อมูลในแต่ละรายการมีความผันผวนสูงและอาจจะมีปัจจัยอย่างเช่นอายุของวงจรผลิตภัณฑ์มีระยะสั้นซึ่งส่งผลต่อความต่อเนื่องของข้อมูลที่ทำการพยากรณ์นั้นมีความท้าทายในการเลือกวิธีการพยากรณ์ที่เหมาะสมสำหรับแต่ละรายการสินค้าและรูปแบบของข้อมูลยอดขายของสินค้านั้น ๆ โดยการใช้โครงข่ายประสาทเทียม (ANN) มีประสิทธิภาพสูงสำหรับสินค้าที่มีความซับซ้อนและไม่เป็นเชิงเส้น ในขณะที่บริษัทกรณีศึกษาสามารถ ใช้วิธีหา Autoregressive Integrated Moving Average (ARIMA) สำหรับสินค้าที่มีแนวโน้มคงที่และไม่มีความผันผวนมาก เช่นสินค้า 3 อันดับแรกเป็นต้นโดยสามารพัฒนารูปแบบการคำนวณใน python เพื่อนำมาช่วยในการคำนวณซึ่งสามารถทำได้โดยการกำหนดรูปแบบการนำเข้าข้อมูลได้จากไฟล์ spreadsheet ที่มีการอัพเดทผลยอดขายจริงได้ตลอดเวลา (Aloorravi, 2024; Chase, 2013; Hopfe et al., 2023; Quiñones-Rivera et al., 2023; Rodrigues et al., 2021; Sallis, 2002; VanderPlas, 2016; Zimmerman, 2020; เทียมศิริ, 2566; จันทรภา, 2564; พรหมณะ, 2566; ศฤงคารศิริ, 2565; สถิรมนวงศ์, 2564; สาริกา, 2566; สุขแก้ว, 2565; อุปกรณ์, 2564)

บรรณานุกรม

กรินทร์ กาญทนานนท์. (2561). *การพยากรณ์ทางสถิติ*. ซีเอ็ดยูเคชั่น.

ชุมพล ศฤงคารศิริ. (2565). *การวางแผนและควบคุมการผลิต*. สมาคมส่งเสริมเทคโนโลยี (ไทย-ญี่ปุ่น).

ชยากร อุปกรณ์. (2564). *การพยากรณ์ยอดขายรายวันของสินค้าที่มีราคาหลากหลายในธุรกิจค้าปลีกโดยใช้วิธีการเรียนรู้ของเครื่อง*, วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต, สาขาวิชาวิศวกรรมอุตสาหการ, คณะวิศวกรรมศาสตร์, จุฬาลงกรณ์มหาวิทยาลัย.

เทียร เทียมศักดิ์. (2566). *แนวโน้มธุรกิจ/อุตสาหกรรม ปี 2567-2569*: อุตสาหกรรมพลาสติก. https://www.krungsri.com/th/research/industry/industry-outlook/petrochemicals/plastics/io/io-plastics-2024-2026

ภมร สถิรมนวงศ์. (2564). *การปรับปรุงการพยากรณ์ความต้องการพัสดุบรรจุและนโยบายการเติมเต็มสินค้าคงคลังของพัสดุบรรจุสาหรับโรงงานผลิตเครื่องดื่มแอลกอฮอล์*, วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต, สาขาวิชาวิศวกรรมอุตสาหการ, คณะวิศวกรรมศาสตร์, จุฬาลงกรณ์มหาวิทยาลัย.

ธนพนธ์ สาริกา. (2566). *การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกหลายช่องทาง (*Omni Channel) : *กรณีศึกษาผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทย*, วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต, สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน, คณะโลจิสติกส์, มหาวิทยาลัยบูรพา.

พัชรี สุขแก้ว. (2565). *การพยากรณ์ความต้องการเพื่อวางแผนการสั่งซื้อวัตถุดิบล่วงหน้า กรณีศึกษาบริษัทผลิตชิ้นส่วนรถยนต์*, งานนิพนธ์วิทยาศาสตรมหาบัณฑิต, สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน, คณะโลจิสติกส์, มหาวิทยาลัยบูรพา.

วิทิตยาพร พรหมณะ. (2566). *การพยากรณ์ราคายางแผ่นรมควันในประเทศไทย*, การค้นคว้าอิสระวิทยาศาสตรมหาบัณฑิต, สาขาวิชาวิทยาการข้อมูล, บัณฑิตวิทยาลัย, มหาวิทยาลัยเชียงใหม่.

อุรชา จันทรภา. (2564). *การพยากรณ์มูลค่าการส่งออกรถยนต์ อุปกรณ์ และส่วนประกอบของประเทศไทย*, วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต, สาขาวิชาวิศวกรรมอุตสาหการ, คณะวิศวกรรมศาสตร์, จุฬาลงกรณ์มหาวิทยาลัย.

Aloorravi, S. (2024). *Mastering Time Series Analysis and Forecasting with Python*. Orange

Education Pvt Ltd.

Chase, C.W. (2013). *Demand-Driven Forecasting: A Structured Approach to Forecasting*. Wiley. https://books.google.co.th/books?id=iVIbAAAAQBAJ

Hopfe, D.H., Lee, K. & Yu, C. (2023). Short-term forecasting airport passenger flow during periods of volatility: Comparative investigation of time series vs. neural network models. Journal of Air Transport Management, 115.

Rivera, H.Q., Ovalle, O.R., & Morales, W.A., (2023). Demand Forecasting Using a Hybrid Model Based on Artificial Neural Networks: A Study Case on Electrical Products. Journal of Industrial Engineering and Management, 16(2), 363-381.

Rodrigues, L., Rumenos, L.R.M. & Bacchi, P. (2021). Performance evaluation of forecasting models based on time series and machine learning techniques: an application to light fuel consumption in Brazil. International Journal of Energy Sector Management, 16(4), 636-658.

Sallis, E. (2002). *Total Quality Management in Education* (3 ed.). Stylus Publishing Inc.

VanderPlas, J. (2016). *Python Data Science Handbook* O'Relly Media, Inc.

Zimmerman, G. (2020). *5 Supply Chain Chokepoints You Need to Fix. Association for Supply Chain Management (ASCM)*. https://www.ascm.org/ascm-insights/5-supply-chain-chokepoints-you-need-to-fix/

มหาวิทยาลัยบูรพา
BURAPHA UNIVERSITY

ประวัติย่อของผู้วิจัย

ชื่อ-สกุล	ชัยชนะ อารีย์วิจิตรวงษ์
วัน เดือน ปี เกิด	13 ธันวาคม 2531
สถานที่เกิด	ชลบุรี
สถานที่อยู่ปัจจุบัน	128/57 หมู่ 10 ต.หนองปรือ อ.บางละมุง จ.ชลบุรี
ประวัติการศึกษา	พ.ศ.2554 บริหารธุรกิจบัณฑิต (การจัดการโลจิสติกส์) มหาวิทยาลัยเกษตรศาสตร์
	พ.ศ.2568 วิทยาศาสตรมหาบัณฑิต (การจัดการโลจิสติกส์และโซ่อุปทาน) มหาวิทยาลัยบูรพา