การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกหลายช่องทาง (Omni Channel) : กรณีศึกษาผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทย

ธนพนธ์ สาริกา

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน
คณะโลจิสติกส์ มหาวิทยาลัยบูรพา
2566

ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกหลายช่องทาง (Omni Channel) : กรณีศึกษาผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทย

ธนพนธ์ สาริกา

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน
คณะโลจิสติกส์ มหาวิทยาลัยบูรพา
2566

ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

The Comparison of Demand Forecasting Techniques in Omnichannel Retail: A Case Study of Electrical and Electronic Products in Thailand

THANAPON SARIKA

A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF
THE REQUIREMENTS FOR MASTER DEGREE OF SCIENCE
IN LOGISTICS AND SUPPLY CHAIN MANAGEMENT
FACULTY OF LOGISTICS
BURAPHA UNIVERSITY
2023

COPYRIGHT OF BURAPHA UNIVERSITY

คณะกรรมการควบคุมวิทยานิพนธ์และคณะกรรมการสอบวิทยานิพนธ์ได้พิจารณาวิทยานิพนธ์ของ ธนพนธ์ สาริกา ฉบับนี้แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน ของมหาวิทยาลัยบูรพาได้

คณะกรรมการควบคุมวิทยานิพนธ์
อาจารย์ที่ปรึกษาหลัก

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

คณะกรรมการสอบวิทยานิพนธ์

..... ประธาน
(ผู้ช่วยศาสตราจารย์ ดร.สราวุธ จันทร์สุวรรณ)

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

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.จุฑาทิพย์ สุรารักษ์)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ชมพูนุท อ่ำช้าง)

..... คณบดีคณะโลจิสติกส์
(รองศาสตราจารย์ ดร. ณกร อินทร์พยุง)
วันที่.....เดือน.....พ.ศ.....

บัณฑิตวิทยาลัย มหาวิทยาลัยบูรพา อนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาการจัดการโลจิสติกส์และโซ่อุปทาน ของมหาวิทยาลัยบูรพา

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

64910161: สาขาวิชา: การจัดการโลจิสติกส์และโซ่อุปทาน; วท.ม. (การจัดการโลจิสติกส์และโซ่อุปทาน)
คำสำคัญ: การพยากรณ์ความต้องการ, ธุรกิจค้าปลีกหลายช่องทาง, การพาณิชย์อิเล็กทรอนิกส์, การวิเคราะห์ ABC

ธนพนธ์ สาริกา : การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกหลายช่องทาง (Omni Channel) : กรณีศึกษาผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทย. (The Comparison of Demand Forecasting Techniques in Omnichannel Retail: A Case Study of Electrical and Electronic Products in Thailand) คณะกรรมการควบคุมวิทยานิพนธ์: อนิรุทธ์ ขันธสะอาด ปี พ.ศ. 2566.

การพยากรณ์ที่มีประสิทธิภาพจะมีบทบาทสำคัญในการจัดการห่วงโซ่อุปทาน การควบคุมสินค้าคงคลัง และการตัดสินใจเชิงกลยุทธ์ งานวิจัยนี้นำเสนอการวิเคราะห์ที่ครอบคลุมของการพยากรณ์ยอดขายกลุ่มเครื่องใช้ไฟฟ้าขององค์กรกรณีศึกษาที่มีช่องทางการจัดจำหน่ายทั้งออนไลน์และออฟไลน์ โดยมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการพยากรณ์ความต้องการที่แม่นยำโดยใช้วิธีการวิเคราะห์ ABC เพื่อระบุรายการสินค้าที่มีผลกระทบต่อภาคธุรกิจมากที่สุดร่วมกับวิธีการพยากรณ์ที่กำหนด ได้แก่ การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก, การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปแนนเชียลชั้นเดียว, การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปแนนเชียลซ้ำสองครั้ง , Autoregressive Integrated Moving Average และ Feed-Forward Neural Network โดยใช้ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE), ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (MAD), ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (MAPE) ในการวัดค่าความคลาดเคลื่อนของการพยากรณ์ ซึ่งผลการวิจัยพบว่ารายการสินค้าช่องทางขายออนไลน์ 6 จาก 10 รายการระบุว่า วิธีการพยากรณ์แบบ WMA มีความแม่นยำมากที่สุด 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 โดยวิธีการที่นำเสนอสามารถลดต้นทุนของคงคลังต่อสัปดาห์ได้ประมาณร้อยละ 45 อย่างไรก็ตามแม้ว่าภาพรวมของรายการสินค้าทั้งสองช่องทางแบบจำลอง ARIMA จะให้ผลการพยากรณ์ที่มีประสิทธิภาพที่สุดแต่ในการนำไปใช้จริงควรพิจารณาร่วมกับแบบจำลองอื่นเพื่อวัดผลและเปรียบเทียบประสิทธิภาพด้วย

64910161: MAJOR: LOGISTICS AND SUPPLY CHAIN MANAGEMENT; M.Sc. (LOGISTICS AND SUPPLY CHAIN MANAGEMENT)

KEYWORDS: Demand Forecasting Model, Omni-channel, e-Commerce, ABC Analysis

THANAPON SARIKA : THE COMPARISON OF DEMAND FORECASTING TECHNIQUES IN OMNICHANNEL RETAIL: A CASE STUDY OF ELECTRICAL AND ELECTRONIC PRODUCTS IN THAILAND. ADVISORY COMMITTEE: ANIRUT KANTASAARD, 2023.

Effective forecasting plays an important role in supply chain management. the significance of accurate forecasting in supply chain, inventory management, and strategic decisions. Focusing on consumer electronics, it presents a comprehensive sales forecast model for both online and offline channels, utilizing the ABC analysis alongside various techniques including Weighted Moving Average (WMA), Single Exponential Smoothing (SES) and Double Exponential Smoothing (DES), Autoregressive Integrated Moving Average (ARIMA), and Feed-Forward Neural Network (FFNNs), evaluated through MSE, MAD, and MAPE. Results indicate the Weighted Moving Average as the most accurate for 6 of 10 online items (with average MAPE of 25.89%), while Autoregressive Integrated Moving Average stands out for 4 of 8 offline items (with average MAPE of 26.74%). A recalculated Safety Stock reduces minimum weekly holding costs by 1,746,848 Baht, potentially decreasing weekly inventory costs by 45%. However, the prominence of the Autoregressive Integrated Moving Average model suggests it be integrated with other models for comprehensive performance evaluation.

กิตติกรรมประกาศ

รายงานวิจัยฉบับนี้สำเร็จลุล่วงด้วยดีเนื่องจากความกรุณาและความช่วยเหลือจากผู้ช่วยศาสตราจารย์ ดร.อนิรุทธ์ ขันธสะอาดและอาจารย์ผรณกษม อินทรทัต ที่ได้เสียสละเวลาอันมีค่ายิ่ง ในการให้คำปรึกษาการดำเนินงานวิจัย ตลอดจนได้ตรวจสอบและแก้ไขข้อบกพร่องต่างๆอันเป็นประโยชน์ในการจัดทำ วิทยานิพนธ์ ตั้งแต่เริ่มดำเนินการจนกระทั่งดำเนินการเสร็จสมบูรณ์ ตลอดจนถึงผู้ช่วยศาสตราจารย์ ดร.สราวุธ จันทร์สุวรรณ ประธานกรรมการผู้ทรงคุณวุฒิภายนอก ผู้ช่วยศาสตราจารย์ ดร. จุฑาทิพย์ สุรารักษ์ กรรมการ และผู้ช่วยศาสตราจารย์ ดร. ชมพูนุท อ่ำช้าง กรรมการ ที่ได้ให้คำแนะนำในการสอบจนทำให้วิทยานิพนธ์ฉบับนี้สมบูรณ์มากยิ่งขึ้น ผู้ศึกษาขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

ขอขอบพระคุณครอบครัวของข้าพเจ้า ที่ได้ให้กำลังใจและส่งเสริมสนับสนุนกำลังทรัพย์ในการเล่าเรียนครั้งนี้จนสำเร็จการศึกษา

ขอขอบคุณผู้จัดการของบริษัทกรณีศึกษาตัวอย่าง ที่ได้กรุณาให้ความร่วมมือทางด้านข้อมูลรายละเอียดของการดำเนินงานวิจัยครั้งนี้ รวมไปถึงเพื่อนและพี่น้องที่มีส่วนเกี่ยวข้องในการเก็บข้อมูลและรวบรวมข้อมูลในการศึกษาเป็นอย่างดี

คุณค่าและประโยชน์ของการศึกษาครั้งนี้ ผู้ศึกษาขอมอบเป็นเครื่องบูชาบุพการี บูรพาจารย์และผู้ที่มีอุปการคุณทุกท่านที่มีส่วนส่งเสริมให้ผู้ศึกษาประสบความสำเร็จในการดำเนินชีวิตและก้าวหน้าในหน้าที่การงาน

ธนพนธ์ สาริกา

สารบัญ

หน้า

บทคัดย่อภาษาไทย ..... ง

บทคัดย่อภาษาอังกฤษ ..... จ

กิตติกรรมประกาศ ..... ฉ

สารบัญ ..... ช

สารบัญตาราง ..... ฌ

สารบัญภาพ ..... ฎ

บทที่ 1 บทนำ 1

1.1 ความสำคัญและที่มาของปัญหา 1

1.2 วัตถุประสงค์ของโครงการวิจัย 2

1.3 ขอบเขตของงานวิจัย 2

1.4 ประโยชน์ที่คาดว่าจะได้รับ 3

1.5 นิยามศัพท์เฉพาะ 3

บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง 4

2.1 กลยุทธ์การตลาดแบบไร้รอยต่อ (Omni Channel Marketing) 4

2.2 การวิเคราะห์จัดกลุ่มด้วยระบบเอบีซี (ABC Analysis) 7

2.3 วิธีการพยากรณ์ 11

2.4 การวัดค่าความคลาดเคลื่อนของการพยากรณ์ 12

2.5 Weighted Moving Average (WMA) 13

2.6 Single Exponential Smoothing Method (SES) 13

2.7 Double Exponential Smoothing Method (DES) 14

2.8 Autoregressive Integrated Moving Average (ARIMA) 14

2.9 Feedforward Neural network (FFNNs) 17
บทที่ 3 ระเบียบวิธีวิจัย 24
3.1 การเตรียมข้อมูล (Prepare Data) 26
3.2 การจัดหมวดหมู่ตามหลัก ABC Analysis 27
3.3 การพยากรณ์ (Forecasting) 28
3.4 เปรียบเทียบและวัดค่าความถูกต้องของผลการพยากรณ์ 30
3.5 การคำนวณต้นทุน 31
3.6 สรุปผล 31
บทที่ 4 ผลการวิจัย 32
4.1 การคัดเลือกรายการสินค้าที่จะนำมาพยากรณ์ด้วยวิธี ABC Analysis 32
4.2 การพยากรณ์ยอดขายของรายการสินค้า 35
4.3 ผลลัพธ์การพยากรณ์ทั้ง 5 วิธี (ออนไลน์) 49
4.4 ผลลัพธ์การพยากรณ์ทั้ง 5 วิธี (ออฟไลน์) 57
4.5 การคำนวณต้นทุน 66
บทที่ 5 สรุปอภิปรายผลและข้อเสนอแนะ 69
5.1 สรุปผลการศึกษา 69
5.2 ข้อเสนอแนะ 71
บรรณานุกรม 73
ประวัติย่อของผู้วิจัย 77

สารบัญตาราง

หน้า

ตารางที่ 1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้กลยุทธ์ Omni Channel 6
ตารางที่ 2 สรุปการนำ ABC Analysis มาใช้กับการพยากรณ์ 9
ตารางที่ 3 สรุปงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ 20
ตารางที่ 4 สรุปงานวิจัยที่เกี่ยวข้อง 22
ตารางที่ 5 ข้อมูลรายการสินค้าของสาขาออนไลน์และออฟไลน์ 34
ตารางที่ 6 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง WMA 35
ตารางที่ 7 แสดงค่า Error จากการพยากรณ์ปริมาณยอดขายสินค้าของสาขาออฟไลน์ด้วยแบบจำลอง WMA 37
ตารางที่ 8 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง SES 38
ตารางที่ 9 แสดงค่า Error จากการพยากรณ์ของสาขาออฟไลน์ด้วยแบบจำลอง SES 39
ตารางที่ 10 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง DES 40
ตารางที่ 11 แสดงค่า Error จากการพยากรณ์ของสาขาออฟไลน์ด้วยแบบจำลอง DES 41
ตารางที่ 12 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง ARIMA 43
ตารางที่ 13 แสดงค่า Error จากการพยากรณ์ของสาขาออฟไลน์ด้วยแบบจำลอง ARIMA 44
ตารางที่ 14 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง FFNNs 46
ตารางที่ 15 แสดงค่า Error จากการพยากรณ์ปริมาณยอดขายสินค้าของสาขาออฟไลน์ด้วยแบบจำลอง FFNNs 48
ตารางที่ 16 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU1 สาขาออนไลน์ 49
ตารางที่ 17 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU2 สาขาออนไลน์ 50
ตารางที่ 18 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU3 สาขาออนไลน์ 51
ตารางที่ 19 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU4 สาขาออนไลน์ 52
ตารางที่ 20 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU5 สาขาออนไลน์ 53

ตารางที่ 21 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU6 สาขาออนไลน์..... 53
ตารางที่ 22 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU7 สาขาออนไลน์..... 54
ตารางที่ 23 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU8 สาขาออนไลน์..... 55
ตารางที่ 24 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU9 สาขาออนไลน์..... 56
ตารางที่ 25 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU10 สาขาออนไลน์ 56
ตารางที่ 26 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้าสาขาออฟไลน์ 1 57
ตารางที่ 27 แสดงค่าเปรียบเทียบตัวชี้วัดแบบจำลองทั้ง 5 แบบของรายการสินค้าสาขาออฟไลน์ 2 58
ตารางที่ 28 แสดงค่าเปรียบเทียบตัวชี้วัดแบบจำลองทั้ง 5 แบบของรายการสินค้าสาขาออฟไลน์ 3 60
ตารางที่ 29 แสดงค่าเปรียบเทียบตัวชี้วัดแบบจำลองทั้ง5แบบของรายการสินค้าสาขาออฟไลน์4และ5 62
ตารางที่ 30 ตารางสรุปวิธีการพยากรณ์ที่แม่นยำที่สุดของสินค้าแต่ละรายการ 63
ตารางที่ 31 ตารางแสดงค่าสัมประสิทธิ์ความแปรปรวนของสินค้าแต่ละรายการ 64
ตารางที่ 32 ตารางแสดงจุดสั่งซื้อใหม่ของสินค้าแต่ละรายการ..... 66
ตารางที่ 33 ตารางแสดงปริมาณสินค้าคงคลังสำรองของสินค้าแต่ละรายการ 67
ตารางที่ 34 แสดงค่าเปรียบเทียบต้นทุนและปริมาณสินค้าคงคลังขั้นต่ำต่อสัปดาห์ 68

สารบัญภาพ

หน้า

ภาพที่ 1 ตัวอย่างแผนภาพพาเรโต้การแบ่งกลุ่มของ ABC Analysis 7
ภาพที่ 2 กรอบแนวคิดขั้นตอนการวิจัย 25
ภาพที่ 3 ตัวอย่างข้อมูลยอดขายที่ดึงมาจากระบบ 26
ภาพที่ 4 ตัวอย่างข้อมูล transection transfer ไปแต่ละสาขา 27
ภาพที่ 5 ตัวอย่างข้อมูล ABC Analysis ของยอดขายสินค้า 27
ภาพที่ 6 ตัวอย่างการใช้ฟังก์ชัน Solver ของ Microsoft Excel 28
ภาพที่ 7 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 1 สาขาออนไลน์ 50
ภาพที่ 8 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 2 สาขาออนไลน์ 51
ภาพที่ 9 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 3 สาขาออนไลน์ 51
ภาพที่ 10 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 4 สาขาออนไลน์ 52
ภาพที่ 11 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 5 สาขาออนไลน์ 53
ภาพที่ 12 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 6 สาขาออนไลน์ 54
ภาพที่ 13 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 7 สาขาออนไลน์ 54
ภาพที่ 14 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 8 สาขาออนไลน์ 55

ภาพที่ 15 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 9 สาขาออนไลน์ 56

ภาพที่ 16 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 10 สาขาออนไลน์ 57

ภาพที่ 17 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 1 57

ภาพที่ 18 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 2 58

ภาพที่ 19 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU3 สาขาออฟไลน์ 2 59

ภาพที่ 20 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 3 60

ภาพที่ 21 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU3 สาขาออฟไลน์ 3 61

ภาพที่ 22 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU4 สาขาออฟไลน์ 3 61

ภาพที่ 23 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 4 62

ภาพที่ 24 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 5 62

ภาพที่ 25 กราฟเปรียบเทียบต้นทุนมูลค่าสินค้าที่ต้องถือครองต่อสัปดาห์ระหว่างแบบปัจจุบันและแบบใหม่ 68

บทที่ 1
บทนำ

1.1 ความสำคัญและที่มาของปัญหา

ในปัจจุบันตลาดของธุรกิจ e-Commerce ในประเทศไทยมีแนวโน้มที่เพิ่มสูงขึ้น จากรายงานของ (SEA, 2020) ได้กล่าวว่าตลาด e-Commerce ของไทยมีมูลค่าอยู่ที่ 11,000 ล้านเหรียญสหรัฐในปี 2020 และคาดการณ์ว่าภายใน 5 ปีจะมีแนวโน้มเพิ่มสูงขึ้นถึง 52,000 ล้านเหรียญสหรัฐ ซึ่งคิดเป็นอัตราการเติบโตร้อยละ 35% ต่อปี นอกจากนี้รัฐบาลไทยยังให้การสนับสนุนภาค e-Commerce โดยจัดหาเงินทุนและมาตรการจูงใจด้านภาษีเพื่อส่งเสริมการเติบโต และออกมาตรการเพื่อปรับปรุงโครงสร้างพื้นฐานด้านลอจิสติกส์ รวมไปถึงการระบาดใหญ่ของโควิด-19 ยังเป็นปัจจัยหนึ่งที่เร่งให้เกิดการเปลี่ยนแปลงสู่ e-Commerce โดยผู้บริโภคจำนวนมากที่ต้องกักตัวอยู่บ้านได้ซื้อของผ่านทางช่องทางออนไลน์มากขึ้น แต่ว่าภายหลังช่วงการระบาดของโควิด-19 กลยุทธ์การตลาดในปัจจุบันหลายๆองค์กรได้มุ่งเน้นไปที่กลยุทธ์ Omni Channel กันมากขึ้น เพราะว่าช่องทางทั้งออฟไลน์และออนไลน์ยังคงมีความสำคัญทั้งคู่ ซึ่งพฤติกรรมของผู้บริโภคชาวไทยกว่า 82% นิยมซื้อสินค้ากับแบรนด์ที่มีทั้งหน้าร้านปกติและหน้าร้านออนไลน์ (Thompson, 2021) ซึ่งหน้าร้านปกติหรือช่องทางออฟไลน์จะมุ่งเน้นไปที่การนำเสนอการให้บริการหรือการตอบสนองความต้องการในทันที ส่วนร้านค้าออนไลน์จะมีข้อดีตรงที่ช่วยอำนวยความสะดวกสบายของผู้บริโภคสามารถเข้าถึงสินค้าได้หลากหลาย โดยสรุปแล้วทั้งช่องทางออฟไลน์และออนไลน์ต่างมีข้อได้เปรียบ เสียเปรียบที่แตกต่างกัน ซึ่งทางเลือกระหว่างช่องทางทั้งสองนั้นขึ้นอยู่กับความชอบและความต้องการของลูกค้าเป็นหลัก

หนึ่งในอุตสาหกรรมของตลาด e-Commerce ที่น่าสนใจคืออุตสาหกรรมเครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ โดยอุปกรณ์เครื่องใช้ไฟฟ้าถือได้ว่าเป็นปัจจัยหนึ่งที่สามารถอำนวยความสะดวกในชีวิตประจำวันของเราได้เป็นอย่างมาก ซึ่งการมาถึงของนวัตกรรม “อินเทอร์เน็ตสรรพสิ่ง” (Internet of things) แสดงให้เห็นว่าอุตสาหกรรมนี้ยังมีการพัฒนาอยู่ตลอดเวลา และ (ETDA, 2021) รายงานของสำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์ในปี 2021 ได้ระบุว่ากลุ่มร้านค้าธุรกิจคอมพิวเตอร์และอุปกรณ์อิเล็กทรอนิกส์มีขนาดใหญ่เป็นอันดับที่ 3 และมีมูลค่าของตลาดเพิ่มขึ้น 9.49% เมื่อเทียบกับปี 2563 สถิติเหล่านี้แสดงให้เห็นถึงความสำคัญที่เพิ่มขึ้นของอุตสาหกรรมเครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ของตลาด e-Commerce ในประเทศไทย

ความท้าทายที่สำคัญของธุรกิจที่มีหน้าร้านหลายสาขาหรือมีการดำเนินกลยุทธ์แบบไร้รอยต่อ (Omni Channel) คือความสามารถในการจัดการสต๊อกสินค้าในแต่ละสาขา เนื่องจากการสต๊อกสินค้าไว้แต่ล่ะที่จะมีต้นทุนสินค้าคงคลัง ถ้าหากมีการบริหารจัดการไม่ดี เช่น เมื่อลูกค้าต้องการสินค้าแต่

เมื่อไปถึงสาขาแล้วพบว่าที่สาขานี้ไม่มีของ ต้องรอสั่งของมาจากสาขาอื่นหรือจากคลังใหญ่ (DC) ซึ่งโดยทั่วไปอาจจะจัดส่งตามรอบรถ Milk-run หรือจะเป็นการเรียกใช้บริการรถด่วน ซึ่งจะช่วยในเรื่องของ Service level ตอบสนองความต้องการของลูกค้าได้เร็ว แต่ก็ต้องแบกรับต้นทุนที่เพิ่มขึ้น ไม่ว่าจะใช้วิธีไหนล้วนแต่ทำให้มีต้นทุนค่าขนส่งที่เพิ่มสูงขึ้น ดังนั้นการจัดการสต๊อกสินค้าที่มีประสิทธิภาพจะช่วยทำให้ต้นทุนของธุรกิจลดลง และสามารถตอบสนองความต้องการของลูกค้าได้อย่างทันท่วงที ลดการเสียโอกาสจากการขาย

แม้ในปัจจุบันจะมีแนวทางการแก้ปัญหาที่หลากหลายเช่น การวัดสภาพคล่องของสินค้าคงคลัง (Cover day) คือการประมาณการว่าสินค้าที่มีจะเพียงพอต่อความต้องการขายไปได้กี่วัน แต่เนื่องด้วยข้อจำกัดในกรณีที่องค์กรมีสินค้าที่หลากหลายและมีหลายสาขา การที่จะทำ Cover day กับสินค้าทั้งหมดแทบจะเป็นไปไม่ได้เนื่องจากจะทำให้องค์กรต้องแบกรับต้นทุนที่สูงจนเกินไป

ผู้วิจัยเล็งเห็นว่าปัญหานี้เป็นปัญหาที่มักจะเกิดขึ้นบ่อยๆไม่ว่าจะเป็นช่องทางออนไลน์หรือออฟไลน์ ถ้ามีของไม่เพียงพอกับความต้องการของผู้บริโภคก็จะทำให้สูญเสียโอกาสในการขายได้ ดังนั้นการพยากรณ์ความต้องการของลูกค้าเพื่อสต็อกสินค้าไว้จึงเป็นวิธีการที่ผู้วิจัยคิดว่าเหมาะสมที่สุด เนื่องจากวิธีการนี้มีต้นทุนที่ไม่สูงและสามารถใช้ข้อมูล transaction ของการขายจากระบบมาช่วยในการพยากรณ์ได้ ซึ่งประโยชน์ที่ได้รับนอกจากจะช่วยลดต้นทุนด้านต่างๆแล้วยังช่วยลดภาระงานของพนักงานจากการที่ต้องจัดเตรียมของหรือสินค้าเพื่อส่งไปยังสาขาที่ต้องการอีกด้วย

1.2 วัตถุประสงค์ของโครงการวิจัย

1.เพื่อศึกษาระดับความสำคัญของสินค้าเครื่องใช้ไฟฟ้าที่มีผลกระทบต่อยอดขายของบริษัทกรณีศึกษา

2.เพื่อศึกษาแบบจำลองการพยากรณ์ความต้องการของลูกค้า และสามารถระบุเปรียบเทียบโมเดลการพยากรณ์ยอดขายที่แม่นยำที่สุดของสินค้าประเภทเครื่องใช้ไฟฟ้าขององค์กรกรณีศึกษา

3.เพื่อเปรียบเทียบค่าความคลาดเคลื่อนและปรับปรุงประสิทธิภาพของแบบจำลองการพยากรณ์

4.ช่วยลดต้นทุนสินค้าคงคลังให้กับองค์กรกรณีศึกษาได้

1.3 ขอบเขตของงานวิจัย

การศึกษานี้ได้มีการใช้ข้อมูลยอดขายของสาขาออนไลน์และออฟไลน์จากระบบภายในขององค์กรกรณีศึกษา เป็นระยะเวลา 1 ปี ตั้งแต่เดือน มกราคม – ธันวาคม 2565 โดยลักษณะของข้อมูลจะเป็นยอดขายของสินค้าที่ดึงมาจากระบบภายในองค์กร ซึ่งสาขาที่เลือกจะแบ่งเป็น สาขาออนไลน์ 1 สาขา และสาขาออฟไลน์อีก 5 สาขา โดยทั้ง 5 สาขาของฝั่งออฟไลน์ได้เลือกมาจากปริมาณยอดขายที่สูงและเป็นสาขาขนาดใหญ่

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ยอดขายที่พยากรณ์จะช่วยให้ธุรกิจลดต้นทุนสินค้าคงคลังจากสินค้าบางรายการที่ขายไม่ดี และเพิ่มยอดขายจากสินค้ายอดนิยม เนื่องจากบริษัทสามารถนำเสนอผลิตภัณฑ์ที่ตอบสนองความต้องการและความพึงพอใจของลูกค้าได้

2. ความต้องการที่คาดการณ์สามารถรักษาระดับการให้บริการ (Service level) แก่ลูกค้าได้

3. ช่วยให้บริษัทเพิ่มประสิทธิภาพ ความแม่นยำ ในการจัดการสินค้าคงคลัง ลดสินค้าคงคลัง และเพิ่มความพึงพอใจของลูกค้า

4. การพยากรณ์ยอดขายที่แม่นยำสามารถช่วยให้องค์กรกรณีศึกษาตัดสินใจทางธุรกิจได้ดีขึ้น เช่น การปรับระดับการสต๊อกสินค้าและการกำหนดกลยุทธ์ด้านราคา ซึ่งโมเดลการพยากรณ์ที่แม่นยำที่สุดจะช่วยเป็นแนวทางให้บริษัทในอุตสาหกรรมหรือตลาดเดียวกันรวมไปถึงผู้ที่สนใจศึกษา ปรับปรุงความแม่นยำในการพยากรณ์

1.5 นิยามศัพท์เฉพาะ

1. การพาณิชย์อิเล็กทรอนิกส์ (e-Commerce) หมายถึง ธุรกิจพาณิชย์อิเล็กทรอนิกส์หรือการดำเนินการซื้อขายสินค้าและบริการผ่านระบบเครือข่ายคอมพิวเตอร์หรืออินเทอร์เน็ต

2. Omni Channel หมายถึง การรวมทุกช่องทางที่สามารถเข้าถึงลูกค้าหรือผู้บริโภคมาไว้ในที่เดียว โดยไม่ใช่แค่เฉพาะ Offline และ Online

3. หน้าร้านปกติ (Store offline) หมายถึง ช่องทางจัดจำหน่ายสินค้าหรือบริการที่มีสถานที่ตั้ง

4. หน้าร้านออนไลน์ (Store online) หมายถึง ช่องทางจัดจำหน่ายสินค้าหรือบริการที่อยู่บนอินเทอร์เน็ตโดยมีการซื้อขายผ่านแพลตฟอร์มต่างๆ

5. อินเทอร์เน็ตสรรพสิ่ง (Internet of things) หมายถึง การที่สิ่งของต่างๆรอบตัวเราสามารถเชื่อมโยงสู่โลกอินเทอร์เน็ต ให้เราสามารถสั่งการควบคุมการใช้งานอุปกรณ์ต่างๆผ่านทางเครือข่ายอินเทอร์เน็ตได้

6. มิลค์รัน (Milk-run) หมายถึง เทคนิคหนึ่งที่นำมาใช้เพื่อสนับสนุนระบบการผลิตแบบ just-in-time (Jit) เพื่อช่วยลดต้นทุนรวมของการขนส่งและลดปริมาณสินค้าคงคลัง

7. ระดับการให้บริการ (Service level) หมายถึง ความน่าจะเป็นที่ความต้องการของลูกค้าจะไม่สูงเกินกว่าปริมาณวัสดุคงคลังหรือสินค้าคงคลังที่มีในขณะนั้น

8. ข้อมูลธุรกรรม (Transaction) หมายถึง รายการธุรกรรมจะแสดงรายละเอียดของกิจกรรมต่างๆที่เกิดขึ้น

บทที่ 2
เอกสารและงานวิจัยที่เกี่ยวข้อง

การสต๊อกสินค้าให้เพียงพอต่อความต้องการของผู้บริโภคเป็นส่วนที่สำคัญส่วนหนึ่งต่อการตัดสินใจเลือกซื้อสินค้าหรือบริการ ในปัจจุบันองค์กรหลายๆแห่งมักจะพยายามรักษาระดับการให้บริการ Service level ของลูกค้าให้สูงอยู่เสมอเพื่อสร้างความได้เปรียบในการแข่งขันกับคู่แข่งรายอื่นในเรื่องของความเร็ว ทำให้ผู้ประกอบการจึงจำเป็นต้องพัฒนาและเพิ่มขีดความสามารถในการแข่งขันให้สูงขึ้น การเตรียมสินค้าให้เพียงพอต่อความต้องการของผู้บริโภคจึงเป็นส่วนหนึ่งที่สำคัญ หากมีการบริหารจัดการไม่ดีจะทำให้บริษัทมีต้นทุนที่สูงขึ้นได้

ในการศึกษานี้ผู้วิจัยได้ทำการศึกษาพื้นฐานของแนวคิดและทฤษฎีที่เกี่ยวข้องเพื่อใช้เป็นแนวทางในการดำเนินการวิจัยโดยมีสาระสำคัญดังนี้

แนวคิดและทฤษฎีที่เกี่ยวข้อง

2.1 กลยุทธ์การตลาดแบบไร้รอยต่อ (Omni Channel Marketing)

Eggdigital (2021) กลยุทธ์ทางธุรกิจที่มีเป้าหมายเพื่อให้ผู้บริโภคได้รับประสบการณ์จากบริการหรือสินค้าที่ราบรื่นและบูรณาการในหลายช่องทาง ซึ่งผู้บริโภคสามารถโต้ตอบกับแบรนด์หรือธุรกิจผ่านช่องทางต่างๆ เช่น ร้านค้าหน้าร้าน เว็บไซต์ แอปบนอุปกรณ์เคลื่อนที่ แพลตฟอร์มโซเชียลมีเดีย และช่องทางดิจิทัลอื่นๆ

Neslin (2006) ได้นิยามคำว่า “ช่องทาง” ว่าเป็นจุดหนึ่งที่ลูกค้าสามารถสื่อสารกับองค์กรหรือภาคธุรกิจได้ และได้จำแนกความแตกต่างระหว่าง Multi-channel และ Omni-channel ไว้ดังนี้

Multi-channel คือกลุ่มกิจกรรมการซื้อ-ขายที่มากกว่า 1 ช่องทาง แต่ลูกค้าไม่สามารถเชื่อมโยงแต่ละช่องทางได้ ทางด้านของ Omni-channel คือร้านค้าสามารถควบคุมช่องทางได้อย่างครบวงจร เช่น กรณีที่ลูกค้าซื้อของมาจากร้านค้าออนไลน์ แต่เมื่อต้องการเคลมสินค้าลูกค้าสามารถติดต่อกับทางร้านค้าที่เป็นช่องทางออฟไลน์ได้โดยไม่ต้องเคลมสินค้ากับช่องทางที่ซื้อมาในตอนแรก

Kitsupasin (2021) ได้ระบุเครื่องมือของการสื่อสารในช่องทางออฟไลน์และออนไลน์ไว้ดังนี้

เครื่องมือของการสื่อสารในช่องทางออฟไลน์

1. ประวัติขององค์กร (Company Profile) ในการสร้างความมั่นใจแก่ลูกค้าหรือผู้บริโภค ความน่าเชื่อถือขององค์กรเป็นเรื่องที่สำคัญ ประวัติขององค์กรจะเป็นช่องทางที่นำเสนอตัวธุรกิจและสร้างภาพลักษณ์ที่ดีให้กับองค์กร

2. รายการสินค้า (Catalog) รายการสินค้าที่หลากหลายรวมไปถึงการ สื่อสารกับลูกค้า โดยมีวัตถุประสงค์เพื่อให้ลูกค้าสามารถเข้าถึงรายละเอียดของสินค้าและบริการได้สะดวก เข้าใจได้ง่าย เพื่อเข้าถึงกลุ่มลูกค้าเป้าหมายได้อย่างรวดเร็ว

เครื่องมือของการสื่อสารในช่องทางออนไลน์

1. ช่องทางที่หลากหลาย ในปัจจุบันอินเทอร์เน็ตเข้ามามีบทบาทมากขึ้น และมีแพลตฟอร์มต่างๆเกิดขึ้นมากมาย ซึ่งช่องทางต่างๆจะเข้ามาช่วยทำให้ลูกค้าสามารถเข้าถึงสินค้าได้หลากหลายและอำนวยความสะดวกได้เป็นอย่างมาก

2. เว็ปไซต์ เป็นช่องทางที่สำคัญอย่างมาก ผู้บริโภคหรือลูกค้ามักจะค้นหารายละเอียดหรือข้อมูลของสินค้าก่อนการตัดสินใจซื้อเสมอ ดังนั้นเว็ปไซต์ที่ดีควรมีการนำเสนอที่เข้าใจง่าย ลูกค้าสามารถเข้าถึงสินค้าได้หลากหลาย สามารถเปรียบเทียบสินค้าก่อนการตัดสินใจซื้อได้

ประโยชน์ของกลยุทธ์การตลาดแบบไร้รอยต่อ

ประโยชน์ของภาคธุรกิจ

- ช่องทางในการขายสินค้าที่หลากหลาย ซึ่งจะช่วยเพิ่มโอกาสในการเข้าถึง และตัดสินใจเลือกซื้อให้กับลูกค้า
- สามารถสร้างประสบการณ์ที่ดีให้กับลูกค้าได้ ทำให้เกิดการแนะนำและบอกต่อ ซึ่งเป็นอีกช่องทางในการขยายกลุ่มลูกค้าให้กว้างขึ้น
- รวบรวมข้อมูลของลูกค้าเพื่อนำมาวิเคราะห์ เพื่อพัฒนาสินค้าหรือบริการให้น่าพึงพอใจมากยิ่งขึ้น
- เพิ่มความน่าเชื่อถือให้กับธุรกิจ เพราะการมีช่องทางติดต่อทั้งออนไลน์และออฟไลน์ จะทำให้ลูกค้าเกิดความเชื่อถือต่อธุรกิจมากยิ่งขึ้น

ประโยชน์ของผู้ซื้อ

- สามารถซื้อสินค้าได้สะดวก รวดเร็ว และมีหลากหลายช่องทางให้เลือก
- เลือกช่องทางในการชำระสินค้าได้หลากหลาย
- ติดต่อกับแบรนด์ หรือธุรกิจนั้นๆ ได้หลากหลายช่องทาง

งานวิจัยที่เกี่ยวข้องกับการทำ Omni Channel

Ploensuk, Yawila, & Sitt-uam (2022) มีวัตถุประสงค์เพื่อศึกษาความไว้วางใจ และการรับรู้คุณค่าเชิงประสบการณ์ที่ส่งผลต่อความตั้งใจสนับสนุนของผลิตภัณฑ์เครื่องสำอางจากธรรมชาติและสมุนไพรที่ใช้ช่องทางการจัดจำหน่ายแบบบูรณาการของผู้บริโภคในเขตอำเภอเมืองจังหวัดพิษณุโลกรวบรวมข้อมูลโดยใช้แบบสอบถามในกลุ่มตัวอย่างจำนวน 385 คน ทำการสุ่มตัวอย่างแบบสะดวก วิเคราะห์ข้อมูลด้วยสถิติเชิงพรรณนาได้แก่การแจกแจงความถี่ ค่าร้อยละ ค่าเฉลี่ยค่าเบี่ยงเบนมาตรฐานทดสอบสมมติฐานด้วยการวิเคราะห์ถดถอยเชิงพหุคูณ ผลการศึกษาพบว่า ความไว้วางใจด้านความสามารถ ความซื่อสัตย์ และความเมตากรุณา ส่งผลทางบวกต่อความตั้งใจสนับสนุน

ผลิตภัณฑ์ที่ใช้ช่องทางการจัดจำหน่ายแบบบูรณาการของผู้บริโภคในเขตอำเภอเมืองจังหวัดพิษณุโลก อย่างมีนัยสำคัญทางสถิติที่ 0.05 สามารถพยากรณ์ได้ร้อยละ 79.7

Ryu (2019) มุ่งเน้นไปที่การทำนายความตั้งใจในการจับจ่ายสินค้าในกลุ่มตลาดแฟชั่นของผู้บริโภคโดยใช้พฤติกรรมส่วนบุคคล โดยใช้ข้อมูลจากผู้บริโภคในสหรัฐอเมริกา 403 ราย และสร้างแบบจำลองสมการ Structural Equation Modeling (SEM) เพื่อทดสอบสมมติฐานที่เสนอ โดยผลการวิจัยระบุว่าลักษณะส่วนบุคคลเหล่านี้ส่งผลในเชิงบวกต่อความตั้งใจในการซื้อสินค้าแบบหลายช่องทางของผู้บริโภค

ตารางที่ 1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้กลยุทธ์ Omni Channel

Omni Channel	Authors	Method	Result
ในประเทศ	Ploensuk, Yawila, & Sitt-uam (2022)	ใช้แบบสอบถามในกลุ่มตัวอย่างจำนวน 385 คน วิเคราะห์ข้อมูลด้วยสถิติเชิงพรรณนาได้แก่การแจกแจงความถี่ ค่าร้อยละ ค่าเฉลี่ย ค่าเบี่ยงเบนมาตรฐาน ทดสอบสมมติฐานด้วย การวิเคราะห์ถดถอยเชิงพหุคูณ	ส่งผลทางบวกอย่างมีนัยสำคัญทางสถิติที่ 0.05
ต่างประเทศ	Ryu (2019)	ใช้ Structural Equation Modeling :SEM) ในการตรวจสอบความสัมพันธ์ระหว่างตัวแปร	ลักษณะส่วนบุคคล Fasion Innovativeness, Technology Innovativeness, Fashion Purchase Involvement, Omni-channel Shopping Intention ส่งผลในเชิงบวกต่อความตั้งใจในการซื้อสินค้าแบบหลายช่องทางของผู้บริโภค

ที่มา: ผู้วิจัย

2.2 การวิเคราะห์จัดกลุ่มด้วยระบบเอบีซี (ABC Analysis)

การบริหารสินค้าคงคลังด้วย ABC Analysis เป็นแนวคิดการบริหารจัดการสินค้าคงคลังด้วยการจัดกลุ่มสินค้าตามมูลค่าการใช้ในรอบระยะเวลาหนึ่ง โดยมีพื้นฐานมาจากพาเรโต้ นักเศรษฐศาสตร์และวิศวกรชาวอิตาลี เป็นแนวคิดที่ให้ความสำคัญกับการจัดกลุ่มสินค้าโดยแบ่งออกเป็น 3 กลุ่ม คือ มาก ปานกลาง และน้อย เพื่อให้ง่ายต่อการบริหารจัดการตามกลุ่มสินค้า โดยเกณฑ์การจัดมีหลายแบบตามแต่นโยบายขององค์กรนั้นๆ เช่น มูลค่ายอดขายของสินค้า การจัดลำดับสินค้าตามมูลค่าสินค้าคงคลัง

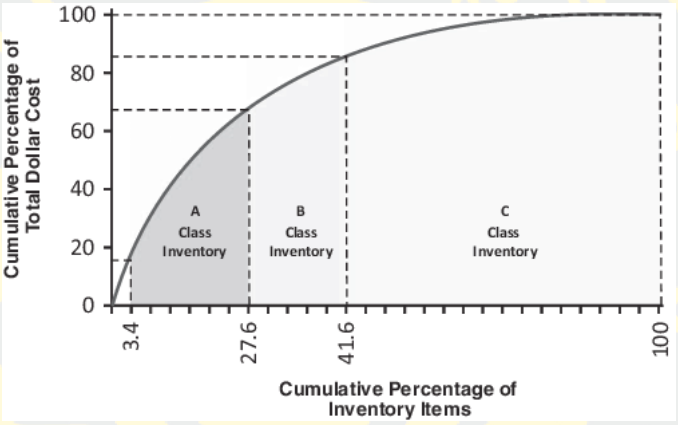

ภาพที่ 1 ตัวอย่างแผนภาพพาเรโต้การแบ่งกลุ่มของ ABC Analysis

ที่มา: (Sawadsaringkarn, 2022)

โดยทั่วไปแล้ว ABC analysis จะใช้ในการบริหารสินค้าคงคลังซึ่งจะแบ่งตามลำดับชั้นความสำคัญออกเป็น 3 ส่วนคือ A B และ C ดังนี้

A หมายถึงมีสินค้าคงคลังอยู่ที่ 15-20% ของรายการสินค้าทั้งหมด แต่มีมูลค่าอยู่ประมาณ 70-80% ของมูลค่าสินค้าทั้งหมด ดังนั้นสินค้าที่อยู่ในกลุ่มนี้ต้องได้รับการควบคุมอย่างเข้มงวดที่สุด เนื่องจากมีความสำคัญต่อภาคธุรกิจมากที่สุด

B หมายถึงมีสินค้าคงคลังอยู่ที่ 30-40% ของรายการสินค้าทั้งหมด แต่มีมูลค่าอยู่ประมาณ 15% ของมูลค่าสินค้าทั้งหมด ดังนั้นสินค้าที่อยู่ในกลุ่มนี้ต้องได้รับการควบคุมอย่างเข้มงวดในระดับปานกลาง

C หมายถึงมีสินค้าคงคลังอยู่ที่ 40-50% ของรายการสินค้าทั้งหมด แต่มีมูลค่าอยู่ประมาณ 5-10% ของมูลค่าสินค้าทั้งหมด ดังนั้นการควบคุมดูแลสินค้าในกลุ่มนี้จะไม่เข้มงวดมากนัก ส่วนใหญ่จะเป็นพวกสินค้าที่ขายไม่ดีหรือไม่ค่อยได้ใช้งานบ่อย (Dead Stock)

ซึ่งงานวิจัยฉบับนี้จะนำหลักการ ABC Analysis เข้ามาช่วยในการคัดกรองรายการสินค้าหรือ SKU ที่มีผลต่อปริมาณและยอดขายของธุรกิจกรณีศึกษา เพื่อให้ได้รายการสินค้าที่สำคัญมาใช้ในการพยากรณ์ต่อไป

งานวิจัยที่เกี่ยวข้องกับการทำ ABC Analysis

Xi & Sha (2014) ได้นำเสนอการเพิ่มประสิทธิภาพการจัดการสินค้าคงคลัง โดยใช้วิธีโมเดล exponential smoothing ในการพยากรณ์ และใช้ ABC ในการจำแนกประเภท โดยประเภท A มีเปอร์เซ็นต์สะสมอยู่ที่ 5% ซึ่งผลลัพธ์ได้ชี้ให้เห็นว่าวิธีการจัดการการจำแนกประเภท ABC สามารถช่วยเพิ่มประสิทธิภาพการพยากรณ์ได้ โดยลดปริมาณสินค้าคงคลังของวัสดุประเภท A ลงซึ่งช่วยลดต้นทุน Carrying Cost ลงได้

Worachotepanyaratana (2021) ได้ทำการศึกษากระบวนการทำงานของโรงงานเกี่ยวกับชิ้นส่วนยายนต์โลหะ ซึ่งกำลังประสบกับปัญหาที่สินค้าบางรายการมีปริมาณมากและน้อยเกินไปในบางช่วงเวลา ซึ่งปัญหานี้ส่งผลกระทบต่อต้นทุนของโรงงานเป็นอย่างมาก โดยทางผู้วิจัยได้วางแผนการพยากรณ์ความต้องการด้วยทฤษฎีการวิเคราะห์แบบ ABC Classification โดยมีวัตถุประสงค์เพื่อวิเคราะห์เทคนิคการพยากรณ์ความต้องการชิ้นส่วนยานยนต์ที่เหมาะสมสำหรับสินค้า Class A และเพื่อวิเคราะห์ปริมาณจุดสั่งซื้อใหม่ และลดต้นทุนการจัดเก็บสินค้า โดยเทคนิคที่นำมาใช้พยากรณ์มี Linear Trend Line Model, Exponential Smoothing และ Moving Averages โดยใช้ MAPE เป็นตัวชี้วัด ผลลัพธ์ที่ได้คือ สามารถลดต้นทุนไป 30%

Phuthongkham & Tiwaratreewit (2021) มีวัตถุประสงค์เพื่อหารูปแบบการพยากรณ์ที่เหมาะสม ลดต้นทุนค่าเสียโอกาส และเพื่อหาจุดสั่งซื้อใหม่ โดยมีปัญหาคือการจัดการวัตถุดิบที่เผื่อเหลือมากเกินไปทำให้เกิดการเน่าเสีย ผู้วิจัยได้พยากรณ์ความต้องการของพิซซ่า 7 รายการโดยมีกลุ่มตัวอย่างคือวัตถุดิบในการทำพิซซ่าจำนวน 13 รายการ ด้วยวิธีการพยากรณ์ การหาค่าเฉลี่ยเคลื่อนที่อย่างง่าย, หาค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก และวิธีหาค่าปรับเรียบเอกซ์โปเนนเชียล ซึ่งผลลัพธ์ที่ได้พบว่าวิธีการพยากรณ์แบบถัวเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก (Weighted Moving Average) เป็นวิธีที่เหมาะสมที่สุดโดยมีค่า MAD ต่ำที่สุดอยู่ที่ 2.31 แล้วนำรายการวัตถุดิบมาจัดกลุ่มตามความสำคัญด้วยวิธี ABC Analysis เพื่อคำนวณจุดสั่งซื้อใหม่ของวัตถุดิบกลุ่ม A ซึ่งผลที่ได้คือลดปัญหาการเสียโอกาสในการขายได้ถึง 8,762 บาทต่อเดือน

ตารางที่ 2 สรุปการนำ ABC Analysis มาใช้กับการพยากรณ์

ABC Analysis	Authors	Method	Result
ในประเทศ	Worachotepanyaratana (2021)	ใช้ ABC ในการจัดกลุ่มสินค้าเพื่อเลือกสินค้าที่อยู่ในกลุ่ม A มาพยากรณ์ด้วยวิธี Linear Trend Line Model, Exponential Smoothing และ Moving Averages โดยใช้ MAPE เป็นตัวชี้วัด	สามารถลดต้นทุนไป 30%
	Phuthongkham & Tiwaratreewit (2021)	Moving Average Weighted Moving Average Exponential Smoothing ใช้ MAD เป็นตัวชี้วัด นำรายการวัตถุดิบมาจัดกลุ่มตามความสำคัญด้วยวิธี ABC Analysis เพื่อคำนวณจุดสั่งซื้อใหม่	Weighted Moving Average มีค่า MAD 2.31 ลดปัญหาการเสียโอกาสในการขายได้ 8,762 บาทต่อเดือน
ต่างประเทศ	Xi & Sha (2014)	ใช้โมเดล exponential smoothing ในการพยากรณ์ และใช้ ABC ในการจำแนกประเภท	โดยลดปริมาณสินค้าคงคลังของวัสดุประเภท A ลง ซึ่งช่วยลดต้นทุน Carrying Cost

ที่มา: ผู้วิจัย

การคำนวณหาค่าสัมประสิทธิ์ความแปรปรวน (Variability Coefficient: VC) เป็นการวัดทางสถิติที่ใช้ในการประเมินความแปรปรวนสัมพัทธ์หรือการกระจายตัวของจุดข้อมูลในชุดข้อมูล ซึ่งมีประโยชน์เมื่อเปรียบเทียบชุดข้อมูลกับหน่วยหรือสเกลต่างๆ เนื่องจากเป็นมาตรฐานในการวัดความแปรปรวน หากค่าสัมประสิทธิ์ความแปรปรวนมีค่าไม่เกิน 0.25 หมายความว่าความต้องการสินค้ามีระดับที่คงที่ Sriphrabu & Chamnanlor (2022) ได้อธิบายสมการไว้ดังนี้

$$\text{Variability coefficient} = \frac{Est\ var\ D}{(\bar{d})^2}$$

โดยที่

$Est\ var\ D$ = ค่าความแปรปรวนของความต้องการสินค้า

$\bar{d}$ = ค่าเฉลี่ยความต้องการสินค้าย้อนหลัง

ซึ่งค่าความแปรวนของความต้องการสินค้าสามารถคำนวณได้จากสมการดังนี้

$$Est\ var\ D = \frac{\sum_{i=1}^{n}(d^2 - \bar{d}^2)}{n}$$

โดยที่

n = จำนวนสัปดาห์ของข้อมูลความต้องการสินค้า

d^2 = ปริมาณความต้องการสินค้ายกกำลังสอง

$\bar{d}^2$ = ค่าเฉลี่ยปริมาณความต้องการสินค้ายกกำลังสอง

การวิเคราะห์จุดสั่งซื้อใหม่ (Reorder Point: ROP) เป็นแนวคิดสำคัญในการจัดการสินค้าคงคลังและการจัดการห่วงโซ่อุปทาน ซึ่งแสดงถึงระดับสินค้าคงคลังที่บริษัทควรสั่งซื้อสินค้าเพื่อเติมสินค้าในสต็อกก่อนที่จะหมด เป้าหมายหลักของการสร้างจุดสั่งซื้อใหม่คือเพื่อให้แน่ใจว่าบริษัทจะไม่มีปัญหาเรื่องการขาดแคลนสินค้า ในขณะเดียวกันก็หลีกเลี่ยงการสต๊อกสินค้ามากเกินไป ซึ่งส่งผลต่อต้นทุนและพื้นที่จัดเก็บ Salagosa (2022) ได้อธิบายสมการไว้ดังนี้

$$\text{ROP} = \text{d x L}$$

โดยที่

d = ปริมาณความต้องการสินค้าต่อวัน

L = ระยะเวลาการรอคอยสินค้า

สินค้าคงคลังสำรอง (Safety Stock: SS) คือปริมาณสินค้าคงคลังเพิ่มเติมที่บริษัทเก็บไว้มากกว่าความต้องการที่คาดไว้ เพื่อชดเชยความไม่แน่นอนต่างๆ และเหตุการณ์ที่ไม่คาดคิดในห่วงโซ่อุปทาน โดยมีวัตถุประสงค์หลักเพื่อให้แน่ใจว่าบริษัทสามารถตอบสนองความต้องการของลูกค้าได้ แม้ว่าจะมีความผันผวนในความต้องการ หรือความท้าทายต่างๆที่คาดไม่ถึง โดยสมการในการคำนวณสินค้าคงคลังสำรองในปัจจุบันมีด้วยกันหลายวิธี ซึ่งวิธีที่ผู้วิจัยเลือกมาใช้ในงานวิจัยนี้จะมีเรื่องของระดับการให้บริการเข้ามาเกี่ยวข้องด้วย ซึ่งสามารถกำหนดได้จากนโยบายขององค์กรนอกจากนี้ยังพบว่าการคำนวณนี้เป็นที่นิยมในหลายๆงานวิจัยที่ได้ทำการศึกษา Dasananda & Chaovalitwongse (2022) ได้อธิบายสมการไว้ดังนี้

$$Safety\ Stock = Z\sigma_d\sqrt{L}$$

โดยที่

Z = ค่า *Safety stock factor* (ระดับการให้บริการ 99%, Z= 2.58)

σ_d = ค่าเบี่ยงเบนมาตรฐานของความต้องการสินค้า

L = ระยะเวลานำ (สัปดาห์)

ความสำคัญของการพยากรณ์

การพยากรณ์เป็นเครื่องมือที่ช่วยในการวางแผนขององค์กรให้เตรียมพร้อมรับมือกับความไม่แน่นอนที่อาจจะเกิดขึ้นในอนาคตได้ ซึ่งช่วยในการตัดสินใจอย่างมีแบบแผน สำหรับภาคธุรกิจจะใช้การพยากรณ์โดยมีวัตถุประสงค์ดังนี้

- ใช้ทรัพยากรให้มีประสิทธิภาพมากขึ้น
- ประมาณการค่าใช้จ่าย
- คาดการปริมาณการขายหรือรายได้ในอนาคต

2.3 วิธีการพยากรณ์

วิธีการพยากรณ์เชิงคุณภาพ เป็นรูปแบบการพยากรณ์ที่ใช้ประสบการณ์ ความรู้ เป็นผู้พยากรณ์ โดยไม่ใช้ตัวแบบทางคณิตศาสตร์ ทำให้ตรวจสอบความแม่นยำของการพยากร์ได้ยากกว่าการพยากรณ์เชิงปริมาณ ซึ่งการพยากรณ์ในรูปแบบนี้จะมีเทคนิคดังนี้

1. การใช้การระดมความคิด (Jury of Executive Operation) เป็นการระดมความคิดหรือเป็นการประชุมเพื่อให้ทุกคนออกความคิดเห็นเกี่ยวกับสิ่งที่จะเกิดขึ้นในอนาคต ซึ่งวิธีการนี้จะมีข้อเสียตรงที่อาจจะเกิด Bias หรือความเอนเอียงได้

2. การประมาณการ (Judgement) วิธีนี้มักใช้กับธุรกิจขนาดเล็กที่มีเจ้าของเพียงคนเดียวโดยอาศัยจากประสบการณ์ที่ทำงานด้านนั้นๆมาเป็นระยะเวลานาน

3. การพยากรณ์ยอดขาย (Sale Force Composite Forecasts) เป็นรูปแบบการพยากรณ์ที่ให้หัวหน้าแต่ละฝ่ายหรือตัวแทนขายแต่ละคนประมาณการยอดขาย แล้วนำมารวมกันกลายเป็นค่าพยากรณ์ของบริษัท

4. การพยากรณ์ด้วยเทคนิคเดลไฟ (Delphi) เทคนิคการพยากรณ์นี้เป็นการปรับปรุงแก้ข้อเสียของเทคนิควิธีระดมความคิด ซึ่งก่อให้เกิด Bias หรือความเอนเอียงขึ้นจึงแก้ปัญหาโดยให้ผู้บริหารเขียนคำตอบพร้อมทั้งระบุเหตุผลส่งมาโดยไม่ผ่านการพบปะกัน ทำให้จะได้รับความเห็นของทุกคน

วิธีการพยากรณ์เชิงปริมาณ เป็นการพยากรณ์ที่ใช้ข้อมูลเชิงปริมาณเป็นตัวเลขในอดีต เพื่อนำมาพยากรณ์ค่าในอนาคต โดยสร้างตัวแบบทางคณิตศาสตร์ ซึ่งการพยากรณ์ประเภทนี้แบ่งออกเป็น 2 เทคนิคย่อยคือ

1. การพยากรณ์ความสัมพันธ์ (Casual Forecasting) เป็นเทคนิคที่ใช้ปัจจัยที่คาดว่าจะมีความสัมพันธ์กับตัวแปรที่จะพยากรณ์ เช่น ถ้าต้องการพยากรณ์ยอดขายก็จะพิจารณาหาความสัมพันธ์ระหว่างยอดขายกับค่าโฆษณา ซึ่งการหาความสัมพันธ์ดังกล่าวจะใช้เทคนิคที่เรียกว่าการวิเคราะห์ความถดถอย

2. การพยากรณ์อนุกรมเวลา (Time series Forecasting) เป็นเทคนิคการพยากรณ์ที่ใช้เฉพาะข้อมูลในอดีตของตัวแปรที่ต้องการพยากรณ์ เพื่อนำมาพยากรณ์หาค่าของตัวแปรนั้นๆในอนาคต เช่น การใช้ข้อมูลยอดขายในอดีตเพื่อดูแนวโน้มหรือพยากรณ์ยอดขายในอนาคต

2.4 การวัดค่าความคลาดเคลื่อนของการพยากรณ์

1. ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (Mean Absolute Deviation: MAD) เป็นเทคนิคที่วัดความแม่นยำโดยแก้ปัญหาเทคนิคค่าเฉลี่ยความผิดพลาดโดยใช้การพิจารณาความแตกต่างของยอดพยากรณ์กับยอดจริงโดยไม่คำนึงถึงเครื่องหมาย

$$MAD = \frac{\sum |A_t - F_t|}{n}$$

โดยที่

F_t = ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

A_t = ค่าความต้องการจริงในช่วงเวลาปัจจุบัน

n = จำนวนของข้อมูล

2. ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error: MSE) เป็นวิธีวัดความแม่นยำโดยแก้ปัญหาวิธีค่าเฉลี่ยความผิดพลาด โดยพิจารณาระหว่างความแตกต่างยอดจริงกับยอดพยากรณ์ด้วยวิธียกกำลังสอง

$$MSE = \frac{1}{n}\sum_{i=1}^{n} \frac{(A_t - F_t)^2}{n}$$

โดยที่

F_t = ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

A_t = ค่าความต้องการจริงในช่วงเวลาปัจจุบัน

n = จำนวนของข้อมูล

3. ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error : MAPE) เป็นเทคนิคที่วัดค่าความแม่นยำโดยคำนวณจากร้อยละของความผิดพลาดในการพยากรณ์ โดยไม่คำนึงถึงเครื่องหมาย ค่าที่ได้ต่ำ แสดงว่าเทคนิคนั้นมีความแม่นยำ

$$MAPE = \frac{\sum \frac{|A_t - F_t|}{A_t} \times 100}{n}$$

โดยที่

F_t = ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

A_t = ค่าความต้องการจริงในช่วงเวลาปัจจุบัน

n = จำนวนของข้อมูล

2.5 Weighted Moving Average (WMA)

Weighted Moving Average คือ เส้นค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก โดยจะถ่วงน้ำหนักข้อมูลที่ใหม่มากกว่าข้อมูลที่เก่า การถ่วงน้ำหนักข้อมูลจะทำให้ค่าเฉลี่ยที่ได้มีการเคลื่อนที่ที่สอดคล้องกับข้อมูลจริงมากขึ้น ทำให้เวลานำไปใช้งานสามารถติดตามสถานการณ์ได้อย่างทันท่วงที

$$WMA(n) = \frac{\sum_{i=1}^{n} iP_i}{\sum_{i=1}^{n} i} = \frac{(1xP_1 + 2xP_2 + \cdots + nxP_n)}{1 + 2 + \cdots + n}$$

โดยที่

P = ข้อมูลตัวแปรหรือราคา

n = จำนวนของข้อมูลย้อนหลัง

2.6 Single Exponential Smoothing Method (SES)

เป็นเทคนิคการพยากรณ์ที่ได้รับความนิยมมากอีกวิธีหนึ่งเนื่องจากใช้ข้อมูลน้อย คือใช้เพียงค่าของข้อมูลค่าพยากรณ์ก่อนหน้าค่าความต้องการในปัจจุบันและค่าปัจจัยถ่วงน้ำหนักปรับเรียบการพยากรณ์แบบปรับเรียบเอ็กซ์โพเนนเชียล

$$F_{t+1} = \propto Y_t + (1 - \propto)F_t$$

โดยที่

F_{t+1} = ค่าพยากรณ์ในช่วงเวลาต่อไป

Y_t = ค่าความต้องการจริงในช่วงเวลาปัจจุบัน

F_t = ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

$\propto$ = ค่าถ่วงน้ำหนักปรับเรียบ

2.7 Double Exponential Smoothing Method (DES)

เป็นวิธีที่ใช้หลักการของเอ็กโพเนนเชียล ซึ่งคล้ายกับวิธี Single exponential smoothing แต่วิธี Single exponential smoothing เหมาะกับข้อมูลที่มีความไม่แน่นอนเพียงอย่างเดียว จึงทำให้มีค่าคงที่สำหรับปรับเรียบเพียง 1 ค่า ซึ่งเทคนิคนี้เหมาะสำหรับข้อมูลที่มีแนวโน้มแบบเส้นตรงแต่ไม่มีความเป็นฤดูกาล โดยหลักการของเทคนิคนี้คือ การคำนวณค่าฐานถัวเฉลี่ยปรับเรียบของข้อมูลช่วงเวลาปัจจุบันแล้วจึงปรับด้วยค่าแนวโน้ม

สมการพยากรณ์

$$F_{t+m} = L_t + mT_t$$

สมการปรับเรียบ

$$L_t = \propto Y_t + (1-\propto)(L_{t-1} + T_{t-1})$$

สมการแนวโน้ม

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1}$$

โดยที่

L_t = ค่าปรับเรียบตัวใหม่ ณ เวลา t

T_t = ตัวประมาณแนวโน้ม I ช่วงเวลา t

Y_t = ค่าข้อมูลจริง ณ ช่วงเวลา t

$\propto$ = ค่าคงที่สำหรับการปรับเรียบ

β = ค่าคงที่ปรับเรียบสำหรับแนวโน้ม

m = งวดเวลาที่ต้องการพยากรณ์ล่วงหน้า

2.8 Autoregressive Integrated Moving Average (ARIMA)

แบบจำลอง ARIMA เป็นการพยากรณ์ที่ถูกเสนอโดยบ็อกซ์-เจนกินส์ ในปี 1970 โดยเป็นการอาศัยพฤติกรรมของข้อมูลในอดีต เพื่อนำมากำหนดรูปแบบในปัจจุบัน และอธิบายแนวโน้มของตัวมันเองในอนาคต ซึ่งเป็นวิธีที่ให้ค่าพยากรณ์ในระยะสั้นที่ดี กล่าวคือมีค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง MSE ของการพยากรณ์ต่ำกว่าวิธีอื่น เหมาะสำหรับการพยากรณ์ไปข้างหน้าในระยะเวลาสั้นๆ โดยจำเป็นต้องใช้อนุกรมเวลาที่ยาว (อัครพงศ์ อั้นทอง, 2550) โดยทั่วไปแบบจำลองจะประกอบด้วย 3

ส่วนหลักๆคือ Auto Regressive (AR(p)) Integrated (I(d)) และ Moving Average (MA(q)) เนื่องจากข้อมูลอนุกรมเวลาส่วนใหญ่จะมีลักษณะที่ไม่คงที่ ดังนั้นต้องมีการนำข้อมูลอนุกรมเวลามาหาระดับผลต่าง โดยมีสมการดังนี้

$$Y_t = Y_{t-1} + \varepsilon_t$$

ผลต่างอันดับที่ 1 (First Difference)

$$Y_t' = Y_t - Y_{t-1} + \varepsilon_t$$

ผลต่างอันดับที่ 2 (Second-Order Difference)

$$Y_t'' = Y_t' - Y_{t-1}' + \varepsilon_t$$

Auto Regressive (AR(p)) ข้อมูลอนุกรมเวลาขึ้นอยู่กับข้อมูลความล่าช้าในอดีตอันดับ p เขียนในรูปสมการได้ดังนี้

$$Y_t = \theta_0 + \delta_1 Y_{t-1} + \delta_2 Y_{t-2} + \cdots + \delta_p Y_{t-p} + e_t$$

โดยที่

θ_0 = ค่าคงที่

$\delta_1, \delta_2, \ldots, \delta_p$ = ค่าสัมประสิทธิ์ของตัวแปรล่าช้า

$Y_{t-1}, Y_{t-2}, \ldots, Y_{t-p}$ = ตัวแปรล่าช้าของ Y

e_t = ค่าความคลาดเคลื่อน

Moving Average (MA(q)) ข้อมูลอนุกรมเวลาขึ้นอยู่กับความคลาดเคลื่อนในปัจจุบันและความคลาดเคลื่อนของความล่าช้าอันดับ q เขียนในรูปสมการได้ดังนี้

$$Y_t = \theta_0 + e_t - \varphi_1 e_{t-1} - \varphi_2 e_{t-2} + \cdots + \varphi_q e_{t-q}$$

โดยที่

θ_0 = ค่าคงที่

$\varphi_1, \varphi_2, \ldots, \varphi_q$ = ค่าสัมประสิทธิ์ของตัวแปรล่าช้า

$e_{t-1}, e_{t-2}, \ldots, e_{t-q}$ = ตัวแปรล่าช้าของค่าความคลาดเคลื่อน

e_t = ค่าความคลาดเคลื่อน

โดยเมื่อนำความสัมพันธ์ระหว่าง AR และ MA มารวมกันจะได้สมการดังนี้

กรณีที่ข้อมูลมีลักษณะคงที่

$$\boldsymbol{Y_t = \theta_0 + \delta_1 Y_{t-1} + \delta_2 Y_{t-2} + \cdots + \delta_p Y_{t-p} + e_t - \varphi_1 e_{t-1} - \varphi_2 e_{t-2} + \cdots + \varphi_q e_{t-q}}$$

กรณีที่ข้อมูลมีลักษณะไม่คงที่

$$\boldsymbol{\Delta^d Y_t = \theta_0 + \delta_1 \Delta^d Y_{t-1} + \delta_2 \Delta^d Y_{t-2} + \cdots + \delta_p \Delta^d Y_{t-p} + e_t - \varphi_1 e_{t-1} - \varphi_2 e_{t-2} + \cdots + \varphi_q e_{t-q}}$$

โดยที่

Δ^d = ผลต่างอันดับที่ d

ขั้นตอนการพยากรณ์มีดังนี้

ขั้นตอนที่ 1 การทดสอบความนิ่งของข้อมูล (Stationary) ด้วย Augmented Dickey-Fuller test (ADF) เป็นการทดสอบว่าทุกตัวแปรที่กำหนดในแบบจำลองมีลักษณะของข้อมูลที่คงที่หรือไม่

ขั้นตอนที่ 2 พล็อตกราฟ ACF และ PACF เพื่อใช้ในการวิเคราะห์และคาดการณ์อนุกรมเวลา โดยจะให้ข้อมูลเชิงลึกเกี่ยวกับโครงสร้างความสัมพันธ์ของข้อมูลอนุกรมเวลาและเพื่อหาค่า Auto Regressive AR: p และ Moving Average MA: q

Autocorrelation function (ACF) เป็นกราฟที่สร้างจากข้อมูลอนุกรมเวลา โดยนำค่าความสัมพันธ์ (correlation) ของข้อมูลที่ถูกแบ่งเป็นส่วนๆ โดยแต่ละส่วนจะถูกแบ่งในช่วง k หน่วยเวลา กล่าวคือเป็นการวัดความสัมพันธ์ระหว่างจุดข้อมูลและค่าก่อนหน้าที่ค่าหน่วงเวลาต่างกัน (Heckman, 2016)

Partial Autocorrelation function (PACF) การวัดระดับความสัมพันธ์ที่เกิดขึ้นของพจน์อื่นๆที่จะนำมารวมไว้ในตัวแบบ (Heckman, 2016)

ขั้นตอนที่ 3 นำแบบจำลองที่ได้มาพยากรณ์ค่าในอนาคตโดยสามารถทำได้ทั้งแบบจุดและแบบช่วง โดยเปรียบเทียบค่าที่เกิดขึ้นจริง

Akaike Information Criterion (AIC) เป็นเกณฑ์ที่คิดค้นโดยอาไคเคะ โดยใช้เป็นเครื่องมือในการค้นหาตัวแบบที่ให้ค่าพยากรณ์แม่นยำที่สุด เป็นวิธีการที่ใช้ในการประมาณค่าพารามิเตอร์ของแบบจำลอง โดยหากค่าสถิติยิ่งมีค่าน้อยแปลว่าแบบจำลองสามารถเป็นตัวแทนข้อมูลได้ดี

โครงข่ายประสาทเทียม (Artificial Neural Networks : ANN)

เป็นหนึ่งในเทคนิคของการทำเหมืองข้อมูล (Data Mining) เพื่อจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ เป็นโครงข่ายของโหนดการคำนวณแบบง่ายๆ แต่ละโหนดจะรับค่าตัวแปรคูณกับค่าน้ำหนักรวม และส่งต่อไปยังโหนดถัดไป

การเรียนรู้สำหรับ Neural Networks

การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการเรียนแบบที่เมื่อสอนเสร็จแล้วจะมีการตรวจสอบว่าคำตอบที่ได้นั้นถูกต้องหรือไม่

การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการเรียนรู้แบบไม่มีผู้สอน โดยโครงข่ายประสาทเทียมจะจัดเรียงโครงสร้างตามลักษณะของข้อมูล

จากวิธีการพยากรณ์ที่ได้กล่าวมาข้างต้นผู้วิจัยเห็นว่าลักษณะของข้อมูลที่มีอยู่ มีความเหมาะสมคือเป็นข้อมูลในอดีต และมีช่วงระยะเวลาที่เพียงพอ นอกจากนี้ผู้วิจัยยังสนใจการนำเทคนิค Artificial Neural Network (ANN) มาใช้พยากรณ์ด้วยเนื่องจากมีความยืดหยุ่นและให้ค่าความแม่นยำสูงกว่าการใช้เทคนิคทางสถิติและทางคณิตศาสตร์ทั่วไป

2.9 Feedforward Neural network (FFNNs)

โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า เป็นเครือข่ายประสาทเทียมประเภทหนึ่งที่ประมวลผลข้อมูลในลักษณะไหลทิศทางเดียว จากชั้นข้อมูลเข้า (Input layer) ไปยังชั้นที่ซ่อนอยู่ (Hidden layer) และสุดท้ายไปยังชั้นข้อมูลออก (Output layer) ประกอบด้วยเซลล์ประสาทเทียมที่เชื่อมต่อกันซึ่งจัดอยู่ในชั้นต่างๆ โดยเซลล์ประสาทแต่ละเซลล์จะใช้ฟังก์ชันการกระตุ้นกับอินพุต การปรับน้ำหนักซ้ำๆ ระหว่างการฝึก โครงข่ายประสาทเทียมประเภทนี้ถูกนำมาใช้กันอย่างแพร่หลายสำหรับงานต่างๆ เช่น การจดจำภาพ การประมวลผลภาษาธรรมชาติ และการวิเคราะห์อนุกรมเวลา โดยงานวิจัยของ Sujjaviriyasup (2020) ได้อธิบายโครงสร้างสมการไว้ดังนี้

$$X_{t+1} = h(\beta_0 + \sum_{j=1}^{D} \beta_j g(W_{0j} + \sum_{i=1}^{m} W_{ij} X_{t-(i-1)}))$$

โดยที่

m = จำนวนข้อมูลป้อนเข้า

D = จำนวนโหนดในชั้นซ่อนตัวตามลำดับ

W_{0j} และ W_{ij} = ค่าเอนเอียง (Bias) ของโหนดที่ j ในชั้นซ่อนตัว

X_t = ค่าข้อมูลอนุกรมเวลาที่ t

β_0 และ β_j = ค่าเอนเอียง (Bias) ของค่าเป้าหมายในชั้นแสดงข้อมูล

g = ฟังก์ชั่นไม่เป็นเชิงเส้นของแต่ละโหนด

h = ฟังก์ชั่นเชิงเส้นตรงของความสัมพันธ์ระหว่างแต่ละโหนดกับค่าเป้าหมาย

โดยมีขั้นตอนการดำเนินงาน คือ ค่าถ่วงน้ำหนักต่างๆจะถูกกำหนดขึ้นด้วยวิธีการสุ่ม โดยค่าเอนเอียงจะรวมในกลุ่มของค่าถ่วงน้ำหนักด้วย จากนั้นป้อนค่าของข้อมูลป้อนเข้าขนาด m ค่า เข้าสู่โครงข่ายประสาทเทียมเพื่อพยากรณ์ โดยพิจารณาค่าผลรวมกำลังสองของความผิดพลาดจากการพยากรณ์เปรียบเทียบกับค่าจริง และพิจารณาค่าความชันของแต่ละค่าถ่วงน้ำหนัก จากนั้นทำการปรับน้ำหนักของแต่ละค่าถ่วงน้ำหนักเพื่อหาค่าถ่วงน้ำหนักที่ให้ค่าผลรวมกำลังสองของค่าความผิดพลาดที่น้อยที่สุด

งานวิจัยที่เกี่ยวข้องกับการพยากรณ์

Shukla & Jharkharia (2011) ได้นำเสนอการประยุกต์ใช้แบบจำลอง Autoregressive Integrated Moving Average (ARIMA) เพื่อพยากรความต้องการผักและผลไม้สดในแต่ละวัน โมเดลถูกสร้างขึ้นโดยใช้ข้อมูลยอดขายของหัวหอมตลอด 25 เดือนจากตลาดแห่งหนึ่งในประเทศอินเดีย ผลลัพธ์ที่ได้คือมีค่า MAPE อยู่ที่ 43.14% ซึ่งทางผู้วิจัยกล่าวว่าอยู่ในเกณฑ์ที่ยอมรับได้สำหรับตลาดผักและผลไม้ที่มีความต้องการที่ไม่แน่นอน

Mulphala (2014) ได้ทำการศึกษาเทคนิคการพยากรณ์ยอดขายสินค้าอุปโภคที่เหมาะสมของบริษัทเอกชนแห่งหนึ่ง ระยะเวลา 1 ปี ตั้งแต่เดือนมกราคม 2555 ถึงเดือนธันวาคม 2556 ทางบริษัทใช้วิธีถัวเฉลี่ยเคลื่อนที่ (Moving Average) ในพยากรณ์ยอดขายสินค้าทุกประเภทและวัดค่าความคลาดเคลื่อนของการพยากรณ์โดยใช้ค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (MAPE) พบว่ามีค่าความคลาดเคลื่อนสูง ผู้วิจัยจึงได้เสนอเทคนิคการพยากรณ์เชิงอนุกรมเวลาซึ่งประกอบด้วยการพยากรณ์แบบแยกส่วนประกอบ (Decomposition Method), การพยากรณ์โดยวิธีถัวเฉลี่ยเคลื่อนที่ (Moving Average Method),การพยากรณ์โดยวิธีการปรับเรียบเอกซ์โพเนนเชียล (Exponential Smoothing Method)และการพยากรณ์โดยแบบจำลองAutoregressive Integrated Moving Average Model (ARIMA) และใช้ MAPE เป็นตัวชี้วัด ผลการวิจัยพบว่า สินค้าจำนวน 73 รายการจาก 137 รายการ เหมาะกับวิธี Moving Average โดยมีค่าความคลาดเคลื่อนจากการพยากรณ์ลดลงถึง 11%

Chawla, Singh, Lamba, Gangwani, & Soni (2019) มีความพยายามที่จะใช้ Artificial neural networks (ANN) โดยได้ใช้ข้อมูลของบริษัทค้าปลีกแห่งหนึ่งของอเมริกา (Walmart) ซึ่งข้อมูลนั้นมีมากเกินกว่าที่จะประมวลผลบน Matlab ได้ จึงได้แยกออกเป็น 10 ร้านค้า ซึ่งในส่วนของ Walmart มีข้อมูลอยู่ 143 สัปดาห์ ซึ่งได้แบ่งออกเป็น 104 สัปดาห์สำหรับการฝึก และ 39 สัปดาห์สำหรับการทดสอบ ในการพยากรณ์ความต้องการโดยสร้างแบบจำลองทางคณิตศาสตร์ ด้วยซอฟแวร์

Matlab และใช้ภาษา R เพื่อสร้าง ANN โดยผลลัพธ์ที่ได้คือ ANN สามารถใช้กับชุดข้อมูลขนาดใหญ่ได้

Sermpongpan, Chungcharoen, & Opasanon (2020) ได้พยากรณ์ความต้องการใช้ปูนซีเมนต์ในประเทศไทยในระยะ 5 ปีข้างหน้า ผลลัพธ์ที่ได้พบว่าตัวแบบรวมผลพยากรณ์ระหว่างตัวแบบถดถอยพหุคูณกับตัวแบบ ARIMA ทั้งในตัวแบบปริมาณความต้องการใช้ปูนซีเมนต์และตัวแบบอัตราการเปลี่ยนแปลงปริมาณความต้องการใช้ปูนซีเมนต์ ให้ค่าความคลาดเคลื่อนที่ต่ำที่สุด โดยผลของตัวแบบรวมผลพยากรณ์ทั้ง 2 แสดงให้เห็นว่าปริมาณความต้องการใช้ปูนซีเมนต์ในประเทศไทยในปี ค.ศ. 2021 อยู่ในช่วง 36,223-42,082 พันตัน โดยมีค่า RMSE เท่ากับ 752.74 พันตัน ซึ่งต่ำกว่าค่า RMSE ของผลพยากรณ์ที่ได้จากตัวแบบพยากรณ์อัตราเปลี่ยนแปลงปริมาณความต้องการใช้ปูนซีเมนต์ในประเทศที่ 2,098.92 พันตัน

Aljaaf, Mohsin, Al-Jumeily, & Alloghani (2021) ได้ศึกษาเกี่ยวกับการสร้างแบบจำลองตามโครงข่ายประสาทเทียมแบบ Feed-forward (FFNNs) Auto-regressive Integrated Moving Average (ARIMA) และ Exponential Smoothing เพื่อคาดการณ์การแพร่ระบาดของ Covid-19 ในประเทศอิรัก ผลการวิจัยพบว่าแบบจำลอง Feed-forward neural networks (FFNNs) มีความแม่นยำในการพยากรณ์ผู้ติดเชื้อรายวันอยู่ที่ 87.6% ที่รักษาหายอยู่ที่ 82.4% และผู้เสียชีวิตอยู่ที่ 84.3% การศึกษานี้แสดงให้เห็นว่ากลุ่มของโครงข่ายประสาทเทียมแบบ Feed-forward (FFNNs) เป็นเครื่องมือที่มีประสิทธิภาพในการพยากรณ์การระบาดของโควิด-19 ในอิรัก

Zhao, Li, & Qu (2022) ได้นำเสนอแบบจำลอง ARIMA และแบบจำลอง Hybrid ARIMA เพื่อพยากรณ์ความแม่นยำของการทำนายปริมาณฝุ่น PM 2.5 ในเมืองปักกิ่ง โดยใช้ Akaike Information Criterion (AIC) และ GridSearch (GS) ในการช่วยปรับค่าพารามิเตอร์ p, d, q ซึ่งผลลัพธ์ที่ได้พบว่า Hybrid ARIMA มีค่า RMSE ที่ 99.23% และผลลัพธ์ได้แสดงให้เห็นว่าการใช้ AIC และ GS เข้ามาช่วยกำหนดค่าพารามิเตอร์สามารถให้ผลลัพธ์ที่ดี

Panya et al., (2023) ได้ทำการศึกษาการพยากรณ์ยอดขายของบริษัทตัวแทนจัดจำหน่ายอุปกรณ์ไฟฟ้า มีวัตถุประสงค์เพื่อนำเสนอการลดค่าความคลาดเคลื่อนของอุตสาหกรรมที่มีความผันแปรสูงด้วยการแปลงข้อมูล ใช้ข้อมูล 36 เดือน โดยมีวิธีการพยากรณ์คือ ปรับเรียบเส้นโค้งเลขชี้กำลังของโฮลต์ วิธีการเอกซ์โปเนนเชียลปรับเรียบด้วยเส้นโค้งเลขชี้กำลังของบราวน์ และวิธีการเอกซ์โปเนนเชียลปรับเรียบด้วยเส้นโค้งเลขชี้กำลังที่มีแนวโน้มแบบแดม ซึ่งผลลัพธ์ที่ได้พบว่าวิธีการพยากรณ์แบบปรับเรียบเส้นโค้งเลขชี้กำลังของโฮลต์มีค่า MAPE อยู่ที่ 2.81

ตารางที่ 3 สรุปงานวิจัยที่เกี่ยวข้องกับการพยากรณ์

Forecasting	Authors	Method	Result
ในประเทศ	Mulphala (2014)	การพยากรณ์แบบแยกส่วนประกอบ (Decomposition Method), การพยากรณ์โดยวิธีถัวเฉลี่ยเคลื่อนที่ (Moving Average Method),การพยากรณ์โดยวิธีการปรับเรียบเอกซ์โพเนนเชียล (Exponential Smoothing Method)และการพยากรณ์โดยแบบจำลอง Autoregressive Integrated Moving Average Model (ARIMA) และใช้ MAPE เป็นตัวชี้วัด	ค่าความคลาดเคลื่อนจากการพยากรณ์ลดลง 11%
	Sermpongpan et al. (2020)	Autoregressive Integrated Moving Average (ARIMA) ตัวชี้วัดเป็น RMSE	ได้ค่า RMSE ต่ำกว่าค่า RMSE ของผลพยากรณ์ที่ 2,098.92 พันตัน
	Panya et al. (2023)	ปรับเรียบเส้นโค้งเลขชี้กำลังของโฮลต์ วิธีการเอกซ์โปเนนเชียลปรับเรียบด้วยเส้นโค้งเลขชี้กำลังของบราวน์ และวิธีการเอกซ์โปเนนเชียลปรับเรียบด้วยเส้นโค้งเลขชี้กำลังที่มีแนวโน้มแบบแดม ตัวชี้วัดเป็น MAPE	วิธีการพยากรณ์แบบปรับเรียบเส้นโค้งเลขชี้กำลังของโฮลต์มีค่า MAPE อยู่ที่ 2.81

Forecasting	Authors	Method	Result
ต่างประเทศ	Shukla and Jharkharia (2011)	ใช้ Autoregressive Integrated Moving Average (ARIMA) เพื่อพยากรความต้องการ และใช้ MAPE เป็นตัวชี้วัด	โมเดลที่ใช้พยากรณ์มีค่าความคลาดเคลื่อนอยู่ที่ 43.14%
	Chawla, et al. (2019).	ใช้ Matlab ในการทำ ANN ซึ่งตัว Matlab มีข้อจำกัดคือไม่สามารถประมวลผลข้อมูลขนาดใหญ่ได้ ผู้วิจัยจึงได้ทำการ Spilt ข้อมูลออกเป็นส่วนๆแล้วแยกประมวลผล	แบบจำลองเครือข่ายประสาทเทียม (ANN) สามารถทำนายได้อย่างแม่นยำ มีประสิทธิภาพดีกว่าแบบจำลองทางสถิติแบบดั้งเดิม
	Aljaaf et al. (2021)	-Feed-forward neural networks (FFNNs) -Auto-regressive Integrated Moving Average (ARIMA) -Exponential Smoothing มีตัวชี้วัดคือ RMSE MAE MPE และ MAPE	FFNNs มีความแม่นยำในการพยากรณ์ผู้ติดเชื้อรายวันอยู่ที่ 87.6% ที่รักษาหายอยู่ที่ 82.4% และผู้เสียชีวิตอยู่ที่ 84.3%
	Zhao & Li (2022)	นำเสนอแบบจำลอง ARIMA และแบบจำลอง Hybrid ARIMA เพื่อพยากรณ์ความแม่นยำของการทำนายปริมาณฝุ่น PM 2.5 ในเมืองปักกิ่ง โดยใช้ Akaike Information Criterion (AIC) และ GridSearch (GS) ในการช่วยปรับค่าพารามิเตอร์ p, d, q	Hybrid ARIMA มีค่า RMSE ที่ 99.23% และผลลัพธ์ได้แสดงให้เห็นว่าการใช้ AIC และ GS เข้ามาช่วยกำหนดค่าพารามิเตอร์สามารถให้ผลลัพธ์ที่ดี

ที่มา: ผู้วิจัย

ตารางที่ 4 สรุปงานวิจัยที่เกี่ยวข้อง

Authors	Omni Channel	ABC Analysis	Forecasting			
			Weighted Moving Average (WMA)	Exponential Smoothing	Autoregressive Integrated Moving Average (ARIMA)	Neural Networks
Shukla and Jharkharia (2011)					X	
Mulphala (2014)			X	X	X	
Xi and Sha (2014)		X		X		
Chawla, et al. (2019).						X
Ryu (2019)	X					
Sermpongpan et al. (2020)					X	
Aljaaf et al. (2021)				X	X	X
Worachotepanyaratana (2021)		X	X	X		
Phuthongkham & Tiwaratreewit (2021)		X	X	X		
Ploensuk, Yawila, & Sitt-uam (2022)	X					
Zhao & Li (2022)					X	

ที่มา: ผู้วิจัย

จากงานวิจัยที่ผ่านมาในอดีต พบว่าปัญหาส่วนใหญ่ที่ผู้วิจัยพบ คือคุณสมบัติทางสถิติของข้อมูล ไม่มีรูปแบบที่ชัดเจน หรือมีค่าที่ผิดปกติมากเกินไป ถ้าข้อมูลมีรูปแบบหรือเหตุการณ์ที่คาดเดาไม่ได้โมเดลการพยากรณ์แบบอนุกรมเวลาอาจไม่แม่นยำ รวมถึงผลลัพธ์ที่ได้ก็ไม่อาจสรุปได้ว่าวิธีการใดดีที่สุด เนื่องจากผลลัพธ์ที่แตกต่างกันมาจากข้อมูลคนละชนิด เช่น ข้อมูลของปริมาณฝุ่น ข้อมูลของ

จำนวนผู้ติดเชื้อโควิด หรือข้อมูลของชนิดสินค้าวัตถุดิบ ดังนั้นในการพยากรณ์จะต้องหาวิธีการพยากรณ์หลายๆวิธีมาใช้เพื่อเปรียบเทียบแบบจำลองที่มีความเหมาะสมกับข้อมูลมากที่สุด ในส่วนของการออกแบบโครงสร้างของแบบจำลอง Neural Network การกำหนดจำนวนชั้นและจำนวนนิวรอลจะส่งผลต่อการพยากรณ์ เนื่องจากจำนวนนิวรอนที่น้อยเกินไปจะทำให้แบบจำลองไม่สามารถหาความสัมพันธ์ที่ซ่อนอยู่ในข้อมูลได้ รวมไปถึงการกำหนดอัตราเรียนรู้ จำนวนรอบการเรียนรู้ ซึ่งการกำหนดที่น้อยเกินไปก็อาจส่งผลให้แบบจำลองยังไม่สามารถจับรูปแบบของข้อมูลได้ ซึ่งจากงานวิจัยที่ได้ศึกษาไม่ได้กล่าวถึงหลักการในการกำหนดค่าพารามิเตอร์ต่างๆ รวมไปถึงข้อจำกัดต่างๆของการใช้ software สำเร็จรูป นอกจากนี้ควรคำนึงถึงการนำไปใช้จริงกับภาคธุรกิจหรือองค์กรด้วย

การทำ Cross Validation (CV) จากงานวิจัยของ (Jiang & Wang, 2017) ได้อธิบายว่าการทำ CV ให้ประสิทธิภาพที่ไม่ดีกับข้อมูลที่เป็นอนุกรมเวลา (Shrivastava, 2020) ได้อธิบายว่าในกรณีของอนุกรมเวลาการทำ CV นั้นไม่มีความสำคัญ เนื่องจากไม่สามารถเลือกตัวอย่างแบบสุ่มและกำหนดให้กับชุดข้อมูลการทดสอบหรือชุดข้อมูลการฝึกได้ เนื่องจากไม่มีเหตุผลที่จะใช้ค่าจากอนาคตเพื่อคาดการณ์ค่าในอดีต (Chaiyadecha, 2021) ได้อธิบายว่า สำหรับข้อมูลที่เป็นอนุกรมเวลา การใช้งาน K-Fold Cross Validation อาจไม่เหมาะสม เพราะอนุกรมเวลามีตัวแปรสำคัญที่ต้องการความต่อเนื่องคือ เวลา ดังนั้นการแบ่งข้อมูลแบบสุ่มจะทำให้ความหมายของอนุกรมเวลาผิดไป

จากการศึกษาสภาพปัญหาของงานวิจัยต่างๆที่เกี่ยวข้องทำให้ผู้วิจัยมีความสนใจที่จะใช้วิธีการพยากรณ์แบบอนุกรมเวลา (time Series) เช่น WMA, SES, DES รวมไปถึง ARIMA และการนำ FFNNs มาใช้พยากรณ์ยอดขายของสินค้าประเภทเครื่องใช้ไฟฟ้าเนื่องจากเทคนิค ANN มีความยืดหยุ่นและในหลายๆงานวิจัยพบว่าให้ค่าความแม่นยำสูงกว่าการใช้เทคนิคทางสถิติทั่วไป โดยมีจุดประสงค์เพื่อหาวิธีการพยากรณ์ที่มีความเหมาะสมกับสินค้าประเภทเครื่องใช้ไฟฟ้ามากที่สุด ซึ่งในงานวิจัยนี้ทางผู้วิจัยจะศึกษาให้ครอบคลุมทั้งในส่วนของ Omni Channel และ ABC Analysis ที่จะนำมาใช้ในกระบวนการคัดเลือกสินค้าที่จะทำการพยากรณ์

บทที่ 3
ระเบียบวิธีวิจัย

งานวิจัยนี้เป็นการศึกษาการพยากรณ์ความต้องการของผู้บริโภคของบริษัทขายเครื่องใช้ไฟฟ้าแห่งหนึ่ง ซึ่งเป็นธุรกิจที่มีทั้งร้านค้าออนไลน์และออฟไลน์ โดยมีรายการสินค้ากว่า 4,000 รายการ จากปัญหาในเรื่องของสินค้าที่ไม่เพียงพอต่อความต้องการของผู้บริโภคทำให้หลายๆ ครั้งต้องมีการ Transfer ของไปมาระหว่างสาขา ส่งผลให้มีต้นทุนที่เพิ่มสูงขึ้น นอกจากนี้ยังเป็นการเพิ่มภาระงานให้กับพนักงานของสาขาต้นทางเนื่องจากต้องมีการหยิบรวมไปถึงเตรียมของเพื่อส่งให้กับสาขาปลายทาง ทำให้พนักงานทำงานในส่วนของตนเองได้ไม่เต็มประสิทธิภาพ ในการศึกษานี้ได้เสนอวิธีการแก้ปัญหาด้วยการพยากรณ์ความต้องการของผู้บริโภค โดยแยกเป็นส่วนของออนไลน์และออฟไลน์ ซึ่งในส่วนของสาขาออฟไลน์ของบริษัทกรณีศึกษานี้มีมากกว่า 90 สาขา จึงต้องทำการเลือกในส่วนของสาขาใหญ่ที่มียอดขายสูงมาใช้ในการวิจัยครั้งนี้

ขั้นตอนต่อมาจะนำข้อมูลมาวิเคราะห์และคัดเลือกรายการสินค้า (SKU) ที่มี Impact ต่อภาคธุรกิจมากที่สุด โดยใช้วิธี ABC Analysis ซึ่งจะเลือกจากจำนวนรายการในกลุ่ม A หลังจากใช้วิธี ABC Analysis ทำการแปลงข้อมูลที่ดึงมาจากในระบบให้อยู่ในรูปแบบที่เหมาะสมต่อการนำมาใช้งาน จากนั้นทำการแบ่งข้อมูลเป็น 2 ชุด (split data) คือข้อมูลฝึกอบรมและข้อมูลสำหรับการทดสอบ โดย 70% เป็นข้อมูลที่ใช้สำหรับการฝึกอบรมและอีก 30% เป็นข้อมูลสำหรับการทดสอบ เพื่อไม่ให้ตัวของโมเดลที่ใช้พยากรณ์เกิด overfitting หรือ underfitting คือ ตัวของโมเดลไม่สามารถนำไปใช้กับข้อมูลอื่นได้หรือตัวของโมเดลไม่มีความแม่นยำในการพยากรณ์ หลังจากนั้นนำข้อมูลมาเข้าในส่วนของ Model พยากรณ์ที่ได้กำหนดไว้ และนำผลลัพธ์ที่ได้มาพิจารณาเปรียบเทียบผล วิเคราะห์และสรุปผล โดยมีขั้นตอนการวิจัยสามารถแสดงได้ดังนี้

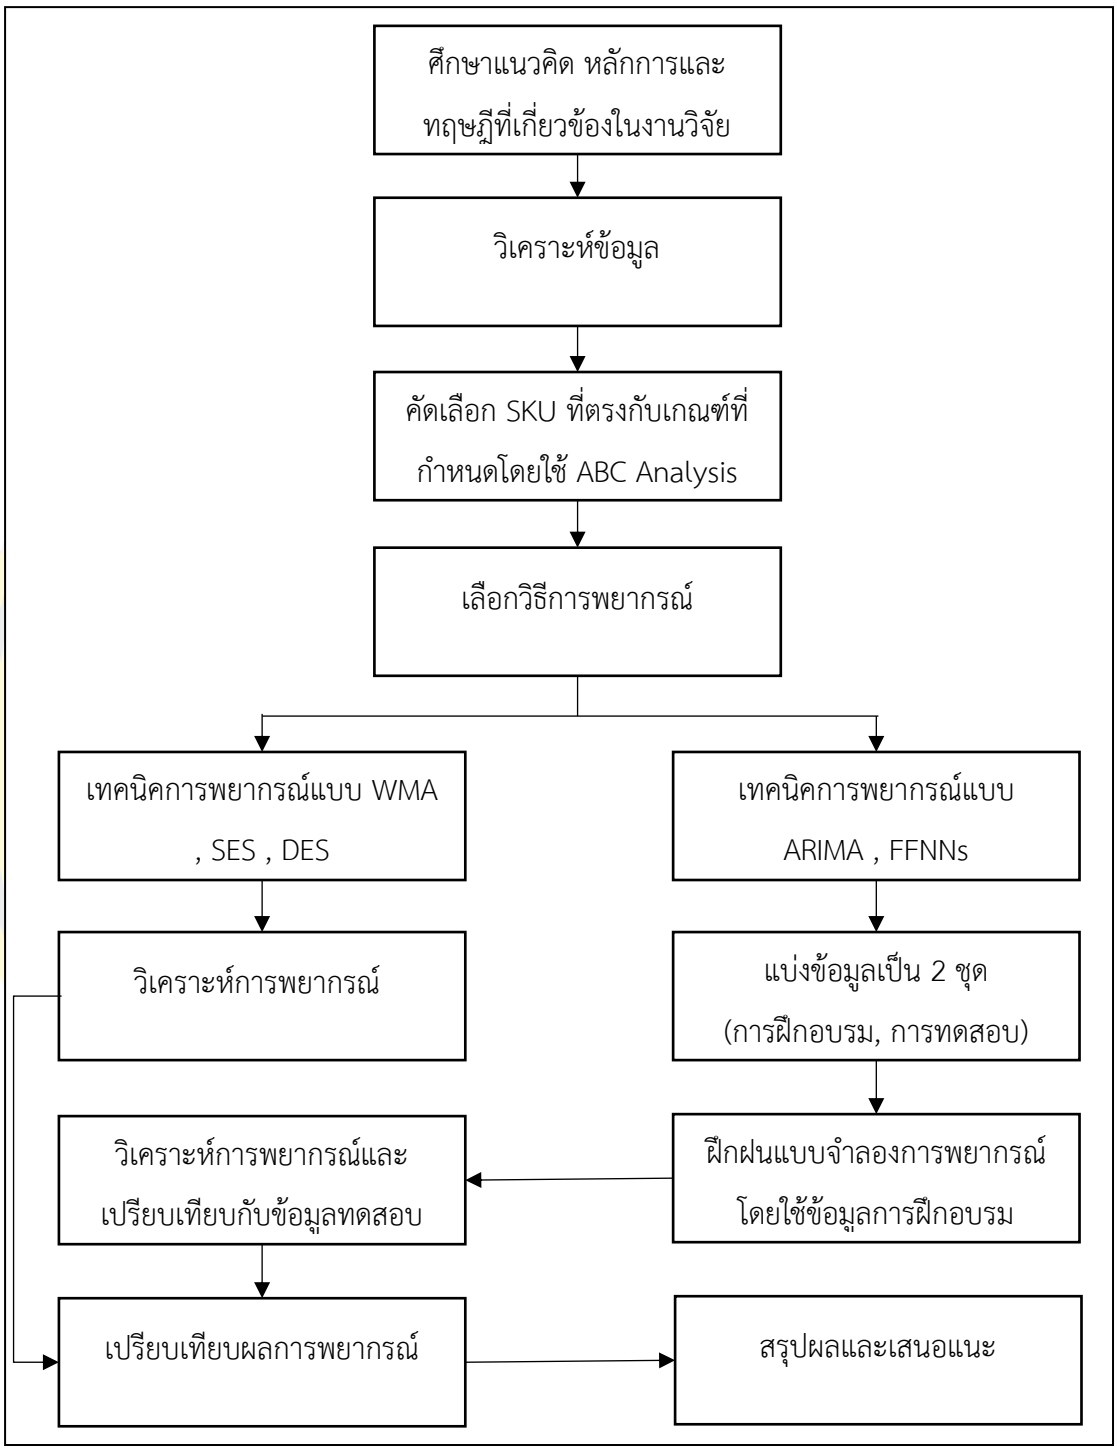

ภาพที่ 2 กรอบแนวคิดขั้นตอนการวิจัย

ที่มา: ผู้วิจัย

ขั้นตอนการวิจัย

3.1 การเตรียมข้อมูล (Prepare Data)

1. รวบรวมข้อมูลรายละเอียดของธุรกิจกรณีศึกษาสำหรับการวิเคราะห์ ได้แก่

1.1 ข้อมูลยอดขายของทั้งสาขาออนไลน์และออฟไลน์ ประกอบด้วย เลข Order เลข SKU ชื่อสินค้า จำนวน วันที่ขาย ประเภทการชำระเงิน ฯลฯ เนื่องจากเป็นข้อมูลที่ดึงมาจากในระบบ ทำให้ต้องมีการแปลงข้อมูลก่อนเพื่อให้เหมาะสมต่อการใช้งานต่อไป

1.2 ข้อมูลการทำ safety stock ในปัจจุบัน เนื่องจากธุรกิจกรณีศึกษามีสินค้ามากกว่า 4,000 รายการและมีหลายสาขา รวมไปถึงแต่ละสาขาก็มีพื้นที่ที่จำกัดและไม่เท่ากัน ทำให้ในปัจจุบันทางบริษัทได้ใช้การทำ Safety stock กับสินค้าบางรายการเพื่อสต๊อกสินค้าไว้ขาย

1.3 ขั้นตอนการ transfer สินค้าไปแต่ละสาขา ประกอบด้วย เลขที่ใบโอน สาขาต้นทาง สาขาปลายทาง ชื่อสินค้า SKU จำนวน ฯลฯ

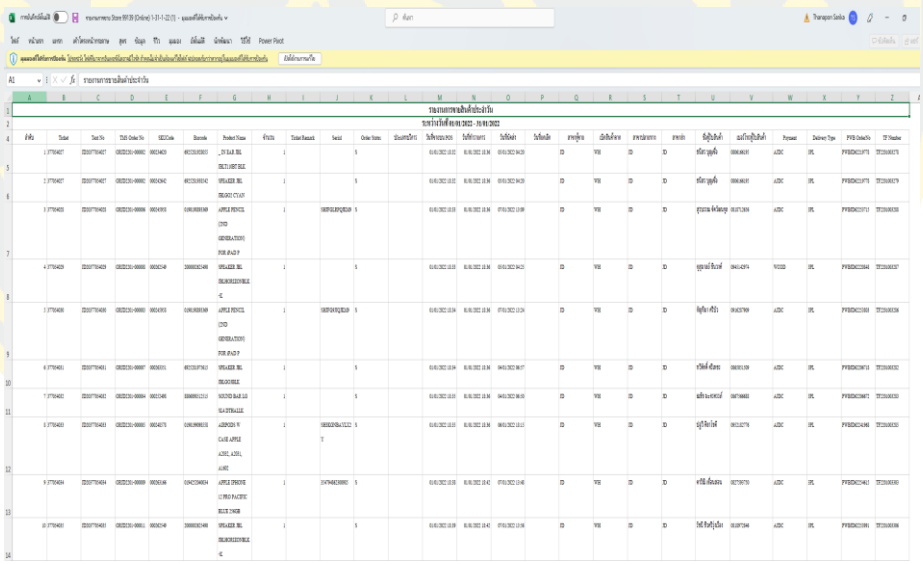

ภาพที่ 3 ตัวอย่างข้อมูลยอดขายที่ดึงมาจากระบบ

ที่มา: ผู้วิจัย

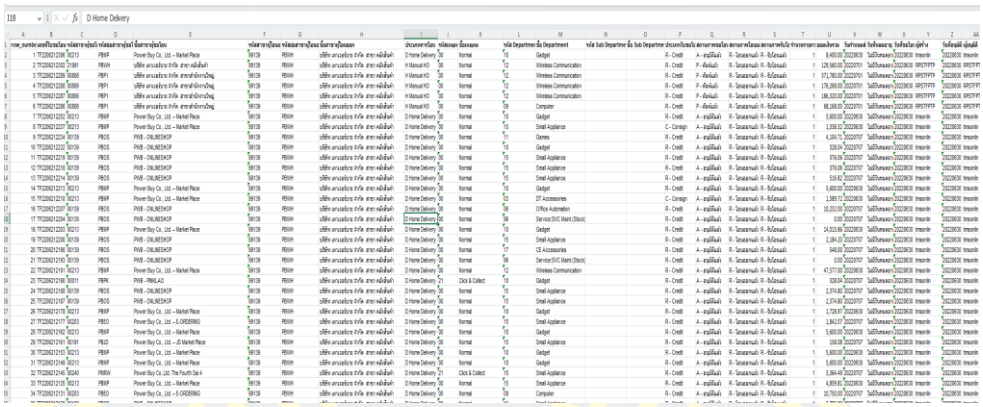

ภาพที่ 4 ตัวอย่างข้อมูล transection transfer ไปแต่ละสาขา

ที่มา: ผู้วิจัย

3.2 การจัดหมวดหมู่ตามหลัก ABC Analysis

คัดเลือก SKU ที่ตรงกับเกณฑ์ที่กำหนดเนื่องจากรายการสินค้าที่ทางบริษัทกรณีศึกษาได้ขายอยู่ในปัจจุบันโดยใช้ข้อมูลจากรายการยอดขายมีมากว่า 4,000 รายการซึ่งยังไม่รวบกับสินค้าที่ขายไม่ได้ (Dead Stock) ทำให้ต้องมีการคัดเลือกสินค้ามาพยากรณ์ซึ่งทางผู้วิจัยได้ใช้วิธี ABC Analysis เพื่อหา SKU ของรายการสินค้าที่มีผลต่อยอดขายของภาคธุรกิจมากที่สุด โดยดูจากสินค้าที่มีปริมาณยอดขายและราคาสูงมากที่สุด โดยเกณฑ์ที่ใช้คัดเลือก SKU เพื่อนำไปพยากรณ์ต่อมีดังนี้

1. เป็นรายการสินค้าที่มีมูลค่าสะสมอยู่ใน 50 อันดับแรกของกลุ่ม A
2. เป็นรายการสินค้าที่ไม่ได้อยู่ในกลุ่มสินค้า Pre-Orders
3. เป็นรายการสินค้าที่มีจำนวนวันที่หรือข้อมูลเพียงพอต่อการนำไปพยากรณ์

No.	SKU	Product Name	ยอดขาย	Store	ราคา	ยอดขายรวม	%มูลค่า	%มูลค่าสะสม	%รายการสินค้าสะสม	Group
1	272218	AIRPODS PRO APPLE MLWK3ZA/A	10346	99139	8,992.00	93,031,232.00	9.9124%	9.9124%	0.0341%	A
2	262132	SPEAKER JBL JBLFLIPESSENTIAL	6016	99139	4,390.00	26,410,240.00	2.8140%	12.7264%	0.0682%	A
3	276848	APPLE IPHONE 13 128GB GREEN	766	99139	29,900.00	22,903,400.00	2.4403%	15.1668%	0.1024%	A
4	273659	PLAYSTATION 5 UITRA HD BLU-RAY SONY CFI-	1324	99139	16,990.00	22,494,760.00	2.3968%	17.5636%	0.1365%	A
5	263523	APPLE IPHONE 11 WHITE 64GB	893	99139	22,100.00	19,735,300.00	2.1028%	19.6664%	0.1706%	A
6	272219	AIRPODS (3RD GENERATION) APPLE MME73ZA/A	2846	99139	6,790.00	19,324,340.00	2.0590%	21.7254%	0.2047%	A
7	276861	APPLE IPHONE 13 PRO MAX 128GB ALPINE GRE	380	99139	42,900.00	16,302,000.00	1.7370%	23.4623%	0.2388%	A
8	248578	AIRPODS W CASE APPLE A2032, A2031, A1602	2836	99139	4,990.00	14,151,640.00	1.5078%	24.9702%	0.2729%	A
9	280275	PLAYSTATION 5 ULTRA HD BLURAY HORIZON BU	639	99139	20,390.00	13,029,210.00	1.3883%	26.3584%	0.3071%	A
10	263522	APPLE IPHONE 11 BLACK 64GB	497	99139	22,100.00	10,983,700.00	1.1703%	27.5287%	0.3412%	A
11	252069	ไมโครเวฟ MANUAL 20L ELECTROLUX EMM20K18G	4956	99139	2,190.00	10,853,640.00	1.1564%	28.6852%	0.3753%	A
12	263526	APPLE IPHONE 11 PURPLE 64GB	445	99139	22,100.00	9,834,500.00	1.0479%	29.7331%	0.4094%	A
13	263528	APPLE IPHONE 11 BLACK 128GB	408	99139	24,100.00	9,832,800.00	1.0477%	30.7807%	0.4435%	A
14	269019	เครื่องฟอกอากาศ 16-495QM PHILIPS AC0820/	1492	99139	5,990.00	8,937,080.00	0.9522%	31.7330%	0.4777%	A
15	281922	APPLE IPHONE 14 PRO MAX 256GB DEEP PURPLE	178	99139	48,900.00	8,704,200.00	0.9274%	32.6604%	0.5118%	A
16	243841	SPEAKER JBL JBLXTREME2 BLKAS	675	99139	11,900.00	8,032,500.00	0.8559%	33.5163%	0.5459%	A
17	270688	APPLE IPHONE 13 PRO MAX SIERRA BLUE 128G	184	99139	42,900.00	7,893,600.00	0.8411%	34.3573%	0.5800%	A
18	270687	APPLE IPHONE 13 PRO MAX GOLD 128GB	166	99139	42,900.00	7,121,400.00	0.7588%	35.1161%	0.6141%	A
19	281918	APPLE IPHONE 14 PRO MAX 128GB DEEP PURPLE	152	99139	44,900.00	6,824,800.00	0.7272%	35.8433%	0.6482%	A
20	230834	_HEADPHONE JBL JBLT450BLK	4421	99139	1,490.00	6,587,290.00	0.7019%	36.5451%	0.6824%	A
21	266593	ไมโครเวฟ MANUAL 20L,700W HAIER M2001W	3192	99139	1,990.00	6,352,080.00	0.6768%	37.2220%	0.7165%	A
22	282841	PLAYSTATION 5 ULTRA HD BLURAY FIFA 23 BU	295	99139	20,790.00	6,133,050.00	0.6535%	37.8754%	0.7506%	A
23	263533	APPLE IPHONE 11 GREEN 128GB	252	99139	24,100.00	6,073,200.00	0.6471%	38.5225%	0.7847%	A
24	279144	OS-LED TV 55" LG NANOCELL 4K SMART DTV 5	185	99139	30,990.00	5,733,150.00	0.6109%	39.1334%	0.8188%	A
25	245958	APPLE PENCIL (2ND GENERATION) FOR IPAD P	1235	99139	4,490.00	5,545,150.00	0.5908%	39.7242%	0.8530%	A
26	267485	LED TV 43" LG UHD SMART DTV 43UP7750PTB.	303	99139	17,990.00	5,450,970.00	0.5808%	40.3050%	0.8871%	A
27	269045	หม้อทอดไร้น้ำมัน PHILIPS HD9200/91	1241	99139	4,290.00	5,323,890.00	0.5673%	40.8723%	0.9212%	A
28	269035	เครื่องปิ้งแอนกประสงค์ 2L PHILIPS HR2221/00	2634	99139	1,890.00	4,978,260.00	0.5304%	41.4027%	0.9553%	A
29	276863	APPLE IPHONE 13 PRO MAX 256GB ALPINE GRE	106	99139	46,900.00	4,971,400.00	0.5297%	41.9324%	0.9894%	A
30	263529	APPLE IPHONE 11 WHITE 128GB	205	99139	24,100.00	4,940,500.00	0.5264%	42.4588%	1.0235%	A

ภาพที่ 5 ตัวอย่างข้อมูล ABC Analysis ของยอดขายสินค้า

ที่มา: ผู้วิจัย

3.3 การพยากรณ์ (Forecasting)

1. การพยากรณ์ด้วยแบบจำลองอนุกรมเวลา (Time-Series)

ในส่วนของวิธีการพยากรณ์แบบอนุกรมเวลา (Time-Series) WMA SES และ DES จะใช้ Microsoft Excel ในการพยากรณ์โดยใช้ฟังก์ชัน Solver ของ Microsoft Excel เข้ามาช่วยในการกำหนดค่าน้ำหนัก (w), Alpha และ Beta ซึ่งในส่วนของการกำหนดระยะเวลา n ของวิธีการพยากรณ์แบบ WMA ทางผู้วิจัยได้แบ่งเป็น n= 2, 3 และ 4 สัปดาห์ เนื่องจากในการวางแผนรอบรถ Milk-run ขององค์กรกรณีศึกษาจะมีการวางแผนเป็นรายเดือน ซึ่งตาม n สัปดาห์ที่กำหนดเป็นช่วงเวลาที่อยู่ในระยะเวลา 1 เดือนพอดี

การหาค่าน้ำหนักจะใช้ Solver หาค่าน้ำหนักรายการสินค้าละ 3 ครั้งตามตัวชี้วัดโดยกำหนด Objective Function คือ ผลรวมที่ต่ำที่สุดของค่าความคลาดเคลื่อน MSE, MAD, MAPE และ Decision Variable คือค่าน้ำหนัก w, Alpha, Beta โดยกำหนด Constraints ให้มีค่าตั้งแต่ 0-1

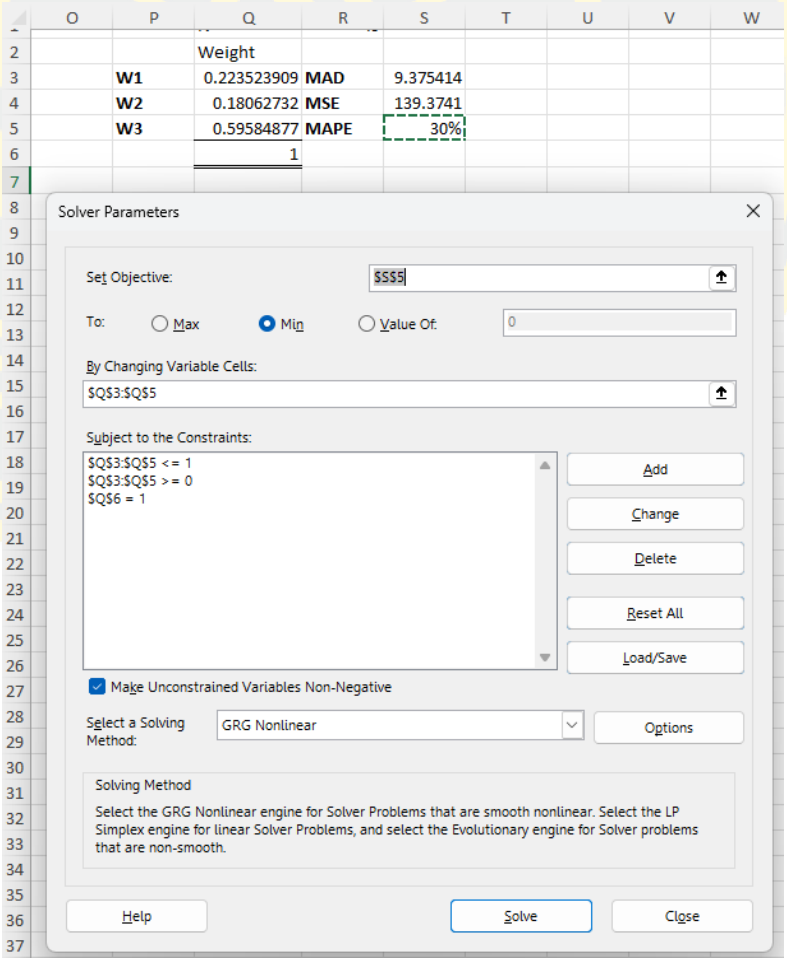

ภาพที่ 6 ตัวอย่างการใช้ฟังก์ชัน Solver ของ Microsoft Excel

ที่มา: ผู้วิจัย

2. Autoregressive Integrated Moving Average (ARIMA)

สำหรับการพยากรณ์ด้วยแบบจำลอง ARIMA ผู้วิจัยได้ใช้ Google Colab เป็นเครื่องมือเข้ามาช่วยในการพยากรณ์ โดยมีขั้นตอนดังนี้

1. แบ่งข้อมูลออกเป็น 70:30 โดย 70% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการฝึก และอีก 30% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการทดสอบ เนื่องจากข้อมูลระยะเวลา 1 ปีเมื่อแปลงเป็นรายสัปดาห์แล้วจะได้ทั้งหมด 52 สัปดาห์ซึ่งเมื่อแบ่งตามอัตราส่วนที่ได้กล่าวข้อมูลสำหรับฝึกจะอยู่ที่ 36 สัปดาห์หรือประมาณ 9 เดือนและข้อมูลสำหรับทดสอบตัวแบบจะอยู่ที่ 3 เดือน

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

3. ทำการพล็อตกราฟ ACF และ PACF เพื่อใช้ในการวิเคราะห์และคาดการณ์อนุกรมเวลา โดยจะให้ข้อมูลเชิงลึกเกี่ยวกับโครงสร้างความสัมพันธ์ของข้อมูลอนุกรมเวลาและเพื่อหาค่า p, q

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

Akaike Information Criterion (AIC) คือตัววัดที่ใช้ในสถิติเพื่อเปรียบเทียบและเลือกระหว่างแบบจำลองทางสถิติต่างๆ ได้รับการพัฒนาโดย Hirotugu Akaike นักสถิติชาวญี่ปุ่น หลักการของการประมาณค่าความน่าจะเป็นสูงสุด ซึ่งเป็นวิธีการที่ใช้ในการประมาณค่าพารามิเตอร์ของแบบจำลอง

3. Feedforward Neural network (FFNNs)

ผู้วิจัยได้ใช้ Google Colab เป็นเครื่องมือเข้ามาช่วยในการพยากรณ์ โดยใช้ไลบรารีที่ชื่อว่า Tensorflow และ Keras ที่เป็น API เข้ามาช่วยในการสร้างโมเดลพยากรณ์ เนื่องจาก TensorFlow เป็นไลบรารีฟรีที่พัฒนาโดย Google Brain Team ซึ่งในการนำไปใช้งานจริงทางภาคธุรกิจสามารถนำไปใช้ได้โดยไม่มีค่าใช้จ่ายใดๆ โดยขั้นตอนการพยากรณ์มีดังนี้

1. แบ่งข้อมูลสำหรับฝึกและทดสอบที่ 70:30 โดย 70% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการฝึก และอีก 30% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการทดสอบ

2. เรียกใช้ API Keras เพื่อสร้างโครงสร้างของโมเดล โดยจะประกอบไปด้วย Hidden layer และ Output layer ใช้ MSE เป็นฟังก์ชันในการส่งกลับค่าสูญเสีย (loss) และใช้ Adam เป็น Optimizer ช่วยในการปรับ learning rate

ในงานวิจัยนี้ผู้วิจัยได้เลือกใช้ Adam เป็น Optimizer เนื่องจาก Adam เป็น Optimizer ที่รวมข้อดีของแต่ละ Optimizer แล้วลบข้อด้อยต่างๆออกไปเช่น decaying learning rate ของ Adagrad ซึ่งช่วยให้โมเดลไม่หยุดเรียนรู้ได้ นอกจากนี้ยังเร็วกว่า Gradient Descent และลดปัญหาการแกว่งของพารามิเตอร์ได้อีกด้วย (Limkonchotiwat, 2019)

3. ใช้ GridSearch เข้ามาช่วยในการกำหนดจำนวนชั้นและจำนวนเซลล์ในชั้นของ Hidden layer สำหรับจำนวนชั้นจะกำหนดอยู่ที่ 1-3 ชั้น และจำนวนเซลล์กำหนดให้เริ่มตั้งแต่ 10-100 โดยจะเพิ่มขึ้นครั้งละ 10 เนื่องจากตัวของข้อมูลไม่ได้มีความซับซ้อนและมีขนาดที่เล็ก โดยจะพิจารณาจากคะแนนค่าเฉลี่ยของข้อผิดพลาดกำลังสอง (MSE) ที่ดีที่สุด

4. ในส่วนของกระบวนการวนซ้ำ (epochs) และ batch size เนื่องด้วยข้อจำกัดของซอฟต์แวร์ Google Colab ที่เป็นตัวฟรีนั้นจะเป็นการประมวลผลบนคลาวด์เซิร์ฟเวอร์ซึ่งจะจำกัดในเรื่องของ RAM Disk และความแรงของ CPU ที่ใช้ประมวลผล ดังนั้นผู้วิจัยจึงได้ทำการสุ่มรายการสินค้ามาทดสอบโดยใช้ GridSearch หาค่าของ epochs ตั้งแต่ 100-1,000 เพื่อสร้างกราฟแสดงแนวโน้มการลดลงของค่าสูญเสีย (loss) เพื่อนำมาใช้ตัดสินใจในการกำหนดค่า epochs ซึ่งในงานวิจัยนี้ผู้วิจัยได้กำหนดค่าไว้ที่ 1,000 ในส่วนของ batch size คือจำนวนรายการข้อมูลที่จะให้ Optimizer คำนวณในหนึ่งครั้ง ทางผู้วิจัยได้กำหนดค่าโดยคำนึงถึงความสามารถของทรัพยากร RAM Disk ซึ่งขนาดแบทช์ที่ใหญ่ขึ้นจะใช้หน่วยความจำมากขึ้น ทางผู้วิจัยจึงได้ทดลองกำหนดค่า batch size ที่ 3 ช่วง คือ 1. มีขนาดเล็กกว่าชุดข้อมูล 2. มีขนาดเท่ากับชุดข้อมูล 3. มีขนาดมากกว่าชุดข้อมูล จากการสุ่มกับข้อมูลรายการสินค้า 3 SKU พบว่าการกำหนดขนาด batch size เท่ากับชุดข้อมูลให้ผลลัพธ์ที่เป็นค่าความคลาดเคลื่อนต่ำที่สุด ดังนั้นทางผู้วิจัยจึงขอกำหนดขนาดของ batch size เท่ากับขนาดของชุดข้อมูลในงานวิจัยนี้

3.4 เปรียบเทียบและวัดค่าความถูกต้องของผลการพยากรณ์

3.4.1 Mean Squared Error (MSE) ค่าความคลาดเคลื่อนที่ได้จะแสดงส่วนต่างกำลังสองระหว่างค่าที่พยากรณ์และค่าจริง

3.4.2 Mean Absolute Deviation (MAD) ค่าความคลาดเคลื่อนที่ได้คือปริมาณยอดขายที่เป็นจำนวนชิ้น

3.4.3 Mean Absolute Percentage Error (MAPE) ค่าความคลาดเคลื่อนจะแสดงในรูปแบบร้อยละของยอดขาย

โดยทั้ง MSE MAD และ MAPE ถ้าค่าความคลาดเคลื่อนที่ได้มีค่าน้อยจะหมายถึง ค่าพยากรณ์ที่ได้จะมีค่าใกล้เคียงค่าจริง

3.4.4 R-square ใช้วัดตัวแบบทางคณิตศาสตร์ว่ามีความเหมาะสมกับข้อมูลมากหรือน้อยเพียงใด

3.5 การคำนวณต้นทุน

คำนวณในส่วนของมูลค่าสินค้าคงคลังขั้นต่ำ (Safety Stock) ที่ต้องถือครองต่อสัปดาห์ ซึ่งสำหรับข้อมูลของสินค้าคงคลัง ทางองค์กรกรณีศึกษาสามารถให้ข้อมูลในส่วนของสาขาออนไลน์ได้เท่านั้น เนื่องจากสาขาออนไลน์เป็นแหล่งข้อมูลหลักของงานวิจัยนี้ และข้อมูลที่ได้รับไม่สามารถใช้กับสาขาออฟไลน์ได้ เนื่องจากแต่ละสาขาจะมีการจัดการสต๊อกที่ไม่เหมือนกัน โดยขึ้นอยู่กับผู้จัดการสาขา ซึ่งข้อมูลที่ได้มาจะเป็นปริมาณสินค้าคงคลังขั้นต่ำ (Safety Stock) รายเดือน ดังนั้นผู้วิจัยจึงต้องทำการแปลงให้อยู่ในรูปแบบของรายสัปดาห์ก่อน จึงจะนำไปคำนวนหาต้นทุนต่อไป

ขั้นตอนที่ 1 ทางผู้วิจัยนำผลการพยากรณ์ของแบบจำลองที่ได้ผลลัพธ์ที่ดีที่สุด มาทำการหาปริมาณสินค้าคงคลังขั้นต่ำ (Safety Stock) ใหม่

ขั้นตอนที่ 2 นำราคาของสินค้าต่อชิ้นคูณเข้ากับจำนวนของปริมาณสินค้าคงคลังขั้นต่ำ (Safety Stock) ทั้งแบบปัจจุบันและการพยากรณ์ เพื่อหามูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์ จากนั้นเปรียบเทียบและสรุปผล

3.6 สรุปผล

เปรียบเทียบผลที่ได้รับจากการวิจัยตามวัตถุประสงค์ที่ตั้งไว้ รวมไปถึงเสนอแนะแนวทางการศึกษาเพิ่มเติมระบุถึงปัญหาที่พบระหว่างการดำเนินการวิจัย เพื่อเป็นแนวทางแก้และปรับปรุงให้กับงานวิจัยต่อๆไป

บทที่ 4
ผลการวิจัย

การศึกษาวิจัยเรื่อง “การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกหลายช่องทาง” โดยในขั้นตอนแรกจะเป็นการระบุรายการสินค้าที่จะนำมาพยากรณ์ด้วยวิธี ABC Analysis โดยอิงจาก ปริมาณการขาย และมูลค่าของตัวสินค้า ซึ่งในงานวิจัยฉบับนี้ได้ทำการแบ่งข้อมูลออกเป็น 2 ส่วน คือ การขายผ่านช่องทางออนไลน์ และการขายผ่านช่องทางออฟไลน์ โดยมีรายละเอียดข้อมูลจากการดำเนินการวิจัยดังนี้

4.1 การคัดเลือกรายการสินค้าที่จะนำมาพยากรณ์ด้วยวิธี ABC Analysis

ในการจัดกลุ่มรายการสินค้า ผู้วิจัยจะทำการศึกษาข้อมูลยอดขายจากระบบเพื่อคำนวณมูลค่าสะสมของรายการสินค้า โดยแบ่งกลุ่มสินค้าออกเป็น 3 กลุ่ม ได้แก่ กลุ่ม A คือรายการสินค้าที่มูลค่ายอดขายสูง กลุ่ม B คือรายการสินค้าที่มูลค่ายอดขายปานกลาง และกลุ่ม C คือรายการสินค้าที่มูลค่ายอดขายต่ำ เพื่อทำการคัดเลือกรายการสินค้าจากกลุ่ม A ที่มีเงื่อนไขเหมาะสมที่จะนำไปพยากรณ์ในขั้นตอนต่อไป

ในการคัดเลือกรายการสินค้าด้วย ABC Analysis ทางผู้วิจัยได้แบ่งข้อมูลออกเป็น 2 ส่วนดังที่กล่าวไว้ข้างต้น โดยการขายผ่านช่องทางออนไลน์จะมี 1 สาขาและช่องทางออฟไลน์จะมี 5 สาขา จากนั้นทางผู้วิจัยได้นำข้อมูลรายการสินค้า ยอดขายสินค้า และมูลค่าสินค้า มาทำการคำนวณใน Microsoft Excel เพื่อหายอดขายรวมของสินค้า และคำนวณเป็นเปอร์เซ็นต์ของมูลค่าสินค้า จากนั้นทำการเรียงข้อมูลจากมากไปน้อยตามมูลค่าของยอดขายรวม โดยกำหนดเกณฑ์ของสินค้ากลุ่ม A ไว้ที่ 80% ของเปอร์เซ็นต์มูลค่าสะสม สินค้ากลุ่ม B ที่ 10% ถัดมาจากสินค้ากลุ่มแรก และสินค้ากลุ่ม C ที่ 10% ถัดมาจากสินค้ากลุ่มที่สอง

จากการศึกษาข้อมูลยอดขายที่ดึงมาจากระบบภายในองค์กรของกรณีศึกษาพบว่ามีรายการสินค้ามากกว่า 4,000 รายการ และบางรายการสินค้าเป็นสินค้าที่อยู่ในกลุ่ม Pre – Orders ที่มีการเปิดขายเป็นรอบๆทำให้ข้อมูลที่จะนำมาใช้พยากรณ์ในขั้นตอนต่อไปมีไม่เพียงพอ จากการคัดเลือกข้อมูลยอดขายผ่านช่องทางออนไลน์ด้วยวิธี ABC Analysis พบว่า สินค้ากลุ่ม A มีจำนวนทั้งหมด 339 รายการ มีมูลค่ารวม 782,884,835 บาท คิดเป็นร้อยละ 79.991 ของมูลค่ารวมทั้งหมด สินค้ากลุ่ม B มีจำนวน 367 รายการ มีมูลค่ารวม 97,815,939 บาท คิดเป็นร้อยละ 13.994 ของมูลค่ารวมทั้งหมด และสินค้ากลุ่ม C มีจำนวน 3,423 รายการ มีมูลค่ารวม 87,013,598 บาท คิดเป็นร้อยละ 6.015 ของมูลค่ารวมทั้งหมด

ในส่วนของข้อมูลยอดขายผ่านช่องทางออฟไลน์โดยใช้วิธี ABC Analysis ในการคัดเลือกข้อมูลรายการสินค้าจากทั้ง 5 สาขาพบว่า

สาขาที่ 1 มีรายละเอียดดังนี้

สินค้ากลุ่ม A จำนวนทั้งหมด 78 รายการ มีมูลค่ารวม 15,541,032 คิดเป็นร้อยละ 79.788% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม B จำนวนทั้งหมด 70 รายการ มีมูลค่ารวม 1,984,078 คิดเป็นร้อยละ 10.186% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม C จำนวนทั้งหมด 339 รายการ มีมูลค่ารวม 1,952,729 คิดเป็นร้อยละ 10.025% ของมูลค่ารวมทั้งหมด

สาขาที่ 2 มีรายละเอียดดังนี้

สินค้ากลุ่ม A จำนวนทั้งหมด 235 รายการ มีมูลค่ารวม 31,014,277 คิดเป็นร้อยละ 79.943% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม B จำนวนทั้งหมด 157 รายการ มีมูลค่ารวม 3,899,542 คิดเป็นร้อยละ 10.052% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม C จำนวนทั้งหมด 794 รายการ มีมูลค่ารวม 3,881,799 คิดเป็นร้อยละ 10.006% ของมูลค่ารวมทั้งหมด

สาขาที่ 3 มีรายละเอียดดังนี้

สินค้ากลุ่ม A จำนวนทั้งหมด 89 รายการ มีมูลค่ารวม 28,194,818 คิดเป็นร้อยละ 79.846% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม B จำนวนทั้งหมด 93 รายการ มีมูลค่ารวม 3,564,218 คิดเป็นร้อยละ 10.094% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม C จำนวนทั้งหมด 522 รายการ มีมูลค่ารวม 3,552,251 คิดเป็นร้อยละ 10.060% ของมูลค่ารวมทั้งหมด

สาขาที่ 4 มีรายละเอียดดังนี้

สินค้ากลุ่ม A จำนวนทั้งหมด 106 รายการ มีมูลค่ารวม 16,743,158 คิดเป็นร้อยละ 79.944% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม B จำนวนทั้งหมด 84 รายการ มีมูลค่ารวม 2,104,919 คิดเป็นร้อยละ 10.050% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม C จำนวนทั้งหมด 399 รายการ มีมูลค่ารวม 2,095,506 คิดเป็นร้อยละ 10.005% ของมูลค่ารวมทั้งหมด

สาขาที่ 5 มีรายละเอียดดังนี้

สินค้ากลุ่ม A จำนวนทั้งหมด 104 รายการ มีมูลค่ารวม 11,884,799 คิดเป็นร้อยละ 79.944% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม B จำนวนทั้งหมด 72 รายการ มีมูลค่ารวม 1,499,691 คิดเป็นร้อยละ 10.088% ของมูลค่ารวมทั้งหมด

สินค้ากลุ่ม C จำนวนทั้งหมด 332 รายการ มีมูลค่ารวม 1,481,956 คิดเป็นร้อยละ 9.968% ของมูลค่ารวมทั้งหมด

ตารางที่ 5 ข้อมูลรายการสินค้าของสาขาออนไลน์และออฟไลน์

สาขา	รายการสินค้า	ประเภทสินค้า	ยอดขาย (จำนวน)	ยอดขาย (บาท)
Store Online	SKU 1	Gadget Truly Wireless	7,994	71,882,048
	SKU 2	Gadget Speaker	5,569	24,447,910
	SKU 3	Gadget Truly Wireless	3,842	26,087,180
	SKU 4	Gadget Truly Wireless	3,638	18,153,620
	SKU 5	Electric Appliances	1,710	3,744,900
	SKU 6	Gadget Speaker	1,019	12,126,100
	SKU 7	Gadget Headphone/Earphone	4,870	7,256,300
	SKU 8	Electric Appliances	1,494	2,973,060
	SKU 9	Accessories	1,355	6,083,950
	SKU 10	Electric Appliances	1,754	7,524,660
Store 1	SKU 1	Gadget Truly Wireless	761	6,842,912
Store 2	SKU 1	Gadget Truly Wireless	620	5,575,040
	SKU 3	Gadget Truly Wireless	571	3,877,090
Store 3	SKU 1	Gadget Truly Wireless	830	7,463,360
	SKU 3	Gadget Truly Wireless	761	5,167,190
	SKU 4	Gadget Truly Wireless	1,051	5,244,490
Store 4	SKU 1	Gadget Truly Wireless	867	7,796,064
Store 5	SKU 1	Gadget Truly Wireless	480	4,316,160

ที่มา: ผู้วิจัย

จากการใช้วิธีการ ABC Analysis เข้ามาช่วยในการคัดเลือกรายการสินค้าที่จะนำไปพยากรณ์ พบว่าในส่วนของช่องทางการขายออนไลน์ มีรายการสินค้า 10 รายการที่ตรงตามเงื่อนไขที่ได้กล่าวไว้ในหัวข้อ 3.2 และช่องทางการขายออฟไลน์ สาขาที่ 1 มีรายการสินค้า 1 รายการ สาขาที่ 2 มี 1 รายการ สาขาที่ 3 มี 3 รายการ สาขาที่ 4 มี 1 รายการ และสาขาที่ 5 มี 1 รายการ โดยสินค้าส่วนใหญ่ของสาขาออนไลน์พบว่ามีสินค้าหลากหลายประเภท เช่น Gadget Truly Wireless ,Electric Appliances และ Gadget Speaker แต่ในทางกลับกันสาขาออฟไลน์พบว่าสินค้าทั้งหมดเป็นประเภท Gadget Truly Wireless หรือหูฟังไร้สาย

4.2 การพยากรณ์ยอดขายของรายการสินค้า

ในส่วนของวิธีการพยากรณ์แบบอนุกรมเวลา (Time-Series) จะใช้ Microsoft Excel ในการพยากรณ์โดยใช้ฟังก์ชัน Solver ของ Microsoft Excel เข้ามาช่วยในการกำหนดค่าน้ำหนัก w สำหรับการพยากรณ์แบบ WMA และกำหนดค่า Alpha, Beta สำหรับการพยากรณ์แบบ SES, DES ซึ่งในส่วนของการกำหนดระยะเวลา n ของวิธีการพยากรณ์แบบ WMA ทางผู้วิจัยได้แบ่งเป็น n= 2, 3, 4 เนื่องจากในการวางแผนรอบรถ Milk-run ขององค์กรกรณีศึกษาจะมีการวางแผนเป็นรายเดือน ซึ่งตาม n ที่กำหนดเป็นช่วงเวลาที่อยู่ในระยะเวลา 1 เดือนพอดี

4.2.1 Weighted Moving Average (WMA)

ผลการพยากรณ์ปริมาณยอดขายสินค้า โดยใช้ Microsoft Excel มาช่วยในการพยากรณ์และใช้ฟังก์ชัน Solver ในการช่วยกำหนดค่าถ่วงน้ำหนัก โดยคำนวณแยกหาค่าที่ดีที่สุดของแต่ละตัวชี้วัดได้ผลลัพธ์ดังนี้

สาขาออนไลน์

ตารางที่ 6 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง WMA

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้		ค่า Error		
			MAD	MSE	MAPE
SKU 1	Weighted Moving Average	(n = 2)	34.20	1,980.68	23.60%
		(n = 3)	32.97	1,906.47	22.74%
		(n = 4)	33.44	1,857.24	22.86%
SKU 2	Weighted Moving Average	(n = 2)	22.10	751.71	21.80%
		(n = 3)	21.55	723.37	21.47%
		(n = 4)	21.79	733.97	21.76%

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้		ค่า Error		
			MAD	MSE	MAPE
SKU 3	Weighted Moving Average	(n = 2)	15.56	440.13	22.34%
		(n = 3)	15.77	447.45	22.63%
		(n = 4)	15.20	422.14	21.93%
SKU 4	Weighted Moving Average	(n = 2)	23.43	984.15	33.45%
		(n = 3)	22.46	923.53	32.64%
		(n = 4)	21.37	855.63	30.13%
SKU 5	Weighted Moving Average	(n = 2)	9.37	144.38	30.21%
		(n = 3)	9.27	139.37	30.37%
		(n = 4)	9.14	137.04	30.20%
SKU 6	Weighted Moving Average	(n = 2)	6.10	52.06	32.43%
		(n = 3)	5.20	41.09	28.00%
		(n = 4)	5.06	39.79	27.91%
SKU 7	Weighted Moving Average	(n = 2)	30.31	1,402.83	32.28%
		(n = 3)	29.15	1,307.95	31.69%
		(n = 4)	28.28	1,238.21	30.98%
SKU 8	Weighted Moving Average	(n = 2)	7.37	81.35	27.41%
		(n = 3)	6.78	74.30	25.60%
		(n = 4)	6.29	65.36	23.34%
SKU 9	Weighted Moving Average	(n = 2)	5.70	57.94	23.66%
		(n = 3)	5.74	58.04	23.71%
		(n = 4)	5.57	56.14	23.72%
SKU 10	Weighted Moving Average	(n = 2)	7.52	109.48	22.63%
		(n = 3)	7.54	106.95	22.56%
		(n = 4)	7.50	101.66	22.89%

ที่มา: ผู้วิจัย

สาขาออฟไลน์

ตารางที่ 7 แสดงค่า Error จากการพยากรณ์ปริมาณยอดขายสินค้าของสาขาออฟไลน์ด้วยแบบจำลอง WMA

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้		ค่า Error		
				MAD	MSE	MAPE
Store 1	SKU 1	Weighted Moving Average	(n = 2)	4.65	41.71	31.31%
			(n = 3)	4.42	37.65	29.79%
			(n = 4)	4.10	34.34	27.07%
Store 2	SKU 1	Weighted Moving Average	(n = 2)	2.99	21.87	25.46%
			(n = 3)	2.91	19.44	24.67%
			(n = 4)	2.66	16.90	22.32%
	SKU 3	Weighted Moving Average	(n = 2)	2.65	11.22	25.13%
			(n = 3)	2.47	10.47	24.08%
			(n = 4)	2.50	10.58	24.47%
Store 3	SKU 1	Weighted Moving Average	(n = 2)	6.27	83.82	36.61%
			(n = 3)	6.02	80.57	35.01%
			(n = 4)	5.41	69.75	31.92%
	SKU 3	Weighted Moving Average	(n = 2)	4.56	31.44	34.08%
			(n = 3)	4.16	25.25	32.97%
			(n = 4)	3.50	21.11	28.05%
	SKU 4	Weighted Moving Average	(n = 2)	5.68	47.30	30.28%
			(n = 3)	4.86	34.32	25.18%
			(n = 4)	4.66	32.40	24.12%
Store 4	SKU 1	Weighted Moving Average	(n = 2)	4.13	27.19	25.27%
			(n = 3)	3.85	24.40	23.87%
			(n = 4)	3.39	21.67	21.02%
Store 5	SKU 1	Weighted Moving Average	(n = 2)	1.99	6.27	22.23%
			(n = 3)	1.52	4.07	17.19%
			(n = 4)	1.49	3.86	17.10%

ที่มา: ผู้วิจัย

จากการพยากรณ์ด้วยแบบจำลอง WMA ที่ n = 2, 3, 4 ในส่วนของสาขาออนไลน์พบว่าที่ n = 4 จะให้ผลลัพธ์การพยากรณ์ที่ดีกว่าซึ่งมีค่าความคลาดเคลื่อนต่ำที่สุด โดยมีเพียง SKU 1 , 2 ที่ n = 3 ที่ให้ผลการพยากรณ์ดีกว่า n = 4 ในส่วนของสาขาออฟไลน์พบว่าแบบจำลอง WMA ที่ n = 4 ได้ให้ผลลัพธ์การพยากรณ์ที่ใกล้เคียงกับสาขาออนไลน์เช่นกัน โดยรายการสินค้า SKU 1 ของสาขาที่ 5 มีค่าความคลาดเคลื่อนต่ำที่สุดในแบบจำลอง WMA ที่ n = 4

4.2.2 Single Exponential Smoothing Method (SES)

สาขาออนไลน์

ตารางที่ 8 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง SES

รายการ	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	MAD	MSE	MAPE
SKU 1	Single Exponential Smoothing (SES)	ค่า Error	32.46	1,749.97	22.58%
		Alpha	0.39	0.39	0.41
SKU 2	Single Exponential Smoothing (SES)	ค่า Error	21.75	737.83	21.52%
		Alpha	0.49	0.44	0.52
SKU 3	Single Exponential Smoothing (SES)	ค่า Error	16.36	487.12	23.89%
		Alpha	0.59	0.40	0.61
SKU 4	Single Exponential Smoothing (SES)	ค่า Error	23.43	1,028.71	33.86%
		Alpha	0.66	0.68	0.69
SKU 5	Single Exponential Smoothing (SES)	ค่า Error	9.13	137.09	29.69%
		Alpha	0.74	0.64	0.74
SKU 6	Single Exponential Smoothing (SES)	ค่า Error	5.68	50.61	31.37%
		Alpha	0.33	0.38	0.50
SKU 7	Single Exponential Smoothing (SES)	ค่า Error	28.17	1,339.17	31.77%
		Alpha	0.30	0.31	0.55
SKU 8	Single Exponential Smoothing (SES)	ค่า Error	6.18	65.87	24.51%
		Alpha	0.13	0.22	0.44
SKU 9	Single Exponential Smoothing (SES)	ค่า Error	5.71	58.48	23.93%
		Alpha	1.00	1.00	0.92
SKU 10	Single Exponential Smoothing (SES)	ค่า Error	8.46	103.77	22.66%
		Alpha	0.05	0.56	0.76

ที่มา: ผู้วิจัย

สาขาออฟไลน์

ตารางที่ 9 แสดงค่า Error จากการพยากรณ์ของสาขาออฟไลน์ด้วยแบบจำลอง SES

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	MAD	MSE	MAPE
Store 1	SKU 1	Single Exponential Smoothing (SES)	ค่า Error	3.64	28.84	20.38%
			Alpha	0.01	0.11	0.00
Store 2	SKU 1	Single Exponential Smoothing (SES)	ค่า Error	2.74	15.46	23.85%
			Alpha	0.20	0.12	0.27
	SKU 3	Single Exponential Smoothing (SES)	ค่า Error	2.33	8.76	22.59%
			Alpha	0.15	0.15	0.11
Store 3	SKU 1	Single Exponential Smoothing (SES)	ค่า Error	5.57	73.88	34.08%
			Alpha	0.22	0.23	0.31
	SKU 3	Single Exponential Smoothing (SES)	ค่า Error	3.65	22.92	25.70%
			Alpha	0.13	0.16	0.06
	SKU 4	Single Exponential Smoothing (SES)	ค่า Error	4.57	32.06	24.80%
			Alpha	0.15	0.00	0.15
Store 4	SKU 1	Single Exponential Smoothing (SES)	ค่า Error	3.15	20.77	18.23%
			Alpha	0.11	0.16	0.04
Store 5	SKU 1	Single Exponential Smoothing (SES)	ค่า Error	1.51	3.91	17.60%
			Alpha	0.07	0.11	0.12

ที่มา: ผู้วิจัย

จากการพยากรณ์ด้วยแบบจำลอง SES ในส่วนของสาขาออนไลน์พบว่าค่า Alpha ที่ได้จากการใช้เครื่องมือ Solver ของ Microsoft Excel ในการกำหนดค่า ซึ่งรายการสินค้าส่วนใหญ่มีค่าอยู่ระหว่าง 0.13 – 0.76 โดยมีเพียงรายการสินค้า SKU 9 ที่มีค่า Alpha เข้าใกล้ 1 มากที่สุด ซึ่งหมายความว่า การพยากรณ์จะอิงตามการสังเกตครั้งล่าสุดเป็นหลัก และในส่วนของสาขาออฟไลน์พบว่าค่า Alpha ของรายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า การพยากรณ์จะอิงตามค่าการพยากรณ์ในอดีตเป็นหลัก และได้รับอิทธิพลน้อยจากค่าการสังเกตครั้งล่าสุด จากผลการพยากรณ์ด้วยแบบจำลอง SES แสดงให้เห็นว่ามีประสิทธิภาพกับข้อมูลยอดขายของสาขาออฟไลน์

มากกว่าสาขาออนไลน์ โดยสาขาออฟไลน์มีค่าเฉลี่ยของ MAPE อยู่ที่ 23.4% และออนไลน์อยู่ที่ 26.58%

4.2.3 Double Exponential Smoothing Method (DES)

สาขาออนไลน์

ตารางที่ 10 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง DES

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	MAD	MSE	MAPE
SKU 1	Double Exponential Smoothing (DES)	ค่า Error	33.10	1,784.28	23.02%
		Alpha	0.39	0.39	0.41
		Beta	0.00	0.00	0.00
SKU 2	Double Exponential Smoothing (DES)	ค่า Error	22.18	752.29	21.94%
		Alpha	0.49	0.44	0.52
		Beta	0.00	0.00	0.00
SKU 3	Double Exponential Smoothing (DES)	ค่า Error	16.83	496.67	24.01%
		Alpha	0.50	0.40	0.48
		Beta	0.21	0.00	0.16
SKU 4	Double Exponential Smoothing (DES)	ค่า Error	23.85	1,048.88	34.07%
		Alpha	0.66	0.68	0.66
		Beta	0.01	0.00	0.02
SKU 5	Double Exponential Smoothing (DES)	ค่า Error	9.31	139.78	30.27%
		Alpha	0.74	0.64	0.74
		Beta	0.00	0.00	0.00
SKU 6	Double Exponential Smoothing (DES)	ค่า Error	5.78	51.60	31.11%
		Alpha	0.37	0.38	0.36
		Beta	0.02	0.00	0.06
SKU 7	Double Exponential Smoothing (DES)	ค่า Error	28.72	1,365.43	32.39%
		Alpha	0.30	0.31	0.55
		Beta	0.00	0.00	0.00

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	MAD	MSE	MAPE
SKU 8	Double Exponential Smoothing (DES)	ค่า Error	6.27	67.16	24.81%
		Alpha	0.12	0.22	0.39
		Beta	0.01	0.00	0.05
SKU 9	Double Exponential Smoothing (DES)	ค่า Error	5.82	59.63	24.40%
		Alpha	1.00	1.00	0.92
		Beta	0.00	0.00	0.00
SKU 10	Double Exponential Smoothing (DES)	ค่า Error	8.63	105.81	23.10%
		Alpha	0.05	0.56	0.76
		Beta	0.00	0.00	0.00

ที่มา: ผู้วิจัย

สาขาออฟไลน์

ตารางที่ 11 แสดงค่า Error จากการพยากรณ์ของสาขาออฟไลน์ด้วยแบบจำลอง DES

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	MAD	MSE	MAPE
Store 1	SKU 1	Double Exponential Smoothing (DES)	ค่า Error	3.72	29.40	20.78%
			Alpha	0.01	0.11	0.00
			Beta	0.00	0.00	0.08
Store 2	SKU 1	Double Exponential Smoothing (DES)	ค่า Error	2.65	15.37	21.68%
			Alpha	0.05	0.05	0.04
			Beta	0.60	0.13	0.83
	SKU 3	Double Exponential Smoothing (DES)	ค่า Error	2.38	8.95	23.07%
			Alpha	0.15	0.15	0.11
			Beta	0.00	0.00	0.00

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	MAD	MSE	MAPE
Store 3	SKU 1	Double Exponential Smoothing (DES)	ค่า Error	5.68	75.32	34.75%
			Alpha	0.22	0.23	0.31
			Beta	0.00	0.00	0.00
	SKU 3	Double Exponential Smoothing (DES)	ค่า Error	3.69	22.95	26.16%
			Alpha	0.08	0.11	0.05
			Beta	0.02	0.03	0.01
	SKU 4	Double Exponential Smoothing (DES)	ค่า Error	4.73	32.69	25.29%
			Alpha	0.00	0.00	0.15
			Beta	0.26	0.00	0.00
Store 4	SKU 1	Double Exponential Smoothing (DES)	ค่า Error	3.22	21.17	18.59%
			Alpha	0.11	0.16	0.04
			Beta	0.00	0.00	0.00
Store 5	SKU 1	Double Exponential Smoothing (DES)	ค่า Error	1.53	3.99	17.80%
			Alpha	0.08	0.11	0.12
			Beta	0.00	0.00	0.02

ที่มา: ผู้วิจัย

จากการพยากรณ์ด้วยแบบจำลอง DES ในส่วนของสาขาออนไลน์และออฟไลน์พบว่าค่า Alpha ที่ได้มีค่าใกล้เคียงกับแบบจำลอง SES ซึ่งหมายความว่ารายการสินค้าที่มีค่า Alpha เข้าใกล้ 1 คือการพยากรณ์จะอิงตามการสังเกตครั้งล่าสุดเป็นหลักและ รายการสินค้าที่มีค่า Alpha เข้าใกล้ 0 การพยากรณ์จะอิงตามค่าการพยากรณ์ในอดีตเป็นหลัก ในส่วนของค่า Beta ทั้งสาขาออนไลน์และออฟไลน์พบว่ารายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า การพยากรณ์ได้รับอิทธิพลน้อยลงจากการเปลี่ยนแปลงล่าสุดในแนวโน้มของอนุกรมเวลา จากการพยากรณ์ด้วยแบบจำลอง DES แสดงให้เห็นว่าแบบจำลองมีประสิทธิภาพกับข้อมูลยอดขายของสาขาออฟไลน์มากกว่าสาขาออนไลน์ โดยสาขาออฟไลน์มีค่าเฉลี่ยของ MAPE อยู่ที่ 23.51% และสาขาออนไลน์มีค่าเฉลี่ยของ MAPE อยู่ที่ 26.91%

4.2.4 Autoregressive Integrated Moving Average (ARIMA)

สาขาออนไลน์

ตารางที่ 12 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง ARIMA

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวแบบที่กำหนด		ตัวชี้วัด	Train	Test
SKU 1	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	36.55	26.77
		d	0	MSE	2,008.00	934.45
		q	0	MAPE	25.41%	21.22%
SKU 2	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	26.94	22.90
		d	1	MSE	1,146.10	862.26
		q	1	MAPE	26.05%	30.73%
SKU 3	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	20.62	20.20
		d	1	MSE	753.62	560.14
		q	0	MAPE	28.95%	32.78%
SKU 4	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	25.72	23.67
		d	1	MSE	1,436.83	1,465.40
		q	0	MAPE	34.66%	29.41%
SKU 5	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	10.42	8.00
		d	1	MSE	170.64	127.33
		q	0	MAPE	32.14%	28.31%
SKU 6	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	5.90	5.15
		d	0	MSE	53.93	33.89
		q	0	MAPE	31.75%	36.32%
SKU 7	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	22.40	36.18
		d	0	MSE	861.09	1,931.26
		q	0	MAPE	26.77%	34.59%
SKU 8	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	7.67	5.60
		d	1	MSE	106.28	50.98
		q	1	MAPE	27.91%	27.78%

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวแบบที่กำหนด		ตัวชี้วัด	Train	Test
SKU 9	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	6.11	5.07
		d	0	MSE	64.19	38.04
		q	0	MAPE	25.17%	26.03%
SKU 10	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	7.21	8.08
		d	0	MSE	91.33	130.43
		q	0	MAPE	22.87%	18.11%

ที่มา: ผู้วิจัย

สาขาออฟไลน์

ตารางที่ 13 แสดงค่า Error จากการพยากรณ์ของสาขาออฟไลน์ด้วยแบบจำลอง ARIMA

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวแบบที่กำหนด		ตัวชี้วัด	Train	Test
Store 1	SKU 1	Autoregressive Integrated Moving Average (ARIMA)	p	2	MAD	4.32	3.21
			d	0	MSE	31.58	12.57
			q	0	MAPE	28.74%	27.86%
Store 2	SKU 1	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	3.54	3.54
			d	1	MSE	24.21	16.11
			q	1	MAPE	27.00%	47.07%
	SKU 3	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	2.64	2.85
			d	0	MSE	10.45	10.40
			q	0	MAPE	28.03%	19.51%

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวแบบที่กำหนด		ตัวชี้วัด	Train	Test
Store 3	SKU 1	Autoregressive Integrated Moving Average (ARIMA)	p	1	MAD	6.50	4.41
			d	0	MSE	91.54	25.84
			q	2	MAPE	37.11%	45.64%
	SKU 3	Autoregressive Integrated Moving Average (ARIMA)	p	2	MAD	3.07	4.11
			d	0	MSE	13.23	28.12
			q	1	MAPE	25.11%	21.53%
Store 4	SKU 4	Autoregressive Integrated Moving Average (ARIMA)	p	3	MAD	4.76	6.08
			d	1	MSE	44.30	47.05
			q	0	MAPE	26.44%	25.35%
	SKU 1	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	3.93	2.31
			d	1	MSE	30.38	9.38
			q	1	MAPE	22.96%	17.02%
Store 5	SKU 1	Autoregressive Integrated Moving Average (ARIMA)	p	0	MAD	1.44	1.42
			d	0	MSE	3.63	3.08
			q	3	MAPE	16.75%	16.44%

ที่มา: ผู้วิจัย

จากการพยากรณ์ด้วยแบบจำลอง ARIMA ในส่วนของสาขาออนไลน์พบว่า ค่าความคลาดเคลื่อนจากชุดข้อมูลสำหรับฝึกมีค่า MAPE เฉลี่ยอยู่ที่ 28.17% และจากชุดข้อมูลสำหรับทดสอบมีค่า MAPE เฉลี่ยอยู่ที่ 28.53% โดยรายการสินค้า SKU10 มีค่าความคลาดเคลื่อนต่ำที่สุดโดยมีค่า MAPE จากชุดข้อมูลสำหรับฝึกอยู่ที่ 22.87% และมีค่า MAPE จากชุดข้อมูลสำหรับทดสอบอยู่ที่ 18.11%

สำหรับสาขาออฟไลน์พบว่า ค่าความคลาดเคลื่อนจากชุดข้อมูลสำหรับฝึกมีค่า MAPE เฉลี่ยอยู่ที่ 26.52% และจากชุดข้อมูลสำหรับทดสอบมีค่า MAPE เฉลี่ยอยู่ที่ 27.55% จากการพยากรณ์ด้วยแบบจำลอง ARIMA แสดงให้เห็นว่าแบบจำลองมีประสิทธิภาพกับข้อมูลยอดขายของสาขาออฟไลน์มากกว่าสาขาออนไลน์

4.2.5 Feedforward Neural network (FFNNs)

สาขาออนไลน์

ตารางที่ 14 แสดงค่า Error จากการพยากรณ์ของสาขาออนไลน์ด้วยแบบจำลอง FFNNs

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	Train	Test
SKU 1	Feedforward Neural network (FFNNs)	MAD	43.36	43.27
		MSE	2,839.33	2,738.80
		MAPE	30.72%	27.47%
		R-square	0.256	0.453
SKU 2	Feedforward Neural network (FFNNs)	MAD	22.21	26.07
		MSE	824.41	1,135.09
		MAPE	22.15%	34.74%
		R-square	0.019	0.638
SKU 3	Feedforward Neural network (FFNNs)	MAD	22.12	31.96
		MSE	782.84	1,307.09
		MAPE	36.80%	51.81%
		R-square	0.072	0.624
SKU 4	Feedforward Neural network (FFNNs)	MAD	25.82	41.39
		MSE	1,138.48	2,189.02
		MAPE	42.78%	78.20%
		R-square	0.081	0.281
SKU 5	Feedforward Neural network (FFNNs)	MAD	16.12	17.85
		MSE	403.14	375.47
		MAPE	51.43%	96.96%
		R-square	0.004	0.177

รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	Train	Test
SKU 6	Feedforward Neural network (FFNNs)	MAD	5.92	5.49
		MSE	59.58	40.72
		MAPE	28.64%	38.77%
		R-square	0.174	0.211
SKU 7	Feedforward Neural network (FFNNs)	MAD	38.86	57.28
		MSE	2,445.98	4,551.68
		MAPE	49.07%	78.84%
		R-square	0.429	0.165
SKU 8	Feedforward Neural network (FFNNs)	MAD	6.79	6.15
		MSE	72.27	58.70
		MAPE	25.63%	30.31%
		R-square	0.075	0.044
SKU 9	Feedforward Neural network (FFNNs)	MAD	11.04	13.66
		MSE	186.81	229.75
		MAPE	46.18%	58.05%
		R-square	0.481	0.028
SKU 10	Feedforward Neural network (FFNNs)	MAD	8.85	9.47
		MSE	121.24	132.31
		MAPE	28.58%	29.83%
		R-square	0.230	0.534

ที่มา: ผู้วิจัย

สาขาออฟไลน์

ตารางที่ 15 แสดงค่า Error จากการพยากรณ์ปริมาณยอดขายสินค้าของสาขาออฟไลน์ด้วยแบบจำลอง FFNNs

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	Train	Test
Store 1	SKU 1	Feedforward Neural network (FFNNs)	MAD	4.59	4.00
			MSE	34.27	18.81
			MAPE	30.08%	34.87%
			R-square	0.053	0.031
Store 2	SKU 1	Feedforward Neural network (FFNNs)	MAD	3.13	2.86
			MSE	18.88	10.57
			MAPE	23.91%	37.29%
			R-square	0.102	0.017
	SKU 3	Feedforward Neural network (FFNNs)	MAD	3.37	3.13
			MSE	17.32	13.69
			MAPE	32.91%	24.97%
			R-square	0.070	0.077
Store 3	SKU 1	Feedforward Neural network (FFNNs)	MAD	7.00	6.17
			MSE	123.01	43.92
			MAPE	35.83%	61.43%
			R-square	0.029	0.055
	SKU 3	Feedforward Neural network (FFNNs)	MAD	3.50	3.52
			MSE	18.85	22.12
			MAPE	30.02%	18.36%
			R-square	0.003	0.006
	SKU 4	Feedforward Neural network (FFNNs)	MAD	5.95	5.14
			MSE	58.93	42.93
			MAPE	30.94%	27.26%
			R-square	0.007	0.006

สาขา	รายการสินค้า	เทคนิคการพยากรณ์ที่เลือกใช้	ตัวชี้วัด	Train	Test
Store 4	SKU 1	Feedforward Neural network (FFNNs)	MAD	3.89	4.37
			MSE	26.25	27.24
			MAPE	22.85%	33.27%
			R-square	0.070	0.259
Store 5	SKU 1	Feedforward Neural network (FFNNs)	MAD	2.18	2.29
			MSE	7.91	6.95
			MAPE	23.33%	28.01%
			R-square	0.194	0.101

ที่มา: ผู้วิจัย

จากการพยากรณ์ด้วยแบบจำลอง FFNNs ในส่วนของสาขาออนไลน์พบว่า ค่าความคลาดเคลื่อนของชุดข้อมูลสำหรับฝึกและทดสอบนั้น แบบจำลองแสดงประสิทธิภาพได้ต่ำ เมื่อพิจารณาจากค่า R-square ที่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่าระหว่างตัวแปรอินพุตและตัวแปรเป้าหมายแบบจำลองไม่สามารถจับความสัมพันธ์ในข้อมูลได้เท่าที่ควร อาจกล่าวได้ว่าแบบจำลองไม่เหมาะกับข้อมูลพยากรณ์ที่กำหนด ในส่วนของสาขาออฟไลน์พบว่าแบบจำลองนี้สามารถให้ผลลัพธ์การพยากรณ์ที่มีประสิทธิภาพมากกว่าข้อมูลยอดขายของสาขาออนไลน์ โดยมีค่า MAPE ของชุดข้อมูลสำหรับฝึกเฉลี่ยอยู่ที่ 28.73% และชุดข้อมูลสำหรับทดสอบเฉลี่ยอยู่ที่ 33.18%

4.3 ผลลัพธ์การพยากรณ์ทั้ง 5 วิธี (ออนไลน์)

จากการพยากรณ์ปริมาณยอดขายสินค้าออนไลน์ของแต่ละวิธีพยากรณ์ เมื่อนำผลลัพธ์มาเปรียบเทียบกันตามรายการ SKU สามารถสรุปได้ดังนี้

ตารางที่ 16 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU1 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU1	Weighted Moving Average	n 2	34.20	1,980.68	23.60%
		n 3	32.97	1,906.47	22.74%
		n 4	33.44	1,857.24	22.86%
	Single Exponential		32.46	1,749.97	22.58%
	Double Exponential		33.10	1,784.28	23.02%
	ARIMA	(1,0,0)	**26.77**	**934.45**	**21.22%**
	Feedforward Neural network		43.27	2,738.80	27.47%

ที่มา: ผู้วิจัย

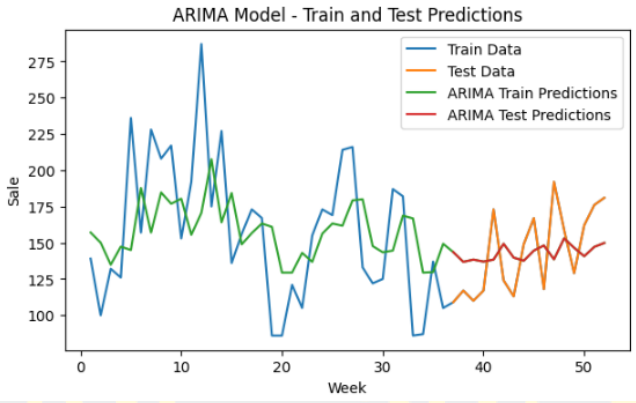

ภาพที่ 7 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 1 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 1 พบว่าแบบจำลองการพยากรณ์ ARIMA ที่ตัวแบบ (1,0,0) แสดงค่า MAD, MSE และ MAPE ได้ต่ำที่สุดโดยมีค่า MAD = 26.77 MSE = 934.45 และ MAPE = 21.22% ซึ่งบ่งชี้ถึงความแม่นยำในการพยากรณ์ที่ดีกว่าเมื่อเทียบกับแบบจำลองอื่น ในส่วนของแบบจำลอง WMA ที่มีช่วงเวลา n2, n3 และ n4 ยังถือว่ามีความแม่นยำที่ใกล้เคียงกัน รวมไปถึงแบบจำลอง SES และ DES ด้วย ในขณะที่แบบจำลอง FFNNs แสดงค่าความคลาดเคลื่อนสูงที่สุด ซึ่งบ่งบอกได้ว่ามีความแม่นยำที่ค่อนข้างต่ำในการพยากรณ์ยอดขาย SKU1 เมื่อเทียบกับแบบจำลองอื่น ผลลัพธ์เหล่านี้แสดงให้เห็นว่าแบบจำลอง ARIMA ที่ตัวแบบ (1,0,0) เป็นแบบจำลองการพยากรณ์ที่เหมาะสมที่สุดสำหรับรายการสินค้า SKU 1 โดยให้ความแม่นยำในการพยากรณ์ที่ดีที่สุดในแบบจำลองทั้ง 5 วิธี

ตารางที่ 17 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU2 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU2	Weighted Moving Average	n 2	22.10	751.71	21.80%
		n 3	**21.55**	**723.37**	**21.47%**
		n 4	21.79	733.97	21.76%
	Single Exponential		21.75	737.83	21.52%
	Double Exponential		22.18	752.29	21.94%
	ARIMA	(0,1,1)	22.90	862.26	30.73%
	Feedforward Neural network		26.07	1,135.09	34.74%

ที่มา: ผู้วิจัย

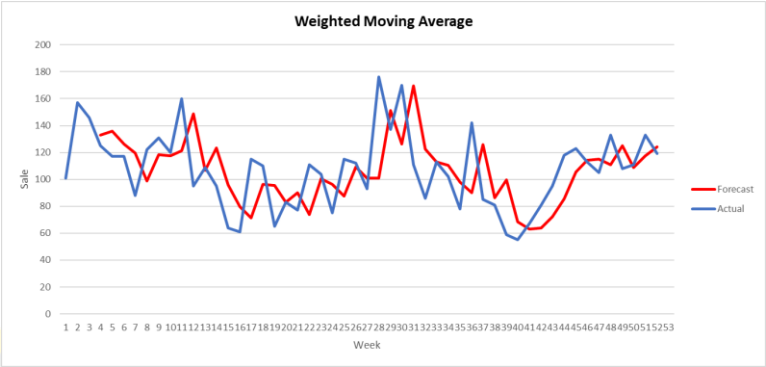

ภาพที่ 8 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 2 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 2 ผลการวิจัยพบว่าแบบจำลอง WMA ที่ n = 2, 3, 4 SES และ DES มีความแม่นยำในการพยากรณ์ในระดับที่เกาะกลุ่มกัน โดยแบบจำลอง WMA ที่ n = 3 มีผลลัพธ์ที่ดีที่สุด ซึ่งแสดงค่าความคลาดเคลื่อนต่ำที่สุดที่ MAD = 21.55 MSE = 723.37 และ MAPE = 21.47% บ่งชี้ถึงความแม่นยำในการพยากรณ์ที่แม่นยำกว่าเมื่อเทียบกับแบบจำลองอื่น อย่างไรก็ตาม แบบจำลอง ARIMA ที่ตัวแบบ (0,1,1) และ FFNNs นั้นให้ค่าความคลาดเคลื่อนที่สูงที่สุด

ตารางที่ 18 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU3 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU3	Weighted Moving Average	n 2	15.56	440.13	22.34%
		n 3	15.77	447.45	22.63%
		n 4	**15.20**	**422.14**	**21.93%**
	Single Exponential		16.36	487.12	23.89%
	Double Exponential		16.83	496.67	24.01%
	ARIMA	(1,1,0)	20.20	560.14	32.78%
	Feedforward Neural network		31.96	1,307.09	51.81%

ที่มา: ผู้วิจัย

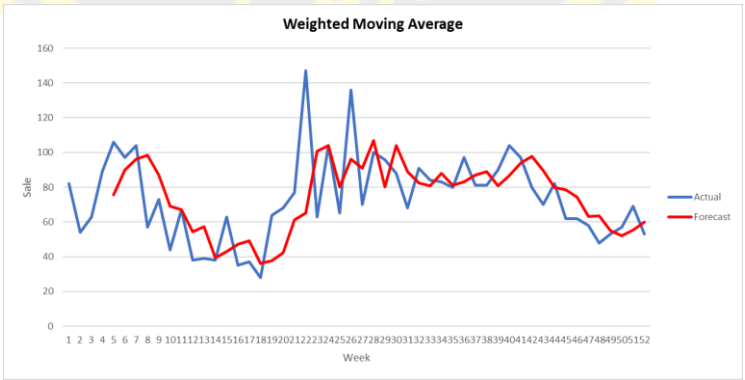

ภาพที่ 9 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 3 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 3 ผลการวิจัยพบว่าแบบจำลอง WMA ที่ n = 4 มีความแม่นยำที่ดีที่สุด เนื่องจากมีค่าความคลาดเคลื่อนที่ต่ำที่สุด โดยมีค่า MAD = 15.20 MSE = 422.14 และ MAPE = 21.93% แสดงให้เห็นว่าแบบจำลอง WMA ที่ n = 4 มีความเหมาะสมที่สุดสำหรับรายการสินค้า SKU 3

ตารางที่ 19 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU4 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU4	Weighted Moving Average	n 2	23.43	984.15	33.45%
		n 3	22.46	923.53	32.64%
		n 4	**21.37**	**855.63**	30.13%
	Single Exponential		23.43	1,028.71	33.86%
	Double Exponential		23.85	1,048.88	34.07%
	ARIMA	(0,1,0)	23.67	1,465.40	**29.41%**
	Feedforward Neural network		41.39	2,189.02	78.20%

ที่มา: ผู้วิจัย

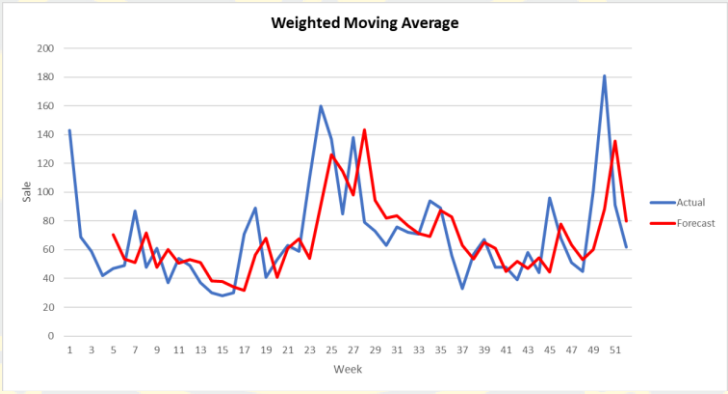

ภาพที่ 10 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 4 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 4 ผลการวิจัยพบว่า ในบรรดาแบบจำลอง WMA, SES, DES และ ARIMA ที่ตัวแบบ (0,1,0) มีค่าความคลาดเคลื่อนที่เกาะกลุ่มกัน โดยแบบจำลอง SES DES และ ARIMA มีค่าความคลาดเคลื่อนที่สูงกว่าเล็กน้อย โดยแบบจำลอง FFNNs มีค่าความคลาดเคลื่อนที่สูงที่สุด สำหรับแบบจำลองพยากรณ์ที่ดีที่สุดของรายการสินค้า SKU 4 คือ WMA ที่ n = 4 เนื่องจากตัวชี้วัด 2 ใน 3 ตัวมีค่าความคลาดเคลื่อนที่ต่ำที่สุด โดยมีค่า MAD = 21.37 MSE = 855.63 และ MAPE ที่สูงกว่าแบบจำลอง ARIMA เล็กน้อยที่ 30.13%

ตารางที่ 20 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU5 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU5	Weighted Moving Average	n 2	9.37	144.38	30.21%
		n 3	9.27	139.37	30.37%
		n 4	9.14	137.04	30.20%
	Single Exponential		9.13	137.09	29.69%
	Double Exponential		9.31	139.78	30.27%
	ARIMA	(0,1,0)	**8.00**	**127.33**	**28.31%**
	Feedforward Neural network		17.85	375.47	96.96%

ที่มา: ผู้วิจัย

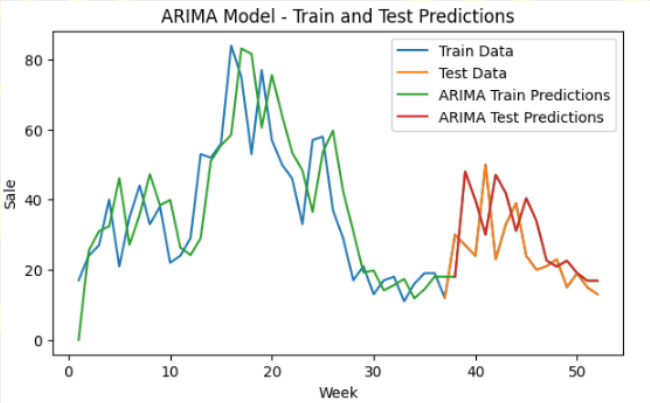

ภาพที่ 11 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 5 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 5 ผลการวิจัยพบว่า แบบจำลอง ARIMA ที่ตัวแบบ (0,1,0) มีความแม่นยำในการพยากรณ์ดีที่สุดเมื่อเทียบกับแบบจำลองอีก 4 แบบ โดยมีค่าความคลาดเคลื่อน MAD = 8 MSE = 127.33 และ MAPE = 28.31% ซึ่งแสดงให้เห็นว่าแบบจำลอง ARIMA ที่ตัวแบบ (0,1,0) มีความเหมาะสมสำหรับรายการสินค้า SKU 5 มากที่สุด

ตารางที่ 21 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU6 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU6	Weighted Moving Average	n 2	6.10	52.06	32.43%
		n 3	5.20	41.09	28.00%
		n 4	**5.06**	39.79	**27.91%**
	Single Exponential		5.68	50.61	31.37%
	Double Exponential		5.78	51.60	31.11%
	ARIMA	(1,0,0)	5.15	**33.89**	36.32%
	Feedforward Neural network		5.49	40.72	38.77%

ที่มา: ผู้วิจัย

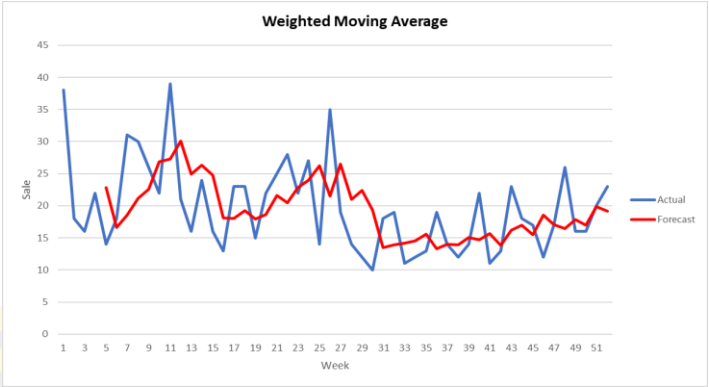

ภาพที่ 12 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 6 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 6 ผลการวิจัยพบว่า แบบจำลอง WMA ที่ n = 4 มีความเหมาะสมสำหรับรายการสินค้า SKU 6 มากที่สุด เนื่องจากตัวชี้วัด 2 ใน 3 ตัว คือ MAD และ MAPE มีค่าความคลาดเคลื่อนน้อยที่สุด โดยมีค่าอยู่ที่ 5.06 และ 27.91% ตามลำดับ

ตารางที่ 22 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU7 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU7	Weighted Moving Average	n 2	30.31	1,402.83	32.28%
		n 3	29.15	1,307.95	31.69%
		n 4	28.28	**1,238.21**	**30.98%**
	Single Exponential		**28.17**	1,339.17	31.77%
	Double Exponential		28.72	1,365.43	32.39%
	ARIMA	(1,0,0)	36.18	1,931.26	34.59%
	Feedforward Neural network		57.28	4,551.68	78.84%

ที่มา: ผู้วิจัย

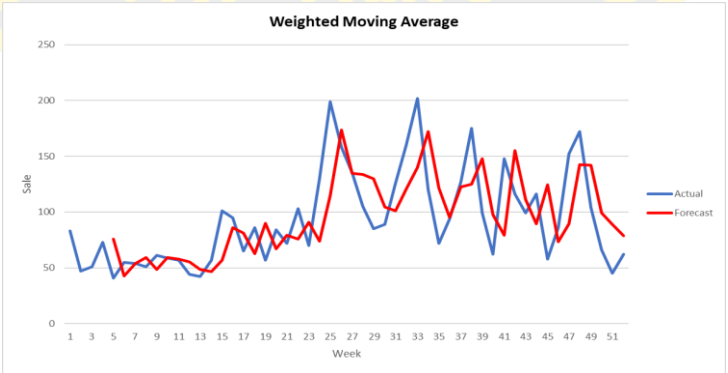

ภาพที่ 13 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 7 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 7 ผลการวิจัยพบว่า แบบจำลอง WMA ที่ n = 4 มีความเหมาะสมสำหรับรายการสินค้า SKU 7 มากที่สุด เนื่องจากตัวชี้วัด 2 ใน 3 ตัว มีค่าความคลาดเคลื่อนน้อยที่สุด โดยมีค่า MAD = 28.28 MSE = 1,238.21 และ MAPE = 30.98% ซึ่งค่า MSE และ MAPE มีค่าดีที่สุดเป็นอันดับ 1 ส่วน MAD มีค่าความแม่นยำเป็นอันดับ 2 รองจากแบบจำลอง SES ซึ่งมีค่าห่างกันเพียงเล็กน้อย

ตารางที่ 23 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU8 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU8	Weighted Moving Average	n 2	7.37	81.35	27.41%
		n 3	6.78	74.30	25.60%
		n 4	6.29	65.36	**23.34%**
	Single Exponential		6.18	65.87	24.51%
	Double Exponential		6.27	67.16	24.81%
	ARIMA	(0,1,1)	**5.60**	**50.98**	27.78%
	Feedforward Neural network		6.15	58.70	30.31%

ที่มา: ผู้วิจัย

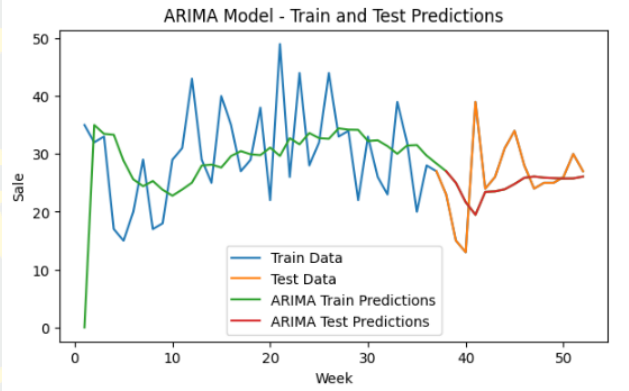

ภาพที่ 14 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 8 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 8 ผลการวิจัยพบว่า แบบจำลองการพยากรณ์ ARIMA ที่ตัวแบบ (0,1,1) มีความแม่นยำในการพยากรณ์สูงที่สุดใน 5 แบบ มีค่าความคลาดเคลื่อน MAD และ MSE น้อยเป็นอันดับที่ 1 โดยมีค่าอยู่ที่ 5.6 และ 50.98 ตามลำดับ ส่วน MAPE ที่ดีที่สุดคือแบบจำลอง WMA ที่ n = 4ดังนั้นจึงสรุปได้ว่าแบบจำลองการพยากรณ์ ARIMA ที่ตัวแบบ (0,1,1) มีความเหมาะสมกับรายการสินค้า SKU 8 มากที่สุด

ตารางที่ 24 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU9 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU9	Weighted Moving Average	n 2	5.70	57.94	**23.66%**
		n 3	5.74	58.04	23.71%
		n 4	5.57	56.14	23.72%
	Single Exponential		5.71	58.48	23.93%
	Double Exponential		5.82	59.63	24.40%
	ARIMA	(1,0,0)	**5.07**	**38.04**	26.03%
	Feedforward Neural network		13.66	229.75	58.05%

ที่มา: ผู้วิจัย

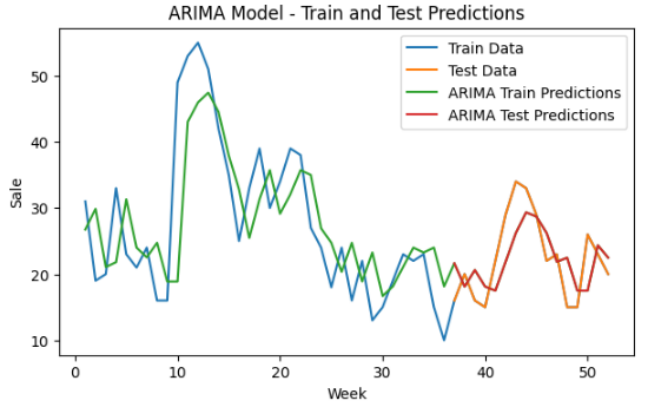

ภาพที่ 15 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 9 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 9 ผลการวิจัยพบว่า แบบจำลองการพยากรณ์ ARIMA ที่ตัวแบบ (1,0,0) มีความเหมาะสมในการพยากรณ์รายการสินค้า SKU 9 มากที่สุด โดยตัวชี้วัด 2 ใน 3 มีค่าที่น้อยที่สุด คือ MAD และ MSE โดยมีค่าความคลาดเคลื่อน MAD = 5.07 MSE = 38.04 และ MAPE = 26.03% สำหรับค่า MAPE ที่ดีที่สุดคือแบบจำลอง WMA ที่ W = 2 ซึ่งมีค่าอยู่ที่ 23.66%

ตารางที่ 25 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้า SKU10 สาขาออนไลน์

SKU	Forecasting Model		MAD	MSE	MAPE
SKU10	Weighted Moving Average	n 2	7.52	109.48	22.63%
		n 3	7.54	106.95	22.56%
		n 4	**7.50**	**101.66**	22.89%
	Single Exponential		8.46	103.77	22.66%
	Double Exponential		8.63	105.81	23.10%
	ARIMA	(1,0,0)	8.08	130.43	**18.11%**
	Feedforward Neural network		9.47	132.31	29.83%

ที่มา: ผู้วิจัย

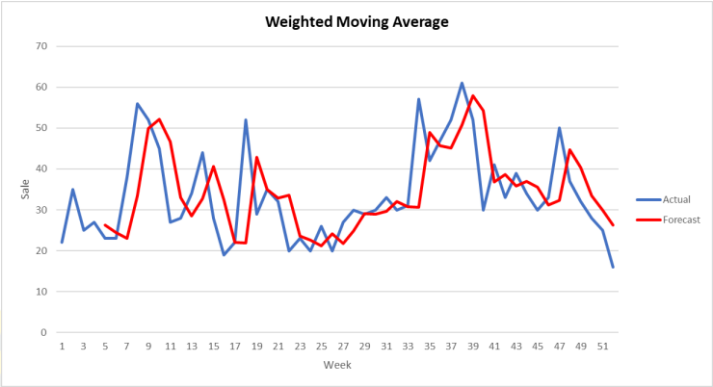

ภาพที่ 16 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้า SKU 10 สาขาออนไลน์

ที่มา: ผู้วิจัย

รายการสินค้า SKU 10 ผลการวิจัยพบว่า แบบจำลอง WMA ที่ n = 4 มีประสิทธิภาพที่ดีกว่าวิธีอื่น เนื่องจากตัวชี้วัด 2 ใน 3 คือ MAD และ MSEมีค่าที่ดีที่สุด โดยมีค่าอยู่ที่ 7.5 และ 101.66 ตามลำดับ สำหรับค่า MAPE ที่ดีที่สุดคือแบบจำลอง ARIMA ที่ตัวแบบ (1,0,0) ซึ่งมีค่าอยู่ที่ 29.83%

4.4 ผลลัพธ์การพยากรณ์ทั้ง 5 วิธี (ออฟไลน์)

ตารางที่ 26 แสดงค่าเปรียบเทียบตัวชี้วัดของรายการสินค้าสาขาออฟไลน์ 1

Store	SKU	Forecasting Model		MAD	MSE	MAPE
			n 2	4.65	41.71	31.31%
		Weighted Moving Average	**n 3**	4.42	37.65	29.79%
			n 4	4.10	34.34	27.07%
Store 1	**SKU 1**	**Single Exponential**		3.64	28.84	**20.38%**
		Double Exponential		3.72	29.40	20.78%
		ARIMA	**(2,0,0)**	**3.21**	**12.57**	27.86%
		Feedforward Neural network		4.00	18.81	34.87%

ที่มา: ผู้วิจัย

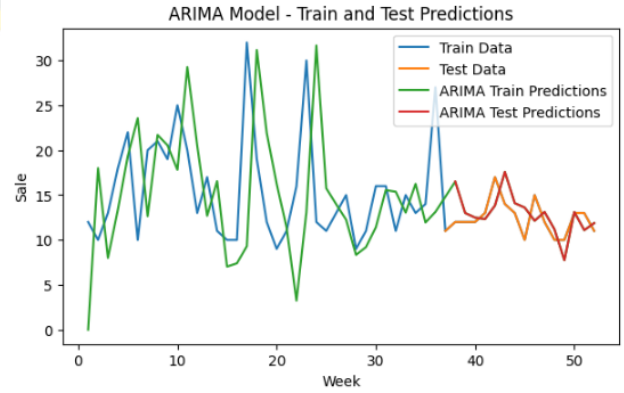

ภาพที่ 17 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 1

ที่มา: ผู้วิจัย

สาขาที่ 1 มีจำนวนรายการสินค้าจำนวน 1 รายการคือ SKU 1 ซึ่งผลการวิจัยพบว่าแบบจำลอง ARIMA ที่ตัวแบบ (2,0,0) มีความแม่นในการพยากรณ์มากที่สุด เนื่องจากตัวชี้วัด 2 ใน 3 คือ MAD และ MSE มีค่าความคลาดเคลื่อนน้อยเป็นอันดับที่ 1 โดยมีค่าอยู่ที่ 3.21 และ 12.57 ตามลำดับ

ตารางที่ 27 แสดงค่าเปรียบเทียบตัวชี้วัดแบบจำลองทั้ง 5 แบบของรายการสินค้าสาขาออฟไลน์ 2

Store	SKU	Forecasting Model		MAD	MSE	MAPE
Store 2	SKU 1	Weighted Moving Average	n 2	2.99	21.87	25.46%
			n 3	2.91	19.44	24.67%
			n 4	2.66	16.90	22.32%
		Single Exponential		2.74	15.46	23.85%
		Double Exponential		**2.65**	15.37	**21.68%**
		ARIMA	(0,1,1)	3.54	16.11	47.07%
		Feedforward Neural network		2.86	**10.57**	37.29%
	SKU 3	Weighted Moving Average	n 2	2.65	11.22	25.13%
			n 3	2.47	10.47	24.08%
			n 4	2.50	10.58	24.47%
		Single Exponential		**2.33**	**8.76**	22.59%
		Double Exponential		2.38	8.95	23.07%
		ARIMA	(1,0,0)	2.85	10.40	**19.51%**
		Feedforward Neural network		3.13	13.69	24.97%

ที่มา: ผู้วิจัย

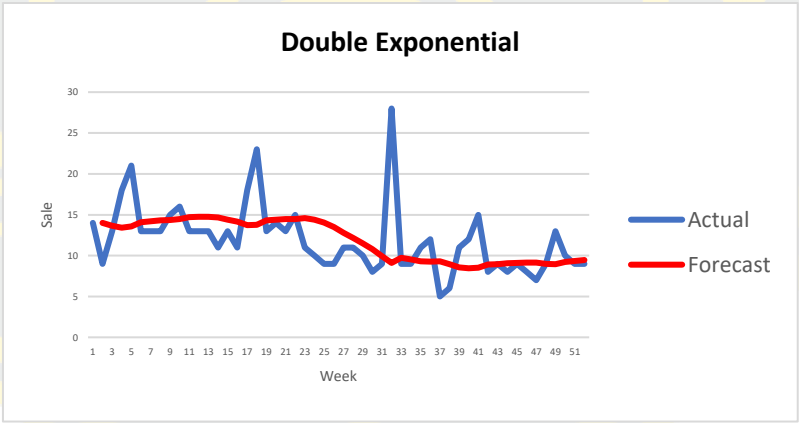

ภาพที่ 18 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 2

ที่มา: ผู้วิจัย

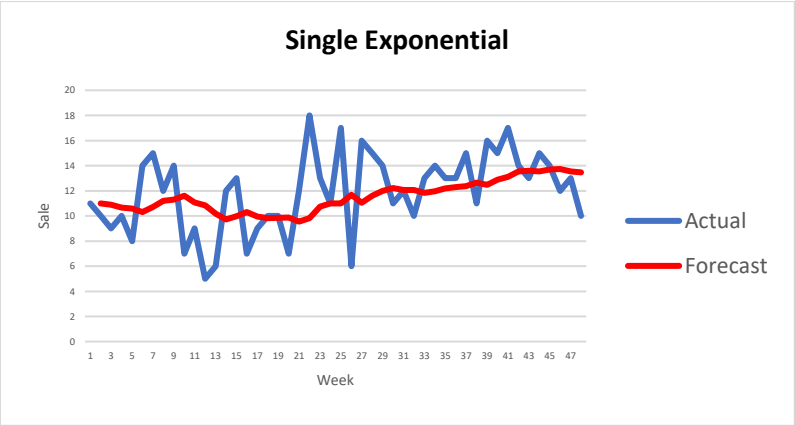

ภาพที่ 19 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU3 สาขาออฟไลน์ 2

ที่มา: ผู้วิจัย

สาขาที่ 2 มีจำนวนรายการสินค้าจำนวน 2 รายการคือ SKU 1, 3 ซึ่งผลการพยากรณ์พบว่ารายการสินค้า SKU 1 แบบจำลองที่มีความแม่นยำที่สุดคือ DES เนื่องจากตัวชี้วัด 2 ใน 3 คือ MAD และ MAPE มีค่าความคลาดเคลื่อนน้อยที่สุด โดยมีค่าอยู่ที่ 2.65 และ 21.68% ตามลำดับ สำหรับค่า MSE ที่ดีที่สุดเป็นของแบบจำลอง FFNNs โดยมีค่าอยู่ที่ 10.57 แม้จะมีค่าน้อยกว่าของแบบจำลอง DES ที่ 15.37 แต่เมื่อเทียบ MAD และ MAPE แล้วกลับมีค่าที่สูงกว่าแบบจำลอง DES อยู่มาก ดังนั้นจึงสรุปให้แบบจำลอง DES มีความเหมาะสมในการพยากรณ์รายการสินค้านี้มากที่สุด รายการสินค้า SKU 3 ของสาขาที่ 2 จากผลการวิจัยพบว่าแบบจำลองที่มีความแม่นยำที่สุดคือ SES โดยมีค่าความคลาดเคลื่อน MAD = 2.33 MSE = 8.76 และ MAPE = 22.59% โดยมีค่า MAPE น้อยเป็นอันดับที่ 2 รองจากแบบจำลอง ARIMA ที่ตัวแบบ (1,0,0) แต่ตัวชี้วัด 2 ใน 3 คือ MAD และ MSE มีค่าดีที่สุด จึงสรุปได้ว่ารายการสินค้า SKU 3 ของสาขาที่ 2 แบบจำลอง SES มีความเหมาะสมที่สุด

ตารางที่ 28 แสดงค่าเปรียบเทียบตัวชี้วัดแบบจำลองทั้ง 5 แบบของรายการสินค้าสาขาออฟไลน์ 3

Store	SKU	Forecasting Model		MAD	MSE	MAPE
			n 2	6.27	83.82	36.61%
		Weighted Moving Average	**n 3**	6.02	80.57	35.01%
			n 4	5.41	69.75	**31.92%**
	SKU 1	**Single Exponential**		5.57	73.88	34.08%
		Double Exponential		5.68	75.32	34.75%
		ARIMA	**(1,0,2)**	**4.41**	**25.84**	45.64%
		Feedforward Neural network		6.17	43.92	61.43%
			n 2	4.56	31.44	34.08%
		Weighted Moving Average	**n 3**	4.16	25.25	32.97%
			n 4	**3.50**	**21.11**	28.05%
Store 3	**SKU 3**	**Single Exponential**		3.65	22.92	25.70%
		Double Exponential		3.69	22.95	26.16%
		ARIMA	**(2,0,1)**	4.11	28.12	21.53%
		Feedforward Neural network		3.52	22.12	**18.36%**
			n 2	5.68	47.30	30.28%
		Weighted Moving Average	**n 3**	4.86	34.32	25.18%
			n 4	4.66	32.40	**24.12%**
	SKU 4	**Single Exponential**		**4.57**	**32.06**	24.80%
		Double Exponential		4.73	32.69	25.29%
		ARIMA	**(3,1,0)**	6.08	47.05	25.35%
		Feedforward Neural network		5.14	42.93	27.26%

ที่มา: ผู้วิจัย

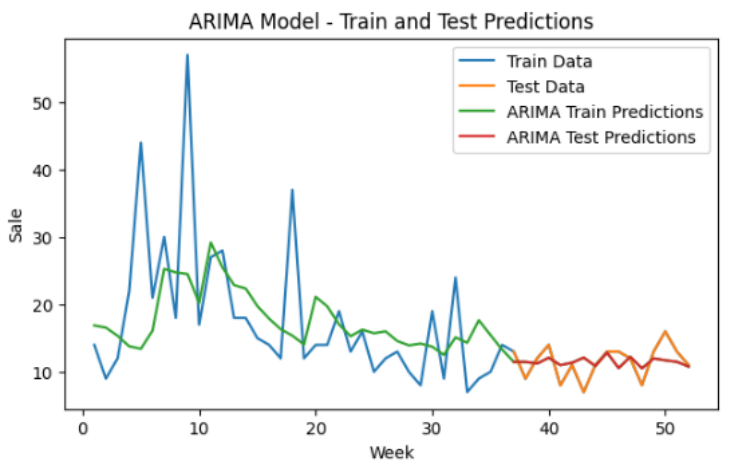

ภาพที่ 20 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 3

ที่มา: ผู้วิจัย

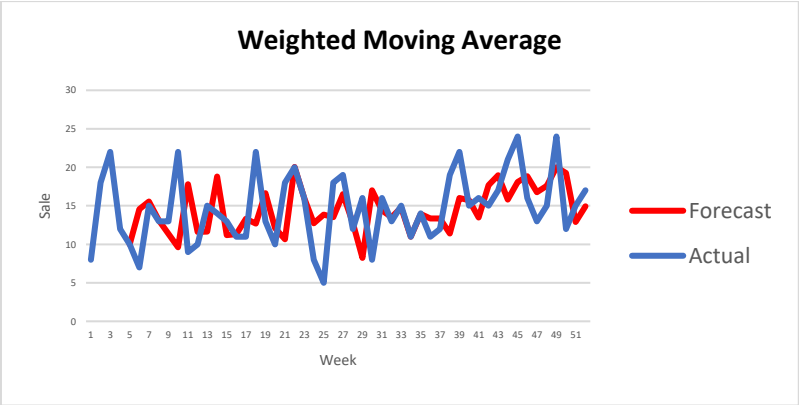

ภาพที่ 21 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU3 สาขาออฟไลน์ 3

ที่มา: ผู้วิจัย

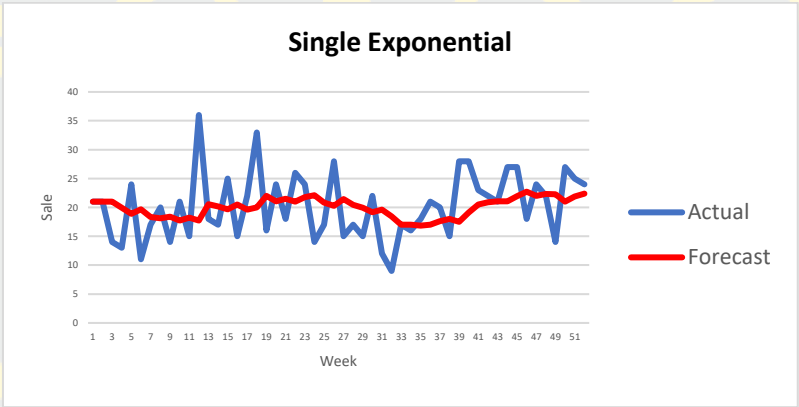

ภาพที่ 22 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU4 สาขาออฟไลน์ 3

ที่มา: ผู้วิจัย

สาขาที่ 3 มีจำนวนรายการสินค้าจำนวน 3 รายการคือ SKU 1, 3, 4 ซึ่งผลการพยากรณ์พบว่ารายการสินค้า SKU 1 แบบจำลองที่มีความแม่นยำที่สุดคือ ARIMA ที่ตัวแบบ (1,0,2) มีความแม่นยำในการพยากรณ์มากที่สุด เนื่องจากตัวชี้วัด 2 ใน 3 คือ MAD และ MSE มีค่าน้อยที่สุด

รายการสินค้า SKU 3 ของสาขาที่ 3 จากผลการวิจัยพบว่าแบบจำลองที่มีความแม่นยำที่สุดคือ WMA ที่ n = 4 เนื่องจากตัวชี้วัด 2 ใน 3 คือ MAD และ MSE มีค่าน้อยที่สุด โดยมีค่าMAD = 3.5 MSE = 21.11 ซึ่งน้อยเป็นอันดับที่ 1 ของแบบจำลองทั้งหมด

รายการสินค้า SKU 4 ของสาขาที่ 3 จากผลการวิจัยพบว่าแบบจำลองที่มีความแม่นยำที่สุดคือ SES เนื่องจากตัวชี้วัด 2 ใน 3 คือ MAD และ MSE มีค่าน้อยที่สุด ส่วน MAPE มีค่าน้อยเป็นอันดับที่ 2 รองจากแบบจำลอง WMA ที่ n = 4 โดยมีค่าที่ห่างกันไม่มาก

ตารางที่ 29 แสดงค่าเปรียบเทียบตัวชี้วัดแบบจำลองทั้ง5แบบของรายการสินค้าสาขาออฟไลน์4และ5

Store	SKU	Forecasting Model		MAD	MSE	MAPE
			n 2	4.13	27.19	25.27%
		Weighted Moving Average	**n 3**	3.85	24.40	23.87%
			n 4	3.39	21.67	21.02%
Store 4	**SKU 1**	**Single Exponential**		3.15	20.77	18.23%
		Double Exponential		3.22	21.17	18.59%
		ARIMA	**(0,1,1)**	**2.31**	**9.38**	**17.02%**
		Feedforward Neural network		4.37	27.24	33.27%
			n 2	1.99	6.27	22.23%
		Weighted Moving Average	**n 3**	1.52	4.07	17.19%
			n 4	1.49	3.86	17.10%
Store 5	**SKU 1**	**Single Exponential**		1.51	3.91	17.60%
		Double Exponential		1.53	3.99	17.80%
		ARIMA	**(0,0,3)**	**1.42**	**3.08**	**16.44%**
		Feedforward Neural network		2.29	6.95	28.01%

ที่มา: ผู้วิจัย

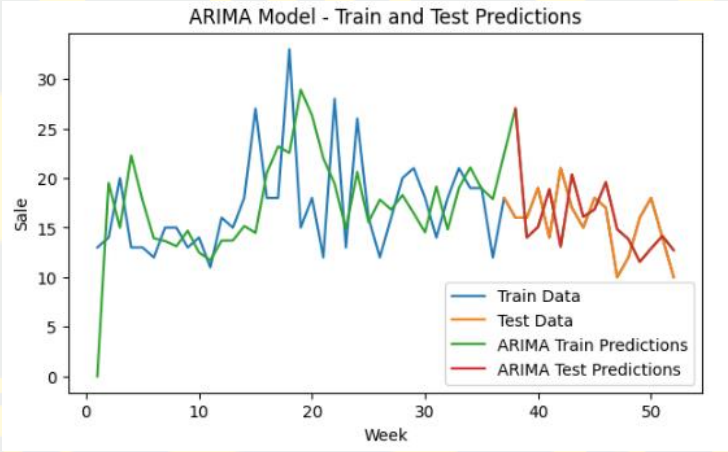

ภาพที่ 23 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 4

ที่มา: ผู้วิจัย

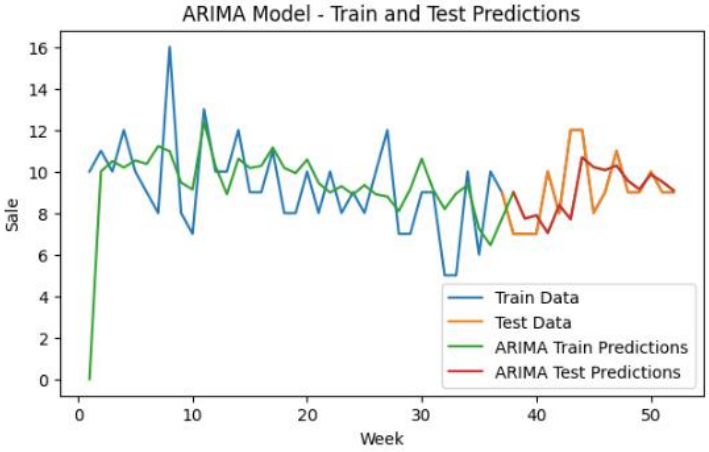

ภาพที่ 24 เปรียบเทียบผลพยากรณ์ของแบบจำลองที่ดีที่สุดของรายการสินค้าSKU1 สาขาออฟไลน์ 5

ที่มา: ผู้วิจัย

สาขาที่ 4 และ 5 มีจำนวนรายการสินค้าจำนวนสาขาละ 1 รายการคือ SKU 1 ซึ่งผลการวิจัยพบว่าแบบจำลอง ARIMA ที่ตัวแบบ (0,1,1) สำหรับสาขาที่ 4 เป็นแบบจำลองการพยากรณ์ที่มีความเหมาะสมกับรายการสินค้านี้มากที่สุด เนื่องจากตัวชี้วัดทั้ง 3 ตัวมีค่าน้อยที่สุด และในส่วนของสาขาที่ 5 แบบจำลอง ARIMA ที่ตัวแบบ (0,0,3) มีค่าความแม่นยำในการพยากรณ์ดีที่สุดจากทั้ง 5 แบบ โดยที่มีค่าตัวชี้วัดทั้ง 3 ตัวน้อยเป็นอันดับที่ 1 ทั้งหมด

สรุปผลการพยากรณ์ของรายการสินค้าทั้ง 18 รายการด้วยแบบจำลองทั้ง 5 วิธี โดยแต่ละรายการสามารถสรุปได้ดังตารางที่ 16

ตารางที่ 30 ตารางสรุปวิธีการพยากรณ์ที่แม่นยำที่สุดของสินค้าแต่ละรายการ

สาขา	รายการสินค้า	วิธีการพยากรณ์ที่แม่นยำที่สุด
ออนไลน์	SKU 1	Autoregressive Integrated Moving Average (ARIMA)
	SKU 2	Weighted Moving Average (WMA)
	SKU 3	Weighted Moving Average (WMA)
	SKU 4	Weighted Moving Average (WMA)
	SKU 5	Autoregressive Integrated Moving Average (ARIMA)
	SKU 6	Weighted Moving Average (WMA)
	SKU 7	Weighted Moving Average (WMA)
	SKU 8	Autoregressive Integrated Moving Average (ARIMA)
	SKU 9	Autoregressive Integrated Moving Average (ARIMA)
	SKU 10	Weighted Moving Average (WMA)
สาขาออฟไลน์ 1	SKU 1	Autoregressive Integrated Moving Average (ARIMA)
สาขาออฟไลน์ 2	SKU 1	Double Exponential Smoothing (DES)
	SKU 3	Single Exponential Smoothing (SES)
สาขาออฟไลน์ 3	SKU 1	Autoregressive Integrated Moving Average (ARIMA)
	SKU 3	Weighted Moving Average (WMA)
	SKU 4	Single Exponential Smoothing (SES)
สาขาออฟไลน์ 4	SKU 1	Autoregressive Integrated Moving Average (ARIMA)
สาขาออฟไลน์ 5	SKU 1	Autoregressive Integrated Moving Average (ARIMA)

ที่มา: ผู้วิจัย

การคำนวณหาค่าสัมประสิทธิ์ความแปรปรวน (Variability coefficient: VC)

จากนั้นทำการคำนวณหาค่าสัมประสิทธิ์ความแปรปรวน (Variability coefficient: VC) เพื่อประเมินและเปรียบเทียบความแปรปรวนของสินค้า โดยใช้ข้อมูลพยากรณ์ตั้งแต่เดือนมกราคม – ธันวาคม ปี พ.ศ. 2565 ด้วยสมการดังนี้

$$\text{Variability coefficient} = \frac{Est\ var\ D}{(\bar{d})^2}$$

โดยที่

$Est\ var\ D$ = ค่าความแปรปรวนของความต้องการสินค้า

$\bar{d}$ = ค่าเฉลี่ยความต้องการสินค้าย้อนหลัง

ซึ่งค่าความแปรวนของความต้องการสินค้าสามารถคำนวณได้จากสมการดังนี้

$$Est\ var\ D = \frac{\sum_{i=1}^{n}(d^2 - \bar{d}^2)}{n}$$

โดยที่

n = จำนวนสัปดาห์ของข้อมูลความต้องการสินค้า

d^2 = ปริมาณความต้องการสินค้ายกกำลังสอง

$\bar{d}^2$ = ค่าเฉลี่ยปริมาณความต้องการสินค้ายกกำลังสอง

ตารางที่ 31 ตารางแสดงค่าสัมประสิทธิ์ความแปรปรวนของสินค้าแต่ละรายการ

สาขา	รายการสินค้า	$\bar{d}$	$\bar{d}^2$	$\sum_{i=1}^{n}(d^2 - \bar{d}^2)$	Est var D	VC
ออนไลน์	SKU 1	152.56	23,274.91	49,217.40	956.05	0.0415
	SKU 2	106.08	11,252.35	25,069.08	511.61	0.0455
	SKU 3	74.80	5,594.31	18,332.29	381.92	0.0683
	SKU 4	68.04	4,629.37	29,376.18	612.00	0.1322
	SKU 5	32.59	1,062.18	9,354.61	179.90	0.1694
	SKU 6	19.30	372.67	895.75	18.66	0.0501
	SKU 7	96.21	9,256.05	56,673.00	1180.69	0.1276
	SKU 8	28.78	828.20	1,103.25	21.63	0.0261
	SKU 9	26.05	678.61	3,043.82	58.53	0.0863
	SKU 10	34.50	1,190.10	4,309.70	89.79	0.0754

สาขาออฟไลน์ 1	SKU 1	14.67	215.23	204.28	3.93	0.0183
สาขาออฟไลน์ 2	SKU 1	11.83	139.95	309.68	3.07	0.0434
	SKU 3	11.94	142.51	198.51	4.14	0.0290
สาขาออฟไลน์ 3	SKU 1	15.77	248.58	1,052.53	20.24	0.0814
	SKU 3	14.47	209.34	408.56	8.51	0.0407
	SKU 4	20.39	415.81	295.83	5.69	0.0137
สาขาออฟไลน์ 4	SKU 1	16.73	279.76	270.46	5.30	0.0190
สาขาออฟไลน์ 5	SKU 1	9.24	85.46	43.13	0.83	0.0097

ที่มา: ผู้วิจัย

จากการคำนวณหาค่าสัมประสิทธิ์ความแปรปรวน (Variability coefficient: VC) ของรายการสินค้าทั้ง 18 รายการ พบว่ารายการสินค้าทั้งหมดมีค่าระหว่าง 0.0097 – 0.1694 ซึ่งมีค่าน้อยกว่า 0.25 ดังนั้นหมายความว่าค่าในชุดข้อมูลไม่แตกต่างจากค่าเฉลี่ยมากและมีค่าความแปรปรวนที่ต่ำ

การคำนวณหาจุดสั่งซื้อใหม่ (Reorder Point: ROP)

การหาจุดสั่งซื้อใหม่ (ROP) โดยทำการใช้ปริมาณความต้องการสินค้าทั้ง 18 รายการ จากการพยากรณ์ด้วยแบบจำลองที่มีความแม่นยำมากที่สุดแต่ละรายการจากสมการได้ดังนี้

$$\mathrm{ROP} = \mathrm{d} \times \mathrm{L}$$

โดยที่

d = ปริมาณความต้องการสินค้าต่อวัน

L = ระยะเวลาการรอคอยสินค้า

ในการดำเนินงานบริษัทกรณีศึกษามีการดำเนินกิจการทุกวัน (365 วัน) และมีรอบรถการจัดส่งสินค้าทุกๆ 7 วัน

ตารางที่ 32 ตารางแสดงจุดสั่งซื้อใหม่ของสินค้าแต่ละรายการ

สาขา	รายการสินค้า	ปริมาณความต้องการทั้งปี	จำนวนวันทำงานทั้งปี	(d)	(L)	(ROP)
ออนไลน์	SKU 1	7,780.62	365	21.32	7	149.22
	SKU 2	5,197.78	365	14.24	7	99.68
	SKU 3	3,590.17	365	9.84	7	68.85
	SKU 4	3,265.9	365	8.95	7	62.63
	SKU 5	1,694.73	365	4.64	7	32.5
	SKU 6	926.63	365	2.54	7	17.77
	SKU 7	4,618.03	365	12.65	7	88.56
	SKU 8	1,467.7	365	4.02	7	28.15
	SKU 9	1,354.61	365	3.71	7	25.98
	SKU 10	1,655.9	365	4.54	7	31.76
สาขาออฟไลน์ 1	SKU 1	762.88	365	2.09	7	14.63
สาขาออฟไลน์ 2	SKU 1	603.33	365	1.65	7	11.57
	SKU 3	573.01	365	1.57	7	10.99
สาขาออฟไลน์ 3	SKU 1	819.85	365	2.25	7	15.72
	SKU 3	694.49	365	1.9	7	13.32
	SKU 4	1,060.35	365	2.91	7	20.34
สาขาออฟไลน์ 4	SKU 1	853.03	365	2.34	7	16.36
สาขาออฟไลน์ 5	SKU 1	480.71	365	1.32	7	9.22

ที่มา: ผู้วิจัย

4.5 การคำนวณต้นทุน

ในส่วนของต้นทุนที่เป็นมูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์ เนื่องจากช่องทางออฟไลน์ทางองค์กรไม่ได้มีนโยบายที่จะมุ่งเน้นการสต๊อกสินค้าไว้ที่สาขา โดยการเลือกรายการสินค้าและจำนวนมาจัดเก็บจะขึ้นอยู่กับวิธีการจัดการของผู้จัดการสาขา ซึ่งแตกต่างกับส่วนของช่องทางออนไลน์ที่ต้องรองรับปริมาณคำสั่งซื้อทั่วทั้งประเทศ ดังนั้นส่วนของต้นทุนที่เป็นมูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์จะเป็นของคลังสินค้าออนไลน์ จะทำการคำนวณสินค้าคงคลังสำรอง (Safety Stock: SS) เมื่อได้

ปริมาณสินค้าคงคลังสำรองแล้วจะนำไปคูณด้วยราคาสินค้าเพื่อเปรียบเทียบมูลค่าสินค้าที่ต้องถือคลองต่อสัปดาห์ โดยคำนวณสินค้าคงคลังสำรองด้วยสมการดังนี้

$$Safety\ Stock = Z\sigma_d\sqrt{L}$$

โดยที่

Z = ค่า *Safety stock factor* (ระดับการให้บริการ 99%, Z= 2.58)

σ_d = ค่าเบี่ยงเบนมาตรฐานของความต้องการสินค้า

L = ระยะเวลานำ (สัปดาห์)

ตารางที่ 33 ตารางแสดงปริมาณสินค้าคงคลังสำรองของสินค้าแต่ละรายการ

รายการสินค้า	ประเภทสินค้า	Safety stock factor	ค่าเบี่ยงเบนมาตรฐาน (σ)	ระยะเวลานำ (L)	สินค้าคงคลังสำรอง (SS)
SKU 1	Gadget Truly Wireless	2.58	31.0652	1	80.15
SKU 2	Gadget Speaker	2.58	22.6189	1	58.36
SKU 3	Gadget Truly Wireless	2.58	19.5428	1	50.42
SKU 4	Gadget Truly Wireless	2.58	24.7387	1	63.83
SKU 5	Electric Appliances	2.58	13.4125	1	34.60
SKU 6	Gadget Speaker	2.58	4.3199	1	11.15
SKU 7	Gadget Headphone/Earphone	2.58	31.3611	1	88.65
SKU 8	Electric Appliances	2.58	4.6510	1	12.00
SKU 9	Accessories	2.58	7.6508	1	19.74
SKU 10	Electric Appliances	2.58	9.4755	1	24.45

ที่มา: ผู้วิจัย

ในส่วนของต้นทุนที่เป็นมูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์ เมื่อคำนวณปริมาณสินค้าคงคลังขั้นต่ำใหม่แล้วเปรียบเทียบพบว่า มีปริมาณสินค้าที่ต้องถือครองลดลงไป 282 ชิ้นต่อสัปดาห์ หรือคิดเป็นมูลค่าลดลงไป 1,746,848 บาทต่อสัปดาห์ โดยมีสินค้า 9 รายการที่มีปริมาณการถือครองลดลง และ 1 รายการที่มีปริมาณเท่าเดิม ซึ่งรายละเอียดในส่วนของจำนวนชิ้นของสินค้าแต่ละรายการได้ทำการปรับค่าให้เป็นจำนวนเต็มดังตารางที่ 20

ตารางที่ 34 แสดงค่าเปรียบเทียบต้นทุนและปริมาณสินค้าคงคลังขั้นต่ำต่อสัปดาห์

รายการสินค้า	ราคา (ชิ้น)	Safety Stock per Week (ปัจจุบัน)	Cost (ปัจจุบัน)	Safety Stock (ใหม่)	Cost (ใหม่)	ผลลัพธ์ (บาท)
SKU 1	8,992	200	1,798,400	81	728,352	1,070,048
SKU 2	4,390	120	526,800	59	259,010	267,790
SKU 3	6,790	70	475,300	51	346,290	129,010
SKU 4	4,990	80	399,200	64	319,360	79,840
SKU 5	2,190	50	109,500	35	76,650	32,850
SKU 6	11,900	20	238,000	12	142,800	95,200
SKU 7	1,490	100	149,000	89	132,610	16,390
SKU 8	1,990	40	79,600	12	23,880	55,720
SKU 9	4,490	20	89,800	20	89,800	-
SKU 10	4,290	30	128,700	25	107,250	21,450

ที่มา: ผู้วิจัย

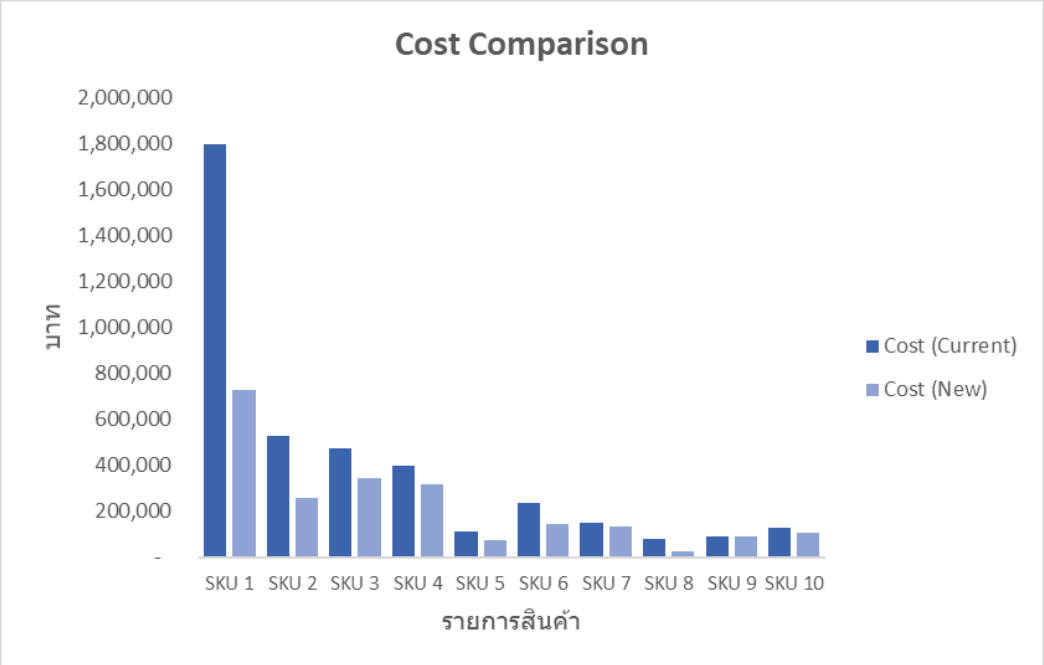

ภาพที่ 25 กราฟเปรียบเทียบต้นทุนมูลค่าสินค้าที่ต้องถือครองต่อสัปดาห์ระหว่างแบบปัจจุบันและแบบใหม่

ที่มา: ผู้วิจัย

บทที่ 5
สรุปอภิปรายผลและข้อเสนอแนะ

5.1 สรุปผลการศึกษา

ท่ามกลางการแข่งขันของอุตสาหกรรม e-Commerce ในปัจจุบันการเลือกดำเนินกลยุทธ์ต่างๆ เพื่อสร้างความได้เปรียบในการแข่งขันกับคู่แข่งรายอื่นนั้นเป็นเรื่องที่สำคัญ การพยากรณ์ที่มีประสิทธิภาพจะมีบทบาทสำคัญในการจัดการห่วงโซ่อุปทาน การควบคุมสินค้าคงคลัง และรวมไปถึงการตัดสินใจเชิงกลยุทธ์ งานวิจัยนี้นำเสนอการวิเคราะห์ที่ครอบคลุมของแบบจำลองการพยากรณ์ยอดขายกลุ่มเครื่องใช้ไฟฟ้าขององค์กรกรณีศึกษาที่มีช่องทางการจัดจำหน่ายทั้งออนไลน์และออฟไลน์ โดยใช้ ABC Analysis เพื่อเลือก SKU ที่เหมาะสมที่สุดสำหรับการพยากรณ์ร่วมกับแบบจำลองต่างๆ

การพยากรณ์ปริมาณยอดขายของสาขาออนไลน์ผลลัพธ์ที่ได้แสดงให้เห็นว่า แบบจำลอง WMA ที่จำนวนของข้อมูลย้อนหลังมากขึ้นมีแนวโน้มว่าจะมีค่าความแม่นยำที่สูงขึ้น โดยรายการสินค้า SKU 6 ใน 10 รายการมีความแม่นยำในการพยากรณ์ด้วยแบบจำลอง WMA ที่ดีกว่าแบบจำลองอื่น แม้ว่า WMA จะให้ผลลัพธ์การพยากรณ์ที่ดีที่สุดจากทุกแบบจำลอง แต่ในส่วนของแบบจำลองอื่นๆ เช่น SES DES และ ARIMA ต่างก็ให้ค่าความแม่นยำในการพยากรณ์ที่เกาะกลุ่มกันกับ WMA เช่นกัน ซึ่งสอดคล้องกับงานวิจัยของ Mulphala (2014) ที่ได้ใช้เครื่องมือการพยากรณ์โดยวิธีการปรับเรียบเอกซ์โปเนนเชียล และ ARIMA ซึ่งได้ให้ผลลัพธ์การพยากรณ์ที่ใกล้เคียงกัน ในส่วนของสาขาออฟไลน์พบว่ารายการสินค้า SKU 4 ใน 8 รายการจากทั้ง 5 สาขาแสดงให้เห็นว่าแบบจำลอง ARIMA ให้ผลลัพธ์ที่แม่นยำกว่าแบบจำลองอื่นทั้ง 4 แบบ โดยแบบจำลองที่มีระดับความแม่นยำรองลงมาคือ SES จากผลลัพธ์ที่ได้แสดงให้เห็นว่าพฤติกรรมการเลือกซื้อสินค้าของผู้บริโภคในส่วนของสาขาออนไลน์และสาขาออฟไลน์นั้นมีความคล้ายกัน เนื่องจากแบบจำลองที่สามารถแสดงประสิทธิภาพได้ดีกับรายการสินค้าออนไลน์ก็สามารถแสดงผลลัพธ์ที่ดีกับสาขาออฟไลน์ได้เช่นกัน

ด้านประสิทธิภาพของแบบจำลองการพยากรณ์ความต้องการของลูกค้าองค์กรกรณีศึกษาจากการพยากรณ์ยอดขายกับรายการสินค้าช่องทางออนไลน์ทั้ง 10 รายการพบว่า แบบจำลอง WMA ที่จำนวนของข้อมูลย้อนหลังมากขึ้นมีแนวโน้มว่าจะมีค่าความแม่นยำที่สูงขึ้น โดยรายการสินค้า 6 จาก 10 รายการมีความแม่นยำในการพยากรณ์ด้วยแบบจำลอง WMA ที่ดีกว่าแบบจำลองอื่น แม้ว่า WMA จะให้ผลลัพธ์การพยากรณ์ที่ดีที่สุดจากทุกแบบจำลอง แต่ในส่วนของแบบจำลองอื่น เช่น แบบจำลอง ARIMA ต่างก็ให้ค่าความแม่นยำในการพยากรณ์ที่เกาะกลุ่มกับแบบจำลอง WMA เช่นกัน ทางด้านช่องทางออฟไลน์พบว่า รายการสินค้า 4 จาก 8 รายการจากทั้ง 5 สาขาแสดงให้เห็นว่า

แบบจำลอง ARIMA ให้ผลลัพธ์ที่แม่นยำกว่าแบบจำลองอื่น และการนำเครื่องมือ Akaike Information Criterion (AIC) เข้ามาช่วยกำหนดค่าพารามิเตอร์ p, d, q สามารถให้ผลลัพธ์ที่ดีได้ ซึ่งสอดคล้องกับงานวิจัยของ Zhao, Li, & Qu (2022) ที่ได้ทำการพยากรณ์ด้วยแบบจำลอง ARIMA โดยใช้ AIC กำหนดค่าพารามิเตอร์สำหรับการพยากรณ์

ทางด้านประสิทธิภาพของแบบจำลองการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลชั้นเดียว (SES) และแบบจำลองการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (DES) พบว่าค่า Alpha ของรายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า การพยากรณ์จะให้ความสำคัญกับข้อมูลในอดีตมากกว่า ในส่วนของค่า Beta ในแบบจำลอง DES พบว่ารายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 เช่นกัน ซึ่งหมายความว่าองค์ประกอบแนวโน้มไม่เปลี่ยนแปลงอย่างมีนัยสำคัญเมื่อเวลาผ่านไป หรือมีการเปลี่ยนแปลงในอัตราที่ช้ามาก วิธีการตรวจไม่พบแนวโน้มที่แข็งแกร่งในข้อมูล ซึ่งอาจมีสาเหตุมาจาก ความผันผวนของข้อมูลในระยะสั้นหรือข้อมูลไม่เพียงพอ ซึ่งอาจเป็นผลมาจากยอดขายสินค้าในวันที่จัดโปรโมชั่นที่มักจะมียอดขายสูงกว่าปกติ จากสาเหตุที่กล่าวมาส่งผลให้แบบจำลองการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้งทำงานได้ไม่เต็มประสิทธิภาพ ในส่วนของแบบจำลองการพยากรณ์ด้วยวิธี FFNNs ในงานวิจัยนี้ แม้ว่าในตัวชี้วัดของสินค้าบางรายการจะมีค่าความคลาดเคลื่อนที่ต่ำที่สุด แต่เมื่อดูภาพรวมประสิทธิภาพของแบบจำลองได้แสดงให้เห็นผลลัพธ์ที่มีค่าความคลาดเคลื่อนสูงกว่าวิธีอื่น ซึ่งไม่สอดคล้องกับงานวิจัยของ Aljaaf, Mohsin, Al-Jumeily, & Alloghani (2021) ที่ได้พยากรณ์ด้วยแบบจำลอง FFNNs กับข้อมูลที่เป็นอนุกรมเวลาและได้ให้ผลลัพธ์ที่มีประสิทธิภาพกับการพยากรณ์ เมื่อพิจารณาจากการวิเคราะห์ ABC พบว่าสินค้าส่วนใหญ่ในงานวิจัยนี้จะเป็นกลุ่มสินค้าตามฤดูการ ซึ่งข้อมูลที่ใช้พยากรณ์ในงานวิจัยนี้มีระยะเวลา 1 ปี อาจไม่เพียงต่อการเรียนรู้ของแบบจำลอง จึงสรุปได้ว่าแบบจำลองการพยากรณ์ FFNNs เป็นเครื่องมือที่ไม่มีประสิทธิภาพในงานวิจัยนี้

เมื่อดูจากผลลัพธ์การพยากรณ์ของสาขาออนไลน์และออฟไลน์พบว่าแบบจำลอง ARIMA มีความเหมาะสมกับข้อมูลรายการสินค้าส่วนใหญ่มากกว่าแบบจำลองอื่นๆ อย่างไรก็ตามในการนำไปใช้จริงควรใช้ร่วมกับแบบจำลองอื่นๆด้วยเช่นกัน เนื่องจากสินค้าบางรายการ แบบจำลองอื่นเช่น WMA SES และ DES ได้ให้ผลลัพธ์การพยากรณ์ที่ดีกว่า ในส่วนของต้นทุนมูลค่าการถือครองสินค้าขั้นต่ำต่อสัปดาห์หลังจากคำนวณ Safety Stock ใหม่แล้ว เมื่อเปรียบเทียบกับปัจจุบันมีต้นทุนลดลงไป 1,746,848 บาท หรือประมาณ 45%

สำหรับระดับการให้บริการ (Service level) ถึงแม้ว่าปริมาณสินค้าคงคลังขั้นต่ำจะมีระดับที่ลดลงแต่เนื่องด้วยการพยากรณ์ที่แม่นยำจะช่วยให้บริษัทสามารถวางแผนการสต๊อกสินค้า หรือรวมไปถึงการจัดส่งและกระจายสินค้าได้มีประสิทธิภาพมากขึ้น โดยเฉพาะสินค้าที่มีอายุการเก็บรักษา (Shelf life) ซึ่งในกรณีศึกษานี้จะเป็นพวกอุปกรณ์คอมพิวเตอร์ เช่น หูฟัง ลำโพง และรวมไปถึงสินค้าที่มียางเป็นส่วนประกอบ เนื่องจากสินค้าเหล่านี้จำเป็นต้องเก็บอยู่ในอุณหภูมิที่เหมาะสม ถ้าหากเก็บไว้ในที่ที่มีอุณหภูมิสูงจนเกินไปจะทำให้ส่วนประกอบของยางเสื่อมสภาพเร็วขึ้น ดังนั้นการวางแผนจัดส่งสินค้าที่มีประสิทธิภาพมากขึ้นจะช่วยป้องกันปัญหานี้ โดยลูกค้าจะได้รับสินค้าที่มีคุณภาพและสามารถรักษาระดับการให้บริการ (Service level) แก่ลูกค้าได้

5.2 ข้อเสนอแนะ

ผลการทดลองในงานวิจัยนี้เป็นการพยากรณ์ยอดขายรายการสินค้าประเภทเครื่องใช้ไฟฟ้าของบริษัทเอกชนแห่งหนึ่ง โดยใช้เครื่องมือพยากรณ์ทั้งหมด 5 แบบคือ WMA, SES, DES, ARIMA, และ FFNNs ซึ่งทางผู้วิจัยมีความเห็นในประเด็นต่างๆ รวมถึงข้อเสนอแนะเพื่อเป็นแนวทางในการพัฒนางานวิจัยในอนาคต ดังนี้

1. ข้อมูลที่ใช้ในการพยากรณ์ในงานวิจัยนี้มีระยะเวลา 1 ปี ซึ่งข้อมูลที่นำมาพยากรณ์ของสินค้าบางรายการมีระยะเวลาไม่เพียงพอต่อการสังเกตแนวโน้มแบบจำลองของสินค้าบางรายการโดยเฉพาะสินค้าที่เป็น Seasonal Product ดังนั้นเพื่อผลลัพธ์การพยากรณ์ที่ดีขึ้นทางผู้วิจัยมีข้อเสนอว่าควรมีปริมาณของข้อมูลที่มีระยะเวลามากกว่านี้

2. ลักษณะของข้อมูลที่ใช้พยากรณ์ ทางผู้วิจัยพบว่าข้อมูลที่ดึงมาจากระบบภายในองค์กร มีคำสั่งซื้อที่อยู่ในลักษณะของ B2B ซึ่งคำสั่งซื้อลักษณะนี้ส่วนใหญ่มักจะเป็นการสั่งซื้อในปริมาณมากและเป็นการทำสัญญาซื้อในราคาพิเศษ ซึ่งถือว่าเป็นส่วนของข้อมูลการสั่งซื้อที่ไม่ปกติ ซึ่งทางผู้วิจัยพยายามที่จะตัดส่วนของข้อมูลคำสั่งซื้อที่ไม่ปกตินี้ออกไป แต่ก็พบว่าหลายๆคำสั่งซื้อได้ใช้ชื่อของบุคคลในการสั่ง ทำให้ยากต่อการคัดกรอง ผู้วิจัยมีข้อเสนอว่าในการเก็บข้อมูลคำสั่งซื้อควรมีการแยกประเภทของคำสั่งซื้อ เพื่อให้ง่ายต่อการนำข้อมูลมาใช้พยากรณ์และเพิ่มประสิทธิภาพของการพยากรณ์ให้ดียิ่งขึ้น

3. ในการพยากรณ์ด้วยแบบจำลอง ARIMA และ FFNNs ส่วนของการกำหนดค่าพารามิเตอร์ในงานวิจัยนี้ได้ใช้ AIC และ Grid search เป็นเครื่องมือในการช่วยกำหนดค่า ซึ่งในงานวิจัยต่อไปสามารถใช้เป็นแนวทางในการเลือกเครื่องมืออื่นๆเข้ามาช่วยในการกำหนดค่า เพื่อเปรียบเทียบผลการพยากรณ์ด้วยเครื่องมือช่วยกำหนดค่าพารามิเตอร์ต่างๆได้

4. ส่วนของแบบจำลองโครงข่ายประสาทเทียมในงานวิจัยนี้ได้ใช้ Adam เป็น Optimizer เพียงตัวเดียวที่ช่วยในการปรับค่าอัตราการเรียนรู้ ดังนั้นในงานวิจัยต่อไปผู้วิจัยมีข้อเสนอว่าควรใช้ Optimizer หลายๆตัวเพื่อเปรียบเทียบความสามารถในการช่วยปรับค่าอัตราการเรียนรู้ รวมไปถึงการใช้ ANNs ตัวอื่นๆเข้ามาเปรียบเทียบผลการพยากรณ์ โดยอาจจะมีการทำ Association rule ของสินค้าเพื่อหาความสัมพันธ์ที่เกี่ยวข้องของสินค้าที่ลูกค้ามักจะซื้อพร้อมกัน เพื่อนำไปเป็นตัวแปรในการพยากรณ์

5. กรณีของแบบจำลอง Feedforward Neural network (FFNNs) ในงานวิจัยนี้พบว่า ได้ให้ผลลัพธ์ที่ไม่ค่อยดีนักเมื่อเทียบกับแบบจำลองอื่น โดยปัญหาที่พบก็คือข้อมูลมีช่วงระยะเวลาที่สั้นเกินไป ซึ่งช่วงข้อมูลที่สั้นอาจไม่ได้ให้ตัวอย่างที่เพียงพอสำหรับแบบจำลองในการเรียนรู้ความสัมพันธ์ที่ซ่อนอยู่อย่างมีประสิทธิภาพ รวมไปถึงทำให้แบบจำลองไม่สามารถจับรูปแบบหรือแนวโน้มของข้อมูลได้

บรรณานุกรม

Aljaaf, A. J., Mohsin, T. M., Al-Jumeily, D., & Alloghani, M. (2021). A fusion of data science and feed-forward neural network-based modelling of COVID-19 outbreak forecasting in IRAQ. *Journal of Biomedical Informatics, 118*, 103766.

Chaiyadecha, S. (2021). วิธีทำ Cross Validation สำหรับ Time series. Retrieved from https://lengyi.medium.com/cross-validation-time-series-model-1cca8424e442

Chawla, A., Singh, A., Lamba, A., Gangwani, N., & Soni, U. (2019). *Demand forecasting using artificial neural networks—a case study of American retail corporation.* Paper presented at the Applications of Artificial Intelligence Techniques in Engineering: SIGMA 2018, Volume 2.

Dasananda, N., & Chaovalitwongse, P. (2022). Inventory management support system for home decor onlinebusiness *Journal of Engineering and Innovation, 15*(3), 71-80.

ETDA. (2021). Value of e-Commerce Survey in Thailand 2021. Retrieved from https://www.etda.or.th/th/Useful-Resource/publications/Value-of-e-Commerce-Survey-in-Thailand-2021-Slides.aspx

Heckman, E. (2016). Fitting an ARIMA Model. Retrieved from https://blog.minitab.com/en/starting-out-with-statistical-software/fitting-an-arima-model

Jiang, G., & Wang, W. (2017). Markov cross-validation for time series model evaluations. *Information Sciences, 375*, 219-233.

Kitsupasin, K. (2021). *Omni Channel Marketing Factors Effecting on Purchasing Decision Making Consumers of Central Department Store in the Region of Bangkok Metropolis.* Bangkok University,

Limkonchotiwat, P. (2019). Deep Learning Optimization & Activation Function. Retrieved from https://medium.com/mmp-li/deep-learning-ep-2-optimization-activation-function

Mulphala, K. (2014). STUDY OF THE APPROPRIATE FORECASTING METHODS FOR CONSUMER PRODUCT DEMAND OF A PUBLIC COMPANY. *Journal of Business*

Administration The Association of Private Higher Education Institutions of Thailand, 3(1), 12-21.

Neslin, S. A., Grewal, D., Leghorn, R., Shankar, V., Teerling, M. L., Thomas, J. S., & Verhoef, P. C. (2006). Challenges and opportunities in multichannel customer management. *Journal of service research, 9(2)*, 95-112.

Phuthongkham, C., & Tiwaratreewit, T. (2021). DEMAND FORECASTING FOR RAW MATERIALS TO REDUCE THE LOST SALES OPPORTUNITY., A CASE STUDY FOR A PIZZA HUK T&J SHOP. *Valaya Alongkorn, 2*(3), 20-31.

Ploensuk, P., Yawila, L., & Sitt-uam, R. (2022). Trust Perception Experience Value and Patronage Intention of Herbal Cosmetics Product in Omni-Channel of Consumers in Meaung District, Phitsanulok Province. *Academic Journal of Phetchaburi Rajabhat University., 12*(2), 86-97.

Ryu, J. S. (2019). Consumer characteristics and shopping for fashion in the omni-channel retail environment. *Asian Journal of Business Environment, 9(4)*, 15-22.

Salagosa, N. (2022). An Inventory Management Optimization Honey Roasted Banana Products : A Case Study of the Local Herbal Processing Community Enterprise Group at Mae Ramat Sub-district, Mae Ramat District, Tak Province. *The Golden Teak: Humanity and Social Science Journal, 28*(2), 134-140.

Sawadsaringkarn, P. (2022). ABC Analysis. Retrieved from https://drpiyanan.com/2022/03/05/abc-analysis/

SEA, e.-C. (2020). Southeast Asia E-commerce: Winning the Next Wave of Shoppers. Retrieved from https://www.thinkwithgoogle.com/intl/en-apac/consumer-insights/consumer-trends/how-southeast-asia-ecommerce-businesses-can-take-brands-to-next-level/

Sermpongpan, C., Chungcharoen, E., & Opasanon, S. (2020). Forecasting of Cement Consumption in Thailand. *NIDA Business Journal*(26), 81-107.

Shrivastava, S. (2020). Cross Validation in Time Series. Retrieved from https://medium.com/@soumyachess1496/cross-validation-in-time-series-566ae4981ce4

Shukla, M., & Jharkharia, S. (2011). ARIMA models to forecast demand in fresh supply chains. *International Journal of Operational Research, 11*(1), 1-18.

Sriphrabu, P., & Chamnanlor, C. (2022). Economic Order-quantity Determination for Fuel Demand: a Case Study of a Freight Forwarder. *RMUTP Research Journal, 16*(2), 54-64.

Sujjaviriyasup, T. (2020). Forecasting Model for Currency Exchange Rates. *Thai Science and Technology Journal*, 26-40.

Sumranhun, P., Rungcharoen, S., Damrongwatthanayothin, B., somtobburana, P., patsaphat, B., & Nuchpum, T. (2023). THE REDUCING OF THE ERROR IN FORECASTING DEMAND FOR INDUSTRIAL PRODUCTS WITH HIGH VARIATION BY DATA TRANSFORMATION TECHNIQUES. *Journal of Management and Marketing Rajamangala University of technology Thanyaburi, 10*(1), 36-54.

Thompson. (2021). 13 เทรนด์พฤติกรรมช้อปคนไทย และกลยุทธ์แบรนด์บาลานซ์ช่องทางขาย “Online-Physical Shop-D2C”. Retrieved from https://www.brandbuffet.in.th/2021/06/thailand-future-shopper-2021-online-physical-shop-d2c-trends/

Worachotepanyaratana, S. (2021). Demand Forecasting and Inventory Management: A Case Study of Automotive Part Manufacturing Company. *Sripatum Chonburi Academic Journal, 17*(3), 155-166.

Xi, J., & Sha, P. B. (2014). Research on optimization of inventory management based on demand forecasting. *Applied Mechanics and Materials, 687*, 4828-4831.

Zhao, L., Li, Z., & Qu, L. (2022). Forecasting of Beijing PM2. 5 with a hybrid ARIMA model based on integrated AIC and improved GS fixed-order methods and seasonal decomposition. *Heliyon, 8*(12).

มหาวิทยาลัยบูรพา
BURAPHA UNIVERSITY

ประวัติย่อของผู้วิจัย

ชื่อ-สกุล ธนพนธ์ สาริกา

วัน เดือน ปี เกิด 1 กรกฎาคม 2540

สถานที่เกิด จังหวัดลพบุรี

สถานที่อยู่ปัจจุบัน เดอะไรส์ คอนโดมิเนียม บี3 142/201 หมู่ 1 ต.เสม็ด อ.เมืองชลบุรี จ.ชลบุรี 20000

ประวัติการศึกษา หลักสูตรบริหารธุรกิจบัณฑิต สาขาการค้าระหว่างประเทศและการจัดการโลจิสติกส์ คณะโลจิสติกส์ มหาวิทยาลัยบูรพา