



การพยากรณ์ยอดขายสำหรับการขายปลีกในอีคอมเมิร์ซโดยใช้การเรียนรู้ของเครื่อง
SALES FORECASTING FOR RETAIL SALE IN E-COMMERCE USING MACHINE

LEARNINGS



วรัญชรี ธิรพัฒน์นพร

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566

การพยากรณ์ยอดขายสำหรับการขายปลีกในสหรัฐอเมริกาโดยใช้การเรียนรู้ของเครื่อง



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566

ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

SALES FORECASTING FOR RETAIL SALE IN E-COMMERCE USING MACHINE
LEARNINGS



VARUNCHAREE TIRAPHATTANAPORN

A Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การพยากรณ์ยอดขายสำหรับการขายปลีกในอเมริกาโดยใช้การเรียนรู้ของเครื่อง

ของ

วรัญชรี ธิรพัฒน์นพร

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

ที่ปรึกษาหลัก

(อาจารย์ ดร.ศุภร คนธภักดิ์)

ประธาน

(รองศาสตราจารย์ ดร.ดวงดาว วิชาดากุล)

กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.นุรีย์ วิวัฒน์วัฒนา)

ชื่อเรื่อง	การพยากรณ์ยอดขายสำหรับการขายปลีกในอีคอมเมิร์ซโดยใช้การเรียนรู้ของเครื่อง
ผู้วิจัย	วรัญชรี ธิรพัฒนานพร
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	อาจารย์ ดร. ศุภร คนธภักดี

การพยากรณ์ยอดขายนั้นช่วยให้ผู้ประกอบการสามารถคาดการณ์ยอดขายหรือมูลค่าของสินค้าที่ต้องผลิตได้ ส่งผลให้สามารถผลิตสินค้าได้เพียงพอตามความต้องการของผู้บริโภค งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาการสร้างแบบจำลองที่ใช้สำหรับการพยากรณ์ยอดขายสินค้า โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบลึก LSTM เปรียบเทียบสมรรถนะกับแบบจำลองโครงข่ายประสาทเทียมแบบ MLP แบบจำลองอนุกรมเวลาแบบ SARIMA และ SARIMAX ในการพยากรณ์ยอดขายสินค้าล่วงหน้า โดยใช้ชุดข้อมูลการสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ ซึ่งมีข้อมูลยอดขายรายวันตั้งแต่เดือน มกราคม 2564 ถึง มิถุนายน 2566 ผู้วิจัยสนใจที่จะเปรียบเทียบผลของการพยากรณ์ โดยพิจารณาจากค่า RMSE MAE และ MAPE ในการเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 4 วิธี ผลจากการทดลองพบว่า แบบจำลอง LSTM มีประสิทธิภาพในการพยากรณ์ยอดขายที่แม่นยำกว่า MLP SARIMA และ SARIMAX ในสินค้าแฉก้นทรงสูง และแฉก้นทรงเอียงกลาง ซึ่งสินค้าทั้ง 2 ชนิดนี้มีความซับซ้อนของข้อมูลอย่างมาก เนื่องจากในปี 2564 ช่วงสถานการณ์โควิดทำให้มียอดขายสูงขึ้นอย่างรวดเร็ว และในปีต่อมามียอดขายกลับลดลงอย่างรวดเร็ว ซึ่งในแบบจำลอง LSTM มีความสามารถในการจัดเรียงข้อมูลและจำความจำในช่วงเวลาที่ย้อนหลังได้ดี และมีความสามารถในการจัดการกับลักษณะข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพ และแบบจำลอง MLP มีประสิทธิภาพในการพยากรณ์ยอดขายที่แม่นยำกว่า LSTM SARIMA และ SARIMAX ในสินค้าแฉก้นทรงสูงใหญ่ เนื่องจากแฉก้นทรงสูงใหญ่มีลักษณะของข้อมูลที่มีความซับซ้อนน้อยลง จึงทำให้ MLP มีประสิทธิภาพที่ดีกว่า และจากการทดลองแบบจำลอง SARIMAX เพื่อพิจารณาวันโปรโมชันเข้าไปเป็นปัจจัยภายนอกในแบบจำลอง ซึ่งจากการทดลองพบว่าแบบจำลอง SARIMAX ให้ประสิทธิภาพที่ดีกว่าแบบจำลอง SARIMA แสดงว่าวันโปรโมชันส่งผลให้แบบจำลองมีประสิทธิภาพที่ดีขึ้น

คำสำคัญ : การพยากรณ์ยอดขายสินค้า, การเรียนรู้ของเครื่อง, โครงข่ายประสาทเทียมแบบลึก, อนุกรมเวลา

Title	SALES FORECASTING FOR RETAIL SALE IN E-COMMERCE USING MACHINE LEARNINGS
Author	VARUNCHAREE TIRAPHATTANAPORN
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Subhorn Khonthapagdee

The forecasting of sales enables business owners to anticipate and meet consumer demand, thereby ensuring that products are produced in sufficient quantities, neither exceeding nor falling short of consumer needs. This research aimed to study the creation of models for sales forecasting using LSTM and compare their performance with the MLP, SARIMA and SARIMAX models. The dataset used in this study comes from a retail store in Thailand that sells products online. The dataset included daily transactional sales data from January 2021 to June 2023. The researchers aim to compare the performance of forecasting using the LSTM model, MLP model, SARIMA model, and the SARIMAX model, considering metrics such as RMSE, MAE, and MAPE. The experimental results indicate that the LSTM model outperforms MLP, SARIMA, and SARIMAX in accurately forecasting sales for Tall Vase and Medium Slanted Vase products. Both product types exhibited highly complex data patterns, especially during the COVID-19 situation in 2020, when sales rapidly increased, followed by a sharp decline in the subsequent year. The LSTM model's ability to sequence data and retain memory of past trends allows it to accurately capture seasonal patterns and data trends. Additionally, it efficiently handles complex data characteristics, leading to superior performance. The MLP model demonstrates better performance in forecasting sales for Large Tall Vase products, which had fewer complex data characteristics compared to the other product types. The simplified data nature of these products contributes to the MLP model's effectiveness. Furthermore, the SARIMAX model, which incorporates promotional days as external factors, outperforms the SARIMA model. This indicates that promotional days significantly influence the model's forecasting accuracy, improving its performance.

Keyword : Sales forecast, Machine learning, Long-and short-term memory, Time series models

กิตติกรรมประกาศ

การจัดทำวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดีจากการสนับสนุน ความรู้ความช่วยเหลือ คำแนะนำ ตลอดจนแนวทางในการทำวิจัยและจัดทำสารนิพนธ์ของ อ.ดร.ศุภร คนธภักดี อาจารย์ที่ปรึกษา และคณาจารย์ทุกท่านในหลักสูตรวิทยาการข้อมูล ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์มหาวิทยาลัยศรีนครินทรวิโรฒ การสนับสนุนจากบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการนำเสนอผลงานวิจัย ผู้วิจัยจึงขอขอบคุณมา ณ ที่นี้



วรัญชรี ถิรพัฒนานพร

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ณ
สารบัญรูปภาพ	ญ
บทที่ 1 บทนำ.....	1
ที่มาและความสำคัญ	1
วัตถุประสงค์.....	2
ขอบเขตของการวิจัย	2
ประโยชน์ที่คาดว่าจะได้รับ.....	3
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	4
1. ทฤษฎีเกี่ยวกับ Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX)	4
2. ทฤษฎีเกี่ยวกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short- Term Memory: LSTM)	9
3. ทฤษฎีเกี่ยวกับโครงข่ายประสาทเทียมแบบ Multi-Layer Perceptron (MLP).....	13
4. ทฤษฎีเกี่ยวกับการประเมินวัดความแม่นยำของแต่ละอัลกอริทึม	15
5. งานวิจัยที่เกี่ยวข้อง	16
บทที่ 3 วิธีดำเนินการวิจัย.....	24

1. กระบวนการทำงานของแบบจำลอง.....	24
2. การเก็บรวบรวมข้อมูล (Data Collection).....	26
3. การสำรวจข้อมูล (Exploratory Data Analysis : EDA).....	27
4. การเตรียมข้อมูล (Data Preparation)	32
5. อัลกอริทึมของแบบจำลองการทำนาย	36
บทที่ 4 ผลการดำเนินการวิจัย	43
1. ผลลัพธ์ของการสร้างแบบจำลอง SARIMA	43
2. ผลลัพธ์ของการสร้างแบบจำลอง SARIMAX.....	46
2. ผลลัพธ์ของการสร้างแบบจำลอง LSTM	48
3. ผลลัพธ์ของการสร้างแบบจำลอง MLP	51
4. ผลลัพธ์จากการเปรียบเทียบการพยากรณ์ยอดขายระหว่างแบบจำลอง SARIMA LSTM และ MLP.....	53
บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	57
1. สรุปผลการวิจัย.....	57
2. อภิปรายผลการวิจัย	58
3. ข้อเสนอแนะ	60
บรรณานุกรม	61
ประวัติผู้เขียน.....	64

สารบัญตาราง

หน้า

ตาราง 1 ตารางเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า RMSE ของแต่ละแบบจำลอง .	18
ตาราง 2 ตารางเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า RMSE ของแต่ละแบบจำลอง .	19
ตาราง 3 แสดงตารางสรุปผลงานวิจัยที่ศึกษา.....	23
ตาราง 4 แสดงตัวแปรของรายการธุรกรรมการขาย	26
ตาราง 5 แสดงค่าพารามิเตอร์ที่ใช้ของสินค้าแต่ละประเภทในแบบจำลอง SARIMA และ แบบจำลอง SARIMAX	38
ตาราง 6 แสดงผลการวัดประสิทธิภาพในแต่ละสินค้า ของแบบจำลอง SARIMA	44
ตาราง 7 แสดงผลการวัดประสิทธิภาพของแต่ละสินค้า ของแบบจำลอง SARIMAX	46
ตาราง 8 แสดงผลการวัดประสิทธิภาพของแต่ละสินค้า ของแบบจำลอง LSTM.....	49
ตาราง 9 แสดงผลการวัดประสิทธิภาพของแต่ละสินค้า ของแบบจำลอง MLP.....	51
ตาราง 10 แสดงค่า RMSE MAE และ MAPE ของแต่ละแบบจำลอง	58

สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 แสดงโครงสร้างของ RNN	9
ภาพประกอบ 2 แสดงโครงสร้างของ LSTM.....	9
ภาพประกอบ 3 แสดงโครงสร้างของ Forget gate layer	10
ภาพประกอบ 4 แสดงโครงสร้างของ Input gate layer	11
ภาพประกอบ 5 แสดงโครงสร้างของ Output gate layer.....	12
ภาพประกอบ 6 Multi-Layer Perceptron	15
ภาพประกอบ 7 Flowchart กระบวนการทำงานของแบบจำลอง SARIMA และ SARIMAX	24
ภาพประกอบ 8 Flowchart กระบวนการทำงานของแบบจำลอง LSTM และ MLP	25
ภาพประกอบ 9 แสดงตัวอย่างข้อมูลธุรกรรมการขาย.....	27
ภาพประกอบ 10 แสดงยอดขายตั้งแต่ปี 2564 - 2566 โดยจำแนกตามรายเดือน	27
ภาพประกอบ 11 แสดงจำนวนออเดอร์ในแต่ละเดือนและปี.....	28
ภาพประกอบ 12 แสดงจำนวนออเดอร์ในแต่ละวัน.....	28
ภาพประกอบ 13 แสดงจำนวนออเดอร์ตามช่วงเวลา	29
ภาพประกอบ 14 แสดงยอดขายแยกตามหมวดหมู่.....	29
ภาพประกอบ 15 แสดงยอดขายแยกตามหมวดหมู่และปี.....	30
ภาพประกอบ 16 แสดงยอดขายสินค้าในหมวดหมู่ของตกแต่งบ้าน	30
ภาพประกอบ 17 แสดงยอดขายสินค้าในสินค้าประเภทแจกัน	31
ภาพประกอบ 18 แสดงคอลัมน์ CodeDiscount ที่ทำการแปลงข้อมูล.....	32
ภาพประกอบ 19 แสดงคอลัมน์ Promotion_Day และ SumPromotionDay ที่ทำการเพิ่มเข้ามา	33
ภาพประกอบ 20 แสดงคอลัมน์ End_of_week ที่ทำการเพิ่มเข้ามา	33
ภาพประกอบ 21 แสดงข้อมูล Netprice และ SumPromotionDay ตาม End_of_Week	34

ภาพประกอบ 22 แสดงความสัมพันธ์ระหว่างยอดขายกับวันโปรโมชั่น	34
ภาพประกอบ 23 แสดงความสัมพันธ์ระหว่างยอดขาย (Netprice) กับ วันโปรโมชั่น (promotion_day)	35
ภาพประกอบ 24 แสดงความสัมพันธ์ระหว่างยอดขาย (Netprice) กับ รหัสส่วนลด (CodeDiscount)	35
ภาพประกอบ 25 แสดงความสัมพันธ์ระหว่างยอดขาย (Netprice) กับ รวมโปรโมชั่น (SumPromotionDay)	36
ภาพประกอบ 26 แสดงค่า Trend Seasonal และ Residual ของ train data แจกกันทรงสูง	37
ภาพประกอบ 27 แสดงค่า Trend Seasonal และ Residual ของ train data แจกกันทรงเอียงกลาง	37
ภาพประกอบ 28 แสดงค่า Trend Seasonal และ Residual ของ train data แจกกันทรงสูงใหญ่	38
ภาพประกอบ 29 แสดงค่า Loss ในแต่ละ epochs ของแจกกันทรงสูง	40
ภาพประกอบ 30 แสดงค่า Loss ในแต่ละ epochs ของแจกกันทรงเอียงกลาง	40
ภาพประกอบ 31 แสดงค่า Loss ในแต่ละ epochs ของแจกกันทรงสูงใหญ่	40
ภาพประกอบ 32 แสดงค่า Loss ในแต่ละ epochs ของแจกกันทรงสูง	41
ภาพประกอบ 33 แสดงค่า Loss ในแต่ละ epochs ของแจกกันทรงเอียงกลาง	42
ภาพประกอบ 34 แสดงค่า Loss ในแต่ละ epochs ของแจกกันทรงสูงใหญ่	42
ภาพประกอบ 35 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงสูง	44
ภาพประกอบ 36 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงเอียงกลาง	45
ภาพประกอบ 37 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงสูงใหญ่	45
ภาพประกอบ 38 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงสูง	47
ภาพประกอบ 39 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงเอียงกลาง	47
ภาพประกอบ 40 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงสูงใหญ่	48
ภาพประกอบ 41 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกกันทรงสูง	49

ภาพประกอบ 42 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงเอียงกลาง..... 50

ภาพประกอบ 43 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูงใหญ่..... 50

ภาพประกอบ 44 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูง 52

ภาพประกอบ 45 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงเอียงกลาง..... 52

ภาพประกอบ 46 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูงใหญ่..... 53

ภาพประกอบ 47 แสดงการเปรียบเทียบการพยากรณ์ในแต่ละแบบจำลองของแจกันทรงสูง 53

ภาพประกอบ 48 แสดงการเปรียบเทียบการพยากรณ์ในแต่ละแบบจำลองของทรงเอียงกลาง.... 54

ภาพประกอบ 49 แสดงการเปรียบเทียบการพยากรณ์ในแต่ละแบบจำลองของแจกันทรงสูงใหญ่54

ภาพประกอบ 50 กราฟแสดงค่า RMSE MAE และ MAPE เปรียบเทียบระหว่างแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าแจกันทรงสูง 55

ภาพประกอบ 51 กราฟแสดงค่า RMSE MAE และ MAPE เปรียบเทียบระหว่างแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าแจกันทรงเอียงกลาง..... 55

ภาพประกอบ 52 กราฟแสดงค่า RMSE MAE และ MAPE เปรียบเทียบระหว่างแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าแจกันทรงสูงใหญ่..... 56

บทที่ 1

บทนำ

ที่มาและความสำคัญ

ในปัจจุบันเศรษฐกิจกำลังก้าวเข้าสู่ยุคดิจิทัล อีกทั้งอินเทอร์เน็ตได้เข้ามามีบทบาทอย่างยิ่งในชีวิตประจำวัน จึงส่งผลให้ธุรกิจออนไลน์นั้นเป็นสิ่งที่ได้รับความนิยมมากขึ้น ซึ่งจะเห็นได้ชัดในช่วงปี 2563 - 2564 ที่ผ่านมา เป็นช่วงที่ประชาชนต้องเจอกับโรคระบาด Covid-19 ทำให้การใช้ชีวิตประจำวันต้องมีการเปลี่ยนแปลงไป จากการซื้อขายผ่านทางหน้าร้าน กลัปกกลายเป็นการซื้อขายช่องทางออนไลน์ จึงส่งผลให้อัตราการซื้อขายช่องทางออนไลน์ หรือ E-commerce มีอัตราการเติบโตสูงขึ้นอย่างมีนัยยะ ทำให้หลายธุรกิจเห็นความสำคัญและผลักดันการขายผ่านช่องทางออนไลน์ อีกทั้งประชาชนบางส่วนได้เห็นความสำคัญในการขายออนไลน์เพิ่มขึ้น จึงเป็นเหตุผลที่ทำให้ช่องทางออนไลน์มีร้านใหม่เกิดขึ้นอย่างแพร่หลาย แต่กลับพบว่าไม่ใช่ทุกธุรกิจที่จะประสบความสำเร็จ อย่างบางธุรกิจหากไม่มีการเตรียมพร้อมทางด้านความต้องการของผู้บริโภค ขั้นตอนการผลิต การจัดการคลังสินค้า หรือกลยุทธ์ต่างๆ ที่ใช้ในการดึงดูดผู้บริโภค ก็อาจจะทำให้ธุรกิจนั้นไม่ประสบความสำเร็จ ดังนั้นจากสถานการณ์ที่ไม่แน่นอนที่อาจเกิดขึ้นได้ในอนาคต การเตรียมความพร้อมต่างๆ เป็นสิ่งที่สำคัญ หากเจ้าของธุรกิจทราบประมาณการจำนวนสินค้าที่ผู้บริโภคต้องการหรือยอดขายล่วงหน้าได้ จะทำให้ธุรกิจสามารถรับมือได้กับทุกสถานการณ์ และยังทำให้เจ้าของธุรกิจสามารถบริหารงบประมาณที่มีอยู่ให้เกิดประโยชน์สูงสุดกับธุรกิจอีกด้วย

ด้วยเหตุนี้การวางแผนและการจัดการที่ดีจึงเป็นสิ่งสำคัญต่อธุรกิจอย่างมาก เนื่องจากการผลิตสินค้าแต่ละชิ้นต่างมีต้นทุนในการผลิต หากมีการสั่งผลิตสินค้าที่มากเกินไปเกินความต้องการของผู้บริโภค อาจทำให้สินค้าค้างสต็อกและเงินจมทุนได้ หรืออีกกรณีที่มีการสั่งผลิตสินค้าไม่พอต่อความต้องการของผู้บริโภค อาจทำให้ผู้ประกอบการเสียโอกาสในการขายสินค้าดังกล่าว ด้วยเหตุผลข้างต้นหากมีการพยากรณ์ยอดขายในอนาคตได้อย่างแม่นยำ จะทำให้ผู้ประกอบการสามารถคาดการณ์ความต้องการหรือมูลค่าของสินค้าที่ต้องผลิตได้ ทำให้ธุรกิจสามารถเผชิญกับความผันแปรของความต้องการได้ จึงทำให้สามารถผลิตสินค้าได้เพียงพอตามความต้องการของผู้บริโภค ไม่มากเกินไปหรือน้อยเกินไป ทำให้ธุรกิจได้กำไรตามที่คาดการณ์ไว้ นอกจากนี้การพยากรณ์ยอดขายยังเปรียบเสมือนเป้าหมายหลักของธุรกิจ ที่ต้องใช้กลยุทธ์ต่างๆ เพื่อให้บรรลุเป้าหมาย หรืออาจกล่าวได้ว่าการวางแผนที่ดีจะนำไปสู่การขับเคลื่อนธุรกิจที่ดี

ผู้วิจัยจึงเล็งเห็นปัญหานี้ ดังนั้นจุดมุ่งหมายของการวิจัยเพื่อสร้างแบบจำลองการพยากรณ์ยอดขายสินค้า โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบลึก Long-Short-Term

Memory (LSTM) เปรียบเทียบสมรรถนะกับแบบจำลองโครงข่ายประสาทเทียมแบบ Multi-Layer Perceptron (MLP) แบบจำลองอนุกรมเวลาแบบ Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX) ในการพยากรณ์ยอดขายสินค้าล่วงหน้า

วัตถุประสงค์

1. เพื่อศึกษาการสร้างแบบจำลองและวิเคราะห์เปรียบเทียบสมรรถนะของ แบบจำลองโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM) เปรียบเทียบกับแบบจำลองโครงข่ายประสาทเทียมแบบ Multi-Layer Perceptron (MLP) แบบจำลองอนุกรมเวลาแบบ Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX) ในการพยากรณ์ยอดขายล่วงหน้า โดยทำการพยากรณ์ยอดขายเป็นรายสัปดาห์ (Week)
2. เพื่อให้ทราบถึงหลักการของอัลกอริทึม LSTM, MLP และแบบจำลองอนุกรมเวลา SARIMA, SARIMAX แล้วสามารถนำมาปรับใช้งานได้เหมาะสม
3. เพื่อให้ทราบถึงแนวโน้มของความต้องการสินค้าของลูกค้าในช่วงเวลาของการทำนาย และสามารถนำแบบจำลองนี้ไปประยุกต์ใช้งานได้จริง

ขอบเขตของการวิจัย

1. ข้อมูลที่ใช้ในงานวิจัย ใช้ข้อมูลการสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ ซึ่งมีข้อมูลยอดขายรายวันตั้งแต่เดือน มกราคม 2564 ถึง มิถุนายน 2566
2. เตรียมข้อมูลและทำความสะอาดให้ข้อมูลอยู่ในรูปแบบที่พร้อมนำมาวิเคราะห์และสร้างแบบจำลองในการพยากรณ์ยอดขาย โดยทำการพยากรณ์สินค้าที่ขายดี 3 อันดับ ได้แก่ แจกัณฑ์ทองสูง แจกัณฑ์ทองสูงใหญ่ และแจกัณฑ์ทองเอียงกลาง
3. สร้างแบบจำลองการพยากรณ์โดยใช้ แบบจำลองโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM) เปรียบเทียบกับแบบจำลองโครงข่ายประสาทเทียมแบบ Multi-Layer Perceptron (MLP) แบบจำลองอนุกรมเวลาแบบ Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX)

4. วัดประสิทธิภาพของแบบจำลอง โดยพิจารณาจาก ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error: RMSE) ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) และ ค่าเฉลี่ยเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

ประโยชน์ที่คาดว่าจะได้รับ

- 1.สามารถนำแบบจำลองที่ได้ไปประยุกต์ใช้งานได้จริง
- 2.สามารถพยากรณ์ยอดขายหรือจำนวนของสินค้าที่ต้องผลิตได้ ทำให้ธุรกิจสามารถเผชิญกับความผันแปรของความต้องการได้ ส่งผลให้สามารถผลิตสินค้าได้เพียงพอตามความต้องการของผู้บริโภค ไม่มากเกินไปหรือน้อยเกินไป



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

ในการศึกษาการพยากรณ์ยอดขายของสินค้า ผู้วิจัยได้ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง และได้นำเสนอตามหัวข้อต่อไปนี้

1. ทฤษฎีเกี่ยวกับ Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX)
2. ทฤษฎีเกี่ยวกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM)
3. ทฤษฎีเกี่ยวกับโครงข่ายประสาทเทียมแบบ (Multi-Layer Perceptron : MLP)
4. ทฤษฎีเกี่ยวกับการประเมินวัดความแม่นยำของแต่ละอัลกอริทึม
5. งานวิจัยที่เกี่ยวข้อง

การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

การวิเคราะห์ข้อมูลทางสถิติที่เปลี่ยนแปลงไปตามลำดับการเกิดขึ้น หรือการเปลี่ยนแปลงของตัวแปรในช่วงเวลาที่ผ่านมา ซึ่งในการเปลี่ยนแปลงของข้อมูลเหล่านั้น อาจจะเป็นการเปลี่ยนแปลงที่มีรูปแบบ หรือไม่มีก็ได้ แต่ในกรณีที่ข้อมูลทางสถิติดังกล่าวแสดงให้เห็นถึงรูปแบบในช่วงเวลาที่ผ่านมาในอดีต จะส่งผลทำให้สามารถพยากรณ์การเปลี่ยนแปลงของข้อมูลในอนาคตได้ โดยการวิเคราะห์ข้อมูลอนุกรมเวลาจะขึ้นอยู่กับ การเปลี่ยนแปลงของเวลาในอดีตเป็นที่ตั้ง (บรรจงพัฒนา and Banjongpattana 2021)

1. ทฤษฎีเกี่ยวกับ Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX)

แบบจำลอง ARIMA โดยวิธีของ George E.P.Box และ Gwilym M. Jenkins มีชื่อเต็มว่า Auto-Regressive Integrated Moving Average เป็นวิธีการทางสถิติที่ใช้สำหรับวิเคราะห์และพยากรณ์อนุกรมเวลา (Time Series) โดยมีพารามิเตอร์ คือ p, d, q ซึ่งแบบจำลอง ARIMA จะต้องมีความสมบัติ Stationary

การทดสอบ Stationary ของข้อมูล สามารถทดสอบทางสถิติด้วย Augmented Dickey-Fuller test (ADF-Test) ซึ่งถูกนำเสนอโดย Dickey และ Fuller ในปี ค.ศ. 1979 โดยมีแนวคิดในการทดสอบ Unit Root ของข้อมูลอนุกรมเวลาว่ามีความคงที่หรือไม่ โดยที่ทำการทดสอบสมมติฐานด้วยกันทั้งหมด 3 แบบ ได้แก่ 1. ไม่มีค่าคงที่และแนวโน้มเวลา 2. มีค่าคงที่ 3. มีค่าคงที่และแนวโน้มเวลา โดยในการพิจารณาว่าข้อมูลมีลักษณะคงที่หรือไม่คงที่จะใช้การเปรียบเทียบค่าสถิติ ADF-Test เทียบกับค่าวิกฤต Mackinnon ซึ่งมีสมมติฐาน ดังนี้

สมมติฐานหลัก	$H_0: \delta = 0$	ข้อมูลมี Unit Root
สมมติฐานรอง	$H_1: \delta < 0$	ข้อมูลไม่มี Unit Root

หากข้อมูลทำการทดสอบยอมรับสมมติฐานหลัก H_0 แสดงว่าข้อมูลนั้นมีลักษณะ Nonstationary แต่ถ้าข้อมูลทำการทดสอบปฏิเสธสมมติฐานหลัก H_0 แสดงว่าข้อมูลนั้นมี Stationary ดังสมการที่ (1), (2) และ (3)

$$\text{ไม่มีค่าคงที่และแนวโน้มเวลา} \quad \Delta X_t = \theta X_{t-1} + \varepsilon_t \quad (1)$$

$$\text{มีเฉพาะค่าคงที่} \quad \Delta X_t = \alpha + X_{t-1} + \varepsilon_t \quad (2)$$

$$\text{มีทั้งค่าคงที่และแนวโน้มเวลา} \quad \Delta X_t = \alpha + \beta_t \theta X_{t-1} + \varepsilon_t \quad (3)$$

โดยที่ θ เป็น ค่าพารามิเตอร์ของการทดสอบ Unit Root

β_t เป็น ค่าคงที่ของแนวโน้ม

α เป็น ค่าคงที่ระดับ

ต่อมาในปี ค.ศ. 1984 Said and Dickey นำเสนอว่า หากข้อมูลมีลักษณะไม่คงที่ จะต้องทำการหาผลต่างลำดับที่ 1 ของข้อมูลชุดนี้ ซึ่งจากขั้นตอนนี้จะทำให้ทราบว่าจะต้องทำการ Integrated ของแบบจำลอง ARIMA(p,d,q) นั้น ว่าค่าของ d มีค่าเท่าใด โดยเพิ่มจำนวนพจน์ของ Lagged Difference เข้าไปในสมการเพื่อแก้ปัญหาความสัมพันธ์ในตัว (Autocorrelation)

ในปี ค.ศ. 1976 George E.P.Box และ Gwilym M. Jenkins ได้พัฒนาแบบจำลอง SARIMAX โดยมีข้อสมมติฐานว่าค่าปัจจุบันของค่าสังเกตเป็นฟังก์ชันเชิงเส้นของค่าสังเกตและค่าความคลาดเคลื่อนสุ่มในอดีต (Kaewhawong 2015) ซึ่งแบบจำลอง SARIMAX

เป็นการรวมกันของอนุกรมเวลา (Time Series) 3 เทคนิค ประกอบไปด้วย 3 ส่วนหลัก ๆ ได้แก่ AR (Autoregressive), I(Integrated) และ MA (Moving average) ซึ่งในแต่ละเทคนิคมีหน้าที่ช่วยกำจัด Noise ออกจากข้อมูลเพื่อพยายามลด Error term ให้มากที่สุด และความแตกต่างระหว่างแบบจำลอง SARIMAX กับ ARIMA คือ แบบจำลอง SARIMAX สามารถจัดการข้อมูลที่มีลักษณะเป็นฤดูกาลได้ดี และสามารถเพิ่มปัจจัยภายนอกหรือ Exogenous variables เข้าไปในแบบจำลองได้ เพื่อช่วยประสิทธิภาพในการทำนายได้ดียิ่งขึ้น โดยมีพารามิเตอร์ p, d, q, P, D, Q, s และ $exog$ โดยที่ $AR = p, P$ (Seasonal), $I = d, D$ (Seasonal), $MA = q, Q$ (Seasonal), $s =$ ตัวกำหนดช่วงเวลาของอนุกรมเวลาและ Exogenous variables เป็นตัวแปรปัจจัยภายนอก (Xinxiang, Bo and Huijuan 2017) โดยรายละเอียดของแต่ละส่วนมีดังนี้

1) แบบจำลอง Auto Regressive (AR (p))

แบบจำลอง Auto Regressive หรือ AR(p) เป็นวิธีการคาดการณ์ค่าในอนาคตจากข้อมูลในอดีต โดยใช้ค่าที่ผ่านมา p ค่า มาวิเคราะห์และหาความสัมพันธ์ โดยกระบวนการ AR นั้นใช้พารามิเตอร์ p ซึ่งเป็นค่า lag (ค่าความล่าช้า) ซึ่งสามารถเขียนอยู่ในรูปสมการได้ดังสมการที่ (4)

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (4)$$

โดยที่

- c เป็น ค่าคงที่
- ϕ_p เป็น order ของ Auto regressive
- y_{t-p} เป็น ค่าของอนุกรมเวลาที่เวลา $t-p$
- ε_t เป็น ค่าคลาดเคลื่อนของโมเดล (ค่า white noise)

2) แบบจำลอง Moving Average (MA (q))

แบบจำลอง Moving Average (MA) หรือ MA(q) เป็นวิธีการคาดการณ์ค่าในอนาคตจาก ความคลาดเคลื่อนของข้อมูลในอดีต กล่าวคือ เทคนิค Moving Average (MA) มีหลักการทำงานคล้ายกับ (Auto regressive) AR แต่แตกต่างกันตรงที่ Moving Average (MA) จะสนใจความสัมพันธ์ระหว่าง error ของช่วงเวลาปัจจุบัน โดยกระบวนการ MA นั้นใช้พารามิเตอร์ q ในการหา error ซึ่งสามารถเขียนให้อยู่ในรูปสมการได้ดังสมการที่ (5)

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (5)$$

โดยที่

- c เป็น ค่าคงที่
 ε_t เป็น ค่า error ของ Model (ค่า white noise)
 θ_q เป็น order ของ Moving Average
 ε_{t-q} เป็น ผลรวมระหว่างค่าปัจจุบันกับค่าก่อนหน้าของ error term

3) กระบวนการ Integrated (I(d))

กระบวนการ Integrated (I(d)) คือ การหาผลต่างระหว่างข้อมูลปัจจุบันกับข้อมูล ถอยหลังไป d คาบเวลา โดยสาเหตุที่ต้องทำการหาผลต่างของอนุกรมเวลา เนื่องจากแบบจำลอง ARIMA ต้องใช้ในการวิเคราะห์ข้อมูลอนุกรมเวลาที่มีคุณสมบัติคงที่ (Stationary) เท่านั้น โดยในกรณีข้อมูลอนุกรมเวลาที่ใช้ในการวิเคราะห์ที่มีคุณสมบัติไม่คงที่ (Non-Stationary) จะต้องทำการแปลงข้อมูลดังกล่าวให้เป็นข้อมูลที่มีคุณสมบัติคงที่ก่อน โดยการหาผลต่างของข้อมูลอนุกรมเวลา (Differencing) ก่อนที่นำไปสร้างแบบจำลอง ARIMA หรือ SARIMA ซึ่งโดยทั่วไปแล้วหากต้องการหาผลต่างอันดับที่ d สามารถเขียนในรูปของ I(d) ดังนี้

$$I(d) \quad \text{คือ} \quad \Delta_d \chi_t = \Delta_{d-1} (\chi_t - \chi_{t-1})$$

$$\text{หรือ} \quad (1-B)^d \chi_t$$

ความแตกต่างของแบบจำลอง SARIMAX และแบบจำลอง ARIMA ที่กล่าวข้างต้น ดังสมการที่ (6) สมการที่ (7) และ สมการที่ (8)

ARIMA Model

$$\varphi(B) \nabla^d y(t) = \theta(B) \varepsilon(t) \quad (6)$$

SARIMA Model

$$\varphi(B) \phi(B^S) \nabla^d \nabla_S^D y(t) = \theta(B) \vartheta(B^S) \varepsilon(t) \quad (7)$$

SARIMAX Model

$$\varphi(B) \phi(B^S) \nabla^d \nabla_S^D y(t) = \beta_k x'_{k,t} + \theta(B) \vartheta(B^S) \varepsilon(t) \quad (8)$$

จากสมการ

$y(t)$	เป็น ตัวแปรที่ใช้สำหรับทำนาย
$\varphi(B)$	เป็น order ที่ไม่เป็นฤดูกาล ของ Autoregressive
$\varnothing(B^S)$	เป็น order ที่ไม่เป็นฤดูกาล ของ Autoregressive
$\theta(B)$	เป็น order ที่ไม่เป็นฤดูกาล ของ Moving Average
$\vartheta(B^S)$	เป็น order ที่เป็นฤดูกาล ของ Moving Average
∇^d	เป็น order ของการ differencing ที่ไม่เป็นฤดูกาล ของ Integrated
∇_S^D	เป็น order ของการ differencing ที่เป็นฤดูกาล ของ Integrated
$\varepsilon(t)$	เป็น ค่าคลาดเคลื่อนของโมเดล (ค่า white noise)
β_k	เป็น ค่าสัมประสิทธิ์ของตัวแปร exogenous ที่ใส่เข้ามา k^{th}
$x'_{k,t}$	เป็น ค่า vector ที่ประกอบด้วยตัวแปรที่ถูก input เข้ามา k^{th} ที่เวลา t

สรุปพารามิเตอร์ที่ใช้ใน ARIMA SARIMA และ SARIMAX

- p คือ พารามิเตอร์ของ AR (Autoregressive) เป็นจำนวนครั้งที่ค่าของตัวแปรตามช่วงเวลาก่อนหน้า (lag) ที่ถูกนำมาใช้ในการทำนายค่าในช่วงเวลา โดยปกติจะต้องพิจารณา ลักษณะของกราฟ ACF (Autocorrelation Function) เพื่อเลือกค่าที่เหมาะสมสำหรับ p

- d คือ พารามิเตอร์ I (Integrated) เป็นจำนวนครั้งในการทำ Differencing ทั้งหมด (ทำ Differencing เพื่อให้ข้อมูลเป็น stationary)

- q คือ พารามิเตอร์ MA (Moving Average) เป็นจำนวนครั้งที่ค่าของค่าคลาดเคลื่อนในช่วงเวลาก่อนหน้า (lag) จะถูกนำมาใช้ในการทำนายค่าในช่วงเวลาปัจจุบัน โดยปกติจะต้องพิจารณา ลักษณะของกราฟ PACF (Partial Autocorrelation Function) เพื่อเลือกค่าที่เหมาะสม สำหรับ q

- P คือ พารามิเตอร์ของ AR (Autoregressive) ที่เป็นฤดูกาล


- D คือ พารามิเตอร์ I (Integrated) เป็นจำนวนในการทำ Differencing ที่เป็น seasonal

- Q คือ พารามิเตอร์ MA (Moving Average) ที่เป็นฤดูกาล

- exog คือ เพิ่มตัวแปรตัวอื่นเข้าไปในแบบจำลอง ARIMA เพื่อเพิ่มความแม่นยำในการช่วยทำนาย

- s คือ ตัวที่กำหนดช่วงเวลาของอนุกรมเวลาและขึ้นอยู่กับข้อมูลที่ถูกนำมาใช้ เช่น ข้อมูลเป็นราย week $s=12$ (12 สัปดาห์ = 1 ไตรมาส) เป็นต้น

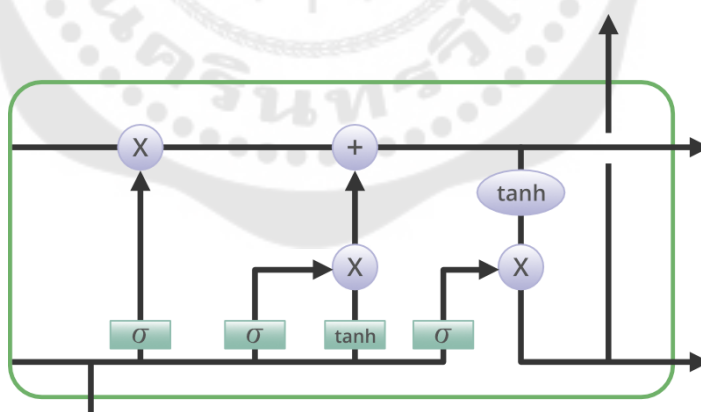
2. ทฤษฎีเกี่ยวกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM)



ภาพประกอบ 1 แสดงโครงสร้างของ RNN

ที่มา : (Tangruamsub, 2017)

Long Short-Term Memory Model (LSTM) เป็นเทคนิคที่ถูกพัฒนามาจาก Recurrent neural network (RNN) โดย Sepp Hochreiter และ Juergen Schmidhuber ซึ่งข้อเสียของ RNN คือ สามารถดูข้อมูลย้อนหลังได้แค่เพียงระยะสั้น ๆ เท่านั้น จึงทำให้เกิดปัญหาในการทำ Backpropagation algorithm ซึ่งจะคำนวณ gradient ของ loss function ย้อนหลังของแต่ละโหนด การทำ Backpropagation จะทำย้อนกลับไปหลายขั้นตอนและหลายโหนด จึงทำให้เกิดปัญหา Vanishing Gradient Problem ดังนั้นเพื่อแก้ไขปัญหาดังกล่าว จึงทำให้เกิดเทคนิค LSTM ขึ้นมา



ภาพประกอบ 2 แสดงโครงสร้างของ LSTM

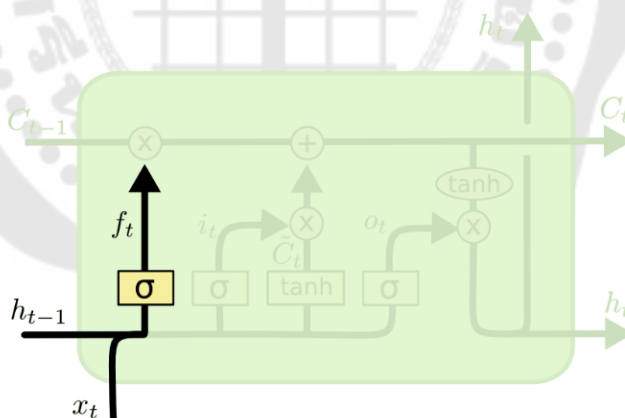
ที่มา : (aakarshachug, 2023)

Long Short-Term Memory (LSTM) ถือว่าเป็นประเภทหนึ่งของสถาปัตยกรรมแบบ Recurrent Neural Network (RNN) LSTM ถูกออกแบบให้จดจำ Patterns ในช่วงเวลานานๆ มี

ประสิทธิภาพสำหรับปัญหาการทำนายที่เป็น Sequential เนื่องจากสามารถเก็บข้อมูลก่อนหน้า และนำมาร่วมใช้ในการประมวลผลได้ สามารถแก้ปัญหา Long-term Dependency ได้ โดย RNN แบบดั้งเดิมจะเผชิญกับ ความท้าทายในเรื่อง Long-range Dependency และมีปัญหา Vanishing Gradient ซึ่ง LSTM ถูกออกแบบมาให้จดจำ Long-term Information โดยใช้ Gating Mechanisms ที่ออกแบบมาเฉพาะ และสามารถใช้ Model ได้ทั้ง Long-term และ Short-term Temporal Sequences (Soontranon 2023)

หลักการการทำงานของแบบจำลอง LSTM คือ สามารถจัดเก็บสถานะ หรือข้อมูลของแต่ละ โหนดเอาไว้เพื่อที่เวลาย้อนกลับไปได้จะดูที่ทราบถึงที่มาของข้อมูลดังกล่าวว่าเดิมเป็นค่าอะไร และในแบบจำลอง LSTM มีฟังก์ชันพิเศษที่มีหน้าที่เหมือนประตู (Gate) ที่จะทำหน้าที่ควบคุมข้อมูลที่ จะเข้ามาในแต่ละโหนด ซึ่งประกอบไปด้วย 1. Forget gate layer เปรียบเสมือนประตูความจำ คัดเลือกข้อมูลที่สำคัญเก็บไว้ และลืมข้อมูลที่ไม่สำคัญ 2. Input gate layer เปรียบเสมือนประตูรับ ข้อมูล คัดเลือกข้อมูลใหม่ที่สำคัญเข้ามาประมวลผล 3. Output gate layer เปรียบเสมือนประตู ส่งออกและควบคุมผลลัพธ์ที่ส่งออก

Forget Gate Layer



ภาพประกอบ 3 แสดงโครงสร้างของ Forget gate layer

ที่มา : (Olah, 2015)

Forget Gate มีหน้าที่ในการคัดเลือกข้อมูลที่เข้ามาใน Cell State โดยจะคัดเลือกข้อมูลที่ สำคัญเก็บไว้ และลืมข้อมูลที่ไม่สำคัญ ซึ่งข้อมูลที่คัดเลือกว่าควรเก็บไว้ จะถูกประเมินจากข้อมูล

input ที่เข้ามาในโหนดนั้นๆ รวมกับผลลัพธ์ที่ได้จากการคำนวณของโหนดก่อนหน้า ผ่านฟังก์ชัน sigmoid ดังสมการที่ (9)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (9)$$

จากสมการ

f_t เป็น Forget gate

σ เป็น ฟังก์ชัน sigmoid

W_f เป็น คำนวณน้ำหนักของ matrices


h_{t-1} เป็น ค่า output ของ cell state ก่อนหน้า (ที่ timestamp t-1)

x_t เป็น ค่า input ที่เข้ามาใน cell state ณ เวลา t

b_f เป็น ค่า bias

ผลลัพธ์ที่ได้จาก Forget gate layer จะมีค่าอยู่ระหว่าง 0 และ 1 หากได้ค่าเป็น 0 หมายถึงให้ลบค่าเดิมออก และหากได้ค่าเป็น 1 หมายถึงให้เก็บค่าไว้

Input gate layer



ภาพประกอบ 4 แสดงโครงสร้างของ Input gate layer

ที่มา : (Olah, 2015)

Input Gate มีหน้าที่ควบคุม การไหลของข้อมูลใหม่ จากอินพุตปัจจุบันเข้าสู่เซลล์หน่วยความจำ (Cell State) โดยพิจารณาความสำคัญร่วมกับข้อมูลที่อยู่ในเซลล์หน่วยความจำอยู่แล้ว จากนั้นส่ง Candidate Input แล้วรอการอนุมัติจาก Forget Gate ดังสมการที่ (10) และ (11)


$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (10)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (11)$$

จากสมการ

- i_t เป็น Input gate
- σ เป็น ฟังก์ชัน sigmoid
- C_t เป็น ค่า candidate ของ cell state ที่เวลา t
- \tanh เป็น ฟังก์ชัน tanh
- W_i, W_c เป็น ค่าน้ำหนักของ matrices
- h_{t-1} เป็น ค่า output ของ cell state ก่อนหน้า (ที่ timestamp t-1)
- x_t เป็น ค่า input ที่เข้ามาใน cell state ณ เวลา t
- b_i, b_c เป็น ค่า bias

Output gate layer



ภาพประกอบ 5 แสดงโครงสร้างของ Output gate layer

ที่มา : (Olah, 2015)

Output Gate ทำหน้าที่เป็นตัวกรอง ควบคุมว่าข้อมูลได้จากเซลล์หน่วยความจำ (Cell State) ที่ส่งผลต่อเอาต์พุตของ time step ปัจจุบันจริง ๆ และถูกส่งต่อไปยังหน่วย LSTM ถัดไปในลำดับ ช่วยให้เครือข่ายสามารถเลือกได้อย่างมีวิจารณญาณว่าข้อมูลจากอดีตใดที่เกี่ยวข้องมากที่สุดสำหรับงานปัจจุบันโดยข้อมูลที่จะทำการ output นั้นจะดูจาก cell state ที่ผ่านกระบวนการคำนวณต่างๆ แล้ว ดังสมการที่ (12)

$$o_t = \sigma (W_o \cdot [h_{t-1}, x_t] + b_o) \quad (12)$$

จากสมการ

- o_t เป็น Output gate
- σ เป็น ฟังก์ชัน sigmoid
- W_o เป็น ค่าน้ำหนักของ matrices
- h_{t-1} เป็น ค่า output ของ cell state ก่อนหน้า (ที่ timestamp t-1)
- x_t เป็น ค่า input ที่เข้ามาใน cell state ณ เวลา t
- b_o เป็น ค่า bias

output ที่ได้ออกมานั้นจะถูกแบ่งออกเป็น 2 ส่วน คือ ค่า output ที่ได้จาก โหนดนั้นๆ กับ ค่า output ที่จะถูกส่งไปเป็นข้อมูล input ของโหนดถัดไป

สรุปพารามิเตอร์ที่ใช้ในแบบจำลอง LSTM


- Number of neurons, nodes คือจำนวน neurons ที่ใช้ในแต่ละ hidden layer ของ LSTM
- Epoch คือ จำนวนรอบที่โมเดลจะทำ forward และ back propagation วนไปเรื่อยๆ จนครบ training sample ทั้งหมด
- Batch size คือจำนวนของ sample ที่ถูก training ในหนึ่ง batch

3. ทฤษฎีเกี่ยวกับโครงข่ายประสาทเทียมแบบ Multi-Layer Perceptron (MLP)

MLP ย่อมาจาก Multi-Layer Perceptron เป็นแบบจำลองเครือข่ายประสาทเทียมประเภทหนึ่ง que เรียนรู้จากข้อมูลผ่านกระบวนการ supervised learning เปรียบเสมือนสมองกลจักรที่มีโครงสร้างหลายชั้น ทำงานคล้ายเซลล์ประสาทในสมองมนุษย์

หลักการการทำงานของ MLP คือในแต่ละชั้นของชั้นซ่อนตัว (Hidden Layer) จะมีฟังก์ชันสำหรับคำนวณเมื่อได้รับสัญญาณ (Output) จากโหนดในชั้นก่อนหน้า เรียกว่า Activation Function โดยในแต่ละชั้น ไม่จำเป็นต้องเป็นฟังก์ชัน เดียวกันก็ได้ ชั้นซ่อนตัวนั้นมีหน้าที่สำคัญ คือ จะพยายาม แปลงข้อมูลที่เข้ามาในชั้น (Layer) นั้นๆ ให้สามารถแยกแยะความแตกต่างโดยใช้เส้นตรงเส้นเดียว (Linearly Separable) และก่อนที่ข้อมูลจะถูกส่งไปถึงชั้นข้อมูลออก (Output Layer) ในบางครั้งอาจ จำเป็นต้องใช้ชั้นซ่อนตัวมากกว่า 1 ชั้น ในการแปลงข้อมูลให้อยู่ในรูป Linearly Separable

ในการคำนวณหา Output ในปัญหาการจำแนกทำได้โดยการใส่ข้อมูล Input เข้าไปในโครงข่ายประสาทเทียมที่เราได้ทำการหาไว้แล้ว จากนั้นให้ทำการเปรียบเทียบค่าของ Output ใน Output Layer และให้ทำการเลือกค่าของ Output ที่มีค่าสูงกว่า (Neuron ที่มีค่าสูงกว่า) และทำการรับค่าของค่าพยากรณ์ที่ตรงกับ Neuron ที่เลือกและให้นำค่ามาเปรียบเทียบกับค่าที่ยอมรับได้ หากค่าของอยู่ในช่วงที่รับได้ (Error น้อยกว่า Error ที่เรากำหนด) ก็ให้ทำการรับข้อมูลชุดถัดไป แต่หากค่าของ มากกว่าค่าที่ยอมรับได้ให้ทำการปรับค่าน้ำหนักและ Biased ตามขั้นตอนที่ได้กล่าวไว้ข้างต้น เมื่อทำการปรับน้ำหนักเรียบร้อยแล้ว ให้ทำการรับข้อมูลชุดถัดไปและทำตามขั้นตอนซ้ำอีกรอบจนกระทั่งถึงข้อมูลชุดสุดท้าย และเมื่อทำข้อมูลชุดสุดท้ายเสร็จจะนับเป็น 1 รอบของการคำนวณ (1 Epoch) จากนั้นจะทำการหาค่าผิดพลาดรวมเฉลี่ย จากค่าเฉลี่ยของ ที่ได้เก็บค่าเอาไว้เพื่อใช้ในการตรวจสอบว่าค่าโดยเฉลี่ยในการจำแนกนั้นมีค่าน้อยกว่าค่าผิดพลาดที่ยอมรับได้หรือไม่ถ้าใช่แสดงว่าโครงข่ายประสาทเทียมที่สร้างขึ้นนั้น สามารถให้ผลลัพธ์ที่ถูกต้องของทุกๆ ข้อมูลแล้ว จึงทำการจบการเรียนรู้ได้แต่ถ้าไม่ใช่ให้กลับไปทำตามขั้นตอนแรกโดยเริ่มรับข้อมูลชุดที่ 1 ใหม่ดังภาพประกอบที่ 6



ภาพประกอบ 6 Multi-Layer Perceptron

4. ทฤษฎีเกี่ยวกับการประเมินวัดความแม่นยำของแต่ละอัลกอริทึม

ในงานวิจัยนี้จะใช้ค่า Root Mean Squared Error (RMSE) ค่า Mean Absolute Error (MAE) และ Mean Absolute Percent Error (MAPE) ในการวัดค่าความแม่นยำของอัลกอริทึม

3.1 รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Squared Error : RMSE) คือ การวัดความแตกต่างระหว่างค่าจริงและค่าพยากรณ์ ถ้าหากค่า RMSE นั้นมีค่าน้อย แสดงว่าค่าพยากรณ์นั้นประมาณค่าได้ใกล้เคียงกับค่าจริง ดังสมการที่ (13)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (13)$$

จากสมการ

Y_i เป็น ค่าจริงของ samples test ที่ i

\hat{Y}_i เป็น ค่าพยากรณ์ของ samples test ที่ i

n เป็น จำนวน samples ทั้งหมด

3.2 ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) คือ การหาค่าเฉลี่ยของความแตกต่างสัมบูรณ์ระหว่างค่าพยากรณ์และค่าจริง ถ้าหากค่า MAE นั้นมีค่าน้อย แสดงว่าค่าทำนายนั้นมีค่าใกล้เคียงกับค่าจริง ดังสมการที่ (14)

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (14)$$

จากสมการ

Y_i เป็น ค่าจริงของ samples test ที่ i

\hat{Y}_i เป็น ค่าพยากรณ์ของ samples test ที่ i

n เป็น จำนวน samples ทั้งหมด

3.3 ค่าเฉลี่ยความผิดพลาดร้อยละสัมบูรณ์ (Mean Absolute Percent Error : MAPE) คือ การหาเปอร์เซ็นต์ค่าเฉลี่ยของความแตกต่างสัมบูรณ์ระหว่างค่าพยากรณ์และค่าจริง ถ้าหากค่า MAPE นั้นมีค่าน้อย แสดงว่าค่าพยากรณ์นั้นประมาณค่าได้ใกล้เคียงกับค่าจริงดัง สมการที่ (15)

$$MAPE = \frac{\sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_t} \times 100}{N} \quad (15)$$

จากสมการ

Y_i คือ ค่าจริงของ samples test ที่ i

\hat{Y}_i คือ ค่าพยากรณ์ของ samples test ที่ i

n คือ จำนวน samples ทั้งหมด

ถ้าค่า MAPE น้อยกว่า 10% จัดว่าการพยากรณ์ค่อนข้างแม่นยำ ถ้าค่า MAPE อยู่ระหว่าง 10% ถึง 20% จัดว่าการพยากรณ์ใช้ได้ดี ถ้าค่า MAPE อยู่ระหว่าง 20% ถึง 50% จัดว่าการพยากรณ์พอใช้ ถ้าค่า MAPE มากกว่า 50% จัดว่าการพยากรณ์ไม่แม่นยำ และถ้าค่า MAPE น้อยกว่า 10% จัดว่า การพยากรณ์ค่อนข้างแม่นยำ (Falatouri, Darbanian et al. 2022)

5. งานวิจัยที่เกี่ยวข้อง

(1) บทความวิจัยเรื่อง Demand Forecasting Using Machine Learning to Manage Product Inventory for Multi-channel Retailing Store (Kheawpeam and Sinthupinyo 2023)

งานวิจัยนี้ได้ทำการพยากรณ์ความต้องการสินค้า เนื่องจากปัจจุบันร้านค้าขนาดเล็กและขนาดกลางส่วนใหญ่มีช่องทางการจัดจำหน่ายที่หลากหลายทั้งบนแพลตฟอร์มออนไลน์และออฟไลน์ ซึ่งสินค้าถูกรวบรวมไว้ในสินค้าคงคลังเดียวกัน โดยไม่มีการอัปเดตสต็อกสินค้าแบบ

เรียลไทม์ทุกช่องทางจำหน่าย ซึ่งทำให้เกิดปัญหาปริมาณสินค้าไม่เพียงพอกับความต้องการของลูกค้าหรือสินค้าบางรายการอาจเกินความต้องการของลูกค้า งานวิจัยนี้จึงมีแนวคิดในการพยากรณ์ความต้องการสินค้าอย่างมีประสิทธิภาพ คือ นำมาช่วยเหลือเจ้าของร้านในการแก้ปัญหาของร้านในเรื่องการจัดการสินค้าคงคลัง และยังสามารถช่วยลดต้นทุนได้ เช่น ค่าขนส่ง ค่าสินค้าคงคลัง ค่าแรง เป็นต้น

แบบจำลองที่ใช้ในการพยากรณ์ของงานวิจัยนี้ คือ XGBoost Model, CatBoost Model และ Linear Regression Model โดยข้อมูลที่ใช้ คือ ข้อมูลร้านค้าปลีกในประเทศไทยแห่งหนึ่งที่มีช่องทางจำหน่ายสินค้าทั้งออนไลน์และออฟไลน์ เป็นข้อมูลตั้งแต่วันที่ 1 มกราคม 2560 ถึง 31 ธันวาคม 2564 ซึ่งมียอดจำหน่ายรวม 408,724 รายการ

ผลลัพธ์ที่ได้จากการวัดความแม่นยำด้วยค่า SMAPE ของแต่ละแบบจำลองสรุปได้ว่าการพยากรณ์ความต้องการสินค้าใน 7 วันข้างหน้าแสดงให้เห็นว่าแบบจำลอง XGBoost ทำงานได้ดีกว่าแบบจำลอง CatBoost และ Linear Regression โดยค่า SMAPE ของแบบจำลองคือ 24.13% และผลการพยากรณ์ความต้องการสินค้าใน 30 วันแสดงให้เห็นว่าแบบจำลอง CatBoost ทำงานได้ดีกว่าแบบจำลอง XGBoost และ Linear Regression โดยค่า SMAPE ของแบบจำลองคือ 24.47%

(2) บทความวิจัยเรื่อง Time Series Forecasting using LSTM and ARIMA (Khulood Albeladi, Bassam Zafar and Mueen 2023)

งานวิจัยนี้ได้ทำการศึกษาเปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM และ ARIMA สำหรับการพยากรณ์ราคาในตลาดอสังหาริมทรัพย์ งานวิจัยนี้ใช้ข้อมูลจาก Mulkia Gulf Real Estate ที่ MarketWatch

จากการเปรียบเทียบการประเมินวัดประสิทธิภาพของแต่ละแบบจำลองด้วยค่า MAE, MAPE, MdAPE และ MSE พบว่าแบบจำลอง ARIMA มีประสิทธิภาพสูงกว่า เนื่องจากมีความแม่นยำในการพยากรณ์สำหรับมูลค่าราคาสูงสุดในอนาคตได้ดีกว่าแบบจำลอง LSTM

(3) บทความวิจัยเรื่อง Sales Forecasting: A Comparison of Traditional and Modern Times-Series Forecasting Models on Sales Data with Seasonality (Ali and Nakti 2023)

งานวิจัยนี้ได้ศึกษาการเปรียบเทียบแบบจำลอง โดยใช้แบบจำลองดั้งเดิม คือ ARIMA และ SARIMA เปรียบเทียบกับแบบจำลองสมัยใหม่ คือ Prophet และ LSTM สำหรับการพยากรณ์

ยอดขาย การวางแผนการผลิต และการคาดการณ์สินค้าคงคลัง ซึ่งเป็นองค์ประกอบสำคัญของธุรกิจ โดยข้อมูลที่ใช้ในการศึกษามาจากองค์กรการค้าและผลิตอาหาร ปี 2017 - 2020 โดยชุดข้อมูลประกอบด้วย วันที่และยอดขายรวม การศึกษาที่ใช้ข้อมูลในการ Train 80% และ Test 20% จากการเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า RMSE ของแต่ละแบบจำลอง ได้ค่า RMSE ดังนี้

ตาราง 1 ตารางเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า RMSE ของแต่ละแบบจำลอง

No.	Model	RMSE
1	ARIMA (2,1,4)	4378654
2	SRIMA (1,0,2,4)	3546770
3	Phophet	3789678
4	LSTM	5621916

สรุปผลได้ว่า แบบจำลอง SARIMA และ Prophet ทำงานได้ดีที่สุดในข้อมูลชุดนี้ ซึ่ง SARIMA สามารถทำงานได้ดีสำหรับยอดขายที่มีการเคลื่อนไหวอย่างรวดเร็ว และมีรูปแบบตามฤดูกาล

(4) บทความวิจัยเรื่อง Sales Forecasting of a Hypermarket: Case Study in Baghdad Using Machine Learning (Anwer and Akyüz 2022)

งานวิจัยนี้ได้ศึกษาเปรียบเทียบประสิทธิภาพของแบบจำลอง 5 แบบ ได้แก่ Adaptive Regression Splines (MARS), Long Short-Term Memory Network (LSTM), Seasonal Auto-Regressive Integrated Moving Average (SARIMA), ARIMA และ Recurrent Neural Network (RNN) สำหรับการพยากรณ์ยอดขายในไฮเปอร์มาร์เก็ตในกรุง Baghdad โดยข้อมูลที่ใช้ในการศึกษามาจาก Hypermarket FamilyMart Al-Mansour ในเมือง Baghdad ประเทศอิรัก เป็นข้อมูลตั้งแต่ปี 2016 - 2021

จากการเปรียบเทียบการประเมินวัดความแม่นยำของแต่ละแบบจำลอง ด้วยค่า RMSE สรุปผลได้ว่า แบบจำลอง SARIMA มีประสิทธิภาพมากที่สุด เนื่องจากข้อมูลชุดนี้มีแนวโน้มและฤดูกาลทำให้เหมาะสำหรับการพยากรณ์ยอดขายในไฮเปอร์มาร์เก็ต และแบบจำลอง ARIMA,

LSTM และ RNN ไม่เหมาะสมสำหรับข้อมูลชุดนี้เนื่องจากข้อมูลนี้มีลักษณะตามฤดูกาลและไม่คงที่

ตาราง 2 ตารางเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า RMSE ของแต่ละแบบจำลอง

Time Series Split Cross Validation	Avg. Measures Over 12 Folds	
	R ²	RMSE
ARIMA	-0.392	141380
SARIMA	0.73	657537
MARS	0.558	94391
LSTM	0.583	92737
RNN	0.554	97702

(5) บทความวิจัยเรื่อง Predictive Analytics for Demand Forecasting – A Comparison of SARIMA and LSTM in Retail SCM (Falatouri, Darbanian et al. 2022)

งานวิจัยนี้ได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMA และ LSTM สำหรับการพยากรณ์ความต้องการในการจัดการห่วงโซ่อุปทานการค้าปลีก (Supply Chain Management) โดยใช้ข้อมูลยอดขายปลีกจริงมากกว่า 37 เดือนจากผู้ค้าปลีกชาวออสเตรเลีย

จากการเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า mean absolute percentage error (MAPE) and root mean square deviation (RMSE) ของแต่ละแบบจำลอง สรุปผลได้ว่า ทั้งสองแบบจำลองให้ผลลัพธ์ที่สมเหตุสมผลถึงดี โดย LSTM ทำงานได้ดีสำหรับผลิตภัณฑ์ที่มีความต้องการคงที่ และ SARIMA ทำงานได้ดีสำหรับผลิตภัณฑ์ที่มีพฤติกรรมตามฤดูกาล และงานวิจัยนี้ได้แนะนำ SARIMAX ที่เอาปัจจัยภายนอกเข้ามาในแบบจำลอง โดยปัจจัยภายนอก คือ การส่งเสริมการขาย ผลลัพธ์พบว่าทำงานได้ดีขึ้นอย่างมากสำหรับผลิตภัณฑ์ที่มีโปรโมชั่น

(6) บทความวิจัยเรื่อง Time-series forecasting of seasonal items sales using machine learning – A comparative analysis (Ensafi, Amin et al. 2022)

งานวิจัยนี้ได้ทำการศึกษาเปรียบเทียบประสิทธิภาพของแบบจำลอง Seasonal Autoregressive Integrated Moving Average (SARIMA), Triple Exponential Smoothing,

Prophet, Long Short-Term Memory (LSTM) และ Convolutional Neural Network (CNN). สำหรับการพยากรณ์ยอดขายเฟอร์นิเจอร์ โดยชุดข้อมูลที่ใช้ คือ ชุดข้อมูลการขาย Superstore ตั้งแต่ปี 2014 - 2017 มีฟีเจอร์ 21 ฟีเจอร์ และประกอบด้วยข้อมูลการขาย 3 หมวดหมู่ ได้แก่ เฟอร์นิเจอร์ สินค้าเทคโนโลยี และเครื่องใช้สำนักงาน แต่ในงานวิจัยนี้มุ่งเน้นไปที่การขายเฟอร์นิเจอร์ เนื่องจากมีรูปแบบตามฤดูกาลที่ชัดเจน

จากการเปรียบเทียบการประเมินวัดประสิทธิภาพของแต่ละแบบจำลองด้วยค่า Root Mean Squared Error (RMSE) และ Mean Absolute Percentage Error (MAPE) สรุปผลได้ว่า Stacked LSTM Model มีประสิทธิภาพมากที่สุด

(7) บทความวิจัยเรื่อง Forecasting Pet Food Item Stock using ARIMA and LSTM (Ahnaf, Kurniawati and Anggana 2021)

งานวิจัยนี้ได้ทำการศึกษาการพยากรณ์ยอดขายอาหารสัตว์รักษาโรคที่ขายในร้านสัตวแพทย์ เพื่อช่วยในการคาดการณ์สต็อกอาหาร โดยใช้แบบจำลอง ARIMA และ LSTM โดยงานวิจัยนี้ใช้ข้อมูลการขายอาหารสัตว์รักษาโรคใน Vet to Pet ที่ตั้งอยู่ในเมืองบันดุงประเทศอินโดนีเซีย ข้อมูลการขายตั้งแต่เดือนมกราคม 2018 – กุมภาพันธ์ 2021

จากการเปรียบเทียบการประเมินวัดประสิทธิภาพของแต่ละแบบจำลองด้วยค่า Root Mean Square Error (RMSE) พบว่า แบบจำลอง ARIMA ได้ค่า RMSE 9.21 และ แบบจำลอง LSTM ได้ค่า RMSE 9.74 สรุปได้ว่า แบบจำลอง ARIMA มีประสิทธิภาพที่ดีกว่า แบบจำลอง LSTM เหมาะกับข้อมูลที่คงที่และมีรูปแบบเฉพาะ

(8) บทความวิจัยเรื่อง Demand Forecasting in Production Planning for Dairy Products Using Machine Learning and Statistical Method (Vithitsontorn and Chongstitvatana 2022)

งานวิจัยนี้ศึกษาการพยากรณ์ความต้องการในการวางแผนการผลิตผลิตภัณฑ์นม โดยใช้ข้อมูลการขายรายวันที่รวบรวมจากระบบ ERP ขององค์การส่งเสริมการค้าสินค้าเกษตรอินทรีย์ (อ.ส.ค.) ภายในเดือนตุลาคม พ.ศ. 2559 – เดือนกันยายน พ.ศ.2564 (5 ปี) บันทึกโดยโรงงาน 5 แห่ง มีผลิตภัณฑ์ขายมากกว่า 100 รายการ แต่เลือกผลิตภัณฑ์เพียง 25 รายการที่ต้องการการคาดการณ์ เนื่องจากครอบคลุม 90% ของรายได้ทั้งหมด และผลผลิตประจำเดือนที่ผลิตโดยโรงงานทั้งหมด เลือกสินค้า 8 รายการ จากทั้งหมด 40 รายการที่แตกต่างกัน โดยมีปริมาณ

ยอดขายที่มีความผันผวนสูงตั้งแต่ 10 หน่วยต่อเดือน จนถึงมากกว่า 800,000 หน่วยต่อเดือนและ ข้อมูลวันหยุดรวบรวมจากธนาคารแห่งประเทศไทย

งานวิจัยนี้เป็นการศึกษาเปรียบเทียบระหว่างแบบจำลอง ARIMA และ LSTM ทำการประเมินวัดความแม่นยำด้วยค่า RMSE, MAE และ MASE พบว่า ARIMA มีประสิทธิภาพดีกว่าในข้อมูลแนวโน้มขึ้น (uptrend) แต่แบบจำลอง LSTM มีประสิทธิภาพที่ดีกว่าในข้อมูลแนวโน้มลง (downtrend) หรือข้อมูลที่มีความซับซ้อน และการฝึกแบบจำลองด้วยการสังเกตรายเดือนให้ผลลัพธ์ที่ดีกว่า เมื่อเทียบกับการสังเกตรายสัปดาห์

(9) บทความวิจัยเรื่อง Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM (Dave, Leonardo et al. 2021)

งานวิจัยนี้ได้ทำการพยากรณ์การส่งออกของอินโดนีเซีย เนื่องจากการส่งออกเป็นปัจจัยสำคัญที่ช่วยให้เศรษฐกิจของประเทศอินโดนีเซียเติบโตขึ้น งานวิจัยนี้มีวัตถุประสงค์ ช่วยสนับสนุนการกำหนดนโยบายของรัฐบาล และเตรียมความพร้อมสำหรับการส่งออกสินค้าได้อย่างเพียงพอ

แบบจำลองที่ใช้ในการพยากรณ์ของงานวิจัยนี้คือ SARIMAX LSTM และ Hybrid ARIMA-LSTM โดยชุดข้อมูลที่ใช้ คือ ข้อมูลส่งออกรายเดือนของประเทศอินโดนีเซียตั้งแต่ปี 1998 – 2019 ซึ่งนำข้อมูลมาจากเว็บไซต์ Federal Reserve Economic

จากการเปรียบเทียบการประเมินวัดความแม่นยำด้วยค่า MAPE ของแต่ละแบบจำลอง สรุปผลได้ว่า แบบจำลองแบบผสมผสานกันระหว่าง ARIMA และ LSTM ให้ค่า MAPE เท่ากับ 7.38% ซึ่งให้ค่า MAPE ต่ำที่สุด แบบจำลอง ARIMA ให้ค่า MAPE เท่ากับ 9.38% และแบบจำลอง LSTM ให้ค่า MAPE เท่ากับ 8.56% ดังนั้นแบบจำลองแบบผสมผสานให้ความแม่นยำที่ดีกว่า

(10) บทความวิจัยเรื่อง Application of SARIMAX Model to Forecast Daily Sales in Food Retail Industry (Arunraj, Ahrens and Fernandes 2016)

งานวิจัยนี้ได้ทำการศึกษาการพยากรณ์ยอดขายรายวันของอาหารที่เสิร์ฟ โดยใช้แบบจำลอง Seasonal Autoregressive Integrated Moving Average with external variables (SARIMAX) โดยเพิ่มตัวแปรปัจจัยภายนอกที่มีอิทธิพลเข้าไป เปรียบเทียบกับแบบจำลอง Seasonal Autoregressive Integrated Moving Average (SARIMA) โดยงานวิจัยนี้ใช้ข้อมูลยอดขายก๋วยเตี๋ยวรายวัน (เป็นกิโลกรัม) จากร้านค้าปลีกที่ลดราคาในภูมิภาคบาวาเรียตอนล่าง ประเทศเยอรมนี โดยมีข้อมูลตั้งแต่เดือน ธันวาคม 2009 - สิงหาคม 2014

จากการเปรียบเทียบการประเมินวัดประสิทธิภาพของแต่ละแบบจำลองด้วยค่า Mean Absolute Percentage Error (MAPE) และ Root Mean Square Error (RMSE) พบว่า แบบจำลอง SARIMAX ให้ประสิทธิภาพดีกว่า เมื่อมีการนำเอาตัวแปรปัจจัยภายนอกอย่าง การลดราคา วันโปรโมชัน และวันหยุดเข้ามาในแบบจำลอง ทำให้ค่า MAPE และ RMSE ลดลงส่งผลให้แบบจำลอง SARIMAX มีประสิทธิภาพที่ดียิ่งขึ้น



ตาราง 3 แสดงตารางสรุปผลงานวิจัยที่ศึกษา

	ชื่องานวิจัย	ปี	แบบจำลอง				Remark	
			ARIMA	LSTM	Hybrid	อื่นๆ		
1.	Demand Forecasting Using Machine Learning to Manage Product Inventory for Multi-channel Retailing Store	2023				XGBoost CatBoost	- XGBoost พยากรณ์ความต้องการสินค้าใน 7 วันข้างหน้าได้ดี - CatBoost พยากรณ์ความต้องการสินค้าใน 30 วันข้างหน้าได้ดี	
2.	Time Series Forecasting using LSTM and ARIMA	2023	ARIMA	LSTM				
3.	Sales Forecasting: A Comparison of Traditional and Modern Times-Series Forecasting Models on Sales Data with Seasonality	2023	ARIMA	LSTM		Prophet		
			SRIMA					
4.	Sales Forecasting of a Hypermarket: Case Study in Baghdad Using Machine Learning	2023	ARIMA	LSTM		MARS	RNN	แบบจำลอง SARIMA มีประสิทธิภาพมากที่สุด เนื่องจากข้อจำกัดที่มีแนวโน้มและฤดูกาล
			SARIMA					
5.	Predictive Analytics for Demand Forecasting – A Comparison of SARIMA and LSTM in Retail SCM	2022	SARIMA	LSTM				- LSTM ทำงานได้ดีสำหรับผลิตภัณฑ์ที่มีความต้องการคงที่
			SRIMAX					- SARIMAX ทำงานได้ดีสำหรับผลิตภัณฑ์ที่มีพฤติกรรมตามฤดูกาล
6.	Time-series forecasting of seasonal items sales using machine learning – A comparative analysis	2022	SRIMA	LSTM		CNN		
7.	Forecasting Pet Food Item Stock using ARIMA and LSTM	2021	ARIMA	LSTM				
8.	Demand Forecasting in Production Planning for Dairy Products Using Machine Learning and Statistical Method	2022	ARIMA	LSTM				
9.	Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM	2020	SARIMAX	LSTM	ARIMA-LSTM			
10.	Application of SARIMAX Model to Forecast Daily Sales in Food Retail Industry	2016	SARIMA					
			SARIMAX					

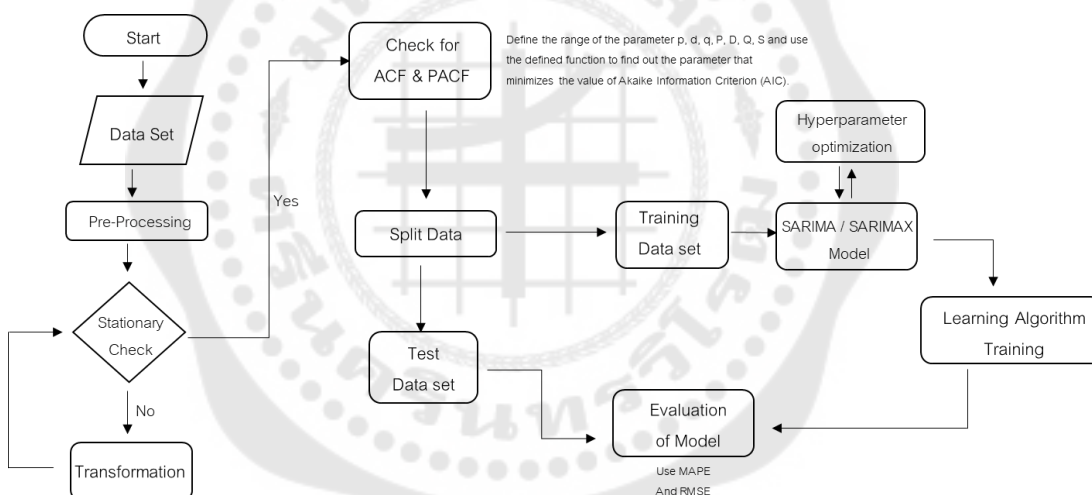
(ส่วนที่ถูกลายเส้นไว้นี้เป็นแบบจำลองที่ให้ค่าออกมาดีที่สุด)

บทที่ 3 วิธีดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

1. กระบวนการทำงานของแบบจำลอง
2. การเก็บรวบรวมข้อมูล (Data Collection)
3. การสำรวจข้อมูล (Exploratory Data Analysis : EDA)
4. การเตรียมข้อมูล
5. อัลกอริทึมของแบบจำลองการทำนาย

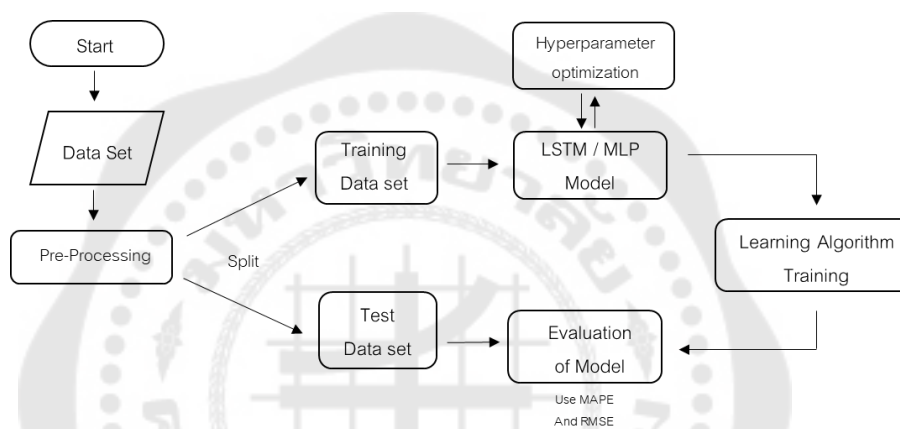
1. กระบวนการทำงานของแบบจำลอง



ภาพประกอบ 7 Flowchart กระบวนการทำงานของแบบจำลอง SARIMA และ SARIMAX

จากภาพประกอบที่ 7 Flowchart ได้อธิบายกระบวนการทำงานของแบบจำลอง SARIMA และ SARIMAX โดยเริ่มตั้งแต่การนำเข้าข้อมูล การเตรียมข้อมูล การสำรวจข้อมูล ทำความสะอาดข้อมูลและแปลงข้อมูลให้อยู่ในรูปแบบที่สามารถนำไปวิเคราะห์ต่อได้ จากนั้นเช็คความคงที่ของข้อมูล (Stationary) และเช็คค่า ACF, PACF เพื่อหาค่าพารามิเตอร์ p,d,q,P,D,Q,s โดยสามารถดู p,d,q,P,D,Q,s ได้จากค่า AIC ที่ต่ำที่สุด จากนั้นทำการแบ่งข้อมูล (Split Data) ออกเป็นข้อมูลฝึกสอน (Training Set) และข้อมูลทดสอบ (Test Set) โดยกำหนดให้แบ่งข้อมูลฝึกสอน(Training Set) เป็น 80 % และข้อมูลทดสอบ (Test Set) เป็น 20%

จากนั้นนำข้อมูลฝึกสอน (Training Set) ใส่เข้าแบบจำลองโดยใช้เทคนิค Seasonal Autoregressive Integrated Moving Averages (SARIMA) และ Seasonal Autoregressive Integrated Moving Averages with Exogenous Regressors (SARIMAX) ให้แบบจำลองทำการเรียนรู้ข้อมูล จากนั้นทำการเลือกพารามิเตอร์ให้เหมาะสมอีกครั้ง เพื่อให้แบบจำลองทำนายค่าออกมาได้ดีที่สุด และสุดท้ายนำข้อมูลที่ได้จากการทำนายมาเทียบกับข้อมูลทดสอบ (Test Set) เพื่อประเมินวัดประสิทธิภาพความแม่นยำของแบบจำลอง โดยใช้ค่า Root Mean Square Error (RMSE) Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE)



ภาพประกอบ 8 Flowchart กระบวนการทำงานของแบบจำลอง LSTM และ MLP

จากภาพประกอบที่ 8 Flowchart ได้อธิบายกระบวนการทำงานของแบบจำลอง LSTM และ MLP โดยเริ่มตั้งแต่การนำเข้าข้อมูล การเตรียมข้อมูล การสำรวจข้อมูล ทำความสะอาดข้อมูล และแปลงข้อมูลให้อยู่ในรูปแบบที่สามารถนำไปวิเคราะห์ต่อได้ จากนั้นทำการแบ่งข้อมูล (Split Data) ออกเป็นข้อมูลฝึกสอน (Training Set) และข้อมูลทดสอบ (Test Set) โดยกำหนดให้แบ่งข้อมูลฝึกสอน (Training Set) เป็น 80% และข้อมูลทดสอบ (Test Set) เป็น 20% และทำการ scale ข้อมูล

จากนั้นนำข้อมูลฝึกสอน (Training Set) ใส่เข้าแบบจำลองโดยใช้เทคนิค Long Short-Term Memory (LSTM) และ Multi-Layer Perceptron (MLP) ให้แบบจำลองทำการเรียนรู้ข้อมูล จากนั้นทำการเลือกพารามิเตอร์ให้เหมาะสมอีกครั้ง เพื่อให้แบบจำลองทำนายค่าออกมาได้ดีที่สุด และสุดท้ายนำข้อมูลที่ได้จากการทำนายมาเทียบกับข้อมูลทดสอบ (Test Set) เพื่อประเมินวัดประสิทธิภาพความแม่นยำของแบบจำลอง โดยใช้ค่า Root Mean Square Error (RMSE) Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE)

2. การเก็บรวบรวมข้อมูล (Data Collection)

ในงานวิจัยนี้ใช้ข้อมูลธุรกรรมยอดขายจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ โดยมีข้อมูลตั้งแต่เดือน มกราคม 2564 – มิถุนายน 2566 โดยมี 1 ตาราง เป็นรายการธุรกรรมการขาย มีคอลัมน์ทั้งหมด 24 คอลัมน์ และมีจำนวนข้อมูล 62,632 แถว ดังตารางที่ 4

ตาราง 4 แสดงตัวแปรของรายการธุรกรรมการขาย

Variable	Description
Order_id	เลขที่ออเดอร์
Status	สถานะคำสั่ง
customer_name	ชื่อลูกค้า
Date	วันที่ทำการชำระเงิน
channel	ช่องทางการชำระเงิน เช่น Online Payment
payment	ช่องทางการชำระเงิน เช่น iBanking Payment (SCB)
Shipping	ชื่อขนส่ง
Type_of_Delivery	ประเภทการจัดส่ง เช่น pick up = เจ้าหน้าที่เข้ามารับสินค้า , Drop off = นำสินค้าไปส่งที่ขนส่ง
Tracking_Number	เลขติดตามพัสดุ
Expected_delivery_date	วันที่คาดว่าจะจัดส่งสินค้า
Delivery_time	วันเวลาที่จัดส่งสินค้า
option	ชื่อสินค้าที่เริ่บบนโพสหน้าแอปพลิเคชัน shopee
category	หมวดหมู่สินค้า
sub_category	หมวดหมู่ย่อยของสินค้า
product	ชื่อสินค้าที่เป็นตัวเลือก
Initial_price	ราคาตั้งต้น
Sale_price	ราคาขาย
quantity	จำนวนสินค้าที่ขาย
Netprice	ราคาสุทธิที่ได้รับ
Discount_by_seller	ส่วนลดที่ออกโดยร้านค้า (เป็น code ที่ร้านค้าให้เก็บ)
Discount_by_Shopee	ส่วนลดที่ออกโดย shopee
CodeDiscount	รหัส code ส่วนลด
Transaction Fee	ค่าธรรมเนียม


3. การสำรวจข้อมูล (Exploratory Data Analysis : EDA)

งานวิจัยนี้ใช้ภาษาไพทอน (Python) ในการวิเคราะห์ข้อมูลและทำ Machine Learning จากการศึกษาข้อมูล ข้อมูลชุดนี้ไม่มีค่า missing value

Order_id	Status	customer_name	Date	channel	payment	Shipping	Type_of_Delivery	Tracking_Number	Expected_delivery_date	...	bundle_deal	promotion_day	SumPromotionDay
210511BWOC241P	สำเร็จแล้ว	toeyyyyyyyyyyy	2021-05-11	เก็บเงินปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	TH019606788965	2021-05-13 12:41:00	...	0	0
210511B6AXWF7Q	สำเร็จแล้ว	ily_c	2021-05-11	ชำระผ่าน ATM	Bank Transfer	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	TH016025641665	2021-05-13 05:40:00	...	0	0
210511CQFYFHST	สำเร็จแล้ว	poiipraewx	2021-05-11	Mobile Banking	iBanking Payment V2 (K Plus)	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	TH011646100865	2021-05-13 20:06:00	...	0	0
210511CWASA AFC	สำเร็จแล้ว	sattawathkhaosod	2021-05-11	ชำระผ่าน ATM	Bank Transfer	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Kerry	pickup	SHPS071359736	2021-05-13 22:11:00	...	0	0
210512EES2QMBR	สำเร็จแล้ว	jabsss	2021-05-12	ชำระผ่าน ATM	Bank Transfer	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	TH011544088665	2021-05-14 12:43:00	...	0	0
210805RE3HNA04	สำเร็จแล้ว	wanich0	2021-08-05	บัตรเครดิต/บัตรเดบิต	Airpay Credit Card	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	TH014561029798	2021-08-07 12:17:00	...	0	0
210811AVSET7NR	สำเร็จแล้ว	real_at	2021-08-11	ShopeePay	Airpay Wallet V2	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	TH011335709428	2021-08-14 16:48:00	...	0	0
211010EHBWSTE3	สำเร็จแล้ว	ping55000	2021-10-10	เก็บเงินปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Kerry	pickup	SHPS103071384	2021-10-15 00:58:00	...	0	1
2111081E4AJPBQ	สำเร็จแล้ว	vitaree	2021-11-08	บัตรเครดิต/บัตรเดบิต	Airpay Credit Card	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Shopee X...	pickup	SPXTH01561506615B	2021-11-10 12:46:00	...	0	0
220703F88MMK1W	สำเร็จแล้ว	karyapach_z	2022-07-03	ShopeePay	Airpay Wallet V2	Standard Delivery - ส่งตรงมาใน	ประเทศไทย-Kerry	pickup	SHPS155381703	2022-07-05 12:11:00	...	0	0

ภาพประกอบ 9 แสดงตัวอย่างข้อมูลธุรกรรมการขาย

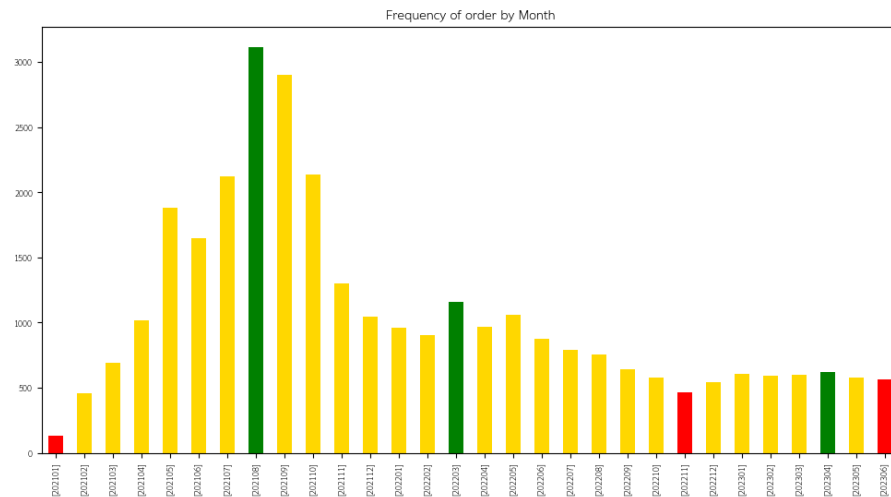
ทำการวิเคราะห์ยอดขาย จากภาพประกอบที่ 10 จะเห็นว่าในปี 2564 มียอดขายที่สูงมาก เนื่องจากปี 2564 มีสถานการณ์โควิด-19 จึงทำให้ผู้คนอยู่บ้านและหันมาซื้อของออนไลน์กันมากขึ้น จึงทำให้ยอดขายสูงโดดขึ้นมา ต่อมาในปี 2565 - 2566 ยอดขายค่อยๆ ลดลงมาเรื่อยๆ เนื่องจากสถานการณ์โควิดเริ่มคลี่คลาย ทำให้ผู้คนเริ่มออกไปใช้ชีวิตตามปกติ



ภาพประกอบ 10 แสดงยอดขายตั้งแต่ปี 2564 - 2566 โดยจำแนกตามรายเดือน

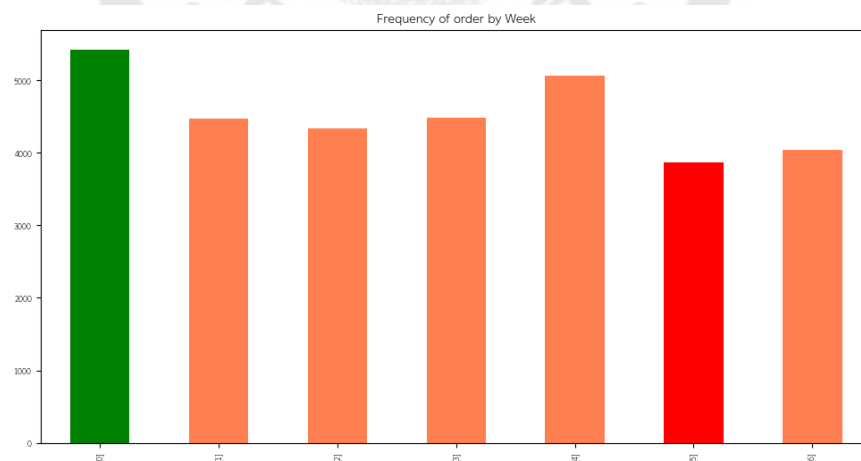
ทำการวิเคราะห์จำนวนออเดอร์ในแต่ละเดือนจำแนกตามปี จากภาพประกอบที่ 11 จะเห็นว่าในปี 2564 เดือนสิงหาคมเป็นเดือนที่ขายดีที่สุด และเดือนมกราคมเป็นเดือนที่ขายได้น้อยที่สุดเนื่องจากเดือนมกราคม 2564 เป็นเดือนที่เพิ่งเปิดร้านเป็นเดือนแรก ต่อมาในปี 2565 เดือน

มีนาคมเป็นเดือนที่ขายดีที่สุด และเดือนพฤศจิกายนเป็นเดือนที่ขายได้น้อยที่สุด และในปี 2566 เดือนเมษายนเป็นเดือนที่ขายดีที่สุด และเดือนมิถุนายนเป็นเดือนที่ขายได้น้อยที่สุด




ภาพประกอบ 11 แสดงจำนวนออเดอร์ในแต่ละเดือนและปี

ทำการวิเคราะห์จำนวนออเดอร์แยกเป็นรายวัน จากภาพประกอบที่ 12 จะเห็นว่าวันที่ขายดีที่สุดจะเป็นวันอาทิตย์ เนื่องจากเป็นวันหยุดสุดสัปดาห์ และวันที่ขายได้น้อยที่สุดจะเป็นวันศุกร์




ภาพประกอบ 12 แสดงจำนวนออเดอร์ในแต่ละวัน

ทำการวิเคราะห์จำนวนออเดอร์ตามช่วงเวลา จากภาพประกอบที่ 13 จะเห็นว่าช่วงเวลาที่ยอดนิยมที่สุดจะเป็นช่วงเวลา 00.00 น. เนื่องจากเป็นเวลาที่ทาง Shopee จะปล่อยโค้ดส่วนลดหรือ โค้ดส่งฟรีขั้นต่ำ 0 บาท จึงทำให้ช่วงเวลานี้สามารถขายของได้มากที่สุด




ภาพประกอบ 13 แสดงจำนวนออเดอร์ตามช่วงเวลา

ทำการวิเคราะห์ว่าหมวดหมู่ไหนที่ขายดีที่สุดในร้าน จากภาพประกอบที่ 14 จะเห็นว่าหมวดหมู่ของตกแต่งบ้านขายได้ 56.1% ซึ่งเป็นหมวดหมู่ที่ขายดีที่สุดในร้าน รองลงมาเป็นอะไหล่เครื่องใช้ไฟฟ้า 24.1% ของใช้ภายในบ้าน 14.2% ของเล่นของสะสม 3.1% และอื่นๆ 2.5% ตามลำดับ




ภาพประกอบ 14 แสดงยอดขายแยกตามหมวดหมู่

และจากประกอบที่ 15 จะเห็นว่าหมวดหมู่ของตกแต่งบ้าน ขายได้มากที่สุดในทุก ๆ ปี




ภาพประกอบ 15 แสดงยอดขายแยกตามหมวดหมู่และปี

ทำการวิเคราะห์ว่าหมวดหมู่ของตกแต่งบ้านสินค้าตัวไหนที่ขายดีที่สุด จากภาพประกอบที่ 16 จะเห็นว่าสินค้าแจกันเป็นสินค้าที่ขายดีที่สุดในทุก ๆ ปี



ภาพประกอบ 16 แสดงยอดขายสินค้าในหมวดหมู่ของตกแต่งบ้าน

ทำการวิเคราะห์สินค้าประเภทแฉก้น เนื่องจากแฉก้นขายดีที่สุดในหมวดหมู่ของตกแต่งบ้าน จากภาพประกอบที่ 17 จะเห็นว่าแฉก้นที่ขายดีที่สุดและยอดขายโดดเด่นออกมา คือ แฉก้นทรงสูง แฉก้นทรงเอียงกลาง และแฉก้นทรงสูงใหญ่ ตามลำดับ



ภาพประกอบ 17 แสดงยอดขายสินค้าในสินค้าประเภทแฉก้น

สรุปผลลัพธ์ที่ได้จากการ EDA

1. ในปี พ.ศ. 2564 มียอดขายที่สูงโดดเด่นขึ้นมาเนื่องจากสถานการณ์โควิด และในปีต่อมา ยอดขายค่อยๆ ลดลงเรื่อย ๆ เนื่องจากสถานการณ์โควิด เริ่มคลี่คลายทำให้ผู้คนเริ่มออกไปใช้ชีวิตตามปกติ
2. ช่วงเดือนสิงหาคม พ.ศ. 2564 เป็นช่วงที่มีคำสั่งซื้อมากที่สุด
3. ลูกค้าจะทำการซื้อสินค้ามากที่สุดในวันอาทิตย์ วันพฤหัสบดี วันพุธ วันจันทร์ วันอังคาร วันเสาร์ และวันศุกร์ ตามลำดับ
4. ช่วงเวลาที่มีคำสั่งซื้อมากที่สุด คือช่วงเวลา 00.00 น. เนื่องจากเป็นเวลาที่ทาง Shopee ปลดล็อคโค้ดส่วนลด หรือโค้ดส่งฟรี ทำให้ช่วงเวลานี้มีคำสั่งซื้อมากที่สุด
5. หมวดหมู่ของสินค้าที่มีคำสั่งซื้อมากที่สุด คือ ของตกแต่งบ้าน 56.1% อะไหล่เครื่องใช้ไฟฟ้า 24.1% ของใช้ภายในบ้าน 14.2% ของเล่นของสะสม 3.1% และอื่นๆ 2.5% ตามลำดับ

6. สินค้าในหมวดหมู่ของตกแต่งบ้านที่มีคำสั่งซื้อมากที่สุดคือ แจกัน ดอกไม้ และพาน เซรามิค ตามลำดับ

7. 3 รายการสินค้าขายดีในสินค้าประเภทแจกัน คือ แจกันทรงสูง แจกันทรงเอียงกลาง และแจกันทรงสูงใหญ่ ตามลำดับ

4. การเตรียมข้อมูล (Data Preparation)

การเตรียมข้อมูลสำหรับการฝึกฝนของแบบจำลอง พบว่าหมวดหมู่ที่ขายดีที่สุดคือหมวดหมู่ของตกแต่งบ้าน และสินค้าที่ขายดีที่สุดในหมวดหมู่นี้คือสินค้าประเภทแจกัน และจากการสำรวจข้อมูล พบว่าช่วงเวลาที่ขายดีที่สุด คือช่วงเวลา 00.00 น. ซึ่งเป็นช่วงเวลาที่ทาง Shopee ได้ทำการปล่อยโค้ดส่วนลด และโค้ดส่งฟรีออกมาในวันโปรโมชันต่างๆ ดังนั้นผู้วิจัยจึงจะทำการแปลงข้อมูลในคอลัมน์ CodeDiscount ให้เป็น 0 และ 1 และทำการเพิ่มฟีเจอร์วันโปรโมชันเข้ามาในชุดข้อมูล

กระบวนการแปลงข้อมูล

เนื่องด้วยข้อมูลในคอลัมน์ CodeDiscount เป็นข้อมูลรหัสส่วนลดที่ถูกค่าใช้ซึ่งอยู่ในรูปแบบที่ไม่พร้อมใช้งาน จึงจำเป็นต้องแปลงข้อมูลในคอลัมน์นี้ โดยหากในคอลัมน์นี้มีการใช้รหัสส่วนลด จะให้เท่ากับ 1 และหากไม่มีการใช้รหัสส่วนลดจะให้เท่ากับ 0 ดังภาพประกอบที่ 18

Order_id	Status	customer_name	Date	channel	payment	Shipping	Type_of_delivery	Tracking_number	Expected_delivery_date	CodeDiscount	
210511BW0C241P	สำเร็จแล้ว	loeyyyyyyyyyyy	2021-05-11 12:41:00	เงินในปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Shopee X...	pickup	TH019006788965	2021-05-13 12:41:00	0
210511B6AXWF7Q	สำเร็จแล้ว	lly_c	2021-05-11 05:40:00	ชำระเงิน ATM	Bank Transfer	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Shopee X...	pickup	TH016025641665	2021-05-13 05:40:00	0
210511COQVYFHT	สำเร็จแล้ว	polipraewx	2021-05-11 20:06:00	Mobile Banking	iBanking Payment V2 (K Plus)	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Shopee X...	pickup	TH011646100865	2021-05-13 20:06:00	0
210511CWA5A AFC	สำเร็จแล้ว	saitawathkhaosod	2021-05-11 22:11:00	ชำระเงิน ATM	Bank Transfer	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Kerry	pickup	SHP5071359736	2021-05-13 22:11:00	0
210512EES2QMBR	สำเร็จแล้ว	jabbsr	2021-05-12 12:43:00	ชำระเงิน ATM	Bank Transfer	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Shopee X...	pickup	TH011544088665	2021-05-14 12:43:00	0
220703F88MMX1W	สำเร็จแล้ว	kanyapach_z	2022-07-03 12:11:00	ShopeePay	Airpay Wallet V2	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Kerry	pickup	SHP5155381703	2022-07-05 12:11:00	1
220703F88MMX1W	สำเร็จแล้ว	kanyapach_z	2022-07-03 12:11:00	ShopeePay	Airpay Wallet V2	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Kerry	pickup	SHP5155381703	2022-07-05 12:11:00	1
220722524QMV6	สำเร็จแล้ว	benjamaswaew	2022-07-22 14:59:00	เงินในปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Kerry	pickup	SHP5160787905	2022-07-25 14:59:00	1
2208132EED016P	สำเร็จแล้ว	7to0jeml_b	2022-08-13 17:33:00	เงินในปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Kerry	pickup	SHP5166622534	2022-08-16 17:33:00	1
2208132EED016P	สำเร็จแล้ว	7to0jeml_b	2022-08-13 17:33:00	เงินในปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	ไม่ระบุชื่อ-Kerry	pickup	SHP5166622534	2022-08-16 17:33:00	1

ภาพประกอบ 18 แสดงคอลัมน์ CodeDiscount ที่ทำการแปลงข้อมูล

ทำการเพิ่มคอลัมน์ promotion_day เป็นข้อมูลวันโปรโมชัน ซึ่งวันโปรโมชันจะมีทั้งหมด 3 วันต่อเดือน ได้แก่ 1. วัน Double Day (เป็นวันที่และเดือนที่เหมือนกัน เช่น วันที่ 2 เดือน 2 , วันที่ 3 เดือน 3 เป็นต้น) 2. วัน Mid Month Sale (เป็นวันที่ 15 ของทุกเดือน) 3. วัน Shopee Pay (เป็นวันที่ 25 ของทุกเดือน) โดยหากวันไหนเป็นวันโปรโมชันจะให้เท่ากับ 1 และวันที่ไม่ใช่วันโปรโมชัน

จะให้เท่ากับ 0 และทำการเพิ่มคอลัมน์ SumPromotionDay เป็นการรวมโปรโมชั่นทั้งหมด โดยเอา CodeDiscount (รหัสส่วนลด) และ promotion_day (วันโปรโมชั่น) มารวมกัน ดังภาพประกอบที่

19

order_id	Status	customer_name	Date	channel	payment	Shipping	Type_of_Delivery	Tracking_Number	Expected_delivery_date	...	CodeDiscount	bundle_desc	promotion_day	SumPromotionDay
210511BWC241P	สำเร็จแล้ว	toeyyyyyyyyyyy	2021-05-11 12:41:00	เริ่มรับปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	pickup	TH019506789955	2021-05-13 12:41:00	...	0		0	0
210511B6AXWF7Q	สำเร็จแล้ว	ily_c	2021-05-11 05:40:00	ชำระเงิน ATM	Bank Transfer	Standard Delivery - ส่งตรงมา	pickup	TH016025641665	2021-05-13 05:40:00	...	0		0	0
210511CQFYFHST	สำเร็จแล้ว	poiipraevx	2021-05-11 20:06:00	Mobile Banking	Banking Payment V2 (K Plus)	Standard Delivery - ส่งตรงมา	pickup	TH011646100865	2021-05-13 20:06:00	...	0		0	0
210511CWASAAFQ	สำเร็จแล้ว	kattawalkhaasod	2021-05-11 22:11:00	ชำระเงิน ATM	Bank Transfer	Standard Delivery - ส่งตรงมา	pickup	SHP5071359736	2021-05-13 22:11:00	...	0		0	0
210512EES2QMBR	สำเร็จแล้ว	jabbs	2021-05-12 12:43:00	ชำระเงิน ATM	Bank Transfer	Standard Delivery - ส่งตรงมา	pickup	TH011544089665	2021-05-14 12:43:00	...	0		0	0
220703F88MX1V	สำเร็จแล้ว	kanyapach_2	2022-07-03 12:11:00	ShopeePay	Airpay Wallet V2	Standard Delivery - ส่งตรงมา	pickup	SHP5155381703	2022-07-05 12:11:00	...	1		0	1
220703F88MX1V	สำเร็จแล้ว	kanyapach_2	2022-07-03 12:11:00	ShopeePay	Airpay Wallet V2	Standard Delivery - ส่งตรงมา	pickup	SHP5155381703	2022-07-05 12:11:00	...	1		0	1
220722524QMV6C	สำเร็จแล้ว	benjamasaeew	2022-07-22 14:59:00	เริ่มรับปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	pickup	SHP5160707905	2022-07-25 14:59:00	...	1		0	1
220813ZED016P	สำเร็จแล้ว	700jeml_b	2022-08-13 17:33:00	เริ่มรับปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	pickup	SHP5166622534	2022-08-16 17:33:00	...	1		0	1
220813ZED016P	สำเร็จแล้ว	700jeml_b	2022-08-13 17:33:00	เริ่มรับปลายทาง	Cash on Delivery	Standard Delivery - ส่งตรงมา	pickup	SHP5166622534	2022-08-16 17:33:00	...	1		0	1

ภาพประกอบ 19 แสดงคอลัมน์ Promotion_Day และ SumPromotionDay ที่ทำการเพิ่มเข้ามา เนื่องจากผู้วิจัยต้องการพยากรณ์ยอดขายเป็นรายสัปดาห์ เพราะทางร้านสั่งผลิตสินค้าเป็นรายสัปดาห์ ดังนั้นผู้วิจัยจึงทำการเพิ่มคอลัมน์ End_of_week ดังภาพประกอบที่ 20

Order_id	Status	customer_name	Date	End_of_Week
210511BWC241P	สำเร็จแล้ว	toeyyyyyyyyyyy	2021-05-11	2021-05-16
210511B6AXWF7Q	สำเร็จแล้ว	ily_c	2021-05-11	2021-05-16
210511CQFYFHST	สำเร็จแล้ว	poiipraevx	2021-05-11	2021-05-16

ภาพประกอบ 20 แสดงคอลัมน์ End_of_week ที่ทำการเพิ่มเข้ามา

วิเคราะห์ความสัมพันธ์ระหว่างตัวแปร (Correlations)

แสดงการวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลยอดขายสินค้า (Netprice) กับ วัน โปรโมชั่น โดยข้อมูลของชุดนี้ ดังภาพประกอบที่ 21


End_of_Week	Netprice	SumPromotionDay
2021-01-03	6903	0
2021-01-10	11288	0
2021-01-17	5739	13
2021-01-24	4655	3
2021-01-31	13947	17
...
2023-06-04	16085	137
2023-06-11	19870	259
2023-06-18	15180	188
2023-06-25	18480	189
2023-07-02	17247	136

ภาพประกอบ 21 แสดงข้อมูล Netprice และ SumPromotionDay ตาม End_of_Week


จากภาพประกอบที่ 22 - 25 จะเห็นว่ายอดขายสินค้ากับวันโปรโมชันมีความสัมพันธ์กัน จะเห็นว่า CodeDiscount (รหัสโค้ดส่วนลด) มีความสัมพันธ์สูงถึง 0.84 ซึ่งมีความสัมพันธ์กันมากกว่า promotion_day เนื่องจากโดยส่วนใหญ่ ลูกค้ามักจะใช้โค้ดส่งฟรีกับสินค้าภายในร้าน เนื่องจากสินค้าภายในร้านจะมีค่าเฉลี่ยอยู่ที่ 55 บาท จึงทำให้ใช้โค้ดส่งฟรีคุ้มกว่า ซึ่งในวันโปรโมชัน ทาง Shopee มักจะออกโค้ดส่วนลดที่ลดสินค้าได้เยอะ ลูกค้ามักจะนำโค้ดไปใช้กับสินค้าที่ราคาสูงในวันโปรโมชัน

	Netprice	CodeDiscount	promotion_day	SumPromotionDay
Netprice	1.000000	0.844694	0.665509	0.785371
CodeDiscount	0.844694	1.000000	0.824138	0.949803
promotion_day	0.665509	0.824138	1.000000	0.959963
SumPromotionDay	0.785371	0.949803	0.959963	1.000000


ภาพประกอบ 22 แสดงความสัมพันธ์ระหว่างยอดขายกับวันโปรโมชัน



ภาพประกอบ 23 แสดงความสัมพันธ์ระหว่างยอดขาย (Netprice) กับ
วันโปรโมชั่น (promotion_day)



ภาพประกอบ 24 แสดงความสัมพันธ์ระหว่างยอดขาย (Netprice) กับ
รหัสส่วนลด (CodeDiscount)



ภาพประกอบ 25 แสดงความสัมพันธ์ระหว่างยอดขาย (Netprice) กับ
รวมโปรโมชั่น (SumPromotionDay)

5. อัลกอริทึมของแบบจำลองการทำนาย

ในงานวิจัยนี้ได้ใช้แบบจำลอง SARIMA SARIMAX LSTM และ MLP ในการพยากรณ์ยอดขาย โดยจะทำการพยากรณ์ยอดขายเป็นรายสัปดาห์ ซึ่งจะพยากรณ์ยอดขายของสินค้า 3 รายการที่มียอดขายสูงสุด ได้แก่ แจกันทรงสูง แจกันทรงเอียงกลาง และแจกันทรงสูงใหญ่ โดยทำการเปรียบเทียบสมรรถนะโดยใช้ค่า Root Mean Squared Error (RMSE) Mean Absolute Error (MAE) และ Mean Absolute Percent Error (MAPE) เป็นตัวชี้วัดความแม่นยำของแต่ละแบบจำลอง ซึ่งข้อมูลใน Dataset มีข้อมูลตั้งแต่เดือน มกราคม 2564 - มิถุนายน 2566 (128 สัปดาห์) โดยผู้วิจัยจะทำการแบ่งข้อมูลเป็น train 80% และ test 20%


ซึ่งจากการวิเคราะห์ความสัมพันธ์ระหว่างยอดขายกับวันโปรโมชั่น จะเห็นว่า 2 ปีเจอรันี้มีความสัมพันธ์กัน ดังนั้นในงานวิจัยนี้จะใช้ข้อมูล Feature SumPromotion เป็นข้อมูล input เพื่อช่วยเพิ่มประสิทธิภาพในการพยากรณ์ยอดขายในแบบจำลอง SARIMAX

แบบจำลอง SARIMA และ SARIMAX :


หลักการทำงานของ SARIMA และ SARIMAX คือ จะนำข้อมูลที่ต้องการพยากรณ์มาใช้ในการ train โดยแบบจำลอง SARIMA และ SARIMAX เหมาะกับข้อมูลที่มีฤดูกาล และข้อจำกัดของแบบจำลองนี้ข้อมูลจะต้องมีความคงที่ (Stationary)

การพยากรณ์ยอดขายสินค้าของแบบจำลอง SARIMA และ SARIMAX นั้นมีข้อมูลทั้งหมด 128 สัปดาห์ ซึ่งจะทำการแบ่งข้อมูลออกเป็น 2 ชุด คือ train 80% (สัปดาห์ที่ 1 – 102) และ test 20% (สัปดาห์ที่ 103 – 128) โดยที่ในแบบจำลอง SARIMA จะใช้ข้อมูล Feature Netprice (ยอดขาย) เป็นข้อมูล input และในแบบจำลอง SARIMAX จะใช้ข้อมูล Feature Netprice และ Feature SumPromotion เป็นข้อมูล input


นำข้อมูลยอดขายที่ทำการแบ่งเป็น train set ของสินค้าประเภทแจกันทรงสูง แจกันทรงเอียงกลาง และแจกันทรงสูงใหญ่ มาตรวจสอบดูค่า Trend Seasonal และ Residual จากภาพประกอบที่ 26 - 28 จะเห็นได้ว่าข้อมูลยอดขายนั้นมี Trend ขึ้นและลง และมีความเป็น Seasonal เนื่องจากกราฟมีลักษณะเป็น Pattern



ภาพประกอบ 26 แสดงค่า Trend Seasonal และ Residual ของ train data แจกันทรงสูง



ภาพประกอบ 27 แสดงค่า Trend Seasonal และ Residual ของ train data แจกันทรงเอียงกลาง



ภาพประกอบ 28 แสดงค่า Trend Seasonal และ Residual ของ train data แจกกันทรงสูงใหญ่

จากข้อมูลสินค้าประเภทแจกทั้ง 3 ประเภท ยังมียอดขายที่ไม่คงที่ (Non-Stationary) ดังนั้นจึงต้องทำการ Differencing เพื่อให้ข้อมูลเป็น stationary โดยในงานวิจัยนี้จะใช้สถิติทดสอบ Augmented Dickey-Fuller test (ADF-Test) เทียบกับค่าวิกฤต (ค่าวิกฤต = 0.05) หากค่า p-value < 0.05 แสดงว่าข้อมูลมีความคงที่ (Stationary)

จากนั้นใช้ Grid Search ในการ Tuning Parameter เพื่อหาค่า p,d,q ที่ดีที่สุด ซึ่งดูได้จากค่า Akaike Information Criterion (AIC) ที่ต่ำที่สุด โดยกำหนดให้ p,P = range (1,3) , d = 1 (เนื่องจากทำการ diff 1 ครั้งก็สามารถทำข้อมูลให้เป็น stationary) , q,Q = range (1,3) และ s = 12 (เนื่องจากดูจากกราฟ Seasonal แล้วชุดข้อมูลนี้มี Seasonal เป็นรายไตรมาส ดังนั้น 1 ไตรมาส คือ 12 week ซึ่งได้ค่าพารามิเตอร์ที่ดีที่สุด ดังตารางที่ 5 - 6

ตาราง 5 แสดงค่าพารามิเตอร์ที่ใช้ของสินค้าแต่ละประเภทในแบบจำลอง SARIMA และแบบจำลอง SARIMAX

สินค้า	(p,d,q) x (P,D,Q,s)
แจกกันทรงสูง	(1,1,1) x (1,1,1,12)
แจกกันทรงเอียงกลาง	(2,1,1) x (1,1,1,12)
แจกกันทรงสูงใหญ่	(1,1,1) x (1,1,1,12)


นำค่าพารามิเตอร์ที่ได้ไป fit กับแบบจำลอง SARIMA และ แบบจำลอง SARIMAX โดยแบบจำลอง SARIMAX ทำการเพิ่ม Exogenous variable (exog) ซึ่งเป็นตัวแปรวันโปรโมชันเข้าไปในแบบจำลองโดยกำหนดตัวแปรเป็น SumPromotionDay จากนั้นทำการพยากรณ์ยอดขายใน 19 สัปดาห์ถัดไป แล้วนำข้อมูลที่ได้จากการพยากรณ์มาเปรียบเทียบกับ test (ข้อมูลจริง) และนำค่าที่ได้มาหาค่า RMSE, MAE และ MAPE เพื่อวัดประสิทธิภาพของแบบจำลอง

แบบจำลอง LSTM :


ในการพยากรณ์ยอดขายสินค้าของแบบจำลอง LSTM จะทำการแบ่งข้อมูลออกเป็น 2 ชุด คือ train 80% (สัปดาห์ที่ 1 – 102) และ test 20% (สัปดาห์ที่ 103 – 128) แล้วจึงแบ่งชุดข้อมูลของ train และ test ออกเป็นข้อมูลที่จะใช้ในการ input และ output ของแบบจำลอง โดยแปลงค่าของชุดข้อมูลให้อยู่ในรูปแบบของอาร์เรย์ 3 มิติ ซึ่งถูกแบ่งออกเป็น [sample, timesteps, feature] เพื่อใช้ในแบบจำลอง LSTM แล้วทำการ tuning parameter เพื่อหาค่าพารามิเตอร์ที่ดีที่สุด

ทำการกำหนด Timestep = 7 เข้ามาช่วยในการขยับข้อมูลย้อนหลังหรือขยับข้อมูลไปข้างหน้า ซึ่งในงานวิจัยนี้จะใช้ข้อมูลสัปดาห์ที่ 103 – 109 ในการพยากรณ์สัปดาห์ที่ 110 และใช้ข้อมูลสัปดาห์ที่ 104 - 110 ในการพยากรณ์สัปดาห์ที่ 111 โดยที่จะ shift ข้อมูลไปที่ละ 1 ซึ่งแบบจำลอง LSTM จะใช้ข้อมูลแบบ sequence ซึ่งต้องการการจัดเรียงให้เป็นลำดับของข้อมูลตามเวลา เพื่อให้โมเดลเรียนรู้และเข้าใจลำดับของข้อมูลได้ ซึ่งข้อมูล input ที่ใช้ในแบบจำลองนี้ จะใช้ข้อมูล Feature Netprice (ยอดขาย) ของวันก่อนหน้าเพื่อใช้ในการพยากรณ์ ส่วนข้อมูล output คือข้อมูลที่ต้องการพยากรณ์นั้นได้กำหนดค่าเป็น 19 เพราะต้องการจะพยากรณ์ยอดขายทั้งหมด 19 สัปดาห์ ซึ่งจะใช้ข้อมูล test ในการพยากรณ์ เนื่องจากในข้อมูล test มีทั้งหมด 26 สัปดาห์ จึงสามารถทำการพยากรณ์ได้ 19 สัปดาห์ เนื่องจากกำหนด Timestep = 7 และทำการ shift ข้อมูลไปที่ละ 1

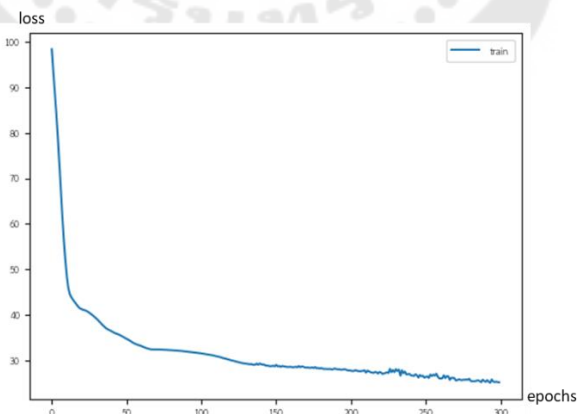
ได้ค่าพารามิเตอร์ที่ดีที่สุด คือ epochs = 300 จากภาพประกอบที่ 29 - 31 จะเห็นว่าในการ train แต่ละ epochs ค่า loss จะลดลงเรื่อย ๆ เมื่อถึง ณ จุด ๆ หนึ่งค่า loss จะเริ่มคงที่มี hidden neuron (n_node) = 16 โดยกำหนดค่า activation function = relu และ optimize = adam เพื่อเพิ่มประสิทธิภาพในการช่วยทำนายผลของแบบจำลอง แล้วจึงทำการ fit ข้อมูลกับแบบจำลองเพื่อให้แบบจำลองนั้นทำการพยากรณ์ยอดขายไปอีก 19 สัปดาห์ข้างหน้า



ภาพประกอบ 29 แสดงค่า Loss ในแต่ละ epochs ของแจกันทรงสูง



ภาพประกอบ 30 แสดงค่า Loss ในแต่ละ epochs ของแจกันทรงเอียงกลาง




ภาพประกอบ 31 แสดงค่า Loss ในแต่ละ epochs ของแจกันทรงสูงใหญ่

แบบจำลอง MLP :


ในการพยากรณ์ยอดขายสินค้า ของแบบจำลอง MLP จะทำการแบ่งข้อมูลออกเป็น 2 ชุด คือ train 80% (สัปดาห์ที่ 1 – 102) และ test 20% (สัปดาห์ที่ 103 – 128) แล้วจึงแบ่งชุดข้อมูลของ train และ test ออกเป็นข้อมูลที่จะใช้ในการ input และ output ของแบบจำลอง โดยแปลงค่าของชุดข้อมูลให้อยู่ในรูปแบบของอาร์เรย์ 3 มิติ ซึ่งถูกแบ่งออกเป็น [sample, timesteps, feature] เพื่อใช้ในแบบจำลอง MLP แล้วทำการ tuning parameter เพื่อหาค่าพารามิเตอร์ที่ดีที่สุด

และทำการกำหนด Timestep = 7 คือจำนวนข้อมูลย้อนหลังที่จะนำมาใช้ในการทำนายข้อมูลปัจจุบันในแต่ละชุดข้อมูล โดยแบบจำลอง MLP จะไม่สนใจ sequence ซึ่งข้อมูล input ที่ใช้ในแบบจำลองนี้ จะใช้ข้อมูล Feature Netprice (ยอดขาย) ของวันก่อนหน้าเพื่อใช้ในการพยากรณ์ ส่วนข้อมูล output คือข้อมูลที่ต้องการพยากรณ์นั้นได้กำหนดค่าเป็น 19 เพราะต้องการจะพยากรณ์ยอดขายทั้งหมด 19 สัปดาห์ ซึ่งจะใช้ข้อมูล test ในการพยากรณ์ เนื่องจากในข้อมูล test มีทั้งหมด 26 สัปดาห์ จึงสามารถทำการพยากรณ์ได้ 19 สัปดาห์ เนื่องจากกำหนด Timestep = 7 และทำการ shift ข้อมูลไปที่ละ 1


ซึ่งได้ค่าพารามิเตอร์ที่ดีที่สุด คือ epochs = 300 จากภาพประกอบที่ 32 - 34 จะเห็นว่าในการ train แต่ละ epochs ค่า loss จะลดลงเรื่อย ๆ เมื่อถึง ณ จุด ๆ หนึ่งค่า loss จะเริ่มคงที่มี 2 Layer ได้แก่ hidden Layer (n_{node}) = 16 และ Output Layer = 1 โดยกำหนดค่า activation function = relu และ optimize = adam เพื่อเพิ่มประสิทธิภาพในการช่วยทำนายผลของแบบจำลอง แล้วจึงทำการ fit ข้อมูลกับแบบจำลองเพื่อให้แบบจำลองนั้นทำการพยากรณ์ยอดขายไปอีก 19 สัปดาห์ข้างหน้า



ภาพประกอบ 32 แสดงค่า Loss ในแต่ละ epochs ของแจกันทรงสูง



ภาพประกอบ 33 แสดงค่า Loss ในแต่ละ epochs ของแจกันทรงเอียงกลาง



ภาพประกอบ 34 แสดงค่า Loss ในแต่ละ epochs ของแจกันทรงสูงใหญ่

บทที่ 4

ผลการดำเนินการวิจัย

ในการวิจัยการพยากรณ์ยอดขายในอีก 19 สัปดาห์ข้างหน้า ซึ่งใช้ข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ ซึ่งมีข้อมูลยอดขายรายวันตั้งแต่เดือน มกราคม 2564 ถึง มิถุนายน 2566 โดยใช้เทคนิคการเรียนรู้ของเครื่อง ผู้วิจัยได้ดำเนินการวิจัยโดยการศึกษาตามขอบข่ายและขั้นตอนต่าง ๆ ตลอดจนการวัดประสิทธิภาพ เพื่อให้บรรลุจุดประสงค์ของการวิจัยที่กำหนดไว้ ดังนี้

1. ผลลัพธ์ของการสร้างแบบจำลอง SARIMA
2. ผลลัพธ์ของการสร้างแบบจำลอง SARIMAX
3. ผลลัพธ์ของการสร้างแบบจำลอง LSTM
4. ผลลัพธ์ของการสร้างแบบจำลอง MLP
5. ผลลัพธ์จากการเปรียบเทียบการพยากรณ์ยอดขายระหว่างแบบจำลอง SARIMA LSTM และ MLP

1. ผลลัพธ์ของการสร้างแบบจำลอง SARIMA

จากการสร้างแบบจำลอง SARIMA โดยใช้ข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่งที่ขายบนแพลตฟอร์มออนไลน์ โดยใช้ RMSE MAE และ MAPE เป็นตัววัดประสิทธิภาพของแบบจำลอง SARIMA จากผลการทดลอง สรุปได้ดังนี้

แก๊นทรงสูงได้ค่า RMSE = 1222.19 , MAE 968.65 และ MAPE = 44.96 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 1222.19 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 968.85 บาท และ ค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 44.96% ของค่าจริง

แก๊นทรงเอียงกลางได้ค่า RMSE = 879.41, MAE 701.46 และ MAPE = 29.26 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 879.41บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 701.46 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 29.26% ของค่าจริง

แก๊นทรงสูงใหญ่ RMSE = 368.45, MAE 276.26 และ MAPE = 27.03 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 368.45 บาท ค่าพยากรณ์มี


ความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 276.26 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 27.03% ของค่าจริง

สรุปได้ว่าได้ว่าแบบจำลอง SARIMA ได้ค่า RMSE MAPE และ MAE ของแจกันทรงสูงใหญ่มีค่าต่ำที่สุด ดังนั้นในแบบจำลอง SARIMA แจกันทรงสูงใหญ่มีประสิทธิภาพที่ดีที่สุด ดังตารางที่ 6


ตาราง 6 แสดงผลการวัดประสิทธิภาพในแต่ละสินค้า ของแบบจำลอง SARIMA

Product	RMSE	MAE	MAPE
แจกันทรงสูง	1222.19	968.65	44.96
แจกันทรงเอียงกลาง	879.41	701.46	29.26
แจกันทรงสูงใหญ่	368.45	276.26	27.03


ทำการพล็อตกราฟ โดยนำค่าพยากรณ์ที่ได้จากแบบจำลอง SARIMA และค่าจริงที่ได้จากข้อมูลจริง ได้ดังภาพประกอบที่ 35 - 37



ภาพประกอบ 35 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูง



ภาพประกอบ 36 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงเอียงกลาง



ภาพประกอบ 37 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูงใหญ่

2. ผลลัพธ์ของการสร้างแบบจำลอง SARIMAX

จากการสร้างแบบจำลอง SARIMAX โดยใช้ข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ และใช้ปัจจัยภายนอก ตัวแปร exogenous variable คือ วันโปรโมชัน มาช่วยเพิ่มประสิทธิภาพในการพยากรณ์ยอดขายสินค้า โดยใช้ RMSE MAPE และ MAE เป็นตัววัดประสิทธิภาพของแบบจำลอง SARIMAX จากผลการทดลอง สรุปได้ดังนี้

แจกันทรงสูงได้ค่า RMSE = 810.37, MAE = 690.57 และ MAPE 31.45 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 810.37 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 690.57 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 31.45% ของค่าจริง

แจกันทรงเอียงกลางได้ค่า RMSE = 847.23, MAE = 673.86 และ MAPE 27.48 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 847.23 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 673.86 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 27.48% ของค่าจริง และ


แจกันทรงสูงใหญ่ RMSE = 349.95, MAE = 281.21 และ MAPE 26.14 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 349.95 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 281.21 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 26.14% ของค่าจริง

สรุปได้ว่าได้ว่าแบบจำลอง SARIMAX ได้ค่า RMSE MAPE และ MAE ของแจกันทรงสูงใหญ่มีค่าต่ำที่สุด ดังนั้นในแบบจำลอง SARIMAX แจกันทรงสูงใหญ่มีประสิทธิภาพที่ดีที่สุด ดังตารางที่ 7


ตาราง 7 แสดงผลการวัดประสิทธิภาพของแต่ละสินค้า ของแบบจำลอง SARIMAX

Product	RMSE	MAE	MAPE
แจกันทรงสูง	810.37	690.57	31.45
แจกันทรงเอียงกลาง	847.23	673.86	27.48
แจกันทรงสูงใหญ่	349.95	281.21	26.14


ทำการพล็อตกราฟ โดยนำค่าพยากรณ์ที่ได้จากแบบจำลอง SARIMAX และค่าจริงที่ได้จากข้อมูลจริง ได้ดังภาพประกอบที่ 38 - 40



ภาพประกอบ 38 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูง



ภาพประกอบ 39 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงเอียงกลาง



ภาพประกอบ 40 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูงใหญ่

2. ผลลัพธ์ของการสร้างแบบจำลอง LSTM

จากการสร้างแบบจำลอง LSTM โดยใช้ข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ โดยมีการกำหนดข้อมูลที่ใช้ย้อนหลังเป็น 7 สัปดาห์โดยที่แบบจำลอง LSTM จะใช้ข้อมูลแบบ sequence ซึ่งต้องการการจัดเรียงให้เป็นลำดับของข้อมูลตามเวลา และข้อมูลยอดขายที่ต้องการจะพยากรณ์ไปอีก 19 สัปดาห์ข้างหน้า ซึ่งใช้ RMSE MAE และ MAPE เป็นตัววัดประสิทธิภาพของแบบจำลอง LSTM จากผลการทดลอง สรุปได้ดังนี้

แจกันทรงสูงได้ค่า RMSE = 592.50, MAE = 452.65 และ MAPE = 19.84 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 592.50 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 452.65 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 19.84% ของค่าจริง

แจกันทรงเอียงกลางได้ค่า RMSE = 563.48, MAE = 461.39 และ MAPE = 25.16 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 563.48 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 461.39 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 25.16% ของค่าจริง

แจกันทรงสูงใหญ่ RMSE = 303.47, MAE = 269.95 และ MAPE = 28.00 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 303.47 บาท ค่าพยากรณ์มี


ความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 269.95 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 28.00% ของค่าจริง

สรุปได้ว่าแบบจำลอง LSTM สินค้าแบบแจกันทรงสูง มีประสิทธิภาพที่ดีที่สุดในการพยากรณ์ โดยค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 19.84% ของค่าจริง ซึ่งมีค่าต่ำที่สุด ดังตารางที่ 8


ตาราง 8 แสดงผลการวัดประสิทธิภาพของแต่ละสินค้า ของแบบจำลอง LSTM

Product	RMSE	MAE	MAPE
แจกันทรงสูง	592.50	452.65	19.84
แจกันทรงเอียงกลาง	563.48	461.39	25.16
แจกันทรงสูงใหญ่	303.47	269.95	28.00


ทำการพล็อตกราฟ โดยนำค่าพยากรณ์ที่ได้จากแบบจำลอง LSTM และค่าจริงที่ได้จากข้อมูลจริง ดังภาพประกอบที่ 41 - 43



ภาพประกอบ 41 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูง



ภาพประกอบ 42 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงเอียงกลาง



ภาพประกอบ 43 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูงใหญ่

3. ผลลัพธ์ของการสร้างแบบจำลอง MLP

จากการสร้างแบบจำลอง MLP โดยใช้ข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ โดยมีการกำหนดข้อมูลที่ให้ย้อนหลังเป็น 7 สัปดาห์และข้อมูลยอดขายที่ต้องการจะพยากรณ์ไปอีก 19 สัปดาห์ข้างหน้า ซึ่งใช้ RMSE MAE และ MAPE เป็นตัววัดประสิทธิภาพของแบบจำลอง MLP จากผลการทดลอง สรุปได้ดังนี้

แจกันทรงสูงได้ค่า RMSE = 629.83, MAE = 566.07 และ MAPE = 26.91 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 629.83 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 566.07 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 26.91% ของค่าจริง

แจกันทรงเอียงกลางได้ค่า RMSE = 587.66, MAE = 503.07 และ MAPE = 25.46 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 587.66 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 503.07 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 25.46% ของค่าจริง


แจกันทรงสูงใหญ่ได้ค่า RMSE = 283.79, MAE = 218.88 และ MAPE = 22.64 หมายถึง รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 283.79 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 218.88 บาท และค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 22.64% ของค่าจริง

สรุปได้ว่าแบบจำลอง LSTM สินค้าแบบแจกันสูงใหญ่ มีประสิทธิภาพที่ดีที่สุดในการพยากรณ์ โดยค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 22.64% ของค่าจริง ซึ่งมีค่าต่ำที่สุด ดังตารางที่ 9


ตาราง 9 แสดงผลการวัดประสิทธิภาพของแต่ละสินค้า ของแบบจำลอง MLP

Product	RMSE	MAE	MAPE
แจกันทรงสูง	629.83	566.07	26.91
แจกันทรงเอียงกลาง	587.66	503.07	25.46
แจกันทรงสูงใหญ่	283.79	218.88	22.64


ทำการพล็อตกราฟ โดยนำค่าพยากรณ์ที่ได้จากแบบจำลอง MLP และค่าจริงที่ได้จากข้อมูลจริง ดังภาพประกอบที่ 44 - 46



ภาพประกอบ 44 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูง




ภาพประกอบ 45 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงเอียงกลาง




ภาพประกอบ 46 กราฟแสดงค่าพยากรณ์เทียบกับยอดขายจริงของแจกันทรงสูงใหญ่

4. ผลลัพธ์จากการเปรียบเทียบการพยากรณ์ยอดขายระหว่างแบบจำลอง SARIMA LSTM และ MLP


ผลลัพธ์ที่ได้จากการทดลองด้วยแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าทั้ง 3 แบบ นำค่าพยากรณ์ที่ได้มาเปรียบเทียบกับยอดขายจริง ด้วยการพล็อตกราฟ ดังภาพประกอบที่ 47 - 49



ภาพประกอบ 47 แสดงการเปรียบเทียบการพยากรณ์ในแต่ละแบบจำลองของแจกันทรงสูง




ภาพประกอบ 48 แสดงการเปรียบเทียบการพยากรณ์ในแต่ละแบบจำลองของทรงเอียงกลาง




ภาพประกอบ 49 แสดงการเปรียบเทียบการพยากรณ์ในแต่ละแบบจำลองของแจกันทรงสูงใหญ่


เพื่อให้เห็นประสิทธิภาพของการพยากรณ์ของแต่ละแบบจำลอง SARIMA SARIMAX LSTM และ MLP ชัดเจนมากยิ่งขึ้น จึงทำการเปรียบเทียบค่า RMSE MAE และ MAPE ของแต่ละแบบจำลองด้วยกราฟ ดังภาพประกอบที่ 50 - 52



ภาพประกอบ 50 กราฟแสดงค่า RMSE MAE และ MAPE เปรียบเทียบระหว่างแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าแจกันทรงสูง



ภาพประกอบ 51 กราฟแสดงค่า RMSE MAE และ MAPE เปรียบเทียบระหว่างแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าแจกันทรงเอียงกลาง



ภาพประกอบ 52 กราฟแสดงค่า RMSE MAE และ MAPE เปรียบเทียบระหว่างแบบจำลอง SARIMA SARIMAX LSTM และ MLP ของสินค้าแจกันทรงสูงใหญ่

จากกราฟจะเห็นได้ว่าแบบจำลอง LSTM มีค่า RMSE MAPE และ MAE น้อยกว่า SARIMA SARIMAX และ MLP ในแจกันทรงสูงและแจกันทรงเอียงกลาง แสดงว่าค่าที่พยากรณ์ได้ในแบบจำลอง LSTM ใกล้เคียงกับค่าจริงมากที่สุด ดังนั้นจึงสรุปได้ว่า แบบจำลอง LSTM มีประสิทธิภาพในการพยากรณ์ยอดขายของแจกันทรงสูงและแจกันทรงเอียงกลางได้แม่นยำกว่าแบบจำลอง SARIMA SARIMAX และ MLP

และจากกราฟจะเห็นได้ว่าแบบจำลอง MLP มีค่า RMSE MAPE และ MAE น้อยกว่า SARIMA SARIMAX และ LSTM ในแจกันทรงสูงใหญ่ แสดงว่าค่าที่พยากรณ์ได้ในแบบจำลอง MLP ใกล้เคียงกับค่าจริงมากที่สุด ดังนั้นจึงสรุปได้ว่า แบบจำลอง MLP มีประสิทธิภาพในการพยากรณ์ยอดขายของแจกันทรงสูงใหญ่ได้แม่นยำกว่าแบบจำลอง SARIMA SARIMAX และ LSTM

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

ในการวิจัยการพยากรณ์ยอดขาย ในอีก 19 สัปดาห์ข้างหน้า ซึ่งใช้ข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ ซึ่งมีข้อมูลยอดขายรายวันตั้งแต่เดือน มกราคม 2564 ถึง มิถุนายน 2566 โดยใช้เทคนิคการเรียนรู้ของเครื่อง ผู้วิจัยได้วัดประสิทธิภาพของแบบจำลองแต่ละอัลกอริทึมเพื่อนำมาเปรียบเทียบและสรุปผล โดยสามารถแบ่งหัวข้อในการสรุปผลได้ดังต่อไปนี้

1. สรุปผลการวิจัย
2. อภิปรายผลการวิจัย
3. ข้อเสนอแนะ

1. สรุปผลการวิจัย

ในปัจจุบันเศรษฐกิจกำลังก้าวเข้าสู่ยุคดิจิทัล อีกทั้งอินเทอร์เน็ตได้เข้ามามีบทบาทอย่างยิ่งในชีวิตประจำวัน จึงส่งผลให้ธุรกิจออนไลน์กลายเป็นสิ่งที่ได้รับความนิยมมากขึ้น การใช้ชีวิตประจำวันมีการเปลี่ยนแปลงไป จากการซื้อขายผ่านทางหน้าร้าน กลักลับกลายเป็นการซื้อขายช่องทางออนไลน์ จึงทำให้ช่องทางออนไลน์มีร้านใหม่เกิดขึ้นอย่างแพร่หลาย แต่กลับพบว่าไม่ใช่ทุกธุรกิจที่จะประสบความสำเร็จ ดังนั้นจากสถานการณ์ที่ไม่แน่นอนที่อาจเกิดขึ้นได้ในอนาคต การเตรียมความพร้อมต่างๆ เป็นสิ่งที่สำคัญ หากมีการสั่งผลิตสินค้าที่มากเกินไปเกินความต้องการของผู้บริโภค อาจทำให้สินค้าค้างสต็อกและเงินจมทุนได้ หรืออีกกรณีที่มีการสั่งผลิตสินค้าไม่พอบต่อความต้องการของผู้บริโภค อาจทำให้ผู้ประกอบการเสียโอกาสในการขายสินค้าได้ ซึ่งถ้าปัญหาดังกล่าวนั้นสามารถที่จะพยากรณ์ยอดขายในอนาคตได้ จะทำให้ผู้ประกอบการสามารถคาดการณ์ยอดขายหรือมูลค่าของสินค้าที่ต้องผลิตได้ และยังทำให้เจ้าของธุรกิจสามารถบริหารงบประมาณที่มีอยู่ให้เกิดประโยชน์สูงสุดกับธุรกิจอีกด้วย

ในการวิจัยนี้ ได้ทำการศึกษาและวิเคราะห์เปรียบเทียบสมรรถนะระหว่างแบบจำลอง SARIMA SARIMAX MLP และ LSTM โดยผู้วิจัยได้เลือกศึกษาข้อมูลการขายสินค้าจากร้านค้าแห่งหนึ่ง ที่ขายบนแพลตฟอร์มออนไลน์ ซึ่งมีข้อมูลยอดขายรายวันตั้งแต่เดือน มกราคม 2564 ถึง มิถุนายน 2566 โดยใช้เทคนิคการเรียนรู้ของเครื่อง เพื่อเป็นแนวทางในการพัฒนาการสร้างแบบจำลองในการพยากรณ์ยอดขายสินค้าในอีก 19 สัปดาห์ข้างหน้า โดยวัดประสิทธิภาพของแบบจำลองได้ดังตารางที่ 10

ตาราง 10 แสดงค่า RMSE MAE และ MAPE ของแต่ละแบบจำลอง

Product	Method	RMSE	MAE	MAPE
แจกันทรงสูง	SARIMA	1222.19	968.65	44.96
	SARIMAX	810.37	690.57	31.45
	LSTM	592.50	452.65	19.84
	MLP	629.83	566.07	26.91
แจกันทรงเอียงกลาง	SARIMA	879.41	701.46	29.26
	SARIMAX	847.23	673.86	27.48
	LSTM	563.48	461.39	25.16
	MLP	587.66	503.07	25.46
แจกันทรงสูงใหญ่	SARIMA	368.45	276.26	27.03
	SARIMAX	349.95	281.21	26.14
	LSTM	303.47	269.95	28.00
	MLP	283.79	218.88	22.64

จากผลการทดลองสรุปได้ว่า แบบจำลองที่มีประสิทธิภาพที่สุดของสินค้าแจกันทรงสูง และทรงเอียงกลาง คือแบบจำลอง LSTM และแบบจำลองที่มีประสิทธิภาพที่สุดของสินค้าแจกันทรงสูงใหญ่ คือแบบจำลอง MLP

2. อภิปรายผลการวิจัย

เนื่องจากในการวิจัยนี้ได้สร้างแบบจำลอง SARIMA SARIMAX LSTM และ MLP เพื่อใช้ในการพยากรณ์ยอดขายล่วงหน้า ดังนั้นจึงเลือกใช้ RMSE MAE และ MAPE มาเป็นตัววัดประสิทธิภาพของแบบจำลอง หรือการหาค่า error ซึ่งได้จากการหาค่าความแตกต่างระหว่างค่าที่ได้จากการทำนายกับค่าจริง แล้วนำไปหาค่าเฉลี่ย โดย RMSE แตกต่างกับ MAE ตรงที่ RMSE จะนำผลรวมค่าเฉลี่ย error ที่ได้มายกกำลังสองแล้วถอดรากที่สอง ส่วน MAE จะนำผลรวมค่าเฉลี่ยของ error ที่ได้มาถอดค่าสัมบูรณ์ และ MAPE จะวัดความแม่นยำของการพยากรณ์โดยการหาค่าเฉลี่ยของความแตกต่างระหว่างค่าพยากรณ์และค่าจริงเป็นเปอร์เซ็นต์ โดยที่ค่า RMSE จะมีผลต่อค่า error ที่ค่อนข้างสูงหรือเป็น outlier ซึ่งได้จากการพยากรณ์มากกว่า MAE เนื่องจาก RMSE มีขั้นตอนการคำนวณที่นำค่าผิดพลาดแต่ละค่าไปยกกำลังสอง และหลังจากนั้นนำมาหาค่าเฉลี่ย

ส่งผลให้ค่าผิดพลาดที่มีความผิดพลาดมาก ๆ มีน้ำหนักมากขึ้นในการคำนวณ RMSE เมื่อเปรียบเทียบกับค่าผิดพลาดที่น้อยลง ซึ่งทำให้ RMSE มักจะได้ค่าที่มากกว่า MAE เนื่องจาก MAE หาค่าเฉลี่ยของ error ที่ได้มาถอดค่าสัมบูรณ์ โดยไม่ต้องยกกำลังสอง ทำให้ค่า Error ทุกตัวมีผลต่อค่า MAE เท่ากัน

จากการพยากรณ์ยอดขายสินค้าแจกันทรงสูงพบว่า แบบจำลอง LSTM ให้ประสิทธิภาพที่ดีที่สุด เนื่องจากมีค่า RMSE MAE และ MAPE ต่ำที่สุด คือ ค่า RMSE = 592.50, MAE = 452.65 และ MAPE = 19.84 หมายความว่า รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 592.50 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 452.65 บาท และ ค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 19.84% ของค่าจริง ซึ่งหมายความว่าสามารถพยากรณ์ได้อยู่ในเกณฑ์ดี จากการพยากรณ์ยอดขายสินค้าแจกันทรงเอียงกลาง พบว่าแบบจำลองแบบจำลอง LSTM ให้ประสิทธิภาพที่ดีที่สุด เนื่องจากมีค่า RMSE MAE และ MAPE ต่ำที่สุด คือ ค่า RMSE = 563.48, MAE = 461.39 และ MAPE = 25.16 หมายความว่า รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 563.48 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 461.39 บาท และ ค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 25.16% ของค่าจริง ซึ่งหมายความว่าสามารถพยากรณ์ได้อยู่ในเกณฑ์สมเหตุสมผล แต่จะเห็นได้ว่าแบบจำลอง MLP ก็มีประสิทธิภาพใกล้เคียงกับแบบจำลอง LSTM เนื่องจากเป็นเพราะว่าข้อมูลของแจกันทรงเอียงกลางไม่ซับซ้อนมากพอที่จะให้ LSTM มีประสิทธิภาพที่มากเหมือนเคสอื่น ๆ ในกรณีที่ข้อมูลไม่ซับซ้อนมาก โมเดลทั้งสองอาจมีประสิทธิภาพใกล้เคียงกัน และจากการพยากรณ์ยอดขายสินค้าแจกันทรงสูงใหญ่ พบว่าแบบจำลอง MLP ให้ประสิทธิภาพที่ดีที่สุด เนื่องจากมีค่า RMSE MAE และ MAPE ต่ำที่สุด คือ ค่า RMSE = 283.79, MAE = 218.88 และ MAPE = 22.64 หมายความว่า รากที่สองของความคลาดเคลื่อนโดยเฉลี่ยของการพยากรณ์เป็นจำนวน 283.79 บาท ค่าพยากรณ์มีความแตกต่างจากค่าจริงโดยเฉลี่ยอยู่ที่ประมาณ 218.88 บาท และ ค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์เป็น 22.64% ของค่าจริง ซึ่งหมายความว่าสามารถพยากรณ์ได้อยู่ในเกณฑ์สมเหตุสมผล

จากสินค้าแจกันทั้ง 3 รายการ แบบจำลองที่ให้ประสิทธิภาพที่ดีที่สุดของแจกันทรงสูง และทรงเอียงกลาง คือ แบบจำลอง LSTM และแบบจำลองที่ให้ประสิทธิภาพที่ดีที่สุดของแจกันทรงสูงใหญ่ คือ แบบจำลอง MLP ซึ่งในแบบจำลอง LSTM มีความสามารถในการจัดเรียงข้อมูลและจำความจำในช่วงเวลาย้อนหลังได้ดี ซึ่งช่วยให้แบบจำลองสามารถจับฤดูกาลและแนวโน้มของข้อมูลได้อย่างแม่นยำ และแบบจำลอง LSTM มีความสามารถในการจัดการกับลักษณะ

ซับซ้อนและลำดับข้อมูลได้อย่างมีประสิทธิภาพ จากข้อมูลชุดนี้ในช่วงปีโควิดทำให้ข้อมูลมี ยอดขายสูงโดดขึ้นมา จึงอาจทำให้ข้อมูลมีลักษณะที่ซับซ้อน แบบจำลอง LSTM จึงมีประสิทธิภาพ มากกว่า SARIMA หรือ SAIMAX และแบบจำลอง MLP ที่ให้ประสิทธิภาพที่ดีที่สุดของแฉกั้น ทรงสูงใหญ่ อาจเกิดจากลักษณะของข้อมูลที่มีความซับซ้อนน้อยลงหรือมีลักษณะที่เหมาะสมกับ การใช้ MLP มากกว่า LSTM

ในงานวิจัยนี้ได้ทดลองใช้แบบจำลอง SARIMAX เพื่อพิจารณาวันโปรโมชันเข้าไปเป็น ปัจจัยภายนอกในแบบจำลอง ซึ่งจากผลการทดลองพบว่าแบบจำลอง SARIMAX ให้ประสิทธิภาพ ที่ดีกว่าแบบจำลอง SARIMA แสดงว่าวันโปรโมชันส่งผลให้แบบจำลองมีประสิทธิภาพที่ดีขึ้น

จากผลการทดลอง ทำให้สามารถพยากรณ์ยอดขายหรือจำนวนของสินค้าที่ต้องผลิตได้ ทำให้ธุรกิจสามารถวางแผนการผลิตให้เหมาะสมกับความต้องการนั้น ๆ โดยลดความขัดแย้งใน การจัดการคลังสินค้าและปรับปรุงระบบจัดการสต็อก ลดความสูญเสียจากสินค้าที่ลือค้างอยู่ใน คลังสินค้าหรือสินค้าที่ขายไม่ได้ และมีสินค้าเพียงพอตามความต้องการของผู้บริโภค ไม่มาก เกินไปหรือน้อยเกินไป

3. ข้อเสนอแนะ

1. ในงานวิจัยนี้ใช้ข้อมูลทั้งหมด 122 สัปดาห์ในการฝึกฝนแบบจำลอง หากรวบรวม ข้อมูลให้มากขึ้น อาจช่วยให้แบบจำลองสามารถเรียนรู้ข้อมูลได้มากขึ้น และมีประสิทธิภาพในการ พยากรณ์ความต้องการได้แม่นยำและมีประสิทธิภาพมากขึ้น

2. ในแบบจำลอง LSTM และ MLP ได้ใช้ Feature Netprice(ยอดขาย) เข้าไปใน แบบจำลองเพียง Feature เดียว ควรเพิ่ม Feature อื่น ๆ เข้าไปในแบบจำลองเพื่อเพิ่มประสิทธิภาพ ในการพยากรณ์ยอดขายได้แม่นยำมากยิ่งขึ้น

3. ลองทำการทดลองใช้ Cross-Validation ในการแบ่งข้อมูลออกเป็น Train Validate Test

บรรณานุกรม

- Ahnaf, M. S., A. Kurniawati and H. D. Anggana (2021). Forecasting Pet Food Item Stock using ARIMA and LSTM. 2021 4th International Conference of Computer and Informatics Engineering (IC2IE).
- Ali, Y. and S. Nakti (2023). Sales Forecasting: A Comparison of Traditional and Modern Times-Series Forecasting Models on Sales Data with Seasonality. 2023 10th International Conference on Computing for Sustainable Global Development (INDIACom).
- Anwer, M. O. and S. Akyüz (2022). Sales Forecasting of a Hypermarket: Case Study in Baghdad Using Machine Learning. 2022 30th Signal Processing and Communications Applications Conference (SIU).
- Arunraj, N., D. Ahrens and M. Fernandes (2016). "Application of SARIMAX Model to Forecast Daily Sales in Food Retail Industry." International Journal of Operations Research and Information Systems 7: 1-21.
- Dave, E., A. Leonardo, M. Jeanice and N. Hanafiah (2021). "Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM." Procedia Computer Science 179: 480-487.
- Ensafi, Y., S. H. Amin, G. Zhang and B. Shah (2022). "Time-series forecasting of seasonal items sales using machine learning – A comparative analysis." International Journal of Information Management Data Insights 2(1): 100058.
- Falatouri, T., F. Darbanian, P. Brandtner and C. Udokwu (2022). "Predictive Analytics for Demand Forecasting – A Comparison of SARIMA and LSTM in Retail SCM." Procedia Computer Science 200: 993-1003.
- Kaewhawong, N. (2015). "Forecasting Electricity Consumption of Thailand by Using SARIMA and Regression Models with ARMA Errors."
- Kheawpeam, N. and S. Sinthupinyo (2023). Demand Forecasting Using Machine Learning to Manage Product Inventory for Multi-channel Retailing Store. 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS).
- Khulood Albeladi, Bassam Zafar and A. Mueen (2023). "Time Series Forecasting using LSTM and ARIMA."

- Soontranon, N. (2023). "LSTM คือ อะไร." from https://www.nerd-data.com/deep_learning_lstm/?fbclid=IwAR0IFef4sK1mylecilY0jeRMtM-cjcp1hfv6JsAy_DqH0y7xBOoIUkWiD_k.
- Tangruamsub, S. (2017). "Long Short-Term Memory (LSTM)." from <https://medium.com/@sinart.t/long-short-term-memory-lstm-e6cb23b494c6>.
- Withitsontorn, C. and P. Chongstitvatana (2022). Demand Forecasting in Production Planning for Dairy Products Using Machine Learning and Statistical Method. 2022 International Electrical Engineering Congress (iEECON).
- Xinxiang, Z., Z. Bo and F. Huijuan (2017). A comparison study of outpatient visits forecasting effect between ARIMA with seasonal index and SARIMA. 2017 International Conference on Progress in Informatics and Computing (PIC).
- บรรจงพัฒนา, ภ. and P. Banjongpattana (2021). การศึกษาและเปรียบเทียบตัวแบบการพยากรณ์ ARIMA, ARIMAX และ GARCH ต่อดัชนี SET50 ในช่วงก่อน-หลังการเกิดวิกฤตการณ์โรคระบาดโควิด-19, มหาวิทยาลัยธรรมศาสตร์.

ประวัติผู้เขียน

