



การวิเคราะห์เปรียบเทียบวิธีการเรียนรู้ด้วยแมชชีนเลิร์นนิงในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์

A COMPARATIVE ANALYSIS OF MACHINE LEARNING METHODS FOR COMMODITY DEMAND
FORECASTING

อัจฉราวรรณ คำสาย

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566

การวิเคราะห์เปรียบเทียบวิธีการเรียนรู้ด้วยแมชชีนเลิร์นนิงในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์



อัจฉราวรรณ คำสาย

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล
คณะคณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

A COMPARATIVE ANALYSIS OF MACHINE LEARNING METHODS FOR COMMODITY DEMAND
FORECASTING



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

สารนิพนธ์เรื่อง
การวิเคราะห์เปรียบเทียบวิธีการเรียนรู้ด้วยแมชชีนเลิร์นนิงในการพยากรณ์ความต้องการสินค้าโภค
ภัณฑ์
ของ
อัจฉราวรรณ คำสาย

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์จัตตชัย เอกปัญญากุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... อาจารย์ที่ปรึกษา
(ผู้ช่วยศาสตราจารย์ ดร. นุรีย์ วิวัฒน์วัฒนา)

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร. ดวงดาว วิชาดากุล)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร. ศิริสรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การวิเคราะห์เปรียบเทียบวิธีการเรียนรู้ด้วยแมชชีนเลิร์นนิงในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์
ผู้วิจัย	อัจฉราวรรณ คำสาย
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.นุรีย์ วิวัฒน์วัฒนา

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง โดยใช้แบบจำลอง Autoregressive Integrated Moving Average (ARIMA) และ Multi-Layer Perceptron (MLP) ในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์ โดยใช้ข้อมูลราคาปิดรายวันของสินค้าโภคภัณฑ์ ได้แก่ โกโก้ กาแฟ ฝ้าย น้ำส้ม ไม่แปรรูป และน้ำตาล จากข้อมูลอนุกรมเวลา การประเมินความแม่นยำของวิธีการพยากรณ์ทั้งสองประเภทใช้เกณฑ์การประเมินสามแบบ ได้แก่ ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ถูกรวบรวมที่สอง (Root Mean Squared Error - RMSE) ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error - MAPE) ผลการวิจัยพบว่า โมเดล MLP แสดงประสิทธิภาพที่เหนือกว่า ARIMA ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ทั้ง 6 ชนิด โดย MLP มีค่า RMSE MAE และ MAPE ต่ำกว่า ARIMA ในทุกประเภทสินค้า โกโก้มีค่า RMSE ของ MLP เท่ากับ 43.02 ขณะที่ ARIMA มีค่าเท่ากับ 105.57 ส่วนความแตกต่างของค่าคลาดเคลื่อนน้อยที่สุดพบในน้ำตาล โดยค่า RMSE ของ MLP เท่ากับ 0.51 และ ARIMA เท่ากับ 0.96 จากผลการวิจัย โมเดล MLP แสดงให้เห็นถึงความยืดหยุ่นและความสามารถในการจับความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นของข้อมูลได้ดีกว่า ARIMA ซึ่งเป็นโมเดลเชิงเส้นและมีข้อจำกัดในการจับความสัมพันธ์ที่ซับซ้อน

คำสำคัญ: การเรียนรู้ของเครื่อง, แมชชีนเลิร์นนิง, การเรียนรู้ทางสถิติแบบดั้งเดิม

Title	A COMPARATIVE ANALYSIS OF MACHINE LEARNING METHODS FOR COMMODITY DEMAND FORECASTING
Author	ATCHARAWAN KAMSAI
Degree	MASTER OF SCIENCE
Academic Year	2023
Advisor	Assistant Professor Dr. Nuwee Wiwatwattana

The objective of this research is to compare the performance of traditional statistical forecasting methods with machine learning methods, specifically utilizing the Autoregressive Integrated Moving Average (ARIMA) model and the Multi-Layer Perceptron (MLP) model for forecasting the demand for commodities. The study employs closing price data of commodities such as cocoa, coffee, cotton, orange juice, lumber, and sugar from time series data. The accuracy of the forecasting methods is evaluated using three criteria: Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The findings indicate that the MLP model outperformed the ARIMA model in forecasting the closing prices of all six commodities. The MLP model exhibits lower RMSE, MAE, and MAPE values than the ARIMA model across all commodity types. For cocoa, the RMSE value of the MLP model is 43.02, compared to 105.57 for the ARIMA model. The smallest difference in error values is observed in sugar, with an RMSE of 0.51 for the MLP model and 0.96 for the ARIMA model. The results demonstrated that the MLP model has greater flexibility and capability in capturing complex and non-linear relationships within the data compared to the ARIMA model, which is a linear model with limitations in handling complex relationships.

Keywords: Demand Forecasting, Time Series Forecasting, Machine Learning Models, Auto-Regressive Integrated Moving Average (ARIMA), Multi-Layer Perceptron (MLP)

กิตติกรรมประกาศ

สารนิพนธ์ฉบับนี้ไม่สามารถสำเร็จลงได้ด้วยผู้วิจัยเพียงคนเดียว ยังมีบุคคลที่หาคำแนะนำความช่วยเหลือ และให้การสนับสนุน

ขอขอบพระคุณ ผศ.ดร.นุรีย์ วิวัฒน์วัฒนา อาจารย์ที่ปรึกษาที่ได้ให้คำปรึกษาและความช่วยเหลือ รวมถึงชี้แนะแนวทางต่าง ๆ อันเป็นประโยชน์อย่างยิ่งในการทำสารนิพนธ์นี้

ขอขอบพระคุณคณะกรรมการสอบสารนิพนธ์ซึ่งประกอบไปด้วย รศ.ดร.ดวงดาว วิชาดา กุล และ ผศ.ดร.ศิริสรรพ เหล่าหะเกียรติ ที่กรุณาให้เกียรติเป็นคณะกรรมการรวมทั้งให้คำปรึกษาและข้อเสนอแนะอันเป็นประโยชน์อย่างมากต่อการทำสารนิพนธ์ฉบับนี้

ขอกราบขอบพระคุณบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ และคณาจารย์ทุกท่านในภาควิชาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ที่กรุณาให้ความรู้คำแนะนำ และสนับสนุนการทำวิจัย

อัจฉรวรรณ คำสาย

สารบัญ

หน้า

บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ	ฉ
สารบัญ	
สารบัญตาราง (ถ้ามี)	ญ
สารบัญรูปภาพ (ถ้ามี)	ฎ
บทที่ 1 บทนำ	12
1.1 ภูมิหลัง	12
1.2 ความมุ่งหมายของงานวิจัย	13
1.3 ความสำคัญของงานวิจัย	14
1.4 ขอบเขตของงานวิจัย	15
1.5 นิยามศัพท์เฉพาะ	15
1.6 กรอบแนวคิดในงานวิจัย	16
1.7 สมมุติฐานในงานวิจัย	17
บทที่ 2 ทบทวนวรรณกรรม	18
2.1 ทฤษฎีที่เกี่ยวข้อง	18
2.1.1 วิธีการทางสถิติแบบดั้งเดิม	18
2.1.2 วิธีการเรียนรู้ของเครื่อง (Machine Learning)	19
2.1.3 การวัดประสิทธิภาพการพยากรณ์ของโมเดล	23
2.2 งานวิจัยที่เกี่ยวข้อง	24

2.2.1 Forecasting Mid-Long Term Electric Energy Consumption Through Bagging ARIMA and Exponential Smoothing Methods [6].....	30
2.2.2 Decomposition and Forecasting Time Series In The Business Economy Using Prophet Forecasting Model [7]	30
2.2.3 Combining Forecasts of ARIMA and Exponential Smoothing Model [8]	30
การศึกษานี้มีวัตถุประสงค์เพื่อปรับปรุงความแม่นยำในการพยากรณ์โดยการรวมโมเดล ARIMA ซึ่งเป็นวิธีการคาดการณ์อนุกรมเวลาแบบดั้งเดิมทั้ง และการศึกษานี้วัตถุประสงค์เพื่อ สำรวจว่าการรวมกันของวิธีเหล่านี้สามารถนำไปสู่การคาดการณ์ที่แม่นยำมากยิ่งขึ้น วิธีที่ใช้ใน การศึกษานี้คือ ARIMA ข้อที่ค้นพบในการศึกษานี้สรุปได้ว่าการรวมกันของ ARIMA และ แบบจำลองแบบเอกซ์โปเนนเชียลนำไปสู่ความแม่นยำในการคาดการณ์ที่ดีขึ้น.....	30
2.2.4 Time Series Forecasting Model for Supermarket Sales Using FB-Prophet [9].....	31
2.2.5 A Hybrid Forecasting Model Using LSTM and Prophet for Energy Consumption with Decomposition of Time Series Data [10]	31
2.2.6 Time-Series Forecasting of Seasonal Data Using Machine Learning Methods [11].....	32
2.2.7 Time-Series Analysis and Flood Prediction Using A Deep Learning Approach [12]	33
2.2.8 A Comprehensive Study and Performance Analysis of Deep Neural Network-Based Approaches in Wind Time-Series Forecasting [13]	33
2.2.9 Dynamic Adaptive Encoder-Decoder Deep Learning Networks For Multivariate Time Series Forecasting of Building Energy Consumption [14].....	34
2.2.10 Are Transformers Effective for Time Series Forecasting? [15]	34
2.2.11 Tsmixer: An All-MLP Architecture For Time Series Forecasting [5]	35
บทที่ 3 การดำเนินการวิจัย.....	36

3.1 แนวคิดและภาพรวมวิธีการวิจัย	36
3.2 เกี่ยวกับชุดข้อมูล.....	37
3.2.1 แหล่งที่มาของข้อมูล	37
3.3 การสำรวจและวิเคราะห์ข้อมูล (Exploratory Data Analysis - EDA).....	37
3.3.1 การตรวจสอบข้อมูล	37
3.3.2 สำรวจการกระจายตัวของราคาและปริมาณการซื้อขายสำหรับสินค้าโภคภัณฑ์ของแต่ละชนิด.....	38
3.3.3 แสดงกราฟเส้นแสดงแนวโน้มของราคาสินค้าโภคภัณฑ์ตามปี.....	39
3.3.4 แสดงแผนภูมิเวลาตัวแปรปริมาณการซื้อขายของสินค้าแต่ละรายการ	42
3.4 การสร้างแบบจำลองพยากรณ์	45
3.4.1 การสร้างแบบจำลอง Autoregressive Integrated Moving Average (ARIMA).....	47
3.4.2 การสร้างแบบจำลอง Multi-Layer Perceptron (MLP).....	50
บทที่ 4 ผลการศึกษา	53
4.1 ผลการทดลองแบบจำลอง Autoregressive Integrated Moving Average (ARIMA).....	53
4.3 ผลการทดลองแบบจำลอง Multi-Layer Perceptron (MLP)	55
บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	58
5.1 สรุปผลการวิจัย	58
5.2 อภิปรายผล	63
5.3 ข้อเสนอแนะ	64
บรรณานุกรม	66

สารบัญตาราง (ถ้ามี)

หน้า

ตาราง 1 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวិธีการพยากรณ์ทางสถิติแบบดั้งเดิม	25
ตาราง 2 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวิธีการพยากรณ์ทางสถิติแบบดั้งเดิม (ต่อ).....	26
ตาราง 3 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (ต่อ).....	27
ตาราง 4 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (ต่อ).....	28
ตาราง 5 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (ต่อ).....	29
ตาราง 6 ค่าที่ดีที่สุดของโมเดล ARIMA จากการใช้ฟังก์ชัน Auto Arima.....	48
ตาราง 7 การปรับแต่งค่าพารามิเตอร์สำหรับแบบจำลอง Multilayer Perceptron (MLP).....	52
ตาราง 8 ผลการทดลองแบบจำลอง ARIMA.....	53
ตาราง 9 ผลการทดลองแบบจำลอง MLP.....	55
ตาราง 10 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า RMSE.....	58
ตาราง 11 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAE.....	60
ตาราง 12 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAPE	61

สารบัญรูปภาพ (ถ้ามี)

หน้า

ภาพประกอบ 1 กรอบแนวคิดงานวิจัย	16
ภาพประกอบ 2 โครงสร้าง Multi-Layer Perceptron (MLP) เครือข่ายประสาทเทียมแบบฟีดฟอร์เวิร์ดสำหรับงานเรียนรู้ของเครื่อง	21
ภาพประกอบ 3 โหลดข้อมูลอนุกรมเวลาจากชุดข้อมูลที่ใช้ในการศึกษา	38
ภาพประกอบ 4 การกระจายตัวของราคาและปริมาณการซื้อขายสำหรับสินค้าโภคภัณฑ์ของแต่ละชนิด	38
ภาพประกอบ 5 กราฟเส้นแสดงแนวโน้มของราคาน้ำส้ม	39
ภาพประกอบ 6 กราฟเส้นแสดงแนวโน้มของราคาน้ำตาล	40
ภาพประกอบ 7 กราฟเส้นแสดงแนวโน้มของราคาโกโก้	40
ภาพประกอบ 8 กราฟเส้นแสดงแนวโน้มของราคากาแฟ	41
ภาพประกอบ 9 กราฟเส้นแสดงแนวโน้มของราคาฝ้าย	41
ภาพประกอบ 10 กราฟเส้นแสดงแนวโน้มของราคาไม้แปรรูป	42
ภาพประกอบ 11 แผนภูมิเวลาตัวแปรปริมาณของโกโก้	42
ภาพประกอบ 12 แผนภูมิเวลาตัวแปรปริมาณของกาแฟ	43
ภาพประกอบ 13 แผนภูมิเวลาตัวแปรปริมาณของน้ำตาล	43
ภาพประกอบ 14 แผนภูมิเวลาตัวแปรปริมาณของฝ้าย	44
ภาพประกอบ 15 แผนภูมิเวลาตัวแปรปริมาณของน้ำส้ม	44
ภาพประกอบ 16 แผนภูมิเวลาตัวแปรปริมาณของไม้แปรรูป	45
ภาพประกอบ 17 แผนผังแสดงกระบวนการสร้างแบบจำลองของ ARIMA	47
ภาพประกอบ 18 แผนผังแสดงกระบวนการสร้างแบบจำลองของ MLP	50
ภาพประกอบ 19 ตัวอย่างรูปแบบข้อมูลก่อนและหลังจากทำการแปลงข้อมูล	51
ภาพประกอบ 20 กราฟการพยากรณ์ราคารายวันของแต่ละสินค้าของโมเดล ARIMA	54
ภาพประกอบ 21 กราฟการพยากรณ์ราคาของแต่ละสินค้าของโมเดล MLP	56
ภาพประกอบ 22 แผนภูมิแท่งผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า RMSE	59
ภาพประกอบ 23 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAE	60
ภาพประกอบ 24 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAPE	62

บทที่ 1

บทนำ

1.1 ภูมิหลัง

สินค้าโภคภัณฑ์หรือสินค้าเกษตรกรรมประเภทพืชผลเช่น กาแฟ น้ำตาล โกโก้ และฝ้าย เป็นสินค้าที่มีความอ่อนไหวต่อการเปลี่ยนแปลงของฤดูกาลและสภาพภูมิอากาศ การผลิตสินค้าเหล่านี้มีผลกระทบอย่างมากต่อเศรษฐกิจโลก รวมถึงการดำรงชีพของเกษตรกรและผู้ประกอบการค้าจำนวนมาก การคาดการณ์ความต้องการสินค้าโภคภัณฑ์ทางการเกษตรจึงถือเป็นงานที่ท้าทายอย่างยิ่ง เนื่องจากต้องพิจารณาปัจจัยหลายประการ ได้แก่ รูปแบบของสภาพอากาศ ความพึงพอใจและพฤติกรรมของผู้บริโภค เหตุการณ์ทางการเมืองและภูมิรัฐศาสตร์ในระดับภูมิภาคและระดับโลก รวมถึงค่าเงินดอลลาร์สหรัฐที่อ่อนค่าลงในปัจจุบัน ส่งผลให้ราคาสินค้าโภคภัณฑ์ที่ซื้อขายกันเป็นสกุลดอลลาร์มีราคาสูงขึ้น ซึ่งได้เกื้อหนุนให้ราคาสินค้าโภคภัณฑ์ต่าง ๆ รวมถึงน้ำตาล มีแนวโน้มปรับตัวสูงขึ้น อีกทั้ง ผลผลิตน้ำตาลที่เพิ่มขึ้นของบราซิลทำให้อาณานิคมน้ำตาลถูกกดดัน และภาพอุปทานน้ำตาลจากอินเดียคาดว่าจะลดลง หลังจากรัฐมนตรีกระทรวงอาหารของอินเดียได้ควบคุมการส่งออกน้ำตาลส่งออกของอินเดีย ความต้องการน้ำตาลดิบทั่วโลกในช่วงครึ่งหลังของปี 2566 จึงเพิ่มขึ้น เนื่องจากบางประเทศ อาทิ จีน และอินโดนีเซียไม่สามารถชะลอการนำเข้าน้ำตาลได้ [1]

ดังนั้น การเปลี่ยนแปลงของราคาน้ำตาลเป็นผลสะท้อนจากการเปลี่ยนแปลงของสภาวะตลาดทั่วโลกและสภาวะภายในประเทศที่ส่งออกน้ำตาล ซึ่งรวมถึงการเปลี่ยนแปลงของอัตราแลกเปลี่ยน การเปลี่ยนแปลงของผลผลิต และการเปลี่ยนแปลงของความต้องการ ในปี 2566 ความต้องการน้ำตาลทั่วโลกคาดว่าจะเพิ่มขึ้นเป็น 180.05 ล้านตัน ในขณะที่ผลผลิตน้ำตาลของอินเดียในปี 2566 คาดว่าจะอยู่ที่ราว ๆ 36 ล้านตัน และผลผลิตน้ำตาลของบราซิลในปี 2566 คาดว่าจะอยู่ที่ราว ๆ 42.6 ล้านตัน สภาวะตลาดน้ำตาลทั่วโลกในปี 2566 จึงขึ้นอยู่กับเปลี่ยนแปลงของความต้องการและอุปทานในแต่ละประเทศที่ส่งออกน้ำตาล

สำหรับการศึกษาในงานวิจัยนี้ มุ่งเน้นไปที่การเปรียบเทียบวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมและวิธีการเรียนรู้ของเครื่อง (Machine Learning) โดยใช้โครงข่ายประสาทเทียม (Neural Network) โดยวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมนั้นอาศัยข้อมูลในอดีตและสมมติฐานทางสถิติเพื่อจับรูปแบบการคาดการณ์ราคาปิดของสินค้าโภคภัณฑ์ อย่างไรก็ตาม วิธีการเหล่านี้มีข้อจำกัดหลายประการ เช่น ความจำเป็นในการปรับพารามิเตอร์ด้วยตนเอง ความยากลำบากในการจัดการข้อมูลที่ไม่คงที่ (Non-Stationary) [1] และการไม่สามารถรวมตัวแปรภายนอกได้ ยิ่งไปกว่านั้น วิธีการเหล่านี้อาจไม่สามารถจับความสัมพันธ์ที่ซับซ้อนที่มีอยู่ในตลาดสินค้าโภคภัณฑ์ได้

ซึ่งวิธีการเรียนรู้ทางสถิติแบบดั้งเดิมในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์มักใช้เทคนิคทางสถิติ เช่น Autoregressive Integrated Moving Average (ARIMA) ซึ่งวิธีนี้เป็นที่นิยมเป็นอย่างมาก แต่ก็มีข้อจำกัดในการจัดการกับความซับซ้อนและความไม่แน่นอนของข้อมูลที่มีความซับซ้อน และมักจำเป็นต้องมีความรู้ล่วงหน้าเกี่ยวกับข้อมูลและความสัมพันธ์ระหว่างตัวแปรที่เกี่ยวข้อง

เมื่อเทียบกับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) โดยใช้โครงข่ายประสาทเทียม (Neural Network) เช่น Multi-Layer Perceptron (MLP) ที่สามารถเรียนรู้จากข้อมูลจำนวนมากและแยกคุณสมบัติที่เกี่ยวข้องโดยอัตโนมัติ โดยไม่จำเป็นต้องมีความรู้ล่วงหน้าหรือการแทรกแซงของมนุษย์มากนัก ทำให้สามารถจัดการกับความซับซ้อนและความไม่แน่นอนของข้อมูลได้ดีกว่าวิธีการเรียนรู้ทางสถิติแบบดั้งเดิม

คำถามหลักที่เกิดขึ้นในการวิจัยนี้คือ วิธีการเรียนรู้ของเครื่อง (Machine Learning) โดยใช้โครงข่ายประสาทเทียม (Neural Network) เช่น Multi-Layer Perceptron (MLP) มีประสิทธิภาพดีกว่าวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมอย่าง Autoregressive Integrated Moving Average (ARIMA) ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ที่เป็นข้อมูลอนุกรมเวลาหรือไม่ เพื่อตอบคำถามนี้ ผู้วิจัยได้นำวิธีการทางสถิติมาเปรียบเทียบกับประสิทธิภาพของวิธีการเหล่านี้กับชุดข้อมูลสินค้าโภคภัณฑ์ โดยใช้เกณฑ์ในการประเมิน ได้แก่ ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ถูกทำรากที่สอง (Root Mean Squared Error - RMSE) ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error - MAPE)

1.2 ความมุ่งหมายของงานวิจัย

1) เปรียบเทียบประสิทธิภาพ ของวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (Machine Learning) โดยใช้โครงข่ายประสาทเทียม (Neural Network) ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ที่เป็นข้อมูลอนุกรมเวลา

2) ประเมินความแม่นยำ ของวิธีการพยากรณ์ทั้งสองประเภท โดยใช้เกณฑ์ในการประเมิน ได้แก่ ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ถูกทำรากที่สอง (Root Mean Squared Error - RMSE) ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error - MAPE)

1.3 ความสำคัญของงานวิจัย

ความสำคัญของการวิจัยนี้เชื่อมโยงวิธีการพยากรณ์แบบดั้งเดิมกับเทคโนโลยีการเรียนรู้ของเครื่องสมัยใหม่ โดยมีจุดมุ่งหมายเพื่อวิเคราะห์เปรียบเทียบและนำเสนอหลักฐานเชิงประจักษ์ที่จะช่วยผู้ประกอบการในอุตสาหกรรมเลือกเทคนิคการพยากรณ์ที่เหมาะสมที่สุด ความสำคัญของการวิจัยนี้มีหลายประการ ดังนี้:

1) การพยากรณ์ราคาที่เหมาะสม วิธีการพยากรณ์ราคาปิดที่แม่นยำและมีประสิทธิภาพสูงสำหรับสินค้าโภคภัณฑ์จะช่วยให้นักลงทุนและผู้ประกอบการสามารถวางแผนกลยุทธ์ทางการเงินและการลงทุนได้อย่างเหมาะสม

2) การจัดการความเสี่ยง การพยากรณ์ราคาสินค้าโภคภัณฑ์อย่างแม่นยำช่วยลดความเสี่ยงในการตัดสินใจทางธุรกิจและการลงทุน โดยเฉพาะในภาวะที่ตลาดมีความผันผวนสูง

3) การเพิ่มประสิทธิภาพทางเศรษฐกิจ ผลการวิจัยสามารถนำไปใช้สนับสนุนการตัดสินใจเชิงกลยุทธ์ในการบริหารพอร์ตการลงทุนและการวางแผนทางการเงิน ซึ่งจะช่วยให้เกิดการจัดสรรทรัพยากรทางการเงินอย่างมีประสิทธิภาพ

4) การสนับสนุนการตัดสินใจทางนโยบาย ข้อมูลการพยากรณ์ราคาที่ถูกต้องสามารถช่วยให้ผู้กำหนดนโยบายวางแผนและออกมาตรการที่เหมาะสมเพื่อรับมือกับความผันผวนของราคาสินค้าโภคภัณฑ์

5) การปรับตัวต่อการเปลี่ยนแปลงของตลาด ความสามารถในการพยากรณ์ราคาสินค้าโภคภัณฑ์ช่วยให้ผู้ประกอบการและนักลงทุนสามารถปรับตัวต่อการเปลี่ยนแปลงของตลาดได้รวดเร็วและมีประสิทธิภาพมากขึ้น

6) การลดความไม่แน่นอน การนำเทคนิคการเรียนรู้ของเครื่องที่สามารถจัดการกับข้อมูลที่ซับซ้อนและไม่คงที่มาใช้ในการพยากรณ์ราคา ช่วยลดความไม่แน่นอนในการคาดการณ์และเพิ่มความเชื่อมั่นในการตัดสินใจลงทุน

7) การเสริมสร้างความรู้และเทคโนโลยี งานวิจัยนี้จะเป็นการเสริมสร้างความรู้และทักษะในการใช้เทคนิคการเรียนรู้ของเครื่องในด้านการพยากรณ์ทางการเงินและการลงทุน ซึ่งเป็นทักษะที่มีความสำคัญในยุคดิจิทัล

8) การพัฒนากลยุทธ์การซื้อขายที่มีประสิทธิภาพ การพยากรณ์ราคาที่เหมาะสมช่วยให้นักลงทุนและผู้ค้าสามารถพัฒนากลยุทธ์การซื้อขายที่มีประสิทธิภาพมากขึ้น ซึ่งอาจนำไปสู่ผลตอบแทนที่ดีขึ้นและการจัดการความเสี่ยงที่มีประสิทธิภาพ

9) การเพิ่มสภาพคล่องในตลาด การมีเครื่องมือพยากรณ์ราคาที่เหมาะสมอาจช่วยเพิ่มความมั่นใจของผู้เล่นในตลาด ส่งผลให้เกิดการซื้อขายที่มากขึ้นและเพิ่มสภาพคล่องในตลาดสินค้าโภคภัณฑ์

1.4 ขอบเขตของงานวิจัย

งานวิจัยนี้มุ่งเน้นไปที่การประยุกต์ใช้วิธีการเรียนรู้ของเครื่อง (Machine Learning) และวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์ โดยเฉพาะ โกโก้ กาแฟ ฝ้าย ไม้แปรรูป น้ำส้ม และน้ำตาล โดยใช้โมเดลที่เหมาะสมสำหรับข้อมูลและบริบทที่มีอยู่ สำหรับวิธีการทางสถิติดั้งเดิม ผู้วิจัยใช้ Autoregressive Integrated Moving Average (ARIMA) ในการทำนายความต้องการสินค้าเหล่านี้ ในขณะที่สำหรับการเรียนรู้ของเครื่องใช้โครงข่ายประสาทเทียม (Neural Network) โดยใช้ Multi-Layer Perceptron (MLP)

เป้าหมายเพื่อให้เข้าใจอย่างละเอียดว่าวิธีการเรียนรู้ของเครื่องและวิธีการทางสถิติดั้งเดิมสามารถปรับให้เหมาะสมสำหรับการพยากรณ์ความต้องการในบริบทเฉพาะนี้ได้อย่างไร และเพื่อตอบคำถามนี้ ผู้วิจัยจึงเปรียบเทียบประสิทธิภาพของวิธีการเหล่านี้กับชุดข้อมูลสินค้าโภคภัณฑ์และประเมินโดยใช้เมตริกที่เหมาะสม เช่น ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ถูกทำรากที่สอง (Root Mean Squared Error - RMSE) ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error - MAPE) ทั้งนี้ งานวิจัยนี้มุ่งเน้นพิจารณาจากความแม่นยำในการพยากรณ์ ด้วยการวัดความสามารถของโมเดลในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์

1.5 นิยามศัพท์เฉพาะ

1) สินค้าโภคภัณฑ์หรือสินค้าที่มนุษย์ปลูก (Soft Commodities)

สินค้าโภคภัณฑ์หรือสินค้าที่มนุษย์ปลูก หมายถึง ผลิตภัณฑ์ที่ได้จากการเกษตร เช่น กาแฟ น้ำตาล โกโก้ และฝ้าย ซึ่งมีความอ่อนไหวต่อการเปลี่ยนแปลงของฤดูกาลและสภาพภูมิอากาศ

2) ทฤษฎีแบบจำลอง Autoregressive Integrated Moving Average (ARIMA)

ทฤษฎีแบบจำลอง ARIMA หมายถึง โมเดลอนุกรมเวลาที่ใช้ในการคาดการณ์แนวโน้มและรูปแบบในชุดข้อมูลอนุกรมเวลา

โมเดลนี้ประกอบด้วยสามองค์ประกอบหลัก

1) การถดถอยเชิงอนุกรม (Autoregressive - AR) อธิบายว่าข้อมูลในชุดข้อมูลอนุกรมเวลามีความสัมพันธ์กับข้อมูลในอดีตอย่างไร

2) การปรับให้อนุกรมเวลาที่มีความนิ่ง (Integrated - I) อธิบายว่าข้อมูลในชุดข้อมูลอนุกรมเวลาได้รับการปรับให้เรียบแล้วหรือไม่


3) ค่าเฉลี่ยเคลื่อนที่ (Moving Average - MA) อธิบายว่าข้อมูลในชุดข้อมูลอนุกรมเวลาที่มีการเคลื่อนที่เฉลี่ยอย่างไร

3) ทฤษฎีแบบจำลอง Multi-Layer Perceptron (MLP)

ทฤษฎีแบบจำลอง MLP เป็นโมเดลประสาทเทียมประเภทหนึ่งที่ใช้สำหรับงาน Machine Learning หลากหลายประเภทแบบจำลอง MLP ประกอบด้วยชั้นของโหนดประสาทเทียมที่เชื่อมต่อกัน ซึ่งแต่ละชั้นจะเรียนรู้รูปแบบที่ซับซ้อน

1.6 กรอบแนวคิดในงานวิจัย

งานวิจัยนี้ใช้กรอบแนวคิดการเรียนรู้ของเครื่องเพื่อพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์เปรียบเทียบกับการเรียนรู้ทางสถิติแบบดั้งเดิม ดังภาพประกอบที่ 1



ภาพประกอบ 1 กรอบแนวคิดงานวิจัย

Data Preprocessing คือ การจัดการกับข้อมูลที่ไม่สมบูรณ์ การลบข้อมูลที่ผิดพลาด และการแปลงข้อมูลให้เหมาะสมกับการวิเคราะห์

Exploratory Data Analysis (EDA) คือ การวิเคราะห์ข้อมูลเบื้องต้นเพื่อทำความเข้าใจลักษณะของข้อมูล การค้นหาความสัมพันธ์ระหว่างตัวแปร และการตรวจสอบสมมติฐาน

Normalization และ Scaling คือ การปรับข้อมูลให้อยู่ในช่วงที่เหมาะสมเพื่อให้โมเดลสามารถเรียนรู้ได้ดีขึ้น

Model Training คือ การฝึกสอนโมเดลด้วยข้อมูลเทรน

Evaluation และ Comparison คือ การประเมินผลการทำนายของโมเดล และการเปรียบเทียบผลระหว่างโมเดลที่ต่างกัน

Interpretation และ Insight คือ การแปลผลจากการวิเคราะห์ข้อมูล และการสกัดสาระหรือความรู้จากข้อมูล

1.7 สมมุติฐานในงานวิจัย

การประยุกต์ใช้วิธีการเรียนรู้ของเครื่อง (Machine Learning) และวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ มีสมมุติฐานเบื้องต้น ดังนี้

1) การใช้เทคโนโลยีการเรียนรู้ของเครื่อง เช่น Multi-Layer Perceptron (MLP) สามารถปรับโมเดลให้เหมาะสมกับข้อมูลอย่างมีประสิทธิภาพ เนื่องจากการเรียนรู้ของเครื่องสามารถพยากรณ์ได้ค่าประเมินประสิทธิภาพของโมเดลได้ดีกว่าวิธีการพยากรณ์ทางสถิติแบบดั้งเดิม และมีความสามารถในการปรับปรุงและปรับแต่งโครงสร้างของโมเดลให้เข้ากับลักษณะของข้อมูลและลำดับข้อมูลที่ซับซ้อนได้ดีขึ้น

2) การเปรียบเทียบประสิทธิภาพของวิธีการต่าง ๆ ในการทำนายจะช่วยให้เข้าใจลึกซึ้งเกี่ยวกับความสามารถและข้อจำกัดของแต่ละวิธี ซึ่งสามารถนำมาปรับปรุงและเลือกใช้วิธีการที่เหมาะสมที่สุดสำหรับการพยากรณ์ราคาของสินค้าโภคภัณฑ์



บทที่ 2

ทบทวนวรรณกรรม

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 วิธีการทางสถิติแบบดั้งเดิม

2.1.1.1 ทฤษฎีแบบจำลอง Autoregressive Integrated Moving Average (ARIMA)

การสร้างโมเดลสำหรับการพยากรณ์อนุกรมเวลา (Time Series Forecasting) โดยใช้วิธีการการถดถอยเชิงอนุกรมแบบรวมค่า หรือ ARIMA ถือเป็นหนึ่งในเทคนิคที่ได้รับความนิยมอย่างมากในการวิเคราะห์ข้อมูลทางสถิติแบบดั้งเดิม โมเดล ARIMA ประกอบด้วยส่วนประกอบสำคัญ 3 ส่วน ได้แก่ การถดถอยเชิงอนุกรม (Autoregressive – AR), ส่วนประกอบของค่าผลต่างที่ทำให้อนุกรมเวลามีความนิ่ง (Integrated – I) และค่าเฉลี่ยเคลื่อนที่ (Moving Average - MA) โดยการประมวลผลข้อมูลด้วยโมเดล ARIMA มีจุดมุ่งหมายหลักเพื่อกำจัดสัญญาณรบกวน (Noise) ออกจากข้อมูลอนุกรมเวลา ด้วยการลดค่าความคลาดเคลื่อน (Error Term) ให้น้อยที่สุด จนสามารถมั่นใจได้ว่าข้อมูลนั้นมีความน่าเชื่อถือ ซึ่งจะส่งผลให้การพยากรณ์ในขั้นตอนต่อไปมีประสิทธิภาพสูงขึ้น

ก่อนการสร้างโมเดล ARIMA จำเป็นต้องมีการตรวจสอบคุณสมบัติของอนุกรมเวลาเบื้องต้น ประกอบด้วย 1) การตรวจสอบว่าอนุกรมเวลามีสัญญาณรบกวนที่ไม่สามารถกำจัดออกไปได้หรือไม่ หากมีสัญญาณดังกล่าว แสดงว่าอนุกรมเวลานั้นไม่มีความสัมพันธ์กัน และ 2) การตรวจสอบว่าอนุกรมเวลามีสถานะคงที่ (Stationarity) หรือไม่ หากไม่มีสถานะคงที่จำเป็นต้องทำการหาค่าผลต่าง (Differencing) เพื่อให้อนุกรมเวลามีสถานะคงที่ก่อนการสร้างโมเดล [2]

โมเดล ARIMA ประกอบด้วยพารามิเตอร์ 3 ตัว ได้แก่ p,d,q

p เป็นพารามิเตอร์ของส่วนประกอบ AR

d เป็นพารามิเตอร์ของส่วนประกอบ I

q เป็นพารามิเตอร์ของส่วนประกอบ MA

สมการการคำนวณโมเดล Autoregressive Integrated Moving Average (ARIMA) ดังนี้

$$y'_t = I + \alpha_1 y'_{(t-1)} + \alpha_2 y'_{(t-2)} + \dots + \alpha_p y'_{(t-p)} + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_p e_{t-p}$$

โดยที่

y'_t แทนค่าที่ต้องการพยากรณ์ในช่วงเวลา t ในชุดข้อมูลอนุกรมเวลา

I แทนค่าคงที่หรือค่าอ้างอิงที่จะถูกเพิ่มไปในการพยากรณ์

$\alpha_1, \alpha_2, \dots, \alpha_p$ แทนพารามิเตอร์ของโมเดล Autoregressive (AR) ซึ่งหมายถึงค่าของตัวแปรตามในช่วงเวลาก่อนหน้า p

$y'(t-1), y'(t-2), \dots, y'(t-p)$ แทนค่าของตัวแปรตามในช่วงเวลาก่อนหน้า p

$e_t, e_{(t-1)}, \dots, e_{(t-p)}$ แทนค่าความผิดพลาด (Residuals) ในช่วงเวลา t และช่วงเวลาก่อนหน้า p

$\theta_1, \theta_2, \dots, \theta_q$ แทนพารามิเตอร์ของโมเดล Moving Average (MA) ซึ่งหมายถึงค่าของความผิดพลาดในช่วงเวลาก่อนหน้า q

2.1.2 วิธีการเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นกระบวนการที่ระบบคอมพิวเตอร์สามารถเรียนรู้และปรับปรุงด้วยตนเองจากประสบการณ์โดยไม่ต้องโดยชัดเจนต่อการโปรแกรมมาก่อนหน้า โดยกระบวนการของการเรียนรู้ของเครื่อง มีองค์ประกอบหลักอยู่สามประการ ดังนี้

1) ข้อมูล เป็นสิ่งที่ระบบคอมพิวเตอร์จะเรียนรู้ ข้อมูลถูกนำไปในระบบและใช้เพื่อสร้างแบบจำลอง (Model) ซึ่งจะใช้ในการเรียนรู้และการทำนาย

2) แบบจำลอง เป็นโครงสร้างหรืออัลกอริทึมที่ใช้ในการเรียนรู้จากข้อมูล แบบจำลองอาจมีลักษณะต่าง ๆ ขึ้นอยู่กับประเภทของปัญหาและการใช้งาน เช่น สร้างแบบจำลองแบบมีการดูแล (Supervised Machine Learning) หรือการสร้างแบบจำลองแบบไม่มีการดูแลหรือไม่ต้องมีการสอน (Unsupervised Learning)

3) การปรับแต่งและการทดสอบ เป็นกระบวนการที่ระบบคอมพิวเตอร์จะปรับปรุงแบบจำลองโดยใช้ข้อมูลการฝึกอย่างต่อเนื่อง และทดสอบประสิทธิภาพของแบบจำลองด้วยข้อมูลที่ไม่เคยเห็นมาก่อน เพื่อตรวจสอบว่าแบบจำลองทำงานได้ดีและสามารถใช้งานได้จริงในสภาพแวดล้อมที่แตกต่างกันได้ดีแค่ไหน

วิธีการเรียนรู้ของเครื่อง (Machine Learning Methods) สามารถแบ่งออกเป็นสามหมวดหลักได้ ดังนี้ การเรียนรู้แบบมีการดูแล (Supervised Machine Learning) นิยามตัวเองด้วยการใช้ชุดข้อมูลที่มีเลเบล (Labeled Datasets) เพื่อฝึกอัลกอริทึมให้สามารถจำแนกประเภทข้อมูลหรือทำนายผลลัพธ์ได้อย่างแม่นยำ ข้อมูลนำเข้าจะถูกส่งเข้าไปในโมเดลและโมเดลจะปรับน้ำหนักจนกว่าจะถูกปรับไปอย่างเหมาะสม ขั้นตอนนี้เกิดขึ้นในกระบวนการ Cross Validation เพื่อให้แน่ใจว่าโมเดลหลักเล็งประสิทธิภาพที่มากเกินไป (Over-fitting) หรือประสิทธิภาพต่ำเกินไป (Underfitting) โดยวิธีที่ใช้ในการเรียนรู้แบบมีการดูแล มีดังนี้ Neural Networks, Naive Bayes, Linear Regression, Logistic Regression, Random Forest, และ Support Vector Machine (SVM)

การเรียนรู้แบบไม่มีการดูแลหรือไม่ต้องมีการสอน (Unsupervised Machine Learning) ใช้อัลกอริทึมเรียนรู้ของเครื่องในการวิเคราะห์และจัดกลุ่มข้อมูลที่ไม่มีเลเบล (Unlabeled Datasets) เพื่อค้นพบรูปแบบที่ซ่อนอยู่หรือการจัดกลุ่มข้อมูลโดยไม่ต้องมีการเข้ามาเกี่ยวข้องของมนุษย์ ความสามารถของวิธีนี้ในการค้นพบความคล้ายคลึงและความแตกต่างในข้อมูลทำให้มันเหมาะสำหรับการวิเคราะห์ข้อมูลเพื่อค้นความคล้ายคลึง (Exploratory Data Analysis), กลยุทธ์การขายสินค้าร่วม, การแบ่งกลุ่มลูกค้า, และการระบุรูปแบบและรูปภาพ อีกทั้งยังใช้ในการลดจำนวนคุณสมบัติในโมเดลผ่านกระบวนการลดขนาดมิติ (PCA) และการแยกค่าไอเกียม (SVD) เป็นวิธีการทั่วไปสำหรับนี้ โดยวิธีที่ใช้ในการเรียนรู้แบบไม่มีการดูแล มีดังนี้ Neural Networks, K-Means Clustering, และ Probabilistic Clustering Methods

การเรียนรู้แบบลองหาข้อมูลเอง (Semi-Supervised Learning) การเรียนรู้แบบลองหาข้อมูลเองเสนอความสมดุลที่ดีระหว่างการเรียนรู้แบบมีการดูแลและการเรียนรู้แบบไม่มีการดูแล ในระหว่างการฝึกอบรม วิธีนี้จะใช้ชุดข้อมูลที่มีเลเบล (Labeled Datasets) เล็กน้อยเพื่อควบคุมการจำแนกประเภทและการสกัดคุณลักษณะจากชุดข้อมูลที่มีเลเบลมากขึ้น การเรียนรู้แบบลองหาข้อมูลเองสามารถ [3]

2.1.2.1 ทฤษฎีแบบจำลอง Multi-Layer Perceptron (MLP)


Multi-Layer Perceptron หรือ MLP เป็นประเภทหนึ่งของเครือข่ายประสาทเทียม (Artificial Neural Network - ANN) ที่ประกอบด้วยหลายชั้นของเซลล์ประสาท เซลล์ประสาทใน MLP มักใช้ฟังก์ชันการกระตุ้นที่ไม่เป็นเชิงเส้น ทำให้เครือข่ายสามารถเรียนรู้รูปแบบที่ซับซ้อนได้ MLP มีความสำคัญในการเรียนรู้ของเครื่องเพราะสามารถเรียนรู้ความสัมพันธ์ที่ไม่เป็นเชิงเส้นในข้อมูล ทำให้เป็นโมเดลที่มีประสิทธิภาพสำหรับงานต่าง ๆ เช่น การจำแนกประเภท (Classification) การถดถอย (Regression) และการรับรู้รูปแบบ (Pattern Recognition)

MLP เป็นหนึ่งในรูปแบบเครือข่ายประสาทเทียม (Neural Network) ชนิดฟีดฟอร์เวิร์ด (Feed-forward Neural Network) ที่นิยมใช้อย่างแพร่หลาย โดยโครงสร้างของ MLP ประกอบด้วย ชั้นนำเข้า (Input Layer), ชั้นซ่อน (Hidden Layer) อย่างน้อยหนึ่งชั้น และชั้นนำออก (Output Layer) ซึ่งในแต่ละชั้นซ่อนจะมีนิวรอนจำนวนหนึ่งซึ่งรับข้อมูลนำเข้า คูณด้วยน้ำหนักของการเชื่อมโยง จากนั้นผ่านฟังก์ชันแปลงสัญญาณ (Activation Function) เช่น Sigmoid หรือ ReLU ก่อนส่งต่อไปยังชั้นถัดไป [4]

ซึ่งปัจจุบัน MLP ได้รับความนิยมในการประยุกต์ใช้งานด้านต่าง ๆ รวมถึงการจัดการกับข้อมูลอนุกรมเวลา (Time Series) มีงานวิจัยในช่วงปี 2022-2023 ได้นำ MLP มาประยุกต์ใช้ เช่น Chen et al. (2022) ใช้ MLP ร่วมกับเทคนิค Attention ในการพยากรณ์อนุกรมเวลาด้านสภาพอากาศ พบว่าสามารถให้ผลการพยากรณ์ที่แม่นยำกว่าวิธีดั้งเดิม [5]

ข้อได้เปรียบของ MLP คือความสามารถในการประมวลผลข้อมูลที่ซับซ้อน โดยการเพิ่มจำนวนชั้นซ่อนและปรับค่าน้ำหนักการเชื่อมโยงอย่างเหมาะสม อย่างไรก็ตาม การเพิ่มจำนวนชั้นซ่อนจะทำให้ปริมาณการคำนวณเพิ่มขึ้น รวมถึงอาจเกิดปัญหาการค่าที่ดีเกินกว่าประสิทธิภาพ (Over-fitting) ดังนั้น การออกแบบโครงสร้างของ MLP จึงต้องคำนึงถึงสมดุลระหว่างความซับซ้อนและประสิทธิภาพ

ภาพตัวอย่างโครงสร้าง Multi-layer Perceptron (MLP) เครือข่ายประสาทเทียมแบบฟีดฟอร์เวิร์ดสำหรับงานเรียนรู้ของเครื่อง ดังภาพประกอบที่ 2



ภาพประกอบ 2 โครงสร้าง Multi-Layer Perceptron (MLP) เครือข่ายประสาทเทียมแบบฟีดฟอร์เวิร์ดสำหรับงานเรียนรู้ของเครื่อง

ที่มา: (What Is a Multilayer Perceptron (MLP) or a Feedforward Neural Network (FNN)? - AIML.Com, n.d.)

Multi-Layer Perceptron (MLP) คือโครงข่ายประสาทเทียมที่ประกอบด้วยชั้นนำเข้า (Input Layer), ชั้นซ่อน (Hidden Layer) อย่างน้อยหนึ่งชั้น และชั้นนำออก (Output Layer) โดยนิรอนในแต่ละชั้นจะมีการเชื่อมต่อกับนิรอนในชั้นถัดไป การคำนวณในแต่ละนิรอนนั้นประกอบด้วยการทำ weighted sum ของอินพุต ดังสมการ

$$z_j = \sum_{i=1}^n w_{ij}x_i + b_j$$

โดยที่

z_j แทนค่าผลรวมถ่วงน้ำหนัก (Weighted Sum) ของนิรอนที่ j

w_{ij} แทนค่าน้ำหนัก (Weight) ที่เชื่อมต่อกับนิรอนที่ i ในชั้นก่อนหน้าและนิรอนที่ j ในปัจจุบัน

x_i แทนค่า Input ของนิรอนที่ j

b_j แทนค่า Input ของนิวรอนที่ i

จากนั้นค่าผลรวมถ่วงน้ำหนักนี้จะถูกส่งผ่านฟังก์ชันการกระตุ้น (Activation Function) เช่น ReLU, Sigmoid หรือ Tanh เพื่อให้ได้ค่าผลลัพธ์ ดังสมการ

$$a_j = f(z_j)$$

โดยที่

a_j แทนค่าผลลัพธ์หลังการกระตุ้นของนิวรอนที่ j

f แทนฟังก์ชันการกระตุ้น

สำหรับการพยากรณ์ค่าต่อเนื่องใช้ฟังก์ชันการกระตุ้นแบบ Linear ในชั้น Output ซึ่งสามารถเขียนได้ดังสมการ

$$\hat{y} = a_k = z_k = \sum_{j=1}^m w_{kj}a_j + b_k$$

โดยที่

$\hat{y}$ แทนค่าพยากรณ์

w_{kj} แทนค่าน้ำหนักระหว่างนิวรอนใน Hidden Layer และ Output Layer

a_j แทนค่าผลลัพธ์หลังการกระตุ้นของนิวรอนใน Hidden Layer

b_k แทนค่าไบอัสของนิวรอนในชั้น Output

การฝึกอบรม (Training) ของ MLP ใช้กระบวนการ Backpropagation ซึ่งเป็นการคำนวณ Gradient ของ Loss Function เพื่อปรับค่าน้ำหนักและไบอัส (Bias) ให้เหมาะสมกับข้อมูล การฝึกอบรมนี้ใช้วิธีการ Gradient Descent ซึ่งอัปเดตค่าน้ำหนักดังสมการ

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} - n \frac{\partial L}{\partial w_{ij}}$$

โดยที่

$w_{ij}^{(t+1)}$ แทนค่าน้ำหนักที่อัปเดตแล้ว

$w_{ij}^{(t)}$ แทนค่าน้ำหนักก่อนอัปเดต

n แทนค่า Learning Rate

$\frac{\partial L}{\partial w_{ij}}$ แทนค่า gradient ของ Loss Function L ต่อด่าน้ำหนัก w_{ij}

2.1.3 การวัดประสิทธิภาพการพยากรณ์ของโมเดล

ในการวัดประสิทธิภาพการพยากรณ์ของโมเดลการพยากรณ์ความต้องการสินค้าโภคภัณฑ์โดยการพยากรณ์ราคาปิดของทุก ๆ สินค้า ผู้วิจัยใช้ตัวชี้วัด ดังต่อไปนี้

2.1.3.1 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ถูกทำรากที่สอง (Root Mean Squared Error - RMSE)

RMSE เป็นค่าที่ใช้วัดความแม่นยำของโมเดลการทำนายค่า ซึ่งคำนวณโดยการนำค่าความคลาดเคลื่อนกำลังสอง (Squared Error) ทั้งหมดมาเฉลี่ย แล้วทำรากที่สอง โดย RMSE เป็นการวัดความแม่นยำของโมเดลโดยพิจารณาถึงขนาดของความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น โดยไม่คำนึงถึงทิศทางของความคลาดเคลื่อน

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

โดยที่

n แทนจำนวนของตัวอย่าง (หรือข้อมูล) ทั้งหมดที่ใช้ในการคำนวณ MSE

y_i แทนค่าจริง (Actual Value) ของตัวอย่างที่ i

$\hat{y}_i$ แทนค่าทำนาย (Predicted Value) ของตัวอย่างที่ i

$(y_i - \hat{y}_i)^2$ แทนความคลาดเคลื่อนในรูปแบบของการยกกำลังสอง (Squared Error)

$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ แทนความคลาดเคลื่อนในรูปแบบของการยกกำลังสอง

2.1.3.2 ค่าเฉลี่ยค่าความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE)

ค่าเฉลี่ยค่าความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE) เป็นการวัดความคลาดเคลื่อนเฉลี่ยระหว่างค่าพยากรณ์และค่าจริง โดยคำนวณจากผลรวมของค่าความคลาดเคลื่อนสัมบูรณ์ทั้งหมดหารด้วยจำนวนข้อมูล หรือกล่าวอีกทางหนึ่งคือ เป็นการวัดขนาดของข้อผิดพลาดโดยไม่สนใจทิศทาง ถ้า MAE มีค่ามาก แสดงว่าโมเดลของมีประสิทธิภาพต่ำ

MAE คำนวณได้จากสมการดังนี้

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

โดยที่

n แทนจำนวนของตัวอย่าง (หรือข้อมูล) ทั้งหมดที่ใช้ในการคำนวณ MSE

y_i แทนค่าจริง (Actual Value) ของตัวอย่างที่ i

$\hat{y}_i$ แทนค่าทำนาย (Predicted Value) ของตัวอย่างที่ i
 $|y_i - \hat{y}_i|$ แทนความคลาดเคลื่อนในรูปแบบของค่าสัมบูรณ์ (Absolute Error)
 $\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$ แทนค่าเฉลี่ยของความคลาดเคลื่อนที่ได้จากการหาค่า
 สัมบูรณ์ของความแตกต่างระหว่างค่าจริงและค่าทำนายทุกตัวอย่างในชุดข้อมูลที่ใช้ในการฝึกหรือ
 ทดสอบโมเดล

2.1.3.3 ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error - MAPE)

MAPE เป็นค่าที่ใช้วัดความแม่นยำของโมเดลการทำนายค่า ซึ่งคำนวณโดยการ
 นำค่าความคลาดเคลื่อนสัมบูรณ์ทั้งหมดมาเฉลี่ย แล้วคูณด้วย 100% โดย MAPE เป็นการวัด
 ความแม่นยำของโมเดลโดยพิจารณาถึงขนาดของความคลาดเคลื่อนทั้งหมดที่เกิดขึ้น โดยไม่
 คำนึงถึงทิศทางของความคลาดเคลื่อน (บวกหรือลบ) MAPE มีค่ายิ่งต่ำยิ่งดี

MAPE คำนวณได้จากสมการดังนี้

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}$$

โดยที่

n แทนจำนวนของตัวอย่าง (หรือข้อมูล) ทั้งหมดที่ใช้ในการคำนวณ MSE

y_i แทนค่าจริง (Actual Value) ของตัวอย่างที่ i

$\hat{y}_i$ แทนค่าทำนาย (Predicted Value) ของตัวอย่างที่ i

$\frac{|y_i - \hat{y}_i|}{y_i}$ แทนความคลาดเคลื่อนในรูปแบบของเปอร์เซ็นต์ของค่าสัมบูรณ์

(absolute percentage error)

$$\frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \text{ แทนค่าเฉลี่ยของความคลาดเคลื่อนที่ได้จากการคำนวณ}$$

เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ทั้งหมด

2.2 งานวิจัยที่เกี่ยวข้อง

จากการศึกษางานวิจัยการวิเคราะห์วิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับ
 วิธีการเรียนรู้ของเครื่อง สามารถสรุปภาพรวมวิจัยที่ต้องการศึกษาได้ ดังตารางที่ 1-5

ตาราง 1 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวិธีการพยากรณ์ทางสถิติแบบดั้งเดิม^๒

No.	Paper Topics	Year	Objective	Data Source	Goal Standard	Model Techniques
¹	Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods	2018	To enhance electric energy demand forecasts.	Using monthly electric energy consumption time series from different countries.	To improve the forecast accuracy of the demand for energy end-use services in both developed and developing countries.	Bootstrap aggregating (Bagging) and forecasting methods
²	Decomposition and forecasting time series in the business economy using prophet forecasting model	2019	To identify seasonal trends in revenue development in a selected e-commerce segment.	The e-commerce subject selected is active primarily in the field of sales of professional outdoor supplies and organizing outdoor educational courses, seminars, and competitions.	The goal is to provide a two-year forecast.	Python Prophet

ตาราง 2 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวិธีการพยากรณ์ทางสถิติแบบดั้งเดิม (ต่อ)

No.	Paper Topics	Year	Objective	Data Source	Goal Standard	Model Techniques
3	Combining forecasts of ARIMA and exponential smoothing model	2019	To improve forecast accuracy by combining ARIMA and exponential smoothing models.	Not specified in the summary.	Improved forecast accuracy.	ARIMA and exponential smoothing models.
4	Time series forecasting model for supermarket sales using FB-prophet	2021	To forecast sale prices applied by an Italian food wholesaler.	Sales history of a retail store.	To automate pricing tasks usually taken care by human workforce.	ARIMA models, Prophet, LSTM, and CNNs.

ตาราง 3 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวិธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (ต่อ)

No.	Paper Topics	Year	Objective	Data Source	Goal Standard	Model Techniques
5	A hybrid forecasting model using LSTM and Prophet for energy consumption with decomposition of time series data	2022	To propose an efficient forecasting framework by hybridizing the RNN model with Prophet.	Real-world energy consumption data of seven countries.	To improve the forecasting performance.	LSTM and Prophet.
6	Time-Series Forecasting of Seasonal Data Using Machine Learning Methods	2023	To build automatic real-time control systems using models for forecasting time series with seasonal variability.	Actual data from sensors of a monitoring system.	To obtain predictions with reasonable accuracy using limited history data sets.	SARIMA, Holt-Winters Exponential Smoothing, ETS, Prophet, XGBoost, and LSTM.

ตาราง 4 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวลีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (ต่อ)

No.	Paper Topics	Year	Objective	Data Source	Goal Standard	Model Techniques
7	Time-series analysis and Flood Prediction using a Deep Learning Approach	2022	To solve time series prediction problems using deep neural networks.	Meteorological data	To reduce computational and time complexity with high accuracy.	Gated Recurrent Networks (GRU), a variant of recurrent neural network model.
8	A comprehensive study and performance analysis of deep neural network-based approaches in wind time-series forecasting	2023	To explore the capabilities of machine learning for the probabilistic forecasting of fractional Brownian motion (fBm).	Meteorological parameters related to wind time-series.	To determine if the self-similarity property is preserved in a forecasting time series and which machine learning algorithms are the most effective.	Nonlinear autoregressive exogenous inputs (NARX), nonlinear input-output (NIO), and nonlinear autoregressive (NAR) neural network models.

ตาราง 5 สรุปภาพรวมงานวิจัยที่ทำการศึกษาวិธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (ต่อ)

No.	Paper Topics	Year	Objective	Data Source	Goal Standard	Model Techniques
9	Dynamic adaptive encoder-decoder deep learning networks for multivariate time series forecasting of building energy consumption	2023	To solve time series prediction problems using deep neural networks.	Meteorological data	To reduce computational and time complexity with high accuracy.	Gated Recurrent Networks (GRU), a variant of recurrent neural network model.
10	Are Transformers Effective for Time Series Forecasting?	2023	The paper questions the validity of Transformer-based solutions for the long-term time series forecasting (LTSF) task.	The paper uses nine real-life datasets for their experiments.	The goal is to explore the impacts of various design elements of LTSF models on their temporal relation extraction capability.	The paper uses Transformer-based solutions and a simple one-layer linear model named LTSF-Linear.

2.2.1 Forecasting Mid-Long Term Electric Energy Consumption Through Bagging ARIMA and Exponential Smoothing Methods [6]

งานวิจัยนี้มีวัตถุประสงค์เพื่อเพิ่มการคาดการณ์ความต้องการพลังงานไฟฟ้าโดยใช้อนุกรมเวลาการใช้พลังงานไฟฟ้ารายเดือนจากประเทศต่าง ๆ เป้าหมายคือการปรับปรุงความแม่นยำในการพยากรณ์ความต้องการบริการการใช้พลังงานปลายทางทั้งในประเทศที่พัฒนาแล้วและกำลังพัฒนา วิธีที่ใช้ในการศึกษาค้นคว้าครั้งนี้ ได้แก่ วิธี Bootstrap Aggregating (Bagging) และวิธีการคาดการณ์ (Forecasting Methods)

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับงานวิจัยของผู้ศึกษาวิจัยเนื่องจากใช้วิธีการพยากรณ์ทางสถิติแบบดั้งเดิม อย่าง Autoregressive Integrated Moving Average (ARIMA) ซึ่งผู้ศึกษาวิจัยกำลังเปรียบเทียบกับวิธีการเรียนรู้ของเครื่องในการวิจัย

2.2.2 Decomposition and Forecasting Time Series In The Business Economy Using Prophet Forecasting Model [7]

จุดประสงค์ของการศึกษาค้นคว้าคือเพื่อระบุแนวโน้มตามฤดูกาลในการพัฒนารายได้ในกลุ่มอีคอมเมิร์ซที่เลือก ประเภทอีคอมเมิร์ซที่เน้นนั้นเกี่ยวกับการขายอุปกรณ์กลางแจ้งระดับมืออาชีพระดับหลัก และการจัดหลักสูตรการศึกษา การสัมมนา และการแข่งขันกลางแจ้ง เป้าหมายคือการจัดทำการคาดการณ์สองปี วิธีที่ใช้ในการศึกษาค้นคว้าคือแบบจำลอง Python Prophet โมเดลนี้เป็นขั้นตอนสำหรับการคาดการณ์ข้อมูลอนุกรมเวลาโดยอิงจากแบบจำลองเพิ่มเติม ซึ่งแนวโน้มที่ไม่เชิงเส้นสอดคล้องกับฤดูกาลรายปี รายสัปดาห์ และรายวัน รวมถึงผลกระทบในวันหยุด แม้ว่าการค้นพบที่เฉพาะเจาะจงไม่ได้กล่าวถึงในบทสรุป แต่ก็สามารถสรุปได้ว่าการศึกษาค้นคว้าสามารถระบุแนวโน้มตามฤดูกาลได้สำเร็จ และให้การคาดการณ์สองปีสำหรับกลุ่มอีคอมเมิร์ซที่เลือกโดยใช้แบบจำลอง Prophet

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับงานวิจัยของผู้ศึกษาวิจัยเนื่องจากใช้วิธีการพยากรณ์สมัยใหม่ (Prophet) ซึ่งสามารถนำมาเปรียบเทียบกับวิธีการดั้งเดิมอย่าง ARIMA, เอกซ์โปเนนเชียล และวิธีการเรียนรู้ของเครื่องอื่น ๆ นอกจากนี้ยังมุ่งเน้นไปที่การคาดการณ์อุปสงค์ในภาคอีคอมเมิร์ซซึ่งเป็นการคาดการณ์อุปสงค์สินค้าโภคภัณฑ์ประเภทหนึ่ง การใช้ Prophet สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิผลและการบังคับใช้ในการพยากรณ์อุปสงค์สินค้าโภคภัณฑ์

2.2.3 Combining Forecasts of ARIMA and Exponential Smoothing Model [8]

การศึกษาค้นคว้านี้มีวัตถุประสงค์เพื่อปรับปรุงความแม่นยำในการพยากรณ์โดยการรวมโมเดล ARIMA ซึ่งเป็นวิธีการคาดการณ์อนุกรมเวลาแบบดั้งเดิมทั้ง และการศึกษาค้นคว้าวัตถุประสงค์

เพื่อสำรวจว่าการรวมกันของวิธีเหล่านี้สามารถนำไปสู่การคาดการณ์ที่แม่นยำมากยิ่งขึ้น วิธีที่ใช้ในการศึกษานี้คือ ARIMA ข้อที่ค้นพบในการศึกษานี้สรุปได้ว่าการรวมกันของ ARIMA และแบบจำลองแบบเอกซ์โปเนนเชียลนำไปสู่ความแม่นยำในการคาดการณ์ที่ดีขึ้น

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับการวิจัยของผู้ศึกษา เนื่องจากการสำรวจการผสมผสานระหว่างวิธีการพยากรณ์แบบดั้งเดิม 1 วิธี คือ ARIMA ซึ่งผู้วิจัยนั้นกำลังเปรียบเทียบวิธีเหล่านี้กับวิธีการเรียนรู้ของเครื่องในการวิจัยครั้งนี้ของผู้ศึกษาวิจัย ผลการศึกษานี้สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของการผสมผสานวิธีการแบบดั้งเดิม และการเปรียบเทียบกับวิธีการเรียนรู้ของเครื่องในแง่ของความแม่นยำในการคาดการณ์

2.2.4 Time Series Forecasting Model for Supermarket Sales Using FB-Prophet [9]

จุดประสงค์ของการศึกษานี้คือเพื่อคาดการณ์ราคาขายที่ใช้โดยผู้ค้าส่งอาหารในอิตาลีเป้าหมายคือทำให้งานการกำหนดราคาซึ่งปกติแล้วดูแลโดยบุคคลากรที่เป็นมนุษย์เป็นไปโดยอัตโนมัติ ระบบอัตโนมัตินี้คาดว่าจะปรับปรุงประสิทธิภาพและความแม่นยำในการกำหนดราคา ซึ่งเป็นสิ่งสำคัญในอุตสาหกรรมค้าปลีก วิธีที่ใช้ในการศึกษานี้ประกอบด้วยแบบจำลอง ARIMA, FB Prophet, LSTM และ CNNs เป็นการผสมผสานระหว่างวิธีการทางสถิติแบบดั้งเดิม (ARIMA) เครื่องมือพยากรณ์สมัยใหม่ (FB Prophet) และวิธีการเรียนรู้เชิงลึก (LSTM และ CNN) การใช้วิธีการที่หลากหลายทำให้เกิดแนวทางการพยากรณ์ที่ครอบคลุม แม้ว่าการค้นพบที่เฉพาะเจาะจงไม่ได้กล่าวถึงในบทสรุป แต่ก็สามารถอนุมานได้ว่าการศึกษานี้พบว่าเครื่องมือ FB Prophet มีประสิทธิภาพในการพยากรณ์ยอดขายในซูเปอร์มาร์เก็ตการวิจัยสรุปว่า FB Prophet เป็นโมเดลการพยากรณ์ที่ดีกว่าในแง่ของข้อผิดพลาดต่ำ มีการพยากรณ์ที่ดีกว่าและความเหมาะสมที่ดีกว่า

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับการวิจัยของผู้ศึกษา เนื่องจากการสำรวจการใช้วิธีการเรียนรู้แบบดั้งเดิมและวิธีการเรียนรู้ของเครื่องในการพยากรณ์ ซึ่งสอดคล้องกับหัวข้อการวิจัยของผู้ศึกษาวิจัย ผลการศึกษานี้สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของวิธีการเหล่านี้ในการคาดการณ์ความต้องการสินค้าโภคภัณฑ์ โดยเฉพาะในบริบทของการขายในซูเปอร์มาร์เก็ต

2.2.5 A Hybrid Forecasting Model Using LSTM and Prophet for Energy Consumption with Decomposition of Time Series Data [10]

การศึกษานี้เพื่อเสนอการคาดการณ์ที่มีประสิทธิภาพโดยการผสมผสานโมเดลโครงข่ายประสาทเทียมที่ลึก (RNN) กับ Prophet เป้าหมายคือการปรับปรุงประสิทธิภาพการคาดการณ์ข้อมูลการใช้พลังงานบนโลกทั้งหมดของ 7 ประเทศในช่วงสิบปี วิธีที่ใช้ในการศึกษานี้คือ Long Short-Term Memory (LSTM) และ Prophet โดย LSTM เป็น RNN ประเภทหนึ่ง

สามารถเรียนรู้การพึ่งพาระยะยาวซึ่งทำให้เหมาะสำหรับการพยากรณ์อนุกรมเวลา ในการศึกษาทั้งสองวิธีนี้ถูกรวมเข้าด้วยกันเพื่อปรับปรุงความแม่นยำในการคาดการณ์ พบว่า การผสมข้ามสายพันธุ์ระหว่างแบบจำลอง LSTM และ Prophet นำไปสู่การปรับปรุงประสิทธิภาพการคาดการณ์ที่ดีขึ้นกว่าการใช้เพียง LSTM หรือ Prophet อย่างเดียว

นอกจากนี้ การวิจัยนี้ยังได้เปรียบเทียบโมเดลใหม่กับเทคนิคที่ดีที่สุดที่มีอยู่ในปัจจุบัน เช่น ARIMA, SVR, วิธี Holt-Winters, EMD-LSTM และ EMD-GRU ผลการวิจัยพบว่าแบบจำลองใหม่ให้การคาดการณ์ได้ดีกว่าเทคนิคเหล่านี้สำหรับบางประเทศ สำหรับประเทศอื่นๆ โมเดลใหม่ของพวกเขาก็ดีพอๆ กับเทคนิคเหล่านี้

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับงานวิจัยของผู้วิจัย เนื่องจากการสำรวจการใช้วิธีการเรียนรู้ของเครื่องและเครื่องมือพยากรณ์สมัยใหม่ (Prophet) ในการพยากรณ์ซึ่งสอดคล้องกับหัวข้อวิจัย ผลการศึกษานี้สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของวิธีการเหล่านี้ในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์ โดยเฉพาะในบริบทของการใช้พลังงาน

2.2.6 Time-Series Forecasting of Seasonal Data Using Machine Learning

Methods [11]

การศึกษานี้มีวัตถุประสงค์เพื่อสร้างระบบควบคุมแบบเรียลไทม์อัตโนมัติโดยใช้แบบจำลองสำหรับการคาดการณ์อนุกรมเวลาที่มีความแปรปรวนตามฤดูกาล เป้าหมายคือเพื่อให้ได้การคาดการณ์ที่มีความแม่นยำพอสมควรโดยใช้ชุดข้อมูลประวัติที่จำกัด วิธีที่ใช้ในการศึกษาคือ SARIMA, Holt-Winters Exponential Smoothing, ETS, Prophet, XGBoost และ LSTM เป็นการผสมผสานระหว่างวิธีการทางสถิติแบบดั้งเดิม (SARIMA, Holt-Winters Exponential Smoothing, ETS), เครื่องมือพยากรณ์สมัยใหม่ (Prophet, XGBoost) และวิธีการเรียนรู้เชิงลึก (LSTM) การใช้วิธีการที่หลากหลายทำให้เกิดแนวทางการพยากรณ์ที่ครอบคลุม ผลการศึกษาแสดงให้เห็นว่าแนวทางที่นำเสนอ ซึ่งใช้ตัวอย่างข้อมูลในอดีตขนาดเล็กเพื่อสร้างการคาดการณ์ในระยะสั้น มีประสิทธิภาพในการลดภาระในทรัพยากรการประมวลผล ในขณะเดียวกันก็รักษาความแม่นยำของการประมาณการไว้ เป็นสิ่งสำคัญอย่างยิ่งสำหรับระบบควบคุมอัตโนมัติแบบเรียลไทม์ที่ใช้งานบนอุปกรณ์ฝังตัวในบรรดาวิธีการต่างๆ ที่ทดสอบ วิธี XGBoost ทำงานได้ดีที่สุดตามชุดคุณลักษณะ อย่างไรก็ตาม ด้วยการเพิ่มประสิทธิภาพของอัลกอริทึมสำหรับการค้นหาพารามิเตอร์โมเดล อัลกอริทึมอื่นๆ เช่น LSTM อาจทำงานได้ดีขึ้น

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับงานวิจัยของผู้วิจัย เนื่องจากการสำรวจการใช้วิธีการเรียนรู้แบบดั้งเดิมและวิธีการเรียนรู้ของเครื่องในการพยากรณ์ ซึ่งสอดคล้องกับหัวข้อการวิจัยที่กำลังศึกษา ผลการศึกษานี้สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของวิธีการเหล่านี้ในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์

2.2.7 Time-Series Analysis and Flood Prediction Using A Deep Learning Approach [12]

จุดประสงค์ของการศึกษานี้เพื่อแก้ปัญหาการพยากรณ์อนุกรมเวลาโดยใช้โครงข่ายประสาทเทียมเชิงลึก เป้าหมายคือการลดความซับซ้อนในการคำนวณและเวลาด้วยความแม่นยำสูง วิธีที่ใช้ในการศึกษานี้คือ Gated Recurrent Networks (GRU) ซึ่งเป็นรูปแบบหนึ่งของโมเดลโครงข่ายประสาทที่เกิดซ้ำ GRU เป็น RNN ประเภทหนึ่งที่สามารถใช้ข้อมูลในอดีตเพื่อการคาดการณ์ได้อย่างมีประสิทธิภาพ และเร็วกว่าในแง่ของความเร็วในการเทรน

สิ่งที่พบในการวิจัยนี้ สรุปได้ว่าอัลกอริทึมการเรียนรู้เชิงลึก เช่น Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM) และ Gated Recurrent Units (GRU) สามารถระบุรูปแบบและแนวโน้มในข้อมูลที่ไม่ใช่เชิงเส้นได้อย่างมีประสิทธิภาพ ซึ่งมีประโยชน์อย่างยิ่งเมื่อขาดความเข้าใจเกี่ยวกับโดเมนสำหรับการสำรวจฟีเจอร์ (Feature Introspection) โดยผู้วิจัยได้พัฒนาวิธีการเรียนรู้เชิงลึกแบบใหม่ RNN-GRU เพื่อค้นหารูปแบบในข้อมูล และใช้ข้อมูลในอดีตเพื่อคาดการณ์ข้อมูลใหม่ได้อย่างแม่นยำ เนื่องจากแบบจำลองที่นำเสนอสามารถประมาณการเกิดน้ำท่วมได้ดี ด้วยการพิจารณาจากปริมาณน้ำฝนเป็นปัจจัยที่มีอิทธิพลมากที่สุด อีกทั้งการคาดการณ์ด้วยอัลกอริทึมการเรียนรู้เชิงลึกสามารถช่วยป้องกัน การเตรียมพร้อม การตอบสนอง และการฟื้นตัวจากการฟื้นตัวจากภัยพิบัติน้ำท่วม

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับการวิจัยในครั้งนี้ เนื่องจากเป็นการสำรวจการใช้วิธีการเรียนรู้ของเครื่อง ในการพยากรณ์ ซึ่งสอดคล้องกับหัวข้อการวิจัยของผู้วิจัย ผลการศึกษานี้สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของวิธีนี้ในการพยากรณ์อุปสงค์สินค้าโภคภัณฑ์

2.2.8 A Comprehensive Study and Performance Analysis of Deep Neural Network-Based Approaches in Wind Time-Series Forecasting [13]

งานวิจัยนี้เปรียบเทียบประสิทธิภาพของสถาปัตยกรรมการเรียนรู้เชิงลึกต่าง ๆ รวมถึงโครงข่ายประสาทเทียมที่เกิดซ้ำ (RNN) โครงข่ายประสาทแบบคอนโวลูชัน (CNN) และโมเดล Restricted Boltzmann Machine (RBM) กับวิธีการทางสถิติแบบดั้งเดิม โดยในงานวิจัยนี้ใช้ชุดข้อมูลขนาดใหญ่ของการวัดความเร็วลมจากฟาร์มกังหันลมที่แตกต่างกันสามแห่งเพื่อฝึกและประเมินแบบจำลอง ชุดข้อมูลประกอบด้วยข้อมูลความเร็วลมในอดีต รวมถึงคุณลักษณะด้านอุตุนิยมวิทยา เช่น อุณหภูมิ ความดัน และทิศทางลม และใช้ตัวชี้วัดประสิทธิภาพที่หลากหลาย รวมถึงค่า Mean Squared Error (MSE) และ Root Mean Squared Error (RMSE) เพื่อประเมินความแม่นยำของแบบจำลอง พบว่าโมเดลการเรียนรู้เชิงลึกมีประสิทธิภาพเหนือกว่าวิธีการทางสถิติแบบดั้งเดิมในการพยากรณ์ความเร็วลม โมเดลที่มีประสิทธิภาพดีที่สุดคือโมเดล RNN-CNN

แบบไฮบริดที่รวมข้อมูลทั้งเชิงเวลาและเชิงพื้นที่ไว้ด้วยกัน อีกทั้งผู้เขียนยังพบว่าคุณสมบัติความคล้ายคลึงกันในตัวเอง (Self-Similarity) ของ fBm ยังคงอยู่ในอนุกรมเวลาการพยากรณ์

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับการวิจัยของผู้วิจัยในครั้งนี้อย่างยิ่ง เนื่องจากจะทำให้ภาพรวมที่ครอบคลุมในการพยากรณ์ความเร็วลมด้วยการเรียนรู้เชิงลึก ผลการวิจัยของผู้เขียนชี้ให้เห็นว่าโมเดลการเรียนรู้เชิงลึกสามารถบรรลุความแม่นยำสูงในการพยากรณ์ความเร็วลม แม้ในสภาวะที่มีความไม่แน่นอนและไม่เชิงเส้นก็ตาม

2.2.9 Dynamic Adaptive Encoder-Decoder Deep Learning Networks For Multivariate Time Series Forecasting of Building Energy Consumption [14]

งานวิจัยมีวัตถุประสงค์ เพื่อพัฒนาโมเดลการเรียนรู้เชิงลึกสำหรับการคาดการณ์การใช้พลังงานในอาคารโดยใช้ข้อมูลอุตุนิยมวิทยา ผู้เขียนได้เสนอแบบจำลองใหม่ที่ใช้ Gated Recurrent Networks (GRUs) และสามารถปรับตัวเข้ากับการเปลี่ยนแปลงของการกระจายข้อมูลที่อยู่เบื้องหลัง โดยได้เสนอแบบจำลอง Dynamic Adaptive Encoder-Decoder (DADE) ใหม่สำหรับการคาดการณ์การใช้พลังงานในอาคารโดยใช้ข้อมูลอุตุนิยมวิทยาเปรียบเทียบกับโมเดลการคาดการณ์อื่น ๆ ที่หลากหลาย รวมถึงโมเดลทางสถิติแบบดั้งเดิมและโมเดลการเรียนรู้เชิงลึก พบว่าโมเดล DADE มีประสิทธิภาพเหนือกว่าโมเดลอื่น ๆ ทั้งหมดในแง่ของความแม่นยำในการพยากรณ์

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับการวิจัยของผู้วิจัย เนื่องจากนำเสนอโมเดลการเรียนรู้เชิงลึกแบบใหม่สำหรับการคาดการณ์การใช้พลังงานในอาคาร โมเดล DADE สามารถบรรลุความแม่นยำในการคาดการณ์สูง และสามารถปรับให้เข้ากับการเปลี่ยนแปลงในการกระจายข้อมูลพื้นฐานได้ แม้ว่าการวิจัยฉบับนี้จะมุ่งเน้นเฉพาะการคาดการณ์การใช้พลังงานในอาคาร แต่โมเดล DADE ที่เสนอสามารถนำไปใช้เพื่อคาดการณ์ข้อมูลแบบเวลาอื่น ๆ รวมถึงความต้องการสินค้าโภคภัณฑ์ได้เช่นกัน โมเดล DADE เหมาะเป็นพิเศษสำหรับการคาดการณ์ความต้องการสินค้าโภคภัณฑ์ เนื่องจากสามารถปรับตัวเข้ากับการเปลี่ยนแปลงของการกระจายข้อมูลที่อยู่เบื้องหลัง ความต้องการสินค้าโภคภัณฑ์เป็นปรากฏการณ์ที่ซับซ้อน ได้รับอิทธิพลจากปัจจัยหลายประการ เช่น ภาวะเศรษฐกิจ ความก้าวหน้าทางเทคโนโลยี และภัยธรรมชาติ โมเดล DADE สามารถเรียนรู้ปัจจัยเหล่านี้และปรับแต่งโมเดลการคาดการณ์ให้เหมาะสม

2.2.10 Are Transformers Effective for Time Series Forecasting? [15]

งานวิจัยนี้ศึกษาประสิทธิภาพของโมเดล Transformer สำหรับการคาดการณ์ข้อมูลแบบเวลาในระยะยาว (LTSF) โดยใช้ข้อมูลทั้งหมด 9 ชุด เพื่อประเมินประสิทธิภาพของโมเดล Transformer กับโมเดล LTSF-Linear และใช้เมตริกต่าง ๆ เพื่อประเมินประสิทธิภาพ เช่น Mean

Squared Error (MSE) และ Mean Absolute Error (MAE) พบว่าโมเดล Transformer ประสบความสำเร็จมากกว่า LTSF-Linear ในบางชุดข้อมูลเท่านั้น อีกทั้งยังพบว่าโมเดล Transformer มีความอ่อนไหวต่อความยาวของลำดับข้อมูลมากกว่า LTSF-Linear

งานวิจัยฉบับนี้มีความเกี่ยวข้องกับการวิจัยของผู้วิจัยเกี่ยวกับการวิเคราะห์เชิงเปรียบเทียบระหว่างวิธีการแบบดั้งเดิมและวิธีการเรียนรู้เชิงลึกในการคาดการณ์ความต้องการสินค้าโภคภัณฑ์ เนื่องจากให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของโมเดล Transformer ในงานการคาดการณ์ข้อมูลแบบเวลาในระยะยาว แม้ผลการวิจัยของผู้เขียนแนะนำว่าโมเดล Transformer อาจไม่ใช่ตัวเลือกที่ดีที่สุดสำหรับการคาดการณ์ความต้องการสินค้าโภคภัณฑ์เนื่องจากเป็นงานการคาดการณ์ในระยะยาว แต่ก็ยังคงเป็นประโยชน์ในการศึกษาเพิ่มเติม

2.2.11 Tsmixer: An All-MLP Architecture For Time Series Forecasting [5]

งานวิจัยนี้นำเสนอ Time-Series Mixer (TSMixer) ซึ่งเป็นสถาปัตยกรรมใหม่สำหรับการพยากรณ์อนุกรมเวลา โดยอาศัยการเรียนรู้ของ Multi-Layer Perceptron (MLPs) มีการออกแบบเฉพาะเพื่อจัดการกับข้อมูลอนุกรมเวลาแบบพหุตัวแปร ซึ่งมีความซับซ้อนสูง

ในอดีตมีการนำเครือข่ายประสาทเทียมแบบลำดับ (Recurrent) หรือแบบมีกลไกการจดจำ (Attention-based) มาใช้ในการจัดการกับความซับซ้อนดังกล่าว อย่างไรก็ตาม งานวิจัยก่อนหน้านี้พบว่า แม้แต่แบบจำลองเชิงเส้นอย่างง่ายสำหรับข้อมูลหนึ่งตัวแปร ก็สามารถให้ประสิทธิภาพที่ดีกว่าแบบจำลองเรียนรู้เชิงลึกบางชนิดในการทดสอบด้วยชุดข้อมูลมาตรฐานทางวิชาการ

ดังนั้น งานวิจัยนี้จึงศึกษาศักยภาพของแบบจำลองเชิงเส้นสำหรับการพยากรณ์อนุกรมเวลา โดยเสนอสถาปัตยกรรม TSMixer ซึ่งมีการผสมผสานข้อมูลในมิติของเวลาและมิติของรายการ เพื่อสกัดข้อมูลได้อย่างมีประสิทธิภาพ ด้วยการวางซ้อนกันของ MLPs หลายชั้น

ผลการทดสอบบนชุดข้อมูลมาตรฐานทางวิชาการที่เป็นที่นิยมพบว่า TSMixer ซึ่งสามารถนำไปใช้งานได้ง่าย มีประสิทธิภาพเทียบเท่ากับแบบจำลองล้ำสมัยที่เหมาะสมกับชุดข้อมูลเฉพาะนั้นๆ นอกจากนี้ เมื่อทดสอบบนชุดข้อมูล M5 ซึ่งเป็นชุดข้อมูลจริงขนาดใหญ่ด้านการค้าปลีก TSMixer แสดงให้เห็นถึงประสิทธิภาพที่เหนือกว่าทางเลือกอื่นๆ ที่เป็นสถานะปัจจุบัน

ผลการวิจัยนี้ย้ำถึงความสำคัญของการใช้ประโยชน์จากข้อมูลระหว่างตัวแปรและข้อมูลเสริมอย่างมีประสิทธิภาพ เพื่อปรับปรุงประสิทธิภาพการพยากรณ์อนุกรมเวลา นอกจากนี้ยังมีการวิเคราะห์เพิ่มเติมเพื่อแสดงให้เห็นถึงศักยภาพของ TSMixer โดยหลักการออกแบบของ TSMixer คาดว่าจะเปิดโอกาสใหม่สำหรับการพยากรณ์อนุกรมเวลาด้วยวิธีการเรียนรู้ของเครื่อง

บทที่ 3 การดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้แบ่งขั้นตอนดำเนินการวิจัย ดังนี้

- 3.1 แนวคิดและภาพรวมวิธีการวิจัย
- 3.2 เกี่ยวกับชุดข้อมูล
- 3.3 การสำรวจและวิเคราะห์ข้อมูล (Exploratory Data Analysis - EDA)
- 3.4 การสร้างแบบจำลองพยากรณ์

3.1 แนวคิดและภาพรวมวิธีการวิจัย

การพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์มีความสำคัญอย่างยิ่งในภาคการเกษตรและอุตสาหกรรมที่เกี่ยวข้อง เนื่องจากช่วยให้ผู้มีส่วนได้ส่วนเสียทุกฝ่าย ตั้งแต่เกษตรกร ผู้ผลิต ผู้ค้า และนักลงทุน สามารถวางแผนและตัดสินใจได้อย่างมีประสิทธิภาพมากขึ้น

วิธีการพยากรณ์ทางสถิติแบบดั้งเดิม เช่น Auto Regressive Integrated Moving Average (ARIMA) มักให้ผลการพยากรณ์ที่ดีเมื่อใช้กับข้อมูลที่มีความแน่นอนและรูปแบบที่ชัดเจน วิธีการเหล่านี้ทำงานได้ดีเมื่อข้อมูลมีแนวโน้มเสถียรและไม่มีความผันผวนสูง โมเดลพยากรณ์ทางสถิติแบบดั้งเดิมมักมีความซับซ้อนต่ำกว่าเมื่อเทียบกับโมเดลการเรียนรู้ของเครื่อง เนื่องจากมีจำนวนพารามิเตอร์ที่ต้องปรับแต่งน้อยกว่าและการสร้างและปรับแต่งโมเดลทำได้ง่าย และไม่ต้องใช้เวลามาก นอกจากนี้ โมเดลเหล่านี้ยังต้องการข้อมูลเชิงเวลาที่มีคุณภาพและปริมาณเพียงพอเพื่อทำการพยากรณ์

ในทางตรงกันข้าม วิธีการเรียนรู้ของเครื่อง (Machine Learning) อย่าง Multi-Layer Perceptron (MLP) มักจะมีความแม่นยำในการพยากรณ์สูงกว่า เนื่องจากสามารถจับรูปแบบที่ซับซ้อนได้ดีกว่า โมเดลการเรียนรู้ของเครื่องสามารถจัดการกับข้อมูลที่มีความผันผวนสูงและมีรูปแบบที่ซับซ้อนได้ดี อย่างไรก็ตาม โมเดลการเรียนรู้ของเครื่องมักมีความซับซ้อนสูงกว่าและต้องการการปรับแต่งที่ละเอียด เนื่องจากมีจำนวนพารามิเตอร์มาก การสร้างและปรับแต่งโมเดลอาจต้องใช้เวลามากและต้องการความเชี่ยวชาญทางด้านเทคนิค นอกจากนี้ วิธีการเรียนรู้ของเครื่องยังต้องการข้อมูลจำนวนมากและข้อมูลที่มีความหลากหลายเพื่อสร้างโมเดลที่มีความแม่นยำสูง

อย่างไรก็ตาม ในงานวิจัยนี้ได้ศึกษาเกี่ยวกับวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมด้วยวิธี ARIMA เปรียบเทียบกับวิธีการเรียนรู้ของเครื่องโดยใช้โมเดล MLP เพื่อพยากรณ์ความต้องการสินค้าโภคภัณฑ์ การศึกษาเปรียบเทียบวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมและวิธีการเรียนรู้ของเครื่องใน

การพยากรณ์ราคาปิดรายวันของสินค้าโภคภัณฑ์ โดยพิจารณาจากปัจจัยสำคัญคือความแม่นยำในการพยากรณ์ราคาปิดของแต่ละสินค้า

3.2 เกี่ยวกับชุดข้อมูล

โดยข้อมูลที่ใช้ในการศึกษาในครั้งนี้เป็นข้อมูลราคาปิดของสินค้าโภคภัณฑ์รายวันตั้งแต่วันที่ 3 มกราคม 2000 - 18 สิงหาคม 2023 ซึ่งชุดข้อมูลนี้ประกอบด้วยข้อมูลราคาสินค้าโภคภัณฑ์ที่หลากหลาย โดยเป็นข้อมูลราคาสินค้าโภคภัณฑ์จากเว็บไซต์ Yahoo Finance [16]

3.2.1 แหล่งที่มาของข้อมูล

ชุดข้อมูลนี้สามารถดาวน์โหลดได้จากเว็บไซต์ Kaggle ซึ่งเป็นเว็บไซต์สำหรับแบ่งปันข้อมูลแบบเปิด (Open Data)

Link: <https://www.kaggle.com/datasets/guillemservera/agricultural-futures>

คำอธิบายของคอลัมน์ข้อมูล:

Date: วันที่ที่บันทึกข้อมูล รูปแบบ: YYYY-MM-DD

Open: ราคาเปิดตลาดของวัน

High: ราคาสูงสุดที่ทำได้ระหว่างการซื้อขาย

Low: ราคาต่ำสุดที่ทำได้ระหว่างการซื้อขาย

Close: ราคาปิดตลาด

Volume: จำนวนสัญญาที่ซื้อขายในช่วงการซื้อขาย

Ticker: สัญลักษณ์ตัวย่อที่ใช้ในการซื้อขายสินค้าโภคภัณฑ์

Commodity: สินค้าโภคภัณฑ์เช่น โกโก้ กาแฟ ฝ้าย ไม้แปรรูป น้ำส้ม และน้ำตาล)

3.3 การสำรวจและวิเคราะห์ข้อมูล (Exploratory Data Analysis - EDA)

3.3.1 การตรวจสอบข้อมูล


เนื่องจากข้อมูลที่ใช้ในการวิจัยนี้เป็นข้อมูลอนุกรมเวลา (Time Series) ผู้วิจัยจึงได้ดำเนินการตรวจสอบประเภทข้อมูลของแต่ละคอลัมน์และแปลงคอลัมน์วันที่ให้เป็นดัชนี (Index) เพื่อให้ง่ายต่อการวิเคราะห์ข้อมูลอนุกรมเวลาในขั้นตอนถัดไป การดำเนินการนี้ช่วยให้ผู้วิจัยสามารถจัดการกับข้อมูลอนุกรมเวลาได้อย่างมีประสิทธิภาพและสามารถใช้เวลาที่มืออยู่ในการวิเคราะห์ข้อมูลอย่างมีประสิทธิภาพ โดยขั้นตอนแรกดำเนินการโหลดข้อมูลจากชุดข้อมูลที่นำมาศึกษาในครั้งนี้ ดังภาพประกอบที่ 3

```
# Import the time series data
df = pd.read_csv('/content/gdrive/My Drive/Colab Notebooks/Thesis/all_agricultural_products_data.csv', index_col='date')]
```

ภาพประกอบ 3 โหลดข้อมูลอนุกรมเวลาจากชุดข้อมูลที่ใช้ในการศึกษา

3.3.2 สํารวจการกระจายตัวของราคาและปริมาณการซื้อขายสำหรับสินค้าโภคภัณฑ์ของแต่ละชนิด

จากการวิเคราะห์เบื้องต้นด้วยการสร้างกราฟกระจายตัวของราคาปิดและปริมาณการซื้อขายสำหรับสินค้าโภคภัณฑ์หลัก 6 ชนิด ได้แก่ น้ำตาล โกโก้ กาแฟ ผัก ไม้แปรรูป และน้ำส้ม พบว่าแต่ละสินค้านี้มีลักษณะการกระจายตัวที่แตกต่างกัน โดยน้ำตาลมีการกระจายตัวของปริมาณการซื้อขายในช่วงกว้าง แสดงถึงความผันผวนสูง แต่ราคาปิดกระจายตัวในช่วงแคบ ในขณะที่โกโก้มีการกระจายตัวของราคาปิดในช่วงกว้างที่สุด แสดงถึงความผันผวนของราคาสูง ส่วนกาแฟและผักมีการกระจายตัวของปริมาณการซื้อขายในระดับใกล้เคียงกัน และราคาปิดกระจายตัวในช่วงแคบที่สุด ไม้แปรรูปและน้ำส้มมีการกระจายตัวของราคาปิดในช่วงแคบ แสดงถึงความผันผวนของราคาต่ำ ดังการแสดงผลกราฟการกระจายตัว ตามภาพประกอบที่ 4




ภาพประกอบ 4 การกระจายตัวของราคาและปริมาณการซื้อขายสำหรับสินค้าโภคภัณฑ์ของแต่ละชนิด


3.3.3 แสดงกราฟเส้นแสดงแนวโน้มของราคาสินค้าโภคภัณฑ์ตามปี

โดยกราฟเส้นนี้แสดงให้เห็นถึงการเปลี่ยนแปลงของราคาสินค้าโภคภัณฑ์หลัก ๆ ได้แก่ น้ำตาล โกโก้ กาแฟ ผัวย ไม้แปรรูป และน้ำส้ม ตลอดช่วงเวลาหลายปี โดยแกนนอนแสดงปี และแกนตั้งแสดงราคา จากกราฟเส้นแสดงแนวโน้มของราคาสินค้าโภคภัณฑ์ตามปี สามารถสรุปการวิเคราะห์ได้ดังนี้


ราคาน้ำส้ม น้ำส้มและโกโก้ มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องในช่วงปีหลัง ๆ แสดงให้เห็นถึงความต้องการที่เพิ่มขึ้นสำหรับสินค้าเหล่านี้ ดังการแสดงผลของกราฟเส้นแสดงแนวโน้มของราคาของน้ำส้ม น้ำส้มและโกโก้ ตามภาพประกอบที่ 5 - 7



ภาพประกอบ 5 กราฟเส้นแสดงแนวโน้มของราคาน้ำส้ม




ภาพประกอบ 6 กราฟเส้นแสดงแนวโน้มของราคาน้ำตาล




ภาพประกอบ 7 กราฟเส้นแสดงแนวโน้มของราคาโกโก้

ราคากาแฟและฝ้ายมีจุดสูงสุดที่โดดเด่นในปี 2010 ก่อนจะลดลง แต่กลับมาพุ่งสูงขึ้นอีกครั้งในปี 2020 ซึ่งอาจเป็นผลจากปัจจัยอุปสงค์และอุปทานในช่วงเวลานั้น ดังการแสดงผลของกราฟเส้นแสดงแนวโน้มของราคาของกาแฟและฝ้าย ตามภาพประกอบที่ 8 - 9




ภาพประกอบ 8 กราฟเส้นแสดงแนวโน้มของราคากาแฟ



ภาพประกอบ 9 กราฟเส้นแสดงแนวโน้มของราคาฝ้าย


ราคาไม้แปรรูปค่อนข้างคงที่ในช่วงระยะเวลาหนึ่ง ก่อนจะเพิ่มขึ้นอย่างรวดเร็วในปี 2020 แล้วตกลงในปีหลัง ๆ ซึ่งอาจสะท้อนถึงผลกระทบจากภาวะเศรษฐกิจและอุตสาหกรรมก่อสร้าง ดังการแสดงผลของกราฟเส้นแสดงแนวโน้มของราคาของไม้แปรรูป ตามภาพประกอบที่




ภาพประกอบ 10 กราฟเส้นแสดงแนวโน้มของราคาไม้แปรรูป

3.3.4 แสดงแผนภูมิเวลาตัวแปรปริมาณการซื้อขายของสินค้าแต่ละรายการ


การวิเคราะห์แผนภูมิเวลาแสดงตัวแปรปริมาณการซื้อขายของสินค้าโภคภัณฑ์หลักในช่วงปี 2000 ถึง 2023 พบแนวโน้มที่น่าสนใจหลายประการ เช่น ปริมาณการซื้อขายโกโก้ กาแฟ และน้ำตาลมีการเพิ่มขึ้นอย่างต่อเนื่องในช่วงหลังของข้อมูล ซึ่งอาจสะท้อนถึงความต้องการที่เพิ่มขึ้นจากการเติบโตของประชากรและรายได้ การเพิ่มขึ้นของชนชั้นกลางและการปรับเปลี่ยนรูปแบบการบริโภคอาจเป็นปัจจัยสำคัญที่ขับเคลื่อนอุปสงค์ของสินค้าเหล่านี้ ดังการแสดงผลตามภาพประกอบที่ 11 - 13



ภาพประกอบ 11 แผนภูมิเวลาตัวแปรปริมาณของโกโก้




ภาพประกอบ 12 แผนภูมิเวลาตัวแปรปริมาณของกาแฟ




ภาพประกอบ 13 แผนภูมิเวลาตัวแปรปริมาณของน้ำตาล

ในขณะที่ปริมาณการซื้อขายฝ้ายและน้ำส้มค่อนข้างคงที่เมื่อเทียบกับช่วงต้นของข้อมูล แสดงให้เห็นว่าอุปสงค์สำหรับสินค้าเหล่านี้ไม่ได้เปลี่ยนแปลงมากนักในช่วงเวลาดังกล่าว ซึ่งอาจเป็นผลมาจากการเติบโตของอุตสาหกรรมที่เกี่ยวข้องในอัตราที่ค่อนข้างคงที่ ดังการแสดงผลตามภาพประกอบที่ 14 - 15




ภาพประกอบ 14 แผนภูมิเวลาตัวแปรปริมาณของฝ้าย



ภาพประกอบ 15 แผนภูมิเวลาตัวแปรปริมาณของน้ำส้ม

สำหรับไม้แปรรูปนั้น พบการเพิ่มขึ้นอย่างมากในช่วงปี 2006-2008 ก่อนจะตกลงสู่จุดต่ำสุดในช่วง 2009-2010 ซึ่งสอดคล้องกับวิกฤตเศรษฐกิจโลกในช่วงเวลานั้น หลังจากนั้นมีการฟื้นตัวในปี 2012 แต่ต่อมาลดลงอีกครั้งจนถึงปัจจุบัน ซึ่งอาจสะท้อนถึงผลกระทบจากวิกฤตเศรษฐกิจและปัจจัยอื่นๆ ที่มีต่ออุปสงค์ของไม้แปรรูป เช่น การชะลอตัวของภาคก่อสร้างและอุตสาหกรรมที่เกี่ยวข้อง ดังการแสดงผลตามภาพประกอบที่ 16



ภาพประกอบ 16 แผนภูมิเวลาตัวแปรปริมาณของไม้แปรรูป

สรุปได้ว่า การวิเคราะห์แผนภูมิเวลาแสดงตัวแปรปริมาณการซื้อขายของสินค้าโภคภัณฑ์หลักในช่วงปี 2000 ถึง 2023 ทำให้เห็นแนวโน้มที่แตกต่างกันในแต่ละประเภทสินค้า โดยโกโก้ กาแฟ และน้ำตาล มีปริมาณการซื้อขายเพิ่มขึ้นอย่างต่อเนื่อง สะท้อนความต้องการที่เพิ่มขึ้นจากการเติบโตของประชากร รายได้ และการขยายตัวของชนชั้นกลาง ขณะที่ฝ้ายและน้ำส้มมีความคงที่ เนื่องจากอุตสาหกรรมที่เกี่ยวข้องเติบโตในอัตราค่อนข้างคงที่ ส่วนไม้แปรรูปมีความผันผวนสูงจากผลกระทบของวัฏจักรเศรษฐกิจโลก การเข้าใจแนวโน้มเหล่านี้เป็นประโยชน์อย่างยิ่งต่อการคาดการณ์ความต้องการและวางแผนการผลิตสินค้าโภคภัณฑ์ในอนาคต เพื่อรองรับความต้องการของตลาดที่เปลี่ยนแปลงไปอย่างเหมาะสม

3.4 การสร้างแบบจำลองพยากรณ์

ในงานวิจัยนี้สร้างแบบจำลองพยากรณ์ทั้งหมด 2 แบบ ได้แก่ Autoregressive Integrated Moving Average (ARIMA) และ Multi-Layer Perceptron (MLP) เพื่อพยากรณ์ราคาปิดรายวันของสินค้าโภคภัณฑ์ ชุดข้อมูลที่ใช้ในการวิจัยนี้ประกอบด้วยข้อมูลสินค้าโภคภัณฑ์ตั้งแต่ปี 2000 ถึง 2023


อย่างไรก็ตาม เพื่อให้การพยากรณ์มีความแม่นยำและเป็นปัจจุบันมากขึ้น จึงเลือกใช้ข้อมูลที่อัปเดตล่าสุด โดยแบ่งข้อมูลเป็นสองชุดคือ ชุดข้อมูลฝึกและชุดข้อมูลทดสอบ โดยข้อมูลตั้งแต่ปี 2022-01-03 ถึง 2023-05-24 ถูกใช้เป็นข้อมูลฝึกสำหรับสร้างแบบจำลอง ในขณะที่ข้อมูลตั้งแต่ปี 2023-05-25 ถึง 2023-08-18 ถูกใช้เป็นข้อมูลทดสอบเพื่อประเมินประสิทธิภาพของแบบจำลองในการพยากรณ์

ขั้นตอนการดำเนินการเริ่มต้นด้วยการนำเข้าสู่ชุดข้อมูล การทำความสะอาดข้อมูลเพื่อตรวจสอบและจัดการค่าผิดปกติ และการเตรียมข้อมูลให้อยู่ในรูปแบบที่เหมาะสม จากนั้นแบ่งชุด

ข้อมูลออกเป็นชุดข้อมูลฝึกและชุดข้อมูลทดสอบ และเข้าสู่กระบวนการสร้างลำดับข้อมูลที่จำเป็นสำหรับการฝึกและทดสอบโมเดลต่าง ๆ ขั้นตอนต่อไปคือการสร้างและฝึกแบบจำลอง โดยใช้ชุดข้อมูลฝึกเพื่อปรับปรุงความแม่นยำ สุดท้ายทำการทำนายผลลัพธ์สำหรับช่วงวันที่ 2023-05-25 ถึง 2023-08-18 หรือระยะเวลา 56 วัน โดยใช้แบบจำลองที่ฝึกแล้ว และประเมินผลด้วยเมตริกต่าง ๆ เช่น Root Mean Squared Error (RMSE), Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE)



3.4.1 การสร้างแบบจำลอง Autoregressive Integrated Moving Average (ARIMA)



ภาพประกอบ 17 แผนผังแสดงกระบวนการสร้างแบบจำลองของ ARIMA

ตามภาพประกอบที่ 17 เป็นแผนผังแสดงกระบวนการสร้างแบบจำลอง ARIMA ในงานวิจัยนี้ได้สร้างแบบจำลอง ARIMA โดยใช้วิธีการ Rolling Forecast เพื่อทำนายราคาปิดของสินค้าโภคภัณฑ์ 6 ประเภท ได้แก่ โกโก้ กาแฟ ฝ้าย น้ำส้ม ไม้แปรรูป และน้ำตาล มีกระบวนการดังนี้

เริ่มต้นด้วยการสำรวจและเตรียมข้อมูลเบื้องต้น โดยแปลงรูปแบบและจัดการกับค่าว่าง เมื่อเตรียมข้อมูลเรียบร้อยแล้ว ในขั้นตอนถัดไปคือการดำเนินการทำการทดสอบความเป็น Stationary โดยการใช้ทดสอบ Augmented Dickey-Fuller (ADF Test) ของข้อมูล และใช้เทคนิคการ Differencing เพื่อแปลงข้อมูลให้อยู่ในรูปแบบ Stationary

ผลจากการทดสอบโดยตรวจสอบค่า p-value ของแต่ละชุดข้อมูล พบว่า

ไม้แปรรูป: p-value = 0.0943

น้ำตาล: p-value = 0.1389

โกโก้: p-value = 0.1282

ฝ้าย: p-value = 0.0652

กาแฟ: p-value = 0.1977

น้ำส้ม: p-value = 0.9907

จากผลการทดสอบทุกชุดข้อมูลมีค่า p-value ที่สูงกว่า 0.05 ซึ่งบ่งชี้ว่าข้อมูลเหล่านี้เป็น Non-Stationary หรือไม่มีความคงที่ ดังนั้นจึงต้องมีการใช้เทคนิค Differencing เพื่อให้ข้อมูลที่น่ามาศึกษามีความคงที่และนำไปศึกษาต่อไป

สำหรับการแบ่งข้อมูลได้ทำการแบ่งออกเป็นชุดฝึกอบรม (Training Data) และชุดทดสอบ (Test Data) ใช้ข้อมูล 90% แรกเป็นชุดฝึกอบรมและ 10% สุดท้ายเป็นชุดทดสอบ และทำนายข้อมูลในช่วงทดสอบ เริ่มต้นด้วยการใช้ข้อมูลย้อนหลัง 30 วันสุดท้ายของชุดฝึกอบรมเป็นข้อมูล History จากนั้นสร้างแบบจำลอง ARIMA โดยใช้ฟังก์ชัน `auto_arima` เพื่อค้นหาแบบจำลองที่เหมาะสมที่สุดสำหรับแต่ละชุดข้อมูล ซึ่งฟังก์ชัน `auto_arima` จะหาค่าพารามิเตอร์ของโมเดล ARIMA ได้แก่ p, d, q โดยค่า p หมายถึงจำนวนของ Lags (ความล่าช้า) ของตัวแปร Dependent ที่จะนำมาใช้ในโมเดล Auto-Regression ค่า d หมายถึงจำนวนครั้งของการ Differencing ที่ทำให้ข้อมูลเป็น Stationary (ข้อมูลมีความนิ่ง) และสุดท้ายคือค่า q หมายถึงจำนวนของ Lags ของความผิดพลาด (Error Terms) ที่จะนำมาใช้ในโมเดล Moving Average โดยค่าที่ดีที่สุดหลังจากใช้ฟังก์ชัน `auto_arima` ในการหาค่าพารามิเตอร์ของแต่ละชุดข้อมูลดังในตารางที่ 6


ตาราง 6 ค่าที่ดีที่สุดของโมเดล ARIMA จากการใช้ฟังก์ชัน Auto Arima

Product	Best model
โกโก้	(1,1,1)
กาแฟ	(0,1,0)
ฝ้าย	(2,1,2)
น้ำส้ม	(1,1,3)
ไม้แปรรูป	(2,1,3)
น้ำตาล	(0,1,0)

ในขั้นตอนถัดไป ทำการเรียนรู้จากชุดข้อมูลฝึกอบรม และทำนายข้อมูล 7 วัน ถัดไปในชุดทดสอบ เมื่อได้ข้อมูลทำนายใหม่จะนำมาอัปเดตข้อมูลประวัติและทำซ้ำขั้นตอนนี้ จนกว่าจะทำนายครบทุกข้อมูลในชุดทดสอบ ผลลัพธ์ของการทำนายถูกประเมินด้วยตัวชี้วัด RMSE MAE และ MAPE เพื่อวัดความแม่นยำของแบบจำลอง ARIMA ในการทำนายราคาสินค้า โกโก้กันซ์

Rolling Forecast เป็นเทคนิคที่ใช้ในการทำนายข้อมูลอนาคตในงานวิเคราะห์ ข้อมูลอนุกรมเวลา โดยมีการอัปเดตแบบจำลองอย่างต่อเนื่องด้วยข้อมูลใหม่ทุกครั้งที่ได้รับการ สังเกตใหม่ วิธีนี้ช่วยให้การทำนายมีความแม่นยำและสอดคล้องกับข้อมูลที่เปลี่ยนแปลงอย่าง ต่อเนื่องในอนาคต กระบวนการ Rolling Forecast เริ่มต้นด้วยการสร้างแบบจำลองจากข้อมูลชุด ฝึกอบรม หลังจากนั้นจะใช้ข้อมูลใหม่ที่ได้รับเพื่ออัปเดตแบบจำลองและทำนายข้อมูลในช่วงเวลา ถัดไปอย่างต่อเนื่อง [17]

3.4.2 การสร้างแบบจำลอง Multi-Layer Perceptron (MLP)



ภาพประกอบ 18 แผนผังแสดงกระบวนการสร้างแบบจำลองของ MLP

ตามภาพประกอบที่ 18 เป็นแผนผังแสดงกระบวนการสร้างแบบจำลองของ Multilayer Perceptron (MLP) ในงานวิจัยนี้ นำแบบจำลอง MLP มาประยุกต์ใช้เพื่อพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ โดยมีกระบวนการวิจัยที่ครอบคลุมตั้งแต่การจัดการข้อมูลไปจนถึงการปรับแต่งโมเดล ดังนี้

สำรวจและวิเคราะห์ข้อมูล เพื่อทำความเข้าใจลักษณะและแนวโน้มของราคาสินค้าโภคภัณฑ์ จากนั้นดำเนินการเตรียมข้อมูลโดยคัดกรองช่วงเวลาที่เกี่ยวข้องและเลือกเฉพาะข้อมูลราคาปิดซึ่งเป็นตัวแปรสำคัญในการพยากรณ์

การแปลงข้อมูลให้เหมาะสมกับโมเดล MLP โดยใช้เทคนิค Split Sequence เพื่อสร้างชุดข้อมูล Input-Output ที่สอดคล้องกับลักษณะการเรียนรู้ของโมเดล ในการศึกษาได้กำหนดจำนวนก้าวเวลา (Time Steps) เท่ากับ 3 ซึ่งเหมาะสมกับการพยากรณ์ระยะสั้น ตัวอย่างรูปแบบข้อมูลก่อนและหลังจากทำการแปลงข้อมูลเพื่อเตรียมพร้อมก่อนนำไปเรียนรู้กับโมเดล MLP ดังภาพประกอบที่ 19

Original Training Data (first 10 values):
[2499. 2462. 2457. 2423. 2521. 2521. 2588. 2559. 2609. 2659.]

Transformed Training Data Samples:
Input: [2499. 2462. 2457.], Output: 2423.0
Input: [2462. 2457. 2423.], Output: 2521.0
Input: [2457. 2423. 2521.], Output: 2521.0
Input: [2423. 2521. 2521.], Output: 2588.0
Input: [2521. 2521. 2588.], Output: 2559.0
Input: [2521. 2588. 2559.], Output: 2609.0
Input: [2588. 2559. 2609.], Output: 2659.0
Input: [2559. 2609. 2659.], Output: 2631.0
Input: [2609. 2659. 2631.], Output: 2657.0
Input: [2659. 2631. 2657.], Output: 2660.0

Original Testing Data (first 10 values):
[3017. 2991. 3005. 3007. 3008. 3026. 3056. 3045. 3103. 3149.]

Transformed Testing Data Samples:
Input: [3017. 2991. 3005.], Output: 3007.0
Input: [2991. 3005. 3007.], Output: 3008.0
Input: [3005. 3007. 3008.], Output: 3026.0
Input: [3007. 3008. 3026.], Output: 3056.0
Input: [3008. 3026. 3056.], Output: 3045.0
Input: [3026. 3056. 3045.], Output: 3103.0
Input: [3056. 3045. 3103.], Output: 3149.0
Input: [3045. 3103. 3149.], Output: 3180.0
Input: [3103. 3149. 3180.], Output: 3136.0
Input: [3149. 3180. 3136.], Output: 3186.0

ภาพประกอบ 19 ตัวอย่างรูปแบบข้อมูลก่อนและหลังจากทำการแปลงข้อมูล

การออกแบบโครงสร้างของโมเดล MLP โดยใช้โครงสร้างแบบ Sequential ประกอบด้วย ชั้น Dense Layers ที่มีการกำหนดจำนวนยูนิตและฟังก์ชันกระตุ้น (Activation Function) อย่าง

เหมาะสม เพื่อให้โมเดลสามารถเรียนรู้ความสัมพันธ์ที่ซับซ้อนในข้อมูลได้อย่างมีประสิทธิภาพ ซึ่งการปรับแต่งไฮเปอร์พารามิเตอร์เป็นกระบวนการสำคัญในการเพิ่มประสิทธิภาพของโมเดล โดยมีการทดลองปรับค่าพารามิเตอร์ต่าง ๆ ได้แก่ Hidden Layers, Activation Functions, Optimizer, Learning Rate, Batch Size, Number of Epochs, Dropout Rate และ Loss Function เพื่อหาชุดค่าที่ให้ผลลัพธ์ที่ดีที่สุด โดยในงานวิจัยนี้ได้มีการปรับแต่งค่าพารามิเตอร์ ดังตารางที่ 7

ตาราง 7 การปรับแต่งค่าพารามิเตอร์สำหรับแบบจำลอง Multilayer Perceptron (MLP)

Number of Hidden Layers	2
Units in Hidden Layers	100, 50
Activation Functions	relu, relu
Optimizer	adam
Learning Rate	0.001
Batch Size	32
Number of Epochs	200
Dropout Rate	0
Loss Function	mse

ในขั้นตอนการฝึกฝนโมเดลใช้ชุดข้อมูลฝึกที่เตรียมไว้และทำการประเมินประสิทธิภาพของโมเดลด้วยชุดข้อมูลทดสอบ โดยใช้เกณฑ์วัดประสิทธิภาพ ได้แก่ RMSE MAE และ MAPE เช่นเดียวกันกับโมเดล ARIMA

บทที่ 4

ผลการศึกษา

ในการศึกษานี้ได้ทำการวิเคราะห์เปรียบเทียบประสิทธิภาพของวิธีการทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ โดยใช้แบบจำลอง Auto-Regressive Integrated Moving Average (ARIMA) และ Multi-Layer Perceptron (MLP) เพื่อค้นหาวิธีการที่เหมาะสมที่สุดสำหรับการพยากรณ์ราคาปิดของสินค้า ต่อไปนี้คือผลการวิเคราะห์เปรียบเทียบประสิทธิภาพของแบบจำลองทั้งสอง


4.1 ผลการทดลองแบบจำลอง Autoregressive Integrated Moving Average (ARIMA)

ในการวิเคราะห์ข้อมูลอนุกรมเวลา ผู้วิจัยได้ใช้โมเดล Autoregressive Integrated Moving Average (ARIMA) เพื่อพยากรณ์ราคาสินค้าโภคภัณฑ์ ซึ่งประกอบด้วยโกโก้ กาแฟ ฝ้าย น้ำส้ม ไม้แปรรูป และน้ำตาล ผลการทดลองและการประเมินค่าความแม่นยำของโมเดล ARIMA ถูกสรุปในตารางต่อไปนี้

ตาราง 8 ผลการทดลองแบบจำลอง ARIMA

Product	RMSE	MAE	MAPE (%)	Avg Price
น้ำตาล	0.96	0.71	2.94	14.56
ฝ้าย	3.31	2.72	3.24	71.40
กาแฟ	6.86	5.26	3.15	128.85
น้ำส้ม	14.78	11.47	3.98	196.18
ไม้แปรรูป	45.98	31.60	8.10	355.83
โกโก้	105.57	75.68	2.30	2,230.59

ผลการทดลองแสดงค่าความแม่นยำของโมเดล ARIMA โดยสินค้าน้ำตาลมีค่าความแม่นยำสูงสุดด้วยค่า RMSE ที่ 0.96, MAE ที่ 0.71 และ MAPE ที่ 2.94% ในขณะที่สินค้าที่มีความคลาดเคลื่อนโดยวัดจากค่า MAPE พบว่า ไม้แปรรูปมีค่ามากที่สุด ซึ่งมีค่า MAPE สูงถึง 8.10% RMSE ที่ 45.98 และ MAE ที่ 31.60



ภาพประกอบ 20 กราฟการพยากรณ์ราคารายวันของแต่ละสินค้าของโมเดล ARIMA

ภาพประกอบที่ 20 แสดงกราฟการพยากรณ์ราคาปิดรายวันของสินค้าโภคภัณฑ์แต่ละประเภท ทำให้สามารถเห็นการเคลื่อนไหวของราคาในช่วงเวลาต่าง ๆ และการพยากรณ์ของโมเดล ARIMA ที่สอดคล้องกับความเป็นจริง ซึ่งสรุปประสิทธิภาพของการทำนายแบบ Rolling Forecast ของ ARIMA สำหรับสินค้าหลากหลายชนิดได้ ดังนี้

ข้อมูลโกโก้ (Cocoa Data) แสดงให้เห็นว่าโมเดล ARIMA สามารถทำนายแนวโน้มขาขึ้นและความผันผวนได้อย่างแม่นยำ แต่มีการล่าช้าเล็กน้อยในบางจุด โดยค่าทำนายใกล้เคียงกับค่าจริงในช่วงส่วนใหญ่ของการทดสอบ สำหรับข้อมูลกาแฟ (Coffee Data) พบว่าโมเดลมีความยากลำบากในการติดตามการลดลงอย่างรวดเร็วของราคา ซึ่งทำให้เกิดความแตกต่างอย่างชัดเจนระหว่างค่าจริงและค่าทำนาย ในส่วนของข้อมูลฝ้าย (Cotton Data) โมเดลไม่สามารถจับแนวโน้ม

ราคาที่เป็นระดับต่ำได้อย่างถูกต้อง ทำให้ทำนายราคาสูงเกินไป สำหรับข้อมูลน้ำส้ม (Orange Juice Data) โมเดลสามารถทำนายแนวโน้มและความผันผวนได้ดีแม้ว่าจะมีความแตกต่างเล็กน้อยในบางช่วง ข้อมูลไม้แปรรูป (Random Length Lumber Data) แสดงให้เห็นว่าโมเดลทำนายแนวโน้มเพิ่มขึ้นซึ่งไม่สอดคล้องกับราคาจริงที่คงที่ในระดับต่ำ ทำให้ค่าทำนายต่ำกว่าราคาจริงในช่วงขาขึ้นและสูงกว่าค่าจริงในช่วงขาลงอย่างต่อเนื่อง ในกรณีของข้อมูลน้ำตาล (Sugar Data) โมเดลสามารถจับแนวโน้มและรูปแบบความผันผวนได้ดี แต่มีความล่าช้าเล็กน้อยในบางช่วง ข้อสรุปจากการวิเคราะห์นี้ โมเดล ARIMA ทำงานได้ดีในการจับแนวโน้มที่สม่ำเสมอและความผันผวนเล็กน้อย แต่มีข้อจำกัดในการจัดการกับการเปลี่ยนแปลงอย่างรวดเร็วและการคงที่ในระดับราคาที่ต่ำ ซึ่งแสดงให้เห็นว่าโมเดล ARIMA มีความแข็งแกร่งสำหรับสินค้าบางชนิด แต่จำเป็นต้องมีการปรับเปลี่ยนเพิ่มเติมหรือใช้โมเดลทางเลือกในการจัดการกับข้อมูลที่มีความผันผวนมากหรือเปลี่ยนแปลงอย่างรวดเร็ว


4.3 ผลการทดลองแบบจำลอง Multi-Layer Perceptron (MLP)

ผลการทดสอบแบบจำลอง Multi-Layer Perceptron (MLP) เพื่อพยากรณ์ราคาสินค้า เช่น โกโก้ กาแฟ ฝ้าย น้ำส้ม ไม้แปรรูป และน้ำตาล โดยวัดประสิทธิภาพของโมเดลด้วยค่า RMSE MAE และ MAPE ผลการทดลองและการประเมินค่าความแม่นยำของโมเดล MLP ถูกสรุปในตารางที่ 9

ตาราง 9 ผลการทดลองแบบจำลอง MLP

Product	RMSE	MAE	MAPE (%)	Avg Price
น้ำตาล	0.51	0.41	1.67	14.56
ฝ้าย	1.92	1.53	1.84	71.40
กาแฟ	4.45	3.45	2.03	128.85
น้ำส้ม	11.00	8.78	3.08	196.18
ไม้แปรรูป	28.10	18.29	4.83	355.83
โกโก้	43.02	33.52	1.02	2,230.59

ผลการทดลองแสดงค่าความแม่นยำของโมเดล MLP โดยสินค้าน้ำตาลมีค่าความแม่นยำสูงสุดด้วยค่า RMSE ที่ 0.51, MAE ที่ 0.41 และ MAPE ที่ 1.67% ในขณะที่สินค้าที่มีความคลาดเคลื่อนโดยวัดจากค่า MAPE พบว่า ไม้แปรรูป มีค่ามากที่สุด ซึ่งมีค่า MAPE ที่ 4.83% RMSE ที่ 28.10 และ MAE ที่ 18.29



ภาพประกอบ 21 กราฟการพยากรณ์ราคาของแต่ละสินค้าของโมเดล MLP

ภาพประกอบที่ 21 แสดงกราฟการพยากรณ์ราคาสินค้าโภคภัณฑ์แต่ละประเภท ทำให้สามารถเห็นการเคลื่อนไหวของราคาในช่วงเวลาต่าง ๆ และการพยากรณ์ของโมเดล MLP ที่สอดคล้องกับความเป็นจริง ซึ่งเป็นเครื่องยืนยันความแม่นยำและความน่าเชื่อถือของโมเดล MLP

การวิเคราะห์การทำนายของโมเดล MLP สำหรับสินค้าหลากหลายชนิดแสดงให้เห็นถึงประสิทธิภาพและข้อจำกัดของโมเดลในการทำนายราคาปิดจริง ข้อมูลโกโก้ (Cocoa Data) แสดงให้เห็นว่าโมเดล MLP สามารถทำนายแนวโน้มขาขึ้นและความผันผวนได้อย่างแม่นยำ โดยค่าทำนายใกล้เคียงกับค่าจริงในช่วงส่วนใหญ่ของการทดสอบ แต่มีการเบี่ยงเบนเล็กน้อยในช่วงสำหรับข้อมูลกาแฟ (Coffee Data) พบว่าโมเดลมีความสามารถในการติดตามแนวโน้มขาขึ้นได้ดีขึ้นเมื่อเทียบกับ ARIMA แต่ยังคงมีความแตกต่างอย่างเห็นได้ชัดระหว่างค่าจริงและค่าทำนายในช่วงปลายของการทดสอบ ในส่วนของข้อมูลฝ้าย (Cotton Data) มีความสามารถในการทำนายช่วงนี้ได้ค่อนข้างแม่นยำ โดยค่าทำนายใกล้เคียงกับค่าจริงในหลายช่วง อย่างไรก็ตาม โมเดลยังคงมีความคลาดเคลื่อนในบางช่วง โดยค่าทำนายมีแนวโน้มสูงกว่าค่าจริงเล็กน้อย ซึ่งอาจเกิดจากการที่โมเดลไม่สามารถจับความผันผวนและแนวโน้มราคาที่คงที่ในระดับต่ำได้อย่างถูกต้อง เช่นเดียวกับ ARIMA ทำให้ทำนายราคาสูงเกินไป สำหรับข้อมูลน้ำส้ม (Orange Juice Data)

โมเดลสามารถทำนายแนวโน้มและความผันผวนได้ดีเช่นเดียวกับ ARIMA โดยมีความแตกต่างเล็กน้อยในบางช่วง ข้อมูลไม้แปรรูป (Random Length Lumber Data) แสดงให้เห็นว่าโมเดลทำนายแนวโน้มเพิ่มขึ้นซึ่งไม่สอดคล้องกับราคาจริงที่คงที่ในระดับต่ำ ทำให้ค่าทำนายสูงกว่าค่าจริงอย่างต่อเนื่อง ในกรณีของข้อมูลน้ำตาล (Sugar Data) โมเดลสามารถจับแนวโน้มและรูปแบบความผันผวนได้ดีในช่วงต้นของการทดสอบ แต่มีความคลาดเคลื่อนเล็กน้อยในช่วงปลาย



บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

5.1 สรุปผลการวิจัย


การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง โดยใช้แบบจำลอง Autoregressive Integrated Moving Average (ARIMA) และ Multi-Layer Perceptron (MLP) ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ โดยใช้ข้อมูลราคาปิดของสินค้าโภคภัณฑ์ ได้แก่ โกโก้ กาแฟ ฝ้าย น้ำส้ม ไม้แปรรูป และน้ำตาล จากข้อมูลอนุกรมเวลา เพื่อประเมินความแม่นยำของวิธีการพยากรณ์ทั้งสองประเภท โดยใช้เกณฑ์ในการประเมิน ได้แก่ ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ถูกทำรากที่สอง (Root Mean Squared Error - RMSE) ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error - MAE) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error - MAPE) ผลการวิจัยพบว่า การเปรียบเทียบประสิทธิภาพ โมเดล MLP แสดงประสิทธิภาพที่เหนือกว่า ARIMA ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ทั้ง 6 ชนิด โดยการประเมินความแม่นยำได้ ดังนี้ ค่า RMSE: MLP มีค่า RMSE ต่ำกว่า ARIMA ในทุกสินค้า ความแตกต่างมากที่สุดพบในโกโก้ (ARIMA: 105.57, MLP: 43.02) ความแตกต่างน้อยที่สุดพบในน้ำตาล (ARIMA: 0.96, MLP: 0.51) ค่า MAE: MLP มีค่า MAE ต่ำกว่า ARIMA ในทุกสินค้า ความแตกต่างมากที่สุดพบในโกโก้ (ARIMA: 75.68, MLP: 33.52) ความแตกต่างน้อยที่สุดพบในน้ำตาล (ARIMA: 0.71, MLP: 0.41) และ ค่า MAPE: MLP มีค่า MAPE ต่ำกว่า ARIMA ในทุกสินค้า ความแตกต่างมากที่สุดพบในไม้แปรรูป (ARIMA: 8.1%, MLP: 4.83%) ความแตกต่างน้อยที่สุดพบในน้ำส้ม (ARIMA: 3.98%, MLP: 3.08%)

ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า *Root Mean Squared Error (RMSE)*

ตาราง 10 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า RMSE

Product	ARIMA	MLP
น้ำตาล	0.96	0.51
ฝ้าย	3.31	1.92
กาแฟ	6.86	4.45
น้ำส้ม	14.78	11.00
ไม้แปรรูป	45.98	28.10
โกโก้	105.57	43.02

จากตารางผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า RMSE สามารถเห็นได้ว่าโมเดล MLP มีค่า RMSE ต่ำกว่าโมเดล ARIMA ในทุกผลิตภัณฑ์ ซึ่งบ่งบอกถึงประสิทธิภาพที่ดีกว่าในการทำนายราคาสินค้า สามารถแสดงผลแผนภูมิแท่ง ดังภาพประกอบที่ 22 ดังนี้



ภาพประกอบ 22 แผนภูมิแท่งผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า RMSE

ในภาพประกอบที่ 22 แสดงผลการเปรียบเทียบค่า Root Mean Squared Error (RMSE) ระหว่างโมเดล ARIMA และ MLP สำหรับสินค้าหลากหลายชนิด โดยมีรายละเอียดที่น่าสนใจ ดังนี้ สำหรับโกโก้ ค่า RMSE ของโมเดล MLP ต่ำกว่าโมเดล ARIMA อย่างชัดเจน โดยค่า RMSE ของ ARIMA อยู่ที่ 105.57 ในขณะที่ MLP อยู่ที่ 43.02 ในกรณีของกาแฟ ค่า RMSE ของทั้งสองโมเดล มีความใกล้เคียงกัน โดย MLP มีค่า RMSE ต่ำกว่าเล็กน้อย โดยค่า RMSE ของ ARIMA คือ 6.86 ในขณะที่ MLP คือ 4.45 สำหรับฝ้าย ค่า RMSE ของโมเดล MLP ต่ำกว่าโมเดล ARIMA อย่างชัดเจน โดยค่า RMSE ของ ARIMA คือ 3.31 ในขณะที่ MLP คือ 1.92 สำหรับน้ำตาล โมเดล MLP มีค่า RMSE ต่ำกว่าโมเดล ARIMA แสดงถึงประสิทธิภาพที่ดีกว่าในการทำนาย โดยค่า RMSE ของ ARIMA อยู่ที่ 14.78 ในขณะที่ MLP อยู่ที่ 11.0 ในกรณีของไม้แปรรูป โมเดล MLP มีค่า RMSE ต่ำกว่าโมเดล ARIMA ซึ่งแสดงถึงความแม่นยำที่สูงกว่าในการทำนายราคาของไม้แปรรูป โดยค่า RMSE ของ ARIMA คือ 45.98 ในขณะที่ MLP คือ 28.1 สำหรับน้ำตาล ค่า RMSE ของทั้งสองโมเดลมีความใกล้เคียงกัน แต่ MLP มีค่า RMSE ต่ำกว่าเล็กน้อย โดยค่า RMSE ของ ARIMA คือ 0.96 ในขณะที่ MLP คือ 0.51 ภาพรวมแสดงให้เห็นว่าโมเดล MLP มีความสามารถในการทำนาย


ที่ดีกว่าโมเดล ARIMA ในทุกผลิตภัณฑ์ โดยเฉพาะในกรณีของโกโก้และไม้แปรรูปที่มีความแตกต่างอย่างชัดเจน

ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า *MAE*

ตาราง 11 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAE

Product	ARIMA	MLP
น้ำตาล	0.71	0.41
ฝ้าย	2.72	1.53
กาแฟ	5.26	3.45
น้ำส้ม	11.47	8.78
ไม้แปรรูป	31.60	18.29
โกโก้	75.68	33.52

จากตารางข้างต้นสามารถเห็นได้ว่าโมเดล MLP มีค่า MAE ต่ำกว่าโมเดล ARIMA ในทุกผลิตภัณฑ์ ซึ่งบ่งบอกถึงประสิทธิภาพที่ดีกว่าในการทำนายราคาสินค้า สามารถแสดงผลแผนภูมิแท่ง ดังภาพประกอบที่ 23



ภาพประกอบ 23 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAE

ในภาพประกอบที่ 23 แสดงผลการเปรียบเทียบค่า Mean Absolute Error (MAE) ระหว่างโมเดล ARIMA และ MLP สำหรับสินค้าหลากหลายชนิด ซึ่งมีรายละเอียดที่น่าสนใจ ดังนี้ สำหรับโกโก้ ค่า MAE ของโมเดล MLP ต่ำกว่าโมเดล ARIMA อย่างชัดเจน โดยค่า MAE ของ


ARIMA อยู่ที่ 75.68 ในขณะที่ MLP อยู่ที่ 33.52 สำหรับกาแฟ ค่า MAE ของทั้งสองโมเดลมีความใกล้เคียงกัน โดย MLP มีค่า MAE ต่ำกว่าเล็กน้อย โดยค่า MAE ของ ARIMA คือ 5.26 ในขณะที่ MLP คือ 3.45 สำหรับฝ้าย ค่า MAE ของโมเดล MLP ต่ำกว่าโมเดล ARIMA อย่างชัดเจน โดยค่า MAE ของ ARIMA คือ 2.72 ในขณะที่ MLP คือ 1.53 ในกรณีน้ำส้ม โมเดล MLP มีค่า MAE ต่ำกว่าโมเดล ARIMA แสดงถึงประสิทธิภาพที่ดีกว่าในการทำนาย โดยค่า MAE ของ ARIMA อยู่ที่ 11.47 ในขณะที่ MLP อยู่ที่ 8.78 สำหรับไม้แปรรูป โมเดล MLP มีค่า MAE ต่ำกว่าโมเดล ARIMA ซึ่งแสดงถึงความแม่นยำที่สูงกว่าในการทำนายราคาของไม้แปรรูป โดยค่า MAE ของ ARIMA คือ 31.6 ในขณะที่ MLP คือ 18.29 สุดท้ายสำหรับน้ำตาล ค่า MAE ของทั้งสองโมเดลมีความใกล้เคียงกัน แต่ MLP มีค่า MAE ต่ำกว่าเล็กน้อย โดยค่า MAE ของ ARIMA คือ 0.71 ในขณะที่ MLP คือ 0.41 ภาพรวมแสดงให้เห็นว่าโมเดล MLP มีความสามารถในการทำนายที่ดีกว่าโมเดล ARIMA ในทุกผลิตภัณฑ์ โดยเฉพาะในกรณีของโกโก้และไม้แปรรูปที่มีความแตกต่างอย่างชัดเจน

ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า *MAPE*

ตาราง 12 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAPE

Product	ARIMA	MLP
โกโก้	2.30	1.02
น้ำตาล	2.94	1.67
กาแฟ	3.15	2.03
ฝ้าย	3.24	1.84
น้ำส้ม	3.98	3.08
ไม้แปรรูป	8.10	4.83

จากตารางข้างต้นสามารถเห็นได้ว่าโมเดล MLP มีค่า MAPE ต่ำกว่าโมเดล ARIMA ในทุกผลิตภัณฑ์ ซึ่งบ่งบอกถึงประสิทธิภาพที่ดีกว่าในการทำนายราคาสินค้า สามารถแสดงผลแผนภูมิแท่ง ดังภาพประกอบที่ 24



ภาพประกอบ 24 ผลการประเมินประสิทธิภาพของโมเดลโดยประเมินด้วยค่า MAPE

ในภาพประกอบที่ 24 แสดงผลการเปรียบเทียบค่า Mean Absolute Percentage Error (MAPE) ระหว่างโมเดล ARIMA และ MLP สำหรับสินค้าหลากหลายชนิด โดยมีรายละเอียดที่น่าสนใจ ดังนี้ สำหรับโกโก้ ค่า MAPE ของโมเดล MLP ต่ำกว่าโมเดล ARIMA อย่างชัดเจน โดยค่า MAPE ของ ARIMA อยู่ที่ 2.3% ในขณะที่ MLP อยู่ที่ 1.02% สำหรับกาแฟ ค่า MAPE ของทั้งสองโมเดลมีความใกล้เคียงกัน โดย MLP มีค่า MAPE ต่ำกว่าเล็กน้อย โดยค่า MAPE ของ ARIMA คือ 3.15% ในขณะที่ MLP คือ 2.03% ในกรณีของฝ้าย ค่า MAPE ของโมเดล MLP ต่ำกว่าโมเดล ARIMA อย่างชัดเจน โดยค่า MAPE ของ ARIMA คือ 3.24% ในขณะที่ MLP คือ 1.84% สำหรับน้ำตาล โมเดล MLP มีค่า MAPE ต่ำกว่าโมเดล ARIMA แสดงถึงประสิทธิภาพที่ดีกว่าในการทำนาย โดยค่า MAPE ของ ARIMA อยู่ที่ 3.98% ในขณะที่ MLP อยู่ที่ 3.08% ในกรณีของไม้แปรรูป โมเดล MLP มีค่า MAPE ต่ำกว่าโมเดล ARIMA ซึ่งแสดงถึงความแม่นยำที่สูงกว่าในการทำนายราคาของไม้แปรรูป โดยค่า MAPE ของ ARIMA คือ 8.1% ในขณะที่ MLP คือ 4.83% สำหรับน้ำตาล ค่า MAPE ของทั้งสองโมเดลมีความใกล้เคียงกัน แต่ MLP มีค่า MAPE ต่ำกว่าเล็กน้อย โดยค่า MAPE ของ ARIMA คือ 2.94% ในขณะที่ MLP คือ 1.67% ภาพรวมแสดงให้เห็นว่าโมเดล MLP มีความสามารถในการทำนายที่ดีกว่าโมเดล ARIMA ในทุกผลิตภัณฑ์ โดยเฉพาะในกรณีของโกโก้ และไม้แปรรูปที่มีความแตกต่างอย่างชัดเจน

ผลการวิจัยแสดงให้เห็นว่าโมเดล Multi-Layer Perceptron (MLP) มีประสิทธิภาพเหนือกว่า Autoregressive Integrated Moving Average (ARIMA) ในการพยากรณ์ราคาปิดของ

สินค้าโภคภัณฑ์ทั้ง 6 ชนิด โดยมีค่าความคลาดเคลื่อนที่ต่ำกว่าในทุกเกณฑ์การประเมิน ได้แก่ RMSE, MAE และ MAPE ความแตกต่างนี้เป็นผลมาจากโครงสร้างและการทำงานที่แตกต่างกันของทั้งสองโมเดล โดย MLP เป็นโครงข่ายประสาทเทียมที่สามารถเรียนรู้และจับความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นได้ดีกว่า ARIMA ซึ่งเป็นโมเดลเชิงเส้นที่มีข้อจำกัดในการจับความสัมพันธ์ที่ซับซ้อน นอกจากนี้ MLP ยังมีความยืดหยุ่นสูงในการปรับตัวต่อการเปลี่ยนแปลงของตลาดและปัจจัยภายนอกที่ส่งผลกระทบต่อราคาสินค้าโภคภัณฑ์ ทำให้สามารถจัดการกับข้อมูลที่มีความผันผวนสูงได้ดีกว่า ARIMA

ความแตกต่างของประสิทธิภาพระหว่างสองโมเดลมีความแตกต่างกันไปตามประเภทของสินค้าโภคภัณฑ์ โดยพบว่ามีความแตกต่างมากที่สุดในการพยากรณ์ราคาโกโก้ ซึ่งอาจเป็นผลมาจากความผันผวนสูงของราคาและอิทธิพลจากปัจจัยหลายอย่าง เช่น สภาพอากาศ การเมือง และเศรษฐกิจโลก ในขณะที่พบความแตกต่างน้อยที่สุดในการพยากรณ์ราคาน้ำตาล (สำหรับ RMSE และ MAE) และน้ำส้ม (สำหรับ MAPE) ซึ่งอาจเป็นเพราะราคาของสินค้าเหล่านี้มีความผันผวนน้อยกว่าหรือมีรูปแบบที่ชัดเจนกว่า ทำให้ ARIMA สามารถจับรูปแบบได้ใกล้เคียงกับ MLP มากขึ้น อย่างไรก็ตาม MLP ยังคงแสดงประสิทธิภาพที่เหนือกว่าในทุกกรณี ซึ่งสะท้อนให้เห็นถึงความสามารถในการใช้ประโยชน์จากข้อมูลจำนวนมากในการเรียนรู้และปรับปรุงประสิทธิภาพการพยากรณ์ได้ดีกว่า ARIMA โดยเฉพาะอย่างยิ่งในบริบทของตลาดสินค้าโภคภัณฑ์ที่มีความซับซ้อนและมีการเปลี่ยนแปลงอยู่ตลอดเวลา

5.2 อภิปรายผล

จากผลการวิจัยพบว่าโมเดล MLP แสดงประสิทธิภาพที่เหนือกว่า ARIMA ในการพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ทั้ง 6 ชนิด โดย MLP มีค่าความคลาดเคลื่อนที่ต่ำกว่าในทุกเกณฑ์การประเมิน ได้แก่ RMSE MAE และ MAPE ซึ่งสอดคล้องกับสมมติฐานที่ตั้งไว้ว่าเทคโนโลยีการเรียนรู้ของเครื่องสามารถปรับโมเดลให้เหมาะสมกับข้อมูลได้อย่างมีประสิทธิภาพ เนื่องจากสามารถพยากรณ์ได้ค่าประเมินประสิทธิภาพของโมเดลได้ดีกว่าวิธีการพยากรณ์ทางสถิติแบบดั้งเดิม และสามารถปรับปรุงและปรับแต่งโครงสร้างของโมเดลให้เข้ากับลักษณะของข้อมูลและลำดับข้อมูลที่ซับซ้อนได้ดีขึ้น

ผลการวิจัยนี้สอดคล้องกับงานวิจัยที่ผ่านมาที่พบว่าโมเดลการเรียนรู้ของเครื่องมีประสิทธิภาพสูงกว่าโมเดลทางสถิติแบบดั้งเดิมในการพยากรณ์ข้อมูลอนุกรมเวลา เช่น งานวิจัยของ Zhang P. 2003 [18] ซึ่งพบว่าโครงข่ายประสาทเทียมสามารถพยากรณ์ข้อมูลอนุกรมเวลาได้ดีกว่า ARIMA เมื่อมีการพิจารณาความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นในข้อมูล นอกจากนี้

ผลการวิจัยของ Fischer et al. 2018 [19] ยังสนับสนุนว่าการใช้เทคโนโลยีการเรียนรู้ของเครื่องในการพยากรณ์ตลาดหุ้นมีความแม่นยำสูงกว่าวิธีการทางสถิติแบบดั้งเดิมเช่นกัน

ความสามารถของ MLP ในการจับความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นในข้อมูล ทำให้สามารถเรียนรู้และปรับตัวกับการเปลี่ยนแปลงของข้อมูลได้ดีกว่า ARIMA นอกจากนี้ MLP ยังสามารถจัดการกับ Outliers และ Noise ในข้อมูลได้ดีกว่า ทำให้ผลการพยากรณ์มีความแม่นยำสูงขึ้น การปรับตัวต่อข้อมูลที่ไม่เป็นสถานะนิ่งและการเรียนรู้จากข้อมูลที่มีการเปลี่ยนแปลงอย่างรวดเร็ว ทำให้ MLP สามารถพยากรณ์ราคาปิดของสินค้าโภคภัณฑ์ที่มีความผันผวนสูงได้ดีกว่า ARIMA

ข้อจำกัดของการวิจัยนี้คือการใช้ข้อมูลราคาปิดของสินค้าโภคภัณฑ์เพียง 6 ชนิดเท่านั้น ซึ่งอาจไม่ครอบคลุมสินค้าที่มีความหลากหลายทางด้านลักษณะและพฤติกรรมการเปลี่ยนแปลงของราคา นอกจากนี้ การใช้ข้อมูลอนุกรมเวลาในช่วงเวลาที่จำกัดอาจส่งผลต่อความทั่วไปของผลการวิจัยในบริบทอื่น ๆ

ผลการวิจัยนี้แสดงให้เห็นถึงศักยภาพของการใช้เทคโนโลยีการเรียนรู้ของเครื่องในการพยากรณ์ความต้องการสินค้าโภคภัณฑ์ ซึ่งสามารถนำไปประยุกต์ใช้ในด้านอื่น ๆ เช่น การพยากรณ์ยอดขาย การบริหารจัดการสินค้าคงคลัง หรือการวางแผนการผลิตในอุตสาหกรรมต่าง ๆ การวิจัยเพิ่มเติมอาจเน้นไปที่การใช้ข้อมูลที่หลากหลายและวิธีการพยากรณ์ที่ผสมผสานระหว่างวิธีการเรียนรู้ของเครื่องกับวิธีการทางสถิติเพื่อเพิ่มความแม่นยำในการพยากรณ์ในอนาคต

5.3 ข้อเสนอแนะ

การวิจัยครั้งนี้มีข้อเสนอแนะหลายประการสำหรับการวิจัยในอนาคต การประยุกต์ใช้วิธีการเรียนรู้ของเครื่อง (Machine Learning) เช่น Multi-Layer Perceptron (MLP) ในการพยากรณ์ข้อมูลอนุกรมเวลาของสินค้าโภคภัณฑ์ได้แสดงให้เห็นถึงประสิทธิภาพที่เหนือกว่าเมื่อเทียบกับวิธีการพยากรณ์ทางสถิติแบบดั้งเดิม เช่น ARIMA ดังนั้น ข้อเสนอแนะคือการสำรวจวิธีการเรียนรู้ของเครื่องเพิ่มเติม เช่น Long Short-Term Memory (LSTM) หรือ Recurrent Neural Network (RNN) ที่สามารถจับความสัมพันธ์ที่ยาวนานในข้อมูลอนุกรมเวลาได้ดีขึ้น นอกจากนี้ ควรพิจารณานำข้อมูลที่มีความหลากหลายและครอบคลุมมากขึ้นมาใช้ในการพยากรณ์ เพื่อให้ได้ผลการวิจัยที่มีความทั่วไปและเชื่อถือได้มากขึ้น การรวมข้อมูลจากหลายแหล่งและการประยุกต์ใช้วิธีการพยากรณ์แบบผสมผสานระหว่างวิธีการเรียนรู้ของเครื่องและวิธีการทางสถิติก็อาจเป็นทางเลือกที่ดีเพื่อเพิ่มความแม่นยำในการพยากรณ์ นอกจากนี้ การวิจัยในอนาคตควรเน้นไปที่การวิเคราะห์ปัจจัยที่มีผลต่อความผันผวนของราคาสินค้าโภคภัณฑ์ เพื่อปรับปรุงประสิทธิภาพของ

โมเดลและให้คำแนะนำในการตัดสินใจที่แม่นยำยิ่งขึ้นในบริบทของการบริหารจัดการสินค้าคงคลัง
และการวางแผนการผลิต



บรรณานุกรม

- [1] S. Wang, C. Li, and A. Lim, "Why Are the ARIMA and SARIMA not Sufficient," Apr. 2019, Accessed: Aug. 20, 2023. [Online]. Available: <https://arxiv.org/abs/1904.07632v3>
- [2] V. Kotu and B. Deshpande, "Time Series Forecasting," *Data Science*, pp. 395–445, 2019, doi: 10.1016/B978-0-12-814761-0.00012-5.
- [3] "What Is Machine Learning (ML)? | IBM." Accessed: Jun. 13, 2024. [Online]. Available: <https://www.ibm.com/topics/machine-learning>
- [4] "What is a Multilayer Perceptron (MLP) or a Feedforward Neural Network (FNN)? - AIML.com." Accessed: Jun. 13, 2024. [Online]. Available: <https://aiml.com/what-is-a-multilayer-perceptron-mlp/>
- [5] S.-A. Chen *et al.*, "TSMixer: An All-MLP Architecture for Time Series Forecasting," Mar. 2023, Accessed: Mar. 31, 2024. [Online]. Available: <https://arxiv.org/abs/2303.06053v5>
- [6] E. M. de Oliveira and F. L. Cyrino Oliveira, "Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods," *Energy*, vol. 144, pp. 776–788, Feb. 2018, doi: 10.1016/J.ENERGY.2017.12.049.
- [7] M. Navratil and A. Kolkova, "Decomposition and forecasting time series in business economy using prophet forecasting model," *Central European Business Review*, vol. 8, no. 4, pp. 26–39, 2019, doi: 10.18267/J.CEBR.221.
- [8] A. M. C. H. Attanayake, S. S. N. Perera, and U. P. Liyanage, "COMBINING FORECASTS OF ARIMA AND EXPONENTIAL SMOOTHING MODELS," *Adv Appl Stat*, vol. 59, no. 2, pp. 199–208, Dec. 2019, doi: 10.17654/AS059020199.
- [9] B. Kumar Jha and S. Pande, "Time Series Forecasting Model for Supermarket Sales using FB-Prophet," *Proceedings - 5th International Conference on Computing Methodologies and Communication, ICCMC 2021*, pp. 547–554, Apr. 2021, doi: 10.1109/ICCMC51019.2021.9418033.
- [10] S. Arslan, "A hybrid forecasting model using LSTM and Prophet for energy consumption with decomposition of time series data," *PeerJ Comput Sci*, vol. 8, p. e1001, Oct. 2022, doi: 10.7717/peerj-cs.1001.
- [11] V. Kramar and V. Alchakov, "Time-Series Forecasting of Seasonal Data Using Machine Learning Methods," *Algorithms*, vol. 16, no. 5, 2023, doi: 10.3390/a16050248.

- [12] S. J. G., C. P., and U. M. Rajasekaran, "Time-series analysis and Flood Prediction using a Deep Learning Approach," in *2022 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET)*, 2022, pp. 139–142. doi: 10.1109/WiSPNET54241.2022.9767102.
- [13] Md. M. Rahman *et al.*, "A comprehensive study and performance analysis of deep neural network-based approaches in wind time-series forecasting," *J Reliab Intell Environ*, vol. 9, no. 2, pp. 183–200, 2023, doi: 10.1007/s40860-021-00166-x.
- [14] J. Guo, P. Lin, L. Zhang, Y. Pan, and Z. Xiao, "Dynamic adaptive encoder-decoder deep learning networks for multivariate time series forecasting of building energy consumption," *Appl Energy*, vol. 350, p. 121803, 2023, doi: <https://doi.org/10.1016/j.apenergy.2023.121803>.
- [15] A. Zeng, M. Chen, L. Zhang, and Q. Xu, "Are Transformers Effective for Time Series Forecasting?" Oct. 2022. doi: 10.48550/arXiv.2205.13504.
- [16] "Commodities Futures Prices & Day Charts - Yahoo Finance." Accessed: Jun. 13, 2024. [Online]. Available: <https://finance.yahoo.com/commodities>
- [17] "Rolling Forecast Guide | FP&A Best Practices Tutorial." Accessed: Jul. 01, 2024. [Online]. Available: <https://www.wallstreetprep.com/knowledge/rolling-forecast-best-practices-guide-fpa-professionals/>
- [18] P. G. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, pp. 159–175, Jan. 2003, doi: 10.1016/S0925-2312(01)00702-0.
- [19] T. Fischer and C. Krauss, "Deep learning with long short-term memory networks for financial market predictions," *Eur J Oper Res*, vol. 270, no. 2, pp. 654–669, Oct. 2018, doi: 10.1016/J.EJOR.2017.11.054.

