

การศึกษาเชิงเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก
สำหรับการพยากรณ์ราคาหุ้นกลุ่มเทคโนโลยีโดยใช้คะแนนวิเคราะห์ความรู้สึก
จากข่าวและปัจจัยทางเศรษฐกิจ

A COMPARATIVE STUDY OF MACHINE LEARNING AND DEEP
LEARNING MODELS FOR TECHNOLOGY STOCK PRICE PREDICTION
USING NEWS SENTIMENT AND ECONOMIC INDICATOR



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาสถิติและการวิเคราะห์ธุรกิจ
ภาควิชาสถิติ คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2568

KMITL-2025-SC-M-050-050

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

A COMPARATIVE STUDY OF MACHINE LEARNING AND DEEP
LEARNING MODELS FOR TECHNOLOGY STOCK PRICE PREDICTION
USING NEWS SENTIMENT AND ECONOMIC INDICATOR



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENTS FOR THE DEGREE OF MASTER OF SCIENCE IN STATISTICS AND
BUSINESS ANALYTICS

DEPARTMENT OF STATISTIC SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2025

KMITL-2025-SC-M-050-050

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2025

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRAB

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

| | |
|---------------------------------|--|
| หัวข้อการค้นคว้าอิสระ | การศึกษาเชิงเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้นกลุ่มเทคโนโลยีโดยใช้คะแนนวิเคราะห์ความรู้สึกจากข่าวและปัจจัยทางเศรษฐกิจ |
| ชื่อนักศึกษา | ญาดา สรณะสมบุรณ์ |
| รหัสประจำตัว | 66056020 |
| ปริญญา | วิทยาศาสตรมหาบัณฑิต (สถิติและการวิเคราะห์ธุรกิจ) |
| ภาควิชา | สถิติ |
| พ.ศ. | 2568 |
| อาจารย์ที่ปรึกษาการค้นคว้าอิสระ | ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์ |

บทคัดย่อ

การศึกษาในครั้งนี้ได้พัฒนาแบบจำลองการพยากรณ์ราคาปิดของหุ้นเทคโนโลยีชั้นนำ 5 ราย ได้แก่ GOOGLE, MSFT, AAPL, NVDA และ META โดยใช้เทคนิคขั้นสูงทั้งจากการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ได้แก่ Light Gradient Boosting Machine (LightGBM), Extreme Gradient Boosting (XGBoost), Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU) และ Long Short-Term Memory (LSTM) กรอบการวิเคราะห์ที่ในงานวิจัยนี้ได้้นำคะแนนอารมณ์ที่สกัดจากบทความข่าวทางการเงินซึ่งเกี่ยวข้องกับหุ้นแต่ละตัว โดยใช้เครื่องมือ VADER Sentiment Analysis มาผนวกร่วมกับตัวแปรทางเศรษฐกิจมหภาคหลากหลายรายการ ประสิทธิภาพของแบบจำลองได้รับการประเมินแยกกันสำหรับหุ้นแต่ละราย โดยใช้ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเป็นตัวชี้วัดหลัก และเพื่อทดสอบความแตกต่างอย่างมีนัยสำคัญทางสถิติของประสิทธิภาพระหว่างแบบจำลองทั้งห้า ได้ใช้การทดสอบของ Friedman ซึ่งเป็นสถิติแบบไม่อิงพารามิเตอร์ จากนั้นจึงดำเนินการทดสอบ Wilcoxon signed-rank สำหรับการเปรียบเทียบรายคู่ ผลการทดลองพบว่า XGBoost ให้ผลการพยากรณ์ที่ดีที่สุดสำหรับหุ้น MSFT และ AAPL ในขณะที่ GRU แสดงผลลัพธ์เหนือกว่าสำหรับหุ้น NVDA และ META ส่วน RNN ให้ความแม่นยำสูงสุดในการพยากรณ์ราคาปิดของหุ้น GOOGLE

คำสำคัญ : หุ้นเทคโนโลยี, การเรียนรู้ของเครื่อง, โครงข่ายประสาทเทียมเชิงลึก, วิเคราะห์อารมณ์จากข่าว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

| | |
|----------------------------------|--|
| Independent Study Title | A Comparative Study of Machine Learning and Deep Learning Models for Technology Stock Price Prediction Using News Sentiment and Economic Indicator |
| Student Name | Yada Soranasomboon |
| Student ID | 66056020 |
| Degree | Master of Science (Statistics and Business Analytics) |
| Department | Statistics |
| Year | 2025 |
| Independent Study Advisor | Asst.Prof.Dr.Pornpimol Chaiwuttisak |

Abstract

This study developed predictive models for the closing prices of five leading technology stocks: GOOGL, MSFT, AAPL, NVDA, and META by employing five advanced machine learning and deep learning techniques: Light Gradient Boosting Machine (LightGBM), Extreme Gradient Boosting (XGBoost), Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), and Long Short-Term Memory (LSTM). The modeling framework integrated sentiment scores derived from financial news articles specific to each stock using the VADER Sentiment Analysis tool, in conjunction with a range of macroeconomic indicators. Model performance was evaluated separately for each stock using Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE) as primary metrics. To determine whether statistically significant differences existed among the predictive performance of the models across all stocks, the Friedman test was employed, followed by the Wilcoxon signed-rank test for post-hoc pairwise comparisons. The empirical results indicated that XGBoost achieved superior predictive accuracy for MSFT and AAPL, GRU outperformed other models for NVDA and META, while RNN yielded the most accurate forecasts for GOOGL.

Keywords : Technology Stocks, Machine Learning, Deep Learning Networks, Sentiment Analysis from News Articles

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

การวิจัยเรื่อง “การศึกษาเชิงเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้นกลุ่มเทคโนโลยีโดยใช้คะแนนวิเคราะห์ความรู้สึกจากข่าวและปัจจัยทางเศรษฐกิจ” ฉบับนี้สำเร็จลุล่วงลงได้ด้วยความกรุณาอย่างยิ่งจากอาจารย์ที่ปรึกษา ผศ.ดร.พรพิมล ชัยวุฒิ ศักดิ์ ที่ให้คำแนะนำและช่วยเหลือในทุกขั้นตอนที่ศึกษารายวิชาโครงการทางสถิติ ตลอดจนดำเนินการแล้วเสร็จ ผู้วิจัยรู้สึกซาบซึ้งในความกรุณา และกราบขอบพระคุณอาจารย์เป็นอย่างสูง ณ โอกาสนี้

ขอกราบขอบพระคุณอาจารย์สาขาสถิติ คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ทุกท่านที่เป็นผู้ให้ความรู้แก่ผู้วิจัย เพื่อนำมาประยุกต์ใช้ในการทำการค้นคว้าอิสระ จนทำให้ผู้วิจัยประสบความสำเร็จในการทำงานวิจัยฉบับนี้ด้วยดี

ขอขอบพระคุณ คุณพ่อ คุณแม่ พี่สาว ที่ได้ให้ความรัก ความเมตตา และการสนับสนุนด้านต่าง ๆ มาโดยตลอด ทำให้ข้าพเจ้าประสบความสำเร็จในการศึกษาในครั้งนี้ ขอขอบคุณสำหรับทุกสิ่งทุกอย่างที่ท่านทำให้เสมอมา

ท้ายนี้ผู้วิจัยหวังเป็นอย่างยิ่งว่าการวิจัยเรื่อง “การศึกษาเชิงเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้นกลุ่มเทคโนโลยีโดยใช้คะแนนวิเคราะห์ความรู้สึกจากข่าวและปัจจัยทางเศรษฐกิจ” จะเป็นประโยชน์และเป็นแนวทางในการศึกษาและพัฒนาแบบจำลองการทำนายราคาหุ้นกลุ่มเทคโนโลยีได้

นางสาวญาดา สรณะสมบุรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

| | หน้า |
|---|----------|
| บทคัดย่อภาษาไทย | ก |
| บทคัดย่อภาษาอังกฤษ | ข |
| กิตติกรรมประกาศ | ค |
| สารบัญ | ง |
| สารบัญตาราง | ช |
| สารบัญรูป | ญ |
| บทที่ 1 บทนำ | 1 |
| 1.1 ความเป็นมาและความสำคัญของงานวิจัย/ปัญหา | 1 |
| 1.2 วัตถุประสงค์ของงานวิจัย | 3 |
| 1.3 สมมติฐานการวิจัย | 4 |
| 1.4 ขอบเขตของงานวิจัย | 4 |
| 1.5 ประโยชน์ที่คาดว่าจะได้รับ | 5 |
| บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง | 6 |
| 2.1 อนุกรมเวลา (Time Series) | 6 |
| 2.2 การวิเคราะห์ความรู้สึก (Sentiment Analysis) | 6 |
| 2.3 VADER (Valence Aware Dictionary and Sentiment Reasoner) | 6 |
| 2.4 การเรียนรู้ของเครื่อง (Machine Learning) | 8 |
| 2.5 Extreme Gradient Boosting (XGBoost) | 9 |
| 2.6 Light Gradient Boosting Machine (LightGBM) | 10 |
| 2.7 การเรียนรู้เชิงลึก (Deep learning) | 10 |
| 2.8 Recurrent Neural Network (RNN) | 12 |
| 2.9 Long Short-Term Memory (LSTM) | 14 |
| 2.10 Gated Recurrent Unit (GRU) | 16 |
| 2.11 Permutation Feature Importance (PFI) | 18 |
| 2.12 การทดสอบแบบจับคู่ (Paired T-Test) | 19 |
| 2.13 การทดสอบ Wilcoxon signed rank test | 19 |
| 2.14 การวิเคราะห์ความแปรปรวนแบบวัดซ้ำ (Repeated Measures ANOVA) | 20 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

| | หน้า |
|---|-----------|
| 2.15 การทดสอบของฟริดแมน (Friedman test) | 20 |
| 2.16 การประเมินความแม่นยำแบบจำลอง | 21 |
| 2.17 งานวิจัยที่เกี่ยวข้อง | 22 |
| 2.17.1 งานวิจัยที่ใช้การวิเคราะห์ความรู้สึกในการทำนายราคาหุ้น | 22 |
| 2.17.2 งานวิจัยที่ใช้เฉพาะราคาหุ้นในการทำนาย | 23 |
| 2.17.3 งานวิจัยที่ใช้ปัจจัยทางเศรษฐกิจในการทำนายราคาหุ้น | 25 |
| บทที่ 3 วิธีการดำเนินงานวิจัย | 27 |
| 3.1 ข้อมูลที่ใช้ในงานวิจัย | 27 |
| 3.2 เครื่องมือที่ใช้ในการวิจัย | 29 |
| 3.3 การจัดการข้อมูล (Data processing) | 29 |
| 3.3.1 การดึงข้อมูล | 29 |
| 3.3.2 การจัดเตรียมข้อมูลให้พร้อมสำหรับการประมวลผล | 30 |
| 3.4 การวิเคราะห์ความรู้สึกจากข่าว | 31 |
| 3.5 สร้างแบบจำลอง | 31 |
| 3.5.1 การปรับช่วงข้อมูล (Data Normalization) | 31 |
| 3.5.2 การแบ่งข้อมูล | 31 |
| 3.5.3 การสร้างแบบจำลองทำนายราคาปิดของหุ้น | 31 |
| 3.6 การวัดประสิทธิภาพแบบจำลอง | 35 |
| 3.6.1 การเปรียบเทียบประสิทธิภาพของทุกแบบจำลองของหุ้นเทคโนโลยีแต่ละตัว | 35 |
| 3.6.2 การวัดประสิทธิภาพของแบบจำลอง | 36 |
| 3.6.3 การประเมินประสิทธิภาพของแบบจำลอง | 36 |
| 3.7 การวิเคราะห์ความสำคัญของตัวแปร | 37 |
| บทที่ 4 ผลการวิจัยและการอภิปรายผล | 38 |
| 4.1 ผลการวิเคราะห์การเตรียมข้อมูล | 38 |
| 4.1.1 ผลการสำรวจข้อมูลราคาปิดของหุ้นเทคโนโลยีและปัจจัยทางเศรษฐกิจต่าง ๆ | 38 |
| 4.1.2 ผลการจัดการค่านอกเกณฑ์ | 39 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

| | หน้า |
|---|-----------|
| 4.2 ผลการวิเคราะห์ความรู้สึกจากข่าว | 41 |
| 4.3 ผลการวิเคราะห์การสร้างแบบจำลองทำนายราคาปิดของหุ้น | 41 |
| 4.4 ผลการวัดประสิทธิภาพของแบบจำลอง | 43 |
| 4.4.1 ผลการเปรียบเทียบประสิทธิภาพของทุกแบบจำลองของหุ้นเทคโนโลยีแต่ละตัว | 43 |
| 4.4.2 ผลการวัดประสิทธิภาพของแบบจำลอง | 52 |
| 4.4.3 ผลการประเมินประสิทธิภาพของแบบจำลอง | 53 |
| 4.5 ผลการวิเคราะห์ความสำคัญของตัวแปร | 57 |
| บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ | 62 |
| 5.1 สรุปผลการวิจัย | 62 |
| 5.1.1 สรุปแบบจำลองที่เหมาะสมในการทำนายราคาปิดของหุ้นเทคโนโลยี | 62 |
| 5.1.2 สรุปผลประเมินประสิทธิภาพแบบจำลองการทำนาย | 63 |
| 5.1.3 สรุปผลการวิเคราะห์ตัวแปรที่มีอิทธิพลต่อราคาของหุ้นเทคโนโลยี | 63 |
| 5.2 อภิปรายผลการวิจัย | 64 |
| 5.2.1 แบบจำลองทำนายราคาหุ้นเทคโนโลยีแต่ละตัว | 65 |
| 5.2.2 ตัวแปรทางเศรษฐกิจที่มีผลกระทบต่อราคาปิดของหุ้น | 65 |
| 5.3 ข้อจำกัดของงานวิจัย | 69 |
| 5.4 ข้อเสนอแนะ | 69 |
| 5.4.1 ข้อเสนอแนะในการนำผลการวิจัยไปใช้ | 69 |
| 5.4.2 ข้อเสนอแนะในการทำวิจัยครั้งต่อไป | 69 |
| เอกสารอ้างอิง | 70 |
| ภาคผนวก | 76 |
| ประวัติผู้เขียน | 90 |

สารบัญตาราง

| ตารางที่ | หน้า |
|--|------|
| 3.1 ตัวแปรที่ใช้ในงานวิจัย | 27 |
| 3.2 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง LightGBM | 32 |
| 3.3 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง XGBoost | 33 |
| 3.4 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง RNN | 34 |
| 3.5 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง LSTM | 34 |
| 3.6 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง GRU | 35 |
| 4.1 รายละเอียดข้อมูลราคาปิดของหุ้นเทคโนโลยี และตัวแปรทางเศรษฐกิจต่าง ๆ | 38 |
| 4.2 ค่าพารามิเตอร์ของแบบจำลอง LightGBM | 42 |
| 4.3 ค่าพารามิเตอร์ของแบบจำลอง XGBoost | 42 |
| 4.4 ค่าพารามิเตอร์ของแบบจำลอง RNN | 42 |
| 4.5 ค่าพารามิเตอร์ของแบบจำลอง GRU | 43 |
| 4.6 ค่าพารามิเตอร์ของแบบจำลอง LSTM | 43 |
| 4.7 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ด้วยวิธีต่าง ๆ | 44 |
| 4.8 ผลการทดสอบฟริตแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ด้วยวิธีต่าง ๆ | 44 |
| 4.9 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ด้วยวิธีต่าง ๆ | 45 |
| 4.10 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT ด้วยวิธีต่าง ๆ | 45 |
| 4.11 ผลการทดสอบฟริตแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT ด้วยวิธีต่าง ๆ | 46 |
| 4.12 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT ด้วยวิธีต่าง ๆ | 46 |
| 4.13 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL ด้วยวิธีต่าง ๆ | 47 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

| ตารางที่ | หน้า |
|---|------|
| 4.14 ผลการทดสอบฟรีดแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL ด้วยวิธีต่าง ๆ | 47 |
| 4.15 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL ด้วยวิธีต่าง ๆ | 48 |
| 4.16 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ด้วยวิธีต่าง ๆ | 49 |
| 4.17 ผลการทดสอบฟรีดแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ด้วยวิธีต่าง ๆ | 49 |
| 4.18 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ด้วยวิธีต่าง ๆ | 50 |
| 4.19 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META ด้วยวิธีต่าง ๆ | 50 |
| 4.20 ผลการทดสอบฟรีดแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META ด้วยวิธีต่าง ๆ | 51 |
| 4.21 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META ด้วยวิธีต่าง ๆ | 51 |
| 4.22 ประสิทธิภาพของแบบจำลองหุ้นเทคโนโลยีด้วยอัลกอริทึมต่าง ๆ ด้วยค่า MAE | 52 |
| 4.23 ประสิทธิภาพของแบบจำลองหุ้นเทคโนโลยีด้วยอัลกอริทึมต่าง ๆ ด้วยค่า MAPE | 52 |
| 4.24 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น GOOGL | 53 |
| 4.25 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น GOOGL | 53 |
| 4.26 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น MSFT | 54 |
| 4.27 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น MSFT | 54 |
| 4.28 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น AAPL | 54 |
| 4.29 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น AAPL | 55 |
| 4.30 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น NVDA | 55 |
| 4.31 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น NVDA | 56 |
| 4.32 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น META | 56 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

| ตารางที่ | หน้า |
|--|------|
| 4.33 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น META | 56 |
| 4.34 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง RNN ในการทำนายราคาปิดหุ้น GOOGL | 57 |
| 4.35 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง XGBoost ในการทำนายราคาปิดหุ้น MSFT | 58 |
| 4.36 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง XGBoost ในการทำนายราคาปิดหุ้น AAPL | 59 |
| 4.37 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง GRU ในการทำนายราคาปิดหุ้น NVDA | 60 |
| 4.38 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง GRU ในการทำนายราคาปิดหุ้น META | 61 |

สารบัญรูป

| รูปที่ | หน้า |
|--|------|
| 2.1 กระบวนการทำงานของ XGBoost | 9 |
| 2.2 กระบวนการทำงานของ LightGBM | 10 |
| 2.3 กระบวนการทำงานของ Deep Learning | 11 |
| 2.4 กระบวนการทำงานของ RNN | 12 |
| 2.5 ลักษณะการทำงานของ RNN | 13 |
| 2.6 กระบวนการทำงานของ LSTM | 14 |
| 2.7 ลักษณะการทำงานหลักของ LSTM | 15 |
| 2.8 ลักษณะการทำงานของ GRU | 17 |
| 4.1 แผนภาพกล่องของข้อมูลราคาปิดของหุ้นเทคโนโลยี และตัวแปรทางเศรษฐกิจต่าง ๆ | 40 |
| 4.2 ตัวอย่างการแปลงค่าอารมณ์จากข้อมูลเนื้อหาสรุปข่าว | 41 |

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การลงทุนเป็นการใช้เงินเพื่อสร้างผลตอบแทนในอนาคต โดยการนำเงินที่ได้จากการออมไปซื้อสินทรัพย์ต่าง ๆ เช่น หุ้น อสังหาริมทรัพย์ หรือพันธบัตร เพื่อให้มีมูลค่าเพิ่มขึ้นในอนาคต ซึ่งในปัจจุบันการออมเงินเพียงอย่างเดียวอาจไม่สามารถรักษามูลค่าของเงินในระยะยาวได้ เนื่องจากภาวะเงินเฟ้อส่งผลให้ระดับราคาสินค้าและบริการเพิ่มสูงขึ้นอย่างต่อเนื่อง ขณะที่อัตราเงินเฟ้อและค่าจ้างอาจไม่ได้ปรับตัวขึ้นตามอัตราเงินเฟ้อ ส่งผลให้อำนาจการซื้อต่ำลง มูลค่าเงินลดลง และทำให้รายได้ที่หามาอาจไม่เพียงพอต่อการยังชีพ ซึ่งอัตราเงินเฟ้อทั่วไปของประเทศไทยในปี 2567 เฉลี่ยอยู่ที่ 0.4% ต่อปี (ศูนย์วิจัยกสิกรไทย, 2567) แต่อัตราดอกเบี้ยเงินฝากในประเทศไทยอยู่ที่ 0.25% ถึง 0.30% ต่อปี (ธนาคารแห่งประเทศไทย, 2568) ทำให้อัตราผลตอบแทนที่แท้จริงติดลบ ดังนั้นจึงจำเป็นต้องมองหาการลงทุนที่จะสามารถเอาชนะเงินเฟ้อได้ การลงทุนมีหลายรูปแบบไม่ว่าจะเป็น การลงทุนในตราสารหนี้ การลงทุนในพันธบัตรและหุ้นกู้ การลงทุนในหุ้น การลงทุนในอสังหาริมทรัพย์ และการลงทุนในของมีค่าและสินทรัพย์ดิจิทัล ซึ่งแต่ละการลงทุนนั้นมีอัตราผลตอบแทน และความเสี่ยงที่แตกต่างกัน

การลงทุนในหุ้นนั้นเป็นการลงทุนที่มีสภาพคล่องค่อนข้างสูง เมื่อเปรียบเทียบกับการลงทุนประเภทอื่น เช่น อสังหาริมทรัพย์ ทองคำ หุ้นสามารถป้องกันเงินเฟ้อได้ โดยหุ้นมีแนวโน้มที่จะเติบโตตามภาวะเศรษฐกิจและรายได้ของบริษัท ในขณะที่ตราสารหนี้อาจไม่สามารถรักษามูลค่าเมื่อเผชิญกับเงินเฟ้อสูง ๆ ได้ เพราะมีอัตราดอกเบี้ยที่คงที่ แต่ผลตอบแทนจากหุ้นไม่จำกัดเพียงอัตราดอกเบี้ยที่แน่นอนเหมือนตราสารหนี้ หากธุรกิจเติบโตดีผู้ถือหุ้นอาจได้รับผลตอบแทนที่สูงขึ้นอย่างต่อเนื่องจากราคาหุ้นที่เพิ่มขึ้น รวมถึงเงินปันผลจากผลกำไรของบริษัท และการถือหุ้นทำให้ผู้ลงทุนมีสิทธิในการเป็นเจ้าของร่วมในบริษัท มีสิทธิในการออกเสียงและเข้าร่วมประชุมผู้ถือหุ้น ซึ่งผู้ลงทุนในตราสารหนี้หรือหุ้นกู้ไม่ได้มีสิทธิเช่นนี้ แต่มีเพียงสิทธิในการรับดอกเบี้ยเท่านั้น อย่างไรก็ตามการลงทุนในหุ้นมีความเสี่ยงสูงกว่าตราสารหนี้ เพราะราคาหุ้นมีความผันผวนตามภาวะตลาดและปัจจัยต่าง ๆ

ในช่วงหลายปีที่ผ่านมาตลาดหุ้นอเมริการันนั้น กำลังได้รับความนิยมเพิ่มขึ้นอย่างต่อเนื่องในหมู่นักลงทุนไทย เนื่องจากเป็นตลาดหุ้นที่ใหญ่และมีสภาพคล่องสูงที่สุดในโลก ตลาดหุ้นอเมริกาเป็นแหล่งรวมบริษัทยักษ์ใหญ่ระดับโลกมากมาย ให้ผลตอบแทนที่น่าสนใจ โดยดัชนี S&P 500 ให้เอกสารนี้เป็นเอกสารที่สวอนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผลตอบแทนเฉลี่ยประมาณ 10% ต่อปีในระยะยาว (พิชัย ยอดพฤติการณ์, 2567) และการลงทุนในหุ้นอเมริกาช่วยให้นักลงทุนไทยสามารถกระจายความเสี่ยงในพอร์ตการลงทุนได้ดียิ่งขึ้น โดยไม่พึ่งพาเศรษฐกิจไทยเพียงอย่างเดียว ในปัจจุบันปัญญาประดิษฐ์ (AI) ได้เข้ามามีบทบาทสำคัญในชีวิตประจำวันของเราอย่างมาก ตั้งแต่การใช้ผู้ช่วยเสมือน เช่น Siri หรือ Google Assistant การแนะนำเนื้อหาบนโซเชียลมีเดีย ไปจนถึงการทำธุรกรรมทางการเงิน การประยุกต์ใช้ AI เหล่านี้ช่วยเพิ่มความสะดวกสบายและประสิทธิภาพในชีวิตประจำวันของเรา (AIGEN, 2564) การเติบโตของ AI ส่งผลให้หุ้นในกลุ่มเทคโนโลยีมีความน่าสนใจมากขึ้น บริษัทที่มีการพัฒนาและนำ AI มาใช้ในผลิตภัณฑ์และบริการของตน เช่น Alphabet Inc. (GOOGL), Microsoft Corporation (MSFT), Apple Inc. (AAPL), NVIDIA Corporation (NVDA) และ Meta Platforms Inc. (META) อย่างไรก็ตาม การลงทุนในหุ้นเทคโนโลยีควรพิจารณาปัจจัยต่าง ๆ เช่น นวัตกรรม ความเชี่ยวชาญ และความสามารถในการทำกำไรของบริษัท นอกจากนี้ ควรติดตามแนวโน้มของอุตสาหกรรมและการเปลี่ยนแปลงของตลาดอย่างใกล้ชิด เพื่อประเมินความเสี่ยงและโอกาสในการลงทุน (Mitrade, 2567) ดังนั้นในช่วงที่ AI เข้ามามีบทบาทในชีวิตประจำวันมากขึ้น จึงเป็นตัวเลือกที่น่าสนใจในการลงทุนในอนาคต

กลยุทธ์การลงทุนในหุ้นที่ช่วยลดความเสี่ยงและเพิ่มผลตอบแทนได้อย่างเหมาะสม แบ่งออกเป็น 2 วิธี ได้แก่ การวิเคราะห์ปัจจัยพื้นฐาน เช่น ทำการศึกษาบริษัทที่จะลงทุน ดูงบการเงิน อัตราเงินปันผลตอบแทน และความสามารถในการแข่งขัน และการวิเคราะห์ทางเทคนิค เป็นการคำนวณราคาทางคณิตศาสตร์ ในการวิเคราะห์แนวโน้มราคาหุ้นในอนาคต จะใช้เพื่อประกอบการตัดสินใจเลือกจังหวะเวลาในการซื้อหรือขายหุ้น ซึ่งราคาหุ้นนั้นจะผันผวนตามปัจจัย ๆ เช่น ข่าว ดัชนีราคาผู้บริโภค หรือ ฤดูกาล เป็นต้น ดังนั้นการวิเคราะห์หาปัจจัยที่ส่งผลต่อราคาหุ้นนั้น จะช่วยให้การวิเคราะห์แนวโน้ม แผนการลงทุน และคาดการณ์กระทบที่จะเกิดขึ้นได้แม่นยำมากยิ่งขึ้น

เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ได้รับความนิยมอย่างแพร่หลายในด้านการวิเคราะห์และพยากรณ์ราคาหุ้น เนื่องจากมีความสามารถในการเรียนรู้รูปแบบจากข้อมูลจำนวนมาก และสามารถสร้างแบบจำลองที่มีประสิทธิภาพในการคาดการณ์แนวโน้มของตลาดได้อย่างแม่นยำ จากการศึกษาของ Shahi et al. (2019) พบว่าการเปรียบเทียบประสิทธิภาพของแบบจำลอง Long Short-Term Memory (LSTM) และ Gated Recurrent Unit (GRU) โดยใช้ข้อมูลราคาหุ้นร่วมกับคะแนนอารมณ์จากข่าวการเงิน สามารถเพิ่มความแม่นยำของการพยากรณ์ได้ โดยใช้ค่าความคลาดเคลื่อนเฉลี่ย (MAE) เป็นเกณฑ์ในการวัดผลลัพธ์ ในขณะที่เดียวกันงานวิจัยของ Delpeche, Menon, & Du (2022) ได้สร้างแบบจำลองเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การทำนายราคาหุ้นโดยใช้ปัจจัยทางเศรษฐกิจร่วมกับเทคนิคการเรียนรู้เชิงลึก และใช้การวิเคราะห์องค์ประกอบหลัก (PCA) เพื่อคัดเลือกตัวแปรสำคัญ พบว่าโมเดลที่พัฒนาขึ้นมีความคลาดเคลื่อนเฉลี่ยเพียง 0.01537 และตัวแปรที่มีผลกระทบหลักต่อดัชนีตลาดหุ้น ได้แก่ หนี้สิน อัตราดอกเบี้ยของธนาคารกลางสหรัฐฯ ราคาน้ำมัน GDP และราคาที่อยู่อาศัย อย่างไรก็ตามจากการทบทวนวรรณกรรมพบว่างานวิจัยยังมีข้อจำกัดหลายประการเช่น การใช้ข้อมูลจากแหล่งเดียว ไม่ว่าจะเป็นข้อมูลข่าวสารหรือข้อมูลทางเศรษฐกิจ ส่งผลให้แบบจำลองอาจยังไม่สะท้อนภาพรวมของปัจจัยที่มีผลต่อราคาหุ้นได้อย่างครบถ้วน อีกทั้งการประเมินประสิทธิภาพของแบบจำลองมักอาศัยเพียงค่าความคลาดเคลื่อน เช่น MAE, RMSE หรือ MAPE ซึ่งแม้จะสะท้อนระดับความแม่นยำได้ในระดับหนึ่ง แต่ยังไม่สามารถระบุได้ว่าแบบจำลองแต่ละแบบมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติหรือไม่ นอกจากนี้งานวิจัยหลายชิ้นยังขาดการใช้วิธีการทดสอบสมมติฐานเชิงสถิติ เช่น การทดสอบ Paired Sample t-test เพื่อเปรียบเทียบระหว่างค่าทำนายกับค่าจริงอย่างเป็นระบบ ซึ่งเป็นขั้นตอนที่มีความสำคัญในการประเมินประสิทธิภาพของแบบจำลอง

ดังนั้นผู้วิจัยจึงเล็งเห็นความสำคัญของการทำนายราคาหุ้นโดยการผสมผสานข้อมูลจากหลายมิติ ได้แก่ ข้อมูลราคาหุ้น ข่าวสาร และตัวแปรทางเศรษฐกิจ ในการสร้างแบบจำลองการทำนายด้วยเทคนิคการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก พร้อมทั้งประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยเครื่องมือทางสถิติที่เหมาะสม เช่น ค่า MAE, MAPE และการทดสอบสมมติฐานทางสถิติ เพื่อให้สามารถระบุแบบจำลองที่มีประสิทธิภาพสูงสุดในการทำนายราคาหุ้นกลุ่มเทคโนโลยีได้อย่างแม่นยำ ตลอดจนวิเคราะห์ปัจจัยสำคัญที่ส่งผลต่อการเปลี่ยนแปลงของราคาหุ้น ซึ่งสามารถใช้เป็นแนวทางประกอบการตัดสินใจลงทุนได้อย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์ของงานวิจัย

- 1) สร้างแบบจำลองการทำนายราคาหุ้นด้วยการเรียนรู้ของเครื่อง 5 วิธี ได้แก่ LightGBM, XGBoost, RNN, GRU และ LSTM
- 2) วิเคราะห์และเปรียบเทียบประสิทธิภาพของแบบจำลอง เพื่อระบุแบบจำลองที่เหมาะสมที่สุด
- 3) วิเคราะห์ปัจจัยด้านข่าวสารและตัวแปรเศรษฐกิจที่ส่งผลต่อการเปลี่ยนแปลงของราคาปิดของหุ้นกลุ่มเทคโนโลยี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.3 สมมติฐานการวิจัย

- 1) แบบจำลองการทำนายราคาหุ้นเทคโนโลยีแต่ละวิธี ได้แก่ LightGBM, XGBoost, RNN, GRU และ LSTM ให้ผลการทำนายที่แตกต่างกันอย่างมีนัยสำคัญทางสถิติ
- 2) ราคาปิดของหุ้นที่ทำนายได้จากแบบจำลองไม่มีความแตกต่างอย่างมีนัยสำคัญจากราคาปิดจริงของหุ้น
- 3) คะแนนข่าว และปัจจัยทางเศรษฐกิจ ได้แก่ อัตราการว่างงานของสหรัฐฯ, อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, อัตราดอกเบี้ยที่กำหนดโดยธนาคารกลางสหรัฐฯ, ดัชนีค่าเงินดอลลาร์สหรัฐฯ, อัตราเงินเฟ้อ, ผลิตภัณฑ์มวลรวมในสหรัฐฯ, ดัชนีราคาผู้บริโภค, ยอดขายปลีก, ราคาทองคำ, ราคาน้ำมัน, สถานะข่าว, ดัชนี S&P 500, ดัชนี Nasdaq 100 และราคา Bitcoin ส่งผลต่อราคาปิดของหุ้น GOOGL (Alphabet), MSFT (Microsoft), AAPL (Apple), NVDA (NVIDIA), และ META (Meta Platforms)

1.4 ขอบเขตของงานวิจัย

การศึกษาในครั้งนี้ใช้ข้อมูลทุติยภูมิในการสร้างแบบจำลองทำนายราคาหุ้น ตั้งแต่ 1 มีนาคม พ.ศ. 2565 ถึง 28 กุมภาพันธ์ พ.ศ. 2568 จำนวน 753 วันประกอบไปด้วย

- 1) ราคาปิดรายวัน ของหุ้นอเมริกาในกลุ่มอุตสาหกรรมเทคโนโลยีและนวัตกรรม ที่เป็นส่วนหนึ่งของดัชนี S&P 500 ได้แก่ GOOGL (Alphabet), MSFT (Microsoft), AAPL (Apple), NVDA (NVIDIA), และ META (Meta Platforms) เนื่องจากบริษัทเหล่านี้จัดอยู่ในกลุ่ม Big Tech ซึ่งมีมูลค่าตลาดรวมคิดเป็นประมาณ 30% ของดัชนี S&P 500 (Bloomberg, 2023)

ซึ่งดัชนี S&P 500 มักถูกใช้เป็นตัวแทนของสุขภาพเศรษฐกิจสหรัฐฯ ดังนั้นความเคลื่อนไหวของราคาหุ้นในกลุ่ม Big Tech ย่อมมีผลกระทบต่อตลาดการเงินโดยรวม ทั้งยังสะท้อนถึงแนวโน้มของเศรษฐกิจดิจิทัล ซึ่งมีบทบาทสำคัญต่อ ผลิตภัณฑ์มวลรวมในประเทศ และการจ้างงานของประเทศ (Olufemi Ariyo, 2024) เก็บรวบรวมจากเว็บไซต์ investing.com

- 2) ข่าวจะเป็นการสรุปเนื้อหาข่าวที่เกี่ยวข้องกับราคาหุ้นทั้ง 5 ตัวนี้ ได้แก่ GOOGL, MSFT, AAPL, NVDA และ META โดยเก็บรวบรวมจาก Alpha Vantage News API ซึ่งเป็นบริการที่ให้ข้อมูลข่าวสารจากแหล่งข่าวทางการเงินที่น่าเชื่อถือ เช่น Benzinga, MarketWatch, CNBC, Business Insider เป็นต้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) ปัจจัยทางเศรษฐกิจที่เกี่ยวข้อง เก็บรวบรวมจากเว็บไซต์ investing.com และ tradingview.com ประกอบไปด้วย อัตราการว่างงานของสหรัฐฯ, อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, อัตราดอกเบี้ยที่กำหนดโดยธนาคารกลางสหรัฐอเมริกา, ดัชนีค่าเงินดอลลาร์สหรัฐฯ, อัตราเงินเฟ้อ, ผลิตภัณฑ์มวลรวมในสหรัฐอเมริกา, ดัชนีราคาผู้บริโภค, ยอดขายปลีก, ราคาทองคำ, ราคาน้ำมัน, สถานะข่าว, ดัชนี S&P 500, ดัชนี Nasdaq 100 และราคา Bitcoin

1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ช่วยให้นักลงทุนเข้าใจถึงกลไกและปัจจัยขับเคลื่อนตลาด และทำให้นักลงทุนตัดสินใจวางแผนใจซื้อขายหุ้นได้อย่างมีประสิทธิภาพ
- 2) เป็นแนวทางการตัดสินใจในการลงทุนของนักลงทุนที่สนใจเกี่ยวกับหุ้น GOOGLE, MSFT, AAPL, NVDA และ META ซึ่งการทำนายราคาช่วยให้ทราบถึงแนวโน้มของราคาว่าจะไปในทิศทางไหนในช่วงเวลานั้น ๆ ยังช่วยควบคุมความเสี่ยงของการลงทุนและเพิ่มโอกาสในการทำกำไรจากการลงทุน

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 อนุกรมเวลา (Time Series)

ข้อมูลอนุกรมเวลา หรือข้อมูลแบบ Time Series คือชุดข้อมูลที่มีค่าของข้อมูลที่อ้างอิงตามเวลา โดยแต่ละอนุกรมเวลา หรือแต่ละช่วงเวลาจะมีการบันทึกข้อมูลหรือค่าที่วัดได้ ณ เวลานั้น ๆ โดยหน่วยของเวลาอาจเป็น ปี เดือน สัปดาห์ วัน ชั่วโมง ฯลฯ เช่น สภาพอากาศ จำนวนคนเข้าเว็บไซต์ ณ เวลานั้น ๆ ราคาหุ้น อัตราแลกเปลี่ยนรายวัน ยอดขายรายวัน/รายเดือน ปริมาณการใช้ไฟในแต่ละวัน โดยลักษณะข้อมูลอนุกรมเวลาจะแบ่งออกเป็น 4 แบบ ได้แก่ แนวโน้ม (Trend) ความแปรผันตามฤดูกาล (Seasonality) ความแปรผันตามวัฏจักร (Cycle) และ ความแปรผันเนื่องจากเหตุการณ์ผิดปกติ (Irregular) ซึ่งจะนำลักษณะอนุกรมเวลามาศึกษาวิเคราะห์ และคาดการณ์การพยากรณ์ (Forecast)

2.2 การวิเคราะห์ความรู้สึก (Sentiment Analysis)

การวิเคราะห์ความรู้สึก (Sentiment Analysis) เป็นกระบวนการที่ใช้การประมวลผลภาษาธรรมชาติ (Natural Language Processing - NLP) และการเรียนรู้ของเครื่อง (Machine Learning) ในการระบุและจำแนกความคิดเห็นหรืออารมณ์ที่แสดงออกมาในรูปแบบข้อความ โดยเฉพาะในบริบทของการสื่อสารออนไลน์ เช่น ความคิดเห็นในโซเชียลมีเดีย รีวิวสินค้า หรือข้อความอื่น ๆ ที่เกี่ยวข้องกับแบรนด์หรือบริการต่าง ๆ โดยเน้นการแยกแยะว่าเนื้อหาเหล่านั้นแสดงถึงความรู้สึกในเชิงบวก เชิงลบ หรือเป็นกลาง ซึ่งการใช้ Sentiment Analysis ในการประเมินความพึงพอใจของลูกค้าที่มีต่อผลิตภัณฑ์หรือบริการหรือใช้ในการติดตามความคิดเห็นของลูกค้า เพื่อวิเคราะห์ตลาด และตอบสนองความต้องการของผู้บริโภคได้อย่างตรงจุดมากขึ้น (Wisensight, 2023)

2.3 Valence Aware Dictionary and Sentiment Reasoner (VADER)

Hutto & Gilbert (2014) ได้อธิบายว่า VADER เป็นเครื่องมือที่ใช้ในการวิเคราะห์ความรู้สึก (Sentiment Analysis) แบบอิงกฎ (Rule-based) ซึ่งออกแบบมาโดยเฉพาะสำหรับบริการวิเคราะห์ข้อความที่ไม่เป็นทางการ เช่น โพสต์บนโซเชียลมีเดีย บทวิจารณ์สินค้า หรือข้อความที่มีการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ใช้คำย่อและอีโมจิ VADER เป็นแพ็คเกจ Open Source ภายใน Natural Language Toolkit (NLTK) และถูกพัฒนาให้สามารถประมวลผลข้อความภาษาอังกฤษโดยอาศัย พจนานุกรมคำที่ให้คะแนนอารมณ์ และ กฎทางภาษาศาสตร์ เพื่อระบุ และให้คะแนนความรู้สึกในข้อความ โดยแยกเป็น ความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง นอกจากนี้ยังสามารถจัดการข้อความที่มีลักษณะเฉพาะ เช่น การใช้คำซ้ำ การใช้ตัวพิมพ์ใหญ่ หรือเครื่องหมายอัศเจรีย์ ที่แสดงอารมณ์ในข้อความ

หลักการการทำงานของ Sentiment Analysis โดยแบ่งออกเป็นขั้นตอนดังนี้

1. การเตรียมข้อมูล ข้อมูลส่วนใหญ่มักเต็มไปด้วย Noise เช่น ข้อความที่ไม่เกี่ยวข้องหรือข้อมูลที่ซ้ำซ้อน การทำความสะอาดข้อมูลช่วยให้ได้ข้อมูลที่พร้อมใช้งาน เช่น การลบข้อความไม่จำเป็น เช่น สัญลักษณ์พิเศษ (#, @), URLs, HTML tags การแยกคำ (Tokenization) คือการแยกข้อความออกเป็นคำหรือประโยค การลบ Stop Words คือการลบคำที่ไม่มีความหมายในเชิงเนื้อหา เช่น “คือ” “และ” “หรือ” และการแปลงคำให้อยู่ในรูปแบบรากศัพท์ (Lemmatization/Stemming) เพื่อลดคำซ้ำ เช่น "running" เป็น "run"

2. การกำหนดคะแนนอารมณ์ในคำศัพท์ (Sentiment Lexicon) VADER ใช้ฐานข้อมูล Lexical ที่มีคำศัพท์ที่ถูกแบ่งออกเป็นกลุ่มของความรู้สึก ประกอบด้วยคำศัพท์กว่า 7,500 คำและสัญลักษณ์ที่มีคะแนนอารมณ์กำกับ เช่น "happy" : +2.4 (เชิงบวก) "sad" : -2.1 (เชิงลบ) "neutral" : 0 (เป็นกลาง) และมีการปรับคะแนนอารมณ์ตามบริบท VADER ใช้กฎทางภาษาศาสตร์ในการปรับคะแนนของคำ เช่น คำขยาย คำปฏิเสธ ตัวพิมพ์ใหญ่ และเครื่องหมายอัศเจรีย์ เป็นต้น

3. การคำนวณคะแนนอารมณ์ (Sentiment Scoring) แบ่งออกเป็น 4 ประเภท

3.1 คะแนนอารมณ์เชิงบวก (Positive)

3.2 คะแนนอารมณ์เชิงลบ (Negative)

3.3 คะแนนอารมณ์ที่เป็นกลาง (Neutral)

3.4 คะแนนรวม (Compound Score) ที่คำนวณจากค่าทั้งหมดในข้อความ โดยอยู่ในช่วง -1 ถึง 1

โดย Compound Score สามารถคำนวณได้จากสมการที่ 2.1

$$\text{Compound Score} = \frac{x}{\sqrt{x^2 + a}} \quad (2.1)$$

เมื่อ x คือ ผลรวมของคะแนนอารมณ์ทั้งหมดที่ได้จากคำในข้อความ

a คือ ค่าคงที่ที่ทำให้คะแนนรวมอยู่ในช่วง -1 ถึง +1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 การเรียนรู้ของเครื่อง (Machine Learning)

Machine Learning (ML) หรือการเรียนรู้ของเครื่อง คือระบบที่สามารถเรียนรู้ได้จากตัวอย่างด้วยตนเอง โดยปราศจากการป้อนคำสั่งของโปรแกรมเมอร์ ประกอบไปด้วยข้อมูลและเครื่องมือทางสถิติเพื่อการทำนายผลลัพธ์ออกมา เครื่องคอมพิวเตอร์จะรับข้อมูลเข้ามาและใช้อัลกอริทึมเพื่อหาคำตอบ ซึ่ง Machine Learning จะเรียนรู้ผ่านการค้นพบรูปแบบหรือแบบแผนซ้ำ ๆ โดย Machine ไม่สามารถเรียนรู้ได้หากไม่มีข้อมูลที่สามารถนำไปใช้ได้ หรือชุดข้อมูลที่ขาดความหลากหลายจะทำให้ยากต่อการทำนาย (สมาคมโปรแกรมเมอร์ไทย, 2561)

Machine Learning สามารถแบ่งออกเป็น 3 ประเภทดังนี้

1. การเรียนรู้โดยมีผู้สอน (Supervised learning) เป็นการเรียนรู้ที่เครื่องจะต้องอาศัยข้อมูลในการฝึกฝน เปรียบเสมือนกับการเรียนการสอนของเด็กเล็ก โดยจำเป็นจะต้องอาศัยชุดข้อมูลต่าง ๆ ซึ่งประกอบไปด้วยชุดของข้อมูลและชุดผลลัพธ์ของข้อมูลที่ต้องการ โดยผลที่ได้จากการเรียนรู้คือ Machine Learning สามารถคาดคะเนผลลัพธ์ที่เกิดขึ้นจากการได้รับข้อมูล ประเภทของการเรียนรู้โดยมีผู้สอนจะแบ่งออกเป็น 2 ประเภท คือ การจำแนกประเภท (Classification) และการถดถอยเชิงสถิติ (Statistical Regression)

1.1 การจำแนกประเภท (Classification) เป็นการแยกประเภทเป็นหนึ่งในการเรียนรู้แบบมีผู้สอน และเป็นประเภทที่พบบ่อย เช่น การจดจำใบหน้าของคน

1.2 การถดถอยเชิงสถิติ (Statistical Regression) การถดถอยเชิงสถิติเป็นการหาความสัมพันธ์ระหว่างตัวแปร เช่น พื้นที่ของดิน (x) กับราคาที่ดิน (y) โมเดลที่ใช้ในการหาความสัมพันธ์มีด้วยกันหลายแบบ แต่ที่นิยมคือ การถดถอยเชิงเส้น (Linear Regression) (Phongchit, 2018)

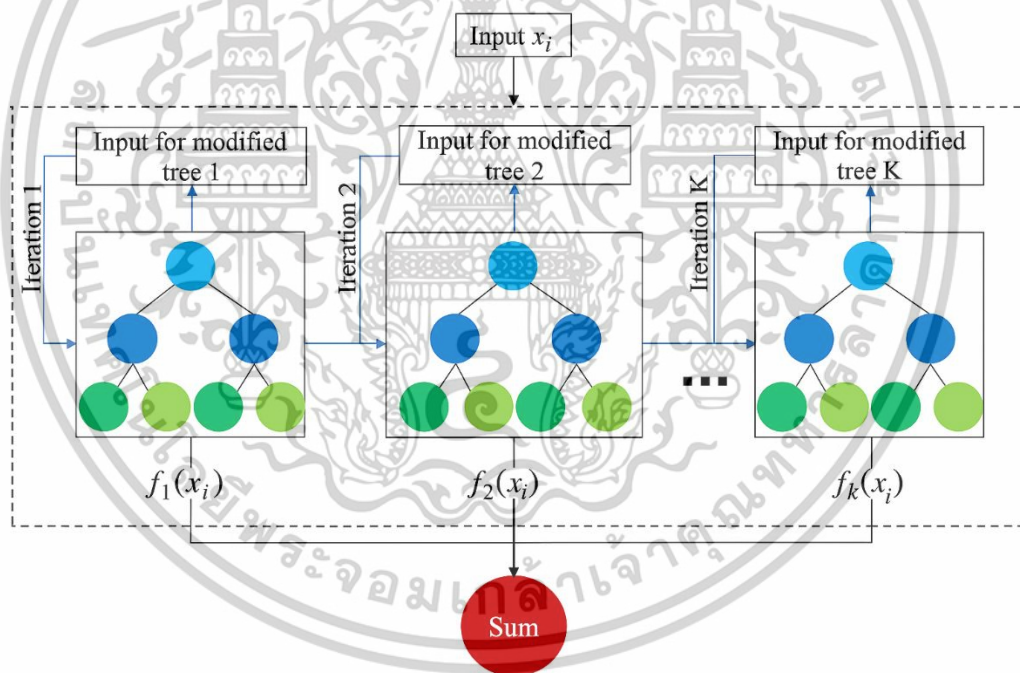
2. การเรียนรู้โดยไม่มีผู้สอน (Unsupervised learning) เป็นการเรียนรู้ที่ให้เครื่องนั้นสามารถเรียนรู้ได้ด้วยตนเอง โดยไม่ต้องมีค่าเป้าหมายของแต่ละข้อมูล ซึ่งวิธีการคือมนุษย์จะเป็นผู้ใส่ข้อมูลต่าง ๆ และกำหนดสิ่งที่ต้องการจากข้อมูลเหล่านั้น โดยให้เครื่องวิเคราะห์จากการจำแนกและสร้างแบบแผนจากข้อมูลที่ได้รับมา

3. การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) เป็นการเรียนรู้สิ่งต่าง ๆ จากการลองผิดลองถูกภายใต้แนวคิดที่จะเลือกกระทำสิ่งที่ทำให้ได้ผลลัพธ์มากที่สุด โดยทำการเรียนรู้จากการลองผิดลองถูกในสถานการณ์ในอดีตหรือระบบจำลองและพยายามที่จะพัฒนาระบบการตัดสินใจให้ดีขึ้นเรื่อย ๆ โดยที่อาจพัฒนาด้วยการพยายามสร้างแบบจำลองสถานการณ์ต่าง ๆ (ฝ่ายนโยบายและยุทธศาสตร์ สำนักงานส่งเสริมเศรษฐกิจดิจิทัล, ม.ป.ป.)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5 Extreme Gradient Boosting (XGBoost)

Bishop (2006) ได้อธิบาย XGBoost ว่าเป็นเทคนิคที่เรียนรู้ความผิดพลาดการทำนายของแบบจำลอง โดยเอาต้นไม้ตัดสินใจหลายแบบจำลองมาต่อกัน และมีการขยายโครงสร้างต้นไม้แบบ Level-Wise Growth โดยจะขยายทุกโหนด (leaf) ในระดับเดียวกันก่อน (ทั้งต้นไม้) ก่อนจะไปยังระดับถัดไป หลักการทำงานของ XGBoost เริ่มต้นด้วยการนำข้อมูลเข้าเพื่อสร้างต้นไม้การตัดสินใจลำดับแรกในการทำนายค่าผลลัพธ์ จากนั้นจะคำนวณค่าความคลาดเคลื่อน (Residual) และใช้ค่าความคลาดเคลื่อนนั้น เป็นเป้าหมายในการสร้างต้นไม้ถัดไป ทำซ้ำไปเรื่อย ๆ จนกว่าจะครบจำนวนที่กำหนดหรือไม่สามารถลดความผิดพลาดได้อีก จากนั้นเมื่อทำการฝึกต้นไม้การตัดสินใจหลายครบแล้ว ทำการรวมค่าทำนายของต้นไม้ทั้งหมดในลักษณะผลรวมแบบถ่วงน้ำหนักเพื่อสร้างค่าพยากรณ์สุดท้าย ดังรูปที่ 2.1



รูปที่ 2.1 กระบวนการทำงานของ XGBoost

ที่มา: Zou et al. (2022)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.6 Light Gradient Boosting Machine (LightGBM)

Thanapunnamas (2024) ได้อธิบาย LightGBM ว่าเป็นเฟรมเวิร์กการเรียนรู้ของเครื่องที่พัฒนาโดย Microsoft ซึ่งมีความเชี่ยวชาญในการสร้างอัลกอริทึมต้นไม้สำหรับการตัดสินใจที่มีประสิทธิภาพสูง โดยเฉพาะในการจัดอันดับ การจำแนกประเภท และการถดถอย การทำงานของ LightGBM เป็นการสร้างต้นไม้แบบ Leaf-Wise Growth โดยจะเลือกขยายเฉพาะโหนด (leaf) ที่มีการลดค่า loss มากที่สุด ในแต่ละรอบ ซึ่งช่วยให้สามารถสร้างต้นไม้ที่ลึกขึ้นและเรียนรู้ได้เร็วขึ้น และประสิทธิภาพในการจัดการข้อมูลขนาดใหญ่ หลังจากฝึกต้นไม้หลายต้นเรียบร้อยแล้ว จะรวบรวมผลลัพธ์จากแต่ละต้นไม้ สำหรับปัญหา Regression จะใช้การเฉลี่ยแบบถ่วงน้ำหนักเพื่อสร้างค่าพยากรณ์สุดท้าย แต่ปัญหา Classification จะใช้ Majority Voting ในการตัดสินใจสุดท้าย ดังรูปที่ 2.2



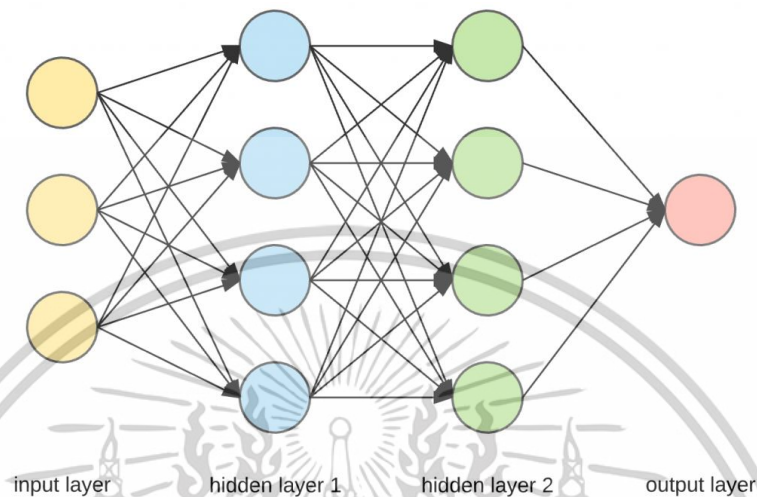
รูปที่ 2.2 กระบวนการทำงานของ LightGBM

ที่มา: Kiliç (2023)

2.7 การเรียนรู้เชิงลึก (Deep Learning)

Deep Learning หรือการเรียนรู้เชิงลึก เป็นศาสตร์แขนงย่อยในการเรียนรู้ของเครื่อง ซึ่งเลียนแบบการทำงานของระบบประสาทของมนุษย์ในการประมวลผล โดยเป็นเทคนิคในโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) มีโครงสร้างประกอบด้วย ชั้นรับข้อมูล (Input Layer) ชั้นประมวลผลข้อมูล (Hidden Layer) และ ชั้นส่งออกข้อมูลไปใช้ (Output Layer) ข้อมูลที่ได้จะมีค่าถ่วงน้ำหนัก ค่าความเอนเอียงของข้อมูล และการคำนวณทางคณิตศาสตร์ ส่วน Hidden layer จะมีกี่ชั้น (Layer) ก็ได้และยังมีหลายชั้น (Layer) แบบจำลองก็จะมีมากขึ้นและเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สามารถทำนายผลได้ดีขึ้น ลักษณะการทำงานของ Deep Learning แสดงดังรูปที่ 2.3 (ณัฐวดี หงส์บุญมี และคณิน ประทุมทอง, 2563)



รูปที่ 2.3 กระบวนการทำงานของ Deep Learning

ที่มา: Lelli (2019)

Activation Function คือ ฟังก์ชันที่ใช้ในการรับผลรวมจากการประมวลผลทั้งหมดจากทุก Input Node เข้ามาพิจารณาตามกลไกการคำนวณของ Activation Function นั้น ๆ แล้วส่งต่อไปเป็น Output ต่อไป โดยมี Activation Function สำหรับปัญหาแบบ Regression ที่สำคัญ 3 ตัวดังนี้

1. Linear Activation function มีลักษณะการทำงานเป็นแบบเชิงเส้น ตามสมการเส้นตรง สูตรคณิตศาสตร์จะเป็นดังสมการที่ 2.2

$$y = mx \quad (2.2)$$

Output y เป็นผลลัพธ์ของฟังก์ชัน จะมีค่าเท่ากับค่าเท่ากับค่าใดค่าหนึ่ง (m) คูณกับค่า x (Input) ที่ป้อนเข้าฟังก์ชัน (m ในทางคณิตศาสตร์คือค่าความชันของเส้นตรง)

2. Rectified Linear Unit (ReLU) เป็นฟังก์ชันที่ให้ผลลัพธ์เท่ากับค่า x (Input) ถ้า ค่า Input เข้ามากกว่า 0 แต่ค่า Input เข้ามาเป็นค่าลบ Output จะได้ค่าเป็น 0 ดังสมการที่ 2.3


$$F(x) = \begin{cases} 0, & \text{if } x < 0 \\ x, & \text{otherwise} \end{cases} \quad (2.3)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. Leaky ReLU มีลักษณะคล้าย ReLU คือ Input กับ Output มีความสัมพันธ์เป็นเชิงเส้น แต่ Leaky ReLU จะให้ Output ค่าลบได้ โดยค่าความชันเส้นจะลดลงเมื่อค่า Input เป็นลบ (ค่า Slope น้อย) ช่วยแก้ปัญหา Dying ReLU ที่บางครั้งค่า bias เป็นค่าลบ

2.8 Recurrent Neural Network (RNN)

เมอร์อง (2566) ได้อธิบายว่า RNN เป็นแบบจำลอง Deep Learning ที่ออกแบบมาเพื่อจัดการกับข้อมูลลำดับเวลา (sequential data) หรือข้อมูลที่มีการเชื่อมโยงกันในลำดับ เช่น ข้อความเสียง หรือข้อมูลแบบอนุกรมเวลา โดย RNN มีการทำงานแบบเชื่อมโยงข้อมูลจากสถานะก่อนหน้า (hidden state) เข้ากับสถานะปัจจุบัน ดังรูปที่ 2.4 ซึ่งช่วยให้แบบจำลองสามารถเก็บข้อมูลจากอดีตมาใช้งานได้ และทุก ๆ เวลาของการคำนวณ RNN จะปรับปรุงสถานะซ่อน (hidden state) โดยอิงตามข้อมูลปัจจุบันและสถานะก่อนหน้า ซึ่งโครงสร้างแบบเครือข่ายที่มีการวนซ้ำกลับไปยังตัวเอง ทำให้สามารถประมวลผลข้อมูลลำดับได้




รูปที่ 2.4 กระบวนการทำงานของ RNN

ที่มา: Smitsomboon (2020)

โดย RNN มีกระบวนการทำงานดังรูปที่ 2.5

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.5 ลักษณะการทำงานของ RNN

ที่มา: Wong et al. (2016)

1. การคำนวณ Hidden State ปัจจุบันถูกคำนวณจาก Hidden State ก่อนหน้า และข้อมูลอินพุตปัจจุบัน ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.4

$$h_t = f(W_h \cdot h_{(t-1)} + W_x \cdot x_t + b_h) \quad (2.4)$$

2. การคำนวณเอาต์พุต เอาต์พุตที่ได้จาก Hidden State ปัจจุบัน ซึ่งสามารถคำนวณได้ตาม ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.5

$$y_t = g(W_y \cdot h_t + b_y) \quad (2.5)$$

3. การอัปเดตข้อมูลในลำดับถัดไป Hidden State จะถูกส่งไปยังลำดับถัดไป เพื่อใช้ในการคำนวณต่อ

โดยที่ y_t คือเอาต์พุต ณ เวลาปัจจุบัน

h_t คือ Hidden State ณ เวลาปัจจุบัน

$h_{(t-1)}$ คือ Hidden State ขั้นตอนก่อนหน้าหรือของ Network ที่แล้ว

x_t คือข้อมูลอินพุต ณ เวลาปัจจุบัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

W_h คือน้ำหนัก (Weight) ที่เชื่อมโยงกับ Hidden State ณ เวลาปัจจุบัน และ Hidden State ก่อนหน้า

W_x คือน้ำหนัก (Weight) ที่เชื่อมโยงกับอินพุต ณ เวลาปัจจุบัน กับ Hidden State ณ เวลาปัจจุบัน


W_y คือน้ำหนัก (Weight) ที่ใช้สร้างเอาต์พุต

b_y คือค่าเอนเอียง (Bias) ของเอาต์พุต

f คือฟังก์ชันกระตุ้น (Activation Function) เช่น tanh หรือ ReLU

2.9 Long Short-Term Memory (LSTM)

Smitsomboon (2020) ได้อธิบาย LSTM เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมแบบวนซ้ำ (RNN) ที่ออกแบบมาเพื่อแก้ปัญหาคการลดลงของเกรเดียนต์ (Vanishing Gradient) ซึ่งเป็นข้อจำกัดสำคัญของ RNN ดั้งเดิม โดย LSTM สามารถเก็บข้อมูลที่มีระยะเวลายาวนานได้ดีกว่า RNN ทั่วไป และเหมาะสำหรับการทำงานกับข้อมูลลำดับเวลา (Sequential Data) โดย LSTM มีหลักการทำงานคล้ายคลึงกับ RNN ซึ่งจะแตกต่างตรง Hidden State ของ RNN มีเพียงสถานะ Hidden State ที่ใช้เก็บข้อมูลจากเวลาที่ผ่านไป ซึ่งข้อมูลใน Hidden State อาจถูกลืมไปเรื่อย ๆ เมื่อย้อนกลับไปหลายลำดับเวลา แต่ LSTM มี Memory Cell ที่ใช้เก็บข้อมูลระยะยาว และ Hidden State ที่ใช้เก็บข้อมูลระยะสั้น และมีกลไก Gates ที่ช่วยควบคุมการเก็บและลืมข้อมูลใน Memory Cell และ Hidden State เพื่อให้เก็บข้อมูลที่สำคัญได้อย่างมีประสิทธิภาพ ดังรูปที่ 2.6




รูปที่ 2.6 กระบวนการทำงานของ LSTM

ที่มา: Smitsomboon (2020)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยขั้นตอนการทำงานหลักของ LSTM แบ่งออกเป็น 3 Gate และสามารถแบ่งออกได้เป็น 4 ขั้นตอน ดังรูป 2.7



รูปที่ 2.7 ลักษณะการทำงานหลักของ LSTM

ที่มา: Rasifaghihi (2020)

1. Forget Gate (f_t) ตัดสินใจว่าจะลืมข้อมูลใดใน Memory Cell ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.6

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \tag{2.6}$$

2. Input Gate (i_t) ตัดสินใจว่าจะเพิ่มข้อมูลใดเข้าไปใน Memory Cell ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.7

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \tag{2.7}$$

และสร้างข้อมูลใหม่ที่ควรเพิ่ม ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.8

$$C_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \tag{2.8}$$

3. Cell State Update รวมข้อมูลเก่าและใหม่เพื่อปรับปรุงหน่วยความจำ ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.9

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C_t \tag{2.9}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4. Output Gate (o_t) ตัดสินใจว่าข้อมูลใน Memory Cell ส่วนใดจะส่งออกไปยัง Hidden State ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.10

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (2.10)$$

และสร้าง Hidden State ใหม่ ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.11

$$h_t = o_t \cdot \tanh(b_f) \quad (2.11)$$

โดยที่ h_t คือ Hidden State ของเซลล์ ณ ปัจจุบัน

h_{t-1} คือ Hidden State ของเซลล์ก่อนหน้า

C_t คือหน่วยความจำ ณ ปัจจุบัน

C_{t-1} คือหน่วยความจำก่อนหน้า

x_t คืออินพุตปัจจุบัน

W_f, W_i, W_c, W_o คือน้ำหนักของแต่ละ gate

b_f, b_i, b_c, b_o คือความเอนเอียงของแต่ละ gate

σ คือฟังก์ชัน sigmoid (ทำให้ค่าผลลัพธ์อยู่ในช่วง 0-1)


\tanh คือฟังก์ชัน hyperbolic tangent (ค่าผลลัพธ์อยู่ในช่วง -1 ถึง 1)

2.10 Gated Recurrent Unit (GRU)

GRU เป็นโครงสร้างหนึ่งของโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network - RNN) ซึ่งได้รับการพัฒนาจาก LSTM (Long Short-Term Memory) โดยมีการปรับปรุงโครงสร้างให้เรียบง่ายกว่า LSTM แต่ยังสามารถจัดการข้อมูลลำดับเวลาและแก้ปัญหา Vanishing Gradient ได้ดี GRU ถูกออกแบบมาให้มี Gates สำหรับควบคุมการเก็บและลืมข้อมูล โดยตัดบางองค์ประกอบที่ซับซ้อนใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

LSTM ออก เช่น ไม่มี Memory Cell แยกต่างหาก แต่ใช้ Hidden State เพียงอย่างเดียว ดังรูปที่ 2.8 (GeeksforGeeks, n.d.)



รูปที่ 2.8 ลักษณะการทำงานของ GRU

ที่มา: Smitsomboon (2020)

กระบวนการทำงานหลักของ GRU มีดังนี้

1. Reset Gate (r_t) ตัดสินใจว่าควรลืมข้อมูลเก่าจาก Hidden State หรือไม่ ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.12

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2.12)$$

2. Update Gate (z_t) ตัดสินใจว่าจะเก็บข้อมูลเก่าหรือเพิ่มข้อมูลใหม่จากอินพุตที่ Hidden State เท่าไหร่ ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.13

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (2.13)$$

3. Hidden State Candidate (h_t) สร้างค่าผู้สมัครสำหรับ Hidden State ใหม่โดยอิงจากอินพุตปัจจุบันและ Hidden State ที่ถูกรีเซ็ต ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.14

$$h_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \quad (2.14)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4. Hidden State (h_t) อัปเดต Hidden State โดยการผสมข้อมูลเก่าและข้อมูลใหม่ตาม Update Gate ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.15

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot h_t \quad (2.15)$$

โดยที่ h_t คือ Hidden State ของเซลล์ ณ ปัจจุบัน

h_{t-1} คือ Hidden State ของเซลล์ก่อนหน้า

z_t คือ Update Gate

r_t คือ Reset Gate

h_t คือ Hidden State Candidate

x_t คืออินพุตปัจจุบัน

W_r, W_z, W_h คือน้ำหนักของแต่ละ gate

b_r, b_z, b_h คือความเอนเอียงของแต่ละ gate

σ คือฟังก์ชัน sigmoid (ทำให้ค่าผลลัพธ์อยู่ในช่วง 0-1)

\tanh คือฟังก์ชัน hyperbolic tangent (ค่าผลลัพธ์อยู่ในช่วง -1 ถึง 1)

\odot คือการคูณแบบองค์ประกอบต่อองค์ประกอบ (Element-wise Multiplication)

2.11 Permutation Feature Importance (PFI)

Permutation Feature Importance (PFI) เป็นเทคนิคที่ใช้ในการประเมินความสำคัญของตัวแปร โดยพิจารณาจากผลกระทบที่เกิดขึ้นกับประสิทธิภาพของโมเดลเมื่อตัวแปรนั้นถูกสลับค่าภายในคอลัมน์แบบสุ่ม (permutation) โดยไม่เปลี่ยนค่าของตัวแปรอื่น ซึ่งแนวคิดหลักคือ หากการสลับค่าของฟีเจอร์ใดส่งผลให้ประสิทธิภาพของโมเดลลดลงอย่างชัดเจน แสดงว่าฟีเจอร์นั้นมีความสำคัญต่อการทำนายผลของโมเดล โดยมีหลักการทำงานดังนี้ ทำการฝึกโมเดลด้วยชุดข้อมูลฝึก จากนั้นประเมินค่าประสิทธิภาพของโมเดล และสลับค่าของฟีเจอร์ทีละตัวเพื่อประเมินว่า

ประสิทธิภาพของโมเดลเปลี่ยนแปลงไปอย่างไร การลดลงของค่าประสิทธิภาพ หลังจากการสลับค่าเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สะท้อนถึงความสำคัญของพีเจอรันั้น โดยพีเจอร์ที่ทำให้ประสิทธิภาพของโมเดลลดลงมากจะถูกจัดให้มีความสำคัญสูง ซึ่งถ้ามีค่าเป็นบวกหมายความว่าตัวแปรนั้นมีความสำคัญมาก แต่ถ้ามีค่าติดลบสามารถสรุปได้ว่า ตัวแปรนั้นอาจเป็น noise หรือมีผลเสียต่อโมเดล (Fisher, Rudin, & Dominici, 2019)

2.12 การทดสอบแบบจับคู่ (Paired T-Test)

Statistics Solutions, (n.d.-a) อธิบายไว้ว่า Paired T-Test เป็นการทดสอบทางสถิติที่ใช้เปรียบเทียบค่าเฉลี่ยระหว่างกลุ่มตัวอย่างที่เกี่ยวข้องกันสองกลุ่ม ซึ่งกลุ่มตัวอย่างแต่ละกลุ่มวัดจากตัวอย่างเดียวกัน หรือจากตัวอย่างที่จับคู่กัน ตัวอย่างเช่น ตรวจสอบความแตกต่างของค่าเฉลี่ยก่อนและหลังการรักษา โดยมีข้อตกลงเบื้องต้นดังนี้

1. ประชากรมีการแจกแจงแบบปกติ
2. ข้อมูลทั้ง 2 กลุ่มไม่เป็นอิสระกัน
3. ข้อมูลอยู่ในมาตรวัดอันดับหรือมากกว่าขึ้นไป

โดยมีสมมติฐานทางสถิติดังนี้

$$H_0 : \mu_1 - \mu_2 = 0$$

$$H_1 : \mu_1 - \mu_2 \neq 0$$

เมื่อ μ_1 และ μ_2 แทนค่าเฉลี่ยประชากรกลุ่มที่ 1 และ 2 ตามลำดับ

2.13 การทดสอบ Wilcoxon signed rank test

Statistics Solutions, (n.d.-b) อธิบายไว้ว่า Wilcoxon signed rank test เป็นการทดสอบทางสถิติแบบไม่ใช้พารามิเตอร์ (Nonparametric) ที่ใช้เปรียบเทียบความแตกต่างระหว่างกลุ่มตัวอย่างสองกลุ่มที่มีความสัมพันธ์กัน ซึ่งเหมาะกับกรณีที่มีข้อมูลไม่มีการแจกแจงแบบปกติ โดยมีข้อตกลงเบื้องต้นดังนี้

1. ข้อมูลทั้ง 2 กลุ่มไม่เป็นอิสระกัน
2. ข้อมูลอยู่ในมาตรวัดอันดับหรือมากกว่าขึ้นไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยมีสมมติฐานทางสถิติดังนี้

$$H_0 : M_1 - M_2 = 0$$

$$H_1 : M_i - M_k \neq 0$$

เมื่อ M_1 และ M_2 แทนค่ามัธยฐานของประชากรกลุ่มที่ 1 และ 2 ตามลำดับ

2.14 การวิเคราะห์ความแปรปรวนแบบวัดซ้ำ (Repeated Measures ANOVA)

Field (2013) อธิบายว่า การวิเคราะห์ความแปรปรวนแบบวัดซ้ำ เป็นเทคนิคทางสถิติที่ใช้สำหรับ เปรียบเทียบค่าเฉลี่ยของตัวแปรตาม (Dependent Variable) ตั้งแต่ 3 กลุ่มขึ้นไป ภายใต้เงื่อนไขที่ข้อมูลไม่เป็นอิสระกัน ซึ่งเป็นการวัดค่าของตัวแปรเดียวกันซ้ำหลายครั้งในกลุ่มตัวอย่างเดียวกัน (Within-Subjects Design) ในการทดสอบสมมติฐานมีข้อตกลงเบื้องต้นดังนี้

1. ประชากรทุกกลุ่มมีการแจกแจงแบบปกติ
2. กลุ่มตัวอย่างแต่ละกลุ่มต้องไม่เป็นอิสระกัน
3. ความแปรปรวนของความแตกต่างระหว่างเงื่อนไขต้องเท่ากัน
4. ข้อมูลอยู่ในมาตรวัดอันดับขึ้นไป

โดยมีสมมติฐานทางสถิติดังนี้

$$H_0 : \mu_1 = \mu_2 = \mu_3 = \dots = \mu_k$$

$$H_1 : \mu_i \neq \mu_k \text{ ค่าเฉลี่ยประชากรอย่างน้อย 1 คู่ ; } i \neq j$$

เมื่อ $\mu_1, \mu_2, \mu_3, \dots, \mu_k$ แทนค่าเฉลี่ยประชากรกลุ่มที่ 1, 2, 3, ..., k ตามลำดับ

2.15 การทดสอบของฟรีดแมน (Friedman test)

Laerd Statistics (n.d.) ได้อธิบายการทดสอบของฟรีดแมน (Friedman Test) เป็นการทดสอบทางสถิติแบบไม่ใช้พารามิเตอร์ ที่ใช้สำหรับเปรียบเทียบค่ามัธยฐานของกลุ่มที่สัมพันธ์กันตั้งแต่ 3 กลุ่มขึ้นไป ใช้ในกรณีที่ข้อมูลไม่มีการแจกแจงแบบปกติ โดยมีข้อตกลงเบื้องต้นดังนี้

1. กลุ่มตัวอย่างแต่ละกลุ่มต้องไม่เป็นอิสระกัน
2. ข้อมูลอยู่ในมาตรวัดเรียงอันดับขึ้นไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยมีสมมติฐานทางสถิติดังนี้

$$H_0 : M_1 = M_2 = M_3 = \dots = M_k$$

$$H_1 : M_i \neq M_k \text{ ค่ามัธยฐานประชากรอย่างน้อย 1 คู่ ; } i \neq j$$

เมื่อ $M_1, M_2, M_3, \dots, M_k$ แทนค่ามัธยฐานประชากรกลุ่มที่ 1, 2, 3, ..., k ตามลำดับ

2.16 การประเมินความแม่นยำแบบจำลอง

การประเมินความคลาดเคลื่อน ความแม่นยำของแบบจำลอง มีความสำคัญกับการเรียนรู้ของเครื่อง เนื่องจากแบบจำลองที่ได้มีความเหมาะสมที่จะนำไปใช้งานหรือไม่ ซึ่งทำการประเมินประสิทธิภาพของแบบจำลองด้วยการวัดความแตกต่างระหว่างข้อมูลจริงกับค่าพยากรณ์ โดย y_i และ \hat{y}_i คือค่าของตัวแปรตามจากข้อมูลและค่าพยากรณ์ของตัวแปรตาม ตามลำดับ สำหรับ $i = 1, 2, \dots, n$ ฟังก์ชันวัดความคลาดเคลื่อนที่ใช้สำหรับปัญหา Regression (PCP, 2020) ได้แก่

1) ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error)

การวัดความถูกต้องของการทำนาย ที่วัดจากค่าความคลาดเคลื่อนโดยไม่คำนึงถึงทิศทางของค่าความคลาดเคลื่อน ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.16

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.16)$$

2) ค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error)

เป็นวิธีวัดความแม่นยำโดยคำนวณเปอร์เซ็นต์ความผิดพลาดในการพยากรณ์ โดยไม่คำนึงถึงเครื่องหมาย ค่า MAPE ยิ่งน้อยยิ่งมีความแม่นยำสูง ซึ่งสามารถคำนวณได้ตาม สมการที่ 2.17

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100 \quad (2.17)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.17 งานวิจัยที่เกี่ยวข้อง

2.17.1 งานวิจัยที่ใช้การวิเคราะห์ความรู้สึกในการทำนายราคาหุ้น

งานวิจัยในกลุ่มนี้ให้ความสำคัญกับการนำ ข้อมูลข่าวสารทางการเงินหรือโซเชียลมีเดีย มาวิเคราะห์อารมณ์ (Sentiment Analysis) ก่อนนำมาใช้เป็นตัวแปรร่วมกับราคาหุ้นรายวัน โดยใช้แบบจำลอง Deep Learning และ Machine Learning ในการพยากรณ์

1) **Mohan et al. (2019)** ทำการศึกษาเรื่อง Stock Price Prediction Using News Sentiment Analysis งานวิจัยนี้ทำการพยากรณ์ราคาหุ้นโดยใช้การวิเคราะห์อารมณ์จากข่าวการเงิน โดยใช้ข้อมูลราคาปิดดัชนี S&P 500 รายวัน เป็นระยะเวลา 5 ปี พร้อมกับบทความข่าวเกี่ยวกับบริษัทใน S&P 500 รวมทั้งสิ้น 265,463 บทความ และใช้โมเดล Machine Learning และ Deep Learning ประกอบไปด้วย ARIMA, Facebook Prophet และ RNN-LSTM จากการศึกษาพบว่า โมเดล RNN-LSTM ที่ใช้ข้อมูลราคาหุ้นและข้อมูลข่าวสารมีความแม่นยำสูงสุด โดยสามารถลดข้อผิดพลาดของการพยากรณ์ได้ดีกว่าโมเดลเชิงสถิติอย่าง ARIMA และ Facebook Prophet อย่างมีนัยสำคัญ นอกจากนี้การใช้ข่าวการเงินในโมเดลพยากรณ์ช่วยให้การคาดการณ์แนวโน้มของราคาหุ้นมีประสิทธิภาพมากขึ้น โดยเฉพาะในกรณีที่ข้อมูลข่าวสารมีปริมาณมากเพียงพอ

2) **Shahi et al. (2019)** ทำการศึกษาเรื่อง Stock Price Forecasting with Deep Learning: A Comparative Study งานวิจัยนี้ทำการเปรียบเทียบประสิทธิภาพของ Long Short-Term Memory (LSTM) และ Gated Recurrent Unit (GRU) นอกจากนี้ ยังวิเคราะห์ว่าการนำอารมณ์ของข่าวการเงินมาใช้ร่วมกับข้อมูลหุ้นสามารถช่วยเพิ่มความแม่นยำของโมเดลได้หรือไม่ โดยใช้ข้อมูลราคาหุ้นของ Agriculture Development Bank (ADBL) ตั้งแต่วันที่ 20 มีนาคม 2011 - 14 พฤศจิกายน 2019 และใช้ VADER Sentiment Analysis เพื่อแปลงหัวข้อข่าวเป็นคะแนนอารมณ์ (Sentiment Score) จากการศึกษาพบว่า LSTM และ GRU มีประสิทธิภาพใกล้เคียงกันเมื่อใช้ข้อมูลหุ้นเพียงอย่างเดียว เมื่อนำอารมณ์ของข่าวมาใช้ (LSTM-News และ GRU-News) ความแม่นยำเพิ่มขึ้นอย่างมีนัยสำคัญ และโมเดล LSTM-News มีค่าความผิดพลาดต่ำที่สุด (MAE = 17.69) เมื่อเทียบกับโมเดลอื่น ๆ

3) **Gu et al. (2024)** ทำการศึกษาเรื่อง Predicting Stock Prices with FinBERT-LSTM: Integrating News Sentiment Analysis งานวิจัยนี้ทำการทำนายราคาหุ้น eBay ที่อยู่ในดัชนี NASDAQ 100 โดยใช้ 3 วิธีในการสร้างตัวแบบ ได้แก่ FinBERT-LSTM, LSTM และ DNN ใช้ข้อมูลราคาหุ้นจาก Yahoo Finance ตั้งแต่ 15 ก.พ. 2009 – 12 มิ.ย. 2020 และข่าวการเงินจาก Benzinga รวมกว่า 843,000 บทความ ซึ่งวิธี FinBERT-LSTM คือการใช้การวิเคราะห์ความรู้สึก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากข่าวควบคุมกับราคาหุ้นในการสร้างตัวแบบ แต่วิธีอื่น ๆ ใช้เฉพาะราคาปิดของหุ้นในการสร้างตัวแบบอย่างเดียว โดยใช้ MAE และ MAPE เป็นตัววัดประสิทธิภาพของตัวแบบ จากการศึกษาพบว่า FinBERT-LSTM มีประสิทธิภาพดีที่สุด (MAE = 173.67, MAPE = 0.045) การใช้ความรู้สึกจากข่าวช่วยลดค่าความผิดพลาด (Error) ได้อย่างมีนัยสำคัญ และตัวแบบ DNN ที่ใช้ข้อมูลราคาหุ้นเพียงอย่างเดียวให้ผลลัพธ์ต่ำที่สุด

4) **Padmanayana et al. (2021)** ทำการศึกษาเรื่อง Stock Market Prediction Using Twitter Sentiment Analysis งานวิจัยนี้ศึกษาผลกระทบของ อารมณ์ที่แสดงออกผ่านทวีตใน Twitter ต่อการพยากรณ์ราคาหุ้น โดยใช้ Naïve Bayes สำหรับการวิเคราะห์อารมณ์ และ XGBoost สำหรับการพยากรณ์ตลาดหุ้น ใช้ Twitter API เพื่อดึงทวีตที่เกี่ยวข้องกับบริษัทที่ศึกษา และใช้ Yahoo Finance API เพื่อนำเข้าราคาหุ้นรายวัน จากการศึกษาพบว่า โมเดล XGBoost มีความแม่นยำในการพยากรณ์ราคาหุ้นถึง 89.8% และการใช้ข้อมูลอารมณ์จาก Twitter และข้อมูลหุ้น ช่วยเพิ่มประสิทธิภาพของการพยากรณ์มากกว่าการใช้ข้อมูลหุ้นเพียงอย่างเดียว

สรุปสาระสำคัญของงานวิจัยกลุ่มที่ใช้การวิเคราะห์อารมณ์ในการทำนายราคาหุ้น

การใช้ข้อมูลอารมณ์ไม่ว่าจะมาจากข่าวหรือโซเชียลมีเดีย ร่วมกับข้อมูลราคาหุ้นในอดีต ช่วยยกระดับความแม่นยำของแบบจำลองการทำนายราคาหุ้น โดยเฉพาะเมื่อใช้ร่วมกับโมเดล Deep Learning ที่มีความสามารถในการจัดการกับข้อมูลอนุกรมเวลาและข้อมูลที่ไม่เป็นโครงสร้าง อย่างไรก็ตาม ประสิทธิภาพของแบบจำลองยังขึ้นอยู่กับปริมาณและคุณภาพของแหล่งข่าว หรือข้อมูลอารมณ์ที่นำมาใช้ ซึ่งเป็นประเด็นสำคัญที่ควรพิจารณาในการออกแบบระบบพยากรณ์ราคาหุ้นในอนาคต

2.17.2 งานวิจัยที่ใช้เฉพาะราคาหุ้นในการทำนาย

งานวิจัยกลุ่มนี้พึ่งพา ข้อมูลราคาหุ้นในอดีตเพียงอย่างเดียว โดยไม่ใช้ข่าวหรือข้อมูลทางเศรษฐกิจอื่น ๆ มาสร้างตัวแปรเพิ่มเติม ส่วนใหญ่นำแบบจำลอง Time Series เช่น ARIMA หรือ Deep Learning อย่าง LSTM มาทดลองเปรียบเทียบกับแบบจำลอง Machine Learning เช่น Random Forest หรือ XGBoost สามารถสรุปได้ว่าแบบจำลองโครงข่ายประสาทเทียมเชิงลึกมักมีความแม่นยำสูงกว่าสถิติแบบดั้งเดิม โดยเฉพาะเมื่อมีข้อมูลย้อนหลังจำนวนมาก

1) **Moghar & Hamiche (2020)** ทำการศึกษาเรื่อง Stock Market Prediction Using LSTM Recurrent Neural Network งานวิจัยนี้มุ่งเน้นไปที่อัลกอริทึม Recurrent Neural Networks (RNN) และ Long Short-Term Memory (LSTM) ซึ่งเป็นโครงข่ายประสาทเทียมที่สามารถจัดการกับข้อมูลอนุกรมเวลาได้ดี โดยใช้ข้อมูลราคาหุ้นรายวันของ GOOGL และ NKE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มีวัตถุประสงค์คือ วัดความแม่นยำของอัลกอริทึม Machine Learning และวิเคราะห์จำนวน Epochs มีผลต่อความแม่นยำของแบบจำลองอย่างไร จากการศึกษาพบว่า LSTM สามารถติดตามแนวโน้มของราคาหุ้นได้ดี และมีความแม่นยำสูงกว่าการใช้โมเดลเชิงเส้น เช่น ARIMA การเพิ่มจำนวน Epochs ช่วยลดค่าความผิดพลาดของโมเดล และทำให้พยากรณ์ได้แม่นยำขึ้น และข้อมูลที่มีความผันผวนสูง อาจทำให้โมเดลสูญเสียความแม่นยำหากไม่ได้รับการปรับแต่งที่เหมาะสม

2) **Chatterjee et al. (2021)** ทำการศึกษาเรื่อง Stock Price Prediction Using Time Series, Econometric, Machine Learning, and Deep Learning Models งานวิจัยนี้ทำการเปรียบเทียบแบบจำลอง 6 แบบ ใน 3 อุตสาหกรรม (IT, ธนาคาร และสุขภาพ) เพื่อพยากรณ์ราคาหุ้น โดยใช้ข้อมูลราคาหุ้นจากตลาดหลักทรัพย์แห่งชาติของอินเดีย (NSE) ได้แก่ Infosys, ICICI และ SUN PHARMA ตั้งแต่ มกราคม 2004 ถึง ธันวาคม 2019 โมเดลที่ใช้ประกอบไปด้วย Holt-Winters Exponential Smoothing, ARIMA, Random Forest, MARS (Multivariate Adaptive Regression Spline), Simple RNN และ LSTM จากการศึกษาพบว่าโมเดล MARS มีประสิทธิภาพดีที่สุดในช่วงข้อมูลราคาหุ้น Infosys และ ICICI แต่โมเดล Random Forest มีประสิทธิภาพดีที่สุดในช่วงข้อมูลราคาหุ้น SUN PHARMA

3) **Zhu & He (2022)** ทำการศึกษาเรื่อง Prediction of Amazon's Stock Price Based on ARIMA, XGBoost, and LSTM Models งานวิจัยนี้ทำการเปรียบเทียบประสิทธิภาพของ 3 โมเดล ได้แก่ ARIMA (Autoregressive Integrated Moving Average), XGBoost (Extreme Gradient Boosting), และ LSTM (Long Short-Term Memory) ในการพยากรณ์ราคาหุ้นของ Amazon โดยใช้ Mean Squared Error (MSE) เป็นตัววัดความแม่นยำของโมเดล โดยใช้ข้อมูลราคาหุ้นของ Amazon ตั้งแต่ปี 2010 ถึง 2019 จากการศึกษาพบว่า LSTM เป็นโมเดลที่เหมาะสมที่สุดในการพยากรณ์ราคาหุ้นของ Amazon โดยให้ค่าความผิดพลาดต่ำสุดเมื่อเทียบกับ ARIMA และ XGBoost

4) **Jabed (2024)** ทำการศึกษาเรื่อง Stock Market Price Prediction using Machine Learning Techniques งานวิจัยนี้นำเสนอการใช้อัลกอริทึมได้แก่ Long Short-Term Memory (LSTM), Facebook Prophet และ Random Forest Regressor และใช้ข้อมูลราคาหุ้นรายวัน 10 บริษัทที่จดทะเบียนในตลาดหลักทรัพย์ Dhaka (DSEbd) ใช้ข้อมูลย้อนหลัง 6 เดือน และ 6 บริษัทระดับโลก (Amazon, Apple, Microsoft, Google, Netflix และ Tesla) ข้อมูลย้อนหลัง 10 ปี จากการศึกษาพบว่า โมเดล LSTM เป็นโมเดลที่มีความแม่นยำสูงสุด ในการพยากรณ์ราคาหุ้น โดยมีความผิดพลาดต่ำที่สุดเมื่อเทียบกับโมเดลอื่น ๆ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สรุปสาระสำคัญของงานวิจัยกลุ่มที่ใช้เฉพาะข้อมูลราคาหุ้นในการทำนาย

งานวิจัยในกลุ่มนี้ชี้ให้เห็นว่า การใช้ข้อมูลราคาหุ้นย้อนหลังเพียงอย่างเดียวสามารถนำมาสร้างแบบจำลองที่มีประสิทธิภาพได้ หากเลือกอัลกอริทึมที่เหมาะสม และมีการปรับแต่งอย่างถูกต้อง และแบบจำลองโครงข่ายประสาทเทียมเชิงลึก โดยเฉพาะ LSTM มักให้ผลลัพธ์ที่แม่นยำกว่าวิธีแบบดั้งเดิมในการพยากรณ์ข้อมูลอนุกรมเวลา อย่างไรก็ตามยังมีข้อจำกัดในด้านการไม่พิจารณาปัจจัยภายนอก เช่น ข่าวสารหรือปัจจัยทางเศรษฐกิจ ซึ่งอาจมีอิทธิพลต่อพฤติกรรมของตลาดอย่างมีนัยสำคัญ

2.17.3 งานวิจัยที่ใช้ปัจจัยทางเศรษฐกิจในการทำนายราคาหุ้น

งานวิจัยจำนวนมากที่มุ่งวิเคราะห์ความสัมพันธ์ระหว่างปัจจัยทางเศรษฐกิจมหภาคกับความเคลื่อนไหวของตลาดการเงิน ทั้งในตลาดหุ้นแบบดั้งเดิมและตลาดคริปโตเคอร์เรนซี โดยใช้เทคนิคทางสถิติและการเรียนรู้ของเครื่องเข้ามาประยุกต์ใช้เพื่อเพิ่มความแม่นยำในการพยากรณ์และการวิเคราะห์ปัจจัยที่ส่งผลกระทบต่อราคาสินทรัพย์ ตัวแปรเศรษฐกิจที่มักถูกนำมาศึกษา ได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศ, อัตราดอกเบี้ย, เงินเฟ้อ, ราคาน้ำมัน, อัตราการว่างงาน และดัชนีราคาผู้บริโภค เป็นต้น ซึ่งงานวิจัยที่เกี่ยวข้องต่อไปนี้แสดงให้เห็นถึงแนวทางการวิเคราะห์และผลการศึกษาจากหลากหลายมุมมอง ทั้งในตลาดหุ้นและตลาดคริปโตเคอร์เรนซี ซึ่งช่วยสร้างความเข้าใจเชิงลึกเกี่ยวกับบทบาทของตัวแปรเศรษฐกิจต่อการเปลี่ยนแปลงของราคาสินทรัพย์ทางการเงิน

1) **Delpeche, Menon, & Du (2022)** ทำการศึกษาเรื่อง The Impact of Macroeconomic Indicators on the Stock Market Using Statistical & Deep Learning Methods งานวิจัยนี้ศึกษาผลกระทบของตัวชี้วัดทางเศรษฐกิจมหภาคที่มีต่อดัชนีตลาดหุ้น โดยใช้เทคนิคทางสถิติและ Deep Learning เพื่อวิเคราะห์และพยากรณ์แนวโน้มตลาด ตัวแปรที่ศึกษาได้แก่ GDP, Unemployment Rate, Inflation Rate, Federal Funds Rate, Oil Price, Treasury Yields, Personal Consumption Expenditure (PCE), ราคาที่อยู่อาศัย, หนี้สิน, Exchange Rate และ Non-Farm Payrolls ซึ่งใช้เทคนิค LSTM Neural Networks ในการพยากรณ์ข้อมูลอนุกรมเวลา และใช้ PCA ในการวิเคราะห์ปัจจัย จากการศึกษาพบว่าแบบจำลอง LSTM มีค่าความคลาดเคลื่อนเฉลี่ยอยู่ที่ 0.01537 และการวิเคราะห์ปัจจัยโดยใช้ PCA ระบุว่าหนี้สิน, Federal Funds Rate, ราคาน้ำมัน, GDP และราคาที่อยู่อาศัย เป็น 5 ตัวแปรหลักที่มีผลกระทบต่อตลาดหุ้น

2) **Lin, Vecchio, Yager, & Liu (2022)** ทำการศึกษาเรื่อง Macroeconomic Factors and Stock Market Indices งานวิจัยนี้มุ่งศึกษาว่า ปัจจัยเศรษฐกิจมหภาค (Macroeconomic Factors) ได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศ (GDP), อัตราดอกเบี้ยของเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ธนาคารกลาง (Effective Funds Rate), ราคาน้ำมัน, ปริมาณเงินในระบบเศรษฐกิจ (Money Supply), ดัชนีราคาผู้บริโภค (CPI), อัตราการว่างงาน และดัชนีราคาผู้ผลิต (PPI) ส่งผลต่อดัชนีตลาดหุ้น ได้แก่ Dow Jones, S&P 500 และ NASDAQ อย่างไร ใช้ข้อมูลช่วงปี 2011–2021 ในการสร้างแบบจำลองถดถอย เพื่อตรวจสอบผลกระทบของปัจจัยเศรษฐกิจต่อดัชนีตลาดหุ้นแต่ละตัว จากการศึกษาพบว่าดัชนี NASDAQ สะท้อนผลกระทบจากปัจจัยเศรษฐกิจมหภาคมากที่สุดเมื่อเทียบกับ S&P 500 และ Dow Jones

3) Srinivasan, Maity, & Kumar (2022) ทำการศึกษาเรื่อง Macro-Financial Parameters Influencing Bitcoin Prices: Evidence from Symmetric and Asymmetric ARDL Models งานวิจัยนี้วิเคราะห์ว่า ปัจจัยเศรษฐกิจมหภาคและการเงิน (macro-financial indicators) เช่น CPI, ดัชนีตลาดหุ้น, อัตราดอกเบี้ย, ราคาน้ำมัน ฯลฯ มีผลกระทบต่อราคาของ Bitcoin หรือไม่ โดยใช้แบบจำลอง ARDL ทั้งแบบสมมาตรและอสมมาตร ตัวแปรที่ศึกษาได้แก่ ปัจจัยภายนอกคือ CPI, DJIA, Federal Funds Rate, ราคาน้ำมัน, USD Index, Gold, S&P GSCI และปัจจัยภายในคือ ปริมาณซื้อขาย (Volume), จำนวนธุรกรรม (Transactions), Hash Rate, Google Trends จากการศึกษาพบว่าตัวแปร DJIA, USD Index, Volume, Transactions, Hash Rate, Oil Price, Google Trends มีผลกระทบต่อราคา Bitcoin อย่างมีนัยสำคัญ

สรุปสาระสำคัญของงานวิจัยกลุ่มที่ใช้ปัจจัยเศรษฐกิจมหภาคในการทำนายราคาหุ้น

งานวิจัยในกลุ่มนี้ชี้ให้เห็นว่า ตัวแปรเศรษฐกิจมหภาคมีอิทธิพลอย่างชัดเจนต่อราคาของสินทรัพย์ในตลาดการเงิน ไม่ว่าจะเป็นหุ้นหรือคริปโต ซึ่งสะท้อนให้เห็นถึงความสำคัญของการพิจารณาข้อมูลเศรษฐกิจควบคู่กับข้อมูลราคาสินทรัพย์ในการสร้างแบบจำลองการทำนาย

บทที่ 3

วิธีการดำเนินงานวิจัย

งานวิจัยนี้ใช้ข้อมูลราคาปิดรายวันของหุ้นเทคโนโลยี สรุปรูปเนื้อหาข่าว และปัจจัยทางเศรษฐกิจที่เกี่ยวข้องโดยเริ่มจากการนำเข้าข้อมูลจากแหล่งต่าง ๆ และทำการเตรียมข้อมูลก่อนนำไปใช้ โดยทำการสำรวจข้อมูล ตรวจสอบค่านอกเกณฑ์ แปลงค่าข้อมูลให้อยู่ในรูปแบบพร้อมใช้งาน เมื่อทำการเตรียมข้อมูลเรียบร้อยแล้ว ทำการแปลงสรุปรูปเนื้อหาข่าวเป็นคะแนนอารมณ์ และทำการสร้างแบบจำลองทำนายราคาปิดของหุ้นเทคโนโลยีด้วยวิธีต่าง ๆ โดยมีวิธีการดำเนินงานดังนี้

3.1 ข้อมูลที่ใช้ในงานวิจัย

ข้อมูลที่ใช้ในงานวิจัยนี้เป็นข้อมูลทุติยภูมิเป็นข้อมูลราคาปิดรายวันของหุ้นเทคโนโลยี สรุปรูปเนื้อหาข่าว และปัจจัยทางเศรษฐกิจที่เกี่ยวข้อง ตั้งแต่ 1 มีนาคม พ.ศ. 2565 ถึง 28 กุมภาพันธ์ พ.ศ. 2568 โดยข้อมูลเหล่านี้ เก็บรวบรวมจากเว็บไซต์ investing.com tradingview.com และ Alpha Vantage API ซึ่งมีข้อมูลดังตารางที่ 3.1

ตารางที่ 3.1 ตัวแปรที่ใช้ในงานวิจัย

| ชื่อตัวแปร | ความหมาย | หน่วย | มาตราวัด | งานวิจัย |
|--|---|--------|-----------|----------|
| ราคาปิดหุ้น GOOGL | ราคาซื้อขายสุดท้ายของหุ้นบริษัท Alphabet Inc. | รายวัน | อัตราส่วน | |
| ราคาปิดหุ้น MSFT | ราคาซื้อขายสุดท้ายของหุ้นบริษัท Microsoft Corporation | รายวัน | อัตราส่วน | |
| ราคาปิดหุ้น AAPL | ราคาซื้อขายสุดท้ายของหุ้นบริษัท Apple Inc.. | รายวัน | อัตราส่วน | |
| ราคาปิดหุ้น NVDA | ราคาซื้อขายสุดท้ายของหุ้นบริษัท NVIDIA Corporation | รายวัน | อัตราส่วน | |
| ราคาปิดหุ้น META | ราคาซื้อขายสุดท้ายของหุ้นบริษัท Meta Platforms, Inc. | รายวัน | อัตราส่วน | |
| คะแนนความรู้สึกจากข่าวที่เกี่ยวข้องกับหุ้น GOOGL | ค่าที่ใช้แทนระดับความรู้สึกที่ปรากฏในข่าวที่เกี่ยวข้องกับหุ้น GOOGL | รายวัน | อันตรภาค | |
| คะแนนความรู้สึกจากข่าวที่เกี่ยวข้องกับหุ้น MSFT | ค่าที่ใช้แทนระดับความรู้สึกที่ปรากฏในข่าวที่เกี่ยวข้องกับหุ้น Microsoft Corporation | รายวัน | อันตรภาค | |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 ตัวแปรที่ใช้ในงานวิจัย (ต่อ)

| ชื่อตัวแปร | ความหมาย | หน่วย | มาตรวัด | งานวิจัย |
|---|--|----------|------------|--------------------------|
| คะแนนความรู้สึกจากข่าวที่เกี่ยวกับหุ้น AAPL | ค่าที่ใช้แทนระดับความรู้สึกที่ปรากฏในข่าวที่เกี่ยวกับหุ้น Apple Inc. | รายวัน | อันตรายภาค | |
| คะแนนความรู้สึกจากข่าวที่เกี่ยวกับหุ้น NVDA | ค่าที่ใช้แทนระดับความรู้สึกที่ปรากฏในข่าวที่เกี่ยวกับหุ้น NVIDIA Corporation | รายวัน | อันตรายภาค | |
| คะแนนความรู้สึกจากข่าวที่เกี่ยวกับหุ้น META | ค่าที่ใช้แทนระดับความรู้สึกที่ปรากฏในข่าวที่เกี่ยวกับหุ้น Meta Platforms, Inc. | รายวัน | อันตรายภาค | |
| สถานะข่าว | ตัวบ่งชี้ว่าในวันนั้นมีข่าวหรือไม่ โดย 0 คือไม่มีข่าว และ 1 คือมีข่าว | รายวัน | นามบัญญัติ | |
| Unemployment | อัตราการว่างงานของสหรัฐฯ | รายเดือน | อัตราส่วน | Delpeche et al. (2022) |
| U.S. Treasury Yield | อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ | รายวัน | อัตราส่วน | Delpeche et al. (2022) |
| Retail Sales | ยอดขายรวมของสินค้าและบริการที่ขายให้กับผู้บริโภคปลายทาง | รายเดือน | อัตราส่วน | |
| U.S. Dollar Index | ความแข็งค่าของเงินดอลลาร์สหรัฐฯ เทียบกับสกุลเงินต่าง ๆ | รายวัน | อัตราส่วน | Srinivasan et al. (2022) |
| Fed Interest Rate | อัตราดอกเบี้ยที่กำหนดโดยธนาคารกลางสหรัฐอเมริกา | รายเดือน | อัตราส่วน | Delpeche et al. (2022) |
| U.S. Inflation rate | อัตราเงินเฟ้อ | รายเดือน | อัตราส่วน | Delpeche et al. (2022) |
| U.S. Gross Domestic Product | มูลค่าตลาดของสินค้าและบริการขั้นสุดท้ายที่ผลิตในประเทศในช่วงเวลาหนึ่ง | รายเดือน | อัตราส่วน | Delpeche et al. (2022) |
| U.S. Consumer Price Index | ดัชนีราคาผู้บริโภค การเปลี่ยนแปลงของราคาสินค้าและบริการ | รายเดือน | อัตราส่วน | Srinivasan et al. (2022) |
| ราคาทองคำ (Gold) | ราคาทองคำ กำหนดโดยการซื้อขายทองในบรรดาตลาดการเงินทั่วโลก | รายวัน | อัตราส่วน | Srinivasan et al. (2022) |
| ราคาน้ำมัน (WTI) | ราคาน้ำมัน จากแหล่งน้ำมันในสหรัฐอเมริกา | รายวัน | อัตราส่วน | Delpeche et al. (2022) |
| S&P 500 | ดัชนีตลาดหุ้นสหรัฐฯ รวมเอาหุ้นขนาดใหญ่ 500 แห่งของสหรัฐฯ | รายวัน | อัตราส่วน | Lin et al. (2022) |
| Nasdaq 100 | ดัชนีตลาดหุ้นที่รวมเอาหุ้นที่มีมูลค่าตลาดสูงสุด 100 อันดับแรก | รายวัน | อัตราส่วน | Lin et al. (2022) |
| Bitcoin | สกุลเงินดิจิทัล สกุลแรกที่ถูกสร้างขึ้นบน Blockchain | รายวัน | อัตราส่วน | Srinivasan et al. (2022) |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 เครื่องมือที่ใช้ในการวิจัย

1) Python คือ ภาษาโปรแกรมที่ใช้กันอย่างแพร่หลาย โดยถูกออกแบบให้มีโครงสร้างและไวยากรณ์ของภาษาที่ไม่ซับซ้อน เข้าใจง่าย และครอบคลุมลักษณะงานที่หลากหลาย ทำให้มีความเหมาะสมสำหรับผู้เริ่มต้นเขียนโปรแกรมไปจนถึงนักพัฒนาในองค์กร (ภาษาซี ทูรกฤษณา, 2564)

2) Google Colaboratory คือ ผลิตภัณฑ์จากการวิจัยของ Google ช่วยให้ทุกคนสามารถเขียนโปรแกรมภาษา Python ผ่านบราวเซอร์ได้และเหมาะสำหรับการทำ Machine Learning และเป็นบริการโน้ตบุ๊ก Jupyter ที่ไม่จำเป็นต้องตั้งค่าเพื่อใช้งานในขณะที่ให้การเข้าถึงทรัพยากรการประมวลผลรวมถึง GPU (Google, n.d.)

3) GitHub คือ แพลตฟอร์มการพัฒนาซอฟต์แวร์ออนไลน์ที่ใช้สำหรับการจัดเก็บ ติดตาม และทำงานร่วมกันในโครงการซอฟต์แวร์ ช่วยให้ให้นักพัฒนาสามารถอัปเดตโค้ดของตนเองและทำงานร่วมกับนักพัฒนารายอื่นในโครงการโอเพนซอร์ส GitHub ยังทำหน้าที่เป็นเครือข่ายสังคมออนไลน์ที่ให้นักพัฒนาสามารถสร้างเครือข่ายทำงานร่วมกันและนำเสนอผลงานของพวกเขาได้อย่างเปิดเผย (Juviler, 2021)

4) SPSS (Statistical Package for the Social Science) คือ โปรแกรมสำเร็จรูปที่ใช้สำหรับการวิเคราะห์ข้อมูลทางสถิติ เช่น ค่าเฉลี่ย ร้อยละ ค่าฐานนิยม หรือการนำเสนอในรูปแบบกราฟ การแจกแจงความถี่ในรูปแบบของตาราง ฯลฯ ไปจนถึงการวิเคราะห์ข้อมูลด้วยเทคนิคทางสถิติ เช่น การใช้ Factor Analysis, Discriminant Analysis เป็นต้น (enable survey, 2022)

3.3 การจัดการข้อมูล (Data Processing)

3.3.1 การดึงข้อมูล

งานวิจัยนี้ทำการดึงข้อมูลออกเป็น 2 แบบ คือ ดึงข้อมูลผ่านเว็บไซต์ และดึงข้อมูลผ่าน API

1) การดึงข้อมูลผ่านเว็บไซต์

งานวิจัยนี้ทำการดึงข้อมูลตัวแปรทางเศรษฐกิจต่าง ๆ จากเว็บไซต์ investing.com และtradingview.com แล้วเลือกชุดข้อมูล และกำหนดวันที่ต้องการ จากนั้นทำการดาวน์โหลดออกมาเป็นรูปแบบ CSV

2) การดึงข้อมูลผ่าน API

งานวิจัยนี้ทำการดึงข้อมูลข่าว ผ่าน Alpha Vantage ซึ่ง Alpha Vantage คือผู้ให้บริการ API ด้านข้อมูลการเงินและเศรษฐกิจ โดยทำการดึงผ่านภาษา Python มีขั้นตอนดังนี้ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1) กำหนดคำ (Keyword) ในการค้นหาข่าวสารที่เกี่ยวข้อง ในงานวิจัยนี้ได้กำหนดโดยแบ่งออกเป็น 5 หุ่นดังต่อไปนี้ AAPL หรือ Apple, MSFT หรือ Microsoft, META หรือ Facebook หรือ Instagram, GOOG หรือ google หรือ Alphabet และสุดท้าย NVDA หรือ NVIDIA

2.2) ระบุ URL สำหรับดึงข้อมูล ดังนี้ https://www.alphavantage.co/query?function=NEWS_SENTIMENT&tickers={symbols}&time_from={time_from}&time_to={time_to}&limit=1000&apikey={api_key}

2.3) ส่งคำขอไปยัง API ด้วยคำสั่ง `requests.get()`

2.4) บันทึกข้อมูลออกมาเป็นรูปแบบ CSV

3.3.2 การจัดเตรียมข้อมูลให้พร้อมสำหรับการประมวลผล

ก่อนการนำข้อมูลไปใช้ และตรวจสอบความผิดพลาดของข้อมูล และการทำความสะอาดข้อมูลเป็นการตรวจจับข้อมูล แก้ไข ลบ แทนที่ และจัดรูปแบบของข้อมูลที่ไม่สมบูรณ์ ซ้ำซ้อน ให้มีความถูกต้องและเป็นระเบียบ ดังนี้

1) ลบข้อมูลข่าวที่เก่ากว่า 1 มีนาคม พ.ศ. 2565 และ ใหม่กว่า 28 กุมภาพันธ์ พ.ศ. 2568 เพื่อให้สอดคล้องกับชุดข้อมูลราคาปิดของหุ้น

2) จัดการค่าว่าง เมื่อตรวจสอบยังพบว่ามีค่าว่างอยู่ทำการแทนที่ด้วยค่ากลาง หรือค่าก่อนหน้า

3) จัดการค่านอกเกณฑ์ เป็นการกำจัดข้อมูลที่แตกต่างไปจากข้อมูลในกลุ่มอย่างผิดปกติ โดยตรวจสอบค่านอกเกณฑ์ด้วยวิธี Boxplot

4) จัดการข้อมูลตัวแปรรายเดือนแปลงเป็นรายวัน โดยมีตัวแปรดังนี้ Fed Interest Rate, Unemployment, U.S. Inflation rate, U.S. Gross Domestic Product (GDP), Retail Sales และ U.S. Consumer Price Index (CPI) เนื่องจากตัวเลขเศรษฐกิจหลักของสหรัฐฯ เหล่านี้ถูกประกาศโดยหน่วยงานรัฐบาลที่แตกต่างกันเดือนละครั้ง ดังนั้นช่วงระยะเวลาระหว่างประกาศตัวเลขใหม่ขึ้นมาจะมีค่าคงที่ตลอดเวลา จึงทำการแปลงข้อมูลรายเดือนเป็นรายวันด้วยค่าคงที่ของแต่ละเดือนนั้น ๆ

5) แปลงวันที่และเวลาที่ประกาศข่าว เนื่องจากข่าวที่ถูกประกาศออกมาผู้วิจัยได้ดึงข้อมูลจาก Alpha Vantage โดยผ่าน API ช่วงเวลาจะอยู่ในรูปหน่วยเวลา UTC (Coordinated

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Universal Time) จึงทำการแปลงเป็นหน่วยเวลา EST (Eastern Standard Time) เป็นเขตเวลาที่ใช้ในสหรัฐอเมริกาตามเวลาทำการของหุ้นอเมริกา

3.4 การวิเคราะห์ความรู้สึกจากข่าว

ข้อมูลสรุปเนื้อหาข่าวของแต่ละหุ้นที่รวบรวมได้จาก Alpha Vantage โดยผ่าน API ในการนำข่าวจากเว็บไซต์ต่าง ๆ เช่น Benzinga, MarketWatch, CNBC และ Business Insider เป็นต้น มารวบรวม และผู้วิจัยนำข้อมูลมาวิเคราะห์ความรู้สึกโดยใช้ VADER Sentiment ซึ่งสามารถแยกอารมณ์ในข้อความนั้นเป็นความรู้สึกเชิงบวก เชิงลบ หรือเป็นกลาง มีค่าตั้งแต่ -1 ถึง 1 แล้วนำค่าอารมณ์ที่ได้มารวบรวมกันในแต่ละวัน แล้วหาค่าเฉลี่ยของวันนั้น ๆ

3.5 การสร้างแบบจำลอง

3.5.1 การปรับช่วงข้อมูล (Data Normalization)

เป็นเทคนิคหนึ่งในการจัดเตรียมข้อมูลก่อนสร้างแบบจำลอง โดยทำการปรับช่วงขอบเขตของข้อมูลชนิดตัวเลข ให้อยู่ในช่วงเดียวกัน ที่เหมาะกับการนำไปประมวลผลต่อ โดยงานวิจัยนี้ใช้ MinMaxScaler จากไลบรารี scikit-learn ในการปรับช่วงข้อมูล ให้เป็นอยู่ในช่วง [0, 1]

3.5.2 การแบ่งข้อมูล

ในงานวิจัยนี้มีข้อมูลที่ใช้ในการทำนายราคาปิดของหุ้นจำนวน 753 วัน แล้วแบ่งข้อมูลออกเป็น 2 ชุดได้แก่ ชุดข้อมูลฝึก และชุดข้อมูลทดสอบ เป็นชุดข้อมูลฝึก 75% : ชุดข้อมูลทดสอบ 25% เป็นการแบ่งข้อมูลตามลำดับเวลา โดยชุดข้อมูลฝึกจะนำมาหาไฮเปอร์พารามิเตอร์ที่เหมาะสมต่อราคาปิดของหุ้นและอัลกอริทึม ซึ่งงานวิจัยนี้ใช้ TimeSeriesSplit เป็นเทคนิคการตรวจสอบความถูกต้องแบบไขว้ (cross-validation) ที่ออกแบบมาโดยเฉพาะสำหรับข้อมูลอนุกรมเวลา (time series data) แทนที่จะทำการสุ่มแบ่งข้อมูลเหมือนใน k-fold Cross-Validation แบบดั้งเดิม แต่ TimeSeriesSplit จะรักษาลำดับเวลาไว้ โดยในงานวิจัยนี้ทำการแบ่งข้อมูลออกเป็น 5 ส่วน

3.5.3 การสร้างแบบจำลองทำนายราคาปิดของหุ้น

ใช้เทคนิค Machine Learning 5 วิธี ได้แก่ LightGBM, XGBoost, RNN, GRU และ LSTM ซึ่งก่อนจะทำการสร้างแบบจำลอง จำเป็นต้องหาไฮเปอร์พารามิเตอร์ที่ดีที่สุดในแต่ละอัลกอริทึม ซึ่งงานวิจัยนี้ใช้ Grid Search ในการปรับค่าไฮเปอร์พารามิเตอร์ โดยปรับแต่งไฮเปอร์พารามิเตอร์ แต่ละ

เทคนิคดังนี้ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1) LightGBM เป็นอัลกอริทึมที่ใช้การรวมต้นไม้ตัดสินใจหลายต้นโดยอาศัยเทคนิค Gradient Boosting มีความโดดเด่นด้านความเร็วและประสิทธิภาพในการประมวลผล ในการสร้างแบบจำลองนี้ผู้วิจัยใช้ Python library 'lightgbm' ด้วยคำสั่ง 'LGBMRegressor' โดยมีไฮเปอร์พารามิเตอร์ที่ปรับประกอบได้ด้วย

- max_depth คือความลึกสูงสุดของต้นไม้ (Decision Tree) แต่ละต้น ยิ่งต้นไม้มีความลึกมากจะสามารถแยกข้อมูลได้ละเอียดมากขึ้น
- n_estimators คือจำนวนต้นไม้ที่ใช้ใน boosting
- min_data_in_leaf คือจำนวนข้อมูลขั้นต่ำในแต่ละ leaf node
- feature_fraction คือสัดส่วนของฟีเจอร์ที่เลือกใช้ในการ train แต่ละต้นไม้
- max_bin คือจำนวน bin สูงสุดที่ใช้แบ่งค่าของฟีเจอร์แบบ histogram
- learning_rate คือการปรับขนาดของ Error ในแต่ละครั้งของการปรับปรุง Weight และ Bias

และค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างแบบจำลอง LightGBM ดังตารางที่ 3.2

ตารางที่ 3.2 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง LightGBM

| ไฮเปอร์พารามิเตอร์ | ขอบเขตค่าปรับจูน |
|--------------------|-------------------------|
| max_depth | 3, 5, 7, 9 |
| n_estimators | 100, 200, 400, 600 |
| min_data_in_leaf | 25, 50, 100, 150, 200 |
| feature_fraction | 0.5, 0.6, 0.7, 0.8, 0.9 |
| max_bin | 50, 100, 150, 200, 400 |
| learning_rate | 0.01, 0.1, 0.2 |

2) XGBoost เป็นอัลกอริทึมที่นำเอาต้นไม้ตัดสินใจหลายๆต้นมาฝึกสอน โดยต้นไม้ตัดสินใจแต่ละต้นจะเกิดจากการเรียนรู้จากความผิดพลาดของต้นไม้ก่อนหน้า ในการสร้างแบบจำลองนี้ผู้วิจัยใช้ Python library 'xgboost' ด้วยคำสั่ง 'XGBRegressor' โดยมีไฮเปอร์พารามิเตอร์ที่ปรับประกอบได้ด้วย

- alpha คือน้ำหนักมาตรฐานในชั้น L1
- max_depth คือความลึกสูงสุดของต้นไม้ (Decision Tree) แต่ละต้นใน

ต้นไม้มากจะสามารถแยกข้อมูลได้ละเอียดมากขึ้น
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตเห็นาไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- `n_estimators` คือจำนวนต้นไม้ที่ใช้ใน boosting
- `colsample_bytree` คืออัตราส่วนของฟีเจอร์ที่จะสุ่มเลือกมาใช้ในการสร้างแต่ละต้นไม้
- `min_child_weight` คือค่าน้ำหนักรวมขั้นต่ำของตัวอย่างในแต่ละ leaf
- `reg_lambda` คือค่าควบคุมความซับซ้อนของแบบจำลอง
- `learning_rate` คือการปรับขนาดของ Error ในแต่ละครั้งของการปรับปรุง Weight และ Bias

และค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างตัวแบบ XGBoost ดังตารางที่ 3.3

ตารางที่ 3.3 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง XGBoost

| ไฮเปอร์พารามิเตอร์ | ขอบเขตค่าปรับจูน |
|--------------------|--------------------|
| Alpha | 0, 0.1, 1, 10 |
| max_depth | 3, 5, 7, 9 |
| n_estimators | 100, 200, 400, 600 |
| colsample_bytree | 0.1, 0.3, 0.5, 0.7 |
| min_child_weight | 1, 3, 5 |
| reg_lambda | 0, 0.1, 1, 10 |
| learning_rate | 0.01, 0.1, 0.2 |

3) RNN มีการทำงานแบบเชื่อมโยงข้อมูลจากสถานะก่อนหน้า (hidden state) เข้ากับสถานะปัจจุบัน ซึ่งช่วยให้แบบจำลองสามารถเก็บข้อมูลจากอดีตมาใช้งานได้ ในการสร้างแบบจำลองนี้ผู้วิจัยใช้ Python library 'tensorflow.keras' ด้วยคำสั่ง 'SimpleRNN' ซึ่งงานวิจัยนี้ได้พัฒนาแบบจำลอง RNN ที่ประกอบด้วยทั้งหมด 3 ชั้น โดยเริ่มจาก Input layer ซึ่งมีจำนวนหน่วยความจำ 128 หน่วย ตามด้วย Hidden layer มี neuron จำนวน 64 หน่วย และ Output layer มี neuron สำหรับการทำนายผลลัพธ์จำนวน 1 หน่วย และมีไฮเปอร์พารามิเตอร์ที่ปรับประกอบได้ด้วย

- `optimizer` คืออัลกอริทึมที่ใช้ในการปรับค่าน้ำหนักของแบบจำลอง เพื่อให้ค่าความสูญเสีย (loss) ลดลงในการเทรนแต่ละรอบ
- `batch_size` คือจำนวนข้อมูลที่ถูกใช้ในการฝึกแต่ละรอบ
- `epochs` คือจำนวนรอบของการฝึกแบบจำลองทั้งหมดที่ใช้ข้อมูลฝึกในการฝึก 1 รอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างแบบจำลอง RNN ดังตารางที่ 3.4

ตารางที่ 3.4 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง RNN

| ไฮเปอร์พารามิเตอร์ | ขอบเขตค่าปรับจูน |
|--------------------|-----------------------------|
| Optimizer | RMSprop, Adam, AdamW, Nadam |
| batch_size | 16, 32, 64, 128, 256 |
| epochs | 100, 150, 200, 250, 300 |

4) LSTM เป็นอัลกอริทึม RNN ที่ถูกพัฒนาขึ้นเพื่อจดจำข้อมูลระยะยาวได้ดีขึ้น โดยเพิ่มโครงสร้างพิเศษ เช่น forget gate, input gate และ output gate ช่วยให้การจัดการกับข้อมูลลำดับที่ซับซ้อนได้ ในการสร้างแบบจำลองนี้ผู้วิจัยใช้ Python library 'tensorflow.keras' ด้วยคำสั่ง 'LSTM' ซึ่งงานวิจัยนี้ได้พัฒนาแบบจำลอง LSTM ที่ประกอบด้วยทั้งหมด 3 ชั้น โดยเริ่มจาก Input layer ซึ่งมีจำนวนหน่วยความจำ 128 หน่วย ตามด้วย Hidden layer มี neuron จำนวน 64 หน่วย และ Output layer มี neuron สำหรับการทำนายผลลัพธ์จำนวน 1 หน่วย และมีไฮเปอร์พารามิเตอร์ที่ปรับประกอบได้ด้วย

- optimizer คืออัลกอริทึมที่ใช้ในการปรับค่าน้ำหนักของแบบจำลอง เพื่อให้ค่าความสูญเสีย (loss) ลดลงในการเทรนแต่ละรอบ
- batch_size คือจำนวนข้อมูลที่ถูกใช้ในการฝึกแต่ละรอบ
- epochs คือจำนวนรอบของการฝึกแบบจำลองทั้งหมดที่ใช้ข้อมูลฝึกในการฝึก 1 รอบ

และค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างแบบจำลอง LSTM ดังตารางที่ 3.5

ตารางที่ 3.5 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง LSTM

| ไฮเปอร์พารามิเตอร์ | ขอบเขตค่าปรับจูน |
|--------------------|-----------------------------|
| optimizer | RMSprop, Adam, AdamW, Nadam |
| batch_size | 16, 32, 64, 128, 256 |
| epochs | 100, 150, 200, 250, 300 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5) GRU เป็นทางเลือกของ LSTM ที่มีโครงสร้างเรียบง่ายกว่า โดยรวม gate บางส่วนเข้าด้วยกัน เช่น update gate และ reset gate ทำให้คำนวณเร็วขึ้นแต่ยังสามารถจดจำลำดับข้อมูลได้อย่างมีประสิทธิภาพ ในการสร้างแบบจำลองนี้ผู้วิจัยใช้ Python library 'tensorflow.keras' ด้วยคำสั่ง 'GRU' ซึ่งงานวิจัยนี้ได้พัฒนาแบบจำลอง GRU ที่ประกอบด้วยทั้งหมด 3 ชั้น โดยเริ่มจาก Input layer ซึ่งมีจำนวนหน่วยความจำ 128 หน่วย ตามด้วย Hidden layer มี neuron จำนวน 64 หน่วย และ Output layer มี neuron สำหรับการทำนายผลลัพธ์จำนวน 1 หน่วย และมีไฮเปอร์พารามิเตอร์ที่ปรับประกอบได้ด้วย

- optimizer คืออัลกอริทึมที่ใช้ในการปรับค่าน้ำหนักของแบบจำลอง เพื่อให้ค่าความสูญเสีย (loss) ลดลงในการเทรนแต่ละรอบ
 - batch_size คือจำนวนข้อมูลที่ถูกใช้ในการฝึกแต่ละรอบ
 - epochs คือจำนวนรอบของการฝึกแบบจำลองทั้งหมดที่ใช้ข้อมูลฝึกในการฝึก 1 รอบ
- และค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างแบบจำลอง GRU ดังตารางที่ 3.6

ตารางที่ 3.6 ค่าไฮเปอร์พารามิเตอร์ที่ทดลองใช้ในแบบจำลอง GRU

| ไฮเปอร์พารามิเตอร์ | ขอบเขตค่าปรับจูน |
|--------------------|-----------------------------|
| optimizer | RMSprop, Adam, AdamW, Nadam |
| batch_size | 16, 32, 64, 128, 256 |
| epochs | 100, 150, 200, 250, 300 |

3.6 การวัดประสิทธิภาพแบบจำลอง

3.6.1 การเปรียบเทียบประสิทธิภาพของทุกแบบจำลองของหุ่นเทคโนโลยีแต่ละตัว

การเปรียบเทียบประสิทธิภาพของทุกแบบจำลองเพื่อดูว่ามีแบบจำลองใดที่แตกต่างกันอย่างมีนัยสำคัญหรือไม่ โดยใช้สถิติทดสอบ Repeated Measures ANOVA เมื่อข้อมูลมีการแจกแจงแบบปกติ โดยมีสมมติฐานดังนี้

สมมติฐานทางสถิติ

$$H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5$$

$$H_1 : \mu_i \neq \mu_k \text{ ค่าเฉลี่ยความคลาดเคลื่อนอย่างน้อย 1 คู่; } i \neq j$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ $\mu_1, \mu_2, \mu_3, \mu_4, \mu_5$ แทนค่าเฉลี่ยความคลาดเคลื่อนการทำนายราคาปิดของหุ้น ด้วยวิธี LightGBM, XGBoost, RNN, GRU และ LSTM ตามลำดับ

และใช้ Friedman test เมื่อข้อมูลไม่ได้มีการแจกแจงแบบปรกติ โดยมีสมมติฐานดังนี้

สมมติฐานทางสถิติ

$$H_0 : M_1 = M_2 = M_3 = M_4 = M_5$$

$$H_1 : M_i \neq M_k \text{ ค่ามัธยฐานความคลาดเคลื่อนอย่างน้อย 1 คู่ ; } i \neq j$$

เมื่อ M_1, M_2, M_3, M_4, M_5 แทนค่ามัธยฐานความคลาดเคลื่อนการทำนายราคาปิดของหุ้น ด้วยวิธี LightGBM, XGBoost, RNN, GRU และ LSTM ตามลำดับ

3.6.2 การวัดประสิทธิภาพของแบบจำลอง

งานวิจัยนี้ทำการวัดประสิทธิภาพของแบบจำลองด้วย 2 วิธี ได้แก่ ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) และค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

3.6.3 การประเมินประสิทธิภาพของแบบจำลอง

ประเมินประสิทธิภาพของแบบจำลอง ด้วยสถิติทดสอบ Paired Sample t-test เป็นเทคนิคทางสถิติที่ใช้ในการเปรียบเทียบประสิทธิภาพ เพื่อดูว่าค่าจริงและค่าทำนายได้มีความแตกต่างกันอย่างมีนัยสำคัญหรือไม่ โดยมีสมมติฐานดังนี้

สมมติฐานทางสถิติ

$$H_0 : \mu_1 - \mu_2 = 0$$

$$H_1 : \mu_1 - \mu_2 \neq 0$$

เมื่อ μ_1 แทนค่าเฉลี่ยของค่าจริงของราคาปิดของหุ้น

μ_2 แทนค่าเฉลี่ยของราคาปิดหุ้นที่ได้จากแบบจำลองการทำนาย

เมื่อข้อมูลไม่ได้มีการแจกแจงแบบปรกติ ให้ใช้สถิติทดสอบ Wilcoxon Signed Rank Test โดยมีสมมติฐานดังนี้

สมมติฐานทางสถิติ

$$H_0 : M_1 - M_2 = 0$$

$$H_1 : M_i - M_k \neq 0$$

เมื่อ M_1 แทนค่ามัธยฐานของค่าจริงของราคาปิดของหุ้น

M_2 แทนค่ามัธยฐานเฉลี่ยของราคาปิดหุ้นที่ได้จากแบบจำลองการทำนาย

3.7 การวิเคราะห์ความสำคัญของตัวแปร

เมื่อได้แบบจำลองที่มีประสิทธิภาพมากที่สุดของแต่ละหุ้นแล้ว ทำการหาตัวแปรที่มีอิทธิพลต่อราคาหุ้น โดยใช้วิธี Permutation feature importance ซึ่งเป็นวิธีการหาความสำคัญของตัวแปร โดยการสับและสลับของแต่ละตัวแปร เพื่อดูว่าหากไม่มีตัวแปรนี้ จะส่งผลต่อแบบจำลองอย่างไร

บทที่ 4

ผลการวิจัยและการอภิปรายผล

ผลการศึกษาของการวิจัยเรื่อง การศึกษาเชิงเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้นกลุ่มเทคโนโลยีโดยใช้คะแนนวิเคราะห์ความรู้สึก จากข่าวและปัจจัยทางเศรษฐกิจ ในการศึกษาครั้งนี้ผู้วิจัย ทำการสร้างแบบจำลองการทำนายราคาปิดของหุ้นเทคโนโลยีด้วยวิธีต่าง ๆ และเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยมีผลการวิจัยดังนี้

4.1 ผลการวิเคราะห์การเตรียมข้อมูล

4.1.1 ผลการสำรวจข้อมูลราคาปิดของหุ้นเทคโนโลยีและปัจจัยทางเศรษฐกิจต่าง ๆ

พบว่ามีข้อมูลตั้งแต่ 1 มีนาคม พ.ศ. 2565 ถึง 28 กุมภาพันธ์ พ.ศ. 2568 จำนวน 753 วัน โดยมีรายละเอียดดังตารางที่ 4.1

ตารางที่ 4.1 รายละเอียดข้อมูลราคาปิดของหุ้นเทคโนโลยี และตัวแปรทางเศรษฐกิจต่าง ๆ

| ชื่อตัวแปร | ประเภท | ชนิดข้อมูล | MIN | MAX | MEAN | SD |
|--|-------------|------------|---------|----------|--------|--------|
| ราคาปิดหุ้น GOOGL | ตัวแปรตาม | Float | 83.43 | 206.38 | 135.29 | 30.22 |
| ราคาปิดหุ้น MSFT | ตัวแปรตาม | Float | 214.25 | 467.56 | 340.47 | 72.18 |
| ราคาปิดหุ้น AAPL | ตัวแปรตาม | Float | 125.02 | 259.02 | 181.69 | 31.77 |
| ราคาปิดหุ้น NVDA | ตัวแปรตาม | Float | 11.227 | 149.43 | 60.00 | 45.03 |
| ราคาปิดหุ้น META | ตัวแปรตาม | Float | 88.91 | 736.67 | 337.46 | 170.43 |
| คะแนนความรู้สึกจากข่าว ที่เกี่ยวกับหุ้น GOOGL | ตัวแปรอิสระ | Float | -0.3818 | 0.8225 | 0.2449 | 0.1879 |
| คะแนนความรู้สึกจากข่าว ที่เกี่ยวกับหุ้น MSFT | ตัวแปรอิสระ | Float | -0.5679 | 0.9349 | 0.3034 | 0.2067 |
| คะแนนความรู้สึกจากข่าว ที่เกี่ยวกับหุ้น AAPL | ตัวแปรอิสระ | Float | -0.7027 | 0.9168 | 0.2492 | 0.1975 |
| คะแนนความรู้สึกจากข่าว ที่เกี่ยวกับหุ้น NVDA | ตัวแปรอิสระ | Float | -0.7906 | 0.864433 | 0.3139 | 0.2218 |
| คะแนนความรู้สึกจากข่าว ที่เกี่ยวกับหุ้น META | ตัวแปรอิสระ | Float | -0.7269 | 0.8979 | 0.1846 | 0.2399 |
| สถานะข่าว | ตัวแปรอิสระ | Integer | 0 | 1 | - | - |

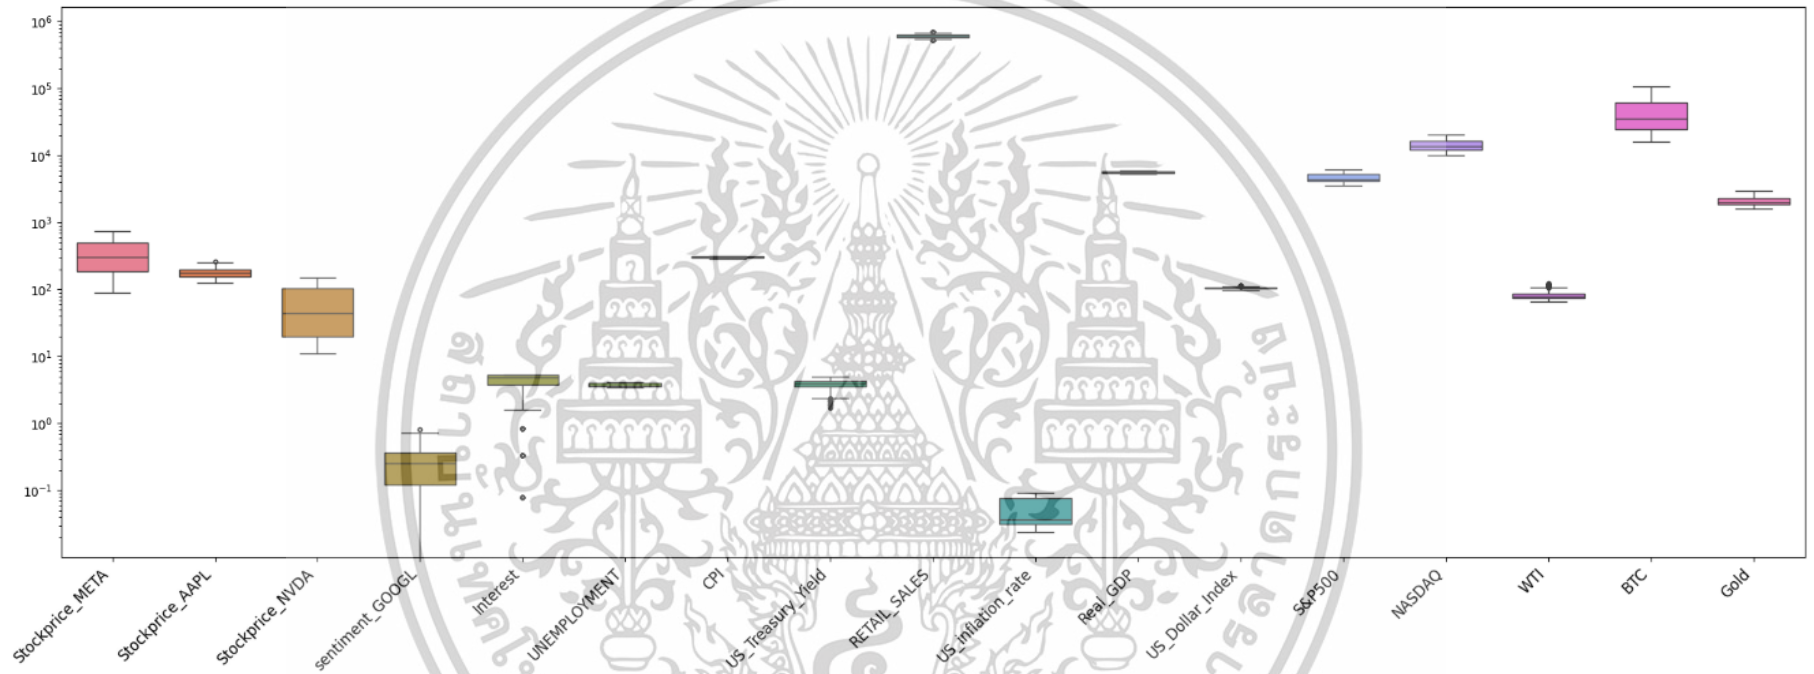
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.1 รายละเอียดข้อมูลราคาปิดของหุ้นเทคโนโลยี และตัวแปรทางเศรษฐกิจต่าง ๆ (ต่อ)

| ชื่อตัวแปร | ประเภท | ชนิดข้อมูล | MIN | MAX | MEAN | SD |
|-----------------------------|-------------|------------|----------|----------|----------|----------|
| Unemployment | ตัวแปรอิสระ | Float | 3.4 | 4.2 | 3.78 | 0.24 |
| U.S. Treasury Yield | ตัวแปรอิสระ | Float | 1.72 | 4.98 | 3.85 | 0.62 |
| Retail Sales | ตัวแปรอิสระ | Integer | 526218 | 702255 | 605615 | 33317.88 |
| U.S. Dollar Index | ตัวแปรอิสระ | Float | 97.39 | 114.11 | 104.52 | 2.89 |
| Fed Interest Rate | ตัวแปรอิสระ | Float | 287.50 | 317.67 | 4.18 | 1.57 |
| U.S. Inflation rate | ตัวแปรอิสระ | Float | 0.024 | 0.091 | 0.05 | 0.02 |
| U.S. Gross Domestic Product | ตัวแปรอิสระ | Float | 5337.27 | 6001.465 | 5705.16 | 179.94 |
| U.S. Consumer Price Index | ตัวแปรอิสระ | Float | 287.504 | 317.671 | 305.58 | 8.44 |
| ราคาทองคำ (Gold) | ตัวแปรอิสระ | Float | 1623.6 | 2956.1 | 2100.12 | 334.02 |
| ราคาน้ำมัน (WTI) | ตัวแปรอิสระ | Float | 65.72 | 126.47 | 82.09 | 12.32 |
| S&P 500 | ตัวแปรอิสระ | Float | 3577.03 | 6144.15 | 4682.79 | 730.07 |
| Nasdaq 100 | ตัวแปรอิสระ | Float | 10213.29 | 20173.89 | 14431.59 | 2820.98 |
| ราคา Bitcoin | ตัวแปรอิสระ | Float | 15776.2 | 106157.2 | 43979.72 | 24230.92 |

4.1.2 ผลการจัดการค่านอกเกณฑ์

จากการตรวจสอบพบว่าตัวแปร Fed Interest Rate มีค่านอกเกณฑ์ ดังรูป 4.1 ผู้วิจัยจึงนำตัวแปร Fed Interest Rate หาค่านอกเกณฑ์สุดโต่ง (Extreme Outlier) พบว่าไม่มีค่านอกเกณฑ์สุดโต่ง จึงไม่ทำการตัดข้อมูลออก



รูปที่ 4.1 แผนภาพกล่องของข้อมูลราคาปิดของหุ้นเทคโนโลยี และตัวแปรทางเศรษฐกิจต่าง ๆ

4.2 การวิเคราะห์ความรู้สึกจากข่าว

นำข้อมูลเนื้อหาสรุปข่าวที่รวบรวมได้ มาแปลงเป็นค่าอารมณ์ โดยใช้ VADER Sentiment ในการวิเคราะห์อารมณ์ในข่าว แล้วนำค่าอารมณ์มาหาค่าเฉลี่ยของวันนั้น ๆ ผู้วิจัยใช้ Python library ' nltk.sentiment' ด้วยคำสั่ง 'SentimentIntensityAnalyzer' จะได้ตัวอย่างผลลัพธ์ของข่าวเกี่ยวกับหุ้น APPL ดังรูป 4.2

| | time_published | title | summary | overall_sentiment_score |
|-----|----------------|---|---|-------------------------|
| 0 | 2025-02-28 | Buffett's On The Sidelines - Should You Follow... | Warren Buffett and Berkshire Hathaway (NYSE: ... | 0.082801 |
| 1 | 2025-02-28 | Warren Buffett's Subtle Message To Trump: 'Spe... | Warren Buffett, the legendary investor and CEO... | 0.374552 |
| 2 | 2025-02-28 | Competitor Analysis: Evaluating Apple And Comp... | In today's rapidly changing and highly competi... | 0.287114 |
| 7 | 2025-02-28 | Great News for Apple Stock Investors | Apple (NASDAQ: AAPL) stock investors are cau... | -0.383535 |
| 10 | 2025-02-28 | Tim Cook's Apple Is Developing New Technology ... | Apple Inc. AAPL is working on introducing a ne... | 0.187926 |
| ... | ... | ... | ... | ... |

รูปที่ 4.2 ตัวอย่างการแปลงค่าอารมณ์จากข้อมูลเนื้อหาสรุปข่าว

4.3 ผลการวิเคราะห์การสร้างแบบจำลองทำนายราคาปิดของหุ้น

การสร้างแบบจำลองทำนายราคาปิดของหุ้น ทำการปรับพารามิเตอร์ของแบบจำลองให้เหมาะสม เพื่อให้จะทำให้แบบจำลองมีประสิทธิภาพมากที่สุด และลดความผิดพลาดให้น้อยที่สุดในการทำนายราคาปิดของหุ้น โดยจะทำการปรับพารามิเตอร์แต่ละอัลกอริทึมทั้งหมด 5 อัลกอริทึม และหุ้นเทคโนโลยีทั้ง 5 ตัว ดังนี้

- 1) พารามิเตอร์ที่เหมาะสมแบบจำลองทำนายราคาปิดหุ้น ด้วยวิธี LightGBM แสดงค่าดังตารางที่ 4.2

ตารางที่ 4.2 ค่าพารามิเตอร์ของแบบจำลอง LightGBM

| ไฮเปอร์พารามิเตอร์ | ค่าไฮเปอร์พารามิเตอร์ | | | | |
|--------------------|-----------------------|------|------|------|------|
| | GOOGL | MSFT | AAPL | NVDA | META |
| max_depth | 5 | 3 | 3 | 3 | 3 |
| n_estimators | 600 | 600 | 600 | 200 | 600 |
| min_data_in_leaf | 25 | 25 | 25 | 25 | 25 |
| feature_fraction | 0.6 | 0.9 | 0.9 | 0.8 | 0.7 |
| max_bin | 50 | 50 | 400 | 100 | 50 |
| learning_rate | 0.2 | 0.2 | 0.2 | 0.1 | 0.2 |

2) พารามิเตอร์ที่เหมาะสมแบบจำลองทำนายราคาปิดหุ้น ด้วยวิธี XGBoost มีแสดงค่าดังตารางที่ 4.3

ตารางที่ 4.3 ค่าพารามิเตอร์ของแบบจำลอง XGBoost

| ไฮเปอร์พารามิเตอร์ | ค่าไฮเปอร์พารามิเตอร์ | | | | |
|--------------------|-----------------------|------|------|------|------|
| | GOOGL | MSFT | AAPL | NVDA | META |
| alpha | 0.1 | 0.1 | 0.1 | 0.1 | 0.1 |
| max_depth | 3 | 3 | 3 | 3 | 3 |
| n_estimators | 600 | 600 | 200 | 600 | 600 |
| colsample_bytree | 0.7 | 0.7 | 0.7 | 0.5 | 0.7 |
| min_child_weight | 3 | 1 | 1 | 1 | 1 |
| reg_lambda | 1 | 0.1 | 1 | 0.1 | 0.1 |
| learning_rate | 0.2 | 0.2 | 0.2 | 0.2 | 0.2 |

3) พารามิเตอร์ที่เหมาะสมแบบจำลองทำนายราคาปิดหุ้น ด้วยวิธี RNN แสดงค่าดังตารางที่ 4.4

ตารางที่ 4.4 ค่าพารามิเตอร์ของแบบจำลอง RNN

| ไฮเปอร์พารามิเตอร์ | ค่าไฮเปอร์พารามิเตอร์ | | | | |
|--------------------|-----------------------|------|---------|------|---------|
| | GOOGL | MSFT | AAPL | NVDA | META |
| optimizer | RMSprop | Adam | RMSprop | Adam | RMSprop |
| batch_size | 32 | 16 | 32 | 16 | 32 |
| epochs | 300 | 200 | 250 | 150 | 300 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4) พารามิเตอร์ที่เหมาะสมแบบจำลองทำนายราคาปิดหุ้น ด้วยวิธี GRU แสดงค่าดังตารางที่ 4.5

ตารางที่ 4.5 ค่าพารามิเตอร์ของแบบจำลอง GRU

| ไฮเปอร์พารามิเตอร์ | ค่าไฮเปอร์พารามิเตอร์ | | | | |
|--------------------|-----------------------|-------|---------|-------|-------|
| | GOOGL | MSFT | AAPL | NVDA | META |
| optimizer | RMSprop | Nadam | RMSprop | AdamW | AdamW |
| batch_size | 16 | 16 | 16 | 16 | 16 |
| epochs | 300 | 300 | 250 | 300 | 200 |

5) พารามิเตอร์ที่เหมาะสมแบบจำลองทำนายราคาปิดหุ้น ด้วยวิธี LSTM แสดงค่าดังตารางที่ 4.6

ตารางที่ 4.6 ค่าพารามิเตอร์ของแบบจำลอง LSTM

| ไฮเปอร์พารามิเตอร์ | ค่าไฮเปอร์พารามิเตอร์ | | | | |
|--------------------|-----------------------|---------|------|------|-------|
| | GOOGL | MSFT | AAPL | NVDA | META |
| optimizer | AdamW | RMSprop | Adam | Adam | Nadam |
| batch_size | 16 | 16 | 16 | 16 | 16 |
| epochs | 300 | 300 | 300 | 250 | 300 |

4.4 ผลการวัดประสิทธิภาพของแบบจำลอง

4.4.1 ผลการเปรียบเทียบประสิทธิภาพของทุกแบบจำลองของหุ้นเทคโนโลยีแต่ละตัว

ผลการทดลองมีหลายแบบจำลองจึงสรุปเปรียบเทียบให้ทราบถึงผลการทดลอง และเลือกแบบจำลองที่ดีที่สุด โดยเปรียบเทียบประสิทธิภาพของแบบจำลองจากทั้งหมด 5 วิธีได้แก่ LightGBM, XGBoost, RNN, GRU และ LSTM ของแต่ละหุ้นด้วย สถิติทดสอบ Repeated Measure ANOVA หรือ Friedman test ดังนี้

1) แบบจำลองในการทำนายราคาปิดของหุ้น GOOGL

ตารางที่ 4.7 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ด้วยวิธีต่าง ๆ

| | อัลกอริทึม | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|------------|--------------------|-----|----------|---------------|-----|---------|
| | | ค่าสถิติทดสอบ | df | p-value. | ค่าสถิติทดสอบ | df | p-value |
| ค่า | LightGBM | .146 | 179 | .000 | .941 | 179 | .000 |
| ความคลาด | XGBoost | .094 | 179 | .001 | .966 | 179 | .000 |
| เคลื่อน | RNN | .123 | 179 | .000 | .932 | 179 | .000 |
| | GRU | .109 | 179 | .000 | .944 | 179 | .000 |
| | LSTM | .092 | 179 | .001 | .961 | 179 | .000 |

จากตารางที่ 4.7 การตรวจสอบข้อตกลงเบื้องต้นที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าค่าความคลาดเคลื่อนการทำนายหุ้น GOOGL ที่ใช้อัลกอริทึม LightGBM, XGBoost, RNN, GRU และ LSTM ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของฟริตแมนในการทดสอบความแตกต่างระหว่างค่ามัธยฐานของทุกแบบจำลอง

ตารางที่ 4.8 ผลการทดสอบฟริตแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ด้วยวิธีต่าง ๆ

| สมมติฐานว่าง | การทดสอบ | p-value | การตัดสินใจ |
|--|---|---------|--------------------|
| การแจกแจงของค่าความคลาดเคลื่อนของ LightGBM, XGBoost, RNN, GRU และ LSTM เหมือนกัน | การวิเคราะห์ความแปรปรวนแบบจัดอันดับของ Friedman | 0.000 | ปฏิเสธสมมติฐานว่าง |

จากตารางที่ 4.8 การทดสอบของฟริตแมน พบว่า P-value = 0.000 ที่ระดับนัยสำคัญ 0.05 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่า ประสิทธิภาพของแบบจำลองทั้ง 5 อัลกอริทึม มีอย่างน้อย 1 คู่ที่แตกต่างกัน จึงทำการเปรียบเทียบพหุคูณ เพื่อทดสอบความแตกต่างของค่ามัธยฐานแต่ละคู่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.9 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ด้วยวิธีต่าง ๆ

| เปรียบเทียบระหว่าง แบบจำลอง | ค่าสถิติทดสอบ | ค่าความคลาด เคลื่อน | ค่าสถิติ มาตรฐาน | p-value | Adj. p-value |
|--------------------------------|---------------|------------------------|---------------------|---------|--------------|
| GRU-LSTM | -.961 | .167 | -5.749 | .000 | .000 |
| GRU-RNN | 1.827 | .167 | 10.930 | .000 | .000 |
| GRU-LightGBM | 2.397 | .167 | 14.340 | .000 | .000 |
| GRU-XGBoost | 3.279 | .167 | 19.621 | .000 | .000 |
| LSTM-RNN | .866 | .167 | 5.181 | .000 | .000 |
| LSTM-LightGBM | 1.436 | .167 | 8.591 | .000 | .000 |
| LSTM-XGBoost | 2.318 | .167 | 13.872 | .000 | .000 |
| RNN-LightGBM | .570 | .167 | 3.409 | .001 | .007 |
| RNN-XGBoost | 1.453 | .167 | 8.691 | .000 | .000 |
| LightGBM-XGBoost | -.883 | .167 | -5.281 | .000 | .000 |

จากตารางที่ 4.9 การเปรียบเทียบแบบจำลองรายคู่ทั้งหมด 10 คู่ พบว่า ที่ระดับนัยสำคัญ 0.05 ค่ามัธยฐานของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น GOOGL ทุกรายคู่มีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ ซึ่งหมายความว่า การเลือกใช้แบบจำลองการทำนายมีอิทธิพลอย่างมีนัยสำคัญต่อผลลัพธ์ที่ได้

2) แบบจำลองในการทำนายราคาปิดของหุ้น MSFT

ตารางที่ 4.10 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT ด้วยวิธีต่าง ๆ

| | อัลกอริทึม | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|---------------------|------------|--------------------|-----|---------|---------------|-----|---------|
| | | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่า | LightGBM | .035 | 179 | .200 | .991 | 179 | .299 |
| ความคลาด เคลื่อน | XGBoost | .098 | 179 | .000 | .974 | 179 | .002 |
| | RNN | .088 | 179 | .002 | .968 | 179 | .000 |
| | GRU | .092 | 179 | .001 | .969 | 179 | .000 |
| | LSTM | .119 | 179 | .000 | .941 | 179 | .000 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.10 การตรวจสอบเบื้องต้นที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าค่าความคลาดเคลื่อนการทำนายหุ้น MSFT ที่ใช้อัลกอริทึม LightGBM มีการแจกแจงแบบปกติ แต่อัลกอริทึม XGBoost, RNN, GRU และ LSTM ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของฟรีดแมนในการทดสอบความแตกต่างระหว่างค่ามัธยฐานของทุกแบบจำลอง

ตารางที่ 4.11 ผลการทดสอบฟรีดแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT ด้วยวิธีต่าง ๆ

| สมมติฐานว่าง | การทดสอบ | p-value | การตัดสินใจ |
|--|---|---------|--------------------|
| การแจกแจงของค่าความคลาดเคลื่อนของ LightGBM, XGBoost, RNN, GRU และ LSTM เหมือนกัน | การวิเคราะห์ความแปรปรวนแบบจัดอันดับของ Friedman | 0.000 | ปฏิเสธสมมติฐานว่าง |

จากตารางที่ 4.11 การทดสอบของฟรีดแมน พบว่า P-value = 0.000 ที่ระดับนัยสำคัญ 0.05 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่า ประสิทธิภาพของแบบจำลองทั้ง 5 อัลกอริทึม มีอย่างน้อย 1 คู่ที่แตกต่างกัน จึงทำการเปรียบเทียบพหุคูณ เพื่อทดสอบความแตกต่างของค่ามัธยฐานแต่ละคู่

ตารางที่ 4.12 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT ด้วยวิธีต่าง ๆ

| เปรียบเทียบระหว่างแบบจำลอง | ค่าสถิติทดสอบ | ค่าความคลาดเคลื่อน | ค่าสถิติมาตรฐาน | p-value | Adj. p-value |
|----------------------------|---------------|--------------------|-----------------|---------|--------------|
| LSTM-XGBoost | .140 | .167 | .836 | .403 | 1.000 |
| LSTM-GRU | .961 | .167 | 5.749 | .000 | .000 |
| LSTM-RNN | 2.335 | .167 | 13.972 | .000 | .000 |
| LSTM-LightGBM | 2.793 | .167 | 16.713 | .000 | .000 |
| XGBoost-GRU | -.821 | .167 | -4.914 | .000 | .000 |
| XGBoost-RNN | -2.196 | .167 | -13.137 | .000 | .000 |
| XGBoost-LightGBM | 2.654 | .167 | 15.877 | .000 | .000 |
| GRU-RNN | 1.374 | .167 | 8.223 | .000 | .000 |
| GRU-LightGBM | 1.832 | .167 | 10.964 | .000 | .000 |
| RNN-LightGBM | .458 | .167 | 2.741 | .006 | .061 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.12 การเปรียบเทียบแบบจำลองรายคู่ทั้งหมด 10 คู่ พบว่า ที่ระดับนัยสำคัญ 0.05 ค่ามัธยฐานของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น MSFT มี 1 คู่อัลกอริทึมที่ไม่แตกต่างกันคือ อัลกอริทึม LSTM กับ XGBoost ซึ่งหมายความว่าทางเลือกใช้แบบจำลองคู่นี้อาจให้ผลการทำนายที่ไม่แตกต่างกันอย่างมีนัยสำคัญ ขณะที่แบบจำลองคู่อื่น ๆ ทั้งหมดแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

3) แบบจำลองในการทำนายราคาปิดของหุ้น AAPL

ตารางที่ 4.13 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL ด้วยวิธีต่าง ๆ

| ค่า | อัลกอริทึม | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|---------------------|------------|--------------------|-----|---------|---------------|-----|---------|
| | | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ความคลาด เคลื่อน | LightGBM | .091 | 179 | .001 | .969 | 179 | .000 |
| | XGBoost | .094 | 179 | .001 | .972 | 179 | .001 |
| | RNN | .098 | 179 | .000 | .974 | 179 | .002 |
| | GRU | .126 | 179 | .000 | .951 | 179 | .000 |
| | LSTM | .170 | 179 | .000 | .914 | 179 | .000 |

จากตารางที่ 4.13 การตรวจสอบข้อตกลงเบื้องต้นที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าค่าความคลาดเคลื่อนการทำนายหุ้น AAPL ที่ใช้อัลกอริทึม LightGBM, XGBoost, RNN, GRU และ LSTM ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของฟริตแมนในการทดสอบความแตกต่างระหว่างค่ามัธยฐานของทุกแบบจำลอง

ตารางที่ 4.14 ผลการทดสอบฟริตแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL ด้วยวิธีต่าง ๆ

| สมมติฐานว่าง | การทดสอบ | p-value | การตัดสินใจ |
|--|---|---------|--------------------|
| การแจกแจงของค่าความคลาดเคลื่อนของ LightGBM, XGBoost, RNN, GRU และ LSTM เหมือนกัน | การวิเคราะห์ความแปรปรวนแบบจัดอันดับของ Friedman | 0.000 | ปฏิเสธสมมติฐานว่าง |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.14 การทดสอบของพรีดแมน พบว่า P-value = 0.000 ที่ระดับนัยสำคัญ 0.05 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่า ประสิทธิภาพของแบบจำลองทั้ง 5 อัลกอริทึม มีอย่างน้อย 1 คู่ที่แตกต่างกัน จึงทำการเปรียบเทียบพหุคูณ เพื่อทดสอบความแตกต่างของค่ามัธยฐานแต่ละคู่

ตารางที่ 4.15 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL ด้วยวิธีต่าง ๆ

| เปรียบเทียบระหว่าง แบบจำลอง | ค่าสถิติทดสอบ | ค่าความคลาด เคลื่อน | ค่าสถิติ มาตรฐาน | p-value | Adj. p-value |
|--------------------------------|---------------|------------------------|---------------------|---------|--------------|
| XGBoost-LightGBM | .704 | .167 | 4.212 | .000 | .000 |
| XGBoost-RNN | -1.575 | .167 | -9.426 | .000 | .000 |
| XGBoost-LSTM | -1.609 | .167 | -9.627 | .000 | .000 |
| XGBoost-GRU | -2.955 | .167 | -17.683 | .000 | .000 |
| LightGBM-RNN | -.872 | .167 | -5.215 | .000 | .000 |
| LightGBM-LSTM | -.905 | .167 | -5.415 | .000 | .000 |
| LightGBM-GRU | -2.251 | .167 | -13.471 | .000 | .000 |
| RNN-LSTM | -.034 | .167 | -.201 | .841 | 1.000 |
| RNN-GRU | -1.380 | .167 | -8.256 | .000 | .000 |
| LSTM-GRU | 1.346 | .167 | 8.056 | .000 | .000 |

จากตารางที่ 4.15 การเปรียบเทียบแบบจำลองรายคู่ทั้งหมด 10 คู่ พบว่า ที่ระดับนัยสำคัญ 0.05 ค่ามัธยฐานของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น AAPL มี 1 คู่อัลกอริทึมที่ไม่แตกต่างกันคือ อัลกอริทึม RNN กับ LSTM ซึ่งหมายความว่า การเลือกใช้แบบจำลองคู่นี้ อาจให้ผลการทำนายที่ไม่แตกต่างกันอย่างมีนัยสำคัญ ขณะที่แบบจำลองคู่อื่น ๆ ทั้งหมดแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

4) แบบจำลองในการทำนายราคาปิดของหุ้น NVDA

ตารางที่ 4.16 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ด้วยวิธีต่าง ๆ

| | อัลกอริทึม | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|------------|--------------------|-----|---------|---------------|-----|---------|
| | | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่า | LightGBM | .061 | 179 | .200 | .971 | 179 | .001 |
| ความคลาด | XGBoost | .061 | 179 | .098 | .983 | 179 | .031 |
| เคลื่อน | RNN | .062 | 179 | .094 | .975 | 179 | .002 |
| | GRU | .063 | 179 | .080 | .981 | 179 | .014 |
| | LSTM | .081 | 179 | .006 | .969 | 179 | .001 |

จากตารางที่ 4.16 การตรวจสอบข้อตกลงเบื้องต้นที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าค่าความคลาดเคลื่อนการทำนายหุ้น NVDA ที่ใช้อัลกอริทึม LSTM ไม่มีการแจกแจงแบบปกติ ขณะที่อัลกอริทึมอื่น ๆ มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของฟริตแมนในการทดสอบความแตกต่างระหว่างค่ามัธยฐานของทุกแบบจำลอง

ตารางที่ 4.17 ผลการทดสอบฟริตแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ด้วยวิธีต่าง ๆ

| สมมติฐานว่าง | การทดสอบ | p-value | การตัดสินใจ |
|--|---|---------|--------------------|
| การแจกแจงของค่าความคลาดเคลื่อนของ LightGBM, XGBoost, RNN, GRU และ LSTM เหมือนกัน | การวิเคราะห์ความแปรปรวนแบบจัดอันดับของ Friedman | 0.000 | ปฏิเสธสมมติฐานว่าง |

จากตารางที่ 4.17 การทดสอบของฟริตแมน พบว่า P-value = 0.000 ที่ระดับนัยสำคัญ 0.05 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่า ประสิทธิภาพของแบบจำลองทั้ง 5 อัลกอริทึม มีอย่างน้อย 1 คู่ที่แตกต่างกัน จึงทำการเปรียบเทียบพหุคูณ เพื่อทดสอบความแตกต่างของค่ามัธยฐานแต่ละคู่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.18 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ด้วยวิธีต่าง ๆ

| เปรียบเทียบระหว่าง แบบจำลอง | ค่าสถิติทดสอบ | ค่าความคลาด เคลื่อน | ค่าสถิติ มาตรฐาน | p-value | Adj. p-value |
|--------------------------------|---------------|------------------------|---------------------|---------|--------------|
| GRU-LSTM | -1.464 | .167 | -8.758 | .000 | .000 |
| GRU-XGBoost | 1.844 | .167 | 11.031 | .000 | .000 |
| GRU-RNN | 2.676 | .167 | 16.011 | .000 | .000 |
| GRU-LightGBM | 3.961 | .167 | 23.699 | .000 | .000 |
| LSTM-XGBoost | .380 | .167 | 2.273 | .023 | .230 |
| LSTM-RNN | 1.212 | .167 | 7.254 | .000 | .000 |
| LSTM-LightGBM | 2.497 | .167 | 14.942 | .000 | .000 |
| XGBoost-RNN | -.832 | .167 | -4.981 | .000 | .000 |
| XGBoost-LightGBM | 2.117 | .167 | 12.669 | .000 | .000 |
| RNN-LightGBM | 1.285 | .167 | 7.688 | .000 | .000 |

จากตารางที่ 4.18 การเปรียบเทียบแบบจำลองรายคู่ทั้งหมด 10 คู่ พบว่า ที่ระดับนัยสำคัญ 0.05 ค่ามัธยฐานของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น NVDA ทุกรายคู่มีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ ซึ่งหมายความว่า การเลือกใช้แบบจำลองการทำนายมีอิทธิพลอย่างมีนัยสำคัญต่อผลลัพธ์ที่ได้

5) แบบจำลองในการทำนายราคาปิดของหุ้น META

ตารางที่ 4.19 ผลการทดสอบการแจกแจงปกติของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META ด้วยวิธีต่าง ๆ

| | อัลกอริทึม | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|------------|--------------------|-----|---------|---------------|-----|---------|
| | | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่า | LightGBM | .097 | 179 | .000 | .973 | 179 | .001 |
| ความคลาด | XGBoost | .067 | 179 | .049 | .976 | 179 | .004 |
| เคลื่อน | RNN | .070 | 179 | .033 | .962 | 179 | .000 |
| | GRU | .088 | 179 | .002 | .970 | 179 | .001 |
| | LSTM | .156 | 179 | .000 | .910 | 179 | .000 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.19 การตรวจสอบข้อตกลงเบื้องต้นที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าค่าความคลาดเคลื่อนการทำนายหุ้น META ที่ใช้อัลกอริทึม LightGBM, XGBoost, RNN, GRU และ LSTM ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของฟรیدแมนในการทดสอบความแตกต่างระหว่างค่ามัธยฐานของทุกแบบจำลอง

ตารางที่ 4.20 ผลการทดสอบฟรیدแมนของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META ด้วยวิธีต่าง ๆ

| สมมติฐานว่าง | การทดสอบ | p-value | การตัดสินใจ |
|--|---|---------|--------------------|
| การแจกแจงของค่าความคลาดเคลื่อนของ LightGBM, XGBoost, RNN, GRU และ LSTM เหมือนกัน | การวิเคราะห์ความแปรปรวนแบบจัดอันดับของ Friedman | 0.000 | ปฏิเสธสมมติฐานว่าง |

จากตารางที่ 4.20 การทดสอบของฟรیدแมน พบว่า P-value = 0.000 ที่ระดับนัยสำคัญ 0.05 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่า ประสิทธิภาพของแบบจำลองทั้ง 5 อัลกอริทึม มีอย่างน้อย 1 คู่ที่แตกต่างกัน จึงทำการเปรียบเทียบพหุคูณ เพื่อทดสอบความแตกต่างของค่ามัธยฐานแต่ละคู่

ตารางที่ 4.21 ผลการเปรียบเทียบพหุคูณของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META ด้วยวิธีต่าง ๆ

| เปรียบเทียบระหว่างแบบจำลอง | ค่าสถิติทดสอบ | ค่าความคลาดเคลื่อน | ค่าสถิติมาตรฐาน | p-value | Adj. p-value |
|----------------------------|---------------|--------------------|-----------------|---------|--------------|
| GRU-LightGBM | 1.251 | .167 | 7.487 | .000 | .000 |
| GRU-LSTM | -1.592 | .167 | -9.526 | .000 | .000 |
| GRU-RNN | 1.816 | .167 | 10.864 | .000 | .000 |
| GRU-XGBoost | 2.659 | .167 | 15.911 | .000 | .000 |
| LightGBM-LSTM | -.341 | .167 | -2.039 | .041 | .414 |
| LightGBM-RNN | -.564 | .167 | -3.376 | .001 | .007 |
| LightGBM-XGBoost | -1.408 | .167 | -8.423 | .000 | .000 |
| LSTM-RNN | .223 | .167 | 1.337 | .181 | 1.000 |
| LSTM-XGBoost | 1.067 | .167 | 6.384 | .000 | .000 |
| RNN-XGBoost | .844 | .167 | 5.047 | .000 | .000 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.21 การเปรียบเทียบแบบจำลองรายคู่ทั้งหมด 10 คู่ พบว่า ที่ระดับนัยสำคัญ 0.05 ค่ามัธยฐานของค่าความคลาดเคลื่อนการทำนายราคาปิดของหุ้น META มี 1 คู่อัลกอริทึมที่ไม่แตกต่างกันคือ อัลกอริทึม LSTM กับ RNN ซึ่งหมายความว่าทางเลือกใช้แบบจำลองคู่นี้อาจให้ผลการทำนายที่ไม่แตกต่างกันอย่างมีนัยสำคัญ ขณะที่ แบบจำลองคู่อื่น ๆ ทั้งหมดแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

4.4.2 ผลการวัดประสิทธิภาพของแบบจำลอง

เมื่อทำการเปรียบเทียบความแตกต่างประสิทธิภาพของแบบจำลองเรียบร้อยแล้ว จากนั้นทำการวัดประสิทธิภาพของแบบจำลอง ด้วยค่าเฉลี่ยร้อยละความคลาดเคลื่อนสมบูรณ์ (MAE) ดังตารางที่ 4.22 และค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (MAPE) ดังตารางที่ 4.23

ตารางที่ 4.22 ประสิทธิภาพของแบบจำลองหุ้นเทคโนโลยีด้วยอัลกอริทึมต่าง ๆ ด้วยค่า MAE

| แบบจำลอง | อัลกอริทึม | | | | |
|----------|------------|----------------|----------------|----------------|---------|
| | LightGBM | XGBoost | RNN | GRU | LSTM |
| GOOGL | 14.3038 | 13.8089 | 10.4465 | 11.6317 | 10.4994 |
| MSFT | 24.9004 | 12.2786 | 14.0696 | 13.1344 | 12.4384 |
| AAPL | 43.4929 | 41.9582 | 48.5218 | 52.8068 | 48.9581 |
| NVDA | 34.6175 | 29.6176 | 31.7813 | 23.1482 | 28.7698 |
| META | 79.0521 | 89.7530 | 87.7123 | 75.2969 | 99.2184 |

ตารางที่ 4.23 ประสิทธิภาพของแบบจำลองหุ้นเทคโนโลยีด้วยอัลกอริทึมต่าง ๆ ด้วยค่า MAPE

| แบบจำลอง | อัลกอริทึม | | | | |
|----------|------------|---------------|---------------|---------------|--------|
| | LightGBM | XGBoost | RNN | GRU | LSTM |
| GOOGL | 0.0776 | 0.0751 | 0.0571 | 0.0678 | 0.0598 |
| MSFT | 0.0576 | 0.0285 | 0.0322 | 0.0304 | 0.0287 |
| AAPL | 0.1883 | 0.1815 | 0.2092 | 0.2280 | 0.2109 |
| NVDA | 0.2643 | 0.2250 | 0.2408 | 0.1748 | 0.2181 |
| META | 0.1299 | 0.1485 | 0.1439 | 0.1233 | 0.1600 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4.3 ผลการประเมินประสิทธิภาพของแบบจำลอง

เมื่อได้แบบจำลองที่เหมาะสมที่สุดของหุ่นเทคโนโลยีแต่ละตัวเรียบร้อยแล้ว ทำการประเมินประสิทธิภาพของแบบจำลองด้วย Paired t-test หรือ Wilcoxon Signed-Rank Test ดังนี้

1) แบบจำลองการทำนายราคาปิดของหุ้น GOOGL ใช้วิธี RNN

ตารางที่ 4.24 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น GOOGL

| | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|--------------------|-----|---------|---------------|-----|---------|
| | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่าจริง | .105 | 179 | .000 | .965 | 179 | .000 |
| ค่าทำนาย | .180 | 179 | .000 | .901 | 179 | .000 |

จากตารางที่ 4.24 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าข้อมูลทั้ง 2 ชุด ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของ Wilcoxon signed-rank test ในการประเมินประสิทธิภาพของแบบจำลอง

ตารางที่ 4.25 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น GOOGL

| | ค่าทำนาย - ค่าจริง |
|------------------------|--------------------|
| Z | -5.893 |
| Asymp. Sig. (2-tailed) | .000 |

จากตารางที่ 4.25 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Wilcoxon signed-rank test พบว่า P-value = 0.000 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่าค่าจริงและค่าทำนายมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

2) แบบจำลองทำนายราคาปิดของหุ้น MSFT ใช้วิธี XGBoost

ตารางที่ 4.26 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น MSFT

| | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|--------------------|-----|---------|---------------|-----|---------|
| | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่าจริง | .105 | 179 | .000 | .965 | 179 | .000 |
| ค่าทำนาย | .180 | 179 | .000 | .901 | 179 | .000 |

จากตารางที่ 4.26 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าข้อมูลทั้ง 2 ชุด ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของ Wilcoxon signed-rank test ในการประเมินประสิทธิภาพของแบบจำลอง

ตารางที่ 4.27 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น MSFT

| | ค่าทำนาย - ค่าจริง |
|------------------------|--------------------|
| Z | -11.603 |
| Asymp. Sig. (2-tailed) | .000 |

จากตารางที่ 4.27 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Wilcoxon signed-rank test พบว่า P-value = 0.000 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่าค่าจริงและค่าทำนายมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

3) แบบจำลองทำนายราคาปิดของหุ้น AAPL ใช้วิธี XGBoost

ตารางที่ 4.28 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น AAPL

| | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|--------------------|-----|---------|---------------|-----|---------|
| | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่าจริง | .105 | 179 | .000 | .965 | 179 | .000 |
| ค่าทำนาย | .180 | 179 | .000 | .901 | 179 | .000 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.28 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าข้อมูลทั้ง 2 ชุด ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของ Wilcoxon signed-rank test ในการประเมินประสิทธิภาพของแบบจำลอง

ตารางที่ 4.29 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น AAPL

| | ค่าทำนาย - ค่าจริง |
|------------------------|--------------------|
| Z | -1.197 |
| Asymp. Sig. (2-tailed) | .231 |

จากตารางที่ 4.29 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Wilcoxon signed-rank test พบว่า P-value = 0.000 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่าค่าจริงและค่าทำนายมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

4) แบบจำลองทำนายราคาปิดของหุ้น NVDA ใช้วิธี GRU

ตารางที่ 4.30 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น NVDA

| | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|--------------------|-----|---------|---------------|-----|---------|
| | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่าจริง | .105 | 179 | .000 | .965 | 179 | .000 |
| ค่าทำนาย | .180 | 179 | .000 | .901 | 179 | .000 |

จากตารางที่ 4.30 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าข้อมูลทั้ง 2 ชุด ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของ Wilcoxon signed-rank test ในการประเมินประสิทธิภาพของแบบจำลอง

ตารางที่ 4.31 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น NVDA

| | ค่าทำนาย - ค่าจริง |
|------------------------|--------------------|
| Z | -11.598 |
| Asymp. Sig. (2-tailed) | .000 |

จากตารางที่ 4.31 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Wilcoxon signed-rank test พบว่า P-value = 0.000 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่าค่าจริงและค่าทำนายมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

5) แบบจำลองทำนายราคาปิดของหุ้น META ใช้วิธี GRU

ตารางที่ 4.32 ผลการทดสอบการแจกแจงปกติของค่าจริงและค่าทำนายของหุ้น META

| | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
|----------|--------------------|-----|---------|---------------|-----|---------|
| | ค่าสถิติทดสอบ | df | p-value | ค่าสถิติทดสอบ | df | p-value |
| ค่าจริง | .105 | 179 | .000 | .965 | 179 | .000 |
| ค่าทำนาย | .180 | 179 | .000 | .901 | 179 | .000 |

จากตารางที่ 4.32 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Kolmogorov Smirnov พบว่าข้อมูลทั้ง 2 ชุด ไม่มีการแจกแจงแบบปกติ ดังนั้นจึงใช้การทดสอบของ Wilcoxon signed-rank test ในการประเมินประสิทธิภาพของแบบจำลอง

ตารางที่ 4.33 ผลการทดสอบความแตกต่างของค่าจริงและค่าทำนายของหุ้น META

| | ค่าทำนาย - ค่าจริง |
|------------------------|--------------------|
| Z | -10.639 |
| Asymp. Sig. (2-tailed) | .000 |

จากตารางที่ 4.33 ที่ระดับนัยสำคัญ 0.05 จากการทดสอบ Wilcoxon signed-rank test พบว่า P-value = 0.000 จึงไม่สามารถยอมรับ H_0 ดังนั้นสามารถสรุปได้ว่าค่าจริงและค่าทำนายมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

4.5 ผลการวิเคราะห์ความสำคัญของตัวแปร

การวิเคราะห์ความสำคัญของตัวแปรเพื่อทำความเข้าใจว่าปัจจัยใดส่งผลต่อผลลัพธ์ของแบบจำลอง ดังนี้

1) แบบจำลองทำนายราคาปิดของหุ้น GOOGL

ตารางที่ 4.34 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง RNN ในการทำนายราคาปิดหุ้น GOOGL

| Feature | Weight |
|-----------------------------------|---------|
| ดัชนี NASDAQ | 0.3643 |
| ราคา Bitcoin | 0.1919 |
| ราคาน้ำมัน | 0.1198 |
| ดัชนีค่าเงินดอลลาร์สหรัฐฯ | 0.1170 |
| อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ | 0.0702 |
| อัตราการว่างงานของสหรัฐฯ | 0.0521 |
| อัตราเงินเฟ้อของสหรัฐฯ | 0.0166 |
| sentiment_GOOGL | 0.0155 |
| สถานะข่าว | 0.0012 |
| อัตราดอกเบี้ยของสหรัฐฯ | -0.0062 |
| ดัชนีราคาผู้บริโภค | -0.0097 |
| ยอดขายปลีก | -0.0103 |
| ดัชนี S&P500 | -0.0489 |
| ผลิตภัณฑ์มวลรวมภายในประเทศ | -0.0715 |
| ราคาทองคำ | -0.2987 |

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.34 พบว่าตัวแปรที่มีอิทธิพลต่อผลการทำนายราคาปิดของหุ้น NVDA ได้แก่ ดัชนี NASDAQ ซึ่งมีค่าน้ำหนักสูงสุดที่ 0.3643 รองลงมาคือราคา Bitcoin มีค่าน้ำหนัก 0.1919 และราคาน้ำมันที่ 0.1198 ในทางกลับกันตัวแปรบางตัว เช่น ราคาทองคำ, ผลิตภัณฑ์มวลรวมภายในประเทศ และดัชนี S&P500 มีค่าเท่ากับ -0.2987 , -0.0715 และ -0.0489 ตามลำดับ ซึ่งมีค่าน้ำหนักติดลบค่อนข้างสูงหมายความว่าอาจเป็นตัวแปรที่รบกวนแบบจำลองทำให้ผลทำนายแยกลงเมื่อนำมาใช้

2) แบบจำลองทำนายราคาปิดของหุ้น MSFT

ตารางที่ 4.35 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง XGBoost ในการทำนายราคาปิดหุ้น MSFT

| Feature | Weight |
|-----------------------------------|---------|
| อัตราเงินเฟ้อของสหรัฐฯ | 0.0473 |
| ราคาน้ำมัน | 0.0275 |
| ดัชนี NASDAQ | 0.0245 |
| ดัชนีค่าเงินดอลลาร์สหรัฐฯ | 0.0237 |
| ดัชนี S&P500 | 0.0128 |
| อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ | 0.0052 |
| sentiment_MSFT | 0.001 |
| ราคาทองคำ | 0.0001 |
| สถานะข่าว | 0 |
| อัตราการว่างงานของสหรัฐฯ | 0 |
| ดัชนีราคาผู้บริโภค | 0 |
| ผลิตภัณฑ์มวลรวมภายในประเทศ | -0.0007 |
| ยอดขายปลีก | -0.0019 |
| อัตราดอกเบี้ยของสหรัฐฯ | -0.0291 |
| ราคา Bitcoin | -0.0565 |

จากตารางที่ 4.35 พบว่าตัวแปรที่มีอิทธิพลต่อผลการทำนายราคาปิดของหุ้น NVDA ได้แก่ อัตราเงินเฟ้อของสหรัฐฯ ซึ่งมีค่าน้ำหนักสูงสุดที่ 0.0473 รองลงมาคือราคาน้ำมันดิบ ดัชนี NASDAQ และดัชนีค่าเงิน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดอลลาร์สหรัฐฯ มีค่าน้ำหนักเท่ากับ 0.0275, 0.0245 และ 0.0237 ตามลำดับ ในทางกลับกันตัวแปรบางตัว เช่น อัตราดอกเบี้ย และราคา Bitcoin มีค่าเท่ากับ -0.0291 และ -0.0565 ตามลำดับ ซึ่งมีค่าน้ำหนักติดลบค่อนข้างสูงหมายความว่าอาจเป็นตัวแปรที่รบกวนแบบจำลองทำให้ผลทำนายแยกลงเมื่อนำมาใช้

3) แบบจำลองทำนายราคาปิดของหุ้น AAPL

ตารางที่ 4.36 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง XGBoost ในการทำนายราคาปิดหุ้น AAPL

| Feature | Weight |
|-----------------------------------|---------|
| ดัชนี S&P500 | 0.0292 |
| sentiment_AAPL | 0.0106 |
| อัตราดอกเบี้ยของสหรัฐฯ | 0.0099 |
| ดัชนี NASDAQ | 0.0087 |
| ราคาทองคำ | 0 |
| ราคา Bitcoin | 0 |
| สถานะข่าว | 0 |
| ดัชนีราคาผู้บริโภค | 0 |
| อัตราการว่างงานของสหรัฐฯ | 0 |
| ผลิตภัณฑ์มวลรวมภายในประเทศ | 0 |
| ดัชนีค่าเงินดอลลาร์สหรัฐฯ | -0.0014 |
| ยอดขายปลีก | -0.0087 |
| อัตราเงินเฟ้อของสหรัฐฯ | -0.0320 |
| ราคาน้ำมัน | -0.0449 |
| อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ | -0.0602 |

จากตารางที่ 4.36 พบว่าตัวแปรที่มีอิทธิพลต่อผลการทำนายราคาปิดของหุ้น AAPL ได้แก่ ดัชนี S&P500 โดยมีค่าน้ำหนักสูงถึง 0.0292 รองลงมาคือ sentiment_AAPL มีค่าน้ำหนัก 0.0106 และอัตราดอกเบี้ยของสหรัฐฯ มีค่าน้ำหนัก 0.0099 ในทางกลับกันตัวแปรบางตัว เช่น อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, ราคาน้ำมัน และอัตราเงินเฟ้อของสหรัฐฯ มีค่าเท่ากับ -0.0602, -0.0449 และ -0.0320

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตามลำดับ ซึ่งมีค่าน้ำหนักติดลบหมายความว่าอาจเป็นตัวแปรที่รบกวนแบบจำลองทำให้ผลทำนายแยกลงเมื่อนำมาใช้

4) แบบจำลองทำนายราคาปิดของหุ้น NVDA

ตารางที่ 4.37 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง GRU ในการทำนายราคาปิดหุ้น NVDA

| Feature | Weight |
|-----------------------------------|---------|
| ผลิตภัณฑ์มวลรวมภายในประเทศ | 0.1329 |
| อัตราการว่างงานของสหรัฐฯ | 0.0696 |
| sentiment_NVDA | 0.0084 |
| อัตราดอกเบี้ยของสหรัฐฯ | 0.0073 |
| สถานะข่าว | 0 |
| อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ | -0.0069 |
| ราคาน้ำมัน | -0.0212 |
| ดัชนีค่าเงินดอลลาร์สหรัฐฯ | -0.0274 |
| ยอดขายปลีก | -0.0298 |
| ดัชนีราคาผู้บริโภค | -0.0304 |
| อัตราเงินเฟ้อของสหรัฐฯ | -0.0321 |
| ราคาทองคำ | -0.0777 |
| ดัชนี S&P500 | -0.1253 |
| ดัชนี NASDAQ | -0.1554 |
| ราคา Bitcoin | -0.2493 |

จากตารางที่ 4.37 พบว่าตัวแปรที่มีอิทธิพลต่อผลการทำนายราคาปิดของหุ้น NVDA ได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศ ซึ่งมีค่าน้ำหนักสูงสุดที่ 0.1329 รองลงมาคือ อัตราการว่างงานของสหรัฐฯ มีค่าน้ำหนัก 0.0695 ในทางกลับกันตัวแปรบางตัว เช่น ราคา Bitcoin, ดัชนี NASDAQ และ ดัชนี S&P500 มีค่าเท่ากับ -0.249, -0.155 และ -0.125 ตามลำดับ ซึ่งมีค่าน้ำหนักติดลบค่อนข้างมาก หมายความว่าอาจเป็นตัวแปรที่รบกวนแบบจำลองทำให้ผลทำนายแยกลงเมื่อนำมาใช้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5) แบบจำลองทำนายราคาปิดของหุ้น META

ตารางที่ 4.38 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยวิธี Permutation Feature Importance สำหรับแบบจำลอง GRU ในการทำนายราคาปิดหุ้น META

| Feature | Weight |
|-----------------------------------|---------|
| ราคาทองคำ | 2.1664 |
| อัตราการว่างงานของสหรัฐฯ | 1.6019 |
| ผลิตภัณฑ์มวลรวมภายในประเทศ | 0.2162 |
| อัตราดอกเบี้ยของสหรัฐฯ | 0.1223 |
| สถานะข่าว | 0.1017 |
| อัตราเงินเฟ้อของสหรัฐฯ | 0.0924 |
| ราคา Bitcoin | 0.0620 |
| ดัชนีราคาผู้บริโภค | 0.0236 |
| ราคาน้ำมัน | -0.0037 |
| sentiment_META | -0.0700 |
| อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ | -0.2169 |
| ดัชนี S&P500 | -0.5579 |
| ดัชนี NASDAQ | -0.6623 |
| ดัชนีค่าเงินดอลลาร์สหรัฐฯ | -0.8330 |
| ยอดขายปลีก | -1.4828 |

จากตารางที่ 4.38 พบว่าตัวแปรที่มีอิทธิพลต่อผลการทำนายราคาปิดของหุ้น META ได้แก่ ราคาทองคำซึ่งมีค่าน้ำหนักสูงสุดที่ 2.166 ตามด้วย อัตราการว่างงานของสหรัฐฯ ที่มีค่าน้ำหนัก 1.601 และผลิตภัณฑ์มวลรวมภายในประเทศ มีค่าน้ำหนัก 0.216 ในทางกลับกันตัวแปรบางตัว เช่น ยอดขายปลีก, ดัชนีค่าเงินดอลลาร์สหรัฐฯ และดัชนี NASDAQ มีค่าเท่ากับ -1.482, -0.832 และ -0.662 ตามลำดับ ซึ่งมีค่าน้ำหนักติดลบค่อนข้างมาก หมายความว่าอาจเป็นตัวแปรที่รบกวนแบบจำลองทำให้ผลทำนายแยกลงเมื่อนำมาใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

การศึกษาเชิงเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้นกลุ่มเทคโนโลยีโดยใช้คะแนนวิเคราะห์ความรู้สึกร่วมจากข่าวและปัจจัยทางเศรษฐกิจ ซึ่งงานวิจัยนี้มีวัตถุประสงค์ เพื่อสร้างตัวแบบจำลองการทำนายราคาหุ้นด้วยการเรียนรู้ของเครื่อง 5 วิธี ได้แก่ LightGBM, XGBoost, RNN, GRU และ LSTM และวิเคราะห์เปรียบเทียบประสิทธิภาพของแบบจำลองเพื่อระบุแบบจำลองที่เหมาะสมที่สุด และระบุปัจจัยทางเศรษฐกิจและข่าวสาร ที่ส่งผลต่อการเปลี่ยนแปลงของราคาหุ้น โดยข้อมูลที่ใช้ในการวิเคราะห์คือ ราคาปิดของหุ้นเทคโนโลยีทั้ง 5 ตัว ได้แก่ GOOGLE, MSFT, AAPL, NVDA และ META ความรู้สึกจากข่าวและตัวแปรทางเศรษฐกิจ สามารถสรุปผลได้ดังนี้

5.1 สรุปผลการวิจัย

5.1.1 สรุปแบบจำลองที่เหมาะสมในการทำนายราคาปิดของหุ้นเทคโนโลยี

งานวิจัยนี้ทำการทำนายราคาปิดของหุ้นด้วยเทคนิคการเรียนรู้ของเครื่องและโครงข่ายประสาทเทียมเชิงลึกทั้งหมด 5 วิธีประกอบไปด้วย LightGBM, XGBoost, RNN, GRU และ LSTM โดยทำการเปรียบเทียบประสิทธิภาพของแบบจำลองการทำนายราคาปิดของหุ้นเทคโนโลยี ด้วยสถิติทดสอบ ฟรีดแมน ดังนี้

1) แบบจำลองการทำนายราคาปิดของหุ้น GOOGLE วิธี RNN มีประสิทธิภาพสูงสุด เนื่องจากประสิทธิภาพของแบบจำลองการทำนายราคาปิดของหุ้น GOOGLE ด้วยอัลกอริทึม XGBoost นั้นแตกต่างกับทุกอัลกอริทึม และมีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ต่ำที่สุดที่ 10.4465 ดอลลาร์สหรัฐ และ 5.71% ตามลำดับ

2) แบบจำลองการทำนายราคาปิดของหุ้น MSFT วิธี XGBoost มีประสิทธิภาพสูงสุด มีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ต่ำที่สุดที่ 12.2786 ดอลลาร์สหรัฐ และ 2.85% ตามลำดับ และจากการทดสอบเปรียบเทียบประสิทธิภาพของแบบจำลองพบว่าอัลกอริทึม LSTM กับ XGBoost มีประสิทธิภาพไม่แตกต่างกัน ดังนั้นการเลือกใช้แบบจำลองคู่นี้อาจให้ผลการทำนายที่ไม่แตกต่างกันอย่างมีนัยสำคัญ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) แบบจำลองการทำนายราคาปิดของหุ้น AAPL วิธี XGBoost มีประสิทธิภาพสูงสุด เนื่องจากประสิทธิภาพของแบบจำลองการทำนายราคาปิดของหุ้น AAPL อัลกอริทึม XGBoost นั้นแตกต่างกับทุกอัลกอริทึม และมีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ต่ำที่สุดที่ 41.9582 ดอลลาร์สหรัฐ และ 18.15% ตามลำดับ

4) แบบจำลองการทำนายราคาปิดของหุ้น NVDA วิธี GRU มีประสิทธิภาพสูงสุด เนื่องจากประสิทธิภาพของแบบจำลองการทำนายราคาปิดของหุ้น NVDA ทุกคู่อัลกอริทึมที่ต่างกัน และมีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ต่ำที่สุดที่ 23.1482 ดอลลาร์สหรัฐ และ 17.48% ตามลำดับ

5) แบบจำลองการทำนายราคาปิดของหุ้น META วิธี GRU มีประสิทธิภาพสูงสุด เนื่องจากประสิทธิภาพของแบบจำลองการทำนายราคาปิดของหุ้น META ทุกคู่อัลกอริทึมที่ต่างกัน และมีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ต่ำที่สุดที่ 75.2969 ดอลลาร์สหรัฐ และ 12.33% ตามลำดับ

5.1.2 สรุปผลการประเมินประสิทธิภาพแบบจำลองการทำนาย

เมื่อทำการเลือกแบบจำลองการทำนายราคาหุ้นเทคโนโลยีที่เหมาะสมที่สุดแต่ละหุ้นเรียบร้อยแล้ว จึงทำการประเมินประสิทธิภาพของแบบจำลองด้วยสถิติทดสอบ Wilcoxon signed-rank test พบว่า แบบจำลองที่กล่าวไปข้างต้นข้อ 5.1.1 ค่าจริงและค่าทำนายมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ ซึ่งหมายความว่าแบบจำลองยังไม่สามารถทำนายได้อย่างแม่นยำเพียงพอในบริบทของข้อมูลชุดนี้

5.1.3 สรุปผลการวิเคราะห์ตัวแปรที่มีอิทธิพลต่อราคาของหุ้นเทคโนโลยี

งานวิจัยในครั้งนี้ได้ทำการศึกษาตัวแปรทางเศรษฐกิจที่ส่งผลต่อราคาปิดของหุ้นเทคโนโลยีทั้ง 5 ตัว ได้แก่ GOOGL, MSFT, AAPL, NVDA และ META โดยใช้วิธี Permutation Feature Importance สามารถสรุปได้ดังนี้

1) หุ้น GOOGL จากแบบจำลอง RNN พบว่า ดัชนี NASDAQ, ราคา Bitcoin และราคาน้ำมัน มีอิทธิพลสูงต่อราคาปิดของหุ้น GOOGL เนื่องจาก Google เป็นบริษัทเทคโนโลยีขนาดใหญ่ที่มีความสัมพันธ์กับดัชนี NASDAQ และตลาดคริปโตซึ่งมีความเคลื่อนไหวตามแนวโน้มของเทคโนโลยีและนวัตกรรม ขณะที่ตัวแปรอย่างราคาทองคำ และผลิตภัณฑ์มวลรวมภายในประเทศ มีค่าน้ำหนักติดลบค่อนข้างมาก แสดงว่าอาจเป็นตัวแปรที่รบกวนการทำนายของแบบจำลองในกรณีนี้

2) หุ้น MSFT จากแบบจำลอง XGBoost พบว่าอัตราเงินเฟ้อ, ราคาน้ำมัน และดัชนี NASDAQ มีอิทธิพลมากที่สุดต่อการทำนายราคาปิดของหุ้น MSFT สะท้อนถึงความอ่อนไหวของบริษัท เทคโนโลยีต่อภาวะเงินเฟ้อและต้นทุนพลังงาน ขณะที่ราคา Bitcoin และ อัตราดอกเบี้ย มีค่าน้ำหนักติดลบค่อนข้างมาก จึงอาจไม่ได้ส่งผลโดยตรงต่อราคาหุ้น MSFT ในแบบจำลองนี้

3) หุ้น AAPL จากแบบจำลอง XGBoost พบว่าดัชนี S&P500, คะแนนความรู้สึกจากข่าวเกี่ยวกับหุ้น AAPL และอัตราดอกเบี้ย มีอิทธิพลต่อราคาปิดของหุ้น AAPL ซึ่งสะท้อนให้เห็นว่า แนวโน้มสภาพรวมตลาดและข่าวสารเกี่ยวกับบริษัทมีความสำคัญ อย่างไรก็ตามตัวแปรมหภาค เช่น อัตราผลตอบแทนพันธบัตร, ราคาน้ำมัน และอัตราเงินเฟ้อ มีค่าน้ำหนักติดลบแสดงว่าอาจเป็นตัวแปรที่รบกวนการทำนายของแบบจำลองในกรณีนี้

4) หุ้น NVDA แบบจำลอง GRU พบว่าผลิตภัณฑ์มวลรวมภายในประเทศ และอัตราการว่างงานมีอิทธิพลสูงต่อราคาปิดของหุ้น NVDA ซึ่งแสดงถึงความเชื่อมโยงของบริษัทกับภาวะเศรษฐกิจโดยรวม ขณะที่ตัวแปรอย่างราคา Bitcoin, ดัชนี NASDAQ และ ดัชนี S&P500 มีค่าน้ำหนักติดลบอย่างมาก แสดงให้เห็นว่าการใช้ตัวแปรเหล่านี้อาจทำให้ผลทำนายของแบบจำลองแยกลง

5) หุ้น META แบบจำลอง GRU พบว่าราคาทองคำ และอัตราการว่างงาน เป็นตัวแปรที่มีอิทธิพลต่อราคาปิดของหุ้น META มากที่สุด ซึ่งอาจสะท้อนถึงบทบาทของ META ในภาวะเศรษฐกิจผันผวน ในขณะที่ยอดขายปลีก, ดัชนีค่าเงินดอลลาร์สหรัฐฯ และดัชนี NASDAQ มีค่าน้ำหนักติดลบมาก อาจเป็นปัจจัยที่รบกวนผลการทำนายของแบบจำลองในกรณีนี้

5.2 อภิปรายผลการวิจัย

งานวิจัยนี้ได้ทำการสร้างแบบจำลองการทำนายราคาปิดของหุ้นเทคโนโลยี โดยใช้คะแนนความรู้สึกจากข่าวและปัจจัยทางเศรษฐกิจต่าง ๆ ด้วยอัลกอริทึมทั้ง 5 ตัว ได้แก่ LightGBM, XGBoost, RNN, GRU และ LSTM และทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยใช้สถิติทดสอบฟรีดแมน และพิจารณาค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ประกอบการเลือกแบบจำลองที่เหมาะสม และทำการวิเคราะห์ตัวแปรทางเศรษฐกิจที่ส่งผลต่อราคาปิดของหุ้น ซึ่งหุ้นแต่ละตัวก็มีตัวแปรทางเศรษฐกิจที่ส่งผลต่อราคาปิดของหุ้นแตกต่างกันไป สามารถสรุปได้ดังนี้

5.2.1 แบบจำลองทำนายราคาหุ้นเทคโนโลยีแต่ละตัว

1) แบบจำลองทำนายราคาหุ้น MSFT และ AAPL ด้วย XGBoost ให้ประสิทธิภาพการทำนายที่ดีที่สุด ซึ่งสอดคล้องกับงานวิจัยของ Padmanayana et al. (2021) ที่ใช้ XGBoost ร่วมกับข้อมูลจาก Twitter และปัจจัยทางเศรษฐกิจในการพยากรณ์ราคาหุ้นและพบว่ามีความแม่นยำสูง อย่างไรก็ตามผลการศึกษานี้ขัดแย้งกับงานของ Mohan et al. (2019), Zhu & He (2022) และ Javed (2024) ที่รายงานว่าแบบจำลองโครงข่ายประสาทเทียมเชิงลึกมักให้ประสิทธิภาพดีกว่าแบบจำลองแบบ Tree-based ซึ่งความขัดแย้งนี้อาจเกิดจากขนาดข้อมูลที่ใช้หรือปัญหา Overfitting ของแบบจำลอง

2) แบบจำลองทำนายราคาหุ้น NVDA และ META ด้วย GRU ให้ผลการทำนายที่ดีที่สุด ซึ่งสอดคล้องกับงานของ Shahi et al. (2019) ที่เปรียบเทียบ LSTM และ GRU และพบว่า GRU-News สามารถให้ผลลัพธ์ใกล้เคียงหรือดีกว่า LSTM ในบางกรณี แต่ขัดแย้งกับงานของ Chatterjee et al. (2021) พบว่าแบบจำลองที่ใช้อัลกอริทึมการเรียนรู้ของเครื่องมีประสิทธิภาพดีกว่าอัลกอริทึมการเรียนรู้เชิงลึก

3) แบบจำลองทำนายราคาหุ้น GOOGL ด้วย RNN ให้ได้ผลลัพธ์ที่ดีที่สุด ซึ่งสอดคล้องกับงานของ Mohan et al. (2019) ที่ใช้แบบจำลอง RNN-LSTM ในการทำนายราคาหุ้นในดัชนี S&P 500 อย่างไรก็ตามขัดแย้งกับงานของ Chatterjee et al. (2021) พบว่าแบบจำลองที่ใช้อัลกอริทึมการเรียนรู้ของเครื่องมีประสิทธิภาพดีกว่าอัลกอริทึมการเรียนรู้เชิงลึก

5.2.2 ตัวแปรทางเศรษฐกิจที่มีผลกระทบต่อราคาปิดของหุ้น

ตัวแปรทางเศรษฐกิจที่ส่งผลต่อราคาปิดของหุ้นนั้นแตกต่างกันไป ตามลักษณะเฉพาะของแต่ละบริษัท ทั้งนี้สามารถสรุปผลการวิเคราะห์ได้ดังนี้

1) หุ้น GOOGL จากแบบจำลอง RNN พบว่าดัชนี NASDAQ มีความสำคัญสูงสุดในการทำนายราคาหุ้น GOOGL ซึ่งสอดคล้องกับ Lin et al. (2022) ที่ระบุว่า NASDAQ มีความอ่อนไหวต่อปัจจัยเศรษฐกิจมากที่สุด และ ตามด้วยราคาน้ำมัน ซึ่งสอดคล้องกับงานวิจัย Delpeche et al. (2022) และ Srinivasan et al. (2022) ที่ชี้ว่าราคาน้ำมันเป็นตัวแปรสำคัญในการทำนายตลาดหุ้นโดยรวม นอกจากนี้ตัวแปรเศรษฐกิจพื้นฐานที่มีความสำคัญรองลงมาได้แก่ อัตราการว่างงาน และอัตราเงินเฟ้อของสหรัฐฯ ซึ่งขัดแย้งกับงานวิจัย Delpeche et al. (2022) ที่ระบุว่าอัตราการว่างงาน และอัตราเงินเฟ้อของสหรัฐฯ ไม่ส่งผลกระทบต่อตลาดหุ้นดัชนีค่าเงินดอลลาร์สหรัฐฯ แต่ดัชนีค่าเงินดอลลาร์สหรัฐฯ สอดคล้องกับงานวิจัย Srinivasan et al. (2022) ที่พบว่าดัชนีค่าเงินดอลลาร์มีผลต่อพฤติกรรมการลงทุนและราคา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สินทรัพย์เสี่ยง และคะแนนความรู้สึก สอดคล้องกับงานวิจัย Mohan et al. (2019), Shahi et al. (2019), Gu et al. (2024) และ Padmanayana et al. (2021) ที่พบว่าการใช้คะแนนความรู้สึกในการสร้างตัวแบบทำนายช่วยให้การคาดการณ์แนวโน้มของราคาหุ้นมีประสิทธิภาพมากขึ้น

ขณะที่ราคาทองคำ อัตราดอกเบี้ยของสหรัฐฯ ดัชนีราคาผู้บริโภค และผลิตภัณฑ์มวลรวมภายในประเทศ ไม่มีอิทธิพลต่อการทำนายราคาหุ้น และส่งผลให้แบบจำลองมีความแม่นยำน้อยลง ซึ่งสอดคล้องกับงานวิจัย Srinivasan et al. (2022) และ Delpeche et al. (2022) ที่ชี้ให้เห็นว่าดัชนีราคาผู้บริโภค อัตราดอกเบี้ยของสหรัฐฯ และราคาทองคำ เป็นตัวแปรที่ไม่ส่งผลกระทบต่อตลาดหุ้น แต่ผลิตภัณฑ์มวลรวมภายในประเทศ ชัดแย้งกับงานวิจัยของ Delpeche et al. (2022) ระบุว่าผลิตภัณฑ์มวลรวมภายในประเทศ เป็นปัจจัยสำคัญที่ส่งผลต่อดัชนีตลาดและราคาหุ้นโดยรวม

2) หุ้น MSFT จากแบบจำลอง XGBoost พบว่าปัจจัยสำคัญที่สุดคือ อัตราเงินเฟ้อของสหรัฐฯ ซึ่งอาจสะท้อนผลกระทบต่อการดำเนินธุรกิจและต้นทุนของผู้บริโภค ตามมาด้วยราคาน้ำมัน, ดัชนี NASDAQ และดัชนีค่าเงินดอลลาร์สหรัฐฯ ซึ่งสอดคล้องกับงานวิจัย Lin et al. (2022) ที่ระบุว่าดัชนี NASDAQ ตอบสนองต่อปัจจัยเศรษฐกิจได้อย่างชัดเจน และสอดคล้องกับ Delpeche et al. (2022) และ Srinivasan et al. (2022) ที่ชี้ว่าราคาน้ำมันและดัชนีค่าเงินดอลลาร์สหรัฐฯ มีผลต่อดัชนีตลาดหลัก

ขณะที่อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, คะแนนความรู้สึกจากข่าว, ราคาทองคำ, อัตราการว่างงานของสหรัฐฯ, ดัชนีราคาผู้บริโภค, ผลิตภัณฑ์มวลรวมภายในประเทศ และอัตราดอกเบี้ยของสหรัฐฯ ไม่มีอิทธิพลต่อการทำนายราคาหุ้น และส่งผลให้แบบจำลองมีความแม่นยำน้อยลง ซึ่งสอดคล้องกับงานวิจัย Delpeche et al. (2022) และ Srinivasan et al. (2022) ระบุว่าอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, ราคาทองคำ, อัตราการว่างงานของสหรัฐฯ, อัตราดอกเบี้ยของสหรัฐฯ และดัชนีราคาผู้บริโภค ไม่มีบทบาทสำคัญในการพยากรณ์ตลาดหุ้น ซึ่งขัดแย้งกับงานวิจัย Mohan et al. (2019), Shahi et al. (2019), Gu et al. (2024) และ Padmanayana et al. (2021) ที่พบว่าการใช้คะแนนความรู้สึกในการสร้างตัวแบบทำนายช่วยลดค่าความผิดพลาดได้อย่างมีนัยสำคัญ และขัดแย้งกับงานวิจัย Delpeche et al. (2022) ระบุว่าผลิตภัณฑ์มวลรวมภายในประเทศเป็นปัจจัยสำคัญที่ส่งผลต่อดัชนีตลาดและราคาหุ้นโดยรวม แต่ในแบบจำลอง MSFT กลับพบว่าผลิตภัณฑ์มวลรวมภายในประเทศ ไม่มีอิทธิพลต่อราคาปิดของหุ้น MSFT

3) หุ้น AAPL แบบจำลอง XGBoost พบว่าตัวแปรที่มีความสำคัญที่สุดในการทำนายราคาหุ้น AAPL ได้แก่ ดัชนี S&P500 และคะแนนความรู้สึก ซึ่งสอดคล้องกับงานวิจัยของ Mohan et al.

(2019), Shahi et al. (2019), Gu et al. (2024) และ Padmanayana et al. (2021) ที่ชี้ว่าข้อมูลข่าวและคะแนนความรู้สึกมีบทบาทในการพยากรณ์ราคาหุ้นได้อย่างแม่นยำ นอกจากนี้การที่ดัชนี S&P500 มีความสำคัญ สอดคล้องกับงานวิจัย Lin et al. (2022) ที่ชี้ว่าดัชนีตลาดหลักมีความสัมพันธ์กับหุ้นเทคโนโลยีขนาดใหญ่

ขณะที่ตัวแปรเศรษฐกิจมหภาคอื่น ๆ เช่น อัตราเงินเฟ้อของสหรัฐฯ, ราคาน้ำมัน, อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, อัตราการว่างงาน, ดัชนี NASDAQ, อัตราดอกเบี้ยของสหรัฐฯ, ราคาทองคำ, ดัชนีค่าเงินดอลลาร์สหรัฐฯ, ดัชนีราคาผู้บริโภค และผลิตภัณฑ์มวลรวมภายในประเทศ ไม่มีอิทธิพลต่อการทำนายราคาหุ้น และส่งผลให้แบบจำลองมีความแม่นยำน้อยลง ซึ่งขัดแย้งกับงานวิจัยของ Delpeche et al. (2022) ที่ชี้ว่าผลิตภัณฑ์มวลรวมภายในประเทศ, ราคาน้ำมัน และอัตราดอกเบี้ยเป็นปัจจัยสำคัญที่ส่งผลต่อดัชนีตลาด ขณะเดียวกันขัดแย้งกับ Lin et al. (2022) ที่เห็นว่า NASDAQ และปัจจัยเศรษฐกิจมหภาคมีผลต่อราคาหุ้นกลุ่มเทคโนโลยีโดยตรง แต่สอดคล้องกับ Delpeche et al. (2022) และ Srinivasan et al. (2022) ระบุว่าอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, ราคาทองคำ, อัตราการว่างงานของสหรัฐฯ, อัตราเงินเฟ้อของสหรัฐฯ และดัชนีราคาผู้บริโภค ไม่มีบทบาทสำคัญในการพยากรณ์ตลาดหุ้น

4) หุ้น NVDA แบบจำลอง GRU พบว่าตัวแปรที่มีความสำคัญมากที่สุดคือ ผลิตภัณฑ์มวลรวมภายในประเทศ และอัตราการว่างงานของสหรัฐฯ ซึ่งสอดคล้องกับงานวิจัย Delpeche et al. (2022) ที่ระบุว่าผลิตภัณฑ์มวลรวมภายในประเทศเป็นหนึ่งในตัวแปรหลักที่ส่งผลต่อแนวโน้มตลาดหุ้น และชี้ว่าเศรษฐกิจโดยรวมส่งผลต่ออุตสาหกรรมเทคโนโลยี อย่างไรก็ตาม อัตราการว่างงานของสหรัฐฯ ซึ่งมีน้ำหนักค่อนข้างสูงในแบบจำลองนี้ ขัดแย้งกับงานของ Delpeche et al. (2022) ที่ชี้ว่าอัตราการว่างงานไม่มีผลต่อการเคลื่อนไหวของตลาดหุ้น

ขณะที่ตัวแปรอย่าง ดัชนี NASDAQ, ดัชนี S&P500, ดัชนีค่าเงินดอลลาร์สหรัฐฯ, ราคาทองคำ, อัตราเงินเฟ้อของสหรัฐฯ, ราคาน้ำมัน, ดัชนีราคาผู้บริโภค, คะแนนความรู้สึก, อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ และอัตราดอกเบี้ยของสหรัฐฯ ไม่มีอิทธิพลต่อการทำนายราคาหุ้น NVDA ซึ่งขัดแย้งกับงานวิจัย Lin et al. (2022), Delpeche et al. (2022) และ Srinivasan et al. (2022) ที่ระบุว่า ดัชนี S&P500 และ NASDAQ, ดัชนีค่าเงินดอลลาร์สหรัฐฯ, อัตราดอกเบี้ยของสหรัฐฯ และราคาน้ำมัน มีบทบาทสำคัญต่อพฤติกรรมของตลาดหุ้น นอกจากนี้ คะแนนความรู้สึก ก็มีน้ำหนักต่ำมาก แสดงว่าแบบจำลองไม่สามารถใช้ข้อมูลข่าวเพื่อปรับปรุงการพยากรณ์ราคาหุ้น NVDA ได้ ซึ่งขัดกับงานวิจัยของ Mohan et al. (2019), Shahi et al. (2019), Gu et al. (2024) และ Padmanayana et al. (2021) ที่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พบว่า sentiment analysis มีประโยชน์อย่างมีนัยสำคัญในการพยากรณ์ราคาหุ้น แต่สอดคล้องกับ Delpeche et al. (2022) และ Srinivasan et al. (2022) ระบุว่าอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, ราคาทองคำ, อัตราเงินเฟ้อของสหรัฐฯ และดัชนีราคาผู้บริโภค ไม่มีบทบาทสำคัญในการพยากรณ์ตลาดหุ้น

5) หุ้น META แบบจำลอง GRU พบว่าตัวแปรที่มีอิทธิพลสูงที่สุดคือ ราคาทองคำ และอัตราการว่างงานของสหรัฐฯ ซึ่งอาจสะท้อนพฤติกรรมของนักลงทุนที่หลีกเลี่ยงความเสี่ยงโดยหันไปลงทุนในทองคำ หรืออาจสะท้อนความเชื่อมโยงของแรงงานต่อรายได้ในอุตสาหกรรมดิจิทัล ซึ่ง ขัดแย้งกับ Delpeche et al. (2022) และ Srinivasan et al. (2022) ที่ระบุว่าทองคำ และอัตราการว่างงานไม่มีผลชัดเจนต่อดัชนีตลาดหุ้น ตัวแปรที่มีความสำคัญรองลงมาได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศ, อัตราดอกเบี้ยของสหรัฐฯ, อัตราเงินเฟ้อของสหรัฐฯ และดัชนีราคาผู้บริโภค ซึ่งสอดคล้องกับงานวิจัย Delpeche et al. (2022) ที่ชี้ว่าผลิตภัณฑ์มวลรวมภายในประเทศ และอัตราดอกเบี้ยมีบทบาทสำคัญในการพยากรณ์ตลาดหุ้น ขณะเดียวกันขัดแย้งกับ Delpeche et al. (2022) และ Srinivasan et al. (2022) ระบุว่าอัตราเงินเฟ้อของสหรัฐฯ และดัชนีราคาผู้บริโภคไม่มีอิทธิพลสำคัญต่อการเคลื่อนไหวของราคาหุ้น

นอกจากนี้ แบบจำลองยังพบว่า ดัชนี NASDAQ, S&P500, ดัชนีค่าเงินดอลลาร์สหรัฐฯ, อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ, คะแนนความรู้สึก และราคาน้ำมัน ไม่มีอิทธิพลต่อการทำนายราคาหุ้น META ซึ่งขัดแย้งอย่างชัดเจนกับงานวิจัย Lin et al. (2022) ที่ชี้ว่าหุ้นกลุ่มเทคโนโลยีมีความสัมพันธ์โดยตรงกับ ดัชนี NASDAQ และ S&P500 อีกทั้งคะแนนความรู้สึกไม่มีอิทธิพลในแบบจำลองนี้ ซึ่งขัดแย้งกับงานวิจัย Mohan et al. (2019), Shahi et al. (2019), Gu et al. (2024) และ Padmanayana et al. (2021) ที่พบว่าคะแนนความรู้สึกจากข่าวสารมีบทบาทสำคัญในการช่วยทำนายแนวโน้มราคาหุ้น และขัดแย้งกับงานวิจัย Srinivasan et al. (2022) ที่ระบุว่าดัชนีค่าเงินดอลลาร์สหรัฐฯ และราคาน้ำมัน มีอิทธิพลต่อพฤติกรรมการลงทุนในสินทรัพย์เสี่ยง ในขณะที่ อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ สอดคล้องกับงานวิจัยของ Delpeche et al. (2022) ที่ระบุว่า ตัวแปรด้านผลตอบแทนพันธบัตรมีผลต่อความเคลื่อนไหวของตลาดหุ้น

5.3 ข้อจำกัดของงานวิจัย

1) งานวิจัยนี้ใช้ข้อมูลข่าวที่เกี่ยวข้องกับหุ้นตัวนั้นโดยเฉพาะ โดยจะกำหนดค่าเฉพาะในการค้นหาข่าวเช่น หุ้น AAPL จะกำหนดค่าว่า AAPL และ Apple Inc ซึ่งการกำหนดค่าเฉพาะแบบนี้ทำให้ได้ข้อมูลข่าวเฉพาะหุ้นนั้นตัวเดียว ซึ่งจะได้ข่าวเกี่ยวกับเศรษฐกิจ หรือการเมืองของสหรัฐฯ อาจทำให้คะแนนความรู้สึกจากข่าวไม่มีอิทธิพลต่อราคาหุ้น

2) ข้อมูลข่าวที่ใช้ในการศึกษามีข้อจำกัดด้านช่วงเวลา เนื่องจากผู้วิจัยดึงข้อมูลข่าวจาก API ของ Alpha Vantage ซึ่งสามารถเข้าถึงข้อมูลได้ย้อนหลังเพียงถึงวันที่ 1 มีนาคม พ.ศ. 2565 ส่งผลให้ชุดข้อมูลมีขนาดจำกัด อาจกระทบต่อความหลากหลายของเหตุการณ์ทางเศรษฐกิจที่ส่งผลต่อราคาหุ้น และอาจส่งผลต่อความแม่นยำของแบบจำลองในระยะยาว

5.4 ข้อเสนอแนะ

5.4.1 ข้อเสนอแนะในการนำผลการวิจัยไปใช้

นักลงทุนสามารถนำแบบจำลองการทำงานนี้ไปใช้ประกอบการตัดสินใจในการซื้อหรือขายหุ้น โดยอิงจากแนวโน้มราคาที่เหมาะสมล่วงหน้า ซึ่งอาจช่วยลดความเสี่ยงและเพิ่มโอกาสในการทำกำไร แต่ควรระวังการนำแบบจำลองไปใช้ เนื่องจากแบบจำลองเป็นเพียงหนึ่งในเครื่องมือที่ใช้ประกอบการตัดสินใจซื้อขายหุ้น และแม้ว่าแบบจำลองจะสามารถทำนายแนวโน้มราคาได้ในระดับหนึ่ง แต่ตลาดหุ้นมีความผันผวนสูงจากปัจจัยภายนอก เช่น ข่าวฉุกเฉิน เหตุการณ์ทางการเมือง หรือแรงเก็งกำไร ซึ่งแบบจำลองไม่สามารถคาดการณ์ได้ล่วงหน้า

5.4.2 ข้อเสนอแนะในการทำวิจัยครั้งต่อไป

1) จำนวนข้อมูลมีอย่างจำกัด ทำให้การเรียนรู้ของเครื่องและโครงข่ายประสาทเทียมเชิงลึก ใช้ความสามารถได้ไม่เต็มประสิทธิภาพ จึงต้องให้ความสนใจกับการหาอัลกอริทึมการเรียนรู้เครื่องและโครงข่ายประสาทเทียมเชิงลึกที่มีประสิทธิภาพในการเรียนรู้ภายใต้ข้อมูลจำกัด

2) การเก็บข้อมูลเพิ่มเติมให้มีจำนวนเพิ่มมากขึ้น เพื่อให้ประสิทธิภาพการทำนายราคาปิดของหุ้นเทคโนโลยีแต่ละตัวดียิ่งขึ้น

3) ควรพิจารณาแบ่งชุดข้อมูลทดสอบให้ครอบคลุมถึงช่วงเวลาที่มีความผิดปกติ (Irregular) เพื่อประเมินความสามารถของแบบจำลองในการจัดการกับข้อมูลที่อยู่เหนือจากรูปแบบปกติ ซึ่งจะช่วยให้เพิ่มความแข็งแกร่งและความน่าเชื่อถือของผลการทำนายในสถานการณ์จริงได้มากยิ่งขึ้น

4) การปรับค่าไฮเปอร์พารามิเตอร์เพิ่มเติม โดยกำหนดช่วงของค่าไฮเปอร์พารามิเตอร์ให้กว้างขึ้นและละเอียดขึ้น เพื่อให้แบบจำลองมีประสิทธิภาพมากขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- ภาشري์ ทูรภุษาณา. (2564). *Python คืออะไร? เป็นภาษาที่ง่ายจริงหรือ?*. ค้นเมื่อ 20 เมษายน 2568, จาก <https://blog.skooldio.com/what-is-python/>
- ณรง, ออเรเลียง. 2566. *Hand-On Machine Learning with Scikit-Learn, Keras & TensorFlow*. แปลโดย วิโรจน์ อัครังสี. พิมพ์ครั้งที่ 1. นนทบุรี : คอร์ฟังก์ซัน.
- สมาคมโปรแกรมเมอร์ไทย. (2561). *การเรียนรู้ของเครื่อง (Machine Learning) (ฉบับมือใหม่)*. ค้นเมื่อ 15 กุมภาพันธ์ 2568, จาก <https://www.thaiprogrammer.org/2018/12/การเรียนรู้ของเครื่องmachine-le/>
- ศูนย์วิจัยกสิกรไทย. (2567). *เงินเฟ้อปี 2567 เหลืออยู่ที่ 0.4% มองเงินเฟ้อปี 2568 ชัยดีขึ้นมาอยู่ที่ 0.7%*. ค้นเมื่อ 15 กุมภาพันธ์ 2568, จาก <https://www.kasikornresearch.com/th/analysis/k-social-media/Pages/Inflation-EBR4112-FB-06-01-24.aspx?utm>
- ธนาคารแห่งประเทศไทย. (2568). *อัตราดอกเบี้ยประจำวันของธนาคารพาณิชย์*. ค้นเมื่อ 15 กุมภาพันธ์ 2568, จาก <https://www.bot.or.th/th/statistics/interest-rate.html?utm>
- ฝ่ายนโยบายและยุทธศาสตร์ สำนักงานส่งเสริมเศรษฐกิจดิจิทัล. (ม.ป.ป). *Machine Learning สิ่งใกล้ตัวแห่งยุคใหม่*. ค้นเมื่อ 20 เมษายน 2568, จาก <https://www.depa.or.th/th/article-view/article11-2563>
- พิชัย ยอดพฤติการณ์. (2567). *สำรวจโอกาสและความเสี่ยงตลาดหุ้นสหรัฐฯ*. ค้นเมื่อ 15 กุมภาพันธ์ 2568, จาก <https://www.setinvestnow.com/th/knowledge/article/468-tsi-explore-us-stock-market-opportunities-risks?utm>
- ณัฐวดี หงส์บุญมี และ คณิน ประทุมทอง. (2563). *ระบบวิเคราะห์ชนบัตร์ปลอมด้วยภาพถ่ายผ่านสมาร์ตโฟนโดยใช้เทคนิคการเรียนรู้เชิงลึก*. *Journal of Information Science and Technology*, 10(2), 90-100

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- AIGEN. (2021). *10 ตัวอย่างของเทคโนโลยี AI ที่ทำให้การใช้ชีวิตเป็นเรื่องง่ายมาก*. Retrieved December 12, 2024, from <https://aigencorp.com/10-examples-of-ai-in-daily-life/>
- Bishop, C.M. (2006). *Pattern recognition and machine learning*. New York: Springer.
- Bloomberg. (2023). *Nvidia and Five Tech Giants Now Command 30% of the S&P 500 Index*. Retrieved April 20, 2025, from <https://www.bloomberg.com/news/articles/2024-05-30/nvidia-and-five-tech-giants-now-command-30-of-the-s-p-500-index>
- Chatterjee, A., Bhowmick, H., & Sen, J. (2021). *Stock price prediction using time series, econometric, machine learning, and deep learning models*. In 2021 IEEE Mysore Sub Section International Conference (MysuruCon), Hassan, India.
- Delpeche, A., Menon, S., & Du, Z. (2022). *The impact of macroeconomic indicators on the stock market using statistical & deep learning methods*. Stevens Institute of Technology, Financial Systems Center. Retrieved May 27, 2025, from <https://fsc.stevens.edu/the-impact-of-macroeconomic-indicators-on-the-stock-market-using-statistical-deep-learning-methods/>
- enable survey. (2022). *โปรแกรม SPSS คืออะไร มีขั้นตอนการใช้เพื่อการวิเคราะห์ข้อมูลอย่างไร*. Retrieved April 20, 2025, from <https://www.enablestudies.com/article-detail/8ac2a4f7-13c8-4982-b849-2f2fc64da5dc/spss>
- Field, A. (2013). **Discovering statistics using IBM SPSS statistics**. 4th ed. London : SAGE Publications.
- Fisher, A., Rudin, C., & Dominici, F. (2019). *All Models are Wrong, but Many are Useful: Learning a Variable's Importance by Studying an Entire Class of Prediction Models Simultaneously*. *Journal of Machine Learning Research*, 20(177), 1–81.
- GeeksforGeeks. (n.d.). *Gated Recurrent Unit Networks*. Retrieved February 20, 2025, from <https://www.geeksforgeeks.org/gated-recurrent-unit-networks/>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Google. (n.d.). *Colaboratory*. Retrieved April 20, 2025, from <https://research.google.com/colaboratory/faq.html>
- Gu, W., Zhong, Y., Li, S., Wei, C., Dong, L., Wang, Z., & Yan, C. (2024). *Predicting stock prices with FinBERT-LSTM: Integrating news sentiment analysis*. 2024 8th International Conference on Cloud and Big Data Computing (CBDC 2024), Oxford, United Kingdom
- Hutto, C., & Gilbert, E. (2014). VADER: A Parsimonious Rule-Based Model for Sentiment Analysis of Social Media Text. *Proceedings of the International AAAI Conference on Web and Social Media*, 8(1), 216-225. <https://doi.org/10.1609/icwsm.v8i1.14550>
- Jabed, M. I. K. (2024). Stock market price prediction using machine learning techniques. *American International Journal of Sciences and Engineering Research*, 7(1), 1–6. <https://doi.org/10.46545/aijser.v7i1.308>
- Kılıç, İ. (2023). *Light GBM: A Powerful Gradient Boosting Algorithm*. Retrieved April 20, 2025, from <https://medium.com/@ilyurek/light-gbm-a-powerful-gradient-boosting-algorithm-fe145a1cd8a6>
- Laerd Statistics. (n.d.). *Friedman test in SPSS Statistics*. Retrieved June 20, 2025, from <https://statistics.laerd.com/spss-tutorials/friedman-test-using-spss-statistics.php>
- Lelli, F. (2019). *Neural networks: The basics and a collection of YouTube videos for learning the basics*. Retrieved April 20, 2025, from <https://francescolelli.info/tutorial/neural-networks-a-collection-of-youtube-videos-for-learning-the-basics/>
- Lin, G., Vecchio, A., Yager, E., & Liu, W. (2022). *Macroeconomic factors and stock market indices*. *International Journal of Business and Economics*, 7(1), 55–69.

- Mitrade. (2024). *8 หุ้นเทคโนโลยีที่น่าสนใจในปี 2024 (เวอร์ชันล่าสุด)*. Retrieved December 12, 2024, from <https://www.mitrade.com/th/insights/shares/basics/us-tech-stocks-to-buy>
- Moghar, A., & Hamiche, M. (2020). Stock market prediction using LSTM recurrent neural network. *Procedia Computer Science*, (170), 1168–1173. <https://doi.org/10.1016/j.procs.2020.03.253>
- Mohan, S., Mullanpudi, S., Sammeta, S., Vijayvergia, P., & Anastasiu, D. C. (2019). *Stock Price Prediction Using News Sentiment Analysis*. In 2019 IEEE 5th International Conference on Big Data Computing Service and Applications (BigDataService), Newark, CA, USA.
- Olufemi Ariyo. (2024). *Tech's Role in Shaping the Future of Work: Innovation, Entrepreneurship, and Economic Growth*. Retrieved April 20, 2025, from <https://medium.com/@roariyo/techs-role-in-shaping-the-future-of-work-innovation-entrepreneurship-and-economic-growth-67bc5983fbec>
- Padmanayana, Varsha, & Bhavya K. (2021). Stock market prediction using Twitter sentiment analysis. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 7(4), 265–270. <https://doi.org/10.32628/CSEIT217475>
- PCP. (2563). *MAE, MSE, RMSE-เลือกใช้อย่างใตีมอลองดูที่ความหมาย*. Retrieved February 20, 2025, from <https://medium.com/c-g-datacommunity/mse-rmse-mae-เลือกใช้อย่างใตีมอลองดูที่ความหมาย>
- Rasifaghihi, N. (2020). *Predictive analytics: Regression analysis with LSTM, GRU and BiLSTM to predict water consumption*. Retrieved April 20, 2025 from <https://medium.com/data-science/predictive-analysis-rnn-lstm-and-gru-to-predict-water-consumption-e6bb3c2b4b02> mdpi.com+4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Shahi, T. B., Shrestha, A., Neupane, A., & Guo, W. (2020). Stock price forecasting with deep learning: A comparative study. *Mathematics*, 8(9), 1441. <https://doi.org/10.3390/math8091441>
- Sonkavde, G., Dharrao, D. S., Bongale, A. M., Deokate, S. T., Doreswamy, D., & Bhat, S. K. (2023). Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications. *International Journal of Financial Studies*, 11(94). <https://doi.org/10.3390/ijfs11030094>
- Smitsomboon, S. (2020). สรุปความเข้าใจ RNN, LSTM, GRU (24/10/2020). Retrieved April 20, 2025, from <https://sirawich99.medium.com/สรุปความเข้าใจ-rnn-lstm-gru-24-10-2020-95602afe3053>
- Srinivasan, P., Maity, B., & Kumar, K. K. (2022). Macro-financial parameters influencing Bitcoin prices: Evidence from symmetric and asymmetric ARDL models. *Review of Economic Analysis*, 14(1), 143–175. <https://doi.org/10.15353/rea.v13i3.3585>
- Statistics Solutions. (n.d.-a). Paired sample t-test. Retrieved May 5, 2025, from <https://www.statisticssolutions.com/free-resources/directory-of-statistical-analyses/paired-sample-t-test/>
- Statistics Solutions. (n.d.-b). What is the Wilcoxon sign test?. Retrieved May 5, 2025, from <https://www.statisticssolutions.com/free-resources/directory-of-statistical-analyses/what-is-the-wilcoxon-sign-test/>
- Thanapunnamas, P. (2024). โมเดลการทำนาย และการปรับปรุงความแม่นยำ. ค้นเมื่อ 20 เมษายน 2568, จาก <https://eleceasy.com/t/topic/6845>
- Wisesight. (2023). Sentiment Analysis คืออะไร ช่วยวิเคราะห์ลูกค้ำและเพิ่มประสิทธิภาพให้กับ การทำธุรกิจได้อย่างไร. 15 กุมภาพันธ์ 2568, จาก <https://wisesight.com/th/news/what-is-sentiment-analysis/>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Wong, W. K., Shi, X., Yeung, D. Y., & Woo, W. C. (2016). "A deep-learning method for precipitation nowcasting." in **WMO WWRP 4th International Symposium on Nowcasting and Very-short-range Forecast 2016**. Hong Kong.

Zhu, Z., & He, K. (2022). Prediction of Amazon's stock price based on ARIMA, XGBoost, and LSTM models. *Proceedings of Business and Economic Studies*, 5(5), 127–136. <https://doi.org/10.26689/pbes.v5i5.4432>

Zou, M., Jiang, W.-G., Qin, Q.-H., Liu, Y.-C., & Li, M.-L. (2022). Optimized XGBoost model with small dataset for predicting relative density of Ti-6Al-4V parts manufactured by selective laser melting. *Materials*, 15(15), 5298. <https://doi.org/10.3390/ma15155298>



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รายละเอียดของโค้ดที่ใช้ในการสร้างแบบจำลองทำนายราคาปิดของหุ้น

อัลกอริทึม LightGBM

```
def model_lightgbm(X_train, y_train, X_test, y_test, feature_fraction, learning_rate,
                  max_bin, max_depth, min_data_in_leaf, n_estimators,
                  date_test, date_train, feature_names, label_name='Dataset'):

    params = {
        'feature_fraction': feature_fraction,
        'learning_rate': learning_rate,
        'max_bin': max_bin,
        'max_depth': max_depth,
        'min_data_in_leaf': min_data_in_leaf,
        'n_estimators': n_estimators,
    }
    model = LGBMRegressor(**params, verbosity=-1, n_jobs=-1, random_state=42)
    model.fit(X_train, y_train,
              eval_set=[(X_test, y_test)],
              eval_metric='mse',
              callbacks=[early_stopping(stopping_rounds=50)])
    # ===== Train Metrics =====
    y_train_pred = model.predict(X_train)
    print('-----')
    print('Train')
    print(f'R2 Value Train: {r2_score(y_train, y_train_pred):.4f}')
    print(f'MSE Train:      {mean_squared_error(y_train, y_train_pred):.4f}')
    print(f'RMSE Train:      {np.sqrt(mean_squared_error(y_train, y_train_pred)):.4f}')
    print(f'MAE Train:       {mean_absolute_error(y_train, y_train_pred):.4f}')
    print(f'MAPE Train:      {mean_absolute_percentage_error(y_train, y_train_pred):.4f}')
    print('-----')
    plt.figure(figsize=(12, 6))
    plt.plot(date_train, y_train, label='Actual', color='blue')
    plt.plot(date_train, y_train_pred, label='Prediction', color='orange')
    plt.xticks(rotation=45)
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

plt.title(f'LightGBM Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

# ===== Test Metrics =====
y_pred = model.predict(X_test)

print('-----')
print('Test')
print(f'R2 Value Test: {r2_score(y_test, y_pred):.4f}')
print(f'MSE Test: {mean_squared_error(y_test, y_pred):.4f}')
print(f'RMSE Test: {np.sqrt(mean_squared_error(y_train, y_train_pred)):.4f}')
print(f'MAE Test: {mean_absolute_error(y_test, y_pred):.4f}')
print(f'MAPE Test: {mean_absolute_percentage_error(y_test, y_pred):.4f}')
print('-----')

plt.figure(figsize=(12, 6))
plt.plot(date_test, y_test, label='Actual', color='blue')
plt.plot(date_test, y_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'LightGBM Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

df_result = pd.DataFrame({
    'date': date_test,
    'actual': y_test,
    'prediction': y_pred
})

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

})

perm = PermutationImportance(model, random_state=1).fit(X_test, y_test)

from IPython.display import display
display(eli5.show_weights(perm, feature_names=list(feature_names)))

return model

```

อัลกอริทึม XGBoost

```

def model_XGBoost(X_train, y_train, X_test, y_test, learning_rate, max_depth,
                  alpha, reg_lambda, n_estimators, min_child_weight, colsample_bytree,
                  date_test, date_train, feature_names, label_name='Dataset'):

    params = {
        'learning_rate': learning_rate,
        'max_depth': max_depth,
        'alpha': alpha,
        'reg_lambda': reg_lambda,
        'n_estimators': n_estimators,
        'min_child_weight': min_child_weight,
        'colsample_bytree': colsample_bytree,
    }

    model = XGBRegressor(**params, early_stopping_rounds = 50)
    model.fit(X_train, y_train ,
              eval_set=[(X_test, y_test)],
              verbose=False)

    # ===== Train Metrics =====
    y_train_pred = model.predict(X_train)
    print('-----')
    print("Train")
    print(f'R2 Value Train: {r2_score(y_train, y_train_pred):.4f}')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

print(f'MSE Train:    {mean_squared_error(y_train, y_train_pred):.4f}')
print(f'RMSE Train:   {np.sqrt(mean_squared_error(y_train, y_train_pred)):.4f}')
print(f'MAE Train:    {mean_absolute_error(y_train, y_train_pred):.4f}')
print(f'MAPE Train:   {mean_absolute_percentage_error(y_train, y_train_pred):.4f}')
print('-----')
plt.figure(figsize=(12, 6))
plt.plot(date_train, y_train, label='Actual', color='blue')
plt.plot(date_train, y_train_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'LightGBM Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

# ===== Test Metrics =====
y_pred = model.predict(X_test)
print('-----')
print('Test')
print(f'R2 Value Test:  {r2_score(y_test, y_pred):.4f}')
print(f'MSE Test:      {mean_squared_error(y_test, y_pred):.4f}')
print(f'RMSE Test:     {root_mean_squared_error(y_test, y_pred):.4f}')
print(f'MAE Test:      {mean_absolute_error(y_test, y_pred):.4f}')
print(f'MAPE:         {mean_absolute_percentage_error(y_test, y_pred):.4f}')
print('-----')

plt.figure(figsize=(12, 6))
plt.plot(date_test, y_test, label='Actual', color='blue')
plt.plot(date_test, y_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'XGBoost Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

df_result = pd.DataFrame({
    'date': date_test,
    'actual': y_test,
    'prediction': y_pred
})

perm = PermutationImportance(model, random_state=1).fit(X_test, y_test)

from IPython.display import display
display(eli5.show_weights(perm, feature_names=list(feature_names)))

return model

```

อัลกอริทึม RNN

```

def model_RNN(X_train, y_train, X_test, y_test, batch_size, epochs,
              optimizer, date_test, date_train, feature_names, label_name='Dataset'):
    def create_model():
        model = Sequential()
        model.add(SimpleRNN(128, input_shape=(look_back, X_train.shape[2])))
        model.add(Dropout(0.2))
        model.add(Dense(64, activation='relu'))
        model.add(Dropout(0.2))
        model.add(Dense(1, activation='linear'))
        model.compile(loss='mse', optimizer=optimizer)
        return model

    params = {
        'batch_size': batch_size,

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

    'epochs': epochs,
}

early_stopping = EarlyStopping(
    monitor='val_loss',
    patience=10,
    restore_best_weights=True
)

model = KerasRegressor(model=create_model, verbose=0, **params)
model.fit(X_train, y_train, callbacks=[early_stopping])

# ===== Train Metrics =====
y_train_pred = model.predict(X_train)
print('-----')
print('Train')
print(f'R2 Value Train: {r2_score(y_train, y_train_pred):.4f}')
print(f'MSE Train: {mean_squared_error(y_train, y_train_pred):.4f}')
print(f'RMSE Train: {np.sqrt(mean_squared_error(y_train, y_train_pred)):.4f}')
print(f'MAE Train: {mean_absolute_error(y_train, y_train_pred):.4f}')
print(f'MAPE Train: {mean_absolute_percentage_error(y_train, y_train_pred):.4f}')
print('-----')
plt.figure(figsize=(12, 6))
plt.plot(date_train, y_train, label='Actual', color='blue')
plt.plot(date_train, y_train_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'LightGBM Prediction- {label_name}')
plt.xlabel("Time")
plt.ylabel("Close Price")
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# ===== Test Metrics =====
y_pred = model.predict(X_test)
print('-----')
print('Test')
print(f'R2 Value Test: {r2_score(y_test, y_pred):.4f}')
print(f'MSE Test: {mean_squared_error(y_test, y_pred):.4f}')
print(f'RMSE Test: {root_mean_squared_error(y_test, y_pred):.4f}')
print(f'MAE Test: {mean_absolute_error(y_test, y_pred):.4f}')
print(f'MAPE: {mean_absolute_percentage_error(y_test, y_pred):.4f}')
print('-----')

plt.figure(figsize=(12, 6))
plt.plot(date_test, y_test, label='Actual', color='blue')
plt.plot(date_test, y_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'RNN Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

df_result = pd.DataFrame({
    'date': date_test,
    'actual': y_test,
    'prediction': y_pred
})

df_result.to_csv(os.path.join(path_Test, f'df_RNN_{label_name}.csv'))

def permutation_feature_importance_3d(model, X_test, y_test, feature_names=None):

    n_features1 = X_test.shape[2]
    baseline_preds = model.predict(X_test)
    baseline_score = mean_absolute_error(y_test, baseline_preds)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

importances = []

for i in range(n_features1):
    X_permuted = copy.deepcopy(X_test)
    # สุ่ม permute ไปที่ feature i ทุก timestep
    for t in range(X_permuted.shape[1]):
        np.random.shuffle(X_permuted[:, t, i]) # สุ่มค่าของ feature ที่ i ที่ timestep t

    permuted_preds = model.predict(X_permuted)
    permuted_score = mean_absolute_error(y_test, permuted_preds)
    importance = permuted_score - baseline_score
    importances.append(importance)

if feature_names is None:
    feature_names = [f'Feature_{i}' for i in range(n_features1)]

# สร้าง DataFrame สำหรับแสดงผล
import pandas as pd
importance_df = pd.DataFrame({
    'feature': feature_names,
    'importance': importances
}).sort_values(by='importance', ascending=False)

return importance_df

importance_df = permutation_feature_importance_3d(model, X_test, y_test, feature_names)
sns.barplot(data=importance_df, x='importance', y='feature')
plt.title('Permutation Feature Importance')
plt.tight_layout()
plt.show()

return model, importance_df

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัลกอริทึม GRU

```

def model_GRU(X_train, y_train, X_test, y_test, batch_size, epochs,
              optimizer, date_test, date_train, feature_names, label_name='Dataset'):
    def create_model():
        model = Sequential()
        model.add(GRU(128, input_shape=(look_back, X_train.shape[2])))
        model.add(Dropout(0.2))
        model.add(Dense(64, activation='relu'))
        model.add(Dropout(0.2))
        model.add(Dense(1, activation='linear'))
        model.compile(loss='mse', optimizer=optimizer)
        return model

    params = {
        'batch_size': batch_size,
        'epochs': epochs,
    }

    early_stopping = EarlyStopping(
        monitor='val_loss',
        patience=10,
        restore_best_weights=True
    )

    model = KerasRegressor(model=create_model, verbose=0, **params)
    model.fit(X_train, y_train, callbacks=[early_stopping])

    # ===== Train Metrics =====
    y_train_pred = model.predict(X_train)
    print('-----')
    print("Train")
    print(f'R2 Value Train: {r2_score(y_train, y_train_pred):.4f}')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

print(f'MSE Train:    {mean_squared_error(y_train, y_train_pred):.4f}')
print(f'RMSE Train:  {np.sqrt(mean_squared_error(y_train, y_train_pred)):.4f}')
print(f'MAE Train:   {mean_absolute_error(y_train, y_train_pred):.4f}')
print(f'MAPE Train:  {mean_absolute_percentage_error(y_train, y_train_pred):.4f}')
print('-----')
plt.figure(figsize=(12, 6))
plt.plot(date_train, y_train, label='Actual', color='blue')
plt.plot(date_train, y_train_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'LightGBM Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

# ===== Test Metrics =====
y_pred = model.predict(X_test)
print('-----')
print('Test')
print(f'R2 Value Test: {r2_score(y_test, y_pred):.4f}')
print(f'MSE Test:     {mean_squared_error(y_test, y_pred):.4f}')
print(f'RMSE Test:    {root_mean_squared_error(y_test, y_pred):.4f}')
print(f'MAE Test:     {mean_absolute_error(y_test, y_pred):.4f}')
print(f'MAPE Test:    {mean_absolute_percentage_error(y_test, y_pred):.4f}')
print('-----')

plt.figure(figsize=(12, 6))
plt.plot(date_test, y_test, label='Actual', color='blue')
plt.plot(date_test, y_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'GRU Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

df_result = pd.DataFrame({
    'date': date_test,
    'actual': y_test,
    'prediction': y_pred
})

perm = PermutationImportance(model, random_state=1).fit(X_test, y_test)

from IPython.display import display
display(eli5.show_weights(perm, feature_names=list(feature_names)))

return model

```

อัลกอริทึม LSTM

```

def model_LSTM(X_train, y_train, X_test, y_test, batch_size, epochs,
               optimizer, date_test, date_train, feature_names, label_name='Dataset'):
    def create_model():
        model = Sequential()
        model.add(LSTM(128, input_shape=(look_back, X_train.shape[2])))
        model.add(Dropout(0.2))
        model.add(Dense(64, activation='relu'))
        model.add(Dropout(0.2))
        model.add(Dense(1, activation='linear'))
        model.compile(loss='mse', optimizer=optimizer)
        return model

    params = {
        'batch_size': batch_size,
        'epochs': epochs,

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

}
early_stopping = EarlyStopping(
    monitor='val_loss',
    patience=10,
    restore_best_weights=True
)

model = KerasRegressor(model=create_model, verbose=0, **params)
model.fit(X_train, y_train, callbacks=[early_stopping])

# ===== Train Metrics =====
y_train_pred = model.predict(X_train)
print('-----')
print('Train')
print(f'R2 Value Train: {r2_score(y_train, y_train_pred):.4f}')
print(f'MSE Train: {mean_squared_error(y_train, y_train_pred):.4f}')
print(f'RMSE Train: {np.sqrt(mean_squared_error(y_train, y_train_pred)):.4f}')
print(f'MAE Train: {mean_absolute_error(y_train, y_train_pred):.4f}')
print(f'MAPE Train: {mean_absolute_percentage_error(y_train, y_train_pred):.4f}')
print('-----')
plt.figure(figsize=(12, 6))
plt.plot(date_train, y_train, label='Actual', color='blue')
plt.plot(date_train, y_train_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'LightGBM Prediction- {label_name}')
plt.xlabel("Time")
plt.ylabel("Close Price")
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

# ===== Test Metrics =====
y_pred = model.predict(X_test)
print('-----')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

print('Test')
print(f'R2 Value Test: {r2_score(y_test, y_pred):.4f}')
print(f'MSE Test: {mean_squared_error(y_test, y_pred):.4f}')
print(f'RMSE Test: {root_mean_squared_error(y_test, y_pred):.4f}')
print(f'MAE Test: {mean_absolute_error(y_test, y_pred):.4f}')
print(f'MAPE Test: {mean_absolute_percentage_error(y_test, y_pred):.4f}')
print('-----')

plt.figure(figsize=(12, 6))
plt.plot(date_test, y_test, label='Actual', color='blue')
plt.plot(date_test, y_pred, label='Prediction', color='orange')
plt.xticks(rotation=45)
plt.title(f'LSTM Prediction- {label_name}')
plt.xlabel('Time')
plt.ylabel('Close Price')
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()

df_result = pd.DataFrame({
    'date': date_test,
    'actual': y_test,
    'prediction': y_pred
})

perm = PermutationImportance(model, random_state=1).fit(X_test, y_test)

from IPython.display import display
display(eli5.show_weights(perm, feature_names=list(feature_names)))

return model

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

| | | | |
|------------------|--|------------|------|
| ชื่อ | นางสาวญาดา สรณะสมบูรณ์ | | |
| วัน เดือน ปีเกิด | 20 เมษายน พ.ศ. 2544 | | |
| ที่อยู่ปัจจุบัน | ตำบลหน้าเมือง อำเภอเมือง จังหวัดฉะเชิงเทรา 24000 | | |
| ประวัติการศึกษา | (2565) วิทยาศาสตร์บัณฑิต สาขาสถิติ (มหาวิทยาลัยขอนแก่น) | เกรดเฉลี่ย | 3.65 |



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้