

การเรียนรู้เชิงลึกแบบผสมผสานสำหรับการพยากรณ์ราคาน้ำมันดิบตลาด
สหรัฐฯ ระยะสั้น

A HYBRID DEEP LEARNING APPROACH FOR SHORT-TERM U.S.
CRUDE OIL PRICE PREDICTION



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ.2568

KMITL-2025-SC-M-017-011

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

A HYBRID DEEP LEARNING APPROACH FOR SHORT-TERM U.S.
CRUDE OIL PRICE PREDICTION



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE
IN DATA SCIENCE AND ANALYTICS
KMUTL DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2025

KMITL-2025-SC-M-017-011

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2025

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การเรียนรู้เชิงลึกแบบผสมผสานสำหรับพยากรณ์ราคาน้ำมันดิบตลาดสหรัฐฯ ระยะสั้น
ชื่อนักศึกษา	ศิริพร ก้องอจลนันท
รหัสประจำตัว	65056081
ปริญญา	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์)
พ.ศ.	ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง 2568
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ผู้ช่วยศาสตราจารย์ ดร.กนกวรรณ ลีโรจนประภา

บทคัดย่อ

น้ำมันดิบถือเป็นพลังงานที่สำคัญ และนิยมซื้อขายในตลาดทางการเงิน ซึ่งในอดีตการพยากรณ์น้ำมันดิบนิยมใช้วิธีการพยากรณ์แบบอนุกรมเวลาแบบคลาสสิก เช่น ARIMA และ GARCH ที่ใช้ตัวแปรอิสระที่เป็นข้อมูลรายเดือน ทำให้แบบจำลองอาจไม่สอดคล้องกับความผันผวนที่เกิดขึ้นในระยะสั้น ดังนั้นหลายงานวิจัยจึงนำโครงข่ายประสาทเทียมมาใช้ในการพยากรณ์ราคาน้ำมันดิบซึ่งให้ค่าความแม่นยำที่ดีขึ้น อย่างไรก็ตามในงานวิจัยนี้ต้องการปรับปรุงประสิทธิภาพของแบบจำลองโดยการเปรียบเทียบแบบจำลองคอนโวลูชัน (Convolution Neural Network: CNN) แบบจำลอง Long Short-Term Memory (LSTM) และแบบผสมผสาน CNN-LSTM โดยรวบรวมปัจจัยที่เกี่ยวข้องกับตลาดการเงินรายวันรวมทั้งสิ้น 23 ตัวแปร ได้แก่ ราคาสินค้าโภคภัณฑ์ (Commodities) 5 ตัวแปร ดัชนีหุ้นจากตลาดหลักทรัพย์ (Stocks) 8 ตัวแปร อัตราแลกเปลี่ยน (Exchange Rate) 8 ตัวแปร และดัชนีมหภาค (Macroeconomic Index) 2 ตัวแปร เก็บข้อมูลตั้งแต่วันที่ 2 มกราคม ค.ศ. 2018 ถึงวันที่ 31 ธันวาคม ค.ศ. 2024 จำนวนทั้งหมด 1,805 ข้อมูล แบ่งข้อมูลการศึกษาออกเป็น 3 ชุด คือ ชุดข้อมูลฝึกสอน (Training Data Set) วันที่ 2 มกราคม ค.ศ. 2018 – 31 ธันวาคม ค.ศ. 2022 ชุดข้อมูลตรวจสอบ (Validation Data Set) วันที่ 1 มกราคม ค.ศ. 2023 – 31 ธันวาคม ค.ศ. 2023 และชุดข้อมูลทดสอบ (Test Data Set) วันที่ 1 มกราคม ค.ศ. 2024 – 31 ธันวาคม ค.ศ. 2024 งานวิจัยนี้ได้ทำการเปรียบเทียบช่วงเวลาข้อมูลย้อนหลังที่เหมาะสมสำหรับการพยากรณ์ราคาน้ำมันดิบระยะสั้น โดยพิจารณาเวลาย้อนหลัง 3, 4, 5 และ 30 วัน ผลการศึกษาพบว่าแบบจำลองผสมผสาน CNN-LSTM ให้ค่าความแม่นยำสูงสุดเมื่อเทียบกับแบบจำลองอื่นๆ โดยเฉพาะอย่างยิ่งเมื่อใช้ข้อมูลย้อนหลัง 3 วัน โดยมีค่า MAE เท่ากับ 1.0437 MAPE เท่ากับ 1.3962 RMSE เท่ากับ 1.3422 และ R^2 เท่ากับ 0.94

คำสำคัญ : การเรียนรู้เชิงลึกแบบผสมผสาน, โครงข่ายประสาทเทียม, การพยากรณ์ระยะสั้น, ราคาน้ำมันดิบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Independent Study Title	A Hybrid Deep Learning Approach for Short-Term U.S Crude Oil Price Prediction
Student Name	Siriporn Kongajalanon
Student ID	65056081
Degree	Master of Science (Data Science and Analytics) KMITL-Digital Analytics and Intelligence Center
Year	2025
Independent Study Advisor	Asst. Prof. Dr. Kanogkan Leerojanaprapa

Abstract

Crude oil is an essential energy source and popular in the financial market. Traditionally, crude oil forecasting has relied on classical time series methods such as ARIMA and GARCH. Which utilize monthly data as independent variables. Consequently, these models may not adequately capture short-term volatility. To address this limitation, many studies have employed artificial neural networks for crude oil price forecasting, achieving improved accuracy.

This research aims to further enhance forecasting model performance by comparing three models: Convolution Neural Network (CNN), Long Short-Term Memory (LSTM), and a hybrid CNN-LSTM model. The study incorporates 23 daily financial market variables, including: commodities 5 variables, stock indices 8 variables, exchange rate 8 variables and macroeconomic indices 2 variables. The study covers the period from January 2nd, 2018, to December 31st, 2024, for a total of 1,850 data points. The data was divided into three sets of study: a training data set, covering the period from January 2, 2018 to December 31, 2022, a validation data set, covering the period from January 1, 2023 to December 31, 2023, and a test data set, covering the period from January 1, 2024 to December 31, 2024. This research compared the optimal historical data window for short-term crude oil price forecasting, examining lookback periods of 3, 4, 5, and 30 days. The findings revealed that the hybrid CNN-LSTM model achieved the highest accuracy compared to other models, particularly with a 3-day lookback, which yielded an MAE of 1.0473, MAPE of 1.3962, RMSE of 1.3422, and R² of 0.94.

Keywords : Hybrid Deep Learning, Artificial Neural Network, Short-term Forecasting, Crude Oil Price

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

การค้นคว้าอิสระฉบับนี้สำเร็จลุล่วงด้วงความกรุณาจาก ผู้ช่วยศาสตราจารย์ ดร.กนกวรรณ ลิ
โรจนประภา อาจารย์ที่ปรึกษาที่ได้กรุณาสละเวลาและให้ความอนุเคราะห์ในการให้คำแนะนำ
ข้อคิดเห็น ตลอดจนแนวทางแก้ไข เพื่อนำไปปรับปรุงการค้นคว้าอิสระให้ดียิ่งขึ้น รวมถึงผู้ช่วย
ศาสตราจารย์ ดร.วรางคณา กัมปาน และ รองศาสตราจารย์ ดร.ละออ บุญเกษม ที่ให้เกียรติมาเป็น
กรรมการค้นคว้าอิสระ และให้คำแนะนำเพื่อปรับปรุงการค้นคว้าอิสระให้ดียิ่งขึ้น

สุดท้ายนี้ขอขอบคุณ บิดา มารดา และเพื่อนในศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอม
เกล้าลาดกระบังที่ให้การสนับสนุนด้วยดีเสมอมา

นางสาว ศิริพร ก้องอจลานนท์



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อ.....	ก
Abstract.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ซ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	3
1.3 ขอบเขตของงานวิจัย.....	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 โครงข่ายประสาทเทียม.....	5
2.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN).....	6
2.2.1 ชั้นคอนโวลูชัน (Convolutional Layers).....	6
2.2.2 ชั้นพูลลิง (Pooling Layers).....	7
2.2.3 ชั้นเชื่อมต่อแบบสมบูรณ์ (Fully Connected Layers).....	7
2.3 โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM).....	7
2.3.1 Cell State.....	8
2.3.2 เกท (Gate).....	9
2.4 แบบจำลองโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM.....	12
2.5 การเลือกคุณลักษณะ (Feature Selection).....	12
2.6 วิศวกรรมคุณลักษณะ (Feature Engineering).....	13
2.7 การปรับแต่งพารามิเตอร์ (Hyperparameter Tuning).....	13
2.8 Permutation Feature Importance.....	13
2.9 การประเมินวัดความแม่นยำของแต่ละอัลกอริทึม (Evaluation Models).....	14
2.10 ปัจจัยที่มีผลกระทบต่อราคาน้ำมันดิบของตลาดสหรัฐฯ.....	15
2.10.1 ตลาดการเงิน (Financial Market).....	16
2.10.2 ตลาดสินค้าโภคภัณฑ์ (Commodity Market).....	16
2.11 งานวิจัยที่เกี่ยวข้อง.....	16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
บทที่ 3 วิธีดำเนินงานวิจัย	23
3.1 การเก็บรวบรวมข้อมูล (Data Collection).....	23
3.2 การเตรียมข้อมูล (Data Preparation).....	25
3.2.1 การตรวจสอบข้อมูลที่ขาดหายไป (Missing Value).....	25
3.2.2 การคัดเลือกคุณลักษณะ (Feature Selection).....	27
3.2.3 วิศวกรรมคุณลักษณะ (Feature Engineering).....	28
3.2.4 การแบ่งชุดข้อมูล (Data Split).....	28
3.3 การออกแบบโครงข่ายประสาทเทียม.....	29
3.4 Hyperparameter Tuning.....	31
3.5 เครื่องมือที่ใช้วัดประสิทธิภาพแบบจำลอง.....	32
3.6 Feature Importance.....	32
บทที่ 4 ผลการวิจัยและการอภิปรายผล	34
4.1 การวิเคราะห์ข้อมูลเบื้องต้น.....	34
4.2 ผลการวิจัยการเปรียบเทียบการพยากรณ์ราคาน้ำมันดิบที่ใช้เวลาย้อนหลังแตกต่างกัน...35	35
4.2.1 แบบจำลอง CNN.....	35
4.2.2 แบบจำลอง LSTM (1).....	36
4.2.3 แบบจำลอง LSTM (2).....	37
4.2.4 แบบจำลอง CNN-LSTM.....	38
4.3 ผลการวิจัยการเปรียบเทียบการพยากรณ์ราคาน้ำมันดิบที่ทำการลดขนาดมิติของข้อมูลด้วยค่าสหสัมพันธ์ ± 0.4 ที่เวลาย้อนหลังแตกต่างกัน.....	39
4.3.1 แบบจำลอง CNN.....	40
4.3.2 แบบจำลอง LSTM (1).....	41
4.3.3 แบบจำลอง LSTM (2).....	42
4.3.4 แบบจำลอง CNN-LSTM.....	43
4.4 สรุปผลการเปรียบเทียบประสิทธิภาพแบบจำลอง.....	44
4.5 ปัจจัยที่มีผลต่อการพยากรณ์ราคาน้ำมันดิบสหรัฐอเมริกา ด้วยวิธี Permutation Feature Importance (PFI).....	46
4.4.1 แบบจำลอง CNN.....	47
4.4.2 แบบจำลอง LSTM (1).....	47
4.4.3 แบบจำลอง LSTM (2).....	48
4.4.4 แบบจำลอง CNN-LSTM.....	49
4.6 การอภิปรายผล.....	53

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	58
5.1 สรุปผลการวิจัย.....	58
5.2 ข้อเสนอแนะ.....	60
เอกสารอ้างอิง.....	61
ภาคผนวก.....	65
ประวัติผู้เขียน.....	72



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1 สรุปข้อมูลวิจัยใช้อ้างอิง	19
3.1 ตัวแปรสำหรับการศึกษา จำนวน 29 ตัวแปร	24
3.2 Hyperparameter Tuning ที่ใช้ในแบบจำลอง A B C และ D	31
4.1 ค่า Hyperparameter ของแบบจำลอง CNN ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน.....	36
4.2 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน.....	36
4.3 ค่า Hyperparameter ของแบบจำลอง LSTM (1) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน.....	36
4.4 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน..	36
4.5 ค่า Hyperparameter ของแบบจำลอง LSTM (2) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน.....	37
4.6 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (2) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน..	38
4.7 ค่า Hyperparameter ของแบบจำลอง CNN-LSTM ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน... 38	
4.8 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-LSTM ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน	38
4.9 เปรียบเทียบผลการทดลองของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM โดยวัดจากค่า MAE.....	39
4.10 ค่า Hyperparameter ของแบบจำลอง CNN ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน	40
4.11 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน	41
4.12 ค่า Hyperparameter ของแบบจำลอง LSTM (1) ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน	41
4.13 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน... 41	
4.14 ค่า Hyperparameter ของแบบจำลอง LSTM (2) ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน	42
4.15 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (2) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน 42	
4.16 ค่า Hyperparameter ของแบบจำลอง CNN-LSTM ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน 43	
4.17 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-LSTM ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน 43	
4.18 เปรียบเทียบผลการทดลองของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM ด้วยข้อมูลชุดทดสอบที่ทำการลดขนาดมิติของข้อมูลด้วยค่าสหสัมพันธ์ โดยวัดจากค่า MAE.....	44
4.19 ค่าเฉลี่ยของค่า MAE จำแนกตามจำนวนตัวแปรและเวลาย้อนหลังที่แตกต่างกันในแต่ละแบบจำลอง	45
4.20 ค่าเฉลี่ยของค่า MAE จำแนกตามเวลาย้อนหลังและจำนวนตัวแปรที่แตกต่างกันในแต่ละแบบจำลอง	46
4.21 ตัวแปรอิสระ 5 อันดับแรกที่มีอิทธิพลในการพยากรณ์ราคาน้ำมันดิบระยะสั้นของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM	52
4.22 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN - LSTM ที่เวลาย้อนหลัง 30 วัน.....	57
5.1 เปรียบเทียบประสิทธิภาพที่ดีที่สุดของแบบจำลอง CNN, LSTM (1), LSTM (2) และ CNN-LSTM	59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

ภาพที่	หน้า
1.1 สัดส่วนการผลิตน้ำมันดิบแบ่งตามประเทศ	2
1.2 ปริมาณการส่งออกน้ำมันดิบของประเทศสหรัฐอเมริกาแบ่งตามภูมิภาค	2
2.1 ภาพจำลองแสดงโครงข่ายประสาทเทียม	5
2.2 แบบจำลองแสดงโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)	6
2.3 การทำงานของชั้นคอนโวลูชัน	7
2.4 โครงสร้างโครงข่ายประสาทเทียมแบบ LSTM	8
2.5 โครงสร้าง LSTM Cell State	8
2.6 โครงสร้าง LSTM Forget Gate	9
2.7 โครงสร้าง LSTM Input Gate	10
2.8 โครงสร้าง Cell State ณ t	10
2.9 โครงสร้าง Output Gate	11
2.10 โครงสร้างการทำงานของแบบจำลอง CNN-LSTM	12
3.1 วิธีดำเนินงานวิจัย	23
3.2 ข้อมูลสูญหายเนื่องจากวันทำการแตกต่างกัน	25
3.3 ข้อมูลสูญหายหลังจากลบข้อมูลวันอาทิตย์ออกจากชุดข้อมูล	26
3.4 ค่าสหสัมพันธ์ของข้อมูล (Correlation)	27
3.5 การออกแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network)	29
3.6 การออกแบบโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (1)	30
3.7 การออกแบบโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (2)	30
3.8 การออกแบบโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM	31
3.9 การแบ่งข้อมูลด้วยวิธี TimeSeriesSplit	32
3.10 ตัวอย่าง python code ของการหา Feature Importance ด้วยวิธี Permutation Feature Importance (PFI)	33
4.1 ราคาน้ำมันดิบสหรัฐฯในช่วง ค.ศ. 2018-2024	34
4.2 Permutation Feature Importance ของแบบจำลอง CNN ที่เวลาย้อนหลัง 3 วัน	47
4.3 Permutation Feature Importance ของแบบจำลอง LSTM (1) ที่เวลาย้อนหลัง 5 วัน	48
4.4 Permutation Feature Importance ของแบบจำลอง LSTM (2) ที่เวลาย้อนหลัง 3 วัน	49
4.5 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 3 วัน	50
4.6 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 4 วัน	50
4.7 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 5 วัน	51
4.8 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 30 วัน	51
4.9 ราคาน้ำมันดิบจากการพยากรณ์เทียบราคาน้ำมันดิบจริงของแบบจำลอง CNN-LSTM ในชุดข้อมูลทดสอบ	54
4.10 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) และ LSTM (2) ด้วยค่า MAE	55
4.11 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) และ LSTM (2) ด้วยค่า MAPE	55

เอกสารนี้เป็นเอกสารที่จัดทำขึ้นเพื่อการเรียนการสอนเท่านั้น และอยู่ภายใต้ลิขสิทธิ์ของสถาบันฯ

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.12 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) และ LSTM (2) ด้วยค่า RMSE..... 56



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1


บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

น้ำมันดิบเป็นของเหลวตามธรรมชาติที่ประกอบด้วยสารประกอบไฮโดรคาร์บอนหลากหลายชนิด เมื่อน้ำมันดิบถูกกลั่นจะแปลงสภาพเป็นผลิตภัณฑ์สำเร็จรูปต่างๆ เช่น ก๊าซหุงต้มที่ใช้ในครัวเรือน เบนซิน ดีเซล น้ำมันเครื่องบิน น้ำมันเตาที่ใช้ในการสำหรับรถยนต์ เครื่องบิน เรือเดินทะเล หรือ แนฟทาเบาที่ใช้เป็นสารตั้งต้นในอุตสาหกรรมปิโตรเคมี สำหรับนำไปผลิตเม็ดพลาสติก จากตัวเลขขององค์การพลังงานระหว่างประเทศ (International Energy Agency: IEA) สัดส่วนการบริโภคน้ำมันของโลกในปี 2023 คิดเป็นร้อยละ 39 เมื่อเทียบกับพลังงานประเภทอื่นๆ (The International Energy Agency, 2024) จากที่กล่าวมาข้างต้นทำให้น้ำมันดิบถือเป็นแหล่งพลังงานที่สำคัญในปัจจุบัน การเปลี่ยนแปลงของราคาน้ำมันดิบจึงส่งผลกระทบต่อกิจกรรมทางเศรษฐกิจทั่วโลก (Deng et al., 2021) ความสำคัญดังกล่าวทำให้น้ำมันดิบเป็นหนึ่งในสินค้าที่มีการซื้อขายขนาดใหญ่ในตลาดการเงิน (Financial market) (Corporate Finance Institute, 2024)

ราคาน้ำมันดิบอ้างอิงในตลาดโลกมีราคาอ้างอิงหลัก 3 ประเภท 1. น้ำมันดิบเบรนท์ (Brent) เป็นน้ำมันดิบที่ขุดเจาะจากทะเลเหนือ มีระดับกำมะถันต่ำ เหมาะสมสำหรับกลั่นเป็นน้ำมันเบนซินและน้ำมันดีเซล 2. น้ำมันดิบตลาดสหรัฐอเมริกา (West Texas Intermediate: WTI) เป็นน้ำมันดิบที่ขุดเจาะจากแหล่งน้ำมันในประเทศสหรัฐอเมริกา มีระดับกำมะถันต่ำกว่าน้ำมันดิบเบรนท์ เหมาะสมสำหรับกลั่นเป็นน้ำมันเบนซิน 3. น้ำมันดิบดูไบ (Dubai) เป็นน้ำมันดิบที่ขุดเจาะจากแหล่งน้ำมันดูไบ ประเทศสหรัฐอาหรับเอมิเรตส์ มีระดับกำมะถันสูง ทำให้ค่าใช้จ่ายในการกลั่นน้ำมันดิบสูงกว่าน้ำมันดิบเบรนท์และน้ำมันดิบตลาดสหรัฐอเมริกา จากภาพที่ 1.1 แสดงให้เห็นว่าในปี ค.ศ. 2023 ประเทศสหรัฐอเมริกามีสัดส่วนการผลิตน้ำมันดิบสูงสุด คิดเป็นร้อยละ 12.9 ประเทศที่ผลิตน้ำมันดิบเป็นอันดับสองคือ ประเทศรัสเซีย คิดเป็นร้อยละ 10.1 และประเทศที่ผลิตน้ำมันดิบเป็นอันดับสามคือประเทศซาอุดีอาระเบีย คิดเป็นร้อยละ 9.7 การผลิตน้ำมันดิบของประเทศสหรัฐอเมริกาเริ่มเพิ่มขึ้นตั้งแต่ปี ค.ศ. 2009 เนื่องจากการพัฒนาเทคโนโลยีขุดเจาะน้ำมัน ในปีค.ศ. 2023 การส่งออกน้ำมันดิบสหรัฐอเมริกาเฉลี่ยอยู่ที่ 4.1 ล้านบาร์เรลต่อวันเพิ่มขึ้นประมาณ 13% เปรียบเทียบกับปีค.ศ. 2022 จากปัญหาภูมิรัฐศาสตร์ระหว่างรัสเซียและยูเครนในช่วยต้นปี ค.ศ. 2022 ทำให้ยุโรปคว่ำบาตร (Sanction) การนำเข้าน้ำมันจากรัสเซียและพึ่งพาการนำเข้าจากสหรัฐอเมริกาเพิ่มมากขึ้น ดังภาพที่ 1.2 นอกจากนี้การซื้อขายน้ำมันดิบในตลาดหลักทรัพย์นิวยอร์ก (New York Stock Exchange) ใช้ น้ำมันดิบ WTI เป็นน้ำมันดิบอ้างอิง ความต้องการซื้อที่สูงประกอบกับอิทธิพลของตลาดหลักทรัพย์นิวยอร์ก ทำให้การซื้อขายน้ำมันดิบ WTI กลายเป็นผู้นำในกลุ่มสินค้าโภคภัณฑ์ล่วงหน้าทั่วโลก (Cen & Wang, 2019)


Global crude oil and condensate production in 2023 by select countries
million barrels per day



ภาพที่ 1.1 สัดส่วนการผลิตน้ำมันดิบแบ่งตามประเทศ

(ที่มา: <https://www.eia.gov/todayinenergy/detail.php?id=64125>)

Annual U.S. crude oil exports by destination region (2015–2023)
million barrels per day



ภาพที่ 1.2 ปริมาณการส่งออกน้ำมันดิบของประเทศสหรัฐอเมริกาแบ่งตามภูมิภาค

(ที่มา: <https://www.eia.gov/todayinenergy/detail.php?id=61584>)

ความผันผวนของราคาน้ำมันเกิดจากการเปลี่ยนแปลงของอุปสงค์และอุปทานของน้ำมันดิบแต่ช่วงเวลา ในระยะสั้นราคาน้ำมันจะผันผวนมากกว่าในระยะยาว จากเหตุการณ์ที่คาดการณ์ไม่ได้ เช่น โรคระบาด ปัจจัยทางการเมือง สภาพอากาศ และการเก็งกำไรของนักลงทุน (Cheng et al., 2019; Xu et al., 2023) ส่งผลให้การพยากรณ์น้ำมันมีความซับซ้อนมากขึ้น ซึ่งไม่เหมาะกับวิธีการพยากรณ์แบบอนุกรมเวลาที่เป็นเส้นตรงที่นิยมในอดีต เช่น ARIMA และ GARCH เพื่อเพิ่มความแม่นยำในการพยากรณ์ นักวิจัยจึงหันมาใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) เช่น แบบจำลองคอนโวลูชัน (Convolution Neural Network; CNN) และ แบบจำลอง Long Short-Term Memory (Long Short-Term Memory; LSTM) นอกจากนี้ยังเป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Term Memory (LSTM) เนื่องจากแบบจำลองสามารถเรียนรู้ เข้าใจความซับซ้อนที่ไม่เป็นเส้นตรง (Nonlinear) ของข้อมูลราคาน้ำมันได้ ตัวอย่างเช่น งานวิจัยของ Deng. et al. (2021) ที่ใช้ LSTM ทำนายราคาน้ำมันของตลาดอ้างอิงเชิงไฮ้ได้ความแม่นยำสูงกว่า ARIMA และงานวิจัยของ Zhang and Hong (2022) ที่ทำการเปรียบเทียบตัวแบบพยากรณ์ราคาน้ำมันดิบของตลาดสหรัฐอเมริกาและยุโรป ซึ่ง LSTM สามารถพยากรณ์ราคาน้ำมันดิบได้ดีกว่า เมื่อเทียบกับ ARIMA และ RNN ซึ่งสอดคล้องกับงานวิจัยของ Kumar. et al. (2018) ที่ทำการพยากรณ์ราคาน้ำมันดิบด้วยวิธี ARIMA MLP และ RNN ซึ่งผลการทดลองแสดงว่าโครงข่ายประสาทเทียมสามารถพยากรณ์ที่เป็นความสัมพันธ์แบบไม่เป็นเส้นตรง (Nonlinear) ได้ดีกว่าการพยากรณ์อนุกรมเวลาแบบคลาสสิก นอกจากนี้งานวิจัยที่ผ่านมา นิยมใช้ข้อมูลทางเศรษฐกิจ เช่น ผลิตภัณฑ์มวลรวมประชาชาติ (Gross Domestic Product: GDP) ของประเทศต่างๆ ปริมาณการผลิตน้ำมัน ปริมาณนำเข้าน้ำมัน ซึ่งเป็นข้อมูลรายเดือนในการพยากรณ์ราคาน้ำมัน ที่อาจจะไม่สอดคล้องกับราคาน้ำมันที่ผันผวนสูงในระยะสั้นและไม่สอดคล้องกับการตัดสินใจซื้อขายน้ำมันในตลาดที่มักใช้เวลาในการตัดสินใจเพียงไม่กี่วัน ซึ่งเป็นรูปแบบของการตัดสินใจลงทุนในระยะสั้น

งานวิจัยนี้จึงนำเสนอการทำนายราคาน้ำมันดิบรายวันของตลาดสหรัฐอเมริกา โดยใช้แบบจำลองที่มีความซับซ้อนในกลุ่มการเรียนรู้เชิงลึก ซึ่งได้แก่ แบบจำลองคอนโวลูชัน (Convolution Neural Network) แบบจำลอง Long Short-Term Memory (LSTM) และ แบบจำลองผสมผสาน CNN-LSTM ร่วมกับราคาน้ำมันย้อนหลังในช่วงที่แตกต่างกัน และตัวแปรอิสระที่มีการซื้อขายในตลาดการเงิน (Financial Market) เพื่อให้สามารถกำหนดระยะเวลาการทำนายล่วงหน้าที่เหมาะสมกับแบบจำลองทั้ง 3 แบบ และคัดเลือกแบบจำลองที่เหมาะสมสำหรับการพยากรณ์ราคาน้ำมันดิบรายวันของตลาดสหรัฐอเมริกา

1.2 วัตถุประสงค์ของงานวิจัย

- 1) เปรียบเทียบการพยากรณ์ราคาน้ำมันดิบตลาดสหรัฐอเมริการะยะสั้น ด้วยแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN) แบบจำลอง LSTM และแบบจำลองผสมผสาน CNN-LSTM
- 2) ระบุปัจจัยที่ส่งผลต่อราคาน้ำมันดิบรายวันของตลาดสหรัฐอเมริกา

1.3 ขอบเขตของงานวิจัย

1.3.1 ขอบเขตด้านตัวแปร

ข้อมูลที่ใช้ในการศึกษานี้เป็นข้อมูลทุติยภูมิ มีตัวแปรตามคือราคาน้ำมันดิบตลาดสหรัฐอเมริกา และตัวแปรอิสระทั้งสิ้น 29 ตัวแปร ซึ่งเป็นข้อมูลรายวันแบ่งเป็น 4 กลุ่มตัวแปร ได้แก่

- 1) ราคาสินค้าโภคภัณฑ์ (Commodities) ได้แก่ ราคาน้ำมันดิบตลาดสหรัฐอเมริกา (WTI Crude Oil) ราคาทองคำ (Gold Spot US Dollar) ราคาแก๊สธรรมชาติ (Natural Gas) ราคาเงิน (Silver) และ ราคาถ่านหิน (Newcastle Coal)

- 2) ดัชนีหุ้นจากตลาดหลักทรัพย์ (Stocks) ได้แก่ ดัชนีหุ้นตลาดหลักทรัพย์บราซิล (Bovespa: IBOV) ดัชนีหุ้นตลาดหลักทรัพย์แคนาดา (S&P/TSX Composite: GSPTSE) ดัชนีหุ้นตลาดหลักทรัพย์อเมริกา (S&P 500: SPX) ดัชนีหุ้นตลาดหลักทรัพย์ฝรั่งเศส (CAC 40: FCHI) ดัชนีหุ้นตลาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลักทรัพย์นอร์เวย์ (OSE Benchmark: OSEBX) ดัชนีหุ้นตลาดหลักทรัพย์รัสเซีย (MOEX Russia Index: IMOEX) ดัชนีหุ้นตลาดหลักทรัพย์เยอรมัน (DAX: GDAXI) ดัชนีหุ้นตลาดหลักทรัพย์เกาหลีใต้ (KOSPI: KS11) ดัชนีหุ้นตลาดหลักทรัพย์ญี่ปุ่น (Nikkei 225: N225) ดัชนีหุ้นตลาดหลักทรัพย์ชาวดีอาร์เอเชีย (TASI) ดัชนีหุ้นตลาดหลักทรัพย์อินเดีย (BSE Sensex 30: BSESN) และ ดัชนีหุ้นตลาดหลักทรัพย์จีน (Shanghai Composite: SSEC)

3) อัตราแลกเปลี่ยน (Exchange rate) ได้แก่ อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ (EUR-USD) อัตราแลกเปลี่ยนหยวนต่อดอลลาร์สหรัฐ (CNY-USD) อัตราแลกเปลี่ยนรูปีต่อดอลลาร์สหรัฐ (INR-USD) อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐ (JPY-USD) อัตราแลกเปลี่ยนปอนด์สเตอร์ลิงต่อดอลลาร์สหรัฐ (GBP-USD) อัตราแลกเปลี่ยนโครนนอร์เวย์ต่อดอลลาร์สหรัฐ (NOK-USD) อัตราแลกเปลี่ยนโครนเดนมาร์กต่อดอลลาร์สหรัฐ (DKK-USD) อัตราแลกเปลี่ยนเปโซเม็กซิกันต่อดอลลาร์สหรัฐ (MXN-USD) อัตราแลกเปลี่ยนรูเบิลรัสเซียต่อดอลลาร์สหรัฐ (RUB-USD) และ อัตราแลกเปลี่ยนโครนาสวีเดนต่อดอลลาร์สหรัฐ (SEK-USD)

4) ดัชนีมหภาค (Macroeconomic) ได้แก่ ดัชนีดอลลาร์ (US dollar index) และ อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐ 10 ปี (US 10Year Bond Yield)

1.3.2 ขอบเขตด้านเวลา

ข้อมูลที่น่ามาศึกษาเป็นข้อมูลรายวันระหว่างวันที่ 2 มกราคม ค.ศ. 2018 - 31 ธันวาคม ค.ศ. 2024 โดยไม่นำราคาน้ำมันที่มีการซื้อขายในวันเสาร์และอาทิตย์ เนื่องจากข้อจำกัดด้านตัวแปรอิสระที่บางตัวแปรมีข้อมูลเฉพาะเวลาทำการจันทร์ถึงศุกร์เท่านั้น

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ได้แบบจำลองที่เหมาะสมและมีประสิทธิภาพในการพยากรณ์ราคาน้ำมันดิบระยะสั้นตลาดสหรัฐอเมริกา
- 2) เพื่อทดสอบว่าตัวแปรรายวันในตลาดการเงินสามารถพยากรณ์ราคาน้ำมันดิบระยะสั้นตลาดสหรัฐอเมริกา
- 3) นำผลการพยากรณ์ราคาน้ำมันดิบในตลาดสหรัฐอเมริกาไปใช้เป็นแนวทางในการตัดสินใจลงทุน เพื่อให้เกิดประสิทธิภาพสูงสุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


ผู้วิจัยได้ศึกษาแนวคิด ทฤษฎี และเอกสารที่เกี่ยวข้องเพื่อนำมาทำการวิจัยการพยากรณ์ราคาน้ำมันดิบระยะสั้นตลาดสหรัฐอเมริกา เพื่อเป็นข้อมูลประกอบการศึกษาและอภิปรายผลการวิจัย ซึ่งประกอบด้วยคิดและทฤษฎี ดังนี้

- 2.1 โครงข่ายประสาทเทียม
- 2.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน
- 2.3 โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM)
- 2.4 โครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM
- 2.5 การเลือกคุณลักษณะ
- 2.6 วิศวกรรมคุณลักษณะ
- 2.7 การปรับแต่งพารามิเตอร์
- 2.8 Permutation Feature Importance
- 2.9 การประเมินวัดความแม่นยำของแต่ละอัลกอริทึม
- 2.10 ปัจจัยที่มีผลกระทบต่อราคาน้ำมันดิบของตลาดสหรัฐอเมริกา
- 2.11 งานวิจัยที่เกี่ยวข้อง

2.1 โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

โครงข่ายประสาทเทียมเป็นหนึ่งในเทคนิคของการเรียนรู้ของเครื่อง ที่จำลองมาจากโครงข่ายระบบประสาทของมนุษย์ ประกอบด้วยหลายชั้นของโหนด (Node) หรือ เรียกว่าเซลล์ประสาท (Neurons) ที่เชื่อมต่อกันเพื่อที่จะหารูปแบบ (Pattern) ของข้อมูล และทำนายผล (Bhatt et al., 2023)

โครงข่ายประสาทเทียมจะประกอบด้วย ชั้นนำเข้า (Input Layer) ชั้นที่ถูกซ่อนซึ่งสามารถมีได้มากกว่า 1 ชั้น (Hidden Layer) และ ชั้นนำออก (Output Layer) ตามภาพที่ 2.1




ภาพที่ 2.1 ภาพจำลองแสดงโครงข่ายประสาทเทียม

ที่มา : Bhatt. et al. (2023)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นประเภทหนึ่งของโครงข่ายประสาทเทียมที่เหมาะสมสำหรับการประมวลผลภาพ เช่น การจดจำวัตถุ และการจำแนกประเภทของภาพ (IBM, 2024; Wang et al., 2021; Bhatt et al., 2023) ซึ่งโครงข่ายประสาทเทียมแบบคอนโวลูชันมีโครงสร้างเหมือนกับโครงข่ายประสาทเทียมที่ประกอบด้วย ชั้นนำเข้า (Input Layer) ชั้นที่ถูกซ่อน (Hidden Layer) และ ชั้นนำออก (Output Layer) แต่ในชั้นที่ถูกซ่อนจะมีจำนวนชั้นที่มากกว่า รวมถึงมีชั้นคอนโวลูชัน (Convolutional Layers) และ ชั้นพูลลิง (Pooling Layers) เพื่อใช้ในการสกัดคุณลักษณะ (feature extraction) (Chen & He, 2018)



ภาพที่ 2.2 แบบจำลองแสดงโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)

ที่มา : Bhatt. et al. (2023)


ภาพที่ 2.2 ได้แสดงโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ทั้งหมด 7 เลเยอร์ ประกอบด้วย ชั้นนำเข้า (Input Layer) ชั้นคอนโวลูชัน (Convolutional Layers) 2 เลเยอร์ ชั้นพูลลิง (Pooling Layers) 2 เลเยอร์ โดยใช้เทคนิคเลือกข้อมูลที่สูงที่สุดก่อนส่งไปยังชั้นต่อไป ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully Connected Layers) 1 เลเยอร์ และชั้นนำออก (Output Layer) ซึ่งเป็นชั้นสุดท้ายที่ให้ผลลัพธ์ของการพยากรณ์

2.2.1 ชั้นคอนโวลูชัน (Convolutional Layers)

ชั้นคอนโวลูชันเป็นชั้นสำคัญของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่จะใช้ชุดของฟิลเตอร์ (Filter) หรือเรียกอีกอย่างว่า เคอร์เนล (Kernel) กับข้อมูลนำเข้าโดยแต่ละฟิลเตอร์จะทำการเลื่อนไปตำแหน่งต่างๆ เพื่อดำเนินการคอนโวลูชัน (Convolutional) โดยการทำการคอนโวลูชันเพื่อตรวจจ็บบรูปแบบ (Patterns) ที่สำคัญของข้อมูล

คอนโวลูชันเป็นการคำนวณแบบ Dot Product ระหว่างพื้นที่ส่วนย่อยของข้อมูลและฟิลเตอร์ จากภาพที่ 2.3 กำหนดค่าฟิลเตอร์ที่ขนาด 1×3 เมื่อนำไปคอนโวลูชันกับพื้นที่ส่วนย่อย จะได้ผลลัพธ์เท่ากับ $(0 \times 2) + (1 \times 2) + (2 \times 2) = 6$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



Padding

```
nn.Conv1d(in_channels=1, out_channels=1,
kernel_size=3, padding=1,
bias=False
)
```

Size

$$L_{out} = \left\lfloor \frac{L_{in} + 2 \times \text{padding} - \text{dilation} \times (\text{kernel_size} - 1) - 1}{\text{stride}} + 1 \right\rfloor$$

$$6 = \frac{6 + (2 * 1) - 1 * (3 - 1) - 1}{1} + 1$$

jinglescode.github.io

ภาพที่ 2.3 การทำงานของชั้นคอนโวลูชัน

ที่มา : Jing (2024)

หลังจากทำการคอนโวลูชันจะนำผลลัพธ์ที่ได้ผ่านฟังก์ชันกระตุ้น (Activation Function) ซึ่งในงานวิจัยนี้ใช้ Tanh Function เป็นฟังก์ชันที่ให้ผลลัพธ์ออกมาเป็นค่า -1 ถึง 1 ก่อนส่งผลลัพธ์ไปในชั้นถัดไป

2.2.2 ชั้นพูลลิ่ง (Pooling Layers)

ชั้นพูลลิ่งเป็นชั้นที่ทำการลดมิติของข้อมูลหรือลดจำนวนของพารามิเตอร์ ในข้อมูลนำเข้า ซึ่งจะทำงานเหมือนกับชั้นคอนโวลูชันที่จะทำการเลื่อนฟิลเตอร์ไปที่ข้อมูลนำเข้า แต่ฟิลเตอร์จะไม่มีน้ำหนัก (Weight) ซึ่งพูลลิ่งมี 2 ประเภทได้แก่ Max Pooling ที่ทำการฟิลเตอร์ไปที่ข้อมูลนำเข้าและเลือกค่าที่สูงที่สุดส่งไปที่ชั้นนำออก และ Average Pooling ที่ทำการหาค่าเฉลี่ยของข้อมูลส่งไปที่ชั้นนำออก


2.2.3 ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully Connected Layers)

หลังจากที่ข้อมูลนำเข้าผ่านชั้นคอนโวลูชันและพูลลิ่งส่งมาชั้นเชื่อมโยงแบบสมบูรณ์ ซึ่งเป็นขั้นสุดท้ายของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ทำหน้าที่ในจำแนกประเภท (Classification) หรือการพยากรณ์ข้อมูล (Forecasting) ผลลัพธ์ที่ได้จากชั้นนี้ จะคำนวณผ่านฟังก์ชันกระตุ้น (Activation Function) (Chen & He, 2018)

2.3 โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM)

LSTM หรือ Long Short-Term Memory เป็นประเภทของโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network) ที่ถูกออกแบบมาเพื่อจัดการกับข้อมูลแบบลำดับ โดย LSTM สามารถแก้ปัญหา Gradient ที่ลดลงเรื่อยๆ จนมีค่าเข้าใกล้ศูนย์ ทำให้น้ำหนัก (Weight) ไม่เกิดการเอกสารถีนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เปลี่ยนแปลง เราเรียกปัญหานี้ว่า Vanishing Gradient Descent ซึ่งเป็นปัญหาในโครงข่ายประสาทเทียมแบบวนกลับ โดยการนำสถานะเซลล์ปัจจุบัน (Cell State) และเกต (Gate) ที่มาตัดสินใจว่าข้อมูลนี้ควรจดจำหรือลบทิ้งไป (Olah, 2015) การทำงานของ LSTM แบ่งออกเป็น 2 ส่วน คือ



ภาพที่ 2.4 โครงสร้างโครงข่ายประสาทเทียมแบบ LSTM

ที่มา : Olah (2015)

2.3.1 Cell State

Cell State เป็นเซลล์ที่ทำหน้าที่จดจำหรือลบข้อมูล โดยอาศัยข้อมูลนำเข้า (Input Value) ซึ่งหมายความว่าข้อมูลบางส่วนก่อนหน้า (Cell State from Timestamp = $t-1$) บางส่วนควรลืมและเพิ่มข้อมูลใหม่ (Input Data Timestamp t) เข้าไปในหน่วยความจำ



ภาพที่ 2.5 โครงสร้าง LSTM Cell State

ที่มา : Olah (2015)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.2 เกต (Gate)

เกตเป็นส่วนควบคุมการไหลของข้อมูล เพื่อให้ LSTM มีการพิจารณาว่าควรจดจดข้อมูลในแต่ละโหนด (Node) ได้ง่ายขึ้น ซึ่งเกตสามารถแบ่งออกได้ เป็น 3 ประเภท

1. Forget gate

เป็น Gate ที่ทำหน้าที่กำหนดว่าข้อมูลที่เข้ามาใน Cell ควรจะเก็บไว้หรือลืมไป ซึ่งข้อมูลจะถูกประเมินจากข้อมูลนำเข้า ณ เวลา t และ ผลลัพธ์ของ Cell state ณ เวลา t - 1 โดยผ่านฟังก์ชันกระตุ้น ดังสมการที่ (2.1)



ภาพที่ 2.6 โครงสร้าง LSTM Forget Gate

ที่มา : Olah (2015)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.1)$$


โดยที่ f_t คือ ผลลัพธ์จากการคำนวณ Forget gate ณ เวลา t
 σ คือ ฟังก์ชันกระตุ้น
 W_f คือ น้ำหนักของ Forget gate
 h_{t-1} คือ ผลลัพธ์ของ hidden ณ เวลา t - 1
 x_t คือ ข้อมูลนำเข้า ณ เวลา t
 b_f คือ Bias ของ Input gate

ผลลัพธ์ที่ได้จาก Forget Gate จะอยู่ระหว่างค่า 0 และ 1 ถ้าผลลัพธ์เป็น 0 หมายถึงจะลืมนำค่าของ Cell State เดิม ถ้าผลลัพธ์เป็น 1 หมายถึงจะเก็บค่า Cell State นี้

2. Input Gate

Input Gate เป็นเกต (Gate) ที่จะตัดสินใจว่าควรจะมีข้อมูลใหม่เข้าไปใน Cell State ซึ่งจะแบ่งออกเป็น 2 ส่วน Input layer เป็นชั้นที่จะตัดสินใจว่าค่าใดจะถูกอัปเดตไปใน Cell State ถ้าต้องอัปเดต จะทำการสร้างค่า Candidate ใหม่ โดยใช้ฟังก์ชันกระตุ้น Tanh ตามสมการที่ (2.2) และสมการที่ (2.3)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 2.7 โครงสร้าง LSTM Input Gate

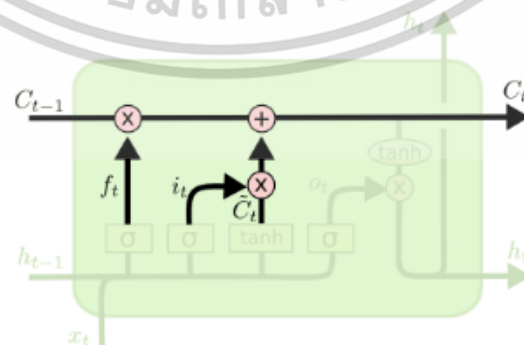
ที่มา : Olah (2015)

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{2.2}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{2.3}$$

- โดยที่
- i_t คือ Input layer ณ เวลา t
 - \tilde{C}_t คือ Candidate ใหม่ ณ เวลา t
 - σ, \tanh คือ ฟังก์ชันกระตุ้น
 - W_i, W_c คือ น้ำหนัก
 - h_{t-1} คือ ผลลัพธ์ของ Hidden State ณ เวลา t-1
 - x_t คือ ข้อมูลนำเข้า ณ เวลา t
 - b_i, b_c คือ Bias ของ Input gate

ต่อมาจะมาทำการอัปเดต Cell state ณ เวลา t จาก Forget Gate, Input Layer และ Candidate ใหม่ ณ เวลา t ตามสมการข้างต้น สมการของ Cell state ณ เวลา t ตามสมการที่ (2.4)



ภาพที่ 2.8 โครงสร้าง Cell State ณ t

ที่มา : Olah (2015)

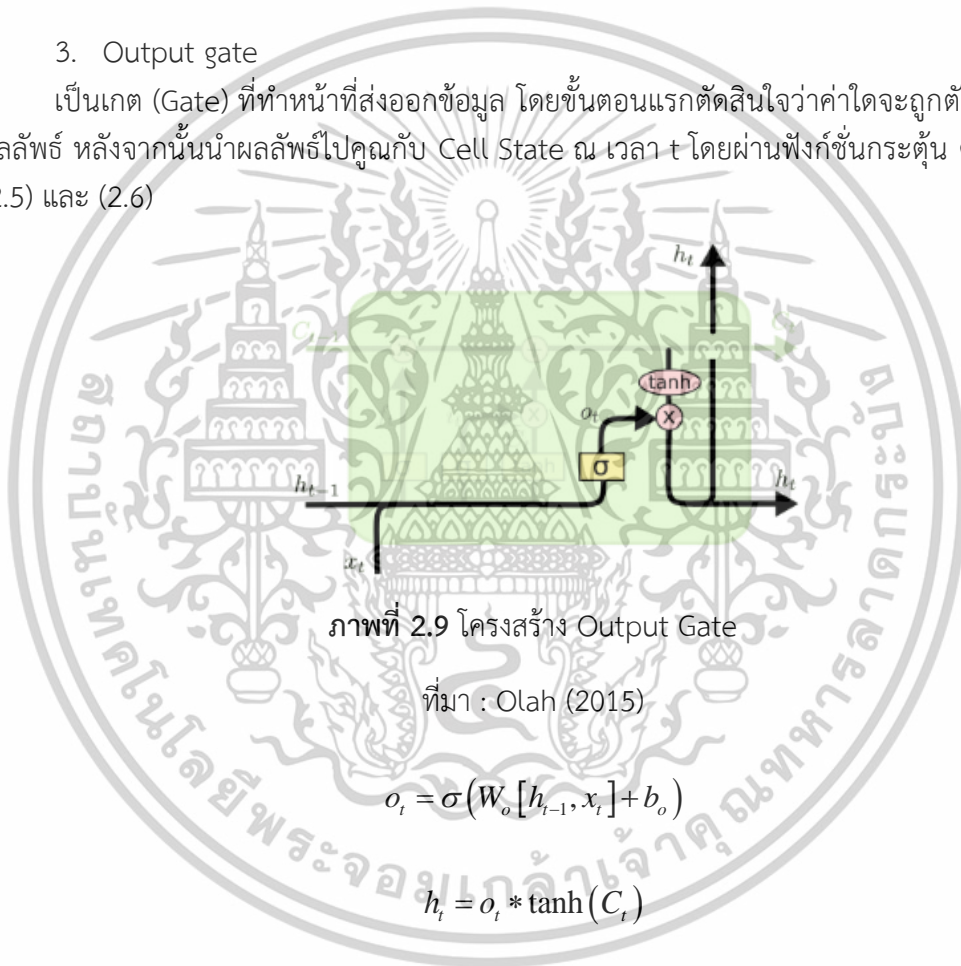
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.4)$$

โดยที่ C_t	คือ Cell state ณ t
C_{t-1}	คือ Cell state ณ t-1
\tilde{C}_t	คือ Candidate ใหม่ ณ เวลา t
f	คือ ผลลัพธ์จากการคำนวณ Forget gate ณ เวลา t
i_t	คือ Input layer ณ เวลา t

3. Output gate

เป็นเกต (Gate) ที่ทำหน้าที่ส่งออกข้อมูล โดยขั้นตอนแรกตัดสินใจว่าค่าใดจะถูกตัดสลิบใจเป็นผลลัพธ์ หลังจากนั้นนำผลลัพธ์ไปคูณกับ Cell State ณ เวลา t โดยผ่านฟังก์ชันกระตุ้น ดังสมการที่ (2.5) และ (2.6)



ภาพที่ 2.9 โครงสร้าง Output Gate

ที่มา : Olah (2015)

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.5)$$


$$h_t = o_t * \tanh(C_t) \quad (2.6)$$

โดยที่ o_t	คือ Output gate
σ, \tanh	คือ ฟังก์ชันกระตุ้น
W_o	คือ น้ำหนัก
C_t	คือ cell state ณ t
h_{t-1}	คือ ผลลัพธ์ของ Hidden state ณ เวลา t - 1
x_t	คือ ข้อมูลนำเข้า ณ เวลา t
b_o	คือ bias

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้ในเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 โครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM

แบบจำลองโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM พัฒนามาจากแบบจำลอง CNN และ แบบจำลอง LSTM โดย CNN จะทำหน้าที่ดึง Feature ที่สำคัญจากข้อมูล โดยเฉพาะข้อมูลที่เป็นภาพหรือตาราง และ LSTM สามารถจดจำข้อมูลในอดีตและนำมาใช้วิเคราะห์ข้อมูลในปัจจุบันได้ ทำให้แบบจำลอง CNN-LSTM สามารถวิเคราะห์ข้อมูลที่มีโครงสร้างซับซ้อนและมีความสัมพันธ์เชิงลำดับได้ จากภาพที่ 2.10 เป็นโครงสร้างแบบจำลอง CNN-LSTM โดยข้อมูลจะผ่านชั้นนำเข้าผ่านชั้น CNN ดึง feature ที่สำคัญของข้อมูลนำเข้า และส่งผลลัพธ์ไปยังชั้น LSTM เพื่อพยากรณ์ข้อมูลมีลำดับ



ภาพที่ 2.10 โครงสร้างการทำงานของแบบจำลอง CNN-LSTM

ที่มา : Aksan, et al. (2023)

2.5 การเลือกคุณลักษณะ (Feature Selection)

การเลือกคุณลักษณะเป็นเทคนิคหนึ่งในการลดมิติของข้อมูล โดยการการเลือกชุดข้อมูลย่อยที่ยังเกี่ยวข้องกับข้อมูลชุดเดิมเข้าสู่แบบจำลอง ส่งผลให้เพิ่มประสิทธิภาพของแบบจำลอง การคัดเลือกคุณลักษณะมีหลายหลายวิธี (Feature Selection) แต่ในงานวิจัยนี้จะใช้วิธี Spearman Correlation

Spearman Correlation สามารถหาความสัมพันธ์ของสองตัวแปรที่ไม่เป็นเส้นตรงได้ (Nonlinear) และมีความอ่อนไหวต่อค่าผิดปกติน้อยกว่า Pearson Correlation ซึ่งค่าสหสัมพันธ์ (Correlation) จะอยู่ในช่วง -1 ถึง 1 โดยที่ค่าสหสัมพันธ์เข้าใกล้ 1 หมายความว่า ตัวแปรสองตัวมีความสัมพันธ์ไปในทิศทางเดียวกัน ค่าสหสัมพันธ์เข้าใกล้ -1 หมายความว่า ตัวแปรสองตัวมีความสัมพันธ์ไปในตรงกันข้ามกัน และค่าสหสัมพันธ์เท่ากับ 0 หมายความว่าตัวแปรสองตัวไม่มีความสัมพันธ์กัน (Bocianowski et al., 2024)

2.6 วิศวกรรมคุณลักษณะ (Feature Engineering)

กระบวนการแปลงข้อมูลดิบหรือตัวแปรนำเข้าเพื่อใช้ในการเรียนรู้ของเครื่อง (Machine Learning) ในการสร้างแบบจำลอง ซึ่งประสิทธิภาพของแบบจำลองมักขึ้นอยู่กับคุณภาพของข้อมูลที่ใช้ในการฝึกอบรม (Training Data) ในบทวิจัยนี้จะทำ Feature Engineering 2 วิธีคือ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. การปรับช่วงข้อมูล (Feature scaling) ด้วยวิธี Min-max Scaling

การปรับช่วงข้อมูลด้วยวิธี Min-max Scaling คือการปรับช่วงของข้อมูลที่กำหนดให้อยู่ระหว่างค่าต่ำสุดและค่าสูงสุด ซึ่งส่วนใหญ่มักกำหนดในช่วง $[0, 1]$ ซึ่งสามารถคำนวณได้จาก

$$x = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.7)$$

2. การเพิ่มข้อมูลย้อนหลัง

ราคาน้ำมันเป็นข้อมูลอนุกรมเวลา (Time Series Data) เนื่องจากเป็นข้อมูลที่ถูกจัดเก็บตามลำดับเวลาอย่างต่อเนื่องและมีช่วงเวลาที่แน่นอน ราคาน้ำมันมีการเปลี่ยนแปลงตามเวลา ดังนั้นจึงมีการเพิ่มข้อมูลในอดีตเพื่อมาทำนายราคาน้ำมันในอนาคต

2.7 การปรับแต่งพารามิเตอร์ (Hyperparameter Tuning)

การปรับแต่งพารามิเตอร์ (Hyperparameter Tuning) คือกระบวนการระบุและเลือกพารามิเตอร์ที่เหมาะสมที่สุดสำหรับใช้ฝึกฝนแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) การปรับแต่งพารามิเตอร์จะช่วยลดฟังก์ชันสูญเสีย (Loss Function) ส่งผลให้โมเดลมีประสิทธิภาพมากขึ้น (IBM, 2024) ซึ่งในโครงข่ายประสาทเทียม พารามิเตอร์ที่มักจะถูกปรับแต่งได้แก่ อัตราการเรียนรู้ (Learning Rate) จำนวนข้อมูลที่จะให้ Optimizer จำนวนในหนึ่งรอบ (Batch Size) จำนวนชั้นที่ถูกซ่อน (Hidden Layer) จำนวนชั้นของโหนด (Node Layers) จำนวนรอบของการฝึกข้อมูล (Epochs) และฟังก์ชันกระตุ้น (Activation Function)

วิธีการปรับแต่งพารามิเตอร์ (Hyperparameter Tuning Methods) แบ่งได้เป็น 2 แบบได้แก่

1. Grid Search เป็นวิธีการหาพารามิเตอร์ที่ครอบคลุมที่สุด โดยกำหนดค่าสำหรับการแต่งพารามิเตอร์แต่ละตัว ต่อมา Grid Search จะทำการสร้างโมเดลทุกค่าที่เป็นไปได้ของทุกพารามิเตอร์ที่กำหนด และทำการประเมินประสิทธิภาพเปรียบเทียบกัน ซึ่งการทำ Grid Search ต้องใช้เวลาและทรัพยากรการคำนวณจำนวนมาก

2. Random Search มีวิธีการทำงานคล้าย Grid Search ที่ต้องทำการสำหรับการแต่งพารามิเตอร์แต่ละตัว และสร้างโมเดล แต่ Random Search จะทำการสุ่มค่าพารามิเตอร์ตามรอบที่กำหนดไว้และทำการประเมินประสิทธิภาพเปรียบเทียบกันเพื่อหาพารามิเตอร์ที่ให้ค่าความแม่นยำดีที่สุด

งานวิจัยนี้จะทำปรับแต่งพารามิเตอร์ ด้วยวิธี Random Search เนื่องจากใช้เวลาในการประมวลผลน้อยกว่าและให้ผลลัพธ์ที่ใกล้เคียงกัน (Stuke et al., 2021) การปรับแต่งพารามิเตอร์จะกล่าวในหัวข้อ 3.5

2.8 Permutation Feature Importance

เทคนิคนี้เป็นเทคนิคในการวัดความสำคัญของแต่ละตัวแปรด้วยการคำนวณค่าความผิดพลาด (Error) ในการทำนายของแบบจำลอง หลังจากสุ่มสลับข้อมูลในตัวแปร หลังจากสลับข้อมูลแล้วค่าความผิดพลาดเพิ่มขึ้น หมายความว่าตัวแปรนั้นมีความสำคัญกับแบบจำลอง ในขณะที่เดียวกันถ้าค่า

ไม่ว่าการณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความผิดพลาดไม่เปลี่ยนแปลง หมายความว่าตัวแปรนี้ไม่มีความสำคัญกับแบบจำลอง (Christoph, 2024)

อัลกอริทึม Permutation Feature Importance มีวิธีการทำงานดังนี้

1. ประเมินค่าความผิดพลาดจากแบบจำลอง (e_{orig}) ตามสมการที่ (2.8)

$$e_{orig} = L(y, \hat{f}(X)) \quad (2.8)$$

2. สำหรับแต่ละตัวแปร $j \in \{1, \dots, p\}$;

ก. สร้างสำเนาของตัวแปร X (X_{perm}) เพื่อใช้สลับค่าของตัวแปรที่เลือกโดยการสลับ

ลำดับในตัวแปร X_j เพื่อเป็นการทำลายความสัมพันธ์ระหว่าง ตัวแปร X_j และ Y

ข. ประเมินค่าความผิดพลาดจากแบบจำลอง (e_{perm}) โดยอ้างอิงจากข้อมูลที่ถูกลับลำดับในตัวแปร X (X_{perm})

$$e_{perm} = L(Y, \hat{f}(X_{perm})) \quad (2.9)$$

ค. คำนวณ Feature Importance จากสมการ (2.10)

$$FI_j = e_{perm} - e_{orig} \quad (2.10)$$

2.9 การประเมินวัดความแม่นยำของแต่ละอัลกอริทึม (Evaluation Models)

การวัดความแม่นยำเพื่อประเมินประสิทธิภาพของแบบจำลองด้วยชุดข้อมูลทดสอบ (Test Data Set) การวิจัยนี้ใช้การเปรียบเทียบค่าต่างๆดังต่อไปนี้

1. ค่าเฉลี่ยของความผิดพลาดสมบูรณ์ (Mean Absolute Error: MAE)

ค่านี้เป็นวิธีวัดความแม่นยำโดยการพิจารณาความแตกต่างของค่าจริงและค่าพยากรณ์ โดยไม่คำนึงถึงเครื่องหมาย ตามสมการที่ (2.11) ถ้าผลลัพธ์เข้าใกล้ 0 หมายความว่า ค่าพยากรณ์ที่ได้มาจากแบบจำลองมีค่าใกล้ค่าจริง

$$MAE = \frac{\sum |A_t - F_t|}{n} \quad (2.11)$$

2. ค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error: MAPE)

วิธีวัดความแม่นยำด้วยการพิจารณาจากเปอร์เซ็นต์ความผิดพลาดในการพยากรณ์ ตามสมการที่ (2.12) ถ้าผลลัพธ์เข้าใกล้ 0 หมายความว่า ค่าพยากรณ์ที่ได้มาจากแบบจำลองมีค่าใกล้ค่าจริง

$$MAPE = \frac{\sum |(A_t - F_t) / A_t|}{n} \times 100\% \quad (2.12)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE)

วิธีนี้พิจารณาจากรากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ตามสมการที่ (2.13) ถ้าผลลัพธ์เข้าใกล้ 0 หมายความว่า ค่าพยากรณ์ที่ได้มาจากแบบจำลองมีค่าใกล้เคียงค่าจริง

$$RMSE = \sqrt{\frac{\sum (A_t - F_t)^2}{n}} \quad (2.13)$$

4. ค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of Determination: R^2)

ค่าสัมประสิทธิ์แสดงการตัดสินใจเป็นดัชนีที่บอกถึงร้อยละของการเปลี่ยนแปลงในตัวแปรตามที่มีผลมาจากตัวแปรอิสระทุกตัวตามสมการ (2.14) ถ้าผลลัพธ์เข้าใกล้ 1 หมายถึง ตัวแปรอิสระสามารถอธิบายการเปลี่ยนแปลงของตัวแปรตามได้ และถ้าผลลัพธ์เข้าใกล้ 0 หมายถึง ตัวแปรอิสระสามารถอธิบายการเปลี่ยนแปลงของตัวแปรตามได้น้อย

$$R^2 = 1 - \frac{\sum (A_t - F_t)^2}{\sum (A_t - \bar{F}_t)^2} \quad (2.14)$$

โดยที่	A_t	คือ	ค่าจริง ณ เวลา t
	F_t	คือ	ค่าพยากรณ์ ณ เวลา t
	\bar{F}_t	คือ	ค่าเฉลี่ยของค่าพยากรณ์ ณ เวลา t
	n	คือ	จำนวนข้อมูลทั้งหมด

2.10 ปัจจัยที่มีผลกระทบต่อราคาน้ำมันดิบของตลาดสหรัฐอเมริกา

จากงานวิจัยของ Miao. et al. (2017) ได้สรุปปัจจัยที่ส่งผลต่อราคาน้ำมันดิบออกเป็น 6 ปัจจัย ได้แก่ อุปทาน (Supply) อุปสงค์ (Demand) ตลาดการเงิน (Financial Market) ตลาดสินค้าโภคภัณฑ์ (Commodity Market) การเก็งกำไร (Speculative) และปัจจัยภูมิรัฐศาสตร์ (Geopolitical Factor) ตัวแปรที่เกี่ยวข้องกับอุปสงค์และอุปทาน เป็นข้อมูลรายเดือนและรายไตรมาส เช่น ปริมาณการผลิตน้ำมันดิบของโลก การส่งออกน้ำมันดิบของโลก ปริมาณน้ำมันสำรองของสหรัฐอเมริกา และผลิตภัณฑ์มวลรวมของประเทศจีน และ สหรัฐอเมริกา (Gross Domestic Product) ในส่วนตัวแปรที่เกี่ยวข้องกับการเก็งกำไร และ ปัจจัยภูมิรัฐศาสตร์ในงานวิจัยของ Miao และคณะ เช่น สัดส่วนระหว่างปริมาณการซื้อขายล่วงหน้าน้ำมันกับปริมาณการผลิตน้ำมันทั่วโลก และ จำนวนเหตุการณ์ก่อการร้ายในภูมิภาคตะวันออกกลางและแอฟริกาเหนือ เป็นข้อมูลอ้างอิงที่ไม่สามารถเข้าถึงได้ในปัจจุบัน จึงได้มีการพิจารณาดัชนีความไม่แน่นอนของราคาน้ำมัน (Oil Price Uncertainty Index) และ ดัชนีความเสี่ยงทางภูมิรัฐศาสตร์ (Geopolitical Risk Index) เป็นตัวแปรทดแทน เนื่องจากทั้งสองดัชนีสะท้อนระดับความไม่แน่นอนและความเสี่ยงที่ส่งผลกระทบต่อราคาน้ำมัน แต่ข้อมูลดังกล่าวเป็นข้อมูลรายเดือน ซึ่งไม่สอดคล้องกับงานวิจัยที่มุ่งเน้นการพยากรณ์ราคาน้ำมันดิบโดยใช้ปัจจัยที่มี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลรายวันในการพยากรณ์ซึ่งที่มีข้อมูลเป็นรายวันได้แก่ ตลาดการเงิน (Financial Market) และ ตลาดสินค้าโภคภัณฑ์ (Commodity Market)

2.10.1 ตลาดการเงิน (Financial Market)

1. หุ้น (Stocks) เป็นตลาดทุน (Capital Market) ที่ใหญ่ที่สุด เมื่อเศรษฐกิจดีขึ้น กำไรของบริษัทจะเพิ่มขึ้น ส่งผลให้ราคาหุ้นของบริษัทนั้นสูงขึ้น ตลาดหุ้นถือเป็นหนึ่งดัชนีชี้วัดประสิทธิภาพทางเศรษฐกิจของแต่ละประเทศ (Alamgir & Amin, 2021) ทำให้มีงานวิจัยใช้ดัชนีหุ้นเป็นตัวชี้วัด เช่น งานวิจัยของ Assaad and Fayek (2021) ได้ทำการพยากรณ์ราคาน้ำมันดิบตลาดสหรัฐฯ โดยใช้ข้อมูลราคาหุ้นบริษัทเทคโนโลยีของสหรัฐฯมาเป็นตัวแปรตาม โดยใช้ตัวแบบ MLP LSTM และ CNN-LSTM พบว่า ราคาหุ้นของบริษัทเทคโนโลยีชั้นนำของสหรัฐอเมริกาสามารถพยากรณ์ราคาน้ำมันดิบได้ โดย ตัวแบบพยากรณ์ LSTM ให้ค่าความแม่นยำสูงที่สุดที่ค่า MAPE 2.09% เมื่อเทียบกับตัวแบบพยากรณ์ DNN และ CNN-LSTM หรืองานวิจัยของ Akil. et al. (2024) ใช้ดัชนีหุ้น S&P 500 NASDAQ และ Dow Jones Industrial Average (DJIA) เป็นปัจจัยในการพยากรณ์ราคาน้ำมันดิบ

2. พันธบัตร (Bonds) เป็นตลาดทุนที่ใหญ่เป็นอันดับสอง เพราะเป็นการลงทุนที่มีความเสี่ยงต่ำ มีความผันผวนน้อยกว่า เมื่อนักลงทุนกังวลเกี่ยวกับผลตอบแทนในอนาคต มีแนวโน้มที่จะเปลี่ยนมาลงทุนในพันธบัตรเพิ่มขึ้น (U.S. Energy Information Administration, 2024)

3. อัตราแลกเปลี่ยน (Currency) เกณฑ์มาตรฐานน้ำมันมีราคาเป็นเงินสกุลดอลลาร์สหรัฐ การอ่อนค่าของเงินสกุลดอลลาร์สหรัฐ ทำให้ราคาน้ำมันลดลง ส่งผลให้อุปสงค์ของน้ำมันเพิ่มขึ้นในทางกลับกัน การแข็งค่าของเงินสกุลดอลลาร์สหรัฐ ทำให้ราคาน้ำมันมีราคาสูงขึ้นในมุมมองของผู้นำเข้า ส่งผลให้อุปสงค์ของน้ำมันลดลง (Ricci, 2024)

2.10.2 ตลาดสินค้าโภคภัณฑ์ (Commodity Market)

การเปลี่ยนแปลงของราคาสินค้าในตลาดโภคภัณฑ์อาจจะส่งผลต่อความผันผวนของราคาน้ำมันดิบ เช่น สินค้าโภคภัณฑ์ด้านพลังงานที่สามารถทดแทนน้ำมันดิบได้ เช่น แก๊สธรรมชาติ หรือ ถ่านหิน นอกจากนี้น้ำมันถือเป็นสินทรัพย์ที่มีความเสี่ยงสูง ซึ่งถ้าเกิดเหตุการณ์ที่ไม่แน่นอน นักลงทุนมีแนวโน้มที่จะกระจายความเสี่ยงไปยังสินทรัพย์ที่มีความปลอดภัยมากขึ้น เช่น ทองคำ

2.11 งานวิจัยที่เกี่ยวข้อง

ในอดีตการพยากรณ์หรือศึกษาตัวแปรที่ส่งผลต่อราคาน้ำมันดิบนิยมใช้แบบจำลองเศรษฐมิติ (Econometric Model) เช่น Miao. et al. (2017) ทำการศึกษาตัวแปรที่มีผลต่อราคาน้ำมันด้วยวิธีการถดถอยแลซโซ (Least Absolute Shrinkage and Selection Operator: LASSO) โดยราคาน้ำมันดิบย้อนหลัง ปริมาณการผลิตเหล็ก (World Steel Production) ดัชนี Kilian (Kilian Index) เป็นดัชนีที่วัดการเปลี่ยนแปลงความต้องการสินค้าโภคภัณฑ์ในอุตสาหกรรม ดัชนี ISM (Institute for Supply Management Index: ISM Index) เป็นดัชนีวัดกิจกรรมภาคการผลิตของสหรัฐอเมริกา ดัชนี CRB rind (CRB Raw Industrial Materials index) เป็นดัชนีที่วัดความเคลื่อนไหวของราคาสินค้าโภคภัณฑ์ ดัชนีดอลลาร์ (US dollar index) และ ปัจจัยภูมิรัฐศาสตร์ (Geopolitical Factor) เป็นปัจจัยที่มีผลต่อราคาน้ำมันดิบ ซึ่งน้ำมันดิบย้อนหลังเป็นปัจจัยที่กำหนดราคาน้ำมันดิบที่สำคัญที่สุด และ Nyangarika and Tang (2018) ทำการศึกษาตัวแปรที่มีผลต่อราคาน้ำมันด้วยวิธี ARIMA

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Autoregressive Integrated Moving Average) พบว่า ราคาทองคำ และปัจจัยภูมิรัฐศาสตร์ (Geopolitical Factor) มีผลต่อราคาน้ำมันดิบ

ต่อมาเทคโนโลยีที่พัฒนาไปอย่างรวดเร็วทำให้การเรียนรู้ของเครื่อง (Machine Learning) ถูกนำมาใช้ในการพยากรณ์ราคาน้ำมันดิบอย่างมากมาย ด้วยความสามารถของแบบจำลองที่สามารถพยากรณ์ข้อมูลที่ไม่ใช่เส้นตรงได้ดีกว่าการพยากรณ์แบบเดิม เช่น Kumar. et al. (2018) ที่ทำการพยากรณ์ราคาน้ำมันดิบรายวันและรายสัปดาห์ ด้วยวิธีการ ARIMA (Autoregressive Integrated Moving Average) BPN (Back Propagation Neural Network) และ RNN (Recurrent Neural Network) พบว่า RNN สามารถพยากรณ์ราคาน้ำมันดิบได้ดีกว่า โดยวัดจากค่า RMSE MAE MAPE ซึ่งสามารถสรุปได้ว่า โครงข่ายประสาทเทียมสามารถพยากรณ์โมเดลที่มีความสัมพันธ์ไม่เป็นเส้นตรงได้ดีกว่าการพยากรณ์แบบเดิม ซึ่งสอดคล้องกับ Zhang and Hong (2022) ได้ทำการเปรียบเทียบตัวแบบการพยากรณ์ราคาน้ำมันดิบระหว่าง ARIMA (Autoregressive Integrated Moving Average) ANN (Artificial Neural Network) และ LSTM โดยแบ่งเป็นสามช่วงเวลา คือ ระยะเวลาสั้น ระยะเวลากลาง และ ระยะเวลายาว จากผลการวิจัยพบว่า การพยากรณ์ราคาน้ำมันดิบโดยใช้แบบจำลองโครงข่ายประสาทเทียม LSTM มีประสิทธิภาพดีที่สุดทั้ง 3 ช่วงเวลาโดยวัดจากค่า MSA MAE และ SDAPE และ Aldabagh. et al. (2023) ได้เสนอการพยากรณ์ราคาน้ำมันดิบแบบผสมผสาน CNN-LSTM จากผลการวิจัยพบว่าตัวแบบผสมผสาน CNN-LSTM ให้ผลลัพธ์ที่ดีกว่าเมื่อเทียบกับ CNN และ LSTM โดยให้ค่า RMSE และ MAPE ต่ำที่สุด

งานวิจัยที่กล่าวไปข้างต้นใช้ราคาน้ำมันดิบรายวันในการพยากรณ์เพียงอย่างเดียว แต่ความผันผวนของราคาน้ำมันดิบเกิดจากความไม่สมดุลระหว่างอุปสงค์อุปทาน ทำให้มีหลายวิจัยนำปัจจัยที่เกี่ยวข้องกับอุปสงค์และอุปทานมาช่วยในการเพิ่มความแม่นยำให้กับการพยากรณ์ร่วมกับการเรียนรู้ของเครื่อง (Machine Learning) เช่น Lu. et al. (2021) ได้ทำการพยากรณ์ราคาน้ำมันดิบรายเดือนโดยใช้ตัวแปรทั้งหมด 30 ตัวที่เกี่ยวข้องกับ อุปสงค์ อุปทาน น้ำมันดิบสำรอง ตลาดการเงิน มาพยากรณ์โดยใช้ตัวแบบ LSTM, Random Walk (RW), Autoregressive Integrated Moving Average Models (ARMA), Elman Neural Networks (ENN), ELM Neural Networks (EL), Wavelet Neural Networks (WNN) และ Generalized Regression Neural Network (GRNN) จากผลการทดลองพบว่า ใช้ Bayesian Model Averaging ในการเลือกตัวแปรเข้าสู่แบบจำลองพบว่า LSTM ให้ค่าความแม่นยำที่ดีที่สุดโดยวัดจาก RMSE, MAPE และ Directional Symmetry (DS) ซึ่งตัวแปรที่เข้าสู่แบบจำลองเป็นตัวแปรที่เกี่ยวข้องกับดัชนีทางเศรษฐกิจ ดัชนีราคาผู้ผลิต (Producer Price Index: PPI), ดัชนีผู้จัดการฝ่ายจัดซื้อ (Purchasing Managers' Index: PMI) น้ำมันดิบสำรอง ดัชนีดอลลาร์ และ ราคาทองแดง นอกจากนี้งานวิจัย Aldabagh. et al. (2024) ได้ทำการเปรียบเทียบตัวแบบพยากรณ์น้ำมันดิบรายเดือนทั้งหมด 8 ตัวแบบคือ ต้นไม้ตัดสินใจ (Decision Tree) ป่าสุ่ม (Random Forests) การเพิ่มประสิทธิภาพแบบไล่ระดับ (Gradient Boosting) โครงข่ายประสาทเทียม (Neural Network) โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) LSTM Bi-LSTM และ แบบผสมผสาน CNN-LSTM โดยมีปัจจัยทางเศรษฐกิจ ได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศ (GDP) ปริมาณการบริโภคน้ำมัน (Oil Consumption) ปริมาณการผลิต (Oil Production) และ ปริมาณน้ำมันสำรอง (Oil Capacity) ผลการวิจัยพบว่า CNN-LSTM ให้ความแม่นยำดีที่สุดที่ค่า RMSE และ MAE ที่ 7.94 และ 2.23 ตามลำดับ นอกจากนี้การวิจัยนี้ยังเพิ่มตัวแปรทางการเงินคือ Dollar Index มาร่วมในการวิเคราะห์ ซึ่งพบว่า การใช้ผลต่างของ Dollar Index เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ให้ผลลัพธ์ดีกว่าไม่มีตัวแปรทางการเงิน โดยให้ค่า RMSE และ MAE ต่ำที่สุดที่ 3.93 และ 1.33 ตามลำดับ

จากข้อมูลข้างต้นการพยากรณ์ราคาน้ำมันดิบที่ใช้อุปสงค์และอุปทานส่วนใหญ่เป็นข้อมูลที่เป็นรายสัปดาห์หรือรายเดือน ซึ่งอาจจะไม่สามารถพยากรณ์ราคาน้ำมันดิบที่มีความผันผวนในระยะสั้นได้ จึงมีการนำข้อมูลในตลาดการเงิน และตลาดสินค้าโภคภัณฑ์มาพยากรณ์ราคาน้ำมันดิบ เช่น Xu. et al. (2024) ที่ได้ทำตัวแปรในตลาดการเงินรายวัน ได้แก่ ราคาสินค้าโภคภัณฑ์ อัตราแลกเปลี่ยน ดัชนีตลาดหุ้น และตัวชี้วัดเศรษฐกิจมหภาค มาเป็นตัวแปรในการพยากรณ์ราคาน้ำมันดิบ ร่วมกับแบบจำลองต่างๆ พบว่า แบบจำลอง ARIMAX ให้ประสิทธิภาพการพยากรณ์ดีที่สุด เมื่อเทียบกับ MLP GRU และ LSTM ที่ MAE เท่ากับ 2.8713 MAPE เท่ากับ 4.9104 RMSE 4.6516 และ R^2 เท่ากับ 0.9282 นอกจากนี้งานวิจัยนี้ ทำการทดลองแบบจำลองแบบผสมผสาน ระหว่าง CNN และ GRU MLP LSTM พบว่า แบบผสมผสาน CNN-LSTM ให้ประสิทธิภาพการพยากรณ์ดีที่สุด ที่ MAE เท่ากับ 2.5216 MAPE เท่ากับ 4.6329 RMSE เท่ากับ 4.1746 และ R^2 เท่ากับ 0.9508 นอกจากนี้แบบจำลองนี้ยังเสนอการคัดเลือกคุณลักษณะ 5 แบบ เพื่อทำนายร่วมกับ แบบจำลองต่างๆ พบว่าการคัดเลือกคุณลักษณะแบบ Pearson Correlation รวมกับ แบบจำลอง MLP สามารถเพิ่มประสิทธิภาพของแบบจำลองได้ โดยที่วัดจากค่าความคลาดเคลื่อนที่ MAE เท่ากับ 1.8187 MAPE เท่ากับ 3.4199 RMSE เท่ากับ 2.9424 และ R^2 เท่ากับ 0.9708 ตัวแปรที่ถูกคัดเลือกด้วยวิธี Pearson Correlation ได้แก่ ราคาน้ำมันย่อนหลัง 1 วัน ราคาเงิน อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ อัตราแลกเปลี่ยนหยวนต่อดอลลาร์สหรัฐดัชนีดอลลาร์ ราคาทองคำ และอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐ 10 ปี

ตารางที่ 2.1 สรุปข้อมูลวิจัยใช้อ้างอิง

ผู้วิจัย	แบบจำลอง	ความถี่	ตัวแปร					
			ราคาสินค้าโภคภัณฑ์	ดัชนีหุ้นจากตลาดหลักทรัพย์	อัตราแลกเปลี่ยน	ดัชนีมหภาค	อื่น	
							อุปทาน	อุปสงค์
Jesus. et al. (2020)	Dynamic ordinary least squares (DOLS)	รายวัน	ราคาน้ำมันดิบ	ดัชนีหุ้นจากตลาดหลักทรัพย์เยอรมัน (DAX) ดัชนีหุ้นจากตลาดหลักทรัพย์ซาอุดีอาระเบีย (TASI) ดัชนีหุ้นจากตลาดหลักทรัพย์บราซิล (IBOVESPA) ดัชนีหุ้นจากตลาดหลักทรัพย์แคนาดา (S&P/TSX) ดัชนีหุ้นจากตลาดหลักทรัพย์จีน (Shanghai Composite) ดัชนีหุ้นจากตลาดหลักทรัพย์เกาหลีใต้ (KOSPI) ดัชนีหุ้นจากตลาดหลักทรัพย์อเมริกา (S&P 500) ดัชนีหุ้นจากตลาดหลักทรัพย์ฝรั่งเศส (CAC 40) ดัชนีหุ้นจากตลาดหลักทรัพย์อินเดีย (SENSEX (India) ดัชนีหุ้นจากตลาดหลักทรัพย์ญี่ปุ่น (NIKKEI) ดัชนีหุ้นจากตลาดหลักทรัพย์นอร์เวย์ (OSEAX) ดัชนีหุ้นจากตลาดหลักทรัพย์รัสเซีย (MICEX)	-	-	-	-

ตารางที่ 2.1 สรุปข้อมูลวิจัยใช้อ้างอิง (ต่อ)

ผู้วิจัย	แบบจำลอง	ความถี่	ตัวแปร					
			ราคาสินค้า โภคภัณฑ์	ดัชนีหุ้นจาก ตลาด หลักทรัพย์	อัตรา แลกเปลี่ยน	ดัชนี ภูมิภาค	อื่น	
							อุปทาน	อุปสงค์
Lu. et al. (2021)	Random walk, ARMA, MLP, RBFNN, GRNN, Elman, WNN, LSTM	รายเดือน	ราคาน้ำมันดิบ ราคาแก๊ส ธรรมชาติ ราคาทองคำ ราคาทองแดง	S&P 500 Dow Jones Industrial Index NASDAQ index	อัตรา แลกเปลี่ยน ปอนด์สเตอร์ลิง ต่อดอลลาร์ สหรัฐ	-	ปริมาณการผลิตน้ำมัน ทั่วโลก ปริมาณการผลิตน้ำมัน ของกลุ่มประเทศโอเปก และนอกกลุ่มประเทศ โอเปก ปริมาณน้ำมันดิบสำรอง	CPI PPI PMI ปริมาณการนำเข้า น้ำมันดิบของเมืองจีน ปริมาณการบริโภค น้ำมันกลุ่มประเทศ OECD
Zhang & Hong, (2022)	ARIMA, ANN, LSTM	รายวัน	ราคาน้ำมันดิบ	-	-	-	-	-
Aldabagh. et al. (2023)	ARIMA, SVM, CNN, LSTM, CNN-LSTM	รายวัน	ราคาน้ำมัน	-	-	-	-	-

หมายเหตุ : ตัวหนา คือแบบจำลองและตัวแปรที่ใช้ในงานวิจัย

ตารางที่ 2.1 สรุปข้อมูลวิจัยใช้อ้างอิง (ต่อ)

ผู้วิจัย	แบบจำลอง	ความถี่	ตัวแปร					
			ราคาสินค้า โภคภัณฑ์	ดัชนีหุ้นจาก ตลาด หลักทรัพย์	อัตรา แลกเปลี่ยน	ดัชนี นิมิต	อื่น	อุปสงค์
Aldabagh. et al. (2024)	Decision Tree, Random Forests, Gradient Boosting, Neural Networks, CNN, LSTM, Bi-LSTM, CNN-LSTM	รายเดือน	ราคา น้ำมันดิบ	-	-	ดัชนี ดอลลาร์	ปริมาณการผลิตน้ำมัน นอกกลุ่มโอเปก ปริมาณการผลิตน้ำมัน ของประเทศซาอุดีอารา เบีย และ WTI กำลังการผลิตสำรอง ของโอเปก	ปริมาณการบริโภค น้ำมันทั่วโลก ปริมาณการบริโภค น้ำมันกลุ่มประเทศ OECD และนอกกลุ่ม ประเทศ OECD ผลิตภัณฑ์มวลรวม ภายในประเทศโลก และนอกกลุ่ม ประเทศ OECD (GDP)

หมายเหตุ : ตัวหนา คือ แบบจำลองและตัวแปรที่ใช้ในงานวิจัย

ตารางที่ 2.1 สรุปข้อมูลวิจัยใช้อ้างอิง (ต่อ)

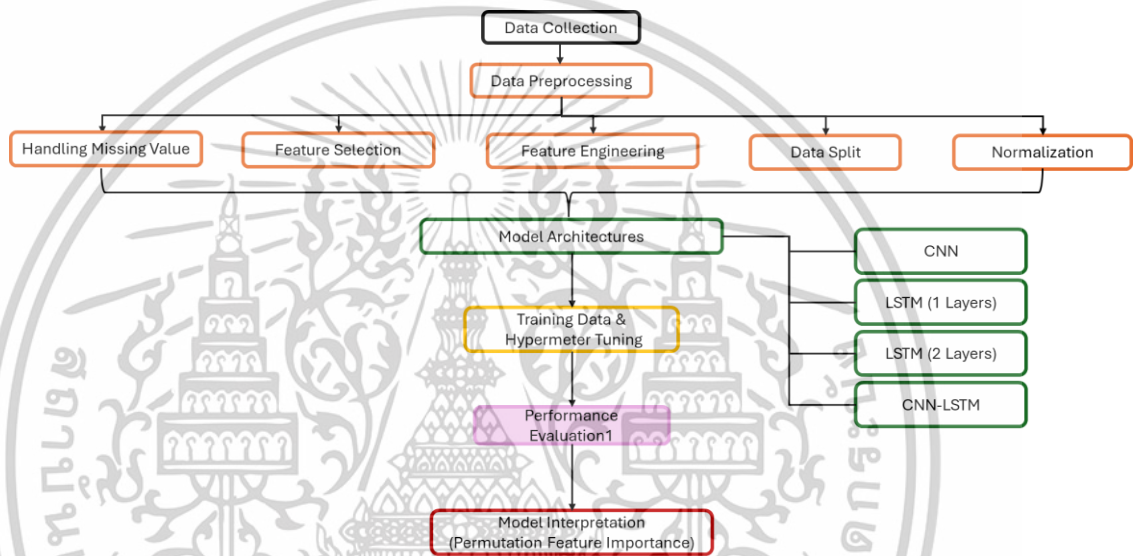
ผู้วิจัย	แบบจำลอง	ความถี่	ตัวแปร					
			ราคาสินค้าโภคภัณฑ์	ดัชนีหุ้นจากตลาดหลักทรัพย์	อัตราแลกเปลี่ยน	ดัชนีมหภาค	อื่น	
							อุปทาน	อุปสงค์
Akil. et al. (2024)	LSTM-TCN	รายวัน รายเดือน	ราคาน้ำมันดิบ	S&P 500 NASDAQ DJIA	-	ดัชนีดอลลาร์ ตัวเงินคลังสหรัฐอายุ 3 เดือน 1 ปี และ 10 ปี ดอกเบี้ยในตลาดเงินสหรัฐ อัตราเงินเฟ้อ	-	ดัชนีราคาสินค้า โภคภัณฑ์ ดัชนีความไม่ แน่นอนทาง เศรษฐกิจ ปริมาณการบริโภค น้ำมัน
Xu. et al. (2024)	ARIMAX MLP LSTM GRU CNN-CNN CNN-GRU CNN-MLP CNN- LSTM	รายวัน	ราคา น้ำมันดิบ ราคาทองคำ ราคาแก๊ส ธรรมชาติ ราคาเงิน	S&P 500 DJIA	อัตราแลกเปลี่ยนปอนด์ สเตอร์ลิงต่อดอลลาร์สหรัฐ อัตราแลกเปลี่ยนยูโร ต่อดอลลาร์สหรัฐ อัตราแลกเปลี่ยนดอลลาร์ สหรัฐต่อหยวน	ดัชนีดอลลาร์ อัตราผลตอบแทน พันธบัตรรัฐบาลสหรัฐ 10 ปี	-	-

หมายเหตุ : ตัวหนา คือแบบจำลองและตัวแปรที่ใช้ในงานวิจัย

บทที่ 3

วิธีดำเนินงานวิจัย

การวิจัยนี้จัดทำขึ้นเพื่อเปรียบเทียบแบบจำลองที่เหมาะสมต่อการพยากรณ์ราคาน้ำมันดิบระยะสั้น โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN) แบบจำลอง LSTM และ แบบจำลองแบบผสม CNN-LSTM รวมถึงหาราคาย้อนหลังที่เหมาะสมที่สามารถเพิ่มประสิทธิภาพของการพยากรณ์ นอกจากนี้ยังทำการทดลองลดตัวแปรเข้าสู่แบบจำลอง โดยพิจารณาจากค่าสหสัมพันธ์ (Correlation) เพื่อพิสูจน์ว่าการลดตัวแปรสามารถเพิ่มประสิทธิภาพของการพยากรณ์



ภาพที่ 3.1 วิธีดำเนินงานวิจัย

3.1 การเก็บรวบรวมข้อมูล (Data Collection)

ข้อมูลที่ใช้ในการศึกษาครั้งนี้มาจากเว็บไซต์ (Website) investing.com ที่รวบรวมราคาปิดของราคาสินค้าโภคภัณฑ์ (Commodities) ดัชนีหุ้นจากตลาดหลักทรัพย์ (Stocks) อัตราแลกเปลี่ยน (Exchange Rate) และดัชนีมหภาค (Macroeconomics) ตั้งแต่วันที่ 2 มกราคม ค.ศ. 2018 ถึง 31 ธันวาคม ค.ศ. 2024 ทั้งหมด 29 ตัวแปร ดังที่แสดงไว้ในตารางที่ 3.1 ผู้วิจัยทำการรวมตัวแปรทั้งหมดด้วยโปรแกรม Excel โดยใช้วันที่จากการเปิดทำการของตลาดน้ำมันสหรัฐอเมริกา (West Texas Intermediate: WTI)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 ตัวแปรสำหรับการศึกษา จำนวน 29 ตัวแปร

กลุ่มของตัวแปร	ตัวแปร	สัญลักษณ์
1. ราคาสินค้าโภคภัณฑ์ (Commodities)	ราคาน้ำมันดิบตลาดสหรัฐ (WTI Crude Oil)	WTI
	ราคาทองคำ (Gold Spot US Dollar)	Gold
	ราคาแก๊สธรรมชาติ (Natural Gas)	NG
	ราคาเงิน (Silver)	SV
	ราคากถ่านหิน (Newcastle Coal)	Coal
2. ดัชนีหุ้นจากตลาดหลักทรัพย์ (Stocks)	ดัชนีหุ้นจากตลาดหลักทรัพย์บราซิล (Bovespa: IBOV)	IBOV
	ดัชนีหุ้นจากตลาดหลักทรัพย์แคนาดา (S&P/TSX Composite: GSPTSE)	GSPTSE
	ดัชนีหุ้นจากตลาดหลักทรัพย์อเมริกา (S&P 500: SPX)	SPX
	ดัชนีหุ้นจากตลาดหลักทรัพย์ฝรั่งเศส (CAC 40: FCHI)	FCHI
	ดัชนีหุ้นจากตลาดหลักทรัพย์นอร์เวย์ (OSE Benchmark: OSEBX)	OSEBX
	ดัชนีหุ้นจากตลาดหลักทรัพย์รัสเซีย (MOEX Russia Index: IMOEX)	IMOEX
	ดัชนีหุ้นจากตลาดหลักทรัพย์เยอรมัน (DAX: GDAXI)	DAX
	ดัชนีหุ้นจากตลาดหลักทรัพย์เกาหลีใต้ (KOSPI: KS11)	KS11
	ดัชนีหุ้นจากตลาดหลักทรัพย์ญี่ปุ่น (Nikkei 225: N225)	N225
	ดัชนีหุ้นจากตลาดหลักทรัพย์ฮาวไคอาระเบีย (TASI)	TASI
	ดัชนีหุ้นจากตลาดหลักทรัพย์อินเดีย (BSE Sensex 30)	BSESN
	ดัชนีหุ้นจากตลาดหลักทรัพย์จีน (Shanghai Composite)	SSEC
3. อัตราแลกเปลี่ยน (Exchange rate)	อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ	EUR-USD
	อัตราแลกเปลี่ยนหยวนต่อดอลลาร์สหรัฐ	CNY-USD
	อัตราแลกเปลี่ยนรูปีต่อดอลลาร์สหรัฐ	INR-USD
	อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐ	JPY-USD
	อัตราแลกเปลี่ยนปอนด์สเตอร์ลิงต่อดอลลาร์สหรัฐ	GBP-USD
	อัตราแลกเปลี่ยนโครนนอร์เวย์ต่อดอลลาร์สหรัฐ	NOK-USD
	อัตราแลกเปลี่ยนโครนเดนมาร์กต่อดอลลาร์สหรัฐ	DKK-USD
	อัตราแลกเปลี่ยนเปโซเม็กซิกันต่อดอลลาร์สหรัฐ	MXN-USD
	อัตราแลกเปลี่ยนรูเบิลรัสเซียต่อดอลลาร์สหรัฐ	RUB-USD
	อัตราแลกเปลี่ยนโครนาสวีเดนต่อดอลลาร์สหรัฐ	SEK-USD
4. ดัชนีมหภาค (Macroeconomics)	ดัชนีดอลลาร์ (US dollar Index)	DXY
	อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐ 10 ปี (US 10Year Bond Yield)	US10B

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้เพื่อการศึกษานี้เท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 การเตรียมข้อมูล (Data Preparation)

3.2.1 การตรวจสอบข้อมูลที่ขาดหายไป (Missing Value)

DayOfweek	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday
WTI	0.0	0.0	0.0	0.0	0.0	NaN	0.0
Gold	0.0	0.0	1.0	0.0	0.0	NaN	356.0
NG	1.0	0.0	1.0	1.0	0.0	NaN	327.0
SV	0.0	0.0	1.0	1.0	0.0	NaN	347.0
Coal	4.0	0.0	1.0	0.0	0.0	NaN	356.0
IBOV	18.0	19.0	10.0	15.0	12.0	NaN	356.0
GSPTSE	46.0	3.0	3.0	3.0	1.0	NaN	356.0
SPX	36.0	1.0	4.0	9.0	1.0	NaN	356.0
FCHI	11.0	2.0	4.0	2.0	1.0	NaN	356.0
OSEBX	48.0	36.0	34.0	45.0	32.0	NaN	356.0
IMOEX	22.0	15.0	15.0	11.0	12.0	NaN	356.0
DAX	17.0	6.0	5.0	5.0	2.0	NaN	356.0
KS11	28.0	17.0	22.0	15.0	16.0	NaN	356.0
N225	50.0	16.0	14.0	17.0	16.0	NaN	356.0
TASI	16.0	15.0	16.0	17.0	354.0	NaN	16.0
BSESN	20.0	19.0	19.0	17.0	15.0	NaN	355.0
SSEC	33.0	22.0	20.0	21.0	28.0	NaN	356.0
EUR/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
CNY/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
INR/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
JPY/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
GBP/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
NOK/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
DKK/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
MXN/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
RUB/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
SEK/USD	0.0	0.0	0.0	0.0	0.0	NaN	356.0
US dollar index	4.0	0.0	0.0	0.0	0.0	NaN	353.0
US 10Y Bond Yield	2.0	0.0	1.0	1.0	2.0	NaN	351.0


ภาพที่ 3.2 ข้อมูลสูญหายเนื่องจากวันทำการแตกต่างกัน

จากการสำรวจข้อมูลที่มีข้อมูลเริ่มต้น 1,805 วัน 29 ตัวแปร พบว่าตัวแปรอื่นๆ นอกจากราคาน้ำมันดิบตลาดสหรัฐอเมริกา (WTI Crude Oil) มีข้อมูลสูญหาย เนื่องจากตลาดการซื้อขายน้ำมันดิบ WTI เปิดทำการวันอาทิตย์ และข้อมูลที่ทำการรวบรวมมา มาจากหลายประเทศที่มีวันทำการรวมถึงวันหยุดที่แตกต่างกัน จากภาพที่ 3.2 พบว่า ข้อมูลที่สูญหายเป็นข้อมูลของวันอาทิตย์ที่ตลาดน้ำมันดิบ WTI เปิดทำการมากกว่า 300 วัน ในงานวิจัยนี้จึงจะขอลบข้อมูลวันอาทิตย์ออกจากชุดข้อมูล

เมื่อลบข้อมูลวันอาทิตย์พบว่ามีตัวแปร 4 ตัวที่มีข้อมูลสูญหายมากกว่า 100 วัน 4 ตัวแปร คือ ดัชนีหุ้นจากตลาดหลักทรัพย์ซาอุดีอาระเบีย (TASI) ดัชนีหุ้นจากตลาดหลักทรัพย์นอร์เวย์ (OSE Benchmark: OSEBX) ดัชนีหุ้นจากตลาดหลักทรัพย์จีน (Shanghai Composite: SSEC) และดัชนีหุ้นจากตลาดหลักทรัพย์ญี่ปุ่น (Nikkei 225: N225) เนื่องจากวันหยุดที่แตกต่างกัน เช่น ตลาดไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลักทรัพย์ชาวดีอาราเบียดทำการวันศุกร์ ตามภาพที่ 3.3 ซึ่งข้อมูลของ TASI และ OSBEX มีข้อมูลสูญหาย 418 และ 195 วัน ตามลำดับ เพื่อรักษาปริมาณข้อมูลงานวิจัยนี้จะทำการตัดตัวแปร TASI และ OSBEX ออกจากชุดข้อมูล ข้อมูลสูญหายของ SSEC และ N225 มีจำนวน 124 และ 113 วัน ซึ่งเมื่อพิจารณาจากค่าสหสัมพันธ์ พบว่า N225 มีค่าสหสัมพันธ์กับราคาน้ำมันดิบที่ 0.60 ในขณะที่ SSEC มีค่าสหสัมพันธ์อยู่ที่ 0.19 งานวิจัยนี้จึงขอลบตัวแปร SSEC ออกจากชุดข้อมูล ทำให้เหลือข้อมูลทั้งสิ้น 1,805 วัน 26 ตัวแปร

หลังจากทำการลบตัวแปรที่มีข้อมูลสูญหายออกจากชุดข้อมูล พบว่ายังมีข้อมูลสูญหายอยู่ เพื่อรักษาปริมาณข้อมูล งานวิจัยนี้จึงขอทำการจัดการข้อมูลที่สูญหายด้วยการแทนที่ข้อมูลวันทำการก่อนหน้า ทำให้เหลือจำนวนตัวแปรอิสระทั้งสิ้น 26 ตัวแปร 1,805 วัน เพื่อเข้าสู่กระบวนการต่อไป

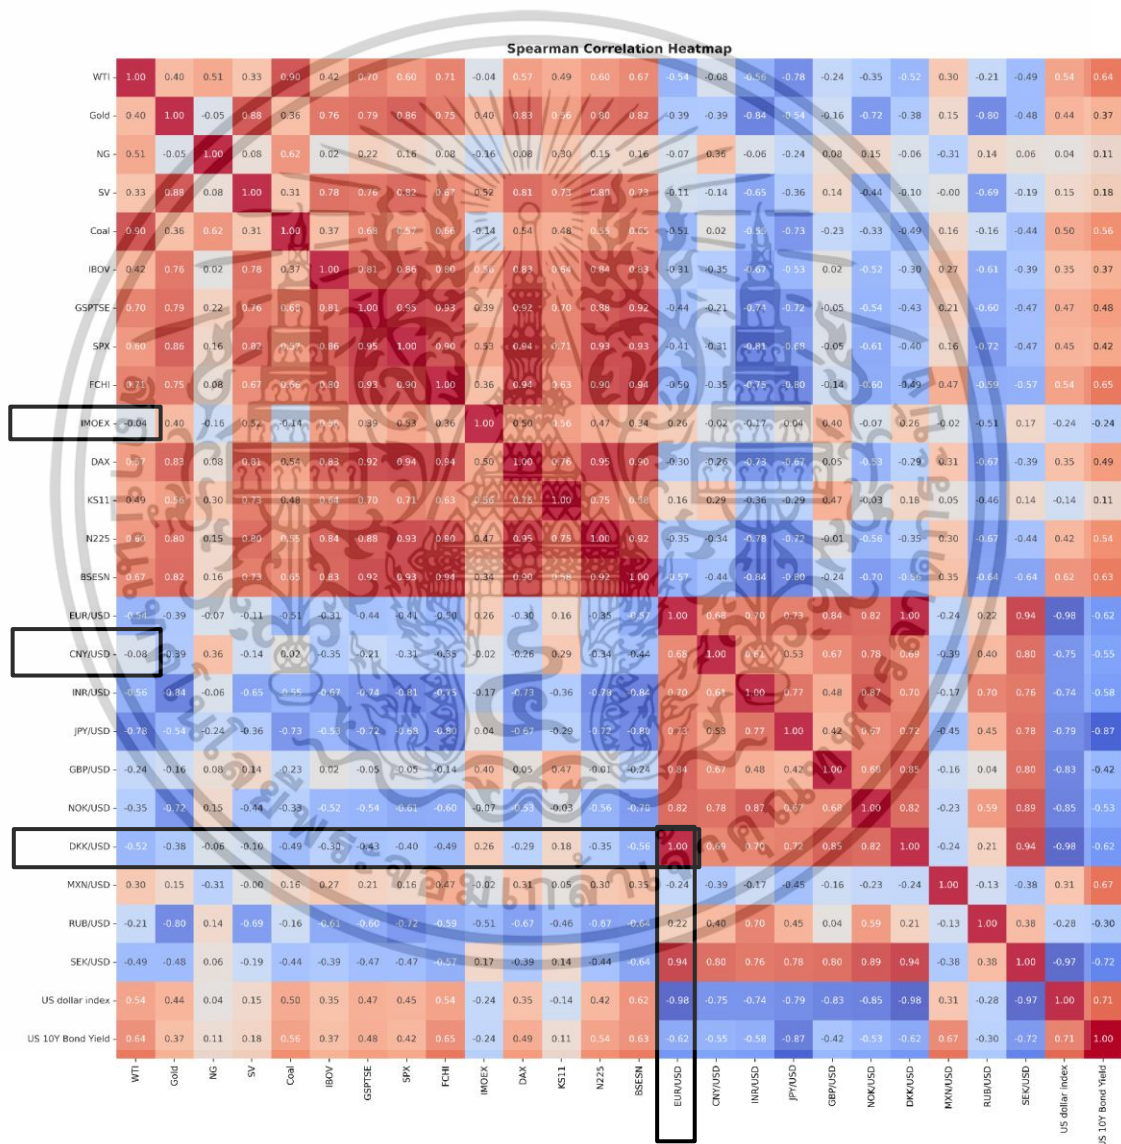


ภาพที่ 3.3 ข้อมูลสูญหายหลังจากลบข้อมูลวันอาทิตย์ออกจากชุดข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.2 การคัดเลือกคุณลักษณะ (Feature Selection)

หลังจากทำการทำความสะอาดข้อมูล จะนำตัวแปรทั้งหมด 26 ตัว เข้าสู่กระบวนการหาค่าความสัมพันธ์ (Correlation) ระหว่างราคาน้ำมันดิบตลาดสหรัฐ (WTI) กับตัวแปรอื่นๆ ด้วยวิธี Spearman จากภาพที่ 3.4 พบว่า ตัวแปรทุกตัวมีความสัมพันธ์กับราคาน้ำมัน โดยราคาสินค้าโภคภัณฑ์ ดัชนีหุ้นจากตลาดหลักทรัพย์ และ ดัชนีมหภาค มีความสัมพันธ์ในทิศทางเดียวกัน ยกเว้น ดัชนีหุ้นตลาดหลักทรัพย์รัสเซีย (MOEX Russia Index: IMOEX) อัตราแลกเปลี่ยนความสัมพันธ์ในทิศทางตรงกันข้าม ยกเว้น อัตราแลกเปลี่ยนเปโซเม็กซิกันต่อดอลลาร์สหรัฐ (MXN-USD) ที่มีความสัมพันธ์ในทิศทางเดียวกับราคาน้ำมันดิบ



ภาพที่ 3.4 ค่าสหสัมพันธ์ของข้อมูล (Correlation)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อพิจารณาค่าสหสัมพันธ์ (Correlation) ระหว่างราคาน้ำมันดิบตลาดสหรัฐ (WTI) กับตัวแปรอื่นๆ พบว่า ดัชนีหุ้นจากตลาดหลักทรัพย์รัสเซีย (MOEX Russia Index: IMOEX) และ อัตราแลกเปลี่ยนหยวนต่อดอลลาร์สหรัฐ (CNY-USD) มีค่าสหสัมพันธ์ -0.04 และ -0.08 ตามลำดับ ซึ่งมีค่าสหสัมพันธ์กับราคาน้ำมันไม่สูงมาก การศึกษาครั้งนี้จึงจะลบ 2 ตัวแปรนี้ออกจากชุดข้อมูล

เมื่อพิจารณาค่าสหสัมพันธ์ระหว่างตัวแปรอื่นๆ พบว่า อัตราแลกเปลี่ยนโครนเดนมาร์กต่อดอลลาร์สหรัฐ (DKK-USD) และ อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ (EUR-USD) มีความสัมพันธ์กันสูง โดยที่มีค่าสหสัมพันธ์ 1 จากการศึกษาศาลม. et al. (2024) พบว่าอัตราแลกเปลี่ยนยูโร (EUR) มีผลต่อราคาน้ำมันมากกว่าโครนเดนมาร์ก (DKK) เพื่อป้องกันการเกิด Multicollinearity ระหว่างตัวแปร การศึกษาครั้งนี้จะลบอัตราแลกเปลี่ยนโครนเดนมาร์กต่อดอลลาร์สหรัฐ (DKK-USD) ออกจากชุดข้อมูล ทำให้เหลือข้อมูลทั้งสิ้น 1,805 ข้อมูล 23 ตัวแปรเข้าสู่กระบวนการต่อไป

นอกจากนี้งานวิจัยนี้ทำการเปรียบเทียบระหว่างนำตัวแปรทั้งหมด 23 ตัวแปรเข้าสู่แบบจำลองกับคัดเลือกตัวแปรที่เหมาะสม โดยใช้ค่าสหสัมพันธ์ที่ ± 0.4 เพื่อทดสอบว่าการลดขนาดมิติของข้อมูลช่วยเพิ่มประสิทธิภาพของแบบจำลองได้

3.2.3 วิศวกรรมคุณลักษณะ (Feature Engineering)

1. การเพิ่มข้อมูลย้อนหลัง

เนื่องจากการพยากรณ์ราคาน้ำมันเป็นข้อมูลแบบอนุกรมเวลา ราคาน้ำมันปัจจุบันและราคาน้ำมันในอดีตมีความสัมพันธ์กัน จึงมีงานวิจัยที่ใช้ราคาน้ำมันย้อนหลังเป็นตัวแปรในแบบจำลอง เช่น งานวิจัยของ Akil. et al. (2024) ใช้ข้อมูลย้อนหลัง 3 วันของราคาน้ำมันดิบ และตัวแปรเศรษฐกิจอื่นๆเข้าสู่แบบจำลองเพื่อให้แบบจำลองรับรู้รูปแบบและแนวโน้มระยะสั้น และ งานวิจัยของ Sen. et al. (2024) โดยใช้ราคาน้ำมันดิบย้อนหลัง 3 วัน 4 วัน และ 5 วัน พยากรณ์ราคาน้ำมันดิบ เนื่องจากนักธุรกิจ (Trader) ที่สนใจทำการซื้อขายน้ำมันเป็นรายสัปดาห์ ผลวิจัยพบว่าราคาน้ำมันย้อนหลัง 4 วันให้ผลการพยากรณ์ที่ดีที่สุด งานวิจัยนี้ต้องการศึกษาข้อมูลย้อนหลังที่เหมาะสมสำหรับการพยากรณ์ราคาน้ำมันดิบระยะสั้น โดยจะทำการใช้ข้อมูลย้อนหลัง 3 วัน 4 วัน 5 วัน และ 30 วัน เพื่อที่จะนำเข้าสู่แบบจำลองในขั้นตอนถัดไป

2. ปรับช่วงขอบเขตของข้อมูล (Feature Scaling)

ช่วงของข้อมูลมีค่าที่แตกต่างกัน เนื่องจากหน่วยการวัดที่แตกต่างกันจึงแก้ปัญหาด้วยเทคนิค Normalization ที่จะทำให้ช่วงข้อมูลอยู่ระหว่าง 0 ถึง 1 ด้วยวิธี Min-Max Scalar

3.2.4 การแบ่งชุดข้อมูล (Data Split)

ในการศึกษาครั้งนี้แบ่งข้อมูลทั้งหมด 1,805 วันเป็น 3 เป็นชุดข้อมูล Train, Validation และ Test ตามช่วงเวลาต่อไปนี้

1. ชุดข้อมูลฝึกสอน (Training Data Set) เป็นข้อมูลตั้งแต่ 2 มกราคม ค.ศ. 2018 ถึง 31 ธันวาคม ค.ศ. 2022 มีจำนวนทั้งหมด 1,290 วัน
2. ชุดข้อมูลตรวจสอบ (Validation Data Set) เป็นข้อมูลตั้งแต่ 1 มกราคม ค.ศ. 2023 ถึง 31 ธันวาคม ค.ศ. 2023 มีจำนวนทั้งหมด 259 วัน
3. ชุดข้อมูลทดสอบ (Test Data Set) เป็นข้อมูลตั้งแต่ 1 มกราคม ค.ศ. 2024 ถึง 31 ธันวาคม ค.ศ. 2024 มีจำนวนทั้งหมด 256 วัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3 การออกแบบโครงข่ายประสาทเทียม

งานวิจัยนี้ได้เสนอการใช้โครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM ในการพยากรณ์ราคาน้ำมันดิบตลาดน้ำมันสหรัฐอเมริกาในวันถัดไป ซึ่งแบบจำลองคอนโวลูชัน (Convolution Neural Network: CNN) มีประสิทธิภาพในการคัดเลือกแบบจำลองในข้อมูลอนุกรมเวลา ในขณะที่แบบจำลอง Long Short-Term Memory (LSTM) มีความสามารถในการจัดลำดับความสัมพันธ์ของตัวแปร (Aldabagh et al., 2023)


ในขั้นตอนแรกของการพัฒนาแบบจำลอง ผู้วิจัยได้นำวิธีการออกแบบโครงข่ายประสาทเทียมอ้างอิงจาก Livieris. et al. (2020) ที่ทำการเปรียบเทียบเทียบการพยากรณ์ราคาทองคำรายวันด้วยวิธี Support Vector Regression (SVR) LSTM และแบบผสมผสาน CNN-LSTM พบว่า การพยากรณ์ราคาทองคำด้วยวิธีแบบผสมผสาน CNN-LSTM ให้ค่าความแม่นยำดีที่สุด โดยมี CNN Filter Unit 2 Layers LSTM Unit 1 Layer และมี Hyperparameter ดังต่อไปนี้

1. CNN Filter Unit1 คือ 64
2. CNN Filter Unit2 คือ 128
3. LSTM Unit คือ 200
4. Optimizer คือ Adam
5. Batch Size คือ 128

ในงานวิจัยนี้จึงทำการออกแบบโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM อ้างอิงจาก Livieris. et al. โดยมี CNN Filter Unit 2 Layers และ LSTM Unit 1 Layer และได้ทำการออกแบบโครงข่ายประสาทเทียมของแบบจำลอง CNN และ LSTM ดังต่อไปนี้

1. แบบจำลอง CNN

แบบจำลองนี้ได้ออกแบบ แบบจำลอง CNN ทั้งหมด 8 เลเยอร์ (Layers) โดยประกอบด้วย ชั้นนำเข้า (Input Layer) ชั้นคอนโวลูชัน (Convolution Layers) 2 เลเยอร์ ชั้นพูลลิง 2 เลเยอร์ Flatten 1 เลเยอร์ Dense หรือ ชั้นซ่อน (Hidden Layer) หรือ Fully Connected Layer 1 เลเยอร์ และชั้นนำออก (Output Layer)

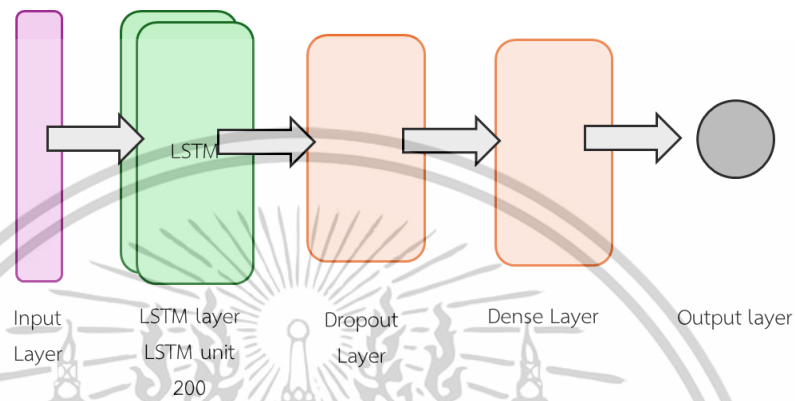


ภาพที่ 3.5 การออกแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. แบบจำลอง LSTM (1)

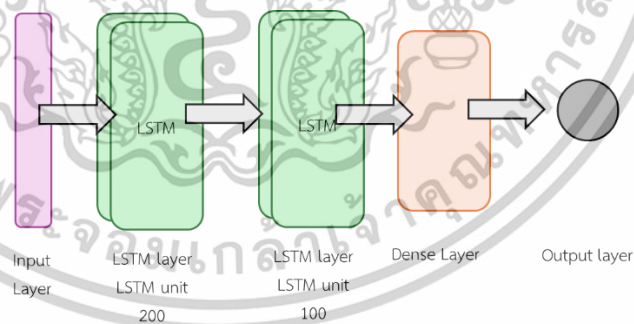
แบบจำลองนี้ได้ออกแบบ แบบจำลอง LSTM (1) ทั้งหมด 5 เลเยอร์ (Layers) โดยประกอบด้วย ชั้นนำเข้า (Input Layer) LSTM (LSTM Layers) 1 เลเยอร์ Dropout 1 เลเยอร์ Dense หรือ ชั้นซ่อน (Hidden Layer) หรือ Fully Connected Layer 1 เลเยอร์ และ ชั้นนำออก (Output Layer)



ภาพที่ 3.6 การออกแบบโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (1)

3. แบบจำลอง LSTM (2)

แบบจำลองนี้ได้ออกแบบ แบบจำลอง LSTM ทั้งหมด 5 เลเยอร์ (Layers) โดยประกอบด้วย ชั้นนำเข้า (Input Layer) LSTM (LSTM Layers) 2 เลเยอร์ Dense Layers หรือ ชั้นซ่อน (Hidden Layer) หรือ Fully Connected Layer 1 เลเยอร์ และชั้นนำออก (Output Layer)




ภาพที่ 3.7 การออกแบบโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (2)

4. แบบจำลอง CNN-LSTM

แบบจำลองนี้ได้ออกแบบ แบบจำลอง CNN-LSTM ทั้งหมด 9 เลเยอร์ (Layers) โดยประกอบด้วย ชั้นนำเข้า (Input Layer) ชั้นคอนโวลูชัน (Convolution Layers) 2 เลเยอร์ ชั้นพูลลิง (Pooling Layer) 1 เลเยอร์ Flatten 1 เลเยอร์ LSTM (LSTM Layers) 1 เลเยอร์ Dropout 1 เลเยอร์ Dense หรือ ชั้นซ่อน (Hidden Layer) หรือ Fully Connected Layer 1 เลเยอร์ และ ชั้นนำออก (Output Layer)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลนำเข้าทั้งหมดจะส่งต่อไปขึ้น CNN เพื่อเรียนรู้และแบ่งความสำคัญของตัวแปร ก่อนส่งไปยังชั้น LSTM เพื่อเรียนรู้ความสัมพันธ์ของตัวแปรต่างๆ และข้อมูลทั้งหมดจะถูกประมวลผลในชั้น Dense และ ส่งต่อไปชั้นสุดท้าย คือ Dropout เพื่อลดปัญหา Overfitting ก่อนจะนำข้อมูลออกเป็นชั้นข้อมูลนำออก (Output Layer)



ภาพที่ 3.8 การออกแบบโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM

3.4 Hyperparameter Tuning


วิจัยนี้นำข้อมูลชุดฝึกสอนมาหาชุดแบบจำลองทั้ง 4 แบบ โดยมีการกำหนดค่าพารามิเตอร์ของ Batch size, Epoch, Optimizer และ Activation function ไว้คงที่ เนื่องจากข้อจำกัดด้านทรัพยากรการประมวลผล โดยก่อนที่จะกำหนดค่าพารามิเตอร์คงที่ได้ทำการทดลองโดยวัดจากความผิดพลาดของชุดข้อมูลตรวจสอบที่ต่ำที่สุดตามภาคผนวก ก.

ตารางที่ 3.2 Hyperparameter Tuning ที่ใช้ในแบบจำลอง A B C และ D

Hyperparameter	ค่าที่ใช้ในแต่ละ Parameter
Epoch	100
Batch Size	16
Max Pooling	1
Learning Rate	[0.001, 0.01, 0.1]
CNN Filter Unit	[32, 64, 128]
LSTM Unit	[50, 100, 200]
Dense Unit	[16, 32, 64]
Dropout	[0.1, 0.2, 0.3]
Activation Function	Tahn
Optimizer	Adam

จากนั้นนำข้อมูลชุดฝึกฝนทำ Hyperparameter Tuning โดยพารามิเตอร์ที่ต้องปรับได้แก่ Learning Rate, CNN Filter Unit, LSTM Unit, Dense unit และ Dropout ด้วยวิธี Random Search โดยจะทำการสุ่มค่า Hyperparameter 100 ครั้ง และแบ่งข้อมูลด้วยวิธี TimeSeriesSplit เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยจะแบ่งข้อมูลเป็น 3 ชุดฝึกสอน และ 3 ชุดตรวจสอบ ในแต่ละรอบของการแบ่งข้อมูล ขนาดของข้อมูลฝึกสอนจะเพิ่มขึ้น ในขณะที่ขนาดของข้อมูลตรวจสอบจะคงที่ โดยจะเลือกค่าพารามิเตอร์ที่ให้ผลลัพธ์เฉลี่ยที่ดีที่สุดเพื่อใช้ในการฝึกแบบจำลองกับข้อมูลทดสอบ Hyperparameter ของงานวิจัยนี้ ดังตารางที่ 3.2



ภาพที่ 3.9 การแบ่งข้อมูลด้วยวิธี TimeSeriesSplit

3.5 เครื่องมือที่ใช้วัดประสิทธิภาพแบบจำลอง

งานวิจัยนี้ใช้ วิธีค่าเฉลี่ยของความผิดพลาดสมบูรณ์ (Mean Absolute Error: MAE) วิธีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error: MAPE) และรากกำลังสองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE) เพื่อทดสอบประสิทธิภาพของข้อมูลที่พยากรณ์ ซึ่งถ้าผลลัพธ์ออกมาเข้าใกล้ 0 หมายความว่าค่าพยากรณ์มีค่าใกล้เคียงกับค่าจริง

นอกจากนี้ยังประเมินผลการอธิบายของตัวแปรอิสระกับตัวแปรตาม จาก ค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of Determination: R^2) ผลลัพธ์เข้าใกล้ 1 หมายความว่าตัวแปรอิสระสามารถอธิบายการเปลี่ยนแปลงของตัวแปรตามได้

3.6 Feature Importance

วิจัยนี้ได้ใช้เทคนิคที่เรียกว่า Permutation Feature Importance (PFI) ซึ่งเป็นเทคนิคที่ใช้วัดความสำคัญของแต่ละตัวแปร โดยสังเกตการลดลงของประสิทธิภาพของโมเดลเมื่อค่าของแปรนั้นมีการสับเปลี่ยนแบบสุ่ม (Akil et al., 2024) ด้วยการใช้ Library ใน Permutation_importance ใน Sklearn โดยมีขั้นตอนดังต่อไปนี้

1. คำนวนประสิทธิภาพของแบบจำลอง A B C D ด้วยชุดข้อมูลทดสอบ (Test Data Set) ทดสอบด้วยค่า ค่าเฉลี่ยของกำลังสองของความผิดพลาด (Mean Squared Error: MSE) เพื่อนำเป็น Baseline Score

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. สร้างสำเนาของตัวแปรทั้งหมด 23 ตัวของชุดทดสอบเพื่อนำมาใช้สุ่มเปลี่ยนค่าตัวแปร ซึ่ง จะทำการสุ่มเปลี่ยนข้อมูลแต่ละตัว แล้วแทนตัวแปรที่สุ่มกลับเข้าสู่แบบจำลอง

3. ทำการคำนวณประสิทธิภาพของแบบจำลองหลังจากสุ่มเปลี่ยนค่าตัวแปร โดยในวิจัยนี้จะทำ การสุ่มทั้งหมด 100 รอบ เพื่อนำไปเปรียบเทียบกับ Baseline Score ถ้า Importance Score ที่ คำนวณมีค่าเป็น 0 แปลว่าการสุ่มเปลี่ยนค่าของตัวแปรมีความสำคัญน้อย หรือไม่มีความสำคัญกับ แบบจำลอง

```
[ ] from sklearn.inspection import permutation_importance

def calculate_permutation_importance(model, X_test, y_test, features, n=60):
    importance_scores = {}
    baseline_score = model.evaluate(X_test, y_test, verbose=0)[0]

    for feature_index, feature in enumerate(features): # Iterate using feature index
        X_test_permuted = X_test.copy()
        sum_score = 0

        for i in range(n):
            permuted_values = np.random.permutation(X_test_permuted[:, feature_index, :])
            X_test_permuted[:, feature_index, :] = permuted_values
            permuted_score = model.evaluate(X_test_permuted, y_test, verbose=0)[0]
            sum_score += permuted_score

        importance_score = baseline_score - (sum_score / n)
        importance_scores[feature] = importance_score

    return importance_scores
```

ภาพที่ 3.10 ตัวอย่าง python code ของการทำ Feature Importance ด้วยวิธี Permutation Feature Importance (PFI)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


บทที่ 4

ผลการวิจัยและการอภิปรายผล

บทนี้จะกล่าวถึงผลการทดลองแบ่งเป็น 3 ส่วนคือ การเปรียบเทียบความสามารถในการพยากรณ์ราคาน้ำมันดิบด้วย 3 แบบจำลองคือ CNN LSTM และ CNN-LSTM การกำหนดช่วงเวลาที่ใช้ในการพยากรณ์ราคาน้ำมันดิบ และการเปรียบเทียบว่าเกณฑ์ในการลดมิติของข้อมูลด้วยค่าสหสัมพันธ์ โดยทดสอบประสิทธิภาพของแบบจำลองด้วยวิธีค่าเฉลี่ยของความผิดพลาดสมบูรณ์ (Mean Absolute Error: MAE) วิธีค่าเฉลี่ยของกำลังสองของความผิดพลาด (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error: RMSE)

4.1 การวิเคราะห์ข้อมูลเบื้องต้น

จากข้อมูลราคาน้ำมันดิบสหรัฐฯรายวันตั้งแต่วันที่ 2 มกราคม ค.ศ. 2018 - 31 ธันวาคม ค.ศ. 2024 ดังภาพที่ 4.1 จะเห็นว่าราคาน้ำมันดิบสหรัฐฯมีความผันผวนสูง ซึ่งเหตุการณ์ที่ทำให้ราคาน้ำมันมีความผันผวน ดังรายละเอียดต่อไปนี้



ภาพที่ 4.1 ราคาน้ำมันดิบสหรัฐฯในช่วง ค.ศ. 2018-2024

1. ในช่วงปลายปี 2018 ถึง ต้นปี 2019 ราคาน้ำมันดิบตลาดสหรัฐฯ (WTI Crude Oil) มีความผันผวนสูง เนื่องจากการเพิ่มขึ้นของอุปทาน การเพิ่มปริมาณการผลิตของสหรัฐอเมริกา รัสเซีย และซาอุดีอาระเบีย รวมถึงการผ่อนคลายมาตรการลงโทษทางเศรษฐกิจ (U.S Sanction) ให้กับอิหร่าน ส่งผลให้ อิหร่านสามารถส่งออกน้ำมันได้มากขึ้น ประกอบกับการลดลงของอุปสงค์ จากการชะลอการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เติบโตของเศรษฐกิจ และ สงครามการค้าระหว่างจีนและสหรัฐ (US-China Trade tension) ที่เริ่มต้นขึ้นประมาณช่วงกลางปี ค.ศ. 2018 (U.S. Energy Information Administration (EIA), 2019)

2. ในช่วงปี ค.ศ. 2020 ถึง ค.ศ. 2022 เป็นช่วงที่ตลาดน้ำมันได้รับผลกระทบการลดลงของอุปสงค์เนื่องจากโรคระบาดโคโรนาไวรัสที่ทำให้ให้การเดินทางหยุดชะงัก ประกอบกับผู้ส่งออกน้ำมันรายใหญ่ เช่น ซาอุดีอาระเบีย และรัสเซียปฏิเสธการลดกำลังการผลิตให้สอดคล้องกับความต้องการที่ลดลง ทำให้ราคาน้ำมันลดลงอย่างรวดเร็วในช่วงต้นปี ค.ศ. 2020 (Ma et al., 2021) ต่อมากลุ่ม OPEC ได้ตกลงลดปริมาณการผลิตลงเพื่อให้สอดคล้องกับอุปสงค์ที่ลดลงทำให้ราคาน้ำมันค่อยปรับตัวขึ้น (U.S. Energy Information Administration (EIA), 2020) รวมถึงสถานการณ์โรคระบาดมีการปรับตัวดีขึ้น ทำให้ราคาน้ำมันมีการปรับตัวสูงขึ้น ต่อมาในช่วงต้นปี ค.ศ. 2022 ได้เกิดเหตุการณ์ภูมิรัฐศาสตร์ระหว่างรัสเซียและยูเครน ทำให้ราคาน้ำมันเพิ่มสูงขึ้น (RiEnergia, 2023)

3. ในช่วงปี ค.ศ. 2023 ราคาน้ำมันยังมีความผันผวนต่อเนื่องทั้งจากความกังวลเรื่องเศรษฐกิจถดถอย (Recession) เหตุการณ์ภูมิรัฐศาสตร์ระหว่างรัสเซียและยูเครนที่ยังคงต่อเนื่อง และการไม่เพิ่มปริมาณการผลิตของกลุ่มโอเปก ในช่วงปลายเดือนกันยายน จะเห็นว่าราคาน้ำมันเพิ่มขึ้นสูงสุดเนื่องจากเหตุการณ์ภูมิรัฐศาสตร์ระหว่างอิสราเอลและฮามัส (Israel-Hamas Conflict) ที่ทะเลแดงทำให้เรือขนส่งสินค้าต้องเปลี่ยนเส้นทางไปทางแอฟริกา ทำให้เพิ่มอุปสงค์ของน้ำมัน (U.S. Energy Information Administration (EIA), 2024)

จากข้อสรุปข้างต้นจะพบว่าความผันผวนของราคาน้ำมันในช่วง 2018-2024 มาจากหลายปัจจัยทั้ง โรคระบาด การชะลอตัวของเศรษฐกิจ เหตุการณ์ภูมิรัฐศาสตร์ และนโยบายการผลิตน้ำมันของกลุ่มโอเปกและรัสเซีย

4.2 ผลการวิจัยการเปรียบเทียบการพยากรณ์ราคาน้ำมันดิบที่ใช้เวลาย้อนหลังแตกต่างกัน

ในงานวิจัยนี้ได้มีการออกแบบ แบบจำลองโครงข่ายประสาทเทียม ทั้งหมด 4 แบบ คือ โครงข่ายประสาทเทียมคอนโวลูชัน (Convolution : CNN) โครงข่ายประสาทเทียม LSTM ที่มี LSTM Unit 1 เลเยอร์ และ 2 เลเยอร์ และโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM ร่วมกับตัวแปรอิสระ 23 ตัว ที่กำหนดเวลาย้อนหลัง 3 วัน 4 วัน 5 วัน และ 30 วัน นำเสนอผลการทดสอบประสิทธิภาพการพยากรณ์จากข้อมูลชุดข้อมูลตรวจสอบ (Validation Data) และชุดทดสอบ (Test Data)

4.2.1 แบบจำลอง CNN

จากแบบจำลองที่ผ่านการปรับพารามิเตอร์ ให้ค่า Hyperparameter ที่เหมาะสม ดังตารางที่ 4.1 และแสดงผลการเปรียบเทียบประสิทธิภาพ ดังตารางที่ 4.2 พบว่า เวลาของตัวแปรอิสระย้อนหลัง 3 วัน ให้ประสิทธิภาพการทดลองดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1709 1.5645 1.4847 และ 0.9242 ตามลำดับ เวลาของตัวแปรอิสระย้อนหลัง 5 วัน ให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.3941 1.8411 1.7137 และ 0.9001 ตามลำดับ เวลาของตัวแปรอิสระย้อนหลัง 4 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.4053 1.8811 1.7069 และ 0.8996 ตามลำดับ เวลาของตัวแปรอิสระย้อนหลัง 30 วัน มีประสิทธิภาพในการพยากรณ์น้อย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 2.2528 2.9890 2.7865 และ 0.7548 ตามลำดับ

ตารางที่ 4.1 ค่า Hyperparameter ของแบบจำลอง CNN ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
Filter Unit1	128	64	64	32
Filter Unit2	32	32	64	64
Learning Rate	0.001	0.001	0.001	0.001
Dense Unit	32	32	64	32

ตารางที่ 4.2 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.0704	1.4540	1.3851	0.9133	1.1709	1.5645	1.4847	0.9242
4	1.1575	1.5532	1.4677	0.9029	1.4053	1.8811	1.7069	0.9001
5	1.1080	1.4904	1.4276	0.9083	1.3941	1.8411	1.7137	0.8996
30	1.8933	2.5952	2.3758	0.7677	2.2528	2.9890	2.7865	0.7548

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

4.2.2 แบบจำลอง LSTM (1)

ตารางที่ 4.3 ค่า Hyperparameter ของแบบจำลอง LSTM (1) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
LSTM Unit	100	200	200	100
Dropout Rate	0.1	0.1	0.1	0.3
Learning Rate	0.001	0.001	0.001	0.001
Dense Unit	16	64	16	16

จากแบบจำลองที่ผ่านการปรับพารามิเตอร์ ให้ค่า Hyperparameter ที่เหมาะสม ดังตารางที่ 4.3 และแสดงผลการเปรียบเทียบประสิทธิภาพ ดังตารางที่ 4.4 พบว่า เวลาของตัวแปรอิสระย้อนหลัง 5 วัน ให้ประสิทธิภาพการทดลองดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1948 1.5809

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปเผยแพร่บนสื่อออนไลน์โดยไม่ผ่านการอนุมัติจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.4926 และ 0.9239 ตามลำดับ เวลาย้อนหลัง 30 วันให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.4030 1.8687 1.7886 และ 0.8990 ตามลำดับ เวลาย้อนหลัง 4 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.4659 1.9537 1.8359 และ 0.8844 ตามลำดับ เวลาย้อนหลัง 3 วันมีประสิทธิภาพในการพยากรณ์น้อยที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.5482 2.0428 1.8815 และ 0.8783 ตามลำดับ

ตารางที่ 4.4 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.3696	1.8588	1.7506	0.8615	1.5482	2.0428	1.8815	0.8783
4	1.3635	1.8530	1.7354	0.8642	1.4659	1.9537	1.8359	0.8844
5	1.0776	1.4648	1.3989	0.9120	1.1948	1.5809	1.4926	0.9239
30	1.2695	1.7342	1.6541	0.8874	1.4030	1.8678	1.7886	0.8990

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

4.2.3 แบบจำลอง LSTM (2)

ตารางที่ 4.5 ค่า Hyperparameter ของแบบจำลอง LSTM (2) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
LSTM Unit 1	200	50	100	50
LSTM Unit 2	200	200	200	100
Dropout Rate	0.3	0.3	0.1	0.2
Learning Rate	0.001	0.01	0.01	0.001
Dense Unit	64	64	64	16

จากแบบจำลองที่ผ่านการปรับพารามิเตอร์ ให้ค่า Hyperparameter ที่เหมาะสม ดังตารางที่ 4.5 และแสดงผลการเปรียบเทียบประสิทธิภาพ ดังตารางที่ 4.6 พบว่า เวลาของตัวแปรอิสระย้อนหลัง 3 วัน ให้ประสิทธิภาพการทดลองดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.2771 1.6934 1.5951 และ 0.9125 ตามลำดับ เวลาย้อนหลัง 4 วันให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.2795 1.6967 1.6132 และ 0.9107 ตามลำดับ เวลาย้อนหลัง 5 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.3069

1.7489 1.6482 และ 0.9071 ตามลำดับ เวลาย้อนหลัง 30 วันมีประสิทธิภาพในการพยากรณ์น้อย
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 2.1696 2.9294 2.6268 และ 0.7821 ตามลำดับ

ตารางที่ 4.6 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (2) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.0789	1.4502	1.4095	0.9102	1.2771	1.6934	1.5951	0.9125
4	1.1710	1.5854	1.5203	0.8958	1.2795	1.6967	1.6132	0.9107
5	1.0841	1.4658	1.4235	0.9089	1.3069	1.7489	1.6482	0.9071
30	1.5352	2.0689	1.9509	0.8434	2.1696	2.9294	2.6268	0.7821

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

4.2.4 แบบจำลอง CNN-LSTM

ตารางที่ 4.7 ค่า Hyperparameter ของแบบจำลอง CNN-LSTM ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
Filter Unit1	128	32	64	32
Filter Unit2	128	128	32	64
LSTM Unit	200	200	200	200
Dropout Rate	0.3	0.2	0.1	0.1
Learning Rate	0.001	0.001	0.001	0.001
Dense Unit	32	64	64	32

ตารางที่ 4.8 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-LSTM ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	0.9709	1.3129	1.2613	0.9281	1.0473	1.3962	1.3422	0.9381
4	1.0143	1.3658	1.3109	0.9225	1.0864	1.4371	1.3568	0.9369
5	1.173	1.5905	1.5105	0.8974	1.3275	1.7410	1.6390	0.9082
30	1.0867	1.4724	1.4059	0.9187	1.1411	1.5167	1.4640	0.9323

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากแบบจำลองที่ผ่านการปรับพารามิเตอร์ ให้ค่า Hyperparameter ที่เหมาะสม ดังตารางที่ 4.7 และแสดงผลการเปรียบเทียบประสิทธิภาพ ดังตารางที่ 4.8 พบว่า เวลาของตัวแปรอิสระย้อนหลัง 3 วัน ให้ประสิทธิภาพการทดลองดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0473 1.3962 1.3422 และ 0.9381 ตามลำดับ เวลาที่ย้อนหลัง 4 วัน ให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0864 1.4371 1.3568 และ 0.9369 ตามลำดับ เวลาที่ย้อนหลัง 30 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1411 1.5167 1.4640 และ 0.9323 ตามลำดับ เวลาที่ย้อนหลัง 5 วัน มีประสิทธิภาพในการพยากรณ์น้อยที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.3275 1.7410 1.6390 และ 0.9082 ตามลำดับ

จากผลการทดลองในหัวข้อที่ 4.2.1 – 4.2.4 พบว่า แบบจำลองแบบผสมผสาน CNN-LSTM ร่วมกับเวลาที่ย้อนหลัง 3 วัน ให้ค่าความแม่นยำที่ดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0473 1.3962 1.3422 และ 0.9381 ตามลำดับ โดยมีพารามิเตอร์ดังต่อไปนี้

1. CNN Filter Unit ชั้นแรก เท่ากับ 128
2. CNN Filter Unit ชั้นที่สอง เท่ากับ 128
3. LSTM Unit เท่ากับ 200
4. Dropout Rate เท่ากับ 0.3
5. Learning Rate เท่ากับ 0.001
6. Dense Unit เท่ากับ 32

ตารางที่ 4.9 เปรียบเทียบผลการทดลองของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM โดยวัดจากค่า MAE

อันดับ	แบบจำลอง			
	CNN	LSTM (1)	LSTM (2)	CNN-LSTM
1	3 (1.1709)	5 (1.1948)	3 (1.2771)	3 (1.0473)
2	5 (1.3941)	30 (1.4030)	4 (1.2795)	4 (1.0864)
3	4 (1.4053)	4 (1.4659)	5 (1.3069)	30 (1.1411)
4	30 (2.2528)	3 (1.5482)	30 (2.1696)	5 (1.3275)

หมายเหตุ ตัวเลขนอกวงเล็บคือเวลาที่ย้อนหลัง และตัวเลขในวงเล็บคือค่า MAE

4.3 ผลการวิจัยการเปรียบเทียบการพยากรณ์ราคาน้ำมันดิบที่ทำการลดขนาดมิติของข้อมูลด้วยค่าสหสัมพันธ์ ± 0.4 ที่เวลาที่ย้อนหลังแตกต่างกัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในงานวิจัยนี้ได้มีการทดลองคัดเลือกตัวแปรด้วยค่าสหสัมพันธ์ที่ ± 0.4 เพื่อทดสอบว่าการลดขนาดมิติของข้อมูลช่วยเพิ่มความแม่นยำในการพยากรณ์ ตัวแปรที่ค่าสหสัมพันธ์ ± 0.4 มีทั้งหมด 17 ตัวแปร ได้แก่

1. ราคาสินค้าโภคภัณฑ์ (Commodities) 3 ตัวแปร ได้แก่ ราคาน้ำมันดิบตลาดสหรัฐ (WTI Crude Oil) ราคาแก๊สธรรมชาติ (Natural Gas) และ ราคาถ่านหิน (Newcastle Coal)

2. ดัชนีหุ้นจากตลาดหลักทรัพย์ (Stocks) 8 ตัวแปร ได้แก่ ดัชนีหุ้นจากตลาดหลักทรัพย์บราซิล (Bovespa: IBOV) ดัชนีหุ้นจากตลาดหลักทรัพย์แคนาดา (S&P/TSX Composite: GSPTSE) ดัชนีหุ้นจากตลาดหลักทรัพย์อเมริกา (S&P 500: SPX) ดัชนีหุ้นจากตลาดหลักทรัพย์ฝรั่งเศส (CAC 40: FCHI) ดัชนีหุ้นจากตลาดหลักทรัพย์เยอรมัน (DAX: GDAXI) ดัชนีหุ้นจากตลาดหลักทรัพย์เกาหลีใต้ (KOSPI: KS11) ดัชนีหุ้นจากตลาดหลักทรัพย์ญี่ปุ่น (Nikkei 225: N225) และ ดัชนีหุ้นจากตลาดหลักทรัพย์อินเดีย (BSE Sensex 30: BSESN)

3. อัตราแลกเปลี่ยน (Exchange Rate) 4 ตัวแปร ได้แก่ อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ (EUR-USD) อัตราแลกเปลี่ยนรูปีต่อดอลลาร์สหรัฐ (INR-USD) อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐ (JPY-USD) และ อัตราแลกเปลี่ยนโครนาสวีเดนต่อดอลลาร์สหรัฐ (SEK-USD)

4. ดัชนีมหภาค (Macroeconomics) 2 ตัวแปร ได้แก่ ดัชนีดอลลาร์ (US dollar Index) และ อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐ 10 ปี (US 10Year Bond Yield)

4.3.1 แบบจำลอง CNN

เมื่อเปรียบเทียบการกำหนดตัวแปรอิสระเป็นเวลา ย้อนหลัง 3, 4, 5 และ 30 วัน พบว่า เวลา ย้อนหลัง 3 วัน ในชุดข้อมูลตรวจสอบ (Validation Data) ให้ประสิทธิภาพการทดลองที่ดีที่สุด ในขณะที่ชุดทดสอบ (Test Data) เวลา ย้อนหลัง 4 วัน ให้ประสิทธิภาพการทดลองที่ดีที่สุด ซึ่งในงานวิจัยนี้ จะพิจารณาเวลา ย้อนหลังที่เหมาะสมจากชุดข้อมูลตรวจสอบ (Validation Data) เนื่องจากเป็นชุด ข้อมูลที่ใช้ในการทำ Hyperparameter Tuning เพื่อให้แบบจำลองมีประสิทธิภาพดีที่สุด

ตารางที่ 4.10 ค่า Hyperparameter ของแบบจำลอง CNN ใช้เวลา ย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลา ย้อนหลัง (วัน)			
	3	4	5	30
Filter Unit1	128	64	128	32
Filter Unit2	128	64	32	32
Learning Rate	0.001	0.001	0.001	0.001
Dense Unit	32	16	64	32

จากตารางที่ 4.11 พบว่า ในชุดตรวจสอบเวลา ย้อนหลัง 3 วัน ให้ประสิทธิภาพการทดลองที่ดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0112 1.3619 1.2954 และ 0.9242 ตามลำดับ เวลา ย้อนหลัง 5 วัน ให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0495 1.4194 1.3208 และ 0.9215 ตามลำดับ เวลา ย้อนหลัง 4 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดย

ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0840 1.4598 1.3838 และ 0.9137 ตามลำดับ เวลา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปเผยแพร่โดยไม่ได้รับอนุญาตถือว่าผิดกฎหมาย

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ย้อนหลัง 30 วันมีประสิทธิภาพในการพยากรณ์น้อยที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 2.3338 3.2079 2.8898 และ 0.6563 ตามลำดับ

ตารางที่ 4.11 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.0112	1.3619	1.2954	0.9242	1.2830	1.6821	1.6100	0.9109
4	1.0840	1.4598	1.3838	0.9137	1.2657	1.6671	1.5629	0.9162
5	1.0495	1.4194	1.3208	0.9215	1.3181	1.7311	1.6168	0.9106
30	2.3338	3.2079	2.8898	0.6563	1.8989	2.4856	2.3962	0.8187

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

4.3.2 แบบจำลอง LSTM (1)

ตารางที่ 4.12 ค่า Hyperparameter ของแบบจำลอง LSTM (1) ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
LSTM Unit	200	200	100	200
Dropout Rate	0.1	0.3	0.3	0.2
Learning Rate	0.001	0.001	0.001	0.001
Dense Unit	64	16	16	64

ตารางที่ 4.13 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.0999	1.4945	1.4208	0.9088	1.1973	1.5963	1.5140	0.9212
4	1.1845	1.5995	1.5278	0.8948	1.3442	1.7771	1.6404	0.9077
5	1.0315	1.3925	1.3379	0.9195	1.2175	1.6147	1.5132	0.9217
30	1.0845	1.4660	1.3955	0.9199	1.2930	1.7250	1.6439	0.9147

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

เมื่อเปรียบเทียบการกำหนดตัวแปรอิสระเป็นเวลาย้อนหลัง 3, 4, 5 และ 30 วัน พบว่า เวลา
ย้อนหลัง 5 วัน ในชุดข้อมูลตรวจสอบ (Validation Data) ให้ประสิทธิภาพการทดลองดีที่สุด ในขณะที่
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่ในชุดทดสอบ (Test Data) เวลาย้อนหลัง 3 วันให้ประสิทธิภาพการทดลองที่ดีที่สุด ซึ่งในงานวิจัยนี้จะพิจารณาเวลาย้อนหลังที่เหมาะสมจากชุดข้อมูลตรวจสอบ (Validation Data) เนื่องจากเป็นชุดข้อมูลที่ใช้ในการทำ Hyperparameter Tuning เพื่อให้แบบจำลองมีประสิทธิภาพดีที่สุด

จากตารางที่ 4.13 พบว่า ในชุดตรวจสอบเวลาย้อนหลัง 5 วันให้ประสิทธิภาพการทดลองที่ดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0315 1.3925 1.3375 และ 0.9195 ตามลำดับ เวลาย้อนหลัง 30 วันให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0845 1.4660 1.3955 และ 0.9199 ตามลำดับ เวลาย้อนหลัง 3 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.0999 1.4945 1.4208 และ 0.9088 ตามลำดับ เวลาย้อนหลัง 4 วันมีประสิทธิภาพในการพยากรณ์น้อยที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1845 1.5995 1.5278 และ 0.8948 ตามลำดับ

4.3.3 แบบจำลอง LSTM (2)

จากแบบจำลองที่ผ่านการปรับพารามิเตอร์ ให้ค่า Hyperparameter ที่เหมาะสม ดังตารางที่ 4.14 และแสดงผลการเปรียบเทียบประสิทธิภาพ ดังตารางที่ 4.15 พบว่าเวลาย้อนหลัง 3 วัน ให้ประสิทธิภาพการทดลองดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1799 1.5600 1.4739 และ 0.9253 ราคาย้อนหลัง 5 วันให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1967 1.5943 1.5017 และ 0.9229 ราคาย้อนหลัง 4 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.2604 1.6716 1.5683 และ 0.9156 และ ราคาย้อนหลัง 30 วันมีประสิทธิภาพในการพยากรณ์น้อยที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.6989 2.3239 2.2073 และ 0.85 ตามลำดับ

ตารางที่ 4.14 ค่า Hyperparameter ของแบบจำลอง LSTM (2) ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
LSTM Unit 1	100	100	50	100
LSTM Unit 2	200	200	100	200
Dropout Rate	0.1	0.3	0.3	0.2
Learning Rate	0.01	0.01	0.01	0.001
Dense Unit	32	16	64	64

ตารางที่ 4.15 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (2) ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.0253	1.3852	1.3308	0.9200	1.1799	1.5600	1.4739	0.9253

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4	1.0523	1.4149	1.3752	0.9148	1.2604	1.6716	1.5683	0.9156
5	1.0523	1.4169	1.3732	0.9152	1.1967	1.5943	1.5017	0.9229
30	1.3126	1.7708	1.6606	0.8865	1.6989	2.3239	2.2073	0.8461

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

4.3.4 แบบจำลอง CNN-LSTM

จากตารางที่ 4.17 พบว่า ราคาย้อนหลัง 5 วัน ให้ประสิทธิภาพการทดลองดีที่สุด โดยค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1186 1.4864 1.4051 และ 0.9325 ราคาย้อนหลัง 4 วัน ให้ประสิทธิภาพรองลงมาที่ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.1959 1.6007 1.5147 และ 0.9213 ราคาย้อนหลัง 3 วัน ให้ประสิทธิภาพการพยากรณ์เป็นอันดับ 3 โดยค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.2739 1.6882 1.5610 และ 0.9162 และ ราคาย้อนหลัง 30 วัน มีประสิทธิภาพในการพยากรณ์น้อยที่สุดเมื่อเทียบราคาย้อนหลังอื่น โดยที่ค่า ค่า MAE MAPE RMSE และ R^2 เท่ากับ 1.3917 1.8356 1.6935 และ 0.9094 ตามลำดับ

ตารางที่ 4.16 ค่า Hyperparameter ของแบบจำลอง CNN-LSTM ที่ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

Parameter	เวลาย้อนหลัง (วัน)			
	3	4	5	30
Filter Unit1	128	128	32	128
Filter Unit2	64	128	128	128
LSTM Unit	50	200	200	200
Dropout Rate	0.3	0.3	0.2	0.2
Learning Rate	0.001	0.001	0.001	0.001
Dense Unit	32	32	16	32

ตารางที่ 4.17 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN-LSTM ใช้เวลาย้อนหลัง 3, 4, 5 และ 30 วัน

เวลา ย้อนหลัง	Validation Data				Test Data			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
3	1.0521	1.4259	1.3604	0.9164	1.2739	1.6882	1.5610	0.9162
4	1.0356	1.3988	1.3133	0.9223	1.1959	1.6007	1.5147	0.9213
5	1.0076	1.3615	1.2835	0.9259	1.1186	1.4864	1.4051	0.9325
30	1.1083	1.5126	1.4357	0.9152	1.3917	1.8356	1.6935	0.9094

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดลองในหัวข้อที่ 4.3.1 – 4.3.4 พบว่า แบบจำลองแบบผสมผสาน CNN-LSTM ร่วมกับเวลาย้อนหลัง 5 วัน ให้ค่าความแม่นยำที่ดีที่สุด โดยค่า MAE MAPE RMSE และ R2 ของชุดข้อมูลทดสอบ เท่ากับ 1.1186 1.4864 1.4051 และ 0.9325 ตามลำดับ โดยมีพารามิเตอร์ดังต่อไปนี้

1. CNN Filter Unit ชั้นแรก เท่ากับ 32
2. CNN Filter Unit ชั้นที่สอง เท่ากับ 128
3. LSTM Unit เท่ากับ 200
4. Dropout Rate เท่ากับ 0.2
5. Learning Rate เท่ากับ 0.001
6. Dense Unit เท่ากับ 16

ตารางที่ 4.18 เปรียบเทียบผลการทดลองของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM ด้วยข้อมูลชุดทดสอบที่ทำการลดขนาดมิติของข้อมูลด้วยค่าสหสัมพันธ์ โดยวัดจากค่า MAE

อันดับ	แบบจำลอง			
	CNN	LSTM (1)	LSTM (2)	CNN-LSTM
1	4 (1.2657)	3 (1.1973)	3 (1.1799)	5 (1.1186)
2	3 (1.2830)	5 (1.2175)	5 (1.1967)	4 (1.1959)
3	5 (1.3181)	30 (1.2930)	4 (1.2604)	3 (1.2739)
4	30 (1.8989)	4 (1.3442)	30 (1.6989)	30 (1.3917)

หมายเหตุ ตัวเลขนอกวงเล็บคือเวลาย้อนหลัง และตัวเลขในวงเล็บคือค่า MAE ของชุดข้อมูลตรวจสอบ

4.4 สรุปผลการเปรียบเทียบประสิทธิภาพแบบจำลอง

จากหัวข้อที่ 4.2 และ 4.3 เป็นการทดลองหาแบบจำลองที่เหมาะสมกับการพยากรณ์ราคาน้ำมันดิบระยะสั้น โดยใช้เวลาย้อนหลังที่แตกต่างกัน และจำนวนตัวแปรอิสระที่แตกต่างกัน ในหัวข้อนี้จะทำการสรุปผลการทดลอง ดังต่อไปนี้

1. แบบจำลองที่มี 23 ตัวแปร และ 17 ตัวแปร

งานวิจัยนี้ทำการทดสอบการลดขนาดมิติข้อมูลด้วยค่าสหสัมพันธ์ที่ ± 0.4 ทำให้เหลือตัวแปรอิสระเข้าสู่แบบจำลองทั้งหมด 17 ตัวแปร จากตัวแปรอิสระทั้งหมด 23 ตัวแปร แสดงผลดังตารางที่ 4.19

เมื่อเปรียบเทียบค่าเฉลี่ยของค่า MAE ของทุกแบบจำลองแยกตามจำนวนตัวแปร พบว่า การใช้ตัวแปร 17 ตัวให้ประสิทธิภาพในการพยากรณ์ดีกว่าที่ค่า MAE เท่ากับ 1.3209 ในขณะที่ค่า MAE ของ 23 ตัวแปรเท่ากับ 1.4044

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อพิจารณาแยกตามแบบจำลองพบว่า แบบจำลอง CNN LSTM (1) LSTM (2) ให้ค่าเฉลี่ยดีที่สุดในตัวแปรอิสระ 17 ตัวแปร ที่ค่า MAE เท่ากับ 1.4414 1.2630 และ 1.3340 ตามลำดับ และ MAE ของทุกช่วงเวลาย้อนหลังของแบบจำลอง CNN-LSTM ให้ค่าเฉลี่ย MAE ดีที่สุดที่สุดเมื่อใช้ตัวแปรอิสระ 23 ตัว ในขณะที่แบบจำลอง CNN-LSTM ยังเป็นแบบจำลองที่ให้ประสิทธิภาพดีที่สุดในเมื่อเปรียบเทียบกับแบบจำลองอื่น 23 ตัวแปรที่มีค่าเฉลี่ยของ MAE ทุกช่วงเวลา เท่ากับ 1.1506 และ 1.2450 ตามลำดับ แสดงตารางที่ 4.19

ตารางที่ 4.19 ค่าเฉลี่ยของค่า MAE จำแนกตามจำนวนตัวแปรและเวลาย้อนหลังที่ต่างกันในแต่ละแบบจำลอง

จำนวนตัวแปร	เวลาย้อนหลัง (วัน)	แบบจำลอง				ค่าเฉลี่ย
		CNN	LSTM (1)	LSTM (2)	CNN-LSTM	
23	3	1.1709	1.5482	1.2771	1.0473	1.2609
	4	1.4053	1.4659	1.2795	1.0864	1.3093
	5	1.3941	1.1948	1.3069	1.3275	1.3058
	30	2.2528	1.4030	2.1696	1.1411	1.7416
	ค่าเฉลี่ย	1.5558	1.4030	1.5083	1.1506	1.4044
17	3	1.283	1.1973	1.1799	1.2739	1.2335
	4	1.2657	1.3442	1.2604	1.1959	1.2666
	5	1.3181	1.2175	1.1967	1.1186	1.2127
	30	1.8989	1.2930	1.6989	1.3917	1.5706
	ค่าเฉลี่ย	1.4414	1.2630	1.3340	1.2450	1.3209

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุดใน

2. แบบจำลองที่ใช้เวลาย้อนหลัง 3 วัน 4 วัน 5 วัน และ 30 วันในการพยากรณ์

นอกจากทำการทดลองใช้ตัวแปรอิสระที่ต่างกัน งานวิจัยนี้ยังทำการทดลองโดยใช้เวลาย้อนหลังที่ต่างกันเพื่อหาเวลาที่เหมาะสมในการพยากรณ์ราคาน้ำมันดิบ เมื่อพิจารณาค่าเฉลี่ยของค่า MAE ของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM ดังตารางที่ 4.20 พบว่าเวลาย้อนหลัง 3 วัน ให้ค่า MAE ต่ำที่สุดที่ 1.2472 อันดับที่สองคือ เวลาย้อนหลัง 5 วัน มีค่า MAE ที่ 1.2593 เวลาย้อนหลัง 4 วัน ให้ประสิทธิภาพเป็นอันดับถัดมา มีค่า MAE เท่ากับ 1.2880 และ เวลาย้อนหลัง 30 วัน เป็นอันดับสุดท้าย โดยที่ค่า MAE เท่ากับ 1.6562

เมื่อเปรียบเทียบค่าเฉลี่ยของ MAE แยกตามแบบจำลองพบว่า แบบจำลอง CNN และ LSTM (2) ให้ประสิทธิภาพดีที่สุดในราคาย้อนหลัง 3 วัน โดยค่าเฉลี่ย MAE จากแบบจำลองที่มีตัวแปรอิสระ 23 ตัวแปร และ 17 ตัวแปร เท่ากับ 1.2270 และ 1.2285 ตามลำดับ แบบจำลอง CNN-LSTM ให้ประสิทธิภาพดีที่สุดในเวลาย้อนหลัง 4 วัน ที่ค่าเฉลี่ย MAE เท่ากับ 1.1412 น้อยกว่าเวลาย้อนหลัง 3 วันเล็กน้อย และ แบบจำลอง LSTM (1) ให้ประสิทธิภาพดีที่สุดในราคาย้อนหลัง 5 วันที่มีค่า MAE เท่ากับ 1.2060 โดยที่แบบจำลองที่มีประสิทธิภาพดีที่สุดในแต่ละช่วงเวลาย้อนหลังคือ แบบจำลอง CNN-LSTM ยกเว้นเวลาย้อนหลัง 5 วัน ที่ LSTM (1) มีประสิทธิภาพดีกว่า ตามตารางที่ 4.20

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้สำหรับการใช้ในเพื่อการศึกษาค้นคว้าเท่านั้น เมื่ออนุญาตให้เผยแพร่ไปยังประโยชน์ทางการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. แบบจำลองที่ดีที่สุด

จากตารางที่ 4.19 และ 4.20 เมื่อทำการเปรียบเทียบแบบจำลองที่ดีที่สุดในแต่ละช่วงเวลาย้อนหลังที่แตกต่างกันที่ตัวแปรอิสระ 23 ตัวแปร พบว่า แบบจำลอง CNN-LSTM คือแบบจำลองที่มีประสิทธิภาพดีที่สุดที่เวลาย้อนหลัง 3 วัน 4 วัน และ 30 วัน ในขณะที่เวลาย้อนหลัง 5 วัน LSTM (1) มีประสิทธิภาพดีกว่า

เมื่อพิจารณาตัวแปรอิสระ 17 ตัวแปรในแต่ละช่วงเวลาย้อนหลังที่แตกต่างกัน พบว่าแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 4 วัน และ 5 วัน ให้ประสิทธิภาพดีที่สุด ในขณะที่ LSTM (2) มีประสิทธิภาพดีเมื่อกำหนดช่วงเวลาย้อนหลัง 3 วัน และ สุดท้ายแบบจำลอง LSTM (1) มีประสิทธิภาพดีที่กำหนดย้อนหลัง 5 วัน

เมื่อประเมินจากค่า MAE เฉลี่ยในมุมมองของจำนวนตัวแปรและช่วงเวลาย้อนหลังที่แตกต่างกัน แบบจำลอง CNN-LSTM คือแบบจำลองที่มีประสิทธิภาพดีที่สุดสำหรับการพยากรณ์ราคาน้ำมันดิบระยะสั้นเมื่อใช้เวลาย้อนหลัง 3 วัน ร่วมกับตัวแปรอิสระ 23 ตัวแปร มีค่า MAE เท่ากับ 1.0473

ตารางที่ 4.20 ค่าเฉลี่ยของค่า MAE จำแนกตามเวลาย้อนหลังและจำนวนตัวแปรที่แตกต่างกันในแต่ละแบบจำลอง

เวลาย้อนหลัง (วัน)	จำนวนตัวแปร	แบบจำลอง				ค่าเฉลี่ย
		CNN	LSTM (1)	LSTM (2)	CNN- LSTM	
3	23	1.1709	1.5482	1.2771	1.0473	1.2609
	17	1.283	1.1973	1.1799	1.2739	1.2335
	ค่าเฉลี่ย	1.2270	1.3728	1.2285	1.1606	1.2472
4	23	1.4053	1.4659	1.2795	1.0864	1.3093
	17	1.2657	1.3442	1.2604	1.1959	1.2666
	ค่าเฉลี่ย	1.3355	1.4051	1.2700	1.1412	1.2880
5	23	1.3941	1.1948	1.3069	1.3275	1.3058
	17	1.3181	1.2175	1.1967	1.1186	1.2127
	ค่าเฉลี่ย	1.3561	1.2060	1.2518	1.2231	1.2593
30	23	2.2528	1.4030	2.1696	1.1411	1.7416
	17	1.8989	1.2930	1.6989	1.3917	1.5706
	ค่าเฉลี่ย	2.0759	1.3480	1.9343	1.2664	1.6562

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

4.5 ปัจจัยที่มีผลต่อการพยากรณ์ราคาน้ำมันดิบสหรัฐอเมริกาด้วยวิธี Permutation Feature Importance (PFI)

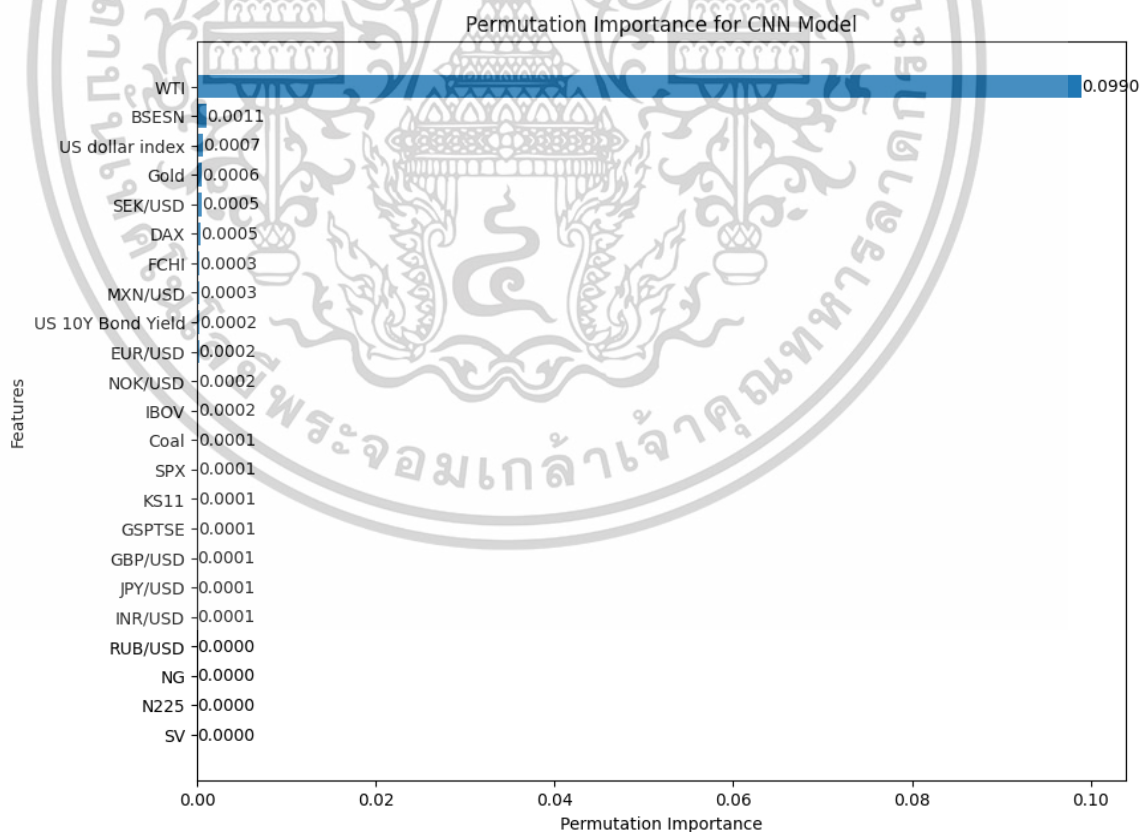
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โครงข่ายประสาทเทียมมีโครงสร้างที่ซับซ้อน การทำความเข้าใจวิธีการตัดสินใจของแบบจำลองมีความสำคัญมาก โดยเฉพาะในภาคการเงินและเศรษฐศาสตร์ (Akil et al., 2024) เพราะสามารถให้ข้อมูลเชิงลึกเพื่อประกอบการตัดสินใจ เพื่อเข้าใจว่าตัวแปรใดมีอิทธิพลต่อการพยากรณ์ราคาน้ำมันดิบตลาดสหรัฐอเมริกา การศึกษานี้ใช้เทคนิค Feature Importance ด้วยวิธี Permutation Feature Importance (PFI) ดังอธิบายในข้อ 2.8 ซึ่งเป็นวิธีวัดประสิทธิภาพของแบบจำลองเมื่อมีการสับเปลี่ยนลำดับในตัวแปรอิสระ โดยที่ PFI มีค่าเท่ากับ 0 หมายความว่า ตัวแปรอิสระนั้นไม่มีผลต่อการพยากรณ์ของแบบจำลอง

การศึกษานี้จะทำการดูตัวแปรที่มีอิทธิพลต่อผลการพยากรณ์ของโมเดลที่มีประสิทธิภาพดีที่สุดในหัวข้อ 4.2 และ 4.3

4.5.1 แบบจำลอง CNN

จากการศึกษาในหัวข้อที่ 4.2 และ 4.3 แบบจำลอง CNN มีประสิทธิภาพดีที่สุดในตัวแปรอิสระ 23 ตัวที่ราคาย้อนหลัง 3 วัน โดยที่ MAE MAPE RMSE และ R^2 ของข้อมูลทดสอบ เท่ากับ 1.1709 1.5645 1.4847 และ 0.9242 ตามลำดับ จากภาพที่ 4.2 ตัวแปรอิสระที่มีอิทธิพลต่อแบบจำลอง CNN 5 อันดับแรก คือ ราคาน้ำมันดิบตลาดสหรัฐ (WTI Crude Oil) ดัชนีหุ้นจากตลาดหลักทรัพย์อินเดีย (BSE Sensex 30: BSESN) ดัชนีดอลลาร์ (US dollar Index) ราคาทองคำ (Gold Spot US Dollar) และ อัตราแลกเปลี่ยนโคโรนาสวีเดนต่อดอลลาร์สหรัฐ (SEK-USD)

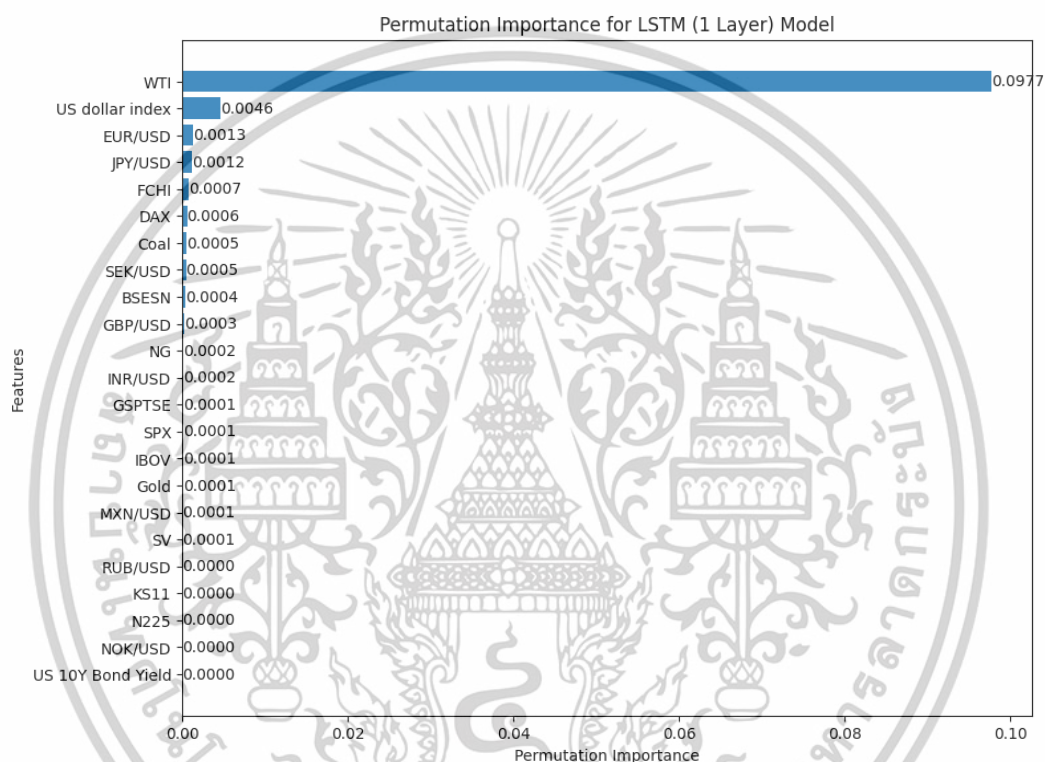


ภาพที่ 4.2 Permutation Feature Importance ของแบบจำลอง CNN ที่เวลาย้อนหลัง 3 วัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.5.2 แบบจำลอง LSTM (1)

จากการศึกษาในหัวข้อที่ 4.2 และ 4.3 แบบจำลอง LSTM (1) มีประสิทธิภาพดีที่สุด ที่ตัวแปรอิสระ 23 ตัวที่ราคาย้อนหลัง 5 วัน โดยที่ MAE MAPE RMSE และ R^2 ของข้อมูลทดสอบ เท่ากับ 1.1948 1.5809 1.4926 และ 0.9239 ตามลำดับ จากภาพที่ 4.3 ตัวแปรอิสระที่มีอิทธิพลต่อแบบจำลอง LSTM (1) 5 อันดับแรก คือ ราคาน้ำมันดิบตลาดสหรัฐฯ (WTI Crude Oil) ดัชนีดอลลาร์ (US dollar Index) อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐฯ (EUR-USD) อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐฯ (JPY-USD) และ ดัชนีหุ้นจากตลาดหลักทรัพย์ฝรั่งเศส (CAC 40: FCHI)




ภาพที่ 4.3 Permutation Feature Importance ของแบบจำลอง LSTM (1) ที่เวลาย้อนหลัง 5 วัน

4.5.3 แบบจำลอง LSTM (2)

จากการศึกษาในหัวข้อที่ 4.2 และ 4.3 แบบจำลอง LSTM (2) มีประสิทธิภาพดีที่สุด ที่ตัวแปรอิสระ 17 ตัวที่ราคาย้อนหลัง 3 วัน โดยที่ MAE MAPE RMSE และ R^2 ของข้อมูลทดสอบ เท่ากับ 1.1799 1.5600 1.4739 และ 0.9256 ตามลำดับ จากภาพที่ 4.4 ตัวแปรอิสระที่มีอิทธิพลต่อแบบจำลอง LSTM (2) 5 อันดับแรก คือ ราคาน้ำมันดิบตลาดสหรัฐฯ (WTI Crude Oil) ดัชนีดอลลาร์ (US dollar Index) อัตราแลกเปลี่ยนโคโรนาสวีเดนต่อดอลลาร์สหรัฐฯ (SEK-USD) อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐฯ (JPY-USD) และ อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐฯ (EUR-USD)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.4 Permutation Feature Importance ของแบบจำลอง LSTM (2) ที่เวลาย้อนหลัง 3 วัน


4.5.4 แบบจำลอง CNN-LSTM

จากการศึกษาในหัวข้อที่ 4.2 และ 4.3 แบบจำลอง CNN-LSTM มีประสิทธิภาพดีที่สุด ที่ตัวแปรอิสระ 24 ตัวที่เวลาย้อนหลัง 3 วัน โดยที่ MAE MAPE RMSE และ R^2 ของข้อมูลทดสอบ เท่ากับ 1.0473 1.3962 1.3422 และ 0.9381 ตามลำดับ จากภาพที่ 4.5 ตัวแปรอิสระที่มีอิทธิพลต่อแบบจำลอง CNN - LSTM 5 อันดับแรก คือ ราคาน้ำมันดิบตลาดสหรัฐฯ (WTI Crude Oil) ดัชนีดอลลาร์ (US dollar Index) อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐฯ (EUR-USD) อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐฯ (JPY-USD) และ อัตราแลกเปลี่ยนโคโรนาสวีเดนต่อดอลลาร์สหรัฐฯ (SEK-USD) ตามภาพที่ 4.5

ภาพที่ 4.5 – 4.8 แสดงตัวแปรอิสระที่มีผลต่อการพยากรณ์ราคาน้ำมันดิบระยะสั้นด้วยที่เวลาย้อนหลัง 3 วัน 4 วัน 5 วัน และ 30 วันของแบบจำลอง CNN-LSTM พบว่า ราคาน้ำมันดิบตลาดสหรัฐฯ (WTI Crude Oil) ดัชนีดอลลาร์ (US dollar Index) อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐฯ (EUR-USD) เป็นตัวแปรอิสระร่วมที่อยู่ใน 5 อันดับแรก ที่ระยะเวลาย้อนหลังแตกต่างกัน




ภาพที่ 4.5 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาซ้อนหลัง 3 วัน

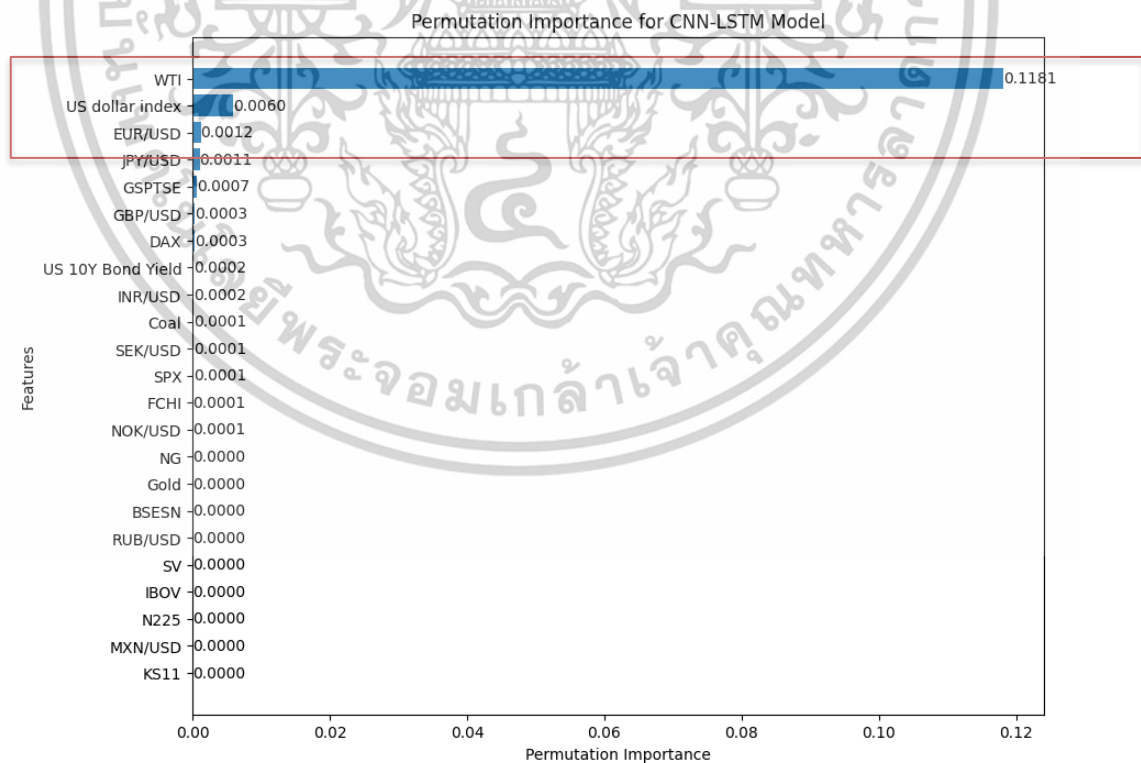


ภาพที่ 4.6 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาซ้อนหลัง 4 วัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.7 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 5 วัน



ภาพที่ 4.8 Permutation Feature Importance ของแบบจำลอง CNN-LSTM ที่เวลาย้อนหลัง 30 วัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดลองในหัวข้อ 4.5.1 – 4.5.4 สามารถสรุปตัวแปรอิสระ 5 อันดับแรกที่มีอิทธิพลต่อการพยากรณ์ราคาน้ำมันระยะสั้นดังตารางที่ 4.21 โดยที่ ราคาน้ำมันดิบตลาดสหรัฐ (WTI Crude Oil) ดัชนีดอลลาร์ (US dollar Index) อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ (EUR-USD) อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐ (JPY-USD) เป็นปัจจัยที่มีอิทธิพลในแบบจำลอง LSTM ทั้งสองแบบ และ CNN-LSTM

ตารางที่ 4.21 ตัวแปรอิสระ 5 อันดับแรกที่มีอิทธิพลในการพยากรณ์ราคาน้ำมันดิบระยะสั้นของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM

อันดับ	แบบจำลอง CNN (เวลาย้อนหลัง 3 วัน)	แบบจำลอง LSTM (1) (เวลาย้อนหลัง 5 วัน)	แบบจำลอง LSTM (2) (เวลาย้อนหลัง 3 วัน)	แบบจำลอง CNN- LSTM (เวลาย้อนหลัง 3 วัน)
1	ราคาน้ำมันดิบตลาด สหรัฐ (WTI Crude Oil)	ราคาน้ำมันดิบ ตลาดสหรัฐ (WTI Crude Oil)	ราคาน้ำมันดิบ ตลาดสหรัฐ (WTI Crude Oil)	ราคาน้ำมันดิบ ตลาดสหรัฐ (WTI Crude Oil)
2	ดัชนีหุ้นจากตลาด หลักทรัพย์อินเดีย (BSE Sensex 30: BSESN)	ดัชนีดอลลาร์ (US dollar Index)	ดัชนีดอลลาร์ (US dollar Index)	ดัชนีดอลลาร์ (US dollar Index)
3	ดัชนีดอลลาร์ (US dollar Index)	อัตราแลกเปลี่ยนยูโร ต่อดอลลาร์สหรัฐ (EUR-USD)	อัตราแลกเปลี่ยนโค รนาสวีเดนต่อดอลลาร์ สหรัฐ (SEK- USD)	อัตราแลกเปลี่ยนยูโร ต่อดอลลาร์สหรัฐ (EUR-USD)
4	ราคาทองคำ (Gold Spot US Dollar)	อัตราแลกเปลี่ยน เยนต่อดอลลาร์ สหรัฐ (JPY-USD)	อัตราแลกเปลี่ยน เยนต่อดอลลาร์สหรัฐ (JPY-USD)	อัตราแลกเปลี่ยน เยนต่อดอลลาร์สหรัฐ (JPY-USD)
5	อัตราแลกเปลี่ยนโค รนาสวีเดนต่อดอลลาร์ สหรัฐ (SEK-USD)	ดัชนีหุ้นจากตลาด หลักทรัพย์ฝรั่งเศส (CAC 40: FCHI)	อัตราแลกเปลี่ยนยูโร ต่อดอลลาร์สหรัฐ (EUR-USD)	อัตราแลกเปลี่ยนโค รนาสวีเดนต่อดอลลาร์ สหรัฐ (SEK- USD)

หมายเหตุ : ตัวหนาเป็นตัวแปรที่มีอิทธิพลในการพยากรณ์ราคาน้ำมันของทุกแบบจำลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


4.6 การอภิปรายผล

การพยากรณ์ราคาน้ำมันดิบที่แม่นยำและมีประสิทธิภาพเป็นสิ่งสำคัญสำหรับสำหรับภาคธุรกิจที่ใช้น้ำมันดิบ เช่น การขนส่ง ภาคอุตสาหกรรมปิโตรเคมี หรือ นักลงทุน เนื่องจากราคาน้ำมันมีการซื้อขายในตลาดการเงิน (Financial Market) งานวิจัยนี้จึงมีวัตถุประสงค์ในการสร้างแบบจำลองที่สามารถเพิ่มประสิทธิภาพการพยากรณ์ราคาน้ำมันดิบระยะสั้น โดยใช้ตัวแปรรายวันที่มีในตลาดการเงิน จากการศึกษาแสดงให้เห็นว่าการพยากรณ์ราคาน้ำมันดิบระยะสั้นด้วยโครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM เป็นวิธีการทำนายที่ให้ประสิทธิภาพดีที่สุด

เมื่อเปรียบเทียบผลการทดลองจำแนกตามจำนวนตัวแปรและเวลาย้อนหลังที่แตกต่างกัน พบว่า โครงข่ายประสาทเทียมแบบผสมผสาน CNN-LSTM ที่กำหนดเวลาย้อนหลัง 3 วัน ร่วมกับตัวแปรอิสระ 23 ตัวแปร เป็นวิธีการทำนายที่ให้ประสิทธิภาพสูงสุด เนื่องจากแบบจำลองมีค่าความผิดพลาดน้อยเมื่อเทียบกับแบบจำลองอื่นๆ ซึ่งผลประเมินความแม่นยำของแบบจำลองแบบผสมผสาน CNN-LSTM ที่มีค่า MAE เท่ากับ 1.0473 MAPE เท่ากับ 1.3962 RMSE เท่ากับ 1.3422 และ R^2 เท่ากับ 0.9381 แบบจำลอง LSTM (2) กำหนดเวลาย้อนหลัง 3 วัน ร่วมกับตัวแปรอิสระ 17 ตัว เป็นแบบจำลองที่มีประสิทธิภาพรองลงมา มีค่า MAE เท่ากับ 1.1799 MAPE เท่ากับ 1.5600 RMSE เท่ากับ 1.4739 และ R^2 เท่ากับ 0.9253 แบบจำลอง CNN ที่กำหนดเวลาย้อนหลัง 3 วัน ร่วมกับตัวแปรอิสระ 23 ตัว เป็นแบบจำลองที่มีประสิทธิภาพอันดับถัดมา มีค่า MAE เท่ากับ 1.1709 MAPE เท่ากับ 1.5645 RMSE เท่ากับ 1.4847 และ R^2 เท่ากับ 0.9242 และแบบจำลอง LSTM (1) ที่กำหนดเวลาย้อนหลัง 5 วัน ร่วมกับตัวแปรอิสระ 23 ตัว เป็นแบบจำลองที่มีประสิทธิภาพน้อยสุด มีค่า MAE เท่ากับ 1.1948 MAPE เท่ากับ 1.5809 RMSE เท่ากับ 1.4926 และ R^2 เท่ากับ 0.9239

ผลการศึกษานี้สอดคล้องกับงานวิจัยของ Xu. et al. (2024) ที่พยากรณ์ราคาน้ำมันดิบโดยใช้ตัวแปรที่เกี่ยวข้องกับตลาดการเงินรายวันร่วมกับราคาน้ำมันดิบ พบว่าแบบจำลองแบบผสมผสาน CNN-LSTM ให้ผลลัพธ์การพยากรณ์ราคาน้ำมันดิบที่ดีที่สุด โดยวัดจาก MAE เท่ากับ 2.5216 และ RMSE เท่ากับ 4.1746 และ งานวิจัยของ Aldabagh. et al. (2023) ที่ทำการเปรียบเทียบแบบจำลอง ARIMA SVM CNN LSTM และ CNN-LSTM โดยใช้ราคาน้ำมันดิบเป็นตัวแปรอิสระ ผลการทดลองพบว่าแบบจำลองแบบผสมผสาน CNN-LSTM สามารถพยากรณ์ราคาน้ำมันดิบระยะสั้นได้มีประสิทธิภาพมากที่สุด โดยวัดจากค่า RMSE เท่ากับ 2.36 ต่อมา Aldabagh. et al. (2024) ได้ทำวิจัยการพยากรณ์ราคาน้ำมันดิบรายเดือน โดยการใช้ปัจจัยที่เกี่ยวข้องกับอุปสงค์และอุปทาน รวมถึงปัจจัยที่เกี่ยวข้องกับตลาดการเงิน (Financial Market) คือ ดัชนีดอลลาร์ (US dollar index) พบว่าแบบจำลองแบบผสมผสาน CNN-LSTM มีประสิทธิภาพในการทำนายมากที่สุด โดยวัดจากค่า MAE และ RMSE เท่ากับ 2.23 และ 7.94 ตามลำดับ และ แบบจำลองมีค่าความผิดพลาดน้อยลงเมื่อเพิ่มดัชนีดอลลาร์ (US dollar index) โดยค่า MAE และ RMSE เท่ากับ 1.82 และ 5.04

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

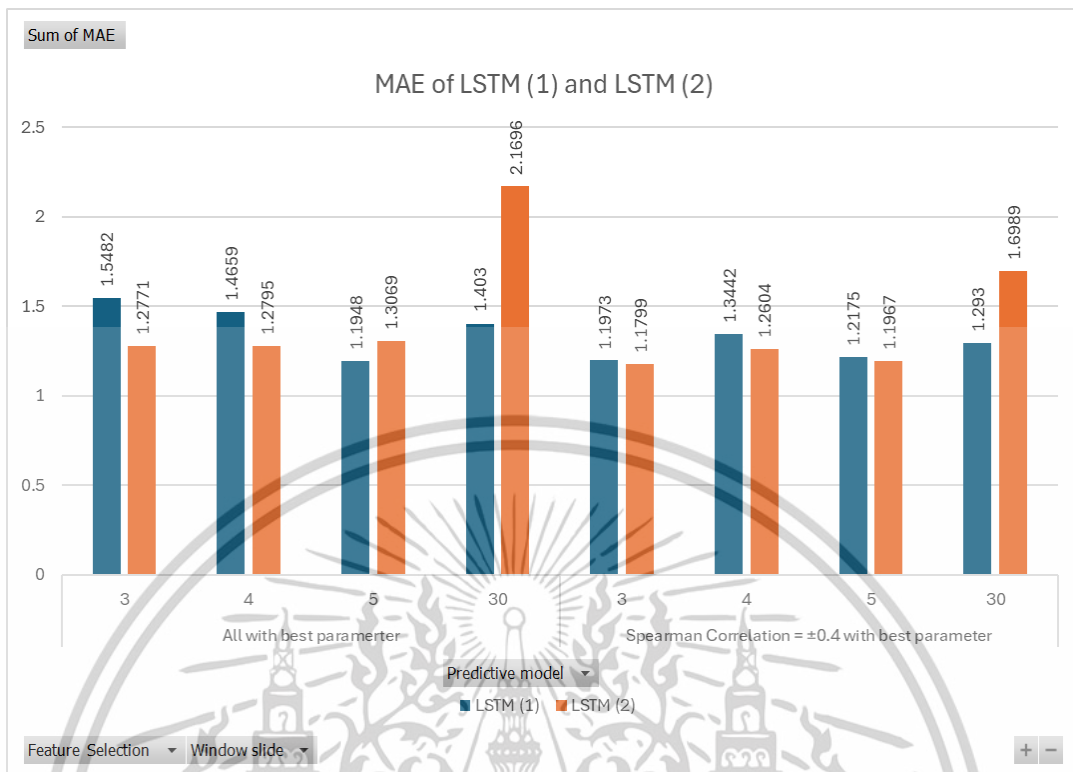


ภาพที่ 4.9 ราคาน้ำมันดิบจากการพยากรณ์เทียบราคาน้ำมันดิบจริงของแบบจำลอง CNN-LSTM ในชุดข้อมูลทดสอบ

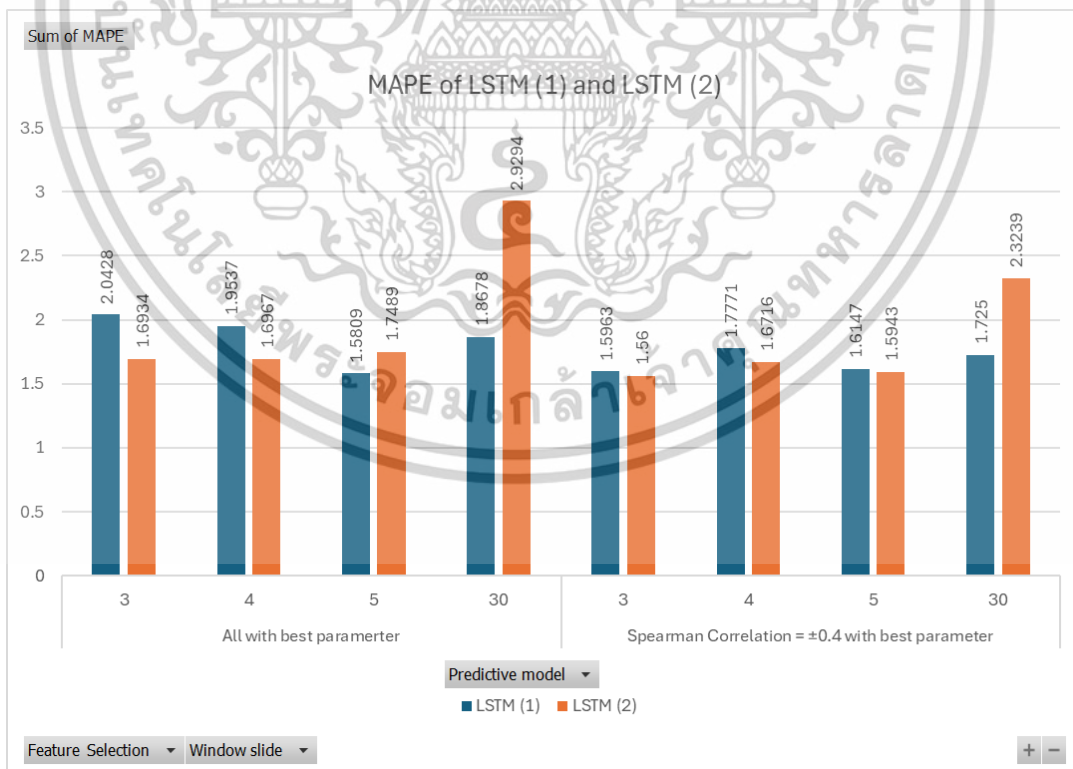
แบบจำลอง LSTM ในการศึกษาครั้งนี้มี 2 แบบจำลองคือ LSTM (1) ที่มี LSTM Unit 1 เลเยอร์ และ LSTM (2) ที่มี LSTM Unit 2 เลเยอร์ จากการศึกษาแสดงให้เห็นว่า ประสิทธิภาพของแบบจำลอง LSTM (2) ที่เวลาย้อนหลัง 3 วัน และ 4 วัน ให้ประสิทธิภาพของการพยากรณ์ดีกว่า ในขณะที่ LSTM (1) ให้ประสิทธิภาพของการพยากรณ์ดีกว่า ที่เวลาย้อนหลัง 5 วัน และ 30 วัน

เมื่อพิจารณาเวลาย้อนหลังควบคู่กับจำนวนตัวแปร พบว่า แบบจำลอง LSTM (2) ที่เวลาย้อนหลัง 3 วัน และ 4 วัน ร่วมกับตัวแปรอิสระ 17 ตัว ให้ประสิทธิภาพที่ดีที่สุด ที่ค่า MAE เท่ากับ 1.1799 และ 1.2604 ตามลำดับ แบบจำลอง LSTM (1) ที่เวลาย้อนหลัง 5 วัน จะมีประสิทธิภาพดีที่สุด เมื่อทำงานร่วมกับตัวแปรอิสระ 24 ตัว ที่ MAE เท่ากับ 1.1948 ในขณะที่ LSTM (1) ที่เวลาย้อนหลัง 30 วัน จะมีประสิทธิภาพเมื่อทำงานร่วมกับตัวแปรอิสระ 17 ตัว

เมื่อเปรียบเทียบประสิทธิภาพการพยากรณ์ของ LSTM ทั้งสองแบบจำลองร่วมกับตัวแปรอิสระ 17 ตัว และ 23 ตัว พบว่า LSTM (2) ร่วมกับตัวแปรอิสระ 17 ตัว ที่เวลาย้อนหลัง 3 วัน ให้ประสิทธิภาพที่ดีที่สุด ที่ MAE เท่ากับ 1.1799 MAPE เท่ากับ 1.5600 RMSE เท่ากับ 1.4739 ตามภาพ 4.7 – 4.9

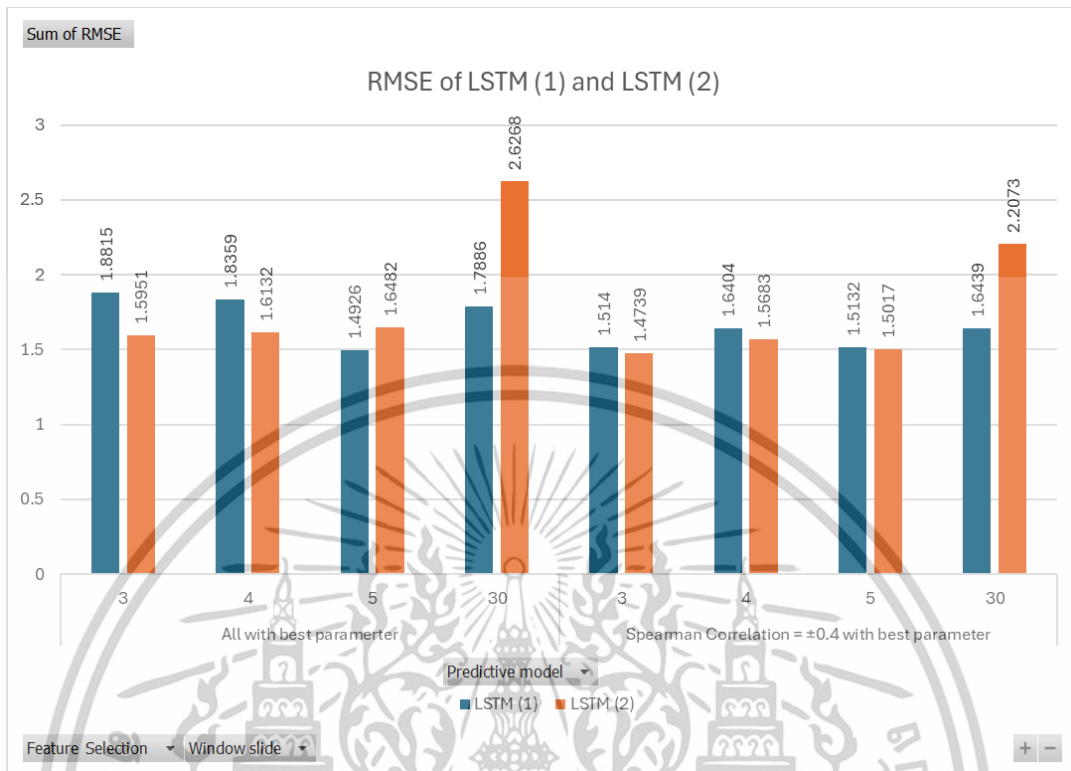


ภาพที่ 4.10 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) และ LSTM (2) ด้วยค่า MAE



ภาพที่ 4.11 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) และ LSTM (2) ด้วยค่า MAPE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.12 เปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM (1) และ LSTM (2) ด้วยค่า RMSE

การศึกษานี้มีจุดมุ่งหมายเพื่อที่จะพยากรณ์ราคาน้ำมันดิบระยะสั้น เพื่อเป็นแนวทางสำหรับการประกอบการตัดสินใจของนักลงทุน โดยเฉพาะนักลงทุนที่มีการซื้อขายเป็นรายสัปดาห์ โดยมีการใช้เวลาย้อนหลัง 3 – 5 วัน จากตารางที่ 4.20 สามารถสรุปได้ว่าเวลาย้อนหลัง 3 วัน สำหรับแบบจำลอง CNN LSTM (1) และ CNN-LSTM ให้ประสิทธิภาพที่ดีที่สุดสอดคล้องกับงานวิจัยของ Akil. et al. (2024) ที่ใช้ราคาน้ำมันดิบและตัวแปรอิสระอื่นๆ ย้อนหลัง 3 วัน เนื่องจากแบบจำลองสามารถเรียนรู้รูปแบบและแนวโน้มของข้อมูลได้ ในขณะที่แบบจำลอง LSTM (2) มีประสิทธิภาพดีที่สุดเมื่อทำงานร่วมกับเวลาย้อนหลัง 5 วัน

นอกจากนี้การศึกษานี้ยังทำการใช้เวลาย้อนหลัง 30 วัน เพราะจากการทบทวนวิจัยอ้างอิงพบว่า การพยากรณ์ราคาน้ำมันดิบนิยมพยากรณ์เป็นรายเดือน ผลการทดลองแสดงให้เห็นว่าแบบจำลอง CNN-LSTM ร่วมกับตัวแปรอิสระ 23 ตัวแปรให้ประสิทธิภาพดีที่สุด ถัดมาคือแบบจำลอง LSTM (1) LSTM (2) และ CNN ร่วมกับตัวแปรอิสระ 17 ตัวแปร ดังตารางที่ 4.22 เมื่อเปรียบเทียบกับผลการทดลองของ Aldabagh. et al. (2024) ที่พยากรณ์ราคาน้ำมันดิบรายเดือนแบบจำลอง CNN มีค่า MAE เท่ากับ 2.12 RMSE เท่ากับ 6.67 แบบจำลอง LSTM มีค่า MAE เท่ากับ 1.55 RMSE เท่ากับ 4.17 และแบบจำลอง CNN-LSTM มีค่า MAE เท่ากับ 1.33 RMSE เท่ากับ 3.93 พบว่าแบบจำลอง CNN และ LSTM ในงานวิจัยนี้ร่วมกับตัวแปรอิสระรายวัน 17 ตัวให้ประสิทธิภาพของการพยากรณ์ดีกว่า สำหรับแบบจำลองแบบผสมผสาน CNN-LSTM ให้ประสิทธิภาพดีกว่าเมื่อใช้ตัวแปรอิสระ 23 ตัวแปร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.22 เปรียบเทียบประสิทธิภาพของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN-LSTM ที่เวลาย้อนหลัง 30 วัน

แบบจำลอง	จำนวนตัวแปร	ประสิทธิภาพการพยากรณ์ Test Dataset			
		MAE	MAPE	RMSE	R ²
CNN	23	2.2528	2.989	2.7865	0.7548
	17	1.8989	2.4856	2.3962	0.8187
LSTM (1)	23	1.403	1.8678	1.7886	0.899
	17	1.293	1.725	1.6439	0.9147
LSTM (2)	23	2.1696	2.9294	2.6268	0.7821
	17	1.6989	2.3239	2.2073	0.8461
CNN-LSTM	23	1.1411	1.5167	1.464	0.9323
	17	1.3917	1.8356	1.6935	0.9094

หมายเหตุ : ตัวเอียง คือ ผลการทดลองที่มีประสิทธิภาพดีที่สุด

งานวิจัยนี้ทำการศึกษาว่าตัวแปรอิสระใดบ้างที่มีอิทธิพลกับแบบจำลองด้วยวิธีการ Permutation Feature Importance พบว่า ราคาน้ำมันดิบเป็นปัจจัยที่มีอิทธิพลกับการพยากรณ์ราคาน้ำมันดิบระยะสั้นมากที่สุดซึ่งสอดคล้องกับงานวิจัยของ Miao. et al. (2017) ที่ค้นพบว่าราคาน้ำมันย้อนหลังเป็นปัจจัยที่สำคัญที่สุดในการพยากรณ์ราคาน้ำมัน เมื่อพิจารณาตัวแปรอิสระ 5 อันดับแรกที่มีอิทธิพลกับการพยากรณ์ราคาน้ำมันดิบพบว่าดัชนีดอลลาร์ (US Dollar Index) เป็นอีกหนึ่งปัจจัยที่มีอิทธิพลต่อแบบจำลองทั้ง 4 แบบจำลองแต่อยู่ในสัดส่วนที่ไม่สูงเมื่อเทียบกับราคาน้ำมันดิบย้อนหลัง ซึ่งสอดคล้องกับงานวิจัยของ Aldabagh และคณะ (2024) ที่พบว่า แบบจำลองมีประสิทธิภาพดีขึ้น เมื่อเพิ่มดัชนีดอลลาร์ (US Dollar Index)

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

บทนี้จะเป็นการสรุปผลการวิเคราะห์ที่สำคัญพร้อมข้อเสนอแนะที่เกี่ยวข้อง

5.1 สรุปผลการวิจัย

งานวิจัยนี้เสนอการเปรียบเทียบการพยากรณ์ราคาน้ำมันดิบร่วมกับตัวแปรทางการเงินรายวัน ด้วยแบบจำลองโครงข่ายประสาทเทียม 4 แบบจำลอง คือ 1. แบบจำลอง CNN 2. แบบจำลอง LSTM ที่มี LSTM Unit 1 เลเยอร์ 3. แบบจำลอง LSTM ที่มี LSTM Unit 2 เลเยอร์ 4. แบบจำลองผสมผสาน CNN-LSTM โดยใช้เวลาย้อนหลัง 3 วัน 4 วัน 5 วัน และ 30 วัน และจำนวนตัวแปรอิสระทางการเงิน 23 ตัวแปร และ 17 ตัวแปร ทำการทดลองทั้งสิ้น 32 การทดลอง

จากตารางที่ 5.1 สามารถสรุปผลการทดลองที่ดีที่สุดได้ทั้งหมด 8 การทดลอง จากทั้งหมด 32 การทดลอง โดยจำแนกตามแบบจำลอง จำนวนตัวแปร และ ช่วงเวลาย้อนหลังที่ดีที่สุด สามารถสรุปผลการทดลองได้ดังนี้

1. แบบจำลองแบบผสมผสาน CNN-LSTM คือแบบจำลองที่มีประสิทธิภาพดีที่สุดในการพยากรณ์เมื่อเทียบกับแบบจำลองอื่นๆ โดยแบบจำลอง CNN-LSTM ที่ช่วงเวลาย้อนหลัง 3 วันที่กำหนดตัวแปรอิสระ 23 ตัวสามารถพยากรณ์ราคาน้ำมันดิบระยะสั้นได้ค่อนข้างแม่นยำ มีค่า MAE เท่ากับ 1.0473 MAPE เท่ากับ 1.3962 RMSE เท่ากับ 1.3422 และ R^2 เท่ากับ 0.9381 โดยพารามิเตอร์ของแบบจำลอง CNN-LSTM ที่มีประสิทธิภาพดีที่สุดในการศึกษานี้ มีพารามิเตอร์ดังนี้

1. CNN Filter Unit ชั้นแรก เท่ากับ 128
2. CNN Filter Unit ชั้นที่สอง เท่ากับ 128
3. LSTM Unit เท่ากับ 200
4. Dropout Rate เท่ากับ 0.3
5. Learning Rate เท่ากับ 0.001
6. Dense Unit เท่ากับ 32

2. เมื่อพิจารณาประสิทธิภาพการพยากรณ์จำแนกตามจำนวนตัวแปรอิสระ พบว่าแบบจำลองแบบผสมผสาน CNN-LSTM ยังคงเป็นแบบจำลองที่ให้ประสิทธิภาพดีที่สุดในการพยากรณ์ราคาน้ำมันดิบระยะสั้น ซึ่งแบบจำลอง CNN-LSTM ที่กำหนดตัวแปรอิสระ 23 ตัว ให้ประสิทธิภาพดีกว่ากำหนดตัวแปรอิสระ 17 ตัวแปร ซึ่งมีค่า MAE เท่ากับ 1.1186 MAPE เท่ากับ 1.4864 RMSE เท่ากับ 1.4051 และ R^2 เท่ากับ 0.9325

นอกจากนี้ผลการทดลองยังแสดงให้เห็นว่าการลดขนาดมิติของข้อมูลด้วยค่าสหสัมพันธ์ไม่ได้เพิ่มประสิทธิภาพสำหรับแบบจำลอง CNN LSTM (1) และ CNN-LSTM ในขณะที่ LSTM (2) มีประสิทธิภาพดีขึ้นเมื่อลดมิติของตัวแปรอิสระจาก 23 ตัวแปรเป็น 17 ตัวแปร

3. เมื่อพิจารณาช่วงเวลาย้อนหลัง ผลการทดลองแสดงให้เห็นว่าการใช้เวลาย้อนหลังไม่เกิน 5 วันให้ประสิทธิภาพดีกว่า 30 วัน โดยแบบจำลอง CNN-LSTM ยังคงเป็นแบบจำลองที่มีประสิทธิภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดีที่สุดที่ราคาย้อนหลัง 3 วัน 4 วัน และ 30 วัน ที่กำหนดตัวแปรอิสระ 23 ตัวแปร ในขณะที่ช่วงเวลาย้อนหลัง 4 วัน แบบจำลอง CNN-LSTM มีประสิทธิภาพดีที่สุดเมื่อกำหนดตัวแปรอิสระ 17 ตัวแปร มีค่า MAE เท่ากับ 1.1186 MAPE เท่ากับ 1.4864 RMSE เท่ากับ 1.4051 และ R^2 เท่ากับ 0.9325

4. นอกเหนือจากแบบจำลอง CNN-LSTM ที่มีประสิทธิภาพการทดลองที่ดีที่สุด สามารถสรุปผลการทดลองในแต่ละแบบจำลองที่แสดงดังตารางที่ 5.1 ข้อสรุปดังต่อไปนี้

4.1 แบบจำลอง CNN มีประสิทธิภาพดีที่สุด เมื่อกำหนดตัวแปรอิสระ 23 ตัวแปรพร้อมกับช่วงเวลาย้อนหลัง 3 วัน มีค่า MAE เท่ากับ 1.1709 MAPE เท่ากับ 1.5645 RMSE เท่ากับ 1.4847 และ R^2 เท่ากับ 0.9242

4.2 แบบจำลอง LSTM (1) มีประสิทธิภาพดีที่สุด เมื่อกำหนดตัวแปรอิสระ 23 ตัวแปรพร้อมกับช่วงเวลาย้อนหลัง 5 วัน มีค่า MAE เท่ากับ 1.1948 MAPE เท่ากับ 1.5809 RMSE เท่ากับ 1.4926 และ R^2 เท่ากับ 0.9239

4.3 แบบจำลอง LSTM (2) มีประสิทธิภาพดีที่สุด เมื่อกำหนดตัวแปรอิสระ 17 ตัวแปรพร้อมกับช่วงเวลาย้อนหลัง 3 วัน มีค่า MAE เท่ากับ 1.1799 MAPE เท่ากับ 1.5600 RMSE เท่ากับ 1.4739 และ R^2 เท่ากับ 0.9253

4.4 แบบจำลอง CNN-LSTM เมื่อกำหนดตัวแปรอิสระ 23 ตัวแปรพร้อมกับช่วงเวลาย้อนหลัง 3 วัน เป็นแบบจำลองที่ดีที่สุด ดังที่กล่าวไว้ในหัวข้อ 1

ตารางที่ 5.1 เปรียบเทียบประสิทธิภาพที่ดีที่สุดของแบบจำลอง CNN, LSTM (1), LSTM (2) และ CNN-LSTM

แบบจำลอง	จำนวนตัวแปร	เวลาย้อนหลัง (วัน)	ประสิทธิภาพการพยากรณ์ Test Dataset			
			MAE	MAPE	RMSE	R^2
CNN	23	3	1.1709	1.5645	1.4847	0.9242
	17	4	1.2657	1.6671	1.5629	0.9162
LSTM (1)	23	5	1.1948	1.5809	1.4926	0.9239
	17	3	1.1973	1.5963	1.5140	0.9212
LSTM (2)	23	3	1.2771	1.6934	1.5951	0.9125
	17	3	1.1799	1.5600	1.4739	0.9253
CNN-LSTM	23	3	1.0473	1.3962	1.3422	0.9381
	17	5	1.1186	1.4864	1.4051	0.9325

5. จากการศึกษาปัจจัยที่มีอิทธิพลต่อการพยากรณ์ด้วยวิธี Permutation Feature Importance ของแบบจำลองที่ดีที่สุด พบว่าราคาน้ำมันดิบในอดีตเป็นปัจจัยสำคัญที่ส่งผลต่อการพยากรณ์ราคาน้ำมันดิบระยะสั้นตลาดสหรัฐอเมริกา คิดเป็นร้อยละ 91.62 รองลงมาคือ ดัชนีดอลลาร์ คิดเป็นร้อยละ 4.88 อัตราแลกเปลี่ยนยูโรต่อดอลลาร์สหรัฐ อัตราแลกเปลี่ยนเยนต่อดอลลาร์สหรัฐ และเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัตราแลกเปลี่ยนโคโรนาสวีเดนต่อดอลลาร์สหรัฐ เป็นลำดับถัดมาคิดเป็นร้อยละ 1.13 0.66 และ 0.39 ตามลำดับ

โดยสรุปแบบจำลอง CNN-LSTM คือแบบจำลองที่มีประสิทธิภาพในการพยากรณ์ดีที่สุดในทุกช่วงเวลาและจำนวนตัวแปร แบบจำลอง LSTM (2) มีประสิทธิภาพดีที่สุดเมื่อกำหนดตัวแปรอิสระ 17 ตัวแปรพร้อมกับช่วงเวลาย้อนหลัง 3 วัน ในขณะที่แบบจำลอง CNN และ LSTM (1) มีประสิทธิภาพการทดลองดีที่สุดเมื่อกำหนดตัวแปรอิสระ 23 ตัวแปร พร้อมกับช่วงเวลาย้อนหลัง 3 วัน สำหรับแบบจำลอง CNN และ 5 วัน สำหรับแบบจำลอง LSTM (1)

5.2 ข้อเสนอแนะ

1. งานวิจัยนี้พยากรณ์ราคาน้ำมันดิบระยะสั้นตลาดสหรัฐอเมริกาด้วยราคาน้ำมันด้วยข้อมูลทางตลาดทางการเงิน (Financial Market) อย่างเดียว ซึ่งความผันผวนของราคาน้ำมันดิบเกิดขึ้นได้จากหลายปัจจัยทั้ง โรคระบาด ปัจจัยทางภูมิรัฐศาสตร์ ซึ่งสามารถนำข้อมูลเกี่ยวกับการวิเคราะห์ความรู้สึก (Sentimental Analysis) จากข่าวมาเป็นตัวแปรในการสร้างแบบจำลองเพื่อเพิ่มประสิทธิภาพของแบบจำลอง นอกจากนี้การวิเคราะห์ความรู้สึกจากข่าวอาจจะสามารถช่วยวิเคราะห์ได้ว่าข่าวแบบใดที่จะส่งผลกระทบต่อราคาน้ำมันบ้าง เพื่อที่นักลงทุนจะได้นำปัจจัยนั้นไปประกอบการตัดสินใจได้ดียิ่งขึ้น

2. งานวิจัยนี้ปรับค่า Hyperparameter ได้แก่ Batch size, Epoch, Optimizer และ Activation function จากตัวแปร 23 ตัว ร่วมกับราคาย้อนหลัง 3 วัน เพื่อเพิ่มความสามารถในการพยากรณ์ควรปรับค่า Hyperparameter ใหม่เมื่อมีการเพิ่มตัวแปร นอกจากนี้การวิจัยนี้หาค่า Hyperparameter ด้วย Random Search ถ้าเพิ่มจำนวนรอบในการในการหา Hyperparameter หรือ ใช้เทคนิค Grid Search อาจเพิ่มประสิทธิภาพของแบบจำลองได้

3. จากการทดสอบตัวแปรที่มีอิทธิพลต่อแบบจำลองของงานวิจัยนี้พบว่า ราคาน้ำมันดิบในอดีตเป็นปัจจัยสำคัญที่ส่งผลต่อราคาน้ำมันดิบ รองลงมาคือดัชนีดอลลาร์ เพื่อประหยัดทรัพยากรด้านเวลา การปรับแต่งพารามิเตอร์ และการประมวลผล สามารถใช้แบบจำลอง ARIMAX ที่รองรับกับการใส่ตัวแปรภายนอกได้และสามารถจัดการกับข้อมูลที่มีจำนวนจำกัดได้ดี โดยอาจจะทำการลดมิติของข้อมูลให้ซับซ้อนน้อยลงโดยการตัดตัวแปรที่มีความสำคัญน้อยออกจากชุดข้อมูล

เอกสารอ้างอิง

- Akil, S., Sekkate, S., & Adib, A. (2024). "Multimodal Deep Learning for Oil Price Forecasting Using Economic Indicators". *Procedia Computer Science*, 236(396), 402-409. <https://doi.org/https://doi.org/10.1016/j.procs.2024.05.047>
- Alamgir, F., & Amin, S. B. (2021). The nexus between oil price and stock market: Evidence from South Asia. *Energy Reports*, 7(1), 693-703. <https://doi.org/https://doi.org/10.1016/j.egyr.2021.01.027>
- Aldabagh, H., Zheng, X., & Mukkamala, R. (2023). A Hybrid Deep Learning Approach for Crude Oil Price Prediction. *The Journal of Risk and Financial Management.*, 16(12), 503. <https://doi.org/https://doi.org/10.3390/jrfm16120503>
- Aldabagh, H., Zheng, X., Najand, M., & Mukkamala, R. (2024). Forecasting Crude Oil Price Using Multiple Factors. *The Journal of Risk and Financial Management.*, 17(9), 415. <https://doi.org/https://doi.org/10.3390/jrfm17090415>
- Assaad, R. H., & Fayek, S. (2021). Predicting the Price of Crude Oil and its Fluctuations Using Computational Econometrics: Deep Learning, LSTM, and Convolutional Neural Networks. *Econometric Research in Finance*, 6(2), 119-137. <https://doi.org/10.2478/erfin-2021-0006>
- Bhatt, B., Gaikwad, A. S., & Uganya, G. (2023). *The Fundamentals of Machine Learning*. London: LAP LAMBERT Academic Publishing.
- Bocianowski, J., Pilarek, D. W., Kaniewska, A. K., Matusiak, K., & Wiatrowska, B. (2024, May 15). *Comparison of Pearson's and Spearman's correlation coefficients values for selected traits of Pinus sylvestris L.* <https://doi.org/10.21203/rs.3.rs-4380975/v1>
- Cai, Y., Mignon, V., & Saadaoui, J. (2022). Not all political relation shocks are alike: Assessing the impacts of US–China tensions on the oil market. *ELSEVIER*, 114(3), 106199. <https://doi.org/10.1016/j.eneco.2022.106199>
- Cen, Z., & Wang, J. (2019). Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer. *Energy*, 169, 160-171. <https://doi.org/https://doi.org/10.1016/j.energy.2018.12.016>
- Chen, S., & He, H. (2018). Stock Prediction Using Convolutional Neural Network. *IOP Conf. Series: Materials Science and Engineering*. IOP. <https://doi.org/10.1088/1757-899X/435/1/012026>
- Cheng, F., Li, T., Wei, Y., & Fan, T. (2019). The VEC-NAR model for short-term forecasting of oil prices. *Energy Economics*, 78(2), 656-667. <https://doi.org/https://doi.org/10.1016/j.eneco.2017.12.035>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Christoph, M. (2024, July 31). *Permutation Feature Importance*. Retrieved from <https://christophm.github.io/interpretable-ml-book/feature-importance.html>
- Corporate Finance Institute. (2024, November). *Crude Oil Overview*. Retrieved November 2024, from <https://corporatefinanceinstitute.com/resources/economics/crude-oil-overview/>
- Deng, C., Ma, L., & Zeng, T. (2021). Crude Oil Price Forecast Based on Deep Transfer Learning: Shanghai Crude Oil as an Example. *Sustainability*, 13(24), 13770. <https://doi.org/https://doi.org/10.3390/su132413770>
- Hong Jing. (01 December 2024). *How Convolutional Layers Work in Deep Learning Neural Networks?* เ ข้ า ถึ ง ไ ต้ จ ำ ก jinglescode.github.io: <https://jinglescode.github.io/2020/11/01/how-convolutional-layers-work-deep-learning-neural-networks/>
- IBM. (2024, July 23). Retrieved from IBM: <https://www.ibm.com/think/topics/hyperparameter-tuning>
- IBM. (2024). *What are convolutional neural networks?* Retrieved December 2024, from IBM: <https://www.ibm.com/think/topics/convolutional-neural-networks>
- Jesus, D. P., Souza Bezerra, B. F., & Nóbrega Besarria, C. d. (2020). The non-linear relationship between oil prices and stock prices: Evidence from oil-importing and oil-exporting countries. *Research in International Business and Finance*, 54(101229). <https://doi.org/https://doi.org/10.1016/j.ribaf.2020.101229>
- Kumar, K. S., Swapna, V., Rani, J., & Gopal, V. H. (2018). Volatility of daily and Weekly Crude Oil Prices – A Statistical Perspective. *International Journal of Scientific Research in Mathematical and Statistical Sciences*, 5(5), 108-113. <https://doi.org/10.26438/ijrsmss/v5i5.108113>
- Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN-LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(5), 17351-17360. <https://doi.org/10.1007/s00521-020-04867-x>
- Lu, Q., Sun, S., Duan, H., & Wang, S. (2021). Analysis and forecasting of crude oil price based on the variable selection-LSTM integrated model. *Energy Informatics*, 4(2), 47. <https://doi.org/10.1186/s42162-021-00166-4>
- Ma, R. R., Xiong, T., & Bao, Y. (2021). The Russia-Saudi Arabia oil price war during the COVID-19 pandemic. *Energy Economics*, 102, 105517. <https://doi.org/10.1016/j.eneco.2021.105517>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Miao, H., Ramchander, S., Wang, T., & Yang, D. (2017). Influential factors in crude oil price forecasting. *Energy Economics*, 68, 77-88. <https://doi.org/https://doi.org/10.1016/j.eneco.2017.09.010>
- Nyngarika, A. M., & Tang, B.-j. (2018). Oil Price Factors: Forecasting on the Base of Modified ARIMA Model. *IOP Conference Series Earth and Environmental Science*, 192, 012058. <https://doi.org/10.1088/1755-1315/192/1/012058>
- Olah, C. (2015, August 27). *Understanding LSTM Networks*. Retrieved from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Ricci, M. (2024). *European Central Bank*. Retrieved from The link between oil prices and the US dollar: evidence and economic implications: https://www.ecb.europa.eu/press/economic-bulletin/focus/2024/html/ecb.ebbox202407_02~5ce155d504.en.html
- RiEnergia. (2023, January 3). *Will the oil market volatility of 2022 be repeated in 2023?* Retrieved from <https://rienergia.staffettaonline.com/articolo/35127/Will+the+oil+market+volatility+of+2022+be+repeated+in+2023/Finley#:~:text=The%20oil%20market%20in%202022,historically%20a%20very%20volatile%20commodity.>
- Sabrina, E., & Otaviano, C. (2023). *Unpacking the Relationship between Crude Oil Financialization and Volatility: The Tale of Speculative Positions*. The Policy Center for the New South (PCNS).
- Sen, A., & Choudhury, K. D. (2024). Forecasting the Crude Oil prices for last four decades using deep learning approach. *Resources Policy*, 88(4), 104438. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.104438>
- Stuke, A., Rinke, P., & Todorovic, M. (2021). Efficient hyperparameter tuning for kernel ridge regression with Bayesian optimization. *Machine Learning Science and Technology*, 2(3). <https://doi.org/10.1088/2632-2153/abee59>
- SuperAnnotate. (2023, October 12). *Activation functions in neural networks [Updated 2024]*. Retrieved January 13, 2025, from <https://www.superannotate.com/blog/activation-functions-in-neural-networks#:~:text=Therefore%2C%20in%20order%20for%20a,differentiable%2C%20including%20the%20activation%20function.>
- The International Energy Agency. (2024, September). *World Energy Balances Highlights*. Retrieved December 2024, from <https://www.iea.org/data-and-statistics/data-product/world-energy-balances-highlights>
- U.S. Energy Information Administration (EIA). (2019, January 2). *Energy commodity prices fell significantly in the last quarter of 2018*. Retrieved from

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- <https://www.eia.gov/todayinenergy/detail.php?id=37832#:~:text=Crude%20oil%20prices%20ended%202018,the%20first%20time%20since%202015.>
- U.S. Energy Information Administration (EIA). (2020, September 23). *OPEC+ agreement to reduce production contributes to global oil market rebalancing*. Retrieved from <https://www.eia.gov/todayinenergy/detail.php?id=45236#:~:text=On%20April%2015%2C%20members%20of,known%20as%20OPEC%2B%2C%20agreed%20to>
- U.S. Energy Information Administration (EIA). (2024, January 2). *Brent crude oil prices averaged \$19 per barrel less in 2023 than 2022*. Retrieved from <https://www.eia.gov/todayinenergy/detail.php?id=61142#:~:text=The%20price%20of%20Brent%20crude,demand%20fell%20short%20of%20expectations.>
- U.S. Energy Information Administration. (2024). *WHAT DRIVES CRUDE OIL PRICES?* Retrieved December 2024, from <https://www.eia.gov/finance/markets/crudeoil/supply-opec.php>
- Wang, Z. J., Turko, R., Shaikh, O., Park, H., Das, N., Hohman, F., . . . Chau, D. H. (2021). CNN EXPLAINER: Learning Convolutional Neural Networks with Interactive Visualization. *IEEE TRANSACTIONS ON VISUALIZATION AND COMPUTER GRAPHICS*, 27(2), 1396 - 1406. <https://doi.org/10.1109/TVCG.2020.3030418>
- Xu, Y., Duong, D., & Xu, H. (2023). Attention! Predicting crude oil prices from the perspective of extreme weather. *Elsevier*.
- Xu, Y., Liu, T., Fang, Q., Du, P., & Wang, J. (2024). *Crude oil price forecasting with multivariate selection, machine learning, and a nonlinear combination strategy*. Retrieved from ELSEVIER.
- Zhang, K., & Hong, M. (2022). Forecasting crude oil price using LSTM neural networks. *Data Science in Finance and Economics*, 2(3), 163-180. <https://doi.org/10.3934/DSFE.2022008>



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก
การตั้งค่า Hyperparameter ของแบบจำลอง
เพื่อทำ Random Search



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ก.1 การออกแบบโครงข่ายประสาทเทียม

วิจัยนี้อ้างอิงการออกแบบโครงข่ายประสาทเทียมและค่าพารามิเตอร์เริ่มต้นจากงานวิจัยของ Livieris. et al. (2020) และมีการทดลองเพิ่ม Max Pooling Layer ในแบบจำลอง CNN และ Dropout Layers ในแบบจำลอง LSTM (1) LSTM (2) และ CNN - LSTM โดยทำการประเมินประสิทธิภาพของแบบจำลองโดยใช้ข้อมูลย้อนหลัง 3 วัน พบว่า แบบจำลอง CNN ที่เพิ่ม Max Pooling Layer แบบจำลอง LSTM (1) และ CNN - LSTM ที่เพิ่ม Dropout ให้ประสิทธิภาพในการพยากรณ์ดีกว่าโดยประเมินจากค่า MAE MAPE RMSE และ R^2 ในขณะที่แบบจำลอง LSTM (2) แบบจำลองที่ไม่เพิ่ม Dropout Layer ให้ประสิทธิภาพการพยากรณ์ดีกว่า

ตารางที่ ก.1 เปรียบเทียบค่าความผิดพลาดของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN - LSTM ที่โครงสร้างแบบจำลองแตกต่างกัน

แบบจำลอง	Performance Metrics (Validation Dataset)							
	Model				Model with adding Max Pooling and Dropout Layers			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
CNN	1.5178	2.0621	1.9097	0.8352	1.3703	1.8450	1.7095	0.8679
LSTM (1)	1.3838	1.8525	1.7652	0.8592	1.3423	1.8169	1.7172	0.8667
LSTM (2)	1.4715	1.9725	1.8658	0.8427	1.6013	2.1656	2.0183	0.8159
CNN - LSTM	1.4859	2.0342	1.8855	0.8393	1.4286	1.9358	1.8512	0.8451

ก.2 Epoch ที่เหมาะสมสำหรับแบบจำลอง

จาก ก.1 นำแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN - LSTM มาทดลองหา Epoch ที่เหมาะสม โดยเปรียบเทียบระหว่าง Epoch 50 รอบ และ 100 รอบ พบว่า 100 รอบให้ประสิทธิภาพของทุกแบบจำลองดีกว่า 50 รอบ

ตารางที่ ก.2 เปรียบเทียบค่าความผิดพลาดของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN - LSTM ที่ Epoch เท่ากับ 50 รอบ และ 100 รอบ

แบบจำลอง	Performance Metrics (Validation Dataset)							
	Epoch = 50				Epoch = 100			
	MAE	MAPE	RMSE	R^2	MAE	MAPE	RMSE	R^2
CNN	1.3703	1.8450	1.7095	0.8679	1.2395	1.6658	1.5821	0.8869
LSTM (1)	1.3423	1.8169	1.7172	0.8667	1.3073	1.7649	1.6697	0.8740
LSTM (2)	1.4715	1.9725	1.8658	0.8427	1.3742	1.8441	1.7403	0.8631
CNN - LSTM	1.4859	2.0342	1.8855	0.8393	1.1573	1.5626	1.4736	0.9019

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้ทำซ้ำโดยไม่ได้รับอนุญาต

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ก.3 เปรียบเทียบค่าความผิดพลาดจากการทดลอง Optimizer และ Activation Function

จากตารางที่ ก.3 - ก.6 พบว่า Optimizer คือ Adam และ Activation Function คือ Tanh ให้ค่าความผิดพลาดต่ำสุดของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN - LSTM

ตารางที่ ก.3 เปรียบเทียบค่าความผิดพลาดของแบบจำลอง CNN ที่ Optimizer และ Activation Function ต่างกัน

แบบจำลอง	Epoch	Optimizer	Activation function	Performance Metrics (Validation Dataset)			
				MAE	MAPE	RMSE	R ²
CNN	100	Adam	Tanh	1.2395	1.6658	1.5821	0.8869
			Relu	1.9042	2.5555	2.4204	0.7353
		RMSprop	Tanh	1.7969	2.3633	2.3225	0.7562
			Relu	2.7610	3.7299	3.3297	0.4990

ตารางที่ ก.4 เปรียบเทียบค่าความผิดพลาดของแบบจำลอง LSTM (1) ที่ Optimizer และ Activation Function ต่างกัน

แบบจำลอง	Epoch	Optimizer	Activation function	Performance Metrics (Validation Dataset)			
				MAE	MAPE	RMSE	R ²
LSTM (1)	100	Adam	Tanh	1.3073	1.7649	1.6697	0.8740
			Relu	2.2732	3.0888	2.7614	0.6554
		RMSprop	Tanh	1.6768	2.2525	2.1270	0.7956
			Relu	2.4648	3.2996	2.9776	0.5994

ตารางที่ ก.5 เปรียบเทียบค่าความผิดพลาดของแบบจำลอง LSTM (2) ที่ Optimizer และ Activation Function ต่างกัน

แบบจำลอง	Epoch	Optimizer	Activation function	Performance Metrics (Validation Dataset)			
				MAE	MAPE	RMSE	R ²
LSTM (2)	100	Adam	Tanh	1.3742	1.8441	1.7403	0.8631
			Relu	1.9126	2.5584	2.4018	0.7393
		RMSprop	Tanh	2.0090	2.7059	2.4739	0.7234
			Relu	2.5082	3.3426	3.1507	0.5514

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่สามารถนำข้อมูลไปใช้ประโยชน์อื่นใดได้

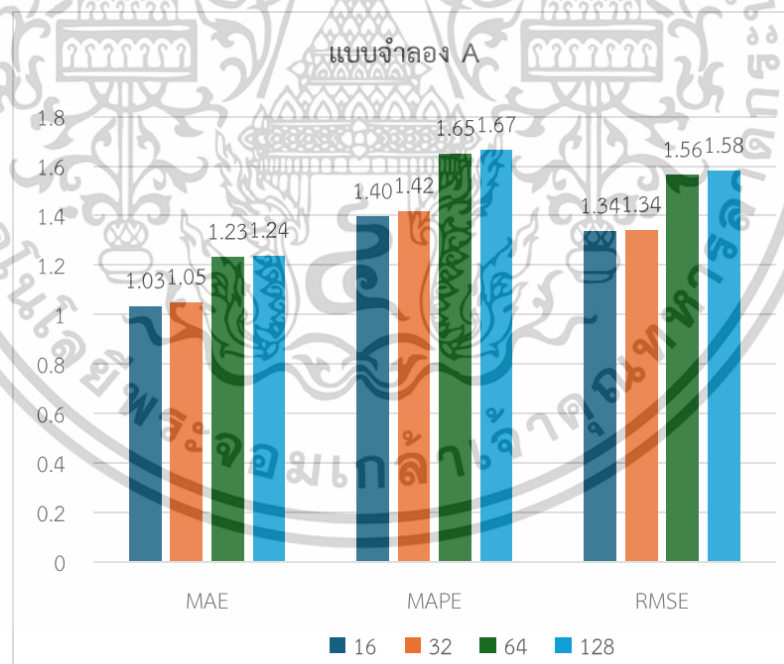
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.6 เปรียบเทียบค่าความผิดพลาดของแบบจำลอง CNN - LSTM ที่ Optimizer และ Activation Function ต่างกัน

แบบจำลอง	Epoch	Optimizer	Activation function	Performance Metrics (Validation Dataset)			
				MAE	MAPE	RMSE	R ²
CNN - LSTM	100	Adam	Tanh	1.1573	1.5626	1.4736	0.9019
			Relu	1.9737	2.6458	2.4216	0.7350
		RMSprop	Tanh	2.1404	2.8667	2.6520	0.6822
			Relu	2.7922	3.7486	3.4270	0.4693


ก.4 เปรียบเทียบค่าความผิดพลาดจากการทดลอง Batch Size

จากภาพที่ ก.1-ก.4 พบว่า Batch Size ที่เหมาะสมของแบบจำลอง CNN LSTM (1) LSTM (2) และ CNN - LSTM คือ 16

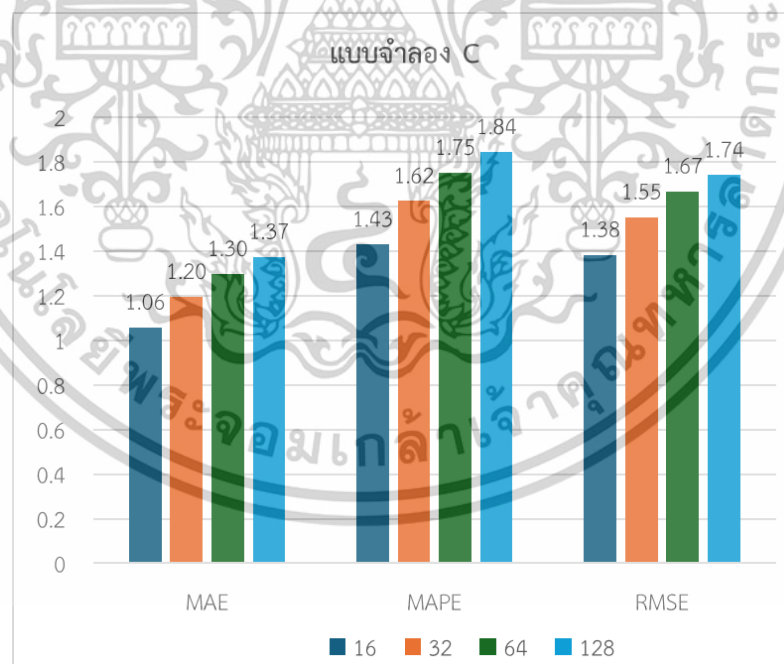


ภาพที่ ก.1 ค่า MAE MAPE และ RMSE ของแบบจำลอง CNN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ ก.2 ค่า MAE MAPE และ RMSE ของแบบจำลอง LSTM (1)



ภาพที่ ก.3 ค่า MAE MAPE และ RMSE ของแบบจำลอง LSTM (2)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ ก.4 ค่า MAE MAPE และ RMSE ของแบบจำลอง CNN - LSTM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ นางสาว ศิริพร ก้องจอลานนท์
วัน เดือน ปี เกิด 2 พฤศจิกายน 2036
ที่อยู่ปัจจุบัน 1325/44 เอกชัย 125 แขวง บางบอน เขต บางบอน กรุงเทพฯ 10150
ประวัติการศึกษา (2559) เศรษฐศาสตรบัณฑิต สาขา เศรษฐศาสตร์ เกรดเฉลี่ย 3.51
มหาวิทยาลัยศรีนครินทรวิโรฒ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้