วิเคราะห์เปรียบเทียบการพยากรณ์ความผันผวนของราคาหุ้นระหว่าง GARCH และ MACHINE LEARNING/DEEP LEARNING

โดย

ธรรศทัพพ์ สงวนสุข

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต (การบัญชีและการบริหารการเงิน)
สาขาวิชาการบัญชีและการบริหารการเงิน
คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์
ปีการศึกษา 2567

Ref. code: 25676602110550SKO

COMPARISON OF STOCK PRICE VOLATILITY FORECASTING: GARCH AND MACHINE LEARNING/DEEP LEARNING

BY

TASSATAP SANGUANSUK

AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE REQUIREMENTS FOR THE DEGREE OF MASTER OF SCIENCE (ACCOUNTING AND FINANCIAL MANAGEMENT)

ACCOUNTING AND FINANCIAL MANAGEMENT
FACULTY OF COMMERCE AND ACCOUNTANCY
THAMMASAT UNIVERSITY

ACADEMIC YEAR 2024

Ref. code: 25676602110550SKO

มหาวิทยาลัยธรรมศาสตร์
คณะพาณิชยศาสตร์และการบัญชี

การค้นคว้าอิสระ

ของ

ธรรศทัพพ์ สงวนสุข

เรื่อง

วิเคราะห์เปรียบเทียบการพยากรณ์ความผันผวนของราคาหุ้นระหว่าง
GARCH และ MACHINE LEARNING/DEEP LEARNING

ได้รับการตรวจสอบและอนุมัติ ให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต (การบัญชีและการบริหารการเงิน)

เมื่อ วันที่ 30 ก.ค. 2568

ประธานกรรมการสอบการค้นคว้าอิสระ .....
(ผู้ช่วยศาสตราจารย์ ดร.นพธนิษฐ์ โชติสาร)

กรรมการและอาจารย์ที่ปรึกษาการค้นคว้าอิสระ .....
(ผู้ช่วยศาสตราจารย์ ดร.วินัย นาดี)

คณบดี .....
(รองศาสตราจารย์ ดร.สมชาย สุภัทรกุล)

หัวข้อการค้นคว้าอิสระ	วิเคราะห์เปรียบเทียบการพยากรณ์ความผันผวนของราคาหุ้นระหว่าง GARCH และ MACHINE LEARNING/DEEP LEARNING
ชื่อผู้เขียน	ธรรศทัพพ์ สงวนสุข
ชื่อปริญญา	วิทยาศาสตรมหาบัณฑิต (การบัญชีและการบริหารการเงิน)
สาขาวิชา	การบัญชีและการบริหารการเงิน
คณะ	พาณิชยศาสตร์และการบัญชี
มหาวิทยาลัย	มหาวิทยาลัยธรรมศาสตร์
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ผู้ช่วยศาสตราจารย์ ดร.วินัย นาดี
ปีการศึกษา	2567

บทคัดย่อ

การศึกษาค้นคว้าอิสระฉบับนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของการพยากรณ์ความผันผวนของราคาหุ้นระหว่างแบบจำลอง GARCH กับเทคนิค Machine Learning และ Deep Learning โดยใช้ดัชนี S&P500 และ SET Index เป็นกรณีศึกษา ตัวแบบที่นำมาทดสอบประกอบด้วย GARCH, XGBoost, Random Forest, Support Vector Machine (SVM), Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU) และ Long Short-Term Memory (LSTM) โดยใช้ข้อมูลราคาหลักทรัพย์ย้อนหลัง 10 ปี และดำเนินการทดสอบทั้งในรูปแบบโมเดลเดี่ยว (Single Model) และโมเดลผสม (Hybrid Model) ที่ผสานค่า GARCH เข้ากับ Deep Learning

ผลการวิจัยพบว่า LSTM และ GRU สามารถพยากรณ์ความผันผวนได้แม่นยำที่สุดในทุกตลาดและทุกช่วงเวลา เมื่อพิจารณาจากค่าความคลาดเคลื่อน (MAE, MSE, RMSE) ขณะที่โมเดลผสมระหว่าง GARCH กับ Machine Learning อย่าง XGBoost และ Random Forest แสดงให้เห็นถึงการเพิ่มประสิทธิภาพอย่างชัดเจน ในทางกลับกัน การเพิ่ม GARCH เข้าไปในโมเดล Deep Learning กลับไม่เพิ่มประสิทธิภาพ และในบางกรณียังลดความแม่นยำลง นอกจากนี้ยังพบว่าการแยกข้อมูลช่วง COVID-19 ออก ช่วยให้โมเดลมีความแม่นยำในการพยากรณ์มากขึ้น

ข้อค้นพบเหล่านี้สะท้อนให้เห็นถึงศักยภาพของ Deep Learning ในการพยากรณ์ความผันผวนในตลาดทุนที่มีลักษณะข้อมูลไม่เป็นเส้นตรง และความสำคัญของการพิจารณาลักษณะของข้อมูลร่วมกับโครงสร้างของแบบจำลองที่เลือกใช้

Ref. code: 25676602110550SKO

คำสำคัญ: ความผันผวนของราคาหุ้น, ตลาดหลักทรัพย์, การพยากรณ์

Ref. code: 25676602110550SKO

Independent Study Title	COMPARISON OF STOCK PRICE VOLATILITY FORECASTING: GARCH AND MACHINE LEARNING/DEEP LEARNING
Author	Tassatap Sanguansuk
Degree	Master of Science (Accounting and Financial Management)
Major Field	Accounting and Financial Management
Faculty	Commerce and Accountancy
University	Thammasat University
Independent Study Advisor	Assistant Professor Winai Nadee, Ph.D.
Academic Year	2024

ABSTRACT

This independent study aims to compare the effectiveness of stock price volatility forecasting between traditional GARCH models and modern Machine Learning/Deep Learning techniques. The study utilizes historical data from the S&P500 and SET indices over the past decade, implementing models such as GARCH, XGBoost, Random Forest, Support Vector Machine (SVM), Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), and Long Short-Term Memory (LSTM). Both single-model and hybrid-model approaches are evaluated, with hybrid models incorporating GARCH-derived features into machine learning models.

The results indicate that Deep Learning models, particularly LSTM and GRU, outperform traditional models in terms of predictive accuracy, as measured by MAE, MSE, and RMSE, across both markets and time periods. Tree-based models like XGBoost and Random Forest also show improved performance when combined with GARCH features. Conversely, adding GARCH inputs to deep learning models often leads to marginal declines in performance, possibly due to redundancy or overfitting. The exclusion of the COVID-19 period from the dataset further improved model accuracy, supporting the importance of data stationarity in financial forecasting.

Ref. code: 25676602110550SKO

These findings underscore the potential of deep learning for modeling nonlinear, dynamic patterns in financial markets and emphasize the importance of model selection based on data characteristics and use-case requirements.

Keywords: Volatility Forecasting, Machine Learning, Deep Learning

Ref. code: 25676602110550SKO

กิตติกรรมประกาศ

การศึกษาค้นคว้าอิสระนี้สามารถสำเร็จลุล่วงไปได้ด้วยดีเนื่องจากได้รับความกรุณาเป็นอย่างยิ่งจากผู้ช่วยศาสตราจารย์ ดร.วินัย นาดี อาจารย์ที่ปรึกษางานวิจัย ที่ให้คำแนะนำและช่วยชี้แนะแนวทางการทำวิจัยอย่างต่อเนื่อง ด้วยความเอาใจใส่และอดทน ผู้วิจัยรู้สึกขอบพระคุณเป็นอย่างยิ่งที่ความทุ่มเทจากอาจารย์ และขอขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.นพธนิษฐ์ โชติสาร ที่กรุณาให้เกียรติมาเป็นประธานกรรมการสอบ และให้ข้อเสนอแนะเพิ่มเติมที่เป็นประโยชน์อย่างยิ่งส่งผลให้งานวิจัยฉบับนี้มีความสมบูรณ์และถูกต้องมากยิ่งขึ้น

นอกจากนี้ข้าพเจ้าขอขอบพระคุณอาจารย์และเจ้าหน้าที่ประจำหลักสูตรควบตรี–โท คณะพาณิชยศาสตร์และการบัญชีมหาวิทยาลัยธรรมศาสตร์ทุกท่านสำหรับองค์ความรู้และประสบการณ์ที่ข้าพเจ้าได้รับตลอดระยะเวลาที่ศึกษา และสำหรับการประสานงานต่าง ๆ

สุดท้ายนี้ขอขอบคุณครอบครัวบุคคลใกล้ชิดที่คอยเป็นกำลังใจและอยู่เคียงข้างเสมอ รวมถึงเพื่อน ๆ และทุกคนที่มีส่วนช่วยเหลือ ให้คำปรึกษา และสนับสนุนในการดำเนินการศึกษาค้นคว้าอิสระฉบับนี้จนสำเร็จลุล่วง

ธรรศทัพพ์ สงวนสุข

Ref. code: 25676602110550SKO

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	(1)
บทคัดย่อภาษาอังกฤษ	(3)
กิตติกรรมประกาศ	(5)
สารบัญตาราง	(10)
สารบัญภาพ	(12)
รายการสัญลักษณ์และคำย่อ	(17)
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ	1
1.2 วัตถุประสงค์ของการศึกษา	3
1.3 คำถามการวิจัย	4
1.4 กรอบแนวคิดการวิจัย	5
1.5 ขอบเขตการศึกษา	6
1.6 ประโยชน์ที่คาดว่าจะได้รับ	6
บทที่ 2 วรรณกรรมและงานวิจัยที่เกี่ยวข้อง	7
2.1 คำนิยามที่เกี่ยวข้อง	7
2.1.1 หุ้นสามัญ (Common Stock)	7
2.1.2 ความผันผวน (Volatility)	7
2.1.3 เศรษฐมิติ (Econometrics)	8
2.1.4 การเรียนรู้ของเครื่อง (Machine Learning)	8

Ref. code: 25676602110550SKO

2.1.5 การเรียนรู้เชิงลึก (Deep Learning) 8
2.1.6 ตลาดหลักทรัพย์แห่งประเทศไทย (SET) 9
2.1.7 ดัชนีตลาดหลักทรัพย์แห่งประเทศไทย (SET Index) 9
2.1.8 ดัชนี S&P 500 (Standard & Poor's 500 Index) 9
2.2 งานวิจัยที่เกี่ยวข้อง 10
2.2.1 การศึกษาความผันผวนของตลาดการเงิน 10
2.2.2 แมชชีนเลิร์นนิ่ง (Machine learning) 12
2.2.3 การผสานโมเดลดีปเลิร์นนิงร่วมกับแบบจำลอง GARCH 15

บทที่ 3 วิธีการวิจัย 21

3.1 ประชากรและกลุ่มตัวอย่าง 21
3.2 โมเดลที่สร้างจากเทคนิคการเรียนรู้ของเครื่องและเทคนิคการเรียนรู้เชิงลึก 21
3.2.1 เอ็กซ์ตรีมเกรเดียนต์บูสติ้ง 21
3.2.2 แรนดอมฟอเรสต์ 22
3.2.3 ซัพพอร์ตเวกเตอร์แมชชีน 23
3.2.4 รีเคอร์เรนท์นิวรัลเน็ตเวิร์ก 23
3.2.5 เกตเตดรีเคอร์เรนท์ยูนิต 24
3.2.6 ลองชอร์ตเทอมเมมโมรี 25
3.3 วิธีการดำเนินการวิจัย 27
3.3.1 การเก็บข้อมูล (Data Gathering) 27
3.3.2 การจัดการข้อมูล (Data Preprocessing) 27
3.3.2.1 ผลตอบแทนรายวันเชิงลอการิทึม (Log Returns) 28
3.3.2.2 ช่วงการซื้อขายเชิงลอการิทึม (Log Trading Range) 28
3.3.2.3 อัตราการเปลี่ยนแปลงของปริมาณการซื้อขายเชิงลอการิทึม (Log Volume Change) 29
3.3.2.4 อัตราความผันผวนย้อนหลัง n วัน (Previous n day Volatility) 29
3.3.3 การฝึกสอนตัวแบบ (Model Training) 29
3.3.4 การทดสอบตัวแบบ (Model Testing) 30

Ref. code: 25676602110550SKO

3.4 ค่าสถิติที่ใช้ในการเปรียบเทียบความแม่นยำของตัวแบบ (Evaluation Metrics) 31
3.4.1 ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) 31
3.4.2 ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error: MSE) 31
3.4.3 รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) 32

บทที่ 4 ผลการวิจัยและอภิปรายผล 33

4.1การวิเคราะห์ผลการทดลอง 33
4.1.1 ประสิทธิภาพการพยากรณ์โมเดลเดี่ยว (Single model) 33
4.1.1.1 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี S&P500 33
4.1.1.2 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี SET 39
4.1.2 ประสิทธิภาพการพยากรณ์โมเดลผสม (Hybrid model) 45
4.1.2.1 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนีS&P500 45
4.1.2.2 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนี SET 49
4.1.3 ประสิทธิภาพการพยากรณ์โมเดลเดี่ยว (Single model) บนข้อมูลที่ไม่รวมช่วง Covid-19 54
4.1.3.1 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี S&P500 ไม่รวมช่วง Covid-19 54
4.1.3.2 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี SET ไม่ รวมช่วง Covid-19 59
4.1.4 ประสิทธิภาพการพยากรณ์โมเดลผสม (Hybrid model) บนข้อมูลที่ไม่รวมช่วง Covid-19 65
4.1.4.1 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี S&P500ไม่รวมช่วง Covid-19 65

Ref. code: 25676602110550SKO

4.1.4.2 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนี SET ไม่ รวมช่วง Covid-19 69

บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ 75

5.1 สรุปผลการวิจัย 75
5.2 ข้อจำกัดในงานวิจัย 76
5.2.1 ข้อมูลที่ใช้ในการสร้างตัวแบบ 76
5.2.2 จำนวนตัวแปรอิสระ 76
5.2.3 ข้อจำกัดด้านทรัพยากรฮาร์ดแวร์ในการประมวลผลโมเดล 76
5.2.4 ข้อจำกัดด้านการกำหนดพารามิเตอร์ของโมเดล (Hyperparameter Tuning) 77
5.3 ข้อเสนอแนะและแนวทางในการทำวิจัยในขั้นถัดไป 77
5.3.1 ขยายขอบเขตของข้อมูล 77
5.3.2 การปรับเปลี่ยนหรือเพิ่มเติมตัวแปรอิสระอื่น ๆ 78
5.3.3 การประเมินผลด้วยเกณฑ์เพิ่มเติมนอกเหนือจาก MAE/MSE/RMSE 78
5.3.4 การปรับเปลี่ยน Time Step ในการพยากรณ 78

รายการอ้างอิง 79

ภาคผนวก

ภาคผนวก ก กระบวนการเทรนโมเดล 84

ประวัติผู้เขียน 96

Ref. code: 25676602110550SKO

สารบัญตาราง

ตารางที่ หน้า

4.1 ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี S&P500 34

4.2 ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี S&P500 35

4.3 ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนีS&P500 38

4.4 ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี SET 40

4.5 ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี SET 41

4.6 ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET 44

4.7 ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี S&P500 49

4.8 ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET 53

4.9 ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี S&P500 ไม่รวมช่วง Covid-19 55

4.10 ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี S&P500 ไม่รวมช่วง Covid-19 55

4.11 ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี S&P500 ไม่รวม ช่วง Covid-19 58

4.12 ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี SET ไม่รวมช่วง Covid-19 60

4.13 ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี SET ไม่ รวมช่วง Covid-19 60

4.14 ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET ไม่รวมช่วง Covid-19 63

Ref. code: 25676602110550SKO

4.15 ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวน ราคาดัชนี S&P500 ไม่รวม ช่วง Covid-19 68

4.16 ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวน ราคาดัชนี SET ไม่รวมช่วง Covid-19 73

Ref. code: 25676602110550SKO

สารบัญภาพ

ภาพที่	หน้า
1.1 กรอบแนวคิดการวิจัย	5
2.1 Error Measures for MSFT	14
2.2 Hybrid GARCH-GRU model structure	16
2.3 S&P 500, Bitcoin and gold's daily prices	16
2.4 Comparison of volatility forecasts based on the MSE loss function across all models and distributions for S&P 500	17
2.5 โครงสร้างแบบจำลอง GE-LSTM hybrid model	18
2.6 Results of out-of-sample forecasts with various loss functions	19
2.7 Diebold–Mariano test for the MAE difference on real data	20
3.1 ภาพเปรียบเทียบ single decision tree กับ random forest	22
3.2 ขั้นตอนการทำ Random forest	23
3.3 โครงสร้างของ Recurrent Neural Network (RNN)	24
3.4 โครงสร้างของ GRU (Gated Recurrent Unit)	25
3.5 โครงสร้างโดยรวมของเครือข่าย LSTM แบบลำดับเวลา (Sequential LSTM Architecture)	26
3.6 รายละเอียดภายในเซลล์ LSTM (LSTM Cell Structure with Gates: Forget, Input, Output)	26
3.7 โครงสร้างของเครือข่าย LSTM	30
4.1 กราฟเส้นแสดงความผันผวนที่พยากรณ์GARCH กับอัตราความผันผวนหลักทรัพย์ดัชนี S&P500	34
4.2 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บน ดัชนี S&P500	35
4.3 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บน ดัชนี S&P500	36
4.4 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บน ดัชนี S&P500	36
4.5 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี S&P500	37

Ref. code: 25676602110550SKO

4.6 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RandomForest บนดัชนี S&P500 37
4.7 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Support Vector Machine บนดัชนี S&P500 38
4.8 กราฟเส้นแสดงความผันผวนที่พยากรณ์GARCH กับอัตรา ความผันผวนหลักทรัพย์ดัชนี SET 40
4.9 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บน ดัชนี SET 41
4.10 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บน ดัชนี SET 42
4.11 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บน ดัชนี SET 42
4.12 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี SET 43
4.13 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random Forest บนดัชนี SET 43
4.14 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Support Vector Machine บนดัชนี SET 44
4.15 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บน ดัชนี S&P500 46
4.16 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี S&P500 46
4.17 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี S&P500 47
4.18 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บน ดัชนี S&P500 47
4.19 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Random Forest บนดัชนี S&P500 48
4.20 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี S&P500 48

Ref. code: 25676602110550SKO

4.21 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บน ดัชนี SET 50
4.22 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี SET 50
4.23 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี SET 51
4.24 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บน ดัชนี SET 51
4.25 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บน ดัชนี SET 52
4.26 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี SET 52
4.27 กราฟเส้นแสดงความผันผวนที่พยากรณ์GARCH กับอัตราความผันผวนหลักทรัพย์ดัชนี S&P500 ไม่ รวมช่วง Covid-19 54
4.28 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บน ดัชนี S&P500 ไม่รวมช่วง Covid-19 55
4.29 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บน ดัชนี S&P500 ไม่รวมช่วง Covid-19 56
4.30 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บน ดัชนี S&P500 ไม่รวมช่วง Covid-19 56
4.31 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี S&P500 ไม่รวมช่วง Covid-19 57
4.32 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random Forest บนดัชนี S&P500 ไม่รวมช่วง Covid-19 57
4.33 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บน ดัชนี S&P500 ไม่รวมช่วง Covid-19 58
4.34 กราฟเส้นแสดงความผันผวนที่พยากรณ์GARCH กับอัตราความผันผวนหลักทรัพย์ดัชนี SET ไม่รวม ช่วง Covid-19 59
4.35 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บน ดัชนี SET ไม่รวมช่วง Covid-19 60

Ref. code: 25676602110550SKO

4.36 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บน ดัชนี SET ไม่รวมช่วง Covid-19 61
4.37 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บน ดัชนี SET ไม่รวมช่วง Covid-19 61
4.38 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random Forest บนดัชนี SET ไม่รวมช่วง Covid-19 62
4.39 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี SET ไม่รวมช่วง Covid-19 62
4.40 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Support Vector Machine บนดัชนี SET ไม่รวมช่วง Covid-19 63
4.41 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บน ดัชนี S&P500 ไม่รวมช่วง Covid-19 65
4.42 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี S&P500 ไม่รวมช่วง Covid-19 66
4.43 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี S&P500 ไม่รวมช่วง Covid-19 66
4.44 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บน ดัชนี S&P500 ไม่รวมช่วง Covid-19 67
4.45 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Random Forest บนดัชนี S&P500 ไม่รวมช่วง Covid-19 67
4.46 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี S&P500 ไม่รวมช่วง Covid-19 68
4.47 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บน ดัชนี SET ไม่รวมช่วง Covid-19 70
4.48 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี SET ไม่รวมช่วง Covid-19 70
4.49 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี SET ไม่รวมช่วง Covid-19 71
4.50 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บน ดัชนี SET ไม่รวมช่วง Covid-19 71

Ref. code: 25676602110550SKO

4.51 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Random Forest บนดัชนี SET ไม่รวมช่วง Covid-19 72
4.52 กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี SET ไม่รวมช่วง Covid-19 72

Ref. code: 25676602110550SKO

รายการสัญลักษณ์และคำย่อ

สัญลักษณ์/คำย่อ	คำเต็ม/คำจำกัดความ
ANN	Artificial Neural Network
ML	Machine Learning
DL	Deep Learning
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
LSTM	Long Short-Term Memory
GRU	Gated Recurrent Unit
SET	The Stock Exchange of Thailand
S&P500	Standard & Poor's 500
SVM	Support Vector Machine
ARIMA	Auto Regressive Integrated Moving Average
XGBoost	Extreme Gradient Boosting
RNN	Recurrent Neural Network

Ref. code: 25676602110550SKO

บทที่ 1
บทนำ

1.1 ที่มาและความสำคัญ

สำหรับผู้ที่ลงทุนหรือมีความเกี่ยวข้องกับตลาดหลักทรัพย์ สิ่งที่น่ากลัวที่สุดคือความไม่แน่นอนในอนาคตหรือเรียกว่าความเสี่ยงนั้นเอง เมื่อมองเข้าไปลึกกว่านั้นหนึ่งในความเสี่ยงที่ต้องระวังเป็นอันดับแรก ๆ คือ ความเสี่ยงที่เกิดจากความผันผวนของราคาหลักทรัพย์ ทำให้มีนักการเงินและเศรษฐศาสตร์หลายคนในอดีตพยายามจะพยากรณ์หรือคาดการณ์ความผันผวนออกมาในรูปแบบต่างๆ เช่น การใช้ราคาเฉลี่ยย้อนหลังมาคำนวณกลายเป็น Simple Moving Average (SMA) หรือนำค่าเบี่ยงเบนมาตรฐานมาใช้เกิดเป็น Bollinger Band (BB) เมื่อเวลาผ่านไปก็เกิดการพัฒนาและเพิ่มความซับซ้อนเข้าไปในสมการต่างๆ จึงเกิดการประยุกต์ใช้หลักการเชิงสถิติเข้ามาช่วย

หลักการเชิงสถิติโดยเฉพาะในด้านการพยากรณ์ (Forecasting) นับว่ามีความสำคัญและได้รับการนำไปประยุกต์ใช้อย่างแพร่หลายในหลากหลายสาขา ไม่ว่าจะเป็นการพยากรณ์สภาพอากาศ การคาดการณ์ความต้องการใช้พลังงาน ไปจนถึงการประยุกต์ใช้ในภาคการเงินเพื่อคาดการณ์ความผันผวนของราคาสินทรัพย์ทางการเงิน เช่น หุ้น ตราสารหนี้ และอนุพันธ์ทางการเงินต่าง ๆ ซึ่งมีผลโดยตรงต่อการวางแผนกลยุทธ์การลงทุนและการบริหารความเสี่ยงในตลาดทุน ตลอดช่วงหลายทศวรรษที่ผ่านมา นักวิจัยและนักวิเคราะห์ได้พัฒนาแบบจำลองทางสถิติและอนุกรมเวลาหลากหลายรูปแบบขึ้นมาเพื่อรองรับการพยากรณ์ความผันผวนของข้อมูลเหล่านี้ ตัวอย่างเช่น Autoregressive Integrated Moving Average (ARIMA) ซึ่งเป็นแบบจำลองพื้นฐานที่ได้รับความนิยมในหลากหลายสาขา และ Generalized Autoregressive Conditional Heteroskedasticity (GARCH) ที่ได้รับการออกแบบมาโดยเฉพาะสำหรับจัดการกับข้อมูลทางการเงินที่มีความผันผวนเปลี่ยนแปลงอยู่ตลอดเวลาอย่างไรก็ตาม แม้ว่าจะมีการพัฒนาแบบจำลองเหล่านี้อย่างต่อเนื่อง แต่ก็ยังคงมีข้อจำกัดและความท้าทายหลายประการในการนำไปใช้กับข้อมูลจริง โดยเฉพาะในบริบทของข้อมูลทางการเงินซึ่งมักมีลักษณะ ไม่เป็นเส้นตรง (Non-linearity) และมีความผันผวนที่ไม่แน่นอนสูง ทำให้แบบจำลองที่ถูกพัฒนาขึ้นบนพื้นฐานของ แนวโน้มเชิงเส้น (Linear Trends) อาจไม่สามารถสะท้อนพฤติกรรมจริงของตลาดได้อย่างแม่นยำ ส่งผลให้ผลลัพธ์ของการพยากรณ์เกิดความคลาดเคลื่อนอย่างมีนัยสำคัญเมื่อเปรียบเทียบกับสิ่งที่เกิดขึ้นจริง นอกจากนี้ ข้อมูลอนุกรมเวลาทางการเงินยังมีลักษณะเฉพาะที่สำคัญอีกประการหนึ่ง คือ ภาวะความแปรปรวนไม่คงที่ (Heteroscedasticity) ซึ่งหมายถึงการที่ความแปรปรวนของผลตอบแทนเปลี่ยนแปลงไปตามเวลา โดยเฉพาะในช่วงที่ตลาดเกิดความผัน

Ref. code: 25676602110550SKO

ผวนรุนแรง เช่น ช่วงวิกฤตเศรษฐกิจหรือเหตุการณ์สำคัญที่ส่งผลต่อราคาสินทรัพย์ ลักษณะเช่นนี้ถือเป็นสิ่งที่พบได้ทั่วไปในข้อมูลทางการเงินและส่งผลต่อความแม่นยำของการพยากรณ์โดยตรง ในทางกลับกัน แบบจำลองการถดถอยทั่วไป (Regression Model) มักตั้งสมมติฐานพื้นฐานว่า Homoskedasticity หรือความแปรปรวนของพจน์ความผิดพลาด (Error Term) มีค่าคงที่ตลอดช่วงเวลา ซึ่งสมมติฐานนี้มักไม่สอดคล้องกับลักษณะของข้อมูลทางการเงินในโลกแห่งความเป็นจริง ด้วยเหตุนี้ จึงจำเป็นต้องมีการพัฒนาแบบจำลองที่สามารถรองรับเงื่อนไข Heteroscedasticity ได้อย่างมีประสิทธิภาพ อาทิ แบบจำลอง GARCH และแบบจำลองต่อยอดอื่น ๆ ที่สามารถอธิบายและพยากรณ์พฤติกรรมความผันผวนที่เปลี่ยนแปลงไปตามกาลเวลา โดยพิจารณาว่าข้อมูลในอดีตมีผลต่อระดับความผันผวนในอนาคต (Hamilton, 1994) ซึ่งช่วยเพิ่มความแม่นยำในการคาดการณ์ความเสี่ยงและความผันผวนของผลตอบแทนในตลาดการเงินได้ดียิ่งขึ้น ด้วยเหตุนี้การเลือกใช้แบบจำลองที่เหมาะสมซึ่งสามารถรองรับลักษณะเฉพาะของข้อมูลทางการเงินได้อย่างครบถ้วน จึงเป็นหัวใจสำคัญของการพยากรณ์ความผันผวนในบริบทของตลาดการเงินยุคปัจจุบัน

นอกจากการพัฒนาแบบจำลองทางสถิติและอนุกรมเวลาต่าง ๆ แล้ว ในช่วงหลายปีที่ผ่านมา แนวคิดเรื่องแมชชีนเลิร์นนิ่ง (Machine Learning) ได้เข้ามามีบทบาทสำคัญและได้รับความสนใจเพิ่มมากขึ้นในงานวิจัยและการประยุกต์ใช้ในหลากหลายสาขา รวมถึงในภาคการเงิน โดยเฉพาะในด้านการพยากรณ์ความผันผวนและผลตอบแทนของสินทรัพย์ทางการเงิน ด้วยศักยภาพของแมชชีนเลิร์นนิ่งในการเรียนรู้จากข้อมูลจำนวนมหาศาลและจับความสัมพันธ์เชิงซ้อนที่มีความไม่เป็นเชิงเส้น (Non-linearity) ได้อย่างมีประสิทธิภาพ ส่งผลให้เครื่องมือและเทคนิคเหล่านี้สามารถเอาชนะข้อจำกัดของแบบจำลองทางสถิติแบบดั้งเดิมที่มักตั้งอยู่บนสมมติฐานเชิงเส้นและข้อจำกัดเรื่องโครงสร้างของโมเดลได้เป็นอย่างดี มีการศึกษาจำนวนมากที่นำเทคนิคแมชชีนเลิร์นนิ่งหลากหลายรูปแบบ อาทิ Random Forest, Support Vector Machine (SVM), Neural Networks รวมถึง Deep Learning มาประยุกต์ใช้กับข้อมูลทางการเงิน โดยเฉพาะในด้านการพยากรณ์ความผันผวนของผลตอบแทน (Volatility Forecasting) และพบว่ามีประสิทธิภาพเหนือกว่าแบบจำลองทางสถิติแบบดั้งเดิมในหลายกรณี ทั้งในแง่ของความแม่นยำในการพยากรณ์และความสามารถในการรับมือกับข้อมูลที่มีความซับซ้อนสูง การเข้ามาของเทคโนโลยีแมชชีนเลิร์นนิ่งจึงถือเป็นพัฒนาการสำคัญที่ช่วยเพิ่มศักยภาพในการวิเคราะห์และพยากรณ์ข้อมูลทางการเงิน โดยเฉพาะในยุคที่ข้อมูลมีความหลากหลายและมีความผันผวนสูงอย่างต่อเนื่องเช่นในปัจจุบัน ทำให้การประยุกต์ใช้โมเดลเหล่านี้เป็นทางเลือกสำคัญในการเพิ่มความแม่นยำและประสิทธิภาพของการวิเคราะห์ความเสี่ยงและการตัดสินใจลงทุนในตลาดการเงิน

Ref. code: 25676602110550SKO

จากศักยภาพของแมชชีนเลิร์นนิ่งที่สามารถจัดการกับข้อมูลที่มีความซับซ้อนและไม่เป็นเชิงเส้นได้อย่างมีประสิทธิภาพ จึงได้เกิดแนวทางการพัฒนาแบบจำลองไฮบริด (Hybrid Models) ที่ผสานข้อดีของ แบบจำลองทางสถิติแบบดั้งเดิม เข้ากับ เทคนิคแมชชีนเลิร์นนิ่ง เพื่อเพิ่มความแม่นยำในการพยากรณ์ความผันผวนของตลาดการเงิน โดยหนึ่งในแนวทางสำคัญที่ได้รับความสนใจอย่างมาก คือ การนำแบบจำลอง GARCH มาประยุกต์ร่วมกับ Machine Learning เนื่องจาก GARCH มีจุดแข็งในการอธิบายลักษณะ Heteroscedasticity หรือความแปรปรวนที่เปลี่ยนแปลงไปตามเวลา ซึ่งเป็นลักษณะสำคัญของข้อมูลทางการเงิน ขณะที่ Machine Learning สามารถเรียนรู้รูปแบบความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นจากข้อมูลจำนวนมากได้ การผสานโมเดลทั้งสองจึงช่วยลดข้อจำกัดของกันและกัน และเพิ่มศักยภาพในการพยากรณ์ผลตอบแทนและความผันผวนของสินทรัพย์ทางการเงินได้ดียิ่งขึ้น ตัวอย่างของการประยุกต์ ได้แก่ การใช้ GARCH ในการสร้างหรือแยกองค์ประกอบของความผันผวนออกมาเป็นตัวแปรอธิบาย (Features) เพื่อป้อนเข้าสู่โมเดล Machine Learning เช่น Random Forest หรือ Neural Network เพื่อเพิ่มความแม่นยำในการพยากรณ์ หรือในทางกลับกัน อาจใช้ Machine Learning ช่วยวิเคราะห์หาพารามิเตอร์หรือโครงสร้างของ GARCH ให้เหมาะสมกับข้อมูลมากที่สุด ซึ่งช่วยให้โมเดลสามารถสะท้อนลักษณะเชิงพลวัตของตลาดได้อย่างมีประสิทธิภาพ งานวิจัยหลายชิ้นพบว่าโมเดลไฮบริดลักษณะนี้สามารถเพิ่มความแม่นยำในการพยากรณ์ความผันผวนและลดข้อผิดพลาดจากการใช้ GARCH หรือ Machine Learning เพียงอย่างเดียวได้อย่างมีนัยสำคัญ โดยเฉพาะในช่วงเวลาที่ตลาดมีความผันผวนสูงหรือเกิดเหตุการณ์ไม่คาดฝัน ทำให้แนวทางการผสมผสาน GARCH เข้ากับ Machine Learning เป็นอีกหนึ่งทิศทางสำคัญที่ได้รับความสนใจและมีแนวโน้มเติบโตอย่างต่อเนื่องในสายงานวิจัยและการวิเคราะห์ทางการเงินยุคใหม่

1.2 วัตถุประสงค์ของการศึกษา

งานค้นคว้าอิสระนี้มุ่งเน้นศึกษาถึงศักยภาพและเปรียบเทียบประสิทธิภาพของการประยุกต์ใช้ เทคนิคแมชชีนเลิร์นนิ่ง ที่หลากหลายในการพยากรณ์ความผันผวนของราคาหลักทรัพย์ งานวิจัยนี้จึงมุ่งเน้นการทดลองใช้โมเดลสำคัญ ได้แก่ Extreme Gradient Boosting (XGBoost), Random Forest, Support Vector Machine (SVM), Long Short-Term Memory (LSTM) และ Gated Recurrent Unit (GRU) ซึ่งล้วนเป็นเทคนิคที่ได้รับการยอมรับอย่างแพร่หลายในด้านการประมวลผลข้อมูลเชิงเวลา (Time-Series Data) และการวิเคราะห์ข้อมูลที่มีความซับซ้อนสูง โดยแต่ละเทคนิคมีจุดเด่นและความสามารถเฉพาะตัวในการจัดการกับข้อมูลที่มีความผันผวนและไม่เป็นเชิงเส้น (Non-linear) ซึ่งเป็นลักษณะสำคัญของข้อมูลราคาหลักทรัพย์ในตลาดการเงิน การเปรียบเทียบ

Ref. code: 25676602110550SKO

ผลลัพธ์ของโมเดลเหล่านี้จะช่วยให้เห็นถึงขีดความสามารถของแต่ละเทคนิคในการคาดการณ์ความผันผวน รวมถึงประเมินความเหมาะสมในการนำไปประยุกต์ใช้ในบริบทของการวิเคราะห์และบริหารความเสี่ยงทางการเงินในอนาคต

การทดสอบประสิทธิภาพของเทคนิคแมชชีนเลิร์นนิ่งและแบบจำลอง GARCH สามารถแบ่งออกเป็นวัตถุประสงค์ได้ดังนี้

1.2.1 เพื่อศึกษาและเปรียบเทียบการประยุกต์ใช้เทคนิคแมชชีนเลิร์นนิ่งเพื่อพยากรณ์ความผันผวนของราคาหลักทรัพย์

1.2.2 เพื่อศึกษาการผสานเทคนิคแมชชีนเลิร์นนิ่ง เข้ากับแบบจำลอง GARCH เพื่อใช้ในการพยากรณ์ความผันผวนของราคาหลักทรัพย์

1.2.3 เพื่อศึกษาการผสานเทคนิคแมชชีนเลิร์นนิ่งเพื่อพยากรณ์ ในช่วง Covid-19 ถ้าหากตัดชุดข้อมูลที่มีความผันผวนผิดปกติจะให้ค่าความคลาดเคลื่อนระหว่างผลการพยากรณ์กับค่าความจริง (Prediction Error) แตกต่างจากการพยากรณ์ด้วยแบบจำลอง GARCH เพียงอย่างเดียวหรือไม่

1.3 คำถามการวิจัย

1.3.1 การใช้แมชชีนเลิร์นนิ่งแบบใดจะสามารถทำให้ความคลาดเคลื่อนของผลและความเป็นจริงที่น้อยที่สุด

1.3.2 GARCH สามารถช่วยทำให้ผลการพยากรณ์ของแมชชีนเลิร์นนิ่งดีขึ้นได้จริงหรือไม่

1.3.3 การตัดข้อมูลที่มีความผันผวนไม่ปกติอย่างเช่นช่วง Covid-19 จะทำให้โมเดลพยากรณ์นายได้ดีขึ้นหรือไม่

Ref. code: 25676602110550SKO

1.4 กรอบแนวคิดการวิจัย

ภาพที่ 1.1

กรอบแนวคิดการวิจัย

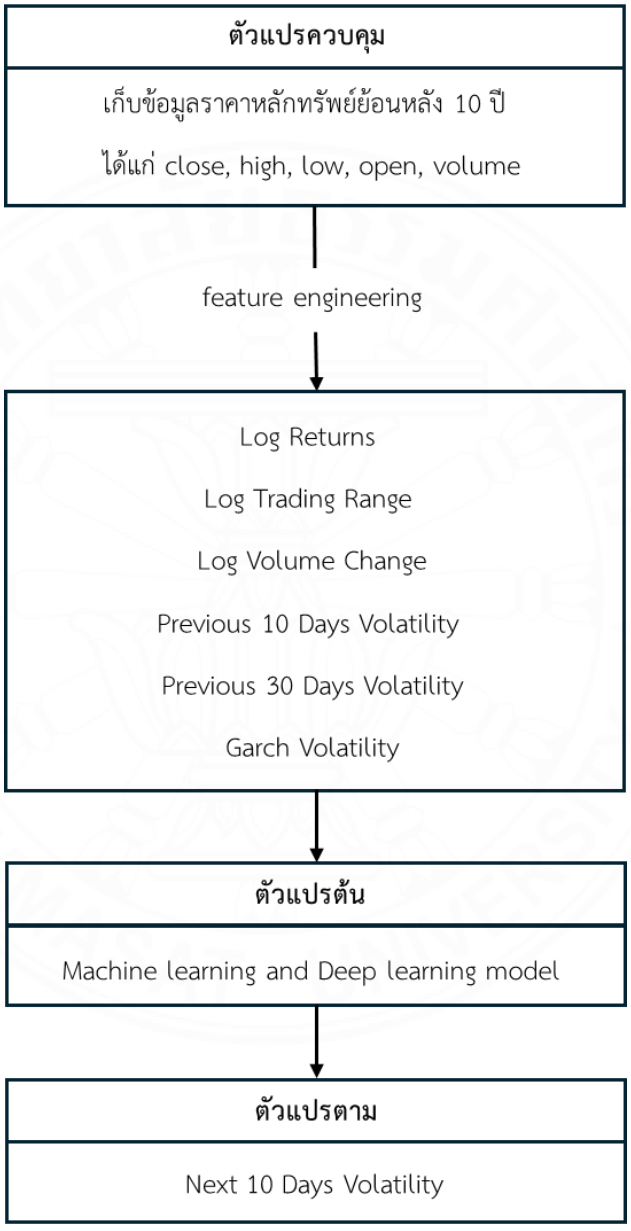

Ref. code: 25676602110550SKO

1.5 ขอบเขตการศึกษา

การศึกษานี้ใช้ข้อมูลการเคลื่อนไหวของราคาสินทรัพย์ในอดีตโดยใช้กรอบระยะเวลาย้อนหลัง 10 ปี เริ่มตั้งแต่วันที่ 1 มกราคม พ.ศ. 2558 ถึงวันที่ 31 ธันวาคม พ.ศ. 2567 เมื่อได้ราคารายวันมาแล้วจะนำไปคิดความผันผวนแต่ละวันต่อไป

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 เพื่อศึกษาหาวิธีการใหม่ๆ และเป็นตัวเลือกให้แก่นักลงทุนในตลาดหลักทรัพย์ ในการพยากรณ์ความผันผวน แล้วสามารถปรับเปลี่ยนกลยุทธ์การลงทุนของตนให้เหมาะกับความผันผวนที่เปลี่ยนแปลงไปได้ดียิ่งขึ้น

1.6.2 เพื่อเป็นแนวทางในการประยุกต์การเขียนโปรแกรมไพธอน ในด้านแมชชีนเลิร์นนิ่งเข้ากับการวิเคราะห์ข้อมูลด้านการลงทุนหรือการเงิน

Ref. code: 25676602110550SKO

บทที่ 2
วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.1 คำนิยามที่เกี่ยวข้อง

2.1.1 หุ้นสามัญ (Common Stock)

ตราสารที่กิจการออกให้แก่ผู้ถือ เพื่อระดมเงินทุนไปใช้ในกิจการ โดยผู้ถือหุ้นจะมีฐานะเป็น "เจ้าของ" ซึ่งจะมีส่วนได้เสียหรือมีสิทธิในทรัพย์สินและรายได้ของกิจการ ได้รับผลตอบแทนเป็นเงินปันผล (Dividend) เมื่อกิจการมีกำไร และหากกิจการมีผลการดำเนินงานที่ดี ราคาหุ้นเติบโตก็จะสามารถทำกำไรได้จากส่วนต่างราคา (Capital Gain) ได้ด้วย

แต่ผลตอบแทนจากการลงทุนในหุ้นจะไม่ค่อยแน่นอน ขึ้นอยู่กับผลการดำเนินงานของกิจการนั้น ๆ หากกิจการมีปัญหาจนถึงขั้นล้มละลาย ผู้ถือหุ้นจะได้รับเงินลงทุนคืนก็ต่อเมื่อกิจการจ่ายภาระผูกพันแก่เจ้าหนี้และผู้ถือหุ้นบุริมสิทธิเรียบร้อยแล้ว ซึ่งถือเป็น “ความเสี่ยง” ของการลงทุนในหุ้น

2.1.2 ความผันผวน (Volatility)

ระดับความไม่แน่นอนหรือการเปลี่ยนแปลงของราคาสินทรัพย์ทางการเงิน เช่น ราคาหุ้น อัตราแลกเปลี่ยน หรือดัชนีตลาดหลักทรัพย์ ภายในช่วงระยะเวลาหนึ่ง โดยทั่วไป ความผันผวนมักถูกใช้เป็นตัวชี้วัดความเสี่ยงของสินทรัพย์ กล่าวคือ หากสินทรัพย์มีความผันผวนสูง จะหมายถึงราคามีแนวโน้มเปลี่ยนแปลงขึ้นลงอย่างรุนแรงและรวดเร็ว ขณะที่สินทรัพย์ที่มีความผันผวนต่ำจะมีการเปลี่ยนแปลงของราคาที่ค่อนข้างคงที่หรือคาดการณ์ได้ง่ายกว่า

ในเชิงปริมาณ ความผันผวนมักวัดโดยการคำนวณ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ของผลตอบแทนในช่วงเวลาหนึ่ง หรือใช้แบบจำลองทางสถิติเช่น GARCH (Generalized Autoregressive Conditional Heteroskedasticity) เพื่อจับการเปลี่ยนแปลงของความผันผวนตามกาลเวลา

ในบริบทของการพยากรณ์หรือการวิเคราะห์ข้อมูลทางการเงิน ความผันผวนเป็นปัจจัยสำคัญที่ช่วยให้นักลงทุนสามารถประเมินความเสี่ยงของตลาด และช่วยให้โมเดลต่าง ๆ สามารถปรับตัวเพื่อคาดการณ์พฤติกรรมของราคาหรือดัชนีได้แม่นยำยิ่งขึ้น

Ref. code: 25676602110550SKO

2.1.3 เศรษฐมิติ (Econometrics)

สาขาหนึ่งของเศรษฐศาสตร์ที่ประยุกต์ใช้หลักคณิตศาสตร์ สถิติ และทฤษฎีเศรษฐศาสตร์ เพื่อวิเคราะห์ข้อมูลเชิงประจักษ์ (empirical data) และทดสอบสมมติฐานทางเศรษฐศาสตร์ จุดมุ่งหมายหลักของเศรษฐมิติ คือการสร้างแบบจำลองทางเศรษฐศาสตร์ที่สามารถอธิบาย พยากรณ์ หรือทำนายพฤติกรรมของตัวแปรทางเศรษฐกิจได้อย่างมีประสิทธิภาพ

ในทางปฏิบัติ เศรษฐมิติมักใช้แบบจำลองถดถอย (regression models) เพื่อวิเคราะห์ความสัมพันธ์เชิงปริมาณระหว่างตัวแปรต่าง ๆ เช่น รายได้กับการบริโภค ราคาหุ้นกับผลประกอบการ หรือดอกเบี้ยกับเงินเฟ้อ นอกจากนี้ เศรษฐมิติยังครอบคลุมเทคนิคขั้นสูง เช่น แบบจำลองอนุกรมเวลา (Time Series Models), แบบจำลองตัวแปรปัจจัยร่วม (Panel Data Models), และแบบจำลองที่มีเงื่อนไขแปรปรวน (ARCH/GARCH) ซึ่งช่วยให้นักวิจัยสามารถจัดการกับข้อมูลที่มีความซับซ้อนหรือมีลักษณะเฉพาะ เช่น ความผันผวนในตลาดการเงิน

2.1.4 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) คือ สาขาหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่มุ่งเน้นการพัฒนาอัลกอริทึมและแบบจำลองคอมพิวเตอร์ที่สามารถเรียนรู้จากข้อมูลและทำการคาดการณ์หรือการตัดสินใจโดยไม่ต้องเขียนโปรแกรมแบบกำหนดกฎชัดเจนล่วงหน้า

โมเดล Machine Learning จะเรียนรู้รูปแบบหรือความสัมพันธ์ของข้อมูลจากตัวอย่างในอดีต (training data) แล้วนำไปใช้ในการคาดการณ์กับข้อมูลใหม่ (unseen data) ได้อย่างอัตโนมัติ เทคนิคที่นิยมใช้ เช่น การถดถอยเชิงเส้น (Linear Regression), การจำแนกประเภท (Classification), การจัดกลุ่ม (Clustering), การเรียนรู้แบบเสริมแรง (Reinforcement Learning) และแบบจำลองที่ซับซ้อนขึ้น เช่น Random Forest, Support Vector Machine (SVM), และ XGBoost

Machine Learning ได้รับความนิยมอย่างแพร่หลายในการวิเคราะห์ข้อมูลขนาดใหญ่และซับซ้อน เช่น การพยากรณ์ราคาหุ้น การตรวจจับการฉ้อโกง และการประมวลผลภาษาธรรมชาติ เนื่องจากสามารถปรับตัวกับข้อมูลที่มีความไม่แน่นอนหรือมีโครงสร้างที่ซับซ้อนได้อย่างยืดหยุ่นและมีประสิทธิภาพ

2.1.5 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep Learning) คือแขนงย่อยของการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้โครงข่ายประสาทเทียมหลายชั้น (Artificial Neural Networks) เพื่อเรียนรู้รูปแบบและโครงสร้างที่ซับซ้อนจากข้อมูลจำนวนมาก โดยแต่ละชั้นของเครือข่ายจะทำหน้าที่

Ref. code: 25676602110550SKO

แยกแยะคุณลักษณะ (features) จากข้อมูลในระดับที่ลึกขึ้นเรื่อย ๆ ซึ่งช่วยให้โมเดลสามารถเรียนรู้จากข้อมูลที่ไม่เป็นเชิงเส้น (non-linear) ได้อย่างมีประสิทธิภาพ

Deep Learning ถูกนำมาใช้ในงานหลากหลาย เช่น การจดจำภาพ (image recognition), การรู้จำเสียงพูด (speech recognition), การประมวลผลภาษาธรรมชาติ (natural language processing) และในบริบททางการเงิน เช่น การพยากรณ์ราคาหุ้น การวิเคราะห์ความรู้สึกจากรายงานทางการเงิน และการจำแนกข้อความเชิงความหมาย

หนึ่งในจุดเด่นของ Deep Learning คือความสามารถในการ “เรียนรู้คุณลักษณะจากข้อมูลโดยอัตโนมัติ” โดยไม่จำเป็นต้องออกแบบฟีเจอร์ด้วยตนเองเหมือนใน Machine Learning แบบดั้งเดิม อย่างไรก็ตาม Deep Learning ต้องการข้อมูลจำนวนมากและพลังการประมวลผลสูงในการฝึกโมเดล

2.1.6 ตลาดหลักทรัพย์แห่งประเทศไทย (SET)

ตลาดหลักทรัพย์แห่งประเทศไทย คือองค์กรที่จัดตั้งขึ้นเพื่อเป็นศูนย์กลางในการซื้อขายหลักทรัพย์ภายใต้กฎหมายของประเทศไทย โดยมีบทบาทในการอำนวยความสะดวกแก่บริษัทจดทะเบียน นักลงทุน และผู้มีส่วนได้เสียในตลาดทุน ตลอดจนกำกับดูแลให้การซื้อขายหลักทรัพย์เป็นไปอย่างโปร่งใส มีประสิทธิภาพ และเป็นธรรม ภายใต้การกำกับของสำนักงานคณะกรรมการกำกับหลักทรัพย์และตลาดหลักทรัพย์ (ก.ล.ต.) โดยมีเป้าหมายเพื่อส่งเสริมการระดมทุนของภาคธุรกิจและสร้างโอกาสการลงทุนที่หลากหลายให้กับสาธารณชน

2.1.7 ดัชนีตลาดหลักทรัพย์แห่งประเทศไทย (SET Index)

SET Index คือดัชนีที่สะท้อนความเคลื่อนไหวของราคาหลักทรัพย์ทั้งหมดที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย (SET) โดยคำนวณจากมูลค่าหลักทรัพย์ตามราคาตลาด (market capitalization) ของหุ้นสามัญที่มีคุณสมบัติตามเกณฑ์ที่ตลาดหลักทรัพย์กำหนด ทั้งนี้ SET Index มีค่าเริ่มต้นที่ 100 จุด ณ วันเปิดทำการซื้อขายวันแรกของตลาดหลักทรัพย์ฯ เมื่อวันที่ 30 เมษายน พ.ศ. 2518 โดยใช้เป็นดัชนีชี้วัดแนวโน้มของตลาดหุ้นไทยในภาพรวม

2.1.8 ดัชนี S&P 500 (Standard & Poor’s 500 Index)

ดัชนี S&P 500 คือดัชนีตลาดหลักทรัพย์ที่จัดทำโดยบริษัท S&P Dow Jones Indices ซึ่งประกอบด้วยหลักทรัพย์ของบริษัทขนาดใหญ่จำนวน 500 บริษัทที่จดทะเบียนในตลาดหลักทรัพย์ของสหรัฐอเมริกา เช่น NYSE และ NASDAQ โดยมีการคำนวณดัชนีตามมูลค่าตลาด (market capitalization-weighted) ดัชนีนี้ได้รับการยอมรับอย่างกว้างขวางว่าเป็นตัวแทนของภาพรวมเศรษฐกิจและภาวะตลาดหุ้นของสหรัฐอเมริกา เนื่องจากครอบคลุมหลากหลายกลุ่มอุตสาหกรรม และสะท้อนแนวโน้มของบริษัทขนาดใหญ่ในประเทศ

Ref. code: 25676602110550SKO

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 การศึกษาความผันผวนของตลาดการเงิน

งานวิจัยเรื่อง Portfolio Selection Harry Markowitz(1952) ถือเป็นรากฐานสำคัญของทฤษฎีการลงทุนสมัยใหม่ โดยเสนอแนวคิดเรื่อง การกระจายความเสี่ยง (Portfolio Diversification) และการสร้างพอร์ตโฟลิโอที่ให้ผลตอบแทนที่เหมาะสมกับระดับความเสี่ยงที่นักลงทุนยอมรับได้ Markowitz แนะนำว่า นักลงทุนไม่ควรพิจารณาเพียงผลตอบแทนที่คาดหวังจากการลงทุนในสินทรัพย์แต่ละตัวเท่านั้น แต่ควรคำนึงถึงความเสี่ยงและความสัมพันธ์ระหว่างสินทรัพย์ (correlation) ในการสร้างพอร์ตโฟลิโอด้วย

แนวคิดหลักของงานวิจัยนี้คือ ทฤษฎีพอร์ตโฟลิโอสมัยใหม่ (Modern Portfolio Theory - MPT) ซึ่งเน้นการสร้างพอร์ตโฟลิโอที่ให้ผลตอบแทนสูงสุดสำหรับระดับความเสี่ยงที่กำหนด หรือความเสี่ยงต่ำสุดสำหรับผลตอบแทนที่กำหนด โดยใช้หลักการทางคณิตศาสตร์และสถิติในการคำนวณ Markowitz เสนอให้ใช้ ความแปรปรวน (variance) และ ความแปรปรวนร่วม (covariance) ระหว่างสินทรัพย์เป็นตัววัดความเสี่ยง และแสดงให้เห็นว่าการรวมสินทรัพย์ที่มีความสัมพันธ์ต่ำหรือเป็นลบสามารถลดความเสี่ยงของพอร์ตโฟลิโอได้โดยไม่ลดผลตอบแทนที่คาดหวัง

ทฤษฎีพอร์ตโฟลิโอสมัยใหม่จึงเป็นรากฐานแนวคิดที่สำคัญทำให้ในหลายปีต่อมามีการคำนึงถึงความเสี่ยงมากขึ้นมีการประดิษฐ์คิดค้นเครื่องมือต่าง ๆ สำหรับใช้ในการวัดความเสี่ยงหรือความผันผวนของหลักทรัพย์ ซึ่งเครื่องมือที่เป็นที่นิยมมากที่สุดในหมู่เศรษฐศาสตร์การเงินคือเครื่องที่ตั้งอยู่บนแนวคิด กระบวนการสุ่มที่มีความแปรปรวนไม่คงที่แบบมีเงื่อนไข (conditionally heteroscedastic stochastic) กลุ่มนี้มีโมเดลที่เป็นที่นิยมในการพยากรณ์ความผันผวน เช่น แบบจำลอง GARCH คิดค้นโดย Bollerslev (1986) & Taylor (1986) ซึ่งพัฒนาต่อยอดมาจากแบบจำลอง ARCH คิดค้นโดย Engle (1982) เพื่อใช้ในการวิเคราะห์และพยากรณ์ ความผันผวน (Volatility) ของข้อมูลอนุกรมเวลา (Time Series) โดยเฉพาะข้อมูลทางการเงิน เช่น ราคาหุ้น อัตราแลกเปลี่ยน และผลตอบแทนจากสินทรัพย์ต่าง ๆ วัตถุประสงค์หลักของแบบจำลอง GARCH คือ การอธิบายลักษณะ ความไม่แน่นอนที่เปลี่ยนแปลงตามเวลา (Time-Varying Volatility) หรือ Heteroskedasticity ซึ่งพบได้บ่อยในข้อมูลทางการเงิน โดยสมมติให้ค่าความผันผวนของข้อผิดพลาด (Error Term) ในแต่ละช่วงเวลาขึ้นอยู่กับค่าความผันผวนและข้อผิดพลาดในอดีต GARCH จึงสามารถนำมาใช้ในการพยากรณ์ระดับความเสี่ยงหรือความผันผวนในอนาคตได้อย่างมีประสิทธิภาพ

ซึ่งมีประโยชน์อย่างยิ่งในงานด้านการเงินและการบริหารความเสี่ยง (Risk Management)

Ref. code: 25676602110550SKO

สมการพื้นฐานของ GARCH(p,q) สามารถเขียนได้ดังนี้ :

$$\sigma_t^2 = \omega + \sum_{i=1}^{p} \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^{q} \beta_j \sigma_{t-j}^2$$

สำหรับการประยุกต์ใช้งานจริง GARCH(1,1) เป็นรูปแบบที่ได้รับความนิยมและใช้งานอย่างแพร่หลายที่สุด โดยเฉพาะในข้อมูลผลตอบแทนสินทรัพย์ทางการเงินรายวัน (Daily Asset Returns) เนื่องจากสามารถอธิบายลักษณะ Volatility Clustering หรือ ความผันผวนที่เกิดขึ้นต่อเนื่องเป็นกลุ่ม ได้อย่างมีประสิทธิภาพ พร้อมทั้งใช้จำนวนพารามิเตอร์น้อย ช่วยให้โมเดลไม่ซับซ้อนเกินไป สมการของ GARCH(1,1) เขียนได้ดังนี้:

$$\sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

แต่แม้ว่าจะมีความนิยมสูงแต่ แบบจำลอง GARCH ก็ยังคงมีข้อบกพร่องอยู่ ข้อมูลที่ใช้ในการคำนวณมีผลตอบแทนในอดีตและความแปรปรวนแบบมีเงื่อนไขเป็นหลัก ทำให้นักวิจัยในรุ่นต่อ ๆ มาพยายามปรับเปลี่ยนและขยายโครงสร้างของแบบจำลอง GARCH ด้วยการเพิ่มตัวแปรอื่น ๆ เข้าไปเกิดเป็นแบบจำลองอื่น ๆ ตามมา เช่น EGARCH (Nelson, 1991), APARCH (Ding, Engle & Granger, 1993), GJR-GARCH (Glosten, Jagannathan & Runkle, 1993), และ TGARCH (Zakoian, 1994)

ในช่วงเวลาที่ข้อมูลถูกรวบรวมสำหรับงานวิจัยนี้ มีเหตุการณ์สำคัญอย่างการระบาดของ Covid-19 ซึ่งก่อให้เกิดความผันผวนในลักษณะที่ผิดปกติจากภาวะเศรษฐกิจทั่วไป ตามแนวทางการควบคุมของ Zhang et al. (2021) และ Narayan et al. (2022) ที่แนะนำให้จำแนกข้อมูลออกเป็นช่วง shock และ non-shock เพื่อลดความผิดเพี้ยนของโมเดล โดยเฉพาะในการวิจัยเชิงพยากรณ์ (forecasting) และการสร้างแบบจำลองทางการเงินที่มีความไวต่อภาวะวิกฤตทางเศรษฐกิจ แนวทางนี้ยังช่วยเพิ่มความน่าเชื่อถือของการประเมินโมเดลในช่วงเวลาที่มีเสถียรภาพ (normal condition) และส่งเสริมให้ผลการทดลองสะท้อนถึงประสิทธิภาพที่แท้จริงของโมเดลมากยิ่งขึ้น

การตัดช่วงข้อมูลที่มีเหตุการณ์ Covid-19 ออก ถือเป็นขั้นตอนสำคัญในการควบคุมตัวแปรแทรกซ้อน (confounding variables) ที่อาจมีผลกระทบต่อความสัมพันธ์ระหว่างตัวแปรต้นและตัวแปรตาม โดยเฉพาะในบริบทของการเรียนรู้ของโมเดลปัญญาประดิษฐ์ ซึ่งมีแนวโน้มที่จะเรียนรู้จากความสัมพันธ์ในข้อมูลเชิงสถิติ แม้กระทั่งความสัมพันธ์ที่เกิดขึ้นเพียงชั่วคราว (spurious

Ref. code: 25676602110550SKO

correlation) เช่น ช่วงที่เกิดการระบาดของ Covid-19 ซึ่งส่งผลกระทบอย่างรุนแรงต่อปัจจัยทางเศรษฐกิจในวงกว้าง ไม่ว่าจะเป็นรายได้ของบริษัท ความผันผวนของตลาด และพฤติกรรมของผู้บริโภค หากข้อมูลในช่วงเวลาดังกล่าวถูกนำมาใช้ฝึกโมเดลโดยไม่มีการควบคุมหรือแยกวิเคราะห์ อาจส่งผลให้โมเดลเรียนรู้ pattern ที่ผิดเพี้ยนจากความเป็นจริง (model bias) และเกิดปัญหา overfitting กับเหตุการณ์เฉพาะช่วงเวลา (event-specific noise) จนอาจลดความสามารถในการทำนายในสถานการณ์ปกติลงอย่างมีนัยสำคัญ

2.2.2 แมชชีนเลิร์นนิ่ง (Machine learning)

ในขณะที่นักการเงินและนักเศรษฐศาสตร์ยังคงมุ่งมั่นพัฒนาแบบจำลองทางเศรษฐมิติเพื่อพยากรณ์ความผันผวนของตลาดการเงินให้มีความแม่นยำและสอดคล้องกับความเป็นจริงมากยิ่งขึ้นนั้น อีกด้านหนึ่งของวงวิชาการ โดยเฉพาะในสาขาวิทยาการคอมพิวเตอร์ ได้เกิดการพัฒนาอย่างก้าวหน้าในด้านเทคนิค แมชชีนเลิร์นนิง (Machine Learning) โดยเฉพาะอย่างยิ่งเครือข่ายประสาทเทียม (Artificial Neural Networks: ANNs) ซึ่งถือเป็นเทคนิคสำคัญที่เข้ามายกระดับศักยภาพของแบบจำลองเชิงการวิเคราะห์ข้อมูลทั้งในลักษณะการพยากรณ์ (Regression) และการจำแนกประเภท (Classification) ให้มีความแม่นยำมากยิ่งขึ้น

ในบริบทของการเรียนรู้ของเครื่อง (Machine Learning) Géron (2019) อธิบายว่าเป็นศาสตร์และศิลป์ของการโปรแกรมคอมพิวเตอร์ให้สามารถเรียนรู้จากข้อมูล โดยไม่จำเป็นต้องกำหนดกฎเกณฑ์ไว้อย่างชัดเจน ซึ่งแนวคิดนี้ได้รับการวางรากฐานตั้งแต่ปี ค.ศ. 1959 โดย Arthur Samuel ที่ให้นิยามว่า Machine Learning คือ "ขอบเขตของการศึกษา ที่ทำให้คอมพิวเตอร์สามารถเรียนรู้ได้โดยไม่ต้องมีการโปรแกรมอย่างชัดเจน" ต่อมา Mitchell (1997) ได้ให้นิยามเชิงวิศวกรรมว่าโปรแกรมคอมพิวเตอร์จะถือว่า “เรียนรู้” เมื่อประสิทธิภาพ (Performance: P) ในการทำงานของภารกิจหนึ่ง (Task: T) ดีขึ้นตามประสบการณ์ (Experience: E) ที่ได้รับ ตัวอย่างเช่น โปรแกรมคัดกรองอีเมลขยะ (spam filter) สามารถเรียนรู้จากชุดข้อมูลตัวอย่างที่ถูกระบุว่าเป็นสแปมหรือไม่ใช่สแปม โดยชุดข้อมูลที่ใช้ฝึกเรียกว่า training set และแต่ละตัวอย่างเรียกว่า training instance ซึ่งในกรณีนี้ งานที่ต้องทำ (T) คือการตรวจจับสแปม ข้อมูลฝึก (E) คืออีเมลที่มีการติดป้ายกำกับ และตัววัดประสิทธิภาพ (P) อาจใช้ความแม่นยำ (accuracy) เป็นหลัก การที่คอมพิวเตอร์มีข้อมูลจำนวนมาก เช่น การดาวน์โหลดวิกิพีเดียทั้งชุด โดยไม่มีการเรียนรู้หรือปรับปรุงตามภารกิจที่กำหนดไว้ ไม่ถือว่าเป็นการเรียนรู้ของเครื่อง

เมื่อศาสตร์ด้าน Machine Learning พัฒนาไปอย่างต่อเนื่อง โดยเฉพาะในด้านการเรียนรู้จากข้อมูลจำนวนมากและซับซ้อน แนวทางการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นสาขาย่อยของ Machine Learning ก็เริ่มมีบทบาทสำคัญมากขึ้น โดยอาศัยโครงสร้างของแบบจำลอง

Ref. code: 25676602110550SKO

ที่เลียนแบบการทำงานของสมองมนุษย์ นั่นคือ โครงข่ายประสาทเทียม (Artificial Neural Networks) ความก้าวหน้าดังกล่าวนำไปสู่การประยุกต์ใช้เครือข่ายประสาทเทียมในงานด้านการพยากรณ์ทางการเงินอย่างแพร่หลาย โดยเฉพาะการออกแบบสถาปัตยกรรมของแบบจำลองให้สามารถจัดการกับข้อมูลเชิงเวลา (Time Series Data) ได้อย่างมีประสิทธิภาพ โดยมุ่งเน้นการเรียนรู้จากข้อมูลในอดีตเพื่อนำมาสร้างผลต่อการพยากรณ์ในอนาคต อาทิ Recurrent Neural Networks (RNNs) ซึ่งถูกพัฒนาโดย Hopfield (1982) และต่อมาได้รับการขยายความสามารถโดย Williams, Hinton และ Rumelhart (1986) ให้สามารถจดจำและนำข้อมูลจากช่วงเวลาก่อนหน้ามาประมวลผลในลักษณะลำดับต่อเนื่อง (Sequential Data Processing)

ต่อมามีการพัฒนารูปแบบเครือข่ายที่สามารถจัดการกับปัญหาการสูญเสียข้อมูลในระยะยาว (Vanishing Gradient Problem) ได้อย่างมีประสิทธิภาพมากขึ้น ได้แก่ Long Short-Term Memory (LSTM) ซึ่งถูกเสนอโดย Hochreiter และ Schmidhuber (1997) นอกจากนี้ ยังมีการพัฒนา Gated Recurrent Unit (GRU) โดย Chung et al. (2014) ซึ่งถือเป็นสถาปัตยกรรมเครือข่ายแบบ RNN ที่ถูกออกแบบให้มีโครงสร้างที่เรียบง่ายกว่า LSTM แต่ยังคงรักษาความสามารถในการจดจำข้อมูลระยะยาวได้ดี

งานวิจัยในปัจจุบันจึงให้ความสนใจต่อการประยุกต์ใช้เครือข่ายประสาทเทียมเชิงลำดับ (Sequential Neural Networks) เหล่านี้อย่างกว้างขวาง โดยเฉพาะ GRU ซึ่งถูกนำมาใช้ในการพัฒนาแบบจำลองเชิงพยากรณ์ความผันผวนของตลาดการเงิน เนื่องจากมีจุดเด่นด้านโครงสร้างที่กระชับ ประมวลผลได้รวดเร็ว และลดความซับซ้อนในการฝึกสอนโมเดล ขณะเดียวกันยังสามารถรักษาประสิทธิภาพในการจับรูปแบบและความสัมพันธ์ของข้อมูลเชิงเวลาได้อย่างมีประสิทธิผล

ในด้านการประยุกต์แมชชีนเลิร์นนิ่งและดีปเลิร์นนิง Sunye Wang(2024) ได้มีการทดลองใช้แมชชีนเลิร์นนิ่งและดีปเลิร์นนิงพยากรณ์ราคาหุ้น Microsoft ทั้งหมด 5 โมเดลในการดังนี้ Random Forest , XGBoost, ANN, RNN และ LSTM ซึ่งให้ผลเป็นไปตามภาพที่ 2.1

Ref. code: 25676602110550SKO

ภาพที่ 2.1

Error Measures for MSFT

Prediction Models	Error Measures		
	R^2	MSE	MAE
Random Forest	0.99	17.37	3.27
XGBoost	0.98	23.97	4.20
ANN	-1.05	4118.73	63.50
RNN	0.99	17.09	3.01
LSTM	0.99	18.94	3.25

Note. Adapted from Stock price prediction based on artificial neural networks and ensemble learning algorithms, by Y. Li & S. Jiang, 2024, (SHS Web of Conferences, 190, 02007. https://doi.org/10.1051/shsconf/202419002007)

จากภาพผลการทดลองพบว่าโมเดล RNN ให้ประสิทธิภาพสูงสุดในทั้งสามตัวชี้วัด โดยมีค่า R^2 อยู่ที่ 0.99 แสดงว่าโมเดลสามารถอธิบายความแปรปรวนของข้อมูลได้เกือบทั้งหมด ขณะที่ MSE และ MAE อยู่ในระดับต่ำที่สุดที่ 17.09 และ 3.01 ตามลำดับ สะท้อนให้เห็นถึงความแม่นยำในการพยากรณ์สูงสุดเมื่อเปรียบเทียบกับโมเดลอื่น ๆ

รองจาก RNN คือ Random Forest และ LSTM ซึ่งมีค่า R^2 เท่ากันที่ 0.99 เช่นเดียวกัน แต่มีค่าความคลาดเคลื่อนเฉลี่ยสูงกว่าเล็กน้อย โดยเฉพาะในกรณีของ Random Forest ซึ่งมี MSE เท่ากับ 17.37 และ MAE เท่ากับ 3.27 ส่วน LSTM มี MSE เท่ากับ 18.94 และ MAE เท่ากับ 3.25 แสดงให้เห็นว่าโมเดลทั้งสองนี้ก็มีศักยภาพสูงในการพยากรณ์เช่นกัน และเหมาะกับข้อมูลชุดนี้ในเชิงการนำไปประยุกต์ใช้จริง

สำหรับ XGBoost แม้จะมีค่า R^2 ที่ค่อนข้างดี (0.98) แต่กลับมี MSE และ MAE สูงกว่า Random Forest และ LSTM อย่างเห็นได้ชัด โดยมีค่าเท่ากับ 23.97 และ 4.20 ตามลำดับ ซึ่งอาจเกิดจากความไวต่อการเลือกฟีเจอร์หรือพารามิเตอร์ที่ยังไม่เหมาะสม

ในทางตรงกันข้าม โมเดล ANN กลับให้ผลลัพธ์ที่แย่ที่สุดอย่างชัดเจน ด้วยค่า R^2 ที่ติดลบ (-1.05) ซึ่งหมายความว่าโมเดลทำนายได้แย่ยิ่งกว่าการเดาค่ากลางของข้อมูล ขณะเดียวกัน

Ref. code: 25676602110550SKO

ยังมีค่า MSE และ MAE สูงผิดปกติ (4,118.73 และ 63.50) ซึ่งแสดงถึงความล้มเหลวในการเรียนรู้รูปแบบของข้อมูลอย่างสิ้นเชิง อาจเกิดจากปัญหา overfitting, ขาดการปรับพารามิเตอร์ที่เหมาะสม หรือไม่เหมาะกับข้อมูลชนิดนี้

โดยสรุป RNN คือโมเดลที่เหมาะสมที่สุดสำหรับการพยากรณ์ราคาหุ้นในชุดข้อมูลนี้ รองลงมาคือ Random Forest และ LSTM ซึ่งทั้งสามโมเดลนี้ให้ผลลัพธ์ที่น่าเชื่อถือและมีความคลาดเคลื่อนต่ำ ในขณะที่ XGBoost มีศักยภาพแต่ยังด้อยกว่าเล็กน้อย ส่วน ANN ไม่เหมาะสำหรับบริบทของการพยากรณ์ในลักษณะนี้

2.2.3 การผสานโมเดลดีปเลิร์นนิงร่วมกับแบบจำลอง GARCH

ในการทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องในสองหัวข้อที่กล่าวมา แสดงให้เห็นถึงศาสตร์แขนงที่แตกต่างกัน แต่มีเป้าหมายเดียวกันคือการพยากรณ์อนาคตให้แม่นยำที่สุด จึงเกิดเป็นคำถามให้กับนักวิจัยในช่วงหลังมานี้ ถ้าหากนำสองศาสตร์มารวมกันจะทำให้สามารถพยากรณ์ได้แม่นยำขึ้นหรือไม่ โดยในงานวิจัย Jakub Michańków, Łukasz Kwiatkowski, Janusz Morajda (2023) ได้ศึกษาการผสานแบบจำลอง GARCH-type models หรือแบบจำลอง ที่มีพื้นฐานมาจาก GARCH ประกอบด้วย GARCH, GJR-GARCH, EGARCH, APARCH เข้ากับเครือข่าย GRU โดยทำการฝึกโมเดลด้วยข้อมูลทั้งหมดสามชุดคือ 1. S&P 500 index (ข้อมูลการซื้อขาย 5 วันต่อสัปดาห์ ตั้งตแต่วันที่ ระหว่างวันที่ 6 เมษายน พ.ศ. 2552 ถึง 31 ธันวาคม พ.ศ. 2563) 2. Bitcoin (BTC/USD; ข้อมูลตลอด 7 วันต่อสัปดาห์ ใช้ราคาซื้อขายระหว่างวันที่ 5 สิงหาคม พ.ศ. 2556 ถึง 31 ธันวาคม พ.ศ. 2563) 3. ทองคำ (XAU/USD; ข้อมูลการซื้อขาย 5 วันต่อสัปดาห์ ใช้ราคาซื้อขายระหว่างวันที่ 8 กรกฎาคม พ.ศ. 2553 ถึง 31 ธันวาคม พ.ศ. 2563) ช่วงเวลาของข้อมูลในแต่ละชุดถูกกำหนดให้ครอบคลุมระยะเวลาที่สอดคล้องกัน เพื่อให้ได้จำนวนข้อสังเกตเท่ากันที่ 2,707 จุดข้อมูลในแต่ละกรณีศึกษา GRU มีสมการดังนี้

$$z_t = \sigma_g(W_z x_t + U_z o_{t-1} + b_z)$$

$$r_t = \sigma_g(W_r x_t + U_r o_{t-1} + b_r)$$

$$\widehat{o_t} = \phi_o(W_o x_t + U_o(r_t \odot o_{t-1}) + b_o)$$

$$o_t = (1 - z_t) \odot o_{t-1} + z_t \odot \widehat{o_t}$$

Ref. code: 25676602110550SKO

ภาพที่ 2.2

Hybrid GARCH-GRU model structure

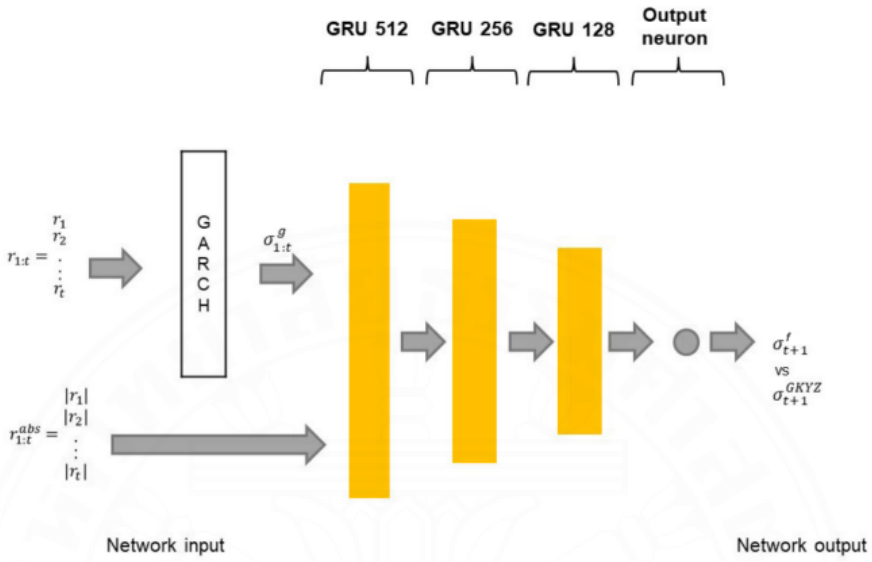

Note. From *Combining Deep Learning and GARCH Models for Financial Volatility and Risk Forecasting*, by Jakub Michaήków, Łukasz Kwiatkowski, & Janusz Morajda, 2023. (https://arxiv.org/abs/2310.01063)

ภาพที่ 2.3

S&P 500, Bitcoin and gold's daily prices

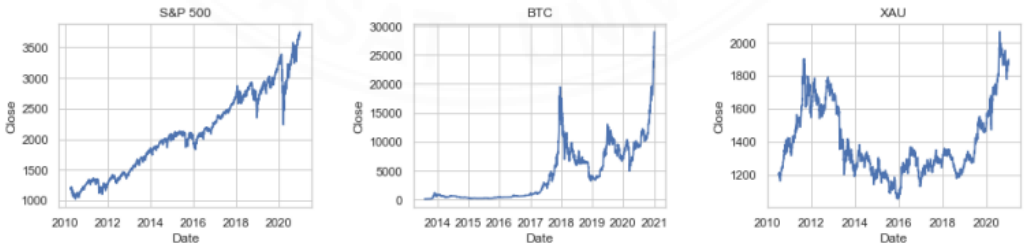

Note. From *Combining Deep Learning and GARCH Models for Financial Volatility and Risk Forecasting*, by Jakub Michaήków, Łukasz Kwiatkowski, & Janusz Morajda. (https://arxiv.org/abs/2310.01063)

ภาพรวมผลการศึกษาพบว่า GARCH-GRU ช่วยเพิ่มประสิทธิภาพในการพยากรณ์ความผันผวนได้อย่างมีนัยสำคัญในกรณีของ EGARCH-GRU กับ S&P 500 และ ทองคำ อีก

Ref. code: 25676602110550SKO

ด้านคือ APARCH-GRU กับ Bitcoin เมื่อวัดจากค่า Mean Squared Error (MSE) อย่างไรก็ตาม GARCH-GRUและอื่น ๆ ไม่ใช่โมเดลที่ดีที่สุดในทุกสถานการณ์ ในบางกรณีผลลัพธ์ที่ได้อาจไม่มีนัยสำคัญทางสถิติ (Statistically Insignificant) หรือมีนัยสำคัญทางสถิติน้อยกว่าที่คาดการณ์ไว้ เช่น การเปรียบเทียบระหว่าง EGARCH ภายใต้สมมติฐานการแจกแจงแบบปกติเงื่อนไข (Conditionally Normal EGARCH) กับ EGARCH-GRU หรือ EGARCH ภายใต้การแจกแจงแบบ Student's t-distribution กับ EGARCH-GRU และ APARCH ภายใต้การแจกแจงแบบ skewed t-distribution กับ APARCH-GRU

ภาพที่ 2.4

Comparison of volatility forecasts based on the MSE loss function across all models and distributions for S&P 500

Metrics / Model	G(N)	G(N)-GRU	G(STD)	G(STD)-GRU	G(SSTD)	G(SSTD)-GRU
MSE	0.0844	0.0168	0.0646	0.0183	0.0575	0.0159
DM p-value	0.0379		0.0494		0.0189	
Metrics / Model	E(N)	E(N)-GRU	E(STD)	E(STD)-GRU	E(SSTD)	E(SSTD)-GRU
MSE	0.1539	0.0167	0.1362	0.0160	0.1350	**0.0152**
DM p-value	0.0018		0.0025		0.0046	
Metrics / Model	GJR(N)	GJR(N)-GRU	GJR(STD)	GJR(STD)-GRU	GJR(SSTD)	GJR(SSTD)-GRU
MSE	0.1388	0.0181	0.1244	0.0153	0.1053	0.0156
DM p-value	0.0347		0.0395		0.0290	
Metrics / Model	AP(N)	AP(N)-GRU	AP(STD)	AP(STD)-GRU	AP(SSTD)	AP(SSTD)-GRU
MSE	0.1103	0.0333	0.1015	0.0253	0.0890	0.0221
DM p-value	0.0237		0.0160		0.0009	

Note. From *A stock market risk forecasting model through integration of switching regime, ANFIS and GARCH techniques*, by R. Chandra, J. Aryal, & D. Alahakoon, 2018, *arXiv*. (https://arxiv.org/pdf/2310.01063)

ในกรณีของโมเดลอื่น Ha Young Kim, Chang Hyun Wona (2018) ได้มีการผสานแบบจำลอง GARCH-type models ประกอบด้วย GARCH, EGARCH กับ LSTM และ Deep feedforward network โดยใช้ชุดข้อมูล KOSPI 200 index หรือ 200 หุ้นที่มูลค่ามากที่สุดและเป็นตัวแทนของตลาดหลักทรัพย์เกาหลี ข้อมูลระหว่างวันที่ 1 มกราคม พ.ศ. 2544 ถึงวันที่ 30 กันยายน พ.ศ. 2554 โดย LSTM มีสมการดังนี้

$$g_t = \sigma\left(U_g x_t + W_g h_{t-1} + b_f\right)$$

Ref. code: 25676602110550SKO

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i)$$

$$\widetilde{c_t} = \tanh(U_c x_t + W_c h_{t-1} + b_c)$$

$$c_t = g_t * c_{t-1} + i_t * \widetilde{c_t}$$

$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o)$$

$$h_t = o_t * \tanh(c_t)$$

ภาพที่ 2.5

โครงสร้างแบบจำลอง GE-LSTM hybrid model

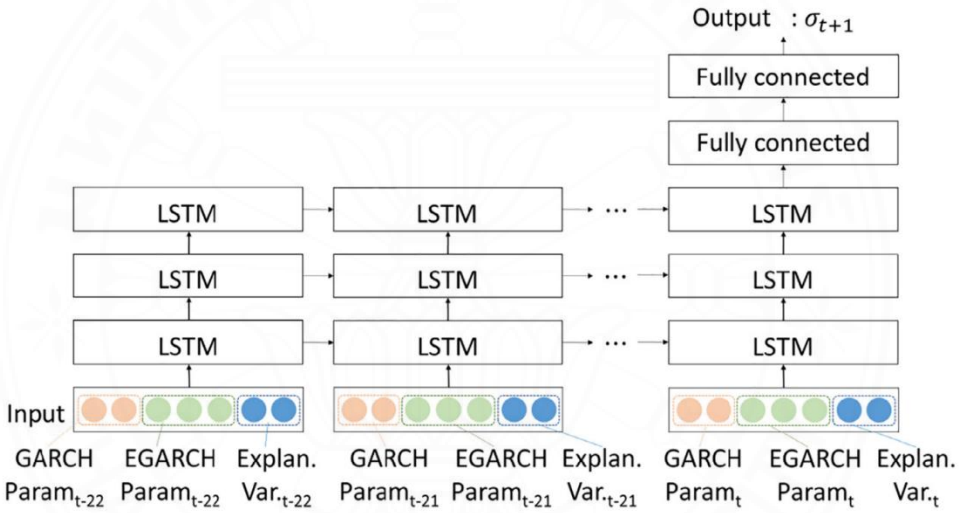

Note. From *A stock market risk forecasting model through integration of switching regime, ANFIS and GARCH techniques*, by Rohitash Chandra, Jagannath Aryal, & Damminda Alahakoon, 2018.
https://www.sciencedirect.com/science/article/pii/S0957417418301416

จากผลการทดลองของงานวิจัยพบว่าโมเดล LSTM-based hybrid ที่ผสานกับ GARCH-type models ให้ประสิทธิภาพในการพยากรณ์ความผันผวนของดัชนี KOSPI 200 ดีกว่าโมเดลแบบเดี่ยวและ hybrid models แบบอื่นอย่างมีนัยสำคัญ โดยเฉพาะ GEW-LSTM ซึ่งรวม GARCH, EGARCH และ EWMA เข้ากับ LSTM แสดงผลการพยากรณ์แม่นยำที่สุดในทุกตัวชี้วัด ได้แก่ MAE, MSE, HMAE และ HMSE โดยลดค่าความคลาดเคลื่อนเฉลี่ย (MAE) ลงถึง 37.2% เมื่อเทียบกับ E-DFN ซึ่งเป็น hybrid model ที่ดีที่สุดในกลุ่ม DFN-based models นอกจากนี้ GEW-LSTM ยังสามารถลด MSE, HMAE และ HMSE ได้ 57.3%, 24.7% และ 48% ตามลำดับ แสดงให้เห็นว่าการ

Ref. code: 25676602110550SKO

เพิ่มข้อมูลจากหลาย GARCH-type models เข้าไปใน LSTM ช่วยให้โมเดลสามารถเรียนรู้รูปแบบความต่อเนื่องเชิงเวลา (temporal patterns) และความสัมพันธ์เชิงซ้อนของข้อมูลการเงินได้อย่างมีประสิทธิภาพ ส่งผลให้ผลลัพธ์แม่นยำกว่าการผสานกับ GARCH เพียงตัวเดียว ทั้งนี้ยังพบว่า เมื่อเพิ่มจำนวนวันใน window size ผลการพยากรณ์จะยิ่งแม่นยำมากขึ้น และเมื่อเพิ่มระยะเวลาการพยากรณ์ล่วงหน้า ความคลาดเคลื่อนจะเพิ่มขึ้น สอดคล้องกับข้อสรุปที่ว่า hybrid model ซึ่งผสานข้อมูลจากหลาย GARCH-type models มีศักยภาพสูงสุดในการพยากรณ์ความผันผวนของตลาดการเงินในเชิงเวลา

ภาพที่ 2.6

Results of out-of-sample forecasts with various loss functions

		Model	MAE	MSE	HMAE	HMSE
Single model		EWMA	0.06559	0.00936	1.82616	3.87996
		GARCH	0.05925	0.00693	1.56660	2.87190
		EGARCH	0.05898	0.00641	1.11166	1.55857
		DFN	0.02083	0.00570	0.65977	0.78589
		LSTM	0.01498	0.00302	0.51864	0.44231
DFN-based hybrid model	with one GARCH-type	W-DFN	0.01943	0.00495	0.63632	0.77037
		G-DFN	0.01941	0.00429	0.60864	0.60309
		E-DFN	0.01701	0.00350	0.56996	0.45170
LSTM-based hybrid model	with one GARCH-type	W-LSTM	0.01322	0.00279	0.49125	0.32835
		G-LSTM	0.01271	0.00252	0.45258	0.29479
		E-LSTM	0.01191	0.00216	0.44651	0.28760
	with two GARCH-type	GW-LSTM	0.01156	0.00160	0.44188	0.28379
		EW-LSTM	0.01136	0.00158	0.43396	0.25292
		GE-LSTM	0.01089	0.00150	0.43279	0.23519
	with three GARCH-type	GEW-LSTM	0.01069	0.00149	0.42911	0.23492

Note. From *Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques*, by J. Patel, S. Shah, P. Thakkar, & K. Kotecha, 2015, *Expert Systems with Applications, 42*(1), 259–268. (https://doi.org/10.1016/j.eswa.2018.03.006)

S. Chen, W. K. Härdle และ K. Jeong (2009) ได้ทดลองในลักษณะเดียวกัน โดยใช้ GARCH รวมกับ Support Vector Machine ที่ใช้ kernel function ต่างกัน แต่โดยรวมให้ค่า error ที่ต่ำการใช้ GARCH ทั้งหมด นอกจากนี้ยังต่ำกว่าโมเดลANN-GARCH อีกด้วยโดยเฉพาะที่ใช้ Gaussian kernel (SVMg), ให้ผลลัพธ์ดีกว่าโมเดลแบบดั้งเดิมอย่างชัดเจนในทุกเกณฑ์และทุกขนาดตัวอย่างที่ MAE 0.0000796 และ 0.0000456 ดูผลลัพธ์ได้ตามภาพที่

Ref. code: 25676602110550SKO

ภาพที่ 2.7

Diebold–Mariano test for the MAE difference on real data

Models	Sample Size = 500				Sample Size = 1000			
	Normality		Student's *t*		Normality		Student's *t*	
	MAE	DA	MAE	DA	MAE	DA	MAE	DA
Moving Average	0.0001276	44.07	0.0001747	59.32	0.0001198	54.24	0.0002130	40.68
Standard GARCH	0.0000972	76.27	0.0001765	55.93	0.0000488	79.66	0.0001083	59.32
EGARCH	0.0001312	67.80	0.0002075	64.41	0.0000730	57.63	0.0001864	74.58
ANN-GARCH	0.0001517	72.88	0.0002481	57.63	0.0000904	62.71	0.0001442	67.80
SVMl-GARCH	0.0000960	76.27	0.0001369	71.19	0.0000501	74.58	0.0000715	72.88
SVMp-GARCH	0.0000924	76.27	0.0001371	71.19	0.0000479	71.19	0.0000714	77.97
SVMg-GARCH	0.0000796	86.44	0.0001397	81.36	0.0000456	83.05	0.0000769	98.31

Note. From *Forecasting volatility with support vector machine–based GARCH model*, by W. Ou & Z. Wang, 2010, *Journal of Forecasting, 29*(4), pp. 406–433. https://doi.org/10.1002/for.1134

โดยสรุป จากการทบทวนวรรณกรรมทั้งหมดที่กล่าวไปข้างต้น ทำให้เราเจอโมเดลที่น่าสนใจในการใช้พยากรณ์หลักทรัพย์ 4 โมเดลได้แก่ Random Forest , XGBoost, RNN ,LSTM นอกจากนี้ ยังพบว่าในงานวิจัยหลายฉบับมีแนวโน้มในการผสมผสานโมเดลทางสถิติแบบดั้งเดิม เช่น GARCH เข้ากับเทคนิคแมชชีนเลิร์นนิงสมัยใหม่ เพื่อเพิ่มความสามารถในการพยากรณ์ความผันผวนของตลาดที่มีลักษณะไม่เป็นเชิงเส้น (nonlinear) และไม่อยู่กับที่ (non-stationary) โดยเฉพาะโมเดลอย่าง GRU (Gated Recurrent Unit) ซึ่งเป็นโครงข่ายประสาทเทียมที่ออกแบบมาให้เรียนรู้ข้อมูลลำดับเวลาเช่นเดียวกับ LSTM แต่มีโครงสร้างเรียบง่ายกว่า และ Support Vector Machine (SVM) ที่เมื่อถูกนำมาใช้งานร่วมกับ GARCH เช่นในรูปแบบ SVM–GARCH หรือ SVRg–GARCH จะช่วยเพิ่มความแม่นยำในการพยากรณ์ความผันผวนได้อย่างมีนัยสำคัญ

จากการรวบรวมองค์ความรู้ทั้งหมดข้างต้น จึงสามารถสรุปได้ว่า โมเดลที่มีศักยภาพสูงในการนำมาศึกษาและพัฒนาเพื่อพยากรณ์ข้อมูลด้านการเงินและหลักทรัพย์ ได้แก่ Random Forest, XGBoost, RNN, LSTM, GRU และ Support Vector Machine ซึ่งแต่ละโมเดลมีจุดแข็งที่แตกต่างกัน และอาจสามารถนำมาผสมผสานเพื่อสร้างโมเดลแบบผสม (hybrid model) ที่ให้ผลลัพธ์แม่นยำยิ่งขึ้นในการพยากรณ์พฤติกรรมของตลาดทุนในสถานการณ์ที่หลากหลาย

Ref. code: 25676602110550SKO

บทที่ 3
วิธีการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาโมเดลเชิงพยากรณ์สำหรับข้อมูลอนุกรมเวลา (Time Series Data) โดยแบ่งกระบวนการพยากรณ์ออกเป็นสองส่วนหลัก ดังนี้ ส่วนแรกมุ่งเน้นการพยากรณ์ความผันผวนของราคาหลักทรัพย์ โดยอาศัยตัวแปรต้นที่ได้จากกระบวนการสร้างคุณลักษณะ (Feature Engineering) บนชุดข้อมูลดั้งเดิม จากนั้นนำตัวแปรดังกล่าวเข้าสู่กระบวนการวิเคราะห์ด้วยเทคนิคแมชชีนเลิร์นนิงและดีปเลิร์นนิง ส่วนที่สอง เป็นการขยายชุดตัวแปรต้นด้วยการเพิ่มตัวแปรด้านเศรษฐมิติ (Econometric Features) และดำเนินการสร้างคุณลักษณะเพิ่มเติมอีกครั้ง ก่อนนำไปใช้ในการพยากรณ์ ภายหลังการพัฒนาโมเดลทั้งสองส่วน ผลลัพธ์ที่ได้จะถูกนำมาเปรียบเทียบประสิทธิภาพเชิงพยากรณ์ โดยใช้เกณฑ์การประเมินความแม่นยำที่แตกต่างกัน ซึ่งรายละเอียดของค่าสถิติที่ใช้ในการเปรียบเทียบจะนำเสนอในหัวข้อถัดไป

3.1 ประชากรและกลุ่มตัวอย่าง

งานวิจัยนี้กำหนดประชากรกลุ่มเป้าหมายเป็นการเคลื่อนไหวของดัชนี S&P500 และ SET โดยทำการเก็บข้อมูลรายวันของสินทรัพย์ประกอบไปด้วย ราคาปิด (Close), ราคาสูงสุด (High), ราคาต่ำสุด (Low), ราคาเปิด (Open), ปริมาณการซื้อขาย (Volume) มีขอบเขตการเก็บข้อมูลเป็นระยะเวลาย้อนหลัง 10 ปี ตั้งแต่วันที่ 1 มกราคม พ.ศ.2558 ถึง วันที่ 31 ธันวาคม พ.ศ. 2567 ของทั้งใน S&P500 และ SET จากฐานข้อมูล Yahoo Finance เว็บไซต์ https://finance.yahoo.com (ณ วันที่ 18 มีนาคม พ.ศ.2568)

3.2 โมเดลที่สร้างจากเทคนิคการเรียนรู้ของเครื่องและเทคนิคการเรียนรู้เชิงลึก

3.2.1 เอ็กซ์ตรีมเกรเดียนต์บูสติ้ง

เอ็กซ์ตรีมเกรเดียนต์บูสติ้ง (Extreme Gradient Boosting: XGBoost) เป็นอัลกอริทึมในกลุ่มของเทคนิคการเรียนรู้แบบเสริมแรง (Ensemble Learning) ที่พัฒนามาจากวิธี Gradient Boosting โดย Chen and Guestrin (2016) ลักษณะเด่นของ XGBoost คือการนำหลายต้นไม้ตัดสินใจ (Decision Trees) มารวมกันแบบอนุกรม (Sequential Ensemble) เพื่อแก้ไขข้อผิดพลาดของแต่ละต้นไม้ในรอบก่อนหน้าอย่างต่อเนื่อง ทำให้โมเดลมีความแม่นยำสูง และสามารถ

Ref. code: 25676602110550SKO

จัดการกับข้อมูลที่มีความซับซ้อนได้ดี นอกจากนี้ XGBoost ยังออกแบบมาให้มีความสามารถในการจัดการกับ Missing Values และป้องกัน Overfitting ผ่าน Regularization ส่งผลให้ XGBoost ได้รับความนิยมอย่างแพร่หลายในงานวิเคราะห์ข้อมูลเชิงทำนาย (Predictive Analytics)

3.2.2 แรนดอมฟอเรสต์

แรนดอมฟอเรสต์ (Random Forest) เป็นอัลกอริทึมในกลุ่มของเทคนิคการเรียนรู้แบบเสริมแรง (Ensemble Learning) โดยพัฒนาโดย Breiman (2001) ลักษณะเด่นของ Random Forest คือการสร้างต้นไม้ตัดสินใจจำนวนมาก (Multiple Decision Trees) แบบสุ่ม (Randomized Trees) และใช้วิธีการโหวต (Voting) เพื่อหาคำตอบสุดท้าย ซึ่งช่วยลดปัญหาการ Overfitting ของโมเดลเดี่ยว และเพิ่มความแม่นยำในการทำนาย Random Forest มีความสามารถในการจัดการกับข้อมูลที่มีจำนวนตัวแปรจำนวนมาก (High-Dimensional Data) และสามารถวัดความสำคัญของตัวแปร (Feature Importance) ได้อย่างมีประสิทธิภาพ

ภาพที่ 3.1

ภาพเปรียบเทียบ single decision tree กับ random forest

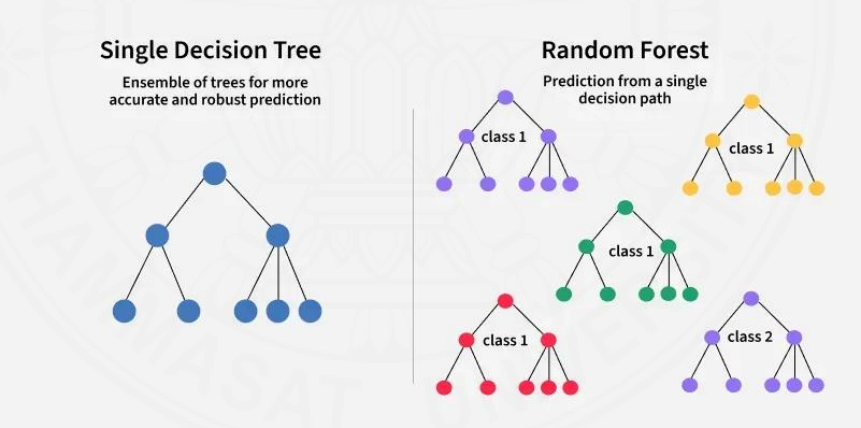

Note. Random Forest Algorithm in Machine Learning, Geeksforgeeks, 2025, (https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/)

Ref. code: 25676602110550SKO

ภาพที่ 3.2

ขั้นตอนการทำ Random forest

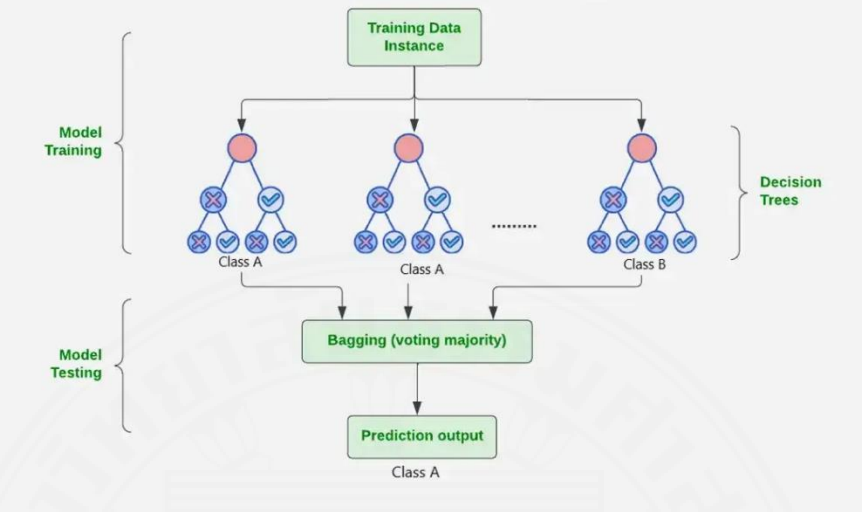

Note. Random Forest Algorithm in Machine Learning, Geeksforgeeks, 2025, (https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in machine-learning/)

3.2.3 ซัพพอร์ตเวกเตอร์แมชชีน

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) เป็นอัลกอริทึมในกลุ่มของการเรียนรู้แบบมีผู้สอน (Supervised Learning) โดย Vapnik (1995) ซึ่งออกแบบมาเพื่อใช้แก้ปัญหาการจำแนกประเภท (Classification) และการพยากรณ์ (Regression) ลักษณะเด่นของ SVM คือการหาขอบเขต (Hyperplane) ที่ดีที่สุดในการแบ่งกลุ่มข้อมูลออกจากกัน โดยพิจารณาจากการเพิ่มระยะห่าง (Margin) ระหว่างกลุ่มข้อมูลให้มากที่สุด เพื่อให้โมเดลมีความสามารถในการจำแนกข้อมูลใหม่ได้อย่างแม่นยำ SVM ยังสามารถประยุกต์ใช้ Kernel Trick เพื่อแปลงข้อมูลที่ไม่สามารถแยกเส้นตรงได้ในมิติเดิม ให้สามารถแยกได้ในมิติที่สูงขึ้น (Higher-Dimensional Space) แต่ SVM อาจมีข้อจำกัดด้านประสิทธิภาพเมื่อใช้กับชุดข้อมูลขนาดใหญ่มาก

3.2.4 รีเคอร์เรนท์นิวรัลเน็ตเวิร์ก

รีเคอร์เรนท์นิวรัลเน็ตเวิร์ก (Recurrent Neural Network: RNN) เป็นอัลกอริทึมในกลุ่มของโครงข่ายประสาทเทียม (Neural Network) ที่ออกแบบมาเพื่อจัดการกับข้อมูลที่มีลักษณะลำดับ (Sequential Data) หรืออนุกรมเวลา (Time Series) โดยเฉพาะ ซึ่งถูกนำเสนอครั้งแรกโดย Rumelhart et al. (1986) ลักษณะเด่นของ RNN คือการมี หน่วยความจำ (Memory) ภายในเครือข่าย ที่สามารถจดจำข้อมูลจากช่วงเวลาก่อนหน้า (Past Information) และนำมาประมวลผล

Ref. code: 25676602110550SKO

ร่วมกับข้อมูลในช่วงเวลาปัจจุบัน ทำให้ RNN มีความสามารถในการเรียนรู้ ความสัมพันธ์เชิงลำดับ (Temporal Dependencies) ของข้อมูลได้ อย่างไรก็ตาม แม้ว่า RNN จะมีข้อดีในการจัดการข้อมูลลำดับ แต่ก็ประสบปัญหา Vanishing Gradient เมื่อทำการเรียนรู้ข้อมูลระยะยาว (Long-Term Dependencies) ส่งผลให้ประสิทธิภาพลดลงเมื่อนำไปใช้กับข้อมูลที่มีความสัมพันธ์ระยะยาวสูง

ภาพที่ 3.3

โครงสร้างของ Recurrent Neural Network (RNN)

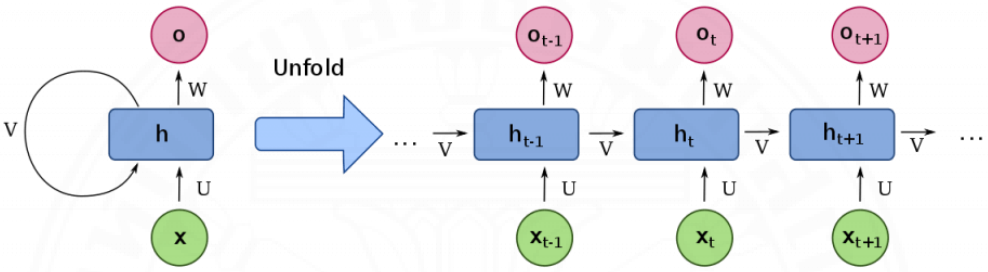

Note. Adapted from RNN คืออะไร? GRU คืออะไร? สอนเขียน RNN/GRU ด้วย Python – NLP EP.9, by Bualabs, 2020, April 8. (https://www.bualabs.com/archives/3103/what-is-rnn-recurrent-neural-network-what-is-gru-gated-recurrent-unit-teach-how-to-build-rnn-gru-with-python-nlp-ep-9/)

3.2.5 เกตเตดรีเคอร์เรนท์ยูนิต

เกตเตดรีเคอร์เรนท์ยูนิต (Gated Recurrent Unit: GRU) เป็นอัลกอริทึมในกลุ่มของโครงข่ายประสาทเทียมแบบรีเคอร์เรนท์ (Recurrent Neural Network: RNN) ซึ่งได้รับการพัฒนาโดย Cho et al. (2014) โดยมีวัตถุประสงค์หลักเพื่อแก้ไขข้อจำกัดของ RNN ดั้งเดิมที่ประสบปัญหา Vanishing Gradient เมื่อทำการเรียนรู้ข้อมูลในลักษณะลำดับ (Sequence Data) หรืออนุกรมเวลา (Time Series)

GRU มีโครงสร้างที่เรียบง่ายกว่า Long Short-Term Memory (LSTM) โดยใช้สองเกตหลัก ได้แก่ Update Gate และ Reset Gate ในการควบคุมข้อมูลที่ควรส่งผ่านหรือถูกลืมในแต่ละช่วงเวลา ทำให้อัลกอริทึมสามารถจดจำข้อมูลสำคัญในระยะยาวและลดความซับซ้อนของโมเดลลงเมื่อเปรียบเทียบกับ LSTM

แม้ว่า GRU จะถูกพัฒนาขึ้นมาเพื่อจัดการกับปัญหาลำดับข้อมูล แต่ด้วยคุณสมบัติในการจดจำและเรียนรู้ข้อมูลในอดีตได้อย่างมีประสิทธิภาพ จึงได้รับความนิยมในการนำมา

Ref. code: 25676602110550SKO

ประยุกต์ใช้สำหรับการพยากรณ์ข้อมูลในลักษณะอนุกรมเวลา (Time Series Forecasting) โดยสามารถสร้างแบบจำลองความสัมพันธ์เชิงซ้อนระหว่างข้อมูลในอดีตกับอนาคตได้อย่างมีประสิทธิภาพ

ภาพที่ 3.4

*โครงสร้างของ GRU (*Gated Recurrent Unit*)*

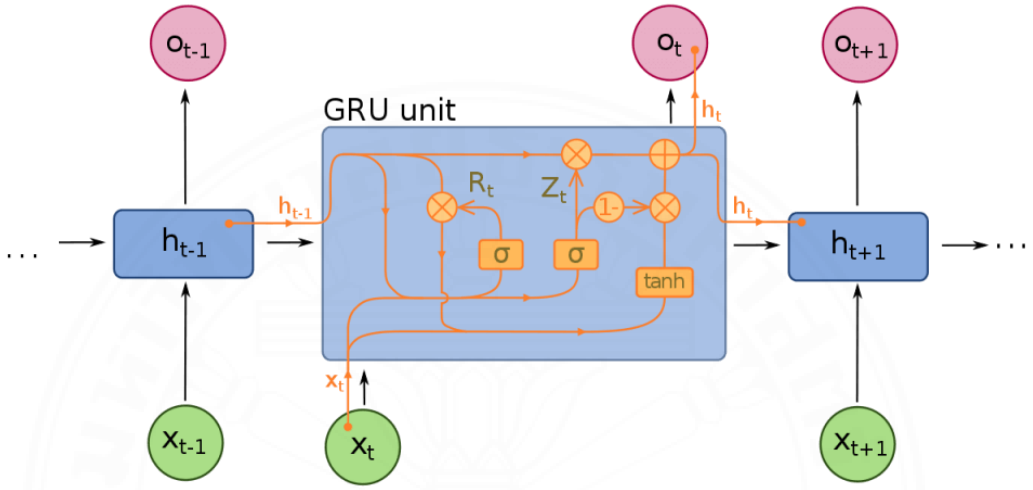

Note. Adapted from *RNN คืออะไร? GRU คืออะไร? สอนเขียน RNN/GRU ด้วย Python – NLP EP.9*, by Bualabs, 2020, April 8. (https://www.bualabs.com/archives/3103/what-is-rnn-recurrent-neural-network-what-is-gru-gated-recurrent-unit-teach-how-to-build-rnn-gru-with-python-nlp-ep-9/)

3.2.6 ลองชอร์ตเทอมเมมโมรี

ลองชอร์ตเทอมเมมโมรี (Long Short-Term Memory: LSTM) เป็นอัลกอริทึมในกลุ่มโครงข่ายประสาทเทียมแบบรีเคอร์เรนท์ (Recurrent Neural Network: RNN) ที่ถูกพัฒนาโดย Hochreiter และ Schmidhuber (1997) โดยมีวัตถุประสงค์หลักเพื่อแก้ไขข้อจำกัดของ RNN ดั้งเดิมที่มักประสบปัญหา Vanishing Gradient ส่งผลให้ไม่สามารถจดจำข้อมูลระยะยาวได้อย่างมีประสิทธิภาพ

LSTM ได้เพิ่มกลไก หน่วยความจำ (Memory Cell) และ ประตู (Gates) เข้ามาในโครงสร้างของโมเดล เพื่อควบคุมการไหลของข้อมูลทั้งการรับเข้า การลืม และการส่งผ่านข้อมูลไปยังสถานะถัดไป ซึ่งประกอบด้วย 3 ประตูสำคัญ ได้แก่ Forget Gate, Input Gate และ Output Gate โดยแต่ละประตูจะทำหน้าที่กรองข้อมูลที่จำเป็นหรือไม่จำเป็นในแต่ละช่วงเวลา

ด้วยโครงสร้างดังกล่าว LSTM สามารถเรียนรู้และจดจำความสัมพันธ์ของข้อมูลในระยะยาวได้ดี จึงถูกนำมาใช้ในงานด้านการพยากรณ์ข้อมูลอนุกรมเวลา (Time Series

Ref. code: 25676602110550SKO

Forecasting) ได้อย่างมีประสิทธิภาพ โดยสามารถจับความสัมพันธ์เชิงซ้อนและรูปแบบแฝงในข้อมูลได้

ภาพที่ 3.5

โครงสร้างโดยรวมของเครือข่าย LSTM แบบลำดับเวลา (Sequential LSTM Architecture)

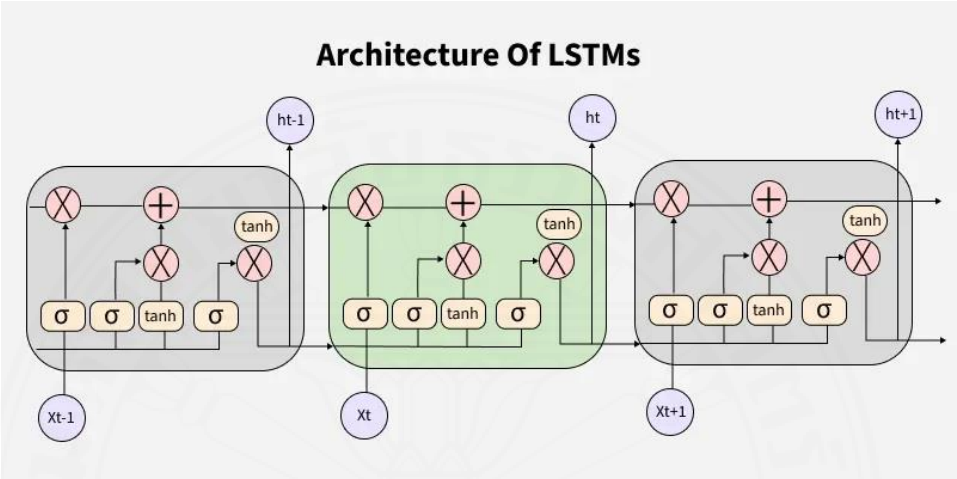

Note. Adapted from *Deep Learning | Introduction to Long Short-Term Memory (LSTM)*, by GeeksforGeeks, 2020. (https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/)

ภาพที่ 3.6

รายละเอียดภายในเซลล์ LSTM (LSTM Cell Structure with Gates: Forget, Input, Output)

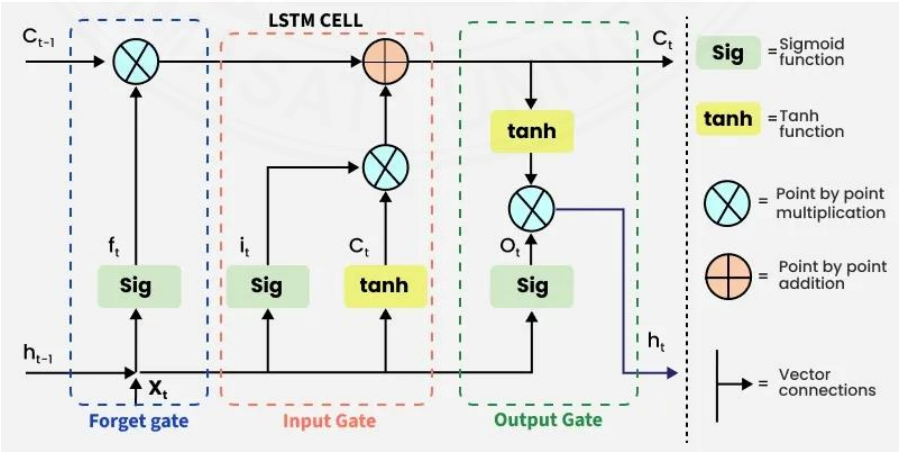

Note. Adapted from *Deep Learning | Introduction to Long Short-Term Memory (LSTM)*, by GeeksforGeeks, 2020. (https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/)

Ref. code: 25676602110550SKO

3.3 วิธีการดำเนินการวิจัย

3.3.1 การเก็บข้อมูล (Data Gathering)

งานวิจัยนี้ดำเนินการเก็บรวบรวมข้อมูลดัชนี S&P 500 (สัญลักษณ์ ^GSPC) ซึ่งเป็นตัวแทนของตลาดหุ้นสหรัฐอเมริกา และดัชนี SET ซึ่งเป็นตัวแทนของตลาดหุ้นไทย(สัญลักษณ์ ^SET.BK) โดยใช้ข้อมูลราคาหลักทรัพย์รายวัน (Daily Price Data) ประกอบด้วย ราคาปิด (Close), ราคาสูงสุด (High), ราคาต่ำสุด (Low), ราคาเปิด (Open) และปริมาณการซื้อขาย (Volume) ในช่วงระยะเวลา 10 ปี ตั้งแต่วันที่ 1 มกราคม พ.ศ. 2558 ถึงวันที่ 31 ธันวาคม พ.ศ. 2567 กระบวนการดึงข้อมูลดำเนินการผ่านไลบรารี yfinance ของภาษา Python ซึ่งเป็นเครื่องมือสำหรับเชื่อมต่อและดึงข้อมูลตลาดการเงินจากฐานข้อมูล Yahoo Finance ได้อย่างสะดวกและมีความน่าเชื่อถือ โดยใช้คำสั่ง yf.download() เพื่อดึงข้อมูลในรูปแบบรายวัน (Daily Interval) ตัวอย่างคำสั่งที่ใช้มีดังนี้ การดำเนินการดังกล่าวทำให้ได้ชุดข้อมูลดิบซึ่งมีลักษณะเป็น Time Series Data สำหรับใช้ในการพัฒนาแบบจำลองเชิงพยากรณ์ต่อไป ทั้งนี้ ข้อมูลที่ดึงมาครอบคลุมคุณลักษณะที่สำคัญทางการเงินครบถ้วน สามารถนำไปใช้ในการวิเคราะห์และสร้างตัวแปรต้นสำหรับแบบจำลองได้อย่างเหมาะสม

3.3.2 การจัดการข้อมูล (Data Preprocessing)

ภายหลังการรวบรวมข้อมูลจนครบถ้วน ได้ดำเนินการเตรียมความพร้อมของข้อมูล (Data Preprocessing) สำหรับการพัฒนาแบบจำลองเชิงพยากรณ์ โดยเริ่มจากการตรวจสอบและจัดการข้อมูลสูญหาย (Missing Data) ซึ่งอาจเกิดขึ้นจากความคลาดเคลื่อนในการบันทึกหรือข้อจำกัดของแหล่งข้อมูล โดยดำเนินการลบข้อมูลที่ไม่สมบูรณ์หรือใช้วิธีการประมาณค่า ในกรณีที่เหมาะสม เพื่อให้ได้ชุดข้อมูลที่มีความสมบูรณ์และพร้อมสำหรับการวิเคราะห์ นอกเนื่องจากนี้ยังสร้างอีกสองชุดข้อมูลของ ดัชนี S&P 500 และ ดัชนี SET โดยทำการตัดส่วนของปีที่มีเหตุการณ์ Covid-19 ออกเพื่อแยกทดสอบและเปรียบเทียบผลกระทบของเหตุการณ์ได้

ต่อจากนั้นจึงเข้าสู่กระบวนการสร้างคุณลักษณะ (Feature Engineering) ซึ่งเป็นขั้นตอนสำคัญในการเพิ่มศักยภาพของแบบจำลอง โดยพิจารณาสร้างตัวแปรใหม่ในรูปแบบอัตราการเปลี่ยนแปลงเชิงร้อยละ (Percentage Change Features) และฟีเจอร์เชิงลอการิทึม (Logarithmic Features) เพื่อสะท้อนลักษณะเชิงพลวัตของราคาหลักทรัพย์และปริมาณการซื้อขายได้อย่างเหมาะสมกับลักษณะของข้อมูลเชิงเวลา (Time Series Data) ฟีเจอร์ที่สร้างขึ้น ได้แก่ ผลตอบแทนรายวันเชิงลอการิทึม (Log Returns), ช่วงการซื้อขายเชิงลอการิทึม (Log Trading Range), อัตราการเปลี่ยนแปลงของปริมาณการซื้อขายเชิงลอการิทึม (Log Volume Change), อัตรา

Ref. code: 25676602110550SKO

ความผันผวนย้อนหลัง 10 วัน (Previous 10-day Volatility), อัตราความผันผวนย้อนหลัง 30 วัน (Previous 30-day Volatility) และอัตราความผันผวนล่วงหน้า 10 วัน (Next 10-day Volatility)

การนำลอการิทึม (Logarithmic Transformation) มาประยุกต์ใช้ในกระบวนการสร้างฟีเจอร์มีวัตถุประสงค์เพื่อให้แบบจำลองสามารถจับความสัมพันธ์เชิงสัดส่วน ของข้อมูลได้อย่างมีประสิทธิภาพมากยิ่งขึ้น เนื่องจากการเปลี่ยนแปลงของราคาหลักทรัพย์และปริมาณการซื้อขายในตลาดการเงินมักเกิดขึ้นในลักษณะของอัตราส่วนมากกว่าค่าตัวเลขสัมบูรณ์ (Absolute Change) อีกทั้งการใช้ลอการิทึมยังช่วยลดปัญหาความเบ้ (Skewness) ของข้อมูล และทำให้การแจกแจงของข้อมูลมีลักษณะใกล้เคียงกับการแจกแจงปกติ (Normal Distribution) ซึ่งเป็นสมมติฐานสำคัญของหลายเทคนิคทางสถิติและแบบจำลองเชิง Machine Learning นอกจากนี้ ฟีเจอร์ในรูปแบบเปอร์เซ็นต์และลอการิทึมยังช่วยลดอคติที่เกิดจากความแตกต่างของระดับราคา (Price Scale) และปริมาณการซื้อขาย (Trading Volume) ของหลักทรัพย์แต่ละตัว ส่งผลให้แบบจำลองสามารถตีความและเรียนรู้โครงสร้างของข้อมูลได้ง่ายขึ้น และสามารถนำไปประยุกต์ใช้กับหลักทรัพย์ตัวอื่น ๆ ที่มีลักษณะทางการเงินแตกต่างกันได้อย่างมีประสิทธิภาพมากยิ่งขึ้น อีกทั้งยังช่วยส่งเสริมความสามารถในการพยากรณ์ (Generalization Ability) ของแบบจำลองให้สามารถใช้งานได้ในวงกว้างและรองรับความหลากหลายของชุดข้อมูลในอนาคต

3.3.2.1 ผลตอบแทนรายวันเชิงลอการิทึม (Log Returns)

Log Returns อธิบายอัตราการเปลี่ยนแปลงของราคาปิดระหว่างสองวันติดต่อกัน โดยการแปลงให้อยู่ในรูปลอการิทึมธรรมชาติ (Natural Logarithm) ช่วยลดผลกระทบของค่าผันผวนสูงในข้อมูลทางการเงิน และทำให้การแจกแจงของผลตอบแทนเข้าใกล้รูปแบบการแจกแจงแบบปกติมากขึ้น

$$\log\ \text{return} = \ln\left(\frac{\text{Close}_t}{\text{Close}_{t-1}}\right)$$

3.3.2.2 ช่วงการซื้อขายเชิงลอการิทึม (Log Trading Range)

Log Trading Range อธิบายช่วงความผันผวนของราคาภายในวันเดียว โดยพิจารณาค่าสูงสุดและต่ำสุดของราคาหลักทรัพย์ในแต่ละวัน แล้วนำมาคำนวณในรูปของลอการิทึม ช่วยให้สามารถวิเคราะห์ความเสี่ยงเชิงสัดส่วนได้ชัดเจนยิ่งขึ้น

Ref. code: 25676602110550SKO

$$\log \text{ trading range} = \ln\left(\frac{\text{High}_t}{\text{Low}_t}\right)$$

3.3.2.3 อัตราการเปลี่ยนแปลงของปริมาณการซื้อขายเชิงลอการิทึม (Log Volume Change)

Log Volume Change อธิบายการเปลี่ยนแปลงของปริมาณการซื้อขายระหว่างสองวันติดต่อกัน โดยการแปลงค่าด้วยลอการิทึม ช่วยลดความเบ้ของข้อมูล และทำให้การวิเคราะห์หรือการนำเข้าโมเดลมีความเสถียรยิ่งขึ้น

$$\log \text{ volume change} = \ln\left(\frac{\text{Volume}_t}{\text{Volume}_{t-1}}\right)$$

3.3.2.4 อัตราความผันผวนย้อนหลัง n วัน (Previous n day Volatility)

Previous n day Volatility อธิบายระดับความผันผวนของผลตอบแทนในช่วง n วันย้อนหลัง โดยการคำนวณส่วนเบี่ยงเบนมาตรฐานของผลตอบแทนที่ถูกแปลงให้อยู่ในรูปของลอการิทึม ซึ่งค่าดังกล่าวสามารถใช้เป็นตัวแทนความเสี่ยงในช่วงเวลาหนึ่ง และเป็นตัวแปรสำคัญในงานด้านการวิเคราะห์เชิงปริมาณและการพยากรณ์ราคาทางการเงิน

$$\text{Previous n days Volatility} \quad = \sigma_t^n$$

$$= \sqrt{\frac{1}{n-1}\sum_{i=0}^{n}(\log r_{t-i})^2}$$

3.3.3 การฝึกสอนตัวแบบ (Model Training)

เมื่อข้อมูลถูกจัดการพร้อมสำหรับการฝึกโมเดลเราจึงแบ่งชุดข้อมูลออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลฝึกสอน (Training Set) ชุดข้อมูลตรวจสอบไขว้ (Cross Validation Set) และชุดข้อมูลทดสอบ (Testing Set) โดยทำการแบ่งเป็น 60:20:20 เมื่อเริ่มทำการฝึกพร้อม early-stop เพื่อป้องกันไม่ให้โมเดลทำงานเกินความจำเป็นหาก error ไม่ลดลงอีกแล้ว ในระหว่างการฝึกรปรับค่าพารามิเตอร์ของแต่ละอัลกอริทึม พร้อมทั้งค้นหาตัวแบบที่มีประสิทธิภาพในการพยากรณ์สูงที่สุดโดยใช้ข้อมูลชุดฝึกสอน และเมื่อได้โมเดลที่พอใจจะทำการเซฟในรูปแบบไฟล์ .h5

Ref. code: 25676602110550SKO

ภาพที่ 3.7

โครงสร้างของเครือข่าย LSTM

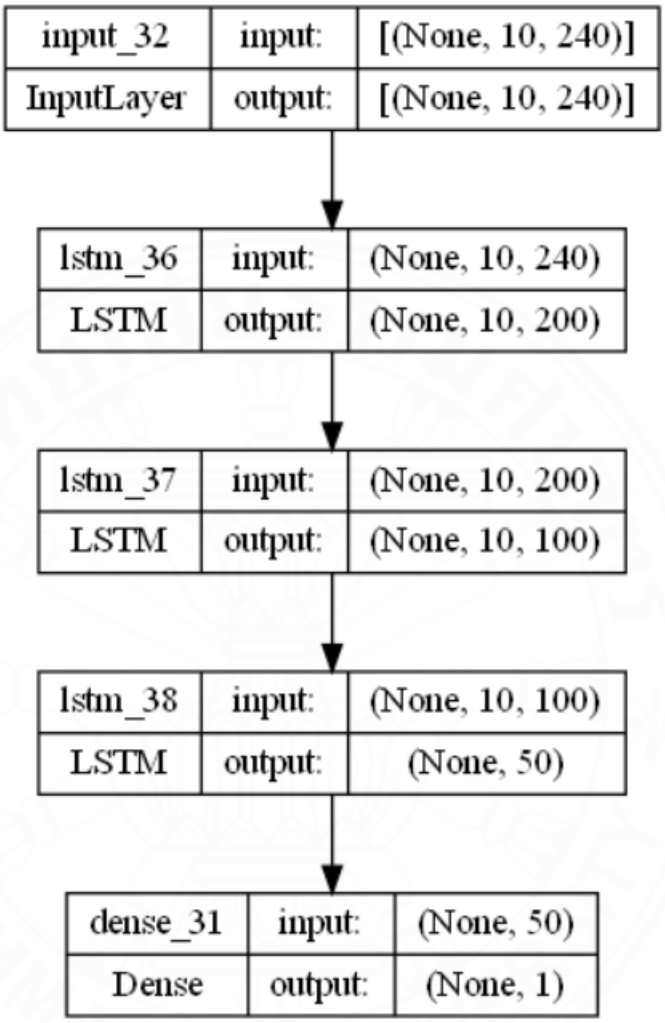

3.3.4 การทดสอบตัวแบบ (Model Testing)

ในขั้นตอนสุดท้ายจะใช้ชุดข้อมูลทดสอบ ซึ่งถือเป็นข้อมูลใหม่ที่ตัวแบบไม่เคยเห็นมาก่อน มาใช้ในการทดสอบประสิทธิภาพการพยากรณ์ของตัวแบบ พร้อมทั้งโหลดโมเดลที่ได้จากขั้นตอนก่อนหน้ามาทดสอบ

Ref. code: 25676602110550SKO

3.4 ค่าสถิติที่ใช้ในการเปรียบเทียบความแม่นยำของตัวแบบ (Evaluation Metrics)

ในการจำแนกระหว่างโมเดลที่มีประสิทธิภาพสูงและโมเดลที่มีประสิทธิภาพต่ำจำเป็นต้องมีค่าตัวเลขที่มีเหมาะสมในการใช้วัดประสิทธิภาพความแม่นยำ ค่าที่นิยมใช้ในการวัดประสิทธิภาพในการพยากรณ์ของโมเดลมีด้วยกัน 3 ค่าด้วยกัน คือ 1. ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) 2. ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) และ 3. รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

3.4.1 ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE)

ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) เป็นตัวชี้วัดที่ใช้วัดความคลาดเคลื่อนโดยเฉลี่ยระหว่างค่าที่แบบจำลองพยากรณ์ ($\hat{\boldsymbol{y}}_{\boldsymbol{t}}$) กับค่าจริง ($\boldsymbol{y}_{\boldsymbol{t}}$) โดยการคำนวณจากค่าความแตกต่างสัมบูรณ์ของแต่ละช่วงเวลาแล้วหาค่าเฉลี่ย MAE มีข้อดีคือให้ค่าน้ำหนักเท่ากันกับข้อผิดพลาดทุกรายการ จึงเหมาะกับกรณีที่ไม่ต้องการให้ค่าผิดพลาดขนาดใหญ่มากเกินไปมีอิทธิพลต่อผลลัพธ์รวม

$$\mathrm{MAE} = \frac{1}{\mathrm{T}}\sum_{\mathrm{t}=1}^{\mathrm{T}}|\hat{\mathrm{y}}_{\mathrm{t}} - \mathrm{y}_{\mathrm{t}}|$$

T = จำนวนข้อมูลทั้งหมดหรือจำนวนช่วงเวลา (Time steps)

y_t = ค่าจริง (Actual value)

$\hat{y}_t$ = ค่าการท้านาย (Prediction value)

3.4.2 ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error: MSE)

ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) เป็นตัวชี้วัดที่นิยมใช้ในงานทำนายและการวิเคราะห์โมเดลเชิงปริมาณ โดยจะนำค่าความคลาดเคลื่อน (Error) ของแต่ละช่วงเวลามายกกำลังสองเพื่อลดผลของค่าลบ และให้ความสำคัญกับข้อผิดพลาดขนาดใหญ่ MSE มีลักษณะอ่อนไหวต่อ outliers จึงเหมาะกับกรณีที่ต้องการเน้นการลงโทษข้อผิดพลาดขนาดใหญ่

$$\mathrm{MSE} = \frac{1}{\mathrm{T}}\sum_{\mathrm{t}=1}^{\mathrm{T}}(\hat{\mathrm{y}}_{\mathrm{t}} - \mathrm{y}_{\mathrm{t}})^2$$

T = จำนวนข้อมูลทั้งหมดหรือจำนวนช่วงเวลา (Time steps)

y_t = ค่าจริง (Actual value)

$\hat{y}_t$ = ค่าการท้านาย (Prediction value)

Ref. code: 25676602110550SKO

3.4.3 รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE)

RMSE คือค่ารากที่สองของ MSE ซึ่งมีหน่วยเดียวกับตัวแปรต้นฉบับ จึงช่วยให้การตีความผลลัพธ์ทำได้ง่ายขึ้นกว่า MSE โดยเฉพาะเมื่อใช้ในการประเมินผลของโมเดลการพยากรณ์ทางการเงินหรือข้อมูลเชิงเวลา RMSE เป็นตัวชี้วัดที่นิยมใช้เนื่องจากรวมข้อดีของการลงโทษข้อผิดพลาดขนาดใหญ่เช่นเดียวกับ MSE แต่มีหน่วยสอดคล้องกับข้อมูลจริง

$$\mathrm{RMSE} = \sqrt{\frac{1}{\mathrm{T}}\sum_{\mathrm{t}=1}^{\mathrm{T}}(\hat{y}_t - y_t)^2}$$

T = จำนวนข้อมูลทั้งหมดหรือจำนวนช่วงเวลา (Time steps)

y_t = ค่าจริง (Actual value)

$\hat{y}_t$= ค่าการท้านาย (Prediction value)

Ref. code: 25676602110550SKO

บทที่ 4
ผลการวิจัยและอภิปรายผล

4.1 การวิเคราะห์ผลการทดลอง

จากการออกแบบและสร้างตัวแบบทางเศรษฐมิติและโมเดลที่ใช้เทคนิคการเรียนรู้ของเครื่องและเทคนิคการเรียนรู้เชิงลึก โดยการนำข้อมูลความรู้ที่ได้จากการศึกษาวรรณกรรมและงานวิจัยที่เกี่ยวข้องมาปรับใช้ในการศึกษาแล้ว ในส่วนถัดไปจะกล่าวถึงผลการศึกษาโดยจะเริ่มจากผลสรุปการเปรียบเทียบของตัวแบบการพยากรณ์ในแต่ละส่วนของการศึกษา โดยการทดลองจะเริ่มจากการทดลองโมเดลเดี่ยวตามด้วยโมเดลผสมบนสองชุดข้อมูลคือ SET index และ S&P500 index หลังจากนั้นจึงทดสอบผลกระทบของ Covid-19 ว่าหากตัดช่วงข้อมูลที่มีเหตุการณ์นี้ทิ้งไปจะทำให้ได้ผลที่แตกต่างจากเดิมหรือไม่

4.1.1 ประสิทธิภาพการพยากรณ์โมเดลเดี่ยว (Single model)

ในขั้นตอนแรกของการทดลอง ผู้วิจัยได้ดำเนินการทดสอบประสิทธิภาพของแต่ละโมเดลแบบแยกเดี่ยว เพื่อประเมินความสามารถในการพยากรณ์ความผันผวนของราคาหลักทรัพย์ โดยเริ่มจากการใช้โมเดลทางเศรษฐมิติ ได้แก่ GARCH ซึ่งถูกนำมาใช้ในการพยากรณ์ความผันผวนของดัชนีราคาหลักทรัพย์ S&P500 และ SET ทั้งนี้ การประเมินประสิทธิภาพของการพยากรณ์จะพิจารณาจากค่าทางสถิติ 3 เกณฑ์ ได้แก่ ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE), ค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนยกกำลังสอง (Root Mean Squared Error: RMSE) และค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error: MSE) ซึ่งได้จากการเปรียบเทียบระหว่างค่าความผันผวนที่พยากรณ์ได้กับค่าความผันผวนที่เกิดขึ้นจริง หลังจากนั้น ได้ดำเนินการทดลองเพิ่มเติมด้วยโมเดลแมชชีนเลิร์นนิ่งต่าง ๆ เพื่อเปรียบเทียบประสิทธิภาพกับโมเดล GARCH โดยมีวัตถุประสงค์เพื่อระบุว่า โมเดลแบบใดมีความสามารถในการพยากรณ์ความผันผวนได้แม่นยำที่สุดภายใต้เกณฑ์การประเมินเดียวกัน

4.1.1.1 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี S&P500

การสร้างตัวแบบการพยากรณ์ความผันผวนของราคาหลักทรัพย์ดัชนี S&P500 โดยใช้ GARCH จะใช้ตัวแปรเพียงหนึ่งตัวแปรในขั้นตอนการสร้างตัวแบบคือ ความผันผวนเฉลี่ยย้อนหลัง 30 วันล่าสุด เพื่อทำการพยากรณ์ค่าความ ผันผวน

Ref. code: 25676602110550SKO

ภาพที่ 4.1

กราฟเส้นแสดงความผันผวนที่พยากรณ์ GARCH กับอัตราความผันผวนหลักทรัพย์ดัชนี S&P500

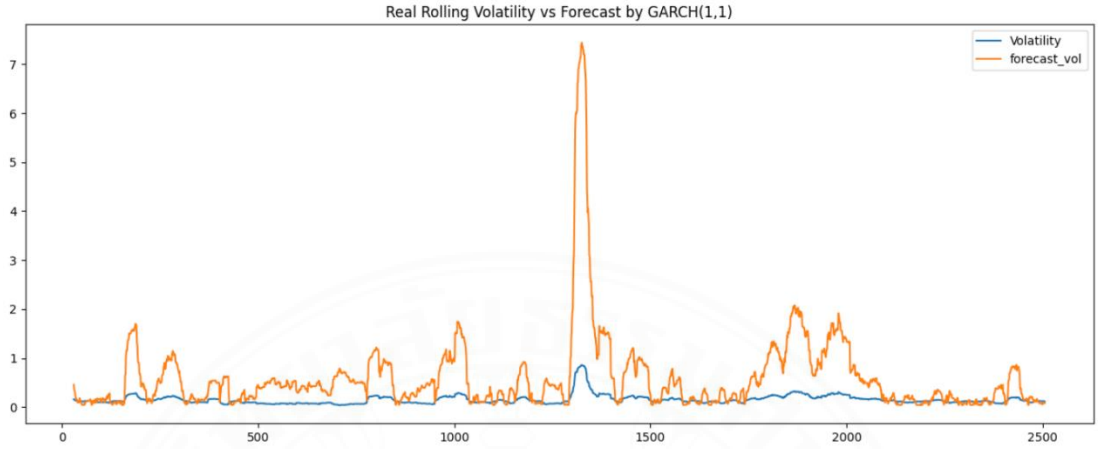

ตารางที่ 4.1

ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี S&P500

Model	Trend	alpha	beta
GARCH	0.1691	0.9622	0.0378

ค่า alpha = 0.9622 สะท้อนให้เห็นว่า ความแปรปรวนตามเงื่อนไขในปัจจุบัน (conditional variance) มีความไวต่อ shock หรือความคลาดเคลื่อนของค่าพยากรณ์ในช่วงเวลาก่อนหน้าอย่างมาก กล่าวคือ โมเดลให้ความสำคัญกับข้อมูลใหม่ที่เข้ามาในระบบเป็นหลัก ความผิดพลาดจากอดีตล่าสุดมีอิทธิพลสูงในการกำหนดค่าความผันผวนในช่วงเวลาปัจจุบัน

ในขณะเดียวกัน ค่า beta = 0.0378 แม้จะมีขนาดเล็กเมื่อเทียบกับ alpha แต่ก็มีนัยสำคัญในการบ่งชี้ว่า โมเดลยังคงนำเอาความแปรปรวนจากช่วงเวลาก่อนหน้าเข้ามาคำนวณร่วมด้วย กล่าวคือ ความผันผวนในอดีตยังคงมีบทบาทในการส่งอิทธิพลต่อค่าความผันผวนในปัจจุบัน แต่ในระดับที่จำกัด เมื่อรวมค่า alpha + beta = 1.0000 พอดี แสดงให้เห็นว่า โมเดลนี้มีลักษณะอยู่ในภาวะ เสถียรภาพจำกัด (boundary stationarity) ซึ่งหมายความว่า ความผันผวนจะยังคงมีความต่อเนื่องสูง (high persistence) และอาจลดลงได้ช้าหลังจากเกิด shock ในตลาด อย่างไรก็ตาม โมเดลยังไม่ถึงขั้นไม่เสถียร (non-stationary) ซึ่งถือว่าอยู่ในขอบเขตที่ยอมรับได้ในเชิงเศรษฐมิติ

ส่วนค่า Trend = 0.1691 ทำหน้าที่เป็นค่าคงที่ในสมการ GARCH โดยบ่งชี้ถึงระดับพื้นฐานของความแปรปรวนในระบบ หรือค่าความผันผวนที่ยังคงอยู่แม้ในกรณีที่ไม่มี

Ref. code: 25676602110550SKO

shock หรือความแปรปรวนตกค้างจากอดีต เป็นค่าที่ช่วยให้โมเดลสามารถเริ่มการคำนวณได้แม้ในสภาวะตลาดปกติ

ตารางที่ 4.2

ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี S&P500

Model	MSE	RMSE	MAE
GARCH	0.791349	0.889578	0.463082

การสร้างตัวแบบการพยากรณ์ความผันผวนของราคาหลักทรัพย์ดัชนี S&P500 โดยใช้แมชชีนเลิร์นนิ่งจะใช้ตัวแปร 5 ตัวแปรในขั้นตอนการสร้างตัวแบบ ซึ่งจะใช้ข้อมูลความผันผวนก่อนช่วงเวลาที่ต้องการพยากรณ์ 10 วัน และ30 วันล่าสุด เพื่อทำการพยากรณ์ค่าความผันผวน ทั้งนี้ ได้มีการทดลองสร้างตัวแบบขึ้นมาทั้งหมด 6 ตัวแบบ เพื่อเปรียบเทียบประสิทธิภาพการพยากรณ์ โดยแต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.2 – 4.7 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

ภาพที่ 4.2

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บนดัชนี S&P500

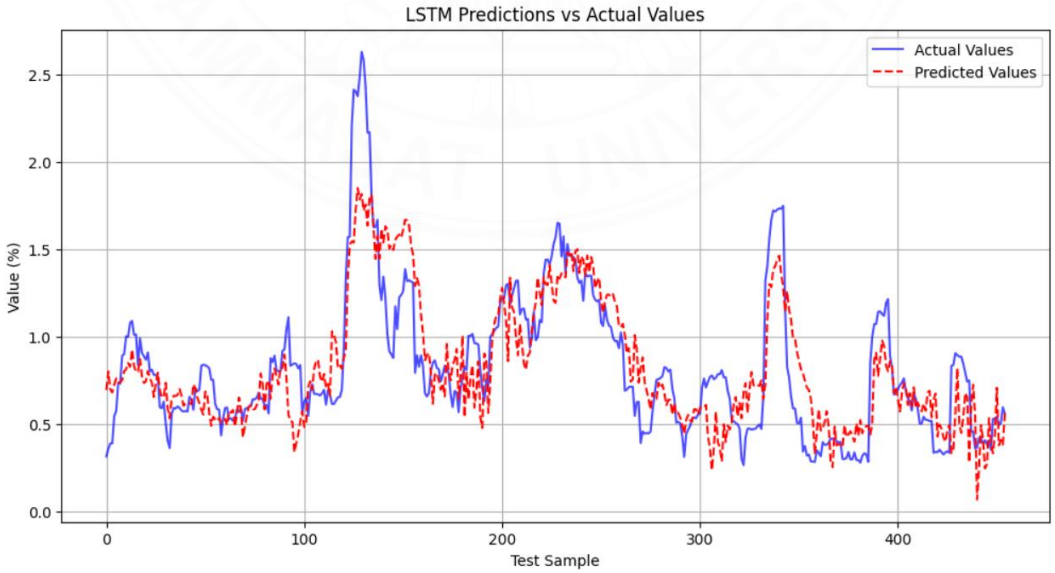

Ref. code: 25676602110550SKO

ภาพที่ 4.3

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บนดัชนี S&P500

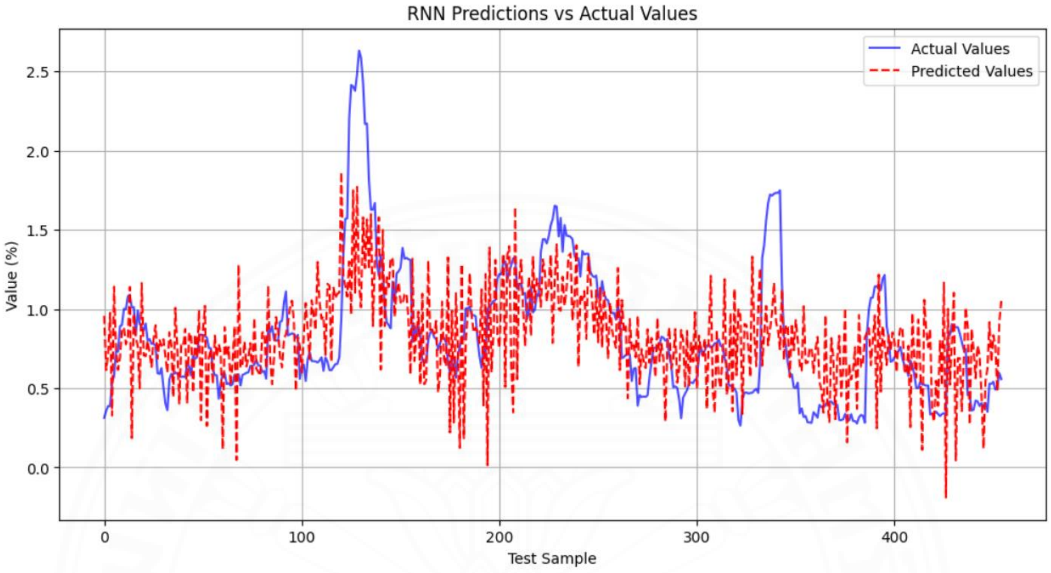

ภาพที่ 4.4

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บนดัชนี S&P500

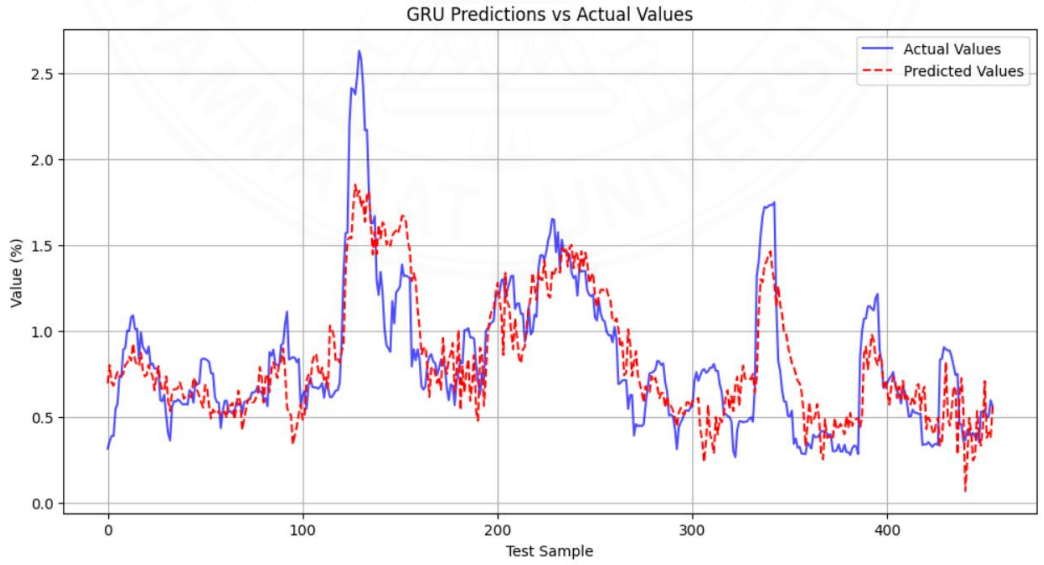

Ref. code: 25676602110550SKO

ภาพที่ 4.5

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี S&P500

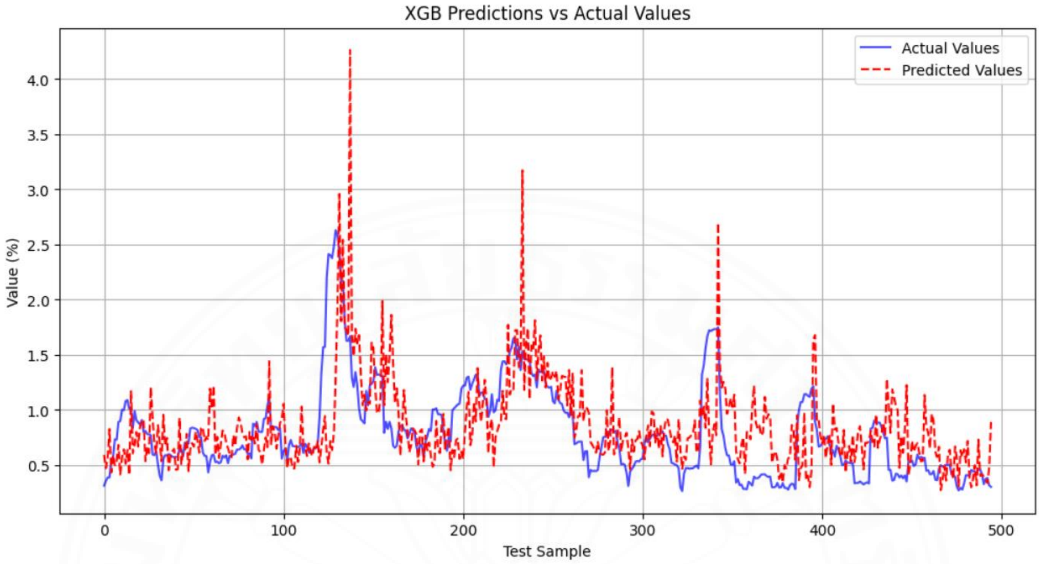

ภาพที่ 4.6

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random-Forest บนดัชนี S&P500

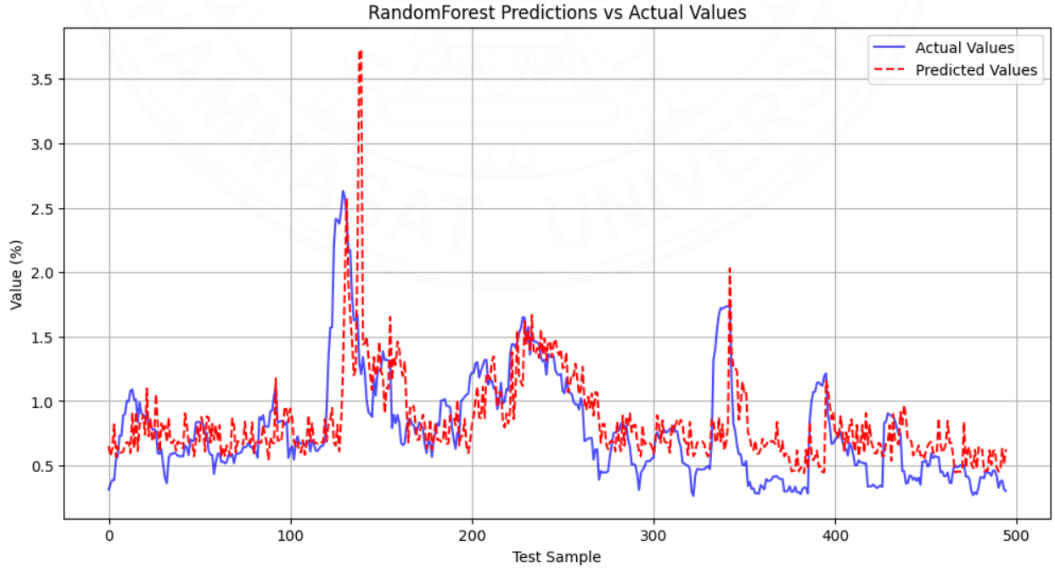

Ref. code: 25676602110550SKO

ภาพที่ 4.7

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Support Vector Machine บนดัชนี S&P500

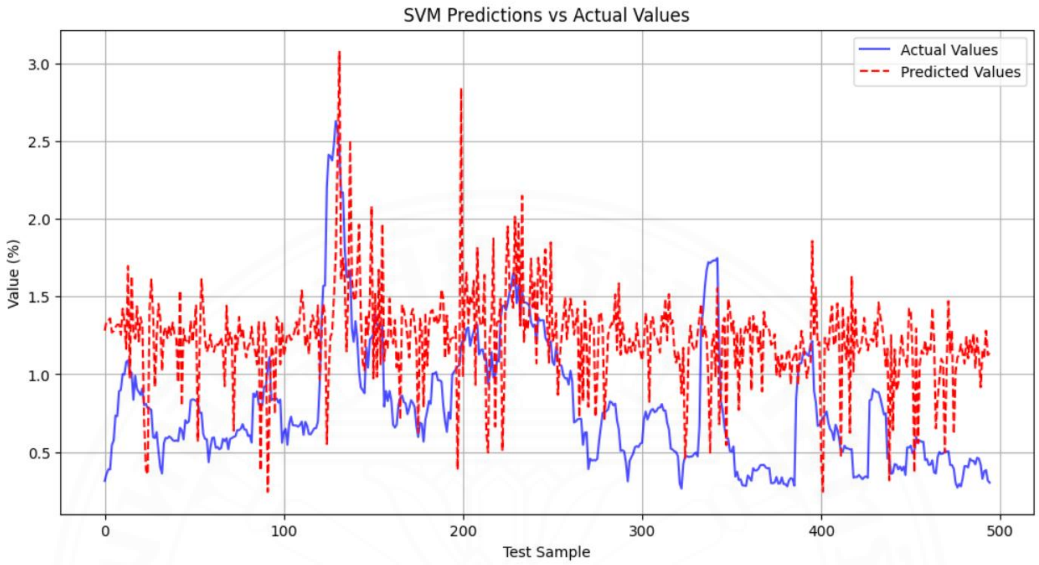

ตารางที่ 4.3

ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี S&P500

Model	MSE	RMSE	MAE
GARCH	0.791349	0.889578	0.463082
LSTM	0.000004	0.001895	0.001490
RNN	0.000014	0.003782	0.002910
GRU	0.000007	0.002642	0.002065
XGBoost	0.000016	0.004011	0.002846
Random Forest	0.000013	0.003639	0.002426
Support Vector Machine	0.000037	0.006097	0.005448

จากการเปรียบเทียบประสิทธิภาพของโมเดลต่าง ๆ ที่นำมาใช้ในการทำนายความผันผวนของข้อมูล พบว่าโมเดลในกลุ่มที่พัฒนามาจาก Recurrent Neural Networks (โดยต่อจากนี้จะขอเรียกว่ากลุ่ม RNNs รวม RNN, LSTM, GRU) โดยเฉพาะ LSTM และ GRU สามารถให้ผลการทำนายที่มีค่าความคลาดเคลื่อนน้อยที่สุดเมื่อพิจารณาจาก MSE, RMSE และ MAE

Ref. code: 25676602110550SKO

โดย LSTM ให้ค่าความผิดพลาดต่ำที่สุดในทุกตัวชี้วัด สะท้อนถึงศักยภาพของโมเดลนี้ในการเรียนรู้รูปแบบและลำดับของข้อมูลเวลาได้อย่างลึกซึ้งและมีประสิทธิภาพ ในขณะที่ GRU และ RNN ซึ่งอยู่ในกลุ่มโมเดลแบบลำดับเช่นเดียวกัน ก็สามารถให้ผลการทำนายที่ใกล้เคียงกับ LSTM โดย GRU มีค่าความผิดพลาดต่ำกว่า RNN เล็กน้อย ซึ่งแสดงให้เห็นว่าโมเดลเหล่านี้มีความสามารถในการจับความสัมพันธ์ในข้อมูลเวลาได้ดี สำหรับโมเดลอื่นๆ เช่น Random Forest และ XGBoost ก็ให้ผลลัพธ์ที่น่าพอใจในระดับหนึ่ง โดย Random Forest ทำผลงานได้ดีกว่า XGBoost เล็กน้อย อย่างไรก็ตาม เมื่อเปรียบเทียบกับโมเดลแบบลำดับแล้ว ยังมีค่าความผิดพลาดที่สูงกว่าอยู่พอสมควร ส่วนโมเดล Support Vector Machine กลับให้ผลลัพธ์ที่ด้อยกว่าทุกโมเดล โดยเฉพาะในแง่ของค่าความคลาดเคลื่อนเฉลี่ย (MAE) ซึ่งมีค่าสูงที่สุดในกลุ่มนี้ สุดท้ายคือโมเดล GARCH ซึ่งเป็นโมเดลเชิงสถิติแบบดั้งเดิมสำหรับการทำนายความผันผวน แม้ว่าจะเป็นที่นิยมในงานวิจัยทางการเงิน แต่จากผลการทดสอบพบว่ามีค่าความผิดพลาดสูงที่สุดในทุกตัวชี้วัด แสดงให้เห็นว่าโมเดลนี้อาจไม่สามารถตอบสนองต่อความซับซ้อนของข้อมูลในปัจจุบันได้ดีเท่ากับโมเดลเชิงลึก

กล่าวโดยสรุป ผลการทดลองครั้งนี้ชี้ให้เห็นว่า การนำโมเดลกลุ่ม RNNs มาใช้ ในรูปแบบโมเดลเดี่ยว โดยเฉพาะ LSTM และ GRU เป็นทางเลือกที่มีความเหมาะสมอย่างยิ่งในการทำนายความผันผวนของข้อมูล เนื่องจากสามารถลดความคลาดเคลื่อนในการทำนายได้อย่างมีนัยสำคัญเมื่อเทียบกับโมเดลแบบอื่น ๆ

4.1.1.2 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี SET

เพื่อให้การศึกษามีความครอบคลุมและสามารถสะท้อนผลลัพธ์ในบริบทของตลาดที่แตกต่างกันได้อย่างมีประสิทธิภาพตามที่ได้เกริ่นนำไว้ในบทก่อนหน้า งานวิจัยนี้จึงได้ดำเนินการทดลองเพิ่มเติมกับข้อมูลจากตลาดหลักทรัพย์แห่งประเทศไทย โดยเลือกใช้ดัชนี SET ซึ่งเป็นดัชนีที่สะท้อนภาพรวมของราคาหลักทรัพย์ในตลาดหลักทรัพย์ไทย โดยตรง เพื่อเป็นตัวแทนของตลาดในประเทศ การใช้ดัชนี SET เป็นกรณีศึกษานี้ มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของการประยุกต์ใช้โมเดลต่าง ๆ ที่ได้ศึกษาไว้ก่อนหน้านี้ในบริบทของตลาดต่างประเทศ กับการนำมาใช้งานจริงในบริบทของตลาดไทย ทั้งนี้เพื่อประเมินว่าโมเดลเหล่านี้มีความสามารถในการเรียนรู้และทำนายแนวโน้มของราคาหลักทรัพย์ได้ดีเพียงใด เมื่อสภาพแวดล้อมของตลาดเปลี่ยนแปลงไป

การทดลองนี้ยังเป็นการยืนยันความสามารถของโมเดลในเชิงความยืดหยุ่นในการนำไปปรับใช้ในสภาพตลาดที่มีความแตกต่างด้านโครงสร้าง ข้อมูล และพฤติกรรมของผู้ลงทุน ซึ่งนับเป็นปัจจัยสำคัญที่มีผลต่อความแม่นยำของการทำนายความผันผวนในตลาดทุน โดยเริ่มจากการสร้าง GARCH ดังภาพที่ 4.8

Ref. code: 25676602110550SKO

ภาพที่ 4.8

กราฟเส้นแสดงความผันผวนที่พยากรณ์ GARCH กับอัตรา ความผันผวนหลักทรัพย์ดัชนี SET

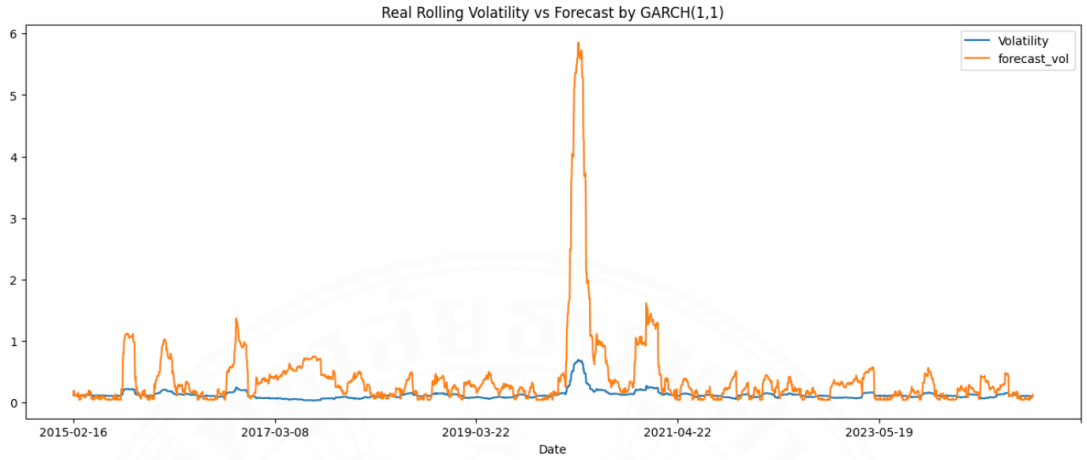

ตารางที่ 4.4

ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี SET

Model	Trend	alpha	beta
GARCH	0.1812	1.0000	0.0000

จากการประเมินค่าพารามิเตอร์ของโมเดล GARCH เพื่อใช้ในการวิเคราะห์ความผันผวนของข้อมูล พบว่าค่าพารามิเตอร์ที่ได้มีลักษณะเฉพาะที่สะท้อนถึงโครงสร้างของความแปรปรวนตามเวลาอย่างชัดเจน โดยมีค่า Trend = 0.1812, alpha = 1.0000 และ beta = 0.0000

ค่า alpha ที่มีค่าสูงถึง 1.0000 บ่งชี้ว่า ความผันผวนในปัจจุบัน (conditional variance) มีการตอบสนองอย่างเต็มที่ต่อค่าความผิดพลาด (shock) ในช่วงเวลาก่อนหน้า กล่าวคือ ความแปรปรวนในแต่ละช่วงเวลาถูกขับเคลื่อนด้วยอิทธิพลของข้อมูลใหม่ที่เข้ามาอย่างสมบูรณ์ ในขณะที่ค่า beta เท่ากับ 0.0000 แสดงให้เห็นว่าความแปรปรวนที่ตกค้างจากช่วงเวลาก่อนหน้า (lagged variance) ไม่ได้ส่งอิทธิพลต่อความผันผวนในปัจจุบันเลย กล่าวโดยรวม โมเดลนี้แสดงลักษณะของ GARCH(1,1) ซึ่งใกล้เคียงกับ ARCH model และเหมาะสมกับกรณีที่ความผันผวนถูกอธิบายได้เกือบทั้งหมดด้วย shock ในระยะสั้น โดยไม่มีการส่งต่อความแปรปรวนจากอดีตมายังปัจจุบันมากนัก

นอกจากนี้ ค่า Trend = 0.1812 อาจสะท้อนถึงระดับพื้นฐานของความผันผวนหรือ mean level ที่คงอยู่ในระบบ ซึ่งทำหน้าที่เป็นค่าคงที่ (constant) ในสมการการ

Ref. code: 25676602110550SKO

ประมาณความแปรปรวนตามเวลา ผลลัพธ์ในลักษณะนี้มีนัยสำคัญเชิงปฏิบัติ เนื่องจากสามารถชี้ให้เห็นถึงโครงสร้างของความเสี่ยงในตลาดที่เกิดจากความเปลี่ยนแปลงอย่างรวดเร็ว มากกว่าการค่อย ๆ สะสมความผันผวนจากอดีต

ตารางที่ 4.5

ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี SET

Model	MSE	RMSE	MAE
GARCH	0.411087	0.641160	0.279292

ลำดับถัดไปเป็นการสร้างโมเดล Deep learning และ Machine บนราคาหลักทรัพย์ดัชนี SET โดยแต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.9 – 4.14 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

ภาพที่ 4.9

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บนดัชนี SET

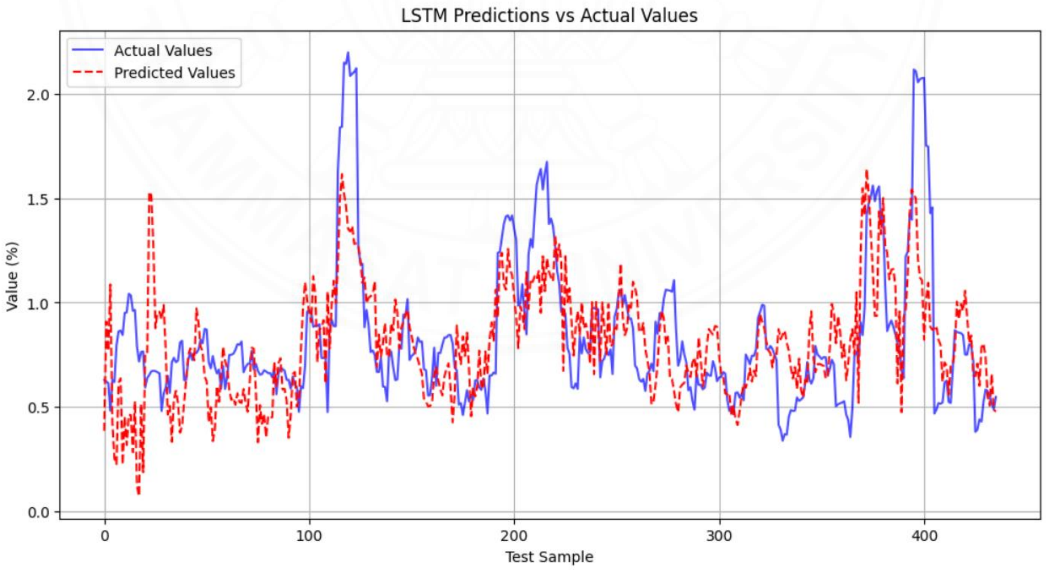

Ref. code: 25676602110550SKO

ภาพที่ 4.10

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บนดัชนี SET

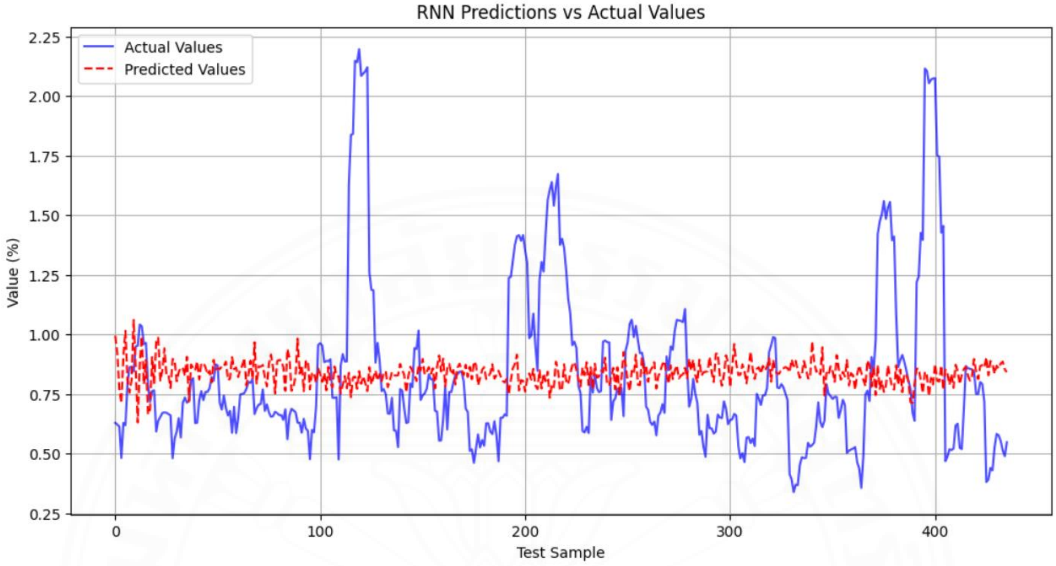

ภาพที่ 4.11

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บนดัชนี SET

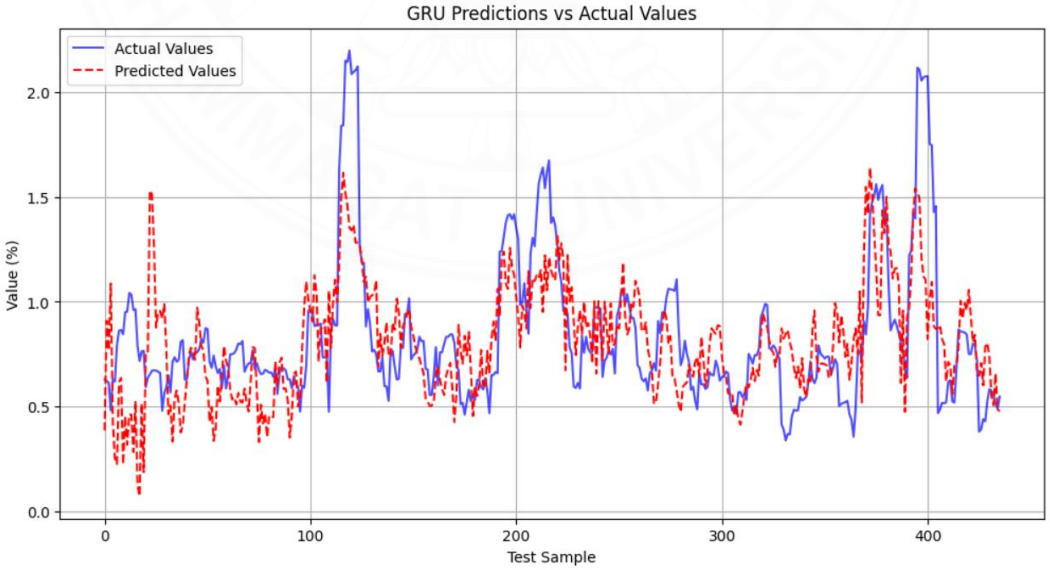

Ref. code: 25676602110550SKO

ภาพที่ 4.12

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี SET

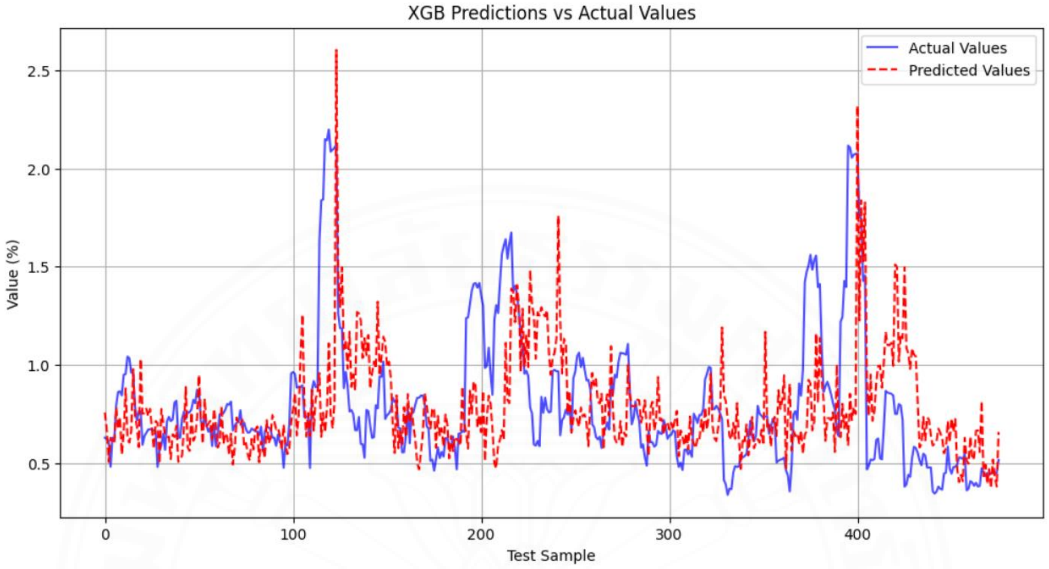

ภาพที่ 4.13

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random Forest บนดัชนี SET

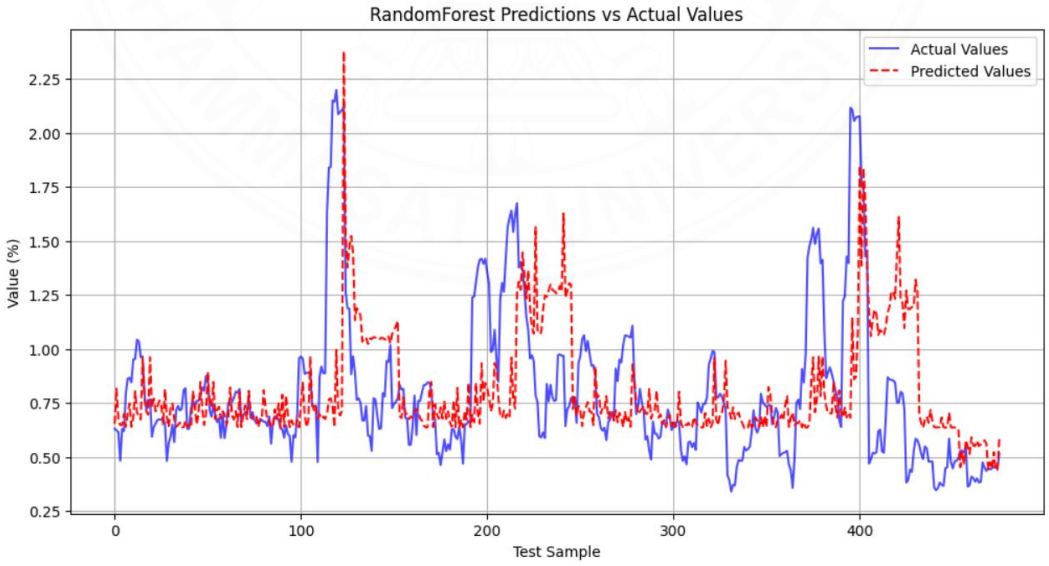

Ref. code: 25676602110550SKO

ภาพที่ 4.14

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Support Vector Machine บนดัชนี SET

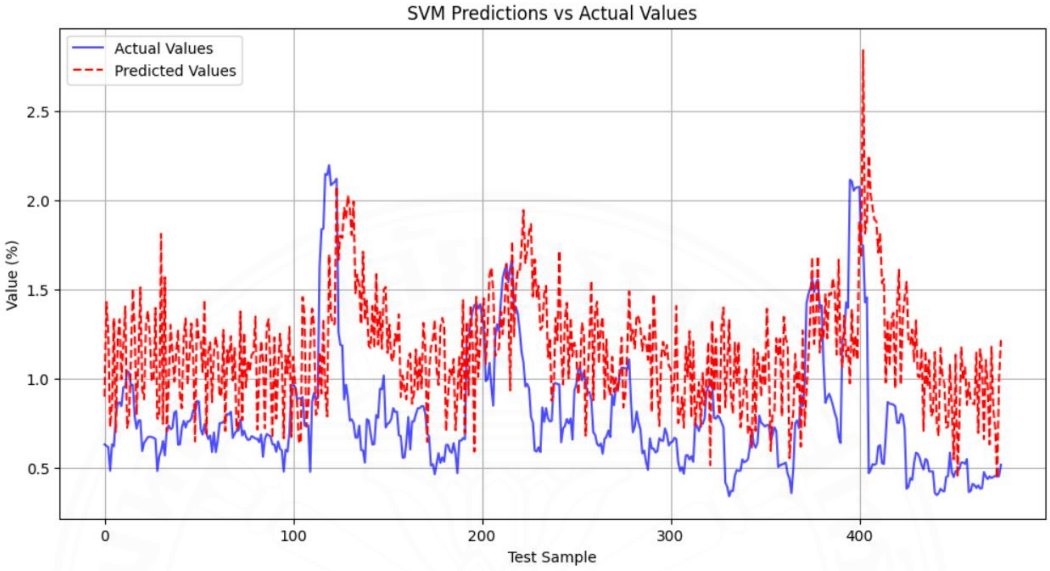

ตารางที่ 4.6

ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET

Model	MSE	RMSE	MAE
GARCH	0.411087	0.641160	0.279292
LSTM	0.000008	0.002894	0.002170
RNN	0.000014	0.003679	0.002606
GRU	0.000014	0.003765	0.002715
XGBoost	0.000013	0.003657	0.002511
Random Forest	0.000013	0.003645	0.002473
Support Vector Machine	0.000029	0.00538	0.004501

จากผลการเปรียบเทียบประสิทธิภาพของโมเดลต่าง ๆ บนดัชนี SET Index พบว่าโมเดลกลุ่ม RNNs โดยเฉพาะ LSTM ยังคงแสดงผลลัพธ์ที่ดีที่สุด โดยให้ค่าความผิดพลาดต่ำที่สุดในทุกตัวชี้วัด ได้แก่ MSE, RMSE และ MAE ซึ่งสอดคล้องกับผลลัพธ์บน S&P500 ที่ LSTM ทำผลงานได้ดีที่สุดเช่นกัน แสดงให้เห็นถึงความสามารถในการเรียนรู้ลำดับเวลาและจับความสัมพันธ์

Ref. code: 25676602110550SKO

เชิงลึกของข้อมูลได้อย่างมีประสิทธิภาพในทั้งสองตลาด ในกลุ่มของโมเดล RNN และ GRU พบว่าค่าความผิดพลาดอยู่ในระดับใกล้เคียงกัน โดย GRU ให้ผลแย่กว่าเล็กน้อยในตลาด SET แต่ดีกว่า RNN ในตลาด S&P500 ซึ่งอาจแสดงให้เห็นว่า GRU มีความสามารถในการปรับตัวกับลักษณะของข้อมูลตลาดแต่ละแบบแตกต่างกันไป

โมเดล XGBoost และ Random Forest ก็ให้ค่าผลลัพธ์ที่ใกล้เคียงกัน โดยในตลาด SET ทั้งสองโมเดลให้ผลที่ใกล้เคียงกัน และดีกว่าบนตลาด S&P500 เล็กน้อย ซึ่งแสดงให้เห็นถึงความเหมาะสมของโมเดลประเภทนี้กับข้อมูลตลาดในประเทศ อย่างไรก็ตาม โมเดล Support Vector Machine (SVM) ยังคงมีค่าความผิดพลาดสูงสุดในทั้งสองตลาด โดยเฉพาะค่าความผิดพลาดแบบเฉลี่ย (MAE) แสดงให้เห็นว่าโมเดลนี้อาจไม่เหมาะกับลักษณะข้อมูลทางการเงินที่มีความซับซ้อนและไม่เป็นเส้นตรงเช่นตลาดหุ้น สุดท้าย โมเดล GARCH ที่เป็นสถิติแบบดั้งเดิม ยังคงให้ผลลัพธ์ที่ด้อยกว่าโมเดลอื่นอย่างชัดเจนทั้งในตลาด SET และ S&P500 ซึ่งสะท้อนถึงข้อจำกัดของโมเดลเชิงสถิติในการจับข้อมูลเชิงลำดับเวลาและความไม่แน่นอนในตลาดปัจจุบัน

4.1.2 ประสิทธิภาพการพยากรณ์โมเดลผสม (Hybrid model)

ในการทดลองนี้ ได้มีการพัฒนาโมเดลผสม (Hybrid Model) โดยผสานจุดแข็งของแบบจำลอง GARCH ซึ่งมีความสามารถในการจับลักษณะของความผันผวนแบบมีเงื่อนไขในข้อมูลอนุกรมเวลา (time-varying volatility) เข้ากับอัลกอริทึมของ Machine Learning ที่มีความสามารถในการเรียนรู้เชิงลึกจากข้อมูลเชิงซ้อน

ขั้นตอนของการผสมโมเดลเริ่มจากการนำค่าความผันผวนที่ได้จาก GARCH มาใช้เป็นหนึ่งในคุณลักษณะ (feature) สำหรับการฝึกโมเดล Machine Learning เพื่อให้แบบจำลองสามารถเรียนรู้ได้ทั้งโครงสร้างเชิงเวลาและลักษณะไม่เชิงเส้นของข้อมูลอย่างมีประสิทธิภาพยิ่งขึ้น

แนวทางดังกล่าวมีเป้าหมายเพื่อเพิ่มความแม่นยำในการพยากรณ์ โดยอาศัยจุดแข็งของ GARCH ในด้านการจำลองลักษณะความไม่แน่นอนของตลาด และจุดเด่นของ Machine Learning ในการดึงรูปแบบที่ซ่อนอยู่ในข้อมูล ทำให้โมเดลผสมมีศักยภาพในการปรับตัวกับความเปลี่ยนแปลงของตลาดได้ดียิ่งขึ้นเมื่อเทียบกับโมเดลเดี่ยว

4.1.2.1 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนี S&P500

ผลลัพธ์การสร้างโมเดลผสมระหว่าง GARCH กับ Deep learning และ Machine บนราคาหลักทรัพย์ดัชนี S&P500 โดยแต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.15 – 4.20 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

Ref. code: 25676602110550SKO

ภาพที่ 4.15

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บนดัชนี S&P500

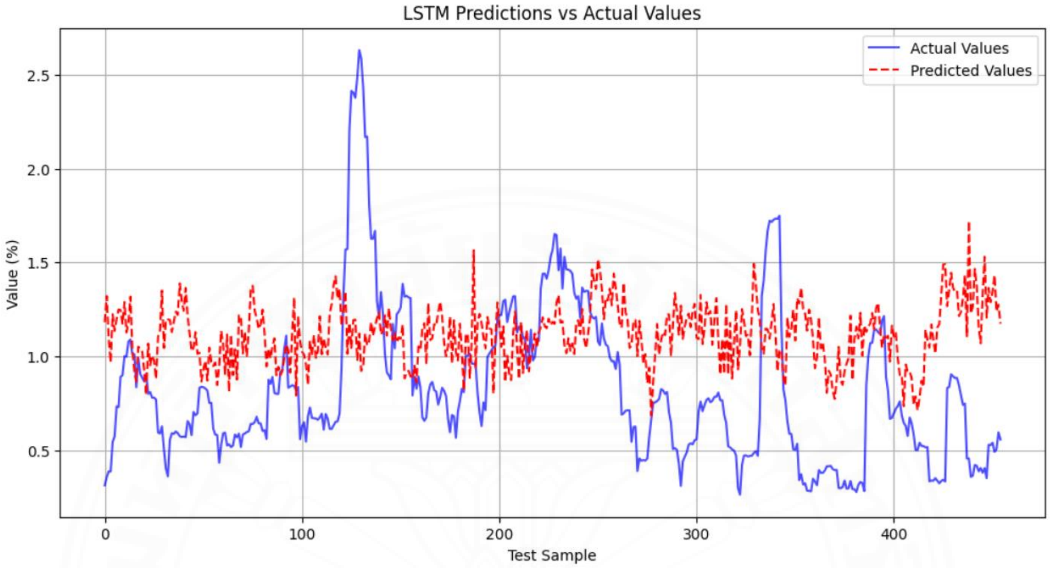

ภาพที่ 4.16

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี S&P500

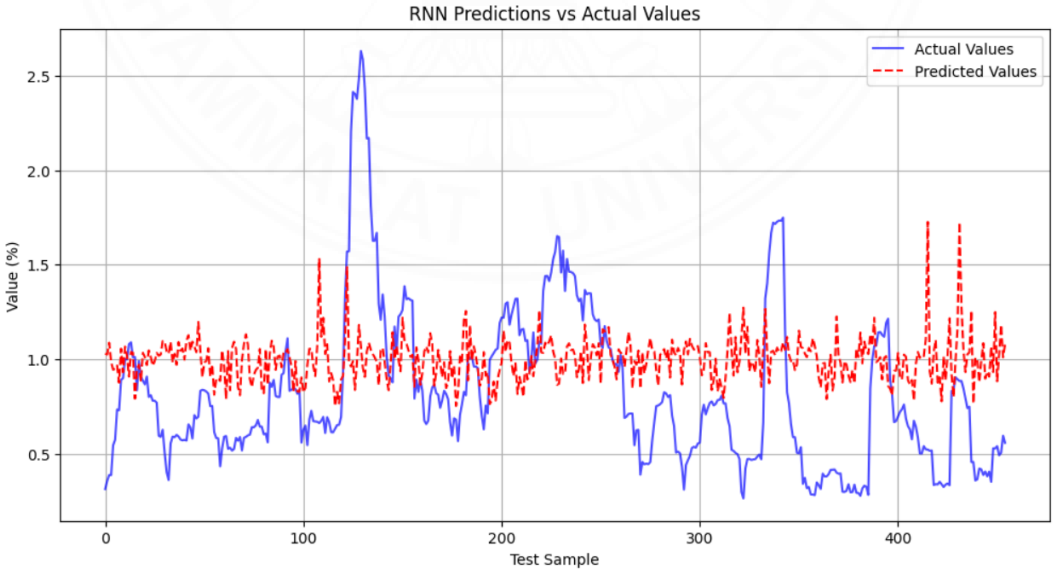

Ref. code: 25676602110550SKO

ภาพที่ 4.17

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี S&P500

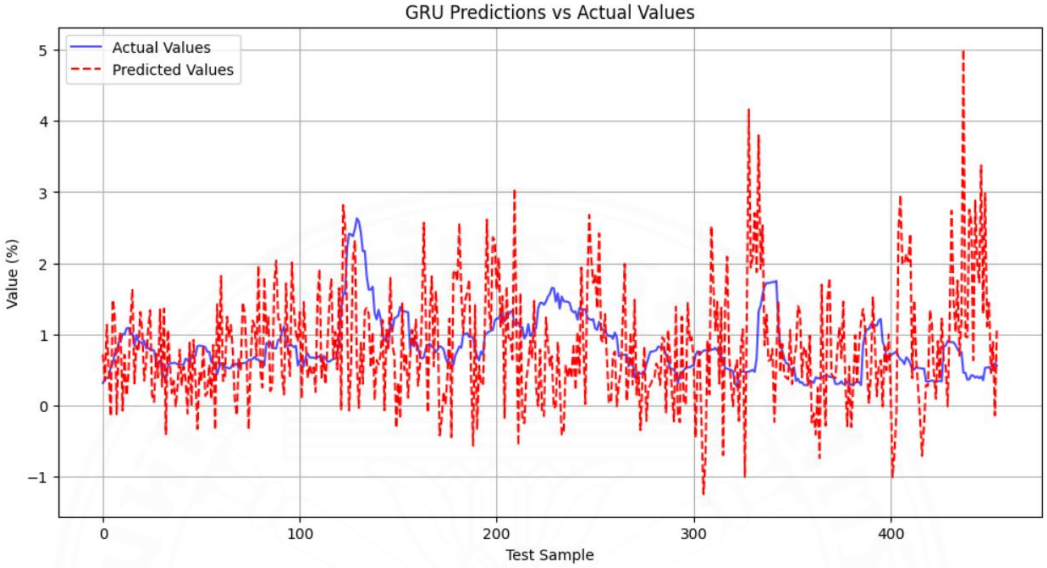

ภาพที่ 4.18

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บนดัชนี S&P500

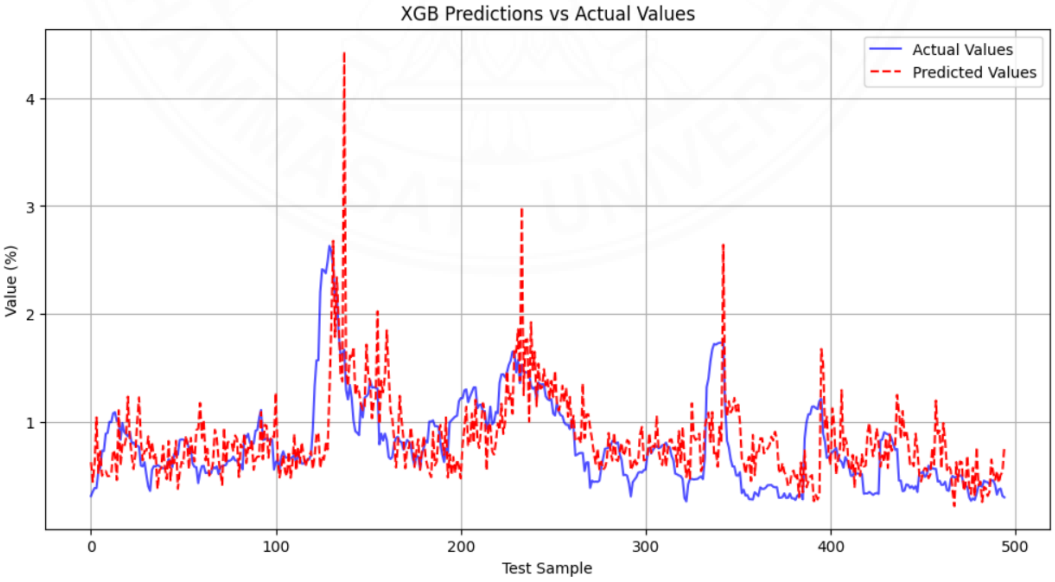

Ref. code: 25676602110550SKO

ภาพที่ 4.19

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Random Forest บนดัชนี S&P500

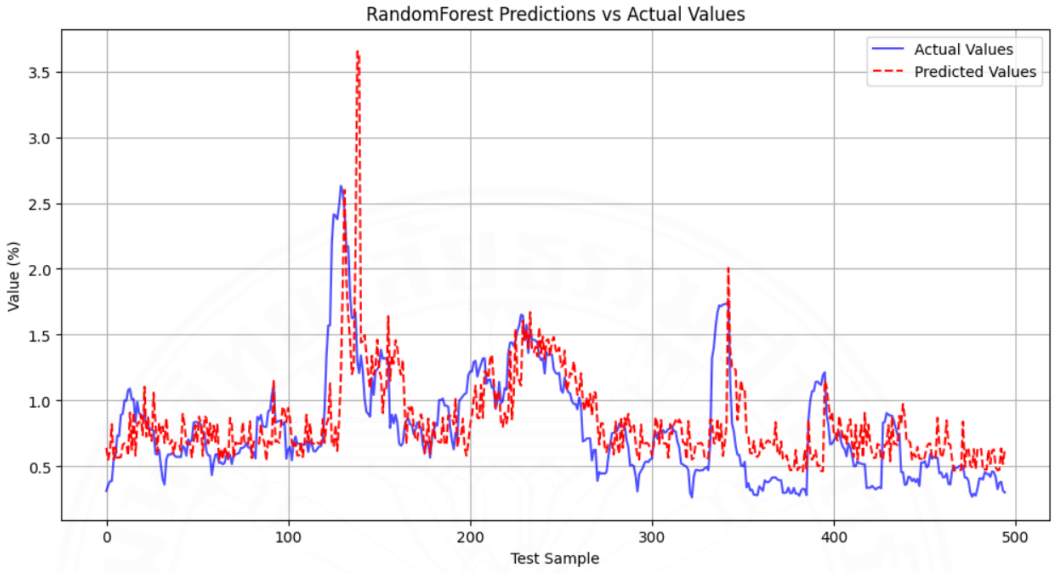

ภาพที่ 4.20

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี S&P500

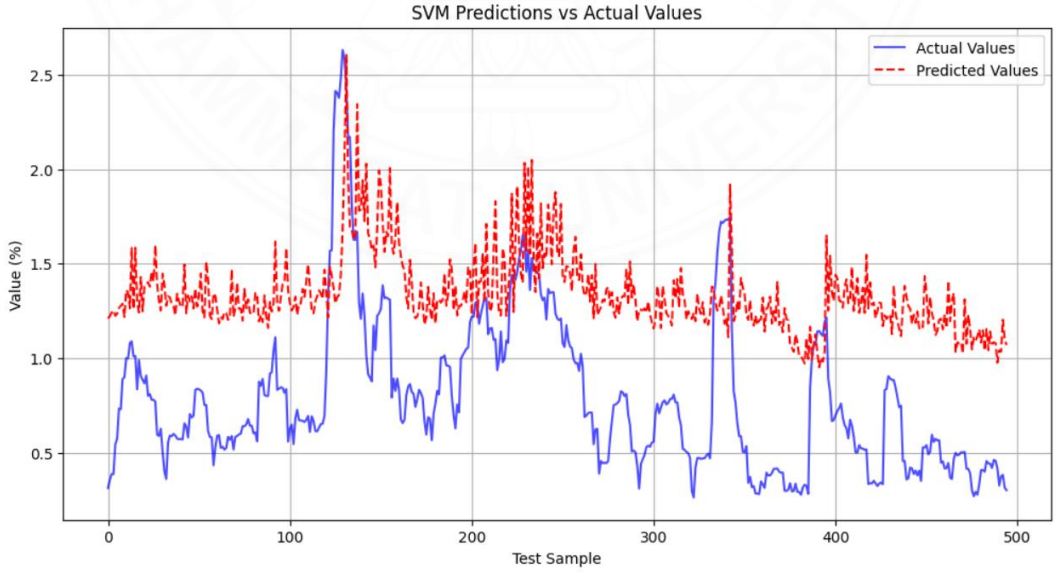

Ref. code: 25676602110550SKO

ตารางที่ 4.7

ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี S&P500

Model	MSE	RMSE	MAE
GARCH	0.791349	0.889578	0.463082
LSTM	0.000028	0.005317	0.004472
RNN	0.000021	0.004601	0.003747
GRU	0.000082	0.009058	0.006935
XGBoost	0.000016	0.003966	0.002771
Random Forest	0.000013	0.003608	0.002403
Support Vector Machine	0.000041	0.006426	0.005979

จากตารางผลการทดลองแสดงให้เห็นว่า การนำโมเดล GARCH มาผสมร่วมกับอัลกอริทึม Machine Learning และ Deep Learning ในลักษณะของ Hybrid Model ส่งผลให้บางโมเดลมีประสิทธิภาพเพิ่มขึ้นบางโมเดล โดยเฉพาะในกรณีของ XGBoost และ Random Forest ซึ่งสามารถลดค่าความผิดพลาด (MSE, RMSE และ MAE) ลงจากกรณีที่ไม่มีการใช้ GARCH

XGBoost เมื่อใช้ร่วมกับ GARCH ค่า MAE ลดลงจาก 0.002846 เป็น 0.002771 แสดงให้เห็นถึงการปรับปรุงในความแม่นยำของการทำนาย Random Forest มีค่า MAE ลดลงจาก 0.002426 เป็น 0.002403 ซึ่งแม้จะเป็นการลดลงเพียงเล็กน้อย แต่สะท้อนถึงประโยชน์จากการเพิ่ม feature

อย่างไรก็ตาม ในกรณีของ LSTM และ GRU ซึ่งเป็นโมเดล Deep Learning ที่มีความสามารถสูงในการเรียนรู้ลำดับข้อมูลอยู่แล้ว กลับพบว่าเมื่อเพิ่ม GARCH เข้ามาประสิทธิภาพกลับลดลงเล็กน้อย (ค่า MSE, RMSE และ MAE สูงขึ้นเมื่อเทียบกับโมเดลเดี่ยว) ซึ่งอาจเกิดจากความซ้ำซ้อนของข้อมูล หรือความไม่จำเป็นของการเพิ่ม feature ความผันผวนในโมเดลที่สามารถเรียนรู้ได้ในตัวเอง

4.1.2.2 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนี SET

ผลลัพธ์การสร้างโมเดลผสมระหว่าง GARCH กับ Deep learning และ Machine บนราคาหลักทรัพย์ดัชนี SET โดยแต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.21 – 4.26 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

Ref. code: 25676602110550SKO

ภาพที่ 4.21

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บนดัชนี SET

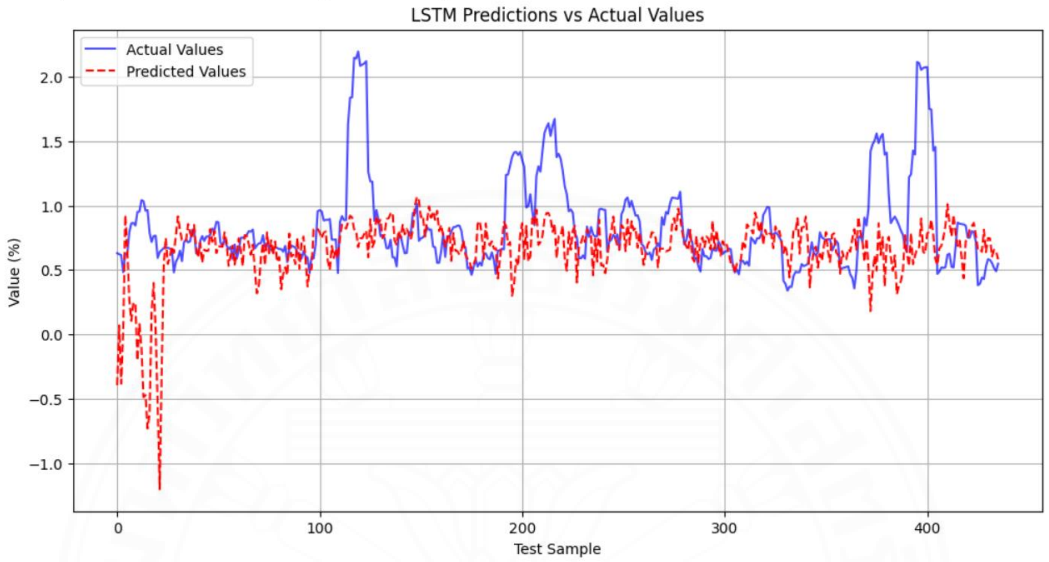

ภาพที่ 4.22

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี SET

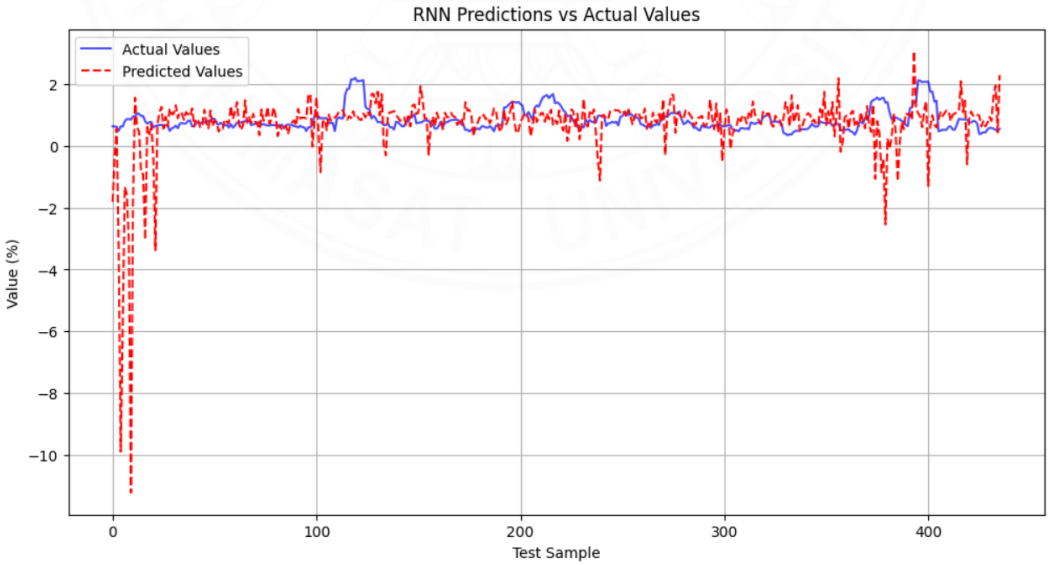

Ref. code: 25676602110550SKO

ภาพที่ 4.23

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี SET

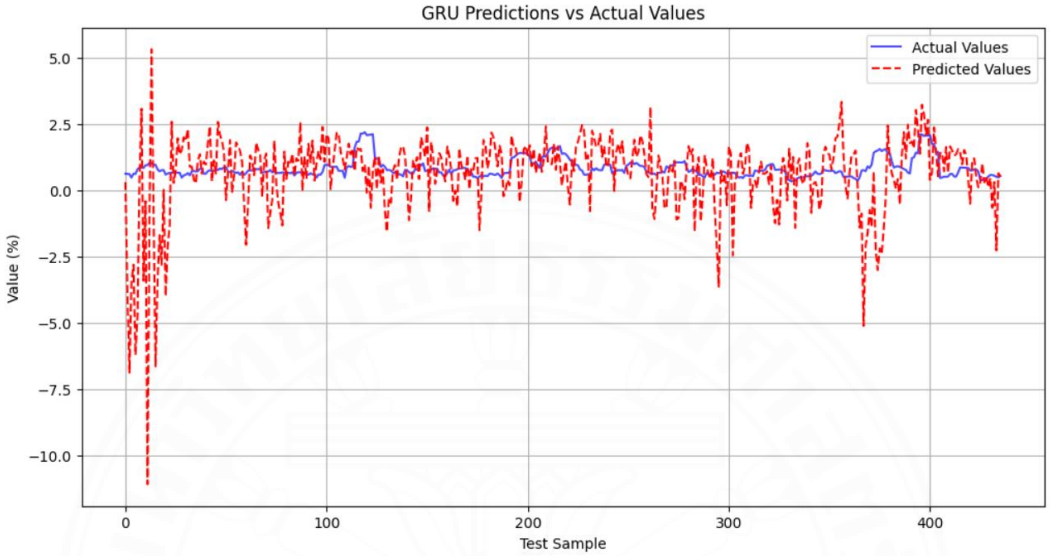

ภาพที่ 4.24

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บนดัชนี SET

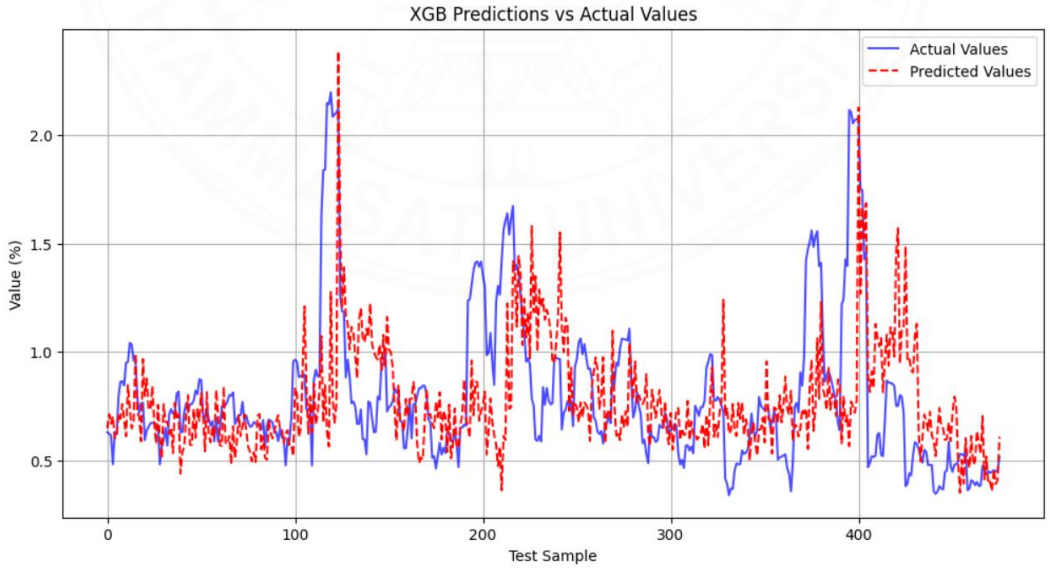

ภาพที่ 4.25

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บนดัชนี SET

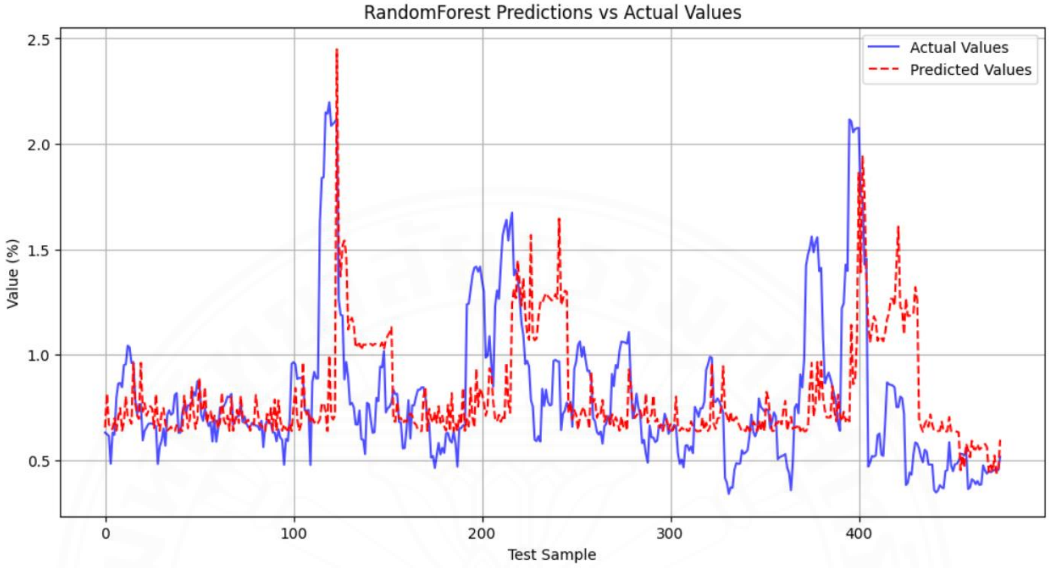

ภาพที่ 4.26

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี SET

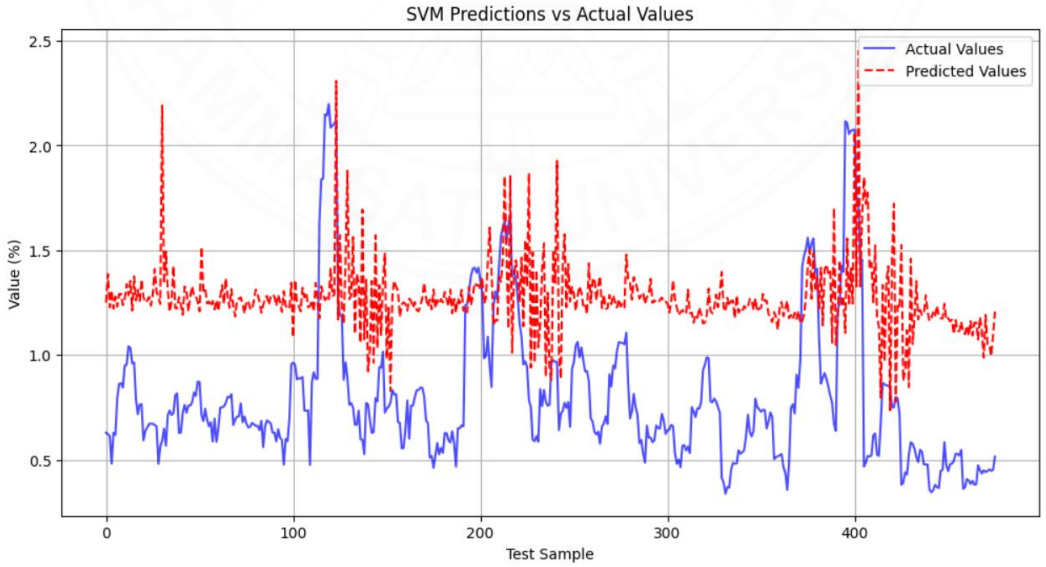

Ref. code: 25676602110550SKO

ตารางที่ 4.8

ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET

Model	MSE	RMSE	MAE
GARCH	0.411087	0.641160	0.279292
LSTM	0.000020	0.004484	0.002869
RNN	0.000127	0.011291	0.005514
GRU	0.000237	0.015389	0.010072
XGBoost	0.000013	0.003645	0.002483
Random Forest	0.000013	0.003648	0.002478
Support Vector Machine	0.000034	0.005824	0.005324

จากการทดลองเปรียบเทียบประสิทธิภาพของโมเดลในการพยากรณ์ความผันผวนของดัชนี SET ระหว่างโมเดลเดี่ยว (Single Model) และโมเดลผสม (Hybrid Model) ที่เพิ่มค่าความผันผวนจากแบบจำลอง GARCH เป็นฟีเจอร์เสริม พบว่าผลลัพธ์ที่ได้มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างกลุ่มของโมเดล Machine Learning และกลุ่มของโมเดล Deep Learning

พบว่าผลลัพธ์จากโมเดลผสมที่นำค่าความผันผวนจาก GARCH เข้ามาร่วมด้วย พบว่าโมเดล Tree-based อย่าง XGBoost และ Random Forest ยังคงรักษาระดับประสิทธิภาพไว้ได้ดี โดยค่า MAE ลดลงเล็กน้อยในกรณีของ XGBoost จาก 0.002511 เป็น 0.002483 และในกรณีของ Random Forest ค่า MAE ขยับเล็กน้อยจาก 0.002473 เป็น 0.002478 อย่างไรก็ตาม กลุ่มของโมเดล RNNS กลับมีแนวโน้มของประสิทธิภาพที่ลดลงอย่างชัดเจน โดยเฉพาะ GRU ที่ค่า MAE เพิ่มจาก 0.002715 เป็น 0.010072 และ RNN ที่เพิ่มจาก 0.002606 เป็น 0.005514 ขณะที่ LSTM แม้จะยังคงมีประสิทธิภาพในระดับที่ยอมรับได้ แต่ค่า MAE ก็เพิ่มจาก 0.002170 เป็น 0.002869

จากผลลัพธ์ดังกล่าวสามารถสรุปได้ว่า การเพิ่ม GARCH เป็นฟีเจอร์ในโมเดลผสมมีแนวโน้มช่วยเสริมประสิทธิภาพของโมเดลกลุ่ม Tree-based ซึ่งไม่ได้ออกแบบมาเพื่อเรียนรู้ลำดับข้อมูลโดยตรง ขณะที่ในกลุ่มของโมเดล RNNs ซึ่งสามารถเรียนรู้ลักษณะความผันผวนจากข้อมูลเดิมได้ดีอยู่แล้ว การเพิ่มฟีเจอร์ที่มีลักษณะซ้ำซ้อนอาจส่งผลให้เกิด overfitting หรือเรียนรู้ข้อมูลผิดทิศทาง ทำให้ความแม่นยำลดลง ดังนั้นจึงควรพิจารณาความเหมาะสมของฟีเจอร์เพิ่มเติมกับชนิดของโมเดลอย่างรอบคอบ

Ref. code: 25676602110550SKO

4.1.3 ประสิทธิภาพการพยากรณ์โมเดลเดี่ยว (Single model) บนข้อมูลที่ไม่รวมช่วง Covid-19

การแพร่ระบาดของโรค Covid-19 ในช่วงปี พ.ศ. 2563–2564 ส่งผลให้เกิดความผันผวนอย่างรุนแรงในตลาดการเงินทั่วโลก รวมถึงตลาดหลักทรัพย์แห่งประเทศไทย ซึ่งความผันผวนนี้ไม่ได้เกิดจากกลไกตลาดตามปกติ หากแต่เกิดจากเหตุการณ์ไม่ปกติ (exogenous shock) ที่ยากต่อการพยากรณ์และไม่สามารถสะท้อนพฤติกรรมทางเศรษฐกิจตามปกติได้อย่างแท้จริง

ด้วยเหตุนี้ งานวิจัยฉบับนี้จึงแยกการทดลองเพื่อประเมินประสิทธิภาพของโมเดลเดี่ยวออกเป็น 2 ช่วง ได้แก่ ช่วงที่มี(การทดลองก่อนหน้านี้) และช่วงข้อมูลที่ไม่มีเหตุการณ์ Covid-19 (ข้อมูลที่ไม่มีปี 2020-2021) โดยในหัวข้อนี้จะมุ่งวิเคราะห์ข้อมูลช่วงก่อนการระบาด เพื่อประเมินสมรรถนะของโมเดลภายใต้สถานการณ์ที่ไม่มีเหตุการณ์ผันผวนผิดปกติแทรกแซง ซึ่งเป็นไปตามหลักการของการวิเคราะห์แบบ *stationarity assumption* ที่นิยมใช้ในงานวิจัยด้านการพยากรณ์ทางการเงิน การตัดช่วงข้อมูลที่มีเหตุการณ์ Covid-19 ออก จึงเป็นการควบคุมตัวแปรแทรกซ้อนที่อาจทำให้โมเดลเรียนรู้ข้อมูลผิดเพี้ยน และทำให้การวัดประสิทธิภาพของโมเดลในสถานการณ์ปกติมีความแม่นยำมากขึ้น ซึ่งสอดคล้องกับแนวทางในงานวิจัยของ Zhang et al. (2021) และ Narayan et al. (2022) ที่แนะนำให้แยกวิเคราะห์ข้อมูลในช่วง shock กับ non-shock ออกจากกันเพื่อป้องกันการ overfitting และการบิดเบือนผลการทดลอง

4.1.3.1 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี S&P500 ไม่รวมช่วง Covid-19

ภาพที่ 4.27

กราฟเส้นแสดงความผันผวนที่พยากรณ์ GARCH กับอัตราความผันผวนหลักทรัพย์ดัชนี S&P500 ไม่รวมช่วง Covid-19

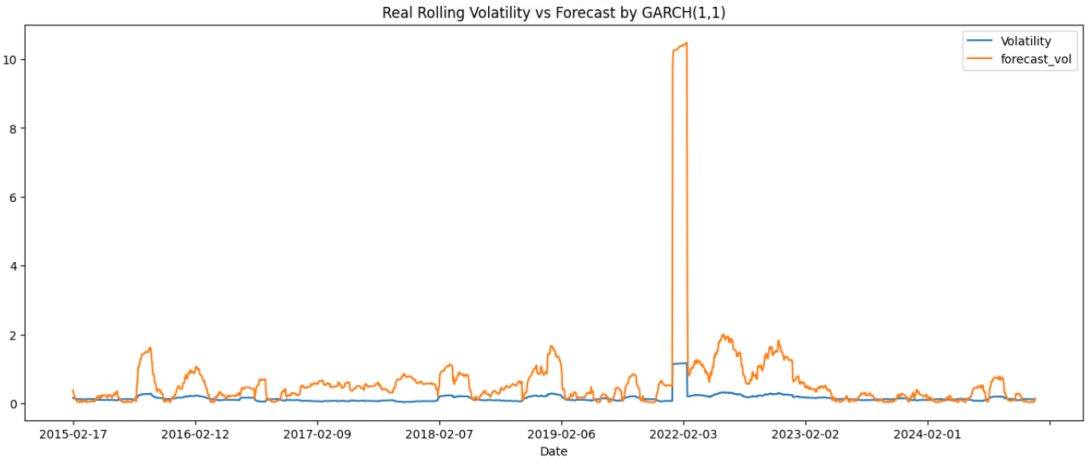

Ref. code: 25676602110550SKO

ตารางที่ 4.9

ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี S&P500 ไม่รวมช่วง Covid-19

Model	Trend	alpha	beta
GARCH	0.1074	0.9173	0.0827

ตารางที่ 4.10

ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี S&P500 ไม่รวมช่วง Covid-19

Model	MSE	RMSE	MAE
GARCH	1.556984	1.247791	0.517235

ผลลัพธ์การสร้างโมเดลเดี่ยวระหว่าง GARCH กับ Deep learning และ Machine บนราคาหลักทรัพย์ดัชนี S&P500 โดยไม่รวมช่วง Covid-19 แต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.28 – 4.33 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

ภาพที่ 4.28

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บนดัชนี S&P500 ไม่รวมช่วง Covid-19

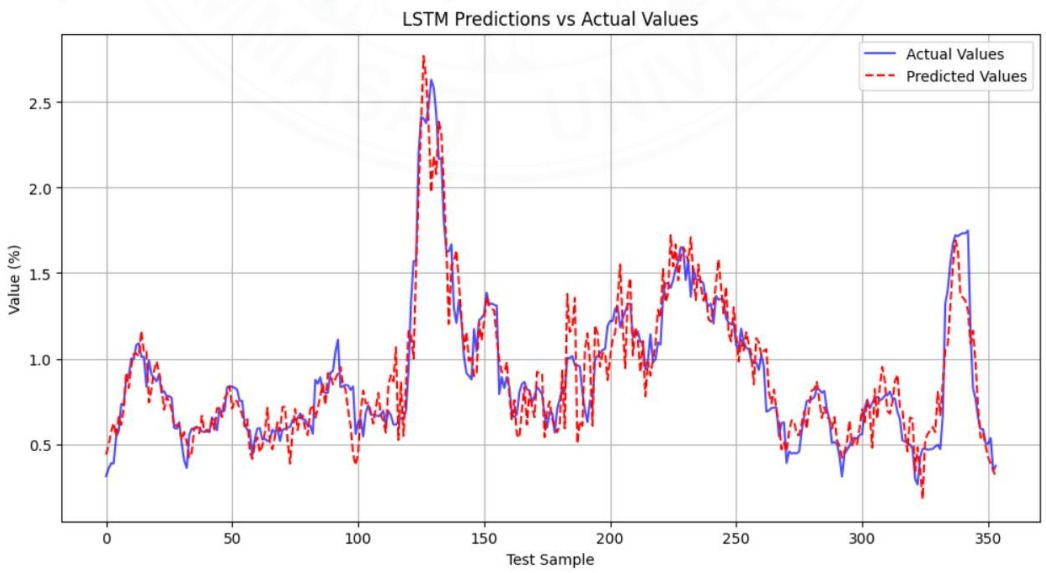

Ref. code: 25676602110550SKO

ภาพที่ 4.29

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บนดัชนี S&P500 ไม่รวมช่วง Covid-19

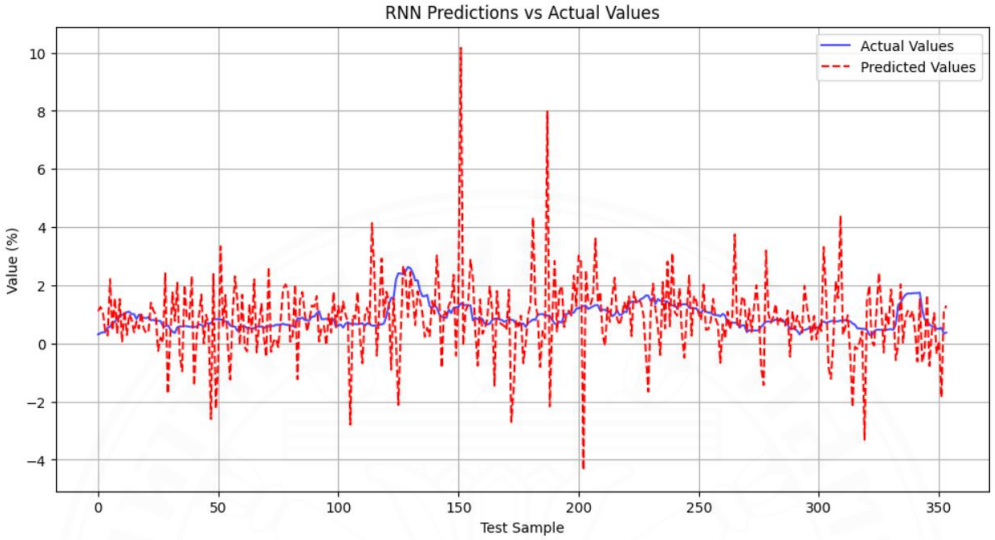

ภาพที่ 4.30

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บนดัชนี S&P500 ไม่รวมช่วง Covid-19

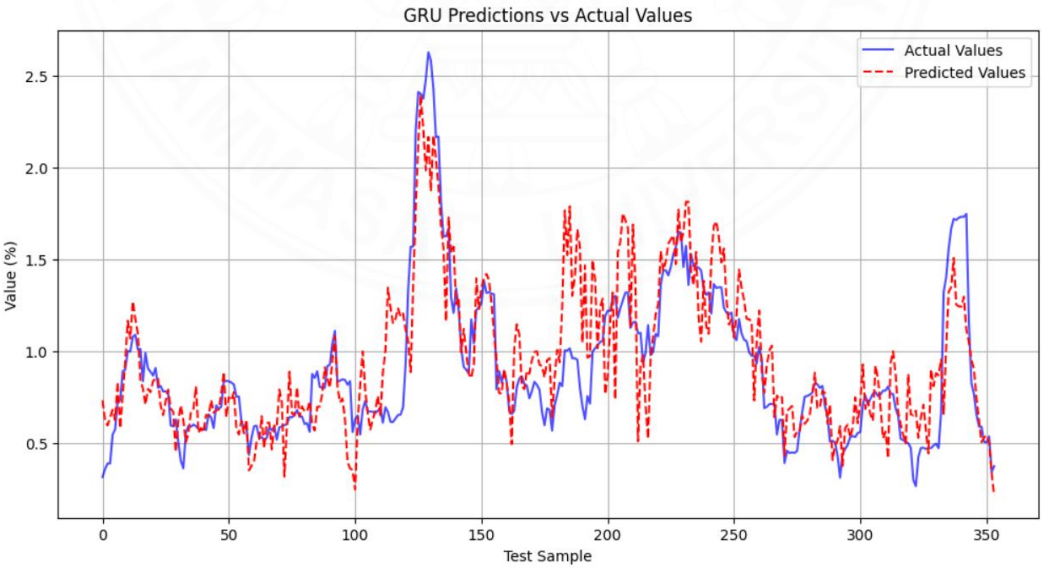

Ref. code: 25676602110550SKO

ภาพที่ 4.31

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี S&P500 ไม่รวมช่วง Covid-19

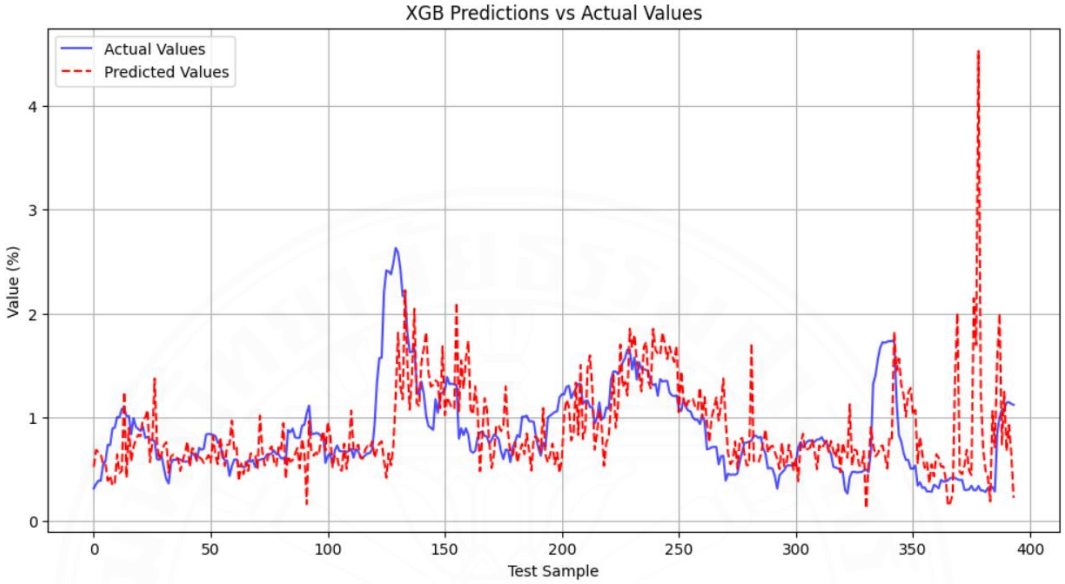

ภาพที่ 4.32

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random Forest บนดัชนี S&P500 ไม่รวมช่วง Covid-19

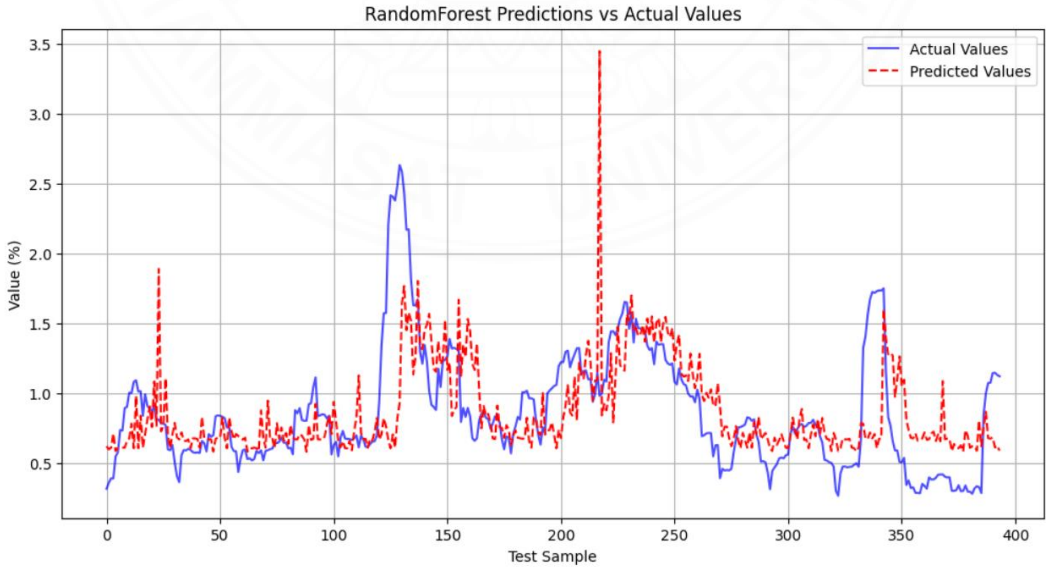

Ref. code: 25676602110550SKO

ภาพที่ 4.33

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บนดัชนี S&P500 ไม่รวมช่วง Covid-19

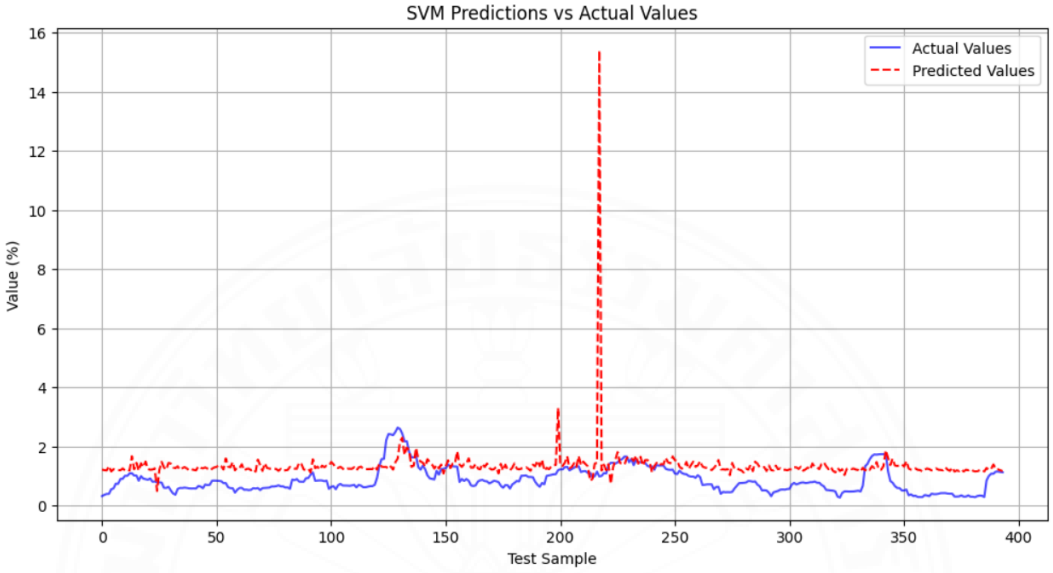

ตารางที่ 4.11

ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี S&P500 ไม่รวมช่วง Covid-19

Model	MSE	RMSE	MAE
GARCH	1.556984	1.247791	0.517235
LSTM	0.000003	0.001605	0.001194
RNN	0.000179	0.013385	0.009038
GRU	0.000006	0.002508	0.001871
XGBoost	0.000023	0.004842	0.003091
Random Forest	0.000015	0.003915	0.002590
Support Vector Machine	0.000088	0.009367	0.005616

จากการวิเคราะห์ผลการทดลองเปรียบเทียบประสิทธิภาพของโมเดลในการพยากรณ์ความผันผวนของดัชนี S&P500 ภายใต้เงื่อนไขที่แตกต่างกันระหว่างการ “รวมช่วง

Ref. code: 25676602110550SKO

COVID-19” และ “ตัดช่วง COVID-19 ออก” พบว่า ช่วงเวลาของข้อมูลมีผลกระทบอย่างมีนัยสำคัญต่อความแม่นยำของการพยากรณ์โดยเฉพาะในโมเดลกลุ่ม RNNs

เมื่อพิจารณาชุดข้อมูลที่ รวมช่วง COVID-19 พบว่าโมเดล LSTM ยังคงมีประสิทธิภาพสูงสุด โดยให้ค่า MAE เพียง 0.001490 รองลงมาได้แก่ GRU และ RNN ซึ่งมีค่า MAE เท่ากับ 0.002065 และ 0.002910 ตามลำดับ ในขณะที่โมเดล XGBoost และ Random Forest ซึ่งอยู่ในกลุ่ม Tree-based ยังมีค่าความคลาดเคลื่อนสูงกว่าเล็กน้อย โดย XGBoost มี MAE เท่ากับ 0.002846 ส่วน SVM มีประสิทธิภาพต่ำที่สุดด้วยค่า MAE สูงถึง 0.005448

อย่างไรก็ตาม เมื่อ ตัดช่วง COVID-19 ออกจากชุดข้อมูล ผลการพยากรณ์ของโมเดล Deep learning ดีขึ้นอย่างชัดเจน โดยเฉพาะ LSTM ที่ค่า MAE ลดลงเหลือเพียง 0.001194 และค่า MSE ลดลงเหลือ 0.000003 ซึ่งถือว่าเป็นค่าความคลาดเคลื่อนต่ำที่สุดในทุกโมเดลที่ใช้ GRU ก็มีการปรับตัวที่ดีขึ้นเช่นกัน โดย MAE ลดลงจาก 0.002065 เหลือ 0.001871 ทางด้าน Machine learning โมเดลส่วนใหญ่ไม่ต่างจากเดิมมากนักมีเพียงerror มากขึ้นเล็กน้อย XGBoost มีค่า MAE เพิ่มขึ้นเป็น 0.003091 จากเดิม 0.002846 ขณะที่ Random Forest และ RNN ก็มีแนวโน้มค่าความผิดพลาดเพิ่มขึ้นเล็กน้อย

โดยสรุป การตัดข้อมูลในช่วง COVID-19 ส่งผลให้ประสิทธิภาพของทุกโมเดลเดี่ยวดีขึ้นในกลุ่ม RNNs เช่น LSTM และ GRU ที่มีความไวต่อ outlier และเหตุการณ์ผิดปกติ ทำให้การฝึกโมเดลบนข้อมูลที่มีเสถียรภาพมากขึ้นช่วยลดค่าความคลาดเคลื่อนได้อย่างมีนัยสำคัญ ผลลัพธ์นี้สะท้อนให้เห็นถึงความสำคัญของการคัดกรองช่วงเวลาของข้อมูลในการสร้างโมเดลพยากรณ์ทางการเงิน

4.1.3.2 ผลการศึกษาการสร้างตัวโมเดลเดี่ยวบนราคาหลักทรัพย์ดัชนี SET ไม่รวมช่วง Covid-19

ภาพที่ 4.34

กราฟเส้นแสดงความผันผวนที่พยากรณ์ GARCH กับอัตราความผันผวนหลักทรัพย์ดัชนี SET ไม่รวมช่วง Covid-19

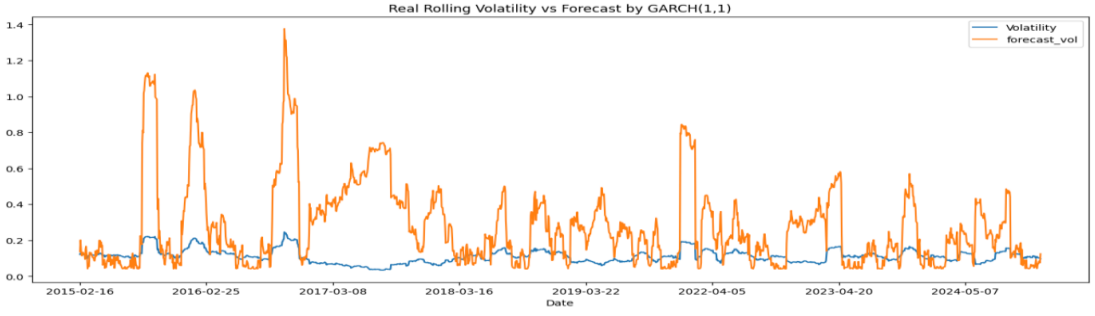

Ref. code: 25676602110550SKO

ตารางที่ 4.12

ค่าพารามิเตอร์ที่ประมาณค่าจากแบบจำลอง GARCH บนดัชนี SET ไม่รวมช่วง Covid-19

Model	Trend	alpha	beta
GARCH	0.1682	1.0000	1.7482e-17

ตารางที่ 4.13

ตารางแสดงประสิทธิภาพของGARCHที่ใช้ในการพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี SET ไม่รวมช่วง Covid-19

Model	MSE	RMSE	MAE
GARCH	0.078126	0.279511	0.190821

ผลลัพธ์การสร้างโมเดลเดี่ยวระหว่าง GARCH กับ Deep learning และ Machine บนราคาหลักทรัพย์ดัชนี SET โดยไม่รวมช่วง Covid-19 แต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.35 – 4.40 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

ภาพที่ 4.35

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว LSTM บนดัชนี SET ไม่รวมช่วง Covid-19

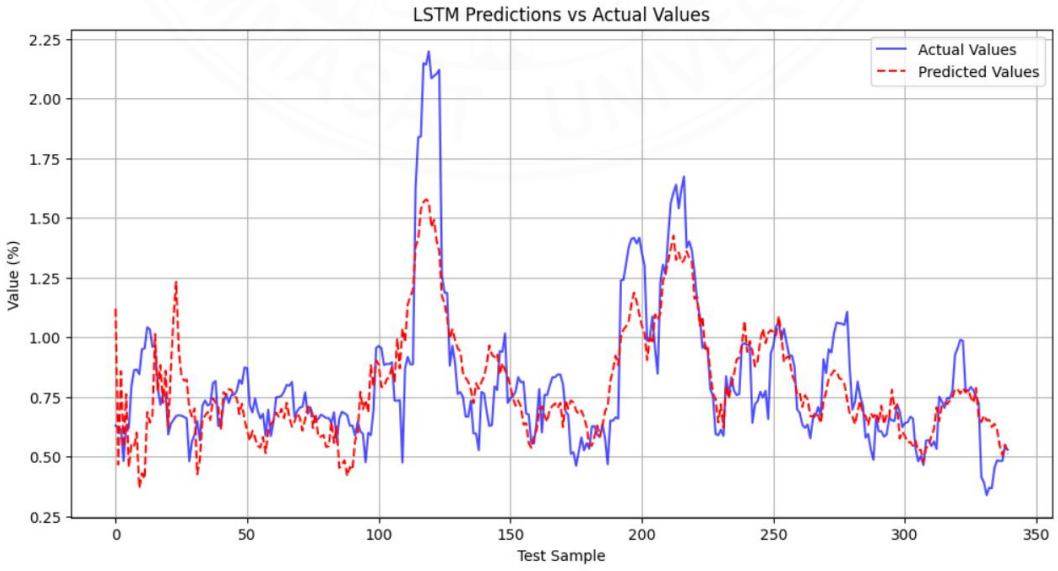

Ref. code: 25676602110550SKO

ภาพที่ 4.36

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว RNN บนดัชนี SET ไม่รวมช่วง Covid-19

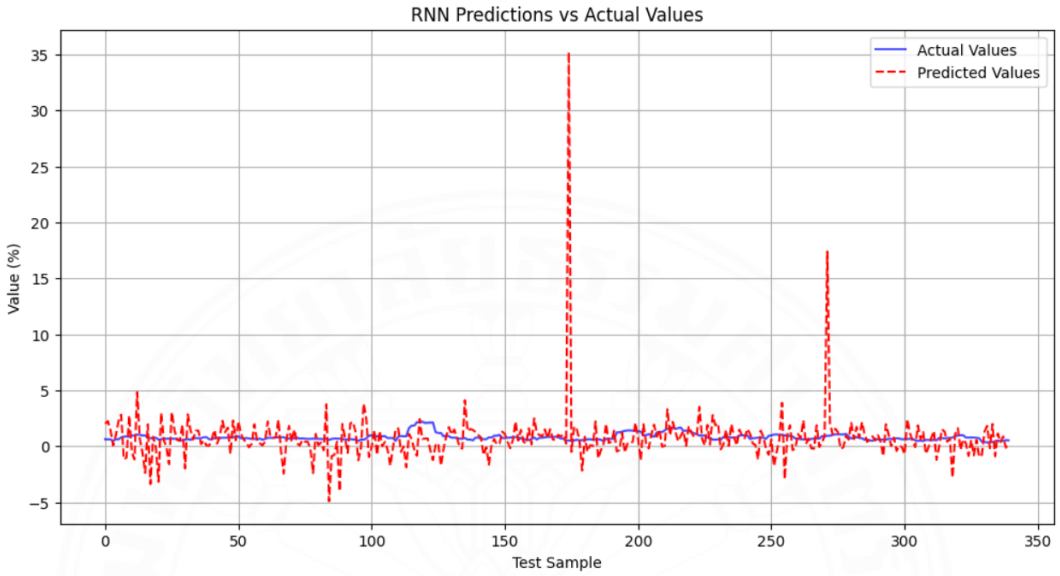

ภาพที่ 4.37

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว GRU บนดัชนี SET ไม่รวมช่วง Covid-19

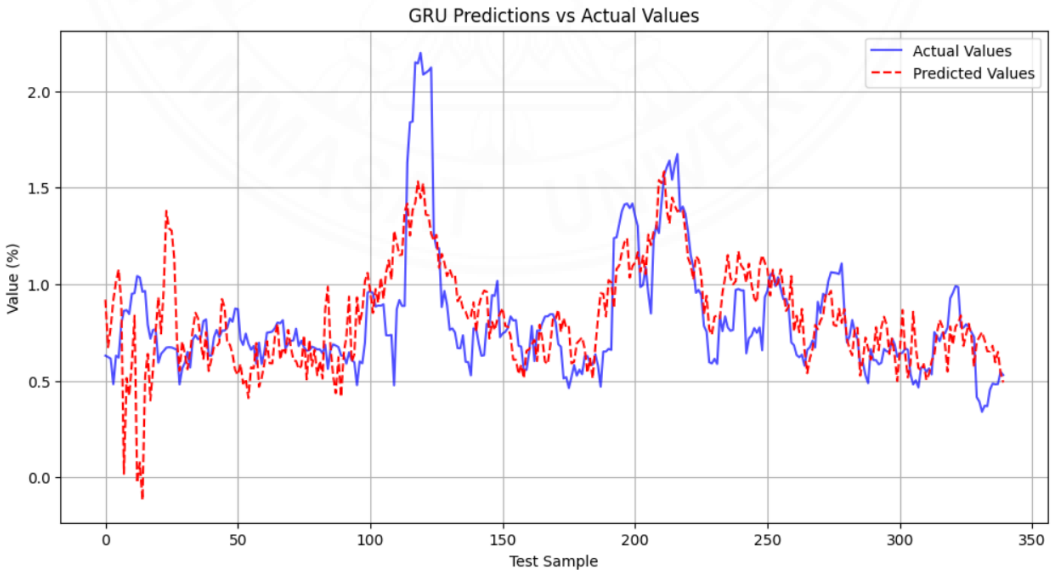

Ref. code: 25676602110550SKO

ภาพที่ 4.38

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Random Forest บนดัชนี SET ไม่รวมช่วง Covid-19

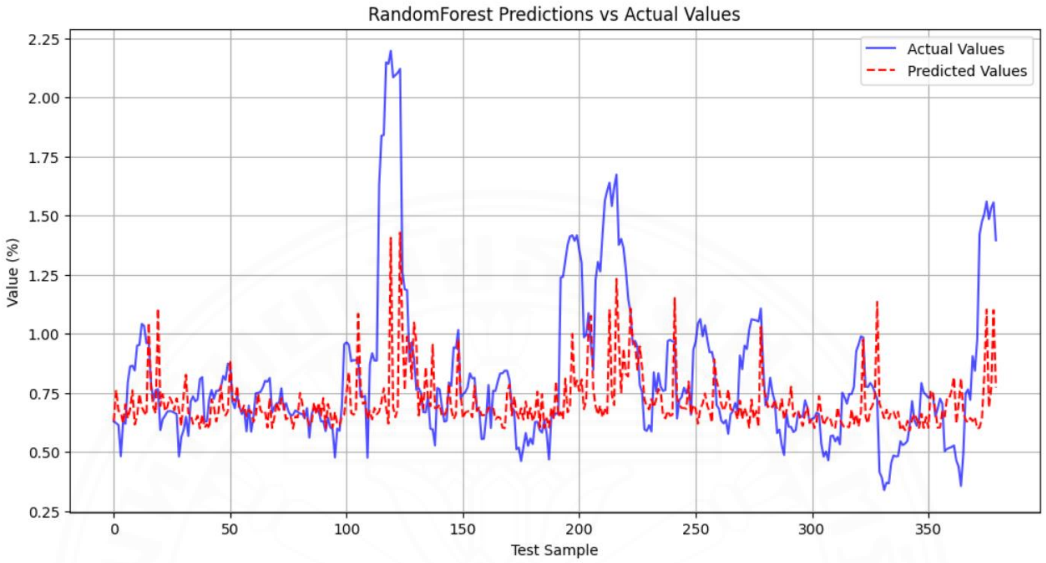

ภาพที่ 4.39

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว XGBoost บนดัชนี SET ไม่รวมช่วง Covid-19

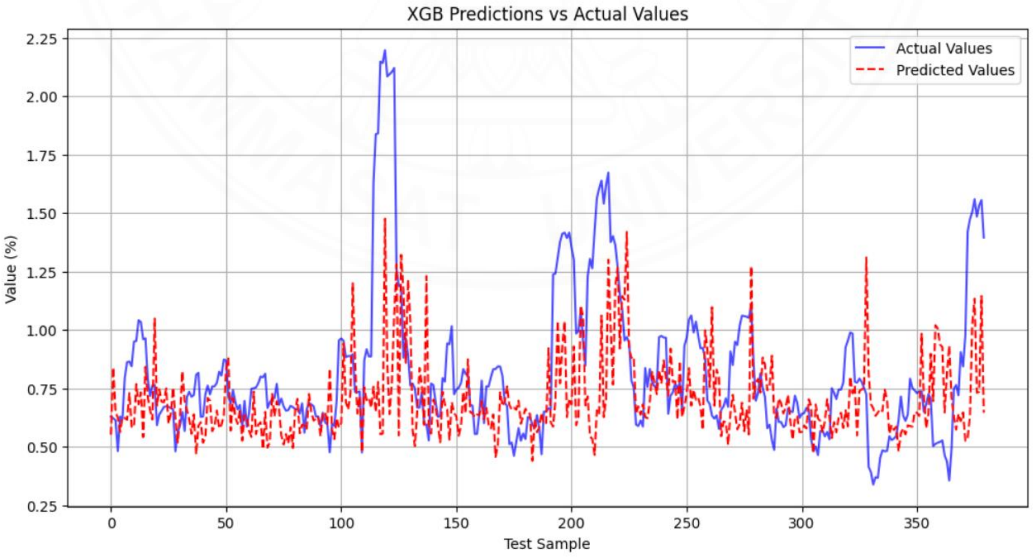

Ref. code: 25676602110550SKO

ภาพที่ 4.40

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลเดี่ยว Support Vector Machine บนดัชนี SET ไม่รวมช่วง Covid-19

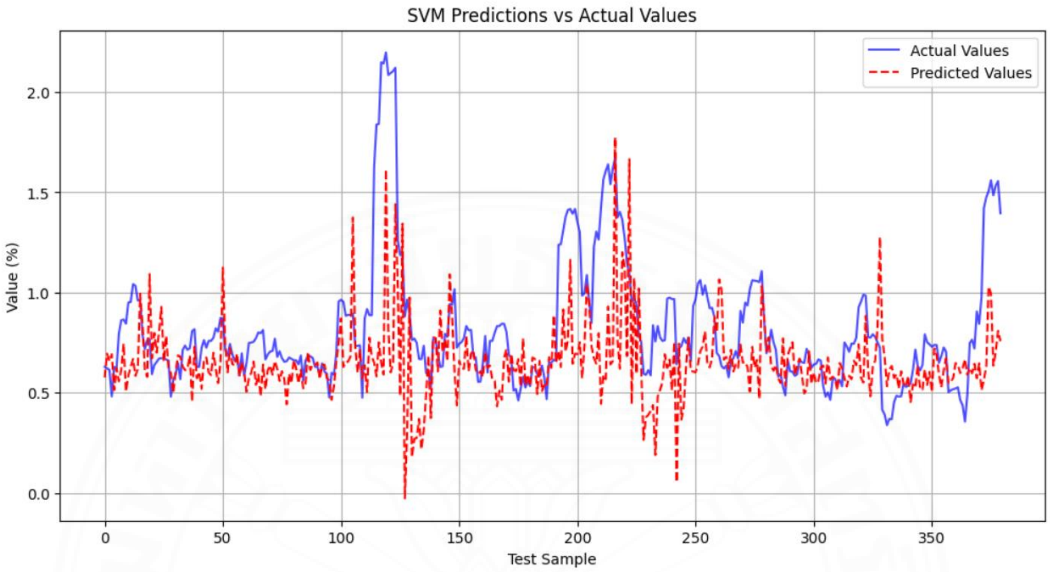

ตารางที่ 4.14

ตารางแสดงประสิทธิภาพของโมเดลเดี่ยวที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET ไม่รวมช่วง Covid-19

Model	MSE	RMSE	MAE
GARCH	0.078126	0.279511	0.190821
LSTM	0.000004	0.001885	0.001378
RNN	0.000603	0.024560	0.011222
GRU	0.000007	0.002554	0.001855
XGBoost	0.000011	0.003385	0.002227
Random Forest	0.000010	0.003123	0.001918
Support Vector Machine	0.000021	0.004574	0.004218

จากการทดลองเปรียบเทียบประสิทธิภาพของโมเดลในการพยากรณ์ความผันผวนของดัชนี SET ภายใต้สองเงื่อนไข ได้แก่ ชุดข้อมูลที่รวมช่วง COVID-19 และชุดข้อมูลที่

Ref. code: 25676602110550SKO

ตัดช่วง COVID-19 ออก พบว่าการมีหรือไม่มีช่วงเวลาที่มีความผันผวนสูงอย่างวิกฤตโควิด-19 มีผลอย่างมีนัยสำคัญต่อความแม่นยำของโมเดลในแทบทุกกรณี

ในชุดข้อมูลที่รวมช่วง COVID-19 พบว่าแบบจำลอง LSTM ให้ผลลัพธ์ดีที่สุดในกลุ่ม โดยมีค่า MAE เท่ากับ 0.002170 และค่า RMSE เท่ากับ 0.002894 รองลงมาคือ Random Forest และ XGBoost ที่มีค่า MAE เท่ากับ 0.002473 และ 0.002511 ตามลำดับ ส่วนโมเดล SVM มีประสิทธิภาพต่ำที่สุดด้วยค่า MAE เท่ากับ 0.004501 และ GARCH มีค่า MAE สูงถึง 0.279292 ซึ่งตอกย้ำข้อจำกัดของโมเดลเชิงเศรษฐมิติแบบดั้งเดิมในการจัดการกับความผันผวนที่ไม่เป็นเชิงเส้น

เมื่อเปรียบเทียบกับชุดข้อมูลที่ตัดช่วง COVID-19 ออก พบว่าความแม่นยำของทุกโมเดลยกเว้น RNN เพิ่มขึ้นอย่างชัดเจน โดยเฉพาะ LSTM ที่ค่า MAE ลดลงจาก 0.002170 เป็น 0.001378 และค่า RMSE เหลือเพียง 0.001885 GRU และ Random Forest ก็มีแนวโน้มดีขึ้นเช่นกัน โดย GRU มี MAE ลดลงจาก 0.002715 เป็น 0.001855 และ Random Forest จาก 0.002473 เหลือ 0.001918 ส่วน XGBoost ก็แสดงผลลัพธ์ที่แม่นยำมากขึ้น โดย MAE ลดลงเหลือ 0.002227 ขณะที่ RNN แม้จะยังมี MAE สูงขึ้นเมื่อเทียบกับโมเดลอื่น ๆ แต่ก็มีค่าลดลงจาก 0.002606 เหลือ 0.0011222 เช่นกัน

โดยสรุป การตัดช่วงเวลาโควิด-19 ออกจากชุดข้อมูลมีผลในเชิงบวกต่อประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ โดยเฉพาะในกลุ่ม Deep Learning อย่าง LSTM และ GRU ที่ไวต่อ outlier และความเปลี่ยนแปลงรุนแรงของข้อมูล การใช้ข้อมูลที่มีเสถียรภาพมากขึ้นจึงช่วยให้โมเดลสามารถเรียนรู้ pattern ได้ชัดเจนกว่าเดิม และส่งผลต่อความแม่นยำของการพยากรณ์ในทางที่ดีขึ้นอย่างเด่นชัด

Ref. code: 25676602110550SKO

4.1.4 ประสิทธิภาพการพยากรณ์โมเดลผสม (Hybrid model) บนข้อมูลที่ไม่รวมช่วง Covid-19

4.1.4.1 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนี S&P500 ไม่รวมช่วง Covid-19

เพื่อประเมินประสิทธิภาพของการพยากรณ์ความผันผวนในช่วงเวลาปกติที่ไม่มีเหตุการณ์ภายนอกที่ส่งผลกระทบต่อความเคลื่อนไหวของตลาดอย่างรุนแรง งานวิจัยนี้จึงทำการสร้างและทดสอบโมเดลผสม (Hybrid Model) ระหว่าง GARCH กับโมเดลเชิงลึก (Deep Learning) ได้แก่ LSTM และโครงข่ายประสาทเทียมอื่น ๆ บนชุดข้อมูลของดัชนี S&P500 โดยเฉพาะในช่วงเวลาที่ไม่รวมการระบาดของโรคโควิด-19 ซึ่งเป็นช่วงเวลาที่ความผันผวนของตลาดมีลักษณะใกล้เคียงกับภาวะปกติ

ผลลัพธ์การสร้างโมเดลผสมระหว่าง GARCH กับ Deep learning และ Machine บนราคาหลักทรัพย์ดัชนี S&P500 โดยไม่รวมช่วง Covid-19 แต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.35 – 4.40 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

ภาพที่ 4.41

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บนดัชนี S&P500 ไม่รวมช่วง Covid-19

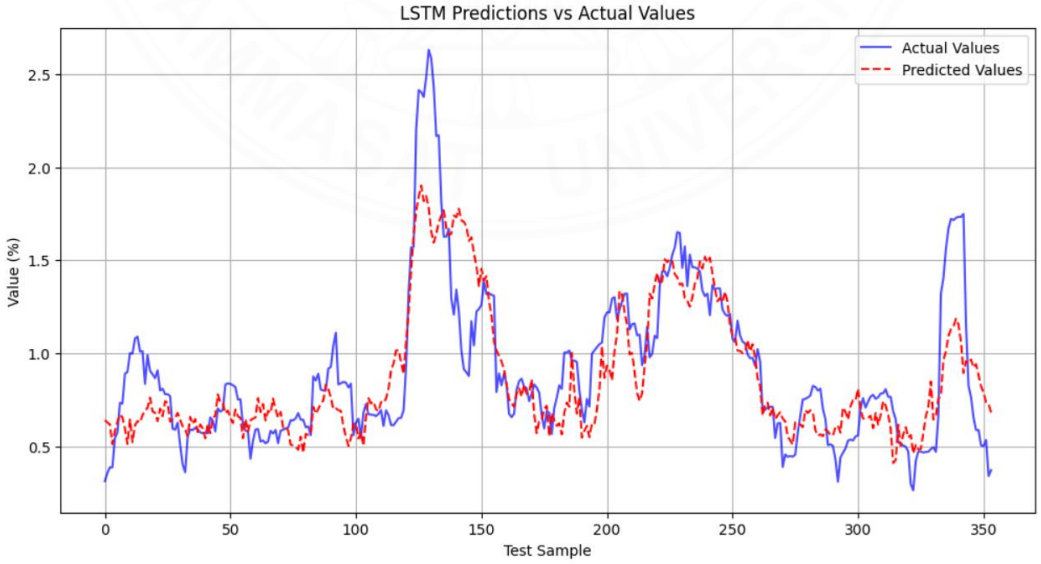

Ref. code: 25676602110550SKO

ภาพที่ 4.42

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี S&P500 ไม่รวมช่วง Covid-19

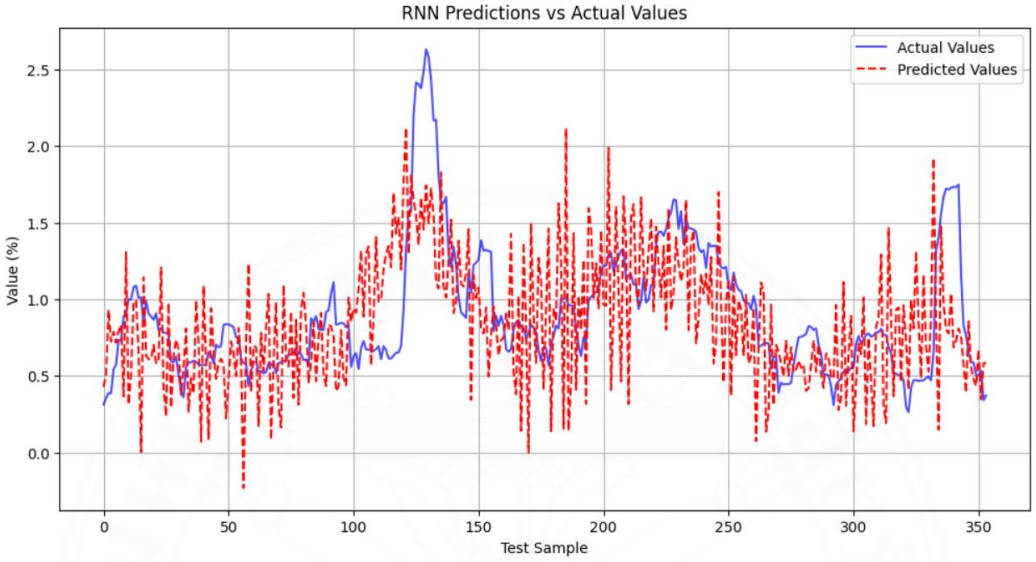

ภาพที่ 4.43

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี S&P500 ไม่รวมช่วง Covid-19

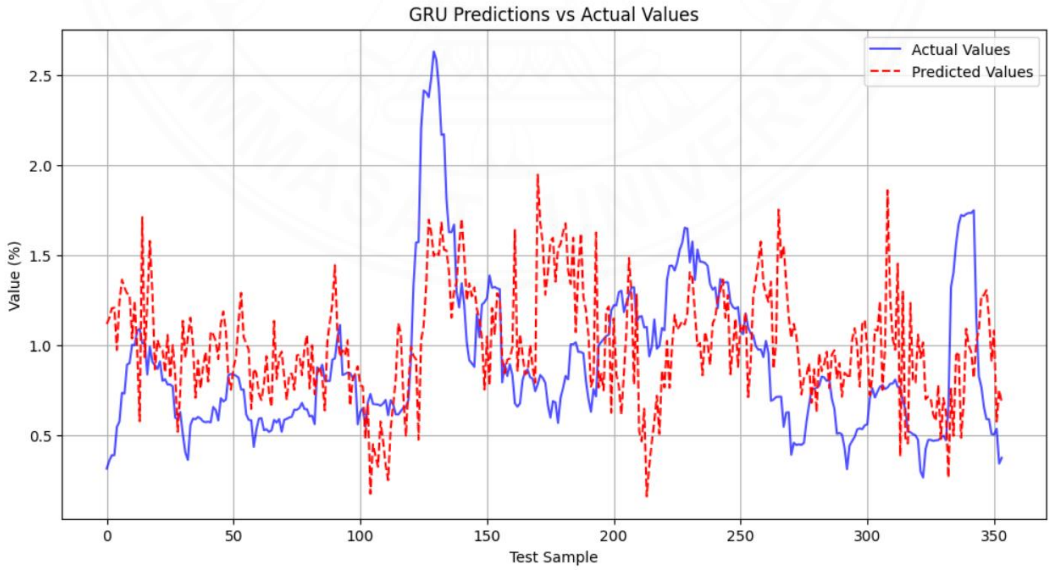

Ref. code: 25676602110550SKO

ภาพที่ 4.44

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บนดัชนี S&P500 ไม่รวมช่วง Covid-19

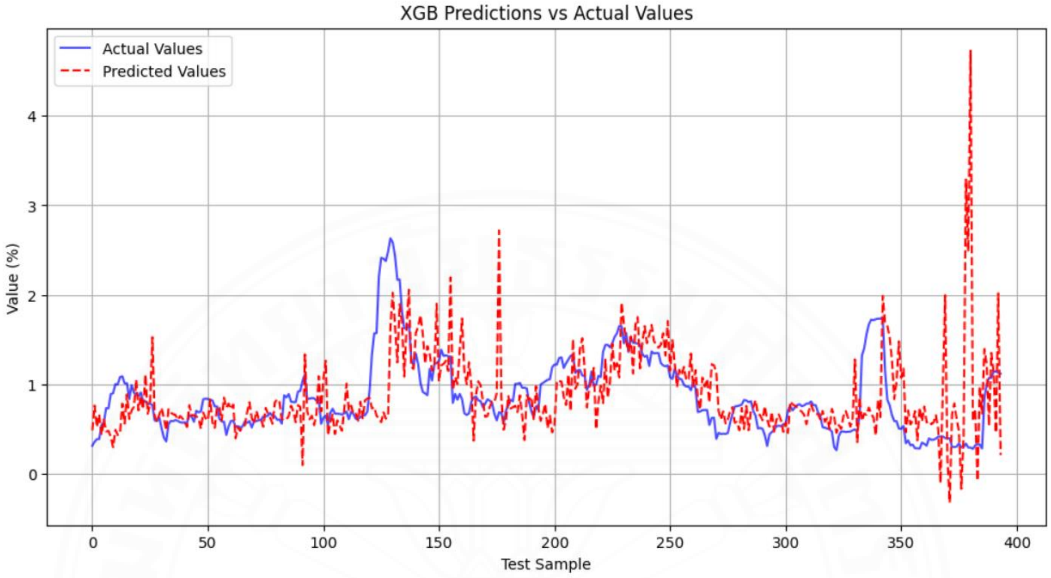

ภาพที่ 4.45

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Random Forest บนดัชนี S&P500 ไม่รวมช่วง Covid-19

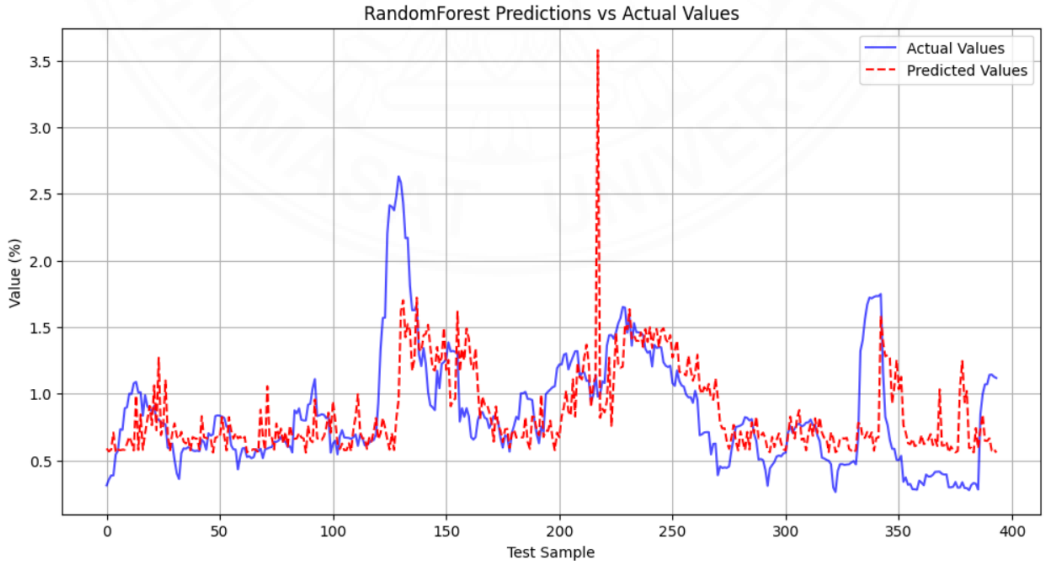

Ref. code: 25676602110550SKO

ภาพที่ 4.46

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี S&P500 ไม่รวมช่วง Covid-19

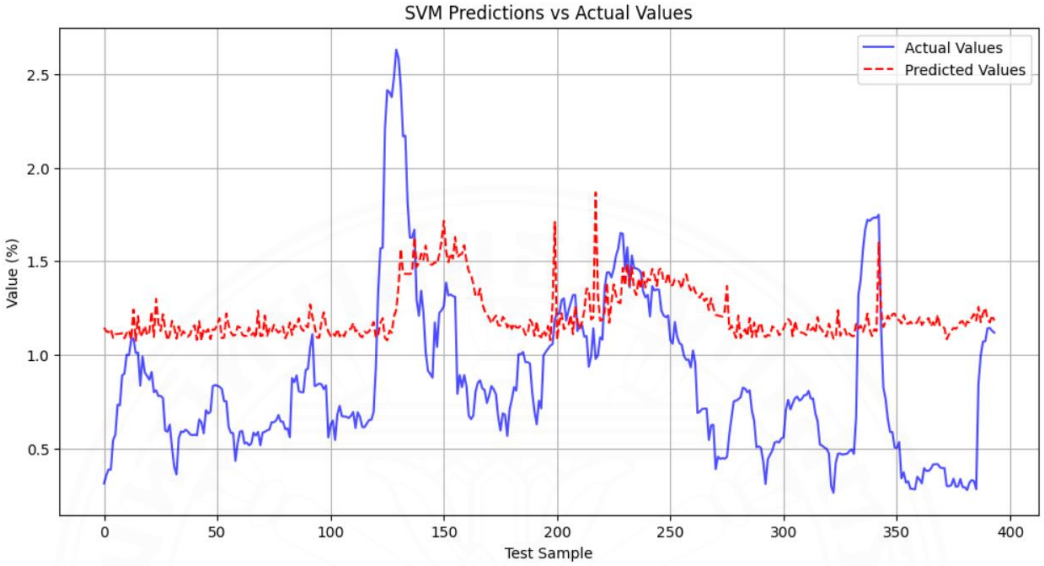

ตารางที่ 4.15

ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี S&P500 ไม่รวมช่วง Covid-19

Model	MSE	RMSE	MAE
GARCH	1.556984	1.247791	0.517235
LSTM	0.000006	0.002475	0.001813
RNN	0.000020	0.004479	0.003586
GRU	0.000021	0.004597	0.003701
XGBoost	0.000011	0.003385	0.002227
Random Forest	0.000016	0.003965	0.002606
Support Vector Machine	0.000028	0.005245	0.004581

จากการทดลองเปรียบเทียบผลลัพธ์ของโมเดลผสม (Hybrid Model) ที่เพิ่มฟีเจอร์ GARCH เข้ามาร่วมกับอัลกอริธึม Machine Learning สำหรับการพยากรณ์ความผันผวนของดัชนี S&P500 ภายใต้เงื่อนไขที่แตกต่างกันระหว่างชุดข้อมูลที่รวมช่วง COVID-19 และชุดข้อมูลที่

Ref. code: 25676602110550SKO

ตัดช่วง COVID-19 ออก พบว่าประสิทธิภาพของโมเดลได้รับผลกระทบอย่างมีนัยสำคัญจากช่วงเวลาของข้อมูล

ในกรณีที่รวมช่วง COVID-19 ไว้ในชุดข้อมูล พบว่าโมเดล XGBoost และ Random Forest ยังคงให้ผลลัพธ์ที่ดี โดย XGBoost มีค่า MAE เท่ากับ 0.002771 และ Random Forest เท่ากับ 0.002403 ซึ่งแสดงถึงประสิทธิภาพที่มั่นคงของโมเดล Tree-based แม้ในภาวะที่ข้อมูลมีความผันผวนสูง อย่างไรก็ตาม โมเดลกลุ่ม RNNs อย่าง GRU และ LSTM กลับมีค่า MAE ค่อนข้างสูงขึ้น โดย GRU มีค่า MAE เท่ากับ 0.006935 และ LSTM เท่ากับ 0.004472 สะท้อนถึงความอ่อนไหวของโมเดลเชิงลึกต่อ outlier และเหตุการณ์ไม่ปกติในตลาด ขณะที่ SVM ยังคงมีค่าความคลาดเคลื่อนสูงสุด (MAE = 0.005979) และ GARCH มี MAE สูงถึง 0.279292 เช่นเดียวกับชุดข้อมูลอื่น

เมื่อพิจารณาชุดข้อมูลที่ตัดช่วง COVID-19 ออก พบว่าผลลัพธ์ของทุกโมเดลดีขึ้นยกเว้น Random Forest โดย LSTM กลับมาแสดงประสิทธิภาพสูงสุดอีกครั้ง ด้วยค่า MAE ลดลงเหลือ 0.001813 และ GRU ลดลงเหลือ 0.003701 ส่วน XGBoost MAE ลดเหลือ 0.002227 RNN และ SVM ก็แสดงแนวโน้มการปรับตัวในทิศทางที่ดีขึ้น โดย RNN มีค่า MAE เท่ากับ 0.003586 ส่วน SVM ลดลงจาก 0.005979 เหลือ 0.004581 มีเพียง Random Forest ที่ MAE เพิ่มจาก 0.002403 เป็น 0.002606

โดยสรุป การตัดข้อมูลในช่วง COVID-19 ส่งผลให้โมเดลผสมส่วนใหญ่มีความแม่นยำในการพยากรณ์เพิ่มขึ้น โดยเฉพาะกลุ่ม RNNs ที่ไวต่อความแปรปรวนของข้อมูล ส่งผลให้ LSTM และ GRU สามารถแสดงศักยภาพได้ดีขึ้นอย่างเด่นชัด ส่วนกลุ่มโมเดล Machine Learning อย่าง XGBoost และ SVM ยังคงมีประสิทธิภาพที่มั่นคงทั้งก่อนและหลังการตัดข้อมูล ซึ่งสะท้อนถึงความยืดหยุ่นของโมเดลกลุ่มนี้ต่อข้อมูลในภาวะตลาดที่แตกต่างกัน

4.1.4.2 ผลการศึกษาการสร้างตัวโมเดลผสมบนราคาหลักทรัพย์ดัชนี SET ไม่รวมช่วง Covid-19

เพื่อเปรียบเทียบศักยภาพของโมเดลผสมในการพยากรณ์ความผันผวนระหว่างตลาดทุนในประเทศและต่างประเทศว่าจะให้ผลลัพธ์ที่ต่างกันหรือไม่หากช่วงเวลาที่ไม่มีผลกระทบจากการแพร่ระบาดของโควิด-19 ซึ่งถือเป็นช่วงเวลาที่ตลาดอยู่ในสภาวะปกติและไม่มีความผันผวนจากปัจจัยภายนอกในระดับรุนแรง

ผลลัพธ์การสร้างโมเดลผสมระหว่าง GARCH กับ Machine บนราคาหลักทรัพย์ดัชนี SET โดยไม่รวมช่วง Covid-19 แต่ละโมเดลจะมีลักษณะเป็นไปดังภาพที่ 4.47– 4.51 โดยที่เส้นสีน้ำเงินแสดงถึงความผันผวนที่เกิดขึ้นจริง และเส้นสีแดงคือผลจากการพยากรณ์

Ref. code: 25676602110550SKO

ภาพที่ 4.47

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม LSTM บนดัชนี SET ไม่รวมช่วง Covid-19

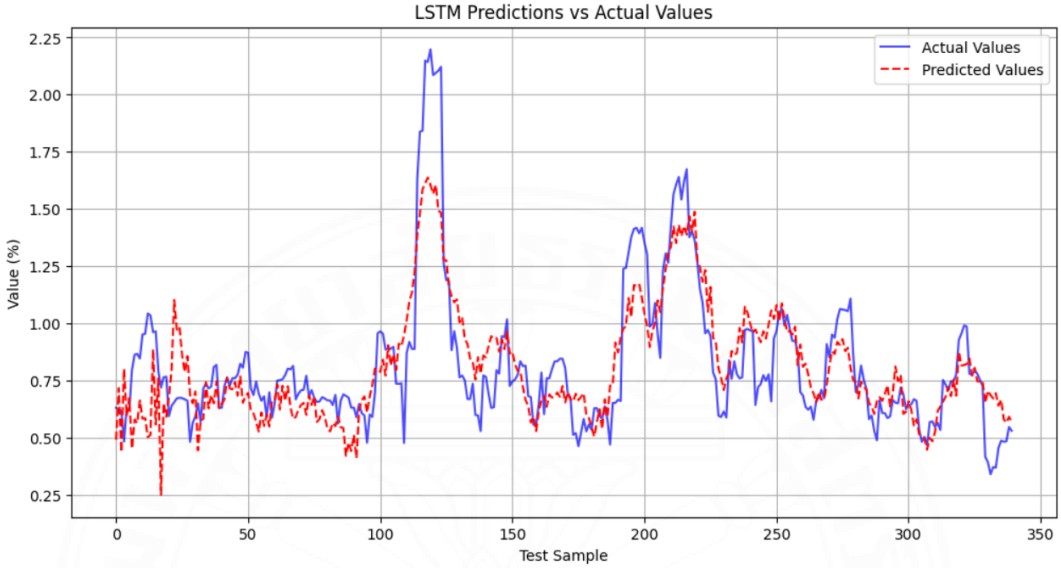

ภาพที่ 4.48

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม RNN บนดัชนี SET ไม่รวมช่วง Covid-19

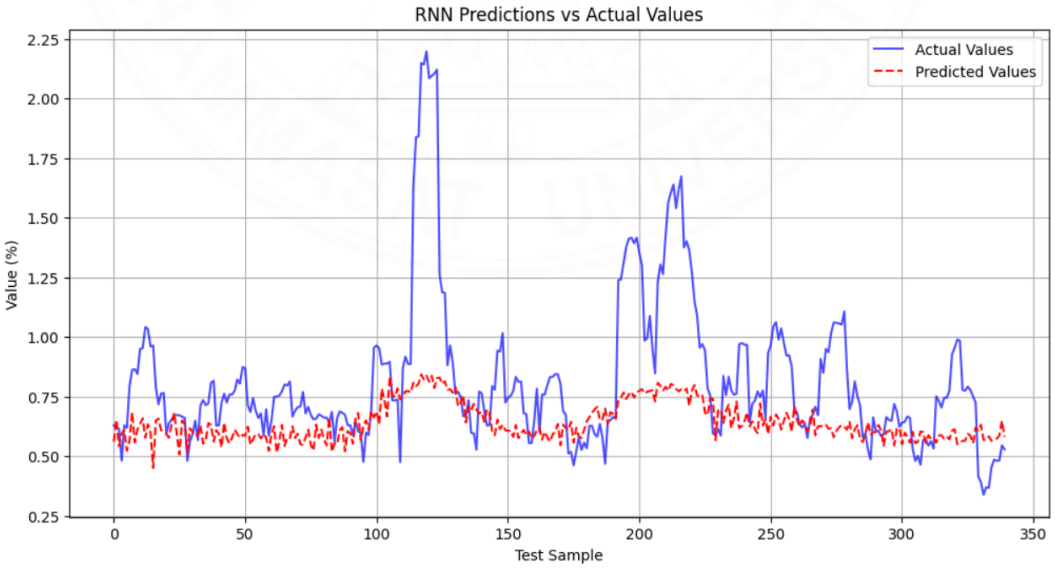

Ref. code: 25676602110550SKO

ภาพที่ 4.49

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม GRU บนดัชนี SET ไม่รวมช่วง Covid-19

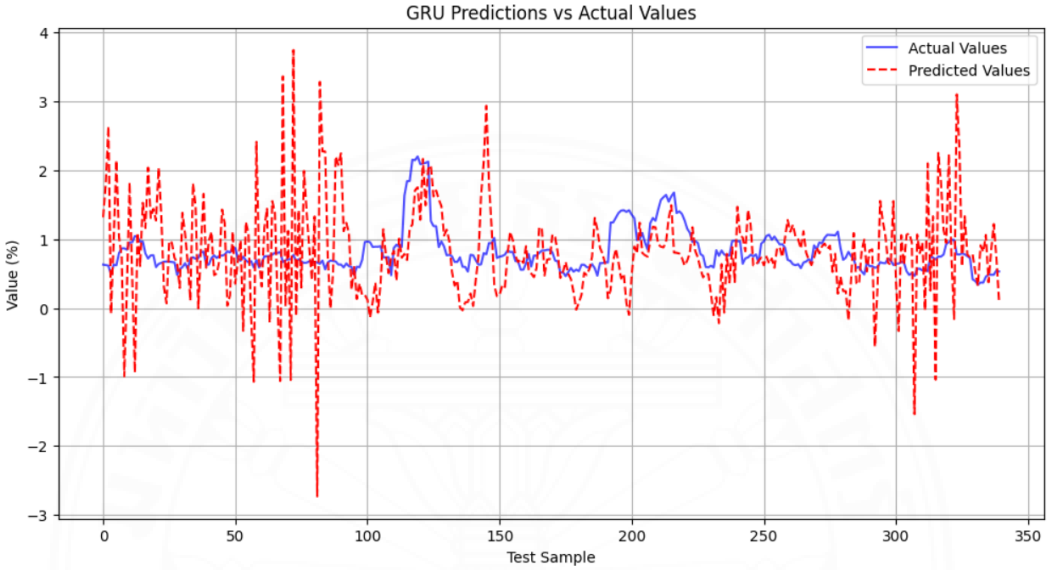

ภาพที่ 4.50

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม XGBoost บนดัชนี SET ไม่รวมช่วง Covid-19

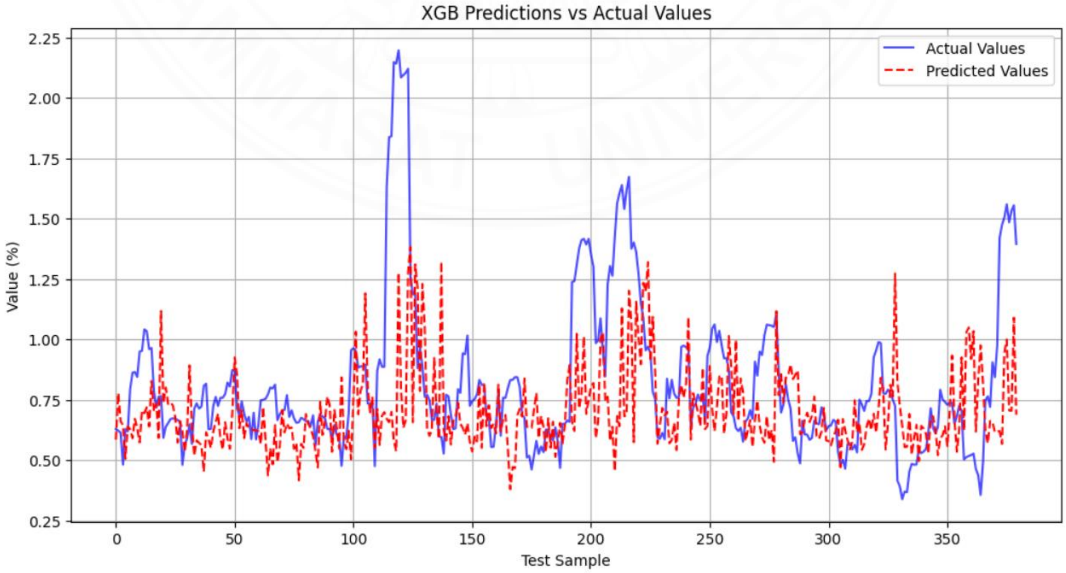

Ref. code: 25676602110550SKO

ภาพที่ 4.51

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Random Forest บนดัชนี SET ไม่รวมช่วง Covid-19

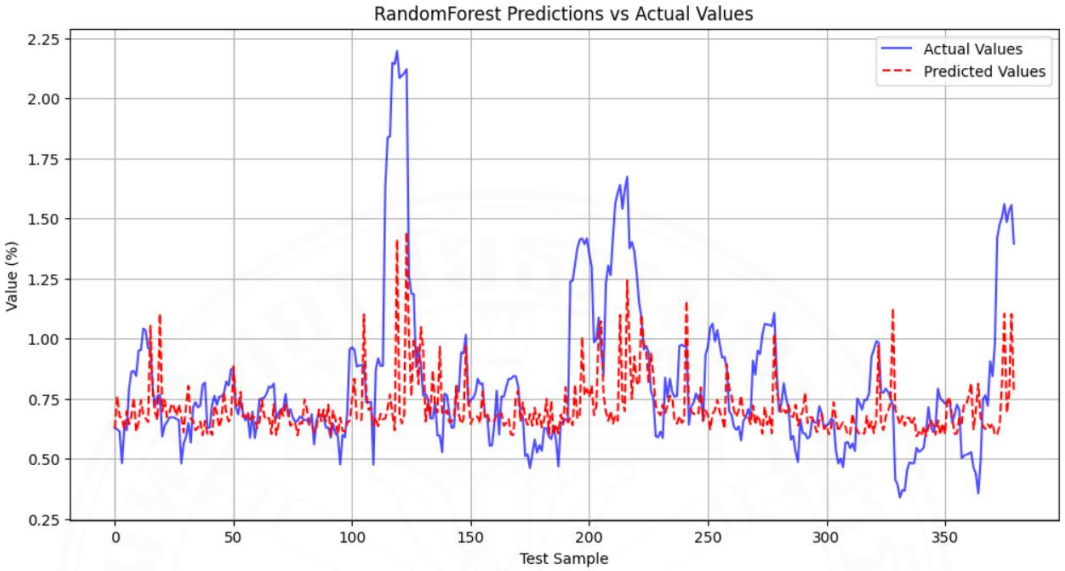

ภาพที่ 4.52

กราฟเส้นแสดงความผันผวนที่พยากรณ์กับความผันผวนที่เกิดขึ้นจริง โดยใช้โมเดลผสม Support Vector Machine บนดัชนี SET ไม่รวมช่วง Covid-19

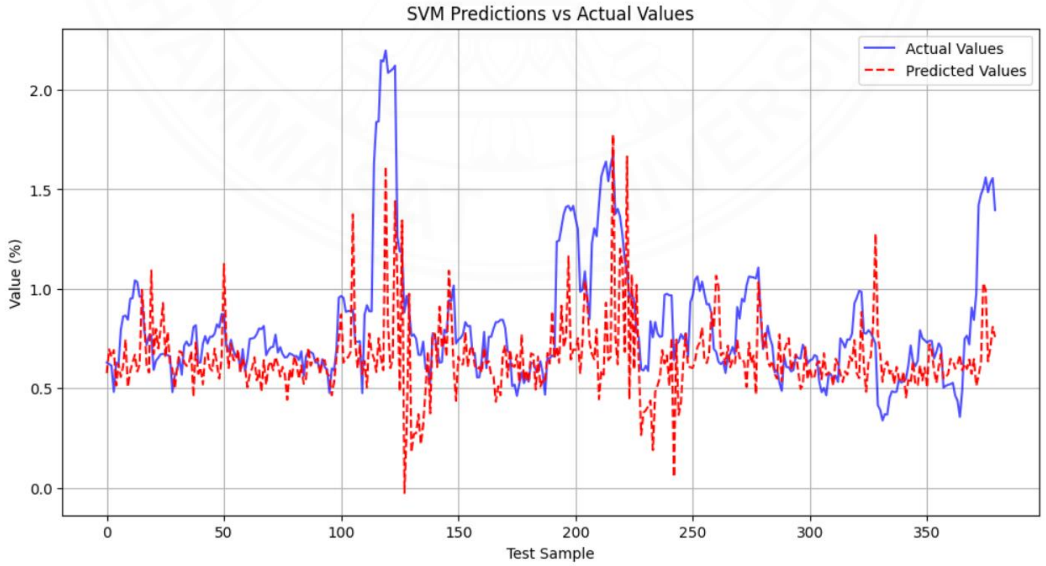

Ref. code: 25676602110550SKO

ตารางที่ 4.16

ตารางแสดงประสิทธิภาพของโมเดลผสมที่ใช้ในการพยากรณ์ความผันผวนราคาดัชนี SET ไม่รวมช่วง Covid-19

Model	MSE	RMSE	MAE
GARCH	0.078126	0.279511	0.190821
LSTM	0.000003	0.001803	0.001371
RNN	0.000010	0.003224	0.002111
GRU	0.000055	0.007414	0.005411
XGBoost	0.000011	0.003385	0.002227
Random Forest	0.000010	0.003125	0.001918
Support Vector Machine	0.000021	0.004574	0.004218

จากการทดลองเปรียบเทียบประสิทธิภาพของโมเดลผสม (Hybrid Model) ที่นำค่าความผันผวนจากแบบจำลอง GARCH มาใช้เป็นฟีเจอร์ร่วมกับโมเดล Machine Learning สำหรับการพยากรณ์ความผันผวนของดัชนี SET ภายใต้สองเงื่อนไข ได้แก่ ชุดข้อมูลที่รวมช่วง COVID-19 และชุดข้อมูลที่ตัดช่วง COVID-19 ออก พบว่าช่วงเวลาของข้อมูลมีผลต่อความแม่นยำของโมเดลอย่างชัดเจน

ในกรณีที่รวมช่วง COVID-19 ไว้ พบว่าโมเดล Tree-based ได้แก่ XGBoost และ Random Forest มีค่า MAE อยู่ที่ 0.002483 และ 0.002478 ตามลำดับ โดยสามารถรักษาระดับประสิทธิภาพได้ แม้ในช่วงที่ตลาดมีความผันผวนสูง ส่วนโมเดลกลุ่ม RNNs เช่น LSTM และ GRU ให้ค่า MAE ที่สูงขึ้น โดย LSTM มีค่า MAE เท่ากับ 0.002869 และ GRU มีค่า MAE สูงถึง 0.010072 ซึ่งบ่งชี้ว่าโมเดลเหล่านี้มีความไวต่อความไม่ปกติของข้อมูลจากวิกฤตการณ์ เช่น การระบาดของโรคโควิด-19 ทำให้ความแม่นยำลดลง

ในทางกลับกัน เมื่อใช้ชุดข้อมูลที่ตัดช่วง COVID-19 ออก พบว่าโมเดลเกือบทุกตัวมีค่าความคลาดเคลื่อนลดลงอย่างมีนัยสำคัญ โดยเฉพาะในกลุ่ม RNNs เช่น LSTM ที่ค่า MAE ลดลงเหลือ 0.001371 และ GRU ลดลงเหลือ 0.005411 ส่วน RNN ก็มีค่า MAE ลดลงจาก 0.005514 เหลือ 0.002111 สำหรับ XGBoost และ Random Forest แม้จะมีความเปลี่ยนแปลงไม่มาก แต่ก็ยังรักษาค่าความคลาดเคลื่อนให้อยู่ในระดับต่ำที่ MAE เท่ากับ 0.002227 และ 0.001918 ตามลำดับ

Ref. code: 25676602110550SKO

โดยสรุป การตัดช่วง COVID-19 ออกจากชุดข้อมูลมีผลในเชิงบวกต่อประสิทธิภาพของโมเดลผสมบนดัชนี SET โดยเฉพาะในกลุ่ม RNNs ที่อ่อนไหวต่อ outlier มากกว่ากลุ่ม Tree-based การทำความสะอาดข้อมูลเพื่อลดความแปรปรวนจึงเป็นแนวทางสำคัญที่ช่วยให้โมเดลสามารถเรียนรู้และพยากรณ์ได้แม่นยำยิ่งขึ้น

Ref. code: 25676602110550SKO

บทที่ 5
สรุปผลการวิจัยและข้อเสนอแนะ

การค้นคว้าอิสระเรื่องวิเคราะห์การเปรียบเทียบการพยากรณ์ความผันผวนของราคาหุ้นระหว่าง GARCH และ Machine Learning/Deep Learning สามารถสรุปผลการวิจัยและข้อเสนอแนะได้ 4 ส่วน ได้แก่ สรุปผลการวิจัย ข้อจำกัดงานวิจัย ประโยชน์และแนวทางการนำไปใช้ และสุดท้ายข้อเสนอแนะสำหรับงานวิจัยในอนาคต ซึ่งมีรายละเอียดดังนี้

5.1 สรุปผลการวิจัย

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง GARCH กับเทคนิค Machine Learning และ Deep Learning ในการพยากรณ์ความผันผวนของราคาหลักทรัพย์ โดยใช้ดัชนี S&P500 และ SET Index เป็นกรณีศึกษา และแบ่งการวิเคราะห์ออกเป็นทั้งแบบโมเดลเดี่ยว (single model) และโมเดลผสม (hybrid model)

จากผลการศึกษาตามวัตถุประสงค์ข้อที่หนึ่ง ซึ่งต้องการเปรียบเทียบการประยุกต์ใช้เทคนิคแมชชีนเลิร์นนิงเพื่อพยากรณ์ความผันผวนของราคาหลักทรัพย์ พบว่าโมเดลในกลุ่ม RNNs ทั้ง LSTM และ GRU ให้ผลคลาดเคลื่อนที่น้อยที่สุด ในหลายๆ สถานการณ์ ต่อมาโมเดลอื่นๆ Random Forest และ XGBoost ให้ผลลัพท์ที่ดีลองลงมามีค่าความคลาดเคลื่อนต่ำกว่าโมเดล GARCH แบบดั้งเดิมอย่างชัดเจน

สำหรับวัตถุประสงค์ข้อที่สอง ซึ่งมุ่งศึกษาการผสาน GARCH กับเทคนิค Machine learning ในลักษณะ Hybrid Model ผลการทดลองแสดงให้เห็นว่า การใช้ค่าความผันผวนจาก GARCH เป็นหนึ่งในฟีเจอร์ของโมเดล Machine Learning มิได้ให้ผลดีตามที่คลาดการณ์ไว้เมื่อตอนเริ่มการศึกษา กลับพบผลดีขึ้นเพียงแค่ XGBoost และ Random Forest ในกรณีที่เลวร้ายยังทำให้โมเดลอื่นๆ มีค่าความคลาดเคลื่อนที่เพิ่มมากกว่าเดิมเกิดเป็นความซับซ้อนของข้อมูลในการเทรนโมเดลดงให้เห็นว่าโมเดลบางประเภทอาจมีความสามารถเพียงพอในการเรียนรู้โครงสร้างความผันผวนโดยไม่ต้องพึ่งพาแบบจำลองเชิงสถิติ

ในส่วนของวัตถุประสงค์ข้อที่สาม ที่ต้องการศึกษาผลของการตัดช่วงเวลาที่มีเหตุการณ์ COVID-19 ออก พบว่าโมเดลจำนวนมากโดยเฉพาะ LSTM และ GRU มีประสิทธิภาพเพิ่มขึ้นเมื่อใช้ข้อมูลที่ไม่มีช่วงเวลา COVID-19 สะท้อนให้เห็นว่าโมเดลเหล่านี้ไวต่อ outlier และความแปรปรวนสูง

Ref. code: 25676602110550SKO

ซึ่งเป็นคุณสมบัติที่ต้องพิจารณาอย่างรอบคอบหากจะนำไปใช้งานจริงในสถานการณ์ที่มีความไม่แน่นอนทางเศรษฐกิจ

โดยสรุป โมเดลที่เหมาะสมกับการพยากรณ์ความผันผวนของราคาหลักทรัพย์ควรคำนึงถึงลักษณะของข้อมูลและสภาวะตลาดเป็นสำคัญ ทั้งนี้ การเลือกใช้โมเดลกับการสร้างฟีเจอร์ที่เหมาะสม หรือการผสานโมเดล GARCH เข้ากับเทคนิค Machine Learning บางประเภทล้วนเป็นแนวทางที่มีศักยภาพในการใช้งานจริงอย่างยิ่งในบริบทของการบริหารความเสี่ยงทางการเงินยุคใหม่

5.2 ข้อจำกัดในงานวิจัย

5.2.1 ข้อมูลที่ใช้ในการสร้างตัวแบบ

เนื่องจากในปีพ.ศ. 2563 เป็นต้นมา ได้เกิดการแพร่ระบาดของโรคโควิด-19 ซึ่งส่งผลกระทบอย่างมีนัยสำคัญต่อการเคลื่อนไหวของราคาหลักทรัพย์ในตลาดหลักทรัพย์แห่งประเทศไทย รวมถึงสินทรัพย์ทางการเงินในหลายประเทศทั่วโลก โดยเหตุการณ์ดังกล่าวถือเป็นสถานการณ์ที่ไม่ปกติและยากต่อการคาดการณ์ล่วงหน้า แม้ว่าเราจะทำการทดลองโดยแบ่งออกเป็นชุดข้อมูลที่รวมเหตุการณ์การแพร่ระบาดของโรคโควิด-19 และชุดข้อมูลที่ไม่รวมเหตุการณ์การแพร่ระบาดของโรคโควิด-19 เพื่อทดสอบผลกระทบของเหตุการณ์พิเศษนี้ แต่เมื่อนำไปใช้งานจริงหากไม่มีเหตุการณ์พิเศษหรือมีเหตุการณ์พิเศษเกิดขึ้นในรูปแบบใหม่ อาจก่อให้เกิดผลลัพธ์การเปลี่ยนแปลงผลการทำนายของตัวแบบ

5.2.2 จำนวนตัวแปรอิสระ

ในการศึกษาครั้งนี้ใช้ตัวแปรอิสระในการสร้างตัวแบบพยากรณ์ราคาหลักทรัพย์ทั้งหมดจำนวน 6 ตัวแปร ซึ่งอิงมาจากการทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องและคัดเลือกตัวแปรที่มีความสัมพันธ์กับการเปลี่ยนแปลงของราคาหลักทรัพย์ดัชนี SET50 และ S&P500 มาบางตัว ซึ่งมีผลต่อประสิทธิภาพความแม่นยำของตัวแบบการพยากรณ์ ซึ่งในหมายความว่าเมื่อนำตัวแบบพยากรณ์ไปประยุกต์ใช้ในราคาหลักทรัพย์อื่น ๆ ตัวแปรอิสระทั้ง 6 ตัวอาจจะไม่มีประสิทธิภาพเหมือนการทดลองครั้งนี้ นำไปสู่ผลลัพธ์ที่ดีขึ้นหรือแย่ลงได้

5.2.3 ข้อจำกัดด้านทรัพยากรฮาร์ดแวร์ในการประมวลผลโมเดล

เนื่องจากโมเดลประเภท Deep Learning โดยเฉพาะ LSTM และ GRU มีโครงสร้างที่ซับซ้อนและต้องใช้ทรัพยากรในการประมวลผลจำนวนมาก การฝึกและทดสอบโมเดลในงานวิจัยฉบับนี้จึงต้องดำเนินการภายใต้ข้อจำกัดของเครื่องคอมพิวเตอร์ส่วนบุคคล (Personal Computer) ที่ไม่มีการ์ดประมวลผลแบบกราฟิก (GPU) ระดับสูง หรือหน่วยความจำ (RAM) ขนาด

Ref. code: 25676602110550SKO

ใหญ่เพียงพอ ข้อจำกัดนี้ส่งผลให้ต้องลดขนาดของข้อมูลหรือจำกัดจำนวน epoch และ batch size ในการฝึกโมเดล เพื่อให้สามารถประมวลผลได้ภายในเวลาที่เหมาะสม ซึ่งอาจกระทบต่อประสิทธิภาพสูงสุดที่โมเดลสามารถทำได้ในเชิงทฤษฎี นอกจากนี้ ยังไม่สามารถทดลองใช้โมเดลขนาดใหญ่หรือโมเดลใหม่ที่มีพารามิเตอร์จำนวนมาก เช่น Transformer-based models ได้อย่างเต็มที่ ดังนั้น หากมีการใช้ทรัพยากรฮาร์ดแวร์ที่มีประสิทธิภาพสูงกว่านี้ในงานวิจัยอนาคต เช่น ระบบที่มี GPU ประสิทธิภาพสูงหรือทำงานผ่าน Cloud Computing ก็อาจช่วยให้สามารถฝึกโมเดลที่ซับซ้อนมากขึ้นได้เต็มประสิทธิภาพ และอาจได้ผลลัพธ์ที่แม่นยำยิ่งขึ้น

5.2.4 ข้อจำกัดด้านการกำหนดพารามิเตอร์ของโมเดล (Hyperparameter Tuning)

ในงานวิจัยฉบับนี้ การกำหนดพารามิเตอร์ของโมเดล (hyperparameters) เช่น จำนวน hidden units, learning rate, batch size และจำนวน epoch ถูกเลือกบนพื้นฐานของการทดลองเบื้องต้นและข้อจำกัดของเวลาและทรัพยากรในการประมวลผล แม้ว่าวิธีนี้จะเพียงพอสำหรับการประเมินประสิทธิภาพในภาพรวม แต่ยังไม่สามารถยืนยันได้ว่าเป็นการเลือกค่าที่เหมาะสมที่สุด (optimal) สำหรับแต่ละโมเดล การปรับพารามิเตอร์ให้เหมาะสมในเชิงลึกโดยใช้วิธีการเช่น Grid Search, Random Search หรือ Bayesian Optimization อาจช่วยให้ได้โมเดลที่มีประสิทธิภาพสูงขึ้น โดยเฉพาะอย่างยิ่งในกลุ่มของ Deep Learning ซึ่งพารามิเตอร์มีอิทธิพลต่อผลลัพธ์อย่างมาก ดังนั้น งานวิจัยในอนาคตควรพิจารณานำเทคนิคการปรับค่าพารามิเตอร์เชิงระบบมาใช้ เพื่อให้มั่นใจว่าโมเดลที่ได้มีประสิทธิภาพสูงสุดภายใต้เงื่อนไขข้อมูลที่ใช้

5.3 ข้อเสนอแนะและแนวทางในการทำวิจัยในขั้นถัดไป

5.3.1 ขยายขอบเขตของข้อมูล

การวิจัยครั้งนี้ดำเนินการบนข้อมูลดิบสองชุดคือ SET Index และ S&P500 Index ซึ่งเป็นตัวแทนของตลาดหุ้นไทยและตลาดหุ้นสหรัฐฯ ตามลำดับ อย่างไรก็ตาม โมเดลที่แสดงประสิทธิภาพดีในสองชุดข้อมูลนี้ อาจไม่ได้ให้ผลลัพธ์ในระดับเดียวกันเมื่อประยุกต์ใช้กับข้อมูลจากตลาดอื่น หรือกับหุ้นรายตัวที่มีลักษณะแตกต่างกัน ดังนั้น งานวิจัยในอนาคตควรขยายขอบเขตของข้อมูลให้ครอบคลุมกลุ่มสินทรัพย์ที่หลากหลายยิ่งขึ้น เพื่อประเมินความสามารถในการทั่วไปของโมเดลอย่างรอบด้านยิ่งขึ้น

Ref. code: 25676602110550SKO

5.3.2 การปรับเปลี่ยนหรือเพิ่มเติมตัวแปรอิสระอื่น ๆ

แม้ว่างานวิจัยนี้จะเลือกใช้ตัวแปรอิสระจำนวน 6 ตัวที่เกี่ยวข้องกับความผันผวนของราคาหลักทรัพย์จากดัชนี SET และ S&P500 ซึ่งผ่านการพิจารณาจากวรรณกรรมที่เกี่ยวข้องแล้ว แต่ยังมีโอกาสในการเพิ่มตัวแปรอื่นที่อาจส่งผลต่อความแม่นยำของการพยากรณ์ เช่น ตัวแปรด้านมหภาคทางเศรษฐกิจ อารมณ์ของนักลงทุน (Investor Sentiment) หรือข้อมูลข่าวสารที่ส่งผลต่อทิศทางตลาดในระยะสั้น โดยเฉพาะการนำเทคนิคการวิเคราะห์ความรู้สึก (Sentiment Analysis) จากข้อความข่าวหรือโพสต์บนโซเชียลมีเดียมาผสมกับโมเดลการเรียนรู้ของเครื่องและเชิงลึก อาจช่วยสะท้อนสภาวะตลาดได้ทันเหตุการณ์และมีผลเชิงพยากรณ์ต่อความผันผวนของราคาหลักทรัพย์มากยิ่งขึ้น

5.3.3 การประเมินผลด้วยเกณฑ์เพิ่มเติมนอกเหนือจาก MAE/MSE/RMSE

เกณฑ์ MAE, MSE และ RMSE ให้ข้อมูลเกี่ยวกับความแม่นยำของการพยากรณ์ แต่ในบริบทของการบริหารความเสี่ยง นักลงทุนอาจสนใจประสิทธิภาพของโมเดลในช่วงที่ตลาดผันผวนสูง (tail risk) ดังนั้นงานวิจัยในอนาคตควรพิจารณาใช้เกณฑ์อื่นร่วมด้วย เช่น Directional Accuracy, Value-at-Risk (VaR) violation rate, หรือ Backtesting with trading strategy simulation เพื่อสะท้อนคุณภาพของโมเดลในมุมมองของผู้ใช้งานจริงมากขึ้น

5.3.4 การปรับเปลี่ยน Time Step ในการพยากรณ์

ในงานวิจัยฉบับนี้ การสร้างตัวแบบพยากรณ์ใช้ข้อมูลในระดับรายวัน (daily data) เป็นหลัก ทั้งในขั้นตอนการคำนวณฟีเจอร์และการกำหนดเป้าหมายของการพยากรณ์ อย่างไรก็ตาม ความถี่ของข้อมูล (time step) มีผลโดยตรงต่อความแม่นยำและความเหมาะสมของตัวแบบ โดยเฉพาะในบริบทที่ผู้ใช้งานมีความต้องการในช่วงเวลาที่แตกต่างกัน เช่น รายชั่วโมง (intra-day), รายสัปดาห์ หรือรายเดือน งานวิจัยในอนาคตสามารถทดลองเปรียบเทียบประสิทธิภาพของโมเดลภายใต้ระดับ time step ที่หลากหลาย เพื่อประเมินว่าโมเดลใดมีความสามารถในการพยากรณ์ได้แม่นยำที่สุดในแต่ละช่วงเวลา นอกจากนี้ การใช้ข้อมูลความถี่สูง (high-frequency data) เช่น รายชั่วโมง หรือ tick data อาจมีประโยชน์ในการพยากรณ์ความผันผวนระยะสั้น โดยเฉพาะในสภาวะตลาดที่มีการเปลี่ยนแปลงอย่างรวดเร็ว การขยายขอบเขตไปยังระดับ time step ที่หลากหลายจะช่วยให้โมเดลสามารถตอบโจทย์เชิงกลยุทธ์ได้กว้างขึ้น ทั้งในมุมมองของนักลงทุนระยะสั้น กลาง และยาว อีกทั้งยังเป็นการเปิดทางให้กับการพัฒนาโมเดลที่สามารถเรียนรู้จากข้อมูลหลายระดับความถี่ได้พร้อมกัน (multi-resolution learning) ซึ่งเป็นแนวโน้มที่ได้รับความสนใจในงานวิจัยด้านการเงินเชิงลึกในปัจจุบัน

Ref. code: 25676602110550SKO

รายการอ้างอิง

หนังสือและบทความในหนังสือ

สรรพฤทธิ์ มฤคทัต และ บุญเสริม กิจศิริกุล (2562). *การรู้จำรูปแบบและการเรียนรู้ของเครื่อง (Pattern Recognition and Machine Learning)*. NSTDA Shop.

บทความวารสาร

วิจิตร คลังภูเขียว, พฤฒ ธนรัช, และ ปิยภัทร บุษบาบดินท. (2565). การพยากรณ์ความผันผวนของดัชนี SET ด้วยตัวแบบโครงข่ายประสาทเทียม-GARCH. *วารสารวิชาการคอมพิวเตอร์ศึกษา, 7*(1), 101–114.

สื่ออิเล็กทรอนิกส์

Bualabs. (2020, April 8). *RNN คืออะไร? GRU คืออะไร? สอนเขียน RNN/GRU ด้วย Python – NLP EP.9*. Bualabs. https://www.bualabs.com/archives/3103/what-is-rnn-recurrent-neural-network-what-is-gru-gated-recurrent-unit-teach-how-to-build-rnn-gru-with-python-nlp-ep-9/

Ref. code: 25676602110550SKO

Books

Géron, A. (2019*). Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems (2nd ed.)*. O'Reilly Media.

Hilpisch, Y. (2018). *Python for finance: Mastering data-driven finance (2nd ed.)*. O'Reilly Media.

Jansen, S. (2020). *Machine learning for algorithmic trading: Predictive models to extract signals from market and alternative data for systematic trading strategies with Python (2nd ed.)*. Packt Publishing.

Wooldridge, J. M. (2016). *Introductory econometrics: A modern approach (6th ed.)*. Cengage Learning.

Articles

Chen, S., Härdle, W. K., & Jeong, K. (2010). Forecasting volatility with support vector machine-based GARCH model. *Journal of Forecasting, 29*(4), 406–433. https://doi.org/10.1002/for.1134

Herwartz, H. (2017). Stock return prediction under GARCH — An empirical assessment. *International Journal of Forecasting, 33*(3), 569–580. https://doi.org/10.1016/j.ijforecast.2017.01.002

Huang, Y., Dai, X., Wang, Q., & Zhou, D. (2020). A hybrid model for carbon price forecasting using GARCH and long short-term memory network. *Expert Systems with Applications, 140*, 112867. https://doi.org/10.1016/j.eswa.2019.112867

Kim, H. Y., & Won, C. H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications, 103*, 25–37.

Ref. code: 25676602110550SKO

Kristjanpoller, W. R., & Michell, K. V. (2017). A stock market risk forecasting model through integration of switching regime, ANFIS and GARCH techniques. *Decision Support Systems, 91*, 24–33. https://doi.org/10.1016/j.dss.2016.11.005

Kristjanpoller, W. R., & Michell, K. V. (2018). A stock market risk forecasting model through integration of switching regime, ANFIS and GARCH techniques. *Applied Soft Computing, 67*, 106–116. https://doi.org/10.1016/j.asoc.2018.02.055

Lee, T., Fang, Y., & Su, J. (2019). Forecasting stock price volatility: New evidence from the GARCH-MIDAS model. *Dynamics of Continuous, Discrete & Impulsive Systems, Series B, 26*(6), 1059–1073. https://doi.org/10.5537/dcdisb.026.1059

Lu, X., Que, D., & Cao, G. (2020). Volatility forecast based on the hybrid artificial neural network and GARCH-type models. *Expert Systems with Applications, 160*, 113596. https://doi.org/10.1016/j.eswa.2020.113596

McNally, S., Roche, J., & Caton, S. (2018). Predicting the price of Bitcoin using Machine Learning. *Procedia Computer Science, 134*, 1–6. https://doi.org/10.1016/j.procs.2018.07.193

Narayan, P. K. (2022). Introduction of the special issue on COVID-19 and the financial and economic systems. *Financial Innovation, 8*, Article 59. https://doi.org/10.1186/s40854-022-00363-4

Ramos-Pérez, E., Alonso-González, P. J., & Núñez-Velázquez, J. J. (2019). Forecasting volatility with a stacked model based on a hybridized Artificial Neural Network. *Expert Systems with Applications, 125*, 306–316. https://doi.org/10.1016/j.eswa.2019.05.044

Ramos-Pérez, E., Alonso-González, P. J., & Núñez-Velázquez, J. J. (2021). Forecasting volatility with a stacked model based on a hybridized Artificial Neural Network. *Applied Soft Computing, 111*, 107658. https://doi.org/10.1016/j.asoc.2021.107658

Wang, S. (2024). *Machine learning and deep learning predictive models for the stock market*. SHS Web of Conferences, 196, 02007. https://doi.org/10.1051/shsconf/202419602007

Ref. code: 25676602110550SKO

Wang, Y., Yang, S., & Han, Y. (2019). Combining deep learning and GARCH models for financial volatility and risk forecasting. *Expert Systems with Applications, 140*, 112855. https://doi.org/10.1016/j.eswa.2019.112855

Yao, Y., Zhai, J., Cao, Y., Ding, X., Liu, J., & Luo, Y. (2017). Data analytics enhanced component volatility model. *Expert Systems with Applications, 84*, 232–241. https://doi.org/10.1016/j.eswa.2017.05.025

Zhang, C., Zhang, Y., Cucuringu, M., & Qian, Z. (2022). Volatility forecasting with machine learning and intraday commonality. *arXiv preprint arXiv:2202.08962*.

Electronic Media

GeeksforGeeks. (2020). *Deep Learning | Introduction to Long Short-Term Memory (LSTM).* https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/

Sinart, T. (2019, April 19). *Long Short-Term Memory (LSTM).* Medium. https://medium.com/@sinart.t/long-short-term-memory-lstm-e6cb23b494c6

Yahoo Finance. (n.d.). *S&P 500 (^GSPC) historical data*. Retrieved June 25, 2025, from https://finance.yahoo.com/quote/%5EGSPC/

Yahoo Finance. (n.d.). *SET Index (^SET.BK) historical data*. Retrieved June 25, 2025, from https://finance.yahoo.com/quote/%5ESET.BK/

Ref. code: 25676602110550SKO

ภาคผนวก

Ref. code: 25676602110550SKO

ภาคผนวก ก
กระบวนการเทรนโมเดล

งานวิจัยชิ้นนี้ได้มีการเขียนโปรแกรมผ่าน Jupyter Notebook โดยมีพื้นฐานการเขียนจากโมเดลของ Thomas Le Menestrel (2020) เป้าหมายเพื่อสร้างโมเดลที่ทำนายความผันผวน มีขั้นตอนในการเทรน ต่อไปนี้

1. การดาวน์โหลด Packages และ Library

```
import pandas as pd
from pandas.plotting import autocorrelation_plot
from pandas_datareader import data
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import math
from arch import arch_model
import yfinance as yf
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import GRU, Dense
from keras.layers import LSTM
from keras.layers import Dropout
from tensorflow.keras.callbacks import EarlyStopping
%matplotlib inline
from tensorflow import keras
from tensorflow.keras import layers
# Datetime
import datetime
```

Ref. code: 25676602110550SKO

```
# Scikit-Learn
from sklearn.model_selection import train_test_split, RandomizedSearchCV
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.metrics import mean_absolute_error
# Keras
from keras.models import Model
from keras.layers import *
from keras.utils.vis_utils import plot_model
from tensorflow.keras.models import load_model
# Ignore warning
import warnings
warnings.filterwarnings("ignore")

# Ignore warning
from arch import arch_model

#Machine learning
from xgboost import XGBRegressor
from sklearn.ensemble import RandomForestRegressor
from sklearn.svm import SVR
```

Ref. code: 25676602110550SKO

2. การ scraping ข้อมูลจาก yahoo finance

```
df = yf.download(tickers = '^GSPC', start=start_date, end=end_date, interval='1d')
df.replace(0, np.nan, inplace=True)
df.dropna(inplace=True)
```

3. การทำ feature engineering

```
#Log Returns
df['Log_Returns'] = np.log(df.Close) - np.log(df.Close.shift(1))
#Log Trading Range
df['Log_Trading_Range'] = np.log(df.High) - np.log(df.Low)
#Log Volume Change
df['Log_Volume_Change'] = np.log(df.Volume) - np.log(df.Volume.shift(1))
#Previous 10-day Volatility
df['Previous_10_Day_Volatility'] = df['Log_Returns'].rolling(window = 10).std()
#Previous 30-day Volatility
df['Previous_30_Day_Volatility'] = df['Log_Returns'].rolling(window = 30).std()
#Next 10-days volatility
df['Next_10_Days_Volatility'] = df['Log_Returns'].iloc[::-1].rolling(window =
10).std().iloc[::-1]
df.dropna(inplace = True)
```

Ref. code: 25676602110550SKO

4. การทำ GARCH MODEL

```
df['Volatility'] = df['Previous_30_Day_Volatility'] * (252**0.5) # Annualize
vol = df["Volatility"] * 100
am = arch_model(vol, vol='Garch', p=1, o=0, q=1, dist='Normal')
res = am.fit(disp='off')
display(res.summary())
df['forecast_vol'] = 0.1 * np.sqrt(
    res.params['omega'] +
    res.params['alpha[1]'] * res.resid**2 +
    res.conditional_volatility**2 * res.params['beta[1]']
)
display(df.tail(10))
df.dropna(inplace = True)

plt.figure(figsize=(16,6))
df["Volatility"].plot()
df["forecast_vol"].plot()
plt.title("Real Rolling Volatility vs Forecast by GARCH(1,1)")
plt.legend()
plt.show()
```

Ref. code: 25676602110550SKO

5. การเตรียมข้อมูลสำหรับการเทรนโมเดล

```
X = df.drop(["Next_10_Days_Volatility",'Low','High','Open','forecast_vol'], axis=1)
y = df["Next_10_Days_Volatility"]
X = np.array(X.values)
y = np.array(y.values).reshape(-1, 1)

# อัตราส่วนสำหรับการแบ่ง train/test (เช่น 20% สำหรับ test)
test_ratio = 0.2

# คำนวณขนาดของ test set
test_size = int(len(X) * test_ratio)

# แบ่งข้อมูล
X_train = X[test_size:,]
X_test = X[:test_size,]
y_train = y[test_size:]
y_test = y[:test_size]

# แสดงขนาดของข้อมูลที่แบ่ง
print(X_train.shape, y_train.shape)
print(X_test.shape, y_test.shape)
```

Ref. code: 25676602110550SKO

6. เพิ่ม lagging feature สำหรับข้อมูล

```
def get_lagged(x, y, t, s):

    lagged = []

    for i in range(x.shape[0] - t):

        if i == x.shape[0] - t:

            break

        for k in range(t):

            if k < t:

                lagged.append(x[i+k])

    lagged = np.array(lagged).reshape(s)

    return lagged, y[:lagged.shape[0],]
```

```
N = 30


X_train, y_train = get_lagged(X_train, y_train, N, (X_train.shape[0]-N,
N*X_train.shape[1]))
X_test, y_test = get_lagged(X_test, y_test, N, (X_test.shape[0]-N,
N*X_test.shape[1]))


print(X_train.shape, X_test.shape)
print(y_train.shape, y_test.shape)
```

Ref. code: 25676602110550SKO

```
T = 10


X_train, y_train = get_lagged(X_train, y_train, T, (X_train.shape[0]-T, T,
X_train.shape[1]))
X_test, y_test = get_lagged(X_test, y_test, T, (X_test.shape[0]-T, T,
X_test.shape[1]))


print(X_train.shape, X_test.shape)
print(y_train.shape, y_test.shape)
```

7. การสร้างโมเดล

7.1 Long Short-Term Memory (LSTM)

```
inputLSTM = Input(shape=(X_train.shape[1], X_train.shape[2]))
y = LSTM(200, return_sequences=True)(inputLSTM)  # Layer 1: 200 nodes
y = LSTM(100, return_sequences=True)(y)  # Layer 2: ลดเหลือ 100 nodes
y = LSTM(50)(y)
y = Dense(1)(y)
lstm = Model(inputs=inputLSTM, outputs=y)
lstm.summary()


plot_model(lstm, to_file='model_plot.png', show_shapes=True,
show_layer_names=True)
lstm.compile(optimizer=keras.optimizers.Adam(learning_rate=0.01),loss=tf.keras.lo
sses.MeanSquaredError()
             ,metrics=[tf.keras.metrics.RootMeanSquaredError()])
early_stopping = EarlyStopping(monitor='val_loss', patience=25,
restore_best_weights=True, verbose=1)
hist = lstm.fit(X_train,
y_train,batch_size=700,epochs=100,verbose=1,validation_split=0.2,shuffle=False,)
```

Ref. code: 25676602110550SKO

7.2 Recurrent Neural Network (RNN)

```
from keras.layers import Input, SimpleRNN, Dense
from keras.models import Model

# สร้างโมเดล RNN
inputRNN = Input(shape=(X_train.shape[1], X_train.shape[2]))
y = SimpleRNN(200, return_sequences=True)(inputRNN)
y = SimpleRNN(200)(y)
y = Dense(1)(y)

# กำหนดโมเดล
rnn = Model(inputs=inputRNN, outputs=y)

# แสดงโครงสร้างของโมเดล
rnn.summary()

plot_model(rnn, to_file='model_plot.png', show_shapes=True,
show_layer_names=True)

rnn.compile(optimizer=keras.optimizers.Adam(learning_rate=0.01),loss=tf.keras.loss
es.MeanSquaredError(),metrics=[tf.keras.metrics.RootMeanSquaredError()])

hist = rnn.fit(X_train,
y_train,batch_size=700,epochs=100,verbose=1,validation_split=0.3,shuffle=False)
```

Ref. code: 25676602110550SKO

7.3 Gated Recurrent Unit (GRU)

```
# สร้างโมเดล GRU
inputGRU = Input(shape=(X_train.shape[1], X_train.shape[2]))
y = GRU(200, return_sequences=True)(inputGRU)
y = GRU(200)(y)
y = Dense(1)(y)
# กำหนดโมเดล
gru = Model(inputs=inputGRU, outputs=y)
# แสดงโครงสร้างของโมเดล
gru.summary()
plot_model(gru, to_file='model_plot.png', show_shapes=True,
show_layer_names=True)
gru.compile(optimizer=keras.optimizers.Adam(learning_rate=0.01),loss=tf.keras.loss
es.MeanSquaredError(),metrics=[tf.keras.metrics.RootMeanSquaredError()])

hist = gru.fit(X_train,
y_train,batch_size=700,epochs=100,verbose=1,validation_split=0.3,shuffle=False,
callbacks=[early_stopping])
```

7.4 XGBoost

```
# Train XGBoost Model
xgb_model = XGBRegressor(n_estimators=100, max_depth=5, random_state=42)
xgb_model.fit(X_train, y_train)
#X_test = X_test.reshape(X_test.shape[0], X_test.shape[1])
# Make Predictions
y_pred = xgb_model.predict(X_train)
```

Ref. code: 25676602110550SKO

7.5 Random Forrest

```
# Train XGBoost Model
rf_model = RandomForestRegressor(n_estimators=100, max_depth=5,
random_state=42)
rf_model.fit(X_train, y_train)
#X_test = X_test.reshape(X_test.shape[0], X_test.shape[1])
# Make Predictions
y_pred = rf_model.predict(X_train)
```

7.6 Support Vector Machine

```
# Train XGBoost Model
svm_model = SVR(kernel='rbf', C=100, gamma=0.1, epsilon=0.01)
svm_model.fit(X_train, y_train)
#X_test = X_test.reshape(X_test.shape[0], X_test.shape[1])
# Make Predictions
y_pred4 = svm_model.predict(X_train)
```

Ref. code: 25676602110550SKO

8. แสดงผลลัพธ์การทำนาย

```
for ind, i in enumerate(model.predict(X_test)):

    print('Prediction: ' + str('{:.2f}'.format(round(100 * round(i[0], 4),3))) + ',    ' +
'Actual Value: ' + str('{:.2f}'.format(round(100 * round(y_test[ind][0],4),2))))
```

```
# คำนวณค่าทำนายจากโมเดล LSTM
predictions = mooodel.predict(X_test).flatten()  # ทำให้เป็น 1D array
actuals = y_test.flatten()  # ค่าจริงในรูปแบบ 1D array

# พล็อตกราฟเปรียบเทียบ
plt.figure(figsize=(12, 6))
plt.plot(actuals * 100, label="Actual Values", color='blue', alpha=0.7)
plt.plot(predictions * 100, label="Predicted Values", color='red', linestyle='dashed')
plt.title("Model Predictions vs Actual Values")
plt.xlabel("Test Sample")
plt.ylabel("Value (%)")
plt.legend()
plt.grid(True)
plt.show()
```

Ref. code: 25676602110550SKO

9. วัดผลค่าความคลาดเคลื่อน

```
def printing_out_results_of_a_model_round_up(model, X_test, y_test):

    y_pred = model.predict(X_test)

    # Print the R2 score
    print("R2 score:\n")
    print(('{:.2f}'.format(100 * r2_score(y_test, y_pred))) + " %")
    print("\n")
    # Print the RMSE
    print("RMSE:\n")
    print(round(math.sqrt(mean_squared_error(y_test, y_pred)), 6))  # 4 decimal
places
    print('\n')
    # Print the Mean Squared Error
    print("Mean Squared Error:\n")
    print('{:.6f}'.format(mean_squared_error(y_test, y_pred)))  # 6 decimal places
    print('\n')
    # Print the Mean Absolute Error
    print("Mean Absolute Error:\n")
    print('{:.6f}'.format(mean_absolute_error(y_test, y_pred)))

printing_out_results_of_a_model_round_up(lstm, X_test, y_test)
```

Ref. code: 25676602110550SKO

ประวัติผู้เขียน

ชื่อ	ธรรศทัพพ์ สงวนสุข
วุฒิการศึกษา	ปีการศึกษา 2566: บริหารธุรกิจบัณฑิต (การจัดการธุรกิจแบบบรณาการ) มหาวิทยาลัยธรรมศาสตร์

Ref. code: 25676602110550SKO