

การพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย

FORECASTING THE VOLATILITY OF STOCK RETURNS IN THE
STOCK EXCHANGE OF THAILAND



นายพลิชฐ์ อนันต์เจริญพร
PASIT ANANCHAROENPORN

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

2567

KMITL-2024-SC-M-017-040

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

FORECASTING THE VOLATILITY OF STOCK RETURNS IN THE
STOCK EXCHANGE OF THAILAND



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

2024

KMITL-2024-SC-M-017-040

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2024

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย
ชื่อนักศึกษา	นายพลิชฐ์ อนันต์เจริญพร
รหัสนักศึกษา	63605079
ปริญญา	วิทยาศาสตร์มหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์) ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
พ.ศ.	2567
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ผู้ช่วยศาสตราจารย์ ดร.ปัทมา เจริญพร

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์ในการสร้างแบบจำลองที่เหมาะสมในการพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย ซึ่งเป็นศูนย์กลางการซื้อขายหลักทรัพย์ของประเทศไทย และเป็นหนึ่งในตลาดหลักทรัพย์ที่สำคัญในภูมิภาคเอเชียตะวันออกเฉียงใต้ ความผันผวนของผลตอบแทนหุ้นในตลาดหลักทรัพย์แห่งประเทศไทยมีความสำคัญในการบริหารความเสี่ยงและการตัดสินใจลงทุน ดังนั้นการสร้างแบบจำลองที่สามารถพยากรณ์ค่าความผันผวนได้อย่างแม่นยำจึงมีความสำคัญอย่างยิ่ง ในงานวิจัยนี้ ได้มีการใช้แบบจำลองในกลุ่ม GARCH ได้แก่ แบบจำลอง GARCH แบบจำลอง GJR-GARCH และแบบจำลอง TARARCH โดยใช้ข้อมูลราคาหุ้นของตลาดหลักทรัพย์แห่งประเทศไทย ระหว่างวันที่ 1 มกราคม 2559 ถึงวันที่ 31 ธันวาคม 2566 โดยทำการแบ่งข้อมูลออกเป็น 3 ส่วน คือ ชุดข้อมูลฝึกสอน (Train Set) จำนวน 1,329 วัน คิดเป็นร้อยละ 70 ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Set) จำนวน 284 วัน คิดเป็นร้อยละ 15 และชุดข้อมูลทดสอบ (Test Set) จำนวน 284 วัน คิดเป็นร้อยละ 15 ผู้วิจัยได้ทำการทดสอบการทำงานของแบบจำลองในกลุ่ม GARCH โดยใช้วิธีการทำนายแบบ Expanding window กับข้อมูลในชุดฝึกสอนและชุดตรวจสอบความถูกต้อง ผลการศึกษาพบว่าแบบจำลอง TARARCH เป็นแบบจำลองที่มีค่าความคลาดเคลื่อนในการทำนายต่ำที่สุด โดยมีค่า RMSPE เท่ากับ 0.1927 ดังนั้น ผู้วิจัยจึงเลือกแบบจำลอง TARARCH สำหรับการทำนายกับชุดข้อมูลทดสอบ ซึ่งมีค่า RMSPE เท่ากับ 0.1876

คำสำคัญ : แบบจำลอง GARCH, แบบจำลอง GJR-GARCH, แบบจำลอง TARARCH, ความผันผวนของผลตอบแทนหุ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Independent Study Title	Forecasting the Volatility of Stock Returns In The Stock Exchange of Thailand
Student Name	Mr.Pasit Ananchaoenporn
Student ID	63605079
Degree	Master of Science (Data Science and Analytics) KMITL-Digital Analytics and Intelligence Center
Year	2024
Independent Study Advisor	Asst. Prof. Dr. Patama Charoenphol

Abstract

This research aims to develop an appropriate model for forecasting the volatility of stock returns on The Stock Exchange of Thailand (SET), which is the central trading hub for securities in Thailand and one of the key exchanges in Southeast Asia. The volatility of stock returns on SET is crucial for risk management and investment decision-making. Therefore, creating a model that can accurately predict volatility is of significant importance. In this research, models from the GARCH family were utilized, including the GARCH model, GJR-GARCH model and TARCH model. Stock price data from the SET, spanning from January 1, 2016 to December 31, 2023, were used. The data were divided into 3 parts: a training set comprising 1,329 days (70%), a validation set comprising 284 days (15%) and a test set comprising 284 days (15%). The researcher tested the performance of the GARCH family models using the expanding window forecasting method on the training and validation sets. The results indicated that the TARCH model had the lowest prediction error, with an RMSPE of 0.1927. Therefore, the researcher selected the TARCH model for forecasting on the test set, which resulted in an RMSPE of 0.1876.

Keywords: GARCH model, GJR-GARCH model, TARCH model, the volatility of stock returns

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

การศึกษาวิจัยฉบับนี้สำเร็จลุล่วงได้ด้วยดีเนื่องจากได้รับความกรุณาอย่างสูงจากอาจารย์ ผู้ช่วยศาสตราจารย์ ดร.ปัทมา เจริญพร และ ดร.อัคเดช อุดมชัยพร ที่ให้คำปรึกษาในงานวิจัยและให้คำแนะนำ ตลอดจนปรับปรุงแก้ไขข้อบกพร่องต่าง ๆ รวมทั้งบุคคลที่ผู้ที่ศึกษาค้นคว้าวิจัยนำมาอ้างอิงทางวิชาการตามที่ปรากฏในเอกสารอ้างอิงเพื่อให้การศึกษาวิจัยฉบับนี้มีความสมบูรณ์มากที่สุด

ขอขอบคุณ อาจารย์ รองศาสตราจารย์ ดร.ละออ บุญเกษม และ ผู้ช่วยศาสตราจารย์ ดร.ยุวดี กล่อมวิเศษ ผู้เป็นกรรมการสอบในงานวิจัยครั้งนี้ รวมทั้งขอบคุณอาจารย์ทุกท่านที่เคยสั่งสมให้ความรู้มาตลอดการศึกษา ขอขอบคุณเจ้าหน้าที่ประจำหลักสูตรวิทยาการข้อมูลและการวิเคราะห์ทุกท่านที่คอยให้คำปรึกษา คอยช่วยเหลือในการศึกษาระดับปริญญาโท และขอขอบคุณเพื่อน ๆ ทุกคนที่เคยช่วยเหลือไม่ว่าทางตรงหรือทางอ้อม

สุดท้ายนี้ขอขอบคุณบิดา มารดา และครอบครัวของข้าพเจ้าตลอดจนญาติพี่น้องผู้มีพระคุณทุกท่านที่คอยสนับสนุนช่วยเหลือให้คำปรึกษาในด้านต่าง ๆ และเป็นกำลังใจตลอดการศึกษา ทำให้ข้าพเจ้าสามารถทำงานวิจัยฉบับนี้ได้สำเร็จลุล่วง

นายพลีษฐ์ อนันต์เจริญพร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

บทคัดย่อภาษาไทย	ก
บทคัดย่อภาษาอังกฤษ	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญรูป	ช
บทที่ 1 บทนำ	1
1.1 ความสำคัญและที่มาของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตของงานวิจัย	2
1.4 ขั้นตอนการดำเนินงาน	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 การศึกษาความผันผวนของตลาดการเงิน	4
2.2 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)	5
2.3 แบบจำลองที่ใช้ในการศึกษา	5
2.3.1 GARCH	6
2.3.2 GJR-GARCH	8
2.3.3 TARARCH	8
2.4 การทดสอบความนิ่งของข้อมูล (Unit Root Test)	9
2.5 การประเมินและเปรียบเทียบประสิทธิภาพของโมเดล	10
2.5.1 รากที่สองของเปอร์เซ็นต์ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE)	10
2.5.2 รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)	10
2.6 Schwarz's Bayesian Information Criteria (BIC)	10
2.7 งานวิจัยที่เกี่ยวข้อง	11
บทที่ 3 วิธีการดำเนินงานวิจัย	12
3.1 ข้อมูลและแหล่งที่มาของข้อมูล	13
3.2 การเตรียมความพร้อมของข้อมูล	13
3.2.1 การสร้างตัวแปรผลตอบแทน	13

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.2 การสร้างตัวแปรเป้าหมาย	13
3.2.3 การทดสอบความนิ่งของตัวแปรผลตอบแทน	14
3.2.4 การนอร์มัลไลเซชันข้อมูล	15
3.3 การสร้างแบบจำลองพยากรณ์ความผันผวน	15
3.3.1 การสร้างแบบจำลอง GARCH	17
3.3.2 การสร้างแบบจำลอง GJR-GARCH	18
3.3.3 การสร้างแบบจำลอง TARCH	19
3.4 การวัดประสิทธิภาพของแบบจำลอง	20
3.5 เครื่องมือที่ใช้ในการทดลอง	21
3.5.1 ฮาร์ดแวร์	21
3.5.2 ซอฟต์แวร์	21
บทที่ 4 ผลการวิจัยและการอภิปรายผล	22
4.1 ผลการสำรวจเบื้องต้น	22
4.1.1 การวิเคราะห์ตัวแปรเบื้องต้น	22
4.1.2 การวิเคราะห์ตัวแปรผลตอบแทน	23
4.1.3 การทดสอบความนิ่งของตัวแปรผลตอบแทน	24
4.1.4 การนอร์มัลไลเซชันข้อมูล	24
4.2 ผลการทำงานของแบบจำลอง	25
4.2.1 ผลการทำงานของแบบจำลอง GARCH	26
4.2.2 ผลการทำงานของแบบจำลอง GJR-GARCH	27
4.2.3 ผลการทำงานของแบบจำลอง TARCH	28
4.3 การอภิปรายผล	30
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	32
5.1 สรุปผลการวิจัย	32
5.2 ขอบเขตและข้อจำกัด	33
5.3 ปัญหาและอุปสรรค	33
5.4 ข้อเสนอแนะ	33
เอกสารอ้างอิง	34
ภาคผนวก	36
ประวัติผู้เขียน	42

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
3.1 ไลบรารี (Library) ที่ใช้ในงานวิจัย	21
4.1 เปรียบเทียบค่า RMSPE ของแต่ละแบบจำลอง	30
4.2 เปรียบเทียบค่า RMSE ของแต่ละแบบจำลอง	30



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
3.1 ขั้นตอนวิธีการวิจัยการพยากรณ์ความผันผวนของ SET	12
3.2 การสร้างตัวแปรผลตอบแทน ด้วยโปรแกรมไพธอน	13
3.3 การคำนวณความผันผวนรายวัน ด้วยโปรแกรมไพธอน	14
3.4 การสร้างตัวแปรเป้าหมาย ด้วยโปรแกรมไพธอน	14
3.5 การทดสอบความนิ่งของตัวแปรผลตอบแทนโดยการใช้ ADF Test	14
3.6 การทำนอร์มัลไลเซชันของตัวแปรผลตอบแทน ด้วยโปรแกรมไพธอน	15
3.7 การทำนอร์มัลไลเซชันของตัวแปรเป้าหมาย ด้วยโปรแกรมไพธอน	15
3.8 วิธีการฝึกสอนสำหรับการทำนายแบบ Expanding window	16
3.9 การคำนวณความผันผวนเฉลี่ยรายวัน ด้วยโปรแกรมไพธอน	16
3.10 การสร้างแบบจำลอง GARCH	17
3.11 การสร้างแบบจำลอง GJR-GARCH	18
3.12 การสร้างแบบจำลอง TARCh	19
3.13 การคำนวณค่า RMSPE ด้วยโปรแกรมไพธอน	20
3.14 การคำนวณค่า RMSE ด้วยโปรแกรมไพธอน	20
4.1 กราฟแสดงราคาปิดของหลักทรัพย์ดัชนี SET	23
4.2 กราฟแสดงผลตอบแทนของหลักทรัพย์ดัชนี SET	23
4.3 กราฟแสดงผลการนอร์มัลไลเซชันของตัวแปรผลตอบแทน	24
4.4 กราฟแสดงผลการนอร์มัลไลเซชันของตัวแปรเป้าหมาย	25
4.5 กราฟแสดงผลการประเมินแบบจำลอง GARCH บนข้อมูลตรวจสอบ	26
4.6 กราฟแสดงการเรียนรู้ด้วย GARCH(2, 1) บนข้อมูลฝึกสอน	26
4.7 กราฟทำนายความผันผวนด้วย GARCH(2, 1) บนข้อมูลตรวจสอบ	27
4.8 กราฟแสดงผลการประเมินแบบจำลอง GJR-GARCH บนข้อมูลตรวจสอบ	27
4.9 กราฟแสดงการเรียนรู้ด้วย GJR-GARCH(2, 1) บนข้อมูลฝึกสอน	28
4.10 กราฟทำนายความผันผวนด้วย GJR-GARCH(2, 1) บนข้อมูลตรวจสอบ	28
4.11 กราฟแสดงผลการประเมินแบบจำลอง TARCh บนข้อมูลตรวจสอบ	29
4.12 กราฟแสดงการเรียนรู้ด้วย TARCh(1, 1, 0) บนข้อมูลฝึกสอน	29
4.13 กราฟทำนายความผันผวนด้วย TARCh(1, 1, 0) บนข้อมูลตรวจสอบ	29
4.14 กราฟแสดงผลการประเมินแบบจำลอง TARCh บนข้อมูลทดสอบ	31
4.15 กราฟแสดงการเรียนรู้ด้วย TARCh(1, 2, 0) บนข้อมูลฝึกสอนและข้อมูลตรวจสอบ	31

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.16 กราฟทำนายความผันผวนด้วย TARCH(1, 2, 0) บนข้อมูลทดสอบ

31



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของปัญหา

ตลาดหลักทรัพย์แห่งประเทศไทย (SET) เป็นศูนย์กลางการซื้อขายหลักทรัพย์ที่สำคัญของประเทศไทย และมีบทบาทสำคัญในการพัฒนาเศรษฐกิจของประเทศ โดย SET ให้โอกาสในการระดมทุนสำหรับบริษัทต่าง ๆ และเป็นแหล่งลงทุนที่สำคัญสำหรับนักลงทุนทั้งในและนอกประเทศ การลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยนั้นเป็นที่นิยมอย่างมาก เนื่องจากสามารถให้ผลตอบแทนที่ดีได้ แต่ในขณะเดียวกันก็มีความเสี่ยงสูงเนื่องจากความผันผวนของราคาหลักทรัพย์

ความผันผวนของผลตอบแทนหุ้นเป็นหนึ่งในปัจจัยที่มีผลกระทบต่อการตัดสินใจลงทุนและการบริหารความเสี่ยงของนักลงทุน ความผันผวนสูงมักจะทำให้องค์กรไม่แน่นอนและความเสี่ยงที่เพิ่มขึ้นในตลาด ซึ่งอาจเกิดจากปัจจัยหลายประการ เช่น การเปลี่ยนแปลงทางเศรษฐกิจ การเมือง และปัจจัยภายนอกอื่น ๆ การพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้นอย่างแม่นยำจึงเป็นสิ่งสำคัญที่จะช่วยให้ นักลงทุนสามารถตัดสินใจได้อย่างมีข้อมูลและลดความเสี่ยงจากการลงทุน

อย่างไรก็ตาม การพยากรณ์ความผันผวนของผลตอบแทนหุ้นนั้นเป็นเรื่องที่ทำนาย เนื่องจากความผันผวนในตลาดหลักทรัพย์เป็นปรากฏการณ์ที่มีความซับซ้อนและมีการเปลี่ยนแปลงอยู่ตลอดเวลา การใช้แบบจำลองทางคณิตศาสตร์และสถิติในการพยากรณ์ค่าความผันผวนจึงเป็นแนวทางหนึ่งที่มีความสนใจจากนักวิจัยและนักลงทุน

ในบรรดาแบบจำลองทางสถิติที่ใช้ในการพยากรณ์ความผันผวนของผลตอบแทนหุ้นแบบจำลอง GARCH (Generalized Autoregressive Conditional Heteroskedasticity) ได้รับการยอมรับอย่างกว้างขวาง เนื่องจากมีความสามารถในการจับลักษณะการเปลี่ยนแปลงของความผันผวนได้ดี แบบจำลอง GARCH สามารถขยายให้ครอบคลุมลักษณะการเปลี่ยนแปลงที่ซับซ้อนได้มากขึ้น เช่น แบบจำลอง GJR-GARCH (Glosten-Jagannathan-Runkle GARCH) และแบบจำลอง TARARCH (Threshold GARCH) ซึ่งสามารถจับผลกระทบที่ไม่สมมาตรของการเปลี่ยนแปลงในตลาดได้ดียิ่งขึ้น

การวิจัยนี้มีความสำคัญเนื่องจากสามารถนำผลลัพธ์ที่ได้ไปประยุกต์ใช้ในการบริหารความเสี่ยงและการวางแผนกลยุทธ์การลงทุนในตลาดหลักทรัพย์แห่งประเทศไทย ทั้งยังสามารถเป็นข้อมูล

พื้นฐานในการพัฒนาแบบจำลองพยากรณ์ที่มีความซับซ้อนมากขึ้นในอนาคต เพื่อเพิ่มประสิทธิภาพและความแม่นยำในการพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้น

การพัฒนาและการประเมินแบบจำลอง GARCH และแบบจำลองที่ขยายเพิ่มขึ้นเป็นขั้นตอนที่สำคัญในการวิจัยครั้งนี้ เนื่องจากการทำความเข้าใจในโครงสร้างของความผันผวนและการพยากรณ์ที่แม่นยำสามารถช่วยให้นักลงทุนและผู้จัดการพอร์ตโฟลิโอสามารถตัดสินใจได้อย่างมีข้อมูลและลดความเสี่ยงในการลงทุน

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อสร้างโมเดลในการพยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า โดยใช้แบบจำลองในกลุ่ม GARCH
2. เพื่อเปรียบเทียบประสิทธิภาพในการพยากรณ์ของแบบจำลอง โดยพิจารณาจากค่ารากที่สองของเปอร์เซ็นต์ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE) และค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

1.3 ขอบเขตของงานวิจัย

1. กลุ่มตัวอย่างที่ใช้ในการศึกษาคือ ข้อมูลหุ้นสามัญที่ได้มาจากเว็บไซต์ Yahoo Finance โดยใช้ข้อมูลราคาหุ้นของตลาดหลักทรัพย์แห่งประเทศไทย ระหว่างวันที่ 1 มกราคม 2559 ถึงวันที่ 31 ธันวาคม 2566
2. ตัวแปรที่เกี่ยวข้องได้แก่ ราคาปิด (Close) และผลตอบแทน (Returns)
3. แบบจำลองที่ใช้ในการพยากรณ์คือ แบบจำลองในกลุ่ม GARCH ได้แก่ แบบจำลอง GARCH แบบจำลอง GJR-GARCH และแบบจำลอง TARARCH
4. เครื่องมือที่ใช้ในการศึกษาครั้งนี้คือ โปรแกรมภาษาไพธอน (Python) โดยใช้ไลบรารี (Library) ต่าง ๆ เช่น
 - Yahoo Finance ใช้ในการดึงข้อมูลราคาหุ้น
 - Pandas ใช้ในการดำเนินการกับข้อมูลแบบตาราง
 - Seaborn ใช้ในการแสดงผลรูปแบบกราฟต่าง ๆ
 - ARCH ใช้ในการทำแบบจำลองในกลุ่ม GARCH

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.4 ขั้นตอนการดำเนินงาน

1. ศึกษาทฤษฎีที่เกี่ยวข้องกับการพยากรณ์ความผันผวนของราคาหลักทรัพย์ทางการเงิน
2. รวบรวม และจัดเตรียมข้อมูล
3. ทดสอบความนิ่งของข้อมูล โดยใช้วิธี Augmented Dickey-Fuller test (ADF test)
4. สร้างแบบจำลองพยากรณ์ความผันผวน โดยใช้แบบจำลองในกลุ่ม GARCH
5. เปรียบเทียบประสิทธิภาพของแบบจำลอง โดยพิจารณาจากค่ารากที่สองของเปอร์เซ็นต์

ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE)

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. ทำให้ทราบถึงแบบจำลองที่มีประสิทธิภาพมากที่สุด และเหมาะสมในการใช้พยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า
2. เพื่อให้ให้นักวิเคราะห์ราคาหลักทรัพย์สามารถพยากรณ์ความผันผวนของราคาหลักทรัพย์ดัชนี SET ได้ดียิ่งขึ้น
3. เพื่อใช้เป็นข้อมูลประกอบการตัดสินใจและการวางแผนการลงทุน รวมถึงการบริหารความเสี่ยงจากการลงทุน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การศึกษาความผันผวนของตลาดการเงิน

การศึกษาความผันผวนของตลาดสินทรัพย์ทางการเงิน ผ่านข้อมูลอนุกรมเวลาทางการเงิน (Financial time series) เป็นวิธีการวัดความเสี่ยงที่เกิดขึ้นจากการลงทุนในสินทรัพย์นั้น ๆ ซึ่งความสามารถในการพยากรณ์ความผันผวนที่จะเกิดขึ้นได้อย่างแม่นยำจะช่วยให้สถาบันการเงิน ธนาคารพาณิชย์ บริษัทต่าง ๆ ตลอดจนนักลงทุนรายย่อย สามารถบริหารความเสี่ยงที่อาจเกิดขึ้นจากการลงทุนได้อย่างมีประสิทธิภาพทั้งผ่านการวางกลยุทธ์การลงทุน รวมถึงการป้องกัน และจำกัดความเสี่ยงโดยใช้เครื่องมือทางการเงิน

จากการทำการทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องในการศึกษาและพยากรณ์ความผันผวนของข้อมูลอนุกรมเวลาทางการเงิน พบว่าตัวแบบ GARCH (Generalized Autoregressive Conditional Heteroscedasticity) เป็นหนึ่งในแบบจำลองที่เป็นที่รู้จัก และมีการใช้อย่างแพร่หลายในการพยากรณ์ความผันผวนของราคาหลักทรัพย์ทางการเงิน เนื่องจากมีจุดแข็งในการเป็นแบบจำลองที่มีคุณสมบัติเหมาะสม สามารถใช้กับข้อมูลทางการเงินที่เป็นอนุกรมเวลาทางการเงินได้ดี โดยเฉพาะอย่างยิ่ง GARCH(1, 1) ที่ไม่ซับซ้อนมาก และง่ายต่อการใช้งาน (Bollerslev, 1987) จากการที่สมมติฐานของแบบจำลองสอดคล้องกับลักษณะเฉพาะของข้อมูลทางการเงิน นั่นคือ การมีการกระจุกตัวของความผันผวน (Volatility Clustering) (Mandelbrot & Taylor, 1967) และการกระจายตัวของผลตอบแทนแบบโด่งสูง (Leptokurtosis) กล่าวอีกนัยหนึ่งก็คือข้อมูลผลตอบแทนจากหลักทรัพย์ทางการเงินไม่ได้แจกแจงแบบปกติมาตรฐาน (Normal Distribution) แต่มักจะมีลักษณะแพตเทิล (Fat Tail) ซึ่งคือการที่ปลายด้านซ้ายและขวาของกราฟการกระจายตัวมีความหนาแน่นมากกว่า และมีจุดสูงสุดของเส้นกราฟการกระจายตัวที่สูงกว่าการกระจายตัวแบบปกติมาตรฐาน

อย่างไรก็ดี ตัวแบบ GARCH ก็ยังมีจุดด้อยที่ไม่สามารถประมวลข้อมูลที่มีผลกระทบจากเหตุการณ์ที่ไม่คาดคิด (Shock) ในแง่ที่ส่งผลบวกและในแง่ที่ส่งผลลบที่มีความรุนแรงต่างกัน จึงมีการคิดค้นแบบจำลองอื่น ๆ ขึ้นมาเพื่อปิดจุดด้อยดังกล่าว เช่น แบบจำลอง GJR-GARCH (Glosten-Jagannathan-Runkle GARCH) โดย Glosten, Jagannathan และ Runkle (1993) และแบบจำลอง TARARCH โดย Zakoian (1994)

2.2 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

ข้อมูลอนุกรมเวลา (Time Series Data) คือ ชุดของข้อมูลที่เกี่ยวข้องกับช่วงเวลา เช่น ยอดขายสินค้าที่เก็บรวบรวมต่อเนื่องกันไปเป็นระยะเวลาหลายเดือน ข้อมูลรายได้ประชาชาติปีต่าง ๆ ที่เก็บรวบรวมต่อเนื่องกันไปเป็นระยะเวลาหลายปี ข้อมูลราคาของหุ้นหรือสกุลเงินดิจิทัลในแต่ละวัน เป็นต้น ข้อมูลอนุกรมเวลาอาจอยู่ในลักษณะที่เป็นข้อมูลรายปี รายไตรมาส หรือรายเดือน ทั้งขึ้นอยู่กับความเหมาะสมในการนำไปใช้ประโยชน์ในการวิเคราะห์อนุกรมเวลา เป็นวิธีการทางสถิติที่ใช้ข้อมูลในอดีตวิเคราะห์หาแบบจำลองเพื่ออธิบายลักษณะความสัมพันธ์ระหว่างข้อมูลที่เก็บตามลำดับเวลา โดยข้อมูลที่ใช้ในการวิเคราะห์จะมีลักษณะที่นิ่ง (Stationary) และใช้แบบจำลองในการพยากรณ์ข้อมูลในอนาคต หรือพิจารณาความสัมพันธ์ระหว่างตัวแปรต่าง ๆ ที่เกี่ยวข้อง ในการหาคุณลักษณะของอนุกรมเวลาเราสามารถเลือกใช้แบบจำลองได้หลายแบบ เช่น แบบจำลอง GARCH เป็นต้น

2.3 แบบจำลองที่ใช้ในการศึกษา

Box และ Jenkins (1970) ได้พัฒนาแบบจำลอง Autoregressive integrated moving average (ARIMA) เพื่ออธิบายการเปลี่ยนแปลงของอนุกรมเวลาโดยใช้ข้อมูลในอดีต โดยองค์ประกอบของแบบจำลอง ARIMA ประกอบด้วย 3 ส่วน ได้แก่ ส่วน Autoregressive process หรือ AR(p) เป็นส่วนที่อธิบายข้อมูลปัจจุบันด้วยข้อมูลในอดีต ส่วน Integrated(d) เป็นส่วนที่บอกจำนวนความแตกต่างที่จำเป็นในการทำให้อนุกรมเวลาคงที่ และส่วน Moving average process หรือ MA(q) เป็นส่วนที่อธิบายข้อมูลปัจจุบันด้วยความคลาดเคลื่อนทั้งในอดีตและปัจจุบัน ซึ่งแบบจำลองนี้สามารถเขียนอยู่ในรูป ARIMA(p, d, q) แต่ถ้าหากข้อมูลที่น่ามาใช้มีลักษณะที่นิ่งแล้ว d จะมีค่าเท่ากับ 0 กล่าวคือในส่วน Integrated จะหายไป จะได้เป็นแบบจำลอง ARMA(p, q)

ซึ่งแบบจำลอง ARIMA เหมาะสำหรับการพยากรณ์ข้อมูลที่มีจำนวนไม่มากและมีการผันผวนของข้อมูลที่ไม่สูง หรือไม่มีการเปลี่ยนแปลงของเทรน ดังนั้นถ้าข้อมูลมีจำนวนมากและมีความผิดปกติของข้อมูล มีความผันผวนเกิดขึ้นทำให้เทรนเปลี่ยน แบบจำลองนี้จะไม่สามารถพยากรณ์ออกมาได้ หรือการพยากรณ์นั้นจะมีความผิดพลาดและความคลาดเคลื่อนเกิดขึ้น

ต่อมาจึงได้มีการเสนอแบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH) เป็นแบบจำลองทางสถิติที่ใช้ในการวิเคราะห์ความผันผวนในอนุกรมเวลาเพื่อคาดการณ์ความผันผวนในอนาคต ข้อมูลทางการเงินส่วนใหญ่มีค่าความแปรปรวนไม่คงที่ (Heteroscedasticity) กล่าวคือ ความผันผวนของอัตราผลตอบแทนที่พิจารณาจากความแปรปรวนแบบมีเงื่อนไข (Conditional Variance) ซึ่งเป็นฟังก์ชันที่ขึ้นอยู่กับความคลาดเคลื่อนในอดีต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Engle (1982) ได้เสนอแบบจำลอง ARCH ขึ้นมาเพื่อใช้ในการประเมินความเสี่ยงโดยให้แบบจำลองความผันผวนที่ใกล้เคียงกับตลาดจริงมากขึ้น โดย Engle และคนอื่น ๆ ที่ทำงานเกี่ยวกับแบบจำลอง ARCH ตระหนักดีว่าข้อมูลทางการเงินในอดีตมีอิทธิพลต่อข้อมูลในอนาคต นั่นคือค่าจำกัดความของการถดถอยอัตโนมัติ (Autoregressive) ส่วนเงื่อนไขความแปรปรวนไม่คงที่ของแบบจำลอง ARCH อ้างถึงข้อเท็จจริงที่สังเกตได้ว่าความผันผวนในตลาดการเงินนั้นไม่คงที่ ข้อมูลทางการเงินทั้งหมดไม่ว่าจะเป็นมูลค่าตลาดหุ้น ตลาดสกุลเงินดิจิทัล ราคาน้ำมัน อัตราแลกเปลี่ยน หรือ GDP ล้วนผ่านช่วงเวลาที่มีความผันผวนสูงและต่ำ ซึ่งความผันผวนที่ไม่สม่ำเสมอและรุนแรงนี้เป็นเรื่องยากสำหรับแบบจำลองก่อนหน้านี้ อย่างไรก็ตาม แบบจำลอง ARCH สามารถแก้ไขปัญหาดังกล่าวที่เกิดจากรูปแบบประเภทนี้ในข้อมูลได้ นอกจากนี้แบบจำลอง ARCH ยังทำงานได้ดีที่สุดกับข้อมูลความถี่สูง (รายชั่วโมง รายวัน รายเดือน รายไตรมาส) ดังนั้นจึงเหมาะสำหรับข้อมูลทางการเงินด้วยเหตุนี้ แบบจำลอง ARCH จึงกลายเป็นแกนหลักสำหรับการสร้างแบบจำลองทางการเงินที่มีความผันผวนสูง

ต่อมา Bollerslev (1986) ได้เสนอแบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH) ซึ่งพัฒนามาจาก ARCH แต่มีการลดจำนวนค่าพารามิเตอร์ลง เป็นหนึ่งในแบบจำลองที่เป็นที่รู้จัก และมีการใช้อย่างแพร่หลายในการพยากรณ์ความผันผวนของราคาหลักทรัพย์ทางการเงิน และต่อมาแบบจำลอง GARCH ยังได้มีการประยุกต์ไปในอีกหลายรูปแบบ

2.3.1 GARCH (Generalized Autoregressive Conditional Heteroscedasticity)

แบบจำลอง GARCH เป็นแบบจำลองที่ใช้ในการพยากรณ์ความผันผวนในข้อมูลที่มีการเปลี่ยนแปลงตลอดเวลา โครงสร้างของแบบจำลอง GARCH ประกอบด้วย 2 ส่วนหลัก คือ ส่วนของแบบจำลอง AR (Autoregressive) และส่วนของแบบจำลอง MA (Moving Average) โดยมีตัวแปร p และ q ที่เป็นพารามิเตอร์ที่กำหนดระดับของ AR และ MA ตามลำดับ โดยส่วนของแบบจำลอง AR เป็นส่วนที่พิจารณาค่าในช่วงเวลาก่อนหน้าเพื่อทำนายค่าในช่วงเวลาถัดไป จำนวนของค่าที่พิจารณาในช่วงเวลาก่อนหน้าจะกำหนดโดยพารามิเตอร์ p ซึ่งเป็นพารามิเตอร์ที่กำหนดจำนวนค่าที่ใช้ในการพิจารณา โดยสมการของ AR มีรูปแบบดังสมการที่ 2.1

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t \quad (2.1)$$

โดย	y_t	คือ ค่าในช่วงเวลา t
	c	คือ ค่าคงที่ (Constant Term)
	ϕ_i	คือ พารามิเตอร์ของแบบจำลอง AR
	p	คือ จำนวนค่าก่อนหน้าที่จะพิจารณา
	ε_t	คือ ค่าความคลาดเคลื่อนในช่วงเวลา t

ในส่วนของแบบจำลอง MA ส่วนนี้เป็นส่วนที่ใช้ค่าความผิดพลาดจากช่วงเวลาก่อนหน้าเพื่อลดความผันผวนในข้อมูล และทำนายค่าของข้อมูลในช่วงเวลาถัดไป จำนวนของค่าความผิดพลาดที่ใช้ในการคำนวณในช่วงเวลาก่อนหน้าจะกำหนดโดยพารามิเตอร์ q ซึ่งเป็นพารามิเตอร์ที่กำหนดจำนวนของค่าที่ใช้ในการคำนวณ โดยสมการของ MA มีรูปแบบดังสมการที่ 2.2

$$y_t = \mu + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (2.2)$$

โดย	y_t	คือ ค่าในช่วงเวลา t
	μ	คือ ค่าเฉลี่ยของข้อมูล
	θ_j	คือ พารามิเตอร์ของแบบจำลอง MA
	q	คือ จำนวนของค่าความผิดพลาดจากช่วงเวลาก่อนหน้า
	ε_t	คือ ค่าความคลาดเคลื่อนในช่วงเวลา t

การรวมส่วนของ AR และ MA เข้าด้วยกันในแบบจำลอง GARCH ช่วยเพิ่มความยืดหยุ่น และความสามารถในการจัดการกับความผันผวนในช่วงเวลาที่มีการเปลี่ยนแปลงได้ดีขึ้น โดยในส่วนของ AR ใช้ข้อมูลในช่วงเวลาก่อนหน้าเพื่อทำนายค่าในช่วงเวลาถัดไป ซึ่งส่วนนี้ช่วยให้โมเดลสามารถจำลองความเปลี่ยนแปลงในค่าข้อมูลในช่วงเวลาต่อเนื่องได้ดี ในขณะที่ส่วนของ MA ใช้ค่าความผิดพลาดจากช่วงเวลาก่อนหน้าเพื่อลดความผันผวนในข้อมูล และทำนายค่าของข้อมูลในช่วงเวลาถัดไปอย่างมีประสิทธิภาพ โดยสมการของ GARCH มีรูปแบบดังสมการที่ 2.3

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2.3)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- โดย σ_t^2 คือ ค่าความผันผวนในช่วงเวลา t
 ω คือ ค่าคงที่ (Constant Term)
 α_i, β_j คือ พารามิเตอร์ของแบบจำลอง GARCH
 ε_{t-i}^2 คือ ค่าความคลาดเคลื่อนในช่วงเวลา t - i

2.3.2 GJR-GARCH (Glosten-Jagannathan-Runkle GARCH)

แบบจำลอง GJR-GARCH ถูกพัฒนาโดย Glosten, Jagannathan และ Runkle (1993) เป็นแบบจำลองที่พัฒนาขึ้นจากแบบจำลอง GARCH โดยเพิ่มการพิจารณาผลกระทบของ Asymmetric shocks ส่วนสำคัญที่เพิ่มเข้ามาคือ Indicator function ที่ช่วยแยกแยะระหว่างแรงกระทบที่เป็นบวกและเป็นลบ โดยสมการของ GJR-GARCH มีรูปแบบดังสมการที่ 2.4

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \gamma I_{t-1} \varepsilon_{t-1}^2 \quad (2.4)$$

- โดย σ_t^2 คือ ค่าความผันผวนในช่วงเวลา t
 ω คือ ค่าคงที่ (Constant Term)
 α_i, β_j คือ พารามิเตอร์ของแบบจำลอง GARCH
 γ คือ พารามิเตอร์ที่แสดงผลกระทบของข่าวร้าย
 I_{t-1} คือ Indicator function ที่มีค่าเป็น 1 เมื่อ $\varepsilon_{t-1} < 0$ (ข่าวร้าย) และเป็น 0 เมื่อ $\varepsilon_{t-1} \geq 0$ (ข่าวดี)
 ε_{t-i}^2 คือ ค่าความคลาดเคลื่อนในช่วงเวลา t - i

2.3.3 TARCh (Threshold GARCH)

แบบจำลอง TARCh ถูกพัฒนาโดย Zakoian (1994) เป็นแบบจำลองที่ปรับปรุงจากแบบจำลอง GJR-GARCH เพื่อเพิ่มความยืดหยุ่นในการจัดการกับ Asymmetric shocks ต่อความผันผวนของข้อมูล โดยมีการกำหนดจำนวนของค่า lags ที่จะถูกใช้ใน Indicator function ซึ่งถูกกำหนดโดยพารามิเตอร์ γ โดยสมการของ TARCh มีรูปแบบดังสมการที่ 2.5

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \sum_{k=1}^o \gamma_k I_{t-k} \varepsilon_{t-k}^2 \quad (2.5)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดย	σ_t^2	คือ ค่าความผันผวนในช่วงเวลา t
	ω	คือ ค่าคงที่ (Constant Term)
	α_i, β_j	คือ พารามิเตอร์ของแบบจำลอง GARCH
	γ_k	คือ พารามิเตอร์ที่แสดงผลกระทบของข่าวร้าย
	I_{t-k}	คือ Indicator function ที่มีค่าเป็น 1 เมื่อ $\varepsilon_{t-k} < 0$ (ข่าวร้าย) และเป็น 0 เมื่อ $\varepsilon_{t-k} \geq 0$ (ข่าวดี)
	ε_{t-i}^2	คือ ค่าความคลาดเคลื่อนในช่วงเวลา t - i

2.4 การทดสอบความนิ่งของข้อมูล (Unit Root Test)

การทดสอบความนิ่งของข้อมูลอนุกรมเวลา (Time Series Data) เป็นขั้นตอนสำคัญในการวิเคราะห์ข้อมูลทางสถิติ เพื่อให้แน่ใจว่าข้อมูลมีลักษณะนิ่ง (Stationary) ซึ่งเป็นเงื่อนไขพื้นฐานในการสร้างแบบจำลองอนุกรมเวลา เช่น แบบจำลองในกลุ่ม GARCH การทดสอบความนิ่งสามารถทำได้โดยใช้ Augmented Dickey-Fuller test (ADF Test) โดยมีรูปแบบดังสมการที่ 2.6

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-i} + \varepsilon_t \quad (2.6)$$

โดย	Δy_t	คือ การเปลี่ยนแปลงของ y_t
	α	คือ ค่าคงที่ (Constant Term)
	β	คือ สัมประสิทธิ์ของตัวแปรแนวโน้มเชิงเส้น
	t	คือ ตัวแปรเวลา
	γ	คือ สัมประสิทธิ์ของ y_{t-1}
	δ_i	คือ สัมประสิทธิ์ของค่าที่ล่าช้า Δy_{t-i}
	ε_t	คือ ค่าความคลาดเคลื่อนในช่วงเวลา t

ในการทดสอบ ADF-test เราจะดูค่าสัมประสิทธิ์ γ ของ y_{t-1} หาก γ มีค่าน้อยกว่า 0 จะปฏิเสธ H_0 ซึ่งแสดงว่าเป็นข้อมูลที่นิ่ง (Stationary)

2.5 การประเมินและเปรียบเทียบประสิทธิภาพของโมเดล

เกณฑ์ที่นิยมใช้ในการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลองมีทั้งหมด 2 เกณฑ์ ได้แก่ รากที่สองของเปอร์เซ็นต์ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE) และรากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) โดยแต่ละเกณฑ์จะมีสูตร และวิธีการวัดค่าความผิดพลาดคลาดเคลื่อนระหว่างค่าจริงและค่าพยากรณ์ที่แตกต่างกันไป โดยสมการของ RMSPE และ RMSE มีรูปแบบดังสมการที่ 2.7 และ 2.8 ตามลำดับ

2.5.1 รากที่สองของเปอร์เซ็นต์ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE)

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{Y_i - \hat{Y}_i}{Y_i} \right)^2} \quad (2.7)$$

2.5.2 รากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (2.8)$$

2.6 Schwarz's Bayesian Information Criteria (BIC)

เกณฑ์สารสนเทศของเบส์ (Bayesian Information Criteria: BIC) ถูกนำเสนอโดย Gideon E. Schwarz (1978) เป็นเครื่องมือในการคัดเลือกโมเดลทางสถิติที่ใช้เพื่อเปรียบเทียบ และคัดเลือกโมเดลที่เหมาะสมที่สุดจากชุดของโมเดลทางสถิติที่มีอยู่ มีรูปแบบดังสมการที่ 2.9

$$BIC = -2\ln(\hat{L}) + k \cdot \ln(n) \quad (2.9)$$

โดย	\hat{L}	คือ ค่าความน่าจะเป็นสูงสุดของโมเดล (Maximum Likelihood)
	k	คือ จำนวนพารามิเตอร์ในโมเดล
	n	คือ จำนวนข้อมูลทั้งหมด

2.7 งานวิจัยที่เกี่ยวข้อง

สุนันท์ใจ และกัญญาสุตา (2563) ได้ทำการศึกษาแบบจำลองความผันผวนที่เหมาะสมกับอัตราผลตอบแทนของกองทุนหุ้นจีน และพยากรณ์ความผันผวนของอัตราผลตอบแทนของกองทุนหุ้นจีน โดยศึกษาปัจจัยสภาพแวดล้อมทางเศรษฐกิจมหภาค โดยใช้แบบจำลอง GARCH ในการประมาณค่าแบบจำลองความผันผวน เมื่อทำการประมาณค่าแบบจำลองความผันผวนของกองทุนหุ้นจีนทั้งสอง เมื่อทำการเปรียบเทียบค่า Akaike info criterion (AIC) และ Schwarz criterion (SC) ของแต่ละแบบจำลอง พบว่าแบบจำลอง GARCH(1, 1) มีความเหมาะสมสำหรับกองทุนหุ้นจีนยิ่งยั้งมากที่สุด และเมื่อนำไปพยากรณ์ โดยจะทำการพยากรณ์ความผันผวนของผลตอบแทนล่วงหน้าทีละหนึ่งวัน เป็นจำนวน 5 วัน พบว่า ความผันผวนอัตราผลตอบแทนมีแนวโน้มลดลง

Katsiampa (2017) ได้ทำการศึกษาพบว่า Bitcoin มีความผันผวนสูงมากเมื่อเทียบกับสกุลเงินและศึกษาประสิทธิภาพของแบบจำลอง GARCH ชนิดต่าง ๆ ได้แก่ GARCH, EGARCH, TGARCH, APARCH, CGARCH และ ACGARCH โดยพิจารณาจากค่า AIC, BIC และ HQ เพื่อเลือกแบบจำลองที่เหมาะสมที่สุด สำหรับการอธิบายความผันผวนของ Bitcoin ซึ่งได้ว่าแบบจำลอง ACGARCH เป็นแบบจำลองที่มีความเหมาะสมในการศึกษาความผันผวนของ Bitcoin

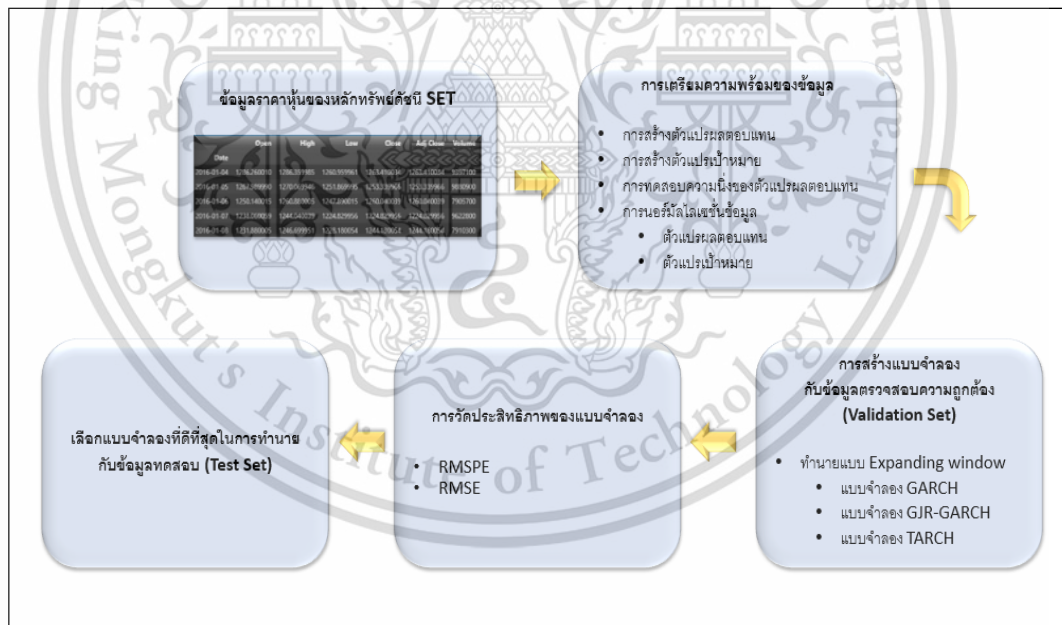
ศุภกาญจน์ และศิริขวัญ (2562) ได้ทำการศึกษาความผันผวนของอัตราผลตอบแทนของตลาดหลักทรัพย์โดยใช้แบบจำลอง GARCH ผลการศึกษาพบว่า ความผันผวนแบบมีเงื่อนไขของอัตราผลตอบแทนของตลาดหลักทรัพย์ใน 4 ประเทศ ได้แก่ ไทย ญี่ปุ่น อังกฤษ และสหรัฐอเมริกา นั้นขึ้นอยู่กับค่าความคลาดเคลื่อนและค่าความผันผวนแบบมีเงื่อนไขในอดีตอย่างมีนัยสำคัญทางสถิติ และจากการทดสอบคุณภาพพระยะยาว พบว่าในประเทศไทยมีความสัมพันธ์เชิงคุณภาพในระยะยาวกับทุกประเทศ ได้แก่ สหรัฐอเมริกา อังกฤษและญี่ปุ่น

Naimy and Hayek (2018) ได้ทำการศึกษาความผันผวนของอัตราแลกเปลี่ยน Bitcoin โดยใช้แบบจำลองประเมิน และได้เปรียบเทียบความสามารถในการทำนายของแบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH) (1, 1), Exponentially Weighted Moving Average (EWMA) และ Exponential GARCH (EGARCH) (1, 1) ซึ่งพบว่า แบบจำลองของ EGARCH(1, 1) มีประสิทธิภาพดีกว่า GARCH(1, 1) และ EWMA

บทที่ 3

วิธีการดำเนินงานวิจัย

วัตถุประสงค์ของงานวิจัยนี้คือการพยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า โดยจะทำการเปรียบเทียบประสิทธิภาพการพยากรณ์แบบจำลองในกลุ่ม GARCH ได้แก่ แบบจำลอง GARCH แบบจำลอง GJR-GARCH และแบบจำลอง TARCH เพื่อเลือกใช้แบบจำลองที่ให้ค่าความผิดพลาดคลาดเคลื่อนต่ำที่สุด โดยพิจารณาจากค่ารากที่สองของเปอร์เซ็นต์ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE) เป็นตัวหลัก พร้อมทั้งพิจารณาค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) เป็นตัวประกอบการตัดสินใจ โดยในบทนี้จะเป็นการนำเสนอในส่วนของกรอบแนวคิดงานวิจัย วิธีดำเนินงานวิจัย และเครื่องมือที่ใช้สำหรับการวิจัยตามลำดับ ซึ่งประกอบไปด้วยข้อมูล และแหล่งที่มาของข้อมูล กระบวนการวิจัย การเปรียบเทียบประสิทธิภาพ เครื่องมือที่ใช้ในการวิจัย สามารถเขียนเป็นขั้นตอนได้ดังรูปที่ 3.1



รูปที่ 3.1 ขั้นตอนวิธีการวิจัยการพยากรณ์ความผันผวนของ SET

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1 ข้อมูลและแหล่งที่มาของข้อมูล

ในการรวบรวมข้อมูลงานวิจัยครั้งนี้ ผู้วิจัยได้นำข้อมูลราคาหุ้นของหลักทรัพย์ดัชนี SET จาก Yahoo Finance ระหว่างวันที่ 1 มกราคม 2559 ถึงวันที่ 31 ธันวาคม 2566 จากนั้นตรวจสอบความสมบูรณ์ของข้อมูลที่จะใช้ หากมีข้อมูลไม่ถูกต้องจะต้องจัดการก่อนที่จะเข้าสู่ขั้นตอนต่อไป นอกจากนี้ที่กล่าวมาแล้ว การทำความเข้าใจข้อมูลก็เป็นสิ่งที่สำคัญ เช่น การสร้างกราฟเส้นของราคาปิดรายวันของหลักทรัพย์ดัชนี SET การดูรูปแบบการกระจายตัวของตัวแปรต่าง ๆ ที่เกี่ยวข้อง ฯลฯ เพื่อให้เกิดความคุ้นเคยกับข้อมูลมากยิ่งขึ้น

3.2 การเตรียมความพร้อมของข้อมูล

3.2.1 การสร้างตัวแปรผลตอบแทน

ความผันผวนของหลักทรัพย์ใด ๆ คือการเปลี่ยนแปลงของผลตอบแทนของหลักทรัพย์นั้น ดังนั้น ในการสร้างแบบจำลองพยากรณ์ความผันผวนราคาหลักทรัพย์ดัชนี SET จึงทำการกำหนดตัวแปรผลตอบแทนจากหลักทรัพย์ดัชนี SET (Return of SET Index) เป็นตัวแปรที่จะใช้ในการสร้างแบบจำลองพยากรณ์ความผันผวนในการศึกษาครั้งนี้ สามารถเขียนได้ดังรูปที่ 3.2

```
# CALCULATE PRICE RETURNS AS DAILY PERCENTAGE CHANGE
df['returns'] = 100 * df.Close.pct_change().dropna()
```

รูปที่ 3.2 การสร้างตัวแปรผลตอบแทน ด้วยโปรแกรมไพธอน

3.2.2 การสร้างตัวแปรเป้าหมาย

ในงานวิจัยนี้มีวัตถุประสงค์ คือการพยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า จึงทำการสร้างตัวแปรเป้าหมายโดยใช้ตัวแปรผลตอบแทนจากหลักทรัพย์ดัชนี SET (Return of SET Index) คำนวณความผันผวนที่เกิดขึ้นรายวันโดยใช้กรอบช่วงเวลา 30 วัน คำสั่งที่ใช้ในการคำนวณความผันผวนรายวันสามารถเขียนได้ดังรูปที่ 3.3 จากนั้นเปลี่ยนความผันผวนในปัจจุบันย้อนหลังไป 7 วัน สามารถเขียนได้ดังรูปที่ 3.4

```
# CREATE A FUNCTION THAT CALCULATE REALIZED VOLATILITY
def realized_volatility_daily(return):
    n = len(return)
    return np.sqrt(np.sum(return**2)/(n - 1))
```

รูปที่ 3.3 การคำนวณความผันผวนรายวัน ด้วยโปรแกรมไพธอน

```
interval_window = 30
n_future = 7
# GET FORWARD LOOKING REALIZED VOLATILITY
df['vol_future'] = df.returns.shift(-n_future)\
    .rolling(window=interval_window)\
    .apply(realized_volatility_daily)
```

รูปที่ 3.4 การสร้างตัวแปรเป้าหมาย ด้วยโปรแกรมไพธอน

3.2.3 การทดสอบความนิ่งของตัวแปรผลตอบแทน

เนื่องจากแบบจำลองในกลุ่ม GARCH มีสมมติฐานในเรื่องตัวแปร โดยจะต้องเป็นตัวแปรที่มีความนิ่ง (Stationarity) เท่านั้น ที่จะสามารถนำมาใช้สร้างตัวแบบได้ ดังนั้น ในขั้นตอนนี้จึงทำการทดสอบความนิ่งของตัวแปรที่ได้กำหนดไว้ นั่นคือ ผลตอบแทนจากหลักทรัพย์ดัชนี SET โดยใช้การทดสอบ ADF Test ซึ่งพบว่าตัวแปรผลตอบแทนจากหลักทรัพย์ดัชนี SET เป็นตัวแปรที่มีความนิ่งเหมาะสมแก่การใช้เป็นตัวแปรในการสร้างแบบจำลองในกลุ่ม GARCH สามารถเขียนได้ดังรูปที่ 3.5

```
# ADF Test
adfuller_results = adfuller(df.returns.dropna())
print(f'ADF Statistic: {adfuller_results[0]}')
print(f'p-value: {adfuller_results[1]}')
Output: ADF Statistic: -10.602444524717127
p-value: 6.121741604490924e-19
```

รูปที่ 3.5 การทดสอบความนิ่งของตัวแปรผลตอบแทนโดยการใช้ ADF Test

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่หรือใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.4 การนอร์มัลไลเซชันข้อมูล

การนอร์มัลไลเซชันข้อมูล เป็นการทำให้ข้อมูลให้อยู่ในรูปแบบเดียวกันเพื่อให้มีความเป็นมาตรฐาน และสามารถนำข้อมูลไปใช้ได้อย่างมีประสิทธิภาพ โดยวิธีที่ใช้ในงานวิจัยนี้คือ การทำให้เป็นบรรทัดฐานด้วยค่าต่ำสุดและสูงสุด (Min-max normalization) วิธีนี้เป็นวิธีที่นิยมใช้เพื่อทำข้อมูลให้เป็นมาตรฐาน โดยที่ค่าต่ำสุดจะถูกแปลงให้มีค่าเป็น 0 และค่าสูงสุดจะถูกแปลงให้มีค่าเป็น 1 และค่าอื่น ๆ จะถูกแปลงเป็นค่าที่อยู่ระหว่าง 0 ถึง 1 โดยกระบวนการนอร์มัลไลเซชันของตัวแปรผลตอบแทน สามารถเขียนได้ดังรูปที่ 3.6 และการนอร์มัลไลเซชันของตัวแปรเป้าหมาย สามารถเขียนได้ดังรูปที่ 3.7

```
# INITIATE SCALER
scaler_vol = MinMaxScaler()
# FIT SCALER TO RETURNS VARIABLE
df['returns'] = scaler_vol.fit(df['returns'].values.reshape(-1,1))
```

รูปที่ 3.6 การนอร์มัลไลเซชันของตัวแปรผลตอบแทน ด้วยโปรแกรมไพธอน

```
# INITIATE SCALER
scaler_vol = MinMaxScaler()
# FIT SCALER TO TARGET VARIABLE
df['vol_future'] = scaler_vol.fit(df['vol_future'].values.reshape(-1,1))
```

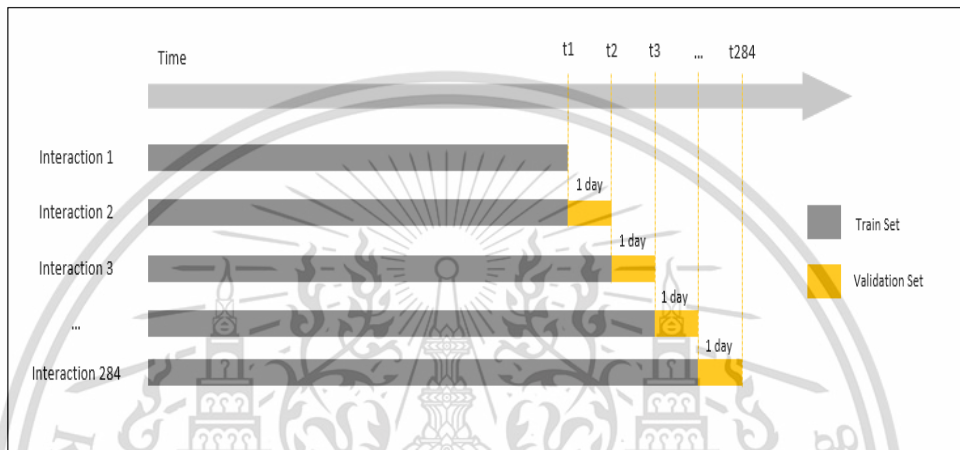
รูปที่ 3.7 การนอร์มัลไลเซชันของตัวแปรเป้าหมาย ด้วยโปรแกรมไพธอน

3.3 การสร้างแบบจำลองพยากรณ์ความผันผวน

ข้อมูลที่ใช้ในงานวิจัยนี้มีทั้งหมด 1,897 วัน โดยตัวแปรที่ใช้ในการสร้างแบบจำลองพยากรณ์ความผันผวนคือ ตัวแปรผลตอบแทนจากหลักทรัพย์ดัชนี SET (Return of SET Index) จากนั้นแบ่งข้อมูลออกเป็น 3 ส่วน (70:15:15) คือ ชุดข้อมูลฝึกสอน (Train Set) จำนวน 1,329 วัน ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Set) จำนวน 284 วัน และชุดข้อมูลทดสอบ (Test Set) จำนวน 284 วัน ในงานวิจัยนี้ได้ทำการฝึกสอนแบบจำลองในกลุ่ม GARCH ได้แก่ แบบจำลอง GARCH

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบบจำลอง GJR-GARCH และแบบจำลอง TARARCH โดยใช้วิธีการทำนายแบบ Expanding window เพื่อทำการพยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า ซึ่งเป็นวิธีการประเมินแบบจำลองสำหรับการทำนายข้อมูลอนุกรมเวลา (Time Series Data) โดยจะใช้ชุดข้อมูลฝึกสอน (Train Set) ในการฝึกสอนครั้งแรก จากนั้นจะค่อย ๆ เพิ่มข้อมูลตรวจสอบความถูกต้อง (Validation Set) ทีละ 1 วัน ในการฝึกสอนครั้งต่อ ๆ ไปจนหมด สามารถเขียนได้ดังรูปที่ 3.8 และสำหรับวิธีการคำนวณความผันผวนเฉลี่ยรายวัน สามารถเขียนได้ดังรูปที่ 3.9



รูปที่ 3.8 วิธีการฝึกสอนสำหรับการทำนายแบบ Expanding window

```
# DAILY VOLATILITY
pred = np.sqrt(np.mean(vaR))
```

รูปที่ 3.9 การคำนวณความผันผวนเฉลี่ยรายวัน ด้วยโปรแกรมไพธอน

จากนั้น จะทำการหาค่าพารามิเตอร์ที่ดีที่สุดของแต่ละแบบจำลองเพื่อให้ได้ผลการพยากรณ์ที่แม่นยำที่สุด ซึ่งสามารถทำได้โดยการวนลูปตรวจสอบค่าพารามิเตอร์ต่าง ๆ และเปรียบเทียบค่า RMSPE ของแต่ละแบบจำลองกับค่าจริงของตัวแปรเป้าหมาย พร้อมทั้งพิจารณาค่า RMSE เป็นตัวประกอบการตัดสินใจ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.1 การสร้างแบบจำลอง GARCH

ค่าพารามิเตอร์ของแบบจำลอง GARCH ที่ทำการตรวจสอบ คือ พารามิเตอร์ p และ พารามิเตอร์ q เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนายกับค่าจริงของตัวแปรเป้าหมาย ซึ่งมีตัวอย่างการสร้างแบบจำลอง GARCH ดังรูปที่ 3.10

```
# HYPERPARAMETER TUNING FOR GARCH MODEL
for p, q in pq_s:
    t_garch_pq = arch_model(r_train, vol='GARCH', p=p, q=q)
    t_garch_pq_fit = t_garch_pq.fit(dispatch='off')
    # CONDITIONAL VOLATILITY OUTPUTS
    cond_vol_arr = t_garch_pq_fit.conditional_volatility.values
    rolling_forecasts = []

    # ITERATE OVER EACH TIME STEP IN THE VALIDATION SET
    for i in range(284):
        idx = val_idx[i]
        train = df.returns[idx].dropna()
        # TRAIN MODEL USING ALL PREVIOUS TIME STEPS' DATA
        model = arch_model(train, vol='GARCH', p=p, q=q)
        model_fit = model.fit(dispatch='off')
        # MAKE PREDICTION 7 DAYS OUT
        vaR = model_fit.forecast(horizon=7, reindex=False,
                                method='bootstrap').variance.values
        pred = np.sqrt(np.mean(vaR))
```

รูปที่ 3.10 การสร้างแบบจำลอง GARCH

3.3.2 การสร้างแบบจำลอง GJR-GARCH

ค่าพารามิเตอร์ของแบบจำลอง GJR-GARCH ที่ทำการตรวจสอบ คือ พารามิเตอร์ p และพารามิเตอร์ q เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนายกับค่าจริงของตัวแปรเป้าหมาย ซึ่งมีตัวอย่างการสร้างแบบจำลอง GJR-GARCH ดังรูปที่ 3.11

```
# HYPERPARAMETER TUNING FOR GJR-GARCH MODEL
for p, q in pq_s:
    t_gjr_pq = arch_model(r_train, p=p, q=q, o=1,
                          vol='GARCH', dist='skewt')
    t_gjr_pq_fit = t_gjr_pq.fit(dispatch='off')
    # CONDITIONAL VOLATILITY OUTPUTS
    cond_vol_arr = t_gjr_pq_fit.conditional_volatility.values
    rolling_forecasts = []

    # ITERATE OVER EACH TIME STEP IN THE VALIDATION SET
    for i in range(284):
        idx = val_idx[i]
        train = df.returns[idx].dropna()
        # TRAIN MODEL USING ALL PREVIOUS TIME STEPS' DATA
        model = arch_model(train, p=p, q=q, o=1,
                          vol='GARCH', dist='skewt')
        model_fit = model.fit(dispatch='off')
        # MAKE PREDICTION 7 DAYS OUT
        vaR = model_fit.forecast(horizon=7, reindex=False,
                                method='bootstrap').variance.values
        pred = np.sqrt(np.mean(vaR))
```

รูปที่ 3.11 การสร้างแบบจำลอง GJR-GARCH

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.3 การสร้างแบบจำลอง TARCH

ค่าพารามิเตอร์ของแบบจำลอง TARCH ที่ทำการตรวจสอบ คือ พารามิเตอร์ p พารามิเตอร์ q และพารามิเตอร์ o เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนายกับค่าจริงของตัวแปรเป้าหมาย ซึ่งมีตัวอย่างการสร้างแบบจำลอง TARCH ดังรูปที่ 3.12

```
# HYPERPARAMETER TUNING FOR TARCH MODEL
for p, q, o in pqo_s:
    t_tarch_pqo = arch_model(r_train, p=p, q=q, o=o,
                             power=1.0, dist='skewt')
    t_tarch_pqo_fit = t_tarch_pqo.fit(dispatch='off')
    # CONDITIONAL VOLATILITY OUTPUTS
    cond_vol_arr = t_tarch_pqo_fit.conditional_volatility.values
    rolling_forecasts = []

    # ITERATE OVER EACH TIME STEP IN THE VALIDATION SET
    for i in range(284):
        idx = val_idx[i]
        train = df.returns[idx].dropna()
        # TRAIN MODEL USING ALL PREVIOUS TIME STEPS' DATA
        model = arch_model(train, p=p, q=q, o=o,
                           power=1.0, dist='skewt')
        model_fit = model.fit(dispatch='off')
        # MAKE PREDICTION 7 DAYS OUT
        vaR = model_fit.forecast(horizon=7, reindex=False,
                                method='bootstrap').variance.values
        pred = np.sqrt(np.mean(vaR))
```

รูปที่ 3.12 การสร้างแบบจำลอง TARCH

จากนั้น ทดสอบประสิทธิภาพของแต่ละแบบจำลอง ด้วยการคำนวณค่า RMSPE เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนาย โดยจะเลือกแบบจำลองที่มีค่า RMSPE ต่ำที่สุด พร้อมทั้งพิจารณาค่า RMSE เป็นตัวประกอบการตัดสินใจ ในผลการวิจัยครั้งนี้ พบว่า แบบจำลอง TARCh เป็นแบบจำลองที่มีค่า RMSPE ต่ำที่สุด โดยค่า RMSPE ของแบบจำลอง TARCh เท่ากับ 0.1927 ดังนั้น แบบจำลอง TARCh ถูกเลือกเป็นแบบจำลองที่เหมาะสมที่สุดสำหรับการทำนายกับข้อมูลในชุดข้อมูลทดสอบ (Test Set) เนื่องจากมีความคลาดเคลื่อนในการทำนายน้อยที่สุดเมื่อเทียบกับแบบจำลองอื่น ๆ โดยค่า RMSPE ของแบบจำลอง TARCh สำหรับการทำนายกับข้อมูลในชุดข้อมูลทดสอบ (Test Set) เท่ากับ 0.1876

3.4 การวัดประสิทธิภาพของแบบจำลอง

ในงานวิจัยนี้มุ่งเน้นการวัดประสิทธิภาพของแบบจำลองเพื่อหาแบบจำลองที่เหมาะสมที่สุด โดยเป้าหมายคือ การทำให้แบบจำลองมีค่าความคลาดเคลื่อนในการทำนายต่ำที่สุด การประเมินประสิทธิภาพของแบบจำลองจะใช้ทั้งหมด 2 เกณฑ์ ได้แก่ รากที่สองของเปอร์เซ็นต์ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSPE) สามารถเขียนได้ดังรูปที่ 3.13 และรากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) สามารถเขียนได้ดังรูปที่ 3.14

```
# DEFINE ROOT MEAN SQUARED PERCENTAGE ERROR FUNCTION
def RMSPE(y_true, y_pred):
    output = np.sqrt(np.mean(np.square((y_true - y_pred)/y_true)))
    return output
```

รูปที่ 3.13 การคำนวณค่า RMSPE ด้วยโปรแกรมไพธอน

```
# DEFINE ROOT MEAN SQUARED ERROR FUNCTION
def RMSE(y_true, y_pred):
    output = np.sqrt(mse(y_true, y_pred))
    return output
```

รูปที่ 3.14 การคำนวณค่า RMSE ด้วยโปรแกรมไพธอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5 เครื่องมือที่ใช้ในการทดลอง





3.5.1 ฮาร์ดแวร์

รายละเอียดคอมพิวเตอร์ที่ทำการประมวลผลแบบจำลองในกลุ่ม GARCH มีดังนี้
Intel(R) Core(TM) i5-1135G7 Ram 16 GB

3.5.2 ซอฟต์แวร์

ในงานวิจัยนี้ตัดสินใจใช้ VS Code (Visual Studio Code) เป็นเครื่องมือที่ได้รับ
ความนิยมสำหรับการเขียนโปรแกรมหลายภาษา โดยเฉพาะ Python ที่สามารถติดตั้งไลบรารี
(Library) สำหรับการทำโมเดลต่าง ๆ ได้

ไลบรารี (Library) เปรียบเสมือนโปรแกรมสำเร็จรูปที่เก็บฟังก์ชันการทำงานที่
เฉพาะทาง ประโยชน์ของไลบรารีสำเร็จรูปที่มากับโปรแกรมก็คือ ผู้ใช้งานไม่จำเป็นต้องสร้าง
ไลบรารีขึ้นมาใหม่เองทั้งหมด แต่สามารถนำไลบรารีที่ได้มีการพัฒนาไว้อยู่แล้วมาใช้งานได้เลย ตาม
ตารางที่ 3.1

Python library	Function
	ใช้ในการดึงข้อมูลราคาหุ้นจาก Yahoo Finance
	ใช้ในการดำเนินการกับข้อมูลแบบตาราง หรือข้อมูลในรูปแบบ DataFrame
	ใช้ในการแสดงผลรูปแบบกราฟต่าง ๆ
	ใช้ในการทำแบบจำลองในกลุ่ม GARCH

ตารางที่ 3.1 ไลบรารี (Library) ที่ใช้ในงานวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

ผลการวิจัยและการอภิปรายผล


จากการศึกษาวิจัยเพื่อค้นหาแบบจำลองที่เหมาะสมในการพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย ผู้วิจัยใช้ข้อมูลราคาหุ้นของหลักทรัพย์ดัชนี SET จาก Yahoo Finance ระหว่างวันที่ 1 มกราคม 2559 ถึงวันที่ 31 ธันวาคม 2566 โดยมีจำนวนข้อมูลรวมทั้งสิ้น 1,934 ข้อมูล

4.1 ผลการสำรวจเบื้องต้น

หลังจากการเตรียมความพร้อมของข้อมูลด้วยขั้นตอนการตรวจสอบความสมบูรณ์ของข้อมูลที่จะใช้เสร็จสิ้นแล้วจะเริ่มทำการทดลองตามขั้นตอนต่าง ๆ โดยเริ่มจากการวิเคราะห์ตัวแปรเบื้องต้น การวิเคราะห์ตัวแปรผลตอบแทน การทดสอบความนิ่งของตัวแปรผลตอบแทน การนอร์มัลไลเซชันของตัวแปรผลตอบแทนกับตัวแปรเป้าหมาย และท้ายสุดจะเป็นการประมวลผลของแบบจำลอง

4.1.1 การวิเคราะห์ตัวแปรเบื้องต้น


ข้อมูลราคาหุ้นของหลักทรัพย์ดัชนี SET จาก Yahoo Finance ประกอบไปด้วย ข้อมูลราคาเปิด (Open) ราคาสูงสุด (High) ราคาต่ำสุด (Low) ราคาปิด (Close) ราคาปิดที่ถูกปรับแล้ว (Adjusted close) และปริมาณการซื้อขายของหุ้น (Volume) โดยรูปที่ 4.1 จะเป็นกราฟแสดงราคาปิดของหลักทรัพย์ดัชนี SET ในช่วงระยะเวลาที่ทำการศึกษา จากกราฟจะเห็นได้ว่าราคาปิดของหลักทรัพย์ดัชนี SET มีความผันผวนที่สูงตามช่วงเวลาโดยเฉพาะในช่วงต้นปี 2020 ที่ราคาลดลงอย่างมากจากการระบาดของ COVID-19 หลังจากนั้นราคาฟื้นตัวอย่างรวดเร็วในปี 2021 แต่ยังคงมีความผันผวนสูง ตลอดช่วงปี 2022-2023 ราคายังคงมีความผันผวนสูง และลดลงอีกครั้งในช่วงปลายปี 2023 สะท้อนถึงปัจจัยทางเศรษฐกิจ และเหตุการณ์ต่าง ๆ ที่มีผลกระทบต่อตลาดโดยรวม การวิเคราะห์เบื้องต้นนี้ช่วยให้ผู้วิจัยเข้าใจลักษณะและแนวโน้มของข้อมูลพื้นฐานในตลาดหุ้นไทย



รูปที่ 4.1 กราฟแสดงราคาปิดของหลักทรัพย์ดัชนี SET

4.1.2 การวิเคราะห์ตัวแปรผลตอบแทน

ในการวิเคราะห์และสร้างโมเดลในการพยากรณ์ค่าความผันผวนของผลตอบแทนในตลาดหลักทรัพย์แห่งประเทศไทย (SET) ตัวแปรที่มีความสำคัญมาก ได้แก่ ตัวแปรผลตอบแทน (Returns) โดยคำนวณจากการเปลี่ยนแปลงของราคาปิดระหว่างวัน โดยรูปที่ 4.2 จะเป็นกราฟแสดงผลตอบแทน พบว่ามีความผันผวนที่เกิดขึ้นในแต่ละช่วงเวลา โดยเฉพาะในช่วงปี 2020 มีความผันผวนสูงมาก ซึ่งสอดคล้องกับเหตุการณ์การระบาดของ COVID-19



รูปที่ 4.2 กราฟแสดงผลตอบแทนของหลักทรัพย์ดัชนี SET

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1.3 การทดสอบความนิ่งของตัวแปรผลตอบแทน

งานวิจัยนี้ได้ทำการทดสอบความนิ่งของตัวแปร (Stationarity) ได้แก่ ตัวแปรผลตอบแทน (Returns) โดยใช้การทดสอบ ADF Test ซึ่งเป็นสิ่งสำคัญสำหรับการวิเคราะห์ทางสถิติ และการสร้างแบบจำลองในข้อมูลเชิงเวลา

ทดสอบด้วยสถิติ ADF Test โดยตั้งสมมติฐานทางสถิติดังนี้


H_0 : ตัวแปรผลตอบแทน เป็นข้อมูลที่ไม่นิ่ง (Non-Stationary)

H_1 : ตัวแปรผลตอบแทน เป็นข้อมูลที่นิ่ง (Stationary)

โดยจากผลลัพธ์ของโปรแกรมไพธอน ได้ค่า p-value = $6.12 * 10^{-19}$ ซึ่งสามารถสรุปผลลัพธ์การทดสอบ ADF Test คือได้ค่า p-value น้อยกว่า α ที่ 0.05 ทำให้ ปฏิเสธ H_0 สรุปว่าตัวแปรผลตอบแทน เป็นข้อมูลที่นิ่ง (Stationary) ดังนั้น ตัวแปรนี้สามารถใช้ในการสร้างแบบจำลองในกลุ่ม GARCH ได้อย่างเหมาะสม


4.1.4 การนอร์มัลไลเซชันข้อมูล

งานวิจัยนี้ได้ทำการนอร์มัลไลเซชันข้อมูล โดยใช้วิธีการทำให้เป็นบรรทัดฐานด้วยค่าต่ำสุดและสูงสุด (Min-max normalization) วิธีนี้เป็นวิธีที่นิยมใช้เพื่อทำข้อมูลให้เป็นมาตรฐาน โดยที่ค่าต่ำสุดจะถูกแปลงให้มีค่าเป็น 0 และค่าสูงสุดจะถูกแปลงให้มีค่าเป็น 1 และค่าอื่น ๆ จะถูกแปลงเป็นค่าที่อยู่ระหว่าง 0 ถึง 1 โดยรูปที่ 4.3 จะเป็นกราฟแสดงผลการนอร์มัลไลเซชันของตัวแปรผลตอบแทน และรูปที่ 4.4 จะเป็นกราฟแสดงผลการนอร์มัลไลเซชันของตัวแปรเป้าหมาย



รูปที่ 4.3 กราฟแสดงผลการนอร์มัลไลเซชันของตัวแปรผลตอบแทน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.4 กราฟแสดงผลลัพธ์การนอร์มัลไลเซชันของตัวแปรเป้าหมาย

จากนั้นทำการแบ่งข้อมูลออกเป็น 3 ส่วน (70:15:15) คือ ชุดข้อมูลฝึกสอน (Train Set) จำนวน 1,329 วัน ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Set) จำนวน 284 วัน และชุดข้อมูลทดสอบ (Test Set) จำนวน 284 วัน โดยตัวแปรที่ใช้ในการสร้างแบบจำลองพยากรณ์ความผันผวนคือ ตัวแปรผลตอบแทนจากหลักทรัพย์ดัชนี SET (Return of SET Index)

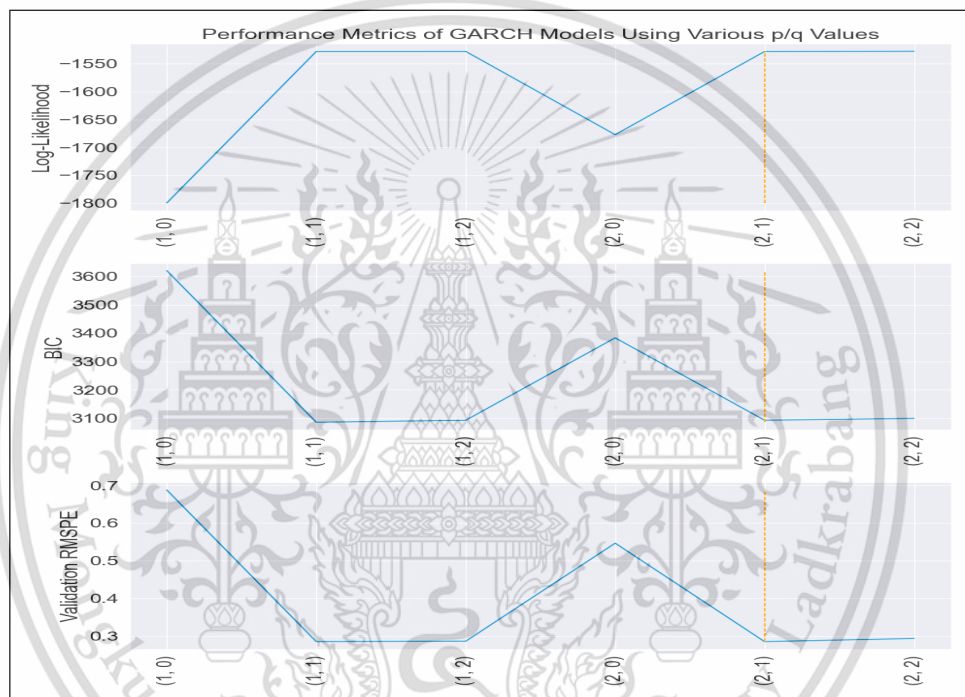
4.2 ผลการทำงานของแบบจำลอง

การประมวลผลของแบบจำลองแบ่งออกเป็น 3 วิธี ได้แก่ แบบจำลอง GARCH แบบจำลอง GJR-GARCH และแบบจำลอง TARARCH โดยใช้วิธีการทำนายแบบ Expanding window เพื่อทำการพยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า โดยจะใช้ชุดข้อมูลฝึกสอน (Train Set) ในการฝึกสอนครั้งแรก จากนั้นจะค่อย ๆ เพิ่มข้อมูลตรวจสอบความถูกต้อง (Validation Set) ทีละ 1 วัน ในการฝึกสอนครั้งต่อ ๆ ไป ซึ่งแต่ละวิธีจะมีการหาค่าพารามิเตอร์ที่ดีที่สุดเพื่อให้ได้ผลการพยากรณ์ที่แม่นยำที่สุด ซึ่งสามารถทำได้โดยการวนลูปตรวจสอบค่าพารามิเตอร์ต่าง ๆ และเปรียบเทียบค่า RMSPE ของแต่ละโมเดลกับค่าจริงของตัวแปรเป้าหมาย พร้อมทั้งพิจารณาค่า RMSE เป็นตัวประกอบการตัดสินใจ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.1 ผลการทำงานของแบบจำลอง GARCH

ค่าพารามิเตอร์ของแบบจำลอง GARCH ที่ทำการตรวจสอบ คือ พารามิเตอร์ p และ พารามิเตอร์ q เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนาย ผลการทดสอบพบว่า แบบจำลอง GARCH ที่มีพารามิเตอร์ $p=2$ และ $q=1$ หรือ GARCH(2, 1) เป็นโมเดลที่ดีที่สุดสำหรับการทำนาย เนื่องจากมีค่า RMSPE ต่ำที่สุด คือ 0.2849 ดังรูปที่ 4.5 จากนั้นนำโมเดลที่ได้ไปทำการเรียนรู้กับชุดข้อมูลฝึกสอน (Train Set) ได้ผลลัพธ์ดังรูปที่ 4.6 และไปทำนายผลกับชุดตรวจสอบความถูกต้อง (Validation Set) ได้ผลลัพธ์ดังรูปที่ 4.7




รูปที่ 4.5 กราฟแสดงผลการประเมินแบบจำลอง GARCH บนข้อมูลตรวจสอบ



รูปที่ 4.6 กราฟแสดงการเรียนรู้ด้วย GARCH(2, 1) บนข้อมูลฝึกสอน

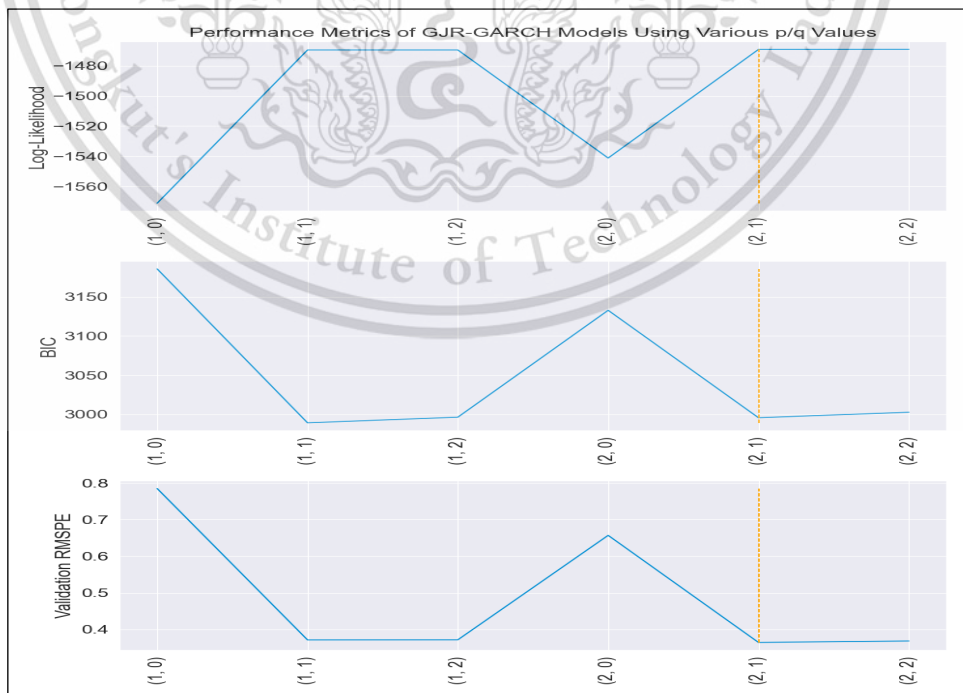
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.7 กราฟทำนายความผันผวนด้วย GARCH(2, 1) บนข้อมูลตรวจสอบ


4.2.2 ผลการทำงานของแบบจำลอง GJR-GARCH

ค่าพารามิเตอร์ของแบบจำลอง GJR-GARCH ที่ทำการตรวจสอบ คือ พารามิเตอร์ p และพารามิเตอร์ q เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนาย ผลการทดสอบพบว่าแบบจำลอง GJR-GARCH ที่มีพารามิเตอร์ $p=2$ และ $q=1$ หรือ GJR-GARCH(2, 1) เป็นโมเดลที่ดีที่สุดสำหรับการทำนาย เนื่องจากมีค่า RMSPE ต่ำที่สุด คือ 0.3645 ดังรูปที่ 4.8 จากนั้นนำโมเดลที่ได้ไปทำการเรียนรู้กับชุดข้อมูลฝึกสอน (Train Set) ได้ผลลัพธ์ดังรูปที่ 4.9 และไปทำนายผลกับชุดตรวจสอบความถูกต้อง (Validation Set) ได้ผลลัพธ์ดังรูปที่ 4.10




รูปที่ 4.8 กราฟแสดงผลการประเมินแบบจำลอง GJR-GARCH บนข้อมูลตรวจสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.9 กราฟแสดงการเรียนรู้ด้วย GJR-GARCH(2, 1) บนข้อมูลฝึกสอน



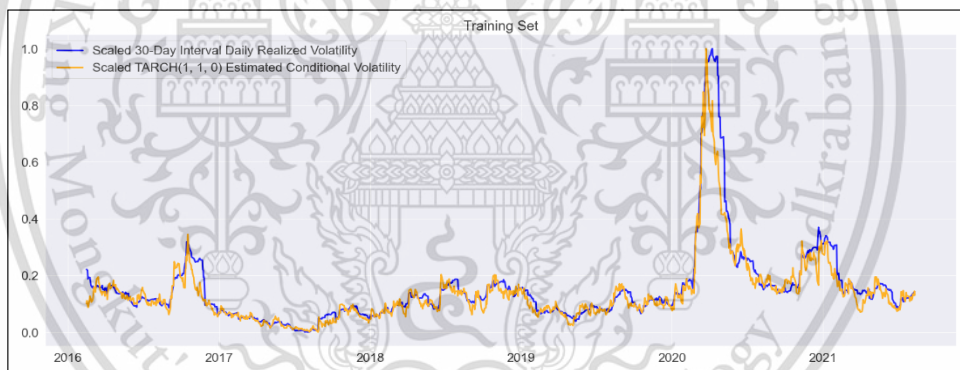
รูปที่ 4.10 กราฟทำนายความผันผวนด้วย GJR-GARCH(2, 1) บนข้อมูลตรวจสอบ

4.2.3 ผลการทำงานของแบบจำลอง TARCh


ค่าพารามิเตอร์ของแบบจำลอง TARCh ที่ทำการตรวจสอบ คือ พารามิเตอร์ p พารามิเตอร์ q และพารามิเตอร์ α เพื่อเปรียบเทียบความคลาดเคลื่อนในการทำนาย ผลการทดสอบพบว่า แบบจำลอง TARCh ที่มีพารามิเตอร์ $p=1$ $q=1$ และ $\alpha=0$ หรือ TARCh(1, 1, 0) เป็นโมเดลที่ดีที่สุดสำหรับการทำนาย เนื่องจากมีค่า RMSPE ต่ำที่สุด คือ 0.1927 ดังรูปที่ 4.11 จากนั้นนำโมเดลที่ได้ไปทำการเรียนรู้กับชุดข้อมูลฝึกสอน (Train Set) ได้ผลลัพธ์ดังรูปที่ 4.12 และไปทำนายผลกับชุดตรวจสอบความถูกต้อง (Validation Set) ได้ผลลัพธ์ดังรูปที่ 4.13



รูปที่ 4.11 กราฟแสดงผลการประเมินแบบจำลอง TARCh บนข้อมูลตรวจสอบ



รูปที่ 4.12 กราฟแสดงการเรียนรู้ด้วย TARCh(1, 1, 0) บนข้อมูลฝึกสอน



รูปที่ 4.13 กราฟทำนายความผันผวนด้วย TARCh(1, 1, 0) บนข้อมูลตรวจสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 การอภิปรายผล

จากผลการวิเคราะห์ข้อมูล และการทดสอบประสิทธิภาพของแบบจำลองในกลุ่ม GARCH ได้แก่ แบบจำลอง GARCH แบบจำลอง GJR-GARCH และแบบจำลอง TARARCH โดยใช้วิธีการทำนายแบบ Expanding window โดยจะใช้ชุดข้อมูลฝึกสอน (Train Set) ในการฝึกสอนครั้งแรก จากนั้นจะค่อย ๆ เพิ่มข้อมูลตรวจสอบความถูกต้อง (Validation Set) ทีละ 1 วัน ในการฝึกสอนครั้งต่อ ๆ ไป เพื่อเปรียบเทียบค่า RMSPE ของแต่ละแบบจำลองกับค่าจริงของตัวแปรเป้าหมาย ตามตารางที่ 4.1 พร้อมทั้งพิจารณาค่า RMSE เป็นตัวประกอบการตัดสินใจ ตามตารางที่ 4.2

Model	RMSPE
GARCH(2, 1)	0.2849
GJR-GARCH(2, 1)	0.3645
TARCH(1, 1, 0)	0.1927

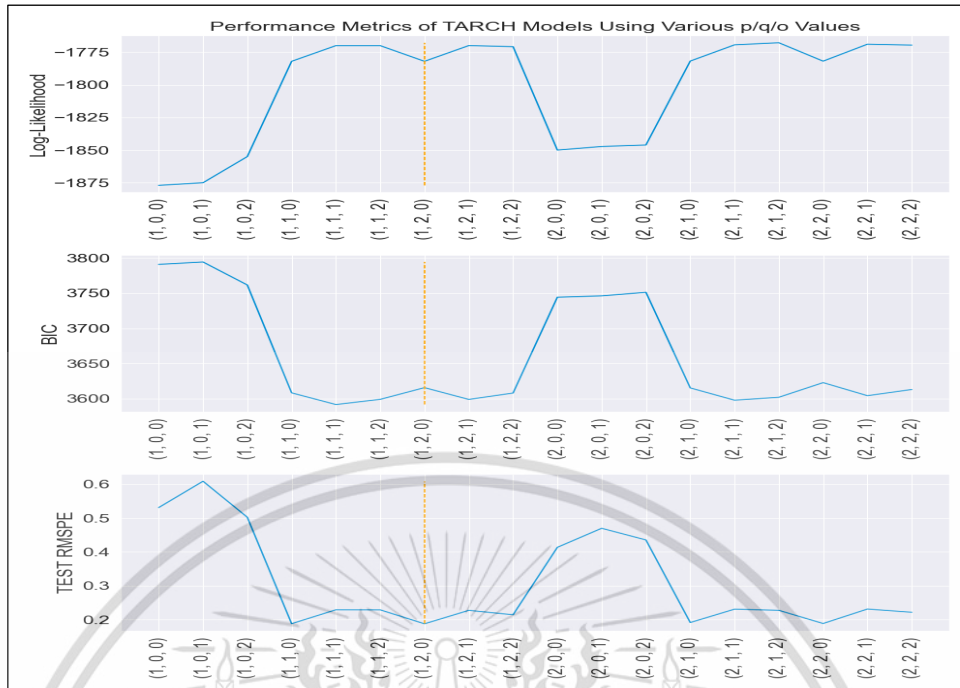
ตารางที่ 4.1 เปรียบเทียบค่า RMSPE ของแต่ละแบบจำลอง

Model	RMSE
GARCH(2, 1)	0.0356
GJR-GARCH(2, 1)	0.0435
TARCH(1, 1, 0)	0.0234


ตารางที่ 4.2 เปรียบเทียบค่า RMSE ของแต่ละแบบจำลอง

จากนั้น ผู้วิจัยจะเลือกแบบจำลองที่มีค่า RMSPE ต่ำที่สุด ซึ่งผลการวิจัยครั้งนี้ พบว่าแบบจำลอง TARARCH เป็นแบบจำลองที่มีค่า RMSPE ต่ำที่สุด โดยค่า RMSPE ของแบบจำลอง TARARCH เท่ากับ 0.1927 และมีค่า RMSE ต่ำที่สุดด้วย ดังนั้น แบบจำลอง TARARCH ถูกเลือกเป็นแบบจำลองที่เหมาะสมที่สุดสำหรับการทำนายกับข้อมูลในชุดข้อมูลทดสอบ (Test Set) โดยจะใช้วิธีการทำนายแบบ Expanding window และทำการรวมรูปตรวจสอบค่าพารามิเตอร์ต่าง ๆ พบว่า พารามิเตอร์ $p=1$ $q=2$ และ $o=0$ หรือ TARARCH(1, 2, 0) เป็นแบบจำลองที่มีค่า RMSPE คือ 0.1876 ดังรูปที่ 4.14 จากนั้นนำแบบจำลองที่ได้ไปทำการเรียนรู้กับชุดข้อมูลฝึกสอน รวมกับชุดตรวจสอบความถูกต้อง ได้ผลลัพธ์ดังรูปที่ 4.15 และไปทำนายผลกับชุดข้อมูลทดสอบ ได้ผลลัพธ์ดังรูปที่ 4.16


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.14 กราฟแสดงผลการประเมินแบบจำลอง TARCH บนข้อมูลทดสอบ



รูปที่ 4.15 กราฟแสดงการเรียนรู้ด้วย TARCH(1, 2, 0) บนข้อมูลฝึกสอนและข้อมูลตรวจสอบ



รูปที่ 4.16 กราฟทำนายความผันผวนด้วย TARCH(1, 2, 0) บนข้อมูลทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้นำเสนอการสร้างแบบจำลองที่เหมาะสมในการพยากรณ์ค่าความผันผวนของผลตอบแทนหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย โดยใช้แบบจำลองในกลุ่ม GARCH ได้แก่ แบบจำลอง GARCH แบบจำลอง GJR-GARCH และแบบจำลอง TARARCH โดยจะเสนอขั้นตอน และวิธีการในการทำงานต่าง ๆ ของอัลกอริทึมที่พัฒนาขึ้น เริ่มตั้งแต่การตรวจสอบความสมบูรณ์ของข้อมูล การสร้างตัวแปรผลตอบแทน การสร้างตัวแปรเป้าหมาย การทดสอบความนิ่งของตัวแปรผลตอบแทน และการนอร์มัลไลเซชันของตัวแปรผลตอบแทนกับตัวแปรเป้าหมาย จากนั้นผู้วิจัยจะนำเสนอผลการทดสอบการทำงานของแบบจำลองในกลุ่ม GARCH โดยใช้วิธีการทำนายแบบ Expanding window เพื่อทำการพยากรณ์ความผันผวนเฉลี่ยรายวันของราคาหลักทรัพย์ดัชนี SET ใน 7 วันข้างหน้า โดยจะใช้ชุดข้อมูลฝึกสอน (Train Set) ในการฝึกสอนครั้งแรก จากนั้นจะค่อย ๆ เพิ่มข้อมูลตรวจสอบความถูกต้อง (Validation Set) ทีละ 1 วัน ในการฝึกสอนครั้งต่อ ๆ ไป ซึ่งจากการวิจัยพบว่า แบบจำลอง TARARCH เป็นแบบจำลองที่มีค่าความคลาดเคลื่อนในการทำนายต่ำที่สุด โดยมีค่า RMSPE เท่ากับ 0.1927 ดังนั้น ผู้วิจัยทำการเลือกแบบจำลอง TARARCH สำหรับการทำนายกับข้อมูลในชุดข้อมูลทดสอบ (Test Set) โดยใช้วิธีการทำนายแบบ Expanding window ซึ่งมีค่า RMSPE เท่ากับ 0.1876

งานวิจัยนี้มีประโยชน์สำหรับนักลงทุนที่สนใจการซื้อขายเพื่อทำกำไรในระยะเวลายาว ๆ โดยที่ต้องการข้อมูลเชิงลึกเกี่ยวกับความผันผวนล่วงหน้าของราคาหลักทรัพย์ดัชนี SET เพื่อช่วยในการบริหารความเสี่ยงอย่างมีประสิทธิภาพ และสามารถตัดสินใจในการซื้อขายได้อย่างถูกต้องและรวดเร็ว

5.2 ขอบเขตและข้อจำกัด

1. การเลือกตัวแปรที่ใช้ในการสร้างแบบจำลองอาจมีความไม่สมบูรณ์ ซึ่งอาจส่งผลกระทบต่อความแม่นยำของการพยากรณ์ นอกจากนี้ ปัจจัยภายนอกที่ไม่ได้นำมาพิจารณาอาจมีผลกระทบต่อความผันผวนของผลตอบแทนหุ้น
 2. การใช้วิธีการทำนายแบบ Expanding window อาจให้ผลลัพธ์ที่ดีในระยะสั้นถึงระยะกลาง แต่การทำนายระยะยาวอาจมีความคลาดเคลื่อนสูง เนื่องจากปัจจัยที่เปลี่ยนแปลงไปในอนาคต
- เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ตลาดหลักทรัพย์มีการเปลี่ยนแปลงอยู่ตลอดเวลา ซึ่งอาจทำให้แบบจำลองที่สร้างขึ้นในช่วงเวลาหนึ่งไม่สามารถใช้งานได้ดีในช่วงเวลาอื่น นอกจากนี้ เหตุการณ์ทางเศรษฐกิจและการเมืองที่ไม่คาดคิดอาจส่งผลกระทบต่อความผันผวนของผลตอบแทนหุ้น

5.3 ปัญหาและอุปสรรค

ความไม่ถูกต้องของข้อมูลใน Yahoo Finance ข้อมูลที่แสดงในแพลตฟอร์มนี้บางครั้งอาจมีข้อผิดพลาดเชิงเทคนิค เช่น ข้อมูลราคาหุ้นที่ไม่ถูกต้องหรือข้อมูลการเงินที่ไม่สมบูรณ์ ซึ่งจำเป็นต้องมีการสำรวจข้อมูลก่อนนำไปใช้งาน

5.4 ข้อเสนอแนะ

1. งานวิจัยในครั้งนี้ใช้ ตัวแปรผลตอบแทน (Return) ในการสร้างแบบจำลอง ซึ่งอาจจะมีตัวแปรภายนอกอื่น ๆ ที่มีผลกระทบต่อความผันผวนของหุ้นได้ เช่น ข้อมูลเศรษฐกิจ ข่าวสารต่าง ๆ หรือตัวแปรทางการเงิน เพื่อเพิ่มประสิทธิภาพในการพยากรณ์
2. การใช้โมเดลอื่น ๆ ที่มีความซับซ้อนมากขึ้น เช่น LSTM เพื่อเปรียบเทียบประสิทธิภาพของการพยากรณ์กับแบบจำลอง GARCH, GJR-GARCH, และ TAR

เอกสารอ้างอิง

- ARCH Modeling - arch 6.3.0. (n.d.). Retrieved Feb 17, 2024, from https://arch.readthedocs.io/en/latest/univariate/univariate_volatility_modeling.html#Specifying-Common-Models
- Banton, C. (2022, January 31). *Computing historical volatility in Excel*. Investopedia. Retrieved Feb 5, 2024, from <https://www.investopedia.com/articles/investing/102715/computing-historical-volatility-excel.asp>
- Chibui. (n.d.). *Bitcoin volatility forecasting*. GitHub. Retrieved Feb 5, 2024, from https://github.com/chibui191/bitcoin_volatility_forecasting/blob/main/Notebooks/Reports/report_notebook.ipynb
- Cway investment. (2018, October 11). *Volatility Modeling Using GARCH*. Retrieved Mar 12, 2024, from <https://medium.com/cw-quantlab/volatility-modeling-using-garch-8f3490de6cdd>
- Ozdemir, O. (n.d.). *ARCH-GARCH Tutorial with rugarch package*. Retrieved Feb 10, 2024, from <https://users.metu.edu.tr/ozancan/ARCHGARCHTutorial.html>
- Paraskevi Katsiampa (2017). *Volatility estimation for Bitcoin: A comparison of GARCH models*. Economics Letter. Retrieved Mar 23, 2024, from <https://www.sciencedirect.com/science/article/abs/pii/S0165176517302501>
- Volatility Forecasting - arch 6.3.0. (n.d.). Retrieved Feb 18, 2024, from https://arch.readthedocs.io/en/latest/univariate/univariate_volatility_forecasting.html
- Volatility Forecasting - arch 6.3.0. (n.d.). Retrieved Feb 19, 2024, from https://arch.readthedocs.io/en/latest/univariate/univariate_volatility_forecasting.html#TARCH
- ธนัชชา บุญญะ. (2566). *การศึกษาแบบจำลองที่เหมาะสมสำหรับการพยากรณ์และความสัมพันธ์ของปัจจัยที่ส่งผลกระทบต่ออัตราผลตอบแทนของสกุลเงินดิจิทัล*. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ สาขาวิชาการประกันภัย ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย.
- พงศกร พัวพัฒนกุล. (2560). *การวิเคราะห์ปัจจัยที่ส่งผลกระทบต่อความผันผวนของราคา Bitcoin*. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ สาขาวิชาการเงิน มหาวิทยาลัยกรุงเทพ.

- พรรณธร ศรีสถาพร. (2563). การศึกษาเปรียบเทียบการพยากรณ์ความผันผวนและราคาหลักทรัพย์
ดัชนี SET50 ระหว่างตัวแบบทางเศรษฐมิติและตัวแบบที่ใช้ เทคนิคการเรียนรู้ของเครื่อง
(MACHINE LEARNING). วิทยานิพนธ์ปริญญาโทมหาบัณฑิต สาขาวิชาการบัญชีและการ
บริหารการเงิน คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์.
- วิศรุต ตระกูลวีระยุทธ. (2561). เปรียบเทียบประสิทธิภาพแบบจำลองวิเคราะห์มูลค่าความเสี่ยง
Value at Risk: กรณีกองทุนรวมหุ้นระยะยาว. วิทยานิพนธ์ปริญญาโทมหาบัณฑิต
เศรษฐศาสตรมหาบัณฑิต สาขาเศรษฐศาสตร์ธุรกิจ คณะเศรษฐศาสตร์
มหาวิทยาลัยธรรมศาสตร์.
- สุนันทใจ เนตรงาม และ กัญญสุตา นิมนอนุสรณ์กุล. (2559). การวิเคราะห์ความผันผวนของอัตรา
ผลตอบแทนกองทุนหุ้นจีน. วิทยานิพนธ์ปริญญาโทมหาบัณฑิต เศรษฐศาสตรมหาบัณฑิต
มหาวิทยาลัยเชียงใหม่.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชุดคำสั่งการประมวลผลและผลลัพธ์ด้วยโปรแกรมภาษาไพธอน

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
import yfinance as yf
from datetime import date
from scipy import stats
from datetime import datetime, timedelta
from sklearn.metrics import mean_squared_error as mse
from sklearn.preprocessing import MinMaxScaler
from statsmodels.tsa.stattools import adfuller
import itertools
from arch import arch_model

%matplotlib inline
```

ไลบรารี (Library) ต่าง ๆ ที่ใช้

```
# SELECT START AND END DATE
start = '2016-01-01'
end = '2023-12-31'
ticker = '^SET.BK'

df = yf.download(ticker, start=start, end=end, interval='1d')

[*****100%*****] 1 of 1 completed

df = df[df['Volume'] > 1000000]
df.head()
```

Date	Open	High	Low	Close	Adj Close	Volume
2016-01-04	1286.260010	1286.359985	1260.959961	1263.410034	1263.410034	9397100
2016-01-05	1267.989990	1270.069946	1251.869995	1253.339966	1253.339966	9880900
2016-01-06	1250.140015	1260.880005	1247.890015	1260.040039	1260.040039	7905700
2016-01-07	1238.060059	1244.040039	1224.829956	1224.829956	1224.829956	9622800
2016-01-08	1231.880005	1246.699951	1228.180054	1244.180054	1244.180054	7910300

ข้อมูลราคาหุ้นของหลักทรัพย์ดัชนี SET จาก Yahoo Finance

```
# CALCULATE PRICE RETURNS AS DAILY PERCENTAGE CHANGE USING pct_change()
df['returns'] = 100 * df.Close.pct_change().dropna()

df.dropna(inplace=True)
df.head()
```

Date	Open	High	Low	Close	Adj Close	Volume	returns
2016-01-05	1267.989990	1270.069946	1251.869995	1253.339966	1253.339966	9880900	-0.797055
2016-01-06	1250.140015	1260.880005	1247.890015	1260.040039	1260.040039	7905700	0.534577
2016-01-07	1238.060059	1244.040039	1224.829956	1224.829956	1224.829956	9622800	-2.794362
2016-01-08	1231.880005	1246.699951	1228.180054	1244.180054	1244.180054	7910300	1.579819
2016-01-11	1233.859985	1235.180054	1220.959961	1234.500000	1234.500000	7897500	-0.778027

การสร้างตัวแปรผลตอบแทน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

# CREATE A FUNCTION THAT CALCULATE REALIZED VOLATILITY
def realized_volatility_daily(series_return):
    n = len(series_return)
    return np.sqrt(np.sum(series_return**2)/(n - 1))

INTERVAL_WINDOW = 30
n_future = 7

# GET FORWARD LOOKING REALIZED VOLATILITY
df['vol_future'] = df.log_returns.shift(-n_future)\
    .rolling(window=INTERVAL_WINDOW)\
    .apply(realized_volatility_daily)

```

การสร้างตัวแปรเป้าหมาย

```

# RETURNS
adfuller_results = adfuller(df.returns.dropna())

print(f'ADF Statistic: {adfuller_results[0]}')
print(f'p-value: {adfuller_results[1]}')
print('Critical Values:')
for key, value in adfuller_results[4].items():
    print(f'{key}: {value:.4f}')

```

การทดสอบความนิ่งของตัวแปรผลตอบแทน

```

def transform_volatility_to_scaler(scaler, tf_series):
    """
    Transform a series to a fitted scaler
    """
    idx = tf_series.index
    output = pd.Series(scaler.transform(tf_series.values.reshape(-1,1))[:,0],
                      index=idx)
    return output

# INITIATE SCALER
scaler_vol = MinMaxScaler()

# FIT SCALER TO CURRENT VOLATILITY IN TRAINING SET
scaler_vol = scaler_vol.fit(x_train.values.reshape(-1,1))

```

การนอร์มัลไลเซชันข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

#HYPERPARAMETER TUNING FOR GARCH MODEL
pq_s = [p for p in itertools.product(range(3), repeat=2)]
# ELIMINATE PERMUTATIONS WITH p = 0
pq_s = list(filter(lambda x: x[0] != 0, pq_s))
# RMSPE ON VALIDATION SET
garch_rmspe = []
# LOG LIKELIHOOD
garch_LLH = []
# BIC
garch_bic = []

for p, q in pq_s:
    # SET SEED FOR REPRODUCIBILITY
    np.random.seed(seed)

    # FITTING GARCH(p,q) MODEL
    t_garch_pq = arch_model(r_train, vol='GARCH', p=p, q=q)
    t_garch_pq_fit = t_garch_pq.fit(dispatch='off')

    # SCALING CONDITIONAL VOLATILITY OUTPUTS
    sclr = MinMaxScaler()
    cond_vol_arr = t_garch_pq_fit.conditional_volatility.values.reshape(-1,1)

    # FITTING SCALER TO MODEL'S CONDITIONAL VOLATILITY
    sclr = sclr.fit(cond_vol_arr)

    # INITIALIZING rolling_forecasts VALUES LIST
    rolling_forecasts = []

    # ITERATE OVER EACH TIME STEP IN THE VALIDATION SET
    for i in range(len(r_val)):
        # GET THE DATA AT ALL PREVIOUS TIME STEPS
        idx = val_idx[i]
        train = df.returns[:idx].dropna()

        # TRAIN MODEL USING ALL PREVIOUS TIME STEPS' DATA
        model = arch_model(train, vol='GARCH', p=p, q=q)
        model_fit = model.fit(dispatch='off')

        # MAKE PREDICTION
        var = model_fit.forecast(horizon=n_future,
                                reindex=False,
                                method='bootstrap').variance.values
        pred = np.sqrt(np.mean(var))

        # APPEND TO rolling_forecasts LIST
        rolling_forecasts.append(pred)

    # CONVERT PREDICTIONS
    y_preds = pd.Series(rolling_forecasts, index=val_idx)

    # TRANSFORM PREDICTIONS USING FITTED SCALER FOR SPECIFIC p/q SET
    y_preds_scaled = transform_volatility_to_scaler(sclr, y_preds)

    # APPENDING PERFORMANCE METRICS TO LISTS
    garch_LLH.append(t_garch_pq_fit.loglikelihood)
    garch_bic.append(t_garch_pq_fit.bic)
    garch_rmspe.append(RMSPE(y_val_scaled, y_preds_scaled))

```

การสร้างแบบจำลอง GARCH บนข้อมูลตรวจสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

#HYPERPARAMETER TUNING FOR GJR-GARCH MODEL
pq_s = [p for p in itertools.product(range(3), repeat=2)]
# ELIMINATE PERMUTATIONS WITH p = 0
pq_s = list(filter(lambda x: x[0] != 0, pq_s))
# RMSPE ON VALIDATION SET
gjr_rmspe = []
# LOG LIKELIHOOD
gjr_LLH = []
# BIC
gjr_bic = []

for p, q in pq_s:
    # SET SEED FOR REPRODUCIBILITY
    np.random.seed(seed)

    # FITTING GJR-GARCH MODEL
    t_gjr_pq = arch_model(r_train, p=p, q=q, o=1,
                          vol='GARCH', dist='skewt')
    t_gjr_pq_fit = t_gjr_pq.fit(dispatch='off')

    # SCALING CONDITIONAL VOLATILITY OUTPUTS
    sclr = MinMaxScaler()
    cond_vol_arr = t_gjr_pq_fit.conditional_volatility.values.reshape(-1,1)

    # FITTING SCALER TO MODEL'S CONDITIONAL VOLATILITY
    sclr = sclr.fit(cond_vol_arr)

    # INITIALIZING rolling_forecasts VALUES LIST
    rolling_forecasts = []

    # ITERATE OVER EACH TIME STEP IN THE VALIDATION SET
    for i in range(len(r_val)):
        # GET THE DATA AT ALL PREVIOUS TIME STEPS
        idx = val_idx[i]
        train = df.returns[:idx].dropna()

        # TRAIN MODEL USING ALL PREVIOUS TIME STEPS' DATA
        model = arch_model(train, p=p, q=q, o=1,
                           vol='GARCH', dist='skewt')

        model_fit = model.fit(dispatch='off')

        # MAKE PREDICTION
        var = model_fit.forecast(horizon=n_future,
                                reindex=False,
                                method='bootstrap').variance.values
        pred = np.sqrt(np.mean(var))

        # APPEND TO rolling_forecasts LIST
        rolling_forecasts.append(pred)

    # CONVERT PREDICTIONS
    y_preds = pd.Series(rolling_forecasts, index=val_idx)

    # TRANSFORM PREDICTIONS USING FITTED SCALER FOR SPECIFIC p/q SET
    y_preds_scaled = transform_volatility_to_scaler(sclr, y_preds)

    # APPENDING PERFORMANCE METRICS TO LISTS
    gjr_LLH.append(t_gjr_pq_fit.loglikelihood)
    gjr_bic.append(t_gjr_pq_fit.bic)
    gjr_rmspe.append(RMSPE(y_val_scaled, y_preds_scaled))

```

การสร้างแบบจำลอง GJR-GARCH บนข้อมูลตรวจสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

pqr_s = [p for p in itertools.product(range(3), repeat=3)]
# ELIMINATE PERMUTATIONS WITH p = 0
pqr_s = list(filter(lambda x: x[0] != 0, pqr_s))
# RMSPE ON VALIDATION SET
tarch_rmspe = []
# LOG LIKELIHOOD
tarch_LLH = []
# BIC
tarch_bic = []

for p, q, o in pqr_s:
    # SET SEED FOR REPRODUCIBILITY
    np.random.seed(seed)

    # FITTING TARCH(p,q,o) MODEL
    t_tarch_pqr = arch_model(r_train, p=p, q=q, o=o, power=1.0,
                             dist='skewt')
    t_tarch_pqr_fit = t_tarch_pqr.fit(dispatch='off')

    # SCALING CONDITIONAL VOLATILITY OUTPUTS
    sclr = MinMaxScaler()
    cond_vol_arr = t_tarch_pqr_fit.conditional_volatility.values.reshape(-1,1)

    # FITTING SCALER TO MODEL'S CONDITIONAL VOLATILITY
    sclr = sclr.fit(cond_vol_arr)

    # INITIALIZING rolling_forecasts VALUES LIST
    rolling_forecasts = []

    # ITERATE OVER EACH TIME STEP IN THE VALIDATION SET
    for i in range(len(r_val)):
        # GET THE DATA AT ALL PREVIOUS TIME STEPS
        idx = val_idx[i]
        train = df.returns[:idx].dropna()

        # TRAIN MODEL USING ALL PREVIOUS TIME STEPS' DATA
        model = arch_model(train, p=p, q=q, o=o, power=1.0,
                           dist='skewt')
        model_fit = model.fit(dispatch='off')

        # MAKE PREDICTION
        var = model_fit.forecast(horizon=n_future,
                                reindex=False,
                                method='bootstrap').variance.values
        pred = np.sqrt(np.mean(var))

        # APPEND TO rolling_forecasts LIST
        rolling_forecasts.append(pred)

    # CONVERT PREDICTIONS
    y_preds = pd.Series(rolling_forecasts, index=val_idx)

    # TRANSFORM PREDICTIONS USING FITTED SCALER FOR SPECIFIC p/q/o SET
    y_preds_scaled = transform_volatility_to_scaler(sclr, y_preds)

    # APPENDING PERFORMANCE METRICS TO LISTS
    tarch_LLH.append(t_tarch_pqr_fit.loglikelihood)
    tarch_bic.append(t_tarch_pqr_fit.bic)
    tarch_rmspe.append(RMSPE(y_val_scaled, y_preds_scaled))

```

การสร้างแบบจำลอง TARCH บนข้อมูลตรวจสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ	นายพิเชษฐ์ อนันต์เจริญพร
วัน เดือน ปีเกิด	23 สิงหาคม 2539
ที่อยู่ปัจจุบัน	504/44 ซ.ประชาราษฎร์บำเพ็ญ 20 ถ.ประชาราษฎร์บำเพ็ญ แขวงสามเสนนอก เขตห้วยขวาง กรุงเทพฯ 10310
ประวัติการศึกษา	ปีการศึกษา 2561 ปริญญาตรี วิทยาศาสตร์บัณฑิต สาขาสถิติ เกรดเฉลี่ย 3.01 มหาวิทยาลัยธรรมศาสตร์
ทุนการศึกษา	
ผลงานทางวิชาการ	



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้