

การเปรียบเทียบวิธีในการพยากรณ์ราคาหุ้นด้วยแบบจำลองอาร์ม่า, โครงข่ายประสาทเทียม และตัว
แบบผสม



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาสถิติ ภาควิชาสถิติ

คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2564

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

An Comparison of Stock Price Forecasting Methods with ARIMA, Artificial Neural
Network and Hybrid model



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Statistics
Department of Statistics
FACULTY OF COMMERCE AND ACCOUNTANCY
Chulalongkorn University
Academic Year 2021
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การเปรียบเทียบวิธีในการพยากรณ์ราคาหุ้นด้วยแบบจำลอง อาร์มีมา, โครงข่ายประสาทเทียม และตัวแบบผสม
โดย	น.ส.กาญจน์ภววรรณ จงศิริวิโรจ
สาขาวิชา	สถิติ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.วิฐุรา พึ่งพาพงศ์

คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้
เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณบดีคณะพาณิชยศาสตร์และการ
บัญชี
(รองศาสตราจารย์ ดร.วิเลิศ ภูริวัชร)

คณะกรรมการสอบวิทยานิพนธ์
..... ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.อนุภาพ สมบูรณ์สวัสดิ์)
..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.วิฐุรา พึ่งพาพงศ์)
..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.นัท กุลวานิช)
..... กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร. ทพญ.นัจชลี ศรีมณีกาญจน์)

กาญจน์ภิวรรณ จงศิริวิโรจ : การเปรียบเทียบวิธีในการพยากรณ์ราคาหุ้นด้วยแบบจำลอง
 อาร์มีน่า, โครงข่ายประสาทเทียม และตัวแบบผสม. (An Comparison of Stock Price
 Forecasting Methods with ARIMA, Artificial Neural Network and Hybrid
 model) อ.ที่ปรึกษาหลัก : ผศ. ดร.วิจรรยา พึ่งพาพงศ์

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบวิธีการพยากรณ์ราคาปิดหุ้นรายวันในอนาคต
 โดยใช้ตัวแบบอาร์มีน่าซึ่งสร้างจากวิธีการค้นหาแบบกริด โครงข่ายประสาทเทียมและตัวแบบผสมใน
 การพยากรณ์ราคาของหุ้น ภายใต้ตัวอย่างหุ้นที่ถูกเลือกมาตามระดับความผันผวนจากสูงไปต่ำ ใน
 กลุ่มอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ ได้แก่ HANA, DELTA และ SVI ตามลำดับ
 โดยเก็บข้อมูลราคาปิดรายวันของหุ้นตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564 (5
 ปีย้อนหลัง) ซึ่งอาศัยการแบ่งชุดข้อมูลฝึกสอนด้วยวิธี ตรวจสอบไขว้ (rolling forward
 validation) ทั้งวิธีตรวจสอบไขว้แบบสลับ และวิธีตรวจสอบไขว้แบบ moving window ซึ่ง
 ผลการวิจัยพบว่า เมื่อใช้ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์เป็นเกณฑ์ในการคัดเลือกตัว
 แบบ ทั้งสองวิธีการแบ่งชุดข้อมูลย่อยนั้น โครงข่ายประสาทเทียมมีความแม่นยำมากที่สุดในการ
 พยากรณ์ราคาปิดของหุ้น HANA, DELTA และ SVI รวมถึงตัวแบบผสมดังกล่าวไม่จำเป็นต้องมี
 ประสิทธิภาพดีกว่าการใช้แต่ละตัวแบบเพียงลำพังเสมอไป ตัวแบบอาร์มีน่าซึ่งสร้างจากวิธีการค้นหา
 แบบกริดสามารถพยากรณ์ได้ดีกว่าในหุ้นที่มีระดับความผันผวนกลางและระดับต่ำ ในขณะที่
 โครงข่ายประสาทเทียมสามารถพยากรณ์ได้ดีในทุกระดับความผันผวนราคาหุ้น

จุฬาลงกรณ์มหาวิทยาลัย
 CHULALONGKORN UNIVERSITY

สาขาวิชา สถิติ
 ปีการศึกษา 2564

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6380039526 : MAJOR STATISTICS

KEYWORD: ARIMA, Autoregressive Integrated Moving Average Model, ANN, Artificial Neural Network, HYBRID, ARIMA with ANN, Stock Price's Forecasting

Karnpiwan Jongsiriviroj : An Comparison of Stock Price Forecasting Methods with ARIMA, Artificial Neural Network and Hybrid model. Advisor: Asst. Prof. VITARA PUNGPAPONG, Ph.D.

The purpose of this research is to compare the forecasting methods of daily closing stock price in the future including an ARIMA model built on grid search method, an artificial neural network and a hybrid model. Sample stocks in technology and electronic industry were selected according to the level of their volatility from high to low. These include HANA, DELTA, and SVI respectively. The daily closing price of stocks from October 2016 to October 2021 (the past five years) was divided into the training dataset and the testing dataset using both a rolling forward cross-validation method and a cumulative cross-validation method. The mean absolute percentage error was used as the criterion for model selection. With both cross-validation methods, we found that the artificial neural network performed the best in forecasting the closing prices of HANA, DELTA and SVI stocks. Interestingly, a hybrid model did not always outperform other methods. The ARIMA model, built on the grid search method, had better predictive ability for stocks with medium and low volatility while the neural network performed generally well at forecasting all levels of stock price volatility.

Field of Study: Statistics

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

การดำเนินโครงการครั้งนี้สามารถสำเร็จลุล่วงไปได้ด้วยดี เพราะได้รับความอนุเคราะห์จากผู้มีพระคุณหลายท่านด้วยกัน ทางผู้ดำเนินงานโครงการจึงใคร่ขอพระขอบคุณไว้ ณ โอกาสนี้

อนึ่ง ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ดร.วิฐรา พึ่งพาพงศ์ที่กรุณารับเป็นอาจารย์ที่ปรึกษาโครงการ พร้อมทั้งได้ให้คำแนะนำ คำชี้แจงถึงปัญหาและระยะเวลาให้คำปรึกษาถึงแนวทางการแก้ไขปัญหาที่เกิดขึ้นในโครงการอย่างเอาใจใส่มาตลอด ตั้งแต่โครงการยังมีเพียงแค่อีเมลเริ่มต้น จวบจนกระทั่งโครงการนี้ได้สำเร็จลุล่วงอย่างสมบูรณ์ ลำดับถัดมา ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.นันท กุลวานิช และผู้ช่วยศาสตราจารย์ ดร.อนุภาพ สมบูรณ์สวัสดิ์ ผู้ให้ความกรุณาเป็นกรรมการสอบโครงการนี้ พร้อมทั้งชี้แจงถึง จุดบกพร่องต่าง ๆ ตลอดจนให้คำแนะนำเพื่อให้โครงการนี้สมบูรณ์ยิ่งขึ้น นอกจากนี้ขอขอบพระคุณคณาจารย์ทุกท่านผู้อบรมและประสิทธิประสาทวิชาความรู้ต่าง ๆ ทั้งในและนอกรั้วมหาวิทยาลัย

สุดท้ายนี้ ขอขอบพระคุณครอบครัวที่คอยเป็นกำลังใจรวมถึงให้การสนับสนุนมาโดยตลอด และเพื่อน ๆ พี่ ๆ ทุกคน สำหรับความคิดเห็นต่าง ๆ รวมถึงคอยช่วยเหลือแนะ ช่วยเหลือเกื้อกูลกันมาตลอดการดำเนินโครงการครั้งนี้ ขอขอบพระคุณทุก ๆ ท่าน ไว้ ณ ที่นี้ด้วย



กาญจณีภิวรรณ จงศิริวิโรจ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	1
สารบัญภาพ.....	3
บทที่ 1 บทนำ.....	13
1.1 ความเป็นมาและความสำคัญของปัญหา.....	13
1.2 วัตถุประสงค์.....	16
1.3 ขอบเขตของการวิจัย.....	16
1.4 วิธีดำเนินการวิจัย.....	17
1.5 แผนการดำเนินงาน.....	18
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	20
2.1 แนวคิดและทฤษฎี.....	20
2.2 งานวิจัยที่เกี่ยวข้อง.....	25
บทที่ 3 วิธีการวิจัย.....	28
บทที่ 4 ผลการวิจัย.....	35
บทที่ 5 สรุปผลวิเคราะห์และข้อเสนอแนะ.....	84
บรรณานุกรม.....	90
ประวัติผู้เขียน.....	95

สารบัญตาราง

	หน้า
ตาราง 3.1 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	38
ตาราง 3.2 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	40
ตาราง 3.3 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	43
ตาราง 3.4 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	45
ตาราง 3.5 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	48
ตาราง 3.6 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	50
ตาราง 3.7 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	54
ตาราง 3.8 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	56
ตาราง 3.9 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	58
ตาราง 3.10 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	60

ตาราง 3.11 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	63
ตาราง 3.12 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	65
ตาราง 3.13 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น HANA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	68
ตาราง 3.14 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น HANA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	70
ตาราง 3.15 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น DELTA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	73
ตาราง 3.16 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น DELTA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	75
ตาราง 3.17 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น SVI ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative	77
ตาราง 3.18 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น SVI ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window	79
ตาราง 4.0 การเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ ARIMA, ตัวแบบ ANN และตัวแบบผสม	81
ตาราง 4.1 แสดงตัวแบบ ANN ที่เหมาะสมที่สุดของหุ้น HANA	82
ตาราง 4.2 แสดงตัวแบบ ANN ที่เหมาะสมที่สุดของหุ้น DELTA	82
ตาราง 4.3 แสดงตัวแบบ ANN ที่เหมาะสมที่สุดของหุ้น SVI	83
ตาราง 5.0 การเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ ARIMA, ตัวแบบ ANN และตัวแบบผสม เพื่อตรวจสอบว่าตัวแบบใดสามารถรับมือกับความเปลี่ยนแปลงของราคาหุ้นเนื่องจากสภาวะโรคระบาด ได้ดีที่สุด	86

สารบัญภาพ

	หน้า
ภาพ 1.1 แสดงราคาปิดรายวันของหุ้น HANA ตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564	15
ภาพ 1.2 แสดงราคาปิดรายวันของหุ้น DELTA ตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564	15
ภาพ 1.3 แสดงราคาปิดรายวันของหุ้น SVI ตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564	15
ภาพ 1.4 แสดงแบบจำลองการทำงานของโครงข่ายประสาท	23
ภาพ 2.1 rolling forward validation แบบ cumulative	30
ภาพ 2.2 rolling forward validation แบบ moving window	30
ภาพ 3.1 แสดงการแบ่งชุดข้อมูล 866 วันแรก (70 %) เป็น training set และ 371 วันสุดท้าย (30 %) เป็น test set ของตัวอย่างหุ้น HANA	29
ภาพ 3.2 แสดงกราฟราคาปิดหุ้นรายวันระหว่าง training set, validation set และค่าพยากรณ์ (forecast) จากตัวแบบ ARIMA ด้วยวิธีแบ่งข้อมูล rolling forward	31
ภาพ 3.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1	36
ภาพ 3.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2	37

ภาพ 3.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3	37
ภาพ 3.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4	37
ภาพ 3.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1	38
ภาพ 3.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2	39
ภาพ 3.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3	39
ภาพ 3.1.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4	39
ภาพ 3.1.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1	41
ภาพ 3.1.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2	41

<p>ภาพ 3.1.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3</p>	42
<p>ภาพ 3.1.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4</p>	42
<p>ภาพ 3.1.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1</p>	44
<p>ภาพ 3.1.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2</p>	44
<p>ภาพ 3.1.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3</p>	44
<p>ภาพ 3.1.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4</p>	45
<p>ภาพ 3.1.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1</p>	46
<p>ภาพ 3.2.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2</p>	46

ภาพ 3.2.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3	47
ภาพ 3.2.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4	47
ภาพ 3.2.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1	48
ภาพ 3.2.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2	49
ภาพ 3.2.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3	49
ภาพ 3.2.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4	49
ภาพ 3.2.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 1	52
ภาพ 3.2.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 2	52

ภาพ 3.2.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 3	53
ภาพ 3.3.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 4	53
ภาพ 3.3.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 1	47
ภาพ 3.3.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 2	64
ภาพ 3.3.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 3	55
ภาพ 3.3.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 4	55
ภาพ 3.3.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 1	57
ภาพ 3.3.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 2	57

<p>ภาพ 3.3.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 3</p>	57
<p>ภาพ 3.3.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 4</p>	58
<p>ภาพ 3.3.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 1</p>	59
<p>ภาพ 3.4.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 2</p>	59
<p>ภาพ 3.4.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 3</p>	59
<p>ภาพ 3.4.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 4</p>	60
<p>ภาพ 3.4.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 1</p>	61
<p>ภาพ 3.4.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 2</p>	61

ภาพ 3.4.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 3	62
ภาพ 3.4.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 4	62
ภาพ 3.4.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 1	63
ภาพ 3.4.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 2	64
ภาพ 3.4.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 3	64
ภาพ 3.5.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 4	64
ภาพ 3.5.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 1	66
ภาพ 3.5.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 2	66

<p>ภาพ 3.5.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 3</p>	67
<p>ภาพ 3.5.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 4</p>	67
<p>ภาพ 3.5.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 1</p>	68
<p>ภาพ 3.5.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 2</p>	69
<p>ภาพ 3.5.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 3</p>	69
<p>ภาพ 3.5.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 4</p>	69
<p>ภาพ 3.5.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 1</p>	71
<p>ภาพ 3.6.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูล ด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 2</p>	71

ภาพ 3.6.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 3	72
ภาพ 3.6.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 4	72
ภาพ 3.6.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 1	73
ภาพ 3.6.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 2	73
ภาพ 3.6.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 3	74
ภาพ 3.6.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 4	74
ภาพ 3.6.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 1	75
ภาพ 3.6.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 2	76

ภาพ 3.6.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 3	76
ภาพ 3.7.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 4	76
ภาพ 3.7.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 1	78
ภาพ 3.7.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 2	78
ภาพ 3.7.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 3	78
ภาพ 3.7.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 4	79
ภาพ 4.1 แสดงการพยากรณ์ราคาปิดรายวันของหุ้น HANA ด้วยแบบจำลอง ANN เทียบกับราคาจริงในชุดข้อมูลทดสอบ	82
ภาพ 4.2 แสดงการพยากรณ์ราคาปิดหุ้น DELTA รายวันด้วยแบบจำลอง ANN เทียบกับราคาจริงในชุดข้อมูลทดสอบ	82
ภาพ 4.3 แสดงการพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยแบบจำลอง ANN เทียบกับราคาจริงในชุดข้อมูลทดสอบ	83

บทที่ 1

บทนำ

ความเป็นมาและความสำคัญของปัญหา


ปัจจุบันการลงทุนเข้ามามีบทบาทกับการดำเนินชีวิตเป็นอย่างมาก การลงทุนแต่ละประเภทนั้นต่างมีอัตราผลตอบแทนและความเสี่ยงที่ระดับแตกต่างกันไป ทั้งนี้การลงทุนที่ต้องการระดับผลตอบแทนที่สูงขึ้น มักจะมาพร้อมกับระดับความเสี่ยงที่สูงขึ้นอย่างมีนัยสำคัญเสมอ [1] คำถามที่น่าสนใจคือ เราจะสามารถลงทุนอย่างไรเพื่อให้ผลตอบแทนสูง แต่มีระดับความเสี่ยงต่ำ ดังนั้นคณิตศาสตร์จึงเป็นเครื่องมือสำคัญเป็นอย่างมากในการวางแผนการลงทุนและบริหารความเสี่ยงในอนาคต [1]

การลงทุนทุกประเภทล้วนมีจุดประสงค์ให้การลงทุนนั้นได้รับผลตอบแทนที่ออกเงยจากเงินที่เราได้ทำการลงทุนไป คำถามคือเราจะต้องทำอย่างไรจึงจะทำให้ได้ผลตอบแทนตามที่คาดหวังนั้น ในปัจจุบันจึงได้มีเทคนิคการพยากรณ์ราคาสินทรัพย์เผยแพร่ออกมามากมายในหลากหลายประเภทของการลงทุนซึ่งนักลงทุนคาดหวังว่าเทคนิคนั้น ๆ จะมีความแม่นยำในการพยากรณ์เพื่อให้ให้นักลงทุนได้รับผลตอบแทนที่คาดหวังได้ในท้ายที่สุด โดยการลงทุนในหุ้นถือเป็นหนึ่งในประเภทการลงทุนซึ่งได้รับความนิยมเป็นอย่างมากเช่นกัน [2] เนื่องจากแม้การลงทุนในหุ้นจะเป็นหนึ่งในการลงทุนที่มีความเสี่ยง แต่สามารถให้ผลตอบแทนสูงแก่นักลงทุน หากจัดการพอร์ตการลงทุนอย่างรอบคอบ ซึ่งในการจัดการหุ้นในพอร์ต ข้อมูลเกี่ยวกับราคาหุ้นจึงมีความสำคัญเป็นอย่างมาก โดยนักลงทุนมีหลายวิธีในการพยากรณ์ราคาหุ้น เช่น ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines : SVM) หรือโครงข่ายประสาทเทียม (Artificial Neural Networks : ANN) และอีกวิธีหนึ่งคือการใช้การวิเคราะห์อนุกรมเวลา ซึ่งหนึ่งในเทคนิคที่ใช้บ่อยที่สุดในการการวิเคราะห์อนุกรมเวลา คือ อารีมา (Autoregressive Integrated Moving Average Model : ARIMA)

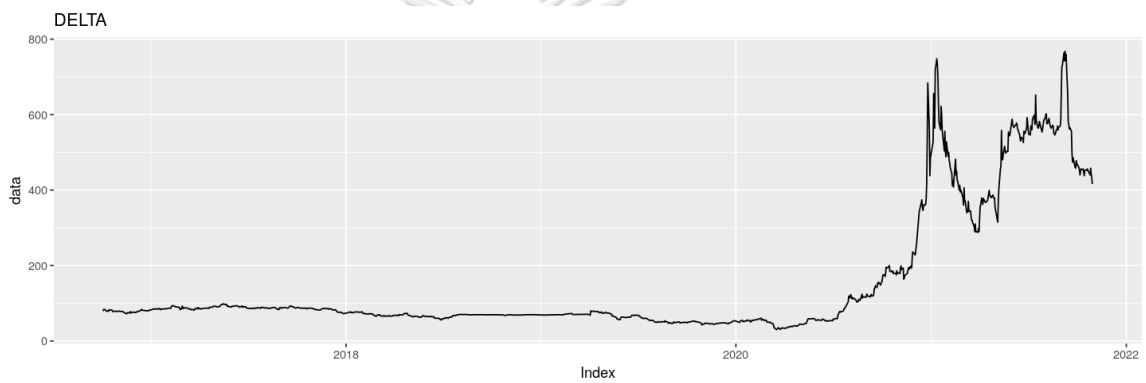
ในช่วงหลายปีที่ผ่านมากลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์มีพัฒนาการมาอย่างต่อเนื่อง เนื่องจากการพัฒนาอุปกรณ์อิเล็กทรอนิกส์เพื่อรองรับเทคโนโลยี 5G รวมทั้งยานยนต์อัจฉริยะหรือยานยนต์เชื่อมต่อและขับเคลื่อนอัตโนมัติ (Connected and Autonomous Vehicle :CAV) ซึ่งนำไปสู่การเปลี่ยนแปลงสู่ยุคเทคโนโลยีสำหรับสินค้าไฮเทคที่สามารถเชื่อมต่อกับอุปกรณ์ต่างๆ ผ่านเครือข่ายอินเทอร์เน็ต (Internet of Things : IoT) ทำให้ความต้องการชิ้นส่วนทางอิเล็กทรอนิกส์ รวมไปถึงสินค้าอิเล็กทรอนิกส์ต่าง ๆ เช่น โทรศัพท์, แท็บเล็ต, โน้ตบุ๊ก รวมถึงคอมพิวเตอร์ตั้งโต๊ะมีการเติบโตสูงขึ้น โดยเฉพาะในภาวะโรคระบาดซึ่งส่งผลให้ความต้องการอุปกรณ์อิเล็กทรอนิกส์เพื่อการศึกษหรือทำงาน

ระยะใกล้มีปริมาณเพิ่มมากขึ้น ประกอบกับปัญหาการขาดแคลน IC โดยเฉพาะสำหรับรถยนต์ และการเร่งลงทุนใหม่รวมถึงการเข้ามาตั้งฐานผลิตในไทยเพิ่มขึ้นของประเทศผู้นำด้านเทคโนโลยีการผลิตสินค้าอิเล็กทรอนิกส์ ยิ่งทำให้หุ้นกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์มีมูลค่าเพิ่มสูงขึ้น อย่างไรก็ตาม ปัจจัยอื่น ๆ เช่น การเพิ่มขึ้นของค่าจ้างแรงงานไทย รวมถึงการพัฒนาเทคโนโลยีในอุตสาหกรรมสนับสนุนที่ล่าช้าและการเติบโตของประเภทสินค้าอิเล็กทรอนิกส์ในห่วงโซ่การผลิตของโลกที่เปลี่ยนแปลงอย่างรวดเร็ว กลับส่งผลให้ต้นทุนการผลิตสินค้าอิเล็กทรอนิกส์ของไทยเพิ่มสูงขึ้น [3] ซึ่งเป็นที่ทราบกันดีว่านักลงทุนที่ประสบความสำเร็จจำเป็นต้องมีการวางแผนการลงทุนในอนาคตที่ดี จากปัญหาความผันผวนของหุ้นกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ดังกล่าวจึงเป็นสาเหตุจูงใจให้ผู้จัดทำโครงการนี้มีแนวคิดในการพยากรณ์ราคาปิดหุ้นรายวันในอนาคตด้วยวิธีพยากรณ์ต่าง ๆ ภายใต้ตัวอย่างหุ้นที่ถูกเลือกมาตามระดับความผันผวนของราคาหุ้น โดยที่ระดับความผันผวนของราคาหุ้นนั้นถูกแสดงด้วยค่าเบต้า ซึ่งเป็นตัวชี้วัดเชิงปริมาณของความผันผวนของราคาหุ้นนั้น ๆ เทียบกับดัชนีตลาดหุ้นโดยรวม ซึ่งในงานวิจัยนี้ได้เลือกหุ้นกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ โดยใช้ค่าเบต้าจาก www.settrade.com โดยหุ้นที่มีค่าเบต้ามากกว่า 1 จะมีความผันผวนมากกว่าตลาดหุ้นโดยรวม ในขณะที่หุ้นที่มีค่าเบต้าประมาณ 1 จะเป็นหุ้นที่มีความผันผวนระดับกลางที่เคลื่อนไหวในราคาใกล้เคียงและทิศทางเดียวกับตลาดโดยรวม (SET INDEX) และหุ้นที่มีค่าเบต่าน้อยกว่า 1 แต่มากกว่า 0 จะเป็นหุ้นที่มีความผันผวนของราคาในระดับที่ต่ำกว่าแต่เป็นไปในทิศทางเดียวกันกับตลาดโดยรวม [4] เช่น หุ้นหนึ่งซึ่งมีค่าเบต้าเท่ากับ 0.2 เมื่อตลาดโดยรวมเพิ่มขึ้น 10% ราคาหุ้นนี้จะเพิ่มขึ้น 2% ทั้งนี้ความเสี่ยงในการลงทุนจะแปรผันตรงกับความผันผวนของราคา ซึ่งเพื่อหลีกเลี่ยงความเอนเอียงที่เกิดจากภาวะโรคระบาดตั้งแต่ปี พ.ศ. 2563 เป็นต้นไป จึงใช้ค่าเบต้าในปี พ.ศ. 2562 เป็นเกณฑ์ในการเลือกหุ้นตามความผันผวนของราคาหุ้นจากระดับสูงไประดับต่ำ ได้แก่ หุ้น HANA, หุ้น DELTA และหุ้น SVI (ดังที่แสดงภาพกราฟราคาปิดรายวันของหุ้นในภาพ 1.1, ภาพ 1.2 และภาพ 1.3 ตามลำดับ) โดยใช้ตัวแบบต่าง ๆ เช่น อาร์มา (Autoregressive Integrated Moving Average Model : ARIMA), โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) และตัวแบบผสม (Hybrid) ในการพยากรณ์ราคาของหุ้น โดยคาดหวังว่าจะเป็นประโยชน์แก่นักลงทุนและบุคคลทั่วไปที่ต้องการลงทุนในหุ้นกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ เพื่อช่วยให้นักลงทุนได้ทราบถึงตัวแบบที่เหมาะสมสำหรับพยากรณ์ราคาปิดรายวันของกลุ่มตัวอย่างหุ้นอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ที่ถูกเลือกมาเพื่อช่วยในการตัดสินใจในการ

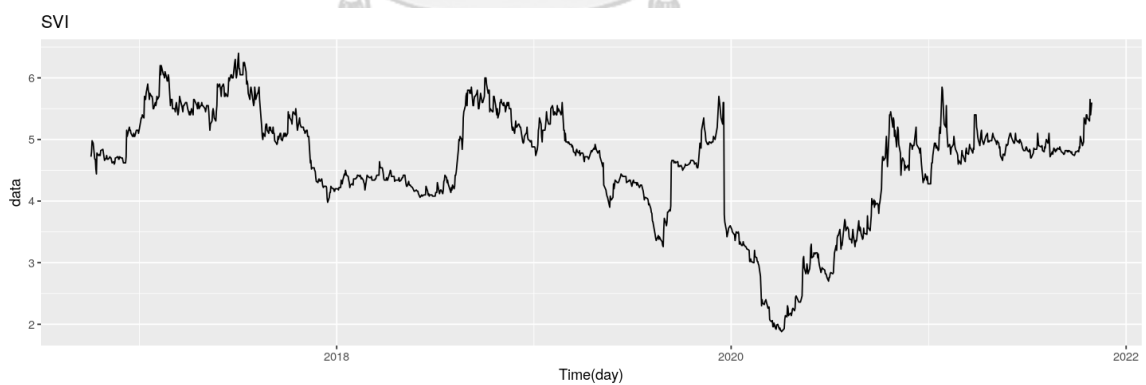
ลงทุนในหุ้นได้ดียังขึ้น



ภาพ 1.1 แสดงราคาปิดรายวันของหุ้น HANA ตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564



ภาพ 1.2 แสดงราคาปิดรายวันของหุ้น DELTA ตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564



ภาพ 1.3 แสดงราคาปิดรายวันของหุ้น SVI ตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564

บริบทของปัญหา

จากปัญหาดังกล่าวจึงเป็นสาเหตุสูงใจให้ผู้จัดทำโครงการนี้มีแนวคิดในการพยากรณ์ราคาหุ้นในอนาคตด้วยวิธีพยากรณ์ต่าง ๆ ภายใต้วงศ์อย่างหุ้นที่ถูกเลือกมา โดยใช้ตัวแบบต่าง ๆ เช่น ARIMA (Autoregressive Integrated Moving Average Model : ARIMA), โครงข่ายประสาทเทียม (Artificial Neural Network :ANN) และตัวแบบผสม (Hybrid) ในการพยากรณ์ราคาของหุ้น โดยคาดหวังว่าจะเป็นประโยชน์แก่นักลงทุนและบุคคลทั่วไปที่ต้องการลงทุนในหุ้นในระยะยาว

วัตถุประสงค์ของการวิจัย

เพื่อวิเคราะห์ว่าแบบจำลองแบบใดมีความเหมาะสมภายใต้กลุ่มตัวอย่างหุ้นที่ถูกเลือกมา

สมมติฐานการวิจัย

Hybrid มีประสิทธิภาพในการพยากรณ์ราคาหุ้นที่สุด

ขอบเขตของการวิจัย

1. ข้อมูลราคาหุ้นที่ใช้ในการศึกษาในที่นี้จะเป็นราคาปิดรายวันของหุ้นตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564 (5 ปีย้อนหลัง)
2. โดยเลือกหุ้นตามระดับความผันผวนของหุ้นในปีพ.ศ. 2562 ในอุตสาหกรรมเดียวกัน จำนวน 1 อุตสาหกรรม โดยเลือกอุตสาหกรรมละ 3 หุ้น คือ หุ้นในกลุ่มอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ ได้แก่ หุ้นที่มีความผันผวนมาก คือ HANA, หุ้นที่มีความผันผวนต่ำ คือ SVI และหุ้นที่มีความผันผวนปานกลาง คือ DELTA
3. ตัวแบบพยากรณ์ ได้แก่ ARIMA, ANN, และ ARIMA-ANN

เงื่อนไขที่สำคัญของการวิจัย

1. คำจำกัดความของงานวิจัย

คำศัพท์	คำจำกัดความของคำศัพท์
ANN	Artificial Neural Network
ARIMA	Autoregressive Integrated Moving Average Model

2. ข้อยกเว้นงานวิจัย

ในงานวิจัยนี้อาจมีข้อยกเว้นบางประการ เช่น

- 2.1 ตัวอย่างหุ้นที่นำมาวิจัยถูกเลือกมาจากหมวดธุรกิจและเทคโนโลยีและขึ้นส่วนอิเล็กทรอนิกส์เท่านั้น โดยที่หุ้นดังกล่าวนั้นไม่มีการแตกพาร์ระหว่างที่ชุดข้อมูลถูกเก็บรวบรวม
- 2.2 อาจมีตัวแปรอื่น ๆ ที่ส่งผลต่อราคาของหุ้นที่ผู้วิจัยไม่ได้นำมาวิเคราะห์ ซึ่งอาจส่งผลกระทบต่อพยากรณ์ราคาหุ้น
- 2.3 ในการวิจัยนี้เลือกหุ้นตามระดับความผันผวนของราคาในปีพ.ศ. 2562 เท่านั้น ซึ่งอาจไม่ได้แสดงระดับความผันผวนที่แท้จริงของตัวอย่างหุ้นที่ถูกเลือกมาภายในระยะเวลาที่ข้อมูลถูกเก็บรวบรวม

วิธีดำเนินการวิจัย

1. กำหนดปัญหา
2. ค้นคว้าเอกสาร ทฤษฎี และกรอบแนวคิดที่เกี่ยวข้อง
3. เก็บรวบรวมข้อมูลราคาหุ้น
4. เขียนโครงร่างวิทยานิพนธ์เพื่อกำหนดขอบเขตการทำงาน
5. สร้างตัวแบบพยากรณ์ราคาหุ้นและเปรียบเทียบประสิทธิภาพที่ได้รับ
6. นำเสนอโครงร่างวิทยานิพนธ์
7. วิเคราะห์ข้อมูลเพื่อเปรียบเทียบผลที่ได้ และสรุปผลการศึกษา
8. นำเสนอวิทยานิพนธ์
9. จัดทำรูปเล่มวิทยานิพนธ์

ข้อมูล

ข้อมูลทุติยภูมิจาก efinancethai

แนวทางการวิเคราะห์ข้อมูลและสถิติที่ใช้ในการวิเคราะห์

$$\text{Mean Percentage Error : MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right|$$

เมื่อ n แทนจำนวนทั้งหมดของ observations

Y_i แทนค่าสังเกตของข้อมูลอนุกรมเวลา ณ เวลา i

\hat{Y}_i แทนข้อมูลส่วนที่พยากรณ์ด้วยตัวแบบต่าง ๆ ณ เวลา i

และเลือกตัวแบบที่ให้ค่า MAPE ต่ำสุด

การสรุปผลวิเคราะห์ข้อมูล

นำเสนอข้อมูลในรูปแบบกราฟและตาราง เพื่อตรวจสอบดูว่าวิธีการแบบใดให้ผลดีกว่ากัน

ปีที่ทำวิจัย / ระยะเวลา

สิงหาคม 2564 – พฤษภาคม 2565 / ระยะเวลาทั้งสิ้น 10 เดือน

ปฏิทินดำเนินการวิจัย

แผนการดำเนินงาน	ระยะเวลา									
	พ.ศ. 2564					พ.ศ. 2565				
	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.
กำหนดปัญหา										
ศึกษาทฤษฎี และกรอบแนวคิดที่เกี่ยวข้อง										
เก็บรวบรวมข้อมูลราคาหุ้น										
สร้างตัวแบบพยากรณ์ราคาหุ้นและเปรียบเทียบประสิทธิภาพที่ได้รับ										
เขียนโครงร่างวิทยานิพนธ์เพื่อกำหนดขอบเขตการทำงาน										
นำเสนอโครงร่างวิทยานิพนธ์										
วิเคราะห์ข้อมูลเพื่อเปรียบเทียบผลที่ได้และสรุปผลการศึกษา										
นำเสนอวิทยานิพนธ์										
จัดทำรูปเล่มวิทยานิพนธ์										

ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

นักลงทุนและบุคคลทั่วไป

1. ช่วยในการตัดสินใจในการลงทุนในหุ้นภายใต้กลุ่มตัวอย่างของอุตสาหกรรมเทคโนโลยี และชิ้นส่วนอิเล็กทรอนิกส์ที่ถูกเลือก โดยพิจารณาจากค่าพยากรณ์มูลค่าของหุ้นในอนาคต
2. ช่วยให้นักลงทุนทราบถึงตัวแบบที่เหมาะสมสำหรับพยากรณ์ราคาของกลุ่มตัวอย่างหุ้นของอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ที่ถูกเลือกมา



บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 แนวคิดและทฤษฎี

1. การวิเคราะห์อนุกรมเวลา

อนุกรมเวลา คือ เซตข้อมูลเชิงปริมาณที่มีการจัดเก็บเป็นช่วงเวลาที่ต่อเนื่องกัน (Continuous) [3] โดยมี index ขึ้นกับเวลา กล่าวคือ มีการจัดเรียงตามเวลาที่บันทึกข้อมูลนั้นโดยที่มีระยะห่าง (scale) เท่า ๆ กัน เช่น รายได้ต่อเดือน ต่อไตรมาส หรือต่อปีของบริษัทตลอด 3 ปี, ปริมาณน้ำฝนต่อเดือน ตั้งแต่ปี 2568 ถึง 2570, ข้อมูลรายได้เฉลี่ยของเกษตรกรไทยรายวันตั้งแต่ต้นเดือน ม.ค. ถึงปลายเดือน ธ.ค. ตลอดจนดัชนีตลาดหลักทรัพย์ในแต่ละวันเมื่อปิดทำการซื้อขายในแต่ละวัน เป็นต้น

ในชีวิตประจำวัน ปัญหาทางอนุกรมเวลาที่สำคัญอาจเกิดขึ้นได้หลากหลายรูปแบบ เช่น ในทางการแพทย์ การติดตามและสังเกตการวัดความดันโลหิตในช่วงเวลาหนึ่งอาจเป็นประโยชน์สำหรับการประเมินยาที่ใช้ในการรักษาภาวะเครียดมากเกินไป หรือการติดตามชุดประชากรต่าง ๆ ของนักสังคมศาสตร์ เช่น อัตราการเกิดหรือการลงทะเบียนเรียนในโรงเรียน ตลอดจนตัวเลขการว่างงานรายเดือน หรือราคาหุ้นรายวัน เป็นต้น [20]

ซึ่งวิธีวิเคราะห์อนุกรมเวลามีด้วยกันหลายวิธี เนื่องจากข้อมูลอนุกรมเวลาส่วนใหญ่มักมีโครงสร้างซึ่งมีส่วนประกอบที่เป็นเชิงเส้นและไม่เชิงเส้น [8] จึงทำให้สามารถจำแนกวิธีการวิเคราะห์ออกเป็นสองส่วนโดยสังเขป ได้แก่ วิธีการวิเคราะห์แบบเชิงเส้น เช่น ARIMA (Autoregressive Integrated Moving Average Model : ARIMA) และวิธีการวิเคราะห์แบบไม่เชิงเส้น เช่น โครงข่ายประสาทเทียม (Artificial Neural Network : ANN)

1.1 วิธี ARIMA

(Autoregressive Integrated Moving Average Model : ARIMA) เป็นเทคนิคซึ่งได้รับการเสนอโดย Box and Jenkins (1970) เพื่อพยากรณ์อนุกรมเวลา [5] เป็นหนึ่งในตัวแบบทางสถิติที่ได้รับความนิยมเป็นอย่างมากในการพยากรณ์ความสัมพันธ์ที่เป็นเชิงเส้นตรง [7] โดยการพยากรณ์ด้วยวิธีนี้จะการอาศัยพฤติกรรมของตัวข้อมูลในอดีต มาใช้กำหนดรูปแบบในปัจจุบัน แล้วอธิบายแนวโน้มหรือปรากฏการณ์ต่างๆ ในอนาคต [4] จึงเป็นวิธีที่เหมาะสมกับการพยากรณ์ข้อมูลอนุกรมเวลา [8] เนื่องจากมีค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง (Mean Square Error : MSE) ต่ำ จึงทำให้วิธีนี้นั้นพยากรณ์ระยะสั้นได้ดี [9] โดยวิธี ARIMA (p,d,q) สามารถอธิบายได้ดังนี้

1. แบบจำลอง AR(p) (Autoregressive Process: AR(p)) เป็นแบบจำลองที่ตั้งอยู่บนสมมติฐานซึ่งค่าของอนุกรมเวลา Y_t นั้นขึ้นอยู่กับค่าสังเกตของอนุกรมเวลาในอดีตที่เคยเกิดขึ้น p ค่า โดย p คือ preceding term หรือ lagged term ของ Autoregressive term ดังสมการที่ 2.1

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.1)$$

โดย ε_t แทน white noise หรือค่าคลาดเคลื่อน ณ เวลา t

2. แบบจำลอง MA(q) (Moving Average Process: MA(q)) เป็นแบบจำลองที่ตั้งอยู่บนสมมติฐานซึ่งอนุกรมเวลา Y_t นั้นขึ้นอยู่กับค่าความคลาดเคลื่อนทั้งในอดีต ($\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$) หรือค่าความคลาดเคลื่อนที่เกิดขึ้นในอดีตเป็นจำนวน q ค่าและในปัจจุบัน (ε_t) โดย q คือ จำนวนของระยะห่าง (lagged term) ของค่าความคลาดเคลื่อนตั้งแต่อดีตจนถึงปัจจุบัน และ ε_h แทน white noise หรือค่าคลาดเคลื่อน ณ เวลา h เมื่อ $t \leq h \leq t - q$ ดังสมการที่ 2.2

$$Y_t = \mu + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q} \quad (2.2)$$

3. แบบจำลอง ARMA(p,q) (Autoregressive and Moving Average Process: ARMA(p,q)) เป็นแบบจำลองซึ่งประกอบด้วยทั้งแบบจำลอง AR และแบบจำลอง MA ดังนั้นจึงเป็นแบบจำลองที่ตั้งอยู่บนสมมติฐานว่าอนุกรมเวลา Y_t นั้นขึ้นอยู่กับทั้งค่าสังเกตของอนุกรมเวลาในอดีตรวมถึงค่าความคลาดเคลื่อนตั้งแต่อดีตจนถึงปัจจุบัน ดังสมการที่ 2.3

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q} \quad (2.3)$$


4. Integrated (I(d)) เป็นการหาผลต่างของอนุกรมเวลา Y_t ซึ่ง d คือจำนวนครั้งของการแปลงอนุกรมเวลา Y_t ซึ่งมีคุณสมบัติไม่คงที่ (Non-stationary) ให้มีคุณสมบัติคงที่ (Stationary) เพื่อให้ค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐานของข้อมูลไม่แปรผันตามเวลาที่เปลี่ยนไป ดังนั้น ก่อนที่จะสามารถนำข้อมูลอนุกรมเวลาดังกล่าวนี้ไปสร้างแบบจำลอง ARIMA เป็นลำดับถัดไป จึงมีความจำเป็นที่จะต้องหาผลต่างของอนุกรมเวลา (ผลต่างอันดับที่ d) สำหรับอนุกรมเวลาเพื่อทำให้อนุกรมเวลาคงที่เสียก่อน ซึ่งโดยทั่วไปแล้วผลต่างอันดับที่ d สามารถเขียนในรูปของ I(d) ดังนี้

$$\Delta_d Y_t = \Delta_{d-1} (Y_t - Y_{t-1}) \text{ หรือ } (1-B)^d Y_t \quad (2.4)$$

1.2 ANN

โครงข่ายประสาทเทียม (Artificial Neural Network :ANN) เป็นหนึ่งในตัวแบบการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised learning) โดยตัวแบบนี้ถูกพัฒนาจากการลอกเลียนแบบโครงข่ายประสาทของสิ่งมีชีวิตเพื่อใช้ในการจำแนกและการทำนาย ซึ่งได้รับความนิยมอย่างกว้างขวางและถูกประยุกต์ใช้ในงานวิจัยต่างๆ [10] - [17] ในช่วงหลายสิบปีที่ผ่านมา เป็นวิธีที่ไม่จำเป็นต้องมีข้อตกลงเบื้องต้น และยังสามารถวิเคราะห์ข้อมูลได้โดยไม่ขึ้นกับรูปแบบการแจกแจงของข้อมูล (distribution) [19] เป็นวิธีที่นำข้อดีของระบบประสาทมาใช้ในการทำงานร่วมกับความสามารถของคอมพิวเตอร์ จึงสามารถเรียนรู้จากประสบการณ์จากในอดีตเพื่อจำแนกลักษณะของสิ่งของที่มีคุณสมบัติคล้ายคลึงกัน รวมไปถึงการแปลความหมายจากภาพและสัญลักษณ์ต่าง ๆ นอกจากนี้ งานด้านการพยากรณ์เองก็เป็นงานอีกประเภทหนึ่งซึ่งสามารถนำโครงข่ายประสาทเทียมหรือตัวแบบ ANN มาประยุกต์ใช้งานได้ เนื่องจากตัวแบบ ANN สามารถเรียนรู้รูปแบบของข้อมูลที่มีความซับซ้อนจึงเป็นวิธีที่สามารถใช้ในการพยากรณ์ได้ดีกว่าวิธีที่ใช้ในการพยากรณ์แบบดั้งเดิม ดังเช่นที่ Delugio [18] ได้เคยกล่าวไว้ โดยในหน่วยประมวลผลย่อย (node) ซึ่งเป็นที่เกิดกระบวนการประมวลผลของตัวแบบ สำหรับแต่ละหน่วยประมวลผลย่อยในโครงข่ายประสาทเทียมนั้นจะมีข้อมูลนำเข้าหลายค่าผ่านเข้ามา ซึ่งแต่ละค่านั้นจะถูกคูณด้วยค่าถ่วงน้ำหนัก (weight) แล้วนำผลรวมของผลคูณที่ได้ส่งผ่านไปยังฟังก์ชันกระตุ้น (activation function) เพื่อหาผลลัพธ์ออกมา และทำการส่งไปยังหน่วยประมวลผลย่อยต่อไป [7] ดังสมการที่ 2.5 และภาพ 1.4 ด้านล่าง [20]

$$S = \sum_{i=1}^n W_i X_i + b \quad (2.5)$$



ภาพ 1.4 แบบจำลองการทำงานของโครงข่ายประสาทเทียม

ทั้งนี้ตัวแบบ ANN ซึ่งนิยมในการใช้พยากรณ์อนุกรมเวลาคือ โครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น (multi-layer perceptron : MLP) ซึ่งเป็นโครงข่ายประสาทเทียมที่มีโครงสร้างจำนวนหลายชั้น [7] เหมาะสำหรับงานที่มีความซับซ้อน โดยมีโครงสร้างประกอบด้วยชั้นข้อมูลนำเข้า (input layer), ชั้นซ่อน (hidden layer) และชั้นผลลัพธ์ (output layer) ทำงานต่อเนื่องกันจากด้านซ้ายไปด้านขวาของโครงสร้าง ทั้งนี้สำหรับแต่ละชั้นหรือแต่ละ layer จะประกอบด้วยหน่วยประมวลผลย่อยหรือ node ซึ่งจะมีกี่หน่วยก็ได้ในแต่ละชั้น ซึ่ง node ในชั้นข้อมูลนำเข้านั้นจะเชื่อมต่อกับ node ในชั้นซ่อนที่อยู่ถัดไปในทุกๆ node และ node ที่อยู่ในชั้นซ่อนดังกล่าวก็จะเชื่อมต่อกับ node ที่อยู่ในชั้นถัดไป ตามลำดับ ซึ่งส่งผลให้เอาต์พุตหรือผลลัพธ์ของ node หนึ่งกลายเป็นอินพุตของ node ที่อยู่ถัดไป จนถึงชั้นผลลัพธ์ ซึ่งสามารถเขียนในรูปสมการที่ 2.6 ซึ่งถูกอ้างอิงจาก นัท กุลวานิช [7] ได้ดังนี้

$$Y_t = \alpha + \sum_{j=1}^n \alpha_j f(\beta_{ij} Y_{t-1} + \beta_j) + \varepsilon_t \quad (2.6)$$

เมื่อ Y_t แทนค่าจริงของข้อมูลอนุกรมเวลา ณ เวลา t

α แทนเวกเตอร์ของค่าถ่วงน้ำหนักระหว่าง node จำนวน n หน่วย ในชั้นซ่อน กับ node ในชั้นผลลัพธ์

β_{ij} แทนค่าถ่วงน้ำหนักระหว่าง node แต่ละหน่วย จำนวน m หน่วย ในชั้นข้อมูลนำเข้า กับ node ใน hidden layer โดยที่ $i = 1, 2, \dots, m$ และ $j = 1, 2, \dots, n$

β_j แทนค่าถ่วงน้ำหนักระหว่าง node แต่ละหน่วยซึ่งอยู่ในชั้นซ่อน โดยที่ $j = 1, 2, \dots, n$

f แทนฟังก์ชันกระตุ้น เช่น sigmoid logistic function หรือ $f(x) = \frac{1}{(1 + e^{-x})}$

, rectified linear activation function หรือ $f(x) = \max(0, x)$

ε_t แทนค่า error term หรือค่าของความคลาดเคลื่อน ณ เวลา t

1.3 ตัวแบบผสม ARIMA และ ANN (hybrid model, ARIMA - ANN)

ดังเช่นที่ นัท กุลวานิช [7] กล่าวไว้ว่า โครงสร้างอนุกรมเวลาโดยส่วนมาก มักประกอบด้วย ส่วนที่เป็นเชิงเส้นและไม่เชิงเส้น ดังนั้นการใช้ตัวแบบ ARIMA ซึ่งเป็นตัวแบบเชิงเส้นตรง ร่วมกับ โครงข่ายประสาทเทียมซึ่งเป็นตัวแบบที่ไม่เป็นเชิงเส้นตรง จึงสามารถอธิบายความเปลี่ยนแปลงของ ข้อมูลอนุกรมเวลาได้ดียิ่งขึ้น เพื่อเพิ่มความแม่นยำในการพยากรณ์ Zhang [10] จึงได้เสนอตัวแบบ ผสมระหว่างตัวแบบดังกล่าว ซึ่งภายหลังได้มีผู้วิจัยใช้ตัวแบบผสมดังกล่าวในงานวิจัยด้านการ พยากรณ์อนุกรมเวลา เช่น ชยกร สมศิลา และคณะ [11] ชญานิน บุญมานะ และ นัท กุลวานิช [12] พงษ์ศิริ ศิริพาณิชย์ และคณะ [13] Ebrahimi [14] Koutroumanidis และคณะ [15] Meth และ คณะ [16] และ Faruk [17] ซึ่งงานวิจัยในข้างต้นทั้งหมดล้วนแล้วแต่ได้รับข้อสรุปผลแบบเดียวกัน นั่นคือ ตัวแบบผสมระหว่างตัวแบบดังกล่าวนี้มีความแม่นยำสูงกว่าการใช้ตัวแบบ ARIMA โดย ลำพัง โดยตัวแบบผสมระหว่างตัวแบบ ARIMA และโครงข่ายประสาทเทียม สามารถแสดงได้ดัง สมการที่ 2.7 ดังนี้ [7]

$$Y_t = F_t^{ARIMA} + F_t^{ANN} + \varepsilon_t \quad (2.7)$$

เมื่อ Y_t แทนค่าจริงของข้อมูลอนุกรมเวลา ณ เวลา t

F_t^{ARIMA} แทนค่าพยากรณ์ซึ่งถูกพยากรณ์ด้วยตัวแบบ ARIMA (ส่วนที่เป็นฟังก์ชันเชิงเส้นตรง ของอนุกรมเวลา)

F_t^{ANN} แทนค่าพยากรณ์ซึ่งพยากรณ์ด้วยโครงข่ายประสาทเทียมหรือตัวแบบ ANN (ส่วนที่ไม่ เป็นฟังก์ชันเชิงเส้นตรงของอนุกรมเวลา)

ε_t แทน error term หรือค่าของความคลาดเคลื่อน ณ เวลา t โดย $\hat{\varepsilon}_t = Y_t - \hat{F}_t^{ARIMA}$

ซึ่งขั้นตอนในการสร้างตัวแบบผสมนั้นสามารถอธิบายได้ดังต่อไปนี้

1) ทำการพยากรณ์ข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในอนุกรมเวลาด้วยตัวแบบ ARIMA คือ

$$\hat{F}_t^{ARIMA}$$

2) ทำการคำนวณเศษที่เหลือ ($\hat{\varepsilon}_t$) จากการพยากรณ์ด้วยตัวแบบ ARIMA ดังกล่าว

3) ทำการพยากรณ์ค่าส่วนที่เหลือซึ่งถือว่าเป็นข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงจากขั้นตอนที่ 2

ด้วยตัวแบบ ANN ซึ่งในที่นี้คือ \hat{F}_t^{ANN}

4) ทำการรวมค่าพยากรณ์ที่ได้จากขั้นตอนที่ 1 และขั้นตอนที่ 3 จากสมการที่ 2.7 ซึ่ง

$$Y_t = \hat{F}_t^{ARIMA} + \hat{F}_t^{ANN}$$

2.2 งานวิจัยที่เกี่ยวข้อง

ราคาทุเรียนไทยที่ขายทั้งในประเทศและต่างประเทศได้ถูกพยากรณ์ด้วยวิธีการพยากรณ์แบบ Box-Jenkins โดยนายไพศาล เรืองฤทธิ์ [21] ซึ่งได้ทำการเก็บรวบรวมข้อมูลเป็นเวลา 162 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2550 ถึงเดือนมิถุนายน พ.ศ. 2563 โดยผลวิจัยพบว่า SARIMA(2,1,2)(0,1,1)₁₂ และ SARIMA(1,1,1)(0,1,1)₁₂ เป็นตัวแบบที่เหมาะสมต่อการคาดการณ์ราคาทุเรียนไทยทั้งที่ขายในประเทศและนอกประเทศ ด้วยความแม่นยำร้อยละ 91.9 และร้อยละ 97.7 ตามลำดับ และราคามีแนวโน้มเพิ่มขึ้นทั้งในปี พ.ศ. 2563 และปีพ.ศ. 2564

อนุชิตา อนันต์ทรัพย์สุข และนัท กุลวานิช [22] ทำการเปรียบเทียบประสิทธิภาพการพยากรณ์ของแบบจำลอง SARIMA, ตัวแบบผสมระหว่าง SARIMA - ANN รวมถึงตัวแบบผสมระหว่าง SARIMA - SVM (Support Vector Machine : SVM) ในการคาดการณ์ชุดข้อมูลจริงและชุดข้อมูลจำลองของราคาขายปลีกของผลผลิตมะนาวขนาด 1 และ 2 ผลการวิจัยพบว่าตัวแบบผสมล้วนมีประสิทธิภาพเหนือกว่า SARIMA ในการคาดการณ์ราคาขายปลีกของผลผลิตมะนาวทั้งในชุดข้อมูลจริง และชุดข้อมูลจำลอง ซึ่งตัวแบบผสมระหว่าง SARIMA - ANN มีประสิทธิภาพมากที่สุดในชุดข้อมูลจริง

กำธร ตันศิริรุ่งเรือง และ สมพร บันโกษา [23] ได้เก็บรวบรวมข้อมูลจากธนาคารไทยพาณิชย์ ธนาคารกสิกรไทย และธนาคารกรุงเทพ เป็นเวลา 6 ปี เพื่อพยากรณ์ราคาหุ้นในกลุ่มธนาคารพาณิชย์ในอีก 1 ปีข้างหน้า ด้วยแบบจำลอง ARIMA และ ARIMAX โดยใช้ MAPE และ RMSE (Root Mean Square Error : MAPE) เป็นเกณฑ์ในการคัดเลือกตัวแบบ ผลการวิจัยพบว่า แบบจำลอง ARIMA และแบบจำลอง ARIMAX ในปีพ.ศ. 2562 มีประสิทธิภาพในการคาดการณ์ราคาหุ้นไม่มาก ในขณะที่ในปี พ.ศ. 2561 แบบจำลองทั้งสองโดยเฉพาะอย่างยิ่งแบบจำลอง ARIMAX สามารถคาดการณ์ราคาหุ้นได้แม่นยำกว่าแบบจำลองในปีพ.ศ. 2562 อย่างเห็นได้ชัดรวมถึงราคาคาดการณ์ที่ได้จากตัวแบบนั้นใกล้เคียงกับราคาจริงของหุ้น คาดว่ามีปัจจัยภายนอกซึ่งส่งผลกระทบต่อราคาหุ้นในปีพ.ศ. 2562 เป็นผลให้แบบจำลองให้ค่าพยากรณ์ไม่แม่นยำในปีดังกล่าว

ชญาสิน บุญมานะ และนัท กุลวานิช [12] เปรียบเทียบประสิทธิภาพที่ได้จากการทำนายราคาปิดหุ้น SCB ด้วยตัวแบบ ARIMA, ตัวแบบผสมระหว่าง ARIMA - ANN และตัวแบบผสมระหว่าง ARIMA - SVM (Support Vector Machine : SVM) โดยใช้ชุดข้อมูลจริงและชุดข้อมูลซึ่งถูกจำลองด้วยแบบจำลอง ARIMA โดยใช้ MAPE และ RMSE เป็นเกณฑ์ในการคัดเลือกตัวแบบ ผลการวิจัยพบว่าตัวแบบผสมระหว่าง ARIMA - SVM มีความแม่นยำในการพยากรณ์สูงที่สุดในชุดข้อมูลทดสอบ ซึ่งสอดคล้องกับผลจากชุดข้อมูลจำลอง

รณชัย ชื่นรัชช [24] ได้ทำการพยากรณ์ค่าความหนาแน่นเฉลี่ยของฝุ่นละออง PM10 รายวันในภาคเหนือ โดยใช้ข้อมูลจำนวนสามชุด สร้างตัวแบบพยากรณ์ผสมระหว่าง AR-ANN ผลการวิจัยพบว่าตัวแบบผสมผสาน AR-ANN ให้ค่า RMSE และ MAPE ที่ต่ำกว่าตัวแบบพยากรณ์ ARIMA ดังนั้นจึงสามารถสรุปได้ว่าตัวแบบพยากรณ์ AR-ANN เป็นตัวแบบที่เหมาะสมในการพยากรณ์ค่าความหนาแน่นของฝุ่นละออง PM10 ในภาคเหนือ

อดิษฐ์โอและคณะ [25] ทำการเปรียบเทียบประสิทธิภาพการพยากรณ์ของแบบจำลอง ANN และ ARIMA ในการคาดการณ์ข้อมูลอนุกรมเวลาของหุ้นจากตลาดหลักทรัพย์นิวยอร์ก ผลการศึกษาพบว่าทั้ง ANN และ แบบจำลอง ARIMA สามารถคาดการณ์ราคาหุ้นได้ดี โดยที่ ANN มีประสิทธิภาพมากกว่า

วิจยาและคณะ [26] แสดงการเปรียบเทียบระหว่างแบบจำลอง ANN และแบบจำลอง ARIMA ตามตลาดหลักทรัพย์อินโดนีเซีย ซึ่งผลลัพธ์พบว่าแบบจำลอง ANN ให้ประสิทธิภาพเหนือกว่าแบบจำลอง ARIMA

ถังและคณะ [27] กล่าวถึงผลการศึกษาเปรียบเทียบตัวแบบ ANN และ ARIMA ในการพยากรณ์อนุกรมเวลา ผลวิจัยพบว่าแบบจำลอง ARIMA พยากรณ์ระยะสั้นได้ดีกว่า ในขณะที่ ANN นั้นเหมาะสมกว่าสำหรับการพยากรณ์ระยะยาว

แม้นักวิจัยหลายคนแย้งว่าการรวมแบบจำลองจำนวนมากสำหรับการพยากรณ์เข้าด้วยกันจะให้ค่าประมาณที่ดีกว่าแบบจำลองอนุกรมเวลาเดียวกันก็ตาม เหมิเซลและเคซี่ [28] ได้ทำการสร้างตัวแบบผสมด้วยการรวมแบบจำลอง ARIMA และ TDNNs (Time-Delay Neural Network : TDNN) เพื่อคาดการณ์ชุดข้อมูลจริงแก่ชุด ผลลัพธ์แสดงให้เห็นว่าตัวแบบผสมดังกล่าวไม่จำเป็นต้องมีประสิทธิภาพดีกว่าการใช้แต่ละตัวแบบเพียงลำพัง เนื่องจากกระบวนการเลือกแบบจำลองมีส่วนสำคัญเป็นอย่างยิ่งต่อความนิยมในตัวแบบผสม

บทที่ 3

วิธีการวิจัย

โดยขั้นตอนการวิจัยสามารถอธิบายโดยสังเขปได้ดังนี้

1. **ศึกษาทฤษฎี และกรอบแนวคิดที่เกี่ยวข้อง** ดึงหัวข้อทฤษฎีและงานวิจัยที่เกี่ยวข้อง ในบทที่ 2
2. **เก็บรวบรวมข้อมูล** โดยเก็บรวบรวมข้อมูลราคาปิดรายวันของหุ้นตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564 (5 ปีย้อนหลัง) โดยเลือกหุ้นในกลุ่มอุตสาหกรรมเทคโนโลยีและขึ้นส่วนอิเล็กทรอนิกส์ ตามระดับความผันผวนของหุ้นในปีพ.ศ. 2562 จำนวน 3 หุ้น ได้แก่ หุ้นที่มีความผันผวนมาก คือ HANA, หุ้นที่มีความผันผวนปานกลาง คือ DELTA และหุ้นที่มีความผันผวนต่ำ คือ SVI

3. ขั้นตอนการแบ่งชุดข้อมูล

โดยแบ่งชุดข้อมูลออกเป็น 5 ส่วน ด้วยวิธีตรวจสอบไขว้ (rolling forward validation)

3.1 rolling forward validation แบบ cumulative

3.2 rolling forward validation แบบ moving window

4. ขั้นตอนการสร้างตัวแบบพยากรณ์ ตรวจสอบและทดสอบตัวแบบ

โดยใช้ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Percentage Error : MAPE) เป็นเครื่องมือในการเปรียบเทียบและตัดสินใจเลือกตัวแบบ

4.1 สร้างแบบจำลองในชุดข้อมูลฝึก (training set) และตรวจสอบเพื่อคัดเลือกตัวแบบในชุดข้อมูลตรวจสอบ (validation set)

โดยในงานวิจัยนี้ได้สร้างและเปรียบเทียบระหว่างตัวแบบต่าง ๆ ได้แก่ ARIMA, ANN, และ ARIMA-ANN ในการพยากรณ์ราคาปิดรายวันของหุ้น HANA, DELTA และ SVI ภายใต้การแบ่งชุดข้อมูลในข้อ 3.1 และ 3.2

แล้วทำการตรวจสอบตัวแบบเพื่อคัดเลือกตัวแบบในชุดข้อมูลตรวจสอบ โดยตัวแบบที่มีประสิทธิภาพหรือมีความแม่นยำมากที่สุดจะมีค่าเฉลี่ย MAPE ต่ำที่สุด

4.2 ทดสอบตัวแบบที่ได้จากข้อ 4.1 ในชุดข้อมูลทดสอบ (test set)

ต่อมาจึงใช้ตัวแบบที่ได้จากข้อ 4.1 นั้นมาสร้างตัวแบบพยากรณ์ราคาปิดรายวันของหุ้นอีก ครั้งในแต่ละหุ้น แล้วพยากรณ์ชุดข้อมูลทดสอบเป็นลำดับสุดท้าย ซึ่งในการวิจัยนี้จะแบ่งชุดข้อมูล 866 วันแรก (70 %) เป็นชุดข้อมูลฝึกและ 371 วันสุดท้าย (30 %) เป็นชุดข้อมูลทดสอบ

5. สรุปผลการวิจัย

ต่อไปจะทำการอธิบายหัวข้อที่ 3. ขั้นตอนการแบ่งชุดข้อมูลและหัวข้อที่ 4. ขั้นตอนการสร้างตัวแบบพยากรณ์ ตรวจสอบและทดสอบตัวแบบโดยละเอียด ดังต่อไปนี้

3. ขั้นตอนการแบ่งชุดข้อมูลด้วยวิธีตรวจสอบไปข้างหน้า (rolling forward validation)


การศึกษานี้ใช้ชุดข้อมูลราคาปิดรายวันของหุ้นตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564 (5 ปีย้อนหลัง) เป็นจำนวน 1,237 observations โดยเลือกหุ้นในกลุ่มอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ ตามระดับความผันผวนของหุ้นในปีพ.ศ. 2562 ได้แก่ หุ้นที่มีความผันผวนมาก คือ HANA, หุ้นที่มีความผันผวนปานกลาง คือ DELTA และ หุ้นที่มีความผันผวนต่ำ คือ SVI โดยเปรียบเทียบความแม่นยำระหว่างตัวแบบพยากรณ์ ได้แก่ ARIMA, ANN และ ARIMA - ANN (Hybrid)

ซึ่งอาศัยการแบ่งชุดข้อมูลออกเป็น 5 ส่วน ด้วยวิธีตรวจสอบไปข้างหน้า (rolling forward validation) ซึ่งจะแบ่งชุดข้อมูลออกเป็นชุดข้อมูลฝึก (training set) และชุดข้อมูลตรวจสอบ (validation set) ที่แตกต่างกันหลายชุด และข้อผิดพลาดในแต่ละส่วนจะถูกเฉลี่ยเพื่อคำนวณค่าประมาณข้อผิดพลาดของแบบจำลองให้แม่นยำและมีประสิทธิภาพยิ่งขึ้น จากนั้นจึงทำการสร้างแบบจำลองด้วยชุดข้อมูลที่ได้จากการแบ่งด้วยวิธีการดังกล่าวทั้ง 2 วิธี ได้แก่

1. rolling forward validation แบบ cumulative
2. rolling forward validation แบบ moving window

ซึ่งวิธี rolling forward validation แบบ cumulative นั้นเป็นวิธีที่จะสะสมข้อมูลเพิ่มขึ้นในทุก ๆ รอบของการสร้างแบบจำลอง ในขณะที่วิธี rolling forward validation แบบ moving window นั้นจะอาศัยข้อมูลชุดใหม่เป็นชุดข้อมูลฝึก (training set) ในแต่ละรอบของการสร้างแบบจำลอง ซึ่งสังเกตว่าทั้งสองวิธีจะใช้ชุด

ข้อมูลตรวจสอบ (validation set) ชุดเดียวกันในแต่ละรอบการสร้างแบบจำลอง ดังที่แสดงในภาพ 2.1 และภาพ 2.2 ตามลำดับ



(ภาพ 2.1 rolling forward validation แบบ cumulative) (ภาพ 2.2 rolling forward validation แบบ moving window)

แล้วจึงนำชุดข้อมูลฝึก (training set) ทั้งสองแบบที่ได้ไปสร้างตัวแบบในการพยากรณ์ราคาปิดของแต่ละหุ้นในแต่ละรอบเป็นลำดับต่อมา จากนั้นจึงเปรียบเทียบประสิทธิภาพของตัวแบบทั้งหมดในแต่ละหุ้น (ดังขั้นตอนที่ 4.1)

เกณฑ์ในการคัดเลือกตัวแบบ

โดยใช้ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Percentage Error : MAPE) เป็นเครื่องมือในการเปรียบเทียบและตัดสินเลือกตัวแบบ ในแต่ละวิธีการแบ่งชุดข้อมูลด้วยการ rolling forward validation โดยที่ตัวแบบที่ดีจะมีค่า MAPE ต่ำ และเลือกตัวแบบที่ให้ค่าเฉลี่ยของ MAPE ต่ำที่สุด อย่างไรก็ตามในงานวิจัยนี้จะแสดงค่าคลาดเคลื่อนกำลังสองเฉลี่ย (root mean square error : RMSE) ควบคู่ไปด้วยกัน โดย MAPE และ RMSE แสดงสมการดังสมการที่ 3.1 และ 3.2 ต่อไปนี้

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (3.1)$$


$$\text{และ } RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (3.2)$$

เมื่อ n แทนจำนวนทั้งหมดของ observations, Y_i แทนค่าสังเกตของข้อมูลอนุกรมเวลา ณ เวลา i

\hat{Y}_i แทนข้อมูลส่วนที่พยากรณ์ด้วยตัวแบบต่าง ๆ ณ เวลา i

ต่อมาจึงใช้ตัวแบบที่ได้นั้นมาสร้างตัวแบบพยากรณ์รายวันของหุ้นอีกครั้ง แล้วพยากรณ์ชุดข้อมูลทดสอบ (test set) เป็นลำดับสุดท้าย (ดังขั้นตอนที่ 4.2) ซึ่งในการวิจัยนี้จะแบ่งชุดข้อมูล 866 วันแรก (70 %) เป็นชุดข้อมูลฝึก (training set) และ 371 วันสุดท้าย (30 %) เป็นชุดข้อมูลทดสอบ (test set) ดัง

ภาพ 3.1



ภาพ 3.1 แสดงการแบ่งชุดข้อมูล 866 วันแรก (70 %) เป็น training set และ 371 วันสุดท้าย (30 %) เป็น test set ของตัวอย่างหุ้น HANA

4. ขั้นตอนการสร้างตัวแบบพยากรณ์ ตรวจสอบและทดสอบตัวแบบ

4.1 สร้างแบบจำลองในชุดข้อมูลฝึก (training set) และตรวจสอบเพื่อคัดเลือกตัวแบบในชุดข้อมูลตรวจสอบ (validation set) โดยศึกษาและเปรียบเทียบตัวแบบต่าง ๆ ต่อไปนี้

4.1.1 ARIMA


ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative และ moving window เพื่อสร้างชุดข้อมูลย่อยสำหรับใช้เป็น training set และ validation set แล้วจึงนำชุดข้อมูลที่ได้ไปสร้างตัวแบบเป็นลำดับถัดมา โดยการสร้างตัวแบบ ARIMA มีขั้นตอนดังนี้

1. กำหนดขอบเขตพารามิเตอร์: ไฮเปอร์พารามิเตอร์แนวโน้ม และไฮเปอร์พารามิเตอร์ฤดูกาล โดยให้ order ของพารามิเตอร์ดังกล่าวอยู่ในช่วง $[0,2]$ กล่าวคือ พารามิเตอร์ p, d, q ของ Non-seasonal ARIMA และ พารามิเตอร์ P, D, Q ของ Seasonal ARIMA ซึ่งมี lag คือ 365 นั้น มีค่าเป็นจำนวนเต็มได้ตั้งแต่ 0 ถึง 2

2. พิจารณาการสร้างตัวแบบ ARIMA ภายใต้ค่าพารามิเตอร์ที่อยู่ภายในช่วงที่กำหนด แล้วทำการหาตัวแบบที่เหมาะสมสำหรับพยากรณ์ราคาของหุ้นแต่ละตัวในแต่ละรอบด้วยวิธีการค้นหาแบบกริด โดยใช้ชุดข้อมูลที่ถูกแบ่งด้วยวิธี rolling forward validation ทั้งแบบ cumulative หรือแบบ moving window เป็นจำนวน 4 รอบ ดังภาพตัวอย่าง 3.2 โดยใช้ค่า MAPE เป็นเกณฑ์ในการตัดสินใจ ซึ่งตัวแบบที่เหมาะสมในแต่ละรอบนั้นจะให้ค่า MAPE ต่ำที่สุด เพื่อให้ตัวแบบนั้นมีค่ามีความแม่นยำในการพยากรณ์สูงที่สุดในแต่ละรอบ

3. คำนวณค่าเฉลี่ย MAPE และ RMSE

ซึ่งผลลัพธ์ค่าเฉลี่ย MAPE และ RMSE ของหุ้นแต่ละตัว จากขั้นตอนการวิจัยข้างต้น จะเป็นค่าที่ใช้ในการเปรียบเทียบความแม่นยำระหว่างตัวแบบ ARIMA และตัวแบบอื่น ๆ ในการวิจัยนี้



ภาพ 3.2 แสดงกราฟราคาปิดหุ้นรายวันระหว่าง training set, validation set และค่าพยากรณ์ (forecast) ของราคาปิดหุ้นรายวันจากตัวแบบ ARIMA ด้วยวิธีแบ่งข้อมูล rolling forward validation แบบ cumulative

4.1.2 โครงข่ายประสาทเทียม (Artificial Neural Network :ANN)

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative และ moving window เพื่อสร้างชุดข้อมูลย่อยสำหรับใช้เป็น training set และ validation set แล้วจึงนำชุดข้อมูลที่ได้ไปสร้างตัวแบบ ANN เป็นลำดับถัดมา โดยการสร้างตัวแบบ ANN มีขั้นตอนดังนี้

1. กำหนดขอบเขตไฮเพอร์พารามิเตอร์ ได้แก่ ชั้นข้อมูลนำเข้า 1 ชั้น ภายใต้อำนาจ 60 โหนด (node), ชั้นผลลัพธ์ 1 ชั้นภายใต้อำนาจ 1 โหนด, จำนวนชั้นซ่อนหรือ hidden layer ไม่เกิน 3 ชั้นภายใต้อำนาจโหนดอยู่ในช่วง (0,100) และใช้ฟังก์ชัน Rectified Linear Activation Function หรือ RELU เป็นฟังก์ชันกระตุ้น รวมถึงใช้ฟังก์ชันทางคณิตศาสตร์คำนวณส่วนกลับ (ตัวผกผันการคูณ) ขององค์ประกอบทั้งหมดในอาร์เรย์ (0.0003,0.03) สำหรับค่าอัตราการเรียนรู้ (learning rate) โดยใช้การสุ่มเลือกพารามิเตอร์ภายในขอบเขตที่กำหนดภายใต้การทำซ้ำ 100 รอบ
2. ต่อไปจึงใช้ training fold และ validation fold ที่ได้แต่ละรอบ สร้างชุดข้อมูล training dataset และ validation dataset ตามลำดับ ทำพยากรณ์ราคาปิดรายวันของหุ้นเทียบกับราคาจริงด้วยตัวแบบ ANN โดยพิจารณาการสร้างตัวแบบ ANN ภายใต้อำนาจไฮเพอร์พารามิเตอร์ ที่อยู่ในช่วงที่กำหนด แล้วทำการหาตัวแบบที่เหมาะสมสำหรับพยากรณ์ราคาของหุ้นแต่ละตัวในแต่ละรอบ ด้วยชุดข้อมูลที่ถูกแบ่งด้วยวิธี rolling forward validation ทั้งแบบ cumulative หรือแบบ moving window เป็นจำนวน 4 รอบ
3. คำนวณค่าเฉลี่ย MAPE และ RMSE ของหุ้นแต่ละตัว จากขั้นตอนการวิจัยข้างต้น เพื่อใช้เป็นค่าที่ใช้ในการเปรียบเทียบความแม่นยำระหว่างตัวแบบ ANN และตัวแบบอื่น ๆ ในกรณีวิจัยนี้

4.1.3 ตัวแบบผสม ARIMA และ ANN (hybrid model, ARIMA - ANN)

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative และ moving window เพื่อสร้างชุดข้อมูลย่อยสำหรับใช้เป็น training set และ validation set แล้วจึงนำชุดข้อมูลที่ได้ไปสร้างตัวแบบผสม (ARIMA - ANN) มีขั้นตอนดังนี้

1. คำนวณส่วนเศษเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA ในชุดข้อมูลฝึกสอนที่ได้จากในข้อที่ 1 ในแต่ละรอบมาสร้างตัวแบบ ANN โดยมีเงื่อนไขเหมือนในขั้นตอนที่ 1 ในหัวข้อ 4.1.2
2. คำนวณผลรวมของค่าพยากรณ์รวมระหว่างค่าพยากรณ์จากตัวแบบ ARIMA ในข้อ 4.1.1 ซึ่งเป็นข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรง และค่าพยากรณ์จากตัวแบบ ANN ซึ่งเป็นข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรง รวมเข้าด้วยกันในแต่ละรอบ (ดังที่อธิบายในหัวข้อ การศึกษาตัวแบบและทฤษฎีแนวคิดข้อที่ 1.1.3 โดยละเอียด)

3. คำนวณค่าเฉลี่ย MAPE และ RMSE ของหุ่นแต่ละตัว จากขั้นตอนการวิจัยข้างต้น เพื่อใช้เป็นค่าที่ใช้ในการเปรียบเทียบความแม่นยำระหว่างตัวแบบผสม และตัวแบบอื่น ๆ ในการวิจัยนี้

4.2 ขั้นตอนการทดสอบตัวแบบในชุดข้อมูลทดสอบ (test set)

4.2.1 ภายหลังจากการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ จากขั้นตอนการสร้างตัวแบบในชุดข้อมูลฝึกและตรวจสอบตัวแบบในชุดข้อมูลตรวจสอบในข้อที่ 2.1 แล้วจึงทำการเลือกตัวแบบที่มีความแม่นยำที่สุดโดยใช้ MAPE เป็นเกณฑ์ในการคัดเลือกตัวแบบในแต่ละหุ่น และเลือกตัวแบบที่มีค่าเฉลี่ย MAPE ต่ำที่สุดในระหว่างตัวแบบ ARIMA, ANN หรือตัวแบบผสม

4.2.2 ต่อมาจึงใช้ตัวแบบที่ได้เลือกมาสร้างตัวแบบพยากรณ์ราคาปิดรายวันของหุ่นอีกครั้งในแต่ละหุ่น แล้วพยากรณ์ชุดข้อมูลทดสอบเป็นลำดับสุดท้าย ซึ่งในการวิจัยนี้จะแบ่งชุดข้อมูล 866 วันแรก (70 %) เป็นชุดข้อมูลฝึกและ 371 วันสุดท้าย (30 %) เป็นชุดข้อมูลทดสอบ



บทที่ 4

ผลการวิจัย

สำหรับหัวข้อนี้จะแสดงผลการวิจัยในขั้นตอนที่ 4.) ขั้นตอนการสร้างตัวแบบพยากรณ์ ตรวจสอบและทดสอบตัวแบบ โดยแบ่งเป็น

4.1 ผลวิจัยในขั้นตอนสร้างแบบจำลองในชุดข้อมูลฝึก (training set) และตรวจสอบเพื่อคัดเลือกตัวแบบในชุดข้อมูลตรวจสอบ (validation set)

4.1.1 ARIMA

4.1.2 ANN

4.1.3 ตัวแบบผสม

4.1.4 เปรียบเทียบประสิทธิภาพระหว่างตัวแบบในชุดข้อมูลตรวจสอบ

4.2 ผลวิจัยในขั้นตอนการทดสอบตัวแบบในชุดข้อมูลทดสอบ (test set) ซึ่งจะแสดงดังต่อไปนี้

4.1 ผลวิจัยในขั้นตอนสร้างแบบจำลองในชุดข้อมูลฝึก (training set) และตรวจสอบเพื่อคัดเลือกตัวแบบในชุดข้อมูลตรวจสอบ (validation set)

โดยจะแสดงผลวิจัยในรูปแบบของตารางและภาพในแต่ละหุ้น ได้แก่ หุ้น HANA, หุ้น DELTA และหุ้น SVI ตามลำดับ ในแต่ละวิธีการพยากรณ์ราคาปิดรายวันของหุ้นดังกล่าว ในหัวข้อต่อไปนี้

4.1.1 ARIMA

หุ้น HANA

- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

หุ้น DELTA

- วิธี rolling forward validation แบบ cumulative

- วิธี rolling forward validation แบบ moving window
หุ้น SVI
- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

4.1.2 ANN


4.1.3 ตัวแบบผสม

4.1.4 เปรียบเทียบประสิทธิภาพระหว่างตัวแบบในชุดข้อมูลตรวจสอบ


4.1.1 ARIMA

1.1.1 หุ้น HANA

- 1) วิธี rolling forward validation แบบ cumulative



ภาพ 3.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1



ภาพ 3.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2



ภาพ 3.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3



ภาพ 3.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4


ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น HANA รายวันด้วยวิธี ARIMA กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.1 – 3.6

โดยมีค่าเฉลี่ย MAPE เพียง 17.071 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 17.071 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 82.929 % ดังตาราง 3.1


HANA							
ARIMA							
fold	length_of training_set	order (p, d, q)	seasonal_order (P, D, Q)	training set		validation set	
				RMSE	MAPE [%]	RMSE	MAPE [%]
1	247	1, 0, 0	0, 0, 0, 365	0.947	1.705	5.638	12.651
2	494	2, 1, 1	0, 0, 0, 365	0.873	1.607	9.439	29.875
3	741	1, 0, 2	0, 2, 0, 365	0.842	1.644	5.761	14.075
4	988	0, 0, 2	0, 2, 0, 365	2.657	6.051	7.056	11.684
Mean:				1.33	2.752	6.973	17.071

ตาราง 3.1 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative

2. วิธี rolling forward validation แบบ moving window




ภาพ 3.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1



ภาพ 3.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2



ภาพ 3.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3



ภาพ 3.1.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น HANA รายวันด้วยวิธี ARIMA กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.7 – 3.1.0


โดยมีค่าเฉลี่ย MAPE เพียง 19.477 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 19.477 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 80.523 % ดังตาราง 3.2

HANA							
ARIMA							
fold	length_of training_set	order (p,d,q)	seasonal_order (P,D,Q)	training set		validation set	
				RMSE	MAPE [%]	RMSE	MAPE [%]
1	247	1, 0, 0	0, 0, 0, 365	0.947	1.705	5.638	12.651
2	247	0, 0, 0	0, 0, 0, 365	5.518	12.116	9.600	30.193
3	247	2, 1, 2	0, 1, 0, 365	0.762	1.715	5.883	14.224
4	247	0, 0, 2	0, 1, 0, 365	2.459	5.931	16.755	20.840
Mean:				2.421	5.367	9.469	19.477


ตาราง 3.2 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

1.1.2 หุ้น DELTA


1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.1.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1



ภาพ 3.1.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2



ภาพ 3.1.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3



ภาพ 3.1.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4


ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น DELTA รายวันด้วยวิธี ARIMA กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จาก ภาพ 3.1.1 – 3.1.4

โดยมีค่าเฉลี่ย MAPE เพียง 16.898 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์
 เฉลี่ยอยู่ที่ร้อยละ 16.989 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 83.011 %


ดังตาราง 3.3

DELTA							
ARIMA							
fold	length_of training_set	order (p, d, q)	seasonal_order (P, D, Q)	training set		validation set	
				RMSE	MAPE [%]	RMSE	MAPE [%]
1	247	1, 0, 0	0, 0, 0, 365	1.574	1.280	13.810	13.151
2	494	2, 1, 1	0, 0, 0, 365	1.324	1.179	8.101	10.123
3	741	1, 0, 2	0, 2, 0, 365	1.322	1.172	35.112	24.544
4	988	0, 0, 2	0, 2, 0, 365	7.184	7.150	130.774	20.139
Mean:				2.851	2.695	46.949	16.989


ตาราง 3.3 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ่น DELTA ในแต่ละรอบ
 ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative



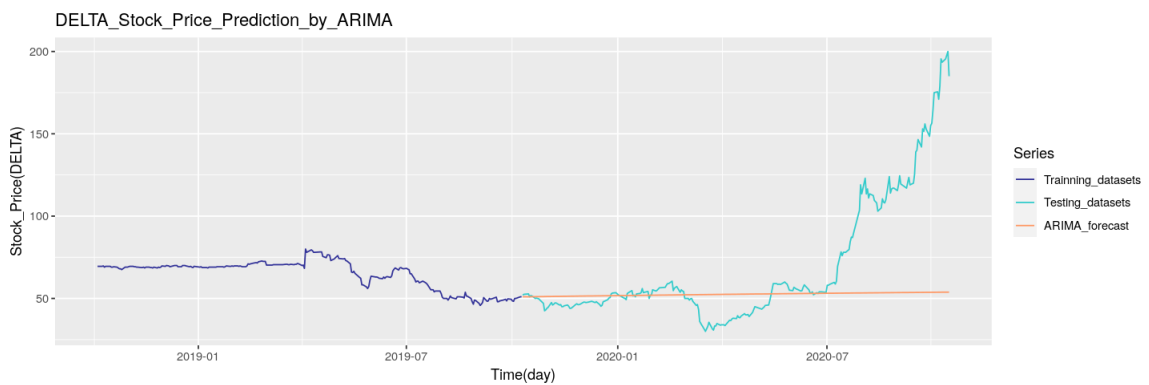
2. วิธี rolling forward validation แบบ moving window



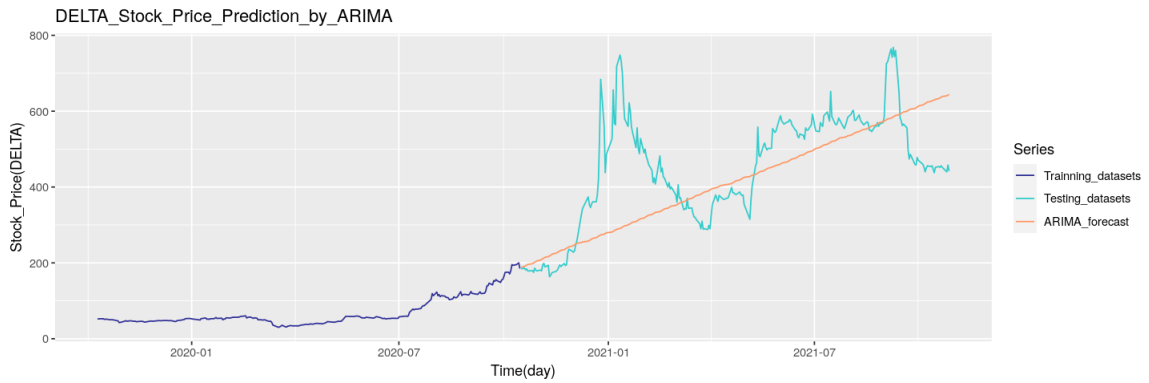
ภาพ 3.1.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1



ภาพ 3.1.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2



ภาพ 3.1.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3



ภาพ 3.1.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น DELTA รายวันด้วยวิธี ARIMA กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.1.5 – 3.1.8


โดยมีค่าเฉลี่ย MAPE เพียง 16.834 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 16.834 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 83.166 % ดังตาราง 3.4

DELTA								
ARIMA								
fold	length_of training_set	order (p,d,q)	seasonal_order (P,D,Q)	training set		validation set		
				RMSE	MAPE [%]	RMSE	MAPE [%]	
1	247	1, 0, 0	0, 0, 0, 365	1.574	1.280	13.810	13.151	
2	247	0, 0, 0	0, 0, 0, 365	1.007	1.042	7.397	9.473	
3	247	2, 1, 2	0, 1, 0, 365	1.299	1.173	40.904	24.786	
4	247	0, 0, 2	0, 1, 0, 365	3.563	2.850	127.730	19.926	
Mean:				1.861	1.586	47.46	16.834	


ตาราง 3.4 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

1.1.3 หุ้น SVI

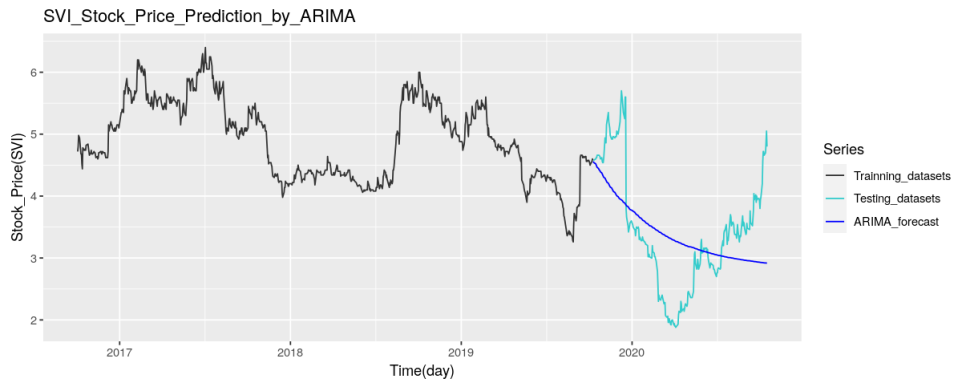
1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.1.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1



ภาพ 3.2.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2



ภาพ 3.2.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3



ภาพ 3.2.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยวิธี ARIMA กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.1.9 – 3.2.2

โดยมีค่าเฉลี่ย MAPE เพียง 11.741 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์
 เฉลี่ยอยู่ที่ร้อยละ 11.741 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 88.259 % ดังตาราง

3.5

SVI								
ARIMA								
fold	length_of training_set	order (p,d,q)	seasonal_order (P,D,Q)	training set		validation set		
				RMSE	MAPE [%]	RMSE	MAPE [%]	
1	247	1, 0, 0	0, 0, 0, 365	0.11196	1.43185	0.74523	9.37449	
2	494	2, 1, 1	0, 0, 0, 365	0.23756	4.10069	0.66679	12.41668	
3	741	1, 0, 2	0, 2, 0, 365	0.10050	1.33531	0.80842	21.54868	
4	988	0, 0, 2	0, 2, 0, 365	0.11899	1.60730	0.26473	3.62445	
Mean:				0.142	2.119	0.621	11.741	

ตาราง 3.5 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ


ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative

2. วิธี rolling forward validation แบบ moving window

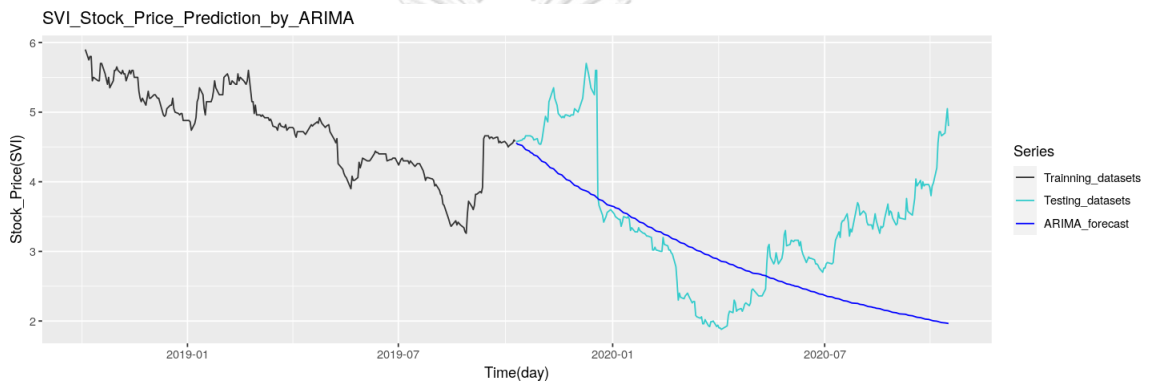
จุฬาลงกรณ์มหาวิทยาลัย




ภาพ 3.2.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation
 แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 1



ภาพ 3.2.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 2



ภาพ 3.2.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 3



ภาพ 3.2.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ARIMA ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยวิธี ARIMA กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จาก ภาพ 3.2.3 – 3.2.6

โดยมีค่าเฉลี่ย MAPE เพียง 12.109 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 12.109 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 87.891 % ดังตาราง 3.6

SVI								
ARIMA								
fold	length_of training_set	order (p,d,q)	seasonal_order (P,D,Q)	training set		validation set		
				RMSE	MAPE [%]	RMSE	MAPE [%]	
1	247	1, 0, 0	0, 0, 0, 365	0.11196	1.43185	0.74523	9.37449	
2	247	0, 0, 0	0, 0, 0, 365	0.19908	3.25165	0.61477	11.13958	
3	247	2, 1, 2	0, 1, 0, 365	0.10003	1.37491	1.02514	24.28983	
4	247	0, 0, 2	0, 1, 0, 365	0.16154	2.49176	0.26518	3.63303	
Mean :				0.143	2.138	0.663	12.109	

ตาราง 3.6 แสดงตัวแบบจำลอง ARIMA ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

ต่อมาจะแสดงผลวิจัยในรูปแบบของตารางและภาพในแต่ละหุ้น ได้แก่ หุ้น HANA, หุ้น DELTA และหุ้น SVI ตามลำดับ ในแต่ละวิธีการพยากรณ์รายวันของหุ้นดังกล่าว ในหัวข้อต่อไปนี้

4.1.2 ANN

หุ้น HANA

- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

หุ้น DELTA

- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

หุ้น SVI

- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

4.1.3 ตัวแบบผสม

4.1.4 เปรียบเทียบประสิทธิภาพระหว่างตัวแบบในชุดข้อมูลตรวจสอบ

4.1.2 ANN

กำหนดขอบเขตพารามิเตอร์ ได้แก่ จำนวนชั้นซ่อนหรือ hidden layer ไม่เกิน 3 ชั้น, จำนวน node อยู่ในช่วง $[0,100]$ และใช้ฟังก์ชันทางคณิตศาสตร์คำนวณส่วนกลับขององค์ประกอบทั้งหมดในอาร์เรย์ $(0.0003, 0.03)$ สำหรับ learning rate โดยใช้การสุ่มเลือกพารามิเตอร์ภายในขอบเขตที่กำหนด

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้าง training fold และ validation fold


ต่อไปจึงใช้ training fold และ validation fold ที่ได้แต่ละรอบ สร้างชุดข้อมูล training dataset และ testing dataset ตามลำดับ ทำพยากรณ์ราคาปิดรายวันของหุ้นเทียบกับราคาจริงด้วยตัวแบบ ANN

โดยพิจารณาการสร้างตัวแบบ ANN ภายใต้อำนาจ parameters ที่อยู่ภายในช่วงที่กำหนด แล้วทำการหาตัวแบบที่เหมาะสมสำหรับพยากรณ์ราคาของหุ้นแต่ละตัวในแต่ละรอบรอบ ด้วยชุดข้อมูลที่ถูกแบ่งด้วยวิธี rolling forward validation ทั้งแบบ cumulative หรือแบบ moving window เป็นจำนวน 4 รอบ โดยใช้ค่า MAPE เป็นเกณฑ์ในการตัดสินใจ ซึ่งตัวแบบที่เหมาะสมในแต่ละรอบนั้นจะให้ค่า MAPE ต่ำที่สุด เพื่อตัวแบบนั้นมีความแม่นยำในการพยากรณ์สูงที่สุดในแต่ละรอบรอบ

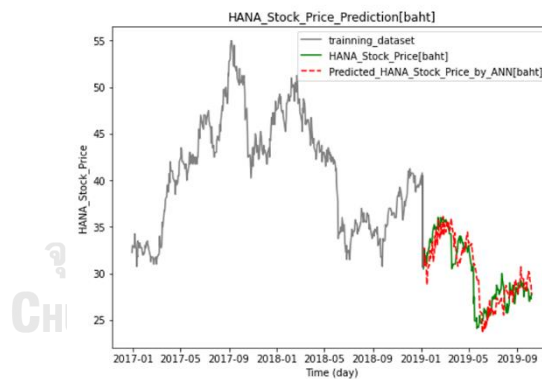
ซึ่งผลลัพธ์ MAPE ของหุ้นแต่ละตัว จากขั้นตอนการวิจัยข้างต้น จะเป็นค่าที่ใช้ในการเปรียบเทียบความแม่นยำระหว่างตัวแบบ ANN และตัวแบบอื่น ๆ ในการวิจัยนี้

1.2.1 หุ้น HANA

1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.2.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 1



ภาพ 3.2.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation

แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 2



ภาพ 3.2.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation

แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 3



ภาพ 3.3.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation

แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 4

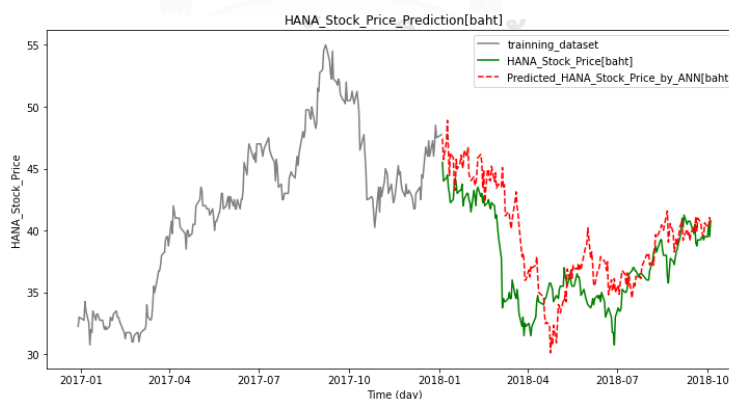
ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น HANA รายวันด้วยวิธี ANN กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.2.7 – 3.3.0

โดยมีค่าเฉลี่ย MAPE เพียง 9.906 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์
 เฉลี่ยอยู่ที่ร้อยละ 9.906 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 90.094 % ดังตาราง 3.7


HANA									
ANN									
fold	best_score	learning_rate	n_hidden	n_neurons	training set		validation set		
					RMSE	MAPE [%]	RMSE	MAPE [%]	
1	-0.073425	0.023473	1	83	2.332	3.881	3.067	6.673	
2	-0.064747	0.018739	1	90	1.764	3.294	6.119	15.866	
3	-0.045487	0.021605	3	83	2.512	5.176	3.867	10.492	
4	-0.038845	0.02198	2	74	2.579	5.824	5.227	6.594	
Mean :					2.297	4.544	4.57	9.906	

ตาราง 3.7 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ
 ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative


2. วิธี rolling forward validation แบบ moving window




ภาพ 3.3.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation
 แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 1



ภาพ 3.3.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 2



ภาพ 3.3.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 3



ภาพ 3.3.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบ ANN ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น HANA รายวันด้วยวิธี ANN กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.3.1 – 3.3.4


โดยมีค่าเฉลี่ย MAPE เพียง 10.309 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 10.309 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 89.691 % ดังตาราง 3.8

HANA									
ANN									
fold	best_score	learning_rate	n_hidden	n_neurons	training set		validation set		
					RMSE	MAPE [%]	RMSE	MAPE [%]	
1	-0.077083	0.023354	1	21	2.092	3.526	3.199	7.460	
2	-0.103946	0.025507	1	76	2.203	4.788	6.411	19.183	
3	-0.103648	0.020614	3	72	1.544	3.990	2.701	6.819	
4	-0.076273	0.025954	1	75	2.440	6.145	6.381	7.773	
Mean :					2.07	4.612	4.673	10.309	


ตาราง 3.8 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น HANA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

1.2.2 หุ้น DELTA


1) วิธี rolling forward validation แบบ cumulative



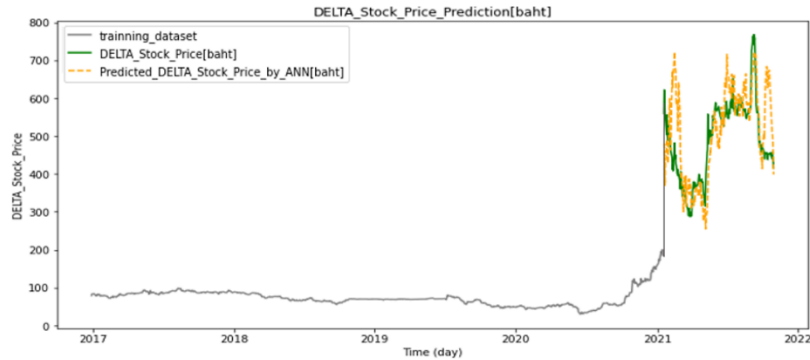
ภาพ 3.3.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 1



ภาพ 3.3.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 2



ภาพ 3.3.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 3



ภาพ 3.3.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 4


ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น DELTA รายวันด้วยวิธี ANN กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.3.5 - 3.3.8

โดยมีค่าเฉลี่ย MAPE เพียง 11.938 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 11.938 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 88.062 % ดังตาราง 3.9


DELTA									
ANN									
fold	best_score	learning_rate	n_hidden	n_neuron	training set		validation set		
					RMSE	MAPE [%]	RMSE	MAPE [%]	
1	-0.098855	0.013725	2	94	2.787	2.524	7.906	10.143	
2	-0.055417	0.018171	1	75	2.650	2.642	5.929	7.737	
3	-0.050011	0.004517	1	95	3.302	3.461	20.689	17.862	
4	-0.042286	0.02217	3	36	5.414	5.233	73.043	12.010	
Mean :					3.538	3.465	26.892	11.938	

ตาราง 3.9 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative


2. วิธี rolling forward validation แบบ moving window




ภาพ 3.3.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 1



ภาพ 3.4.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 2



ภาพ 3.4.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 3



ภาพ 3.4.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบ ANN ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น DELTA รายวันด้วยวิธี ANN กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.3.9 – 3.4.2

โดยมีค่าเฉลี่ย MAPE เพียง 14.646 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 14.646 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 85.354 % ดังตาราง 3.10

จุฬาลงกรณ์มหาวิทยาลัย


DELTA

ANN								
fold	best_score	learning_rate	n_hidden	n_neuron	training set		validation set	
					RMSE	MAPE [%]	RMSE	MAPE [%]
1	-0.085238	0.027206	2	56	2.505	2.304	9.557	10.283
2	-0.085034	0.006731	2	95	2.761	3.319	6.109	7.821
3	-0.072869	0.014744	2	77	2.904	3.567	11.144	15.419
4	-0.055367	0.012258	2	64	15.887	21.553	147.434	25.059
Mean :					6.014	7.686	43.561	14.646


ตาราง 3.10 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น DELTA ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

1.2.3 หุ้น SVI


1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.4.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 1



ภาพ 3.4.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 2



ภาพ 3.4.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 3



ภาพ 3.4.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยวิธี ANN กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จาก

ภาพ 3.4.3 – 3.4.6


โดยมีค่าเฉลี่ย MAPE เพียง 10.51 % นั่นคือมีค่าเฉลี่ยของความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 10.51 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 89.49 % ดังตาราง 3.11

SVI


ANN								
fold	best_score	learning_rate	n_hidden	n_neurons	training set		validation set	
					RMSE	MAPE[%]	RMSE	MAPE[%]
1	-0.100985	0.027211	1	35	0.201	2.873	0.279	5.188
2	-0.068125	0.019374	2	93	0.196	2.969	0.261	4.637
3	-0.05415	0.02871	1	12	0.192	3.039	0.977	29.398
4	-0.045615	0.012536	1	81	0.258	4.491	0.195	2.819
Mean :					0.212	3.343	0.428	10.51

ตาราง 3.11 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative


2. วิธี rolling forward validation แบบ moving window




ภาพ 3.4.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 1



ภาพ 3.4.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 2



ภาพ 3.4.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 3



ภาพ 3.5.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบ ANN ของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยวิธี ANN กับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.4.7 - 3.5.0

โดยมีค่าเฉลี่ย MAPE เพียง 8.799 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 8.799 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 91.201 % ดังตาราง 3.12

SVI								
ANN								
fold	best_score	learning_rate	n_hidden	n_neurons	training set		validation set	
					RMSE	MAPE [%]	RMSE	MAPE [%]
1	-0.100721	0.015264	1	76	0.181	2.516	0.312	4.880
2	-0.090674	0.029759	0	33	0.165	2.687	0.322	5.429
3	-0.081871	0.026088	0	90	0.227	3.946	0.596	18.310
4	-0.078061	0.00725	2	82	0.379	10.633	0.429	6.578
Mean :					0.238	4.945	0.415	8.799

ตาราง 3.12 แสดงตัวแบบจำลอง ANN ที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

ต่อมาจะแสดงผลวิจัยในรูปแบบของตารางและภาพในแต่ละหุ้น ได้แก่ หุ้น HANA, หุ้น DELTA และหุ้น SVI ตามลำดับ ในแต่ละวิธีการพยากรณ์ราคาปิดรายวันของหุ้นดังกล่าว ในหัวข้อต่อไปนี้

4.1.3 ตัวแบบผสม

หุ้น HANA

- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

หุ้น DELTA

- วิธี rolling forward validation แบบ cumulative

วิธี rolling forward validation แบบ moving window
หุ้น SVI


- วิธี rolling forward validation แบบ cumulative
- วิธี rolling forward validation แบบ moving window

4.1.4 เปรียบเทียบประสิทธิภาพระหว่างตัวแบบในชุดข้อมูลตรวจสอบ


4.1.3 ตัวแบบผสม

1.3.1 หุ้น HANA


1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.5.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 1



ภาพ 3.5.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 2



ภาพ 3.5.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 3



ภาพ 3.5.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมกับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.5.1 - 3.5.4


โดยมีค่าเฉลี่ย MAPE เพียง 18.491 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์
 เฉลี่ยอยู่ที่ร้อยละ 18.491 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 81.509 %

ดังตาราง 3.13


HANA									
ARIMA	ANN					training set		validation set	
	fold	best_score	learning_rate	n_hidden	n_neurons	RMSE	MAPE [%]	RMSE	MAPE [%]
	ARIMA(1,0,0)	1	-1.053245	0.000746	3	1	0.633	1.146	9.307
ARIMA(2,1,1)	2	-0.126419	0.002324	3	1	1.022	1.875	3.720	13.873
ARIMA(1,0,2)x(0,2,0) ₃₆₅	3	-0.11279	0.005518	3	7	0.995	2.021	6.168	18.988
ARIMA(0,0,2)x(0,2,0) ₃₆₅	4	-0.06856	0.028226	1	69	1.509	3.228	5.046	18.206
Mean						1.04	2.068	6.06	18.491

ตาราง 3.13 แสดงตัวแบบผลสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น HANA
 ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative


2. วิธี rolling forward validation แบบ moving window




ภาพ 3.5.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation
 แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผลสมของรอบที่ 1



ภาพ 3.5.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 2



ภาพ 3.5.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 3



ภาพ 3.5.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น HANA รายวันด้วยตัวแบบผสมกับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.5.5 – 3.5.8


โดยมีค่าเฉลี่ย MAPE เพียง 16.385 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 16.385 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 83.615 % ดังตาราง 3.14

HANA									
ARIMA	ANN								
	fold	best_score	learning_rate	n_hidden	n_neurons	training set		validation set	
						RMSE	MAPE [%]	RMSE	MAPE [%]
ARIMA(1,1,0)	1	-1.053064	0.000522	3	7	0.599	1.055	5.605	13.982
ARIMA(0,0,0)	2	-0.09789	0.025503	1	90	10.125	17.824	3.346	13.394
ARIMA(2,1,2)x(0,1,0) ₃₆₅	3	-0.094623	0.013253	3	4	16.618	32.766	6.689	19.910
ARIMA(0,0,2)x(0,1,0) ₃₆₅	4	-0.115812	0.021578	3	94	14.441	26.154	6.729	18.253
Mean						10.446	19.45	5.592	16.385


ตาราง 3.14 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น HANA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

1.3.2 หุ้น DELTA


1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.5.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 1



ภาพ 3.6.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 2



ภาพ 3.6.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 3



ภาพ 3.6.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมกับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.5.9 - 3.6.2


โดยมีค่าเฉลี่ย MAPE เพียง 28.797 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 28.797 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 71.203 % ดังตาราง

3.15


DELTA									
ARIMA	ANN								
	fold	best_score	learning_rate	n_hidden	n_neurons	training set		validation set	
						RMSE	MAPE[%]	RMSE	MAPE[%]
ARIMA (0,2,2)x(0,1,0) ₃₆₅	1	-0.976775	0.000462	3	6	1.020	0.833	21.112	24.413
ARIMA (2,1,1)x(0,1,0) ₃₆₅	2	-0.099001	0.002902	3	4	1.819	1.802	11.247	16.743
ARIMA (0,1,2)x(0,1,0) ₃₆₅	3	-0.06871	0.016309	1	1	1.749	1.742	34.416	41.347
ARIMA (0,0,2)x(0,1,0) ₃₆₅	4	-0.051213	0.025039	1	58	4.999	4.671	182.318	32.685
Mean						2.397	2.262	62.273	28.797

ตาราง 3.15 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น DELTA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative


2. วิธี rolling forward validation แบบ moving window




ภาพ 3.6.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 1



ภาพ 3.6.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผสมของรอบที่ 2



ภาพ 3.6.5 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผลมของรอบที่ 3



ภาพ 3.6.6 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผลมของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น DELTA รายวันด้วยตัวแบบผลมกับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.6.3 – 3.6.6

โดยมีค่าเฉลี่ย MAPE เพียง 29.722 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 29.722 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 70.278 % ดังตาราง


3.16

DELTA									
ARIMA	ANN					training set		validation set	
	fold	best_score	learning_rate	n_hidden	n_neurons	RMSE	MAPE[%]	RMSE	MAPE[%]
	ARIMA(0,2,2)x(0,1,0) ₃₆₅	1	-0.983075	0.000414	3	54	2.505	2.304	17.252
ARIMA(2,2,2)	2	-0.146052	0.014463	1	1	2.761	3.319	7.452	15.627
ARIMA(2,1,2)	3	-0.082378	0.024823	3	15	2.904	3.567	20.470	49.246
ARIMA(0,1,2)x(0,1,0) ₃₆₅	4	-0.107683	0.002145	3	44	15.887	21.553	156.994	33.150
Mean						23.312	24.116	50.542	29.722


ตาราง 3.16 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น DELTA ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

1.3.3 หุ้น SVI

1) วิธี rolling forward validation แบบ cumulative




ภาพ 3.6.7 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 1



ภาพ 3.6.8 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 2



ภาพ 3.6.9 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 3



ภาพ 3.7.0 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ cumulative เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมกับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จากภาพ 3.6.3 – 3.7.0


โดยมีค่าเฉลี่ย MAPE เพียง 14.282 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 14.282 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 85.718 %
 ดังตาราง 3.17

SVI									
ARIMA	ANN					training set		validation set	
	fold	best_score	learning_rate	n_hidden	n_neurons	RMSE	MAPE [%]	RMSE	MAPE [%]
	ARIMA(2,2,2)	1	-1.044083	0.001735	3	1	0.064274	0.898821	0.767662
ARIMA(0,0,2)	2	-0.099898	0.015986	2	61	0.151863	2.250744	0.416061	14.374876
ARIMA(1,1,0)	3	-0.087328	0.007678	3	4	0.124625	1.836523	0.922941	26.030608
ARIMA(0,0,1)x(0,1,0) ₃₆₅	4	-0.060715	0.00936	3	85	0.220546	3.668157	0.2385	4.301635
Mean						0.14	2.164	0.586	14.282


ตาราง 3.17 แสดงตัวแบบผสมที่เหมาะสมที่สุดในแต่ละรอบสำหรับหุ้น SVI ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ cumulative




2. วิธี rolling forward validation แบบ moving window




ภาพ 3.7.1 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 1



ภาพ 3.7.2 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 2



ภาพ 3.7.3 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 3



ภาพ 3.7.4 แสดงกราฟระหว่าง ชุดข้อมูลฝึก, ชุดข้อมูลตรวจสอบภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window และค่าพยากรณ์ (forecast) ของราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมของรอบที่ 4

ภายหลังจากการแบ่งชุดข้อมูลออกเป็น 5 ชุด และทำการ rolling forward validation แบบ moving window เพื่อสร้างชุดข้อมูลฝึกในแต่ละรอบ เป็นจำนวน 4 รอบ ผลการเปรียบเทียบค่าพยากรณ์ ราคาปิดหุ้น SVI รายวันด้วยตัวแบบผสมกับราคาปิดหุ้นจริงตามเวลา (วัน) ในแต่ละรอบสามารถแสดงได้จาก ภาพ 3.7.1 – 3.7.4

โดยมีค่าเฉลี่ย MAPE เพียง 15.068 % นั่นคือมีค่าเฉลี่ยของค่าความคลาดเคลื่อนในการพยากรณ์ เฉลี่ยอยู่ที่ร้อยละ 15.068 กล่าวคือ โดยเฉลี่ยตัวแบบมีความแม่นยำในการพยากรณ์ 84.932 %

ดังตาราง 3.18

SVI									
ARIMA	ANN					training set		validation set	
	fold	best_score	learning_rate	n_hidden	n_neurons	RMSE	MAPE[%]	RMSE	MAPE[%]
	ARIMA(2,2,2)	1	-1.052973	0.000793	3	24	0.077	1.039	0.904
ARIMA(0,0,2)	2	-0.120736	0.021983	2	37	1.304	21.245	0.320	15.585
ARIMA (1,0,0)x(0,1,0) ₃₆₅	3	-0.083334	0.004628	2	1	1.229	18.948	0.741	29.388
ARIMA(0,1,1)	4	-0.050819	0.003624	3	13	2.703	45.289	0.264	4.634
Mean						1.328	21.63	0.557	15.068

ตาราง 3.18 แสดงตัวแบบผสมที่เหมาะสมที่สุดสำหรับหุ้น SVI ในแต่ละรอบ ภายใต้การแบ่งข้อมูลด้วยวิธี rolling forward validation แบบ moving window

4.1.4 เปรียบเทียบประสิทธิภาพระหว่างตัวแบบในชุดข้อมูลตรวจสอบ (validation set)

เมื่อใช้ค่าเฉลี่ยของค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (MAPE) เป็นเกณฑ์ในการคัดเลือกและเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ ARIMA, ANN และตัวแบบผสม (ARIMA - ANN) ในการพยากรณ์ราคาปิดหุ้น ได้แก่ หุ้นที่มีความผันผวนมาก คือ HANA, หุ้นที่มีความผันผวนปานกลาง คือ DELTA และ หุ้นที่มีความผันผวนต่ำ คือ SVI ซึ่งผลการวิจัยพบว่า ในการเปรียบเทียบระหว่างตัวแบบทั้งหมด ตัวแบบ ANN มี MAPE ต่ำที่สุด และยังมีค่าเฉลี่ยของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ต่ำที่สุดอีกด้วย (โดยสีไฮไลต์ในช่อง validation set หมายถึงสีของตัวแบบที่มีค่าเฉลี่ย MAPE และค่าเฉลี่ย RMSE ต่ำที่สุดในแต่ละหุ้นในแต่ละวิธีการแบ่งชุดข้อมูล โดยเน้นขอบกรอบสีส้มและสีเทา ตามลำดับ ซึ่งสำหรับไฮไลต์ช่องสีเหลืองหมายถึงตัวแบบ ANN ดังแสดงในตาราง 4.0) ดังนั้น ANN จึงมีความแม่นยำมากที่สุดในการพยากรณ์ราคาปิดรายวันของหุ้นทั้ง HANA, DELTA และ SVI โดยในการพยากรณ์ราคาปิดรายวันของหุ้น DELTA และ SVI ตัวแบบที่มีความแม่นยำรองลงมาในทั้งสองวิธีการแบ่งชุดข้อมูล คือ ARIMA และตัวแบบผสม ตามลำดับ เช่นเดียวกับกับหุ้น HANA ในวิธีแบ่งชุดข้อมูล rolling forward validation แบบ cumulative ในขณะที่วิธีการแบ่งชุดข้อมูลแบบ moving window ในการพยากรณ์ราคาปิดรายวันของหุ้น HANA นั้นมีตัวแบบที่มีความแม่นยำรองลงมา คือ ตัวแบบผสม และ ARIMA ตามลำดับ อย่างไรก็ตาม เมื่อพิจารณาค่าเฉลี่ยของ RMSE แม้ตัวแบบที่มีความแม่นยำที่สุดจะยังคงเป็น ANN เช่นเดิม แต่ผลลัพธ์ตัวแบบที่มีความแม่นยำรองลงมาในการพยากรณ์ราคาปิดรายวัน ในหุ้น HANA ซึ่งมีความผันผวนของราคาในระดับสูง และ SVI ซึ่งมีความผันผวนของราคาในระดับต่ำ ทั้งสองวิธีการแบ่งชุดข้อมูลนั้น ตัวแบบที่มีความแม่นยำรองลงมาจะเปลี่ยนไปเป็นตัวแบบผสมและ ARIMA ตามลำดับ ในขณะที่ยังคงผลลัพธ์เดิมในหุ้น DELTA ซึ่งมีความผันผวนของราคาในระดับปานกลาง ในปี พ.ศ. 2562

นอกเหนือจากนี้ พบว่าในการพยากรณ์ราคาปิดรายวันของหุ้น HANA และ หุ้น DELTA ด้วยตัวแบบ ANN นั้น วิธีแบ่งชุดข้อมูลแบบ cumulative rolling forward validation นั้นมีค่าเฉลี่ยของ MAPE และ ค่าเฉลี่ยของ RMSE ต่ำกว่าวิธีการแบ่งชุดข้อมูล rolling forward validation แบบ rolling window ในขณะที่หุ้น SVI มีผลลัพธ์ตรงข้าม ทั้งนี้เวลาที่ใช้ในการประมวลผลบน jupyterhub ด้วยโปรเซสเซอร์ x86-64 ด้วยจำนวน CPUs ทั้งหมดจำนวน 16 หน่วย ถูกแสดงดังคอลัมน์ 'Time (minutes)' ดังตารางที่ 4.0 ซึ่งแถบสีไฮไลต์สีฟ้าด้านข้าง แสดงถึงความรวดเร็วในการประมวลผล ซึ่งความเข้มของสีไฮไลต์บ่งบอกถึงระยะเวลาที่ใช้ในการประมวลผล (Computing Time) ที่นานขึ้น ยิ่งสีไฮไลต์มีลักษณะฟ้าเข้มขึ้น นั่นคือตัวแบบยิ่งใช้เวลาในการประมวลผลมากกว่าตัวแบบอื่น ๆ ในขณะที่ตัวแบบที่ประมวลผลได้รวดเร็วที่สุดจะมีสีอ่อนที่สุด ตามลำดับ ซึ่ง ARIMA ใช้ระยะเวลาในการประมวลผลน้อยที่สุดในทุกหุ้น

		Moving window				Cumulative					
HANA	Model	training set		validation set		Time (minutes)	training set		validation set		Time (minutes)
		RMSE	MAPE [%]	RMSE	MAPE [%]		RMSE	MAPE [%]	RMSE	MAPE [%]	
	ARIMA	2.421	5.367	9.469	19.477	1.222	1.330	2.752	6.973	17.071	2.188
ANN	2.070	4.612	4.673	10.309	46.291	2.297	4.544	4.570	9.906	75.837	
ARIMA-ANN	10.446	19.450	5.592	16.385	44.420	1.040	2.068	6.060	18.491	80.880	

DELTA	Model	training set		validation set		Time (minutes)	training set		validation set		Time (minutes)
		RMSE	MAPE [%]	RMSE	MAPE [%]		RMSE	MAPE [%]	RMSE	MAPE [%]	
	ARIMA	1.861	1.586	47.460	16.834	1.015	2.851	2.695	46.949	16.989	1.980
ANN	6.014	7.686	43.561	14.646	39.199	3.538	3.465	26.892	11.938	71.829	
ARIMA-ANN	23.312	24.116	50.542	29.722	71.071	2.397	2.262	62.273	28.797	75.283	

SVI	Model	training set		validation set		Time (minutes)	training set		validation set		Time (minutes)
		RMSE	MAPE [%]	RMSE	MAPE [%]		RMSE	MAPE [%]	RMSE	MAPE [%]	
	ARIMA	0.143	2.138	0.663	12.109	0.707	0.142	2.119	0.621	11.741	1.891
ANN	0.238	4.945	0.415	8.799	50.215	0.212	3.343	0.428	10.510	77.522	
ARIMA-ANN	1.328	21.630	0.557	15.068	43.954	0.140	2.164	0.586	14.282	76.385	

ตารางที่ 4.0 แสดงการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ ARIMA, ตัวแบบ ANN และตัวแบบผสม


ต่อมาจึงนำตัวแบบที่มีค่าเฉลี่ยของ MAPE ต่ำที่สุดซึ่งคือตัวแบบ ANN นั้นมาสร้างตัวแบบพยากรณ์ราคาปิดรายวันของหุ้นแต่ละตัว แล้วพยากรณ์ชุดข้อมูลทดสอบ (test set) เป็นลำดับถัดไป

4.2 ผลวิจัยในขั้นตอนการทดสอบตัวแบบในชุดข้อมูลทดสอบ (test set)

ซึ่งในการวิจัยนี้จะแบ่งชุดข้อมูล 866 วันแรก (70 %) เป็นชุดข้อมูลฝึก (training set) และ 371 วันสุดท้าย (30 %) เป็นชุดข้อมูลทดสอบ (test set)

4.2.1 หุ้น HANA

โดยแสดงกราฟการพยากรณ์ราคาปิดรายวันของหุ้น HANA ด้วยแบบจำลอง ANN เทียบกับราคาจริง ในชุดข้อมูลทดสอบดังภาพ 4.1



ภาพ 4.1 แสดงการพยากรณ์ราคาปิดรายวันของหุ้น HANA ด้วยแบบจำลอง ANN เทียบกับราคาจริง ในชุดข้อมูลทดสอบ


พบว่าในการพยากรณ์ราคาปิดรายวันในชุดข้อมูลทดสอบของหุ้น HANA ด้วยตัวแบบ ANN นั้นมี MAPE เพียง 5.049 นั่นคือ มีค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 5.049 ด้วยความแม่นยำในการพยากรณ์ 94.951 % ดังตาราง 4.1

ANN					train error		test error	
best_score	learning_rate	n_hidden	n_neurons		RMSE	MAPE [%]	RMSE	MAPE [%]
-0.042737	0.010002	2	93		3.270	4.936	3.508	5.049

ตาราง 4.1 แสดงตัวแบบ ANN ที่เหมาะสมที่สุดของหุ้น HANA

4.2.2 หุ้น DELTA

โดยแสดงกราฟการพยากรณ์ราคาปิดรายวันของหุ้น DELTA ด้วยแบบจำลอง ANN เทียบกับราคาจริง ในชุดข้อมูลทดสอบ ดังภาพ 4.2



ภาพ 4.2 แสดงการพยากรณ์ราคาปิดหุ้น DELTA รายวันด้วยแบบจำลอง ANN เทียบกับราคาจริง ในชุดข้อมูลทดสอบ


พบว่าในการพยากรณ์ราคาปิดรายวันในชุดข้อมูลทดสอบของหุ้น DELTA ด้วยตัวแบบ ANN นั้นมี MAPE อยู่ที่ 12.610 % นั่นคือ มีค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 12.610 กล่าวคือ ตัวแบบมีความแม่นยำในการพยากรณ์ 87.39 % ดังตาราง 4.2

ANN					train error		test error	
best_score	learning_rate	n_hidden	n_neurons		RMSE	MAPE [%]	RMSE	MAPE [%]
-0.037433	0.017018	3	24		28.835	7.685	64.944	12.610

ตาราง 4.2 แสดงตัวแบบ ANN ที่เหมาะสมที่สุดของหุ้น DELTA

4.2.3 หุ้น SVI

โดยแสดงกราฟการพยากรณ์ราคาปิดรายวันของหุ้น SVI ด้วยแบบจำลอง ANN เทียบกับราคาจริง ในชุดข้อมูลทดสอบ ดังภาพ 4.3



ภาพ 4.3 แสดงการพยากรณ์ราคาปิดหุ้น SVI รายวันด้วยแบบจำลอง ANN เทียบกับราคาจริง ในชุดข้อมูลทดสอบ

พบว่าในการพยากรณ์ราคาปิดรายวันในชุดข้อมูลทดสอบของหุ้น SVI ด้วยตัวแบบ ANN นั้น มี MAPE เพียง 5.940 % นั่นคือมีค่าความคลาดเคลื่อนในการพยากรณ์เฉลี่ยอยู่ที่ร้อยละ 5.940 กล่าวคือตัวแบบมีความแม่นยำในการพยากรณ์ถึง 94.06 % ดังตาราง 4.3

ANN							
best_score	learning_rate	n_hidden	n_neurons	train error		test error	
				RMSE	MAPE [%]	RMSE	MAPE [%]
-0.045531	0.008846	2	66	0.283	4.646	0.380	5.940

ตาราง 4.3 แสดงตัวแบบ ANN ที่เหมาะสมที่สุดของหุ้น SVI

บทที่ 5

อภิปรายผลสรุปและข้อเสนอแนะ

5.1) สรุปผล

ในการเปรียบเทียบประสิทธิภาพในการพยากรณ์ราคาปิดหุ้นรายวันของหุ้นกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ ได้แก่ HANA, DELTA และ SVI ซึ่งมีความผันผวนของราคาหุ้นเทียบกับตลาดโดยรวมในปี พ.ศ. 2562 เรียงจากระดับสูงไประดับต่ำ ตามลำดับ ด้วยการแบ่งชุดข้อมูลวิธี rolling forward validation แบบ cumulative และแบบ moving window ผลการวิจัยพบว่าในบรรดาตัวแบบทั้งหมดนั้น ตัวแบบ ANN มีค่าเฉลี่ยของ MAPE ต่ำที่สุดอย่างชัดเจน และยังมีค่าเฉลี่ยของ RMSE ต่ำที่สุดอีกด้วยในทั้งสองวิธีการแบ่งข้อมูล นั่นคือ ตัวแบบ ANN สามารถพยากรณ์ได้ดีที่สุดในทุกระดับความผันผวนราคาหุ้น ตัวแบบ ARIMA ซึ่งสร้างจากวิธีการค้นหาแบบกริดสามารถพยากรณ์ได้ดีในหุ้นที่มีระดับความผันผวนกลางและระดับต่ำ ในขณะที่ตัวแบบผสมดังกล่าวไม่จำเป็นต้องมีประสิทธิภาพดีกว่าการใช้แต่ละตัวแบบเพียงลำพังเสมอไป ดังนั้นภายใต้ตัวอย่างหุ้นที่ถูกเลือกมา ตัวแบบ ANN จึงทำงานได้ดีในทุกระดับความผันผวนของราคาหุ้นและมีความแม่นยำมากที่สุด ในการพยากรณ์ราคาปิดของหุ้นทั้ง HANA, DELTA และ SVI ด้วยความแม่นยำในการพยากรณ์ 94.951 %, 87.39 % และ 94.06 % ตามลำดับ

5.2) อภิปรายผล

กล่าวโดยสรุป เมื่อนำค่าเฉลี่ยของทั้ง MAPE หรือ RMSE เป็นเกณฑ์ในการคัดเลือกตัวแบบ ตัวแบบ ANN ให้ค่าเฉลี่ยของทั้ง MAPE หรือ RMSE ต่ำที่สุดในทุกตัวอย่างหุ้นที่ได้เลือกมาในทั้งสองวิธีการแบ่งชุดข้อมูล สอดคล้องกับ Ebrahimi [14] ธรณินทร์ [19] รณชัย ชื่นราช [24] อติปิไอและคณะ [25] วิชยาและคณะ [26] ถังและคณะ [27] ซึ่งพบว่าแบบจำลอง ANN ให้ประสิทธิภาพที่ดีกว่าแบบจำลอง ARIMA ในขณะที่ขัดแย้งกับผลวิจัย [11] - [17] และ [22] ซึ่งตัวแบบผสมระหว่างตัวแบบ ARIMA และตัวแบบ ANN ให้ความแม่นยำที่สูงกว่าการใช้ตัวแบบ ARIMA เพียงตัวแบบเดียว เช่นเดียวกับ เทมิเซลและเคซี [28] ซึ่งทำการสร้างตัวแบบผสม ARIMA และ TDNNs โดยผลลัพธ์แสดงให้เห็นว่าตัวแบบผสมดังกล่าวไม่จำเป็นต้องมีประสิทธิภาพดีกว่าการใช้แต่ละตัวแบบเพียงลำพัง ทั้งนี้เนื่องจากความแตกต่างในการเลือกใช้ชุดข้อมูลและฟังก์ชันกระตุ้น รวมไปถึงจนถึงการกำหนดจำนวนหน่วยประมวลผลย่อยในชั้นข้อมูลนำเข้าหรือชั้นซ่อนที่มีความแตกต่างกัน ตลอดจนการนำเอาวิธีตรวจสอบไขว้มาประยุกต์ใช้ในงานวิจัยนี้ ล้วนแล้วแต่เป็นปัจจัยซึ่งอาจทำให้ตัวแบบผสมมีความแม่นยำต่ำกว่าตัวแบบ ARIMA ได้ทั้งสิ้น นอกเหนือจากนี้ สืบเนื่องจากค่าพยากรณ์ของตัวแบบผสมได้รับอิทธิพลจากค่าพยากรณ์ของตัวแบบ ARIMA ซึ่งดังที่ เทมิเซลและอาร์มาน

[29] เสนอว่าตัวแบบผสมที่ซับซ้อนน้อยกว่าที่ประกอบด้วยตัวแบบจำลอง AR-TDNN (Time-Delay Neural Network : TDNN) ประสิทธิภาพดีกว่าตัวแบบผสมที่ซับซ้อนมากกว่า ดังนั้นประสิทธิภาพของตัวแบบผสมอาจได้รับผลกระทบจากตัวแบบ ARIMA ซึ่งมีความซับซ้อนมากจนเกินไปจากวิธีการค้นหาแบบกริด ซึ่งอนุญาตให้ไฮเปอร์พารามิเตอร์ของตัวแบบอนุกรมเวลาสามารถประกอบด้วยทั้งไฮเปอร์พารามิเตอร์แนวนอนและไฮเปอร์พารามิเตอร์ฤดูกาล ทำให้ตัวแบบ ARIMA มีความแม่นยำกว่า ในระยะเวลาการประมวลผลที่สั้นกว่าอีกด้วย

ดังที่ได้แสดงในตาราง 4.0 ตัวแบบ ARIMA ใช้ระยะเวลาในการประมวลผลน้อยที่สุดในทุกหุ้ ในขณะ ANN และตัวแบบผสมใช้ระยะเวลาที่ยาวนานมากกว่า ดังนั้นเมื่อพิจารณาจากเวลาที่ใช้ในการประมวลผล ด้วยความแม่นยำที่ลดลงเพียงเล็กน้อยในบางตัวอย่างหุ้ กลับสามารถลดระยะเวลาที่ต้องใช้ในการประมวลผลลงได้อย่างมาก เช่น ในหุ้ SVI ซึ่งแบ่งข้อมูลด้วยวิธี rolling forward แบบ cumulative ในตารางที่ 4.0 การลดความแม่นยำลงเพียง 1.231 % กลับสามารถลดเวลาในการประมวลผลลงได้ถึงประมาณ 41 เท่า เช่นเดียวกับในหุ้ DELTA ซึ่งแบ่งข้อมูลด้วยวิธี rolling forward แบบ moving window การลดความแม่นยำลงเพียง 2.188 % สามารถลดเวลาในการประมวลผลลงได้ถึงประมาณ 39 เท่า ดังนั้นในกรณีดังกล่าว เมื่อพิจารณาจากเวลาที่ใช้ในการประมวลผลแล้ว ARIMA อาจเป็นตัวแบบทางเลือกที่ดีกว่าตัวแบบ ANN ในแง่ของเวลาประมวลผล

ทั้งนี้สืบเนื่องจากผู้วิจัยได้ทำการเลือกหุ้ตามระดับความผันผวนของหุ้ในปีพ.ศ. 2562 ทว่าจากสภาวะโรคระบาดที่เกิดขึ้นในภายหลัง อาจทำให้ตัวอย่างหุ้ที่ถูกเลือกมาตามระดับความผันผวนในปีพ.ศ. 2562 ในกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์นั้น ไม่ได้เป็นตัวแทนซึ่งแสดงถึงระดับความผันผวนของหุ้อย่างแท้จริงภายในระยะเวลา 5 ปี ซึ่งข้อมูลถูกเก็บรวบรวม เช่น แมวว่าในปี พ.ศ. 2562 หุ้ DELTA จะมีความผันผวนของราคาในระดับปานกลาง แต่เนื่องจากภาวะโรคระบาด ตั้งแต่ปีพ.ศ. 2563 ความต้องการใช้เทคโนโลยีตลอดจนระบบสื่อสารโทรคมนาคมออนไลน์จึงเพิ่มสูงขึ้นมาก หุ้ DELTA ซึ่งดำเนินธุรกิจผลิตชิ้นส่วนอิเล็กทรอนิกส์ที่ใหญ่ที่สุดในไทยนั้นจึงมีราคาผันผวนเป็นอย่างมาก ดังแสดงในภาพ 1.2 โดยราคาหุ้เคยลดลงต่ำสุดถึงระดับ 27 บาทในเดือนมีนาคม [30] จนกระทั่งทำนิวไฮในรอบ 1 ปีในเดือนกรกฎาคม [31] และพุ่งสูงถึงระดับ 600 บาทในเดือนธันวาคมปีเดียวกัน [30] และยังปรับตัวสูงขึ้นอย่างต่อเนื่องในปีพ.ศ. 2564 (โดยสามารถสังเกตราคาหุ้ DELTA ตั้งแต่เดือนกรกฎาคมปี พ.ศ. 2563 เป็นต้นไปได้ดังภาพ 1.9.1 ด้านล่าง) ซึ่งเหตุการณ์สุดขีด (Extreme event) ที่เกิดขึ้นอย่างต่อเนื่องอาจจะทำให้ผลประมาณค่าพารามิเตอร์ของแบบจำลองผิดพลาด จึงทำให้มีค่าคลาดเคลื่อน RMSE มาก ซึ่งส่งผลต่อความ

แม่นยำในการพยากรณ์ของแบบจำลอง อย่างไรก็ตาม ในการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ ตัวแบบ ANN ยังคงมีประสิทธิภาพมากที่สุด แม้ว่าจำเป็นต้องใช้ระยะเวลาประมวลผลค่อนข้างมากก็ตาม

ทั้งนี้ผู้วิจัยได้แนบผลการทดลองการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบในแต่ละหุ่น โดยใช้ชุดข้อมูลฝึกตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนเมษายน พ.ศ. 2564 เพื่อพยากรณ์ราคาหุ้นในอีก 6 เดือนข้างหน้า โดยมีจุดประสงค์เพื่อตรวจสอบว่าตัวแบบใดสามารถรับมือกับความเปลี่ยนแปลงของราคาหุ้นเนื่องจากสภาวะโรคระบาดได้ดีที่สุด ดังตารางที่ 5.0 ซึ่งช่องสีไฮไลต์สีฟ้าในคอลัมน์ 'Time (minutes)' แสดงถึงความรวดเร็วในการประมวลผล โดยมีหน่วยเป็นนาที ซึ่งความเข้มของสีไฮไลต์บ่งบอกถึงระยะเวลาที่ใช้ในการประมวลผลที่ยาวนานขึ้น ยิ่งสีไฮไลต์มีลักษณะฟ้าเข้มขึ้น นั่นคือตัวแบบยิ่งใช้เวลาในการประมวลผลมากกว่าตัวแบบอื่น ๆ ในขณะที่ตัวแบบที่ประมวลผลได้รวดเร็วที่สุดจะมีสีอ่อนที่สุด ตามลำดับ

HANA	Model	training set		validation set		Time (minutes)
		RMSE	MAPE [%]	RMSE	MAPE [%]	
	ARIMA	1.132	2.252	7.663	9.425	2.072
ANN	2.195	2.603	3.929	4.110	20.969	
ARIMA-ANN	0.914	1.970	6.125	7.170	16.287	

DELTA	Model	training set		validation set		Time (minutes)
		RMSE	MAPE [%]	RMSE	MAPE [%]	
	ARIMA	18.019	2.959	174.888	27.189	2.000
ANN	37.754	12.591	95.099	13.910	16.955	
ARIMA-ANN	7.886	3.348	186.947	27.405	20.776	

SVI	Model	training set		validation set		Time (minutes)
		RMSE	MAPE [%]	RMSE	MAPE [%]	
	ARIMA	0.144	2.055	0.266	3.308	1.899
ANN	1.289	0.090	0.207	2.825	20.916	
ARIMA-ANN	0.113	1.829	0.389	5.291	17.152	

ตารางที่ 5.0 แสดงการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ ARIMA, ตัวแบบ ANN และตัวแบบผสมเพื่อตรวจสอบว่าตัวแบบใดสามารถรับมือกับความเปลี่ยนแปลงของราคาหุ้นเนื่องจากสภาวะโรคระบาดได้ดีที่สุด

ซึ่งพบว่า ในการเปรียบเทียบระหว่างตัวแบบทั้งหมด ตัวแบบ ANN มี MAPE ต่ำที่สุด และยังมี RMSE ต่ำที่สุดอีกด้วย (โดยสีไฮไลต์ในช่อง validation set หมายถึงสีของตัวแบบที่มีค่าเฉลี่ย MAPE และค่าเฉลี่ย RMSE ต่ำที่สุดในแต่ละหุ่นในแต่ละวิธีการแบ่งชุดข้อมูล โดยเน้นขอบกรอบสีส้มและสีเทา ตามลำดับ ซึ่งสำหรับไฮไลต์ช่องสีเหลืองหมายถึงตัวแบบ ANN ดังแสดงในตาราง 5.0) ดังนั้น ANN จึงเป็น

ตัวแบบที่สามารถรับมือกับความเปลี่ยนแปลงของราคาหุ้นเนื่องจากภาวะโรคระบาดได้ดีที่สุด และมีความแม่นยำมากที่สุดในพยากรณ์ราคาปิดรายวันของหุ้นทั้ง HANA, DELTA และ SVI ด้วยความแม่นยำ 95.89 %, 86.09 % และ 97.175 % ตามลำดับ

โดยเมื่อพิจารณาทั้งจากค่า MAPE และ RMSE สำหรับในหุ้น DELTA ซึ่งเป็นหุ้นที่มีความผันผวนระดับกลาง ตัวแบบที่มีความแม่นยำรองลงมา คือ ARIMA และตัวแบบผสม ตามลำดับ เช่นเดียวกันกับหุ้น SVI ซึ่งเป็นหุ้นที่มีความผันผวนระดับต่ำในปีพ.ศ. 2562 ในขณะที่ในหุ้น HANA ซึ่งเป็นหุ้นซึ่งมีความผันผวนระดับสูงในปีพ.ศ. 2562 ตัวแบบที่มีความแม่นยำรองลงมาเป็นไปในทิศทางตรงกันข้าม ดังตาราง 5.0

อย่างไรก็ตาม เมื่อพิจารณาจากระยะเวลาที่ใช้ในการประมวลผล สำหรับตัวแบบ ARIMA นั้นมีระยะเวลาในการประมวลผลที่สั้นที่สุดในทุกตัวอย่างหุ้น ดังนั้นสำหรับหุ้น SVI ซึ่งเป็นหุ้นที่แสดงถึงความผันผวนของราคาในระดับต่ำ ตัวแบบ ARIMA ซึ่งมีระยะเวลาในการประมวลผลที่สั้นกว่า ทว่ากลับมีความแม่นยำใกล้เคียงกับตัวแบบ ANN นั้นอาจเป็นตัวเลือกที่ดีในกรณีที่ต้องการลดระยะเวลาในการประมวลผล เนื่องจาก ARIMA นั้นมีความรวดเร็วในการประมวลผลที่สุดแต่มีความแม่นยำต่ำกว่าตัวแบบ ANN ร้อยละ 0.483 จึงอาจพิจารณาเลือกใช้ตัวแบบ ARIMA แทนในหุ้น SVI .ในขณะที่สำหรับหุ้น DELTA การใช้ตัวแบบ ANN ยังคงเป็นตัวเลือกที่สมเหตุสมผล เนื่องจากมีความแม่นยำมากกว่าตัวแบบอื่น ๆ มากกว่าร้อยละ 10 ในขณะที่ใช้ระยะเวลาในการประมวลผลปานกลาง อย่างไรก็ตาม สำหรับหุ้น HANA การเลือกใช้ตัวแบบผสมแทน อาจลดความแม่นยำลงถึงร้อยละ 3 แต่สามารถลดเวลาในการประมวลผลลงได้เล็กน้อย (3.764 นาทีโดยประมาณ) เป็นการทดแทน

นอกเหนือจากนี้ ดังที่อ้างและคณะ [27] กล่าวว่า ตัวแบบ ANN พยากรณ์ระยะยาวได้ดีกว่า ในขณะที่ ARIMA นั้นสามารถรับมือได้ดีกว่ากับการพยากรณ์ระยะสั้น เป็นผลให้สำหรับการใช้ ARIMA เพื่อพยากรณ์ราคาปิดหุ้นรายวันล่วงหน้าในช่วงระยะเวลา 6 เดือน ผลลัพธ์พบว่า ตัวแบบ ANN พยากรณ์ระยะยาวได้ดีกว่า อย่างไรก็ตาม ARIMA ซึ่งสร้างจากวิธีการค้นหาแบบกริดเองก็ทำงานได้ดีในหุ้นที่มีความผันผวนระดับกลางและระดับต่ำ สอดคล้องกับผลสรุปที่ได้ในการเปรียบเทียบประสิทธิภาพของตัวแบบในชุดข้อมูลตรวจสอบ ดังตารางที่ 4.0 ซึ่ง ARIMA สามารถพยากรณ์ได้ตรงลงมาจกตัวแบบ ANN ในหุ้นที่มีระดับความผันผวนกลางและระดับต่ำเช่นเดียวกัน

5.3) ข้อจำกัดและข้อเสนอแนะ

งานวิจัยนี้เลือกใช้ตัวแบบในการเปรียบเทียบความแม่นยำในการพยากรณ์หุ้นกลุ่มธุรกิจหมวดอุตสาหกรรมเทคโนโลยีและชิ้นส่วนอิเล็กทรอนิกส์ ได้แก่ HANA, DELTA และ SVI ตามระดับความผัน

ผวนของราคาหุ้นในปีพ.ศ. 2562 ในระหว่าง 3 ตัวแบบ คือ ตัวแบบ ARIMA, ตัวแบบ ANN และตัวแบบ ARIMA - ANN ผู้สนใจสามารถนำหลักการในงานวิจัยนี้ ร่วมกับศึกษาตัวแบบโครงข่ายประสาทแบบวนซ้ำ (Recurrent neural networks : RNN) หรือการวิเคราะห์สเปกตรัมเดี่ยว (SSA) เป็นเครื่องมือวิเคราะห์อนุกรมเวลาเพิ่มเติมได้ นอกเหนือจากนี้ยังสามารถลดหรือเพิ่มจำนวน node ของชั้นนำเข้าข้อมูลได้ เช่น กำหนดชั้นข้อมูลนำเข้า 1 ชั้น ภายใต้อัน 1 node เพื่อใช้ข้อมูล 1 วันในการพยากรณ์ 1 วันข้างหน้า เป็นต้น หรืออาจลองใช้ฟังก์ชันอื่น ๆ เช่น Exponential Linear Unit function (ELU) เป็นฟังก์ชันกระตุ้นแทน และทดลองเพิ่มจำนวนชั้นซ่อนหรือจำนวนโหนดในชั้นซ่อนให้มากขึ้น เพื่อเพิ่มความซับซ้อนของตัวแบบ

ในงานวิจัยเก็บรวบรวมข้อมูลราคาปิดรายวันของหุ้นตั้งแต่เดือนตุลาคม พ.ศ. 2559 ถึงเดือนตุลาคม พ.ศ. 2564 (5 ปีย้อนหลัง) ผู้สนใจสามารถทดลองประยุกต์ใช้กับชุดข้อมูลอื่น ๆ ซึ่งมีจำนวนค่าสังเกตแตกต่างกันออกไปได้ ซึ่งสำหรับตัวแบบ ARIMA โดยทั่วไปแล้วต้องการชุดข้อมูลซึ่งมีจำนวนค่าสังเกตอย่างน้อย 50 หน่วยขึ้นไป [32] และจะทำงานได้ดีมากกว่าในการพยากรณ์ระยะสั้น [27] ในขณะที่ตัวแบบ ANN ต้องการข้อมูลฝึกจำนวนมากเพื่อฝึกฝน ทั้งนี้จำนวนข้อมูลที่ต้องการนั้นยังขึ้นอยู่กับจำนวนของหน่วยประมวลผลย่อย (node) ในชั้นข้อมูลนำเข้าด้วยว่ามีจำนวนมากน้อยเพียงใด หากชุดข้อมูลมีน้อยอาจประนีประนอมด้วยการลดจำนวน node ของชั้นนำเข้าข้อมูลลง แต่โดยทั่วไปแล้วการใช้ชุดข้อมูลที่มีจำนวนค่าสังเกตน้อยจนเกินไปสำหรับตัวแบบ ANN อาจนำไปสู่ตัวแบบที่ขาดความแม่นยำและมีความเอนเอียง ในขณะที่ชุดข้อมูลฝึกที่มากขึ้นนำไปสู่ความแม่นยำในการพยากรณ์ที่มากขึ้นเช่นกัน

ทั้งนี้อาจทดลองในหุ้นกลุ่มอุตสาหกรรมอื่น ๆ โดยเลือกหุ้นตามระดับความผันผวนของราคาหุ้นในปีอื่น ๆ แทน หรือแบ่งข้อมูลเป็นออกเป็นชุดข้อมูลย่อยให้ละเอียดขึ้นในวิธีตรวจสอบไขว้ เพื่อลดความเอนเอียงของตัวแบบลง



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บรรณานุกรม



- [1] กฤษณะ เนียมมณี. (2019). คณิตศาสตร์เพื่อการลงทุน. กรุงเทพมหานคร: ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย. 238 หน้า.
- [2] จักรกฤษณ์ กิจการรัฐบุต. (2019). ถ้าไม่ลงทุนในหุ้น แล้วจะไปลงทุนอะไรดี. สืบค้นจาก <https://www.moneybuffalo.in.th/หุ้น/ถ้าไม่ลงทุนในหุ้น>
- [3] Wanna Yongpisanphob. (2021). แนวโน้มธุรกิจ/อุตสาหกรรม ปี 2021-2023: อุตสาหกรรมอิเล็กทรอนิกส์. สืบค้นจาก <https://www.krungsri.com/th/research/industry/industry-outlook/Hi-tech-Industries/Electronics/IO>
- [4] Investich. (2020). Beta (β) คืออะไร? สืบค้นจาก <https://investich.com/blog/what-is-beta>
- [5] เณลิ้มพล จตุพร. (2021). การพยากรณ์ทางอนุกรมเวลา (Time Series Forecasting). กรุงเทพมหานคร: สาขาวิชาเศรษฐศาสตร์ มหาวิทยาลัยสุโขทัยธรรมาธิราช. 49 หน้า.
- [6] Robert H. Shumway and David S. Stoffer. (2011). Time Series Analysis and Its Applications Third edition. Springer New York Dordrecht Heidelberg London, 606 p.
- [7] Nat Kulvanich. (2020). Improving Prediction Accuracy of Time Series Data Using ARIMA-ANN Hybrid Model and Regression Analysis. Thai Science and Technology Journal (TSTJ), 28(12), 2101-2112.
- [8] อังคณา ตาเสนา, และธีรศิลป์ กันธา. (2020). การพยากรณ์ผู้โดยสารสนามบินแม่สอดจังหวัดตาก. สืบค้นจาก <https://research.kpru.ac.th/research2/pages/filere/1556607621.pdf>
- [9] อรรถพล สืบพงศ์กร, และสุพัตรา วิสาการ. (2016). การเปรียบเทียบความแม่นยำในการพยากรณ์อัตราแลกเปลี่ยนเงินบาทต่อดอลลาร์สหรัฐอเมริกา.วารสารวิชาการ, 36(2), 121-135.
- [10] Zhang, P.G. (2003). Time series forecasting using a hybrid ARIMA and neural network model, Neurocomputing, 50, 159-175.
- [11] Somsila, C. , Sunat, K. and Chiewchanwattana, S. (2010). Hybrid Model for Air Quality Data Prediction Case Study: Air Quality Data in Thailand, The 11th Graduate Research Conference, 12 p. (in Thai)

- [12] Boonmana, C. and Kulvanich, N. (2017). A comparative prediction accuracy of hybrid time series models, Thai Science Technology Journal, 25(2), 177-190. (in Thai)
- [13] Siripanich, P. , Nillaporn, P. and Trakarnta Ierngsuk, S. (2007). Time Series Forecasting Using a Combined ARIMA and Artificial Neural Network Model of Styrene Price Using a Hybrid ARIMA and Neural Network Model. Operations Research Network 2007, 7 p. (in Thai)
- [14] Ebrahimi, A. (2019). Time series forecasting of styrene price using a hybrid ARIMA and neural network model. Independent Journal of Management & Production, 10, 915-933.
- [15] Koutroumanidis, T., Ioannou, K. and Arabatzis, G. (2009). Predicting fuel wood prices in Greece with the use of ARIMA models artificial neural networks and a hybrid ARIMA-ANN model. Energy Policy, 37, 3627-3634.
- [16] Meth, N., Saxena, V.P. and Pardasani, K.R. (2010). A comparison between hybrid approaches of ANN and ARIMA for Indian stock trend forecasting, Business Intelligence Journal, 3, 23-43.
- [17] Faruk, D.O. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. Engineering Applications of Artificial Intelligence, 23(4), 586-594.
- [18] Delurgio, S.A. (1998). Forecasting Principles and Applications. Singapore : Mc Graw-Hill companies. 802 pp.
- [19] ธรณินทร์ สัจจวิทย์ทรัพย์. (2018). ตัวแบบโครงข่ายประสาทเทียมสำหรับการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย. วารสารวิทยาศาสตร์ มศว, 34(1), 91-107.
- [20] กนิษฐา ยี่มนาค. (2010). การเปรียบเทียบประสิทธิภาพการพยากรณ์ของตัวแบบการวิเคราะห์การถดถอยแบบพหุเมื่อข้อมูลมีระดับการกระจายต่างกัน. วารสารสุทธิปริทัศน์, 24(74), 79-92.
- [21] ไพศาล เรืองฤทธิและคณะ. (2020). การพยากรณ์ราคาทุเรียนในประเทศไทยและราคาทุเรียนส่งออกของประเทศไทย. วารสารวิชาการบริหารธุรกิจมหาลัยแม่โจ้, 2(2), 19 - 31.

- [22] Anansapsuk, A. and Kulvanich, N. (2018). A Comparative Study of Hybrid Time Series Models for Forecasting Seasonal Time Series. 1824 – 1836 p. in 2th *UTCC Academic Day*, June 8, 2018. Bangkok: UTCC (in Thai)
- [23] กำธร ตันศิริรุ่งเรือง, และสมพร ปันโกษา. (2020). พยากรณ์มูลค่าหลักทรัพย์ในกลุ่มธนาคารพาณิชย์ โดยใช้แบบจำลองอาร์มีมา (ARIMA) และแบบจำลองอาร์แมกซ์ (ARIMAX). หน้า 2564 - 2574. ใน รายงานสืบเนื่องจากการประชุมนำเสนอผลวิจัยระดับบัณฑิตศึกษาครั้งที่ 15, 13 สิงหาคม 2020. ปทุมธานี: มหาลัยรังสิต.
- [24] รณชัย ชื่นราช. (2018). การพยากรณ์ค่าความเข้มข้นของฝุ่นละอองขนาดเล็กไม่เกิน 10 ไมครอนด้วยเครือข่ายประสาทเทียมร่วมกับรูปแบบออโตรีเกรสซีฟ. วารสารวิทยาศาสตร์บูรพา, 22(3), 519 – 537.
- [25] Adebisi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural network models for stock price prediction. *Journal of Applied Mathematics*, 2014, 7.
- [26] Y. B. Wijaya, S. Kom and T. A. Napitupulu, (2010). Stock Price Prediction: Comparison of Arima and Artificial Neural Network Methods - An Indonesia Stock's Case, 2010 Second International Conference on Advances in Computing, Control, and Telecommunication Technologies, 176-179.
- [27] Tang, Z., De Almeida, C., & Fishwick, P. A. (1991). Time series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57(5), 303-310.
- [28] Taskaya-Temizel, T., & Casey, M. C. (2005). A comparative study of autoregressive neural network hybrids. *Neural Networks*, 18(5-6), 781-789.
- [29] Tugba, Taskaya Temizel, & Khurshid, Ahmad. (2005). Are ARIMA neural network hybrids better than single models?. 2005 IEEE International Joint Conference on Neural Networks, 5, 3192-3197.
- [30] Arty Siriluck. (2020). ปราชญ์การณ DELTA หุ่นตั้งแห่งปี 2020 พุ่งทะยาน...เหนือคำทำนาย. สืบค้นจาก <https://positioningmag.com/1312243>

[31] หุ่นเด่นวันนี้. (2020). DELTA พิเศษยังไง ทำไมดีดแต่ตะพวดาน?. สืบค้นจาก

<https://www.efinancethai.com/HotStocks>

[32] Box, G. E. P., & Tiao, G. C. (1975). Intervention Analysis with Applications to Economic and Environmental Problems. *Journal of the American Statistical Association*, 70(349), 70–79.

Appendix

https://drive.google.com/drive/folders/1eZeTLIEA7_eZyYRC18ksWeSJvgfSdvf9?usp=sharing



ประวัติผู้เขียน

ชื่อ-สกุล	Karnpiwan
สถานที่เกิด	Bangkok
วุฒิการศึกษา	Master of Science in Statistics (Data Science), (Expected May 2022) Faculty of Commerce and Accountancy, Chulalongkorn University, Bangkok

