



การพยากรณ์ราคาปิดคอยน์ด้วยเทคนิคการเรียนรู้ของเครื่อง

วิทยานิพนธ์
ของ
นิติกร จันทาญ

พหุ ประถม โศ โศ


เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ

มิถุนายน 2564


ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

การพยากรณ์ราคาปิดคอยน์ด้วยเทคนิคการเรียนรู้ของเครื่อง



เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ
มิถุนายน 2564
ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Predicting Bitcoin Price using Machine Learning Techniques



Nitikorn Junhan

A Thesis Submitted in Partial Fulfillment of Requirements
for Master of Science (Information Technology)

June 2021

Copyright of Mahasarakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของพันตำรวจโทนิติกร จันทหาญ แล้วเห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

ประธานกรรมการ

(รศ. ดร. สิทธิชัย บุขหมั่น)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ผศ. ดร. จารีย์ ทองคำ)

กรรมการ

(ผศ. ดร. แกมกาญจน์ สมประเสริฐศรี)

กรรมการ

(ดร. สาธิต แสงประดิษฐ์)

มหาวิทยาลัยอนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา วิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ ของมหาวิทยาลัยมหาสารคาม

(ผศ. ศศิธร แก้วมัน)

คณบดีคณะวิทยาการสารสนเทศ

(รศ. ดร. กริสน์ ชัยมูล)

คณบดีบัณฑิตวิทยาลัย

พุทธ บัณฑิต วิชา

ชื่อเรื่อง	การพยากรณ์ราคาบิตคอยน์ด้วยเทคนิคการเรียนรู้ของเครื่อง		
ผู้วิจัย	นิติกร จันทาญ		
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. จารีย์ ทองคำ		
ปริญญา	วิทยาศาสตรมหาบัณฑิต	สาขาวิชา	เทคโนโลยีสารสนเทศ
มหาวิทยาลัย	มหาวิทยาลัยมหาสารคาม	ปีที่พิมพ์	2564

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของเทคนิคอริมา และเทคนิคถดถอยการเรียนรู้ของเครื่อง อริมาเป็นเทคนิคดั้งเดิม ส่วนเทคนิคถดถอยการเรียนรู้ของเครื่องประกอบด้วย Multilayer perceptron, Radial basis function, และ Support vector machine for regression เป็นเทคนิคใหม่ที่นักวิจัยนำมาใช้ในการสร้างแบบจำลองในการพยากรณ์ในงานต่างๆ เช่น พยากรณ์ราคาทองคำ ราคาน้ำมัน เป็นต้น ในงานวิจัยนี้ได้นำเอาเทคนิคดังกล่าวมาใช้ในการสร้างแบบจำลองอนุกรมเพื่อพยากรณ์ราคาบิตคอยน์เป็นรายวัน โดยบิตคอยน์ (Bitcoin) เป็น สกุลเงินอิเล็กทรอนิกส์ชนิดหนึ่งที่มีการซื้อขายกันตลอดเวลาทำให้ราคามีความผันผวนไม่แน่นอนในแต่ละวัน ข้อมูลที่จะนำมาใช้ประกอบด้วย ราคาเปิดตลาด ราคาสูงสุด ราคาต่ำสุด ราคาปิดตลาด ปริมาณซื้อขาย และมูลค่าตลาดรวม จากเว็บไซต์ www.coinmarketcap.com ตั้งแต่วันที่ 1 มกราคม ค.ศ.2017 ถึง 31 ธันวาคม ค.ศ.2019 ในการวัดประสิทธิภาพของแบบจำลองดังกล่าวหลักการ Sliding window ได้ถูกนำมาใช้ในการแบ่งข้อมูลเป็นชุดข้อมูลฝึกฝน และชุดข้อมูลทดสอบ รวมถึงค่าความเฉลี่ยคลาดเคลื่อนสัมบูรณ์ และค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง ถูกนำมาเป็นเกณฑ์ในการเปรียบเทียบประสิทธิภาพของแบบจำลอง จากการทดลองพบว่า เทคนิค ARIMA มีประสิทธิภาพสูงสุด โดยมีค่า MAE ของการพยากรณ์ ราคาเปิดตลาด ราคาสูงสุด ราคาต่ำสุด ราคาปิดตลาด ปริมาณซื้อขายในแต่ละวัน และ มูลค่าตลาดรวม ต่ำสุดที่ 1.49, 1.55, 1.42, 1.49, 0.27 และ 2.54 ค่า RMSE เท่ากับ 2.38, 2.48, 2.25, 2.38, 0.43 และ 4.03 ตามลำดับ

คำสำคัญ : บิตคอยน์, การพยากรณ์, อนุกรมเวลา, การเรียนรู้ของเครื่อง

TITLE Predicting Bitcoin Price using Machine Learning Techniques
AUTHOR Nitikorn Junhan
ADVISORS Assistant Professor Jaree Thongkam , Ph.D.
DEGREE Master of Science **MAJOR** Information Technology
UNIVERSITY Mahasarakham **YEAR** 2021
University

ABSTRACT

This research aims to compare the performance ARIMA and machine learning techniques, therefore the ARIMA is a classical technique whereas machine learning is Multilayer perceptron, Radial basis function and Support vector machine for regression. Those techniques are used for forecasting in various situations in particular, gold price and oil price forecasting therefore Bitcoin is a cryptocurrency which exchanges all the time that makes Bitcoin price more fluctuated. In this research, ARIMA and machine learning have been used to create a daily Bitcoin price models such as, Open, High, Low, Close, Volume and Marketcap from www.coinmarketcap.com during 1st January 2017 to 31th December 2019. As evaluation, sliding window technique is used for separating the data into training and testing set. Then, MAE and RMSE are used for evaluation. From experiment, ARIMA is the best result therefore the Open, High, Low, Close, Volume and Marketcap are the lowest at 1.49, 1.55, 1.42, 1.49, 0.27 and 2.54 in MAE and 2.38, 2.48, 2.25, 2.38, 0.43 and 4.03 in RMSE respectively.

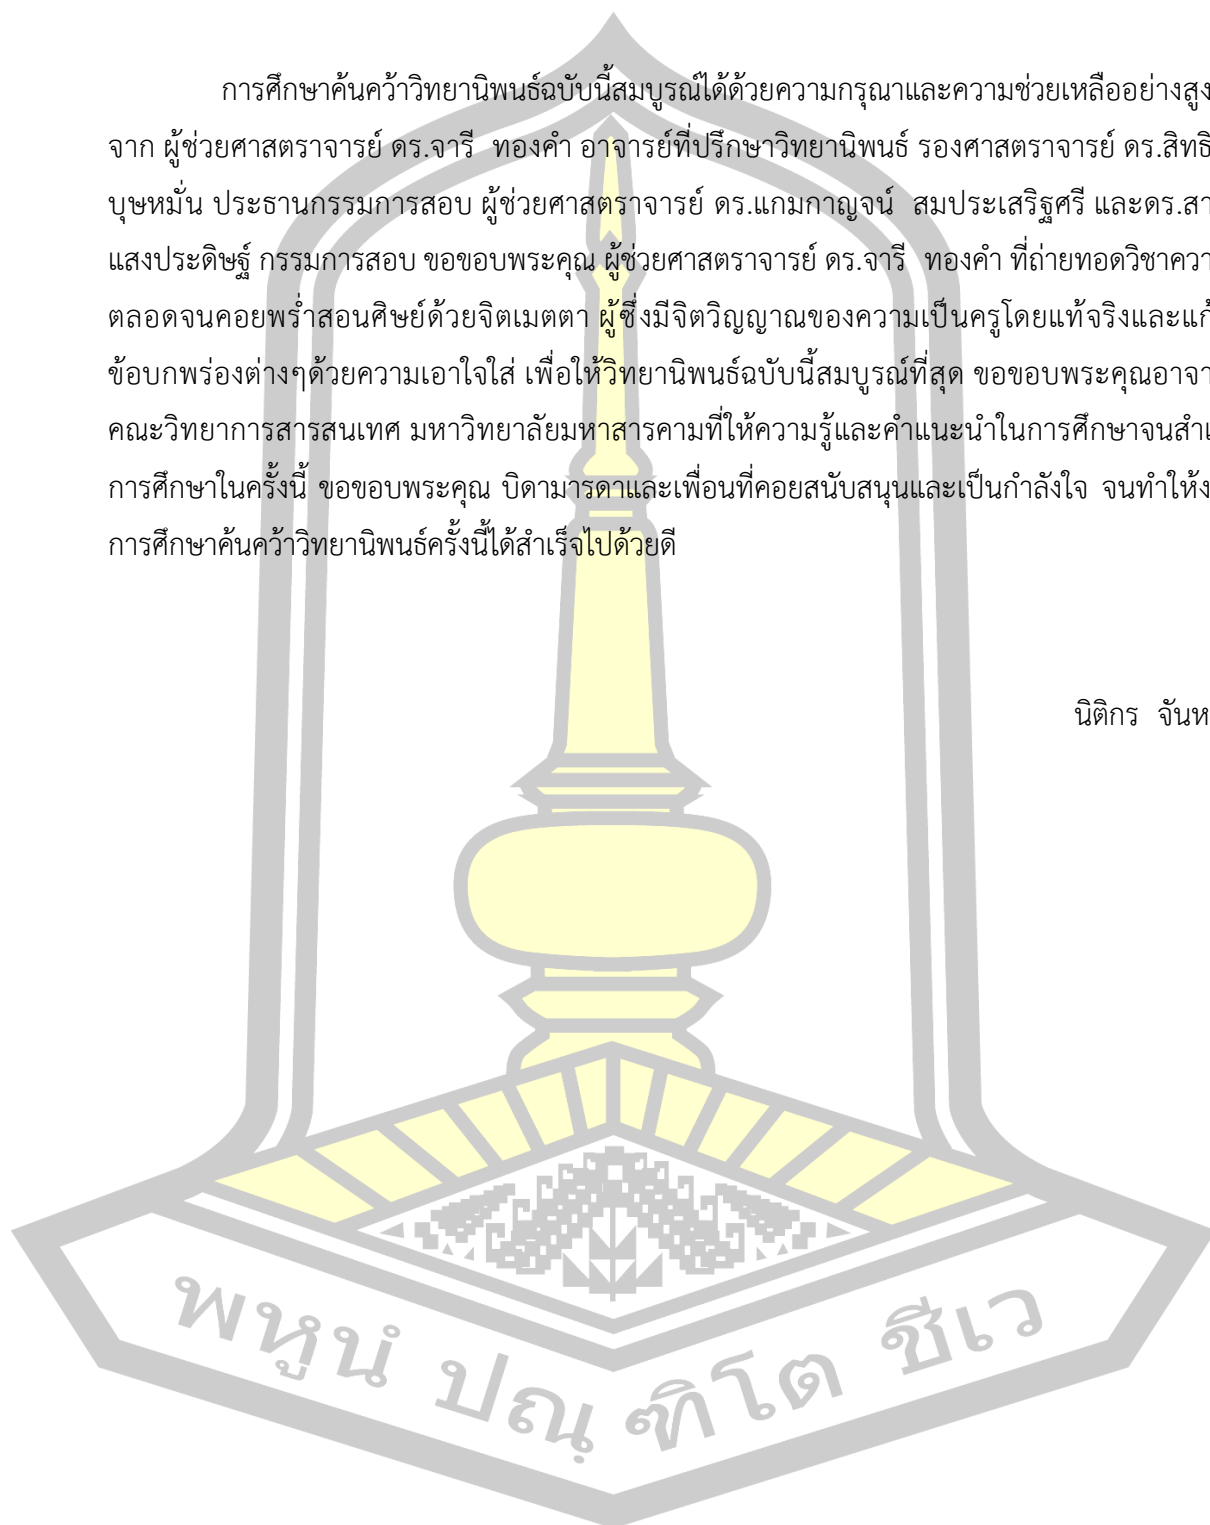
Keyword : Bitcoin, Forecast, Time series, Machine learning

พจนันท์ ปณฺทสิโรต ชีเว

กิตติกรรมประกาศ

การศึกษาค้นคว้าวิทยานิพนธ์ฉบับนี้สมบูรณ์ได้ด้วยความกรุณาและความช่วยเหลืออย่างสูงยิ่งจาก ผู้ช่วยศาสตราจารย์ ดร.จารี ทองคำ อาจารย์ที่ปรึกษาวิทยานิพนธ์ รองศาสตราจารย์ ดร.สิทธิชัย บุษหมั่น ประธานกรรมการสอบ ผู้ช่วยศาสตราจารย์ ดร.แกมกาญจน์ สมประเสริฐศรี และดร.สาธิต แสงประดิษฐ์ กรรมการสอบ ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.จารี ทองคำ ที่ถ่ายทอดวิชาความรู้ตลอดจนคอยพร่ำสอนศิษย์ด้วยจิตเมตตา ผู้ซึ่งมีจิตวิญญาณของความเป็นครูโดยแท้จริงและแก้ไขข้อบกพร่องต่างๆด้วยความเอาใจใส่ เพื่อให้วิทยานิพนธ์ฉบับนี้สมบูรณ์ที่สุด ขอขอบพระคุณอาจารย์ คณะวิทยาการสารสนเทศ มหาวิทยาลัยมหาสารคามที่ให้ความรู้และคำแนะนำในการศึกษาจนสำเร็จการศึกษาในครั้งนี้ ขอขอบพระคุณ บิดามารดาและเพื่อนที่คอยสนับสนุนและเป็นกำลังใจ จนทำให้งานการศึกษาค้นคว้าวิทยานิพนธ์ครั้งนี้ได้สำเร็จไปด้วยดี

นิติกร จันทาญ



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญภาพ.....	ฌ
สารบัญตาราง.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 หลักการและเหตุผล	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 ความสำคัญของงานวิจัย.....	3
1.4 ขอบเขตของงานวิจัย.....	4
1.5 นิยามศัพท์เฉพาะ	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 ทฤษฎีที่เกี่ยวข้อง	5
2.1.1 บิตคอยน์.....	5
2.1.2 Coinmarketcap.....	6
2.1.3 การพยากรณ์.....	7
2.1.4 อนุกรมเวลา.....	7
2.1.5 การวิเคราะห์อนุกรมเวลา	10
2.1.6 เทคนิคในการสร้างแบบจำลอง.....	11
2.2 งานวิจัยที่เกี่ยวข้อง.....	18

บทที่ 3 วิธีดำเนินการวิจัย.....	21
3.1 การเตรียมข้อมูล.....	21
3.2 การวิเคราะห์ข้อมูล.....	22
3.3 การสร้างแบบจำลอง.....	23
3.4 การวัดประสิทธิภาพของแบบจำลอง.....	31
บทที่ 4 ผลการศึกษา.....	33
4.1 ค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์.....	33
4.2 ผลค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์.....	40
4.3 ผลการเปรียบเทียบระหว่างค่าพยากรณ์และค่าจริง.....	46
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ.....	50
5.1 สรุปผล.....	50
5.2 อภิปรายผล.....	51
5.3 ข้อเสนอแนะ.....	52
บรรณานุกรม.....	53
ประวัติผู้เขียน.....	57



สารบัญภาพ

ภาพประกอบที่ 2.1 หน้า Website Coinmarketcap	7
ภาพประกอบที่ 2.2 แนวโน้มอนุกรมเวลา.....	8
ภาพประกอบที่ 2.3 อนุกรมเวลาที่มีส่วนของวัฏจักร	9
ภาพประกอบที่ 2.4 ความผันแปรจากฤดูกาล.....	10
ภาพประกอบที่ 2.5 โครงสร้าง Multilayer Perceptron สำหรับการถดถอย.....	12
ภาพประกอบที่ 2.6 เวกเตอร์ซัพพอร์ท.....	14
ภาพประกอบที่ 3.1 ราคาของบิตคอยน์ตามตัวแปร	22
ภาพประกอบที่ 3.2 การตั้งค่าเทคนิค Multilayer Perceptron บนโปรแกรม WEKA.....	27
ภาพประกอบที่ 3.3 การตั้งค่าเทคนิค Support Vector Machine for Regression.....	28
ภาพประกอบที่ 3.4 การตั้งค่าเทคนิค Radial Basis Function บนโปรแกรม WEKA	30
ภาพประกอบที่ 3.5 การพยากรณ์ราคาบิตคอยน์ด้วยหลักการ Sliding Window.....	32
ภาพประกอบที่ 4.1 ค่าความคลาดเคลื่อน MAE ราคาเปิดตลาด เทคนิค MLP, RBF, SVR และ ARIMA.....	35
ภาพประกอบที่ 4.2 ค่าความคลาดเคลื่อน MAE ราคาสูงสุด เทคนิค MLP, RBF, SVR และ ARIMA.....	36
ภาพประกอบที่ 4.3 ค่าความคลาดเคลื่อน MAE ราคาต่ำสุด เทคนิค MLP, RBF, SVR และ ARIMA.....	37
ภาพประกอบที่ 4.4 ค่าความคลาดเคลื่อน MAE ราคาปิดตลาดเทคนิค MLP, RBF, SVR และ ARIMA.....	38
ภาพประกอบที่ 4.5 ค่าความคลาดเคลื่อน MAE ปริมาณการซื้อขาย เทคนิค MLP, RBF, SVR และ ARIMA.....	39
ภาพประกอบที่ 4.6 ค่าความคลาดเคลื่อน MAE มูลค่าตลาดรวม เทคนิค MLP, RBF, SVR และ ARIMA.....	40
ภาพประกอบที่ 4.7 ค่าความคลาดเคลื่อน RMSE ราคาเปิดตลาด เทคนิค MLP, RBF, SVR และ ARIMA.....	41

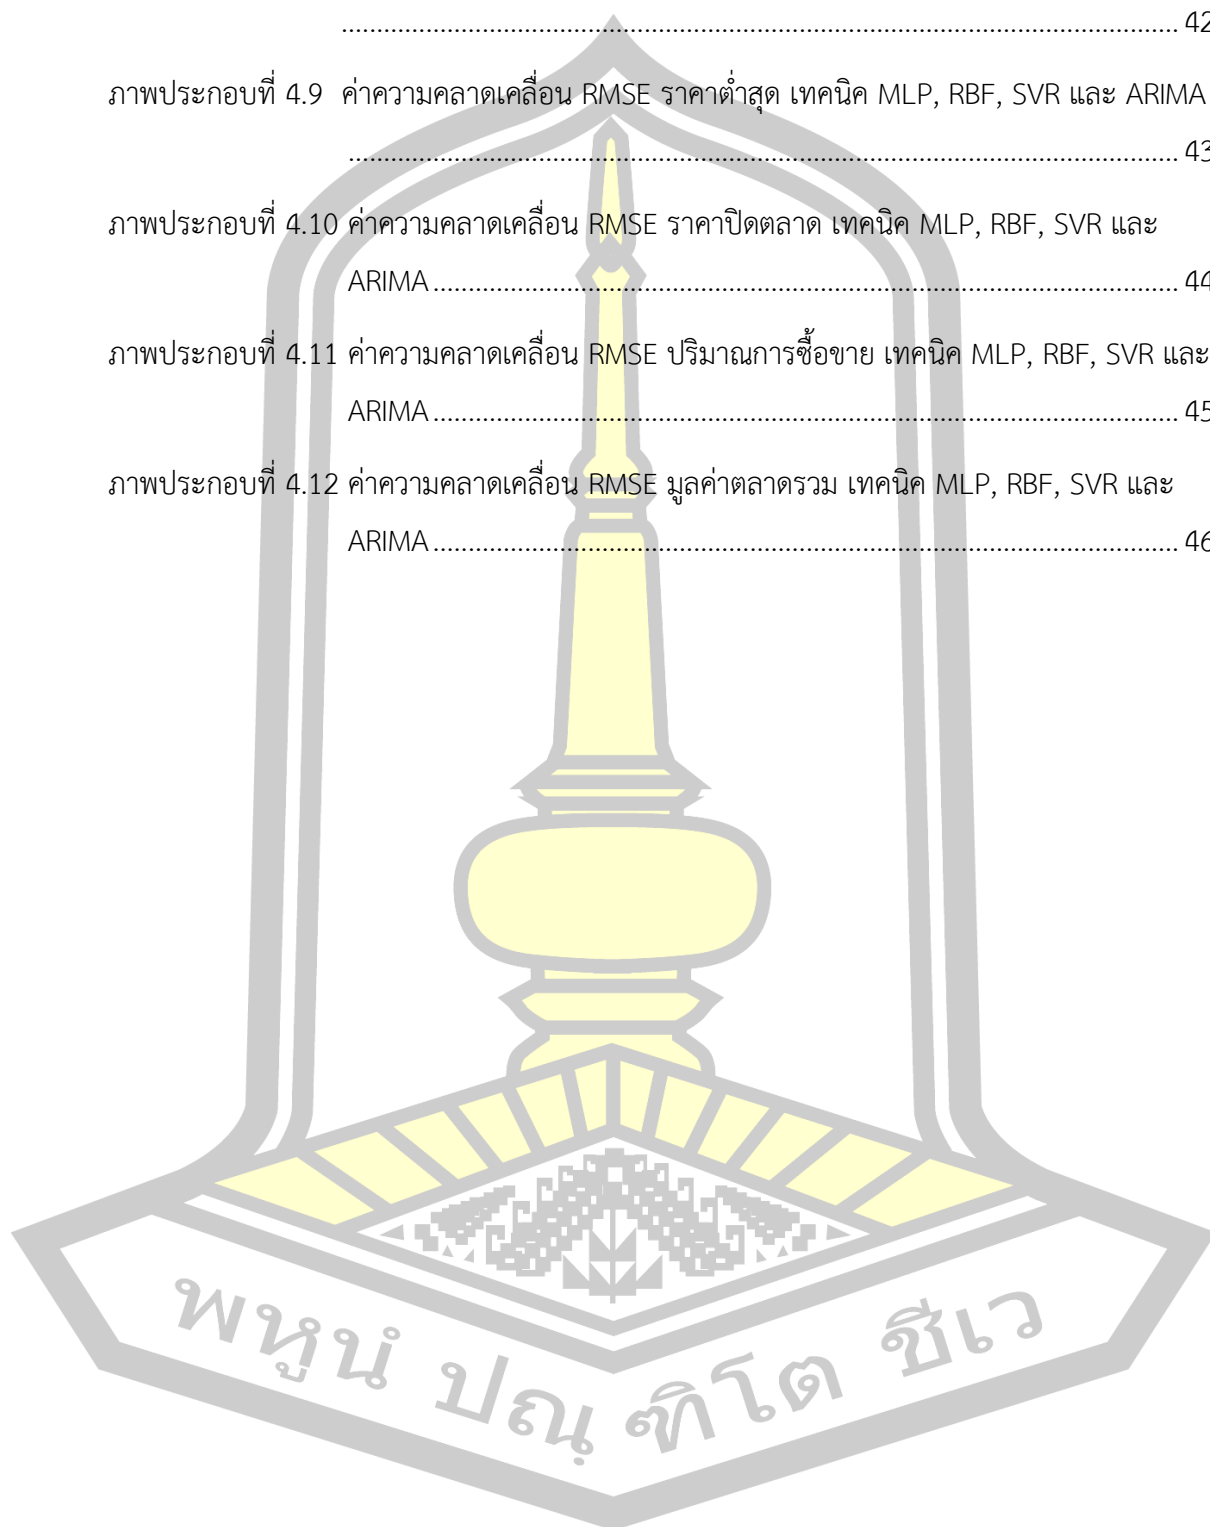
ภาพประกอบที่ 4.8 ค่าความคลาดเคลื่อน RMSE ราคาสูงสุด เทคนิค MLP, RBF, SVR และ ARIMA 42

ภาพประกอบที่ 4.9 ค่าความคลาดเคลื่อน RMSE ราคาต่ำสุด เทคนิค MLP, RBF, SVR และ ARIMA 43

ภาพประกอบที่ 4.10 ค่าความคลาดเคลื่อน RMSE ราคาปิดตลาด เทคนิค MLP, RBF, SVR และ ARIMA 44


ภาพประกอบที่ 4.11 ค่าความคลาดเคลื่อน RMSE ปริมาณการซื้อขาย เทคนิค MLP, RBF, SVR และ ARIMA 45

ภาพประกอบที่ 4.12 ค่าความคลาดเคลื่อน RMSE มูลค่าตลาดรวม เทคนิค MLP, RBF, SVR และ ARIMA 46



สารบัญตาราง

ตารางที่ 3.1 ตัวแปรที่ใช้ในงานวิจัย..... 21



บทที่ 1

บทนำ

1.1 หลักการและเหตุผล

บิตคอยน์ คือสกุลเงินอิเล็กทรอนิกส์ โดยอาศัยเครือข่ายระหว่างเครื่องคอมพิวเตอร์ถึงเครื่องคอมพิวเตอร์โดยไม่มีตัวกลางมาเชื่อมต่อ โดยการส่งบิตคอยน์นั้น ไม่มีสถาบันการเงินเข้ามาเกี่ยวข้องกับหรือเป็นตัวกลางในการตรวจสอบ และบิตคอยน์ได้ถูกคิดค้นขึ้นจากบุคคล หรือกลุ่มบุคคลที่ใช้นามแฝงว่า “Satoshi Nakamoto” โดยบิตคอยน์ได้ถือกำเนิดขึ้นในปี ค.ศ.2008 และเนื่องด้วยความได้เปรียบของตัวบิตคอยน์ที่ใช้หลักการตรวจสอบกันเองในเครือข่ายโดยไม่ผ่านตัวกลาง [1] [2] ทำให้ได้รับความนิยมในหมู่นักลงทุนและผู้สนใจในเทคโนโลยีเข้ามาถือครองบิตคอยน์นี้ โดยจะเห็นได้จากราคา ณ วันที่ 31 ธันวาคม 2562 นั้น ราคาของบิตคอยน์ อยู่ที่ ประมาณ 7,220 ยูเอสดอลลาร์ และมีการทำธุรกรรมในระบบถึง 323,836 ครั้ง ต่อวัน [3] และสำหรับในประเทศไทยมีเว็บไซต์ซื้อขายแลกเปลี่ยนที่เป็นที่นิยมในหมู่นักลงทุนในประเทศไทยชื่อว่า “บิทคับ” (Bitkub) ข้อมูล ณ วันที่ 31 ธันวาคม 2562 นั้น มีนักลงทุนในประเทศไทยได้ทำการซื้อขายบิตคอยน์ โดยมีมูลค่าตลาดรวมประมาณ 138 บิตคอยน์ หรือ คิดเป็นเงินไทย ประมาณ 30 ล้านบาท ต่อวัน [4] ซึ่งจากข้อมูลข้างต้นทำให้เห็นว่า มีผู้ที่สนใจลงทุนในตัวบิตคอยน์ ถึงแม้ว่าจะมีผู้ที่เข้ามาในตลาดการค้าบิตคอยน์จำนวนมาก ย่อมมีผู้ที่ขาดทุนและเกิดความเครียดจนถึงขั้นฆ่าตัวตาย โดยในประเทศจีนมีนักลงทุนชาวจีนขาดทุนในการเก็งกำไรบิตคอยน์ โดยสูญเสียดังกล่าวเป็นมูลค่า 2,000 บิตคอยน์ หรือคิดเป็นมูลค่าประมาณ 434 ล้านบาท จึงทำให้นักลงทุนผู้นั้นจบชีวิตตนเอง [5] นอกจากนี้ ไม่ใช่แค่ในประเทศจีน ยังมีที่ประเทศเกาหลีใต้ นักศึกษาชาวเกาหลีใต้ผู้ซึ่งลงทุนในบิตคอยน์และเคยได้กำไรจากการลงทุน ได้ทำการฆ่าตัวตายเนื่องด้วยขาดทุนในเวลาต่อมา จึงทำให้เกิดการฆ่าตัวตาย [6] ซึ่งจากตัวอย่างข้างต้นนี้ ทำให้เห็นว่า ราคาบิตคอยน์ นั้น มีความผันผวนสูง อัตราการขาดทุนมีมาก หากไม่มีแบบจำลองในการพยากรณ์ราคาบิตคอยน์ที่ดี ย่อมส่งผลให้ผู้ลงทุนในบิตคอยน์ขาดทุน โดยปัจจุบัน มีนักวิจัยได้สร้างแบบจำลองเพื่อทำการพยากรณ์ราคาบิตคอยน์ โดยใช้เทคนิคที่นิยมใช้คือ Moving Average (MA) เนื่องจากราคาของบิตคอยน์นั้นเป็นข้อมูลแบบอนุกรมเวลา อย่างเช่น N. I. Indera และคณะ [7] ได้มีการพยากรณ์ราคาบิตคอยน์ โดยใช้เทคนิค Moving Average (MA) มาใช้ในการพยากรณ์บิตคอยน์ โดยนำตัวแปรราคาปิดตลาดของบิตคอยน์มาทำการวิเคราะห์ เนื่องจากราคาปิดตลาดสะท้อน

กิจกรรมของนักลงทุนตลอดทั้งวัน โดยนักวิจัยได้ทำการเก็บข้อมูลตั้งแต่วันที่ 12 มีนาคม ค.ศ.2012 ถึง 11 มีนาคม ค.ศ.2017 โดยทำการแบ่งข้อมูลออกเป็น การเรียนรู้ของระบบต่อการทดสอบระบบ แบบ 70 ต่อ 30

เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) [8] เป็นปัญญาประดิษฐ์แบบหนึ่งที่มีความสามารถเรียนรู้ได้ด้วยตัวเองและเกิดเป็นค่าประสบการณ์จากการเรียนรู้ซึ่งกระบวนการดังกล่าวมิได้ถูกตั้งคำสั่งด้วยโปรแกรมใด ๆ มีนักวิจัยหลายท่านนำเทคนิคการเรียนรู้ของเครื่องมาใช้ในการพยากรณ์ราคาบิตคอยน์ อย่างเช่น Karakoyun และ Cibikdiken [9] ได้ทำการพยากรณ์ราคาบิตคอยน์ล่วงหน้า 30 วัน เปรียบเทียบเทคนิค ARIMA และ MLP โดยใช้ชุดข้อมูลราคาบิตคอยน์รายวันแบบอนุกรมเวลา ตั้งแต่วันที่ 28 เมษายน 2013 ถึง 29 ตุลาคม 2017 แล้ววัดประสิทธิภาพด้วย MAPE ต่อเทคนิคทั้งสอง ผลปรากฏว่า เทคนิคแบบ ARIMA มีค่าความผิดพลาดที่ 5.36 เปอร์เซ็นต์ และเทคนิค MLP มีค่าความผิดพลาดที่ 1.40 เปอร์เซ็นต์ ตามลำดับ ดังนั้น จะเห็นได้ว่าเทคนิคการเรียนรู้ของเครื่องใช้ในการพยากรณ์ราคาบิตคอยน์แบบอนุกรมเวลา มีประสิทธิภาพดีกว่าเทคนิคแบบ Moving Average Dhruba Banjade [10] ได้ทำการพยากรณ์ราคาบิตคอยน์ โดยใช้ชุดข้อมูลราคาบิตคอยน์รายวันจาก www.coindesk.com/price/ ตั้งแต่ เดือน ธันวาคม 2014 ถึง เดือน สิงหาคม 2018 ซึ่งมีข้อมูลทั้งสิ้น 1230 ชุดข้อมูล และได้้นำเทคนิคโครงข่ายประสาทเทียม (ANN) มาสร้างแบบจำลองเพื่อทำการพยากรณ์ราคาบิตคอยน์ และใช้วิธี RMSE ในการวัดประสิทธิภาพของแบบจำลองที่ใช้ในการพยากรณ์ และ หาค่า R-Squared พบว่าค่า RMSE เท่ากับ 10.20 และ ค่า R-Squared เท่ากับ 0.96 ซึ่งนักวิจัยได้ทำการทดลองเพียงครั้งเดียวต่อแบบจำลอง ส่วนสมร เหล็กกล้า และ จารี ทองคำ [11] ศึกษาเทคนิคและสร้างแบบจำลองเพื่อทำการพยากรณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศ โดยนำข้อมูลขาขึ้นจากเว็บไซต์ www.exness.com ซึ่งเป็นเว็บไซต์ที่ทำการซื้อขายค่าเงินออนไลน์จำนวน 5 สกุลเงิน อันได้แก่ EURUSD, USDJPY, USDCHF, NZDUSD และ GBPUSD ตั้งแต่เดือนกุมภาพันธ์ 2014 ถึงเดือนมกราคม 2017 ซึ่งเป็นข้อมูลอนุกรมเวลา และได้นำเทคนิคดังต่อไปนี้มาทำการพยากรณ์ ได้แก่ Linear Regression, Multi-Layer Perceptron, Support Vector Machine Regression และ เทคนิค Sequential Minimal Optimization Regression และได้ใช้ sliding windows จำนวน 12 รอบ และวัดประสิทธิภาพแบบจำลองในการพยากรณ์ด้วยเทคนิคดังกล่าว ได้แก่ MAE และ RMSE พบว่า เทคนิค Support Vector Machine Regression เหมาะกับการพยากรณ์อัตราแลกเปลี่ยนเงินตรามากที่สุดจากทุกเทคนิค

นอกเหนือจากเทคนิคการเรียนรู้ของเครื่อง แล้วนั้น ยังมี เทคนิคที่เป็นที่นิยมในการใช้พยากรณ์ ข้อมูลที่เป็นอนุกรมเวลาและให้ผลที่มีประสิทธิภาพที่ดี เช่นเทคนิค ARIMA ซึ่งมีนักวิจัยหลายคน เช่น Khedmatia Majid และคณะ [12] ได้ทำการพยากรณ์ราคาบิตคอยน์รายวันตั้งแต่วันที่ 16 ธันวาคม ค.ศ.2017 ถึงวันที่ 1 มิถุนายน ค.ศ.2018 โดยพยากรณ์ราคาบิตตลาดรายวัน จาก www.investing.com โดยใช้เทคนิค ARIMA Kriging ANN Bayesian SVR และ Random Forest โดยวัดประสิทธิภาพของเทคนิคด้วยวิธี RMSE และ MAPE ผลปรากฏว่า เทคนิค ARIMA ให้ ประสิทธิภาพในการพยากรณ์ราคาบิตคอยน์ที่ดีที่สุด ซึ่งมีค่าความคลาดเคลื่อนที่วัดได้ด้วยวิธี RMSE เท่ากับ 258.81 และ วิธี MAPE เท่ากับ 2.36 เปอร์เซ็นต์

ดังนั้นงานวิจัยนี้ผู้วิจัยจะใช้เทคนิค ARIMA, Multilayer Perceptron, Support Vector Machine และ Basis Radial Function ในการสร้างแบบจำลองในการพยากรณ์ราคาของบิตคอยน์ โดยใช้ข้อมูลราคาเปิดตลาด (open) ราคาสูงสุด (High) ราคาต่ำสุด (Low) ราคาปิดตลาด (Close) ปริมาณการซื้อขายในแต่ละวัน (Volume) และ มูลค่าตลาดรวมของบิตคอยน์ (Marketcap) การ ทดลองผู้วิจัยได้นำเอาหลักการ sliding window มาทำการวัดประสิทธิภาพของแบบจำลองและใช้ค่า Mean Absolute Error (MAE) และ Root Mean Square Error (RMSE) เข้ามาตรวจสอบ ประสิทธิภาพของแบบจำลองจากเทคนิคต่าง ๆ ข้างต้น

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 เพื่อศึกษาเทคนิค ARIMA, Multilayer Perceptron, Support Vector Machine for regression และ Basis Radial Function ที่ใช้ในการสร้างแบบจำลองในการพยากรณ์ราคาบิตคอยน์

1.2.2 เพื่อเปรียบเทียบและวัดประสิทธิภาพแบบจำลอง ARIMA, Multilayer Perceptron, Support Vector Machine for regression และ Basis Radial Function ในการพยากรณ์ราคาบิต คอยน์

1.3 ความสำคัญของงานวิจัย

1.3.1 ได้แนวทางในการสร้างแบบจำลองราคาเปิดตลาด (open) ราคาสูงสุด (High) ราคาต่ำสุด (Low) ราคาปิดตลาด (Close) ปริมาณการซื้อขายในแต่ละวัน (Volume) และ มูลค่าตลาดรวมของ บิตคอยน์ (Marketcap) ของบิตคอยน์

1.3.2 ได้แบบจำลองที่มีประสิทธิภาพในการพยากรณ์ราคาเปิดตลาด (open) ราคาสูงสุด (High) ราคาต่ำสุด (Low) ราคาปิดตลาด (Close) ปริมาณการซื้อขายในแต่ละวัน (Volume) และ มูลค่าตลาดรวมของบิตคอยน์ (Marketcap)

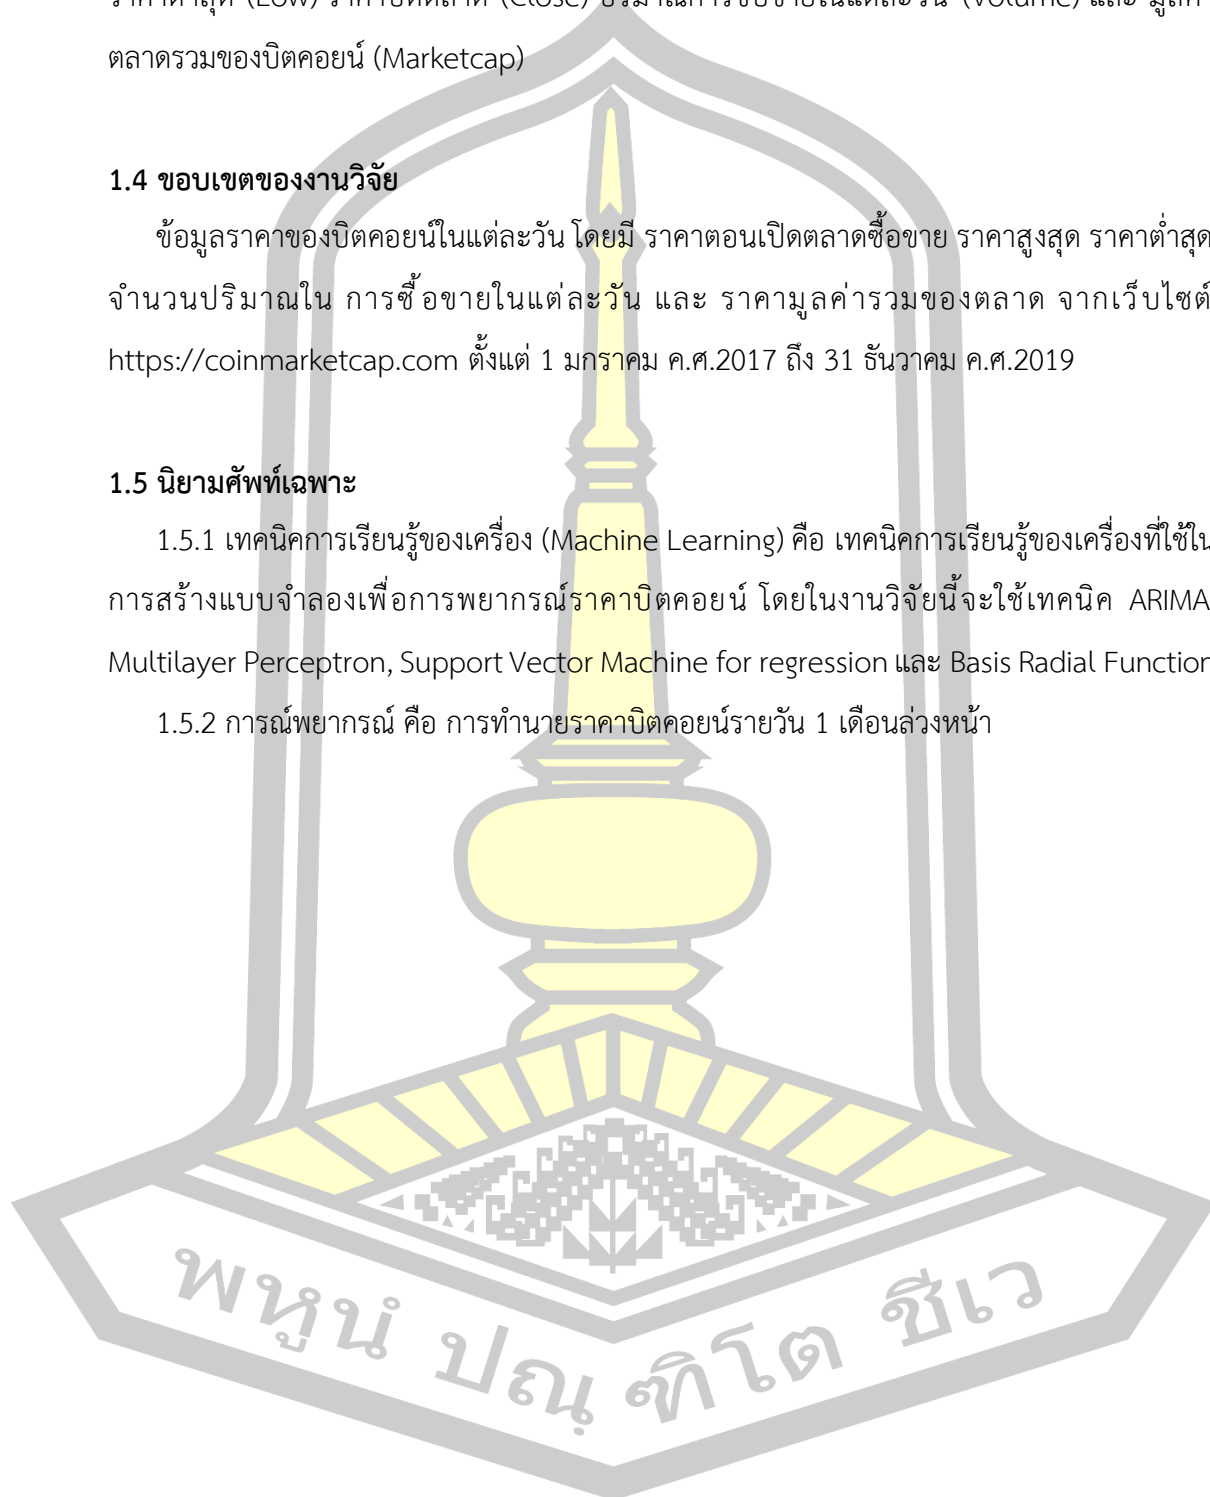
1.4 ขอบเขตของงานวิจัย

ข้อมูลราคาของบิตคอยน์ในแต่ละวัน โดยมี ราคาตอนเปิดตลาดซื้อขาย ราคาสูงสุด ราคาต่ำสุด จำนวนปริมาณในการซื้อขายในแต่ละวัน และ ราคามูลค่ารวมของตลาด จากเว็บไซต์ <https://coinmarketcap.com> ตั้งแต่ 1 มกราคม ค.ศ.2017 ถึง 31 ธันวาคม ค.ศ.2019

1.5 นิยามศัพท์เฉพาะ

1.5.1 เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) คือ เทคนิคการเรียนรู้ของเครื่องที่ใช้ในการสร้างแบบจำลองเพื่อการพยากรณ์ราคาบิตคอยน์ โดยในงานวิจัยนี้จะใช้เทคนิค ARIMA, Multilayer Perceptron, Support Vector Machine for regression และ Basis Radial Function

1.5.2 การณ์พยากรณ์ คือ การทำนายราคาบิตคอยน์รายวัน 1 เดือนล่วงหน้า



บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะดำเนินการอธิบายทฤษฎีที่เกี่ยวข้องซึ่งประกอบด้วย บิตคอยน์ Coinmarketcap การพยากรณ์ อนุกรมเวลา การวิเคราะห์อนุกรมเวลา การวัดประสิทธิภาพแบบจำลอง และงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 บิตคอยน์

บิตคอยน์ถือเป็นสกุลเงินเสมือนจริงชนิดหนึ่งที่ใช้ในการรับชำระหรือใช้จ่ายผ่านระบบเครือข่าย โดยผู้ใช้งานไม่ต้องแสดงตน มีความเป็นส่วนตัวสูง และไม่ถูกควบคุมโดยรัฐบาลในส่วนของ การเงินการธนาคาร ข้อดีของบิตคอยน์คือ มีความเป็นส่วนตัวสูง ไม่สามารถระบุตัวตนได้ สามารถส่งผ่านจากที่หนึ่งไปยังอีกที่หนึ่งผ่านระบบเครือข่ายได้ครั้งละมาก ๆ มีความรวดเร็วและมีค่าธรรมเนียมต่ำ เมื่อเทียบกับการชำระเงินปกติ และถึงแม้ว่าบิตคอยน์จะมีข้อได้เปรียบกว่าเงินทั่วไปแบบเก่า เช่นสกุลเงินยูเอส ดอลลาร์ เงินบาท หรือ เงินกีบ นั้น เงินดิจิทัลหรือบิตคอยน์นี้ ยังมีข้อเสียเปรียบอยู่ กล่าวคือ หากผู้ใช้งานมีความรู้ทางด้านเทคโนโลยีไม่มากพอ อาจมีความเสี่ยงในการใช้บิตคอยน์ในการใช้จ่าย เนื่องจากว่า บิตคอยน์ไม่ได้ถูกควบคุมโดยรัฐบาลใดรัฐบาลหนึ่ง ดังนั้น เมื่อมันมีความเป็นส่วนตัวสูง ไร้ตัวตน การทำธุรกรรมที่ผิดพลาดย่อมส่งผลเสียหายต่อผู้ใช้ที่ไม่มีควมรู้มากพอในการใช้ และไม่ได้รับการคุ้มครองจากรัฐบาลใด ๆ

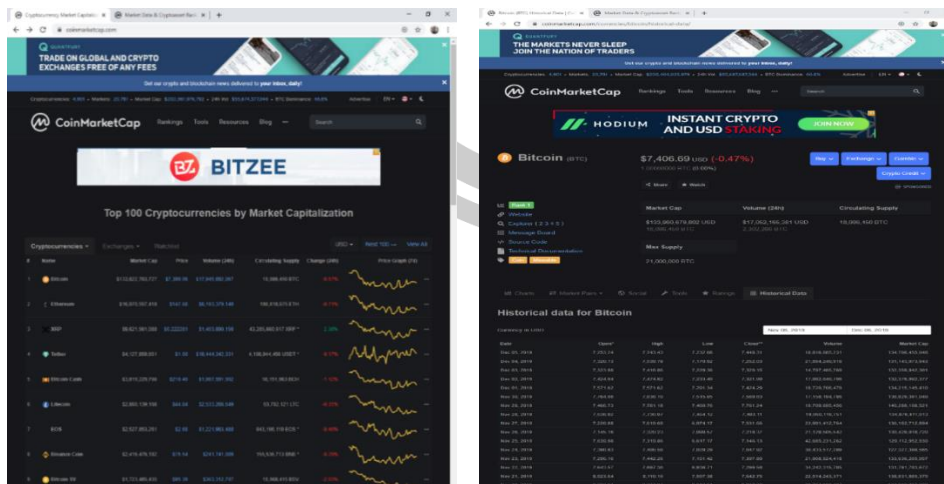
ในการลงทุน ข้อมูลที่เป็นประโยชน์ต่อนักลงทุน ได้แก่ ราคาเปิดตลาด (Open) ซึ่งหมายถึง ราคาเปิดตลาดของการเทรดบิตคอยน์ในกระดานเทรดบิตคอยน์ทั่วโลกที่นำมาคิดเป็นค่าเฉลี่ย โดยอ้างอิงเวลาจาก UTC (Coordinated Universal Time) โดยเริ่ม UTC+14:00 ราคาสูงสุด (High) หมายถึง ราคาสูงสุดของบิตคอยน์ในแต่ละวัน โดยเป็นค่าเฉลี่ยราคาสูงสุดในกระดานเทรดบิตคอยน์ทั่วโลก ราคาต่ำสุด (Low) หมายถึง ราคาต่ำสุดของบิตคอยน์ในแต่ละวัน โดยเป็นค่าเฉลี่ยราคาต่ำสุดในกระดานเทรดบิตคอยน์ทั่วโลก ราคาปิดตลาด (Close) หมายถึง ราคาปิดตลาดของการเทรดบิตคอยน์ในกระดานเทรดบิตคอยน์ทั่วโลกที่นำมาคิดเป็นค่าเฉลี่ย โดยอ้างอิงเวลาจาก UTC (Coordinated Universal Time) โดยเริ่ม UTC-12:00 มูลค่าการซื้อขาย (Volume) หมายถึง มูลค่าการซื้อขายบิตคอยน์ในแต่ละวัน มีหน่วยเป็น ยูเอสดอลลาร์ และ ข้อมูลสุดท้ายคือ มูลค่าตลาดรวม

(Marketcap) หมายถึง มูลค่าตลาดรวมของราคาบิตคอยน์ โดยได้มาจากจำนวนบิตคอยน์คูณด้วยราคาเปิดตลาด ซึ่งตัวแปรที่ได้กล่าวมาทั้งหมดนี้ เป็นข้อมูลอนุกรมเวลาและสามารถนำมาพยากรณ์ราคาได้ด้วยเทคนิค ARIMA, Multilayer Perceptron, Support Vector Machine และ Basis Radial Function โดยนำเทคนิคดังกล่าวมาทำการพยากรณ์ราคาแต่ละตัวแปร เนื่องจากแต่ละตัวแปรมีผลต่อการตัดสินใจของผู้ลงทุน ซึ่งหลักทรัพย์บัวหลวง [13] และ Barbara Rockefeller [14] ผู้แต่งหนังสือ Technical Analysis for Dummies ได้สรุปใจความสำคัญของตลาดหลักทรัพย์ต่าง ๆ ว่า ราคาเปิดตลาด จะเป็นตัวบอกนักลงทุนในการเตรียมกลยุทธ์ในการลงทุน ราคาสูงสุดของบิตคอยน์ จะเป็นตัวบอกนักลงทุนว่าสามารถทำกำไรสูงสุดได้ในแต่ละวัน ราคาต่ำสุดจะเป็นตัวบอกให้นักลงทุนทำการเข้าซื้อบิตคอยน์ ราคาปิดตลาด ทำให้ทราบถึงกิจกรรมของผู้ลงทุนในหนึ่งวันนั้น ๆ ว่ามีสถานะเช่นไร ตลาดมีแนวโน้มเป็นอย่างไร ปริมาณการซื้อขายหมายถึง มูลค่าการซื้อขายบิตคอยน์ในแต่ละวัน มีหน่วยเป็น ยูเอสดอลลาร์ ซึ่งตัวแปรนี้บ่งบอกถึงสภาพคล่องของตลาดว่ามีความคึกคักมากน้อยขนาดไหน มีผู้ลงทุนมาน้อยเพียงใด มูลค่าตลาดรวมหมายถึง มูลค่าตลาดรวมของราคาบิตคอยน์ ทำให้สามารถทราบถึงความนิยมในตัวบิตคอยน์ที่เพิ่มสูงขึ้นหรือลดลง

2.1.2 Coinmarketcap

เว็บไซต์ coinmarketcap [3] เป็นเว็บไซต์ที่รวบรวมราคาของสกุลเงินดิจิทัลต่าง ๆ จากตลาดซื้อขายสกุลเงินดิจิทัลที่มีอยู่ทั่วโลก โดยจะมีการปรับปรุงความเคลื่อนไหวของราคาเป็นแบบนาที่ต่อนาที่ โดยจะแสดงข้อมูลเป็นสกุลเงินดิจิทัลต่อ ยูเอสดอลลาร์ เป็นหลัก โดยราคาที่แสดงบนหน้าเว็บไซต์นั้น จะเป็นการนำราคาของตลาดซื้อขายทั้งหมดมาหาค่าเฉลี่ย จากนั้น เมื่อได้ค่าเฉลี่ยเป็นราคาของเหรียญเป็นยูเอสดอลลาร์ แล้ว จึงจะทำการเปลี่ยนเป็นเงินสกุลอื่น ซึ่งในเว็บไซด์นี้ จะมีข้อมูลที่เกี่ยวข้องกับ วันที่, ราคาตอนเปิดตลาดซื้อขาย, ราคาสูงสุด, ราคาต่ำสุด, จำนวนปริมาณในการซื้อขายในแต่ละวัน และ ราคาดุลค่ารวมของตลาด

พหุ ประถมศึกษา



ภาพประกอบที่ 2.1 หน้า Website Coinmarketcap
ที่มา : [3]


2.1.3 การพยากรณ์

การพยากรณ์ หรือ การทำนายอนาคต โดยการกล่าวถึงของ รุ่งทิวา ถนอมบุญ และสมบัติ ทิมทรัพย์ [15] ได้กล่าวไว้ว่า การพยากรณ์เป็นการนำสารสนเทศในอดีตมาทำการวิเคราะห์อนาคต ซึ่งผลจากอดีตย่อมเป็นปัจจัยที่ส่งผลต่ออนาคต โดยการพยากรณ์นั้น เพื่อให้ทราบถึงแนวโน้มในอนาคตว่า สารสนเทศในอดีต จะส่งผลอย่างไรต่ออนาคตในแง่ดี หรือ แย่ลง ซึ่งผู้ทำการพยากรณ์จะให้ความสำคัญในการพยากรณ์ เพื่อกำหนดแผนนโยบายที่คาดว่าจะได้รับในการทำนายอนาคต นำไปใช้ประโยชน์ในศาสตร์ต่าง ๆ อาทิ เช่น การทำนายเหตุการณ์อาชญากรรม สภาพอากาศ หรือ ในด้านสุขภาพและสาธารณสุข เป็นต้น ซึ่งการวิจัยการทำนายอนาคต นั้น แยกออกเป็นการวิจัยเชิงคุณภาพ สามารถดำเนินการเกี่ยวกับข้อมูลในเชิงลึกได้ดี แต่ไม่สามารถนำข้อมูลตัวแปรหลาย ๆ ชนิด มาทำการพยากรณ์ได้ และในส่วนการวิจัยเชิงปริมาณ จะให้ความสำคัญเกี่ยวกับตัวแปร ที่มีสารสนเทศที่เกี่ยวข้องเพียงพอและสามารถแปลงเป็นตัวเลขได้ ซึ่งมีข้อดีคือสามารถนำข้อมูลจำนวนมากมาทำการวิเคราะห์และพยากรณ์อนาคตได้ดี

2.1.4 อนุกรมเวลา

อนุกรมเวลา [16] (Time Series) หมายถึง การเก็บข้อมูลที่ต่อเนื่องของตัวแปรในห้วงระยะเวลาหนึ่ง โดยมีเวลาเข้ามาเกี่ยวข้อง โดยอาจจะเก็บข้อมูลเป็น รายวัน รายสัปดาห์ รายเดือน รายปี เป็นต้น ข้อมูลอนุกรมเวลามี 4 ลักษณะ ดังนี้


- แนวโน้ม (Trend) คือ ทิศทางการขึ้น หรือ ลง ของอนุกรมเวลา เมื่อมีค่าผ่านไประยะเวลาหนึ่ง ซึ่งแนวโน้มนี้จะสามารถบอกได้ว่าอัตราการเก็บรวบรวมข้อมูลจะมีอัตราเพิ่มขึ้นหรือลดลง ตัวอย่างเช่นการเก็บข้อมูลรายเดือนของยอดขายบริษัทแห่งหนึ่ง ซึ่งในกราฟนั้น การเก็บข้อมูลรายเดือนห้วงระยะเวลา พ.ศ.2543 ถึง 2554 มีแนวโน้มทิศทางเพิ่มขึ้น



ภาพประกอบที่ 2.2 แนวโน้มอนุกรมเวลา

ที่มา: [16]

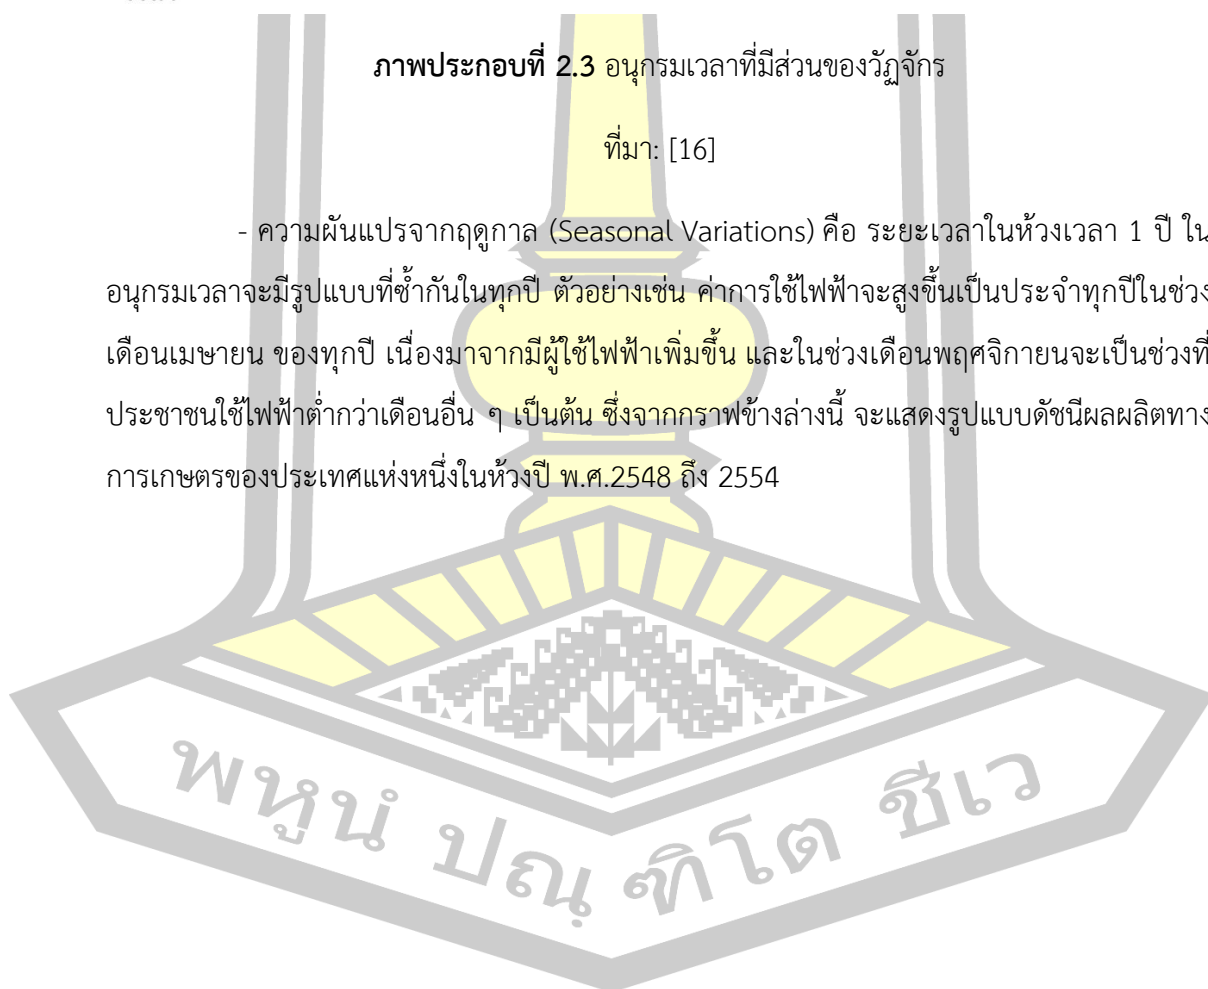
- วัฏจักร (Cycle) คือ ค่าความขึ้นลงในหนึ่งรอบ ซึ่งการนับระยะเวลา จะเกิดขึ้นจากจุดสูงสุด (Peak) ไปหาจุดต่ำสุด (Trough) หรือ จากจุดต่ำสุด ไปหาจุดสูงสุด ซึ่งนับเป็นหนึ่งรอบ และในห้วงที่มีการเปลี่ยนแปลงจากสูงสุดไปยังต่ำสุด ระยะเวลาที่เริ่มมีค่าลดลงนี้จะเรียกว่า ช่วงถดถอย (Recession) และในทางตรงกันข้าม หากจากจุดต่ำสุดเริ่มมีค่าเพิ่มขึ้นไปยังจุดสูงสุด ในห้วงระยะเวลานี้จะเรียกว่า ช่วงฟื้นตัว (Recovery)




ภาพประกอบที่ 2.3 อนุกรมเวลาที่มีส่วนของวัฏจักร

ที่มา: [16]

- ความผันแปรจากฤดูกาล (Seasonal Variations) คือ ระยะเวลาในห้วงเวลา 1 ปี ในอนุกรมเวลาจะมีรูปแบบที่ซ้ำกันในทุกปี ตัวอย่างเช่น ค่าการใช้ไฟฟ้าจะสูงขึ้นเป็นประจำทุกปีในช่วงเดือนเมษายน ของทุกปี เนื่องจากมีผู้ใช้ไฟฟ้าเพิ่มขึ้น และในช่วงเดือนพฤศจิกายนจะเป็นช่วงที่ประชาชนใช้ไฟฟ้าต่ำกว่าเดือนอื่น ๆ เป็นต้น ซึ่งจากกราฟข้างล่างนี้ จะแสดงรูปแบบดัชนีผลผลิตทางการเกษตรของประเทศแห่งหนึ่งในห้วงปี พ.ศ.2548 ถึง 2554





ภาพประกอบที่ 2.4 ความผันแปรจากฤดูกาล

ที่มา: [16]

- ความผันผวนจากเหตุการณ์ไม่ปกติ (Irregular Fluctuations) คือ เหตุการณ์ไม่ปกติ หรือ เหตุการณ์ไม่คาดคิด ที่เกิดขึ้นในห้วงระยะเวลาในอนุกรมเวลา และทำให้รูปแบบอนุกรมเวลา มีความผิดปกติจากรูปแบบเดิม ซึ่งสถานการณ์ที่ทำให้รูปแบบค่าความผิดปกติในอนุกรมเวลานั้น ได้แก่ มีภัยพิบัติ หรือ มีการสู้รบหรือสงคราม เป็นต้น ซึ่งค่าความผันผวนจากเหตุการณ์ไม่ปกตินี้ สามารถคำนวณได้จากการนำค่าแนวโน้ม ค่าวัฏจักร และค่าความผันแปรของฤดูกาลไปหักล้างออกจากค่าอนุกรมเวลา

2.1.5 การวิเคราะห์อนุกรมเวลา

การวิเคราะห์อนุกรมเวลาเป็นระเบียบทางสถิติวิธีพยากรณ์เชิงปริมาณ (Quantitative Forecasting Method) โดยการนำตัวแปรที่สนใจมาวิเคราะห์ และนำไปพยากรณ์ โดยทั่วไปจะใช้ค่าเฉลี่ยของข้อมูล (Mean) ความแปรปรวน (Variance) และค่าความแปรปรวนในช่วงของเวลา (Autocovariance) มาคำนวณ รวมถึงการคำนวณด้วย moving average รวมถึง โดยวิธีของ Box-Jenkins แต่มีนักวิจัยหลายท่านได้ทำนำเอาเทคนิค machine learning มาใช้ในการวิเคราะห์อนุกรมเวลา เช่น สุมิตรรา เมืองขวา [17] ได้พยากรณ์ราคาสุกรพันธุ์ลูกผสม น้ำหนัก 100 กิโลกรัมขึ้นไป

ข้อมูลตั้งแต่ เดือนมกราคม พ.ศ.2556 ถึงเดือนธันวาคม พ.ศ.2560 ระยะเวลา 63 เดือน โดยใช้วิธี Box-Jenkins ผลปรากฏว่ามีค่าความแม่นยำสูงเมื่อเปรียบเทียบค่าพยากรณ์ที่ได้กับค่าราคาจริง โดยค่า RMSE เท่ากับ 1.2720 บาทต่อกิโลกรัม

ในการวิเคราะห์อนุกรมเวลา [16] มีขั้นตอนวิธีดังต่อไปนี้

1. การเตรียมข้อมูล คือ การนำข้อมูลที่มีความต่อเนื่องกันในอดีตเพื่อนำไปใช้ในการพยากรณ์ เช่น ยอดขายรถยนต์รายเดือนในอดีต เพื่อนำไปพยากรณ์ยอดขายรถยนต์ในอนาคต
2. การวิเคราะห์ข้อมูล เป็นขั้นตอนของการวิเคราะห์ว่าข้อมูลที่น่าสนใจมีลักษณะอย่างไร เพื่อให้สามารถเลือกเทคนิคที่จะนำมาใช้ได้อย่างถูกต้อง
3. การสร้างแบบจำลอง เป็นขั้นตอนของการสร้างแบบจำลองเพื่อใช้ในการพยากรณ์ ซึ่งเทคนิคที่นิยมนำมาใช้มีดังต่อไปนี้
4. การประเมินแบบจำลอง เป็นขั้นตอนวัดประสิทธิภาพแบบจำลองที่ใช้ในการพยากรณ์ เพื่อทราบถึงค่าความคลาดเคลื่อนของแบบจำลอง

2.1.6 เทคนิคในการสร้างแบบจำลอง

- ARIMA model หรือ ที่เรียกว่า Auto Regressive Integrated Moving Average ซึ่งเทคนิคนี้แยกออกเป็น 3 ส่วนหลัก ๆ คือ Auto Regressive (AR) แทนด้วยค่า p , Integrated (I) แทนด้วยค่า d และ Moving Average (MA) แทนด้วยค่า q สามารถเขียนเป็นตัวย่อ ARIMA (p, d, q) ซึ่งเทคนิคนี้ จะเป็นการกำจัด Noise เพื่อให้มีค่า error ต่ำที่สุด เมื่อทำการพยากรณ์ข้อมูลที่เป็นอนุกรมเวลา [18] โดยมีสมการดังต่อไปนี้

Auto Regressive มีสมการคือ

$$x_t = C + \sum_{i=1}^p \varphi_i x_{t-i} + \varepsilon_t \quad (2.1)$$

โดยที่

C = ค่าคงที่

φ_i = order ของ auto regressive

x_{t-i} = ค่าของ time series ที่เวลา $t - i$

ε_t = ค่า error ของโมเดล

Moving Average มีสมการคือ

$$x_t = \mu + \varepsilon_t \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.2)$$

โดยที่


μ = ค่าคงที่

ε_t = Error Term ของโมเดล

θ_i = order ของ moving average

ε_{t-i} = คือผลรวมของ error term $t - i$

- โครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (multilayer perceptron for linear regression) [19] เป็นโครงข่ายประสาทเทียมชนิดหนึ่งที่จำลองโครงข่ายประสาทของสมอง โดยมีโครงสร้างหลัก ๆ อยู่ 3 ส่วนด้วยกันคือ ชั้นข้อมูลเข้า (Input layer) ชั้นซ่อน (Hidden layer) และ ชั้นข้อมูลออก (Output layer) ซึ่งแต่ละชั้นจะมีโหนดเซลล์ประสาท (Neuron) เชื่อมต่อกันแบบโครงข่ายของประสาท ซึ่งเส้นเชื่อมต่อระหว่างโหนดจะเรียกว่า Connection โดยสามารถแสดงโครงสร้างได้ดังภาพประกอบที่ 2.5



ภาพประกอบที่ 2.5 โครงสร้าง Multilayer Perceptron สำหรับการถดถอย

ที่มา: [20]


หลักการการทำงานของ MLP นั้น ชั้นข้อมูลเข้าจะทำการรับข้อมูลเข้าแล้วทำการส่งผ่านข้อมูลไปยังเส้นเชื่อมระหว่างโหนด (Connection) และจะทำการคำนวณกับค่าน้ำหนัก (Weight) เพื่อให้ค่าที่ได้มากกว่าค่าจุดกระตุ้นที่กำหนด (Threshold) หากข้อมูลคูณด้วยค่า Weight น้อยกว่าค่ากระตุ้น ข้อมูลจะไม่ได้ถูกส่งต่อไปยังโหนดต่อไป ซึ่งสามารถอธิบายได้ด้วยสมการต่อไปนี้

$$\text{If } (\text{sum}(\text{input} * \text{weight}) > \text{threshold}) \text{ then output} \quad (2.3)$$

ในเทคนิค MLP จะมี อัลกอริทึมที่เรียกว่า “back propagation” ทำหน้าที่เป็นระบบที่ทำการเรียนรู้ของโครงข่าย เมื่อข้อมูลที่เข้ามายังโหนดข้อมูลขาเข้า หรือ Input และไม่สามารถผ่านจุดกระตุ้นเพื่อให้ได้ผลลัพธ์ Output ออกไปได้ ระบบจะทำการปรับค่าน้ำหนัก (Weight) ให้มีผลลัพธ์ที่มากกว่าจุดกระตุ้น (Threshold) เพื่อให้ข้อมูลผ่านไปยังโหนดถัดไป ดังนั้นระบบจะทำการปรับสมดุลค่าน้ำหนักและเกิดการเรียนรู้ขึ้น และทำการเปรียบเทียบค่าความคาดหวังและกับค่าที่ได้ และคำนวณหาค่าความคลาดเคลื่อน ซึ่งเทคนิค MLP นั้น จะทำการปรับค่าซ้ำ ๆ เพื่อให้ได้ผลลัพธ์ค่าความคลาดเคลื่อนที่ดีที่สุด หากระบบยังไม่สามารถเรียนรู้และทำการปรับสมดุลของค่าน้ำหนัก (Weight) จนได้ค่าความผิดพลาดที่ดีที่สุด ระบบจะส่งข้อมูลย้อนกลับไปปรับค่าน้ำหนัก (Weight) จนกว่าจะได้ค่าที่ดีที่สุด

- Support Vector Machine Regression (SVR) [21] เป็นเทคนิคที่ใช้ในการพยากรณ์มาสร้างโมเดลการหาความสัมพันธ์เชิงเส้นได้ด้วยวิธีการถดถอยเชิงเส้น (Regression) โดยมีสมการเชิงเส้นคือ $f(x)$ หรือที่เรียกว่า Support Vector Machine for Regression (SVR) เนื่องจากนำมาวิเคราะห์ชุดข้อมูลที่เป็นค่า (Value) และมีความต่อเนื่อง ซึ่งในงานวิจัยนี้จะได้นำเทคนิค SVR มาสร้างแบบจำลองเพื่อทำการเปรียบเทียบกับแบบจำลองอื่น ๆ สำหรับการพยากรณ์ [22]

พหุ ประถมศึกษา



- Radial Basis Function (RBF) [23] เป็นเทคนิคหนึ่งที่มีความนิยมเพิ่มขึ้นจากหลายๆ เทคนิคในโครงข่ายประสาทเทียม ซึ่งนิยมนำมาใช้วิเคราะห์ในข้อมูลของวิทยาการคอมพิวเตอร์และเกี่ยวกับข้อมูลทางด้านวิศวกรรม ซึ่งเทคนิค RBF นี้ เป็นเทคนิคที่ส่งข้อมูลไปข้างหน้า (Feed-forward neural network) โดยมีสามชั้นหลัก ๆ คือ ชั้นป้อนข้อมูลเข้า หรือ input ที่ถูกสร้างขึ้นเพื่อรับข้อมูลขาเข้า และถัดมาจะเป็นชั้นซ่อน หรือ Hidden layer ซึ่งจะถูกเชื่อมต่อโดยตรงกับชั้นข้อมูลขาเข้าทุก โหนด (Nodes) และในส่วนสุดท้ายเป็นชั้นข้อมูลออก หรือ Output layer ซึ่งเป็นการรวมกันแบบเชิงเส้นกับชั้นข้อมูลเข้าและพารามิเตอร์ของเซลล์ประสาทเทียม ซึ่ง ชั้นข้อมูลเข้ามีความสัมพันธ์กับชั้นข้อมูลออก โดย ชั้นข้อมูลออก แทนโดย y_{t+1} และ ชั้นข้อมูลเข้า แทนโดย y_1, y_2, y_3 ไปจนถึง y_t ตาม

สมการ 2.4

$$y_{t+1} = \alpha_0 + \sum_{j=1}^q \alpha_j g(\beta_{ij} + \sum \beta_{ij} y_{t-i+1}) + \varepsilon \quad (2.4)$$

โดยมี α_j ($j=0, 1, 2, 3, \dots, q$) และ β_{ij} ($i=0, 1, 2, \dots, p; j=1, 2, 3, \dots, q$) ซึ่ง α และ β เป็นพารามิเตอร์ ที่คอยปรับสมดุล หรือ Connection Weights และ p หมายถึง จำนวนโหนดข้อมูลนำเข้า และ q คือจำนวนโหนดที่ซ่อนอยู่ (Hidden nodes) ซึ่งเทคนิค RBF นี้มีคุณสมบัติที่ได้เปรียบกว่าเทคนิคอื่น ๆ ในเรื่องของการออกแบบและใช้เวลาอันสั้นในการให้ระบบเรียนรู้ข้อมูล เทคนิค RBF

นอกจากนำมาใช้ในการ Classification ยังสามารถนำมาพยากรณ์ข้อมูลด้วยเทคนิค Regression ได้ โดยใช้ ฟังก์ชันเกาส์เซียน (Gaussian Function) ซึ่งจะเรียกว่าเทคนิค RBFRegressor [24] ซึ่งฟังก์ชันเกาส์เซียน จะอยู่ในทุกโหนดของชั้นซ่อน (Hidden layers) ทำการคำนวณจุดศูนย์กลางรัศมีของข้อมูล และกำหนดเป็นระยะห่างของจุดศูนย์กลางของฟังก์ชัน ซึ่งข้อมูลที่อยู่ใกล้จุดศูนย์กลางมากที่สุดจะมีค่าความอ่อนไหวมากที่สุด โดยฟังก์ชันเกาส์เซียน มีสมการดังต่อไปนี้

$$\phi(x - c_i) = e^{-\|x - c_i\|^2 / 2\sigma^2} \quad (2.5)$$

โดยที่ C_i คือจุดศูนย์กลางของชุดข้อมูลในพื้นที่ของฟังก์ชัน และ σ คือค่ารัศมีของฟังก์ชัน ซึ่งเทคนิค RBFRegressor นั้น เหมาะกับการคำนวณข้อมูลที่ไม่ได้เป็นเชิงเส้น และปรับค่าความคลาดเคลื่อน (Weight) ออกมาเป็นข้อมูลเชิงเส้น ดังนั้นเทคนิค RBFRegressor เหมาะกับการจัดการกับข้อมูลที่มีความหลากหลายได้ดี

4 การวัดประสิทธิภาพแบบจำลอง

งานวิจัยนี้มีการวัดค่าประสิทธิภาพแบบจำลอง โดยใช้หลักการดังต่อไปนี้

- Sliding Window [11] โดยการแบ่งชุดข้อมูลออกเป็นสองส่วน คือ ชุดข้อมูลที่ให้ระบบทำการเรียนรู้ หรือ Training data และชุดที่ใช้ทำการทดสอบ หรือที่เรียกว่า Testing data โดยข้อมูลที่ใช้เรียนรู้และทดสอบจะเลื่อนไปที่ละชุดจนครบวงรอบ Piyush Kapoor และ Sarabjeet Singh Bedi [25] ได้ทำการพยากรณ์สภาพอากาศเมือง Champawat ประเทศอินเดีย ตั้งแต่ปี 2006 ถึง 2010 และได้้นำเทคนิค sliding window มาใช้เรียนรู้และทดสอบระบบของเทคนิค ANN หรือ โครงข่ายประสาทเทียม ซึ่งเทคนิค sliding window นั้น เหมาะสมกับการพยากรณ์ โดยเฉพาะการพยากรณ์อนุกรมเวลา ซึ่งในงานวิจัยนี้มีตัวอย่างดังต่อไปนี้

ข้อมูล 36 เดือน ชุดข้อมูลทั้งหมดเริ่มตั้งแต่เดือน ม.ค.2017 ถึง ธ.ค.2019 จากนั้นทำการแบ่งระยะเวลาเดือน ม.ค.2017 ถึง ธ.ค.2018 เป็นชุดเรียนรู้ของระบบ (Training) ครั้งที่ 1 และเดือน ม.ค.2019 เป็นชุดข้อมูลทดสอบครั้งที่ 1 (Testing) จากนั้น ทำการเลื่อนชุดข้อมูลทั้งชุดเรียนรู้ของระบบ (Training) และชุดทดสอบ (Testing) อย่างละ 1 เดือน จะได้ชุดเรียนรู้ของระบบ (Training) ครั้งที่ 2 เป็นเดือน ก.พ.2017 ถึง ม.ค.2019 และชุดทดสอบ (Testing) ครั้งที่ 2 เป็นเดือน ก.พ.2019 จากนั้นทำการเลื่อนข้อมูลไปจนถึงข้อมูลชุดสุดท้าย ซึ่งจะเป็นการเรียนรู้ของระบบและทดสอบระบบ (Training and Testing) ครั้งที่ 12 โดยมีเดือน ธ.ค.2017 ถึง พ.ย.2019 เป็นชุดเรียนรู้ของระบบ (Training) ครั้งที่ 12 และเดือน ธ.ค.2019 เป็นชุดทดสอบ (Testing) ครั้งที่ 12 โดยสามารถอธิบายได้ดังนี้

ครั้งที่ 1 ■ Training ■ Testing

ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2017
ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2018
ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2019

ครั้งที่ 2 ■ Training ■ Testing

ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2017
ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2018
ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2019

... ครั้งที่ 12 ■ Training ■ Testing

ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2017
ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2018
ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	2019

จากนั้นจะได้ทำการวัดประสิทธิภาพของแบบจำลองโดยใช้วิธี หาค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (Mean Absolute Error) และ วิธี หาค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error)

- Mean Absolute Error (MAE) [26] คือ การหาค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ เป็นวิธีการหาค่าเฉลี่ยความแตกต่างระหว่างค่าพยากรณ์และความความจริง หากค่าที่ได้ มีค่าน้อย แสดงว่าค่าพยากรณ์มีค่าใกล้เคียงค่าจริง ดังสมการที่ 2.6

พหุบัณฑิต ชีเว

$$MAE = \frac{1}{N} \sum_{t=1}^N |e_t| \quad (2.6)$$

โดยที่ $e_t = x_t - \hat{x}_t$ แทนค่าคลาดเคลื่อนจากการพยากรณ์ ณ เวลา t

N แทนจำนวนเทอมทั้งหมดของ e_t

x_t แทนข้อมูล ณ เวลา t

\hat{x}_t แทนค่าพยากรณ์ ณ เวลา t

- Root Mean Square Error (RMSE) [26] คือ ค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง เป็นการวัดค่าความแตกต่างระหว่างค่าจริงและค่าพยากรณ์ ซึ่งหากค่า RMSE มีค่าที่น้อย แสดงว่าการพยากรณ์นั้นใกล้เคียงกับค่าความเป็นจริง ซึ่งมีสมการตาม 2.7

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^n e_t^2} \quad (2.7)$$

โดยที่ $e_t = x_t - \hat{x}_t$ แทนค่าคลาดเคลื่อนจากการพยากรณ์ ณ เวลา t

N แทนจำนวนเทอมทั้งหมดของ e_t

x_t แทนข้อมูล ณ เวลา t

\hat{x}_t แทนค่าพยากรณ์ ณ เวลา t

พหุ ประถมศึกษา ชีวะ

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 Yu Wang และ Runyu Chen [27] ได้ทำการวิจัยสร้างแบบจำลองเพื่อทำการพยากรณ์ราคาเหรียญดิจิทัลสกุลต่าง ๆ ได้แก่ บิตคอยน์ (Bitcoin) เอธิเรียม (Ethereum) เทตเธอร์ (Tether) อีโอเอส (EOS) ริปเปอร์ (Ripple) และ เหรียญ โลท์คอยน์ (Litecoin) โดยนำข้อมูลอนุกรมเวลา ราคาสูงสุด ต่ำสุด ราคาเปิดตลาด ราคาปิดตลาด และปริมาณการซื้อขายในแต่ละวันจากตลาดซื้อขายออนไลน์ Binance และ Huobi ใช้ข้อมูลราคาในไตรมาสที่สามของปี 2018 ถึง ไตรมาสแรกของปี 2019 มาวิเคราะห์ โดยใช้เทคนิคในการพยากรณ์ราคาเหรียญดิจิทัล อันได้แก่ MLP CNN SVR regression (SVR) BPNN และ RBF จากนั้น นำตัววัดประสิทธิภาพแบบจำลอง ทั้ง MAE และ RMSE เพื่อเปรียบเทียบความแม่นยำในการพยากรณ์ราคาของเหรียญดิจิทัลดังกล่าว ซึ่ง จากการทดลองสร้างแบบจำลองเพื่อทำการพยากรณ์และทำการวัดค่าประสิทธิภาพความแม่นยำในการพยากรณ์ ทั้ง MAE และ RMSE กลับพบว่า แบบจำลองที่มีประสิทธิภาพโดยรวมดีที่สุดคือเทคนิค SVR

2.2.2 Muhammad Fahmi และคณะ [28] ได้ทำการศึกษาแบบจำลองต่าง ๆ ที่เป็นเทคนิคการถดถอย (Regression) อันได้แก่ Linear Regression (LR) Neural Network Regression (NNR) Bayesian Linear Regression (BLR) และ Boosted Decision Tree Regression (BDTR) เพื่อทำการพยากรณ์ราคาบิตคอยน์ โดยนำข้อมูลอนุกรมเวลารายวันมาวิเคราะห์ ได้แก่ ราคาเปิดตลาด ราคาสูงสุด ราคาต่ำสุด ราคาปิดตลาด ตั้งแต่วันที่ 19 สิงหาคม 2013 ถึง วันที่ 19 กรกฎาคม 2016 จากเว็บไซต์ www.coindesk.com มาทำการพยากรณ์ราคาบิตคอยน์ จากนั้นใช้เครื่องมือวัดประสิทธิภาพแต่ละเทคนิค โดยใช้ MAE RMSE RAE RSE เพื่อวัดค่าความผิดพลาดของเทคนิค และใช้ R-Squared เพื่อวัดค่าพยากรณ์และค่าความจริง ซึ่งจากการวัดประสิทธิภาพนั้น เทคนิค Linear Regression (LR) ให้ค่าความคลาดเคลื่อนต่ำที่สุด โดยการพยากรณ์ และวัดประสิทธิภาพด้วย MAE, RMSE, RAE และ RSE ในการพยากรณ์ตัวแปรราคาสูงสุด เท่ากับ 4.876637, 9.271067, 0.034447 และ 0.002660 ตัวแปรราคาต่ำสุดเท่ากับ 5.001090, 11.057373, 0.037486 และ 0.004408 ตัวแปรราคาเปิดตลาดเท่ากับ 5.933206, 11.64092, 0.043219 และ 0.004564 และค่าราคาปิดตลาดอยู่ที่ 4.095639, 8.474145, 0.029633 และ 0.002373 ตามลำดับ และในส่วนการวัดประสิทธิภาพ R-Squared นั้น ทุกเทคนิคมีค่าการพยากรณ์ที่ใกล้เคียงค่าความจริงเป็นอย่างมาก ซึ่งค่าที่มีความห่างจาก 1 มากที่สุดที่วัดประสิทธิภาพได้ คือ 0.989459 นอกเหนือจากนั้น มีค่า 0.99 ขึ้นไปทั้งสิ้น ดังนั้น เทคนิคที่อยู่บนพื้นฐาน Regression เหมาะแก่การนำมาสร้างแบบจำลองในการพยากรณ์ราคาบิตคอยน์

2.2.3 Dhruva Banjade [10] ได้ทำการพยากรณ์ราคาบิตคอยน์ โดยใช้ชุดข้อมูลราคาบิตคอยน์รายวันจาก www.coindesk.com/price/ ตั้งแต่ เดือน ธันวาคม 2014 ถึง เดือน สิงหาคม 2018 ซึ่งมีข้อมูลทั้งสิ้น 1230 ชุดข้อมูล และได้้นำเทคนิคโครงข่ายประสาทเทียม (ANN) มาสร้างแบบจำลองเพื่อทำการพยากรณ์ราคาบิตคอยน์ และใช้วิธี RMSE ในการวัดประสิทธิภาพของแบบจำลองที่ใช้ในการพยากรณ์ และ หาค่า R-Squared เพื่อดูค่าการพยากรณ์เปรียบเทียบกับค่าความจริง ซึ่งผู้วิจัยได้ตั้งค่าเทคนิคโครงข่ายประสาทเทียม (ANN) แบบฟังก์ชัน Sigmoid ปรับเทคนิคโดยให้ชั้นข้อมูลเข้าจำนวน 4 nodes และแบ่งชุดซ่อนออกเป็น 10 nodes และให้ระบบทำการประมวลผลจำนวน 200 ครั้ง ซึ่งการตั้งค่าดังกล่าวเป็นการตั้งค่าที่ให้ผลลัพธ์ในการพยากรณ์ที่ดีที่สุด โดยมีค่าจากการวัดประสิทธิภาพด้วย RMSE เท่ากับ 10.20 และ ค่า R-Squared เท่ากับ 0.96

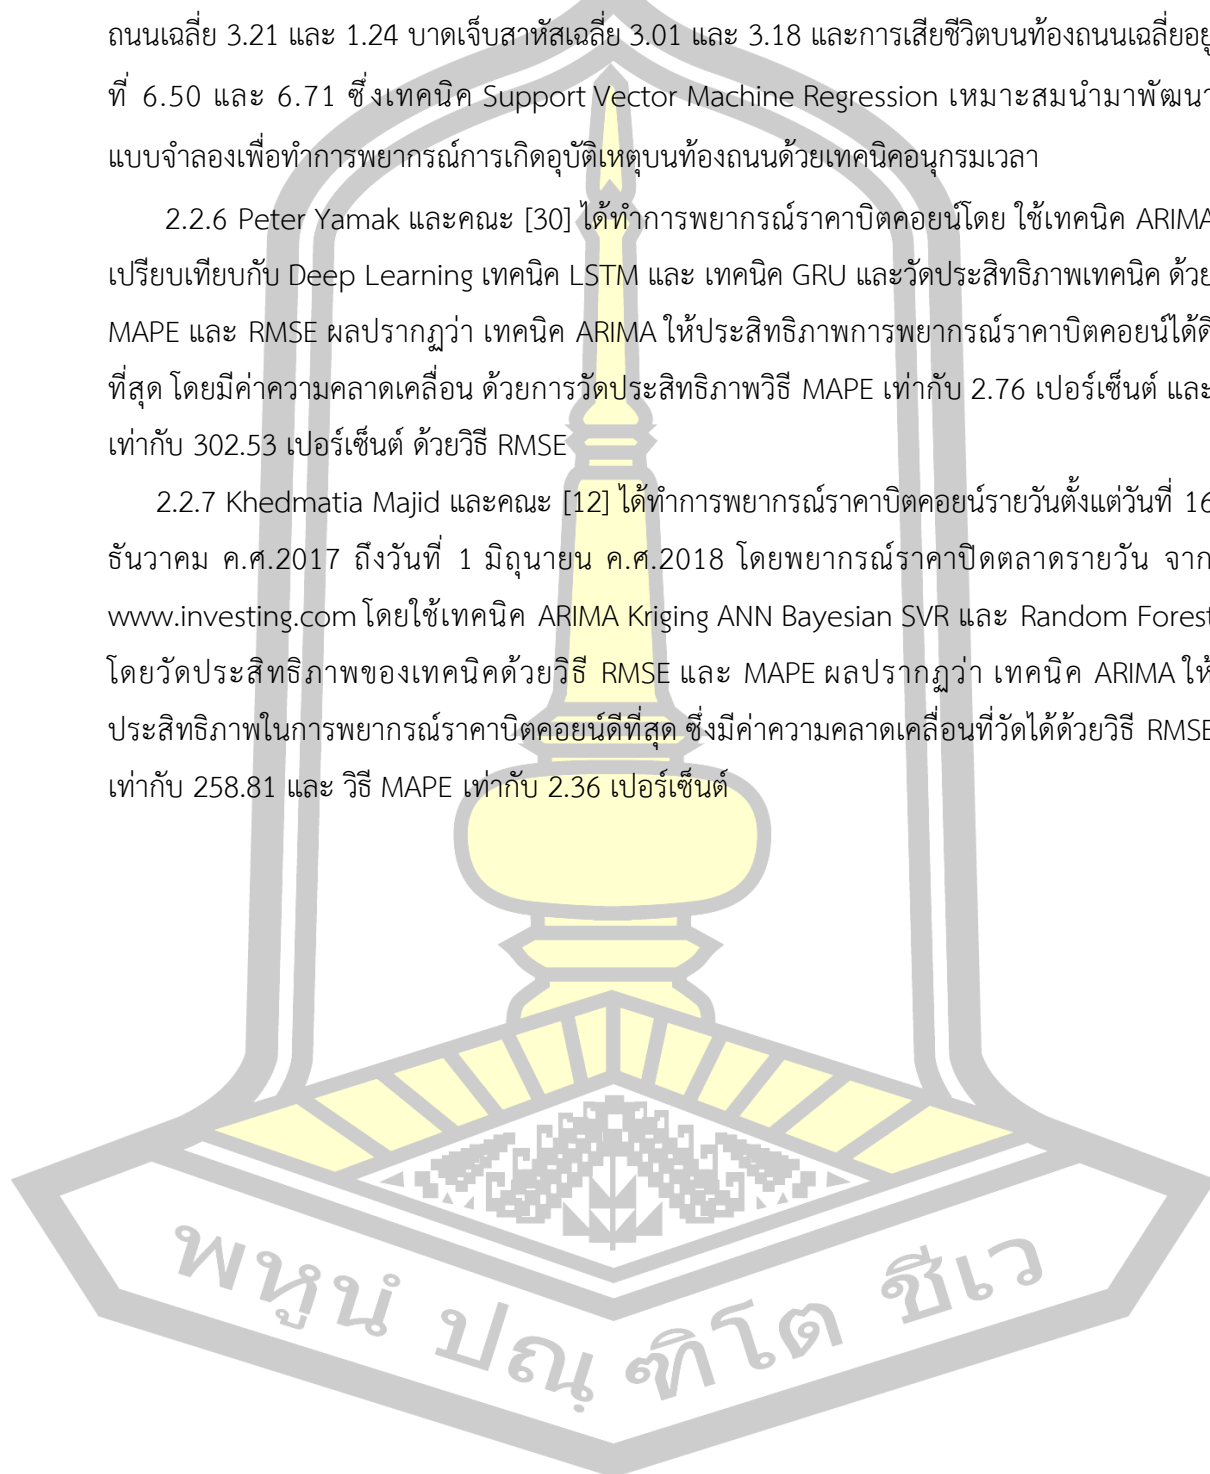
2.2.4 สมพร เหล็กกล้า และ จาริ ทองคำ [11] ศึกษาเทคนิคและสร้างแบบจำลองเพื่อทำการพยากรณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศ โดยนำข้อมูลขาขึ้นจากเว็บไซต์ www.exness.com ซึ่งเป็นเว็บไซต์ที่ทำการซื้อขายค่าเงินออนไลน์ จำนวน 5 สกุลเงิน อันได้แก่ EURUSD, USDJPY, USDCHF, NZDUSD และ GBPUSD ตั้งแต่เดือนกุมภาพันธ์ 2014 ถึงเดือนมกราคม 2017 ซึ่งเป็นข้อมูลอนุกรมเวลา และได้นำเทคนิคดังต่อไปนี้มาทำการพยากรณ์ ได้แก่ Linear Regression, Multi-Layer Perceptron, Support Vector Machine Regression และ เทคนิค Sequential Minimal Optimization Regression ในการทดลองผู้วิจัยนี้ได้ใช้ sliding windows และได้วัดประสิทธิภาพแบบจำลองในการพยากรณ์ด้วยเทคนิคดังกล่าว ได้แก่ MAE และ RMSE ซึ่งเทคนิค Sequential Minimal Optimization Regression มีค่าเฉลี่ยต่ำสุดเมื่อทำการวัดประสิทธิภาพด้วย MAE ซึ่งเท่ากับ 0.499 และมีค่าความผิดพลาดในการคำนวณน้อยที่สุดในทางตรงกันข้าม เทคนิค Support Vector Machine Regression นั้นกลับมีประสิทธิภาพในการพยากรณ์มากที่สุดจากทุกเทคนิค ซึ่งการวัดประสิทธิภาพในส่วนของ RMSE ก็ให้ผลลัพธ์ที่ได้ไม่ต่างกัน

2.2.5 ปัทมญา บุญรักษา และ จาริ ทองคำ [29] ได้ศึกษาและเปรียบเทียบแบบจำลองเพื่อวัดประสิทธิภาพของแบบจำลองที่ใช้ในการพยากรณ์จำนวนผู้ประสบอุบัติเหตุทางถนน ตั้งแต่เดือนมกราคม 2010 ถึง เดือนธันวาคม 2016 ในพื้นที่จังหวัดขอนแก่น โดยนำเทคนิคจำนวน 5 เทคนิค ได้แก่ Linear Regression, Artificial Neural Network, Sequential Minimal Optimization Regression, Support Vector Machine Regression และเทคนิค Gaussian Process ในการทดลองผู้วิจัยนี้ได้ใช้ sliding windows และมาทำการพยากรณ์โดยเปรียบเทียบค่าเฉลี่ยคลาดเคลื่อนสัมบูรณ์ MAE และค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง RMSE ซึ่งจากการพยากรณ์การเกิดอุบัติเหตุทางถนน

เทคนิคที่มีค่าความคลาดเคลื่อน ทั้ง MAE และ RMSE น้อยที่สุด เป็นเทคนิค Support Vector Machine Regression เป็นเทคนิคที่ดีที่สุดจากทั้ง 5 เทคนิค โดยมีค่าพยากรณ์การบาดเจ็บบนท้องถนนเฉลี่ย 3.21 และ 1.24 บาทเจ็บสาหัสเฉลี่ย 3.01 และ 3.18 และการเสียชีวิตบนท้องถนนเฉลี่ยอยู่ที่ 6.50 และ 6.71 ซึ่งเทคนิค Support Vector Machine Regression เหมาะสมนำมาพัฒนาแบบจำลองเพื่อทำการพยากรณ์การเกิดอุบัติเหตุบนท้องถนนด้วยเทคนิคอนุกรมเวลา

2.2.6 Peter Yamak และคณะ [30] ได้ทำการพยากรณ์ราคาบิตคอยน์โดยใช้เทคนิค ARIMA เปรียบเทียบกับ Deep Learning เทคนิค LSTM และ เทคนิค GRU และวัดประสิทธิภาพเทคนิค ด้วย MAPE และ RMSE ผลปรากฏว่า เทคนิค ARIMA ให้ประสิทธิภาพการพยากรณ์ราคาบิตคอยน์ได้ดีที่สุด โดยมีค่าความคลาดเคลื่อน ด้วยการวัดประสิทธิภาพวิธี MAPE เท่ากับ 2.76 เปอร์เซ็นต์ และ เท่ากับ 302.53 เปอร์เซ็นต์ ด้วยวิธี RMSE

2.2.7 Khedmatia Majid และคณะ [12] ได้ทำการพยากรณ์ราคาบิตคอยน์รายวันตั้งแต่วันที่ 16 ธันวาคม ค.ศ.2017 ถึงวันที่ 1 มิถุนายน ค.ศ.2018 โดยพยากรณ์ราคาบิตตลาดรายวัน จาก www.investing.com โดยใช้เทคนิค ARIMA Kriging ANN Bayesian SVR และ Random Forest โดยวัดประสิทธิภาพของเทคนิคด้วยวิธี RMSE และ MAPE ผลปรากฏว่า เทคนิค ARIMA ให้ประสิทธิภาพในการพยากรณ์ราคาบิตคอยน์ที่ดีที่สุด ซึ่งมีค่าความคลาดเคลื่อนที่วัดได้ด้วยวิธี RMSE เท่ากับ 258.81 และ วิธี MAPE เท่ากับ 2.36 เปอร์เซ็นต์



บทที่ 3

วิธีดำเนินการวิจัย

วิธีการวิจัยนี้ ดำเนินการขั้นตอนการทำเหมืองข้อมูลเพื่อนำมาใช้ในการพยากรณ์ราคาบิตคอยน์ โดยการใช้เทคนิคอนุกรมเวลาเข้ามาทำการวิเคราะห์ ซึ่งมีขั้นตอนการดำเนินการดังต่อไปนี้ การเตรียมข้อมูล การดำเนินการก่อนสร้างแบบจำลอง การสร้างแบบจำลอง และการวัดประสิทธิภาพของแบบจำลอง

3.1 การเตรียมข้อมูล


ข้อมูลที่ได้ในการวิจัย นำข้อมูลมาจาก <https://www.coinmarketcap.com> ซึ่งเว็บไซต์นี้เป็นเว็บไซต์ที่รวบรวมราคาเหรียญสกุลเงินดิจิทัลต่าง ๆ และราคาที่ได้เป็นการเฉลี่ยราคาจากกระดานซื้อขายสกุลเงินดิจิทัลที่มีอยู่ทั่วโลก และทำการตรวจสอบความถูกต้องของเวลา และข้อมูล ถ้าข้อมูลที่มีลักษณะผิดปกติจะทำการลบออก ตรวจสอบวันหยุด ถ้าไม่ถูกต้องจะมีการแก้ไขให้ถูกต้อง โดยข้อมูลที่ได้จะมี ราคาเปิดตลาด (open) ราคาสูงสุด (high) ราคาต่ำสุด (low) ราคาปิดตลาด (close) ปริมาณการซื้อขาย (volume) และ มูลค่าตลาดรวม (marketcap) โดยมีหน่วยเป็น USD สามารถแสดงตัวแปรได้ดังตารางที่ 3.1

ตารางที่ 3.1 ตัวแปรที่ใช้ในงานวิจัย

ตัวแปร	คำอธิบายตัวแปร	ชนิดตัวแปร
Period	วัน	Date
Open	ราคาเปิดตลาด	Numeric
High	ราคาสูงสุด	Numeric
Low	ราคาต่ำสุด	Numeric
Close	ราคาปิดตลาด	Numeric
Volume	ปริมาณการซื้อขาย	Numeric
Marketcap	มูลค่าตลาดรวม	Numeric

3.2 การวิเคราะห์ข้อมูล

การวิเคราะห์ข้อมูล ในงานวิจัยนี้ได้ใช้การวิเคราะห์ข้อมูลกราฟเชิงเส้น เพื่อทำการวิเคราะห์ว่าข้อมูลมีลักษณะเป็นการเกิดตามฤดูกาล ดังภาพประกอบที่ 3.1



ภาพประกอบที่ 3.1 ราคาของบิตคอยน์ตามตัวแปร

โดยปกติแล้วข้อมูลที่เป็นคุณค่า (Value) สัมพันธ์กับ ข้อมูลเวลา (Time stamp) ย่อมเป็นข้อมูลอนุกรมเวลา แต่ข้อมูลอนุกรมเวลาไม่สามารถมองด้วยตาได้ชัดเจนว่า มีแนวโน้ม (Trend) หรือมีวัฏจักร (Seasonal Variations) ปรากฏหรือไม่ เพราะเมื่อดูด้วยสายตา อาจไม่สามารถตอบได้ ดังนั้นจำเป็นต้องใช้เครื่องมือทางสถิติเข้ามาตรวจสอบเพื่อหาค่าเฉลี่ย (Mean) และค่าความแปรปรวน (Variance) ถ้าหากค่าทั้งสองไม่คงที่ (non-stationary) แสดงว่าข้อมูลอนุกรมเวลานั้น มี แนวโน้ม และมีวัฏจักรเข้ามาเกี่ยวข้อง โดยสามารถใช้เทคนิค Augmented Dickey-Fuller มาทำการหาค่า p-Value เพื่อทราบถึงค่าคงที่ของข้อมูล ซึ่งหาก ค่า p-Value มากกว่า 0.05 แสดงว่า ข้อมูลอนุกรมเวลานั้น มีแนวโน้มและวัฏจักรเข้ามาเกี่ยวข้อง [18]

จากข้อมูลราคาบิตคอยน์ ตามภาพประกอบที่ 3.1 เมื่อนำมาคำนวณด้วยเทคนิค Augmented Dickey-Fuller ด้วยภาษา Python กับตัวแปร ราคาเปิดตลาด (Open) ราคาสูงสุด (High) ราคาต่ำสุด (Low) ราคาปิดตลาด (Close) ปริมาณซื้อขายในแต่ละวัน (Volume) และ มูลค่าตลาดรวม

(Marketcap) กลับพบว่า มีค่า p-Values เท่ากับ 0.14, 0.13, 0.18, 0.14, 0.51 และ 0.16 ตามลำดับ ซึ่งมากกว่า 0.05 ดังนั้นแสดงว่า ข้อมูลอนุกรมเวลาราคาบิตคอยน์นี้ มีแนวโน้มและวัฏจักรเข้ามาเกี่ยวข้อง

โดยการตรวจสอบนั้น ใช้ code ภาษา Python โดยใช้ แพลตฟอร์ม Google Colab โดยตรวจสอบราคาสูงสุดเป็นตัวอย่าง ได้ดังต่อไปนี้

```
from pandas import read_csv
from matplotlib import pyplot as plt
from google.colab import files
uploaded = files.upload()
df = read_csv('b2017-2019.csv', header=0, index_col=0)
```

โดยที่ b2017-2019.csv เป็นข้อมูลอนุกรมเวลาที่จะทำการทดสอบ จากนั้น ใช้เทคนิค Augmented Dickey-Fuller เข้ามาทดสอบเพื่อหาค่า p-Value ดังต่อไปนี้

```
from statsmodels.tsa.stattools import adfuller
adf_res = adfuller(df['High'], autolag = 'AIC')
print('p-Values:' + str(adf_res[1]))
```

และเมื่อ run คำสั่งออกมา ค่า p-Value จะได้ 0.139 ซึ่งมากกว่า 0.05

3.3 การสร้างแบบจำลอง

การสร้างแบบจำลอง ในการวิจัยนี้ได้นำตัวแปรในตารางที่ 3.1 โดยการแยกข้อมูลออกเป็นชุดจำนวน 6 ชุด แต่ละชุดประกอบด้วยวันที่ และตัวแปร ตัวอย่างเช่น เมื่อต้องการพยากรณ์ราคาเปิดตลาด ก็จะทำให้นำข้อมูล วันที่ และราคาเปิดตลาดเข้าเป็นข้อมูลเข้า แล้วทำการสร้างแบบจำลองด้วยเทคนิค

3.3.1 เทคนิค ARIMA

เทคนิค ARIMA คือ Auto Regressive Integrated Moving Average คือเทคนิคที่นิยมใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา หลักการของเทคนิคนี้จะเป็นการลดค่าความแปรปรวนของข้อมูล แล้วจึงนำมาทำการพยากรณ์ เพื่อให้เกิดความคลาดเคลื่อน (Error) น้อยที่สุด โดยเทคนิคนี้ สามารถแยกออกเป็น 3 ส่วน ได้ดังต่อไปนี้

AR = Auto Regressive หรือแทนด้วยค่า p

I = Integrated หรือแทนด้วยค่า d

MA = Moving Average หรือแทนด้วยค่า q

ซึ่ง โมเดลของ ARIMA นั้น สามารถเขียนได้ด้วย ARIMA(p, d, q) จากงานวิจัยนี้ ได้นำตัวแปรทั้ง 6 ตัวแปร และ จำนวน 12 รอบของชุดข้อมูล มาทำการประมวลผลโดยใช้ภาษา Python โดยมีลำดับขั้นตอนดังต่อไปนี้

นำข้อมูลอนุกรมเวลาเข้ามา โดยใช้คำสั่ง

```
from pandas import read_csv
from matplotlib import pyplot as plt
from google.colab import files
uploaded = files.upload()
df = read_csv('round1.csv', header=0, index_col=0)
```

โดยที่ round1.csv คือชุดข้อมูลรอบที่ 1

ทดสอบลักษณะข้อมูลอนุกรมเวลา ว่ามีความเสถียรหรือไม่ ซึ่งการจะพยากรณ์อนุกรมเวลาโดยใช้เทคนิค ARIMA จะต้องกำจัดแนวโน้มและวัฏจักรออกจากข้อมูล โดยตรวจสอบโดยใช้เทคนิค Augmented Dickey-Fuller โดยที่ค่า p-Value จะต้องต่ำกว่า 0.05 ถึงจะถือว่าข้อมูลเหมาะแก่การนำไปใช้ในการพยากรณ์

```

from statsmodels.tsa.stattools import adfuller
adf_res = adfuller(df['High'], autolag = 'AIC')
print('p-Values:' + str(adf_res[1]))

```

จากนั้น หาค่า p, d และ q เพื่อ หาโมเดลที่ดีที่สุดของเทคนิค ARIMA

```

import warnings
warnings.filterwarnings('ignore')
p = d = q = range(0, 3)
pdq = list(itertools.product(p, d, q))

aic = [ ]

for param in pdq:
    try:
        model = ARIMA(df['High'].dropna(), order = param)
        results = model.fit()
        print('Order = {}'.format(param))
        print('AIC = {}'.format(results.aic))
        a = 'Order: '+str(param) + ' AIC: ' + str(results.aic)
        aic.append(a)
    except:
        continue

```

เมื่อได้โมเดล ARIMA จึงทำการพยากรณ์

```

#ARIMA model
model = ARIMA(df['High'], order = (2, 1, 2))
results = model.fit()
print(results.summary())

```

```

#Prediction
plt.figure = (15,4)
plt.plot(df['High_diff'], color = 'green', label = 'Actual diff')
plt.plot(results.predict(), color= 'orange', label = 'Predicted diff')
plt.legend()

```

จากนั้น ถึงวัดประสิทธิภาพของแบบจำลอง ด้วยวิธี MAE และ RMSE

```

from sklearn.metrics import mean_squared_error
from math import sqrt

rms = sqrt(mean_squared_error(df_pred['High'], df_pred['Predicted_High']))
print(mae)
print(rms)

```

จากนั้นนำค่า พยากรณ์ที่ได้นำไปเปรียบเทียบกับค่าจริง โดยใช้คำสั่ง

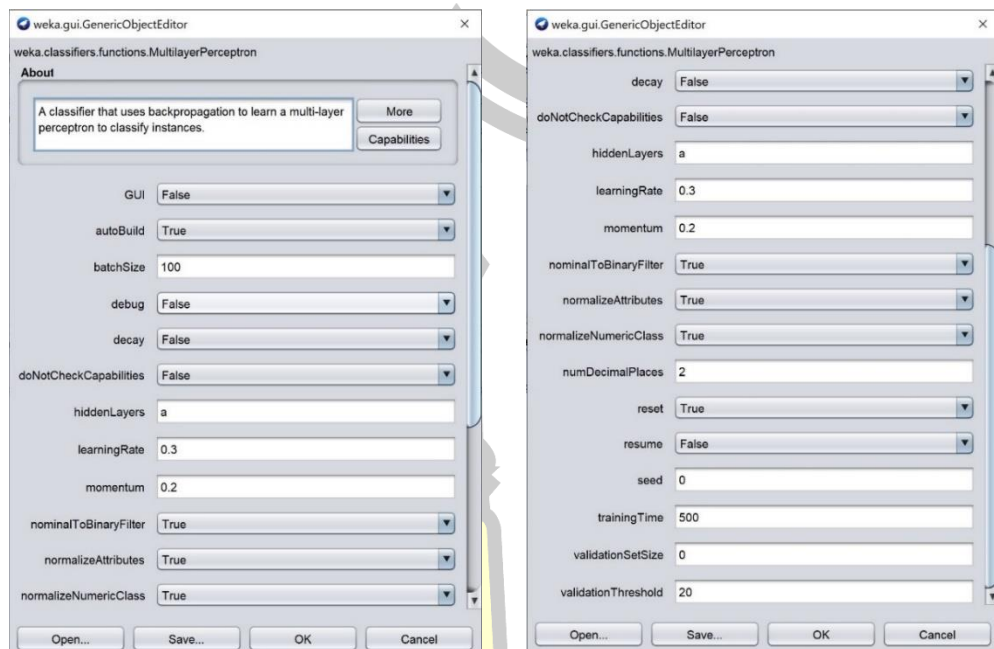
```

results.predict()

```



3.3.2 เทคนิคโครงข่ายประสาทเทียมหลายชั้น Multilayer Perceptron (MLP)



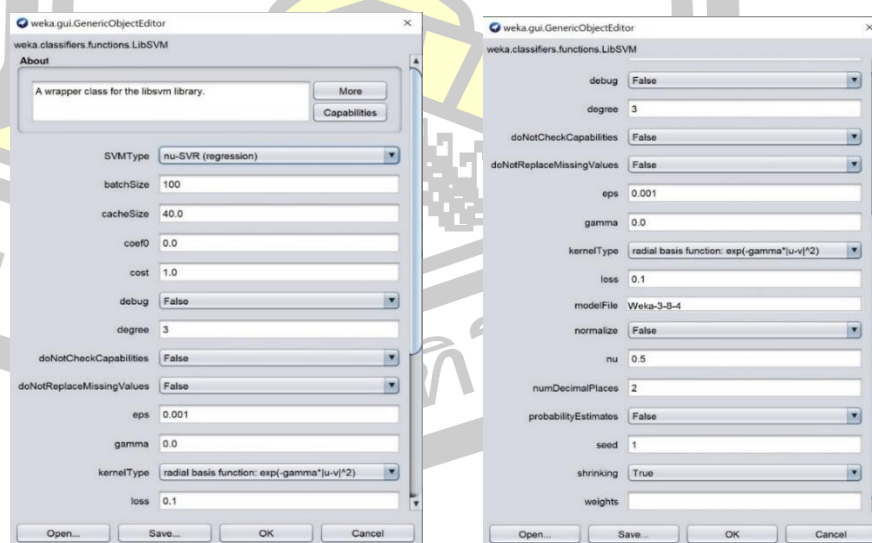
ภาพประกอบที่ 3.2 การตั้งค่าเทคนิค Multilayer Perceptron บนโปรแกรม WEKA

การตั้งค่า พารามิเตอร์ ของเทคนิค Multilayer Perceptron บนโปรแกรม WEKA ได้ตั้งค่า ดังต่อไปนี้

- GUI คือการตั้งค่าแสดงผลแบบ Graphic Unit Interface ตั้งค่าเป็น False
- autoBuild คือ การเพิ่มและเชื่อมต่อชั้นซ่อนของโหนดในระบบโครงสร้างเครือข่าย ตั้งค่าเป็น True
- batchSize คือจำนวนตัวเลขชุดการคำนวณในการพยากรณ์ที่ถูกปรับประสิทธิภาพ ตั้งค่าเป็น 100
- debug คือ ถ้าชุดข้อมูลเป็นจริง การจำแนกอาจมีผลลัพธ์เพิ่มเติมในหน้าผลลัพธ์ของชุดข้อมูล ตั้งค่าเป็น False
- decay คือ ผลต่อค่าการเรียนรู้ลดน้อยลง ตั้งค่าเป็น False
- donotcheckcapabilities คือ ถ้าชุดข้อมูลสามารถตั้งค่า ความสามารถในการจำแนกจะไม่ถูกตรวจสอบก่อนการจำแนกข้อมูลจะถูกสร้างขึ้น (ใช้อย่างระมัดระวังในการลดเวลาการประมวลผล) ตั้งค่าเป็น False

- hiddenLayers คือ การตั้งค่าจำนวนชั้นซ่อน ตั้งค่าเป็น a ให้ระบบตั้งค่าอัตโนมัติ
- learningRate คือ ค่าการเรียนรู้การปรับสมดุลของค่าน้ำหนัก ตั้งค่าเป็น 0.3
- momentum คือ การปรับค่าโมเมนตัม ในการปรับค่าน้ำหนัก ตั้งค่าเป็น 0.2
- nominalToBinaryFilter คือ การประมวลผลเพื่อทำการปรับเปลี่ยนตัวกรองข้อมูลจาก nominal เป็น binary ตั้งค่าเป็น True
- normalizeAttributes คือ ลดค่าความแปรปรวนของตัวแปร ตั้งค่าเป็น True
- normalizeNumericClass คือ ลดค่าความแปรปรวนของชุดข้อมูลที่เป็นตัวเลข ตั้งค่าเป็น True
- numDecimalPlace คือ จำนวนทศนิยมในการแสดงผลของโมเดลต่างๆ ตั้งค่าเป็น 2
- reset คือ ตั้งค่าเพื่ออนุญาตให้เครือข่ายทำการจัดค่าอัตราการเรียนรู้ใหม่ ตั้งค่าเป็น True
- resume คือ ตั้งค่าเมื่อการจำแนกนั้นสามารถสร้างแบบจำลองการเรียนรู้ของระบบต่อเนื่อง เมื่อมีการเรียกประสิทธิภาพแบบจำลองการเรียนรู้ซ้ำ ตั้งค่าเป็น False
- seed คือ ค่าเริ่มต้นในการสุ่มเรียกตัวเลขการประมวลผล ตั้งค่าเป็น 0
- trainingTime คือ ค่าวงรอบในการประมวลผลการเรียนรู้ ตั้งค่าเป็น 500
- validationSetSize คือ ขนาดเปอร์เซ็นต์ชุดข้อมูลการตรวจสอบความถูกต้อง ตั้งค่าเป็น 0
- validationThreshold คือ การยุติการตรวจสอบความถูกต้องของชุดข้อมูลทดสอบ ตั้งค่าเป็น 20

3.3.3 เทคนิค Support Vector Machine for Regression (SVR)



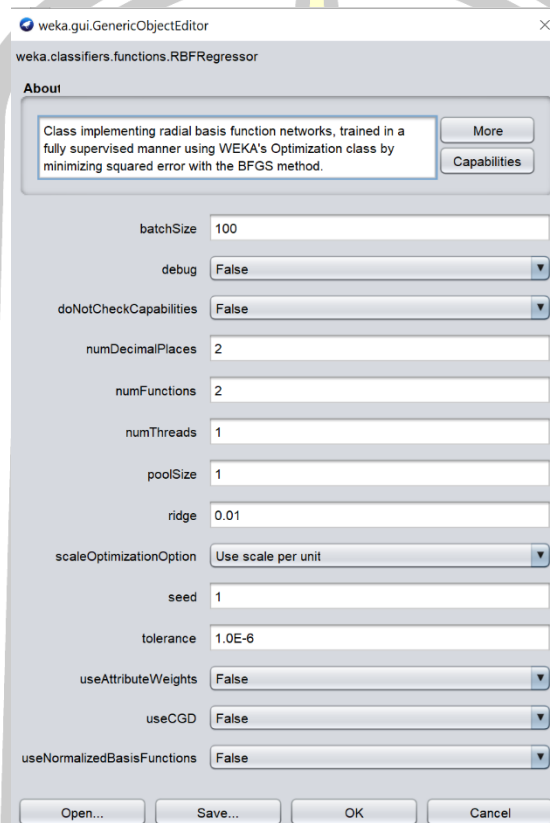
ภาพประกอบที่ 3.3 การตั้งค่าเทคนิค Support Vector Machine for Regression

การตั้งค่า พารามิเตอร์ ของเทคนิค Support Vector Machine for Regression บนโปรแกรม WEKA ได้ตั้งค่าดังต่อไปนี้

- SVRType คือ รูปแบบโมเดลของเทคนิค SVR ตั้งค่าเป็น nu-SVR สำหรับการถดถอย
- batchSize คือจำนวนตัวเลขชุดการคำนวณในการพยากรณ์ที่ถูกปรับประสิทธิภาพ ตั้งค่าเป็น 100
- cacheSize คือ ขนาดข้อมูลสำรองมีหน่วยเป็น Megabytes ตั้งค่าเป็น 40.0
- coef0 คือ ค่าสัมประสิทธิ์ ตั้งค่าเป็น 0.0
- cost คือ ค่าพารามิเตอร์โมเดลของ C-SVC, epsilon-SVR และ nu-SVR
- debug คือ ถ้าชุดข้อมูลเป็นจริง การจำแนกอาจมีผลลัพธ์เพิ่มเติมในหน้าผลลัพธ์ของชุดข้อมูล ตั้งค่าเป็น False
- degree คือ ค่าระดับของ Kernel ตั้งค่าเป็น 3
- donotcheckcapabilities คือ ถ้าชุดข้อมูลสามารถตั้งค่า ความสามารถในการจำแนกจะไม่ถูกตรวจสอบก่อนการจำแนกข้อมูลจะถูกสร้างขึ้น (ใช้อย่างระมัดระวังในการลดเวลาการประมวลผล) ตั้งค่าเป็น False
- donotReplaceMissingValues คือ การปิดคำสั่งอัตโนมัติในการแทนค่าตัวแปรที่หายไป ตั้งค่าเป็น False
- eps คือ เกณฑ์ค่าความต้านทาน ตั้งค่าเป็น 0.001
- gamma คือ ค่า gamma ที่ใช้มีค่าระหว่าง 0 ถึง 1 ตั้งค่าเป็น 0.0
- kernelType คือ รูปแบบ kernel ที่ใช้ ตั้งค่าเป็น $\exp(-\text{gamma} * |u-v|^2)$
- loss คือ รูปแบบค่าสูญเสียของ function epsilon-SVR ตั้งค่าเป็น 0.1
- modelFile คือ การบันทึกค่าภายในของเทคนิค libSVR ในรูปแบบแฟ้มข้อมูล ตั้งค่าเป็น Weka 3-8-4
- normalize คือ การลดค่าแปรปรวนของข้อมูล ตั้งค่าเป็น True
- nu คือ ค่าของ nu ในเทคนิค nu-SVC, one-Class SVR และ nu-SVR
- numDecimalPlace คือ จำนวนทศนิยมในการแสดงผลของโมเดลต่างๆ ตั้งค่าเป็น 2
- probabilitiesEstimates คือ ค่าความเป็นไปได้ในการประมาณการ แทนค่า -1/+1 ในการแก้ไขปัญหาของการจำแนกข้อมูล ตั้งค่าเป็น False
- seed คือ ค่าเริ่มต้นในการสุ่มเรียกตัวเลขการประมวลผล ตั้งค่าเป็น 1

- shrinking คือ การดำเนินการค้นพบหรือการเรียนรู้ด้วยตัวเอง ตั้งค่าเป็น True
- weights คือ ค่าถ่วงน้ำหนักที่ใช้ในการคำนวณ หากปล่อยว่าง ในค่า 1 เป็นค่าเริ่มต้น

3.3.4 เทคนิค Radial Basis Function (RBFRegressor)



ภาพประกอบที่ 3.4 การตั้งค่าเทคนิค Radial Basis Function บนโปรแกรม WEKA

การตั้งค่า พารามิเตอร์ ของเทคนิค Radial Basis Function (RBFRegressor) บนโปรแกรม WEKA ได้ตั้งค่าดังต่อไปนี้

- batchSize คือจำนวนตัวเลขชุดการคำนวณในการพยากรณ์ที่ถูกปรับประสิทธิภาพ ตั้งค่าเป็น 100
- debug คือ ถ้าชุดข้อมูลเป็นจริง การจำแนกอาจมีผลลัพธ์เพิ่มเติมในหน้าผลลัพธ์ของชุดข้อมูล ตั้งค่าเป็น False

- donotcheckcapabilities คือ ถ้าชุดข้อมูลสามารถตั้งค่า ความสามารถในการจำแนกจะไม่ถูกตรวจสอบก่อนการจำแนกข้อมูลจะถูกสร้างขึ้น (ใช้อย่างระมัดระวังในการลดเวลาการประมวลผล) ตั้งค่าเป็น False
- numFunctions จำนวน basis ที่ใช้ ตั้งค่า เป็น 2
- numThreads จำนวน threads ที่ใช้ ตั้งเป็น 1
- poolSize จำนวนแกนประมวลผลของคอมพิวเตอร์ที่ใช้ ตั้งเป็น 1

จากนั้น จะได้แบบจำลองและผลการพยากรณ์ราคาเปิดตลาดของแต่ละเทคนิค แล้วจึงนำไปคำนวณประสิทธิภาพต่อไป

ในการพยากรณ์ราคาสูงสุด โดยการนำข้อมูลวันที่ และข้อมูลราคาสูงสุด เป็นข้อมูลนำเข้าสู่เทคนิคข้างต้น จะถูกนำไปสร้างแบบจำลองและได้ผลการพยากรณ์ราคาสูงสุดของแต่ละวันแต่ละเทคนิค จากนั้นจึงนำไปคำนวณประสิทธิภาพต่อไป

ในการพยากรณ์ราคาต่ำสุด โดยการนำข้อมูลวันที่ และข้อมูลราคาต่ำสุด เป็นข้อมูลนำเข้าสู่เทคนิคข้างต้น จะถูกนำไปสร้างแบบจำลองและได้ผลการพยากรณ์ราคาต่ำสุดของแต่ละวันแต่ละเทคนิค จากนั้นจึงนำไปคำนวณประสิทธิภาพต่อไป

ในการพยากรณ์ราคาปิดตลาด โดยการนำข้อมูลวันที่ และข้อมูลราคาปิดตลาด เป็นข้อมูลนำเข้าสู่เทคนิคข้างต้น จะถูกนำไปสร้างแบบจำลองและได้ผลการพยากรณ์ราคาปิดตลาดของแต่ละวันแต่ละเทคนิค จากนั้นจึงนำไปคำนวณประสิทธิภาพต่อไป


ในการพยากรณ์ปริมาณการซื้อขาย โดยการนำข้อมูลวันที่ และข้อมูลปริมาณการซื้อขาย เป็นข้อมูลนำเข้าสู่เทคนิคข้างต้น จะถูกนำไปสร้างแบบจำลองและได้ผลการพยากรณ์ปริมาณการซื้อขายของแต่ละวันแต่ละเทคนิค จากนั้นจึงนำไปคำนวณประสิทธิภาพต่อไป

ในการพยากรณ์มูลค่าตลาดรวม โดยการนำข้อมูลวันที่ และข้อมูลมูลค่าตลาดรวม เป็นข้อมูลนำเข้าสู่เทคนิคข้างต้น จะถูกนำไปสร้างแบบจำลองและได้ผลการพยากรณ์มูลค่าตลาดรวมของแต่ละวันแต่ละเทคนิค จากนั้นจึงนำไปคำนวณประสิทธิภาพต่อไป

3.4 การวัดประสิทธิภาพของแบบจำลอง

งานวิจัยนี้ได้นำหลักการวัดประสิทธิภาพแบบจำลองโดยใช้วิธี Sliding Window โดยการนำข้อมูลแต่ละชุดจากขั้นตอนที่ 3.3 ทำการแบ่งชุดข้อมูลแต่ละชุด โดยข้อมูลเริ่มจากเดือน มกราคม

ค.ศ.2017 ถึง ธันวาคม ค.ศ.2019 และได้แบ่งข้อมูลชุดแรก โดยชุดที่ทำการฝึกสอนคือ มกราคม ค.ศ. 2017 ถึง ธันวาคม ค.ศ.2018 และใช้ห้วงระยะเวลา 1 เดือน เป็นชุดทดสอบ โยเริ่มเดือน มกราคม ค.ศ.2019 เป็นชุดทดสอบที่ 1 และเลื่อนไปครั้งละ 1 เดือน จนถึงเดือน ธันวาคม ค.ศ.2019 เป็นระยะ 12 รอบเรียนรู้และทดสอบ ดังภาพประกอบที่ 3.2



ภาพประกอบที่ 3.5 การพยากรณ์ราคาบิตคอยน์ด้วยหลักการ Sliding Window

ในงานวิจัยนี้จะได้ทำการวัดประสิทธิภาพของแบบจำลองโดยใช้วิธี หาค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ Mean Absolute Error (MAE) และ วิธี หาค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง Root Mean Square Error (RMSE) เป็นการวัดค่าความแตกต่างระหว่างค่าพยากรณ์ของแบบจำลอง และค่าความเป็นจริง

บทที่ 4


ผลการศึกษา

ในการวิจัยครั้งนี้ ผู้วิจัยได้ทำการศึกษาข้อมูลแล้วใช้โปรแกรม WEKA เวอร์ชัน 3.8.4 ในการทำการทดลอง และวัดค่าประสิทธิภาพของแบบจำลองในการพยากรณ์ราคาบิตคอยน์ ด้วยเทคนิคอนุกรมเวลา 3 เทคนิค ได้แก่ เทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLR) เทคนิคจำแนกเชิงเส้นแบบถดถอย (SVR) และ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) โดยใช้หลักการ Sliding window ทำการแบ่งชุดข้อมูลออกเป็นชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ ออกเป็น 12 ชุดข้อมูล จากนั้นนำวิธี MAE และ RMSE นำมาเปรียบเทียบประสิทธิภาพและในส่วน ของเทคนิค ARIMA ผู้วิจัยได้ใช้ภาษา Python ในการทำการทดลองและวัดประสิทธิภาพด้วยวิธี MAE และ RMSE เช่นเดียวกับการทดลองในโปรแกรม WEKA โดยผู้วิจัยได้นำ Library pandas ทำการอ่าน file ข้อมูล จากนั้น ใช้ Library statsmodels เพื่อนำมาดำเนินการตรวจสอบความเป็น stationary ของชุดข้อมูลโดยใช้ ADF เพื่อหาค่า p-Values หากไม่ได้ค่าที่ต่ำกว่า 0.05 จะทำการ Integrated เพื่อหาค่า d แล้วทดสอบจนกว่าจะได้ค่าที่ต่ำกว่า 0.05 จากนั้น ดำเนินการหาค่า p และ q เพื่อสร้าง โมเดล ARIMA (p, d, q) โดยใช้ Akaike Information Criterion (AIC) ทำการหาโมเดล ที่ดีที่สุด จากนั้นจึงวัดประสิทธิภาพด้วยวิธี MAE และ RMSE ในลำดับถัดไป

4.1 ค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์

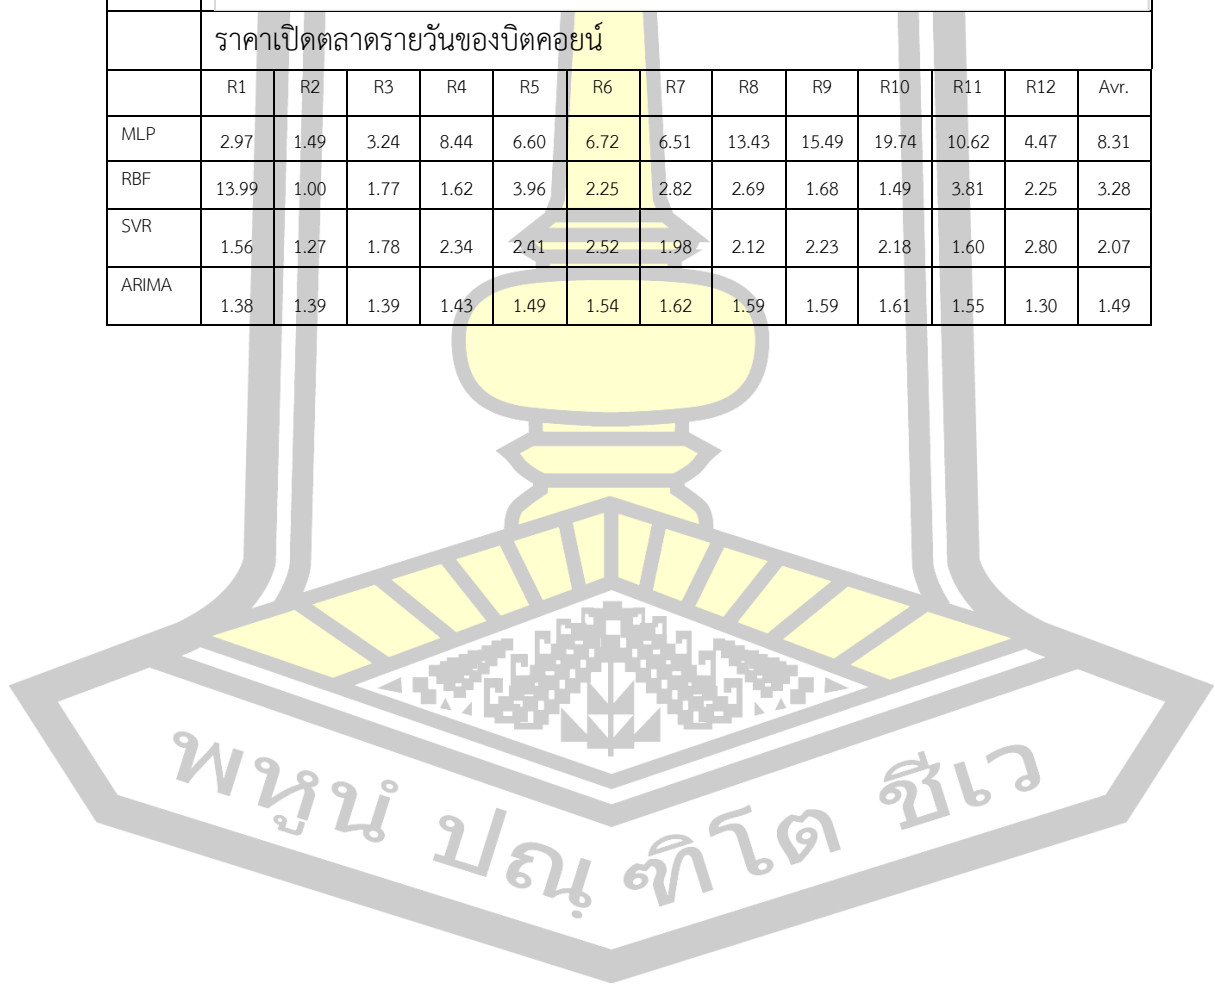
ค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAE) เป็นวิธีการหาค่าเฉลี่ยความแตกต่างระหว่างค่าพยากรณ์ และความความจริง หากค่าที่ได้ มีค่าน้อย แสดงว่าค่าพยากรณ์มีค่าใกล้เคียงค่าจริง และมี ประสิทธิภาพในการพยากรณ์ได้ดี ดังผลการทดลองดังต่อไปนี้

พหุ ประ โท ชี เว




ราคาเปิดตลาดรายวันของบิตคอยน์

	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
MLP	2.97	1.49	3.24	8.44	6.60	6.72	6.51	13.43	15.49	19.74	10.62	4.47	8.31
RBF	13.99	1.00	1.77	1.62	3.96	2.25	2.82	2.69	1.68	1.49	3.81	2.25	3.28
SVR	1.56	1.27	1.78	2.34	2.41	2.52	1.98	2.12	2.23	2.18	1.60	2.80	2.07
ARIMA	1.38	1.39	1.39	1.43	1.49	1.54	1.62	1.59	1.59	1.61	1.55	1.30	1.49



ภาพประกอบที่ 4.1 ค่าความคลาดเคลื่อน MAE ราคาเปิดตลาด เทคนิค MLP, RBF, SVR และ ARIMA


จากภาพที่ 4.1 แสดงค่า MAE ของแบบจำลองราคาเปิดตลาด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 1.49 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 2.07 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 3.28 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี MAE มีค่าความคลาดเคลื่อน ราคาเปิดตลาด เท่ากับ 8.31



MLP	2.45	4.59	4.24	6.32	3.13	9.92	5.12	10.52	6.19	7.18	5.33	10.00	6.25
RBF	1.02	4.95	1.95	3.98	4.17	2.30	3.21	2.97	1.88	1.53	4.02	1.94	2.83
SVR	1.36	1.24	1.85	2.26	2.41	2.61	2.13	2.08	1.88	1.51	1.58	2.48	1.95
ARIMA	1.42	1.43	1.43	1.48	1.54	1.60	1.69	1.66	1.66	1.68	1.62	1.35	1.55

ภาพประกอบที่ 4.2 ค่าความคลาดเคลื่อน MAE ราคาสูงสุด เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.2 แสดงค่า MAE ของแบบจำลองราคาสูงสุด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซีส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 1.55 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 1.95 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซีส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 2.83 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุดคือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ยโดยวัดประสิทธิภาพด้วยวิธี MAE มีค่าความคลาดเคลื่อน ราคาสูงสุด เท่ากับ 6.25




ราคาต่ำสุดรายวันของบิตคอยน์

R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
----	----	----	----	----	----	----	----	----	-----	-----	-----	------

MLP	1.10	1.55	3.34	15.61	12.12	12.14	2.85	5.49	12.41	7.28	3.74	6.61	7.02
RBF	0.98	4.86	1.39	3.55	3.79	2.18	2.22	6.95	7.31	1.71	3.84	2.53	3.44
SVR	1.89	1.25	1.73	2.28	2.33	2.41	1.97	2.09	2.25	2.06	1.51	2.22	2.00
ARIMA	1.31	1.32	1.32	1.36	1.42	1.47	1.53	1.50	1.51	1.53	1.47	1.25	1.42

ภาพประกอบที่ 4.3 ค่าความคลาดเคลื่อน MAE ราคาต่ำสุด เทคนิค MLP, RBF, SVR และ ARIMA


จากภาพที่ 4.3 แสดงค่า MAE ของแบบจำลองราคาต่ำสุด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซีส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 1.42 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 2.00 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซีส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 3.44 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุดคือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ยโดยวัดประสิทธิภาพด้วยวิธี MAE มีค่าความคลาดเคลื่อน ราคาต่ำสุด เท่ากับ 7.02



ราคาปิดตลาดรายวันของบิตคอยน์													
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
MLP	1.10	6.58	2.44	13.62	11.26	11.29	6.30	2.06	9.19	8.28	4.40	13.19	7.48
RBF	1.03	1.01	1.85	3.87	4.03	2.25	2.88	6.49	1.64	1.50	3.87	21.45	4.32
SVR	1.51	1.22	1.76	2.31	2.42	2.53	1.91	2.16	2.29	1.84	1.43	2.14	1.96
ARIMA	1.38	1.39	1.39	1.43	1.49	1.54	1.62	1.59	1.59	1.61	1.55	1.30	1.49

ภาพประกอบที่ 4.4 ค่าความคลาดเคลื่อน MAE ราคาปิดตลาดเทคนิค MLP, RBF, SVR และ ARIMA


จากภาพที่ 4.4 แสดงค่า MAE ของแบบจำลองราคาปิดตลาด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 1.49 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 1.96 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 4.32 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี MAE มีค่าความคลาดเคลื่อน ราคาปิดตลาด เท่ากับ 7.48



ปริมาณซื้อขายในแต่ละวันของบิตคอยน์													
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
MLP	0.57	0.48	0.96	0.53	0.71	1.30	1.04	1.70	1.55	1.90	4.08	7.35	1.85
RBF	0.53	0.35	0.17	0.19	1.60	0.68	0.59	2.11	0.97	1.73	0.82	2.23	1.00
SVR	0.34	0.30	0.26	0.37	0.63	0.82	1.04	1.09	1.18	0.74	0.56	0.87	0.69
ARIMA	0.17	0.18	0.19	0.21	0.24	0.26	0.30	0.31	0.32	0.34	0.35	0.34	0.27

ภาพประกอบที่ 4.5 ค่าความคลาดเคลื่อน MAE ปริมาณการซื้อขาย เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.5 แสดงค่า MAE ของแบบจำลองปริมาณซื้อขายในแต่ละวัน ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 0.27 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 0.69 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 1.00 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี MAE มีค่าความคลาดเคลื่อน ปริมาณซื้อขายในแต่ละวัน เท่ากับ 1.85



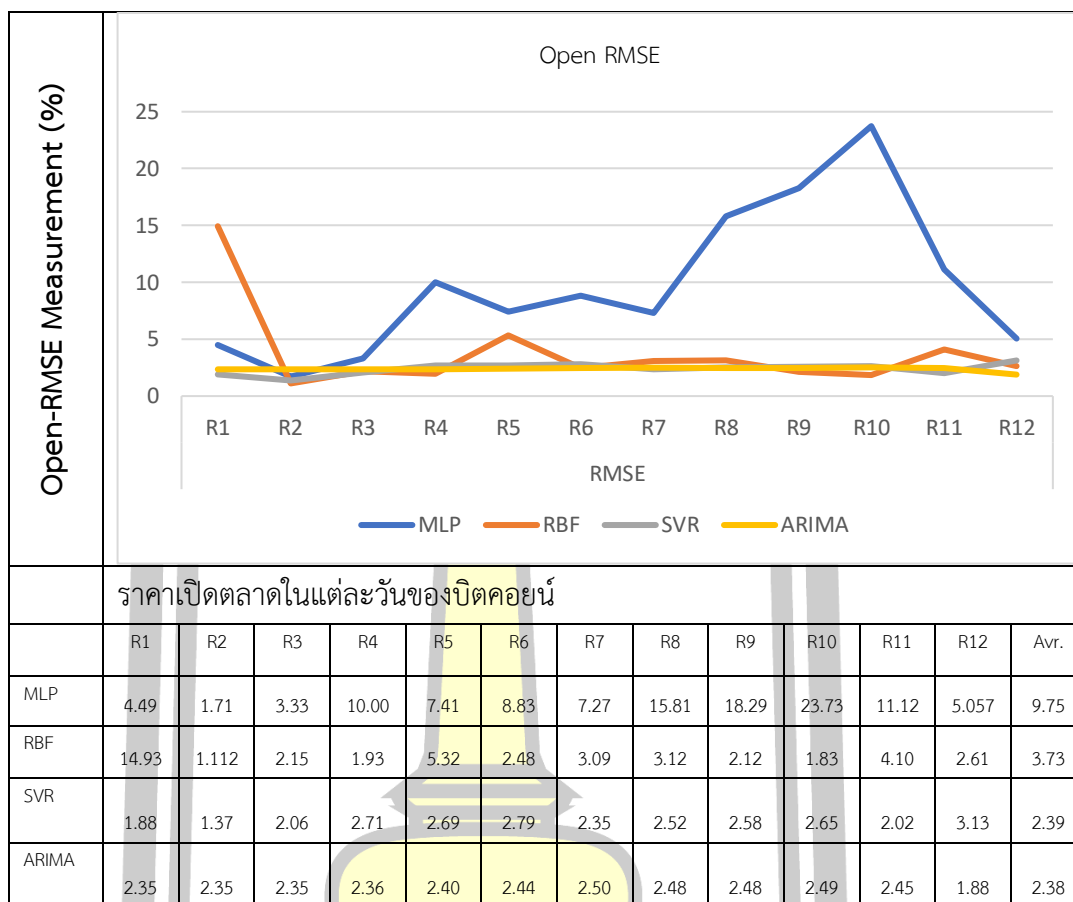
	มูลค่าตลาดรวมในแต่ละวันของบิตคอยน์												
	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
MLP	1.96	4.51	3.13	22.30	20.04	10.41	11.86	4.61	14.50	14.34	6.85	18.27	11.06
RBF	1.77	8.39	3.21	2.72	3.14	3.96	4.77	4.19	2.86	3.00	6.97	3.78	4.06
SVR	2.47	2.12	3.13	3.96	4.20	4.31	3.54	4.15	4.36	3.85	3.27	3.21	3.55
ARIMA	2.32	2.34	2.34	2.42	2.52	2.62	2.77	2.71	2.73	2.76	2.67	2.24	2.54

ภาพประกอบที่ 4.6 ค่าความคลาดเคลื่อน MAE มูลค่าตลาดรวม เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.6 แสดงค่า MAE ของแบบจำลองมูลค่าตลาดรวม ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 2.54 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 3.55 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 4.06 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี MAE มีค่าความคลาดเคลื่อน มูลค่าตลาดรวม เท่ากับ 11.06

4.2 ผลค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์

ผลค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (RMSE) เป็นวิธีการหาค่าเฉลี่ยความแตกต่างระหว่างค่าพยากรณ์และความจริง หากค่าที่ได้ มีค่าน้อย แสดงว่าค่าพยากรณ์มีค่าใกล้เคียงค่าจริง และมีประสิทธิภาพในการพยากรณ์ได้ดี ดังผลการทดลองดังต่อไปนี้




ราคาเปิดตลาดในแต่ละวันของบิตคอยน์

	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
MLP	4.49	1.71	3.33	10.00	7.41	8.83	7.27	15.81	18.29	23.73	11.12	5.057	9.75
RBF	14.93	1.112	2.15	1.93	5.32	2.48	3.09	3.12	2.12	1.83	4.10	2.61	3.73
SVR	1.88	1.37	2.06	2.71	2.69	2.79	2.35	2.52	2.58	2.65	2.02	3.13	2.39
ARIMA	2.35	2.35	2.35	2.36	2.40	2.44	2.50	2.48	2.48	2.49	2.45	1.88	2.38

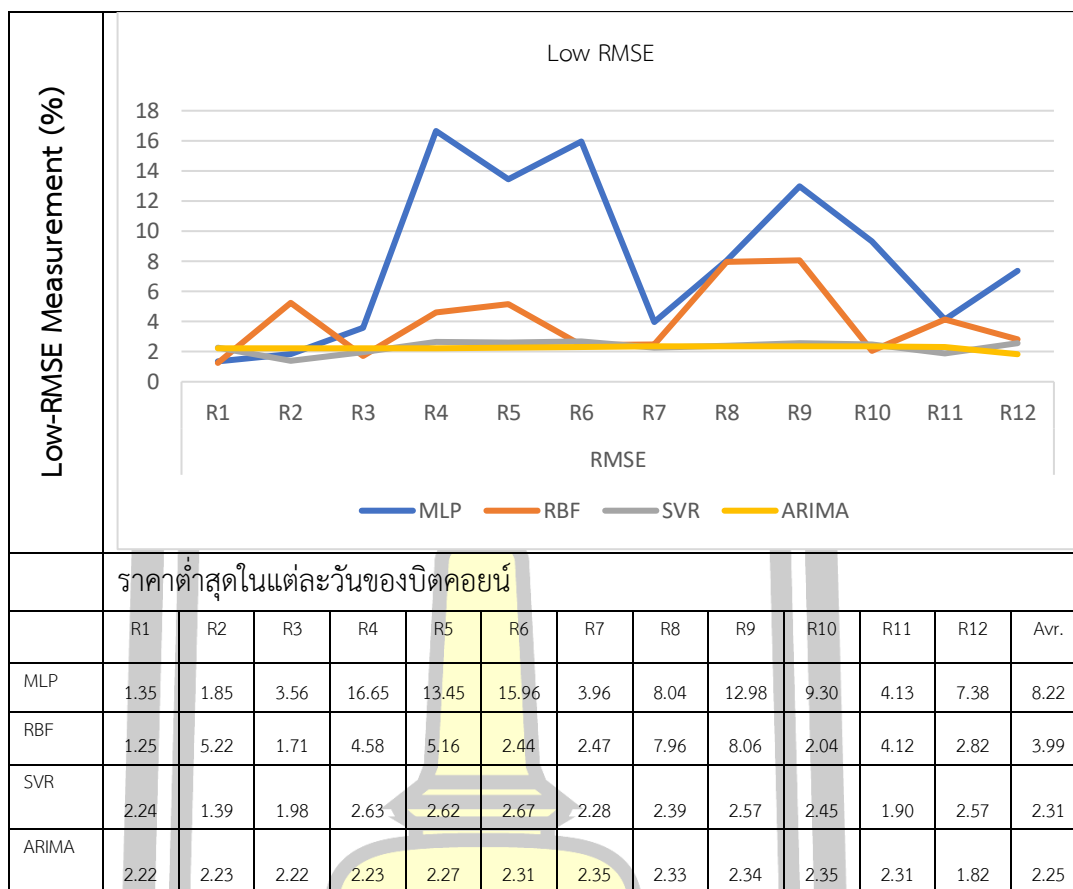
ภาพประกอบที่ 4.7 ค่าความคลาดเคลื่อน RMSE ราคาเปิดตลาด เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.7 แสดงค่า RMSE ของแบบจำลองราคาเปิดตลาด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 2.38 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 2.39 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 3.73 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี RMSE มีค่าความคลาดเคลื่อน ราคาเปิดตลาด เท่ากับ 9.75




ภาพประกอบที่ 4.8 ค่าความคลาดเคลื่อน RMSE ราคาสูงสุด เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.8 แสดงค่า RMSE ของแบบจำลองราคาสูงสุด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 2.27 ซึ่งมิต่ำน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 2.48 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 3.33 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี RMSE มีค่าความคลาดเคลื่อน ราคาสูงสุด เท่ากับ 7.63



ภาพประกอบที่ 4.9 ค่าความคลาดเคลื่อน RMSE ราคาต่ำสุด เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.9 แสดงค่า RMSE ของแบบจำลองราคาต่ำสุด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซีส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 2.25 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 2.31 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซีส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 3.99 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุดคือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ยโดยวัดประสิทธิภาพด้วยวิธี RMSE มีค่าความคลาดเคลื่อน ราคาต่ำสุด เท่ากับ 8.22




ราคาปิดตลาดในแต่ละวันของบิตคอยน์

	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	Avr.
MLP	1.26	8.24	4.22	22.36	17.48	15.65	11.39	3.43	9.74	8.60	4.28	14.98	10.14
RBF	1.41	1.13	2.23	5.36	5.81	2.47	3.81	7.72	2.52	1.93	4.20	22.48	5.09
SVR	1.92	1.21	1.82	2.44	2.31	2.23	2.46	2.65	2.69	2.36	1.93	2.73	2.23
ARIMA	2.35	2.35	2.35	2.36	2.40	2.44	2.50	2.48	2.49	2.49	2.45	1.88	2.38


ภาพประกอบที่ 4.10 ค่าความคลาดเคลื่อน RMSE ราคาปิดตลาด เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.10 แสดงค่า RMSE ของแบบจำลองราคาปิดตลาด ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 2.23 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 2.38 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 5.09 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี RMSE มีค่าความคลาดเคลื่อน ราคาปิดตลาด เท่ากับ 10.14



ภาพประกอบที่ 4.11 ค่าความคลาดเคลื่อน RMSE ปริมาณการซื้อขาย เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.11 แสดงค่า RMSE ของแบบจำลองปริมาณซื้อขายในแต่ละวัน ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 0.43 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 0.90 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 1.21 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี RMSE มีค่าความคลาดเคลื่อน ปริมาณซื้อขายในแต่ละวัน เท่ากับ 2.23




ภาพประกอบที่ 4.12 ค่าความคลาดเคลื่อน RMSE มูลค่าตลาดรวม เทคนิค MLP, RBF, SVR และ ARIMA

จากภาพที่ 4.12 แสดงค่า RMSE ของแบบจำลองมูลค่าตลาดรวม ที่สร้างจากเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) เทคนิคจำแนกเชิงเส้น (SVR) เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) และเทคนิค ARIMA จากการทดลองพบว่า เทคนิค ARIMA มีค่าความคลาดเคลื่อนเฉลี่ย 4.03 ซึ่งมีค่าน้อยและมีความเสถียรที่สุด รองลงมาคือ เทคนิคจำแนกเชิงเส้น (SVR) มีค่าความคลาดเคลื่อนเฉลี่ย 4.39 และรองลงมาคือ เทคนิคโครงข่ายประสาทเทียมแบบเรเดียลเบซิส (RBF) มีค่าความคลาดเคลื่อนเฉลี่ยเท่ากับ 5.18 ส่วนเทคนิคที่มีค่าความคลาดเคลื่อนเฉลี่ยมากที่สุด คือเทคนิคโครงข่ายประสาทเทียมแบบหลายสำหรับการถดถอย (MLP) มีค่าความคลาดเคลื่อนเฉลี่ย โดยวัดประสิทธิภาพด้วยวิธี RMSE มีค่าความคลาดเคลื่อน มูลค่าตลาดรวม เท่ากับ 15.89


4.3 ผลการเปรียบเทียบระหว่างค่าพยากรณ์และค่าจริง

จากผลการศึกษา เทคนิค ARIMA ให้ประสิทธิภาพการพยากรณ์จาก 4 เทคนิค ดีที่สุดและให้ค่าความคาดเคลื่อนต่ำที่สุด ซึ่งในการพยากรณ์ทั้ง 6 ตัวแปร ได้แก่ ราคาเปิดตลาด ราคาสูงสุด ราคาต่ำสุด ราคาปิดตลาด ปริมาณซื้อขายในแต่ละวัน และมูลค่าตลาดรวม ในรอบที่ 12 ของการพยากรณ์นั้น มีค่าความจริงเปรียบเทียบกับค่าพยากรณ์ เทคนิค ARIMA ให้ค่าพยากรณ์ใกล้เคียงกับค่าจริงมากที่สุด ต่อมาเป็นเทคนิค SVR ต่อมาเป็นเทคนิค RBF และสุดท้ายเทคนิคที่มีประสิทธิภาพต่ำสุดคือเทคนิค MLP




พหุ ประถมศึกษา


ภาพประกอบที่ 4.13 เปรียบเทียบค่าจริงและค่าพยากรณ์ ราคาเปิดตลาด




ภาพประกอบที่ 4.14 เปรียบเทียบค่าจริงและค่าพยากรณ์ ราคาสูงสุด




ภาพประกอบที่ 4.15 เปรียบเทียบค่าจริงและค่าพยากรณ์ ราคาต่ำสุด



ภาพประกอบที่ 4.16 เปรียบเทียบค่าจริงและค่าพยากรณ์ ราคาปิดตลาด



ภาพประกอบที่ 4.17 เปรียบเทียบค่าจริงและค่าพยากรณ์ ปริมาณซื้อขายในแต่ละวัน



ภาพประกอบที่ 4.18 เปรียบเทียบค่าจริงและค่าพยากรณ์ มูลค่าตลาดรวม



บทที่ 5

สรุปผล อภิปรายผล และข้อเสนอแนะ

งานวิจัยนี้ ผู้วิจัยได้ทำการนำข้อมูลราคาของบิตคอยน์รายวัน ราคาเปิดตลาด ราคาสูงสุด ราคาต่ำสุด ราคาปิดตลาด ปริมาณการซื้อขาย และมูลค่าตลาดรวม ตั้งแต่วันที่ 1 มกราคม ค.ศ.2017 ถึงวันที่ 31 ธันวาคม ค.ศ.2019 มาสร้างแบบจำลองเพื่อศึกษาประสิทธิภาพและวัดประสิทธิภาพของเทคนิคทั้ง 4 เทคนิค ได้แก่ เทคนิค ARIMA เทคนิค Multilayer Perceptron เทคนิค Support Vector Machine for regression และ เทคนิค Radial Basis Function ซึ่งสามารถนำมาอภิปรายผลได้ดังนี้

5.1 สรุปผล

5.1.1 จากการศึกษาประสิทธิภาพการสร้างแบบจำลองและวัดประสิทธิภาพด้วย MAE และ RMSE เทคนิคที่ให้ประสิทธิภาพสูงที่สุดจาก 4 เทคนิคคือ เทคนิค ARIMA โดยมีค่าความคลาดเคลื่อนที่วัดด้วย MAE ที่ราคาเปิดตลาด เท่ากับ 1.49 ราคาสูงสุดเท่ากับ 1.55 ราคาต่ำสุดเท่ากับ 1.42 ราคาปิดตลาดเท่ากับ 1.49 ปริมาณซื้อขายในแต่ละวันเท่ากับ 0.27 และมูลค่าตลาดรวมเท่ากับ 2.54 และวัดด้วย RMSE ที่ราคาเปิดตลาด เท่ากับ 2.38 ราคาสูงสุดเท่ากับ 2.48 ราคาต่ำสุดเท่ากับ 2.25 ราคาปิดตลาดเท่ากับ 2.38 ปริมาณซื้อขายในแต่ละวันเท่ากับ 0.43 และมูลค่าตลาดรวมเท่ากับ 4.03 รองลงมาคือ เทคนิค Support Vector Machine for regression (SVR) โดยมีค่าความคลาดเคลื่อนที่วัดด้วย MAE ที่ราคาเปิดตลาด เท่ากับ 2.07 ราคาสูงสุดเท่ากับ 1.95 ราคาต่ำสุดเท่ากับ 2.00 ราคาปิดตลาดเท่ากับ 1.96 ปริมาณซื้อขายในแต่ละวันเท่ากับ 0.69 และมูลค่าตลาดรวมเท่ากับ 3.55 และวัดด้วย RMSE ที่ราคาเปิดตลาด เท่ากับ 2.39 ราคาสูงสุดเท่ากับ 2.27 ราคาต่ำสุดเท่ากับ 2.31 ราคาปิดตลาดเท่ากับ 2.23 ปริมาณซื้อขายในแต่ละวันเท่ากับ 0.90 และมูลค่าตลาดรวมเท่ากับ 4.39 รองลงมาคือเทคนิค Radial Basis Function (RBF) โดยมีค่าความคลาดเคลื่อนที่วัดด้วย MAE ที่ราคาเปิดตลาด เท่ากับ 3.28 ราคาสูงสุดเท่ากับ 2.83 ราคาต่ำสุดเท่ากับ 3.44 ราคาปิดตลาดเท่ากับ 4.32 ปริมาณซื้อขายในแต่ละวันเท่ากับ 1.00 และมูลค่าตลาดรวมเท่ากับ 4.06 และวัดด้วย RMSE ที่ราคาเปิดตลาด เท่ากับ 3.73 ราคาสูงสุดเท่ากับ 3.33 ราคาต่ำสุดเท่ากับ 3.99 ราคาปิดตลาดเท่ากับ 5.09 ปริมาณซื้อขายในแต่ละวันเท่ากับ 1.21 และมูลค่าตลาดรวมเท่ากับ 5.18 และเทคนิคที่ให้ประสิทธิภาพต่ำที่สุดคือ Multilayer Perceptron (MLP) โดยมีค่าความคลาดเคลื่อนที่วัดด้วย MAE ที่ราคาเปิดตลาด เท่ากับ 8.31 ราคาสูงสุดเท่ากับ 6.25 ราคาต่ำสุดเท่ากับ 7.02 ราคาปิดตลาดเท่ากับ

7.48 ปริมาณซื้อขายในแต่ละวันเท่ากับ 1.85 และมูลค่าตลาดรวมเท่ากับ 11.06 และวัดด้วย RMSE ที่ราคาเปิดตลาด เท่ากับ 9.75 ราคาสูงสุดเท่ากับ 7.63 ราคาต่ำสุดเท่ากับ 8.22 ราคาปิดตลาดเท่ากับ 10.14 ปริมาณซื้อขายในแต่ละวันเท่ากับ 2.23 และมูลค่าตลาดรวมเท่ากับ 15.89

5.1.2 เปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 4 โดยวัดประสิทธิภาพด้วย MAE และ RMSE จากตัวแปรทั้ง 6 ตัวแปรนั้น ทำให้เห็นว่า เทคนิค ARIMA ให้ประสิทธิภาพในการพยากรณ์ราคาบิตคอยน์ได้ดีที่สุด และเมื่อนำค่าจริง (Actual) กับ ค่าพยากรณ์ (Predicted) มาเปรียบเทียบกัน เทคนิค ARIMA ยังคงให้ประสิทธิภาพในการพยากรณ์ได้ดีที่สุด คือ กราฟค่าพยากรณ์มีทิศทางสอดคล้องกับกราฟค่าจริงมากที่สุด แต่อย่างไรก็ตาม เทคนิคอื่น ๆ ที่นำมาเปรียบเทียบยังคงมีประสิทธิภาพในการพยากรณ์ราคาบิตคอยน์ได้ดี เช่นเดียวกัน คือ มีค่าความคลาดเคลื่อนในการวัดประสิทธิภาพแบบจำลอง ทั้งวิธี MAE และ RMSE มีค่าความคลาดเคลื่อน ไม่เกิน 20 เปอร์เซ็นต์ ทุกเทคนิค และทุกตัวแปรที่ใช้ในการสร้างแบบจำลองและทำการพยากรณ์

5.2 อภิปรายผล

เทคนิค ARIMA ที่ใช้ในการสร้างแบบจำลองในการทดลองนี้มีประสิทธิภาพดีที่สุดในการพยากรณ์ราคาบิตคอยน์รายวัน ทั้ง 6 ตัวแปร ห้วงระยะเวลาตั้งแต่วันที่ 1 มกราคม พ.ศ.2560 ถึง 31 ธันวาคม พ.ศ.2562 เนื่องจากเทคนิค ARIMA ใช้ในการพยากรณ์ข้อมูลที่เป็นอนุกรมเวลา และก่อนที่จะทำการพยากรณ์นั้น จำเป็นจะต้องลดค่าความแปรปรวนของชุดข้อมูลอนุกรมเวลา จนกว่าข้อมูลอนุกรมเวลานั้น ถูกขจัดความแปรปรวน แนวโน้ม และวัฏจักร ที่เป็นปกติวิสัยที่ข้อมูลอนุกรมเวลาส่วนมากมีอยู่ จากนั้น จึงหาโมเดลที่ดีที่สุดในการเริ่มสร้างแบบจำลองในการพยากรณ์ ซึ่งกระบวนการข้างต้น เป็นการลดข้อมูลรบกวน (Noise) ให้ได้มากที่สุดเพื่อให้ได้ค่าความคลาดเคลื่อนต่ำที่สุดนั่นเอง สอดคล้องกับ Peter Yamak และคณะ [30] ได้ทำการพยากรณ์ราคาบิตคอยน์โดยใช้เทคนิค ARIMA เปรียบเทียบกับ Deep Learning เทคนิค LSTM และ เทคนิค GRU และวัดประสิทธิภาพเทคนิค ด้วย MAPE และ RMSE ผลปรากฏว่า เทคนิค ARIMA ให้ประสิทธิภาพการพยากรณ์ราคาบิตคอยน์ได้ดีที่สุด โดยมีค่าความคลาดเคลื่อน ด้วยการวัดประสิทธิภาพวิธี MAPE เท่ากับ 2.76 เปอร์เซ็นต์ และเท่ากับ 302.53 เปอร์เซ็นต์ ด้วยวิธี RMSE และสอดคล้องกับ Khedmatia Majid และคณะ [12] ได้ทำการพยากรณ์ราคาบิตคอยน์รายวันตั้งแต่วันที่ 16 ธันวาคม ค.ศ.2017 ถึงวันที่ 1 มิถุนายน ค.ศ. 2018 โดยพยากรณ์ราคาปิดตลาดรายวัน จาก www.investing.com โดยใช้เทคนิค ARIMA Kriging ANN Bayesian SVR และ Random Forest โดยวัดประสิทธิภาพของเทคนิคด้วยวิธี RMSE และ


MAPE ผลปรากฏว่า เทคนิค ARIMA ให้ประสิทธิภาพในการพยากรณ์ราคาบิตคอยน์ที่ดีที่สุด ซึ่งมีค่าความคลาดเคลื่อนที่วัดได้ด้วยวิธี RMSE เท่ากับ 258.81 และ วิธี MAPE เท่ากับ 2.36 เปอร์เซนต์

5.3 ข้อเสนอแนะ

งานวิจัยนี้เป็นการสร้างแบบจำลองเพื่อวิเคราะห์ประสิทธิภาพของเทคนิคการเรียนรู้ของเครื่อง (machine learning) หากจะนำไปใช้ จำเป็นจะต้องสร้างเครื่องมือ (application) โดยใช้เทคนิคที่ได้มีการวิเคราะห์ดังกล่าวมาปรับใช้ เพื่อที่จะเป็นเครื่องมือในการตัดสินใจสำหรับผู้ลงทุน ซึ่งการวิจัยครั้งต่อไป



บรรณานุกรม

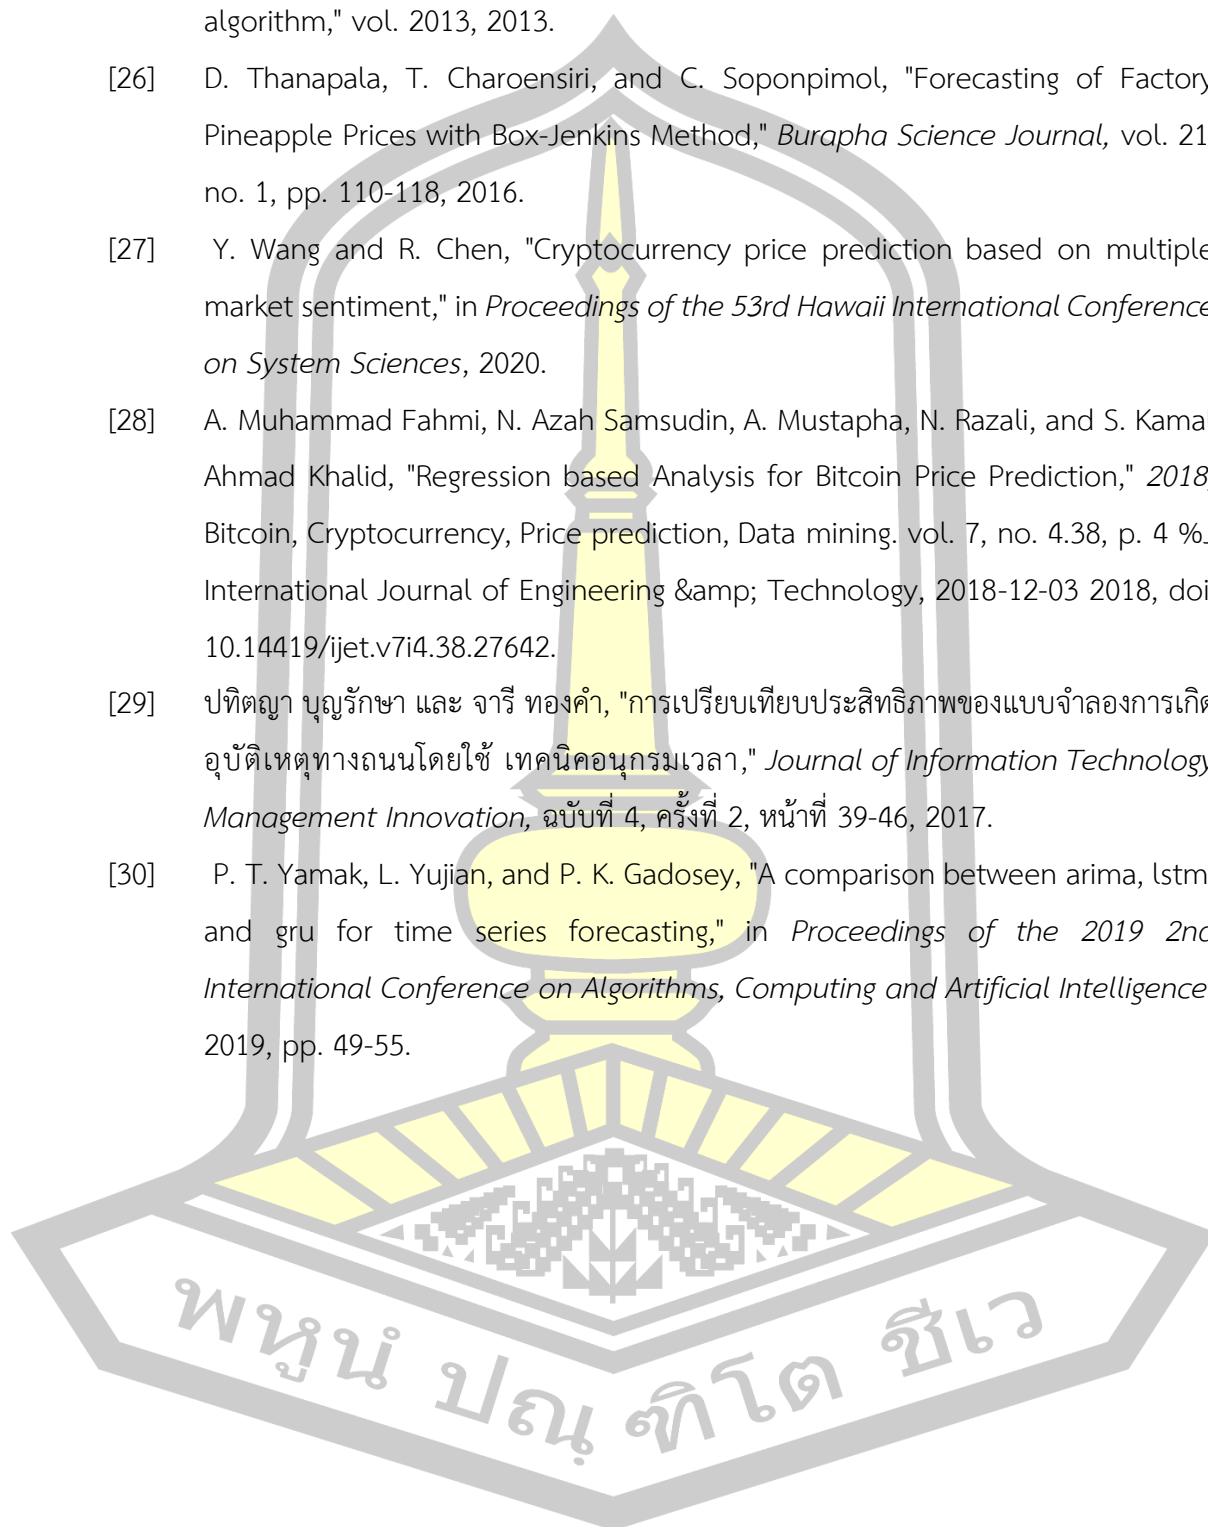


บรรณานุกรม

- [1] M. Crosby, P. Pattanayak, S. Verma, and V. Kalyanaraman, "Blockchain technology: Beyond bitcoin," *Applied Innovation*, vol. 2, no. 6-10, p. 71, 2016.
- [2] S. Nakamoto, "Bitcoin: A peer-to-peer electronic cash system.(2008)," ed, 2008.
- [3] coinmarketcap. "coinmarketcap." <https://coinmarketcap.com/> (accessed 31/12/2019, 2019).
- [4] Bitkub. "Bitkub." <https://coinmarketcap.com/> (accessed 31/12/2019, 2019).
- [5] M. Emem, "Chinese Bitcoin Trader Commits Suicide after Losing 2,000 BTC on 100x Leverage Bet," 2019. [Online]. Available: <https://www.ccn.com/bitcoin-margin-100x-leverage-trader-suicide/>.
- [6] Voice TV, "นศ.เกาหลีใต้ฆ่าตัวตายหลังขาดทุนจากเงินดิจิทัล," (in Thai), *Voice TV*, 2018. [Online]. Available: <https://voicetv.co.th/read/SJti1n-UM>.
- [7] N. Indera, I. Yassin, A. Zabidi, and Z. Rizman, "Non-linear autoregressive with exogeneous input (NARX) Bitcoin price prediction model using PSO-optimized parameters and moving average technical indicators," *Journal of Fundamental Applied Sciences*, vol. 9, no. 3S, pp. 791-808, 2017.
- [8] E. S. Team. "What is Machine Learning? A definition." <https://expertsystem.com/machine-learning-definition/> (accessed.
- [9] E. Karakoyun and A. Cibikdiken, "Comparison of arima time series model and lstm deep learning algorithm for bitcoin price forecasting," in *The 13th multidisciplinary academic conference in prague 2018 (the 13th mac 2018)*, 2018, pp. 171-180.
- [10] D. J. A. a. S. Banjade, "Forecasting Bitcoin Price using Artificial Neural Network," 2020.
- [11] S. Lekkla and J. Thongkam, "Forecasting the trend of foreign exchange rates using time series analysis techniques," Mahasarakham University, 2018.
- [12] M. Khedmatia, F. Seifi, and M. J. Azizi, "Time series forecasting of Bitcoin price based on ARIMA and machine learning approaches."

- [13] B. Securities. "Knowledge Sharing รู้ทัน!! สัญญาณทางเทคนิคบอกหุ้นขาขึ้น ขาลง." <https://knowledge.bualuang.co.th/knowledge-base/technicalbullbear/> (accessed).
- [14] B. Rockefeller, *Technical analysis for dummies*. John Wiley & Sons, 2019.
- [15] R. Thanomboon and S. Teekasab, "การ วิจัย เพื่อ พยากรณ์ อนาคต," *EAU Heritage Journal Science Technology*, vol. 9, no. 1, pp. 74-78, 2015.
- [16] ภูมิฐาน รังคกุลนุวัฒน์, การวิเคราะห์อนุกรมเวลาสำหรับเศรษฐศาสตร์และธุรกิจ. วี.พรีนท์ (1991) จำกัด (in Thai), 2013.
- [17] S. Muangkhousa, "Time Series Forecasting by using Box-Jenkins Method," *Vajira Medical Journal: Journal of Urban Medicine*, vol. 63, no. Supplement, pp. S185-S192, 2019.
- [18] S. Chaiyadecha. "ARIMA model in Python." <https://lengyi.medium.com/> (accessed 12/4, 2020).
- [19] อภิชาติ สุนทรวิภาต, "การประยุกต์ใช้โครงข่ายประสาทเทียมสำหรับการจัดการความต้องการวัตถุดิบชีวมวล : กรณีศึกษาโรงไฟฟ้าชีวมวลแห่งหนึ่ง," Master of Engineering Program in Engineering Management, Engineering and Industrial Technology, มหาวิทยาลัยศิลปากร, มหาวิทยาลัยศิลปากร, 2015.
- [20] A. Mohanty. "Multi layer Perceptron (MLP) Models on Real World Banking Data." <https://becominghuman.ai/multi-layer-perceptron-mlp-models-on-real-world-banking-data-f6dd3d7e998f> (accessed).
- [21] ปริญญา สงวนสัตย์, ปัญญาประดิษฐ์ด้วยการเรียนรู้ของเครื่องฉบับภาษา *python*: ปริญญา สงวนสัตย์, 2019.
- [22] วีระยุทธ พิมพาภรณ์, "การ พัฒนา แบบ จำลอง การ พยากรณ์ ความ สำเร็จ ทาง การ ศึกษา ของ ผู้ เรียน ระหว่าง การ ศึกษา ใน หลัก สูตร โดย เทคนิค วิธี เหมือน ข้อมูล," *Sripatum Review of Science Technology*, ฉบับที่ 10, ครั้งที่ 1, หน้า 07-17, 2018.
- [23] V. Sukmak, J. Thongkam, and J. Leejongpermpoon, "Time series forecasting in anxiety disorders of outpatient visits using data mining," *Asia-Pacific Journal of Science Technology*, vol. 20, no. 2, pp. 241-253, 2015.
- [24] A. H. El Shafie *et al.*, "Radial basis function neural networks for reliably forecasting rainfall," vol. 3, no. 2, pp. 125-138, 2012.

- [25] P. Kapoor and S. S. J. I. S. P. Bedi, "Weather forecasting using sliding window algorithm," vol. 2013, 2013.
- [26] D. Thanapala, T. Charoensiri, and C. Soponpimol, "Forecasting of Factory Pineapple Prices with Box-Jenkins Method," *Burapha Science Journal*, vol. 21, no. 1, pp. 110-118, 2016.
- [27] Y. Wang and R. Chen, "Cryptocurrency price prediction based on multiple market sentiment," in *Proceedings of the 53rd Hawaii International Conference on System Sciences*, 2020.
- [28] A. Muhammad Fahmi, N. Azah Samsudin, A. Mustapha, N. Razali, and S. Kamal Ahmad Khalid, "Regression based Analysis for Bitcoin Price Prediction," 2018, Bitcoin, Cryptocurrency, Price prediction, Data mining. vol. 7, no. 4.38, p. 4 %J International Journal of Engineering & Technology, 2018-12-03 2018, doi: 10.14419/ijet.v7i4.38.27642.
- [29] ปัทิตญา บุญรักษา และ จารีย์ ทองคำ, "การเปรียบเทียบประสิทธิภาพของแบบจำลองการเกิดอุบัติเหตุทางถนนโดยใช้ เทคนิคอนุกรมเวลา," *Journal of Information Technology Management Innovation*, ฉบับที่ 4, ครั้งที่ 2, หน้า 39-46, 2017.
- [30] P. T. Yamak, L. Yujian, and P. K. Gadosey, "A comparison between arima, lstm, and gru for time series forecasting," in *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence*, 2019, pp. 49-55.



ประวัติผู้เขียน

ชื่อ นิตกร จันทาญ
วันเกิด วันศุกร์ ที่ 4 มิถุนายน พ.ศ.2525
สถานที่เกิด ขอนแก่น
สถานที่อยู่ปัจจุบัน 359/15 หมู่ 7 หมู่บ้านอุดมทรัพย์ ตำบลท่าขอนยาง อำเภอกันทรวิชัย
จังหวัดมหาสารคาม
ประวัติการศึกษา พ.ศ.2549 รัฐประศาสนศาสตร์ (รป.บ.(ตร.))
โรงเรียนนายร้อยตำรวจ
พ.ศ.2564 ปริญญาวิทยาศาสตรมหาบัณฑิต (วท.ม.)
สาขาวิชาเทคโนโลยีสารสนเทศ คณะวิทยาการสารสนเทศ
มหาวิทยาลัยมหาสารคาม

พูน ปณ ทิโต ชีเว