


การศึกษาเชิงเปรียบเทียบสำหรับกระบวนการของการพยากรณ์ราคาคริปโตเคอร์เรนซี

วิทยานิพนธ์
ของ
ชนาภรณ์ ผาสุข

เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์
กรกฎาคม 2566

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

การศึกษาเชิงเปรียบเทียบสำหรับกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซี




เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์

กรกฎาคม 2566

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Comparative Study for Cryptocurrency Price Prediction Methods

Chanapon Phasook



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

July 2023

Copyright of Mahasarakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของนางสาวชนาภรณ์ ผาสุข
แล้วเห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาการคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ

(รศ. ดร. ศุภกานต์ พิมลธเรศ)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(รศ. ดร. จันทิมา พลพินิจ)

.....กรรมการ

(ผศ. ดร. พัฒนพงษ์ ชมภูวิเศษ)

.....กรรมการ

(ผศ. ดร. มนัสวี แก่นอำพรพันธ์)

มหาวิทยาลัยอนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญา วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

.....
(รศ. ดร. จันทิมา พลพินิจ)

คณบดีคณะวิทยาการสารสนเทศ

.....
(รศ. ดร. กริสน์ ชัยมูล)

คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	การศึกษาเชิงเปรียบเทียบสำหรับกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซี		
ผู้วิจัย	ชนาภรณ์ ผาสุข		
อาจารย์ที่ปรึกษา	รองศาสตราจารย์ ดร. จันทิมา พลพินิจ		
ปริญญา	วิทยาศาสตรมหาบัณฑิต	สาขาวิชา	วิทยาการคอมพิวเตอร์
มหาวิทยาลัย	มหาวิทยาลัยมหาสารคาม	ปีที่พิมพ์	2566

บทคัดย่อ

งานวิจัยฉบับนี้นำเสนอการศึกษาเชิงเปรียบเทียบกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซี โดยการศึกษาเชิงเปรียบเทียบนี้จะทำการเปรียบเทียบในสองส่วนคือ การเปรียบเทียบการทำนอร์มอลไลซ์ข้อมูลในขั้นตอนของการเตรียมข้อมูล และการเปรียบเทียบอัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี สำหรับการเปรียบเทียบการทำนอร์มอลไลซ์ข้อมูลในขั้นตอนของการเตรียมข้อมูลนั้นจะทำการเปรียบเทียบใน 3 วิธีการได้แก่ การปรับค่าข้อมูลด้วยลอการิทึม การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด และการปรับค่าข้อมูลแบบซี-สกอร์ ในขณะที่การเปรียบเทียบอัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซีจะทำการเปรียบเทียบระหว่างอัลกอริทึมการเรียนรู้ของเครื่อง (เช่น ซัพพอร์ตเวกเตอร์รีเกรสชัน) และอัลกอริทึมการเรียนรู้เชิงลึก (เช่น หน่วยความจำระยะสั้นระยะยาว) สำหรับชุดข้อมูลของบิตคอยน์ อีเธอร์เลียม และไลท์คอยน์ ที่ใช้ในการศึกษาในครั้งนี้ได้ทำการดาวน์โหลดมาจาก <http://cryptocompare.com>

คำสำคัญ : คริปโทเคอร์เรนซี, การพยากรณ์ราคา, การนอร์มอลไลซ์ข้อมูล, การเรียนรู้ของเครื่อง, การเรียนรู้เชิงลึก

พจนัน ปณฺ สกิต ชีเว

TITLE Comparative Study for Cryptocurrency Price Prediction Methods
AUTHOR Chanapon Phasook
ADVISORS Associate Professor Jantima Polpinij , Ph.D.
DEGREE Master of Science **MAJOR** Computer Science
UNIVERSITY Mahasarakham **YEAR** 2023
University

ABSTRACT

This research presents a comparative study of the process of cryptocurrency price prediction. The two components of this comparative study investigate data normalization during the data preparation stage and the algorithms used to develop a model for predicting the closed price cryptocurrency. In the data preparation stage, three techniques are evaluated for data normalization comparisons: log scaling, min-max scaling, and z-score scaling. Meanwhile, the algorithms used for modeling the closed price cryptocurrency are compared between machine learning (e.g. Support Vector Machines) and deep learning (e.g. Long Short-Term Memory) algorithms. The datasets of Bitcoin, Ethereum, and Litecoin used in this study was downloaded from <http://cryptocompare.com>.

Keyword : Cryptocurrency, Price Prediction, Data Normalization, Machine Learning, Deep Learning

พหุ ม ปณ จิต ชีเว

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จสมบูรณ์ได้ด้วยความกรุณาและความช่วยเหลืออย่างสูงยิ่งจากรองศาสตราจารย์ ดร. ศุภกานต์ พิมลธเรศ ประธานกรรมการควบคุมวิทยานิพนธ์ ผู้ช่วยศาสตราจารย์ ดร. มณีสวี แก่นอำพรพันธ์ และผู้ช่วยศาสตราจารย์ ดร. พัฒนพงษ์ ชมภูวิเศษ กรรมการควบคุมวิทยานิพนธ์ ที่ให้คำชี้แนะในการปรับปรุงกระบวนการวิจัยในวิทยานิพนธ์

ขอขอบพระคุณ รองศาสตราจารย์ ดร. จันทิมา พลพินิจ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำปรึกษาและควบคุมการดำเนินงานในวิทยานิพนธ์และเอกสารวิจัยเพื่อการตีพิมพ์จนสำเร็จแล้วเสร็จ

ขอขอบพระคุณ อาจารย์ ดร. บัญชา เหลือผล ที่ให้ความกรุณาในการสอนการเขียนโปรแกรมและให้คำแนะนำต่างๆ เกี่ยวกับการเขียนโปรแกรม

ชนาภรณ์ ผาสุข



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญรูป.....	ญ
บทที่ 1 บทนำ.....	1
1.1. หลักการและเหตุผล.....	1
1.2. วัตถุประสงค์ของการวิจัย.....	2
1.3. ความสำคัญของการวิจัย.....	2
1.4. ขอบเขตของการวิจัย.....	2
1.5. นิยามศัพท์เฉพาะ.....	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 คริปโทเคอร์เรนซี (Cryptocurrency).....	4
2.1.1 บิตคอยน์ (Bitcoin: BTC).....	4
2.1.2 อีเธอร์เลียม (Ethereum: ETH).....	5
2.1.3 ไลท์คอยน์ (Litecoin: LTC).....	7
2.2 กรอบการดำเนินงานทั่วไปของการพยากรณ์ราคาคริปโทเคอร์เรนซี (Generic Framework of Cryptocurrency Price Prediction).....	8
2.2.1 การเตรียมข้อมูล (Pre-processing).....	8
2.2.2 การสร้างโมเดลเพื่อการพยากรณ์ราคาคริปโทเคอร์เรนซี (Modeling of Cryptocurrency Price Prediction).....	10

2.2.3 การประเมิน (Evaluation).....	16
2.3 งานวิจัยที่เกี่ยวข้อง	18
บทที่ 3 วิธีดำเนินการวิจัย.....	25
3.1 ชุดข้อมูล.....	25
3.2 กรอบการดำเนินงาน.....	28
3.2.1 การเตรียมข้อมูล (Data Preparation).....	28
3.2.2 การแปลงข้อมูล (Data Transformation)	30
3.2.3 การสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโตเคอร์เรนซี (Developing of Predictative Models).....	30
3.3 การตั้งค่าอัลกอริทึมสำหรับการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโตเคอร์เรนซี.....	32
บทที่ 4 ผลการศึกษา.....	34
4.1 ตัวอย่างการคำนวณค่าของ RMSE, MAPE และ R-Square.....	34
4.2 ผลการทดลอง.....	35
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ.....	47
5.1 สรุปผล	47
5.2 อภิปรายผล.....	48
5.3 ข้อเสนอแนะ.....	49
บรรณานุกรม.....	50
ประวัติผู้เขียน.....	58

พูน ปณ ภัโต ชีเว

สารบัญตาราง

	หน้า
ตารางที่ 1 การเปรียบเทียบระหว่างบิตคอยน์กับไลท์คอยน์.....	8
ตารางที่ 2 รายละเอียดของข้อมูลที่ใช้ในการศึกษา.....	26
ตารางที่ 3 ตัวอย่างการปรับค่าข้อมูลด้วยลอการิทึม.....	29
ตารางที่ 4 ตัวอย่างการปรับค่าข้อมูลแบบต่ำสุด-สูงสุด.....	29
ตารางที่ 5 ตัวอย่างการปรับค่าข้อมูลแบบ Z-score.....	30
ตารางที่ 6 ตัวอย่างการคำนวณ RMSE.....	34
ตารางที่ 7 ตัวอย่างการคำนวณ MAPE.....	35
ตารางที่ 8 ตัวอย่างการคำนวณ R-Square.....	35
ตารางที่ 9 ผลการพยากรณ์ราคาบิตคอยน์แบบ 7-day prediction period.....	36
ตารางที่ 10 ผลการพยากรณ์ราคาอีเธอร์เลียมแบบ 7-day prediction period.....	36
ตารางที่ 11 ผลการพยากรณ์ราคาไลท์คอยน์แบบ 7-day prediction period.....	37
ตารางที่ 12 ผลการพยากรณ์ราคาบิตคอยน์แบบ 14-day prediction period.....	38
ตารางที่ 13 ผลการพยากรณ์ราคาอีเธอร์เลียมแบบ 14-day prediction period.....	39
ตารางที่ 14 ผลการพยากรณ์ราคาไลท์คอยน์แบบ 14-day prediction period.....	40
ตารางที่ 15 ผลการพยากรณ์ราคาบิตคอยน์แบบ 30-day prediction period.....	41
ตารางที่ 16 ผลการพยากรณ์ราคาอีเธอร์เลียมแบบ 30-day prediction period.....	41
ตารางที่ 17 ผลการพยากรณ์ราคาไลท์คอยน์แบบ 30-day prediction period.....	42

สารบัญรูป

หน้า

รูปที่ 1 มูลค่าตลาดของบิตคอยน์ ตั้งแต่กุมภาพันธ์ ค.ศ. 2013 ถึง 28 มิถุนายน ค.ศ. 2022	5
รูปที่ 2 มูลค่าตลาดของอีเธอร์เลียม ตั้งแต่สิงหาคม ค.ศ. 2031 ถึง 28 มิถุนายน ค.ศ. 2022.....	6
รูปที่ 3 มูลค่าตลาดของไลท์คอยน์ ตั้งแต่มกราคม ค.ศ. 2031 ถึง 28 มิถุนายน ค.ศ. 2022	7
รูปที่ 4 กรอบการดำเนินงานทั่วไปของการพยากรณ์ราคาคริปโตเคอร์เรนซี	8
รูปที่ 5 โครงสร้างของ SVR.....	11
รูปที่ 6 โครงสร้างของ ANNs.....	12
รูปที่ 7 ขั้นตอนการทำงานของ ANNs	12
รูปที่ 8 กระบวนการทำงานของ LSTM	14
รูปที่ 9 กระบวนการทำงานของ GRU.....	15
รูปที่ 10 ตัวอย่างข้อมูลบิตคอยน์.....	25
รูปที่ 11 ตัวอย่างข้อมูลอีเธอร์เลียม	27
รูปที่ 12 ตัวอย่างข้อมูลไลท์คอยน์	27
รูปที่ 13 กรอบการดำเนินงานในการศึกษา.....	28
รูปที่ 14 7-day prediction period.....	31
รูปที่ 15 14-day prediction period	31
รูปที่ 16 30-day prediction period	32
รูปที่ 17 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึมโดยใช้เทคนิคแบบ Log Scaling	45
รูปที่ 18 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึมโดยใช้เทคนิคแบบ Min-Max Scaling	45
รูปที่ 19 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึมโดยใช้เทคนิคแบบ Z-score Scaling	46

บทที่ 1

บทนำ

1.1. หลักการและเหตุผล

เงินตราเข้ารหัสลับ หรือ คริปโทเคอร์เรนซี (Cryptocurrency) [1] เป็นสกุลเงินที่ถูกเข้ารหัสเพื่อใช้ในการป้องกันและยืนยันธุรกรรมผ่านระบบบล็อกเชน (Blockchain) เป็นระบบการชำระเงินดิจิทัลที่ไม่พึ่งพาธนาคารในการยืนยันธุรกรรม เป็นระบบเพียร์ทูเพียร์ที่สามารถโอนและรับเงินได้ทุกที่ทุกเวลา ธุรกรรมจะถูกบันทึกในบัญชีแยกประเภทสาธารณะ [2] โดยใช้บล็อกเชนซึ่งเป็นบัญชีแยกประเภทแบบเปิดและกระจายที่บันทึกธุรกรรมในรหัส สำเนาธุรกรรมของ [3] บล็อกเชนจะได้รับการตรวจสอบเมื่อมีการเปลี่ยนแปลง เพื่อป้องกันการฉ้อโกง แต่ละธุรกรรมจะถูกตรวจสอบโดยนักขุด

ในปัจจุบันมีคริปโทเคอร์เรนซีมากกว่า 10,000 ประเภท และในปีค.ศ. 2020 มีผู้ใช้คริปโทเคอร์เรนซีมากกว่า 50 ล้านคน [4] โดยคริปโทเคอร์เรนซีที่ได้รับความนิยมที่สุดคือบิตคอยน์ (Bitcoin) ซึ่งเป็นเหรียญที่เก่าแก่และมีมูลค่ามากที่สุด ความสำเร็จของบิตคอยน์นำไปสู่การเพิ่มจำนวนขึ้นของคริปโทเคอร์เรนซีอย่างมากมาย พุ่งสูงขึ้นอย่างมากในปี ค.ศ. 2017 โดยที่มูลค่าตลาด (Market Cap) เพิ่มขึ้นจาก 2.1 หมื่นล้านดอลลาร์สหรัฐ เป็น 4.54 แสนล้านดอลลาร์สหรัฐ [5] แต่ที่รู้จักกันดีและเป็นที่ยอมรับได้แก่ บิตคอยน์แคช (Bitcoin Cash หรือ Altcoin) [6] อีเธอร์เลียม (Ethereum) [6] และ ลൈท์คอยน์ (Litecoin: LTC) [6] เป็นต้น

ถึงแม้ว่าคริปโทเคอร์เรนซีจะได้รับความนิยม แต่การลงทุนกับสินทรัพย์ดิจิทัลมีสิ่งที่ต้องระมัดระวัง โดยผู้ลงทุนจำเป็นต้องทำความเข้าใจอย่างมากในตลาดดิจิทัล โดยทั่วไปนักลงทุนจะอาศัย 3 ปัจจัยหลักในการพิจารณาการลงทุนในสินทรัพย์ดิจิทัล [7] ซึ่งปัจจัยแรกคือการวิเคราะห์ทางเทคนิคเพื่อใช้ในการดูแนวโน้มของคริปโทเคอร์เรนซี สำหรับปัจจัยที่สองคือการวิเคราะห์ปัจจัยพื้นฐาน [5] เพื่อพิจารณาสิ่งที่จะมีผลต่อราคาของคริปโทเคอร์เรนซี [8] และปัจจัยสุดท้ายคือการวิเคราะห์สภาพตลาดหรืออารมณ์ตลาด เพื่อตรวจสอบเชิงจิตวิทยาของผู้อื่นที่เข้ามาลงทุนว่าคนส่วนใหญ่มองคริปโทเคอร์เรนซีไปในทิศทางไหน [5] อย่างไรก็ตามการจะใช้แค่เพียงการคาดเดาว่า ตัวใดจะมีมูลค่ามากกว่าตัวอื่นนั้น ทำได้ยากมากเนื่องจากราคาของคริปโทเคอร์เรนซีมีความผันผวนและเปลี่ยนแปลงได้ตลอดเวลา

จากปัญหาข้างต้นส่งผลให้นักลงทุนหลายคนมองว่า หากสามารถคาดการณ์ราคาคริปโทเคอร์เรนซีได้ล่วงหน้า ก็จะสามารถใช้ประกอบการตัดสินใจ (Decision Making) เกี่ยวกับการลงทุนกับสินทรัพย์ดิจิทัลได้ ดังนั้นในช่วงทศวรรษที่ผ่านมาจึงมีการนำเสนองานวิจัยที่เกี่ยวกับการพยากรณ์ราคาคริปโทเคอร์เรนซีขึ้นมาจำนวนมาก [9-15] ซึ่งงานวิจัยที่ผ่านนั้นมักจะนำเสนอกระบวนการสำหรับการพยากรณ์ราคาคริปโทเคอร์เรนซีที่แตกต่างกัน ทั้งในเรื่องของการเตรียมข้อมูล (Data Pre-processing) ที่แตกต่าง ๆ กัน และอัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อการพยากรณ์ราคาคริปโทเคอร์เรนซี ซึ่งอัลกอริทึมที่ได้รับความนิยมจะอยู่ในสองกลุ่มใหญ่ ๆ คือ กลุ่มที่ใช้

อัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) และกลุ่มที่ใช้อัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning) ซึ่งผลลัพธ์ของการพยากรณ์ราคาคริปโทเคอร์เรนซีจากกระบวนการเหล่านี้ ก็ล้วนให้ผลลัพธ์ที่น่าพอใจ อย่างไรก็ตามมันก็ยากจะสรุปว่ากระบวนการสำหรับการพยากรณ์ราคาคริปโทเคอร์เรนซีใดที่ดีที่สุดต่อการประยุกต์ใช้กับข้อมูลคริปโทเคอร์เรนซีได้หลากหลาย เพราะงานวิจัยที่ผ่านมาจะศึกษากระบวนการของตัวกับชุดข้อมูลใดชุดข้อมูลหนึ่งเท่านั้น เช่น ชุดข้อมูลของบิตคอยน์ หรืออีเธอร์เลียม

ดังนั้นงานวิจัยฉบับนี้จึงนำเสนอเพื่อศึกษาเชิงเปรียบเทียบกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซีที่แตกต่างกัน

1.2 วัตถุประสงค์ของการวิจัย

เพื่อศึกษาเชิงเปรียบเทียบกระบวนการของการพยากรณ์ราคาปิด (Closed Price) ของคริปโทเคอร์เรนซีที่แตกต่างกันใน 2 รูปแบบคือ

- 1) กระบวนการบนพื้นฐานของการเรียนรู้ของเครื่อง (Machine Learning based Approach)
- 2) กระบวนการบนพื้นฐานของการเรียนรู้เชิงลึก (Deep Learning based Approach)

1.3 ความสำคัญของการวิจัย

ปัจจุบันราคาคริปโทเคอร์เรนซีได้รับความนิยมและการยอมรับมากขึ้น จนทำให้เกิดการลงทุนในเงินสกุลนี้เพิ่มมากขึ้น แน่นอนว่าความเปลี่ยนแปลงของกลไกด้านการตลาดหรือสถานการณ์ต่างๆ อาจจะทำให้ความผันผวนของค่าเงินเกิดนำเสนอกระบวนการเชิงเปรียบเทียบอัลกอริทึม เพื่อหาอัลกอริทึมที่เหมาะสมสำหรับการพยากรณ์ราคาคริปโทเคอร์เรนซี ดังนั้นนักลงทุนหลายคนมองว่าหากสามารถคาดการณ์ราคาราคาคริปโทเคอร์เรนซีได้ล่วงหน้า ก็จะสามารถใช้ประกอบการตัดสินใจ (Decision Making) เกี่ยวกับการลงทุนกับสินทรัพย์ดิจิทัลได้

1.4 ขอบเขตของการวิจัย

1.4.1 นำเสนอกระบวนการในการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี โดยมีกรณีศึกษาอย่างน้อย 3 สกุลเงินของคริปโทเคอร์เรนซี ได้แก่ บิตคอยน์ อีเธอร์เลียม และไลท์คอยน์

1.4.2 ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลการซื้อขายคริปโทเคอร์เรนซีในช่วงเวลา 1 วัน ระหว่างวันที่ 13 สิงหาคม ค.ศ. 2016 ถึง 3 มกราคม ค.ศ. 2022 โดยจะใช้ข้อมูลจากการศึกษาจากเว็บไซต์ <http://cryptocompare.com> หน่วยของสกุลในการศึกษาคือ ดอลลาร์สหรัฐ (USD)

1.4.3 เปรียบเทียบกระบวนการของการพยากรณ์ราคาปิด (Closed Price) ของคริปโทเคอร์เรนซีที่แตกต่างกันใน 2 ประเด็นหลัก คือ

1.4.3.1 เทคนิคการทำนอร์มอลไลเซชันของข้อมูลในขั้นตอนการเตรียมข้อมูล โดยจะทำการเปรียบเทียบใน 3 วิธี ได้แก่

- (1) การปรับค่าข้อมูลด้วยลอการิทึม (Log Scaling)
- (2) การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด (Min-Max Scaling)
- (3) การปรับค่าข้อมูลแบบซี-สกอร์ (Z-score Scaling)

1.4.3.2 อัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อการพยากรณ์ (Predictive Model) ราคาปิดของคริปโทเคอร์เรนซี

- (1) โมเดลเพื่อการพยากรณ์ที่สร้างจากอัลกอริทึมการเรียนรู้ของเครื่อง โดยจะศึกษาด้วยอัลกอริทึมการเรียนรู้ของเครื่องอย่างน้อย 1 อัลกอริทึม เช่น อัลกอริทึมซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR)
- (2) โมเดลเพื่อการพยากรณ์ที่สร้างจากอัลกอริทึมการเรียนรู้เชิงลึก โดยจะศึกษาด้วยอัลกอริทึมการเรียนรู้เชิงลึกอย่างน้อย 1 อัลกอริทึม เช่น หน่วยความจำระยะสั้นระยะยาว (Long Short-Term Memory: LSTM)

1.4.4 การประเมินกระบวนการในการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี จะประเมินด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error : RMSE), ข้อผิดพลาดสมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error : MAPE) และสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R-Square)

1.5 นิยามศัพท์เฉพาะ

1. การศึกษาเชิงเปรียบเทียบ (Comparative Study) หมายถึง การเปรียบเทียบกระบวนการที่ใช้ในการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี ที่จะมีการเปรียบเทียบใน 2 คือ กระบวนการบนพื้นฐานของการเรียนรู้ของเครื่อง (Machine Learning based Approach) และกระบวนการบนพื้นฐานของการเรียนรู้เชิงลึก (Deep Learning based Approach)

2. กระบวนการบนพื้นฐานของการเรียนรู้ของเครื่อง (Machine Learning based Approach) คือ กระบวนการที่ใช้อัลกอริทึมการเรียนรู้ของเครื่องในการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี

3. กระบวนการบนพื้นฐานของการเรียนรู้เชิงลึก (Deep Learning based Approach) คือ กระบวนการที่ใช้อัลกอริทึมการเรียนรู้เชิงลึกในการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี

4. การนอร์มอลไลเซชันข้อมูล (Data Normalization) หมายถึง การปรับช่วงขอบเขตของข้อมูล (Feature Scaling) สำหรับข้อมูลชนิดตัวเลขตัวเลขที่บ่งบอกปริมาณ (Cardinal Number) ของคุณลักษณะ (Feature) โดยให้ตัวเลขแต่ละตัวเหล่านั้นอยู่ในช่วงเดียวกัน เพื่อให้เหมาะสมกับการนำไปประมวลผลต่อไป

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้เป็นการกล่าวถึง การทบทวนวรรณกรรมงานวิจัย แนวคิด ที่เกี่ยวข้องกับศึกษาเชิงเปรียบเทียบการพยากรณ์ราคาสกุลเงินคริปโทเคอร์เรนซี และกรอบการดำเนินงานทั่วไป โดยมีรายละเอียดดังนี้

2.1 คริปโทเคอร์เรนซี (Cryptocurrency)

ในงานวิจัยนี้จะศึกษาคริปโทเคอร์เรนซี อย่างน้อย 3 สกุลเงินของคริปโทเคอร์เรนซี ได้แก่ บิตคอยน์ อีเธอร์เลียม และไลท์คอยน์

2.1.1 บิตคอยน์ (Bitcoin: BTC)

บิตคอยน์ (Bitcoin) [16] เป็นสกุลเงินดิจิทัลแบบกระจายอำนาจที่บันทึกธุรกรรมในบัญชีแยกประเภทที่เรียกว่าบล็อกเชน (Blockchain) เพื่อตรวจสอบธุรกรรมและสร้างความเชื่อถือในเครือข่าย และยังมีกาใช้เทคโนโลยีแบบเพียร์ทูเพียร์ (Peer-to-Peer) เพื่อดำเนินการโดยไม่มีอำนาจกลางหรือธนาคาร การจัดการธุรกรรมและใช้ในการออกแบบบิตคอยน์ โดยใช้เครือข่ายบล็อกเชนแบบโอเพ่นซอร์ส (Open-Source Blockchain) บิตคอยน์เป็นเงินสกุลดิจิทัลแรกที่ถูกพัฒนาขึ้นโดยนามแฝง Satoshi Nakamoto ในปีค.ศ. 2008 โดยมีเป้าหมายคือการสร้างระบบเงินสดอิเล็กทรอนิกส์ใหม่ที่มีการกระจายอำนาจอย่างสมบูรณ์โดยไม่มีเซิร์ฟเวอร์หรืออำนาจจากส่วนกลาง ในปีเดียวกัน Nakamoto ได้มีการตีพิมพ์เอกสารไวท์เปเปอร์ (Whitepaper) ที่มีชื่อว่า "Bitcoin: A Peer-to-Peer Electronic Cash System" [17, 18] โดยเนื้อหาของเอกสารจะเสนอระบบสำหรับการทำธุรกรรมทางอิเล็กทรอนิกส์โดยใช้ระบบการตรวจสอบแบบเพียร์ทูเพียร์ผ่านบล็อกเชน ซึ่งเป็นการอธิบายแนวคิดของบิตคอยน์และยังเป็นต้นแบบในการพัฒนาสกุลเงินดิจิทัลอื่น เช่น อีเธอร์เลียม (Ethereum) และ ไลท์คอยน์ (Litecoin)

บิตคอยน์มีการใช้ขายครั้งแรก [19, 20] เมื่อวันที่ 20 พฤษภาคม ค.ศ. 2010 ที่ร้านพิซซ่าของ Papa John's โดย Laszlo Hanyecz ใช้ 1,000 บิตคอยน์ ในการซื้อพิซซ่า 2 ถาด โดยมีมูลค่า 25 ดอลลาร์สหรัฐ ซึ่งในปีเดียวกันบิตคอยน์มีมูลค่าเพียงแค่ 40 ดอลลาร์สหรัฐ [21] ในปี ค.ศ. 2021 บิตคอยน์มีความผันผวนอย่างมากในช่วงครึ่งปีแรกบิตคอยน์มีมูลค่ามากกว่า 64,000 ดอลลาร์ และลดลงต่ำกว่า 30,000 ดอลลาร์สหรัฐ อย่างรวดเร็วในช่วงเดือนกรกฎาคม แต่ในเดือนพฤศจิกายนราคาบิตคอยน์มีมูลค่าสูงถึง 68,000 ดอลลาร์สหรัฐ แต่ถึงอย่างไรก็ตามในช่วงเดือนมกราคมในปี ค.ศ. 2022 ราคาบิตคอยน์ร่วงลงมาต่ำกว่า 35,000 ดอลลาร์สหรัฐ [22] นักลงทุนคาดว่าเนื่องจากอุปทานที่อยู่จำกัดของบิตคอยน์เป็นตัวแปรสำคัญในการผลักดันราคาของบิตคอยน์ให้พุ่งขึ้นสูงเป็นอันดับ 1 ของสกุลเงินดิจิทัล [4] ในปัจจุบันบิตคอยน์มีมูลค่าตลาดประมาณ 794.80 พันล้านดอลลาร์สหรัฐ ซึ่งหมายถึงว่าบิตคอยน์มีสภาพคล่องของตลาดมากและมีการเข้าถึงอย่างกว้างขวางในหมู่ของนักลงทุน แต่ถึงอย่างไรก็ตามบิตคอยน์ยังคงมีความผันผวนค่อนข้างสูง



รูปที่ 1 มูลค่าตลาดของบิตคอยน์ ตั้งแต่กุมภาพันธ์ ค.ศ. 2013 ถึง 28 มิถุนายน ค.ศ. 2022
ที่มา: [23]

สาเหตุที่บิตคอยน์มีมูลค่าสูงสุดในตลาดคริปโตเคอเรนซี สาเหตุหลักคือ [18] การผลิตบิตคอยน์ที่มีจำนวนจำกัดเพื่อทำบิตคอยน์เป็นสกุลเงินดิจิทัลที่หายากในอนาคตซึ่งมีเพียงแค่ 21 ล้านบิตคอยน์ ในปัจจุบันมีบิตคอยน์ที่ถูกขุดมากกว่า 18.99 ล้านบิตคอยน์ สำหรับการขุดบิตคอยน์เป็นวิธีการตรวจสอบการทำธุรกรรมและเป็นการรักษาความปลอดภัยของเครือข่ายโดยรวม

2.1.2 อีเธอร์เลียม (Ethereum: ETH)

อีเธอร์เลียม หรือ อีเธอร์ (Ether) [24] เป็นสกุลเงินเครือข่ายของอีเธอร์เลียม (Ethereum) เป็นหนึ่งในสกุลเงินดิจิทัล (Cryptocurrency) ที่ใช้เทคโนโลยีบล็อกเชนแบบโอเพ่นซอร์ส (Open-Source Blockchain) ที่มีการกระจายอำนาจ เช่นเดียวกับบิตคอยน์พร้อมฟังก์ชันสัญญาอัจฉริยะ (Smart contract) [25] ถูกพัฒนาขึ้นโดยโปรแกรมเมอร์ Vitalik Buterin ชาวรัสเซีย ซึ่งเคยเป็นนักเขียนและเป็นหนึ่งในผู้ร่วมก่อตั้งนิตยสาร Bitcoin ในปี ค.ศ. 2011 [26] ภายหลังได้มีการแยกตัวออกมาสร้างอีเธอร์เลียมในปี ค.ศ. 2013 [27] ซึ่งจุดประสงค์ในการพัฒนาอีเธอร์เลียมให้มีความสามารถใช้งานได้ไม่ต่างจากบิตคอยน์ แต่ปรับปรุงข้อบกพร่องต่าง ๆ และเพิ่มความสามารถของเหรียญให้หลากหลายขึ้นทำอะไรได้มากกว่าบิตคอยน์ ปัจจุบันอีเธอร์เลียมเป็นสกุลเงินที่สามารถนำไปประยุกต์ใช้ได้กับธุรกิจประเภทต่าง ๆ ไม่จำกัดแค่การใช้ในธุรกรรมทางการเงินเท่านั้น สิ่งที่อีเธอร์เลียมแตกต่างจากบิตคอยน์คือ อีเธอร์เลียมไม่ได้เป็นแค่สกุลเงินเพียงอย่างเดียวเท่านั้น บล็อกเชนแบบโอเพ่นซอร์สที่อนุญาตให้ผู้คนเข้ามาพัฒนาหรือเขียนข้อมูลต่าง ๆ ลงบนสกุลเงินได้ ทำให้เราสามารถสร้างแอปพลิเคชันต่าง ๆ ขึ้นมาบนเครือข่ายอีเธอร์เลียมได้อีกชั้นหนึ่ง จึงช่วยให้อีเธอร์เลียมมีรูปแบบการใช้งานที่หลากหลายต่างจากบิตคอยน์ [28] เพราะบิตคอยน์จะเน้นการทำธุรกรรมทางการเงินเพียงอย่างเดียว

อีเธอร์เลียมเปิดซื้อ-ขายครั้งแรกบนเว็บไซต์ Kraken เมื่อวันที่ 7 สิงหาคม ค.ศ. 2015 โดยกำหนดอัตราแลกเปลี่ยนแรกไว้ที่ 1 ETH เท่ากับ 2.77 ดอลลาร์สหรัฐ ในช่วงการซื้อ-ขายของสามวันแรกราคาของอีเธอร์เลียมลดลงอยู่ที่ 0.68 ดอลลาร์สหรัฐ ในช่วงครึ่งปีหลังอีเธอร์เลียมได้รับความนิยมเพิ่มอย่างต่อเนื่อง [28] เมื่อวันที่ 12 พฤษภาคม ค.ศ. 2021 ราคาอีเธอร์มีมูลค่าสูงที่สุดอยู่ที่ 4,356.99 ดอลลาร์สหรัฐ ซึ่งเพิ่มขึ้นจากปี ค.ศ. 2015 อยู่ที่ 745210.1% [29] ปัจจุบันอีเธอร์เลียมมีมูลค่าเป็นอันดับ 2 รองจากบิตคอยน์



รูปที่ 2 มูลค่าตลาดของอีเธอร์เลียม ตั้งแต่สิงหาคม ค.ศ. 2016 ถึง 28 มิถุนายน ค.ศ. 2022
ที่มา: [23]

สาเหตุหลักที่ส่งผลให้อีเธอร์เลียมได้รับความนิยม [27] ประเด็นแรกคืออีเธอร์เลียมอนุญาตให้ผู้ใช้งานเขียนโปรแกรมลงไปในข้อมูลของเหรียญได้ผ่านระบบ Smart Contract ซึ่งเป็นโปรแกรมที่ทำงานบนอีเธอร์เลียมบล็อกเชน (Ethereum Blockchain) จึงทำให้นักพัฒนาจำนวนมากหันมาสนใจอีเธอร์เลียม และนำระบบ Smart Contract ไปประยุกต์ใช้ในหลากหลายธุรกิจทั่วโลก ตัวอย่างของการนำระบบ Smart Contract ไปใช้งาน อย่างเช่น การชำระค่าบัตรเครดิต ธุรกิจเช่ารถ นอกจากนี้ Smart Contract ยังนำไปประยุกต์ใช้ได้อีกหลายรูปแบบ ไม่ว่าจะเป็นการซื้อขายสินค้าออนไลน์ การโอนเงินข้ามประเทศ การขอใบอนุญาตต่าง ๆ หรือแม้แต่การขอสินเชื่อจากสถาบันการเงิน

ประเด็นที่สองคือ การรวมตัวขององค์กรที่ติดอันดับ Fortune 500, ธุรกิจสตาร์ทอัพ, นักวิชาการและผู้เชี่ยวชาญด้านบล็อกเชนของอีเธอร์เลียม โดยเป็นการรวมตัวกันผ่านองค์กรที่เรียกว่า Enterprise Ethereum Alliance (EEA) ซึ่งเป็นองค์กรอุตสาหกรรมที่นำโดยสมาชิกในองค์กร เพื่อขับเคลื่อนการใช้เทคโนโลยีอีเธอร์เลียมบล็อกเชน เป็นมาตรฐานเปิดเพื่อเพิ่มความสามารถให้กับองค์กร รวมถึงการนำเสนอสถาปัตยกรรมและข้อกำหนดมาตรฐานที่เปิดกว้างเพื่อเร่งการยอมรับ EEA [27, 30] ปัจจุบันมีสมาชิกกว่า 116 บริษัท เช่น Microsoft, JP Morgan, Toyota และ

Intel ด้วยเหตุผลนี้ จึงทำให้อีเธอร์เลียมเป็นสกุลเงินที่นักลงทุนให้ความยอมรับ และมองว่ามีเสถียรภาพกว่าสกุลเงินดิจิทัลอื่นๆ เนื่องจากมีบริษัทชั้นนำเข้าร่วม EEA

นอกจากนี้ อีเธอร์เลียมสามารถลงทุนในรูปแบบการเทรด โดยนำเหรียญสกุลเงินดิจิทัลอื่นแลกกับอีเธอร์เลียม เพื่อสามารถใช้ในการเก็งกำไรตามอัตราแลกเปลี่ยนมูลค่าของตลาด ซึ่งในปัจจุบันมีเว็บไซต์สำหรับการแลกเปลี่ยนซื้อ-ขายอีเธอร์เลียมเป็นจำนวนมาก

2.1.3 ไลท์คอยน์ (Litecoin: LTC)

ไลต์คอยน์ (Litecoin) [31] เป็นสกุลเงินทางอินเทอร์เน็ตแบบ peer-to-peer ที่สร้างขึ้นในปี ค.ศ. 2011 โดย Charlie Lee อดีตรองวิศวกรของ Google ไลต์คอยน์ถูกพัฒนาจากซอร์สโค้ดดั้งเดิมของบิตคอยน์จึงมีลักษณะที่คล้ายกัน [32] ไลต์คอยน์เป็นโอเพ่นซอร์สเครือข่ายการชำระเงินที่มีการกระจายอำนาจอย่างสมบูรณ์โดยไม่มีหน่วยงานกลางจึงส่งผลให้ไลต์คอยน์เป็นสื่อกลางทางการค้าและยังเป็นส่วนเสริมของบิตคอยน์

ไลต์คอยน์เปิดการซื้อขาย [33] ครั้งแรกในเดือนมิถุนายน ค.ศ. 2013 โดยมีมูลค่าเพียง 2.83 ดอลลาร์สหรัฐ ต่อมาในเดือนพฤศจิกายนในปีเดียวกันไลต์คอยน์มีการเติบโตพุ่งสูงขึ้น 100% เนื่องจากนักลงทุนเริ่มให้ความสนใจ ส่งผลให้ราคาตอนนั้นอยู่ที่ 4.39 ดอลลาร์สหรัฐ ในช่วงปลายปี ค.ศ. 2021 ไลต์คอยน์ทำสถิติสูงสุดอยู่ที่ 410.26 ดอลลาร์



รูปที่ 3 มูลค่าตลาดของไลต์คอยน์ ตั้งแต่มกราคม ค.ศ. 2013 ถึง 28 มิถุนายน ค.ศ. 2022
ที่มา: [34]

ความแตกต่างระหว่างไลต์คอยน์และบิตคอยน์ เนื่องจากไลต์คอยน์มีการพัฒนาจากบิตคอยน์ทำให้ [33, 35-37] นักลงทุนส่วนใหญ่มองว่าไลต์คอยน์ถูกสร้างขึ้นเพื่อตอบสนองต่อแนวโน้มของบิตคอยน์มากกว่าเป็นสกุลเงินดิจิทัลที่ใช้สำหรับการลงทุน เพราะเหตุนี้ นักพัฒนาจึงมี


การปรับปรุงการทำงานของไลท์คอยน์ให้มีประสิทธิภาพมากกว่าบิตคอยน์ ดังตารางที่ 1 แสดงข้อเปรียบเทียบระหว่างบิตคอยน์กับไลท์คอยน์

ตารางที่ 1 การเปรียบเทียบระหว่างบิตคอยน์กับไลท์คอยน์

ปัจจัยที่สนใจ	Bitcoin	Litecoin
ความเร็วในการทำธุรกรรม	9 นาที	2.5 นาที
ขีดจำกัดของเหรียญ	21 ล้านเหรียญ	84 ล้านเหรียญ
มูลค่าตลาด	793.16 พันล้านดอลลาร์	7.83 พันล้านดอลลาร์

2.2 กรอบการดำเนินงานทั่วไปของการพยากรณ์ราคาคริปโทเคอร์เรนซี (Generic Framework of Cryptocurrency Price Prediction)

จากการการศึกษาที่ผ่านมา สามารถสรุปเป็นกรอบการดำเนินงานทั่วไปของการพยากรณ์ค่าสกุลเงินที่ถูกเข้ารหัสได้เป็น 2 ขั้นตอนหลัก ๆ ดังแสดงในรูปที่ 4 และอธิบายรายละเอียดได้คร่าว ๆ ดังนี้



รูปที่ 4 กรอบการดำเนินงานทั่วไปของการพยากรณ์ราคาคริปโทเคอร์เรนซี

2.2.1 การเตรียมข้อมูล (Pre-processing)

การเตรียมข้อมูล [38] คือ การแปลงข้อมูลให้อยู่ในรูปแบบที่เหมาะสมกับการนำไปสร้างโมเดลเพื่อการพยากรณ์กระบวนการชุด ซึ่งเทคนิคโดยพื้นฐานของการเตรียมข้อมูลได้แก่

1. การจัดการกับข้อมูลสูญหาย (Missing Value Handling) คือการแก้ปัญหาข้อมูลที่สูญหายไป ซึ่งอาจจะเป็นการสูญหายของข้อมูลบางตัวแปรหรือบางคุณลักษณะ ซึ่งอาจจะนำไปสู่ความผิดพลาดในการพยากรณ์ของโมเดล ซึ่งวิธีการที่ใช้สำหรับจัดการกับข้อมูลสูญหายมีทางเลือกให้พิจารณาค่อนข้างหลากหลาย หากเลือกใช้วิธีการจัดการกับข้อมูลสูญหายที่ไม่เหมาะสมย่อมส่งผลทำให้เกิดการบิดเบือนผลการวิเคราะห์ โดยทั่วไปหากจำนวนข้อมูลสูญหายในชุดข้อมูลที่ใช้นั้นไม่เกิน 5% อาจเลือกใช้วิธีการอย่างง่ายคือ ใช้วิธีการไม่เลือกข้อมูลที่มีปัญหามาใช้ในการวิเคราะห์

2. การนอร์มอลไลเซชันข้อมูล (Data Normalization) วิธีการปรับช่วงขอบเขตของข้อมูลชนิดตัวเลขในแต่ละตัวแปรหรือคุณลักษณะให้อยู่ในช่วงเดียวกันที่มีความเหมาะสมกับการนำไป

ประมวลผลในขั้นตอนต่อไป เทคนิคการนอร์มอลไลเซชันข้อมูลโดยพื้นฐานได้แก่ การปรับค่าข้อมูลด้วยอัลกอริทึม (Log Scaling) การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด (Min-max Scaling) และการปรับค่าข้อมูลแบบซี-สกอร์ (Z-score Scaling)

(1) การปรับค่าข้อมูลด้วยลอการิทึม (Log Scaling)

การปรับค่าข้อมูลด้วยลอการิทึม [39, 40] เป็นวิธีการแสดงข้อมูลตัวเลขที่มีช่วงกว้าง โดยเฉพาะข้อมูลที่มีความแปรปรวนสูง การปรับขนาดบันทึกจะเป็นการสร้างมาตรฐานของข้อมูลให้ช่วงข้อมูลแคบลง โดยมีสมการดังนี้

$$x' = \log(x) \quad (2.1)$$

โดยค่า x คือ ค่า (Value) ในคุณลักษณะที่ต้องการปรับ

(2) การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด (Min-max Scaling)

การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด [39, 41] เป็นการปรับข้อมูลให้เป็นมาตรฐาน เป็นการแปลงเชิงเส้นของข้อมูลที่ไม่มีโครงสร้างเดิม มันปรับขนาดข้อมูลจาก 0 ถึง 1 โดยมีสมการดังนี้

$$x' = \frac{(X - X_{min})}{X_{max} - X_{min}} \quad (2.2)$$

โดยค่า x คือ ค่า (Value) ในคุณลักษณะที่ต้องการปรับ

(3) การปรับค่าข้อมูลแบบซี-สกอร์ (Z-score Scaling)

การปรับค่าข้อมูลแบบซี-สกอร์ [39, 41, 42] เป็นวิธีการปรับค่าที่ใช้แทนค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) จากค่ากลาง (Mean) โดยวิธีนี้สามารถเปรียบเทียบคะแนนสองคะแนนที่ต่างกันซึ่งมาจากการแจกแจงคุณลักษณะมีค่าเฉลี่ยเป็น 0 และค่าเบี่ยงเบนมาตรฐานเท่ากับ 1 เพื่อหาค่าความผิดปกติ โดยมีสมการดังนี้

$$x' = \frac{x - \mu}{SD} \quad (2.3)$$

โดยค่า x คือ ค่า (Value) ในคุณลักษณะที่ต้องการปรับ ในขณะที่ μ คือ ค่า เฉลี่ย และ SD คือ ค่าเบี่ยงเบนมาตรฐานของข้อมูล

3. การคัดเลือกคุณลักษณะ (Feature Selection) เป็นขั้นตอนของการเลือกคุณลักษณะหรือตัวแปรสำหรับการพยากรณ์ (Predictive Variables) ซึ่งในการเลือกคุณลักษณะนี้สามารถอ้างอิงจากงานวิจัยก่อนหน้าได้ เช่นในงานวิจัยของ [10, 43, 44]

4. การแปลงข้อมูล (Data Transformation) คือกระบวนการแปลงข้อมูลให้เหมาะสมกับการวิเคราะห์ตามวัตถุประสงค์หรือความต้องการ โดยทั่วไปมักจะแสดงในรูปแบบของเวกเตอร์ของข้อมูลที่แสดงความสัมพันธ์ระหว่างข้อมูลในแต่ละระเบียน (Record) และตัวแปร (Variables) หรือคุณลักษณะ (Features) ของข้อมูลระเบียนนั้น

2.2.2 การสร้างโมเดลเพื่อการพยากรณ์ราคาคริปโทเคอร์เรนซี (Modeling of Cryptocurrency Price Prediction)

จากการทบทวนวรรณกรรม พบว่าอัลกอริทึมหรือเทคนิคที่นิยมใช้ในการพยากรณ์ราคาคริปโทเคอร์เรนซีมากที่สุด ได้แก่ Autoregressive Integrated Moving Average (ARIMA), Machine Learning และ Deep Learning

2.2.2.1 Autoregressive Integrated Moving Average (ARIMA) เป็นหนึ่งในการวิเคราะห์ข้อมูลแบบอนุกรมเวลา (Time Series Analysis) คือการอาศัยข้อมูลในอดีตเพื่อกำหนดรูปแบบของข้อมูลและพยากรณ์ข้อมูลในอนาคต หลักการหลักของ ARIMA คือ พยายามกำจัด “Noise” ออกจาก Time series เพื่อที่จะลด Error ให้ได้มากที่สุด แม้เทคนิคแบบ ARIMA จะได้รับความนิยมในแนวทางการวิเคราะห์ข้อมูลเชิงสถิติ แต่ก็มีข้อที่ต้องพึงระวังคือ [48]

ประเด็นที่ 1 : เทคนิคแบบ ARIMA เป็นเทคนิคแบบดั้งเดิมที่ผู้ใช้งานต้องมีความเชี่ยวชาญและประสบการณ์มากพอ เพราะประสิทธิภาพของโมเดลที่สร้างขึ้นมาจะขึ้นกับทักษะและประสบการณ์ของผู้ใช้ ซึ่งในความเป็นจริงทุกๆ โมเดลก็น่าจะเป็นไปในทำนองเดียวกัน

ประเด็นที่ 2 : เทคนิคแบบ ARIMA เป็นเทคนิคที่ไม่ได้อยู่บนทฤษฎี หลักการ หรือความสัมพันธ์เชิงโครงสร้างใดๆ ที่ชัดเจน ดังนั้นประสิทธิภาพของโมเดลที่สร้างขึ้นมาจะขึ้นกับทักษะและประสบการณ์ของผู้ใช้


ประเด็นที่ 3 : เทคนิคแบบ ARIMA เป็นเทคนิคโมเดลที่ค่อนข้างเชี่ยวชาญเมื่อต้องสร้างแบบจำลองแนวโน้มโดยรวมพร้อมกับรูปแบบตามฤดูกาล ซึ่ง ARIMA จะอยู่บนพื้นฐานแบบ “การมองย้อนกลับ (Backward Looking)” ดังนั้น ARIMA มักจะพยากรณ์จุดกลับตัว (Turning Point) ได้ไม่ดี ยกเว้นจุดกลับตัวนั้นจะแสดงถึงดุลยภาพระยะยาว (Long-Run Equilibrium)

2.2.2.2 การเรียนรู้ของเครื่อง (Machine Learning: ML) คือ เทคนิคระบบที่สามารถเรียนรู้ได้จากตัวอย่างด้วยตนเอง โดยปราศจากการป้อนคำสั่งของมนุษย์ การทำให้ระบบคอมพิวเตอร์สามารถประมวลผล คาดการณ์ ตัดสินปัญหาต่างๆ ด้วยตนเองผ่านการเรียนรู้ชุดข้อมูลที่ป้อนเข้าไป ปัจจุบันการใช้การเรียนรู้ของเครื่องในงานด้านการพยากรณ์เพราะสามารถสร้างโมเดลได้ง่าย และมีการประมวลผลที่เร็ว นอกจากนี้ในการสร้างโมเดลหรือการประมวลผลอาจจะกระทำได้โดยผู้ใช้งานที่ไม่ได้มีความเชี่ยวชาญมากก็ได้ (No Human Intervention Needed) รวมทั้งการเรียนรู้ของเครื่องสามารถใช้งานหรือจัดการข้อมูลได้ทั้งแบบหลายมิติ (Multi-Dimensional Data) หรือหลายตัวแปร (Multi-Variety Data) [49] การเรียนรู้เชิงลึก (Deep learning) คือ วิธีการเรียนรู้แบบอัตโนมัติด้วยการเลียนแบบการทำงานของโครงข่ายประสาทของมนุษย์ (Neurons) โดยนำระบบโครงข่ายประสาท (Neural Network) มาซ้อนกันหลายชั้น (Layer) และทำการเรียนรู้ข้อมูลตัวอย่าง ซึ่งข้อมูลดังกล่าวจะถูกนำไปใช้ในการตรวจจำรูปแบบ (Pattern) หรือจัดหมวดหมู่ข้อมูล (Classify The Data) โดยข้อดีของสร้างโมเดลของพยากรณ์ด้วยการเรียนรู้เชิงลึก [50] เพราะจะช่วยลดอคติของแบบจำลองโดยแท้จริง เนื่องจากโมเดลจะได้รับการสอนให้ทำซ้ำจนได้ค่าหรือฟังก์ชันเป้าหมาย สำหรับใน

งานวิจัยนี้จะใช้ Support Vector Regression (SVR), Artificial Neural Networks (ANNs) และ Kernel Regression (KR)

(1) ซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR)

ซัพพอร์ตเวกเตอร์รีเกรสชัน หรือ SVR [51-55] เป็นอัลกอริทึมที่รองรับทั้งการถดถอยเชิงเส้นและการถดถอยไม่เชิงเส้น SVR ทำงานบนหลักการของซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) สำหรับการจำแนกประเภท ซึ่งมีความแตกต่างกันเพียงเล็กน้อยคือ SVM เป็นตัวแยกประเภทสำหรับการทำนายข้อมูลที่ไม่ต่อเนื่อง ในขณะที่ SVR ใช้สำหรับการจัดประเภทข้อมูลแบบต่อเนื่อง โดยแนวคิดหลักของ SVR คือการประมาณค่าที่ดีที่สุดภายในระยะขอบที่กำหนด (ϵ -tube) หรือการปรับให้เหมาะสมกลับข้อผิดพลาดที่กำหนด



รูปที่ 5 โครงสร้างของ SVR
ที่มา: [55]

สำหรับการทำงานของ SVR [52] โดยทั่วไปเมื่อกำหนดจุดข้อมูล อัลกอริทึมจะใช้เส้นโค้งเป็นขอบเขตการตัดสินใจ แต่สำหรับ SVR จะใช้เส้นโค้งเพื่อค้นหาการจับคู่ระหว่างเวกเตอร์กับตำแหน่งของเส้นโค้ง เวกเตอร์นั้นจะเป็นตัวกำหนดการจับคู่ใกล้ที่สุดระหว่างจุดของข้อมูลและฟังก์ชันที่ใช้แสดง โดย SVR มีสมการดังนี้

$$\bullet \text{ Minimize: } \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (2.4)$$


$$\bullet \text{ Constraints: } \begin{aligned} y_i - wx_i - b &\leq \varepsilon + \xi_i \\ wx_i + b - y_i &\leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (2.5)$$

(2) โครงข่ายประสาทเทียม (Artificial Neural Networks: ANN)

ANN [56-62] เป็นแบบจำลองคอมพิวเตอร์ที่เลียนแบบการทำงานของเซลล์ประสาทของมนุษย์ สามารถเรียนรู้ด้วยเครื่องและจดจำรูปแบบได้ ANNs ถูกนำเสนอครั้งแรกในปี 1943 โดย Warren McCulloch นักประสาทวิทยาและ Walter Pitts นักคณิตศาสตร์ [63] ได้มีการตีพิมพ์เอกสารที่มีชื่อว่า “A Logical Calculus Of The Ideas Imminent In Nervous” โดยในเนื้อหาได้มีการอธิบายแบบจำลองทางคณิตศาสตร์ของโครงข่ายประสาทเทียม ในปี 1951

Marvin Minsky ได้สร้างเครื่องการเรียนรู้เครือข่ายประสาทเทียม โดยใช้ Stochastic Neural Analog Reinforcement Calculator (SNARC) ซึ่งเป็นเครือข่ายแบบสุ่มของ Hebb Synapses ได้สำเร็จเป็นสำเร็จเป็นเครื่องแรก


โครงสร้างของ ANNs จะประกอบด้วยชั้นโหนด (Nodes) ซึ่งมี Input layer, Hidden layer และ Output layer ซึ่งแต่ละโหนดจะเชื่อมต่อกับโหนดอื่น โดยที่มีน้ำหนักและเกณฑ์ที่เกี่ยวข้องกัน ซึ่งจะมีลักษณะคล้ายกับเซลล์ประสาทของมนุษย์ ดังรูปที่ 6 จะแสดงโครงสร้างของ ANNs



รูปที่ 6 โครงสร้างของ ANNs
ที่มา: [62]

การทำงานของ ANNs ดังรูป 6 จะแสดงทีละขั้นตอนในการทำงานของ ANNs ซึ่งประกอบด้วย 5 องค์ประกอบได้แก่

1. Input Layer หรือ ข้อมูลป้อนเข้า คือการนำชุดข้อมูลที่เป็นตัวเลขนำเข้าสู่โมเดล (Model) เพื่อประมวลผลต่อไป
2. Weights หรือ ค่าน้ำหนัก คือเป็นค่าที่ใช้ในการจดจำข้อมูลอื่นๆ ที่จัดอยู่ในรูปแบบเดียวกัน



รูปที่ 7 ขั้นตอนการทำงานของ ANNs
ที่มา: [62]

3. Summation Function หรือ ฟังก์ชันผลรวม คือ ผลรวมของข้อมูลอินพุต (X_i) และค่าน้ำหนัก (W_i) มีสมการดังนี้

$$S = \sum_{i=1}^n x_i * w_i + b \quad (2.6)$$

โดยที่ x คือ อินพุต
 w คือ ค่าน้ำหนัก
 b คือ ค่าอคติ (Bias)
 n คือ จำนวนอินพุตจากเลเยอร์ขาเข้า
 i คือ ตัวนับตั้งแต่ 1 ถึง n

4. Transfer Function หรือ ฟังก์ชันการแปลง คือ ในฟังก์ชันนี้จะทำการเปลี่ยนแปลงข้อมูลจากข้อมูลป้อนเข้าเป็นข้อมูลส่งออก ซึ่งฟังก์ชันการแปลงแบ่งออกเป็น 4 ประเภท ได้แก่ Unit Step, Sigmoid, Piecewise Linear, Gaussian และ Linear Function

5. Output Layer หรือ ข้อมูลส่งออก คือ ข้อสรุปของโมเดลที่เกิดจากการคำนวณทั้งหมด ข้อสรุปที่ได้อาจมีโหนดเดียวหรือมีหลายโหนดในเลเยอร์นี้

(3) เคอร์เนลการถดถอย (Kernel Regression: KR)

เคอร์เนลการถดถอย หรือ KR [61-63] เป็นวิธีการประมาณค่าแบบจำลองการถดถอยเพื่อให้เหมาะสมกับชุดข้อมูล สำหรับการรวบรวมข้อมูล KR จะช่วยในการกำหนดฟังก์ชันการถดถอยที่เหมาะสมกับชุดข้อมูลที่สุด วิธีนี้ยังตีความและประมาณค่าที่ได้นอกเหนือจากชุดข้อมูล ซึ่งจะตรงข้ามกับการถดถอยเชิงเส้นซึ่งจะพิจารณาสมมติฐานพื้นฐาน แต่สำหรับ KR ที่ถูกจัดประเภทเป็นเทคนิคที่ไม่ใช้พารามิเตอร์จะไม่พิจารณาสมมติฐานขั้นพื้นฐาน ในงานวิจัยนี้จะใช้ฟังก์ชันเกาส์เซียนเคอร์เนล (The Gaussian Kernel Function) คำนวณชุดของข้อมูล โดยมีสมการดังนี้

$$K(x) = \frac{1}{h\sqrt{2\pi}} e^{-0.5\left(\frac{x-x_i}{h}\right)^2} \quad (2.7)$$


โดยที่ x_i คือ จุดของข้อมูล
 x คือ ผลลัพธ์การคำนวณฟังก์ชันเคอร์เนล
 h คือ แบนด์วิดท์ (Bandwidth)

2.2.2.3 การเรียนรู้เชิงลึก (Deep Learning: DL) คือ เทคนิคระบบที่สามารถเรียนรู้ได้จากตัวอย่างด้วยตนเอง โดยปราศจากการป้อนคำสั่งของมนุษย์ ซึ่งสามารถทำให้ประมวลผลคาดการณ์ หรือตัดสินใจปัญหาต่างๆ ผ่านการเรียนรู้จากชุดข้อมูลที่ป้อน โดยการเรียนรู้เชิงลึก

(1) หน่วยความจำระยะสั้นระยะยาว (Long Short-Term Memory: LSTM)

หน่วยความจำระยะสั้นระยะยาว หรือ LSTM [64-68] คือ หนึ่งในโครงข่ายประเภท Recurrent Neural Network (RNN) ที่สามารถเรียนรู้การพึ่งพาลำดับในปัญหาการ

พยากรณ์ลำดับ [69] ถูกนำเสนอครั้งแรกในปี ค.ศ. 1997 โดย Sepp Hochreiter และ Jürgen Schmidhuber ได้มีการตีพิมพ์เอกสารที่มีชื่อว่า “Long Short-Term Memory” โดยในเนื้อหาได้มีการอธิบายโครงสร้างของ LSTM จุดประสงค์ของ LSMT ถูกสร้างขึ้นสำหรับการประมวลผลลำดับ (Sequence) และเพื่อแก้ไขปัญหาการพึ่งพาในระยะยาว (Long – Term Dependencies) ใน RNN เนื่องจากการไล่ระดับสี (Gradient) หายไปส่งผลให้ขัดขวางการเรียนรู้ของลำดับข้อมูลที่มีขนาดยาว โดยรูปที่ 8 จะแสดงการทำงานของ LSTM



รูปที่ 8 กระบวนการทำงานของ LSTM
ที่มา: [65]

จากรูปที่ 8 จะแสดงการทำงานหลักของ LSTM คือ

- Cell State คือที่เก็บ state ของ Memory Cell
- Gate คือ ตัวที่ควบคุมการไหลของข้อมูล ซึ่งก็คือ ค่า Analog ที่ควบคุม

Read, Write หรือ Forget

โดยสามารถอธิบายแต่ละขั้นตอนการทำงาน [65] ได้ดังนี้

• Forget Gate คือ การล้าง Cell State เดิมเพื่อเตรียมพื้นที่สำหรับหารันข้อมูลใหม่ โดยมี Forget Gate จะทำหน้าที่การตัดสินใจสำหรับการล้าง Cell State ซึ่ง Forget Gate จะให้ค่า 0 กับ 1 โดยที่ค่า 0 คือการล้าง Cell State และค่า 1 คือ ไม่ล้าง Cell State

สำหรับการสร้าง Forget Gate Input Data ที่เข้ามา ประกอบกับ Hidden State เพื่อเป็นการประกอบารตัดสินใจ โดยจะใช้ Sigmoid Function เป็นตัวตัดสินใจ โดยมีสมการดังนี้

$$f_t = \sigma(W_x^f x_t + W_h^f h_{t-1} + b_f) \quad (2.8)$$

• Write คือ เมื่อมีชุดข้อมูลใหม่เข้ามา การอัปเดต Cell State จะถูกควบคุมโดย Input Gate และ Sigmoid Function เป็นตัวตัดสินใจจะอัปเดตข้อมูลใหม่หรือไม่ โดยมีสมการดังนี้

$$i_t = \sigma(W_x^i x_t + W_h^i h_{t-1} + b_i) \quad (2.9)$$

• ในกรณีที่อนุญาตในการอัปเดตข้อมูลใหม่ Input Modulation Gate เป็นตัวตัดสินใจ โดยมีสมการดังนี้


$$g_t = \tanh(W_x^f x_t + W_h^f h_{t-1} + b_f) \quad (2.10)$$

• การอัปเดต Cell State เมื่อได้ข้อมูลจาก Forget Gate, Input Gate และ Input Modulation Gate ขั้นตอนนี้จะเป็นการอัปเดต Cell State โดยมีสมการดังนี้

$$C_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (2.11)$$

(2) Gated Recurrent Units (GRU)

GRU [70-78] เป็นหนึ่งในประเภทของโครงข่าย RNN ถูกนำเสนอในปี ค.ศ. 2014 โดย Kyunghun Cho Et All [77] ได้มีการตีพิมพ์เอกสารที่มีชื่อว่า “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation” GRU ถูกพัฒนาขึ้นเพื่อแก้ปัญหา Vanishing Gradient และ Exploding Gradient นอกจากนี้ GRU ยังสามารถแก้ปัญหการไล่ระดับสีที่หายไปของ RNN GRU มีลักษณะคล้ายกับ LSTM คือ Forget Gate แต่เนื่องจาก GRU ไม่มี Output Gate จึงทำให้มี Parameter น้อยกว่า LSTM ส่งผลให้เทรนข้อมูลได้ง่าย รวดเร็ว และเหมาะสมสำหรับข้อมูลที่มีขนาดเล็ก ดังรูปที่ 9 จะแสดงการทำงานของ GRU



รูปที่ 9 กระบวนการทำงานของ GRU
ที่มา: [71]

ขั้นตอนการทำงานของ GRU สามารถแบ่งได้เป็น 4 ขั้นตอน [74, 78] ได้ดังนี้

(1) อัปเดตเกต (Update Gate: z_t)

เป็นขั้นตอนที่ช่วยควบคุมการไหลของข้อมูลที่ส่งผ่านไปยังอนาคต ในขั้นตอนนี้จะขจัดความเสี่ยงของปัญหาการไล่ระดับสีที่หายไป มีสมการดังนี้

$$Z_t = \sigma(W^{(z)} x_t + U^{(z)} h_{t-1}) \quad (2.12)$$

โดยที่ t คือ ช่วงเวลา

x_t คือ อินพุตเวกเตอร์

h_{t-1} คือ สถานะที่ซ่อนอยู่ก่อนหน้า

w_z คือ อัปเดตเทริกซ์น้ำหนักของเกต

สำหรับ σ หรือ Sigmoid Function คือ เมื่อทำการป้อนข้อมูล (Input) เข้าสู่โมเดล Sigmoid Function จะจับคู่แควระหว่าง 0 กับ 1 เท่านั้น แม้ว่าข้อมูลที่ถูกป้อนเข้ามาจะมากเพียงใด

(2) รีเซ็ตเกต (Reset Gate : r_t)

ในขั้นตอนนี้เป็นแบบจำลองที่ใช้ในการตัดสินใจลืมข้อมูลที่ผ่านมามากหรือน้อยเพียงใด มีสมการดังนี้

$$r_t = \sigma(W^{(r)}x_t + U^{(r)}h_{t-1}) \quad (2.13)$$

โดยที่ t คือ ช่วงเวลา
 r_t คือ รีเซ็ตเกต
 h_{t-1} คือ สถานะที่ซ่อนอยู่ก่อนหน้า
 w_r คือ เทตริกซ์น้ำหนักของเกตสำหรับ

(3) เกตในการดำเนินการ (Current Memory Content: $\hat{h}_t$)

ในขั้นตอนแรกของรีเซ็ตเกตจะเก็บข้อมูลที่เกี่ยวข้องจากอดีตมาลงในเนื้อหาหน่วยความจำใหม่ มีสมการดังนี้

$$\hat{h}_t = \tanh(Wx_t + r_t \odot Uh_{t-1}) \quad (2.14)$$

โดยที่ t คือ ช่วงเวลา
 $\hat{h}_t$ คือ ฟังก์ชันหน่วยความจำปัจจุบัน
 r_t คือ รีเซ็ตเกต
 x_t คือ อินพุตเวกเตอร์
 h_{t-1} คือ สถานะที่ซ่อนอยู่ก่อนหน้า
 w_r คือ เทตริกซ์น้ำหนักของเกตสำหรับ

(4) หน่วยความจำสุดท้ายในขั้นตอนเวลาปัจจุบัน (Final Memory At Content Time Step: h_t)

ในขั้นตอนสุดท้าย [78] ค่าเวกเตอร์ที่อยู่ในอัปเดตเกตจะเก็บข้อมูลสำหรับหน่วยความจำปัจจุบันและส่งต่อไปยังเครือข่าย โดยจะกำหนดข้อมูลที่จะรวบรวมจากเนื้อหาปัจจุบันมีสมการดังนี้

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \hat{h}_t \quad (2.15)$$

โดยที่ t คือ ช่วงเวลา
 h_{t-1} คือ สถานะที่ซ่อนอยู่ก่อนหน้า
 $\hat{h}_t$ คือ ฟังก์ชันหน่วยความจำปัจจุบัน
 z_t คือ อัปเดตเกต

2.2.3 การประเมิน (Evaluation)

สำหรับในขั้นตอนนี้จะทำการประเมินโมเดลในการพยากรณ์ราคาคริปโทเคอร์เรนซี 3 วิธีได้แก่ รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE),

ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) และ สัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R-Square)

- (1) รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง
(Root Mean Square Error: RMSE)

รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง หรือ RMSE [53, 54, 64-66, 80] เป็นอีกหนึ่งวิธีการวัดข้อผิดพลาดของโมเดลที่เป็นที่นิยม โดยจะมีคุณสมบัติที่คล้ายคลึงกับ MSE คือวิธีนี้จะเป็นการคาดการณ์ความแม่นยำของโมเดล ซึ่งแตกต่างกันตรงที่ค่าความผิดพลาดที่คำนวณได้ของ RMSE จะสามารถอ่านค่าได้ง่ายเนื่องจากไม่มีเลขยกกำลังสอง โดยมีสมการดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (2.16)$$

โดยที่ n คือ จำนวนข้อมูล
 y_t คือ ค่าจริง
 $\hat{y}_t$ คือ ค่าทำนาย

อย่างไรก็ตาม [64, 65] ค่า RMSE มีความ Sensitive กับ Outlier มาก ซึ่งอาจจะส่งผลให้ค่าที่ได้อาจมีความบิดเบือนต่อค่าที่ได้ฝึกปกติ

- (2) ข้อผิดพลาดสัมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error: MAPE)

ข้อผิดพลาดสัมบูรณ์เปอร์เซ็นต์ หรือ MAPE [53, 54] เป็นค่าวัดความแม่นยำ โดยการคำนวณเปอร์เซ็นต์ความผิดพลาดของโมเดล โดยมีสมการดังนี้

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \times 100 \quad (2.17)$$

โดยที่ n คือ จำนวนข้อมูล
 y_t คือ ค่าจริง
 $\hat{y}_t$ คือ ค่าทำนาย

- (3) สัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R-Square)

สัมประสิทธิ์การตัดสินใจ หรือ R-Square (R^2) [84-87] เป็นวิธีการวัดสัดส่วนของความแปรปรวนของตัวแปรตามโมเดลการถดถอยโดยจะระบุเป็นเปอร์เซ็นต์ (Percentage) R-Square จะวัดความเหมาะสมระหว่างแบบจำลองของโมเดลกับตัวแปรตามในระดับ 0 -100%

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (2.18)$$

โดยที่ y_t คือ ค่าจริง
 $\bar{y}$ คือ ค่าการคาดคะเน

เนื่องจาก R-Square ค่อนข้างมีความ Sensitive กับ Outlier ซึ่งอาจจะส่งผลให้ค่าที่ได้อาจมีความบิดเบือนต่อค่าที่ได้ผิดปกติ ค่าที่ได้จะอยู่ในระหว่าง 0 ถึง 1 โดยค่าที่ใกล้กับ 0 จะบ่งบอกถึงความไม่พอดีกันระหว่างชุดข้อมูลกับโมเดล และค่าที่ใกล้กับ 1 จะบ่งบอกถึงความพอดีระหว่างชุดข้อมูลกับโมเดล

2.3 งานวิจัยที่เกี่ยวข้อง

ในส่วนนี้จะเป็นการทบทวนงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ค่าเงินสกุลดิจิทัล จากการศึกษาที่ผ่านมาพบว่ามีการศึกษาอย่างต่อเนื่องและหลากหลาย ตัวอย่างงานวิจัยในการพยากรณ์ราคาคริปโทเคอร์เรนซีสามารถแสดงได้ดังนี้

Phaladisailoed และ Numnonda [10] พบว่าการผันผวนของราคาบิตคอยน์ ทำให้การคาดการณ์ราคาเป็นไปได้ยาก จึงต้องการหาโมเดลที่มีประสิทธิภาพและมีความแม่นยำสูงที่สุดในการพยากรณ์ราคาบิตคอยน์ จากอัลกอริทึม ซึ่งจะช่วยให้ผู้ลงทุนลดภาวะความเสี่ยงที่เกิดจากความผันผวนของราคาบิตคอยน์ ดังนั้นนักวิจัยกลุ่มนี้จึงได้ศึกษาเชิงเปรียบเทียบการใช้โมเดลการเรียนรู้ของเครื่องในการพยากรณ์ราคาของบิตคอยน์ ซึ่งข้อมูลที่ใช้เป็นข้อมูลการซื้อขายในบิตคอยน์ช่วงเวลา 1 นาที ในระหว่างวันที่ 1 มกราคม ค.ศ. 2012 ถึง 8 มกราคม ค.ศ. 2018 ที่รวบรวมมาจากเว็บไซต์การแลกเปลี่ยน บิตคอยน์ คือ www.kaggle.com โดยชุดข้อมูลถูกจัดเก็บอยู่ในไฟล์รูปแบบ CSV จำนวนข้อมูลที่ใช้ในการคำนวณคือ 2,195 ระเบียบ และข้อมูลแต่ละตัวมี 8 ตัวแปร ได้แก่ Latest Trade (Close), Opening Trade (Open), Highest Trade During Day (High), Lowest Trade During Day (Low), Mean Bitcoin Price (Weighted Price), Total Trade Volume For Day In BTS (Volume_BTS), Total Trade Volume Of In USD (Volume_Currency), และ Data Recorded Time (Time Stamp) ในการเตรียมข้อมูลมีการปรับสเกลข้อมูลให้อยู่ระหว่าง 0-1 ด้วยฟังก์ชัน MinMaxScaler ใน Scikit-Learn เพื่อให้เหมาะสมต่อการนำไปสร้างโมเดล จากนั้นทำการสร้างโมเดลด้วย 4 อัลกอริทึมคือ Theil-Sen Regression, Huber Regression, Long Short-Term Memory (LSTM) และ Gated Recurrent Unit (GRU) โดยผ่านการเรียกใช้ของ Scikit-Learn และ Keras ในการวัดประสิทธิภาพของโมเดล ใช้ Mean Square Error (MSE) และค่า R-square (R2) พบว่าโมเดลที่พัฒนาจากอัลกอริทึมที่ได้ศึกษาทั้งหมดให้ผลลัพธ์ที่น่าพอใจ โดยเฉพาะอย่างยิ่ง โมเดลที่พัฒนาจากอัลกอริทึม GRU เพราะให้ค่า MSE ที่ 0.00002 และค่า R2 อยู่ที่ 99.2 %

ในปี ค.ศ. 2019 Ji และคณะ [9] ได้ศึกษามีวิธีการด้านการเรียนรู้เชิงลึก (Deep Learning) มากมายที่น่าเสนอมาเพื่อใช้ในการพยากรณ์ราคาของบิตคอยน์ ซึ่งงานวิจัยนี้ได้ทำการศึกษาเชิงเปรียบเทียบกระบวนการของการพยากรณ์ราคาด้วยวิธีการของการเรียนรู้เชิงลึก ได้แก่ Convolution Neural Network (CNN), Deep Neural Network (DNN), Recurrent Neural Network (RNN), Deep Residual Network (ResNet), CNN + RNN (CRNN), Ensemble Method ของอัลกอริทึมการเรียนรู้เชิงลึก, และอัลกอริทึมการเรียนรู้ของเครื่อง 1 ตัว คือ Support

Vector Machine (SVM) โดยใช้ข้อมูลอนุกรมเวลาของตลาด Bitstamp Bitcoin Market (USD) จากเว็บไซต์ Bitcoincharts ตั้งแต่วันที่ 29 พฤศจิกายน ค.ศ. 2011 จนถึง 31 ธันวาคม ค.ศ. 2018 ข้อมูลที่ได้จะถูกแปลงเป็นค่าเฉลี่ยรายวันสำหรับการใช้ในการศึกษา โดยจะพิจารณาคุณสมบัติบล็อกเชนของ บิตคอยน์ ทั้ง 29 คุณลักษณะ โดยจะไม่พิจารณาคุณสมบัติที่เป็นหน่วยความจำซึ่งจะเหลือ 25 คุณลักษณะ นำคุณสมบัติที่เหลือไปพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) เพื่อวิเคราะห์ความสัมพันธ์ระหว่างคุณสมบัติที่เหลือกับราคา Bitstamp Bitcoin ซึ่งจะเหลือ 18 คุณลักษณะ และเพื่อให้เหมาะสมกับการเรียนรู้เชิงลึกจึงมีการจัดเตรียมรูปแบบของข้อมูลดังนี้ จุดข้อมูลแต่ละจุด p เป็นเวกเตอร์มูลค่าจริง 18 คุณลักษณะ ซึ่งแต่ละคุณลักษณะจัดเก็บมูลค่ารายวันเพื่อคาดการณ์ราคาบิตคอยน์ เมื่อขนาดของแต่ละซีควเ็นซ์เท่ากับ m ข้อมูลลำดับทั้งหมด $2590 - m + 1$ ถูกใช้เพื่อฝึกและทดสอบแบบจำลองการพยากรณ์เชิงลึกที่หลากหลาย กล่าวคือ ตั้งแต่ $S[1 : m]$ ถึง $S[2590 - m + 1 : 2590]$ เมื่อได้ชุดข้อมูลจากนั้นทำการเปรียบเทียบการเรียนรู้เชิงลึกด้วยเครื่องมือ Support Vector Machine (SVM) ใน Scikit-Learn Library โดยจำแนกเป็น 3 kernel ได้แก่ namely (Linear), poly (Polynomial) and RBF (Radial Basis Function) ซึ่งภายหลังจากการวัดประสิทธิภาพของโมเดลด้วยค่า Mean absolute percentage error (MAPE) ในการประเมินโมเดลเพื่อการพยากรณ์ราคาบิตคอยน์ โดยทำการทดสอบ Sequence Size Of Previous Data หรือ m ที่ขนาดเท่ากับ 5, 10, 20, 50 และ 100 โดยหากพิจารณาค่า $m = 5$ พบว่า DNN ให้ผลลัพธ์ที่ดีที่สุดคือ 3.61, $m = 10$ และ 20 พบว่า LSTM ให้ผลลัพธ์ที่ดีที่สุดคือ 3.96 และ 4.46 ตามลำดับ, $m = 50$ และ 100 พบว่า SVM ให้ผลลัพธ์ที่ดีที่สุดคือ 6.34 และ 12.77 ตามลำดับดังนั้นโมเดลที่โมเดลการจำแนกประเภทมีประสิทธิภาพมากกว่าโมเดลการถดถอยแต่เมื่อเปรียบเทียบกระบวนการพยากรณ์ราคาด้วยการเรียนรู้เชิงลึกแสดงให้เห็นว่ายังไม่มีเครื่องมือที่โดดเด่นในการพยากรณ์ราคา

ในปี ค.ศ. 2020 Mahendra และคณะ [14] พบว่าความผันผวนของราคาบิตคอยน์จะทำให้นักลงทุนเกิดความสับสน ดังนั้นวิธีการพยากรณ์ราคาของบิตคอยน์ด้วยโมเดลพยากรณ์ราคาของบิตคอยน์อาจจะช่วยลดความเสี่ยงในการลงทุนด้วย ดังนั้นนักวิจัยกลุ่มนี้จึงได้ศึกษาการสร้างโมเดลเพื่อการพยากรณ์ราคาบิตคอยน์โดยใช้การเรียนรู้เชิงลึก โดยข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลมาตรฐานการซื้อขายบิตคอยน์จากเว็บไซต์ Kaggle ที่จัดเก็บอยู่ในไฟล์รูปแบบ CSV มีจำนวนทั้งสิ้น 1,098 ระเบียบ ที่มี 8 ตัวแปร ได้แก่ Data Recorded Time (Time Stamp), Latest Trade (Close), Opening Trade (Open), Highest Trade During Day (High), Lowest Trade During Day (Low), Total Trade Volume For Day In BTS (Volume BTS), Total Trade Volume Of In USD (Volume_Currency) และ Mean Bitcoin Price (Weighted Price) ซึ่ง 80% ของข้อมูลชุดนี้ถูกใช้เป็นข้อมูลชุดสอน (Training Set) และอีก 20% ถูกใช้เป็นข้อมูลชุดทดสอบ สำหรับการสร้างโมเดลเพื่อการพยากรณ์ราคาบิตคอยน์นั้นจะสร้างโดยใช้ Tensor Flow Backend ใน Keras Library ซึ่งในงานวิจัยนี้ทำการศึกษาเชิงเปรียบเทียบด้วยอัลกอริทึมการเรียนรู้เชิงลึก 3 อัลกอริทึม ได้แก่ Long Short Term Memory (LSTM), Gated Recurrent Unit (GRU), Convolution Neural Network (CNN) และอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) 1 อัลกอริทึม

ได้แก่ Support Vector Machine (SVM) ภายหลังการสร้างโมเดลเพื่อการพยากรณ์ราคาบิตคอยน์ ด้วยอัลกอริทึมเหล่านี้เสร็จแล้ว ได้นำข้อมูลชุดทดสอบมาทำการทดสอบประสิทธิภาพของการพยากรณ์ด้วยวิธี Root Mean Square Error (RMSE) พบว่า LSTM และ GRU ให้ผลลัพธ์ที่น่าพอใจมากที่สุด โดย LSTM มีค่า RMSE อยู่ที่ 0.022 ขณะที่ GRU มีค่า RMSE อยู่ที่ 0.014 ซึ่งจะเห็นว่า GRU ให้ผลลัพธ์ที่ดีกว่า LSTM โดยนักวิจัยให้เหตุผลว่าการที่ LSTM มีจำนวนพารามิเตอร์ที่มากกว่า GRU อาจจะส่งผลต่อประสิทธิภาพของการวิเคราะห์ข้อมูล หากพารามิเตอร์เหล่านั้นกำหนดค่าไม่เหมาะสมกับข้อมูลที่กำลังวิเคราะห์ ในทางตรงข้ามอัลกอริทึม GRU ที่มีความซับซ้อนของพารามิเตอร์น้อยกว่าจึงให้ประสิทธิภาพที่ดีกว่า LSTM เพราะการกำหนดค่าพารามิเตอร์ที่เหมาะสมทำได้ง่ายกว่า

ในปี ค.ศ. 2021 Samaddar และคณะ [84] ได้ศึกษาวิธีการด้านการเรียนรู้เครื่อง (Machine Learning) มากมายที่นำเสนอมาเพื่อใช้ในการพยากรณ์ราคาของบิตคอยน์ ซึ่งงานวิจัยนี้ได้ทำการศึกษาเชิงเปรียบเทียบกระบวนการของการพยากรณ์ราคาด้วยวิธีการของการเรียนรู้เครื่อง ได้แก่ Artificial Neural Network (ANN), Recurrent Neural Network (RNN), Convolutional Neural Network (CNN), Random Forest (RF) และ K-Nearest Neighbors (k-NN) โดยใช้ข้อมูล Bitcoin Historical Data จากเว็บไซต์ Kaggle ซึ่งประกอบด้วย 8 ตัวแปร ได้แก่ Data Recorded Time (Time Stamp), Latest Trade (Close), Opening Trade (Open), Highest Trade During Day (High), Lowest Trade During Day (Low), Total Trade Volume For Day In BTS (Volume_BTS), Total Trade Volume Of In USD (Volume_Currency) และ Mean Bitcoin Price (Weighted Price) ที่ได้จะถูกนำมาแปลงเป็นชุดข้อมูลสะอาด (Data Cleaning) เนื่องจากข้อมูลบางส่วนมีค่าว่าง (Null) เป็นจำนวนมาก จากนั้นนำข้อมูลปรับสเกลข้อมูลด้วยฟังก์ชัน MinMaxScaler และทำการแบ่งข้อมูลที่ใช้ในการฝึกอบรม 73% และ 27% การวิเคราะห์ข้อมูลโดยใช้โมเดลการทดสอบเวลาของ Deep Learning model ได้แก่ CNN, RNN และ ANN โดยใช้ Epochs เพื่อระบุจำนวนการวนซ้ำ ซึ่งถูกกำหนดเป็นเวลา 5 ถึง 10 Epochs โดยมีขนาดแบทช์เท่ากับ 64 และทำการเปิดใช้งานฟังก์ชันคือ Rectified Liner Unit (ReLU), Mean Squared Error (MSE) และ Adaptive Moment Estimation (Adam) เพื่อลดพารามิเตอร์ใน MSE ในการเตรียมข้อมูลสำหรับการฝึกอบรม ชุดข้อมูลที่เตรียมไว้จะถูกป้อนออกเป็น 2 เลเยอร์ ที่แตกต่างกัน โดยเลเยอร์ที่หนึ่ง คือ เลเยอร์ LSTM จะถูกป้อนข้อมูลลงในโมเดล RNN สำหรับอัลกอริทึมอื่น ข้อมูลจะถูกป้อนลงในเลเยอร์ Maxpool, Flatten และ Conv1D และข้อมูลจะถูกป้อนในโมเดล CNN ในส่วนการวิเคราะห์โมเดลการทดสอบเวลาของ Machine learning ได้แก่ RF และ K-NN เนื่องจากไม่มีความจำเป็นที่จะใช้ Epochs โมเดล RF จึงได้รับการฝึกอบรมเกี่ยวกับฟังก์ชันคอร์เนลพื้นฐานแนวรัศมี และ k-NN ได้รับการฝึกฝนโดยใช้ ค่า k เป็น 5 ค่าอัตราการเรียนรู้จะถูกนำมาเป็นค่าเริ่มต้น (0.01) หลังจากนำข้อมูลชุดทดสอบมาทำการทดสอบพบว่าเมื่อทำการเปรียบเทียบ CNN, RNN และ ANN ผลลัพธ์คือ CNN มีความเสถียรภาพ มากที่สุด โดยค่าความแม่นยำสูงถึง 99.7% และ MSE ต่ำถึง 0.000162046 เมื่อเปรียบเทียบระหว่าง K-NN และ RF ผลลัพธ์ที่ดีที่สุดคือ K-NN ซึ่งมีความ

แม่นยำ 100.02331% ค่า MSE ได้ 0.6374 ซึ่งมีค่าที่สูงมากเมื่อเทียบกับค่า MSE ของ RF ดังนั้นการทดลองแบบ CNN มีความสามารถในการคาดการณ์ที่ดีที่สุด

ใน ค.ศ. 2019 Valencia และคณะ [85] ได้ทำการศึกษาเชิงเปรียบเทียบเกี่ยวกับอัลกอริทึมที่ใช้ในการพยากรณ์ราคาคริปโทเคอร์เรนซี เพื่อหาอัลกอริทึมที่มีความแม่นยำในการพยากรณ์ราคาคริปโทเคอร์เรนซี โดยใช้เทคนิคเดียวกับเทคนิคที่ใช้ในการพยากรณ์ราคาบิตคอยน์ โดยสกุลเงินที่ใช้ในการศึกษาได้แก่ บิตคอยน์, อีเธอร์เลียม, รีปเปอร์ และไลท์คอยน์ ซึ่งการศึกษาจะใช้ข้อมูล 2 ส่วนได้แก่ ข้อมูลด้านการตลาด (Market Data) และข้อมูลจากสื่อสังคมออนไลน์ (Social Data) โดยได้ทำการเก็บรวบรวมข้อมูลในระหว่างวันที่ 16 กุมภาพันธ์ ค.ศ. 2018 ถึง 21 เมษายน ค.ศ. 2018 รวมระยะเวลาในการเก็บข้อมูลทั้งสิ้น 60 วัน ซึ่งในส่วนการรวบรวมข้อมูลข้อมูลด้านการตลาดนั้น ได้รวบรวมข้อมูลการแลกเปลี่ยนคริปโทเคอร์เรนซีจำนวน 65 รายการที่มีความนิยมสูงสุดด้วย API สาธารณะของเว็บไซต์ Cryptocompare.com โดยข้อมูลด้านการตลาดนั้นจะประกอบด้วย ราคาเปิด (Opening Price) ราคาสูงสุด (Highest Price) ราคาต่ำสุด (Lowest Price) ราคาปิด (Closing Price) และปริมาณการทำธุรกรรมในแต่ละช่วงของเวลา (Transaction Volume for Each Time-step) สำหรับในส่วนของการเก็บรวบรวมข้อมูลจากสื่อสังคมออนไลน์เป็นการรวบรวมจาก Twitter เป็นข้อมูลด้วยการใช้ twitter API ในการดึงข้อความทวีตหรือการรีทวีต จำนวนข้อความทวีตทั้งหมด 20,789,572 ข้อความ โดยเลือกจากหลักเกณฑ์ดังนี้ 1. ถูกสร้างขึ้นในช่วงระยะเวลาที่ทำการศึกษา 2. มีชื่อหรือสัญลักษณ์ของสกุลเงินใดสกุลเงินหนึ่งในข้อความทวีตหรือการแท็กข้อความ 3. เขียนด้วยภาษาอังกฤษ และ 4. ทวีตที่ซ้ำกันจะไม่ถูกนำมาวิเคราะห์ด้วยกระบวนการการวิเคราะห์ความรู้สึก (Sentiment Analysis) เพื่อวัดข้อความรู้สึกจากข้อความทวีตที่เกี่ยวข้องกับคริปโทเคอร์เรนซีด้วยการใช้เครื่องมือที่ชื่อว่า Valence Aware Dictionary and Sentiment Reasoner (VADER) ซึ่งเป็นเครื่องมือในการวิเคราะห์ความรู้สึกด้วยคำและกฎ ซึ่งเป็นไลบรารีในไพทอน (Python) จากข้อมูลที่ได้ทำการรวบรวมไว้นั้น ข้อมูลทั้งหมดจะถูกแบ่งข้อมูลแบบ Holdout Method คือ 70:30 โดย 70% จะใช้เป็นข้อมูลชุดสอน (Training Set) และอีก 30% จะถูกใช้เป็นข้อมูลชุดทดสอบ (Test Set) สำหรับการสร้างโมเดลเพื่อการพยากรณ์ราคาคริปโทเคอร์เรนซีจะใช้ไลบรารี Scikit-learn โดยทำการศึกษาเชิงเปรียบเทียบในอัลกอริทึม 3 อัลกอริทึมได้แก่ Multi-Layer Perceptron (MLPs), Support Vector Machine (SVM) และ Random Forests (RF) ภายหลังการสร้างโมเดลเพื่อการพยากรณ์ราคาคริปโทเคอร์เรนซีด้วยอัลกอริทึมเหล่านี้เสร็จผลลัพธ์ที่ได้คือ MLP เป็นอัลกอริทึมที่ให้ผลลัพธ์ในการพยากรณ์ราคาคริปโทเคอร์เรนซีที่ดีที่สุดในทุกสกุลเงินดิจิทัลที่ได้ศึกษา รองลงมาคืออัลกอริทึม SVM ที่เหมาะสมสำหรับการพยากรณ์ราคาคริปโทเคอร์เรนซีในสกุลบิตคอยน์ รีปเปอร์ และไลท์คอยน์ ในขณะที่อัลกอริทึม RF ใช้ได้ดีที่สุดในสกุลเงินบิตคอยน์และไลท์คอยน์ แต่ก็เป็นผลลัพธ์ที่ไม่น่าพอใจนัก

ในปี ค.ศ. 2019 Yiyang และ Yeze [86] ได้ทำการศึกษาเชิงเปรียบเทียบเกี่ยวกับการใช้ปัญญาประดิษฐ์ (Artificial Intelligence : AI) เพื่อสร้างโมเดลที่มีความแม่นยำในการพยากรณ์ราคาคริปโทเคอร์เรนซี โดยสกุลเงินที่ใช้ในการศึกษา ได้แก่ บิตคอยน์, อีเธอร์เลียม และรีปเปอร์ ซึ่งข้อมูลราคาคริปโทเคอร์เรนซีเหล่านี้ได้ถูกรวบรวมมาจากเว็บไซต์ <http://www.blocjchain.com/markets>

ในระหว่างวันที่ 7 สิงหาคม ค.ศ. 2015 จนถึงวันที่ 2 มิถุนายน ค.ศ. 2018 รวมระยะเวลาในการเก็บข้อมูลทั้งสิ้น 1,030 วัน โดยใช้ตัวแปร 3 ตัวของราคาคริปโทเคอร์เรนซีเหล่านี้ได้แก่ ราคาสูงสุด (Highest Price), ราคาต่ำสุด (Lowest Price) และราคาปิดตลาด (Closing Price) ในการสร้างโมเดลเพื่อพยากรณ์ราคาเปิดตลาด (Opening Price) ในสองถึงสามวันข้างหน้า หลังจากการเตรียมข้อมูลแล้ว เพื่อหลีกเลี่ยงปัญหา Over Fitting ระหว่างการสร้างโมเดลเพื่อการพยากรณ์ราคาเปิดตลาดของราคาคริปโทเคอร์เรนซี นักวิจัยได้ทำการแบ่งข้อมูล 80% จากข้อมูลทั้งหมดเป็นชุดสอน (Training) และใช้ข้อมูล 20% จากข้อมูลทั้งหมดเป็นข้อมูลชุดทดสอบ (Testing) อย่างไรก็ตาม ก่อนการสร้างโมเดลนักวิจัยได้ทำการตรวจสอบความชัดเจนของผันผวน (Sharp Fluctuations) ของราคาเปิดตลาดของราคาคริปโทเคอร์เรนซีเหล่านี้โดยพิจารณาจากประวัติของราคาเปิดตลาดร่วมกับส่วนเบี่ยงเบนมาตรฐาน (Standard Deviations) เพราะสิ่งเหล่านี้สามารถบ่งชี้ถึงความแม่นยำของโมเดลเพื่อการพยากรณ์ราคาเปิดตลาดของราคาคริปโทเคอร์เรนซีที่กำลังจะสร้างได้ จากข้อมูลที่ใช้ในการศึกษาพบว่าประวัติของราคาเปิดตลาดพบว่าค่าเฉลี่ยราคาเปิดตลาดของบิตคอยน์, อีเธอร์เลียม และริบเปอร์อยู่ที่ \$3082.084, \$194.810 และ \$0.223 ตามลำดับ และมีช่วงความเชื่อมั่น 95% ของราคาเปิดตลาดที่ผ่านมาคือ [2834.034, 3330.134], [176.977, 212.642] และ [0.196, 0.248] ตามลำดับ เมื่อนำข้อมูลที่ได้ดังกล่าวมาวิเคราะห์ความผันผวนและส่วนเบี่ยงเบนมาตรฐานพบว่าบิตคอยน์และอีเธอร์เลียมมีความผันผวนสูงมาก นั่นคือ 4,063 และ 292 ตามลำดับ แต่มีค่าเบี่ยงเบนมาตรฐานเท่ากันที่ 0.43 จากนั้นนักวิจัยได้ศึกษาเชิงเปรียบเทียบการสร้างโมเดลเพื่อการพยากรณ์ราคาเปิดตลาดของราคาคริปโทเคอร์เรนซีด้วยอัลกอริทึม 2 ตัว ได้แก่ Artificial Neural Network (ANN) และ Long-Short-Term-Memory (LSTM) ในการทดสอบโมเดลเพื่อการพยากรณ์ราคาเปิดตลาดของราคาคริปโทเคอร์เรนซีใน 7 วัน, 14 วัน, 21 วัน, 30 วัน และ 60 วันข้างหน้า โดยผลการทดลองแสดงให้เห็นว่า LSTM สามารถให้ประสิทธิภาพในเชิงค่าความถูกต้อง (Accuracy) ในการพยากรณ์ราคาเปิดตลาดของราคาคริปโทเคอร์เรนซีได้ดีกว่า ANN อย่างไรก็ตามนักวิจัยเชื่อว่าหากมีการเพิ่มจำนวนข้อมูลในชุดสอนมากขึ้น ANN ก็น่าที่จะให้ประสิทธิภาพใกล้เคียงกับ

ในปี ค.ศ. 2019 Chen และคณะ [87] ได้ทำการศึกษาเชิงเปรียบเทียบใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning: ML) สำหรับทำนายทิศทางของการเปลี่ยนแปลงราคาอีเธอร์เลียมเพื่อตอบคำถามที่ว่า “Will Ether increase in price tomorrow?” เนื่องจากข้อมูลในระหว่างวันที่ 30 สิงหาคม ค.ศ. 2017 จนถึง 19 ตุลาคม ค.ศ. 2019 พบว่าราคาของอีเธอร์เลียมมีความผันผวนสูงมากถึง 77.91% เมื่อเปรียบเทียบกับราคาของบิตคอยน์ ซึ่งความผันผวนดังกล่าวส่งผลต่อราคาขายของอีเธอร์เลียม สำหรับชุดข้อมูลที่ใช้ในการศึกษานี้ เป็นชุดข้อมูลราคาขายของอีเธอร์เลียมที่มีการสุ่มตัวอย่างในช่วงเวลา 1 ชั่วโมงในระหว่างวันที่ วันที่ 30 สิงหาคม ค.ศ. 2015 ถึง 2 ธันวาคม ค.ศ. 2017 โดยข้อมูลเหล่านี้ได้ถูกทดสอบด้านสถิติและมีการคำนวณน้อยที่สุด (Minimum) อยู่ที่ 0.41 ค่าราคาขายมากที่สุด (Maximum) อยู่ที่ 507.94 ส่วนค่ามัธยฐาน (Median) อยู่ที่ 11.7 และเมื่อแบ่งข้อมูลตามควอร์ไทล์ (Quartile: Q) พบว่าในควอร์ไทล์ที่ 1 (Q1) ราคาขายตรงกลางระหว่างจำนวนที่น้อยที่สุดและมัธยฐานของชุดข้อมูลอยู่ 7.81 ในขณะที่ในควอร์ไทล์ที่ 3 (Q3) ซึ่งเป็นราคาขายตรงกลางระหว่างมัธยฐานและจำนวนที่มากที่สุดมีค่าอยู่ 88.56 โดยมีค่าเฉลี่ยราคาขาย (Mean) และ

ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) คือ 79.4737 และ 122.95 ตามลำดับ จากข้อมูลทางสถิติที่แสดงให้เห็นถึงความแปรปรวนที่สูงมากของชุดข้อมูลนี้เอง ดังนั้นนักวิจัยจึงได้ตัดชุดข้อมูลบางส่วนออกไปตามคำแนะนำในงานวิจัยของ Bovaird (2017) ซึ่งจะเลือกเอาเฉพาะข้อมูลหลังวันที่ 26 กุมภาพันธ์ ค.ศ. 2017 เนื่องจากราคาอีเธอร์เลียมกำลังมีแนวโน้มสูงขึ้น เพราะได้รับการผลักดันโดยองค์กรด้านสกุลเงินที่ถูกเข้ารหัส ด้วยการกระทำดังกล่าวทำให้ส่วนเบี่ยงเบนมาตรฐานมีค่าลดลงเล็กน้อยคืออยู่ที่ 122.14 ในขณะที่ค่าเฉลี่ยราคาขายอยู่ที่ 220.0679 จากนั้นชุดข้อมูลที่ได้รับการปรับปรุงนี้ได้ถูกแบ่งออกเป็น 3 ส่วนคือ ชุดสอน: ชุดตรวจสอบ: ชุดทดสอบ ด้วยอัตราส่วน 80: 10: 10 หลังจากนั้นนักวิจัยได้ทดสอบนำข้อมูลไปสร้างโมเดลสำหรับการพยากรณ์ราคาของอีเธอร์เลียมด้วย Logistic Regression, Support Vector Machine, Random Forest, Naive Bayes. Autoregressive Integrated Moving Average (ARIMA), Recurrent Neural network (RNN) และ Neural Network (NN) โดยใช้เครื่องมือคือ Scikit-Learn จากผลการทดลองพบว่า ARIMA ให้ประสิทธิภาพในการพยากรณ์ราคาของอีเธอร์เลียมในข้อมูลชุดนี้มากที่สุดคือให้ค่าความถูกต้อง (Accuracy) อยู่ที่ 61.17% ในขณะที่ Random Forest ให้ประสิทธิภาพต่ำที่สุด โดยให้ค่าความถูกต้องที่ 50.81 % ซึ่งนักวิจัยได้สรุปว่าการที่ ARIMA ให้ประสิทธิภาพที่ดีที่สุดเนื่องจาก ARIMA มีคุณสมบัติที่เหมาะสมในการใช้งานกับข้อมูลอนุกรมเวลา.

ใน ค.ศ. 2019 Wirawan และคณะ [88] พบว่าราคาบิตคอยน์มีความผันผวนที่ไม่แน่นอน ซึ่งกระบวนการในการพยากรณ์ราคาบิตคอยน์จึงเป็นสิ่งที่จำเป็นในการพยากรณ์ราคาของบิตคอยน์ในอนาคต ซึ่งงานวิจัยนี้ได้รวบรวมข้อมูลจากเว็บไซต์ www.coingecko.com ในช่วงระหว่างวันที่ 1 พฤษภาคม ค.ศ. 2013 ถึงวันที่ 7 มิถุนายน ค.ศ. 2019 ที่จัดเก็บอยู่ในไฟล์รูปแบบ CSV ซึ่งมีจำนวนทั้งสิ้น 2,227 ระเบียบ โดยชุดข้อมูลประกอบไปด้วย 4 แอททริบิวต์ (Attribute) ได้แก่ Snapped_At, ราคา (Price), มูลค่าการตลาด (Market_Cap) และมูลค่าทั้งหมด (Total_Volume) สำหรับในกระบวนการสร้างแบบจำลองเพื่อการพยากรณ์ราคาของบิตคอยน์นั้นประกอบด้วย 3 ขั้นตอน โดยขั้นตอนแรกคือขั้นตอนของการเตรียมข้อมูล (Pre-processing) ซึ่งประกอบด้วย การกำจัดแอททริบิวต์ที่ไม่จำเป็นต่อการพยากรณ์ข้อมูลออกไป (Attribute Removal) เพราะอาจจะทำให้ประสิทธิภาพในการพยากรณ์ราคาบิตคอยน์ลดลงได้ ซึ่งในงานวิจัยนี้จะใช้แอททริบิวต์เพียง 2 ตัว ได้แก่ Snapped_At และ Price ในขณะที่แอททริบิวต์ Market_Cap และ Total_Volume ไม่ได้ถูกใช้กระบวนการพยากรณ์ราคาบิตคอยน์ จากนั้นจะทำการทดสอบข้อมูลอนุกรมเวลาที่มีคุณสมบัติคงที่ (Stationary Test) เนื่องจากงานวิจัยนี้ใช้แบบจำลอง ARIMA (Autoregressive Integrated Moving Average) ดังนั้นจึงต้องใช้การวิเคราะห์ข้อมูลอนุกรมเวลาที่มีคุณสมบัติคงที่ (Stationary) เข้ามาด้วย ในกรณีที่ข้อมูลอนุกรมเวลาที่ใช้ในการวิเคราะห์สมบัติไม่คงที่ (Nonstationary) จะต้องทำการแปลงข้อมูลอนุกรมเวลาดังกล่าวให้มีคุณสมบัติคงที่ก่อน โดยการหาผลต่างของข้อมูลอนุกรมเวลา (Differencing) หรือการหาค่า Natural logarithm ของอนุกรมเวลาก่อนที่จะนำข้อมูลนั้นไปสร้างแบบจำลอง ARIMA เมื่อเสร็จสิ้นในขั้นตอนของการเตรียมข้อมูลแล้วก็จะนำข้อมูลที่ได้ไปสร้างแบบจำลองการพยากรณ์ราคาบิตคอยน์ด้วยแบบจำลอง ARIMA โดยใน ARIMA จะมีฟังก์ชันสำคัญ 2 ตัว ในการสร้างกราฟเพื่อใช้ในการวิเคราะห์ คือ Autocorrelation Function (ACF) และ Partial


Autocorrelation Function (PACF) โดย ACF เป็นเป็นกราฟที่สร้างจากข้อมูลอนุกรมเวลา โดยนำค่าความสัมพันธ์ (Correlation) ของข้อมูลที่ถูกแบ่งเป็นส่วนๆ โดยแต่ละส่วนจะถูกแบ่งในช่วง k หน่วยเวลา ในขณะที่ PACF จะทำการวัดระดับความสัมพันธ์ที่เกิดขึ้นของพจน์อื่นๆ ที่จะนำมารวมไว้ในตัวแบบ โดยในการสร้างแบบจำลองการพยากรณ์บิตคอยน์ด้วย ARIMA นั้น จะมีการศึกษาใน 3 สถานการณ์ คือ

- สถานการณ์ที่ 1 จะใช้ข้อมูลชุดสอนที่เป็นข้อมูลในระหว่างวันที่ 1 พฤษภาคม ค.ศ. 2013 - 31 มีนาคม ค.ศ. 2019 (2,159 ระเบียบ) และข้อมูลชุดทดสอบที่เป็นข้อมูลในระหว่างวันที่ 1 เมษายน ค.ศ. 2019 - 7 เมษายน ค.ศ. 2019
- สถานการณ์ที่ 2 จะใช้ข้อมูลชุดสอนที่เป็นข้อมูลในระหว่างวันที่ 1 พฤษภาคม ค.ศ. 2013 ถึง 30 เมษายน ค.ศ. 2019 (2,189 ระเบียบ) และข้อมูลชุดทดสอบที่เป็นข้อมูลในระหว่างวันที่ 1 พฤษภาคม ค.ศ. 2019 ถึง 7 พฤษภาคม ค.ศ. 2019
- สถานการณ์ที่ 3 จะใช้ข้อมูลชุดสอนที่เป็นข้อมูลในระหว่างวันที่ 1 พฤษภาคม ค.ศ. 2019 ถึง 31 พฤษภาคม ค.ศ. 2019 (2,220 ระเบียบ) และข้อมูลชุดทดสอบที่เป็นข้อมูลในระหว่างวันที่ 1 มิถุนายน ค.ศ. 2019 ถึง 7 มิถุนายน ค.ศ. 2019

สำหรับการวัดประสิทธิภาพของแบบจำลองการพยากรณ์บิตคอยน์นั้น จะประเมินด้วยค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percent Error: MAPE) พบว่า

- ในสถานการณ์ที่ 1 แบบจำลอง ARIMA (5, 1, 6) จะให้ค่า MAPE ที่ต่ำที่สุด โดยให้ค่าเฉลี่ยอยู่ที่ 6.89
- สถานการณ์ที่ 2 แบบจำลอง ARIMA (4, 1, 4) จะให้ค่า MAPE ที่ต่ำที่สุด โดยให้ค่าเฉลี่ยอยู่ที่ 3.24
- สถานการณ์ที่ 3 แบบจำลอง ARIMA (4, 1, 4) จะให้ค่า MAPE ที่ต่ำที่สุด โดยให้ค่าเฉลี่ยอยู่ที่ 3.24

จากผลการทดสอบข้างต้น ทำให้แบบจำลอง ARIMA (4, 1, 4) ถูกเลือกเป็นโมเดลที่ดีที่สุดในการพยากรณ์ราคาบิตคอยน์สำหรับข้อมูลชุดนี้



บทที่ 3 วิธีดำเนินการวิจัย

การดำเนินงานวิจัยในบทนี้ผู้วิจัยได้นำเสนอรูปแบบการชุดข้อมูลที่นำมาใช้ในการทดสอบและขั้นตอนการดำเนินงานของการศึกษาเชิงเปรียบเทียบสำหรับกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซี ซึ่งจะมีกรอบดำเนินงานดังนี้

3.1 ชุดข้อมูล

ชุดข้อมูลที่ใช้ในการศึกษาเป็นชุดข้อมูลมาตรฐานจากเว็บไซต์ <https://cryptocompare.com/> ซึ่งเป็นข้อมูลการซื้อขายคริปโทเคอร์เรนซีในช่วงเวลา 1 วัน ระหว่างวันที่ 13 สิงหาคม ค.ศ. 2016 ถึง 3 มกราคม ค.ศ. 2022 หน่วยสกุลเงินที่ใช้ในการซื้อขาย คือ ดอลลาร์สหรัฐ (USD) โดยรายละเอียดของข้อมูลแต่ละชุดที่จะใช้ในการศึกษา แสดงในตารางที่ 2

รูปที่ 10, รูปที่ 11 และรูปที่ 12 แสดงตัวอย่างข้อมูลของบิตคอยน์ อีเธอร์เลียม และ ลایتคอยน์ ตามลำดับ

	High	Low	Open	Close	Volume	Adj Close
Date						
2014-09-17	468.174011	452.421997	465.864014	457.334015	21056800	457.334015
2014-09-18	456.859985	413.104004	456.859985	424.440002	34483200	424.440002
2014-09-19	427.834991	384.532013	424.102997	394.795990	37919700	394.795990
2014-09-20	423.295990	389.882996	394.673004	408.903992	36863600	408.903992
2014-09-21	412.425995	393.181000	408.084991	398.821014	26580100	398.821014
...	...	...	...	...	...	...
2022-08-23	21646.203125	20955.138672	21401.044922	21528.087891	31878280659	21528.087891
2022-08-24	21783.076172	21195.005859	21526.455078	21395.019531	31962253368	21395.019531
2022-08-25	21789.636719	21362.441406	21395.458984	21600.904297	31028679593	21600.904297
2022-08-26	21804.908203	20199.482422	21596.085938	20260.019531	42326789564	20260.019531
2022-08-27	20334.722656	20036.839844	20236.427734	20236.988281	43909636096	20236.988281

2902 rows × 6 columns

รูปที่ 10 ตัวอย่างข้อมูลบิตคอยน์

ตารางที่ 2 รายละเอียดของข้อมูลที่ใช้ในการศึกษา

ชื่อชุดข้อมูล	จำนวนข้อมูล (ระเบียน)	จำนวนตัวแปรทั้งหมด	ชื่อตัวแปร	ความหมาย
Bitcoin (BTC)	2,902 (2015-2022)	7	Date	วันและเวลาที่บันทึกข้อมูล
			Opening Trade (Open)	ราคาเปิดตลาด
			Highest Trade During Day (High)	ราคาซื้อขายสูงสุดระหว่างวัน
			Lowest Trade During Day (Low)	ราคาซื้อขายต่ำสุดระหว่างวัน
			Total Trade Volume for Day (Volume)	ปริมาณการซื้อขายทั้งหมดของวัน
			Close Price (Close)	ราคาปิดตลาด
			Adjusted Close Price (Adj. Close)	ราคาปิดที่ถูกรับแล้ว
Ethereum (ETH)	1,753 (2017-2022)	7	Date	วันและเวลาที่บันทึกข้อมูล
			Opening Trade (Open)	ราคาเปิดตลาด
			Highest Trade During Day (High)	ราคาซื้อขายสูงสุดระหว่างวัน
			Lowest Trade During Day (Low)	ราคาซื้อขายต่ำสุดระหว่างวัน
			Total Trade Volume for Day (Volume)	ปริมาณการซื้อขายทั้งหมดของวัน
			Close Price (Close)	ราคาปิดตลาด
			Adjusted Close Price (Adj. Close)	ราคาปิดที่ถูกรับแล้ว
Litecoin (LTC)	2,568 (2015-2022)	7	Date	วันและเวลาที่บันทึกข้อมูล
			Opening Trade (Open)	ราคาเปิดตลาด
			Highest Trade During Day (High)	ราคาซื้อขายสูงสุดระหว่างวัน
			Lowest Trade During Day (Low)	ราคาซื้อขายต่ำสุดระหว่างวัน
			Total Trade Volume for Day (Volume)	ปริมาณการซื้อขายทั้งหมดของวัน
			Close Price (Close)	ราคาปิดตลาด
			Adjusted Close Price (Adj. Close)	ราคาปิดที่ถูกรับแล้ว

	High	Low	Open	Close	Volume	Adj Close
Date						
2017-11-09	14.496100	13.896400	13.977200	14.209500	129201000	14.209500
2017-11-10	15.353500	13.917800	14.188300	14.603100	299856992	14.603100
2017-11-11	19.813299	14.590800	14.624500	19.420900	958982016	19.420900
2017-11-12	21.754101	15.036500	19.461100	15.183700	697452992	15.183700
2017-11-13	16.662600	14.469700	15.309400	16.105900	350880000	16.105900
...	...	...	...	...	...	...
2022-08-23	34.606216	32.382393	34.015045	34.297916	912497079	34.297916
2022-08-24	36.629528	33.036243	34.296329	35.309185	1125022262	35.309185
2022-08-25	37.972614	35.312546	35.312546	37.132900	1316217518	37.132900
2022-08-26	38.154541	33.677547	37.132378	33.887104	1657422977	33.887104
2022-08-27	34.325584	33.640633	33.943428	34.114162	1673225728	34.114162

1753 rows × 6 columns

รูปที่ 11 ตัวอย่างข้อมูลอีเธอร์เลียม


	High	Low	Open	Close	Volume	Adj Close
Date						
2015-08-17	4.034990	3.935340	3.963320	3.983960	2289060	3.983960
2015-08-18	3.999570	3.437700	3.983680	3.469710	3464380	3.469710
2015-08-19	3.619150	3.358540	3.479650	3.477820	5742670	3.477820
2015-08-20	3.624970	3.470810	3.470810	3.605090	2882900	3.605090
2015-08-21	3.643090	3.548290	3.600230	3.565020	1720630	3.565020
...	...	...	...	...	...	...
2022-08-23	57.581665	54.280712	57.246269	57.079433	524532444	57.079433
2022-08-24	57.463272	55.827904	57.077991	56.478168	471510182	56.478168
2022-08-25	57.368172	56.088352	56.475605	56.792576	432646387	56.792576
2022-08-26	57.959911	52.514240	56.782242	52.744450	567680603	52.744450
2022-08-27	52.960693	52.149017	52.749493	52.607841	578177664	52.607841

2568 rows × 6 columns

รูปที่ 12 ตัวอย่างข้อมูลไลท์คอยน์

3.2 กรอบการดำเนินงาน

ในส่วนนี้เป็นการแสดงภาพรวมในการดำเนินงานวิจัย โดยสามารถแสดงได้ดังรูปที่ 13



รูปที่ 13 กรอบการดำเนินงานในการศึกษา

จากรูปที่ 13 จะเห็นภาพรวมของกระบวนการในการดำเนินงานวิจัยของการศึกษา การเชิงเปรียบเทียบสำหรับกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซี กระบวนการนำเสนอจะแบ่งการทำงานเป็น 3 ส่วนหลัก ได้แก่ ขั้นตอนการเตรียมข้อมูล ขั้นตอนการสร้างโมเดลเพื่อพยากรณ์ และการวัดประสิทธิภาพโมเดล

3.2.1 การเตรียมข้อมูล (Data Preparation)

เนื่องจากข้อมูลที่นำมาใช้เป็นข้อมูลที่สมบูรณ์ ไม่มีการสูญหายของข้อมูล ดังนั้นในขั้นตอนการเตรียมข้อมูลจึงประกอบด้วย 3 ขั้นตอน คือ การเลือกคุณลักษณะ การทำนอร์มอลไลเซชันข้อมูล และการแปลงข้อมูล (Data Transformation)

3.2.1.1 การเลือกคุณลักษณะ (Feature Selection)

สำหรับขั้นตอนของการเลือกคุณลักษณะหรือตัวแปรสำหรับการพยากรณ์ (Predictive Variables) ซึ่งในการศึกษานี้ การเลือกคุณลักษณะหรือตัวแปรสำหรับการพยากรณ์นี้จะอ้างอิงมาจากการวิจัยก่อนหน้า [10, 43, 44] สำหรับการเลือกคุณสมบัติจะพิจารณาคุณสมบัติที่มีความเกี่ยวข้องมากที่สุด เนื่องจากคุณสมบัติบางประการอาจจะส่งผลทำให้ประสิทธิภาพของการพยากรณ์ลดลง ซึ่งจะใช้คุณลักษณะหรือตัวแปรสำหรับการพยากรณ์ 4 ตัว เพื่อสร้างโมเดลเพื่อการพยากรณ์ (Predictive Model) ได้แก่ Opening Trade (Open), Highest Trade During Day (High), Lowest Trade During Day (Low) และ Total Trade Volume for Day (Volume)

3.2.1.2 การทำนอร์มอลไลเซชันข้อมูล

การทำนอร์มอลไลเซชันข้อมูล คือ ปรับค่าข้อมูลให้เหมาะสมต่อการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดของคริปโตเคอเรนซี ในที่นี้จะศึกษาใน 3 วิธีการ ได้แก่

(1) การปรับค่าข้อมูลด้วยลอการิทึม (Log scaling)

การปรับค่าข้อมูลด้วยลอการิทึมมีสมการดังนี้

$$\acute{x} = \log(x) \quad (3.1)$$

โดยค่า x คือ ค่า (Value) ที่อยู่ในคุณลักษณะหนึ่ง ๆ

สามารถยกตัวอย่างการปรับค่าข้อมูลด้วยลอการิทึมได้ดังตารางที่ 3 แสดงค่าการปรับค่าข้อมูลด้วยลอการิทึม

ตารางที่ 3 ตัวอย่างการปรับค่าข้อมูลด้วยลอการิทึม

Day	Original Value in 'Open' Variable	New Value in 'Open' Variable
1	\$112.3	2.050379756
2	\$108.4	2.035029282
3	\$148.9	2.172894698
4	\$117.4	2.069668097

(2) การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด (Min-Max Scaling)

การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด [39, 41] เป็นการแปลงเชิงเส้นของข้อมูลที่ไม่มีโครงสร้างเดิม มันปรับขนาดข้อมูลจาก 0 ถึง 1 โดยมีสมการดังนี้

$$\acute{x} = \frac{(X - X_{min})}{X_{max} - X_{min}} \quad (3.2)$$

โดยค่า x คือ ค่า (Value) ที่อยู่ในคุณลักษณะหนึ่ง ๆ

จากข้อมูลตารางที่ 4 ค่าที่ปรากฏในค่าดั้งเดิมของตัวแปร 'Open' สามารถไปได้ค่า Min และค่า Max ได้ 108.40 และ 148.90 ตามลำดับ ดังนั้นสามารถแสดงยกตัวอย่างการปรับค่าข้อมูลแบบต่ำสุด-สูงสุดได้ดังตารางที่ 4

ตารางที่ 4 ตัวอย่างการปรับค่าข้อมูลแบบต่ำสุด-สูงสุด

Day	Original Value in 'Open' Variable	New Value in 'Open' Variable
1	\$112.3	0.0963
2	\$108.4	0
3	\$148.9	1
4	\$117.4	0.2222

(3) การปรับค่าข้อมูลแบบซี-สกอร์ (Z-score)

การปรับค่าข้อมูลแบบซี-สกอร์ [39, 41, 42] เป็นวิธีการปรับค่าที่ใช้ประโยชน์จากค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) จากค่าเฉลี่ย (Mean) โดยมีสมการดังนี้

$$\hat{x} = \frac{x - \mu}{SD} \quad (3.3)$$

โดยค่า x คือ ค่าคุณลักษณะ ขณะที่ μ คือ ค่าเฉลี่ย และ SD คือค่าเบี่ยงเบนมาตรฐาน

จากข้อมูลตารางที่ 5 สามารถคำนวณค่าเบี่ยงเบนมาตรฐานและค่าเฉลี่ยได้ 15.9966 และ 121.75 ตามลำดับ ดังนั้นสามารถแสดงยกตัวอย่างการปรับค่าข้อมูลแบบซี-สกอร์ได้ดังตารางที่ 5

ตารางที่ 5 ตัวอย่างการปรับค่าข้อมูลแบบ Z-score

Day	Original Value in 'Open' Variable	New Value in 'Open' Variable
1	\$112.3	-0.591
2	\$108.4	-0.835
3	\$148.9	1.697
4	\$117.4	-0.272

เมื่อค่าของ Z-score สูงกว่า 0 แสดงว่าค่าตัวอย่างอยู่เหนือค่าเฉลี่ย และเมื่อค่า Z-scores ต่ำกว่า 0 แสดงว่าค่าตัวอย่างต่ำกว่าค่าเฉลี่ย

3.2.2 การแปลงข้อมูล (Data Transformation)

ขั้นตอนนี้เป็นขั้นตอนการแปลงข้อมูลให้เหมาะสมกับการนำไปสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโทเคอร์เรนซี ซึ่งหากเป็นการนำข้อมูลไปสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโทเคอร์เรนซีด้วยอัลกอริทึมการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Machine Learning) ข้อมูลจะถูกจัดอยู่ในรูปแบบเวกเตอร์ แต่หากนำข้อมูลไปสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโทเคอร์เรนซีด้วยอัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning) ข้อมูลจะถูกจัดอยู่ในรูปแบบ Sequence

3.2.3 การสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโทเคอร์เรนซี

(Developing of Predicative Models)

เบื้องต้นในขั้นตอนนี้จะเป็นการใช้ข้อมูลชุดสอน (Training Set) เพื่อสร้างตัวพยากรณ์ราคาปิดคริปโทเคอร์เรนซี โดยจะเป็นการศึกษาเชิงเปรียบเทียบในอัลกอริทึม 2 รูปแบบ คือ อัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) และอัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning) ซึ่งอัลกอริทึมที่เลือกในการศึกษาค้างนี้ ได้แก่

3.2.3.1 กระบวนการบนพื้นฐานของการเรียนรู้ของเครื่อง (Machine Learning based Approach) โดยในส่วนของอัลกอริทึมการเรียนรู้ของเครื่องมีการเปรียบเทียบ 3 อัลกอริทึม ได้แก่

1. Support Vector Regression (SVR)
2. Artificial Neural Networks (ANNs)
3. Kernel Regression (KR)

3.2.3.2 กระบวนการบนพื้นฐานของการเรียนรู้เชิงลึก (Deep Learning based Approach) โดยในส่วนของอัลกอริทึมการเรียนรู้ของเครื่องมีการเปรียบเทียบ 2 อัลกอริทึม ได้แก่

1. Gated Recurrent Unit (GRU)
2. Long Short-Term Memory (LSMT)

3.3 การตั้งค่าทดลอง (Experimental Setup)

ในการศึกษาี้ จะทำการศึกษาใน 3 รูปแบบคือ

3.3.1 ใช้ 7 วันในการสร้างโมเดลเพื่อการพยากรณ์เพื่อพยากรณ์ราคาปิดในวันที่ 8 (7-day prediction period) ซึ่งสามารถได้ดังรูปที่ 14

Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day 10	Day 11
Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day 10	Day 11

Train
 Test

รูปที่ 14 7-day prediction period

3.3.2 ใช้ 14 วันในการสร้างโมเดลเพื่อการพยากรณ์เพื่อพยากรณ์ราคาปิดในวันที่ 15 (14-day prediction period) ซึ่งสามารถได้ดังรูปที่ 15

Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day 10
Day 11	Day 12	Day 13	Day 14	Day 15	Day 16	Day 17	Day 18		
Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day 10
Day 11	Day 12	Day 13	Day 14	Day 15	Day 16	Day 17	Day 18		

Train
 Test

รูปที่ 15 14-day prediction period

3.3.3 ใช้ 30 วันในการสร้างโมเดลเพื่อการพยากรณ์เพื่อพยากรณ์ราคาปิดในวันที่ 31 (30-day prediction period) ซึ่งสามารถได้ดังรูปที่ 16

Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day 10
Day 11	Day 12	Day 13	Day 14	Day 15	Day 16	Day 17	Day 18	Day 19	Day 20
Day 21	Day 22	Day 23	Day 24	Day 25	Day 26	Day 27	Day 28	Day 29	Day 30
Day 31	Day 32	Day 32							
Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7	Day 8	Day 9	Day 10
Day 11	Day 12	Day 13	Day 14	Day 15	Day 16	Day 17	Day 18	Day 19	Day 20
Day 21	Day 22	Day 23	Day 24	Day 25	Day 26	Day 27	Day 28	Day 29	Day 30
Day 31	Day 32	Day 32							

Train
 Test

รูปที่ 16 30-day prediction period

3.3 การตั้งค่าอัลกอริทึมสำหรับการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโตเคอเรนซ์

3.4.1 การตั้งค่าอัลกอริทึม SVR สำหรับการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโตเคอเรนซ์ดังนี้

1. มีการใช้ฟังก์ชันเคอร์เนลด้วย RBF
2. กำหนดค่า C คือ 1,000
3. กำหนดค่า Gamma คือ 0.0001
4. กำหนดค่า Epsilon คือ 0.1
5. กำหนดค่า Window Length คือ 7, 14 และ 30 ตามลำดับ

3.4.2 การตั้งค่าอัลกอริทึม ANN สำหรับการสร้างโมเดลเพื่อการพยากรณ์ราคาปิดคริปโตเคอเรนซ์ดังนี้

1. จำนวนของ Input Layer คือ 20 neurons
2. กำหนดค่า Dropout คือ 0.2
3. ฟังก์ชัน Activation คือ Rectified Linear Unit (ReLU)
4. Batch Size คือ 2
5. Optimizer คือ Rmsprop
6. Loss Function คือ MSE
7. กำหนดค่า Window Length คือ 7, 14 และ 30 ตามลำดับ
8. จำนวน Epochs คือ 20

3.4.3 การตั้งค่าอัลกอริทึม LSTM และ GRU สำหรับการสร้างโมเดลเพื่อการพยากรณ์

1. จำนวนของ Input Layer คือ 100 neurons
2. จำนวนของ Dense ของ Output Layer คือ 1
3. กำหนดค่า Dropout คือ 0.2
4. ฟังก์ชัน Activation คือ Rectified Linear Unit (ReLU)
5. Batch Size คือ 32
6. Optimizer คือ Adam
7. Loss Function คือ MSE
8. กำหนดค่า Window Length คือ 7, 14 และ 30 ตามลำดับ
9. จำนวน Epochs คือ 20

บทที่ 4 ผลการศึกษา

4.1 ตัวอย่างการคำนวณค่าของ RMSE, MAPE และ R-Square

4.1.1 รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE) โดยมีสมการดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$$

โดยที่ n คือ จำนวนข้อมูล
 y_t คือ ค่าจริง
 $\hat{y}_t$ คือ ค่าทำนาย

โดยสามารถยกตัวอย่างการหาค่า RMSE ได้ดังนี้ สมมติว่าตารางที่ 6 แสดงค่าของข้อมูลจริง และค่าของข้อมูลที่เกิดจากการทำนาย

ตารางที่ 6 ตัวอย่างการคำนวณ RMSE

Month	Actual	Predict	predict-actual	(predict-actual) ²	(predict-actual) ² /n
1	\$112.3	\$124.7	12.4	153.76	38.44
2	\$108.4	\$103.7	-4.7	22.09	5.5225
3	\$148.9	\$116.6	-32.3	1,043.29	260.8225
4	\$117.4	\$78.5	-38.9	1,513.21	378.3025
Sum					683.0875
RMSE					26.13594

4.1.2 ข้อผิดพลาดสมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error: MAPE) โดยมีสมการดังนี้

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \times 100$$

โดยที่ n คือ จำนวนข้อมูล
 y_t คือ ค่าจริง
 $\hat{y}_t$ คือ ค่าทำนาย

โดยสามารถยกตัวอย่างการหาค่า MAPE ได้ดังนี้ สมมติว่าตารางที่ 7 แสดงค่าของข้อมูลจริง และค่าของข้อมูลที่เกิดจากการทำนาย

ตารางที่ 7 ตัวอย่างการคำนวณ MAPE

Month	Actual	Predict	actual- predict	(actual- predict)/ actual	(actual-predict)/ actual*100
1	\$112.3	\$124.7	-12.4	0.110418522	11.04185218
2	\$108.4	\$103.7	4.7	0.043357934	4.335793358
3	\$148.9	\$116.6	32.3	0.21692411	21.69241101
4	\$117.4	\$78.5	38.9	0.331345826	33.13458262
MAPE					17.55115979

4.1.3 สัมประสิทธิ์การตัดสินใจ (Coefficients of Determination: R-Square) โดยมีสมการดังนี้

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

โดยที่ y_t คือ ค่าจริง

$\bar{y}$ คือ ค่าการคาดคะเน

โดยสามารถยกตัวอย่างการหาค่า R-Square ได้ดังนี้ สมมติว่าตารางที่ 8 แสดงค่าของข้อมูลจริง และค่าของข้อมูลที่เกิดจากการทำนาย

ตารางที่ 8 ตัวอย่างการคำนวณ R-Square

Month	Actual	Predict	Actual ²	Predict ²	Actual* Predict	$[(n\sum \text{Actual}*\text{Predict} - (\sum \text{Actual})(\sum \text{Predict})/\sqrt{n\sum \text{Actual}^2 - (\sum \text{Actual})^2} * \sqrt{n\sum \text{Predict}^2 - (\sum \text{Predict})^2})]^2$
1	\$112.3	\$124.7	12611.29	15550.09	237	(0.2336) ²
2	\$108.4	\$103.7	11750.56	10753.69	212.1	
3	\$148.9	\$116.6	22171.21	13595.56	265.5	
4	\$117.4	\$78.5	13782.76	6162.25	195.9	
SUM	487	423.5	60316	46062	910.5	
R-Square						0.0546

4.2 ผลการทดลอง

ภายหลังจากที่ได้ทำการทดลองเบื้องต้นด้วยอัลกอริทึม SVR, ANNs, KR, LSTM และ GRU ได้ผลการทดลองด้วย RMSE, MAPE และ R-Square สำหรับการวิเคราะห์ผลจะใช้เว็บไซต์ Colaboratory หรือ Colab ซึ่งเป็นการเรียกใช้ Python บนเว็บเบราว์เซอร์ ดังต่อไปนี้

ตารางที่ 9 ผลการพยากรณ์ราคาบิตคอยน์แบบ 7-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.1040	6.6598	-0.1657
	Log Scaling	0.0581	9.2951	0.8040
	Min-max	0.0570	9.7853	0.6680
	Z-score	0.0436	7.6719	0.8307
Average Scores of the SVR models		0.0657	8.3530	0.5343
ANNs	Non-normalization	0.1753	27.3149	-2.3144
	Log Scaling	0.1587	23.3410	-1.7142
	Min-max	0.0913	4.6586	0.1012
	Z-score	0.1138	14.5212	-0.3954
Average Scores of the ANNs models		0.1348	17.4589	-1.0807
KR	Non-normalization	0.1113	4.6290	-0.1877
	Log Scaling	0.0426	9.3143	0.7824
	Min-max	0.0555	9.8945	0.6935
	Z-score	0.0396	7.8001	0.8556
Average Scores of the KR models		0.0623	7.9095	0.5360
LSTM	Non-normalization	0.0992	3.8441	-0.0617
	Log Scaling	0.0548	5.6465	-0.1265
	Min-max	0.0553	7.7008	0.6843
	Z-score	0.1611	5.6445	0.8515
Average Scores of the LSTM models		0.0926	5.7090	0.3369
GRU	Non-normalization	557190	251676	-3.3452
	Log Scaling	0.1110	8.8262	-0.1917
	Min-max	0.0568	5.4055	0.6433
	Z-score	0.0558	4.0231	0.8392
Average Scores of the GRU models		139297.56	62923.56	-0.5136

ตารางที่ 10 ผลการพยากรณ์ราคาอีเธอร์เลียมแบบ 7-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.1271	1.5987	-0.1388
	Log Scaling	0.0567	9.1547	0.8241
	Min-max	0.0555	9.8691	0.6475
	Z-score	0.0426	9.3016	0.8313

ตารางที่ 10 (ต่อ)

Average Scores of the SVR models		0.0705	7.4810	0.5410
ANNs	Non-normalization	0.1892	4.6606	-1.5212
	Log Scaling	0.2552	7.2720	-3.5869
	Min-max	0.1185	1.7541	0.0104
	Z-score	0.2517	7.1581	-3.4632
Average Scores of the ANNs models		0.2037	5.2112	-2.1402
KR	Non-normalization	0.1359	17.5508	-0.1586
	Log Scaling	0.0499	1.1489	0.8548
	Min-max	0.0707	1.9283	0.6681
	Z-score	0.0489	1.0261	0.8604
Average Scores of the KR models		0.0764	5.4135	0.5562
LSTM	Non-normalization	0.1236	1.3334	-0.0765
	Log Scaling	0.0681	1.5899	-0.1023
	Min-max	0.0679	1.6810	0.6813
	Z-score	0.1408	2.4585	0.8545
Average Scores of the LSTM models		0.1001	1.7657	0.3393
GRU	Non-normalization	384481	111015	-926912
	Log Scaling	0.1729	4.4270	0.5077
	Min-max	0.1113	2.1584	0.6829
	Z-score	0.1015	1.8832	0.8436
Average Scores of the GRU models		96120.35	27755.87	-231727.5

ตารางที่ 11 ผลการพยากรณ์ราคาหลักทรัพย์แบบ 7-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.1500	6.2772	-0.2362
	Log Scaling	0.0767	5.4765	0.8224
	Min-max	0.0758	5.0846	0.6849
	Z-score	0.0569	1.8768	0.8423
Average Scores of the SVR models		0.0899	4.6788	0.5284
ANNs	Non-normalization	0.2149	16.3630	-1.5368
	Log Scaling	0.2433	19.8963	-2.2500
	Min-max	0.1234	7.9987	0.1634
	Z-score	0.2177	15.1945	-1.6032
Average Scores of the ANNs models		0.1998	14.8631	-1.3067

ตารางที่ 11 (ต่อ)

KR	Non-normalization	0.1599	5.3007	-0.2381
	Log Scaling	0.0568	1.8681	0.8422
	Min-max	0.0757	5.1020	0.7195
	Z-score	0.0535	2.1084	0.8618
Average Scores of the KR models		0.0865	3.5948	0.5464
LSTM	Non-normalization	0.1398	3.5237	-0.0734
	Log Scaling	0.0825	3.5091	-0.3849
	Min-max	0.0837	3.6906	0.6043
	Z-score	0.1657	10.4716	0.8502
Average Scores of the LSTM models		0.1179	5.2988	0.2491
GRU	Non-normalization	16356.5	663020	-129452
	Log Scaling	0.1395	5.8750	0.1252
	Min-max	0.0794	2.1819	0.3109
	Z-score	0.0847	2.2618	0.8515
Average Scores of the GRU models		4089.201	165757.6	-32362.7

ตารางที่ 12 ผลการพยากรณ์ราคาบิตคอยน์แบบ 14-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.1509	2.6860	-0.2920
	Log Scaling	0.0688	7.3779	0.7442
	Min-max	0.0650	6.6449	0.7711
	Z-score	0.0675	5.6152	0.9135
Average Scores of the SVR models		0.0881	5.5810	0.5342
ANNs	Non-normalization	0.5391	20.3198	-15.4839
	Log Scaling	0.7537	29.0357	-31.2152
	Min-max	0.0872	5.3865	0.1806
	Z-score	0.6811	24.6751	-25.3085
Average Scores of the ANNs models		0.5153	19.8543	-17.9568
KR	Non-normalization	1.9950	11.9903	-55.3905
	Log Scaling	0.0671	2.4670	0.7521
	Min-max	0.0635	1.5101	0.7784
	Z-score	0.0390	1.0086	0.9195
Average Scores of the KR models		0.5412	4.2440	-13.2351

ตารางที่ 12 (ต่อ)

LSTM	Non-normalization	0.1460	2.3048	-0.2101
	Log Scaling	0.1870	6.4709	-0.4517
	Min-max	0.0630	4.7685	-1.0277
	Z-score	0.0647	4.3052	0.9232
Average Scores of the LSTM models		0.1152	4.4624	-0.1916
GRU	Non-normalization	244416	278387	-3.3876
	Log Scaling	0.1861	7.3669	0.7747
	Min-max	0.0638	4.6479	0.7772
	Z-score	0.0698	2.7881	0.9213
Average Scores of the GRU models		61104.08	69600.45	-0.2286

ตารางที่ 13 ผลการพยากรณ์ราคาอีเธอร์เลียมแบบ 14-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.1876	2.3316	-0.2668
	Log Scaling	0.0687	7.3767	0.8873
	Min-max	0.0650	6.6378	0.7532
	Z-score	0.0677	5.5187	0.9099
Average Scores of the SVR models		0.0973	5.4662	0.5709
ANNs	Non-normalization	0.6384	14.7354	-13.6715
	Log Scaling	0.5853	15.3463	-11.3314
	Min-max	0.4259	7.5375	-5.5301
	Z-score	0.6265	13.4972	-13.1279
Average Scores of the ANNs models		0.5690	12.7791	-10.9152
KR	Non-normalization	0.1962	2.4619	-0.2824
	Log Scaling	0.0559	1.1984	0.8951
	Min-max	0.0827	1.3623	0.7661
	Z-score	0.0500	1.0547	0.9215
Average Scores of the KR models		0.0962	1.5193	0.5751
LSTM	Non-normalization	0.1747	1.5546	-0.0994
	Log Scaling	0.2852	6.2654	-0.3775
	Min-max	0.0824	2.2289	0.7716
	Z-score	0.1060	1.8410	0.9223
Average Scores of the LSTM models		0.1621	2.9725	0.3043

ตารางที่ 13 (ต่อ)

GRU	Non-normalization	226633	29759	-184873
	Log Scaling	0.1596	1.4034	0.4228
	Min-max	0.1921	2.6660	0.7077
	Z-score	0.1518	1.2629	0.9214
Average Scores of the GRU models		56658.38	7441.083	-46217.7

ตารางที่ 14 ผลการพยากรณ์ราคาหลักทรัพย์แบบ 14-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.2068	2.8482	-0.2974
	Log Scaling	0.0701	0.8524	0.8656
	Min-max	0.0871	1.2104	0.7725
	Z-score	0.0929	1.4703	0.9084
Average Scores of the SVR models		0.2068	2.8482	-0.2974
ANNs	Non-normalization	0.6210	16.6602	-10.6905
	Log Scaling	0.4960	12.8952	-6.4583
	Min-max	0.7353	20.0389	-15.3899
	Z-score	0.7288	16.4899	-15.1025
Average Scores of the ANNs models		0.6453	16.5211	-11.9103
KR	Non-normalization	0.2129	3.3145	-0.3092
	Log Scaling	0.0665	1.3173	0.8582
	Min-max	0.0866	1.9011	0.7806
	Z-score	0.0549	1.0822	0.9107
Average Scores of the KR models		0.1052	1.9038	0.5601
LSTM	Non-normalization	0.1019	1.5234	-0.0026
	Log Scaling	0.1202	2.5706	0.7332
	Min-max	0.0961	2.1071	0.6178
	Z-score	0.0909	1.7000	0.8999
Average Scores of the LSTM models		0.1023	1.9753	0.5634
GRU	Non-normalization	59906.34	96156	-103639
	Log Scaling	0.0913	1.8146	0.9081
	Min-max	0.1095	2.2368	0.5974
	Z-score	0.1414	1.5876	0.9147
Average Scores of the GRU models		14976.67	24040.41	-25909.1

ตารางที่ 15 ผลการพยากรณ์ราคาบิตคอยน์แบบ 30-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.2431	3.7568	-0.5426
	Log Scaling	0.0961	1.7146	3.0551
	Min-max	0.0784	1.5534	0.8388
	Z-score	0.1180	3.3016	0.9535
Average Scores of the SVR models		0.1339	2.5816	1.0762
ANNs	Non-normalization	2.9440	85.7425	-225.1922
	Log Scaling	2.2151	64.2302	-127.0546
	Min-max	2.6158	75.3834	-177.5699
	Z-score	2.9515	80.1723	-226.3408
Average Scores of the ANNs models		2.6816	76.3821	-189.0394
KR	Non-normalization	0.2489	4.8598	-0.5542
	Log Scaling	0.1099	3.0551	0.7452
	Min-max	0.0785	1.5724	0.8403
	Z-score	0.0421	0.7868	0.9575
Average Scores of the KR models		0.1199	2.5685	0.4972
LSTM	Non-normalization	0.2181	2.4728	-0.2423
	Log Scaling	0.0947	1.0703	-3.0309
	Min-max	0.0909	1.6490	0.8140
	Z-score	0.3907	9.8327	0.9646
Average Scores of the LSTM models		0.1986	3.7562	-0.3736
GRU	Non-normalization	389230	123155	-3.9535
	Log Scaling	0.6006	16.5899	0.7901
	Min-max	0.0860	1.3013	0.8546
	Z-score	0.0788	1.2463	0.9660
Average Scores of the GRU models		97307.69	30793.53	-0.3357

ตารางที่ 16 ผลการพยากรณ์ราคาอีเธอร์เลียมแบบ 30-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.3077	10.0422	-0.4567
	Log Scaling	0.0728	4.4582	0.9184
	Min-max	0.1071	12.0476	0.8235
	Z-score	0.0552	4.0183	0.9530

ตารางที่ 16 (ต่อ)

Average Scores of the SVR models		0.1357	7.6415	0.5595
ANNs	Non-normalization	3.1058	244.2308	-147.3884
	Log Scaling	3.1784	250.0681	-154.4012
	Min-max	2.2021	125.1130	-73.5944
	Z-score	2.6446	178.3357	-106.5869
Average Scores of the ANNs models		2.782725	199.4369	-120.493
KR	Non-normalization	0.3154	2.7919	-0.4705
	Log Scaling	0.0728	4.4582	0.9241
	Min-max	0.1071	12.0476	0.8212
	Z-score	0.0552	4.0183	0.9550
Average Scores of the KR models		0.1376	5.8290	0.5575
LSTM	Non-normalization	0.2982	8.6577	-0.3678
	Log Scaling	0.1163	3.4065	0.6235
	Min-max	0.1161	7.9402	0.8431
	Z-score	0.3112	17.1352	0.9639
Average Scores of the LSTM models		0.2105	9.2849	0.5157
GRU	Non-normalization	406888	474261	-2.5467
	Log Scaling	0.1572	5.4191	0.9086
	Min-max	0.2191	1.8369	0.8486
	Z-score	0.2076	7.2107	0.9660
Average Scores of the GRU models		101722.1	118568.9	0.044125

ตารางที่ 17 ผลการพยากรณ์ราคาหลักทรัพย์แบบ 30-day prediction period

Algorithm	Data Normalization Techniques	Evaluation Measures		
		RMSE	MAPE	R-Square
SVR with RBF kernel function	Non-normalization	0.3112	4.9611	-0.6407
	Log Scaling	0.1251	2.0636	0.7749
	Min-max	0.0999	1.8916	0.8308
	Z-score	0.1171	1.6182	0.9357
Average Scores of the SVR models		0.1633	2.6336	0.4752
ANNs	Non-normalization	2.8788	81.9813	-139.3730
	Log Scaling	3.5257	100.7110	-209.5441
	Min-max	3.5093	97.6270	-207.5869
	Z-score	2.7707	63.1006	-129.0284
Average Scores of the ANNs models		3.1711	85.8550	-171.3831

ตารางที่ 17 (ต่อ)

KR	Non-normalization	0.3200	3.7280	-0.6535
	Log Scaling	0.1152	1.5915	0.7818
	Min-max	0.0999	1.8921	0.8401
	Z-score	0.0616	0.9594	0.9386
Average Scores of the KR models		0.1492	2.0428	0.4768
LSTM	Non-normalization	0.2749	3.1923	-0.2804
	Log Scaling	0.1604	2.9671	0.7487
	Min-max	0.1328	3.1798	0.7056
	Z-score	0.1158	2.3763	0.9393
Average Scores of the LSTM models		0.1710	2.9289	0.5283
GRU	Non-normalization	273266	270116	-126475
	Log Scaling	0.1362	2.1691	0.8944
	Min-max	0.1521	1.6997	0.7626
	Z-score	0.1261	1.5314	0.9465
Average Scores of the GRU models		68316.6	67530.35	-31618.1


หากพิจารณาผลการทดลองในตารางข้างต้น สำหรับด้านเทคนิคการทำนอร์มอลไลเซชันข้อมูล แม้ว่าเทคนิคแบบ Log Scaling จะเป็นเทคนิคที่ง่ายที่สุด แต่ในการศึกษานี้กลับให้ผลลัพธ์ที่ดีกว่าเทคนิคแบบ Min-max และ Z-score ซึ่งเนื่องจาก Log Scaling อาจช่วยเปลี่ยนการกระจายของข้อมูลโดยการปรับขนาดบันทึกส่งผลให้การสร้างมาตรฐานของข้อมูลให้ช่วงข้อมูลแคบลง และช่วยในการปรับปรุงประสิทธิภาพเชิงเส้นของแบบจำลองและการกระจายแบบเบ้ของตัวแปรต่อเนื่องผ่านการแปลงด้วยลอการิทึม (Logarithmic Transformation) เพื่อให้สามารถใช้สถิติเชิงพารามิเตอร์ได้ ในขณะเดียวกัน การทำนอร์มอลไลเซชันแบบ Min-max ให้ผลลัพธ์ที่ดีกว่าการทำนอร์มอลไลเซชันแบบ Z-score เนื่องจากการทำนอร์มอลไลเซชันแบบ Min-max ปรับค่าของคุณลักษณะให้อยู่ระหว่าง 0 ถึง 1 ซึ่งวิธีการนี้นักงานได้กับข้อมูลที่มีการกระจายของคุณลักษณะอาจไม่ใช่แบบเกาส์เซียน และค่าของคุณลักษณะนั้นอยู่ภายในช่วงเวลาที่จำกัด หรือ Bounded Interval (เช่น แต่ละคุณลักษณะจะอยู่ในช่วง 0-300) สำหรับข้อมูลที่ไม่ได้ทำเทคนิคการทำนอร์มอลไลเซชัน จากตารางข้างต้นพบว่าค่าเฉลี่ยที่ได้ค่อนข้างสูงกว่าค่าที่ได้ทำเทคนิคการทำนอร์มอลไลเซชัน เนื่องจากเป็นชุดข้อมูลที่ไม่เชิงเส้นและความผันผวนค่อนข้างสูงส่งผลให้ข้อมูลมีความซับซ้อน

แต่หากพิจารณาเกี่ยวกับอัลกอริทึมที่ใช้ในการพัฒนาแบบจำลองการคาดการณ์ จะเห็นว่า KR มีผลลัพธ์ดีกว่า SVR ที่ใช้ RBF เป็นฟังก์ชันเคอร์เนลเพียงเล็กน้อย สำหรับ KR จะค้นหาฟังก์ชันที่เหมาะสมสำหรับข้อมูล และยังช่วยในการควบคุมความแปรปรวนและอคติของเอาต์พุตส่งผลให้พารามิเตอร์มีความต่อเนื่องส่งผลต่อการทำนายแบบจำลอง ในขณะที่ SVR ให้ผลลัพธ์ที่ดีกว่า GRU, LSTM และ ANNs ตามลำดับ เนื่องจาก SVR เหมาะสำหรับชุดข้อมูลขนาดเล็ก GRU ให้ผลลัพธ์ที่ดีกว่า LSTM เนื่องจาก GRU ไม่มี Output Gate ส่งผลให้มี Parameter น้อยกว่า LSTM เหมาะสม


กับข้อมูลขนาดเล็ก ในขณะที่ LSTM มีความแม่นยำมากกว่าในชุดข้อมูลโดยใช้ลำดับที่ยาวกว่า ใน การศึกษานี้ ได้ใช้ระยะเวลาคาดการณ์ 7 วัน 14 วัน และ 30 วันสำหรับการพยากรณ์ราคาปิด ของคริปโตเคอร์เรนซี ด้วยเหตุนี้ ชุดข้อมูลขนาดเล็กอาจไม่ส่งผลกระทบบ่อยอย่างมีนัยสำคัญต่อ SVR และ GRU แต่ก็มีผลกระทบต่อประสิทธิภาพของ LSTM นอกจากนี้ SVR ยังมีความสามารถในการทำให้ เป็นภาพรวมที่ดีและมีความแม่นยำในการคาดการณ์สูง เนื่องจากมีประสิทธิภาพสำหรับค่าผิดปกติ (Robust to Outliers) ดังนั้นจึงไม่น่าแปลกใจที่ SVR ทำงานได้ดีกว่า GRU, LSTM และ ANNs เนื่องจากขนาดชุดข้อมูลที่เล็กในกรณีการใช้งานนี้

เมื่อพิจารณาเกี่ยวกับในด้านการประเมินผล จากการศึกษาครั้งนี้ผลการทดลองตารางข้างต้น พบว่าการประเมินค่าของ RMSE ให้ผลลัพธ์ที่ดีกว่าเมื่อใช้ร่วมกันกับโมเดลที่พัฒนาด้วยอัลกอริทึม SVR และ KR เนื่องจาก RMSE มีการปรับข้อมูลให้เป็นมาตรฐานและมีการทดสอบความเหมาะสม ระหว่างโมเดลกับชุดข้อมูล โดยค่า RMSE ที่ต่ำที่สุดเมื่อนำไปใช้กับชุดข้อมูลบิตคอยน์และอีเธอร์เลียม ตามการคาดการณ์ 7 วันของโมเดล SVR และ KR คือ 0.0516 และ 0.0459 ตามลำดับ สำหรับ MAPE พบว่าจะให้ผลลัพธ์ที่ดีกับโมเดลกับโมเดล SVR เนื่องจาก MAPE จะวัดความถูกต้องของการ พยากรณ์ค่าที่ต่ำจะบ่งบอกถึงความแม่นยำของการพยากรณ์ โดยค่า MAPE ที่ดีที่สุดเมื่อนำไปใช้กับ ชุดข้อมูลบิตคอยน์ตามการคาดการณ์ 7 วัน คือ 0.0671 และสำหรับ R-Square จะให้ผลลัพธ์ที่ดีกับ โมเดล SVR, KR และ GRU เนื่องจาก R-Square เป็นการวัดสัดส่วนของความแปรปรวนของตัวแปร ตามโมเดล ซึ่งค่าที่ได้จะบ่งบอกถึงความพอดีของชุดข้อมูลและโมเดล โดยค่า R-Square ที่ดีที่สุดเมื่อนำไปใช้กับชุดข้อมูลไลท์คอยน์ 7 วัน และอีเธอร์เลียม 14 วัน และ 30 วันของโมเดล SVR, KR และ GRU คือ 0.7832, 0.8609 และ 0.9077 ตามลำดับ แต่ถึงอย่างไรก็ตามจากตารางข้างต้นจะพบว่า โมเดลของ ANNs มีค่าเฉลี่ยของ R-Square ที่ติดลบเนื่องจากการคาดการณ์ของโมเดลแย่กว่าฟังก์ชัน คงที่ที่คาดการณ์ค่าเฉลี่ยของข้อมูลส่งผลให้ค่าที่ได้ติดลบ


พหุ ประสิทธิภาพ



รูปที่ 17 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึมโดยใช้เทคนิคแบบ Log Scaling



รูปที่ 18 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึมโดยใช้เทคนิคแบบ Min-Max Scaling



รูปที่ 19 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึมโดยใช้เทคนิคแบบ Z-score Scaling



บทที่ 5

สรุปผล อภิปรายผล และข้อเสนอแนะ

การวิจัยเรื่อง การศึกษาเชิงเปรียบเทียบสำหรับกระบวนการของการพยากรณ์ราคาคริปโทเคอร์เรนซี มีวัตถุประสงค์เพื่อศึกษากระบวนการที่แตกต่างกันใน 2 รูปแบบ คือ

- 1) กระบวนการบนพื้นฐานของการเรียนรู้ของเครื่อง (Machine Learning based Approach)
- 2) กระบวนการบนพื้นฐานของการเรียนรู้เชิงลึก (Deep Learning based Approach)

โดยข้อมูลที่นำมาศึกษาในวิจัยในครั้งนี้จะศึกษาคริปโทเคอร์เรนซี อย่างน้อย 3 สกุลเงินของคริปโทเคอร์เรนซี ได้แก่ บิตคอยน์ อีเธอร์เลียม และไลท์คอยน์ ซึ่งเป็นชุดข้อมูลมาตรฐานจากเว็บไซต์ <https://cryptocompare.com/> ซึ่งเป็นข้อมูลการซื้อขายคริปโทเคอร์เรนซีในช่วงเวลา 1 วัน ระหว่างวันที่ 13 สิงหาคม ค.ศ. 2016 ถึง 3 มกราคม ค.ศ. 2022 หน่วยสกุลเงินที่ใช้ในการซื้อขายคือ ดอลลาร์สหรัฐ (USD) รวมชุดข้อมูลที่ใช้ในการศึกษาทั้งหมดคือ 7,223 ระเบียบ โดยบิตคอยน์มีข้อมูลทั้งหมด 2,902 ระเบียบ อีเธอร์เลียมมีข้อมูลทั้งหมด 1,753 ระเบียบ และไลท์คอยน์มีข้อมูลทั้งหมด 2,568 ระเบียบ

การวิเคราะห์ข้อมูลในงานวิจัยครั้งนี้ ได้มีการเปรียบเทียบกระบวนการของการพยากรณ์ราคาปิด (Closed Price) ของคริปโทเคอร์เรนซีที่แตกต่างกันใน 2 ประเด็นหลัก คือ

- 1) เทคนิคการทำนอร์มอลไลเซชันของข้อมูลในขั้นตอนการเตรียมข้อมูล จะทำการเปรียบเทียบใน 3 วิธีได้แก่ การปรับค่าข้อมูลด้วยลอการิทึม (Log Scaling), การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด (Min-Max Scaling) และการปรับค่าข้อมูลแบบซี-สกอร์ (Z-score Scaling)
- 2) อัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อการพยากรณ์ (Predictive Model) โดยจะศึกษาด้วยอัลกอริทึมการเรียนรู้ของเครื่อง ได้แก่ Support Vector Regression (SVR), Artificial Neural Networks (ANNs) และ Kernel Regression (KR) ในส่วนของการเรียนรู้เชิงลึก ได้แก่ Long Short-Term Memory (LSTM) และ Gated Recurrent Units (GRU)

การประเมินกระบวนการในการพยากรณ์ราคาปิดของคริปโทเคอร์เรนซี จะประเมินด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error : RMSE), ข้อผิดพลาดสมบูรณ์เปอร์เซ็นต์ (Mean Absolute Percentage Error : MAPE) และสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R-Square)

5.1 สรุปผล

ผลการวิจัยสามารถสรุปได้ดังนี้

- 1) Root Mean Square Error (RMSE): ให้ผลลัพธ์ที่ดีกว่าเมื่อใช้ร่วมกันกับโมเดลที่พัฒนาด้วยอัลกอริทึม SVR และ KR สำหรับค่า RMSE ที่ต่ำที่สุดเมื่อนำไปใช้กับชุดข้อมูลบิตคอยน์

และอีเธอร์เลียมตามการคาดการณ์ 7 วันของโมเดล SVR และ KR คือ 0.0516 และ 0.0459 ตามลำดับ

2) Mean Absolute Percentage Error (MAPE): ให้ผลลัพธ์ที่ดีกับโมเดล SVR ค่า MAPE ที่ดีที่สุดเมื่อนำไปใช้กับชุดข้อมูลบิตคอยน์ตามการคาดการณ์ 7 วัน คือ 0.0671

3) R-Squared: ให้ผลลัพธ์ที่ดีกับโมเดล SVR, KR และ GRU ค่า R-Square ที่ดีที่สุดเมื่อนำไปใช้กับชุดข้อมูลไลท์คอยน์ 7 วัน และอีเธอร์เลียม 14 วัน และ 30 วันของโมเดล SVR, KR และ GRU คือ 0.7832, 0.8609 และ 0.9077 ตามลำดับ สำหรับโมเดล ANNs มีค่าเฉลี่ยของ R-Square ที่ติดลบ เนื่องจากการคาดการณ์ของโมเดลแยกว่าฟังก์ชันคงที่ที่คาดการณ์ค่าเฉลี่ยของข้อมูลส่งผลให้ค่าที่ได้ติดลบ

5.2 อภิปรายผล

จากผลการวิจัยสามารถนำมาอภิปรายผล ได้ดังนี้

1) ด้านเทคนิคการทำนอร์มอลไลเซชันของข้อมูลในขั้นตอนการเตรียมข้อมูล

(1) การปรับค่าข้อมูลด้วยลอการิทึม (Log Scaling): เป็นเทคนิคที่ให้ผลลัพธ์ดีที่สุดเมื่อเทียบกับเทคนิคแบบ Min-max และ Z-score เนื่องจาก Log Scaling อาจช่วยเปลี่ยนการกระจายของข้อมูลโดยการปรับขนาดบันทึกส่งผลให้การสร้างมาตรฐานของข้อมูลให้ช่วงข้อมูลแคบลง

(2) การปรับค่าข้อมูลแบบต่ำสุด-สูงสุด (Min-Max Scaling): เป็นเทคนิคที่ให้ผลลัพธ์ดีกว่า Z-score เนื่องจาก Min-Max จะปรับค่าของคุณลักษณะให้อยู่ระหว่าง 0 ถึง 1 ซึ่งวิธีการนี้มักทำงานได้ดีกับข้อมูลที่มีการกระจายของคุณลักษณะอาจไม่ใช่แบบเกาส์เซียนและค่าในคุณลักษณะนั้นอยู่ภายในช่วงเวลาที่จำกัด ส่งผลให้ค่าคาดการณ์ที่ได้ไม่ดีเท่าที่ควร

(3) การปรับค่าข้อมูลแบบซี-สกอร์ (Z-score Scaling): เนื่องจาก Z-score เป็นวิธีการตรวจจับและลบค่าผิดปกติที่มีประสิทธิภาพสูง ซึ่งวิธีนี้จะให้ผลลัพธ์ที่ดีสำหรับชุดข้อมูลที่มีความสมบูรณ์หรือใกล้เคียงกับการกระจายตามปกติ

แม้ว่าเทคนิค Log Scaling ให้ผลลัพธ์ที่ดีกว่าเทคนิคแบบ Min-Max และ Z-score ตามลำดับ Log Scaling จะเป็นเทคนิคที่ง่ายที่สุดและช่วยปรับปรุงประสิทธิภาพเชิงเส้นของแบบจำลองและการกระจายแบบเบ้ของตัวแปรต่อเนื่องเพื่อให้สามารถใช้สถิติเชิงพารามิเตอร์ได้ในขณะเดียวกัน Min-Max จะปรับค่าของคุณลักษณะให้อยู่ระหว่าง 0 ถึง 1 ซึ่งวิธีการนี้มักทำงานได้ดีกับข้อมูลที่มีการกระจายของคุณลักษณะอาจไม่ใช่แบบเกาส์เซียนและค่าในคุณลักษณะนั้นอยู่ภายในช่วงเวลาที่จำกัด ส่งผลให้ค่าคาดการณ์ที่ได้ไม่ดีเท่าที่ควร

2) อัลกอริทึมที่ใช้ในการสร้างโมเดลเพื่อการพยากรณ์ (Predictive Model)

(1) Kernel Regression (KR): ให้ผลลัพธ์ที่ดีที่สุดเมื่อเปรียบเทียบกับโมเดล SVR, GRU, LSTM และ ANNs เนื่องจาก KR จะค้นหาฟังก์ชันที่เหมาะสมสำหรับข้อมูล และยังช่วยในการควบคุมความแปรปรวนและอคติของเอาต์พุตส่งผลให้พารามิเตอร์มีความต่อเนื่องส่งผลต่อการทำนาย

(2) Support Vector Regression (SVR): ให้ผลลัพธ์ที่ดีในโมเดล GRU, LSTM และ ANNs เนื่องจาก SVR สามารถระบุตำแหน่งไฮเปอร์เพลน ส่งผลให้ลดข้อผิดพลาดในการคาดคะเน และ SVR ยังเหมาะสำหรับชุดข้อมูลขนาดเล็ก

(3) Gated Recurrent Units (GRU): ให้ผลลัพธ์ดีกว่า LSTM และ ANNs เนื่องจาก GRU มี Parameter น้อยกว่า LSTM แต่ทำงานคล้ายกับ LSTM ที่มี forget gate เพื่อแก้ไขปัญหาการไล่ระดับสีที่หายไป GRU ยังมีความซับซ้อนน้อยกว่า LSTM เนื่องจากมีจำนวนประตูน้อยกว่า และ GRU ยังเหมาะสำหรับชุดข้อมูลขนาดเล็ก

(4) Long Short-Term Memory (LSTM): ให้ผลลัพธ์ดีกว่า ANNs เนื่องจาก LSTM มีความซับซ้อนและต้องการข้อมูลการฝึกอบรมมากจึงไม่เหมาะสมกับข้อมูลขนาดเล็ก

(5) Artificial Neural Networks (ANNs): เนื่องจาก ANNs มีความสามารถในการวิเคราะห์ความซับซ้อนของชุดข้อมูลขนาดใหญ่จึงไม่เหมาะสมกับชุดข้อมูลขนาดเล็ก

ผลการวิจัยพบว่าในการศึกษานี้ ได้ใช้ระยะเวลาคาดการณ์ 7 วัน, 14 วัน และ 30 วัน สำหรับการพยากรณ์ราคาปิดของคริปโตเคอร์เรนซี ด้วยเหตุนี้ ชุดข้อมูลขนาดเล็กอาจไม่ส่งผลกระทบต่อ SVR, KR และ GRU แต่ก็มีผลกระทบต่อประสิทธิภาพของ LSTM นอกจากนี้ SVR ยังมีความสามารถในการทำให้เป็นภาพรวมที่ดีและมีความแม่นยำในการคาดการณ์สูง

5.3 ข้อเสนอแนะ

1) ข้อเสนอแนะเพื่อการนำผลการวิจัยไปใช้

(1) จากผลการวิจัยพบว่า อัลกอริทึม KR, SVR และ GRU มีความแม่นยำค่อนข้างสูง ดังนั้นการใช้อัลกอริทึมดังกล่าวในการพยากรณ์ราคาคริปโตเคอร์เรนซี จะสามารถใช้ประกอบการตัดสินใจเกี่ยวกับการลงทุนสินทรัพย์ดิจิทัลได้

2) ข้อเสนอแนะจากงานวิจัยครั้งต่อไป

(1) เนื่องจากงานวิจัยครั้งนี้ได้ศึกษาชุดข้อมูล 3 ชุดข้อมูล ได้แก่ บิตคอยน์ อีเธอร์เลียม และไลท์คอยน์ ส่งผลให้มีชุดข้อมูลที่ใช้ในการศึกษาน้อย ในงานวิจัยครั้งต่อไปควรเพิ่มชุดข้อมูลในการศึกษา

(2) ควรมีการศึกษาปัจจัยด้านอื่นๆ ที่อาจจะส่งผลกระทบต่อราคาคริปโตเคอร์เรนซี เช่น เศรษฐกิจ, ข่าวสาร หรือ Twitter

บรรณานุกรม

1. Narktong, J. ราชบัณฑิตยสถานตั้งคำจำกัดความของคำว่า Cryptocurrency และ Blockchain เป็นภาษาไทยแล้ว [ออนไลน์]. 2019; Available from: <https://siamblockchain.com/2019/08/14/office-of-the-royal-society-adds-cryptocurrency-and-blockchain/>.
2. What is Cryptocurrency? Cryptocurrency Security: 4 Tips to Safely Invest in Cryptocurrency [ออนไลน์]. 2021; Available from: <https://www.kaspersky.com/resource-center/definitions/what-is-cryptocurrency/>
3. Ashford, K. and J. Schmidt. What Is Cryptocurrency? [ออนไลน์]. 2020; Available from: <https://www.forbes.com/advisor/investing/what-is-cryptocurrency/>.
4. Understanding The Different Types of Cryptocurrency [ออนไลน์]. 2021; Available from: https://www.sofi.com/learn/content/understanding-the-different-types-of-cryptocurrency/?__cf_chl_jschl_tk__=pmd_e7f0554cc5da9279c192665c180aa545a6c1f28a-1627668250-0-ggNtZGzNAmKjcnBszOiQ
5. Baur, D., Hong, K. and Lee, A., Bitcoin: Medium of exchange or speculative assets?. Journal of International Financial Markets, Institutions and Money, 2018. 54: p. 177-189.
6. Chuen, D. Handbook of Digital Currency: Bitcoin, Innovation, Financial Instruments, and Big Data. 2015. 1-588.
7. ความเข้าใจที่ลึกซึ้งในตลาดสินทรัพย์ดิจิทัล คือหนทางเดียวที่จะเอาชนะตลาดนี้ได้ [ออนไลน์] 2020; Available from: <https://www.finnomena.com/zipmex/digital-asset-understanding/>
8. Wright, C. S. Bitcoin: A Peer-to-Peer Electronic Cash System. SSRN Electronic Journal, 2008.
9. Ji, S., Kim, J. and Im, H. A Comparative Study of Bitcoin Price Prediction Using Deep Learning. Mathematics, 2019. 7(10): p. 898.
10. Phaladisailoed, T. and Numnonda, T. Machine Learning Models Comparison for Bitcoin Price Prediction, in International Conference on Information Technology and Electrical Engineering (ICITEE). 2018. p. 506-511.
11. Tandon, S., et al. Bitcoin Price Forecasting using LSTM and 10-Fold Cross validation, in International Conference on Signal Processing and Communication (ICSC). 2019. p. 323-328.
12. Hayes, A. and Boyle, M. J. Peer-to-Peer (P2P) Service [ออนไลน์]. 2021; Available from: <https://www.investopedia.com/terms/p/peertopeer-p2p-service.asp>.

13. Ji, S., Kim, J. and Im, H. A Comparative Study of Bitcoin Price Prediction Using Deep Learning. *Mathematics*, 2019. 7(10): p. 898.
14. Mahendra, E., Madan, H., Gupta, S. and Singh, S. V. Bitcoin Price Prediction Using Deep Learning and Real Time Deployment, in 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN). 2020. p. 264-268.
15. Ibrahim, A.F., Corrigan, L. and Kashef, R. Predicting the Demand in Bitcoin Using Data Charts: A Convolutional Neural Networks Prediction Model, in IEEE Canadian Conference on Electrical and Computer Engineering (CCECE). 2020. p. 1-4.
16. National Organization for Rare Diseases. [online] 16 August 1999 cited 21 August 1999; Available from: <http://www.rarediseases.org>.
17. Nakamoto, S. Bitcoin: A Peer-to-Peer Electronic Cash System. 2009.
18. Sofi. What Is Bitcoin (BTC)? [ออนไลน์]. 2022; Available from: <https://www.sofi.com/what-is-bitcoin/>.
19. Bitcoin Was First Used To Buy Pizza. Other Interesting Tidbits [ออนไลน์]. 2021; Available from: <https://www.ndtv.com/business/the-first-bitcoin-transaction-was-for-buying-pizzas-more-interesting-tidbits-inside-2512643>.
20. HANKIN, A. Bitcoin Pizza Day: Celebrating the \$80 Million Pizza Order [ออนไลน์]. 2019; Available from: <https://www.investopedia.com/news/bitcoin-pizza-day-celebrating-20-million-pizza-order/>.
21. Dematteo, M. Bitcoin Doubled Its Value in 2021, Then Nearly Lost It All In the First Month of 2022. Here's a Look at Its Price Over the Years [ออนไลน์]. 2022; Available from: <https://time.com/nextadvisor/investing/cryptocurrency/bitcoin-price-history/>.
22. ย้อนรอย: จุดต่ำสุดของราคา Bitcoin ในรอบที่ผ่านมามาจนถึงปัจจุบัน จะไปไหนต่อ? [ออนไลน์]. 2020; Available from: <https://siamblockchain.com/2020/11/20/turn-back-to-the-lowest-point-of-bitcoin/>.
23. Coinmarketcap, Ethereum [ออนไลน์]. 2022.
24. Reiff, N. Bitcoin vs. Ethereum: What's the Difference? [ออนไลน์]. 2020; Available from: <https://www.investopedia.com/articles/investing/031416/bitcoin-vs-ethereum-driven-different-purposes.asp>.
25. Freankenfield, J. Decentralized Applications – dApps [ออนไลน์]. 2021; Available from: <https://www.investopedia.com/terms/d/decentralized-applications-dapps.asp>.
26. Finley, k. Out in the Open: Teenage Hacker Transforms Web Into One Giant

- Bitcoin Network [ออนไลน์]. 2014; Available from: <https://www.wired.com/2014/01/ethereum/>.
27. Freankenfield, J. Ethereum [ออนไลน์]. 2021; Available from: <https://www.investopedia.com/terms/e/ethereum.asp>.
 28. Magas, J. Five Years of Ethereum: From a Teenage Dream to a \$38B Blockchain [ออนไลน์]. 2020; Available from: <https://cointelegraph.com/news/five-years-of-ethereum-from-a-teenage-dream-to-a-38b-blockchain>.
 29. Coingecko. Ethereum (ETH) [ออนไลน์]. 2021; Available from: <https://www.coingecko.com/th/coin/ethereum>.
 30. Innocent, O. Ethereum Enterprise Alliance (EEA): What Is It? 2021; Available from: <https://medium.com/xord/ethereum-enterprise-alliance-eea-what-is-it-e7ca820f410b>.
 31. Sofi. What is Litecoin & How Does it Work? [ออนไลน์]. 2021; Available from: <https://www.sofi.com/learn/content/what-is-litecoin/>.
 32. Litecoin. WHAT IS LITECOIN? [ออนไลน์]. Available from: <https://litecoin.org/>
 33. Fernado, J. Bitcoin vs. Litecoin: What's the Difference? [ออนไลน์]. 2021; Available from: <https://www.investopedia.com/articles/investing/042015/bitcoin-vs-litecoin-whats-difference.asp>.
 34. Coinmarketcap. Litecoin [ออนไลน์]. 2022; Available from: <https://coinmarketcap.com/currencies/litecoin/>.
 35. markets, c. What is litecoin? [ออนไลน์]. Available from: <https://www.cmcmarkets.com/en/learn-cryptocurrencies/what-is-litecoin>.
 36. Hayes, A. 10 Important Cryptocurrencies Other Than Bitcoin [ออนไลน์]. 2022; Available from: <https://www.investopedia.com/tech/most-important-cryptocurrencies-other-than-bitcoin/>.
 37. Daly, L. What Is Litecoin? [ออนไลน์]. 2021; Available from: <https://www.fool.com/investing/stock-market/market-sectors/financials/cryptocurrency-stocks/litecoin/>.
 38. Stitch. What is data transformation: definition, benefits, and uses [ออนไลน์]. 2022; Available from: <https://www.stitchdata.com/resources/data-transformation>.
 39. Galaktikasoftware. Data mining normalization [ออนไลน์]. 2019; Available from: <https://galaktika-soft.com/blog/data-mining-normalization.html>.
 40. Normalization. 2022; Available from: <https://developers.google.com/machine-learning/data-prep/transform/normalization>.
 41. Shamil, F. R. Data mining normalization method. 2020; Available from:

- <https://t4tutorials.com/data-normalization-before-data-mining/>.
42. Shamil, F. R. Z-Score Normalization [ออนไลน์]. 2020; Available from: <https://t4tutorials.com/z-score-normalization-data-mining/>.
 43. Yiyang, W. and Yeze, Z. Cryptocurrency Price Analysis with Artificial Intelligence. 2019. p. pp. 97-101.
 44. Suhwan, J., K. Jongmin, and Hyeonseung, I. A Comparative Study of Bitcoin Price Prediction Using Deep Learning. Mathematics, 2019. 7(10): p. 898.
 45. Knight, J. Kernel regression [ออนไลน์]. 2021; Available from: <https://invezz.com/definitions/kernel-regression/>.
 46. BowTied_Raptor. Kernel Regression [ออนไลน์]. 2021; Available from: <https://bowtiedraptor.substack.com/p/kernel-regression>.
 47. Mehta, K. Kernel Regression from Scratch in Python [ออนไลน์]. 2020; Available from: <https://towardsdatascience.com/kernel-regression-from-scratch-in-python-ea0615b23918>.
 48. Meyler, A., Kenny, G. and Quinn, T. Forecasting irish inflation using ARIMA models. 1998.
 49. Anochi, J., Almeida, V. and Haroldo, F. Machine Learning for Climate Precipitation Prediction Modeling over South America. 2021.
 50. Sun, D., Wu, J., Huang, H., Wang, R., Liang, F. and Xinhua, H. Prediction of Short-Time Rainfall Based on Deep Learning. 2021.
 51. Girgin, S. Support Vector Regression in 6 Steps with Python [ออนไลน์]. 2019; Available from: <https://medium.com/pursuitnotes/support-vector-regression-in-6-steps-with-python-c4569acd062d>.
 52. Pedamkar, P. Support Vector Regression [ออนไลน์]. 2020; Available from: <https://www.educba.com/support-vector-regression/>.
 53. Rawat, A. S. What is Support Vector Regression? [ออนไลน์]. 2021; Available from: <https://www.analyticssteps.com/blogs/what-support-vector-regression>.
 54. Community, E. Getting Started with Support Vector Regression in Python [ออนไลน์]. 2022; Available from: <https://www.section.io/engineering-education/support-vector-regression-in-python/>.
 55. Bhattacharyya, I. Support Vector Regression Or SVR [ออนไลน์]. 2018; Available from: <https://medium.com/coinmonks/support-vector-regression-or-svr-8eb3acf6d0ff>.
 56. Sack, H. Marvin Minsky and Artificial Neural Networks [ออนไลน์]. 2020; Available from: <http://scihi.org/marvin-minsky-artificial-neural-networks/>.
 57. Dertat, A. Applied Deep Learning - Part 1: Artificial Neural Networks [ออนไลน์].


- 2017; Available from: <https://towardsdatascience.com/applied-deep-learning-part-1-artificial-neural-networks-d7834f67a4f6>.
58. IBM. What are Neural Networks [ออนไลน์]. 2020; Available from: <https://www.ibm.com/cloud/learn/neural-networks>.
 59. Deepanshi. Beginners Guide to Artificial Neural Network [ออนไลน์]. 2021; Available from: <https://www.analyticsvidhya.com/blog/2021/05/beginners-guide-to-artificial-neural-network/>.
 60. Warren McCulloch , W.P., A logical calculus of the ideas immanent in nervous activity. 1943: p. 115-133.
 61. HistoryofInformation. McCulloch & Pitts Publish the First Mathematical Model of a Neural Network [ออนไลน์]. Available from: <https://www.historyofinformation.com/detail.php?id=634>.
 62. ประกอบผล, ธ., Artificial Neural Networks. 2009.
 63. McCulloch, W.S. and W. Pitts, A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 1943. 5(4): p. 115-133.
 64. Saxena, S. Introduction to Long Short Term Memory (LSTM) [ออนไลน์]. 2021; Available from: <https://www.analyticsvidhya.com/blog/2021/03/introduction-to-long-short-term-memory-lstm/>.
 65. Tangruamsub, S. Long Short-Term Memory (LSTM) [ออนไลน์]. 2017; Available from: <https://medium.com/@sinart.t/long-short-term-memory-lstm-e6cb23b494c6>.
 66. Geeksforgeeks. Long Short Term Memory Networks Explanation [ออนไลน์]. 2021; Available from: <https://www.geeksforgeeks.org/long-short-term-memory-networks-explanation/?ref=lbp>.
 67. Amidi, A. and S. Amidi. Recurrent Neural Networks cheatsheet [ออนไลน์]. 2022; Available from: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks>.
 68. Arbel, N. How LSTM networks solve the problem of vanishing gradients [ออนไลน์]. 2018; Available from: <https://medium.datadriveninvestor.com/how-do-lstm-networks-solve-the-problem-of-vanishing-gradients-a6784971a577>.
 69. Hochreiter, S. and J. Schmidhuber, Long Short-term Memory. Neural computation, 1997. 9: p. 1735-80.
 70. กนกทิพย์สถาพร, ส. Recurrent Neural Network (RNN) หมายถึง Gated Recurrent Unit (GRU) คืออะไร สอนสร้าง RNN ถึง GRU ด้วยภาษา Python – NLP ep.9 [ออนไลน์]. 2019; Available from: <https://www.bualabs.com/archives/3103/what-is-rnn-recurrent-neural-network-what-is-gru-gated-recurrent-unit-teach-how-to-build>

[rnn-gru-with-python-nlp-ep-9/](#).

71. Stackoverflow. Discrepancy between diagram and equations of GRU? [ออนไลน์]. 2019; Available from: <https://stackoverflow.com/questions/57448101/discrepancy-between-diagram-and-equations-of-gru>.
72. Saxena, S. Introduction to Gated Recurrent Unit (GRU) [ออนไลน์]. 2021; Available from: <https://www.analyticsvidhya.com/blog/2021/03/introduction-to-gated-recurrent-unit-gru/>.
73. patel, M. Vanishing and Exploding Gradients in Neural Networks [ออนไลน์]. 2021; Available from: <https://medium.datadriveninvestor.com/vanishing-and-exploding-gradients-in-neural-networks-bddd4504e59c>.
74. Kostadinov, S. Understanding GRU Networks [ออนไลน์]. 2017; Available from: <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>.
75. Geeksforgeeks. Gated Recurrent Unit Networks [ออนไลน์]. 2022; Available from: <https://www.geeksforgeeks.org/gated-recurrent-unit-networks/>.
76. Marktmuse. Gated Recurrent Unit (GRU) [ออนไลน์]. 2022; Available from: <https://blog.marketmuse.com/glossary/gated-recurrent-unit-gru-definition/>.
77. Cho, K., et al., Learning phrase representations using RNN encoder-decoder for statistical machine translation. 2014.
78. Singhal, G. LSTM versus GRU Units in RNN [ออนไลน์]. 2020; Available from: <https://www.pluralsight.com/guides/lstm-versus-gru-units-in-rnn>.
79. Vidhya, A. Beginners Guide to Artificial Neural Network [ออนไลน์]. 2021; Available from: <https://www.analyticsvidhya.com/blog/2021/05/beginners-guide-to-artificial-neural-network/>.
80. Acharya, S. What are RMSE and MAE? [ออนไลน์]. 2021; Available from: <https://towardsdatascience.com/what-are-rmse-and-mae-e405ce230383>.
81. MAE, MSE, RMSE — เลือกใช้ยังไงดีมาลองดูที่ความหมาย [ออนไลน์]. 2020; Available from: <https://medium.com/c-g-datacommunity/mse-rmse-mae->.
82. Machine learning: an introduction to mean squared error and regression lines [ออนไลน์]. 2018; Available from: <https://www.freecodecamp.org/news/machine-learning-mean-squared-error-regression-line-c7dde9a26b93/>.
83. Kumar, A. Mean Squared Error or R-Squared – Which one to use? [ออนไลน์]. 2022; Available from: <https://vitalflux.com/mean-square-error-r-squared-which-one-to-use/>.
84. Samaddar, M., Roy, R., De, S. and Karmakar, R. A Comparative Study of Different Machine Learning Algorithms on Bitcoin Value Prediction, in International

Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT). 2021. p. 1-7.

85. Valencia, F. Gómez-Espinosa A. and Valdés-Aguirre, B., Price Movement Prediction of Cryptocurrencies Using Sentiment Analysis and Machine Learning. 2019.
86. Yiyang, W. and Yeze, Z. Cryptocurrency Price Analysis with Artificial Intelligence. 2019. p. pp. 97-101.
87. Chen, M., Narwal, N. and Schultz, M., Predicting Price Changes in Ethereum. 2019.
88. Wirawan, I. M., Widiyaningtyas, T. and Hasan, M. M. Short Term Prediction on Bitcoin Price Using ARIMA Method 2019.



ประวัติผู้เขียน

ชื่อ	นางสาวชนาภรณ์ ผาสุก
วันเกิด	1 ตุลาคม พ.ศ. 2540
สถานที่เกิด	จังหวัดร้อยเอ็ด
สถานที่อยู่ปัจจุบัน	222 หมู่ 6 ตำบลรอบเมือง อำเภอเมือง จังหวัดร้อยเอ็ด 45000
ประวัติการศึกษา	พ.ศ. 2563 บธ.บ. (บริหารธุรกิจบัณฑิต) มหาวิทยาลัยมหาสารคาม พ.ศ. 2566 วท.ม. (วิทยาศาสตรมหาบัณฑิต) มหาวิทยาลัยมหาสารคาม
ผลงานวิจัย	Phasook, C., Polpinij, J. and Luaphol, B. A Study of Comparative Methods for Closed-Price Cryptocurrency Prediction, The 6th International Conference on Information Technology (InCIT2022), Panyapiwat Institute of Management (PIM), Nonthaburi, Thailand.

พหุมน ปณ จิต ชีเว