

การทำนายราคาสกุลเงินดิจิทัลด้วยวิธีการเรียนรู้ของเครื่อง  
และกลุ่มปัจจัยภายนอก

CRYPTOCURRENCY PRICE PREDICTION USING MULTIPLE MACHINE  
LEARNING TECHNIQUES AND MULTIPLE EXTERNAL FEATURES  
COMBINATIONS



นายพงศ์ภัทร จารุวิจิตรรัตนา  
MR. PONGPEERA JARUVIJITRATTANA

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาข้อมูลและการวิเคราะห์  
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง  
คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2566

KMITL-2023-SC-M-017-053

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

CRYPTOCURRENCY PRICE PREDICTION USING MULTIPLE MACHINE  
LEARNING TECHNIQUES AND MULTIPLE EXTERNAL FEATURES  
COMBINATIONS



MR. PONGPEERA JARUVIJITRATTANA

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

2023

KMITL-2023-SC-M-017-053

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



**COPYRIGHT 2023**

**SCHOOL OF SCIENCE**

**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABAN**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การทำนายราคาสกุลเงินดิจิทัลด้วยวิธีการเรียนรู้ของเครื่อง และกลุ่มปัจจัยภายนอก
ชื่อนักศึกษา	นายพงศ์ภีระ จารุวิจิตรรัตนนา
รหัสประจำตัว	64605077
ปริญญา	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์) ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
พ.ศ.	2566
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ดร.จิรภัทร์ หยกรัตนศักดิ์

## บทคัดย่อ

การศึกษาในครั้งนี้ มีวัตถุประสงค์เพื่อหาแบบจำลองที่เหมาะสมกับการทำนายราคาคริปโทเคอร์เรนซีทั้ง 4 เหรียญ ได้แก่ Bitcoin (BTC) Ethereum (ETH) Cardana (ADA) และ Solana (SOL) โดยมีการสร้างแบบจำลองแบบตัวแปรเดียวและแบบตัวแปรกลุ่มปัจจัยภายนอก ซึ่งตัวแปรกลุ่มปัจจัยภายนอกประกอบด้วย ปริมาณการซื้อขาย (Trading Volume), ดัชนีความกลัวและความโลภ (Fear & Greedy index), อัตราดอกเบี้ยสหรัฐอเมริกา (Interest Rate of the United States) และ อัตราเงินเฟ้อสหรัฐอเมริกา (Inflation rate of the United States) โดยใช้เทคนิค ARIMAX XGBoost LSTM FBProphet N-BEATS และ TFT ซึ่งใช้ข้อมูลรายวันตั้งแต่วันที่ 1 กุมภาพันธ์ 2561 ถึง 31 มีนาคม 2566

ผลการศึกษาพบว่า การทำนายราคาคริปโทเคอร์เรนซีทั้ง 4 เหรียญแบบจำลองที่ให้ประสิทธิภาพดีที่สุดคือ XGBoost แบบตัวแปรเดียว ซึ่งค่า RMSE MAE และ MAPE ของแบบจำลองนั้นได้ผลลัพธ์ดังนี้ BTC XGBoost ตัวแปรเดียว อยู่ที่ 576.17, 384.85 และ ETH XGBoost ตัวแปรเดียว อยู่ที่ 60.527, 40.06 และ 0.0311, ADA XGBoost ตัวแปรเดียว อยู่ที่ 0.016, 0.011 และ 0.033, SOL XGBoost ตัวแปรเดียว อยู่ที่ 1.94, 1.11 และ 0.05962 ในขณะที่ความสำคัญของปัจจัยที่มีผลต่อแบบจำลองแบบกลุ่มปัจจัยภายนอกที่มากที่สุดได้แก่อัตราเงินเฟ้อ อยู่ที่ 8 แบบจำลอง

**คำสำคัญ :** การทำนาย การเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก สกุลเงินดิจิทัล อนุกรมเวลา

<b>Independent Study Title</b>	Cryptocurrency Price Prediction Using Multiple Machine Learning Techniques and Multiple External Features Combinations
<b>Student Name</b>	Pongpeera Jaruvijitrattana
<b>Student ID</b>	64605077
<b>Degree</b>	Master of Science (Data Science and Analytics) KMITL- Digital Analytics and Intelligence Center
<b>Year</b>	2023
<b>Independent Study Advisor</b>	Dr.Jiraphat Yokrattanasak

## Abstract

The purpose of this study were to find out suitable model for all 4 cryptocurrencies including Bitcoin (BTC) Ethereum (ETH) Cardana (ADA) และ Solona (SOL) by comparing between univariate models and multivariate models. In this study, exogenous variables consists of 4 factors were trading volume, fear & greedy index, inflation rate of the United States and Interest rate of the United States. In this study, a total of 6 machine learning models were used, including ARIMAX, XGBoost, LSTM, FBProphet, N-BEATS and TFT. Data was collected, started from 1<sup>st</sup> February 2018 to 31<sup>st</sup> March 2023

The results show that the prediction of XGBoost univariate models is the best performance in all 4 cryptocurrencies which RMSE MAE and MAPE of BTC XGBoost univariate model is 576.17, 384.85 and 0.0213, ETH XGBoost univariate model is 60.527, 40.06 and 0.0311, ADA XGBoost univariate model is 0.016, 0.011 and 0.033, SOL XGBoost univariate model is 1.94, 1.11 and 0.05962. In terms of feature importance of multivariate models, it shows that inflation rate of the United Stages is the most important in most of the model which is found in 8 models.

**Keywords:** Prediction, Machine learning, Deep learning, Cryptocurrency, Time series

## กิตติกรรมประกาศ

การค้นคว้าแบบอิสระฉบับนี้สำเร็จได้ด้วยความอนุเคราะห์ของ ศาสตราจารย์ ดร.จิรภัทร์ หยกรัตนศักดิ์ อาจารย์ที่ปรึกษาการค้นคว้าแบบอิสระ ที่คอยกรุณาให้ความรู้ คำปรึกษา คำแนะนำ ตลอดจนข้อคิดเห็นต่างๆ ในการตรวจแก้ไขจนการค้นคว้าแบบอิสระเสร็จสมบูรณ์ ข้าพเจ้าขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

ขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.ละออ บุญเกษม ที่กรุณารับประธานกรรมการสอบการค้นคว้าแบบอิสระ และผู้ช่วยศาสตราจารย์ ดร.ปัทมา เจริญพร เป็นกรรมการที่ปรึกษาการค้นคว้าแบบอิสระ ที่กรุณาให้คำแนะนำ เป็นอย่างดีในการตรวจสอบข้อบกพร่องต่างๆ จนทำให้การค้นคว้าแบบอิสระฉบับนี้สมบูรณ์มากยิ่งขึ้น

ข้าพเจ้าขอกราบขอบพระคุณ คุณพ่อ คุณแม่ และครอบครัว ตลอดจนผู้ที่มีส่วนเกี่ยวข้อง ไม่ว่าจะ เป็นเจ้าหน้าที่หรือเพื่อนร่วมรุ่น ที่คอยให้การสนับสนุนและให้ความช่วยเหลือรวมถึงให้กำลังใจแก่ข้าพเจ้า จนทำให้การค้นคว้าแบบอิสระเล่มนี้เสร็จสมบูรณ์

สุดท้ายนี้หากมีข้อผิดพลาดประการใด หรือมีสิ่งที่ขาดตกบกพร่องไป ผู้เขียนขอภัยเป็น อย่างสูง และขออนุมัติไว้แต่เพียงผู้เดียว หวังว่าการค้นคว้าแบบอิสระเล่มนี้จะเป็นประโยชน์ไม่มากก็น้อยสำหรับหน่วยงานที่เกี่ยวข้องหรือนักลงทุนผู้สนใจจะศึกษาเกี่ยวกับการทำนายราคาคริปโทเคอร์เรนซีต่อไป

นาย พงศ์ภีระ จารุวิจิตรรัตน์

# สารบัญ

	หน้า
บทคัดย่อ	ก
Abstract	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญภาพ	ช
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตของงานวิจัย	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ	3
1.5 ขั้นตอนดำเนินงาน	3
1.6 ระยะเวลาดำเนินงาน	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	5
2.1 แนวความคิด	5
2.1.1 สกุลเงินดิจิทัล (Cryptocurrency)	5
2.1.2 ข้อมูลอนุกรมเวลา (Time Series Data)	10
2.1.3 ปัจจัยภายนอกที่มีผลต่อมูลค่าของสกุลเงินดิจิทัล (Cryptocurrency External Factor)	10
2.1.4 แบบจำลองสำหรับการทำนายชุดข้อมูลอนุกรมเวลา (Model For Time series Forecasting)	13
2.2 งานวิจัยที่เกี่ยวข้อง	21

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

<b>บทที่ 3 วิธีดำเนินงานวิจัย</b>	<b>24</b>
3.1 ข้อมูลที่นำมาใช้ในการวิจัย (Research dataset)	24
3.2 เครื่องมือที่และภาษาที่ใช้ในการวิจัย (Research Tool)	24
3.3 การเก็บรวบรวมข้อมูล (Data Collection)	24
3.4 การจัดเตรียมข้อมูล (Data Preprocessing)	25
3.5 การแบ่งข้อมูลเพื่อสอนและทดสอบ (Train & Test dataset)	25
3.6 การสร้างแบบจำลอง (Model Creation)	25
3.7 การวัดประสิทธิภาพแบบจำลอง (Model Evaluation)	29
3.8 การทำนายผล (Model Prediction)	29
3.9 ทดสอบประสิทธิภาพกับชุดข้อมูลทดสอบ (Test Performance)	29
3.10 เปรียบเทียบแบบจำลองและสรุปผล (Model comparison and conclusion)	29
<b>บทที่ 4 ผลการวิจัยและอภิปรายผล</b>	<b>30</b>
4.2 ผลลัพธ์จากการวิจัย	30
4.2.1 กราฟราคาปิดเหรียญเปรียบเทียบกับราคาปิดที่ถูกทำนาย 90 วัน	30
4.2.2 ผลลัพธ์ค่า RMSE MAE MAPE	46
4.2.3 Feature Importance	49
<b>บทที่ 5 สรุปผลการศึกษาและข้อเสนอแนะ</b>	<b>57</b>
5.1 สรุปผลการศึกษา	57
5.2 ข้อเสนอแนะ	57
<b>เอกสารอ้างอิง</b>	<b>58</b>
<b>ประวัติผู้เขียน</b>	<b>60</b>

## สารบัญตาราง

ตารางที่	หน้า
ตารางที่ 1.1 แผนการดำเนินงานวิจัย	4
ตารางที่ 2.1 ข้อมูลทางเทคนิคของ Bitcoin (BTC)	7
ตารางที่ 2.2 ข้อมูลทางเทคนิคของ Ethereum (ETH)	8
ตารางที่ 2.3 ข้อมูลทางเทคนิคของ Cardano (ADA)	9
ตารางที่ 2.4 ข้อมูลทางเทคนิคของ Solana (SOL)	9
ตารางที่ 2.5 สรุปรงานวิจัยที่เกี่ยวข้อง	21
ตารางที่ 3.1 การตั้งค่าของแบบจำลอง ARIMAX	26
ตารางที่ 4.1 ค่า RMSE MAE MAPE ของแบบจำลอง BTC	46
ตารางที่ 4.2 ค่า RMSE MAE MAPE ของแบบจำลอง ETH	47
ตารางที่ 4.3 ค่า RMSE MAE MAPE ของแบบจำลอง ADA	47
ตารางที่ 4.4 ค่า RMSE MAE MAPE ของแบบจำลอง SOL	48

## สารบัญภาพ

ภาพที่	หน้า
ภาพที่ 2.1 สถาปัตยกรรมแบบจำลองหน่วยความจำระยะสั้นแบบยาว	15
ภาพที่ 2.2 สถาปัตยกรรมของ XGBoost	17
ภาพที่ 2.3 สถาปัตยกรรมของ N-Beats	19
ภาพที่ 2.4 สถาปัตยกรรมของ Temporal Fusion Transformer (Google)	20
ภาพที่ 3.1 การตั้งค่าแบบจำลอง XGBoost	26
ภาพที่ 3.2 โครงสร้างแบบจำลอง LSTM ตัวแปรเดียว	26
ภาพที่ 3.3 โครงสร้างแบบจำลองของตัวแปรแบบกลุ่มปัจจัยภายนอก	27
ภาพที่ 3.4 ค่าพารามิเตอร์ของแบบจำลอง FBProphet ตัวแปรเดียว	27
ภาพที่ 3.5 ค่าพารามิเตอร์ของแบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอก	27
ภาพที่ 3.6 ค่าพารามิเตอร์ของแบบจำลอง N-BEATS ตัวแปรเดียว	27
ภาพที่ 3.7 ค่าพารามิเตอร์ของแบบจำลอง N-BEATS ตัวแปรแบบกลุ่มปัจจัยภายนอก	28
ภาพที่ 3.8 ค่าพารามิเตอร์ของแบบจำลอง TFT ตัวแปรเดียว	28
ภาพที่ 3.9 ค่าพารามิเตอร์ของแบบจำลอง N-BEATS ตัวแปรแบบกลุ่มปัจจัยภายนอก	28
ภาพที่ 4.1 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย ARIMAX	30
ภาพที่ 4.2 กราฟเปรียบเทียบระหว่างราคาปิดจริง ราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย XGboost	31
ภาพที่ 4.3 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย LSTM	32
ภาพที่ 4.4 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย FBProphet	32
ภาพที่ 4.5 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย N-BEATS	33
ภาพที่ 4.6 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย TFT	34
ภาพที่ 4.7 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย ARIMAX	34
ภาพที่ 4.8 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว	35

และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย XGBoost	
ภาพที่ 4.9 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย LSTM	36
ภาพที่ 4.10 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย FBProphet	36
ภาพที่ 4.11 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย N-BEATS	37
ภาพที่ 4.12 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย TFT	38
ภาพที่ 4.13 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย ARIMAX	38
ภาพที่ 4.14 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย XGBoost	39
ภาพที่ 4.15 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย LSTM	40
ภาพที่ 4.16 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย FBProphet	40
ภาพที่ 4.17 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย N-BEATS	41
ภาพที่ 4.18 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย TFT	42
ภาพที่ 4.19 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย ARIMAX	42
ภาพที่ 4.20 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย XGboost	43
ภาพที่ 4.21 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย LSTM	44
ภาพที่ 4.22 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย FBProphet	44
ภาพที่ 4.23 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว	45

และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย N-BEATS

ภาพที่ 4.24 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียว	46
และแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย TFT	
ภาพที่ 4.25 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ BTC	49
ภาพที่ 4.26 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ BTC	49
ภาพที่ 4.27 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ BTC	50
ภาพที่ 4.28 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ BTC	50
ภาพที่ 4.29 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ ETH	51
ภาพที่ 4.30 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ ETH	51
ภาพที่ 4.31 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ ETH	52
ภาพที่ 4.32 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ ETH	52
ภาพที่ 4.33 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ ADA	53
ภาพที่ 4.34 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ ADA	53
ภาพที่ 4.35 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ ADA	54
ภาพที่ 4.36 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ ADA	54
ภาพที่ 4.37 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ SOL	55
ภาพที่ 4.38 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ SOL	55
ภาพที่ 4.39 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ SOL	56
ภาพที่ 4.40 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ SOL	56

# บทที่ 1

## บทนำ

โครงการวิจัยเรื่อง การทำนายราคาสกุลเงินดิจิทัลด้วยวิธีการเรียนรู้ของเครื่องและกลุ่มปัจจัยภายนอกเพื่อศึกษากลุ่มของปัจจัยภายนอกที่มีผลต่อราคาของ คริปโทเคอร์เรนซี ที่สามารถช่วยเพิ่มประสิทธิภาพของแบบจำลองเพื่อให้สามารถทำนายราคาคริปโทเคอร์เรนซีในอนาคตให้มีความแม่นยำมากที่สุด เพื่อที่นักลงทุนสามารถนำไปใช้วางแผนการลงทุนให้เหมาะสมยิ่งขึ้น ส่วนของบทที่ 1 ซึ่งเป็นบทนำ จะประกอบด้วย ความเป็นมาและความสำคัญของปัญหา วัตถุประสงค์ของงานวิจัย ขอบเขตงานวิจัย ประโยชน์ที่ได้รับจากงานวิจัย และนิยามศัพท์เฉพาะ โดยมีรายละเอียด ดังต่อไปนี้

### 1.1 ความเป็นมาและความสำคัญของปัญหา

สกุลเงินดิจิทัล หรือที่เรียกกันว่า คริปโทเคอร์เรนซี (Cryptocurrency) เป็นสกุลเงินที่เริ่มเข้ามามีบทบาทในปี พ.ศ.2552 โดยสกุลเงินดิจิทัลนี้เป็นเสมือนสื่อกลางในการทำธุรกรรมแบบไม่ระบุตัวตน ใช้การเข้ารหัสเพื่อรักษาความปลอดภัยของธุรกรรม และการสร้างหน่วยใหม่ จะถูกสร้างและอยู่ภายใต้การดูแลของเครือข่ายคอมพิวเตอร์ทั่วโลก ซึ่งจะหมุนเวียนกันอยู่ภายในโลกออนไลน์ (สำนักงานคณะกรรมการธุรกรรมทางอิเล็กทรอนิกส์. กลุ่มงานกำกับฯ, 2560) สกุลเงินดิจิทัลที่ถูกสร้างเป็นเหรียญแรกและได้รับความนิยมที่สุดคือ บิทคอยน์ (Bitcoin) บิทคอยน์ถูกสร้างขึ้นในปี พ.ศ. 2552 ซึ่งปัจจุบันยังได้รับความนิยมมากที่สุดและเป็นสกุลเงินดิจิทัลที่มีค่ามากที่สุด (Wayne Duggan, 2022) ในปัจจุบันมีสกุลเงินดิจิทัลเกิดขึ้นมากมาย ข้อมูลจากเว็บไซต์ Statista ระบุว่า ในเดือนกุมภาพันธ์ ปี พ.ศ.2565 มีสกุลเงินดิจิทัลมากกว่า 10,000 สกุลเงิน

คริปโทเคอร์เรนซี (Cryptocurrency) ได้กลายเป็นทางเลือกที่ได้รับความนิยมการลงทุนเมื่อไม่นานมานี้เนื่องจากสกุลเงินแบบดั้งเดิม (Traditional Fiat Currencies) นั้นมีข้อจำกัดทางด้านความปลอดภัย นโยบายทางการเงินที่เข้มงวดและระเบียบข้อบังคับของธนาคาร ในทางตรงกันข้ามสกุลเงินดิจิทัลนั้นให้โซลูชันสำหรับการกระจายอำนาจ ความไม่เปลี่ยนแปลง และการไม่ระบุตัวตน ซึ่งในปัจจุบันด้วยข้อมูลที่พร้อมใช้งานมากขึ้นทำให้การทำให้เป็นอัตโนมัติขึ้นเกิดขึ้นในทุก ๆ อุตสาหกรรมรวมถึงคริปโทเคอร์เรนซี (Cryptocurrency) ซึ่งทำให้เกิดการแลกเปลี่ยนโดยใช้บล็อกเชนที่มและแบบจำลองด้วยการเรียนรู้ของเครื่อง (Machine Learning Model) (Yan Pang, et al., 2019) ถึงแม้ว่าข้อมูลจะมีความพร้อมมากขึ้น แต่เนื่องจากคริปโทเคอร์เรนซี (Cryptocurrency) นั้นเป็นสินทรัพย์ดิจิทัลแบบใหม่และราคามีความผันผวนค่อนข้างมาก ทำให้การทำนายราคานั้นเป็นไปได้ยาก การหาปัจจัยที่มีผลกระทบต่อราคาคริปโท

เคอร์เรนซี (Cryptocurrency) จึงเป็นสิ่งที่ท้าทาย ยิ่งไปกว่านั้นคริปโทเคอร์เรนซี (Cryptocurrency) ยังเปิดให้ทำการซื้อขาย 24 ชั่วโมง 7 วัน เพื่อให้ได้ผลลัพธ์ในการลงทุนที่ดีที่สุด การใช้ Bot trade ควบคู่ไปกับอัลกอริทึมที่เหมาะสมนั้น จะทำให้ผู้ลงทุนเพิ่มโอกาสในการได้ผลตอบแทนจากการลงทุนได้ดียิ่งขึ้น

ทั้งนี้จากการศึกษาของ Serafini และเพื่อน ได้ศึกษาเรื่อง “Sentiment-Driven Price Prediction of the Bitcoin based on Statistical and Deep Learning Approaches” โดยใช้แบบจำลอง ARIMAX and LSTM-based RNN กับกลุ่มตัวแปรราคาเฉลี่ยของเหรียญบิทคอยน์ (Bitcoin หรือ BTC) ผสมกับ ปริมาณซื้อขาย BTC, อารมณ์และความรู้สึกต่อ BTC, ปริมาณการส่งข้อความบนทวิตเตอร์ที่เกี่ยวข้องกับ BTC ซึ่งผู้ทำการศึกษาค้นพบว่า กลุ่มตัวแปรที่ดีที่สุดคือ ราคาเฉลี่ย BTC และ อารมณ์และความรู้สึกต่อ BTC และแบบจำลองที่ให้ผลลัพธ์ที่ดีที่สุดคือแบบจำลอง ARIMAX ด้วยค่า MSE 0.00030187

นอกจากนั้นยังมีงานวิจัยที่ศึกษาปัจจัยภายนอกที่ อาจมีผลกระทบต่อราคาคริปโทเคอร์เรนซี (Cryptocurrency) เช่น อัตราแลกเปลี่ยนบิทคอยน์ต่อดอลลาร์สหรัฐอเมริกาดอลลาร์ออสเตรเลีย ยูโร และเยน (Edward M Ruiz, 2014) ความเร็วในการขุดบิทคอยน์ ความยากในการขุดบิทคอยน์ (Sean McNally, 2016) หรือการใช้ราคาของคริปโทเคอร์เรนซี (Cryptocurrency) อื่นๆมาเป็นปัจจัยภายนอก (Wang Zhengyang, et al., 2019)

ดังนั้นงานศึกษานี้จึงมุ่งเน้นการสร้างแบบจำลองเพื่อทำนายราคาของคริปโทเคอร์เรนซี (Cryptocurrency) ต่าง ๆ ที่ได้รับความนิยม โดยใช้แบบจำลองด้วยการเรียนรู้ของเครื่อง (Machine Learning Model) หลาย ๆ เทคนิค และกลุ่มปัจจัยภายนอกที่คาดว่าจะมีความสัมพันธ์ เช่น ปริมาณการซื้อขาย (Trading Volume), ดัชนีความกลัวและความโลภ (Fear & Greedy index), อัตราดอกเบี้ยสหรัฐอเมริกา (Interest Rate of the United States) และ อัตราเงินเฟ้อสหรัฐอเมริกา (Inflation rate of United States) เพื่อลดความเสี่ยงทางการลงทุน และการซื้อ-ขายสกุลเงินดิจิทัล

## 1.2 วัตถุประสงค์ของงานวิจัย

วัตถุประสงค์ของการทำวิจัยนี้ คือ

- 1) ศึกษาวิธีการและเปรียบเทียบประสิทธิภาพของแบบจำลองการทำนายราคาของคริปโทเคอร์เรนซี ด้วยวิธีการเรียนรู้ของเครื่องแบบต่าง ๆ
- 2) ศึกษาความสัมพันธ์ระหว่างคริปโทเคอร์เรนซีและกลุ่มของปัจจัยภายนอกที่นำมาใช้ในแบบจำลองต่าง ๆ

3) ศึกษาการนำอัลกอริทึมไปประยุกต์ใช้ในการทำนายราคาคริปโทเคอร์เรนซีเพื่อใช้ในการวางแผนการลงทุน

### 1.3 ขอบเขตของงานวิจัย

ขอบเขตของงานวิจัย มีดังต่อไปนี้

1) ข้อมูลรายวันของเหรียญคริปโทเคอร์เรนซี (Cryptocurrency) ต่าง ๆ ได้แก่ BTC, ETH, ADA และ Solana

2) ข้อมูลปัจจัยภายนอกอื่น ๆ เช่น ปริมาณการซื้อขาย (Trading Volume), ดัชนีความกลัวและความโลภ (Fear & Greedy index), อัตราดอกเบี้ยสหรัฐอเมริกา (Interest Rate of the United States) และ อัตราเงินเฟ้อสหรัฐอเมริกา (Inflation rate of United States)

ระยะเวลาข้อมูลที่ใช้ในงานวิจัยนี้จะใช้ข้อมูลรายวันตั้งแต่วันที่ 1 กุมภาพันธ์ 2561 ถึง 31 มีนาคม 2566

### 1.4 ประโยชน์ที่คาดว่าจะได้รับ

ผลจากการศึกษารั้งนี้ น่าจะเป็นประโยชน์แก่ผู้ที่สนใจและผู้ลงทุนในคริปโทเคอร์เรนซี (Cryptocurrency) การทราบถึงปัจจัยที่มีผลต่อคริปโทเคอร์เรนซี (Cryptocurrency) สามารถนำไปใช้เป็นแนวทางการวางแผนการลงทุน ลดความเสี่ยงในการประกอบการตัดสินใจในการลงทุนคริปโทเคอร์เรนซี (Cryptocurrency) ในอนาคตได้

### 1.5 ขั้นตอนดำเนินงาน

ขั้นตอนในการดำเนินงานวิจัยมีดังนี้

- 1.5.1 การเก็บข้อมูล (Data Collection)
- 1.5.2 การสำรวจข้อมูล (Exploratory Data Analysis)
- 1.5.3 การเตรียมข้อมูล (Data Preprocessing)
- 1.5.4 การสร้างแบบจำลอง (Model Creation)
- 1.5.5 การวัดประสิทธิภาพแบบจำลอง (Model Evaluation)
- 1.5.6 การทำนายผล (Model Prediction)
- 1.5.7 ทดสอบประสิทธิภาพกับชุดข้อมูลทดสอบ (Test Performance)
- 1.5.8 เปรียบเทียบแบบจำลองและสรุปผล (Model Comparison and Conclusion)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 1.6 ระยะเวลาดำเนินงาน

ระยะเวลาดำเนินงานในการวิจัยนี้ จะใช้เวลาทั้งหมด 8 เดือน ซึ่งจะแบ่งเป็นขั้นตอนใหญ่ 5 ขั้นตอน ขั้นตอนย่อย 10 ขั้นตอน ดังตารางที่ 1.1

ตารางที่ 1.1 แผนการดำเนินงานวิจัย

กิจกรรม	ระยะเวลาดำเนินงาน							
	2565		2566					
	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.	มิ.ย.
<b>ก. ขั้นตอนการเตรียมการ</b>								
1. ค้นหาชื่อเรื่องหรือปัญหาที่จะทำ								
2. การศึกษาเอกสารงานวิจัยที่เกี่ยวข้อง								
3. ศึกษาเครื่องมือที่ใช้ในงานวิจัย								
<b>ข. การเก็บข้อมูลและเตรียมข้อมูล</b>								
4. เก็บข้อมูล								
5. เตรียมข้อมูล								
<b>ค. การสร้างแบบจำลองและประเมินประสิทธิภาพ</b>								
6. สร้างแบบจำลอง								
7. ประเมินประสิทธิภาพ								
<b>ง. การทำนายผลและทดสอบประสิทธิภาพแบบจำลอง</b>								
8. ทำนายผล								
9. ทดสอบประสิทธิภาพ								
<b>จ. การทำรายงาน</b>								
10. เขียนรายงาน								

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 แนวความคิด

##### 2.1.1 สกุลเงินดิจิทัล (Cryptocurrency)

คริปโทเคอร์เรนซีคืออะไร

จากพจนานุกรมของ Cambridge ได้ให้คำนิยามว่า สกุลเงินดิจิทัลที่ถูกผลิตจากโครงข่ายสาธารณะ แทนที่จะถูกสร้างโดยรัฐบาลต่างๆ ซึ่งใช้การเข้ารหัสลับเพื่อทำให้มั่นใจว่าการชำระเงินถูกส่งและรับอย่างปลอดภัย

ประวัติศาสตร์โดยย่อของคริปโทเคอร์เรนซี

แนวคิดของคริปโทเคอร์เรนซีปรากฏขึ้นครั้งแรกในปี 1983 หลังจากนักเข้ารหัสชาวอเมริกาชื่อ David Chaum ได้ทำการเผยแพร่เอกสารประชุมทางวิชาการในหัวข้อ ยุคแรกของเงินอิเล็กทรอนิกส์ที่ถูกเข้ารหัสโดยไม่ต้องระบุตัวตน ซึ่งแนวคิดก็คือสกุลเงินที่สามารถถูกส่งแบบไม่สามารถตรวจสอบได้และไม่มีจำเป็นต้องมีตัวกลาง ยกตัวอย่างเช่น ธนาคาร ในปี 1995 Chaum ได้สร้างคริปโทเคอร์เรนซีตัวต้นแบบชื่อเหรียญ Digicash จากแนวคิดดังกล่าว

หลังจากนั้นในปี 1998 Bit Gold ได้ถูกออกแบบโดย Nick Szabo ซึ่ง Bit Gold ต้องการผู้เข้าร่วมในการใช้พลังงานคอมพิวเตอร์ในการแก้ปัญหาปริศนาการเข้ารหัส และผู้ที่สามารถแก้ปัญหาได้จะได้รับรางวัล ซึ่งแนวคิดนี้ เมื่อรวมกับแนวคิดของ Chaum จึงทำให้เกิดผลลัพธ์ที่ใกล้เคียงบิทคอยน์มากๆ

แต่ Szabo สามารถแก้ปัญหา double-spending (การคัดลอกและวางข้อมูลดิจิทัล) โดยปราศจากการใช้อำนาจส่วนกลางในการตรวจสอบได้ จนกระทั่ง 10 ปีหลังจากนั้นมีกลุ่มหรือคนที่ไม่ประสงค์ออกนามในนามแฝงว่า Satoshi Nakamoto เผยแพร่เอกสารที่ชื่อว่า Bitcoin – A Peer to Peer Electronic Cash System

จุดเริ่มต้น (2008-2010)

วันที่ 31 ธันวาคมปี 2008 Satoshi Nakamoto เผยแพร่เอกสารบิทคอยน์ซึ่งอธิบายหลักการการทำงานของโครงข่ายบล็อกเชน Satoshi เริ่มทำ Bitcoin โปรเจกในวันที่ 18 สิงหาคม 2008 หลังจากที่มีชื่อ website ชื่อ Bitcoin.org ประวัติศาสตร์บิทคอยน์ได้เริ่มขึ้นหลังจากนั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Satoshi Nakamoto ได้ขุดบล็อกแรกของโครงข่ายบิตคอยน์ในวันที่ 3 มกราคม 2009 หลังจากนั้น 6 เดือน บิตคอยน์สามารถแลกเปลี่ยนได้ในเดือน เมษายน 2010 ซึ่งมูลค่าในตอนนั้นอยู่ที่ต่ำกว่า 14 cents โดยราคาได้พุ่งไปถึง 36 cents ช่วงต้นเดือนพฤศจิกายน ก่อนที่มูลค่าจะกลับมาประมาณ 29 cents

การเริ่มต้นของตลาดจนกระทั่งเป็นรูปเป็นร่าง (2010-2014)

บิตคอยน์เริ่มแสดงให้เห็นว่ามีมูลค่าในโลกแห่งความจริง ในกุมภาพันธ์ปี 2011 มูลค่าขึ้นไปอยู่ที่ \$1.06 และร่วงกลับมาอยู่ที่ประมาณ 87 cents ในฤดูใบไม้ผลิราคาพุ่งขึ้นจากช่วงต้นเมษายน ถึงปลายเดือนพฤษภาคม จาก 86 cents ไปที่ \$8.89

ในวันที่ 1 มิถุนายน หลังจากที่ Gawker เผยแพร่เรื่องราวเกี่ยวกับการความน่าสนใจของ เหรียญในคอมมูนิตี้การซื้อขายออนไลน์ ราคาพุ่งมากกว่า 3 เท่าในหนึ่งสัปดาห์ ไปที่ \$27 ซึ่งมูลค่าในตลาดของ Bitcoin เกือบๆ \$130 ล้าน อย่างไรก็ตามในเดือนกันยายน 2011 มูลค่าลดลงเหลือ \$4.77

ในเดือนตุลาคมปี 2011 Litecoin ได้ปรากฏขึ้น ซึ่งหลังจากนั้นไม่นานก็เป็นเหรียญที่มีมูลค่าในตลาดสูงเป็นอันดับสอง ซึ่งในปีนี้มีเหรียญต่างๆมากมายถูกสร้างขึ้น ได้แก่ PPCoin, Namecoin และ เหรียญอื่นๆกว่า 10 เหรียญซึ่ง เหรียญเหล่านี้ถูกเรียกว่า altcoins

ในปี 2012 ราคา บิตคอยน์ยังขึ้นอย่างต่อเนื่อง และในเดือนกันยายน องค์กรกลาง บิตคอยน์ (Bitcoin foundation) ได้ถูกก่อตั้งขึ้นเพื่อโปรโมทการพัฒนาและการให้ความเข้าใจบิตคอยน์ ซึ่งในปีนี้ OpenCoin และ Ripple ก็ได้เปิดตัวในปีนี้

ในปี 2013 ราคาบิตคอยน์ ขึ้นอย่างต่อเนื่องและตกอย่างรุนแรง วันที่ 19 พฤศจิกายน ราคาพุ่งถึง \$755 และตกลงมาที่ \$378 ในวันเดียวกัน จนกระทั่งในวันที่ 30 พฤศจิกายน ราคาขึ้นอย่างต่อเนื่องจนมีมูลค่า \$1,163 อย่างไรก็ตาม นี่คือจุดเริ่มต้นของขาลงระยะยาวซึ่งสิ้นสุดที่ราคาบิตคอยน์ กลับลงมาที่ \$152 ในเดือนมกราคม 2015 ซึ่งในปี 2013 เหรียญ Dodge Coin ที่สร้างมาเพื่อล้อเลียน ขำๆ ได้ถูกสร้างขึ้น และเป็นที่ยอมรับอย่างมากในปัจจุบัน โดยมี Elon Musk เป็นผู้สนับสนุนอยู่เบื้องหลัง

การแพร่กระจายของการฉ้อโกง (2014-2016)

ในเดือน มกราคม 2014 MT.Gox ตลาดแลกเปลี่ยนบิตคอยน์ที่ใหญ่ที่สุด ณ ตอนนั้น ประกาศล้มละลาย มูลค่าความเสียหาย 850,000 บิตคอยน์ในขณะนั้นไม่มีใครรู้ว่าเกิดอะไรขึ้นแน่ชัด เหมือนกับว่าบิตคอยน์ที่หายไปได้ถูกขโมยที่ละเล็กละน้อยตลอดเวลาเริ่มตั้งแต่ปี 2011 และถูกนำกลับมาขายในตลาดแลกเปลี่ยนต่างๆเป็นเงินสด จนกระทั่ง Mt.Gox ตรวจสอบครบถ้วนแล้วพบว่าเหรียญหายไปหมดแล้ว ซึ่ง CEO Mark Karpeles ถูกจับในข้อหาฉ้อโกงในปี 2017 และถูกปล่อยตัวในปี 2019 ซึ่งเหรียญที่หายไปก็ยังคงเป็นปริศนาอยู่จนถึงทุกวันนี้ ซึ่งการฉ้อโกงได้เกิดขึ้นอย่างต่อเนื่อง โดยเฉพาะตลาด การแลกเปลี่ยนขนาดเล็ก

บิตคอยน์สร้างปรากฏการณ์ระดับโลก (2016-2018)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ราคาบิทคอยน์พุ่งขึ้นอย่างต่อเนื่อง จาก \$434 ในเดือนมกราคม 2016 ไปยัง \$998 ในเดือนมกราคม 2017 ซึ่งในเดือนกรกฎาคม 2017 บิทคอยน์ซอฟต์แวร์อัปเดตได้รับการอนุมัติด้วยเป้าหมายที่จะสนับสนุนการพัฒนา Lightning Network (a layer-two scaling solution) เช่นเดียวกับการพัฒนาด้านความปลอดภัย หลังจาก 1 สัปดาห์หลังจากการอัปเดต ราคาขึ้นไปอยู่ที่ประมาณ \$2,700 ซึ่งในวันที่ 17 ธันวาคม 2017 บิทคอยน์ได้ทำจุดสูงสุดเกือบๆ \$20,000

ในช่วงเวลานี้ Ethereum ได้ถูกสร้างขึ้นและมีมูลค่าในตลาดสูงเป็นอันดับสองอย่างรวดเร็วหลังจากเปิดตัวในเดือนกรกฎาคมปี 2015

#### Bust and Recovery, and Bust and Recovery... (2018-Present)

บิทคอยน์และอีเธอเรียมไม่สามารถรักษาการทำจุดสูงสุดอย่างต่อเนื่องไว้ได้ เนื่องด้วยกฎระเบียบและความปลอดภัยทางการเงินทำให้ราคาร่วงมาที่ \$3,700 เหยี่ยพลายปี 2018

อย่างไรก็ตาม ราคาเริ่มฟื้นตัวในตอนปลายปี 2022 ยุคฟื้นฟูนั้นเริ่มต้นมาจาก บริษัท MicroStrategy ซึ่งเป็นบริษัททางด้าน business intelligence ได้ประกาศในเดือนสิงหาคมว่าได้ซื้อบิทคอยน์ เป็นมูลค่า \$250 ล้าน ซึ่งเป็นจุดเริ่มต้นของตลาดกระทิง และหลังจากนั้นราคาได้พุ่งขึ้นไปอีกด้วยการซื้อบิทคอยน์ จาก Tesla ตอนต้นปี 2021 ซึ่งในเดือนพฤศจิกายน 2021 บิทคอยน์ได้ทำจุดสูงสุด ณ ปัจจุบันอยู่ที่ \$69,000

หลังจากนั้นราคาได้ตกลงอีกครั้งจากจุดสูงสุด ซึ่งสาเหตุนี้เกิดจากความกังวลในเศรษฐกิจมหภาคซึ่งเป็นผลมาจาก อัตราเงินเฟ้อที่สูงขึ้น ดอกเบี้ยที่ปรับตัวสูงขึ้น และ ความหวาดกลัวในสงคราม ซึ่งจากจุดสูงสุดราคาบิทคอยน์ได้ตกลงมาอยู่ที่อยู่ที่ ราคา \$16,000 ในเดือนพฤศจิกายน 2022 ประวัติของสกุลเงินดิจิทัลที่ได้รับความนิยม

**2.1.1.1 บิทคอยน์ (Bitcoin: BTC)** เป็นสกุลเงินดิจิทัลเหรียญแรกที่มีการใช้งานจริง Bitcoin เป็นคริปโทเคอร์เรนซีแบบไม่มีตัวกลางซึ่งถูกอธิบายครั้งแรกในเอกสารทางวิชาการโดยบุคคลหรือกลุ่มที่มีนามแฝงว่า Satoshi Nakamoto ซึ่งหลังจากนั้นไม่นานก็ได้เปิดตัวครั้งแรกในเดือนมกราคมปี 2009 ซึ่งข้อมูลทางเทคนิคของบิทคอยน์จากเว็บไซต์ [www.coinmarketcap.com](http://www.coinmarketcap.com) สามารถดูได้จากตารางที่ 2.1

ตารางที่ 2.1 ข้อมูลทางเทคนิคของ Bitcoin (BTC)

Consensus mechanism	Prove of Work
Hash function	SHA-256
Circulating supply	19,209,556 (at 17.11.2022)
Supply limit	21,000,000
ATH	\$68,789.63

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**2.1.1.2 อีเธอเรียม (Ethereum: ETH)** เป็นระบบบล็อกเชนโอเพนซอสแบบไม่รวมศูนย์ซึ่งมีคุณสมบัติเป็นเจ้าของสกุลเงินดิจิทัลด้วยตัวมันเอง ETH ทำงานเป็นแพลตฟอร์มสำหรับสกุลเงินดิจิทัลอื่นๆ อีกทั้งยังเป็นตัวดำเนินการสำหรับสัญญาอัจฉริยะแบบไม่รวมศูนย์ (decentralized smart contracts)

อีเธอเรียมถูกนำมาอธิบายครั้งแรกในปี 2013 ในเอกสารทางวิชาการที่ถูกเขียนโดย Vitalik Buterin และ ผู้ร่วมก่อตั้งอื่นๆ ได้ระดมทุนสำหรับโปรเจกต์ผ่านทางออนไลน์ในช่วงฤดูร้อนปี 2014 หลังจากนั้น Ethereum Foundation ได้เปิดตัวเหรียญอย่างเป็นทางการเมื่อวันที่ 30 กรกฎาคม 2015 ซึ่งข้อมูลทางเทคนิคของอีเธอเรียมจากเว็บไซต์ [www.coinmarketcap.com](http://www.coinmarketcap.com) สามารถดูได้จากตารางที่ 2.2

ตารางที่ 2.2 ข้อมูลทางเทคนิคของ Ethereum (ETH)

Consensus mechanism	V.1 Prove of Work V.2 Prove of Stake
Hash function	Keccak-256
Circulating supply	122,373,866 (at 17.11.2022)
Supply limit	-
ATH	\$4,891.70

**2.1.1.3 คาร์ดาโน (Cardano: ADA)** เป็นสกุลเงินดิจิทัลที่พัฒนาขึ้นบนโครงการ Cardano blockchain โดยโครงการคาร์ดาโน ถูกสร้างขึ้นโดยบริษัท IOHK (Input Output Hong Kong) ภายใต้การนำของ Charles Hoskinson ที่เป็นผู้ก่อตั้งร่วมของ Ethereum โครงการนี้มีเป้าหมายที่จะสร้างแพลตฟอร์มบล็อกเชนที่ปลอดภัยและมีความมั่นคงเพื่อสนับสนุนการพัฒนาแอปพลิเคชันที่มีประสิทธิภาพสูงในระดับองค์กร

เหรียญคาร์ดาโนจะถูกใช้เป็นส่วนหลักในโครงการ Cardano blockchain และมีหน้าที่เป็นเครื่องมือในการจัดการธุรกรรมภายในเครือข่าย นอกจากนี้คาร์ดาโนยังสามารถใช้ในการโหวตเพื่อเลือกตั้งผู้ปกครองภายในโครงการคาร์ดาโน รวมถึงส่งเสริมความมั่งคั่งของชุมชนผู้ถือคาร์ดาโนอีกด้วย

ADA ได้รับการจัดจำหน่ายผ่านกระบวนการ Initial Coin Offering (ICO) ในปี 2017 โดยการจัดจำหน่ายมีจำนวนจำกัด จำนวนคาร์ดาโนที่จะถูกสร้างขึ้นมีจำนวนคงที่อยู่ที่ 45,000,000,000 เหรียญ โดยมีการจัดสร้างคาร์ดาโน ขึ้นมาพร้อมกับเครือข่ายคาร์ดาโน ในขณะนี้คาร์ดาโนยังคงเป็นสกุล

เงินที่มีความนิยมในวงกว้างและมีการซื้อขายบนแพลตฟอร์มการซื้อขายสกุลเงินดิจิทัลต่างๆ ซึ่งข้อมูลทางเทคนิคของคาร์ดาโนจากเว็บไซต์ [www.coinmarketcap.com](http://www.coinmarketcap.com) สามารถดูได้จากตารางที่ 2.3

ตารางที่ 2.3 ข้อมูลทางเทคนิคของ Cardano (ADA)

Consensus mechanism	Prove of Stake
Hash function	BLAKE2b-224 BLAKE2b-256
Circulating supply	35,157,347,936 (at 17.11.2022)
Supply limit	45,000,000,000
ATH	\$3.101

**2.1.1.4 โซโลน่า (Solona: SOL)** ถูกสร้างขึ้นด้วยจุดประสงค์เพื่อที่จะให้บริการโซลูชันการเงินแบบกระจายอำนาจ (Decentralized Finance: DiFi) โดยมีผู้ก่อตั้งคือ Anatoly Yakovenko และ Greg Fitzgerald ซึ่งแนวคิดในโปรเจกต์นี้เริ่มขึ้นในปี 2017 หลังจากนั้นในเดือนมีนาคม ปี 2022 ได้ทำการเปิดตัว โดยกลุ่มผู้ก่อตั้งโซโลน่าซึ่งมีสำนักงานใหญ่อยู่ที่ Geneva, Switzerland

Solona ถูกออกแบบมาเพื่ออำนวยความสะดวกในการสร้างแอปพลิเคชันแบบกระจายอำนาจ (Decentralized App: DApp) ซึ่งเป้าหมายของมันคือการเพิ่ม scalability โดยใช้เทคนิค proof-of-history (POH) บวกกับ proof of stake (POS) ในการแก้ไขข้อบกพร่อง ซึ่งข้อมูลทางเทคนิคของคาร์ดาโนจากเว็บไซต์ [www.coinmarketcap.com](http://www.coinmarketcap.com) สามารถดูได้จากตารางที่ 2.4

ตารางที่ 2.4 ข้อมูลทางเทคนิคของ Solona (SOL)

Consensus mechanism	Prove of History Prove of Stake
Hash function	SHA-256
Circulating supply	362,656,205.02 (at 17.11.2022)
Supply limit	-
ATH	\$259.96

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.1.2 ข้อมูลอนุกรมเวลา (Time Series Data)

คือ ข้อมูลอนุกรมเวลา (Time Series data) คือ ชุดของข้อมูลที่เก็บรวบรวมตามระยะเวลาเป็นช่วง ๆ อย่างต่อเนื่องกัน เช่น ข้อมูลยอดขายสินค้าที่เก็บรวบรวมต่อเนื่องกันไปเป็นระยะเวลาหลาย ๆ เดือน ข้อมูลมูลค่าสกุลเงินดิจิทัลในแต่ละวันเมื่อปิดทำการซื้อขายในแต่ละวันที่เก็บรวบรวมต่อเนื่องกันไปเป็นระยะเวลาหลาย ๆ ปี เป็นต้น ข้อมูลอนุกรมเวลาอาจอยู่ในลักษณะที่เป็นข้อมูลรายปี รายไตรมาส หรือรายเดือนก็ได้ ทั้งนี้ขึ้นอยู่กับความเหมาะสมในการนำไปใช้ประโยชน์ โดยทั่วไปข้อมูลอนุกรมเวลาประกอบด้วยองค์ประกอบ 4 ส่วน คือ แนวโน้ม (Trend), ฤดูกาล (Seasonal), วัฏจักร (Cycle) และเหตุการณ์ที่ผิดปกติหรือเหตุการณ์ความไม่แน่นอน (Irregular)

อนุกรมเวลาสามารถแบ่งได้ 2 ประเภท ได้แก่

2.1.2.1 อนุกรมเวลาเชิงเดียว (Univariate time series) หมายถึง อนุกรมเวลาที่มีค่าสังเกตที่

สนใจ เพียงค่าเดียว ในแต่ละช่วงเวลา

2.1.2.2 อนุกรมเวลาเชิงพหุ (Multivariate time series) หมายถึง อนุกรมเวลาที่มีค่าสังเกตที่สนใจ มากกว่า 1 ค่า ในแต่ละช่วงเวลา

### 2.1.3 ปัจจัยภายนอกที่มีผลต่อมูลค่าของสกุลเงินดิจิทัล (Cryptocurrency External Factor)

สกุลเงินดิจิทัลนั้นถือเป็นสินทรัพย์รูปแบบใหม่ที่นักลงทุนนั้นให้ความสนใจอย่างมาก ในการคาดการณ์มูลค่าของสกุลเงินดิจิทัลเพื่อที่จะลงทุนและเก็งกำไรให้ได้อย่างเหมาะสม นักลงทุนและนักวิจัยได้มีการศึกษาความสัมพันธ์ระหว่างสกุลเงินดิจิทัลและปัจจัยภายนอกต่างๆ ซึ่งในงานวิจัยนี้ผู้ศึกษาต้องการที่จะศึกษาตัวแปรภายนอกที่มีผลต่อสกุลเงินดิจิทัลแต่ละประเภทเป็นอย่างไร ตัวแปรที่ผู้ศึกษาสนใจมีดังนี้

#### 2.1.3.1 ปริมาณการซื้อขายสกุลเงินดิจิทัล (Cryptocurrency Trading Volume)

คือ ปริมาณการซื้อขายที่เกิดขึ้นกับสกุลเงินดิจิทัลในตลาดทั้งหมดโดยทั่วไปแล้วจะถูกคำนวณรวมภายใน 24 ชม.หรือสรุปทุกวัน ซึ่งตัววัดนี้สามารถบ่งบอกได้ถึงความนิยมของตัวสกุลเงินดิจิทัล ยิ่งปริมาณการซื้อขายมีมากแสดงว่าสกุลเงินดิจิทัลนี้มีความนิยมที่สูงขึ้น ซึ่งปริมาณการซื้อขายนั้นมีความสัมพันธ์โดยตรงกับความผันผวนของราคา หากปริมาณการซื้อนั้นสมดุลกับปริมาณการขายราคาก็จะคงที่ ถ้าหากปริมาณการซื้อมีมากกว่าปริมาณการขาย ก็จะทำให้ราคาดังกล่าวสูงขึ้น ในทางกลับกัน ถ้าปริมาณการขายมีมากกว่าปริมาณการซื้อก็จะส่งผลให้ราคาลดลง

### 2.1.3.2 ดัชนีความกลัวและความโลภ (Fear and greed Index)

คือดัชนีที่ถูกใช้เพื่อวัดอารมณ์และความรู้สึกของนักลงทุนที่มีต่อตลาด ตัวชี้วัดนี้สามารถบ่งบอกให้เห็นได้ว่าตลาดนั้นเป็นตลาดกระทิงหรือตลาดหมีซึ่งตัวดัชนีนี้ถูกสร้างขึ้นจากความกลัวและความโลภของนักลงทุนในตลาด

ระดับค่าความกลัวและความโลภนั้นจะอยู่ระหว่าง 0-100 โดยที่ค่า 0 นั้นหมายถึง กลัวสุดขีดในขณะที่ 100 หมายถึงโลภสุดขีด

การคำนวณดัชนีความกลัวและความโลภนั้นมาจากการคำนวณค่าเฉลี่ยถ่วงน้ำหนักจากเครื่องมือชี้วัด (indicator) ทั้งหมด 5 ตัว ได้แก่

#### 1. ความผันผวนของตลาด (Volatility) (25%)

ความผันผวนนั้นเปรียบเทียบจากราคาปิดของเหรียญในปัจจุบันแล้วค่าสูงสุดของมันที่ลดลงจากค่าเฉลี่ยจาก 30 วันและ 90 วัน เมื่อค่าความผันผวนพุ่งขึ้นสูงนั้นมีความเป็นไปได้ว่าตลาดกำลังกลัว

#### 2. โมเมนตัมและปริมาณการซื้อขาย (Market Momentum/Volume) (25%)

คำนวณจากโมเมนตัมและปริมาณการซื้อขาย และเปรียบเทียบค่าเฉลี่ยย้อนหลัง 30 วันและ 90 วัน เมื่อโมเมนตัมกลับตัวขึ้นอย่างแรงแสดงว่าตลาดเป็นช่วงขาขึ้น

#### 3. สื่อสังคม (Social Media) (15%)

ตัวบ่งชี้ใช้ข้อมูล like, post และ hashtags ที่เกี่ยวกับสกุลเงินดิจิทัลมาวิเคราะห์ จาก twitter เพื่อวิเคราะห์อารมณ์และความรู้สึก ถ้าตัวบ่งชี้สื่อสังคมนั้นมีค่าสูงขึ้นแสดงว่าตลาดกำลังมีความโลภ

#### 4. ความมีอำนาจเหนือกว่า Dominance (10%)

คำนวณจาก สัดส่วนของ Bitcoin ในตลาดต่อ Altcoin โดยมอง Bitcoin เป็นที่ปักเงินเมื่อเกิดความกลัวขึ้นในตลาด และมอง Altcoin เพื่อการเก็งกำไรเท่านั้น ซึ่งถ้าสัดส่วน Bitcoin ในตลาดยิ่งมากหมายถึงตลาดเข้าสู่ช่วงขาลง

#### 5. แนวโน้ม (Trends) (10%)

เป็นแนวโน้มจากการค้นหาใน Google Search Trends ที่เกี่ยวข้องกับ Bitcoin ซึ่งถ้ามีการค้นหาเยอะก็จะสะท้อนให้เห็นว่านักลงทุนให้ความสนใจกับตลาด และอาจมีความโลภเกิดขึ้น

#### 6. แบบสำรวจ (Surveys) (15%) - ปัจจุบันได้ยกเลิกไปแล้ว

ใช้แพลตฟอร์มในการสำรวจชื่อ strawpoll.com เก็บข้อมูลว่ารู้สึกอย่างไรกับตลาดทุกๆ อาทิตย์โดยปกติจะมีคนโหวตประมาณ 2,000-3,000 คน เพื่อที่จะได้เห็นภาพอารมณ์ความรู้สึกของนักลงทุนในตลาด

### 2.1.3.3 อัตราดอกเบี้ยสหรัฐอเมริกา (Interest Rate of the United States)

คืออัตราดอกเบี้ยที่ธนาคารกลางของสหรัฐอเมริกา (Federal Reserve) กำหนดเพื่อควบคุมการกำหนดราคาเงินยืมระหว่างธนาคาร อัตราดอกเบี้ยส่งผลต่อค่าเงินที่ธนาคารสามารถกู้ยืมจากธนาคารกลางได้ ซึ่งมีผลต่อการกู้ยืมเงินของบุคคล ธุรกิจ และภาครัฐในประเทศ รวมถึงมีผลต่ออัตราแลกเปลี่ยนเงินตราของประเทศกับต่างประเทศด้วย

การตัดสินใจเกี่ยวกับอัตราดอกเบี้ยของสหรัฐอเมริกาดำเนินการโดยคณะกรรมการนโยบายการเงินของธนาคารกลางสหรัฐอเมริกา (Federal Open Market Committee - FOMC) โดยผลกระทบจากภาวะเศรษฐกิจ สถานการณ์การเงิน และเป้าหมายการเสริมสร้างเศรษฐกิจจะมีผลต่อการกำหนดอัตราดอกเบี้ย อัตราดอกเบี้ยสูงส่งผลให้การกู้ยืมแพงขึ้นและกระตุ้นการออกแบบริยะสั้น ในขณะที่อัตราดอกเบี้ยต่ำส่งผลให้การกู้ยืมถูกลงและส่งเสริมการลงทุน

อัตราดอกเบี้ยสหรัฐอเมริกา (Interest Rate of the United States) อาจมีผลกระทบต่อ บิทคอยน์ ในลักษณะต่อไปนี้

1. การเปลี่ยนแปลงในอัตราดอกเบี้ยสามารถส่งสัญญาณให้ผู้ลงทุนปรับตัวและประเมินความเสี่ยงในการลงทุนในบิทคอยน์ และสินทรัพย์อื่น ๆ หากอัตราดอกเบี้ยสูงขึ้น อาจทำให้ผู้ลงทุนมีแนวโน้มเลือกลงทุนในสินทรัพย์ที่ให้ผลตอบแทนที่สูงกว่าบิทคอยน์ ซึ่งอาจทำให้ราคาของบิทคอยน์ลดลง
2. อัตราดอกเบี้ยสูงสามารถเป็นปัจจัยที่ส่งผลให้นักลงทุนที่กำลังคาดหวังได้รับผลตอบแทนจากการลงทุนในสินทรัพย์ที่มีอัตราผลตอบแทนที่แน่นอน ซึ่งอาจลดปริมาณเงินที่ถูกลงทุนในบิทคอยน์และส่งผลให้ราคาของบิทคอยน์ลดลง
3. การเปลี่ยนแปลงในอัตราดอกเบี้ยสามารถส่งสัญญาณให้ผู้ลงทุนมองว่าสถานะเศรษฐกิจของสหรัฐอาจมีความเสี่ยงสูงหรือน่าเชื่อถือน้อยลง ซึ่งอาจกระทบต่อการมีความสนใจในการลงทุนในสินทรัพย์ที่มีความเสี่ยงสูงเช่น ซึ่งอาจส่งผลให้ราคาของบิทคอยน์ลดลงหรือเพิ่มขึ้นได้

### 2.1.3.4 อัตราเงินเฟ้อสหรัฐอเมริกา (Inflation rate of United States)

อัตราเงินเฟ้อ (Inflation rate) ในสหรัฐอเมริกาหมายถึงอัตราการเพิ่มขึ้นของระดับราคาสินค้าและบริการในเศรษฐกิจของประเทศนั้น ซึ่งสามารถวัดได้โดยใช้ตัวชี้วัด CPI (Consumer Price Index) ซึ่งเป็นตัวชี้วัดระดับราคาของสินค้าและบริการที่ผู้บริโภคใช้ในชีวิตประจำวัน อัตราเงินเฟ้อจะแสดงเป็น เปอร์เซ็นต์ต่อปีหรือต่อระยะเวลาที่กำหนด ตัวอย่างเช่น หากอัตราเงินเฟ้อของสหรัฐอเมริกาคือ 2% ต่อปี แปลว่าระดับราคาของสินค้าและบริการ ในสหรัฐอเมริกาคือเพิ่มขึ้นเฉลี่ยประมาณ 2% ต่อปี

อัตราเงินเพื่อสหรัฐอเมริกาสามารถมีผลต่อเศรษฐกิจและผู้บริโภคในหลายๆ ด้าน เช่น การซื้อสินค้าและบริการที่แพงขึ้น การส่งเสริมการลงทุนในทรัพยากรและทรัพย์สิน การปรับตัวให้เข้ากับการเปลี่ยนแปลงในรายได้ และการกำหนดนโยบายเศรษฐกิจโดยรัฐบาล เพื่อช่วยควบคุมอัตราเงินเพื่อให้เกิดสถานะเศรษฐกิจที่เสถียรและคงที่มากยิ่งขึ้น

อัตราตราเงินเพื่อของสหรัฐอเมริกาอาจมีผลกระทบต่อบิตคอยน์ในลักษณะต่อไปนี้การเพิ่มขึ้นของอัตราเงินเพื่อ: เมื่อมีการเพิ่มขึ้นของอัตราเงินเพื่อในสหรัฐอเมริกา อาจส่งผลให้ผู้คนเลือกลงทุนในสินทรัพย์เพื่อปกป้องค่าเงินของพวกเขา ซึ่งอาจส่งผลให้บิตคอยน์กลายเป็นทางเลือกที่น่าสนใจสำหรับการลงทุน โดยเฉพาะอย่างยิ่งเมื่อบิตคอยน์ถือเป็นสกุลเงินที่มีฐานะเป็น "ทองคำดิจิทัล" หรือ สกุลเงินที่มีความคงที่สูงกว่าสกุลเงินดัชนีทั่วไป

ความเสี่ยงและความผันผวน: บิตคอยน์เป็นสกุลเงินที่มีความผันผวนสูง อัตราเงินเพื่อที่เปลี่ยนแปลงอาจส่งผลให้มีความเสี่ยงและความผันผวนในราคาของบิตคอยน์มากขึ้น เนื่องจากผู้คนอาจเริ่มสนใจเปลี่ยนแปลงสกุลเงินเพื่อหาความคงที่และการลงทุนที่น่าเชื่อถือ

ความสัมพันธ์กับสถานการณ์เศรษฐกิจ: อัตราเงินเพื่อสามารถเป็นตัวบ่งชี้ในการวิเคราะห์สถานการณ์เศรษฐกิจ หากมีการเพิ่มขึ้นของอัตราเงินเพื่อในสหรัฐอเมริกาเนื่องจากความผันผวนของเศรษฐกิจ อาจมีผลต่อภาพรวมของตลาดสกุลเงินดิจิทัลรวมถึงบิตคอยน์

การตรวจสอบการลงทุนและการซื้อขาย: อัตราเงินเพื่อที่เปลี่ยนแปลงอาจส่งผลให้ผู้คนตรวจสอบและปรับปรุงกลยุทธ์การลงทุนและการซื้อขายของพวกเขา การเปลี่ยนแปลงในอัตราแลกเปลี่ยนอาจส่งผลต่อความเสี่ยงและกำไรที่เกิดขึ้นในการซื้อขายบิตคอยน์

#### 2.1.4 แบบจำลองสำหรับการทำนายชุดข้อมูลอนุกรมเวลา (Model For Time series Forecasting)

การทำพยากรณ์ข้อมูลอนุกรมเวลานั้นสามารถทำได้หลายวิธีโดยจะถูกแบ่งออกเป็น 2 วิธีด้วยกัน คือวิธีแบบ แบบจำลองทางสถิติ (Statistic Model) และ แบบจำลองการเรียนรู้เชิงลึก (Deep Learning Model) ซึ่งในการศึกษานี้ ผู้วิจัยได้ทำการเลือกแบบจำลองที่เป็นที่นิยมในการพยากรณ์ราคา เพื่อเปรียบเทียบผลลัพธ์ที่ได้ ดังนี้

##### 2.1.4.1 ARIMAX

หรือ ชื่อเต็มคือ Autoregressive Integrated Moving Average with Explanatory Variable เป็นการอธิบายร่วมกันของแบบจำลอง ARIMA กับตัวแปรภายนอกหรือปัจจัยอื่น (x) ที่น่าจะมีอิทธิพลต่อราคาบิตคอยน์ ทั้งนี้ (x) ในการศึกษานี้ คือ ปริมาณการซื้อขายสกุลเงินดิจิทัล ดัชนีความ

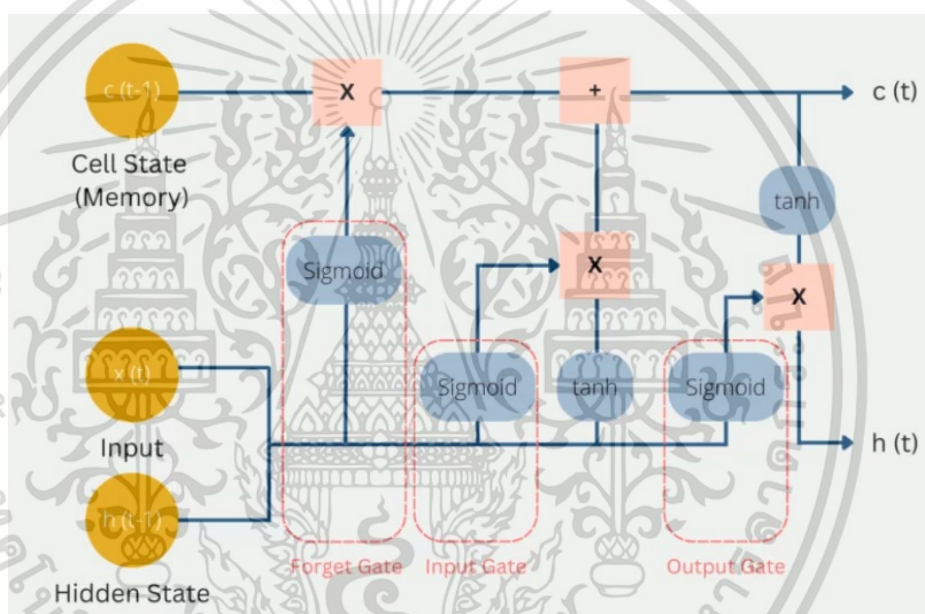
กลัวและความโลภต่อบิทคอยน์ อัตราดอกเบี้ยของสหรัฐอเมริกา และ อัตราเงินเฟ้อของสหรัฐอเมริกา  
สูตรในการคำนวณของ ARIMAX ประกอบด้วยส่วนต่างๆดังนี้

$$\Delta^d y_t = \alpha + \phi_1 \Delta^d y_t + \dots + \phi_p \Delta^d y_{t-p} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (2.1)$$

โดยที่	$y_t$	คือ	ค่าสังเกตในอนุกรมเวลา ณ เวลา t
	d	คือ	จำนวนครั้งของการหาผลต่างเพื่อให้อนุกรมเวลามีคุณสมบัติคงที่ (Stationary)
	p	คือ	อันดับของ Autoregressive
	q	คือ	อันดับของ Moving Average
	$\alpha$	คือ	ค่าคงที่ (Constant Term)
	t	คือ	เวลา
	$\Delta$	คือ	ผลต่าง
	$\phi_1, \dots, \phi_p$	คือ	พารามิเตอร์ Autoregressive
	$\theta_1, \dots, \theta_q$	คือ	พารามิเตอร์ Moving Average
	$\varepsilon_t$	คือ	กระบวนการ white noise หรือค่าความคลาดเคลื่อน ณ เวลา ภายใต้ข้อสมมติที่ว่าความคลาดเคลื่อนที่คนละเวลาเป็นตัวแปรสุ่ม ที่เป็นอิสระต่อกัน โดยมีการแจกแจงปกติที่มีค่าเฉลี่ยเป็นศูนย์และ ความแปรปรวนคงที่
	$\beta_0, \beta_1$	คือ	พารามิเตอร์ของตัวแปร x
	$x_t, x_{t-1}$	คือ	ปัจจัยภายนอก

#### 4.1.4.2 แบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM)

แบบจำลองหน่วยความจำระยะสั้นแบบยาว (LSTM) เป็นรูปแบบหนึ่งของโครงข่ายระบบประสาทแบบย้อนกลับ (RNN) เพื่อแก้ปัญหาการลดลงของเกรเดียนต์ (Vanishing Gradient) เมื่อลำดับของข้อมูลที่ได้รับเข้ามามีจำนวนมากเกินไป โดยการทำงานของ LSTM นั้นจะมีความคล้ายคลึงกับ RNN แต่ในส่วนของชั้นซ่อน (Hidden state) ที่ใช้สำหรับจดจำลำดับของข้อมูลก่อนหน้านั้น LSTM จะมีการเรียนรู้ว่า เมื่อใดควรลืม (Forget) เขียน (Write) หรืออนุญาตให้อ่าน (Read) ซึ่งทำให้สามารถรองรับข้อมูลที่มีลำดับปริมาณมากที่เข้ามาได้



ภาพที่ 2.1 สถาปัตยกรรมแบบจำลองหน่วยความจำระยะสั้นแบบยาว

ที่มา : <https://databasecamp.de/en/ml/lstms>

จากภาพที่ 2.1 สถาปัตยกรรมของ LSTM นั้นประกอบมีส่วนประกอบที่สำคัญดังนี้

1. Cell State ( $C_t$ ): เป็นเซลล์สถานะที่ใช้เก็บและควบคุมข้อมูลที่ผ่านผ่านเครือข่าย LSTM ในระหว่างการทำงาน โดยเซลล์สถานะจะช่วยในการจำแนกและควบคุมข้อมูลที่จำเป็นในการทำนายและวิเคราะห์ข้อมูลเวลา
2. Input Gate ( $i_t$ ): เป็นประตูที่ช่วยในการควบคุมการเข้าสู่เซลล์สถานะ ( $C_t$ ) โดยแยกแยะว่าข้อมูลใดจะถูกนำเข้าไปยังเซลล์สถานะและมีน้ำหนักแตกต่างกันเพื่อควบคุมข้อมูล

3. Forget Gate (f): เป็นประตูที่ช่วยในการควบคุมและลืมข้อมูลที่ไม่เกี่ยวข้องหรือไม่สำคัญออกจากเซลล์สถานะ (Ct) โดยอนุญาตให้ข้อมูลที่ไม่สำคัญถูกล้างออกไป
4. Output Gate (o): เป็นประตูที่ช่วยในการควบคุมและเลือกข้อมูลที่จะถูกส่งออกจากเซลล์สถานะ (Ct) เพื่อนำไปใช้งานต่อในกระบวนการทำนายและวิเคราะห์ข้อมูล
5. Hidden State (ht): เป็นสถานะที่เก็บข้อมูลระหว่างการทำงานของเครือข่าย LSTM ที่ใช้เพื่อให้ข้อมูลไปสู่เซลล์ LSTM ในรอบถัดไป โดยเรียกว่า hidden state เนื่องจากค่านี้ไม่ถูกเผยแพร่ ออกนอกโมเดล

LSTM ประกอบด้วยเลเยอร์หลายๆ ชั้นซึ่งมีหน้าที่ในการทำงานและเชื่อมต่อกันเพื่อประมวลผลข้อมูลเวลา โดยลำดับของเลเยอร์ใน LSTM สามารถแสดงได้เป็นนี้:

Input Layer: รับข้อมูลเวลาเป็นข้อมูลนำเข้าสำหรับการทำนายและวิเคราะห์


LSTM Layer: เลเยอร์ LSTM ที่ประมวลผลข้อมูลเวลาและรักษาสถานะและความสัมพันธ์ของข้อมูลในแต่ละเวลา

Output Layer: ส่งผลลัพธ์ที่ทำนายหรือวิเคราะห์ออกมาในรูปแบบที่ต้องการ เช่น ค่าที่ทำนายข้อมูลในข้อมูลเวลาถัดไป

ซึ่งในแต่ละชั้นของ LSTM มีการคำนวณและการปรับค่าของเมตริกซ์ที่มีความสำคัญเพื่อให้เครือข่าย LSTM สามารถจัดการและวิเคราะห์ข้อมูลเวลาได้ในลักษณะที่เหมาะสม

### 2.1.4.3 XGBoost (eXtreme Gradient Boosting)

XGBoost เป็นเทคนิคที่พัฒนามาจาก Gradient Boosting ซึ่ง XGBoost เป็นแบบจำลองที่นำเอาต้นไม้ตัดสินใจมาฝึกสอนต่อกันหลาย ๆ ต้น โดยที่ต้นไม้ตัดสินใจแต่ละต้นจะเรียนรู้จากค่าความผิดพลาดของต้นก่อนหน้า ซึ่งทำให้ความแม่นยำในการทำนายจะมากขึ้นเรื่อย ๆ เมื่อมีการเรียนรู้ของต้นไม้ตัดสินใจต่อเนื่องกันจนมีความลึกมากพอ แบบจำลองจะหยุดเรียนรู้เมื่อไม่เหลือค่าความผิดพลาดจากต้นไม้ตัดสินใจต้นก่อนหน้าให้เรียนรู้แล้ว (ภูมิวุฒิสาร, 2561) ซึ่งค่าผลลัพธ์การทำนายของ XGBoost นั้นคือผลรวมของผลลัพธ์จากต้นไม้ตัดสินใจทั้งหมด (Decision Tree)



ภาพที่ 2.2 สถาปัตยกรรมของ XGBoost

ที่มา : Y. Wang, Z. Pan, J. Zheng, L. Qian, M. Li (2019). A hybrid ensemble method for pulsar candidate classification. *Astrophys Space Sci* (2019), 364,139. DOI:10.1007/s10509-019-3602-4

#### 2.1.4.4 Facebook Prophet (FBProphet)

Facebook Prophet คือชุดเครื่องมือและไลบรารีที่พัฒนาโดย Facebook เพื่อใช้ในการทำนายและโมเดลชุดข้อมูลเวลา (time series data) โดยเฉพาะในส่วนของการทำงานและการวิเคราะห์ชุดข้อมูลที่มีความซับซ้อนตามแบบฉบับของเวลาจริง

Prophet มีความสามารถที่มีประสิทธิภาพในการจัดการกับลักษณะพิเศษของข้อมูลเวลา เช่น การจัดสรรหน่วยเวลาที่ขาดหายไป (missing data) และความผิดปกติที่อาจเกิดขึ้น โดยมีความสามารถในการรับมือกับแบบแผนของเทรนด์ (trends) และประวัติการเกิดขึ้นซ้ำๆ ในชุดข้อมูลเวลา เครื่องมือและไลบรารี Prophet นำเสนอโครงสร้างแบบกำหนดเองที่ใช้ในการวิเคราะห์ข้อมูลเวลา โดยประกอบด้วยสองส่วนหลัก:

1. Trend Component Modeling: Prophet จะสร้างโมเดลและโครงสร้างที่เกี่ยวข้องกับแนวโน้มของข้อมูลเวลา ทั้งแนวโน้มที่เป็นเส้นตรง (linear trend) และแนวโน้มที่เปลี่ยนแปลงได้ (non-linear trend) โดยใช้การกำหนดของผู้ใช้งาน โดยทั่วไป Prophet สามารถจัดการกับแนวโน้มประจำปี (yearly seasonality) และแนวโน้มประจำสัปดาห์ (weekly seasonality) ได้อย่างมีประสิทธิภาพ

2. Seasonality Component Modeling: Prophet สามารถจัดการกับประจำกลางวัน (daily seasonality) และประจำเดือน (monthly seasonality) โดยอัตโนมัติ โดยการค้นหาและการปรับเพื่อให้สอดคล้องกับลักษณะการเกิดขึ้นแบบฉบับของข้อมูล

Prophet มีการใช้งานที่เป็นมาตรฐานและใช้งานง่ายในรูปแบบของ Python สามารถนำไปใช้ในงานทำนายและวิเคราะห์ข้อมูลเวลาในหลากหลายอุตสาหกรรม เช่น การวิเคราะห์ภาพยนตร์ การทำนายยอดขายสินค้า การทำนายการใช้พลังงาน และอื่นๆ

สูตรในการคำนวณของ Facebook Prophet ประกอบด้วยส่วนต่างๆดังนี้

$$y(t) = g(t) + s(t) + h(t) + e(t) \quad (2.2)$$

โดยที่	$g(t)$	คือ	ค่าแนวโน้ม
	$s(t)$	คือ	ค่าฤดูกาล
	$h(t)$	คือ	ค่าที่มีผลกระทบต่อวันหยุดหรือเหตุการณ์พิเศษ
	$e(t)$	คือ	ค่าความคลาดเคลื่อน
	$y(t)$	คือ	ค่าที่ถูกทำนาย
	$t$	คือ	เวลา


#### 2.2.4.5 N-BEATS

เป็นโมเดลเรียนรู้เชิงลึก (deep learning model) ที่ถูกใช้ในงานทางการทำนายแบบชุดข้อมูลชุดเวลา (time series forecasting) โดย N-Beats ได้ถูกพัฒนาขึ้นโดยทีมวิจัยของ Google Research เป็นความร่วมมือระหว่างหน่วยงาน Google Brain และ Google AI.

N-Beats ถูกออกแบบให้เป็นโมเดลที่เหมาะสมสำหรับการทำนายชุดข้อมูลชุดเวลาที่มีความซับซ้อนและหลากหลาย โดยใช้โครงสร้างของบล็อกสองชนิด คือ Backcast Block และ Forecast Block. Backcast Block ใช้ในการเรียนรู้และทำนายค่าย้อนหลังของชุดข้อมูลชุดเวลา ในขณะที่ Forecast Block ใช้ในการทำนายค่าข้างหน้าของชุดข้อมูลชุดเวลา

โดยสำหรับแต่ละบล็อก จะประกอบไปด้วยเลเยอร์ที่มีการเชื่อมต่อกัน ได้แก่ Linear Layer, Gated Residual Network (GRN), และ เลเยอร์ที่ใช้ในการทำนาย เช่น Feed-Forward Neural Network (FFN) โดยตัวโมเดลจะถูกเรียนรู้ในขั้นตอน Backcast และใช้ในการทำนายในขั้นตอนการทำนาย N-Beats มีความสามารถในการจัดการกับข้อมูลชุดข้อมูลชุดเวลาที่มีความหลากหลายและ

ความซับซ้อน และสามารถปรับแต่งโมเดลเพื่อตรงกับความต้องการและลักษณะของชุดข้อมูลได้ การออกแบบสถาปัตยกรรมของ N-Beats นั้นแสดงได้ดังภาพที่ 2.3



ภาพที่ 2.3 สถาปัตยกรรมของ N-Beats

ที่มา : Boris N., Dmitri C., Nicolas C., Yoshua B. (2020). N-BEATS: NEURAL

BASIS EXPANSION ANALYSIS FOR INTERPRETABLE TIME SERIES FORECASTING. ICLR 2020,3.

#### 2.1.4.6 Temporal Fusion Transformer (Google)

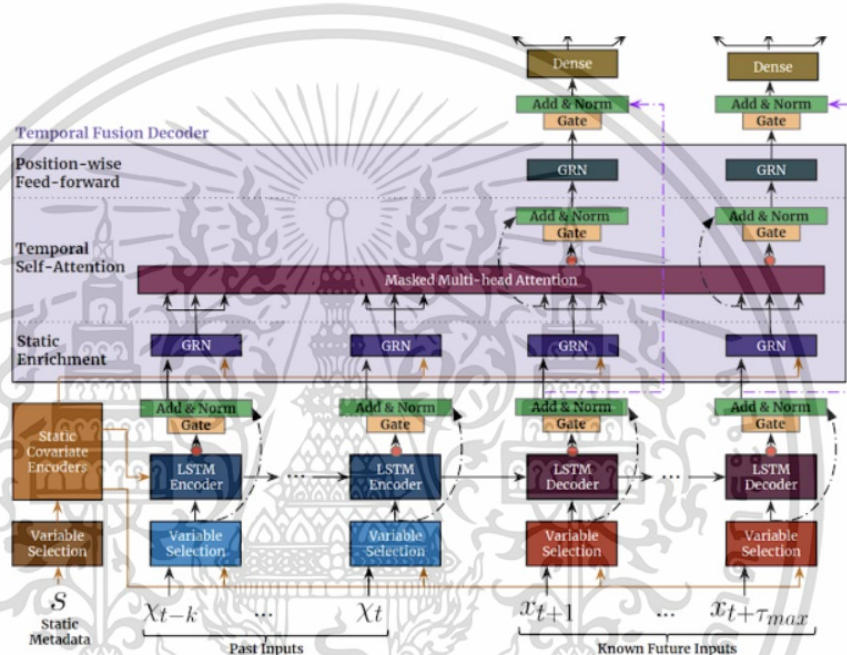
Temporal Fusion Transformer (TFT) เป็นโมเดลที่ถูกพัฒนาโดยทีมวิจัยของ Google ใช้สำหรับการทำนายและโมเดลชุดข้อมูลชุดเวลา (time series forecasting) โดยเฉพาะ โมเดลนี้ผสมผสานคุณสมบัติของ Transformer และเทคนิคการประมวลผลแบบพื้นฐานและชุดข้อมูลชุดเวลา

TFT ใช้โครงสร้างของ Transformer ซึ่งเป็นโมเดลเรียนรู้เชิงลึกที่พัฒนาขึ้นเพื่อการประมวลผลและแปลงข้อมูลที่มีความสัมพันธ์ต่างๆ ในกรณีของ TFT โมเดลนี้ถูกออกแบบให้เหมาะสำหรับการทำนายและโมเดลชุดข้อมูลชุดเวลาที่มีความซับซ้อนและหลากหลาย

TFT ใช้หลักการทำงานแบบแยกส่วน (decomposition) เพื่อแบ่งประเด็นของการทำนายชุดข้อมูลชุดเวลาเป็นส่วนย่อย โดยแยกคุณลักษณะ (feature) ของชุดข้อมูลชุดเวลาออกเป็นส่วนๆ เช่น คุณลักษณะเวลา, คุณลักษณะภูมิศาสตร์ และคุณลักษณะอื่นๆ แล้วจึงทำนายแต่ละส่วนแยกกัน โดยใช้แบบจำลองที่เหมาะสมกับแต่ละส่วน

นอกจากนี้ TFT ยังมีการนำเอาความรู้และข้อมูลที่อยู่ในระบบเชิงสนับสนุน (contextual information) ของชุดข้อมูลชุดเวลามาใช้ ซึ่งสามารถช่วยเพิ่มประสิทธิภาพในการทำนาย โดยใช้ข้อมูลภายนอกเช่น ข้อมูลปริมาณการขาย, ข้อมูลเชิงภูมิศาสตร์ เป็นต้น

TFT เป็นโมเดลที่มีความยืดหยุ่นและสามารถปรับแต่งได้ตามลักษณะของชุดข้อมูลชุดเวลาที่ต้องการทำนาย และมีประสิทธิภาพในการจัดการกับชุดข้อมูลชุดเวลาที่มีความซับซ้อนและหลากหลาย ซึ่งภาพที่ 2.4 เป็นสถาปัตยกรรมของ TFT



ภาพที่ 2.4 สถาปัตยกรรมของ Temporal Fusion Transformer (Google)

ที่มา : Bryan L., Sercan O., Nicolas L., Tomas P. (2020). Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. Elsevier 2020,6.

## 2.2 งานวิจัยที่เกี่ยวข้อง

ในส่วนนี้จะทำการสรุปงานวิจัยที่เกี่ยวข้องกับการทำนายราคาและแบบจำลองแบบต่างๆที่ได้มีการวิจัยไว้ก่อนหน้าดังตารางที่ 2.5

ตารางที่ 2.5 สรุปงานวิจัยที่เกี่ยวข้อง

ผู้วิจัย	ปี	เรื่อง	ปัจจัยภายนอก	วิธีวิเคราะห์	ข้อค้นพบ
Edward M Ruiz	2014	Forecasting Exchange Rate Volatility with High Frequency Bitcoin Data : Is digital currency really that different?	- อัตราแลกเปลี่ยนบิตคอยน์ต่อดอลลาร์สหรัฐอเมริกา ดอลลาร์ออสเตรเลีย ยูโร และเยน	Generalized Autoregressive Conditional Heteroscedasticity (GARCH)	ผลเก็งกำไรเมื่อประกาศใช้สกุลเงินดิจิทัล พบในบิตคอยน์มากกว่า USD, YEN, AUD และ Euro ที่ผันผวนสูง และมีความแตกต่างระหว่างการคาดการณ์และจำนวนเงินที่เก็งกำไร
Sean McNally	2016	Predicting the price of Bitcoin using Machine Learning	-ราคาเปิดปิดและราคาสูงสุดต่ำสุดของบิตคอยน์ในแต่ละวัน -ความเร็วในการขุดบิตคอยน์ -ความยากในการขุดบิตคอยน์	-Machin Learning -RNN -LSTM -Time Series Analysis	การดำเนินงานของ Bayesian Optimized Recurrent Neural Network และ Long Short Term Memory Network มีความแม่นยำสูงสุดคือ 52 % และ RMSE 8% และแบบจำลอง ARIMA เป็นแบบจำลองที่นิยมนำมาเปรียบเทียบกับแบบจำลองการเรียนรู้เชิงลึก
Muhammad J Amjad and Devavrat	2017	Trading Bitcoin and Online Time Series Prediction	-อัตราแลกเปลี่ยนบิตคอยน์ -อัตราผลตอบแทนจากการลงทุน	-ARIMA	ราคาของบิตคอยน์มีคุณสมบัติหยุดนิ่งและการผสมอัลกอริทึมการจำแนกประเภทและการเรียนรู้การรู้จำการแจกแจงแบบเจ็อนไซเชิงประจักษ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.5 (ต่อ)

					โดยตรง (EC) ดีกว่า ARIMA และ Sharp Ratio มากกว่า 2.0 โดยเฉลี่ยเป็นผลตอบแทนจากการทดสอบในช่วง 2-4 เดือน
Wang Zhengyang Li Xingzhou Ruan Jinjin	2019	Prediction of Cryptocurrency Price Dynamics with Multiple Machine Learning Techniques	-ใช้ราคาของสกุลเงินดิจิทัลอื่น ๆ ได้แก่ BTC ETH XRP XLM LTC และ XMR	-ANN -LSTM -วิเคราะห์ช่วงเวลาที่แตกต่างกันในการทำนาย	LSTM เหมาะกับการทำนายข้อมูลอนุกรมเวลามากกว่า ANN การใช้ข้อมูลราคาของสกุลเงินอื่น ๆ ให้ผลลัพธ์ที่ดีขึ้นในการทำนายราคาบิตคอยน์ในช่วงเวลาที่ใช้นั้นการทำนายส่งผลต่อค่าความผิดพลาดของการทำนายเป็นอย่างสูง
Yan Pang Ganeshkumar Sundararaj and Jiewen Ren	2019	Cryptocurrency Price Prediction Using Time Series and Social Sentiment Data	-ข้อมูลอารมณ์ความรู้สึก	-ARIMA -ARIMAX -LSTM	ตัวแบบที่ใช้ข้อมูลอารมณ์ความรู้สึกนั้นให้ผลลัพธ์ที่ดีกว่าในการหาความสัมพันธ์ที่ไม่ใช่เชิงเส้นซึ่งตัวแบบที่ให้ผลลัพธ์ที่ดีที่สุดคือ ตัวแบบโครงข่ายประสาท เมื่อเปรียบเทียบกับตัวแบบอื่นๆ
Yu Wang and Runyu Chen	2020	Cryptocurrency price prediction based on multiple market sentiment	-อารมณ์ความรู้สึกจากสื่อสังคมออนไลน์ -ข้อมูลการรีวิว -price premium rate ในตลาดที่แตกต่างกัน	-LSTM -RNN -SVM -BPNN -RBF	การใช้ price premium rate ในตลาดที่ต่างกันนั้นส่งผลต่อราคาที่ถูกทำนายและการเพิ่มคอมเม้นจากสื่อสังคมออนไลน์ช่วยเพิ่มความแม่นยำให้กับแบบจำลองอย่างมีนัยสำคัญ
ภูมิชาย จิตชัย โอม ศรีนิล	2021	การทำนายดัชนีหุ้นด้วยการใช้แบบจำลองการเรียนรู้เชิงลึก	-ราคาเปิด -ราคาสูงสุด -ราคาต่ำสุด -ราคาปิด -ปริมาณการซื้อขาย	-CNN -LSTM -LSTM แบบ encoder	แบบจำลองที่ให้ความแม่นยำสูงสุดคือ CNN ที่ใช้ตัวแปรแบบตัวแปรเดียว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.5 (ต่อ)

Giulia Serafini Ping Yi Qingquan Zhang Marco Brambillay, Jiayue Wangk, Yiwei Hu and Beibei L	2022	Sentiment-Driven Price Prediction of the Bitcoin based on Statistical and Deep Learning Approaches	-ปริมาณการซื้อขายบิทคอยน์ -อารมณ์ความรู้สึกจาก twitter -ปริมาณข้อความบนเกี่ยวกับบิทคอยน์บน twitter	-ARIMAX -LSTM	การใช้ข้อมูลอารมณ์ความรู้สึกจาก twitter ช่วยให้ตัวแบบมีประสิทธิภาพมากขึ้น ผลลัพธ์ที่ได้จากการศึกษาพบว่า ARIMAX ซึ่งเป็นตัวแบบทางสถิติ ให้ผลลัพธ์ที่ดีกว่า LSTM ที่เป็นการเรียนรู้แบบโครงข่ายประสาท ไม่เสมอไปที่ตัวแบบการเรียนรู้เชิงลึกจะให้ผลลัพธ์ที่ดีกว่าตัวแบบทางสถิติ
Andras Ferenczi Costin Badic	2022	Prediction of Ether Prices Using DeepAR and Probabilistic Forecasting	-ราคา Gas ต่อธุรกรรม -ราคา Ether -ราคา Matic -มูลค่าการโอนย้ายต่อธุรกรรม(Value Transfer by Transaction) -Committed transactions -ค่าการโอนย้ายโทเคน (Token Transfer) -เหตุการณ์สัญญา (Contract Events) -ปริมาณการใช้ Gas ต่อ ธุรกรรม	-DeepAR -วิเคราะห์ด้วย dynamic feature prediction technique	กลุ่มของปัจจัยภายนอกตัวแบบที่ผลลัพธ์ที่ดีที่สุดเลือกใช้ คือ ราคา Ether, มูลค่าการโอนย้ายต่อธุรกรรม,ค่าการโอนย้ายโทเคน, Committed transactions และปริมาณการใช้ Gas ต่อ ธุรกรรม DeepAR มีประสิทธิภาพในการทำงานดีกว่าแบบจำลองทางสถิติ โดยเฉพาะการทำงานกับข้อมูลขนาดใหญ่ ซึ่งใช้พลังงานน้อยกว่าและเร็วกว่า ทำให้สามารถสร้างแบบจำลองที่ทำนายผลระดับนาทีเดียว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 3

### วิธีดำเนินงานวิจัย

การวิจัยนี้เป็นการศึกษาการทำนายราคาคริปโทเคอร์เรนซีต่างๆ ได้แก่ Bitcoin, Ethereum, Cardano, Solana ด้วยตัวแบบประเภทต่างๆ ทั้งแบบดั้งเดิมที่เป็นสถิติ แบบการเรียนรู้เชิงลึก และแบบผสมระหว่างสถิติและการเรียนรู้เชิงลึก ได้แก่ตัวแบบ ARIMAX, RNN-LSTM, XGBoost, FBProphet, Temporal Fusion Transformer (TFT) ซึ่งในการศึกษาคั้งนี้จะใช้ปัจจัยภายนอกต่างๆ เพื่อช่วยสอนแบบจำลองเพื่อให้ผลลัพธ์ที่ดีที่สุด ได้แก่ค่า ปริมาณการซื้อขาย ดัชนีความกล้าและกลัวต่อบิตคอยน์ อัตราดอกเบี้ย และ อัตราเงินเฟ้อ

#### 3.1 ข้อมูลที่นำมาใช้ในการวิจัย (Research dataset)

3.1.1 ข้อมูลที่ต้องการทำนาย (target feature) คือราคาปิด (Close price) ในแต่ละวันของแต่ละคริปโทเคอร์เรนซี

3.1.2 ข้อมูลปัจจัยภายนอก (exogenous variables) ได้แก่ ปริมาณการซื้อขาย ดัชนีความกล้าและกลัวต่อบิตคอยน์ อัตราดอกเบี้ย และ อัตราเงินเฟ้อ

#### 3.2 เครื่องมือที่และภาษาที่ใช้ในการวิจัย (Research Tool)

ผู้วิจัยใช้ภาษา python ในการทำวิจัย เขียนบน google colab ซึ่งเป็น cloud platform ตัวหนึ่งที่นิยมใช้ในการเขียนภาษา python ซึ่งภาษา python มี libraries ที่หลากหลาย เหมาะแก่การเก็บรวบรวมข้อมูล วิเคราะห์ข้อมูล จัดการข้อมูล และการสร้างแบบจำลอง วัดประสิทธิภาพ และการแสดงผล

#### 3.3 การเก็บรวบรวมข้อมูล (Data Collection)

ในการศึกษานี้ผู้วิจัยใช้ข้อมูล ระหว่างวันที่ 1 กุมภาพันธ์ 2561 ถึง วันที่ 31 เดือนมีนาคม 2566 ในการวิจัย เนื่องจากข้อมูล ดัชนีความกล้าและกลัวต่อบิตคอยน์ เริ่มมีการจัดเก็บครั้งแรกในวันที่ 1 กุมภาพันธ์ 2561

##### 3.3.1 การเก็บข้อมูลราคาและปริมาณคริปโทเคอร์เรนซี

ใช้ yfinance library ในการเก็บข้อมูลราคา และ ปริมาณการซื้อขายย้อนหลัง รายวัน การเก็บข้อมูลดัชนีความกล้าและกลัวต่อบิตคอยน์ ซึ่งในการวิจัยนี้จะใช้ราคาปิดในแต่ละวันเป็นตัวแปรที่ต้องการทำนาย

##### 3.3.2 การเก็บข้อมูลดัชนีความกล้าและกลัวต่อบิตคอยน์

ใช้ API ในการดึงข้อมูลจากเว็บไซต์ <https://alternative.me/>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.3.3 การเก็บข้อมูลอัตราดอกเบี้ยและข้อมูลเงินเพื่อ

ใช้ API ของ the Federal Reserve Economic Data (FRED) API ในการดึงข้อมูลอัตราดอกเบี้ยและค่าดัชนีราคาผู้บริโภค (Consumer Price Index: CPI) ซึ่งค่าดัชนีราคาผู้บริโภคนั้นถูกนำมาคำนวณเป็นอัตราเงินเพื่อ ดังนั้นข้อมูลที่ใช้ในการวิจัยนี้จะมีทั้งหมด 1,882 แถว และ 6 คอลัมน์

### 3.4 การจัดเตรียมข้อมูล (Data Preprocessing)

มีขั้นตอนขั้นตอนดังนี้

1. เปลี่ยนค่า ในคอลัมน์ วันที่ ให้เป็นค่าประเภทวันที่ และ ตั้งให้เป็นค่า index
2. ทำการรวมชุดข้อมูลระหว่างราคาคริปโทเคอร์เรนซีและชุดของมูลปัจจัยภายนอกทั้งหมด
3. ตรวจสอบค่า missing value และจัดการ missing value
4. แก้ไขชื่อคอลัมน์
5. สร้างข้อมูลค่าเงินเพื่อจากค่าดัชนีราคาผู้บริโภคแล้วนำคอลัมน์ราคาผู้บริโภคออก
- 6.

### 3.5 การแบ่งข้อมูลเพื่อสอนและทดสอบ (Train & Test dataset)

เนื่องจากผู้วิจัยต้องการให้แบบจำลองทำนายผลล่วงหน้า 90 วัน ดังนั้นผู้วิจัยจะได้แบ่งข้อมูลในการสอนแบบจำลองตั้งแต่วันที่ 1 กุมภาพันธ์ 2561 ถึง 31 ธันวาคม 2565 ส่วนข้อมูลในการทดสอบแบบจำลองจะประกอบไปด้วยข้อมูลจากวันที่ 1 มกราคม 2566- 31 มีนาคม 2562 ดังนั้นข้อมูลในการสอนแบบจำลองจะมี 1,792 แถว ในขณะที่ข้อมูลในการทดสอบแบบจำลองจะมี 90 แถว

### 3.6 การสร้างแบบจำลอง (Model Creation)

ในการวิจัยนี้จะสร้างแบบจำลองแบบแปรเดียวและตัวแปรแบบกลุ่มเพื่อที่จะศึกษาว่าแบบจำลองแบบไหนให้ผลลัพธ์ในการทำนายที่ดีกว่ากัน และตัวแปรแบบกลุ่มนั้นตัวแปรไหนส่งผลต่อราคามากที่สุด

ซึ่งปัจจัยตัวแปรแบบกลุ่มนั้นคือ ปริมาณการซื้อขาย ดัชนีความกลัวและกลัวต่อبيتคอยน์ อัตราดอกเบี้ย และ เงินเพื่อ

#### 3.6.1 การตั้งค่าแบบจำลอง

##### 1 การตั้งค่าแบบจำลอง ARIMAX

ใช้ไลบรารี pmdarima และฟังก์ชัน auto\_arima() ในการหาค่าพารามิเตอร์ที่ดีที่สุดซึ่งแต่ละแบบจำลองมีการตั้งค่าดังตารางที่ 3.1

ตารางที่ 3.1 การตั้งค่าของแบบจำลอง ARIMAX

เหรียญคริปโทเคอร์เรนซี	ประเภทโมเดล	การตั้งค่า
BTC	ตัวแปรเดียว	ARIMA(0,1,0)(2,1,0)[12]
	ตัวแปรแบบกลุ่มปัจจัยภายนอก	ARIMA(1,0,2)(0,0,0)[0]
ETH	ตัวแปรเดียว	ARIMA(1,1,1)(2,1,0)[12]
	ตัวแปรแบบกลุ่มปัจจัยภายนอก	ARIMA(0,1,0)(0,0,0)[0]
ADA	ตัวแปรเดียว	ARIMA(3,1,1)(2,1,0)[12]
	ตัวแปรแบบกลุ่มปัจจัยภายนอก	ARIMA(4,0,2)(0,0,0)[0]
SOL	ตัวแปรเดียว	ARIMA(1,1,0)(2,1,0)[12]
	ตัวแปรแบบกลุ่มปัจจัยภายนอก	ARIMA(0,1,0)(0,0,0)[0]

## 2 การตั้งค่าแบบจำลอง XGBoost

ใช้ไลบรารี XGBoost และฟังก์ชัน XGBRegressor() แบบจำลองทั้งหมดใช้การตั้งค่าดังภาพที่

3.1

```
model = XGBRegressor(objective='reg:squarederror', n_estimators=1000)
```

ภาพที่ 3.1 การตั้งค่าแบบจำลอง XGBoost

## 3 การตั้งค่าแบบจำลอง LSTM

ใช้ไลบรารี tensorflow โดยฟังก์ชัน LSTM\_model() ซึ่งทุกเหรียญจะใช้การตั้งค่าสำหรับตัวแปรแบบเดียวดังภาพที่ 3.2 และแบบตัวแปรกลุ่มปัจจัยภายนอกดังภาพที่ 3.3

```
Model: "sequential"
-----
Layer (type)                Output Shape              Param #
-----
lstm (LSTM)                  (None, 90, 50)           10400
dropout (Dropout)           (None, 90, 50)            0
lstm_1 (LSTM)                (None, 90, 50)           20200
dropout_1 (Dropout)         (None, 90, 50)            0
lstm_2 (LSTM)                (None, 50)                20200
dropout_2 (Dropout)         (None, 50)                 0
dense (Dense)                (None, 1)                  51
-----
Total params: 50,851
Trainable params: 50,851
Non-trainable params: 0
```

ภาพที่ 3.2 โครงสร้างแบบจำลอง LSTM ตัวแปรเดียว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Model: "sequential_1"
-----
Layer (type)                Output Shape              Param #
-----
lstm_3 (LSTM)                (None, 50)                11200
dropout_3 (Dropout)          (None, 50)                 0
dense_1 (Dense)              (None, 1)                  51
-----
Total params: 11,251
Trainable params: 11,251
Non-trainable params: 0

```

ภาพที่ 3.3 โครงสร้างแบบจำลองของตัวแปรแบบกลุ่มปัจจัยภายนอก

#### 4 การตั้งค่าแบบจำลอง FBProphet

ใช้ไลบรารี prophet โดยใช้ฟังก์ชัน Prophet() โดยใช้ค่าพารามิเตอร์ดั้งเดิม ซึ่งทุกเหรียญการตั้งค่าพารามิเตอร์สำหรับตัวแปรเดียวดังภาพที่ 3.4 และ แบบตัวแปรกลุ่มปัจจัยภายนอกดังภาพที่ 3.5

```
model = Prophet()
```

ภาพที่ 3.4 ค่าพารามิเตอร์ของแบบจำลอง FBProphet ตัวแปรเดียว

```

model_mul = Prophet()
model_mul.add_regressor('Volume')
model_mul.add_regressor('fear_greed')
model_mul.add_regressor('interestrate')
model_mul.add_regressor('cpichange')

```

ภาพที่ 3.5 ค่าพารามิเตอร์ของแบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอก

#### 5 การตั้งค่าแบบจำลอง N-Beats

ใช้ไลบรารี neuralforecast โดยใช้ฟังก์ชัน NBEATSx() ซึ่งทุกเหรียญการตั้งค่าพารามิเตอร์สำหรับตัวแปรเดียวดังภาพที่ 3.6 และ แบบตัวแปรกลุ่มปัจจัยภายนอกดังภาพที่ 3.7

```

model = NBEATSx(h=90, input_size=180,
                loss=DistributionLoss(distribution='Normal', level=[80, 90]),
                scaler_type='robust',
                max_steps=200,
                val_check_steps=10,
                early_stop_patience_steps=2,
                )

```

ภาพที่ 3.6 ค่าพารามิเตอร์ของแบบจำลอง N-BEATS ตัวแปรเดียว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

model = NBEATsx(h=90, input_size=180,
               loss=DistributionLoss(distribution='Normal', level=[80, 90]),
               scaler_type='robust',
               hist_exog_list=['Volume', 'fear_greed', 'interestrates', 'cpchange'],
               max_steps=200,
               val_check_steps=10,
               early_stop_patience_steps=2,
               )

```

ภาพที่ 3.7 ค่าพารามิเตอร์ของแบบจำลอง N-BEATS ตัวแปรแบบกลุ่มปัจจัยภายนอก

## 6 การตั้งค่าแบบจำลอง TFT

ใช้ไลบรารี neuralforecast โดยใช้ฟังก์ชัน TFT() ซึ่งทุกเหรียญจะทำการตั้งค่าสำหรับตัวแปรแบบเดียวดังภาพที่ 3.8 และแบบตัวแปรกลุ่มปัจจัยภายนอกดังภาพที่ 3.9

```

1 nf = NeuralForecast(
2   models=[TFT(h=90, input_size=180,
3             hidden_size=20,
4             loss=DistributionLoss(distribution='StudentT', level=[80, 90]),
5             learning_rate=0.005,
6             max_steps=500,
7             val_check_steps=10,
8             early_stop_patience_steps=10,
9             scaler_type='robust',
10            windows_batch_size=None,
11            enable_progress_bar=True),
12 ],
13 freq='D'
14 )

```

ภาพที่ 3.8 ค่าพารามิเตอร์ของแบบจำลอง TFT ตัวแปรเดียว

```

1 nf_multi = NeuralForecast(
2   models=[TFT(h=90, input_size=180,
3             hidden_size=20,
4             loss=DistributionLoss(distribution='StudentT', level=[80, 90]),
5             learning_rate=0.005,
6             hist_exog_list=['Volume', 'fear_greed', 'interestrates', 'cpchange'],
7             max_steps=500,
8             val_check_steps=10,
9             early_stop_patience_steps=10,
10            scaler_type='robust',
11            windows_batch_size=None,
12            enable_progress_bar=True),
13 ],
14 freq='D'
15 )

```

ภาพที่ 3.9 ค่าพารามิเตอร์ของแบบจำลอง N-BEATS ตัวแปรแบบกลุ่มปัจจัยภายนอก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.7 การวัดประสิทธิภาพแบบจำลอง (Model Evaluation)

ในการวัดประสิทธิภาพของแบบจำลองนั้นทางผู้วิจัยจะใช้มาตรวัดที่เป็นที่นิยมสำหรับแบบจำลองในการทำนายอนุกรมเวลา ซึ่งได้แก่ ค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Squared Error: RMSE), ค่าเฉลี่ยของความผิดพลาดสัมบูรณ์ (Mean Absolute error: MAE), ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ในการดูประสิทธิภาพของแบบจำลองของทั้ง 3 ค่านี้ ถ้าได้ค่าน้อย หมายความว่าแบบจำลองมีประสิทธิภาพในการทำนายที่ดี

### 3.8 การทำนายผล (Model Prediction)

เมื่อได้วิธีการพยากรณ์ที่เหมาะสมที่สุดกับอนุกรมเวลาชุดนี้ จากนั้นจะทำวิเคราะห์ราคาปิดของคริปโทเคอร์เรนซีล่วงหน้า 90 วัน ด้วยวิธีการพยากรณ์ดังกล่าว

### 3.9 ทดสอบประสิทธิภาพกับชุดข้อมูลทดสอบ (Test Performance)

นำค่าพยากรณ์ล่วงหน้าที่ได้ ไปเปรียบเทียบกับราคาปิดที่เกิดขึ้นจริงระหว่าง มกราคม ถึง มีนาคม 2566 เพื่อทดสอบว่าแบบจำลองดังกล่าวมีความแม่นยำกับข้อมูลที่ไม่เคยเห็นมาก่อนมากน้อยเพียงใด

### 3.10 เปรียบเทียบแบบจำลองและสรุปผล (Model comparison and conclusion)

ทำการสรุปแบบจำลองของแต่ละแบบจำลองในแต่ละสกุลเงินเพื่อดูว่าปัจจัยภายนอกกลุ่มใดที่ทำให้แบบจำลองมีความแม่นยำสูงสุด

## บทที่ 4


### ผลการวิจัยและอภิปรายผล

ในบทนี้จะแสดงผลแบบจำลองของคริปโทเคอร์เรนซีทั้ง 4 เหรียญ ได้แก่ BTC ETH ADA และ SOL โดยทั้ง 4 เหรียญ จะใช้การเรียนรู้ของเครื่องทั้งหมด 6 ประเภท ได้แก่ ARIMAX XGBoost LSTM FBProphet และ TFT โดยแต่ละประเภทการเรียนรู้จะถูกสร้างด้วยตัวแปรเดียวและกลุ่มปัจจัยภายนอก

#### 4.2 ผลลัพธ์จากการวิจัย

##### 4.2.1 กราฟราคาปิดเหรียญเปรียบเทียบกับราคาปิดที่ถูกทำนาย 90 วัน


ในส่วนนี้จะแสดงผลลัพธ์ของการทำนายราคาคริปโทเคอร์เรนซีทั้ง 4 เหรียญ ในทุกๆ แบบจำลองเปรียบเทียบระหว่างผลลัพธ์จากค่าทำนายแบบจำลองตัวแปรเดียว แบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกและราคาปิดจริง ซึ่งผลลัพธ์ที่ได้จะเป็นการทำนายราคาล่วงหน้า 90 วัน ดังภาพที่ 4.1



ภาพที่ 4.1 กราฟเปรียบเทียบระหว่างราคาปิดจริง ราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย ARIMAX


จากภาพที่ 4.1 ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรเดียวมีแนวโน้มขึ้นลงอยู่ระหว่างค่าประมาณ 16,500 ถึง 17,500 ซึ่งค่า RMSE อยู่ที่ 6975.01 ค่า MAE อยู่ที่ 6232.29 และ MAPE อยู่ที่ 0.2578

ในขณะที่ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรกลุ่มปัจจัยภายนอกมีแนวโน้มลดลงจากประมาณ 24,000 ลงมาที่ประมาณ 20,000 ซึ่งค่า RMSE อยู่ที่ 11462.36 ค่า MAE อยู่ที่ 8030.64 และ MAPE อยู่ที่ 0.2260 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก




ภาพที่ 4.2 กราฟเปรียบเทียบระหว่างราคาปิดจริง ราคาที่ทำนายแบบจำลองตัวแปรเดี่ยวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย XGBoost

จากภาพที่ 4.2 ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรเดี่ยวค่อนข้างใกล้เคียงจากราคาปิดจริง ซึ่งค่า RMSE อยู่ที่ 576.17 ค่า MAE อยู่ที่ 384.85 และ MAPE อยู่ที่ 0.0213 ในขณะที่ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรกลุ่มปัจจัยภายนอกราคาค่อนข้างสูงกว่า ราคาปิดจริง เกือบ 2 เท่า ทำให้ค่าความผิดพลาดค่อนข้างสูง ค่า RMSE อยู่ที่ 15062.31 ค่า MAE อยู่ที่ 13216.32 และ MAPE อยู่ที่ 0.6257 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.3 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดี่ยวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย LSTM


จากภาพที่ 4.3 ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรเดี่ยว ราคาการทำนายทิศทางเดียวกับราคาปิดจริงแต่ค่าที่ทำนายจะต่ำกว่าเล็กน้อย ค่า RMSE อยู่ที่ 1370.68 ค่า MAE อยู่ที่ 1112.30 และ MAPE อยู่ที่ 0.0482 ในขณะที่ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรกลุ่มปัจจัยภายนอกมีแนวโน้มคล้ายกับราคาปิดจริงแต่ค่าที่ทำนายต่ำกว่าค่อนข้างมาก ซึ่งค่า RMSE อยู่ที่ 5434.67 ค่า MAE อยู่ที่ 4960.99 และ MAPE อยู่ที่ 0.2071 ซึ่งแบบจำลองตัวแปรเดี่ยวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.4 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดี่ยวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย FBProphet


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากภาพที่ 4.4 ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรเดียวมีแนวโน้มตรงกันข้ามกับราคาปิดจริงและค่าที่ทำนายต่ำกว่าค่อนข้างมาก ซึ่งค่า RMSE อยู่ที่ 17752.81 ค่า MAE อยู่ที่ 17032.15 และ MAPE อยู่ที่ 0.7276 ในขณะที่ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรกลุ่มปัจจัยภายนอกมีแนวโน้มคล้ายกับราคาปิดจริงและค่าที่ทำนายต่ำกว่าค่อนข้างมาก ซึ่งค่า RMSE อยู่ที่ 10403.41 ค่า MAE อยู่ที่ 9930.38 และ MAPE อยู่ที่ 0.4233 ซึ่งแบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรเดียว




ภาพที่ 4.5 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย N-BEATS

จากภาพที่ 4.5 ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรเดียวนั้นราคาจะค่อยๆ ลดลงจาก ประมาณ 17,000 ถึงประมาณ 15,000 ซึ่งค่า RMSE อยู่ที่ 7950.86 ค่า MAE อยู่ที่ 7212.54 และ MAPE อยู่ที่ 0.3000 ในขณะที่ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นราคามีแนวโน้มสูงขึ้นจาก 15,000 ไป ถึงประมาณ 17,500 ซึ่งสูงกว่าราคาปิดจริง ซึ่งค่า RMSE อยู่ที่ 9339.10 ค่า MAE อยู่ที่ 7922.40 และ MAPE อยู่ที่ 0.3412 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.6 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ BTC ด้วย TFT


จากภาพที่ 4.6 ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มสูงขึ้นจาก 17,000 ไป ถึงประมาณ 19,000 ซึ่งต่ำกว่าราคาปิดจริง ซึ่งค่า RMSE อยู่ที่ 5364.14 ค่า MAE อยู่ที่ 4736.86 และ MAPE อยู่ที่ 0.1957 ในขณะที่ผลลัพธ์จากการทำนายราคา BTC แบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นราคาค่อยๆขึ้นจาก 17,800 ไปถึงประมาณ 18,500 ซึ่งค่า RMSE อยู่ที่ 6196.74 ค่า MAE อยู่ที่ 5510.19 และ MAPE อยู่ที่ 0.2279 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.7 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย ARIMAX

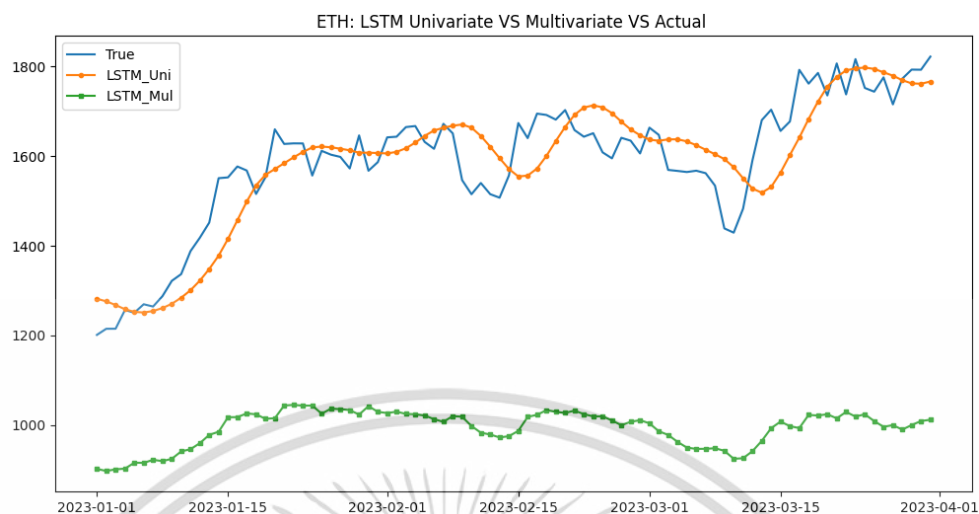
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากภาพที่ 4.7 ผลลัพธ์จากการทำนายราคา ETH แบบจำลองตัวแปรเดียวนั้นราคาวิ่งขึ้นลงอยู่ระหว่างประมาณ 1,100 ถึง 1,180 ซึ่งค่า RMSE อยู่ที่ 404.70 ค่า MAE อยู่ที่ 373.98 และ MAPE อยู่ที่ 0.2278 ในขณะที่ผลลัพธ์จากการทำนายราคา ETH นั้นราคามีแนวโน้มลงเล็กน้อย จากประมาณ 1,650 ลงมาที่ประมาณ 1,580 ซึ่งค่า RMSE อยู่ที่ 168.80 ค่า MAE อยู่ที่ 122.36 และ MAPE อยู่ที่ 0.0822 ซึ่งแบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรเดียว



ภาพที่ 4.8 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย XGBoost


จากภาพที่ 4.8 ผลลัพธ์จากการทำนายราคา ETH แบบจำลองตัวแปรเดียวนั้นราคามีใกล้เคียงกับราคาปิดจริง ซึ่งค่า RMSE อยู่ที่ 60.527 ค่า MAE อยู่ที่ 40.06 และ MAPE อยู่ที่ 0.0311 ในขณะที่ผลลัพธ์จากการทำนายราคา ETH นั้นราคาค่อนข้างสูงกว่าราคาปิดจริง 2 เท่า ซึ่งค่า RMSE อยู่ที่ 1404.99 ค่า MAE อยู่ที่ 1369.48 และ MAPE อยู่ที่ 0.8830 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.9 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย LSTM

จากภาพที่ 4.9 ผลลัพธ์จากการทำนายราคา ETH แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มใกล้เคียงกับราคาปิดจริงแต่ค่าต่ำกว่าเล็กน้อย ซึ่งค่า RMSE อยู่ที่ 90.28 ค่า MAE อยู่ที่ 70.81 และ MAPE อยู่ที่ 0.0445


ในขณะที่ผลลัพธ์จากการทำนายราคา ETH นั้นราคามีแนวโน้มคล้ายกับราคาปิดจริงแต่ค่าต่ำกว่ามากเกือบ 2 เท่า ซึ่งค่า RMSE อยู่ที่ 606.16 ค่า MAE อยู่ที่ 594.12 และ MAPE อยู่ที่ 0.3702 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.10 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย FBProphet


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากภาพที่ 4.10 ผลลัพธ์จากการทำนายราคา ETH แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มลดลงจากประมาณ 750 จนเกือบ 0 ซึ่งค่า RMSE อยู่ที่ 1335.36 ค่า MAE อยู่ที่ 1291.95 และ MAPE อยู่ที่ 0.8013 ในขณะที่ผลลัพธ์จากการทำนายราคา ETH นั้นราคามีแนวโน้มลดลงจากประมาณ 250 จนมีค่าติดลบ 500 ซึ่งค่า RMSE อยู่ที่ 1885.191 ค่า MAE อยู่ที่ 1855.72 และ MAPE อยู่ที่ 1.1596 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก




ภาพที่ 4.11 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย N-BEATS

จากภาพที่ 4.11 ผลลัพธ์จากการทำนายราคา ETH แบบจำลองตัวแปรเดียวนั้นราคาวิ่งขึ้นลงอยู่ในกรอบ 1,180 จนถึง 1,350 ซึ่งค่า RMSE อยู่ที่ 389.11 ค่า MAE อยู่ที่ 366.17 และ MAPE อยู่ที่ 0.2244 ในขณะที่ผลลัพธ์จากการทำนายราคา ETH นั้นราคาวิ่งขึ้นลงอยู่ในกรอบ 435.07 จนถึง 1,550 ซึ่งค่า RMSE อยู่ที่ 389.11 ค่า MAE อยู่ที่ 405.79 และ MAPE อยู่ที่ 0.2478 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.12 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ETH ด้วย TFT

จากภาพที่ 4.12 ผลลัพธ์จากการทำนายราคา ETH แบบจำลองตัวแปรเดียวนั้นราคาวิ่งขึ้นเล็กน้อยจากประมาณ 1,180 จนถึง ประมาณ 1,200 กว่า ซึ่งค่า RMSE อยู่ที่ 401.50 ค่า MAE อยู่ที่ 377.42 และ MAPE อยู่ที่ 0.2311 ในขณะที่ผลลัพธ์จากการทำนายราคา ETH นั้นราคานั้นวิ่งอยู่ในกรอบแคบมากๆที่ประมาณ 1,240 ถึง ประมาณ 1,260 กว่า ซึ่งค่า RMSE อยู่ที่ 381.70 ค่า MAE อยู่ที่ 352.88 และ MAPE อยู่ที่ 0.2149 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก




ภาพที่ 4.13 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย ARIMAX

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากภาพที่ 4.13 ผลลัพธ์จากการทำนายราคา ADA แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มลงเป็นลูกคลื่นจาก 0.25 จนถึงประมาณ 0.05 ซึ่งค่า RMSE อยู่ที่ 0.2094 ค่า MAE อยู่ที่ 0.1958 และ MAPE อยู่ที่ 0.5410

ในขณะที่ผลลัพธ์จากการทำนายราคา ADA นั้นราคามีแนวโน้มลงเล็กน้อยจากประมาณ 0.325 จนถึงประมาณ 0.300 ซึ่งค่า RMSE อยู่ที่ 0.4436 ค่า MAE อยู่ที่ 0.3421 และ MAPE อยู่ที่ 0.4536 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก




ภาพที่ 4.14 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย XGBoost

จากภาพที่ 4.14 ผลลัพธ์จากการทำนายราคา ADA แบบจำลองตัวแปรเดียวนั้นราคามีผลลัพธ์ใกล้เคียงกับราคาปิดจริงเป็นอย่างมากซึ่งค่า RMSE อยู่ที่ 0.016 ค่า MAE อยู่ที่ 0.011 และ MAPE อยู่ที่ 0.033 ในขณะที่ผลลัพธ์จากการทำนายราคา ADA นั้นราคามีค่าสูงกว่าค่าจริงเกือบ 4-8 เท่า ผลลัพธ์ที่ได้มีความคลาดเคลื่อนสูงมาก ซึ่งค่า RMSE อยู่ที่ 1.1357 ค่า MAE อยู่ที่ 1.1321 และ MAPE อยู่ที่ 3.227 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.15 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย LSTM

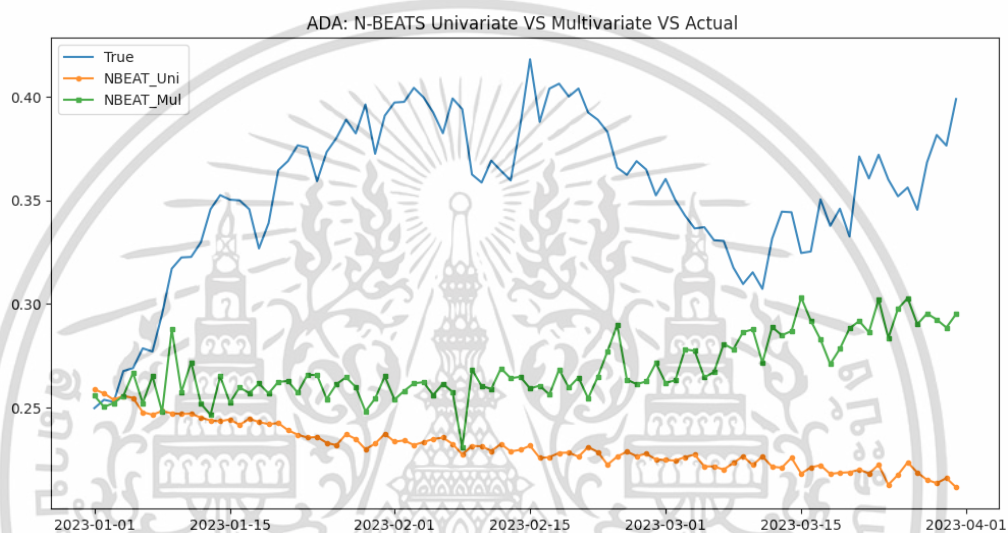
จากภาพที่ 4.15 ผลลัพธ์จากการทำนายราคา ADA แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มไปในทิศทางเดียวกับราคาปิดจริง ซึ่งค่า RMSE อยู่ที่ 0.0235 ค่า MAE อยู่ที่ 0.0199 และ MAPE อยู่ที่ 0.0568 ในขณะที่ผลลัพธ์จากการทำนายราคา ADA นั้นราคามีแนวโน้มไปในทิศทางเดียวกันแต่อยู่ในกรอบที่แคบกว่าที่ 0.300-0.330 ถึงซึ่งค่า RMSE อยู่ที่ 0.0419 ค่า MAE อยู่ที่ 0.03679 และ MAPE อยู่ที่ 0.1016 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.16 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย FBProphet


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากภาพที่ 4.16 ผลลัพธ์จากการทำนายราคา ADA แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มไปในทิศทางตรงกันข้าม ซึ่งลดลงจากประมาณ 0.09 ถึงเกือบ -0.2 ซึ่งค่า RMSE อยู่ที่ 0.4326 ค่า MAE อยู่ที่ 0.4237 และ MAPE อยู่ที่ 1.1919 ในขณะที่ผลลัพธ์จากการทำนายราคา ADA นั้นราคามีแนวโน้มคล้ายกับราคาปิดจริง แต่ราคาต่ำกว่ามาก ซึ่งค่า RMSE อยู่ที่ 0.2820 ค่า MAE อยู่ที่ 0.2754 และ MAPE อยู่ที่ 0.7731 ซึ่งแบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรเดียว




ภาพที่ 4.17 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย N-BEATS

จากภาพที่ 4.17 ผลลัพธ์จากการทำนายราคา ADA แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มลดลงจาก ประมาณ 0.26 ถึง 0.22 ซึ่งค่า RMSE อยู่ที่ 0.1302 ค่า MAE อยู่ที่ 0.1230 และ MAPE อยู่ที่ 0.3378 ในขณะที่ผลลัพธ์จากการทำนายราคา ADA นั้นราคามีแนวโน้มขึ้นอยู่ในกรอบ 0.23 ถึง 0.0943 ซึ่งค่า RMSE อยู่ที่ 0.0853 ค่า MAE อยู่ที่ 0.1230 และ MAPE อยู่ที่ 0.2314 ซึ่งแบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรเดียว



ภาพที่ 4.18 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ ADA ด้วย TFT


จากภาพที่ 4.18 ผลลัพธ์จากการทำนายราคา ADA แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มขึ้นเล็กน้อยจากประมาณ 0.270 จนถึงประมาณ 0.290 ซึ่งค่า RMSE อยู่ที่ 0.0791 ค่า MAE อยู่ที่ 0.0725 และ MAPE อยู่ที่ 0.1973 ในขณะที่ผลลัพธ์จากการทำนายราคา ADA นั้นราคาวิ่งจนเกือบเป็นเส้นตรงอยู่ที่ประมาณ 0.29 ซึ่งค่า RMSE อยู่ที่ 0.0729 ค่า MAE อยู่ที่ 0.0670 และ MAPE อยู่ที่ 0.1835 ซึ่งแบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรเดียว



ภาพที่ 4.19 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย ARIMAX


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากภาพที่ 4.19 ผลลัพธ์จากการทำนายราคา SOL แบบจำลองตัวแปรเดียวนั้นราคามีทิศทางตรงกันข้ามกับราคาปิดจริง ซึ่งมีแนวโน้มลดลงจาก 10 จนถึง 0 ซึ่งค่า RMSE อยู่ที่ 17.52 ค่า MAE อยู่ที่ 16.66 และ MAPE อยู่ที่ 0.7666 ในขณะที่ผลลัพธ์จากการทำนายราคา SOL นั้นราคามีแนวโน้มลดลงจากประมาณ 13 จนถึงประมาณ 9 ซึ่งค่า RMSE อยู่ที่ 10.47 ค่า MAE อยู่ที่ 9.87 และ MAPE อยู่ที่ 0.4494




ภาพที่ 4.20 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย XGboost

จากภาพที่ 4.20 ผลลัพธ์จากการทำนายราคา SOL แบบจำลองตัวแปรเดียวนั้นราคาใกล้เคียงกับราคาปิดจริงค่อนข้างมาก ซึ่งค่า RMSE อยู่ที่ 10.47 ค่า MAE อยู่ที่ 9.87 และ MAPE อยู่ที่ 0.4494 ในขณะที่ผลลัพธ์จากการทำนายราคา SOL นั้นราคาสูงกว่าค่าจริงอย่างมากในช่วง 2 เดือนแรก ประมาณ 6-7 เท่า ซึ่งค่า RMSE อยู่ที่ 108.45 ค่า MAE อยู่ที่ 92.29 และ MAPE อยู่ที่ 4.5437 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.21 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย LSTM

จากภาพที่ 4.21 ผลลัพธ์จากการทำนายราคา SOL แบบจำลองตัวแปรเดียวนั้นราคามีแนวโน้มไปในทิศทางเดียวกับราคาปิดจริง ซึ่งค่า RMSE อยู่ที่ 2.441 ค่า MAE อยู่ที่ 1.95 และ MAPE อยู่ที่ 0.098 ในขณะที่ผลลัพธ์จากการทำนายราคา SOL นั้นต่ำกว่าราคาปิดจริงมากจนมีค่าติดลบ 200 กว่า ซึ่งค่า RMSE อยู่ที่ 242.09 ค่า MAE อยู่ที่ 241.70 และ MAPE อยู่ที่ 11.8628 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก




ภาพที่ 4.22 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย FBProphet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากภาพที่ 4.22 ผลลัพธ์จากการทำนายราคา SOL แบบจำลองตัวแปรเดียวนั้นต่ำมีแนวโน้มลดลงจาก ประมาณ -2 จนติดลบถึงเกือบ -60 ซึ่งค่า RMSE อยู่ที่ 65.84 ค่า MAE อยู่ที่ 63.55 และ MAPE อยู่ที่ 2.9673

ในขณะที่ผลลัพธ์จากการทำนายราคา SOL นั้นต่ำมีแนวโน้มลดลงจาก ประมาณ 4 จนติดลบถึงเกือบ -50 ซึ่งค่า RMSE อยู่ที่ 55.45 ค่า MAE อยู่ที่ 52.89 และ MAPE อยู่ที่ 2.4632 ซึ่งแบบจำลองตัวแปรกลุ่มปัจจัยภายนอกนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรเดียว



ภาพที่ 4.23 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย N-BEATS

จากภาพที่ 4.23 ผลลัพธ์จากการทำนายราคา SOL แบบจำลองตัวแปรเดียวนั้นต่ำมีแนวโน้มขึ้นในช่วงครึ่งเดือนแรกแล้วค่อยๆลดลงจากประมาณ 10 จนถึง 2 ซึ่งค่า RMSE อยู่ที่ 14.61 ค่า MAE อยู่ที่ 13.97 และ MAPE อยู่ที่ 0.6478 ในขณะที่ผลลัพธ์จากการทำนายราคา SOL มีแนวโน้มไปในทิศทางขึ้นซึ่งมีค่ามากกว่าราคาปิดค่อนข้างมาก ซึ่งค่า RMSE อยู่ที่ 59.17 ค่า MAE อยู่ที่ 55.07 และ MAPE อยู่ที่ 2.6888 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก



ภาพที่ 4.24 กราฟเปรียบเทียบระหว่างราคาปิดจริงราคาที่ทำนายแบบจำลองตัวแปรเดียวและแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกของ SOL ด้วย TFT

จากภาพที่ 4.24 ผลลัพธ์จากการทำนายราคา SOL แบบจำลองตัวแปรเดียวนั้นต่ำมีแนวโน้มขึ้นในช่วงครึ่งเดือนแรกจาก เกือบ 14 ไป 14กว่าๆ แล้วลดลงมาที่ 12 ซึ่งค่า RMSE อยู่ที่ 8.24 ค่า MAE อยู่ที่ 7.71 และ MAPE อยู่ที่ 0.3504 ในขณะที่ผลลัพธ์จากการทำนายราคา SOL นั้นต่ำมีค่าสูงกว่าราคาปิดจริงอยู่ประมาณ 2-2.5 เท่าซึ่งค่า RMSE อยู่ที่ 25.47 ค่า MAE อยู่ที่ 25.29 และ MAPE อยู่ที่ 1.2651 ซึ่งแบบจำลองตัวแปรเดียวนั้นมีประสิทธิภาพในการทำนายดีกว่าแบบตัวแปรกลุ่มปัจจัยภายนอก

#### 4.2.2 ผลลัพธ์ค่า RMSE MAE MAPE

ผลลัพธ์ของค่า RMSE MAE MAPE จะแบ่งออกเป็น 4 ตารางตามแต่ละเหรียญเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในแต่ละเหรียญว่าแบบจำลองใดมีค่าความผิดพลาดในการทำนายน้อยที่สุดดังตารางที่ 4.1-4.4

ตารางที่ 4.1 ค่า RMSE MAE MAPE ของแบบจำลอง BTC

แบบจำลอง	RMSE	MAE	MAPE
ARIMA ที่ใช้ตัวแปรเดียว (Univariate)	6975.01	6232.29	0.2578
ARIMAX ที่ใช้ตัวแปรกลุ่ม (Multivariate)	11462.36	8030.64	0.2260
XGBoost ที่ใช้ตัวแปรเดียว (Univariate)	576.17	384.85	0.0213
XGBoost ที่ใช้ตัวแปรกลุ่ม (Multivariate)	15062.31	13216.32	0.6257

ตารางที่ 4.1 (ต่อ)

LSTM ที่ใช้ตัวแปรเดียว (Univariate)	1370.68	1112.30	0.0482
LSTM ที่ใช้ตัวแปรกลุ่ม (Multivariate)	5434.67	4960.99	0.2071
FBProphet ที่ใช้ตัวแปรเดียว (Univariate)	17752.81	17032.15	0.7276
FBProphet ที่ใช้ตัวแปรกลุ่ม (Multivariate)	10403.41	9930.38	0.4233
N-BEATS ที่ใช้ตัวแปรเดียว (Univariate)	7950.86	7212.54	0.3000
N-BEATS ที่ใช้ตัวแปรกลุ่ม (Multivariate)	9339.10	7922.40	0.3412
TFT ที่ใช้ตัวแปรเดียว (Univariate)	5364.14	4736.86	0.1957
TFT ที่ใช้ตัวแปรกลุ่ม (Multivariate)	6196.74	5510.19	0.2279

ตารางที่ 4.2 ค่า RMSE MAE MAPE ของแบบจำลอง ETH

แบบจำลอง	RMSE	MAE	MAPE
ARIMA ที่ใช้ตัวแปรเดียว (Univariate)	404.70	373.98	0.2278
ARIMAX ที่ใช้ตัวแปรกลุ่ม (Multivariate)	168.80	122.36	0.0822
XGBoost ที่ใช้ตัวแปรเดียว (Univariate)	60.527	40.06	0.0311
XGBoost ที่ใช้ตัวแปรกลุ่ม (Multivariate)	1404.99	1369.48	0.8830
LSTM ที่ใช้ตัวแปรเดียว (Univariate)	90.28	70.81	0.0445
LSTM ที่ใช้ตัวแปรกลุ่ม (Multivariate)	606.16	594.12	0.3702
FBProphet ที่ใช้ตัวแปรเดียว (Univariate)	1335.36	1291.95	0.8013
FBProphet ที่ใช้ตัวแปรกลุ่ม (Multivariate)	1885.191	1855.72	1.1596
N-BEATS ที่ใช้ตัวแปรเดียว (Univariate)	389.11	366.17	0.2244
N-BEATS ที่ใช้ตัวแปรกลุ่ม (Multivariate)	435.07	405.79	0.2478
TFT ที่ใช้ตัวแปรเดียว (Univariate)	401.50	377.42	0.2311
TFT ที่ใช้ตัวแปรกลุ่ม (Multivariate)	381.70	352.88	0.2149

ตารางที่ 4.3 ค่า RMSE MAE MAPE ของแบบจำลอง ADA

แบบจำลอง	RMSE	MAE	MAPE
ARIMA ที่ใช้ตัวแปรเดียว (Univariate)	0.2094	0.1958	0.5410
ARIMAX ที่ใช้ตัวแปรกลุ่ม (Multivariate)	0.4436	0.3421	0.4536

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.3 (ต่อ)

XGBoost ที่ใช้ตัวแปรเดียว (Univariate)	0.016	0.011	0.033
XGBoost ที่ใช้ตัวแปรกลุ่ม (Multivariate)	1.1357	1.1321	3.227
LSTM ที่ใช้ตัวแปรเดียว (Univariate)	0.0235	0.0199	0.0568
LSTM ที่ใช้ตัวแปรกลุ่ม (Multivariate)	0.0419	0.03679	0.1016
FBProphet ที่ใช้ตัวแปรเดียว (Univariate)	0.4326	0.4237	1.1919
FBProphet ที่ใช้ตัวแปรกลุ่ม (Multivariate)	0.2820	0.2754	0.7731
N-BEATS ที่ใช้ตัวแปรเดียว (Univariate)	0.1302	0.1230	0.3378
N-BEATS ที่ใช้ตัวแปรกลุ่ม (Multivariate)	0.0943	0.0853	0.2314
TFT ที่ใช้ตัวแปรเดียว (Univariate)	0.0791	0.0725	0.1973
TFT ที่ใช้ตัวแปรกลุ่ม (Multivariate)	0.0729	0.0670	0.1835

ตารางที่ 4.4 ค่า RMSE MAE MAPE ของแบบจำลอง SOL

แบบจำลอง	RMSE	MAE	MAPE
ARIMA ที่ใช้ตัวแปรเดียว (Univariate)	17.52	16.66	0.7666
ARIMAX ที่ใช้ตัวแปรกลุ่ม (Multivariate)	10.47	9.87	0.4494
XGBoost ที่ใช้ตัวแปรเดียว (Univariate)	1.94	1.11	0.05962
XGBoost ที่ใช้ตัวแปรกลุ่ม (Multivariate)	108.45	92.29	4.5437
LSTM ที่ใช้ตัวแปรเดียว (Univariate)	2.441	1.95	0.098
LSTM ที่ใช้ตัวแปรกลุ่ม (Multivariate)	242.09	241.70	11.8628
FBProphet ที่ใช้ตัวแปรเดียว (Univariate)	65.84	63.55	2.9673
FBProphet ที่ใช้ตัวแปรกลุ่ม (Multivariate)	55.45	52.89	2.4632
N-BEATS ที่ใช้ตัวแปรเดียว (Univariate)	14.61	13.97	0.6478
N-BEATS ที่ใช้ตัวแปรกลุ่ม (Multivariate)	59.17	55.07	2.6888
TFT ที่ใช้ตัวแปรเดียว (Univariate)	8.24	7.71	0.3504
TFT ที่ใช้ตัวแปรกลุ่ม (Multivariate)	25.47	25.29	1.2651


แบบจำลองของแต่ละคริปโทเคอร์เรนซี ค่า RMSE MAE และ MAE ที่มีค่าน้อยที่สุดคือแบบจำลอง XGBoost ที่ใช้ตัวแปรเดียว (Univariate) ส่วนอันดับสองนั้นได้แก่แบบจำลอง LSTM ที่ใช้ตัวแปรเดียว (Univariate)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


### 4.2.3 Feature Importance

ในส่วนนี้ จะแสดงค่า feature importance ของแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอกทั้งหมด ยกเว้น แบบจำลอง N-BEATS และ TFT เนื่องจากแบบจำลองไม่สามารถแสดงค่าได้ ซึ่ง feature importance นี้จะใช้เพื่อเปรียบเทียบว่าปัจจัยภายนอกตัวใดมีผลต่อราคาคริปโทเคอร์เรนซีในแต่ละแบบทดลองอย่างไรบ้าง

Feature Importance ของแบบจำลอง BTC




ภาพที่ 4.25 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ BTC




ภาพที่ 4.26 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ BTC

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.27 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ BTC




ภาพที่ 4.28 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ BTC


ในแต่ละแบบจำลองนั้น มีความสำคัญของปัจจัยที่ส่งผลต่อราคาไม่เหมือนกัน ซึ่งในทั้งสี่แบบจำลองนั้น มีสามแบบที่ปัจจัย อัตราเงินเฟ้อมีความสำคัญสูงสุด ในขณะที่อีกสองแบบจำลองนั้นปัจจัยที่สำคัญที่สุดคือค่า ปริมาณการซื้อขาย และ อัตราดอกเบี้ย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## Feature Importance ของแบบจำลอง ETH




ภาพที่ 4.29 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ ETH




ภาพที่ 4.30 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ ETH

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.31 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ ETH




ภาพที่ 4.32 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ ETH


ในแต่ละแบบจำลองนั้น มีความสำคัญของปัจจัยที่ส่งผลต่อราคาไม่เหมือนกัน ซึ่งในทั้งสี่แบบจำลองนั้น มีสองแบบที่ปัจจัย อัตราเงินเฟ้อมีความสำคัญสูงสุด ในขณะที่อีกสองโมเดลนั้นปัจจัยที่สำคัญที่สุดคือ ค่า ปริมาณการซื้อขาย และ อัตราดอกเบี้ย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## Feature Importance ของแบบจำลอง ADA




ภาพที่ 4.33 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ ADA

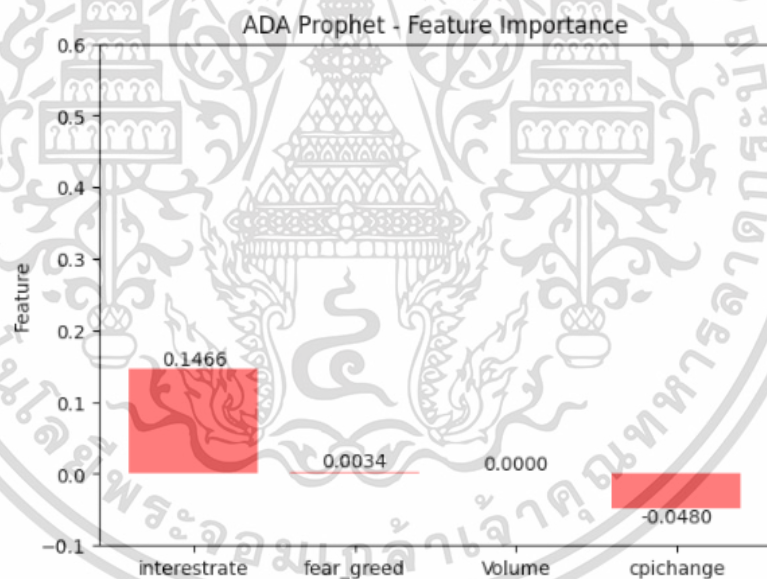


ภาพที่ 4.34 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ ADA

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.35 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ ADA




ภาพที่ 4.36 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ ADA


ในแต่ละแบบจำลองนั้น มีความสำคัญของปัจจัยที่ส่งผลต่อราคาไม่เหมือนกัน ซึ่งในทั้งสี่แบบจำลองนั้น มีสองแบบที่ปัจจัย ปริมาณการซื้อขาย มีความสำคัญสูงสุด ในขณะที่อีกสองโมเดลนั้นปัจจัยที่สำคัญที่สุดคือค่า อัตราเงินเฟ้อ และ อัตราดอกเบี้ย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## Feature Importance ของแบบจำลอง SOL

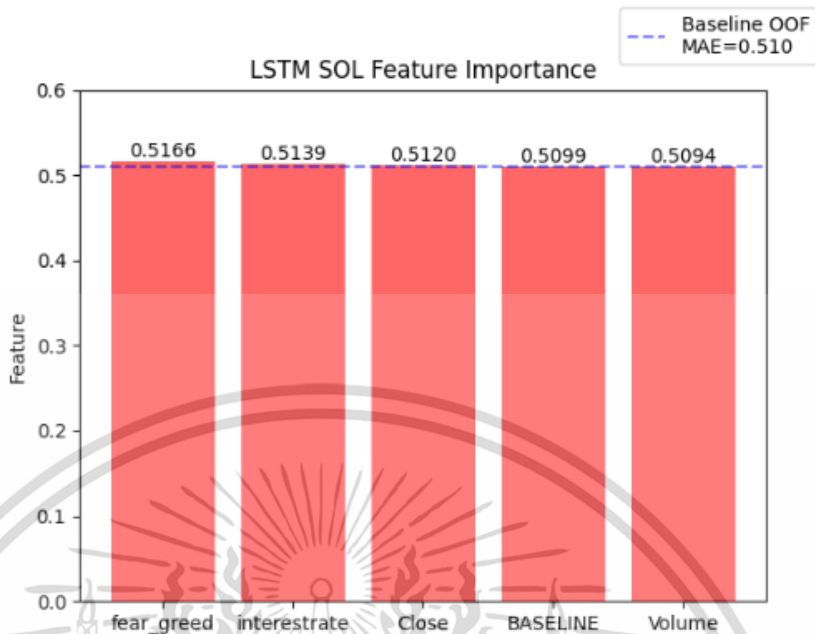


ภาพที่ 4.37 feature importance แบบจำลอง ARIMAX ตัวแปรกลุ่มปัจจัยภายนอกของ SOL




ภาพที่ 4.38 feature importance แบบจำลอง XGBoost ตัวแปรกลุ่มปัจจัยภายนอกของ SOL

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.39 feature importance แบบจำลอง LSTM ตัวแปรกลุ่มปัจจัยภายนอกของ SOL



ภาพที่ 4.40 feature importance แบบจำลอง FBProphet ตัวแปรกลุ่มปัจจัยภายนอกของ SOL

ในแต่ละแบบจำลองนั้น มีความสำคัญของปัจจัยที่ส่งผลต่อราคาไม่เหมือนกัน ซึ่งในทั้งสี่แบบจำลองนั้น มีสองแบบที่ปัจจัย อัตราเงินเฟ้อมีความสำคัญสูงสุด ในขณะที่อีกสองโมเดลนั้นปัจจัยที่สำคัญที่สุดคือ ค่า ความกล้าและความกลัว และ อัตราดอกเบี้ย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

### สรุปผลการศึกษาและข้อเสนอแนะ

#### 5.1 สรุปผลการศึกษา

จากการศึกษาในครั้งนี้ผู้วิจัยต้องการที่จะศึกษาการทำนายราคาของคริปโทเคอร์เรนซี เพื่อที่จะสามารถใช้งานแผนการลงทุนในอนาคต ซึ่งในการวิจัยนี้ได้นำแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่องแบบต่างๆ ทั้งแบบดั้งเดิมด้วยสถิติ และแบบใหม่ด้วยการเรียนรู้เชิงลึกมาใช้ในการทดลอง ได้แก่ ARIMAX XGBoost LSTM FBProphet N-BEATS และ TFT ซึ่งทำการทดลองแต่ละเทคนิคด้วยตัวแปรแบบเดียวและตัวแปรแบบกลุ่มปัจจัยภายนอก ซึ่งปัจจัยกลุ่มภายนอกประกอบไปด้วย ปริมาณการซื้อขาย ดัชนีความกลัวและกลัวต่อบิตคอยน์ อัตราดอกเบี้ย และอัตราเงินเฟ้อ เพื่อทำนายราคาของคริปโทเคอร์เรนซี ซึ่งในงานวิจัยนี้ ผู้วิจัยได้เลือกสกุลเงินดิจิทัลที่ได้รับความนิยมมาใช้ในการศึกษาทั้งหมด 4 เหรียญ ได้แก่ Bitcoin Ethereum Cardano และ Solana ซึ่งผลลัพธ์ของแบบจำลองที่ให้ผลดีที่สุดทั้ง 4 เหรียญ คือ XGBoost แบบตัวแปรเดียว และอันดับที่สองคือ LSTM แบบตัวแปรเดียว ซึ่งสาเหตุที่แบบจำลองที่มีตัวแปรเดียวนั้นให้ผลลัพธ์ที่แม่นยำกว่าตัวแปรแบบกลุ่มปัจจัยภายนอกนั้น ในแต่ละช่วงเวลาทิศทางของความสัมพันธ์ระหว่างราคาปิดของสกุลเงินดิจิทัลและปัจจัยภายนอกนั้นมีทิศทางที่แตกต่างกันในแต่ละช่วงเวลา ทำให้เกิดความคลาดเคลื่อนที่สูงขึ้นในแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอก ในขณะที่ความสำคัญของปัจจัยที่ส่งผลต่อราคาเหรียญนั้นในแต่ละแบบจำลองแบบตัวแปรกลุ่มปัจจัยภายนอก ให้ผลสำคัญไม่เหมือนกัน ซึ่งปัจจัยที่มีความสำคัญที่พบมากที่สุดแบบจำลองทั้งหมด คือ อัตราเงินเฟ้อ อยู่ที่ 8 แบบจำลอง

ซึ่งในงานวิจัยนี้มีข้อจำกัดทางด้านทรัพยากรของเครื่องคอมพิวเตอร์ทำให้ไม่สามารถทำการรันแบบจำลองที่ใช้เทคนิคการเรียนรู้เชิงลึกในจำนวนรอบที่สูงได้ทำให้ประสิทธิภาพของแบบจำลองอาจยังไม่ดีเท่าที่ควร อีกทั้งข้อมูลดัชนีความกลัวและกลัวต่อบิตคอยน์มีข้อมูลย้อนหลังที่จำกัดทำให้จำนวนตัวอย่างที่ใช้ในการสอนแบบจำลองอาจมีจำนวนน้อยเกินไป

#### 5.2 ข้อเสนอแนะ

ขอเสนอแนะสำหรับการศึกษาครั้งต่อไป ช่วงเวลาที่ใช้ในการสอนแบบทดลองและระยะเวลาในการทำนายอาจมีผลต่อความแม่นยำในการทำนาย ในการทดลองถัดไปควรที่จะปรับเปลี่ยนช่วงเวลาเพื่อทดสอบว่าประสิทธิภาพของแบบจำลองนั้นดีขึ้นหรือไม่ ทั้งนี้ตัวแปรตามที่เป็นราคาปิดของคริปโทเคอร์เรนซินั้นมีความผันผวนสูง ซึ่งในการทดลองครั้งถัดไปอาจเปลี่ยนตัวแปรตามเป็นเปอร์เซ็นต์ของราคาที่เปลี่ยนแปลงในแต่ละวันแทนที่ และในการศึกษาครั้งถัดไปผู้ศึกษาอาจเพิ่มปัจจัยภายนอกอื่นๆ ที่คาดว่าจะมีผลกระทบต่อราคาคริปโทเคอร์เรนซีในการสอนแบบจำลอง เช่น ราคาทอง ดัชนีดอลลาร์สหรัฐ ปัจจัยทางเศรษฐกิจอื่นๆ เป็นต้น

## เอกสารอ้างอิง

- Edward M Ruiz. (2557). Forecasting Exchange Rate Volatility with High Frequency Bitcoin Data : Is digital currency really that different?
- Sean McNally (2559). Predicting the price of Bitcoin using Machine Learning.
- จิ้นโน, ภ. (2559, 07). การพยากรณ์ราคาข้าวส่งออกของประเทศไทยโดยใช้แบบจำลอง ARIMAX.
- JJ. (2559). MAE and RMSE — Which Metric is Better? Retrieved from <https://medium.com/human-in-a-machine-world/mae-and-rmse-which-metric-is-better-e60ac3bde13d>
- Muhammad, J Amjad and Devavrat (2560). Trading Bitcoin and Online Time Series Prediction.
- ภูมิวุฒิสาร, ร. ภ. (2561). การพยากรณ์ปริมาณน้ำฝนระยะสั้นในบริเวณพื้นที่สนามบินสุวรรณภูมิด้วยโครงข่ายระบบประสาทแบบย้อนกลับ. Journal of Information Science and Technology.
- Wang Zhengyang, Li Xingzhou and Ruan Jinjin (2562). Prediction of Cryptocurrency Price Dynamics with Multiple Machine Learning Techniques.
- Li, Y. W. (2562). A hybrid ensemble method for pulsar candidate classification. Astrophys Space Sci.
- Yan Pang, Ganeshkumar Sundararaj and Jiewen Ren (2562). Cryptocurrency Price Prediction Using Time Series and Social Sentiment Data.
- Hansika Hewamalage, C. B. (2563). Recurrent Neural Networks for Time Series Forecasting: Current Status. Elsevier.
- Yu Wang and Runyu Chen (2563). Cryptocurrency price prediction based on multiple market sentiment.

วนเศรษฐ, ส. ป. (2564). การพยากรณ์ราคาหุ้นในหมวดอุตสาหกรรมเทคโนโลยีสารสนเทศและการสื่อสารเพื่อคาดการณ์ผลตอบแทนจากกลยุทธ์การลงทุนถัวเฉลี่ยต้นทุน. *Journal of Social Academic*.

ภูมิชาย จิตชัยโอม ศรีนิล (2564). การทำนายดัชนีหุ้นด้วยการใช้แบบจำลองการเรียนรู้เชิงลึก

moneybuffalo. (2564, ตุลาคม 27). Retrieved from moneybuffalo:

<https://www.moneybuffalo.in.th/vocabulary/what-is-fear-and-greed-index>

Giulia Serafini, Ping Yi, Qingquan Zhang, Marco Brambillay, Jiayue Wangk, Yiwei Hu and Beibei L(2565). Sentiment-Driven Price Prediction of the Bitcoin based on Statistical and Deep Learning Approaches.

Andras Ferenczi and Costin Badic (2565). Prediction of Ether Prices Using DeepAR and Probabilistic Forecasting.

Ziyang Yuan (2566). Gold and Bitcoin Price Prediction based on KNN XGBoost and LightGBM Model.

Boris N., Dmitri C., Nicolas C., Yoshua B. (2020). N-BEATS: NEURAL BASIS EXPANSION ANALYSIS FOR INTERPRETABLE TIME SERIES FORECASTING. *ICLR 2020*,3.

Bryan L., Sercan O., Nicolas L., Tomas P. (2020). Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. *Elsevier 2020*,6.

## ประวัติผู้เขียน

ชื่อ-สกุล	นาย พงศ์ภีระ จารุวิจิตรรัตนา
วัน เดือน ปี เกิด	17 มกราคม 2528
ประวัติการศึกษา	สำเร็จการศึกษามัธยมศึกษาตอนปลาย โรงเรียนนวมินทราชินูทิศ บดินทรเดชา สิงห์ สิงหเสนี สำเร็จการศึกษาปริญญาตรี สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง สาขา วิทยาการคอมพิวเตอร์ สำเร็จการศึกษาปริญญาโท มหาวิทยาลัยอัสสัมชัญ สาขาบริหารธุรกิจ
ประวัติการทำงาน	ผู้จัดการโครงการ บริษัท Prime Solution and Services co. ltd ผู้จัดการโครงการ บริษัท วิโปรเทค จำกัด Application Support Supervisor บริษัท อุตสาหกรรมใหม่ไทย จำกัด (Jim Thompson Thai Silk Company Limited) Senior System Engineer บริษัท Wallenius Wilhelmsen Logistics Business Support Co.Ltd Technology Consultant บริษัท HP Hewlett Packard IT System Administrator บริษัท ATOS Solution and Services Limited

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้