



การสร้างโมเดลเพื่อทำนายราคาของเหรียญ Ethereum ด้วยราคาสินทรัพย์
ทางการเงิน ดัชนีตลาดและปัจจัยทางเศรษฐกิจมหภาคในตลาดเงินและ
ตลาดทุนของประเทศไทย

โดย

อริศิษฐ์ วัฒนาศุทธิวงศ์

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต
สาขาวิชาการแปรรูปธุรกิจทางดิจิทัล
วิชาเอกวิทยาศาสตร์ข้อมูล
วิทยาลัยนวัตกรรม มหาวิทยาลัยธรรมศาสตร์
ปีการศึกษา 2567

PREDICTIVE MODELING FOR ETHEREUM PRICE BY FINANCIAL
ASSETS, MARKET INDICES AND OTHER MACROECONOMIC
FACTORS IN FINANCIAL AND CAPITAL
MARKET OF THAILAND

BY

ATHISIT WATTANASUTTHIWONG

AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENTS FOR THE DEGREE OF MASTER OF SCIENCE
DIGITAL BUSINESS TRANSFORMATION
DATA SCIENCE
COLLEGE OF INNOVATION
THAMMASAT UNIVERSITY
ACADEMIC YEAR 2024

มหาวิทยาลัยธรรมศาสตร์

วิทยาลัยนวัตกรรมการศึกษา

การค้นคว้าอิสระ

ของ

อติศิษฐ์ วัฒนาศูทธิวงศ์

เรื่อง

การสร้างโมเดลเพื่อทำนายราคาของเหรียญ Ethereum ด้วยราคาสินทรัพย์ทางการเงิน ดัชนีตลาด
และปัจจัยทางเศรษฐกิจมหภาคในตลาดเงินและตลาดทุนของประเทศไทย

ได้รับการตรวจสอบและอนุมัติ ให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต

เมื่อ วันที่ 16 ธันวาคม พ.ศ. 2567

ประธานกรรมการสอบการค้นคว้าอิสระ



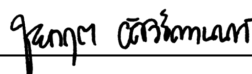
(ดร.มานิต สาทิตสมิตพงษ์)

กรรมการและอาจารย์ที่ปรึกษาการค้นคว้าอิสระ



(ผู้ช่วยศาสตราจารย์ ดร.นพพล ตั้งจิตพรหม)

คณบดี



(ผู้ช่วยศาสตราจารย์ ดร.ชยกฤต อัครวิชิตานนท์)

หัวข้อการค้นคว้าอิสระ	การสร้างโมเดลเพื่อทำนายราคาของเหรียญ Ethereum ด้วยราคาสินทรัพย์ทางการเงิน ดัชนีตลาดและปัจจัยทางเศรษฐกิจมหภาคในตลาดเงินและตลาดทุนของประเทศไทย
ชื่อผู้เขียน	อริศิษฐ์ วัฒนาสุทธิวงศ์
ชื่อปริญญา	วิทยาศาสตรมหาบัณฑิต
สาขาวิชา/คณะ/มหาวิทยาลัย	การแปรรูปธุรกิจทางดิจิทัล วิชาเอกวิทยาศาสตร์ข้อมูล วิทยาลัยนวัตกรรม มหาวิทยาลัยธรรมศาสตร์
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ผู้ช่วยศาสตราจารย์ ดร.นพพล ตั้งจิตพรหม
ปีการศึกษา	2567

บทคัดย่อ

สกุลเงินดิจิทัลนับเป็นสินทรัพย์การลงทุนเกิดใหม่ที่ได้รับความนิยมมากขึ้นอย่างต่อเนื่อง และปัจจัยที่มีผลต่อราคาสินทรัพย์กลุ่มนี้ก็ยังเป็นเป็นโจทย์ที่ท้าทายสำหรับนักวิเคราะห์และนักวิจัย หนึ่งในปัจจัยที่มีผลต่อราคาของสินทรัพย์กลุ่มนี้คือปัจจัยด้านเศรษฐกิจมหภาคอย่างไรก็ดี ข้อมูลที่ใช้เป็นปัจจัยอธิบายในงานวิจัยส่วนมากยังคงเป็นข้อมูลจากประเทศขนาดเศรษฐกิจใหญ่หรือประเทศเศรษฐกิจพัฒนาแล้วเท่านั้น

งานวิจัยชิ้นนี้จึงทำการทดลองศึกษาประสิทธิภาพในการอธิบายการเปลี่ยนแปลงราคาของ Ethereum โดยทดสอบการใช้ข้อมูลจากประเทศเศรษฐกิจขนาดใหญ่อย่างสหรัฐอเมริกา เปรียบเทียบกับข้อมูลจากประเทศเศรษฐกิจขนาดเล็กอย่างประเทศไทย โดยมีทฤษฎีสนับสนุนคือ กระแสโลกาภิวัตน์ (Globalization) ที่ทำให้ระบบเศรษฐกิจมีความเชื่อมโยงต่อกันมากขึ้น โดยใช้เทคนิคด้านวิทยาศาสตร์ข้อมูลผ่าน 3 โมเดลคือ ARIMAX, SVR และ LSTM

ผลการศึกษาพบว่าข้อมูลจากประเทศไทยยังไม่ได้มีประสิทธิภาพเทียบเท่ากับข้อมูลจากสหรัฐอเมริกาสำหรับโมเดล ARIMAX และ SVR อย่างไรก็ตาม โมเดล LSTM มีประสิทธิภาพในการพยากรณ์ราคา Ethereum ได้ในระดับทัดเทียมกันจากการใช้ข้อมูลจากสหรัฐอเมริกาเทียบกับข้อมูลไทย โดยพบว่าปัจจัยที่มีผลมากที่สุดคือดัชนีหุ้น S&P 500 และดัชนีหุ้น SETTECH

คำสำคัญ: Ethereum, ARIMA, SVR, LSTM, Thai Data

Independent Study Title	PREDICTIVE MODELING FOR ETHEREUM PRICE BY FINANCIAL ASSETS, MARKET INDICES AND OTHER MACROECONOMIC FACTORS IN FINANCIAL AND CAPITAL MARKET OF THAILAND
Author	Athisit Wattanasutthiwong
Degree	Master of Science
Department/Faculty/University	Digital Business Transformation Data Science College of Innovation Thammasat University
Independent Study Advisor	Assistant Professor Nopphon Tangjitprom, Ph.D.
Academic Year	2024

ABSTRACT

Cryptocurrencies are emerging investment assets that are continuously gaining popularity. Factors affecting the price of these assets remain a challenge for analysts and researchers. Macroeconomic factors are one of the key pricing factors. However, the data used as an explanatory factor in most research is still only data from large or advanced economies.

This research conducted an experiment to study the efficiency in explaining the price changes of Ethereum by testing the use of data from a large and small economic country (USA. & Thailand). Globalization is a support theory as it shows the interconnectedness of economics. The test is done through data science techniques with 3 models: ARIMAX, SVR and LSTM.

The results show that Thailand data are not as efficient as USA data for ARIMAX and SVR. However, the LSTM model has a comparable performance in forecasting Ethereum prices using data from the USA and Thailand, with the most influential factors being the S&P 500 and SETTECH indexes.

Keywords: Ethereum, ARIMA, SVR, LSTM, Thai Data

กิตติกรรมประกาศ

การค้นคว้าอิสระเล่มนี้สำเร็จลุล่วงด้วยดีจากคำแนะนำและข้อเสนอแนะจากอาจารย์ที่ปรึกษา ผศ. ดร.นพพล ตั้งจิตพรหมและอีกท่านคือประธานกรรมการการสอบ อ. ดร.มานิต สาธิตสมิต พงษ์ที่ให้คำแนะนำที่เป็นประโยชน์เพิ่มเติม ทำให้การค้นคว้าอิสระเล่มนี้สมบูรณ์มากขึ้น

ขอบคุณทุกกำลังใจจากครอบครัวและภรรยา ที่ส่งเสริมและสนับสนุนช่วยเหลือให้การค้นคว้าอิสระเล่มนี้สำเร็จได้อย่างลุล่วง ขอขอบคุณเจ้าหน้าที่เจ้าหน้าที่วิชาการของคณะที่ช่วยเหลือชี้แจงขั้นตอนการส่งเอกสารต่างๆ

อติศิษฐ์ วัฒนาสุทธิวงศ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	(1)
บทคัดย่อภาษาอังกฤษ	(2)
กิตติกรรมประกาศ	(3)
สารบัญตาราง	(7)
สารบัญภาพ	(8)
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ	1
1.2 วัตถุประสงค์การวิจัย	2
1.3 สมมติฐานงานวิจัย	2
1.4 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย	3
1.5 แผนงานการค้นคว้าอิสระ	3
บทที่ 2 วรรณกรรมและงานวิจัยที่เกี่ยวข้อง	4
2.1 จุดประสงค์และขอบเขตการทบทวนวรรณกรรม	4
2.2 ประวัติความเป็นมาและความสำคัญของ Ethereum	4
2.3 งานวิจัยที่ใช้ปัจจัยทางเศรษฐศาสตร์มหภาคเพื่ออธิบายการเปลี่ยนแปลง ราคาของ Ethereum	5
2.4 งานวิจัยที่อธิบายกระแสโลกาภิวัตน์	7
2.5 โมเดลทำนายข้อมูลอนุกรมเวลาที่เกี่ยวข้อง	9

	(5)
2.5.1 Classical Time Series Model: ARIMA และ ARIMAX	9
2.5.2 Supervised Model: SVR	11
2.5.3 Deep Learning-Based Model: LSTM	11
2.6 สรุปผลการทบทวนวรรณกรรม	12
บทที่ 3 วิธีการวิจัย	13
3.1 ระเบียบวิธีการทำวิจัย	13
3.2 การรวบรวมข้อมูล	13
3.3 การทำความสะอาดและการแปลงข้อมูล	18
3.4 การวิเคราะห์ข้อมูล	18
3.4.1 เทคนิคที่ใช้	18
3.4.2 เกณฑ์ที่ใช้วัดประสิทธิภาพ	19
3.4.3 การปรับค่าตัวแปรและภาษาการเขียนโปรแกรม	19
3.4.4 การแบ่งชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ	19
3.5 การกำหนดค่าตัวแปร (parameter) ที่เหมาะสมในแต่ละโมเดล	20
3.5.1 โมเดล 1: ARIMA และ ARIMAX	20
3.5.2 โมเดล 2: SVR	21
3.5.2 โมเดล 3: LSTM	21
3.6 จริยธรรมในการวิจัยและประเด็นด้านข้อมูลส่วนบุคคล	22
3.7 ข้อจำกัดของงานวิจัย	22
3.8 สรุปผลระเบียบวิธีการทำวิจัย	22
บทที่ 4 ผลการวิจัยและอภิปรายผล	24
4.1 ผลการวิจัย	24
4.1.1 โมเดล ARIMA และ ARIMAX	24
4.1.2 โมเดล SVR	28
4.1.2 โมเดล LSTM	32
4.2 อภิปรายผลการวิจัย	36
4.2.1 ผลการวิเคราะห์ในแต่ละโมเดล	36

	(6)
4.2.2 ตัวแปรที่มีผลในการพยากรณ์ราคา Ethereum	37
บทที่ 5 สรุปผลวิจัยและข้อเสนอแนะ	40
5.1 สรุปผลวิจัย	40
5.2 ปัญหาและข้อเสนอแนะ	41
รายการอ้างอิง	42
ประวัติผู้เขียน	45



สารบัญตาราง

ตารางที่	หน้า
3.1 ตารางข้อมูลตัวแปร	14
3.2 ตารางสรุปวิธีการทำวิจัย	23
4.1 ผลลัพธ์ของโมเดล ARIMAX ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล USD	26
4.2 ผลลัพธ์ของโมเดล ARIMAX ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล THB	26
4.3 สรุปค่าตัวแปรโมเดล SVR	29
4.4 ผลลัพธ์ของโมเดล SVR ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล USD	30
4.5 ผลลัพธ์ของโมเดล SVR ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล THB	30
4.6 สรุปค่าตัวแปรโมเดล LSTM	32
4.7 ผลลัพธ์ของโมเดล LSTM ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล USD	34
4.8 ผลลัพธ์ของโมเดล LSTM ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล THB	34
4.9 สรุปการประเมินผลด้วยค่า MAPE ทั้ง 3 โมเดล	37
4.10 ตัวแปรอิสระที่ใช้สำหรับโมเดล SVR	39

สารบัญภาพ

ภาพที่	หน้า
3.1 ตัวอย่างการแบ่งข้อมูล k-fold cross validation สำหรับ Time Series Data	20
4.1 ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย ARIMA (1, 1, 1)	24
4.2 ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย ARIMA (1, 1, 1)	25
4.3 ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย ARIMAX (1, 1, 1) และตัวแปรอิสระ 3 ตัว	27
4.4 ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย ARIMAX (1, 1, 1) และตัวแปรอิสระ 1 ตัว	27
4.5 ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย SVR	28
4.6 ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย SVR	29
4.7 ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย SVR และตัวแปรอิสระ 5 ตัว	31
4.8 ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย SVR และตัวแปรอิสระ 5 ตัว	31
4.9 ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย LSTM	32
4.10 ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย LSTM	33
4.11 ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย LSTM และตัวแปรอิสระ 1 ตัว	35
4.12 ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย LSTM และตัวแปรอิสระ 1 ตัว	35
4.13 ข้อมูลโมเดล ARIMAX ในการพยากรณ์ราคา ETH สกุล USD	38
4.14 ข้อมูลโมเดล ARIMAX ในการพยากรณ์ราคา ETH สกุล THB	38

บทที่ 1 บทนำ

1.1 ที่มาและความสำคัญ

วิทยาศาสตร์ข้อมูลเป็นศาสตร์ที่ถือกำเนิดมาได้ไม่นานเมื่อเทียบกับศาสตร์ด้านอื่นๆ เป็นศาสตร์ที่ผสมผสานองค์ความรู้หลายด้านทั้งคณิตศาสตร์ สถิติ วิทยาการคอมพิวเตอร์และการสื่อสารเข้าด้วยกันเพื่อสกัดองค์ความรู้และข้อมูลเชิงลึกจากข้อมูลจำนวนมาก วิทยาศาสตร์ข้อมูลมีพัฒนาการค่อนข้างก้าวกระโดดในช่วงหลังปี ค.ศ. 2000 ที่เริ่มต้นจากการเข้ามาของสื่อสังคมออนไลน์ที่มีการขยายวงกว้างขึ้นรวดเร็ว ปริมาณข้อมูลในโลกขยายตัวเพิ่มขึ้นในอัตราทวีคูณตามจำนวนผู้ใช้งานสื่อสังคมออนไลน์ ข้อมูลปริมาณมหาศาลและพัฒนาการในด้านเทคโนโลยีการประมวลผลของเครื่องคอมพิวเตอร์ผลักดันให้เกิดการพัฒนาอัลกอริทึมในการวิเคราะห์ข้อมูลมากขึ้น ทุกวันนี้วิทยาศาสตร์ข้อมูลมีบทบาทสำคัญในหลากหลายอุตสาหกรรม โดยเฉพาะสาขาด้านการเงิน ที่มีการใช้ข้อมูลปริมาณมหาศาลนี้ในการวิเคราะห์และทำนายผลต่างๆ ที่มีคุณค่าในเชิงพาณิชย์กับหลายๆ บริษัท ไม่ว่าจะเป็นการวิเคราะห์พฤติกรรมลูกค้า การทำนายโอกาสผิดชำระหนี้ การตรวจจับธุรกรรมที่ผิดปกติและมีโอกาสฉ้อโกง หรือการวิเคราะห์ข้อมูลตลาด คาดการณ์ราคาที่เหมาะสมของสินทรัพย์แต่ละประเภท

สินทรัพย์สกุลเงินดิจิทัล (Cryptocurrency) เป็นสินทรัพย์ทางเลือกในการลงทุนยุคใหม่ที่เพิ่งเกิดขึ้นได้ไม่นาน มีราคาและอัตราผลตอบแทนที่ผันผวนสูงกว่าสินทรัพย์การลงทุนแบบดั้งเดิม อย่างเช่นหุ้นสามัญหรือหุ้นกู้ เงินสกุลดิจิทัลที่มีขนาดตลาดใหญ่ที่สุดและเกิดขึ้นเป็นตัวแรกคือบิตคอยน์ (Bitcoin) งานวิจัยในศาสตร์ด้านการทำนายราคาสินทรัพย์ประเภทสกุลเงินดิจิทัลส่วนมากจึงมุ่งเน้นไปที่การทำนายราคาของบิตคอยน์ มีงานวิจัยหลายงานที่ค้นพบปัจจัยต่างๆ ที่อธิบายการเคลื่อนไหวของราคาบิตคอยน์ เช่นปัจจัยด้านพื้นฐานของสกุลเงินดิจิทัล ปัจจัยด้านเทคโนโลยี ปัจจัยด้านเศรษฐศาสตร์ ปัจจัยด้านความผันผวนของตลาด ปัจจัยเกี่ยวกับตัวนักลงทุนและปัจจัยด้านสื่อสังคมออนไลน์ อย่างไรก็ตาม ปัจจัยที่ใช้ในการอธิบายราคา เท่าที่ผู้วิจัยทราบ ทั้งหมดเป็นปัจจัยในระดับโลกหรือเป็นกลุ่มข้อมูลจากประเทศเศรษฐกิจขนาดใหญ่ทั้งสิ้น ยังไม่เคยมีงานวิจัยขึ้นใดที่ใช้ปัจจัยของประเทศเศรษฐกิจขนาดเล็กอย่างประเทศไทยมาศึกษาเพื่อทำนายราคาของสินทรัพย์สกุลเงินดิจิทัลอย่างเหรียญ Ethereum มาก่อน ซึ่ง Ethereum เป็นหนึ่งในกลุ่มสกุลเงินดิจิทัลที่มีขนาดตลาดใหญ่เป็นอันดับ 2 รองจากบิตคอยน์ มีขนาดตลาดอยู่ที่ 4.5 แสนล้านดอลลาร์สหรัฐอเมริกาจากผลการสืบค้นข้อมูลผ่าน <https://coinmarketcap.com/> ณ วันที่ 6 มีนาคม 2567

กระแสโลกาภิวัตน์ในยุคปัจจุบันส่งผลให้ภาคเศรษฐกิจของหลายประเทศมีความเชื่อมโยงกันมากขึ้น ไม่ว่าจะเป็นด้านการค้าขาย นำเข้า ส่งออกระหว่างประเทศ แรงงานข้ามชาติ นโยบายด้านการเงิน การคลัง อัตราแลกเปลี่ยน หรือเหตุการณ์วิกฤตใหญ่อย่างวิกฤตต้มยำกุ้งในประเทศไทยเมื่อปี พ.ศ. 2540 หรือการระบาดของโควิด 19 ที่เริ่มขึ้นในประเทศจีนปี พ.ศ.2562 ก็เป็นสองเหตุการณ์ใหญ่ที่ส่งผลกระทบต่อเป็นวงกว้างในหลายประเทศ จึงเป็นที่มาของผู้วิจัยที่คาดว่าปัจจัยเฉพาะของประเทศไทยก็สามารถใช้ในการทำนายราคาสินทรัพย์สกุลเงินดิจิทัลได้แม้ว่าจะไม่น่ามีความเกี่ยวข้องโดยตรงกับราคาของสินทรัพย์นี้ที่ซื้อขายกันในประเทศไทยค่อนข้างน้อยเมื่อเทียบกับสัดส่วนการซื้อขายทั้งหมดทั่วโลก ซึ่งในงานวิจัยชิ้นนี้จะศึกษาที่ปัจจัยกลุ่มเศรษฐศาสตร์มาทำนายราคาเหรียญ Ethereum ซึ่งหากผลลัพธ์ที่ได้เป็นไปตามสมมติฐานของผู้วิจัยจริง ก็จะเปิดโอกาสให้นักวิเคราะห์ นักเศรษฐศาสตร์ ผู้กำหนดนโยบาย หรือนักลงทุนทั่วไปที่ชำนาญในตลาดประเทศไทยสามารถใช้การคาดการณ์ตัวแปรในกลุ่มเศรษฐกิจของประเทศไทยเพื่อทำนายราคาเหรียญ Ethereum ได้

1.2 วัตถุประสงค์การวิจัย

1. เพื่อศึกษาว่าปัจจัยทางด้านเศรษฐศาสตร์ในประเทศไทย สามารถใช้อธิบายการเปลี่ยนแปลงราคาของเหรียญ Ethereum ได้หรือไม่ โดยใช้กระบวนการด้านวิทยาศาสตร์ข้อมูล
2. หากมีปัจจัยที่สามารถอธิบายได้ ปัจจัยใดมีผลต่อราคาของ Ethereum มากที่สุดและไล่ตามลำดับได้

1.3 สมมติฐานงานวิจัย

กระแสโลกาภิวัตน์ที่เชื่อมโยงเศรษฐกิจของแต่ละประเทศเข้าด้วยกัน จะทำให้ปัจจัยเศรษฐกิจเฉพาะตัวของประเทศไทยเองที่แม้ว่าจะไม่ได้เกี่ยวข้องโดยตรงหรือเกี่ยวในสัดส่วนที่น้อยมากกับตลาดการซื้อขายเหรียญ Ethereum สามารถใช้อธิบายการเปลี่ยนแปลงราคาของเหรียญ Ethereum ได้ด้วยกระบวนการด้านวิทยาศาสตร์ข้อมูล

1.4 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

คาดว่าจะเป็งานวิจัยชิ้นแรกที่พยายามอธิบายการเปลี่ยนแปลงของราคาเหรียญ Ethereum ด้วยปัจจัยเฉพาะด้านทางเศรษฐศาสตร์ของประเทศไทย และเป็นทิศทางในอนาคตต่อไปสำหรับผู้วิจัยท่านอื่นๆ ให้ลองศึกษาโดยใช้ปัจจัยเฉพาะของประเทศไทยมาอธิบายการเปลี่ยนแปลงราคาเหรียญ Ethereum

1.5 แผนงานการค้นคว้าอิสระ

การค้นคว้าอิสระนี้มีรายละเอียดทั้งหมด 5 บทด้วยกันคือ บทที่ 1 เป็นบทนำดังที่ได้กล่าวไว้ในหน้าก่อนหน้า บทที่ 2 การทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องซึ่งจะสรุปสาระสำคัญของงานวิจัยที่เกี่ยวข้องกับการทำนายราคาเหรียญ Ethereum บทที่ 3 วิธีการวิจัยเหตุผลในการเลือกใช้โมเดลที่นำมาทดสอบ บทที่ 4 ผลการวิจัยและอภิปรายผล จะมีการเปรียบเทียบผลการวิจัยของแต่ละโมเดลที่เลือกใช้ และอธิบายสาเหตุและผลลัพธ์ และจบที่ บทที่ 5 เป็นการสรุปผลวิจัยและข้อเสนอแนะสำหรับงานวิจัยในอนาคตสำหรับผู้วิจัยท่านอื่นๆ

บทที่ 2

วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.1 จุดประสงค์และขอบเขตการทบทวนวรรณกรรม

การทบทวนวรรณกรรมจะเน้นไปที่งานวิจัยที่ใช้ปัจจัยทางเศรษฐศาสตร์มหภาคมาอธิบายการเปลี่ยนแปลงราคาของEthereum รวมถึงรายละเอียดของเทคนิคที่ใช้ประมวลผล และงานวิจัยที่ศึกษาเกี่ยวกับกระแสโลกาภิวัตน์เพื่อเป็นหลักฐานสนับสนุนสมมติฐานที่ว่าเศรษฐกิจระหว่างประเทศมีความเชื่อมโยงต่อกัน รวมทั้งทบทวนที่มาและความสำคัญของ Ethereum และโมเดลการทำนายข้อมูลอนุกรมเวลาที่เกี่ยวข้องกับงานวิจัยนี้

2.2 ประวัติความเป็นมาและความสำคัญของ Ethereum

Ethereum เป็นแพลตฟอร์ม blockchain แบบกระจายศูนย์ (Decentralized) ที่ถูกพัฒนาขึ้นโดย Vitalik และเปิดตัวสู่สาธารณะในช่วงปี 2015 โดยใช้เงินสกุล Ether (ETH) เป็นเงินสกุลกลางในการทำธุรกรรมบนแพลตฟอร์ม Ethereum มีจุดเด่นสำคัญคือสามารถประยุกต์ใช้ Smart Contract ในการทำธุรกรรม โดยที่ Smart Contract นี้เป็นโปรแกรมที่สามารถดำเนินการได้ด้วยตัวเองเมื่อครบเงื่อนไขที่ตกลงกันไว้ ความสามารถนี้เหนือกว่าสกุลเงินดิจิทัลตัวแรกที่เกิดขึ้นอย่างบิตคอยน์ที่ทำให้เกิดการทำธุรกรรมแบบกระจายศูนย์โดยไม่ผ่านตัวกลางในรูปแบบอื่นๆได้ เช่นการกู้ยืม การระดมทุนประเภท Initial Coin Offering (ICO) และการสร้างแอปพลิเคชันแบบกระจายศูนย์ (Decentralized Application)

Ethereum เข้ามาเปลี่ยนแปลงวงการเทคโนโลยีด้วย Decentralized Application (dApp) ซึ่งแตกต่างกับ Application ที่ใช้กันอยู่ทุกวันนี้ไม่ว่าจะเป็น Facebook หรือ Line ที่เป็น Centralized Application จุดเด่นที่ dApp นำมาคือความน่าเชื่อถือและสามารถตรวจสอบย้อนหลังได้ เพราะผู้ใช้สามารถตรวจสอบชุดคำสั่งที่อยู่บน dApp ได้ และหากผู้ใช้มีความเข้าใจในภาษาคอมพิวเตอร์ก็จะสามารถเข้าใจได้ว่า dApp นั้นมีกลไกการทำงานอย่างไร โดยเฉพาะเรื่องของการเงินที่ต้องการความปลอดภัยและความโปร่งใสสูง ซึ่งการเงินแบบกระจายศูนย์จะถูกเรียกว่า Decentralized Finance (DeFi) อีกปัจจัยหนึ่งคือ เนื่องจาก Blockchain คือเทคโนโลยีที่มีการกระจาย Node ประมวลผลออกไปทั้งเครือข่าย จึงไม่ต้องกังวลว่าผู้ให้บริการ Application นั้นๆจะประสบปัญหาต้องปิดตัวลง ทำให้ข้อมูลของผู้ใช้ที่อยู่บน Application นั้นๆสูญหายไป การที่

Ethereum blockchain เข้ามามีบทบาทเข้ามาเป็นแพลตฟอร์มที่ทำให้นักพัฒนาสร้างสรรค์ dApp ที่มีทั้งความปลอดภัยและโปร่งใส เข้ามามีส่วนร่วมในแพลตฟอร์มมากขึ้นจะยิ่งส่งผลให้สกุลเงินดิจิทัลอย่าง Ethereum มีมูลค่าและมีความสำคัญเพิ่มขึ้นต่อเนื่องตามแนวโน้มของผู้พัฒนาและผู้ใช้งานที่ยังมีจำนวนเพิ่มขึ้นจากการขยายตัวของโลกดิจิทัล

2.3 งานวิจัยที่ใช้ปัจจัยทางเศรษฐศาสตร์มหภาคเพื่ออธิบายการเปลี่ยนแปลงราคาของ Ethereum

(Khedr, Arif, Raj, El-Bannany, Alhashmi & Sreedharan, 2021) ได้ทำการสำรวจงานวิจัยที่ทำนายราคาของสกุลเงินดิจิทัลในช่วงปี 2010 ถึง 2020 ซึ่งมีทั้งการใช้เทคนิคทางสถิติดั้งเดิมและใช้เทคนิคการเรียนรู้ของเครื่อง พบว่างานวิจัยจำนวนมากเพิ่งเริ่มตีพิมพ์หลังจากปี 2017 เป็นต้นมา สะท้อนถึงการได้รับความนิยมที่เพิ่มมากขึ้นในช่วงไม่กี่ปีหลังมานี้ โดยเทคนิคการเรียนรู้ของเครื่องค่อนข้างจะมีประสิทธิภาพสูงกว่าเทคนิคทางสถิติดั้งเดิม ขยายความต่อไปได้ว่าเทคนิคการเรียนรู้แบบเครื่องที่มีความซับซ้อน ใช้จัดการข้อมูลที่มีความซับซ้อน มีความสัมพันธ์แบบ non-linear และมีความเปลี่ยนแปลงรวดเร็วอย่างข้อมูลสกุลเงินดิจิทัลได้ดีกว่าเทคนิคทางสถิติดั้งเดิมที่มีกระบวนการไม่ซับซ้อนนัก เทคนิคการเรียนรู้ของเครื่องที่ทำงานได้ดีมีหลายเทคนิคเช่น Random Forest ที่มีจุดเด่นในการจัดการชุดข้อมูลขนาดใหญ่และป้องกันปัญหา overfit ได้ดี หรือ Support Vector Machines (SVMs) ที่มีประสิทธิภาพกับการทำงานกับข้อมูลที่มี dimensionality สูงและค้นหารูปแบบของข้อมูลได้ หรือ Neural Networks ซึ่งเป็นเทคนิคที่ทรงพลังในการหาความสัมพันธ์แบบซับซ้อนจากชุดข้อมูลขนาดใหญ่ และ Long Short-Term Memory (LSTM) ที่สามารถจัดการข้อมูลอนุกรมเวลาได้ดี อย่างไรก็ตามเทคนิคที่มีประสิทธิภาพสูงในการทำนายราคามักจะเป็น black-box model ที่ยากต่อการทำความเข้าใจและแปลผล ว่าตัวแปรใดที่มีผลต่อการทำนายหรือ model มีหลักการตัดสินใจอย่างไรถึงทำนายข้อมูลนี้ออกมา (Loyola-Gonzalez, 2019) ให้ความเห็นไว้ว่าการเลือกใช้ model จะขึ้นอยู่กับโจทย์ของปัญหาเป็นหลัก หากโจทย์ของปัญหาคือการทำให้ได้ความแม่นยำสูงสุดและความโปร่งใสของ model ไม่ใช่ประเด็นสำคัญ ผู้วิจัยก็สามารถเลือกใช้ black-box model ได้แต่ถ้าโจทย์คือต้องการความโปร่งใส อธิบายได้ ตรวจสอบขั้นตอนการตัดสินใจ เพื่อทำความเข้าใจหรือตรวจสอบว่าตัวแปรใดมีผลมากในการอธิบาย ก็อาจเลือกใช้ white-box model ได้ทั้ง 2 ประเภทสามารถมีประสิทธิภาพได้สูงทัดเทียมกันขึ้นอยู่กับขอบเขตการใช้งานและข้อมูลที่ป้อนเข้าไป (Peng, Prentice, Shams & Sarker, 2023) ทำการทบทวนวรรณกรรมแบบเป็นระบบในเรื่องของปัจจัยที่มีผลต่อราคาสกุลเงินดิจิทัล โดยผู้วิจัยได้จัดกลุ่มปัจจัยหลักออกเป็น 6 ตัวคือ 1.

ปัจจัยพื้นฐาน คู่ที่ปัจจัยพื้นฐานตามหลักเศรษฐศาสตร์คืออุปสงค์มากขึ้น ย่อมทำให้ราคาสูงขึ้นและอุปทานของตัวเหรียญสกุลเงินดิจิทัลที่อาจมีจำนวนจำกัดในบางเหรียญ เช่นบิตคอยน์ (Bitcoin) ที่จะมีอุปทานสูงสุดคือ 21 ล้านเหรียญในปี 2140 ตามที่ถูกกำหนดไว้ในอัลกอริทึมปัจจุบัน (Ciaian, Rajcaniova & Kanacs, 2016) หรือเหรียญทางเลือกอีกหนึ่งตัวอย่างไบแนนซ์คอยน์ (Binance Coin) ก็มีการประกาศเผาเหรียญเป็นระยะซึ่งเป็นกลไกในการลดอุปทานเหรียญ เสริมสร้างมูลค่าและความหายากของไบแนนซ์คอยน์ในระยะยาว (Pitchaporn, 2023) 2. ปัจจัยทางด้านเทคโนโลยี เป็นปัจจัยที่เกี่ยวข้องกับเทคโนโลยี blockchain เช่น hash rate ซึ่งหมายถึงความเร็วในการดำเนินการของคอมพิวเตอร์เพื่อแก้สมการบนบิตคอยน์เน็ตเวิร์ค (Sakurai & Shudo, 2023) การ halving ที่เป็นเหตุการณ์สำคัญต่อบิตคอยน์ เกิดขึ้นในทุกๆ 4 ปี การ halving ทำให้รางวัลที่นักขุดบิตคอยน์ในเน็ตเวิร์คได้รับลดลงครึ่งหนึ่ง เป็นการรักษาสถานะความขาดแคลนของบิตคอยน์ (Singla, Singla & Gupta, 2023) 3. ปัจจัยด้านเศรษฐศาสตร์ เป็นตัวเลขที่บ่งบอกสถานะทางเศรษฐกิจ เช่นอัตราดอกเบี้ย อัตราแลกเปลี่ยนเงินตราต่างประเทศ อัตราเงินเฟ้อ ราคาทอง ราคาน้ำมันดิบ ดัชนีตลาดหุ้น นโยบายเศรษฐกิจ และนโยบายที่เกี่ยวข้องกับสกุลเงินดิจิทัล 4. ปัจจัยด้านความผันผวนในตลาด ด้วยลักษณะเฉพาะตัวของสกุลเงินดิจิทัลที่มีความผันผวนค่อนข้างสูงเมื่อเทียบกับสินทรัพย์ทางการเงินดั้งเดิมอย่างหุ้นหรือหุ้นกู้ ปัจจัยกลุ่มนี้ใช้การศึกษาจากข่าวและเหตุการณ์ใหญ่ๆ เช่นการโจมตีของกลุ่มก่อการร้าย โรคระบาด COVID-19 ที่มีผลต่อความเชื่อมั่นของนักลงทุน 5. ปัจจัยด้านคุณลักษณะเฉพาะตัวของนักลงทุน เช่น ความน่าสนใจของสกุลเงินดิจิทัล ค่าความนิยม ความเชื่อมั่นนักลงทุนอารมณ์และความรู้สึกของผู้พัฒนาแพลตฟอร์ม และ 6. ปัจจัยจากสื่อสังคมออนไลน์ มักจะใช้ข้อมูลตามคีย์เวิร์ดคำค้นหา หรือการเข้าชมหน้าเว็บ เช่น Wikipedia และ Google Trends และ Google Search ปัจจัยหลักที่งานวิจัยชิ้นนี้ศึกษาคือด้านเศรษฐศาสตร์ (Peng et al., 2023) พบว่าทุกตัวแปรในกลุ่มนี้คือ อัตราแลกเปลี่ยน อัตราดอกเบี้ย อัตราเงินเฟ้อ ดัชนีตลาดหุ้น ราคาทองคำและน้ำมันดิบ ล้วนมีนัยสำคัญต่อราคาของสกุลเงินดิจิทัลทั้งสิ้น อย่างไรก็ตาม ข้อจำกัดสำคัญของงานวิจัยคือจำนวนชิ้นงานวิจัยที่นำมาทบทวนส่วนมากมุ่งเน้นไปที่การศึกษาและอธิบายการเปลี่ยนแปลงราคาของบิตคอยน์ เนื่องจากบิตคอยน์เป็นสกุลเงินดิจิทัลตัวแรกและมีขนาดตลาดใหญ่ที่สุด งานวิจัยที่ศึกษาการเปลี่ยนแปลงราคาของ Ethereum ยังมีอยู่ค่อนข้างน้อย

วัชรระ รัตโรจนากุล (2566) ได้ทำการศึกษาปัจจัยที่มีผลต่อการเปลี่ยนแปลงราคาของ Ethereum โดยใช้เทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอน (supervised learning) ทั้งหมด 2 เทคนิคคือ SVR (support vector regression) และ XGBoost (extreme gradient boosting) ใช้ปัจจัยทั้งหมด 4 กลุ่มครอบคลุมตัวแปรด้านเศรษฐศาสตร์ในกลุ่มราคาทองคำ น้ำมันดิบและดัชนีตลาดหุ้นในกลุ่มเศรษฐกิจขนาดใหญ่อย่างสหรัฐ สหภาพยุโรป จีนและญี่ปุ่น ตัวแปรข้อมูลจาก

Ethereum blockchain เช่นจำนวนธุรกรรมรายวัน ค่าธรรมเนียมต่อธุรกรรม ตัวแปรทางด้านสื่อสังคมออนไลน์จาก Wikipedia Reddit Telegram และ Twitter และตัวแปรราคาของสกุลเงินดิจิทัลตัวอื่นๆ เช่น บิตคอยน์ ไบแนนซ์คอยน์ ผลการศึกษาพบว่าทุกตัวแปรที่นำมาใช้สามารถอธิบายการเปลี่ยนแปลงราคาของ Ethereum ได้ทุกตัวยกเว้นตัวแปรด้านสื่อสังคมออนไลน์ และเทคนิค SVR ให้ผลลัพธ์ที่แม่นยำสูงกว่า XGBoost

(Kim, Bock & Lee, 2021) ศึกษาเทคนิคการทำนายราคา Ethereum เช่นกันโดยใช้ 2 กลุ่มปัจจัยเป็นตัวแปรอธิบายการเปลี่ยนแปลงราคา คือ ข้อมูลเศรษฐกิจศาสตร์ ประกอบด้วยดัชนีตลาดหุ้นในประเทศที่มีเศรษฐกิจขนาดใหญ่อย่างสหรัฐอเมริกา สหภาพยุโรป จีนและญี่ปุ่น ดัชนีความผันผวนของตลาดหุ้น ราคาทองคำ ราคาน้ำมันดิบ อัตราแลกเปลี่ยนเงินตราต่างประเทศ และข้อมูลจาก blockchain platform พบว่าทั้งสองปัจจัยมีผลต่อการทำนายราคาของ Ethereum ข้อสรุปเป็นไปในทิศทางเดียวกันกับงานวิจัยของ (Lawuobahsumo, Algieri & Leccadito, 2023) ซึ่งทำการทดสอบว่ากลุ่มตัวแปรด้านเศรษฐกิจศาสตร์และการเงินมีผลต่อการคาดการณ์ผลตอบแทนในระดับเกินปกติ (extreme returns) ของสกุลเงินดิจิทัลใหญ่ 5 ตัว (Bitcoin, Ethereum, Ripple, Litecoin และ Dogecoin) หรือไม่โดยใช้เทคนิค Monotone Composite Quantile Regression Neural Network (MCQRNN) เทียบกับโมเดลพื้นฐาน Historical Simulation และ ARMA (1,1) - GARCH (1,1) ผลลัพธ์พบว่า MCQRNN มีประสิทธิภาพสูงกว่าโมเดลพื้นฐาน และปัจจัยที่มีนัยสำคัญต่อการคาดการณ์อัตราผลตอบแทนแบบรุนแรงคือ VIX index (ดัชนีวัดความผันผวนตลาดหุ้น), Treasury yield spread 10Y-3M (ส่วนต่างอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐ), 5-year forward inflation expectation (คาดการณ์อัตราเงินเฟ้อใน 5 ปีข้างหน้า) และ 10-Year Breakeven Inflation Rate (ส่วนต่างของอัตราผลตอบแทนพันธบัตรกับพันธบัตรชดเชยเงินเฟ้อ 10 ปี)

2.4 งานวิจัยที่อธิบายกระแสโลกาภิวัตน์

(Greenwood-Nimmo, Nguyen & Shin, 2021) ได้พัฒนาเทคนิคที่ใช้วัดความเชื่อมโยงทางเศรษฐกิจมหภาค (Macroeconomic Connectedness) ในระบบเศรษฐกิจทั้งหมด 25 ประเทศ ด้วยเทคนิค Vector Autoregression (VAR) ผลการศึกษานี้พบว่ากลุ่มประเทศเศรษฐกิจใหญ่อย่างสหรัฐอเมริกา สหภาพยุโรป จีน และบราซิลมีอิทธิพลต่อทิศทางเศรษฐกิจโลกโดยรวมสูง ซึ่งสอดคล้องกับ (Wu, 2020) ที่ศึกษาถึงความบูรณาการในตลาดหุ้นของประเทศในภูมิภาคตะวันออกและเอเชียตะวันออกเฉียงใต้ ผลการศึกษาพบว่าปัจจัยเศรษฐกิจของสหรัฐอเมริกาส่งผลอย่างมากและเป็นตัวขับเคลื่อนที่สำคัญต่อการเคลื่อนไหวของตลาดหุ้นในกลุ่มประเทศตะวันออกและตะวันออก

เฉียงใต้ อีกทั้งยังพบว่าการแผ่ขยายอิทธิพลของจีนก็มีผลกับทิศทางตลาดหุ้นในภูมิภาคนี้ด้วยเช่นกัน งานวิจัยของ (Greenwood-Nimmo et al., 2021) ยังได้ใช้เหตุการณ์วิกฤตเศรษฐกิจทางการเงินครั้งใหญ่เมื่อปี 2008 เป็นกรณีศึกษาเพื่อประเมินผลกระทบในโลกความเป็นจริงประกอบ พบว่าวิกฤตนี้ส่งผลอย่างรวดเร็วและรุนแรงต่อระบบการค้าขายและการเติบโตทางเศรษฐกิจ เป็นการตอกย้ำสมมติฐานความเชื่อมโยงของโลกการเงินและกิจกรรมทางเศรษฐกิจ อย่างไรก็ตาม ข้อมูลกลุ่มตัวอย่างที่ใช้คือปี 1980 – 2007 ซึ่งเป็นข้อมูลที่ค่อนข้างเก่าและอาจจะไม่ได้สะท้อนภาพปัจจุบันได้เหมาะสมนัก ตัวแปรบางตัวอาจจะเปลี่ยนไปค่อนข้างเยอะ เช่น ค่าคะแนนระดับอิทธิพลต่อเศรษฐกิจโลกของจีน ขนาดเศรษฐกิจของจีนในปี 2007 กับปี 2022 มีขนาดใหญ่ขึ้นเกือบ 5 เท่าตัว ขนาด GDP ของเศรษฐกิจจีน ในปี 2022 คือ 17,693 พันล้านดอลลาร์สหรัฐ ขณะที่ปี 2007 มีขนาด GDP อยู่ที่ 3,550 พันล้านดอลลาร์สหรัฐเท่านั้น อ้างอิงการสืบค้นข้อมูลจากเว็บไซต์ TradingEconomics.com อีกทั้งวิกฤตใหญ่อย่าง COVID-19 ที่มีการระบาดทั่วโลกในช่วงปี 2020 ก็เป็นอีกหนึ่งตัวอย่างกรณีศึกษาที่น่าสนใจในการเปรียบเทียบผลกระทบกับวิกฤตการเงินเมื่อปี 2008

(Kohpaiboon & Jongwanich, 2019) ใช้วิธีการทบทวนงานวิจัยเชิงประจักษ์ที่เกี่ยวข้องโดยให้ไทยเป็นประเทศกรณีศึกษา สรรวจผลกระทบของโลกาภิวัตน์ต่อเศรษฐกิจไทย โดยมุ่งเน้นที่ 3 องค์ประกอบสำคัญคือ การค้าระหว่างประเทศ การลงทุนโดยตรงจากต่างประเทศ (FDI) และการเคลื่อนย้ายของแรงงานข้ามพรมแดน ซึ่งผลลัพธ์ต่อเศรษฐกิจมีทั้งด้านดีและด้านเสีย การค้าเสรีระหว่างประเทศทำให้ไทยส่งออกสินค้าไปยังตลาดโลก กระตุ้นการเติบโตทางเศรษฐกิจ เพิ่มการจ้างงาน ในขณะที่เงินลงทุนโดยตรงจากต่างประเทศ (FDI) ทำให้ไทยได้รับความรู้และโอกาสในการเข้าถึงเทคโนโลยีใหม่ๆ ส่งเสริมการพัฒนาเศรษฐกิจและสร้างงานที่ใช้ทักษะสูง ในขณะเดียวกันผลกระทบด้านลบคือไทยก็เผชิญกับการแข่งขันด้านการค้าที่รุนแรงขึ้นซึ่งอาจกระทบกับจำนวนการจ้างงานที่น้อยลงและค่าแรงที่ลดลงไปด้วย (Chaipravat, 1975) และบทสัมภาษณ์ผู้ว่าการธนาคารแห่งประเทศไทย¹ ได้ให้นิยามลักษณะเศรษฐกิจประเทศไทยไว้ว่าเป็นเศรษฐกิจขนาดเล็กแบบเปิด จึงมักได้รับผลกระทบค่อนข้างมากจากปัจจัยต่างประเทศ ซึ่งสอดคล้องกับสมมติฐานของผู้วิจัยที่มองว่าการเปลี่ยนแปลงของตัวแปรด้านเศรษฐกิจมหภาคจากประเทศเศรษฐกิจใหญ่จะมีผลกระทบทั้งทางตรงและทางอ้อมต่อเศรษฐกิจของไทย

(Steger, Benedikter, Pechlaner & Kofler, 2023) ได้กล่าวถึงอนาคตแห่งโลกทุนนิยมแบบโลกาภิวัตน์ ที่ถูกกำหนดโดยการพัฒนาที่สำคัญสามประการ หนึ่งคือระบบต่างๆที่ถูกพัฒนาจนเชื่อมกันไปหมดตามกระแสโลกาภิวัตน์ สองคือระบบกำลังอยู่ระหว่างการปรับโครงสร้างและการเปลี่ยนแปลงรอบใหม่ อิงจากการเปลี่ยนแปลงทางดิจิทัลและการเงินที่ก้าวหน้ายิ่งขึ้นของเศรษฐกิจ

¹ หมายเหตุ. จาก “ธปท. บนเวทีโลก ในสายตา เศรษฐพุดิ สุธธิวาทนฤพุดิ,” 2567, *พระสยาม BOT Magazine*, 67(1)

และสังคมโลก และสามคือระบบกำลังเผชิญกับวิกฤตทุนนิยม ทั้งทางเศรษฐกิจและโครงสร้าง ระบบการเงินมีความสำคัญ มีความซับซ้อนและมีความเชื่อมโยงกันขึ้นมาก วิกฤตทางเศรษฐกิจและการเงินมีโอกาสจะส่งผลกระทบต่อเป็นวงกว้าง อย่างเช่นการระบาดของ COVID-19 ที่ส่งผลกระทบต่อเป็นวงกว้างทั่วโลก กิจกรรมทางเศรษฐกิจในหลายประเทศต้องหยุดชะงักกันหมด (Aharon, Ali & Naved, 2023) ทำการวิเคราะห์ผลกระทบจากวิกฤตการเงินในภาคธนาคารเมื่อปี 2023 ที่มีธนาคารล้มละลายไป 4 ธนาคารคือ Signature Bank, Silvergate Bank, Silicon Valley Bank และ Credit Suisse ส่งผลกระทบต่อตลาดหุ้นทั่วโลก โดยเฉพาะหุ้นกลุ่มธนาคาร แม้ผลกระทบจะไม่ได้รุนแรงมาก เนื่องจากได้รับการเข้าพยับยั้งและแก้ไขปัญหาอย่างอย่างรวดเร็วจากทั้งธนาคารกลางสหรัฐ (Federal Reserve Bank) และหน่วยงานกำกับดูแลตลาดเงินของสวิตเซอร์แลนด์ (FINMA) แต่เหตุการณ์นี้ก็ทำให้เห็นว่าตลาดหุ้นตอบสนองต่อข่าวด้านลบอย่างรวดเร็วและรุนแรง

2.5 โมเดลทำนายข้อมูลอนุกรมเวลาที่เกี่ยวข้อง

งานวิจัยนี้ใช้โมเดลจากสามประเภทโมเดลคือโมเดลเชิงสถิติดั้งเดิมที่จัดว่าเป็นโมเดลที่มีประสิทธิภาพสูงและได้รับความนิยมในการใช้คาดการณ์ข้อมูลอนุกรมเวลาอย่าง ARIMA (Autoregressive Integrated Moving Average) โมเดลในกลุ่มการเรียนรู้แบบมีผู้สอน (Supervised Learning) อย่าง SVR (Support Vector Regression) ที่ถูกพัฒนาต่อจาก Support Vector Machine (SVM) ให้สามารถจัดการกับข้อมูลจำนวนต่อเนื่องได้ และโมเดลในกลุ่ม Deep Learning อย่าง LSTM (Long Short-Term Memory) ที่เลียนแบบการทำงานของระบบประสาทของมนุษย์ โดยอาศัยโครงข่ายประสาทเทียม (Artificial Neural Network) ที่มีหลายชั้นซ้อนทับกัน LSTM เป็นหนึ่งในโมเดลประเภท Recurrent Neural Network (RNN) ที่ถูกออกแบบมาเพื่อจัดการกับ Sequential Data หรือข้อมูลที่มีลำดับเช่น ข้อมูลอนุกรมเวลา ข้อความ เสียง หรือวิดีโอ

2.5.1 Classical Time Series Model: ARIMA และ ARIMAX

ARIMA (Autoregressive Integrated Moving Average) เป็นโมเดลทางสถิติที่ใช้สำหรับการวิเคราะห์ข้อมูลอนุกรมเวลาที่ถูกเสนอตั้งแต่ปี 1970 โดย Box และ Jenkins ซึ่งเทคนิคแรกที่ถูกเสนอคือเทคนิค ARMA แบ่งเป็น 2 ส่วนคือ AR (Autoregressive) และ MA (Moving Average) ซึ่งยังมีข้อจำกัดภายใต้เงื่อนไขที่ว่าข้อมูลต้องมีลักษณะนิ่ง (Stationary) จึงเกิดการพัฒนาต่อขึ้นมาเป็น ARIMA เพื่อให้ใช้งานกับข้อมูลที่มีลักษณะไม่นิ่งหรือมีแนวโน้มได้ ในโมเดล ARIMA จึงมีทั้งหมด 3 องค์ประกอบสำคัญคือ

1. AR (Autoregressive) อธิบายถึงความสัมพันธ์ระหว่างค่าปัจจุบันของข้อมูลกับค่าในอดีตของข้อมูล

2. I (Integrated) อธิบายแนวโน้มการเปลี่ยนแปลงของข้อมูล

3. MA (Moving Average) อธิบายความสัมพันธ์ระหว่างค่าปัจจุบันของข้อมูลกับค่าความคลาดเคลื่อนที่เกิดขึ้นในอดีต

สัญกรณ์ในการแสดง ARIMA คือ ARIMA(p, d, q) โดยที่

p = ลำดับของ AR หมายถึงจำนวนค่าล่าช้าของตัวแปรตามในอดีต

d = ลำดับของการทำ differencing เพื่อให้ข้อมูลมีลักษณะนิ่ง

q = ลำดับของ MA หมายถึงจำนวนค่าล่าช้าของความผิดพลาดในอดีต

ARIMA แสดงสมการได้ดังสมการที่ 2.1

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} \quad (2.1)$$

โดยที่ Y_t = ข้อมูลจริง ณ เวลา t

c = ค่าคงที่

ϵ_t = ค่าความคลาดเคลื่อนที่เวลา t

$\phi_1, \phi_2, \dots, \phi_p$ = สัมประสิทธิ์ค่า AR

$\theta_1, \theta_2, \dots, \theta_q$ = สัมประสิทธิ์ค่า MA

p = ตัวแปรลำดับ order ของ AR

q = ตัวแปรลำดับ order ของ MA

ARIMAX (Autoregressive Integrated Moving Average with Exogenous Variable) มีลักษณะเช่นเดียวกันกับ ARIMA แต่เพิ่มตัวแปรอิสระที่ใช้อธิบายตัวแปรตามเข้าไป แสดงสมการได้ดังสมการที่ 2.2

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \dots + \beta_k X_{t-k} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} \quad (2.2)$$

โดยที่ X_t = ตัวแปรอิสระที่เวลา t

$\beta_1, \beta_2, \dots, \beta_k$ = สัมประสิทธิ์ของตัวแปรอิสระ

2.5.2 Supervised Model: SVR

SVR หรือ Support Vector Regression (Awad, Khanna, Awad & Khanna, 2015) ถูกพัฒนาต่อยอดมาจาก Support Vector Machine (SVM) ที่จัดการได้กับข้อมูลที่มีผลลัพธ์ได้แค่สองค่า (binary class) เท่านั้น ใช้หลักการ SVM ในการสร้างเส้นแบ่งเขตข้อมูล (hyperplane) ที่ช่วยให้สามารถทำนายค่าที่เป็นจำนวนต่อเนื่องได้

สมการของ SVR แสดงได้ดังสมการที่ 2.3

$$f(x) = w^T * k(x) + b \quad (2.3)$$

โดยที่ $f(x)$ = ผลลัพธ์ที่คาดการณ์

w = เวกเตอร์น้ำหนัก เป็นตัวกำหนดทิศทางของ hyperplane

$k(x)$ = ฟังก์ชัน kernel ที่แปลงข้อมูลไปยังมิติที่สูงขึ้น

b = ค่าไบแอส เป็นค่าคงที่

2.5.3 Deep Learning-Based Model: LSTM

LSTM หรือ Long Short-Term Memory (Archit, 2023) เป็นโมเดลในกลุ่ม Deep Learning ประเภท RNN (Recurrent Neural Network) ซึ่งถูกออกแบบมาให้จัดการกับข้อมูลมีลำดับ (Sequence Data) โดยเฉพาะ สามารถเรียนรู้ความสัมพันธ์ระหว่างข้อมูลในอดีตและปัจจุบัน โครงสร้างหลักของ LSTM ประกอบด้วย 4 ส่วนดังนี้

1. Cell State (Memory Cell) หรือหน่วยความจำ มีหน้าที่ในการเลือกจำข้อมูลที่สำคัญ และลืมข้อมูลที่ไม่สำคัญ

2. Forget Gate เป็นส่วนที่ควบคุมว่าจะลืมข้อมูลอะไร

3. Input Gate มีหน้าที่ควบคุมว่าจะรับข้อมูลอะไรจากปัจจุบัน

4. Output Gate ควบคุมว่าจะส่งข้อมูลอะไรไปยัง Output

LSTM เรียนรู้ความสัมพันธ์ระหว่างข้อมูลในอดีตและปัจจุบัน ผ่านกลไก Cell State และ Gates 3 ประตุโดยสามารถสรุปหน้าที่ของแต่ละประตุได้ดังนี้

1. Forget Gate พิจารณาข้อมูลจาก Cell State เก่า และ Input ใหม่ เพื่อตัดสินใจว่าจะลืมข้อมูลอะไรจากอดีต

2. Input Gate พิจารณาข้อมูลจาก Input ใหม่เพื่อตัดสินใจว่าจะรับข้อมูลอะไรมาเก็บใน Cell State

3. Output Gate พิจารณาข้อมูลจาก Cell State ใหม่ เพื่อตัดสินใจว่าจะส่งข้อมูลอะไรไปยัง Output

2.6 สรุปผลการทบทวนวรรณกรรม

มีงานวิจัยจำนวนมากที่ศึกษาการคาดการณ์ราคาสกุลเงินดิจิทัลโดยใช้ปัจจัยหลากหลายด้านมาอธิบาย ซึ่งก็พบว่าปัจจัยในหลายๆ กลุ่มก็มีผลและอธิบายการเปลี่ยนแปลงของราคาสกุลเงินดิจิทัลได้ ทั้งนี้ทั้งนั้น งานวิจัยเป็นส่วนมากเน้นที่การศึกษาราคาของบิตคอยน์เป็นหลัก ด้วยความที่บิตคอยน์เป็นเหรียญสกุลเงินดิจิทัลตัวแรกที่เกิดขึ้น เป็นเหรียญหลักและมีขนาดตลาดใหญ่ที่สุด ราคาและอัตราผลตอบแทนมีความผันผวนสูง ซึ่งเป็นมูลเหตุจูงใจให้เกิดการซื้อขายเพื่อเก็งกำไรสูง ส่วนเหรียญที่มีขนาดตลาดใหญ่เป็นอันดับสองอย่าง Ethereum ยังคงมีงานวิจัยน้อยชิ้นที่เน้นการศึกษาราคาของ Ethereum ซึ่งแม้ว่าจะมีขนาดตลาดเล็กกว่าบิตคอยน์ถึงเกือบ 3 เท่าตัว แต่ Ethereum ก็เป็นหนึ่งในตัวเลือกที่ดีที่สุดในการลงทุนทางเลือกสำหรับนักลงทุน หนึ่งในปัจจัยที่ได้รับความนิยมสูงในการใช้เพื่ออธิบายการเปลี่ยนแปลงราคาของสกุลเงินดิจิทัลคือปัจจัยทางด้านเศรษฐศาสตร์ เช่น ดัชนีตลาดหุ้น ราคาทองคำ ราคาน้ำมันดิบ อัตราแลกเปลี่ยนเงินตราระหว่างประเทศ ซึ่งงานวิจัยหลายชิ้นก็พบว่าปัจจัยด้านนี้มีผลทำให้ประสิทธิภาพการทำนายราคาสกุลเงินดิจิทัลดีขึ้น อย่างไรก็ตาม ปัจจัยด้านเศรษฐศาสตร์นี้มักใช้ข้อมูลจากประเทศเศรษฐกิจขนาดใหญ่ อย่างดัชนีตลาดหุ้นสหรัฐอเมริกา หรือสหภาพยุโรป ซึ่งในโลกปัจจุบัน เศรษฐกิจทั่วโลกมีความเชื่อมโยงและทั่วถึงกันไปหมดตามกระแสโลกาภิวัตน์ ประเทศไทยแม้ว่าจะเป็นประเทศเศรษฐกิจขนาดเล็ก แต่มีลักษณะเป็นเศรษฐกิจแบบเปิด ได้รับผลกระทบจากปัจจัยต่างประเทศค่อนข้างมาก ซึ่งหมายความว่าปัจจัยด้านเศรษฐศาสตร์ ตลาดเงินและตลาดทุนของไทย มีแนวโน้มสูงที่จะมีความสัมพันธ์กับประเทศเศรษฐกิจขนาดใหญ่ ผู้วิจัยจึงมองว่าเป็นโอกาสในการศึกษาเพื่อทดสอบว่าการใช้ปัจจัยในระดับท้องถิ่นของประเทศไทยสามารถใช้เพื่อทดแทนปัจจัยในระดับโลกได้สำหรับการคาดการณ์ราคาของสกุลเงินดิจิทัล Ethereum ได้หรือไม่

บทที่ 3 วิธีการวิจัย

3.1 ระเบียบวิธีการทำวิจัย

จุดประสงค์ของงานวิจัยนี้คือเพื่อการทำนายราคาของสกุลเงินดิจิทัล Ethereum โดยใช้ปัจจัยด้านเศรษฐศาสตร์มหภาค ข้อมูลจากตลาดเงินและตลาดทุน ทำการเปรียบเทียบระหว่างการใช้ตัวแปรอิสระระดับโลกของสหรัฐอเมริกาและตัวแปรอิสระระดับท้องถิ่นจากไทย ข้อมูลจึงมีลักษณะเป็นอนุกรมเวลา (Time-Series) และเป็นเลขจำนวนต่อเนื่อง (Continuous Value) จึงจำเป็นต้องใช้โมเดลที่จัดการกับข้อมูลจำนวนต่อเนื่องแบบมีลำดับแบบอนุกรมเวลาได้ รวมถึงต้องสามารถเพิ่มจำนวนตัวแปรอิสระเข้าไปเพื่อช่วยในการทำนายข้อมูลได้ด้วย

3.2 การเก็บรวบรวมข้อมูล

ข้อมูลด้านเศรษฐศาสตร์มหภาค ตลาดเงินและตลาดทุนที่เป็นตัวแปรอิสระในงานวิจัยชิ้นนี้จะรวบรวมจาก Bloomberg Terminal ซึ่งเป็นเครื่องมือที่ใช้สำหรับวิเคราะห์ข้อมูลการเงิน ข้อมูลตลาด และข้อมูลธุรกิจ ได้รับความนิยมนักลงทุน นักวิเคราะห์ ผู้จัดการกองทุน และผู้เชี่ยวชาญด้านการเงินต่างๆ ข้อมูลทั้งหมดถูกรวบรวมมาจากตลาดหลักทรัพย์เช่นข้อมูลราคา ปริมาณการซื้อขาย บริษัทต่างๆที่มีการส่งข้อมูลผลประกอบการ งบการเงิน และหน่วยงานภาครัฐอย่างรัฐบาลหรือธนาคารกลางที่เผยแพร่ข้อมูลเศรษฐกิจของประเทศจากหลายประเทศทั่วโลก ราคา Ethereum (ETH) ในสกุลเงินดอลลาร์สหรัฐอเมริกาและสกุลบาทรวบรวมจาก investing.com

ข้อมูลที่รวบรวมจะเป็นข้อมูลของสหรัฐอเมริกาและประเทศไทยที่มีลักษณะคล้ายกันเปรียบเทียบกันได้ เป็นข้อมูลที่สำคัญและใช้กันอย่างแพร่หลาย เก็บข้อมูลในช่วงมีนาคม ปี 2018 ถึง มิถุนายน ปี 2024 นอกจากตัวแปรเป้าหมายอย่างราคา Ethereum แล้วยังมีกลุ่มข้อมูลตัวแปรอิสระที่แบ่งได้เป็น 3 กลุ่มใหญ่คือ

1. ข้อมูลเศรษฐศาสตร์มหภาค (Macroeconomic Factor) เช่น GDP อัตราการว่างงาน ดัชนีราคาผู้บริโภค ข้อมูลกลุ่มนี้มักมีความถี่ในการเผยแพร่เป็นรายเดือนและรายไตรมาส จึงต้องมีการแปลงข้อมูลให้อยู่ในระดับรายวันโดยแบ่งเป็นการแทนที่ข้อมูลตรงๆ และแบ่งข้อมูลออกเป็นช่วงตามค่าควอไทล์ (IQR)

2. ข้อมูลด้านตลาดการเงิน (Financial Market) เช่น ดอกเบี้ย อัตราผลตอบแทนพันธบัตรรัฐบาล อัตราแลกเปลี่ยน ข้อมูลกลุ่มนี้มีการเผยแพร่เป็นรายวัน แต่จะมีวันที่ข้อมูลขาดหายไปในช่วงที่ไม่ใช่วันทำการของตลาด การวิเคราะห์ที่ใช้การคำนวณทำการตลาดเท่านั้นสำหรับการประมวลผลในกรณีที่มีตัวแปรอิสระ

3. ข้อมูลตลาดทุน (Capital Market) เช่น ดัชนีตลาดหุ้น ดัชนีความผันผวนในตลาดหุ้น กลุ่มนี้มีการเผยแพร่เป็นรายวัน ซึ่งข้อมูลมีครบและเป็นข้อมูลจริงทั้งหมด จึงไม่ต้องมีการแก้ไข

รายละเอียดของตัวแปรทั้งหมดสรุปได้ดังตารางที่ 3.1

ตารางที่ 3.1

ตารางข้อมูลตัวแปร

หมวดหมู่	ตัวแปร	ความถี่	คำอธิบายตัวแปร
ตัวแปรตาม	Ethereum Price	รายวัน	ราคารายวันของ Ethereum ในสกุลเงินดอลลาร์สหรัฐและสกุลบาท
ตัวแปรอิสระกลุ่ม Macroeconomic (Global)	U.S. GDP Quarterly Growth	รายไตรมาส	อัตราการเติบโต GDP สหรัฐอเมริกา รายไตรมาส
	U.S. Unemployment Rate	รายเดือน	อัตราการว่างงานของสหรัฐอเมริกา เป็นสัดส่วนของจำนวนผู้ว่างงานต่อกำลังแรงงานทั้งหมด
	U.S. CPI	รายเดือน	ดัชนีราคาผู้บริโภค สหรัฐอเมริกา เป็นตัววัดการเปลี่ยนแปลงราคาสินค้าและบริการ

ตารางที่ 3.1

ตารางข้อมูลตัวแปร (ต่อ)

หมวดหมู่	ตัวแปร	ความถี่	คำอธิบายตัวแปร
ตัวแปรอิสระกลุ่ม Macroeconomic (Global)	U.S. Core CPI	รายเดือน	ดัชนีราคาผู้บริโภคพื้นฐาน สหรัฐอเมริกา คำนวณจาก CPI โดยไม่รวมราคากลุ่มสินค้า อาหารสดและพลังงาน
	PCE Deflator	รายเดือน	ตัวชี้วัดการเปลี่ยนแปลงของ ราคาสินค้าและบริการที่ใช้ใน การบริโภคภายในสหรัฐอเมริกา โดยคำนวณจากรายจ่ายเพื่อการ บริโภคส่วนบุคคล
ตัวแปรอิสระกลุ่ม Macroeconomic (Local)	Thai GDP Quarterly Growth	รายไตรมาส	อัตราการเติบโต GDP ไทยราย ไตรมาส
	Thai Unemployment Rate	รายไตรมาส	อัตราการว่างงานของไทย เป็น สัดส่วนของจำนวนผู้ว่างงานต่อ กำลังแรงงานทั้งหมด
	Thai CPI	รายเดือน	ดัชนีราคาผู้บริโภคไทย เป็นตัว วัดการเปลี่ยนแปลงราคาสินค้า และบริการ
	Thai Core CPI	รายเดือน	ดัชนีราคาผู้บริโภคพื้นฐานไทย คำนวณจาก CPI โดยไม่รวม ราคากลุ่มสินค้าอาหารสดและ พลังงาน

ตารางที่ 3.1

ตารางข้อมูลตัวแปร (ต่อ)

หมวดหมู่	ตัวแปร	ความถี่	คำอธิบายตัวแปร
ตัวแปรอิสระกลุ่ม Financial Market (Global)	U.S. 2-Year Treasury Yield	รายวัน	ผลตอบแทนรายปีของพันธบัตร รัฐบาลสหรัฐอเมริกา อายุ 2 ปี
	U.S. 10-Year Treasury Yield	รายวัน	ผลตอบแทนรายปีของพันธบัตร รัฐบาลสหรัฐอเมริกา อายุ 10 ปี
	DXY Index	รายวัน	ดัชนีเงินดอลลาร์สหรัฐ ใช้วัด มูลค่าของเงินดอลลาร์สหรัฐเทียบกับ สกุลเงินหลักของโลกอีก 6 สกุล (EUR, JPY, GBP, CAD, SEK, CHF)
ตัวแปรอิสระกลุ่ม Financial Market (Local)	2-Year Thai Government Bond Yield	รายวัน	ผลตอบแทนรายปีของพันธบัตร รัฐบาลไทย อายุ 2 ปี
	10-Year Thai Government Bond Yield	รายวัน	ผลตอบแทนรายปีของพันธบัตร รัฐบาลไทย อายุ 10 ปี
	USD/THB Exchange Rate	รายวัน	อัตราแลกเปลี่ยนเงินตราระหว่าง ประเทศระหว่างสกุลเงินบาทกับ ดอลลาร์สหรัฐ
ตัวแปรอิสระกลุ่ม Capital Market (Global)	Dow Jones Industrial Average	รายวัน	ดัชนีดาวโจนส์ แสดงผลการ ดำเนินงานของหุ้นขนาดใหญ่ 30 ตัว

ตารางที่ 3.1

ตารางข้อมูลตัวแปร (ต่อ)

หมวดหมู่	ตัวแปร	ความถี่	คำอธิบายตัวแปร
ตัวแปรอิสระกลุ่ม Capital Market (Global)	S&P 500	รายวัน	ดัชนี S&P 500 แสดงผลการดำเนินงานของหุ้นขนาดใหญ่ 500 ตัว
	Nasdaq 100	รายวัน	ดัชนีแนสแด็ก 100 แสดงผลการดำเนินงานของหุ้นเทคโนโลยีและนวัตกรรม 100 ตัว
	CBOE Volatility Index (VIX)	รายวัน	ดัชนีที่ใช้วัดความผันผวนของตลาดหุ้น S&P 500 เป็นตัวชี้วัดความกังวลของนักลงทุน
ตัวแปรอิสระกลุ่ม Capital Market (Local)	SET Index	รายวัน	ดัชนีที่แสดงผลการดำเนินงานของหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย
	SETFIN Index	รายวัน	ดัชนีที่แสดงผลการดำเนินงานของหุ้นกลุ่มการเงินในตลาดหลักทรัพย์แห่งประเทศไทย
	SETTECH Index	รายวัน	ดัชนีที่แสดงผลการดำเนินงานของหุ้นกลุ่มเทคโนโลยีสารสนเทศและการสื่อสารในตลาดหลักทรัพย์แห่งประเทศไทย
	MAI Index	รายวัน	ดัชนีราคาหุ้นตลาดหลักทรัพย์ เอ็ม เอ ไอ

3.3 การทำความสะอาดและการแปลงข้อมูล

สำหรับข้อมูลรายไตรมาสและรายเดือน มีการปรับข้อมูลให้กลายเป็นความถี่รายวันสองรูปแบบ

1. แทนที่ข้อมูลตรงๆ เช่นข้อมูลไตรมาส 2 ในปี 2018 ใช้แทนที่ข้อมูลทุกวันทำการในเดือนเมษายนถึงเดือนมิถุนายนของปี 2018

2. แบ่งข้อมูลออกเป็นช่วงตามค่าควอไทล์ (IQR) และค่าในช่วงที่ผิดปกติ (Outlier) ซึ่งทำให้มีตัวแปรเพิ่มขึ้นมาอีก 5 ตัวแปร โดย 5 ตัวแปรนี้มีค่าเท่ากับ 0 หรือ 1

และในส่วนของคุณค่าที่เป็นค่าว่างใช้วิธีการประมาณค่าเชิงเส้นสำหรับตัวแปรที่มีค่าว่างจำนวนไม่มาก และใช้การแทนที่ข้อมูลด้วยค่าจริงจากแหล่งข้อมูลอื่นที่น่าเชื่อถือ คืออัตราผลตอบแทนตราสารหนี้รัฐบาลไทยจาก ThaiBMA.com เนื่องจากพบว่ามีข้อมูลว่างจำนวนมากเป็นเวลาหลายช่วงและเป็นจำนวนวันติดต่อกันหลายวันในช่วงนั้นๆ

3.4 การวิเคราะห์ข้อมูล

3.4.1 เทคนิคที่ใช้

การวิเคราะห์นี้จะทำการเปรียบเทียบโมเดลที่มีจุดเด่นในการทำงานกับข้อมูลแบบอนุกรมเวลาทั้งหมด 3 กลุ่มคือ โมเดลทางสถิติดั้งเดิม ARIMA (Autoregressive Integrated Moving Average) โมเดลการเรียนรู้แบบมีผู้สอน SVR (Support Vector Regression) และโมเดลในกลุ่ม Deep Learning อย่าง LSTM (Long Short-Term Memory)

1. ARIMA (Autoregressive Integrated Moving Average) และ ARIMAX (Autoregressive Integrated Moving Average with Exogenous Variables) เป็นโมเดลสถิติพื้นฐานดั้งเดิมที่เกิดขึ้นมาตั้งแต่ปี 1970 ยึดหลักการใช้ข้อมูลในอดีตและปัจจุบันทำนายข้อมูลในอนาคต จัดเป็นโมเดลทางสถิติดั้งเดิมที่ได้รับความนิยมสูงกับการใช้งานด้านการทำนายข้อมูลอนุกรมเวลา จึงเหมาะเป็นโมเดลพื้นฐานตัวแรกที่ใช้เพื่อทำการเปรียบเทียบ

2. SVR (Support Vector Regression) เป็นโมเดลที่พัฒนาต่อยอดจาก SVM (Support Vector Machine) ที่ใช้ทำนายข้อมูลตัวเลขแบบต่อเนื่อง เนื่องจากโมเดลกลุ่ม SVM ค่อนข้างมีประสิทธิภาพดีในการทำนายราคา Ethereum จากผลการสำรวจและข้อสรุปงานวิจัยของ (Khedr et al., 2021) ซึ่งสอดคล้องกับผลการศึกษาของ วิชระ รัตโรจนากุล (2566) เช่นกัน

3. LSTM (Long Short-Term Memory) เป็นโมเดลในกลุ่ม Deep Learning ที่มีจุดเด่นในการจัดการกับข้อมูลอนุกรมเวลา (Khedr et al., 2021) มองไปในทิศทางเดียวกัน โดยให้ข้อสรุปไว้ว่า LSTM เป็นโมเดลที่มีศักยภาพสูงที่สุดในการทำนายข้อมูลแบบอนุกรมเวลา

3.4.2 เกณฑ์ที่ใช้วัดประสิทธิภาพ

ใช้ค่า MAPE (Mean Absolute Percentage Error) เป็นค่าเดียวในการวัดประสิทธิภาพของทุกโมเดล เนื่องจากราคา Ethereum มีลักษณะผันผวนสูงและเติบโตอย่างก้าวกระโดด มีอัตราผลตอบแทนรายปีสูงได้ถึงหลัก 100% การวัดค่าความผิดพลาดด้วยเปอร์เซ็นต์จึงเหมาะสมกว่าการดูด้วยค่าจำนวนราคาผิดพลาด สมการของ MAPE แสดงได้ตามสมการที่ 3.1

$$\text{MAPE} = (1 / n) * \sum (|A_t - F_t| / |A_t|) \quad (3.1)$$

โดยที่ n = จำนวนข้อมูล

A_t = ข้อมูลที่เกิดขึ้นจริง

F_t = ข้อมูลที่ทำนายจากโมเดล

3.4.3 การปรับค่าตัวแปรและภาษาการเขียนโปรแกรม

ใช้ภาษา Python เป็นหลักในการประมวลผลข้อมูล มีกระบวนการปรับค่าตัวแปรที่พยายามให้ได้ผลลัพธ์ที่ดีที่สุดโดยพิจารณาจากสามปัจจัยหลักคือ ประสิทธิภาพตัวชี้วัด เวลาในการประมวลผล และความซับซ้อนของโมเดล สำหรับทุกๆโมเดลโดยใช้ประโยชน์จากฟังก์ชันการทำ Parameter Optimization เช่นการสุ่มค่าตัวแปรเป็นช่วงหรือการใช้ฟังก์ชัน Bayesian Optimization จาก Library ของภาษา Python

3.4.4 การแบ่งชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ


ใช้หลักการ k-fold cross validation ในการประเมินประสิทธิภาพของโมเดล โดยการแบ่งข้อมูลออกเป็น k ส่วนเท่าๆ กัน แล้วนำแต่ละส่วนมาใช้เป็นชุดทดสอบสลับกันไป โดยส่วนที่เหลือจะใช้เป็นชุดฝึกสอน ทำให้ได้ค่าประเมินผลที่เป็นกลางและน่าเชื่อถือมากขึ้น อย่างไรก็ตาม ข้อมูลที่ใช้ประมวลผลมีลักษณะเป็นข้อมูลอนุกรมเวลา การใช้ k-fold cross validation แบบปกติจึงไม่เหมาะสม เนื่องจากข้อมูลอนุกรมเวลามีลำดับเวลาที่สำคัญ หากแบ่งข้อมูลแบบสุ่ม อาจทำให้ข้อมูล

ในอนาคตหลุดไปอยู่ในชุดฝึกสอน ซึ่งจะทำให้โมเดลเกิดการ overfit และประเมินผลได้ไม่ถูกต้อง การฝึกโมเดลด้วยข้อมูลอนุกรมเวลาจึงต้องรักษาลำดับเวลาของข้อมูล โดยมีกระบวนการดังต่อไปนี้

- 1) กำหนดขนาดของชุดทดสอบ ผู้วิจัยกำหนดขนาดข้อมูลชุดทดสอบที่ 30
 - 2) แบ่งข้อมูลออกเป็นส่วนๆ ตามลำดับเวลา ชุดข้อมูล 30 ลำดับท้ายสุดเป็นชุดทดสอบและที่เหลือเป็นชุดฝึกสอน
 - 3) เลื่อนลำดับชุดข้อมูลทดสอบไปที่ละขั้น และทำซ้ำจนกว่าจะครบทุกส่วนของข้อมูล
- กระบวนการ k-fold cross validation สำหรับข้อมูลอนุกรมเวลาสรุปได้ดังภาพที่ 3.1

ภาพที่ 3.1

ตัวอย่างการแบ่งข้อมูล k-fold cross validation สำหรับ Time Series Data



3.5 การกำหนดค่าตัวแปร (parameter) ที่เหมาะสมในแต่ละโมเดล

3.5.1 โมเดล 1: ARIMA และ ARIMAX

มี 3 ตัวแปรสำคัญที่ต้องทำการทดลองและหาค่าที่เหมาะสมคือ p , d และ q โดยเริ่มจากค่า d (differencing order) ที่เป็นการหาผลต่างของข้อมูลเพื่อให้ข้อมูลมีความนิ่ง (stationary) หรือมีค่าเฉลี่ยและความแปรปรวนคงที่ โดยผลการทดสอบพบว่าค่า $d = 1$ เหมาะสม

กับข้อมูล ต่อมาทำการหาค่า p (autoregressive order) และ q (moving average order) จากการพลอตกราฟ autocorrelation และ partial autocorrelation ซึ่งพบว่า p และ $q = 1$ เหมาะสมกับข้อมูล ในส่วนของการเลือก feature ที่เหมาะสมเพื่อใช้ในโมเดล ARIMAX ใช้เทคนิค Recursive Feature Elimination ในการคัดเลือกตัวแปร โดยผู้วิจัยกำหนดจำนวน feature ไว้ที่ 5 สถานการณ์คือ feature ที่ดีที่สุด 1, 3, 5, 8 และ 10 อันดับแรกในการประมวลผล

3.5.2 โมเดล 2: SVR

มี 3 ตัวแปรสำคัญที่ทำการทดลองและหาค่าเหมาะสมคือประเภท kernel, c และ epsilon โดยผู้วิจัยเริ่มจากประเภท kernel ก่อนซึ่งได้ผลลัพธ์ว่า kernel แบบ RBF เหมาะสมที่สุดกับข้อมูลชุดนี้ ต่อมาจึงทดสอบหาค่า c และ epsilon ด้วยฟังก์ชัน Bayesian Optimization โดยกำหนดค่า c ในช่วง 0.1 – 30 และค่า epsilon ในช่วง 0.001 - 2 ในส่วนของการเลือก feature ที่เหมาะสม ใช้เทคนิค Select K Best ในการคัดเลือกตัวแปร โดยผู้วิจัยกำหนดจำนวน feature ไว้ที่ 5 สถานการณ์คือ feature ที่ดีที่สุด 1, 3, 5, 8 และ 10 อันดับแรกในการประมวลผล ในแต่ละสถานการณ์ top feature ที่เลือกมา ทำการค้นหาค่า c และ epsilon ที่ดีที่สุดอีกครั้งด้วยฟังก์ชัน Bayesian Optimization โดยกำหนดค่า c ในช่วง 0.1 – 30 และค่า epsilon ในช่วง 0.001 – 1

3.5.3 โมเดล 3: LSTM

มีตัวแปรที่ค่อนข้างหลากหลายและซับซ้อน ผู้วิจัยขอกำหนดและปรับเปลี่ยนค่าตัวแปรเพียง 3 ตัวเนื่องจากข้อจำกัดด้านทรัพยากรที่ใช้ในการทดลองและหาค่าที่เหมาะสมคือ epoch, batch size และ neuron โดยกำหนดรอบ epoch ที่ 10 – 50, ค่า batch size ที่ 1, 2, 4, 8, 16, 32, 64 และ จำนวน neuron ที่ 1 – 5 สำหรับ LSTM ที่ไม่มีตัวแปรอิสระและจำนวน neuron ที่ 5 – 30 สำหรับ LSTM ที่ใช้ตัวแปรอิสระในการประมวลผล ผลการทดสอบตัวแปรทั้ง 3 ค่าพบว่าโมเดลยังสามารถปรับค่าที่เหมาะสมและมีประสิทธิภาพยิ่งขึ้นได้อีก แต่ข้อจำกัดสำคัญคือกำลังการคำนวณและเวลาในการประมวลผล ซึ่งยังทำให้ดึงประสิทธิภาพสูงของโมเดล LSTM ออกมาไม่ได้มากนัก

3.6 จริยธรรมในการวิจัยและประเด็นด้านข้อมูลส่วนบุคคล

ข้อมูลทั้งหมดที่ใช้ในงานวิจัยเป็นข้อมูลด้านเศรษฐศาสตร์ ตลาดเงินและตลาดทุน ที่เผยแพร่สู่สาธารณะทั้งหมด ไม่มีข้อมูลส่วนบุคคลใดๆ ที่ใช้ประกอบการประมวลผลในงานวิจัยนี้

3.7 ข้อจำกัดของงานวิจัย

ข้อมูลในด้านเศรษฐศาสตร์มหภาคที่รวบรวมได้มักจะอยู่ในรูปความถี่รายเดือนและรายไตรมาส จึงไม่สามารถใช้งานกับการทำนายข้อมูลรายวันอย่างราคาเหรียญ Ethereum ได้โดยตรง จำเป็นต้องมีการแปลงข้อมูลเพื่อให้ข้อมูลที่มีความถี่รายเดือนและรายไตรมาสยังคงความหมายที่ดีเพื่ออธิบายการเปลี่ยนแปลงข้อมูลรายวัน อาจจำเป็นต้องใช้การตัดสินใจตามความเห็นควรจากตัวผู้วิจัยเอง เช่น การประมาณค่าในช่วง (Interpolation) หรือแทนที่ด้วยข้อมูลที่เหมาะสม นอกจากนี้แล้ว เหรียญ Ethereum มีการซื้อขายทุกวันตลอด 24 ชั่วโมงโดยไม่มีตัวกลาง จึงไม่ได้มีราคาปิดอย่างเป็นทางการ นิยามเวลาของราคาปิดจึงขึ้นอยู่กับแหล่งข้อมูลที่อาจไม่ได้ระบุไว้ชัดเจนว่าใช้เวลาไหนในการทำราคาปิด

อีกหนึ่งข้อจำกัดสำคัญคือทรัพยากรในการคำนวณและประมวลผลในการปรับค่าตัวแปรต่างๆ สำหรับโมเดล LSTM ซึ่งผู้วิจัยพบว่าใช้เวลาค่อนข้างนานในการประมวลผลแต่ละรอบ ทำให้ยังยากในการ fine tune ค่าตัวแปรที่จะดึงประสิทธิภาพของโมเดลออกมาให้ได้มากที่สุดอยู่

3.8 สรุปผลระเบียบวิธีการทำวิจัย

เทคนิคที่ใช้ในการวิเคราะห์ กลุ่มตัวแปรตาม ตัวแปรอิสระ และการวัดผลสามารถสรุปได้ดังตารางที่ 3.2 ผลการวิเคราะห์ที่ได้นี้จะสามารถตอบโจทย์ที่ว่า กลุ่มปัจจัยอิสระด้านเศรษฐศาสตร์ในระดับท้องถิ่นอย่างประเทศไทย มีประสิทธิภาพมากน้อยเพียงใดในการอธิบายการเปลี่ยนแปลงราคาเมื่อเทียบกับปัจจัยระดับโลก ที่เน้นข้อมูลเศรษฐศาสตร์ของสหรัฐอเมริกา ในการทำนายราคาของสกุลดิจิทัล Ethereum หากปัจจัยกลุ่มนี้มีศักยภาพการใช้งานที่ดีในระดับหนึ่งก็เป็นการเปิดมุมมองและวิธีการเลือกสรรตัวแปรอิสระในระดับท้องถิ่นต่อไปได้ การเลือกใช้ตัวแปรในระดับท้องถิ่นเปิดโอกาสให้นักวิเคราะห์ สถาบันการเงิน นักลงทุนรายย่อย และผู้เชี่ยวชาญที่มีความเข้าใจในโครงสร้างเศรษฐกิจประเทศไทยคาดการณ์ตัวแปรอิสระเองได้ ทั้งจากความคิดเห็นส่วนตัวหรือการคาดการณ์ของตลาด

ตารางที่ 3.2

ตารางสรุปวิธีการทำวิจัย

ลำดับ โมเดล	ประเภทโมเดล	โมเดล	ตัวแปรตาม	ตัวแปรอิสระ	ตัวชี้วัด
1.1	Classical Time Series Model	ARIMA	Ethereum Price (in USD and THB)	Date	MAPE
1.2		ARIMAX	Ethereum Price (in USD)	Date (business day) and Global Factors	MAPE
1.3		ARIMAX	Ethereum Price (in THB)	Date (business day) and Local Factors	MAPE
2.1	Supervised Model	SVR	Ethereum Price (in USD and THB)	Date	MAPE
2.2		SVR	Ethereum Price (in USD)	Date (business day) and Global Factors	MAPE
2.3		SVR	Ethereum Price (in THB)	Date (business day) and Local Factors	MAPE
3.1	Deep Learning- Based Model	LSTM	Ethereum Price (in USD and THB)	Date	MAPE
3.2		LSTM	Ethereum Price (in USD)	Date (business day) and Global Factors	MAPE
3.3		LSTM	Ethereum Price (in THB)	Date (business day) and Local Factors	MAPE

บทที่ 4

ผลการวิจัยและอภิปรายผล

4.1 ผลการวิจัย

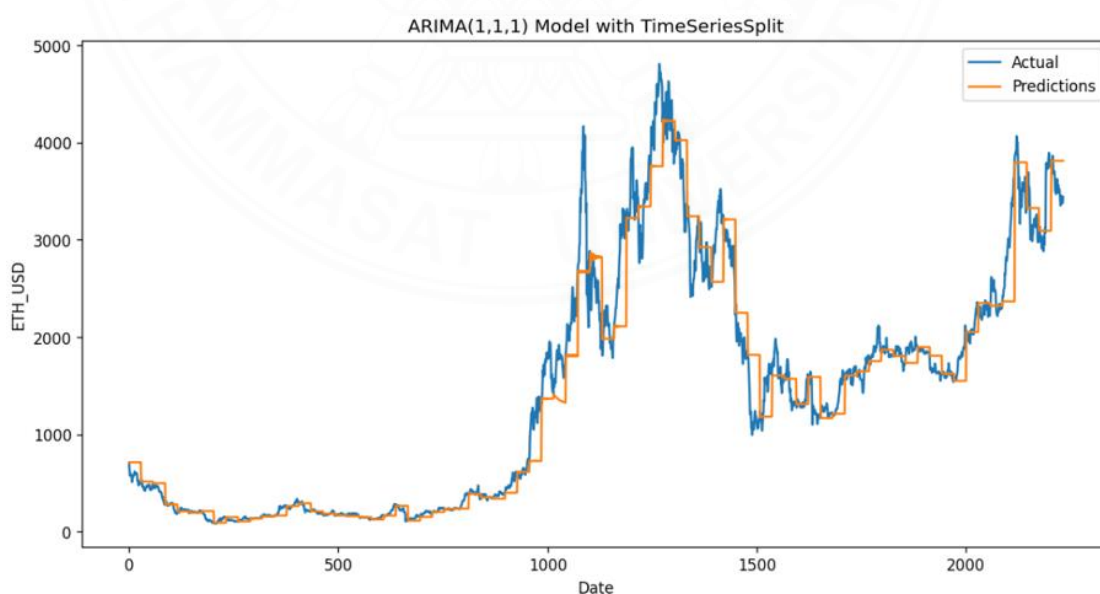
จากการนำ 3 โมเดลมาประมวลผลด้วยเทคนิคต่างๆ ทั้งกับการพยากรณ์ข้อมูล ETH โดยมีและไม่มีตัวแปรอิสระ และเปรียบเทียบผลการทดสอบระหว่างตัวแปรอิสระระดับโลกและระดับท้องถิ่น ได้ผลลัพธ์ดังนี้

4.1.1 โมเดล ARIMA และ ARIMAX

สำหรับ ARIMA (1, 1, 1) ได้ผลลัพธ์ค่า MAPE ใกล้เคียงกันทั้งสองกรณีในการพยากรณ์ค่า ETH ในสกุลเงิน USD และ THB ที่ 13.56% และ 13.52% ตามลำดับ ตามภาพที่ 4.1 และ 4.2


ภาพที่ 4.1

ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย ARIMA (1, 1, 1)



ภาพที่ 4.2

ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย ARIMA (1, 1, 1)



ในด้านของ ARIMAX (1, 1, 1) พบว่าค่า MAPE แย่ลงโดย MAPE สำหรับการพยากรณ์ ETH ในสกุล USD และ THB ได้ผลลัพธ์ที่ 17.18% และ 16.99% ตามลำดับ โดยค่า MAPE ในแต่ละสถานการณ์ตามค่าตัวแปรอิสระที่เลือกมีค่าตามตารางที่ 4.1 และตารางที่ 4.2 และผลลัพธ์การทำนายตามภาพที่ 4.3 และ 4.4

ตารางที่ 4.1

ผลลัพธ์ของโมเดล ARIMAX ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล USD

จำนวนตัวแปรอิสระ	ตัวแปรอิสระ	MAPE	เปรียบเทียบผลกับ ARIMA
1	PCE	17.31%	-3.75%
3	PCE, PCE Q1, PCE Q2	17.18%	-3.62%
5	PCE, PCE Q1, PCE Q2, PCE Q3, PCE Q4	17.27%	-3.71%
8	PCE, PCE Q1, PCE Q2, PCE Q3, PCE Q4, Unemp Q4, CPI, CoreCPI Q1	19.12%	-5.56%
10	PCE, PCE Q1, PCE Q2, PCE Q3, PCE Q4, Unemp Q4, CPI, CoreCPI Q1, CoreCPI, CoreCPI Q2	19.07%	-5.51%


ตารางที่ 4.2

ผลลัพธ์ของโมเดล ARIMAX ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล THB

จำนวนตัวแปรอิสระ	ตัวแปรอิสระ	MAPE	เปรียบเทียบผลกับ ARIMA
1	Unemp Q3	16.99%	-3.47%
3	Unemp Q3, Unemp Q2, Unemp Q4	17.17%	-3.65%
5	Unemp Q3, Unemp Q2, Unemp Q4, Unemp Q1, GB10Y	17.05%	-3.53%
8	Unemp Q3, Unemp Q2, Unemp Q4, Unemp Q1, GB10Y, GDP Q1, GDP Q3, GDP Q4	17.02%	-3.50%
10	Unemp Q3, Unemp Q2, Unemp Q4, Unemp Q1, GB10Y, GDP Q1, GDP Q3, GDP Q4, GDP Q2, CoreCPI	17.09%	-3.57%


ภาพที่ 4.3

ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย ARIMAX (1, 1, 1) และตัวแปรอิสระ 3 ตัว



ภาพที่ 4.4

ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย ARIMAX (1, 1, 1) และตัวแปรอิสระ 1 ตัว

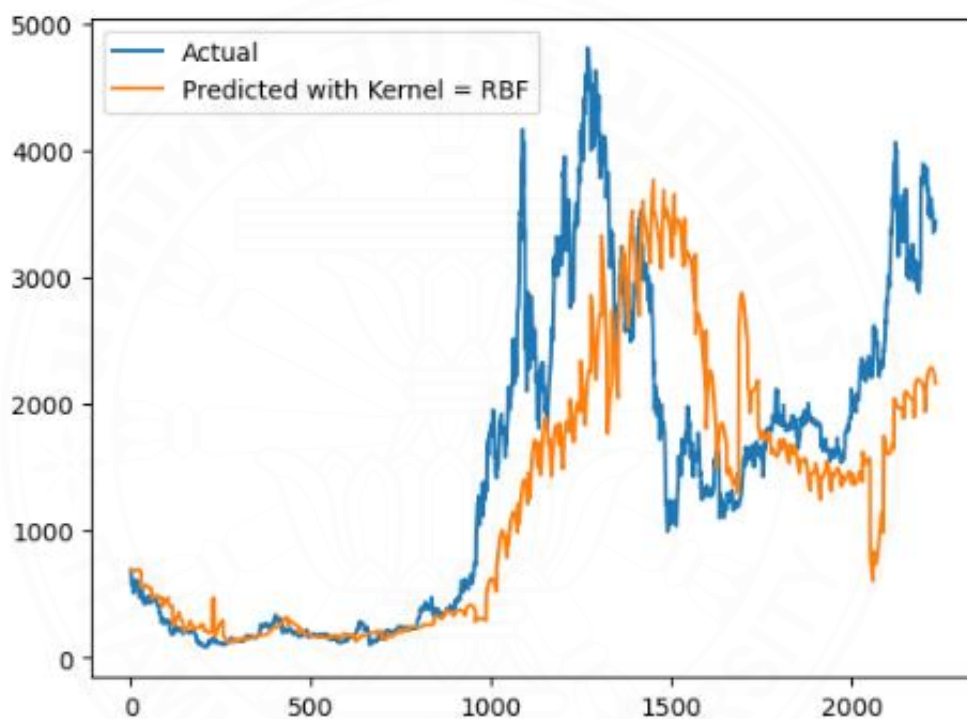


4.1.2 โมเดล SVR

สำหรับ SVR ได้ผลลัพธ์ค่า MAPE ใกล้เคียงกันทั้งสองกรณีในการพยากรณ์ค่า ETH ในสกุลเงิน USD และ THB ที่ 37.29% และ 36.44% ตามลำดับ ตามภาพที่ 4.5 และ 4.6


ภาพที่ 4.5

ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย SVR



ภาพที่ 4.6

ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย SVR



ค่าตัวแปรตามและค่าตัวแปรอื่นๆที่ใช้สร้างโมเดล SVR นั้น สามารถสรุปได้ดังตามตารางที่ 4.3 ด้านล่าง

ตารางที่ 4.3

สรุปค่าตัวแปรโมเดล SVR

ตัวแปรตาม	Kernel Type	C	Epsilon	MAPE
ETH USD	RBF	0.1093	0.04231	37.29%
ETH THB	RBF	0.1217	0.1204	36.44%

สำหรับ SVR หลังเพิ่มตัวแปรอิสระ พบว่าค่า MAPE ในการพยากรณ์ราคา ETH ทั้งสกุล USD และ THB ดีขึ้นโดย MAPE ฝั่งสกุล USD เพิ่มขึ้นมาที่ 29.15% และสกุล THB เพิ่มขึ้นเล็กน้อยเป็น 35.34% ผลลัพธ์จากการพยากรณ์ราคา ETH ในสกุล USD และ THB ด้วยโมเดล SVR

แบบมีตัวแปรอิสระสรุปได้ตามตารางที่ 4.4 และ 4.5 และผลลัพธ์การพยากรณ์เป็นไปตามภาพที่ 4.7 และ 4.8

ตารางที่ 4.4

ผลลัพธ์ของโมเดล SVR ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล USD

จำนวนตัวแปรอิสระ	ตัวแปรอิสระ	MAPE	เปรียบเทียบผลกับ SVR (ไม่มีตัวแปรอิสระ)
1	SP	45.38%	-8.09%
3	SP, DJIA, NDQ	35.98%	1.31%
5	SP, DJIA, NDQ, PCE, Year	29.15%	8.14%
8	SP, DJIA, NDQ, PCE, Year, CPI, CoreCPI, CoreCPI Q4	32.28%	5.01%
10	SP, DJIA, NDQ, PCE, Year, CPI, CoreCPI, CoreCPI Q4, Unemp Q4, PCE Q4	34.81%	2.48%

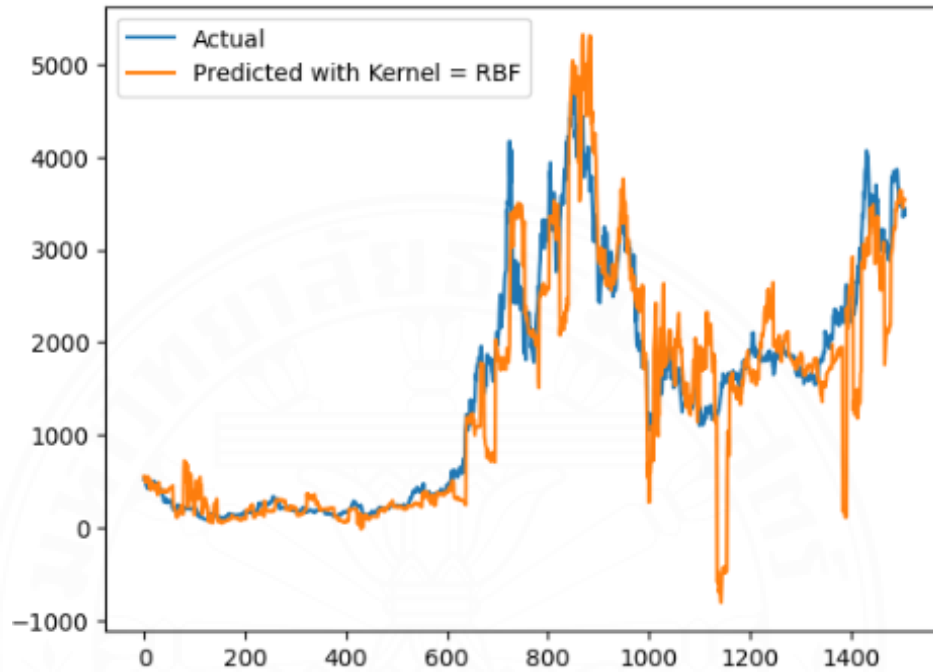
ตารางที่ 4.5

ผลลัพธ์ของโมเดล SVR ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล THB

จำนวนตัวแปรอิสระ	ตัวแปรอิสระ	MAPE	เปรียบเทียบผลกับ SVR (ไม่มีตัวแปรอิสระ)
1	SETTECH	52.70%	-16.26%
3	SETTECH, MAI, Year	35.47%	0.97%
5	SETTECH, MAI, Year, FX, Unemp Q1	35.34%	1.10%
8	SETTECH, MAI, Year, FX, Unemp Q1, SETFIN, GB10Y, GDP Outlier	35.67%	0.77%
10	SETTECH, MAI, Year, FX, Unemp Q1, SETFIN, GB10Y, GDP Outlier, Unemp Q3, CPI	37.33%	-0.89%

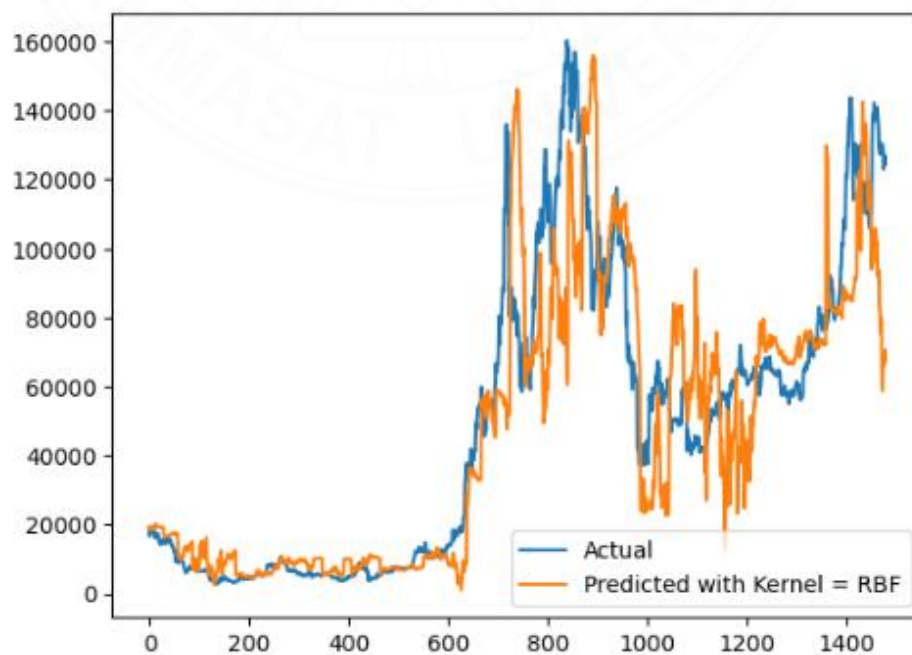
ภาพที่ 4.7

ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย SVR และตัวแปรอิสระ 5 ตัว



ภาพที่ 4.8

ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย SVR และตัวแปรอิสระ 5 ตัว



4.1.3 โมเดล LSTM

ได้ผลลัพธ์ค่า MAPE ใกล้เคียงกันเช่นเดียวกับ 2 โมเดลแรก โดยการพยากรณ์ ETH ในสกุล USD มีค่า MAPE ที่ 11.69% และในสกุล THB ที่ 12.41% ผลลัพธ์การพยากรณ์ราคา เป็นไปตามภาพที่ 4.9 และ 4.10 ค่าตัวแปรที่ใช้ในโมเดล LSTM สรุปได้ตามตารางที่ 4.6


ตารางที่ 4.6

สรุปค่าตัวแปรโมเดล LSTM

ตัวแปรตาม	Epoch	Batch Size	Neuron	MAPE
ETH USD	50	32	2	11.69%
ETH THB	50	32	2	12.41%


ภาพที่ 4.9

ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย LSTM



ภาพที่ 4.10

ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย LSTM



หลังเพิ่มตัวแปรอิสระเข้าไป ผลลัพธ์ค่า MAPE ทั้งในการพยากรณ์ ETH สกุล USD และ THB ดีขึ้น โดยฝั่งสกุล USD เพิ่มขึ้นเล็กน้อยที่ 11.08% และด้านสกุล THB เพิ่มขึ้นมาที่ 9.7% ผลลัพธ์จากการพยากรณ์ราคา ETH ในสกุล USD และ THB ด้วยโมเดล LSTM แบบมีตัวแปรอิสระสรุปได้ตามตารางที่ 4.7 และ 4.8 และผลลัพธ์การพยากรณ์เป็นไปตามภาพที่ 4.11 และ 4.12 การประมวลในแต่ละรอบอาจมีผลลัพธ์ที่ผันผวนแตกต่างกันไป เนื่องจากผู้วิจัยใช้ค่า batch size ค่อนข้างใหญ่เนื่องจากข้อจำกัดทางทรัพยากรการคำนวณ ทำให้ผลลัพธ์สุดท้ายที่ประมวลผลได้ค่าออกมาแตกต่างจากรอบทดสอบจำนวนตัวแปร

ตารางที่ 4.7

ผลลัพธ์ของโมเดล LSTM ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล USD

จำนวนตัวแปรอิสระ	ตัวแปรอิสระ	MAPE	เปรียบเทียบผลกับ LSTM (ไม่มีตัวแปรอิสระ)
1	SP	7.69%	4.00%
3	SP, DJIA, NDQ	9.83%	1.86%
5	SP, DJIA, NDQ, PCE, CoreCPI	12.80%	-1.11%
8	SP, DJIA, NDQ, PCE, CoreCPI, CPI, CoreCPI Q4, PCE Q4	22.05%	-10.36%
10	SP, DJIA, NDQ, PCE, CoreCPI, CPI, CoreCPI Q4, PCE Q4, Unemp Q4, CoreCPI Q2	23.52%	-11.83%

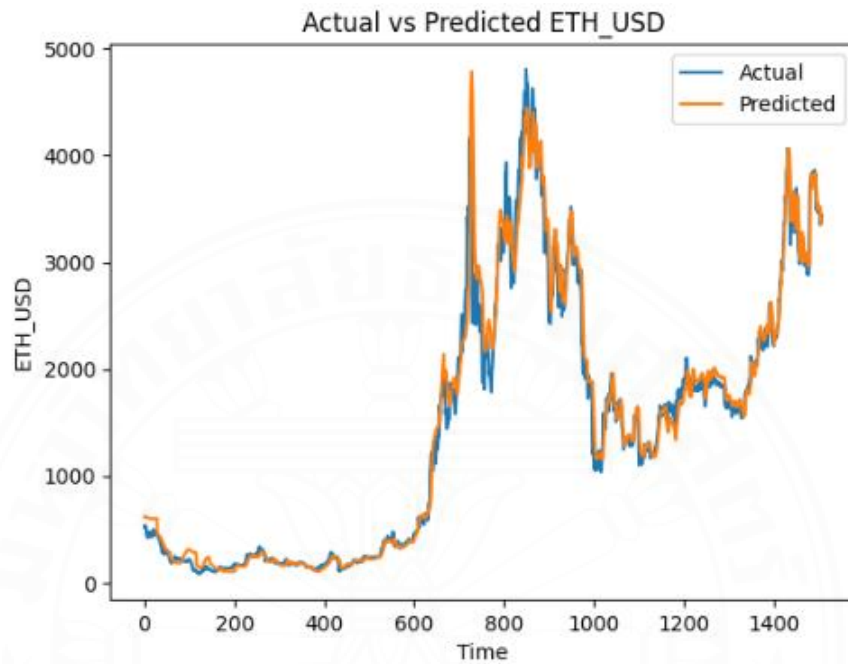
ตารางที่ 4.8

ผลลัพธ์ของโมเดล LSTM ตามจำนวนตัวแปรอิสระที่เลือกใช้กับ ETH สกุล THB

จำนวนตัวแปรอิสระ	ตัวแปรอิสระ	MAPE	เปรียบเทียบผลกับ LSTM (ไม่มีตัวแปรอิสระ)
1	SETTECH	7.36%	5.05%
3	SETTECH, FX, MAI	11.98%	0.43%
5	SETTECH, FX, MAI, SETFIN, Unemp Q1	25.26%	-12.85%
8	SETTECH, FX, MAI, SETFIN, Unemp Q1, Unemp Q3, GB10Y, GDP Outlier	24.18%	-11.77%
10	SETTECH, FX, MAI, SETFIN, Unemp Q1, Unemp Q3, GB10Y, GDP Outlier, GDP Q4, CPI	28.93%	-16.52%

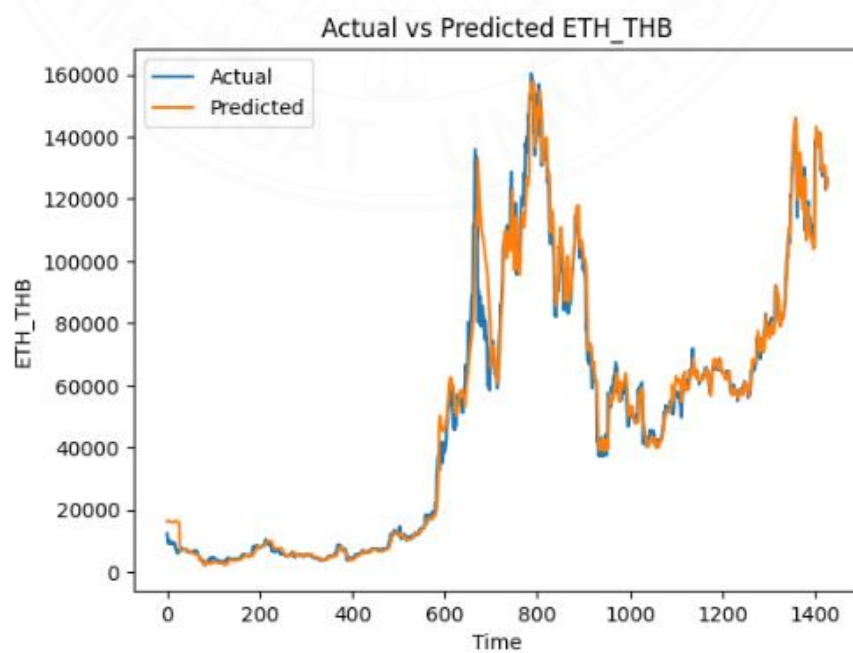
ภาพที่ 4.11

ผลลัพธ์การทำนายราคา ETH ในสกุล USD ด้วย LSTM และตัวแปรอิสระ 1 ตัว



ภาพที่ 4.12

ผลลัพธ์การทำนายราคา ETH ในสกุล THB ด้วย LSTM และตัวแปรอิสระ 1 ตัว



4.2 อภิปรายผลการวิจัย

4.2.1 ผลการวิเคราะห์ในแต่ละโมเดล

ในโมเดลที่ 1 ARIMA & ARIMAX เป็นที่น่าสังเกตว่าการเพิ่มตัวแปรอิสระเข้าไปกลับทำให้ผลการทดสอบ MAPE แย่ลง ในทางกลับกัน กรณีการประมวลผลของ ARIMA มีจำนวนข้อมูลที่มากกว่าเพราะไม่มีการตัดวันหยุดออก อาจตีความได้ว่าโมเดล ARIMAX สูญเสียประสิทธิภาพจากการเรียนรู้ pattern ของข้อมูลไป โดยผลบวกจากตัวแปรอิสระไม่สามารถชดเชยผลเสียจากจำนวนข้อมูลที่ลดลงได้ ผลจากการเพิ่มตัวแปรอิสระระดับท้องถิ่นจากประเทศไทย ให้ผลลัพธ์ที่ดีกว่าตัวแปรอิสระระดับโลกเล็กน้อย แต่ไม่มีนัยสำคัญ เนื่องจากในภาพรวม โมเดลมีประสิทธิภาพลดลงจาก ARIMA ผู้วิจัยลองทำการทดสอบเพิ่มเติมเล็กน้อยโดยการเพิ่มจำนวนข้อมูลวันหยุดกลับเข้าไปให้ชุดข้อมูลมีขนาดเท่ากับที่ใช้ในโมเดล ARIMA ผลลัพธ์ที่ได้คือค่า MAPE ดีขึ้นกลับมาที่ราว ๆ 13.5% ซึ่งก็ไม่ได้แตกต่างจาก ARIMA อย่างมีนัยสำคัญ การใช้ข้อมูลจำนวนมากขึ้นและความถี่สูงขึ้นมีแนวโน้มจะทำให้ ARIMA มีประสิทธิภาพในการพยากรณ์มากขึ้น อ้างอิงจาก (Gunawan & Febrianti, 2023) ที่ทำการศึกษาค่าการพยากรณ์ราคา Ethereum ด้วยข้อมูลรายสัปดาห์ในช่วงเดือนมกราคม 2017 ถึง ธันวาคม 2020 ซึ่งมีจำนวนข้อมูลเพียง 208 หน่วยโดยได้ผลลัพธ์ MAPE ที่ 51.94% ซึ่งแย่กว่าผลลัพธ์งานวิจัยชิ้นนี้อย่างมีนัยสำคัญ

ในโมเดลที่ 2 SVR เมื่อเทียบกับ SVR พื้นฐานที่ไม่มีตัวแปรอิสระ ผลลัพธ์ค่า MAPE ดีขึ้นค่อนข้างมากหลังจากเพิ่มกลุ่มตัวแปรอิสระระดับโลกเข้าไป อย่างไรก็ตาม การใช้กลุ่มตัวแปรอิสระระดับท้องถิ่นมีผลลัพธ์ดีขึ้นเพียงเล็กน้อย โดยทั้งสองกรณีเปรียบเทียบใช้ตัวแปรอิสระทั้งหมด 5 ตัวเท่ากัน ซึ่งสามารถสรุปได้ว่าการใช้ตัวแปรอิสระระดับโลกยังคงมีประสิทธิภาพดีกว่าตัวแปรระดับท้องถิ่นในการพยากรณ์ราคา Ethereum

โมเดลที่ 3 LSTM การปรับค่าตัวแปรทำได้ค่อนข้างยากเนื่องจากการฝึกสอนโมเดลแต่ละครั้งใช้เวลานานและต้องการกำลังการประมวลผลที่สูง จึงยังทำให้การปรับค่าตัวแปรต้องคำนึงถึงประสิทธิภาพ และความเร็วในการประมวลผลร่วมกัน ไม่ว่าจะเป็นรอบ epoch ที่ยังปรับให้สูงขึ้นได้อีกหรือค่า batch size ที่สามารถปรับให้เล็กลงได้อีกหรือจำนวน neuron ที่ยังสามารถเพิ่มขึ้นได้อีกเพื่อให้โมเดลเรียนรู้ pattern ที่ซับซ้อนมากขึ้นตามจำนวนตัวแปรอิสระที่ใส่เพิ่มเข้าไปได้เพื่อดึงประสิทธิภาพของโมเดลให้ได้มากขึ้น เมื่อเทียบกับ LSTM พื้นฐานที่ไม่มีตัวแปรอิสระ ผลลัพธ์ค่า MAPE ดีขึ้นในระดับใกล้เคียงกันและใช้ตัวแปรอิสระ 1 ตัวในทั้งสองกรณี อาจเกิดจากช่วงการสุ่มค่าตัวแปรของผู้วิจัยที่ยังไม่ใหญ่มากพอ จึงทำให้โมเดลยังเรียนรู้ pattern ของข้อมูลที่ซับซ้อนมากเกินไป ตัวแปรได้ไม่ตึงเครียด อย่างไรก็ดี โมเดลในกลุ่ม Deep Learning อย่าง LSTM มีศักยภาพสูงพอในการ

ดีงประสิทธิภาพการพยากรณ์ราคา Ethereum จากตัวแปรอิสระระดับโลกและระดับท้องถิ่นได้ดีขึ้นในระดับที่ใกล้เคียงกัน

ในภาพรวมโดยสรุป ผลลัพธ์การประเมินผลทั้ง 3 โมเดลโดยใช้ค่า MAPE เป็นเกณฑ์ประเมินประสิทธิภาพสามารถสรุปได้ตามตารางที่ 4.9 โดยในโมเดล ARIMA / ARIMAX พบว่าขนาดและความถี่ของชุดข้อมูลมีผลต่อประสิทธิภาพในการพยากรณ์ของโมเดลมากกว่าการใส่ชุดตัวแปรอิสระเข้าไป สำหรับโมเดล SVR ค่าตัวแปรอิสระระดับโลกยังคงมีประสิทธิภาพสูงกว่าตัวแปรระดับท้องถิ่นและโมเดลสุดท้าย LSTM พบว่าโมเดลมีประสิทธิภาพสูง โดยการใช้งานตัวแปรระดับท้องถิ่นสามารถช่วยในการพยากรณ์ราคา Ethereum ได้ดีใกล้เคียงกับการใช้ตัวแปรระดับโลกแม้ว่าค่า parameter ที่ใช้ในโมเดลจะยังไม่ใช่ค่าที่ดีที่สุด

ตารางที่ 4.9

สรุปการประเมินผลด้วยค่า MAPE ทั้ง 3 โมเดล

โมเดล	ตัวแปรตาม	MAPE ฐาน	MAPE หลังจากใช้ตัวแปรอิสระ	เปรียบเทียบ
ARIMA / ARIMAX	ETH in USD	13.56%	17.18%	▼ 3.62%
ARIMA / ARIMAX	ETH in THB	13.52%	16.99%	▼ 3.47%
SVR	ETH in USD	37.29%	29.15%	▲ 8.14%
SVR	ETH in THB	36.44%	35.34%	▲ 1.10%
LSTM	ETH in USD	11.69%	11.08%	▲ 0.61%
LSTM	ETH in THB	12.41%	9.70%	▲ 2.71%

4.2.2 ตัวแปรที่มีผลในการพยากรณ์ราคา Ethereum

สำหรับโมเดล 1 ARIMA / ARIMAX ที่ใช้เทคนิค Recursive Feature Elimination (RFE) มีข้อมูลตัวแปรที่เลือกตามภาพที่ 4.13 สำหรับ ETH สกุล USD และภาพที่ 4.14 สำหรับ ETH สกุล THB เมื่อพิจารณาค่า p-value ที่มีค่าเกินระดับนัยสำคัญ 0.05 ก็สามารถสรุปได้ว่าตัวแปรอิสระทุกตัวที่ถูกเลือกมาไม่มีผลหรือมีผลน้อยมากในการช่วยพยากรณ์ราคา Ethereum ซึ่งสอดคล้องกับค่า MAPE ที่ลดลงจากโมเดลพื้นฐาน ARIMA เช่นกัน

ภาพที่ 4.13

ข้อมูลโมเดล ARIMAX ในการพยากรณ์ราคา ETH สกุล USD

SARIMAX Results						
Dep. Variable:	ETH_USD	No. Observations:	1554			
Model:	ARIMA(1, 1, 1)	Log Likelihood	-9241.521			
Date:	Tue, 10 Sep 2024	AIC	18495.042			
Time:	15:25:37	BIC	18527.130			
Sample:	0	HQIC	18506.975			
	- 1554					
Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
PCE	-56.6165	67.183	-0.843	0.399	-188.292	75.059
PCE_Q1	-8.3144	90.995	-0.091	0.927	-186.661	170.032
PCE_Q2	-5.6941	87.040	-0.065	0.948	-176.289	164.901
ar.L1	-0.5259	0.081	-6.459	0.000	-0.685	-0.366
ma.L1	0.4335	0.089	4.857	0.000	0.259	0.608
sigma2	8658.0299	119.773	72.287	0.000	8423.280	8892.780
Ljung-Box (L1) (Q):		0.01	Jarque-Bera (JB):	13575.49		
Prob(Q):		0.92	Prob(JB):	0.00		
Heteroskedasticity (H):		22.65	Skew:	-0.82		
Prob(H) (two-sided):		0.00	Kurtosis:	17.39		

ภาพที่ 4.14

ข้อมูลโมเดล ARIMAX ในการพยากรณ์ราคา ETH สกุล THB

SARIMAX Results						
Dep. Variable:	ETH_THB	No. Observations:	1506			
Model:	ARIMA(1, 1, 1)	Log Likelihood	-14163.069			
Date:	Tue, 10 Sep 2024	AIC	28334.138			
Time:	16:11:24	BIC	28355.404			
Sample:	0	HQIC	28342.059			
	- 1506					
Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
Unemp_Q3	341.0999	3243.785	0.105	0.916	-6016.602	6698.802
ar.L1	-0.8425	0.049	-17.323	0.000	-0.938	-0.747
ma.L1	0.7719	0.056	13.695	0.000	0.661	0.882
sigma2	8.859e+06	1.12e+05	78.978	0.000	8.64e+06	9.08e+06
Ljung-Box (L1) (Q):		0.39	Jarque-Bera (JB):	23006.42		
Prob(Q):		0.53	Prob(JB):	0.00		
Heteroskedasticity (H):		26.25	Skew:	-0.77		
Prob(H) (two-sided):		0.00	Kurtosis:	22.09		

ในโมเดล 2 SVR มีตัวแปรอิสระที่ถูกเลือกในการใช้งาน 5 ตัวโดยวิธี Select K Best ทั้งในกรณี ETH สกุล USD และ THB โดยรายละเอียดตัวแปรสรุปได้ตามตารางที่ 4.10 ตัวแปรที่ถูกเลือกมามีความเกี่ยวข้องกับตลาดหุ้นและอัตราเงินเฟ้อ สำหรับตัวแปรระดับโลก และมีลักษณะคล้ายกันระดับหนึ่งสำหรับตัวแปรระดับท้องถิ่นคือดัชนีตลาดหุ้นย่อยกลุ่มเทคโนโลยีและตลาดหุ้นรองอย่าง MAI และอัตราแลกเปลี่ยน สำหรับกลุ่มตัวแปรอิสระระดับโลก อาจตีความได้ว่า ความร้อนแรงในตลาดหุ้นและดัชนี PCE Deflator ซึ่งเป็นดัชนีชี้วัดอัตราเงินเฟ้อที่ธนาคารกลางสหรัฐอเมริกาให้ความสำคัญและมีผลในการกำหนดทิศทางนโยบายการเงิน มีผลต่อนักลงทุนในการตัดสินใจลงทุนใน Ethereum มากกว่าปัจจัยอื่น เช่นเดียวกันกับกลุ่มตัวแปรอิสระระดับท้องถิ่นที่มีดัชนีย่อยในตลาดหุ้นหลักและตลาดหุ้น MAI รวมถึงอัตราแลกเปลี่ยนเป็นส่วนสำคัญในการกำหนดราคา Ethereum ในกรณีของตัวแปรประเทศไทยนั้นอาจตีความได้ว่านักลงทุนมอง Ethereum เป็นสินทรัพย์ความเสี่ยงสูง คล้ายกับหุ้นขนาดเล็กในตลาด MAI และมีความเชื่อมโยงกับหุ้นกลุ่มเทคโนโลยีจากดัชนี SETTECH รวมถึงค่าเงินบาทที่น่าจะแปรผันตรงกับราคา Ethereum เช่นกัน คือเมื่อค่าเงินบาทอ่อน ราคา Ethereum หน่วยเงินบาทก็ควรจะสูงขึ้นตาม

ตารางที่ 4.10

ตัวแปรอิสระที่ใช้สำหรับโมเดล SVR

ตัวแปรตาม	ตัวแปรอิสระที่ถูกเลือก
ETH in USD	PCE, DJIA, SP, NDQ, Year
ETH in THB	SETTECH, FX, MAI, Unemp Q1, Year

โมเดลที่ 3 LSTM พบว่าค่า MAPE ดีที่สุดอยู่ที่การเลือกตัวแปรเพียง 1 ตัวในการใช้งานคือดัชนี S&P 500 และดัชนี SETTECH ในการพยากรณ์ราคา Ethereum ในหน่วยสกุลเงิน USD และ THB การตีความคล้ายคลึงกับในกรณีตัวแปรของ SVR คือภาวะตลาดหุ้นมีผลอย่างมีนัยสำคัญต่อนักลงทุนในการตัดสินใจซื้อหรือขาย Ethereum ในขณะที่ตัวแปรทางด้านเศรษฐกิจมหภาคและตลาดเงินอย่างอัตราการเติบโต GDP อัตราว่างงาน หรือผลตอบแทนพันธบัตรรัฐบาลยังมีผลน้อยกว่าภาวะตลาดหุ้น อีกหนึ่งข้อสังเกตคือตัวแปรฝั่งสหรัฐอเมริกาเป็นดัชนีหุ้น S&P 500 ผิดไปจากคาดการณ์ของผู้วิจัยที่คาดว่าจะป็นดัชนี NASDAQ ที่มีความสัมพันธ์กับด้านเทคโนโลยีมากกว่า ซึ่งอาจเกิดจากความสัมพันธ์ที่สูงใกล้เคียงกันทั้งสามดัชนีหลัก โดยถ้าเลือกใช้ 3 ตัวแปรอิสระ โมเดล LSTM เลือกใช้ดัชนีหุ้นหลักทั้งสามตัวคือ DJIA, S&P 500 และ NASDAQ

บทที่ 5

สรุปผลวิจัยและข้อเสนอแนะ

5.1 สรุปผลวิจัย

Ethereum เป็นหนึ่งในกลุ่มสินทรัพย์สกุลเงินดิจิทัลยุคใหม่ เป็นทางเลือกใหม่ให้กับผู้ลงทุน โดยเฉพาะกลุ่มที่รับความเสี่ยงได้ เนื่องจากลักษณะเฉพาะตัวของสกุลเงินดิจิทัลส่วนมากยังมีลักษณะผันผวนสูง โจทย์ปัญหาที่นักวิเคราะห์และนักวิจัยยังตั้งคำถามคือปัจจัยอะไรที่กำหนดราคา Ethereum ได้บ้าง หนึ่งในปัจจัยที่ได้รับความนิยมสูงในการศึกษาคือปัจจัยทางด้านเศรษฐกิจ ตลาดเงินและตลาดหุ้น ซึ่งมีการยืนยันในหลายๆงานวิจัยว่าปัจจัยกลุ่มนี้มีผลต่อราคา Ethereum โดยข้อมูลตัวแปรอิสระที่งานวิจัยอื่นๆใช้กัน มักจะเป็นกลุ่มข้อมูลประเทศเศรษฐกิจขนาดใหญ่เช่น สหรัฐอเมริกา สหภาพยุโรป ญี่ปุ่น หรือจีน เป็นหลักในการศึกษา เท่าที่ผู้วิจัยค้นหาข้อมูล ยังไม่เคยพบงานวิจัยใดที่ใช้ข้อมูลจากประเทศเศรษฐกิจขนาดเล็ก เช่นประเทศไทย ในการเป็นตัวแปรอิสระมาอธิบายการเปลี่ยนแปลงราคาเหรียญ Ethereum

แนวความคิดการนำข้อมูลจากประเทศเศรษฐกิจขนาดเล็กอย่างประเทศไทยมาใช้ในการศึกษาเกิดจากกระแสโลกาภิวัตน์ (Globalization) ที่ทำให้เศรษฐกิจของของหลายๆ ประเทศมีความเชื่อมโยงกันทั้งในทางตรงและทางอ้อม เช่นการค้าขายและการลงทุนระหว่างประเทศ ในเหตุการณ์วิกฤตใหญ่ระดับโลกหลายครั้ง จะเห็นได้ว่าผลกระทบมักจะไม่จบแค่ในประเทศ แต่มีผลกระทบลุกลามเป็นวงกว้าง อย่างประเทศไทยเองก็มีการพึ่งพาภาคต่างประเทศเยอะ ทั้งการลงทุนและภาคการท่องเที่ยว หากความเชื่อมโยงนี้มีมากพอ การพยากรณ์ราคา Ethereum ที่เป็นสินทรัพย์ระดับโลก และมีการกำหนดราคาจากนักลงทุนทุกประเทศทั่วโลก ก็อาจจะไม่จำเป็นต้องใช้ข้อมูลจากประเทศเศรษฐกิจขนาดใหญ่เสมอไปในการอธิบายการเปลี่ยนแปลงราคา

ผลสรุปการวิจัยนั้น พบว่าโมเดลในกลุ่ม Deep Learning อย่าง LSTM (Long Short-Term Memory) มีศักยภาพสูงพอที่จะสามารถใช้ข้อมูลจากประเทศเศรษฐกิจขนาดเล็กอย่างประเทศไทยในการอธิบายการเปลี่ยนแปลงราคาของเหรียญ Ethereum ได้ทัดเทียมกับการใช้ข้อมูลประเทศเศรษฐกิจขนาดใหญ่อย่างสหรัฐอเมริกา โดยปัจจัยลำดับต้นๆ ที่มีผลกับราคา Ethereum คือภาวะตลาดหุ้น และปัจจัยรองลงมาสำหรับข้อมูลฝั่งสหรัฐอเมริกาเป็นกลุ่มดัชนีวัดค่าเงินเฟ้อ ที่เป็นตัวกำหนดทิศทางนโยบายการเงินของธนาคารกลางสหรัฐ ในส่วนปัจจัยรองของประเทศไทยคืออัตราแลกเปลี่ยนเงินตราต่างประเทศ

5.2 ปัญหาและข้อเสนอแนะ

ปัญหาด้านทรัพยากรการคำนวณและประมวลผลเป็นอุปสรรคสำคัญ โดยเฉพาะกับกระบวนการปรับค่า หาค่าตัวแปรที่เหมาะสมกับโมเดล LSTM ซึ่งใช้กำลังการประมวลผลสูงและใช้เวลานาน ช่วงในการสุ่มค่าตัวแปรเกิดจากการตัดสินใจของผู้วิจัย ซึ่งอาจแตกต่างไปจากค่าที่เหมาะสมที่สุดได้ไม่มากนัก งานวิจัยชิ้นนี้จึงยังดึงประสิทธิภาพของ LSTM ออกมาได้ไม่มากนัก

ผู้วิจัยมีข้อเสนอแนะแบ่งเป็น 3 ข้อจากผลการวิจัยทั้ง 3 โมเดล

1. ในโมเดล ARIMA นั้นพบว่าผลลัพธ์ที่ค่อนข้างดี และไม่จำเป็นต้องมีตัวแปรอิสระเพิ่มเติม แต่ข้อมูลจำเป็นต้องมีมาก และความถี่สูง หากมีงานวิจัยที่ต้องการศึกษาคาดการณ์ราคา Ethereum เพิ่มเติม สามารถพิจารณาหาแหล่งข้อมูลที่มีความถี่มากกว่ารายวัน และเป็นช่วงระยะเวลาที่ยาวขึ้นอีกได้ อาจได้ผลลัพธ์ที่ดียิ่งขึ้นโดยไม่ต้องใช้ความพยายามปรับค่าตัวแปรมาก

2. สำหรับโมเดล LSTM พบว่ามีผลลัพธ์ค่อนข้างดี แต่จำเป็นต้องมีทรัพยากรการคำนวณที่สูงเพราะการปรับและทดลองหาค่าตัวแปรใช้กำลังการประมวลผลและเวลานานในการฝึกโมเดล ผู้วิจัยเชื่อว่าประสิทธิภาพของโมเดลยังทำได้มากกว่านี้ จากการปรับค่าตัวแปรให้มีช่วงที่ใหญ่ขึ้นเพื่อทดสอบค่าตัวแปรที่มากกว่านี้กับผลลัพธ์

3. จากตัวแปรอิสระที่มีผลมากที่สุดในการอธิบายราคาของ Ethereum คือด้านดัชนีตลาดหุ้น คือ S&P 500 จากฝั่งสหรัฐอเมริกาและ SETTECH จากฝั่งไทย งานวิจัยที่สามารถต่อยอดได้คือเจาะรายละเอียดลงไปที่หุ้นรายตัวที่เป็นสมาชิกของทั้งสองดัชนีนี้ โดยเฉพาะหุ้นที่มีมูลค่าตลาดใหญ่และมีน้ำหนักต่อดัชนีมากๆ เช่นหุ้นบริษัทเทคโนโลยีใหญ่ๆของสหรัฐอเมริกา หรือหุ้นที่ทำธุรกิจเกี่ยวกับชิ้นส่วนอิเล็กทรอนิกส์ของไทย

รายการอ้างอิง

หนังสือและบทความในหนังสือ

- Aharon, D. Y., Ali, S., & Naved, M. (2023). Too big to fail: The aftermath of Silicon Valley Bank (SVB) collapse and its impact on financial markets. *Research in International Business and Finance*, 66, 102036.
- Alahmari, S. A. (2019). Using Machine Learning ARIMA to Predict the Price of Cryptocurrencies. *The ISC International Journal of Information Security*, 11(3), 139-144. doi: 10.22042/isecure.2019.11.0.18
- Ariyo, A. A., Adewumi, A. O., & Ayo, C. K. (2014, March). Stock price prediction using the ARIMA model. In *2014 UKSim-AMSS 16th international conference on computer modelling and simulation* (pp. 106-112). IEEE.
- Awad, M., Khanna, R., Awad, M., & Khanna, R. (2015). Support vector regression. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 67-80.
- Chaipravat, O. (1975). *A Macroeconometric Model of Thailand, with Special Emphasis on Mechanism of Domestic Price Determination for a Small, Open Economy*. Department of Economic Research, Bank of Thailand.
- Ciaian, P., Rajcaniova, M., & Kancs, D. A. (2016). The economics of BitCoin price formation. *Applied economics*, 48(19), 1799-1815.
- Greenwood-Nimmo, M., Nguyen, V. H., & Shin, Y. (2021). Measuring the connectedness of the global economy. *International Journal of Forecasting*, 37(2), 899-919.
- Gunawan, D. & Febrianti, I. (2023). Ethereum Value Forecasting Model using Autoregressive Integrated Moving Average (ARIMA). *International Journal of Advances in Social Sciences and Humanities*, 2(1), 29-35.
- Khedr, A. M., Arif, I., El - Bannany, M., Alhashmi, S. M., & Sreedharan, M. (2021). Cryptocurrency price prediction using traditional statistical and machine - learning techniques: A survey. *Intelligent Systems in Accounting, Finance and Management*, 28(1), 3-34.

- Kim, H. M., Bock, G. W., & Lee, G. (2021). Predicting Ethereum prices with machine learning based on Blockchain information. *Expert Systems with Applications*, 184, 115480.
- Kohpaiboon, A., & Jongwanich, J. (2021). Economic consequences of globalisation: case study of Thailand. *this volume*, 164-191.
- Loyola-Gonzalez, O. (2019). Black-box vs. white-box: Understanding their advantages and weaknesses from a practical point of view. *IEEE access*, 7, 154096-154113.
- Peng, S., Prentice, C., Shams, S., & Sarker, T. (2023). A systematic literature review on the determinants of cryptocurrency pricing. *China Accounting and Finance Review*, (ahead-of-print).
- Sakurai, A., & Shudo, K. (2023, January). Impact of the hash rate on the theoretical fork rate of blockchain. In *2023 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 1-4). IEEE.
- Singla, A., Singla, M., & Gupta, M. (2023). Unpacking the Impact of Bitcoin Halving on the Crypto Market: Benefits and Limitations. *Scientific Journal of Metaverse and Blockchain Technologies*, 1(1), 43-50.
- Steger, M. B., Benedikter, R., Pechlaner, H., & Kofler, I. (2023). *Globalization*. University of California Press.
- Wu, F. (2020). Stock market integration in East and Southeast Asia: The role of global factors. *International Review of Financial Analysis*, 67, 101416.

บทความวารสาร

ธปท. บนเวทีโลก ในสายตา เศรษฐพุฒิ สุทธิวาหนฤพุฒิ. (13 กุมภาพันธ์ 2567). พระสยาม BOT Magazine, 67(1). สืบค้นจาก https://www.bot.or.th/th/research-and-publications/articles-and-publications/bot-magazine/Phrasiam-66-4/governortalk_intertheme.html

วิทยานิพนธ์

วัชระ รัตโรจนากุล (2566). การศึกษาปัจจัยที่มีผลต่อการเปลี่ยนแปลงราคาของสกุลเงินดิจิทัลอีเธอเรียมโดยใช้เทคนิคการเรียนรู้ของเครื่อง. มหาวิทยาลัยธรรมศาสตร์.

สื่ออิเล็กทรอนิกส์

Pitchaporn. (2023). Binance ประกาศเผาเหรียญ BNB ประจำไตรมาสครั้งที่ 25 จำนวน 2.1 ล้านโทเคน มูลค่ากว่า 1.6 หมื่นล้านบาท. สืบค้นจาก

<https://siamblockchain.com/2023/10/16/binance-announced-the-25th-quarterly-bnb-burn-of-2-1-million-tokens-worth-over-16-billion-baht/>

Bitkub Exchange. (2021, February 1). รู้จักกับ Ethereum สกุลเงินดิจิทัลอันดับ 2 ของโลก [Web blog message]. Retrieved from

<https://www.bitkub.com/th/blog/ethereum-2nd-largest-cffb5e9df430>

Archit, S. (2023, January 18). Introduction to Long Short-Term Memory (LSTM) [Web blog message]. Retrieved from <https://medium.com/analytics-vidhya/introduction-to-long-short-term-memory-lstm-a8052cd0d4cd>

ประวัติผู้เขียน

ชื่อ

อติศิษฐ์ วัฒนาสุทธิวงศ์

วุฒิการศึกษา

ปีการศึกษา 2557: บริหารธุรกิจบัณฑิต

มหาวิทยาลัยธรรมศาสตร์

