

การศึกษาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์ราคาของเงินดิจิทัล

ทิว ภูระย้า

TNII

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

บัณฑิตศึกษา สาขาเทคโนโลยีสารสนเทศ

สถาบันเทคโนโลยีไทย – ญี่ปุ่น

ปีการศึกษา 2566

THE STUDY OF MACHINE LEARNING MODELS FOR FORECAST PRICE OF
CRYPTOCURRENCY

Tiew Phuraya

TNII

A Term Paper Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science Program in Information Technology

Graduate Studies

Thai-Nichi Institute of Technology

Academic Year 2023

หัวข้อสารนิพนธ์

การศึกษาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์

ราคาของเงินดิจิทัล

โดย

ทิว ภูระย้า

สาขาวิชา

เทคโนโลยีสารสนเทศ

อาจารย์ที่ปรึกษาสารนิพนธ์

ว่าที่ร้อยตรี ดร.พิชิตชัย คำอินทร์

บัณฑิตศึกษา สถาบันเทคโนโลยีไทย-ญี่ปุ่น อนุมัติให้บัณฑิตวิทยาลัยเป็น ส่วนหนึ่งของ
การศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

.....รองอธิการบดีฝ่ายวิชาการ

(รองศาสตราจารย์ ดร.วรากร ศรีเชวงทรัพย์)

วันที่.....เดือน.....พ.ศ.....

คณะกรรมการสอบสารนิพนธ์

.....ประธานกรรมการ

(ดร.อภิษฎา นิมคุ้มภัย)

.....กรรมการ

(ดร.ศรายุทธ นนท์ศิริ)

.....อาจารย์ที่ปรึกษาสารนิพนธ์

(ว่าที่ร้อยตรี ดร.พิชิตชัย คำอินทร์)

ทิว ภูระย้า : การศึกษาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์ราคาของเงินดิจิทัล.
 อาจารย์ที่ปรึกษา : ว่าที่ร้อยตรี ดร.พิชิตชัย คำอินทร์, 46 หน้า.

ในปัจจุบันมีการลงทุนได้หลายทางเลือกมากขึ้น ที่ได้รับความสนใจเป็นอย่างมาก คือ การลงทุนในเงินดิจิทัล (Cryptocurrency) และมีการจัดตั้งกองทุน Bitcoin ETF ซึ่งทำให้มีเงินลงทุนไหลเข้ามาเป็นจำนวนมากในอนาคต ทำให้ความผันผวนของราคาเงินดิจิทัลเกิดขึ้นได้มาก ซึ่งการพยากรณ์ราคาเงินดิจิทัลเป็นเรื่องที่ท้าทายมากเนื่องจาก แนวโน้มของราคาที่สูงขึ้น ลงของเงินดิจิทัลนั้นเกิดจากข้อมูลที่มีความซับซ้อนมาก จำนวนความต้องการซื้อ ต้องการขาย และเป็นตลาดออนไลน์ที่มีความผันผวนอยู่ตลอดเวลา ดังนั้นจึงมีงานวิจัยจำนวนมากที่เสนอการใช้การเรียนรู้ของเครื่องเพื่อทำนายราคาเงินดิจิทัล โดยงานวิจัยนี้ศึกษาชุดข้อมูลของเงินดิจิทัลที่มีมูลค่าการเทรดที่สูงที่สุด 3 อันดับได้แก่ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) หลังจากนั้นใช้แบบจำลอง ในการพยากรณ์ราคาเงินดิจิทัลคือ โครงข่ายระบบประสาทเทียมแบบย้อนกลับ (Recurrent Neural Network : RNN) โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN) โครงข่ายประสาทเทียมแบบประตูสัญญาณวนกลับ (Gated Recurrent Units : GRU) หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM) และโครงข่ายประสาทเทียมผสมผสาน (Hybrid Long Short-Term Memory Convolutional Neural Network : LSTM-CNN) และเปรียบเทียบประสิทธิภาพในการพยากรณ์ จากการศึกษาพบว่า ชุดข้อมูลของ Bitcoin (BTC) แบบจำลอง LSTM มีประสิทธิภาพดีที่สุด ส่วนชุดข้อมูลของ Ethereum (ETH) แบบจำลอง LSTM-CNN มีประสิทธิภาพดีที่สุด ส่วนชุดข้อมูลของ Binance coin (BNB) แบบจำลอง LSTM-CNN มีประสิทธิภาพดีที่สุด

บัณฑิตศึกษา

สาขาวิชา เทคโนโลยีสารสนเทศ

ปีการศึกษา 2566

ลายมือชื่อนักศึกษา

ลายมือชื่ออาจารย์ที่ปรึกษา

TIEW PHURAYA : THE STUDY OF MACHINE LEARNING MODELS FOR FORECAST PRICE OF CRYPTOCURRENCY. ADVISOR : ACTING.SUB.L.T. DR. PICHITCHAI KAMIN, 46 PP.

In the current investment there are numerous options available and one that has garnered significant attention is investing in cryptocurrency. The establishment of the Bitcoin Exchange Traded Fund (ETF) leading to a substantial influx of investments in future. This has resulted in heightened volatility in the prices of digital currencies. Forecasting digital currency prices is particularly challenging due to the upward and downward trends in cryptocurrency prices are influenced by highly complex data and the constantly fluctuating online market. Consequently, studies have been proposed to the use of machine learning for predicting cryptocurrency price. Research in this study data from the top three cryptocurrencies by market capitalization Bitcoin (BTC), Ethereum (ETH), and Binance Coin (BNB) after that use the model. To forecast the price of digital currency is Recurrent Neural Network (RNN), Convolutional Neural Network (CNN), Gated Recurrent Units (GRU), Long Short-Term Memory (LSTM), Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN) and compare the efficiency of the predictions. The findings of the study indicate that, for the Bitcoin dataset, the LSTM model demonstrated the highest predictive performance. For the Ethereum dataset, the GRU model exhibited the best performance, while for the Binance Coin dataset, the LSTM-CNN hybrid model performed most effective.

Graduate Studies

Field of Study Information Technology

Academic Year 2023

Student's Signature.....

Advisor's Signature.....

กิตติกรรมประกาศ

การทำวิทยานิพนธ์นี้สำเร็จลงด้วยดีนั้น ผู้วิจัยขอขอบคุณ ว่าที่ร้อยตรี ดร.พิชิตชัย คำอินทร์และ ดร.ศรายุทธ นนท์ศิริ ที่ได้สละเวลาในการให้คำแนะนำ การสนับสนุน รวมถึงตรวจสอบข้อบกพร่องทุกขั้นตอนของการทำสารนิพนธ์ รวมทั้งขอขอบคุณคณาจารย์คณะและเจ้าหน้าที่บัณฑิตศึกษาของสถาบันเทคโนโลยีไทย-ญี่ปุ่น ที่อำนวยความสะดวกต่าง ๆ ในการจัดทำและตรวจสอบเล่มสารนิพนธ์ฉบับนี้ให้สมบูรณ์และประสบความสำเร็จไปได้ด้วยดี

ทั้งนี้ผู้วิจัยขอขอบคุณคณะกรรมการสอบทุกท่าน ได้แก่ ดร.อภิษฎา นิยมคุ้มภัย และ ดร.ศรายุทธ นนท์ศิริ ที่ได้กรุณาให้ข้อเสนอแนะที่เป็น ประโยชน์และช่วยตรวจสอบข้อบกพร่องของสารนิพนธ์ฉบับนี้ จนสามารถทำให้สารนิพนธ์ฉบับนี้ เสร็จสิ้นสมบูรณ์ตามขอบเขตที่กำหนดไว้

นอกจากนี้ทางผู้วิจัยขอขอบคุณแรงสนับสนุนจากครอบครัว อาจารย์ทุกท่านที่ได้ให้ความรู้ และให้คำปรึกษาตลอดระยะเวลาการศึกษา

ผู้วิจัยหวังเป็นอย่างยิ่งว่า สารนิพนธ์ฉบับนี้จะเกิดประโยชน์ต่อผู้ที่มีความสนใจ สามารถนำไปต่อยอดและเป็นแนวทางในการลงทุนสำหรับตลาดเงินดิจิทัลต่อไปได้

ทิว ภูระย้า

TNI

THAI - NICHI INSTITUTE OF TECHNOLOGY

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ฉ
บทที่	
1 บทนำ.....	1
1.1 ความเป็นมา และปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตของการศึกษา.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.5 นิยามศัพท์เฉพาะ.....	3
2 แนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง	5
2.1 ความรู้เกี่ยวกับเงินดิจิทัล	5
2.2 การเรียนรู้ของเครื่อง.....	5
2.3 แบบจำลองการเรียนรู้ของเครื่อง.....	6
2.4 การปรับค่าด้วยวิธี Normalization.....	11
2.5 การแบ่งข้อมูลรูปแบบ Sliding Window.....	12
2.6 การแบ่งข้อมูลเพื่อประเมินประสิทธิภาพของตัวแบบจำลอง.....	12
2.7 การประเมินค่าความผิดพลาดจากการพยากรณ์.....	13
2.8 งานวิจัยที่เกี่ยวข้อง	15
3 วิธีการดำเนินงาน	17
3.1 ขั้นที่ 1 การวิเคราะห์ข้อมูลปัญหา รวมทั้งศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง	18

สารบัญ(ต่อ)

บทที่		หน้า
3	3.2 ขั้นที่ 2 รวบรวมข้อมูลราคาของเงินดิจิทัล	20
	3.3 ขั้นที่ 3 ปรับค่าด้วยวิธี Normalization	20
	3.4 ขั้นที่ 4 กำหนดชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ	20
	3.5 ขั้นที่ 5 การแบ่งข้อมูลด้วยวิธี Sliding Window.....	20
	3.6 ขั้นที่ 6 สร้างแบบจำลอง.....	20
	3.7 ขั้นที่ 7 เปรียบเทียบและประเมินประสิทธิภาพของแบบจำลอง	22
4	ผลการวิจัย.....	22
	4.1 ชุดข้อมูลราคาของ Bitcoin (BTC)	23
	4.2 ชุดข้อมูลราคาของ Ethereum (ETH).....	28
	4.3 ชุดข้อมูลราคาของ Binance coin (BNB).....	34
	4.4 ประเมินประสิทธิภาพของแบบจำลองทั้งหมด	39
5	บทสรุป อภิปราย และข้อเสนอแนะ	41
	5.1 สรุปผลการวิจัย.....	41
	5.2 อภิปรายผลวิจัย	42
	5.3 ปัญหาและอุปสรรคในการทำงานวิจัย	43
	5.4 ข้อเสนอแนะงานวิจัย	43
	บรรณานุกรม.....	44
	ประวัติผู้เขียนสารนิพนธ์.....	46

สารบัญตาราง

ตาราง	หน้า
3.1 ขั้นตอนการวิจัย	17
3.2 ค่าพารามิเตอร์สำหรับแบบจำลอง	21
4.1 แสดงประสิทธิภาพของแบบจำลองของชุดข้อมูล Bitcoin (BTC)	23
4.2 แสดงประสิทธิภาพของแบบจำลองของชุดข้อมูล Ethereum (ETH).....	29
4.3 แสดงประสิทธิภาพของแบบจำลองของชุดข้อมูล Binance coin (BNB).....	34
4.4 แสดงประสิทธิภาพของแบบจำลองทั้งหมด	40



สารบัญรูป

รูป	หน้า
2.1 สถาปัตยกรรมแบบย่อของ RNN	6
2.2 สถาปัตยกรรมแบบแสดงชั้นลำดับของ RNN	6
2.3 ตัวอย่างการคอนโวลูชันจากข้อมูลนำเข้าขนาด $7 \times 7 \times 1$ และ Filter ขนาด $3 \times 3 \times 1$	7
2.4 สถาปัตยกรรมของ GRU	9
2.5 สถาปัตยกรรมของ LSTM	9
2.6 เกิดที่1	9
2.7 เกิดที่2และ3	9
2.8 เกิดที่4	9
2.9 แผนภาพโครงข่ายประสาทเทียม CNN-LSTM	11
2.10 แผนภาพโครงข่ายประสาทเทียม LSTM-CNN	11
2.11 การแบ่งข้อมูลรูปแบบ Sliding Window	12
3.1 กรอบแนวความคิด	17
3.2 ขั้นตอนการวิเคราะห์ข้อมูลปัญหาของงานวิจัย	18
3.3 กราฟแสดงราคาของ BTC	19
3.4 กราฟแสดงราคาของ ETH	19
3.5 กราฟแสดงราคาของ BNB	20
4.1 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง RNN ของ BTC	24
4.2 แสดงประสิทธิภาพของแบบจำลอง RNN ของ BTC	24
4.3 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง CNN ของ BTC	25
4.4 แสดงประสิทธิภาพของแบบจำลอง CNN ของ BTC	25
4.5 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง GRU ของ BTC	26
4.6 แสดงประสิทธิภาพของแบบจำลอง GRU ของ BTC	26
4.7 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM ของ BTC	27
4.8 แสดงประสิทธิภาพของแบบจำลอง LSTM ของ BTC	27
4.9 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM-CNN ของ BTC	28

สารบัญรูป(ต่อ)

รูป	หน้า
4.10 แสดงประสิทธิภาพของแบบจำลอง LSTM-CNN ของ BTC.....	28
4.11 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง RNN ของ ETH.....	29
4.12 แสดงประสิทธิภาพของแบบจำลอง RNN ของ ETH.....	30
4.13 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง CNN ของ ETH.....	30
4.14 แสดงประสิทธิภาพของแบบจำลอง CNN ของ ETH.....	31
4.15 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง GRU ของ ETH.....	31
4.16 แสดงประสิทธิภาพของแบบจำลอง GRU ของ ETH.....	32
4.17 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM ของ ETH.....	32
4.18 แสดงประสิทธิภาพของแบบจำลอง LSTM ของ ETH.....	33
4.19 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM-CNN ของ ETH.....	33
4.20 แสดงประสิทธิภาพของแบบจำลอง LSTM-CNN ของ ETH.....	34
4.21 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง RNN ของ BNB.....	35
4.22 แสดงประสิทธิภาพของแบบจำลอง RNN ของ BNB.....	35
4.23 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง CNN ของ BNB.....	36
4.24 แสดงประสิทธิภาพของแบบจำลอง RNN ของ BNB.....	36
4.25 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง GRU ของ BNB.....	37
4.26 แสดงประสิทธิภาพของแบบจำลอง GRU ของ BNB.....	37
4.27 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM ของ BNB.....	38
4.28 แสดงประสิทธิภาพของแบบจำลอง LSTM ของ BNB.....	38
4.29 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM-CNN ของ BNB	39
4.30 แสดงประสิทธิภาพของแบบจำลอง LSTM-CNN ของ BNB	39

บทที่ 1

บทนำ

1.1 ความเป็นมา และปัญหา

ปัจจุบันการใช้อินเทอร์เน็ตหรือการหาข้อมูลต่าง ๆ สามารถเข้าถึงได้ง่ายรวดเร็วจึงทำให้เกิดเทคโนโลยีใหม่ ๆ ที่ทำให้การติดต่อสื่อสาร หรือเชื่อมต่อกับบุคคลทั่วโลกได้อย่างไร้พรมแดนโดยสังคมออนไลน์ปัจจุบันได้มีการตระหนักถึงความสำคัญของการกระจายศูนย์ (Decentralized) โดยการกำจัดตัวกลางออกเพื่อสร้างความปลอดภัย โปร่งใส มีความน่าเชื่อถือ มั่นคงและให้ความสำคัญกับการเก็บข้อมูล อีกทั้งยังมีค่าทำธุรกรรมที่ต่ำ เทคโนโลยีนี้เรียกว่า "บล็อกเชน" (Blockchain) ในหลาย ๆ ประเทศมีการผลักดันนวัตกรรมใหม่ ๆ โดยใช้เทคโนโลยีบล็อกเชนเข้ามาช่วยเหลือในการสร้างนวัตกรรม โดยเทคโนโลยีบล็อกเชนนับเป็นเทคโนโลยีที่อยู่เบื้องหลังของเงินดิจิทัล (Cryptocurrency) เงินดิจิทัลถูกสร้างมาเพื่อใช้แลกเปลี่ยนระหว่างกันแทนเงินสด เป็นสินทรัพย์ดิจิทัลประเภทหนึ่งที่มีการเข้ารหัส มีราคากลางในการซื้อขายแปรผันตามกลไกตลาด เงินดิจิทัลยังไม่ถือเป็นเงินตราตามกฎหมายเนื่องจากไม่มีรัฐบาลใดเข้ามาควบคุมจัดการ

เนื่องจากในปัจจุบันหลาย ๆ ประเทศเริ่มยอมรับเงินดิจิทัลกันมากขึ้น มีการซื้อขายกันอย่างแพร่หลายมากขึ้น และมีการจัดตั้งกองทุน Bitcoin ETF ซึ่งทำให้มีเงินลงทุนไหลเข้ามาเป็นจำนวนมากในอนาคต ทำให้ผู้คนหันมาลงทุนเพิ่มขึ้นกว่าแต่ก่อนจึงทำให้มูลค่าการตลาด (Market Capitalization) เติบโตมากขึ้น พบว่าเงินดิจิทัลที่มีมูลค่าการตลาดที่สูงสุด 3 อันดับคือ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) ตามลำดับ โดยนักลงทุนส่วนใหญ่ยังเน้นการเก็งกำไร เป็นการเทรด (trade) เพื่อเก็บกำไรส่วนต่างจากราคา จึงทำให้เงินดิจิทัลมีความผันผวนของราคาเป็นอย่างมาก งานวิจัยนี้จึงมุ่งเน้นไปที่การพยากรณ์ราคาของเงินดิจิทัลที่มีมูลค่าการตลาดที่สูงสุด 3 อันดับด้วยอัลกอริทึมการเรียนรู้ของเครื่องในรูปแบบต่าง ๆ เพื่อศึกษาแบบจำลองที่มีความสามารถในการพยากรณ์ราคาของเงินดิจิทัลโดยอาศัยข้อมูลเว็บไซต์ <https://finance.yahoo.com> ดังนั้นผู้วิจัยจึงสนใจศึกษาการพยากรณ์ด้วยการเรียนรู้ของเครื่องซึ่งอาจใช้เป็นแนวทางในการลดความเสี่ยงด้านราคาสำหรับนักลงทุนในเงินดิจิทัล

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อสร้างแบบจำลองพยากรณ์ราคาของของเงินดิจิทัลที่มีมูลค่าการตลาดที่สูงที่สุด 3 อันดับ คือ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) ตามลำดับโดยใช้เทคนิค

1.2.1) Recurrent Neural Network (RNN)

1.2.2) Convolutional Neural Network (CNN)

1.2.3) Gated Recurrent Units (GRU)

1.2.4) Long Short-Term Memory (LSTM)

1.2.5) Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN)

1.3 ขอบเขตของการศึกษา

1.3.1 ขอบเขตด้านข้อมูล

ข้อมูลที่ใช้ในการศึกษานี้ เป็นข้อมูลเกี่ยวกับทางการเงิน ซึ่งทางผู้วิจัยได้นำข้อมูลมาจาก www.finance.yahoo.com โดยใช้ Library คือ yfinance ในการนำข้อมูลมาใช้งาน

1.3.2 ขอบเขตด้านเวลา

ในที่นี้จะใช้ข้อมูลราคาของเงินดิจิทัลที่มีมูลค่าการตลาดที่สูงที่สุด 3 อันดับ คือ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) ตามลำดับ สืบค้นได้ตั้งแต่วันที่ 1 มกราคม พ.ศ.2561 จนถึงวันที่ 31 ธันวาคม พ.ศ. 2566

1.3.3 ขอบเขตด้านเทคนิคและวิธีการ

1.3.3.1) ศึกษาแบบจำลองพยากรณ์ราคาของของเงินดิจิทัลแบบจำลอง 5 แบบ คือ

1.3.3.1.1) Recurrent Neural Network (RNN)

1.3.3.1.2) Convolutional Neural Network (CNN)

1.3.3.1.3) Gated Recurrent Units (GRU)

1.3.3.1.4) Long Short-Term Memory (LSTM)

1.3.3.1.5) Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN)

1.3.3.2) การประเมินประสิทธิภาพของแบบจำลองด้วย 1) Mean Absolute Error (MAE) 2) Mean Square Error (MSE) 3) Root Mean Square Error (RMSE) 4) R-Squared

1.4 ประโยชน์ที่คาดว่าจะได้รับ

ได้แบบจำลองพยากรณ์ราคาของเงินดิจิทัลจากเทคนิคเพื่อเป็นเครื่องมือหนึ่งที่ช่วยนักลงทุนตัดสินใจในการซื้อขายเงินดิจิทัล 5 แบบจำลอง คือ

1.4.1.) Recurrent Neural Network (RNN)

1.4.2) Convolutional Neural Network (CNN)

1.4.3) Gated Recurrent Units (GRU)

1.4.4) Long Short-Term Memory (LSTM)

1.4.5) Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN)

1.5 นิยามศัพท์เฉพาะ

1.5.1 **โครงข่ายประสาทเทียมแบบย้อนกลับ (Recurrent Neural Network : RNN)** หรือ เป็นโครงข่ายประสาทเทียม (Artificial Neural Network : ANN) รูปแบบหนึ่งที้ออกแบบมาเพื่อแก้ปัญหาเกี่ยวกับข้อมูลประเภทอนุกรมเวลา (Time Series) โดย RNN มีชั้นซ่อน (Hidden state) ที่สามารถจดจำข้อมูลก่อนหน้าได้ จึงสามารถใช้ในการทำนายหรือพยากรณ์ข้อมูลอนุกรมเวลาในอนาคต

1.5.2 **โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN)** หรือ เป็นโครงข่ายประสาทเทียมที่ได้รับความนิยมในการประมวลผลข้อมูลรูปภาพ โครงสร้างของ CNN มีการลดจำนวนการเชื่อมต่อระหว่างชั้นเพื่อลดความซับซ้อนและใช้ Filter หรือ Kernel เพื่อดึงเนื้อหาของภาพ ทำให้ลดความสำคัญของตำแหน่งข้อมูล โดย CNN เหมาะสำหรับการวิเคราะห์ภาพและสามารถปรับใช้กับประเภทอนุกรมเวลา (Time Series) ที่มีลักษณะซ้ำ ๆ ได้อย่างมีประสิทธิภาพ

1.5.3 **โครงข่ายประสาทเทียมแบบประตูสัญญาณวกกลับ (Gated Recurrent Units : GRU)** หรือ โครงข่ายประสาทเทียมแบบประตูสัญญาณวกกลับ เป็นรูปแบบหนึ่งของ RNN เพื่อแก้ปัญหาการมีหน่วยความจำระยะสั้นของ RNN ซึ่งการทำงานภายในของ GRU จะมีความคล้ายคลึงกับ LSTM เช่นกัน แต่จะลดความซับซ้อนของประตู (Gate) ลงเหลือเพียงแค่ 2 ประตู เพื่อให้เกิดความรวดเร็วในการคำนวณ ได้แก่ Update Gate เป็นประตู นำเข้าข้อมูลเพื่อนำไปคำนวณในการปรับสถานะของค่าเซลล์ และ Reset Gate เป็นประตูที่ใช้ในการตัดสินใจว่าจะปรับสถานะเซลล์เมื่อมีข้อมูลใหม่เข้ามาหรือไม่

1.5.4 **หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM)** หรือ เป็นรูปแบบหนึ่งของ RNN เพื่อแก้ปัญหาการลดลงของเกรเดียนต์ (Vanishing gradient) เมื่อลำดับ

ของข้อมูลที่ได้รับเข้ามามีจำนวนมากเกินไป โดยการทำงานของ LSTM นั้นจะมีความคล้ายคลึงกับ RNN แต่ในส่วน of ชั้นซ่อน (Hidden state) ที่ใช้สำหรับจดจำลำดับของข้อมูลก่อนหน้านั้น LSTM จะมีการเรียนรู้ว่า เมื่อใดควรลืม (Forget) เขียน (Write) หรืออนุญาตให้อ่าน (Read) ซึ่งทำให้สามารถรองรับข้อมูลที่มีลำดับปริมาณมากที่เข้ามาได้

1.5.5 โครงข่ายประสาทเทียมผสมผสาน (Hybrid Long Short-Term Memory Convolutional Neural Network : LSTM-CNN) แบบจำลองการเรียนรู้ของเครื่องที่ผสมผสานระหว่าง CNN และ LSTM หรือ LSTM และ CNN เพื่อให้ได้ประสิทธิภาพในการพยากรณ์ได้ดีขึ้น



บทที่ 2

แนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

ในบทนี้กล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องโดยเนื้อหาของการทบทวนวรรณกรรมมีรายละเอียดดังต่อไปนี้

2.1 ความรู้เกี่ยวกับเงินดิจิทัล

เงินดิจิทัลเริ่มต้นมาจากการพัฒนาระบบการเงินให้กับคนทั่วโลก โดยไม่ต้องใช้สถาบันการเงินหรือ หน่วยงานใดเป็นตัวกลางในการตรวจสอบและบันทึกข้อมูลการเงินแต่ทุกคนสามารถมีส่วนร่วมโดยใช้ คอมพิวเตอร์ของตนเองมาทำงานในระบบนี้ผ่านเครือข่ายอินเทอร์เน็ตโดยเมื่อมีคำสั่งการเงินคอมพิวเตอร์ของทุกคนในระบบจะเห็นคำสั่งดังกล่าวและช่วยกันตรวจสอบว่าการสั่งโอนดังกล่าวมาจากต้นทางที่แท้จริงหรือไม่และต้นทางมีเงินเพียงพอหรือไม่ซึ่งกระบวนการตรวจสอบจะให้คอมพิวเตอร์ทุกเครื่องในเครือข่ายแข่งกันคำนวณเพื่อตรวจสอบความถูกต้อง และเครื่องใดทำได้ก่อนจะได้รางวัลเป็นเงินดิจิทัลและข้อมูลที่ตรวจสอบเสร็จแล้ว จะถูกนำไปเก็บไว้ในรายการประวัติธุรกรรมบนบล็อกเชนซึ่งเป็นข้อมูลอิเล็กทรอนิกส์ที่จัดเก็บแบบเรียงลำดับต่อไปเรื่อย ๆ ตามลำดับของการเกิดขึ้นของธุรกรรมหลังจากนั้นเงินดิจิทัลใช้พื้นฐานของการจัดเก็บประวัติธุรกรรมแบบบล็อกเชน ซึ่งระบบจัดเก็บนี้เมื่อนำข้อมูลมาเรียงต่อกันตามลำดับธุรกรรมแล้ว จะทำให้เกิดการแก้ไขประวัติย้อนหลังได้ยากมาก เพราะนอกจากต้องแก้ไขข้อมูลในคอมพิวเตอร์ทุกเครื่องที่เก็บข้อมูลให้ตรงกันแล้วการจะแก้ไขตัวเลขที่เป็นดัชนีในการชี้ลำดับข้อมูลที่เก็บไว้ให้เป็นตัวเลขชุดใหม่ก็ทำได้ยากมากในทางคณิตศาสตร์เช่นกัน ซึ่งในกรณีของบิตคอยน์ได้เป็นตัวอย่างแรก ๆ ที่แสดงให้เห็นถึงการนำการจัดเก็บข้อมูลแบบบล็อกเชนมาประยุกต์ใช้ในวงกว้าง นอกจากนี้ยังให้รางวัลกับผู้เข้าร่วมการตรวจสอบความถูกต้องของธุรกรรมเป็นเงินดิจิทัลซึ่งกระบวนการนี้เป็นสิ่งที่เรียกว่าการขุดเหมือง (Mining) ซึ่งเป็นแรงจูงใจให้มีผู้มาร่วมเชื่อมต่อกับเครือข่ายและนำทรัพยากรทั้งการเชื่อมต่ออินเทอร์เน็ต อุปกรณ์ฮาร์ดแวร์ การใช้กระแสไฟฟ้า และพื้นที่จัดเก็บข้อมูล มาร่วมเป็นส่วนหนึ่งของเครือข่ายในการประมวลผลและจัดเก็บข้อมูลธุรกรรม ในการศึกษาครั้งนี้จะทำการศึกษาเงินดิจิทัลที่มีมูลค่าตามราคาตลาดที่สูงสุด 3 อันดับคือ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) ตามลำดับ

2.2 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง (Machine Learning) เป็นกระบวนการที่ทำให้คอมพิวเตอร์มีการเรียนรู้ด้วย ตนเองโดยไม่ต้องเขียนโปรแกรมกำกับโดยใช้แบบจำลองที่สร้างจากชุดข้อมูลที่มี

ความสัมพันธ์กัน และสามารถนำไปทำนายหรือใช้ในการตัดสินใจประเภทการเรียนรู้ของเครื่องแบ่งออกเป็น 3 ประเภท

2.2.1 การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นการเรียนรู้ที่ผู้ใช้จะต้องสอนการเรียนรู้ โดยสิ่งที่จะมาสอนคอมพิวเตอร์นั้น คือ ข้อมูล (Data) จากนั้นอาศัยข้อมูลในการฝึกฝนช่วยให้คอมพิวเตอร์สามารถเรียนรู้และคาดคะเนผลลัพธ์ต่าง ๆ ได้อย่างแม่นยำมากยิ่งขึ้น


2.2.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นการเรียนรู้โดยที่คอมพิวเตอร์นั้น ๆ จะทำการเรียนรู้สิ่งต่าง ๆ ด้วยตัวเองโดยไม่ต้องตั้งค่าเป้าหมายของแต่ละข้อมูล ระบบจะสามารถนำไปวิเคราะห์และสร้างแบบแผนจากข้อมูลที่ได้รับเข้าไป

2.2.3 การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) เป็นการเรียนรู้แบบไม่มีผู้สอนซึ่งเป็นการเรียนรู้จากการลองผิดลองถูกจากสถานการณ์ในอดีตหรือระบบจำลองเพื่อพัฒนาระบบการตัดสินใจให้ดียิ่งขึ้น

2.3 แบบจำลองการเรียนรู้ของเครื่อง

2.3.1 โครงข่ายระบบประสาทเทียมแบบย้อน (Recurrent Neural Network : RNN)


เป็นโครงข่ายประสาทเทียมประเภทหนึ่ง [1] ที่มีการวนภายใน Node ทำให้สามารถประมวลผลข้อมูลที่เรียงกันเป็นลำดับหรือมีลักษณะประเภทอนุกรมเวลา (Time Series) ดังแสดงในรูปที่ 2.1 แสดงสถาปัตยกรรมแบบย่อของ RNN ซึ่ง RNN ประมวลผลของอนุกรมข้อมูลนำเข้า โดยการนำข้อมูลนำเข้าของ Node วนกลับเข้าไปใน Node เดิมร่วมกับข้อมูลนำเข้าในลำดับถัดไป ซึ่งการทำเช่นนี้ทำให้ RNN สามารถเก็บและรักษา State ที่บรรจุข้อมูลที่แบบจำลองได้เห็นมาในลำดับก่อนหน้าไว้ได้ ซึ่งการวนรับข้อมูลนำเข้าในลำดับถัดไปในแต่ละครั้ง จะทำให้ State เปลี่ยนไปและแบบจำลองเรียนรู้ข้อมูลนำเข้าทั้งอนุกรม ซึ่งสามารถดูสถาปัตยกรรมแบบแสดงชั้นลำดับดังแสดงในรูปที่ 2.2 ที่เกิดจากการกางสถาปัตยกรรมแบบย่อดังแสดงในรูปที่ 2.1



รูปที่ 2.1 สถาปัตยกรรมแบบย่อของ RNN [1] รูปที่ 2.2 สถาปัตยกรรมแบบแสดงชั้นลำดับของ RNN [1]

2.3.2 โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Network : CNN)

แบบจำลองโครงข่ายประสาทเทียม [1] ที่นิยมนำมาใช้ในการเรียนรู้ข้อมูลรูปภาพ หรือ Computer Vision โดยเป็นรูปแบบอย่างง่ายของโครงข่ายประสาทเทียมทั่วไป ที่เป็น Fully Connected หรือมี Edges เชื่อมข้อมูลระหว่างชั้นก่อนหน้าและชั้นโครงข่ายประสาทเทียมที่สนใจครบทุกคู่ Node แต่สำหรับ CNN จะเป็นการลดจำนวน Edge ระหว่างสองชั้นนี้ลง แต่ละ Node ของชั้น CNN จะมี Edge เชื่อมไปแค่บาง Node ของชั้นก่อนหน้าเท่านั้น ซึ่ง Edge เหล่านี้เรียกว่า Filter หรือ Kernel ดังแสดงในรูปที่ 2.3 และค่าน้ำหนักใน Filter จะถูกเรียนรู้ได้ในตอนฝึกแบบจำลอง นอกจากนี้ค่าน้ำหนักยังถูกใช้ซ้ำ ๆ กันสำหรับแต่ละ Node ของชั้น CNN ทั้งนี้สามารถนำมาใช้กับ Time Series ที่อาจจะมีรูปแบบข้อมูลซ้ำ ๆ กันแต่จะมีการเปลี่ยนตำแหน่งไปได้



รูปที่ 2.3 ตัวอย่างการคอนโวลูชันจากข้อมูลนำเข้าขนาด $7 \times 7 \times 1$ และ Filter ขนาด $3 \times 3 \times 1$ [1]

2.3.3 โครงข่ายประสาทเทียมแบบประตูสัญญาณวนกลับ (Gated Recurrent Units : GRU)

แบบโครงข่ายประสาทเทียมชนิดนี้ [2] พัฒนาขึ้นมาเพื่อแก้ปัญหามีหน่วยความจำระยะสั้นของ RNN เช่นเดียวกับ LSTM ซึ่งการทำงานภายในของ GRU จะมีความคล้ายคลึงกับ LSTM เช่นกัน แต่จะลดความซับซ้อนของประตู (Gate) ลงเหลือเพียง แค่ 2 ประตู เพื่อให้เกิดความรวดเร็วในการคำนวณ

Update Gate (z) เป็นประตูนำเข้าข้อมูลเพื่อนำไปคำนวณในการปรับสถานะของค่าเซลล์เพื่อส่งเป็นข้อมูลขาออกในการคำนวณในขั้นต่อไป ฟังก์ชันกระตุ้นที่ควบคุมการทำงานประตูนี้ อยู่คือ Sigmoid Function ฟังก์ชันซิกมอยด์ (σ) ผลลัพธ์ที่จะได้ออกมาจะมีค่าอยู่ระหว่างค่า 0 ถึง 1 หรือก็คือ Z_t ตามสมการที่ 2.1

$$Z_t = \sigma(W_{xz}x_t + W_{xz}h_{t-1} + b_z) \quad (2.1)$$

Reset Gate (r) เป็นประตู่ที่ใช้ในการตัดสินใจว่าจะปรับสถานะเซลล์เมื่อมีข้อมูลใหม่เข้ามาหรือไม่ มีฟังก์ชันซิกมอยด์ทำหน้าที่เป็นฟังก์ชันกระตุ้น เพื่อทำการตัดสินใจว่าจะให้มีการปรับเปลี่ยนสถานะเซลล์หรือไม่ ในการคำนวณส่วนนี้จะใช้ข้อมูลนำเข้าปัจจุบันที่เข้ามาพร้อมกับชั้นซ่อน (Hidden State) ก่อนหน้าตามสมการที่ 2.2


$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \quad (2.2)$$

หลังจากที่ได้สมการของประตูทั้ง 2 แล้ว สิ่งที่เราต้องการคือการคำนวณเอาต์พุตที่ทำนายได้ ในสถานะชั้นซ่อนที่เวลาปัจจุบัน (h'_t) ซึ่งคำนวณจากผลรวมระหว่างข้อมูลนำเข้าที่เวลาปัจจุบัน (x_t) คูณกับเมทริกซ์ค่าถ่วงน้ำหนักของเอาต์พุต (W_{xh}) กับการทำ Element-wise Product ($\odot$) ระหว่าง Reset Gate (r) กับสถานะชั้นซ่อนก่อนหน้า (Hidden State) เพื่อตัดสินใจว่าจะเอาสถานะของชั้น ซ่อนก่อนหน้านี้นี้มาเท่าใด ซึ่งผลลัพธ์ของการทำ Element-wise Product ($\odot$) จะคูณอยู่กับเมทริกซ์ค่าถ่วงน้ำหนักของ Update Gate ตามสมการที่ 2.3

$$h'_t = \tanh(W_{xh}x_t + W_{rh}h_{t-1} + b_h) \quad (2.3)$$

เนื่องจากฟังก์ชันกระตุ้นที่ใช้คือ ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent: $\tanh$) หรือฟังก์ชันแทนซึ่งเป็นฟังก์ชันไม่เชิงเส้น (Nonlinearity Function) ค่าที่ได้ออกมาจึงจะอยู่ในช่วง -1 ถึง 1 ซึ่งจะช่วยป้องกันการเกิดปัญหาการลดลงของเกรเดียนต์ เนื่องจากฟังก์ชันนี้จะจำกัดค่า (Bounds) ให้อยู่ระหว่างช่วงดังกล่าว จึงทำให้สามารถที่จะคำนวณค่าการแพร่กลับของความผิดพลาด (Backpropagation) ได้โดยที่ค่าที่ได้ออกมาจะไม่เป็นค่าอนันต์ ขั้นตอนสุดท้ายคือการคำนวณสถานะชั้นซ่อนที่เวลาปัจจุบันเพื่อส่งออกไปเป็นผลลัพธ์สุดท้าย หรือก็คือเป็นการตัดสินใจว่าจะทำการปรับเปลี่ยนค่าให้เป็นค่าใด ระหว่างผลลัพธ์ที่ทำนายได้จากสถานะชั้นซ่อนก่อนหน้า (h'_t) หรือผลลัพธ์ที่ทำนายได้จากสถานะชั้นซ่อนปัจจุบัน (h_t) ในสัดส่วนเท่าใด ตามสมการที่ 2.4 สำหรับสถาปัตยกรรมของ GRU สามารถแสดงได้ดังรูปที่ 2.4


$$h_t = (1 - z_t)h_{t-1} + z_th'_t \quad (2.4)$$



รูปที่ 2.4 สถาปัตยกรรมของ GRU [3]

2.3.4 หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM)

แบบโครงข่ายประสาทเทียมชนิดนี้ [1] พัฒนาขึ้นมาเพื่อแก้ปัญหบางอย่างจาก RNN แบบเดิมมักจะมีปัญหาการปรับเปลี่ยนค่าน้ำหนักในชั้นต้น ๆ น้อยเกินไป หรือ Vanishing Gradient เพราะข้อมูลนำเข้ามีความยาวมากเกินไป เป็นผลให้แบบจำลองไม่สามารถเรียนรู้จากข้อมูลในส่วนแรก ๆ ได้ แต่ LSTM สามารถเรียนรู้และมีความจำสำหรับข้อมูลในระยะยาวได้ โดยส่วนสำคัญของ LSTM ก็คือเซลล์ State (C.) ที่จะเดินทางยาวไปตาม Node ของ LSTM และมีการรับค่าเพื่อเปลี่ยนแปลงเซลล์ State จาก 4 เกตในแต่ละ Node ดังที่แสดงในรูปที่ 2.5



รูปที่ 2.5 สถาปัตยกรรมของ LSTM [1]



รูปที่ 2.6 เกตที่ 1 [1]

รูปที่ 2.7 เกตที่ 2 และ 3 [1]

รูปที่ 2.8 เกตที่ 4 [1]

เกตที่ 1 ดังแสดงในรูปที่ 2.6 เป็นเกตซิกมอยด์หรือสามารถเรียกได้ว่าเป็นเกตฟอร์เก็ต (Forget gate) คำนวณออกจากเกตนี้จะได้ f_t ที่ถูกสร้างขึ้นมาจาก ฟังก์ชันซิกมอยด์ที่รับค่า

h_{t-1} และ x_t ตามสมการ 2.5 ผลที่ได้จะมีค่าระหว่าง 0 ถึง 1 เพื่อนำคูณกับ C_{t-1} โดย 1 หมายถึงเก็บรักษา State ก่อนหน้าไว้ทั้งหมดและ 0 หมายถึงลืม State ก่อนหน้าทั้งหมด

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.5)$$

ในส่วนถัดไปดังแสดงในรูปที่ 2.7 จะเป็นการตัดสินใจการใช้หรือจำข้อมูลใหม่เพื่อนำเข้ามาในเซลล์ State ในส่วนนี้จะมี 2 เกต เกตแรกเป็นเกตซิกมอยด์ และเกตที่สองเป็นเกตแทนเอช (Tanh Gate) ซึ่ง จะถูกรวมกันแล้วใช้ในการปรับเปลี่ยนเซลล์ State ตามสมการที่ 2.6 และ 2.7

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.6)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.7)$$

ส่วนสุดท้ายดังแสดงในรูปที่ 2.8 คือส่วนที่ตัดสินใจการปล่อยค่านำออกของ Node ในส่วนนี้จะเริ่ม จากการนำ h_{t-1} และ x_t มาเข้าฟังก์ชันซิกมอยด์ได้เป็น O_t ตามสมการที่ 2.8 จากนั้นนำ C_t มาเข้าฟังก์ชันแทนเอชและนำไปคูณกับ O_t ตามสมการที่ 2.9 เพื่อให้ค่านำออกจาก Node มีเพียงส่วนที่ถูกเลือกแล้วเท่านั้น

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.8)$$


$$h_t = O_t * \tanh(C_t) \quad (2.9)$$

ค่านำออกที่ได้จะเป็น State ของ Node และจะถูกใช้เป็นค่านำเข้าใน Node ถัดไป ร่วมกับเซลล์ State เพื่อช่วยในการจำข้อมูลก่อนหน้านี้ ด้วยรูปแบบของเกตและเซลล์ State ใน LSTM ทำให้แบบจำลองประเภทนี้สามารถแก้ปัญหา Vanishing Gradient ได้


2.3.5 โครงข่ายประสาทเทียมผสมผสาน (Hybrid Long Short-Term Memory Convolutional Neural Network : LSTM-CNN)

โครงข่ายประสาทเทียมผสมผสาน[1] ระหว่าง CNN และ LSTM แบบจำลอง (CNN-LSTM) แสดงได้ดังรูปที่ 2.9 CNN ซึ่งทำหน้าที่เลือกตัวแปร โดยการเรียนรู้และให้ น้ำหนักตัวแปรแต่

ละตัวที่แตกต่างกัน เพื่อเรียนรู้แบ่งระดับความสำคัญของตัวแปร ก่อนส่งต่อไปยังชั้น LSTM เพื่อเรียนรู้ความสัมพันธ์ของตัวแปรต่าง ๆ ในอนุกรมเวลากับฉลากข้อมูล จากนั้นส่งข้อมูลต่อไปยังชั้น Batch Normalization เพื่อลดปัญหา Overfit ข้อมูลทั้งหมดจะถูกประมวลผลในโครงข่ายประสาทเทียม Dense และในชั้นสุดท้ายจะเป็น Dropout layer เพื่อลดปัญหา Overfit ส่วนแบบจำลอง (LSTM-CNN) แสดงได้ดังรูปที่ 2.10 ประกอบด้วยชั้นข้อมูลนำเข้ารูปแบบเดียวกันกับแบบจำลอง CNN-LSTM แต่มีการสลับลำดับชั้น LSTM มาก่อน CNN จากนั้นมีการเพิ่มชั้น Average Pooling หรือ Max Pooling และชั้น Flatten เพื่อจัดการข้อมูลที่ออกมาจากชั้น CNN ก่อนจะนำไปเข้าชั้น Batch Normalization ชั้น Dense และชั้น Dropout



รูปที่ 2.9 แผนภาพโครงข่ายประสาทเทียม CNN-LSTM [1]



รูปที่ 2.10 แผนภาพโครงข่ายประสาทเทียม LSTM-CNN [1]

2.4 การปรับค่าด้วยวิธี Normalization

วิธี Normalization [3] เป็นการแปลงค่าข้อมูลให้อยู่ในช่วงสั้น ๆ ซึ่งจะเป็นข้อมูลให้อยู่ในช่วง 0 – 1 ที่ใช้ในงานวิจัยนี้ หรือมีชื่อเรียกอีกชื่อว่า Min-Max Normalization ตามสมการที่ 2.10

$$x' = \frac{X - X_{min}}{X - X_{max}} \quad (2.10)$$


เมื่อกำหนดให้ x' คือ ค่าที่จะทำให้เป็นปกติมาตรฐานของตัวแปร x

X_{min} คือ ค่าต่ำสุดของตัวแปร x

X_{max} คือ ค่าสูงสุดของตัวแปร x

2.5 การแบ่งข้อมูลรูปแบบ Sliding Window

เป็นการแบ่งข้อมูลฝึกสอนก่อนนำเข้าตัวแบบจำลองพยากรณ์ [4] จุดเริ่มต้นของข้อมูลจะมีการขยับออกไปเรื่อย ๆ แต่จำนวนข้อมูลทั้งหมดยังคงเท่าเดิม ส่วนข้อมูลทดสอบเป็นข้อมูลถัดไป การแบ่งข้อมูลแบบนี้เหมาะกับข้อมูลประเภทอนุกรมเวลา ที่มีการนำข้อมูลเรียงตามเวลาพยากรณ์ค่าถัดไป แสดงดังรูปที่ 2.11



รูปที่ 2.11 การแบ่งข้อมูลรูปแบบ Sliding Window

2.6 การแบ่งข้อมูลเพื่อประเมินประสิทธิภาพของตัวแบบจำลอง

เพื่อประเมินประสิทธิภาพของตัวแบบจำลองที่สร้างขึ้นข้อมูลถูกแบ่งออกเป็นสองส่วน โดยส่วนแรกใช้เป็นข้อมูลสำหรับฝึกฝน และอีกส่วนใช้สำหรับเป็นข้อมูลทดสอบ ตัวแบบที่ถูกสร้างจากข้อมูลฝึกฝนการแบ่งข้อมูลสามารถทำได้หลายวิธีเช่น การแบ่งข้อมูลแบบ Split Test วิธีนี้เป็นที่นิยม โดยแบ่งข้อมูลออกเป็น 2 ส่วน คือ ข้อมูลฝึกฝนและข้อมูลทดสอบ เช่น 80% และ 20% หรือ 90% และ 10% ส่วนที่มีจำนวนข้อมูลมาก เช่น 80% หรือ 90% จะถูกนำไปใช้เป็นข้อมูลฝึกฝนเพื่อให้ได้ตัวแบบจำลอง หลังจากนั้นนำตัวแบบจำลองมาประเมินประสิทธิภาพด้วยข้อมูล 20% หรือ 10% ตามที่แบ่งไว้ตอนต้นในการแบ่งข้อมูลนี้จะแบ่งเพียงครั้งเดียวถ้าข้อมูลฝึกฝนและข้อมูลทดสอบ มีลักษณะคล้ายกันทำให้การประเมินประสิทธิภาพมีค่าสูงในทางกลับกันหากข้อมูลฝึกฝน และข้อมูลทดสอบมีลักษณะแตกต่างกัน ส่งผลทำให้ผลประเมินประสิทธิภาพมีค่าน้อย วิธีนี้เหมาะกับข้อมูลที่มีขนาดใหญ่

2.7 การประเมินค่าความผิดพลาดจากการพยากรณ์

2.7.1 ค่าความคลาดเคลื่อนสมบูรณ์เฉลี่ย (Mean Absolute Error : MAE) เป็นวิธีที่การวัดค่าความคลาดเคลื่อนที่นิยมอีกวิธีหนึ่งซึ่งวิธีนี้จะช่วยบอกถึงความคลาดเคลื่อนรวมได้ ในการวัดค่าความแม่นยำจากวิธีการนี้ยิ่งค่าที่ได้มีค่าน้อยแสดงว่าแบบจำลองที่ได้จะมีความแม่นยำมากตามสมการที่ 2.11

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_t| \quad (2.11)$$

เมื่อกำหนดให้ n แทนค่า จำนวนข้อมูลทั้งหมด

Y_i แทนค่า ข้อมูลที่แท้จริง

Y'_t แทนค่า ผลลัพธ์ที่ได้จากการพยากรณ์

2.7.2 ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error : MSE) การประเมินประสิทธิภาพของการทำงานในการพยากรณ์ค่าข้อมูลที่อยู่ในรูปตัวเลข จะใช้ความผิดพลาดที่เกิดขึ้นของการพยากรณ์ชุดข้อมูลทดสอบโดยเปรียบเทียบค่าผลลัพธ์ที่แท้จริงกับค่าผลลัพธ์จากการพยากรณ์ตามสมการที่ 2.12

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y'_t)^2 \quad (2.12)$$

เมื่อกำหนดให้ n แทนค่า จำนวนข้อมูลทั้งหมด

Y_i แทนค่า ข้อมูลที่แท้จริง

Y'_t แทนค่า ผลลัพธ์ที่ได้จากการพยากรณ์

2.7.3 ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error : RMSE) เป็นวิธีการวัดค่าความคลาดเคลื่อนแบบมาตรฐานที่นิยมใช้กันอย่างแพร่หลาย โดยค่าที่ได้ยิ่งน้อยจะยิ่งแสดงว่าตัวแบบจำลองมีความแม่นยำมาก วิธีการคำนวณคือจะเป็นการนำค่า MSE ที่คำนวณได้มาหารากที่สอง ตามสมการที่ 2.13

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_t)^2} \quad (2.13)$$

เมื่อกำหนดให้ n แทนค่า จำนวนข้อมูลทั้งหมด

Y_i แทนค่า ข้อมูลที่แท้จริง

Y'_i แทนค่า ผลลัพธ์ที่ได้จากการพยากรณ์

2.7.4 R-squared ใช้เป็นตัววัดคุณภาพของแบบจำลองทางสถิติที่ใช้ในการประมาณค่าหรือพยากรณ์ข้อมูลตามแบบจำลองที่สร้างขึ้น โดย R-squared จะบ่งบอกถึงสัดส่วนของความแปรปรวนของตัวแปรตามที่สามารถอธิบายได้ ค่า R-squared คำนวณจากการเปรียบเทียบความแปรปรวนของค่าที่ได้จากแบบจำลองกับความแปรปรวนทั้งหมดของข้อมูล เพื่อวัดความเหมาะสมของแบบจำลองในการอธิบายความเปลี่ยนแปลงของตัวแปรตาม

$$R - \text{squared} = 1 - \frac{SSE}{SST} \quad (2.14)$$

$$SSE = \sum (Y' - Y)^2 \quad (2.15)$$

$$SST = \sum (Y_{avg} - Y)^2 \quad (2.16)$$

Sum of Squared Errors (SSE) คือผลรวมของค่าความแตกต่างระหว่างค่าที่พยากรณ์จากแบบจำลองกับค่าจริง

Sum of Squares Total (SST) คือผลรวมของความแปรปรวนทั้งหมดของตัวแปรตาม

Y แทนค่า ข้อมูลที่แท้จริง

Y' แทนค่า ผลลัพธ์ที่ได้จากการพยากรณ์

Y_{avg} แทนค่า ค่าเฉลี่ยของข้อมูลที่แท้จริง

ค่า R-squared จะอยู่ในช่วง 0 ถึง 1 โดยค่าที่สูงขึ้นแสดงให้เห็นถึงความเหมาะสมของแบบจำลองในการพยากรณ์

2.8 งานวิจัยที่เกี่ยวข้อง

ในปี ค.ศ 2019 K.Thaweephon [5] ได้นำเสนอตัวแบบสำหรับพยากรณ์ปริมาณความหนาแน่นของฝุ่นละออง PM2.5 ด้วยแบบจำลอง LSTM และแบบจำลอง SARIMAX และจากการศึกษาพบว่าแบบจำลอง LSTM นั้นให้ค่า RMSE และ MAE ของแต่ละช่วงเวลาในการทำนายออกมาดีกว่าแบบจำลอง SARIMAX ซึ่งการทำนายในอีก 1 ชั่วโมงข้างหน้าแบบจำลอง LSTM ได้ค่าเฉลี่ยของ RMSE = 3.11 ไมโครกรัมต่อลูกบาศก์เมตร และ MAE = 2.36 ไมโครกรัมต่อลูกบาศก์เมตร ในขณะที่ค่าความผิดพลาด (error) ของแบบจำลอง SARIMAX นั้นมีค่าสูงกว่าเป็นเท่าตัว

ในปี ค.ศ 2019 M.Vijha et al. [6] งานวิจัยนี้ใช้แบบจำลอง ANN และ Random Forest เพื่อทำนายราคาปิดในวันถัดไปสำหรับห้าบริษัทในอุตสาหกรรมต่าง ๆ โดยใช้ข้อมูลทางการเงิน ได้แก่ ราคาเปิด ราคาสูง ราคาต่ำ และราคาปิดของหุ้น ถูกลำมาใช้เพื่อสร้างตัวแปรใหม่ ซึ่งจะถูกใช้เป็นอินพุตให้กับแบบจำลอง ประสิทธิภาพของแบบจำลองถูกประเมินโดยใช้ตัวชี้วัดมาตรฐาน ได้แก่ RMSE (Root Mean Squared Error) และ MAPE (Mean Absolute Percentage Error) จากการศึกษานี้พบว่า ตัวแบบจำลองของ ANN มีประสิทธิภาพดี Random Forest ในการทำนายราคาปิดของหุ้น โดยที่ RMSE = 0.42 และ MAPE 0.77

ในปี ค.ศ 2021 W.Lertthaweedech [1] ได้นำเสนอตัวแบบทำนายแนวโน้มราคาน้ำมันและส่งสัญญาณการซื้อขายน้ำมันให้ดียิ่งขึ้นเมื่อเทียบกับกลยุทธ์การซื้อขายน้ำมันแบบดั้งเดิม โดยงานวิจัยนี้ได้นำเสนอเทคนิคการใช้โครงข่ายประสาทเทียมแบบผสมกันระหว่าง CNN และ LSTM โดยหลักการของแบบจำลองคือ CNN สามารถตรวจจับรูปแบบในตำแหน่งต่าง ๆ ของข้อมูล Time Series ได้ ในขณะที่ LSTM สามารถใช้รักษาความจำทั้งระยะสั้นและระยะยาวสำหรับข้อมูล Time Series ได้ การผสมผสานคุณสมบัติเหล่านี้จึงเพิ่มความสามารถให้แบบจำลองได้ จากการศึกษานี้พบว่า การผสมกันของ CNN และ LSTM สามารถเพิ่มความสามารถในการทำกำไรจากการซื้อขายน้ำมันดิบได้ในระยะยาว

ในปี ค.ศ 2021 K.Sonklin [7] ได้นำเสนอแบบจำลองการพยากรณ์ราคาด้วยเทคนิค 1D-CNN, LSTM และ SVR โดยใช้คุณลักษณะจำนวน 9 คุณลักษณะคือ ราคาเปิด ราคาสูงสุด ราคาต่ำสุด ราคาปิด ราคาที่ใช้ชำระราคา ราคาเปลี่ยนแปลง %ราคาเปลี่ยนแปลง ปริมาณการสั่งซื้อ และสถานะคงค้าง โดยนำคุณลักษณะทั้งหมดมาหาความสัมพันธ์กับราคาด้วยวิธีสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson) ผลการวิจัยพบว่าแบบจำลองจำวิธีการ LSTM มีประสิทธิภาพในการพยากรณ์ดีที่สุด

ในปี ค.ศ 2022 S.Puteh [8] ได้นำเสนอการสร้างแบบจำลองที่สามารถคาดการณ์ราคาขายรถยนต์มือสองได้อย่างแม่นยำ โดยศึกษาปัจจัยที่เกี่ยวข้องกับคุณลักษณะต่าง ๆ ของรถยนต์ เช่น รุ่นรถยนต์, ปีที่ผลิต, ขนาดเครื่องยนต์, ประเภทเชื้อเพลิง, ภาษีทางถนน, ประเภทของเกียร์ และ

ระยะทางที่รถยนต์ได้เคลื่อนที่ไปจนถึงปัจจุบัน จากนั้นเปรียบเทียบโมเดลต่าง ๆ คือ Decision Tree Regression, Linear Regression, Ridge Regression, Lasso Regression, และ Random Forest ชุดข้อมูลถูกแบ่งเป็นชุดการฝึกและการทดสอบด้วยอัตราส่วน 80% 20% เพื่อประเมินประสิทธิภาพของโมเดล จากการทดลองพบว่าโมเดล Random Forest ให้ผลลัพธ์ที่ดีที่สุดด้วย $MAE=£942$, $MAPE = 6\%$, และค่าสัมประสิทธิ์ = 0.95

ในปี ค.ศ.2023 K.Narupatpajong [9] ได้นำการสร้างแบบจำลองเบื้องต้นที่ใช้สำหรับการทำนายค่าความเข้มข้นของฝุ่นละอองขนาดเล็ก (PM2.5) โดยชุดข้อมูลที่ใช้ในงานวิจัยนี้ประกอบด้วยข้อมูลฝุ่นละอองขนาดเล็ก (PM2.5) ช่วงวันที่ 1 มกราคม - 31 ธันวาคม 2019 และช่วง 1 มกราคม - 28 กันยายน 2020 ประกอบด้วยตัวแปรที่สามารถส่งผลต่อค่า PM2.5 ได้แก่ อุณหภูมิ, จุดน้ำค้าง, ความชื้น, ทิศทางลม, ความเร็วลม, ลมกระโชก และ ความกดอากาศ แบบจำลองที่ใช้ประกอบด้วย LR (Linear Regression), SVR (Support Vector Regression), XGBoost และ MLP (Multi-Layer Perceptron) จากผลการทดลองพบว่าแบบจำลอง LR (Linear Regression) ให้ผลลัพธ์ที่ดีที่สุด ทั้งในแง่ของความถูกต้องแม่นยำ และความคลาดเคลื่อนที่ต่ำลง โดยผลลัพธ์ที่ดีที่สุดมีค่า $R^2 = 0.9722$, $MAE = 1.6832$, $RMSE = 2.4492$ และ $MAPE(\%) : 9.0302$

TNI

TAI - NICHU INSTITUTE OF TECHNOLOGY


บทที่ 3

วิธีการดำเนินงาน

งานวิจัยเรื่องการศึกษาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์ราคาของเงินดิจิทัลมีขั้นตอนการทำงานดังนี้

ตารางที่ 3.1 ขั้นตอนการวิจัย

ขั้นตอนหลัก	ขั้นตอนย่อย
ขั้นตอนเบื้องต้น	1)การวิเคราะห์ข้อมูลปัญหารวมทั้งศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง
ขั้นตอนการดำเนินการ	2) รวบรวมข้อมูลราคาของเงินดิจิทัล 3) จัดเตรียมข้อมูล หลังจากนั้นวิเคราะห์และสร้างแบบจำลองสำหรับพยากรณ์ราคาของเงินดิจิทัล 4) เปรียบเทียบและประเมินประสิทธิภาพของแบบจำลอง
ขั้นตอนการสรุป	5) สรุปผลและนำเสนอ



รูปที่ 3.1 กรอบแนวความคิด

กรอบแนวคิดสำหรับงานวิจัยนี้ประกอบด้วย 7 ขั้นตอน ดังนี้
ขั้นที่ 1 การวิเคราะห์ข้อมูลปัญหารวมทั้งศึกษาทฤษฎีและงานวิจัย ที่เกี่ยวข้อง

ขั้นที่ 2 รวบรวมข้อมูลราคาของเงินดิจิทัลคือ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) สืบค้นได้ตั้งแต่วันที่ 1 มกราคม พ.ศ.2561 จนถึงวันที่ 31 ธันวาคม พ.ศ.2566

ขั้นที่ 3 การปรับค่าด้วยวิธี Normalization

ขั้นที่ 4 กำหนดชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ เท่ากับ 90 และ 10


ขั้นที่ 5 การแบ่งข้อมูลด้วยวิธี Sliding Window เท่ากับ 10

ขั้นที่ 6 สร้างแบบจำลองแล้วเราต้องปรับมิติของข้อมูลฝึกสอนและทดสอบตามรูปแบบจำลอง จากนั้นนำข้อมูลเข้าสู่แบบจำลองพยากรณ์ และกำหนดค่าพารามิเตอร์ดังตารางที่ 3.2 และ 3.3 หลังจากได้แบบจำลองที่เหมาะสมแล้วให้นำข้อมูลทดสอบเข้าสู่แบบจำลอง

ขั้นที่ 7 ผลลัพธ์จากการพยากรณ์ที่ได้จากแบบจำลองของ RNN, CNN, GRU, LSTM และ LSTM-CNN มาปรับค่าเป็นค่าปกติ และนำผลไปแสดงเปรียบเทียบระหว่างค่าจริงและค่าพยากรณ์

3.1 ขั้นที่ 1 การวิเคราะห์ข้อมูลปัญรวมทั้งศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ผู้วิจัยได้ทำการวิเคราะห์ข้อมูลปัญหาของงานวิจัย เพื่อศึกษาหาแนวทางในสร้างแบบจำลองสำหรับพยากรณ์ราคาของเงินดิจิทัลตามขั้นตอนดังนี้



รูปที่ 3.2 ขั้นตอนการวิเคราะห์ข้อมูลปัญหาของงานวิจัย

3.1.1 ศึกษาข้อมูลและปัญหา

การศึกษาข้อมูลและปัญหาวิจัยในครั้งนี้ เป็นส่วนหนึ่งของการสร้างแบบจำลองพยากรณ์ราคาของเงินดิจิทัล ซึ่งเงินดิจิทัลมีความแปรปรวนสูงและซับซ้อนมีปัจจัยที่ส่งผลต่อราคาของเงินดิจิทัลมีมากมาย การคาดการณ์ราคาพยากรณ์ราคาของเงินดิจิทัลด้วยวิธีดั้งเดิม เช่น การใช้การวิเคราะห์ทางเทคนิคหรือการวิเคราะห์พื้นฐานมักมีข้อจำกัดในการอธิบายความแปรปรวนของราคาเงินดิจิทัล ด้วยเหตุดังกล่าวทำให้นักลงทุนมีความลังเลที่จะลงทุนในเงินดิจิทัล

3.1.2 วิเคราะห์แนวทางข้อมูลที่เกี่ยวข้อง

การเลือกหัวข้อวิจัยของปัญหาที่กล่าวมาจากข้างต้น ทำให้ผู้วิจัยเห็นว่าการเรียนรู้ของเครื่อง (Machine Learning) เป็นเทคโนโลยีที่ช่วยให้สามารถเรียนรู้ความสัมพันธ์ที่ซับซ้อนจาก

ข้อมูลจำนวนมากได้ และคิดว่าสามารถนำมาประยุกต์ใช้เพื่อพยากรณ์ราคาของเงินดิจิทัล ได้อย่างแม่นยำยิ่งขึ้น นอกจากนี้ การเรียนรู้ของเครื่อง (Machine Learning) ยังมีความยืดหยุ่นในการปรับให้เข้ากับข้อมูลและสถานการณ์ใหม่ ๆ ได้ จึงสามารถนำมาประยุกต์ใช้เพื่อพยากรณ์ราคาของเงินดิจิทัลในระยะยาวได้อีกด้วย

3.2 ขั้นที่ 2 รวบรวมข้อมูลราคาของเงินดิจิทัล


รวบรวมจาก ข้อมูลราคาของเงินดิจิทัลจากเว็บไซต์ <https://finance.yahoo.com> ตั้งแต่วันที่ 1 มกราคม พ.ศ.2561 จนถึงวันที่ 31 ธันวาคม พ.ศ.2566 โดยการใช้การเขียนโปรแกรมภาษา Python บน เว็บไซต์ <https://colab.research.google.com> ในการจัดการข้อมูลต่อไปดังรูปที่ 3.3, 3.4 และ 3.5



รูปที่ 3.3 กราฟแสดงราคาของ BTC



รูปที่ 3.4 กราฟแสดงราคาของ ETH



รูปที่ 3.5 กราฟแสดงราคาของ BNB

3.3 ขั้นที่ 3 ปรับค่าด้วยวิธี Normalization

การปรับค่าด้วยวิธี Normalization คือการปรับราคาให้มีค่าตั้งแต่ 0 – 1 ด้วยวิธี Normalization ของข้อมูลราคาของเงินดิจิทัล Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB)

3.4 ขั้นที่ 4 กำหนดชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ

จากชุดข้อมูลราคาของเงินดิจิทัล Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) โดยเราจะกำหนดชุดข้อมูลฝึกสอนเป็น 90% แรก ชุดข้อมูลที่เหลือ 10% เป็นชุดข้อมูลทดสอบ เพื่อให้แบบจำลองเรียนรู้ข้อมูลของ 90% แรกแล้วพยากรณ์ ชุดข้อมูล 10% ที่เหลือ

3.5 ขั้นที่ 5 การแบ่งข้อมูลด้วยวิธี Sliding Window

การแบ่งข้อมูลด้วยวิธี Sliding Window เพื่อสร้างชุดข้อมูล สำหรับฝึกสอนและฝึกทดสอบ แบบจำลองการพยากรณ์ โดยแต่ละ Window จะถูกสร้างขึ้นโดยเลือกข้อมูลย้อนหลังในช่วงเวลาที่กำหนดไว้โดยเลือกที่ 10 วัน

3.6 ขั้นที่ 6 สร้างแบบจำลอง

การสร้างแบบจำลองต้องปรับมิติของข้อมูลฝึกสอนและทดสอบให้เข้ากับแบบจำลอง จากนั้นนำข้อมูลราคาของเงินดิจิทัลเข้าสู่แบบจำลองพยากรณ์ และกำหนดค่าพารามิเตอร์ดังตารางที่ 3.2 และ 3.3

ตารางที่ 3.2 ค่าพารามิเตอร์สำหรับแบบจำลอง

Model	Hidden Layer		Output Layer	
RNN	จำนวนชั้น	1	Dense	1
	จำนวน Units	16	Optimizer	Adam
	Activation	tanh	Epochs	200
	Dropout	0.2	Batch Size	32
CNN	จำนวนชั้น	1	Dense	1
	จำนวน filter	32	Optimizer	Adam
	ขนาด kernel	3	Epochs	200
	Activation	tanh	Batch Size	32
	Dropout	0.2	-	-
	ขนาดMaxPooling	2	-	-
	Flatten	1	-	-
GRU	จำนวนชั้น	2	Dense	1
	จำนวน Units	16	Optimizer	Adam
	Activation	tanh	Epochs	200
	Dropout	0.2	Batch Size	32
LSTM	จำนวนชั้น	2	Dense	1
	จำนวน Units	16	Optimizer	Adam
	Activation	tanh	Epochs	200
	Dropout	0.2	Batch Size	32
LSTM-CNN	จำนวนชั้น	2	Dense	1
	จำนวน Units	16	Optimizer	Adam
	จำนวน filter	32	Epochs	200
	Activation	tanh	Batch Size	32
	ขนาดMaxPooling	2	-	-
	Dropout	0.2	-	-
	Flatten	1	-	-

หลังจากได้แบบจำลองที่เหมาะสมแล้ว ให้นำข้อมูลทดสอบมาผ่านขั้นตอนดังรูปที่ 3.1 โดยนำผลลัพธ์จากการพยากรณ์ที่ได้จากแบบจำลองของ RNN, CNN, GRU, LSTM และ LSTM-CNN มาปรับค่าเป็นค่าปกติ และนำผลไปแสดงกราฟเปรียบเทียบระหว่างค่าจริงและค่าพยากรณ์

3.7 ขั้นที่ 7 เปรียบเทียบและประเมินประสิทธิภาพของแบบจำลอง

การเปรียบเทียบและประเมินประสิทธิภาพของงานวิจัยนี้ทำโดยวัดค่าความคลาดเคลื่อนระหว่างราคาจริงกับราคาที่ทำพยากรณ์ได้ด้วยเพื่อประเมินประสิทธิภาพของแบบจำลอง 4 แบบด้วยกัน คือ MAE, MSE, RMSE และ R-Squared แบบจำลองจะมีประสิทธิภาพมาก เมื่อค่า MAE, MSE, RMSE มีค่าน้อย และแบบจำลองจะมีประสิทธิภาพมาก เมื่อค่า R-Squared มีค่ามาก



บทที่4

ผลการวิจัย

การศึกษาวิจัยเรื่องแบบจำลองการพยากรณ์ราคาของของเงินดิจิทัลที่มีมูลค่าการตลาดที่สูงสุด 3 อันดับคือ Bitcoin (BTC), Ethereum (ETH) และ Binance coin (BNB) ตามลำดับ โดยใช้แบบจำลอง RNN, CNN, GRU, LSTM และ LSTM-CNN พร้อมทั้งประเมินประสิทธิภาพของแบบจำลองด้วย MAE, MSE, RMSE และ R-Squared โดยสามารถแบ่งผลการดำเนินการและการวิเคราะห์ข้อมูล ดังต่อไปนี้

- 4.1 ชุดข้อมูลราคาของ Bitcoin (BTC)
- 4.2 ชุดข้อมูลราคาของ Ethereum (ETH)
- 4.3 ชุดข้อมูลราคาของ Binance coin (BNB)


4.1 ชุดข้อมูลราคาของ Bitcoin (BTC)

ผลลัพธ์ของชุดข้อมูลราคาของ Bitcoin (BTC) จากการประเมินประสิทธิภาพของแบบจำลองของ RNN, CNN, GRU, LSTM และ LSTM-CNN ด้วย MAE, MSE, RMSE และ R-Squared ได้ผลลัพธ์ดังตารางที่ 4.1

ตารางที่ 4.1 แสดงประสิทธิภาพของแบบจำลอง Bitcoin (BTC)

Model	MAE	MSE	RMSE	R-Squared
RNN	472.95	510,966.28	714.81	0.97
CNN	727.06	814,553.47	902.52	0.96
GRU	755.62	739,915.52	890.68	0.97
LSTM	470.03	478,008.42	691.38	0.98
LSTM- CNN	555.35	557,160.97	746.43	0.97

4.1.1 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Bitcoin (BTC) ของแบบจำลอง Recurrent Neural Network (RNN) แสดงดังรูปที่ 4.1 และ 4.2 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.1 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง RNN ของ BTC




รูปที่ 4.2 แสดงประสิทธิภาพของแบบจำลอง RNN ของ BTC

4.1.2 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Bitcoin (BTC) ของแบบจำลอง Convolutional Neural Network (CNN) แสดงดังรูปที่ 4.3 และ 4.4 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.3 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง CNN ของ BTC




รูปที่ 4.4 แสดงประสิทธิภาพของแบบจำลอง CNN ของ BTC

4.1.3 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Bitcoin (BTC) ของแบบจำลอง Gated Recurrent Units (GRU) แสดงดังรูปที่ 4.5 และ 4.6 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.5 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง GRU ของ BTC



รูปที่ 4.6 แสดงประสิทธิภาพของแบบจำลอง GRU ของ BTC

4.1.4 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Bitcoin (BTC) ของแบบจำลอง Long Short-Term Memory (LSTM) แสดงดังรูปที่ 4.7 และ 4.8 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.7 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM ของ BTC



รูปที่ 4.8 แสดงประสิทธิภาพของแบบจำลอง LSTM ของ BTC

4.1.4 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Bitcoin (BTC) ของแบบจำลอง Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN) แสดงดังรูปที่ 4.9 และ 4.10 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์



รูปที่ 4.9 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM-CNN ของ BTC



รูปที่ 4.10 แสดงประสิทธิภาพของแบบจำลอง LSTM-CNN ของ BTC


4.2 ชุดข้อมูลราคาของ Ethereum (ETH)

ผลลัพธ์ของชุดข้อมูลราคาของ Ethereum (ETH) จากการประเมินประสิทธิภาพของแบบจำลองของ RNN, CNN, GRU, LSTM และ LSTM-CNN ด้วย MAE, MSE, RMSE และ R-Squared ได้ผลลัพธ์ดังตารางที่ 4.2

ตารางที่ 4.2 แสดงประสิทธิภาพของแบบจำลอง Ethereum (ETH)

Model	MAE	MSE	RMSE	R-Squared
RNN	38.35	2,794.89	52.86	0.93
CNN	73.65	7,139.16	73.65	0.84
GRU	43.64	3,150.38	43.64	0.93
LSTM	48.97	3,390.68	48.97	0.92
LSTM- CNN	35.02	2,337.67	35.02	0.94

4.2.1 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Ethereum (ETH) ของแบบจำลอง Recurrent Neural Network (RNN) แสดงดังรูปที่ 4.11 และ 4.12 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.11 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง RNN ของ ETH



รูปที่ 4.12 แสดงประสิทธิภาพของแบบจำลอง RNN ของ ETH

4.2.2 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Ethereum (ETH) ของแบบจำลอง Convolutional Neural Network (CNN) แสดงดังรูปที่ 4.13 และ 4.14 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.13 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง CNN ของ ETH



รูปที่ 4.14 แสดงประสิทธิภาพของแบบจำลอง CNN ของ ETH

4.2.3 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Ethereum (ETH) ของแบบจำลอง Gated Recurrent Units (GRU) แสดงดังรูปที่ 4.15 และ 4.16 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.15 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง GRU ของ ETH



รูปที่ 4.16 แสดงประสิทธิภาพของแบบจำลอง GRU ของ ETH

4.2.4 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Ethereum (ETH) ของแบบจำลอง Long Short-Term Memory (LSTM) แสดงดังรูปที่ 4.17 และ 4.18 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.17 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM ของ ETH




รูปที่ 4.18 แสดงประสิทธิภาพของแบบจำลอง LSTM ของ ETH

4.2.5 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Ethereum (ETH) ของแบบจำลอง Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN) แสดงดังรูปที่ 4.19 และ 4.20 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์



รูปที่ 4.19 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM-CNN ของ ETH



รูปที่ 4.20 แสดงประสิทธิภาพของแบบจำลอง LSTM-CNN ของ ETH


4.3 ชุดข้อมูลราคาของ Binance coin (BNB)

ผลลัพธ์ของชุดข้อมูลราคาของ Binance coin (BNB) จากการประเมินประสิทธิภาพของแบบจำลองของ RNN, CNN, GRU, LSTM และ LSTM-CNN ด้วย MAE, MSE, RMSE และ R-Squared ได้ผลลัพธ์ดังตารางที่ 4.3


ตารางที่ 4.3 แสดงประสิทธิภาพของแบบจำลอง Binance coin (BNB)

Model	MAE	MSE	RMSE	R-Squared
RNN	5.89	61.40	7.83	0.84
CNN	7.24	80.67	8.98	0.79
GRU	9.67	120.85	10.99	0.68
LSTM	4.21	45.12	6.71	0.88
LSTM- CNN	4.09	41.60	4.09	0.89

4.3.1 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Binance coin (BNB) ของแบบจำลอง Recurrent Neural Network (RNN) แสดงดังรูปที่ 4.21 และ 4.22 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.21 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง RNN ของ BNB




รูปที่ 4.22 แสดงประสิทธิภาพของแบบจำลอง RNN ของ BNB

4.3.2 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Binance coin (BNB) ของแบบจำลอง Convolutional Neural Network (CNN) แสดงดังรูปที่ 4.23 และ 4.24 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.23 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง CNN ของ BNB




รูปที่ 4.24 แสดงประสิทธิภาพของแบบจำลอง CNN ของ BNB

4.3.3 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Binance coin (BNB) ของแบบจำลอง Gated Recurrent Units (GRU) แสดงดังรูปที่ 4.25 และ 4.26 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.25 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง GRU ของ BNB




รูปที่ 4.26 แสดงประสิทธิภาพของแบบจำลอง GRU ของ BNB

4.3.4 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Binance coin (BNB) ของแบบจำลอง Long Short-Term Memory (LSTM) แสดงดังรูปที่ 4.27 และ 4.28 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์




รูปที่ 4.27 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM ของ BNB




รูปที่ 4.28 แสดงประสิทธิภาพของแบบจำลอง LSTM ของ BNB

4.2.4 กราฟแสดงประสิทธิภาพชุดข้อมูลราคาของ Binance coin (BNB) ของแบบจำลอง Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN) แสดงดังรูปที่ 4.29 และ 4.30 กำหนดเส้นสีน้ำเงินคือราคาจากชุดฝึกสอน เส้นสีส้มคือราคาจากชุดทดสอบ และเส้นสีเขียวคือราคาจากการพยากรณ์



รูปที่ 4.29 ราคาจากชุดทดสอบและราคาจากการพยากรณ์ของแบบจำลอง LSTM-CNN ของ BNB



รูปที่ 4.30 แสดงประสิทธิภาพของแบบจำลอง LSTM-CNN ของ Binance coin (BNB)

4.4 ประเมินประสิทธิภาพของแบบจำลองทั้งหมด

จากตารางที่ 4.1 – 4.3 ได้รวบรวมค่าประสิทธิภาพของแบบจำลอง ของแต่ละชุดข้อมูล แสดงดังตารางที่ 4.4 พบว่าจากชุดข้อมูลของ Bitcoin (BTC) แบบจำลอง LSTM มีประสิทธิภาพดีที่สุด ส่วนชุดข้อมูลของ Ethereum (ETH) แบบจำลอง GRU มีประสิทธิภาพดีที่สุด ส่วนชุดข้อมูลของ Binance coin (BNB) แบบจำลอง LSTM- CNN มีประสิทธิภาพดีที่สุด

ตารางที่ 4.4 แสดงประสิทธิภาพของแบบจำลองทั้งหมด

	Model	MAE	MSE	RMSE	R-Squared
Bitcoin (BTC)	RNN	472.95	510,966.28	714.81	0.97
	CNN	727.06	814,553.47	902.52	0.96
	GRU	755.62	739,915.52	890.68	0.97
	LSTM	470.03	478,008.42	691.38	0.98
	LSTM- CNN	555.35	557,160.97	746.43	0.97
Ethereum (ETH)	RNN	38.35	2,794.89	52.86	0.93
	CNN	73.65	7,139.16	73.65	0.84
	GRU	43.64	3,150.38	43.64	0.93
	LSTM	48.97	3,390.68	48.97	0.92
	LSTM- CNN	35.02	2,337.67	35.02	0.94
Binance coin (BNB)	RNN	5.89	61.40	7.83	0.84
	CNN	7.24	80.67	8.98	0.79
	GRU	9.67	120.85	10.99	0.68
	LSTM	4.21	45.12	6.71	0.88
	LSTM- CNN	4.09	41.60	4.09	0.89

บทที่ 5

บทสรุป อภิปราย และข้อเสนอแนะ

การศึกษาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์ราคาของเงินดิจิทัล โดยใช้เทคนิค RNN, CNN, GRU, LSTM และ LSTM-CNN ซึ่งการวิจัยนี้มีวัตถุประสงค์ตามบทที่ 1 ได้นำเสนอข้อสรุปตามลำดับดังนี้

5.1 สรุปผลการวิจัย

งานวิจัยนี้นำเสนอการศึกษาแบบจำลองการเรียนรู้ของเครื่องเพื่อพยากรณ์ราคาของเงินดิจิทัล โดยใช้แบบจำลองการเรียนรู้ของเครื่อง คือ

5.1.1) Recurrent Neural Network (RNN)

5.1.2) Convolutional Neural Network (CNN)

5.1.3) Gated Recurrent Units (GRU)

5.1.4) Long Short-Term Memory (LSTM)

5.1.5) Hybrid Long Short-Term Memory Convolutional Neural Network (LSTM-CNN)

โดยที่เรียนรู้จากข้อมูลในอดีตโดยชุดข้อมูลที่นำมาพยากรณ์ราคา คือ Bitcoin (BTC), Ethereum (ETH), Binance coin (BNB) ตามลำดับ จากนั้นนำผลพยากรณ์ราคามาหาค่าความผิดพลาดเพื่อเปรียบเทียบแบบจำลองที่ให้ค่าความแม่นยำมากที่สุดของแต่ละชุดข้อมูล โดยใช้ค่าความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และ R-Square โดยผลจากการวิจัยพบว่า

ชุดข้อมูลของ Bitcoin (BTC) ที่มีการแบ่งชุดข้อมูลฝึกสอน เท่ากับ 90% และชุดข้อมูลทดสอบ เท่ากับ 10% และแบ่งชุดข้อมูลแบบ Sliding windows จากการประเมินประสิทธิภาพในการพยากรณ์ราคาของเงินดิจิทัลจากแบบจำลองทั้งหมด พบว่า LSTM มีประเมินประสิทธิภาพมากที่สุดโดยมี ค่าความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) น้อยที่สุด = 470.03 ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) น้อยที่สุด = 478,008.42 ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) น้อยที่สุด = 691.38 และ ค่า R-Square มากที่สุด = 0.98

ชุดข้อมูล Ethereum (ETH) ที่มีการแบ่งชุดข้อมูลฝึกสอน เท่ากับ 90% และชุดข้อมูลทดสอบ เท่ากับ 10% และแบ่งชุดข้อมูลแบบ Sliding windows จากการประเมินประสิทธิภาพในการพยากรณ์ราคาของเงินดิจิทัลจากแบบจำลองทั้งหมด พบว่า LSTM-CNN มีประเมินประสิทธิภาพ

มากที่สุดโดยมี ค่าความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) น้อยที่สุด = 35.02 ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) น้อยที่สุด = 2,337.67 ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) น้อยที่สุด = 48.34 และ ค่า R-Square มากที่สุด = 0.94

ชุดข้อมูล Binance coin (BNB) ที่มีการแบ่งชุดข้อมูลฝึกสอน เท่ากับ 90% และชุดข้อมูลทดสอบ เท่ากับ 10% และแบ่งชุดข้อมูลแบบ Sliding windows จากการประเมินประสิทธิภาพในการพยากรณ์ราคาของเงินดิจิทัล จากแบบจำลองทั้งหมด พบว่า LSTM-CNN มีประสิทธิภาพมากที่สุดโดยมี ค่าความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) น้อยที่สุด = 4.09 ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) น้อยที่สุด = 41.60 ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) น้อยที่สุด = 6.450457 และ ค่า R-Square มากที่สุด = 0.89

5.2 อภิปรายผลวิจัย

งานวิจัยนี้ได้ใช้ข้อมูลราคาของเงินดิจิทัลที่มีมูลค่าการเทรดที่สูงที่สุด 3 อันดับคือ Bitcoin (BTC), Ethereum (ETH), Binance coin (BNB) ตามลำดับ สืบค้นได้ตั้งแต่วันที่ 1 มกราคม พ.ศ. 2561 จนถึงวันที่ 31 ธันวาคม พ.ศ. 2566 นำข้อมูลมาปรับค่าด้วยวิธี Normalization เพื่อให้แบบจำลองทำงานได้ดีขึ้น จากนั้นกำหนดชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจะกำหนดชุดข้อมูลฝึกสอนเป็น 90% แรกชุดข้อมูลที่เหลือ 10% เป็นชุดข้อมูลทดสอบ เพื่อให้แบบจำลองเรียนรู้ข้อมูลของ 90% แรกแล้วพยากรณ์ชุดข้อมูล 10% ที่เหลือ จากนั้นจึงแบ่งข้อมูลด้วยวิธี Sliding Window เท่ากับ 10 วัน และประเมินประสิทธิภาพของด้วย MSE, RMSE, MAE และ R-Square

จากผลการทดลองเปรียบเทียบแบบจำลอง พบว่าชุดข้อมูลของ BTC แบบจำลอง LSTM มีความประเมินประสิทธิภาพมากที่สุด และชุดข้อมูลของ ETH และ BNB แบบจำลอง LSTM - CNN มีประสิทธิภาพมากที่สุด ซึ่งผลลัพธ์ที่ได้แตกต่างกัน เนื่องจากข้อมูลเป็นข้อมูลคนละชุดกัน แต่ทุกชุดข้อมูลจะเห็นว่าแบบจำลอง LSTM จะมีประเมินประสิทธิภาพสูงเพราะว่า LSTM ทำงานได้ดีกับ กับข้อมูลที่เป็นประเภท time-series และเมื่อนำ LSTM ผสม กับ CNN ซึ่ง LSTM มีหน้าที่เพื่อจดจำ Patterns ในชวงเวลานาน ๆ มีประสิทธิภาพสำหรับปัญหาการทำนายที่เป็น Sequential เนื่องจากสามารถเก็บข้อมูลก่อนหน้าและนำมารวมใช้ในการประมวลผลได้ ส่วน CNN สามารถตรวจจับรูปแบบในตำแหน่งต่าง ๆ ของข้อมูล Time Series ได้คุณสมบัติเหล่านี้จึงเพิ่มความสามารถให้กับแบบจำลอง โดยประสิทธิภาพของการพยากรณ์มีความใกล้เคียงกันเป็นผลอันเนื่องมาจาก โครงสร้างของแบบจำลองทั้ง RNN, GRU LSTM และ LSTM-CNN เป็นประเภท Recurrent Neural Network เหมือนกัน อาจจะมีการปรับแต่งโครงสร้างของแบบจำลองของกันออกไปบ้างตามแต่ละแบบจำลอง

งานวิจัยนี้แสดงให้เห็นถึงการพยากรณ์ราคาเงินดิจิทัลซึ่งสามารถนำผลที่ได้ไปประยุกต์ใช้ประกอบการตัดสินใจในการเลือกที่จะลงทุนหรือกำหนดกลยุทธ์ที่เหมาะสมกับความต้องการของนัก

ลงทุน โดยในปัจจุบันแนวโน้มในการใช้ข้อมูลเพื่อตัดสินใจทางธุรกิจ (Data Driven) เทคโนโลยีด้านฮาร์ดแวร์ที่มีศักยภาพการคำนวณที่สูงขึ้นในราคาที่ถูกลงกว่าในอดีต, ข้อมูลปัจจัยต่าง ๆ ที่มีผลต่อราคามีมากขึ้นทั้งในแง่ขนาด ความเร็วและความหลากหลายของข้อมูล รวมถึงแนวโน้มในการวิจัยพัฒนาเทคนิคด้าน Machine Learning และ Deep Learning ที่ได้รับการพัฒนาอย่างรวดเร็วส่งผลให้มีการพัฒนาเทคนิควิธีการใหม่ ๆ ซึ่งช่วยให้นักวิจัยสามารถที่จะนำไปต่อยอดและขยายผลให้เกิดประโยชน์ได้อย่างกว้างขวางและเพิ่มประสิทธิภาพในการพยากรณ์ราคาของเงินดิจิทัล รวมถึงเป็นตัวเลือกเพื่อสร้างโอกาสในการลงทุนของนักลงทุนต่าง ๆ ได้อย่างมีประสิทธิภาพ

งานวิจัยนี้ยังสามารถพัฒนาต่อยอดด้วยการเพิ่มปัจจัยหรือตัวแปรที่มีผลต่อการพัฒนาแบบจำลองเพื่อให้มีความแม่นยำในการพยากรณ์มากขึ้น หรือนำแบบจำลองไปพัฒนาโดยใช้เทคนิคที่มีระดับสูงขึ้น หรือ ทดลองปรับ parameter ต่าง ๆ ของแบบจำลองที่สามารถทำงานได้มีประสิทธิภาพมากขึ้น หรือสร้างแบบจำลองที่มีความซับซ้อนมากขึ้นเพื่อให้เรียนรู้ข้อมูลในอดีตที่ดีขึ้น

5.3 ปัญหาและอุปสรรคในการทำงานวิจัย

เนื่องจากใช้โปรแกรมภาษา Python บน เว็บไซต์ <https://colab.research.google.com> ทำให้มีข้อจำกัดในการใช้งานเนื่องจากเราใช้ตัวฟรี จึงค่อนข้างใช้เวลานานและไม่ต่อเนื่อง ถ้าเราใช้ตัวที่มีการสมัครสมาชิกจะสามารถทำได้เร็วมากขึ้น

5.4 ข้อเสนอแนะงานวิจัย

5.4.1 เพิ่มการระบุช่วงเวลาที่มียุทธศาสตร์สำคัญ เช่น สถานะเศรษฐกิจ การระบาดของโรคติดเชื้อไวรัสโคโรนา และสถานะสงคราม เป็นต้น เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในช่วงเวลา ดังกล่าวว่ามีค่าความแม่นยำหรือถูกต้องแตกต่างกันอย่างไร

5.4.2 โดยในงานวิจัยนี้ได้เลือกเพียง คุณลักษณะเดียวเพื่อนำเข้าสู่แบบจำลอง คือ ราคา (Close) ในงานวิจัยถัดไปควรมีการใช้ คุณลักษณะมากกว่า 1 คุณลักษณะ ซึ่งอาจส่งผลให้ค่าพยากรณ์มีความคลาดเคลื่อนน้อยลง



บรรณานุกรม

TNI

บรรณานุกรม

- [1] W. Lertthaweedech, “*Combining Technical Analysis And Deep Learning Models For Crude Oil Trading*,” M.Sc. Thesis (Computer Science), Chulalongkorn University, Bangkok, Thailand, 2021.
- [2] R. Phooseekhiwe, “*Short Term Precipitation Forecasting Using Recurrent Neural Networks, A Case Study Of Suvarnabhumi Airport*,” M.Sc. Thesis (Statistics), Chulalongkorn University, Bangkok, Thailand, 2021.
- [3] P. Ninthanom et al., “Performance comparison of transformation methods in data mining classification technique,” *Thai Journal of Science and Technology*, vol. 10, no. 1, pp. 14-25, January 2021.
- [4] H. Lu and X. Peng, “*Better Effectiveness of Multi-integrated Neural Networks: Take Stock Big Data As An Example*,” Hindawi, [Online]. Available: <https://downloads.hindawi.com/journals/wcmc/2021/3938409.pdf>. [Accessed: January. 03, 2022].
- [5] K. Thaweephol, “*A Long Short-Term Memory Deep Neural Network Model For Pm2.5 Prediction In The Urban Bangkok Area*,” M.Sc. Thesis (Information Technology), Srinakharinwirot University, Bangkok, Thailand, 2019.
- [6] M. Vijha et al., “Stock closing price prediction using machine learning techniques,” *Procedia Computer Science*, vol. 167, no.326, pp. 599–606, March 2020.
- [7] K. Sonklin, “*Derivative Price Forecasting Models Using 1d Convolutional neural Network Long Short-Term Memory And Support Vector Regression*,” M.Sc. Thesis (Information Technology), Thai-Nichi Institute of Technology, Bangkok, Thailand, 2021.
- [8] S. Putehp, “*Prediction Of Used Car Prices Using Machine Learning*,” M.Sc. thesis (Data Science), Srinakharinwirot University, Bangkok, Thailand, 2022.
- [9] K. Narupatpajong, “*Machine Learning Model For Forecasting Particulate Matter Concentration (Pm 2.5)*,” Ph.D. dissertation (Data Science), Srinakharinwirot University, Bangkok, Thailand, 2023.

ประวัติผู้เขียนสารนิพนธ์



ชื่อ – สกุล

นาย ทิว ภูระย้า

วัน เดือน ปีเกิด

20 กุมภาพันธ์ พ.ศ. 2538

ที่อยู่ปัจจุบัน

111/35 หมู่บ้านแกรนเกิตยา หมู่ 4 ต.สวนหลวง

อ.กระทุ่มแบน จ.สมุทรสาคร 74110

Email : Ph.tiew_st@tni.ac.th

ประวัติการศึกษา

พ.ศ. 2566

วิทยาศาสตรมหาบัณฑิต สาขาเทคโนโลยีสารสนเทศ

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

พ.ศ. 2560

วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมอุตสาหกรรม
มหาวิทยาลัยมหิดล

ประวัติการทำงาน

พ.ศ. 2566 – ปัจจุบัน

นักวิเคราะห์ข้อมูล

ศูนย์ข้อมูลสังหาริมทรัพย์