

การศึกษาพารามิเตอร์ที่เหมาะสมของตัวแบบโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (LSTM) สำหรับการพยากรณ์ราคาสกุลเงินดิจิทัลกรณีศึกษา Bitcoin, Dogecoin และ Ethereum

A Study on Optimal Parameters of Long Short-Term Memory (LSTM) Networks for Cryptocurrency Price Forecasting: A Case Study of Bitcoin, Dogecoin, and Ethereum

วริสา ดาโด้ และ ปิยะชาติ เวียงนาค*

Warisa Datho and Piyachart Wiangnak*

คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่

Faculty of Science and Technology, Chiang Mai Rajabhat University

E-mail: 64143408@g.cmru.ac.th and piyachart@g.cmru.ac.th*

*Corresponding author

(Received: 4 March 2024, Revised: 7 April 2026, Accepted: 15 April 2026)

<https://doi.org/10.57260/stc.2026.1110>

บทคัดย่อ

สกุลเงินดิจิทัล เช่น Bitcoin (BTC), Ethereum (ETH) และ Dogecoin (DOGE) กำลังได้รับความนิยมเพิ่มขึ้น ทำให้การคาดการณ์ราคามีความสำคัญ งานวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบ LSTM เพื่อพยากรณ์ราคาสกุลเงินดิจิทัล โดยเก็บข้อมูลราคาย้อนหลังจาก Yahoo Finance ตั้งแต่วันที่ 7 มกราคม พ.ศ. 2563 ถึงวันที่ 5 มกราคม พ.ศ. 2568 ทำการปรับข้อมูลด้วย Min-Max Scaling และใช้ข้อมูลย้อนหลัง 60 วันพยากรณ์ราคาวันถัดไป จากนั้นสร้างโมเดล LSTM โดยทำการทดลองปรับค่าพารามิเตอร์ 3 ค่า ได้แก่ LSTM Units, Dropout Rate และ Dense Layer และเปรียบเทียบประสิทธิภาพโดยใช้ RMSE ผลการทดลองพบว่า สำหรับ BTC โมเดลที่มี LSTM Units = 60, Dropout Rate = 0.1, Dense Layer = 2 ให้ค่า RMSE ต่ำสุดที่ 1967.35 สำหรับ DOGE โมเดลที่มี LSTM Units = 70, Dropout Rate = 0.1, Dense Layer = 1 ให้ค่า RMSE ต่ำสุดที่ 0.01242 และสำหรับ ETH โมเดลที่มี LSTM Units = 70, Dropout Rate = 0.1, Dense Layer = 1 ให้ค่า RMSE ต่ำสุดที่ 116.54 ผลลัพธ์แสดงให้เห็นว่า LSTM สามารถใช้ในการพยากรณ์แนวโน้มราคาสกุลเงินดิจิทัลได้อย่างมีประสิทธิภาพ แต่ความแม่นยำอาจได้รับผลกระทบจากความผันผวนของตลาด

คำสำคัญ: โครงข่ายประสาทเทียม ครีบิตคอยร์เรนซี เงินดิจิทัล โมเดลพยากรณ์

Abstract

Digital currencies such as Bitcoin (BTC), Ethereum (ETH), and Dogecoin (DOGE) are increasingly popular, emphasizing the importance of price forecasting. This study employs a Long Short-Term Memory (LSTM) artificial neural network to predict digital currency prices. Historical price data were collected from Yahoo Finance, spanning from January 7, 2020 to January 5, 2025. The data were preprocessed using Min-Max Scaling, and a 60-day historical window was used to forecast the next day's price. Subsequently, an LSTM model was constructed by tuning three parameters including, the number of LSTM units, the Dropout Rate, and the number of Dense Layer units and its performance was evaluated using the root mean square error (RMSE). The experimental results revealed that for BTC, the model with 60 LSTM units, a Dropout Rate of 0.1, and 2 Dense Layer units achieved the lowest RMSE of 1967.35; for DOGE, the model with 70 LSTM units, a Dropout Rate of 0.1, and 1 Dense Layer unit achieved the lowest RMSE of 0.01242; and for ETH, the model with 70 LSTM units, a Dropout Rate of 0.1, and 1 Dense Layer units achieved the lowest RMSE of 116.54. These findings demonstrate that LSTM networks can effectively forecast digital currency price trends, although forecasting accuracy may be impacted by market volatility.

Keywords: Artificial neural network, Cryptocurrency, Digital currency, Prediction modelling

บทนำ

ในปัจจุบัน สกุลเงินดิจิทัลหรือคริปโทเคอร์เรนซี เช่น Bitcoin, Dogecoin และ Ethereum ได้กลายเป็นสินทรัพย์ทางการเงินที่มีบทบาทสำคัญในตลาดโลก อย่างไรก็ตาม ลักษณะเฉพาะที่โดดเด่นของสกุลเงินดิจิทัลคือความผันผวนของราคาที่สูงมาก การพยากรณ์ราคาของสกุลเงินดิจิทัลจึงเป็นเรื่องท้าทายที่มีผลต่อการตัดสินใจลงทุน (อุทิศ พงศ์จิรวัดนา และคณะ, 2566) ในอดีตการวิเคราะห์แนวโน้มมักพึ่งพาแบบจำลองทางสถิติ แต่ในปัจจุบันเทคนิคการเรียนรู้ของเครื่อง (Machine learning) และการเรียนรู้เชิงลึก (Deep learning) ได้รับการพิสูจน์แล้วว่ามีประสิทธิภาพสูงกว่าในการจัดการกับข้อมูลทางการเงินที่มีความซับซ้อน (นิติกร จันทาญ, 2564; Cibikdiken & Karakoyun, 2018)

เครื่องมือที่ได้รับการยอมรับอย่างกว้างขวางสำหรับการวิเคราะห์ข้อมูลอนุกรมเวลา (Time series) คือโมเดลหน่วยความจำระยะสั้นแบบยาว (Long short-term memory: LSTM) (ธีรภาพ แสงศรี และคณะ, 2567) ซึ่งการนำ LSTM มาประยุกต์ใช้นั้น ไม่เพียงแต่ช่วยวิเคราะห์ราคาหลักทรัพย์ดั้งเดิม (ณัฐพล จิตะวีระ, 2563) แต่ยังเปิดโอกาสให้นักลงทุนสามารถรับมือกับความผันผวนของตลาดคริปโทเคอร์เรนซี ได้อย่างเป็นระบบมากขึ้น ในการศึกษาครั้งนี้ ผู้วิจัยจึงมุ่งเน้นการปรับปรุงพารามิเตอร์ของ LSTM เพื่อค้นหาโครงสร้างที่เหมาะสมที่สุดในการพยากรณ์ราคาสกุลเงินดิจิทัล

การนำ LSTM มาประยุกต์ใช้ในการพยากรณ์ราคา Bitcoin, Dogecoin และ Ethereum ไม่เพียงแต่ช่วยเพิ่มความแม่นยำในการวิเคราะห์แนวโน้มราคา แต่ยังช่วยให้นักลงทุนสามารถใช้ข้อมูลที่ได้ในการวางแผนกลยุทธ์การลงทุนได้อย่างชัดเจนและมีประสิทธิภาพ นอกจากนี้ การประยุกต์ใช้โมเดลดังกล่าวยังสามารถนำไปพัฒนาระบบเทรดดิ้งอัตโนมัติ (Automated trading system) ที่ทำงานโดยใช้ข้อมูลพยากรณ์เป็นฐานในการตัดสินใจ ซึ่งช่วยลดข้อผิดพลาดจากการตัดสินใจที่เกิดจากอารมณ์ของมนุษย์ อีกทั้งยังสามารถช่วยให้นักลงทุนตอบสนองต่อความผันผวนของตลาดได้รวดเร็วมากขึ้น

ในเชิงวิชาการ การศึกษาและพัฒนาการพยากรณ์ราคาสกุลเงินดิจิทัลด้วย LSTM ยังเป็นส่วนหนึ่งที่สำคัญในการส่งเสริมความก้าวหน้าในด้าน Machine learning และปัญญาประดิษฐ์ โดยเฉพาะในแง่ของการพัฒนาวิธีการวิเคราะห์ข้อมูลแบบอนุกรมเวลา โมเดล LSTM ช่วยสนับสนุนการทำความเข้าใจพฤติกรรมของตลาดในช่วงเวลาต่าง ๆ รวมถึงการเชื่อมโยงปัจจัยทางเศรษฐกิจที่ซับซ้อน ซึ่งสามารถนำไปใช้ประโยชน์ในด้านอื่นๆ เช่น การวิเคราะห์ความเสี่ยง การจัดการพอร์ตโฟลิโอ และการพัฒนาระบบการลงทุนที่อิงข้อมูลทางวิทยาศาสตร์

ในการศึกษารุ่นนี้ ผู้วิจัยมีความสนใจจะเปรียบเทียบประสิทธิภาพของโมเดล หน่วยความจำระยะสั้นแบบยาว (LSTM) โดยการทดลองเปลี่ยนแปลงค่าพารามิเตอร์ต่างๆ โดยมุ่งเน้นการเปลี่ยนแปลงโครงสร้างสำคัญสามส่วน ได้แก่ LSTM, Dropout Rate, และ Dense Layer เพื่อตรวจสอบว่าค่าพารามิเตอร์ใดที่มีผลต่อความแม่นยำของการพยากรณ์มากที่สุด รวมถึงการทดสอบความเสถียรของโมเดลภายใต้สถานการณ์ที่แตกต่างกัน เช่น ความผันผวนของข้อมูลและปริมาณข้อมูลที่ใช้ในการฝึกอบรม ทั้งนี้ จุดมุ่งหมายของการวิจัยคือการค้นหาโครงสร้างและค่าพารามิเตอร์ที่เหมาะสมที่สุด เพื่อให้โมเดล LSTM มีประสิทธิภาพสูงสุดในการพยากรณ์ราคาของสกุลเงินดิจิทัล

วัตถุประสงค์

1. เพื่อใช้โมเดล LSTM สำหรับการพยากรณ์ราคาของสกุลเงินดิจิทัล ได้แก่ Bitcoin, Dogecoin และ Ethereum
2. เปรียบเทียบประสิทธิภาพของโมเดล LSTM เมื่อเปลี่ยนแปลงค่าพารามิเตอร์ต่างๆ เพื่อหาโมเดลที่มีประสิทธิภาพสูงสุดในการพยากรณ์ราคาของสกุลเงินดิจิทัล ได้แก่ Bitcoin, Dogecoin และ Ethereum

ระเบียบวิธีวิจัย

ประชากรและกลุ่มตัวอย่าง

ประชากร ข้อมูลที่ใช้ในงานวิจัยเป็นทุติยภูมิ (Secondary data) ของราคาสกุลเงินดิจิทัล 3 สกุล ได้แก่ Bitcoin, Dogecoin และ Ethereum โดยใช้ข้อมูลอนุกรมเวลา (Time Series) ราคาปิดในแต่ละวัน จากแหล่งข้อมูล Yahoo Finance (<https://finance.yahoo.com/quote/BTC-USD/history>)

กลุ่มตัวอย่าง ราคาสกุลเงินดิจิทัลรายวัน ที่รวบรวมมาจากข้อมูลราคาปิด (Closing price) ในแต่ละวัน เป็นจำนวน 1,826 วันของแต่ละสกุลเงินดิจิทัล ซึ่งการเก็บรวบรวมตั้งแต่วันที่ 7 มกราคม พ.ศ. 2563 ถึงวันที่ 5 มกราคม พ.ศ. 2568

เครื่องมือที่ใช้ในการดำเนินงานวิจัย

การดำเนินงานวิจัยครั้งนี้ ผู้วิจัยได้ใช้การโปรแกรม (Coding) โดยใช้ภาษาไพธอน (Python) ผ่านโปรแกรม Google colab โดยมีไลบรารีสำคัญ ได้แก่ Numpy, Pandas, Matplotlib, และ Scikit-Learn โมดูล TensorFlow และ Keras สำหรับสร้างและฝึกโมเดล LSTM โดยมีแหล่งข้อมูล Yahoo Finance สำหรับดึงข้อมูลราคาสกุลเงินดิจิทัล ผลลัพธ์จากโมเดลประเมินผลด้วยตัวชี้วัดผู้วิจัยเลือกใช้ RMSE เพื่อประเมินประสิทธิภาพของโมเดลเมื่อเผชิญกับความผันผวนสูง (High volatility) ซึ่งเป็นธรรมชาติของตลาดคริปโทเคอร์เรนซีควบคู่กับการใช้ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean absolute percentage Error: MAPE) เพื่อประเมินค่าความคลาดเคลื่อนสัมพัทธ์ (Relative error) ซึ่งทำให้สามารถเปรียบเทียบประสิทธิภาพของโมเดลข้ามสกุลเงินดิจิทัลที่มีระดับราคาแตกต่างกันได้อย่างเป็นรูปธรรมได้

ขั้นตอนดำเนินงาน

1. ศึกษาทฤษฎีและวรรณกรรมที่เกี่ยวข้อง การวิจัยนี้ใช้แนวคิดของโครงข่ายประสาทเทียม (Artificial neural network: ANN) ซึ่งมีการประยุกต์ใช้อย่างแพร่หลายตั้งแต่การพยากรณ์ในภาคการผลิต (ณัฐชา เพียรดี, 2552) ไปจนถึงการซื้อขายสินทรัพย์ทางการเงิน (วิศรุต เลิศทวีเดช, 2564) โดยเฉพาะสถาปัตยกรรม LSTM ที่ถูกคิดค้นขึ้นเพื่อแก้ไขปัญหาการลืมข้อมูลระยะยาวของโมเดล RNN (Hochreiter & Schmidhuber, 1997) ด้วยกลไกการใช้ประตูควบคุม (Gates) ที่ทำให้สามารถเลือกลืมหรือจดจำรูปแบบข้อมูลที่ซับซ้อนได้ (Goodfellow et al., 2016; Olah, 2015)

2. ศึกษาวิเคราะห์ปัญหาและเก็บรวบรวมข้อมูล ข้อมูลที่ใช้ในการศึกษานี้มาจาก Yahoo finance ซึ่งเป็นแหล่งข้อมูลที่เชื่อถือได้และมีข้อมูลราคาสกุลเงินดิจิทัลอย่างละเอียด

2.1 ช่วงเวลาของข้อมูล ข้อมูลราคาปิดรายวัน (Close price) ของ BTC, DOGE, และ ETH ช่วงเวลาที่ศึกษาตั้งแต่วันที่ 7 มกราคม พ.ศ. 2563 ถึง วันที่ 5 มกราคม พ.ศ. 2568

2.2 การจัดการข้อมูล แบ่งออกเป็น

- กำจัดข้อมูลที่ขาดหายหรือมีค่า Null โดยการตัดข้อมูล Record ที่เป็นค่า Null ออก แต่ในการศึกษาครั้งนี้ตรวจสอบไม่พบ ข้อมูลขาดหายหรือมีค่า Null

- การปรับสเกลข้อมูล: ใช้ Min-max scaling เพื่อปรับสเกลข้อมูลให้อยู่ในช่วง 0 ถึง 1 สร้างข้อมูลอนุกรมเวลาชุดนี้ผู้วิจัยเลือกใช้หน้าต่างข้อมูล 60 วัน โดยมีเหตุผลหลัก 3 ข้อได้แก่ 1) เพื่อช่วยกรองสัญญาณรบกวน (Noise) จากความผันผวนรายสัปดาห์ เพื่อโฟกัสกับทิศทางราคาหลักในระยะ 1-2 เดือนได้แม่นยำขึ้น 2) เพื่อรักษาสมดุลการเรียนรู้ เป็นจุดสมดุลที่ป้องกันไม่ให้โมเดลแกว่งตามเทรนด์สั้นเกินไป (Overshooting) และไม่ยาวจนตอบสนองเทรนด์ใหม่ช้าเกินไป (Lagging) และ 3) ครอบคลุมวัฏจักรตลาด: ระยะเวลา 60 วันครอบคลุมรอบการประกาศข่าวสารและตัวเลขทางเศรษฐกิจรายเดือน ซึ่งเป็นปัจจัยหลักที่ขับเคลื่อนตลาด คริปโตเคอเรนซี

- การแบ่งชุดข้อมูล: แบ่งข้อมูลออกเป็น 2 ชุด โดยการใช้การเรียงลำดับตามวันที่ของข้อมูล ชุดฝึก (Training set) 80% (วันที่ 7 มกราคม พ.ศ. 2563 ถึง วันที่ 6 มกราคม พ.ศ. 2567) และชุดทดสอบ (Testing set) 20% (เริ่มตั้งแต่ พ.ศ. 7 มกราคม พ.ศ. 2567 ถึง 5 มกราคม พ.ศ. 2568) เพื่อประเมินความสามารถของโมเดล

3. ในการออกแบบโครงสร้างโมเดล ผู้วิจัยได้ทำการทดลองปรับจูนพารามิเตอร์ (Hyperparameter tuning) 3 ส่วนหลัก ได้แก่ จำนวนยูนิต (LSTM units), อัตราการดรอปเอาต์ (Dropout rate) เพื่อลดภาวะเรียนรู้เกินจริง (Overfitting) และจำนวนชั้น (Dense layer) เพื่อสรุปผลเชิงเส้น ซึ่งเป็นกระบวนการสำคัญในการหาจุดสมดุลของโครงข่ายประสาทเทียม (พชร พงษ์สิทธิศักดิ์, 2563; Mehtab et al., 2020) จากนั้นประเมินประสิทธิภาพการพยากรณ์ด้วย ค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean Square error: RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean absolute percentage error: MAPE) ซึ่งเป็นมาตรฐานสากลที่ได้รับการยอมรับในการประเมินความแม่นยำของการพยากรณ์อนุกรมเวลา (Hyndman & Koehler, 2006)

4. ตรวจสอบความแม่นยำของโมเดล หลังจากที่ได้พัฒนาและฝึกโมเดล LSTM สำหรับการพยากรณ์ราคาสกุลเงินดิจิทัลแล้วทำการเปรียบเทียบค่าพยากรณ์กับค่าจริงที่เกิดขึ้นในอดีตโดยจะประเมินผลการพยากรณ์โดยใช้รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean absolute percentage error: MAPE) เพื่อวัดความแม่นยำของโมเดล

ผลการวิจัย

ในการพยากรณ์ราคาสกุลเงินดิจิทัลแต่ละชนิดโดยใช้โมเดล LSTM พร้อมการปรับค่าพารามิเตอร์หลัก ได้แก่ จำนวน LSTM Units ทดลองใช้ค่าที่เป็นได้ 4 ค่าได้แก่ 50, 60, 70 และ 80 ค่า Dropout Rate ทดลองใช้ 0.1, 0.2, 0.3 และ 0.4 และ จำนวน Dense Layers ทดลองใช้ 1 และ 2 ชั้น โดยการใช้การตรวจสอบค่าความคลาดเคลื่อนด้วย ผู้วิจัยเลือกใช้ RMSE ควบคู่กับการใช้ MAPE ซึ่งทำให้สามารถเปรียบเทียบประสิทธิภาพของโมเดลข้ามสกุลเงินดิจิทัลที่มีระดับราคาแตกต่างกันได้อย่างเป็นรูปธรรมได้ผลการเปรียบเทียบแยกตามชนิดของสกุลเงินดิจิทัล ทั้ง 3 ชนิด ดังนี้

1. การพยากรณ์ราคาสกุลเงินดิจิทัล BTC


ตารางที่ 1 ค่า RMSE ของโมเดล LSTM สำหรับการพยากรณ์ BTC

LSTM	Dropout Rate							
	0.1		0.2		0.3		0.4	
	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)
Units								
50	3,781.34	2,447.43	3,273.85	4,404.53	3,607.31	7,984.17	4,554.79	0,451.39
60	2,184.28	3,145.96	2,348.95	3,054.27	3,348.38	7,641.14	2,785.32	6,602.88
70	2,600.27	3,003.01	2,255.38	3,293.39	5,505.36	3,221.25	2,754.71	6,895.55
80	2,898.46	1,996.27	2,084.53	3,704.64	2,328.49	4,989.16	2,589.55	7,376.58

ตารางที่ 2 ค่า MAPE (%) ของโมเดล LSTM สำหรับการพยากรณ์ BTC

LSTM	Dropout Rate							
	0.1		0.2		0.3		0.4	
	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)
Units								
50	4.19	2.68	3.58	5.06	3.95	9.5	5.18	13.25
60	2.52	3.37	2.5	3.23	3.73	9.35	2.97	7.53
70	2.81	3.41	2.49	3.46	6.71	3.13	3.32	8.25
80	3.26	2.16	2.33	4.08	2.56	5.64	3.18	9.06

จากตารางที่ 1 และ 2 เมื่อพิจารณาค่าของ รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) และค่า Mean absolute percentage error เป็นผลการเปรียบเทียบประสิทธิภาพของโมเดล พบว่า ค่าพารามิเตอร์ที่เหมาะสมกับการพยากรณ์ BTC มากที่สุดคือ ค่าพารามิเตอร์ LSTM = 80, Dropout Rate = 0.1 และ Dense Layer = 2 ได้ค่า RMSE = 1,996.27 และค่า MAPE = 2.16% ซึ่งมีค่าน้อยที่สุดเมื่อเปรียบเทียบกับค่าพารามิเตอร์อื่น



ภาพที่ 1 ราคาปิดของ BTC และ การพยากรณ์กับข้อมูลทดสอบ (Testing Data 20 %) โดยใช้โมเดล LSTM ที่มีค่าพารามิเตอร์ LSTM = 80, Dropout Rate = 0.1 และ Dense Layer = 2 ได้ค่า RMSE = 1,996.27 และค่า MAPE = 2.16%

2. การพยากรณ์ราคาสกุลเงินดิจิทัล DOGE


ตารางที่ 3 ค่า RMSE ของโมเดล LSTM สำหรับการพยากรณ์ DOGE

Dropout Rate								
LSTM	0.1		0.2		0.3		0.4	
Units	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)
50	0.01544	0.01546	0.01349	0.01874	0.01375	0.01415	0.01488	0.02086
60	0.01271	0.01604	0.01338	0.01713	0.01476	0.01477	0.01506	0.01802
70	0.01575	0.01332	0.01524	0.01476	0.01517	0.01449	0.01355	0.01865
80	0.01550	0.01342	0.01482	0.01397	0.01788	0.01538	0.01356	0.01822

ตารางที่ 4 ค่า MAPE (%) ของโมเดล LSTM สำหรับการพยากรณ์ DODGE

Dropout Rate								
LSTM	0.1		0.2		0.3		0.4	
Units	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)
50	4.79	4.88	4.41	5.4	5.78	5.33	4.71	5.77
60	4.31	5.72	4.98	7.53	4.54	5.4	7.5	5.2
70	4.79	5.71	4.56	6.68	6.23	5.01	4.66	5.2
80	4.99	5.06	4.95	4.92	5.02	7.78	5	6.78

จากตารางที่ 3 และ 4 เมื่อพิจารณาค่าของ รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error : RMSE) และค่า Mean absolute percentage error เป็นผลการเปรียบเทียบประสิทธิภาพของโมเดล พบว่า ค่าพารามิเตอร์ที่เหมาะสมกับการพยากรณ์ DOGE มากที่สุดคือ ค่าพารามิเตอร์ LSTM = 60, Dropout Rate = 0.1 และ Dense Layer = 1 ได้ค่า RMSE = 0.01271 และค่า MAPE = 4.31% ซึ่งมีความน้อยที่สุดเมื่อเปรียบเทียบกับค่าพารามิเตอร์อื่น



ภาพที่ 2 ราคาปิดของ DOGE และ การพยากรณ์กับข้อมูลทดสอบ(Testing Data 20 %)

โดยใช้โมเดล LSTM ที่มีค่าพารามิเตอร์ LSTM = 60 , Dropout Rate = 0.1 และ Dense Layer = 1
ได้ค่า RMSE = 0.01271 และค่า MAPE = 4.31%

3. การพยากรณ์ราคาสกุลเงินดิจิทัล ETH


ตารางที่ 5 ค่า RMSE ของโมเดล LSTM สำหรับการพยากรณ์ ETH

LSTM	Dropout Rate							
	0.1		0.2		0.3		0.4	
Units	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)
50	122.74	234.36	156.26	160.43	137.67	201.97	146.59	180.35
60	134.16	127.75	127.87	172.00	136.73	217.21	148.12	346.98
70	163.37	171.12	132.69	130.70	129.70	185.19	133.60	142.28
80	121.60	119.97	150.69	164.29	135.24	130.85	176.01	212.35

ตารางที่ 6 ค่า MAPE (%) ของโมเดล LSTM สำหรับการพยากรณ์ ETH

Dropout Rate								
LSTM	0.1		0.2		0.3		0.4	
Units	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)	Dense(1)	Dense(2)
50	2.94	6.6	3.92	4.04	3.34	5.1	3.56	4.51
60	3.33	3.05	3.04	4.49	3.37	5.78	3.66	9.81
70	4.43	4.49	3.26	3.22	3.10	4.65	3.20	3.52
80	2.97	2.86	3.82	4.36	3.29	3.15	4.52	5.70

จากตารางที่ 5 และ 6 เมื่อพิจารณาค่าของ รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error : RMSE) และค่า Mean Absolute Percentage Error เป็นผลการเปรียบเทียบประสิทธิภาพของโมเดล พบว่า ค่าพารามิเตอร์ที่เหมาะสมกับการพยากรณ์ ETH มากที่สุดคือ ค่าพารามิเตอร์ LSTM = 80, Dropout Rate = 0.1 และ Dense Layer = 2 ได้ค่า RMSE = 119.97 และค่า MAPE = 2.86% ซึ่งมีค่าน้อยที่สุดเมื่อเปรียบเทียบกับค่าพารามิเตอร์อื่น



ภาพที่ 3 ราคาปิดของ ETH และ การพยากรณ์กับข้อมูลทดสอบ (Testing Data 20 %) โดยใช้โมเดล LSTM ที่มีค่าพารามิเตอร์ LSTM = 80, Dropout Rate = 0.1 และ Dense Layer = 2 ได้ค่า RMSE = 119.97 และค่า MAPE = 2.86%

การอภิปรายผล

BTC และ ETH เป็นสกุลเงินหลักที่มีมูลค่าตลาดสูงสุดและมีระบบนิเวศขนาดใหญ่ (Ecosystem) การเคลื่อนไหวของราคาจึงได้รับอิทธิพลจากปัจจัยด้านเศรษฐกิจและด้านอื่นๆที่ซับซ้อน การที่โมเดลต้องการ LSTM units สูงถึง 80 หน่วย สะท้อนให้เห็นว่าข้อมูลอนุกรมเวลาของทั้งสองเหรียญนี้มีความสัมพันธ์ระยะยาว (Long-term dependencies) ที่ซับซ้อนและลึกซึ้ง ซึ่งต้องการหน่วยความจำขนาดใหญ่ในการจับรูปแบบ (Pattern) นอกจากนี้ การใช้ Dense layer = 2 ยังช่วยให้ตัวแบบมีความสามารถในการเรียนรู้คุณลักษณะแบบไม่เป็นเส้นตรง (Non-linear mapping) ได้ดีขึ้น ส่งผลให้โมเดลสามารถรับมือกับช่วงที่ราคามีความผันผวนสูง ดังแสดงจากค่า RMSE ที่ต่ำที่สุดเมื่อเทียบกับพารามิเตอร์อื่น และรักษาระดับเปอร์เซ็นต์ความคลาดเคลื่อนโดยเฉลี่ยให้อยู่ในระดับต่ำ ได้อย่างสม่ำเสมอ การใช้ Dropout rate = 0.1 แสดงให้เห็นว่าการใช้หน่วยความจำสูงในกรณีนี้ไม่ทำให้เกิดภาวะเรียนรู้เกินจริง (Overfitting)

ในส่วนของ DODGE แตกต่างจากสกุลเงินหลักอย่าง BTC และ ETH พฤติกรรมราคาของเหรียญทางเลือกอย่าง DOGE มักขับเคลื่อนด้วยกระแสข่าวและความเชื่อมั่นเชิงอารมณ์ (Sentiment-driven) ในระยะสั้นมากกว่า โครงสร้างตัวแบบที่เหมาะสมที่สุดจึงต้องการความซับซ้อนน้อยกว่า ทั้งในแง่ของขนาดหน่วยความจำ (LSTM units = 60) และชั้นประมวลผลปลายทาง (Dense layer = 1) การใช้โมเดลที่เล็กลงช่วยป้องกันไม่ให้เกิดตัวแบบพยายามจดจำสัญญาณรบกวน (Noise) ที่เกิดจากการแก่งกำไรรอยางไรทิศทาง ซึ่งอาจนำไปสู่ภาวะ Overfitting แม้ความคลาดเคลื่อนโดยเฉลี่ยของ DOGE จะสูงกว่าสกุลเงินหลักเล็กน้อย (MAPE = 4.31%) แต่ก็ถือว่าอยู่ในเกณฑ์ที่รับได้สำหรับสินทรัพย์ที่มีราคาและเสถียรภาพต่ำ

บทสรุปและข้อเสนอแนะ

การพิจารณาเลือกรูปแบบพารามิเตอร์โดยอิงจากทั้งค่า RMSE และ MAPE ในการศึกษาครั้งนี้ แสดงให้เห็นถึง "ความทนทาน (Robustness)" ของตัวแบบ การที่พารามิเตอร์ชุดเดียวกันสามารถทำให้เกิดจุดต่ำสุด (Global minimum) ทั้งในตัวของตัววัดที่ไวต่อค่าผิดปกติอย่างรุนแรง (RMSE) และตัววัดที่สะท้อนสัดส่วนความคลาดเคลื่อนเชิงสัมพัทธ์ (MAPE) แสดงให้เห็นว่า ตัวแบบ LSTM ที่ศึกษาในครั้งนี้มีขีดความสามารถในการวางนัยทั่วไป (Generalization) ได้ดีในระดับหนึ่ง โดยไม่เอนเอียงไปจดจำเฉพาะช่วงเวลาที่มีราคาสูงหรือต่ำจนเกินไป

นอกจากนี้พบว่า ในการพยากรณ์สินทรัพย์ดิจิทัล ไม่มีการตั้งค่าตัวแบบใดที่สามารถใช้ได้ครอบจักรวาล (No free lunch theorem) การพัฒนาตัวแบบพยากรณ์จำเป็นต้องคำนึงถึงพฤติกรรมความผันผวนเฉพาะตัวของแต่ละสินทรัพย์เสมอ ซึ่งผลลัพธ์ที่ได้นี้สอดคล้องกับการศึกษาของ ปิยธิดา รุ่งเรือง (2565) ที่ระบุว่าตัวแบบ LSTM สามารถประยุกต์ใช้เพื่อวิเคราะห์ทิศทางของสกุลเงินดิจิทัลที่มีคุณลักษณะหลากหลายได้อย่างมีประสิทธิภาพ หากได้รับการปรับแต่งโครงสร้างพารามิเตอร์ให้สอดคล้องกับพลวัตของเหรียญนั้นๆ อย่างเหมาะสม

ข้อเสนอแนะ

1. การทดลองโมเดลอื่นเพื่อเปรียบเทียบควรศึกษาและเปรียบเทียบประสิทธิภาพของโมเดลอื่น ๆ เช่น GRU (Gated recurrent unit) หรือ Transformer ซึ่งอาจมีศักยภาพที่ดีกว่าในบางกรณี เพื่อค้นหาโมเดลที่เหมาะสมที่สุดสำหรับการพยากรณ์ราคาสกุลเงินดิจิทัล
2. การใช้ข้อมูลที่หลากหลายการขยายขอบเขตการศึกษาโดยใช้ข้อมูลจากสกุลเงินดิจิทัลอื่น ๆ นอกเหนือจาก Bitcoin, Dogecoin และ Ethereum อาจช่วยเพิ่มความครอบคลุมของงานวิจัย และสามารถประเมินว่าโมเดลสามารถปรับตัวให้เหมาะสมกับข้อมูลที่หลากหลายได้มากน้อยเพียงใด
3. การปรับปรุงความถี่ของข้อมูลการใช้ข้อมูลที่มีความถี่สูงขึ้น เช่น ราคาทุกชั่วโมงหรือทุกนาที อาจช่วยให้โมเดลสามารถตรวจจับความเปลี่ยนแปลงในระยะสั้นได้ดีขึ้น โดยเฉพาะในตลาดที่มีการซื้อขายอย่างต่อเนื่อง

เอกสารอ้างอิง

- ณัฐชา เพียรดี. (2552). *การพัฒนาโครงข่ายประสาทเทียมสำหรับพยากรณ์การผลิต*. (วิทยานิพนธ์ปริญญา มหาบัณฑิต, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ).
- ณัฐพล จิตะวีระ. (2563). *การศึกษารูปแบบการพยากรณ์ราคาหลักทรัพย์โดยใช้แบบจำลองการเรียนรู้เชิงลึก*. (การค้นคว้าอิสระปริญญามหาบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย).
- ธีรภาพ แสงศรี, เทวา พรหมนุชานนท์, และ รุจิพันธุ์ โกษารัตน์. (2567). การวิเคราะห์เปรียบเทียบโมเดล ARIMA และ LSTM สำหรับพยากรณ์ราคาบิตคอยน์: การประยุกต์ใช้เครื่องมือเรียนรู้ของเครื่อง. *Journal of Information Science Research and Practice*, 12(2), 95-107. <https://so03.tci-thaijo.org/index.php/jiskku/article/view/277726>
- นิติกร จันทาญ. (2564). *การพยากรณ์ราคาบิตคอยน์ด้วยเทคนิคการเรียนรู้ของเครื่อง*. (วิทยานิพนธ์ปริญญา มหาบัณฑิต, มหาวิทยาลัยมหาสารคาม). <http://202.28.34.124/dspace/bitstream/123456789/2412/1/62011284507.pdf>
- ปิยธิดา รุ่งเรือง. (2565). *การพยากรณ์ราคาสกุลเงินดิจิทัลและการจัดพอร์ตการลงทุนโดยใช้อัลกอริทึมเวลาพีซี นิวโทรโซฟิควแบบลึงเลที่มีค่าเดียวร่วมกับโมเดล LSTM*. (วิทยานิพนธ์มหาบัณฑิต, บัณฑิตวิทยาลัย, มหาวิทยาลัยเชียงใหม่).
- พชร พงษ์สิทธิศักดิ์. (2563). *การศึกษาเปรียบเทียบการพยากรณ์ความผันผวนและราคาหลักทรัพย์ ดัชนี SET50 ระหว่างตัวแบบทางเศรษฐมิติและอัลกอริทึมแอลเอสทีเอ็ม (LSTM)*. (วิทยานิพนธ์ปริญญา มหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์).
- วิศรุต เลิศทวีเดช. (2564). *การผสมผสานการวิเคราะห์เชิงเทคนิคและแบบจำลองการเรียนรู้เชิงลึกสำหรับการซื้อขายน้ำมันดิบ*. (วิทยานิพนธ์ปริญญามหาบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย). <https://digital.car.chula.ac.th/chulaetd/5398/>

- อุทิศ พงศ์จิรวัฒนา, อนุพงศ์ สุขประเสริฐ, นันทิมา แพงทรัพย์ และ มะลิวัลย์ สารภาพ. (2566). การพยากรณ์ราคาคริปโตเคอร์เรนซีล่วงหน้าด้วยแบบจำลอง ARIMA. *วารสารวิทยาการจัดการ มหาวิทยาลัยราชภัฏอุดรธานี*, 5(4), 1–11. <https://so08.tci-thaijo.org/index.php/MSJournal/article/view/2343>
- Cibikdiken, A. O., & Karakoyun, E. S. (2018). Comparison of ARIMA time series model and LSTM deep learning algorithm for Bitcoin price forecasting. *In Proceedings of the 13th Multidisciplinary Academic Conference*, Prague, Czech Republic.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Mehtab, S., Sen, J., & Dutta, A. (2020). *Stock price prediction using machine learning and LSTM-based deep learning models*. <https://arxiv.org/pdf/2009.10819>
- Olah, C. (2015). *Understanding LSTMs Networks*. Colah's Blog. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>