

Deep Learning to Enhance the Accuracy and Lag-time of Time Series Data Forecasting

Napatr Chongkol^{1,*} and Tanun Jaruvitayakovit²

^{1,2}Department of Computer Engineering, College of Engineering and Technology,
Dhurakij Pundit University, Bangkok 10210, Thailand; Email: ¹67130350@dpu.ac.th, ²tanun.jar@dpu.ac.th

**Corresponding author:* Napatr Chongkol (67130350@dpu.ac.th)

Received: 27 March 2026; **Revised:** 2 June 2026; **Accepted:** 6 June 2026; **Published:** 24 August 2026

Abstract

Time series forecasting is crucial in the present, applied in areas such as weather forecasting, finance, and beyond. Gold price forecasting is highly complex due to significant influences from economic factors. Although current studies have explored gold price forecasting using deep learning models, issues of prediction lag persist, affecting the accuracy of directional forecasts. To address this problem, this research focuses on developing a gold price time series forecasting model with improved accuracy and reduced prediction lag. This is achieved by combining the strengths of the LSTM (Long Short-Term Memory) model, which excels at learning long-term dependencies in data, and the CNN (Convolutional Neural Network) model, which efficiently extracts spatial features from data. Additionally, a data grouping method based on price trend characteristics is employed, allowing the model to learn specific patterns of each trend type appropriately. This reduces lag caused by delayed responses to actual data changes and enhances the accuracy of gold price forecasts in both numerical value and directional movement. Consequently, the model demonstrates strong potential for effective application in real-world financial trading decisions. This study uses gold price data from January 2014 to July 2025, totaling 2,943 days. Price trends are classified into three groups uptrend, sideways and downtrend. Four models are trained, which are LSTM, CNN, LSTM_G3, and CNN_G3. The most suitable model for each group is then selected to create the LSTM+CNN_G3 model. The results show that the LSTM+CNN_G3 model achieves the lowest overall MAE (Mean Absolute Error) at 17.68 US dollars and the highest overall MPM (Movement Prediction Metric) at 54.08%, outperforming the baseline LSTM and CNN models that do not use data grouping. This demonstrates that the grouping method effectively reduces prediction lag. In a gold trading simulation, the LSTM+CNN_G3 model yields the highest profit of 1,870 US dollars, representing a 101.87% return on capital. These findings indicate that grouping data by price trends combined with selecting appropriate architectures can improve accuracy and reduce lag, enabling the model to be effectively applied in real-world financial markets.

Keywords: Time Series Forecasting, Gold Price, LSTM, CNN, Trend-Based Data Grouping



Copyright © 2026 Journal of Computer and Creative Technology. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC-ND).

Citation:

Chongkol, N., & Jaruvitayakovit, T. (2026). Deep Learning to Enhance the Accuracy and Lag-time of Time Series Data Forecasting. *Journal of Computer and Creative Technology*, 4(2), e3550. <https://doi.org/10.65205/jcct.2026.e3550>

การเรียนรู้เชิงลึกเพื่อเพิ่มความแม่นยำและลดเวลาหน่วงของการพยากรณ์ข้อมูลอนุกรมเวลา

ณภัทร จงกล^{1,*} และ ธนัญ จารุวิทย์โกวิท²

^{1,2}สาขาวิชาวิศวกรรมคอมพิวเตอร์ วิทยาลัยวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยธุรกิจบัณฑิตย์
จังหวัดกรุงเทพมหานคร 10210 ประเทศไทย; Email: ¹67130350@dpu.ac.th, ²tanun.jar@dpu.ac.th

*ผู้ประพันธ์บทความ: ณภัทร จงกล (67130350@dpu.ac.th)

รับบทความ: 27 มีนาคม 2569; แก้ไขบทความ: 2 มิถุนายน 2569; ตอรับบทความ: 6 มิถุนายน 2569;
เผยแพร่บทความ: 24 สิงหาคม 2569

บทคัดย่อ

การพยากรณ์อนุกรมเวลาเป็นสิ่งสำคัญในยุคปัจจุบัน ทั้งในด้านการพยากรณ์อากาศ การเงิน และอื่น ๆ โดยเฉพาะการพยากรณ์ราคาทองคำที่มีความซับซ้อนสูงเนื่องจากได้รับอิทธิพลจากปัจจัยทางเศรษฐกิจอย่างมาก แม้ว่าในปัจจุบันจะมีการศึกษาเกี่ยวกับวิธีการพยากรณ์ราคาทองคำโดยใช้แบบจำลองเชิงลึก แต่ยังคงพบปัญหาความล่าช้าในการพยากรณ์ซึ่งส่งผลกระทบต่อความแม่นยำของทิศทางที่พยากรณ์ได้ เพื่อแก้ปัญหาดังกล่าว งานวิจัยนี้จึงมุ่งเน้นการพัฒนาแบบจำลองพยากรณ์อนุกรมเวลาราคาทองคำให้มีความแม่นยำมากขึ้นและลดปัญหาความล่าช้าในการพยากรณ์ โดยอาศัยการผสมผสานจุดเด่นระหว่างโมเดล LSTM (Long Short-Term Memory) ที่มีความสามารถในการเรียนรู้การพึ่งพาระยะยาวของข้อมูล และโมเดล CNN (Convolutional Neural Network) ที่มีความสามารถในการสกัดคุณลักษณะเชิงพื้นที่จากข้อมูลได้อย่างมีประสิทธิภาพ ประกอบกับวิธีการแบ่งกลุ่มข้อมูลตามลักษณะของแนวโน้มราคา ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบเฉพาะของแนวโน้มแต่ละประเภทได้อย่างเหมาะสม ลดปัญหาความล่าช้าที่เกิดจากการตอบสนองต่อการเปลี่ยนแปลงของข้อมูลจริงที่ไม่ทันการณ์ และเพิ่มความแม่นยำในการพยากรณ์ราคาทองคำทั้งในด้านตัวเลขและทิศทาง ซึ่งส่งผลให้แบบจำลองมีศักยภาพในการนำไปประยุกต์ใช้ในการตัดสินใจซื้อขายในตลาดการเงินจริงได้อย่างมีประสิทธิภาพ งานวิจัยนี้ใช้ข้อมูลราคาทองคำตั้งแต่เดือนมกราคม พ.ศ. 2557 ถึงกรกฎาคม พ.ศ. 2568 รวม 2,943 วัน โดยจำแนกแนวโน้มราคาออกเป็น 3 กลุ่ม ได้แก่ ขาขึ้น, ทรงตัว, และขาลง จากนั้นฝึกแบบจำลอง 4 รูปแบบ ได้แก่ LSTM, CNN, LSTM_G3 และ CNN_G3 แล้วเลือกแบบจำลองที่เหมาะสมในแต่ละกลุ่มสร้างเป็นแบบจำลอง LSTM+CNN_G3 ผลการวิจัยพบว่าแบบจำลอง LSTM+CNN_G3 ให้ค่า MAE (Mean Absolute Error) รวมต่ำที่สุดที่ 17.68 ดอลลาร์สหรัฐ และค่า MPM (Movement Prediction Metric) รวมสูงที่สุดที่ 54.08% ซึ่งดีกว่าแบบจำลอง LSTM และ CNN ที่ไม่ได้แบ่งกลุ่มและเป็นโมเดลพื้นฐานของการทำนายข้อมูลอนุกรมเวลา แสดงให้เห็นว่าวิธีการแบ่งกลุ่มช่วยลดปัญหาความล่าช้าได้อย่างมีประสิทธิภาพ และเมื่อจำลองการซื้อขายทองคำด้วยแบบจำลอง LSTM+CNN_G3 ให้กำไรสูงสุดที่ 1,870 ดอลลาร์สหรัฐ คิดเป็น 101.87% ของเงินทุน แสดงให้เห็นว่าการแบ่งกลุ่มข้อมูลตามแนวโน้มราคาร่วมกับการเลือกใช้สถาปัตยกรรมที่เหมาะสมสามารถเพิ่มความแม่นยำและลดปัญหาความล่าช้าได้ ส่งผลให้แบบจำลองมีศักยภาพในการนำไปประยุกต์ใช้จริงในตลาดการเงินได้อย่างมีประสิทธิภาพ

คำสำคัญ: การพยากรณ์อนุกรมเวลา, ราคาทองคำ, แอลเอสทีเอ็ม, ซีเอ็นเอ็น, การแบ่งกลุ่มข้อมูลตามแนวโน้ม



Copyright © 2026 Journal of Computer and Creative Technology. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC-ND).

การอ้างอิง:

ณภัทร จงกล, และ ธนัญ จารุวิทย์โกวิท. (2569). การเรียนรู้เชิงลึกเพื่อเพิ่มความแม่นยำและลดเวลาหน่วงของการพยากรณ์ข้อมูลอนุกรมเวลา. วารสารคอมพิวเตอร์และเทคโนโลยีสร้างสรรค์, 4(2), e3550. <https://doi.org/10.65205/jcct.2026.e3550>

1. บทนำ (Introduction)

ในยุคปัจจุบัน ข้อมูลอนุกรมเวลาถูกสร้างและรวบรวมไว้ในปริมาณมหาศาลและหลากหลายรูปแบบจากแหล่งต่าง ๆ เช่น ข้อมูลการซื้อขายทางการเงินในตลาดหุ้นและตลาดอนุพันธ์ ข้อมูลเซ็นเซอร์จากอุปกรณ์ IoT ข้อมูลการใช้งานบนโลกออนไลน์และโซเชียลมีเดีย ข้อมูลสภาพอากาศจากสถานีตรวจวัดอัตโนมัติ ตลอดจนข้อมูลการขนส่งและโลจิสติกส์ ความก้าวหน้าทางเทคโนโลยีโดยเฉพาะด้านปัญญาประดิษฐ์ออกแบบวิธีการใหม่ในการทำความเข้าใจ พยากรณ์ และตัดสินใจจากข้อมูลอนุกรมเวลาเหล่านี้ได้อย่างแม่นยำมากขึ้น

การพยากรณ์ราคาทองคำ ซึ่งเป็นสินทรัพย์ปลอดภัยและตัวบ่งชี้เศรษฐกิจที่สำคัญเป็นหนึ่งในกรณีศึกษาที่ท้าทาย เนื่องจากราคาถูกขับเคลื่อนโดยปัจจัยทางเศรษฐกิจมหภาคที่ซับซ้อนเช่น อัตราเงินเฟ้อ อัตราดอกเบี้ย ค่าเงินดอลลาร์สหรัฐ และภาวะความตึงเครียดทางภูมิรัฐศาสตร์ (TP & Sultana, 2024) ซึ่งส่งผลให้ราคาทองคำมีความผันผวนที่สูงและยากต่อการทำนาย การเรียนรู้เชิงลึกได้พัฒนาวิธีการพยากรณ์อนุกรมเวลาและสร้างโมเดลที่มีความสามารถในการเรียนรู้คุณลักษณะที่ซับซ้อนจากข้อมูลปริมาณมากได้โดยอัตโนมัติ แนวคิดพื้นฐานเริ่มต้นจาก RNN (Recurrent Neural Network) ซึ่งมีโครงสร้างที่ออกแบบมาเพื่อประมวลผลข้อมูลเชิงลำดับโดยเฉพาะ เนื่องจากมีหน่วยความจำภายในที่บันทึกบริบทจากขั้นเวลาก่อนหน้า LSTM ได้ถูกพัฒนาขึ้นจากโมเดล RNN โดยมีโครงสร้างเกทที่ซับซ้อนซึ่งช่วยควบคุมการไหลของข้อมูล ทำให้สามารถจดจำและเรียนรู้ระยะยาวในลำดับข้อมูลได้อย่างมีประสิทธิภาพ เช่น แนวโน้ม และวัฏจักรนอกเหนือจากสถาปัตยกรรมที่เชี่ยวชาญด้านลำดับแล้ว CNN ซึ่งมีความสามารถด้านการประมวลผลภาพยังสามารถแสดงประสิทธิภาพในการทำนายอนุกรมเวลา เนื่องจากสามารถสกัดคุณลักษณะเชิงพื้นที่จากข้อมูลได้อย่างมีประสิทธิภาพผ่านการดำเนินการ Convolution

ปัจจุบันโมเดลพยากรณ์ในกลุ่ม RNN ที่นิยมใช้ในการพยากรณ์อนุกรมเวลายังมี ปัญหาความล่าช้า (Lagging Problem) เนื่องจากโมเดลเกิดการตอบสนองช้ากับการเปลี่ยนแปลงของข้อมูลจริง (Li et al., 2023) โดยส่วนใหญ่มักเกิดที่จุดกลับตัวหรือจุดที่ข้อมูลมีความผันผวนมาก ซึ่งปัญหานี้ส่งผลกระทบต่อตรงต่อการพยากรณ์ทิศทางโดยเฉพาะการกับประยุกต์อนุกรมเวลาที่ต้องใช้ทิศทางในการตัดสินใจ เช่น ราคาทอง

งานวิจัยนี้จึงนำเสนอการผสมผสานจุดเด่นระหว่างโมเดลในกลุ่ม RNN ที่นิยมใช้ในปัจจุบันอย่าง LSTM ควบคู่กับโมเดล CNN และวิธีการแบ่งกลุ่มตามแนวโน้มข้อมูลเพื่อลดปัญหาดังกล่าวและเพิ่มความแม่นยำให้กับการพยากรณ์ เนื่องจากโมเดล CNN ที่นำมาประยุกต์ใช้กับอนุกรมเวลามีความสามารถด้านการสกัดคุณลักษณะเชิงพื้นที่ ซึ่งส่งผลให้ติดตามความผันผวนของข้อมูลได้ทัน และการแบ่งกลุ่มข้อมูลตามแนวโน้มช่วยให้โมเดลสามารถพยากรณ์ทิศทางทางได้แม่นยำมากขึ้น โดยอนุกรมเวลาที่งานวิจัยนี้เลือกใช้คือ ราคาทองคำ ซึ่งเป็นอนุกรมเวลาที่มีความผันผวนสูง เหมาะสำหรับการวัดประสิทธิภาพของโมเดลผ่านการจำลองการเทรด หรือการทดสอบกับข้อมูลจริงในตลาด

2. วัตถุประสงค์งานวิจัย (Research Objectives)

1. เพื่อเปรียบเทียบประสิทธิภาพของโมเดล LSTM และ CNN สำหรับการพยากรณ์อนุกรมเวลาราคาทองคำ โดยใช้ค่า MAE วัดความคลาดเคลื่อนเชิงปริมาณ และใช้ค่า MPM วัดความถูกต้องของทิศทางที่โมเดลพยากรณ์ได้
2. เพื่อนำเสนอวิธีการลดปัญหาความล่าช้าในการทำนายของโมเดล LSTM และ CNN โดยการแบ่งกลุ่มข้อมูลตามแนวโน้มราคา และเลือกใช้โมเดลที่เหมาะสมในแต่ละกลุ่มในการสร้างโมเดล LSTM+CNN_G3 เพื่อเปรียบเทียบกับโมเดลที่นิยมใช้ในปัจจุบันอย่าง LSTM
3. เพื่อประเมินศักยภาพของโมเดลที่พัฒนาขึ้นในการจำลองการซื้อขายทองคำจริงและเปรียบเทียบกับโมเดล LSTM, CNN และกลยุทธ์ซื้อและถือ (Buy-and-Hold)

3. การทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง (Literature Review)

3.1 การพยากรณ์อนุกรมเวลา

อนุกรมเวลาคือลำดับของข้อมูลที่ถูกจัดเรียงตามช่วงเวลาที่เหมาะสม ๆ กัน เช่น รายชั่วโมง รายวัน รายเดือน หรือรายปี ซึ่งการพยากรณ์อนุกรมเวลาเป็นกระบวนการทำนายค่าในอนาคตโดยอาศัยข้อมูลในอดีตและปัจจุบัน ซึ่งตั้งอยู่บนสมมติฐาน

ที่ว่าค่าในอนาคตของอนุกรมเวลาสามารถประมาณได้จากค่าในอดีต การพยากรณ์อนุกรมเวลาถือเป็นเครื่องมือวิเคราะห์ที่สำคัญในหลากหลายสาขา เช่น การเงิน เศรษฐศาสตร์ การตลาด วิทยาศาสตร์สิ่งแวดล้อม และการจัดการโลจิสติกส์

การพยากรณ์อนุกรมเวลามีองค์ประกอบสำคัญของอนุกรมเวลาประกอบด้วย 3 ส่วนหลัก (Das & Barman, 2025) ได้แก่ แนวโน้ม คือการเคลื่อนที่ของข้อมูลในระยะยาวที่แสดงทิศทางของการเพิ่มขึ้น ลดลง หรือคงที่ ซึ่งอาจเป็นได้ทั้งแบบเชิงเส้นและไม่เชิงเส้น, ฤดูกาล คือรูปแบบที่เกิดขึ้นซ้ำ ๆ เป็นช่วงวงจรตามเวลาที่กำหนด และความสุ่ม คือความผันผวนที่ไม่สามารถคาดเดาได้ซึ่งเกิดจากปัจจัยภายนอกหรือความคลาดเคลื่อนในการวัด

3.2 การเรียนรู้เชิงลึก (Deep learning)

การเรียนรู้เชิงลึก เป็นสาขาหนึ่งของการเรียนรู้ของเครื่องที่มีการสร้างและฝึกฝนโครงข่ายประสาทเทียมหลายชั้น เพื่อเรียนรู้รูปแบบและคุณลักษณะที่ซับซ้อนจากข้อมูลปริมาณมาก ในปัจจุบันการเรียนรู้เชิงลึกได้มีการนำมาประยุกต์กับการพยากรณ์อนุกรมเวลา (Giantsidi & Tarantola, 2025) โดยสามารถเอาชนะวิธีการทางสถิติแบบดั้งเดิมในการพยากรณ์ที่ไม่เป็นเชิงเส้นและการพึ่งพาระยะยาวของข้อมูล โดยการเรียนรู้เชิงลึกมีหลายประเภท เช่น Long Short-Term Memory (LSTM) ซึ่งมีความสามารถในการพยากรณ์อนุกรมเวลา และ Convolutional Neural Network (CNN) เป็นต้น

3.3 โมเดล Long Short-Term Memory (LSTM)

โมเดล Long Short-Term Memory (LSTM) เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมประเภทหนึ่งที่ได้รับการออกแบบมาเพื่อแก้ปัญหาข้อบกพร่องของ Recurrent Neural Networks (RNN) แบบดั้งเดิม (Chen et al., 2024) โดยเฉพาะในเรื่องของการเรียนรู้การพึ่งพาระยะยาวของข้อมูล โมเดล LSTM มีกลไกพิเศษที่เรียกว่า gate ซึ่งประกอบด้วย forget gate, input gate, และ output gate ที่ทำหน้าที่ควบคุมการไหลเวียนของข้อมูล กลไกนี้ทำให้โมเดลสามารถเลือกที่จะจดจำหรือลืมข้อมูลในอดีตได้อย่างเหมาะสม ด้วยคุณสมบัตินี้โมเดล LSTM จึงเป็นที่นิยมอย่างแพร่หลายในการทำนายข้อมูลอนุกรมเวลาทางการเงินรวมถึงการทำนายราคาทองคำ




Figure 1. Long Short-Term Memory (LSTM)

Source: Widiputra et al. (2021)

3.4 โมเดล Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) เป็นที่รู้จักและมีความสามารถในการงานด้านการประมวลผลภาพ แต่ในปัจจุบันได้มีงานวิจัยที่นำโมเดล CNN มาประยุกต์ใช้กับงานอนุกรมเวลาอย่างแพร่หลายเนื่องจากโมเดล CNN สามารถใช้ในการสกัดคุณลักษณะที่สำคัญจากข้อมูลอนุกรมเวลาได้เป็นอย่างดี (Chen & Fan, 2025) เช่น ความผันผวนของราคาในระยะสั้น หรือการเกิดรูปแบบกราฟแท่งเทียนที่สำคัญโดยใช้ Convolution Kernels เลื่อนไปตามลำดับเวลา




Figure 2. Convolutional Neural Network (CNN)

Source: Ortu et al. (2022)

3.5 มาตรฐานประสิทธิภาพการพยากรณ์

Mean Absolute Error (MAE) เป็นมาตรวัดความแม่นยำที่นิยมใช้ในการประเมินโมเดลการพยากรณ์เชิงปริมาณ โดยข้อดีของ MAE คือมีความหมายที่เข้าใจง่ายโดยมีหน่วยเดียวกับข้อมูลต้นฉบับและไม่ไวต่อค่าผิดปกติ โดย MAE คำนวณจากค่าเฉลี่ยของค่าสัมบูรณ์ของความแตกต่างระหว่างค่าจริงกับค่าพยากรณ์ ดังสมการ (1)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Movement Prediction Metric (MPM) เป็นมาตรวัดที่เสนอโดย Samanta et al. (2020) เพื่อประเมินความแม่นยำในการพยากรณ์ทิศทางของการเปลี่ยนแปลงข้อมูล ซึ่งสัมพันธ์โดยตรงกับปัญหาความล่าช้าในการพยากรณ์อนุกรมเวลา คำนวณได้จากสมการ (2)

$$MPM = \frac{TU+TD}{TU+FU+TD+FD} \quad (2)$$

โดย TU แทนปริมาณการทำนายทิศทางขึ้นที่ถูกต้อง, TD แทนปริมาณการทำนายทิศทางลงที่ถูกต้อง, FU แทนปริมาณการทำนายขึ้นที่ผิดพลาด และ FD แทนปริมาณการทำนายลงที่ผิดพลาด

3.6 งานวิจัยที่เกี่ยวข้อง

งานวิจัยของ Lin et al. (2021) เสนอโมเดลแบบใหม่ในการพยากรณ์ทิศทางราคาหุ้นโดยการรวมเทคนิคการวิเคราะห์แผนภูมิแท่งเทียนเข้ากับการเรียนรู้ของเครื่องแบบรวมกลุ่มโดยขั้นแรกจะจำแนกรูปแบบแท่งเทียนจากข้อมูลราคาออกเป็น 13 รูปแบบ จากนั้นฝึกฝนโมเดลการเรียนรู้ 6 ชนิดได้แก่ LR, SVM, KNN, RF, GBDT และ LSTM ทดสอบแยกกันสำหรับแต่ละกลุ่ม เพื่อเลือกโมเดลที่เหมาะสมที่สุดสำหรับรูปแบบราคาแต่ละประเภท และมีการปรับปรุงประสิทธิภาพด้วยการเพิ่มตัวชี้วัดทางเทคนิค 4 กลุ่ม ผลการทดลองกับข้อมูลหุ้นจีนจำนวนมากพบว่า ประสิทธิภาพการทำนายจะมีค่าเพิ่มขึ้นเมื่อมีการแบ่งกลุ่มและเลือกใช้โมเดลที่เหมาะสม

งานวิจัยของ Mehtab et al. (2020) เปรียบเทียบโมเดลสำหรับพยากรณ์ราคาหุ้น โดยใช้ข้อมูลราคาหุ้นราย 5 นาทีของบริษัท Bharat Forge ในตลาดหลักทรัพย์แห่งประเทศไทย โดยใช้โมเดลทั้งหมด 7 แบบ แบ่งเป็นโมเดล CNN จำนวน 3 แบบ และโมเดล LSTM จำนวน 4 แบบ ซึ่งมีทั้งแบบใช้ข้อมูลตัวแปรเดียวและหลายตัวแปร โดยผลการวิจัยพบว่า โมเดล CNN ที่ใช้ข้อมูลตัวแปรเดียวของสองสัปดาห์ก่อนหน้ามีความแม่นยำสูงสุด ขณะที่โมเดล CNN ที่ใช้ข้อมูลข้อมูลตัว

แปรเดียวหนึ่งสัปดาห์ก่อนหน้านี้มีความเร็วในการประมวลผลสูงที่สุด ซึ่งแสดงให้เห็นว่าโมเดลกลุ่ม CNN มีประสิทธิภาพโดยรวมดีกว่าโมเดล LSTM ทั้งในด้านความแม่นยำและความเร็วในการประมวลผล

ผลการศึกษาของ Li et al. (2023) ชี้ให้เห็นว่าการพยากรณ์อนุกรมเวลาทางการเงินด้วย Recurrent Network Model (RNN, LSTM, GRU) มักเผชิญกับปัญหาการล่าช้า โดยเฉพาะอย่างยิ่งในช่วงที่แนวโน้มของข้อมูลเกิดการกลับตัว ซึ่งส่งผลให้ค่าพยากรณ์มีลักษณะใกล้เคียงกับค่าอินพุตในอดีตมากกว่าค่าจริง แม้ว่าการปรับปรุงโมเดลด้วยเทคนิคต่าง ๆ เช่น การใช้ข้อมูลหลายตัวแปร (Multivariate) หรือการแยกส่วนข้อมูล (EMD) จะสามารถบรรเทาปัญหาการล่าช้าได้บางส่วน ซึ่งแสดงให้เห็นว่าโมเดลพื้นฐานอาจจัดการกับปัญหานี้ได้ไม่มากพอ และการพยายามลดความคลาดเคลื่อนเพียงอย่างเดียวอาจไม่เพียงพอ หากไม่ได้พิจารณาปัญหาการล่าช้าของแนวโน้มซึ่งส่งผลต่อทิศทางควบคู่ไปด้วย

งานวิจัยของ Samanta et al. (2020) เสนอเมตริกใหม่ชื่อ Movement Prediction Metric (MPM) เพื่อประเมินความแม่นยำในการพยากรณ์ทิศทางการเปลี่ยนแปลงของข้อมูล ซึ่งสัมพันธ์โดยตรงกับปัญหาการล่าช้า และเสนอวิธีแก้ปัญหาล่าช้าโดยวิธี Dual Network Solution ผลการทดลองกับข้อมูลความเร็วลมและราคาหุ้น Amazon พบว่าโมเดล DNS ให้ค่า Mean Squared Error (MSE) ต่ำที่สุดเมื่อเปรียบเทียบกับวิธีอื่น และให้ค่า MPM สูงขึ้น ซึ่งบ่งชี้ว่าสามารถลดปัญหาการล่าช้าได้อย่างมีประสิทธิภาพ

จากงานวิจัยข้างต้นยังไม่มีงานวิจัยใดที่สามารถแก้ปัญหาล่าช้าของโมเดล LSTM แม้ว่างานวิจัยของ Li et al. (2023) จะมีการปรับปรุงโมเดลด้วยเทคนิคต่าง ๆ แต่ยังมีปัญหาล่าช้าเกิดขึ้น และยังไม่มียานวิจัยใดที่นำการแบ่งกลุ่มข้อมูลตามแนวโน้มของข้อมูลมาประยุกต์ใช้ร่วมกับโมเดล CNN ดังนั้นงานวิจัยนี้จึงได้นำแนวคิดจากงานวิจัยต่าง ๆ มาต่อยอด โดย Lin et al. (2021) แสดงให้เห็นว่าการแบ่งกลุ่มข้อมูลก่อนการพยากรณ์ช่วยเพิ่มประสิทธิภาพ ต่อมาได้แนวคิดจาก Mehtab et al. (2020) ซึ่งพบว่าโมเดล CNN มีประสิทธิภาพเหนือกว่า LSTM ในบางชุดข้อมูลอนุกรมเวลา รวมถึง Li et al. (2023) ที่ชี้ให้เห็นถึงปัญหาการล่าช้าของโมเดลแบบ Recurrent Network โดยเฉพาะในช่วงที่แนวโน้มข้อมูลเกิดการกลับตัว ซึ่งส่งผลให้ค่าพยากรณ์มีความคลาดเคลื่อนด้านทิศทาง จึงนำมาสู่การเลือกใช้โมเดล LSTM ที่เป็นโมเดลที่นิยมใช้ในข้อมูลอนุกรมเวลา ควบคู่กับโมเดล CNN เพื่อเปรียบเทียบประสิทธิภาพและศึกษาความล่าช้าของโมเดล และท้ายที่สุดได้นำเมตริก MPM จากงานวิจัยของ Samanta et al. (2020) ซึ่งถูกพัฒนาขึ้นเพื่อประเมินความแม่นยำในการพยากรณ์ทิศทางที่สัมพันธ์โดยตรงกับปัญหาการล่าช้ามาใช้เป็นเกณฑ์ในการประเมินผลร่วมกับเกณฑ์อื่น ๆ เพื่อให้สามารถตรวจจับและลดปัญหาการล่าช้าของโมเดล

4. กรอบแนวคิดงานวิจัย (Conceptual Framework)

งานวิจัยนี้มีแนวคิดโดยต้องการดึงจุดเด่นของโมเดล LSTM และ CNN เพื่อลดข้อผิดพลาดและลดความล่าช้าของโมเดลโดยวิธีการแบ่งกลุ่มข้อมูลตามแนวโน้มข้อมูลดังแสดงใน Figure 3. โดยอินพุตของงานวิจัยนี้คืออนุกรมเวลาราคาทอง ซึ่งนำมาแยกกลุ่มข้อมูลจากนั้นทำนายค่าราคาปิดของวันถัดไปด้วยโมเดล LSTM และ CNN จะช่วยลดค่าความผิดพลาดของโมเดล เพิ่มอัตราการทายถูกของโมเดล และสามารถนำไปใช้ในการซื้อขายจริง

5. วิธีดำเนินงานวิจัย (Research Methodology)

5.1 การเก็บข้อมูล

ดาวน์โหลดข้อมูลราคาทองคำ (Gold Spot) จากเว็บไซต์ www.investing.com (Investing.Com, 2025) โดยครอบคลุมระยะเวลา ตั้งแต่วันที่ 17 มกราคม 2014 ถึง วันที่ 17 กรกฎาคม 2025 ทั้งหมด 2,943 วัน ข้อมูลที่ใช้ในการวิจัยประกอบด้วยสามคุณสมบัติหลัก ได้แก่ ราคาปิด, ราคาสูงที่สุดของวัน และราคาต่ำที่สุดของวันดังแสดงใน Figure 4. โดยแกน X แทนลำดับของวันที่และแกน Y แทนราคาปิดของทองในแต่ละวัน




Figure 3. Conceptual Framework



Figure 4. Gold Price Chart

Source: Investing.Com (2025)

5.2 การเตรียมข้อมูลและแบ่งกลุ่มข้อมูลตามแนวโน้มราคาทอง

แบ่งข้อมูลราคาทองออกเป็นสองชุด ได้แก่ ชุดฝึกฝน 70% และ ชุดทดสอบ 30% (Bahri & Vahidnia, 2022) จากข้อมูลทั้งหมดตามลำดับเวลา จากนั้นเปลี่ยนข้อมูลให้เป็นอาร์เรย์ด้วยวิธี Sliding Window โดยจากการทดลองเปรียบเทียบ Windows Size ที่ 2, 3, 5 และ 10 พบว่าการเพิ่ม Windows Size ไม่ช่วยให้ความแม่นยำของโมเดลดีขึ้น โดย Windows Size = 2 ให้ผลลัพธ์ที่ดีที่สุดจึงเลือกใช้ Windows Size = 2 ในงานวิจัยนี้ ข้อมูลภายในแต่ละ Window ประกอบด้วย ราคาปิด, ราคาสูงสุด, และราคาต่ำสุดของวัน ซึ่งถูกใช้เป็นอินพุตของโมเดล และกำหนดให้ราคาปิดของวันถัดไปเป็นเป้าหมาย

ของโมเดล จากนั้นจำแนกแนวโน้มของราคาทองคำการออกเป็น 3 กลุ่ม ซึ่งเป็น 3 กลุ่มที่มีการทดลองเบื้องต้นว่ามีจำนวนข้อมูลในการฝึกฝนและทดสอบที่เพียงพอในแต่ละกลุ่ม เพื่อใช้เป็นข้อมูลอินพุตโดยแบ่งเป็น กลุ่มที่ 1 แนวโน้มขาขึ้น, กลุ่มที่ 2 แนวโน้มทรงตัวและ กลุ่มที่ 3 แนวโน้มขาลง โดยมีเกณฑ์ในการกำหนดกลุ่มซึ่งอาศัยการเปรียบเทียบข้อมูลระหว่างวันปัจจุบัน (i) กับวันก่อนหน้า (i-1) โดยพิจารณาจากการเคลื่อนไหวของราคาปิด (P), ราคาสูงสุด (H), และราคาต่ำสุด (L) ร่วมกัน เงื่อนไขในการแบ่งกลุ่มสามารถอธิบายได้ดังแสดงใน Figure 5.

หลังจากการแบ่งกลุ่ม จากนั้นวิเคราะห์ความผันผวนของแต่ละกลุ่มโดยคำนวณจากการเปลี่ยนแปลงราคาที่จะเกิดขึ้น ($P_{i+1}-P_i$) จากนั้นหาค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของแต่ละชุดข้อมูลดังแสดงใน Table 1.




Figure 5. Group Separation Method

Table 1. Group of Samples

Group	Amount of sample	Price change ($P_{i+1} - P_i$)	
		Mean	S.D.
Group 1	Train	670	5.72
	Test	331	11.44
Group 2	Train	804	0.17
	Test	332	2.48
Group 3	Train	584	-5.30
	Test	240	-8.78

5.3 กระบวนการฝึกและทดสอบโมเดล

งานวิจัยนี้สร้างโมเดลทั้งหมด 4 รูปแบบ เพื่อเปรียบเทียบประสิทธิภาพ โดยแบ่งวิธีการฝึกเป็น 2 แนวทางหลัก คือ โมเดลพื้นฐาน (LSTM และ CNN) และโมเดลแบบแบ่งกลุ่มข้อมูล 3 กลุ่ม (LSTM_G3 และ CNN_G3) โดยโมเดลพื้นฐานจะใช้ข้อมูลทั้งหมดในการฝึกและทดสอบโดยไม่มีแบ่งกลุ่มข้อมูล แต่ในโมเดลแบบแบ่งกลุ่มข้อมูล 3 กลุ่มช่วงก่อนการฝึกและทดสอบ จะมีการแบ่งข้อมูลออกเป็น 3 กลุ่มโดยมีเงื่อนไขดังแสดงใน Figure 5. จากนั้นจะฝึกโมเดลแยกกันในแต่ละกลุ่มดังแสดงใน Figure 6. โดยหลังจากที่ฝึกและทดสอบโมเดลทั้งหมดแล้ว จะเลือกโมเดลที่ให้ประสิทธิภาพในการทำนายดีที่สุดของแต่ละกลุ่มนำมาสร้างโมเดล LSTM+CNN_G3




Figure 6. Prediction Model

Table 2. Parameters

Model	Parameters	
CNN	Filters	64
	Kernel size	2
	activation function	Relu
	Pool size	2
	Dense_1	50
	Dense_2	1
LSTM	Units	64
	Dense	50
Optimizer		adam
epochs		20

หลังจากการทำนายจะแบ่งการวิเคราะห์ออกเป็น 2 กลุ่มคือ ความแม่นยำเชิงปริมาณ และความถูกต้องของทิศทางที่ทำนาย ตัวแปรที่ใช้วัดความแม่นยำเชิงปริมาณคือ MAE และตัวแปรที่ใช้วัดความถูกต้องของทิศทางคือ MPM (Samanta et al., 2020)

5.4 จำลองการซื้อขายทอง

เพื่อทดสอบศักยภาพในการประยุกต์ใช้จริง งานวิจัยได้จำลองการซื้อขายทองคำโดยอิงตามสัญญาณทิศทางจากโมเดล โดยเริ่มต้นด้วยเงินทุนเท่ากับราคาทอง 1 ออนซ์ของวันแรกจากชุดทดสอบซึ่งมีค่าเท่ากับ 1835.6 ดอลลาร์สหรัฐ และสิ้นสุด ณ วันสุดท้ายของชุดทดสอบ โดยใช้กลยุทธ์ “ซื้อทั้งหมด” เมื่อทำนายว่าราคาจะขึ้น และ “ขายทั้งหมด” เมื่อทำนายว่าราคาจะลง ดังแสดงใน Figure 7. ผลตอบแทนสะสมที่ได้จะถูกนำมาเปรียบเทียบกับกลยุทธ์ซื้อและถือ โดยการซื้อขายทองในโบรกเกอร์ของประเทศไทยไม่มีค่าธรรมเนียมการซื้อขาย แต่จะมีค่าส่วนต่างของราคาซื้อกับราคาขายซึ่งจะอยู่ประมาณ 0.01% ของราคาซื้อ (Krungthai, 2021)




Figure 7. Gold Trading Simulation Concept

6. ผลการวิจัย (Results)

6.1 ความแม่นยำเชิงปริมาณและทิศทางของโมเดล

งานวิจัยนี้เปรียบเทียบประสิทธิภาพระหว่างโมเดล LSTM และ CNN ทั้งแบบไม่แบ่งกลุ่มและแบบแบ่งกลุ่มตามแนวโน้มราคา โดยใช้ค่า MAE วัดความคลาดเคลื่อนเชิงปริมาณ และค่า MPM วัดความถูกต้องของทิศทางซึ่งสะท้อนปัญหาความล่าช้า

จาก Table 3. พบว่าเมื่อไม่ได้มีการแบ่งกลุ่มข้อมูลตามแนวโน้มราคาของโมเดล LSTM พื้นฐานให้ค่า MAE รวมเท่ากับ 19.98 และ MPM รวมเท่ากับ 52.50% ในส่วนโมเดล CNN พื้นฐานให้ MAE รวม 20.16 และ MPM รวม 51.47% แสดงให้เห็นว่า LSTM มีประสิทธิภาพทั้งเชิงปริมาณและทิศทางดีกว่า CNN เล็กน้อยในภาพรวม แต่เมื่อพิจารณาแยกรายกลุ่ม พบว่าโมเดลพื้นฐานทั้งสองมีปัญหาระยะความล่าช้าอย่างชัดเจน โดยเฉพาะใน กลุ่มขาขึ้น โดยมีค่า MPM ของ LSTM พื้นฐานอยู่ที่เพียง 47.91% และ CNN พื้นฐานอยู่ที่ 47.27% ซึ่งต่ำกว่า 50% แสดงว่าโมเดลไม่มีความแม่นยำในการทำนายขาขึ้นของราคาทอง

เมื่อนำวิธีการแบ่งกลุ่มข้อมูลตามแนวโน้มราคามาประยุกต์พบว่าโมเดล CNN_G3 และ LSTM_G3 ซึ่งเป็นโมเดลที่เกิดจากการแบ่งกลุ่มข้อมูลก่อนการฝึกและทดสอบโมเดล มีค่า MAE รวมลดลง และมีค่า MPM รวมเพิ่มขึ้น และเมื่อวิเคราะห์โมเดล LSTM+CNN_G3 ซึ่งเกิดจากการเลือกโมเดลที่เหมาะสมที่สุดของแต่ละกลุ่มโดยเลือก CNN_G3 สำหรับกลุ่มขาขึ้น, LSTM สำหรับกลุ่มทรงตัว และ LSTM_G3 สำหรับกลุ่มขาลง ให้ค่า MAE รวมต่ำที่สุดที่ 17.68 และ MPM รวมสูงที่สุดที่ 54.08% สูงกว่า LSTM พื้นฐานถึง 3.01% และสูงกว่า CNN พื้นฐานถึง 5.07% การเพิ่มขึ้นของ MPM นี้บ่งชี้ว่าการแบ่งกลุ่มสามารถลดปัญหาความล่าช้าในการทำนาย โดยเฉพาะในช่วงที่แนวโน้มราคาเปลี่ยนแปลง

Table 3. Experimental Results

		MODEL				
		CNN	LSTM	CNN_G3	LSTM_G3	LSTM+CNN_G3
MAE รวม		20.16	19.98	18.43	18.05	17.68
MPM รวม		51.47	52.50	53.17	53.51	54.08
GROUP 1	MAE (US dollar)	20.69	22.43	18.00*	19.01	18.00
	MPM (%)	47.27	47.91	51.45*	51.11	52.45
GROUP 2	MAE (US dollar)	19.44	19.10*	19.28	19.14	19.10
	MPM (%)	52.11	53.31*	52.71	51.81	53.31
GROUP 3	MAE (US dollar)	20.46	18.01	17.83	15.28*	15.28
	MPM (%)	55.83	57.08	55.95	58.33*	58.33

*The Best MAE and MPM in Each Group

6.2 การจำลองการซื้อขายทอง

ในการประเมินศักยภาพการนำโมเดลไปใช้จริง โดยจำลองการซื้อขายทองตามสัญญาณทิศทางจากโมเดล ผลปรากฏว่าโมเดล LSTM+CNN_G3 ให้กำไรสูงสุดที่ 1,870 ดอลลาร์สหรัฐ โดยคิดเป็น 101.87% ของเงินทุนเริ่มต้นซึ่งสูงกว่ากลยุทธ์ซื้อและถือที่กำไร 1,501 ดอลลาร์สหรัฐ อย่างชัดเจน

Table 4. Gold Trading Profit

Model	Profit (US dollar)	Profit (%)
CNN	776	42.28
LSTM	1,383	75.34
CNN_G3	1,757	95.72
LSTM_G3	1,803	98.22
LSTM+CNN_G3 (Presented)	1,870	101.87
Buy-and-Hold	1,501	81.77

7. สรุปผลการวิจัย (Conclusion)

จากการเปรียบเทียบประสิทธิภาพของโมเดล LSTM และ CNN สำหรับการพยากรณ์อนุกรมเวลาราคาทองคำ โดยใช้ค่า MAE วัดความคลาดเคลื่อนเชิงปริมาณ และค่า MPM วัดความถูกต้องของทิศทาง พบว่าโมเดล LSTM พื้นฐานมีประสิทธิภาพดีกว่า CNN พื้นฐานเล็กน้อย โดยให้ค่า MAE รวมเท่ากับ 19.98 และ MPM รวมเท่ากับ 52.50% ในขณะที่ CNN พื้นฐานให้ค่า MAE รวม 20.16 และ MPM รวม 51.47% อย่างไรก็ตามทั้งสองโมเดลซึ่งเป็นโมเดลพื้นฐานยังมีปัญหาความล่าช้าอย่างชัดเจน โดยเฉพาะในกลุ่มแนวโน้มขาขึ้นซึ่งค่า MPM ต่ำกว่า 50%

การพัฒนาวิธีการลดปัญหาความล่าช้าโดยการแบ่งกลุ่มข้อมูลตามแนวโน้มราคาออกเป็น 3 กลุ่ม พบว่าการแบ่งกลุ่มตามแนวโน้มราคาส่งผลให้โมเดลอย่าง LSTM_G3 และ CNN_G3 มีความแม่นยำมากขึ้นทั้งในเชิงปริมาณและทิศทาง โดยเมื่อนำโมเดลที่เหมาะสมในแต่ละกลุ่มมาสร้างโมเดล LSTM+CNN_G3 พบว่าโมเดล LSTM+CNN_G3 ให้ค่า MAE รวมต่ำที่สุดที่ 17.68 และ MPM รวมสูงที่สุดที่ 54.08% ซึ่งสูงกว่า LSTM พื้นฐานถึง 3.01% และสูงกว่า CNN พื้นฐานถึง 5.07% แสดงให้เห็นว่าการแบ่งกลุ่มข้อมูลสามารถลดปัญหาความล่าช้าในการทำนายได้อย่างมีประสิทธิภาพ

เมื่อประเมินศักยภาพของโมเดลที่พัฒนาขึ้นในการจำลองการซื้อขายทองคำจริงพบว่า โมเดล LSTM+CNN_G3 ซึ่งเป็นโมเดลที่งานวิจัยนี้นำเสนอ โดยให้กำไรสูงสุดที่ 1,870 ดอลลาร์สหรัฐ คิดเป็น 101.87% ของเงินทุนเริ่มต้น ซึ่งสูงกว่ากลยุทธ์ซื้อและถือที่กำไร 1,501 ดอลลาร์สหรัฐ อย่างชัดเจน แสดงให้เห็นถึงศักยภาพในการนำไปประยุกต์ใช้จริงในตลาดการเงิน

8. อภิปรายผลการวิจัย (Discussion)

จากผลการศึกษาพบว่าโมเดลที่ผ่านการแบ่งกลุ่มข้อมูลตามแนวโน้มราคาให้ผลลัพธ์ที่ดีกว่าโมเดลพื้นฐานนั้น สอดคล้องกับแนวคิดของ Lin et al. (2021) ที่ชี้ให้เห็นว่าการจำแนกรูปแบบราคาและเลือกใช้โมเดลให้เหมาะสมกับแต่ละรูปแบบสามารถเพิ่มประสิทธิภาพการทำนายได้ โดยที่ LSTM+CNN_G3 มีค่า MAE ต่ำที่สุดและ MPM สูงที่สุด สะท้อนให้เห็นว่าข้อมูลราคาทองคำซึ่งมีความซับซ้อนสูงมีพฤติกรรมที่แตกต่างกันในแต่ละช่วงเวลา การฝึกโมเดลเดี่ยวเพื่อเรียนรู้ทุกพฤติกรรมพร้อมกันอาจไม่เหมาะสมที่สุด ดังนั้นการแบ่งกลุ่มจึงช่วยลดความซับซ้อนของปัญหาที่โมเดลแต่ละตัวต้องเรียนรู้ ทำให้โมเดลสามารถตรวจจับและจดจำคุณลักษณะเฉพาะของแต่ละแนวโน้มได้อย่างมีประสิทธิภาพมากขึ้น

เมื่อพิจารณาความเหมาะสมของโมเดลในแต่ละกลุ่มพบว่า กลุ่มขาขึ้น มีค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของการเปลี่ยนแปลงราคาสูง ซึ่งแสดงถึงความผันผวนของข้อมูลที่มีมาก ส่งผลให้โมเดล CNN_G3 ที่มีความสามารถในการสกัดคุณลักษณะที่สำคัญจากข้อมูลอนุกรมเวลาได้ดี และมีการแบ่งกลุ่มข้อมูลก่อนการฝึกฝนและทดสอบ มีความเหมาะสมที่สุดสำหรับกลุ่มนี้ สอดคล้องกับงานวิจัยของ Mehtab et al. (2020) ที่พบว่าโมเดล CNN มีประสิทธิภาพเหนือกว่า LSTM ในบางชุดข้อมูล จากการวิเคราะห์ข้อมูลกลุ่มทรงตัว พบว่ามีส่วนเบี่ยงเบนมาตรฐานสูงแต่ค่าเฉลี่ยใกล้เคียงศูนย์ สะท้อนว่าข้อมูลผัน

พจนานุกรมไม่มีทิศทางชัดเจนส่งผลให้ทุกโมเดลให้ผลลัพธ์ใกล้เคียงกัน โดยโมเดล LSTM ที่ไม่ได้มีการแบ่งกลุ่มข้อมูลให้ผลดีที่สุด กลุ่มสุดท้ายกลุ่มกลางมีความผันผวนต่ำ โมเดล LSTM_G3 ซึ่งมีประสิทธิภาพในการเรียนรู้รูปแบบระยะยาวจึงทำนายได้แม่นยำที่สุดในกลุ่มนี้

ผลการศึกษานี้สอดคล้องกับข้อค้นพบของ Li et al. (2023) ที่ระบุว่าโมเดลแบบ Recurrent Network มักเผชิญปัญหาความล่าช้าโดยเฉพาะในช่วงที่แนวโน้มข้อมูลเกิดการกลับตัว และการที่โมเดล LSTM+CNN_G3 มีค่า MPM สูงขึ้น แสดงให้เห็นว่าการแบ่งกลุ่มข้อมูลสามารถลดปัญหาความล่าช้าได้อย่างมีประสิทธิภาพ

โมเดล LSTM+CNN_G3 ที่นำเสนอมีศักยภาพสูงในการนำไปประยุกต์ใช้จริง โดยสังเกตได้จากผลกำไรในการจำลองที่สูงกว่ากลยุทธ์ซื้อและถือถึง 24.6% อย่างไรก็ตาม ข้อควรระมัดระวังที่สำคัญในการใช้งานจริง คือ ผลการจำลองในงานวิจัยนี้เกิดขึ้นภายใต้เงื่อนไขในอุดมคติที่สำคัญได้แก่ สามารถซื้อหรือขายทองได้ทันทีที่โดยไม่มีค่าธรรมเนียมในการส่งคำสั่ง และสามารถขายทองได้เต็มจำนวนทุกครั้งโดยไม่มีปัญหาสภาพคล่องหรือราคาที่ลดลงจากปริมาณการขาย โดยในความเป็นจริงการซื้อขายในปริมาณที่มากอาจทำให้ราคาเปลี่ยนและไม่สามารถซื้อ-ขายได้จนครบปริมาณที่ต้องการ

9. ข้อเสนอแนะงานวิจัย (Recommendation)

1. ปรับเปลี่ยนกรอบเวลาจาก 1 วันเป็น 1 ชั่วโมงหรือ 15 นาที เพื่อเพิ่มจำนวนครั้งในการซื้อขายและอาจเกิดรูปแบบที่โมเดลสามารถเรียนรู้ได้มากขึ้น
2. ทดลองแบ่งกลุ่มข้อมูลเพิ่มขึ้นมากกว่า 3 กลุ่ม เช่น การแบ่งตามระดับความรุนแรงของแนวโน้ม (ขาขึ้นแรง ขาขึ้นอ่อน ทรงตัว ขาลงอ่อน ขาลงแรง) และเพิ่มตัวแปรเศรษฐกิจมหภาคที่มีอิทธิพลต่อราคาทองคำ เช่น ดัชนีเงินดอลลาร์สหรัฐ อัตราดอกเบี้ยนโยบาย และดัชนีราคาผู้บริโภค (CPI) เพื่อให้โมเดลเรียนรู้ปัจจัยเชิงสาเหตุได้ดียิ่งขึ้น
3. ทดลองใช้สถาปัตยกรรมโมเดลที่มีความซับซ้อน เช่น Hybrid CNN-LSTM Model และ Attention Mechanism
4. ทดลองการใช้โมเดลกับข้อมูลอื่น ๆ เช่น ราคาหุ้น อัตราแลกเปลี่ยน หรือในงานด้านอื่น ๆ เช่น การทำนายอุณหภูมิ, ความเร็วลม และมลพิษทางอากาศ เป็นต้น เพื่อแก้ปัญหาต่าง ๆ เช่น ปัญหาด้านสิ่งแวดล้อม ปริมาณมลพิษในอากาศ เป็นต้น

10. การเปิดเผยการใช้ปัญญาประดิษฐ์เชิงสร้างสรรค์ (Declaration of Generative AI)

ในระหว่างการจัดทำงานวิจัยนี้ใช้เครื่องมือปัญญาประดิษฐ์แบบสร้างสรรค์ (Generative AI) เพื่อช่วยเหลือในบางส่วนของงานวิจัย ซึ่งเป็นไปตามนโยบายด้าน AI ของวารสารวิชาการ โดยใช้ DeepSeek ช่วยเหลือในการเขียนโค้ดเบื้องต้นและแก้ไขข้อผิดพลาดและปรับปรุงประสิทธิภาพของโค้ดในระหว่างการพัฒนา

11. การแสดงบทบาทผู้เขียน (CRediT Author Statement)

Napatr Chongkol: Conceptualization, Methodology, Software, Validation, Formal Analysis, Investigation, Resources, Data Curation, Writing-Original Draft, Visualization.

Tanun Jaruvitayakovit: Conceptualization, Writing-Review & Editing, Supervision, Project Administration.

All authors read and approved the final manuscript.

12. เอกสารอ้างอิง (References)

Bahri, M. Z., & Vahidnia, S. (2022, November 16-18). Time Series Forecasting Using Smoothing Ensemble Empirical Mode Decomposition and Machine Learning Techniques. *2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering*, 1–6. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICECCME55909.2022.9988336>

- Chen, L., & Fan, X. (2025). TIC-FusionNet: A Multimodal Deep Learning Framework with Temporal Decomposition and Attention-Based Fusion for Time Series Forecasting. *PLOS One*, 20(10), e0333379. <https://doi.org/10.1371/journal.pone.0333379>
- Chen, W., Hussain, W., Cauteruccio, F., & Zhang, X. (2024). Deep Learning for Financial Time Series Prediction: A State-of-the-Art Review of Standalone and Hybrid Models. *Computer Modeling in Engineering & Sciences*, 139(1), 187–224. <https://doi.org/10.32604/cmescs.2023.031388>
- Das, P., & Barman, S. (2025). Perspective Chapter: An Overview of Time Series Decomposition and Its Applications. In Sloboda, B. W., & Quah, C.-H. (Eds), *Business, Management and Economics* (1-15). IntechOpen. <https://doi.org/10.5772/intechopen.1009268>
- Giantsidi, S., & Tarantola, C. (2025). Deep Learning for Financial Forecasting: A Review of Recent Trends. *International Review of Economics & Finance*, 104, 104719. <https://doi.org/10.1016/j.iref.2025.104719>
- Investing.Com. (2025). *Historical XAU/USD Exchange Rates*. <https://th.investing.com/currencies/xau-usd-historical-data> (In Thai)
- Krungthai. (2021). *Gold Wallet, an Online Gold Trading Platform that Enables Real-Time Gold Buying, Selling, and Withdrawal Orders Through the Paotang Application*. <https://krungthai.com/th/krungthai-update/promotion-detail/843> (In Thai)
- Li, J., Song, L., Wu, D., Shui, J., & Wang, T. (2023). Lagging Problem in Financial Time Series Forecasting. *Neural Computing and Applications*, 35(28), 20819–20839. <https://doi.org/10.1007/s00521-023-08879-1>
- Lin, Y., Liu, S., Yang, H., & Wu, H. (2021). Stock Trend Prediction Using Candlestick Charting and Ensemble Machine Learning Techniques with a Novelty Feature Engineering Scheme. *IEEE Access*, 9, 101433–101446. <https://doi.org/10.1109/ACCESS.2021.3096825>
- Mehtab, S., Sen, J., & Dasgupta, S. (2020, November 5-7). Robust Analysis of Stock Price Time Series Using CNN and LSTM-Based Deep Learning Models. *2020 4th International Conference on Electronics, Communication and Aerospace Technology*, 1481–1486. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICECA49313.2020.9297652>
- Ortu, M., Uras, N., Conversano, C., Bartolucci, S., & Destefanis, G. (2022). On Technical Trading and Social Media Indicators for Cryptocurrency Price Classification Through Deep Learning. *Expert Systems with Applications*, 198, 116804. <https://doi.org/10.1016/j.eswa.2022.116804>
- Samanta, S., Pratama, M., Sundaram, S., & Srikanth, N. (2020, July 19-24). A Dual Network Solution (DNS) for Lag-Free Time Series Forecasting. *2020 International Joint Conference on Neural Networks*, 1–8. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/IJCNN48605.2020.9207022>
- TP, K. N., & Sultana, S. (2024, November 7-9). Advanced Techniques for Daily Gold Price Forecasting in India Through Statistical Analysis and Predictive Modeling. *2024 8th International Conference on Computational System and Information Technology for Sustainable Solutions*, 1–6. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/CSITSS64042.2024.10816779>
- Widiputra, H., Mailangkay, A., & Gautama, E. (2021). Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction. *Complexity*, 2021(1), 9903518. <https://doi.org/10.1155/2021/9903518>