Faculty of Science and Technology, Uttaradit Rajabhat University

วารสารวิชาการวิทยาศาสตร์และวิทยาศาสตร์ประยุกต์

Journal homepage: https://ph03.tci-thaijo.org/index.php/ajsas

การประยุกต์ใช้เทคนิคการพยากรณ์อนุกรมเวลาสำหรับการพยากรณ์ราคาปิดของหุ้นหลายช่วงเวลาล่วงหน้าในดัชนี S&P 500

Application of Time Series Forecasting Techniques for Multi-step Forecasting of Stock Closing Prices in the S&P 500 Index

อารียา อ้างอิง[1] สาลินี ธำรงเลาหะพันธุ์[1] ปรารถนา มินเสน[2] และ วฐา มินเสน[1*]

Areeya Ang-ing[1], Salinee Thumronglaohapan[1], Pradthana Minsan[2] and Watha Minsan[1*]

[1]ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ อำเภอเมืองเชียงใหม่ จังหวัดเชียงใหม่ 50200

[1]Department of Statistics, Faculty of Science, Chiang Mai University, Chiang Mai, 50200, Thailand.

[2]ภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่ อำเภอเมืองเชียงใหม่ จังหวัดเชียงใหม่ 50300

[2]Department of Mathematics and Statistics, Faculty of Science and Technology, Chiang Mai Rajabhat University, Chiang Mai, 50300, Thailand.

ข้อมูลบทความ

ประวัติบทความ

รับเมื่อ: 7 สิงหาคม 2569

แก้ไขเมื่อ: 13 กันยายน 2569

ตอบรับเมื่อ: 17 ตุลาคม 2569

เผยแพร่ออนไลน์:

4 พฤศจิกายน 2569

คำสำคัญ

การพยากรณ์อนุกรมเวลา

ตัวแบบการเรียนรู้

SARIMA

การพยากรณ์ร่วม

ราคาปิดหุ้น

***ผู้ประพันธ์บรรณกิจ**

อีเมล์:

wathaminsan@gmail.com

(วฐา มินเสน)

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาตัวแบบการพยากรณ์ร่วม CDTDES และเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ 6 วิธีในการพยากรณ์ราคาปิดรายวันของหุ้น 9 อันดับแรกในดัชนี S&P 500 ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลราคาปิดรายวันของหุ้น BRK.B, AVGO, META, TSLA, GOOGL, AMZN, AAPL, MSFT และ NVDA ตั้งแต่วันที่ 1 มกราคม พ.ศ. 2563 ถึงวันที่ 3 กรกฎาคม พ.ศ. 2568 รวม 1,432 วัน โดยแบ่งข้อมูลเป็นชุดฝึกสอนร้อยละ 80 และชุดทดสอบร้อยละ 20 การศึกษานี้ใช้การพยากรณ์หลายช่วงเวลาล่วงหน้าจากจุดเริ่มต้นคงที่ และเปรียบเทียบวิธีการพยากรณ์ 6 วิธี ได้แก่ FC, CDT, DES, CDTDES, วิธีบ็อกซ์-เจนกินส์ และ LSTM โดยประเมินประสิทธิภาพด้วย RMSE ผลการวิจัยพบว่าไม่มีตัวแบบใดให้ผลการพยากรณ์ดีที่สุดสำหรับข้อมูลทุกชุด โดย LSTM และ CDTDES ให้ผลการพยากรณ์ดีที่สุดจำนวน 3 หลักทรัพย์เท่ากัน ขณะที่วิธีบ็อกซ์-เจนกินส์และ FC ให้ผลดีที่สุดจำนวน 2 และ 1 หลักทรัพย์ ตามลำดับ ส่วน CDT และ DES ไม่พบว่าให้ผลดีที่สุดในข้อมูลชุดใด นอกจากนี้ LSTM สามารถเรียนรู้ความสัมพันธ์ที่ไม่เป็นเชิงเส้นของข้อมูลอนุกรมเวลา ขณะที่ CDTDES ให้ผลดีกว่าการใช้ CDT หรือ DES สำหรับข้อมูลที่มีแนวโน้ม ผลการศึกษาชี้ให้เห็นว่าการเลือกตัวแบบให้เหมาะสมกับลักษณะของข้อมูลมีความสำคัญต่อความแม่นยำของการพยากรณ์ และ CDTDES เป็นอีกทางเลือกหนึ่งสำหรับการพยากรณ์ข้อมูลอนุกรมเวลาที่ไม่มีองค์ประกอบของฤดูกาล

ARTICLE INFO

Article History
Received: 7 August 2026
Revised:13 September2026
Accepted:17 October 2026
Available online:
4 November 2026

Keywords:
Time Series Forecasting
Learning-based Model
SARIMA
Combined Forecasting
Stock Closing Price

***Corresponding author**
Email address:
wathaminsan@gmail.com
(W. Minsan)

ABSTRACT

This study aims to develop the CDTDES combined forecasting model and compare the performance of six forecasting methods in forecasting the daily closing prices of the nine largest stocks in the S&P 500 Index. The dataset consisted of the daily closing prices of BRK.B, AVGO, META, TSLA, GOOGL, AMZN, AAPL, MSFT, and NVDA from January 1, 2020, to July 3, 2025, comprising 1,432 observations. The data were divided into training and testing sets in the proportions of 80% and 20%, respectively. A fixed-origin multi-step forecasting approach was employed to compare the performance of six forecasting methods: FC, CDT, DES, CDTDES, Box–Jenkins, and LSTM. Forecasting performance was evaluated using RMSE. The results revealed that no single model consistently outperformed all others across every dataset. LSTM and CDTDES achieved the best forecasting performance for three stocks each. The Box–Jenkins method and FC achieved the best performance for two and one stocks, respectively. Neither CDT nor DES achieved the best forecasting performance for any dataset. Furthermore, LSTM can learn nonlinear relationships in time series data, whereas CDTDES outperformed CDT and DES for trend-dominated time series. The findings suggest that selecting an appropriate forecasting model according to the characteristics of the data is crucial for improving forecasting accuracy. Moreover, CDTDES provides an alternative approach for forecasting time series data without seasonal components.

1. บทนำ

การลงทุนในตลาดหลักทรัพย์เป็นกลไกสำคัญในการขับเคลื่อนเศรษฐกิจ โดยดัชนีที่ได้รับการยอมรับในระดับสากลอย่างดัชนี S&P 500 ซึ่งจัดทำโดยบริษัท S&P Dow Jones Indices ประกอบด้วยหลักทรัพย์ของบริษัทขนาดใหญ่ในสหรัฐอเมริกามากกว่า 500 บริษัท และถูกใช้เป็นตัวแทนสะท้อนภาพรวมของภาวะเศรษฐกิจและแนวโน้มของภาคอุตสาหกรรมต่าง ๆ อย่างแพร่หลาย ข้อมูลราคาหุ้นซึ่งอยู่ในรูปแบบอนุกรมเวลามีลักษณะผันผวนสูงและมีความไม่แน่นอน ทำให้การพยากรณ์ราคาหุ้นในระยะยาวเป็นประเด็นที่ท้าทายและได้รับความสนใจอย่างต่อเนื่อง เนื่องจากผลการพยากรณ์สามารถใช้สนับสนุนการวางแผนการลงทุน การบริหารความเสี่ยง และการกำหนดกลยุทธ์การลงทุนในระยะกลางและระยะยาวของนักลงทุนและผู้จัดการกองทุน

วิธีทางสถิติถือเป็นแนวทางพื้นฐานที่ใช้กันอย่างแพร่หลายในการพยากรณ์ข้อมูลอนุกรมเวลา โดยมีประสิทธิภาพดีในกรณีที่ข้อมูลมีโครงสร้างเชิงเส้น ในเชิงทฤษฎีสามารถจำแนกได้เป็น 3 กลุ่มหลัก ได้แก่ (1) วิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิก ซึ่งอาศัยการแยกองค์ประกอบของข้อมูล เช่น แนวโน้ม ฤดูกาล และส่วนสุ่ม [1] (2) วิธีการทำให้เรียบ เช่น วิธีของ Holt [2] และ Winters [3] ซึ่งใช้ค่าคงที่การทำให้เรียบในการประมาณระดับและแนวโน้มของข้อมูล และ (3) วิธีบ็อกซ์–เจนกินส์ [4] ซึ่งพัฒนาตัวแบบ Seasonal Autoregressive Integrated Moving Average (SARIMA) ภายใต้สมมติฐานความคงที่ของอนุกรมเวลา โดยใช้ฟังก์ชันสหสัมพันธ์ในตัว (Auto Correlation Function: ACF) และสหสัมพันธ์ในตัวบางส่วน (Partial Auto Correlation Function: PACF) ในการกำหนดโครงสร้างของตัวแบบ

ในเชิงปฏิบัติ โปรแกรมสำเร็จรูปสำหรับการพยากรณ์ได้รับความนิยมเพิ่มขึ้นอย่างต่อเนื่อง เช่น แผ่นงานการพยากรณ์ที่ปรากฏอยู่ใน Microsoft Excel ซึ่งพัฒนาบนพื้นฐานของวิธีการทำให้เรียบแบบเอ็กซ์โพเนนเชียล เป็นโปรแกรมที่สามารถเลือกโครงสร้างของตัวแบบ รวมทั้งประมาณค่าพารามิเตอร์ที่เหมาะสมกับข้อมูลอนุกรมเวลาที่เป็นตัวแปรนำเข้า (Input) ได้โดยอัตโนมัติ จึงเป็นเครื่องมือที่ใช้งานได้สะดวกสำหรับผู้ใช้ทั่วไป โดยในรายงานวิจัยของ Minsan and Minsan [5] และกาญจนา และ วิระภรณ์ [6] รายงานว่าแผ่นงานการพยากรณ์สามารถให้ผลการพยากรณ์ที่มีความแม่นยำในระดับที่น่าพอใจ และเป็นอีกทางเลือกหนึ่งสำหรับการวิเคราะห์ข้อมูลอนุกรมเวลา

อย่างไรก็ตาม ข้อมูลราคาหุ้นมักมีลักษณะผันผวนสูง มีแนวโน้มเปลี่ยนแปลงตามช่วงเวลา มีความไม่แน่นอน และมีความสัมพันธ์ที่ไม่เป็นเชิงเส้น [7] ดังข้อมูลอนุกรมเวลาของราคาปิดหุ้น TSLA ในรูปที่ 1 ที่มีการแนวโน้มเพิ่มขึ้นในช่วงเวลาปี พ.ศ. 2563 ถึง 2564 และลดลงในปี 2565 และเพิ่มขึ้นอีกครั้งในปี 2566 ช่วงต้นปีและลดลงหลังจากนั้น ลักษณะดังกล่าวสะท้อนถึงความซับซ้อนของการพยากรณ์ราคาหุ้น ด้วยเหตุนี้ งานวิจัยในช่วงหลายปีที่ผ่านมาจึงให้ความสนใจกับเทคนิคตัวแบบการเรียนรู้ (Learning-based Models) มากขึ้น โดยเฉพาะโครงข่ายหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM) ซึ่งได้รับการพัฒนาขึ้นเพื่อแก้ปัญหาเกรเดียนต์เลือนหาย และสามารถ

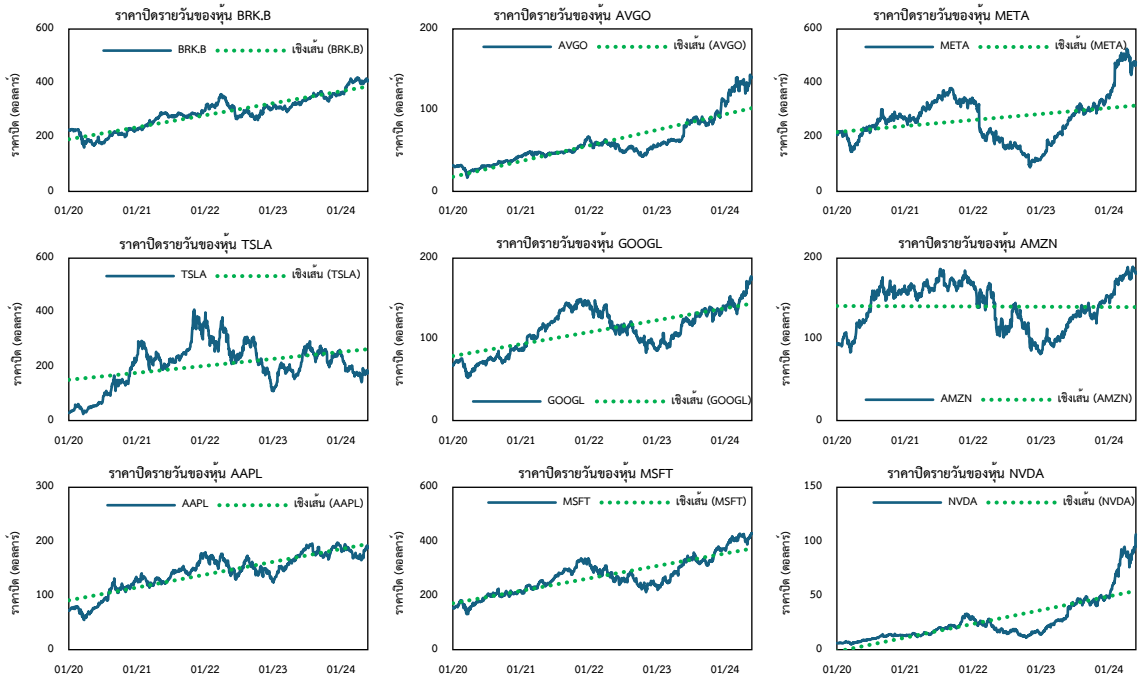

รูปที่ 1 ข้อมูลอนุกรมเวลาของราคาปิดหุ้นทั้ง 9

เรียนรู้ความสัมพันธ์ระยะยาวของข้อมูลได้อย่างมีประสิทธิภาพ [8-9] จากคุณสมบัติดังกล่าว งานวิจัยก่อนหน้าจึงมีการประยุกต์ใช้ LSTM สำหรับการพยากรณ์ข้อมูลอนุกรมเวลาที่มีแนวโน้มเปลี่ยนแปลงตามช่วงเวลา มีความไม่แน่นอน และมีความสัมพันธ์ที่ไม่เป็นเชิงเส้น [10]

ในช่วงที่ผ่านมา แนวคิดการพัฒนาตัวแบบการพยากรณ์ร่วม (Combined Forecasting Models) ได้รับความสนใจเพิ่มขึ้น เนื่องจากสามารถผสมผสานจุดเด่นของตัวแบบแต่ละวิธีเพื่อลดข้อจำกัดของการใช้ตัวแบบเพียงวิธีเดียว และช่วยเพิ่มประสิทธิภาพการพยากรณ์ในหลายสถานการณ์ ตัวอย่างเช่น Minsan and Minsan [11] ได้พัฒนาตัวแบบร่วมระหว่างวิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกและวิธี Holt–Winters โดยใช้การหาค่าเหมาะที่สุดด้วยอัลกอริทึม Whale Optimization Algorithm (WOA) สำหรับข้อมูลที่มีองค์ประกอบของฤดูกาล ซึ่งให้ผลการพยากรณ์ที่มีความแม่นยำสูงกว่าการใช้ตัวแบบเดี่ยว อย่างไรก็ตาม ข้อมูลราคาหุ้นโดยทั่วไปไม่มีองค์ประกอบของฤดูกาลที่ชัดเจน ทำให้ไม่สามารถประยุกต์ใช้ตัวแบบร่วมดังกล่าวได้โดยตรง ดังนั้นในงานวิจัยนี้จึงมีความจำเป็นต้องพัฒนาตัวแบบการพยากรณ์แบบร่วมที่เหมาะสมกับข้อมูลอนุกรมเวลาที่มีเฉพาะองค์ประกอบของแนวโน้ม เพื่อให้สามารถสะท้อนลักษณะของข้อมูลและเพิ่มประสิทธิภาพการพยากรณ์ได้ดียิ่งขึ้น

ดังนั้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาตัวแบบการพยากรณ์ร่วม CDTDES และเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ 6 วิธี ในการพยากรณ์ราคาปิดรายวันของหุ้น 9 อันดับแรกในดัชนี S&P 500 ได้แก่ วิธีการพยากรณ์ทางสถิติ 5 วิธี ประกอบด้วย เครื่องมือแผ่นงานการพยากรณ์ (Forecast Sheet: FC) วิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกที่มีแนวโน้ม (Classical Decomposition with Trend: CDT) วิธีการทำให้เรียบแบบเอ็กซ์โพเนนเชียลสองครั้ง (Double Exponential Smoothing: DES) วิธีบ็อกซ์–เจนกินส์ และตัวแบบการพยากรณ์ร่วมระหว่างวิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกที่มีแนวโน้มและวิธีการทำให้เรียบแบบเอ็กซ์โพเนนเชียลสองชั้น (Combined Classical Decomposition with Trend and Double Exponential Smoothing: CDTDES) ซึ่งพัฒนาขึ้นในการศึกษานี้ และตัวแบบการเรียนรู้ (Learning-based Model) 1 วิธี ได้แก่ LSTM โดยดำเนินการเปรียบเทียบประสิทธิภาพการพยากรณ์ภายใต้กรอบการทดลองและชุดข้อมูลเดียวกัน

การพัฒนา CDTDES ในการศึกษานี้มีแนวคิดจากการผสานการวิเคราะห์องค์ประกอบแนวโน้มของ CDT กับความสามารถในการปรับค่าการพยากรณ์ตามข้อมูลล่าสุดของ DES เพื่อให้สามารถพิจารณาทั้งแนวโน้มของข้อมูลและการเปลี่ยนแปลงของข้อมูลในระยะสั้นร่วมกัน ทั้งนี้ การนำ CDTDES มาเปรียบเทียบกับวิธีการพยากรณ์อื่นภายใต้กรอบการทดลองและชุดข้อมูลเดียวกัน ช่วยให้สามารถศึกษาประสิทธิภาพของตัวแบบที่พัฒนาขึ้นเมื่อเทียบกับวิธีการพยากรณ์ทั้งทางสถิติและตัวแบบการเรียนรู้

การศึกษานี้ใช้การพยากรณ์หลายช่วงเวลาล่วงหน้าจากจุดเริ่มต้นคงที่ (Fixed-origin Multi-step Forecasting) เพื่อประเมินความสามารถของตัวแบบในการพยากรณ์แนวโน้มราคาหุ้นในระยะยาว ซึ่งมีความสำคัญต่อการวางแผนการลงทุน การบริหารความเสี่ยง และการกำหนดกลยุทธ์การลงทุนของนักลงทุนและผู้จัดการกองทุน นอกจากนี้

การพยากรณ์หลายช่วงเวลาล่วงหน้ายังเป็นการทดสอบความสามารถของตัวแบบในการรักษาความแม่นยำและความเสถียรของผลการพยากรณ์เมื่อระยะเวลาการพยากรณ์ยาวขึ้น ซึ่งมีความท้าทายมากกว่าการพยากรณ์เพียงหนึ่งช่วงเวลาล่วงหน้า โดยประสิทธิภาพของแต่ละตัวแบบประเมินด้วยรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ซึ่งให้น้ำหนักกับค่าความคลาดเคลื่อนขนาดใหญ่มากกว่าค่าความคลาดเคลื่อนขนาดเล็ก จึงเหมาะสำหรับใช้ประเมินความแม่นยำของการพยากรณ์ราคาปิดในการศึกษานี้

2. วิธีดำเนินการวิจัย

2.1 เครื่องมือที่ใช้

2.1.1 โปรแกรม Microsoft Excel เวอร์ชัน 365

ใช้สำหรับการพยากรณ์ 4 วิธี คือ (1) FC (2) CDT (3) DES และ (4) CDTDES โดยวิธีที่ (2) ถึง (4) ใช้เครื่องมือ Solver ของ Microsoft Excel เพื่อประมาณค่าพารามิเตอร์ที่เหมาะที่สุด

2.1.2 โปรแกรม Minitab เวอร์ชัน 18

ใช้สำหรับการวิเคราะห์ข้อมูลเบื้องต้นและการตรวจสอบคุณลักษณะของข้อมูลอนุกรมเวลา เช่น การสร้างแผนภาพ ACF เพื่อพิจารณาแนวโน้มและองค์ประกอบของฤดูกาล และการทดสอบความเท่ากันของความแปรปรวนด้วยสถิติของเลวีน (Levene's Test)

2.1.3 แพลตฟอร์ม Google Colab

ซึ่งใช้ภาษา Python เวอร์ชัน 3.12 ใช้สำหรับพัฒนาตัวแบบการพยากรณ์ ได้แก่ วิธีบ็อกซ์–เจนกินส์ รวมทั้งการตรวจสอบความเหมาะสมของตัวแบบ และตัวแบบการเรียนรู้ LSTM

2.2 วิธีดำเนินการวิจัย

งานวิจัยนี้รวบรวมข้อมูลราคาปิดรายวันของหุ้น 9 อันดับแรกในกลุ่มดัชนี S&P 500 โดยใช้น้ำหนักของหลักทรัพย์ในดัชนี (Index Weight) เป็นเกณฑ์ในการจัดอันดับและคัดเลือกหลักทรัพย์ทั้ง 9 หลักทรัพย์เป็นขอบเขตของการศึกษา ประกอบด้วย Berkshire Hathaway (BRK.B), Broadcom Inc. (AVGO), Meta Platforms (META), Tesla Inc. (TSLA), Alphabet Inc. (GOOGL), Amazon (AMZN), Apple Inc. (AAPL), Microsoft (MSFT) และ Nvidia (NVDA) ข้อมูลครอบคลุมช่วงเวลาตั้งแต่วันที่ 1 มกราคม พ.ศ. 2563 ถึงวันที่ 3 กรกฎาคม พ.ศ. 2568 รวมทั้งสิ้น 1,432 วัน โดยสืบค้นจากเว็บไซต์ MarketWatch [12] ณ วันที่ 17 ธันวาคม พ.ศ. 2568 มีลักษณะของข้อมูลอนุกรมเวลาดังรูปที่ 1 พบว่าข้อมูลอนุกรมเวลาของราคาปิดหุ้นทั้ง 8 ชุดมีลักษณะคล้ายคลึงกัน คือ แสดงแนวโน้มเพิ่มขึ้นในระยะยาวร่วมกับความผันผวน ยกเว้น 1 หุ้น คือ AMZN ที่แสดงแนวโน้มลดลง และทั้ง 9 ชุดไม่ปรากฏรูปแบบฤดูกาลที่ชัดเจน ทั้งนี้การดำเนินการวิจัยประกอบด้วย 4 ขั้นตอน ดังต่อไปนี้

ขั้นตอนที่ 1 การเตรียมข้อมูล

ช่วงเวลาตั้งแต่วันที่ 1 มกราคม พ.ศ. 2563 ถึงวันที่ 3 กรกฎาคม พ.ศ. 2568 มีวันที่ไม่มีการซื้อขายเนื่องจากวันหยุดนักขัตฤกษ์ซึ่งตรงกับวันจันทร์–ศุกร์จำนวน 72 วัน คิดเป็นประมาณร้อยละ 5 ของข้อมูลทั้งหมด ผู้วิจัยจึงประมาณค่าราคาปิดในวันที่ไม่มีการซื้อขายดังกล่าว โดยใช้ค่าเฉลี่ยของราคาปิดในวันก่อนหน้าและวันถัดไป เพื่อรักษาความต่อเนื่องของลำดับเวลาและคาบของข้อมูลอนุกรมเวลาในช่วงเวลาซื้อขายปกติวันจันทร์-ศุกร์ จากนั้นแบ่งข้อมูลออกเป็นชุดข้อมูลฝึกสอน (Training Data Set) จำนวน 1,146 วัน (ร้อยละ 80) และชุดข้อมูลทดสอบ (Testing Data Set) จำนวน 286 วัน (ร้อยละ 20) โดยใช้ข้อมูลช่วงต้นสำหรับการสร้างตัวแบบและข้อมูลช่วงท้ายสำหรับการประเมินประสิทธิภาพการพยากรณ์

ขั้นตอนที่ 2 การตรวจสอบลักษณะของข้อมูลอนุกรมเวลา

ทำการตรวจสอบคุณสมบัติเบื้องต้นของข้อมูลอนุกรมเวลาในด้านแนวโน้ม และฤดูกาล โดยใช้แผนภาพ ACF จากโปรแกรม Minitab ดังรูปที่ 2 เพื่อพิจารณารูปแบบของอนุกรมเวลา และแบ่งข้อมูลออกเป็น 2 กลุ่มที่มีจำนวนข้อมูลเท่ากันตามลำดับเวลา และทดสอบความเท่ากันของความแปรปรวนระหว่างทั้งสองกลุ่มด้วยสถิติของเลวีน (Levene's Test) ดังตารางที่ 1

จากรูปที่ 2 ผลการพิจารณาแผนภาพ ACF พบว่า ข้อมูลราคาปิดของหุ้นทุกบริษัทมีค่าสัมประสิทธิ์สหสัมพันธ์ในตัวสูงในช่วงค่า Lag เริ่มต้นและลดลงอย่างช้า ๆ เมื่อค่า Lag เพิ่มขึ้น แสดงให้เห็นว่าอนุกรมเวลามีส่วนประกอบของแนวโน้ม และไม่ปรากฏลักษณะเด่นชัดของส่วนประกอบฤดูกาล ผลการตรวจสอบดังกล่าวแสดงให้เห็นว่า ข้อมูลราคาหุ้นทั้ง 9 ชุดมีแนวโน้ม แต่ไม่ปรากฏองค์ประกอบของฤดูกาลอย่างชัดเจน ดังนั้น วิธีทางสถิติที่นำมาใช้ในการศึกษานี้จึงประกอบด้วยวิธีที่เหมาะสมกับข้อมูลอนุกรมเวลาที่มีแนวโน้ม ได้แก่ FC, CDT, DES และ CDTDES

สำหรับผลการทดสอบความแปรปรวนตารางที่ 1 พบว่า หุ้น AVGO, GOOGL, AAPL, MSFT และ NVDA ข้อมูลมีความแปรปรวนไม่คงที่ ขณะที่หุ้น BRK.B, META, TSLA และ AMZN มีความแปรปรวนคงที่

จากผลการตรวจสอบตารางที่ 1 และรูปที่ 2 ดังกล่าว ในการวิเคราะห์ด้วยวิธีบ็อกซ์–เจนกินส์ ได้ตรวจสอบความคงที่ของอนุกรมเวลาโดยพิจารณาจากกราฟอนุกรมเวลา กราฟ ACF และผลการทดสอบ Augmented Dickey–Fuller (ADF) พบว่าอนุกรมเวลาของข้อมูลทุกชุดไม่คงที่ จึงทำการแปลงข้อมูล (Data Transformation) ตามความเหมาะสมดังนี้ ข้อมูลของหุ้น AVGO, GOOGL, AAPL, MSFT และ NVDA ที่มีความแปรปรวนไม่คงที่ แปลงข้อมูลด้วยเทคนิคบ็อกซ์–ค็อกซ์

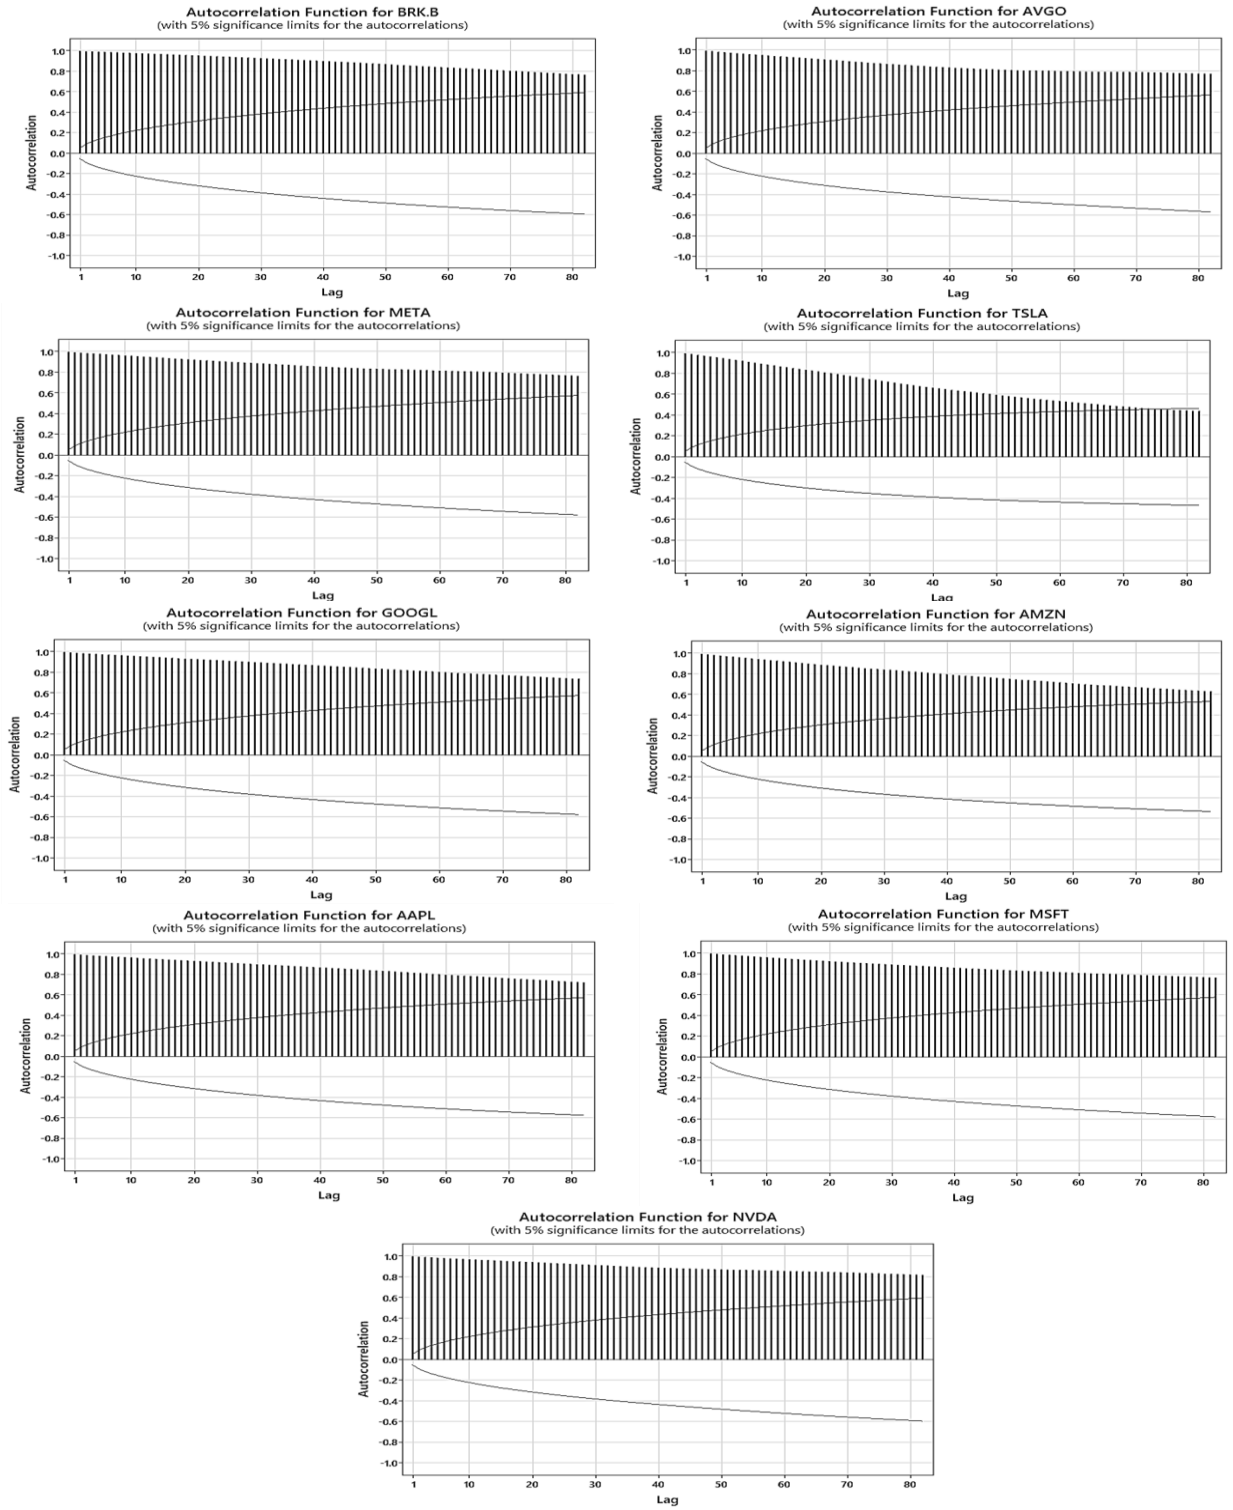

รูปที่ 2 ACF ของข้อมูลอนุกรมเวลาของราคาปิดหุ้นทั้ง 9

ตารางที่ 1 การทดสอบสถิติทดสอบของเลวีนภาวะความเท่ากันของความแปรปรวนของอนุกรมเวลาที่ขจัดแนวโน้มแล้ว และการทดสอบ ADF

ชื่อหุ้น	BRK.B	AVGO	META	TSLA	GOOGL	AMZN	AAPL	MSFT	NVDA
P-value ของเลวีน	0.138	<0.001*	0.991	0.237	<0.001*	0.828	0.023*	<0.001*	<0.001*
P-value ของ ADF	0.922	0.995	0.897	0.118	0.811	0.339	0.335	0.841	0.998

หมายเหตุ: เครื่องหมาย * หมายถึง ค่า P-value < 0.05 ข้อมูลอนุกรมเวลามีความแปรปรวนไม่คงที่

ร่วมกับการหาผลต่างอันดับหนึ่ง (d = 1) เพื่อทำให้อนุกรมเวลามีคุณสมบัติคงที่ ส่วนข้อมูลของหุ้น BRK.B, META, TSLA และ AMZN มีความแปรปรวนคงที่ ใช้วิธีหาผลต่างอันดับหนึ่ง (d = 1) เพียงอย่างเดียว กำหนดตัวแบบเบื้องต้นเป็น $\text{SARIMA}(p,1,q)(P,0,Q)L$

ขั้นตอนที่ 3 การสร้างตัวแบบพยากรณ์

ทำการสร้างตัวแบบพยากรณ์จากวิธีที่กำหนดไว้จำนวน 6 วิธี ได้แก่ FC, CDT, DES, CDTDES, วิธีบ็อกซ์–เจนกินส์ และ LSTM สำหรับแต่ละวิธีได้ดำเนินการสร้างตัวแบบโดยกำหนดหรือประมาณค่าพารามิเตอร์ตามหลักการของแต่ละวิธี เพื่อให้ได้ตัวแบบที่เหมาะสมกับข้อมูลของหุ้นแต่ละหลักทรัพย์ ก่อนนำไปใช้พยากรณ์ข้อมูลในชุดทดสอบ

ขั้นตอนที่ 4 การเปรียบเทียบและการประเมินประสิทธิภาพ

ทำการเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์จากทั้ง 6 วิธี สำหรับหุ้นแต่ละหลักทรัพย์ โดยใช้ RMSE เป็นเกณฑ์ในการประเมิน เนื่องจาก RMSE ให้น้ำหนักกับค่าคลาดเคลื่อนขนาดใหญ่มากกว่าค่าคลาดเคลื่อนขนาดเล็ก จึงเหมาะสำหรับการประเมินความแม่นยำของการพยากรณ์ราคาหุ้นซึ่งอาจมีการเปลี่ยนแปลงของราคาในระดับสูงในบางช่วงเวลา ทั้งนี้ ตัวแบบที่ให้ค่า RMSE ต่ำที่สุดในชุดข้อมูลทดสอบถือว่าเป็นตัวแบบที่เหมาะสมที่สุด

2.3 ตัวแบบการพยากรณ์

ส่วนนี้นำเสนอรายละเอียด หลักการ และขั้นตอนการดำเนินงานของตัวแบบพยากรณ์ทั้ง 6 วิธีที่ใช้ในการศึกษาครั้งนี้ เพื่อเปรียบเทียบประสิทธิภาพด้านความแม่นยำในการพยากรณ์ราคาปิดรายวันของหุ้นแต่ละหลักทรัพย์

2.3.1 แผ่นงานการพยากรณ์

โปรแกรม Microsoft Excel 365 มีเครื่องมือสำเร็จรูปที่เรียกว่า แผ่นงานการพยากรณ์ ซึ่งช่วยให้ผู้ใช้สามารถสร้างตัวแบบพยากรณ์ข้อมูลอนุกรมเวลาได้อย่างสะดวกผ่านส่วนติดต่อผู้ใช้ของโปรแกรม เครื่องมือนี้อาศัยหลักการของวิธีการทำให้เรียบแบบเอ็กซ์โพเนนเชียลในการประมาณค่าและสร้างค่าพยากรณ์ โดยสามารถกำหนดค่าพารามิเตอร์ด้านระดับ แนวโน้ม และฤดูกาล ได้ทั้งแบบอัตโนมัติหรือกำหนดเอง

ในการศึกษาครั้งนี้ ได้กำหนดการตั้งค่าพารามิเตอร์เป็นแบบอัตโนมัติทั้งหมดเพื่อให้โปรแกรมเลือกค่าที่เหมาะที่สุดจากข้อมูลฝึกสอนของแต่ละราคาหุ้น ทั้งนี้กำหนดความยาวช่วงการพยากรณ์เท่ากับจำนวนข้อมูลในชุดทดสอบ ใช้การตรวจจับฤดูกาลแบบอัตโนมัติ กำหนดระดับความเชื่อมั่นร้อยละ 95 และใช้การประมาณค่าสำหรับข้อมูลที่ขาดหายด้วยค่าเฉลี่ยของข้อมูลข้างเคียง มีขั้นตอนการดำเนินงานดังนี้

ขั้นตอนการพยากรณ์ด้วย FC

1. แบ่งข้อมูลอนุกรมเวลาออกเป็นชุดข้อมูลฝึกสอน และชุดข้อมูลทดสอบ

2. นำข้อมูลชุดฝึกสอนไปสร้างตัวแบบด้วยเครื่องมือ Forecast Sheet ในโปรแกรม Microsoft Excel

a. กำหนดพารามิเตอร์ของ Forecast Sheet ดังนี้

b. ฤดูกาล (Seasonality) = Automatic

c. ระดับความเชื่อมั่น (Confidence Interval) = 95%

3. การจัดการค่าที่หายไป (Missing Values) = Average of Adjacent Points

4. ให้โปรแกรมประมาณค่าตัวแบบ ETS (Error, Trend, Seasonality) โดยอัตโนมัติจากชุดข้อมูลฝึกสอน

5. ใช้ตัวแบบที่ได้เพื่อพยากรณ์ข้อมูลในช่วงเวลาของชุดข้อมูลทดสอบ

2.3.2 วิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกที่มีแนวโน้ม

วิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกเป็นวิธีการที่พิจารณาองค์ประกอบของอนุกรมเวลา แล้วทำการแยกองค์ประกอบเหล่านั้นออกจากกัน เช่น แนวโน้ม ฤดูกาล และส่วนสุ่ม จากนั้นจึงสร้างตัวแบบสำหรับแต่ละองค์ประกอบก่อนนำมารวมกันเพื่อใช้ในการพยากรณ์ วิธีดังกล่าวเป็นเทคนิคทางสถิติที่ช่วยให้สามารถวิเคราะห์และแยกแยะโครงสร้างพื้นฐานของข้อมูลอนุกรมเวลาได้อย่างชัดเจน ส่งผลให้เข้าใจลักษณะการเปลี่ยนแปลงของข้อมูลและสามารถเลือกตัวแบบพยากรณ์ที่เหมาะสมกับลักษณะของข้อมูลได้มากขึ้น

อนุกรมเวลาที่มีแนวโน้มแต่ไม่มีฤดูกาลจะมีลักษณะสำคัญคือ ข้อมูลมีการเพิ่มขึ้นหรือลดลงอย่างต่อเนื่องตามเวลา ซึ่งสะท้อนถึงการเปลี่ยนแปลงในระยะยาวอันเกิดจากปัจจัยต่าง ๆ โดยไม่ปรากฏรูปแบบที่เกิดซ้ำในช่วงเวลาคงที่เหมือนข้อมูลที่มีฤดูกาล ทั้งนี้ ข้อมูลมักมีความแปรปรวนแบบสุ่มเกิดขึ้นรอบแนวโน้มหลัก ดังนั้น ในการสร้างตัวแบบพยากรณ์จึงจำเป็นต้องศึกษาลักษณะของแนวโน้มให้ชัดเจน เพื่อเลือกใช้ตัวแบบทางคณิตศาสตร์ที่สอดคล้องกับรูปแบบการเปลี่ยนแปลงของข้อมูล โดยรูปแบบแนวโน้มที่สำคัญมีดังต่อไปนี้

ตัวแบบพยากรณ์ของแนวโน้มเชิงเส้นดังสมการที่ (1)

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t \quad (1)$$

ตัวแบบพยากรณ์ของแนวโน้มพหุนามลำดับ 2 ดังสมการที่ (2)

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t + \hat{\beta}_2 t^2 \quad (2)$$

ตัวแบบพยากรณ์ของแนวโน้มเอ็กซ์โพเนนเชียลดังสมการที่ (3)

$$\hat{Y}_t = \hat{\beta}_0 e^{\hat{\beta}_1 t} \quad (3)$$

ตัวแบบพยากรณ์ของแนวโน้มลอการิทึมดังสมการที่ (4)

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 \ln(t) \quad (4)$$

ตัวแบบพยากรณ์ของแนวโน้มกำลังดังสมการที่ (5)

$$\hat{Y}_t = \hat{\beta}_0 t^{\hat{\beta}_1} \quad (5)$$

โดยที่

$\hat{Y}_t$ แทนค่าพยากรณ์ ณ เวลา t และ $\hat{\beta}_i$ $(i = 0,1,2)$ แทนตัวประมาณค่าคงตัว และ

t แทนเวลา ณ ช่วงเวลาหนึ่ง มีขั้นตอนการดำเนินงานดังนี้

ขั้นตอนการพยากรณ์ด้วย CDT

1. แบ่งข้อมูลอนุกรมเวลาออกเป็นชุดข้อมูลฝึกสอน และชุดข้อมูลทดสอบ

2. กำหนดชุดของตัวแบบแนวโน้ม (Trend Models) ประกอบด้วย

a.แนวโน้มเชิงเส้น (Linear)

b.แนวโน้มพหุนามลำดับ 2 (Quadratic)

c.แนวโน้มเอ็กซ์โพเนนเชียล (Exponential)

d.แนวโน้มลอการิทึม (Logarithmic)

e.แนวโน้มกำลัง (Power)

3. สร้างตัวแบบ CDT สำหรับตัวแบบแนวโน้มแต่ละรูปแบบโดยใช้ข้อมูลชุดฝึกสอนจากนั้นจึงคัดเลือกตัวแบบที่ให้ผลการพยากรณ์มีความแม่นยำสูงที่สุดจากทั้งห้าตัวแบบ เพื่อใช้เป็นตัวแบบของวิธีการ CDT สำหรับชุดข้อมูลนั้น

4. พยากรณ์ข้อมูลในช่วงเวลาของชุดข้อมูลทดสอบสำหรับตัวแบบแนวโน้มที่มีความแม่นยำสูงสุด

2.3.3 วิธีปรับให้เรียบแบบเอ็กซ์โพเนนเชียลสองครั้ง

วิธี DES เป็นวิธีการสร้างสมการพยากรณ์สำหรับอนุกรมเวลาที่มีแนวโน้มแต่ไม่มีฤดูกาล สำหรับวิธี DES ใช้ค่าปรับให้เรียบ 2 ค่า ได้แก่ α และ β ที่มีค่าระหว่าง 0 ถึง 1 สำหรับปรับระดับ และแนวโน้มตามลำดับ

สมการของตัวปรับระดับดังสมการที่ (6)

$$L_t = \alpha y_t + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (6)$$

สมการของตัวปรับแนวโน้มดังสมการที่ (7)

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1} \quad (7)$$

ตัวแบบพยากรณ์ล่วงหน้า p ค่า ดังสมการที่ (8)

$$\hat{Y}_{t+p} = L_t + pT_t \qquad ; p = 1,2,3,\ldots \quad (8)$$

โดยที่

$\hat{Y}_{t+p}$ แทนข้อมูลอนุกรมเวลา ณ เวลา $t+p$ โดย p เป็นการพยากรณ์ล่วงหน้า และ

α แทนค่าทำให้เรียบสำหรับระดับ และ

β แทนค่าทำให้เรียบสำหรับแนวโน้ม มีขั้นตอนการดำเนินงานดังนี้

ขั้นตอนการพยากรณ์ด้วย DES

1. แบ่งข้อมูลอนุกรมเวลาออกเป็นชุดข้อมูลฝึกสอน และชุดข้อมูลทดสอบ

2. กำหนดค่าพารามิเตอร์การปรับเรียบ ได้แก่ α และ β หาค่าที่เหมาะสมโดย Microsoft Excel Solver เพื่อค้นหาค่าที่ให้ผลการพยากรณ์มีความแม่นยำสูงที่สุด

3. สร้างตัวแบบ DES โดยใช้ข้อมูลชุดฝึกสอน

4. ใช้ตัวแบบที่ได้ค่า α และ β หาค่าที่เหมาะสมพยากรณ์ข้อมูลในช่วงเวลาของชุดข้อมูลทดสอบ

2.3.4 ตัวแบบการพยากรณ์ร่วมระหว่างวิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกที่มีแนวโน้มและวิธีการทำให้เรียบแบบเอ็กซ์โพเนนเชียลสองชั้น

ตัวแบบ CDTDES เป็นตัวแบบการพยากรณ์ร่วมที่พัฒนาขึ้นโดยผสมผสานข้อดีของวิธี CDT และ DES สำหรับข้อมูลอนุกรมเวลาที่มีแนวโน้มแต่ไม่มีองค์ประกอบของฤดูกาล โดยกำหนดให้ค่าพยากรณ์สุดท้ายเป็นค่าเฉลี่ยแบบง่าย (Simple Average) ของค่าพยากรณ์จากทั้งสองตัวแบบ แทนการกำหนดน้ำหนักจากการหาค่าเหมาะสมที่สุด (Optimized Weight) ทั้งนี้ เนื่องจาก CDT และ DES มีหลักการประมาณค่าที่แตกต่างกัน กล่าวคือ CDT เป็นการปรับตัวแบบให้เหมาะสมกับข้อมูลทั้งชุด (Global Fitting) ขณะที่ DES เป็นการปรับค่าพยากรณ์แบบเรียกซ้ำทีละช่วงเวลา (Recursive Updating) ซึ่งโดยธรรมชาติแล้ว DES มักให้ค่าความคลาดเคลื่อนของข้อมูลชุดฝึกสอนต่ำกว่า CDT หากประมาณค่าน้ำหนักจากข้อมูลชุดฝึกสอนโดยตรง น้ำหนักของ CDT จึงมีแนวโน้มถูกประมาณค่าเข้าใกล้ศูนย์ ส่งผลให้ตัวแบบร่วมลดรูปเหลือเพียง DES และไม่สามารถใช้ประโยชน์จากจุดเด่นของ CDT ได้อย่างเต็มที่

การศึกษานี้จึงเลือกใช้ค่าเฉลี่ยแบบง่าย ซึ่งสอดคล้องกับแนวคิดของ Forecast Combination Puzzle ของ Clemen [13] และ Stock and Watson [14] ที่รายงานว่าการถัวเฉลี่ยค่าพยากรณ์อย่างง่ายสามารถให้ผล

การพยากรณ์ข้อมูลนอกชุดฝึกสอน (Out-of-sample) ที่มีความแม่นยำและเสถียรกว่าการประมาณค่าน้ำหนักที่เหมาะสมที่สุด เนื่องจากช่วยลดผลกระทบของความคลาดเคลื่อนจากการประมาณค่า (Estimation Error) ทั้งนี้ แม้จะกำหนดน้ำหนักของค่าพยากรณ์จาก CDT และ DES ให้เท่ากัน แต่พารามิเตอร์ภายในของทั้งสองตัวแบบ ได้แก่ ค่าสัมประสิทธิ์ของสมการแนวโน้มใน CDT และค่าปรับให้เรียบ α และ β ของ DES ยังคงถูกประมาณค่าให้เหมาะสมพร้อมกันด้วยโปรแกรม Microsoft Excel Solver

ตัวแบบพยากรณ์ร่วมสามารถเขียนได้ดังสมการที่ (9)

$$\hat{Y}_{CDTDES,t} = \frac{\hat{Y}_{CDT,t} + \hat{Y}_{DES,t}}{2} \tag{9}$$

โดยที่

$\hat{Y}_{CDTDES,t}$ แทนค่าพยากรณ์ของตัวแบบ CDTDES ณ เวลา t

$\hat{Y}_{CDT,t}$ แทนค่าพยากรณ์ของตัวแบบ CDT ณ เวลา t

$\hat{Y}_{DES,t}$ แทนค่าพยากรณ์ของตัวแบบ DES ณ เวลา t มีขั้นตอนการดำเนินงานดังนี้

ขั้นตอนการพยากรณ์ด้วย CDTDES

1. แบ่งข้อมูลอนุกรมเวลาออกเป็นชุดข้อมูลฝึกสอน และชุดข้อมูลทดสอบ

2. ประมาณค่าพารามิเตอร์ของตัวแบบ CDT และ DES โดยใช้โปรแกรม Microsoft Excel Solver หาค่าที่เหมาะที่สุดในฟังก์ชันวัตถุประสงค์

กำหนดฟังก์ชันวัตถุประสงค์ (Objective Function) ที่ใช้ในการประเมินและหาค่าเหมาะที่สุดของตัวแบบ CDTDES คือ RMSE ซึ่งคำนวณจากข้อมูลชุดฝึกสอน ดังแสดงในสมการ (10)

$$\text{RMSE} = \sqrt{\frac{1}{n_1}\sum_{t=1}^{n_1}\left(Y_t - \hat{Y}_{CDTDES,t}\right)^2} \tag{10}$$

โดยที่ n_1 แทนจำนวนข้อมูลในชุดฝึกสอน

ปัญหาการหาค่าเหมาะที่สุดถูกกำหนดให้อยู่ในรูปของการหาค่าต่ำสุดของ RMSE ภายใต้ข้อจำกัดของพารามิเตอร์ทั้ง 4 ค่าในตัวแบบการพยากรณ์ร่วม CDT ที่มีรูปแบบแนวโน้มเชิงเส้น เอ็กซ์โพเนนเชียลลอการิทึม และกำลัง กับ DES $\left(\hat{\beta}_0, \hat{\beta}_1, \alpha, \beta\right)$ และภายใต้ข้อจำกัดของพารามิเตอร์ทั้ง 5 ค่าในตัวแบบการพยากรณ์ร่วม CDT ที่มีรูปแบบแนวโน้มพหุนามลำดับ 2 กับ DES $\left(\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \alpha, \beta\right)$ โดยกำหนดขอบเขตของค่าพารามิเตอร์แนวโน้ม และพารามิเตอร์การทำให้เรียบ ให้อยู่ภายในช่วงที่กำหนด ดังนี้ [11]

- ค่าพารามิเตอร์การทำให้เรียบ α, β อยู่ในช่วง [0,1]
- ค่าสัมประสิทธิ์ของสมการแนวโน้มถูกกำหนดให้อยู่ภายในช่วง ±20% ของค่าประมาณเริ่มต้น

องค์ประกอบของแนวโน้ม (Trend Component) ที่เป็น แนวโน้มเชิงเส้น แนวโน้มเอ็กซ์โพเนนเชียล แนวโน้มลอการิทึมและแนวโน้มกำลัง สามารถแปลงเป็นตัวแบบสมการเชิงเส้นอย่างง่ายได้ทั้งหมด ดังนั้นเมื่อแปลงเป็นสมการเชิงเส้นอย่างง่าย ($\hat{Y}_t'$) แล้วให้ประมาณค่าพารามิเตอร์ด้วยวิธีกำลังสองน้อยที่สุด (Ordinary Least Squares: OLS) ได้สมการที่ (11)

$$\hat{Y}_t' = \hat{\beta}_0' + \hat{\beta}_1' t \tag{11}$$

กำหนดขอบเขตบน (UB) และขอบเขตล่าง (LB) ของค่าพารามิเตอร์จะอยู่ในช่วงดังสมการที่ (12) และ (13)

$$\hat{\beta}_0 \in \left[\hat{\beta}_0' - 0.2\left|\hat{\beta}_0'\right|, \hat{\beta}_0' + 0.2\left|\hat{\beta}_0'\right|\right] \tag{12}$$

$$\hat{\beta}_1 \in \left[\hat{\beta}_1' - 0.2\left|\hat{\beta}_1'\right|, \hat{\beta}_1' + 0.2\left|\hat{\beta}_1'\right|\right] \tag{13}$$

ในกรณีแนวโน้มพหุนามลำดับ 2 ก็ประมาณ $\hat{\beta}_2'$ เพิ่มเติมเพื่อกำหนดขอบเขตบนและขอบเขตล่างดังสมการที่ (14)

$$\hat{\beta}_2 \in \left[\hat{\beta}_2' - 0.2\left|\hat{\beta}_2'\right|, \hat{\beta}_2' + 0.2\left|\hat{\beta}_2'\right|\right] \tag{14}$$

แล้วให้ประมาณค่าพารามิเตอร์ด้วย OLS ได้สมการที่ (15)

$$\hat{Y}_t' = \hat{\beta}_0' + \hat{\beta}_1' t + \hat{\beta}_2' t^2 \tag{15}$$

3. สร้างตัวแบบ CDTDES ตามสมการที่ (9) ตามค่าพารามิเตอร์เหมาะที่สุด โดยใช้ข้อมูลชุดฝึกสอนจากนั้นจึงคัดเลือกตัวแบบที่ให้ผลการพยากรณ์มีความแม่นยำสูงที่สุดจากทั้งห้าตัวแบบ เพื่อใช้เป็นตัวแบบของวิธีการ CDTDES สำหรับชุดข้อมูลนั้น

4. ใช้ตัวแบบที่ได้พยากรณ์ข้อมูลในช่วงเวลาของชุดข้อมูลทดสอบ

แนวคิดของตัวแบบ CDTDES ได้รับการประยุกต์มาจากงานวิจัยของ Minsan and Minsan [11] ซึ่งพัฒนาตัวแบบการพยากรณ์ร่วมระหว่างวิธีวิเคราะห์อนุกรมเวลาแบบคลาสสิกและวิธี Holt-Winters สำหรับข้อมูลที่มีองค์ประกอบของฤดูกาล อย่างไรก็ตาม เนื่องจากข้อมูลราคาหุ้นในการศึกษาครั้งนี้ไม่มีองค์ประกอบของฤดูกาล จึงได้ปรับวิธีการดังกล่าว

โดยใช้ DES แทน Holt-Winters เพื่อให้เหมาะสมกับลักษณะของข้อมูลอนุกรมเวลาที่ศึกษา

2.3.5 การวิเคราะห์อนุกรมเวลาด้วยวิธีบ็อกซ์-เจนกินส์

วิธีบ็อกซ์-เจนกินส์เป็นวิธีการพยากรณ์ที่อาศัยข้อมูลอนุกรมเวลาในอดีตเพียงอย่างเดียวในการพยากรณ์ค่าในอนาคต โดยพิจารณาภายใต้สมมติฐานว่าอนุกรมเวลามีคุณสมบัติคงที่ การกำหนดตัวแบบจะพิจารณาจาก ACF และค่า PACF เพื่อใช้ในการระบุโครงสร้างของตัวแบบ ซึ่งสามารถเขียนตัวแบบทั่วไปได้ในรูป

$$\text{SARIMA}(p,d,q)(P,D,Q)L$$

โดยที่

p แทนการถดถอยในตัวแบบไม่มีฤดูกาลอันดับ p

P แทนการถดถอยในตัวแบบมีฤดูกาลอันดับ P

q แทนค่าเฉลี่ยเคลื่อนที่แบบไม่มีฤดูกาลอันดับ q

Q แทนค่าเฉลี่ยเคลื่อนที่แบบมีฤดูกาลอันดับ Q

L แทนคาบของฤดูกาลที่คาดว่าข้อมูลจะมีความสัมพันธ์กันเอง กำหนดเป็น 4, 5 และ 6 ตามเวลาการซื้อขายหุ้นในรอบสัปดาห์ แม้ข้อมูลจะไม่พบองค์ประกอบของฤดูกาลอย่างชัดเจน แต่การกำหนดค่า L ดังกล่าวช่วยให้สามารถพิจารณาความสัมพันธ์ของข้อมูลตามคาบที่เกี่ยวข้องกับรอบการซื้อขายหุ้นในหนึ่งสัปดาห์ได้ d และ D คือ ลำดับที่ของการหาผลต่างและผลต่างฤดูกาลของอนุกรมเวลา ตามลำดับ

ขั้นตอนการพยากรณ์ด้วย วิธีบ็อกซ์-เจนกินส์

1. จากการตรวจสอบลักษณะของข้อมูลอนุกรมเวลา ตรวจสอบว่าอนุกรมเวลามีคุณสมบัติคงที่หรือไม่ โดยพิจารณาจากกราฟอนุกรมเวลา กราฟ ACF และผลการทดสอบ ADF หากพบว่าอนุกรมเวลาไม่คงที่ ต้องแปลงอนุกรมเวลาให้คงที่ โดยการหาผลต่าง (Differencing) ตามความเหมาะสม ก่อนดำเนินการกำหนดรูปแบบของตัวแบบบ็อกซ์-เจนกินส์

2. กำหนดตัวแบบพยากรณ์ที่เป็นไปได้จากอนุกรมเวลาใหม่ที่คงที่ นั่นคือ กำหนดค่า p,q,P,Q กำหนดเป็น 0, 1, 2 และดำเนินการแบบค้นหากริด (Grid Search)

3. ประมาณค่าพารามิเตอร์ของตัวแบบ เช่น ประมาณค่าด้วยวิธีกำลังสองน้อยที่สุด

4. คำนวณเกณฑ์สารสนเทศของอะกะอิเกะ (Akaike Information Criterion: AIC) แล้วเรียงลำดับค่า AIC ที่ต่ำที่สุดตามการค้นหา กริด และนำตัวแบบที่ AIC ต่ำที่สุดตรวจสอบความเหมาะสมของตัวแบบ

- การตรวจสอบค่าพารามิเตอร์ โดยใช้สถิติการทดสอบที
- การตรวจสอบความเป็นอิสระของค่าความคลาดเคลื่อนของการพยากรณ์ โดยใช้สถิติการทดสอบ Ljung-Box และการพิจารณา ACF และ PACF ของค่าความคลาดเคลื่อน
- การตรวจสอบการแจกแจงปรกติของค่าความคลาดเคลื่อน โดยสถิติการทดสอบของคอลโมโกรอฟ-สมีร์นอฟ
- การตรวจสอบค่าเฉลี่ยของความคลาดเคลื่อนว่าเท่ากับศูนย์ โดยใช้สถิติทดสอบที
- เพื่อประเมินความคงที่ของความแปรปรวนเบื้องต้น โดยสถิติการทดสอบของเลวีน

หากตัวแบบไม่ผ่านเงื่อนไขใด ๆ ในขั้นตอนการตรวจสอบนี้ ให้ดำเนินการเลือกค่า AIC ในลำดับถัดไปมาตรวจสอบความเหมาะสมของตัวแบบ ถ้าได้ตัวแบบที่เหมาะสมให้หยุดขั้นตอนที่ 4

5. ใช้ตัวแบบที่เหมาะสมที่สุดในขั้นตอนที่ 4 มาพยากรณ์ข้อมูลในช่วงเวลาของชุดข้อมูลทดสอบ

2.3.6 โครงข่ายหน่วยความจำระยะสั้นแบบยาว

LSTM เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่ได้รับการพัฒนาขึ้นเพื่อแก้ปัญหาเกรเดียนต์เลือนหาย ซึ่งมักเกิดขึ้นเมื่อข้อมูลอนุกรมเวลามีลำดับยาว โดยโครงสร้างของ LSTM มีลักษณะคล้ายกับ RNN แต่เพิ่มเติมหน่วยความจำและกลไกควบคุม (Gates) สำหรับกำหนดว่าเมื่อใดควรเก็บ ลืม หรือส่งผ่านข้อมูลในแต่ละช่วงเวลา ส่งผลให้สามารถเรียนรู้ความสัมพันธ์ของข้อมูลในระยะยาวได้อย่างมีประสิทธิภาพ และรองรับข้อมูลอนุกรมเวลาที่มีความซับซ้อนได้ดียิ่งขึ้น [15-16] รหัสเทียมของวิธี LSTM แสดงดังรูปที่ 3

จากรูปที่ 3 การกำหนดชุดค่าพารามิเตอร์สำหรับตัวแบบ LSTM ในการศึกษานี้ อาศัยลักษณะของข้อมูลอนุกรมเวลาในตลาดทุนร่วมกับหลักการออกแบบตัวแบบ LSTM โดยการกำหนดช่วงเวลาย้อนหลัง (Lookback period: LB) ที่ 30, 60 และ 90 วัน เป็นการจำลองพฤติกรรมการจดจำข้อมูลย้อนหลังที่ครอบคลุมรอบระยะเวลาการซื้อขายจริงโดยประมาณ 1.5 เดือน, 1 ไตรมาส (3 เดือน) และ 4.5 เดือน ตามลำดับ ซึ่งช่วยให้ตัวแบบสามารถดักจับความสัมพันธ์ทั้งในระยะสั้นและวงจรการประกาศผลประกอบการระยะกลางได้ สำหรับจำนวนโหนดในชั้นซ่อน (Hidden units: U) และขนาดของแบทช์ (Batch size: B) ที่เลือกใช้ 32 และ 64 ซึ่งเป็นค่าฐานสองตามมาตรฐานสากลนั้น เป็นขนาดที่มีความเหมาะสมกับชุดข้อมูลฝึกสอนจำนวน 1,146 วัน เนื่องจากมีความซับซ้อนเพียงพอในการเรียนรู้รูปแบบที่ไม่เป็นเชิงเส้น แต่ไม่มากจนเกินไปจนเพิ่มความเสี่ยงต่อการเกิดภาวะการเรียนรู้เกิน (Overfitting) ควบคู่ไปกับการกำหนดรอบการฝึกสอน (Epochs: E) ที่ 20 และ 50 รอบ ซึ่งเป็นจุดที่ตัวแบบสามารถลู่เข้าสู่ค่าความคลาดเคลื่อนต่ำสุด (Convergence) ได้อย่างมีประสิทธิภาพ โดยไม่จดจำความผันผวนหรือสัญญาณรบกวน (Noise) ของราคาหุ้นมากเกินความจำเป็น

หลังจากกำหนดค่าพารามิเตอร์ที่เหมาะสมแล้ว ผู้วิจัยทำการสร้างตัวแบบ LSTM โดยใช้ข้อมูลชุดฝึกสอนทั้งหมด และใช้ตัวแบบที่ได้พยากรณ์ข้อมูลชุดทดสอบต่อเนื่องไปข้างหน้าครบ 286 วัน จากจุดเริ่มต้นคงที่ (Fixed-origin) โดยไม่มีการเลื่อนจุดเริ่มต้นของการพยากรณ์และไม่มีการสร้างตัวแบบใหม่ในแต่ละช่วงเวลา

หลังจากกำหนดค่าพารามิเตอร์ที่เหมาะสมแล้ว ผู้วิจัยทำการสร้างตัวแบบ LSTM โดยใช้ข้อมูลชุดฝึกสอนทั้งหมด และใช้ตัวแบบที่ได้พยากรณ์ข้อมูลชุดทดสอบต่อเนื่องไปข้างหน้าครบ 286 วัน จากจุดเริ่มต้นคงที่ (Fixed-origin) โดยไม่มีการเลื่อนจุดเริ่มต้นของการพยากรณ์และไม่มีการสร้างตัวแบบใหม่ในแต่ละช่วงเวลา

3. ผลการวิจัยและอภิปรายผล

ตารางที่ 2 แสดงผลการเปรียบเทียบประสิทธิภาพการพยากรณ์ของวิธีการทั้ง 6 วิธี โดยค่า RMSE เป็นเกณฑ์ในการประเมิน พบว่า ไม่มีวิธีการใดที่ให้ผลการพยากรณ์ดีที่สุดสำหรับข้อมูลทุกชุด แสดงให้เห็นว่าประสิทธิภาพของตัวแบบขึ้นอยู่กับลักษณะของข้อมูลราคาหุ้นแต่ละหลักทรัพย์ โดยตัวแบบการเรียนรู้ LSTM ให้ค่าความคลาดเคลื่อนต่ำที่สุดใน 3 หลักทรัพย์ ได้แก่ BRK.B, TSLA และ AAPL ขณะที่ตัวแบบการพยากรณ์ร่วม CDTDES ซึ่งผู้วิจัยพัฒนาขึ้น ให้ผลการพยากรณ์ดีที่สุดใน 3 หลักทรัพย์ ได้แก่ AVGO, META และ AMZN ส่วนวิธีบ็อกซ์–เจนกินส์ให้ผลดีที่สุดใน 2 หลักทรัพย์ ได้แก่ GOOGL และ MSFT และ FC ให้ผลดีที่สุดในหลักทรัพย์ NVDA เพียง 1 หลักทรัพย์ สำหรับ CDT และวิธี DES ไม่พบว่าให้ค่าความคลาดเคลื่อนต่ำที่สุดในข้อมูลชุดใดเลย

จากรูปที่ 4–7 พบว่า ตัวแบบแต่ละวิธีมีลักษณะการพยากรณ์ที่แตกต่างกันตามโครงสร้างของข้อมูล โดย LSTM ให้ผลการพยากรณ์ที่มีความแม่นยำสูงสำหรับหุ้น BRK.B, TSLA และ AAPL ดังจะเห็นได้จากเส้นพยากรณ์ที่สามารถสะท้อนการเปลี่ยนแปลงของแนวโน้มและความผันผวนของข้อมูลได้ใกล้เคียงกับข้อมูลจริง ผลการศึกษาดังกล่าวแสดงให้เห็นว่า LSTM สามารถให้ผลการพยากรณ์ที่ดีสำหรับหลักทรัพย์ทั้งสามรายการภายใต้ข้อมูลและกรอบการทดลองที่ศึกษา ซึ่งสอดคล้องกับงานวิจัยของ Adebiyi et al. [7] และธรรศทัพพ์ [17] ที่รายงานว่าโครงข่ายประสาทเทียมสามารถเรียนรู้รูปแบบความสัมพันธ์ที่ไม่เป็นเชิงเส้นและความผันผวนของตลาดหุ้นได้ดีกว่าตัวแบบอนุกรมเวลาทางสถิติ

สำหรับตัวแบบ CDTDES ซึ่งเป็นตัวแบบที่ผู้วิจัยพัฒนาขึ้น พบว่าสามารถให้ผลการพยากรณ์ดีที่สุดในหุ้น AVGO, META และ AMZN โดยเส้นพยากรณ์สามารถสะท้อนแนวโน้มระยะยาวของข้อมูลได้อย่างต่อเนื่อง แสดงให้เห็นว่าการรวมค่าพยากรณ์จาก CDT และ DES ช่วยเพิ่มประสิทธิภาพการพยากรณ์เมื่อเทียบกับการใช้ CDT หรือ DES เพียงวิธีเดียว ทั้งนี้ CDT มีข้อดีในการเลือกตัวแบบแนวโน้มที่เหมาะสมกับข้อมูลได้หลายรูปแบบ ขณะที่ DES สามารถปรับค่าประมาณระดับและแนวโน้มของข้อมูลอย่างต่อเนื่องผ่านกระบวนการทำให้เรียบ การรวมข้อดีของทั้งสองวิธีจึงช่วยให้ตัวแบบมีความสามารถในการพยากรณ์ข้อมูลที่มีแนวโน้มได้อย่างมีประสิทธิภาพซึ่งสอดคล้องกับงานวิจัยของ Makridakis et al. [18] ที่ระบุว่าวิธีทางสถิติยังคงมีความโดดเด่นในด้านความเสถียรเมื่อจัดการกับข้อมูลที่มีแนวโน้มชัดเจน

สำหรับวิธีบ็อกซ์–เจนกินส์ พบว่าตัวแบบ SARIMA ให้ผลการพยากรณ์ดีที่สุดสำหรับหุ้น GOOGL และ MSFT ซึ่งมีลักษณะข้อมูลค่อนข้างคงที่เมื่อเปรียบเทียบกับหุ้นกลุ่มอื่น โดยหุ้น GOOGL ได้ตัวแบบ SARIMA$(1,1,0)(1,0,0)_6$ ร่วมกับการแปลงข้อมูล $Y^{0.2}$ ขณะที่หุ้น MSFT ได้ตัวแบบ SARIMA$(0,1,1)(2,0,1)_5$ ร่วมกับการแปลงข้อมูล $Y^{0.2}$ ซึ่งเป็นตัวแบบที่ให้ค่าความคลาดเคลื่อนต่ำที่สุดสำหรับข้อมูลทั้งสองชุด ผลการศึกษาดังกล่าวแสดงให้เห็นว่า วิธีบ็อกซ์–เจนกินส์ยังคงมีประสิทธิภาพสำหรับข้อมูลที่สามารถอธิบายได้ด้วยโครงสร้างเชิงเส้น และมีความคงที่ของอนุกรมเวลาหลังการแปลงข้อมูล โดยการเลือกโครงสร้างของตัวแบบ SARIMA ที่เหมาะสมกับข้อมูลแต่ละชุดมีส่วนสำคัญต่อการเพิ่มประสิทธิภาพของการพยากรณ์

แม้ FC จะให้ผลการพยากรณ์ดีที่สุดเพียง 1 หลักทรัพย์ แต่ยังคงเป็นเครื่องมือที่ได้รับความนิยมในทางปฏิบัติ เนื่องจากสามารถดำเนินการพยากรณ์ได้โดยอัตโนมัติผ่านโปรแกรม Microsoft Excel โดยผู้ใช้ไม่จำเป็นต้องกำหนดโครงสร้างของตัวแบบหรือประมาณค่าพารามิเตอร์ด้วยตนเอง จึงเหมาะสำหรับผู้ใช้ทั่วไปและผู้ปฏิบัติงานที่ต้องการความสะดวกในการวิเคราะห์ข้อมูลอนุกรมเวลา อย่างไรก็ตามผลการศึกษาครั้งนี้พบว่า FC ไม่สามารถให้ผลการพยากรณ์ที่ดีที่สุดได้ในข้อมูลส่วนใหญ่ เมื่อเปรียบเทียบกับตัวแบบที่ผู้วิจัยสร้างขึ้นโดยเฉพาะ เช่น CDTDES หรือ LSTM ซึ่งสะท้อนให้เห็นว่า แม้วิธีการพยากรณ์แบบอัตโนมัติจะมีความสะดวกในการใช้งาน แต่การเลือกตัวแบบและประมาณค่าพารามิเตอร์ให้เหมาะสมกับลักษณะของข้อมูลแต่ละชุดยังคงมีบทบาทสำคัญต่อการเพิ่มประสิทธิภาพของการพยากรณ์

ผลการศึกษาครั้งนี้พบว่า FC ไม่สามารถให้ผลการพยากรณ์ที่ดีที่สุดได้ในข้อมูลส่วนใหญ่เมื่อเปรียบเทียบกับตัวแบบที่ผู้วิจัยสร้างขึ้นโดยเฉพาะ เช่น CDTDES หรือ LSTM ซึ่งสะท้อนให้เห็นว่า แม้วิธีการพยากรณ์แบบอัตโนมัติจะมีความสะดวกในการใช้งาน แต่การเลือกตัวแบบและประมาณค่าพารามิเตอร์ให้เหมาะสมกับลักษณะของข้อมูลแต่ละชุดยังคงมีบทบาทสำคัญต่อการเพิ่มประสิทธิภาพของการพยากรณ์

4. สรุปผล

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพการพยากรณ์ราคาปิดรายวันของหุ้น 9 อันดับแรกในดัชนี S&P 500 โดยเปรียบเทียบวิธีการพยากรณ์ทั้งหมด 6 วิธี ได้แก่ FC, CDT, DES, CDTDES, วิธีบ็อกซ์–เจนกินส์ และ LSTM ภายใต้กรอบการพยากรณ์หลายช่วงเวลาล่วงหน้าจากจุดเริ่มต้นคงที่ และประเมินผลด้วย RMSE ผลการศึกษาพบว่า ไม่มีตัวแบบใดที่เหมาะสมกับข้อมูลทุกชุด โดย LSTM และ CDTDES ให้ผลการพยากรณ์ดีที่สุดจำนวน 3 หลักทรัพย์เท่ากัน ขณะที่วิธีบ็อกซ์–เจนกินส์และ FC ให้ผลดีที่สุดจำนวน 2 และ 1 หลักทรัพย์ ตามลำดับ ส่วน CDT และ DES ไม่พบว่าเป็นวิธีที่ให้ค่าความคลาดเคลื่อนต่ำที่สุดในข้อมูลชุดใด

Define hyperparameter sets: $LB = \{30, 60, 90\}$, $U = \{32, 64\}$, $B = \{32, 64\}$, $E = \{20, 50\}$

Split the time series into training set Y_{train} and testing set Y_{test}

Fit the Min-Max scaler using Y_{train} and Transform Y_{train} and Y_{test} using the scaler fitted on Y_{train}

For each lookback period lb in LB

  Prepare input data based on lb

  For each combination of (U, B, E):

    Build LSTM model with U hidden units and Dense output layer

    Compile the model using Adam optimizer and Mean Squared Error (MSE) loss function

    Train the model using batch size B and epochs E

    Predict scaled fitted values $\hat{Y}_{train}$

    Apply inverse Min-Max transformation to obtain actual fitted values

    Compute RMSE by comparing $\hat{Y}_{train}$ with Y_{train}

    Select parameter set with minimum RMSE

Return optimal hyperparameters

Note: The LSTM architecture differs from the RNN in that it incorporates memory cells and gating mechanisms, which enable more effective learning of long-term dependencies in the data

รูปที่ 3 รหัสเทียมของวิธี LSTM

ตารางที่ 2 สรุปค่า RMSE จากการพยากรณ์ทุกวิธีจำแนกตามรายหุ้น

ชื่อหุ้น	วิธีการ					
	FC	CDT	DES	CDTDES	Box-Jenkins	LSTM
BRK.B	43.739	35.535	49.358	62.132	71.136	**18.008***
AVGO	50.489	48.858	37.773	**26.807***	61.469	27.223
META	114.127	126.668	57.148	**48.040***	127.376	57.016
TSLA	117.524	70.722	131.366	92.542	131.091	**55.739***
GOOGL	17.450	39.875	18.324	52.218	**12.986***	13.276
AMZN	26.709	56.874	26.534	**17.096***	26.297	18.386
AAPL	26.888	23.529	34.325	55.463	35.593	**15.596***
MSFT	42.772	34.737	46.909	79.401	**27.966***	29.844
NVDA	**19.255***	36.049	42.973	42.578	24.028	33.442

หมายเหตุ: * หมายถึง ค่า RMSE ที่น้อยที่สุดสำหรับแต่ละหุ้น

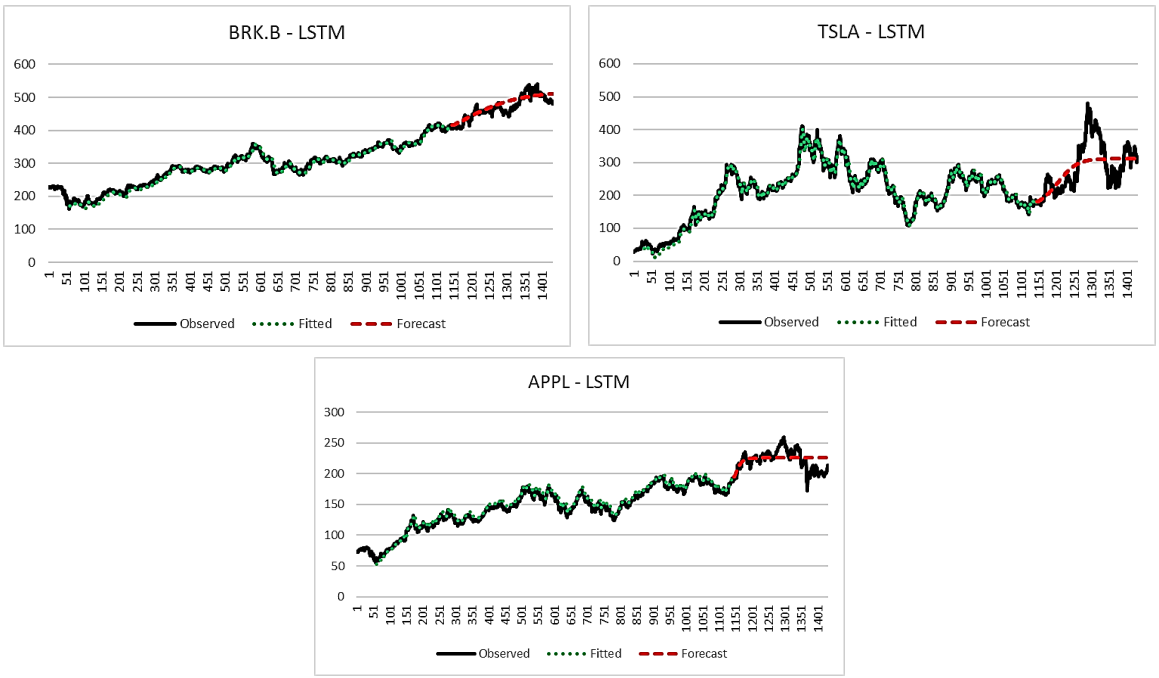

รูปที่ 4 ค่าจริงและค่าพยากรณ์ล่วงหน้า 286 วันของราคาปิดของหุ้น 3 หุ้น โดยใช้วิธีการพยากรณ์ LSTM

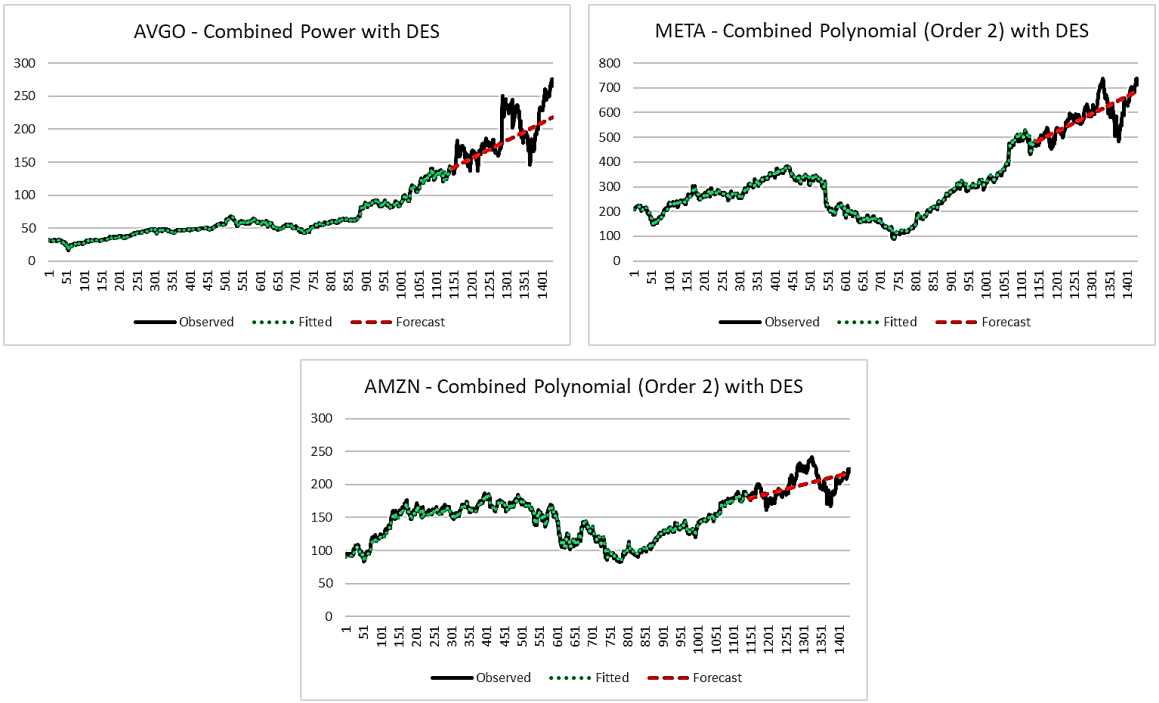

รูปที่ 5 ค่าจริงและค่าพยากรณ์ล่วงหน้า 286 วันของราคาปิดของหุ้น 3 หุ้น โดยใช้วิธีการพยากรณ์ CDTDES

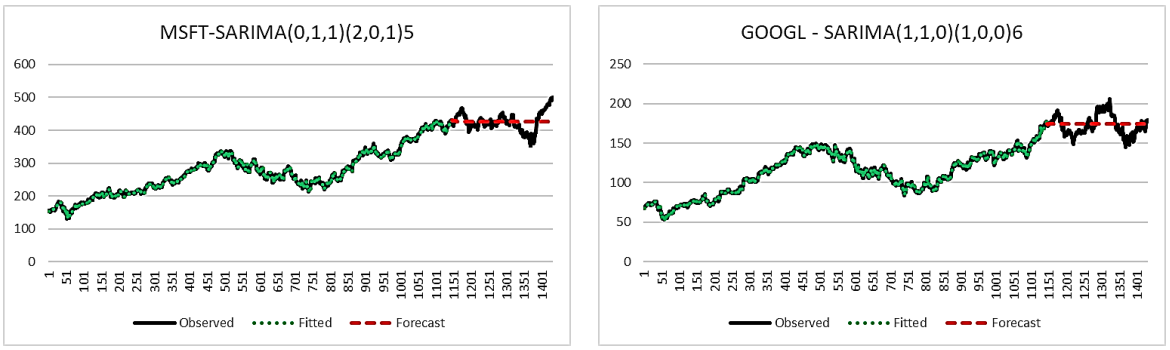

รูปที่ 6 ค่าจริงและค่าพยากรณ์ล่วงหน้า 286 วันของราคาปิดของหุ้น 2 หุ้น โดยใช้วิธีการพยากรณ์ Box-Jenkins ตัวแบบ SARIMA

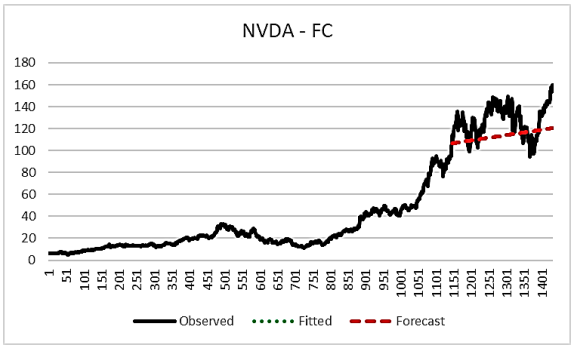

รูปที่ 7 ค่าจริงและค่าพยากรณ์ล่วงหน้า 286 วันของราคาปิดของหุ้น 1 หุ้น โดยใช้วิธีการพยากรณ์ FC

หมายเหตุ: วิธี FC ไม่แสดงค่า Fitted ในการแสดงผล

ผลการวิจัยสำหรับข้อมูลที่ศึกษาชี้ให้เห็นว่าความแม่นยำของการพยากรณ์ขึ้นอยู่กับลักษณะของข้อมูลอนุกรมเวลา โดย LSTM สามารถเรียนรู้ความสัมพันธ์ที่ไม่เป็นเชิงเส้นของข้อมูลได้ CDTDES เหมาะกับข้อมูลที่มีแนวโน้มเด่นชัด และวิธีบ็อกซ์–เจนกินส์ยังคงเป็นอีกทางเลือกที่มีประสิทธิภาพสำหรับข้อมูลที่สามารถอธิบายได้ด้วยโครงสร้างเชิงเส้นของ SARIMA และมีคุณสมบัติคงที่หลังการแปลงข้อมูลตามความเหมาะสม นอกจากนี้ ผลการศึกษายังสะท้อนให้เห็นว่า การเลือกใช้ตัวแบบให้เหมาะสมกับลักษณะของข้อมูลมีความสำคัญมากกว่าการเลือกใช้วิธีการใดวิธีการหนึ่งเพียงอย่างเดียว และในการพยากรณ์ระยะยาว ผู้วิเคราะห์ควรพิจารณาลักษณะของแนวโน้มที่คาดว่าจะเกิดขึ้นร่วมกับผลการพยากรณ์ของตัวแบบ กล่าวคือ หากข้อมูลมีรูปแบบการเปลี่ยนแปลงที่ซับซ้อนและไม่สามารถอธิบายได้ด้วยความสัมพันธ์เชิงเส้นอย่างเพียงพอ ตัวแบบ LSTM อาจเป็นทางเลือกที่เหมาะสมกว่า ในขณะที่กรณีที่ข้อมูลมีแนวโน้มเพิ่มขึ้นหรือลดลงในอัตราค่อนข้างคงที่ ตัวแบบ CDTDES อาจให้ผลการพยากรณ์ที่เหมาะสมกว่า ส่วนข้อมูลที่มีลักษณะค่อนข้างคงที่และสามารถอธิบายได้ด้วยโครงสร้างเชิงเส้น วิธีบ็อกซ์–เจนกินส์ยังคงเป็นอีกทางเลือกที่มีประสิทธิภาพ ผลการศึกษานี้จึงชี้ให้เห็นว่าความรู้เกี่ยวกับคุณลักษณะของข้อมูลและวิจารณญาณของผู้วิเคราะห์ยังคงมีบทบาทสำคัญต่อการคาดการณ์แนวโน้มราคาหุ้นในระยะยาว

ในทางการประยุกต์ใช้ ผลการศึกษาสามารถใช้เป็นแนวทางประกอบการเลือกวิธีการพยากรณ์ราคาหุ้นสำหรับการวิเคราะห์แนวโน้มในระยะยาว โดยผู้วิเคราะห์ควรพิจารณาลักษณะของข้อมูลและแนวโน้มที่คาดว่าจะเกิดขึ้นร่วมกับผลการพยากรณ์ของแต่ละตัวแบบ ไม่ควรพิจารณาจากวิธีการใดวิธีการหนึ่งเพียงอย่างเดียว

ข้อจำกัดของการวิจัย คือ การศึกษาครั้งนี้พิจารณาหุ้นจำนวน 9 หลักทรัพย์ในดัชนี S&P 500 และใช้ข้อมูลในช่วงวันที่ 1 มกราคม พ.ศ. 2563 ถึงวันที่ 3 กรกฎาคม พ.ศ. 2568 ดังนั้น ผลการศึกษาจึงอยู่ภายใต้ขอบเขตของหลักทรัพย์และช่วงเวลาที่ศึกษา และสามารถใช้เป็นข้อมูลประกอบการพิจารณาความเหมาะสมของตัวแบบสำหรับการพยากรณ์ราคาหุ้นในบริบทที่มีลักษณะใกล้เคียงกับข้อมูลที่ศึกษา และการศึกษาครั้งนี้เลือกใช้ RMSE เป็นเกณฑ์ในการประเมินประสิทธิภาพของตัวแบบ เนื่องจาก RMSE ให้น้ำหนักกับค่าความคลาดเคลื่อนขนาดใหญ่มากกว่าค่าความคลาดเคลื่อนขนาดเล็ก ซึ่งสอดคล้องกับวัตถุประสงค์ของการศึกษาที่มุ่งเปรียบเทียบความแม่นยำของการพยากรณ์ราคาปิดของหุ้น ทั้งนี้ หากการศึกษามีวัตถุประสงค์หรือมุ่งเน้นประเด็นอื่น ผู้วิจัยสามารถ

เลือกใช้ตัวชี้วัดการประเมินประสิทธิภาพอื่น ๆ ได้ตามความเหมาะสมของลักษณะข้อมูลและวัตถุประสงค์ของการวิจัย

สำหรับการวิจัยในอนาคต ควรขยายการศึกษาไปยังหลักทรัพย์จากกลุ่มอุตสาหกรรมและตลาดที่หลากหลาย รวมทั้งพิจารณาช่วงเวลาที่แตกต่างกัน เพื่อศึกษาความสม่ำเสมอของผลการพยากรณ์ นอกจากนี้อาจพิจารณาเกณฑ์การประเมินประสิทธิภาพอื่นร่วมกับ RMSE และศึกษาวิธีการพยากรณ์หรือแนวทางการปรับพารามิเตอร์ที่หลากหลายมากขึ้น เพื่อให้สามารถประเมินประสิทธิภาพของตัวแบบได้ครอบคลุมยิ่งขึ้น

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ และภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่ ที่ให้ความอนุเคราะห์ด้านอุปกรณ์และสถานที่สำหรับการดำเนินการวิจัยในครั้งนี้

เอกสารอ้างอิง

[1] Hyndman, R. J., and Athanasopoulos, G. (2018). Forecasting: Principles and practice (2nd ed.). OTexts. https://otexts.com/fpp2/

[2] Holt, C. C. (1957). Forecasting seasonals and trends by exponentially weighted moving averages (O.N.R. Memorandum No. 52). Carnegie Institute of Technology. https://doi.org/10.1016/j.ijforecast.2003.09.015

[3] Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. Management Science, 6(3), 324–342. https://doi.org/10.1287/mnsc.6.3.324

[4] Box, G. E. P., Jenkins, G. M., and Reinsel, G. C. (1994). Time series analysis: Forecasting and control (3rd ed.). John Wiley&Sons, New Jersey.

[5] Minsan, P., and Minsan, W. (2025). Forecasting rainfall in the Ping, Wang, Yom, and Nan River basins of Thailand using decomposition and Holt-Winters methods enhanced by GRG nonlinear optimization. ASEAN Journal of Scientific and Technological Reports, 28(5), Article e259297. https://doi.org/10.55164/ajstr.v28i5.259297

[6] กาญจนา ทองบุญนาค, และ วิระภรณ์ ไหมทอง. (2568). การประมาณค่าพารามิเตอร์เหมาะที่สุดในวิธีโฮลต์-วินเทอร์และการแยกส่วนประกอบด้วยอัลกอริทึมการค้นหาแบบนกกาเหว่า: การพยากรณ์ปริมาณน้ำไหลรายเดือนเข้าสู่อ่างเก็บน้ำของเขื่อนขนาดใหญ่ในภาคกลางและภาคตะวันตกของประเทศไทย. วารสารวิทยาศาสตร์และเทคโนโลยีสู่ชุมชน, 3(5), 1–23. https://doi.org/10.57260/stc.2025.1089

[7] Adebiyi, A. A., Adewumi, A. O., and Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. Journal of Applied Mathematics, 2014, Article 614342. https://doi.org/10.1155/2014/614342

[8] Hochreiter, S. (1991). Untersuchungen zu dynamischen neuronalen Netzen [Diploma thesis, Technische Universität München]. https://www.bioinf.jku.at/publications/older/3804.pdf

[9] Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735

[10] Qiu, J., Wang, B., and Zhou, C. (2020). Forecasting stock prices with long-short term memory neural network based on attention mechanism. PLOS ONE, 15(1), Article e0227222. https://doi.org/10.1371/journal.pone.0227222

[11] Minsan, P., and Minsan, W. (2026). Optimizing combined Holt–Winters and decomposition forecasting models with the whale optimization algorithm for monthly maximum of daily 24-hour average PM2.5 concentrations in the Bangkok metropolitan region. Science & Technology Asia, 31(1), 1–17. https://doi.org/10.14456/scitechasia.2026.1

[12] MarketWatch. (2025). Source: https://www.marketwatch.com. Accessed on December 17, 2025.

[13] Clemen, R. T. (1989). Combining forecasts: A review and annotated bibliography. International Journal of Forecasting, 5(4), 559–583. https://doi.org/10.1016/0169-2070(89)90012-5

[14] Stock, J. H., and Watson, M. W. (2004, September 20). Combination forecasts of output growth in a seven-country data set. Journal of Forecasting, 23(6), 405–430. https://doi.org/10.1002/for.928

[15] รักษ์คณา ภูสีเขียว. (2564).การพยากรณ์ปริมาณน้ำฝนระยะสั้นในบริเวณพื้นที่สนามบินสุวรรณภูมิด้วยโครงข่ายระบบประสาทแบบย้อนกลับ [วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย]. Chulalongkorn University Theses and Dissertations (Chula ETD). https://doi.org/10.58837/CHULA.THE.2021.1060

[16] Olah, C. (2015, August 27). Understanding LSTM networks. colah's blog. https://colah.github.io/posts/2015-08-Understanding-LSTMs/

[17] ธรรศทัพพ์ สงวนสุข. (2567). วิเคราะห์เปรียบเทียบการพยากรณ์ความผันผวนของราคาหุ้นระหว่าง GARCH และ machine learning/deep learning [วิทยานิพนธ์ปริญญามหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์]. https://ethesisarchive.library.tu.ac.th/thesis/2024/TU_2024_6602110550_20340_31458.pdf

[18] Makridakis, S., Spiliotis, E. and Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. PLOS ONE, 13(3), Article e0194889. https://doi.org/10.1371/journal.pone.0194889