

FORECASTING APPLE INC. STOCK PRICES: A COMPARATIVE TIME SERIES ANALYSIS ACROSS MULTIPLE FORECAST HORIZONS

Sirawish TINTANON¹, Watcharin YAKIT¹, Porjai KLINNGAM¹ and Raweewan LENGKAYAN^{1*}

¹ Financial Engineering, School of Science and Technology, University of the Thai Chamber of Commerce, Thailand; raweewan_jen@utcc.ac.th (Corresponding Author)

ARTICLE HISTORY

Received: 10 April 2026

Revised: 24 April 2026

Published: 16 May 2026

ABSTRACT

This study evaluates the forecasting performance of time series models for Apple Inc. (AAPL) monthly closing prices from 2020 to 2025. Three methodologies were compared: Multiplicative Seasonal Decomposition, Holt's Linear Trend, and ARIMA modeling within the Box-Jenkins framework. The analytical process involved Augmented Dickey-Fuller (ADF) stationarity testing, model identification via ACF/PACF, and out-of-sample forecast evaluation using MAE, RMSE, and MAPE metrics. The results indicate that while AAPL stock prices are non-stationary at levels, first-order differencing achieves stationarity ($d = 1$). The comparative analysis reveals that the ARIMA(0,1,0) model, representing a Random Walk process, demonstrated superior accuracy for a long-term 12-month horizon, consistent with the characteristics of efficient markets. Conversely, Holt's Linear Trend yielded the lowest error metrics for short-to-medium-term forecasts (3-6 months). Seasonal Decomposition performed poorly across all horizons due to high stochastic volatility. These findings underscore that model effectiveness is horizon-dependent, suggesting that investors must strategically select forecasting tools based on specific investment timeframes and risk management objectives.

Keywords: Time Series Analysis, ARIMA Model, Holt's Linear Trend, Seasonal Decomposition, Apple Inc. (AAPL)

CITATION INFORMATION: Tintanon, S., Yakıt, W., Klinngam, P., & Lengkayan, R. (2026). Forecasting Apple Inc. Stock Prices: A Comparative Time Series Analysis across Multiple Forecast Horizons. *Procedia of Multidisciplinary Research*, 4(5), 38

การวิเคราะห์ประสิทธิภาพของแบบจำลองอนุกรมเวลาในการพยากรณ์ราคาหุ้น Apple Inc. ภายใต้กรอบเวลาการพยากรณ์ที่แตกต่างกัน

ศิริวิชญ์ ดินตานนท์¹, วัชรินทร์ ยะกิจ¹, พอใจ กลิ่นงาม¹ และ ระวีวรรณ เหลียงขยัน^{1*}

1 คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย; raweewan_len@utcc.ac.th (ผู้ประพันธ์
บรรณกิจ)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อประเมินประสิทธิภาพการพยากรณ์รายเดือนของหุ้น Apple Inc. (AAPL) ระหว่างปี พ.ศ.2563 ถึง 2568 โดยเปรียบเทียบ 3 วิธีการหลัก ได้แก่ การแยกองค์ประกอบเชิงฤดูกาล (Seasonal Decomposition) วิธีของ Holt's Linear Trend และแบบจำลอง ARIMA ภายใต้กรอบแนวคิดของ Box-Jenkins กระบวนการวิเคราะห์ประกอบด้วยการทดสอบความนิ่งของข้อมูลด้วยวิธี ADF การระบุรูปแบบจำลองผ่านค่า ACF/PACF และการประเมินความแม่นยำนอกกลุ่มตัวอย่าง (Out-of-sample) ด้วยค่าดัชนีความคลาดเคลื่อน MAE, RMSE และ MAPE ผลการศึกษาพบว่าราคาหุ้น AAPL มีลักษณะไม่คงที่ (Non-stationary) ในระดับ Level แต่มีความนิ่งหลังจากหาผลต่างลำดับที่ 1 ($d = 1$) ผลการเปรียบเทียบชี้ให้เห็นว่า แบบจำลอง ARIMA(0,1,0) หรือรูปแบบการเดินสุ่ม (Random Walk) ให้ความแม่นยำสูงสุดสำหรับการพยากรณ์ระยะยาวในกรอบเวลา 12 เดือน ซึ่งสอดคล้องกับคุณลักษณะของตลาดที่มีประสิทธิภาพ ในขณะที่วิธีของ Holt's Linear Trend ให้ค่าความคลาดเคลื่อนต่ำที่สุดสำหรับการพยากรณ์ระยะสั้นถึงระยะกลาง (3-6 เดือน) อย่างไรก็ตาม วิธีการแยกองค์ประกอบเชิงฤดูกาลให้ผลการพยากรณ์ที่คลาดเคลื่อนสูงในทุกช่วงเวลา ข้อค้นพบนี้บ่งชี้ว่า ประสิทธิภาพของแบบจำลองขึ้นอยู่กับระยะเวลาของการพยากรณ์ (Horizon-dependent) ดังนั้น การเลือกใช้แบบจำลองควรพิจารณาให้สอดคล้องกับเป้าหมายการลงทุนและการบริหารความเสี่ยงในแต่ละกรอบเวลา

คำสำคัญ: การวิเคราะห์อนุกรมเวลา, แบบจำลอง ARIMA, การพยากรณ์แนวโน้มด้วยวิธีของ Holt, การแยกองค์ประกอบเชิงฤดูกาล, ราคาหุ้น AAPL

ข้อมูลอ้างอิง: ศิริวิชญ์ ดินตานนท์, วัชรินทร์ ยะกิจ, พอใจ กลิ่นงาม และ ระวีวรรณ เหลียงขยัน. (2569). การวิเคราะห์ประสิทธิภาพของแบบจำลองอนุกรมเวลาในการพยากรณ์ราคาหุ้น Apple Inc. ภายใต้กรอบเวลาการพยากรณ์ที่แตกต่างกัน. *Procedia of Multidisciplinary Research*, 4(5), 38

บทนำ

ในบริบทของตลาดทุนสมัยใหม่ ความผันผวนของราคาหุ้นนับเป็นปัจจัยสำคัญที่ส่งผลต่อการตัดสินใจลงทุน นักลงทุนจึงจำเป็นต้องอาศัยเครื่องมือเชิงปริมาณที่สามารถวิเคราะห์และพยากรณ์แนวโน้มราคาได้อย่างเป็นระบบ การวิเคราะห์อนุกรมเวลา (Time Series Analysis) จึงได้รับการยอมรับอย่างแพร่หลาย เนื่องจากสามารถอธิบายโครงสร้างของข้อมูลตามลำดับเวลาและพัฒนาแบบจำลองเพื่อพยากรณ์ค่าในอนาคตได้อย่างมีประสิทธิภาพ หุ้นของ Apple Inc. (AAPL) เป็นหลักทรัพย์ที่มีมูลค่าตลาดสูงและมีบทบาทสำคัญในตลาดทุนโลก โดยมีลักษณะข้อมูลที่สะท้อนทั้งแนวโน้มการเติบโตในระยะยาวและความผันผวนในระยะสั้น จึงเหมาะสมสำหรับการศึกษาเชิงเปรียบเทียบแบบจำลองการพยากรณ์ การศึกษานี้ประยุกต์ใช้แบบจำลองเชิงสถิติ 3 วิธี ได้แก่ Seasonal Decomposition, Holt Exponential Smoothing และ ARIMA ภายใต้กรอบแนวคิด Box-Jenkins เพื่อวิเคราะห์และพยากรณ์ข้อมูลราคาหุ้น วัตถุประสงค์ของการศึกษาคือการเปรียบเทียบประสิทธิภาพของแบบจำลองดังกล่าว โดยประเมินความแม่นยำผ่านข้อมูลทดสอบนอกกลุ่มตัวอย่างในหลายกรอบเวลาการพยากรณ์อย่างใดก็ตาม งานวิจัยส่วนใหญ่มักประเมินแบบจำลองภายใต้กรอบเวลาเพียงช่วงเดียว และมีการเปรียบเทียบแบบจำลองบนชุดข้อมูลเดียวกันอย่างจำกัด โดยเฉพาะในกรณีของหุ้น AAPL ซึ่งงานศึกษาที่มีอยู่ เช่น Xia (2023) และ Sharif and Hasan (2019) มุ่งเน้นการใช้แบบจำลองเพียงประเภทเดียว ส่งผลให้ขาดหลักฐานเชิงประจักษ์ในการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองในหลายช่วงเวลา ดังนั้นการศึกษานี้จึงมุ่งเปรียบเทียบแบบจำลอง Seasonal Decomposition, Holt Exponential Smoothing และ ARIMA บนข้อมูลรายเดือนของหุ้น AAPL ในช่วงหลังวิกฤต COVID-19 พร้อมประเมินความแม่นยำในการพยากรณ์ใน 3 กรอบเวลา ได้แก่ 3 เดือน 6 เดือน และ 12 เดือน เพื่อสนับสนุนการเลือกใช้แบบจำลองให้เหมาะสมกับวัตถุประสงค์การลงทุนในแต่ละช่วงเวลา

ทบทวนวรรณกรรม

การพยากรณ์ข้อมูลอนุกรมเวลา (Time Series Forecasting) เป็นเครื่องมือสำคัญในงานด้านการเงินเชิงปริมาณ โดยเฉพาะการวิเคราะห์ราคาหุ้นซึ่งมีลักษณะความผันผวนสูงและเปลี่ยนแปลงตามเวลาอย่างต่อเนื่อง แบบจำลองเชิงสถิติแบบดั้งเดิม เช่น ARIMA และ Exponential Smoothing ยังคงได้รับความนิยมอย่างแพร่หลาย เนื่องจากสามารถอธิบายโครงสร้างของข้อมูลและให้ผลการพยากรณ์ที่มีความแม่นยำในระดับที่น่าพอใจ แนวคิดพื้นฐานของแบบจำลอง ARIMA ได้รับการพัฒนาโดย Box and Jenkins (2015) ซึ่งเสนอกรอบแนวคิดอย่างเป็นระบบในการสร้างแบบจำลองผ่านขั้นตอนการระบุรูปแบบ (Identification) การประมาณค่าพารามิเตอร์ (Estimation) และการตรวจสอบความเหมาะสมของแบบจำลอง (Diagnostic Checking) โดยเงื่อนไขสำคัญของการใช้แบบจำลองดังกล่าวคือข้อมูลต้องมีความนิ่ง (Stationarity) ซึ่งสามารถตรวจสอบได้ด้วยการทดสอบหน่วยราก เช่น Augmented Dickey-Fuller (ADF) test ที่พัฒนาโดย Dickey and Fuller (1979) ในอีกด้านหนึ่ง วิธีการปรับเรียบด้วยเส้นโค้งเลขชี้กำลัง (Exponential Smoothing) โดยเฉพาะวิธีของ Holt ได้ถูกพัฒนาเพื่อรองรับข้อมูลที่มีแนวโน้ม (Trend) โดยสามารถปรับค่าระดับและแนวโน้มได้พร้อมกัน ทำให้เหมาะสมกับข้อมูลที่ไม่มีรูปแบบฤดูกาลที่ซับซ้อน (Holt, 2004) งานวิจัยของ Sharif and Hasan (2019) สนับสนุนว่า รูปแบบดังกล่าวสามารถให้ผลการพยากรณ์ที่มีความแม่นยำสูงในระยะสั้น โดยเฉพาะข้อมูลราคาหุ้นที่มีแนวโน้มต่อเนื่อง สำหรับการประยุกต์ใช้ในตลาดหุ้น งานของ Yoo (2007) และ Xia (2023) พบว่าแบบจำลอง ARIMA สามารถอธิบายพฤติกรรมของราคาหุ้นและให้ผลการพยากรณ์ที่มีประสิทธิภาพ โดยเฉพาะเมื่อมีการกำหนดพารามิเตอร์ที่เหมาะสมและข้อมูลผ่านการปรับให้อยู่ในรูปแบบนิ่งแล้ว อย่างไรก็ตาม Brockwell and Davis (2016) อธิบายว่า แม้ ARIMA จะมีความสามารถในการจับโครงสร้างเชิงสถิติของข้อมูลได้ดี แต่ประสิทธิภาพของแบบจำลองอาจลดลงเมื่อใช้ในการพยากรณ์ระยะยาว เนื่องจากความไม่แน่นอนของข้อมูลที่เพิ่มขึ้น ในบริบทของประเทศไทย ธนพล ศรีสุข (2563) ได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง ARIMA และ Exponential Smoothing และพบว่า ไม่มีแบบจำลองใดที่ดีที่สุดในทุกกรณี โดย ARIMA เหมาะกับข้อมูลที่มีโครงสร้างเชิงสถิติชัดเจน

ขณะที่ Exponential Smoothing เหมาะกับข้อมูลที่มีแนวโน้มและต้องการการพยากรณ์ระยะสั้น นอกจากนี้ แนวคิดของ Hyndman and Athanasopoulos (2021) ยังชี้ให้เห็นว่า ความแม่นยำของแบบจำลองอนุกรมเวลามีความสัมพันธ์กับช่วงเวลาการพยากรณ์ (Forecast Horizon) กล่าวคือ แบบจำลองส่วนใหญ่จะให้ผลลัพธ์ที่ดีในระยะสั้น แต่มีข้อจำกัดในระยะยาว ซึ่งสอดคล้องกับหลักการที่ว่าไม่มีแบบจำลองใดสามารถให้ผลการพยากรณ์ที่ดีที่สุดได้ในทุกช่วงเวลา (No single best model) จากการทบทวนวรรณกรรมข้างต้น พบว่า งานวิจัยส่วนใหญ่มุ่งเน้นการใช้แบบจำลองเพียงประเภทเดียวหรือประเมินผลในช่วงเวลาการพยากรณ์ที่จำกัด แม้จะมีการศึกษาที่ใช้ข้อมูลราคาหุ้น Apple Inc. จากแหล่งข้อมูล เช่น Yahoo Finance (2025) แต่ยังขาดการเปรียบเทียบแบบจำลองหลายประเภทภายใต้หลายช่วงเวลาการพยากรณ์อย่างเป็นระบบ ดังนั้น การศึกษานี้จึงมุ่งเปรียบเทียบแบบจำลอง Seasonal Decomposition, Holt Exponential Smoothing และ ARIMA บนข้อมูลเดียวกัน และประเมินผลในหลายกรอบเวลา (3, 6 และ 12 เดือน) เพื่อเติมเต็มช่องว่างในวรรณกรรม และสนับสนุนการเลือกใช้แบบจำลองให้เหมาะสมกับวัตถุประสงค์การลงทุนในแต่ละช่วงเวลา

วิธีดำเนินการวิจัย

การศึกษานี้ใช้ข้อมูลราคาปิดรายเดือน (Monthly Closing Price) ของหุ้น Apple Inc. (AAPL) ในช่วงเดือนมกราคม พ.ศ.2563 ถึงเดือนธันวาคม พ.ศ.2568 รวมระยะเวลา 72 เดือน โดยรวบรวมข้อมูลจากฐานข้อมูล Yahoo Finance (2025) ทั้งนี้ การกำหนดช่วงเวลาเริ่มต้น ณ ปี พ.ศ.2563 มีวัตถุประสงค์เพื่อหลีกเลี่ยงผลกระทบจากการเปลี่ยนแปลงเชิงโครงสร้าง (Structural Break) ของตลาดหุ้นในช่วงก่อนหน้า อันเนื่องมาจากวิกฤตการแพร่ระบาดของ COVID-19 ซึ่งส่งผลให้ข้อมูลมีความผันผวนผิดปกติ (Abnormal Volatility) และเกิดค่าผิดปกติ (Outliers) ดังนั้น ช่วงเวลาดังกล่าวจึงสามารถสะท้อนพฤติกรรมราคาหุ้นภายใต้บริบทของสถานะตลาดในยุค “New Normal” ได้อย่างเหมาะสม และช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบแนวโน้ม (Trend) และฤดูกาล (Seasonality) ได้อย่างมีประสิทธิภาพ ข้อมูลถูกแบ่งออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลฝึกสอน (Training Set) ตั้งแต่เดือนมกราคม พ.ศ.2563 ถึงเดือนธันวาคม พ.ศ.2567 จำนวน 60 ค่า สำหรับการสร้างและประมาณค่าพารามิเตอร์ของแบบจำลอง และชุดข้อมูลทดสอบ (Test Set) ตั้งแต่เดือนมกราคม พ.ศ.2568 ถึงเดือนธันวาคม พ.ศ.2568 จำนวน 12 ค่า เพื่อใช้ในการประเมินความแม่นยำของการพยากรณ์นอกกลุ่มตัวอย่าง (Out-of-sample Forecasting) การวิเคราะห์ข้อมูลดำเนินการด้วยโปรแกรมภาษา Python โดยพัฒนาและเปรียบเทียบแบบจำลองอนุกรมเวลา 3 วิธี ได้แก่ 1) การแยกองค์ประกอบ (Seasonal Decomposition) โดยใช้รูปแบบ Multiplicative เนื่องจากลักษณะความผันผวนเชิงฤดูกาลมีความสัมพันธ์กับระดับของข้อมูล 2) วิธีการทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt (Holt's Exponential Smoothing) ซึ่งเหมาะสำหรับข้อมูลที่มีแนวโน้ม และ 3) แบบจำลอง ARIMA ภายใต้กรอบแนวคิด Box-Jenkins สำหรับการวิเคราะห์โครงสร้างเชิงสถิติของอนุกรมเวลา ทั้งนี้ ความแม่นยำของแบบจำลองถูกประเมินด้วยตัวชี้วัดทางสถิติ ได้แก่ Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) และ Mean Absolute Percentage Error (MAPE) เพื่อเปรียบเทียบประสิทธิภาพของแต่ละวิธีอย่างเป็นระบบ

ขั้นตอนการสร้างและเปรียบเทียบแบบจำลอง

กระบวนการพัฒนาและประเมินแบบจำลองประกอบด้วยขั้นตอนสำคัญดังต่อไปนี้

1) การศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ทบทวนแนวคิดและหลักการของการวิเคราะห์อนุกรมเวลา รวมถึงกรอบแนวคิด Box-Jenkins สำหรับแบบจำลอง ARIMA วิธีการแยกองค์ประกอบ และวิธี Holt Exponential Smoothing เพื่อกำหนดแนวทางการพัฒนาแบบจำลองที่เหมาะสม

2) การรวบรวมและเตรียมข้อมูล

รวบรวมข้อมูลราคาปิดรายเดือนของหุ้น AAPL จาก Yahoo Finance และดำเนินการตรวจสอบคุณสมบัติของข้อมูล โดยทดสอบความนิ่ง (stationarity) ด้วยวิธี Augmented Dickey-Fuller (ADF) Test หากข้อมูลไม่นิ่งจะทำการหา

ผลต่าง (differencing) เพื่อให้ได้อนุกรมเวลาที่มีคุณสมบัติเหมาะสมสำหรับการสร้างแบบจำลอง นอกจากนี้ ได้ทำการวิเคราะห์แยกองค์ประกอบของอนุกรมเวลาเพื่อระบุแนวโน้ม (trend) และฤดูกาล(seasonality)

3) การสร้างและประมาณค่าแบบจำลอง


พัฒนาแบบจำลองทั้งสามรูปแบบ ได้แก่ Seasonal Decomposition, Holt's Exponential Smoothing และ ARIMA โดยสำหรับ ARIMA ใช้วิธีการระบุลำดับโมเดล (model identification) ผ่านการพิจารณา ACF, PACF และเกณฑ์สารสนเทศ เช่น AIC และ BIC จากนั้นดำเนินการประมาณค่าพารามิเตอร์ด้วยวิธี Maximum Likelihood Estimation และตรวจสอบความเหมาะสมของโมเดลผ่านการวิเคราะห์เศษเหลือ (diagnostic checking)

4) การประเมินประสิทธิภาพและการคัดเลือกแบบจำลอง

เปรียบเทียบความแม่นยำของแต่ละแบบจำลองโดยใช้ข้อมูลทดสอบปี พ.ศ.2568 และคำนวณค่าดัชนี MAE, RMSE และ MAPE เพื่อประเมินประสิทธิภาพการพยากรณ์ในแต่ละกรอบเวลา (3, 6 และ 12 เดือน) ก่อนคัดเลือกแบบจำลองที่มีความเหมาะสมที่สุดสำหรับการพยากรณ์ราคาหุ้น AAPL

ผลการวิจัย

ผลการวิจัยในบทนี้นำเสนอผลการวิเคราะห์ข้อมูลตามวัตถุประสงค์ของการวิจัย โดยประยุกต์ใช้แบบจำลอง Seasonal Decomposition Holt Exponential Smoothing และ ARIMA ในการวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลา ผลการวิจัยประกอบด้วย การเปรียบเทียบค่าจริงกับค่าพยากรณ์ของแต่ละแบบจำลอง รวมถึงการรายงานค่าดัชนีวัดความแม่นยำ เพื่อใช้ในการประเมินประสิทธิภาพและความเหมาะสมของแบบจำลองที่ใช้ในการศึกษา



ภาพที่ 1 แนวโน้มราคาหุ้นรายเดือนของบริษัท Apple Inc. ช่วงปี 2020-2025

จากภาพที่ 1 แสดงแนวโน้มราคาหุ้นรายเดือนช่วงปี 2020-2025 พบว่า ราคาหุ้นมีแนวโน้มเพิ่มขึ้นโดยรวม แม้มีความผันผวนในบางช่วงเวลา แต่แนวโน้มระยะยาวยังคงเป็นขาขึ้นอย่างชัดเจน สะท้อนลักษณะข้อมูลที่มีแนวโน้ม (trend) ต่อเนื่อง


ตารางที่ 1 ค่า Seasonal Index จากการวิเคราะห์ Seasonal Decomposition

S_1	1.015506	S_5	0.964266	S_9	0.967379
S_2	0.964940	S_6	0.999501	S_{10}	0.973247
S_3	0.983361	S_7	1.064826	S_{11}	1.021393
S_4	0.966439	S_8	1.090204	S_{12}	1.026168

จากตารางที่ 1 แสดงค่า Seasonal Index ที่แกว่งรอบค่า 1 สะท้อนว่า การวิเคราะห์ใช้รูปแบบ Multiplicative Decomposition ซึ่งสะท้อนอิทธิพลของฤดูกาลในแต่ละช่วงเวลา โดยค่าที่มากกว่า 1 หมายถึง ช่วงเวลาที่ข้อมูลมีค่าสูงกว่า

ค่าเฉลี่ย และค่าที่น้อยกว่า 1 หมายถึง ช่วงเวลาที่ข้อมูลมีค่าต่ำกว่าค่าเฉลี่ย ทั้งนี้ S_1 ถึง S_{12} แทนช่วงเวลารายเดือน ตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ค่า Seasonal Index ดังกล่าวสามารถนำไปใช้ประกอบการวิเคราะห์และการพยากรณ์ข้อมูลในขั้นตอนถัดไปได้

สำหรับแบบจำลอง Holt Exponential Smoothing พบว่าโมเดลสามารถติดตามแนวโน้มของราคาหุ้นได้อย่างต่อเนื่อง โดยพารามิเตอร์ระดับ (level) และแนวโน้ม (trend) ที่ประมาณได้สะท้อนทิศทางขาขึ้นของข้อมูล เมื่อประเมินกับข้อมูลทดสอบปี 2025 พบว่า Holt ให้ค่า MAPE ต่ำที่สุดในช่วง 3 และ 6 เดือน แสดงถึงความเหมาะสมในการพยากรณ์ระยะสั้นถึงปานกลาง อย่างไรก็ตาม เนื่องจาก Holt ไม่ได้จำลองโครงสร้างความสัมพันธ์เชิงอัตสหสัมพันธ์ของข้อมูลโดยตรง จึงอาจมีข้อจำกัดในระยะยาว อย่างไรก็ตาม วิธี Holt ไม่ได้จำลองโครงสร้างความสัมพันธ์เชิงอัตโนมัติของข้อมูลโดยตรง จึงอาจมีข้อจำกัดในการอธิบายพฤติกรรมเชิงลึกของอนุกรมเวลาในระยะยาว



ภาพที่ 2 กราฟ ACF และ PACF ของอัตราการเปลี่ยนแปลงราคาหุ้นหลังการทำ Differencing อันดับหนึ่ง

ในการสร้างแบบจำลอง ARIMA จากผลการทดสอบความนิ่ง (Stationary) Augmented Dickey-Fuller (ADF) test พบว่าข้อมูลราคาปีรายเดือนที่ระดับ (level) มีค่า ADF statistic เท่ากับ -0.6534 และ p-value = 0.8584 ซึ่งสูงกว่าระดับนัยสำคัญ 0.05 จึงไม่สามารถปฏิเสธสมมติฐานหลักได้ แสดงว่าข้อมูลมีหน่วยราก (unit root) และยังคงไม่นิ่ง (Non-Stationary) อย่างไรก็ตาม เมื่อทำ differencing อันดับหนึ่ง พบว่า ADF statistic เท่ากับ -6.5031 และ p-value < 0.001 ซึ่งมีนัยสำคัญทางสถิติที่ระดับ 0.05 สะท้อนว่าอนุกรมเวลาหลังการทำ differencing มีความนิ่งแล้ว โดยค่า ACF และ PACF ส่วนใหญ่อยู่ภายในช่วงความเชื่อมั่น 95% และไม่พบรูปแบบที่ชัดเจนของ AR หรือ MA อย่างเด่นชัด ดังนั้น การกำหนดค่า $d = 1$ ในแบบจำลอง ARIMA จึงมีความเหมาะสม ก่อนการเลือกโมเดล ARIMA ที่เหมาะสมนั้น งานวิจัยนี้ได้ใช้วิธี Auto-ARIMA เพื่อพิจารณาค่าพารามิเตอร์ของโมเดล โดยอาศัยเกณฑ์สารสนเทศ AIC และ BIC ในการเปรียบเทียบประสิทธิภาพของโมเดลต่างๆ ซึ่งโมเดลที่มีค่า AIC และ BIC ต่ำที่สุดจะถูกพิจารณาว่าเป็นโมเดลที่เหมาะสมที่สุดสำหรับการพยากรณ์


ตารางที่ 2 ผลการคัดเลือกโมเดล ARIMA โดยใช้เกณฑ์ AIC และ BIC จากข้อมูลฝึกสอนปี 2020-2024

ARIMA (p,d,q)	AIC	BIC
(2,1,2)	460.204855	470.592542
(1,1,0)	461.424552	465.579627
(1,1,1)	461.720154	467.952766
(0,1,0)	458.841983	462.997058

ตารางที่ 3 การเปรียบเทียบประสิทธิภาพการพยากรณ์ของโมเดล ARIMA โดยใช้ข้อมูลทดสอบปี 2025

ARIMA(p,d,q)	RMSE	MAPE	MAE
(2,1,2)	14.7067	5.28%	12.4153
(1,1,0)	13.6949	4.93%	11.5290
(1,1,1)	14.0641	5.12%	11.9624
(0,1,0)	14.0787	5.10%	11.8924we

จากตารางที่ 3 แม้ว่าแบบจำลอง ARIMA(1,1,0) จะให้ค่าความคลาดเคลื่อนต่ำที่สุดเมื่อพิจารณาจากค่า RMSE, MAPE และ MAE แต่เนื่องจากพจน์ AR(1) ในแบบจำลอง ARIMA(1,1,0) ไม่มีนัยสำคัญทางสถิติ ($p = 0.524$) แสดงให้เห็นว่าการเพิ่มพารามิเตอร์ดังกล่าวไม่ได้ช่วยเพิ่มประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ จึงเลือกใช้ ARIMA(0,1,0) ตามหลักความประหยัดของแบบจำลอง โดยยังคงให้ความแม่นยำใกล้เคียงกันในระดับที่ยอมรับได้ และช่วยลดความซับซ้อนรวมถึงความเสี่ยงของการเกิด overfitting ทำให้เหมาะสมต่อการนำไปใช้งานจริงมากกว่า



ภาพที่ 3 กราฟเศษเหลือ (Residual Plot) ของแบบจำลอง ARIMA(0,1,0)

จากภาพที่ 3 พบว่า เศษเหลือมีการกระจายตัวแบบสุ่มรอบค่าเฉลี่ยใกล้ศูนย์ และไม่ปรากฏรูปแบบเชิงเวลาอย่างชัดเจน แสดงว่า แบบจำลองมีความเหมาะสมและสามารถอธิบายข้อมูลได้ดี โดยไม่พบความสัมพันธ์ค้ำในเศษเหลือ ผลการประมาณค่าพารามิเตอร์ของแบบจำลอง ARIMA(0,1,0) พบว่า แบบจำลองไม่มีพจน์ AR และ MA และมีค่า intercept เท่ากับ 2.9046 ($p = 0.0377$) ซึ่งมีนัยสำคัญทางสถิติที่ระดับ 0.05 สะท้อนว่าหลังการปรับข้อมูลด้วยการหาความแตกต่างอันดับที่ 1 ข้อมูลมีลักษณะใกล้เคียงกระบวนการสุ่ม (Random Walk) นอกจากนี้ ผลการทดสอบวินิจฉัยแบบจำลองยืนยันว่า เศษเหลือมีคุณสมบัติเป็น white noise โดยให้ค่า Ljung-Box p-value เท่ากับ 0.07 ซึ่งมากกว่าระดับนัยสำคัญ 0.05 แสดงว่า ไม่พบความสัมพันธ์เชิงอนุกรมในเศษเหลือ อีกทั้งมีการแจกแจงใกล้เคียงปกติ (Jarque-Bera $p = 0.27$) และไม่พบปัญหา heteroskedasticity ($p = 0.76$) แสดงว่า แบบจำลองมีความเหมาะสมเชิงสถิติ เมื่อเปรียบเทียบประสิทธิภาพตามช่วงเวลาการพยากรณ์ (ตารางที่ 4) พบว่า วิธี Holt ให้ความแม่นยำสูงสุดในช่วง 3 และ 6 เดือน ขณะที่ ARIMA(0,1,0) ให้ผลในระดับที่ใกล้เคียง ส่วน Seasonal Decomposition มีความคลาดเคลื่อนสูงที่สุดในทุกช่วงเวลา สะท้อนว่า ไม่มีแบบจำลองใดที่เหมาะสมในทุกระยะการพยากรณ์ สำหรับการพยากรณ์ปี 2026 (ตารางที่ 5) พบว่า แบบจำลอง Holt และ ARIMA แสดงแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องในช่วงเดือนมกราคมถึงมิถุนายน โดยแบบจำลอง ARIMA(0,1,0) ให้ระดับค่าประมาณที่สูงกว่าในทุกเดือน ทั้งนี้ ความแตกต่างดังกล่าวเป็นเพียงความแตกต่างของระดับค่าพยากรณ์ ไม่สามารถใช้สรุปความแม่นยำเชิงเปรียบเทียบได้ เนื่องจากยังไม่มีข้อมูลจริงสำหรับใช้ตรวจสอบผลการพยากรณ์ในปีดังกล่าว

ตารางที่ 4 การวิเคราะห์เปรียบเทียบประสิทธิภาพของแบบจำลองอนุกรมเวลา ปี 2025

ชื่อโมเดล	MAPE			RMSE		
	3 months	6 months	12 months	3 months	6 months	12 months
Seasonal	13.56%	8.12%	11.39%	33.26	23.88	35.53
Decomposition						
Holt Exponential	6.25%	5.40%	5.07%	16.47	13.86	14.06
Smoothing						
ARIMA(0,1,0)	6.25%	5.40%	5.07%	16.47	13.86	14.06

จากตารางที่ 4 ซึ่งเปรียบเทียบประสิทธิภาพของแบบจำลองอนุกรมเวลาในปี 2025 โดยใช้ค่า MAPE และ RMSE เป็นเกณฑ์ประเมิน พบว่า Holt Exponential Smoothing และ ARIMA(0,1,0) ให้ค่าความคลาดเคลื่อนต่ำและมีประสิทธิภาพใกล้เคียงกันในทุกช่วงการพยากรณ์ สะท้อนถึงความเหมาะสมในการนำไปใช้ทั้งในระยะสั้นและระยะยาว ขณะที่ Seasonal Decomposition มีค่าความคลาดเคลื่อนสูงกว่าวิธีอื่นในทุกช่วงการพยากรณ์ อย่างไรก็ตาม เพื่อให้การพยากรณ์มีความครอบคลุมและอ้างอิงข้อมูลล่าสุด จึงได้นำแบบจำลอง Holt Exponential Smoothing และ ARIMA(0,1,0) ไปประมาณค่าใหม่โดยใช้ข้อมูลตั้งแต่ปี 2020-2025 และประยุกต์ใช้ในการพยากรณ์ค่าของปี 2026 ซึ่งผลการพยากรณ์สามารถสรุปได้ดังนี้

ตารางที่ 5 การประมาณค่าพยากรณ์ปี 2026 จากแบบจำลองอนุกรมเวลา

Holt Exponential Smoothing		ARIMA	
2026-01-01	253.35	2026-01-01	274.77
2026-02-01	256.29	2026-02-01	277.67
2026-03-01	259.22	2026-03-01	280.58
2026-04-01	262.15	2026-04-01	283.49
2026-05-01	265.08	2026-05-01	286.40
2026-06-01	268.02	2026-06-01	289.30

จากตารางที่ 5 ซึ่งแสดงผลการประมาณค่าพยากรณ์ปี 2026 ระหว่างแบบจำลอง Holt Exponential Smoothing และ ARIMA พบว่า ทั้งสองแบบจำลองให้แนวโน้มค่าพยากรณ์เพิ่มขึ้นอย่างต่อเนื่องในช่วงเดือนมกราคมถึงมิถุนายน 2026 แบบจำลอง Holt Exponential Smoothing ให้ค่าพยากรณ์เพิ่มจาก 253.35 ในเดือนมกราคม เป็น 268.02 ในเดือนมิถุนายน สะท้อนแนวโน้มเพิ่มขึ้นในอัตราค่อนข้างสม่ำเสมอ ขณะที่แบบจำลอง ARIMA ให้ค่าพยากรณ์สูงกว่าในทุกช่วงเวลา โดยเพิ่มจาก 274.77 เป็น 289.30 แสดงถึงระดับค่าพยากรณ์ที่มากกว่า Holt's Linear ตลอดช่วงการศึกษา โดยสรุป ทั้งสองแบบจำลองสะท้อนทิศทางแนวโน้มขาขึ้นที่สอดคล้องกัน แต่แบบจำลอง ARIMA ให้ระดับค่าพยากรณ์สูงกว่าอย่างต่อเนื่องในทุกเดือนของช่วงที่พิจารณา

ตารางที่ 6 ผลการพยากรณ์ราคาพร้อมช่วงความเชื่อมั่น 95% ปี 2026

เดือน	Holt Exponential Smoothing		เดือน	ARIMA	
	Upper	Lower		Upper	Lower
2026-01-01	275.56	231.15	2026-01-01	298.07	251.47
2026-02-01	278.49	234.08	2026-02-01	310.63	244.72
2026-03-01	281.42	237.02	2026-03-01	320.94	240.22
2026-04-01	284.35	239.95	2026-04-01	330.09	236.89
2026-05-01	287.29	242.88	2026-05-01	338.50	234.29
2026-06-01	290.22	245.81	2026-06-01	346.38	232.23

จากตารางที่ 6 ซึ่งแสดงผลการพยากรณ์ราคาหุ้นพร้อมช่วงความเชื่อมั่นร้อยละ 95 ของแบบจำลอง Holt Exponential Smoothing และ ARIMA ในช่วงเดือนมกราคมถึงมิถุนายน ปี 2026 พบว่า ทั้งสองแบบจำลองให้ค่าพยากรณ์ที่มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง สะท้อนถึงทิศทางขาขึ้นของราคาหุ้นในช่วงเวลาดังกล่าว เมื่อพิจารณาช่วงความเชื่อมั่นพบว่าแบบจำลอง Holt Exponential Smoothing ให้ช่วงค่าพยากรณ์ (Upper-Lower) ที่ค่อนข้างแคบและมีความสม่ำเสมอในเดือน แสดงถึงความไม่แน่นอนของการพยากรณ์ที่อยู่ในระดับคงที่ ในขณะที่แบบจำลอง ARIMA มีช่วงความเชื่อมั่นที่กว้างกว่า และมีแนวโน้มขยายตัวเพิ่มขึ้นตามระยะเวลาการพยากรณ์ สะท้อนถึงความไม่แน่นอนที่เพิ่มขึ้นในอนาคต นอกจากนี้ ค่าขอบบน (Upper bound) ของแบบจำลอง ARIMA มีค่าสูงกว่า Holt ในทุกช่วงเวลา ซึ่งอาจใช้เป็นตัวบ่งชี้ระดับความเสี่ยงสูงสุดของราคาหุ้น ขณะที่ค่าขอบล่าง (Lower bound) มีแนวโน้มลดลงในระยะยาว แสดงถึงความผันผวนที่เพิ่มขึ้นของช่วงประมาณการ โดยสรุป แบบจำลอง Holt Exponential Smoothing เหมาะสำหรับการพยากรณ์ในบริบทที่ต้องการค่าประมาณที่มีเสถียรภาพ ขณะที่แบบจำลอง ARIMA ให้ช่วงการคาดการณ์ที่ครอบคลุมความไม่แน่นอนได้มากกว่า จึงเหมาะสำหรับกรณีวิเคราะห์ความเสี่ยงในระยะยาว

การอภิปรายผล

ผลการศึกษาครั้งนี้สะท้อนให้เห็นถึงความสัมพันธ์ระหว่างลักษณะของแบบจำลองและกรอบเวลาการพยากรณ์อย่างชัดเจน โดยพบว่า แบบจำลอง Holt Exponential Smoothing ให้ความแม่นยำสูงสุดในกรอบเวลา 3 และ 6 เดือน ซึ่งสอดคล้องกับข้อค้นพบของ Sharif and Hasan (2019) ที่ระบุว่า วิธี Holt มีความเหมาะสมในการติดตามแนวโน้มระยะสั้นของราคาหุ้น เนื่องจากให้ความสำคัญกับข้อมูลล่าสุดและสามารถปรับตัวต่อการเปลี่ยนแปลงของข้อมูลได้อย่างรวดเร็ว ในขณะที่แบบจำลอง ARIMA โดยเฉพาะ ARIMA(0,1,0) ซึ่งมีลักษณะใกล้เคียงกับกระบวนการสุ่ม (Random Walk) แสดงให้เห็นถึงความเหมาะสมในการพยากรณ์ระยะยาว เนื่องจากมีโครงสร้างที่เรียบง่ายและสามารถสะท้อนพฤติกรรมของข้อมูลที่มีความไม่แน่นอนสูงได้ดี นอกจากนี้ ผลการวิเคราะห์ยังสนับสนุนแนวคิดที่ว่า แบบจำลองที่มีความซับซ้อนไม่ได้หมายความว่าจะให้ผลการพยากรณ์ที่ดีกว่าเสมอไป โดยจากผลการศึกษาพบว่า แม้แบบจำลอง ARIMA(1,1,0) จะให้ค่าความคลาดเคลื่อนต่ำกว่าเล็กน้อย แต่ความแตกต่างดังกล่าวอยู่ในระดับที่ไม่มาก และพารามิเตอร์เพิ่มเติมไม่ได้มีนัยสำคัญทางสถิติ ส่งผลให้แบบจำลอง ARIMA(0,1,0) ซึ่งมีความเรียบง่ายกว่าสามารถให้ผลลัพธ์ที่มีเสถียรภาพและเหมาะสมต่อการใช้งานจริงมากกว่า ประเด็นนี้สอดคล้องกับหลักความประหยัดของแบบจำลอง (Parsimony Principle) และแนวคิดของ Efficient Market Hypothesis ที่เสนอว่าราคาหุ้นในตลาดที่มีประสิทธิภาพมักมีพฤติกรรมใกล้เคียงกระบวนการสุ่ม ในส่วนของวิธี Seasonal Decomposition พบว่า มีประสิทธิภาพต่ำที่สุดในทุกกรอบเวลาการพยากรณ์ ซึ่งสามารถอธิบายได้จากลักษณะของข้อมูลราคาหุ้นที่ไม่มีรูปแบบฤดูกาลที่ชัดเจนและสม่ำเสมอ โดยข้อมูลทางการเงินมักมีลักษณะเป็นแนวโน้มเชิงสุ่มและความผันผวนสูง ส่งผลให้วิธีการแยกองค์ประกอบแบบ Multiplicative ไม่สามารถอธิบายโครงสร้างของข้อมูลได้อย่างมีประสิทธิภาพ โดยสรุป ผลการศึกษา

นี้ชี้ให้เห็นว่า ไม่มีแบบจำลองใดที่สามารถให้ผลการพยากรณ์ที่ดีที่สุดในทุกช่วงเวลา (Horizon-dependent) ดังนั้น การเลือกใช้แบบจำลองควรพิจารณาให้สอดคล้องกับลักษณะของข้อมูลและวัตถุประสงค์ของการพยากรณ์ในแต่ละช่วงเวลา เพื่อให้ได้ผลลัพธ์ที่มีความเหมาะสมและสามารถนำไปประยุกต์ใช้ได้อย่างมีประสิทธิภาพ

ข้อเสนอแนะ

จากผลการศึกษาที่พบว่า แบบจำลองมีประสิทธิภาพแตกต่างกันตามกรอบเวลาการพยากรณ์ การเลือกใช้แบบจำลองจึงควรพิจารณาให้สอดคล้องกับลักษณะของการทำงาน โดยในกรณีของการพยากรณ์ระยะสั้นถึงระยะกลาง (3-6 เดือน) แบบจำลอง Holt Exponential Smoothing มีความเหมาะสม เนื่องจากสามารถตอบสนองต่อการเปลี่ยนแปลงของข้อมูลได้อย่างรวดเร็ว ขณะที่การพยากรณ์ระยะยาวควรพิจารณาใช้แบบจำลอง ARIMA ซึ่งมีความเสถียรและสามารถสะท้อนพฤติกรรมของข้อมูลที่มีลักษณะเชิงสุ่มได้ดีกว่า นอกจากนี้ การนำผลการพยากรณ์ไปประยุกต์ใช้ควรพิจารณาร่วมกับช่วงความเชื่อมั่น (Confidence Interval) เพื่อสะท้อนระดับความไม่แน่นอนของข้อมูล โดยเฉพาะในบริบทของตลาดหุ้นที่มีความผันผวนสูง การพิจารณาเพียงค่าพยากรณ์แบบจุดอาจนำไปสู่การตัดสินใจที่มีความเสี่ยง ดังนั้น การใช้ช่วงความเชื่อมั่นควบคู่กับการวิเคราะห์เชิงปัจจัยพื้นฐานและการบริหารความเสี่ยง จะช่วยเพิ่มประสิทธิภาพในการตัดสินใจลงทุนได้อย่างเหมาะสมมากยิ่งขึ้น

ข้อเสนอแนะสำหรับการวิจัยในอนาคต

แม้ว่าการศึกษานี้มุ่งเน้นแบบจำลองอนุกรมเวลาแบบตัวแปรเดียว (univariate) แต่ราคาหุ้นในความเป็นจริงได้รับอิทธิพลจากปัจจัยเศรษฐกิจมหภาคและปัจจัยภายนอกหลายประการ ดังนั้น งานวิจัยในอนาคตอาจพิจารณาขยายกรอบการวิเคราะห์โดยนำตัวแปรภายนอก เช่น อัตราดอกเบี้ย อัตราเงินเฟ้อ หรือดัชนีตลาดรวม เข้ามารวมในแบบจำลอง ARIMAX หรือ SARIMAX เพื่อประเมินบทบาทของปัจจัยเศรษฐกิจต่อความแม่นยำในการพยากรณ์ นอกจากนี้ ควรพิจารณาเปรียบเทียบกับเทคนิคการเรียนรู้ของเครื่อง เช่น LSTM หรือแบบจำลองที่สามารถจัดการความสัมพันธ์เชิงไม่เป็นเส้นตรง (non-linear) ได้ดี เพื่อประเมินว่าความซับซ้อนของแบบจำลองช่วยเพิ่มประสิทธิภาพในการพยากรณ์อย่างมีนัยสำคัญหรือไม่ โดยเฉพาะเมื่อใช้ข้อมูลความถี่สูงหรือช่วงเวลาที่ยาวขึ้น การเปรียบเทียบดังกล่าวจะช่วยให้สามารถสรุปข้อได้เปรียบของแบบจำลองเชิงสถิติและแบบจำลองเชิงลึกได้อย่างรอบด้านยิ่งขึ้น

เอกสารอ้างอิง

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control*. 5th ed. Wiley.
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. New York, NY: Springer.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427-431.
- Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20(1), 5-10. (Original work published 1957).
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. 3rd ed. Melbourne, Australia: OTexts.
- Sharif, O., & Hasan, M. Z. (2019). Forecasting the stock price by using Holt's method. *International Journal of Scientific & Engineering Research*, 10(3), 155-162.
- Xia, Z. (2023). *Research on APAL stock price prediction using ARIMA model*. Proceedings of the International Conference on Financial Technology and Data Science (pp. 45-52).
- Yahoo Finance. (2025). *Apple Inc. (AAPL)*. Retrieved from <https://finance.yahoo.com/>.

Yoo, K. (2007). Stock Market Price Forecasting Using the ARIMA Model. *International Journal of Forecasting*, 23(4), 561-570.

ชนพล ศรีสุข. (2563). การเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์ราคาหุ้นด้วยวิธี ARIMA และ Exponential Smoothing. *วารสารบริหารธุรกิจและการบัญชี*, 12(2), 89-104.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Conflicts of Interest: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's Note: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.



Copyright: © 2026 by the authors. This is a fully open-access article distributed under the terms of the Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0).