

การเปรียบเทียบวิธีพยากรณ์ราคาทองคำภายใต้สถานการณ์สงครามรัสเซีย-ยูเครน

สุรเมศวร์ ฮาซิม¹, กฤต ขติณานัง², นวภ ลิ้มสกุล³ และ รัชพล สม่าลี⁴

สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี

มหาวิทยาลัยธรรมศาสตร์ (ศูนย์รังสิต) ปทุมธานี 12120

Received: 11 March 2026; Revised: 28 April 2026; Accepted: 12 May 2026

บทคัดย่อ

ภายใต้สถานการณ์สงครามรัสเซีย-ยูเครนที่ปะทุขึ้นตั้งแต่เดือนกุมภาพันธ์ พ.ศ. 2565 ส่งผลให้ราคาทองคำในตลาดโลกมีแนวโน้มสูงขึ้นเนื่องจากบางประเทศมีการประกาศใช้นโยบายสะสมทองคำเพื่อความมั่นคงทางเศรษฐกิจ และนักลงทุนที่มองหาสินทรัพย์ปลอดภัยจะเพิ่มสัดส่วนการลงทุนในทองคำ งานวิจัยนี้จึงมุ่งประเมินความสามารถในการพยากรณ์ราคาทองคำรายวัน (XAU/USD) ผ่านการนำวิธีการพยากรณ์ 3 วิธีมาทดสอบเปรียบเทียบ ได้แก่ การทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt วิธี ARIMA ตามแนวทางของ Box-Jenkins และวิธีการเรียนรู้ของเครื่องแบบ XGBoost ที่ประยุกต์ใช้ร่วมกับกลยุทธ์การพยากรณ์ล่วงหน้าหลายช่วงเวลาแบบ Direct เพื่อสร้างตัวแบบพยากรณ์ราคาทองคำ ในการการศึกษานี้ใช้ข้อมูลราคาทองคำรายวันจำนวน 773 วัน โดยแบ่งข้อมูล 80% แรก (618 วัน) สำหรับสร้างและฝึกตัวแบบ และ 20% ที่เหลือ (155 วัน) สำหรับประเมินประสิทธิภาพและเปรียบเทียบผลลัพธ์ ผลการศึกษาพบว่า XGBoost มีประสิทธิภาพสูงสุดทั้ง 3 ตัวชี้วัด โดยมีค่า MAD เท่ากับ 132.55 RMSE เท่ากับ 156.49 และ MAPE เท่ากับ 4.96% ผลการศึกษาชี้ให้เห็นว่าแม้วิธีอนุกรมเวลาจะสามารถพยากรณ์แนวโน้มภาพรวมได้ แต่มีข้อจำกัดในการตรวจจับความผันผวนระยะสั้นเนื่องจากมีข้อจำกัดของตัวแบบ ในขณะที่การเรียนรู้ของเครื่องแบบ XGBoost ที่ประยุกต์ใช้ร่วมกับกลยุทธ์การพยากรณ์ล่วงหน้าหลายช่วงเวลาแบบ Direct มีความสามารถในการจัดการกับความสัมพันธ์ที่ไม่เป็นเชิงเส้นของข้อมูลได้ดีกว่า จึงมีความเหมาะสมมากกว่าสำหรับการพยากรณ์ราคาของสินทรัพย์ที่มีความผันผวนสูงในช่วงวิกฤตการณ์ทางภูมิรัฐศาสตร์

คำสำคัญ : สงครามรัสเซีย-ยูเครน, ราคาทองคำ, การพยากรณ์อนุกรมเวลา, การเรียนรู้ของเครื่อง

*Corresponding author. E-mail: ratchapol.samalee@gmail.com

¹ Assistant Professor in Department of Mathematics and Statistics, Faculty of Science and Technology, Thammasat University

^{2,3,4} Student in Department of Mathematics and Statistics, Faculty of Science and Technology, Thammasat University

Comparison of Forecasting Methods for Gold Prices under the Russia-Ukraine War

Suramase Hashim¹ Krit Katichanang² Navaphop Limsakul³ และ Ratchapol Samalee^{*4}

Department of Mathematics and Statistics, Faculty of Science and Technology,
Thammasat University, Pathum Thani 12120

Received: 11 March 2026; Revised: 28 April 2026; Accepted: 12 May 2026

Abstract

In the context of the Russia-Ukraine war that erupted in February 2022, global gold prices have shown an upward trend, driven by gold accumulation policies adopted by certain countries to ensure economic security and increased investor demand for safe-haven assets. This study aims to evaluate the forecasting performance of daily gold prices (XAU/USD) by comparing three forecasting approaches, namely Holt's Exponential Smoothing, the ARIMA method following the Box-Jenkins framework, and the XGBoost machine learning algorithm applied with a Direct multi-step-ahead forecasting strategy to construct gold price forecasting models. The study utilizes 773 daily gold price observations, with the first 80% (618 days) used for model development and training, and the remaining 20% (155 days) reserved for performance evaluation and comparison. The results indicate that XGBoost achieved the highest performance across all three evaluation metrics, with a MAD of 132.55, RMSE of 156.49, and MAPE of 4.96%. The findings suggest that while time series methods are capable of capturing overall trend patterns, they are limited in detecting short-term volatility due to inherent model constraints. In contrast, XGBoost combined with the Direct multi-step-ahead forecasting strategy demonstrates superior ability to handle nonlinear relationships within the data, making it more suitable for forecasting the prices of highly volatile assets during geopolitical crises.

Keywords: Russia-Ukraine war, gold price, time series forecasting, machine learning

*Corresponding author. E-mail: ratchapol.samalee@gmail.com

¹ ผู้ช่วยศาสตราจารย์ สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์

^{2,3,4} นักศึกษา สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์

1. คำนำ

ทองคำเป็นสินทรัพย์ที่มีมูลค่าในตัวเองและสามารถนำไปใช้แลกเปลี่ยนในสกุลเงินอื่นๆได้ สาเหตุที่ทองคำมีมูลค่าในตัวเองนั้นเป็นเพราะทองคำในโลกมีอยู่อย่างจำกัด เป็นปัจจัยสำหรับการกำหนดการมีเงินทุนสำรอง การกักเงิน นอกจากนี้ ทองคำยังได้รับความเชื่อถือให้เป็นสินทรัพย์ปลอดภัยเมื่อเกิดความไม่แน่นอนหรือความผันผวนในตลาดการเงิน [1] การลงทุนในทองคำจึงเป็นหนึ่งในทางเลือกการลงทุนที่ได้รับความนิยมในช่วงเวลาที่เกิดเหตุการณ์สงครามหรือวิกฤตการณ์ทางการเงิน เพื่อทำการสะสมสินทรัพย์เพื่อรักษามูลค่าหรือการเก็งกำไร

จากสถานการณ์สงครามระหว่างรัสเซียและยูเครนที่เกิดขึ้นเมื่อวันที่ 24 กุมภาพันธ์ พ.ศ. 2565 รัสเซียได้ส่งกองกำลังทหารโจมตีเมืองหลวงของยูเครน พันธมิตรชาติตะวันตกนำโดยสหรัฐฯ สหภาพยุโรป และกลุ่ม G7 ได้ร่วมกันประกาศใช้มาตรการคว่ำบาตรทางเศรษฐกิจที่รุนแรงที่สุดครั้งหนึ่งเพื่อสร้างแรงกดดันทางเศรษฐกิจต่อรัสเซียอย่างหนัก และกดดันให้ยุติการสู้รบ ด้านรัสเซียเองก็ได้ประกาศรายชื่อประเทศไม่เป็นมิตรซึ่งเป็นประเทศที่ร่วมคว่ำบาตรรัสเซียจำนวน 48 ประเทศเพื่อกำหนดมาตรการตอบโต้พันธมิตรชาติตะวันตก สถานการณ์ความตึงเครียดจากสงครามและมาตรการคว่ำบาตรต่างๆ ส่งผลให้หลายประเทศกำหนดมาตรการสะสมทองคำเพื่อความมั่นคงต่อเศรษฐกิจและการเงินของประเทศ [2] นอกจากนี้ นักลงทุนที่ต้องการสินทรัพย์ที่มีความเสี่ยงต่ำในช่วงสภาวะสงครามก็เพิ่มสัดส่วนการลงทุนทองคำมากขึ้น [3] ส่งผลให้อุปสงค์ของทองคำในช่วงสงครามรัสเซีย-ยูเครนเพิ่มสูงขึ้น ทำให้ราคาทองคำหลังจากการบุกโจมตีของรัสเซียและการประกาศมาตรการคว่ำบาตรของพันธมิตรชาติตะวันตกปรับตัวสูงขึ้นอย่างเห็นได้ชัด แสดงดังรูปที่ 1



รูปที่ 1 ราคาทองคำหลังจากรัสเซียส่งกองกำลังทหารโจมตียูเครน

การพยากรณ์ราคาทองคำจึงมีประโยชน์อย่างยิ่งในการเป็นข้อมูลเพื่อประกอบการตัดสินใจลงทุนในสถานการณ์เช่นนี้ อย่างไรก็ตามการพยากรณ์ราคาทองคำสามารถทำได้หลายวิธี ซึ่งแต่ละวิธีจะมีความประสิทธิภาพในการพยากรณ์แตกต่างกัน การเลือกวิธีการพยากรณ์ที่มีความเหมาะสมจะช่วยให้ได้ผลการพยากรณ์ที่มีความแม่นยำและสามารถช่วยเป็นข้อมูลประกอบการตัดสินใจได้อย่างน่าเชื่อถือยิ่งขึ้น ในอดีตมีหลายการศึกษาที่นำวิธีทางอนุกรมเวลามาใช้ในการพยากรณ์ราคาทองคำ เช่น การศึกษาของ Khalid & Halim [4] ได้สร้างแบบจำลอง ARIMA สำหรับพยากรณ์ราคาทองคำรายวันจากเว็บไซต์ investing.com โดยใช้ข้อมูลระหว่างปี ค.ศ. 2015-2017 ในการสร้างตัวแบบ จากนั้นนำไปพยากรณ์ราคาในปี ค.ศ. 2018 ผลการศึกษาพบว่าตัวแบบ ARIMA(1,1,1) ให้ผลการพยากรณ์ที่ดีที่สุดโดยมีค่า MAPE เพียง 0.02% ในทำนองเดียวกัน Rama et al. [5] ได้ศึกษาการใช้ตัวแบบ ARIMA พยากรณ์ราคาทองคำรายวันจาก World Gold Council โดยใช้ข้อมูลระหว่างเดือนมกราคม ค.ศ. 2018 ถึงกุมภาพันธ์ ค.ศ. 2023 ในการหาตัวแบบที่เหมาะสมโดยพิจารณาจาก ACF และ PACF จากนั้นวัดประสิทธิภาพของตัวแบบในเดือนมีนาคม ค.ศ. 2023 ผลการศึกษาพบว่าตัวแบบ ARIMA (4,1,4) มีความ

ผิดพลาดในการพยากรณ์น้อยกว่า 1.2% แสดงให้เห็นว่าตัวแบบสามารถพยากรณ์ราคาทองคำได้อย่างแม่นยำ นอกจากนี้ Ariffin et al. [6] ได้เปรียบเทียบวิธีการพยากรณ์สำหรับราคาเหรียญทองคำ Kijang รายวันจากธนาคารกลางมาเลเซีย โดยใช้ข้อมูลระหว่างปี ค.ศ. 2019-2023 และเปรียบเทียบระหว่างวิธีของ Holt, แบบจำลอง ARIMA และวิธี Prophet โดยแบ่งข้อมูล 75% แรกสำหรับสร้างตัวแบบและ 25% หลังสำหรับทดสอบประสิทธิภาพ ผลการศึกษาพบว่าวิธีของ Holt ให้ประสิทธิภาพสูงสุด โดยมีค่า RMSE เท่ากับ 667.8285, MAE เท่ากับ 574.71 และ MAPE เท่ากับ 6.0451%

ในระยะหลังมีหลายงานวิจัยที่ศึกษาการประยุกต์ใช้การเรียนรู้ของเครื่องสำหรับการพยากรณ์ราคาทองคำ การศึกษาของ Makala & Li [7] ได้เปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง ARIMA แบบมีฤดูกาลและวิธีการเรียนรู้ของเครื่องแบบ SVM โดยใช้ข้อมูลรายวันจาก World Gold Council ระหว่างปี ค.ศ. 1979 ถึง 2019 โดยใช้ข้อมูลจนถึงปี ค.ศ. 2014 ในการสร้างแบบจำลองและใช้ช่วงเวลาหลังจากนั้นสำหรับวัดประสิทธิภาพ ผลการศึกษาพบว่า SVM แบบ Poly kernel ให้ผลลัพธ์การพยากรณ์ที่มีความแม่นยำมากกว่า ARIMA(2,1,2)(2,1,2,12) โดยมีค่า MAPE, RMSE และ R-square เท่ากับ 2.49%, 0.0275 และ 0.9978 ตามลำดับ สำหรับการเปรียบเทียบประสิทธิภาพระหว่างวิธีการเรียนรู้ของเครื่องด้วยกัน Fawzy, Rady & Fattah [8] ได้ศึกษาเปรียบเทียบ SVM และ K-NN ในการพยากรณ์ราคาทองคำรายเดือนระหว่างปี ค.ศ. 1989 ถึง 2019 โดยแบ่งข้อมูล 90% แรกสำหรับฝึกและ 10% สุดท้ายสำหรับทดสอบ ผลการศึกษาพบว่า SVM มีประสิทธิภาพสูงกว่า K-NN โดยได้ค่า RMSE เท่ากับ 33.77 นอกจากนี้ Liu [9] ได้ศึกษาการนำ XGBoost มาพยากรณ์ราคาทองคำและบิตคอยน์รายวัน โดยใช้ข้อมูลก่อนวันที่ 12 กันยายน ค.ศ. 2016 แบ่งข้อมูล 70% แรกสำหรับสร้างตัวแบบและ 30% สุดท้ายสำหรับทดสอบ โดยใช้ข้อมูลย้อนหลัง 5 วันเป็นข้อมูลนำเข้า ผลการศึกษาพบว่าพยากรณ์ราคาทองคำบนข้อมูลทดสอบมีค่า RMSE, MAE, MAPE และ R-square เท่ากับ 7.18, 4.693, 0.313% และ 0.999 ตามลำดับ แสดงให้เห็นถึง

ประสิทธิภาพที่ดีเยี่ยมของ XGBoost ในการพยากรณ์ราคาทองคำ

จากการศึกษาในอดีตที่มีการใช้วิธีทางอนุกรมเวลาและการเรียนรู้ของเครื่องในการพยากรณ์ราคาทองคำ พบว่าการเรียนรู้ของเครื่องสามารถให้ผลการพยากรณ์ที่มีความแม่นยำสูงกว่าวิธีทางอนุกรมเวลา [7] นอกจากนี้การศึกษาของ Liu [9] ได้แสดงให้เห็นถึงประสิทธิภาพของการเรียนรู้ของเครื่องแบบ XGBoost ในการพยากรณ์ ผู้วิจัยจึงสนใจนำ XGBoost มาประยุกต์ใช้ในการพยากรณ์ราคาทองคำรายวันภายใต้สถานการณ์สังคมรัสเซีย-ยูเครน และเปรียบเทียบประสิทธิภาพกับวิธีทางอนุกรมเวลา ได้แก่ Holt และ ARIMA เพื่อหาวิธีพยากรณ์ที่มีความแม่นยำสูงสุด ซึ่งจะเป็นประโยชน์ต่อการพยากรณ์ราคาทองคำในสถานการณ์ที่มีความไม่แน่นอนทางเศรษฐกิจและการเงินในอนาคต

2. ทฤษฎีที่เกี่ยวข้อง

2.1 การพยากรณ์อนุกรมเวลา

การพยากรณ์อนุกรมเวลา หมายถึง การพยากรณ์กลุ่มของค่าสังเกตที่เก็บรวบรวมตามเวลาอย่างต่อเนื่อง โดยแต่ละค่าสังเกตมักจะเก็บรวบรวมในช่วงเวลาระยะห่างเท่ากัน และแต่ละค่าสังเกตจะมีความสัมพันธ์กันซึ่งจะแตกต่างจากค่าสังเกตจากการสำรวจที่จะเป็นอิสระกันและไม่ขึ้นกับเวลา เช่น ข้อมูลที่เก็บรายปี รายครึ่งปี รายไตรมาส รายเดือน ตัวอย่างของอนุกรมเวลา เช่น ยอดขายสินค้ารายปีของห้างสรรพสินค้าแห่งหนึ่ง จำนวนนักท่องเที่ยวรายปีที่เดินทางเข้าประเทศ อัตราการว่างงานรายเดือน ราคาปิโตรเลียมของหุ้นของธนาคารแห่งหนึ่ง

2.2 วิธีการทำให้เรียบแบบเอกซ์โพเนนเชียลโดยวิธีของ Holt (Holt's Exponential Smoothing)

การทำให้เรียบแบบเอกซ์โพเนนเชียลวิธีของ Holt เป็นหนึ่งในวิธีการพยากรณ์ปรับให้เรียบแบบเอกซ์โพเนนเชียลที่เหมาะสมกับข้อมูลที่มีแนวโน้มและไม่มีฤดูกาล มีแนวคิดคือการใช้ค่าเฉลี่ยถ่วงน้ำหนักของข้อมูลในอดีตโดยให้น้ำหนักสูงกับข้อมูลล่าสุดและค่าน้ำหนักจะลดลงแบบเอกซ์โพเนนเชียลเมื่อค่าสังเกตมีระยะเวลาดำเนินไป หากข้อมูล

อนุกรมเวลามีแนวโน้มที่เพิ่มขึ้นหรือลดลงในอัตราคงที่จะสามารถอธิบายได้โดยตัวแบบแนวโน้มเส้นตรงดังสมการที่ 1

$$Z_t = \beta_0 + \beta_1 t + \varepsilon_t \quad (1)$$

โดยที่ Z_t หมายถึง ค่าจริงของอนุกรมเวลา ณ เวลาที่ t
 β_0 หมายถึง พารามิเตอร์แสดงค่าในแนวระดับ
 β_1 หมายถึง พารามิเตอร์แสดงความชันของแนวโน้ม
 ε_t หมายถึง ค่าความคลาดเคลื่อนสุ่ม ณ เวลาที่ t

สมการพยากรณ์สำหรับวิธีทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt คำนวณจากค่าสถิติจากการปรับให้เรียบในแนวระดับ S_t แสดงวิธีคำนวณดังสมการที่ 2 และค่าสถิติจากการปรับให้เรียบในความชัน $\hat{\beta}_t$ แสดงวิธีคำนวณดังสมการที่ 3

$$S_t = \alpha Z_t + (1 - \alpha)(S_{t-1} + \hat{\beta}_{t-1}) \quad (2)$$

$$\hat{\beta}_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\hat{\beta}_{t-1} \quad (3)$$

โดยที่ S_t หมายถึง ค่าสถิติจากการปรับให้เรียบในแนวระดับ ณ ช่วงเวลาที่ t
 $\hat{\beta}_t$ หมายถึง ค่าสถิติจากการปรับให้เรียบในแนวความชัน ณ ช่วงเวลาที่ t
 α หมายถึง ค่าคงที่การทำให้เรียบในแนวระดับ โดย $0 \leq \alpha \leq 1$
 γ หมายถึง ค่าคงที่การทำให้เรียบในแนวโน้ม โดย $0 \leq \gamma \leq 1$

ค่าพยากรณ์ด้วยวิธีทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt จะคำนวณจากค่าสถิติจากการทำให้เรียบในแนวระดับ S_t บวกกับค่าสถิติจากการทำให้เรียบในแนวความชัน $\hat{\beta}_t$ ที่คูณกับจำนวนวันล่วงหน้าที่ต้องการพยากรณ์ ℓ แสดงดังสมการที่ 4

$$\hat{Z}_{t+\ell} = S_t + (\hat{\beta}_t \times \ell) \text{ เมื่อ } t = 1, 2, 3, \dots, n \quad (4)$$

โดยที่ $\hat{Z}_{t+\ell}$ หมายถึง ค่าพยากรณ์ล่วงหน้า ℓ ช่วงเวลาสำหรับ Z_t

n หมายถึง จำนวนข้อมูลจริงที่นำมาใช้ในการพยากรณ์

การคำนวณค่าเริ่มต้นของ S_t คือ S_0 แสดงได้ดังสมการที่ 5 และการคำนวณค่าเริ่มต้นของ $\hat{\beta}_t$ คือ β_0 แสดงดังสมการที่ 6

$$S_0 = Z_1 - \frac{1}{2} \hat{\beta}_0 \quad (5)$$

$$\hat{\beta}_0 = \frac{Z_n - Z_1}{n - 1} \quad (6)$$

2.3 วิธีพยากรณ์ ARIMA

2.3.1 การสร้างตัวแบบพยากรณ์ ARIMA

Autoregressive Integrated Moving Average (ARIMA) เป็นหนึ่งในวิธีการพยากรณ์ของ Box และ Jenkins ที่เผยแพร่ในปี ค.ศ. 1970 โดยตัวแบบ ARIMA ประกอบด้วย 2 กระบวนการได้แก่ กระบวนการ Autoregressive อันดับที่ p หรือ AR(p) คือกระบวนการที่แสดงว่าค่าสังเกตค่าหนึ่ง ณ เวลาที่ t (Y_t) ถูกกำหนดขึ้นจากความสัมพันธ์ของตัวมันเองในอดีต $Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-p}$ เมื่อ p คือลำดับของคาบเวลาในอดีตที่เหมาะสมในการอธิบายค่า Y ณ เวลาที่ t แสดงดังสมการที่ 7 และกระบวนการ Moving Average อันดับที่ q หรือ MA (q) คือกระบวนการที่แสดงว่าค่าสังเกตค่าหนึ่ง ณ เวลาที่ t (Y_t) ถูกกำหนดขึ้นจากความคลาดเคลื่อนของข้อมูลอนุกรมเวลาในอดีต $\varepsilon_{t-1}, \varepsilon_{t-2}, \varepsilon_{t-3}, \dots, \varepsilon_{t-q}$ เมื่อ q คือลำดับของคาบเวลาในอดีตที่เหมาะสมในการอธิบายค่า Y ณ เวลาที่ t แสดงดังสมการที่ 8

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (7)$$

$$Y_t = \theta_0 + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (8)$$

ก่อนการพยากรณ์ด้วยวิธี ARIMA จะต้องตรวจสอบความนิ่งของข้อมูล หากพบว่าข้อมูลยังไม่นิ่งจะต้องแปลงข้อมูลให้มีความนิ่งก่อน โดยหากข้อมูลไม่นิ่งเนื่องจากมีความแปรปรวนไม่คงที่ที่จะต้องแปลงข้อมูลด้วยฟังก์ชัน ln และหากข้อมูลยังไม่นิ่งเนื่องจากมีค่าเฉลี่ยไม่คงที่ที่จะต้องหาผลต่าง

ข้อมูล d ครั้งจนกว่าข้อมูลจะนิ่ง โดย d คือจำนวนครั้งของการหาผลต่างที่ทำให้ข้อมูลมีความนิ่ง

เมื่อทำการหาผลต่างข้อมูล d ครั้งเพื่อให้ข้อมูลอนุกรมเวลาที่มีความนิ่งแล้วนำกระบวนการ $AR(p)$ และ $MA(q)$ มารวมกันสามารถเขียนสมการอธิบายข้อมูลอนุกรมเวลา ณ เวลาที่ t ในรูป Backshift Operator ดังสมการที่ 9

$$(1-B)^d(1-\phi_1B-\phi_2B^2-\dots-\phi_pB^p)Y_t = \theta_0 + (1-\theta_1B-\theta_2B^2-\dots-\theta_qB^q)\varepsilon_t \quad (9)$$

โดยที่ $\phi_1, \dots, \phi_p$ หมายถึง พารามิเตอร์แสดงค่าของ Autoregressive processs
อันดับที่ $1, 2, \dots, p$ ตามลำดับ
 $\theta_1, \dots, \theta_q$ หมายถึง พารามิเตอร์แสดงค่าของ Moving Average process
อันดับที่ $1, 2, \dots, q$ ตามลำดับ
 Y_t หมายถึง ข้อมูลอนุกรมเวลา ณ เวลาที่ t
 θ_0 หมายถึง พจน์ค่าคงที่
 B หมายถึง Backshift operator
 p หมายถึง อันดับที่ p ของกระบวนการ Autoregressive
 d หมายถึง อันดับของการหาผลต่างให้ข้อมูลมีความนิ่ง
 q หมายถึง อันดับที่ q ของกระบวนการ Moving Average
 ε_t หมายถึง ความคลาดเคลื่อนสุ่ม ณ เวลาที่ t

การพิจารณาอันดับ p และ q สำหรับกระบวนการ $AR(p)$ และ $MA(q)$ สำหรับสร้างตัวแบบ $ARIMA(p,d,q)$ จะพิจารณาจากคอเรโลแกรมของอนุกรมเวลา โดยตรวจสอบคอเรโลแกรมของสหสัมพันธ์ในตัวเอง (ACF) ซึ่งเป็นค่าวัดความสัมพันธ์ระหว่างค่าสังเกตในอนุกรมเวลากับค่าสังเกตที่อยู่ห่างออกไปก่อนหน้า k ช่วงเวลา สำหรับการพิจารณาอันดับ q สำหรับตัวแบบ $ARIMA(p,d,q)$ แสดงค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองได้ดังสมการที่ 10

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (10)$$

โดยที่ r_k หมายถึง ค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเอง k ช่วงเวลา
 k หมายถึง ช่วงเวลาที่ห่างกัน k โดยที่ $k = 1, 2, 3, \dots$
 n หมายถึง จำนวนของข้อมูลทั้งหมด

จากนั้นตรวจสอบคอเรโลแกรมสหสัมพันธ์ในตัวเองบางส่วน (PACF) ซึ่งเป็นค่าวัดความสัมพันธ์ระหว่างค่าสังเกตในอนุกรมเวลาที่อยู่ห่างกัน k ช่วงเวลา เมื่อกำหนดให้ค่าสังเกตที่เวลาอื่น ๆ ที่มีระยะห่างไกลกว่าคงที่ สำหรับการพิจารณาอันดับ p สำหรับตัวแบบ $ARIMA(p,d,q)$ แสดงค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองบางส่วน (PACF) ได้ดังสมการที่ 11

$$r_{kk} = \begin{cases} r_1 \\ r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j} \\ 1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j \end{cases} \quad (11)$$

โดยที่ r_{kk} หมายถึง ค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนในตัวเอง k ช่วงเวลา
 k หมายถึง ช่วงเวลาที่ห่างกัน k โดยที่ $k = 1, 2, 3, \dots$
 n หมายถึง จำนวนของข้อมูลทั้งหมด

ในการพิจารณาคอเรโลแกรมของ ACF และ PACF จะพิจารณาเลือกตัวแบบ $AR(p)$ หาก ACF ลดลงเข้าใกล้ศูนย์แบบเอกซ์โพเนนเชียลหรือคลื่นรูป sine ขณะที่ PACF จะเกิดค่าที่ชัดเจนจนถึงลำดับที่ p แล้วจึงหายไป พิจารณาเลือกตัวแบบ $MA(q)$ หาก ACF เกิดค่าที่ชัดเจนจนถึงลำดับที่ q แล้วหายไป ในขณะที่ PACF จะลดลงเข้าใกล้ศูนย์แบบเอกซ์โพเนนเชียลหรือคลื่นรูป sine และพิจารณาเลือกตัวแบบ $ARMA(p, q)$ หากทั้ง ACF และ PACF ลดลงเข้าใกล้ศูนย์หลัง Lags อันดับที่ q และ p ตามลำดับ

ภายหลังพิจารณาเลือกตัวแบบ ARIMA(p,d,q) ด้วยคอเรลโลแกรมของ ACF และ PACF หลังจากหาผลต่างข้อมูล d ครั้ง จะทำการประมาณค่าพารามิเตอร์ ตรวจสอบความมีนัยสำคัญของพารามิเตอร์ในตัวแบบที่ได้โดยการตรวจสอบว่าพารามิเตอร์ทุกตัวมีค่าแตกต่างจากศูนย์ หากมีพารามิเตอร์อย่างน้อยหนึ่งตัวที่ไม่แตกต่างจากศูนย์จะต้องทำการกำหนดตัวแบบใหม่ หากทุกพารามิเตอร์มีค่าแตกต่างจากศูนย์จะทำการตรวจสอบความเหมาะสมของตัวแบบโดยการตรวจสอบคุณสมบัติของความคลาดเคลื่อนสุ่มได้แก่ ความคลาดเคลื่อนสุ่มจะต้องไม่มีสหสัมพันธ์ในตัวเอง, ความคลาดเคลื่อนสุ่มมีค่าเฉลี่ยเท่ากับศูนย์, ความคลาดเคลื่อนสุ่มมีการแจกแจงปกติ และความคลาดเคลื่อนสุ่มมีความแปรปรวนคงที่ตลอดทุกช่วงเวลา หากความคลาดเคลื่อนสุ่มไม่ผ่านการตรวจสอบคุณสมบัติอย่างน้อย 1 ข้อ ถือว่าตัวแบบ ที่ได้ไม่มีความเหมาะสมในการพยากรณ์จะต้องใช้อันดับ (p,d,q) อื่นๆในการระบุตัวแบบ ARIMA(p,d,q)

2.3.2 การตรวจสอบความนิ่งของข้อมูล

ก่อนการพยากรณ์ด้วยวิธี ARIMA จะต้องตรวจสอบความนิ่งของข้อมูล หนึ่งในวิธีทดสอบความนิ่งคือการทดสอบ Augmented Dickey-Fuller test ที่จะทำการทดสอบข้อมูลอนุกรมเวลาเขียนในรูปสมการถดถอย AR(p) ในรูปผลต่างอันดับที่ 1 ว่ามี unit root หรือไม่ หากมี unit root จะสรุปผลว่าข้อมูลอนุกรมเวลานั้นไม่นิ่ง โดยข้อมูลอนุกรมเวลาสามารถเขียนในรูปสมการถดถอย AR(p) ในรูปผลต่างอันดับที่ 1 ได้ 3 กรณีได้แก่ กรณีไม่มีค่าคงที่และไม่มีแนวโน้มเวลาแสดงได้ดังสมการที่ 12 กรณีมีเฉพาะค่าคงที่แสดงได้ดังสมการที่ 13 กรณีมีทั้งค่าคงที่และแนวโน้มเวลาแสดงได้ดังสมการที่ 14

$$\Delta Y_t = \delta Y_{t-1} + \sum_{i=1}^p \phi_i \Delta Y_{t-i} + \varepsilon_t \quad (12)$$

$$\Delta Y_t = \alpha + \delta Y_{t-1} + \sum_{i=1}^p \phi_i \Delta Y_{t-i} + \varepsilon_t \quad (13)$$

$$\Delta Y_t = \alpha + \delta Y_{t-1} + \sum_{i=1}^p \phi_i \Delta Y_{t-i} + \beta t + \varepsilon_t \quad (14)$$

การทดสอบ Augmented Dickey-Fuller Test จะเลือกทดสอบสมการถดถอยของอนุกรมเวลาในรูป AR(p)

เพียง 1 กรณีตามลักษณะของข้อมูลโดยมีสมมติฐานการทดสอบและสถิติทดสอบดังนี้

$$H_0 : \delta = 0 \quad (\text{ข้อมูลมี Unit Root ข้อมูลไม่นิ่ง})$$

$$H_1 : \delta < 0 \quad (\text{ข้อมูลไม่มี Unit Root ข้อมูลนิ่ง})$$

สถิติทดสอบ

$$t = \frac{\hat{\delta}}{S(\hat{\delta})} \quad (15)$$

เปรียบเทียบค่าสถิติทดสอบ t กับค่าวิกฤติของตาราง ADF หากค่าสถิติ t มีค่าน้อยกว่าค่าวิกฤติจะปฏิเสธสมมติฐาน H_0 คือข้อมูลอนุกรมเวลาไม่มี unit root หมายถึงข้อมูลอนุกรมเวลามีความนิ่ง

หากข้อมูลอนุกรมเวลาที่นำมาทดสอบยังไม่นิ่งจะต้องแปลงข้อมูลให้มีความนิ่งก่อนโดยการตรวจสอบความแปรปรวนและค่าเฉลี่ยของข้อมูล หากข้อมูลมีความแปรปรวนไม่คงที่ที่จะต้องแปลงข้อมูลด้วยฟังก์ชัน $\ln$ และหากข้อมูลมีค่าเฉลี่ยไม่คงที่ที่จะต้องแปลงข้อมูลด้วยการหาผลต่างจนกว่าข้อมูลจะมีความนิ่ง

2.3.3 การตรวจสอบความมีนัยสำคัญของพารามิเตอร์ในตัวแบบ ARIMA (p,d,q)

การตรวจสอบพารามิเตอร์ทุกตัวในตัวแบบ ARIMA(p,d,q) ว่ามีนัยสำคัญหรือไม่สามารถทำได้โดยการทดสอบ t-test ทดสอบว่าพารามิเตอร์ในตัวแบบทุกตัวมีค่าแตกต่างจากศูนย์หรือไม่ หากมีอย่างน้อย 1 พารามิเตอร์ที่มีค่าไม่แตกต่างจากศูนย์จะต้องทำการกำหนดตัวแบบใหม่สำหรับการทดสอบพารามิเตอร์ของกระบวนการ AR(p) มีสมมติฐานการทดสอบและสถิติทดสอบดังนี้

$$H_0 : \phi_p = 0 \quad \text{เมื่อ } p = 1, 2, 3, \dots$$

$$H_1 : \phi_p \neq 0 \quad \text{เมื่อ } p = 1, 2, 3, \dots$$

สถิติทดสอบ

$$t = \frac{\hat{\phi}_p}{S_{\hat{\phi}_p}}; \text{ มีการแจกแจงแบบ } t \text{ ที่ d.f.} = n-m \quad (16)$$

โดยที่ n หมายถึง จำนวนข้อมูลที่ใช้ศึกษา

m หมายถึง จำนวนพารามิเตอร์ในตัวแบบ

ϕ_p หมายถึง พารามิเตอร์ Autoregressive process อันดับที่ p

$\hat{\phi}_p$ หมายถึง ค่าประมาณพารามิเตอร์ Autoregressive process อันดับที่ p

$S_{\hat{\phi}_p}$ หมายถึง ค่าประมาณของค่าความคลาดเคลื่อนมาตรฐานของ $\hat{\phi}_p$

ปฏิเสธ H_0 ถ้า $|t| > t_{\alpha/2, n-m}$ หมายถึง พารามิเตอร์ ϕ_p มีค่าแตกต่างจากศูนย์ หรือมีพารามิเตอร์ ϕ_p ในตัวแบบ

สำหรับการทดสอบพารามิเตอร์ของกระบวนการ MA(q) มีสมมติฐานการทดสอบและสถิติทดสอบดังนี้

$$H_0: \theta_q = 0 \quad \text{เมื่อ } q = 1, 2, 3, \dots$$

$$H_1: \theta_q \neq 0 \quad \text{เมื่อ } q = 1, 2, 3, \dots$$

สถิติทดสอบ

$$t = \frac{\hat{\theta}_q}{S_{\hat{\theta}_q}}; \text{ มีการแจกแจงแบบ } t \text{ ที่ d.f.} = n-m \quad (17)$$

โดยที่ n หมายถึง จำนวนข้อมูลที่ศึกษา

m หมายถึง จำนวนพารามิเตอร์ในตัวแบบ

θ_q หมายถึง พารามิเตอร์ Moving average process อันดับที่ q

$\hat{\theta}_q$ หมายถึง ค่าประมาณพารามิเตอร์ Moving average process อันดับที่ q

$S_{\hat{\theta}_q}$ หมายถึง ค่าประมาณของค่าความคลาดเคลื่อนมาตรฐานของ $\hat{\theta}_q$

ปฏิเสธ H_0 ถ้า $|t| > t_{\alpha/2, n-m}$ หมายถึงพารามิเตอร์ θ_q มีค่าแตกต่างจากศูนย์ หรือมีพารามิเตอร์ θ_q ในตัวแบบ

2.3.4 การตรวจสอบความความคลาดเคลื่อนสุ่มของตัวแบบ ARIMA (p,d,q)

หลังจากได้ประมาณค่าพารามิเตอร์และตรวจสอบความมีนัยสำคัญของพารามิเตอร์ในตัวแบบ ก่อนพิจารณาเลือกใช้ตัวแบบ ARIMA (p,d,q) พยากรณ์จะต้องตรวจสอบความเหมาะสมของตัวแบบ ARIMA(p,d,q) โดยตรวจสอบคุณสมบัติของความคลาดเคลื่อนสุ่ม 4 ประการได้แก่ ความคลาดเคลื่อนสุ่มมีสหสัมพันธ์ในตนเอง สามารถตรวจสอบโดยการทดสอบ Box-Ljung test, ความคลาดเคลื่อนสุ่มมีค่าเฉลี่ยเท่ากับศูนย์ สามารถทดสอบโดยการทดสอบ t-test, ความคลาดเคลื่อนสุ่มมีการแจกแจงปกติ สามารถตรวจสอบโดยการทดสอบ Kolmogorov-Smirnov test และความคลาดเคลื่อนสุ่มมีความแปรปรวนคงที่ สามารถตรวจสอบโดยการทดสอบ Levene's Test หากตัวแบบที่ได้พบว่าความคลาดเคลื่อนสุ่มไม่ผ่านเกณฑ์คุณสมบัติอย่างน้อย 1 ข้อ จะต้องทำการพิจารณากำหนดตัวแบบ ARIMA (p,d,q) รูปแบบอื่นๆ

1) ตรวจสอบสหสัมพันธ์ในตัวเองของความคลาดเคลื่อนสุ่มโดยใช้การทดสอบ Box-Ljung test

$$H_0: \rho_{\varepsilon_t}(1) = \rho_{\varepsilon_t}(2) = \dots = \rho_{\varepsilon_t}(K) = 0$$

$$H_1: \text{มี } \rho_{\varepsilon_t}(k) \text{ อย่างน้อย 1 ค่าที่แตกต่างจากศูนย์}$$

สถิติทดสอบ

$$Q = n(n+2) \sum_{k=1}^K \frac{r_{\varepsilon_t}^2(k)}{(n-k)}; k = 1, 2, 3, \dots, K \quad (18)$$

โดยที่ n หมายถึง ขนาดตัวอย่างของข้อมูล

$r_{\varepsilon_t}(k)$ หมายถึง สหสัมพันธ์ในตัวเองของความคลาดเคลื่อนที่ Lag k

เมื่อ

$$r_{\varepsilon_t}(k) = \frac{\sum_{t=k+1}^n (e_t - \bar{e})(e_{t-k} - \bar{e})}{\sum_{t=1}^n (e_t - \bar{e})^2} \quad (19)$$

k หมายถึง ช่วงเวลาที่พิจารณาค่าสหสัมพันธ์ในตัวเองของความ

คลาดเคลื่อน โดยที่ $k = 1, 2, 3, \dots, K$
 K หมายถึง จำนวน Lags ทั้งหมดที่
 พิจารณาทำการทดสอบโดย
 กำหนดให้ค่าเท่ากับ $\ln(n)$
 ตามแนวทางเลือกจำนวน Lag
 ของ Tsay [10]

ปฏิเสธ H_0 ถ้า $Q > \chi^2_{\alpha, K-m}$ หมายความว่า
 ความคลาดเคลื่อนสุ่มมีสหสัมพันธ์ในตัวเองตั้งแต่ Lag ที่ 1
 ถึง Lag ที่ K เมื่อ $\chi^2_{\alpha, K-m}$ คือค่าจากตารางสถิติ Chi-
 Square ที่มี d.f. = $K-m$ ซึ่ง m หมายถึงจำนวน
 พารามิเตอร์ในแบบที่นำมาตรวจสอบความเหมาะสม

2) การตรวจสอบการแจกแจงปกติของความ
 คลาดเคลื่อนสุ่มโดยใช้การทดสอบ Kolmogorov-Smirnov

H_0 : ความคลาดเคลื่อนสุ่มมีการแจกแจงปกติ

H_1 : ความคลาดเคลื่อนสุ่มไม่มีการแจกแจงปกติ
 กรณีที่ $n < 30$
 สถิติทดสอบ

$$D_n = \max(D_n^+, D_n^-) \quad (20)$$

$$D_n = \max \left[\max \left| \frac{i}{n} - F(e) \right|, \max \left| F(e) - \frac{(i-1)}{n} \right| \right] \quad (21)$$

เมื่อ $i = 1, 2, \dots, n$

กรณีที่ $n > 30$

สถิติทดสอบ

$$Z = \frac{D_n}{\sqrt{\frac{1}{n}}} \quad (22)$$

โดยที่ $F(e)$ หมายถึง ความน่าจะเป็นสะสมของ
 ค่าประมาณของความคลาดเคลื่อน

ปฏิเสธ H_0 เมื่อ $|Z| > Z_{\alpha/2}$ หมายความว่า
 ความคลาดเคลื่อนสุ่มไม่มีการแจกแจงปกติ โดยที่ $Z_{\alpha/2}$ คือ
 ค่าจากตารางสถิติ Standard Normal

3) การตรวจสอบความคลาดเคลื่อนสุ่มมีค่าเฉลี่ยไม่
 แตกต่างจากศูนย์โดยใช้การทดสอบ t-test

H_0 : ความคลาดเคลื่อนสุ่มมีค่าเฉลี่ยไม่แตกต่างจากศูนย์

H_1 : ความคลาดเคลื่อนสุ่มมีค่าเฉลี่ยแตกต่างจาก
 ศูนย์สถิติทดสอบ

$$t = \frac{\bar{e}}{S_{\bar{e}}} ; \text{เมื่อ } S_{\bar{e}} = \sqrt{\frac{\sum (e - \bar{e})^2}{n-1}} \quad (23)$$

โดยที่ $\bar{e}$ หมายถึง ค่าเฉลี่ยตัวอย่างของค่าความ
 คลาดเคลื่อน

$S_{\bar{e}}$ หมายถึง ส่วนเบี่ยงเบนมาตรฐาน
 ตัวอย่างของค่าความ
 คลาดเคลื่อน

e หมายถึง ความคลาดเคลื่อน

n หมายถึง จำนวนข้อมูลตัวอย่าง

ปฏิเสธ H_0 ถ้า $|t| > t_{\alpha/2, n-1}$ หมายความว่าความ
 คลาดเคลื่อนสุ่มมีค่าเฉลี่ยแตกต่างจากศูนย์

4) การตรวจสอบความคลาดเคลื่อนสุ่มมีความ
 แปรปรวนคงที่ โดยใช้การทดสอบ Levene's Test

$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2$

H_1 : มี $\sigma_i^2 \neq \sigma_j^2$ อย่างน้อย 1 กลุ่ม เมื่อ
 $i=1, 2, \dots, k$ และ $j=1, 2, \dots, k$

สถิติทดสอบ

$$W = \frac{(N-k)}{k-1} \frac{\sum_{i=1}^k N_i (\bar{Z}_{i..} - \bar{Z}_{..})^2}{\sum_{i=1}^k \sum_{j=1}^{N_i} (Z_{ij} - \bar{Z}_{i..})^2} \quad (24)$$

โดยที่ N หมายถึง ขนาดตัวอย่างทั้งหมด

N_i หมายถึง ขนาดตัวอย่างกลุ่มที่ i

$\bar{Z}_{i..}$ หมายถึง ค่าเฉลี่ยของกลุ่ม $Z_{i..}$

$\bar{Z}_{..}$ หมายถึง ค่าเฉลี่ยรวมของ Z_{ij}

ปฏิเสธ H_0 ถ้า $W > F_{\alpha, k-1, N-k}$ หมายความว่า
 ความคลาดเคลื่อนสุ่มมีความแปรปรวนไม่คงที่ โดย
 $F_{\alpha, k-1, N-k}$ คือค่าจากตารางการแจกแจง F ที่มีระดับ
 นัยสำคัญ α และมี d.f. เป็น $k-1$ และ $N-k$

2.4 การพยากรณ์ด้วยวิธีการเรียนรู้ของเครื่องแบบ Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) เป็นอัลกอริทึมการเรียนรู้ของเครื่องที่รวมต้นไม้ตัดสินใจหลายต้นเข้าด้วยกันแบบเป็นลำดับ โดยภายในต้นไม้ตัดสินใจแต่ละต้นที่นำมารวมเข้าด้วยกันจะทำงานคล้ายการตัดสินใจของมนุษย์ที่มีลักษณะแผนภาพต้นไม้ สำหรับงานประเภทการทำนายค่าต่อเนื่อง การรวมโมเดลจะเริ่มจากการสร้างโมเดลแรกที่ยังใช้ทำนายได้ไม่ดี (Weak learner) จากนั้นการสร้างต้นไม้ตัดสินใจครั้งต่อไปจะเรียนรู้ด้วยความคลาดเคลื่อนจากการพยากรณ์หลังจากการสร้างต้นไม้ตัดสินใจเพิ่มในรอบก่อนหน้านี้ กล่าวคือทุกต้นไม้ตัดสินใจใหม่ที่จะนำมารวมเพิ่มเติมจะแตกกิ่งแบ่งค่าความผิดพลาดในการทำนายของโมเดลก่อนหน้านี้ออกตามเงื่อนไขการตัดสินใจที่เหมาะสมจนไม่สามารถแบ่งได้ ทำให้ได้ใบ (Leaf) ซึ่งเป็นค่าพยากรณ์ของต้นไม้ต้นนั้น ค่าพยากรณ์ของต้นไม้จะถูกสร้างโดยมีจุดมุ่งหมายในการทำให้ฟังก์ชันความสูญเสีย (Loss Function) หรือฟังก์ชันคำนวณความผิดพลาดในการทำนายให้มีค่าต่ำที่สุด สำหรับการทำนายค่าต่อเนื่องฟังก์ชันความสูญเสียแสดงได้ดังสมการที่ 25

$$L(y_i, p_i) = (y_i - p_i)^2 \quad (25)$$

โดยที่ $L(y_i, p_i)$ หมายถึง Loss function สำหรับวัด

ความผิดพลาดจากการทำนาย

y_i หมายถึง ข้อมูลจริงลำดับที่ i

p_i หมายถึง ผลลัพธ์จากการพยากรณ์ของข้อมูลจริงลำดับที่ i หลังจากเพิ่มต้นไม้ตัดสินใจ

หลังจากนำผลลัพธ์จากโมเดลแรกมาบวกรวมกับต้นไม้ตัดสินใจที่แก้ไขความผิดพลาดของโมเดลรวมที่มีอยู่ก่อนหน้านี้ สามารถแสดงสมการคำนวณผลลัพธ์จากโมเดลรวมได้ดังสมการที่ 26

$$\text{ผลการทำนายจากโมเดลรวม} = b + \eta(T_1 + T_2 + \dots T_n) \quad (26)$$

โดยที่ b หมายถึง ผลลัพธ์จากโมเดลทำนายพื้นฐาน

η หมายถึง พารามิเตอร์อัตราการเรียนรู้

T_i หมายถึง ผลลัพธ์จากการทำนายของต้นไม้ตัดสินใจที่ i เมื่อ

$$i = 1, 2, 3, \dots, n$$

2.5 สถิติวัดความคลาดเคลื่อนจากการพยากรณ์

ความถูกต้องของการพยากรณ์จะขึ้นอยู่กับความคลาดเคลื่อนหรือความแตกต่างระหว่างค่าจริงและค่าพยากรณ์ นั่นคือหากค่าจริงกับพยากรณ์แตกต่างกันมาก จะมีความคลาดเคลื่อนจากการพยากรณ์สูงโดยความคลาดเคลื่อนคำนวณได้ดังสมการที่ 27

$$e_i = Y_i - \hat{Y}_i \quad (27)$$

โดยที่ e_i หมายถึง ความคลาดเคลื่อนจากการพยากรณ์ เวลาที่ t

Y_i หมายถึง ค่าจริงของข้อมูล เวลาที่ t

$\hat{Y}_i$ หมายถึง ค่าพยากรณ์ข้อมูล เวลาที่ t

ค่าความคลาดเคลื่อน e_i ที่ได้สามารถคำนวณค่าสถิติวัดความแม่นยำของตัวแบบพยากรณ์ ได้แก่ MAD ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ เป็นค่าวัดความถูกต้องที่จะเฉลี่ยความผิดพลาดโดยไม่คำนึงทิศทาง มีหน่วยเดียวกับข้อมูล แสดงดังสมการที่ 28, RMSE ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง มีหน่วยเดียวกับข้อมูล แสดงดังสมการที่ 29 และ MAPE ค่าเฉลี่ยร้อยละของความคลาดเคลื่อนสัมบูรณ์ เป็นค่าวัดที่คำนวณโดยการนำขนาดร้อยละของความคลาดเคลื่อนเทียบกับค่าจริงมาหาค่าเฉลี่ยแสดงดังสมการที่ 30

$$MAD = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (28)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad (29)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{e_i}{Y_i} \right| \times 100}{n} \quad (30)$$

โดยที่ n หมายถึง จำนวนข้อมูล

3. วิธีการดำเนินงานวิจัย

3.1 การเก็บรวบรวมและเตรียมข้อมูล

ข้อมูลที่เก็บรวบรวมสำหรับการสร้างและเปรียบเทียบวิธีการพยากรณ์ คือ ข้อมูลทศนิยมอัตราแลกเปลี่ยนทองคำดอลลาร์สหรัฐ (XAU/USD) จากเว็บไซต์ investing.com เก็บรวบรวมข้อมูลตั้งแต่วันที่ 24 กุมภาพันธ์ พ.ศ. 2565 ถึงวันที่ 14 กุมภาพันธ์ พ.ศ. 2568 รวม 773 วัน ข้อมูลประกอบด้วยวันเดือนปี ราคาสุด ราคาเปิด ราคาสูงสุด ราคาต่ำสุด และอัตราการเปลี่ยนแปลง การศึกษาในครั้งนี้จะใช้ราคาสุดในการวิเคราะห์สร้างตัวแบบพยากรณ์เพื่อเปรียบเทียบประสิทธิภาพแต่ละวิธีโดยแบ่งข้อมูลตามลำดับเวลา โดยใช้ข้อมูลช่วงเวลา 80% แรกสำหรับสร้างตัวแบบพยากรณ์ และใช้ข้อมูลช่วงเวลา 20% สุดท้ายสำหรับการทดสอบประสิทธิภาพของตัวแบบ

3.2 การพยากรณ์ด้วยวิธีทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt

การพยากรณ์ด้วยวิธีทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt มีขั้นตอนดังนี้

- 1) ตรวจสอบส่วนประกอบของอนุกรมเวลาได้แก่ แนวโน้มและฤดูกาล
- 2) ประมาณค่าพารามิเตอร์ด้วยวิธี Maximum Likelihood Estimation (MLE) และสร้างตัวแบบพยากรณ์
- 3) คำนวณค่าพยากรณ์บนข้อมูลทดสอบและคำนวณสถิติวัดประสิทธิภาพ

3.3 การพยากรณ์ด้วยวิธี ARIMA

- 1) ตรวจสอบความนิ่งของข้อมูลหากข้อมูลยังไม่นิ่งจะต้องแปลงข้อมูลให้มีความนิ่งก่อน
- 2) ระบุรูปแบบ ARIMA (p,d,q) จากการตรวจสอบคอเรโลแกรมของ ACF และ PACF ของข้อมูลที่มีความนิ่ง
- 3) ประมาณค่าพารามิเตอร์ด้วยวิธี Maximum Likelihood Estimation (MLE)
- 4) ตรวจสอบความมีนัยสำคัญของทุกพารามิเตอร์ในตัวแบบ
- 5) ตรวจสอบความเหมาะสมของตัวแบบ
- 6) เลือกตัวแบบที่เหมาะสม คำนวณค่าพยากรณ์บนข้อมูลทดสอบ และคำนวณสถิติวัดประสิทธิภาพ

3.4 การพยากรณ์ด้วยวิธี Extreme Gradient Boosting

1) เตรียมข้อมูลโดยการนำข้อมูลราคาล่าสุดรายวันมาหาผลต่างข้อมูล 1 ครั้งเพื่อแก้ไขปัญหาการพยากรณ์ค่านอกช่วงสำหรับข้อมูลที่มีแนวโน้มด้วย XGBoost ตามแนวทางของเอกสารประกอบการใช้งานไลบรารี Skforecast [11]

2) กำหนดไฮเพอร์พารามิเตอร์สำคัญที่จะนำมาใช้สร้างตัวแบบตามแนวทางของ Liu [9] ในการศึกษานี้จะทำการทดลองสำรวจว่าค่าที่เหมาะสมของแต่ละไฮเพอร์พารามิเตอร์ควรอยู่ในช่วงใด จากนั้นจึงดำเนินการหาค่าที่เหมาะสมที่สุดสำหรับแต่ละไฮเพอร์พารามิเตอร์ แสดงค่าที่กำหนดสำหรับการหาค่าที่เหมาะสมของแต่ละไฮเพอร์พารามิเตอร์ดังตารางที่ 1

ตารางที่ 1 ค่าที่กำหนดสำหรับการหาค่าที่เหมาะสมของไฮเพอร์พารามิเตอร์

พารามิเตอร์	ค่าที่กำหนด
Minimum child weight	1, 3
Learning rate	0.01, 0.05
gamma	0.05, 0.1
lambda	0.1, 0.2
Max depth	6, 12
N_estimator	50, 100
จำนวนข้อมูลนำเข้า (วัน)	40, 80

3) หาค่าที่เหมาะสมสำหรับแต่ละไฮเพอร์พารามิเตอร์ด้วยการค้นหาแบบ GridSearch ผ่านการประเมินด้วยวิธี Rolling Window Cross Validation โดยแบ่งเป็น 5 ช่วงเวลา

4) สร้างตัวแบบพยากรณ์ด้วยไฮเพอร์พารามิเตอร์ที่เหมาะสมที่สุดด้วยวิธีการพยากรณ์ล่วงหน้าหลายช่วงเวลาแบบ Direct ตามแนวทางของ Bontempi et al. [12] ที่ได้นำเสนอเทคนิคการนำการเรียนรู้ของเครื่องมาประยุกต์ใช้พยากรณ์อนุกรมเวลา

5) พยากรณ์บนข้อมูลทดสอบ และคำนวณสถิติวัดประสิทธิภาพ

3.5 การเปรียบเทียบประสิทธิภาพการพยากรณ์

การคัดเลือกวิธีการพยากรณ์ที่มีความเหมาะสมมากที่สุดผู้วิจัยเลือกใช้ 3 เกณฑ์การวัดประสิทธิภาพ ได้แก่ MAD ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ , RMSE ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง และ MAPE ค่าเฉลี่ยร้อยละของความคลาดเคลื่อนสัมบูรณ์ สำหรับการคัดเลือกวิธีการพยากรณ์ที่มีความเหมาะสมมากที่สุด

4. ผลการวิจัย

ผลการวิจัยประกอบด้วยผลการวิเคราะห์สำหรับการสร้างตัวแบบพยากรณ์ ค่าพยากรณ์ที่ได้ และค่าประสิทธิภาพการพยากรณ์จากการสร้างตัวแบบโดยใช้อัตราแลกเปลี่ยนทองคำต่อดอลลาร์สหรัฐรายวันตั้งแต่วันที่ 24 กุมภาพันธ์ พ.ศ. 2565 ถึงวันที่ 10 กรกฎาคม พ.ศ. 2567 จำนวน 618 วัน และประเมินประสิทธิภาพบนข้อมูลทดสอบวันที่ วันที่ 11 กรกฎาคม พ.ศ. 2567 ถึงวันที่ 14 กุมภาพันธ์ พ.ศ. 2568 จำนวน 155 วัน แสดงข้อมูลฝึกสำหรับการสร้างตัวแบบพยากรณ์ดังรูปที่ 2

ลักษณะของข้อมูลฝึก



รูปที่ 2 ข้อมูลฝึกสำหรับสร้างตัวแบบพยากรณ์

4.1 ผลการวิเคราะห์ข้อมูลด้วยวิธีการทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt

จากการตรวจสอบข้อมูลฝึกดังรูปที่ 2 พบว่าข้อมูลมีแนวโน้มและไม่มีฤดูกาลจึงมีความเหมาะสมในการพยากรณ์ด้วยวิธีทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt ทำการประมาณค่าพารามิเตอร์ค่าคงที่ในการทำให้เรียบในแนวระดับ α และค่าคงที่ในแนวความชัน γ แล้วคำนวณ

ค่าสถิติปรับให้เรียบในแนวระดับ (S_t) และค่าสถิติปรับให้เรียบในแนวความชัน (β_t) แสดงผลลัพธ์ดังตารางที่ 2

ตารางที่ 2 การคำนวณค่าพารามิเตอร์และค่าเริ่มต้นสำหรับการพยากรณ์ด้วยวิธีของ Holt


พารามิเตอร์	ค่าที่ได้
ค่าคงที่ในการทำให้เรียบในแนวระดับ (α)	0.9343
ค่าคงที่ในการทำให้เรียบของแนวโน้ม (γ)	0.0001
ค่าสถิติปรับให้เรียบในแนวระดับ (S_t)	2370.6225
ค่าสถิติปรับให้เรียบในแนวความชัน (β_t)	0.8034

จากการวิเคราะห์ข้อมูลสามารถเขียนสมการพยากรณ์ล่วงหน้า l ช่วงเวลาต่อจากข้อมูลฝึก เมื่อกำหนดให้ t เป็นจุดสุดท้ายของข้อมูลฝึกได้ดังสมการที่ 31

$$\hat{Z}_{t+l} = 2370.6225 + 0.8034l \quad (31)$$

ผลการพยากรณ์ด้วยสมการพยากรณ์ที่ได้จากการสร้างตัวแบบด้วยวิธีทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt แสดงดังรูปที่ 3

ผลการพยากรณ์ราคาทองคำด้วยวิธีของ Holt




รูปที่ 3 ผลลัพธ์การพยากรณ์ด้วยวิธีการทำให้เรียบแบบเอกซ์โพเนนเชียลของ Holt

4.2 ผลการวิเคราะห์ข้อมูลด้วยวิธี ARIMA


ก่อนทำการระบุตัวแบบพยากรณ์ด้วยวิธี ARIMA ที่เหมาะสมและสร้างตัวแบบพยากรณ์จะต้องทำการตรวจสอบความนิ่งของข้อมูล หากข้อมูลยังไม่นิ่งจะต้องทำการแปลงข้อมูลให้มีความนิ่งก่อน

จากการตรวจสอบความนิ่งของข้อมูลฝึกสำหรับสร้าง
ตัวแบบพยากรณ์ดังรูปที่ 2 โดยการทดสอบ Augmented
Dickey-Fuller Test พบว่าสถิติที่ใช้ทดสอบความนิ่งของ
ข้อมูลคือ Augmented Dickey-Fuller มีค่าเท่ากับ -2.7829
และมี p-value เท่ากับ 0.2469 ซึ่งมากกว่าระดับนัยสำคัญ
 $\alpha = 0.05$ จึงไม่ปฏิเสธสมมติฐานหลักที่ระดับนัยสำคัญ
0.05 หมายความว่าข้อมูลไม่มีความนิ่ง จะต้องทำการแปลง
ข้อมูลให้มีความนิ่งด้วยการหาผลต่างอันดับที่ 1 หลังจากหา
ผลต่างข้อมูลครั้งที่ 1 แล้วจะทำการทดสอบ Augmented
Dickey-Fuller test อีกครั้ง แสดงข้อมูลหลังหาผลต่างครั้งที่
1 ดังรูปที่ 4




รูปที่ 4 ข้อมูลฝึกหลังหาผลต่างครั้งที่ 1

จากการตรวจสอบความนิ่งของข้อมูลหลังหาผลต่าง
ครั้งที่ 1 ดังรูปที่ 4 ด้วยการทดสอบ Augmented Dickey-
Fuller Test พบว่าสถิติที่ใช้ทดสอบความนิ่งของข้อมูล ADF
มีค่า -8.3439 และมี p-value เท่ากับ 0.01 ซึ่งมีค่าต่ำกว่า
ระดับนัยสำคัญ $\alpha = 0.05$ จึงปฏิเสธสมมติฐานหลักที่ระดับ
นัยสำคัญ 0.05 หมายความว่าข้อมูลมีความนิ่งสามารถใช้
พิจารณาคอเรโลแกรมของ ACF และ PACF เพื่อระบุตัว
แบบ ARIMA(p,d,q) แสดงคอเรโลแกรม ACF และ PACF
ของข้อมูลฝึกหลังหาผลต่างข้อมูลครั้งที่ 1 ดังรูปที่ 5



รูปที่ 5 คอเรโลแกรม ACF และ PACF ของข้อมูลฝึกหลัง
หาผลต่างครั้งที่ 1


จากผลการพิจารณาคอเรโลแกรมของสหสัมพันธ์ใน
ตัวเอง (ACF) และคอเรโลแกรมของสหสัมพันธ์บางส่วน
(PACF) ดังรูปที่ 5 พบว่า รูปแบบของ ACF และ PACF ไม่
ปรากฏอย่างแน่ชัด จึงพิจารณาหาผลต่างอันดับที่ 2 แล้วทำ
การทดสอบ Augmented Dickey-Fuller Test เพื่อ
ตรวจสอบความนิ่งอีกครั้ง หากข้อมูลมีความนิ่งจะทำการ
พล็อตคอเรโลแกรมของ ACF และ PACF เพื่อระบุตัวแบบ
ARIMA(p,d,q) ด้วยข้อมูลฝึกหลังหาผลต่างอันดับที่ 2 แสดง
ข้อมูลหลังหาผลต่างครั้งที่ 2 ดังรูปที่ 6



รูปที่ 6 ข้อมูลฝึกหลังหาผลต่างครั้งที่ 2

หลังจากพิจารณาหาผลต่างข้อมูลครั้งที่ 2 ดังรูปที่ 6
และทำการตรวจสอบความนิ่งของข้อมูลด้วยการทดสอบ
Augmented Dickey-Fuller Test พบว่าสถิติที่ทดสอบ
ADF มีค่าเท่ากับ 12.572 และมี p-value เท่ากับ 0.01 ซึ่งมี
ค่าต่ำกว่าระดับนัยสำคัญ $\alpha = 0.05$ จึงปฏิเสธสมมติฐาน
หลักที่ระดับนัยสำคัญ 0.05 หมายความว่าข้อมูลหลังหา
ผลต่างครั้งที่ 2 มีความนิ่งแล้ว ในขั้นตอนต่อไปจะทำการ
พิจารณากำหนดตัวแบบ ARIMA(p,d,q) อีกครั้งด้วยข้อมูล

หลังจากดำเนินการหาผลต่างอันดับที่ 2 แสดงคอเรโลแกรม ACF และ PACF ของข้อมูลหลังหาผลต่างครั้งที่ 2 ดังรูปที่ 7



รูปที่ 7 คอเรโลแกรม ACF และ PACF ข้อมูลฝึกหลังหาผลต่างอันดับที่ 2

จากรูปที่ 7 ลักษณะของสหสัมพันธ์ในตัวเองปรากฏอย่างชัดเจน ณ Lag ที่ 1 แล้วลดลงอย่างรวดเร็ว ในขณะที่สหสัมพันธ์ในตัวเองบางส่วนมีลักษณะลดลงช้าใกล้ 0 จึงกำหนดตัวแบบ ARIMA(0,2,1) ประมาณค่าพารามิเตอร์ด้วยวิธีความน่าจะเป็นสูงสุด จากนั้นจึงตรวจสอบความมีนัยสำคัญของพารามิเตอร์ในตัวแบบนี้ทดสอบว่า θ_1 มีค่าแตกต่างจากศูนย์หรือไม่ ได้ผลลัพธ์ดังตารางที่ 3

ตารางที่ 3 การทดสอบความมีนัยสำคัญของพารามิเตอร์ในตัวแบบ ARIMA(0,2,1)

พารามิเตอร์	Coefficient	S.E. Coefficient	t	p-value
θ_1	-0.996	0.006	-160.86	0.0001

จากตารางที่ 3 เนื่องจากสถิติที่ทดสอบ t มีค่าเท่ากับ -160.86 และมี p-value เข้าใกล้ 0 ซึ่งมีค่าน้อยกว่าระดับนัยสำคัญ $\alpha = 0.05$ จึงปฏิเสธสมมติฐานหลัก หมายความว่าพารามิเตอร์ θ_1 แตกต่างจากศูนย์นั่นคือพารามิเตอร์ θ_1 มีนัยสำคัญ หรือ มีพารามิเตอร์ θ_1 ในตัวแบบ ARIMA(0,2,1) ได้สมการพยากรณ์ด้วยวิธีของ Box และ Jenkins ดังสมการที่ 32

$$\hat{Y}_t = 2Y_{t-1} - Y_{t-2} + e_t - 0.996e_{t-1} \quad (32)$$

ในขั้นตอนต่อไปทำการตรวจสอบความเหมาะสมของตัวแบบ ARIMA(0,2,1) ที่ได้โดยการทดสอบสมมติฐาน

ตรวจสอบคุณสมบัติของความคลาดเคลื่อนของตัวแบบ 4 การทดสอบ ได้แก่ การทดสอบสหสัมพันธ์ในตัวเองด้วย Box-Ljung test การทดสอบการแจกแจงปกติ ด้วย Kolmogorov-Smirnov test การทดสอบว่าเฉลี่ยของค่าคลาดเคลื่อนไม่แตกต่างจากศูนย์ด้วย t-test และการทดสอบความแปรปรวนคงที่ด้วย Levene's test แสดงผลการทดสอบสมมติฐานตรวจสอบคุณสมบัติของความคลาดเคลื่อนที่ได้จากตัวแบบ ARIMA(0,2,1) ดังตารางที่ 4


ตารางที่ 4 ผลการทดสอบสมมติฐานตรวจสอบคุณสมบัติของความคลาดเคลื่อนที่ได้จากตัวแบบ ARIMA(0,2,1)

การตรวจสอบความคลาดเคลื่อน	สถิติทดสอบ	p-value
การมีสหสัมพันธ์ในตัวเอง	Q = 12.2420	0.0316
การแจกปกติ	Z = 0.0485	0.1101
ค่าเฉลี่ยเท่ากับศูนย์	t = 0.7796	0.4359
ความแปรปรวนคงที่	W = 3.4178	0.0004

จากการตรวจสอบความเหมาะสมของตัวแบบ ARIMA(0,2,1) ด้วยการตรวจสอบคุณสมบัติความคลาดเคลื่อน จากตารางที่ 4 พบว่าการตรวจสอบการมีสหสัมพันธ์ในตัวเองด้วยการทดสอบ Box Ljung test ที่ Lag ที่ 1 ถึง 5 มีสถิติทดสอบ Q เท่ากับ 12.2420 และมี p-value เท่ากับ 0.0316 ซึ่งมีค่าต่ำกว่าระดับนัยสำคัญ 0.05 จึงปฏิเสธสมมติฐานหลัก หมายความว่าความคลาดเคลื่อนของตัวแบบ ตั้งแต่ Lag ที่ 1 ถึง 5 มีสหสัมพันธ์ในตัวเอง สำหรับการตรวจสอบการแจกแจงปกติด้วยการทดสอบ Kolmogorov-Smirnov test มีสถิติ Z เท่ากับ 0.0485 มี p-value เท่ากับ 0.1101 ซึ่งสูงกว่าระดับนัยสำคัญ 0.05 จึงไม่ปฏิเสธสมมติฐานหลัก หมายความว่าความคลาดเคลื่อนมีการแจกแจงปกติ ในส่วนของการตรวจสอบคุณสมบัติค่าเฉลี่ยเท่ากับศูนย์ด้วยการทดสอบ t-test มีสถิติทดสอบ t เท่ากับ 0.7796 มี p-value เท่ากับ 0.4359 ซึ่งสูงกว่าระดับนัยสำคัญ 0.05 จึงไม่ปฏิเสธสมมติฐานหลัก หมายความว่าความคลาดเคลื่อนมีค่าเฉลี่ยเท่ากับศูนย์ ในขณะที่การตรวจสอบความแปรปรวนคงที่โดยใช้การทดสอบ Levene's test ที่กำหนดให้ข้อมูลมีจำนวน 10 กลุ่ม พบว่าสถิติ W มีค่าเท่ากับ

3.4178 มี p-value เท่ากับ 0.0004 ซึ่งมีค่าต่ำกว่าระดับนัยสำคัญ 0.05 จึงปฏิเสธสมมติฐานหลัก หมายความว่าความคลาดเคลื่อนมีความแปรปรวนไม่คงที่

ผลการตรวจสอบความเหมาะสมของตัวแบบ ARIMA พบว่าความคลาดเคลื่อนของตัวแบบ ARIMA(0,2,1) ที่ได้ มีการแจกแจงปกติ และมีค่าเฉลี่ยไม่แตกต่างจากศูนย์ แต่มีปัญหาสหสัมพันธ์ในตัวเอง และมีความแปรปรวนไม่คงที่ ดังนั้นตัวแบบ ARIMA(0,2,1) ที่ได้นี้ไม่มีความเหมาะสมในการนำมาใช้พยากรณ์ อย่างไรก็ตามตัวแบบ ARIMA (0,2,1) เป็นตัวแบบที่ดีที่สุดที่ได้จากการศึกษา จึงพิจารณาเลือกใช้ตัวแบบ ARIMA(0,2,1) สำหรับการพยากรณ์ด้วยวิธี ARIMA เพื่อเปรียบเทียบกับวิธีพยากรณ์อื่นๆ ซึ่งจะให้เห็นประสิทธิภาพของแต่ละวิธีพยากรณ์ได้ดียิ่งขึ้น แสดงผลการพยากรณ์ด้วยตัวแบบ ARIMA(0,2,1) ดังรูปที่ 8



รูปที่ 8 ผลลัพธ์การพยากรณ์ด้วยวิธี ARIMA(0,2,1)

4.3 ผลการวิเคราะห์ข้อมูลด้วยวิธีการเรียนรู้ของเครื่องแบบ XGBoost


ก่อนดำเนินการพยากรณ์ ได้มีการแปลงข้อมูลฝึกด้วยการหาผลต่าง 1 ครั้ง เพื่อแก้ปัญหาการพยากรณ์ค่านอกช่วงสำหรับโมเดลประเภทต้นไม้ตัดสินใจ จากนั้นหาไฮเพอร์พารามิเตอร์ที่เหมาะสมที่สุด ด้วยการ ค่าที่เหมาะสมสำหรับแต่ละไฮเพอร์พารามิเตอร์สำหรับการพยากรณ์ด้วยวิธีการเรียนรู้ของเครื่องแบบ XGBoost ดังตารางที่ 5

ตารางที่ 5 ไฮเพอร์พารามิเตอร์ที่เหมาะสมสำหรับการพยากรณ์ด้วยวิธีการเรียนรู้ของเครื่องแบบ XGBoost

ไฮเพอร์พารามิเตอร์	ค่าที่กำหนด
Minimum child weight	1
Learning rate	0.01
Gamma	0.1
Lambda	0.1
Max depth	12
N_estimator	50
จำนวนข้อมูลนำเข้า (วัน)	40


หลังจากกำหนดพารามิเตอร์สำหรับการเรียนรู้ฝึกโมเดลด้วยข้อมูลฝึกที่แปลงให้อยู่ในรูปของผลต่างอันดับที่ 1 โดยจะฝึกโมเดลจำนวนเท่ากับช่วงเวลาล่วงหน้าที่ต้องการพยากรณ์ ดังนั้นจึงมีการฝึกโมเดลทั้งสิ้น 155 โมเดล ตามแนวทางการพยากรณ์ล่วงหน้าหลายช่วงเวลาแบบ Direct โดยกำหนดไฮเพอร์พารามิเตอร์เหมือนกันทุกโมเดล แสดงผลการพยากรณ์ในรูปผลต่างอันดับที่ 1 ดังรูปที่ 9 แสดงผลการพยากรณ์หลังแปลงข้อมูลกลับดังรูปที่ 10

ผลการพยากรณ์ราคาทองคำด้วย XGBoost (ผลต่างลำดับที่ 1)



รูปที่ 9 ผลการพยากรณ์ในรูปผลต่างอันดับที่ 1


ผลการพยากรณ์ราคาทองคำด้วย XGBoost



รูปที่ 10 ผลการพยากรณ์หลังแปลงข้อมูลกลับ

4.4 เปรียบเทียบประสิทธิภาพการพยากรณ์

ผลการพยากรณ์ราคาทองคำในช่วงข้อมูลทดสอบ (Test Set) พบว่าราคาทองคำจริง (เส้นสีน้ำเงิน) มีแนวโน้มปรับตัวสูงขึ้นตลอดช่วงเวลาในชุดข้อมูลทดสอบ และมีความผันผวนเกิดขึ้นในระยะสั้น เมื่อวิเคราะห์ผลลัพธ์ของแต่ละวิธีการพยากรณ์พบว่าโมเดล Holt's Exponential Smoothing (เส้นสีเขียว) และตัวแบบ ARIMA(0,2,1) (เส้นสีส้ม) สามารถจับทิศทางแนวโน้มขาขึ้นโดยรวมได้ดี แต่เส้นพยากรณ์ที่ได้มีลักษณะค่อนข้างเรียบเนื่องจากไม่สามารถสะท้อนความผันผวนของราคาที่เกิดขึ้นได้ ในส่วนของการเรียนรู้ของเครื่อง XGBoost (เส้นสีแดง) มีความสามารถในการพยากรณ์แนวโน้มและตรวจจับความผันผวนได้เล็กน้อย และให้ผลลัพธ์การพยากรณ์ที่มีความแม่นยำมากกว่าโมเดลอื่น แสดงการเปรียบเทียบผลลัพธ์การพยากรณ์ในข้อมูลทดสอบดังรูปที่ 11



รูปที่ 11 ผลการพยากรณ์ด้วยวิธีของ Holt, วิธี ARIMA และวิธี XGBoost บนข้อมูลชุดทดสอบ

ตารางที่ 6 เปรียบเทียบค่าวัดประสิทธิภาพการพยากรณ์ด้วยวิธีของ Holt, ARIMA(0,2,1) และ XGBoost

	Holt's	ARIMA (0,2,1)	XGBoost
MAD	186.1688	151.2608	132.5518
RMSE	210.5272	173.1838	156.4902
MAPE	6.9454%	5.6424%	4.9578%

จากตารางที่ 6 เมื่อพิจารณาการวัดประสิทธิภาพการพยากรณ์พบว่า XGBoost มีค่าวัดความคลาดเคลื่อนในการพยากรณ์ทั้ง MAD, RMSE และ MAPE ต่ำที่สุด รองลงมาคือ

วิธี ARIMA(0,2,1) และวิธีการปรับให้เรียบแบบเอกซ์โพเนนเชียลของ Holt ดังนั้น สรุปได้ว่าวิธีการพยากรณ์ XGBoost มีประสิทธิภาพสูงสุดในการพยากรณ์ราคาทองคำในช่วงสถานการณ์สงครามระหว่างรัสเซียและยูเครนที่ใช้ในการศึกษาครั้งนี้

5. สรุปผล

จากการศึกษาและเปรียบเทียบประสิทธิภาพการพยากรณ์ราคาทองคำภายใต้สถานการณ์ความขัดแย้งระหว่างรัสเซียและยูเครน โดยใช้วิธีการพยากรณ์แบบอนุกรมเวลา ได้แก่ วิธีปรับให้เรียบแบบเอกซ์โพเนนเชียลของ Holt และวิธีของ Box-Jenkins (ARIMA) เปรียบเทียบกับวิธีการเรียนรู้ของเครื่อง XGBoost พบว่า XGBoost มีประสิทธิภาพในการพยากรณ์สูงที่สุดในทุกตัวชี้วัด โดยเมื่อพิจารณาจากค่า MAPE ซึ่งเป็นตัวชี้วัดร้อยละของความผิดพลาดโดยเฉลี่ยพบว่า XGBoost มีค่าร้อยละความผิดพลาดโดยเฉลี่ยต่ำกว่าวิธี Holt 1.9876 จุดเปอร์เซ็นต์ และต่ำกว่าวิธี ARIMA 0.6846 จุดเปอร์เซ็นต์

ผลการวิเคราะห์ยังแสดงให้เห็นว่าวิธีอนุกรมเวลา เช่น Holt และ ARIMA(0,2,1) มีข้อจำกัดในการใช้งานกับข้อมูลที่มีรูปแบบที่ไม่เป็นเชิงเส้นและความสัมพันธ์ที่ซับซ้อน จึงไม่สามารถตรวจจับความผันผวนในระยะสั้นของราคาทองคำได้อย่างมีประสิทธิภาพ ในขณะที่ XGBoost สามารถจัดการกับความสัมพันธ์ที่ไม่เป็นเชิงเส้นได้อย่างมีประสิทธิภาพ จึงสามารถตรวจจับความผันผวนในระยะสั้นได้ดีกว่า แม้ว่า XGBoost จะไม่ได้พัฒนาขึ้นมาโดยเฉพาะสำหรับข้อมูลเชิงลำดับเวลา แต่เมื่อประยุกต์ใช้อย่างเหมาะสมก็สามารถให้ผลพยากรณ์ที่มีความแม่นยำมากกว่าวิธีอนุกรมเวลา โดยเฉพาะในกรณีที่ข้อมูลมีความผันผวนสูง เช่น ราคาทองคำในช่วงที่ตลาดมีความไม่แน่นอนจากเหตุการณ์ทางภูมิรัฐศาสตร์

โดยสรุป ผลการศึกษานี้ชี้ให้เห็นว่าในการพยากรณ์ราคาทองคำระยะสั้นภายใต้ภาวะตลาดที่มีความไม่แน่นอนสูง วิธีการเรียนรู้ของเครื่องแบบ XGBoost ให้ประสิทธิภาพที่เหนือกว่าวิธีอนุกรมเวลาทั้งวิธีการทำให้เรียบแบบเอกซ์โพเนนเชียล และวิธี Autoregressive Integrated Moving Average สอดคล้องกับการศึกษาของ Wang et al. [13] ที่

ในชั้นการเปรียบเทียบประสิทธิภาพพบว่า XGBoost มีประสิทธิภาพมากกว่าวิธี ARIMA อย่างไรก็ตามผลการศึกษายังไม่สอดคล้องกับการศึกษาของ Masud et al. [14] ที่พบว่า ARIMA มีประสิทธิภาพมากกว่าวิธี XGBoost สาเหตุอาจมาจากการข้ามขั้นตอนหาไฮเพอร์พารามิเตอร์ที่เหมาะสมสำหรับการเรียนรู้แบบ XGboost ทำให้ไฮเพอร์พารามิเตอร์ที่ใช้สร้างแบบจำลองไม่สามารถดึงศักยภาพการพยากรณ์ด้วยวิธี XGBoost ได้ดีเท่าที่ควร

6. ข้อเสนอแนะ

ผลการวิจัยนี้สามารถนำไปใช้ประโยชน์ในการพยากรณ์ราคาทองคำภายใต้สภาวะที่มีความไม่แน่นอนสูงเพื่อช่วยประกอบการตัดสินใจของนักลงทุนและหน่วยงานด้านการเงิน อย่างไรก็ตาม ตัวแบบพยากรณ์ควรได้รับการปรับปรุงอย่างสม่ำเสมอเมื่อรูปแบบของข้อมูลเปลี่ยนไป ทั้งในด้านการปรับข้อมูลฝึกใหม่และพิจารณาปรับค่าไฮเพอร์พารามิเตอร์สำหรับวิธีการเรียนรู้ของเครื่อง เพื่อให้ผลพยากรณ์มีความแม่นยำและสอดคล้องกับสภาวะตลาดในแต่ละช่วงเวลา

สำหรับการวิจัยในอนาคต ควรพิจารณานำตัวแปรทางเศรษฐกิจอื่น เช่น ดัชนีดอลลาร์ อัตราดอกเบี้ย อัตราแลกเปลี่ยน หรือดัชนีตลาดหุ้น มาใช้ร่วมกับข้อมูลอนุกรมเวลา เพื่อเพิ่มความสมบูรณ์ของแบบจำลอง นอกจากนี้อาจศึกษาสร้างตัวแบบผสม หรือเลือกใช้วิธีพยากรณ์อื่นเพิ่มเติมนอกเหนือจากวิธีที่ใช้ในงานวิจัยนี้ ซึ่งอาจทำให้พบวิธีพยากรณ์ราคาทองคำอื่นที่มีประสิทธิภาพมากยิ่งขึ้น

7. เอกสารอ้างอิง

- [1] M. Czech and B. Puszer, "Inflation and the price changes of selected gold futures during the COVID-19 pandemic and the war in Ukraine, 2020–2023," *Ruch Prawniczy, Ekonomiczny i Socjologiczny*, vol. 86, no. 4, pp. 209-230, 2024.
- [2] สำนักงานนโยบายและยุทธศาสตร์การค้า, "รายงานสถานการณ์ความขัดแย้งระหว่างรัสเซีย-ยูเครน ประจำวันที่ 16 สิงหาคม 2566," [ออนไลน์]. แหล่งที่มา: <https://www.tpsa.go.th/news/2308-0000000048>. [วันที่เข้าถึง 8 มิถุนายน 2568].
- [3] F. Morina, V. Misiri, S. Dinaj and S. Grima, "The impact of the COVID-19 pandemic and the Russian invasion of Ukraine on gold markets," *Business, Management and Economics Engineering*, vol. 22, no. 1, pp. 17–32, 2024.
- [4] N. A. Khalid and N. A. Halim, "Gold price forecasting using Box-Jenkins method," *Universiti Malaysia Terengganu Journal of Undergraduate Research*, vol. 1, no. 3, pp. 15–27, 2019.
- [5] B. Rama, B. Chandrakala, K. Srujana and B. Sravanthi, "ARIMA model for gold price prediction," *International Research Journal on Advanced Engineering and Management*, vol. 2, pp. 3462-3466, 2024.
- [6] A. Ariffin, M. Haiqal, N. A. Mohamad Nor, M. Hamid and M. Samian, "A comparative analysis of Holt's, ARIMA, and Prophet methods in forecasting Kijang gold prices," *International Journal of Entrepreneurship and Management Practices*, vol. 7, pp. 325-338, 2024.
- [7] D. Makala and Z. Li, "Prediction of gold price with ARIMA and SVM," *Journal of Physics: Conference Series*, vol. 1767, no. 1, p. 012022, 2021.
- [8] H. Fawzy, H. El, A. Rady, A. M. Fattah, and A. Mohamed, "Comparison between support vector machines and K-nearest neighbor for time series forecasting," *Journal of Mathematical and Computational Science*, pp. 2342-2359, 2020.
- [9] S. Liu, "A gold and Bitcoin trading model based on XGBoost prediction," in *Proceedings of the*

- 2024 Guangdong-Hong Kong-Macao Greater Bay Area International Conference on Digital Economy and Artificial Intelligence (DEAI), Hongkong, China, 2024.
- [10] R. S. Tsay, *Analysis of Financial Time Series*, 2nd ed., Hoboken, NJ, USA: John Wiley & Sons, 2005.
- [11] J. Amat Rodrigo and J. Escobar Ortiz, “skforecast,” version 0.19.1, Dec. 2025. [Online]. Available: <https://skforecast.org/>. [Accessed 12 April 2025].
- [12] G. Bontempi, S. Ben Taieb, and Y.-A. Le Borgne, “Machine learning strategies for time series forecasting,” in *Lecture Notes in Business Information Processing*, vol. 138. Springer, Berlin, Heidelberg, 2013.
- [13] X. Wang, R. Hu, and X. Chen, “A comparative study on gold future forecasting based on time series large models and classic models,” *Computer Fraud and Security*, vol. 2025, no. 1, pp. 547–558, 2025.
- [14] S. R. Masud, A. Imtiaz, S. M. Hossain and M. S. U. Miah, “A comprehensive approach to gold price prediction using machine learning and time series models,” in 2025 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI), Gwalior, India, 2025.