



การเปรียบเทียบตัวแบบอนุกรมเวลาและตัวแบบการเรียนรู้ของเครื่องสำหรับการพยากรณ์
ปริมาณการส่งออกมันฝรั่งของประเทศไทย
Comparison of Time Series and Machine Learning Models for Forecasting the
Quantity of Potato Exports in Thailand

กานต์ณัฐ ณ บางช้าง* และ ลฎาภา สังข์ใจสม

สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์ ปทุมธานี 12120

Kannat Na Bangchang* and Ladapa Sangjaisom

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

*Corresponding author: kannat@mathstat.sci.tu.ac.th

Received: 2 June 2026/ Revised: 2 October 2026/ Accepted: 5 October 2026

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองอนุกรมเวลาและแบบจำลองการเรียนรู้ของเครื่องสำหรับการพยากรณ์ปริมาณการส่งออกมันฝรั่งของประเทศไทยรายเดือน โดยใช้ข้อมูลทุติยภูมิรายเดือนจากสำนักงานเศรษฐกิจการเกษตร ครอบคลุมช่วงปี พ.ศ. 2559–2568 จำนวน 120 เดือน การศึกษาเปรียบเทียบแบบจำลอง 5 ประเภท ได้แก่ แบบจำลองโฮลต์-วินเทอร์สแบบคูณ แบบจำลองออโตรีเกรสซีฟอินทิเกรตเอ็มพูฟิงแวลูเรจ แบบจำลองออโตรีเกรสซีฟอินทิเกรตเอ็มพูฟิงแวลูเรจเชิงฤดูกาล แบบจำลองปาสุ่ม และแบบจำลองเอ็กซ์จีบูสต์ โดยแบ่งข้อมูลเป็นชุดฝึกและชุดทดสอบ ในสัดส่วน 90:10, 80:20 และ 70:30 โดยประเมินความแม่นยำของแบบจำลองด้วยค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย และค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย ผลการวิจัยพบว่าในกลุ่มแบบจำลองอนุกรมเวลา แบบจำลอง ARIMA (0,1,3) ให้ผลการพยากรณ์ดีที่สุด โดยมีค่า MAPE เท่ากับ 12.25% ในขณะที่แบบจำลองการเรียนรู้ของเครื่อง XGBoost ให้ผลดีที่สุดโดยรวม โดยมีค่า MAPE ต่ำสุดที่ 8.06% ผลการศึกษาชี้ให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่อง สามารถอธิบายความสัมพันธ์ที่ซับซ้อนของข้อมูลได้ดีกว่าแบบจำลองอนุกรมเวลา ผลลัพธ์นี้สามารถนำไปใช้เป็นแนวทางสนับสนุนการวางแผนการผลิต การบริหารจัดการการส่งออก และการกำหนดนโยบายการค้าสินค้าเกษตรของประเทศไทย

คำสำคัญ: การพยากรณ์อนุกรมเวลา แบบจำลองทางสถิติ แบบจำลองการเรียนรู้ของเครื่อง การส่งออกมันฝรั่ง

Abstract

This study aims to compare the forecasting performance of time series and machine learning models for predicting the monthly quantity of potato exports in Thailand. Secondary monthly data from the Office of Agricultural Economics covering the period from 2016 to 2025 (120 monthly observations) were employed. Five forecasting models were evaluated, namely Holt–Winters Multiplicative, Autoregressive Integrated Moving Average (ARIMA), Seasonal Autoregressive Integrated Moving Average (SARIMA), Random



Forest, and Extreme Gradient Boosting (XGBoost). The dataset was divided into training and testing sets using splits of 90:10, 80:20, and 70:30. Forecasting performance was assessed using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results indicated that ARIMA (0,1,3) achieved the best forecasting performance with a MAPE of 12.25%, whereas XGBoost outperformed all competing models overall with the lowest MAPE of 8.06%. These findings suggest that machine learning models are more effective in capturing complex relationships within the export data than conventional time series models. The proposed comparison provides useful evidence for supporting production planning, export management, and agricultural trade policy in Thailand.

Keywords: Time Series Forecasting, Statistical Model, Machine Learning, Potato Export

บทนำ

มันฝรั่งเป็นพืชอาหารที่มีความสำคัญต่อภาคเกษตรและอุตสาหกรรมอาหารของประเทศไทย โดยเฉพาะในฐานะวัตถุดิบหลักสำหรับอุตสาหกรรมแปรรูปอาหาร เช่น มันฝรั่งทอด ขนมขบเคี้ยว และผลิตภัณฑ์แช่แข็ง ซึ่งมีบทบาทต่อระบบเศรษฐกิจและการจ้างงานในพื้นที่เพาะปลูก สำนักงานเศรษฐกิจการเกษตรระบุว่า มันฝรั่งจัดเป็นพืชเศรษฐกิจรองที่สร้างมูลค่าเพิ่มให้กับภาคเกษตรและอุตสาหกรรมอาหารของประเทศไทยอย่างต่อเนื่อง [1] ประเทศไทยปลูกมันฝรั่งเป็นหลักในพื้นที่ภาคเหนือ โดยจังหวัดเชียงใหม่เป็นแหล่งผลิตสำคัญ รองลงมาคือ ตาก ลำปาง ลำพูน เชียงราย และพะเยา พันธุ์ที่ปลูกมากที่สุดคือพันธุ์ Atlantic ซึ่งเป็นพันธุ์ที่เหมาะสมกับการแปรรูปเชิงอุตสาหกรรม และมีความสำคัญในฐานะพืชอุตสาหกรรมที่สร้างมูลค่าทางเศรษฐกิจหลายพันล้านบาทต่อปี [2] ข้อมูลปีเพาะปลูกช่วง พ.ศ. 2562-2563 ระบุว่าประเทศไทยมีพื้นที่ปลูกมันฝรั่งประมาณ 47,297 ไร่ และมีผลผลิตรวม 138,782 ตัน [3] อย่างไรก็ตามเมื่อพิจารณาเปรียบเทียบระหว่างปริมาณผลผลิตกับความต้องการใช้ภายในประเทศ พบว่าปริมาณผลผลิตมันฝรั่งของไทยยังไม่เพียงพอต่อความต้องการของภาคอุตสาหกรรมและการบริโภค โดยข้อมูลจากสำนักงานเศรษฐกิจการเกษตรในปี พ.ศ. 2562 ระบุว่าประเทศไทยผลิตมันฝรั่งได้เพียง 127,935 ตัน ขณะที่ความต้องการบริโภคภายในประเทศสูงถึง 288,013 ตัน ส่งผลให้ต้องนำเข้ามันฝรั่งจากต่างประเทศประมาณ 165,761 ตัน เพื่อชดเชยช่องว่างระหว่างอุปสงค์และอุปทาน [4] การนำเข้าดังกล่าวส่วนใหญ่เป็นมันฝรั่งดิบสำหรับใช้เป็นวัตถุดิบในโรงงานแปรรูป เพื่อรองรับความต้องการของอุตสาหกรรมอาหารที่ขยายตัวอย่างต่อเนื่อง ในด้านนโยบายภาครัฐ รัฐบาลไทยได้กำหนดโควตาการนำเข้ามันฝรั่งดิบเพื่ออุตสาหกรรมแปรรูปภายใต้กรอบความตกลงขององค์การการค้าโลก (WTO) สำหรับช่วงปี พ.ศ. 2569–2571 โดยในปี พ.ศ. 2569 กำหนดโควตานำเข้า 83,000 ตัน และเพิ่มเป็น 97,200 ตัน ในปี พ.ศ. 2571 โดยกำหนดอัตราภาษีนำเข้าในโควตาไว้ที่ร้อยละ 27 และนอกโควตาในอัตราร้อยละ 125 มาตรการดังกล่าวสะท้อนให้เห็นถึงแนวโน้มความต้องการวัตถุดิบมันฝรั่งของภาคอุตสาหกรรมแปรรูปที่เพิ่มสูงขึ้นในอนาคต [5] อย่างไรก็ตามแม้ว่าความต้องการใช้มันฝรั่งในประเทศจะมีแนวโน้มเพิ่มขึ้น แต่การส่งออกมันฝรั่งของประเทศไทยยังมีปริมาณค่อนข้างจำกัด และมีความผันผวนตามปริมาณผลผลิตภายในประเทศ ต้นทุนการผลิต และสถานการณ์การค้า ทำให้การวางแผนการผลิตและการตลาดเพื่อการส่งออกยังขาดข้อมูลเชิงคาดการณ์ที่ชัดเจน นอกจากนี้การผลิตมันฝรั่งของไทยยังเผชิญข้อจำกัดหลายประการ เช่น การปลูกได้เพียงปีละครั้งในฤดูหนาว ความเสี่ยงจากโรคพืชและสภาพภูมิอากาศ รวมถึงข้อจำกัดด้านพื้นที่เพาะปลูก ซึ่งส่งผลต่อปริมาณผลผลิตและศักยภาพในการขยายการส่งออก [6] ดังนั้นการพยากรณ์การส่งออกมันฝรั่งจึงมีความสำคัญอย่างยิ่ง เนื่องจากจะช่วยให้เกษตรกร ผู้ประกอบการ และหน่วยงานภาครัฐ สามารถวางแผนการผลิต การตลาด และนโยบายการค้าสินค้าเกษตรได้อย่างเหมาะสม ลดความเสี่ยงจากความผันผวนของตลาด และเพิ่มขีดความสามารถในการแข่งขันของมันฝรั่งไทยในระยะยาว การศึกษานี้จึงมีบทบาทสำคัญในการสนับสนุนการตัดสินใจเชิงนโยบายและการพัฒนาภาคเกษตรของประเทศไทยอย่างยั่งยืนงานวิจัยนี้จึงมุ่งศึกษาการพยากรณ์การส่งออกมันฝรั่งของประเทศไทยอย่างเป็นระบบ เพื่อใช้เป็นข้อมูลประกอบการตัดสินใจเชิงนโยบายและเชิงปฏิบัติ เพื่อเป็นแนวทางการประเมินทิศทางการส่งออกใน



อนาคต ลดความเสี่ยงจากความผันผวนของตลาด และสนับสนุนการวางแผน การผลิตและการตลาดมันฝรั่งของประเทศไทยให้มีประสิทธิภาพและยั่งยืนมากยิ่งขึ้น อย่างไรก็ตามปัจจุบันยังไม่สามารถระบุได้อย่างชัดเจนว่าแบบจำลองการพยากรณ์ใดมีความเหมาะสมและให้ความแม่นยำสูงที่สุดสำหรับข้อมูลการส่งออกมันฝรั่งของประเทศไทย เนื่องจากการศึกษาที่เปรียบเทียบประสิทธิภาพของแบบจำลองในบริบทดังกล่าวยังมีอยู่อย่างจำกัด ดังนั้นการศึกษานี้จึงมุ่งเน้นการเปรียบเทียบประสิทธิภาพของแบบจำลองอนุกรมเวลาและแบบจำลองการเรียนรู้ของเครื่องสำหรับการพยากรณ์ปริมาณการส่งออกมันฝรั่งของประเทศไทย และคัดเลือกแบบจำลองที่มีประสิทธิภาพสูงที่สุดสำหรับข้อมูลกรณีศึกษา

วิธีดำเนินการวิจัย

1. การเก็บรวบรวมข้อมูล (Data Collection)

ข้อมูลที่นำมาใช้ในการศึกษาเป็นข้อมูลทุติยภูมิ (Secondary Data) จากสำนักงานเศรษฐกิจการเกษตร (สศก.) อันเป็นหน่วยงานภาครัฐที่ทำหน้าที่เผยแพร่ข้อมูลด้านการเกษตรของประเทศไทยอย่างเป็นทางการ โดยชุดข้อมูลที่น่าสนใจ คือ ข้อมูลสถิติปริมาณการส่งออกมันฝรั่งของประเทศไทยเป็นรายเดือน จำนวน 120 เดือน ซึ่งจัดเก็บในรูปแบบข้อมูลอนุกรมเวลาครอบคลุมระยะเวลา 10 ปี ตั้งแต่ปี พ.ศ. 2559 ถึง พ.ศ. 2568

2. การเตรียมและปรับปรุงข้อมูล (Data Preprocessing)

ในขั้นตอนนี้ผู้วิจัยได้ดำเนินการตรวจสอบคุณภาพของข้อมูลและปรับปรุงข้อมูลอนุกรมเวลาเพื่อให้อยู่ในลักษณะที่เหมาะสมที่สุดสำหรับการนำไปสร้างแบบจำลอง โดยมีรายละเอียดดังนี้ เริ่มจากการตรวจสอบความครบถ้วนของข้อมูล การจัดการกับข้อมูลที่ขาดหาย (Missing Values) และการตรวจสอบค่าผิดปกติ (Outliers) ซึ่งเป็นขั้นตอนสำคัญของการเตรียมข้อมูลก่อนสร้างแบบจำลอง [7, 8] นอกจากนี้ยังได้มีการปรับรูปแบบข้อมูลให้อยู่ในลักษณะที่เหมาะสมกับการวิเคราะห์ เช่น การจัดเรียงข้อมูลตามลำดับเวลา (Time Ordering) และการแปลงข้อมูลให้อยู่ในรูปแบบที่เหมาะสมเพื่อสามารถนำไปประมวลผลในแบบจำลองได้อย่างมีประสิทธิภาพ

3. การวิเคราะห์ข้อมูลเบื้องต้น (Exploratory Data Analysis : EDA)

ผู้วิจัยได้ทำการวิเคราะห์ข้อมูลเบื้องต้นโดยการสร้างแผนภาพอนุกรมเวลา (Time Series Plot) เพื่อศึกษาลักษณะของแนวโน้ม (Trend) และรูปแบบฤดูกาล (Seasonality) ที่อยู่ในข้อมูล จากการพิจารณารูปภาพปริมาณการส่งออกมันฝรั่งของประเทศไทย พบว่าข้อมูลมีลักษณะการเปลี่ยนแปลงขึ้นลงตามช่วงเวลา และมีรูปแบบที่เกิดซ้ำในแต่ละปี ซึ่งแสดงให้เห็นถึงอิทธิพลของฤดูกาลอย่างชัดเจน นอกจากนี้ยังพบว่าข้อมูลมีความผันผวนในระดับหนึ่ง ซึ่งอาจส่งผลกระทบต่อความแม่นยำของแบบจำลอง ด้วยเหตุนี้ผู้วิจัยจึงดำเนินการตรวจสอบคุณสมบัติความนิ่งของข้อมูล (Stationarity) เป็นเทคนิคสำคัญในการทำให้ข้อมูลอนุกรมเวลามีคุณสมบัติเป็น Stationary [9] เพื่อพิจารณาความเหมาะสมก่อนนำไปใช้สร้างแบบจำลองในขั้นต่อไป

1) การทดสอบความนิ่งของข้อมูล (Stationarity Test)

ผู้วิจัยได้ทำการทดสอบด้วย Augmented Dickey-Fuller (ADF Test) ซึ่งเป็นการทดสอบสมมติฐานเกี่ยวกับการมีอยู่ของ unit root ในข้อมูล โดยกำหนดสมมติฐานดังนี้ ระดับนัยสำคัญทางสถิติที่ 0.05

- สมมติฐานหลัก (Null Hypothesis, H_0) คือ ข้อมูลมี unit root และข้อมูลไม่มีความนิ่ง (Non-stationary)
- สมมติฐานรอง (Alternative Hypothesis, H_1) คือ ข้อมูลไม่มี unit root และข้อมูลมีความนิ่ง (Stationary)

ผลการทดสอบ ADF พบว่าค่า Dickey-Fuller statistic เท่ากับ -4.9395 และค่า p-value เท่ากับ 0.01 จากการทดสอบพบว่าเมื่อพิจารณาที่ระดับนัยสำคัญทางสถิติ 0.05 ค่า p-value มีค่าน้อยกว่าระดับนัยสำคัญ ดังนั้นจึงสามารถปฏิเสธสมมติฐานหลัก (H_0) ได้ และสรุปได้ว่าข้อมูลอนุกรมเวลามีข้อมูลมีความนิ่ง

2) การพิจารณาการทำ Differencing

จากการทดสอบความนิ่งของข้อมูลด้วยวิธี Augmented Dickey-Fuller (ADF) Test พบว่าข้อมูลมีคุณสมบัติเป็น Stationary อย่างมีนัยสำคัญทางสถิติ ซึ่งในทางทฤษฎีสามารถกำหนดค่า differencing ลำดับที่ 0 ($d = 0$) สำหรับแบบจำลอง



อย่างไรก็ตามผู้วิจัยได้มีการนำตัวแบบอื่นมามาใช้เป็น benchmark ในการเปรียบเทียบความแม่นยำ กล่าวคือ $d = 0$ เป็นข้อสรุปจากการตรวจสอบความนิ่ง (Stationary) แต่ตัวแบบที่ดีที่สุดอาจจะได้ค่า $d = 0$ ซึ่งเป็นผลมาจากการทำ ADF Test

4. การแบ่งข้อมูลฝึกและทดสอบ (Train-Test Split)

ในการศึกษานี้ผู้วิจัยได้ทำการแบ่งข้อมูลออกเป็น 2 ส่วนตามลำดับเวลา ได้แก่ ชุดข้อมูลฝึก (Training Set) และชุดข้อมูลทดสอบ (Testing Set) เพื่อใช้ในการประเมินประสิทธิภาพของแบบจำลองการพยากรณ์ โดยพิจารณาการแบ่งข้อมูลในหลายสัดส่วน ได้แก่ 90:10, 80:20 และ 70:30 การแบ่งข้อมูลทั้งสามสัดส่วนทำหน้าที่วิเคราะห์ความไว (Sensitivity Analysis) ต่อขนาดของช่วงข้อมูลฝึก โดยข้อมูลช่วงต้นใช้สำหรับฝึกและข้อมูลช่วงท้ายใช้สำหรับทดสอบเสมอ จึงไม่เกิดการสับสนข้อมูลข้ามเวลา มีแนวทางแตกต่างกันตามประเภทของแบบจำลอง ดังนี้

1) แบบจำลองทางอนุกรมเวลา (Timeseries Models) ใช้ข้อมูลในช่วงต้นของอนุกรมเวลาเป็นชุดข้อมูลฝึก และใช้ข้อมูลในช่วงท้ายเป็นชุดข้อมูลทดสอบ โดยคงลำดับเวลา (Time Order) ของข้อมูลไว้ เพื่อสะท้อนลักษณะการพยากรณ์ในสถานการณ์จริง

2) แบบจำลองการเรียนรู้ของเครื่อง (Machine Learning Models) ในการศึกษาได้มีการสร้างตัวแปรหน่วงเวลา (Lag Features) จำนวน 12 เดือน และตัวแปรค่าเฉลี่ยเคลื่อนที่ (Rolling Mean) ซึ่งส่งผลให้เกิดค่าที่ขาดหายไปในช่วงต้นของข้อมูล ดังนั้นผู้วิจัยได้ใช้วิธีการแทนค่าที่ขาดหายไป (Imputation) ด้วยเทคนิค Backward Fill (bfill) เพื่อให้สามารถใช้ข้อมูลได้ครบทุกช่วงเวลา ทำให้อำนาจข้อมูลที่ใช้ในการวิเคราะห์เท่ากับ 120 เดือน

- สัดส่วน 90:10 แบ่งเป็นข้อมูลฝึกจำนวน 108 เดือน และข้อมูลทดสอบจำนวน 12 เดือน

- สัดส่วน 80:20 แบ่งเป็นข้อมูลฝึกจำนวน 96 เดือน และข้อมูลทดสอบจำนวน 24 เดือน

- สัดส่วน 70:30 แบ่งเป็นข้อมูลฝึกจำนวน 84 เดือน และข้อมูลทดสอบจำนวน 36 เดือน

5. การสร้างแบบจำลอง (Model Implementation) ในการศึกษาผู้วิจัยได้พัฒนาแบบจำลองการพยากรณ์

โดยแบ่งออกเป็น 2 กลุ่มหลัก ได้แก่ แบบจำลองทางอนุกรมเวลา และแบบจำลองการเรียนรู้ของเครื่อง
แบบจำลองทางอนุกรมเวลา ได้แก่

1) แบบจำลอง Holt-Winters แบบ Multiplicative

เส้นกราฟมีแนวโน้ม (Trend) ที่ไม่คงที่ และ ฤดูกาล (Seasonality) ดูเหมือนจะขยายตัวตามระดับข้อมูล เมื่อปริมาณการส่งออกสูงขึ้นในบางปี ความแตกต่างระหว่างช่วงสูงสุดและช่วงต่ำสุดก็ยังชัดเจนขึ้น ดังนั้นผู้วิจัยเลือกใช้แบบจำลอง Holt-Winters แบบ Multiplicative ในการพยากรณ์ข้อมูลอนุกรมเวลา เนื่องจากแบบจำลองนี้สามารถแยกแยะและอธิบายองค์ประกอบของข้อมูลได้อย่างครอบคลุม ทั้งแนวโน้มและฤดูกาล เหมาะสำหรับข้อมูลที่มีฤดูกาลเปลี่ยนแปลงตามระดับของข้อมูล [10, 11] ดังสมการต่อไปนี้

$$\hat{Y}_{t+h} = (L_t + hT_t)S_{t+h-m(k+1)}$$

โดยที่ $\hat{Y}_{t+h}$ คือ ค่าพยากรณ์ล่วงหน้า h ช่วงเวลา

L_t คือ องค์ประกอบระดับ (Level) ณ เวลา t

h คือ จำนวนช่วงเวลาที่ต้องการพยากรณ์ล่วงหน้า

T_t คือ องค์ประกอบแนวโน้ม (Trend) ณ เวลา t

S_t คือ องค์ประกอบฤดูกาล (Seasonal) ณ เวลา t

m คือ ความยาวของฤดูกาล ซึ่งกรณีข้อมูลรายเดือนกำหนดเป็น 12

2) แบบจำลอง ARIMA

แบบจำลอง ARIMA ถูกพัฒนาโดย Box และ Jenkins เพื่อวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลา [9] ในการศึกษาการเลือกแบบจำลองดำเนินการเป็นลำดับขั้น ได้แก่ (1) ตรวจสอบความนิ่งของข้อมูลด้วย ADF Test (2) พิจารณาจากกราฟ ACF และ PACF เพื่อกำหนดช่วงของค่า p และ q ที่เหมาะสม (3) ประเมินค่าพารามิเตอร์ของแบบจำลอง และ



(4) เปรียบเทียบแบบจำลองด้วยเกณฑ์ Bayesian Information Criterion (BIC) โดยแบบจำลองที่มี BIC ต่ำจะได้รับการพิจารณาเป็นลำดับแรก จากผลการวิจัยพบว่า ACF มีลักษณะค่อย ๆ ลดลง ขณะที่ PACF มีนัยสำคัญที่ lag 1 จึงเลือกแบบจำลอง ARIMA(1,0,0) เป็นหนึ่งในแบบจำลอง และจากการค้นหาแบบจำลองเพิ่มเติมพบว่า ARIMA(0,1,3) มี BIC เท่ากับ 3181.81 ซึ่งมีค่าต่ำที่สุดในแบบจำลอง ผู้วิจัยจึงนำแบบจำลอง ARIMA(1,0,0) และ ARIMA(0,1,3) ไปเปรียบเทียบความแม่นยำบนชุดข้อมูลทดสอบ ทั้งนี้ ARIMA(0,1,3) เป็น benchmark จากผลการเปรียบเทียบเชิงประจักษ์ ไม่ใช่ค่าที่ได้จาก ADF โดยตรง สำหรับการกำหนดค่า p และ q ผู้วิจัยได้พิจารณาจากกราฟฟังก์ชันอัตโนมัติสัมพันธ์ (ACF) และ กราฟฟังก์ชันอัตโนมัติสัมพันธ์บางส่วน (PACF) ซึ่งใช้ในการตรวจสอบความสัมพันธ์ของข้อมูลในช่วงเวลาย้อนหลัง โดยลักษณะของกราฟดังกล่าวช่วยบ่งชี้จำนวน lag ที่เหมาะสมสำหรับพารามิเตอร์ p และ q ดังสมการต่อไปนี้

$$\phi(B)(1-B)^d Y_t = c + \theta(B)\varepsilon_t$$

โดยที่ B คือ Backshift operator ซึ่ง $BY_t = Y_{t-1}$

d คือ จำนวนครั้งของการทำ Differencing

Y_t คือ ค่าของข้อมูล ณ เวลา t

c คือ ค่าคงที่ของแบบจำลอง

θ คือ ค่าสัมประสิทธิ์ของส่วน moving average

ε_t คือ ค่าความคลาดเคลื่อนสุ่ม ณ เวลา t

3) แบบจำลอง SARIMA

SARIMA เป็นการขยายแบบจำลอง ARIMA เพื่อรองรับองค์ประกอบฤดูกาลของข้อมูล [12] การกำหนดค่าพารามิเตอร์ของแบบจำลองโดยพิจารณาจากผลการทดสอบความนิ่งของข้อมูล (Stationarity) เพื่อกำหนดค่าพารามิเตอร์เชิงไม่เป็นฤดูกาล ได้แก่ d และ D สำหรับส่วนฤดูกาล จากนั้นผู้วิจัยได้ใช้กราฟ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) เพื่อวิเคราะห์ความสัมพันธ์ของข้อมูลในช่วงเวลาย้อนหลัง และใช้เป็นแนวทางในการกำหนดค่าพารามิเตอร์ p, q และพารามิเตอร์เชิงฤดูกาล P, Q รวมถึงกำหนดคาบฤดูกาลเท่ากับ 12 ($m = 12$) ดังสมการต่อไปนี้

$$\phi(B^m)\phi(B)(1-B)^d(1-B^m)^D Y_t = c + \phi(B^m)\theta(B)\varepsilon_t$$

โดยที่ B คือ Backshift Operator

m คือ ความยาวของฤดูกาล ซึ่งกรณีข้อมูลรายเดือนกำหนดเป็น 12

d คือ จำนวนครั้งของการทำ Differencing

D คือ จำนวนครั้งของการทำ Seasonal Differencing

Y_t คือ ค่าของข้อมูล ณ เวลา t

c คือ ค่าคงที่ของแบบจำลอง

θ คือ ค่าสัมประสิทธิ์ของส่วน moving average

ε_t คือ ค่าความคลาดเคลื่อนสุ่ม ณ เวลา t

นอกจากนี้ได้มีการทดลองแบบจำลอง SARIMA หลายรูปแบบ โดยกำหนดคาบฤดูกาล $m = 12$ สำหรับข้อมูลรายเดือน และใช้ผลการตรวจสอบ Stationarity ร่วมกับ ACF และ PACF ทั้งในส่วนที่ไม่เป็นฤดูกาลและส่วนฤดูกาลเพื่อกำหนดพารามิเตอร์ จากผลการวิจัยพบว่า SARIMA(1,0,1)(0,1,1) [12] ให้ BIC เท่ากับ 2909.28 ซึ่งต่ำกว่า SARIMA(1,0,0)(0,0,0) [12] ที่มี BIC เท่ากับ 3209.06 และต่ำกว่า ARIMA(0,1,3) ที่มี BIC เท่ากับ 3181.81 อย่างไรก็ตามการคัดเลือกขั้นสุดท้ายยังต้องพิจารณา ผลการตรวจสอบเศษเหลือและความแม่นยำบนชุดข้อมูลทดสอบร่วมกัน โดย SARIMA(1,0,1)(0,1,1) [12] จึงถูกนำไปเปรียบเทียบกับแบบจำลองอื่นในผลการพยากรณ์



แบบจำลองการเรียนรู้เครื่อง ได้แก่

1) แบบจำลอง Random Forest

เป็นอัลกอริทึมแบบ Ensemble Learning ที่สร้างต้นไม้ตัดสินใจจำนวนมากจากตัวอย่างข้อมูลแบบ Bootstrap และสุ่มเลือกตัวแปรในแต่ละโหนด จากนั้นรวมผลการพยากรณ์ของทุกต้นไม้ด้วยค่าเฉลี่ยเพื่อลดความแปรปรวนของแบบจำลอง [13] ในการศึกษาใช้ตัวแปร lag 1-12 เดือน และตัวแปรค่าเฉลี่ยเคลื่อนที่ โดยมีการเปรียบเทียบ ค่าพารามิเตอร์หลายชุดด้วย Grid Search ร่วมกับการทดลองปรับค่าเพิ่มเติม (Manual Tuning) และใช้การแบ่งข้อมูลตามลำดับเวลาเพื่อหลีกเลี่ยงการสุ่มข้ามเวลา ผู้วิจัยได้เลือกใช้แบบจำลอง Random Forest ซึ่งเป็นอัลกอริทึมการเรียนรู้ของเครื่องแบบ Ensemble Learning ที่พัฒนาจากแนวคิดของ Decision Tree โดยอาศัยการรวมผลลัพธ์จากต้นไม้ตัดสินใจ (Decision Tree) หลายต้นเพื่อเพิ่มความแม่นยำและลดความแปรปรวนของแบบจำลอง โดยใช้วิธีการสุ่มตัวอย่างข้อมูลแบบ Bootstrap และการสุ่มเลือกตัวแปรในแต่ละโหนดของต้นไม้ (Feature Randomness) ซึ่งช่วยลดปัญหา Overfitting และเพิ่มความสามารถในการพยากรณ์ของแบบจำลอง ซึ่งเขียนได้ดังนี้

$$\hat{Y}_t = \frac{1}{B} \sum_{b=1}^B T_b(X_t)$$

โดยที่ $\hat{Y}_t$ คือ ค่าพยากรณ์ ณ เวลา t

B คือ จำนวนต้นไม้ทั้งหมดใน Random Forest

T_b คือ ต้นไม้ตัดสินใจต้นที่ b

X_t คือ เวกเตอร์ของตัวแปรอิสระ

ในการศึกษานี้ผู้วิจัยได้แปลงข้อมูลอนุกรมเวลาให้อยู่ในรูปแบบของตัวแปรอิสระ โดยใช้ค่า lag ของข้อมูลในช่วงเวลาย้อนหลัง เช่น lag1, lag2, ..., lag12 เป็นตัวแปรอินพุตในการฝึกแบบจำลอง

การปรับแต่งพารามิเตอร์ (Hyperparameter Tuning) ผู้วิจัยได้ทำการปรับแต่งค่าพารามิเตอร์ของแบบจำลอง Random Forest โดยใช้วิธี Grid Search ซึ่งการปรับแต่งพารามิเตอร์ด้วย Grid Search ช่วยเพิ่มประสิทธิภาพของแบบจำลอง Machine Learning [14] ร่วมกับการทดลองปรับค่าเพิ่มเติม (Manual Tuning) เพื่อให้ได้ค่าที่เหมาะสมที่สุดกับข้อมูล

2) แบบจำลอง XGBoost (Extreme Gradient Boosting)

เป็นอัลกอริทึม Gradient Boosting ที่ได้รับการพัฒนาให้มีประสิทธิภาพสูงทั้งด้านความเร็วและความแม่นยำ [15] ในการศึกษาใช้ผู้วิจัยได้เลือกใช้แบบจำลอง XGBoost ซึ่งเป็นวิธีการเรียนรู้แบบ boosting ที่พัฒนามาจากแนวคิดของ Gradient Boosting โดยมีจุดเด่นในการเพิ่มประสิทธิภาพของแบบจำลองผ่านการเรียนรู้แบบลำดับขั้น (sequential learning) และสามารถจัดการกับความสัมพันธ์ที่ซับซ้อนของข้อมูลได้เป็นอย่างดี สามารถเขียนได้ดังต่อไปนี้

$$\hat{Y}_t = \sum_{k=1}^K f_k(X_t)$$

โดยที่ $\hat{Y}_t$ คือ ค่าพยากรณ์ ณ เวลา t

K คือ จำนวนต้นไม้ทั้งหมดใน Boosting

f_k คือ ต้นไม้ตัดสินใจต้นที่ k

X_t คือ เวกเตอร์ของตัวแปรอิสระ

ในกระบวนการสร้างแบบจำลอง ผู้วิจัยได้ทำการปรับแต่งค่าพารามิเตอร์ (hyperparameter tuning) ด้วย Grid Search เพื่อเพิ่มความแม่นยำของแบบจำลองโดยใช้ข้อมูลตามลำดับเวลาและไม่สุ่มสับเปลี่ยนลำดับเวลา เพื่อป้องกันข้อมูลรั่วไหลจากอนาคตมายังอดีตโดยการเลือกชุดพารามิเตอร์ดังกล่าวอาศัยผลการทดลองปรับแต่งและประเมินประสิทธิภาพของแบบจำลองก่อนนำไปประเมินกับชุดทดสอบที่แยกไว้ โดยพิจารณาพารามิเตอร์สำคัญ ได้แก่



- จำนวนรอบการเรียนรู้ ($n_estimators$) หมายถึง จำนวนต้นไม้ที่ถูกสร้างขึ้นในกระบวนการ Boosting ซึ่งมีผลต่อความสามารถของแบบจำลองในการเรียนรู้รูปแบบของข้อมูล โดยการเพิ่มจำนวนรอบจะช่วยให้แบบจำลองเรียนรู้ได้ละเอียดมากขึ้น แต่จะใช้เวลาในการประมวลผลเพิ่มขึ้น

- ความลึกของต้นไม้ (max_depth) เป็นการกำหนดระดับความลึกสูงสุดของต้นไม้ตัดสินใจ ซึ่งมีผลต่อความสามารถในการเรียนรู้ความสัมพันธ์ของข้อมูล โดยค่าที่สูงจะช่วยให้แบบจำลองเรียนรู้ความสัมพันธ์ที่ซับซ้อนได้ดีขึ้น แต่หากมากเกินไปอาจทำให้เกิดปัญหา overfitting

- อัตราการเรียนรู้ ($learning_rate$) เป็นค่าที่ควบคุมน้ำหนักของการปรับค่าพยากรณ์ในแต่ละรอบ โดยค่าที่ต่ำจะช่วยให้แบบจำลองเรียนรู้อย่างค่อยเป็นค่อยไปและมีความเสถียรมากขึ้น แต่ต้องใช้จำนวนรอบการเรียนรู้มากขึ้น

- สัดส่วนของข้อมูลที่ใช้ในแต่ละรอบ ($subsample$) เป็นการกำหนดสัดส่วนของข้อมูลที่ถูกสุ่มมาใช้ในการฝึกแบบจำลองในแต่ละรอบ ซึ่งช่วยลดความสัมพันธ์ระหว่างต้นไม้และลดปัญหา overfitting

- สัดส่วนของตัวแปรที่ใช้ในการสร้างต้นไม้ ($colsample_bytree$) เป็นการกำหนดสัดส่วนของตัวแปรที่ถูกสุ่มมาใช้ในการสร้างต้นไม้แต่ละต้น ซึ่งช่วยเพิ่มความหลากหลายของแบบจำลองและลดการพึ่งพาตัวแปรใดตัวแปรหนึ่งมากเกินไป โดย max_depth ระดับต่ำช่วยควบคุมความซับซ้อนของแบบจำลอง ขณะที่ $n_estimators$ ที่สูงขึ้นช่วยให้แบบจำลองเรียนรู้รูปแบบของข้อมูลได้ละเอียดขึ้น ทั้งนี้ผลการเลือกแบบจำลองต้องตีความร่วมกับผลบนชุดทดสอบ และไม่ควรสรุปจากค่าความคลาดเคลื่อนของชุดฝึกเพียงอย่างเดียว

การกำหนดค่า max_depth ในระดับต่ำช่วยลดความซับซ้อนของแบบจำลองและลดปัญหา overfitting ขณะที่ค่า $n_estimators$ ที่สูงขึ้นช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบของข้อมูลได้อย่างละเอียดมากขึ้น นอกจากนี้ค่า $learning_rate = 0.1$ ช่วยให้แบบจำลองเรียนรู้ได้อย่างสมดุลระหว่างความเร็วและความเสถียร การกำหนดค่า $subsample$ และ $colsample_bytree$ เท่ากับ 1.0 ทำให้แบบจำลองใช้ข้อมูลและตัวแปรทั้งหมดในการเรียนรู้ ซึ่งเหมาะสมกับลักษณะของข้อมูลในงานวิจัยนี้

6. การตรวจสอบแบบจำลอง (Model Diagnostic Checking)

หลังจากการสร้างแบบจำลอง ผู้วิจัยได้ทำการตรวจสอบความเหมาะสมของแบบจำลอง โดยสำหรับแบบจำลองทางสถิติด้วยการวิเคราะห์เศษเหลือ (Residual) ได้ใช้การทดสอบ Ljung–Box [16] เพื่อตรวจสอบว่าเศษเหลือ (Residuals) มีความเป็นอิสระในเชิงเวลาหรือไม่และพิจารณา Residual Plot ว่าไม่มีรูปแบบที่เป็นระบบ ซึ่งเป็นเงื่อนไขสำคัญของแบบจำลองอนุกรมเวลา โดยเศษเหลือที่ดีควรมีลักษณะเป็นสัญญาณรบกวนแบบสุ่ม white noise : ไม่มีความสัมพันธ์กันในช่วงเวลาต่าง ๆ โดยกำหนดระดับนัยสำคัญทางสถิติที่ 0.05

- สมมติฐานหลัก (Null Hypothesis) H_0 : เศษเหลือไม่มีความสัมพันธ์กันในช่วงเวลา (No autocorrelation)

- สมมติฐานรอง (Alternative Hypothesis) H_1 : เศษเหลือมีความสัมพันธ์กันในช่วงเวลา (Autocorrelation exists)

จากผลการวิจัยพบว่า Ljung–Box มีค่า p-value เท่ากับ 4.954×10^{-5} สำหรับ Holt–Winters Multiplicative, 0.4804 สำหรับ ARIMA(1,0,0), 0.6093 สำหรับ ARIMA(0,1,3) และ 0.9117 สำหรับ SARIMA(1,0,1)(0,1,1)[12] ตามลำดับ ดังนั้น ARIMA(1,0,0), ARIMA(0,1,3) และ SARIMA มี p-value > 0.05 จึงไม่มีหลักฐานเพียงพอที่จะปฏิเสธ H_0 ว่าเศษเหลือไม่มี autocorrelation ขณะที่ Holt–Winters มี p-value < 0.05 จึงไม่ผ่านเกณฑ์ดังกล่าว ผลนี้ควรนำมาพิจารณาร่วมกับค่าความแม่นยำบนชุดทดสอบ สำหรับแบบจำลองการเรียนรู้ของเครื่อง พิจารณาความเหมาะสมจากผลการประเมินบนชุดทดสอบและความแตกต่างระหว่างผลบนชุดฝึกกับชุดทดสอบ

7. การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)

ประเมินความแม่นยำของแบบจำลองแต่ละประเภทโดยใช้ข้อมูลชุดทดสอบด้วยเกณฑ์ต่อไปนี้ ได้แก่



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

Root Mean Square Error (RMSE) โดยที่ $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$

และ Mean Absolute Percentage Error (MAPE) โดยที่ $MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100$

เมื่อ n คือ จำนวนข้อมูล

y_i คือ ค่าจริงของข้อมูลลำดับที่ i

$\hat{y}_i$ คือ ค่าพยากรณ์ของข้อมูลลำดับที่ i

ซึ่งเป็นตัวชี้วัดความแม่นยำที่ได้รับการยอมรับอย่างแพร่หลาย [17] และนำผลลัพธ์มาเปรียบเทียบเพื่อพิจารณาแบบจำลองที่มีประสิทธิภาพสูงสุด

8. การพยากรณ์ (Forecasting)

หลังจากการสร้างแบบจำลอง ผู้วิจัยได้ทำการพยากรณ์ค่าปริมาณการส่งออกในอนาคต โดยกำหนดช่วงเวลาการพยากรณ์ให้เท่ากับความยาวของชุดข้อมูลทดสอบ (Testing Set) ผลการพยากรณ์ถูกนำเสนอในรูปแบบของกราฟและตาราง โดยแสดงเปรียบเทียบระหว่างค่าจริง (Actual) และค่าที่พยากรณ์ (Forecast) เพื่อให้สามารถประเมินความสอดคล้องของแบบจำลองได้อย่างชัดเจน

ผลการวิจัย

จากการพิจารณาแผนภาพอนุกรมเวลา พบว่าปริมาณการส่งออกมันฝรั่งของประเทศไทยมีความผันผวนตามช่วงเวลา และมีแนวโน้มเพิ่มขึ้นในบางช่วง อย่างไรก็ตามการตรวจสอบคุณสมบัติความนิ่งของข้อมูลด้วยการทดสอบ Augmented Dickey-Fuller (ADF) พบว่าค่า Dickey-Fuller statistic เท่ากับ -4.9395 และค่า p-value เท่ากับ 0.01 จึงปฏิเสธสมมติฐานหลักที่ระดับนัยสำคัญ 0.05 และสรุปได้ว่าข้อมูลมีคุณสมบัติความนิ่ง (Stationary) จึงไม่จำเป็นต้องทำ Non-seasonal Differencing เพิ่มเติม ($d = 0$)

1. ผลการวิเคราะห์เปรียบเทียบการพยากรณ์แบบจำลองทางอนุกรมเวลา (Timeseries Models)

การสร้างแบบจำลองพยากรณ์ภายใต้เงื่อนไขที่ไม่มีการทำ seasonal differencing โดยกำหนดค่า $D = 0$ หมายถึงการสร้างแบบจำลองพยากรณ์โดยไม่ทำการหาผลต่างเชิงฤดูกาลของข้อมูล เนื่องจากข้อมูลไม่มีลักษณะฤดูกาลที่ชัดเจน หรือข้อมูลมีความคงที่ด้านฤดูกาลอยู่แล้ว จึงไม่จำเป็นต้องกำจัดองค์ประกอบฤดูกาลออกก่อนสร้างแบบจำลอง

ในแบบจำลอง SARIMA ค่า D หมายถึง จำนวนครั้งของการทำ Seasonal Differencing ซึ่งเป็นกระบวนการลบค่าข้อมูลย้อนหลังตามรอบฤดูกาล เช่น รายเดือนอาจลบกับข้อมูลย้อนหลัง 12 เดือน เพื่อกำจัดรูปแบบฤดูกาลของข้อมูล หากกำหนด $D = 0$ หมายความว่าไม่ได้ทำ Seasonal Differencing

การกำหนดค่า $D = 0$ มักใช้เมื่อผลการตรวจสอบข้อมูลพบว่าองค์ประกอบฤดูกาลไม่มีผลมาก หรือข้อมูลมีความนิ่ง (Stationary) ในส่วนของฤดูกาลอยู่แล้ว จึงสามารถนำข้อมูลเดิมไปสร้างแบบจำลองได้โดยตรง ซึ่งช่วยลดความซับซ้อนของแบบจำลองและป้องกันการทำ differencing มากเกินไปจนสูญเสียข้อมูลสำคัญของอนุกรมเวลาได้

จากตารางที่ 1 พบว่า ARIMA(0,1,3) ให้ค่าความคลาดเคลื่อนต่ำที่สุดในกรณีการแบ่งข้อมูลแบบ Train-Test ที่สัดส่วน 90:10 โดยมี MAPE = 12.25%, RMSE = 114,252.30 และ MAE = 81,202.20 ซึ่งพบว่า ARIMA(0,1,3) มี BIC = 3181.81 ซึ่งต่ำที่สุดในชุดแบบจำลอง ARIMA ที่ทดลอง จึงสามารถระบุได้ว่าเป็น benchmark ที่ให้ผลดีทั้งในเกณฑ์เชิงแบบจำลองและเชิงพยากรณ์ สำหรับสัดส่วนการแบ่งข้อมูลแบบ 80:20 และ 70:30 พบว่า ARIMA(1,0,0) และ ARIMA(0,1,3) ให้ค่าความคลาดเคลื่อนอยู่ในระดับใกล้เคียงกัน โดย MAPE มีค่าประมาณ 18-20% ขณะที่ Holt-Winters แบบ




ตารางที่ 1 ผลการเปรียบเทียบความแม่นยำของแบบจำลองการพยากรณ์

Train – Test	Model	MAPE	RMSE	MAE
90:10 (108:12 เดือน)	Holt-Winters แบบ Multiplicative	77.63	490,127.90	439,816.80
	ARIMA(1,0,0)	15.22	143,372.80	103,097.80
	ARIMA(0,1,3)	12.25	114,252.30	81,202.20
80:20 (96:24 เดือน)	Holt-Winters แบบ Multiplicative	30.84	250,626.60	184,815.70
	ARIMA(1,0,0)	19.96	241,480.70	144,017.00
	ARIMA(0,1,3)	20.36	231,199.40	139,968.10
70:30 (84:36 เดือน)	Holt-Winters แบบ Multiplicative	23.54	199,142.10	138,220.70
	ARIMA(1,0,0)	18.74	207,431.90	125,098.00
	ARIMA(0,1,3)	18.87	194,912.20	118,952.80

Multiplicative ให้ค่าความคลาดเคลื่อนสูงกว่าในทุกกรณี ผลจากทั้งสามสัดส่วนจึงถูกใช้เป็น sensitivity analysis ต่อขนาดชุดฝึก โดยเฉพาะในสัดส่วน 90:10 แสดงให้เห็นว่าแบบจำลองดังกล่าวไม่สามารถอธิบายลักษณะข้อมูลได้ดีเท่ากับแบบจำลอง ARIMA

การแสดงผลการเปรียบเทียบระหว่างค่าจริง (Actual) และค่าพยากรณ์ (Forecast) ของข้อมูลอนุกรมเวลา

การแบ่งข้อมูลในอัตราส่วนร้อยละ 90 สำหรับการฝึกแบบจำลอง (Training Set) และร้อยละ 10 สำหรับการทดสอบแบบจำลอง (Testing Set) เพื่อประเมินประสิทธิภาพของแบบจำลอง ได้แก่ Holt-Winters แบบ Multiplicative, ARIMA (1,0,0) และ ARIMA(0,1,3)



ภาพที่ 1 การเปรียบเทียบค่าจริง (Actual) กับค่าพยากรณ์จากแบบจำลองต่าง ๆ ภายใต้เงื่อนไขที่ไม่มีการทำ Seasonal Differencing ($D = 0$) ภายใต้สัดส่วน 90:10

จากภาพที่ 1 เส้นสีน้ำเงินแสดงข้อมูลในช่วงฝึก ซึ่งสะท้อนลักษณะของข้อมูลที่มีความผันผวนและการเปลี่ยนแปลงขึ้นลงอย่างต่อเนื่อง ขณะที่เส้นสีดำแสดงค่าจริงในช่วงทดสอบ ซึ่งใช้เป็นเกณฑ์ในการประเมินความแม่นยำของแบบจำลอง เมื่อพิจารณาค่าพยากรณ์ของแบบจำลองต่าง ๆ พบว่าแบบจำลอง Holt-Winters แบบ Multiplicative (เส้นประสีส้ม) มีแนวโน้มการพยากรณ์ที่สูงกว่าค่าจริงและมีความผันผวนมาก โดยเฉพาะในช่วงปลาย ส่งผลให้เกิดการประเมินค่าสูงเกินจริง



(overestimation) ในบางช่วงเวลา ในขณะที่แบบจำลอง ARIMA(1,0,0) (เส้นประสีเขียว) ให้ค่าพยากรณ์ที่มีลักษณะค่อนข้างเรียบและมีแนวโน้มคงที่ สามารถสะท้อนแนวโน้มโดยรวมของข้อมูลได้ในระดับหนึ่ง แต่ยังไม่สามารถจับความผันผวนของข้อมูลจริงได้อย่างชัดเจน สำหรับแบบจำลอง ARIMA(0,1,3) (เส้นประสีม่วง) ให้ค่าพยากรณ์ที่มีลักษณะใกล้เคียงกับแบบจำลอง ARIMA(1,0,0) แต่สามารถปรับตัวต่อการเปลี่ยนแปลงของข้อมูลได้ดีกว่าเล็กน้อย และมีแนวโน้มสอดคล้องกับค่าจริงมากกว่า ในช่วง โดยสรุปแบบจำลอง ARIMA ให้ค่าพยากรณ์ที่มีความเสถียรและสอดคล้องกับแนวโน้มของข้อมูลจริงมากกว่าแบบจำลอง Holt-Winters ซึ่งมีแนวโน้มเกิดการประเมินค่าสูงเกินจริง ผลลัพธ์ดังกล่าวสอดคล้องกับการประเมินเชิงตัวเลขในหัวข้อก่อนหน้า ซึ่งพบว่าแบบจำลอง ARIMA(0,1,3) ให้ค่าความคลาดเคลื่อนต่ำที่สุด

ผลการเปรียบเทียบระหว่าง ค่าจริง (Actual) และ ค่าพยากรณ์ (Forecast)

จากตารางการเปรียบเทียบระหว่างค่าจริง (Actual) และค่าพยากรณ์ (Forecast) รายเดือนจากแบบจำลองต่าง ๆ ในตารางที่ 2 ได้แก่ ARIMA(1,0,0), ARIMA(0,1,3), SARIMA(1,0,1)(0,1,1) [12] และ Holt-Winters แบบ Multiplicative เพื่อประเมินความสามารถของแบบจำลองในการพยากรณ์ข้อมูลให้สอดคล้องกับค่าจริงในแต่ละช่วงเวลา

ในการศึกษานี้ข้อมูลทั้งหมดมีจำนวน 120 เดือน ซึ่งถูกแบ่งออกเป็นข้อมูลฝึก (Training Set) จำนวน 108 เดือน คิดเป็นร้อยละ 90 และข้อมูลทดสอบ (Test Set) จำนวน 12 เดือน คิดเป็นร้อยละ 10 โดยข้อมูลส่วนฝึกถูกใช้ในการสร้างแบบจำลอง และข้อมูลส่วนทดสอบถูกใช้ในการประเมินประสิทธิภาพของแบบจำลอง

จากผลการเปรียบเทียบพบว่าแบบจำลอง ARIMA (0,1,3) ให้ค่าพยากรณ์ที่มีแนวโน้มใกล้เคียงกับค่าจริงในหลายช่วงเวลา และสามารถสะท้อนการเปลี่ยนแปลงของข้อมูลได้ดีกว่าแบบจำลองอื่น โดยมีความคลาดเคลื่อนที่สม่ำเสมอและไม่เบี่ยงเบนจากค่าจริงมากนัก ดังนั้นจึงสรุปได้ว่า แบบจำลอง ARIMA (0,1,3) เป็นแบบจำลองที่ให้ผลการพยากรณ์สอดคล้องกับค่าจริงมากที่สุดในภาพรวม ซึ่งสอดคล้องกับผลการประเมินเชิงตัวเลขในหัวข้อก่อนหน้า

ตารางที่ 2 ผลการเปรียบเทียบระหว่าง ค่าจริง (Actual) และ ค่าพยากรณ์ (Forecast) แบบจำลองทางสถิติ ภายใต้สัดส่วน 90:10

Month	Actual	ARIMA(1,0,0)	ARIMA(0,1,3)	SARIMA(1,0,1)(0,1,1) [12]	Holt-Winters แบบ Multiplicative
1	1,047,453	851,061.50	908,106.30	918,674.70	1,246,959.70
2	526,295	703,630.00	647,299.50	793,927.50	1,347,100.10
3	584,480	617,226.30	549,752.40	811,192.70	1,495,372.90
4	523,582	566,588.50	549,752.40	557,560.00	959,888.50
5	566,406	536,911.70	549,752.40	519,859.00	992,204.50
6	453,139	519,519.30	549,752.40	463,558.70	865,547.10
7	504,491	509,326.30	549,752.40	461,472.20	853,927.80
8	550,178	503,352.60	549,752.40	480,267.40	857,802.50
9	518,286	499,851.60	549,752.40	504,089.00	808,318.70
10	634,055	497,799.90	549,752.40	530,425.80	925,065.50
11	617,898	496,597.40	549,752.40	642,732.00	1,214,331.60
12	860,061	495,892.70	549,752.40	614,252.00	1,097,607.30

2. ผลการวิเคราะห์เปรียบเทียบการพยากรณ์แบบจำลองการเรียนรู้ของเครื่อง (Machine Learning Models)

การแบ่งข้อมูลออกเป็นชุดฝึก (Training Set) และชุดทดสอบ (Testing Set) ในสัดส่วนที่แตกต่างกัน ได้แก่ 90:10, 80:20 และ 70:30 เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยใช้ตัวชี้วัดความคลาดเคลื่อน ได้แก่ MAPE, RMSE และ MAE



จากผลในตารางที่ 3 พบว่าแบบจำลอง Random Forest ให้ค่า MAPE เท่ากับ 11.90%, 12.38% และ 12.32% สำหรับสัดส่วน 90:10, 80:20 และ 70:30 ตามลำดับ โดยค่า RMSE และ MAE มีแนวโน้มสอดคล้องกัน กล่าวคือเมื่อค่า MAPE เพิ่มขึ้น ค่าความคลาดเคลื่อนอื่นก็มีแนวโน้มเพิ่มขึ้นเช่นกัน

ตารางที่ 3 ผลการเปรียบเทียบความแม่นยำของแบบจำลอง Random Forest และ XGBoost


Train-Test	แบบจำลอง	MAPE	RMSE	MAE
90:10 (108:12 เดือน)	Random Forest	11.90	101053.32	76756.50
80:20 (96:24 เดือน)		12.38	147859.89	88691.18
70:30 (84:36 เดือน)		12.32	131550.82	80989.87
90:10 (108:12 เดือน)	XGBoost	8.06	101227.26	59712.72
80:20 (96:24 เดือน)		9.89	146508.29	76016.71
70:30 (84:36 เดือน)		11.21	130843.02	74398.46

ในขณะที่ตารางที่ 4 แสดงให้เห็นว่าแบบจำลอง XGBoost ให้ค่า MAPE เท่ากับ 8.06%, 9.89% และ 11.21% ตามลำดับ ซึ่งมีค่าต่ำกว่า Random Forest ในทุกสัดส่วนการแบ่งข้อมูล โดยเฉพาะสัดส่วน 90:10 ซึ่งมีค่า MAPE ต่ำสุดเท่ากับ 8.06% แสดงให้เห็นว่าแบบจำลองสามารถเรียนรู้ความสัมพันธ์ที่ไม่เป็นเชิงเส้นและจับรูปแบบของข้อมูลได้ดีกว่า Random Forest สำหรับข้อมูลชุดนี้สะท้อนให้เห็นถึงความสามารถในการพยากรณ์ที่ดีกว่า นอกจากนี้ค่า MAE และ RMSE ของ XGBoost ก็มีค่าต่ำกว่า Random Forest โดยรวมเช่นกัน

โดยสรุปแบบจำลอง XGBoost มีประสิทธิภาพในการพยากรณ์สูงกว่า Random Forest สำหรับชุดข้อมูลนี้ โดยเฉพาะในกรณีสัดส่วน 90:10 ซึ่งให้ค่าความคลาดเคลื่อนต่ำที่สุด ดังแสดงในตารางที่ 4

ตารางที่ 4 การเปรียบเทียบค่าจริง (Actual) และค่าพยากรณ์ (Forecast) ของแบบจำลองการเรียนรู้ของเครื่อง

Month	Actual	Random Forest	XGBoost
1	1,047,453	874,399.66	732,684.40
2	526,295	726,686.44	542,820.80
3	584,480	717,485.63	577,206.30
4	523,582	551,472.88	563,268.90
5	566,406	542,520.96	561,710.30
6	453,129	477,825.56	457,983.50
7	504,491	476,522.92	481,595.80
8	550,178	492,184.27	476,170.50
9	518,286	495,873.44	566,085.00
10	634,055	559,100.22	558,052.80
11	617,898	622,736.13	595,789.10
12	860,061	710,063.22	774,116.50



ภาพที่ 2 การเปรียบเทียบระหว่างค่าจริง (Actual) กับ ค่าพยากรณ์ (Forecast) จากแบบจำลอง Random Forest และ XGBoost ภายใต้สัดส่วน 90:10

จากภาพที่ 2 การเปรียบเทียบระหว่างค่าจริงและค่าพยากรณ์ของแบบจำลอง Random Forest และ XGBoost ภายใต้การแบ่งสัดส่วน 90:10 พบว่าแบบจำลองทั้งสองสามารถเรียนรู้รูปแบบของข้อมูลในอดีตได้ดี โดยในช่วงข้อมูลฝึก (Training Set) เส้นค่าพยากรณ์ของทั้งสองแบบจำลองมีความสอดคล้องกับค่าจริงอย่างใกล้เคียง และแสดงให้เห็นถึงแนวโน้มรวมถึงรูปแบบฤดูกาลของข้อมูลได้อย่างชัดเจน อย่างไรก็ตามเมื่อพิจารณาในช่วงข้อมูลทดสอบ (Test Set) ซึ่งเป็นช่วงปลายของข้อมูล พบว่าแบบจำลองทั้งสองยังสามารถสะท้อนแนวโน้มโดยรวมได้ดี แต่มีความคลาดเคลื่อนเพิ่มขึ้นโดยเฉพาะบริเวณที่ข้อมูลมีการเปลี่ยนแปลงอย่างรวดเร็วหรือมีค่าพุ่งสูง (peak) ซึ่งแบบจำลองมีแนวโน้มที่จะประมาณค่าต่ำกว่าค่าจริงเล็กน้อย เมื่อเปรียบเทียบระหว่างแบบจำลองพบว่า XGBoost ให้ค่าพยากรณ์ที่ใกล้เคียงกับค่าจริงมากกว่า Random Forest ในหลายช่วงเวลา โดยเฉพาะในช่วงข้อมูลทดสอบที่มีความผันผวนสูง ซึ่งสอดคล้องกับผลการประเมินเชิงตัวเลขที่แสดงว่า XGBoost มีค่าความคลาดเคลื่อน (MAPE, RMSE และ MAE) ต่ำกว่า Random Forest โดยสรุปแบบจำลองทั้งสองมีประสิทธิภาพในการพยากรณ์ในระดับที่ดี และสามารถนำไปประยุกต์ใช้ในการพยากรณ์ข้อมูลในอนาคตได้ จึงสามารถสรุปได้ว่าแบบจำลอง XGBoost มีความเหมาะสมมากกว่า เนื่องจากสามารถให้ผลการพยากรณ์ที่แม่นยำและสอดคล้องกับค่าจริงได้ดีกว่าในภาพรวม

3. ผลการเปรียบเทียบระหว่าง ค่าจริง (Actual) และ ค่าพยากรณ์ (Forecast)

จากตารางการเปรียบเทียบระหว่างค่าจริง (Actual) และค่าที่ได้จากการพยากรณ์ด้วยแบบจำลอง Random Forest และ XGBoost ในรายเดือน (Month) ของชุดข้อมูลทดสอบ (Testing set) ซึ่งได้จากการแบ่งข้อมูลตามสัดส่วน 90:10 เมื่อพิจารณาเปรียบเทียบระหว่างสองแบบจำลอง พบว่าแบบจำลอง XGBoost ให้ค่าพยากรณ์ที่ใกล้เคียงกับค่าจริงมากกว่า Random Forest ในหลายช่วงเวลา โดยมีความคลาดเคลื่อนน้อยกว่าอย่างสม่ำเสมอ ซึ่งสอดคล้องกับผลการประเมินเชิงตัวเลขที่แสดงว่า XGBoost มีประสิทธิภาพในการพยากรณ์สูงกว่า โดยสรุปตารางที่ 5 นี้แสดงให้เห็นถึงความสามารถของแบบจำลอง และยืนยันว่าแบบจำลอง XGBoost สามารถให้ผลการพยากรณ์ที่แม่นยำกว่าเมื่อเทียบกับ Random Forest สำหรับชุดข้อมูลนี้

4. สรุปผลลัพธ์ของแบบจำลอง

จากตารางการเปรียบเทียบประสิทธิภาพของแบบจำลองระหว่างแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่อง ภายใต้การแบ่งข้อมูลแบบ Train-Test ในสัดส่วน 90:10 พบว่าแบบจำลองการเรียนรู้ของเครื่อง XGBoost ให้ค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAPE) ต่ำที่สุด เท่ากับ 8.06% ซึ่งต่ำกว่าแบบจำลองทางสถิติ ARIMA (0,1,3) ที่มีค่า MAPE เท่ากับ 12.25% อย่างชัดเจน นอกจากนี้เมื่อพิจารณาค่าความคลาดเคลื่อนในรูปแบบอื่น ได้แก่ RMSE และ MAE พบว่าแบบจำลอง XGBoost มีค่าความคลาดเคลื่อนต่ำกว่าแบบจำลองทางสถิติในภาพรวม ซึ่งสะท้อนให้เห็นถึงความสามารถในการ



พยากรณ์ที่แม่นยำกว่าในชุดข้อมูลนี้ ผลการวิเคราะห์ดังกล่าวชี้ให้เห็นว่าแบบจำลอง XGBoost มีศักยภาพในการเรียนรู้รูปแบบของข้อมูลที่มีความซับซ้อนและไม่เป็นเชิงเส้นได้ดีกว่า ในขณะที่แบบจำลอง ARIMA แม้จะเหมาะสมกับข้อมูลอนุกรมเวลา แต่มีข้อจำกัดในการรองรับความสัมพันธ์ที่ซับซ้อนของข้อมูล ดังนั้นจึงสามารถสรุปได้ว่า แบบจำลอง XGBoost เป็นแบบจำลองที่มีประสิทธิภาพสูงที่สุดสำหรับการพยากรณ์ข้อมูลชุดนี้ ภายใต้เงื่อนไขการแบ่งข้อมูลแบบ 90:10

ตารางที่ 5 การเปรียบเทียบแบบจำลองแบบจำลองทางสถิติและแบบจำลองการเรียนรู้ของเครื่อง

	แบบจำลอง	Train - Test	MAPE	RMSE	MAE
แบบจำลองทางสถิติ	ARIMA(0,1,3)	90:10 (108:12 เดือน)	12.25	114,252.30	81,202.20
แบบจำลองการเรียนรู้ของเครื่อง	XGBoost		8.06	101,227.26	59,712.72

อภิปรายและสรุปผลการวิจัย

ผลการศึกษาพบว่าแบบจำลอง XGBoost ให้ค่าความคลาดเคลื่อนต่ำที่สุดเมื่อเปรียบเทียบกับแบบจำลองอื่นที่ใช้ในการศึกษา สะท้อนให้เห็นถึงศักยภาพของแบบจำลองการเรียนรู้ของเครื่องในการเรียนรู้ความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นของข้อมูลอนุกรมเวลา ซึ่งอาจไม่สามารถอธิบายได้อย่างครบถ้วนด้วยแบบจำลองเชิงสถิติแบบดั้งเดิม เช่น ARIMA หรือ Holt-Winters แม้ว่าแบบจำลอง ARIMA (0,1,3) จะเป็นแบบจำลองอนุกรมเวลาที่ให้ผลดีที่สุด แต่ยังมีค่าความคลาดเคลื่อนสูงกว่า XGBoost แสดงให้เห็นว่าการพิจารณาแบบจำลองการเรียนรู้ของเครื่องควบคู่กับแบบจำลองอนุกรมเวลาเป็นแนวทางที่เหมาะสมสำหรับการพยากรณ์ข้อมูลด้านการเกษตรที่มีความผันผวน โดยผลการศึกษาสนับสนุนข้อค้นพบบางงานวิจัยที่รายงานว่า XGBoost สามารถให้ความแม่นยำสูงในการพยากรณ์ข้อมูลเศรษฐกิจและการเกษตรเมื่อข้อมูลมีความสัมพันธ์ที่ซับซ้อน อย่างไรก็ตาม ความได้เปรียบของแบบจำลองอาจแตกต่างกันไปตามลักษณะของข้อมูล จำนวนตัวอย่าง และรูปแบบของฤดูกาล ดังนั้นการเลือกแบบจำลองควรพิจารณาควบคู่กับการตรวจสอบคุณสมบัติของข้อมูลและการประเมินประสิทธิภาพด้วยตัวชี้วัดหลายประเภท

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองพยากรณ์ปริมาณการส่งออกมันฝรั่งรายเดือน โดยใช้ข้อมูลช่วงปี พ.ศ. 2559–2568 จำนวน 120 เดือน ผ่านแบบจำลอง Holt-Winters แบบ Multiplicative, ARIMA, SARIMA, Random Forest และ XGBoost และประเมินผลด้วยการแบ่งข้อมูลตามลำดับเวลาในสัดส่วน 90:10, 80:20 และ 70:30 ผล ADF ของการตรวจสอบพบว่า Dickey-Fuller statistic = -4.9395 และ p-value = 0.01 จึงสนับสนุนว่า Stationarity และค่า d หลักควรเป็น 0 ขณะที่ผลจากการศึกษาพบว่า ARIMA(0,1,3) มี BIC = 3181.81 ต่ำที่สุดในบรรดาตัวแบบ ARIMA โดยให้ MAPE = 12.25% ในสัดส่วน 90:10 จึงใช้เป็น benchmark เปรียบพยากรณ์ ไม่ใช่แบบจำลองที่กำหนด d = 1 จาก ADF โดยตรง สำหรับ SARIMA แบบจำลอง SARIMA(1,0,1)(0,1,1) [12] ให้ BIC = 2909.28 และผ่านการตรวจสอบ Ljung-Box โดยมี p-value = 0.9117 เช่นเดียวกับ ARIMA(1,0,0) และ ARIMA(0,1,3) ที่มี p-value = 0.4804 และ 0.6093 ตามลำดับ ขณะที่ Holt-Winters มี p-value = 4.954×10^{-5} และไม่ผ่านเกณฑ์ Ljung-Box ที่ระดับ 0.05 ในด้านแบบจำลองการเรียนรู้ของเครื่อง XGBoost ให้ MAPE = 8.06%, 9.89% และ 11.21% ในสัดส่วน 90:10, 80:20 และ 70:30 ตามลำดับ และต่ำกว่า Random Forest ซึ่งมี MAPE = 11.90%, 12.38% และ 12.32% ตามลำดับ ผลจึงสนับสนุนว่า XGBoost ให้ความแม่นยำเชิงพยากรณ์สูงกว่า แบบจำลองที่นำมาทดลองในการศึกษานี้ โดยเฉพาะสัดส่วน 90:10 อย่างไรก็ตามการแบ่งข้อมูล 90:10, 80:20 และ 70:30 ซึ่งช่วยตรวจสอบความไวต่อขนาดชุดฝึก โดยตัวแบบ ARIMA ที่เน้นการอธิบายความสัมพันธ์เชิงเส้นเป็นหลัก แม้ว่า ARIMA (0,1,3) จะสามารถให้ผลลัพธ์ที่ดีในเชิงแนวโน้ม แต่ยังไม่สามารถสะท้อนความผันผวนระยะสั้นได้อย่างมีประสิทธิภาพ ในขณะที่แบบจำลอง XGBoost สามารถจัดการกับข้อมูลที่มีความซับซ้อนและมี nonlinear pattern ได้ดีกว่า ส่งผลให้ค่าความคลาดเคลื่อนต่ำกว่าอย่างชัดเจน โดยเฉพาะในกรณีที่ข้อมูลมีความแปรปรวนสูงและมีปัจจัยแฝงที่ไม่สามารถอธิบายได้ด้วยแบบจำลองเชิงเส้น อย่างไรก็ตามการใช้แบบจำลองการเรียนรู้ของ



เครื่องมือข้อจำกัดในการตีความ (interpretability) เมื่อเปรียบเทียบกับแบบจำลองทางสถิติ อีกทั้งยังต้องการการเตรียมข้อมูลและการปรับพารามิเตอร์ที่เหมาะสม เพื่อให้ได้ผลลัพธ์ที่มีประสิทธิภาพสูงสุด ในส่วนของการแบ่งข้อมูล Train-Test พบว่าสัดส่วน 90:10 ให้ผลลัพธ์ที่ดีที่สุดโดยรวม เนื่องจากมีข้อมูลสำหรับการเรียนรู้มากเพียงพอ ขณะที่ในกรณีข้อมูลที่มีความผันผวนสูง ผลลัพธ์สะท้อนให้เห็นว่าการประเมินแบบจำลองหลายรูปแบบก่อนเลือกใช้งานจริงสามารถช่วยเพิ่มความแม่นยำในการพยากรณ์ และเป็นข้อมูลสนับสนุนการวางแผนด้านการผลิต การบริหารจัดการการส่งออก และการกำหนดนโยบายด้านการเกษตรได้ การศึกษาครั้งนี้ใช้ข้อมูลอนุกรมเวลาจากแหล่งข้อมูลเดียวและมุ่งเน้นตัวแปรปริมาณการส่งออกเป็นหลัก จึงยังไม่ได้รวมปัจจัยภายนอก เช่น ราคาตลาดโลก อัตราแลกเปลี่ยน สภาพภูมิอากาศ หรือมาตรการทางการค้า ซึ่งอาจส่งผลกระทบต่อความแม่นยำของการพยากรณ์ นอกจากนี้ ติดกันจำนวนข้อมูลที่ใช้ยังจำกัดอยู่ในช่วงเวลาการศึกษา ซึ่งอาจมีผลต่อประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง

เอกสารอ้างอิง

1. สำนักงานเศรษฐกิจการเกษตร. รายงานสถานการณ์พืชเศรษฐกิจที่สำคัญของประเทศไทย. กรุงเทพฯ: กระทรวงเกษตรและสหกรณ์; 2561.
2. สำนักงานเศรษฐกิจการเกษตร. สถานการณ์การผลิตและการตลาดมันฝรั่งของประเทศไทย. กรุงเทพฯ: กระทรวงเกษตรและสหกรณ์; 2562.
3. สำนักงานเศรษฐกิจการเกษตร. ข้อมูลพื้นที่เพาะปลูกและผลผลิตมันฝรั่ง ปีเพาะปลูก 2562/63. กรุงเทพฯ: กระทรวงเกษตรและสหกรณ์; 2563.
4. สำนักงานเศรษฐกิจการเกษตร. ดุลอุปสงค์-อุปทานมันฝรั่งของประเทศไทย. กรุงเทพฯ: กระทรวงเกษตรและสหกรณ์; 2562.
5. กระทรวงพาณิชย์. ประกาศกำหนดโควตานำเข้ามันฝรั่งดิบเพื่ออุตสาหกรรมแปรรูปภายใต้ความตกลง WTO. กรุงเทพฯ: กระทรวงพาณิชย์; 2566.
6. สำนักงานเศรษฐกิจการเกษตร. รายงานวิเคราะห์ปัจจัยการผลิตและข้อจำกัดของพืชอุตสาหกรรม. กรุงเทพฯ: กระทรวงเกษตรและสหกรณ์; 2564.
7. Han J, Kamber M, Pei J. Data Mining: Concepts and Techniques. 4th ed. Burlington: Morgan Kaufmann; 2022.
8. Kuhn M, Johnson K. Feature Engineering and Selection. Boca Raton: CRC Press; 2019.
9. Box GEP, Jenkins GM, Reinsel GC, Ljung GM. Time Series Analysis: Forecasting and Control. 5th ed. Hoboken: Wiley; 2015.
10. Winters PR. Forecasting sales by exponentially weighted moving averages. Manag Sci 1960;6(3):324-42.
11. Hyndman RJ, Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts; 2021.
12. Brockwell PJ, Davis RA. Introduction to Time Series and Forecasting. 3rd ed. New York: Springer; 2016.
13. Breiman L. Random Forests. Machine Learning 2001;45(1):5-32.
14. James G, Witten D, Hastie T, Tibshirani R. An Introduction to Statistical Learning. 2nd ed. New York: Springer; 2021.
15. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 13-17 August 2016; San Francisco, USA. New York: ACM; 2016. p.785-94.
16. Ljung GM, Box GEP. On a measure of lack of fit in time series models. Biometrika 1978;65(2):297-303.
17. Hyndman RJ, Koehler AB. Another look at measures of forecast accuracy. Int J Forecast 2006;22(4):679-88.