

ตัวแบบผสมของการแปลงบ็อกซ์-ค็อกซ์และซัพพอร์ตเวกเตอร์รีเกรตชันด้วยวิธีการกึ่งนิวตัน
แบบมีขอบเขตสำหรับการพยากรณ์ปริมาณการส่งออกแป้งมันสำปะหลังดิบไปสู่สาธารณรัฐ
ประชาชนจีน

The combined model of Box – Cox transformation and support vector
regression by using L-BFGS-B method for predicting native starch export to
China

ชนิตร์นันท์ กุลทนต์^{1*} ธอรณิ์ สัจจวิริยทรัพย์²

Chanitnan Kultanan¹ Thoranin Sujjaviriyasup¹

สาขาวิศวกรรมโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย¹

E-mail:

บทคัดย่อ

ประเทศไทยเป็นหนึ่งในประเทศผู้ผลิตและส่งออกแป้งมันสำปะหลังดิบรายใหญ่ของตลาดการค้าระหว่างประเทศสามารถสร้างรายได้เข้าสู่ประเทศจำนวนมากในแต่ละปี โดยมีประเทศคู่ค้าที่สำคัญ คือ สาธารณรัฐประชาชนจีน แต่อย่างไรก็ตาม ปริมาณการส่งออกมีลักษณะไม่คงที่และไม่แน่นอนส่งผลต่อการวางแผนและการตัดสินใจด้านการส่งออกในแต่ละช่วงเวลา งานวิจัยนี้ พัฒนาตัวแบบผสมที่รวมวิธีการทั้ง 3 วิธี ซึ่งประกอบไปด้วยการแปลงบ็อกซ์-ค็อกซ์ ซัพพอร์ตเวกเตอร์รีเกรตชันและวิธีการกึ่งนิวตันแบบมีขอบเขต เพื่อใช้ประโยชน์จากทั้ง 3 วิธีดังกล่าวสำหรับการเพิ่มความแม่นยำของการพยากรณ์ให้สูงขึ้น โดยเปรียบเทียบกับตัวแบบพยากรณ์ทางสถิติทั่วไปและตัวแบบผสมของซัพพอร์ตเวกเตอร์รีเกรตชันและวิธีการกึ่งนิวตันแบบมีขอบเขตด้วยเกณฑ์วัดประสิทธิภาพ 5 เกณฑ์ ซึ่งผลการวิจัยพบว่า ตัวแบบผสมที่รวมทั้ง 3 วิธีการให้ความแม่นยำมากที่สุดและมีความแม่นยำร้อยละ 83 จึงมีความน่าสนใจที่จะใช้สำหรับการพยากรณ์ปริมาณการส่งออกแป้งมันสำปะหลังดิบไปสู่สาธารณรัฐประชาชนจีนเพื่อเป็นสารสนเทศประกอบการวางแผนและตัดสินใจที่เกี่ยวข้องกับการส่งออกได้อย่างเหมาะสม

คำสำคัญ: สินค้าเกษตร แป้งมันสำปะหลังดิบ การส่งออก ตัวแบบผสม

¹ อาจารย์ ดร., อาจารย์ประจำสาขาวิชาวิศวกรรมโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย

² อาจารย์ รศ.ดร., อาจารย์ประจำสาขาวิชาวิศวกรรมโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย

* chanitnan_kul@utcc.ac.th

Abstract

Thailand is one of the world's major producers and exporters of native cassava starch and can generate substantial income for each year. The People's Republic of China is the most important trading partner of Thailand for this product. However, export volumes are volatile and uncertain, which plays a significant role in planning and decision-making. This research develops a combined model based on three methods, which consist of Box-Cox transformation, Support Vector Regression, and the L-BFGS-B algorithm, in order to leverage their advantages to enhance forecasting accuracy. By using 5 performance criteria to compare the general statistical forecasting models with Support Vector Regression and the L-BFGS-B algorithm, we found out that the combined model incorporating all three methods yields the highest precision, achieving an accuracy of 83 percent. Consequently, this combined model based on three methods is suitable for forecasting the volume of native cassava starch exports to the People's Republic of China, which provides valuable information to support effective export planning and decision-making.

Keywords: Agricultural commodity, Native starch, Export, Combined model

บทนำ

แป้งมันสำปะหลังดิบเป็นหนึ่งในสินค้าทางการเกษตรที่สำคัญอย่างหนึ่งของประเทศไทย ซึ่งเป็นผลผลิตจากกระบวนการแปรรูปจากหัวมันสำปะหลังสดเพื่อแปลงเป็นแป้งสำหรับการผลิตอาหารหลากหลายรูปแบบ (ชัยวัช ไชวเจริญสุข, 2568) รวมทั้งอุตสาหกรรมต่างๆ ที่มีความจำเป็นต้องใช้แป้งมันสำปะหลังดิบในกระบวนการผลิตต่างๆ เช่น เครื่องดื่ม เอทานอล เป็นต้น ส่งผลให้แป้งมันสำปะหลังดิบเป็นที่ต้องการเพิ่มสูงขึ้นของผู้บริโภคทั้งภายในประเทศและภายนอกประเทศ นอกจากนี้ ปริมาณการผลิตแป้งมันสำปะหลังดิบของประเทศไทยยังมีมากกว่าความต้องการบริโภคภายในประเทศ จึงทำให้ประเทศไทยสามารถผลิตแป้งมันสำปะหลังดิบจำนวนมากเพื่อการส่งออกและเป็นผู้ส่งออกรายใหญ่ไปยังประเทศคู่ค้าต่างๆ นำมาซึ่งมูลค่าการส่งออกจำนวนมากและสร้างรายได้ให้กับประเทศอย่างมาก แต่ผลผลิตหัวมันสำปะหลังซึ่งเป็นวัตถุดิบเริ่มต้นของกระบวนการผลิตแป้งมันสำปะหลังดิบมีความไม่แน่นอน โดยมีผลกระทบจากสภาพอากาศในรอบการเพาะปลูกในแต่ละฤดูกาล โดยหนึ่งในประเทศคู่ค้าที่สำคัญและส่งออกมากที่สุดของประเทศไทย คือ สาธารณรัฐประชาชนจีน ซึ่งมีปริมาณการส่งออกไปจำหน่ายในแต่ละเดือนมีปริมาณค่อนข้างมาก (กรมศุลกากร, 2568)

อย่างไรก็ตาม ปริมาณการส่งออกในแต่ละเดือนที่ส่งไปยังประเทศสาธารณรัฐประชาชนจีนมีปริมาณไม่แน่นอนและไม่คงที่ อีกทั้งยังยากต่อการประมาณการด้วยวิธีการอย่างง่าย เพื่อใช้เป็นสารสนเทศประกอบการวางแผนการส่งออกของประเทศไทย เพื่อให้ต้นทุนต่างๆ ที่เกี่ยวข้องกับการส่งออกให้เกิดความเหมาะสมที่สุด

วัตถุประสงค์การวิจัย

1. นำเสนอตัวแบบผสมของการแปลงบ็อกซ์-ค็อกซ์ (Box-Cox transformation) และซัพพอร์ตเวกเตอร์รีเกรตชัน (Support vector regression) ด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต (L-BFGS method) ที่เหมาะสมที่มีคุณสมบัติการปรับข้อมูลอนุกรมเวลาให้เหมาะสมยิ่งขึ้น ความสัมพันธ์ไม่เชิงเส้นตรง และวิธีการค้นหาที่เหมาะสม เพื่อให้ผลการพยากรณ์ปริมาณการส่งออกเปี่ยมล้นสำหรับปีงบประมาณ 2569
2. เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์ต่างๆ ได้แก่ ตัวแบบทางสถิติ ตัวแบบการเรียนรู้ของเครื่องด้วยเกณฑ์การประเมินประสิทธิภาพการพยากรณ์จำนวน 5 เกณฑ์
3. นำเสนอตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์ปริมาณการส่งออกเปี่ยมล้นสำหรับปีงบประมาณ 2569

การทบทวนวรรณกรรม

การพยากรณ์ปริมาณการส่งออกเป็นหนึ่งในประเด็นที่น่าสนใจสำหรับการวางแผนและบริหารจัดการด้านการส่งออกที่สำคัญเพื่อให้ได้สารสนเทศที่เหมาะสมประกอบการตัดสินใจ (Omoluabi & Ibitoye, 2024) โดยหนึ่งในวิธีการพยากรณ์ที่ได้รับความนิยม คือ การวิเคราะห์อนุกรมเวลา ซึ่งใช้ข้อมูลปริมาณการส่งออกย้อนหลังเพื่อสร้างสมการความสัมพันธ์ทำนายค่าปริมาณการส่งออกที่กำลังจะเกิดขึ้นในอนาคตเพียงปัจจัยเดียว จึงมีความสะดวกในการใช้งานและลดความยุ่งยากด้านปัจจัยที่มีผลต่อการพยากรณ์ หากความแม่นยำของการพยากรณ์มีมากเพียงพอต่อการตัดสินใจภายใต้ข้อจำกัดด้านเวลาและการเข้าถึงข้อมูล

วิธีการพยากรณ์เชิงสถิติเป็นหนึ่งในวิธีการพยากรณ์ที่ได้รับความนิยมใช้มาอย่างยาวนาน ซึ่งใช้ประกอบการวางแผนและดำเนินการต่างๆ โดยตัวแบบที่นิยมใช้ในภาคอุตสาหกรรม คือ ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียล ซึ่งใช้การถ่วงน้ำหนักในการลดความสำคัญของข้อมูลที่อยู่ห่างไกลจากข้อมูลปัจจุบันให้ลดน้อยลงแบบเอ็กโพเนนเชียล โดยตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลที่เหมาะสมกับข้อมูลรายเดือนคือ ตัวแบบโฮลท์วินเทอร์ ซึ่งมีสมการความสัมพันธ์ที่อธิบายได้ทั้งระดับการเปลี่ยนแปลงของข้อมูลอนุกรมเวลา แนวโน้มการเปลี่ยนแปลงของข้อมูลอนุกรมเวลา และฤดูกาลของข้อมูลอนุกรมเวลา จึงมีความเหมาะสมที่จะใช้สำหรับการพยากรณ์ปริมาณการส่งออกเปี่ยมล้นสำหรับปีงบประมาณ นอกจากนี้ ตัวแบบอาร์มาแบบมีฤดูกาล (Seasonal Autoregressive Integrated Moving Average; SARIMA) เป็นหนึ่งในตัวแบบการพยากรณ์ทางสถิติที่ได้รับการยอมรับว่ามีประสิทธิภาพดีสำหรับข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบเชิงเส้นตรงสำหรับ

ข้อมูลรายเดือนและนิยมใช้เป็นตัวแทนพยากรณ์มาตรฐานสำหรับการเปรียบเทียบประสิทธิภาพ (Pannakkong, et. al., 2019; Pannakkong, et. al., 2015)

ถึงแม้ตัวแทนพยากรณ์ทางสถิติจะมีประสิทธิภาพดี แต่ก็มีข้อจำกัดในการใช้งานสำหรับข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรง แต่ตัวแทนการเรียนรู้ของเครื่องมีสมการความสัมพันธ์แบบไม่เชิงเส้นตรงจึงนิยมใช้สำหรับการพยากรณ์ข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงมากกว่า (Tao, et. al., 2023; Mbugua, et. al., 2018) โดยหนึ่งในตัวแทนการเรียนรู้ของเครื่องที่ได้รับความนิยม คือ ตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชัน ซึ่งสามารถให้ผลการพยากรณ์ที่เหมาะสมเพียงค่าเดียว ภายใต้โครงสร้างที่เหมาะสมด้วยวิธีการค่าที่เหมาะสมที่สุด ส่งผลให้ตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันได้รับความนิยมจนถึงปัจจุบัน (Polyiam & Boonrawd, 2017; Du, et. al., 2013)

อย่างไรก็ตาม อาจไม่สามารถระบุความสัมพันธ์ที่เด่นชัดภายในข้อมูลอนุกรมเวลาและข้อมูลอนุกรมเวลายังอาจไม่สมบูรณ์ก่อนการประยุกต์ใช้ตัวแบบต่างๆ ในการสร้างสมการความสัมพันธ์เพื่ออธิบายข้อมูลอนุกรมเวลา จึงอาจส่งผลต่อประสิทธิภาพและความแม่นยำของการพยากรณ์ ทำให้เกิดการนำเสนอวิธีการปรับปรุงคุณภาพของข้อมูลอนุกรมเวลาก่อนการประยุกต์ใช้ตัวแบบต่างๆ โดยหนึ่งในวิธีการที่นำเสนอ คือ การแปลงบ็อกซ์-ค็อกซ์ (Alshamrani, 2025; Zhang, et. al., 2018; Osborne, 2010) เพื่อใช้สำหรับปรับรูปแบบของข้อมูลอนุกรมเวลาให้มีความเหมาะสมสำหรับการสร้างสมการความสัมพันธ์ในการอธิบายและเพิ่มความแม่นยำของการพยากรณ์ให้สูงขึ้น นอกจากคุณภาพของข้อมูลอนุกรมเวลาที่มีความสำคัญต่อประสิทธิภาพการพยากรณ์แล้ว การค้นหาพารามิเตอร์ที่เหมาะสมของตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันก็เป็นอีกหนึ่งประเด็นที่มีผลต่อประสิทธิภาพการพยากรณ์ด้วยเช่นกัน ซึ่งการใช้วิธีการกึ่งนิวตันแบบมีขอบเขตเป็นหนึ่งในวิธีการที่ได้รับความนิยมและใช้สำหรับการค้นหาค่าที่เหมาะสมภายใต้ขอบเขตที่กำหนด (Arun. Et. al., 2025; Amanullah & Kujani, 2025; Wang, et. al., 2024)


งานวิจัยนี้ ประยุกต์ใช้การรวมกันของการแปลงบ็อกซ์-ค็อกซ์เพื่อปรับปรุงข้อมูลอนุกรมเวลาให้เหมาะสมยิ่งขึ้นและใช้ตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันที่สามารถสร้างสมการความสัมพันธ์ไม่เป็นเชิงเส้นตรงเพื่ออธิบายข้อมูลอนุกรมเวลาที่ผ่านมาการแปลงบ็อกซ์-ค็อกซ์ โดยการค้นหาพารามิเตอร์ที่เหมาะสมภายใต้ขอบเขตที่กำหนดด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต เพื่อให้ตัวแบบผสมที่ประกอบไปด้วยวิธีการทั้ง 3 ส่วนให้ผลการพยากรณ์ที่มีความแม่นยำมากยิ่งขึ้น

โดยการเปรียบเทียบประสิทธิภาพการพยากรณ์ใช้เกณฑ์การวัดประสิทธิภาพจำนวน 5 เกณฑ์ ได้แก่ ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error; MAE) ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error; RMSE) ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error; MAPE) รากของค่าเฉลี่ยของร้อยละความคลาดเคลื่อนกำลังสอง (Root Mean Square Percentage Error; RMSPE) และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร (Symmetric Mean Absolute Percentage Error; sMAPE) ตามลำดับ

ระเบียบวิธีการวิจัย

1. ข้อมูลปริมาณการส่งออกแป้งมันดิบรายเดือนไปสาธารณรัฐประชาชนจีน

ข้อมูลปริมาณการส่งออกแป้งมันดิบรายเดือนเป็นข้อมูลอนุกรมเวลาจำนวน 64 ค่าสังเกต ตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึงเดือนเมษายน พ.ศ. 2568 ที่เผยแพร่ออนไลน์บนเว็บไซต์ของกรมศุลกากร (กรมศุลกากร, 2568) ดังรูปที่ 1



รูปที่ 1 ปริมาณการส่งออกแป้งมันดิบไปสาธารณรัฐประชาชนจีน

1. ตัวแบบโฮลท์วินเทอร์

ตัวแบบโฮลท์วินเทอร์เป็นวิธีการปรับเรียบแบบเอ็กโพเนนเชียลที่ประกอบด้วยสมการอธิบายความสัมพันธ์ 3 สมการ สำหรับรูปแบบของการเปลี่ยนแปลงระดับ แนวโน้ม และฤดูกาล ของข้อมูลอนุกรมเวลา เพื่อให้สามารถอธิบายรูปแบบความสัมพันธ์ของข้อมูลอนุกรมเวลาได้ทั้ง 3 รูปแบบข้างต้น โดยมีสมการดังนี้

1.1 ตัวแบบโฮลท์วินเทอร์เชิงการบวก

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (1)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (2)$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad (3)$$

$$\hat{y}_{t+1} = l_t + b_t + s_{t-m+1} \quad (4)$$

1.2 ตัวแบบโฮลท์วินเทอร์เชิงการคูณ

$$l_t = \alpha \left(\frac{y_t}{s_{t-m}} \right) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

$$s_t = \gamma \left(\frac{y_t}{l_{t-1} + b_{t-1}} \right) + (1 - \gamma)s_{t-m} \quad (7)$$

$$\hat{y}_{t+1} = (l_t + b_t)s_{t-m+1} \quad (8)$$

- เมื่อ l_t คือ ค่าประมาณของระดับของข้อมูลอนุกรมเวลา ณ เวลาที่ t
 b_t คือ ค่าประมาณของแนวโน้มของข้อมูลอนุกรมเวลา ณ เวลาที่ t
 s_t คือ ค่าประมาณของฤดูกาลของข้อมูลอนุกรมเวลา ณ เวลาที่ t
 α คือ ค่าการปรับเรียบของระดับ ซึ่งมีค่า $0 < \alpha < 1$
 β คือ ค่าการปรับเรียบของแนวโน้ม ซึ่งมีค่า $0 < \beta < 1$
 γ คือ ค่าการปรับเรียบของฤดูกาล ซึ่งมีค่า $0 < \gamma < 1$
 $\hat{y}_{t+1}$ คือ ค่าพยากรณ์ล่วงหน้า 1 ช่วงเวลา

ตัวแบบโฮลท์วินเทอร์ที่เหมาะสมทั้งแบบเชิงการบวกและเชิงการคูณด้วยเกณฑ์ค่าเฉลี่ยผลรวมกำลังสองของความคลาดเคลื่อนที่น้อยที่สุด จากฟังก์ชัน `hw()` ในแพ็คเกจของโปรแกรม R โดยกำหนด AHW และ MHW แทนตัวแบบโฮลท์วินเทอร์แบบเชิงการบวกและเชิงการคูณ ตามลำดับ (Hyndman, et. al., 2025)

2. ตัวแบบอาร์มาแบบมีฤดูกาล

ตัวแบบอาร์มาแบบมีฤดูกาลเป็นแบบที่ได้รับการพัฒนาต่อจากตัวแบบอาร์มาเพื่อให้สามารถอธิบายข้อมูลอนุกรมเวลาที่มีรูปแบบของฤดูกาลและสามารถให้ความเหมาะสมกับรูปแบบความสัมพันธ์ของข้อมูลอนุกรมเวลามากยิ่งขึ้นและผลการพยากรณ์ที่แม่นยำมากยิ่งขึ้น โดยมีสมการดังนี้

2.1 ตัวแบบอาร์มาแบบมีฤดูกาล

$$\Phi_P(B^S)\mu_P(B)y'_t = \delta + \theta_Q(B)\Theta_Q(B^S)\varepsilon_t \quad (9)$$

- เมื่อ y'_t คือ ค่าของ $(1-B)^d(1-B)^D y_t$
 δ คือ ค่าคงที่
 ε_t คือ ค่าความคลาดเคลื่อน ณ เวลาที่ t
 μ และ B คือ ค่าเฉลี่ยและตัวแปลงค่าอนุกรมเวลาย้อนกลับ ตามลำดับ
 d และ D คือ ค่าลำดับผลต่างแบบไม่มีฤดูกาลและแบบมีฤดูกาล ตามลำดับ
 p และ q คือ ค่าลำดับของตัวแบบอาร์มาแบบไม่มีฤดูกาล
 P และ Q คือ ค่าลำดับของตัวแบบอาร์มาแบบมีฤดูกาล
 $\hat{y}_{t+1}$ คือ ค่าพยากรณ์ล่วงหน้า 1 ช่วงเวลา

ตัวแบบอาร์มาแบบมีฤดูกาลที่เหมาะสมใช้เกณฑ์สารสนเทศอะคาอิเกะที่ปรับความถูกต้องสำหรับขนาดตัวอย่างขนาดเล็ก (Akaike Information Criterion with a correction for small sample size; AICC) ที่น้อยที่สุด โดยใช้ฟังก์ชัน `auto.arima()` ในแพ็คเกจของโปรแกรม R ซึ่งใช้สัญลักษณ์ SARIMA แทนตัวแบบอาร์มาแบบมีฤดูกาล (Hyndman, et. al., 2025)

3. ตัวแบบซัพพอร์ทเวกเตอร์รีเกรตชัน

ตัวแบบซัพพอร์ทเวกเตอร์รีเกรตชันเป็นหนึ่งในตัวแบบการเรียนรู้ของเครื่องที่มีความสามารถสร้างสมการความสัมพันธ์ที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงและเป็นจุดเด่นที่ตัวแบบทางสถิติไม่สามารถอธิบายได้ ซึ่งใช้เรเดียลเบสิคเคอร์เนลฟังก์ชัน (Radial basis kernel function) สำหรับการอธิบายข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรง โดยมีสมการดังนี้

$$f(x) = \sum_{i=1}^T (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (10)$$

เมื่อ α_i and α_i^* คือ ค่าของลากรางจ์ และ $K(x, x_i)$ คือ เคอร์เนลฟังก์ชันแบบเรเดียลเบสิค และค่า b ค่าเอนเอียง

ตัวแบบซัพพอร์ทเวกเตอร์รีเกรตชันที่เหมาะสมใช้เกณฑ์ผลรวมกำลังสองของความคลาดเคลื่อนที่น้อยที่สุด (Karatzoglou, et. al., 2025) โดยใช้สัญลักษณ์ SVR แทนตัวแบบซัพพอร์ทเวกเตอร์รีเกรตชัน

4. ตัวแบบผสมของซัพพอร์ทเวกเตอร์รีเกรตชันและวิธีการกึ่งนิวตันแบบมีขอบเขต

ตัวแบบผสมของซัพพอร์ทเวกเตอร์รีเกรตชันและวิธีการกึ่งนิวตันแบบมีขอบเขตเป็นการรวมข้อดีของความสามารถในการอธิบายความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงของตัวแบบซัพพอร์ทเวกเตอร์รีเกรตชันและการค้นหาค่าพารามิเตอร์ที่เหมาะสมของตัวแบบซัพพอร์ทเวกเตอร์รีเกรตชันเพื่อให้มีประสิทธิภาพดีที่สุดภายใต้ขอบเขตการค้นหากำหนดและสามารถให้ความแม่นยำมากขึ้น โดยมีขั้นตอนการดำเนินการดังนี้

- 4.1 กำหนดค่าข้อมูลป้อนเข้าเพื่อสร้างสมการความสัมพันธ์จำนวน 1 ค่า เพื่อทำนายค่าอนาคต 1 ค่า
- 4.2 กำหนดขอบเขตของค่า Cost มีค่าระหว่าง 0.01 ถึง 50 และ Gamma มีค่าระหว่าง 0.01 ถึง 2 ตามลำดับ
- 4.3 กำหนดค่าเริ่มต้นของค่า Cost เท่ากับ 10 และค่า Gamma มีค่าเท่ากับ 0.1 โดยกำหนดการค้นหาระดับให้ k เท่ากับ 1
- 4.4 พยากรณ์ล่วงหน้า 1 ช่วงเวลา โดยใช้สมการ (10) ของตัวแบบซัพพอร์ทเวกเตอร์รีเกรตที่มีค่าพารามิเตอร์ที่เหมาะสม ซึ่งได้จากการค้นหาค่าที่เหมาะสมด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต
- 4.5 พิจารณาค่าร้อยละความคลาดเคลื่อนสมบูรณ์เฉลี่ยและกำหนดให้อยู่ในรูปของฟังก์ชัน $f(w_k)$ เพื่อปรับค่าพารามิเตอร์ในรอบถัดไป
- 4.6 พิจารณาหาความชันของฟังก์ชัน $f(w_k)$ ด้วยสมการ $g_k = f(w_k)$ ซึ่ง g_k คือ ความชันของฟังก์ชันในรอบที่ k
- 4.7 พิจารณาทิศทางการปรับค่าพารามิเตอร์ด้วยสมการ $d_k = -H_k g_k$ โดย คือ d_k ทิศทางการปรับค่าพารามิเตอร์ของตัวแบบผสมและ H_k คือ เมตริกต์ผกผันของ Hessian ที่ k

- 4.8 ดำเนินการปรับค่าพารามิเตอร์ใหม่
- 4.9 ดำเนินการปรับปรุงเมตริกซ์ผกผันของ Hessian
- 4.10 ดำเนินการซ้ำตั้งแต่ข้อ 4.4 ถึง 4.9 จนกระทั่งครบตามเงื่อนไขของการหยุดปรับปรุงค่า
น้ำหนักที่เหมาะสม
- 4.11 เพิ่มค่า Cost ที่ละ 10 และค่า Gamma ที่ละ 0.1 และดำเนินการซ้ำตั้งแต่ข้อ 4.4 ถึง
4.10 จนกระทั่งค่า Cost เท่ากับ 50 และค่า Gamma มีค่าเท่ากับ 2
- 4.12 เพิ่มค่าป้อนเข้าที่ละ 1 และดำเนินการซ้ำตั้งแต่ข้อ 4.4 ถึง 4.11 จนกระทั่งค่าป้อนเข้ามี
ค่าเท่ากับ 10

ตัวแบบผสมของซัพพอร์ตเวกเตอร์รีเกรตชันและวิธีการกึ่งนิเวศน์แบบมีขอบเขตที่เหมาะสมใช้เกณฑ์
ผลรวมกำลังสองของความคลาดเคลื่อนที่น้อยที่สุด โดยใช้สัญลักษณ์ SVR-L-BFGS แทนตัวแบบผสมของซัพ
พอร์ตเวกเตอร์รีเกรตชันและวิธีการกึ่งนิเวศน์แบบมีขอบเขต

5. ตัวแบบผสมของการแปลงบ็อกซ์-ค็อกซ์และซัพพอร์ตเวกเตอร์รีเกรตชันด้วยวิธีการกึ่งนิเวศน์ แบบมีขอบเขต


ตัวแบบผสมของการแปลงบ็อกซ์-ค็อกซ์และซัพพอร์ตเวกเตอร์รีเกรตชันด้วยวิธีการกึ่งนิเวศน์แบบมี
ขอบเขตเป็นการรวมข้อดีของความสามารถในการปรับปรุงคุณภาพของข้อมูลอนุกรมเวลาก่อนการพยากรณ์
การอธิบายความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงของตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันและการค้นหา
ค่าพารามิเตอร์ที่เหมาะสมของตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันเพื่อให้มีประสิทธิภาพดีที่สุดภายใต้ขอบเขต
การค้นหาที่กำหนดและสามารถให้ความแม่นยำมากที่สุด โดยมีขั้นตอนการดำเนินการดังนี้

- 5.1 กำหนดค่าข้อมูลป้อนเข้าเพื่อสร้างสมการความสัมพันธ์จำนวน 1 ค่า เพื่อทำนายค่า
อนาคต 1 ค่า
- 5.2 กำหนดค่าแลมบ์ดาเริ่มต้นเท่ากับ 0 และแปลงข้อมูลอนุกรมเวลาด้วยสมการ
$$f_\lambda(y_t) = \left(\text{sign}(y_t) |y_t|^\lambda - 1 \right) / \lambda$$
- 5.3 กำหนดขอบเขตของ Cost มีค่าระหว่าง 0.01 ถึง 50 และ Gamma มีค่าระหว่าง 0.01
ถึง 2 ตามลำดับ
- 5.4 กำหนดค่าเริ่มต้นของค่า Cost เท่ากับ 10 และค่า Gamma มีค่าเท่ากับ 0.1 โดย
กำหนดการค้นหาแรกให้ k เท่ากับ 1
- 5.5 พยากรณ์ล่วงหน้า 1 ช่วงเวลา โดยใช้สมการที่ (10) ของตัวแบบซัพพอร์ตเวกเตอร์รีเกรต
ที่มีค่าพารามิเตอร์ที่เหมาะสม ซึ่งได้จากการค้นหาค่าที่เหมาะสมด้วยวิธีการกึ่งนิเวศน์
แบบมีขอบเขต
- 5.6 พิจารณาค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยและกำหนดให้อยู่ในรูปของฟังก์ชัน
 $f(w_k)$ เพื่อปรับค่าพารามิเตอร์ในรอบถัดไป

- 5.7 พิจารณาหาความชันของฟังก์ชัน $f(w_k)$ ด้วยสมการ $g_k = f'(w_k)$ ซึ่ง g_k คือ ความชันของฟังก์ชันในรอบที่ k
- 5.8 พิจารณาทิศทางการปรับค่าพารามิเตอร์ด้วยสมการ $d_k = -H_k g_k$ โดย คือ d_k ทิศทางการปรับค่าพารามิเตอร์ของตัวแบบผสมและ H_k คือ เมตริกต์ผกผันของ Hessian ที่ k
- 5.9 ดำเนินการปรับค่าพารามิเตอร์ใหม่
- 5.10 ดำเนินการปรับปรุงเมตริกซ์ผกผันของ Hessian
- 5.11 ดำเนินการซ้ำตั้งแต่ข้อ 5.5 ถึง 5.10 จนกระทั่งครบตามเงื่อนไขของการหยุดปรับปรุงค่าน้ำหนักที่เหมาะสม
- 5.12 เพิ่มค่าพารามิเตอร์ w ทีละ 10 และค่าพารามิเตอร์ ทีละ 0.1 และดำเนินการซ้ำตั้งแต่ข้อ 5.5 ถึง 5.11 จนกระทั่งค่าพารามิเตอร์ w เท่ากับ 50 และค่าพารามิเตอร์ มีค่าเท่ากับ 2
- 5.13 เพิ่มค่าแลมดาทีละ 1 และดำเนินการซ้ำตั้งแต่ข้อ 5.5 ถึง 5.12 จนกระทั่งมีค่าเท่ากับ 2
- 5.14 เพิ่มค่าป้อนเข้าทีละ 1 และดำเนินการซ้ำตั้งแต่ข้อ 5.5 ถึง 5.13 จนกระทั่งมีค่าเท่ากับ 10

6. การตรวจสอบแบบไขว้ (Cross – validation)

สำหรับการประเมินประสิทธิภาพการพยากรณ์ประกอบเกณฑ์ประเมินต่างๆ ใช้การตรวจสอบแบบไขว้เพื่อลดความเสี่ยงของปัญหาการเรียนรู้ที่ดีเกินความจริง (Overfitting problem) โดยการแบ่งชุดข้อมูลออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลสำหรับการสร้างตัวแบบพยากรณ์ (ร้อยละ 65 ของจำนวนข้อมูลทั้งหมด) และชุดข้อมูลสำหรับทดสอบตัวแบบพยากรณ์ (ร้อยละ 35 ของจำนวนข้อมูลทั้งหมด) ซึ่งสามารถอธิบายดังรูปที่ 2



รูปที่ 2 ชุดข้อมูลสำหรับการสร้างและทดสอบประสิทธิภาพตัวแบบพยากรณ์

เมื่อค่าจริงของปริมาณการส่งออกแข่งขันสำหรับผลิตภัณฑ์เปิดเผยและนำมาใช้คำนวณความคลาดเคลื่อนตามเกณฑ์ประเมินประสิทธิภาพต่างๆ ค่าดังกล่าวจะนำมารวมกับข้อมูลสำหรับการสร้างตัวแบบพยากรณ์เดิมเพื่อปรับปรุงข้อมูลให้ทันสมัยก่อนการสร้างตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์ค่าล่วงหน้าถัดไป

8. เกณฑ์การวัดประสิทธิภาพการพยากรณ์

1. ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (11)$$

2. ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (12)$$

3. ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย

$$MAPE = \frac{\sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \times 100}{n} \quad (13)$$

4. รากของค่าเฉลี่ยของร้อยละความคลาดเคลื่อนกำลังสอง


$$RMSPE = \sqrt{\frac{\sum_{t=1}^n \left(\frac{|y_t - \hat{y}_t|}{y_t} \times 100 \right)^2}{n}} \quad (14)$$

5. ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร

$$sMAPE = \frac{\sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t + \hat{y}_t} \times 200}{n} \quad (15)$$

ผลการวิจัยและอภิปรายผล

จากกระบวนการทดสอบประสิทธิภาพการพยากรณ์ ตัวแบบพยากรณ์ต่างๆ สามารถให้ค่าการพยากรณ์ที่สอดคล้องกับการเปลี่ยนแปลงของราคาโคเนื้อในแต่ละช่วงเวลา ยกเว้นตัวแบบโพลท์วินเทอร์เชิงการคูณที่ให้ผลการพยากรณ์ที่เบี่ยงเบนจากค่าจริงของราคาโคเนื้อค่อนข้างมากเมื่อเทียบกับตัวแบบพยากรณ์อื่นๆ ดังรูปที่ 3



รูปที่ 3 ผลการพยากรณ์ของตัวแบบพยากรณ์ต่างๆ

โดยตัวแบบพยากรณ์ต่างๆ สามารถให้ผลความคลาดเคลื่อนตามเกณฑ์การวัดประสิทธิภาพทั้ง 5 เกณฑ์ ดังตารางที่ 1

ตารางที่ 1 ประสิทธิภาพการพยากรณ์ตามเกณฑ์การวัดประสิทธิภาพต่างๆ

ตัวแบบ	MAE	MAPE	RMSE	RMSPE	sMAPE
ARIMA	32,241,715	21.67	41,224,093	29.12	19.74
AHW	46,422,404	31.57	56,285,591	41.96	31.47
MHW	40,055,411	26.48	50,118,250	35.75	25.03
SVR-L-BFGS	28,671,879	18.35	39,140,043	28.16	16.84
Proposed model	26,830,379	17.36	37,374,290	27.03	15.77

จากผลลัพธ์การประเมินประสิทธิภาพการพยากรณ์ในตารางที่ 1 พบว่า ตัวแบบโสมทวินเทอร์แบบเชิงบวกมีความแม่นยำเหนือกว่าตัวแบบโสมทวินเทอร์แบบเชิงบวก ซึ่งแสดงว่า รูปแบบการเปลี่ยนแปลงของข้อมูลอนุกรมเวลามีลักษณะไม่สม่ำเสมอ โดยสอดคล้องกับลักษณะของการหดตัวลงดังรูปที่ 1 อย่างไรก็ตาม ตัวแบบอาร์มาแบบมีฤดูกาลสามารถให้ความแม่นยำมากกว่าวิธีการปรับเรียบแบบเอ็กโพเนนเชียลสำหรับการเปรียบเทียบวิธีการพยากรณ์ทางสถิติด้วยกัน นอกจากนี้ ตัวแบบผสมของซัพพอร์ตเวกเตอร์เรกชันและวิธีการกึ่งนิวตันแบบมีขอบเขตที่อาศัยสมการความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงและวิธีการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดสามารถให้ความแม่นยำที่เพิ่มมากยิ่งขึ้นกว่าตัวแบบพยากรณ์ทางสถิติทั่วไป ซึ่งแสดงให้เห็นว่า ข้อมูลอนุกรมเวลาของปริมาณการส่งออกแปงมันดิบมีแนวโน้มความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงมากกว่าที่จะเป็นความสัมพันธ์เชิงเส้นตรง อย่างไรก็ตาม ตัวแบบผสมที่รวมกันของวิธีการทั้ง 3 วิธี ซึ่งประกอบได้การแปลงบ็อกซ์-ค็อกซ์ ซัพพอร์ตเวกเตอร์เรกชันและวิธีการกึ่งนิวตันแบบมีขอบเขต โดยการใช้การปรับปรุงคุณภาพของข้อมูลอนุกรมเวลาก่อนการประยุกต์ใช้ตัวแบบพยากรณ์สามารถเพิ่มความแม่นยำและสามารถอธิบายข้อมูลอนุกรมเวลาได้เหมาะสมที่สุด เมื่อเทียบกับตัวแบบผสมของซัพพอร์ตเวกเตอร์เรกชัน

และวิธีการกึ่งนิวตันแบบมีขอบเขตที่ไม่มีวิธีการในการปรับปรุงคุณภาพของข้อมูลอนุกรมเวลาก่อนการประยุกต์ใช้ตัวแบบพยากรณ์และตัวแบบทางสถิติต่างๆ

สรุปผลการวิจัย

จากการทดสอบและประเมินประสิทธิภาพการพยากรณ์ที่เกี่ยวข้องกับปริมาณการส่งออกแป้งมันสำปะหลังดิบไปสาธารณรัฐประชาชนจีน ตัวแบบผสมที่รวมกันของวิธีการทั้ง 3 วิธี มีความแม่นยำมากที่สุดของทุกเกณฑ์การประเมินประสิทธิภาพการพยากรณ์และมีความแม่นยำอย่างน้อยร้อยละ 82 ซึ่งมีความแม่นยำที่ดีและสามารถใช้เป็นสารสนเทศประกอบการวางแผนและการตัดสินใจที่เกี่ยวข้องกับปริมาณการส่งออกแป้งมันสำปะหลังดิบไปยังสาธารณรัฐประชาชนจีนได้

บรรณานุกรม

- ชัยวัช โสวเจริญสุข. (2568). แนวโน้มธุรกิจ/อุตสาหกรรม 2568 – 2570 : อุตสาหกรรมมันสำปะหลัง. เข้าถึงได้จาก: <https://www.krungsri.com/th/research/industry/industry-outlook/agriculture/cassava/io/cassava-2025-2027>
- กรมศุลกากร. (2568). ปริมาณการส่งออกแป้งมันสำปะหลังดิบรายเดือนไปสาธารณรัฐประชาชนจีน. เข้าถึงได้จาก : https://www.customs.go.th/statistic_report.php
- Omoluabi, J. E., & Ibitoye, S. J. (2024). Cassava production and agricultural growth in nigeria: Analysis of effects and forecast. GSC Advanced Research and Reviews, 21(1), 37-46.
- Pannakkong, W., Huynh, V. N., & Sriboonchitta, S. (2015). ARIMA versus artificial neural network for Thailand's cassava starch export forecasting. In Causal Inference in Econometrics (pp. 255-277). Cham: Springer International Publishing.
- Tao, M., Zhang, T., Xie, X., & Liang, X. (2023). Water footprint modeling and forecasting of cassava based on different artificial intelligence algorithms in Guangxi, China. Journal of Cleaner Production, 382, 135238.
- Pannakkong, W., Huynh, V. N., & Sriboonchitta, S. (2019). A novel hybrid autoregressive integrated moving average and artificial neural network model for cassava export forecasting. International Journal of Computational Intelligence Systems, 12(2), 1047-1061.
- Polyiam, K., & Boonrawd, P. (2017, April). A hybrid forecasting model of cassava price based on artificial neural network with support vector machine technique. In 2017 3rd International Conference on Information Management (ICIM) (pp. 123-127). IEEE.

- Du, X. F., Leung, S. C., Zhang, J. L., & Lai, K. K. (2013). Demand forecasting of perishable farm products using support vector machine. *International journal of systems Science*, 44(3), 556-567.
- Mbugua, J. K., & Suksa-ngiam, W. A. T. A. N. Y. O. O. (2018). Predicting suitable areas for growing cassava using remote sensing and machine learning techniques: A study in Nakhon-Phanom Thailand. *Issues in Informing Science and Information Technology*, 15, 043-056.
- Alshamrani, S. S. (2025). Machine Learning Techniques Improving the Box-Cox Transformation in Breast Cancer Prediction. *Electronics*, 14(16), 3173.
- Osborne, J. (2010). Improving your data transformations: Applying the Box-Cox transformation. *Practical Assessment, Research, and Evaluation*, 15(1) : 12. doi: <https://doi.org/10.7275/qbpc-gk17>.
- Zhang, Y., Xiong, R., He, H., & Pecht, M. G. (2018). Lithium-ion battery remaining useful life prediction with Box-Cox transformation and Monte Carlo simulation. *IEEE Transactions on Industrial Electronics*, 66(2), 1585-1597.
- Wang, X., Liu, S., Chen, S., He, X., Duan, W., Wang, S., ... & Xiong, C. (2024). Prediction of adsorption performance of ZIF-67 for malachite green based on artificial neural network using L-BFGS algorithm. *Journal of Hazardous Materials*, 473, 134629.
- Arun, B. S., Ajukumar, V. N., & Anand Sekhar, R. (2025). A novel L-BFGS-B optimized machine learning model for predicting tensile strength of SLM-manufactured Ti-6Al-4V alloys. *Journal of Materials Science*, 60(47), 24765-24783.
- Amanullah, M., & Kujani, T. (2025, June). A Hybrid Model for Meningitis Diagnostic Accuracy with Ensemble Learning: Combining Logistic Regression and L-BFGS. In *2025 Second International Conference on Cognitive Robotics and Intelligent Systems (ICC-ROBINS)* (pp. 290-295). IEEE.
- Hyndman, R., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., Kuroptev, K., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., Yasmeen, F., Garza, F., Girolimetto, D., Ihaka, R., Team, R. C., Reid, D., Shaub, D., Tang, Y., Wang, X., & Zhou, Z. (2025, April 8). Forecasting functions for time series and linear models. In Package 'forecast' (Version 8.24.0) <https://cran.r-project.org/web/packages/forecast/forecast.pdf>
- Karatzoglou, A., Smola, A., Hornik, K., Karatzoglou, M. A., SparseM, S., & Yes, L. (2025, April 8). The kernlab package. Kernel-Based Machine Learning Lab. R package version 0.9.-33. Available online: <https://cran.r-project.org/web/packages/kernlab/index.html>