

ตัวแบบพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบของประเทศไทย
โดยใช้โครงข่ายประสาทเทียมมอดูลรีเกรสซีฟไม่เชิงเส้นแบบเวฟเล็ต

Sugar and raw sugar products export volumes forecasting models
based on wavelet-nonlinear autoregressive neural network

อนาลยา หนานสายอ¹ และ อาทิตย์ อภิโชติธนกุล^{1*}

Analaya Nansaior¹ and Arthit Apichottanakul^{1*}

¹ สาขาวิชาเทคโนโลยีการผลิต คณะเทคโนโลยี มหาวิทยาลัยขอนแก่น

¹ Program of Production Technology, Faculty of Technology, Khon Kaen University

บทคัดย่อ: บทความนี้นำเสนอการพัฒนาตัวแบบพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบรายเดือนของประเทศไทยด้วย โครงข่ายประสาทเทียมมอดูลรีเกรสซีฟไม่เชิงเส้นแบบเวฟเล็ต และเปรียบเทียบผลการพยากรณ์กับวิธีโครงข่ายประสาทเทียมมอดูลรีเกรสซีฟไม่เชิงเส้น ผลลัพธ์แสดงให้เห็นว่าวิธีการโครงข่ายประสาทเทียมมอดูลรีเกรสซีฟไม่เชิงเส้นแบบเวฟเล็ตให้ความแม่นยำที่ดีด้วยค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ในการพยากรณ์ประมาณ 8% และ 6% สำหรับการประมาณปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบตามลำดับ และมีค่าความคลาดเคลื่อนในการพยากรณ์สินค้าเกษตรทั้งสองชนิดด้วยค่า RMSE เท่ากับ 6,745.31 และ 6,719.65 ตัน ตามลำดับ ดังนั้น หน่วยงานที่เกี่ยวข้องหรือผู้มีส่วนได้ส่วนเสียในอุตสาหกรรมอ้อยและน้ำตาลของไทยสามารถที่จะนำตัวแบบนี้ไปใช้ในการกำหนดนโยบายและการบริหารจัดการโซ่อุปทานที่เหมาะสมเพื่อให้เกิดประโยชน์สูงสุด เพื่อรักษาและเพิ่มขีดความสามารถในการแข่งขันโดยรวมได้ต่อไป

คำสำคัญ: การพยากรณ์อนุกรมเวลา; ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบ; โครงข่ายประสาทเทียมมอดูลรีเกรสซีฟไม่เชิงเส้นแบบเวฟเล็ต; อุตสาหกรรมอ้อยและน้ำตาลของไทย

ABSTRACT: The paper presents the development and comparison of the forecasting models for sugar and raw sugar products export volumes of Thailand. This approach has been developed based on wavelet-nonlinear autoregressive neural network (WNAR) and comparisons results with the nonlinear autoregressive neural network (NAR) method. The results show that the developed model provides accuracy prediction solutions with the minimum mean absolute percentage error (MAPE) values of 8%, 6% and minimum root mean square error (RMSE) values of 6,745; 6,720 tons for the sugar and raw sugar products, respectively. Therefore, the related stakeholders in Thai sugarcane and sugar industry should be used the models to set the appropriate policies and manage supply chains, to maximize overall benefits, to maintain and increase overall competitiveness.

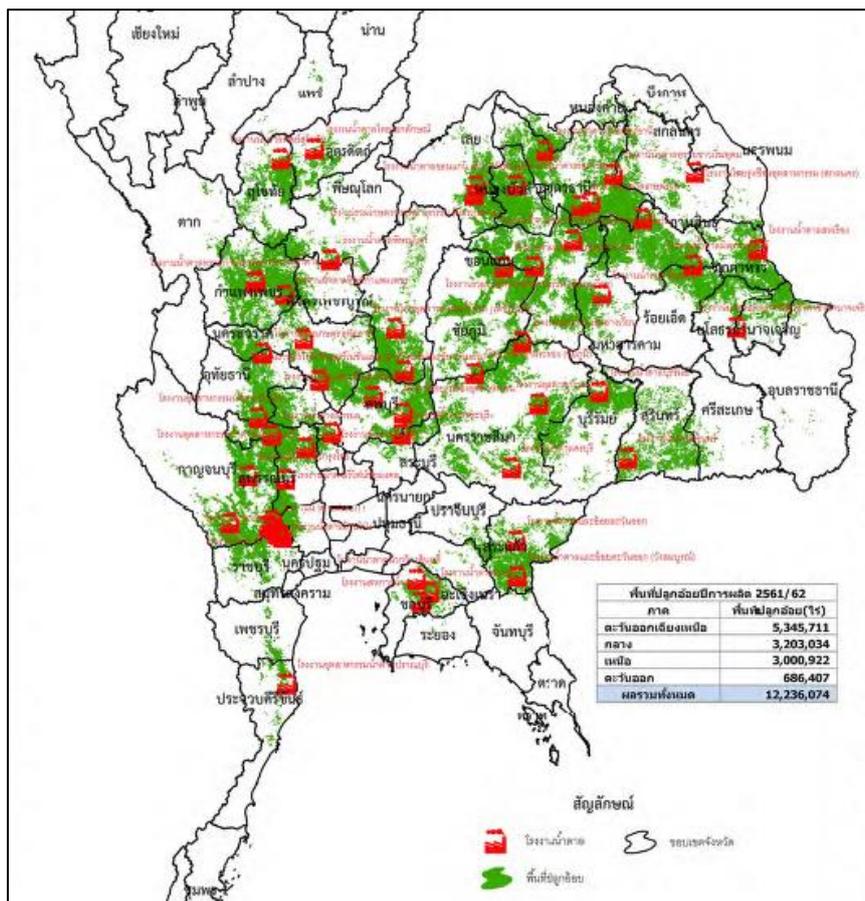
* Corresponding author: arthap@kku.ac.th

Received: date; April 30, 2020 Accepted: date; October 9, 2020 Published: date February 15, 2021

Keywords: time series forecasting; sugar and raw sugar products export volumes; wavelet-nonlinear autoregressive neural network model (WNAR); thai sugarcane and sugar industry

บทนำ

ประเทศไทยเป็นผู้ผลิตและส่งออกน้ำตาลรายใหญ่ที่สำคัญของโลกรองจากประเทศบราซิล สามารถทำรายได้ให้โรงงานน้ำตาลและเกษตรกรชาวไร่อ้อยคิดเป็นมูลค่าไม่ต่ำกว่าหนึ่งแสนล้านบาทต่อปี จึงส่งผลให้อ้อยและน้ำตาลเป็นสินค้าเกษตรที่มีบทบาทสำคัญต่อเศรษฐกิจของประเทศ เนื่องจากโซ่อุปทานอุตสาหกรรมอ้อยและน้ำตาลมีผู้ที่มีส่วนเกี่ยวข้องตั้งแต่ต้นน้ำไปจนถึงปลายน้ำเป็นจำนวนมากซึ่งประกอบด้วยเกษตรกรชาวไร่อ้อย ผู้รวบรวมและให้บริการด้านโลจิสติกส์ต่างๆ โรงงานที่บอ้อและผลิตน้ำตาล การตลาดและผู้กระจายน้ำตาลสู่ผู้บริโภคและอุตสาหกรรมที่ใช้น้ำตาลเป็นวัตถุดิบ รวมทั้งการใช้น้ำตาลภายในประเทศและการส่งออกไปยังตลาดต่างประเทศ นอกจากนี้ในโซ่อุปทานยังมีอุตสาหกรรมต่อเนื่องอื่นๆ ที่เชื่อมโยงกลางและปลายน้ำ อาทิ การผลิตผลิตภัณฑ์โมลาสหรือกากน้ำตาล โรงงานผลิตเอทานอลจากกากอ้อยและกากน้ำตาล โรงงานผลิตไฟฟ้า เยื่อกระดาษและปุ๋ยชีวภาพจากขานอ้อย เป็นต้น จากข้อมูลรายงานปี ค.ศ. 2016/2017 ของบองซูโคร (Bonsucro) ที่เป็นหน่วยงานไม่หวังผลกำไรในการกำหนดมาตรฐานสากลการผลิตอ้อยและน้ำตาลให้มีความยั่งยืนต่อเศรษฐกิจสังคมและสิ่งแวดล้อม (บองซูโคร, 2563) เปิดเผยว่า ประเทศไทยมีเกษตรกรชาวไร่ปลูกอ้อยมากกว่า 336,800 ราย สมาคมชาวไร่อ้อย 33 สมาคมและโรงงานผลิตน้ำตาล 51 แห่งที่ตั้งกระจายอยู่ทั่วประเทศและมีศักยภาพที่บอ้อโดยเฉลี่ย 100 – 106 ล้านเมตริกตันต่อปี ก่อให้เกิดการจ้างแรงงานประมาณ 50,000 คนใน 27 จังหวัด นอกจากนี้การปลูกอ้อยของเกษตรกรยังก่อให้เกิดการสร้างงานให้คนทั่วประเทศมากกว่า 1.5 ล้านคน ซึ่งจากรายงานของบองซูโครได้สรุปว่าโซ่อุปทานอุตสาหกรรมอ้อยและน้ำตาลมีบทบาทที่สำคัญต่อเศรษฐกิจของประเทศช่วยสร้างงานสร้างอาชีพและก่อให้เกิดรายได้ให้กับทุกภาคส่วนที่เกี่ยวข้อง โดยสอดคล้องกับรายงานประจำปีการผลิต 2561/2562 ของสำนักงานคณะกรรมการอ้อยและน้ำตาลที่แสดงพื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาลในประเทศไทย (Figure 1) ส่วนมากกระจายตัวอยู่ในพื้นที่ภาคกลางและภาคตะวันออกเฉียงเหนือ ดังนั้น ทั้งสองภูมิภาคนี้จึงเป็นแหล่งผลิตที่สำคัญของอุตสาหกรรมอ้อยและน้ำตาลไทย



Source: Sugarcane production annual report 2018/2019, Office of the Cane and Sugar Board

Figure 1 Location of sugarcane growing areas and sugarcane mills in Thailand (2018/2019)

สิ่งสำคัญในการบริหารจัดการโซ่อุปทานให้มีประสิทธิภาพเพื่อให้เกิดประโยชน์สูงสุดต่อทุกภาคส่วนในโซ่อุปทานก็คือความสามารถในการคาดการณ์หรือการมองเห็นความต้องการของลูกค้าล่วงหน้าในอนาคตเพื่อนำไปใช้ในการวางแผนจัดการทั้งโซ่อุปทานให้สอดคล้องกับความต้องการได้ โดยเฉพาะอย่างยิ่งอุตสาหกรรมอ้อยและน้ำตาลที่การพยากรณ์อุปสงค์หรือการทราบความต้องการล่วงหน้าจะช่วยสนับสนุนให้การวางแผนเพื่อบริหารจัดการในโซ่อุปทานเป็นไปอย่างมีประสิทธิภาพได้ ดังนั้น การพยากรณ์ปริมาณส่งออกสินค้าเกษตรจึงได้รับความสนใจจากนักวิชาการและนักวิจัยไทยและต่างประเทศในการพัฒนาและประยุกต์ใช้ตัวแบบพยากรณ์สำหรับสินค้าเกษตรที่สำคัญ เช่น การพยากรณ์ปริมาณการส่งออกยางพารา การส่งออกยางคอมพาวด์ การส่งออกมะม่วง และการส่งออกไก่แปรรูปของประเทศไทยด้วยเทคนิคอนุกรมเวลาแบบต่างๆ อาทิ วิธีแยกองค์ประกอบ วิธีปรับเรียบเอกซ์โพเนนเชียลแบบไฮลด์-วินเทอร์ วิธี ARIMA วิธีบ็อกซ์-เจนกินส์ และวิธีอื่นๆ (เฉลิมพล และ พัฒนา, 2559; วราจคณา, 2557; บุญฤทธิ และเสาวภา, 2561; วราจคณา และน้ำอ้อย, 2560) และการพยากรณ์ปริมาณส่งออกเมล็ดของประเทศตุรกีด้วยตัวแบบ ARIMA (Baser et al., 2018) ซึ่งงานวิจัยเหล่านี้จะอาศัยรูปแบบการพยากรณ์เชิงสถิติวิเคราะห์ข้อมูลในอดีตเพื่อหารูปแบบการเคลื่อนไหวของข้อมูลแล้วนำไปใช้คาดการณ์สิ่งที่จะเกิดขึ้นในอนาคต แม้ว่าการพยากรณ์แบบอนุกรมเวลาเหล่านี้จะให้ความแม่นยำที่ดีและยอมรับได้ อย่างไรก็ตาม งานวิจัยจำนวนมากในปัจจุบันจะมุ่งเน้นและให้ความสนใจไปที่การปรับปรุงตัวแบบพยากรณ์ให้มีความแม่นยำเพิ่มสูงมากยิ่งขึ้นด้วยการประยุกต์ใช้วิธีการทางสถิติและคอมพิวเตอร์สมัยใหม่ เช่น วิธีการเรียนรู้ของเครื่อง (Machine learning) วิธีปัญญาประดิษฐ์ (Artificial Intelligence, AI) ซึ่งการประยุกต์ใช้จะเป็นในรูปแบบเดี่ยวหรือแบบผสมนั้นก็ขึ้นอยู่กับเป้าหมายและลักษณะของงานนั้นๆ โดยวิธีการเรียนรู้ของเครื่องประเภทหนึ่งที่ได้รับการนิยมนำไปใช้พยากรณ์ในธุรกิจและอุตสาหกรรมต่างๆ เป็นจำนวนมาก คือ ตัวแบบ

โครงข่ายประสาทเทียม เช่น Multi-layer perceptrons (MLP) with backpropagation, Wavelet neural networks, NAR และ WNAR เป็นต้น เนื่องจากมีความน่าเชื่อถือและให้ความแม่นยำสูง (Li et al., 2020; Hamzaçebi et al., 2019; Mehdizadeh et al., 2019; Kummong & Supratid, 2019; Nourani & Farboudfam, 2019; Huang & Wang, 2018)

การพยากรณ์อนุกรมเวลาด้วยโครงข่ายประสาทเทียมหลายๆ งานวิจัยนิยมนำวิธีการแปลงเวฟเล็ตเข้ามาประยุกต์ร่วมเป็นตัวแทนผสมในการพัฒนารูปแบบการพยากรณ์ ซึ่งวิธีการผสมนี้ช่วยปรับปรุงให้โครงข่ายมีความแม่นยำเพิ่มสูงขึ้นกว่าวิธีโครงข่ายแบบเดิม (Bento et al., 2019; Kummong & Supratid, 2019; Nourani & Farboudfam, 2019; Huang & Wang, 2018) เนื่องจากการแปลงเวฟเล็ต (Wavelet decomposition) สามารถทำให้ตัวแบบสามารถวิเคราะห์และหารูปแบบการเคลื่อนไหวและเปลี่ยนแปลงของข้อมูลในแต่ละช่วงเวลาได้ โดยงานวิจัยของ Li et al., (2020) และ Hamzaçebi et al., (2019) ที่ทำการพยากรณ์ความต้องการไฟฟ้า (Electricity demand) ด้วยตัวแบบโครงข่ายประสาทเทียมร่วมกับการแยกองค์ประกอบแบบฟูเรียร์ (Fourier Decomposition) และการแปลงเวฟเล็ต ส่วน Huang and Wang (2018) ได้คาดการณ์ความต้องการใช้พลังงาน และ Bento et al., (2019) ที่พยากรณ์โหลดไฟฟ้าหรือความต้องการไฟฟ้าระยะสั้น (Load forecasting) โดยใช้การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียม ซึ่งผลลัพธ์ที่ได้จากวิธีการเหล่านี้แสดงให้เห็นชัดเจนว่ามีประสิทธิภาพและมีความแม่นยำสูง นอกจากนี้ งานวิจัยของ Wei et al., (2012) และ Kummong and Supratid (2019) ได้ทำการเปรียบเทียบและชี้ให้เห็นถึงประสิทธิภาพของรูปแบบผสมระหว่างโครงข่ายประสาทเทียมมอดริเรสซิฟไม่เชิงเส้นแบบเวฟเล็ต (WNAR) และแบบธรรมดาตั้งเดิม (NAR) โดยผลลัพธ์ที่ได้แสดงให้เห็นว่าวิธี WNAR ให้ความแม่นยำที่สูงกว่าวิธี NAR พร้อมได้เสนอแนะว่าวิธีการผสมดังกล่าวนี้สามารถนำไปประยุกต์ใช้งานด้านการพยากรณ์อนุกรมเวลาที่ข้อมูลมีการเคลื่อนไหวและเปลี่ยนแปลงในแต่ละช่วงเวลาได้เป็นอย่างดี

ดังนั้น งานวิจัยนี้จึงสนใจที่จะพัฒนารูปแบบพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบรายเดือนของประเทศไทยด้วยวิธี WNAR และเปรียบเทียบกับวิธี NAR ตามแนวทางจากงานวิจัยดังกล่าวข้างต้น เพื่อเป็นเครื่องมือสนับสนุนการตัดสินใจในบริหารจัดการด้วยการวางแผนการผลิต การจัดการผลพลอยได้ การขนส่ง การเพาะปลูก การเก็บเกี่ยวและรวบรวมอ้อย รวมถึงการจัดการสิ่งอำนวยความสะดวกต่างๆ ที่เกี่ยวข้อง เป็นต้น ซึ่งการคาดการณ์ปริมาณการส่งออกของประเทศไทยล่วงหน้าในอนาคตได้จึงมีความสำคัญและหน่วยงานที่เกี่ยวข้องสามารถนำไปเป็นข้อมูลเบื้องต้นในการกำหนดนโยบายและบริหารจัดการโซ่อุปทานอ้อยและน้ำตาลของไทยให้มีผลประโยชน์สูงสุดและเป็นการเพิ่มขีดความสามารถในการแข่งขันให้กับสินค้าอ้อยและน้ำตาลของประเทศไทยให้ยิ่งขึ้นต่อไป

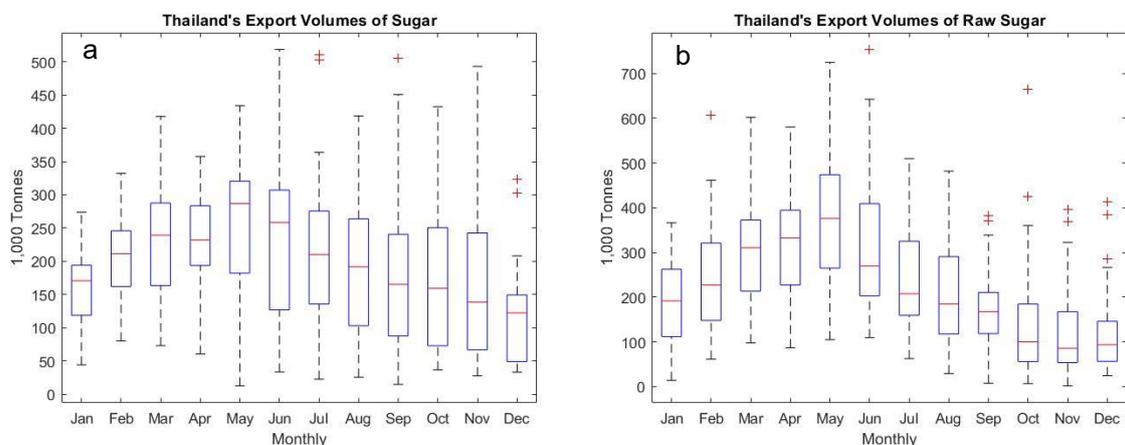


Figure 2 Box plots of Thailand's monthly export volumes of sugar (a) and raw sugar (b) from January 1998 to February 2020 (in 1,000 tonnes)

Table 1 Descriptive statistics of data sets used in this study

| Time series data set | Data set | Obs. | Mean | Std. | Skew. | Kurt. | Max. | Min. |
|----------------------|----------|------|---------|--------|-------|-------|---------|---------|
| Sugar | Training | 186 | 163,000 | 6,607 | 0.48 | -0.40 | 434,062 | 12,496 |
| | Test | 80 | 280,954 | 10,626 | 0.83 | 0.13 | 518,510 | 133,703 |
| | Entire | 266 | 198,475 | 6,517 | 0.55 | 0.12 | 51,8510 | 12,496 |
| Raw Sugar | Training | 186 | 203,432 | 10,501 | 1.29 | 2.04 | 753,633 | 1,829 |
| | Test | 80 | 309,829 | 15,627 | 0.24 | -0.18 | 665,307 | 55,232 |
| | Entire | 266 | 235,431 | 9,203 | 0.84 | 0.53 | 753,633 | 1,829 |

วิธีการดำเนินงานวิจัย

ข้อมูลอนุกรมเวลาปริมาณการส่งออก

ข้อมูลอนุกรมเวลาปริมาณการส่งออกน้ำตาลทรายและน้ำตาลดิบที่ใช้ในงานบทความนี้รวบรวมจากระบบฐานข้อมูลสถิติการส่งออกสินค้าเกษตรของสำนักงานเศรษฐกิจการเกษตร (สำนักงานเศรษฐกิจการเกษตร, 2563) ทั้งสองประเภทเป็นข้อมูลสถิติปริมาณการส่งออกรายเดือนของประเทศไทยตั้งแต่เดือนมกราคม พ.ศ. 2541 – เดือนกุมภาพันธ์ พ.ศ. 2563 (มีหน่วยเป็น 1,000 กิโลกรัม หรือตัน) โดยเป็นข้อมูลรายเดือนจำนวน 22 ปีย้อนหลังที่สำนักงานเศรษฐกิจการเกษตรได้เก็บรวบรวมไว้ซึ่งเพียงพอในการพัฒนาตัวแบบพยากรณ์จากรูปแบบการเคลื่อนไหวของข้อมูลในอดีต จากรูปที่ 2 กราฟแบบ Box plot แสดงปริมาณการส่งออกรายเดือนของสินค้าน้ำตาลทราย (a) และน้ำตาลดิบ (b) พบว่า ปริมาณการส่งออกเฉลี่ยของสินค้าทั้ง 2 ชนิดจะมีค่าสูงสุดในเดือนพฤษภาคมและมีค่าต่ำสุดในเดือนธันวาคมของทุกปี เนื่องจากทั้งสองเดือนดังกล่าวอาจจะเป็นช่วงฤดูกาลที่เริ่มปิดและเปิดหีบอ้อยในแต่ละฤดูกาลผลิตน้ำตาล และจากกราฟ Box plot ปริมาณการส่งออกรายเดือนของน้ำตาลดิบ พบว่ามีค่าผิดปกติ (Outlier) ในช่วงตั้งแต่เดือนกันยายน – ธันวาคม ซึ่งจะส่งผลกระทบต่อความแม่นยำในการพยากรณ์ ทำให้การพัฒนาตัวแบบพยากรณ์มีความยุ่งยากและซับซ้อน โดยงานวิจัยได้แบ่งข้อมูลรายเดือนทั้งหมดที่ใช้ในการพัฒนาตัวแบบพยากรณ์จำนวน 266 ข้อมูลออกเป็น 2 ชุด คือชุดฝึกสอน (Training data) และชุดทดสอบความแม่นยำ (Test data) ในสัดส่วน 70:30% ตามลำดับ ซึ่งการแบ่งข้อมูลสำหรับพัฒนาและทดสอบตัวแบบ (Model validation) สามารถดำเนินการได้หลากหลายรูปแบบ เช่น การแบ่งแบบ Hold-out validation แบ่งข้อมูลออกเป็น 2 ชุด คือ ฝึกสอนและชุดทดสอบความแม่นยำในสัดส่วนต่างๆ อาทิ 60:40%, 70:30%, 80:20% และแบบ K-Fold cross-validation ที่แบ่งข้อมูลเป็น k ชุด ในสัดส่วนเท่าๆ กัน ซึ่งจะกำหนดให้ข้อมูล 1 ชุด เป็นชุดทดสอบและที่เหลือเป็นชุดฝึกสอน แล้วจะเปลี่ยนชุดทดสอบหมุนเวียนกันไปทีละชุดจนครบทุกชุดข้อมูล โดยมักจะนิยมกำหนดให้ k เท่ากับ 5-fold หรือ 10-fold เป็นต้น ซึ่งก็ไม่ได้มีข้อกำหนดว่าจะต้องมีค่าเท่าไรสามารถกำหนดได้ตามความเหมาะสมในด้านเวลาและต้นทุนการพัฒนาตัวแบบ

อย่างไรก็ตาม เพื่อความสะดวกและประหยัดเวลาในการพัฒนาตัวแบบงานวิจัยนี้ที่ทำการแยกส่วนประกอบข้อมูลอนุกรมเวลาออกเป็นส่วนประกอบเวฟเลตในหลายๆ ระดับ เมื่อใช้เทคนิค K-Fold cross-validation จะต้องอาศัยเวลาที่ยาวนานในการพัฒนาตัวแบบ ดังนั้น งานวิจัยนี้จึงได้แบ่งข้อมูลออกเป็น 2 ชุด ตามสัดส่วนดังกล่าวไว้ข้างต้นตามแนวทางการดำเนินงานวิจัยของ Jallal et al. (2020), Zanotti et al., (2019), Khosravi et al. (2018) และ Tealab et al. (2017) และเพื่อป้องกันปัญหา Overfitting ในระหว่างการพัฒนาตัวแบบจึงได้ใช้เทคนิคการเรียนรู้แบบ Bayesian regularization (Kummong & Supratid, 2019; Zanotti et al., 2019) และสถิติเชิงพรรณนาของข้อมูลที่ใช้ในการพัฒนาตัวแบบพยากรณ์แสดงไว้ใน **Table 1** นอกจากนี้ได้ทำการทดสอบความนิ่งของข้อมูล (Unit root test) อนุกรมเวลาปริมาณการส่งออกน้ำตาลทรายและน้ำตาลดิบรายเดือนด้วยวิธี Augmented Dicky-Fuller test (ADF test) และ Kwiatkowski-Phillips-

Schmidt–Shin test (KPSS test) พบว่า ข้อมูลทั้งสองชนิดมีลักษณะนิ่ง (Stationary) ซึ่งสามารถนำวิธี Autoregressive-moving average (ARMA) มาประยุกต์ใช้ได้ แต่เนื่องจากงานวิจัยนี้ให้ความสนใจในการพัฒนาตัวแบบพยากรณ์ด้วยโครงข่ายประสาทเทียมออโตรีเกรสซีฟไม่เชิงเส้นทั้งแบบธรรมดาและแบบเวฟเล็ต เนื่องจากเป็นวิธีการที่เป็นนอนพารามेटริก (Non-parametric) ดังนั้น จึงไม่มีความจำเป็นที่จะต้องมีการทดสอบหรือรู้รูปแบบของข้อมูลใดๆ ก่อนนำเข้าสู่การพัฒนาตัวแบบพยากรณ์ โดยใช้เพียงแค่ข้อมูลในอดีตเพื่อคาดการณ์ค่าในอนาคต (Benmouiza & Chekane, 2016).

โครงข่ายประสาทเทียมออโตรีเกรสซีฟไม่เชิงเส้น (Nonlinear autoregressive neural network, NAR)

โครงข่าย NAR นับว่าเป็นโครงข่ายประสาทเทียมแบบพลวัตประเภทหนึ่งที่ถูกพัฒนาขึ้นมาเพื่อนำไปใช้งานในด้านการพยากรณ์แบบอนุกรมเวลาที่มีตัวแปรเดียวคือเวลา โดยโครงข่าย NAR จะมีการส่งสัญญาณแบบย้อนกลับซ้ำ (Recurrent feedbacks) จากชั้นเอาต์พุต (Output) ของโครงข่ายไปยังชั้นอินพุต (Input) ด้วยการหน่วงเวลา (Delay) นั่นคือ สามารถประมาณค่าเอาต์พุตที่เป็นค่าในอนาคตของอนุกรมเวลาได้ด้วยการใช้เพียงแค่ข้อมูลย้อนหลังในอดีตจำนวน d ค่า ค่าย้อนหลังในอดีตที่มีการหน่วงเวลานี้และถูกนำมาใช้พยากรณ์ค่าในอนาคต เรียกว่า “Time lag” (Kummong and Supratid, 2019; Wei et al., 2012) ในตัวแบบโครงข่าย NAR ค่าตัวแปรตามที่เป็นเอาต์พุต ณ เวลา $t + k$ คือ y_{t+k} ที่คำนวณมาจากค่าเอาต์พุตย้อนหลัง $y_t, y_{t-1}, \dots, y_{t-d}$ ดังนั้น ตัวแบบ NAR ที่มีการพยากรณ์แบบ k-time lag สามารถได้ดังสมการ (1)

$$y_{t+k} = f[y_t, y_{t-1}, \dots, y_{t-d}] \tag{1}$$

โดยทั่วไปแล้วฟังก์ชัน $f[.]$ ที่เป็นการส่งผ่านแบบไม่เชิงเส้น (Nonlinear mapping) นี้จะไม่ทราบค่าฟังก์ชันการทำให้เรียบ (Smoothing function) ของตัวแปรอิสระ แต่ก็สามารถประมาณค่าได้ด้วยการใช้โครงข่ายประสาทเทียมที่มีหลายชั้นแบบมาตรฐานทั่วไป และเนื่องด้วยค่าเอาต์พุตของโครงข่ายนี้ประมาณมาจากค่าจริงเอาต์พุตย้อนหลังในอดีต จึงแสดงได้ในรูปแบบสมการ (2) ดังนี้

$$\hat{y}_{t+k} = \hat{f}[y_t, y_{t-1}, \dots, y_{t-d}] \tag{2}$$

เมื่อ \hat{y}_{t+k} และ $\hat{f}[.]$ เป็นค่าประมาณของ y_{t+k} และ $f[.]$ ตามลำดับ ดังนั้น สมการเอาต์พุตทั่วไปของโครงข่าย NAR ก็สามารถแสดงรายละเอียดได้ดังสมการ (3)

$$\hat{y}_{t+k} = f_{out} \left(b_{out} + \sum_{h=1}^{N_h} w_{outh} * f_h \left(b_h + \sum_{j=0}^d w_{hj} * y_{t-j} \right) \right) \tag{3}$$

เมื่อ f_h และ f_{out} คือ ฟังก์ชันของชั้นซ่อนเร้น (Hidden) และเอาต์พุต ซึ่งโดยทั่วไปฟังก์ชันถ่ายโอนในชั้นซ่อนจะเป็น Tan-Sigmoid : $f_h(x) = 2 / (1 + \exp(-2x)) - 1$ และชั้นเอาต์พุตจะเป็นแบบฟังก์ชันเชิงเส้น $f_{out}(x) = x$ ตามลำดับ ส่วน w_{hj}, b_h และ w_{outh}, b_{out} คือ ค่าน้ำหนัก (Weights) และความเอนเอียง (Biases) ของชั้นซ่อนเร้นและเอาต์พุต ตามลำดับ และตัวแปร N_h คือ จำนวนนิวรอนหรือโหนดในชั้นซ่อนเร้น (Hidden neurons) ในการฝึกสอนโครงข่ายให้เรียนรู้จะเกี่ยวข้องกับการหาค่าที่เหมาะสมของเซตน้ำหนัก w_{hj}, w_{outh} และเซตของความเอนเอียง b_h, b_{out} เพื่อที่จะทำให้ค่าความผิดพลาดจากการพยากรณ์มีค่าน้อยที่สุด (Minimizes the forecasting error) : $error = y_{t+k} - \hat{y}_{t+k}$ โดยผลลัพธ์ที่ได้จากการเรียนรู้ก็คือความสัมพันธ์แบบไม่เชิงเส้นระหว่างอินพุตและเอาต์พุตที่เป็นค่าน้ำหนักจากการเรียนรู้ผ่านจำนวนโหนดในชั้นซ่อนที่กำหนดไว้ (Kummong & Supratid, 2019)

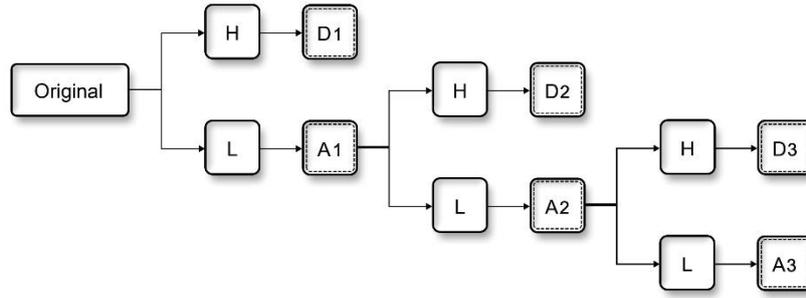


Figure 3 Three-level wavelet decomposition tree

การแปลงเวฟเล็ตแบบไม่ต่อเนื่อง (Discrete wavelet transform)

การแปลงเวฟเล็ตเป็นรูปแบบทางคณิตศาสตร์ที่ใช้อธิบายโครงสร้างของระบบสัญญาณที่ประกอบด้วยกลุ่มของสัญญาณเฉพาะหลายๆ ตัวมารวมกันเป็นสัญญาณหนึ่ง สัญญาณเฉพาะนี้จะเป็นคลื่นเล็กๆ เรียกว่า “เวฟเล็ต” ซึ่งได้มาจากการใช้วิธีการทางคณิตศาสตร์สกัดหรือคัดแยกรูปแบบของข้อมูล (pattern information) ที่ซ่อนอยู่ในสัญญาณอนุกรมเวลาเดิม (Original time series) โดยการแปลงเวฟเล็ตแบบไม่ต่อเนื่อง (Discrete wavelet transform, DWT) ได้รับความนิยมนำไปใช้ในการพัฒนารูปแบบการพยากรณ์อนุกรมเวลา เนื่องด้วยจากเป็นการนำสัญญาณที่เป็นข้อมูลอนุกรมเวลามาคัดแยกผ่านตัวกรองความถี่ต่ำ (Low pass filter, L) และความถี่สูง (High pass filter, H) เพื่อแยกองค์ประกอบของสัญญาณออกเป็นส่วนที่มีความถี่ต่ำ (Approximation, A) และส่วนที่มีความถี่สูง (Detail, D) (Kummong & Supratid, 2019; Nourani & Farboudfam, 2019; Huang & Wang, 2018; Wei et al., 2012) เมื่อแยกส่วนประกอบข้อมูลอนุกรมเวลาโดยผ่านตัวกรองความถี่ต่ำ (L) และความถี่สูง (H) ในระดับที่ 1 ก็จะได้ส่วนประกอบเวฟเล็ตหรือคอมโพเนนต์ A1 และ D1 จากนั้นนำคอมโพเนนต์ A1 ไปแยกส่วนประกอบในระดับที่ 2 ต่อไปจนครบทุกระดับ Figure 3 แสดงการแปลงเวฟเล็ตแบบไม่ต่อเนื่อง 3 ระดับและจะได้ผลลัพธ์เป็นคอมโพเนนต์ A3, D3, D2 และ D1

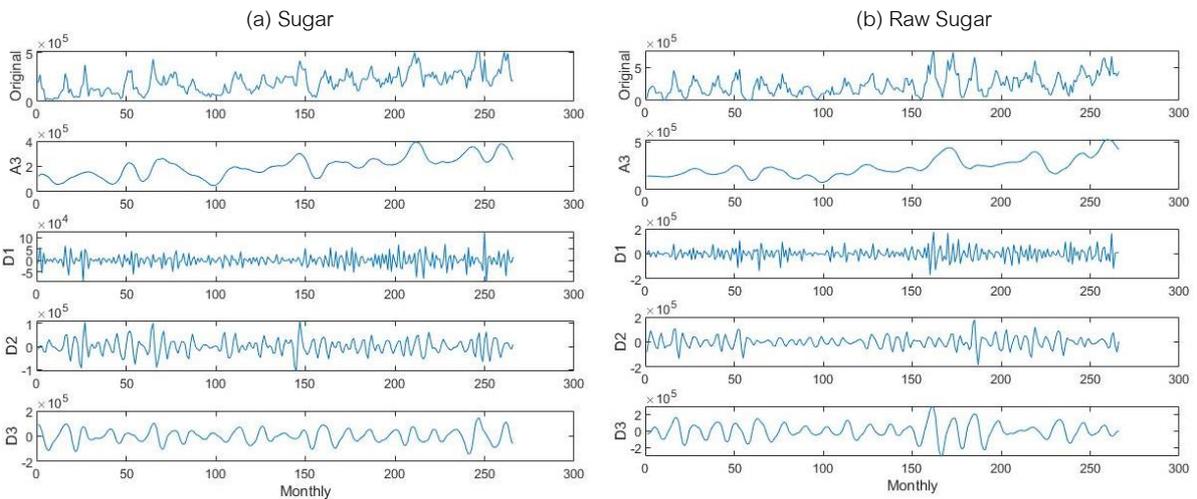


Figure 4 Wavelet decomposition for the original export volumes of sugar (a) and raw sugar (b) with level3 using Daubechies Wavelet No. 5 (db5)

ตัวแบบพยากรณ์ปริมาณส่งออกด้วยโครงข่ายประสาทเทียมมอดูลีกรสซีฟไม่เชิงเส้นแบบเวฟเล็ต (Wavelet-nonlinear autoregressive neural network model, WNAR)

วิธี WNAR ที่นำเสนอในงานวิจัยนี้เป็นการนำวิธี DWT และ NAR มาประยุกต์ใช้งานร่วมกันเพื่อการพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบรายเดือนตามกรอบแนวคิดที่ประยุกต์มาจากงานวิจัยของ Kummong and Supratid (2019) โดยมีรูปแบบการพยากรณ์ดังแสดงใน Figure 5 ซึ่งใช้การแปลงเวฟเล็ตแบบไม่ต่อเนื่อง 3 ระดับสำหรับการเตรียมข้อมูลก่อน (Pre-processing) นำไปใช้ในขั้นตอนการพัฒนาตัวแบบพยากรณ์ ดังนี้

(1) สำหรับขั้นตอนฝึกสอน (Training) ข้อมูลอนุกรมเวลาปริมาณการส่งออกของชุดฝึกสอนจะถูกแยกส่วนประกอบออกเป็นส่วนที่มีความถี่ต่ำ (Approximation) และส่วนที่มีความถี่สูง (Detail) โดยใช้การแปลงเวฟเล็ต DWT ด้วยฟังก์ชัน Daubechies wavelet (db5) ก็จะได้เป็นคอมโพเนนต์ A3, D3, D2 และ D1 (ดังแสดงใน Figure 4 และ 5) จากนั้นนำแต่ละคอมโพเนนต์ที่ได้ไปใช้ในการพัฒนาโครงข่าย NAR แยกกันแต่ละตัว โดยแต่ละตัวแบบ NAR จะทำการฝึกสอนและหาโครงสร้างและสถาปัตยกรรมที่เหมาะสมแยกกัน ภายใต้ขอบเขตของพารามิเตอร์ต่างๆ ที่ได้กำหนดไว้ ซึ่งผลลัพธ์ก็จะได้ตัวแบบ NAR ที่เหมาะสมสำหรับแต่ละคอมโพเนนต์จำนวน 4 ตัวแบบ ดังแสดงใน Figure 5

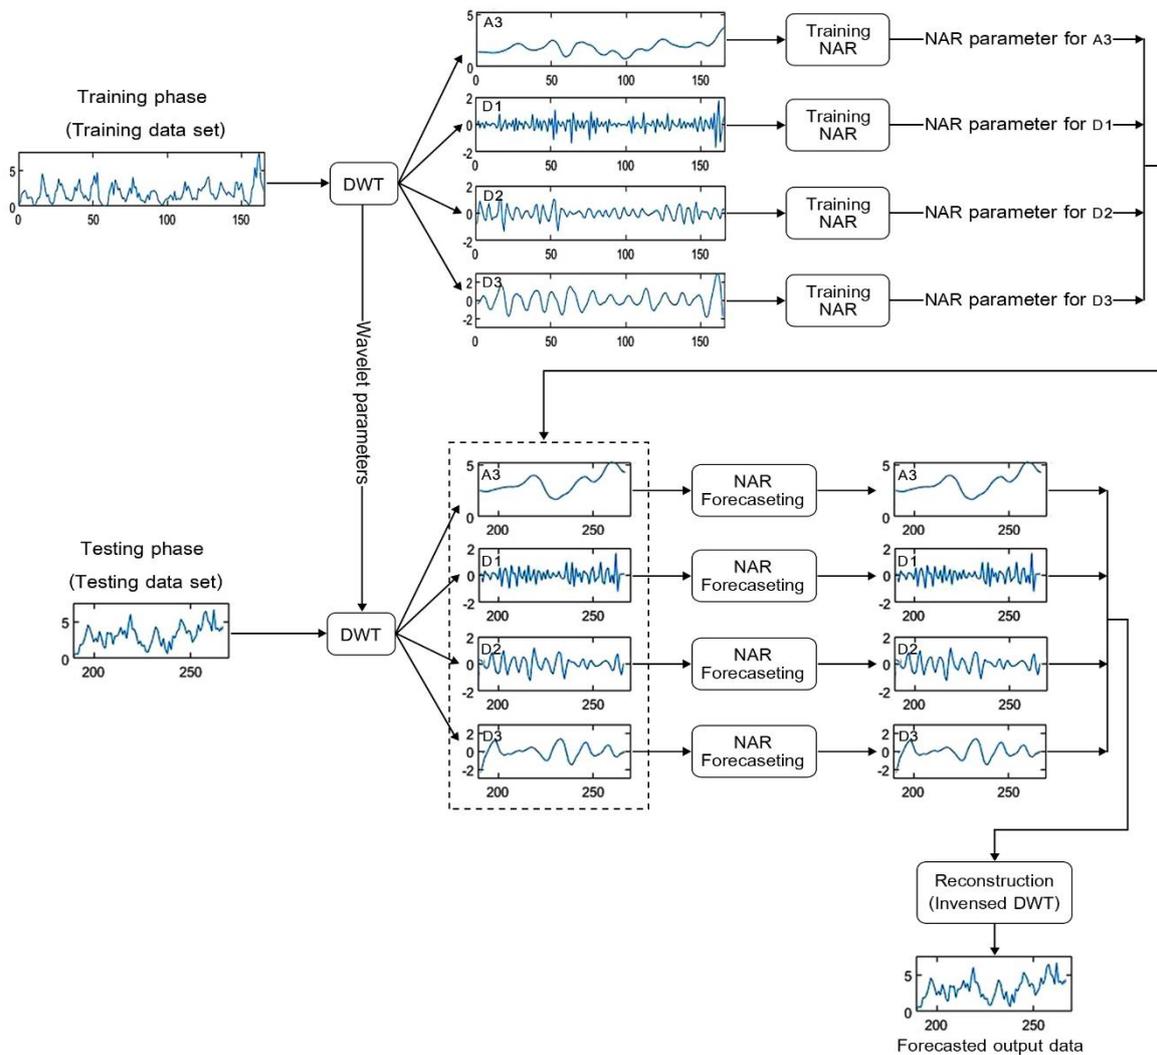


Figure 5 An overall framework of the proposed WNAR

(2) ขั้นตอนทดสอบความแม่นยำ (Test) ข้อมูลอนุกรมเวลาปริมาณการส่งออกของชุดทดสอบจะถูกแยกส่วนประกอบด้วยการแปลงเวฟเลตที่มีค่าพารามิเตอร์ต่างๆ ตามขั้นตอนฝึกสอนก่อนหน้านี้ ซึ่งจะได้ คอมโพเนนต์ A3, D3, D2 และ D1 จากนั้นนำแต่ละคอมโพเนนต์ไปใช้ทดสอบความแม่นยำโครงข่าย NAR ที่ได้จากขั้นตอนการฝึกสอน โดยใช้สำหรับคอมโพเนนต์ที่มีรูปแบบเดียวกันเท่านั้น เช่น คอมโพเนนต์ A3 ใช้ทดสอบ NAR ของ A3 เป็นต้น ดังแสดงใน **Figure 5**

(3) ขั้นตอนการพยากรณ์ (Forecasting output) นำผลลัพธ์ที่ได้จากแต่ละ NAR ของแต่ละคอมโพเนนต์มาทำการรวมองค์ประกอบหรือการสร้างกลับจากคอมโพเนนต์ (Reconstruction) ก็จะได้เอาต์พุตและนำไปประเมินประสิทธิภาพความแม่นยำในการพยากรณ์ต่อไป

การวัดความแม่นยำ

การประเมินประสิทธิภาพของตัวแบบด้วยการวัดความแตกต่างระหว่างข้อมูลจริงกับค่าพยากรณ์ด้วยสถิติ RMSE (Root mean square error) และ MAPE (Mean absolute percentage error) ถ้าค่าที่คำนวณได้มีค่าต่ำและมีค่าเข้าใกล้ศูนย์ก็หมายความว่ามีความแม่นยำ ยิ่งมีค่าต่ำก็ยิ่งมีความแม่นยำที่สูง โดยสามารถคำนวณได้ดังสมการ (4) และ (5) ตามลำดับ เมื่อ y_t คือ ค่าข้อมูลจริง (Actual) และ \hat{y}_t คือ ค่าพยากรณ์ (forecasted output) ณ เวลา t โดย N คือ จำนวนข้อมูลทั้งหมด ($t = 1, 2, \dots, N$)

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (4)$$

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (5)$$

ผลการศึกษา

การพัฒนาตัวแบบโครงข่ายประสาทเทียม NAR และ WNAR โดยการทดลองหาโครงสร้างและสถาปัตยกรรมที่เหมาะสมด้วยการกำหนดพารามิเตอร์ที่เกี่ยวข้อง ดังนี้ กำหนดชั้นซ่อน (Hidden layers) ให้มี 1 – 2 ชั้น จำนวนโหนด (Node) ในชั้นซ่อนเริ่มมีค่าในช่วง 3 – 40 โหนด ตามแนวทางการวิจัยของ Puchalsky et al., (2018) และจำนวนโหนดในชั้นซ่อนเริ่มที่ให้ผลลัพธ์ที่ดีที่สุดจะถูกเลือกเป็นโครงสร้างในการพัฒนาตัวแบบพยากรณ์ ฟังก์ชันกระตุ้น (Activation function) คือ Tansig และใช้อัลกอริทึม Levenberg-Marquardt with Bayesian regularization (Trainbr) เป็นฟังก์ชันในการฝึกสอนและการแปลงเวฟเลตแบบ DWT ด้วยฟังก์ชัน Daubechies wavelet (db5) โดยผลลัพธ์ที่ได้จาก **Table 2** และ **Table 3** ผลที่ได้จากโครงสร้างและสถาปัตยกรรมที่คัดเลือกมาจากกระบวนการทดลองดังกล่าวข้างต้น

การทดสอบประสิทธิภาพของตัวแบบพยากรณ์ที่นำเสนอจะใช้มาวัดความแม่นยำ RMSE และ MAPE ซึ่งคำนวณได้ดังสมการ (4) และ (5) โดยการตัวแบบพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบด้วยโครงข่าย NAR

Table 2 The performance indices of the NAR and WNAR models developed for the sugar and raw sugar data sets with 6 time lags

| Data sets | Method | RMSE | | | MAPE (%) | | |
|-----------|--------|----------|-----------|-----------|----------|-------|--------|
| | | Training | Test | Entire | Training | Test | Entire |
| Sugar | NAR | 6.02 | 61,633.74 | 15,878.08 | 30.09 | 27.55 | 29.44 |
| | WNAR | 0.36 | 6,745.31 | 1,737.95 | 5.48 | 7.96 | 6.12 |
| Raw Sugar | NAR | 37.07 | 79,952.30 | 20,575.58 | 101.52 | 32.73 | 83.79 |
| | WNAR | 0.57 | 6,719.65 | 1,731.18 | 6.47 | 5.65 | 6.26 |

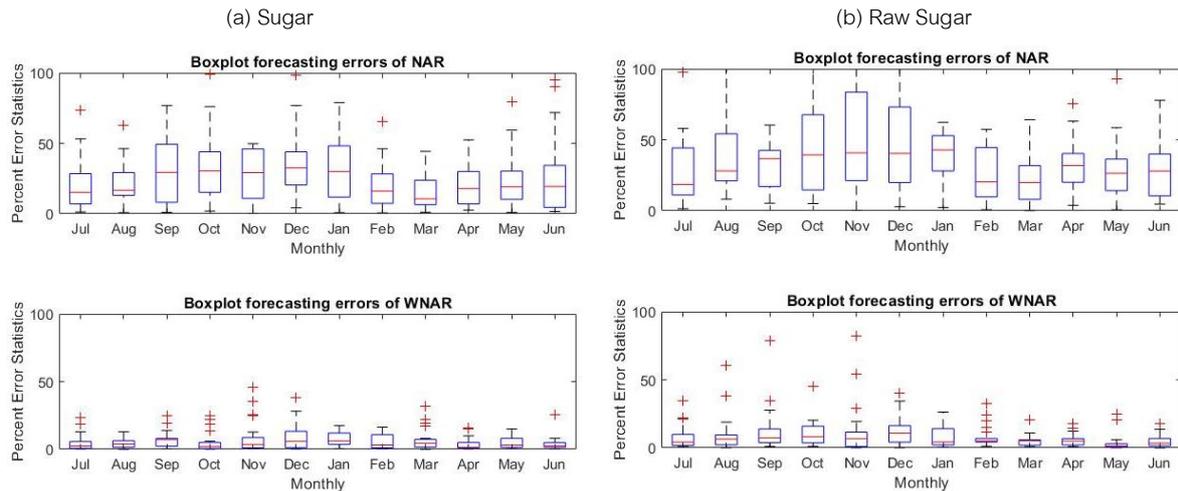


Figure 6 Box plots of the monthly forecast error statistics for export volumes of sugar (a) and raw sugar (b) with NAR and WNAR models

และ WNAR ที่ใช้ข้อมูลย้อนหลังในอดีต 6 ช่วงเวลา (6-Time lags) เพื่อเป็นการทดสอบประสิทธิภาพของตัวแบบพยากรณ์ที่ใช้ข้อมูลย้อนหลัง 6 เดือน ว่าจะสามารถวิเคราะห์รูปแบบการเคลื่อนไหวและการเปลี่ยนแปลงของข้อมูลได้หรือไม่ ซึ่งต้องมีการทดสอบจำนวนช่วงเวลาย้อนหลังในอดีตที่ต่างกันเพื่อหาจำนวนที่เหมาะสม เช่น ย้อนหลังจำนวน 3, 6, 9, 12 เดือน เป็นต้น แต่ ณ ที่นี้จะทดสอบนำร่องด้วยข้อมูลย้อนหลัง 6 เดือนในเบื้องต้นก่อนแล้วค่อยขยายผลถัดไป โดยผลลัพธ์แสดงใน **Table 2** และ **Figure 6** พบว่า วิธีการ WNAR ให้ความแม่นยำสูงกว่าวิธี NAR สำหรับทุกชุดข้อมูลที่ใช้ในการพัฒนาตัวแบบ พิจารณาค่า RMSE พบว่าวิธี WNAR จะมีค่าที่ใกล้เคียงกันในชุดข้อมูลทดสอบของปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบ นั่นคือวิธีการนี้จะมีความคลาดเคลื่อนในการพยากรณ์รายเดือนประมาณ 6,700 ตัน ส่วนวิธี NAR จะมีความคลาดเคลื่อน (ค่า RMSE) ประมาณ 62,000 และ 80,000 ตัน ตามลำดับ พิจารณาค่า MAPE พบว่า วิธี WNAR จะมีความผิดพลาดในการพยากรณ์ประมาณ 8% และ 6% สำหรับการประมาณปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบ ในขณะที่วิธี NAR จะมีค่าประมาณ 28% และ 33% ตามลำดับ โดยค่า MAPE ที่ได้จากวิธี NAR นี้สำหรับข้อมูลชุดฝึกสอนจะมีค่ามากกว่าชุดทดสอบ โดยเฉพาะอย่างยิ่งสำหรับการพยากรณ์น้ำตาลดิบซึ่งมีค่าสูงมาก คือ มีความผิดพลาดประมาณ 102% ทั้งที่เป็นข้อมูลชุดฝึกสอนซึ่งค่าที่ได้ตามทฤษฎีทั่วไปแล้วควรจะมีค่าต่ำ เพราะค่า RMSE สำหรับชุดฝึกสอนก็มีค่าที่ต่ำจึงได้ทำการวิเคราะห์ผลการพยากรณ์น้ำตาลดิบด้วยวิธี NAR เพิ่มเติมดังแสดงใน **Figure 7** ซึ่งแสดงค่าความผิดพลาดสัมพัทธ์ (Percent Error) รายเดือน พบว่า ผลการพยากรณ์มีค่าผิดปกติเกิดขึ้นในเกือบทุกๆ เดือนเว้นแต่เดือนกุมภาพันธ์และมีนาคม ซึ่งส่งผลให้การวัดความแม่นยำด้วยค่า MAPE นั้นมีค่าสูงตามไปด้วยเนื่องจากจะต้องใช้ในการหาค่าเฉลี่ยความผิดพลาดทั้งหมดนั่นเอง

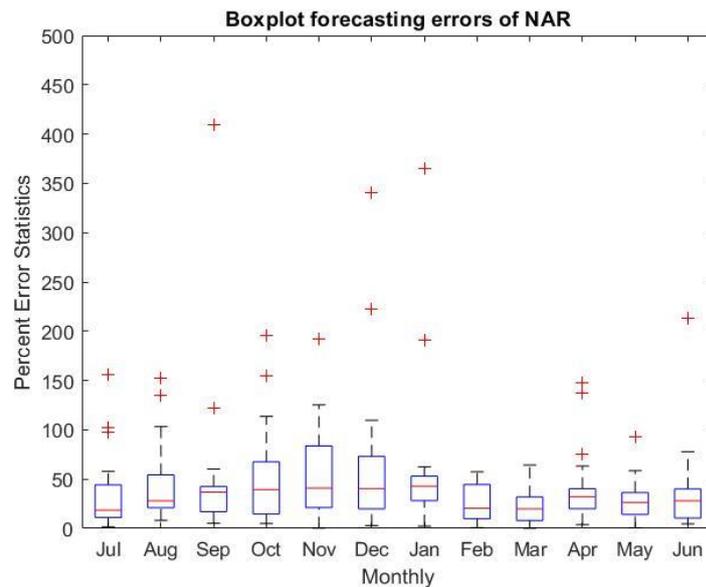


Figure 7 The monthly forecast error statistics of the raw sugar export volumes by using NAR model

จากผลการประเมินประสิทธิภาพการพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบด้วยโครงข่าย NAR และ WNAR ที่ใช้ข้อมูลย้อนหลังในอดีต 6 ช่วงเวลา (6-Time lags) ที่ให้ผลลัพธ์ที่ค่อนข้างดีมีความแม่นยำ ดังนั้น งานวิจัยนี้ได้ขยายผลการพัฒนาตัวแบบพยากรณ์ด้วยการค้นหาว่าจะต้องใช้ข้อมูลย้อนหลังในอดีต (Time lags) จำนวนกี่ช่วงเวลาจึงจะมีความเหมาะสม โดยพัฒนาตัวแบบขึ้นจากช่วงของข้อมูลย้อนหลังในอดีตในการพยากรณ์ที่มีค่าตั้งแต่ 1 – 36 เดือน ดังนี้ จำนวน 1, 3, 6, 9, 12, 15, 18, 21, 24 และ 36 เดือน พร้อมทั้งเปรียบเทียบผลการพยากรณ์ระหว่างวิธี WNAR และ NAR โดยผลลัพธ์ที่ได้แสดงในตารางที่ 3 ผลการพยากรณ์ในแต่ละช่วงเวลาสำหรับข้อมูลชุดทดสอบ ซึ่งพบว่า จำนวนช่วงเวลาย้อนหลังในอดีตที่เหมาะสมในการพยากรณ์ส่งออกน้ำตาลทรายและน้ำตาลดิบด้วยโครงข่าย WNAR คือ 12 และ 9 เดือน ส่วนวิธี NAR จำนวนช่วงเวลาย้อนหลังที่เหมาะสม คือ 36 เดือน สำหรับสินค้าส่งออกน้ำตาลทั้งสองประเภท

Table 3 A comparison of results using the NAR and WNAR models with different forecasting horizons on the test set data

| Forecasting horizon | Sugar | | | | Raw Sugar | | | |
|---------------------|------------------|--------------|-----------------|-------------|------------------|--------------|--------------|-------------|
| | NAR | | WNAR | | NAR | | WNAR | |
| | RMSE | MAPE | RMSE | MAPE | RMSE | MAPE | RMSE | MAPE |
| 1 | 44,619.51 | 24.15 | 3,213.76 | 17.12 | 29,083.10 | 30.70 | 275.84 | 23.00 |
| 3 | 56,371.55 | 25.57 | 7,432.78 | 8.19 | 56,398.04 | 31.15 | 3,721.64 | 9.02 |
| 6 | 61,633.74 | 27.55 | 6,745.31 | 7.96 | 79,952.30 | 32.73 | 6,719.65 | 9.16 |
| 9 | 69,196.12 | 33.24 | 6,413.83 | 7.49 | 48,308.07 | 33.33 | 64.71 | 5.65 |
| 12 | 44,933.52 | 29.08 | 3,568.47 | 6.05 | 43,953.02 | 32.26 | 9,281.49 | 11.46 |
| 15 | 38,005.57 | 23.42 | 13,041.53 | 8.79 | 45,448.64 | 30.79 | 4,505.07 | 7.49 |
| 18 | 33,516.79 | 23.47 | 13,962.73 | 6.87 | 52,842.86 | 32.30 | 2,561.78 | 8.62 |
| 21 | 12,090.83 | 25.07 | 8,218.83 | 7.10 | 52,480.61 | 34.58 | 18,753.93 | 11.34 |
| 24 | 19,167.31 | 23.82 | 10,311.72 | 9.51 | 59,436.53 | 33.39 | 65.23 | 9.44 |
| 36 | 18,082.00 | 23.30 | 16,009.20 | 9.44 | 45,012.06 | 27.78 | 13,448.93 | 13.03 |

วิจารณ์

การพัฒนาและเปรียบเทียบตัวแบบพยากรณ์ปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบของประเทศไทยด้วยวิธี WNAR และ NAR โดยใช้ข้อมูลย้อนหลังในอดีต 6 เดือน ซึ่งวิธี WNAR ให้ผลลัพธ์ที่มีความแม่นยำกว่า และจากการขยายผลเพื่อทดสอบหาช่วงเวลาย้อนหลังในอดีตที่เหมาะสมนอกเหนือจาก 6 เดือน ก็ยังคงพบว่าวิธี WNAR ให้ผลลัพธ์ที่มีความแม่นยำกว่าที่ดีกว่าในการพยากรณ์และมีความแม่นยำที่ดีกว่าการใช้ข้อมูลย้อนหลังเพียงแค่ 6 เดือนเท่านั้น เนื่องจากกว่าวิธีที่นำเสนอที่ใช้การแปลงเวฟเล็ตเข้ามาช่วยรวมสามารถวิเคราะห์เพื่อหารูปแบบการเคลื่อนไหวและการเปลี่ยนแปลงของข้อมูลในแต่ละช่วงเวลาได้ดีกว่าวิธีการแบบดั้งเดิม โดยเฉพาะอย่างยิ่งผลการเปรียบเทียบรูปแบบพยากรณ์ที่ใช้ค่าย้อนหลังในอดีตจำนวนหลากหลายช่วงเวลาตั้งแต่ระยะสั้นไปจนถึงระยะปานกลาง (1, 3, 6, 9, 12, 15, 18, 21, 24 และ 36 เดือน) นั้นก็แสดงให้เห็นถึงประสิทธิภาพของการนำเวฟเล็ตเข้ามาประยุกต์ใช้ที่สามารถวิเคราะห์การเคลื่อนไหวของข้อมูลได้ดียิ่งขึ้น ซึ่งสอดคล้องกับข้อสรุปของงานวิจัยหลายๆ ชิ้นก่อนหน้านี้ที่แสดงให้เห็นว่าการประยุกต์ใช้การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมช่วยทำให้ตัวแบบพยากรณ์อนุกรมเวลามีประสิทธิภาพและมีความแม่นยำเพิ่มมากขึ้น (Li et al., 2020; Bento et al., 2019; Hamzaçebi et al., 2019; Mehdizadeh et al., 2019; Kummong & Supratid, 2019; Nourani & Farboundfam, 2019; Huang & Wang, 2018; Puchalsky et al., 2018; Wei et al., 2012) อย่างไรก็ตาม การพัฒนาตัวแบบพยากรณ์ในอนาคตอาจจะต้องมีการปรับปรุงในประเด็นการแบ่งข้อมูลด้วยวิธี K-fold cross-validation for time series และเนื่องด้วยข้อมูลมีลักษณะเป็น Stationary จึงควรมีการประยุกต์ใช้วิธีการทางสถิติอื่นๆ เช่น ARMA, ARMAX, GARCH เป็นต้น เข้ามาประยุกต์ร่วมกับวิธี NAR และ WNAR เพื่อปรับปรุงให้ตัวแบบมีความแม่นยำเพิ่มสูงขึ้น

สรุป

บทความนี้นำเสนอผลการพัฒนาตัวแบบพยากรณ์ด้วยโครงข่ายประสาทเทียมมอดูลีเกรสซีฟไม่เชิงเส้นแบบเวฟเล็ตสำหรับปริมาณส่งออกน้ำตาลทรายและน้ำตาลดิบของประเทศไทย พร้อมทั้งเปรียบเทียบผลการพยากรณ์กับวิธีโครงข่ายประสาทเทียมมอดูลีเกรสซีฟไม่เชิงเส้น ซึ่งวิธีการที่พัฒนาขึ้นมาให้ความแม่นยำสูงในการพยากรณ์ โดยในการพยากรณ์ตัวแบบที่พัฒนาขึ้นมานั้นสามารถทำการพยากรณ์ล่วงหน้าแบบหลายช่วงเวลา (multi-step-ahead forecasting) ทั้งแบบช่วงระยะสั้นและระยะยาวได้อีกด้วย ดังนั้น ตัวแบบที่นำเสนอจึงมีความเหมาะสมที่จะนำไปใช้เป็นเครื่องมือในการพยากรณ์ปริมาณส่งออกเพื่อให้หน่วยงานที่เกี่ยวข้องนำไปใช้ช่วยสนับสนุนการตัดสินใจในการกำหนดนโยบายและการบริหารจัดการใช้อุปทานอ้อยและน้ำตาลให้มีผลประโยชน์สูงสุด เช่น การวางแผนการเพาะปลูกและเก็บเกี่ยวอ้อย การผลิตน้ำตาลทรายและน้ำตาลดิบ และการจัดการด้านโลจิสติกส์ต่างๆ ที่เกี่ยวข้องต่อไป เพื่อตอบสนองต่อความต้องการของลูกค้าจากต่างประเทศได้อย่างมีประสิทธิภาพ ซึ่งจะช่วยเพิ่มศักยภาพในการแข่งขันให้กับสินค้าอ้อยและน้ำตาลของประเทศไทยต่อไป

เอกสารอ้างอิง

- เฉลิมพล จตุพร และ พัฒนา สุขประเสริฐ. 2559. ตัวแบบพยากรณ์ผลผลิตและปริมาณส่งออกยางพาราของประเทศไทย. แก่นเกษตร. 44(2): 219 – 228.
- บุญฤทธิ์ ชูประดิษฐ์ และเสาวภา ชัยพิทักษ์. 2561. ตัวแบบพยากรณ์ปริมาณการส่งออกมะม่วงของประเทศไทย. วารสารมหาวิทยาลัยนเรศวร: วิทยาศาสตร์และเทคโนโลยี. 26(2): 74 – 85.
- บองชูโคร. แหล่งข้อมูล : <http://www.bonsucro.com> ค้นเมื่อ 11 เมษายน 2563.
- วรางคณา กิรติวิบูลย์. 2557. การพยากรณ์ปริมาณการส่งออกยางคอมปาวด์. วารสารวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ. 30(2): 41 – 56.
- วรางคณา เรียนสุทธิ และน้ำอ้อย นิสัน. 2560. การพยากรณ์ปริมาณการส่งออกไก่แปรรูป. วารสารมหาวิทยาลัยนเรศวร: วิทยาศาสตร์และเทคโนโลยี. 25(2): 140 – 152.

- สำนักงานคณะกรรมการอ้อยและน้ำตาล. 2562. รายงานพื้นที่ปลูกอ้อยปีการผลิต 2561/2562. แหล่งข้อมูล: <http://www.ocsb.go.th/upload/journal/fileupload/923-9040.pdf> ค้นเมื่อ 11 เมษายน 2563.
- สำนักงานเศรษฐกิจการเกษตร. แหล่งข้อมูล: <http://www.oae.go.th> ค้นเมื่อ 21 มีนาคม 2563.
- Başer, U., M. Bozoğlu, N.A. Eroğlu, and B.K. Topuz. 2018. Forecasting chestnut production and export of Turkey using ARIMA model. *Turkish Journal of Forecasting*. 2(2): 27 – 33.
- Benmouiza, K. and A. Cheknane. 2016. Small-scale solar radiation forecasting using ARMA and nonlinear autoregressive neural network models. *Theoretical and Applied Climatology*. 124: 945 – 958.
- Bento, P.M.R., J.A.N. Pombo, M.R.A. Calado, and S.J.P.S Mariano. 2019. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting. *Neurocomputing*. 358: 53 – 71.
- Hamzaçebi, C., H. Avni Es, and R. Çakmak. 2019. Forecasting of Turkey's monthly electricity demand by seasonal artificial neural network. *Neural Computing & Applications*. 31: 2217 – 2231.
- Huang, L. and J. Wang. 2018. Forecasting energy fluctuation model by wavelet decomposition and stochastic recurrent wavelet neural network. *Neurocomputing*. 309: 70 – 82.
- Jallal, M.A., A. González-Vidal, A.F. Skarmeta, S. Chabaa, and A. Zeroual. 2020. A hybrid neuro-fuzzy inference system-based algorithm for time series forecasting applied to energy consumption prediction. *Applied Energy*. 268: 114977.
- Khosravi, A., L. Machado, and R.O. Nunes. 2018. Time-series prediction of wind speed using machine learning algorithms: A case study Osorio wind farm, Brazil. *Applied Energy*. 224: 550 – 566.
- Kummong, R. and S. Supratid. 2019. Long-term forecasting system using wavelet-nonlinear autoregressive neural network conjunction model. *Journal of Modeling in Management*. 14(4): 948 – 971.
- Li, R., P. Jiang, H. Yang, and C. Li. 2020. A novel hybrid forecasting scheme for electricity demand time series. *Sustainable Cities and Society*. 55, 102036, 11 pages.
- Mehdizadeh, S., F. Fathian, and J.F. Adamowski. 2019. Hybrid artificial intelligence-time series models for monthly streamflow modeling. *Applied Soft Computing*. 80: 873 – 887.
- Nourani, V. and N. Farboudfam. 2019. Rainfall time series disaggregation in mountainous regions using hybrid wavelet-artificial intelligence methods. *Environmental Research*. 168: 306 – 318.
- Puchalsky, W., G.T. Robeiro, C.P. da Veiga, R.Z. Freire, and L.S. Coelho. 2018. Agribusiness time series forecasting using wavelet neural networks and metaheuristic optimization: An analysis of the soybean sack price and perishable products demand. *International Journal of Production Economics*. 203: 174 – 189.
- Tealab, A., H. Hefny, and A. Badr. 2017. Forecasting of nonlinear time series using ANN. *Future Computing and Informatics Journal*. 2(1): 39 – 47.
- Wei, S., D. Zuo, and J. Song. 2012. Improving prediction accuracy of river discharge time series using a wavelet-NAR artificial neural network. *Journal of Hydroinformatics*. 14(4): 974 – 991.
- Zanotti, C., M., Rotiroti, S. Sterlacchini, G. Cappellini, L. Fumagalli, G.A. Stefania, M.S. Nannucci, B. Leoni, and T. Bonomi. 2019. Choosing between linear and nonlinear models and avoiding overfitting for short and long term groundwater level forecasting in a linear system. *Journal of Hydrology*. 578: 124015.