



FEAT JOURNAL

FARM ENGINEERING AND AUTOMATION TECHNOLOGY JOURNAL

วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ

## รูปแบบการจัดการสินค้าคงคลังที่อาศัยวิธีการเรียนรู้ของเครื่องสำหรับพยากรณ์ความต้องการในอุตสาหกรรมตะแกรงเหล็กไวร์เมช

### Inventory Management Approach Based on Machine Learning Model for Demand Forecasting in the Steel Wire Mesh Industry

นนทพัทธ์ สุกolkit<sup>1)</sup> ศิรวดี อรัญนารต<sup>1)</sup> และ อาทิตย์ อภิโชติธนกุล<sup>1, 2)\*</sup>Nonthaphat Sukolkit<sup>1)</sup> Sirawadee Arunyanart<sup>1)</sup> and Arthit Apichottanakul<sup>1, 2)\*</sup><sup>1)</sup> ศูนย์วิจัยห่วงโซ่อุปทานและระบบโลจิสติกส์ สาขาวิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น<sup>2)</sup> สาขาวิชาเทคโนโลยีระบบการผลิตและการจัดการอุตสาหกรรม คณะเทคโนโลยี มหาวิทยาลัยขอนแก่น<sup>1)</sup> Supply Chain and Logistics System Research Unit, Department of Industrial Engineering, Faculty of Engineering, Khon Kaen University<sup>2)</sup> Department of Production System Technology and Industrial Management, Faculty of Technology, Khon Kaen University

Received: 29 February 2024

Revised: 23 April 2024

Accepted: 23 April 2024

Available online: 26 June 2024

#### บทคัดย่อ

ปัจจุบันการจัดการสินค้าคงคลังมีบทบาทสำคัญต่อความสำเร็จและความยั่งยืนของธุรกิจ อีกทั้งความต้องการและราคาเหล็กในปัจจุบันมีความผันผวนเป็นอย่างมาก ส่งผลให้งานวิจัยนี้มีวัตถุประสงค์เพื่อเสนอการจัดการสินค้าคงคลัง โดยอาศัยการพยากรณ์ยอดขายตะแกรงเหล็กไวร์เมช โดยทำการพยากรณ์สามวิธี ได้แก่ Holt-Winters, Random Forest และ XGBoost และใช้การแบ่งข้อมูลออกเป็นชุดเรียนรู้และชุดทดสอบ โดยแบ่งเป็นสองอัตราส่วน จากการเปรียบเทียบพบว่าวิธี Random Forest ให้ค่าความแม่นยำในการพยากรณ์สูงสุดที่อัตราส่วน 90:10 โดยมีค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย 4.50 เมื่อได้แบบจำลองการพยากรณ์ที่มีความ

แม่นยำแล้ว จึงนำข้อมูลความต้องการเข้ารูปแบบทางคณิตศาสตร์เพื่อวางแผนนโยบายสินค้าคงคลังแบบ (Q, r) และกำหนดนโยบายการสั่งซื้อวัสดุดิบ โดยเป็นการกำหนดการสั่งซื้อที่ประหยัดที่สุดและจุดสั่งซื้อใหม่เพื่อให้ต้นทุนในการบริหารจัดการสินค้าต่ำที่สุด ผลจากรูปแบบทางคณิตศาสตร์พบว่าสามารถลดต้นทุนรวมของโรงงานในการวางแผนการจัดการนโยบายสินค้าคงคลังได้ถึงร้อยละ 4.75 และต้นทุนที่ได้จากข้อมูลการพยากรณ์ได้มีความใกล้เคียงกับค่าข้อมูลจริง

**คำสำคัญ:** นโยบายสินค้าคงคลัง การสั่งซื้อที่ประหยัดที่สุด จุดสั่งซื้อใหม่ การพยากรณ์ การเรียนรู้ของเครื่อง

### Abstract

Nowadays, inventory management plays an important role in the success and sustainability of a business. Moreover, the current demand and price of steel fluctuate significantly. As a result, the objective of this research is to propose inventory management based on the sales forecast of the steel wire mesh. It performed predictions using three methods: Holt-Winters, Random Forest, and XGBoost. The data were divided into a train set and a test set, with two ratios. From the comparison, it was found that the Random Forest method yielded the highest forecast accuracy at a ratio of 90:10 with a mean absolute percentage error of 4.50. After obtaining an accurate forecast model, the research incorporated demand data into mathematical models to plan inventory policies (Q, r) and determine raw material purchasing policies. It determined the most economical order quantity and re-ordering points for the minimum inventory management costs. The results from the mathematical model revealed that it is possible to reduce the overall cost of factory operations in inventory management planning by up to 4.75% and the costs obtained from the forecast data were close to the actual data values.

**Keywords:** Inventory policy: Economic order quantity: Reorder point: Forecasting: Machine learning

---

\*ติดต่อ: arthap@kku.ac.th

### 1. บทนำ

ปัจจุบันการจัดการสินค้าคงคลังมีบทบาทสำคัญต่อความสำเร็จและความยั่งยืนของธุรกิจในอนาคตหลากหลายรูปแบบ โดยใช้การจัดการระดับสินค้าคงคลังอย่างมีประสิทธิภาพ เพื่อให้ธุรกิจสามารถใช้ทรัพยากรให้เกิด

ประโยชน์สูงสุด ลดต้นทุนที่เกี่ยวข้องกับการมีสินค้าคงคลังที่สูงเกินไป นอกจากนี้ยังช่วยให้สามารถวางแผนการทำงานได้ดีขึ้น และช่วยลดความเสี่ยงในการเกิดของเสีย [1] โดยงานวิจัยนี้มีเป้าหมายในการจัดการสินค้าคงคลังโดยเฉพาะอย่างยิ่งวัสดุที่

เกี่ยวข้องกับเหล็ก ซึ่งเป็นหนึ่งในองค์ประกอบพื้นฐานสำหรับการก่อสร้าง การผลิต และโครงสร้างพื้นฐานหนึ่งในวัสดุที่นำเหล็กมาแปรรูปที่มีความน่าสนใจในปัจจุบัน คือ ตะแกรงเหล็กไวร์เมช (Steel wire mesh) [2] โดยเหล็กชนิดนี้เป็นองค์ประกอบที่สำคัญในการก่อสร้างถนน เป็นวัสดุที่ช่วยเสริมแรงและความมั่นคงให้กับพื้นผิวคอนกรีต และมักถูกนำไปประยุกต์ใช้ในงานต่างๆ เช่น การสร้างถนน สะพาน และเขื่อน โดยหน้าที่หลักของตะแกรงเหล็กไวร์เมช คือ ช่วยกระจายน้ำหนักในวัสดุที่นำไปเสริมแรง ซึ่งสามารถช่วยลดอาการแตกร้าวและการเกิดความล้าของวัสดุได้ อีกทั้งยังช่วยยืดอายุการใช้งานของถนนและลดค่าใช้จ่ายในการบำรุงรักษา นอกจากนี้ยังช่วยให้กระบวนการก่อสร้างเร็วขึ้นอีกด้วย

อย่างไรก็ตามความต้องการและราคาเหล็กในปัจจุบันกลับมีความผันผวนอย่างมาก ซึ่งอาจเกิดจากปัจจัยต่างๆ รวมถึงภาวะทางเศรษฐกิจโดยเฉพาะอย่างยิ่งในประเทศกำลังพัฒนาที่มีแนวโน้มต่อความต้องการเหล็กที่เพิ่มสูงขึ้น [1] ส่งผลให้การคาดการณ์ความต้องการมีความจำเป็นอย่างมาก เนื่องจากเป็นวิธีที่จะช่วยให้ผู้ประกอบการสามารถวางแผนและจัดสรรทรัพยากรได้อย่างมีประสิทธิภาพ

การตอบสนองของความต้องการของลูกค้าโดยที่สามารถควบคุมต้นทุนให้ต่ำได้ เป็นปัจจัยที่สามารถสร้างความได้เปรียบในภาคอุตสาหกรรม โดยการมีวัตถุดิบหรือสินค้าคงคลังให้น้อยที่สุด เนื่องจากการมีวัตถุดิบหรือสินค้าคงคลังจะก่อให้เกิดต้นทุนทั้งในด้านการดูแลวัตถุดิบหรือสินค้า รวมถึงต้นทุนอื่นๆ ที่เกี่ยวข้องกับถือครองวัตถุดิบหรือสินค้า การจัดการระบบสินค้าคงคลังเป็นอีกหนึ่งสิ่งๆ ที่อุตสาหกรรมส่วน

ใหญ่ให้ความสำคัญเป็นอันดับต้นๆ เนื่องจากอุตสาหกรรมในปัจจุบันเกิดความไม่แน่นอนจากปัจจัยต่างๆ บ่อยครั้ง ไม่ว่าจะเป็นความไม่แน่นอนของเครื่องจักร แรงงาน แหล่งวัตถุดิบ และที่สำคัญที่สุดคือ ความไม่แน่นอนของความต้องการของลูกค้า อย่างไรก็ตามเพื่อให้สามารถตอบสนองความต้องการของลูกค้าได้ทันเวลา จึงทำให้สินค้าคงคลังสำรองมีบทบาทอย่างมาก แต่การจัดเก็บสินค้าคงคลังสำรองที่มีมากเกินไป อาจทำให้เกิดค่าใช้จ่ายในการจัดเก็บวัตถุดิบหรือสินค้า

จากความสำคัญที่กล่าวมาข้างต้นส่งผลให้ผู้วิจัยทำการศึกษาวิธีการวางแผนนโยบายการสั่งซื้อวัตถุดิบสำหรับอุตสาหกรรมตะแกรงเหล็กไวร์เมช โดยเริ่มจากการประยุกต์ใช้วิธีการพยากรณ์ต่างๆ ที่มีความแม่นยำเพื่อพยากรณ์ยอดขาย และทำการสร้างรูปแบบทางคณิตศาสตร์ในการวางแผนการสั่งซื้อวัตถุดิบให้เหมาะสมเพื่อลดต้นทุนรวมในการสั่งซื้อวัตถุดิบ การศึกษานี้ใช้วิธีการพยากรณ์อนุกรมเวลาแบบไม่แปรผัน (Univariate time series forecasting) เพื่อคาดการณ์ความต้องการของตะแกรงเหล็กไวร์เมชสำหรับบริษัทผลิตตะแกรงเหล็กในประเทศไทย โดยใช้วิธี Holt-Winters, Random Forest และ XGBoost เพื่อเปรียบเทียบประสิทธิภาพการพยากรณ์แต่ละวิธี รวมถึงใช้การแบ่งชุดข้อมูลการเรียนรู้และการทดสอบ จากนั้นวัดประสิทธิภาพของแบบจำลองการพยากรณ์โดยใช้การวัดผล 2 ค่า ได้แก่ รากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) และค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) จากนั้นนำข้อมูลที่พยากรณ์ได้จากแบบจำลองที่มีความ

แม่นยำที่สุดไปใช้ในการวางแผนการสั่งซื้อวัตถุดิบเพื่อกำหนดปริมาณในการสั่งซื้อในแต่ละครั้งและจุดในการสั่งซื้อใหม่ โดยใช้รูปแบบทางคณิตศาสตร์กำหนดนโยบายสินค้าคงคลังแบบ (Q, r) และหาค่าที่เหมาะสมที่สุด (Optimization) เพื่อให้ได้ต้นทุนรวมของนโยบายการสั่งซื้อต่ำที่สุด

## 2. งานวิจัยที่เกี่ยวข้อง

จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่า ริระพงษ์ และคณะ รวมไปถึง ธีรย์ชนกและอมรินทร์ ได้ศึกษาวิธีการพยากรณ์ยอดขายสินค้าแช่แข็งและยางซิลิโคนตามลำดับ โดยเปรียบเทียบประสิทธิภาพของวิธีการพยากรณ์ จากนั้นใช้ข้อมูลที่ได้จากการพยากรณ์กำหนดจำนวนในการสั่งซื้อวัตถุดิบโดยพิจารณาจากต้นทุนต่าง ๆ [3],[4] กุลบัณฑิต และคณะ มีเป้าหมายในลดต้นทุนสินค้าคงคลังโดยใช้วิธีการพยากรณ์แบบอนุกรมเวลา เพื่อหาปริมาณการสั่งซื้อที่ประหยัด จุดสั่งซื้อซ้ำในการควบคุมต้นทุนสินค้าคงคลัง และลดปริมาณสินค้าเสื่อมสภาพ [5] Koo และคณะ Sugiarto และคณะ รวมไปถึง Makatjane และ Moroke ใช้ Holt-Winters เพื่อคาดการณ์ปริมาณไฟฟ้าและยอดขายในระยะสั้น โดยงานวิจัยเหล่านี้แสดงให้เห็นถึงความสามารถของ Holt-Winters ในการคาดการณ์ ซึ่งสามารถช่วยปรับปรุงการวางแผนการจัดการและการตัดสินใจ [6-8] โดยวิธี Holt-Winters สามารถใช้งานได้ดีในชุดข้อมูลขนาดเล็กถึงขนาดกลางที่มีฤดูกาลหรือรูปแบบของข้อมูลชัดเจน อย่างไรก็ตาม ในปัจจุบันการพยากรณ์ด้วยวิธีทางสถิติเป็นวิธีการที่ต้องอาศัยความรู้ความเข้าใจและความชำนาญอย่างมากในการเลือกใช้วิธีการพยากรณ์ให้เหมาะสม หากขาดความเชี่ยวชาญจะ

ส่งผลให้ไม่สามารถนำการพยากรณ์ไปใช้งานได้อย่างมีประสิทธิภาพ ส่งผลให้ผู้วิจัยจำนวนมากหันมาใช้วิธีการเรียนรู้ของเครื่อง (Machine learning) เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ข้อมูล เนื่องจากการแจกแจงของข้อมูลและการถูกรบกวนของข้อมูลไม่มีผลต่อการพยากรณ์ ส่งผลให้บางวิธีมีความแม่นยำและความยืดหยุ่นสูงกว่าการใช้วิธีทางสถิติทั่วไป

Costas และคณะ รวมถึง Ledmaoui และคณะ ใช้วิธี Random Forest และ XGBoost ในการพยากรณ์การใช้ไฟฟ้าในแต่ละพื้นที่และการผลิตพลังงานจากเซลล์แสงอาทิตย์ตามลำดับ ผลจากการศึกษาเหล่านี้แสดงให้เห็นถึงประสิทธิภาพในการพยากรณ์ที่มีความน่าสนใจ [9],[10] Nasser และคณะ พบแนวทางในการประเมินประสิทธิภาพที่ใช้วิธีต้นไม้ตัดสินใจ (Decision Tree) เป็นพื้นฐาน ในการพยากรณ์ช่วงของข้อมูลที่แตกต่างกัน เช่น การพยากรณ์ระยะสั้น ระยะกลาง และระยะยาว [11] Jnr และ Ziggah ใช้ข้อมูลความต้องการรายชั่วโมงสำหรับการพยากรณ์ความต้องการไฟฟ้าโดยใช้วิธี Random Forest และวัดผลโดยใช้รากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ย และค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย [12] Kabir และคณะ ได้เปรียบเทียบวิธีการพยากรณ์หลายวิธีรวมถึง Random Forest เพื่อคาดการณ์และเพิ่มประสิทธิภาพการผลิต จากผลการเปรียบเทียบพบว่า Random Forest เป็นวิธีที่เหมาะสมที่สุดในการคาดการณ์ [13] จากงานวิจัยของ Akande และคณะ รวมไปถึง Zhu และคณะ ได้ทำการศึกษาการใช้ XGBoost สำหรับคาดการณ์ยอดขาย และความต้องการอะไหล่รถยนต์ตามลำดับ โดยผลลัพธ์ที่ได้จากรากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยและ

ค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย พบว่าวิธี XGBoost สามารถใช้คาดการณ์ยอดขายและความต้องการขึ้นส่วนอะไหล่ได้อย่างมีประสิทธิภาพ [14],[15] XGBoost เป็นแบบจำลองการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงและถูกใช้กันอย่างแพร่หลาย อย่างไรก็ตามการปรับไฮเปอร์พารามิเตอร์มีความสำคัญต่อประสิทธิภาพในการพยากรณ์เป็นอย่างมาก [16] วิกิแกนส์ และคณะ สร้างแบบจำลองการบำรุงรักษาเชิงคาดการณ์ของเครื่องยนต์อากาศยานด้วยวิธี XGBoost และเปรียบเทียบประสิทธิภาพในการคาดการณ์ความเสียหายของเครื่องยนต์อากาศยาน [17] ปวีริศ และพิศิษฐ์ ได้พัฒนาต้นแบบการพยากรณ์โดยใช้วิธี XGBoost เพื่อเพิ่มประสิทธิภาพในการขนส่งสินค้า [18]

การพยากรณ์ยอดขายที่มีความแม่นยำและถูกต้องเป็นเป้าหมายที่สำคัญสำหรับการวางแผนที่ต้องอาศัยการตัดสินใจ และมีความเสี่ยงมาเกี่ยวข้อง ยกตัวอย่างเช่น วางแผนการสั่งซื้อวัตถุดิบ วางแผนการผลิต วางแผนการขนส่ง เป็นต้น หากการพยากรณ์มีค่าที่ถูกต้องแม่นยำส่งผลให้เกิดความได้เปรียบในการแข่งขันทางธุรกิจในอนาคต จากงานของ เมอร์ริภา และธัญภัส พบว่าบริษัทผู้ผลิตเหล็กสำหรับการก่อสร้าง เกิดปัญหาในกระบวนการสั่งซื้อวัตถุดิบ จึงมีวัตถุประสงค์เพื่อกำหนดปริมาณการสั่งซื้อที่ประหยัดที่สุดของวัตถุดิบ จากผลการวิจัยพบว่าการใช้รูปแบบการสั่งซื้อที่เหมาะสมสามารถลดต้นทุนรวมได้ [1] พัชรา และเชษฐา ได้ศึกษาการจัดการวัตถุดิบคงคลังของบริษัทกรณีศึกษาเพื่อหาปริมาณการสั่งซื้อที่ประหยัดที่สุด และการกำหนดจุดสั่งซื้อใหม่ที่ส่งผลให้เกิต้นทุนรวมต่ำที่สุด [19] ชูลีกร

Istiningrum และคณะ รวมถึง จิรายุ และปวีณา ได้ศึกษาการพยากรณ์ปริมาณความต้องการของบรรจุภัณฑ์ของกาแฟ และธุรกิจค้าวัสดุก่อสร้างตามลำดับ โดยหาปริมาณการสั่งซื้อที่ประหยัดที่สุดและจุดสั่งซื้อใหม่ เพื่อเป็นแนวทางในการตัดสินใจในการสั่งซื้อวัตถุดิบได้อย่างเหมาะสม [20-22] ธีระพงษ์ และคมกฤษ ได้พยากรณ์ความต้องการของลูกค้า และสร้างแบบจำลองระดับคงคลังเป้าหมายในการกำหนดระดับสินค้าคงคลังที่เหมาะสม หลังจากนำค่าพยากรณ์เข้ามากำหนดนโยบายสินค้าคงคลัง พบว่าสามารถลดการจุกเก็บสินค้าคงคลังจากเดิมได้ และหากพิจารณาถึงต้นทุนการจุกเก็บ สามารถลดต้นทุนได้เช่นกัน โดยไม่ก่อผลให้เกิดภาวะการขาดส่งสินค้า [23]


### 3. วิธีการวิจัย

งานวิจัยนี้สามารถแบ่งขั้นตอนการวิจัยได้เป็น 2 ส่วน ส่วนแรก คือ การพยากรณ์ความต้องการตะแกรงเหล็กไวร์เมชโดยใช้วิธีต่างๆ ส่วนที่สอง คือ กำหนดนโยบายการสั่งซื้อวัตถุดิบ การพยากรณ์ข้อมูลในงานนี้ใช้วิธีการพยากรณ์ที่หลากหลาย ได้แก่ Holt-Winters, Random Forest และ XGBoost วิธีการเหล่านี้มีจุดแข็งและการใช้งานที่แตกต่างกัน สามารถจัดการกับข้อมูลในรูปแบบที่หลากหลายและนำไปประยุกต์ใช้กับข้อมูลอนุกรมเวลาโดยเฉพาะ โดยเริ่มต้นจากการเลือกแบบจำลองการพยากรณ์ที่มีความแม่นยำสูงที่สุด ทำการเขียนชุดคำสั่งโดยใช้ภาษา Python ผ่านโปรแกรม Google colab จากนั้นวางแผนนโยบายการสั่งซื้อวัตถุดิบโดยใช้รูปแบบทางคณิตศาสตร์เพื่อกำหนดนโยบายสินค้าคงคลังแบบ (Q, r) โดยใช้ฟังก์ชัน Solver ในโปรแกรม

Microsoft Excel มีสมการเป้าหมายคือ ต้นทุนรวมของนโยบายการสั่งซื้อต่ำที่สุด โดยเป็นการกำหนดปริมาณการสั่งซื้อในแต่ละครั้ง และระดับการให้บริการโดยพิจารณาถึงต้นทุนวัตถุดิบ ต้นทุนการถือครองสินค้า ต้นทุนการขนส่ง ต้นทุนคงที่ และค่าปรับจากการขาดส่งเป็นต้น

3.1. การเก็บรวบรวมข้อมูลและการเตรียมข้อมูล

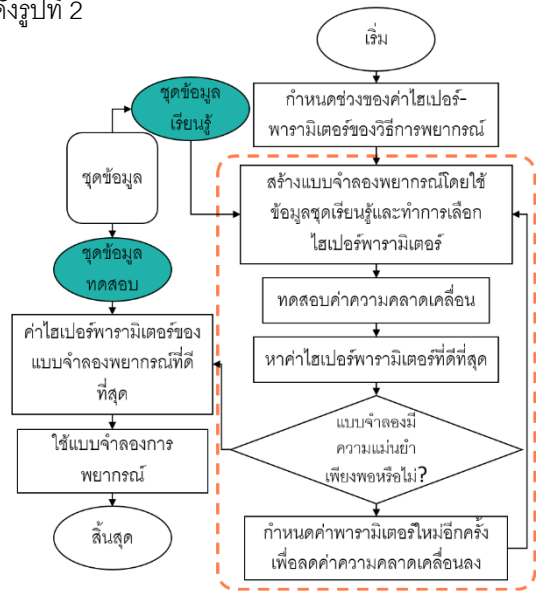
งานวิจัยนี้ใช้ข้อมูลยอดขายตะแกรงเหล็กไวร์เมชของบริษัทแห่งหนึ่งในประเทศไทย โดยเป็นข้อมูลย้อนหลังตั้งแต่เดือนมกราคม พ.ศ. 2566 ถึงเดือนพฤษภาคม พ.ศ. 2566 ซึ่งเป็นข้อมูลยอดขายตะแกรงเหล็กไวร์เมชรวมโดยน้ำหนัก อย่างไรก็ตามงานวิจัยนี้ได้ทำการแบ่งข้อมูล ออกเป็นข้อมูลการเรียนรู้ (Train) และข้อมูลการทดสอบ (Test) โดยแยกเป็นอัตราส่วนได้แก่ 80:20 และ 90:10 ดังรูปที่ 1 จากนั้นใช้กระบวนการล้างข้อมูล (Clean data) เพื่อจัดการกับข้อมูลที่ผิดปกติและไม่ถูกต้อง วัตถุประสงค์ของกระบวนการนี้ คือ เพื่อแก้ไขข้อมูลที่ได้รับความเสี่ยงจากนั้นได้กำหนดข้อมูลในการคำนวณต้นทุนที่ใช้ในการวางแผนนโยบายการสั่งซื้อวัตถุดิบ



รูปที่ 1 การแบ่งชุดข้อมูลการเรียนรู้และชุดข้อมูลทดสอบ

3.2. การสร้างแบบจำลองการพยากรณ์

งานวิจัยนี้ใช้วิธีการพยากรณ์ต่างๆ ดังที่ได้กล่าวไปข้างต้น โดยวิธีเหล่านี้มีจุดแข็งและการใช้งานที่ต่างกัน ทำให้สามารถใช้วิธีการเหล่านี้ในการจัดการกับรูปแบบการพยากรณ์กับข้อมูลอนุกรมเวลา โดยผังงานในการสร้างแบบจำลองการพยากรณ์ ดังรูปที่ 2



รูปที่ 2 วิธีการในการสร้างแบบจำลองการพยากรณ์

3.2.1. Holt-Winters

วิธี Holt-Winters หรือที่รู้จักกันในชื่อ Triple exponential smoothing เป็นวิธีที่ใช้กันทั่วไปในการพยากรณ์ข้อมูลอนุกรมเวลาที่ข้อมูลมีแนวโน้ม และฤดูกาลชัดเจน โดยใช้ค่าปรับให้เรียบสามค่า ได้แก่  $\alpha$   $\beta$  และ  $\gamma$  มีค่าอยู่ระหว่าง 0 ถึง 1 โดยที่  $\alpha$  เป็นตัวปรับน้ำหนักของระดับ  $\beta$  เป็นตัวปรับน้ำหนักของแนวโน้ม และ  $\gamma$  เป็นตัวปรับน้ำหนักของฤดูกาล โดยสมการหลักของวิธีการนี้เป็นไปดังสมการที่ (1) และประกอบด้วยสมการย่อยดังสมการที่ (2)-(4) โดย

แบบจำลองการพยากรณ์จะทำการปรับค่าตัวแปรต่างๆ ให้เข้ากับค่าข้อมูลที่ใช้ในการเรียนรู้ โดยใช้การประมาณการแนวโน้มวิเคราะห์ระดับ และคำนวณองค์ประกอบตามฤดูกาลด้วยค่าเบี่ยงเบนเฉลี่ย วิธีนี้จึงมีความสามารถในการจับรูปแบบที่ซับซ้อนได้อย่างมีประสิทธิภาพ และทำให้วิธีนี้มีศักยภาพในการนำไปใช้ในการพยากรณ์ในข้อมูลรูปแบบต่าง ๆ

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

$$l_t = \alpha (y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1} \quad (3)$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-m} \quad (4)$$

โดยที่  $y_t$  คือ ข้อมูลจริง ณ เวลา  $t$ ,  $l_t$  คือ ค่าประมาณการของระดับ ณ เวลา  $t$ ,  $s_t$  คือ ค่าประมาณการของฤดูกาล ณ เวลา  $t$ ,  $b_t$  คือ ค่าประมาณการของแนวโน้ม ณ เวลา  $t$ ,  $l_{t-1}$  และ  $b_{t-1}$  คือ ค่าประมาณการของระดับและแนวโน้ม ณ เวลาก่อนหน้า ตามลำดับ,  $s_{t-m}$  คือ ส่วนประกอบตามฤดูกาล ณ เวลา  $t$  ปรับตามระดับ  $\alpha$   $\beta$  และ  $\gamma$  พารามิเตอร์สำหรับการปรับให้เรียบของ ระดับ แนวโน้ม และฤดูกาล ตามลำดับ,  $h$  คือ ช่วงเวลาที่ต้องการพยากรณ์

### 3.2.2. Random Forest

Random Forest เป็นแบบจำลองที่นำวิธีต้นไม้ตัดสินใจหลายต้นมาเรียนรู้ร่วมกัน (ตั้งแต่ 10 ต้นหรืออาจมากกว่า 1,000 ต้น) โดยที่ต้นไม้ตัดสินใจเป็นแบบจำลองแบบมีเงื่อนไข (Rule based) โดยไม่มีสมการมากำกับความสัมพันธ์ ต้นไม้ตัดสินใจแต่ละแบบใน Random Forest ถือเป็นแบบจำลองที่มีความแม่นยำไม่สูงมากนัก (Weak learner) แต่เมื่อนำต้นไม้ตัดสินใจจำนวนหลายต้นมาทำการเรียนรู้

ร่วมกัน จะได้แบบจำลองรวมที่มีความแม่นยำมากกว่าแบบจำลองต้นไม้ตัดสินใจแบบต้นเดียว โดยหลักการของ Random Forest เป็นการแบ่งข้อมูลจากชุดข้อมูลทั้งหมดให้ได้ข้อมูลออกมาจำนวน  $n$  ชุด ที่ไม่เหมือนกัน ตามจำนวนต้นไม้ตัดสินใจใน Random Forest ที่กำหนด ระหว่างการพยากรณ์ต้นไม้ตัดสินใจแต่ละต้นทำการพยากรณ์ในแบบจำลองของตัวเอง และเลือกผลการพยากรณ์สุดท้ายด้วยการใช้ผลการลงคะแนนที่ถูกเลือกจากต้นไม้ตัดสินใจมากที่สุด เมื่อแบบจำลองเป็นการจำแนกประเภทหรือ Classification หรือใช้การหาค่าเฉลี่ยจากผลลัพธ์ของต้นไม้ตัดสินใจเมื่อเป็นแบบจำลองการถดถอยหรือ Regression ข้อดีของวิธีการนี้คือสามารถใช้ได้กับข้อมูลที่มีโครงสร้างชัดเจน (ข้อมูลลักษณะเป็นแถวหรือเป็นตาราง) และข้อมูลที่ไม่มีโครงสร้างชัดเจน (เช่น รูปภาพหรือตัวหนังสือ) อีกทั้งยังทำการปรับไฮเปอร์พารามิเตอร์ (Hyper-parameter tuning) ได้ง่ายและเกิดการจดจำมากกว่าเรียนรู้หรือที่เรียกว่า Overfitting

### 3.2.3. eXtreme Gradient Boosting

XGBoost มีหลักการคล้ายกับวิธี Random Forest เป็นการเรียนรู้แบบหลายแบบจำลองเรียนรู้ร่วมกันหรือ Multiple learners เป็นแบบจำลองที่นำวิธีต้นไม้ตัดสินใจมาเรียนรู้ต่อเนื่องกัน โดยที่ต้นไม้ตัดสินใจแต่ละต้นจะเรียนรู้จากค่าความผิดพลาดของต้นก่อนหน้า ทำให้ความแม่นยำในการพยากรณ์สูงขึ้น เมื่อมีการเรียนรู้ของแบบจำลองต่อเนื่องจนมีความลึกมากพอ และแบบจำลองจะหยุดเรียนรู้ต่อเมื่อไม่เหลือรูปแบบ (Pattern) ของค่าความผิดพลาดจากแบบจำลองก่อนหน้าให้เรียนรู้แล้ว สำหรับการเรียนรู้

สามารถแบ่งวิธีการเป็น 3 ตัว ดังนี้ Bagging, Boosting และ Stacking

- Bagging: คือการสร้างตัวเรียนรู้หลายตัว และให้แต่ละตัวเรียนรู้ชุดข้อมูลย่อยของข้อมูลทั้งหมด จากนั้นทำการลงคะแนนให้แบบจำลอง และพิจารณาว่าเสียงส่วนมากหรือหาค่าเฉลี่ยเพื่อพิจารณาว่าแบบจำลองควรตอบคำตอบอย่างไร

- Boosting: คือการเรียนรู้แบบเป็นลำดับโดยตัวเรียนรู้ก่อนหน้าเรียนรู้ แล้วนำข้อผิดพลาดของตัวเรียนรู้มาปรับปรุงตัวเรียนรู้ต่อไปเพื่อลดค่าความคลาดเคลื่อนจากตัวเรียนรู้ก่อนหน้า ส่งผลให้แบบจำลองมีความแม่นยำที่สูงกว่าวิธี Bagging (ลดความลำเอียง) แต่อาจทำให้เกิด Overfitting ของแบบจำลองได้ง่าย

- Stacking: มีหลักการคล้ายกับ Boosting แต่มีการแบ่งแบบจำลองเรียนรู้จำนวนหลายกลุ่ม แล้วนำข้อมูลทั้งหมดให้แบบจำลองเรียนรู้ชุดแรกเรียน จากนั้นนำคำตอบของแบบจำลองเรียนรู้ชุดแรกมารวมกัน และส่งต่อไปให้แบบจำลองเรียนรู้ต่อไปมาเรียนรู้ต่อเนื่องกัน

XGBoost เป็นการรวมวิธีย่อย 3 วิธีที่ได้กล่าวไปข้างต้น ส่งผลให้มีความสามารถเพิ่มสูงขึ้นและมีความน่าสนใจ ยกตัวอย่างเช่น สามารถลดการเกิด Overfitting ของแบบจำลอง และสามารถจัดการกับข้อมูลที่ขาดหายได้แบบอัตโนมัติเป็นต้น

### 3.3 การวัดผลแบบจำลองการพยากรณ์

ในงานนี้ผู้วิจัยใช้การวัดผลของวิธีการพยากรณ์โดยวัดค่าความคลาดเคลื่อนจากราคาที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยและค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย ดังสมการที่ (5) และ (6) ตามลำดับ

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6)$$

โดยที่  $n$  คือ จำนวนข้อมูล,  $y_i$  คือ ข้อมูลจริง ณ เวลา  $i$  และ  $\hat{y}_i$  คือ ข้อมูลการพยากรณ์ ณ เวลา  $i$

### 3.4 การประยุกต์ใช้รูปแบบทางคณิตศาสตร์

ในงานวิจัยนี้เลือกใช้รูปแบบทางคณิตศาสตร์สำหรับวางแผนนโยบายสินค้าคงคลังแบบ (Q, r) เพื่อกำหนดนโยบายการสั่งซื้อวัตถุดิบ โดยเป็นการกำหนดการสั่งซื้อที่ประหยัดที่สุดและจุดสั่งซื้อใหม่ มีเป้าหมายในการลดต้นทุนการดำเนินงานให้ต่ำที่สุด โดยใช้รูปแบบทางคณิตศาสตร์ มีสัญลักษณ์และตัวแปรที่เกี่ยวข้อง ดังนี้

ตารางที่ 1

ตัวแปร	คำอธิบาย	ค่าของตัวแปร
$D$	ความต้องการเฉลี่ยในหนึ่งช่วงเวลา (Mean demand)	ค่าจากการพยากรณ์
$sd_D$	ค่าส่วนเบี่ยงมาตรฐานของความ ต้องการเฉลี่ยในหนึ่งช่วงเวลา (S.D. in demand)	ค่าจากการพยากรณ์
$L$	ระยะเวลาการรอคอยวัตถุดิบในหนึ่งช่วงเวลา (Lead time)	0.47 เดือน
$sd_L$	ค่าส่วนเบี่ยงมาตรฐานของระยะเวลาการรอคอยวัตถุดิบในหนึ่งช่วงเวลา (S.D. in lead time)	0.05 เดือน
$K$	ต้นทุนคงที่สำหรับการสั่งซื้อ โดยไม่คำนึงถึงปริมาณในการสั่งซื้อ (Fixed cost)	300,000 บาท/ครั้ง
$P$	ค่าปรับต่อหนึ่งหน่วยสินค้าเมื่อเกิดการขาดส่ง (Penalty cost)	70 บาท/ก.ก.



<i>H</i>	ต้นทุนการถือครองต่อหนึ่งหน่วย สินค้าในหนึ่งช่วงเวลา (Holding cost)	20 บาท/ ก.ก.
<i>HP</i>	ต้นทุนการถือครองต่อหนึ่งหน่วย สินค้าในหนึ่งช่วงเวลา ขณะการ ขนส่ง (Holding cost on pipeline)	20 บาท/ ก.ก.
<i>CM</i>	ต้นทุนการซื้อต่อหนึ่งหน่วยสินค้า (Purchase cost)	35 บาท/ ก.ก.
<i>TC</i>	ต้นทุนการขนส่งต่อหนึ่งหน่วย สินค้า (Transport cost)	3 บาท/ก.ก.

**สมการเป้าหมาย (Objective function)**

$$MIN = C_{Total}$$

โดยที่

$$โดยที่ C_{Total} = C_{ORD} + C_{CYC} + C_{SFT} + C_{PEN} + C_{PIPE} + C_{PURCH} + C_{TRANS}$$

*C<sub>ORD</sub>* คือ ต้นทุนคงที่สำหรับการสั่งซื้อแต่ละครั้ง

$$โดยที่ C_{ORD} = (K * \frac{D}{Q})$$

*C<sub>CYC</sub>* คือ ต้นทุนการถือครองสินค้า

$$โดยที่ C_{CYC} = H * \frac{Q}{2}$$

*C<sub>SFT</sub>* คือ ต้นทุนการถือครองสินค้าคงคลังขั้นต่ำ

$$โดยที่ C_{SFT} = H * (R - MLD + b(r))$$

*C<sub>PEN</sub>* คือ ค่าปรับเมื่อเกิดการขาดส่ง

$$โดยที่ C_{PEN} = P * D * \frac{b(r)}{Q}$$

*C<sub>PIPE</sub>* คือ ต้นทุนการถือครองสินค้าขณะการขนส่ง

$$โดยที่ C_{PIPE} = HP * MLD$$

*C<sub>PURCH</sub>* คือ ต้นทุนการซื้อสินค้า

$$โดยที่ C_{PURCH} = D * CM$$

*C<sub>TRANS</sub>* คือ ต้นทุนการขนส่ง

$$โดยที่ C_{TRANS} = TC * D$$

**ตัวแปร (Variables)**

*MLD* คือ ความต้องการที่เกิดขึ้นขณะอยู่ในระยะการ  
รอคอยวัตถุดิบ

$$MLD = L * D$$

*sd<sub>0</sub>* คือ ค่าส่วนเบี่ยงมาตรฐานของความต้องการใน  
ช่วงเวลาการรอคอยวัตถุดิบ

$$sd_0 = \sqrt{L * sd_D^2 + D^2 * sd_L^2}$$

*R* คือ จุดสั่งซื้อใหม่ โดยจะสั่งซื้อวัตถุดิบเมื่อสินค้าคง  
คลังรวมกับสินค้าขณะขนส่งลดลงต่ำกว่าจุดสั่งซื้อ  
ใหม่

$$R = MLD + sd_0$$

*SS* คือ สินค้าคงคลังขั้นต่ำ

$$SS = R - MLD$$

*F(r)* คือ ความน่าจะเป็นที่จะไม่ทำให้เกิดการขาดส่ง  
สินค้า หากจุดสั่งซื้อใหม่คือ *r*

$$F(r) = P * \frac{D}{P * D + H * Q} = F(Z);$$

*F(Z)* คือ ความน่าจะเป็นที่ตัวแปรจากการแจก  
แจงแบบปกติจะน้อยกว่าหรือเท่ากับ *Z* หรืออีกนัยหนึ่งคือ  
ระดับการให้บริการ

*b(r)* คือ จำนวนสินค้าที่คาดว่าจะเกิดการขาดส่ง  
ขณะรอคอยวัตถุดิบ หากจุดสั่งซื้อใหม่คือ *r*

$$b(r) = sd_0 * L((r - MLD)/sd_0) = sd_0 * L(Z);$$

*L(Z)* คือ ฟังก์ชันการสูญเสีย หรือจำนวนยอดขาย  
ที่คาดว่าจะเกิดการขาดส่ง

**ตัวแปรตัดสินใจ (Decision variables)**

*Q* คือ จำนวนการสั่งซื้อ ณ จุดสั่งซื้อ (Order quantity)

*Z* คือ ค่าคะแนนมาตรฐาน (Z score)

**สมการข้อจำกัด (Constraints)**

สมการข้อจำกัด 2 สมการนี้เป็นสมการที่ช่วยให้  
สามารถแก้ปัญหาทางคณิตศาสตร์ได้รวดเร็วขึ้น

$Q$  เริ่มหาปริมาณการสั่งซื้อจากสมการที่คำนวณได้

$$\text{โดยที่ } Q \geq \sqrt{2 * K * D/H}$$

$Z$  กำหนดให้หาค่า  $Z$  อยู่ระหว่าง -3 ถึง 3

$$\text{โดยที่ } -3 \leq Z \leq 3$$

#### 4. ผลการวิจัยและอภิปราย

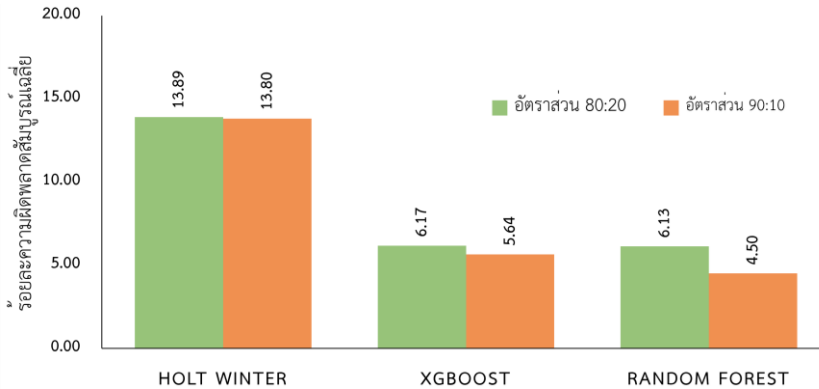
ในงานวิจัยนี้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์สามวิธีได้แก่ Holt-Winters, Random Forest และ XGBoost และใช้วิธีการแบ่งข้อมูลเป็นชุดการเรียนรู้และชุดทดสอบ โดยแบ่งออกเป็น 2 อัตราส่วน ได้แก่ 80:20 และ 90:10 ได้ผลการเปรียบเทียบดังรูปที่ 3 เป็นการเปรียบเทียบความแม่นยำของทุกวิธีและทุกอัตราส่วนด้วยค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย โดยนำข้อมูลที่ได้จากแบบจำลองการพยากรณ์มาเปรียบเทียบกับชุดข้อมูลทดสอบ ในทำนองเดียวกันตารางที่ 2 เป็นการแสดงรากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยและค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย โดยแสดงเป็นตัวเลขโดยตรงเพื่อให้ง่ายต่อการเปรียบเทียบ

ผลการเปรียบเทียบแบบจำลองการพยากรณ์แสดงให้เห็นว่าวิธี Random Forest ให้ผลการพยากรณ์ดีที่สุด ในทั้งสองอัตราส่วน ผลของรากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยและค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ยมีแนวโน้มไปในทิศทางเดียวกัน คือที่อัตราส่วน 90:10 ให้ผลที่มีความแม่นยำสูงกว่า 80:20 โดยวิธี Random Forest มีความแม่นยำสูงสุดที่อัตราส่วน 90:10 ให้ค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ยเท่ากับ 4.50 และให้รากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยเท่ากับ 493,172 อย่างไรก็ตามวิธี Holt-Winters ให้ผลที่ตรงข้ามกัน คือที่อัตราส่วน 80:20 ให้ค่าร้อยละความผิดพลาดสัมบูรณ์

เฉลี่ยที่ต่ำกว่าอัตราส่วน 90:10 แต่ในรากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยอัตราส่วน 90:10 กลับให้ผลที่ดีกว่า โดยที่ Holt-Winters ที่อัตราส่วน 90:10 ให้รากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยเท่ากับ 439,172 และวิธี Holt-Winters ที่ 80:20 มีค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ยสูงสุดโดยมีค่าอยู่ที่ 13.89 อย่างไรก็ตามวิธี XGBoost กลับให้ค่าความคลาดเคลื่อนที่สูงกว่าวิธี Random Forest ซึ่งอาจเกิดจากแบบจำลองไม่สามารถเรียนรู้ชุดข้อมูลชุดนี้ได้ดีเท่าวิธี Random Forest

จากผลการเปรียบเทียบทั้งสามวิธีสามารถสรุปได้ว่าวิธี Random Forest ให้ผลที่ดีที่สุด และการแบ่งข้อมูลการเรียนรู้ที่อัตราส่วน 90:10 ให้ผลที่ดีกว่า 80:20 เล็กน้อยในทุกวิธีการ โดยพบว่าอัตราส่วนของข้อมูลที่ใช้ในการเรียนรู้และการทดสอบส่งผลต่อความแม่นยำของการพยากรณ์ โดยหากมีข้อมูลที่มากเพียงพอจะส่งผลให้แบบจำลองมีความแม่นยำสูงขึ้นสำหรับผลของรูปแบบทางคณิตศาสตร์ในงานวิจัยนี้ผู้วิจัยได้จำลองเหตุการณ์เพื่อทำการเปรียบเทียบ โดยสามารถแบ่งได้เป็น 2 กรณี

**กรณีที่ 1** เป็นการเปรียบเทียบต้นทุนรวมระหว่างการคำนวณต้นทุนโดยใช้ความต้องการจริงร่วมกับรูปแบบทางคณิตศาสตร์เปรียบเทียบกับการคำนวณต้นทุนโดยใช้ความต้องการจริง



รูปที่ 3 การเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์

ตารางที่ 2

การเปรียบเทียบแบบจำลองการพยากรณ์

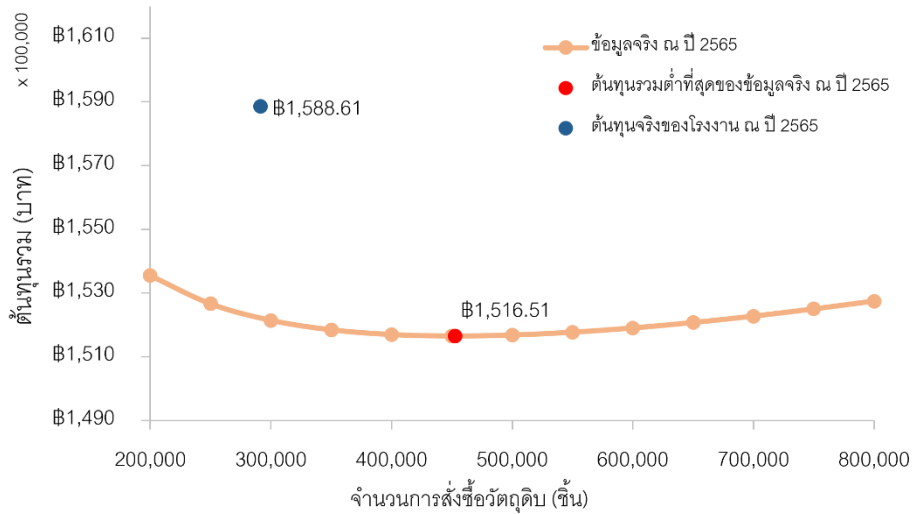
ค่าวัดประสิทธิภาพ	วิธีการพยากรณ์	อัตราส่วน 80:20	อัตราส่วน 90:10
รากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ย (RMSE)	Holt-Winters	425,972	439,172
	XGBoost	249,051	212,644
	Random Forest	248,483	149,372
ค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย (MAPE)	Holt-Winters	13.89	13.80
	XGBoost	6.17	5.64
	Random Forest	6.13	4.50

โดยเป็นการคำนวณต้นทุนที่โรงงานกรณีศึกษาใช้ในปัจจุบัน โดยที่ต้นทุนรวมก่อนการใช้รูปแบบทางคณิตศาสตร์มีค่าเท่ากับ 158,860,596 บาท/ปี และหลังจากใช้รูปแบบทางคณิตศาสตร์มีค่าเท่ากับ 151,651,418 บาท/ปี จากการเปรียบเทียบพบว่าหลังจากใช้รูปแบบทางคณิตศาสตร์สามารถลดต้นทุนรวมได้ถึงร้อยละ 4.75 ดังรูปที่ 4

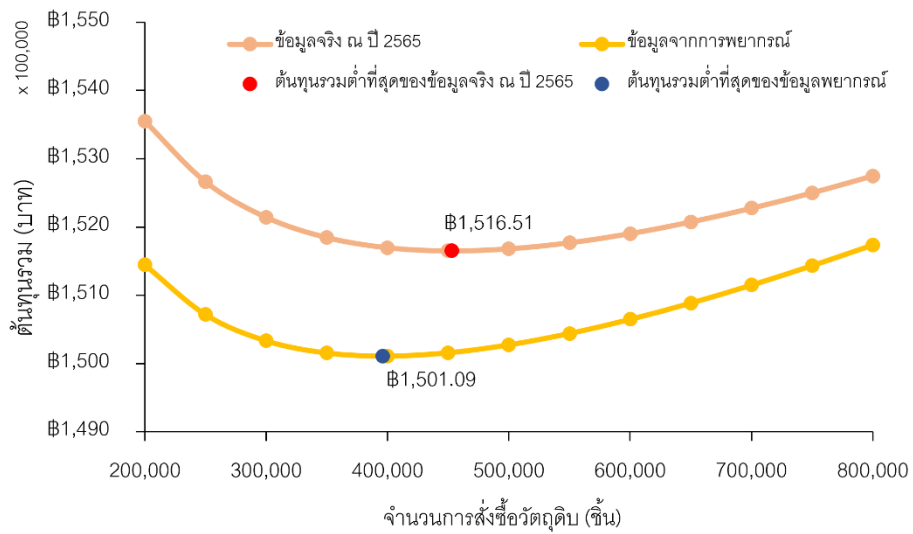
ซึ่งความแตกต่างนี้เกิดจากต้นทุนที่คำนวณจากรูปแบบทางคณิตศาสตร์สามารถยอมให้เกิดการขาดส่งสินค้าได้ โดยมีระดับการให้บริการอยู่ที่ร้อยละ

96.14 และมีปริมาณการสั่งซื้อต่อครั้งอยู่ที่ 452,790 กิโลกรัม

กรณีที่ 2 เป็นการเปรียบเทียบต้นทุนรวมเมื่อใช้รูปแบบทางคณิตศาสตร์กับข้อมูลความต้องการจริง ปี 2565 และข้อมูลที่ได้จากการพยากรณ์ของปี 2565 จากรูปที่ 5 พบว่าต้นทุนระหว่างข้อมูลจริงและข้อมูลพยากรณ์สามารถนำมาเป็นแนวทางในการวางแผนการสั่งซื้อสินค้าในอนาคตได้ เนื่องจากค่าที่ได้จากการพยากรณ์เมื่อนำไปเปรียบเทียบกับค่าจริงนั้นมีค่าใกล้เคียงกัน โดยมีแตกต่างเพียงร้อยละ 1.02



รูปที่ 4 การเปรียบเทียบต้นทุนรวมจากรูปแบบทางคณิตศาสตร์เทียบกับต้นทุนในปัจจุบัน



รูปที่ 5 การเปรียบเทียบต้นทุนรวมจากรูปแบบทางคณิตศาสตร์เทียบกับข้อมูลจริง ณ ปี 2565

## 5. สรุปผลการวิจัย

การศึกษานี้มุ่งเน้นไปที่การประยุกต์ใช้รูปแบบทางคณิตศาสตร์เพื่อวางแผนการสั่งซื้อวัตถุดิบ โดยอาศัยการพยากรณ์ยอดขายโดยใช้วิธีการพยากรณ์ที่ไม่แปรผันเพื่อสร้างแบบจำลองการพยากรณ์ โดยเฉพาะการพยากรณ์อนุกรมเวลาโดยใช้วิธี Holt-Winters, Random Forest และ XGBoost เพื่อปรับปรุงการวางแผนการสั่งซื้อวัตถุดิบ งานนี้ใช้ข้อมูลยอดขายในอดีตจากผู้ผลิตตะแกรงเหล็กไวร์เมชในประเทศไทย โดยได้เปรียบเทียบวิธีการพยากรณ์และใช้การแบ่งข้อมูลสำหรับเรียนรู้แบบจำลอง จากนั้นทำการวัดประสิทธิภาพโดยใช้รากที่สองของความผิดพลาดกำลังสองเฉลี่ยและค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ย ผลลัพธ์แสดงให้เห็นว่าวิธี Random Forest ที่อัตราส่วน 90:10 ให้ผลลัพธ์ที่ดีที่สุด และจากผลการเปรียบเทียบพบว่า ที่อัตราส่วน 80:20 ของวิธีการพยากรณ์ทั้งหมดให้ค่าร้อยละความผิดพลาดสัมบูรณ์เฉลี่ยต่ำสุด หลังจากได้แบบจำลองการพยากรณ์ที่มีความแม่นยำ จึงนำข้อมูลความต้องการเข้ารูปแบบทางคณิตศาสตร์เพื่อวางแผนนโยบายสินค้าคงคลังแบบ (Q, r) และกำหนดนโยบายการสั่งซื้อวัตถุดิบ โดยเป็นการกำหนดการสั่งซื้อที่ประหยัดที่สุดและจุดสั่งซื้อใหม่ ผลจากรูปแบบทางคณิตศาสตร์พบว่า หลังจากใช้รูปแบบทางคณิตศาสตร์สามารถลดต้นทุนรวมในการวางแผนการสั่งซื้อวัตถุดิบได้ถึงร้อยละ 4.75 และเมื่อนำค่าที่ได้จากการพยากรณ์ไปเปรียบเทียบกับค่าจริงในปีเดียวกัน พบว่าต้นทุนรวมมีค่าใกล้เคียงกัน โดยมีความคลาดเคลื่อนเพียงร้อยละ 1.02 ซึ่งผลจากรูปแบบทางคณิตศาสตร์สามารถลด

ต้นทุนรวมของโรงงานได้ และต้นทุนที่ได้จากข้อมูลการพยากรณ์ได้มีความใกล้เคียงกับค่าข้อมูลจริง

## 6. เอกสารอ้างอิง

- [1] เฉอรรร์ภา คุ่มถนอม และ ธัญภัส เมืองบัน. ปริมาณการสั่งซื้อวัตถุดิบหลักที่เหมาะสมกรณีศึกษา บริษัทผลิตเหล็กแท่งและเหล็กเส้น ก่อสร้าง. วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธนบุรี. 2564; 5(1): 1-11.
- [2] Grand View Research. Steel Wire Market Size, Share & Trends Analysis Report By Material (Carbon Steel, Stainless Steel, Alloy Steel), By Application, By Region, And Segment Forecasts, 2022 – 2030. (สืบออนไลน์). [เข้าถึงเมื่อ วันที่ 10 มกราคม 2567]. เข้าถึงได้จาก <https://www.grandviewresearch.com/industry-analysis/steel-wire-market-report/>.
- [3] วีระพงษ์ ทับพร ยอดนภา เกษเมือง เอกพล ทับพร และ ภาครดิษฐ์ แปงจิตต์. การพยากรณ์ยอดขายและการบริหารสินค้าคงคลัง ของสินค้าทางหมักยักซ์แซ่แข็ง : บริษัทสยามแม็คโคร จำกัด มหาชน. วารสารวิชาการมหาวิทยาลัยธนบุรี (วิทยาศาสตร์และเทคโนโลยี). 2561; 2(2): 28-41.

- [4] ถิ่นยั้งนิก จันท์ และ อมรินทร์ เทวตา. การพยากรณ์แบบอนุกรมเวลาเพื่อกำหนดการสั่งซื้อที่ประหยัดที่สุดของโรงงานผลิตยางซิลิโคนแห่งหนึ่ง. วารสารวิทยาลัยโอดิซติคส์และซัพพลายเชน. 2565; 8(2): 28-49.
- [5] กุลบัณฑิต แสงดี อภัสรา นภัทระวี และ ศิริมาพร เจริญในวงศ์เฝ้า. การลดต้นทุนสินค้าคงคลังผ้าแก้วพลาสติกชนิดเรียบรหัส 85 กรณีศึกษา โรงงานบรรจุภัณฑ์พลาสติก. วารสารมนุษยศาสตร์และสังคมศาสตร์ วไลยอลงกรณ์ ในพระบรมราชูปถัมภ์. 2565; 12(2): 189-204.
- [6] Koo B, Kim M, Kim K, Lee H, Park J, Kim C. Short- term electric load forecasting using data mining technique. In 2013 7th International Conference on Intelligent Systems and Control (ISCO). 2013; 153-157.
- [7] Sugiarto V, Sarno R, Sunaryono D. Sales forecasting using Holt-Winters in Enterprise Resource Planning at sales and distribution module. In 2016 International Conference on Information & Communication Technology and Systems (ICTS). 2016; 8-13.
- [8] Makatjane K, Moroke N. Comparative study of holt-winters triple exponential smoothing and seasonal Arima: forecasting short term seasonal car sales in South Africa. Risk governance & control: financial markets & institutions 2016; 6(1).
- [9] Costas M, Villanueva D, Eguía-Oller P, Comesaña M, Ramos S. Load forecasting with machine learning and deep learning methods. Applied Sciences. 2023; 13(13): 7933.
- [10] Ledmaoui Y, Maghraoui A, Aroussi M, Saadane R, Chebak A, Chehri A. Forecasting solar energy production: A comparative study of machine learning algorithms. Energy Reports. 2023; 10: 1004-1012.
- [11] Nasserri M, Falatouri T, Brandtner P, Darbanian F. Applying Machine Learning in Retail Demand Prediction— A Comparison of Tree- Based Ensembles and Long Short- Term Memory-Based Deep Learning. Applied Sciences. 2023; 13(19): 11112.
- [12] Jnr E, Ziggah Y. Electricity demand forecasting based on feature extraction and optimized backpropagation neural network. e-Prime-Advances in Electrical Engineering, Electronics and Energy. 2023; 6: 100293.
- [13] Kabir M, Roy S, Alam F, Nam S, Im K, Tijing L, Shon H. Machine learning-based prediction and optimization of green hydrogen production

- technologies from water industries for a circular economy. *Desalination*. 2023; 567: 116992
- [14] Akande Y, Idowu J, Misra A, Misra S, Akande O, Ahuja R. Application of XGBoost Algorithm for Sales Forecasting Using Walmart Dataset. In *International Conference on Advances in Electrical and Computer Technologies*. 2021; 147-159.
- [15] Zhu Q, Yang L, Liu Y. Research on vehicle spare parts demand forecast based on XGBoost- LightGBM. In *Proceedings of the 2023 5th International Conference on Pattern Recognition and Intelligent Systems*. 2023; 109-114.
- [16] Tran N, Tran T, Nguyen T, Lam M. A new grid search algorithm based on XGBoost model for load forecasting. *Bulletin of Electrical Engineering and Informatics*. 2023; 12(4): 1857-1866.
- [17] วิรากานต์ กิตติบวรกุล ศรายุทธ นนท์ศิริ และ พิชิตชัย คำอินทร์. การเปรียบเทียบประสิทธิภาพเทคนิคการเรียนรู้ของเครื่องสำหรับการบำรุงรักษาเชิงคาดการณ์สำหรับเครื่องยนต์อากาศยาน. *วารสารวิชาการสมาคมสถาบันอุดมศึกษาเอกชนแห่งประเทศไทย*. 2565; 11(1): 1-14.
- [18] ปวีริศ เวชวรรณกิจกุล และ พิศิษฎ์ จารุมณีโรจน์. การพยากรณ์ระยะเวลาการเดินทางด้วยวิธีการเรียนรู้ของเครื่อง โดยใช้ข้อมูลจากพาดหนะ และโทรศัพท์มือถือในจังหวัดกรุงเทพมหานคร. *วารสารไทยการวิจัยดำเนินงาน*. 2565; 10(2): 54-62.
- [19] พัชรา ศรีพระบุ และ เชษฐา ชำนาญหล่อ. การหาปริมาณการสั่งซื้อน้ำมันเชื้อเพลิงอย่างประหยัด: กรณีศึกษาบริษัท รับขนส่งสินค้า. *วารสารวิชาการและวิจัย มทร.พระนคร*. 2565; 16(2): 54-64.
- [20] ชุติกร ชูโชติถาวร. การพยากรณ์และการหาปริมาณการสั่งซื้อที่เหมาะสม เพื่อเป็นแนวทางในการจัดเก็บบรรจุภัณฑ์สำหรับการผลิต กรณีศึกษาบริษัทแปรรูปผลิตภัณฑ์การเกษตร จังหวัดพัทลุง. *วารสารเครือข่ายส่งเสริมการวิจัยทางมนุษยศาสตร์และสังคมศาสตร์*. 2563; 3(3): 92-108.
- [21] จิรายุ ฤทธิแสง และ ปวีณา กองจันทร์. ความยืดหยุ่นในการประยุกต์ใช้ปริมาณการสั่งซื้อที่ประหยัดที่สุดและจุดสั่งซื้อใหม่: กรณีศึกษารูทริกค้าวัสดุก่อสร้างขนาดกลาง. *วารสารวิจัยมหาวิทยาลัยขอนแก่น (ฉบับบัณฑิตศึกษา) สาขามนุษยศาสตร์และสังคมศาสตร์*. 2560; 5(1): 92-104.
- [22] Istiningrum A, Sono S, Putri V. Inventory Cost Reduction and EOQ for Personal Protective Equipment: A Case Study in Oil and Gas Company. *Jurnal Logistik Indonesia*. 2021; 5(2): 86-103.

- [23] วีระพงษ์ ชูมณี และ คมกฤษ ปิติฤกษ์. การประยุกต์ใช้ปัญญาประดิษฐ์กับการพยากรณ์สินค้าในอุตสาหกรรมเครื่องดื่ม. วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ. 2565; 8(2): 88-98.