



FEAT JOURNAL

FARM ENGINEERING AND AUTOMATION TECHNOLOGY JOURNAL

วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ

การประยุกต์ใช้ปัญญาประดิษฐ์กับการพยากรณ์สินค้าในอุตสาหกรรมเครื่องดื่ม Application of Artificial Intelligence to Product Forecasting in an Beverage Industry

ธีระพงษ์ ชูมณี^{1)*} และ คมกฤษ ปิติฤกษ์²⁾Terapong Chumanee^{1)*} and Komkrit Pitiruek²⁾¹⁾ สาขาวิชาวิศวกรรมนวัตกรรม คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น²⁾ สาขาวิชาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น¹⁾ Program of Innovation Engineering, Faculty of Engineering, Khon Kaen University, Khon Kaen, Thailand²⁾ Department of Industrial Engineering, Faculty of Engineering, Khon Kaen University, Khon Kaen, Thailand

Received: 23 March 2022

Revised: 20 May 2022

Accepted: 22 June 2022

Available online: 23 December 2022

บทคัดย่อ

งานวิจัยนี้ได้นำเสนอเกี่ยวกับ การสร้างแบบการพยากรณ์ความต้องการและการกำหนดนโยบายสินค้าคงคลังที่เหมาะสมโดยนำข้อมูลการขายสินค้า 3 ปี ย้อนหลังตั้งแต่ ปี 2561-2663 มาพิจารณาถึงความเหมาะสมการกำหนดหรือจัดเก็บสินค้าคงคลังโดยใช้เทคโนโลยีปัญญาประดิษฐ์ในรูปแบบเทคนิคโครงข่ายประสาทเทียม (Artificial Neural Networks) ในการพยากรณ์ความต้องการของลูกค้า หลังจากนั้นได้ทำการสร้างตัวแบบจำลองระดับคงคลังเป้าหมาย (Order Up to Level Model : OUL) ในการกำหนดระดับสินค้าคงคลังที่เหมาะสมเพื่อเพิ่มประสิทธิภาพและประสิทธิผลสินค้าคงคลังในการลดต้นทุนในการบริหารจัดการสินค้าได้ ซึ่งผู้วิจัยพบว่าจากการทดสอบการนำเทคนิคโครงข่ายประสาทเทียมมาพยากรณ์สินค้าให้ค่าแม่นยำสูงโดยใช้การวัดค่าความคลาดเคลื่อน Root Mean Squared Error (RMSE) สำหรับสินค้าเบียร์ขนาด 620 มิลลิลิตร (CC 620 ml.) ให้ค่า RMSE เท่ากับ 0.1137 และสุราขนาด 700 มิลลิลิตร (BL 700 ml.) เท่ากับ 12.3654 ซึ่งหากค่าผลลัพธ์ค่า RMSE น้อยจะส่งผลให้ค่าพยากรณ์มีความแม่นยำยิ่งขึ้น หลังจากนั้นได้นำค่าพยากรณ์ที่ได้จากโมเดลการพยากรณ์

นำเข้ามากำหนดนโยบายสินค้าคงคลัง โดยพบว่าสามารถลดการจัดเก็บสินค้าคงคลังจากเดิมได้ถึง 40.84% ของการจัดเก็บสินค้าคงคลังแบบเดิมและหากพิจารณาถึงต้นทุนการจัดเก็บสามารถลดต้นทุนได้ถึง 280,278 บาทต่อเดือน โดยไม่ก่อผลให้เกิดภาวะสินค้าขาดมือทำให้สูญเสียโอกาสทางการขายได้

คำสำคัญ: การพยากรณ์ ปัญญาประดิษฐ์ โครงข่ายประสาทเทียม การจัดการสินค้าคงคลัง

Abstract

The purposes of this study were to represent the process of making the forecasting model and the appropriate setting of inventory management policy. The 3-years retrospective selling data from 2018 to 2020 were analyzed by artificial intelligence (AI) in Artificial Neural Networks (ANN) to predict the need of customer and then set up the Order Up to Level Model (OUL) to make proper inventory level management methods for increasing the efficiency while decreasing the cost of product and inventory cost. We found that the test using ANN to predict the product demands resulted in high accurate as Root Mean Squared Error (RMSE) criteria. As the results, it indicated that, for example, CC 620 ml provided RMSE of 0.1137 comparing to that of liquor BL 700 ml. which is 12.3654. The less of RMSE value, the more precision of forecasting result using this method. After obtained the results, we used these results as an input the inventory policy setting. Consequently, the percentage of inventory storage was decreased by 40.84% compared to the existing method. In the cost saving aspect, the storage cost was approximately reduced by 280,278 baht monthly without confronting the inventory shortage problem that causes the opportunity loss.

Keywords: Forecasting Model: Artificial Intelligence: Artificial Neuron Network: Inventory Management

*ติดต่อ: E-mail: tanterapong@gmail.com

1. บทนำ

ปัจจุบันแนวโน้มในการแข่งขันทางธุรกิจในตลาดอุตสาหกรรมเครื่องดื่มมีการแข่งขันค่อนข้างสูงจากข้อมูลในตลาดเครื่องดื่มในปี 2560 จะเห็นได้ว่าตลาดเครื่องดื่มในประเทศไทยมีปริมาณการบริโภคสินค้ารวมกว่า 7,477 ล้านลิตร โดยแบ่งเป็นตลาดเครื่องดื่มไม่มีแอลกอฮอล์และเครื่องดื่มแอลกอฮอล์ สัดส่วน 72:28 คิดเป็นมูลค่าประมาณกว่า 5.7 แสนล้านบาทต่อปี ซึ่งในอนาคตมีแนวโน้ม

การขยายตัวและมีการแข่งขันอย่างรุนแรงทำให้ภาคอุตสาหกรรมเครื่องดื่มในปัจจุบันต้องมีการปรับตัวเพื่อให้ตอบสนองของความต้องการของผู้บริโภคให้รวดเร็วที่สุดในต้นทุนการบริหารจัดการที่ต่ำที่สุดและมีประสิทธิภาพประสิทธิผลสูงสุดในหลายๆ โดยการนำเทคโนโลยีเข้ามาใช้มีบทบาทในการดำเนินธุรกิจเพื่อเสริมสร้างศักยภาพในการแข่งขันทางธุรกิจส่งผลช่วยให้ธุรกิจมีการพัฒนาเติบโตอย่างต่อเนื่องในยุคปัจจุบัน ซึ่งการลงทุนเทคโนโลยีในการบริหารจัดการ

งานด้านโลจิสติกส์ถือเป็นหนึ่งอย่างที่หลาย ๆ บริษัทให้ความสำคัญและมีความจำเป็นอย่างมากในการนำเทคโนโลยีเข้ามาประยุกต์ใช้ในการบริหารจัดการ ตั้งแต่การจัดซื้อ การผลิต การจัดการสินค้าคงคลัง การขนส่ง การบริการลูกค้า เป็นต้นตลอดทั้งซัพพลายเชนจะเห็นได้ว่าในอุตสาหกรรมเครื่องดื่มนำเทคโนโลยีหลากหลายเข้ามาประยุกต์หลากหลายมิติเพื่อสร้างความได้เปรียบให้กับธุรกิจ ซึ่งปัจจุบันหนึ่งในเทคโนโลยีที่เริ่มเข้ามามีบทบาทที่สำคัญคือการนำเทคโนโลยีปัญญาประดิษฐ์เข้ามาเพื่อสร้างความได้เปรียบในตลาดได้ดี ปัจจุบันเทคโนโลยีปัญญาประดิษฐ์มีหลากหลายขึ้นอยู่กับข้อมูลหรือเงื่อนไขที่จะมาทำการทำนายผลลัพธ์ในอนาคตที่ให้ความเหมาะสมและแม่นยำมากที่สุดเช่น 1. Decision Tree เหมาะสำหรับจำแนกประเภทข้อมูล 2. Clustering เหมาะสำหรับการวิเคราะห์การจัดกลุ่ม 3. Artificial Neural Network เหมาะสำหรับแก้ปัญหาการพยากรณ์ต่าง ๆ ข้อมูลทางสถิติให้มีความถูกต้อง

การพยากรณ์หรือการทำนายความต้องการสินค้าในอนาคตที่ถูกต้องและแม่นยำถือเป็นจุดเริ่มต้นที่สำคัญที่จะใช้ในการวางแผนที่ส่งผลต่อการตัดสินใจ การบริหารความเสี่ยงในด้านต่าง ๆ ของธุรกิจตลอดทั้งห่วงโซ่อุปทานขององค์กรได้อย่างเช่น วางแผนผลิต วางแผนการจัดเก็บสินค้าคงคลัง วางแผนขนส่ง เป็นต้น หากการพยากรณ์มีถูกต้องแม่นยำจะส่งนำไปสู่ความได้เปรียบในการแข่งขันทางธุรกิจต่อไปในอนาคต(เอกจิตต์ จึงเจริญ.2560) ซึ่งในการพยากรณ์ด้วยวิธีทางสถิติเป็นวิธีการที่ใช้กันมาจนถึงในปัจจุบันมีหลากหลายรูปแบบ โดยผู้ที่ทำการพยากรณ์ทางสถิติจะต้องมีความรู้ความเข้าใจและความชำนาญอย่างมากเกี่ยวกับวิธีการเลือกใช้เทคนิคในการพยากรณ์ให้

เหมาะสมกับข้อมูลและหากขาดทักษะทางสถิติจะส่งผลทำให้ไม่สามารถนำข้อมูลไปใช้งานได้อย่างมีประสิทธิภาพ ดังนั้นทำให้ผู้วิจัยจำนวนมากเริ่มหันมาใช้เทคนิคโครงข่ายประสาทเทียม(Artificial Neural Network) เพื่อเพิ่มประสิทธิภาพในการพยากรณ์หรือการทำนายข้อมูลโดยที่โครงข่ายประสาทเทียมไม่สนใจว่าข้อมูลมีความแจ่มแจ้งอย่างไรข้อมูลมีปัจจัยหรือสิ่งรบกวนภายนอกอย่างไรบางวิธีนี้จึงมีความยืดหยุ่นและให้ค่าความแม่นยำสูงกว่าการใช้เทคนิคทางสถิติและทางคณิตศาสตร์ทั่วไปโดยโครงข่ายประสาทเทียมเป็นแบบจำลองทางคณิตศาสตร์ที่เลียนแบบการทำงานของโครงข่ายสมองมนุษย์ทำให้ผลที่แบบจำลองจะคล้ายคลึงกับการตัดสินใจของมนุษย์(บุษรา ลัมพิพัฒนางกูร.2549) ซึ่งผู้วิจัยจึงได้สนใจการนำเทคนิค Artificial Neural Network ซึ่งเป็นหนึ่งในเทคนิคด้านปัญญาประดิษฐ์ดังกล่าวนำมาประยุกต์ใช้กับการพยากรณ์การความต้องการสินค้าในอุตสาหกรรมเครื่องดื่มน โดยผู้วิจัยมองว่าหากมีการพยากรณ์การขายที่ดีจะส่งผลให้ทำให้สามารถลดต้นทุนการบริหารจัดการสินค้าคงคลังลงได้และยังสามารถตอบสนองความต้องการให้กับลูกค้าได้อย่างเหมาะสมและรวดเร็วซึ่งสร้างความได้เปรียบในธุรกิจได้ในอนาคต

ดังนั้นงานวิจัยจึงมีวัตถุประสงค์เพื่อการประยุกต์ปัญญาประดิษฐ์ในการพยากรณ์ยอดขายสินค้าและสร้างตัวแบบคณิตศาสตร์ในการจัดเก็บสินค้าให้เหมาะสมเพื่อลดต้นทุนในการบริหารจัดการสินค้าคงคลัง ซึ่งได้นำเสนอวิธีการพยากรณ์โดยนำเทคนิคโครงข่ายประสาทเทียมที่มีความสามารถในการเรียนรู้มาใช้ในการออกแบบจำลองการพยากรณ์ยอดขายสินค้า โดยใช้ข้อมูลจากการขายสินค้า

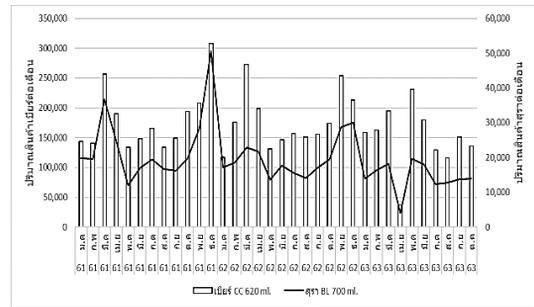
ย้อนหลัง 3 ปี ได้แก่ ข้อมูลยอดการขายสินค้าแบบรายเดือนและข้อมูลแบบรายปี เป็นต้น หลังจากนั้นได้ทำการสร้างตัวแบบจำลองระดับคงคลังเป้าหมาย (Order Up to Level Model : OUL) เพื่อกำหนดนโยบายระดับสินค้าคงคลังในการจัดเก็บสินค้าที่เหมาะสมเพื่อตอบสนองของความต้องการของลูกค้าต่อไปในอนาคต

2. วิธีการวิจัย

งานวิจัยนี้สามารถแบ่งออกเป็น 2 ส่วน ซึ่งได้แก่ การพยากรณ์ยอดขายสินค้าเครื่องดื่มโดยใช้เทคนิคโครงข่ายประสาทเทียมและนำผลลัพธ์จากการพยากรณ์ที่ให้ผลขาดเคลื่อนที่แม่นยำไปกำหนดนโยบายสินค้าคงคลังโดยมีขั้นตอนการดำเนินการดังต่อไปนี้

2.1. การเก็บรวบรวมข้อมูล

ปัจจุบันบริษัทกรณีศึกษามีการขายและจัดเก็บสินค้ามากกว่า 250 รายการโดยสามารถแบ่งเป็น 3 ประเภทได้แก่ กลุ่มสินค้าสุรา กลุ่มสินค้าเบียร์ และกลุ่มสินค้าไม่มีแอลกอฮอล์ ซึ่งหากพิจารณา ยอดการขายและยอดการจัดเก็บสินค้าจากทั้งหมดพบว่าสินค้าสุรา เบียร์ขนาด 620 มิลลิลิตร (CC 620 ml.) และสุราขนาด 700 มิลลิลิตร (BL 700 ml.) ซึ่งมีผลอย่างมากกับต้นทุนการจัดเก็บสินค้าที่มีสต็อกสินค้าค่อนข้างสูงดังนั้นผู้วิจัยจึงเริ่มพิจารณาทำการวิจัยกับรายการสินค้าดังกล่าวโดยการเก็บรวบรวมข้อมูลการขายสินค้าในอดีตย้อนหลัง 3 ปี ตั้งแต่ มกราคม พ.ศ.2561 ถึงเดือนธันวาคม พ.ศ.2563 ในฐานข้อมูลของบริษัทกรณีศึกษา ดังภาพที่ 1

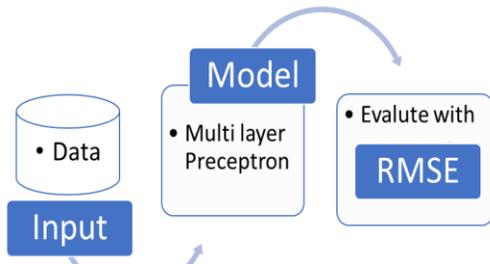


ภาพที่ 1 แสดงตัวอย่างข้อมูลการขายสินค้าเบียร์ขนาด 620 มิลลิลิตร และสุรา 700 มิลลิลิตรย้อนหลังตั้งแต่ปี 2561-2563

สำหรับข้อมูลที่ใช้ในการคำนวณต้นทุนบริหารจัดการคลังสินค้าซึ่งได้แก่ ค่าแรงงาน ค่าจัดเก็บ ค่าเช่า โฟล์คลิฟท์ (Forklift) และอื่นๆ โดยทางบริษัทกรณีศึกษาได้คิดค่าบริหารจัดการคลังสินค้าในอัตรา 8 บาทต่อพาเลทต่อวัน ตามนโยบายของบริษัทซึ่งจะนำไปคำนวณต้นทุนการจัดเก็บต่อไป

2.2. การดำเนินการทดลอง

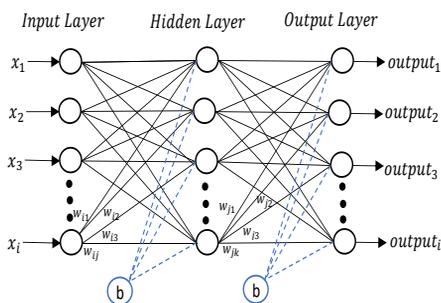
ในการทดสอบประสิทธิภาพของเทคนิคสำหรับการพยากรณ์ข้อมูลในงานวิจัยนี้โดยใช้โปรแกรม Weka (Waikato Environment For Knowledge Analysis) เป็นโปรแกรมที่ทำเหมืองข้อมูลที่นิยมใช้ในการศึกษาและวิจัย โดยการใช้นโยบายโครงข่ายประสาทเทียมในลักษณะ Multilayer Perceptron ในการศึกษาประสิทธิภาพขั้นตอนวิธีการเรียนรู้ สำหรับการพยากรณ์หรือทำนายข้อมูลในอนาคต (เอ ดีหลี่. 2560.) ผู้วิจัยได้นำข้อมูลในข้อ 2.1 เข้าโปรแกรมเพื่อสร้างตัวแบบสำหรับการพยากรณ์จากนั้นวัดประสิทธิภาพของเทคนิคการพยากรณ์ด้วย Root Mean Squared Error (RMSE) ของความคลาดเคลื่อน แสดงดังภาพที่ 2



ภาพที่ 2 ขั้นตอนการดำเนินการทดลอง

2.3 การสร้างแบบจำลองการพยากรณ์ โดยใช้วิธีโครงข่ายประสาทเทียม

ขั้นตอนนี้มีส่วนสำคัญมากกับผลลัพธ์ของการดำเนินงานวิจัย ดังนั้นผู้วิจัยต้องเลือกโมเดลที่มีความแม่นยำที่ดีที่สุดและค่าที่ได้ต้องผิดพลาดน้อยที่สุดซึ่งในการสร้างแบบจำลองการพยากรณ์จะใช้วิธีการโครงข่ายประสาทเทียมหรือเรียกว่า (Artificial Neural Networks) มาใช้ในการสร้างโมเดลในรูปแบบลักษณะ Multilayer Perceptron จะมีการรับข้อมูลขาเข้าจาก Training Set แล้วส่งต่อข้อมูลในชั้นถัดไปผ่านทางโครงข่ายที่กำหนดค่าถ่วงน้ำหนักไว้ในแต่ละเส้นทางเพื่อคำนวณหาผลลัพธ์ในแต่ละนิวรอลแสดงดังภาพที่ 3



ภาพที่ 3 แสดงโมเดลโครงข่ายประสาทเทียมในลักษณะ Multilayer Perceptron

โดยที่ X_i คือ ค่าของข้อมูลนำเข้าที่ i

w คือ ค่าของน้ำหนักระหว่างโหนด

i คือ จำนวนโหนดในชั้น Input Layer

j คือ จำนวนโหนดในชั้น Hidden Layer

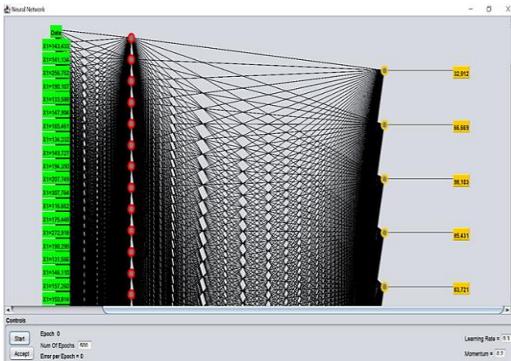
k คือ จำนวนโหนดในชั้น Output Layer

b คือ ค่าเบี่ยงเบน bias

กำหนดสมการเป้าหมาย แสดงดังสมการที่ (1)

$$k = \sum_{i=1}^n X_i * W_{ij} + b \quad (1)$$

โดยที่ k คือ ผลลัพธ์ของการพยากรณ์ และหลักการการทำงานของโครงข่ายประสาทเทียมเมื่อมีข้อมูลนำเข้า (Input) เข้ามายังโครงข่ายประสาทเทียม (Network) ก็นำ Input มาคูณกับค่าน้ำหนัก (Weight) ของแต่ละขาผลที่ได้จาก Input ทุก ๆ ขาของ Neuron จะมารวมกันแล้วนำมาเปรียบเทียบกับระดับการกระตุ้นต่ำที่สุดทำให้เกิดการตอบสนอง (Threshold) ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า Threshold แล้ว Neuron จะส่งค่าผลลัพธ์ (Output) ออกไปและ Output ก็จะถูกส่งไปยัง Input ของ Neuron อื่น ๆ ก็จะเชื่อมใน Network จนได้ผลลัพธ์ที่ต้องการจากนั้นจะต้องตรวจสอบผลลัพธ์ที่ได้ว่ามีความคลาดเคลื่อนเพียงใด หากพบว่ามีความคลาดเคลื่อนสูงจะต้องมีการนำค่าความคลาดเคลื่อนนี้ไปปรับน้ำหนักการเรียนรู้ใหม่ (Weight) ซึ่งการเรียนรู้แบบนี้จะต้องอาศัยการทำซ้ำหลายรอบจนกว่าจะได้ผลลัพธ์ตามที่กำหนดจากนั้นทางผู้วิจัยได้เริ่มทำการทดสอบการสร้างโมเดลการพยากรณ์โดยใช้โปรแกรม Weka หลังจากนำข้อมูลเข้าระบบแล้วทางโปรแกรมจะทำการสร้างโมเดลโครงข่ายประสาทเทียม แสดงดังภาพที่ 4

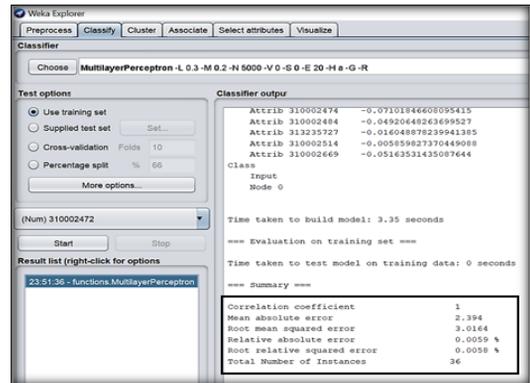


ภาพที่ 4 แสดงแบบจำลองโครงข่ายประสาทเทียมจากโปรแกรม Weka

โดยผู้วิจัยได้กำหนดค่าในการทดลอง ดังนี้ Learning rate 0.3, ค่า Momentum 0.2, ค่า Hidden Layer ไม่ได้กำหนดและสำหรับค่า Training Time จะแบ่งการทดสอบ ออกเป็น 4 ครั้ง โดยแบ่งเป็น 5000 รอบ, 6000 รอบ, 7000 รอบ และ 8000 รอบ ตามลำดับ เนื่องจากหากผู้วิจัยทดสอบด้วยจำนวนรอบที่ต่ำจะทำให้ข้อมูลการพยากรณ์ยิ่งมีความคลื่อนสูงและผลลัพธ์จะขาดความแม่นยำในการพยากรณ์ข้อมูลได้ โดยที่แบ่งสัดส่วนข้อมูลการทดสอบเป็นการเรียนรู้ (Train) และทดสอบ (Test) เท่ากับ 90:10 ซึ่งค่าที่ได้จากการสร้างโมเดลพยากรณ์มีผลต่อค่าความแม่นยำในทั้งการพยากรณ์ยอดขายและการกำหนดนโยบายการจัดเก็บสินค้าในอนาคตของบริษัทได้ โดยผู้วิจัยได้พิจารณาการวัดผลค่าความคลาดเคลื่อนจาก Root Mean Squared Error (RMSE) แสดงดังสมการที่ (2) โดยกำหนดให้ N คือจำนวนชุดข้อมูล ในการหาความแม่นยำโดยใช้โปรแกรม Weka

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\text{ค่าพยากรณ์}_i - \text{ค่าจริง}_i)^2}{N}} \quad (2)$$

หากค่า RMSE มีค่าความคลาดเคลื่อนยิ่งน้อยจะส่งผลให้ค่าพยากรณ์มีความแม่นยำที่สูงและสามารถนำโมเดลดังกล่าวไปทำการทดสอบในการพยากรณ์ต่อไปได้ แสดงดังภาพที่ 5



ภาพที่ 5 แสดงผลลัพธ์ที่ได้จากการออกแบบ

การพยากรณ์จากโปรแกรม Weka หลังจากนั้นโปรแกรมได้แสดงค่าพยากรณ์จากการสร้างโครงข่ายประสาทเทียมได้แสดงดังภาพที่ 6

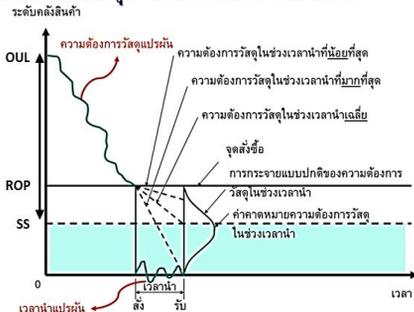
No.	Month	Test Set ALL MT 22	predicted	313235727	6: 313235727	
		Numeric	Numeric	Numeric	Numeric	
1	Jan-18	143433.0	156936.0	61680.0	20615.411404	19772.0
2	Feb-18	141134.0	189759.0	70159.0	20133.510553	19661.0
3	Mar-18	256752.0	234912.0	92345.0	35946.998632	36664.0
4	Apr-18	190107.0	231440.0	73077.0	23981.357607	24545.0
5	May-18	133588.0	188534.0	66398.0	12007.196998	12009.0
6	Jun-18	147904.0	209225.0	74918.0	16170.772026	16966.0
7	Jul-18	165461.0	203198.0	73413.0	21271.826424	19480.0
8	Aug-18	134232.0	180155.0	68035.0	15749.926804	16743.0
9	Sep-18	149727.0	191336.0	72639.0	18236.580425	16160.0
10	Oct-18	194350.0	215326.0	74076.0	19900.355302	19665.0
11	Nov-18	207749.0	241767.0	90488.0	29351.049452	28406.0
12	Dec-18	307764.0	303200.0	110190.0	45689.477283	50516.0
13	Jan-19	116652.0	191475.0	74147.0	19089.15847	17192.0
14	Feb-19	175448.0	208674.0	84263.0	18727.400426	18507.0
15	Mar-19	272918.0	229714.0	86063.0	23444.296359	22954.0
16	Apr-19	198298.0	240800.0	89421.0	20742.854421	21758.0
17	May-19	131666.0	203280.0	66093.0	14699.132802	13674.0
18	Jun-19	145110.0	212152.0	77150.0	17432.696493	15755.0
19	Jul-19	157260.0	209081.0	80050.0	17747.437103	15561.0
20	Aug-19	150814.0	194315.0	73171.0	16173.690574	14109.0

ภาพที่ 6 แสดงตัวอย่างค่าที่ได้พยากรณ์จากโครงข่ายประเทียมจากโปรแกรม Weka

2.4 สร้างตัวแบบสินค้าคงคลัง (Inventory Model)

การกำหนดนโยบายการจัดเก็บสินค้าคงคลังภายในบริษัทกรณีศึกษายังเป็นการเก็บสินค้าโดยอาศัย Inventory Cover Day (CVD) ในการกำหนดนโยบายของบริษัทกรณีศึกษา ซึ่งการบริหารแบบดังกล่าวเป็นการนำ Stock มาหารกับข้อมูลการขายเฉลี่ยย้อนหลัง 30 วันเท่านั้นเพื่อดูความสามารถในการขายสินค้าได้กี่วัน โดยไม่คำนึงถึงความแปรปรวนของยอดขายระหว่างวันและ Leadtime การขนส่งและการผลิตแต่อย่างไร ซึ่งส่งผลทำให้บริษัทพบปัญหาสินค้าขาด Stock (Out of Stock) ในบางช่วงเวลาอยู่บ่อยครั้ง ซึ่งผู้วิจัยเห็นว่าการกำหนดนโยบายดังกล่าวควรที่จะปรับเปลี่ยนนโยบายการจัดเก็บสินค้าในรูปแบบจำลองระดับคงคลังเป้าหมาย (Order Up to Level Model : OUL) แทนการจัดเก็บรูปแบบเดิมซึ่งโมเดล OUL ได้นำความแปรปรวนของยอดขายและ Leadtime การขนส่งและการผลิต มาพิจารณาเพิ่มเติมในการจัดเก็บสินค้าเพื่อรักษาระดับ Inventory ที่เหมาะสมในแต่ละสินค้าและสามารถช่วยตอบสนองความต้องการของลูกค้าได้ในอนาคตตามรายละเอียดดังภาพที่ 7

ความต้องการวัสดุแปรผัน เวลามาแปรผัน



ภาพที่ 7 แสดงแบบจำลอง

แบบจำลองระดับคงคลัง เป้าหมาย : OUL Model

โดยกำหนดให้

- OUL* คือ แบบจำลอง Order up to Level
- ROP* คือ จุดสั่งซื้อสินค้า
- SS* คือ สต็อกเพื่อความปลอดภัย (Safety Stock)
- D* คือ ค่าพยากรณ์อัตราความต้องการสินค้าต่อเดือน (ANN)
- \bar{d} คือ ค่าเฉลี่ยความต้องการสินค้าต่อวัน
- LT* คือ ระยะเวลารอคอยขนส่ง
- LP* คือ ระยะเวลารอคอยรอบการผลิต
- σ_L คือ ค่าเบี่ยงเบนมาตรฐานของระยะเวลานำต่อวัน
- σ_d คือ ค่าเบี่ยงเบนมาตรฐานของความต้องการต่อวัน
- z* คือ ระดับการให้บริการ (Service Level 95%=1.64)

สามารถกำหนดสมการ ดังนี้

$$OUL = ROP + SS \tag{3}$$

$$ROP = \bar{d} * (LP + LT) \tag{4}$$

$$SS = Z * \sqrt{LT\sigma_d^2 + d^2 \sigma_L^2} \tag{5}$$

$$OUL = \bar{d} * (LP + LT) + Z * \sqrt{LT\sigma_d^2 + d^2 \sigma_L^2} \tag{6}$$

หลังจากนั้นได้นำค่าการทำนายข้อมูลการพยากรณ์จาก model โปรแกรม Weka นำค่าที่ได้แทนค่าในสมการโมเดล Inventory โดยใช้โปรแกรม Excel ในการคำนวณหาระดับสินค้าคงคลังที่เหมาะสมในการจัดเก็บสินค้าให้เพียงพอต่อความต้องการลูกค้าต่อไป

3. ผลการวิจัยและอภิปรายผล

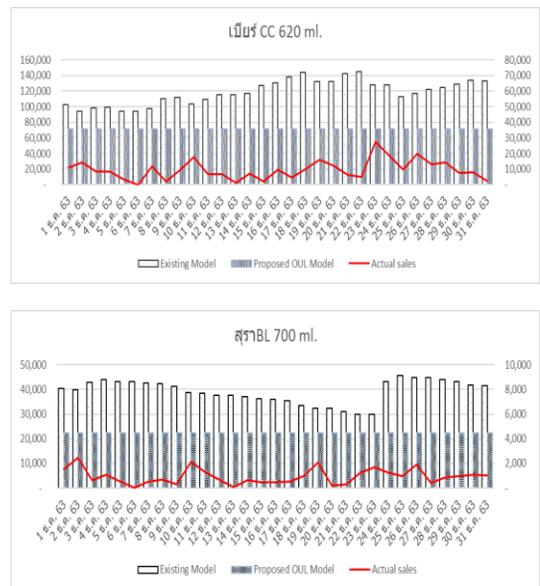
จากการศึกษาการพยากรณ์ยอดขายสินค้าโดยใช้โครงข่ายประสาทเทียมในการพยากรณ์พบว่าจากโมเดลในการทดสอบ 4 ครั้ง ในรูปแบบลักษณะ Multilayer Perceptron โดยแบ่งเป็น 5000 รอบ, 6000 รอบ, 7000 รอบ และ 8000 รอบ ตามลำดับดังตารางที่ 1

ตารางที่ 1 แสดงผลค่า RMSE จากการทดลอง

ครั้งที่	ค่าTraining Time (รอบ)	ค่า RMSE เบียร์ CC	ค่า RMSE สุราBL
1	5,000	3.0164	191.4533
2	6,000	1.0178	112.8426
3	7,000	0.2608	43.9675
4	8,000	0.1137	12.3654

พบว่าสินค้าเบียร์ขนาด 620 มิลลิลิตร (CC 620 ml.) หากต้องการนำโมเดลการพยากรณ์ไปใช้ควรใช้ค่า Training Time 8000 รอบ ให้ค่าความคลาดเคลื่อน $RMSE = 0.1137$ สำหรับสินค้าสุราขนาด 700 มิลลิลิตร (BL 700 ml.) ควรใช้ค่า Training Time 8000 รอบ ให้ค่าความคลาดเคลื่อน $RMSE = 12.3654$ ซึ่งเป็นค่าที่น้อยที่สุดจากการทดสอบ ทั้งหมด 4 รอบ โดยสังเกตจากค่า Root Mean Squared Error (RMSE) ซึ่งค่ายิ่งมีค่าน้อยจะส่งผลทำให้โมเดลมีความคลาดเคลื่อนน้อย เนื่องจากจำนวนการวนรอบของค่า Training Time ที่สูงยิ่งทำให้ข้อมูลต้องมีการปรับน้ำหนักการเรียนรู้ใหม่ (Weight) ซึ่งการเรียนรู้แบบนี้อาจจะต้องอาศัยการทำซ้ำหลายรอบจนกว่าจะได้ผลลัพธ์ตามที่กำหนดเพื่อทำให้มีความแม่นยำมากยิ่งขึ้น

หลังจากได้โมเดลการพยากรณ์และค่าผลลัพธ์ดังกล่าวแล้วนำค่าพยากรณ์จากโมเดลที่ได้เข้าไปทดสอบในแบบจำลอง Order Up to Level Model :OUL ต่อไปและจากข้อมูลบริษัทกรณีศึกษาในช่วงเดือนธันวาคม 2563 เนื่องจากเป็นช่วงที่ขายดีและมีการเก็บสินค้าที่สูงกว่าทุกเดือน รวมทั้งยอดความต้องการสินค้ามีความแปรปรวนสูงเพราะเป็นช่วง Hi-Season ของบริษัท ทางผู้วิจัยจึงได้สนใจนำข้อมูลช่วงเวลาดังกล่าวเข้ามาพิจารณาในการศึกษาและพบว่าสามารถลดปริมาณการการจกเก็บสินค้าได้โดยที่ไม่เกิดปัญหาสินค้าขาดมือ(Out of Stock) แสดงดังภาพที่ 8



ภาพที่ 8 ข้อมูลแสดงการเปรียบเทียบระดับสินค้าคงคลังก่อนและหลังการปรับปรุง

จากการเปรียบเทียบหลังจากการปรับปรุงพบว่าทางบริษัทกรณีสึกษาสามารถลดต้นทุนบริหารจัดการได้สินค้าคงคลังโดยไม่ก่อให้เกิดภาวะสินค้าขาดมือซึ่งจะทำให้สูญเสียโอกาสทางการขายสินค้าให้กับลูกค้าได้ถึง 40.84% ในเดือนธันวาคม 2563 ซึ่งบริษัทกรณีสึกษามีต้นทุนการจัดเก็บสินค้าที่ 8 บาทต่อพาเลทต่อวัน และเมื่อพิจารณาจากจำนวนพาเลทที่ลดลงสะสมตลอดเดือนเท่ากับ 35,034 พาเลทต่อเดือน นำจำนวนพาเลทที่ลดลงมาคูณด้วยต้นทุนการจัดเก็บสินค้าต่อวันบริษัทสามารถลดต้นทุนบริหารจัดการในการจัดเก็บ 280,278 บาทต่อในเดือนธันวาคม 2563

4. สรุป

บทความนี้ได้นำเสนอประสิทธิภาพของการพยากรณ์โดยใช้เทคนิคโครงข่ายประสาทเทียม (ANN) และได้มีการวัดค่าความคลื่อนของตัวแบบการพยากรณ์ RMSE ในการหาความแม่นยำผ่านโปรแกรม Weka ในการทดสอบพบว่า สินค้าเบียร์ขนาด 620 มิลลิลิตร (CC 620 ml.) ที่ค่า Training Time 8,000 รอบ ให้ค่าความคลาดเคลื่อน RMSE = 0.1137 และสำหรับสินค้าสุราขนาด 700 มิลลิลิตร (BL 700 ml.) ค่า Training Time 8,000 รอบ ให้ค่าความคลาดเคลื่อน RMSE = 12.3654 ซึ่งเป็นค่าที่ดีที่สุดและแม่นยำที่สุด ซึ่งประสิทธิภาพของตัวแบบสำหรับการพยากรณ์ต้องอาศัยข้อมูลจำนวนมากสำหรับการสร้างตัวแบบหากมีข้อมูลที่น้อยจะทำให้ประสิทธิภาพในการพยากรณ์ลดลงได้ เมื่อได้ผลลัพธ์ค่าพยากรณ์จากโมเดลดังกล่าวแล้วนำค่าพยากรณ์ดังกล่าวเข้าไปทดสอบโมเดลตัวแบบสินค้าคงคลังพบว่าหลังจากมีการปรับปรุงนโยบาย

การจัดเก็บสินค้าในรูปแบบใหม่ Order Up to Level Model สามารถลดการจัดเก็บสินค้าคงคลังสำหรับสินค้าเบียร์ขนาด 620 มิลลิลิตร (CC 620 ml.) และ สุรา BL 700 ml. ได้ถึง 35,034 พาเลท คิดเป็น 40.84% ของสินค้าคงคลังที่ลดลงเมื่อเทียบกับเดือน ธันวาคม 2563 หากพิจารณาถึงต้นทุนการจัดเก็บสินค้าตามนโยบายบริษัทที่คิดในอัตราการจัดเก็บ 8 บาทต่อพาเลทต่อวันสามารถลดต้นทุนได้ถึง 280,278 บาทต่อเดือน โดยไม่ก่อผลให้เกิดภาวะสินค้าขาดมือทำให้สูญเสียโอกาสทางการขายได้

ซึ่งหลังจากนี้ผู้วิจัยมีแผนที่จะวิจัยเพิ่มเติมกับการขยายกลุ่มสินค้ารายอื่น ๆ ต่อไปนอกจากนี้ยังต้องมีการพัฒนาโมเดลพร้อมกับทดสอบตัวแบบการพยากรณ์อยู่เสมอเพื่อให้ตัวแบบมีความแม่นยำในการพยากรณ์และมีประสิทธิภาพในการนำไปใช้งานต่อไปในอนาคต

5. กิตติกรรมประกาศ

งานวิจัยเล่มนี้สามารถสำเร็จลุล่วงได้ด้วยดีด้วยความอนุเคราะห์จากบุคคลหลายท่าน ซึ่งไม่อาจจะนำมากล่าวได้ทั้งหมดผู้วิจัยขอกราบขอบขอบคุณผู้ช่วยศาสตราจารย์ คมกฤช ปิติฤกษ์ ท่านอาจารย์ที่ปรึกษาในงานวิจัยที่ให้การสนับสนุนการทำงานวิจัยตั้งแต่การเริ่มต้นพร้อมเสนอแนะแนวทางการทำงานวิจัยได้เป็นอย่างดีเพื่อให้งานวิจัยออกมามีคุณภาพและขอขอบคุณบริษัทกรณีสึกษาและคณะทำงานในกลุ่มงานโครงการพัฒนาประสิทธิภาพของบริษัท กรณีสึกษาให้การสนับสนุนในงานวิจัยหรือคำปรึกษาที่ดีเสมอมา เพื่อให้การเขียนงานวิจัยฉบับนี้มีความสมบูรณ์ที่สุดจนกระทั่งสามารถสำเร็จลุล่วงได้ด้วยดี

6. เอกสารอ้างอิง

- [1] กานต์สินี เจริญกิจวัชรชัย. ปัญญาประดิษฐ์กับการพยากรณ์ค่าจ้างแรงงานไทย. [วิทยานิพนธ์ปริญญาเศรษฐศาสตรมหาบัณฑิต]. กรุงเทพฯ : มหาวิทยาลัยธรรมศาสตร์; 2561.
- [2] นิพนธ์ ไตอินทร์. การพยากรณ์ความต้องการและการวางแผนสินค้าคงคลัง สำหรับสินค้าเครื่องดื่ม. [วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต]. กรุงเทพฯ : มหาวิทยาลัยธุรกิจบัณฑิต; 2556.
- [3] บุษรา ลิมพิพัฒนางกูร. การพยากรณ์โอกาสการสำเร็จการศึกษาของนักเรียน โดยใช้จินตคณิตอภีร์แบบหลายวัตถุประสงค์เปรียบเทียบกับระบบโครงข่ายประสาทเทียม. [วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต]. กรุงเทพฯ : สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ; 2549.
- [4] รสริน โคตรเสนา. การพยากรณ์ความต้องการสินค้าโดยวิธีโครงข่ายประสาทเทียมของโรงงานผลิตขนมแห่งหนึ่ง. [วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต]. กรุงเทพฯ : มหาวิทยาลัยธุรกิจบัณฑิต; 2563.
- [5] ไววิทย์ พานิชัยศดร และ มหศักดิ์ เกตุฉ่ำ. การพยากรณ์ยอดขายปลีกแก๊สรถยนต์ด้วยวิธีการวิเคราะห์อนุกรมเวลาและโครงข่ายประสาทเทียม. วารสารวิทยาการและเทคโนโลยี 2560; 7(1): 42-9
- [6] ศุภเชษฐ์ กันน้อม. การประยุกต์ใช้โครงข่ายประสาทเทียมเพื่อพัฒนารูปแบบการพยากรณ์ยอดขายรถจักรยานยนต์ภายในประเทศไทย. [วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต]. กรุงเทพฯ : จุฬาลงกรณ์มหาวิทยาลัย; 2547.
- [7] นภัสสร สกุลประดิษฐ์. การจัดการสินค้าคงคลังในโรงงานผลิตและกระจายสินค้าแช่แข็ง. [วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต]. กรุงเทพฯ : มหาวิทยาลัยธรรมศาสตร์; 2560.
- [8] ศุภโชค แสงสว่าง. การประยุกต์ใช้โครงข่ายประสาทเทียมกับงานทางด้านกาเกษตร. วารสารวิชาการพระจอมเกล้าพระนครเหนือ 2559; 26(2): 319-31.
- [9] วรวิรัตน์ สงฆ์แป้น. การทำเหมืองข้อมูล Data Mining. โรงพิมพ์มหาวิทยาลัยขอนแก่น; 2560.
- [10] อัจฉรา จันวดี. วิธีการปรับปรุงการพยากรณ์ความต้องการวัตถุดิบและนโยบายการเติมเต็มวัตถุดิบคงคลังสำหรับโรงงานผลิตขึ้นรูปเหล็กหล่อแบบออกแบบตามคำสั่งซื้อ. [วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต]. กรุงเทพฯ : จุฬาลงกรณ์มหาวิทยาลัย; 2561.
- [11] เอ ดิห์ลี. การเปรียบเทียบผลการพยากรณ์ราคาบิตคอยน์โดยใช้วิธีการวิเคราะห์การถดถอยโครงข่ายประสาทเทียม และการโปรแกรมเชิงพันธุกรรม. [วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต]. ชลบุรี : มหาวิทยาลัยบูรพา; 2560.

- [12] David Scuse. Peter Reutemann. WEKA Experimenter Tutorial for Version 3-5-8. WEKA Manual; 2008.
- [13] Taghavifar H, Mardani A, HalehKarim-Maslak H and Kalbkhani H. Artificial neural network estimation of wheel rolling resistance in clay loam soil. *Applied Soft Computing*. 2013; 13(8): 3544–51.
- [14] Witchayapong C. The study for increasing of methane content in biogas production from cassava pulp [MSc Thesis]. Nakhon Ratchasima: Suranaree University of Technology; 2017.
- [15] Kavuma C. Variation of Methane and Carbon dioxide yield in a biogas plant [MSc Thesis]. Stockholm: Royal Institute of Technology; 2013.
- [16] Lerdlattaporn R, Phalakornkule C, Trakulvichean S and Songkasiri W. Implementing circular economy concept by converting cassava pulp and wastewater to biogas for sustainable production in starch industry. *Sustainable Environment Research* 2021; 31: 20.