

การพยากรณ์ยอดขายปลีกแก๊สรถยนต์ ด้วยวิธีการวิเคราะห์อนุกรมเวลาและโครงข่ายประสาทเทียม

Demand forecasting for LPG station by Time Series and Artificial Neural Network

ไววิทย์ พานิชอักษร และ มหศักดิ์ เกตุฉ่ำ

ภาควิชาการจัดการระบบสารสนเทศ คณะเทคโนโลยีสารสนเทศ

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้า พระนครเหนือ

ABSTRACT – Demand forecasting plays an important role in business. A good inventory management can increase the competitive advantage. An inventory should be optimized so that firm can increase free cash flow and keep the company's profitability at the same time. Especially, demand forecasting for the LPG station is very difficult because there are many factors which may not be linked directly or indirectly and it also occur in duplicate or random sometime. Thus, only the historical sale data is insufficient for develop an efficient forecast model. With the neural network technique, this technique gives an advantage in extracting the real factor which impact to demand in the future. This paper uses the artificial neural network for developing the forecast model. The result shows the presented methodology has 683 RMSE a day.

KEY WORDS – demand forecast; time series; neural network.


บทคัดย่อ -- การพยากรณ์ความต้องการมีบทบาทอย่างมากในการดำเนินธุรกิจปัจจุบัน การจัดการสินค้าคงคลังที่ดีจะสร้างความเปรียบทางการแข่งขัน การมีปริมาณสินค้าคงคลังที่เหมาะสม ไม่มากเกินไปจนทำให้ไม่เหลือเงินไปลงทุนด้านอื่น และไม่น้อยเกินไปจนต้องสูญเสียโอกาสในการทำกำไร ในการพยากรณ์ความต้องการหรือยอดขายสำหรับสถานีบริการแก๊ส LPG ยิ่งทำได้ยากเพราะมีปัจจัยและข้อมูลจำนวนมาก ที่อาจจะไม่เชื่อมโยงกันหรือเชื่อมโยงกันทั้งในทางตรงและทางอ้อม และอาจจะเกิดขึ้นในรูปแบบที่ซ้ำหรือไม่ซ้ำกันก็ได้ ดังนั้นการจะอาศัยข้อมูลย้อนหลังเพียงอย่างเดียวอาจไม่สามารถพยากรณ์ได้ จึงจำเป็นที่ระบบพยากรณ์ต้องสามารถเรียนรู้ได้เอง และด้วยเทคนิคโครงข่ายประสาทเทียมนั้น ระบบสามารถที่จะเรียนรู้จากปัจจัยต่าง ๆ และสามารถที่จะสกัดเอาลักษณะออกมาได้เอง จึงทำให้ระบบสามารถรู้ได้ว่า ปัจจัยใดมีผลกระทบต่อความต้องการและปัจจัยใดไม่มีผลต่อความต้องการ ในงานวิจัยนี้ผู้วิจัยได้จึงได้นำวิธีการโครงข่ายประสาทเทียมที่สามารถเรียนรู้รูปแบบต่าง ๆ ที่มีความซับซ้อนได้คล้ายกับวิธีการคิดของมนุษย์เข้ามาเพื่อสร้างโมเดลในการพยากรณ์เพื่อแก้ปัญหาดังกล่าว วิธีการนี้พยากรณ์ได้แม่นยำมากโดยมีค่าผิดพลาดเฉลี่ยเพียงหกหรือต่ำกว่าหน่วยต่อวัน จากยอดขายเฉลี่ยหนึ่งหมื่นต่อวัน

1. บทนำ

อัตราเงินเพื่อเพิ่มสูงขึ้นเรื่อย ๆ หากจะนำเงินไปเก็บไว้เฉย ๆ มูลค่าของเงินเหล่านั้นก็จะถูกลดมูลค่าลงเรื่อย ๆ และยิ่งไปกว่านั้นหากนำเงินนั้นไปซื้อสินค้ามาเพื่อจำหน่าย ก็จะยิ่งทำให้เจ้าของเงินหรือเจ้าของกิจการไม่สามารถนำทรัพย์สินไปใช้

ประโยชน์ หรือไปเพื่อมูลค่าได้ หากว่าสินค้าเหล่านั้นยังไม่ได้ถูกจำหน่ายออกไป จึงจำเป็นที่จะต้องจัดการปริมาณสินค้าคงคลังอย่างเหมาะสม ไม่ให้มากเกินไปจนทำให้ไม่เหลือเงินไปลงทุนด้านอื่น แต่ก็ไม่ให้มีน้อยเกินไปจนต้องสูญเสียโอกาสทำกำไรในกรณีที่สินค้าไม่พอจำหน่าย

มีนักวิจัยหลาย ๆ ท่านให้ความสนใจกับปัญหาเหล่านี้ มีงานวิจัยจำนวนมาก เสนอวิธีการต่าง ๆ เพื่อพยากรณ์การใช้งานพลังงานในอนาคต วิธีการ autoregressive, co-integration, time series analysis และวิธีการอื่น ๆ [2], [3], [4] ได้ถูกนำมาใช้ในการพยากรณ์ความต้องการจากข้อมูลที่เป็นปัจจัยที่เป็นตัวแปรต้นที่ส่งผลกระทบต่อตัวแปรตามของความต้องการ ได้แก่ ข้อมูลผลิตภัณฑ์มวลรวมของประเทศ(GDP) ราคาน้ำมัน จำนวนประชากร การส่งออก การนำเข้า เป็นต้น แต่ในงานวิจัยหนึ่ง จะเห็นได้ว่าการพยากรณ์ได้ผลออกมาเป็นเหตุเป็นผล ก็ต่อเมื่อการความต้องการในอนาคตนั้นเพิ่มขึ้น แต่ผลการพยากรณ์จะไม่สมเหตุผลและผิดพลาดได้ในกรณีที่ ความต้องการนั้นลดลงในอนาคต [2]



รูปที่ 1. แสดงการเปรียบเทียบผลพยากรณ์ด้วยวิธีอนุกรมเวลา

การจะนำวิธีการเหล่านั้นไปใช้ในการพยากรณ์ในระดับสถานบริการรายย่อยจึงไม่สามารถทำได้ เพราะความต้องการในแต่ละเวลานั้นมีความแตกต่างกัน ทั้งขึ้นและลงเนื่องจากปัจจัยที่ต่างออกไป และมีปัจจัยซ่อนเร้นอีกมาก ซึ่งต้องหาความสัมพันธ์ให้ได้ จึงจะสามารถพยากรณ์ได้อย่างถูกต้องแม่นยำ งานวิจัยนี้จึงนำเสนอวิธีการนำโครงข่ายประสาทเทียมที่มีความสามารถในการเรียนรู้ มาใช้ในการพัฒนาแบบจำลองเพื่อพยากรณ์ยอดขายปลีกแก๊สรถยนต์จากข้อมูลย้อนหลัง 5 ปี ได้แก่ ข้อมูลราคาน้ำมัน วันที่ ราคาแก๊ส ผลิตภัณฑ์มวลรวมของประเทศ วันหยุดต่าง ๆ

2. แนวคิด / วิธีการที่นำเสนอ

2.1 การทำเหมืองข้อมูล

การทำเหมืองข้อมูล คือ การวิเคราะห์ข้อมูลจากข้อมูลจำนวนมาก เพื่อหาความสัมพันธ์ของข้อมูลที่ซ่อนอยู่ โดยทำการจำแนกประเภท รูปแบบ เชื่อมโยงข้อมูลที่มีความสัมพันธ์กัน

และหาความน่าจะเป็นที่จะเกิดขึ้นเพื่อให้ได้รูปแบบของข้อมูลใหม่ ที่จะนำไปใช้ในวิเคราะห์ความเป็นไปได้ และนำไปใช้ในการประกอบการตัดสินใจ ยังมีข้อมูลมาก ๆ ที่จะยังทำให้การพยากรณ์แม่นยำขึ้นไปด้วย การทำเหมืองข้อมูลจึงเหมือนวิธีการหนึ่งในการจัดเก็บและตีความหมาย ข้อมูล จากเดิมที่มีการจัดเก็บข้อมูลอย่างง่าย ๆ มาเป็นการจัดเก็บในรูปแบบข้อมูลที่สามารถดึงข้อมูลสารสนเทศมาใช้ และสามารถค้นพบความรู้ที่ซ่อนอยู่ในข้อมูลนั้นได้

การพยากรณ์ข้อมูลในอนาคตนั้น ส่วนมากจะแบ่งออกเป็น 2 รูปแบบ หลัก ๆ ได้แก่ การพยากรณ์เชิงคุณภาพ (Qualitative Forecasting) และการพยากรณ์เชิงปริมาณ (Quantitative Forecasting)

การพยากรณ์เชิงคุณภาพ (Qualitative Forecasting) ในบางครั้งเราอาจจะต้องทำการพยากรณ์เหตุการณ์ในอนาคต โดยไม่มีข้อมูลในอดีตที่เกี่ยวข้องกับเหตุการณ์

การพยากรณ์เชิงปริมาณ เป็นการพยากรณ์ที่นำเอาข้อมูลในอดีตมาคำนวณหรือหารูปแบบเพื่อพยากรณ์ค่าในอนาคต การพยากรณ์แบบนี้มีหลายเทคนิคที่นำมาใช้ ในตอนแรกมีการใช้เทคนิคเพียงเทคนิคเดียว ในการหาค่าพยากรณ์ แต่ต่อมาได้มีนักวิจัย นำเทคนิคแต่ละวิธีมาหาค่าพยากรณ์ที่ดีที่สุด ทำให้รู้ว่าแต่ละวิธีหรือแต่ละเทคนิคนั้นจะมีประสิทธิภาพหรือไม่ นั่น ก็ขึ้นอยู่กับข้อมูลที่ใช้ในการทำแบบจำลองด้วย และอาจรวมไปถึงสถานการณ์ที่เหมาะสมกับแบบจำลองนั้น ๆ โดยในปัจจุบันนี้ การเปรียบเทียบเทคนิคยังดีไม่พอ ที่จะแก้ปัญหาค่าผิดพลาดที่เกิดขึ้นจากการพยากรณ์ได้ จึงเริ่มมีนักวิจัยพยายามรวมเทคนิคต่าง ๆ เข้าไว้ด้วยกันโดยดึงแต่ละข้อดีของแต่ละเทคนิคมาใช้ทำแบบจำลอง ด้านล่างนี้เป็นเทคนิคที่นิยมในการทำเหมืองข้อมูล

2.2 ทฤษฎีอนุกรมเวลา (Time Series)

อนุกรมเวลา คือ ชุดของข้อมูลเชิงปริมาณที่จัดเก็บช่วงเวลาใดช่วงเวลาหนึ่ง โดยจัดเรียงตามเวลาที่บันทึกข้อมูลนั้น โดยมีระยะห่างเท่าๆกัน เช่นรายวัน รายสัปดาห์ รายเดือน หรือจะเป็นรายชั่วโมงก็ได้ ตัวอย่างเช่นยอดขายของปั๊มแก๊สแห่งหนึ่งในช่วงเดือนกันยายนเป็นต้น ในทางคณิตศาสตร์แล้ว ถ้าในอนุกรมเวลา คือ ค่าของข้อมูลที่บันทึกติดต่อกันเป็นอันดับของเวลา ในที่นี้แทนค่าของข้อมูลที่บันทึก ณ ช่วงเวลาที่ T ใด ๆ

ด้วย X_1 ดังนั้นอนุกรมเวลาใดเวลาหนึ่งซึ่งถูกบันทึกไว้ N ค่าจะเท่ากับ $X-1, \dots, X_N$

การวิเคราะห์อนุกรมเวลาด้วยตัวแบบ คือ การวิเคราะห์อนุกรมเวลาโดยอาศัยการสร้างแบบจำลองพยากรณ์ (Forecasting Model) ซึ่งจะใช้ข้อมูลในอดีตเพื่อศึกษาถึงความเคลื่อนไหวหรือการเปลี่ยนแปลงของข้อมูลในช่วงเวลาที่เราสงเกตใจในการคาดการณ์สิ่งที่จะเกิดขึ้นข้างหน้าโดยอาศัยเทคนิคของการพยากรณ์เข้ามาช่วยในการหารูปแบบของข้อมูลในอดีต

ส่วนประกอบในอนุกรมเวลา จะแบ่งออกเป็น 4 ส่วน ดังนี้

1. ค่าแนวโน้ม (Trend Variation: T)
2. ฤดูกาล (Seasonal: S)
3. วัฏจักร (Cycle: C)
4. การสุ่มแบบไม่ปกติ (Irregular: I)

ดังนั้นรูปแบบของอนุกรมเวลาจะสามารถสรุปเป็นสมการได้ 2 แบบคือ ตัวแบบการบวก และตัวแบบการคูณดังนี้

1. ตัวแบบการบวก (Additive model)

$$Y = T + S + C + I \quad (1)$$

เกิดขึ้นจากแนวความคิดที่ว่า ส่วนประกอบทั้ง 4 ของอนุกรมเวลาจะต้องเป็นอิสระต่อกัน

2. ตัวแบบการคูณ (Multiplicative model)

$$Y = T \times S \times C \times I \quad (2)$$

เกิดขึ้นจากแนวความคิดที่ว่า ส่วนประกอบทั้ง 4 ของอนุกรมเวลาจะมีความสัมพันธ์กัน หมายความว่า ถ้าส่วนประกอบใดส่วนประกอบหนึ่งมีค่าเปลี่ยนแปลงไปไม่ว่าจะเพิ่มขึ้นหรือลดลงจะมีผลกระทบต่อค่าเปลี่ยนแปลงของส่วนประกอบอื่นๆ ที่เหลือ

2.3 ทฤษฎีแบบจำลองเครือข่ายประสาทเทียม (ANN)

อาจจะเรียกว่าการวิเคราะห์หัดดอยที่ดีที่สุดอย่างหนึ่งแบบจำลองประเภทนี้มีความยืดหยุ่นสูงไม่ยึดติดกับรูปแบบใด ๆ โดยไม่จำเป็นต้องทราบรูปแบบความสัมพันธ์ล่วงหน้าและไม่ขึ้นกับเงื่อนไขทางสถิติ แบบจำลองเครือข่ายประสาทเทียม (Artificial Neural Network; ANN) เครือข่ายประสาทเทียม Neural Network คือแบบจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์เพื่อให้มีความสามารถในการเรียนรู้

การจัดจำแนกรูปแบบ (Pattern Recognition) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ ซึ่งประกอบด้วย เซลล์ประสาท หรือนิวรอน (neurons) และ จุดประสานประสาท (synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาทซึ่งเป็นข้อมูลเข้า และปลายในการส่งกระแสประสาทซึ่งเป็นเหมือนผลลัพธ์ ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรท์เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่นๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนของมัน โครงสร้างของเครือข่ายประสาทเทียมประกอบด้วยนิวรอนซึ่งเชื่อมต่อกันเป็นชั้น ๆ ชั้นแรกเป็นข้อมูลเข้า (input) และชั้นสุดท้ายจะเป็นชั้นผลลัพธ์ในระหว่างชั้นแรกกับชั้นสุดท้ายจะมีชั้นที่ซ่อนอยู่ระหว่างทั้ง 2 ชั้นนั้นอีกที่ชั้นก็ได้หรือจะไม่มีก็ได้ [9] การเรียนรู้ของเครือข่ายประสาทเทียม มี 2 ประเภท คือ


Supervised Learning คือ เรียนแบบได้ตามคำแนะนำวิธีการก็คือ ถ้าเราต้องการจะสอนโมเดลให้แยก แยกกับสิ่งของอื่น ๆ เราก็จะเอาภาพของแมวให้คอมพิวเตอร์ดู แล้วบอกว่า “นี่คือแมว” จากนั้นคอมพิวเตอร์ก็จะ Extract Feature ออกมาจากภาพของแมวที่เราป้อนเข้าไป เช่น มี 4 ขา มี 1 หาง มี 2 ตา และอื่น ๆ เปรียบเสมือนการ classification นั่นเอง ด้วยขั้นตอนพวกนี้ทำให้คอมพิวเตอร์สามารถแยก แยก แมว ออกจากสิ่งอื่น ๆ ได้

Unsupervised Learning เป็นวิธีการที่คล้าย ๆ กับ Supervised Learning แต่ต่างกันตอนที่เรเอาข้อมูลให้ระบบรับรู้ เราจะไม่บอกว่า สิ่งที่เราใส่เข้าไปคืออะไร เช่น ให้ดูรูปแมวเราก็แค่ให้รูปแมวไป แต่ไม่ได้บอกโมเดลว่า “นี่คือแมว” เพราะฉะนั้นสิ่งที่คอมพิวเตอร์จะทำได้คือ การทำ Feature Extraction แล้วพยายามแยกของจาก Feature ที่ Extract ออกมาได้ แต่ก็ยังไม่รู้จริง ๆ ว่านี่คืออะไร แต่ระบบสามารถที่จะเรียกกลุ่ม ๆ ของข้อมูลพวกนั้นว่า Cluster

การทำงานของ Neural networks คือเมื่อรับข้อมูลเข้ามายัง network จะให้น้ำหนักข้อมูลเข้าทุกหน่วยผลที่ได้จากข้อมูลเข้าทุก ๆ ขาของ นิวรอน จะเอามารวมกันแล้วก็เอามาเทียบกับค่าควบคุมระดับผลลัพธ์ของนิวรอน (threshold) ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า threshold แล้วนิวรอน ก็จะส่ง ผลลัพธ์ออกไป ผลลัพธ์ นี้ก็จะถูกส่งไปเป็นข้อมูลเข้า ของ นิวรอน อื่น

ๆ ที่เชื่อมกันใน network ถ้าค่าน้อยกว่า threshold ก็จะไม่ให้ผลลัพธ์ออกมา

ตัวแบบจำลอง ANN นั้นมีอยู่ด้วยกันหลาย แต่แบบจำลองที่สนใจในงานวิจัยครั้งนี้คือ Feed Forward Back Propagation Neural Network (FBPNN) เพราะข้อมูลนำเข้ามีหลายปัจจัย จึงต้องอาศัยการเรียนรู้ และส่งผลย้อนกลับเพื่อปรับปรุงตัวแบบให้มีความถูกต้องและแม่นยำเพิ่มขึ้น ซึ่งแบบจำลองนี้เป็นการเรียนรู้แบบมีผู้สอนหรือว่า Supervised Learning หมายความว่าชุดข้อมูลฝึกอบรม (Training Data Set) Neurons ใน Hidden Layer จะปรับค่า Weight แบบสุ่ม (Random) หรือหมุนเวียน (Rotation) ตามผลของการคำนวณผลลัพธ์ ระบบการเรียนรู้แบบนี้อาจเรียกได้อีกอย่างหนึ่งว่า Reinforcement Learning จะเป็นแบบที่ Neurons ใน Layer ที่ 1 ส่ง Output ให้ Neurons ใน Layer ที่ 2 แต่จะไม่ได้รับ Feedback จาก Neurons ใน Layer ที่ 2 ซึ่งชั้นข้อมูลเข้าทุกโหนดจะถูกเชื่อมไปข้างหน้ากับทุกโหนดที่อยู่ในชั้นถัดไป และโหนดในชั้นถัดไปจะถูกเชื่อมกับในชั้นถัดต่อไปอีกตามลำดับจนกระทั่งถึงชั้นผลลัพธ์



รูปที่ 2. แสดงตัวแบบ Feed Forward Backpropagation Neural Network (FBPNN)

โดยชั้นข้อมูลเข้าแทนด้วยเวกเตอร์ $X=(x_1, x_2, \dots, x_n)$ ชั้นที่ซ่อนอยู่แทนด้วยเวกเตอร์ $H=(h_1, h_2, \dots, h_m)$ และชั้นผลลัพธ์แทนด้วยเวกเตอร์ $Y=(y_1, y_2, \dots, y_n)$ ผลลัพธ์ของหน่วยที่ j ของชั้นที่ซ่อนอยู่ได้จากการคำนวณผลบวกถ่วงน้ำหนักของข้อมูลเข้าทั้ง n ค่าและบวกกับค่าความคลาดเคลื่อน (Bias) จากนั้นผลบวกดังกล่าวจะถูกแปลงโดยฟังก์ชันถ่ายโอน (transfer function) g ให้เป็นผลลัพธ์ออกมา


2.4 การจัดการคลังสินค้า

การจัดการคลังสินค้าหรือการจัดการสินค้าคงคลัง คือการจัดการสินค้าคงคลังที่มีไว้สำหรับการผลิตและการขายเพื่อให้ธุรกิจดำเนินไปได้อย่างมีประสิทธิภาพ เพื่อให้มีสินค้าเพียงพอสำหรับการผลิตหรือจำหน่าย แต่การมีสินค้าคงคลังมากเกินไปก็อาจทำให้ธุรกิจต้องแบกรับต้นทุนด้านการผลิตและเก็บรักษาที่สูงตามไปด้วย แต่ถ้าหากมีสินค้าคงคลังน้อยเกินไปก็อาจทำให้ธุรกิจประสบปัญหาสินค้าขาดแคลนไม่พอจำหน่าย สูญเสียโอกาสทำกำไรได้ และเป็นการเปิดช่องทางให้แก่คู่แข่ง

2.5 การออกแบบและการวางแผนการวิจัย

ทำการศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์ความต้องการด้านพลังงาน กระบวนการพัฒนาโมเดลที่ใช้ และวิธีทดสอบความถูกต้องของโมเดล การเลือกข้อมูลที่จะใช้ในการดำเนินการวิจัย การแก้ไขเพื่อลดข้อผิดพลาดในการพยากรณ์และเทคนิคต่าง ๆ เพื่อเพิ่มความแม่นยำให้กับโมเดล จากนั้นทำการวิเคราะห์หาข้อดีและข้อเสียของแต่ละงานวิจัย เปรียบเทียบดูแนวทาง เพื่อให้มองเห็นถึงปัญหา กำหนดขอบเขตปัญหาและแนวทางการวิจัย จากการศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์ความต้องการด้านพลังงาน การพยากรณ์การขาย และอื่น ๆ ที่เกี่ยวข้อง

หลังจากที่ได้ทำการกำหนดขอบเขต ข้อมูลนำเข้า เป้าหมายและจุดประสงค์รวมถึงปัญหาที่มืออย่างชัดเจนแล้ว จึงดำเนินการออกแบบและพัฒนาวิธีการวิจัย โดยการออกแบบกรอบแนวความคิดและขั้นตอนการดำเนินงานวิจัย ในการวิเคราะห์ข้อมูลทางสถิติ โดยใช้กระบวนการเหมือนข้อมูลในการหารูปแบบของความสัมพันธ์และสร้างแบบจำลองเพื่อบรรลุมิติประสงค์ในการดำเนินการวิจัย



รูปที่ 3. แสดงกรอบแนวคิดในการดำเนินการวิจัย

2.6 การจัดเตรียมข้อมูล

ในการจัดเตรียมข้อมูลนั้น เพื่อให้การดำเนินงานเป็นไปอย่างถูกต้องตามวัตถุประสงค์และมีประสิทธิภาพนั้น ผู้วิจัยจึงแบ่งขั้นตอนการเตรียมข้อมูลออกเป็นขั้นตอนต่าง ๆ ดังนี้

1. คัดเลือกข้อมูล เนื่องจากข้อมูลมีเป็นจำนวนมาก เราจำเป็นต้องค้นหาและรวบรวมข้อมูล โดยอ่านงานวิจัยที่เกี่ยวข้องพบว่า งานวิจัยที่ผู้วิจัยนำเสนอ นั้น เลือกข้อมูลทางด้านเศรษฐกิจ เช่น ความต้องการย้อนหลังผลิตภัณฑ์มวลรวมภายในประเทศ อัตราการเจริญเติบโตของผลิตภัณฑ์มวลรวมภายในประเทศ ทั้งนี้ผู้วิจัยเห็นว่าข้อมูลเหล่านั้นยังไม่เพียงพอที่จะใช้ในการดำเนินงานวิจัยนี้ ผู้วิจัยจึงเพิ่มข้อมูลวันหยุดในเทศกาลต่าง ๆ ราคาแก๊ส และราคาน้ำมันที่มีการเปลี่ยนแปลงขึ้นและลงอยู่ตลอดเวลา ตั้งแต่ช่วงปี พ.ศ. 2555 – 2559 เป็นเวลาทั้งสิ้น 5 ปี ทำให้ได้ข้อมูลมากกว่า 1825 ระเบียบ

2. คัดกรองข้อมูลและเตรียมข้อมูลเพื่อเข้าสู่ระบบ จากที่ต่างกันของข้อมูลที่ได้ทำการรวบรวมมานั้น ไม่ว่าจะเป็นข้อมูลการขยายย้อนหลังผู้ให้บริการค้าปลีกแก๊สรถยนต์ ข้อมูล GDP จากกรมสถิติแห่งชาติ ราคาน้ำมันย้อนหลังเว็บไซต์ของบริษัท ปตท. จำกัด (มหาชน) วันหยุดและเทศกาลต่าง ๆ จากปฏิทิน และอื่น ๆ อีกมากมาย ซึ่งก็มีรูปแบบ ชนิดของแฟ้มข้อมูลไม่เหมือนกัน และบางข้อมูลอาจจะมีส่วนเกินที่ไม่ต้องการอีกเช่น ค่าแรงพนักงาน ค่าไฟฟ้า อัตราดอกเบี้ย และเงินเฟ้อ เป็นต้น จึงต้องทำการลบข้อมูลที่ไม่เกี่ยวข้องออก และเนื่องจากในบางวันที่ปิดหรือสถานีปิดบริการ ไม่ว่าด้วยเหตุผลใด เช่น แก๊สที่เป็นสินค้าหลักหมด อุปกรณ์ชำรุด หรือต้องตรวจสอบความปลอดภัยประจำปี ทำให้มีข้อมูลในส่วนที่หายไปจึงต้องเติมข้อมูลด้วยค่าเฉลี่ยของเดือนนั้นแทน เพื่อให้โมเดลจำลองไม่จดจำสิ่งที่ผิดปกติลงไป

3. การรวมข้อมูล เพื่อให้สามารถประมวลผลข้อมูลได้ จำเป็นที่จะต้องให้ข้อมูลจากหลาย ๆ แหล่งมาอยู่รวมกันด้วยวิธีการใดวิธีการหนึ่ง เช่น รวบรวมฐานข้อมูล รวมไฟล์ต่าง ๆ ไว้ในไฟล์เดียวกัน ดังนั้นจะต้องทำการรวมข้อมูลที่จะใช้ในการทำเหมืองข้อมูล ให้อยู่ในแฟ้มเดียวกัน แต่เนื่องจากข้อมูลที่รวบรวมมานั้นไม่ได้มาจากแหล่งเดียวกัน จึงทำให้วิธีการจัดเก็บไม่เหมือนกัน รูปแบบของข้อมูลจึงไม่เหมือนกันด้วย เช่น มีหน่วยต่างกัน เป็นตัวเลขบ้าง เป็นตัวอักษรบ้าง ตำแหน่งทศนิยมต่างกันบ้าง และหากมีข้อมูลที่ขาดหายไป เนื่องจาก

ช่วงเวลาที่แตกต่างกัน หรือระยะของการเก็บข้อมูล ก็อาจจะเติมด้วยค่าเฉลี่ยแทน เพื่อให้ข้อมูลครบถ้วน

2.7 การสร้างแบบจำลอง

ในขั้นตอนนี้เป็นขั้นตอนที่สำคัญมาก เนื่องจากจะมีผลอย่างมากกับผลลัพธ์ของการดำเนินงานวิจัย ดังนั้นต้องเลือกโมเดลที่ให้ผลดีที่สุด ให้ความแม่นยำที่สุด โดยที่มีค่าผิดพลาดน้อยที่สุด ดังนั้นผู้วิจัยเลือกได้เลือกวิธีการโครงข่ายประสาทเทียม ANN มาใช้ในการสร้างโมเดล โดยนำเข้าข้อมูล 5 ตัวแปร ได้แก่ ข้อมูลราคาน้ำมัน วันที่ ราคาแก๊ส GDP วันหยุดต่าง ๆ และมีผลลัพธ์เป็น 1 ตัวแปรคือยอดขายในแต่ละวัน

แบบจำลองโครงข่ายประสาทเทียมแบบ Feed Forward Backpropagation Neural Network (FBPNN) จะมีการรับข้อมูลเข้ามาจาก Training set แล้วจะส่งต่อไปยังนิเวศในชั้นถัดไปหรือชั้นซ่อนผ่านทางเครือข่ายที่กำหนดค่าถ่วงน้ำหนักไว้ในแต่ละเส้นทางเพื่อคำนวณผลลัพธ์ในแต่ละนิเวศด้วยสมการกระตุ้นแบบ Sigmoid โดยในฟังก์ชันกระตุ้นซิกมอยด์นั้น จะเป็นผลรวมของแต่ละขาเข้าของข้อมูลคูณกับค่าถ่วงน้ำหนักของแต่ละขาโดยสมการดังนี้

$$O_k = f\left(\sum_{j=1}^2 y_j w_{jk} + \theta_k\right) \quad (3)$$

$$f(u) = \frac{1}{1 + e^{-u}} \quad (4)$$

โดยที่ O_k = ผลลัพธ์ที่นิเวศ K
 Y = ข้อมูลที่เข้ามาในนิเวศ
 W = ค่าถ่วงน้ำหนักของเส้นทางที่นำเข้าข้อมูล
 θ = ค่าความลำเอียงหรือ Bias
โดยครั้งแรกค่าถ่วงน้ำหนักจะเป็นค่าสุ่ม และเมื่อได้ผลลัพธ์ เราจะทำการปรับค่าน้ำหนักและค่าลำเอียงระหว่างชั้นเอาทพุต และชั้นซ่อน จากสมการดังต่อไปนี้

$$\delta = O(1 - O)(T - O) \quad (5)$$

$$\Delta W_{ik} = \eta \delta y_i \quad (6)$$

$$\Delta \theta = \eta \delta \quad (7)$$

ดังนั้นยังมีการเรียนรู้มากขึ้น โมเดลก็จะฉลาดขึ้น และมีความผิดพลาดน้อยลงไปเรื่อย ๆ เราจึงต้องมีการสอนในนิเวศต่อไปเรื่อย ๆ เพื่อที่ค่าถ่วงน้ำหนักถูกปรับไปจนทำให้ผล-

ลัทธิออกมาใกล้เคียงที่สุด จำนวนนิวรอนและในชั้นซ่อนก็เช่นกัน หากมีจำนวนมากก็จะช่วยให้โครงข่ายประสาทเทียมสามารถแยกแยะความแตกต่างได้มากขึ้นเช่นกัน แต่หากมีมากเกินไปก็จะมีปัญหาในการพยากรณ์ได้ เพราะโมเดลมีความอ่อนไหวเกินไป เหมือนสมองมนุษย์ที่คิดมากเกินไป ดังนั้นเพื่อให้ได้โมเดลจำลองโครงข่ายประสาทเทียมที่มีความแม่นยำที่สุด ผู้วิจัยต้องทดลองหาจำนวนชั้นซ่อนที่แตกต่างกันออกไป จำนวนค่าการฝึกสอน ค่าอัตราการเรียนรู้ ค่าโมเมนตัม ซึ่งมีได้หลายค่า ทำให้โมเดลสามารถมีความแตกต่างได้อย่างไม่จำกัด ทั้งนี้ผู้วิจัยจึงทดลองจึงจำกัดขอบเขตโดยกำหนดให้ จำนวนชั้นซ่อนมีค่าได้ตั้งแต่ 1 – 2 ชั้น และจำนวน Neural ในชั้นซ่อนมีค่าตั้งแต่ 4, 5, 6, 7, 8, 9, 10 และ วนรอบการเรียนรู้ที่ 200, 300, 400, 500, 700, 900, 1000, 1500 รอบ อัตราการเรียนรู้ที่ 0.1 – 0.2 และโมเมนตัมที่ 0.1 – 0.2 เช่นกัน ดังแสดงในตารางที่ 1

ตารางที่ 1. แสดงขอบเขตแบบจำลองที่ใช้สร้าง โมเดล

Input	ค่าเริ่มต้น	ค่าสิ้นสุด	จำนวนค่าที่จะเกิดขึ้นได้
จำนวน node ใน hidden layer ที่ 1	4	10	7
จำนวน node ใน hidden layer ที่ 2	0	10	8
Learn rate	0.1	0.2	2
Momentum	0.1	0.2	2
Learn cycle	200	1500	8

ดังนั้นจากการนำจำนวนค่าที่จะเกิดขึ้นได้ทั้งหมดมาคูณกัน จะได้ $7 \times 8 \times 2 \times 2 \times 8 = 1792$ ทำให้โอกาสที่จะเป็นไปได้จะเหลือเพียง 1792 รูปแบบ อย่างไรก็ตามก็ถึงจะมีการกำหนดขอบเขตไว้แล้ว แต่รูปแบบที่เกิดขึ้นดังกล่าวยังคงมีจำนวนมาก และการฝึกสอนโมเดลจำเป็นต้องใช้เวลานาน เนื่องจากจำนวนของชุดข้อมูลที่ใช้ในการฝึกสอนมีปริมาณมาก ผู้วิจัยจึงกำหนดตัวแปรด้วยการสุ่มหาค่าในการทดลองตอนแรก แล้วบันทึกผลการทดสอบเพื่อเก็บไว้เป็นข้อมูลในการสอนโมเดล หลังจากนั้นก็ทำการสร้างโมเดลโครงข่ายประสาทเทียมขึ้น โดยให้ข้อมูลนำเข้ามี 5 ตัวแปรตามตารางด้านที่ 2 และผลลัพธ์คือ

ความผิดพลาด เมื่อสอนโมเดลจากข้อมูลจากการสุ่มแล้วทดลองพยากรณ์หารูปแบบโมเดลที่ให้ค่าผิดพลาดน้อยที่สุด 10 อันดับไปสอนตัวเองอีกครั้ง ทำให้โมเดลมีความฉลาดมากขึ้น จนได้ผลพยากรณ์ของโมเดลทั้ง 1792 รูปแบบ โดยมีผลลัพธ์ดังตารางที่ 2

ตารางที่ 2. แสดงผลการพยากรณ์แบบจำลองที่ใช้สร้าง โมเดล

ค่าพยากรณ์	ค่าจริงจากการทดสอบ	Learn Cycle	Learn Rate	Momentum	L1	L2
165.101	888.958	200	0.2	0.2	7	9
594.878	826.527	200	0.2	0.2	9	10
653.953	756.365	200	0.1	0.2	9	5
702.414	754.079	200	0.1	0.2	9	0
715.454	715.454	300	0.1	0.1	7	8
716.939	786.793	200	0.1	0.2	10	0
721.357	772.415	700	0.1	0.1	9	0
746.448	686.489	200	0.1	0.2	9	6
750.653	740.131	200	0.1	0.2	9	4
774.632	781.794	300	0.1	0.1	10	0

โดยที่ L1 = แทนจำนวน node ใน hidden layer ที่ 1
L2 = แทนจำนวน node ใน hidden layer ที่ 2

2.8 ทดสอบแบบจำลอง

นำผลการทดลองจากตารางที่ 1 ไปสร้างโมเดลพยากรณ์แล้ววัดผลประสิทธิภาพความแม่นยำของโมเดล


การทดสอบแบบจำลองเพื่อหาประสิทธิภาพหรือความแม่นยำของแบบจำลองนั้นทำได้โดยการหาค่าความคลาดเคลื่อนเฉลี่ยยกกำลังสอง โดยที่ การหาค่าความคลาดเคลื่อนเฉลี่ยยกกำลังสองหาได้โดยสมการด้านล่างนี้

$$SSE = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (9)$$

ในการคำนวณค่าความแปรปรวนของตัวอย่างทำโดยการหาค่าของค่าเฉลี่ย โดยของค่าเฉลี่ยของ SEE เท่ากับ $n-2$ เนื่องจากการสูญเสียองศาเสรีไป 2 ค่าในการประมาณค่าพารามิเตอร์ β_0 และ β_1 ด้วย b_0 และ b_1 ดังนั้น

$$MSE = \frac{SSE}{n - 2} \quad (10)$$

จากการทดสอบวัดประสิทธิภาพนั้น พบว่าโมเดลที่ให้ความผิดพลาดน้อยที่สุดคือ โมเดลที่มีรูปแบบของจำนวนนิวรอนในชั้นซ่อนที่หนึ่งเท่ากับ 9 จำนวนนิวรอนในชั้นซ่อนที่สองเท่ากับ 6 รอบการเรียนรู้เท่ากับ 200 อัตราการเรียนรู้ 0.1 และค่าถ่วงน้ำหนักเท่ากับ 0.2 มีค่าความผิดพลาดเมื่อวัดความแม่นยำกับชุดข้อมูลทดสอบระยะเวลา 6 เดือนคือ 686.489



รูปที่ 4. แสดงแบบจำลองโครงข่ายประสาทเทียมในการพยากรณ์ยอดขาย

2.9 การพยากรณ์ยอดขาย

จากผลการวัดประสิทธิภาพในข้อที่ 3.4 ทำให้เราทราบว่าโมเดลรูปแบบใด เหมาะสมกับการพยากรณ์ เราจึงสอนโมเดลนั้นต่อไปด้วยข้อมูลที่เหลือทั้งหมด และพยากรณ์ยอดขายข้างหน้าไปอีก 3 เดือน


3. ผลการทดลอง

ผลการทดสอบรูปแบบโครงข่ายประสาทเทียมที่ดีที่สุด 10 รูปแบบโดยกำหนดจำนวนชั้นซ่อน จำนวน Neural ในชั้นซ่อนที่ 1 และที่ 2 วนรอบการเรียนรู้ อัตราการเรียนรู้ และโมเมนตัมตามตารางที่ 2 และผลที่ได้คือ สามารถพยากรณ์ที่มีค่าผิดพลาดเฉลี่ย(RMSE)เท่ากับ 686 ต่อวัน โดยที่ขายเฉลี่ยประมาณอยู่ที่ 9000 ต่อวัน หรือมีความแม่นยำเท่ากับ 89 % และสามารถนำโมเดลดังกล่าวไปพยากรณ์ยอดขายยอดขายล่วงหน้าได้ 3 เดือน หรือ 90 วัน โดยมีผลดังตารางที่ 3

ตารางที่ 3. แสดงผลการพยากรณ์ยอดขายข้างหน้าด้วยโมเดลที่พัฒนาขึ้นมา

Date	Predict	Date	Predict	Date	Predict
Jan 01	7725.05	Jan 31	8013.70	Mar 02	8084.21
Jan 02	7726.65	Feb 01	8015.83	Mar 03	7835.55
Jan 03	7956.14	Feb 02	8017.96	Mar 04	7837.47
Jan 04	7958.12	Feb 03	8020.10	Mar 05	7839.39
Jan 05	7960.12	Feb 04	8022.24	Mar 06	8093.36
Jan 06	7962.11	Feb 05	7783.96	Mar 07	8095.66
Jan 07	7964.12	Feb 06	7785.74	Mar 08	8097.97
Jan 08	7736.32	Feb 07	8028.70	Mar 09	8100.28
Jan 09	7737.96	Feb 08	8030.86	Mar 10	7849.05
Jan 10	7970.15	Feb 09	8033.03	Mar 11	7851.00
Jan 11	7972.18	Feb 10	8035.20	Mar 12	7852.95
Jan 12	7974.20	Feb 11	8037.38	Mar 13	8109.56
Jan 13	7976.24	Feb 12	7796.49	Mar 14	8111.90
Jan 14	7978.28	Feb 13	7798.30	Mar 15	8114.23
Jan 15	7747.85	Feb 14	8043.94	Mar 16	8116.58
Jan 16	7749.52	Feb 15	8046.14	Mar 17	7862.79
Jan 17	7984.42	Feb 16	8048.34	Mar 18	7864.77
Jan 18	7986.48	Feb 17	8050.54	Mar 19	8123.63
Jan 19	7988.54	Feb 18	8052.75	Mar 20	8125.99
Jan 20	7990.61	Feb 19	7809.27	Mar 21	8128.35
Jan 21	7992.69	Feb 20	7811.12	Mar 22	8130.72
Jan 22	7759.64	Feb 21	8059.42	Mar 23	8133.10
Jan 23	7761.34	Feb 22	8061.65	Mar 24	7876.76
Jan 24	7763.05	Feb 23	8063.88	Mar 25	7878.77
Jan 25	8001.03	Feb 24	8066.12	Mar 26	8140.24
Jan 26	8003.13	Feb 25	8068.37	Mar 27	8142.63
Jan 27	8005.23	Feb 26	7822.29	Mar 28	8145.03
Jan 28	8007.34	Feb 27	7824.17	Mar 29	8140.24
Jan 29	7771.67	Feb 28	8075.13	Mar 30	8142.63
Jan 30	7773.41	Mar 01	8081.93	Mar 31	8145.03

และเพื่อให้มั่นใจโมเดลที่ใช้ในการพยากรณ์นั้นมีประสิทธิภาพและน่าเชื่อถือ ในการทดสอบโมเดลด้วยวิธี Cross Validation ที่ค่า Fold เท่ากับ 10 ครั้ง ผลที่ได้คือโมเดลมีค่า RMSE เท่ากับ 1220.92 ดังรูปที่ 5 ที่แสดงกราฟเปรียบเทียบผลพยากรณ์กับชุดข้อมูลสอน ซึ่งจะเห็นได้ว่าผลการพยากรณ์นั้นจะเกาะกลุ่มกับกับข้อมูลสอนได้เป็นอย่างดี



รูปที่ 5. แสดงกราฟเปรียบเทียบผลพยากรณ์กับชุดข้อมูลสอน

4. บทสรุป

งานวิจัยนี้ได้มีความมุ่งหวังเพื่อพยากรณ์ยอดขายแก๊ส LPG ด้วยวิธีการสร้างโมเดลจำลองด้วยการวิเคราะห์ข้อมูลอนุกรมเวลา ด้วยวิธีการแบบโครงข่ายประสาทเทียมซึ่งมีลักษณะการเรียนรู้แบบแพร่กระจายย้อนกลับ โดยนำข้อมูลย้อนหลังเป็นระยะเวลา 5 ปี คือตั้งแต่ พ.ศ. 2555 – 2559 มาทดลองสร้างแบบจำลอง โดยทดสอบกับแบบจำลองหลายแบบแล้วบันทึกผล และจึงนำผลการทดลองไปสร้างเป็นโมเดลการสร้างโมเดลอีกครั้งเพื่อหาความเป็นไปได้ที่ดีที่สุดที่จะสร้างแบบจำลองการพยากรณ์ยอดขายแก๊ส LPG ในแต่ละวัน หลังจากนั้นนำแบบจำลองที่ดีที่สุด 10 อันดับ ไปทดลองสร้างแบบจำลองได้อย่างมีประสิทธิภาพ

อย่างไรก็ดี การวิธีการที่ผู้วิจัยนำเสนอนี้สามารถนำไปใช้กับงานพยากรณ์อื่น ๆ ได้ เพราะโมเดลที่ใช้สร้างโมเดลขึ้นมา สามารถเรียนรู้ได้ ทำให้ผู้วิจัยลดระยะเวลาในการหาโมเดลที่ดีที่สุด

เอกสารอ้างอิง

[1] MD Zakaria Rahman, “Forecasting the Long Term Energy Demand of Bangladesh using SPSS 2011-2040”, *3rd International Conference on Electrical Engineering and*

Information Communication Technology (ICEEICT), March 2016. pp. 1-5

[2] Iwan Awaludin, “A Prediction of Oil Demand in Malaysia Using Time Series Modeling approach”, *2008 International Symposium on Information Technology*, Vol. 3, September 2008. pp. 1-4

[3] Minjie Zhu, “Research of Product Oil Demand Forecast Based on the Combination Forecast Method”, *2010 International Conference on E-Business and E-Government*, May 2010. pp. 796-798

[4] Chengli Zhang, “Analysis and Forecasting of Oil Demand in China”, *2010 International Conference on E-Business and E-Government*, September 2010. pp. 5078-5081

[5] Seyedeh Mahya Seyedan, “Performance analysis and forecasting on Crude Oil: Novel Support Vector Regression application to market demand”, *2015 International Conference on Soft Computing Techniques and Implementations (ICSCTI)*, vol. 3, June 2016. pp. 126-130

[6] Mustafa Akpinar and Nejat Yumusak, “Forecasting Household Natural Gas Consumption with ARIMA Model: A Case Study of Removing Cycle”, *2013 7th International Conference on Application of Information and Communication Technologies*, January 2014. pp. 1-6

[7] Yi-Hui Liang, “Using the combined model for forecasting the tourism demand”, *2016 International Conference on Machine Learning and Cybernetics (ICMLC)*, vol. 2, March 2017. pp. 612-615

[8] Xiaoxiao Guo, “A Prediction-Based Inventory Optimization Using Data Mining Models”, *2014 Seventh International Joint Conference on Computational Sciences and Optimization*, October 2014. pp. 611-615

[9] Thararat Udomchaibanjerd, “NAV Forecasting Model Using Data Mining and Artificial Neural Network”, *The Tenth National Conference on Computing and Information Technology 2014*, May 2014. pp. 890-895