

การพยากรณ์ความต้องการสินค้าด้วยเทคนิคการเรียนรู้ของเครื่องในธุรกิจค้าปลีก

FORECASTING THE GOODS DEMAND THROUGH A LEARNING-BASED MACHINE IN RETAIL BUSINESSES

ชุตินันท์ ภัคคิสิโรตม์¹

เอกสิทธิ์ พัทธวงศ์ศักดิ์²

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อหาวิธีการหรือเทคนิคการพยากรณ์ข้อมูลที่ดีที่สุด สำหรับการคาดการณ์ความต้องการสินค้าของหมวดหมู่และรายการของผลิตภัณฑ์ที่ขายดีที่สุดในร้านค้าแห่งหนึ่ง โดยใช้วิธีการพยากรณ์การวิเคราะห์อนุกรมเวลา (Time Series Analysis) ด้วยวิธีการพยากรณ์ด้วยวิธี Autoregressive Integrated Moving Average (ARIMA) และวิธีปรับเรียบเอกซ์โพเนนเชียลของวินเทอร์ (Holt-Winters' Exponential Smoothing) กับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) 6 เทคนิค ดังนี้ 1. เทคนิคตัวแบบเชิงเส้นทั่วๆไป (Generalized Linear Model) 2. เทคนิคการเรียนรู้เชิงลึก (Deep Learning) 3. เทคนิคต้นไม้ตัดสินใจ (Decision Tree) 4. เทคนิคป่าสุ่ม (Random Forest) 5. เทคนิคต้นไม้กาเดียนบูตสเทท (Gradient Boosted Trees) และ 6. เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) มาใช้ในการพยากรณ์ข้อมูล โดยทำการเปรียบเทียบประสิทธิภาพของแต่ละเทคนิคว่าเทคนิคใดให้ผลลัพธ์ที่มีประสิทธิภาพดีที่สุด มีความเหมาะสมกับข้อมูล ให้ความคลาดเคลื่อนในการพยากรณ์ต่ำที่สุดเพื่อนำไปประยุกต์ใช้ได้จริงกับข้อมูลชุดใหม่ ซึ่งจากผลการทดลองเมื่อพิจารณาประสิทธิภาพของแบบจำลอง เมื่อนำชุดข้อมูลทั้งหมดมาทำการสร้างแบบจำลองด้วยวิธีการและเทคนิคข้างต้น และกำหนดลักษณะ รวมถึงปัจจัยของการพยากรณ์เหมือนกัน เช่น พยากรณ์ 1-3 วัน ข้างหน้า และพิจารณาข้อมูลย้อนหลัง 7-14 วัน ประกอบกับการเพิ่มตัวแปรภายนอก เช่น วันของสัปดาห์, วันทำการและวันหยุด รวมทั้งสัปดาห์ของวัน พบว่าเทคนิคการเรียนรู้ของเครื่องมีประสิทธิภาพที่ดีกว่าวิธีการวิเคราะห์อนุกรมเวลา เนื่องจากวิธีการทำงานและพารามิเตอร์ของทั้งสองแบบมีความแตกต่างกัน

¹ นักศึกษาหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมข้อมูลขนาดใหญ่

² ที่ปรึกษาสารนิพนธ์หลัก

สำหรับงานวิจัยนี้พบว่าเทคนิคการเรียนรู้ของเครื่องด้วยแบบจำลอง Gradient Boosted Trees เป็นเทคนิคที่ดีที่สุด ซึ่งทำการเปรียบเทียบและวัดประสิทธิภาพโดยใช้เกณฑ์ค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error, MAPE) เป็นหลัก ประกอบกับค่าเฉลี่ยของค่าสัมบูรณ์ความคลาดเคลื่อน (Mean Absolute Error, MAE) และค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error, RMSE) โดยผลการวัดประสิทธิภาพด้วยค่าดังกล่าว มีค่า MAPE ต่ำที่สุด อยู่ระหว่าง 14.90% - 33.10%, ค่า MAE คือ 21.74 - 50.72 และ RMSE คือ 30.36 - 61.56 ตามลำดับ ดังนั้นเทคนิคนี้จึงมีประสิทธิภาพมากที่สุดและมีความเหมาะสมกับข้อมูลที่น่ามาใช้สร้างแบบจำลองสำหรับการพยากรณ์มากที่สุด

คำสำคัญ : การคาดการณ์ความต้องการสินค้า, การวิเคราะห์หอนุกรมเวลา, การเรียนรู้ของเครื่อง, ต้นไม้กาเดียนบูตสเตรท

ABSTRACT

The models for this experiment to compare performance were Time Series Analysis, which consists of Autoregressive Integrated Moving Average (ARIMA) and Holt-Winters Method, and the six-model ensemble of Machine Learning techniques, namely-Generalized Linear Model, Deep Learning, Decision Tree, Random Forest, Gradient Boosted Trees, and Support Vector Machines. A model showing ultimate accuracy could be applied to forecast future datasets. In this experiment, two datasets were utilized for analysis and building models: data on the daily of the highest selling product categories and data on the daily best-selling product items in store. The product quantity was predicted in the next 1 to 3 days, considering 7 to 14 days of the historical data. Furthermore, the new features were established as the external variables, namely-weekdays, weekends, and week of month. The performance comparison between the models was based on the lowest Mean Absolute Percentage Error (MAPE), which is the main criteria, Mean Absolute Error (MAE), and Root Mean Square Error

(RMSE). The results showed the lowest MAPE, MAE, and RMSE ranged from 14.90% to 33.10%, 21.74 to 50.72, and 30.36 to 61.56, respectively.

Gradient Boosted Trees, one of the models of Machine Learning techniques, showed ultimately accurate results in this experiment that could be applied to forecast future datasets and be considered as the best demand forecasting technique for predicting product demand in retail.

Keywords: Demand Forecasting, Time Series Analysis, Machine Learning, Gradient Boosted Trees

บทนำ

การคาดการณ์ความต้องการสินค้าของลูกค้า (Demand Forecasting) เป็นสิ่งจำเป็นและมีบทบาทที่สำคัญมากในการจัดการและบริหารปริมาณของคลังสินค้าในกลุ่มอุตสาหกรรมต่าง ๆ โดยเฉพาะอย่างยิ่งในกลุ่มธุรกิจค้าปลีก ซึ่งการคาดการณ์ความต้องการสินค้าเป็นการทำนายความต้องการสินค้าหรือการบริการของลูกค้าในช่วงเวลาที่กำหนดซึ่งเกิดขึ้นในอนาคต โดยเป็นกระบวนการสำคัญในการสร้างผลกำไรหรือทำให้เกิดการขาดทุนในการดำเนินการตลอดจนการคาดการณ์ความต้องการของลูกค้าล่วงหน้า จะช่วยให้บริษัทสามารถกำหนดทิศทางในการดำเนินงานในการผลิตหรือสต็อกสินค้า อีกทั้งจัดเตรียมบุคลากรและอุปกรณ์ในการดำเนินการโดยนำข้อมูลที่เกิดขึ้นในอดีตมาพิจารณาและวิเคราะห์ถึงแนวโน้มที่จะเกิดขึ้นในอนาคต ซึ่งถ้าหากมีการทำนายที่แม่นยำมากเพียงใด ก็จะมีประโยชน์และมีส่วนช่วยต่อการดำเนินการจัดการสต็อกที่เหมาะสมของสินค้าหรือบริการนั้น ๆ เป็นอย่างมาก อีกทั้งยังช่วยเพิ่มโอกาสในการขายสินค้าเพื่อให้ได้กำไรที่สูงสุดอีกด้วย

งานวิจัยนี้จึงมีวัตถุประสงค์เปรียบเทียบวิธีการหรือเทคนิคการพยากรณ์ข้อมูลเพื่อคาดการณ์ปริมาณความต้องการสินค้าสำหรับหมวดหมู่ของผลิตภัณฑ์ที่ขายติดอันดับ 1 ใน 3 ในร้านค้าแห่งหนึ่ง ซึ่งมีสาขาต่าง ๆ มากมาย และอยู่ในกลุ่มอุตสาหกรรมธุรกิจค้าปลีก โดยใช้วิธีการพยากรณ์ด้วยการวิเคราะห์อนุกรมเวลาด้วยตัวแบบ Autoregressive Integrated Moving Average (ARIMA) และวิธีของโฮลต์-วินเทอร์ (Holt-Winter Method) กับเทคนิคการเรียนรู้ของเครื่อง ดังนี้ 1. เทคนิคตัวแบบเชิงเส้นน้อยทั่วไป 2. เทคนิคการเรียนรู้เชิงลึก 3. เทคนิคต้นไม้ตัดสินใจ 4. เทคนิคป่าสุ่ม 5. เทคนิคต้นไม้กาเดียนบูทสเตรท และ 6. เทคนิคซัพพอร์ตเวกเตอร์แมชชีน มาใช้ในการพยากรณ์ข้อมูล โดยมีจุดประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแต่ละเทคนิคว่าเทคนิคใดให้ผลลัพธ์ที่มีประสิทธิภาพดีที่สุด มีความ

เหมาะสมกับข้อมูลให้ความคลาดเคลื่อนในการพยากรณ์ต่ำที่สุดเพื่อนำไปประยุกต์ใช้ได้จริงกับข้อมูลชุดใหม่ ที่มีลักษณะคล้ายคลึงกับข้อมูลที่ใช้ในการวิจัย เพื่อทำการพยากรณ์ต่อไปได้

ข้อมูลที่นำมาพยากรณ์จะใช้ชุดข้อมูลการขายสินค้าหรือผลิตภัณฑ์ และสร้างตัวแปรต่าง ๆ เพิ่มเติม ซึ่งนำมาประมวลผลเพื่อสร้างแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่อง โดยใช้ตัวชี้วัดการประเมินผลด้วยค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error, MAPE) เป็นหลัก ประกอบกับค่าเฉลี่ยของค่าสัมบูรณ์ความคลาดเคลื่อน (Mean Absolute Error, MAE) และค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error, RMSE)

วัตถุประสงค์ของงานวิจัย

1. เพื่อเปรียบเทียบเทคนิคการพยากรณ์ข้อมูลด้วยวิธีการวิเคราะห์อนุกรมเวลา (Time Series Analysis) กับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning Technique) ที่มีประสิทธิภาพมากที่สุด และมีความคลาดเคลื่อนที่ต่ำที่สุด สำหรับการคาดการณ์ความต้องการสินค้าหรือบริการในอนาคต
2. เพื่อทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่องแบบต่าง ๆ เมื่อทำการโดยการเพิ่มตัวแปรภายนอกที่มีคุณลักษณะต่าง ๆ เช่น วันของสัปดาห์ (Day of week) วันทำการ (Weekday) และวันหยุดของสัปดาห์ (Weekend) และสัปดาห์ของเดือน (Week of Month)

ขอบเขตงานวิจัย

1. ข้อมูลกรณีศึกษาที่นำมาใช้ในงานวิจัย
 - 1.1 ข้อมูลยอดขายจริงรายวันของร้านค้าที่มีการขายสินค้าตั้งแต่วันที่ 24 มีนาคม พ.ศ. 2553 ถึงวันที่ 28 มีนาคม พ.ศ. 2555 ซึ่งรวบรวมข้อมูลระยะเวลาประมาณ 2 ปี โดยมีตัวแปรต่าง ๆ เช่น วัน เวลา และสัปดาห์ที่ขายสินค้า รหัสสินค้า ปริมาณการสินค้า มูลค่าการขาย รหัสสาขา
 - 1.2 ข้อมูลของสินค้าหรือผลิตภัณฑ์ ซึ่งแสดงรายละเอียดไว้ในตัวแปรต่าง ๆ เช่น รหัสสินค้า แผนกของสินค้า ประเภทของสินค้า รายการสินค้า แบรนส์สินค้า และขนาดของสินค้า เป็นต้น
2. เตรียมข้อมูลให้อยู่ในรูปแบบที่พร้อมสำหรับการนำวิเคราะห์และสร้างแบบจำลองด้วยการวิเคราะห์แบบเทคนิคต่าง ๆ
3. สร้างแบบจำลองการพยากรณ์ข้อมูล
 - 3.1 สร้างแบบจำลองพยากรณ์ข้อมูลด้วยวิธีการวิเคราะห์อนุกรมเวลา (Time Series Analysis)

3.2 สร้างแบบจำลองพยากรณ์ข้อมูลด้วยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ในเทคนิคต่าง ๆ

4. ทำการวัดประสิทธิภาพของแต่ละแบบจำลองโดยพิจารณาจากค่าความคลาดเคลื่อนด้วยค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error, MAPE) เป็นหลัก ประกอบกับค่าเฉลี่ยของค่าสัมบูรณ์ความคลาดเคลื่อน (Mean Absolute Error, MAE) และค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error, RMSE)

5. เปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์ข้อมูล และนำเสนอแบบจำลองที่มีประสิทธิภาพดีที่สุด ซึ่งเป็นเทคนิคที่เหมาะสมกับชุดข้อมูล

ทฤษฎี และผลงานที่เกี่ยวข้อง

การพยากรณ์ข้อมูลโดยใช้วิธีการวิเคราะห์อนุกรมเวลาและเทคนิคการเรียนรู้ของเครื่องเพื่อทำการวิเคราะห์และสร้างแบบจำลอง ซึ่งวิธีการที่ใช้ในงานวิจัยด้วยเทคนิคต่าง ๆ มีดังต่อไปนี้

1. การพยากรณ์ในรูปแบบอนุกรมเวลา

การวิเคราะห์อนุกรมเวลา (Time Series Analysis) ซึ่งเป็นวิธีการอาศัยข้อมูลจากอดีตเพื่อการพยากรณ์หรือคาดหมายสิ่งที่เกิดขึ้นในอนาคต

1.1 การพยากรณ์ด้วยเทคนิค Autoregressive integrated moving average (ARIMA)

เทคนิคพยากรณ์วิเคราะห์ข้อมูลอนุกรมเวลาอาศัยพฤติกรรมของข้อมูลในอดีตเพื่อกำหนดรูปแบบในปัจจุบัน และอธิบายแนวโน้มหรือปรากฏการณ์ต่างๆ ของตัวข้อมูลเองในอนาคตโดยการหารูปแบบที่เหมาะสมให้กับข้อมูลเพื่อใช้ในการพยากรณ์โดยจะใช้เกณฑ์ AIC เลือกแบบจำลองที่ให้ค่า AIC น้อยที่สุดเป็นแบบจำลองที่ใช้ของข้อมูลอนุกรมเวลาที่พิจารณา

(ผศ.ดร. เฉลิมพล, 2562) แบบจำลอง ARIMA ประกอบด้วยองค์ประกอบ 3 ส่วน คือ

1. AR(p) คือ Y_t ที่ถูกกำหนดด้วย Autoregressive process
โดย $Y_t = Y_{t-1}, Y_{t-2}, \dots, Y_p$
2. I(d) คือ อันดับความหุคหนึ่งของ Y_t
โดย $d = 0, 1, 2, \dots, d$
3. MA(q) คือ Y_t ที่ถูกกำหนดด้วย Moving average process
โดย $Y_t = \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_q$

p และ q หมายถึง ลำดับของคาบเวลาในอดีต (Lag length) ที่เหมาะสม

1.2 การพยากรณ์ด้วยวิธีการโฮลท์-วินเทอร์ (Holt-Winter method)

วิธีการสร้างสมการพยากรณ์สำหรับอนุกรมเวลาที่มีการเคลื่อนไหวเนื่องจากแนวโน้มและมีอิทธิพลของฤดูกาล ซึ่งเป็นวิธีการปรับให้เรียบแบบเอกซ์โพเนนเชียลสามเท่าใช้การปรับให้เรียบแบบเอกซ์โพเนนเชียลสามครั้ง

2. เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Technique)

2.1 ตัวแบบเชิงเส้นนัยทั่วไป (Generalized Linear Model)

วิธีการวิเคราะห์ทางสถิติที่นิยามกันอย่างแพร่หลาย เนื่องจากเป็นรูปแบบที่ง่ายและไม่ซับซ้อนเกินไป โดยวิธีนี้มีแนวคิดเพื่อหาความสัมพันธ์ระหว่างตัวแปรต้นและตัวแปรตามที่ไม่มีข้อจำกัดว่ากระจายตัวของค่าความคลาดเคลื่อนในตัวแปรตาม จะต้องเป็นแบบปกติเท่านั้น และข้อมูลที่นำมาวิเคราะห์หาความสัมพันธ์เป็นได้ทั้งข้อมูลตัวเลขและไม่เป็นตัวเลข

2.2 การเรียนรู้เชิงลึก (Deep Learning)

วิธีการของการเรียนรู้ด้วยเครื่องที่สามารถประมวลผลข้อมูลจำนวนมากด้วยการจำลองเครือข่ายที่เหมือนกับในสมองของมนุษย์ ซึ่งประกอบด้วยเซลล์ประสาทหรือโหนด (Node) ที่ถูกแบ่งออกเป็นชั้น โดยแต่ละเซลล์มีการเชื่อมโยงกันเป็นโครงข่ายและให้ผลลัพธ์ที่ช่วยในการตัดสินใจหรือคาดการณ์ได้ใกล้เคียงกับมนุษย์

2.3 ต้นไม้ตัดสินใจ (Decision Tree)

วิธีการเรียนรู้ของเครื่องที่นำเอาข้อมูลมาสร้างแบบจำลองเพื่อการทำนายหรือพยากรณ์ในรูปแบบของโครงสร้างต้นไม้ที่มีลักษณะจากบนลงล่าง โดยมีเป้าหมายคือการสร้างแบบจำลองที่คาดการณ์ค่าของตัวแปรตามโดยการเรียนรู้กฎการตัดสินใจอย่างง่ายที่อนุมานจากคุณลักษณะข้อมูลโดยจำลองแผนผังการตัดสินใจโดยเลือกแอตทริบิวต์ที่มีอิทธิพลต่อการจำแนกข้อมูลสูงที่สุด (Root node) ไปยังโหนดถัดไปจนกว่าจะไม่มีเงื่อนไขให้ไปต่อ นั่นคือถึง ใบ (Leaf node)

2.4 ป่าสุ่ม (Random Forest)

วิธีการเรียนรู้ของเครื่องที่ใช้พื้นฐานพัฒนามาจากต้นไม้ตัดสินใจในการทำนายในรูปแบบชุดของต้นไม้ตัดสินใจ หลาย ๆ ต้น (Ensemble of Decision Trees) โดยสร้างจากการสุ่มข้อมูลตัวอย่างแบบเลือกแล้วใส่กลับ (random sampling with replacement) เพื่อนำมาสร้างเป็นแบบจำลองต้นไม้โดยแต่ละ

ต้นไม้ลักษณะที่ไม่ซ้ำกัน โดยแต่ละแบบจะจำลองจะมีการทำนายผลซึ่งผลจากการทำนายของต้นไม้แต่ละต้นจะทำการโหวตเลือกผลการทำนายที่ได้รับการโหวตมากที่สุด

2.5 ต้นไม้กาเดียนบูตสเตรท (Gradient Boosted Trees)

วิธีการเรียนรู้ของเครื่องที่มีพื้นฐานมาจากต้นไม้ตัดสินใจซึ่งเป็นการปรับปรุงประสิทธิภาพของแบบจำลองให้มีค่าสูงขึ้น โดยการสุ่มสร้างต้นไม้ตัดสินใจหลายร้อยแบบจำลอง และประเมินผลแต่ละแบบจำลองจนกว่า จะได้ต้นไม้ตัดสินใจที่สมบูรณ์

2.5 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine)

วิธีการเรียนรู้ของเครื่องที่สามารถนำมาช่วยแก้ปัญหาการจำแนกข้อมูล โดยเป็นวิธีที่ใช้ในการวิเคราะห์ข้อมูลและจำแนกข้อมูล ซึ่งอาศัยหลักการของการหาสัมประสิทธิ์ของสมการเพื่อสร้างเส้นแบ่งแยกกลุ่มข้อมูลที่ถูกต้องเข้าสู่กระบวนการสอนให้ระบบเรียนรู้ โดยเน้นไปยังเส้นแบ่งแยกยะกลุ่มข้อมูลได้ดีที่สุด

3. เปรียบเทียบค่าความคลาดเคลื่อนในการประเมินผลการพยากรณ์

ตัวชี้วัดในการประเมิน โดยใช้ความคลาดเคลื่อนของตัวแบบพยากรณ์ ซึ่งใช้เกณฑ์ค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error: MAPE) , ค่าเฉลี่ยของค่าสัมบูรณ์ความคลาดเคลื่อน (Mean Absolute Error: MAE) และค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error: RMSE) โดยค่าความคลาดเคลื่อนดังกล่าวสามารถคำนวณได้จากสมการที่ 2.1, 2.2 และ 2.3 ดังนี้

สมการที่ 2.1 การหาค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error: MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad \dots\dots\dots(2.1)$$

สมการที่ 2.2 การหาค่าเฉลี่ยของค่าสัมบูรณ์ความคลาดเคลื่อน (Mean Absolute Error: MAE)

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad \dots\dots\dots(2.2)$$

สมการที่ 2.3 การหาค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error: RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad \dots\dots\dots(2.3)$$

เมื่อ n คือ จำนวนตัวอย่าง, Y_t คือ ข้อมูลจริง ณ เวลา t, $\hat{Y}_t$ คือ ค่าพยากรณ์ของข้อมูล ณ เวลา t

โดยเกณฑ์ที่ใช้สำหรับการพยากรณ์ MAPE มีดังนี้

- ค่า MAPE น้อยกว่า 10% : การพยากรณ์ค่อนข้างแม่นยำ
- ค่า MAPE อยู่ระหว่าง 10% - 20% : การพยากรณ์ใช้ได้
- ค่า MAPE อยู่ระหว่าง 20% - 50% : การพยากรณ์พอใช้
- ค่า MAPE มากกว่า 50% : การพยากรณ์ไม่แม่นยำ

4. งานวิจัยที่เกี่ยวข้อง

นิลา แก้วหาญ (2547) ในงานวิจัยนี้ได้นำเสนอการพยากรณ์ข้อมูลอนุกรมเวลาโดยวิธีการทำให้เรียบแบบเอกซ์โพเนนเชียลและวิธีการของบ็อกซ์-เจนกินส์ของการพยากรณ์มูลค่าการส่งออกข้าว ยางพารา และมันสำปะหลังพบว่าแบบจำลอง ARIMA โดยวิธีการของบ็อกซ์-เจนกินส์ เป็นแบบจำลองที่ดีที่สุดโดยให้ความคลาดเคลื่อนต่ำสุด

Claudimar Pereira Da Veiga, Cássia Rita Pereira Da Veiga, Anderson Catapan, Ubiratã Tortato and Wesley Vieira Da Silva (2557) ได้นำเสนอวิธีการคาดการณ์ที่เหมาะสมสำหรับผลิตภัณฑ์อาหารที่มีอายุสั้นและเน่าเสียได้ง่าย โดยทำการเปรียบเทียบแบบจำลอง ARIMA และ วิธีปรับเรียบเอกซ์โพเนนเชียลแบบ Holt-Winter สำหรับการทำนายอนุกรมเวลาที่เกิดจากกลุ่มผลิตภัณฑ์นมที่เน่าเสียง่าย และวัดประสิทธิภาพ โดยใช้ค่า Mean Absolute Percentage Error (MAPE) และดัชนีของ Theil inequality (U-Theil) โดยจากผลการศึกษาพบว่าวิธีปรับเรียบเอกซ์โพเนนเชียลแบบ Holt-Winter ได้ผลลัพธ์ที่มีประสิทธิภาพดีกว่า

Jakob Huber (2563) ได้นำเสนอการคาดการณ์การขายผลิตภัณฑ์ในกลุ่มร้านเบเกอรี่เพื่อช่วยในการวางแผนการสั่งซื้อวัตถุดิบและผลิตสินค้าให้เพียงพอต่อความต้องการของลูกค้ารายวัน ซึ่งมีการขายในวันพิเศษกับวันปกติแตกต่างกันมาก โดยใช้แบบจำลอง ANN และ GBT ซึ่งผลการศึกษาพบว่า GBT มีประสิทธิภาพดีกว่า นอกจากนี้ยังพบว่าวิธีการเรียนรู้ของเครื่องยังเหมาะสำหรับการใช้งานในสถานการณ์การคาดการณ์ความต้องการปริมาณที่มากที่มักเกิดขึ้นในอุตสาหกรรมค้าปลีก

Florian Haselbeck, Jennifer Killinger, Klaus Menrad, Thomas Hannus and Dominik G. Grimm (2564) ได้นำเสนอการคาดการณ์ยอดขายของพืชสวนชนิดต่าง ๆ เช่น ไม้กระถาง ดอกไม้ ไม้พุ่ม ซึ่งมีข้อจำกัดของระยะเวลาการเก็บรักษาที่สั้น และมีโอกาสสูงที่ต้องนำไปกำจัดหรือทำลายในกรณีที่ยขายไม่หมด โดยทำการเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องทั้งหมด 9 แบบจำลอง (LassoReg, RidgeReg, ElasticNet, ANN, LSTM, XGBoost, BayesRidge, ARD, GPR) กับ

การพยากรณ์โดยวิธีการทางอนุกรมเวลา 3 แบบ (ES, SARIMA, SARIMAX) โดยจากผลการทดลองแสดงให้เห็นว่าแบบจำลองที่ได้จากวิธีการเรียนรู้ของเครื่องโดยเทคนิค Gradient Boosted Tress (GBT) มีประสิทธิภาพที่ดีที่สุด โดยสำหรับชุดข้อมูลแรกมีค่า MAPE 34.21% และ RMSE 57.11 และชุดข้อมูลที่สองมีค่า MAPE 52.87% และ RMSE 43.48 ตามลำดับ

ระเบียบวิธีวิจัย

แนวทางการวิจัยนำหลักการ Cross-Industry Standard Process For Data Mining (CRISP-DM) ซึ่งเป็นกระบวนการมาตรฐานที่นิยมใช้ในการวิเคราะห์ข้อมูลสำหรับการทำเหมือง ข้อมูลมาประยุกต์ใช้ โดยกระบวนการทำงานในขั้นตอนการต่าง ๆ ตามกระบวนการของ CRISP-DM มีรายละเอียดดังนี้

1. การทำความเข้าใจกับธุรกิจ (Business Understanding)

ศึกษาและทำความเข้าใจเกี่ยวกับธุรกิจประเภทร้านค้าปลีกที่ต้องมีการจัดการคลังสินค้าโดยมีการขายสินค้าหลากหลายประเภทและแต่ละประเภทมีหลากหลายขนาด ซึ่งในแต่ละวันมีการขายสินค้าแต่ละประเภทได้ในปริมาณไม่เท่ากัน มีทั้งสินค้าที่ขายดีและขายไม่ดี ทำให้เกิดปัญหาในการจัดการคลังสินค้า เพื่อเตรียมสำรองสินค้าให้เพียงพอต่อการขาย

2. การทำความเข้าใจกับข้อมูล (Data Understanding)

พิจารณาข้อมูล que เลือกนำมาใช้ในการวิเคราะห์และสร้างแบบจำลอง โดยรวบรวมข้อมูลการขายสินค้าของร้านค้าซึ่งเป็นข้อมูลยอดขายรายวัน โดยทำการเลือกข้อมูลที่น่าสนใจดังนี้

2.1 ข้อมูลการขายสินค้า (Transaction) รายวันของร้านค้าที่มีการขายสินค้าตั้งแต่วันที่ 24 มีนาคม พ.ศ. 2553 ถึงวันที่ 28 มีนาคม พ.ศ. 2555 ซึ่งรวบรวมข้อมูลระยะเวลาประมาณ 2 ปี โดยมีตัวแปรต่าง ๆ เช่น วัน เวลา และสัปดาห์ที่ขายสินค้า รหัสสินค้า ปริมาณการสินค้า มูลค่าการขาย รหัสสาขา เป็นต้น

2.2 ข้อมูลของสินค้าหรือผลิตภัณฑ์ (Product) ซึ่งแสดงรายละเอียดไว้ในตัวแปรต่าง ๆ เช่น รหัสสินค้า แผนกของสินค้า ประเภทของสินค้า รายการสินค้า แบรินด์สินค้า และขนาดของสินค้า

3. การเตรียมข้อมูล (Data Preparation)

เตรียมข้อมูลให้พร้อมสำหรับการวิเคราะห์และสร้างแบบจำลอง โดยขั้นตอนการเตรียมข้อมูลประกอบด้วย ขั้นตอนต่าง ๆ ดังนี้

3.1 การคัดเลือกข้อมูล (Data Selection)

เลือกข้อมูลที่เป็นตัวเลขของข้อมูลที่ต้องการนำมาพยากรณ์มาใช้เนื่องจากเป็นการวิเคราะห์อนุกรมเวลาและการเรียนรู้ของเครื่อง ข้อมูลตัวอย่างดังกล่าวแสดงรายละเอียดดังภาพที่ 1

Row No.	DAY	Date	QUANTITY
1	1	Mar 24, 2010 12:00:00 AM ICT	15
2	2	Mar 25, 2010 12:00:00 AM ICT	6
3	3	Mar 26, 2010 12:00:00 AM ICT	49
4	4	Mar 27, 2010 12:00:00 AM ICT	46
5	5	Mar 28, 2010 12:00:00 AM ICT	25
6	6	Mar 29, 2010 12:00:00 AM ICT	13
7	7	Mar 30, 2010 12:00:00 AM ICT	23
8	8	Mar 31, 2010 12:00:00 AM ICT	26
9	9	Apr 1, 2010 12:00:00 AM ICT	13
10	10	Apr 2, 2010 12:00:00 AM ICT	46
11	11	Apr 3, 2010 12:00:00 AM ICT	38
12	12	Apr 4, 2010 12:00:00 AM ICT	35
13	13	Apr 5, 2010 12:00:00 AM ICT	17
14	14	Apr 6, 2010 12:00:00 AM ICT	27
15	15	Apr 7, 2010 12:00:00 AM ICT	30

ภาพที่ 1 ตัวอย่างข้อมูลที่ถูกคัดเลือกสำหรับการสร้างแบบจำลองด้วยวิธีการและเทคนิคต่าง ๆ

3.2 การแปลงรูปแบบข้อมูล (Data Transformation)

สร้างแอตทริบิวต์เพิ่มเติม โดยสร้างตัวแปรข้อมูลการขายย้อนหลัง 14 วัน จากข้อมูลของวันที่ (Date) และปริมาณการขายสินค้า (Quantity) รายวัน โดยแปลงข้อมูลการขายให้แสดงผล 14 วันย้อนหลังซึ่งแปลงข้อมูลให้เป็นการขายย้อนหลังวันละ 1 แอตทริบิวต์ (DAY – 0 ถึง DAY - 13) และสร้างตัวแปรภายนอกที่อาจจะมีผลต่อการพยากรณ์ จากข้อมูล วันที่ (Date) โดยเริ่มจากการแปลงข้อมูลให้เป็น Nominal (ตัวอักษร) สำหรับการสร้างตัวแปรวันของสัปดาห์ (Day of week) เช่น วันจันทร์ (Monday) ถึง วันอาทิตย์ (Sunday), วันทำการและวันหยุดของสัปดาห์ (Holiday) ซึ่งก็คือ วันทำการ (Weekday) และ วันหยุด (Weekend) และแปลงให้เป็นข้อมูลชนิด Numerical (ตัวเลข) สำหรับการสร้าง

ตัวแปรสัปดาห์ของเดือน (Week of Month) ให้อยู่ในรูปแบบของตัวเลข เช่น 1 แทนสัปดาห์ที่ 1 เป็นต้น โดยตัวอย่างข้อมูลดังกล่าวแสดงได้ดังภาพที่ 2

Row No.	Date	Day of Week	Holiday	Week of Month	DAY - 13	DAY - 12	DAY - 11	DAY - 10	DAY - 9	DAY - 8	DAY - 7	DAY - 6	DAY - 5	DAY - 4	DAY - 3	DAY - 2	DAY - 1	DAY - 0
1	Apr 6, 2010 ...	Tuesday	Weekday	2	1	2	3	4	5	6	7	8	9	10	11	12	13	14
2	Apr 7, 2010 ...	Wednesday	Weekday	2	2	3	4	5	6	7	8	9	10	11	12	13	14	15
3	Apr 8, 2010 ...	Thursday	Weekday	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
4	Apr 9, 2010 ...	Friday	Weekday	2	4	5	6	7	8	9	10	11	12	13	14	15	16	17
5	Apr 10, 2010...	Saturday	Weekend	2	5	6	7	8	9	10	11	12	13	14	15	16	17	18
6	Apr 11, 2010...	Sunday	Weekend	3	6	7	8	9	10	11	12	13	14	15	16	17	18	19
7	Apr 12, 2010...	Monday	Weekday	3	7	8	9	10	11	12	13	14	15	16	17	18	19	20
8	Apr 13, 2010...	Tuesday	Weekday	3	8	9	10	11	12	13	14	15	16	17	18	19	20	21
9	Apr 14, 2010...	Wednesday	Weekday	3	9	10	11	12	13	14	15	16	17	18	19	20	21	22
10	Apr 15, 2010...	Thursday	Weekday	3	10	11	12	13	14	15	16	17	18	19	20	21	22	23
11	Apr 16, 2010...	Friday	Weekday	3	11	12	13	14	15	16	17	18	19	20	21	22	23	24
12	Apr 17, 2010...	Saturday	Weekend	3	12	13	14	15	16	17	18	19	20	21	22	23	24	25
13	Apr 18, 2010...	Sunday	Weekend	4	13	14	15	16	17	18	19	20	21	22	23	24	25	26
14	Apr 19, 2010...	Monday	Weekday	4	14	15	16	17	18	19	20	21	22	23	24	25	26	27
15	Apr 20, 2010...	Tuesday	Weekday	4	15	16	17	18	19	20	21	22	23	24	25	26	27	28

ภาพที่ 2 ตัวอย่างข้อมูลการขายสินค้าสำหรับการนำไปสร้างแบบจำลองเพื่อพยากรณ์ข้อมูล

4. การสร้างแบบจำลอง (Modeling)

ขั้นตอนการวิเคราะห์ข้อมูลด้วยวิธีการและเทคนิคต่าง ๆ โดยนำข้อมูลที่เตรียมจากขั้นตอนก่อนหน้ามาทำการสร้างแบบจำลอง โดยสร้างแบบจำลองเป็น 2 กลุ่มหลัก คือ

4.1 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

1. แบบจำลอง ARIMA

สร้างแบบจำลอง ARIMA โดยใช้ค่า p, d, q เท่ากับ 1, 0 และ 1 ตามลำดับ โดยพิจารณาค่า AIC น้อยที่สุดเป็นแบบจำลองในการพยากรณ์

2. แบบจำลอง Holt-Winters

สร้างแบบจำลอง Holt-Winters โดยใช้ค่า α, β, γ เท่ากับ 0.5, 0.1 และ 0.5 ตามลำดับ โดยใช้ช่วงระยะเวลา (Length of one period) เท่ากับ 4 และใช้แบบจำลองของฤดูกาล (Seasonality Model) เป็น Additive โดยพิจารณาค่าความคลาดเคลื่อนสัมพัทธ์ (Relative Error) น้อยที่สุดเป็นแบบจำลองในการพยากรณ์

4.2 เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Techniques)

1. แบบจำลอง Generalized Linear Model

สร้างแบบจำลอง Generalized Linear Model โดยปรับเปลี่ยนน้ำหนัก (Weights) ของตัวแปรที่ใช้เป็นแบบจำลองในการพยากรณ์

2. แบบจำลอง Deep Learning

สร้างแบบจำลอง Deep Learning (H₂O version 3.30.0.1-rm9.8.1) โดยปรับเปลี่ยนพารามิเตอร์ต่าง ๆ เพื่อให้เครื่องเกิดการเรียนรู้และใช้เป็นแบบจำลองในการพยากรณ์

3. แบบจำลอง Decision Tree

สร้างแบบจำลอง Decision Tree ซึ่งมีค่า Maximum depth เท่ากับ 7 และปรับเปลี่ยนค่าต่าง ๆ เพื่อให้เครื่องเกิดการเรียนรู้และใช้เป็นแบบจำลองในการพยากรณ์

4. แบบจำลอง Random Forest

สร้างแบบจำลอง Random Forest ซึ่งมีค่า Maximum depth เท่ากับ 7 และ Number of Trees เท่ากับ 100 และปรับเปลี่ยนค่าต่าง ๆ เพื่อให้เครื่องเกิดการเรียนรู้และใช้เป็นแบบจำลองในการพยากรณ์

5. แบบจำลอง Gradient Boosted Trees

สร้างแบบจำลอง Gradient Boosted Trees ซึ่งมีค่า Maximum depth เท่ากับ 2 และ Number of Trees เท่ากับ 90 และ Learning Rate เท่ากับ 0.100 โดยปรับเปลี่ยนค่าต่าง ๆ เพื่อให้เครื่องเกิดการเรียนรู้และใช้เป็นแบบจำลองในการพยากรณ์

6. แบบจำลอง Support Vector Machine


สร้างแบบจำลอง Support Vector Machine ซึ่งใช้ Kernel Gamma เท่ากับ 0.005 และ C เท่ากับ 1000 และปรับเปลี่ยนค่าต่าง ๆ เพื่อให้เครื่องเกิดการเรียนรู้และใช้เป็นแบบจำลองในการพยากรณ์

5. การประเมินผล (Evaluation)

วัดประสิทธิภาพของผลลัพธ์โดยใช้ค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error, MAPE) ค่าเฉลี่ยของค่าสัมบูรณ์ความคลาดเคลื่อน (Mean Absolute Error, MAE) และค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error, RMSE) แสดงค่าความคลาดเคลื่อนและทำการเปรียบเทียบด้วยเทคนิควิธีต่าง ๆ และเลือกจัดเก็บแบบจำลองที่ดีที่สุด

6. การปฏิบัติตามผลเสนอแนะ (Deployment)

แบบจำลองที่ดีที่สุดที่นำมาใช้ประโยชน์ ซึ่งเป็นแบบจำลองที่มีความเหมาะสมกับความ ต้องการพยากรณ์ข้อมูลในอนาคตจะถูกนำมาประยุกต์ใช้ในขั้นตอนนี้ โดยตัวอย่างการนำแบบจำลอง การพยากรณ์ข้อมูลไปใช้ประโยชน์สามารถแสดงได้ดังภาพที่ 3



ภาพที่ 3 ตัวอย่างหน้าจอการแสดงผลการพยากรณ์ของข้อมูลสำหรับผู้ใช้งาน

ผลการศึกษา

การวัดผลค่าความคลาดเคลื่อนเพื่อเปรียบเทียบเทคนิคต่าง ๆ สำหรับการทดลองนี้ ได้ทำการทดลองกับข้อมูล 2 ชุด คือ ชุดข้อมูลสินค้าทั้งหมดหมู่ที่ขายดีที่สุด และชุดข้อมูลสินค้ารายการที่ขายดีที่สุด และทำการพยากรณ์ข้อมูลในอีก 1 – 3 วันถัดไป โดยพิจารณาจากปริมาณการขายจริงในวันก่อนหน้า สำหรับการสร้างแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่อง ได้แบ่งการพิจารณาข้อมูลย้อนหลังเป็น 2 ระยะเวลา คือ พิจารณาข้อมูลย้อนหลัง 7 วัน และ 14 วัน ตามลำดับ และมีการเพิ่มตัวแปรภายนอกที่สร้างขึ้น เช่น วันของสัปดาห์ วันทำการและวันหยุดของสัปดาห์ และสัปดาห์ของเดือน แต่สำหรับการวิเคราะห์อนุกรมเวลาจะทำการพิจารณาย้อนหลัง 14 วัน และไม่เพิ่มตัวแปรภายนอก เนื่องจากการวิเคราะห์ด้วยตัวแปรแบบขั้นเดียว จากนั้นทำการวัดประสิทธิภาพและแสดงผลค่า

ความคลาดเคลื่อน โดยตัวอย่างตารางการเปรียบเทียบค่าความคลาดเคลื่อนของการพิจารณาข้อมูลแบบต่าง ๆ ที่ดีที่สุดแสดงได้ดังต่อไปนี้

ตารางที่ 1 ตารางเปรียบเทียบผลการวัดประสิทธิภาพของค่าความคลาดเคลื่อนของการพยากรณ์ด้วยวิธีการและเทคนิคในรูปแบบต่าง ๆ สำหรับการพยากรณ์ใน 1 วันถัดไป เมื่อพิจารณาจากข้อมูลย้อนหลัง 14 วัน

วิธีการพยากรณ์		ชุดข้อมูลสินค้าทั้งหมดหมู่ที่ ขายดีที่สุด			ชุดข้อมูลสินค้ารายการที่ขาย ขายดีที่สุด		
		MAPE	MAE	RMSE	MAPE	MAE	RMSE
Time Series Analysis	ARIMA	24.56	52.85	52.85	52.80	31.98	31.98
	Holt-Winters	27.66	59.37	59.37	60.77	35.59	35.59
Machine Learning	Generalized Linear Model	21.40	55.77	71.69	39.80	45.29	66.53
	Deep Learning	20.10	52.93	66.58	39.50	43.72	61.43
	Decision Tree	18.30	48.09	63.33	34.10	38.10	56.63
	Random Forest	17.90	45.78	58.15	36.20	39.53	59.52
	Gradient Boosted Trees	16.60	43.54	56.32	32.70	33.15	47.17
	Support Vector Machine	18.70	48.22	62.69	36.50	40.78	64.45

ตารางที่ 2 ตารางเปรียบเทียบผลการวัดประสิทธิภาพของค่าความคลาดเคลื่อนของการพยากรณ์ด้วยเทคนิคการเรียนรู้ของเครื่องในรูปแบบต่าง ๆ สำหรับการพยากรณ์ในอีก 2 วันถัดไป เมื่อพิจารณาจากข้อมูลย้อนหลัง 7 วัน

วิธีการพยากรณ์		ชุดข้อมูลสินค้าทั้งหมดหมู่ที่ขายดีที่สุด			ชุดข้อมูลสินค้ารายการที่ขายขายดีที่สุด		
		MAPE	MAE	RMSE	MAPE	MAE	RMSE
Machine Learning	Generalized Linear Model	16.10	40.63	52.65	27.00	24.35	36.78
	Deep Learning	17.90	39.47	50.01	30.60	26.16	39.31
	Decision Tree	18.30	46.63	64.63	28.50	25.30	36.77
	Random Forest	15.60	39.63	52.56	31.70	29.20	40.57
	Gradient Boosted Trees	14.90	36.03	46.13	27.30	22.98	33.74
	Support Vector Machine	15.80	36.59	47.04	28.20	24.54	37.56

ตารางที่ 3 ตารางเปรียบเทียบผลการวัดประสิทธิภาพของค่าความคลาดเคลื่อนของการพยากรณ์ด้วยเทคนิคการเรียนรู้ของเครื่องในรูปแบบต่าง ๆ เมื่อทำการเพิ่มตัวแปรภายนอก (เช่น วันของสัปดาห์ วันทำการและวันหยุดของสัปดาห์ และสัปดาห์ของเดือน) สำหรับการพยากรณ์ในอีก 2 วันถัดไป เมื่อพิจารณาจากข้อมูลย้อนหลัง 7 วัน

วิธีการพยากรณ์		ชุดข้อมูลสินค้าทั้งหมดหมู่ที่ขายดีที่สุด			ชุดข้อมูลสินค้ารายการที่ขายขายดีที่สุด		
		MAPE	MAE	RMSE	MAPE	MAE	RMSE
Machine Learning	Generalized Linear Model	16.10	40.63	52.65	27.00	24.35	36.78
	Deep Learning	17.40	39.11	49.31	31.60	26.52	39.30
	Decision Tree	16.40	41.20	56.91	29.00	28.13	43.67
	Random Forest	16.00	39.92	53.20	32.60	29.92	40.95
	Gradient Boosted Trees	15.00	36.68	48.43	27.20	24.04	35.54
	Support Vector Machine	15.80	36.42	46.89	26.70	24.20	36.76

สรุปและอภิปรายผลการวิจัย

ผลการทดลองเมื่อทำการเปรียบเทียบวิธีการวิเคราะห์อนุกรมเวลา (Time Series Analysis) ทั้ง 2 แบบจำลอง กับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning Technique) ทั้ง 6 เทคนิค พบว่าเทคนิคการเรียนรู้ของเครื่องมีประสิทธิภาพที่ดีกว่าวิธีการวิเคราะห์อนุกรมเวลา ซึ่งผลของการพยากรณ์สำหรับเทคนิคการเรียนรู้ของเครื่อง จะให้ค่า MAPE, MAE และ RMSE ที่ใกล้เคียงกัน เมื่อใช้ลักษณะและปัจจัยของการพยากรณ์เหมือนกัน เช่น พยากรณ์ 1-3 วัน ข้างหน้า และพิจารณาข้อมูลย้อนหลัง 7-14 วัน แต่จะแตกต่างกันมากเมื่อเปรียบเทียบกับวิธีการวิเคราะห์อนุกรมเวลา เนื่องจากวิธีการทำงานและพารามิเตอร์ของทั้งสองแบบมีความแตกต่างกัน โดยพบว่าเมื่อทำการพยากรณ์ข้อมูลให้มีระยะเวลาที่นานยิ่งขึ้น (เช่น พยากรณ์ 3 วันถัดไป) ยิ่งทำให้ค่าความคลาดเคลื่อนมีค่ามากยิ่งขึ้น ซึ่งมีค่ามากกว่าการพยากรณ์ข้อมูลในระยะเวลาอันใกล้ (เช่น พยากรณ์ 1-2 วันถัดไป) อีกทั้งเมื่อพิจารณาข้อมูลย้อนหลังในช่วงระยะเวลานานขึ้นยิ่งทำให้มีค่าความผิดพลาดที่มากขึ้นด้วย เช่น พิจารณาข้อมูลย้อนหลัง 14 วัน มีค่าความผิดพลาดมากกว่าการพิจารณาข้อมูลย้อนหลัง 7 วัน รวมทั้งเมื่อเพิ่มตัวแปรภายนอก เช่น วันของสัปดาห์, วันทำการและวันหยุด อีกทั้งสัปดาห์ของเดือน ก็ไม่ทำให้ค่าความคลาดเคลื่อนมีการเปลี่ยนแปลงมากนัก และสำหรับการพยากรณ์ด้วยเทคนิคการเรียนรู้ของเครื่องนั้น พบว่าเทคนิคการเรียนรู้ของเครื่องด้วยวิธีการของ Gradient Boosted Trees ให้ผลค่าความคลาดเคลื่อนที่น้อยกว่าเทคนิคการเรียนรู้ของเครื่องวิธีอื่น ๆ โดยมีค่า MAPE ต่ำที่สุด อยู่ระหว่าง 14.90% - 33.10%, ค่า MAE คือ 21.74 - 50.72 และ RMSE คือ 30.36 - 61.56 ตามลำดับ เมื่อพิจารณาค่าความคลาดเคลื่อนของชุดข้อมูลทั้งสองพบว่ามีค่าความคลาดเคลื่อนน้อยกว่าวิธีการวิเคราะห์อนุกรมเวลา ซึ่งสอดคล้องไปในทิศทางเดียวกันกับอีกชุดข้อมูลข้างต้น แต่มีค่า MAPE สูงกว่าเล็กน้อย โดยพบข้อสังเกตซึ่งคิดว่าเป็นสมมติฐานของสาเหตุที่น่าสนใจ คือ การกระจายตัวหรือความถี่ของช่วงข้อมูลทั้ง 2 ชุดแตกต่างกัน ชุดที่ให้ค่า MAPE ต่ำมีการกระจายตัวของข้อมูลที่มากกว่าข้อมูลอีกชุดที่นำมาใช้ในการทดลอง

ข้อเสนอแนะ

1. ข้อมูลที่ใช้ควรนำมาทำการแบ่งข้อมูลของคาบหรือระยะเวลาเพื่อนำมาสร้างแบบจำลองให้เหมาะสมตามจุดประสงค์ของการพยากรณ์ เช่น พิจารณาปริมาณสินค้าที่ขายในช่วงที่มีการจัดแคมเปญของสินค้า หรือโปรโมชั่นต่าง ๆ ที่ส่งผลต่อยอดขาย

2. ควรมีการประเมินผลที่ได้อย่างสม่ำเสมอ เพื่อพิจารณาถึงความเหมาะสมและความถูกต้องและทำการปรับเปลี่ยนตัวแปรอิสระเพิ่มเติมที่อาจช่วยเพิ่มประสิทธิภาพของการสร้างแบบจำลองมากขึ้น หรือลองนำเทคนิคใหม่ ๆ ที่ถูกพัฒนามาปรับใช้ให้มีประสิทธิภาพมากขึ้น
3. ควรมีการพิจารณาตัวแปรหรือปัจจัยอื่น ๆ เพิ่มเติม ซึ่งอาจส่งผลกับค่าพยากรณ์
4. ควรมีการพิจารณาถึงช่วงของเทศกาล และวันหยุดต่าง ๆ รวมทั้งระยะเวลาของการจัดโปรโมชั่น และแคมเปญของการตลาดที่ส่งผลต่อยอดขาย หรือมีปริมาณการสั่งซื้อสินค้าในช่วงเวลานั้น ๆ ซึ่งอาจทำให้ส่งผลต่อการพยากรณ์ที่แตกต่างไปจากช่วงเวลาการขายปกติ

บรรณานุกรม

- เฉลิมพล จตุพร. (2562). *การพยากรณ์ทางอนุกรมเวลา (Time Series Forecasting)*. สืบค้น 30 กันยายน 2564 จาก <https://cj007blog.files.wordpress.com/2020/04/07-time-seriesforecasting.pdf>
- นิชา แก้วหาวงษ์. (2547). การศึกษาเปรียบเทียบการพยากรณ์ข้อมูลอนุกรมเวลาโดยวิธีการทำให้เรียบแบบเอ็กซ์โปเนเนเชียลและวิธีการของบ็อกซ์-เจนกินส์: กรณีศึกษาการพยากรณ์มูลค่าการส่งออกข้าว ยางพารา และมันสำปะหลัง. *วารสารวิทยาศาสตร์ มหาวิทยาลัยนเรศวร*, 1(2), 73-90.
- Claudimar Pereira Da Veiga, Cássia Rita Pereira Da Veiga, Anderson Catapan, Ubiratã Tortato and Wesley Vieira Da Silva. (2014). Demand forecasting in food retail: A comparison between the Holt-Winters and ARIMA models. *WSEAS TRANSACTIONS on BUSINESS and ECONOMICS*, 11. E-ISSN: 2224-289, pp. 608-614.
- Florian Haselbeck, Jennifer Killinger, Klaus Menrad, Thomas Hannus and Dominik G. Grimm. (2021). *Machine Learning Outperforms Classical Forecasting on Horticultural Sales Predictions*, 7(4), pp.1420-1438
- Jakob Huber. (2020). Daily retail demand forecasting using machine learning with emphasis on calendric special days. *International Journal of Forecasting*, 36(4), pp.1420-1438.