

วิธีอ้างอิงบทความนี้: ธนพนธ์ สาริกา, อนิรุทธิ์ ชันธสะอาด และพรณกษม อินทรทัต. (2567). การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทย. วารสารปฏิบัติการโลจิสติกส์และซัพพลายเชน, 10(2), 158-176.
<https://doi.org/10.53848/jlsco.v10i2.269977>

Received : June 30, 2023
Revised : September 17, 2023
Accepted : August 24, 2024

การเปรียบเทียบแบบจำลองพยากรณ์ความต้องการในธุรกิจค้าปลีกผลิตภัณฑ์เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ในประเทศไทย

ธนพนธ์ สาริกา^{1*} อนิรุทธิ์ ชันธสะอาด² และ พรณกษม อินทรทัต³

บทคัดย่อ

การพยากรณ์ที่มีประสิทธิภาพจะมีบทบาทสำคัญในการจัดการห่วงโซ่อุปทาน การควบคุมสินค้าคงคลัง และการตัดสินใจเชิงกลยุทธ์ งานวิจัยนี้นำเสนอการวิเคราะห์ที่ครอบคลุมของแบบจำลองการพยากรณ์ยอดขายกลุ่มเครื่องใช้ไฟฟ้าขององค์กร กรณีศึกษาที่มีช่องทางการจัดจำหน่ายทั้งออนไลน์และออฟไลน์ โดยมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการพยากรณ์ความต้องการที่แม่นยำ โดยใช้วิธีการวิเคราะห์ ABC เพื่อระบุรายการสินค้าที่มีผลกระทบต่อภาคธุรกิจมากที่สุด ร่วมกับวิธีการพยากรณ์ที่กำหนด ได้แก่ การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลชั้นเดียว การพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง Autoregressive Integrated Moving Average และ Feed-Forward Neural Network โดยใช้ค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (MAD) ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (MAPE) ในการวัดค่าความคลาดเคลื่อนของ

การพยากรณ์ ซึ่งผลการวิจัยพบว่า รายการสินค้าช่องทางขายออนไลน์ 6 จาก 10 รายการระบุว่าวิธีการพยากรณ์แบบ WMA มีความแม่นยำมากที่สุด โดยมีค่า MAPE เฉลี่ยอยู่ที่ 25.89% และช่องทางขายออฟไลน์พบว่า รายการสินค้า 4 จาก 8 รายการ มีค่าความคลาดเคลื่อนน้อยที่สุดด้วยวิธีการพยากรณ์แบบ ARIMA โดยมีค่า MAPE เฉลี่ยอยู่ที่ 26.74% และต้นทุนมูลค่าการถือครองสินค้าขึ้นต่ำต่อสัปดาห์หลังคำนวณ Safety Stock ใหม่พบว่า มีต้นทุนลดลงไป 513,026 บาท โดยวิธีการที่นำเสนอสามารถลดต้นทุนของคงคลังต่อสัปดาห์ได้ประมาณร้อยละ 13 อย่างไรก็ตามแม้ว่าภาพรวมของรายการสินค้าทั้งสองช่องทางแบบจำลอง ARIMA จะให้ผลการพยากรณ์ที่มีประสิทธิภาพที่สุดแต่ในการนำไปใช้จริงควรพิจารณาร่วมกับแบบจำลองอื่นเพื่อวัดผลและเปรียบเทียบประสิทธิภาพ

คำสำคัญ: การพยากรณ์ความต้องการ ธุรกิจค้าปลีกหลายช่องทาง การพาณิชย์อิเล็กทรอนิกส์ การวิเคราะห์ ABC

ประเภทบทความ: บทความวิจัย

* ผู้รับผิดชอบงานหลัก

¹ นักศึกษาหลักสูตรวิทยาศาสตรมหาบัณฑิต (การจัดการโลจิสติกส์และโซ่อุปทาน) มหาวิทยาลัยบูรพา, อีเมล: thanaponsarika@gmail.com

^{2,3} อาจารย์ประจำ คณะโลจิสติกส์ มหาวิทยาลัยบูรพา, อีเมล: anirut.ka@go.buu.ac.th, paronkasom.in@go.buu.ac.th

ผ่านการรับรองคุณภาพจากศูนย์ดัชนีการอ้างอิงวารสารไทย (TCI.) อยู่ในกลุ่ม 1 สาขามนุษยศาสตร์และสังคมศาสตร์

The Comparison of Demand Forecasting Models in Electrical Appliance and Electronic Products Retail Business in Thailand

Thanapon Sarika^{1*} Anirut Kantasa-ard² and Paronkasom Indradat³

Abstract

Effective forecasting plays an important role in supply chain management. the significance of accurate forecasting in supply chain, inventory management, and strategic decisions. Focusing on consumer electronics, it presents a comprehensive sales forecast model for both online and offline channels, utilizing the ABC analysis alongside various techniques including Weighted Moving Average (WMA), Single Exponential Smoothing (SES) and Double Exponential Smoothing (DES), Autoregressive Integrated Moving Average (ARIMA), and Feed-Forward Neural Network (FFNNs), evaluated through MSE, MAD, and MAPE. Results indicate the Weighted Moving Average as the most accurate for 6 of 10 online items (with average MAPE of 25.89%), while Autoregressive Integrated Moving Average stands out for 4 of 8 offline items (with average MAPE of 26.74%). A recalculated Safety Stock reduces minimum weekly holding costs by 513,026 Baht, potentially decreasing weekly inventory costs by 13%. However, the prominence of the Autoregressive Integrated Moving Average model suggests it be integrated with other models for comprehensive performance evaluation.

Keywords: Demand forecasting model, Omni-channel, e-Commerce, ABC analysis

Type of Article: Research Article

* Corresponding author

1 Master of Science, Logistics and Supply Chain Management, Burapha University,

E-mail: thanaponsarika@gmail.com

²⁻³Lecturer, Faculty of Logistics, Burapha University, E-mail: anirut.ka@go.buu.ac.th, paronkasom.in@go.buu.ac.th

1. บทนำ

ในปัจจุบันตลาดของธุรกิจ E-commerce ในประเทศไทยมีแนวโน้มที่เพิ่มสูงขึ้น โดยมีมูลค่าของตลาดอยู่ที่ 11,000 ล้านดอลลาร์สหรัฐในปี 2020 และคาดการณ์ว่าภายใน 5 ปีจะมีแนวโน้มเพิ่มสูงขึ้นถึง 52,000 ล้านดอลลาร์สหรัฐ ซึ่งคิดเป็นอัตราการเติบโตร้อยละ 35 ต่อปี (Resnick & Tseng, 2016) นอกจากนี้รัฐบาลไทยยังให้การสนับสนุนโดยจัดหาเงินทุนและมาตรการจูงใจด้านภาษีเพื่อส่งเสริมการเติบโตและออกมาตรการเพื่อปรับปรุงโครงสร้างพื้นฐานด้านโลจิสติกส์ รวมไปถึงการระบอบการระบาดของโควิด-19 ยังเป็นปัจจัยหนึ่งที่ทำให้เกิดการเปลี่ยนแปลงที่เร็วขึ้น ซึ่งนับตั้งแต่ช่วงของการแพร่ระบาดหลาย ๆ องค์กรได้มุ่งเน้นไปที่กลยุทธ์แบบไร้รอยต่อ (Omni-channel) กันมากขึ้น ซึ่งพฤติกรรมของผู้บริโภคชาวไทยกว่า 82% นิยมซื้อสินค้ากับแบรนด์ที่มีทั้งหน้าร้านปกติและหน้าร้านออนไลน์ (ดับเบิลยูพี, 2564) ซึ่งหน้าร้านปกติหรือช่องทางการขายออฟไลน์จะมุ่งเน้นไปที่การนำเสนอการให้บริการ สามารถตอบสนองความต้องการได้อย่างทันทั่วทั้งที่ส่วนร้านค้าออนไลน์จะมีจุดแข็ง โดยอำนวยความสะดวกสบายของผู้บริโภค สามารถเข้าถึงสินค้าได้หลากหลายโดยสรุปแล้วทั้งช่องทางออฟไลน์และออนไลน์ต่างมีข้อได้เปรียบ เสียเปรียบที่แตกต่างกัน ซึ่งทางเลือกระหว่างช่องทางทั้งสองนั้นขึ้นอยู่กับความชอบและความต้องการของลูกค้าเป็นหลัก

หนึ่งในอุตสาหกรรมของตลาด E-commerce ที่น่าสนใจคือ อุตสาหกรรมเครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ ในปัจจุบันกลุ่มร้านค้าธุรกิจคอมพิวเตอร์และอุปกรณ์อิเล็กทรอนิกส์มีขนาดใหญ่เป็นอันดับที่ 3 และมีมูลค่าของตลาดเพิ่มขึ้น 9.49% เมื่อเทียบกับปี 2563 (Electronic Transactions Development Agency, 2021) สถิติเหล่านี้แสดงให้เห็นถึงความสำคัญที่เพิ่มขึ้นของอุตสาหกรรมเครื่องใช้ไฟฟ้าในประเทศไทย

ความท้าทายที่สำคัญของธุรกิจที่มีการดำเนินกลยุทธ์แบบไร้รอยต่อ (Omni-channel) คือความสามารถในการจัดการ สต็อกสินค้าในแต่ละสาขา เนื่องจากการสต็อกสินค้าไว้แต่ละที่จะมีต้นทุนสินค้าคงคลัง ถ้าหากมีการบริหารจัดการไม่ดีจะทำให้มีต้นทุนเพิ่มสูงขึ้น ดังนั้นการจัดการสต็อกสินค้าที่มีประสิทธิภาพจะช่วยให้ต้นทุนของธุรกิจลดลง และสามารถตอบสนองความต้องการของลูกค้าได้อย่างทันทั่วทั้งที่ ลดการเสียโอกาสจากการขาย

แม้ในปัจจุบันจะมีแนวทางการแก้ปัญหาที่หลากหลาย เช่น การวัดสภาพคล่องของสินค้าคงคลัง (Cover day) คือ การประมาณการว่าสินค้าที่มีจะเพียงพอต่อความต้องการขายไปได้กี่วัน แต่เนื่องด้วยข้อจำกัดในกรณีที่มีสินค้าที่หลากหลายและมีหลายสาขา การที่จะทำ Cover day กับสินค้าทั้งหมดแทบจะเป็นไปไม่ได้เนื่องจากจะทำให้องค์กรต้องแบกรับต้นทุนที่สูงจนเกินไป

ผู้วิจัยเล็งเห็นว่าปัญหานี้เป็นปัญหาที่มักจะเกิดขึ้นบ่อยครั้ง ไม่ว่าจะเป็นช่องทางออนไลน์หรือออฟไลน์ ดังนั้นการพยากรณ์ความต้องการของลูกค้าเพื่อสต็อกสินค้าไว้จึงเป็นวิธีการที่ผู้วิจัยคิดว่าเหมาะสมที่สุด เนื่องจากวิธีการนี้มีต้นทุนที่ไม่สูงและสามารถใช้ข้อมูล transaction ของการขายจากระบบมาช่วยในการพยากรณ์ได้

2. วัตถุประสงค์ของการวิจัย

1. เพื่อศึกษาระดับสินค้าคงคลังของสินค้าเครื่องใช้ไฟฟ้าที่มีผลกระทบต่อยอดขายของบริษัทกรณีศึกษา
2. เพื่อศึกษาแบบจำลองการพยากรณ์ความต้องการของลูกค้า และสามารถระบุเปรียบเทียบโมเดลการพยากรณ์ยอดขายที่แม่นยำที่สุดของสินค้าประเภทเครื่องใช้ไฟฟ้าขององค์กรกรณีศึกษา
3. เพื่อเปรียบเทียบค่าความคลาดเคลื่อนและปรับปรุงประสิทธิภาพของแบบจำลองการพยากรณ์

3. วรรณกรรมที่เกี่ยวข้อง

3.1 แนวคิดและทฤษฎีเกี่ยวกับ Omni-channel

กลยุทธ์ทางธุรกิจที่มีเป้าหมายเพื่อให้ผู้บริโภคได้รับประสบการณ์จากบริการหรือสินค้าที่ราบรื่นและบูรณาการในหลายช่องทาง ซึ่งผู้บริโภคสามารถโต้ตอบกับแบรนด์หรือธุรกิจผ่านช่องทางต่าง ๆ เช่น ร้านค้าหน้าร้าน เว็บไซต์ แอปบนอุปกรณ์เคลื่อนที่ แพลตฟอร์มโซเชียลมีเดีย และช่องทางดิจิทัลอื่น ๆ ซึ่งการทำ Omni-channel มีข้อดีดังต่อไปนี้

- สามารถตอบสนองความต้องการของลูกค้าได้อย่างสมบูรณ์รอบด้าน
 - เข้าใจ รู้ใจ และรู้จักลูกค้าของแบรนด์ได้เป็นอย่างดีผ่านการเก็บข้อมูลการใช้งานช่องทางต่าง ๆ ของลูกค้า
 - ส่งเสริมภาพลักษณ์ของแบรนด์ให้ชัดเจนและดีมากยิ่งขึ้น ด้วยการเชื่อมต่อทุกช่องทางการขายเข้าด้วยกัน ทำให้ลูกค้าได้รับข้อมูลและการบริการแบบเดียวกันจากทุกช่องทาง
 - เพิ่มยอดขายให้กับธุรกิจได้มากขึ้นจากการเชื่อมต่อทุกช่องทางการจำหน่ายสินค้าและบริการ
- นิยามของคำว่า ช่องทาง คือ จุด ๆ หนึ่งที่ลูกค้าสามารถสื่อสารกับองค์กรหรือภาคธุรกิจได้ และความแตกต่างระหว่าง Multi-channel และ Omni-channel คือดังนี้

Multi-channel คือ กลุ่มกิจกรรมการซื้อ-ขายที่มากกว่า 1 ช่องทาง แต่ลูกค้าไม่สามารถเชื่อมโยงแต่ละช่องทางได้ ทางด้านของ Omni-channel คือ ร้านค้าสามารถควบคุมช่องทางได้อย่างครบวงจร เช่น กรณีที่ลูกค้าซื้อของมาจากร้านค้าออนไลน์ แต่เมื่อต้องการเคลมสินค้าลูกค้าสามารถติดต่อกับทางร้านค้าที่เป็นช่องทางออฟไลน์ได้โดยไม่ต้องเคลมสินค้ากับช่องทางที่ซื้อมาในตอนแรก (Neslin et al., 2006)

3.2 แนวคิดและทฤษฎีเกี่ยวกับ ABC analysis

การบริหารสินค้าคงคลังด้วย ABC Analysis เป็นแนวคิดการบริหารจัดการสินค้าคงคลังด้วยการ

จัดกลุ่มสินค้าตามมูลค่าการใช้ในรอบระยะเวลาหนึ่ง โดยมีพื้นฐานมาจากพาเรโต นักเศรษฐศาสตร์และวิศวกรชาวอิตาลี เป็นแนวคิดที่ให้ความสำคัญกับการจัดกลุ่มสินค้าโดยแบ่งออกเป็น 3 กลุ่ม คือ มาก ปานกลาง และน้อย เพื่อให้ง่ายต่อการบริหารจัดการตามกลุ่มสินค้า โดยเกณฑ์การจัดมีหลายแบบตามแต่นโยบายขององค์กรนั้น ๆ เช่น มูลค่ายอดขายของสินค้า การจัดลำดับสินค้าตามมูลค่าสินค้าคงคลัง

การเพิ่มประสิทธิภาพการจัดการสินค้าคงคลังโดยใช้วิธี Exponential smoothing ในการพยากรณ์ร่วมกับการใช้ ABC ในการจำแนกประเภท สามารถเลือกการพยากรณ์ที่มีผลกระทบต่อยอดขายได้ และช่วยเพิ่มประสิทธิภาพการพยากรณ์ได้ (Xi & Sha, 2014)

3.3 แนวคิดและทฤษฎีเกี่ยวกับการพยากรณ์

1. Weighted moving average (WMA) คือ เส้นค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก โดยจะถ่วงน้ำหนักข้อมูลที่ใหม่มากกว่าข้อมูลที่เก่า การถ่วงน้ำหนักข้อมูลจะทำให้ค่าเฉลี่ยที่ได้มีการเคลื่อนที่ที่สอดคล้องกับข้อมูลจริงมากขึ้น ทำให้เวลานำไปใช้งานสามารถติดตามสถานการณ์ได้อย่างทันท่วงที

$$WMA(n) = \frac{\sum_{i=1}^n i P_i}{\sum_{i=1}^n i} = \frac{(1 \times P_1 + 2 \times P_2 + \dots + n \times P_n)}{1 + 2 + \dots + n} \quad (1)$$

โดยที่

P คือ ข้อมูลตัวแปรหรือราคา

n คือ จำนวนของข้อมูลย้อนหลัง

การพยากรณ์เพื่อหารูปแบบที่เหมาะสมที่สุดลดต้นทุนค่าเสียโอกาส และเพื่อหาจุดสั่งซื้อใหม่โดยใช้วิธีการพยากรณ์ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (MA), หาค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (WMA) และวิธีหาค่าปรับเรียบเอกซ์โปเนนเชียล ผลลัพธ์แสดงให้เห็นว่าวิธีการพยากรณ์แบบ WMA เป็นเครื่องมือที่มีประสิทธิภาพในการพยากรณ์กับข้อมูลที่มีลักษณะเป็นอนุกรมเวลา (จิราพร ภูทองคำ และ ถิรนนท์ทิศา ราตรีวิทย์, 2564)

2. Single exponential smoothing method (SES) เป็นเทคนิคการพยากรณ์ที่ได้รับความนิยมมากอีกวิธีหนึ่ง เนื่องจากใช้ข้อมูลน้อยคือ ใช้เพียงค่าของข้อมูลค่าพยากรณ์ก่อนหน้าค่าความต้องการในปัจจุบัน และค่าปัจจัยถ่วงน้ำหนักปรับเรียบการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียล

$$F_{t+1} = \alpha Y_t + (1-\alpha)F_t \quad (2)$$

โดยที่

$F_{(t+1)}$ คือ ค่าพยากรณ์ในช่วงเวลาต่อไป

Y_t คือ หมายถึง ค่าความต้องการจริงในช่วงเวลาปัจจุบัน

F_t คือ ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

α คือ ค่าถ่วงน้ำหนักปรับเรียบ

3. Double exponential smoothing method (DES) เป็นวิธีที่ใช้หลักการของเอ็กซ์โปเนนเชียล ซึ่งคล้ายกับวิธี Single exponential smoothing แต่วิธี Single exponential smoothing เหมาะกับข้อมูลที่มีความไม่แน่นอนเพียงอย่างเดียว จึงทำให้มีค่าคงที่สำหรับปรับเรียบเพียง 1 ค่า ซึ่งเทคนิคนี้เหมาะสำหรับข้อมูลที่มีแนวโน้มแบบเส้นตรงแต่ไม่มีความเป็นฤดูกาล โดยหลักการของเทคนิคนี้คือการคำนวณค่าฐานถ่วงเฉลี่ยปรับเรียบของข้อมูลช่วงเวลาปัจจุบันแล้วจึงปรับด้วยค่าแนวโน้ม (ศิวพันธ์วรโชติปัญญารัตน์, 2564)

สมการพยากรณ์

$$F_{(t+m)} = L_t + mT_t \quad (3)$$

สมการปรับเรียบ

$$L_t = \alpha Y_t + (1 - \alpha)(L_{(t-1)} + T_{(t-1)}) \quad (4)$$

สมการแนวโน้ม

$$T_t = \beta(L_t - L_{(t-1)}) + (1-\beta)T_{(t-1)} \quad (5)$$

โดยที่

L_t คือ ค่าปรับเรียบตัวใหม่ ณ เวลา t

T_t คือ ตัวประมาณแนวโน้ม l ช่วงเวลา t

Y_t คือ ค่าข้อมูลจริง ณ ช่วงเวลา t

α คือ ค่าคงที่สำหรับการปรับเรียบ

β คือ ค่าคงที่ปรับเรียบสำหรับแนวโน้ม

m คือ จวดเวลาที่ต้องการพยากรณ์ล่วงหน้า

4. Autoregressive integrated moving average (ARIMA) แบบจำลอง ARIMA เป็นการพยากรณ์ที่ถูกเสนอโดยบ็อกซ์-เจนกินส์ ในปี 1970 เป็นโมเดลการวิเคราะห์หอนุกรมเวลาที่รวมองค์ประกอบ Autoregressive, Differencing และ Moving Average เพื่อจับและคาดการณ์รูปแบบในข้อมูลที่ขึ้นกับเวลา เป็นวิธีที่ให้ค่าพยากรณ์ในระยะสั้นได้ดีกว่าคือ มีค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง MSE ของการพยากรณ์ต่ำกว่าวิธีอื่น เหมาะสำหรับการพยากรณ์ไปข้างหน้าในระยะเวลานั้น ๆ โดยจำเป็นต้องใช้อนุกรมเวลาที่ยาว (อัศวพงศ์ อันทอง, 2550)

โดยแบบจำลองจะประกอบด้วย 3 ส่วนหลัก คือ Auto Regressive (AR(p)) Integrated (I(d)) และ Moving Average (MA(q)) เนื่องจากข้อมูลอนุกรมเวลาส่วนใหญ่จะมีลักษณะที่ไม่คงที่ ดังนั้นต้องมีการนำข้อมูลอนุกรมเวลามาหาระดับผลต่างโดยมีสมการดังนี้

$$Y_t = Y_{(t-1)} + \varepsilon_t \quad (6)$$

ผลต่างอันดับที่ 1 (First Difference)

$$Y_t = Y_t - Y_{(t-1)} + \varepsilon_t \quad (7)$$

ผลต่างอันดับที่ 2 (Second-Order Difference)

$$Y_t = Y_t - Y_{(t-1)} + \varepsilon_t \quad (8)$$

Auto Regressive (AR(p)) ข้อมูลอนุกรมเวลาขึ้นอยู่กับข้อมูลความล่าช้าในอดีตอันดับ p เขียนในรูปสมการได้ดังนี้

$$Y_t = \theta_0 + \delta_1 Y_{(t-1)} + \delta_2 Y_{(t-2)} + \dots + \delta_p Y_{(t-p)} + e_t \quad (9)$$

โดยที่

θ_0 คือ ค่าคงที่

$\delta_1, \delta_2, \dots, \delta_p$ คือค่าสัมประสิทธิ์ของตัวแปรล่าช้า

$Y_{(t-1)}, Y_{(t-2)}, \dots, Y_{(t-p)}$ คือตัวแปรล่าช้าของ Y

e_t คือค่าความคลาดเคลื่อน

Moving Average (MA(q)) ข้อมูลอนุกรมเวลา ขึ้นอยู่กับความคลาดเคลื่อนในปัจจุบันและความคลาดเคลื่อนของความล่าช้าอันดับ q เขียนในรูปสมการได้ดังนี้

$$Y_t = \theta_0 + e_t + \varphi_1 e_{(t-1)} + \dots + \varphi_q e_{(t-q)} \quad (10)$$

โดยที่

θ_0 คือ ค่าคงที่

$\varphi_1, \varphi_2, \dots, \varphi_q$ คือ ค่าสัมประสิทธิ์ของตัวแปรล่าช้า

$e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-q)}$ คือ ตัวแปรล่าช้าของค่าความคลาดเคลื่อน

e_t คือ ค่าความคลาดเคลื่อน

การประยุกต์แบบจำลอง Autoregressive Integrated Moving Average (ARIMA) เพื่อพยากรณ์ความต้องการผักและผลไม้สดในแต่ละวัน โมเดลถูกสร้างขึ้นโดยใช้ข้อมูลยอดขายของหัวหอมตลอด 25 เดือน จากตลาดแห่งหนึ่งในประเทศอินเดีย ผลลัพธ์ที่ได้แสดงให้เห็นว่าแบบจำลองสามารถพยากรณ์ข้อมูลที่มีความผันผวนได้อยู่ในเกณฑ์ที่ยอมรับได้สำหรับตลาดผักและผลไม้ที่มีความต้องการที่ไม่แน่นอน (Shukla & Jharkharia, 2011)

เนื่องด้วยลักษณะของสินค้าในงานวิจัยข้างต้นเป็นสินค้าที่มีอายุการเก็บรักษาได้ไม่นาน ทางผู้วิจัยมีความเห็นว่าหากลักษณะของสินค้าที่มีอายุการเก็บรักษานานขึ้นการพยากรณ์ด้วย ARIMA อาจให้ผลลัพธ์ที่ดีขึ้น

การใช้ Akaike information criterion (AIC) และ GridSearch (GS) ในการช่วยปรับค่าพารามิเตอร์ p, d, q ของแบบจำลอง ARIMA สามารถช่วยให้ผลลัพธ์การพยากรณ์มีความแม่นยำมากขึ้น (Zhao et al., 2022)

5. Feedforward neural network (FFNNs) เป็นเครือข่ายประสาทเทียมประเภทหนึ่งที่มีประมวผลข้อมูลในลักษณะไหลทิศทางเดียว จากชั้นข้อมูลเข้า

(Input layer) ไปยังชั้นที่ซ่อนอยู่ (Hidden layer) และสุดท้ายไปยังชั้นข้อมูลออก (Output layer) ประกอบด้วย เซลล์ประสาทเทียมที่เชื่อมต่อกันซึ่งจัดอยู่ในชั้นต่าง ๆ โดยเซลล์ประสาทแต่ละเซลล์จะใช้ฟังก์ชันการกระตุ้นกับอินพุต การปรับน้ำหนักซ้ำ ๆ ระหว่างการฝึก โครงข่ายประสาทเทียมประเภทนี้ถูกนำมาใช้กันอย่างแพร่หลายสำหรับงานต่าง ๆ เช่น การจดจำภาพ การประมวลผลภาษาธรรมชาติ และการวิเคราะห์อนุกรมเวลาโดยงานวิจัยของ (ชรณินทร์ สัจจริยทรัพย์, 2563) ได้อธิบายโครงสร้างสมการไว้ดังนี้

$$X_{t+1} = h(\beta_0 + \sum_{j=1}^D \beta_j g(W_{0j} + \sum_{i=1}^m W_{ij} X_{t-(i-1)})) \quad (11)$$

โดยที่

m คือ จำนวนข้อมูลป้อนเข้า

D คือ จำนวนโหนดในชั้นซ่อนตัวตามลำดับ

W_{0j} และ W_{ij} คือ ค่าเอนเอียง (Bias) ของโหนดที่ j ในชั้นซ่อนตัว

X_t คือ ค่าข้อมูลอนุกรมเวลาที่ t

β_0 และ β_j คือ ค่าเอนเอียง (Bias) ของ

ค่าเป้าหมายในชั้นแสดงข้อมูล

g คือ ฟังก์ชันไม่เป็นเชิงเส้นของแต่ละโหนด

h คือ ฟังก์ชันเชิงเส้นตรงของความสัมพันธ์ระหว่างแต่ละโหนดกับค่าเป้าหมาย

การสร้างแบบจำลองตามโครงข่ายประสาทเทียมแบบ Feed-forward (FFNNs) Auto-regressive Integrated Moving Average (ARIMA) และ Exponential Smoothing เพื่อคาดการณ์การแพร่ระบาดของ Covid-19 ในประเทศอิรัก ผลการวิจัยพบว่าแบบจำลอง Feed-forward neural networks (FFNNs) มีความแม่นยำในการพยากรณ์ผู้ติดเชื้อรายวันอยู่ที่ 87.6% รักษาหายอยู่ที่ 82.4% และผู้เสียชีวิตอยู่ที่ 84.3% จากงานวิจัยนี้พบว่าวิธีที่ใช้ในการพยากรณ์ทั้ง 3 วิธีสามารถให้ผลลัพธ์การพยากรณ์ที่มีประสิทธิภาพ โดยเฉพาะกลุ่มของโครงข่ายประสาทเทียมแบบ Feed-forward (FFNNs) ได้แสดงประสิทธิภาพการพยากรณ์ที่แม่นยำที่สุดกับข้อมูลผู้ติดเชื้อที่มี

ลักษณะเป็นอนุกรมเวลา (Aljaaf et al., 2021)

3.4 การวัดค่าความคลาดเคลื่อนของการพยากรณ์

1. ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (Mean Absolute Deviation, MAD)

$$MAD = \frac{\sum |A_t - F_t|}{n} \quad (12)$$

2. ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error, MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n \frac{(A_t - F_t)^2}{n} \quad (13)$$

3. ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error, MAPE)

$$MAPE = \frac{\sum \frac{|A_t - F_t|}{A_t} \times 100}{n} \quad (14)$$

โดยที่

F_t คือ ค่าพยากรณ์ในช่วงเวลาปัจจุบัน

A_t คือ ค่าความต้องการจริงในช่วงเวลาปัจจุบัน


n คือ จำนวนของข้อมูล

จากงานวิจัยที่ผ่านมาในอดีตพบว่า ปัญหาส่วนใหญ่ที่ผู้วิจัยพบคือ คุณสมบัติทางสถิติของข้อมูล ไม่มีรูปแบบที่ชัดเจนหรือมีค่าที่ผิดปกติมากเกินไป ถ้าข้อมูลมีรูปแบบหรือเหตุการณ์ที่คาดเดาไม่ได้โมเดลการพยากรณ์แบบอนุกรมเวลาอาจไม่แม่นยำ รวมถึงผลลัพธ์ที่ได้ก็ไม่อาจสรุปได้ว่าวิธีการใดดีที่สุด เนื่องจากผลลัพธ์ที่แตกต่างกันมาจากข้อมูลต่างชนิด เช่น ข้อมูลของปริมาณฝุ่น ข้อมูลของจำนวนผู้ติดเชื้อโควิดหรือข้อมูลของชนิดสินค้าวัตถุดิบ ดังนั้นในการพยากรณ์จะต้องหาวิธีการพยากรณ์หลาย ๆ วิธี

มาเพื่อเปรียบเทียบแบบจำลองที่มีความเหมาะสมกับข้อมูลมากที่สุด ในส่วนของการออกแบบโครงสร้างของแบบจำลอง Neural network การกำหนดจำนวนชั้นและจำนวนนิวรอนจะส่งผลต่อการพยากรณ์ เนื่องจากจำนวนนิวรอนที่น้อยเกินไปจะทำให้แบบจำลองไม่สามารถหาความสัมพันธ์ที่ซ่อนอยู่ในข้อมูลได้ รวมไปถึงการกำหนดอัตราการเรียนรู้ จำนวนรอบการเรียนรู้ ซึ่งการกำหนดที่น้อยเกินไปก็อาจส่งผลให้แบบจำลองยังไม่สามารถจับรูปแบบของข้อมูลได้ รวมไปถึงข้อจำกัดต่าง ๆ ของการใช้ Software สำเร็จรูป นอกจากนี้ควรคำนึงถึงการนำไปใช้จริงกับภาคธุรกิจหรือองค์กรด้วย

4. วิธีดำเนินการวิจัย

งานวิจัยนี้เป็นการศึกษาการพยากรณ์ความต้องการของผู้บริโภคกรณีบริษัทขายเครื่องใช้ไฟฟ้าแห่งหนึ่ง ซึ่งเป็นธุรกิจที่มีทั้งร้านค้าออนไลน์และออฟไลน์ ในการศึกษาได้เสนอวิธีการแก้ปัญหาด้วยการพยากรณ์ความต้องการของผู้บริโภค โดยแยกเป็นส่วนของออนไลน์และออฟไลน์ ซึ่งในส่วน of สาขาออฟไลน์ของบริษัทกรณีศึกษานี้มีหลายสาขาทั่วทั้งประเทศ ผู้วิจัยจึงทำการเลือกในส่วน of สาขาขนาดใหญ่ที่มียอดขายสูงมาใช้ในการวิจัยครั้งนี้ โดยงานวิจัยนี้มีขั้นตอนการดำเนินงานวิจัยดังภาพที่ 1



ภาพที่ 1 ขั้นตอนการดำเนินงานวิจัย

4.1 ประชากรและกลุ่มตัวอย่าง

ประชากรคือ ยอดขายรายการสินค้ากลุ่มเครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์กว่า 4,000 รายการของสาขาออนไลน์และออฟไลน์จากระบบภายในขององค์กรกรณีศึกษา เป็นระยะเวลา 1 ปี ตั้งแต่เดือนมกราคม – ธันวาคม 2565

กลุ่มตัวอย่างคือ รายการสินค้าที่คัดเลือกด้วยวิธี ABC Analysis และตรงตามเกณฑ์ที่กำหนดเพื่อตอบวัตถุประสงค์ที่จะนำมาศึกษา

4.2 การจัดหมวดหมู่ตามหลัก ABC analysis

เนื่องจากจำนวน SKU ของบริษัทกรณีศึกษา มีมากกว่า 4,000 รายการ ทางผู้วิจัยจึงได้ใช้วิธี ABC Analysis เข้ามาช่วยในการคัดกรอง SKU ที่ตรงตามเงื่อนไขและวัตถุประสงค์ที่จะนำมาศึกษา โดยมีเกณฑ์

และเงื่อนไข คือ


- เป็นสินค้าที่มียอดขายสูงและอยู่ในกลุ่ม A
- ไม่ใช่สินค้าในกลุ่ม Pre-Orders เนื่องจากสินค้าในกลุ่มนี้จะมีการเปิดขายเป็นรอบ ๆ ทำให้ข้อมูลที่จะมาใช้พยากรณ์มีไม่เพียงพอ
- เป็นรายการสินค้าที่มีจำนวนวันที่หรือข้อมูลเพียงพอต่อการนำไปพยากรณ์

4.3 การพยากรณ์

1. การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักและวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลทางผู้วิจัยได้ใช้ Microsoft excel ในการพยากรณ์ โดยใช้ฟังก์ชัน Solver ของ Microsoft excel เข้ามาช่วยในการกำหนดค่าน้ำหนัก w สำหรับการพยากรณ์แบบ WMA และกำหนดค่า α , β สำหรับ

การพยากรณ์แบบ SES, DES โดยมี Objective function คือ ผลรวมที่ต่ำที่สุดของค่าความคลาดเคลื่อน MSE, MAD, MAPE และ Decision

Variable คือ ค่าน้ำหนัก w , Alpha, Beta โดยกำหนด Constraints ให้มีค่าตั้งแต่ 0-1



ภาพที่ 2 ตัวอย่างการใช้ฟังก์ชัน Solver

การกำหนดระยะเวลา n ของวิธีการพยากรณ์แบบ WMA ทางผู้วิจัยได้แบ่งเป็น $n = 2, 3, 4$ เนื่องจากการวางแผนรอบรถ Milk-run ขององค์กรกรณีศึกษาจะมีการวางแผนเป็นรายเดือน ซึ่งตาม n ที่กำหนดเป็นช่วงเวลาที่อยู่ในระยะเวลาของการวางแผนรอบรถพอดี

2. การพยากรณ์ด้วยวิธี ARIMA วิธีการพยากรณ์แบบ ARIMA ผู้วิจัยได้ใช้ Google Colab เป็นเครื่องมือเข้ามาช่วยในการพยากรณ์โดยมีขั้นตอนดังนี้

1) แบ่งข้อมูลออกเป็น 70:30 โดย 70% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการฝึก และอีก 30% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการทดสอบ

2) ทำการตรวจสอบว่าชุดข้อมูลนั้นคงที่ (Stationary) หรือไม่โดยทำการทดสอบ Augmented Dickey-Fuller test (ADF) โดย (Dickey & Fuller, 1979) ถ้าหากค่า p -value ออกมามากกว่า 0.05

จะต้องทำการ Differencing และทดสอบ ADF test จนกว่าค่า p -value จะน้อยกว่า 0.05

3) ทำการพล็อตกราฟ ACF และ PACF เพื่อใช้ในการวิเคราะห์และคาดการณ์อนุกรมเวลา โดยจะให้ข้อมูลเชิงลึกเกี่ยวกับโครงสร้างความสัมพันธ์ของข้อมูลอนุกรมเวลาและเพื่อหาค่า p , q

4) พยากรณ์โดยกำหนดค่าพารามิเตอร์ p , d , q โดยค่า p ได้มาจากการพล็อตกราฟ PACF ค่า d ได้มาจากการทำ Differencing และค่า q ได้มาจากการพล็อตกราฟ ACF จากนั้นเก็บค่าความคลาดเคลื่อนครั้งที่ 1

5) ใช้คำสั่ง auto_arima เพื่อประเมินชุดค่าพารามิเตอร์ของแบบจำลอง ARIMA (p , d , q) และคำนวณค่า AIC โดยตัวแบบที่มีค่า AIC ต่ำที่สุดจะถูกเลือกมากำหนดเป็นค่าพารามิเตอร์สำหรับการพยากรณ์

6) พยากรณ์โดยกำหนดค่าพารามิเตอร์ที่ได้

จากการเลือก AIC ที่ต่ำที่สุดและวัดค่าความคลาดเคลื่อนด้วยตัวชี้วัด MAD MSE และ MAPE จากนั้นเปรียบเทียบค่าความคลาดเคลื่อนกับการพยากรณ์ครั้งที่ 1 แล้วเลือกตัวแบบที่ให้ค่าความคลาดเคลื่อนต่ำที่สุด

3. การพยากรณ์ด้วยวิธี FFNNs วิธีการพยากรณ์แบบ FFNNs ผู้วิจัยได้ใช้ Google Colab เป็นเครื่องมือเข้ามาช่วยในการพยากรณ์ โดยใช้ไลบรารีที่ชื่อว่า Tensorflow และ Keras ที่เป็น API เข้ามาช่วยในการสร้างโมเดลพยากรณ์ เนื่องจาก TensorFlow เป็นไลบรารีฟรีที่พัฒนาโดย Google brain team ซึ่งในการนำไปใช้งานจริงทางภาคธุรกิจสามารถนำไปใช้ได้โดยไม่มีค่าใช้จ่ายใด ๆ สำหรับการพยากรณ์มีขั้นตอนดังนี้

1) แบ่งข้อมูลสำหรับฝึกและทดสอบที่ 70:30 โดย 70% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการฝึก และอีก 30% ถูกนำไปใช้เพื่อเป็นข้อมูลสำหรับการทดสอบ

2) เรียกใช้ API Keras เพื่อสร้างโครงสร้างของโมเดล โดยจะประกอบไปด้วย Hidden layer และ Output layer ใช้ MSE เป็นฟังก์ชันในการส่งกลับค่าสูญเสีย (loss) และใช้ Adam เป็น Optimizer ช่วยในการปรับ Learning rate

3) การกำหนดจำนวนชั้นและจำนวนเซลล์ทางผู้วิจัยได้ใช้ GridSearch โดยจำนวนชั้นจะกำหนดอยู่ที่ 1-3 ชั้น และจำนวนเซลล์กำหนดให้เริ่มตั้งแต่ 10-100 โดยจะเพิ่มขึ้นครั้งละ 10 เนื่องจากตัวของข้อมูลไม่ได้มีความซับซ้อนและมีขนาดเล็ก โดยจะพิจารณาจากคะแนนค่าเฉลี่ยของข้อผิดพลาดกำลังสอง (MSE) ที่ต่ำที่สุด

กระบวนการวนซ้ำ (Epochs) เนื่องด้วยข้อจำกัดของซอฟต์แวร์ Google Colab ที่เป็นตัวฟรีนั้นจะเป็นการประมวลผลบนคลาวด์เซิร์ฟเวอร์ซึ่งจะถูกจำกัดในเรื่องของ RAM Disk และความแรงของ CPU ที่ใช้ประมวลผล ดังนั้นผู้วิจัยจึงได้ทำการ

สุ่มรายการสินค้ามาทดสอบโดยใช้ GridSearch หาค่าของ epochs ตั้งแต่ 100-1,000 เพื่อสร้างกราฟแสดงแนวโน้มการลดลงของค่าสูญเสีย (loss) เพื่อนำมาใช้ตัดสินใจในการกำหนดค่า epochs ซึ่งในงานวิจัยนี้ผู้วิจัยได้กำหนดค่าไว้ที่ 1,000

Batch size คือ จำนวนรายการข้อมูลที่จะให้ Optimizer คำนวณในหนึ่งครั้ง ทางผู้วิจัยได้กำหนดค่าโดยคำนึงถึงความสามารถของทรัพยากร RAM Disk ซึ่งขนาดแบทช์ที่ใหญ่ขึ้นจะใช้หน่วยความจำมากขึ้นทางผู้วิจัยจึงได้ลองกำหนดค่า Batch size ที่ 3 ช่วง คือ

- มีขนาดเล็กกว่าชุดข้อมูล
- มีขนาดเท่ากับชุดข้อมูล
- มีขนาดมากกว่าชุดข้อมูล

จากการสุ่มกับข้อมูลรายการสินค้า 3 SKU พบว่าการกำหนดขนาด Batch size เท่ากับชุดข้อมูลให้ผลลัพธ์ที่เป็นค่าความคลาดเคลื่อนต่ำที่สุด ดังนั้นทางผู้วิจัยจึงขอกำหนดขนาดของ Batch size เท่ากับขนาดของชุดข้อมูลในงานวิจัยนี้

4) เมื่อได้ค่าพารามิเตอร์ที่ต้องการครบแล้วทำการฝึกอบรมตัวโมเดลด้วยข้อมูลสำหรับฝึกและทำการพยากรณ์ด้วยข้อมูลสำหรับทดสอบ โดยวัดค่าความคลาดเคลื่อนออกมาเป็น MAD MSE และ MAPE

4.4 เปรียบเทียบผลการพยากรณ์และสรุปผล

เมื่อพยากรณ์ครบทั้ง 5 วิธีที่กำหนด ทำการวัดผลการพยากรณ์โดยพิจารณาจากตัวชี้วัดทั้ง 3 ตัวคือ MAD MSE และ MAPE ว่าตัวใดมีค่าต่ำที่สุด หากแบบจำลองไม่ได้มีค่าความคลาดเคลื่อนต่ำที่สุดทั้ง 3 ตัว จะพิจารณาจากแบบจำลองที่มีค่าความคลาดเคลื่อนต่ำที่สุด 2 ตัว

5. ผลการวิจัย

5.1 ผลการจัดกลุ่มสินค้าด้วยหลัก ABC analysis

จากการใช้ ABC Analysis เข้ามาช่วยในการคัดเลือก SKU ที่มีคุณสมบัติเหมาะสมที่จะนำมา

พยากรณ์ เช่น เป็นรายการสินค้าที่อยู่ในกลุ่ม A เป็นรายการสินค้าที่ไม่ได้อยู่ในกลุ่มสินค้า Pre-Orders เป็นรายการสินค้าที่มีจำนวนวันที่หรือข้อมูลเพียงพอ

ต่อการนำไปพยากรณ์ ซึ่งผลลัพธ์ที่ได้คือ ฝั่งออนไลน์มี 10 SKUs และฝั่งออฟไลน์มี 3 SKUs โดยที่ฝั่งออฟไลน์มี 2 SKUs ที่มีเพียงสาขาที่ 3 และ 4 ดังตารางที่ 1

ตารางที่ 1 ข้อมูลรายการสินค้าของสาขาออนไลน์และออฟไลน์จากการคัดเลือกรายการสินค้าด้วย ABC Analysis

Store	SKU	ยอดขาย (จำนวน)	ยอดขาย (บาท)	Store	SKU	ยอดขาย (จำนวน)	ยอดขาย (บาท)
Store Online	SKU 1	7,994	71,882,048	Store 1	SKU 1	761	6,842,912
	SKU 2	5,569	24,447,910	Store 2	SKU 1	620	5,575,040
	SKU 3	3,842	26,087,180		SKU 3	571	3,877,090
	SKU 4	3,638	18,153,620	Store 3	SKU 1	830	7,463,360
	SKU 5	1,710	3,744,900		SKU 3	761	5,167,190
	SKU 6	1,019	12,126,100		SKU 4	1,051	5,244,490
	SKU 7	4,870	7,256,300	Store 4	SKU 1	867	7,796,064
	SKU 8	1,494	2,973,060	Store 5	SKU 1	480	4,316,160
	SKU 9	1,355	6,083,950				
	SKU 10	1,754	7,524,660				

5.2 ผลการพยากรณ์ (Forecast)

1. ผลการพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก จากการพยากรณ์ด้วยแบบจำลอง WMA ที่ $n = 2, 3, 4$ สัปดาห์ ในส่วนของสาขาออนไลน์พบว่าที่ $n = 4$ จะให้ผลลัพธ์การพยากรณ์ที่ดีกว่าซึ่งมีค่าความคลาดเคลื่อนต่ำที่สุด โดยมีเพียง SKU 1, 2 ที่ $n = 3$ ให้ผลการพยากรณ์ดีกว่า ในส่วนของสาขาออฟไลน์พบว่าแบบจำลอง WMA ที่ $n = 4$ ได้ให้ผลลัพธ์การพยากรณ์ที่ใกล้เคียงกับสาขาออนไลน์เช่นกัน โดยรายการสินค้า SKU 1 ของสาขาที่ 5 มีค่าความคลาดเคลื่อนต่ำที่สุดในแบบจำลอง WMA ที่ $n = 4$

2. ผลการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปแนเนเชียลขั้นเดียว จากการพยากรณ์ด้วยแบบจำลอง SES ในส่วนของสาขาออนไลน์พบว่า จากการใช้เครื่องมือ Solver ของ Microsoft Excel ในการกำหนดค่า Alpha ซึ่งรายการสินค้าส่วนใหญ่พบว่ามี

ค่าอยู่ระหว่าง 0.13 – 0.76 โดยมีเพียงรายการสินค้า SKU 9 ที่มีค่า Alpha เข้าใกล้ 1 ซึ่งหมายความว่า การพยากรณ์จะอิงตามการสังเกตครั้งล่าสุดเป็นหลัก และในส่วนของสาขาออฟไลน์พบว่าค่า Alpha ของรายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า การพยากรณ์จะอิงตามค่าการพยากรณ์ในอดีตเป็นหลัก และได้รับอิทธิพลน้อยจากค่าการสังเกตครั้งล่าสุด จากผลการพยากรณ์ด้วยแบบจำลอง SES แสดงให้เห็นว่ามีประสิทธิภาพกับข้อมูลยอดขายของสาขาออฟไลน์มากกว่าสาขาออนไลน์ โดยสาขาออฟไลน์มีค่าเฉลี่ยของ MAPE อยู่ที่ 23.4% และออนไลน์อยู่ที่ 26.58%

3. ผลการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปแนเนเชียลซ้ำสองครั้ง จากการพยากรณ์ด้วยแบบจำลอง DES ด้วยเครื่องมือ Solver ของ Microsoft Excel ในการช่วยกำหนดค่า Alpha และ Beta ส่วนของสาขาออนไลน์และออฟไลน์พบว่า ค่า Alpha ที่ได้มีค่าใกล้เคียงกับแบบจำลอง SES ซึ่งหมายความว่า

รายการสินค้าที่มีค่า Alpha เข้าใกล้ 1 คือ การพยากรณ์จะอิงตามการสังเกตครั้งล่าสุดเป็นหลัก และรายการสินค้าที่มีค่า Alpha เข้าใกล้ 0 การพยากรณ์จะอิงตามค่าการพยากรณ์ในอดีตเป็นหลัก ในส่วนของค่า Beta ทั้งสาขาออนไลน์และออฟไลน์พบว่า รายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า การพยากรณ์ได้รับอิทธิพลน้อยลงจากการเปลี่ยนแปลงล่าสุดในแนวโน้มของอนุกรมเวลา จากการพยากรณ์ด้วยแบบจำลอง DES แสดงให้เห็นว่าแบบจำลองมีประสิทธิภาพกับข้อมูลยอดขายของสาขาออฟไลน์มากกว่าสาขาออนไลน์ โดยสาขาออฟไลน์มีค่าเฉลี่ยของ MAPE อยู่ที่ 23.51% และสาขาออนไลน์มีค่าเฉลี่ยของ MAPE อยู่ที่ 26.91%

4. ผลการพยากรณ์ด้วยวิธี ARIMA จากการพยากรณ์ด้วยแบบจำลอง ARIMA โดยทำการกำหนดตัวแบบด้วยการทำ Differencing เพื่อหาค่า d และพิจารณาจากกราฟ PACF, ACF เพื่อหาค่า p, q ร่วมกับการใช้ AIC หาตัวแบบที่มีค่า AIC score ที่ต่ำที่สุดเพื่อเปรียบเทียบและเลือกตัวแบบที่ให้ค่าความคลาดเคลื่อนต่ำที่สุด ในส่วนของสาขาออนไลน์พบว่า ค่าความคลาดเคลื่อนจากชุดข้อมูลสำหรับฝึกมีค่า MAPE เฉลี่ยอยู่ที่ 28.17% และจากชุดข้อมูลสำหรับทดสอบมีค่า MAPE เฉลี่ยอยู่ที่ 28.53% โดยรายการสินค้า SKU10 มีค่าความคลาดเคลื่อนต่ำที่สุดโดยมีค่า MAPE จากชุดข้อมูลสำหรับฝึกอยู่ที่ 22.87% และมีค่า MAPE จากชุดข้อมูลสำหรับทดสอบอยู่ที่ 18.11%

สำหรับสาขาออฟไลน์พบว่า ค่าความคลาดเคลื่อนจากชุดข้อมูลสำหรับฝึกมีค่า MAPE เฉลี่ยอยู่ที่ 26.52% และจากชุดข้อมูลสำหรับทดสอบมีค่า MAPE เฉลี่ยอยู่ที่ 27.55% จากการพยากรณ์ด้วยแบบจำลอง ARIMA แสดงให้เห็นว่าแบบจำลองมีประสิทธิภาพกับข้อมูลยอดขายของสาขาออฟไลน์มากกว่าสาขาออนไลน์

5. ผลการพยากรณ์ด้วยวิธี FFNNs จากการพยากรณ์ด้วยแบบจำลอง FFNNs โดยใช้ GridSearch ในการช่วยกำหนดจำนวนชั้น (Layer) และจำนวนเซลล์ (Neurons) โดยใช้ Adam เป็น Optimizer ช่วยในการปรับค่าอัตราการเรียนรู้ กำหนดกระบวนการวนซ้ำ (epochs) ไว้ที่ 1,000 และ Batch size ที่ขนาดเท่ากับชุดข้อมูลคือ 52 สัปดาห์ในส่วนของสาขาออนไลน์พบว่า ค่าความคลาดเคลื่อนของชุดข้อมูลสำหรับฝึกและทดสอบนั้น แบบจำลองแสดงประสิทธิภาพได้ต่ำ เมื่อพิจารณาจากค่า R-square ที่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า ระหว่างตัวแปรอินพุตและตัวแปรเป้าหมาย แบบจำลองไม่สามารถจับความสัมพันธ์ในข้อมูลได้เท่าที่ควร อาจกล่าวได้ว่า แบบจำลองไม่เหมาะสมกับข้อมูลพยากรณ์ที่กำหนด ในส่วนของสาขาออฟไลน์พบว่า แบบจำลองนี้สามารถให้ผลลัพธ์การพยากรณ์ที่มีประสิทธิภาพมากกว่าข้อมูลยอดขายของสาขาออนไลน์ โดยมีค่า MAPE ของชุดข้อมูลสำหรับฝึกเฉลี่ยอยู่ที่ 28.73% และชุดข้อมูลสำหรับทดสอบเฉลี่ยอยู่ที่ 33.18%

MAD										
Store	SKU	WMA 2	WMA 3	WMA 4	SES	DES	ARIMA		FFNNs	
							train	test	train	test
Online	SKU 1	34.20	32.97	33.44	32.46	33.10	36.55	26.77	43.36	43.27
	SKU 2	22.10	21.55	21.79	21.75	22.18	26.94	22.90	22.21	26.07
	SKU 3	15.56	15.77	15.20	16.36	16.83	20.62	20.20	22.12	31.96
	SKU 4	23.43	22.46	21.37	23.43	23.85	25.72	23.67	25.82	41.39
	SKU 5	9.37	9.27	9.14	9.13	9.31	10.42	8.00	16.12	17.85
	SKU 6	6.10	5.20	5.06	5.68	5.78	5.90	5.15	5.92	5.49
	SKU 7	30.31	29.15	28.28	28.17	28.72	22.40	36.18	38.86	57.28
	SKU 8	7.37	6.78	6.29	6.18	6.27	7.67	5.60	6.79	6.15
	SKU 9	5.70	5.74	5.57	5.71	5.82	6.11	5.07	11.04	13.66
	SKU 10	7.52	7.54	7.50	8.46	8.63	7.21	8.08	8.85	9.47
1	SKU 1	4.65	4.42	4.10	3.64	3.72	4.32	3.21	4.59	4.00
2	SKU 1	2.99	2.91	2.66	2.74	2.65	3.54	3.54	2.18	2.86
	SKU 3	2.65	2.47	2.50	2.33	2.38	2.64	2.85	7.00	3.13
3	SKU 1	6.27	6.02	5.41	5.57	5.68	6.50	4.41	3.89	6.17
	SKU 3	4.56	4.16	3.50	3.65	3.69	3.07	4.11	3.13	3.52
	SKU 4	5.68	4.86	4.66	4.57	4.73	4.76	6.08	3.50	5.14
4	SKU 1	4.13	3.85	3.39	3.15	3.22	3.93	2.31	3.37	4.37
5	SKU 1	1.99	1.52	1.49	1.51	1.53	1.44	1.42	5.95	2.29

ภาพที่ 3 แสดงค่าความคลาดเคลื่อนของตัวชี้วัด MAD

MSE										
Store	SKU	WMA 2	WMA 3	WMA 4	SES	DES	ARIMA		FFNNs	
							train	test	train	test
Online	SKU 1	1,980.68	1,906.47	1,857.24	1,749.97	1,784.28	2,008.00	934.45	2,839.33	2,738.80
	SKU 2	751.71	723.37	733.97	737.83	752.29	1,146.10	862.26	824.41	1,135.09
	SKU 3	440.13	447.45	422.14	487.12	496.67	753.62	560.14	782.84	1,307.09
	SKU 4	984.15	923.53	855.63	1,028.71	1,048.88	1,436.83	1,465.40	1,138.48	2,189.02
	SKU 5	144.38	139.37	137.04	137.09	139.78	170.64	127.33	403.14	375.47
	SKU 6	52.06	41.09	39.79	50.61	51.60	53.93	33.89	59.58	40.72
	SKU 7	1,402.83	1,307.95	1,238.21	1,339.17	1,365.43	861.09	1,931.26	2,445.98	4,551.68
	SKU 8	81.35	74.30	65.36	65.87	67.16	106.28	50.98	72.27	58.70
	SKU 9	57.94	58.04	56.14	58.48	59.63	64.19	38.04	186.81	229.75
	SKU 10	109.48	106.95	101.66	103.77	105.81	91.33	130.43	121.24	132.31
1	SKU 1	41.71	37.65	34.34	28.84	29.40	31.58	12.57	34.27	18.81
2	SKU 1	21.87	19.44	16.90	15.46	15.37	24.21	16.11	7.91	10.57
	SKU 3	11.22	10.47	10.58	8.76	8.95	10.45	10.40	123.01	13.69
3	SKU 1	83.82	80.57	69.75	73.88	75.32	91.54	25.84	26.25	43.92
	SKU 3	31.44	25.25	21.11	22.92	22.95	13.23	28.12	18.88	22.12
	SKU 4	47.30	34.32	32.40	32.06	32.69	44.30	47.05	18.85	42.93
4	SKU 1	27.19	24.40	21.67	20.77	21.17	30.38	9.38	17.32	27.24
5	SKU 1	6.27	4.07	3.86	3.91	3.99	3.63	3.08	58.93	6.95

ภาพที่ 4 แสดงค่าความคลาดเคลื่อนของตัวชี้วัด MSE

MAPE										
Store	SKU	WMA 2	WMA 3	WMA 4	SES	DES	ARIMA		FFNNs	
							train	test	train	test
Online	SKU 1	23.60%	22.74%	22.86%	22.58%	23.02%	25.41%	21.22%	30.72%	27.47%
	SKU 2	21.80%	21.47%	21.76%	21.52%	21.94%	26.05%	30.73%	22.15%	34.74%
	SKU 3	22.34%	22.63%	21.93%	23.89%	24.01%	28.95%	32.78%	36.80%	51.81%
	SKU 4	33.45%	32.64%	30.13%	33.86%	34.07%	34.66%	29.41%	42.78%	78.20%
	SKU 5	30.21%	30.37%	30.20%	29.69%	30.27%	32.14%	28.31%	51.43%	96.96%
	SKU 6	32.43%	28.00%	27.91%	31.37%	31.11%	31.75%	36.32%	28.64%	38.77%
	SKU 7	32.28%	31.69%	30.98%	31.77%	32.39%	26.77%	34.59%	49.07%	78.84%
	SKU 8	27.41%	25.60%	23.34%	24.51%	24.81%	27.91%	27.78%	25.63%	30.31%
	SKU 9	23.66%	23.71%	23.72%	23.93%	24.40%	25.17%	26.03%	46.18%	58.05%
	SKU 10	22.63%	22.56%	22.89%	22.66%	23.10%	22.87%	18.11%	28.58%	29.83%
1	SKU 1	31.31%	29.79%	27.07%	20.38%	20.78%	28.74%	27.86%	30.08%	34.87%
2	SKU 1	25.46%	24.67%	22.32%	23.85%	21.68%	27.00%	47.07%	23.33%	37.29%
	SKU 3	25.13%	24.08%	24.47%	22.59%	23.07%	28.03%	19.51%	35.83%	24.97%
3	SKU 1	36.61%	35.01%	31.92%	34.08%	34.75%	37.11%	45.64%	22.85%	61.43%
	SKU 3	34.08%	32.97%	28.05%	25.70%	26.16%	25.11%	21.53%	23.91%	18.36%
	SKU 4	30.28%	25.18%	24.12%	24.80%	25.29%	26.44%	25.35%	30.02%	27.26%
4	SKU 1	25.27%	23.87%	21.02%	18.23%	18.59%	22.96%	17.02%	32.91%	33.27%
5	SKU 1	22.23%	17.19%	17.10%	17.60%	17.80%	16.75%	16.44%	30.94%	28.01%

ภาพที่ 5 แสดงค่าความคลาดเคลื่อนของตัวชี้วัด MAPE

Store	SKU	SES			DES						ARIMA			FFNNs	
		Alpha			Alpha			Beta			p	d	q	R-square	
		MAD	MSE	MAPE	MAD	MSE	MAPE	MAD	MSE	MAPE				train	test
Online	SKU 1	0.39	0.39	0.41	0.39	0.39	0.41	0.00	0.00	0.00	1	0	0	0.26	0.45
	SKU 2	0.49	0.44	0.52	0.49	0.44	0.52	0.00	0.00	0.00	0	1	1	0.02	0.64
	SKU 3	0.59	0.40	0.61	0.50	0.40	0.48	0.21	0.00	0.16	1	1	0	0.07	0.62
	SKU 4	0.66	0.68	0.69	0.66	0.68	0.66	0.01	0.00	0.02	0	1	0	0.08	0.28
	SKU 5	0.74	0.64	0.74	0.74	0.64	0.74	0.00	0.00	0.00	0	1	0	0.00	0.18
	SKU 6	0.33	0.38	0.50	0.37	0.38	0.36	0.02	0.00	0.06	1	0	0	0.17	0.21
	SKU 7	0.30	0.31	0.55	0.30	0.31	0.55	0.00	0.00	0.00	1	0	0	0.43	0.16
	SKU 8	0.13	0.22	0.44	0.12	0.22	0.39	0.01	0.00	0.05	0	1	1	0.07	0.04
	SKU 9	1.00	1.00	0.92	1.00	1.00	0.92	0.00	0.00	0.00	1	0	0	0.48	0.03
	SKU 10	0.05	0.56	0.76	0.05	0.56	0.76	0.00	0.00	0.00	1	0	0	0.23	0.53
1	SKU 1	0.01	0.11	0.00	0.01	0.11	0.00	0.00	0.00	0.08	2	0	0	0.05	0.03
2	SKU 1	0.20	0.12	0.27	0.05	0.05	0.04	0.60	0.13	0.83	0	1	1	0.19	0.10
	SKU 3	0.15	0.15	0.11	0.15	0.15	0.11	0.00	0.00	0.00	1	0	0	0.03	0.05
3	SKU 1	0.22	0.23	0.31	0.22	0.23	0.31	0.00	0.00	0.00	1	0	2	0.07	0.26
	SKU 3	0.13	0.16	0.06	0.08	0.11	0.05	0.02	0.03	0.01	2	0	1	0.10	0.02
	SKU 4	0.15	0.00	0.15	0.00	0.00	0.15	0.26	0.00	0.00	3	1	0	0.00	0.01
4	SKU 1	0.11	0.16	0.04	0.11	0.16	0.04	0.00	0.00	0.00	0	1	1	0.07	0.08
5	SKU 1	0.07	0.11	0.12	0.08	0.11	0.12	0.00	0.00	0.02	0	0	3	0.01	0.01

ภาพที่ 6 แสดงข้อมูลค่า Alpha, Beta และค่าพารามิเตอร์ของแบบจำลอง


ในส่วนของต้นทุนเนื่องจากช่องทางออฟไลน์ทางองค์กรไม่ได้มีนโยบายที่จะมุ่งเน้นการสต็อกสินค้าไว้ที่สาขา โดยการเลือกรายการสินค้าและจำนวนมาจัดเก็บจะขึ้นอยู่กับวิธีการจัดการของผู้จัดการสาขา ซึ่งแตกต่างกับส่วนของช่องทางออนไลน์ที่ต้องรองรับปริมาณคำสั่งซื้อทั่วทั้งประเทศ ดังนั้นส่วนของต้นทุนที่เป็นมูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์จะเป็นของ

คลังสินค้าออนไลน์ โดยเมื่อคำนวณปริมาณสินค้าคงคลังขั้นต่ำใหม่แล้วเปรียบเทียบกับพบว่า มีปริมาณสินค้าที่ต้องถือครองลดลงไป 96 ชิ้นต่อสัปดาห์ หรือคิดเป็นมูลค่าลดลงไป 513,026 บาทต่อสัปดาห์ โดยมีสินค้า 6 รายการที่มีปริมาณการถือครองลดลง 3 รายการที่มีปริมาณการถือครองสูงขึ้นและ 1 รายการที่มีปริมาณเท่าเดิมดังภาพที่ 7

ผ่านการรับรองคุณภาพจากศูนย์ดัชนีการอ้างอิงวารสารไทย (TCI.) อยู่ในกลุ่ม 1 สาขามนุษยศาสตร์และสังคมศาสตร์

SKU	Price per unit	Safety Stock Per Month	Safety Stock Per Week	Cost (Current)	Safety Stock (New)	Cost (New)	Result
SKU 1	8,992	800	200	1,798,400	157	1,411,744	386,656.00
SKU 2	4,390	480	120	526,800	107	469,730	57,070.00
SKU 3	6,790	280	70	475,300	75	509,250 -	33,950.00
SKU 4	4,990	320	80	399,200	69	344,310	54,890.00
SKU 5	2,190	200	50	109,500	19	41,610	67,890.00
SKU 6	11,900	80	20	238,000	20	238,000	-
SKU 7	1,490	400	100	149,000	97	144,530	4,470.00
SKU 8	1,990	160	40	79,600	30	59,700	19,900.00
SKU 9	4,490	80	20	89,800	25	112,250 -	22,450.00
SKU 10	4,290	120	30	128,700	35	150,150 -	21,450.00

ภาพที่ 7 แสดงรายการมูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์



ภาพที่ 8 เปรียบเทียบมูลค่าสินค้าคงคลังขั้นต่ำต่อสัปดาห์

6. สรุปผลการวิจัยและอภิปรายผล

1. ด้านระดับสินค้าคงคลังของสินค้าประเภทเครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ที่มีผลกระทบต่อยอดขายของบริษัทกรณีศึกษา จากการใช้เครื่องมือการวิเคราะห์ ABC ช่วยในการจัดกลุ่มของสินค้าโดยพิจารณาจากปัจจัยต่าง ๆ เช่น ปริมาณการขายและราคา พบว่า สินค้าส่วนใหญ่ที่อยู่ในกลุ่ม A จะเป็นกลุ่มสินค้าตามฤดูกาล (Seasonal Product)

ประเภทอุปกรณ์เสริมของโทรศัพท์มือถือ เนื่องมาจากทุกครั้งที่มีการออกโทรศัพท์มือถือรุ่นใหม่ ๆ มักจะส่งผลทำให้ยอดขายของสินค้ากลุ่มนี้เพิ่มสูงขึ้น

2. ด้านประสิทธิภาพของแบบจำลองการพยากรณ์ความต้องการของลูกค้าองค์กรกรณีศึกษา จากการพยากรณ์ยอดขายกับรายการสินค้าช่องทางออนไลน์ทั้ง 10 รายการพบว่า แบบจำลอง WMA ที่จำนวนของข้อมูลย้อนหลังมากขึ้นมีแนวโน้ม

ว่าจะมีค่าความแม่นยำที่สูงขึ้น โดยรายการสินค้า 6 จาก 10 รายการ มีความแม่นยำในการพยากรณ์ด้วยแบบจำลอง WMA ที่ดีกว่าแบบจำลองอื่น แม้ว่า WMA จะให้ผลลัพธ์การพยากรณ์ที่ดีที่สุดจากทุกแบบจำลอง แต่ในส่วนของแบบจำลองอื่น เช่น แบบจำลอง ARIMA ต่างก็ให้ค่าความแม่นยำในการพยากรณ์ที่เกาะกลุ่มกับแบบจำลอง WMA เช่นกัน ทางด้านช่องทางออฟไลน์พบว่า รายการสินค้า 4 จาก 8 รายการ จากทั้ง 5 สาขา แสดงให้เห็นว่าแบบจำลอง ARIMA ให้ผลลัพธ์ที่แม่นยำกว่าแบบจำลองอื่น

ทางด้านประสิทธิภาพของแบบจำลองการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลชั้นเดียว (SES) และแบบจำลองการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (DES) พบว่าค่า Alpha ของรายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 ซึ่งหมายความว่า การพยากรณ์จะให้ความสำคัญกับข้อมูลในอดีตมากกว่า ในส่วนของค่า Beta ในแบบจำลอง DES พบว่า รายการสินค้าส่วนใหญ่มีค่าเข้าใกล้ 0 เช่นกัน ซึ่งหมายความว่าองค์ประกอบแนวโน้มไม่เปลี่ยนแปลงอย่างมีนัยสำคัญเมื่อเวลาผ่านไป หรือมีการเปลี่ยนแปลงในอัตราที่ช้ามาก วิธีการตรวจไม่พบแนวโน้มที่แข็งแกร่งในข้อมูล ซึ่งอาจเป็นผลมาจากยอดขายสินค้าในวันที่จัดโปรโมชั่นที่มักจะมียอดขายสูงกว่าปกติ จากสาเหตุที่กล่าวมาส่งผลให้แบบจำลองการพยากรณ์ด้วยวิธีปรับเรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้งทำงานได้ไม่เต็มประสิทธิภาพ ในส่วนของแบบจำลองการพยากรณ์ด้วยวิธี FFNNs ในงานวิจัยนี้ แม้ว่าในตัวของสินค้าบางรายการจะมีค่าความคลาดเคลื่อนที่ต่ำที่สุด แต่เมื่อพิจารณาประสิทธิภาพของแบบจำลองได้แสดงให้เห็นผลลัพธ์ที่มีค่าความคลาดเคลื่อนสูงกว่าวิธีอื่น ซึ่งจากที่ได้ใช้การวิเคราะห์ ABC พบว่าสินค้าส่วนใหญ่จะเป็นกลุ่มสินค้าตามฤดูกาล ซึ่งข้อมูลที่ใช้พยากรณ์ในงานวิจัยนี้มีระยะเวลา 1 ปี อาจไม่เพียงพอต่อการเรียนรู้ของแบบจำลอง จึงสรุปได้ว่าแบบจำลอง

การพยากรณ์ FFNNs เป็นเครื่องมือที่ไม่มีประสิทธิภาพในงานวิจัยนี้

แม้ว่าช่องทางออนไลน์โดยรวมจะพบว่าแบบจำลอง WMA ได้ให้ผลลัพธ์การพยากรณ์ที่แม่นยำที่สุด แต่เมื่อพิจารณาจากภาพรวมของทั้ง 2 ช่องทางจะเห็นได้ว่า แบบจำลอง ARIMA เป็นแบบจำลองที่ให้ประสิทธิภาพโดยรวมดีกว่าแบบจำลองอื่น ๆ โดยรายการสินค้าทั้ง 18 รายการมี 8 รายการที่แบบจำลอง ARIMA ให้ผลการพยากรณ์ที่แม่นยำที่สุด

7. ข้อเสนอแนะ

7.1 ข้อเสนอแนะในการนำผลการวิจัยไปใช้

ผลการทดลองในงานวิจัยนี้เป็นการพยากรณ์ยอดขายรายการสินค้าประเภทเครื่องใช้ไฟฟ้าของบริษัทเอกชนแห่งหนึ่ง โดยใช้เครื่องมือพยากรณ์ทั้งหมด 5 แบบ คือ WMA SES DES ARIMA และ FFNNs ซึ่งผลลัพธ์ที่ได้สามารถนำไปเป็นแนวทางเปรียบเทียบกับวิธีการพยากรณ์แบบอื่นได้ในส่วนของการกำหนดค่าพารามิเตอร์ของแบบจำลอง ARIMA และ FFNNs ในงานวิจัยนี้ได้ใช้ AIC และ Grid search ในการกำหนดค่า ซึ่งในงานวิจัยต่อไปสามารถใช้เป็นแนวทางในการเลือกเครื่องมืออื่น ๆ เข้ามาช่วยกำหนดค่าได้

7.2 ข้อเสนอแนะในการวิจัยครั้งต่อไป

ในงานวิจัยครั้งต่อไป ข้อมูลที่จะนำมาใช้พยากรณ์ควรมีอย่างน้อย 2 ปี เนื่องจากในธุรกิจประเภทนี้จะมีสินค้าบางรายการที่เป็น Seasonal Product ดังนั้นถ้ามีข้อมูลมากกว่า 1 ปีเข้ามาช่วยในการดูแนวโน้มของยอดขายที่มักจะสูงกว่าปกติในวันที่จัดโปรโมชั่น คาดว่าจะช่วยให้การพยากรณ์มีความแม่นยำมากขึ้น และการทำ Cross validation เพื่อเพิ่มประสิทธิภาพของตัวโมเดล รวมไปถึงการทำ Association rule ของสินค้าเพื่อหาความสัมพันธ์ที่เกี่ยวข้องของสินค้าที่ลูกค้ามักจะซื้อพร้อมกัน เพื่อนำไปเป็นตัวแปรหนึ่งในการพยากรณ์ โดยในงานวิจัยนี้

ผู้วิจัยได้ใช้ AIC และ Grid search ในการกำหนดค่าพารามิเตอร์ของแบบจำลอง ARIMA และ FFNNs ดังนั้นในงานวิจัยครั้งต่อไป ผู้วิจัยควรลองใช้เครื่องมืออื่นเข้ามาช่วยในการกำหนดค่าพารามิเตอร์เพื่อเปรียบเทียบผลการพยากรณ์ ในส่วนของแบบจำลอง

โครงข่ายประสาทเทียมในงานวิจัยนี้ได้ใช้ Adam เพียงตัวเดียว ดังนั้นในงานวิจัยต่อไปควรนำเสนอ Optimizer ตัวอื่นในการช่วยปรับค่าอัตราการเรียนรู้เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง

เอกสารอ้างอิง

- จิราพร ภูทองคำ และถิรนนท์ ทิวาราตรีวิทย์. (2564). การพยากรณ์ความต้องการของวัตถุดิบเพื่อลดการเสียโอกาสทางการขายกรณีศึกษาร้าน Pizza HUK T&J. *วิทยาการจัดการวไลยอลงกรณ์ปริทัศน์*, 2(3), 20-31.
- ดับเบิลยูพี. (2564). 13 เทรนด์พฤติกรรมช้อปปิ้งคนไทย และกลยุทธ์แบรนด์บาลานซ์ช่องทางขาย. ค้นเมื่อ 18 มกราคม 2566, จาก: <https://www.brandbuffet.in.th/2021/06/thailand-future-shopper-2021-online-physical-shop-d2c-trends/>.
- ธรณินทร์ สัจจวิริยทรัพย์. (2563). ตัวแบบพยากรณ์อัตราแลกเปลี่ยนสกุลเงิน. *วารสารวิทยาศาสตร์และเทคโนโลยี*, 28(1), 26-40.
- ศิวนนท์ วรโชติปัญญารัตน์. (2564). การพยากรณ์ความต้องการและจัดการสินค้าคงคลัง: กรณีศึกษาบริษัทชิ้นส่วนยานยนต์แห่งหนึ่งในจังหวัดชลบุรี. *วารสารวิชาการศรีปทุมชลบุรี*, 17(3), 155-166.
- อักรพงศ์ อันทอง. (2550). *คู่มือการใช้โปรแกรม Eviews เบื้องต้น: สำหรับการวิเคราะห์ทางเศรษฐมิติ*. เชียงใหม่: สถาบันวิจัยสังคม มหาวิทยาลัยเชียงใหม่.
- Aljaaf, A. J., Mohsin, T. M., & Alloghani, M. (2021). A fusion of data science and feed-forward neural network-based modelling of COVID-19 outbreak forecasting in IRAQ. *Journal of Biomedical Informatics*, 118, 103766. <https://doi.org/10.1016/j.jbi.2021.103766>.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366a), 427-431. <https://doi.org/10.1080/01621459.1979.10482531>.
- Electronic Transactions Development Agency. (2021). *Value of e-commerce survey in Thailand 2021*. Retrieved 18 January 2023, From: <https://www.eta.or.th/th/Useful-Resource/publications/Value-of-e-Commerce-Survey-in-Thailand-2021-Slides.aspx>.
- Neslin, S. A., Grewal, D., Leghorn, R., Shankar, V., Teerling, M. L., Thomas, J. S., & Verhoef, P. C. (2006). Challenges and opportunities in multichannel customer management. *Journal of service research*, 9(2), 95-112.
- Resnick, D., & Tseng, D. (2016). *Southeast Asia e-commerce: Winning the next wave of shoppers*. Retrieved 24 February 2023, From: <https://www.thinkwithgoogle.com/intl/en-apac/consumer-insights/consumer-trends/how-southeast-asia-ecommerce-businesses-can-take-brands-to-next-level/>.
- Shukla, M., & Jharkharia, S. (2011). ARIMA models to forecast demand in fresh supply chains. *International Journal of Operational Research*, 11(1), 1-18.
- Xi, J., & Sha, P. B. (2014). Research on optimization of inventory management based on demand forecasting. *Applied Mechanics and Materials*, 687, 4828-4831. <https://doi.org/10.4028/www.scientific.net/AMM.687-691.4828>.

Zhao, L., Li, Z., & Qu, L. (2022). Forecasting of Beijing PM2. 5 with a hybrid ARIMA model based on integrated AIC and improved GS fixed-order methods and seasonal decomposition. *Heliyon*, 8(12), Article e12239. <https://doi.org/10.1016/j.heliyon.2022.e12239>