

## การพยากรณ์อนุกรมเวลาและการประยุกต์ในทางเภสัชกรรม

กรกนก เนตรทิพย์<sup>1</sup>, ลาวัลย์ ศรีธธาพุทธร<sup>2,3\*</sup>

<sup>1</sup>เภสัชกร, กองควบคุมวัตถุเสพติด สำนักงานคณะกรรมการอาหารและยา กระทรวงสาธารณสุข จังหวัดนนทบุรี  
<sup>2</sup>รศ.ดร., สาขาวิชาชีวการแพทย์และสารสนเทศศาสตร์ทางสุขภาพ คณะเภสัชศาสตร์ มหาวิทยาลัยศิลปากร จังหวัดนครปฐม  
<sup>3</sup>กลุ่มวิจัยปัญหาประดิษฐ์และเมตาโบลอมิกส์

\* ติดต่อผู้พิมพ์: ลาวัลย์ ศรีธธาพุทธร สาขาวิชาชีวการแพทย์และสารสนเทศศาสตร์ทางสุขภาพ คณะเภสัชศาสตร์ มหาวิทยาลัยศิลปากร จังหวัดนครปฐม  
73000 โทรศัพท์ 0 3425 5800, E-mail: Srattthaphut\_L@su.ac.th

### บทคัดย่อ

#### การพยากรณ์อนุกรมเวลาและการประยุกต์ในทางเภสัชกรรม

กรกนก เนตรทิพย์<sup>1</sup>, ลาวัลย์ ศรีธธาพุทธร<sup>2,3\*</sup>

ว. เภสัชศาสตร์อีสาน 2566; 19(3) : 1-11

รับบทความ: 13 พฤศจิกายน 2565

แก้ไขบทความ: 18 เมษายน 2566

ตอบรับ: 18 สิงหาคม 2566

การพยากรณ์เป็นการคาดการณ์เหตุการณ์ที่จะเกิดขึ้นในอนาคต ซึ่งมีความสำคัญและถูกนำมาใช้ในการวางแผนอย่างมีประสิทธิภาพ การพยากรณ์เชิงปริมาณจากการวิเคราะห์ข้อมูลในอดีตที่นิยมใช้มากคือการพยากรณ์ด้วยข้อมูลอนุกรมเวลา อนุกรมเวลา คือชุดข้อมูลที่ได้อาจจากการสังเกตหรือเก็บเรียงตามลำดับเวลา การพยากรณ์อนุกรมเวลาเป็นกระบวนการพยากรณ์ค่าของข้อมูลอนุกรมเวลาที่จะเกิดขึ้นในอนาคตจากการสังเกตที่ผ่านมา ข้อมูลอนุกรมเวลาประกอบด้วยส่วนต่างๆ ได้แก่ แนวโน้ม (Trend), ฤดูกาล (Seasonal), วัฏจักร (Cyclic) และ สิ่งรบกวน (Noise) ขั้นตอนการพัฒนาแบบจำลองในการพยากรณ์อนุกรมเวลามักใช้ขั้นตอนมาตรฐานตามหลักการ Cross Industry Standard Process for Data Mining (CRISP-DM) เทคนิคที่ใช้ในการพยากรณ์อนุกรมเวลาและหารูปแบบความสัมพันธ์ของข้อมูลสามารถแบ่งออกตามวิธีการสร้างแบบจำลองคือ วิธีการทางสถิติ และวิธีการเรียนรู้ของเครื่อง ในทางเภสัชกรรมได้มีการประยุกต์ใน 2 ส่วนที่น่าสนใจโดยมีวัตถุประสงค์และเทคนิคในการสร้างแบบจำลองที่แตกต่างกัน คือ 1) การพยากรณ์ค่าใช้จ่ายด้านยา นำข้อมูลย้อนหลังของค่าใช้จ่ายด้านยาระยะยาวมาสร้างแบบจำลองเพื่อพยากรณ์ค่าใช้จ่ายในระยะถัดไป ผลการศึกษาสามารถนำไปใช้ในการตัดสินใจเชิงนโยบายหรือวางแผนรองรับสถานการณ์ต่างๆ 2) การพยากรณ์ความต้องการใช้ยา นำหลักการพยากรณ์ความต้องการสินค้ามาใช้ เพื่อประโยชน์ต่อระบบโซ่อุปทานที่ซับซ้อนของอุตสาหกรรมยา สามารถนำปริมาณการใช้ยาหรือยอดขายยาของหน่วยงานมาสร้างแบบจำลองด้วยเทคนิคที่พัฒนาเพื่อเน้นความแม่นยำในการพยากรณ์ และนำไปกำหนดแนวปฏิบัติภายในองค์กรได้ทันต่อความเปลี่ยนแปลง การพยากรณ์อนุกรมเวลาในทางเภสัชกรรมเป็นวิธีการหนึ่งในการนำข้อมูลด้านยาที่บันทึกไว้อย่างต่อเนื่องมาวิเคราะห์เพื่อหาคำตอบล่วงหน้าของสิ่งที่สนใจศึกษา อีกทั้งยังสามารถพัฒนาเทคนิคการพยากรณ์ต่างๆ เพื่อปรับใช้กับข้อมูลที่มีได้ ความแม่นยำในการพยากรณ์ขึ้นอยู่กับวิธีการเลือกวิธีการที่เหมาะสมกับบริบทของข้อมูลอนุกรมเวลา ช่วงเวลาที่ศึกษาและวัตถุประสงค์ในการพยากรณ์

**คำสำคัญ:** อนุกรมเวลา, การพยากรณ์อนุกรมเวลา, แบบจำลองการเรียนรู้ของเครื่อง, การพยากรณ์ค่าใช้จ่ายด้านยา, การพยากรณ์ความต้องการใช้ยา

## Time series forecasting and application in pharmaceutical area

Gornganog Nettip<sup>1</sup>, Lawan Srattaphut<sup>2,3\*</sup>

<sup>1</sup> Pharmacist, Narcotics Revolving Fund, Narcotic Control Division, Food and Drug Administration, Nonthaburi

<sup>2</sup> Assoc. Prof. Dr., Department of Biomedicine and Health Informatics, Faculty of Pharmacy, Silpakorn University, Nakhon Pathom

<sup>3</sup> Artificial Intelligence and Metabolomics Research Group (AiM)

**\*Corresponding author:** Lawan Srattaphut, Department of Biomedicine and Health Informatics, Faculty of Pharmacy, Silpakorn University, Nakhon Pathom, 73000 Thailand. Tel. 034-255800, E-mail: Srattaphut\_L@su.ac.th

### Abstract

#### Time series forecasting and application in pharmaceutical area

Gornganog Nettip<sup>1</sup>, Lawan Srattaphut<sup>2,3\*</sup>

IJPS, 2023; 19(3) : 1-11

**Received:** 13 November 2022

**Revised:** 18 April 2023

**Accepted:** 18 August 2023

Forecasting is a prediction of an event that will happen in the future. This is very important for effective planning. The most popular quantitative forecasting based on historical data analysis is time series forecasting. Time series is a series of observations listed in the order of time. Time series forecasting is the process of predicting the future value of time series data based on past observations. Time series data consists of the following components: Trend, Seasonal, Cyclic and Noise. The standard procedures based on Cross Industry Standard Process for Data Mining (CRISP-DM) framework principles are often used to develop models in time series forecasting. The model development technique used to define the relationships between variables and to forecast time series data can be divided into statistical method and machine learning method. In the field of pharmacy, time series forecasting has been applied in two interesting areas, each with different purposes and techniques. The first is drug expenditure forecasting. Studies were conducted by using long-term retrospective data for developing models to predict drug expenditure in the next period. The results of studies are used to provide decision-making information for well prepare in any situation. The second application is to forecast the demand for drug products, that can cause a profitable in complex supply chain of pharmaceutical industry by using the model from drug consumption or drug sales data. Modeling techniques require more precise prediction to promptly determine the process in organization. In pharmaceutical domain, time series forecasting is one of the methods to fetch the consecutive drug information to analyze for finding the answer of some interest in advance. In addition, forecasting techniques be adjusted to better fit available data The efficiency in forecasting depends on choosing a method that is appropriate for the context of the time series data, study period, and forecasting objectives.

**Keywords:** time series, time series forecasting, machine learning model, drug expenditure forecasting, drug demand forecasting

## บทนำ

การพยากรณ์เป็นสิ่งที่สามารถดึงดูดความสนใจของผู้คนมานานนับพันปี การพยากรณ์ที่ตีกลายไปเป็นความน่าอัศจรรย์ ในขณะที่การพยากรณ์ไม่แม่นยำอาจนำไปสู่ความเสียหายในด้านต่างๆ ได้ ในปัจจุบันการพยากรณ์เป็นสิ่งที่ต้องการและถูกนำไปใช้ในหลายสถานการณ์ เช่น การจะสร้างโรงงานผลิตไฟฟ้าแห่งใหม่ในอีก 5 ปีข้างหน้า ต้องมีข้อมูลพยากรณ์ความต้องการใช้ไฟฟ้าประกอบการตัดสินใจ การกำหนดตารางงานของพนักงานคอลเซ็นเตอร์ในสัปดาห์ถัดไป ต้องมีข้อมูลพยากรณ์ปริมาณสายโทรเข้า ปริมาณสินค้าคงคลัง ต้องมีข้อมูลพยากรณ์ความต้องการใช้สินค้า การพยากรณ์จึงสามารถคาดการณ์ล่วงหน้าได้หลายปีสำหรับการใช้เงินลงทุน หรือพยากรณ์ล่วงหน้าเพียงไม่กี่นาทีล่วงหน้าสำหรับเส้นทางโทรคมนาคมไร้สาย ดังนั้น แม้ว่าข้อมูลจะมีสถานการณ์หรือช่วงเวลาใดๆ มาเกี่ยวข้อง การพยากรณ์จะเป็นตัวช่วยสำคัญในการวางแผนอย่างมีประสิทธิภาพและประสิทธิผล ในขณะที่สถานการณ์หรือสิ่งที่ต้องการพยากรณ์มีทั้งที่สามารถทำได้ง่ายและยาก การคาดการณ์สถานการณ์หรือปริมาณของสิ่งต่างๆ จึงขึ้นอยู่กับหลายปัจจัย ได้แก่ ความรู้และความเข้าใจถึงปัจจัยที่ส่งผลต่อสิ่งที่พยากรณ์นั้น ข้อมูลที่มีอยู่มีปริมาณมากน้อยเพียงใด และการพยากรณ์จะส่งผลกระทบต่อสิ่งที่กำลังพยายามจะพยากรณ์หรือไม่ หลักการสำคัญในการพยากรณ์โดยทั่วไปคือ ผู้พยากรณ์รู้ว่าเมื่อใดที่จะสามารถพยากรณ์ได้อย่างถูกต้อง และเมื่อใดที่การคาดการณ์นั้นไม่ได้ให้ผลดีกว่าการโยนเหรียญเสี่ยงทาย การพยากรณ์ที่ดีจะสามารถจับรูปแบบและความสัมพันธ์ที่แท้จริงซึ่งมีอยู่จากข้อมูลในอดีต แต่ไม่ซ้ำกับเหตุการณ์ในอดีตที่จะไม่เกิดขึ้นอีก ในทุกๆ การเปลี่ยนแปลงของสภาพแวดล้อมที่เกิดขึ้น แบบจำลองในการพยากรณ์ที่ดีจึงสามารถสะท้อนให้เห็นทั้งความเคลื่อนไหวและวิธีการที่สิ่งต่างๆ กำลังแปรเปลี่ยนไปตามสภาพแวดล้อมนั้นด้วย การเลือกวิธีการพยากรณ์ที่เหมาะสมขึ้นอยู่กับชนิดของข้อมูลที่มีอยู่เป็นสำคัญ หากไม่มีข้อมูลเพียงพอ หรือข้อมูลที่มีอยู่ไม่เกี่ยวข้องกับสิ่งที่พยากรณ์ ควรใช้การพยากรณ์เชิงคุณภาพ (qualitative forecasting) ซึ่งเป็นการคาดการณ์จากผู้ที่มีความเชี่ยวชาญหรือทักษะในเรื่องนั้นๆ โดยไม่อิงกับข้อมูลที่มีในอดีต สำหรับการพยากรณ์เชิงปริมาณ (quantitative forecasting) เป็นการพยากรณ์โดยใช้ตัวเลขและหลักการทางสถิติ สามารถใช้ได้เมื่อข้อมูลในอดีตมีปริมาณมากพอ และมีเหตุผลเพียงพอที่จะทำให้เชื่อได้ว่ารูปแบบความสัมพันธ์ที่เคยเกิดขึ้นในอดีตบางลักษณะจะดำเนินต่อไปในอนาคต วิธีการพยากรณ์เชิงปริมาณสามารถ

ทำได้หลายวิธี ส่วนใหญ่มีการพัฒนาขึ้นเฉพาะกับวัตถุประสงค์ จึงมีคุณสมบัติ ความแม่นยำและต้นทุนแตกต่างกันซึ่งต้องพิจารณาในการเลือกใช้ การพยากรณ์เชิงปริมาณที่นิยมใช้มากคือการพยากรณ์ด้วยข้อมูลอนุกรมเวลา (time series data) (Hyndman & Athanasopoulos, 2018)

### 1. ข้อมูลอนุกรมเวลา (Time series data)

อนุกรมเวลาคือชุดข้อมูลที่ได้จากการสังเกตหรือเก็บเรียงตามลำดับเวลา ข้อมูลหนึ่งๆ ในอนุกรมเวลาจะถูกบันทึกอย่างต่อเนื่องในทุกช่วงเวลา (Illukkumbura, 2021; Kotu & Deshpande, 2019) การวิเคราะห์อนุกรมเวลา (Time series analysis) คือกระบวนการสกัดเพื่อดึงเอาข้อมูลที่สำคัญและรูปแบบ (patterns) จากอนุกรมเวลา สำหรับการพยากรณ์อนุกรมเวลา (Time series forecasting) เป็นกระบวนการพยากรณ์ค่าของข้อมูลอนุกรมเวลาที่จะเกิดขึ้นในอนาคตจากการสังเกตและเก็บข้อมูล การพยากรณ์อนุกรมเวลาเป็นหนึ่งในวิธีการวิเคราะห์เชิงคาดการณ์ซึ่งเป็นที่รู้จักกันมานาน มีการนำมาใช้กันอย่างแพร่หลายในองค์กรและมีพื้นฐานมาจากสถิติเชิงลึก ในการพยากรณ์อนุกรมเวลา องค์ประกอบที่สำคัญในการพยากรณ์คือ เวลา ดังนั้นการพยากรณ์ตัวแปรหนึ่งๆ ที่สนใจ จึงเป็นการติดตามความเปลี่ยนแปลงค่าของตัวแปรนั้นในแต่ละช่วงเวลา โดยนำตัวแปรที่มีผลมาใช้ในการพยากรณ์ แตกต่างจากหลักการพยากรณ์ด้วยวิธีการสร้างแบบจำลองอื่นๆ ซึ่งไม่นำเวลา มาเป็นองค์ประกอบในการพิจารณา อีกทั้งอาจไม่มีข้อมูลการสังเกตของเวลาต่อตัวแปรที่สนใจ (Kotu & Deshpande, 2019) ข้อมูลอนุกรมเวลาประกอบด้วยส่วนต่างๆ ดังนี้ (Hyndman & Athanasopoulos, 2018)

- แนวโน้ม (trend) คือแนวโน้มในระยะยาวของข้อมูลที่มีการเพิ่มขึ้นหรือลดลง ซึ่งไม่จำเป็นต้องอยู่ในรูปเส้นตรง อาจเรียกได้อีกอย่างหนึ่งว่า ทิศทางในการเปลี่ยนแปลง เช่น ยอดขายของยานยนต์หนึ่งๆ เมื่ออยู่ในจุดที่มีแนวโน้มเพิ่มขึ้นแต่ละปี สามารถเปลี่ยนแปลงเพิ่มขึ้นหรืออาจลดลงได้เมื่อมีयाอื่นใช้แทน

- ฤดูกาล (seasonal) คือรูปแบบของอนุกรมเวลาที่ปรากฏเมื่อข้อมูลนั้นเป็นผลมาจากปัจจัยที่เกี่ยวกับฤดูกาล เช่น ช่วงเวลาในแต่ละปี หรือวันในแต่ละสัปดาห์ seasonal ส่วนใหญ่จะมีความคงที่และสามารถรู้ความถี่ในการเกิดที่แน่นอน โดยความถี่ของรูปแบบ seasonal ที่เกิดขึ้นอาจแยกออกได้เป็นทุกชั่วโมง ทุกวัน ทุกสัปดาห์ ทุกเดือน ทุกไตรมาส และทุกรอบปี

ตามลักษณะและชนิดของข้อมูลอนุกรมเวลาที่สนใจ เช่น ข้อมูลปริมาณการใช้อินเทอร์เน็ต ข้อมูลการซื้อขายหุ้น ข้อมูลผู้ป่วยที่เข้ารับบริการในแต่ละเดือน ข้อมูลหนี้สินครัวเรือน เป็นต้น

- วัฏจักร (cyclic) เป็นส่วนประกอบของอนุกรมเวลาที่จะเกิดการเพิ่มขึ้นและลดลงของข้อมูลโดยมีความถี่ไม่คงที่ และไม่สามารถคาดการณ์ระยะห่างระหว่างเวลาที่เกิดในแต่ละครั้งได้ โดยแต่ละรอบมักจะห่างกันเกิน 1 ปี เช่น ค่าของข้อมูลที่มีความผันผวนจากสถานะเศรษฐกิจเฟื่องฟูและถดถอย

- สุ่มรบกวน (noise) คือข้อมูลที่เกิดขึ้นซึ่งไม่อยู่ในรูปของ trend, seasonal หรือ cyclic เป็นส่วนที่ไม่สามารถคาดการณ์รูปแบบการเกิดได้ ข้อมูลอนุกรมเวลาทุกชุดจะมี noise เป็นส่วนประกอบเสมอ (Kotu & Deshpande, 2019) บางแหล่งอ้างอิงเรียกส่วนประกอบนี้ว่า remainder component ซึ่งหมายความว่ารวมถึงข้อมูลอื่นๆ ที่ไม่ใช่ trend seasonal หรือ cyclic เช่นกัน (Dix, 2020; Hyndman & Athanasopoulos, 2018)

คุณลักษณะขององค์ประกอบข้อมูลอนุกรมเวลาเมื่อพล็อตกราฟของค่าสังเกตที่แต่ละจุดเวลา จะสามารถแยกได้เป็นแนวโน้ม ฤดูกาล สุ่มรบกวน และวัฏจักร (Kotu & Deshpande, 2019) ดังนั้นเมื่อพิจารณาในรูปแบบทางคณิตศาสตร์ อาจกล่าวได้ว่าอนุกรมเวลาคือชุดข้อมูลของค่าคงที่ในช่วงเวลาหนึ่งๆ (yt) ซึ่งเป็นผลรวมจากส่วนประกอบต่างๆ ที่มีผลมาจากลำดับเวลาในช่วงที่เก็บข้อมูลนั้น (Bontempi *et al.*, 2013) ในการพยากรณ์โดยทั่วไปจะรวมส่วน cyclic อยู่ใน trend เนื่องจากชุดข้อมูลนั้นอาจไม่แสดง cyclic ชัดเจนในช่วงที่เก็บข้อมูล (Ord *et al.*, 2017) สามารถเขียนชุดข้อมูลให้แต่ละส่วนประกอบอยู่ในรูปสมการความสัมพันธ์เชิงบวกหรือความสัมพันธ์แบบทวีคูณได้ดังนี้ (Kotu & Deshpande, 2019; Zdravkovic, 2019)

Time series = Trend + Seasonality + Noise [yt = Tt + St + Et]

Time series = Trend x Seasonality x Noise [yt = Tt x St x Et]

ในปัจจุบันการพยากรณ์อนุกรมเวลามีบทบาทสำคัญในสาขาต่างๆ เช่น เศรษฐกิจ การเงิน อุตุนิยมวิทยา การสื่อสาร โทรคมนาคม รวมทั้งภาคธุรกิจโดยเฉพาะธุรกิจอัจฉริยะ (business intelligence) (Bontempi *et al.*, 2013) ซึ่งสามารถช่วยเป็นข้อมูลในการตัดสินใจสำหรับสิ่งที่จะเกิดขึ้นในอนาคต เช่น การจัดตารางการผลิตสินค้าให้สอดคล้องกับผลการพยากรณ์ยอดขายสินค้า การเตรียมการขนส่งในแต่ละช่วงเวลาจากข้อมูลการพยากรณ์ความต้องการสินค้า และการเตรียม

บุคลากรรองรับการบริการในช่วงที่มีพยากรณ์ว่าจะมีผู้ใช้บริการมาก เป็นต้น (Hyndman & Athanasopoulos, 2018; Kotu & Deshpande, 2019)

## 2. ขั้นตอนการพยากรณ์อนุกรมเวลา

การพยากรณ์อนุกรมเวลาสามารถทำได้โดยการสร้างแบบจำลองการพยากรณ์จากข้อมูลในอดีตจึงมีขั้นตอนการสร้างแบบจำลองเพื่อใช้ในการพยากรณ์ตามหลักวิทยาการข้อมูล (Data Science) (Kotu & Deshpande, 2019; Kullimratchai, 2018) ซึ่งอ้างอิงจาก Cross Industry Standard Process for Data Mining (CRISP-DM) (Chapman *et al.*, 2000) ประกอบด้วยขั้นตอนดังนี้

1) Business understanding การทำความเข้าใจเกี่ยวกับพันธกิจและวัตถุประสงค์ขององค์กรให้ทราบถึงปัญหาหรือสิ่งที่ต้องดำเนินการเพื่อให้พันธกิจลุล่วง ได้ผลลัพธ์ตามวัตถุประสงค์ที่ต้องการจากการพยากรณ์

2) Data understanding การทำความเข้าใจเกี่ยวกับข้อมูล คือการเริ่มต้นรวบรวมข้อมูลที่มีการบันทึกไว้ สามารถอธิบายและตรวจสอบข้อมูลเพื่อนำมาใช้ในการวิเคราะห์ได้อย่างถูกต้องตามขอบเขตของการพยากรณ์

3) Data preparation การจัดเตรียมข้อมูลสำหรับการวิเคราะห์ ถือเป็นขั้นตอนที่ใช้ระยะเวลานานที่สุด โดยการนำข้อมูลไปผ่านกระบวนการก่อนประมวลผล ได้แก่ การสำรวจข้อมูล (data exploration) การประเมินคุณภาพของข้อมูล (data quality assessment) เพื่อให้แน่ใจว่าข้อมูลถูกเก็บมาอย่างถูกต้องในช่วงเวลาที่สนใจศึกษา การจัดการข้อมูลสูญหาย (missing data management) การแปลงชนิดของข้อมูล (data type conversion) เพื่อให้ตัวแปรต่างๆ อยู่ในรูปที่เหมาะสมกับอัลกอริทึมที่จะเลือกใช้ในการวิเคราะห์ การแปลงค่าข้อมูล (transformation) การสำรวจค่าผิดปกติจากชุดข้อมูล (outliers) การเลือกคุณลักษณะเด่นของตัวแปรหรือค่าที่สนใจจะใช้ในการพยากรณ์ (feature selection) และการสุ่มตัวอย่างข้อมูล (data sampling) เพื่อแบ่งกลุ่มของข้อมูลที่จะใช้เป็นชุดข้อมูลฝึกฝน (training data set) และชุดข้อมูลทดสอบ (test data set)

4) Modeling การสร้างแบบจำลองประกอบด้วยขั้นตอนย่อยคือ การคัดเลือกเทคนิคที่ใช้ในการสร้างแบบจำลอง การออกแบบและสร้างแบบจำลองด้วยข้อมูลที่ใช้เป็นชุดข้อมูลฝึกฝน และการประเมินแบบจำลองเบื้องต้นว่ามีตัวแปรและความสัมพันธ์ของข้อมูลครบตามที่วิเคราะห์

5) Evaluation การประเมินแบบจำลอง โดยประเมินผลการพยากรณ์ที่ได้จากแบบจำลองที่สร้างขึ้น จากการหาค่า

เบี่ยงเบนที่เกิดขึ้นเมื่อทดสอบแบบจำลองด้วยข้อมูลชุดทดสอบ และเปรียบเทียบความแม่นยำของผลการพยากรณ์เมื่อใช้เทคนิคในการสร้างแบบจำลองที่ต่างกัน การวัดประสิทธิภาพในการพยากรณ์ของแบบจำลองที่สร้างขึ้น สามารถใช้วิธีการทางสถิติในการหาค่า error ซึ่งเป็นผลต่างระหว่างค่าข้อมูลที่ได้จากการพยากรณ์กับค่าข้อมูลจริง ซึ่งมี 4 แบบได้แก่ Mean absolute deviation, Bias value หรือค่าเฉลี่ยของ error, Mean square error (MSE) และ Mean absolute percentage error (MAPE) (Illukkumbura, 2021)

6) Deployment การนำแบบจำลองไปปรับใช้ในการพยากรณ์ มีการวางแผนการนำแบบจำลองไปปรับใช้ วางแผนการติดตามและปรับปรุงแบบจำลอง

จากการสืบค้นงานวิจัยพบตัวอย่างการศึกษาของ Zadeh NK และคณะ (Zadeh et al., 2014) ดำเนินการพยากรณ์อนุกรมเวลาโดยสร้างแบบจำลองตามขั้นตอน CRISP-DM ซึ่งผู้วิจัยให้ความสำคัญในขั้นตอนการวิเคราะห์ข้อมูลก่อนสร้างแบบจำลอง โดยการนำข้อมูลมาประมวลผลและแสดงให้อยู่ในรูปแบบภาพ จึงมีการทำ Data visualization และการวิเคราะห์ข้อมูลจากแผนภูมิกราฟ (Graph based analysis) ในขั้นตอนการจัดเตรียมข้อมูลด้วย เป็นวิธีการหนึ่งที่จะช่วยให้สามารถเข้าใจภาพรวมและแนวโน้มของชุดข้อมูลที่เก็บมาได้ดีขึ้น

### 3. เทคนิคที่ใช้ในการพยากรณ์อนุกรมเวลา

การพยากรณ์อนุกรมเวลาสามารถแบ่งออกได้เป็น 4 วิธีตามเทคนิคที่ใช้ในการสร้างแบบจำลอง ได้แก่ การพยากรณ์ด้วยวิธีแยกส่วนประกอบของข้อมูลอนุกรมเวลา (time series decomposition) การพยากรณ์ด้วยวิธีการปรับเรียบ (smoothing based techniques) การพยากรณ์ด้วยวิธีการถดถอย (regression based techniques) และการพยากรณ์ด้วยวิธีการเรียนรู้ของเครื่อง (machine learning-based techniques) ซึ่งทั้ง 3 วิธีแรกอาจเรียกรวมกันได้ว่าเป็นวิธีการสร้างแบบจำลองทางสถิติ (statistical methods) (Kotu & Deshpande, 2019)

1) วิธีแยกส่วนประกอบของข้อมูลอนุกรมเวลา เป็นกระบวนการแยกส่วนประกอบของอนุกรมเวลาให้อยู่ในรูปองค์ประกอบพื้นฐานที่เป็นตัวแทนของแต่ละเหตุการณ์ในช่วงเวลานั้น คือการแยกเป็น trend, seasonal และ noise โดยเมื่อแยกออกมาจะพบว่า trend และ seasonal เป็นส่วนของข้อมูลที่สามารถคาดการณ์ได้ หรือเรียกอีกอย่างหนึ่งคือ systematic component ในขณะที่ noise เป็นส่วนที่เกิดขึ้นแบบสุ่ม หรือ non-systematic component วิธีการนี้เป็นวิธีการสำคัญจะทำให้ผู้พยากรณ์เข้าใจความสัมพันธ์ สามารถอธิบายรูปแบบ

ของข้อมูลแต่ละส่วนที่ประกอบกันเป็นอนุกรมเวลาได้ ก่อนที่จะวางแผนเลือกใช้เทคนิคที่เหมาะสมต่อไป เทคนิคที่ใช้ เช่น Classical Decomposition เป็นการแยกส่วนข้อมูลและสร้างแผนภาพของข้อมูลเพื่อนำมาใช้ในการพยากรณ์อย่างง่าย

2) วิธีการปรับเรียบ เป็นวิธีการนำค่าที่ได้จากการสังเกตข้อมูลในอดีต และนำส่วนประกอบสำคัญคือ trend และ seasonal มาใช้ในการสร้างแบบจำลองเพื่อพยากรณ์ค่าข้อมูลในอนาคต จากการประมาณการด้วยค่าเฉลี่ยของข้อมูลในอดีตซึ่งให้น้ำหนักของแต่ละตัวแปรไม่เท่ากัน เทคนิคที่ใช้ คือ simple forecasting methods ซึ่งมีทั้งวิธีการอย่างง่ายและยากขึ้น เช่น Naïve method, Seasonal naïve method, Average method, Moving average smoothing และ Weighted moving average smoothing เป็นต้น อีกเทคนิคที่นิยมคือ วิธีการปรับเรียบด้วยเส้นโค้งเลขชี้กำลัง (Exponential smoothing) เป็นวิธีการที่ให้น้ำหนักกับค่าในอดีตค่าสุดท้ายในการนำมาหาค่าเฉลี่ย เหมาะกับข้อมูลที่มีพารามิเตอร์ไม่มาก เช่น Holt's Two-Parameter Exponential Smoothing และ Holt-Winters' Three-Parameter Exponential Smoothing เป็นต้น

3) วิธีการถดถอย เป็นวิธีการที่คล้ายกับการสร้างแบบจำลองการเรียนรู้ของเครื่องแบบมีผู้สอน (supervised machine learning) ที่พยากรณ์ข้อมูลใหม่ด้วยผลลัพธ์จากชุดข้อมูลฝึกฝน ซึ่งจะมีทั้งตัวแปรอิสระและตัวแปรตาม แต่ในที่นี้เวลาเป็นตัวแปรอิสระ และตัวแปรตามมีความสัมพันธ์เชิงเส้น หลักการของวิธีนี้เป็นการอ้างอิงแนวคิดของสหสัมพันธ์อัตโนมัติ กล่าวคือ ข้อมูลที่ได้จากช่วงเวลาที่อยู่ติดกันมีความสัมพันธ์กัน ในอนุกรมเวลา เทคนิคซึ่งเป็นที่รู้จักมากที่สุดคือ Autoregressive integrated moving average (ARIMA) นอกจากนี้ยังสามารถสร้างแบบจำลองแบบมีผู้สอนด้วยวิธี classification เพื่อใช้ในการพยากรณ์อนุกรมเวลา ได้ด้วยเช่นกัน หากข้อมูลถูกแปลงค่าให้อยู่ในรูปแบบเฉพาะที่มีการติดป้าย (label) และใช้วิธีการเรียนรู้ของเครื่องแบบมีผู้สอนโดยมีตัวแปรนำเข้าจากอนุกรมเวลาที่แบ่งชุดข้อมูลออกเป็นชุดย่อยตามจุดเวลา ซึ่งตัวแปรนำเข้าอยู่ในจุดเวลาที่ต่อจากค่าสังเกตในอดีต เทคนิคอื่นๆ ที่ใช้ได้แก่ การถดถอย, การถดถอยแบบเป็นฤดูกาล (Regression with seasonality) และ ARIMA แบบฤดูกาล (Seasonal ARIMA) ซึ่งมีการใช้รูปแบบฤดูกาลของชุดข้อมูลนั้นมาสร้างแบบจำลองร่วมด้วย (Kotu & Deshpande, 2019)

4) วิธีการเรียนรู้ของเครื่อง ในช่วงสองทศวรรษที่ผ่านมา แบบจำลองที่สร้างโดยการเรียนรู้ของเครื่องได้รับความสนใจเป็นอย่างมากและได้รับการพิสูจน์ว่าเป็นคู่แข่งสำคัญของแบบจำลองทางสถิติในการพยากรณ์ เรียกได้ว่าเป็นแบบจำลองที่ขับเคลื่อนด้วยข้อมูล (Bontempi *et al.*, 2013) ใช้สำหรับการวิเคราะห์ชุดข้อมูลที่มีความซับซ้อนและสร้างแบบจำลองด้วยวิธีการเรียนรู้ของเครื่อง ซึ่งสามารถเรียนรู้คุณลักษณะของตัวแปร (feature) และความสัมพันธ์ระหว่าง feature ได้ วิธีการนี้สามารถรองรับข้อมูลที่มีขนาดใหญ่ขึ้น และข้อมูลที่ไม่ได้มีความสัมพันธ์เชิงเส้น เทคนิคที่ใช้ เช่น CART regression trees (CART), Support Vector Regression (SVR), Gaussian Processes (GP) Multi-Layer Perceptron (MLP), Bayesian Neural Network (BNN), Radial Basis Functions (RBF), Generalized Regression Neural Networks (GRNN), K-Nearest Neighbor regression (KNN) (Ahmed *et al.*, 2010; Makridakis *et al.*, 2018) หลังจากนั้นได้มีการพัฒนาการสร้างแบบจำลองด้วยการเรียนรู้ของเครื่องไปสู่การเรียนรู้เชิงลึก (deep learning) (Choosri *et al.*, 2019) ซึ่งมีรากฐานมาจากการทำงานของปัญญาประดิษฐ์เช่นเดียวกับการเรียนรู้ของเครื่อง แต่มีหลักการทำงานเลียนแบบการทำงานของสมองในการสร้างความฉลาดทางความคิดและพฤติกรรมต่างๆ โดยพยายามค้นหาหลักการคิดที่ซับซ้อนของสมองและออกแบบการทำงานของแบบจำลองจากระบบประสาท ทำให้การเรียนรู้เชิงลึกที่เป็นที่รู้จักในช่วงแรกคือ โครงข่ายประสาทเทียม (Artificial Neural Networks; ANN) มีการนำ feature มากำหนดให้เครื่องเรียนรู้เป็นแต่ละชั้น (layer) (Bengio *et al.*, 2015) เพื่อเพิ่มความแม่นยำในการพยากรณ์ข้อมูลที่มีขนาดใหญ่ มีความซับซ้อนและเป็นข้อมูลที่ไม่ง่าย ตัวอย่างของการเรียนรู้เชิงลึกชนิดอื่นๆ เช่น Long Short Term Memory network (LSTM), Multilayered feedforward artificial neural network (MLFANN) และ Generative adversarial networks (GAN) (Ingle *et al.*, 2021)

#### 4. การประยุกต์การพยากรณ์อนุกรมเวลาในทางเภสัชกรรม

ข้อมูลด้านสุขภาพเป็นข้อมูลที่มีความซับซ้อนซึ่งในปัจจุบันมีการเก็บข้อมูลสุขภาพในรูปอิเล็กทรอนิกส์เป็นจำนวนมากที่สามารถนำไปใช้ประโยชน์เชิงลึกในการศึกษาด้านต่างๆ แม้ว่าข้อมูลที่มีอยู่จะมีความท้าทายจากข้อก้ำกัวในด้านความเป็นส่วนตัวของผู้ป่วย โรงพยาบาล บริษัทประกันสุขภาพ รวมถึงบริษัทยา แนวทางหนึ่งในการจัดการปัญหาดังกล่าวทำได้โดยการเก็บข้อมูลสุขภาพและข้อมูลการใช้ยาที่ไม่ระบุตัวตนของ

ผู้ป่วยซึ่งจะทำให้ไม่สามารถเชื่อมโยงไปสู่ข้อมูลเฉพาะบุคคลได้ การวิเคราะห์ข้อมูลอนุกรมเวลาที่มีการประยุกต์ใช้ในงานวิจัยทางเภสัชกรรมเป็นการศึกษาแบบย้อนหลัง (retrospective study) เพื่อเปรียบเทียบผลที่สนใจศึกษาเมื่อมีการแทรกแซง (intervention) อนุกรมเวลา โดยเก็บข้อมูลทั้งก่อนและหลังจากการแทรกแซงอย่างต่อเนื่องและมีระยะห่างของข้อมูลเท่ากัน เรียกว่า Interrupted time series เป็นการวิจัยกึ่งทดลองที่ใช้ประเมินประสิทธิผลของการแทรกแซง ในสถานการณ์ที่ไม่สามารถศึกษาเชิงทดลองแบบสมบูรณ์ได้ (Kaladee *et al.*, 2013) ตัวอย่างงานวิจัย เช่น การศึกษาของ Sun และคณะ (Sun *et al.*, 2017) ศึกษาระยะเวลาการออกยของผู้ป่วยนอกและความพึงพอใจของผู้ป่วยระหว่างปี 2014 - 2017 ในโรงพยาบาลทั่วไประดับตติยภูมิ ประเทศจีน ด้วยการวิเคราะห์ Interrupted time series วิธีการถดถอยเชิงเส้น พบว่าเมื่อมีการแทรกแซงด้วยการแก้ไขเพื่อลดระยะเวลาการออกยวิธีต่างๆ ระยะเวลาการออกยเฉลี่ยรายเดือนในการเข้าพบแพทย์และการรับยาตามใบสั่งยาลดลง 3.49 นาที ( $P = 0.003$ ) และ 8.70 นาที ( $P = 0.02$ ) ตามลำดับ นอกจากนี้ trend ของระยะเวลาการออกยสำหรับการรับยาตามใบสั่งยายังลดลงอย่างมีนัยสำคัญ ( $P = 0.003$ ) และการศึกษาของ Srumsiri และคณะ (Srumsiri *et al.*, 2016) วิเคราะห์การเข้าถึงยา ผลการรักษา และต้นทุนค่ารักษาพยาบาล เพื่อเปรียบเทียบความแตกต่างหลังจากการประกาศใช้บัญชีย่อย จ(2) ในบัญชียาหลักแห่งชาติ โดยเก็บข้อมูลจากโรงพยาบาลระดับตติยภูมิใน 3 ภาคของประเทศไทยในปี 2006 – 2012 พบว่า หลังจากการประกาศใช้บัญชีย่อย จ(2) 1 ปี มีร้อยละของจำนวนผู้ป่วยได้รับยาในบัญชีย่อยดังกล่าวเพิ่มขึ้น และต้นทุนค่ารักษาพยาบาลรายไตรมาสลดลงอย่างมีนัยสำคัญ จะเห็นได้ว่าการเก็บข้อมูลสุขภาพในลักษณะอนุกรมเวลาสามารถนำมาประยุกต์สำหรับออกแบบงานวิจัยเพื่อตอบคำถามในมุมมองการเปรียบเทียบประสิทธิผลของสิ่งที่สนใจศึกษาในช่วงเวลาต่างๆ ได้

สำหรับการพยากรณ์อนุกรมเวลา ได้เริ่มมีการนำข้อมูลอนุกรมเวลาที่เป็นข้อมูลด้านสุขภาพมาใช้ในการพยากรณ์ด้านเภสัชกรรมคลินิกแต่ไม่เป็นที่นิยมมากนัก อาจเกิดจากข้อจำกัดในการพยากรณ์จากแบบจำลองที่สร้างขึ้นด้วยข้อมูลทางคลินิก ดังตัวอย่างจากการศึกษาของ Willmann และคณะ (Willmann *et al.*, 2013) มีการสร้างแบบจำลอง ARIMA จากข้อมูลการสั่งจ่ายยาต้านจุลชีพของโรงพยาบาลมหาวิทยาลัย Tubingen สหพันธ์สาธารณรัฐเยอรมนีในปี 2002 - 2011 เพื่อพยากรณ์การเกิดเชื้อดื้อยาหลังจากมีการกำกับดูแลการใช้ยาต้านจุลชีพด้วยระบบ

Antimicrobial Stewardship Program (ASP) ผู้วิจัยสรุปว่าแบบจำลองจากข้อมูลอนุกรมเวลา อาจใช้เป็นเครื่องมือหนึ่งในการพยากรณ์ผลของระบบ ASP เพื่อกำหนดนโยบายกำกับดูแลได้ แต่ไม่สามารถสะท้อนสถานะที่เกิดขึ้นจริงได้ทั้งหมดเนื่องจากไม่สามารถเก็บทุกข้อมูลซึ่งเป็นตัวแทนของปัจจัยที่ส่งผลต่อการเกิดเชื้อดื้อยา ทำให้การสร้างแบบจำลองในการพยากรณ์มีความแม่นยำลดลง ปัจจุบันมีการประยุกต์ใช้สำหรับการพยากรณ์ต้นทุนการรักษาพยาบาลอย่างแพร่หลาย ซึ่งมีการใช้เทคนิคในการสร้างแบบจำลองที่แตกต่างกันทั้งการใช้แบบจำลองทางสถิติและแบบจำลองจากการเรียนรู้ของเครื่อง ความท้าทายประการต่อมาคือการเลือกใช้แบบจำลองในการพยากรณ์ที่เหมาะสมในการวิเคราะห์อนุกรมเวลา มีอัลกอริทึมจำนวนน้อยมากที่ได้รับการแนะนำให้ใช้ในการสร้างแบบจำลองการพยากรณ์ที่เกี่ยวข้องกับข้อมูลสุขภาพเนื่องจากต้องใช้ความรู้ใหม่ๆ และความซับซ้อนในตัวข้อมูล จึงมีการพัฒนาการสร้างแบบจำลองด้วยการเรียนรู้ของเครื่องมากขึ้นเพื่อลดข้อจำกัดของการใช้แบบจำลองทางสถิติที่ต้องอาศัยความชำนาญของผู้วิเคราะห์ในการเตรียม feature ต่างๆ (Kaushik et al., 2020)

#### 4.1 การพยากรณ์ค่าใช้จ่ายด้านยา

จากการสืบค้นงานวิจัยพบว่า การพยากรณ์อนุกรมเวลาถูกนำมาใช้พยากรณ์ค่าใช้จ่ายด้านยา เนื่องจากในปัจจุบันค่าใช้จ่ายด้านยาในหลายๆ ประเทศเพิ่มสูงขึ้น ซึ่งเป็นผลมาจากหลายปัจจัย เช่น ประชากรสูงอายุ ความคาดหวังของผู้ป่วยสูงขึ้น ในขณะที่มีการคิดค้นยาใหม่ๆ ที่มีราคาแพงขึ้นเพื่อใช้ในการรักษาพยาบาล ในขณะที่การพยากรณ์จะเป็นเครื่องมือสำคัญในการวางแผนรองรับการเพิ่มขึ้นของค่าใช้จ่ายด้านยา (Kaushik et al., 2017; Linnér et al., 2020) จากงานวิจัยของ Linnér และคณะ (Linnér et al., 2020) ได้ศึกษาการพยากรณ์การใช้ยาและค่าใช้จ่ายด้านยาของกรุงสต็อกโฮล์มทั้งค่ายาผู้ป่วยในและผู้ป่วยนอก รวมทั้งอธิบายผลการพยากรณ์จากแบบจำลองที่ใช้ศึกษาในช่วงระยะเวลา 10 ปี ตั้งแต่ปี 2007 – 2018 โดยการวิเคราะห์อนุกรมเวลาด้วยวิธีการถดถอยเชิงเส้นซึ่งข้อมูลยาจะถูกแยกวิเคราะห์ตามกลุ่มยาที่แบ่งตามรหัส Anatomical Therapeutic Chemical (ATC) ข้อมูลยาทุกกลุ่มจะถูกนำมาพยากรณ์ค่าใช้จ่ายในแต่ละปี โดยพยากรณ์ก่อนหน้านั้น 1 ปีและพยากรณ์ในต้นปีนั้น แล้วนำผลการพยากรณ์ทั้ง 2 ช่วง มาเปรียบเทียบกับค่าใช้จ่ายที่เกิดขึ้นจริง ความแม่นยำของการพยากรณ์แสดงด้วยค่าสัมประสิทธิ์ถดถอย (coefficient) และค่าสัมประสิทธิ์การตัดสินใจ (R<sup>2</sup>) ผลการวิจัยพบว่า ค่าใช้จ่าย

ด้านยาที่ทำการพยากรณ์ในช่วงต้นปีมีความใกล้เคียงกับข้อมูลจริงมากกว่า โดยมีค่า coefficient เท่ากับ 0.827 และค่า R<sup>2</sup> เท่ากับ 0.339 ( $p < 0.05$ ) ความถูกต้องในการพยากรณ์ค่าใช้จ่ายด้านยาในแต่ละปี วัดด้วยค่า MAPE เท่ากับ 1.9% ความแม่นยำในการพยากรณ์มีความแตกต่างกันในแต่ละกลุ่มยา ผู้วิจัยได้อภิปรายถึงปัจจัยที่มีผลต่อความแม่นยำในการพยากรณ์โดยใช้แบบจำลองนี้ได้แก่ ช่วงเวลาที่มียาใหม่หรือยาสามัญใหม่ออกสู่ตลาด อัตราการใช้ยาใหม่ รวมทั้งการเปลี่ยนแปลงนโยบายการเบิกจ่ายค่ายาในระหว่างปีด้วย ผู้วิจัยจึงสรุปว่าการใช้แบบจำลองในการพยากรณ์ดังกล่าวมีความแม่นยำและมีความเหมาะสมกับบริบทของข้อมูล อีกทั้งยังสามารถระบุปัจจัยต่างๆ ที่มีผลต่อความแม่นยำของแบบจำลองได้ หากผลการพยากรณ์ที่ได้จะถูกนำไปใช้ในการตัดสินใจเชิงนโยบาย ควรมีการปรับปรุงและอัปเดตแบบจำลองให้เป็นปัจจุบันก่อนที่จะใช้พยากรณ์ในการตัดสินใจ

ตัวอย่างงานวิจัยอื่นๆ ที่ใช้การสร้างแบบจำลองเพื่อพยากรณ์ค่าใช้จ่ายด้านยาด้วยเทคนิคการเรียนรู้ของเครื่อง เช่น การศึกษาของ Kaushik และคณะ (Kaushik et al., 2017) พยากรณ์ค่าใช้จ่ายด้านยาต่อเดือนของผู้ป่วยในการซื้อยากลับระดับปวดที่ได้รับการส่งจ่ายจากแพทย์ ด้วยการสร้างแบบจำลองโดยใช้เทคนิค LSTM ซึ่งเป็นโครงข่ายประสาทเทียมชนิดหนึ่งที่กำหนดให้เครื่องเรียนรู้ข้อมูลตามลำดับในแต่ละหน่วยความจำที่สร้างขึ้น เปรียบเทียบกับแบบจำลองที่สร้างด้วยเทคนิค ARIMA ผู้วิจัยใช้ข้อมูลจากการเบิกจ่ายประกันสุขภาพของผู้ป่วยในประเทศสหรัฐอเมริกา โดยในชุดข้อมูลประกอบด้วย feature ได้แก่ ข้อมูลทั่วไปของผู้ป่วย (อายุ, เพศ, ภูมิภาค, ปีเกิด) ข้อมูลทางคลินิก (ประเภทการเข้ารับบริการ, ผลการวินิจฉัย, รหัสประจำตัวผู้ป่วย) และข้อมูลค่าใช้จ่ายด้านยาตามกลุ่มระดับปวดของผู้ป่วยในแต่ละเดือน ตั้งแต่เดือนมกราคมปี 2011 ถึงธันวาคมปี 2015 โดยแบ่งชุดข้อมูลในช่วง 4 ปีแรกเป็นชุดข้อมูลฝึกฝน และข้อมูลปี 2015 เป็นชุดข้อมูลทดสอบ ประเมินประสิทธิภาพของแบบจำลองจากค่า Root Mean Square Error (RMSE) ผลการศึกษาพบว่า การสร้างแบบจำลอง ARIMA จากค่าพารามิเตอร์ที่ดีที่สุดนั้น ค่า RMSE จากชุดข้อมูลทดสอบเท่ากับ 16.855 และค่า R<sup>2</sup> เท่ากับ 0.8045 สำหรับแบบจำลอง LSTM ผู้วิจัยได้พัฒนาโดยเลือกใช้หน่วยความจำที่ 3 – 8 จาก 8 หน่วยความจำที่สร้างขึ้น แต่ละหน่วยประกอบด้วย 7 layer เมื่อทดลองวิเคราะห์แบบ single layer LSTM แล้วพบว่า ค่า RMSE จากชุดข้อมูลทดสอบเท่ากับ 14.617 และค่า R<sup>2</sup> = 0.8048 ผู้วิจัยได้ปรับแบบจำลองเป็น stacked LSTM โดยการจับคู่

หน่วยความจำเพื่อเพิ่มจำนวน layer ในการเรียนรู้แต่ละครั้งพบว่าจำนวนรอบของการเรียนรู้ที่ทำให้แบบจำลองมีค่าพยากรณ์ที่ดีที่สุดคือ 3,000 รอบ ค่า RMSE จากชุดข้อมูลทดสอบ เท่ากับ 13.693 และค่า  $R^2 = 0.8159$  ผู้วิจัยสรุปว่า ในชุดข้อมูลนี้ แบบจำลอง stacked LSTM มีประสิทธิภาพในการพยากรณ์ดีกว่าแบบจำลอง ARIMA และ single layer LSTM เล็กน้อย

ต่อมาในปี 2020 Kaushik และคณะ ได้ทำการศึกษาต่อยอดจากงานวิจัยเดิม (Kaushik *et al.*, 2020) โดยเลือกข้อมูลยาที่มีค่าใช้จ่ายสูง 10 อันดับแรกจากชุดข้อมูลเดิม จำนวน 2 รายการ ซึ่งกำหนดให้เป็นยา A และยา B ข้อมูลที่ใช้ในการวิเคราะห์ครั้งนี้คือค่าใช้จ่ายในแต่ละครั้งที่ผู้ป่วยรับยาดังกล่าวเพิ่ม ตั้งแต่วันที่ 2 มกราคม 2011 ถึง 15 เมษายน 2015 (1,565 วัน) แบ่งช่วงแรก 1,306 วันเป็นชุดข้อมูลฝึกฝนและ 259 วันเป็นชุดข้อมูลทดสอบ แล้วสร้างแบบจำลองที่ใช้ในการพยากรณ์เพื่อเปรียบเทียบประสิทธิภาพคือ วิธี persistence เป็นการประมาณการจากค่าพื้นฐาน, ARIMA, MLP, LSTM, และแบบจำลองแบบผสมผสานจากค่าที่ดีที่สุดของแบบจำลอง ARIMA, MLP และ LSTM (ensemble model) ผลการศึกษาพบว่า ensemble model มีประสิทธิภาพในการพยากรณ์เหนือกว่าแบบจำลองอื่นๆ โดยค่าการประเมินผลการพยากรณ์เปรียบเทียบแต่ละแบบจำลองพบว่า ensemble model ให้ค่า RSME น้อยที่สุด โดย RSME ของยา A และยา B เท่ากับ 127.20 และ 40.24 ตามลำดับ ผู้วิจัยสรุปว่า ความแม่นยำของการพยากรณ์ด้วย ensemble model นั้น เกิดจากการออกแบบกระบวนการที่ใช้ในการฝึกสอนแบบจำลอง หลังจากที่ได้กำหนดค่าพารามิเตอร์ให้มีค่าที่เหมาะสมกับแบบจำลองแล้ว ผู้วิจัยยังได้ทำการฝึกสอนแบบจำลองอีกหลายครั้งเพื่อให้แน่ใจว่าเป็นแบบจำลองที่ให้ค่าพยากรณ์ดีที่สุดตามประเภทของแบบจำลองนั้น นอกจากนี้ยังใช้เทคนิค shuffle และ dropout ซึ่งเป็นการสลับและสุ่มดิง node การเรียนรู้ใน neural network ออก เพื่อลดความแม่นยำที่จำเพาะกับการพยากรณ์ชุดข้อมูลฝึกฝนมากเกินไป (overfitting) ของแบบจำลอง ซึ่งช่วยให้การพยากรณ์ชุดข้อมูลทดสอบของแบบจำลองมีความแม่นยำมากขึ้น

#### 4.2 การพยากรณ์ความต้องการในการใช้ยา

การประยุกต์อนุกรมเวลาที่นำมาใช้กันอย่างแพร่หลายอีกประการหนึ่งคือ การพยากรณ์ความต้องการสินค้า (Demand forecasting) (Kotu & Deshpande, 2019) การพยากรณ์ความต้องการสินค้าสามารถใช้เทคนิคการวิเคราะห์อนุกรมเวลาได้หลากหลายขึ้นอยู่กับลักษณะของธุรกิจ การใช้แบบจำลองทาง

สถิติในการพยากรณ์เหมาะกับข้อมูลอนุกรมเวลากรณีที่ ในขณะที่แบบจำลองจากการเรียนรู้ของเครื่องทุกประเภทรวมทั้งแบบจำลองผสม (hybrid model) สามารถใช้ในการพยากรณ์ข้อมูลที่ไม่แน่นอน หรือสถานการณ์ที่เปลี่ยนแปลงรวดเร็ว ซึ่งประสิทธิภาพของแบบจำลองขึ้นอยู่กับมิติของข้อมูลที่น่าสนใจ นอกจากนี้ การพยากรณ์ความต้องการสินค้ายังสามารถแบ่งตามช่วงเวลาที่ต้องการพยากรณ์ออกได้เป็น 3 ชนิดคือ การพยากรณ์ระยะสั้น (รายชั่วโมง, รายวัน) ใช้แบบจำลองผสมในการพยากรณ์ เช่น ANN + ARIMA เป็นต้น ระยะกลาง (รายวัน, รายเดือน) สามารถใช้แบบจำลองการเรียนรู้ของเครื่อง เช่น Regression หรือ Extreme gradient boosting (XGBoost) เป็นต้น และการเรียนรู้เชิงลึก เช่น LSTM, MLFANN หรือ GAN เป็นต้น สำหรับระยะยาว (รายปี) การใช้แบบจำลองทางสถิติจะพยากรณ์ได้ดีกว่า เช่น ARIMA, Holt-Winter และ Exponential Smoothing เป็นต้น แบบจำลองแต่ละประเภทจึงเหมาะกับการพยากรณ์ในช่วงเวลาที่เฉพาะเจาะจง การพยากรณ์ความต้องการสินค้าที่แม่นยำในแต่ละสถานการณ์จึงไม่สามารถใช้เพียงแบบจำลองเดียวได้ (Ingle *et al.*, 2021)

การพยากรณ์ยอดขายที่แม่นยำเป็นวิธีที่สำคัญและต้นทุนไม่สูงสำหรับแต่ละบริษัทในการเพิ่มผลกำไร ลดต้นทุนการผลิต และประสบความสำเร็จในการปรับตัวให้ธุรกิจดำเนินไปได้ภายใต้ความเปลี่ยนแปลง อาจกล่าวได้ว่า ผลการพยากรณ์ยอดขายที่มีประสิทธิภาพสามารถใช้เป็นข้อมูลเพื่อตัดสินใจในการสร้างความสมดุลระหว่างความต้องการของลูกค้าและต้นทุนสินค้าคงคลัง โดยเฉพาะอย่างยิ่งอุตสาหกรรมยาที่ต้องเผชิญกับความท้าทายในหลายรูปแบบ เช่น การเพิ่มสินค้าคงคลังในปริมาณมาก การแข่งขันทางธุรกิจที่เพิ่มสูงขึ้น กฎระเบียบของแต่ละประเทศที่มีการจำกัดการโฆษณาและการตลาด เมื่อลูกค้าต้องการใช้ยา บริษัทต้องสามารถนำส่งยาได้อย่างทันทั่วทั้งระบบโซ่อุปทานของผลิตภัณฑ์ยาจึงมีความซับซ้อน การจัดหาและนำส่งยาให้กับลูกค้ามีช่องทางที่จำกัดและถูกควบคุมอย่างเคร่งครัด การนำหลักการพยากรณ์ความต้องการสินค้ามาใช้จะเป็นประโยชน์กับทั้งระบบโซ่อุปทาน เนื่องจากคุณภาพของผลิตภัณฑ์เป็นสิ่งที่สำคัญและผลิตภัณฑ์หลายรายการมีอายุสั้น (Merkuryeva *et al.*, 2019; Zadeh *et al.*, 2014) ตัวอย่างงานวิจัยที่มีการนำการพยากรณ์อนุกรมเวลามาพยากรณ์ความต้องการในการใช้ยามี ดังนี้

1. การศึกษาของ Zadeh และคณะ (Zadeh *et al.*, 2014) ได้ทำการศึกษาวิธีการในการพยากรณ์ยอดขายของบริษัทยาด้วยการพยากรณ์อนุกรมเวลาและการวิเคราะห์

โครงข่าย (network analysis) โดยใช้ข้อมูลยอดขายรายเดือนของยา 217 รายการจากบริษัทยาแห่งหนึ่งในประเทศอิหร่าน ชุดข้อมูลประกอบด้วย ชื่อยา รหัสยา หมายเลขการขาย ชื่อและรหัสศูนย์ที่รับยา ชื่อผู้ผลิต ราคาขาย และวันที่ขายในแต่ละเดือน เป็นระยะเวลา 36 เดือน ผู้วิจัยทำการเปรียบเทียบแบบจำลองของยาแต่ละรายการที่สร้างขึ้น 3 แบบโดยใช้เทคนิค ARIMA, Neural network และ Hybrid neural network ที่พัฒนาให้มีทั้งส่วนที่รองรับทั้งข้อมูลที่มีความสัมพันธ์เชิงเส้นและไม่มี ความสัมพันธ์เชิงเส้น ในการฝึกสอนแบบจำลอง ผู้วิจัยได้ทดลองใช้ทั้งข้อมูลการขายย้อนหลังของยารายการนั้น และข้อมูลการขายของยาในกลุ่มเดียวกัน ซึ่งการแบ่งกลุ่มยาเป็นผลมาจากการวิเคราะห์โครงข่ายความสัมพันธ์ของยาแต่ละรายการด้วยโปรแกรมคอมพิวเตอร์ ผลการศึกษาพบว่า แบบจำลอง Hybrid neural network มีความแม่นยำในการพยากรณ์มากกว่าแบบจำลองอื่นๆ ค่าการประเมินผลการพยากรณ์เปรียบเทียบแต่ละแบบจำลองพบว่าแบบจำลอง Hybrid neural network ที่ใช้ข้อมูลการขายของยาในกลุ่มเดียวกันทำให้ค่า MSE และค่า MAE ลดลงจากแบบจำลอง Hybrid neural network ที่ใช้ข้อมูลการขายของยานั้นเพียงอย่างเดียว ดังนั้นการใช้ข้อมูลการขายของยาในกลุ่มเดียวกันในการฝึกสอนแบบจำลองจึงช่วยให้แบบจำลองมีความแม่นยำมากขึ้นได้เนื่องจากข้อมูลการขายของยาบางรายการมีไม่เพียงพอ

2. การศึกษาของ Saena และคณะ (Saena & Suttichaya, 2019) ทำการศึกษาการพยากรณ์ปริมาณการขายยาเพื่อใช้ในการกำหนดปริมาณยาคลังของโรงพยาบาลให้มีความเหมาะสม โดยการเปรียบเทียบแบบจำลองที่เหมาะสมในการพยากรณ์ด้วยเทคนิค MLP, LSTM และ 1D Convolutional neural network (CNN) - LSTM ร่วมกับการใช้เทคนิค Rolling window ซึ่ง label ข้อมูลเป็นช่วงขนาด 1, 6 และ 12 เดือน เพื่อพยากรณ์ปริมาณยาที่ต้องจัดซื้อในช่วงเวลา 1 เดือน 3 เดือน และ 6 เดือน ข้อมูลที่ใช้ในการวิจัยเป็นข้อมูลการขายรายเดือนที่ถูกบันทึกในฐานข้อมูลของโรงพยาบาลสิงห์บุรี ตั้งแต่เดือนตุลาคม ปี 2009 จนถึงเดือนกันยายน ปี 2015 หลังจากนั้นจึงนำรายการทั้งหมดมาวิเคราะห์ด้วย ABC/VEN matrix เพื่อคัดเลือดยาจากกลุ่ม AV ซึ่งคิดเป็น 70% มูลค่าของการใช้ยาทั้งหมดในโรงพยาบาล กล่าวคือเป็นยาที่มีมูลค่าการใช้สูง (A) และเป็นยาที่สำคัญในการรักษา (Vital: V) จำนวน 10 รายการ ได้แก่ Metformin tab. 500 mg, Enalapril tab. 5 mg, Enalapril tab 20 mg, Atenolol tab. 50 mg, Paracetamol tab 500 mg, Paracetamol syr. 12 mg/5 ml, Omeprazole cap. 20 mg,

Salbutamol sulfate inh. 0.1 mg/dose, Chlorpheniramine syr. 2 mg/5 ml, Chlorpheniramine tab. 4 mg ผลการศึกษาพบว่าแบบจำลอง CNN-LSTM ให้ผลการพยากรณ์ที่ดีกว่า เนื่องจาก 1D CNN ถูกพัฒนาให้สามารถเรียนรู้ feature ได้เอง ทำให้อัลกอริทึมสามารถเข้าใจรูปแบบที่เกิดขึ้นในแต่ละ window ได้นอกจากนี้ LSTM ยังมีความเหมาะสมในการพยากรณ์ข้อมูลระยะยาวในอนุกรมเวลา ผลการพยากรณ์ที่แม่นยำและมีค่า error น้อยที่สุดคือแบบจำลอง CNN-LSTM ของยา salbutamol inhaler 0.1 mg/dose ที่ rolling window ช่วง 1 เดือน มีค่า MSE เท่ากับ 0.09% ผู้วิจัยอภิปรายเพิ่มเติมว่าการพยากรณ์ในช่วงเวลา 1 เดือนเหมาะกับยาที่ใช้เฉพาะโรค ช่วงเวลา 3 เดือนเหมาะกับยาที่ใช้ทั่วไป และช่วงเวลา 6 เดือน เหมาะกับยาที่ใช้ในโรคเรื้อรัง

3. ในกรณีที่จำนวนข้อมูลอนุกรมเวลาในอดีตมีจำกัดและไม่เพียงพอต่อการสร้างแบบจำลองที่มีประสิทธิภาพ หรือกรณีเป็นยาที่เพิ่งวางตลาด สามารถปรับวิธีการพยากรณ์ให้มีความเหมาะสมกับชุดข้อมูลได้ จากการศึกษาของ Kravets และคณะ (Kravets et al., 2018) ได้ทำการศึกษากการพยากรณ์ยอดขายยาด้วยวิธีการใช้ข้อมูลในอดีตสร้างแบบจำลองแบบ random forest เปรียบเทียบกับแบบจำลองที่สร้างโดยข้อมูลในอดีตร่วมกับปัจจัยที่มีผลต่อยอดขาย ซึ่งผู้วิจัยได้กำหนดปัจจัยที่มีผลดังนี้ 1) เปอร์เซนต์ของจุดขาย (เฉพาะยาที่มีข้อมูล) 2) ส่วนแบ่งทางการตลาดของผลิตภัณฑ์นั้นๆ ในกลุ่มผลิตภัณฑ์เดียวกัน 3) จำนวนครั้งของการมาพบแพทย์ในช่วงเดือนล่าสุด 4) ระยะเวลาที่มีกิจกรรมส่งเสริมการขาย 5) ส่วนแบ่งทางการตลาดของยานั้นจากยอดขายทั้งหมดเทียบกับตลาดของยาทั้งหมดในกลุ่มเดียวกันที่มีขายในประเทศรัสเซีย 6) ส่วนแบ่งทางการตลาดของยานั้นจากราคาทุนเทียบกับตลาดของยาทั้งหมดในกลุ่มเดียวกันที่มีขายในประเทศรัสเซีย 7) ฤดูกาลปัจจุบัน 8) ราคาขาย 9) เปอร์เซนต์การเปลี่ยนแปลงของราคาขาย 10) ข้อมูลการขาย 11) ข้อมูลตัวอย่างที่ใช้ฝึกสอนงาน ชุดข้อมูลมีจำนวน 2 ชุดคือ 40 และ 80 ฉบับ ผู้วิจัยได้แบ่งข้อมูลทั้ง 2 ชุดออกเป็นชุดข้อมูลฝึกฝน 90% และชุดข้อมูลทดสอบ 10% ผลการวิจัยพบว่า การทดลองฝึกสอนแบบจำลองในรอบที่ 2 ด้วยข้อมูล 80 ฉบับ ให้ผลการพยากรณ์ดีขึ้น แบบจำลองที่สร้างโดยข้อมูลในอดีตร่วมกับปัจจัยที่มีผลต่อยอดขายมีประสิทธิภาพในการพยากรณ์ยอดขายมากกว่า ผู้วิจัยจึงสรุปว่า ข้อมูลอนุกรมเวลาที่มีจำนวนบันทึกน้อย สามารถใช้แบบจำลองที่สร้างจากปัจจัยที่มีผลมาพยากรณ์ข้อมูลได้อย่างมีประสิทธิภาพ

## อภิปรายและสรุปผล

ข้อมูลอนุกรมเวลาสามารถนำมาใช้ในการพยากรณ์ได้อย่างมีประสิทธิภาพ ในปัจจุบันการมีการวิจัยพัฒนาเทคนิคใหม่ๆ ในการสร้างแบบจำลองเพื่อพยากรณ์อนุกรมเวลาที่แม่นยำมากขึ้น มีทั้งวิธีการทางสถิติและการเรียนรู้ของเครื่อง เพื่อก้าวข้ามข้อจำกัดของข้อมูลอนุกรมเวลารูปแบบต่างๆ ในทางเกษตรกรรมได้มีการประยุกต์การพยากรณ์อนุกรมเวลาใน 2 ส่วนที่น่าสนใจคือ การพยากรณ์ค่าใช้จ่ายด้านยา ซึ่งใหญ่เป็นข้อมูลแบบตัวแปรเดียว (univariate) งานวิจัยที่ศึกษาการพยากรณ์อนุกรมเวลาเพื่อพยากรณ์ค่าใช้จ่ายด้านยาจะใช้ข้อมูลในอดีตเป็นระยะเวลาหลายปี ทำให้สามารถสร้างแบบจำลองที่มีประสิทธิภาพในการทำนายทั้งแบบจำลองทางสถิติและแบบจำลองจากการเรียนรู้ของเครื่อง ผลการพยากรณ์สามารถนำไปใช้ในประกอบการตัดสินใจเชิงนโยบาย หรือเป็นข้อมูลวางแผนเพื่อรองรับสถานการณ์ต่างๆ ในอีกส่วนหนึ่งคือการพยากรณ์ความต้องการใช้ยา ซึ่งข้อมูลจะมีความซับซ้อนกว่า และเป็นผลมาจากหลายปัจจัย เน้นผลการพยากรณ์ที่แม่นยำเพื่อนำไปใช้กำหนดแนวปฏิบัติภายในองค์กรให้ทันต่อการเปลี่ยนแปลง งานวิจัยที่ศึกษาการพยากรณ์อนุกรมเวลาเพื่อพยากรณ์ความต้องการในการใช้ยาแต่ละรายการจะมีการพัฒนาแบบจำลองให้เหมาะสมกับข้อมูลที่ต้องการศึกษา ผลการวิจัยส่วนใหญ่พบว่าแบบจำลองจากการเรียนรู้ของเครื่องให้ผลการพยากรณ์ที่แม่นยำกว่า จะเห็นได้ว่าการพยากรณ์อนุกรมเวลาสามารถนำมาประยุกต์ได้อย่างหลากหลาย ผู้พยากรณ์ควรศึกษาเทคนิคต่างๆ ในการสร้างแบบจำลอง เนื่องจากประสิทธิภาพสูงสุดในการพยากรณ์ขึ้นอยู่กับวิธีการที่เหมาะสมกับบริบทของข้อมูลอนุกรมเวลา ช่วงเวลาที่สนใจศึกษาและวัตถุประสงค์ในการพยากรณ์

## References

- Ahmed, N. K., Atiya, A. F., Gayar, N. E., & El-Shishiny, H. (2010). An Empirical Comparison of Machine Learning Models for Time Series Forecasting. *Econometric Reviews*, 29(5-6), 594-621. <https://doi.org/https://doi.org/10.1080/07474938.2010.481556>
- Bengio, Y., Goodfellow, I., & Courville, A. (2015). *Deep Learning*.
- Bontempi, G., Taieb, S., & Borgne, Y.-A. L. (2013). Machine Learning Strategies for Time Series Forecasting. *ResearchGate*, 62-77.
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-Step Data Mining Guide*. SPSS Inc.
- Choo Sri, P., Noimanee, J., & Pansin, K. (2019). *AI for Government Administration and Services* (C. Teerathititangkul, Ed. 1 ed.). Digital Government Development Agency.
- Dix, P. (2020). *Time series forecasting methods*. InfluxData Inc. <https://www.influxdata.com/time-series-forecasting-methods/#:~:text=Time%20series%20forecasting%20is%20a,Astronomy>
- Hyndman, R. J., & Athanasopoulos, G. (2018, 11 October 2022). *Forecasting: principles and practice*. OTexts. Retrieved 8 May from <https://otexts.com/fpp2/index.html>
- Illukkumbura, A. (2021). *Introduction to Time Series Analysis* (1 ed.). Anusha Illukkumbura.
- Ingle, C., bakliwal, D., Jain, J., singh, P., Kale, P., & Chhajed, V. (2021, 6-8 July). Demand Forecasting: Literature Review On Various Methodologies. 12th International Conference on Computing Communication and Networking Technologies (ICCCNT) India.
- Kaladee, A., Laopaiboon, M., & Ungpansattawong, S. (2013). Assessment of Pharmacy Interventions Articles with Interrupted Time Series Design in Healthcare Journals: A Systematic Review. *Srinagarind Med J*, 28, 7.
- Kaushik, S., Choudhury, A., Dasgupta, N., Natarajan, S., Pickett, L. A., & Dutt, V. (2017). Using LSTMs for Predicting Patient's Expenditure on Medications. 2017 International Conference on Machine learning and Data Science,



- Kaushik, S., Choudhury, A., Sheron, P. K., Dasgupta, N., Natarajan, S., Pickett, L. A., & Dutt, V. (2020). AI in Healthcare: Time-Series Forecasting Using Statistical, Neural, and Ensemble Architectures. *Front. Big Data*, 3(4), 17.
- Kotu, V., & Deshpande, B. (2019). *Data science concepts and practice* (2 ed.). Elsevier Inc. <https://doi.org/https://doi.org/10.1016/B978-0-12-814761-0.00001-0>
- Kravets, A. G., Gunaïd, M. A., Loshmanov, V. I., Rasulov, S. S., & Lempert, L. B. (2018). Model of medicines sales forecasting taking into account factors of influence. *J. Phys.: Conf. Ser.*, 1015(3), 8.
- Kullimratchai, P. (2018). Entering into the Era of Data Science. *EAU Heritage Journal Science and Technology*, 12(2), 10.
- Linnér, L., Eriksson, I., Persson, M., & Wettermark, B. (2020). Forecasting drug utilization and expenditure: ten years of experience in Stockholm. *BMC Health Serv. Res.*, 20(410), 11.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS One*, 13(3), 26.
- Merkuryevaa, G., Valbergab, A., & Smirnov, A. (2019). Demand forecasting in pharmaceutical supply chains: A case study. *Procedia Comput. Sci.*, 149, 8.
- Ord, K., Fildes, R., & Kourentzes, N. (2017). *Principles of Business Forecasting* (second ed.). Wessex Press Publishing Co.
- Saena, W., & Suttichaya, V. (2019, 30 October - 01 November 2019). Predicting Drug Sale Quantity Using Machine Learning. 14th International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP),
- Sruamsiri, R., Wagner, A. K., Ross-Degnan, D., Lu, C. Y., Dhippayom, T., Ngorsuraches, S., & Chaiyakunapruk, N. (2016). Expanding access to high-cost medicines through the E2 access program in Thailand: effects on utilisation, health outcomes and cost using an interrupted time-series analysis. *BMJ Open*, 6, 10, Article e008671.
- Sun, J., Lin, Q., Zhao, P., Zhang, Q., Xu, K., Chen, H., Hu, C. J., Stuntz, M., Li, H., & Liu, Y. (2017). Reducing waiting time and raising outpatient satisfaction in a Chinese public tertiary general hospital-an interrupted time series study. *BMC Public Health*, 17, 11, Article 688.
- Willmann, M., Marschal, M., Holzl, F., Schroppel, K., Autenrieth, I. B., & Peter, S. (2013). Time Series Analysis as a Tool To Predict the Impact of Antimicrobial Restriction in Antibiotic Stewardship Programs Using the Example of Multidrug-Resistant *Pseudomonas aeruginosa*. *Antimicrob. Agents Chemother.*, 57, 7.
- Zadeh, N. K., Sepehri, M. M., & Farvaresh, H. (2014). Intelligent Sales Prediction for Pharmaceutical Distribution Companies: A Data Mining Based Approach. *Hindawi*, 2014(Mathematical Problems in Engineering), 15.
- Zdravkovic, M. (2019). *Pharma sales data analysis and forecasting*. Kaggle Inc. <https://www.kaggle.com/code/milanzdravkovic/pharma-sales-data-analysis-and-forecasting/notebook>