

ตัวแบบพยากรณ์อัตราแลกเปลี่ยนสกุลเงิน

Forecasting Model for Currency Exchange Rates

ธรรณินทร์ สัจจวิริยทรัพย์*

สาขาวิศวกรรมโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย
ถนนวิภาวดีรังสิต แขวงรัชดาภิเษก เขตดินแดง กรุงเทพมหานคร 10400

Thoranin Sujjaviriyasup*

Logistics Engineering, School of Engineering, University of the Thai Chamber of commerce,
Vibhavadee-Rangsit Road, Ratchadaphisek, Dindaeng, Bangkok 10400

บทคัดย่อ

วัตถุประสงค์ของงานวิจัยนี้ คือ การหาตัวแบบพยากรณ์ที่เหมาะสมสำหรับอัตราแลกเปลี่ยนสกุลเงินต่างประเทศ 3 สกุลเงิน ได้แก่ ดอลลาร์สหรัฐ ดอลลาร์สิงคโปร์ และเงินเยนของประเทศญี่ปุ่น ซึ่งเป็นข้อมูลอนุกรมเวลาที่มีระยะเวลาตั้งแต่เดือนสิงหาคม พ.ศ. 2555 ถึงเดือนกรกฎาคม พ.ศ. 2560 โดยการศึกษาเชิงการเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์ 6 ตัวแบบพยากรณ์ ได้แก่ ตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียล ตัวแบบไฮลวินเทอร์แบบเชิงบวก ตัวแบบไฮลวินเทอร์แบบเชิงคูณ ตัวแบบอาร์มา ตัวแบบอาพิม่า และตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า ตามลำดับ ด้วยเกณฑ์ประเมินประสิทธิภาพของตัวแบบพยากรณ์ 5 เกณฑ์ ซึ่งตัวแบบพยากรณ์ที่เหมาะสมมีบทบาทที่สำคัญต่อการค้าระหว่างประเทศและการกำหนดกลยุทธ์ทางการค้าที่เหมาะสมของประเทศไทย จากผลการวิจัยพบว่าตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าให้ผลการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินต่างประเทศทั้ง 3 สกุลเงิน ที่แม่นยำกว่าตัวแบบพยากรณ์ทางสถิติทั้ง 5 ตัวแบบพยากรณ์ ซึ่งบ่งชี้ให้เห็นว่าตัวแบบพยากรณ์ที่ไม่เป็นเชิงเส้นตรงสามารถอธิบายพฤติกรรมของการเปลี่ยนแปลงของอัตราแลกเปลี่ยนสกุลเงินทั้ง 3 ได้ดีกว่าตัวแบบพยากรณ์ทางสถิติ จึงกล่าวได้ว่าข้อมูลอัตราแลกเปลี่ยนเงินมีลักษณะไม่เป็นเชิงเส้นตรง นอกจากนี้ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าใช้ข้อกำหนดในการสร้างตัวแบบที่น้อยกว่าตัวแบบพยากรณ์ทางสถิติและสามารถสร้างตัวแบบที่ซับซ้อนสำหรับอธิบายข้อมูลอัตราแลกเปลี่ยนเงินทั้ง 3 สกุลเงิน ที่มีประสิทธิภาพ จึงเหมาะสมที่จะพัฒนาเป็นเครื่องมือที่มีประโยชน์ในการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินทั้ง 3 เพื่อประกอบการตัดสินใจสำหรับกำหนดกลยุทธ์ทางการค้าระหว่างประเทศที่เหมาะสม

คำสำคัญ : ตัวแบบพยากรณ์ไม่เป็นเชิงเส้นตรง; อัตราแลกเปลี่ยนสกุลเงิน; ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า; ตัวแบบพยากรณ์ทางสถิติ

Abstract

The objective of this research was to investigate the most suitable forecasting model for three currency exchange rates (e.g. USD, SGD and JPY), which are time series from August 2012 to July 2017. The comparative study was used to find the most proper forecasting model from six forecasting models (e.g. simple exponential smoothing, Additive Holt-Winters, Multiplicative Holt-Winters, ARIMA, ARFIMA, and Feed-forward artificial neural network) based on five accuracy measures. The most suitable forecasting model plays a crucial role in international trade as well as effective import-export strategies of Thailand. The empirical results indicated that the feed-forward neural network outperforms all five statistical forecasting models, which revealed that the patterns of three currency exchange rates follow non-linear pattern rather than linear pattern. In addition, the developed model is formulated based on a few prior assumptions compared to statistical forecasting models. The model is able to construct complex predictive model to describe the currency exchange rates better than statistical forecasting models. Therefore, the proposed model can be a promising tool to predict the currency exchange rates, and to support decision making on effective import-export strategies of Thailand.

Keywords: non-linear forecasting model; currency exchange rate; feed-forward neural network; statistical forecasting model

1. บทนำ

ภาคการส่งออกของประเทศไทยเป็นส่วนหนึ่งที่มีบทบาทที่สำคัญต่อเศรษฐกิจของประเทศ ซึ่งสามารถสร้างรายได้เข้าสู่ประเทศปีละหลายหมื่นล้านเหรียญสหรัฐ [1] แต่ในอีกด้านหนึ่ง ประเทศไทยก็ยังคงจำเป็นต้องนำเข้าสินค้าที่สำคัญด้วยเช่นเดียวกัน ส่งผลให้เกิดการเจรจาทางการค้าระหว่างประเทศกับประเทศคู่ค้าต่าง ๆ จากเหตุผลที่กล่าวมาข้างต้น อัตราแลกเปลี่ยนเงินตราระหว่างประเทศจึงเป็นหนึ่งในตัวแปรที่สำคัญของระบบเศรษฐกิจทั้งภาครัฐและภาคเอกชน [2] เนื่องจากอัตราแลกเปลี่ยนสกุลเงินที่มีความผันผวนจะส่งผลกระทบต่อการได้รับผลตอบแทนจากการส่งออกสินค้าหรือแม้แต่ต้นทุนการผลิต โดยเฉพาะอย่างยิ่งหากจำเป็นต้องพึ่งพาการนำเข้าสินค้าหรือ

วัตถุดิบจำนวนมากจากประเทศคู่ค้า พฤติกรรมของรูปแบบความผันผวนของอัตราแลกเปลี่ยนเงินตราระหว่างประเทศที่เกิดขึ้นอย่างต่อเนื่องตลอดเวลา ส่งผลให้การคาดการณ์อัตราแลกเปลี่ยนที่จะเกิดขึ้นในอนาคต ซึ่งเป็นสารสนเทศสำคัญสำหรับวางแผนการส่งออกและนำเข้าให้มีประสิทธิภาพมากที่สุด ลักษณะการเปลี่ยนแปลงของอัตราแลกเปลี่ยนเงินตราที่มีความผันผวน ตัวแบบอนุกรมเวลา [3-6] เป็นหนึ่งในเครื่องมือที่ประยุกต์ใช้และเป็นที่ยอมรับว่าเป็นเครื่องมือที่มีประสิทธิภาพในการพยากรณ์ค่าอัตราแลกเปลี่ยนเงินตราระหว่างประเทศ โดยอาศัยข้อมูลในอดีตรวมถึงข้อมูลในปัจจุบันเพื่อสร้างตัวแบบสำหรับทำนายค่าของอัตราแลกเปลี่ยนเงินตราระหว่างประเทศที่จะเกิดการเปลี่ยนแปลงในอนาคต ซึ่ง

สารสนเทศที่ได้สามารถสนับสนุนการตัดสินใจในการบริหารจัดการที่เกี่ยวข้องกับการเจรจาการค้าเพื่อให้เกิดประสิทธิภาพมากที่สุด ดังนั้นความแม่นยำของผลพยากรณ์จึงมีบทบาทที่สำคัญและเป็นประเด็นที่น่าสนใจ เพื่อให้ได้สารสนเทศที่มีประโยชน์ในการตัดสินใจมากที่สุด

อย่างไรก็ตาม วิธีการของการทดสอบลักษณะความสัมพันธ์ของข้อมูลอนุกรมเวลาที่ ต้องการพยากรณ์ยังไม่สามารถระบุคุณลักษณะของความสัมพันธ์ที่ชัดเจนและไม่มีตัวแบบพยากรณ์ใดที่มีประสิทธิภาพในการพยากรณ์ได้ดีในทุกสถานการณ์ ส่งผลให้จำเป็นต้องประยุกต์ใช้ตัวแบบพยากรณ์ต่าง ๆ เพื่อสร้างตัวแบบพยากรณ์จากความสัมพันธ์ของข้อมูล ในอดีตรวมถึงข้อมูลในปัจจุบันสำหรับคาดการณ์ค่าที่จะเกิดขึ้นในอนาคตที่ต้องการและเลือกใช้ตัวแบบพยากรณ์ที่ให้ค่าความแม่นยำมากที่สุดเพื่อใช้ประโยชน์ในการพยากรณ์ต่อไป

ตัวแบบการปรับให้เรียบแบบเอ็กซ์โปเนนเชียลอย่างง่าย (simple exponential smoothing) เป็นหนึ่งในตัวแบบการพยากรณ์อย่างง่าย [7] ซึ่งง่ายต่อการใช้งานเนื่องจากมีฟังก์ชันความสัมพันธ์ที่ไม่ซับซ้อนส่งผลให้ได้รับความนิยมและประยุกต์ใช้ในการพยากรณ์ต่าง ๆ โดยใช้สมการของการปรับเรียบแบบเอ็กซ์โปเนนเชียล 1 สมการในการอธิบายการเปลี่ยนแปลงของข้อมูลอนุกรมเวลา แต่การสร้างตัวแบบพยากรณ์จากหลักการดังกล่าวอาจไม่สามารถอธิบายข้อมูลอนุกรมเวลาที่มีลักษณะของแนวโน้มและฤดูกาลได้ ส่งผลให้มีการพัฒนาตัวแบบการปรับเรียบแบบเอ็กซ์โปเนนเชียลที่มีความซับซ้อนเพิ่มมากขึ้น เพื่อให้สามารถอธิบายรูปแบบของการเปลี่ยนแปลงดียิ่งขึ้น ซึ่งตัวแบบไฮลวินเทอร์เป็นหนึ่งในตัวแบบการปรับเรียบแบบเอ็กซ์โปเนนเชียลที่ได้รับการพัฒนาตัวแบบพยากรณ์ให้มีโครงสร้างที่ซับซ้อนเพื่อให้สามารถ

อธิบายอิทธิพลของแนวโน้มและฤดูกาล โดยการอาศัยสมการของการปรับเรียบ 3 สมการ เพื่ออธิบายอิทธิพลดังกล่าว [8-10]

นอกจากหลักการของการปรับเรียบแบบเอ็กซ์โปเนนเชียลที่ได้กล่าวมาข้างต้น ตัวแบบอาร์ไอมา (ARIMA) เป็นหนึ่งในตัวแบบพยากรณ์ทางสถิติที่พัฒนาจากหลักการของการอธิบายสหสัมพันธ์ในตัวภายใต้สถานะคงที่ (stationary state) และได้รับการยอมรับถึงประสิทธิภาพการพยากรณ์ข้อมูลที่มีลักษณะความสัมพันธ์เชิงเส้นตรง [11-13] จึงใช้ในการพยากรณ์อัตราการแลกเปลี่ยนสกุลเงินตราต่างประเทศต่าง ๆ ถึงแม้ว่า ตัวแบบอาร์ไอมาจะมีประสิทธิภาพดีในการพยากรณ์อัตราการแลกเปลี่ยนสกุลเงิน แต่อย่างไรก็ตาม จุดด้อยของตัวแบบอาร์ไอมาที่สร้างจากความสัมพันธ์เชิงเส้นตรงอาจไม่สามารถอธิบายข้อมูลอนุกรมเวลาที่มีคุณลักษณะความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงได้ นอกจากนี้ผลต่างของลำดับเพื่อแปลงข้อมูลอนุกรมเวลาให้อยู่ในสถานะคงที่มีค่าเป็นจำนวนเต็ม จึงอาจส่งผลให้การอธิบายข้อมูลอนุกรมเวลาได้ไม่ดีเท่าที่ควร ตัวแบบอาร์ไอมา (ARFIMA) จึงพัฒนาขึ้นเพื่อให้ผลต่างของลำดับมีค่าไม่เป็นจำนวนเต็ม เพื่อให้สามารถอธิบายรูปแบบของข้อมูลอนุกรมเวลาที่ยิ่งขึ้น [14-18] แต่จากข้อกำหนดด้านความสัมพันธ์เชิงเส้นตรง รวมทั้งสมมติฐานในการสร้างตัวแบบพยากรณ์ทางสถิติที่ค่อนข้างมีมาก จึงได้มีการพัฒนาตัวแบบการเรียนรู้ของเครื่อง (machine learning) ซึ่งมีคุณลักษณะที่โดดเด่นในการพยากรณ์ข้อมูลอนุกรมเวลาที่มีความสัมพันธ์ไม่เป็นเชิงเส้นตรงและเป็นตัวแบบที่สร้างความสัมพันธ์จากคุณลักษณะของข้อมูล (data-driven model) จึงไม่จำเป็นต้องพิจารณาข้อกำหนดในการสร้างตัวแบบมากเหมือนกับตัวแบบพยากรณ์ทางสถิติ

ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเป็นหนึ่งในตัวแบบการเรียนรู้ของเครื่องที่สร้าง

จากการจำลองหลักการทำงานของระบบประสาทของสิ่งมีชีวิต ซึ่งสามารถแปลงข้อมูลให้อยู่ในปริภูมิ (space) ใหม่ในชั้นซ่อนตัว จึงสร้างโครงสร้างทำนายที่มีความซับซ้อนเพื่ออธิบายข้อมูลอนุกรมเวลาที่มีความสัมพันธ์ไม่เป็นเชิงเส้นตรงได้ดี รวมทั้งมีหลักการเรียนรู้แบบแพร่ย้อนกลับ (back propagation) ในการเรียนรู้และปรับค่าน้ำหนักภายในโครงข่ายประสาทเทียม เพื่อให้สามารถลดความผิดพลาดของการทำนายให้น้อยที่สุด เพื่อให้ได้ผลการพยากรณ์ที่ใกล้เคียงกับค่าจริงมากที่สุด หลักการที่กล่าวมาข้างต้น ตัวแบบโครงข่ายประสาทเทียมอาศัยข้อกำหนดในการสร้างตัวแบบพยากรณ์ค่อนข้างน้อยเมื่อเปรียบเทียบกับตัวแบบพยากรณ์ทางสถิติ จึงได้รับความนิยมในการประยุกต์ใช้ในการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินและเผยแพร่ในวารสารต่าง ๆ [19-25]

งานวิจัยนี้ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าซึ่งเป็นตัวแบบพยากรณ์ไม่เป็นเชิงเส้นตรงพัฒนาและประยุกต์ใช้ในการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินต่างประเทศ 3 สกุลเงิน และเปรียบเทียบประสิทธิภาพความถูกต้องของการพยากรณ์กับตัวแบบพยากรณ์ทางสถิติทั้ง 5 ตัวแบบ ด้วยเกณฑ์การประเมินทั้งหมด 5 เกณฑ์ ได้แก่ ค่าเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์ (mean absolute error) ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (root mean squared error) ค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (mean absolute percentage error) ค่ารากที่สองของค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนกำลังสอง (root mean square percentage error) และค่าสัมประสิทธิ์การตัดสินใจ (R-squared) เพื่อค้นหาตัวแบบพยากรณ์ที่เหมาะสมที่สุดและสามารถนำเสนอสารสนเทศที่ได้จากตัวแบบพยากรณ์ประกอบการตัดสินใจ และกำหนดกลยุทธ์สำหรับการเจรจาทางการค้าระหว่างประเทศได้

อย่างมีประสิทธิภาพ

2. ข้อมูลและวิธีการวิจัย

2.1 ข้อมูลอนุกรมเวลาของอัตราแลกเปลี่ยนสกุลเงินต่างประเทศ

ข้อมูลอนุกรมเวลาที่ใช้ในการวิจัยนี้เป็นข้อมูลอัตราแลกเปลี่ยนสกุลเงินต่างประเทศ 3 สกุลเงิน ซึ่งเป็นข้อมูลอนุกรมเวลารายเดือนตั้งแต่เดือนสิงหาคม พ.ศ. 2555 ถึงเดือนกรกฎาคม พ.ศ. 2560 ซึ่งเป็นอัตรากลางของอัตราแลกเปลี่ยนสกุลเงินต่างประเทศ จากข้อมูลเว็บไซต์ของธนาคารแห่งประเทศไทย [26] จำนวน 60 ค่าสังเกต โดยข้อมูลทั้งหมดแสดงดังรูปที่ 1

2.2 ตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียล

การพยากรณ์ข้อมูลอนุกรมเวลา การสร้างตัวแบบพยากรณ์ด้วยวิธีการปรับให้เรียบแบบเอ็กโปเนนเชียลโดยการระบุค่าน้ำหนักของข้อมูลอนุกรมเวลาที่แตกต่างกัน เพื่อให้สามารถอธิบายรูปแบบการเปลี่ยนแปลงของข้อมูลอนุกรมเวลา โดยตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลอย่างง่ายเป็นหนึ่งในตัวแบบการปรับเรียบที่ง่ายที่สุด เนื่องจากมีสมการของการสร้างตัวแบบเพียง 1 สมการ ดังสมการที่ 1

2.2.1 ตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลอย่างง่าย

$$\hat{y}_{t+1|t} = \sum_{i=0}^{t-1} \alpha(1-\alpha)^i y_{t-i} + (1-\alpha)^t l_0 \quad (1)$$

เมื่อ \hat{y}_t คือ ค่าพยากรณ์ ณ เวลาที่ t ; l_0 คือ ค่าเริ่มต้น ณ เวลาที่ t เท่ากับศูนย์; α คือ ค่าการปรับเรียบ โดย $0 < \alpha < 1$

สำหรับการอธิบายเกี่ยวกับตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลอย่างง่ายจะใช้สัญลักษณ์ SES ในส่วนของการแสดงผลเพื่อให้กระชับในการนำเสนอด้วยความต้องการอธิบายรูปแบบของข้อมูลอนุ

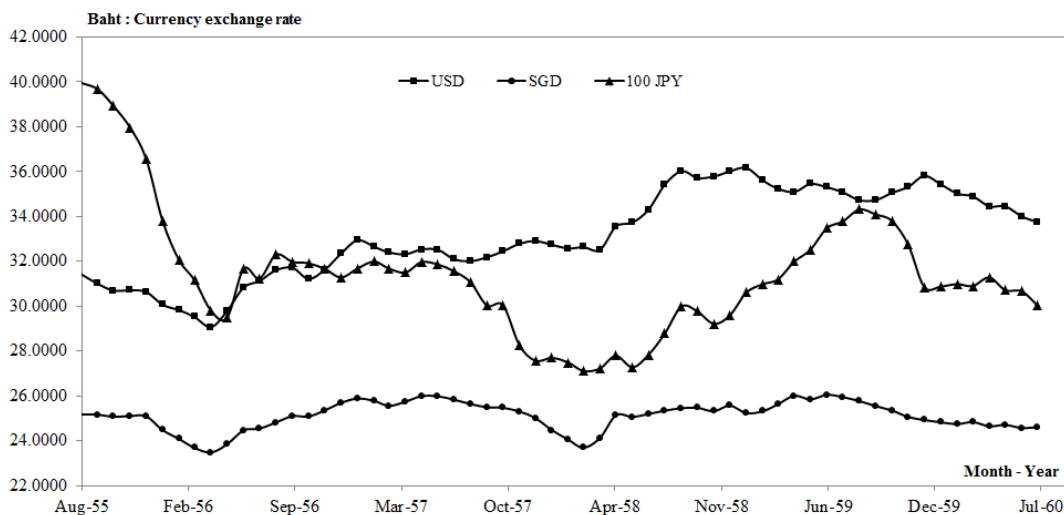


Figure 1 Datasets of currency exchange rates.

กรรมเวลาได้ดียิ่งขึ้น ตัวแบบโฮลวินเทอร์เชิงบวกและเชิงคูณได้พัฒนาเพื่อให้สามารถอธิบายอย่างครอบคลุมยิ่งขึ้น ซึ่งประกอบด้วยสมการของการปรับเรียบแบบเอ็กโปเนนเชียล 3 สมการ ดังสมการที่ 2 ถึง 9 ตามลำดับ

2.2.2 ตัวแบบโฮลวินเทอร์แบบเชิงบวก

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

$$s_t = \gamma(y_t - l_t) + (1 - \gamma)s_{t-m} \quad (4)$$

$$y_{t+h} | t = l_t + hb_t + s_{t-m+1+(h-1) \bmod m} \quad (5)$$

2.2.3 ตัวแบบโฮลวินเทอร์แบบเชิงคูณ

$$l_t = \alpha \left(\frac{y_t}{s_{t-m}} \right) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (6)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (7)$$

$$s_t = \gamma \left(\frac{y_t}{l_t} \right) + (1 - \gamma)s_{t-m} \quad (8)$$

$$y_{t+h} | t = (l_t + hb_t) \times s_{t-m+1+(h-1) \bmod m} \quad (9)$$

เมื่อ l_t คือ ค่าประมาณของระดับของข้อมูลอนุกรมเวลา ณ เวลาที่ t ; b_t คือ ค่าประมาณของแนวโน้มของข้อมูลอนุกรมเวลา ณ เวลาที่ t ; s_t คือ ค่าประมาณ

ของฤดูกาลของข้อมูลอนุกรมเวลา ณ เวลาที่ t ; α คือ ค่าการปรับเรียบ โดย $0 < \alpha < 1$; β คือ ค่าการปรับเรียบ โดย $0 < \beta < 1$; γ คือ ค่าการปรับเรียบ โดย $0 < \gamma < 1$; h คือ ค่าช่วงการพยากรณ์ไปข้างหน้าของข้อมูลอนุกรมเวลา; m คือ ค่าช่วงของอิทธิพลของฤดูกาลของข้อมูลอนุกรมเวลา

เพื่อให้การนำเสนอเกิดความกระชับในการอธิบายในส่วนของผลการวิจัย จะใช้สัญลักษณ์ HW (additive) และ HW (multiplicative) แทนตัวแบบโฮลวินเทอร์แบบเชิงบวกและตัวแบบโฮลวินเทอร์แบบเชิงคูณ ตามลำดับ

งานวิจัยนี้ตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลเขียนขึ้นจากโปรแกรม R [27] ด้วยไลบรารี “forecast” และพิจารณาตัวแบบที่เหมาะสมที่สุดด้วยเกณฑ์อะโคอินฟอร์มชันครอทีเรียแบบมีขนาดตัวอย่างแบบจำกัด (AICc) ที่ต่ำที่สุด โดยอาศัยไลบรารี “forecast” ซึ่งพัฒนาขึ้นเพื่อช่วยให้สามารถหาตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลที่เหมาะสมที่สุด โดยได้รับการอ้างอิงและประยุกต์ใช้ในงานวิจัยที่เผยแพร่ในวารสารวิชาการที่ได้รับการยอมรับต่าง ๆ [28-30]

2.3 ตัวแบบอาร์มา

ตัวแบบอาร์มาเป็นตัวแบบอนุกรมเวลาที่มีความโดดเด่นในการพยากรณ์ข้อมูลที่มีความสัมพันธ์เป็นแบบเชิงเส้นตรง ซึ่งเป็นรูปแบบทั่วไปของตัวแบบอาร์มา (ARMA) ในกรณีที่มีข้อมูลอนุกรมเวลาไม่อยู่ในสถานะคงที่ (non-stationary state) โดยมีสมการทางคณิตศาสตร์ของตัวแบบอาร์มาแบบทั้งที่มีอิทธิพลของฤดูกาลและไม่มีอิทธิพลของฤดูกาล ดังแสดงในสมการที่ 10 และ 11 ตามลำดับ

$$\Phi_P(B^s) \nabla^D \nabla^d Y_t = \mu + \theta_Q(B^s) \varepsilon_t \quad (10)$$

$$\left(1 - \sum_{i=1}^P \phi_i B^i \right) (1-B)^d (Y_t - \mu) = \left(1 - \sum_{j=1}^Q \theta_j B^j \right) \varepsilon_t \quad (11)$$

เมื่อ Y_t และ ε_t คือ ค่าจริงและค่าความคลาดเคลื่อน ณ เวลาที่ t ตามลำดับ; B และ μ คือ ตัวแปลงค่าอนุกรมเวลาย้อนกลับ (backward shift operator) และค่าเฉลี่ย ตามลำดับ; d และ D คือ ลำดับของผลต่างและลำดับของผลต่างฤดูกาล ตามลำดับ; p และ q คือ ลำดับของอาร์มาแบบไม่มีฤดูกาล; P และ Q คือ ลำดับของอาร์มาแบบมีฤดูกาล

สำหรับงานวิจัยนี้ตัวแบบอาร์มาที่เหมาะสมที่สุดจะเลือกจากเกณฑ์อะไคอินฟอร์มเมชันโครทีเรียลแบบมีขนาดตัวอย่างแบบจำกัดที่ค่าต่ำที่สุด ซึ่งเขียนขึ้นจากโปรแกรม R ด้วยไลบรารี “forecast” ของโปรแกรม R ที่ได้พัฒนาขึ้น [27] เพื่อช่วยในการหาตัวแบบอาร์มาทั้งแบบที่มีอิทธิพลของฤดูกาลและไม่มีอิทธิพลของฤดูกาลที่เหมาะสมที่สุดแบบอัตโนมัติด้วยอัลกอริทึมของ Hyndman-Khandakar ซึ่งได้รับการอ้างอิงและประยุกต์ใช้ในงานวิจัยที่ได้รับการเผยแพร่ในวารสารที่เป็นที่ยอมรับต่าง ๆ [28-30] แต่เนื่องจากการหาตัวแบบอาร์มาที่เหมาะสมจะขึ้นอยู่กับจำนวนข้อมูลอนุกรมเวลาที่มีการเปลี่ยนแปลงในแต่ละช่วงเวลา จึงส่งผลให้ลำดับของตัวแบบอาร์มามีการปรับเปลี่ยนไปด้วย ดังนั้นจะใช้สัญลักษณ์ ARIMA (ตัว

แบบอาร์มาแบบไม่ระบุลำดับ) ในส่วนของผลการวิจัยเพื่อความกระชับในการนำเสนอ

2.4 ตัวแบบอาพีมา

ตัวแบบอาพีมาเป็นตัวแบบที่พัฒนาต่อจากตัวแบบอาร์มา ซึ่งกำหนดให้ค่าลำดับของผลต่างมีค่าไม่เป็นจำนวนเต็ม โดยสมการทางคณิตศาสตร์ของตัวแบบอาพีมาสามารถอธิบายดังสมการที่ 12

$$\phi_P(B) \nabla^d Y_t = \mu + \theta_Q(B) \varepsilon_t \quad (12)$$

เมื่อ Y_t และ ε_t คือ ค่าจริงและค่าความคลาดเคลื่อน ณ เวลาที่ t ตามลำดับ; B และ μ คือ ตัวแปลงค่าอนุกรมเวลาย้อนกลับ (backward shift operator) และค่าเฉลี่ย ตามลำดับ; d คือ ลำดับของผลต่างที่ไม่เป็นจำนวนเต็ม; p และ q คือ ลำดับของอาพีมา

การพิจารณาตัวแบบอาพีมาที่เหมาะสมของงานวิจัยนี้ ค่าของลำดับของผลต่างนั้นกำหนดให้มีค่าอยู่ระหว่าง 0 ถึง 0.5 โดยใช้อัลกอริทึมของ Haslett และ Raftery เพื่อประมาณค่าของตัวแบบอาพีมาที่เหมาะสมที่สุด นอกจากนี้อัลกอริทึมของ Hyndman-Khandakar สามารถเลือกลำดับของตัวแบบอาพีมา (p และ q) อย่างอัตโนมัติด้วยเกณฑ์อะไคอินฟอร์มเมชันโครทีเรียลแบบมีขนาดตัวอย่างแบบจำกัดที่น้อยที่สุดโดยตัวแบบอาพีมาที่ประยุกต์ใช้ในงานวิจัยนี้ เขียนขึ้นจากโปรแกรม R ซึ่งไลบรารี “forecast” ของโปรแกรม R [27] ได้ พัฒนาเพื่อช่วยในการพยากรณ์ด้วยการหาตัวแบบที่เหมาะสมแบบอัตโนมัติ ซึ่งได้รับการอ้างอิงและประยุกต์ใช้งานในงานวิจัยที่ได้รับการเผยแพร่ในวารสารที่เป็นที่ยอมรับต่าง ๆ [28-30] แต่เนื่องจากลำดับของตัวแบบอาพีมาที่เปลี่ยนแปลงไปตามการปรับปรุงข้อมูลสำหรับการสร้างตัวแบบพยากรณ์ ดังนั้นตัวแบบอาพีมาในงานวิจัยนี้จะใช้สัญลักษณ์ ARFIMA (ตัวแบบอาพีมาแบบไม่ระบุลำดับ) ในส่วนของผลการวิจัยเพื่อความกระชับในการนำเสนอ

2.5 ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า

ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเป็นหนึ่งในตัวแบบการเรียนรู้ของเครื่องแบบมีผู้สอน (supervised machine learning) ซึ่งจำลองหลักการทำงานของระบบประสาทของสิ่งมีชีวิตสำหรับใช้ในการประมวลผล เพื่อจำแนกและทำนายข้อมูลที่ต้องการศึกษา โดยการใช้สมการทางคณิตศาสตร์เพื่ออธิบายหลักการทำงานของโครงข่ายประสาทเทียมเพื่อปรับค่าพยากรณ์ให้ใกล้เคียงกับค่าจริงมากที่สุด ซึ่งตัวแบบโครงข่ายประสาทเทียมที่ใช้ในงานวิจัยนี้เป็นตัวแบบมีโครงสร้างแบบป้อนไปข้างหน้า ซึ่งประกอบด้วยชั้นของหน่วยรับข้อมูล (input layer) ชั้นซ่อนตัว (hidden layer) จำนวน 1 ชั้น และชั้นของการแสดงผลข้อมูล (output layer) รวมทั้งการเรียนรู้แบบแพร่ย้อนกลับ โดยสามารถอธิบายตัวแบบทางคณิตศาสตร์ดังสมการที่ 13

$$x_{t+1} = h \left(\beta_0 + \sum_{j=1}^D \beta_j g \left(w_{0j} + \sum_{i=1}^m w_{ij} x_{t-(i-1)} \right) \right) \quad (13)$$

เมื่อ m และ D คือ จำนวนข้อมูลป้อนเข้า (input data) และจำนวนโหนด (node) ในชั้นซ่อนตัวตามลำดับ; w_{0j} และ w_{ij} คือ ค่าเอนเอียง (bias) ของโหนดที่ j ในชั้นซ่อนตัว ค่าถ่วงน้ำหนักของข้อมูลป้อนเข้าที่ i ไปยังโหนดที่ j ตามลำดับ; x_t คือ ค่าข้อมูลอนุกรมเวลาที t ; β_0 และ β_j คือ ค่าเอนเอียง (bias) ของค่าเป้าหมายในชั้นแสดงข้อมูล และค่าถ่วงน้ำหนักของข้อมูลป้อนเข้าในชั้นซ่อนตัวของโหนดที่ j ตามลำดับ; $g(\bullet)$ คือ ฟังก์ชันไม่เป็นเชิงเส้นตรงของแต่ละโหนดในชั้นซ่อนตัวด้วยฟังก์ชันซิกมอยด์ (sigmoid function); $h(\bullet)$ คือ ฟังก์ชันเชิงเส้นตรงของความสัมพันธ์ระหว่างแต่ละโหนดกับค่าเป้าหมาย (target data)

รูปแบบความสัมพันธ์ในสมการที่ 13 นั้นสามารถอธิบายขั้นตอนการดำเนินงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า [31] ดังนี้

2.5.1 ค่าถ่วงน้ำหนักต่าง ๆ ของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่กำหนดขึ้นด้วยวิธีการสุ่ม โดยค่าเอนเอียงรวมในกลุ่มของค่าถ่วงน้ำหนักด้วย

2.5.2 ป้อนค่าของข้อมูลป้อนเข้าขนาด m ค่า เข้าสู่โครงข่ายประสาทเทียมเพื่อพยากรณ์ค่าในอนาคตตามสมการที่ 13

2.5.3 พิจารณาค่าผลรวมกำลังสองของความผิดพลาดจากการพยากรณ์เปรียบเทียบกับค่าจริง

2.5.4 พิจารณาค่าความชัน (gradient) ของแต่ละค่าถ่วงน้ำหนัก โดยการหาอนุพันธ์ลำดับที่ 1 ของความผิดพลาดเปรียบเทียบกับค่าถ่วงน้ำหนัก

2.5.5 ปรับน้ำหนักของแต่ละค่าถ่วงน้ำหนักด้วยวิธี Broyden-Fletcher-Goldfarb-Shanno (BFGS) ซึ่งจะใช้ค่าอนุพันธ์ลำดับที่ 2 ของความผิดพลาดเปรียบเทียบกับค่าถ่วงน้ำหนักในรูปแบบเมตริกซ์ผกผันของ Hessian เพื่อหาค่าถ่วงน้ำหนักที่ได้ค่าผลรวมกำลังสองของค่าความผิดพลาดที่น้อยที่สุดดังสมการที่ 14

$$\Delta w_k = -H_k^{-1} g_k \quad (14)$$

เมื่อ Δw_k คือ การปรับค่าน้ำหนักที่ k ; H_k^{-1} คือ เมตริกซ์ผกผันของ Hessian; g_k คือ ความชันที่ k

2.5.6 ดำเนินการในขั้นตอนที่ 2 ถึง 5 จนกระทั่งถึงเกณฑ์ที่กำหนดให้หยุด จึงแสดงผลตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุด

สำหรับตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่ใช้ในงานวิจัยนี้ เขียนขึ้นจากโปรแกรม R ด้วยไลบรารี “nnet” ของโปรแกรม R ที่ได้พัฒนาขึ้น ซึ่งมีการนำไปใช้ในงานวิจัยอย่างแพร่หลาย [32-35] โดยการจัดเรียงข้อมูลอนุกรมเวลาให้อยู่ในรูปแบบ m คอลัมน์ดังรูปที่ 2 ซึ่งใช้ข้อมูลย้อนหลังตั้งแต่คอลัมน์ที่ 1 ถึงคอลัมน์ที่ $m-1$ เป็นข้อมูลป้อนเข้า

และคอลัมน์ที่ m ซึ่งเป็นคอลัมน์สุดท้ายเป็นข้อมูลเป้าหมาย (target data) เพื่อการเรียนรู้ของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าในการสร้างตัวแบบพยากรณ์

$$y_1, y_2, y_3, y_4, \dots, y_{t-3}, y_{t-2}, y_{t-1}, y_t$$



$$\begin{bmatrix} y_1, y_2, y_3, \dots, y_{m-2}, y_{m-1}, y_m \\ y_2, y_3, y_4, \dots, y_{m-1}, y_m, y_{m+1} \\ y_3, y_4, y_5, \dots, y_m, y_{m+1}, y_{m+2} \\ \vdots \\ y_{t-m+1}, \dots, y_{t-2}, y_{t-1}, y_t \end{bmatrix}$$

Figure 2 Data preparation for feed-forward artificial neural network.

ดังนั้นจะใช้สัญลักษณ์ ANN(m, D) แทนตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่จัดเรียงใหม่ m คอลัมน์และมีจำนวนโหนดในชั้นซ่อนตัว D โหนด ในส่วนของผลการวิจัย เพื่อให้การนำเสนอผลอยู่ในรูปแบบที่กระชับ โดยจำนวนคอลัมน์มีค่าตั้งแต่ 2 ถึง 10 คอลัมน์ที่ใช้ในการพัฒนาตัวแบบพยากรณ์เพื่อหาตัวแบบที่เหมาะสมที่สุด นอกจากนี้จำนวนโหนดในชั้นซ่อนตัวมีค่าตั้งแต่ 1 ถึง 100 โดยเพิ่มทีละ 10 โหนด เพื่อให้ได้ตัวแบบที่เหมาะสมที่สุดสำหรับการพยากรณ์ด้วยเช่นกัน

3. การวัดประสิทธิภาพของตัวแบบพยากรณ์

ความจริงที่ทราบโดยทั่วไปว่ายังไม่มีวิธีการวิเคราะห์ลักษณะความสัมพันธ์ของข้อมูลอนุกรมเวลาที่สามารถระบุความสัมพันธ์ได้อย่างชัดเจน ประกอบกับไม่มีผลการยืนยันจากงานวิจัยที่บ่งชี้เกี่ยวกับตัวแบบพยากรณ์ที่มีประสิทธิภาพดีในการพยากรณ์ในทุกสถานการณ์ จึงจำเป็นที่จะต้องนำตัวแบบพยากรณ์ต่าง ๆ เพื่อสร้างฟังก์ชันการทำนายสำหรับพยากรณ์ค่า

ในอนาคต ซึ่งต้องอาศัยการแบ่งชุดข้อมูลสำหรับทดสอบและเกณฑ์การประเมินประสิทธิภาพ ในการพิจารณาความถูกต้องของผลการพยากรณ์และเลือกใช้ตัวแบบพยากรณ์ที่เหมาะสมที่สุดในการหาสารสนเทศที่เป็นประโยชน์ต่อการตัดสินใจที่เหมาะสม

3.1 การแบ่งชุดข้อมูลเพื่อทดสอบตัวแบบพยากรณ์ (cross-validation)

เพื่อทดสอบประสิทธิภาพในการพยากรณ์ค่าในอนาคตของตัวแบบพยากรณ์ การแบ่งชุดข้อมูลสำหรับทดสอบประสิทธิภาพการพยากรณ์ช่วงเวลาล่วงหน้าของแต่ละตัวแบบจึงเป็นหนึ่งในขั้นตอนที่สำคัญ โดยแบ่งข้อมูลเป็น 2 ชุด ได้แก่ ชุดข้อมูลสำหรับการสร้างตัวแบบพยากรณ์และข้อมูลสำหรับการทดสอบตัวแบบพยากรณ์ในสัดส่วนร้อยละ 70 และ 30 ตามลำดับ ซึ่งข้อมูลในชุดทดสอบตัวแบบพยากรณ์จะปิดไว้และไม่เกี่ยวข้องกับชุดข้อมูลในการสร้างตัวแบบ จนกระทั่งข้อมูลอนุกรมเวลาค่านั้นถูกเฉลย เพื่อเปรียบเทียบกับผลการพยากรณ์ที่ได้จากตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพิจารณาความผิดพลาดของการพยากรณ์ด้วยเกณฑ์ต่าง ๆ จึงนำข้อมูลที่ถูกละเลยเข้ามารวมกับชุดข้อมูลสำหรับการสร้างตัวแบบพยากรณ์เดิม เพื่อเป็นชุดข้อมูลสำหรับการสร้างตัวแบบพยากรณ์ตัวใหม่ และใช้ในการพยากรณ์ค่าในอนาคต 1 ค่า ล่วงหน้าต่อไป โดยวิธีดำเนินการดังที่กล่าวมาข้างต้นจะกระทำพยากรณ์ครบทุกค่าในชุดข้อมูลสำหรับการทดสอบตัวแบบพยากรณ์ เพื่อนำค่าพยากรณ์และค่าจริงที่ได้ทั้งหมดสำหรับการประเมินประสิทธิภาพการพยากรณ์ด้วยเกณฑ์ต่าง ๆ

3.2 การประเมินประสิทธิภาพของตัวแบบพยากรณ์

สำหรับการประเมินประสิทธิภาพการพยากรณ์ของตัวแบบต่าง ๆ เกณฑ์การประเมินความ

ถูกต้องของการพยากรณ์ต่าง ๆ จึงนำมาใช้สำหรับวัดประสิทธิภาพ ซึ่งเกณฑ์ที่ใช้ในการประเมินในงานวิจัยนี้มี 5 เกณฑ์ ดังนี้

3.2.1 ค่าเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์ (mean absolute error, MAE) โดย

$$MAE = \text{mean}(|Y_t - \hat{Y}_t|) \quad (15)$$

3.2.2 ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (root mean squared error, RMSE) โดย

$$RMSE = \sqrt{\text{mean}((Y_t - \hat{Y}_t)^2)} \quad (16)$$

3.2.3 ค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (mean absolute percentage error, MAPE) โดย

$$MAPE = \text{mean}\left(\left|\frac{Y_t - \hat{Y}_t}{Y_t}\right| \times 100\right) \quad (17)$$

3.2.4 ค่ารากที่สองของค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนกำลังสอง (root mean square percentage error, RMSPE) โดย

$$RMSPE = \sqrt{\text{mean}\left(\left(\frac{Y_t - \hat{Y}_t}{Y_t} \times 100\right)^2\right)} \quad (18)$$

3.2.5 ค่าสัมประสิทธิ์การตัดสินใจ (R-squared, r^2) โดย

$$r^2 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (17)$$

เมื่อ x_i และ y_i คือ ค่าที่ i ของตัวแปร x และ y ตามลำดับ; \bar{x} และ \bar{y} คือ ค่าเฉลี่ยของตัวแปร x และ y ตามลำดับ

4. ผลการวิจัยและการอภิปรายผล

การพยากรณ์อัตราแลกเปลี่ยนสกุลเงินดอลลาร์สหรัฐด้วยตัวแบบพยากรณ์ต่าง ๆ ซึ่งผลการพยากรณ์แสดงดังในรูปที่ 3 และประสิทธิภาพของตัวแบบพยากรณ์แสดงในตารางที่ 1

ผลการพยากรณ์ในรูปที่ 3 พบว่าแนวโน้มของการพยากรณ์ด้วยตัวแบบต่าง ๆ มีทิศทางสอดคล้องกับข้อมูลอนุกรมเวลาของอัตราแลกเปลี่ยนสกุลเงินดอลลาร์สหรัฐ ยกเว้นตัวแบบโฮลวินเทอร์ทั้ง 2 ตัวแบบพยากรณ์ [HW (additive) และ HW (multiplicative)] และตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลอย่างง่าย (SES) ให้ผลการพยากรณ์ที่เบี่ยงเบนไปจากข้อมูลจริงค่อนข้างมากในช่วงเวลา ซึ่งผลการพยากรณ์ของแต่ละตัวแบบ สามารถพิจารณาประสิทธิภาพของแต่ละตัวแบบพยากรณ์ โดยอาศัยเกณฑ์การพิจารณา 5 เกณฑ์ ดังแสดงในตารางที่ 1


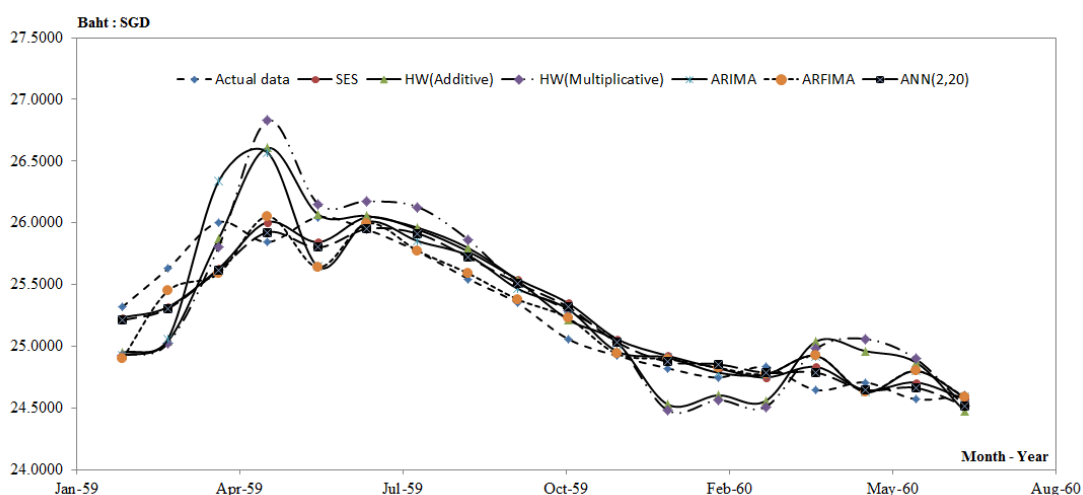


Figure 3 Forecast data of exchange rate for US Dollar.

Table 1 The summary of all forecasting models based on US Dollar.

Model	MAE	RMSE	MAPE	RMSPE	R-squared
SES	0.294	0.333	0.84 %	0.95 %	0.68
HW (Additive)	0.337	0.399	0.97 %	1.14 %	0.59
HW (Multiplicative)	0.358	0.413	1.03 %	1.19 %	0.56
ARIMA	0.263	0.324	0.75 %	0.92 %	0.71
ARFIMA	0.256	0.316	0.73 %	0.89 %	0.70
ANN (3,100)	0.251	0.306	0.72 %	0.87 %	0.76

**Figure 4** Forecast data of exchange rate for Singapore Dollar.

ตารางที่ 1 พบว่าตัวแบบ ANN (3,100) ซึ่งเป็นตัวแบบโครงข่ายประสาทเทียมที่สร้างจากข้อมูลอนุกรมเวลาย้อนหลัง 2 ค่า เพื่อทำนายค่าในอนาคต 1 ช่วงเวลาล่วงหน้า โดยใช้จำนวนโหนดขนาด 100 โหนด สำหรับการแปลงค่าข้อมูลนำเข้าไปสู่ปริภูมิใหม่สำหรับการพยากรณ์ ให้ค่าเฉลี่ยของความคลาดเคลื่อนน้อยที่สุดเมื่อเทียบกับตัวแบบพยากรณ์ทางสถิติทั้ง 5 ตัวแบบ ซึ่งสามารถกล่าวได้ว่าข้อมูลอนุกรมเวลาของอัตราแลกเปลี่ยนสกุลเงินดอลลาร์สหรัฐมีลักษณะความสัมพันธ์ไม่เป็นเชิงเส้นตรงที่เด่นชัดกว่าความสัมพันธ์แบบเชิงเส้นตรง จึงส่งผลให้ตัวแบบพยากรณ์โครงข่าย

ประสาทเทียมแบบป้อนไปข้างหน้าที่มีประสิทธิภาพดี ในการพยากรณ์ข้อมูลอนุกรมเวลาแบบไม่เป็นเชิงเส้นตรงสามารถอธิบายลักษณะของข้อมูลได้ดีกว่า นอกจากนี้ ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าให้ค่าสัมประสิทธิ์การตัดสินใจที่มากที่สุด ซึ่งกล่าวได้ว่าผลการพยากรณ์ที่ได้จากตัวแบบโครงข่ายประสาทเทียมสอดคล้องกับค่าข้อมูลอนุกรมเวลาจริงมากถึงร้อยละ 76 ในส่วนของอาร์ฟิมา (ARFIMA) ซึ่งใช้ผลต่างของข้อมูลอนุกรมเวลาไม่เป็นจำนวนเต็มสามารถให้ค่าเฉลี่ยของความผิดพลาดที่น้อยกว่าตัวแบบอาร์มีนา (ARIMA) จึงแสดงให้เห็นว่าการใช้ผลต่างที่

เป็นจำนวนเต็มอาจไม่สามารถอธิบายลักษณะของการเปลี่ยนแปลงของอัตราแลกเปลี่ยนสกุลเงินดอลลาร์สหรัฐดีเท่าที่ควร

สำหรับการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินดอลลาร์สิงคโปร์ แสดงในรูปแบบที่ 4 และการพิจารณาประสิทธิภาพของตัวแบบพยากรณ์แสดงในตารางที่ 2

การพยากรณ์ข้อมูลอนุกรมเวลาของอัตราแลกเปลี่ยนสกุลเงินดอลลาร์สิงคโปร์ในรูปแบบที่ 4 พบว่าทิศทางของผลการพยากรณ์มีแนวโน้มเป็นไปในแนวเดียวกัน ยกเว้นตัวแบบโฮลวินเทอร์ทั้ง 2 ตัวแบบพยากรณ์ [HW (additive) และ HW (multiplicative)] และตัวแบบอาร์มา (ARIMA) ซึ่งตัวแบบพยากรณ์ทั้ง 3 ให้ค่าพยากรณ์ที่เบี่ยงเบนไปจากข้อมูลจริงค่อนข้างมากในบางช่วงเวลา โดยค่าประสิทธิภาพของตัวแบบพยากรณ์ต่าง ๆ ในตารางที่ 2 พบว่าตัวแบบอาร์ฟิมา (ARFIMA) ซึ่งมีลำดับของผลต่างที่ไม่เป็นจำนวนเต็มยังคงให้ค่าพยากรณ์ที่ดีกว่าตัวแบบอาร์มา (ARIMA) จึงกล่าวได้ว่าตัวแบบอาร์ฟิมาที่ใช้ผลต่างของจำนวนเต็มไม่สามารถอธิบายลักษณะของการเปลี่ยนแปลงของอัตราการแลกเปลี่ยนสกุลเงินดอลลาร์สิงคโปร์เมื่อเปรียบเทียบกับตัวแบบอาร์ฟิมา อย่างไรก็ตาม ตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลอย่างง่ายสามารถให้ค่าเฉลี่ยของความผิดพลาดที่น้อยที่สุดในกลุ่มของตัวแบบ

พยากรณ์ทางสถิติ ถึงแม้ว่าตัวแบบการปรับเรียบแบบเอ็กโปเนนเชียลอย่างง่ายจะให้ผลการพยากรณ์ที่ดีที่สุดในกลุ่มของตัวแบบพยากรณ์ทางสถิติ ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (ANN(2,20)) ที่ใช้ข้อมูลย้อนหลังเพียง 1 ค่า และจำนวนโหนดในชั้นซ่อนตัวจำนวน 20 โหนด ในการแปลงค่าข้อมูลป้อนเข้าให้อยู่ในปริภูมิใหม่ เพื่อสร้างฟังก์ชันความสัมพันธ์ในการพยากรณ์ค่าในอนาคต 1 ช่วงเวลาล่วงหน้า สามารถให้ค่าเฉลี่ยของความผิดพลาดที่น้อยที่สุดทั้ง 4 เกณฑ์ ซึ่งบ่งชี้ว่าความสัมพันธ์ของข้อมูลอัตราแลกเปลี่ยนสกุลเงินดอลลาร์สิงคโปร์เป็นแบบไม่เชิงเส้นตรง จึงส่งผลให้ตัวแบบพยากรณ์ไม่เป็นเชิงเส้นตรงอย่างตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าสามารถอธิบายดีกว่าตัวแบบพยากรณ์ทางสถิติที่สร้างจากความสัมพันธ์ที่เป็นเชิงเส้นตรง นอกจากนี้ตัวแบบโครงข่ายประสาทเทียมสามารถให้ผลการพยากรณ์ที่สอดคล้องกับค่าอัตราการแลกเปลี่ยนสกุลเงินดอลลาร์สิงคโปร์ร้อยละ 89

การพยากรณ์อัตราแลกเปลี่ยนสกุลเงินเยนของประเทศญี่ปุ่น แสดงในรูปแบบที่ 5 และการพิจารณาประสิทธิภาพของตัวแบบพยากรณ์แสดงในตารางที่ 3

Table 2 The summary of all forecasting models based on Singapore Dollar.

Model	MAE	RMSE	MAPE	RMSPE	R-squared
SES	0.163	0.186	0.64 %	0.73 %	0.88
HW (Additive)	0.259	0.314	1.03 %	1.24 %	0.75
HW (Multiplicative)	0.314	0.374	1.24 %	1.47 %	0.71
ARIMA	0.174	0.217	0.68 %	1.14 %	0.76
ARFIMA	0.153	0.207	0.60 %	0.81 %	0.84
ANN (2,20)	0.144	0.174	0.57 %	0.68 %	0.89

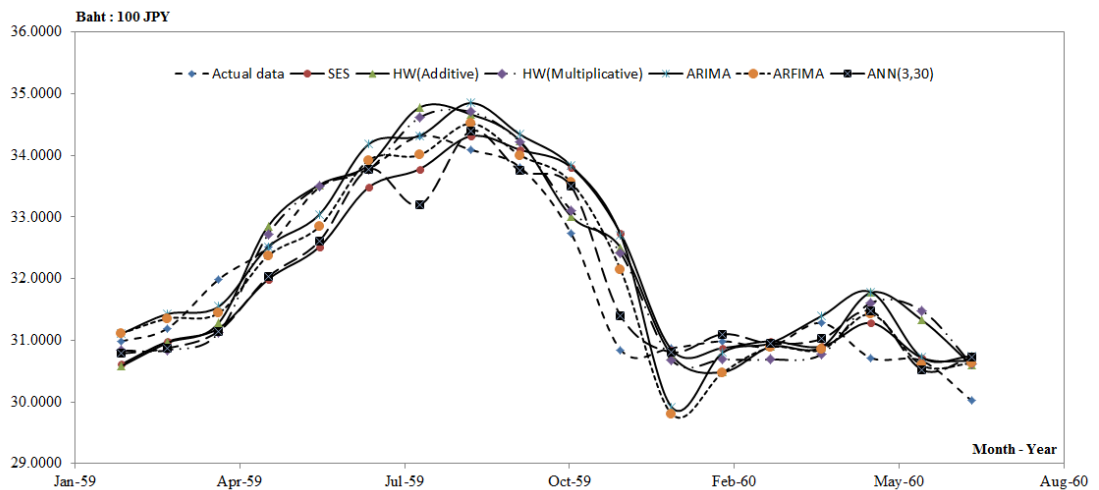


Figure 5 Forecast data of exchange rate for Japanese Yen.

Table 3 The summary of all forecasting models based on Japanese Yen.

Model	MAE	RMSE	MAPE	RMSPE	R-squared
SES	0.502	0.672	1.57 %	2.12 %	0.77
HW (Additive)	0.472	0.610	1.50 %	1.95 %	0.85
HW (Multiplicative)	0.466	0.597	1.48 %	1.91 %	0.85
ARIMA	0.503	0.698	1.59 %	2.22 %	0.81
ARFIMA	0.457	0.575	1.44 %	1.83 %	0.84
ANN (3,30)	0.423	0.540	1.32 %	1.67 %	0.85

แนวโน้มของการพยากรณ์ของตัวแบบพยากรณ์ต่าง ๆ ในการพยากรณ์ข้อมูลอนุกรมเวลาของอัตราแลกเปลี่ยนสกุลเงินเยนประเทศญี่ปุ่นในรูปที่ 5 พบว่าตัวแบบพยากรณ์ทั้งหมดให้ผลการพยากรณ์ที่สอดคล้องกับอัตราการแลกเปลี่ยนสกุลเงินเยนของประเทศญี่ปุ่น โดยเมื่อพิจารณาค่าประสิทธิภาพของตัวแบบพยากรณ์ต่าง ๆ ตารางที่ 3 พบว่าตัวแบบอาร์ฟิม่า (ARFIMA) เป็นตัวแบบที่ให้ค่าเฉลี่ยของความผิดพลาดน้อยที่สุดในกลุ่มของตัวแบบพยากรณ์ทางสถิติ ซึ่งสามารถลดค่าเฉลี่ยของความผิดพลาดค่อนข้างมากเมื่อเปรียบเทียบกับตัวแบบอาร์มีนา (ARIMA) จึงสามารถ

กล่าวว่าการเลือกใช้ตัวแบบอาร์มีนาที่มีผลต่างเป็นจำนวนเต็มอาจให้ค่าความผิดพลาดค่อนข้างมากเมื่อเปรียบเทียบกับค่าจริง ถึงแม้ว่าตัวแบบอาร์ฟิม่าจะให้ค่าเฉลี่ยของความผิดพลาดที่น้อย แต่ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (ANN(3,30)) กลับให้ค่าเฉลี่ยของความผิดพลาดที่น้อยที่สุดเมื่อเปรียบเทียบกับตัวแบบพยากรณ์ทั้งหมดและให้ค่าพยากรณ์ที่สอดคล้องกับอัตราการแลกเปลี่ยนสกุลเงินเยนของประเทศญี่ปุ่นได้ร้อยละ 85

5. สรุปผลการวิจัย

ผลการวิเคราะห์ประสิทธิภาพของตัวแบบพยากรณ์ทั้งหมด ตัวแบบพยากรณ์ทางสถิติทั้ง 4 ตัวแบบ ยกเว้นตัวแบบอาพีมา ให้ผลการพยากรณ์ที่ดีในแต่ละสถานการณ์ที่แตกต่างกัน โดยไม่มีตัวแบบใดที่มีประสิทธิภาพดีในทุกสถานการณ์ แต่ตัวแบบอาพีมาจะมีประสิทธิภาพดีกว่าตัวแบบพยากรณ์ทางสถิติ 2 ใน 3 ชุดข้อมูล สำหรับตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าซึ่งเป็นตัวแบบพยากรณ์ไม่เป็นเชิงเส้นตรงพบว่าให้ประสิทธิภาพในการพยากรณ์ดีในทุกสถานการณ์ จึงสามารถกล่าวได้ว่าข้อมูลอนุกรมเวลาของอัตราการแลกเปลี่ยนสกุลเงินทั้ง 3 สกุลเงิน มีลักษณะความสัมพันธ์ไม่เป็นเชิงเส้นตรงเด่นชัดกว่าความสัมพันธ์ที่เป็นเชิงเส้นตรง รวมทั้งโครงสร้างของตัวแบบโครงข่ายประสาทเทียมสามารถแปลงข้อมูลป้อนเข้าให้อยู่ในปริภูมิใหม่ที่มีความซับซ้อนเพิ่มมากยิ่งขึ้น เพื่อให้สามารถอธิบายลักษณะของข้อมูลอนุกรมเวลาอย่างดียิ่งขึ้น กล่าวคือ ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าสามารถใช้เป็นเครื่องมือสำหรับการพยากรณ์อัตราการแลกเปลี่ยนสกุลเงินทั้ง 3 เพื่อสนับสนุนการตัดสินใจและกำหนดกลยุทธ์ทางการค้าระหว่างประเทศได้

6. References

- [1] Department of Trade Negotiations, Annual Report, Available Source: http://www.dtn.go.th/images/297/Trade/TRADE_2559.pdf, 12 September 2017.
- [2] Rangakulnuwat, P., 2008, Application of vector error correction model in forecasting exchange rates, *Appl. Econ. J.* 15(2): 19-31. (in Thai)
- [3] Rout, M., Majhi, B., Majhi, R. and Panda, G., 2014, Forecasting of currency exchange rates using an adaptive ARMA model with differential evolution based training, *J. King Saud Univ. Comp. Inform. Sci.* 26: 7-18.
- [4] Uyen Ngan, T.M., 2016, Forecasting foreign exchange rate by using ARIMA model: A case of VND/USD exchange rate, *Res. J. Finance Account.* 7(12): 38-44.
- [5] Babu, A.S. and Reddy, S.K., 2015, Exchange rate forecasting using ARIMA, neural network and fuzzy neuron, *J. Stock Forex Trading* 4(3): 1-5.
- [6] Adebisi, A.A., Adewumi, A.O. and Ayo, C.K., 2014, Comparison of ARIMA and artificial neural networks models for stock price prediction, *J. Appl. Math.* 2014: 1-7.
- [7] Maria, F.C. and Eva, D., 2011, Exchange-Rates Forecasting: Exponential smoothing techniques and ARIMA models, *Ann. Fac. Econ.* 1: 499-508.
- [8] Liu, B.X., Wu, Y. and Cheng, X., 2013, RMB exchange rate forecasting model based on exponential smoothing and gray correlation, *Appl. Mech. Mater.* 401: 1480-1483.
- [9] Yoon, G., 2010, Do real exchange rates really follow threshold autoregressive or exponential smooth transition autoregressive models?, *Econ. Model.* 27: 605-612.
- [10] Lawton, R., 1998, How should additive Holt-Winters estimates be corrected?, *Int. J. Forecast.* 14: 393-403.

- [11] Yildiran, C.U. and Fettahoğlu, A., 2017, Forecasting USDTRY rate by ARIMA method, Cogent Econ. Finance 5: 1-11.
- [12] Nwankwo, S.C., 2014, Autoregressive integrated moving average (ARIMA) model for exchange rate (Naira to Dollar), Acad. J. Interdiscip. Stud. 3: 429-433.
- [13] Omekara, C.O., Okereke, O.E. and Ehighibe, S.E., 2016, Time series analysis of interest rate in Nigeria: A comparison of ARIMA and state space models, Int. J. Prob. Stat. 5: 33-47.
- [14] Shittu O.I. and Yaya, O.S., 2009, Measuring forecast performance of ARMA & ARFIMA models: An application to US Dollar/UK pound foreign exchange rate. Eur. J. Sci. Res. 32: 167-176.
- [15] Xiu, J. and Jin, Y., 2007, Empirical study of ARFIMA model based on fractional differencing, Phys. A Stat. Mech. Appl. 377: 138-154.
- [16] Bhardwaj, G. and Swanson, N.R., 2006, An empirical investigation of the usefulness of ARFIMA models for predicting macroeconomic and financial time series, J. Econ. 131: 539-578.
- [17] Sadaei, H.J., Enayatifar, R., Guimarães, F.G., Mahmud, M. and Alzamil, Z. A. , 2016, Combining ARFIMA models and fuzzy time series for the forecast of long memory time series, Neurocomputing 175: 782-796.
- [18] Singh, R.B., Gould, J., Chan, F. and Yang, J.W., 2016. Liquidation discount: A novel application of ARFIMA-GARCH, J. Emp. Finance 36: 151-161.
- [19] Panda, C. and Narasimhan, V. , 2007, Forecasting exchange rate better with artificial neural network, J. Pol. Model. 29: 227-236.
- [20] Rehman, M., Khan, G.M. and Mahmud, S. A. , 2014, Foreign currency exchange rates prediction using cgp and recurrent neural network, IERI Proc. 10: 239-244.
- [21] Yu, L., Wang, S. and Lai, K.K., 2005, A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates, Comp. Operations Res. 32: 2523-2541.
- [22] Moghaddam, A.H., Moghaddam, M.H. and Esfandyari, M. , 2016, Stock market index prediction using artificial neural network, J. Econ. Finance Admin. Sci. 21: 89-93.
- [23] Majhi, R., Panda, G. and Sahoo, G., 2009, Efficient prediction of exchange rates with low complexity artificial neural network models, Exp. Syst. Appl. 36: 181-189.
- [24] Thakur, G.S.M., Bhattacharyya, R. and Mondal, S.S., 2016, Artificial neural network based model for forecasting of inflation in India, Fuzzy Inform. Eng. 8: 87-100.
- [25] Aydin, A. D. and Cavdar, S. C. , 2015, Comparison of prediction performances of artificial neural network (ANN) and vector autoregressive (VAR) Models by using the macroeconomic variables of gold prices, Borsa Istanbul (BIST) 100 index

- and US Dollar- Turkish Lira (USD/ TRY) exchange rates, Proc. Econ. Finance 30: 3-14.
- [26] Bank of Thailand, Rates of Exchange of Commercial Banks, Available Source: <http://www2.bot.or.th/statistics/ReportPage.aspx?reportID=123&language=th>, 12 September 2017.
- [27] Khandakar, Y. and Hyndman, R. J., 2008, Automatic time series forecasting: the forecast Package for R, J. Stat. Software 27(3): 1-22.
- [28] Muller, J. and Bogenberger, K., 2015, Time series analysis of booking data of a free-floating carsharing system in Berlin, Transport. Res. Proc. 10: 345-354.
- [29] Kocic, P., Crimp, S. and Howden, M., 2014, A probabilistic analysis of human influence on recent record global mean temperature changes, Climate Risk Manag. 3: 1-12.
- [30] Ghodhi, Z., Silva, S.E. and Hassani, H., 2015, Bicoid signal extraction with a selection of parametric and nonparametric signal processing techniques, Genom. Proteom. Bioinform. 13: 183-191.
- [31] Sujjaviriyasup, T., 2018, Artificial neural network model for forecasting monthly price of maize in Thailand, Srinakharinwirot Sci. J. 34(1): 91-107. (in Thai)
- [32] Giam, X. and Olden, J.D., 2015, A new R2-based metric to shed greater insight on variable importance in artificial neural networks, Ecol. Model. 313: 307-313.
- [33] Montoye, A.H., Pivarnik, J.M., Mudd, L.M., Biswas, S. and Pfeiffer, K. A., 2017, Evaluation of the activPAL accelerometer for physical activity and energy expenditure estimation in a semi-structured setting, J. Sci. Med. Sport 20: 1003-1007.
- [34] Allard, M.A., Baillié, G., Castro-Benitez, C., Faron, M., Blandin, F., Cherqui, D., Castaing, D., Cunha, A.S., Adam, R. and Vibert, É., 2017, Prediction of the total liver weight using anthropological clinical parameters: Does complexity result in better accuracy?, HPB 19: 338-344.
- [35] Collell, G., Prelec, D. and Patil, K.R., 2018, A simple plug-in bagging ensemble based on threshold-moving for classifying binary and multiclass imbalanced data, Neurocomputing 275: 330-340.
- [36] Schmidt, K., Walz, A., Martín-López, B. and Sachse, R., 2017, Testing socio-cultural valuation methods of ecosystem services to explain land use preferences, Ecosyst. Serv. 26: 270-288.