

การเปรียบเทียบความแม่นยำของการพยากรณ์ ด้วยตัวแบบอนุกรมเวลาแบบผสม

A Comparative Prediction Accuracy of Hybrid Time Series Models

ชยานิน บุญมานะ และนัท กุลวานิช*

ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

แขวงวังใหม่ เขตปทุมวัน กรุงเทพมหานคร 10330

Chayanin Boonmana and Nat Kulvanich*

Department of Statistics, Faculty of Commerce and Accountancy, Chulalongkorn University,

Wangmai, Pathumwan, Bangkok 10330

บทคัดย่อ

การวิจัยนี้ศึกษาเปรียบเทียบความแม่นยำของค่าพยากรณ์ที่ได้จากตัวแบบ ARIMA ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ทเวกเตอร์แมชชีน ในการพยากรณ์ราคาปิดหุ้น SCB ของธนาคารไทยพาณิชย์ จำกัด (มหาชน) โดยใช้ชุดข้อมูลจริงและชุดข้อมูลอนุกรมเวลาที่จำลองด้วยตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(0,1,2) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,1) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) ตัวแบบ ARIMA(2,1,1) และตัวแบบ ARIMA(2,1,2) เมื่อใช้เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (root mean square error, RMSE) เป็นเครื่องมือในการเปรียบเทียบตัวแบบ โดยตัวแบบใดที่มีค่า RMSE ต่ำสุดจะเป็นตัวแบบที่ดีที่สุด จากการศึกษพบว่าตัวแบบผสมระหว่าง ARIMA และซัพพอร์ทเวกเตอร์แมชชีน มีความแม่นยำในการพยากรณ์สูงที่สุดสำหรับการพยากรณ์ในชุดข้อมูลอนุกรมเวลาที่จำลองด้วยตัวแบบ ARIMA(0,1,2) ตัวแบบ ARIMA(1,1,1) และตัวแบบ ARIMA(2,1,2) ส่วนตัวแบบผสมระหว่าง ARIMA และเครือข่ายประสาทเทียมนั้นให้ความแม่นยำในการพยากรณ์สูงที่สุดสำหรับการพยากรณ์ในชุดข้อมูลอนุกรมเวลาในกรณีที่จำลองด้วยตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) และตัวแบบ ARIMA(2,1,1) และสำหรับการพยากรณ์ในชุดข้อมูลจริงของราคาปิดหุ้นรายสัปดาห์ของ SCB ที่มีลักษณะอนุกรมเวลาสอดคล้องกับตัวแบบ ARIMA(1,1,1) ผลการศึกษาพบว่าตัวแบบผสมระหว่าง ARIMA และซัพพอร์ทเวกเตอร์แมชชีนมีความแม่นยำในการพยากรณ์สูงที่สุด ซึ่งสอดคล้องกับผลจากชุดข้อมูลจำลอง

คำสำคัญ : ตัวแบบ ARIMA; ตัวแบบเครือข่ายประสาทเทียม; ตัวแบบซัพพอร์ทเวกเตอร์แมชชีน; ตัวแบบผสม

*ผู้รับผิดชอบบทความ : nat@cbs.chula.ac.th

Abstract

This research is aimed to compare the prediction accuracy between three time series models, traditional ARIMA model, a hybrid model combining ARIMA and artificial neural network model, and a hybrid model combining ARIMA and support vector machine model by using real stock price datasets of the Siam Commercial Bank (SCB) and time series datasets simulated from ARIMA(0,1,1), ARIMA(0,1,2), ARIMA(1,1,0), ARIMA(1,1,1), ARIMA(1,1,2), ARIMA(2,1,0), ARIMA(2,1,1) and ARIMA(2,1,2). Root mean square error (RMSE) is used to compare the prediction accuracy from each model. The model which has the lowest RMSE is the best model. The results suggest that a hybrid ARIMA and support vector machine model has the highest prediction accuracy for the case of ARIMA(0,1,2), ARIMA(1,1,1) and ARIMA(2,1,2) model. However, the prediction accuracy of a hybrid ARIMA and artificial neural network model is found to be highest in the case of ARIMA(0,1,1), ARIMA(1,1,0), ARIMA(1,1,2), ARIMA(2,1,0) and ARIMA(2,1,1) model. Similar forecasting models were developed and evaluated for the weekly closing price of stock price of the Siam Commercial Bank. The results suggest that a hybrid ARIMA(1,1,1) and support vector machine model has the highest prediction accuracy. We observed concordant results on both real and simulated data.

Keywords: ARIMA model; artificial neural network model; support vector machine model; hybrid model

1. บทนำ

ภายใต้สภาพเศรษฐกิจและสังคมในปัจจุบันที่มีความซับซ้อนประกอบกับการเปลี่ยนแปลงอย่างรวดเร็ว นักลงทุนต่างต้องคำนึงถึงผลประโยชน์และความสูญเสียที่อาจเกิดขึ้นจากการตัดสินใจนำสินทรัพย์ที่ตนมีอยู่ไปลงทุน เช่น การซื้อขายหุ้นในตลาดหลักทรัพย์ แม้จะเป็นทางเลือกในการลงทุนที่มีโอกาสได้รับผลตอบแทนสูง แต่ก็มีความเสี่ยงสูงกว่าการลงทุนในรูปแบบอื่น ๆ นักลงทุนจึงต้องมีการวางแผนหรือการตัดสินใจที่ถูกต้องและเป็นระบบเพื่อให้เกิดประโยชน์สูงสุดแก่ตนเองทั้งในระยะสั้นและระยะยาว นอกจากนักลงทุนสามารถใช้ความรู้ ประสบการณ์ และวิจารณญาณของตนเองในการคาดคะเนหรือทำนายราคาปิดหุ้นล่วงหน้าได้ แต่การใช้ข้อมูลราคาปิดหุ้นในอดีตมาพยากรณ์ราคาปิดหุ้นในอนาคตอาจช่วยลดความเสี่ยง

เนื่องจากความไม่แน่นอนของเหตุการณ์ที่จะเกิดขึ้นในอนาคตได้ ด้วยเหตุนี้จึงจำเป็นต้องหาวิธีการทางสถิติที่มีประสิทธิภาพในการพยากรณ์ เพื่อให้ค่าพยากรณ์ที่ได้มีความแม่นยำและมีค่าคลาดเคลื่อนจากการพยากรณ์น้อยที่สุด ซึ่งจะทำให้การลงทุนเกิดความมั่นใจต่อค่าพยากรณ์ที่ได้และนำไปใช้ในการวางแผนและการตัดสินใจ

การวิเคราะห์อนุกรมเวลา (time series analysis) เป็นวิธีการทางสถิติวิธีหนึ่งที่มีการนำข้อมูลในอดีตที่เก็บรวบรวมตามลำดับเวลาอย่างต่อเนื่องมาศึกษาหารูปแบบการเคลื่อนไหวของข้อมูล ด้วยการสร้างสมการหรือตัวแบบเชิงคณิตศาสตร์แทนลักษณะการเคลื่อนไหวดังกล่าว สำหรับพยากรณ์ข้อมูลในอนาคต [1] ซึ่งมีงานวิจัยมากมายที่พยายามศึกษาและพัฒนาตัวแบบอนุกรมเวลา เช่น ปี ค.ศ. 1970 ได้มีการ

นำเสนอตัวแบบ ARIMA หรือรู้จักกันดีในชื่อตัวแบบของ Box และ Jenkins [2,3] มาใช้อธิบายลักษณะการเคลื่อนไหวของอนุกรมเวลาเมื่อข้อมูลมีสหสัมพันธ์กันในตัวและเป็นแบบคงที่ (stationary time series) พบว่า ตัวแบบนี้จะให้ค่าพยากรณ์ที่มีความถูกต้องสูงกว่าค่าพยากรณ์ที่ได้จากวิธีการพยากรณ์ด้วยตัวแบบอื่น ๆ ในการพยากรณ์ระยะสั้น ซึ่งเป็นตัวแบบที่เหมาะสมสำหรับใช้พยากรณ์ข้อมูลอนุกรมเวลาที่เป็นแบบคงที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ และไม่มีแนวโน้ม (trend) แต่ข้อมูลอนุกรมเวลาส่วนใหญ่ลักษณะความสัมพันธ์ดังกล่าวมักไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ ในปี ค.ศ. 1991 จึงได้มีการนำเสนอตัวแบบเครือข่ายประสาทเทียม (artificial neural network model: ANN) ขึ้น [4,5] เพื่อใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา เป็นตัวแบบที่มีความแม่นยำสูง มีความแข็งแกร่ง (robust) เมื่อมีค่านอกเกณฑ์ (outlier) สามารถเรียนรู้ที่จะทำงานในชุดข้อมูลที่มีค่าคลาดเคลื่อนได้ดี ส่วนใหญ่ใช้ในการพยากรณ์ข้อมูลที่มีความซับซ้อน โดยเฉพาะข้อมูลอนุกรมเวลาในส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ รวมทั้งเป็นตัวแบบที่ง่ายต่อการใช้งานเนื่องจากไม่จำเป็นต้องมีเงื่อนไข (assumptions) ในการสร้างตัวแบบ ต่อมาในปี ค.ศ. 1995 ได้มีการพัฒนาตัวแบบใหม่ขึ้นคือ ตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (support vector machine model, SVM) [6,7] เป็นตัวแบบที่ให้ผลการพยากรณ์ที่ดี มีความแม่นยำสูง สำหรับใช้พยากรณ์ข้อมูลอนุกรมเวลาที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์โดยมีแนวคิดเดียวกับตัวแบบเครือข่ายประสาทเทียมแต่ต่างกันตรงที่กระบวนการลดความเสี่ยงให้มีค่าต่ำที่สุด (risk minimization) กล่าวคือ ตัวแบบซัพพอร์ทเวกเตอร์แมชชีนจะใช้กระบวนการลดความเสี่ยงเชิงโครงสร้างให้มีค่าต่ำที่สุด (structural risk minimi-

zation, SRM) ส่วนตัวแบบเครือข่ายประสาทเทียมจะใช้กระบวนการลดความเสี่ยงเชิงการทดลองให้มีค่าต่ำที่สุด (empirical risk minimization, ERM) แต่ข้อมูลอนุกรมเวลาทางธุรกิจส่วนใหญ่ โดยเฉพาะราคาปิดหุ้นในตลาดหลักทรัพย์มักมีโครงสร้างทั้งส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์และไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ ดังนั้นตัวแบบ ARIMA ตัวแบบเครือข่ายประสาทเทียม หรือตัวแบบซัพพอร์ทเวกเตอร์แมชชีนเพียงตัวแบบเดียวอาจไม่สามารถอธิบายลักษณะของข้อมูลอนุกรมเวลาเหล่านั้นได้อย่างถูกต้องและมีความแม่นยำมากนัก

ตัวแบบผสม (hybrid model) [8] พัฒนาขึ้นมาในปี ค.ศ. 2003 สำหรับแก้ปัญหาดังกล่าว เป็นตัวแบบที่ได้รับความนิยมในการพยากรณ์ข้อมูลอนุกรมเวลาทางธุรกิจ โดยการนำตัวแบบที่ใช้สำหรับพยากรณ์ข้อมูลอนุกรมเวลาในส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ คือ ตัวแบบ ARIMA มารวมกับตัวแบบที่ใช้สำหรับพยากรณ์ข้อมูลในส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ คือ ตัวแบบเครือข่ายประสาทเทียม และตัวแบบซัพพอร์ทเวกเตอร์แมชชีนเพื่อทำให้การพยากรณ์มีความถูกต้องและมีความแม่นยำมากยิ่งขึ้น

พงษ์ศิริ และคณะ [9] ได้พยากรณ์อนุกรมเวลาด้วยตัวแบบผสม ARIMA และเครือข่ายประสาทเทียม โดยใช้ข้อมูลราคาปิดหุ้น PTT และใช้เกณฑ์ในการเปรียบเทียบความแม่นยำของตัวแบบ 3 เกณฑ์ ได้แก่ ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (mean square error, MSE) ค่าคลาดเคลื่อนสมบูรณ์เฉลี่ย (mean absolute error, MAE) และเปอร์เซ็นต์ค่าคลาดเคลื่อนสมบูรณ์เฉลี่ย (mean absolute percentage error, MAPE) สรุปได้ว่าสำหรับการพยากรณ์ระยะยาว (30 วัน) ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียมมีความแม่นยำในการพยากรณ์สูงกว่าการใช้ตัวแบบ

ARIMA เพียงตัวแบบเดียว นอกจากนี้ Zhang และคณะ [10] ได้พยากรณ์ราคาปิดหุ้นในตลาดหลักทรัพย์ด้วย ตัวแบบผสม ARMA และซัพพอร์ตเวกเตอร์แมชชีน โดยใช้ข้อมูลราคาปิดหุ้น S&P500 และ Nikkei225 และใช้เกณฑ์ในการเปรียบเทียบความแม่นยำของตัวแบบ 4 เกณฑ์ ได้แก่ ค่าคลาดเคลื่อนกำลังสองเฉลี่ย รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (root mean square error, RMSE) ค่าคลาดเคลื่อนสมบูรณ์เฉลี่ย และเปอร์เซ็นต์ค่าคลาดเคลื่อนสมบูรณ์เฉลี่ย สรุปได้ว่า ตัวแบบผสมระหว่าง ARMA กับซัพพอร์ตเวกเตอร์แมชชีนมีความแม่นยำในการพยากรณ์สูงกว่าการใช้ตัวแบบซัพพอร์ตเวกเตอร์เพียงตัวแบบเดียว

ภัทร [11] ได้เปรียบเทียบความแม่นยำของการพยากรณ์อนุกรมเวลาระหว่างตัวแบบผสมและตัวแบบเดียว โดยเปรียบเทียบตัวแบบ ARIMA ตัวแบบเครือข่ายประสาทเทียม ตัวแบบซัพพอร์ตเวกเตอร์แมชชีน ตัวแบบผสมระหว่างตัวแบบ ARIMA กับตัวแบบเครือข่ายประสาทเทียม ตัวแบบผสมระหว่างตัวแบบ ARIMA กับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน และตัวแบบ hybrid combined โดยใช้ข้อมูล The British pound/US dollar exchange rate และใช้เกณฑ์ในการเปรียบเทียบความแม่นยำของตัวแบบ 4 เกณฑ์ ได้แก่ ค่าคลาดเคลื่อนกำลังสองเฉลี่ย รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย ค่าคลาดเคลื่อนสมบูรณ์เฉลี่ย และเปอร์เซ็นต์ค่าคลาดเคลื่อนสมบูรณ์เฉลี่ย สรุปได้ว่า ตัวแบบผสมไม่ได้มีความแม่นยำในการพยากรณ์สูงกว่าตัวแบบเดียวเสมอไป

การศึกษานี้ผู้วิจัยสนใจที่จะศึกษาและเปรียบเทียบความแม่นยำของค่าพยากรณ์ที่ได้จากตัวแบบ ARIMA ตัวแบบผสมระหว่างตัวแบบ ARIMA กับ

ตัวแบบเครือข่ายประสาทเทียม และตัวแบบผสมระหว่างตัวแบบ ARIMA กับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน โดยใช้ชุดข้อมูลจริงของราคาปิดหุ้น SCB และชุดข้อมูลอนุกรมเวลาที่จำลองด้วยตัวแบบ ARIMA (0,1,0) ตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(0,1,2) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,1) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) ตัวแบบ ARIMA(2,1,1) และตัวแบบ ARIMA(2,1,2) เมื่อใช้เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย เป็นเครื่องมือในการเปรียบเทียบตัวแบบ โดยตัวแบบใดที่มีค่า RMSE ต่ำสุด จะเป็นตัวแบบที่ให้ผลดีที่สุด

2. วิธีการวิจัย

2.1 ศึกษาตัวแบบและทฤษฎีที่เกี่ยวข้อง

2.1.1 ตัวแบบ integrated autoregressive moving average หรือตัวแบบ ARIMA

ตัวแบบ ARIMA พัฒนาขึ้นโดย Box และ Jenkins ในปี ค.ศ. 1970 เป็นวิธีการพยากรณ์ที่นำข้อมูลอนุกรมเวลาในอดีตที่เก็บรวบรวมตามลำดับเวลาอย่างต่อเนื่องมาหาตัวแบบที่เหมาะสม และนำตัวแบบที่ได้มาพยากรณ์ข้อมูลอนุกรมเวลาในอนาคต โดยข้อมูลอนุกรมเวลาที่น่าวิเคราะห์นั้นต้องเป็นแบบคงที่ (stationary) และไม่มีแนวโน้ม

ตัวแบบ ARIMA(p,d,q) คือ ตัวแบบ ARMA(p,q) ที่มีการหาผลต่าง (differencing) อันดับ d เพื่อแปลงข้อมูลอนุกรมเวลาแบบไม่คงที่ (nonstationary time series) ให้เป็นข้อมูลอนุกรมเวลาแบบคงที่ ซึ่งสามารถเขียนในรูปสมการ ได้ดังนี้

$$\phi(B)(1-B)^d x_t = \theta(B)w_t \quad (1)$$

หรือสามารถเขียนสมการที่ (1) ได้เป็น

$$(1-\phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1-B)^d x_t = (1-\theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)w_t \quad (2)$$

เมื่อ $\{x_t; t = 0, \pm 1, \pm 2, \dots\}$ คือ ข้อมูลอนุกรมเวลาแบบคงที่; $\phi_1, \phi_2, \dots, \phi_p$ คือ ค่าคงที่แสดงอันดับของกระบวนการ

autoregressive โดยที่ $\phi_p \neq 0$; $\theta_1, \theta_2, \dots, \theta_q$ คือ ค่าคงที่แสดงอันดับของกระบวนการ moving average โดยที่ $\theta_q \neq 0$; w_t คือ Gaussian white noise ที่มีค่าเฉลี่ยเป็น 0 และความแปรปรวน σ_w^2

2.1.2 ตัวแบบเครือข่ายประสาทเทียม

ตัวแบบเครือข่ายประสาทเทียม เป็นตัวแบบที่คิดค้นขึ้นในปี ค.ศ. 1991 โดย Mc Culloch และ Pitts เพื่อลอกเลียนแบบความสามารถของสมองมนุษย์ กล่าวคือ มีความสามารถในการรวบรวมความรู้ โดยผ่านกระบวนการเรียนรู้ และความรู้เหล่านี้จะถูกจัดเก็บอยู่ในเครือข่ายในรูปแบบค่าถ่วงน้ำหนัก (weight) ซึ่งสามารถปรับเปลี่ยนค่าได้เมื่อมีการเรียนรู้สิ่งใหม่ ๆ เข้าไป โดยการประมวลผลต่าง ๆ ของเครือข่ายประสาทเทียมเกิดขึ้นในหน่วยประมวลผลย่อย เรียกว่า โหนด (node) ซึ่งจำลองมาจากการเชื่อมต่อของเดนไดรต์และแอกซอนในระบบประสาทของมนุษย์ ภายในโหนดจะมีฟังก์ชันกำหนดสัญญาณส่งออกที่เรียกว่า ฟังก์ชันกระตุ้น (activation function) ซึ่งทำหน้าที่เปรียบเสมือนกระบวนการทำงานในเซลล์

เครือข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้า (feedforward artificial neural network) เป็นเครือข่ายประสาทเทียมที่ประกอบด้วยชั้นต่าง ๆ โดยชั้นแรกจะเป็นชั้นข้อมูลนำเข้า (input layer) และชั้นสุดท้ายเป็นชั้นผลลัพธ์ (output layer) ส่วนระหว่างชั้นข้อมูลนำเข้ากับชั้นผลลัพธ์อาจมีหรือไม่มีชั้นซ่อน (hidden layer) อยู่ภายในก็ได้ซึ่งขึ้นกับกฎการเรียนรู้ที่ใช้ในการสอนเครือข่ายประสาทเทียม โดยการเชื่อมต่อระหว่างชั้นของเครือข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้าจะมีค่าถ่วงน้ำหนักเป็นตัวเชื่อม และสัญญาณนำเข้าที่เข้ามาจะถูกส่งไปตามทิศทางของลูกศรที่มีการจำกัดทิศทางการเคลื่อนที่เป็นแบบทางเดียวหรือเคลื่อนที่ไปข้างหน้า โดยเครือข่ายมีการเชื่อมต่อกันอย่างสมบูรณ์ นั่นคือ ที่โหนดทุกโหนด

ในชั้นที่กำหนดเชื่อมต่อกันทุกโหนดกับชั้นถัดไปจนถึงชั้นผลลัพธ์โดยไม่มีการย้อนกลับ

กำหนดเวกเตอร์ $\tilde{x} = (x_1, x_2, \dots, x_n)$

เป็นชุดข้อมูลในชั้นข้อมูลนำเข้า สำหรับการสร้างตัวแบบเครือข่ายประสาทเทียมกรณีที่กำหนดชั้นข้อมูลนำเข้า 1 ชั้น ภายใต้จำนวนโหนด 1 โหนด ชั้นซ่อน 1 ชั้นภายใต้จำนวนโหนด 5 โหนด โดยใช้ sigmoid logistic function เป็นฟังก์ชันกระตุ้น และชั้นผลลัพธ์ 1 ชั้น ภายใต้จำนวนโหนด 1 โหนด โดยใช้ linear function เป็นฟังก์ชันกระตุ้น แต่ละโหนดที่อยู่ในชั้นซ่อนและชั้นผลลัพธ์ จะประกอบไปด้วย 2 ขั้นตอน คือ

พิจารณาโหนดที่อยู่ในชั้นซ่อน

ขั้นตอนที่ 1 : คำนวณค่าผลรวมของโหนดในชั้นซ่อน โดยใช้ฟังก์ชันการรวมกัน (combination function) ซึ่งเป็นการนำค่าของโหนดข้อมูลนำเข้าที่เชื่อมโยงมาคูณกับค่าถ่วงน้ำหนักในแต่ละเส้นเชื่อมโยง ดังนั้นค่าผลรวมของโหนดที่ j ในชั้นซ่อน คือ $net_j = w_{1j}x_1 + bias$ สำหรับ $j=1,2,\dots,5$ (3)

ขั้นตอนที่ 2 : ปรับค่าผลรวมของข้อมูลในชั้นซ่อนด้วยฟังก์ชันกระตุ้น โดยใช้ sigmoid logistic function เพื่อให้ได้ผลลัพธ์ (y_j) ของชั้นซ่อน โดยที่

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

พิจารณาโหนดที่อยู่ในชั้นผลลัพธ์

ขั้นตอนที่ 1 : คำนวณค่าผลรวมของโหนดในชั้นผลลัพธ์ โดยใช้ฟังก์ชันการรวมกัน ดังนั้นค่าผลรวมของโหนดที่ k ในชั้นผลลัพธ์ คือ

$$net_k = \sum_{j=1}^5 w_{jk}y_j = w_{1k}y_1 + w_{2k}y_2 + \dots + w_{5k}y_5 + bias$$

สำหรับ $k = 1$ (5)

ขั้นตอนที่ 2 : ปรับค่าผลรวมของข้อมูลในชั้นผลลัพธ์ด้วยฟังก์ชันกระตุ้น โดยใช้ linear function เพื่อให้ได้ผลลัพธ์ (y_k) ของชั้นผลลัพธ์ โดยที่ $y_k = f(net_k) = net_k$ (6)

2.1.3 ตัวแบบซัพพอร์ทเวกเตอร์แมชชีนสำหรับการถดถอย (support vector machine for regression)

ตัวแบบซัพพอร์ทเวกเตอร์แมชชีนสำหรับการถดถอย พัฒนาขึ้นในปี ค.ศ. 1995 โดย Vapnik เป็นตัวแบบที่มีการใช้กระบวนการลดความเสี่ยงเชิงโครงสร้างให้มีค่าต่ำที่สุด ด้วยกระบวนการปรับรูปแบบข้อมูลจากข้อมูลที่มีมิติต่ำ (low dimension dataset) บนพื้นที่ข้อมูลนำเข้า (input space) ให้อยู่ในรูปแบบของข้อมูลที่มีมิติสูง (high dimension dataset) บนพื้นที่ข้อมูลคุณลักษณะ (feature space) โดยใช้ฟังก์ชันในการปรับรูปแบบข้อมูลเรียกว่าฟังก์ชันเคอร์เนล (kernel function)

กำหนดข้อมูลนำเข้าอยู่ในรูปเวกเตอร์ $D = \{(x_1, y_1), \dots, (x_l, y_l)\}$ เมื่อ $x \in R^n, y \in R$

$$\text{Minimize } \Phi(w, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^l \xi_i + \sum_{i=1}^l \xi_i^* \right) \quad (9)$$

Subject to $y_i [\langle w, x_i \rangle + b] \geq 1 - \xi_i, y_i [\langle w, x_i \rangle + b] \geq 1 - \xi_i^*$ และ $\xi_i, \xi_i^* \geq 0$ โดยใช้ตัวคูณลากรองจ์ (lagrange multiplier) มาช่วยในการหาค่าเวกเตอร์ w และ ξ^* ซึ่งทำให้ L มีค่าน้อยที่สุด

$$\text{เมื่อ } L = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^l \xi_i + \sum_{i=1}^l \xi_i^* \right) - \sum_{i=1}^l \alpha_i^* (y_i - \langle w, x_i \rangle - b + \varepsilon + \xi_i) - \sum_{i=1}^l \alpha_i (\langle w, x_i \rangle + b - y_i + \varepsilon + \xi_i) - \sum_{i=1}^l (\beta_i^* \xi_i^* + \beta_i \xi_i) \quad (10)$$

Subject to $\alpha_i, \alpha_i^* \geq 0$ และ $\beta_i, \beta_i^* \geq 0$ สำหรับทุก $i = 1, 2, \dots, l$

หาอนุพันธ์เทียบกับ w, ξ^* และ b และกำหนดให้เท่ากับ 0 จะได้ค่าประมาณพารามิเตอร์ คือ

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i, \alpha_i^* + \beta_i^* = C \text{ และ } \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0$$

แทนค่าประมาณพารามิเตอร์ที่ได้ในสมการที่ (9) และเปลี่ยนรูปแบบของปัญหาเดิม (primal problem) ให้เป็นรูปแบบของปัญหาควบคู่ (dual problem) ได้ดังนี้

สำหรับ $i = 1, 2, \dots, l$ การหาค่าถ่วงน้ำหนักที่เหมาะสมที่สุดสามารถหาได้จากการปรับค่าที่เหมาะสมของฟังก์ชัน $\Phi(w)$ ตามกระบวนการลดความเสี่ยงเชิงโครงสร้างให้มีค่าต่ำที่สุด ซึ่งประกอบไปด้วย 2 ส่วนหลัก คือ การเพิ่มความกว้างของเส้นขอบให้มากที่สุด (maximum margin) และการลดค่าคลาดเคลื่อนด้วยประสบการณ์ (empirical error) ให้มีค่าน้อยที่สุด โดย $\Phi(w) = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^l L_\varepsilon(y_i - f(x_i, w)) \right)$ (7) โดยที่ $L_\varepsilon(y_i - f(x_i, w))$ แทน $\mathcal{E}$ -insensitive loss function

กำหนดให้ ξ_i และ ξ_i^* แทน ตัวแปรที่ทำให้เกิดค่าคลาดเคลื่อน (slack variable) และอยู่ห่างจากระยะขอบเอปซิลอน ($\mathcal{E}$ -tube) ซึ่งสมการที่ (7) ข้างต้นสามารถเขียนใหม่ได้เป็น

$$\Phi(w, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^l \xi_i + \sum_{i=1}^l \xi_i^* \right) \quad (8)$$

สำหรับการหาฟังก์ชันการถดถอยที่เหมาะสมที่สุด (optimal regression function) จะเป็นการหาค่าที่น้อยที่สุดของฟังก์ชันต่อไปนี้

$$\text{Maximize} -\varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l (\alpha_i + \alpha_i^*) y_i - \frac{1}{2} \sum_{j=1}^l \sum_{i=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \quad (11)$$

$$\text{Subject to } 0 \leq \alpha_i, \alpha_i^* \leq C \text{ และ } \sum_{i=1}^l \alpha_i = \sum_{i=1}^l \alpha_i^* \text{ สำหรับทุก } i = 1, 2, \dots, l$$

ดังนั้นสมการการถดถอยที่เหมาะสมสำหรับพยากรณ์ข้อมูลบนไฮเปอร์เพลน คือ

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (12)$$

แทนที่ฟังก์ชันเคอร์เนลลงในตำแหน่งของ $\langle x_i, x \rangle$ ในสมการที่ (12) เพื่อแปลงข้อมูลนำเข้าที่มีลักษณะไม่เป็นเชิงเส้นตรงบนพื้นที่ข้อมูลนำเข้าให้ข้อมูลมีเรียงตัวใหม่ที่มีลักษณะเป็นเชิงเส้นตรงบนพื้นที่คุณลักษณะ ดังนั้นสมการการถดถอยที่เหมาะสมสำหรับพยากรณ์ข้อมูลบนไฮเปอร์เพลน คือ

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (13)$$

2.1.4 ตัวแบบผสม

ตัวแบบผสมคิดค้นขึ้นในปี ค.ศ. 2003 โดย Zhang เป็นการนำตัวแบบที่ใช้สำหรับพยากรณ์ข้อมูลอนุกรมเวลาส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ คือ ตัวแบบ ARIMA มารวมกับตัวแบบที่ใช้สำหรับพยากรณ์ข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ คือ ตัวแบบเครือข่ายประสาทเทียมหรือตัวแบบซัพพอร์ทเวกเตอร์แมชชีน เพื่อทำให้ค่าพยากรณ์ที่ได้มีความถูกต้องและมีความแม่นยำมากยิ่งขึ้น ซึ่งตัวแบบผสมสามารถแสดงได้ด้วยสมการเชิงคณิตศาสตร์ ดังนี้

$$y_t = L_t + N_t + \varepsilon_t \quad (14)$$

เมื่อ y_t แทนค่าสังเกตของข้อมูลอนุกรมเวลา ณ เวลา t ; L_t แทนข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ ณ เวลา t ; N_t แทนข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ ณ เวลา t ; ε_t แทนค่าคลาดเคลื่อน ณ เวลา t

ขั้นตอนการสร้างตัวแบบผสม

ขั้นตอนที่ 1 : วิเคราะห์ข้อมูลอนุกรมเวลาด้วยตัวแบบ ARIMA เพื่อพยากรณ์ข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ คือ $\hat{L}_t$

ขั้นตอนที่ 2 : คำนวณค่าส่วนเหลือ (residuals) จากตัวแบบ ARIMA โดยที่ $\hat{\varepsilon}_t = y_t - \hat{L}_t$

ขั้นตอนที่ 3 : นำค่าส่วนเหลือที่ได้จากตัวแบบ ARIMA ไปพยากรณ์ข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ คือ $\hat{N}_t$ ด้วยตัวแบบเครือข่ายประสาทเทียมหรือตัวแบบซัพพอร์ทเวกเตอร์แมชชีน

ขั้นตอนที่ 4 : คำนวณหาค่าพยากรณ์รวม (total forecasting) จากสมการ $\hat{y}_t = \hat{L}_t + \hat{N}_t$

2.2 จำลองชุดข้อมูลอนุกรมเวลาด้วยตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(0,1,2) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,1) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) ตัวแบบ ARIMA(2,1,1) และตัวแบบ ARIMA(2,1,2) ซึ่งในแต่ละตัวแบบจะจำลองภายใต้สถานการณ์เดียวกันจำนวน 1,000 รอบ โดยในแต่ละรอบของการจำลองจะจำลองชุดข้อมูลอนุกรมเวลาจำนวน 456 สัปดาห์ และแบ่งออกเป็นชุดข้อมูลฝึกสอนจำนวน 319 สัปดาห์ (คิดเป็น 70 %) สำหรับสร้างตัวแบบ และชุดข้อมูลทดสอบจำนวน 137 สัปดาห์ (คิดเป็น 30 %) สำหรับประเมินความถูกต้องของตัวแบบ และคำนวณค่า MSE, RMSE และ MAE ในแต่ละรอบของการจำลอง

2.3 คำนวณค่าเฉลี่ยของ MSE ค่าเฉลี่ยของ RMSE และค่าเฉลี่ยของ MAE จากการจำลองทั้งหมด 1,000 รอบ และคำนวณค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA ในทั้งชุดข้อมูลฝึกสอน

และชุดข้อมูลทดสอบจากการจำลองข้อมูลในแต่ละรอบ

2.4 นำค่าส่วนเหลือได้จากการพยากรณ์ด้วยตัวแบบ ARIMA ในชุดข้อมูลฝึกสอนจากข้อมูลจำลองในแต่ละรอบ มาสร้างตัวแบบเครือข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้า โดยใช้เทคนิคการแพร่แบบย้อนกลับ (back-propagation) เป็นเทคนิคการเรียนรู้เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.01 ซึ่งตัวแบบเครือข่ายประสาทเทียมประกอบด้วยชั้นข้อมูลนำเข้า 1 ชั้นภายใต้จำนวนโหนด 1 โหนด ชั้นซ่อน 1 ชั้น ภายใต้จำนวนโหนด 1 ถึง 5 โหนดโดยใช้ sigmoid logistic function เป็นฟังก์ชันกระตุ้น และชั้นผลลัพธ์ 1 ชั้น ภายใต้จำนวนโหนด 1 โหนด โดยใช้ linear function เป็นฟังก์ชันกระตุ้น เมื่อกำหนดรอบของการทำซ้ำ (iterations) เท่ากับ 100 รอบ

2.5 พิจารณาคัดเลือกตัวแบบเครือข่ายประสาทเทียม โดยตัวแบบที่เหมาะสมกว่า คือ ตัวแบบที่มีค่า RMSE ต่ำกว่า และพยากรณ์ข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ด้วยตัวแบบเครือข่ายประสาทเทียมในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจากข้อมูลจำลองในแต่ละรอบ

2.6 คำนวณค่าพยากรณ์รวม ซึ่งเป็นการรวมข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากตัวแบบ ARIMA และข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากการตัวแบบเครือข่ายประสาทเทียมเข้าด้วยกัน และคำนวณหาค่า MSE, RMSE และ MAE ในแต่ละรอบของการจำลอง

2.7 คำนวณค่าเฉลี่ยของ MSE ค่าเฉลี่ยของ RMSE และค่าเฉลี่ยของ MAE จากการจำลองทั้งหมด 1,000 รอบ

2.8 นำค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA ในชุดข้อมูลฝึกสอนจากข้อมูลจำลอง

ในแต่ละรอบมาสร้างตัวแบบซัพพอร์ทเวกเตอร์แมชชีนสำหรับการถดถอย ภายใต้จำนวนช่วงเวลาที่ใช้ซ้ำกว่ากัน (lag) เท่ากับ 1 หน่วยเวลา และกำหนดค่า C เท่ากับ 1 และค่า ϵ เท่ากับ 0.1 โดยใช้ Gaussian radial function เป็นฟังก์ชันเคอร์เนล เมื่อกำหนดรอบของการทำซ้ำ 100 รอบ

2.9 พิจารณาคัดเลือกตัวแบบซัพพอร์ทเวกเตอร์แมชชีน โดยตัวแบบที่เหมาะสมกว่า คือ ตัวแบบที่มีค่า RMSE ต่ำกว่า และพยากรณ์ข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ด้วยตัวแบบซัพพอร์ทเวกเตอร์แมชชีนในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจากข้อมูลจำลองในแต่ละรอบ

2.10 คำนวณค่าพยากรณ์รวม ซึ่งเป็นการรวมข้อมูลในส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA และข้อมูลในส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากการพยากรณ์ด้วยตัวแบบซัพพอร์ทเวกเตอร์แมชชีนเข้าด้วยกัน และคำนวณหาค่า MSE, RMSE และ MAE ในแต่ละรอบของการจำลอง

2.11 คำนวณค่าเฉลี่ยของ MSE ค่าเฉลี่ยของ RMSE และค่าเฉลี่ยของ MAE จากการจำลองทั้งหมด 1,000 รอบ

2.12 เก็บรวบรวมข้อมูลจริงราคาปิดหุ้น SCB รายสัปดาห์ของธนาคารไทยพาณิชย์ จำกัด (มหาชน) ตั้งแต่วันที่ 2 เดือนกรกฎาคม พ.ศ. 2550 ถึงวันที่ 8 เดือนกุมภาพันธ์ พ.ศ. 2559 จำนวน 456 สัปดาห์ จากเว็บไซต์ <http://finance.yahoo.com/q?s=SCB.BK> โดยแบ่งชุดข้อมูลราคาปิดหุ้น SCB ออกเป็นชุดข้อมูลฝึกสอน 319 สัปดาห์ (คิดเป็น 70 %) สำหรับสร้างตัวแบบ และชุดข้อมูลทดสอบ 137 สัปดาห์ (คิดเป็น 30 %) สำหรับประเมินความถูกต้องของตัวแบบ

2.13 นำชุดข้อมูลฝึกสอนจำนวน 319 สัปดาห์

จากข้อมูลจริงมาสร้างตัวแบบ ARIMA ภายใต้ค่า p ตั้งแต่ 0 ถึง 2 ค่า d เท่ากับ 1 และค่า q ตั้งแต่ 0 ถึง 2 จากนั้นพิจารณาคัดเลือกตัวแบบข้างต้นโดยตัวแบบที่เหมาะสมที่สุด คือ ตัวแบบ ARIMA(1,1,1) เนื่องจากเป็นตัวแบบที่มีเกณฑ์สารสนเทศของอะไคเกะ (Akaike's information criterion, AIC) ต่ำที่สุด

2.14 พยากรณ์ราคาปิดหุ้น SCB ด้วยตัวแบบ ARIMA(1,1,1) ในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจากข้อมูลจริง ซึ่งจัดเป็นข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ และคำนวณหาค่า MSE, RMSE และ MAE จากนั้นคำนวณค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA(1,1,1) ในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจากข้อมูลจริงข้างต้น

2.15 นำค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA(1,1,1) ในชุดข้อมูลฝึกสอนจากข้อมูลจริง มาสร้างตัวแบบเครือข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้า โดยใช้เทคนิคการแพร่แบบย้อนกลับเป็นเทคนิคการเรียนรู้เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.01 ซึ่งตัวแบบเครือข่ายประสาทเทียมประกอบด้วยชั้นข้อมูลนำเข้า 1 ชั้น ภายใต้จำนวนโหนด 1 โหนด ชั้นซ่อน 1 ชั้น ภายใต้จำนวนโหนด 1 ถึง 5 โหนด โดยใช้ sigmoid logistic function เป็นฟังก์ชันกระตุ้น และชั้นผลลัพธ์ 1 ชั้น ภายใต้จำนวนโหนด 1 โหนด โดยใช้ linear function เป็นฟังก์ชันกระตุ้น เมื่อกำหนดรอบของการทำซ้ำ เท่ากับ 100 รอบ

2.16 พิจารณาคัดเลือกตัวแบบเครือข่ายประสาทเทียมโดยตัวแบบที่เหมาะสมกว่า คือ ตัวแบบที่มีค่า RMSE ต่ำกว่า และพยากรณ์ข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ด้วยตัวแบบเครือข่ายประสาทเทียมในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจากข้อมูลจริงข้างต้น

2.17 คำนวณหาค่าพยากรณ์รวม ซึ่งเป็นการรวมข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากตัวแบบ ARIMA(1,1,1) และข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากตัวแบบเครือข่ายประสาทเทียมเข้าด้วยกัน และคำนวณหาค่า MSE, RMSE และ MAE

2.18 นำค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบ ARIMA(1,1,1) ในชุดข้อมูลฝึกสอนจากข้อมูลจริง มาสร้างตัวแบบซัพพอร์ทเวกเตอร์แมชชีนสำหรับการถดถอย ภายใต้จำนวนช่วงเวลาที่ซ้ำกว่ากันเท่ากับ 1 หน่วยเวลา และกำหนดค่า C เท่ากับ 1 และค่า ϵ เท่ากับ 0.1 โดยใช้ Gaussian radial function เป็นฟังก์ชันเคอร์เนล เมื่อกำหนดรอบของการทำซ้ำ เท่ากับ 100 รอบ

2.19 พิจารณาคัดเลือกตัวแบบซัพพอร์ทเวกเตอร์แมชชีนโดยตัวแบบที่เหมาะสมกว่า คือ ตัวแบบที่มีค่า RMSE ต่ำกว่า และพยากรณ์ข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ด้วยตัวแบบซัพพอร์ทเวกเตอร์แมชชีนในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบจากข้อมูลจริงข้างต้น

2.20 คำนวณหาค่าพยากรณ์รวม ซึ่งเป็นการรวมข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากตัวแบบ ARIMA(1,1,1) และข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงในเทอมของค่าพารามิเตอร์ที่ได้จากตัวแบบซัพพอร์ทเวกเตอร์แมชชีนเข้าด้วยกัน และคำนวณหาค่า MSE, RMSE และ MAE

2.21 เปรียบเทียบความแม่นยำของตัวแบบ ARIMA, ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ทเวกเตอร์แมชชีน โดยใช้เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ยเป็นเครื่องมือในการเปรียบเทียบตัวแบบ โดยตัวแบบใดที่มีค่า RMSE ต่ำสุด

ตารางที่ 1 ผลการเปรียบเทียบความแม่นยำของค่าพยากรณ์จากตัวแบบ ARIMA ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ตเวกเตอร์แมชชีน โดยใช้ชุดข้อมูลจำลอง

ชุดข้อมูลจำลอง	อันดับความแม่นยำของตัวแบบ	ค่าเฉลี่ยของ RMSE	
		ชุดข้อมูลฝึกสอน	ชุดข้อมูลทดสอบ
ตัวแบบ ARIMA(0,1,1)	1. ตัวแบบผสม ARIMA-ANN	3.9793	5.5485
	2. ตัวแบบผสม ARIMA-SVM	4.1769	5.6008
	3. ตัวแบบ ARIMA	4.2232	5.6269
ตัวแบบ ARIMA(0,1,2)	1. ตัวแบบผสม ARIMA-SVM	4.0634	5.5661
	2. ตัวแบบ ARIMA	4.1057	5.5872
	3. ตัวแบบผสม ARIMA-ANN	4.1428	5.7119
ตัวแบบ ARIMA(1,1,0)	1. ตัวแบบผสม ARIMA-ANN	5.2518	7.7504
	2. ตัวแบบผสม ARIMA-SVM	6.3993	9.4765
	3. ตัวแบบ ARIMA	6.4909	9.5688
ตัวแบบ ARIMA(0,1,1)	1. ตัวแบบผสม ARIMA-ANN	3.9793	5.5485
	2. ตัวแบบผสม ARIMA-SVM	4.1769	5.6008
	3. ตัวแบบ ARIMA	4.2232	5.6269
ตัวแบบ ARIMA(1,1,1)	1. ตัวแบบผสม ARIMA-SVM	4.0327	5.5726
	2. ตัวแบบ ARIMA	4.0818	5.5969
	3. ตัวแบบผสม ARIMA-ANN	4.1643	5.7522
ตัวแบบ ARIMA(1,1,2)	1. ตัวแบบผสม ARIMA-ANN	3.9372	5.5597
	2. ตัวแบบผสม ARIMA-SVM	4.1746	5.6091
	3. ตัวแบบ ARIMA	4.2301	5.6221
ตัวแบบ ARIMA(2,1,0)	1. ตัวแบบผสม ARIMA-ANN	4.8786	6.0926
	2. ตัวแบบผสม ARIMA-SVM	5.5665	6.5044
	3. ตัวแบบ ARIMA	5.6640	6.5339
ตัวแบบ ARIMA(2,1,1)	1. ตัวแบบผสม ARIMA-ANN	3.9736	5.6107
	2. ตัวแบบผสม ARIMA-SVM	4.1000	5.6433
	3. ตัวแบบ ARIMA	4.1540	5.6742
ตัวแบบ ARIMA(2,1,2)	1. ตัวแบบผสม ARIMA-SVM	4.0156	5.5492
	2. ตัวแบบ ARIMA	4.0659	5.5835
	3. ตัวแบบผสม ARIMA-ANN	4.0682	5.5998

จะเป็นตัวแบบที่ให้ผลดีที่สุด

2.22 วิเคราะห์และสรุปผลการวิจัย

3. ผลการวิจัย

การวิจัยนี้นำเสนอผลการเปรียบเทียบโดยแบ่งออกเป็น 2 ส่วน คือ ในส่วนที่ 1 เปรียบเทียบความแม่นยำของค่าพยากรณ์ที่ได้จากตัวแบบ ARIMA ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ทเวกเตอร์แมชชีน โดยใช้ชุดข้อมูลจำลอง และส่วนที่ 2 เปรียบเทียบความแม่นยำของค่าพยากรณ์ที่ได้จากตัวแบบ ARIMA ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ทเวกเตอร์แมชชีน โดยใช้ชุดข้อมูลจริงของราคาปิดหุ้น SCB

จากตารางที่ 1 พบว่าสำหรับการพยากรณ์ชุด

ข้อมูลอนุกรมเวลาที่ได้จากการจำลองด้วยตัวแบบ ARIMA(0,1,2) ตัวแบบ ARIMA(1,1,1) และตัวแบบ ARIMA(2,1,2) สรุปได้ว่าตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ทเวกเตอร์แมชชีน มีความแม่นยำในการพยากรณ์สูงสุด รองลงมา คือ ตัวแบบ ARIMA และตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม มีความแม่นยำในการพยากรณ์ต่ำที่สุด ทั้งในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ ส่วนการพยากรณ์ชุดข้อมูลอนุกรมเวลาที่ได้จากการจำลองด้วยตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) และตัวแบบ ARIMA(2,1,1) สรุปได้ว่าตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม มีความแม่นยำในการพยากรณ์สูงสุด รองลงมา คือ ตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ทเวกเตอร์แมชชีน และตัวแบบ ARIMA มีความแม่นยำในการพยากรณ์ต่ำที่สุด

ตารางที่ 2 ค่า MSE, RMSE และ MAE ที่ได้จากการพยากรณ์ราคาปิดหุ้น SCB โดยใช้ชุดข้อมูลจริง

ตัวแบบ	MSE		RMSE		MAE	
	ชุดข้อมูลฝึกสอน	ชุดข้อมูลทดสอบ	ชุดข้อมูลฝึกสอน	ชุดข้อมูลทดสอบ	ชุดข้อมูลฝึกสอน	ชุดข้อมูลทดสอบ
ARIMA	14.519	29.447	3.810	5.427	2.916	4.171
ARIMA-ANN	14.527	29.634	3.811	5.444	2.918	4.198
ARIMA-SVM	14.371	28.564	3.787	5.345	2.901	4.097

จากตารางที่ 2 การศึกษาตัวแบบ ARIMA ภายใต้ค่า p ตั้งแต่ 0 ถึง 2 ค่า d เท่ากับ 1 และค่า q ตั้งแต่ 0 ถึง 2 พบว่าตัวแบบที่เหมาะสมที่สุดสำหรับใช้พยากรณ์ราคาปิดหุ้น SCB คือ ตัวแบบ ARIMA(1,1,1) เนื่องจากเป็นตัวแบบที่มี AIC ต่ำที่สุด ซึ่งมีรูปแบบของสมการคือ $\nabla x_t = -0.9181 \nabla x_{t-1} - 0.9949 w_{t-1} + w_t$ โดยให้ค่า RMSE เท่ากับ 3.810 สำหรับชุดข้อมูลฝึกสอน และ RMSE เท่ากับ 5.427 สำหรับชุดข้อมูล

ทดสอบ

การศึกษาตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม โดยนำค่าส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,1) มาสร้างตัวแบบเครือข่ายประสาทเทียม พบว่าตัวแบบเครือข่ายประสาทเทียม 1-4-1 (กล่าวคือ เป็นตัวแบบเครือข่ายประสาทเทียมที่ชั้นข้อมูลนำเข้ามีจำนวนโนนด 1 โนนด ชั้นซ่อนมีจำนวนโนนด 4 โนนด และชั้นผลลัพธ์มีจำนวนโนนด 1 โนนด)

เป็นตัวแทนที่เหมาะสมที่สุด เนื่องจากเป็นตัวแทนที่ให้ค่า RMSE ต่ำที่สุด จากนั้นคำนวณหาค่าพยากรณ์รวม ซึ่งเป็นการรวมข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงที่ได้จากการพยากรณ์ราคาปิดหุ้น SCB ด้วยตัวแบบ ARIMA(1,1,1) และข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงที่ได้จากการพยากรณ์ราคาปิดหุ้น SCB ด้วยตัวแบบเครือข่ายประสาทเทียม 1-4-1 เข้าด้วยกัน โดยให้ค่า RMSE เท่ากับ 3.811 สำหรับชุดข้อมูลฝึกสอน และ RMSE เท่ากับ 5.444 สำหรับชุดข้อมูลทดสอบ

การศึกษาตัวแบบผสมระหว่าง ARIMA กับ ชัพพอร์ทเวกเตอร์แมชชีน โดยนำค่าส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,1) มาสร้างตัวแบบชัพพอร์ทเวกเตอร์แมชชีนสำหรับการถดถอย พบว่าตัวแบบชัพพอร์ทเวกเตอร์แมชชีนที่มีจำนวนช่วงเวลาที่ใช้ค่า C เท่ากับ 1 หน่วยเวลา ค่า C เท่ากับ 1 ค่า ϵ เท่ากับ 0.1 และค่าส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.544 เป็นตัวแทนที่เหมาะสมที่สุด เนื่องจากเป็นตัวแทนที่ให้ค่า RMSE ต่ำที่สุด จากนั้นคำนวณหาค่าพยากรณ์รวม ซึ่งเป็นการรวมข้อมูลส่วนที่เป็นฟังก์ชันเชิงเส้นตรงที่ได้จากการพยากรณ์ราคาปิดหุ้น SCB ด้วยตัวแบบ ARIMA(1,1,1) และข้อมูลส่วนที่ไม่เป็นฟังก์ชันเชิงเส้นตรงที่ได้จากการพยากรณ์ราคาปิดหุ้น SCB ด้วยตัวแบบชัพพอร์ทเวกเตอร์แมชชีนเข้าด้วยกัน โดยให้ค่า RMSE เท่ากับ 3.787 สำหรับชุดข้อมูลฝึกสอน และ RMSE เท่ากับ 5.345 สำหรับชุดข้อมูลทดสอบ

ดังนั้นสรุปได้ว่าการพยากรณ์ราคาปิดหุ้น SCB โดยใช้ชุดข้อมูลจริงในชุดข้อมูลฝึกสอน ตัวแบบผสมระหว่าง ARIMA(1,1,1) กับชัพพอร์ทเวกเตอร์แมชชีน ให้ค่า RMSE ต่ำกว่าตัวแบบ ARIMA(1,1,1) และตัวแบบผสมระหว่าง ARIMA(1,1,1) กับเครือข่ายประสาทเทียม ตามลำดับ ส่วนการพยากรณ์ราคาปิดหุ้น SCB ในชุดข้อมูลทดสอบ ตัวแบบผสมระหว่าง ARIMA(1,1,1) กับชัพพอร์ทเวกเตอร์แมชชีน ให้ค่า

RMSE ต่ำกว่าตัวแบบ ARIMA(1,1,1) และตัวแบบผสมระหว่าง ARIMA(1,1,1) กับเครือข่ายประสาทเทียม ตามลำดับ ดังนั้นกล่าวโดยสรุปได้ คือ ตัวแบบผสมระหว่าง ARIMA(1,1,1) กับชัพพอร์ทเวกเตอร์แมชชีน มีความแม่นยำในการพยากรณ์สูงสุด รองลงมา คือ ตัวแบบ ARIMA(1,1,1) และตัวแบบผสมระหว่าง ARIMA(1,1,1) กับเครือข่ายประสาทเทียม มีความแม่นยำในการพยากรณ์ต่ำที่สุด ทั้งในชุดข้อมูลฝึกสอน และชุดข้อมูลทดสอบ

4. สรุป

ผลการวิจัยในการเปรียบเทียบความแม่นยำของตัวแบบ ARIMA ตัวแบบผสมระหว่าง ARIMA กับ เครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับชัพพอร์ทเวกเตอร์แมชชีน ในการพยากรณ์ราคาปิดหุ้น SCB ของธนาคารไทยพาณิชย์ จำกัด (มหาชน) โดยใช้ชุดข้อมูลจริงและชุดข้อมูลอนุกรมเวลาที่จำลองด้วยตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(0,1,2) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,1) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) ตัวแบบ ARIMA(2,1,1) และตัวแบบ ARIMA(2,1,2) ผลปรากฏว่าสำหรับการพยากรณ์ในชุดข้อมูลอนุกรมเวลาที่จำลองด้วยตัวแบบ ARIMA(0,1,2), ตัวแบบ ARIMA(1,1,1) และตัวแบบ ARIMA(2,1,2) สรุปได้ว่าตัวแบบผสมระหว่าง ARIMA กับชัพพอร์ทเวกเตอร์แมชชีน มีความแม่นยำในการพยากรณ์สูงสุด รองลงมา คือ ตัวแบบ ARIMA และตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม มีความแม่นยำในการพยากรณ์ต่ำที่สุด สำหรับการพยากรณ์ในชุดข้อมูลอนุกรมเวลาที่จำลองด้วยตัวแบบ ARIMA(0,1,1) ตัวแบบ ARIMA(1,1,0) ตัวแบบ ARIMA(1,1,2) ตัวแบบ ARIMA(2,1,0) และตัวแบบ ARIMA(2,1,1) สรุปได้ว่าตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม มีความ

แม่นยำในการพยากรณ์สูงสุด รองลงมา คือ ตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ตเวกเตอร์แมชชีน และตัวแบบ ARIMA มีความแม่นยำในการพยากรณ์ต่ำที่สุด และการพยากรณ์ในชุดข้อมูลจริงของราคาปิดหุ้น SCB สรุปได้ว่าตัวแบบผสมระหว่าง ARIMA(1,1,1) กับซัพพอร์ตเวกเตอร์แมชชีน มีความแม่นยำในการพยากรณ์สูงสุด รองลงมา คือ ตัวแบบ ARIMA และตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม มีความแม่นยำในการพยากรณ์ต่ำที่สุด ซึ่งให้ผลที่สอดคล้องกันทั้งในชุดข้อมูลจริงและชุดข้อมูลจำลอง

5. ข้อเสนอแนะ

งานวิจัยนี้ผู้ที่สนใจอาจนำไปศึกษาต่อได้อีกในเรื่องดังต่อไปนี้

5.1 ในงานวิจัยนี้เลือกใช้ตัวแบบในการเปรียบเทียบความแม่นยำเพียง 3 ตัวแบบ เท่านั้น คือ ตัวแบบ ARIMA ตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม และตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ตเวกเตอร์แมชชีน ซึ่งในความเป็นจริงแล้วยังมีตัวแบบผสมอีกหลายตัวแบบที่น่าสนใจ เช่น ตัวแบบผสมระหว่าง ARIMA กับ Pegals ตัวแบบผสมระหว่าง ARIMA กับ adaptive neuron-fuzzy Inference system ตัวแบบผสมระหว่าง ARIMA กับ exponential smoothing ตัวแบบผสมระหว่าง ARIMA กับ moving average of percentage change ซึ่งผู้ที่สนใจอาจนำตัวแบบดังกล่าวข้างต้นมาพิจารณาร่วมด้วยเพื่อทำให้การเปรียบเทียบความแม่นยำของตัวแบบมีประสิทธิภาพมากยิ่งขึ้น

5.2 ในงานวิจัยนี้เลือกใช้ตัวแบบ ARIMA ในการพยากรณ์ข้อมูลอนุกรมเวลา ซึ่งผู้ที่สนใจอาจศึกษาตัวแบบ SARIMA (seasonal integrated autoregressive moving average) เพิ่มเติม และนำตัวแบบ

ดังกล่าวมาสร้างเป็นตัวแบบผสม เช่น ตัวแบบผสมระหว่าง SARIMA กับเครือข่ายประสาทเทียม

5.3 การสร้างตัวแบบผสมระหว่าง ARIMA กับเครือข่ายประสาทเทียม ในงานวิจัยนี้ได้มีการคำนวณเหลือที่ได้จากตัวแบบ ARIMA มาสร้างตัวแบบเครือข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้าซึ่งในการศึกษาครั้งต่อไปผู้ที่สนใจอาจนำค่าส่วนเหลือที่ได้จากตัวแบบ ARIMA มาสร้างตัวแบบเครือข่ายประสาทเทียมแบบมีการย้อนกลับแทนการใช้ตัวแบบเครือข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้า นอกจากนี้ อาจเลือกใช้วิธีการแปลงข้อมูลก่อนการสร้างตัวแบบด้วยวิธีอื่นแทนการใช้วิธี max-min normalization เช่น Z-score standardization เพื่อเปรียบเทียบว่าให้ผลเหมือนหรือแตกต่างกันอย่างไร และอาจปรับเปลี่ยนประเภทของฟังก์ชันกระตุ้นที่อยู่ในซ่อนและชั้นผลลัพธ์ เช่น ในชั้นซ่อนอาจเลือกใช้ hyperbolic tangent function เป็นฟังก์ชันกระตุ้นแทนการใช้ Sigmoid logistic function

5.4 การสร้างตัวแบบผสมระหว่าง ARIMA กับซัพพอร์ตเวกเตอร์แมชชีน ในการศึกษาครั้งต่อไป อาจเลือกใช้ kernel function ประเภทอื่นแทนการใช้ Gaussian radial basis function เช่น exponential radial basis function และอาจพิจารณาเลือกใช้ค่า C และค่า ϵ ณ ระดับต่าง ๆ แทน เพราะอาจทำให้ตัวแบบที่ได้มีความแม่นยำมากยิ่งขึ้น

6. รายการอ้างอิง

- [1] ทรงศิริ แต่สมบัติ, 2553, การพยากรณ์เชิงปริมาณ, สำนักพิมพ์มหาวิทยาลัยเกษตรศาสตร์, กรุงเทพฯ, 487 น.
- [2] Shumway, R.H. and Stoffer, D.S., 2010, Time Series Analysis and Its Applications

- with R Examples, 3rd Ed., Springer, USA, 576 p.
- [3] ภูมิฐาน รังคกุลวัฒน์, 2556, การวิเคราะห์อนุกรมเวลาสำหรับเศรษฐศาสตร์และธุรกิจ, สำนักพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย, กรุงเทพฯ, 440 น.
- [4] สายชล สันสมบัติทอง, 2558, การทำเหมืองข้อมูล, จามจุรีโปรดักท์, กรุงเทพฯ, 512 น.
- [5] เอกสิทธิ์ พัทธวงศ์ศักดิ์, 2557, การวิเคราะห์ข้อมูลด้วยเทคนิคดาต้าไมน์นิ่งเบื้องต้น, บริษัท เอเชีย ดิจิตอลการพิมพ์ จำกัด, กรุงเทพฯ, 123 น.
- [6] Gunn, S.R., 1998, Support Vector Machines for Classification and Regression, Faculty of Engineering, Science and Mathematics, University of Southampton, United Kingdom, Available Source: <http://www.ecs.soton.ac.uk/~srg/publications/pdf/SVM.pdf>, November 9, 2015.
- [7] ต้อง ศรีคชา, 2550, การคาดการณ์ราคาหุ้นระยะสั้นโดยวิธีการผสมผสานทำซ้ำตัวกรองความชันการปรับตัวเข้าหา และการปรับตัวการเรียนรู้
- นิรอรพัชชี, วิทยานิพนธ์ปริญญาเอก, สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, กรุงเทพฯ, 177 น.
- [8] Zhang, P.G., 2003, Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, Neurocomputing 50: 159-175.
- [9] พงษ์ศิริ ศิริพานิช, 2550, การพยากรณ์อนุกรมเวลาด้วยตัวแบบผสมระหว่าง ARIMA และเครือข่ายประสาทเทียม, วิทยานิพนธ์ปริญญาโท, มหาวิทยาลัยศิลปากร, นครปฐม, 54 น.
- [10] Zhang, D.Y., Chen, P. and Song, H.W., 2008, Stock market forecasting model based on a hybrid ARMA and support vector machines, Proceeding of The 15th International Conference on Management Science and Engineering, USA, 6: 1312-1317.
- [11] ภัทร วรภู, 2556, การเปรียบเทียบความแม่นยำของการพยากรณ์อนุกรมเวลาระหว่างตัวแบบผสมและตัวแบบเดี่ยว, วิทยานิพนธ์ปริญญาโท, จุฬาลงกรณ์มหาวิทยาลัย, กรุงเทพฯ, 138 น.