

Research Article

การพยากรณ์ความผันผวนของดัชนี SET ด้วยตัวแบบโครงข่ายประสาทเทียม-GARCH

Forecasting volatility of SET with artificial neural network-GARCH models

วิชิต คลังภูเขียว^{1*}, พฤต ธนรัช² และ ปิยภัทร บุษบาบดินทร์¹

Wichit Khangphukhiao^{1*}, Preut Thanarat² and Piyapatr Busababadin¹

¹หน่วยวิจัยสถิติและสถิติประยุกต์ ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม อำเภอกันทรวิชัย จังหวัดมหาสารคาม 44150

²ภาควิชาสื่ออุดมิต คณะวิทยาการสารสนเทศ มหาวิทยาลัยมหาสารคาม อำเภอกันทรวิชัย จังหวัดมหาสารคาม 44150

¹Statistics and Applied Statistics Research Unit, Department of Mathematics, Faculty of Science, Mahasarakham University, Kantarawichai, Mahasarakham 44150, Thailand

²Department of New Media, Faculty of Informatics, Mahasarakham University, Kantarawichai, Mahasarakham 44150, Thailand

*E-mail: wichit.k@msu.ac.th

Received: 26/08/2018; Revised: 25/12/2018; Accepted: 22/01/2019

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบ ANN-GARCH และ ANN-EGARCH ซึ่งเป็นการนำตัวแบบ GARCH รวมในวิธีโครงข่ายประสาทเทียม (ANN) เป็นแบบจำลองไฮบริดจ์ในการพยากรณ์ความผันผวนดัชนีตลาดหลักทรัพย์แห่งประเทศไทย (SET) ผลจากการศึกษาแสดงให้เห็นว่า ANN-GARCH และ ANN-EGARCH มีความแม่นยำสูง โดยใช้ค่ารากที่สองของค่าเฉลี่ยค่าความคลาดเคลื่อนกำลังสอง (RMSE) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) เป็นเกณฑ์ในการวัดความแม่นยำ ทั้งนี้การมีตัวแปรที่สำคัญในตัวแบบ ตัวแบบอธิบายผลพยากรณ์ความผันผวนได้อย่างแม่นยำ

คำสำคัญ: การพยากรณ์ความผันผวน, leverage effect, ความแปรปรวนไม่คงที่, Levenberg-Marquardt backpropagation

Abstract

This research aimed to compare the effectiveness of two forecasting models, ANN-GARCH and ANN-EGARCH. The two hybrid models were formed by a combination of Generalized Auto Regressive Conditional Heteroskedasticity (GARCH) and Artificial Neural Network (ANN) models, used to forecast the volatility of the Stock Exchange of Thailand index (SET). The results showed that both of the ANN-GARCH and ANN-EGARCH forecasts were highly accurate, measured by root mean square error (RMSE) and mean absolute percentage error (MAPE) values. With key variables included, the models accurately described volatility forecasts.

Keywords: volatility forecast, leverage effect, heteroskedasticity, Levenberg-Marquardt backpropagation

บทนำ

ดัชนีราคาหุ้นตลาดหลักทรัพย์แห่งประเทศไทย (stock exchange of Thailand: SET) เป็นดัชนีที่สะท้อนการเคลื่อนไหวของราคาหลักทรัพย์ทั้งหมด (composite index) คำนวณจากหุ้นสามัญจดทะเบียนทุกตัวในตลาดหลักทรัพย์แห่งประเทศไทย ซึ่งการเปลี่ยนแปลงของดัชนี SET สามารถสะท้อนให้เห็นถึงลักษณะของตลาดการลงทุนในอนาคต รวมทั้งมูลค่าการปรับตัวของหุ้นขนาดใหญ่ที่ส่งผลต่ออัตราเติบโตเศรษฐกิจ ผลผลิตมวลรวมของประเทศ (GDP) และสามารถประเมินโอกาสการขยายตัวเศรษฐกิจในประเทศ

ในการสร้างตัวแบบเพื่อคาดการณ์ความผันผวนจากข้อมูลทางเศรษฐกิจ และข้อมูลทางการเงิน มักพบปัญหาความแปรปรวนของความคลาดเคลื่อนไม่คงที่ (heteroskedasticity) ส่งผลให้ความคลาดเคลื่อนค่อนข้างสูง ผลของความคลาดเคลื่อนทำให้เกิดความสูญเสียทางเศรษฐกิจ สำหรับผู้ใช้ตัวแบบที่มีข้อบกพร่องและส่งผลต่อความผิดพลาดการตัดสินใจลงทุน ดังนั้นจึงมีการศึกษาพัฒนาปรับปรุงวิธีการสร้างตัวแบบ เพื่อลดความเสี่ยงและความคลาดเคลื่อนอย่างต่อเนื่อง จากการศึกษาที่ผ่านมา Sónia (2015) และ Wei et al. (2010) ได้นำเสนอตัวแบบกลุ่มของ GARCH ในการพยากรณ์ความผันผวนราคาทองคำในตลาดโลก ซึ่งสามารถอธิบายความผันผวนในระยะสั้นได้ดี จากการศึกษาของ Suebpongsakorn & Wisagarn (2016) พบว่า Exponential GARCH (EGARCH) มีความแม่นยำมากกว่า GARCH สำหรับการคาดการณ์อัตราแลกเปลี่ยนค่าเงินบาทต่อดอลลาร์สหรัฐ แต่เนื่องจากความผันผวนเกิดจากอิทธิพลของตัวแปรปัจจัยในทางเศรษฐกิจ ที่เป็นตัวกำหนดความผันผวนในอนาคต ซึ่งมีนักวิจัย อาทิ Kristjanpoller & Marcel (2016), Lu et al. (2016), Kristjanpoller et al. (2014) และ Khashei et al. (2009) ได้ทำการศึกษาตัวแบบที่สามารถรวมตัวแปรสำคัญในการอธิบายความผันผวน โดยการประยุกต์วิธีโครงข่ายประสาทเทียม (artificial neural networks: ANN) รวมกับตัวแบบ GARCH เป็นตัวแบบไฮบริดคือ ANN-GARCH ที่ให้ความแม่นยำในการพยากรณ์ และวิธี ANN เป็นอีกหนึ่งวิธีที่เหมาะสมสำหรับข้อมูลขนาดใหญ่ (Lin, 2015) ดังนั้น เพื่อ

แสดงให้เห็นถึงผลความแม่นยำ ในการศึกษาครั้งนี้ จึงมีวัตถุประสงค์เพื่อเปรียบเทียบความแม่นยำของตัวแบบ ANN-GARCH กับ ANN-EGARCH โดยใช้ข้อมูลดัชนี SET เป็นกรณีศึกษา ทั้งนี้ได้มีทฤษฎีที่เกี่ยวข้องดังต่อไปนี้

1. ตัวแบบ Generalized autoregressive conditional heteroskedasticity (GARCH)

การสร้างตัวแบบ GARCH ในการศึกษานี้ทำการประมาณสมการค่าเฉลี่ยแบบมีเงื่อนไข (conditional mean equation) ด้วย autoregressive moving average คือ ARMA(1,1) ดังสมการที่ (1) ตัวแบบ GARCH ถูกเสนอ โดย Bollerslev (1986) และได้พัฒนามาจากตัวแบบ ARCH จาก Engle (1982) ซึ่งเป็นการนำความแปรปรวนในระยะสั้นที่ผ่านมา ใส่เข้าไปในตัวแบบ ARCH เป็นตัวแบบ GARCH(q,p) โดย p แทนลำดับของ ε_{t-i}^2 และ q แทนลำดับของ σ_{t-j}^2 ในสมการความแปรปรวนแสดงดังสมการที่ (2) ซึ่งถูกใช้เป็นตัวแบบพื้นฐานในการสร้างตัวแบบไฮบริดจ์

$$r_t = c + \phi_1 r_{t-1} + \theta_1 \varepsilon_{t-1} + \varepsilon_t \quad (1)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2)$$

โดยที่ ϕ_1 และ θ_1 เป็นค่าพารามิเตอร์ และ ε_t เป็นตัวแปรสุ่มคลาดเคลื่อนมีค่าเฉลี่ยเป็น 0 ความแปรปรวนเป็น σ^2 ค่าพารามิเตอร์ของ GARCH คือ $\omega > 0, \alpha_i \geq 0, i = 1, \dots, p, \beta_j > 0, j = 1, \dots, q$

2. ตัวแบบ Exponential GARCH (EGARCH)

ตัวแบบ EGARCH ตามการศึกษาของ Suebpongsakorn & Wisagarn (2016) ซึ่งเป็นตัวแบบที่แสดงผลกระทบเมื่อเกิดเหตุการณ์ไม่คาดฝัน (shock) ด้านบวกและด้านลบส่งผลต่อความแปรปรวนในระยะสั้นไม่เท่ากัน (leverage effect) กำหนดให้ $z_t = \frac{\varepsilon_t}{\sigma_t}$ โดย $E(z_t) = 0$ และ $E\{z_t | -E\{z_t|\}\} = 0$ กำหนดให้ฟังก์ชัน $g(z_t)$ แสดง leverage effect ดังสมการ (3)

$$g(z_t) = \lambda z_t + \omega \{z_t | -E\{z_t|\}\} \quad (3)$$

โดยที่ z_t คือ ผลของเหตุการณ์ไม่คาดฝันด้านบวกหรือลบที่ส่งผลต่อ $g(z)$ ไม่เท่ากัน (asymmetry effect) และ $|z_t| - E\{z_t|\}$ คือ ผลของเหตุการณ์ไม่คาดฝันในทางบวกหรือลบ ที่ส่งผลต่อ $g(z)$ เท่ากัน (symmetry effect) โดย λ และ ω คือค่าพารามิเตอร์ ฟังก์ชัน $g(z)$ แสดงดังนี้

$$\ln(\sigma_t^2) = \gamma_0 + \sum_{i=1}^p \theta_i + \ln(\sigma_{t-1}^2) + \sum_{i=1}^q \gamma_i \omega \left| \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right| + \sum_{k=1}^r \gamma_k \lambda \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \quad (4)$$

โดยที่ $\gamma_1 = 1$ ทำการทดสอบผลของ leverage effect โดยทดสอบความมีนัยสำคัญของค่าพารามิเตอร์ λ ในสมการที่ (4)

3. โครงข่ายประสาทเทียม (artificial neural networks: ANN)

วิธีโครงข่ายประสาทเทียมถูกนำไปใช้ในการพยากรณ์ ซึ่งเป็นวิธีที่ให้ประสิทธิภาพและมีความแม่นยำในการพยากรณ์ มีนักวิจัย Qiu et al. (2016) และ Wang & Wu (2012) ได้นำวิธี ANN ใช้ในการคาดการณ์ข้อมูลผลตอบแทนดัชนีหุ้นในกลุ่มพลังงาน ซึ่งวิธี ANN สามารถเรียนรู้จากตัวอย่างและทำให้เป็นรูปทั่วไป (generalize) ด้วยกฎการเรียนรู้ (learning rule) ทำให้สามารถจำแนกรูปแบบข้อมูลนำเข้า (input) แบบใหม่ที่ไม่รู้จักมาก่อนได้ ในการประยุกต์ใช้ ANN ในการทำนาย จำเป็นต้องกำหนดฟังก์ชันถ่ายโอน (activation function) ซึ่งสามารถแสดงผลลัพธ์ในชั้นซ่อนของโครงข่าย ดังสมการ (5) ชั้นผลลัพธ์ (output) ของโครงข่าย แสดงดังสมการที่ (6)

$$a_j = g \sum_{i=0}^d w_{ji}^{(1)} x_i \quad (5)$$

$$o_i = f \sum_{j=0}^m w_{kj}^{(2)} g \left(\sum_{i=0}^d w_{ji}^{(1)} x_i \right) \quad (6)$$

เมื่อกำหนดให้ w_{ji} แทนค่าน้ำหนักของเส้นเชื่อมจากชั้นข้อมูลนำเข้าและ a_j แทน ผลลัพธ์ในชั้นซ่อน w_{kj} แทนค่าน้ำหนักของเส้นเชื่อมจากชั้นซ่อน g แทนฟังก์ชันถ่ายโอนในชั้นซ่อน f แทนฟังก์ชันถ่ายโอนในชั้นผลลัพธ์ ในการศึกษาครั้งนี้สถาปัตยกรรมของโครงข่าย (network architecture) มีรูปแบบของการไหลแบบไปข้างหน้า (feed forward network) ใช้ levenberg-marquardt backpropagation ทำการปรับค่าพารามิเตอร์เพื่อให้ค่าความคลาดเคลื่อนเข้าสู่จุดต่ำสุด (Srikaew, 2009) ในการศึกษาครั้งนี้ใช้ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (mean squared error: MSE) แสดงความเหมาะสมของโครงข่ายในขั้นตอนการฝึกการเรียนรู้ (Zhang et al., 1998)

4. ตัวแบบ ANN-GARCH

ในการสร้างตัวแบบ ANN-GARCH(q,p,s) ในการพยากรณ์ความผันผวน ตามสมการที่ (7) เป็นไปตาม Donaldson & Kamstra (1997) เป็นการรวมกันระหว่างวิธีโครงข่ายประสาทเทียมกับตัวแบบ GARCH(q,p) และ s คือจำนวนนิเวศในชั้นซ่อน ซึ่งแสดงรายละเอียดในสมการที่ (7)-(10) ดังนี้

$$\sigma_t^2 = C + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \sum_{h=1}^s \xi_h \psi(Z_t \lambda_h) \quad (7)$$

$$\psi(Z_t \lambda_h) = \left[1 + \exp \left(\lambda_{h,d,w} + \sum_{d=1}^1 \left[\sum_{w=1}^m \lambda_{h,d,w} Z_{t-d}^w \right] \right) \right]^{-1} \quad (8)$$

$$Z_{t-d} = \frac{[\varepsilon_{t-d} - E(\varepsilon)]}{\sqrt{E(\varepsilon^2)}} \quad (9)$$

$$\left(\frac{1}{2} \right) \lambda_{h,d,w} \sim \text{uniform}[-1,+1] \quad (10)$$

โดยที่ $\psi(Z_t \lambda_h)$ แสดงในสมการ (8) คือฟังก์ชันถ่ายโอนในรูปของฟังก์ชันซิกมอยด์แบบลอการิทึม (log-sigmoid function) จาก $y = 1/(1 + \exp(-x))$ และ $\xi = w$ คือค่าน้ำหนัก $\psi = g$ คือเป็นฟังก์ชันซิกมอยด์แบบลอการิทึม $Z_t \lambda_h = x_i$ เป็นตัวแปรนำเข้า สมการที่ (9) เป็นการแปลงค่ามาตรฐานของ ε เมื่อมีค่าสูงเกินกว่าปกติ ในข้อมูลนำเข้า แต่ละโหนด และ λ_h คือข้อมูลทุกค่าที่ใช้จะถูกแปลงตามสมการ (10)

5. ตัวแบบ ANN-EGARCH

ตัวแบบ ANN-EGARCH(q,p,s) ตามสมการที่ (11) จะถูกใช้ในการพยากรณ์ความผันผวน ตามการศึกษาของ Melike & Özgür (2009) ได้อธิบายถึงแบบจำลอง GARCH ที่เพิ่มเข้าไปใน ANN ในการคาดการณ์ผลตอบแทน ตลาดหลักทรัพย์ในอิสตันบูลมีความสมมาตร และมีประสิทธิภาพในการพยากรณ์ในลักษณะไม่เป็นเชิงเส้น ได้ดี แสดงดังในสมการที่ (11)-(14) นี้

$$\log \sigma_t^2 = \alpha + \sum_{i=1}^p \beta_i \log \sigma_{t-i}^2 + \sum_{j=1}^q \gamma_j g(z_{t-j}) + \sum_{h=1}^s \xi_h \psi(Z_t \lambda_h) \quad (11)$$

$$\psi(Z_t \lambda_h) = \left[1 + \exp \left(\lambda_{h,d,w} + \sum_{d=1}^1 \left[\sum_{w=1}^m \lambda_{h,d,w} Z_{t-d}^w \right] \right) \right]^{-1} \quad (12)$$

$$Z_{t-d} = \frac{[\varepsilon_{t-d} - E(\varepsilon)]}{\sqrt{E(\varepsilon^2)}} \quad (13)$$

$$\left(\frac{1}{2} \right) \lambda_{h,d,w} \sim \text{uniform}[-1,+1] \quad (14)$$

กำหนดให้ $z_t = \varepsilon_t / \sigma_t$ คือ ผลกระทบของเหตุการณ์ไม่คาดฝันที่ส่งกระทบต่อฟังก์ชัน $g(z_t)$ ในทางบวกหรือทางลบ

วิธีการทดลอง

1. ข้อมูล

ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลอนุกรมเวลาดัชนีตลาดหลักทรัพย์แห่งประเทศไทย (SET) จากเว็บไซต์ตลาดหลักทรัพย์แห่งประเทศไทย (www.set.or.th) เป็นข้อมูลอนุกรมเวลารายวัน ตั้งแต่วันที่ 5 มกราคม 2547 ถึง 31 สิงหาคม 2559 จำนวน 3092 ค่า จากรูปที่ 1 แสดงให้เห็นว่า SET มีแนวโน้มและการเปลี่ยนแปลงของข้อมูลขึ้นลงอยู่ตลอดเวลาอย่างรวดเร็ว ลักษณะเคลื่อนไหวของข้อมูลไม่คงที่หรือไม่นิ่ง (non-stationary) เมื่อทำการแปลงข้อมูลให้อยู่ในรูปผลตอบแทนแบบลอการิทึม โดยใช้ logarithm return ซึ่งมีสมการคำนวณดังนี้ $r_t = \log P_t - \log P_{t-1}$ เมื่อ $t = 1, 2, \dots, T$ โดยที่ r_t เป็นผลตอบแทนแบบลอการิทึม P_t เป็นข้อมูลในปัจจุบันและ P_{t-1} เป็นข้อมูลย้อนหลังไปหนึ่งหน่วยเวลา แสดงให้เห็นว่าข้อมูลคงที่ (รูปที่ 2)


2. วิธีดำเนินการศึกษา

ในการศึกษาครั้งนี้ในขั้นตอนแรก ทำการประมาณหาตัวแบบ GARCH(q,p) และ EGARCH(q,p) ที่มีความเหมาะสมกับข้อมูลเพื่อใช้ในการสร้าง ANN-GARCH(q,p,s) และ ANN-EGARCH(q,p,s) แล้วเปรียบเทียบความแม่นยำโดยใช้เกณฑ์ ค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (root mean square error: RMSE) ดังสมการ (15) และค่าเปอร์เซ็นต์ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (mean absolute percentage error: MAPE) ดังสมการ (16) ในการทดสอบประสิทธิภาพและความแม่นยำของตัวแบบ เมื่อค่า $MAPE \leq 10\%$ นั่นคือ ค่าพยากรณ์ที่ได้จากตัวแบบมีความแม่นยำสูงมาก (Khangphukhieo et al., 2017)


$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{r}_t - r_t)^2} \quad (15)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{r}_t - r_t}{r_t} \right| \times 100 \quad (16)$$

โดยกำหนดให้ r_t เป็นค่าจริงของข้อมูลผลตอบแทนแบบลอการิทึม ณ เวลา t และ $\hat{r}_t$ เป็นค่าพยากรณ์ จากตัวแบบ และ n เป็นจำนวนของข้อมูล



รูปที่ 1. ลักษณะการเปลี่ยนอนุกรมเวลา SET index



รูปที่ 2. ผลตอบแทนแบบลอการิทึมของ SET index

ในการสร้างตัวแบบ มีตัวแปรอิสระจำนวน 6 ตัวแปร ซึ่งเป็นตัวแปรที่มีขนาดความสัมพันธ์สูงกับ SET มีค่าสหสัมพันธ์อยู่ระหว่าง 0.747-0.939 แสดงดังตารางที่ 1 เป็นดัชนีตลาดหลักทรัพย์ในต่างประเทศ ได้แก่ Dow Jones Index (DJIA), Nasdag New York (Nasdag), Financial Times London (FTL), KLSE Composite Malaysia (KLSE), PSE Composite Philippines (PSE) และ KSE Composite South Korea (KSE) จากตารางที่ 1 ยังแสดงให้เห็นว่าตัวแปรอิสระมีความสัมพันธ์กันสูง ซึ่งเกิดปัญหา multicollinearity เมื่อพิจารณาจากค่าแฟคเตอร์ความแปรปรวนขยายตัว (variance inflation factor: VIF) แต่การเกิดปัญหานี้ไม่ส่งผลต่อการทำงานของวิธี ANN เนื่องจากการกำหนดความสัมพันธ์ระหว่าง รูปแบบข้อมูลนำเข้ากับข้อมูลผลลัพธ์ ซึ่งเรียนรู้จากข้อมูลที่มีอยู่ จึงมีประสิทธิภาพในการคำนวณและจดจำในกรณีที่มีจำนวนข้อมูลมาก (Mahipani, 2012) โดยตัวแปรอิสระเหล่านี้ถูกใช้เป็นข้อมูลนำเข้าในการสร้างตัวแบบ ANN-GARCH และ ANN-EGARCH

ตารางที่ 1. ค่าสหสัมพันธ์ของ SET และตัวแปรอิสระ

Variables	DJIA	Nasdag	FTL	KLSE	PSE	KSE	VIF
SET	0.8818	0.8892	0.7465	0.8960	0.9394	0.7631	
DJIA	-	0.9643	0.8376	0.7953	0.8816	0.6764	27.3520
Nasdag		-	0.7499	0.7991	0.9046	0.6742	22.3600
FTL			-	0.7452	0.7394	0.7404	5.5690
KLSE				-	0.9015	0.8866	9.7610
PSE					-	0.7845	10.7670

ผลการทดลอง

ผลการวิเคราะห์ค่าสถิติพรรณนาจากตารางที่ 2 แสดงค่าสถิติของ Log return ของ SET มีค่าเฉลี่ย 0.0217 มีค่าต่ำสุดเท่ากับ -16.0600 ค่าสูงสุด 10.5800 มีค่าความโด่งเท่ากับ 13.6029 แสดงให้เห็นว่ามีความโด่งสูงผิดปกติ มีค่าความเบ้เท่ากับ -0.9113 แสดงให้เห็นว่าเบ้ซ้าย และตัวแปรอิสระ มีค่าเฉลี่ยอยู่ระหว่าง 0.0131 - 0.0535 มีค่าต่ำสุดอยู่ระหว่าง -229.9972 ถึง -34.838 ค่าสูงสุด 36.5323 - 230.7088 จากค่าความโด่งยังแสดงให้เห็นว่าตัวแปรอิสระมีความโด่งสูงผิดปกติ และแสดงให้เห็นว่าเบ้ซ้ายจำนวน 2 ตัวแปร และเบ้ขวาจำนวน 4 ตัวแปร เมื่อทำการทดสอบความนิ่งด้วยสถิติ augmented dickey-fuller test (ADF) พบว่าทุกตัวแปรในการศึกษาครั้งนี้มีความนิ่ง จากการทดสอบการแจกแจงแบบปกติด้วยสถิติทดสอบ jarque-bera (JB test) แสดงให้เห็นว่าทุกตัวแปรไม่มีการแจกแจงแบบปกติ

ตารางที่ 2. สถิติพรรณนาผลตอบแทนแบบลอการิทึมของ SET และตัวแปรอิสระ

Variables	Minimum	Maximum	Mean	Skewness	Kurtosis	JB test (Sig.)	ADF
Log return SET	-16.0600	10.5800	0.0217	-0.9113	13.6029	< 0.0001	-9.1323
DJIA	-229.9972	230.7088	0.0180	0.0403	447.7576	< 0.0001	-12.3590
Nasdag	-70.6853	65.0164	0.0302	-0.0503	26.5677	< 0.0001	-19.7160
FTL	-34.8384	36.5323	0.0131	0.3357	48.0016	< 0.0001	-16.7610
KLSE	-51.9773	50.2394	0.0173	-0.0169	25.3970	< 0.0001	-21.9260
PSE	-102.9983	104.1932	0.0535	0.0177	19.1727	< 0.0001	-22.5870
KSE	-71.8634	74.1830	0.0292	0.1419	50.7293	< 0.0001	-20.2220

หมายเหตุ: สถิติทดสอบ jarque-bera ที่ได้เทียบกับค่าวิกฤต chi-square องศาความเป็นอิสระเท่ากับ 2 ภายใต้อสมมติฐานการทดสอบคือ ข้อมูลอนุกรมเวลาไม่มีการแจกแจงแบบปกติ

จากการกำหนดสมการค่าเฉลี่ย (mean equation) ด้วย ARMA(1,1) และทำการทดสอบนำข้อมูลความคลาดเคลื่อนกำลังสองจากตัวแบบ ARMA(1,1) ด้วยสถิติ Ljung-box Q พบว่ามีอิทธิพลของ ARCH นั้น แสดงให้เห็นว่าข้อมูลอนุกรมเวลามีอิทธิพลของ ARCH ตามตารางที่ 3 จากการทดสอบค่ามาตรฐานของค่าคลาดเคลื่อน และค่ามาตรฐานของค่าคลาดเคลื่อนกำลังสอง ด้วยสถิติทดสอบ Ljung-box (Q-statistics) พบว่าไม่มีความสัมพันธ์กันในตัวแบบ ดังนั้น ตัวแบบที่ทำการประมาณขึ้นมีความเหมาะสม สามารถนำตัวแบบ GARCH และ EGARCH ไปใช้กับอนุกรมเวลาของดัชนี SET ได้ ในการเลือกตัวแบบ GARCH และ EGARCH เพื่อใช้ในการสร้างตัวแบบไฮบริดจ์ใช้เกณฑ์ข้อสนเทศของอาไคเคะ (akaike information criterion: AIC) เมื่อพบว่าตัวแบบมีความเหมาะสมมากกว่าหนึ่งตัวแบบ จากตารางที่ 3 แสดงให้เห็นว่าค่า AIC มีค่าแตกต่างกันเล็กน้อย ซึ่งในการศึกษาครั้งนี้ได้เลือก GARCH(1,1) และ EGARCH(2,2) ที่มีค่า AIC น้อยที่สุดเพื่อใช้ในการสร้างตัวแบบไฮบริดจ์ต่อไป

ตารางที่ 3. ผลการทดสอบความเหมาะสมของตัวแบบ GARCH(q,p) และตัวแบบ EGARCH(q,p)

Models	Standardized residual		Standardized residual squared		AIC
	Q-statistics	Sig.	Q-statistics	Sig.	
GARCH(1,1)	5.7600	0.6442	0.3439	0.9996	3.1525
GARCH(1,2)	5.9180	0.5412	0.2816	0.9993	3.1531
GARCH(2,1)	5.7580	0.6457	0.3238	0.9990	3.1532
GARCH(2,2)	11.8500	0.2084	0.3394	1.0000	3.1537
EGARCH(1,1)	6.0205	0.4731	0.1508	1.0000	3.1152
EGARCH(1,2)	6.5544	0.1773	0.2858	1.0000	3.1152
EGARCH(2,1)	8.7656	0.2472	0.2775	1.0000	3.1114
EGARCH(2,2)	6.7004	0.1245	0.5968	1.0000	3.1020

ผลจากตารางที่ 4 แสดงการประมาณค่าพารามิเตอร์ของสมการความแปรปรวน จากตัวแบบ GARCH(1,1) GARCH(1,2) EGARCH(2,1) และ EGARCH(2,2) จากการทดสอบค่าพารามิเตอร์ของตัวแบบ GARCH(1,2) พบว่าค่าพารามิเตอร์ β_2 ไม่มีนัยสำคัญทางสถิติ ดังนั้นตัวแบบ GARCH(1,2) จึงมีลำดับ q และ p เป็น GARCH(1,1) เมื่อทดสอบค่าพารามิเตอร์ตัวแบบ EGARCH(2,2) พบว่าค่าพารามิเตอร์ β_1 ไม่มีนัยสำคัญทางสถิติ และพบว่าเหตุการณ์ไม่คาดฝันในอดีตทั้งทางบวกและทางลบมีผลต่อ SET แต่ค่าพารามิเตอร์ในตัวแบบ EGARCH(2,1) มีนัยสำคัญทางสถิติ และพบว่าเหตุการณ์ไม่คาดฝันในอดีตทั้งทางบวกมีผลต่อ SET ดังนั้นผู้วิจัยจึงนำตัวแบบ GARCH(1,1) และ EGARCH(2,1) ใช้เป็นตัวแบบพื้นฐานในการสร้างตัวแบบ ANN-GARCH และ ANN-EGARCH ต่อไป

ตารางที่ 4. ผลการประมาณค่าพารามิเตอร์ของตัวแบบ GARCH(q,p) และตัวแบบ EGARCH(q,p)

Parameters	GARCH(1,1)	GARCH(1,2)	EGARCH(2,2)	EGARCH(2,1)
ω	6.7404**	5.8140**	5.0409**	4.6984**
α_1	7.9228**	6.0119**	-10.6084**	-8.1515**
α_2	-	-	-2.5985**	3.6302**
β_1	42.5694**	5.5729**	-0.1144	101.0257**
β_2	-	0.3030	59.5946**	-
γ_1	-	-	7.0166**	4.3353**
γ_2	-	-	8.1265**	0.9784

หมายเหตุ : ** หมายถึงมีนัยสำคัญที่ระดับนัยสำคัญ 0.01

ในการสร้างตัวแบบ ANN-GARCH และ ANN-EGARCH ตัวแปรอิสระทุกตัวถูกใช้เป็นตัวแปรนำเข้าพร้อมกัน โดยใช้โครงข่ายที่มีจำนวน 1 ชั้นซ่อน และใช้ข้อมูล 90% แรกของข้อมูลในการศึกษาเพื่อฝึก (training) และทดสอบ (test) โครงข่าย จากนั้นใช้ข้อมูลที่เหลือ 10% เพื่อเปรียบเทียบผลการพยากรณ์ที่ได้จากโครงข่าย และทำการปรับจำนวนของนิวรอนในชั้นซ่อน จาก 1 ถึง 30 นิวรอน จำนวนรอบในการฝึกการเรียนรู้สูงสุด 1,000 รอบ ค่า MSE ในการฝึกการเรียนรู้ของโครงข่ายเท่ากับ 0.0000 อัตราการเรียนรู้ (learning rate) เท่ากับ 0.0001

ตารางที่ 5. ประสิทธิภาพของตัวแบบ ANN-GARCH(q,p,s) และตัวแบบ ANN-EGARCH(q,p,s)

Neural (s)	Training models						Testing models			
	ANN-GARCH			ANN-EGARCH			ANN-GARCH		ANN-EGARCH	
	Epoch	Time	MSE	Epoch	Time	MSE	RMSE	MAPE	RMSE	MAPE
5	102	2.01	0.0015	126	2.18	0.0012	0.0338	4.2450	0.0291	3.7330
10	113	2.10	0.0012	164	3.14	0.0011	0.0321	4.2156	0.0262	3.3987
15	134	2.33	0.0010	163	3.03	0.0010	0.0312	3.9718	0.0325	3.8315
20	125	2.25	0.0009	105	2.02	0.0009	0.0318	4.1514	0.0369	4.7333
25	181	3.33	0.0008	135	2.37	0.0009	0.0272	3.4726	0.0287	3.6988
30	131	1.06	0.0009	152	2.56	0.0008	0.0288	3.6366	0.0354	3.9694

ผลจากตารางที่ 5 พบว่าในขั้นตอนการฝึกตัวแบบ ANN-GARCH(1,1,s) มีค่า MSE อยู่ระหว่าง 0.0008-0.0015 โดยมีจำนวนรอบของการเรียนรู้อยู่ระหว่าง 102 - 181 รอบ ระยะเวลาในการเรียนรู้ของโครงข่าย 1.06 - 3.33

นาที่ และตัวแบบ ANN-EGARCH(2,2,s) มีค่า MSE อยู่ระหว่าง 0.0008-0.0011 โดยมีจำนวนรอบของการเรียนรู้อยู่ระหว่าง 105 - 164 รอบ ระยะเวลาในการเรียนรู้ของโครงข่ายอยู่ระหว่าง 2.02 - 3.14 นาที่ เมื่อใช้ข้อมูล 10% ในการทดสอบความแม่นยำของตัวแบบ โดยใช้ค่า RMSE และค่า MAPE พบว่าเมื่อเพิ่มจำนวนนิวรอนในชั้นซ่อนสูงสุด 30 นิวรอน ตัวแบบ ANN-GARCH(1,1,s) มีค่า RMSE อยู่ระหว่าง 0.0272 - 0.0338 และค่า MAPE อยู่ระหว่าง 3.4726-4.2450 แสดงให้เห็นว่าค่าพยากรณ์ที่ได้จาก ANN-GARCH(1,1,s) มีความแม่นยำสูง และตัวแบบ ANN-EGARCH(2,2,s) พบว่ามีค่า RMSE อยู่ระหว่าง 0.0262 - 0.0369 และค่า MAPE อยู่ระหว่าง 3.3987 - 4.7333 แสดงให้เห็นว่าค่าพยากรณ์ที่ได้จาก ANN-EGARCH(2,2,s) มีความแม่นยำสูงเช่นเดียวกัน

วิจารณ์และสรุปผลการทดลอง

ผลจากการศึกษาครั้งนี้ได้นำเสนอผลการเปรียบเทียบประสิทธิภาพความแม่นยำตัวแบบ ANN-GARCH กับ ANN-EGARCH ในการพยากรณ์ความผันผวนของดัชนี SET โดยใช้เกณฑ์ในการวัดประสิทธิภาพความแม่นยำด้วยค่า RMSE และ MAPE พบว่าทั้ง 2 ตัวแบบมีความแม่นยำในการพยากรณ์สูง และตัวแบบ ANN-EGARCH(2,2,10) ให้ผลความแม่นยำในการพยากรณ์สูงกว่าตัวแบบ ANN-GARCH(1,1,25) เล็กน้อย อย่างไรก็ตาม ANN-GARCH(1,1,25) มีจำนวนนิวรอนในโครงข่ายมากกว่า ANN-EGARCH(2,2,10) ซึ่งอาจทำให้ระยะเวลาการฝึกการเรียนรู้ของโครงข่ายเพิ่มขึ้น ซึ่งสอดคล้องกับงานวิจัยของ Lu et al. (2016) เป็นผลจากข้อมูลที่ใช้ในการสร้างตัวแบบ มี leverage effect นั่นคือ เมื่อเกิดเหตุการณ์ไม่คาดฝันด้านลบหรือด้านบวก ส่งผลต่อดัชนีในตลาดหลักทรัพย์ไม่เท่ากัน ซึ่งตัวแบบ EGARCH สามารถอธิบายข้อมูลอนุกรมเวลาที่มี leverage effect ได้ดี และผลจากการศึกษายังแสดงให้เห็นว่าตัวแบบ ANN-GARCH และ ANN-EGARCH เป็นอีกหนึ่งวิธีที่สามารถรวมตัวแปรที่มีความสัมพันธ์สูง ในการพยากรณ์ความผันผวนที่มีความแม่นยำ และตัวแบบที่ได้มีความยืดหยุ่นสูง แม้ข้อมูลไม่เป็นเชิงเส้นและมีขนาดใหญ่ ซึ่งข้อจำกัดในการใช้ ANN คือการเพิ่มข้อมูลนำเข้ามากเกินไป ทำให้โครงข่ายใช้เวลานานในขั้นตอนการเรียนรู้ ดังนั้น การเพิ่มจำนวนของข้อมูลนำเข้า ควรคำนึงถึงความสำคัญในการอธิบายผลลัพธ์ และความจำเป็นในการใช้งานของนักวิจัย ข้อเสนอแนะในการศึกษาในครั้งต่อไปคือการประยุกต์ใช้ตัวแบบในกลุ่มของ GARCH ยังมีตัวแบบอื่นที่มีประสิทธิภาพ ซึ่งขึ้นอยู่กับลักษณะของข้อมูลและวัตถุประสงค์ของผู้ใช้

กิตติกรรมประกาศ

คณะผู้วิจัยขอขอบคุณภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม ที่ให้อาณัติให้ห้องปฏิบัติการคอมพิวเตอร์ในการประมวลผลข้อมูล และขอขอบพระคุณ รองศาสตราจารย์ ดร.บังอร กุมพล ที่ให้คำแนะนำในการทำงานวิจัยครั้งนี้

เอกสารอ้างอิง

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Donaldson, R. G. & Kamstra, M. (1997). An artificial neural network-GARCH model for international stock return volatility. *Journal of Empirical Finance*, 4(1), 17-46. [https://doi.org/10.1016/S0927-5398\(96\)00011-4](https://doi.org/10.1016/S0927-5398(96)00011-4)
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987-1007. <https://doi.org/10.2307/1912773>
- Khangphukhico, W., Busababadhin, P. & Kumphon, B. (2017). Forecasting volatility of gold price with artificial neural networks. *Burapha Science Journal*, 20(1), 125-134. (in Thai)
- Khashei, M., Bijari, M. & Ardali G. A. R. (2009). Improvement of auto-regressive integrated moving average models using fuzzy logic and artificial neural networks (ANNs). *Neurocomputing*, 72(4-6), 956-967. <https://doi.org/10.1016/j.neucom.2008.04.017>
- Kristjanpoller, W., Fadic, A. & Marcel, C. M. (2014). Volatility forecasting using hybrid neural network model. *Expert Systems with Applications*, 41(5), 2437-2442. <https://doi.org/10.1016/j.eswa.2013.09.043>
- Kristjanpoller, W. & Marcel, C. M. (2016). Forecasting volatility of oil price using an artificial neural network-GARCH model. *Expert Systems with Applications*, 65, 233-241. <https://doi.org/10.1016/j.eswa.2016.08.045>
- Lin, C. (2015). *Build prediction models for gold prices based on back-propagation neural network*. pp. 155-158. In The 2015 Internal Conference on Modelling, Simulation and Applied Mathematics, 23-24 August 2015, Phuket, Thailand.
- Lu, X., Que, D. & Cao, G. (2016). Volatility forecast based on the hybrid artificial neural network and GARCH-type models. *Procedia Computer Science*, 91, 1044-1049. <https://doi.org/10.1016/j.procs.2016.07.145>
- Mahipan, K. (2012). *The unemployment rate forecasting in Thailand* (M.Sc. thesis) Department of Mathematics, Faculty of Science, Mahasarakham University, Mahasarakham. (in Thai)
- Melike, B. & Özgür, Ö. E. (2009). Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul stock exchange. *Expert Systems with Applications*, 36, 7355-7362. <https://doi.org/10.1016/j.eswa.2008.09.051>

- Qiu, M., Song, Y. & Akagi, F. (2016). Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market. *Chaos, Solitons & Fractals*, 85, 1-7. <https://doi.org/10.1016/j.chaos.2016.01.004>
- Srikaew, A. (2009). *Computational Intelligence*. Bangkok: Charansnitwong Co., Ltd. (in Thai)
- Sónia, R. B. (2015). Forecasting volatility in gold returns under the GARCH, IGARCH and FIGARCH frameworks: New evidence. *Physica A: Statistical Mechanics and its Applications*, 38(4), 355-364.
- Suebpongsakorn, A. & Wisagarn, S. (2016). Comparing the Accuracy of forecasting Methods for the B/\$ Exchange Rate between ARIMA-GARCH and ARIMA-EGARCH models. *University of the Thai Chamber of Commerce Journal Humanities and Social Sciences*, 32(2), 121-135. (in Thai)
- Wang, Y. & Wu, C. (2012). Forecasting energy market volatility using GARCH models: Can multivariate models beat univariate models?. *Energy Economics*, 34, 2167-2181. <https://doi.org/10.1016/j.eneco.2012.03.010>
- Wei, Y., Wang, Y. & Huang, D. (2010). Forecasting crude oil market volatility: Further evidence using GARCH-class models. *Energy Economics*, 32, 1477-1484. <https://doi.org/10.1016/j.eneco.2010.07.009>
- Zhang, G., Patuwo, B. E. & Michael, Y. Hu. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)